

**Proyecciones de cambio climático para la
precipitación en América tropical mediante técnicas
de *downscaling* estadístico**

**Memoria presentada para optar al grado de
Doctor en Física**

Por:

REINER PALOMINO LEMUS

Directoras:

Dra. María Jesús Esteban Parra

Dra. Yolanda Castro Diez



Editorial: Universidad de Granada. Tesis Doctorales
Autor: Reiner Palomino Lemus
ISBN: 978-84-9125-399-0
URI: <http://hdl.handle.net/10481/41555>

Proyecciones de cambio climático para la precipitación en América tropical mediante técnicas de *downscaling* estadístico

Directoras:

Dra. María Jesús Esteban Parra

Profesora Titular
Universidad de Granada

Dra. Yolanda Castro Diez

Profesora Titular
Universidad de Granada

Memoria presentada para optar al grado de:

Doctor en Física

Por:

REINER PALOMINO LEMUS

Licenciado en Matemáticas y Física

Granada, Noviembre de 2015

Agradecimientos

En principio quiera dar gracias a Dios, por darme nuevamente una oportunidad de llegar hasta aquí, llegar a hacer quien soy hoy en día, por haberme dado la sabiduría y la fortaleza para que fuera posible alcanzar este triunfo. Además le doy gracias a Dios por brindarme una familia tan maravillosa.

En mi proceso de formación, son muchas las personas a las que quiero dar gracias, ya que, he recibido su apoyo y acompañamiento, en este difícil camino, y por así decirlo, hacer que este sea más llevadero para mí. Por ello, quiero decir que sin la ayuda y apoyo incondicional de aquellas personas no hubiese sido posible terminar este trabajo. Así, que a provecho de esta oportunidad para expresar mi gratitud a quienes sin lugar a duda, han conformado la fuerza vital para la realización de esta investigación.

En primer lugar quiero expresar mi gratitud a mis directoras María Jesús Esteban Parra, Yolanda Castro Diez, y también a la Dra. Sonia Raquel Gámiz Fortis, por sus consejos, dedicación, entrega, disposición, guía, ánimo y apoyo, tanto en lo laboral como en lo personal y humano “A mis Tutoras Mil Gracias por Todo”. También quiero destacar mi gratitud a la Dra. María Jesús Esteban Parra, por el enorme apoyo científico brindado. No podría dejar de mencionar a mis amigos Mati, Dani, Enrique, Maria, Ana, Andy, Borja, Penélope, Clemente y Farid, con los que he compartido momentos muy agradables. De ustedes me llevo muy buenos recuerdos y quiero que sepan que en Colombia cuentan con un amigo más. Un huequecito aquí se merece, mi buen amigo Jose, a quien le agradezco el brindarme su amistad y las ayudas con MATLAB (Viejo Jose, muchas gracias, me has ayudado mucho a la hora de darle un buen empujón a esta tesis).

Quisiera agradecer a la UNIVERSIDAD TECNOLÓGICA DEL COCÓ y a COLCIENCIAS, por darme la oportunidad de realizar mis estudios de Doctorado otorgándome

la BECA para mi formación. De igual forma quiero agradecer especialmente al Dr. Eduardo García Vega por su apoyo incondicional desde la administración de la UTCH, para poder alcanzar este logro.

Deseo dar las gracias a mis compañeros del Grupo de Investigación en Energías Renovables y Meteorología de la UTCH (Edinson, Nancy, Liliana, Samir) y en especial al profe. William Murillo López quien me brindó la oportunidad de encaminarme en el mundo de la investigación. Dr. Murillo quiero darle las gracias por el apoyo (profesional y personal) incondicional que me ha dado, el cual ha sido fundamental para lograr este objetivo en mi vida.

Un agradecimiento especial quiero dar al Dr. José Daniel Pabón, quien ha contribuido enormemente en mi formación académica y por consiguiente en la realización de esta investigación.

También quiero expresar mi gratitud a las Dras. Alicia Ríos Hurtado y Lucy Marisol Rentería, quienes me han apoyado y guiado durante este proceso de formación. Igualmente quiero agradecer por sus consejos y apoyo brindado a mis colegas profesores de la UTCH, en especial a los profesores del Programa de Matemáticas y Física y al Profesor Gonzalo Aragón.

Quiero agradecer a todos mis familiares y amigos que han aportado su granito de arena para ayudarme a finalizar esta etapa de formación en mi vida. Aquí quiero agradecer a mi amigo, compañero de batallas y hermano de estudios Samir Córdoba Machado, con quien he recorrido todo este camino y me ha brindado siempre su ayuda y apoyo cuando la he necesitado “animo Paquete ya casi terminamos”.

Dejo para el final lo más importante, agradecerle a mi familia todo su apoyo y sacrificio para que llegue este momento. A mi madre, que tanto ha luchado por mí. Todo lo que he logrado es gracias a su esfuerzo y sacrificio. Gracias madre por hacerme creer en tus sueños, tal como tú dices es, por eso hoy diré en tu nombre: fui, vi y vencí. También a mis hermanas. A mi esposa Erika Pinilla Palacios y a mis dos adoradas hijas Isis Dayana e Isabel Cristina les agradezco por su apoyo, amor y comprensión, ya que han sido vitales para poder alcanzar este logro en mi vida.

A la Tierra de Todos y de Nadie, Mi Tierrita (El Chocó)

Tabla de contenido

RESUMEN	v
LISTA DE FIGURAS	ix
LISTA DE TABLAS	xvii
1. INTRODUCCIÓN	1
1.1. Los modelos de circulación general	1
1.2. Proyecto de Intercomparación de Modelos Acoplados (CMIP)	3
1.3. Downscaling	9
1.4. América tropical	12
1.5. Objetivos del trabajo	13
2. ÁREA DE ESTUDIO Y BASES DE DATOS	15
2.1 Área de estudio	15
2.2 Bases de datos	20
2.2.1 Datos de precipitación	20
2.2.2 Datos de presión a nivel del mar	22
2.2.3 Datos de índices de Teleconexión	23
2.3 Modelos de Circulación General (GCM)	24
2.3.1 Simulaciones de clima presente de los Modelos de Circulación General	24
2.3.2 Proyecciones de los Modelos de Circulación General	25
3. METODOLOGÍA	29

1 | INTRODUCCIÓN

3.1	Análisis de Componentes Principales	29
3.2	Métodos de downscaling estadístico	35
3.2.1	Métodos de regresión multivariada	35
3.2.2	Método de regresión por componentes principales (PCR)	37
3.2.3	Intervalos de confianza: Bootstrapping	38
3.3	Diagramas de Taylor	39
4.	VALIDACIÓN DE LA SLP EN LOS MODELOS DEL CMIP5	43
4.1	Introducción	43
4.2	Validación de la SLP mensual	44
4.2.1	Análisis de los campos medios y de la varianza	44
4.2.2	Análisis de los modos de variabilidad mensual	48
4.3	Validación de la SLP estacional	54
4.3.1	Análisis de los campos medios y de la varianza	55
4.3.2	Análisis de los modos de variabilidad estacional	63
4.4	Conclusiones	78
5.	DOWNSCALING DE LA PRECIPITACIÓN	81
5.1	Modos de variabilidad de la SLP estacional	81
5.2	Relación entre los modos de variabilidad de la SLP y la precipitación	92
5.2.1.	Resultados para cada punto de rejilla	93
5.2.2.	Resultados para cada zona seleccionada	99
5.3	Modelos de Downscaling Estadístico para la precipitación	102
5.3.1.	Resultados para cada punto de rejilla	103
5.3.2.	Resultados para cada zona seleccionada	106
5.4	Conclusiones	111
6.	PROYECCIONES DE LA PRECIPITACIÓN EN ESCENARIOS DE CAMBIO CLIMÁTICO	113
6.1	Downscaling de la precipitación en clima presente	114
6.2	Evaluación de simulaciones históricas	116
6.3	Evaluación de los cambios proyectados en la precipitación media estacional	123
6.3.1	Cambios proyectados en la precipitación para el invierno (DEF)	124
6.3.2	Cambios proyectados en la precipitación para la primavera (MAM)	127
6.3.3	Cambios proyectados en la precipitación para la verano (JJA)	131

6.3.4 Cambios proyectados en la precipitación para la otoño (SON)	135
6.4 Análisis de la incertidumbre	140
6.5 Conclusiones	149
7 CONCLUSIONES	153
APPENDIX A. DIFERENCIAS ENTRE LAS PRECIPITACION SIMULADA POR LOS GCM Y LA OBSERVADA POR GCPCC	159
APPENDIX B. CAMBIOS PROYECTADOS EN LA PRECIPITACIÓN MEDIA ESTACIONAL SIMULADA	165
8 BIBLIOGRAFÍA	179

RESUMEN

El cambio climático puede tener importantes repercusiones en el clima de muchas partes del planeta. El último informe del IPCC, AR5, analiza los potenciales cambios en el clima ante distintos escenarios de emisión a partir de las salidas de los Modelos de Circulación General (GCMs) incluidos en la 5ª fase del Proyecto de Intercomparación de modelos climáticos (CMIP5). Los GCMs son una herramienta primordial en el estudio del cambio climático pero adolecen de una suficiente resolución espacial para explorar y distinguir la variada respuesta del clima, en particular en regiones con gran diversidad climática como es el caso de América tropical, aportando una información en muchos casos inadecuada para estudiar los impactos del cambio climático en sistemas tan sensibles y vulnerables como los de esta zona. Existe un acuerdo general sobre la respuesta térmica del sistema climático ante los forzamientos antropogénicos, mostrando una gran homogeneidad espacial. Por el contrario, la respuesta de la precipitación ante estos forzamientos presenta una mayor heterogeneidad e incertidumbre, siendo esta variable la que requiere una mejora en sus proyecciones.

En general la vasta resolución de los GCMs puede ser resuelta mediante las llamadas técnicas de regionalización o downscaling. Para América tropical existen pocos estudios dedicados a explorar el cambio climático a escala regional. Así pues, el objetivo fundamental de esta tesis es la obtención mediante downscaling estadístico de proyecciones de cambio climático para la precipitación estacional en toda el área de América tropical, comprendida entre las latitudes 30°N y 30°S, a partir de las salidas de 20 GCMs del CMIP5.

La primera parte de la tesis se dedica a presentar las principales características climáticas de la zona de estudio, la base de datos utilizada y la metodología empleada. La base de datos observacional de precipitación es la de Global Precipitation Climatology Centre, GPCP, consistente en una rejilla en base mensual con resolución espacial de 0.5° por 0.5°. La metodología

RESUMEN

empleada para la obtención de los modelos de downscaling estadístico (DS) se basa en la Regresión de Componentes Principales, usando como campo predictor la presión a nivel del mar (SLP) y como predictando la precipitación estacional en cada punto de la rejilla. Para la obtención del modelo DS se usaron los datos de SLP del NCEP en el periodo 1950-2010. En este capítulo se describe también brevemente las técnicas de bootstrapping empleadas en la evaluación de la incertidumbre de los modelos así como el test de Wilcoxon-Mann-Whitney usado en la detección de la significación de los cambios.

En cuanto a los resultados, en primer lugar se ha realizado una evaluación de las salidas de la SLP por 40 modelos del CMIP5 en el periodo histórico (1950-2005) como paso previo en la obtención de proyecciones regionales de cambio climático para la precipitación de la zona de estudio, tanto a escala mensual como estacional. Se ha analizado en detalle las diferencias del campo medio y de la varianza, de la SLP de cada modelo respecto a la SLP del NCEP, así como una comparación de sus principales modos de variabilidad, caracterizados mediante los dos primeros vectores propios rotados de un Análisis de Componentes Principales. En general, los GCMs reproducen el patrón espacial de este campo medio, sin que haya desviaciones de más de 10 hPa, con cierto predominio de subestimaciones de la SLP en el Pacífico tropical occidental, y sobrestimaciones en el área continental occidental, sobre todo los Andes. Los principales modos de variabilidad de la SLP en los GCMs representan de forma aceptable las principales características de la SLP del NCEP, tanto a nivel mensual como estacional, siendo difícil establecer un rango que determine qué modelos del CMIP5 son mejores en la reproducción de los mismos de forma general, pues hay diferencias en el comportamiento de los modelos según la época del año. Por ello, la selección final de GCMs se ha establecido en función de la disponibilidad de salidas de los mismos para los escenarios RCP2.6, 4.5 y 8.5.

El capítulo 5 se dedica al desarrollo de los modelos de downscaling estadístico (DS) para la precipitación estacional en Sudamérica mediante la técnica de regresión por componentes principales (PCR), siguiendo fundamentalmente el esquema desarrollado por Li and Smith (2009) y Palomino-Lemus et al. (2015). Para ello, se han analizado los modos de variabilidad de la presión a nivel del mar (SLP) estacional en la región tropical y su influencia en la precipitación de Sudamérica, son usados como variables predictoras de la precipitación en los modelos de regresión, calibrados y validados en los periodos 1950-1993, 1994-2010, respectivamente. La habilidad de los modelos DS generados ha sido evaluada tanto a escala espacial de rejilla, como a escala regional para diferentes zonas seleccionadas en el área de estudio. El DS muestra un funcionamiento adecuado en extensas áreas dentro del dominio analizado, más reducidas cuando se analiza el

periodo de validación. Esto puede ser debido a la peor cobertura de datos en el GPCC en determinadas áreas (áreas selváticas del Amazonas y Orinoco, y Andes) y, en particular en los últimos años. Además, el modelo muestra una habilidad en la reproducción de la precipitación más modesta durante la primavera, lo cual puede estar relacionado con modulaciones de los patrones atmosféricos asociadas al paso de la Zona de Convergencia Intertropical (ITCZ). Aún así el modelo reproduce de forma muy adecuada las características del campo medio de precipitación para todas las estaciones del año. En general, las mayores discrepancias y errores tienden a presentarse en áreas y épocas con una precipitación muy baja (este de los Andes, noroeste de México, sur de Bolivia), en las que elevados cambios en porcentaje implican, sin embargo, variaciones pequeñas en valor absoluto.

Adicionalmente, se ha desarrollado el modelo DS para 10 zonas con una aceptable cobertura de datos, características climáticas bien definidas y en áreas donde el DS realizado en cada punto de rejilla funciona adecuadamente. Los resultados obtenidos para estas zonas muestran una buena habilidad del DS, particularmente para las estaciones de invierno y verano. Para algunas zonas, el DS llega a simular valores extremos de la precipitación.

En el Capítulo 6 se analizan los resultados de los modelos de downscaling estadístico en la obtención de las proyecciones futuras de la precipitación (para la treintena 2071-2100) en la región de América tropical, utilizando las simulaciones de la SLP de 20 GCMs del CMIP5, para los experimentos históricos, y las trayectorias de representación representativas RCP2.6, RCP4.5 y RCP8.5, comparándolos con los cambios de la precipitación proyectados directamente por los GCMs. Tras una recalibración del modelo DS en el periodo 1950-2100, se ha analizado cómo el DS aplicado a los 20 GCMs seleccionados del CMIP5 en clima presente reproduce los datos observacionales del GPCC en el periodo de referencia para clima presente 1971-2000. La principal consecuencia de este análisis es la adecuada representación del campo medio de la precipitación estacional mediante el DS, de tal forma que, considerando el promedio del área para todos los DS, menos de aproximadamente el 20% del área en estudio, presenta cambios significativos de la precipitación DS respecto a las observaciones, siendo además, en general de cuantía pequeña. El DS corrige de forma apreciable importantes desviaciones de la precipitación media mostradas por los diversos GCMs, dando una representación más acertada del campo medio de precipitación sobre el área de estudio, además de mejorar la resolución de las mismas.

Para el periodo 2071-2100 se han obtenido proyecciones regionalizadas de la precipitación en cada estación del año mediante el DS de los 20 GCMs seleccionados con las trayectorias de

RESUMEN

concentración representativas RCP2.6, RCP4.5 y RCP8.5. La evaluación de los cambios proyectados se ha obtenido a través de la diferencia porcentual de la precipitación DS en el periodo 2071-2100 respecto a la precipitación DS en el periodo presente 1971-2100. En general, la extensión del área afectada por cambios significativos así como la intensidad de los mismos aumenta al aumentar el forzamiento radiativo. Los resultados para los RCP2.6 y RCP4.5 son muy parecidos en algunos modelos, siendo en estos modelos, en general pequeños. Los cambios son más claros para el RCP8.5, en todas estaciones del año, con marcadas y extensas variaciones, coherentes para el DS de un número considerable de GCMs.

El invierno es la estación que parece tener menos cambios, la señal hacia un descenso de la precipitación es bastante coherente para gran parte de México, con descensos del 30 al 90% y en el oeste de Colombia con ascensos que pueden llegar a ser del 80%. Para el verano, se acentúan los cambios, estando casi toda el área afectada por cambios significativos bajo el RCP8.5. Para el RCP4.5 se encuentra un descenso muy intenso y coherente sobre una amplia zona en Brasil, desde aproximadamente los 10° S, 60°W. En el RCP8.5 este cambio se incrementa en área e intensidad. Se detecta también un aumento coherente en el norte de Sudamérica y Centroamérica con aumentos que llegan a un 60%. También muestra un aumento de la precipitación al norte de Argentina, que oscila entre el 30% -90%. En primavera destacan aumentos significativos en el noreste de Sudamérica y sur de Brasil, Paraguay y noreste de Argentina, y descensos en el centro y norte de Brasil y en el sur de Bolivia y noreste de Argentina. La zona este de Brasil presenta marcados descensos, del 70% en el RCP4.5 y demás del 80% en el RCP8.5. En otoño, destaca el marcado incremento de la precipitación en el noreste de Brasil, muy consistente en el RCP8.5, extendiéndose para el DS de algunos GCMs tanto hacia el norte como hacia el interior de Brasil, y que puede llegar a aumentos muy elevados (más del 80%) según la zona y el GCM.

En muchos casos, estas estimaciones contrastan de forma muy marcada con las de los GCMs, de tal forma que un GCM y su DS pueden mostrar cambios significativos muy opuestos. Como cabe esperar en el proceso de downscaling, el patrón espacial de cambios es menos uniforme que en los GCMs, pudiendo discernir comportamientos diferentes en zonas relativamente cercanas. Más aún, el DS tiende, en muchos casos, a mostrar un mejor acuerdo en los cambios proyectados (al menos en su signo) con diversos GCMs que estos directamente.

La incertidumbre de las proyecciones mediante DS se ha analizado a partir de los intervalos de confianza estimados mediante bootstrapping para las 10 zonas seleccionadas. En general, el DS de los modelos en clima presente se aproxima al valor medio de la precipitación, con independencia

de la zona y del GCM, con los valores medios de la precipitación observada normalmente dentro del rango intercuartílico del bootstrapping. También, de forma general, se tiene que un número apreciable de GCMs presentan valores muy altos o muy bajos respecto tanto al valor medio observacional como a las estimaciones DS, lo cual puede deberse a una inadecuada representación de los procesos físicos asociados a la precipitación y a la baja resolución de la topografía, de tal forma que el DS parece corregir estos importantes sesgos. Por otro lado, la amplitud de los intervalos de confianza al 95 %, tiende a mostrar un rango similar tanto para el presente como el futuro sin grandes diferencias entre los RCPs, aunque ligeramente mayor para el RCP8.5, lo que indicaría algo más de incertidumbre. Debe también destacarse que las amplitudes de las incertidumbres (intervalo de confianza) muy variables según modelo y zona, e incluso estación del año, de tal forma que tiende a ser más pequeñas en periodos y zonas húmedas, pudiendo oscilar entre menos del 20% a más del 150 %.

LISTA DE FIGURAS

- Figura 1.1. Evolución de los modelos climáticos en los últimos 35 años. Fuente: IPCC, 2001 (Resumen técnico, Cuadro 3, Fig. 1, p. 48).
- Figura 1.2. Resolución espacial de los modelos utilizados por el IPCC en los primeros cuatro informes. Fuente: IPCC 2007 (AR4 WG 1, Capítulo 1, pág 113, Fig. 1.4).
- Figura 1.3. Resolución de los modelos utilizados para los informes de evaluación del IPCC: izquierda AR4, derecha: AR5.
- Figura 1.4. Resumen esquemático de los experimentos de la CMIP5, por edición decadal (izquierda) y largas escalas temporales (derecha).
- Figura 1.5. Extensión de los RCPs (forzamiento radiativo y emisiones de CO₂ asociadas) más allá de 2100. ECP significa extended concentration pathway.
- Figura 2.1. Zona de estudio: a) Topografía. Fuente: NOAA (Amante, 2009). b) Mapa político.
- Figura 2.2. Tipos de climas según la clasificación climática de Köppen-Geiger para la zona de estudio. Fuente: Peel et al. (2007).
- Figura 2.3 Distribución espacial de la precipitación media anual (mm/año), calculada para una rejilla de 0.25°, con 13.382 estaciones ubicadas en la zona de estudio (datos del GPCC en diciembre de 2011).
- Figura 2.4. Número de estaciones por punto de rejilla de los datos del GPCC en julio de (a) 1950, (b) 1980 y (c) 2010.

Figura 2.5. Zonas seleccionadas dentro de la región de estudio para analizar los resultados de los modelos de downscaling estadístico para la precipitación.

Figura 4.1: Distribución espacial de las diferencias (hPa) entre los campos medios de la SLP de los 40 modelos de 1 C MIP5 y de 1 N CEP (SLPGCM-SLPNCEP), durante el periodo de 1950 -2005. Las áreas donde las diferencias no son significativas al nivel de confianza del 95% están marcadas por “.”.

Figura 4.2. Cociente entre el campo de varianzas de la SLP de 40 modelos del CMIP5 y del NCEP durante el periodo 1950 -2005. Las áreas donde los cocientes no son significativos al 95% están marcadas por “.”.

Figura 4.3. Factores de carga de los cuatro primeros REOFS de las anomalías mensuales de la SLP del NCEP y del HadSLP2, para el periodo 1950-2005.

Figura 4.4. Distribución espacial del REOF1 de la SLP mensual obtenido a partir de las salidas de cuarenta modelos del CMIP5, durante el periodo 1950-2004.

Figura 4.5. Distribución espacial del REOF2 de la SLP mensual obtenido a partir de las salidas de cuarenta modelos del CMIP5, durante el periodo de 1950-2004.

Figura 4.6. Diagramas de Taylor para la comparación de los REOF1 y REOF2, obtenidos del PCA de los datos de SLP de reanálisis del NCEP y observacionales HadSLP2, y de los 40 modelos del CMIP5 (Tabla 2.1).

Figura 4.7. Distribución espacial de las diferencias en los campos medios de la SLP de los GCMs respecto al reanálisis NCEP para el invierno (DEF) y la primavera (MAM), en el período 1950-2005. Las áreas donde las diferencias no son significativas al nivel del 95% están marcadas por “.”.

Figura 4.8. Como en la Figura 4.7 pero para las estaciones de verano (JJA) y otoño (SON).

Figura 4.9. Cociente entre el campo de varianzas de la SLP estacional de 40 modelos del CMIP5 y del NCEP durante el periodo 1950-2005, para las estaciones de invierno (DEF) y primavera (MAM). Las áreas donde los cocientes no son significativos al 95% están marcadas por “.”.

Figura 4.10. Como en la Figura 4.9 pero para las estaciones de verano (JJA) y otoño (SON).

Figura 4.11. Diagramas de Taylor para la comparación de los campos medios de la SLP anual y estacional simulada por los modelos respecto al reanálisis NCEP, durante el

periodo de 1950 -2005. Los diferentes modelos están especificados como en la Tabla 2.1. En color azul se indican a los modelos con $r > 0.95$, y en rojo aquellos con $r < 0.9$.

Figura 4.12. Factores de carga de los tres primeros REOFs de la SLP estacional de los datos de reanálisis NCEP en el período 1950-2005.

Figura 4.13. Patrón espacial de variabilidad asociado al REOF1 de invierno de la SLP del NCEP obtenido a partir de las simulaciones de cuarenta modelos del CMIP5 durante el periodo 1950-2004.

Figura 4.14. Como la Figura 4.13 pero para el REOF2 de invierno del NCEP.

Figura 4.15. Diagramas de Taylor para la comparación de los modos principales de variabilidad de la SLP de invierno simulados por los modelos respecto a los REOF1 y REOF2 obtenidos de los datos de reanálisis del NCEP durante el periodo 1950-2005. Los diferentes modelos están especificados como en la Tabla 2.1.

Figura 4.16. Como en la Figura 4.13 pero para el REOF1 de primavera (MAM).

Figura 4.17. Como en la Figura 4.14 pero para el REOF2 de primavera (MAM).

Figura 4.18. Como en la Figura 4.15 pero para primavera (MAM).

Figura 4.19. Como en la Figura 4.13 pero para el REOF1 de verano (JJA).

Figura 4.20. Como en la Figura 4.14 pero para el REOF2 de verano (JJA).

Figura 4.21. Como en la Figura 4.15 pero para verano (JJA).

Figura 4.22. Como en la Figura 4.13 pero para el REOF1 de otoño (SON).

Figura 4.23. Como en la Figura 4.14 pero para el REOF2 de otoño (SON).

Figura 4.24. Como en la Figura 4.15 pero para otoño (SON).

Figura 5.1. Factores de carga para los diez primeros modos de variabilidad obtenidos mediante un PCA de los datos estacionales de invierno (DEF) y verano (JJA) de la SLP del reanálisis del NCEP y sus series PCs correspondientes, en el período 1950-2010.

Figura 5.2. Factores de carga para los diez primeros modos de variabilidad obtenidos mediante un PCA de los datos estacionales de primavera (MAM) y otoño (SON) de la SLP del reanálisis del NCEP y sus series PCs correspondientes, en el período 1950-2010.

Figura 5.3. (a-j) Patrones espaciales de los coeficientes de correlación entre la precipitación de invierno y las 10 primeras PCs de la SLP en invierno. (k-t) Correlaciones estadísticamente significativas al nivel de confianza del 95% (sombreado gris) y porcentaje de área ocupado por las mismas.

Figura 5.4 (a-j) Patrones espaciales de los coeficientes de correlación entre la precipitación de primavera y las 10 primeras PCs de la SLP en primavera. (k-t) Correlaciones estadísticamente significativas al nivel de confianza del 95% (sombreado gris) y porcentaje de área ocupado por las mismas.

Figura 5.5. (a-j) Patrones espaciales de los coeficientes de correlación entre la precipitación de verano y las 10 primeras PCs de la SLP en verano. (k-t) Correlaciones estadísticamente significativas al nivel de confianza del 95% (sombreado gris) y porcentaje de área ocupado por las mismas.

Figura 5.6. (a-j) Patrones espaciales de los coeficientes de correlación entre la precipitación de otoño y las 10 primeras PCs de la SLP en otoño. (k-t) Correlaciones estadísticamente significativas al nivel de confianza del 95% (sombreado gris) y porcentaje de área ocupado por las mismas.

Figura 5.7. Distribución espacial de los coeficientes de correlación entre los valores estacionales de precipitación observados y simulados por el modelo DS para cada punto de rejilla durante los períodos de calibración (1950-1993) y validación (1994-2010).

Figura 5.8. Distribución espacial del porcentaje de RMSE entre los valores estacionales de precipitación observados y simulados por el modelo DS para cada punto de rejilla, durante los periodos de calibración (1950-1993) y validación (1994-2010).

Figura 5.9. a) Distribución espacial de la precipitación estacional (mm) simulada y observada durante el periodo de validación (1994-2010). b) Distribución espacial de la diferencia (%) entre ambos campos.

Figura 5.10. Comparación entre los valores de precipitación observados (en negro) y simulados (en rojo) para las regiones ZN1 a ZN5 durante los periodos de calibración (1950-1993) y validación (1994-2010). Las líneas azules discontinuas representan los intervalos de confianza al 95% de 1000 réplicas obtenidas por el modelo DS en cada zona.

Figura 5.11 Como en la Figura 5.10 pero para las regiones ZN6 a ZN10.

- Figura 6.1. Distribución espacial de los coeficientes de correlación entre los valores observados y predichos por los modelos DS, para la precipitación estacional por punto de rejilla en las estaciones DEF, MAM, JJA y SON, durante los periodos de recalibración 1950-2010 y 1971-2000.
- Figura 6.2. Distribución espacial de las diferencias (en porcentaje) de los campos medios entre la precipitación observada y predicha por el modelo DS durante el periodo de 1971-2000 usando los datos de SLP del reanálisis NCEP.
- Figura 6.3. Diferencias (en porcentaje) entre los campos medios de la precipitación DS para los 20 GCMs del CMIP5 y la precipitación del GPCC (DS-obs), durante el periodo de 1971-2000 en DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95% (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por líneas.
- Figura 6.4. Como la Figura 6.3 pero en MAM.
- Figura 6.5. Al igual que la Figura 6.3 pero en JJA.
- Figura 6.6. Como la Figura 6.3 para en SON.
- Figura 6.7. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando los 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.
- Figura 6.8. Al igual que la Figura 6.7 pero en para el escenario RCP4.5.
- Figura 6.9. Al igual que la Figura 6.7 pero en para el escenario RCP8.5.
- Figura 6.10. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando los 20 modelos del CMIP5 en el escenario RCP2.6 para MAM. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.
- Figura 6.11. Al igual que la Figura 6.10, pero para el escenario RCP4.5.
- Figura 6.12. Al igual que la Figura 6.10, pero para el escenario RCP8.5.

Figura 6.13. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando los 20 modelos del CMIP5 en el escenario RCP2.6 para JJA. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

Figura 6.14. Al igual que la Figura 6.13, pero para el escenario RCP4.5.

Figura 6.15. Al igual que la Figura 6.13, pero para el escenario RCP8.5.

Figura 6.16. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando los 20 modelos del CMIP5 en el escenario RCP2.6 para SON. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

Figura 6.17. Al igual que la Figura 6.16, pero para el escenario RCP4.5.

Figura 6.18. Al igual que la Figura 6.16, pero para el escenario RCP8.5.

Figura 6.19. Box-plot de la precipitación promedio de DEF (en mm) obtenido del DS para las simulaciones históricas (H) (1971-2000) y de futuro (2071-2100) para las diez regiones (filas) considerados para los cinco modelos SD indicados (columnas) bajo los tres escenarios PCRs (2.6, 4.5, 8.5). Las líneas rojas representan los valores medios, "◊" es la media observada, "□" es el valor medio dado por el GCM, y "+" son valor atípicos (outliers). Los percentiles mostrados (2,5, 25, 75 y 97.5) se han determinado mediante bootstrapping de 1000 remuestreos.

Figura 6.20. Como la Figura 6.19 para los GCMs indicados en la parte superior de cada columna.

Figura 6.21. Como la Figura 6.19 para los GCMs indicados en la parte superior de cada columna.

Figura 6.22. Como la Figura 6.19 para los GCMs indicados en la parte superior de cada columna.

Figura 6.23. Box-plot de la precipitación promedio de MAM (en mm) obtenido del DS para las simulaciones históricas (H) (1971-2000) y de futuro (2071-2100) para las diez regiones (filas) considerados para los cinco modelos SD indicados (columnas) bajo los tres escenarios PCRs (2.6, 4.5, 8.5). Las líneas rojas representan los valores medios, "◊" es la media observada, "□" es el valor medio dado por el GCM, y "+" son valor atípicos (outliers). Los percentiles mostrados (2,5, 25, 75 y 97.5) se han determinado mediante bootstrapping de 1000 remuestreos.

Figura 6.24. Como la Figura 6.23 para los GCMs indicados en la parte superior de cada columna.

Figura 6.25. Como la Figura 6.23 para los GCMs indicados en la parte superior de cada columna.

Figura 6.26. Como la Figura 6.23 para los GCMs indicados en la parte superior de cada columna.

Figura A.1. Diferencias (en porcentaje) entre los campos medios de la precipitación simulada por los 20 GCMs de la CMIP5 y la precipitación observada del GPCC, durante el periodo de 1971-2000 en DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95% (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

Figura A.2. Como la Figura A.1 pero en MAM.

Figura A.3. Como la Figura A.1 pero en JJA.

Figura A.4. Como la Figura A.1 pero en SON.

B1. Cambios proyectados de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando las simulaciones de precipitación de 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

Figura B2. Al igual que la Figura B1 pero en para el escenario RCP4.5.

Figura B3. Al igual que la Figura B1 pero en para el escenario RCP8.5.

B4. Cambios proyectados de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando las simulaciones de precipitación de 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

Figura B5. Al igual que la Figura B4 pero en para el escenario RCP4.5.

Figura B6. Al igual que la Figura B4 pero en para el escenario RCP8.5.

B7. Cambios proyectados de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando las simulaciones de precipitación de 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las

diferencias son significativas al nivel de confianza de 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) es tan marcadas por puntos.

Figura B8. Al igual que la Figura B7 pero en para el escenario RCP4.5.

Figura B9. Al igual que la Figura B7 pero en para el escenario RCP8.5.

Figura B10. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando las simulaciones de 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza de 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

Figura B11. Al igual que la Figura B10 pero en para el escenario RCP4.5.

Figura B12. Al igual que la Figura B10 pero en para el escenario RCP8.5.

LISTA DE TABLAS

Tabla 1.1. Características básicas de los Representative Concentration Pathways (RCPs).

Tabla 2.1. Descripción de las 10 zonas seleccionadas dentro de la región de estudio.

Tabla 2.2. Resumen de las características de los GCMs pertenecientes al CMIP5. El asterisco indica los modelos que han sido utilizados en este trabajo. En la primera columna se indica el número del modelo; en la segunda y siguientes, figura el identificador utilizado para el capítulo 4, el nombre del modelo, el centro o grupo al cual pertenece el modelo, y la resolución horizontal atmosférica y oceánica (km) de cada uno.

Tabla 5.1. Coeficientes de correlación lineal entre las PCs de los diez primeros modos de variabilidad de la SLP estacional de invierno (DEF) y verano (JJA) procedentes de los datos de reanálisis del NCEP, con algunos de los principales índices de teleconexión. Los valores significativos al nivel de confianza del 95% se indican con (*).

Tabla 5.2. Coeficientes de correlación lineal entre las PCs de los diez primeros modos de variabilidad de la SLP estacional de primavera (MAM) y otoño (SON) procedentes de los datos de reanálisis del NCEP, con algunos de los principales índices de teleconexión. Los valores significativos al nivel de confianza del 95% se indican con (*).

Tabla 5.3. Coeficientes de correlación entre las series PCs correspondientes a los 10 primeros modos de variabilidad de la SLP y la precipitación estacional regional (ZN1 a ZN10) o la precipitación estacional sin tendencia (ZN1st a ZN10st), para cada una

de las 10 zonas seleccionadas, en el periodo 1950 –2010. Los valores significativos al nivel de confianza del 95% se indican con (*).

Tabla 5.4. Coeficientes de correlación (r) y porcentajes de RMSE (ρ) entre los valores de la precipitación estacional simulados y observados en cada una de las regiones seleccionadas durante los periodos de calibración (1950-1993) y validación (1994-2010).

Tabla 6.1, Listado de modelos del CMIP5, utilizados para el análisis de Downscaling, tanto para el clima presente (1971 a 2000), como para el clima futuro (2071 a 2100) en los escenarios RCP2.6, RCP4.5 y RCP8.5

CAPÍTULO 1

INTRODUCCIÓN

En este capítulo se presenta la motivación que ha impulsado el desarrollo del presente trabajo, destacando la necesidad de la realización de proyecciones de cambio climático para la precipitación de América tropical. Tras una breve descripción de las características de los modelos de circulación general y de las técnicas de regionalización o *downscaling*, se describen los objetivos generales del trabajo y las fases seguidas en la investigación desarrollada.

1.1 Los modelos de circulación general

Los modelos de circulación general acoplados océano-atmósfera (AOGCMs o GCMs), son la principal herramienta para estudiar la dinámica del sistema climático, evaluar su desarrollo y evolución. También son utilizados con éxito en el estudio de la respuesta del sistema climático a diversos forzamientos radiativos, hacer predicciones del estado tiempo a corto y medio plazo y analizar las proyecciones bajo diferentes escenarios climáticos futuros. En los últimos años se han utilizado para evaluar el impacto del incremento de las emisiones antropogénicas de gases de efecto invernadero en la atmósfera, con el objetivo de mejorar la comprensión del sistema climático (Hibbard et al., 2007; Meehl y Hibbard, 2007; Taylor et al., 2009).

Los GCMs hacen una representación matemática del sistema climático, basada en principios físicos, características químicas y principios biológicos, incorporando interacciones asociadas al cambio del uso de la tierra y de los sistemas geoclimáticos (Heffernan, 2010). En consecuencia, los modelos climáticos pueden ser computacionalmente costosos y lentos, incluso cuando se ejecutan en superordenadores.

Los métodos de modelización del clima tuvieron sus orígenes alrededor de 1940, con forma de modelos climáticos tridimensionales (Norte et al., 1981), pero sus inicios se pueden remontar a principios del siglo XX. Vilhelm Bjerknes (1862-1951), considerado por muchos como el padre de la meteorología dinámica, fue el primero en darse cuenta de que la predicción del tiempo, podría ser un problema que requeriría una representación matemática de la realidad del sistema físico, consistente en ecuaciones en las que intervienen la temperatura, los vientos, las corrientes oceánicas y otras variables climáticas, y que en la actualidad se resuelven numéricamente mediante el uso de ordenadores, lo que para la época era imposible. Otro avance importante fue investigado por Carl-Gustav Rossby (1898-1957), quien propuso el principio de conservación de la vorticidad absoluta, para compensar en un planeta en rotación la estabilidad de las oscilaciones que se producen en los fluidos geofísicos (océano-atmósfera). Este patrón de oscilaciones conocidas por el nombre de Ondas de Rossby, es fundamental para la comprensión de los sistemas atmosféricos y la circulación a gran escala. La construcción del primer ordenador (ENIAC) en 1955 marcó el inicio de los modelos de circulación general, pero el costo computacional y la limitada capacidad de los ordenadores a lo largo de los años 60, 70 y 80, truncó la evolución de los GCMs.

Durante las últimas tres décadas, los GCMs han obtenido numerosas mejoras con la implementación de nuevos componentes (ciclo de carbono, la vegetación y la química atmosférica, Figura 1.1) dentro del sistema climático. Aunque esto a su vez ha conducido a un aumento de su complejidad y de los recursos computacionales requeridos, es un desarrollo necesario cuando la interacción de los diferentes procesos necesita ser simulada cuantitativamente para conseguir representar las interacciones de la atmósfera, los océanos, la superficie terrestre, el hielo y la biosfera, de forma más integral y precisa, reforzando así su capacidad predictiva.




Figura 1.1. Evolución de los modelos climáticos en los últimos 35 años. Fuente: IPCC, 2001 (Resumen técnico, Cuadro 3, Fig. 1, p. 48).

Existen numerosos procesos que requieren una parametrización en los GCMs. Las parametrizaciones son representaciones simplificadas e idealizadas de procesos físicos complejos no resueltos a escala de sub-rejilla (procesos de nubes, radiación, turbulencia, interacción suelo-atmósfera) (Held and Sodem, 2006; Dufresne and Bony, 2008; Lohmann and Feichter, 2005). La incorporación de nuevos ajustes en las parametrizaciones y mejoras en los recursos computacionales de los modelos, ha permitido un continuo aumento en la resolución horizontal y vertical de los modelos.

1.2 Proyecto de Intercomparación de Modelos Acoplados (CMIP)

El Proyecto de Intercomparación de Modelos Acoplados “*Coupled Model Intercomparison Project*” (CMIP), nace a finales de 1995, como una iniciativa de esfuerzos conjuntos entre los programas “*Climate Variability and Predictability*” (CLIVAR) y el “*Working*

Group on Coupled Models” (WGCM), los cuales forman parte del “*World Climate Research Programme*” (WCRP) (Meehl et al., 2000). El propósito de CMIP, es proporcionar una base de datos, de las simulaciones generadas por los GCMs bajo condiciones de contorno estandarizados (Meehl et al., 2000, Kang et al., 2002, Covey et al., 2003, Achuta-Rao et al., 2004; Kucharski et al., 2008). En resumen el CMIP estableció un programa de protocolos experimentales estandarizados para el estudio de las salidas de los modelos de circulación general acoplados atmósfera-océano.

La primera fase del CMIP, llamado CMIP1, estaba dirigida principalmente, a las ejecuciones de los “*experimentos de control*” de clima presente, el almacenamiento de las simulaciones y la evaluación de la capacidad de las salidas de los GCMs para representar las condiciones del clima actual (Meehl et al. 1997, Covey et al. 2003). En estos experimentos el CO₂, el forzamiento solar y otros forzamientos externos climáticos se mantuvieron constantes. En la segunda fase (CMIP2), el CO₂ fue incrementado a razón de 1% anual, sin embargo, no se incluyeron otros factores de forzamientos climáticos antropogénicos, asociados a ciertas emisiones de aerosoles con efectos de enfriamiento sobre el clima, ni variaciones naturales como las erupciones volcánicas y la actividad solar (Covey et al., 2003).

Hay que destacar que los resultados basados en el CMIP1, proporcionaron la base para la realización de los segundo informe de evaluación (SAR) del IPCC, en el que se concluye la evidente influencia del forzamiento antropogénico en el clima global (IPCC, 1995). Además, el tercer informe de evaluación (TAR), soportado en el CMIP2, aporta mayores evidencias de la influencia antropogénica en el clima.

A partir de la año 2003, el grupo de trabajo del WGCM comenzó el proceso de planificación para el cuarto informe de evaluación del IPCC (AR4), llegándose a reconocer que esta tercera fase del CMIP, representaba una nueva oportunidad para mejorar las técnicas de acoplamiento de los modelos y para poder comprender mejor la variabilidad de muchos procesos y experimentos no abordados aún (Meehl et al., 2003). Se acordó dar tiempo a los grupos responsables de los modelos ya existentes y nuevos, para que incorporasen mejoras en los mismos y en los recursos informáticos, y propiciar que la información pudiese ser analizada y discutida por un grupo más amplio de investigadores. Una parte crucial de este esfuerzo conjunto fue el de organizar y almacenar las salidas de las simulaciones de forma mundialmente consistente, para posibilitar su análisis por parte de la comunidad internacional. En este proceso

resultó crucial el papel jugado por el equipo de trabajo del Programa para el Diagnóstico e Intercomparación de Modelos Climáticos (*Program For Climate Model Diagnosis and Intercomparison*, PCMDI) (Meehl et al., 2003, 2004, 2005b).

El cuarto informe de evaluación del IPCC (IPCC-AR4), generó una enorme confianza en la capacidad de los GCMs para simular el clima presente y realizar estimaciones más creíbles del cambio climático futuro (IPCC, 2007). Respecto a las fases anteriores, destaca el aumento de la resolución espacio temporal (Figura 1.2) de los GCMs, la mejora del proceso de acoplamiento de sus componentes principales (atmosféricos, oceánicos y terrestres), la formulación del modelo (proceso de transporte y su dinámica interna), y la representación de los efectos directo e indirecto del aerosol.




Figura 1.2. Resolución espacial de los modelos utilizados por el IPCC en los primeros cuatro informes. Fuente: IPCC 2007 (AR4 WG 1, Capítulo 1, pág 113, Fig. 1.4).

http://www.windows2universe.org/earth/climate/climate_modeling.html

La quinta fase del CMIP (CMIP5), se estable con el propósito de hacer frente a las cuestiones de la comunidad científica internacional, surgidas durante la elaboración del AR4, para mejorar la comprensión del clima (Taylor et al., 2007). La mayoría de los principales centros de modelización climática que participaron en el CMIP5, proporcionaron un marco para la realización de experimentos coordinados en el contexto del quinto informe de evaluación

(AR5) del IPCC, que finalizó en noviembre 2014 (IPCC, 2014). Estos experimentos fueron realizados con la participación de 20 grupos de modelización, incluyendo más de 50 modelos climáticos, enmarcados en la tarea de mejorar la comprensión del clima pasado y proporcionar estimaciones del cambio climático futuro, especialmente en aquellas zonas donde existe mayor incertidumbre (Taylor et al., 2012).

Aunque que el CMIP5 se compone de un conjunto de experimentos coordinados, promueve un conjunto de estándares multimedios con el fin de: (1) evaluar los mecanismos responsables de las diferencias presentes en los modelos, no entendidos hasta el momento, como son los asociados a los procesos de retroalimentación de las nubes y el ciclo del carbono; (2) examinar la predictibilidad del clima y explorar la capacidad predictiva de las simulaciones a escala decadal, y (3) determinar por qué los modelos con el mismo forzamiento reproducen diversas de respuestas (Taylor et al., 2012). Algunos centros de modelización han facilitado el acceso sin restricciones a las salidas de los modelos, mientras que otros permiten acceso siempre y cuando sea para uso no comercial, es decir, solamente con fines de investigación y educativos.

Dentro de los nuevos ajustes en las parametrizaciones y de las mejoras introducidas en la resolución de los modelos de CMIP5 respecto al CMIP4, se destaca en primer lugar una resolución horizontal mucho más fina (T159/80 km en lugar de T63/180 km) (Figura 1.3). Con esta mayor resolución, que varía entre los 0.5° y los 4° para el componente atmosférico y alrededor de los 0.4° (~ 45 km) en el oceánico, los procesos físicos como las tormentas oceánicas se pueden simular de forma más realista (Ronald et al., 2011, Taylor et al., 2012).



Figura 1.3. Resolución de los modelos utilizados para los informes de evaluación del IPCC: izquierda AR4, derecha: AR5., Fuente: <https://www.dkrz.de/pdfs/poster/>.

Aunque el CMIP5 se basa en la fase anterior (CMIP3), los experimentos realizados varían de diferentes maneras. En primer lugar las simulaciones del CMIP5 se dividen en dos categorías. La primera de ellas es de *integración* a largo plazo (hasta el 2100 y en algunos llega al 2300) y la segunda es de *interacción* a corto plazo (10 a 30 años, aproximadamente hasta el 2035). Los experimentos a corto plazo, que son realmente nuevos, tratan de caracterizar la trayectoria real del clima en las próximas décadas.

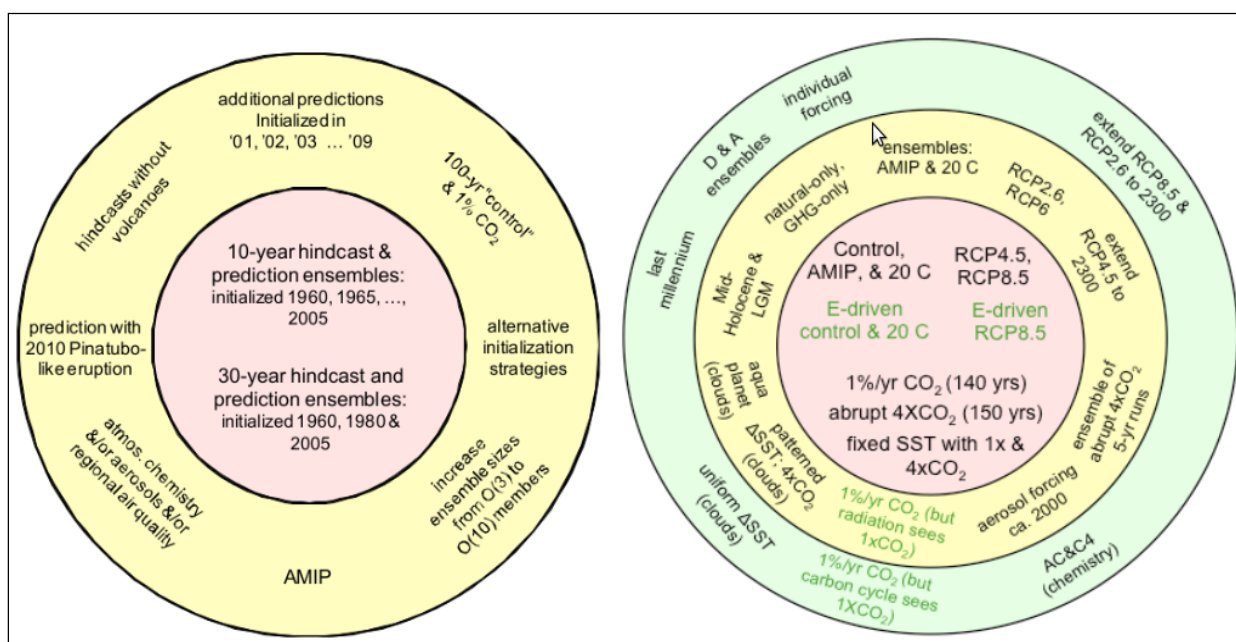


Figura 1.4. Resumen esquemático de los experimentos del CMIP5, predicción decadal (izquierda) y largas escalas temporales (derecha). Fuente: Taylor et al. (2011).

Existen muchos elementos a considerar al intentar hacer proyecciones del sistema climático. En este sentido, los gases de efecto invernadero son un elemento clave; los avances tecnológicos, las circunstancias económicas actuales, los cambios en la generación energética, la superpoblación y el cambio en el uso del suelo, también deben ser considerados. Así el IPCC 2007 en su informe AR4, puso de manifiesto que las actividades antropogénicas son el principal contribuyente del cambio climático, en comparación con otros elementos de forzamiento radiativo natural del sistema climático. Esto motivó la adopción de un nuevo grupo de escenarios socio-económicos acorde con las condiciones actuales, avances tecnológicos, gestión energética, usos del suelo y la emisiones de gases de efecto invernadero (GEIs), llamadas Trayectorias de Concentración Representativas (RCPs, *Representative Concentration Pathways*) en contraste

con los anteriores escenarios SRES (Moss et al., 2010; van Vuuren et al., 2011). Se acordaron cuatro escenarios para el diseño de los experimentos, denominados RCP8.5, RCP6.0, RCP4.5 y RCP2.6 (este último conocido también como RCP3-PD), que hacen referencia al forzamiento radiativo expresado en W/m^2 (Van Vuuren et al., 2007a; van Vuuren et al. 2006, Clarke et al. 2007; Smith and Wigley 2006; Wise et al. 2009; Riahi et al. 2007; Moss et al., 2010; van Vuuren et al., 2011).

En la Tabla 1.1 se resumen las características básicas de los cuatro RCPs definidos relativas al forzamiento radiativo total y a las concentraciones de CO_2 previstos hasta el 2100, propuestos por el *Integrated Assessment Mode* (IAM) y el W GCM, en tre otros (Moss et al., 2010; van Vuuren et al., 2011), y en la Figura 1.5 se representa la extensión (ECPs) de las trayectorias para cada RCP. El primero de ellos, el escenario RCP8.5, considerado como el escenario más extremo, supone un forzamiento de energía impuesto al sistema climático de $8.5 W/m^2$, para unos niveles de concentración de CO_2 (equivalente) de 1370 ppm en 2100. Mientras que en el extremo inferior se encuentra el escenario RCP2.6, que asume que se emitirán menos gases de efecto invernadero, con un forzamiento radiativo máximo de $3.1 W/m^2$ alrededor de 2050 seguido de un descenso hasta los $2.6 W/m^2$, para un nivel de concentración aproximado de CO_2 (equivalente) de 490 ppm en 2100, representando el escenario ideal. Estos dos escenarios abarcan los dos extremos de l cambio climático proyectado durante el siglo XXI. Adicionalmente, existen dos escenarios intermedios, RCP4.5 y RCP6.0, considerados como trayectorias de estabilización intermedias en las que el forzamiento energético impuesto al sistema climático se estabiliza aproximadamente en $4.5 W/m^2$ y $6.0 W/m^2$, respectivamente, después de 2100 (Moss et al., 2010; van Vuuren et al., 2011).

Tabla 1.1. Características básicas de los *Representative Concentration Pathways* (RCPs).

RCPs	Niveles de Forzamiento Radiativo	Concentración de CO_2 (p.p.m)	Vía de Concentración	Modelo proporcionado por
RCP 8.5	Aumento $8.5 W/m^2$ en 2100.	1370 CO_2 -equiv. en 2100	Aumento	MESSAGE (Austria)
RCP 6.0	Estabilización a $6 W/m^2$ después de 2100	~850 CO_2 -equiv.(estabilización después del 2100)	Estabilización sin exceso	AIM (Japón)

RCP 4.5	Estabilización en 4.5 W/m ² después de 2100	~650 CO ₂ -equiv.(estabilización después del 2100)	Estabilización sin exceso	GCAM (EU)
RCP 2.6	Pico ~ 3 W/m ² antes de 2100 con un posterior declive	Pico en ~490 CO ₂ -equiv. antes del 2100 con declive posterior.	Pico y declive	IMAGE (Países Bajos)

La Figura 1.5 indica que la estabilización del forzamiento radiativo para ECP8.5, ECP6 y ECP4.5 a 12, 6 y 4.5 Wm⁻², respectivamente, implica considerables reducciones en las emisiones de CO₂ más allá de 2100.

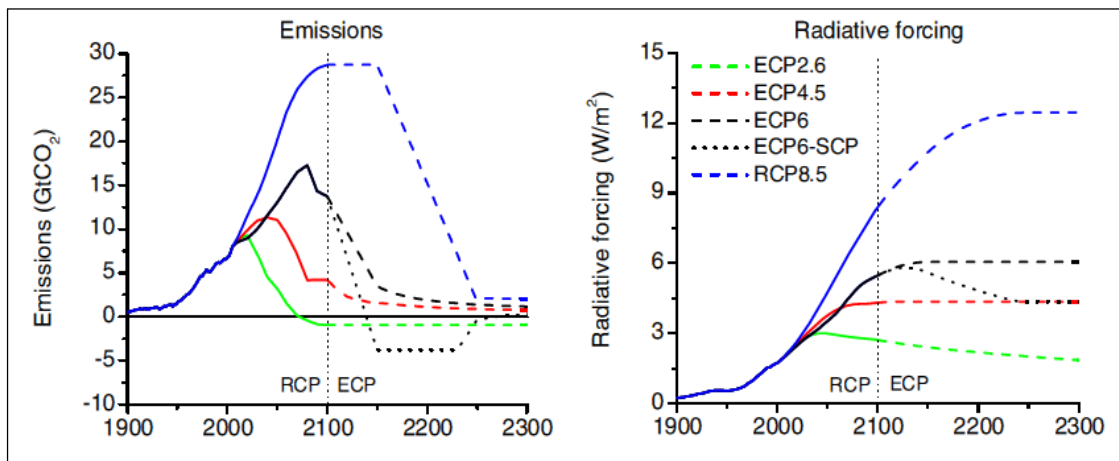


Figura 1.5. Extensión de los RCPs (forzamiento radiativo y emisiones de CO₂ asociadas) más allá de 2100. ECP significa *extended concentration pathway*. Fuente: van Vuuren et al., (2011).

1.3 Downscaling

Como ya se ha mencionado, la resolución de los GCMs más recientes puede llegar a ser del orden de 80 km, por lo que generalmente proporcionan buenos resultados en la simulación de las variables climáticas a gran escala espacial ya que incorporan gran parte de la complejidad del sistema climático global. Sin embargo, no son capaces de resolver procesos a una escala inferior y de incorporar características locales, tales como factores geográficos, topográficos, distribución tierra-agua o tipos de vegetación, lo que los hace inapropiados para la mayoría de los estudios de impacto (Zorita y von Storch, 1999; Fowler et al., 2007). Para los estudios de impactos a escala regional se necesitan variables meteorológicas de entrada con una resolución del orden de 10 km. Una forma de solventar estos problemas de resolución consiste en el uso de los métodos de *downscaling*. Hay dos métodos principales de *downscaling*: dinámico

(Christensen et al., 1998; Murphy, 1999; von Storch et al., 2000; Chen et al., 2006; Schmidli et al., 2006; Christensen et al., 2007). Aunque ambos proporcionan en general resultados igualmente válidos, el primero usa modelos regionales con una resolución horizontal relativamente alta y el segundo método se basa en estudios empíricos de las relaciones entre las anomalías climáticas a gran escala y las fluctuaciones climáticas locales. Hay varias maneras de desarrollar el *downscaling* estadístico pero es importante notar que un modelo de *downscaling* estadístico implícitamente asume que cualquier relación obtenida se mantendrá en el futuro. Sin embargo, comparado con el método dinámico, este tiene la ventaja de ser computacionalmente más sencillo y fácilmente aplicable a nuevas áreas, ya que en el método dinámico expandir el área de estudio o cambiarla ligeramente requiere rehacer el experimento completo. Al menos para el clima actual, las técnicas dinámicas no parecen ofrecer mejoras sustanciales respecto a las estadísticas (Fowler et al., 2007). El método estadístico generalmente requiere pocos parámetros y esto lo hace atractivo para muchas aplicaciones ya que juega un importante papel en la evaluación de impactos a escala regional a partir de los escenarios de cambio climático proporcionados por los GCMs (Grotch y MacCracken, 1991; von Storch et al., 1993; Wilby y Wigley, 1997; Xu, 1999).

Las estimaciones de cambio climático en escalas locales o regionales están afectadas por una considerable cantidad de incertidumbres, provenientes de varias fuentes:

- Incertidumbres y/o variabilidad de los diferentes GCMs, debidas al conocimiento incompleto de los procesos físicos de cambio global subyacentes, vastas resoluciones y procesos no considerados.

- Incertidumbres y/o variabilidad en los escenarios de cambio climático, resultantes de la imposibilidad de predecir las condiciones futuras socioeconómicas.

- Diferentes realizaciones de un GCM dado debido a incertidumbres en los parámetros y a diferentes condiciones iniciales.

- Incertidumbres debidas al método de *downscaling*.

La salida de un GCM correspondiente a un escenario de cambio climático específico, a la que se le aplica el proceso de *downscaling* representa una trayectoria única sobre un número de realizaciones posibles correspondientes a varios escenarios con varios GCMs, que pueden dar

lugar a proyecciones muy distintas (Buytaert et al., 2009). Dicha trayectoria por sí sola no representa un escenario hidrológico futuro, y no será útil en la evaluación de impactos hidrológicos debidos al cambio climático (Simonovic y Li, 2003, 2004). El uso de varios GCMs y varios escenarios conduce a un amplio abanico de proyecciones climáticas regionales a largo plazo, necesario para acotar parte de las incertidumbres antes mencionadas. Son varios los estudios que evalúan estas incertidumbres en la elección del GCM, mostrando en general, que la precipitación presenta estimaciones más dispares y una dependencia estacional de las mismas (Wilby y Harris., 2006; Maurer, 2007).

Ya que las fuentes de error introducidas en el proceso de *downscaling* se suman a las del propio GCM, se hace necesario evaluar y validar las salidas de los modelos globales directamente, es decir antes de llevar a cabo ningún proceso de regionalización. La eficacia de los modelos en reproducir los principales patrones de variabilidad del flujo atmosférico, junto con la vinculación entre estos campos y el clima en la región de estudio lleva a analizar la reproducibilidad de los patrones de ciertas variables tales como la presión al nivel del mar (SLP). Además, existen evidencias en el período observacional de cambios en la variabilidad de baja frecuencia del sistema climático (período posterior a la década de los sesenta frente al período anterior), como el aumento de episodios E I N ñ o y su mayor intensidad, que han sido relacionados con el cambio climático antropogénico. Por tanto, también resulta de interés evaluar dichas tendencias haciendo uso de las salidas de los modelos globales. La validación se establece en términos de comparación entre las salidas de los modelos en los experimentos de simulación *historical* y los datos observacionales y de reanálisis.

Existen diferentes técnicas para llevar a cabo el procedimiento de *downscaling* (métodos de clasificación, métodos lineales como el análisis de correlación canónica, de covarianza máxima -MCA-, de regresión por componentes principales -PCR-, o métodos determinísticos no lineales como los basados en redes neuronales). La mayoría de estos trabajos identifican vectores o modos singulares del campo/s a analizar (PCA si sólo se analiza un campo, o MCA si se analiza más de un campo simultáneamente). Estas técnicas, aunque simples, son efectivas en la obtención de patrones principales que definen la variabilidad de la circulación atmosférica o la conexión de ésta con otra/s variables de interés. Su gran ventaja radica en el hecho de que extraen un número relativamente pequeño de modos (patrones y series temporales) que capturan la mayor parte de la variabilidad del campo o covariabilidad de los campos a analizar (Li and

Smith, 2009; Benestad, 2001). Además los modos principales de variabilidad obtenidos son ortogonales, de forma que sus series temporales asociadas no están correlacionadas, lo que facilita su uso como predictores en modelos de *downscaling*, ya que se reduce considerablemente la dimensionalidad del problema estadístico y la colinealidad de los predictores (Preisendorfer, 1987; Jolliffe, 2002; Wilks, 2006).

Los modos principales de variabilidad pueden ser usados directamente en el proceso de *downscaling* como predictores para la obtención de la variable a proyectar (Mujumdar y Ghosh, 2008). Hay poco consenso en establecer qué variables predictoras resultan más adecuadas, aunque predictores relacionados con la circulación atmosférica, como la SLP son muy utilizados dada su gran disponibilidad tanto observacional como a partir de los GCMs.

1.4 América tropical

La región de América tropical ha recibido en las últimas décadas una atención especial por parte de la comunidad científica global y, en particular, por la del área de las ciencias atmosféricas, debido a sus características meteorológicas y climatológicas. La presencia de ambientes únicos, como la Amazonia (la mayor selva tropical del planeta), el delta del río Amazonas (con el mayor archipiélago fluvial en la tierra), las montañas de los Andes (con sus pendientes muy pronunciadas), el Altiplano, el desierto de Atacama en Chile, la región árida del noreste de Brasil, el extremo oeste de Perú y Ecuador, la megabiodiversidad de la zona del oeste de Colombia y del este de centro América, la migración de la Zona de Convergencia Intertropical (ITCZ), entre otros, que interaccionan en una compleja superposición de procesos físicos, de diversas escalas espacio-temporales, determinan los aspectos meteorológicos y climatológicos de América tropical, constituyendo un componente fundamental del sistema global. A su vez, las características principales de la circulación atmosférica están asociadas con la precipitación de la región, lo que afecta directa e indirectamente a la economía, ecosistemas y a la sociedad (Alexander et al., 2002; Barsugli and Sardeshmukh, 2002). Según el IPCC AR5 (Magrin et al., 2014), se espera que los cambios en la producción agrícola, con consecuencias en el suministro de alimentos, asociados con el cambio climático, muestren una importante variabilidad espacial en centro América y Sudamérica (Marengo et al., 2010). El aumento en la producción agrícola y el intensivo uso de la tierra, particularmente en el área tropical, está dando lugar a problemas de desertización, contaminación del agua, erosión y efectos negativos en la

biodiversidad y en la salud. Por este motivo, el estudio del cambio climático en esta área constituye un importante objetivo para el desarrollo socio-económico de la región, siendo, un reto importante la producción de estimaciones fiables de los cambios en las precipitaciones a escala local.

El último informe del IPCC (IPCC, 2013a, IPCC, 2013b) sugiere tanto aumentos como disminuciones en la precipitación para América Central y Sudamérica en 2100, aunque con elevadas incertidumbres; mientras que en la bibliografía actual existen pocos trabajos dedicados a obtener proyecciones de cambio climático en América tropical, estando más enfocados a regiones particulares como Brasil, Colombia o el sur de Sudamérica (Valverde Ramírez et al., 2006; Solman and Nuñez, 1999; Mendes and Marengo, 2010; Teichmann et al., 2013; Palomino-Lemus et al., 2015). Por tanto, existe una necesidad clara del estudio del cambio climático América tropical.

1.5 Objetivos del trabajo

El presente trabajo toma en consideración la situación anteriormente expuesta y tiene como objetivo principal la generación de proyecciones de cambio climático para la precipitación de América tropical. Para ello se llevará a cabo un *downscaling* estadístico de la precipitación estacional en el área tomando como campo predictor la presión a nivel del mar (SLP) de la región del Pacífico tropical, ya que esta es una de las variables globales más importantes a la hora de describir el clima de la zona de estudio.

Como paso previo para la obtención de proyecciones regionales de cambio climático para la precipitación de la zona de América tropical, se realiza una evaluación de la SLP en el área de estudio en 40 GCMs del CMIP5, tanto a escala mensual como estacional, a partir de las salidas de clima presente. Se presenta un análisis detallado de las diferencias del campo medio y de la varianza, de la SLP de cada modelo respecto a la SLP de datos de reanálisis y observacionales, así como una comparación de sus principales modos de variabilidad, obtenidos a partir de un Análisis de Componentes Principales. La evaluación sistemática de los principales modos de variabilidad es llevada cabo usando diagramas de Taylor, que permiten analizar la correlación de los campos espaciales de la SLP en cada GCMs respecto a los del NCEP, así como su varianza y error cuadrático medio.

Se desarrollan modelos de *downscaling* estadístico (DS) para la precipitación estacional en América tropical mediante la técnica de regresión por componentes principales (PCR), siguiendo fundamentalmente el esquema desarrollado por Li and Smith (2009) y Palomino-Lemus et al. (2015). Para ello, se analizan los modos de variabilidad de la presión a nivel del mar (SLP) estacional en la región tropical y su influencia en la precipitación de América tropical. De este análisis se obtendrán las variables predictoras de la precipitación, que serán utilizadas en los modelos de regresión. La habilidad de los modelos DS generados, para simular la precipitación estacional de Sudamérica, será evaluada tanto a escala espacial de rejilla, como a escala regional para diferentes zonas seleccionadas.

Finalmente, el modelo DS se aplicará para obtener las proyecciones futuras de la precipitación (para la treintena 2071-2100) para la región de América tropical, utilizando las simulaciones de la SLP de 20 GCMs seleccionados del CMIP5 para las trayectorias de representación representativas RCP2.6, RCP4.5 y RCP8.5, comparándolos con los cambios de la precipitación proyectados directamente por los GCMs. Los niveles de confianza del 95% para las cantidades de precipitación obtenidas mediante DS se estimarán a partir de técnicas de *bootstrapping*.

La Tesis se estructura en 8 capítulos que abarca desde la Introducción (Capítulo 1) hasta las referencias empleadas (Capítulo 8). El Capítulo 2 presenta una descripción del clima de América tropical, y de las bases de datos empleadas. El Capítulo 3 describe la metodología usada necesaria para la obtención de las proyecciones de cambio climático de la precipitación. El Capítulo 4 está dedicado a la evaluación de las salidas de SLP de los GCMs del CMIP5; en el Capítulo 5 se desarrolla el modelo de *downscaling* para la precipitación. Finalmente, el Capítulo 6 presenta las proyecciones de cambio climático para el periodo 2071-2100, resultado de aplicar el modelo de *downscaling* a las salidas de los GCMs para los RCPs 2.6, 4.5 y 8.5.

CAPÍTULO 2

ÁREA DE ESTUDIO Y BASES DE DATOS


En este capítulo se presenta una descripción del área de estudio y de sus características climáticas principales. También se indican las bases de datos utilizadas en este trabajo, tanto las procedentes de datos observacionales como las obtenidas de las salidas de los GCMs, especificando sus condiciones correspondientes a las variables analizadas o a las que se han usado como variables predictoras en los modelos de *downscaling*.

2.1 Área de estudio

El área de estudio del presente trabajo se centra en la zona tropical y subtropical del continente americano, cubriendo el área entre los 30°N-30°S y los 120°W-60°W (Figura 2.1), abarcando desde el norte de Centroamérica hasta el centro de América del Sur. Esta zona está compuesta por una variedad de climas y hábitats que resultan en una gran diversidad de paisajes, originados por las relaciones entre distintos factores climáticos, geomorfológicos e hidrológicos. El clima de la zona está fuertemente influenciado por las interacciones e intercambios entre el sistema océano-atmósfera del Atlántico y el Pacífico, condicionado por su compleja topografía, que incluye diferentes tipos de suelo, cadenas de islas y cordilleras (Wang et al., 2006; Mestas-Núñez et al., 2007; Wang and Lee, 2007). Adicionalmente, esta topografía presenta un alto grado

de interacción con la circulación a gran escala para producir variaciones locales en el clima, afectando a la duración e intensidad de la precipitación.

a)



b)



Figura 2.1. Zona de estudio: a) Topografía. Fuente: NOAA (Amante, 2009). b) Mapa político.

América Central y el Caribe podrían describirse como una región que presenta características propias de un clima tropical y en parte subtropical (Barry y Chorley, 1999). La parte continental de América Central presenta un tipo de clima tropical húmedo al este, mientras que al oeste es tanto tropical húmedo como seco, dependiendo de la ubicación concreta (Figura 2.2). Así, las zonas costeras del Caribe de Honduras, Costa Rica y Panamá poseen un régimen de lluvias sorprendentemente homogéneo, debido a las fuertes interacciones de los vientos de bajo nivel con la topografía; en cambio, en el interior de la región de América central, las masas de aire provenientes del noroeste, ocasionan lluvias intensas asociadas a fuertes episodios de viento (Bradbury, 1997). En general, el patrón anual de las precipitaciones para Centroamérica presenta una distribución de tipo bimodal predominantemente al oeste, con máximos relativos a principios de junio y septiembre-octubre y una clara disminución durante julio-agosto, destacándose volúmenes considerables de precipitación durante el año a lo largo de las zonas costeras del Caribe (Whyte et al., 2008). Por otro lado, la región también se ve muy afectada por patrones atmosféricos a escala sinóptica, adicionales a los que afectan a la zona continental, tales como la propagación de las ondas del este, que contribuyen al desarrollo de tormentas y ciclones tropicales produciendo el segundo pico de lluvias del ciclo anual, y traen asociados grandes desastres naturales.. A escala interanual, la precipitación de esta zona se encuentra regulada por el fenómeno El Niño-Oscilación del Sur (ENSO) y la Oscilación del Atlántico Norte (NAO) (Chen and Taylor, 2002; Jury et al., 2007). Adicionalmente, otros factores que definen el clima de Centroamérica son el desarrollo anómalo de la Piscina de Agua Cálida del Atlántico (*Atlantic Warm Pool*, AWP), la alta subtropical del Atlántico norte (NASH), e l gradiente de

variabilidad meridional del Atlántico tropical, y la migración latitudinal de la Zona de Convergencia Intertropical (ZCIT) (Muñoz et al., 2008; Whyte et al., 2008).

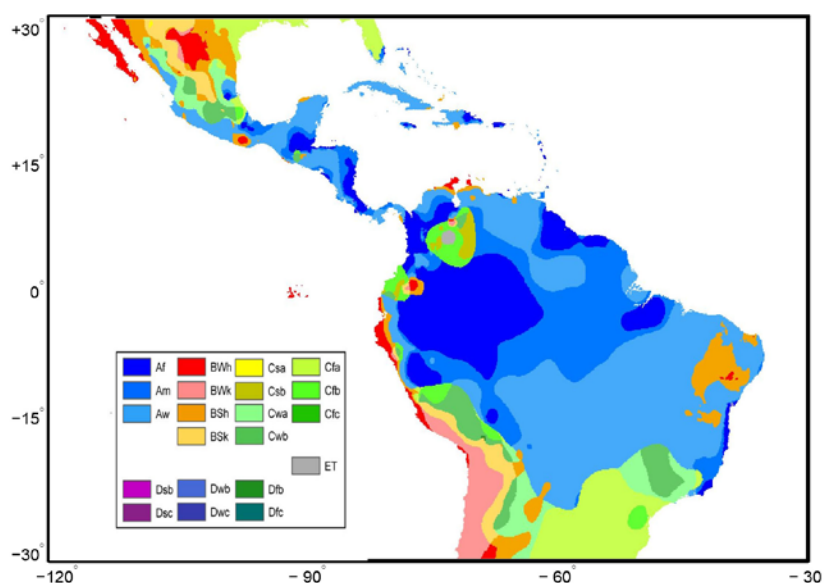


Figura 2.2. Tipos de climas según la clasificación climática de Köppen-Geiger para la zona de estudio. Fuente: Peel et al. (2007).

Por su parte, la climatología del Caribe, tiene características muy similares a las de América Central. Las diferencias en tamaño, forma, topografía y orientación del territorio respecto a los vientos alisios, influyen de manera significativa en la variabilidad climática en los territorios insulares del Caribe (Magaña et al., 1999; Gamble and Curtis, 2008). En general, el patrón anual de precipitación exhibe una estructura bimodal, con un máximo a principios de mayo, un mínimo entre julio-agosto, y un segundo máximo en septiembre-octubre (Granger, 1985; Taylor y Alfaro, 2006; Gamble et al., 2008; Jurado et al., 2007).

Para América del Sur, la dinámica del clima es, en términos generales, el resultado de la compleja superposición e interacción de procesos de diversa escala espacial y temporal, principalmente físicos, que involucran la presencia de fenómenos locales y macroclimáticos (Pabón, 2003). Con un gran porcentaje de su área dentro de la zona tropical, y otro, en menor grado, subtropical y templado (Figura 2.2), la región presenta una topografía compleja y diversa (Figura 2.1), que incluye territorios continentales con valles interandinos, la mayor selva tropical del planeta (el Amazonas) y la presencia de la cadena montañosa más larga del mundo, la cordillera de los Andes (Koster et al., 2000; Marengo et al., 2003; Amante, 2009). Esta cordillera, que tiene una longitud aproximada de unos 7.000 km, con picos que alcanzan hasta

los 6.000 m de altura, se extiende de norte a sur a través de la costa oeste del continente, modificando la circulación atmosférica sobre el continente en una amplia gama de escalas, desde la escala local (Seluchi et al., 2003) hasta las ondas estacionarias planetarias (Satyamurty et al., 1980).

El clima de la región del Amazonas es no solo un elemento muy importante del sistema general de las lluvias tropicales, sino también un factor determinante en el proceso de regulación del ciclo del carbono en el planeta (Lean y Warrilow, 1989; Shukla et al., 1990; Dickinson y Kennedy, 1992; Zhang et al., 1996a). El Amazonas es una cuenca hidrográfica de gran importancia en términos ecológicos y climáticos, debido a su gran tamaño, de aproximadamente 6.000.000 km² de bosque tropical (Goulding et al., 2003). El sistema del alta subtropical en Bolivia se ha explicado como respuesta al calentamiento local adiabático en la región amazónica, asociada a los centros de convección profunda sobre la cuenca del Amazonas en el verano austral. Esta región presenta un régimen de precipitación de tipo monzónico, llamado sistema del monzón de América del Sur (SAMS), cuyo dominio se extiende hasta el sur del Amazonas y la Cuenca del Río de la Plata, presentando una fuerte variabilidad estacional, con una temporada de lluvias durante los meses del verano austral y una estación seca durante el invierno austral (Grimm et al., 2005; Vera et al., 2006a; García y Kayano, 2008; Liebmann y Mechoso, 2010; Gan et al., 2009; Grimm y Silva Días, 2010; Jones y Carvalho, 2002).

Dentro de la zona de estudio, las regiones que experimentan temperaturas cálidas cubren gran parte de Brasil, el norte de Argentina, el noroccidente del continente y la cuenca del Amazonas, incluyendo los países de Colombia, Ecuador, Venezuela y parte de Perú, mientras que las anomalías frías se limitan a Bolivia. En cambio, en el área subtropical entre los 25°S-35°S, los Andes, con una elevación aproximada de 5.000 m al norte de Chile y sur de Perú, bloquean y dividen el flujo zonal del viento, generando un régimen climático relativamente frío y seco al oeste, y un régimen más cálido y húmedo hacia el este (Seluchi y Marengo, 2000). Adicionalmente, las variaciones climáticas en el sur están afectadas por los cambios en la intensidad y la posición latitudinal de la anticiclón subtropical del Pacífico, que bloquea el flujo de masas de aire húmedo del oeste causando variaciones en la temperatura y la precipitación (Aceituno, 1988).

En cuanto a la precipitación, como ya se ha mencionado de manera general en la zona de estudio, la distribución del ciclo de la precipitación está dominada principalmente por la posición

de la Zona de Convergencia Intertropical (ZCIT), y controlada por la ubicación de los Andes, además de los procesos de circulación atmosfera-océano entre los océanos Pacífico oriental y el Atlántico occidental, la circulación atmosférica de la cuenca del Amazonas, y de la vegetación de las diferentes regiones. Específicamente, en Colombia, la interacción entre la topografía y la circulación atmosférica influye fuertemente en la variabilidad del clima. Las diferentes interacciones de estos fenómenos hidrometeorológicos generan grandes volúmenes de precipitación en el occidente de Colombia (Figura 2.3), considerada como uno de los lugares más lluviosos del planeta (Poveda, 2004; Eslava, 1994), con valores medios anuales que superan en algunos casos los 12.000 mm. Adicionalmente, al este de la Cordillera de los Andes, en Perú y Bolivia, se presentan valores cercanos a los 6.000 mm al año, mientras que en el Amazonas los valores oscilan alrededor de los 5.000 mm. Igualmente, un volumen de precipitación anual cercano a 3.000 mm se encuentra en la costa atlántica ecuatorial de Brasil y de la Guyana Francesa, así como en algunas regiones costeras de América Central (Costa Rica, Nicaragua, Honduras, y la región de Minatitlán en el sur de México). Por otro lado, en las regiones de la costa oeste de Chile, Perú, el occidente de Bolivia, parte del este de Brasil y en el norte de México, las medias anuales de precipitación no superan el umbral de los 500 mm, siendo estos valores más bajos (menores a 100 mm) en el extremo oeste de las costas de Chile, Perú y México.

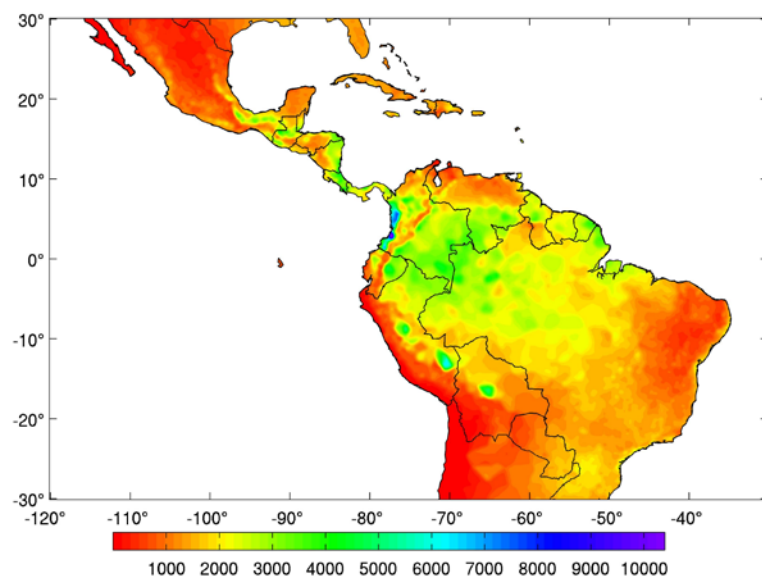


Figura 2.3 Distribución espacial de la precipitación media anual (mm/año), calculada para una rejilla de 0.25°, con 13.382 estaciones ubicadas en la zona de estudio (datos del GPCC en diciembre de 2011).

2.2 Bases de datos

2.2.1 Datos de precipitación

En el presente trabajo se ha utilizado la precipitación del conjunto de datos observacionales del Centro Climatológico Global de Precipitaciones versión 6.0 (*Global Precipitation Climatology Centre*, GPCC). Este centro nace en el Servicio Meteorológico Alemán (DWD) en 1989, por iniciativa de la Organización Meteorológica Mundial (*World Meteorological Organization*, WMO), como componente del Programa Global de Climatología de las Precipitaciones (*Global Precipitation Climatology Project*, GPCP) para avanzar en el conocimiento de los modelos espaciales y temporales de precipitación, dentro del Experimento Global de Agua y Energía (*Global Energy and Water Cycle Experiment*, GEWEX) (Schneider et al., 2013).

Las series de precipitación del GPCC cubren casi la totalidad de las zonas terrestres del globo, excluyendo Groenlandia y la Antártida, a resoluciones espaciales de ($0.5^{\circ} \times 0.5^{\circ}$, $1^{\circ} \times 1^{\circ}$ y $2.5^{\circ} \times 2.5^{\circ}$) de longitud y latitud. Estas fueron desarrolladas usando bases de datos de series mensuales de precipitación observada en todo el mundo, que han ido creciendo y convirtiéndose en un sistema de almacenamiento único, que contiene los datos de precipitación de más de 85.000 estaciones distribuidas en todo el globo, con un total de pluviómetros que oscila entre 150.000 y 250.000 (Sevruk y Klemm, 1989; Nueva et al., 2001; Strangeways, 2007). Adicionalmente, el GPCC cuenta con más de 10.800 series que datan de principios del siglo XX, inclusive algunas se remontan hasta principios del siglo XVIII, superando el número de estaciones respecto a otras bases de datos observacionales tales como las de la *Climatic Research Unit* (CRU), *Global Precipitation Climatology Project* (GPCP), *Food and Agriculture Organization* (FAO) y *Global Historical Climatology Network* (GHCN).

Las series de precipitación estacional observada correspondientes a los puntos de rejilla de la región de estudio [30°N - 30°S , 120°W - 60°W] se han usado como predictando en el proceso de construcción de un modelo de *downscaling* estadístico (DS), obtenido por el método de regresión por componentes principales (PCR), para simular la precipitación estacional durante el periodo 1950-2010 (Capítulo 5). En algunas regiones, muchas condiciones limitan la aplicación práctica de un método de reducción de escala. El principal inconveniente que generalmente se encuentra es el que atañe a la calidad de información y a la densidad del número de estaciones

para representar una región, factores que limitan el proceso de calibración de un modelo de *downscaling*. A modo de ejemplo, en la Figura 2.4 se muestra la densidad de estaciones por punto de rejilla dentro de la región de estudio para el mes de julio de 1950 (a), 1980 (b) y 2010 (c). El número de estaciones anterior a 1950 se reduce considerablemente; también hay una reducción importante en el número de estaciones en el periodo 2000-2010, más importante en los últimos años de este intervalo, siendo el periodo 1950-2000 el que presenta una mayor cobertura de datos.

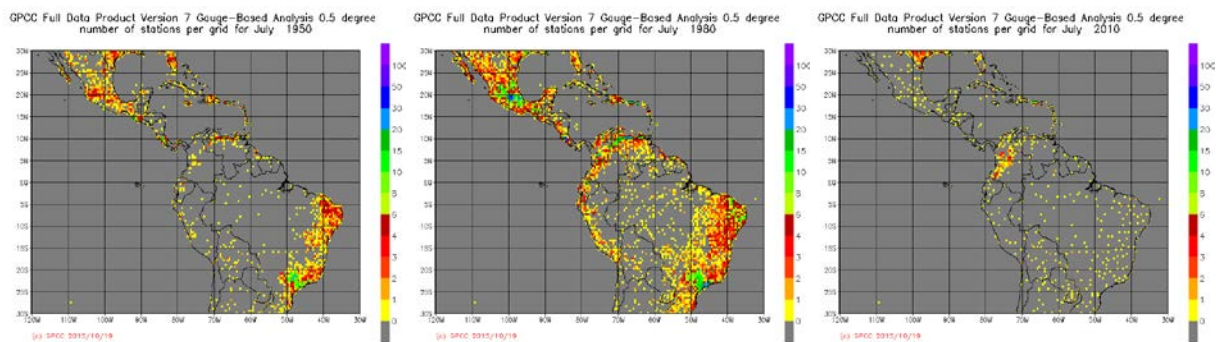


Figura 2.4. Número de estaciones por punto de rejilla de los datos del GPCC en julio de (a) 1950, (b) 1980 y (c) 2010. Fuente: <http://kunden.dwd.de/GPCC/Visualizer>.

Buscando una solución de compromiso entre una suficiente longitud de los registros y una cobertura adecuada en número de estaciones, en el presente trabajo se ha utilizado el periodo 1950-1993 para calibración del modelo de *downscaling* y el 1994-2010 para su validación. Adicionalmente, para analizar los resultados obtenidos por el modelo de *downscaling* (Capítulo 5) se han seleccionado 10 zonas dentro de la región de estudio teniendo en cuenta los factores mencionados relativos a la calidad y cobertura espacial de los datos, así como la uniformidad climática dentro de una misma zona y la diversidad climática entre diferentes zonas. La Figura 2.5 muestra la ubicación de las 10 zonas seleccionadas y la Tabla 2.1 la descripción de las mismas.

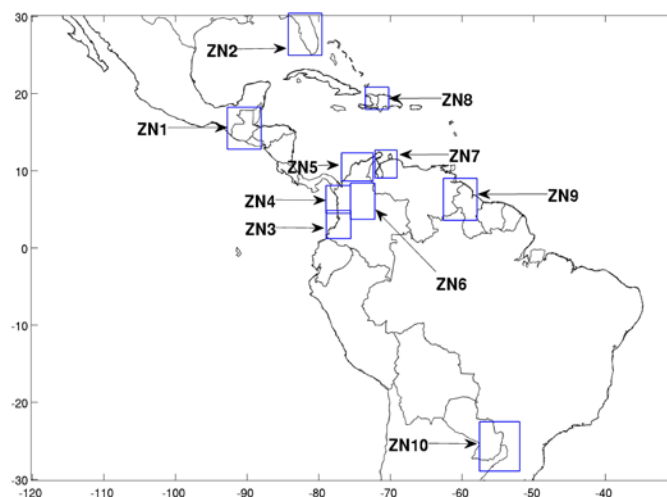


Figura 2.5. Zonas seleccionadas dentro de la región de estudio para analizar los resultados de los modelos de *downscaling* estadístico para la precipitación.

Tabla 2.1. Descripción de las 10 zonas seleccionadas dentro de la región de estudio.

Zonas	Dominio espacial	Descripción
ZN1	12.25°N–18.25°N, 93.75°W–87.75°W,	Límites entre Guatemala y sur de México
ZN2	25.75°N–30.25°N; 82.75°W–79.75°W	Florida, Estados Unidos
ZN3	4.25°N–1.25°S, 78.25°W–76.25°W	Suroeste de Colombia
ZN4	8.25°N–4.25°N, 78.25°W–76.25°W	Noroeste de Colombia
ZN5	12.75°N–8.75°N, 77.75°W–71.25°W	Norte de Colombia
ZN6	8.75°N–4.25°N, 75.75°W–71.75°W	Centro de Colombia
ZN7	13.25°N–9.25°N, 70.75°W, 68.75°W	Extremo norte entre Venezuela y Colombia
ZN8	18.25°N–21.75°N, 73.75°W–70.25°W	en límites entre República Dominicana y Haití
ZN9	9.25°N–4.25°N, 62.25°W–57.75°W	entre Venezuela y Guayana
ZN10	26.75°S–29.25°S, 57.75°W–52.25°W	Límites de Brasil, Argentina Paraguay

2.2.2 Datos de presión a nivel del mar

En el presente estudio se han utilizado datos de la presión a nivel del mar (SLP) en la zona comprendida entre 30°N y 30°S de latitud y entre 120°E y 60°W de longitud, procedentes de dos bases diferentes. La primera de ellas es la base de datos del reanálisis del NCEP, que ha sido empleada tanto en el proceso de evaluación de los Modelos de Circulación General (GCMs) (Capítulo 4), como en su utilización como variable predictora de la precipitación para el desarrollo de los modelos de *downscaling* estadístico (Capítulo 5). Estos datos están disponibles

desde 1948 hasta el presente, con una resolución horizontal de $2.5^{\circ} \times 2.5^{\circ}$ (Kalnay et al., 1996), y en este trabajo se ha empleado el periodo 1950-2005.

La segunda base de datos de SLP utilizada es la del *Hadley Center*, HadSLP2 (Allan and Ansell, 2006), que cuenta con una resolución horizontal de $5^{\circ} \times 5^{\circ}$, cubriendo el periodo 1850-2004. Esta base de datos ha sido utilizada exclusivamente en el proceso de evaluación de las salidas de las simulaciones de los GCMs, empleando el periodo 1950-2004.

2.2.3 Datos de índices de teleconexión

La circulación atmosférica global presenta una serie de patrones espaciales de variabilidad bien definidos (Wallace y Gutzler, 1981; Barnston y Livezey, 1987), especialmente durante el invierno boreal sobre el Hemisferio norte (NH). Tales variaciones pueden estar asociadas con oscilaciones a gran escala en la dinámica atmosférica (por ejemplo, las ondas planetarias, las corrientes en chorro, y los monzones) dando como resultado variaciones simultáneas o con retraso en las condiciones meteorológicas y climáticas en puntos muy distantes sobre la Tierra (patrones de teleconexión). Dichos fenómenos son recurrentes y persistentes. Para estudiar la evolución temporal de tales patrones, se definen unos índices que resumen la fase e intensidad de la oscilación, de manera compacta.

Con el fin de explorar el significado físico de los modos de variabilidad de la SLP, en el presente trabajo se han estudiado las correlaciones existentes entre las componentes principales (PCs) normalizadas de los 10 primeros modos de variabilidad de la SLP estacional y los principales índices de teleconexión, en el periodo 1950-2010 (Capítulo 5). Los índices de teleconexión que resumen los principales modos de variabilidad atmosférica y oceánica a gran escala utilizados son:

Listados de índices de teleconexión, atmosféricos y oceánicos utilizados

INDEX	Nombre en Ingles	Ref
NINO 1+2	Extreme Eastern Tropical Pacific SST (0-10S, 90W-80W) "NOAA Climate Prediction Center (CPC)"	
NINO 3	Eastern Tropical Pacific SST (5N-5S,150W-90W) "CPC"	
NINO 4	Central Tropical Pacific SST (CPC) (5N-5S) (160E-150W) "CPC"	
NINO 3.4	East Central Tropical Pacific SST 5N-5S)(170-120W) "CPC"	

MEI	Multivariate ENSO Index Multivariate ENSO Index (MEI)	
SOI	Southern Oscillation Index	
NAO	North Atlantic Oscillation	
PDO	Pacific Decadal Oscillation	
QBO	Quasi-Biennial Oscillation	
ONI	Oceanic Nino Index	
AMM	Atlantic Meridional Mode	
AMON	Atlantic multidecadal Oscillation	
AAO	Antarctic Oscillation	
CENSO	Bivariate ENSO Timeseries	
GMSST	Global Mean Lan/Ocean Temperature Index	
NP	North Pacific pattern	
PNA	Pacific North American Index	
TNA	Tropical Northern Atlantic Index	
TNI (TRANS-NIÑO INDEX)	Indices of El Niño evolution	(Trenberth y Stepaniak 2001)
WHWP	Western Hemisphere warm pool	(Wang, y. Enfield, 2001)
WP	Western Pacific Index “CPC”	
ATLTRI	Atlantic Tripole SST EOF	(Deser, y Timlin 1997)
EOFAC	Tropical Pacific SST EOF	(Martin et al 2001:)
PACWARM	Pacific Warmpool	“Hoerling et al 2001”

Fuente: <http://www.esrl.noaa.gov/psd/data/climateindices/list/>

2.3 Modelos de Circulación General (GCM)

Los modelos de circulación general (GCMs), gracias a su capacidad para reproducir las principales características físicas y dinámicas del clima (Meehl et al., 2007; Taylor et al., 2012b), constituyen una de las principales herramientas utilizadas en la actualidad para investigar la respuesta del sistema climático al forzamiento radiativo, hacer predicciones climáticas en diferentes escalas de tiempo y realizar proyecciones del clima futuro. Los GCMs han proporcionado diferentes escenarios climáticos para la mayoría de los estudios que implican realizar proyecciones futuras sobre el cambio climático durante el próximo siglo y más allá de este.

2.3.1 Simulaciones de clima presente de los Modelos de Circulación General

Debido a que existen diferencias entre en las simulaciones históricas y, más significativamente, entre las proyecciones futuras de los modelos climáticos, originadas

principalmente por el uso de diferentes parametrizaciones, la utilización de una sola de las simulaciones de los GCMs no proporcionaría resultados que reflejen adecuadamente la incertidumbre inherente a la generación de escenarios climáticos regionales, ya que esto solo representaría una de las posibles vías a seguir por el sistema climático (Cubasch et al., 2001; Giorgi et al., 2001). Así, en el presente estudio se han utilizado las salidas de 40 GCMs, de la quinta fase del proyecto de comparación de modelos acoplados (*Coupled Model Intercomparison Project Phase 5*, CMIP5), del Programa Mundial de Investigaciones Climáticas (WCRP). Estas salidas están disponibles en el servidor web *Earth System Grid Federation* (ESGF), del programa para el Diagnóstico e Intercomparación de Modelos Climáticos (PCMDI, <http://pcmdi9.llnl.gov/>).

Debido a que no existe un enfoque sistemático para determinar cuál de los múltiples *ensembles* en las salidas de los modelos del CMIP5 es la más conveniente para ser elegida, en este trabajo se ha escogido el *ensemble* “r1i1p1” de cada modelo, donde “r1” hace referencia a la primera ejecución del modelo, “i1” al método de inicialización que depende de cada instituto o centro, y por último, “p1” indica la versión del método “*perturbed physics*” (Taylor et al., 2012a). Por otro lado se ha analizado la diferencia entre los distintos miembros del *ensemble* para algunos modelos, no encontrándose diferencias significativas en los campos medios de las variables presión a nivel del mar y temperatura de la superficie del mar. Este tipo de análisis no se realizó con todos los *ensembles* de cada uno de los modelos, debido a la complejidad que conllevaría la búsqueda de detalles, además de no ser el principal objetivo de este trabajo.

En la Tabla 2.2 se presenta el listado de los GCMs pertenecientes al CMIP5 utilizados en este estudio. En la segunda columna aparece la letra asignada a cada modelo que permite una identificación breve del mismo para su representación en los diagramas de Taylor (Capítulo 4).

Se han utilizado las salidas de los GCMs para la variable SLP correspondientes al período *histórico* (1850-2005). En el presente trabajo, a efectos del proceso de evaluación de los distintos GCMs considerados, se ha utilizado el período 1950-2005.

2.3.2 Proyecciones de los Modelos de Circulación General

En las simulaciones de los GCMs del CMIP5, recogidas en el quinto informe de evaluación del IPCC (AR5), se utiliza un nuevo conjunto de escenarios de gases de efecto

invernadero (GEI), de nominados trayectorias de concentración representativas (*Representative Concentration Pathways*, RCP). Las RCPs tienen por objeto hacer una mejor representación de la respuesta del sistema climático a concentraciones crecientes de gases de efecto invernadero, presentando una variedad de posibles evoluciones de la composición atmosférica (Moss et al., 2008, 2010; Musgo et al., 2010). Las proyecciones comprenden en su mayoría un periodo total de simulación para todos los escenarios desde el año 2006 hasta el 2100 (Taylor et al., 2009). En este trabajo, el análisis se ha restringido a tres escenarios (RCP2.6, RCP6 y RCP8.5) para un total de 25 GCMs (los cuales se indican con asterisco en la Tabla 2.2), para el periodo 2071-2100.

Tabla 2.2. Resumen de las características de los GCMs pertenecientes al CMIP5. El asterisco indica los modelos que han sido utilizados en este trabajo. En la primera columna se indica el número del modelo; en la segunda y siguientes, figura el identificador utilizado para el capítulo 4, el nombre del modelo, el centro o grupo al cual pertenece el modelo, y la resolución horizontal atmosférica y oceánica (km) de cada uno.

Nº	Identificador	INSTITUTO ID	Grupo	Resolución Atmosférica	Resolución Oceánica
1	a	ACCESS1.0	CSIRO/Bureau of Meteorology Australia	192×145	360×300
2	b	ACCESS1.3		192×146	360×301
3	c	BCC-CSM1.1*	Beijing Climate Center, China Meteorological Administration (BCC/China)	128×64	360×232
4	d	BCC-CSM1.1(m)*		320×160	360×232
5	e	CCSM4*	National Center for Atmospheric Research (NCAR/USA)	288×192	320×384
6	f	CESM1(BGC)	National Center for Atmospheric Research (NSF-DOE NCAR/USA)	288×192	320×384
7	g	CESM1(CAM5)*		288×192	320×384
8	h	CESM1(FASTCHEM)		288×192	320×384
9	i	CESM1(WACCM)		144×96	320×384
10	j	CMCC-CESM	Centro Euro-Mediterraneo per i Cambiamenti Climatici (CMCC/Italy)	96×48	182×149
11	k	CMCC-CM		480×240	182×149
12	l	CMCC-CMS		192×96	192×96
13	m	CNRM-CM5*	Centre National de Recherches Meteorologiques / Centre Europeen de Recherche et Formation Avancees en Calcul Scientifique (CNRM/France)	256×128	362×292
14	n	CSIRO-Mk3.6.0*	Communication Scientific and Industrial Research Organization (CSIRO/Australia)	96×192	189×192

15	o	CanESM2	Canadian Centre for Climate Modeling and Analysis (CCCma/Canadá)	129×64	256×192
16	p	FGOALS-g2*	LASG, Institute of Atmospheric Physics, Chinese Academy of Sciences; and CESS, Tsinghua University	128×60	360×196
17	q	FGOALS-s2	LASG, Institute of Atmospheric Physics, Chinese Academy of Sciences	128×108	360×196
18	r	FIO-ESM*	The First Institute of Oceanography, SOA, China	128×64	320×384
19	s	GFDL-CM2.1	NOAA Geophysical Fluid Dynamics Laboratory (GFDL/USA)	128×60	360×200
20	t	GFDL-CM3		144×90	360×200
21	u	GFDL-ESM2G*		144×90	360×210
22	v	GFDL-ESM2M*		144×90	360×200
23	w	GISS-E2-H	NASA Goddard Institute for Space Studies (NASA GISS/USA)	144×90	144×90
24	x	GISS-E2-H-CC		144×90	144×90
25	y	GISS-E2-R*		144×90	144×90
26	z	GISS-E2-R-CC		144×90	144×90
27	A	HadCM3	Met Office Hadley Centre (MOHC/UK)	73×96	144×288
28	D	HadGEM2-AO*	National Institute of Meteorological Research (NIMR/South Korea)	145×192	216×360
29	B	HadGEM2-CC	Met Office Hadley Centre(MOHC/UK)	145×192	216×360
30	C	HadGEM2-ES*		145×192	216×360
31	E	IPSL-CM5A-LR*	Institute Pierre-Simon Laplace (IPSL/France)	96×96	149×182
32	F	IPSL-CM5A-MR*		143×144	149×182
33	G	IPSL-CM5B-LR*		96×96	149×182
34	H	MIROC5*	National Institute for Environmental Studies, The university of Tokyo (MIROC/Japan)	128×256	224×256
35	J	MPI-ESM-LR*	Max Planck Institute for Meteorology (MPI-M/Germany)	96×192	220×256
36	K	MPI-ESM-MR*		96×192	404×802
37	L	MPI-ESM-P		96×192	220×256
38	M	MRI-CGCM3*	Meteorological Research Institute (MRI/Japan)	160×320	368×360
39	N	NorESM1-M*	Norwegian Climate Centre (NCC/Norway)	144×96	320×384
40	P	NorESM1-ME*		144×96	320×384

CAPÍTULO 3

METODOLOGÍA

Este Capítulo presenta las principales técnicas de análisis empleadas en la obtención de los modelos de *downscaling* para la precipitación en América tropical. La metodología seguida es de Regresión por Componentes Principales (PCR) que se basa en el Análisis de Componentes Principales (PCA), técnica muy usada en el campo de la Climatología. La aplicación de las técnicas aquí descritas permitirá, por un lado, conocer los principales modos de variabilidad de la presión a nivel del mar (SLP) en área de estudio así como la habilidad de los modelos del CMIP5 para reproducir dichos modos, y la obtención de los predictores para el modelo de *downscaling*. Además se describirán los diagramas de Taylor, usados en la evaluación de las simulaciones de clima presente del CMIP5 y las técnicas de *bootstrapping* utilizadas para los análisis de significación.

3.1 Análisis de Componentes Principales

El Análisis de componentes principales, PCA (Preisendorfer, 1988; Jolliffe, 2002), ha sido ampliamente utilizado en Ciencias de la Atmósfera como herramienta en el estudio de la variabilidad espacial y temporal de campos físicos desde su introducción por Obukhov (1947, 1960), Fukuoka (1951), y Lorenz (1956). De forma general, es una técnica multivariante

empleada para reducir la dimensionalidad de los datos, es to es, simplificar la estructura de la variable multivariante analizada, con el objetivo de obtener una representación sencilla de la misma. La forma en la que se consigue esta reducción de la dimensión de los datos tiene la ventaja, además de la representación de los datos en un número reducido de variables, de que estas no es tán correlacionadas en tresp y de caracterizar los patrones dominantes de las variaciones simultáneas de un campo o variable.

Considerando un conjunto finito de datos compuesto por un campo espacio-temporal $U(t, s)$, que consiste en series temporales medidas en n tiempos correspondientes a p puntos del espacio, este campo puede ser representado como una matriz $U = [U_{t1}, U_{t2}, \dots, U_{tp}]^T$, de orden $n \times p$, en la cual cada vector de $U_t: t = 1, \dots, n$ es un campo espacial, y por tanto se puede considerar que se tienen n realizaciones del campo. Por lo general U es representado como una matriz de datos centrados (anomalías) de n filas y p columnas, esto es, a cada serie temporal se le ha sustraído su valor medio, o estandarizados, es decir, con la media sustraída y divididos por su correspondiente desviación típica. Esto es, si el campo analizado lo escribimos como

$$U = \begin{pmatrix} u_{11} & \dots & u_{p1} \\ \vdots & \ddots & \vdots \\ u_{1n} & \dots & u_{pn} \end{pmatrix} \tag{3.1}$$

las filas representan las muestras en el tiempo y las columnas las variables por punto de medida. Es decir que u_{ij} denota el valor del campo en el tiempo discreto t_i y en el punto espacial s_j , para $i = 1, \dots, n$, y $j = 1, \dots, p$.

A partir de esta matriz de datos se calcula la matriz de covarianza (o de correlaciones si los datos están estandarizados)

$$S = \frac{1}{n} U^T U = \frac{1}{n} \begin{pmatrix} u_{11} & \dots & u_{1n} \\ \vdots & \ddots & \vdots \\ u_{p1} & \dots & u_{pn} \end{pmatrix} \begin{pmatrix} u_{11} & \dots & u_{p1} \\ \vdots & \ddots & \vdots \\ u_{1n} & \dots & u_{pn} \end{pmatrix} = \frac{1}{n} \begin{pmatrix} \sum_i^n u_{1i}^2 & \dots & \sum_i^n u_{1i} u_{ip} \\ \vdots & \ddots & \vdots \\ \sum_i^n u_{1i} u_{ip} & \dots & \sum_i^n u_{pi}^2 \end{pmatrix} \tag{3.2}$$

Formulación de los EOFs

Uno de los objetivos de utilizar el análisis de componentes principales es obtener un número $k \leq p$ de variables incorrelacionadas llamadas componentes principales, PCs, $Z_m =$

$[Z_1, Z_2, \dots, Z_k]$, que son una combinación lineal de las variables iniciales y que explican la mayor parte de su variabilidad (Jolliffe, 2002). Se trata de encontrar un nuevo sistema de coordenadas, es decir, una nueva base, con el criterio de que sobre estas nuevas direcciones las proyecciones de los vectores de observación sean máximas, es to es, en la nueva base $\{\mathbf{e}_1, \dots, \mathbf{e}_p\}$, con $\mathbf{e}_j = (e_j(1), \dots, e_j(p))^T$, la suma de las proyecciones de los vectores $\mathbf{u}(t)$ sobre la dirección \mathbf{e}_j es máxima secuencialmente, siendo, además, los vectores \mathbf{e}_j ortonormales.

Matemáticamente, la obtención de tales vectores se basa en maximizar la expresión:

$$\frac{1}{N} \sum_{t=1}^N [\mathbf{u}^T(t) \mathbf{e}_j]^2 = \frac{1}{N} \sum_{t=1}^N [\mathbf{e}_j^T \mathbf{u}(t)] [\mathbf{u}^T(t) \mathbf{e}_j] \quad (3.3)$$

Con $\mathbf{e}_j^T \mathbf{e}_j = 1$

Con esta última condición, la ecuación (3.3) puede reescribirse como:

$$\frac{1}{N} \sum_{t=1}^N [\mathbf{u}^T(t) \mathbf{e}_j]^2 = \mathbf{e}_j^T \mathbf{S} \mathbf{e}_j$$

La maximización del producto $\mathbf{e}_j^T \mathbf{S} \mathbf{e}_j$, sujeta a las condiciones antes descritas, es un problema de autovalores:

$$\mathbf{S} \mathbf{e}_j = l_j \mathbf{e}_j \Rightarrow (\mathbf{S} - l_j \mathbf{I}) \mathbf{e}_j = 0, \text{ con } j = 1, \dots, p.$$

Donde \mathbf{I} es la matriz identidad de orden $p \times p$. Por tanto, el problema se reduce entonces a diagonalizar la matriz \mathbf{S} , es decir, a encontrar una matriz \mathbf{E} (cuyas columnas son los vectores propios de \mathbf{S}) tal que:

$$\mathbf{E}^{-1} \mathbf{S} \mathbf{E} = \mathbf{L} \text{ o } \mathbf{S} = \mathbf{E} \mathbf{L} \mathbf{E}^T$$

$$\mathbf{S} = \sum_{j=1}^p l_j \mathbf{e}_j \mathbf{e}_j^T$$

Donde \mathbf{L} es diagonal y sus elementos no negativos serán los valores propios. En nuestra aplicación concreta, la matriz a diagonalizar \mathbf{S} , como matriz de covarianzas o correlaciones, es real y simétrica, diagonalizable y con todos los autovalores reales. Los autovectores de \mathbf{S} , \mathbf{e}_j , estarán asociados a los valores propios l_j . A las nuevas direcciones \mathbf{e}_j se les denomina Funciones Empíricas Ortogonales (EOFs).

La representación de las variables iniciales en la nueva base $\{\mathbf{e}_1, \dots, \mathbf{e}_p\}$, se obtiene a partir de la proyección de la matriz de datos sobre los vectores propios

$$\begin{aligned}
 \mathbf{Z}_j &= \mathbf{U} \mathbf{e}_j \quad j = 1, \dots, p \\
 z_j(t) &= \mathbf{u}^T(t) \mathbf{e}_j = \sum_{x=1}^p u(t, x) e_j(x) \quad j = 1, \dots, p; t = 1, \dots, n \\
 \mathbf{Z} &= \mathbf{U} \mathbf{E} \quad (n \times p) \quad \mathbf{Z} = (\mathbf{Z}_1, \dots, \mathbf{Z}_p); \quad \mathbf{Z}_j = (Z_j(1), \dots, Z_j(n)), \quad \dot{\neq} 1, \dots, p
 \end{aligned} \tag{3.4}$$

Además, se tiene que

$$\begin{aligned}
 \mathbf{U} &= \mathbf{U}(\mathbf{E}\mathbf{E}^T) = (\mathbf{U}\mathbf{E})\mathbf{E}^T \\
 \mathbf{U} &= \mathbf{Z}\mathbf{E}^T = \sum_{j=1}^p \mathbf{Z}_j \mathbf{e}_j^T \quad (n \times p)
 \end{aligned} \tag{3.5}$$

Donde la matriz \mathbf{Z} es la matriz de componentes principales, y \mathbf{Z}_j representa la j -ésima componente principal, que puede considerarse como una serie temporal con las mismas dimensiones que los datos iniciales \mathbf{u}_j . Se obtienen proyectando la matriz de covarianzas (o correlaciones) sobre el j -ésimo vector propio o EOF \mathbf{e}_j .

Una propiedad importante de las componentes principales, como ya se ha comentado, es que están incorrelacionadas, esto es

$$\begin{aligned}
 \mathbf{Z}_j^T \mathbf{Z}_k &= n l_j \delta_{jk} \\
 \sum_{t=1}^n Z_j(t) Z_k(t) &= n l_j \delta_{jk}
 \end{aligned} \tag{3.6}$$

Y su varianza es:

$$\mathbf{Var}(\mathbf{Z}_j) = \frac{1}{n} \mathbf{Z}_j^T \mathbf{Z}_j = \frac{1}{n} \sum_{t=1}^n (Z_j(t))^2 = l_j \tag{3.7}$$

La traza de la matriz \mathbf{S} , representa la varianza total de los datos en estudio; de la conservación de la traza se tiene, por tanto, que la suma de los valores propios $l_j, j=1, \dots, p$, es también la varianza total de los datos (ya que ellos representan los elementos de la representación diagonal de \mathbf{S}). Ordenados de mayor a menor, los autovalores l_j representan porciones de varianza del conjunto de los datos; así, l_1 representa la mayor porción de varianza de los datos y la variable \mathbf{Z}_1 obtenida de la ecuación (3.4) es la primera componente principal. En el caso de usar la matriz de correlaciones \mathbf{R} , es tamos estableciendo un nuevo escalado de la varianza, representando el número de variables la varianza total del conjunto de datos. Si tomamos la matriz \mathbf{R} , cada uno de los valores propios representa la varianza porcentual de cada componente, siendo la total igual al número de variables.

Desde la perspectiva de la interpretación climática, los EOFs \mathbf{e}_m representan patrones espaciales de variabilidad, mientras que las PCs, \mathbf{Z}_m , son las series temporales incorrelacionadas que representan la evolución temporal de los patrones espaciales. Una forma útil de analizar estos

patrones espaciales es vía los factores de carga, definidos como las correlaciones entre las series originales y las series PCs. Así, el coeficiente de correlación entre $\mathbf{u}(\cdot, x)$ y \mathbf{Z}_j es:

$$r_{uZ}^2(j, x) = \frac{[\sum_{t=1}^n u(t, x)Z_j(t)]^2}{[\sum_{t=1}^n u^2(t, x)][\sum_{j=1}^p Z_j^2(t)]} = \frac{l_j e_j^2(x)}{\sum_{j=1}^p l_j e_j^2(x)} \quad (3.8)$$

Expresión que se simplifica si se usan datos estandarizados (se diagonaliza la matriz de correlaciones \mathbf{R}) a:

$$r_{uZ}^2(j, x) = \frac{l_j e_j^2(x)}{\sum_{j=1}^p l_j e_j^2(x)} = l_j e_j^2(x) \quad (3.9)$$

Y por tanto, los factores de carga $\sqrt{l_j} e_j(x)$ son con una interpretación directa de los patrones espaciales de variabilidad.

Reglas de selección y rotación de EOFs

El PCA se aplica en muchas ocasiones como una herramienta de reducción de la dimensión, esto es, para reducir el número de variables a tratar. En estas aplicaciones suele diagonalizarse la matriz de covarianzas (salvo que se manejen datos de distintas variables físicas), y el número de PCs a considerar tiende a elegirse de tal forma que en su conjunto explique un porcentaje de varianza elevado del conjunto de datos. En otras situaciones, a partir de cierto valor de l_j , los porcentajes de varianza explicados por los EOFs y sus correspondientes PCs son muy pequeños, conteniendo una información climática poco relevante y representada por patrones espacio-temporales estocásticos. Las reglas de selección establecen criterios que indican a partir de qué EOF, la información es irrelevante o espuria en el análisis realizado. Existen varios tipos de reglas de selección, siendo las basadas en la varianza las más empleadas. Estas reglas se fundamentan en la suposición de que los vectores propios asociados a valores propios más grandes son los más significativos, y los más pequeños representan las variables aleatorias o ruido de los datos.

La regla de North (North et al., 1982) es una de las reglas más usadas en estudios climáticos. Esta regla se basa en la estimación de los errores de los valores propios, cuya expresión es

$$\Delta l_j = \sqrt{\frac{2}{n}} l_j$$

siendo Δl_j el error asociado al valor propio l_j , de tal forma que los valores propios significativos son los primeros para los cuales no se cumple que

$$|l_j - l_{j+1}| < \Delta l_j$$

Así pues, esta regla establece que valores propios que pueden considerarse degenerados, no representan información relevante. Sin embargo, rara vez se van tener realmente valores propios degenerados en una matriz de covarianzas o correlaciones, y desde el punto de vista físico es posible que existan patrones que expliquen porcentajes de varianza similares. Por ello, aunque la regla de North es una regla objetiva, es conveniente emplearla con cierta cautela, junto con otras reglas de selección.

La propiedad de ortogonalidad de los EOFs y de incorrelación entre las PCs es, en muchas ocasiones, de gran utilidad, por ejemplo cuando las series PCs se usan como variables independientes en un modelo de regresión múltiple. Sin embargo, esta restricción de los EOFs y PCs puede dificultar su interpretación física, ya que en la naturaleza, y en particular en el clima, los patrones de variabilidad no necesariamente son totalmente independientes (incorrelacionados), de tal forma que los procesos están interrelacionados.

Este problema se trata mediante la rotación de los EOFs. La rotación supone sustituir los patrones originales por otros más representativos desde el punto de vista físico. Los nuevos EOFs (ahora REOFs) se obtienen a partir de los patrones originales, haciendo que maximicen cierto funcional alineal de simplicidad.

En estudios climáticos, la rotación se aplica para obtener patrones espaciales físicamente coherentes, que tengan la varianza espacial mínima posible. Para este fin, la rotación más usada es la varimax-row (Richman, 1986). Partiendo de los patrones EOFs obtenidos, $\{\mathbf{e}_1, \dots, \mathbf{e}_M\}$, (M es el número de EOFs significativos) se obtienen unos nuevos patrones rotados $\{\mathbf{e}^r_1, \dots, \mathbf{e}^r_M\}$, tales que minimizan la medida de simplicidad,

$$\mathcal{F}(\mathbf{e}^r_1, \dots, \mathbf{e}^r_M) = \sum_{m=1}^M f_r(\mathbf{e}^r_m)$$

donde

$$f_r(\mathbf{e}_m) = \frac{1}{p} \sum_{i=1}^p (e_{mi})^2 - \frac{1}{p^2} \left(\sum_{i=1}^p e_{mi} \right)^2$$

y donde e_{mi} es la componente i -ésima del vector \mathbf{e}_m .

3.2 Métodos de *downscaling* estadístico

Las técnicas de reducción de escala estadística (*statistical downscaling*, DS), son una alternativa al *downscaling* dinámico, que presentan la ventaja de un menor costo computacional. En esencia, las técnicas de DS consisten en la utilización de métodos estadísticos que buscan establecer relaciones empíricas entre las variables predictoras (por ejemplo SLP o SST) y los predictandos (valores observacionales de precipitación) (Bronstert et al., 2002; Fowler et al., 2007).

En la práctica este tipo de técnicas requiere transformar los predictores originales $X(t)$ en un nuevo conjunto de variables interpretables $Z_m(t)$ que eviten los efectos de la multicolinealidad y alta dimensionalidad de sus variables, siendo, como ya se ha dicho, el PCA una de las técnicas estadísticas multivariantes más utilizada en las Ciencias de la Atmósfera (Preisendorfer, 1988; Jolliffe, 2002; Wilks, 2009; Hannachi et al., 2007).

Las nuevas variables originadas, las series PCs, $Z_m(t)$, contienen un gran porcentaje de la variabilidad de campo predictor $X(t)$, que corresponde a las variables originales. Sin embargo, $Z_m(t)$ por sí solas no representan ninguna información sobre los predictandos. Por lo tanto, la utilización de técnicas estadísticas que maximizen las interrelaciones entre los predictores y el campo predictando, como la regresión de componentes principales (PCR), el análisis de correlación canónica (CCA) o el análisis parcial de mínimos cuadrados (PLS) entre otros, se convierten en los métodos apropiados para optimizar este proceso de interrelación (Fernández y Sáenz, 2003; Bergant y Kajfez-Bogataj, 2005).

3.2.1 Métodos de *regresión multivariada*

Los modelos basados en la regresión multivariada son generalmente simples y de fácil interpretación al tratar de representar el grado de relación lineal (o no lineal a través de una transformación de los datos) entre los predictores y el predictando.

Multicolinealidad

En la regresión múltiple, la estimación de parámetros es una parte esencial del ajuste del modelo y de su interpretación. Uno de los principales problemas con los habituales estimadores por mínimos cuadrados de un modelo lineal con muchos regresores es la multicolinealidad, que

describe la situación en la que dos o más variables predictoras en un modelo estadístico están relacionadas linealmente, es decir la existencia de dependencia casi lineal entre las variables predictoras (Draper and Smith, 1981; Jolliffe, 2002). El efecto de la multicolinealidad radica en la ineficiencia de la estimación de los coeficientes de regresión, de tal forma que las varianzas de algunos de los coeficientes de regresión estimados pueden llegar a ser muy grande, por lo que el modelo tiende a producir estimaciones inestables y potencialmente engañosas, generando dificultad en la evaluación relativa de las variables, lo que significa que los mejores predictores pueden no ser relevantes, incluso si son verdaderamente influyente debido a que los coeficientes pueden ser estimados, pero con errores estándar exagerados (Jolliffe, 2002; Wilks, 2006).

Se han propuesto varias técnicas para abordar el problema de la multicolinealidad y aumentar la precisión de las estimaciones. A continuación se comentan brevemente estas opciones:

(1) **Eliminación de variables.** Debido a su simplicidad, la eliminación de series o variables altamente correlacionadas es un método muy utilizado. Los métodos de regresión por pasos (*stepwise*) tienen en cuenta este enfoque. Pero presenta dos inconvenientes, que afectan de manera significativa al modelo. En primer lugar, la obtención de una reducción significativa de la respuesta del modelo por parte de las variables explicativas. En segundo lugar, la determinación de qué variables se encuentran altamente correlacionadas entre sí, para proceder a retirarlas del modelo, lo cual es un desafío cuando su el número de variables es muy grande.

(2) **Transformación ortogonal de los datos.** El propósito de realizar una transformación ortogonal de las variables originales U_t , es obtener un nuevo conjunto de variables incorrelacionadas Z_m que sean independientes entre sí. Para ello pueden usarse técnicas como el anteriormente descrito PCA.

(3) **Búsqueda de estimaciones sesgadas.** La idea es buscar estimadores sesgados de los coeficientes de regresión pero con varianzas más pequeñas que los estimadores obtenidos por mínimos cuadrados, tales como la regresión por componentes principales (PCR) y la regresión por mínimos cuadrados parciales (PLS).

3.2.2 Método de regresión por componentes principales (PCR)

Como se ha mencionado anteriormente, la multicolinealidad entre un subconjunto de datos se convierte en una seria dificultad cuando un modelo de regresión tiene un gran número de datos de entrada, y lleva a estimaciones erróneas de la ecuación de regresión (Draper y Smith, 1981; Jolliffe, 2002). El uso de estimadores de regresión sesgados, como la regresión de componentes principales (PCR) se sugiere comúnmente para abordar los problemas asociados con la multicolinealidad (Draper y Smith, 1998). Por otro lado es una técnica de análisis de datos multivariante que generaliza y combina las mejores características de la regresión lineal múltiple y el análisis de componentes principales (Wold et al., 1987). El objetivo del PCR es elegir el modelo de regresión con la raíz del error cuadrático medio (RMSE) más bajo. El primer paso en el análisis de PCR, consiste en realizar un PCA sobre la matriz de covarianza de los datos de entrada usados como campo predictor, seguido de un análisis de regresión lineal sobre las componentes principales seleccionadas, a partir de correlacionar las PCs seleccionadas con el campo predictando. Este es el método que se empleará para modelar la precipitación estacional a partir de las PCs de la SLP (Capítulo 4) siguiendo el esquema propuesto por Li y Smith (2009), descrito a continuación.

Considere un modelo de regresión por componentes principales (PCR) (Draper y Smith, 1981; Jolliffe, 2002) para llegar a un modelo predictivo de una variable (por ejemplo, la precipitación) $[Y(t)]$, $t = 1, \dots, N$, como sigue:

$$Y(t) = \sum_{k=1}^{M^*} \alpha_k Z_k(t) + \varepsilon_t \quad (3.10)$$

donde Z_k representan las series PCs del campo predictor, siendo M^* el número de PCs consideradas para representar el campo predictor. El modelo es ajustado mediante mínimos cuadrados usando un conjunto de datos de entrenamiento correspondientes a n años ($n < N$), $\{(X(t), Y(t)) : t = 1, \dots, n\}$, es de la forma

$$\hat{Y}(t) = \sum_{m=1}^{M^*} \hat{\alpha}_m Z_m(t) \quad (3.11)$$

el cual puede ser escrito como

$$\hat{Y}(t) = \sum_{m=1}^{M^*} \hat{\alpha}_k \left(\sum_{k=1}^p e_{km} X_k(t) \right) = \sum_{k=1}^p \hat{\beta}_k X_k(t) \quad (3.12)$$

donde

$$\hat{\beta}_k = \sum_{m=1}^{M^*} \hat{\alpha}_k e_{km}(t)$$

El modelo calibrado o "entrenado" basado en el conjunto de datos $\{(X(t), Y(t)) : t=1, \dots, n\}$ dado por la ecuación (3.12) puede demostrar su robustez mediante el uso de datos independientes $\{(X(t+h), Y(t+h)) : h=1, \dots, N-n\}$. Así pues, la aplicación del modelo pasa por la proyección del campo predictor para cualquier tiempo sobre los EOFs de este campo obtenidos en el intervalo de calibración; es decir, para obtener las predicciones en un periodo distinto del de calibración se usan como variables predictoras las proyecciones (a modo de PCs) del campo predictor en ese tiempo.

Más aún, puesto que el objetivo del *downscaling* estadístico es la obtención de valores futuros de la precipitación usando salidas de GCMs, estas proyecciones se obtienen como

$$\hat{Y}(t) = \sum_{m=1}^{M^*} \hat{\alpha}_k \left(\sum_{k=1}^p e_{km} X'_k(t) \right) = \sum_{k=1}^p \hat{\beta}_k X'_k(t)$$

donde X' representa el campo predictor (SLP) de los GCMs.

3.2.3 Intervalos de confianza: *Bootstrapping*

El *bootstrapping* es una técnica de estimación no paramétrica descrita por Efron (1979) y Efron y Tibshirani (1993). Se trata más que de una técnica o modelo específico, de un método general a partir del cual pueden cubrirse diferentes objetivos de análisis de datos, incluyendo la estimación de intervalos de confianza (IC) o tests de significación estadística. Para ello se obtiene la distribución de muestreo de un estadístico y de sus propiedades mediante un procedimiento muy simple que consiste en crear un gran número de muestras con reposición de los datos observados. Recordemos que la distribución de muestreo de un estadístico es clave a la hora de realizar tareas de inferencia estadística. Así pues el *bootstrapping* es una técnica de remuestreo.

En este trabajo, el objetivo del *bootstrapping* ha sido cuantificar la incertidumbre de las estimaciones de las precipitaciones a escala reducida utilizando la ec. (3.11) en relación con un "futuro" $X_i(t+h)$ ($i=1, \dots, p, h=1, \dots, N-n$). Para ello hay que establecer la función de distribución acumulativa G para el intervalo de confianza de l error de predicción $Y(t+h) - \hat{Y}(t+h)$, donde $\hat{Y}(t+h) = \sum \hat{\beta}_k X_k(t+h)$ viene dado por la ec. (3.11). Un intervalo de confianza al $100(1-\alpha)\%$ de l a predicción $Y(t+h)$ basado en un " futuro" $X_i(t+h)$ ($i=1, \dots, p; h=1, \dots, N-n$) viene dado por

$$\left[\hat{Y}(t+h) + G^{-1}(\alpha/2), \hat{Y}(t+h) + G^{-1}(1-\alpha/2) \right] \quad (3.13)$$

Sin embargo, ya que se desconoce la distribución de la variabilidad residual ε_t en el modelo PCR dado por la ec. (3.10), no se puede obtener la distribución G analíticamente. Esta es obtenida mediante *bootstrapping*, siguiendo el esquema propuesto por Stine (1985) y adaptado por Li y Smith (2009).

En primer lugar, el parámetro de estimación $\hat{\beta}_k$ es calculado utilizando los datos de entrenamiento observados $\{(X(t), Y(t)), t=1, \dots, n\}$. Estas estimaciones son entonces utilizadas para calcular valores ajustados de $\hat{Y}(t)$ y los residuos $e_t = Y(t) - \hat{Y}(t)$.

Para una muestra independiente $\{X(t+h), 1 \leq h \leq N-n\}$, el valor predicho viene dado por $\hat{Y}(t+h) = \sum_{k=1}^p \hat{\beta}_k X_k(t+h)$. La distribución de l error F se estima mediante la distribución empírica de los residuos, que denotamos F_n , generada mediante $B = 1000$ nuevas réplicas de los campos $X_k(t)$ e $Y(t)$ (SLP y precipitación, en este caso) con reemplazo, derivados de las series originales.

Cada muestra *bootstrap* se utiliza para calcular una estimación simulada β_k^* para la obtención del valor predicho $\hat{Y}^*(t+h)$ y del error predicho $e_t^* = Y^*(t+h) - \hat{Y}^*(t+h)$. La distribución

empírica de e_i^* , \tilde{G} es una estimación de la distribución de los errores de predicción de la *bootstrapping*, la cual se puede utilizar como estimación de la función de distribución G en la ecuación (3.13). Por lo tanto, un intervalo de predicción $100(1-\alpha)\%$ para la precipitación futura $Y(t+h)$, se puede estimar como

$$\left[\hat{Y} = (t+h) + \tilde{G}^{-1}(\alpha/2), \hat{Y} = (t+h) + \tilde{G}^{-1}(1-\alpha/2) \right] \quad (3.14)$$

Donde $\tilde{G}^{-1}(\alpha/2)$ es el $(\alpha/2)$ -ésimo percentil de las B réplicas *bootstrapping*.

El método de *bootstrapping* también se puede utilizar para obtener una estimación de error de los distintos parámetros de la regresión. El enfoque más simple posible es el método percentil en el que a partir de la estimación de los modelos con $B = 1000$ muestras *bootstrap*, se obtienen los percentiles correspondientes a los valores de $B(\alpha/2)$ y $B(1-\alpha/2)$ que definen los intervalos de confianza al $100(1-\alpha)\%$. A partir de estos coeficientes se calcula

$$t_b = \frac{\hat{\theta}_b - \hat{\theta}}{\hat{\sigma}_b}$$

que sigue una t de Student con $n-2$ grados de libertad, donde $\hat{\theta}_b$ es la estimación del estadístico de interés, obtenido de la b -ésima muestra *bootstrap*, $\hat{\sigma}_b$ es la desviación estándar de esta estimación, y $\hat{\theta}$ es la estimación obtenida a partir del conjunto de datos original completo (por ejemplo, los coeficientes de regresión). Por tanto, los intervalos de confianza por *bootstrapping* vienen dados por

$$\hat{\theta} - t_b \left(1 - \frac{\alpha}{2} \right) \leq \theta \leq \hat{\theta} - t_b \frac{\alpha}{2} \quad (3.15)$$

3.3 Diagramas de Taylor

Los diagramas de Taylor (Taylor, 2001) permiten evaluar de forma sencilla y compacta las principales diferencias entre un determinado patrón de variabilidad (REOF) en los modelos (en nuestro caso de las simulaciones históricas de los GCMs del CMIP5) respecto al del campo de referencia u observacional (la SLP del NCEP o del HadSLP2). Este diagrama permite resumir algunos parámetros estadísticos y comparar los resultados de varios modelos respecto a las observaciones, al mostrar sus coeficientes de correlación, la raíz del error cuadrático medio (RMSE),

y la varianza total explicada por cada modo de la SLP de los modelos en comparación con la SLP de la base de datos observacional. El coeficiente de correlación R es un coeficiente de correlación espacial definido como:

$$R = \frac{\frac{1}{N} \sum_{i=1}^N (f_n - \bar{f})(r_n - \bar{r})}{\delta_f \delta_r} \quad (3.16)$$

donde N es el número de puntos de rejilla, f_n son los valores del patrón espacial obtenido con los datos modelados y r_n con los datos observados en cada punto, mientras que las medias \bar{f} y \bar{r}

son las medias de ambos, y $\delta_f = \left[\frac{1}{N} \sum_{i=1}^N (f_n - \bar{f})^2 \right]^{1/2}$ y $\delta_r = \left[\frac{1}{N} \sum_{i=1}^N (r_n - \bar{r})^2 \right]^{1/2}$ son las

desviaciones estándar para f y r , respectivamente.

La diferencia en los errores cuadráticos medios centrados (RMSE) viene dada por

$$E' = \left[\frac{1}{N} \sum_{i=1}^N ((f_n - \bar{f}) - (r_n - \bar{r}))^2 \right]^{1/2} \quad (3.17)$$

El diagrama de Taylor representa la información referida δ_f / δ_r , E' y R en un gráfico polar. La razón por la que en cada punto del plano bidimensional del diagrama de Taylor se pueden cuantificar las diferencias entre dos campos, con tres estadísticos distintos al mismo tiempo, es que estos estadísticos están relacionados por la siguiente ecuación:

$$E'^2 = \delta_f^2 + \delta_r^2 - 2\delta_f \delta_r R \quad (3.18)$$

Prueba de Wilcoxon-Mann-Whitney

Se ha utilizado el test de Wilcoxon-Mann-Whitney para determinar si los promedios entre la precipitación estimada por el DS y la observada, así como la proyectada para diferentes escenarios de emisión en el futuro y para el periodo histórico difieren significativamente (Iman 1994). Esta prueba no paramétrica se basa en rangos y es ligeramente menos potente que las pruebas paramétricas, como la prueba t , pero no requiere muestras que sigan una distribución normal (Helsel y Hirsch, 1992). La necesidad del uso de este test viene dada por el hecho de que se desconoce la distribución de probabilidad que sigue la precipitación en el futuro. Además esta prueba no requiere homocedasticidad.

Considere dos muestras independientes Y_1 , de tamaño n_1 , e Y_2 , de tamaño n_2 , extraídas de la misma población o de dos poblaciones idénticas. Se mezclan las $n_1+n_2 = n$ observaciones y, como si se tratara de una sola muestra, se le asignan rangos R_i (1 a la más pequeña, 2 a la más pequeña de las restantes, ..., n a la más grande; resolviendo los empates asignando el rango promedio), teniendo n_1 rangos R_{i1} (los n_1 rangos correspondientes a las observaciones de la muestra Y_1) y n_2 rangos R_{i2} (los n_2 rangos correspondientes a las observaciones de la muestra Y_2).

Se calculan los estadísticos $S_1 =$ “suma de los rangos asignados a la muestra Y_1 ” y $S_2 =$ “suma de los rangos asignados a la muestra Y_2 ”. Para ambas muestras Y_1, Y_2 se calculan los estadísticos:

$$U_1 = n_1 n_2 + \frac{n_1(n_1+1)}{2} - S_1 \quad U_2 = n_1 n_2 + \frac{n_2(n_2+1)}{2} - S_2 \quad (3.19)$$

Puesto que se supone que las dos muestras se han extraído de dos poblaciones idénticas, cabe esperar que U_1 y U_2 sean aproximadamente iguales (excepto en la cantidad atribuible a las fluctuaciones propias del azar muestral). Si U_1 y U_2 son muy distintos, existirá cierta evidencia de que las muestras proceden de poblaciones distintas. Por tanto, la hipótesis nula de que ambos promedios poblacionales son iguales podría rechazarse si U_1 (o U_2) es demasiado grande o demasiado pequeño. Para determinar esto último, podemos basarnos en la probabilidad concreta asociada al estadístico U :

$$U = U_1 \quad \text{si } U_1 < \frac{n_1 n_2}{2} \quad \text{ó} \quad U = U_2 \quad \text{si } U_2 < \frac{n_1 n_2}{2} \quad (3.20)$$

La distribución de U está tabulada para distintos valores del nivel crítico (significación), α . Si n_1 y n_2 (en la práctica mayores de 8) son suficientemente grandes, el estadístico

$$Z = \frac{U - \mu_U}{\sigma_U} = \frac{U - \frac{n_1 n_2}{2}}{\sqrt{\frac{n_1 n_2 (n_1 + n_2 + 1)}{12}}} \quad (3.21)$$

sigue una distribución normal. Así, se rechazará la hipótesis nula (igualdad de medias) al nivel de confianza del 95% si $|Z| > 1.96$.

CAPÍTULO 4

VALIDACIÓN DE LA SLP EN LOS MODELOS DEL CMIP5

Como paso previo para la obtención de proyecciones regionales de cambio climático para la precipitación de la zona de América tropical, en este capítulo se presenta una evaluación de la SLP en el área de estudio procedente de 40 modelos de circulación general de la quinta fase del Proyecto de Intercomparación de Modelos Acoplados “*Coupled Model Intercomparison Project Phase 5 (CMIP5)*”, tanto a escala mensual como estacional, a partir de las salidas de clima presente. Se presenta un análisis detallado de las diferencias del campo medio y de la varianza, de la SLP de cada modelo respecto a la SLP del NCEP, así como una comparación de sus principales modos de variabilidad.

4.1 Introducción

El análisis de las diferencias de los campos medios de la SLP en los distintos modelos del CMIP5 respecto a los datos de reanálisis del NCEP, es la primera parte del presente capítulo, cuyo principal objetivo radica en la identificación de las regiones en las que los GCMs son capaces de reproducir mejor los valores de la SLP, así como la identificación de zonas en las que esta variable puede estar sobre o subestimada por los distintos modelos. En primer lugar, este

análisis se hace a partir de los valores mensuales (apartado 4.1), y posteriormente en base estacional (apartado 4.2), siendo el periodo de estudio 1950-2005. Para ello, para cada modelo se ha analizado una simulación de la SLP de clima presente en el periodo mencionado.

Actualmente muchos investigadores reconocen que los estudios de cambio climático no pueden limitarse solamente a los cambios en los campos medios (Taylor et al., 2012, IPCC, 2013). Así, varios autores han comparado las varianzas de los valores mensuales y estacionales de los datos observados y de los simulados a partir de los GCMs. En este capítulo, además de analizar las diferencias en los valores medios de la SLP, se analizan los resultados obtenidos para los cocientes entre las varianzas de los datos de SLP simulados y observados. La determinación de la significación estadística de los cambios encontrados se realiza mediante un test-t de Student para los campos medios, y una prueba F para el análisis de varianzas. La óptima representación en la varianza es aquella cuyo valor del cociente es igual a 1 o lo más cercano a este valor; si la distribución espacial muestra una zona con valores por debajo de la unidad, la región presenta un déficit de variabilidad respecto a la de los datos del NCEP, o un exceso de la variabilidad si la relación es mayor que 1.

También en este capítulo se plantea estudiar si los modelos analizados son capaces de reproducir de manera razonable los diferentes modos de variabilidad de la SLP. Para ello se aplica el análisis de componentes principales a las anomalías mensuales de la SLP del reanálisis (NCEP) y observacionales (HadSLP2), así como a los datos correspondientes a las salidas de los modelos, en el periodo 1950-2004. Los EOFs significativos que se obtienen en cada caso, son rotados para lograr una mejor interpretación física de los patrones obtenidos. La representación de sus factores de carga permite estudiar la distribución espacial asociada a estos modos de variabilidad y extraer conclusiones respecto a la capacidad que presentan los 40 modelos del CMIP5 considerados para reproducir dichos modos.

4.2 Validación de la SLP mensual

4.2.1 Análisis de los campos medios y de la varianza

En la Figura 4.1 se muestran los resultados obtenidos para las diferencias de los campos medios entre la SLP de los modelos del CMIP5 respecto a los datos de reanálisis en escala mensual, indicándose con “.” los puntos de rejilla donde las diferencias no son significativas al nivel de confianza del 95% de acuerdo con los resultados del test-t. Claramente se observa que la

mayoría de los modelos tienden a subestimar la SLP tanto en el extremo norte como en el extremo sur del área de estudio. En cambio estas diferencias no son tan notables en la zona de influencia del ENSO (inferiores a un 1 hPa en la mayoría de los casos), y son ligeramente superiores en el resto de la zona de estudio para todos los modelos con la excepción de los modelos FGOALS-g2 (p), FGOALS-s2 (q), GFDL-ESM2G (u) y GFDL-ESM2M (v), que tienden a subestimar ligeramente los campos medios de la SLP (aproximadamente en 2 hPa), y de los modelos GFDL-CM2.1 (s), GFDL-CM3 (t), GISS-E2-H (w), GISS-E2-H-CC (x), GISS-E2-R (y) y GISS-E2-R-CC (z) que sobrestiman los valores observacionales de la SLP, entre 2 hPa y 4 hPa, siendo el HadCM3 (A) el modelo que presenta los máximos valores de sobrestimación. Adicionalmente se observa que estos modelos muestran diferencias sustanciales de sobrestimación del campo medio de la SLP en la zona correspondiente a la cordillera de los Andes. En cambio, los modelos IPSL-CM5A-LR (E), IPSL-CM5A-MR (F) y IPSL-CM5B-LR (G) subestiman en mayor medida el campo medio de la SLP al sur de la cordillera de los Andes.

Desde un punto de vista más general, se observa que la mayoría de los modelos presentan una ligera tendencia a la sobrestimación de la SLP en el Pacífico ecuatorial, y a la subestimación en el extremo noroeste y al este de las costas australianas. Los modelos c-h, p-r, u, v, E, F, M, N y P de la Figura 4.1 muestran subestimaciones moderadas, inferiores a 4 hPa, en zona continental de América central. Finalmente, cabe decir que se aprecia que muy pocos modelos muestran zonas con diferencias no significativas.

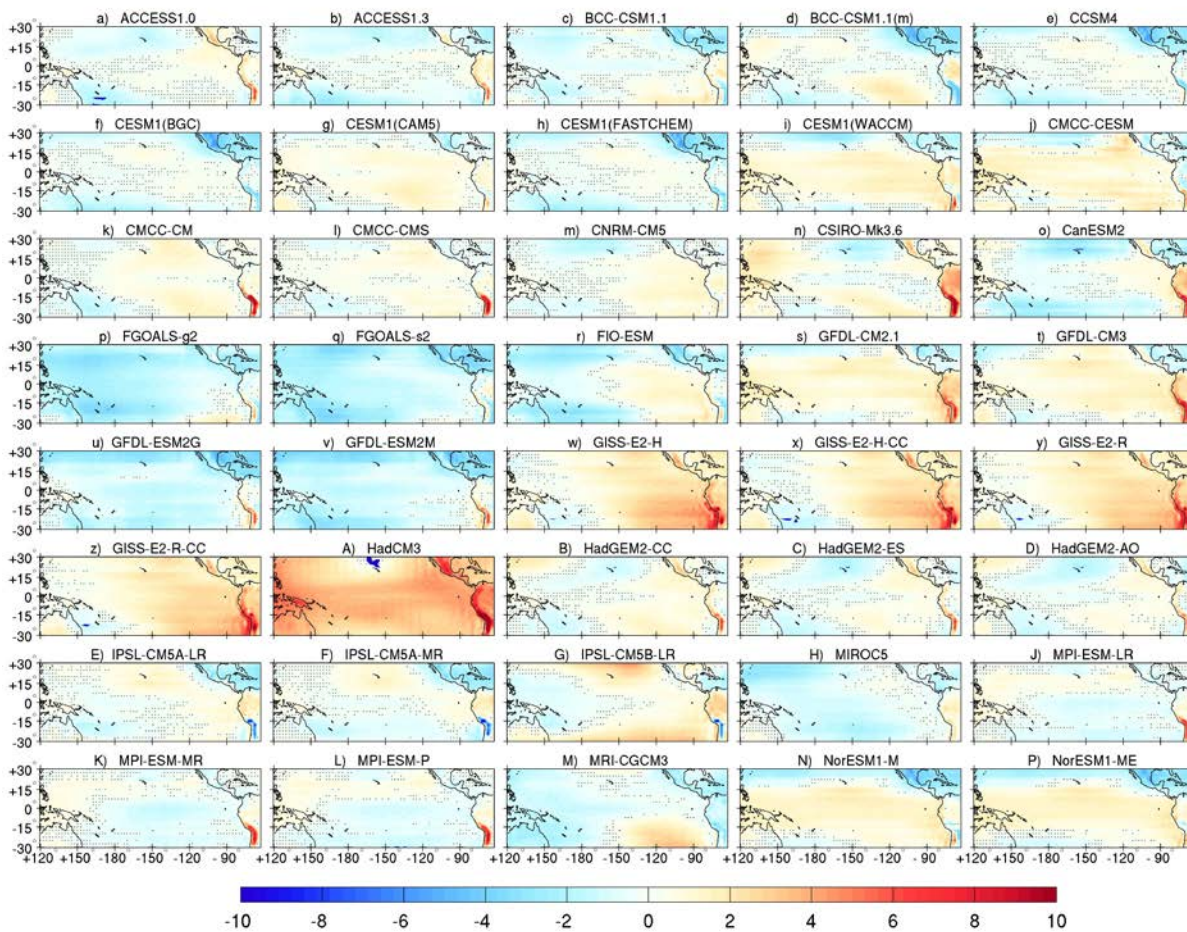


Figura 4.1: Distribución espacial de las diferencias (hPa) entre los campos medios de la SLP de los 40 modelos del CMIP5 y del NCEP ($SLP_{GCM} - SLP_{NCEP}$), durante el periodo de 1950-2005. Las áreas donde las diferencias no son significativas al nivel de confianza del 95% están marcadas por “.”.

En la Figura 4.2 se muestra el cociente entre el campo de varianzas simulado por cada GCM y el observado durante el periodo de 1950-2005. Los resultados de la evaluación sugieren que, para el clima actual, las anomalías de algunas simulaciones no son coherentes con las del conjunto de datos del reanálisis. Aunque un gran número de las simulaciones reproducen las características generales de la variabilidad observada, hay algunas diferencias notables. Así, la variabilidad de la SLP en la zona tropical es bien reproducida por la mayoría de los modelos en la superficie oceánica y, en menor medida, en áreas continentales, donde los valores se encuentran dentro del rango aceptable según la prueba F. Los resultados indican que las simulaciones de los modelos FGOALS-s2 (q), GFDL-CM2.1 (s), GFDL-ESM2G (u), GFDL-CM3 (t) y GFDL-ESM2M (v) difieren considerablemente en su capacidad de reproducir la variabilidad interanual de las anomalías de la SLP del NCEP, sobreestimando fuertemente la variabilidad de la SLP sobre prácticamente toda la zona de estudio, con excepción de Australia.

Por otra parte, las simulaciones del BCC-CSM1.1 (c) y BCC-CSM1.1(m) (d), se caracterizan por la presencia de dos fuertes núcleos de sobreestimación de la varianza en la zona norte del área de estudio, que también aparecen, pero más débiles, en las simulaciones del HadGEM2-CC (B), HadGEM2-ES (C), HadGEM2-AO (D), IPSL-CM5A-LR (E), IPSL-CM5A-MR (F), IPSL-CM5B-LR (G) y del MRI-CGCM3 (M). Por otro parte, la Figura 4.2 muestra que las simulaciones del GISS-E2-H (w), GISS-E2-H-CC (x), GISS-E2-R (y) y GISS-E2-R-CC (z), presentan un déficit significativo de la variabilidad respecto al NCEP, en toda la franja central del Pacífico tropical (entre los 10°S y 10°N aproximadamente). Finalmente, en la Figura 4.2 se muestra que las simulaciones que hacen una mejor representación la varianza en la región de estudio son las de ACCESS1.0 (a), ACCESS1.3 (b), CCSM4 (e), CESM1(BGC) (f), CESM1(CAM5) (g) y CESM1(FASTCHEM) (h).

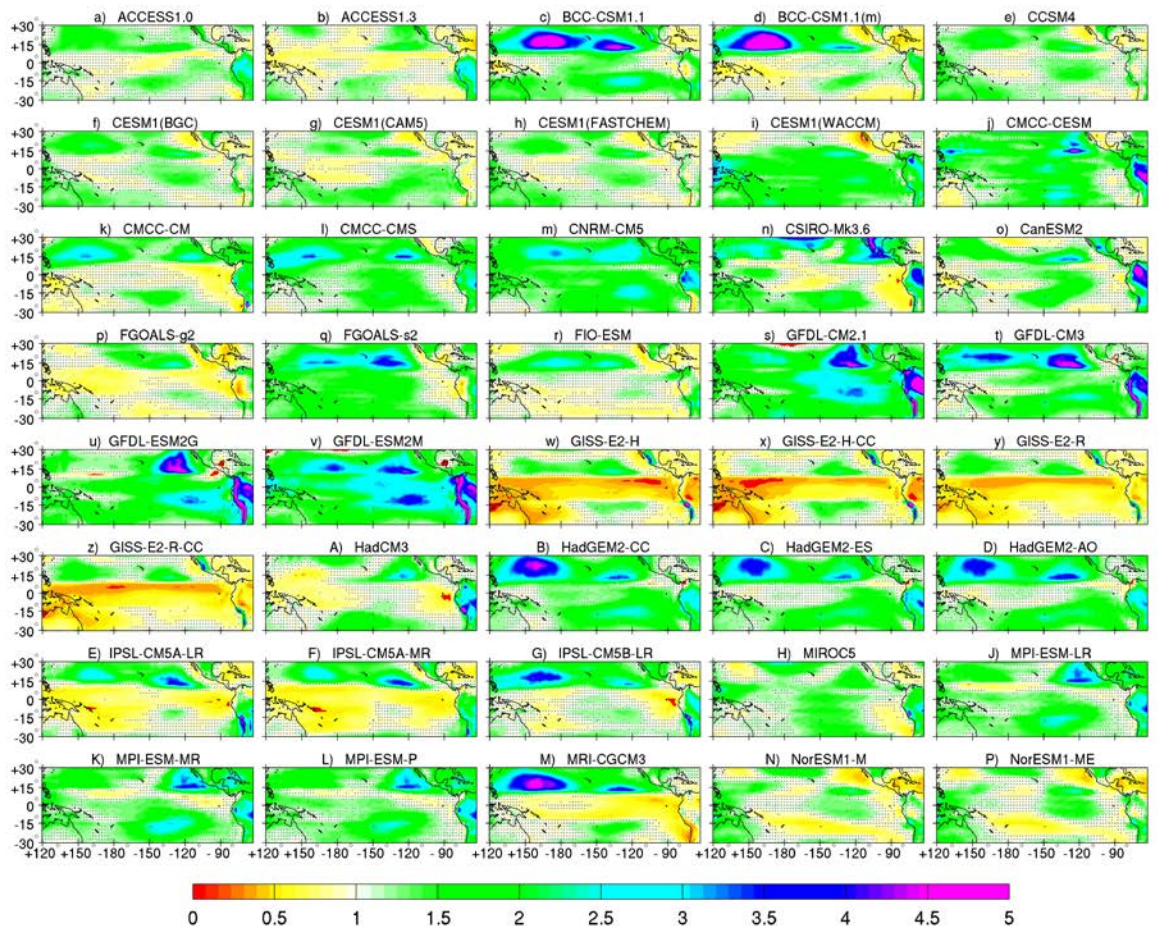


Figura 4.2. Cociente entre el campo de varianzas de la SLP de 40 modelos del CMIP5 y del NCEP durante el periodo 1950-2005. Las áreas donde los cocientes no son significativos al 95% están marcadas por “.”.

4.2.2 Análisis de los modos de variabilidad mensual

Como se ha comentado al comienzo de este capítulo, se ha aplicado el análisis de componentes principales a los datos de anomalías mensuales de SLP del NCEP, así como a los del HadSLP2, correspondientes al periodo 1950-2004. Los resultados muestran la existencia de 4 EOFs significativos que han sido rotados para lograr una mejor interpretación física de los patrones obtenidos. La Figura 4.3 muestra la distribución espacial de estos cuatro primeros EOFs (para ambos conjuntos de datos, NCEP y HadSLP2) mediante la representación de sus factores de carga. Estos cuatro modos de variabilidad significativos encontrados, para el caso de la SLP del NCEP, explican un 24.95%, 19.33%, 9.78% y 7.42% de la varianza, respectivamente, representando en conjunto el 61,48% de la varianza total de la SLP. Los cuatro primeros EOFs correspondientes a los datos del HadSLP2 explican porcentajes similares de varianza (23.41%, 17.31%, 10.02% y 8.04%, respectivamente). A primera vista, los patrones espaciales asociados al primer modo de variabilidad (REOF1) de l NCEP y d el H adSLP2 son similares, estando asociado al fenómeno ENSO. Este primer modo de variabilidad de la SLP, con un coeficiente de correlación entre los patrones espaciales del NCEP y de l HadSLP2 de 0.98, exhibe un fuerte núcleo de correlación con valores positivos entre los 150°W -90°W, más pronunciado para el NCEP, y débiles correlaciones negativas llegando a casi cero en el oeste del Pacífico tropical. Adicionalmente, se observa que el patrón de correlaciones para el REOF1 del NCEP, presenta valores de correlación más bajos a medida que se adentra en la zona continental de América del Sur, mientras que, el centro de correlaciones negativas es muy similar en ambas bases de datos.

El porcentaje de varianza explicada por el segundo modo de variabilidad (REOF2) en el NCEP (19.33%) es ligeramente superior que en el HadSLP2 (17.31%), presentando un patrón típico de la circulación de Walker. Este modo muestra un fuerte núcleo de correlaciones positivas sobre el Pacífico tropical occidental, entre 120°E y 165°W, y otro pequeño centro, también de correlaciones positivas pero más débiles, sobre el continente sudamericano. En contraste, a parecen correlaciones negativas dividiendo estos centros de acción. Este patrón espacial es muy similar al de la Oscilación del Sur (Philander, 1989).

El REOF3 (9.78% de varianza explicada para el NCEP y 10.02% para el HadSLP2) presenta un fuerte núcleo de correlaciones positivas ubicadas sobre toda la zona continental y costa oeste del continente americano, el cual tiende a debilitarse a medida que se extiende sobre

la franja ecuatorial hasta los 150°W, junto con dos centros de correlaciones negativas ubicados al norte, alrededor de los 15°N-140°E, y al sur, por debajo de los 15°S.

Por otro lado, el cuarto modo de variabilidad (REOF4) explica un 7.42% de la varianza de la SLP del NCEP y un 8.04% del HadSLP2, mostrando un fuerte centro de correlaciones positivas por encima de los 10°N, entre los 130°E y los 120°W.

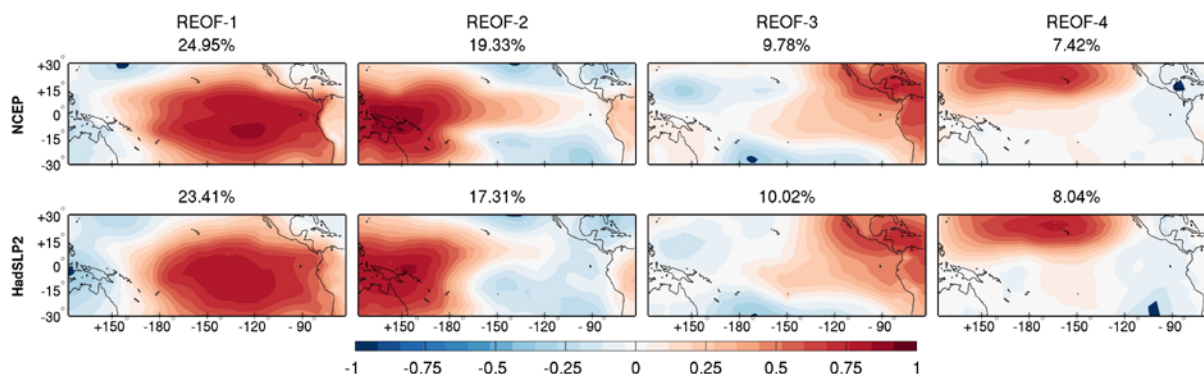


Figura 4.3. Factores de carga de los cuatro primeros REOFs de las anomalías mensuales de la SLP del NCEP y del HadSLP2, para el periodo 1950-2005.

Las Figuras 4.4 y 4.5 ilustran los patrones espaciales de variabilidad de las anomalías mensuales de SLP asociados a dos primeros REOFs de los 40 modelos del CMIP5 en el periodo 1950-2004. Estos patrones muestran esencialmente la misma configuración que la de los dos primeros REOFs de los datos observacionales y de reanálisis, si bien el orden según la varianza explicada puede cambiar, apareciendo para algunos modelos un patrón muy semejante al del REOF1 de estos datos, pero correspondiendo al REOF2 del modelo. Este aspecto se ha tenido en cuenta a la hora de presentar los resultados, de tal forma que la Figuras 4.4 y 4.5 muestran los dos primeros modos de variabilidad simulados por los GCMs, en función, no del porcentaje de varianza explicada (mostrado en la parte superior del panel, junto con el nombre del modelo) de la SLP, sino de su similitud con el REOF1 y REOF2 de los datos del NCEP y Had2SLP. La comparación cuantitativa de los resultados obtenidos de la análisis de variabilidad espacial aplicado a los datos de reanálisis y observacionales, y a los modelos, se realiza a través del uso de diagramas de Taylor. Estos diagramas resumen los resultados de la comparación a través del coeficiente de correlación, la desviación estándar y el error cuadrático medio (RMSE). Igualmente, en la Figura 4.6, que muestra los diagramas de Taylor usados para comparar los modos de variabilidad espacial de la SLP de los GCMs con los obtenidos de las bases de datos

del NCEP y HadSLP2, se ha seguido el mismo criterio de similitud de los REOFs en lugar de porcentaje de varianza explicado.

Los modelos analizados tienden a reproducir de manera razonable el campo espacial de correlación asociado al primer modo de variabilidad de la SLP (Figura 4.4). Además, es posible observar que los modelos CMCC-CMS (l), CNRM-CM5 (m) y HadGEM2-CC (B), son los que mejor reproducen la distribución espacial de los patrones de correlación para este modo de NCEP, con máximos coeficientes de correlación de 0.96, como se aprecia en el diagrama de Taylor (Figura 4.6). El primer modo del modelo CMCC-CMS (l) y del CNRM-CM5 (m) muestra un gran centro de correlaciones positivas con forma de óvalo muy similar, pero más fuerte, que el mostrado por el NCEP.

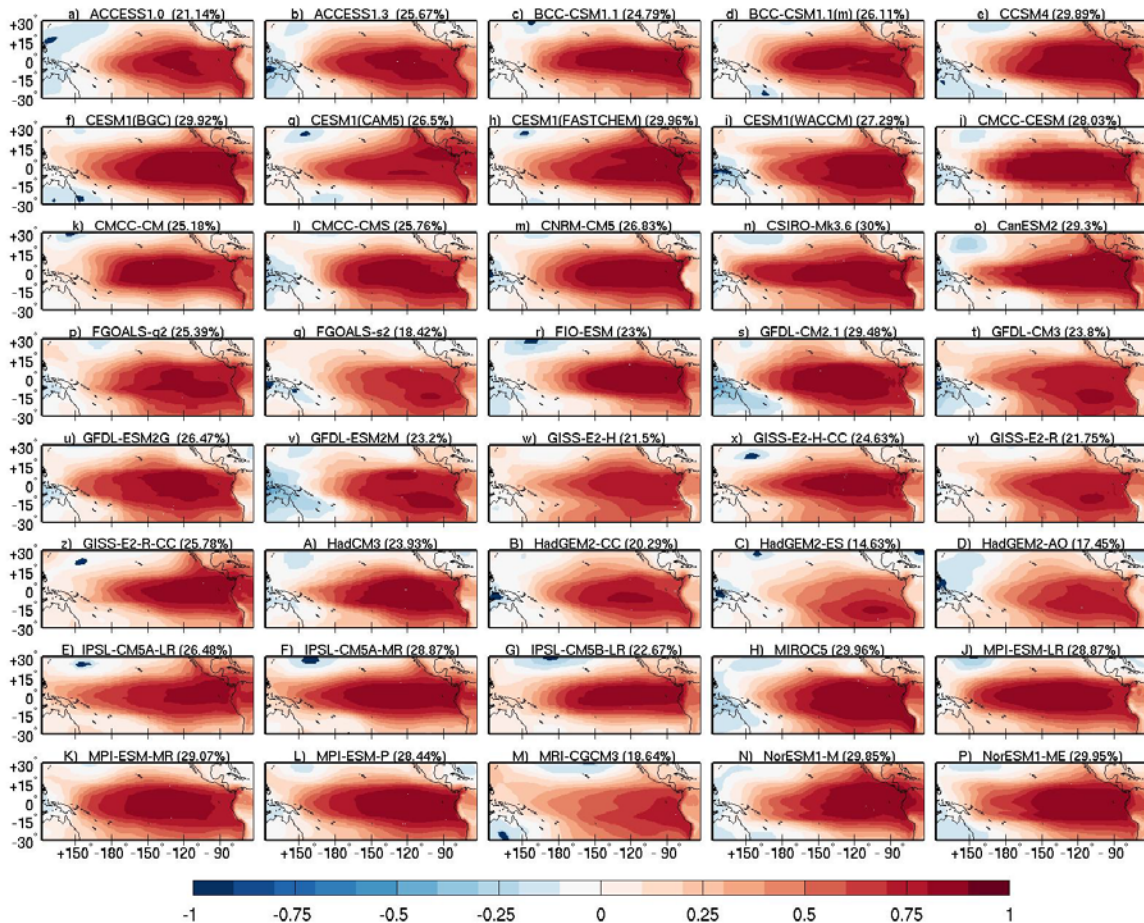


Figura 4.4. Distribución espacial del REOF1 de la SLP mensual obtenido a partir de las salidas de cuarenta modelos del CMIP5, durante el periodo 1950-2004.

Por su parte, los modelos que distorsionan en mayor grado los campos espaciales de correlación del primer modo de variabilidad, vienen encabezados por el CESM1(CAM5) (g), con

una varianza total explicada del 26.5%, con correlaciones de 0.74 y 0.71, respecto al NCEP y el HadSLP2, respectivamente. El centro de correlaciones positivas ubicado en el Pacífico toma forma de lengua alargada llegando hasta la costa australiana. Además, la distribución espacial de estas correlaciones sobre el continente americano y el Caribe es relativamente mayor que en los patrones del NCEP y del HadSLP2.

Por otra parte, también se observa que algunas simulaciones tienden a distorsionar este patrón, mostrando estructuras irregulares no muy definidas en algunos casos. Aun así, todos los modelos logran obtener una buena representación de la distribución espacial del REOF1, en comparación con los datos del NCEP y HadSLP2. Asimismo, en un considerable número de los modelos, la varianza total explicada por el primer modo presenta valores superiores a la del REOF1 de ambas bases de datos, de reanálisis y observacionales (24.95% y 23.41%, respectivamente), siendo más evidente en los modelos CESM1(FASTCHEM) (h), CSIRO-Mk3.6.0 (n), MIROC5 (H), NorESM1-M (N), y NorESM1-ME (P), (29.96%, 30%, 29.96%, 29.85% y 29.95%, respectivamente), con diferencias de hasta un 5% más en la varianza explicada. Por otro lado, los modelos FGOALS-s2 (q), HadGEM2-ES (C) y HadGEM2-AO (D) presentan varianzas muy por debajo de las observacionales (18.42%, 14.9% y 17.45%, respectivamente), explicando hasta un 10% menos, mostrando factores de carga más débiles y menos extensos en el Pacífico central y frente a las costas de Sudamérica.

La Figura 4.5 muestra los resultados relativos al segundo modo de variabilidad para los 40 GCMs analizados, que en casi todos los casos se corresponde al segundo REOF. De manera general, la mayoría de los modelos hacen una aceptable representación del patrón espacial asociado a este modo de la SLP, el cual se asemeja al patrón tropical de la Oscilación del Sur. Igualmente se encuentra que la mayoría de los modelos subestiman la varianza explicada por el REOF2 del NCEP (19.33%), aunque esta subestimación no es tan marcada respecto al HadSLP2 (17.31%). Los modelos que mejor representan el patrón asociado al segundo modo de variabilidad del NCEP son el GFDL-ESM2G (u), ACCESS1.3 (b), FGOALS-g2 (p) y MPI-ESM-P (L) aunque con varianzas explicadas menores que las mostradas por el REOF2 de los datos de reanálisis (13.08%, 15.89%, 17.24% y 14.65%, respectivamente). Por otro lado, el MRI-CGCM3 (M) y el FIO-ESM (r) son los modelos que distorsionan en mayor grado el segundo modo, con una varianza explicada de 20.55% y 23.62%, respectivamente, por encima de la correspondiente a los datos de reanálisis.

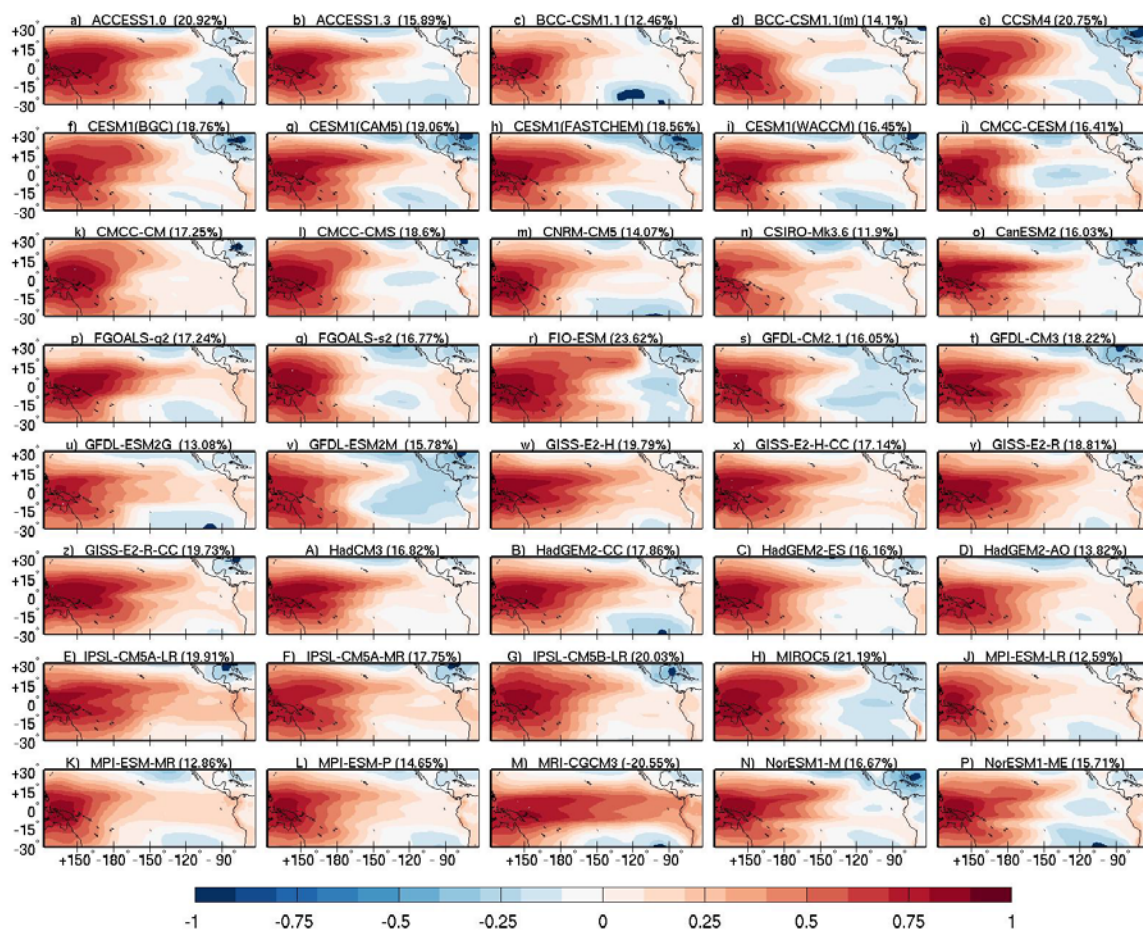


Figura 4.5. Distribución espacial del REOF2 de la SLP mensual obtenido a partir de las salidas de cuarenta modelos del CMIP5, durante el periodo de 1950-2004.

De manera general, para el REOF1, los valores de los coeficientes de correlación entre el REOF1 del reanálisis del NCEP y el de las simulaciones son superiores a 0.75, mientras que para los datos del HadSLP2 este límite inferior baja a 0.65 para algunos GCMs. No obstante, para la mayoría de los modelos este límite es superior a 0.8 en ambos casos (Figura 4.6). Por tanto, al contrastar los resultados obtenidos a partir de las dos bases de datos, reanálisis y observacionales, los coeficientes de correlación de los REOFs de las simulaciones respecto al NCEP son ligeramente superiores. En el caso de 1 REOF2, los resultados son indistinguibles, con correlaciones por encima de 0.78 para ambas bases de datos. Por otra parte, los valores de la varianza total explicada y la desviación estándar del REOF1, tiende a presentar valores similares entre el los y una menor desviación respecto al NCEP, que respecto al HadSLP2, donde la varianza total explicada por la mayoría de los modelos tiende a estar por encima, mientras que los valores de la desviación estándar por debajo.

Los diagramas de Taylor (Figura 4.6) nos permiten realizar una comparación más exhaustiva, no sólo atendiendo a los coeficientes de correlación entre los REOFs simulados y observados, sino también a la desviación estándar y al RMSE. El máximo coeficiente de correlación entre los patrones simulados y del reanálisis del NCEP para el REOF1, lo encabeza el modelo CNRM-CM5 (m), con una de correlación de 0.961 y desviación estándar de 0.35, presentando además el menor RMSE con un valor de 0.098. Le siguen los modelos CMCC-CMS (l) y el HadGEM2-CC (B), con altos coeficientes de correlación (0.960 y 0.959, respectivamente), y bajos RMSE (0.1 para ambos). Por el contrario, los coeficientes de correlación más bajos los presentan los modelos IPSL-CM5A-LR (E) y CESM1(CAM5) (g), con valores de 0.75 y 0.74, respectivamente, además, presentando un 5% más en la varianza explicada, y una menor desviación estándar, más evidente incluso en el caso del modelo IPSL-CM5A-LR (E). La comparación con el REOF1 de la SLP del HadSLP2 (Figura 4.6), muestra el menor RMSE para el modelo CMCC-CMS (l), con un valor de 0.113, presentando este GCM también el máximo coeficiente de correlación (0.953), y una desviación estándar del campo simulado de 0.358, ligeramente menor respecto al observado. El máximo RMSE y el menor coeficiente de correlación (0.645) lo presenta el modelo GISS-E2-R (y).

Los coeficientes de correlación entre los patrones espaciales de variabilidad del REOF2 de la SLP simulada y observada en la zona del Pacífico ecuatorial, presentan valores ligeramente superiores a los del REOF1, tanto para el NCEP como para el HadSLP2 (algo mayores en este caso). Las máximas correlaciones entre las simulaciones y el reanálisis se dan para los modelos GFDL-ESM2G (u), ACCESS1.3 (b), FGOALS-g2 (p) y MPI-ESM-P (L), con valores de 0.96, y la mínima con el FIO-ESM (r) con un valor de 0.78. En cambio, para el HadSLP2 los mayores coeficientes de correlación los presentan los modelos HadGEM2-ES (C), con un valor de 0.97, y BCC-CSM1.1 (c), CNRM-CM5 (m), IPSL-CM5A-MR (F), GFDL-ESM2M (v), ACCESS1.3 (b), GFDL-CM2.1 (s), MPI-ESM-P (L), y FGOALS-s2 (q), con valores de 0.95; el valor mínimo de correlación de 0.8 se obtiene para el (M) MRI-CGCM3 (M).

Para este REOF2, la mayoría de los modelos presentan valores de la varianza total explicada y de la desviación estándar inferiores a los del NCEP, con excepción del GFDL-ESM2M (v), que presenta menor varianza explicada (15.78%) que en los datos de reanálisis (19.33%), y valores superiores para la desviación estándar.

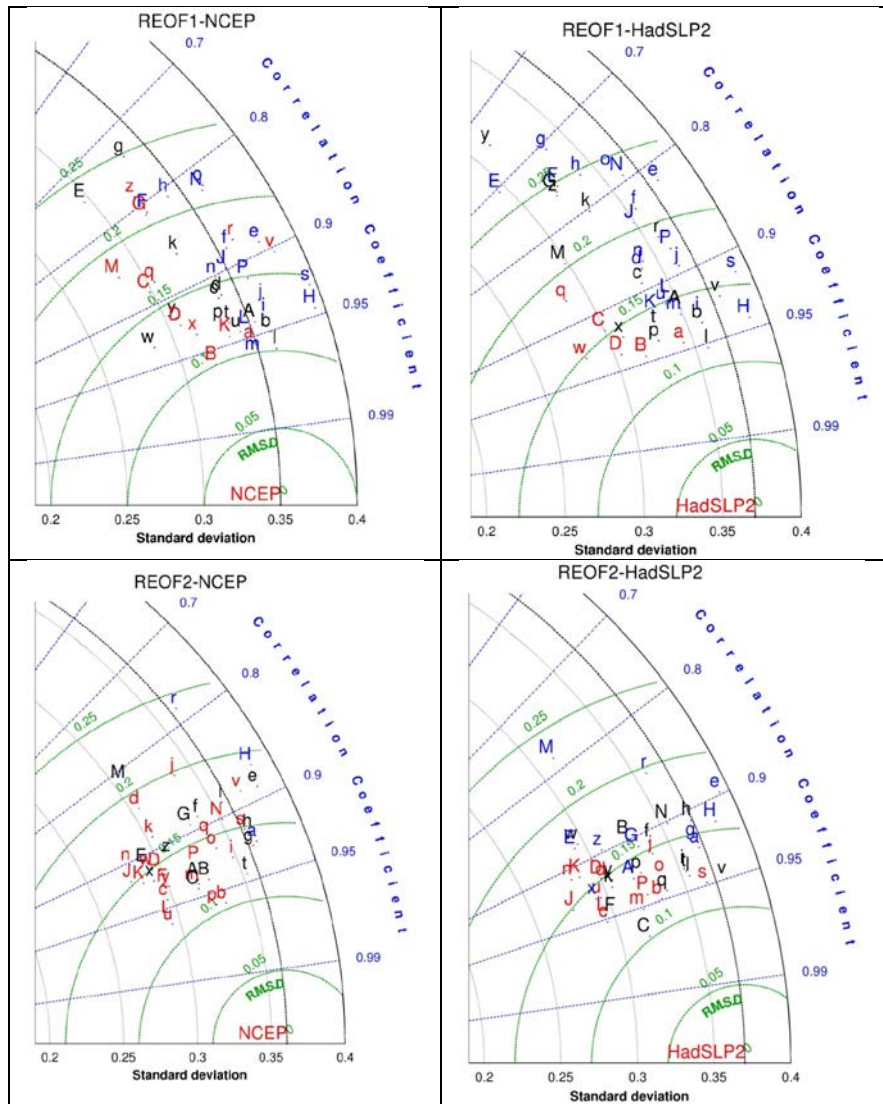


Figura 4.6. Diagramas de Taylor para la comparación de los REOF1 y REOF2, obtenidos del PCA de los datos de SLP de reanálisis del NCEP y observacionales HadSLP2, y de los 40 modelos del CMIP5 (Tabla 2.1).

4.3 Validación de la SLP estacional

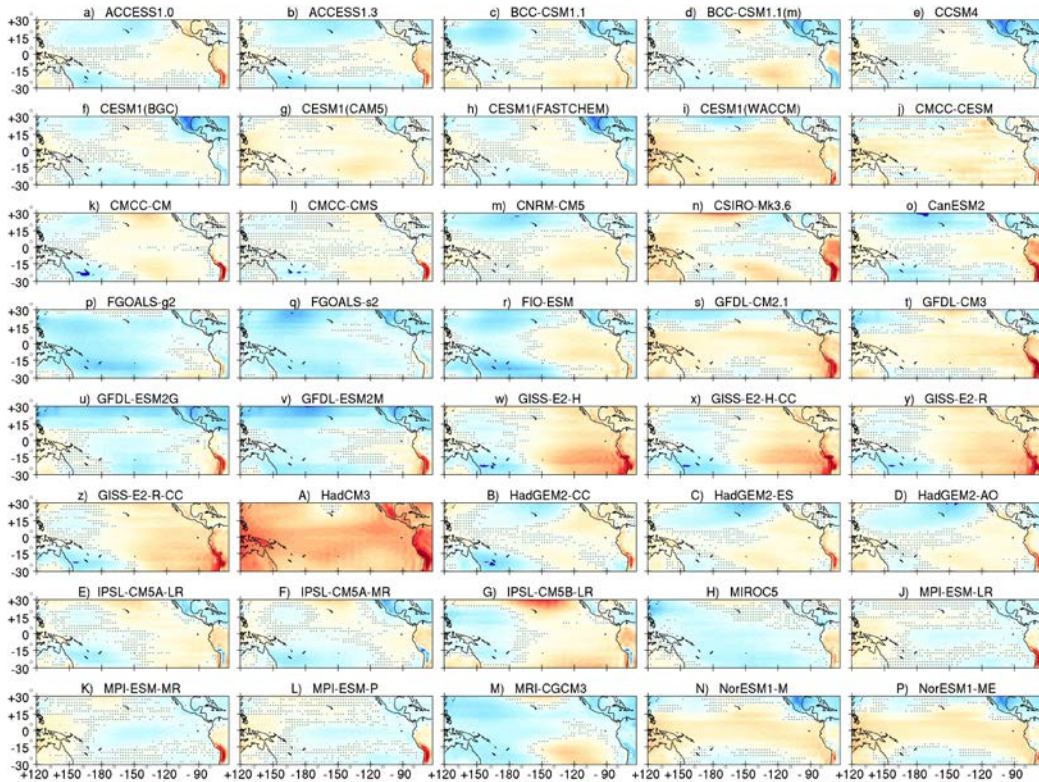
Siguiendo el esquema del apartado anterior, en este apartado se presenta una evaluación exhaustiva de la SLP en los modelos del CMIP5 tomando como base de datos de referencia el reanálisis del NCEP para cada estación del año, considerando invierno como el promedio de los meses de diciembre a febrero (DEF), primavera de marzo a mayo (MAM), verano de junio a agosto (JJA) y otoño de septiembre a noviembre (SON).

4.3.1 Análisis de los campos medios y de la varianza

Los resultados para las diferencias en los campos medios de la SLP estacional simulados por los 40 GCMs, respecto a los del reanálisis del NCEP, se muestran en la Figura 4.7 (invierno, primavera) y Figura 4.8 (verano, otoño), indicándose con “.” los puntos de rejilla donde estas diferencias no son significativas de acuerdo con los resultados del test-t de Student. En primer lugar hay que destacar que, en general, al igual que en análisis mensual, los modelos CMIP5 son capaces de capturar las características básicas de los patrones espaciales de los campos medios de la SLP estacional del NCEP en el océano, pero el comportamiento de los modelos es relativamente pobre en la simulación de la SLP sobre la cordillera de los Andes. También hay que resaltar que las simulaciones tienden a subestimar la SLP en el extremo norte, y que estas diferencias no son tan notables en la zona de influencia del ENSO (en torno a 1 hPa), y un poco superiores en el resto de la zona de estudio. Como ocurría en el análisis mensual, destaca la sobreestimación general de la SLP por los modelos, GFDL-CM2.1 (s), GFDL-CM3 (t), GISS-E2-H (w), GISS-E2-H-CC (x), GISS-E2-R (y), GISS-E2-R-CC (z) y HadCM3 (A), en todas las estaciones, siendo en este caso estacional el GISS-E2-R-CC (y), y particularmente el HadCM3 (A), los que muestran mayores sobreestimaciones en las simulaciones (> 4 hPa). Adicionalmente, se observa que las simulaciones de estos dos modelos muestran diferencias sustanciales de sobreestimación de los campos medios de la SLP en la zona correspondiente a la cordillera de los Andes y el área continental de Sudamérica, siendo mucho más fuerte en el HadCM3 (A), abarcando también toda la zona norte continental de la región de estudio, con diferencias de hasta 10 hPa en invierno (DEF) y otoño (SON) (Figuras 4.7 y 4.8).

A pesar que la mayoría de las diferencias en los campos simulados a nivel estacional tienden a presentar patrones similares en las cuatro estaciones, existen algunas excepciones como las simulaciones del HadGEM2-CC (B), que muestra un comportamiento particular ya que sobreestima fuertemente en el extremo noroeste en SON, pero no en las otras estaciones. Las simulaciones del MRI-CGCM3 (M), también muestran un patrón similar en DEF, MAM y SON, pero diferente en JJA.

Invierno



Primavera

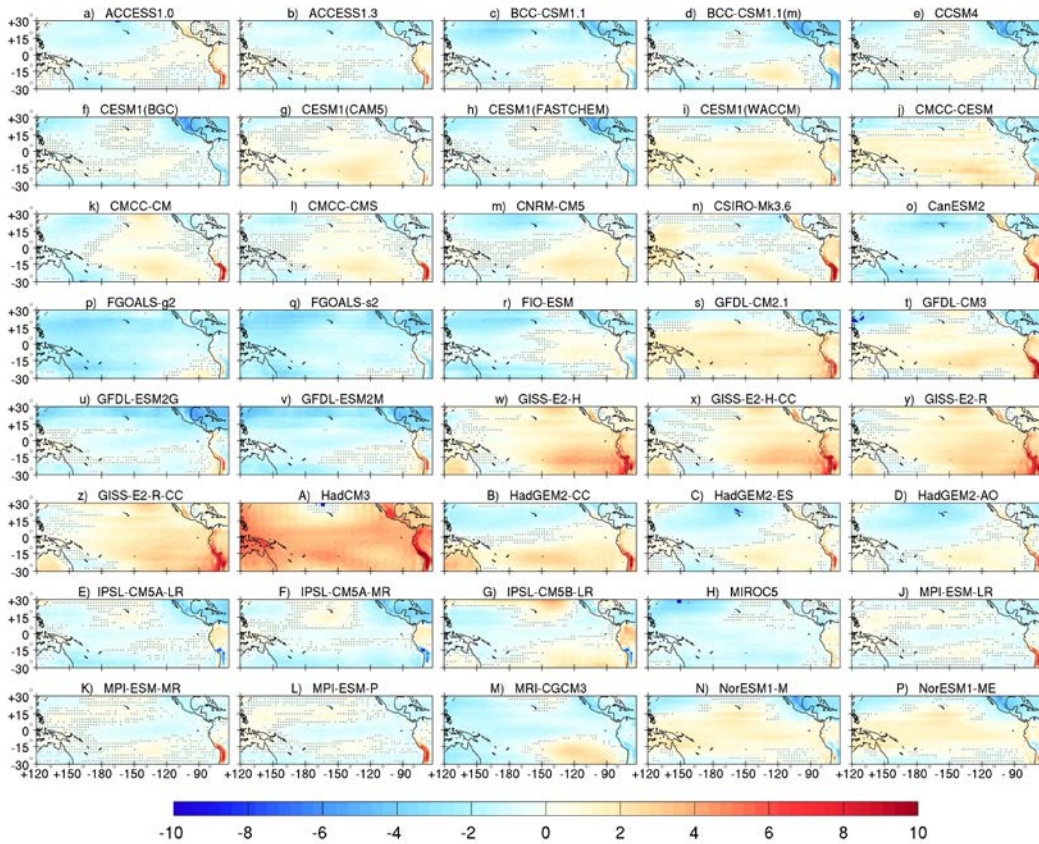
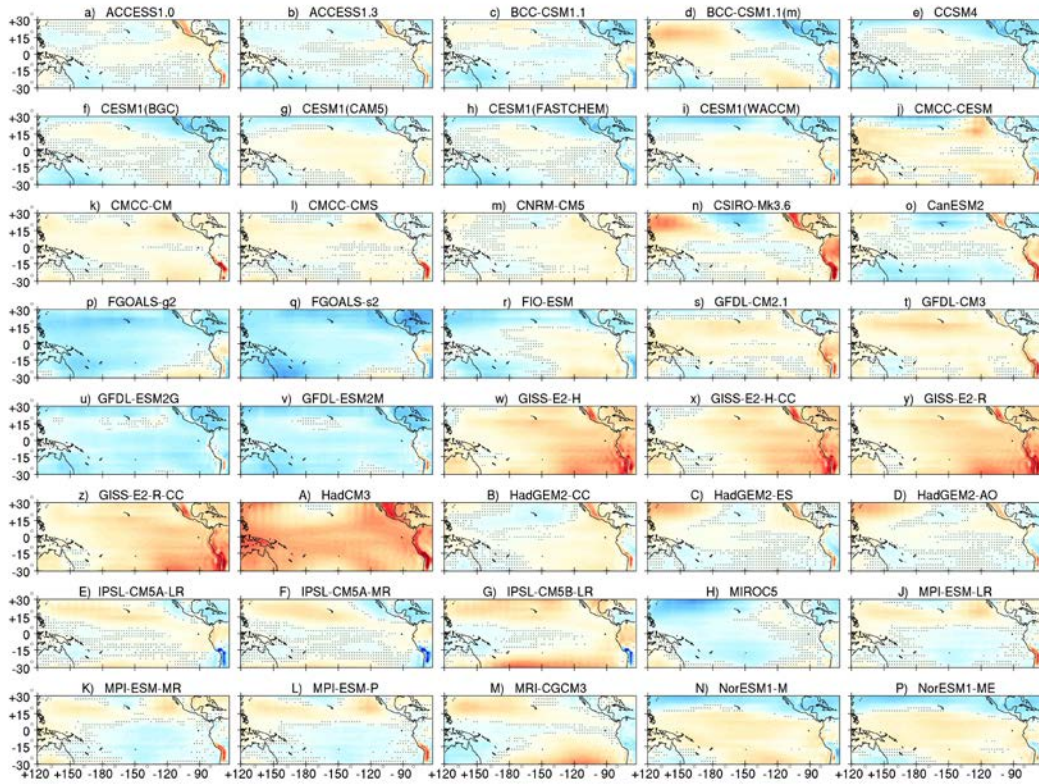


Figura 4.7. Distribución espacial de las diferencias en los campos medios de la SLP de los GCMs respecto al reanálisis NCEP para el invierno (DEF) y la primavera (MAM), en el período 1950-2005. Las áreas donde las diferencias no son significativas al nivel del 95% están marcadas por “.”.

Verano



Otoño

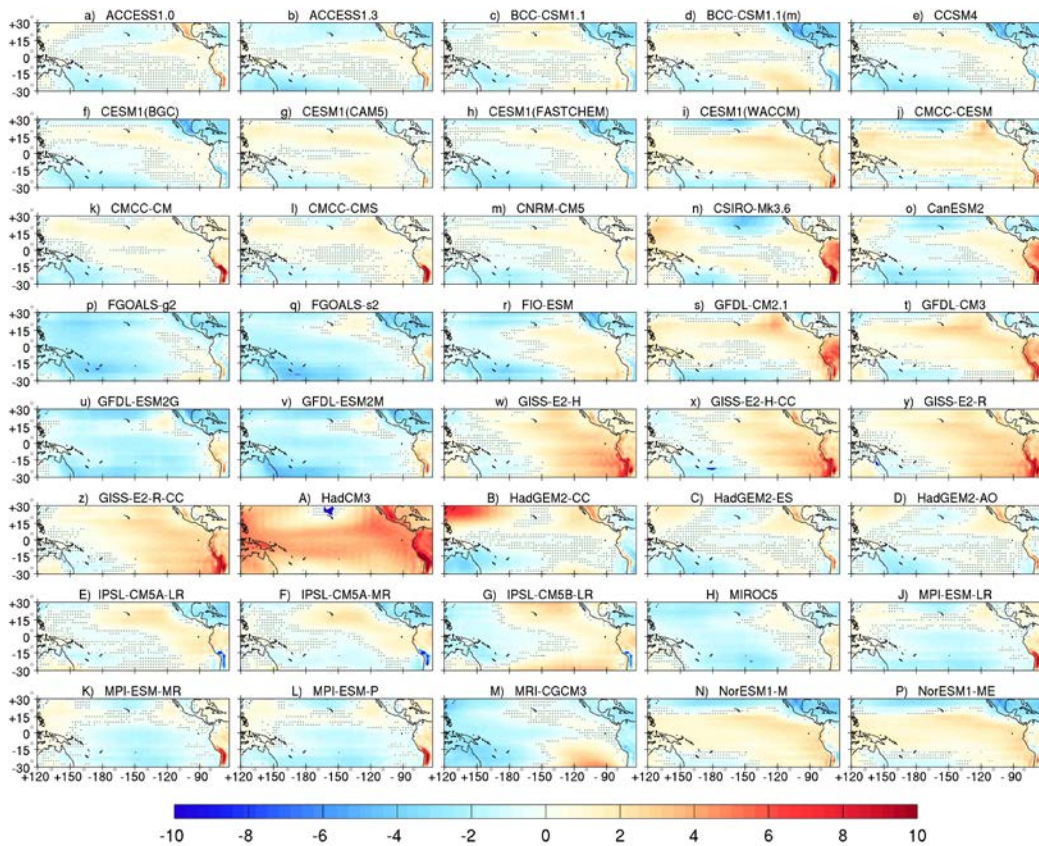
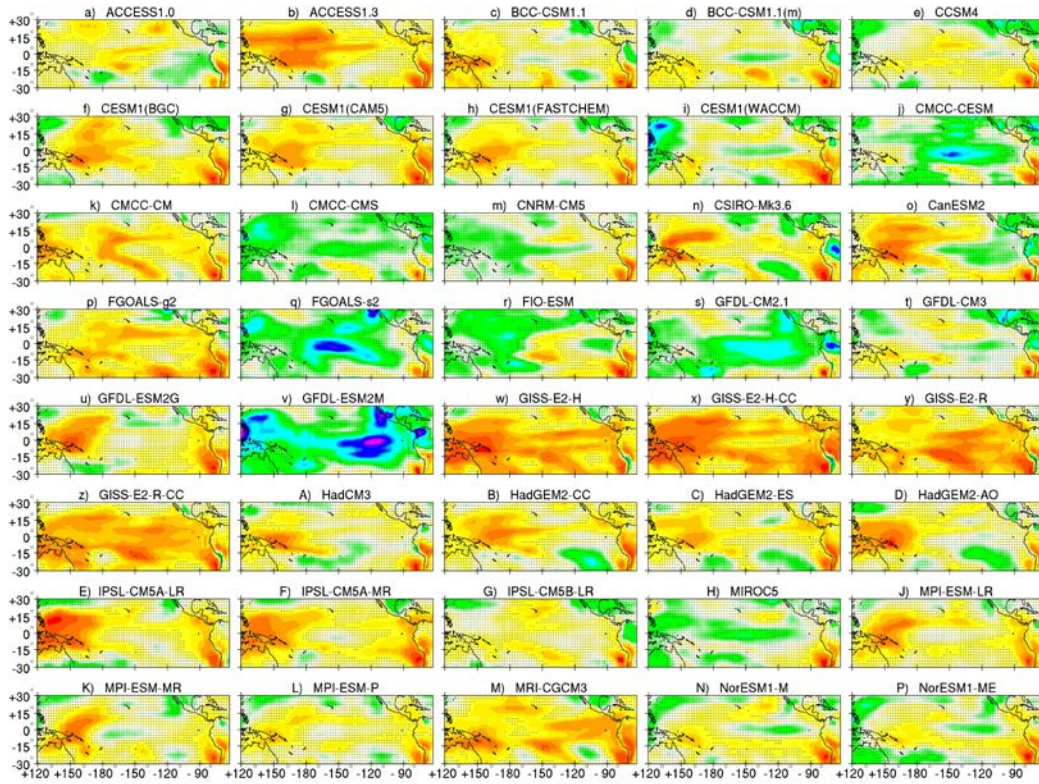


Figura 4.8. Como en la Figura 4.7 pero para las estaciones de verano (JJA) y otoño (SON).

Los resultados obtenidos es tacionalmente en el análisis de los cocientes entre las varianzas simuladas y las del reanálisis del NCEP se muestran en las Figuras 4.9 y Figura 4.10, indicándose con el símbolo “.” las zonas donde se puede aceptar la igualdad de varianzas al nivel de confianza del 95%, de acuerdo a los valores del test F. Estas figuras muestran que un gran número de simulaciones subestima la variabilidad observada, aunque, en un gran porcentaje las simulaciones hacen una buena reproducción de la misma, ya que las regiones con variaciones no significativas representan un porcentaje de área mayor que las regiones con variaciones significativas. El cociente entre la varianza simulada y observada tiende a estar más cercano a 1 en las estaciones de JJA y SON, en comparación con DEF y MAM. Los resultados indican que, en las cuatro estaciones, las simulaciones del GISS-E2-H (w), GISS-E2-H-CC (x), GISS-E2-R (y), GISS-E2-R-CC (z), IPSL-CM5A-LR (E) y IPSL-CM5A-MR (F) subestiman la variabilidad observada en toda la franja ecuatorial del océano Pacífico, mientras que las simulaciones pertenecientes a los modelos del CMCC-CESM (j), CMCC-CMS (l), GFDL-CM2.1 (s) y GFDL-ESM2M (v) sobreestiman la variabilidad de la SLP observada en todas las estaciones. La simulación del GFDL-ESM2M (v), es la que sobreestima en mayor grado la variabilidad de la SLP, con valores muy altos sobre todo el extremo oeste y al norte de Australia en primavera e invierno, al igual que un fuerte gradiente en la varianza estacional sobre el océano Pacífico y el continente americano, algo más débil en otoño. En general, las simulaciones antes descritas son las que más desvirtúan de forma sistemática la varianza de la SLP en todas las estaciones.

En las Figuras 4.9 y 4.10, también se muestra que la mayoría de los modelos presentan los cambios más significativos en invierno y primavera al norte y este de Australia, la zona de influencia del ENSO y sobre el oeste de Chile y Perú. También destaca que sobre la cordillera de los Andes en las estaciones de verano y otoño las varianzas de los modelos son más realistas. En cambio en la estación de DEF y MAM, un gran número de modelos muestran muchas más regiones con déficit que con exceso de la variabilidad.

Invierno



Primavera

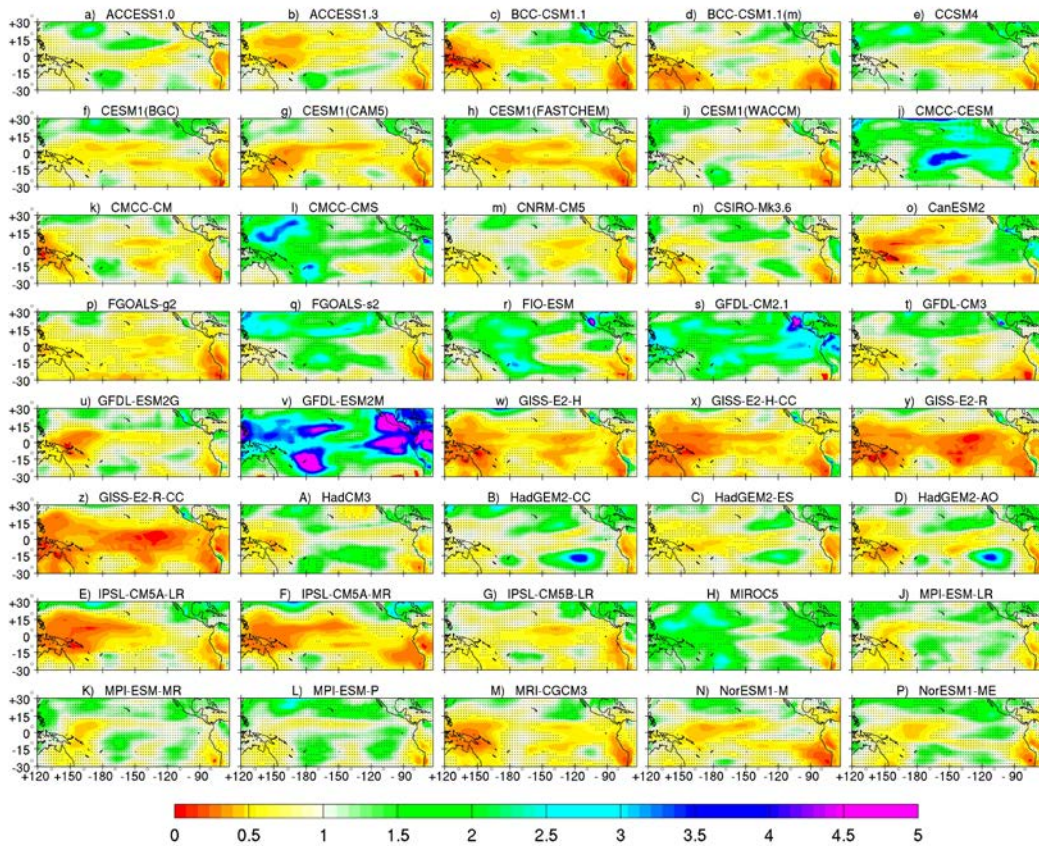
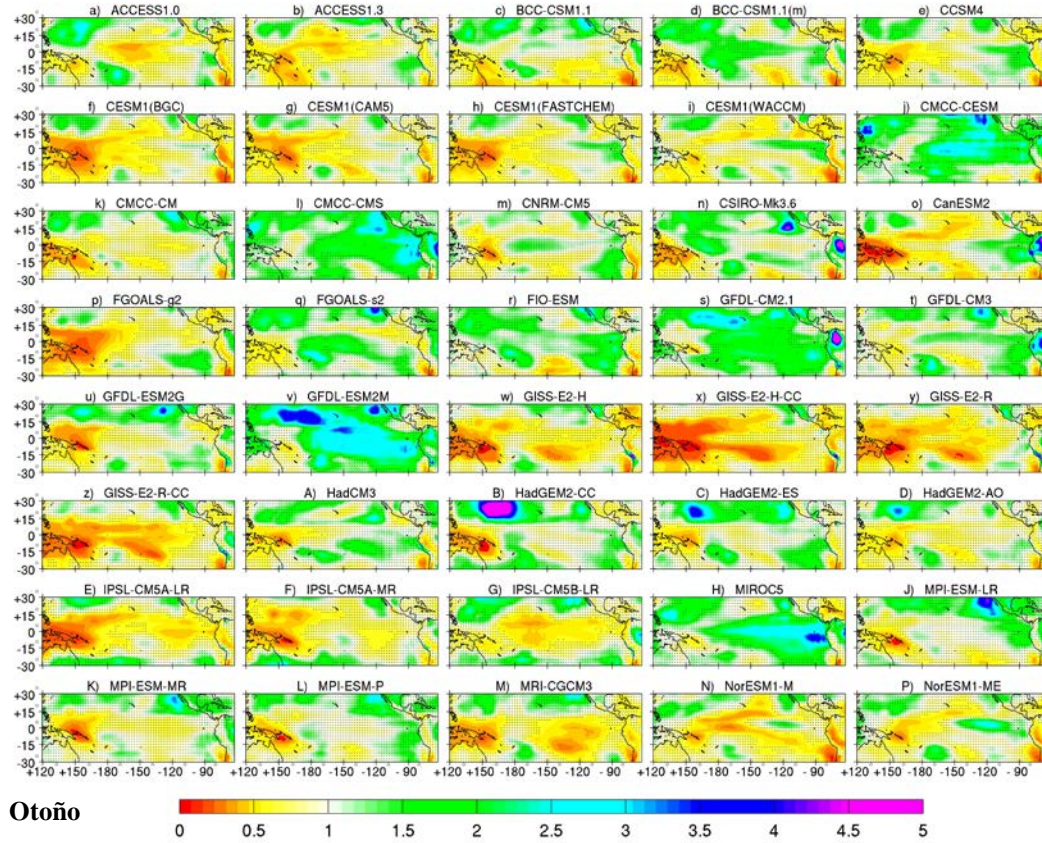


Figura 4.9. Cociente entre el campo de varianzas de la SLP estacional de 40 modelos del CMIP5 y del NCEP durante el periodo 1950-2005, para las estaciones de invierno (DEF) y primavera (MAM). Las áreas donde los cocientes no son significativos al 95% están marcadas por “.”.

Verano



3

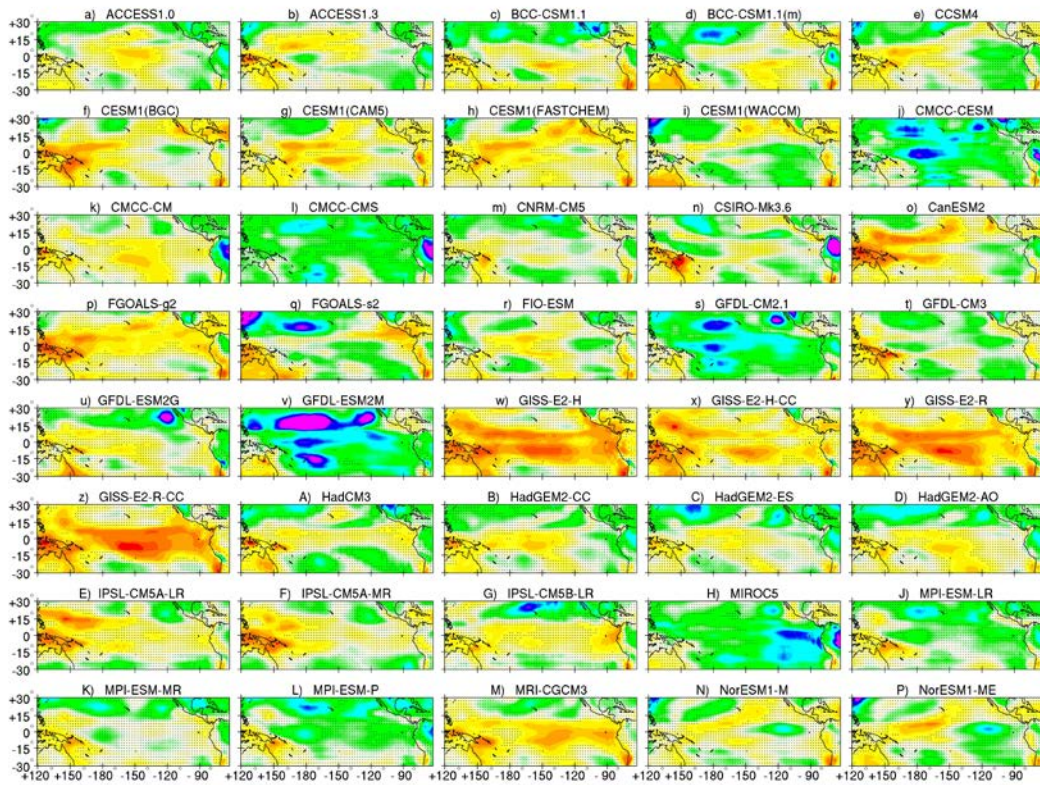
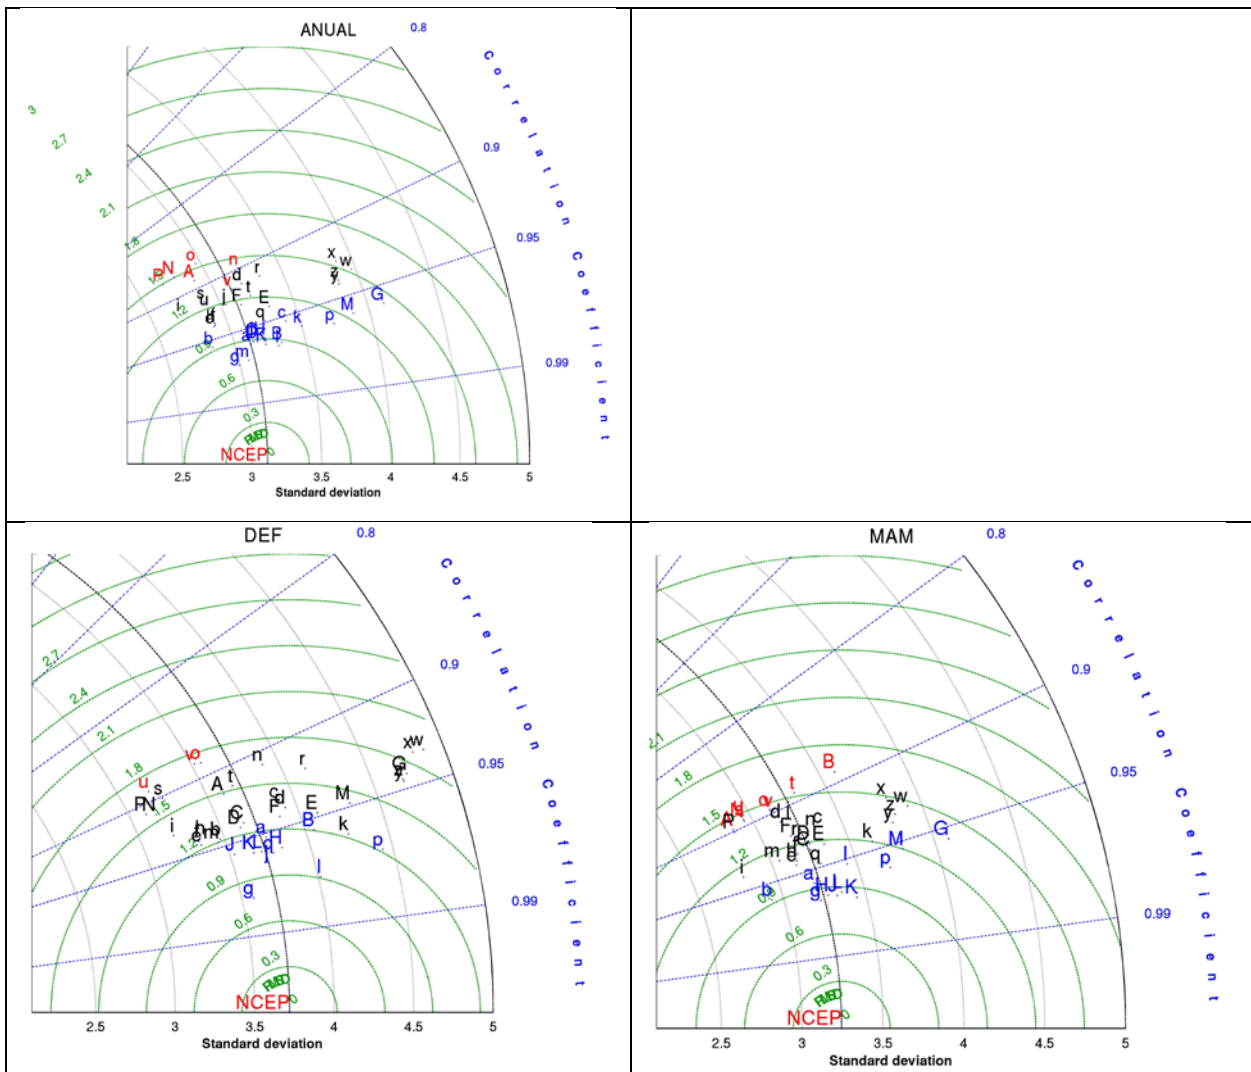


Figura 4.10. Como en la Figura 4.9 pero para las estaciones de verano (JJA) y otoño (SON).

Con el fin de proporcionar una visión de conjunto, se analizan con más detalle las principales diferencias entre los campos medios anuales y estacionales de la SLP del NCEP y las simulaciones de los distintos modelos del CMIP5, mediante los diagramas de Taylor mostrados en la Figura 4.11. Se aprecia que la mayoría de los GCMs son capaces de simular la variabilidad espacial de SLP tanto anual como estacionalmente. Todos los modelos muestran altos valores para el coeficiente de correlación espacial (> 0.8) y bajos valores para los RMSE (< 2 hPa), lo que indica que la capacidad de los modelos para representar la variabilidad espacial de la SLP en la zona de estudio es buena, tanto a escala anual como estacional. Los coeficientes de correlación de las simulaciones respecto al NCEP son ligeramente superiores para el promedio anual, así como en invierno (DEF) y verano (JJA). Así, en estas estaciones se alcanzan coeficientes de correlación espacial por encima de 0.98 para los modelos del CESM1(CAM5) (g) y CMCC-CMS (l) en DEF, y el CNRM-CM5 (m) en JJA. Para el promedio anual (Figura 4.11), las simulaciones de CESM1(CAM5) (g), CNRM-CM5 (m) y CMCC-CMS (l), con 0.97, de coeficiente de correlación, RMSE < 0.8 y diferencia menor que 1.9 hPa en la desviación estándar respecto al campo observado, son las que mejor representan las anomalías de la SLP anual. Por otro lado, las simulaciones del HadCM3 (A), NorESM1-ME (P), NorESM1-M (N) y CanESM2 (o), con coeficientes de correlación inferiores (< 0.90) y RMSE > 1.4 , son las que hacen una peor representación del campo medio de la SLP a escala anual. En conjunto, los campos medios de la SLP están mejor representados por los modelos en las estaciones de verano (JJA), invierno (DEF) y primavera (MAM), cuando el número de GCMs con coeficientes de correlación superior a 0.95 respecto al NCEP fue de 16, 12 y 11, respectivamente, mientras que en otoño (SON) solo 7 modelos superaron este umbral. En la Figura 4.11, también es posible observar que en las cuatro estaciones la mayoría de las simulaciones tienden a sobreestimar la desviación estándar del NCEP, si bien para el invierno hay una mayor dispersión en el diagrama de Taylor, mientras que en primavera, el nivel de dispersión es el más bajo.

Los máximos coeficientes de correlación en los campos medios simulados y observados para DEF, los encabezan los modelos CESM1(CAM5) (g) y CMCC-CMS (l), con $r = 0.98$ para ambos modelos, y con desviación estándar igual a 0.78 y 0.91, respectivamente. También hay que resaltar que el RMSE para ambos modelos es inferior a 0.91. Los coeficientes de correlación espacial más bajos para DEF los presentan los modelos GFDL-ESM2G (u), CanESM2 (o) y GFDL-ESM2M (v), con $r = 0.89$ (Figura 4.11), y RMSE de 1.69, 1.73 y 1.73, respectivamente. En MAM es el MPI-ESM-MR (K), el modelo que presenta el coeficiente de correlación más alto respecto al NCEP ($r = 0.97$), un RMSE más bajo (0.83), con una desviación

similar a la observada (3.44), mientras que el GFDL-ESM2G (U) es el que muestra el coeficiente de correlación más bajo ($r = 0.88$). En cambio, en JJA y SON es el CNRM-CM5 (m) el modelo que mejor representa los campos medios, y el CSIRO-Mk3.6.0 (n), el que presenta el coeficiente de correlación más bajo ($r = 0.84$ en JJA y $r = 0.83$ en SON). Como ya se ha mencionado, las máximas desviaciones se presentan en la estación de invierno, particularmente al comparar las simulaciones de los modelos GISS-E2-H (w), GISS-E2-H-CC (x), IPSL-CM5B-LR (G) y GISS-E2-R (y).



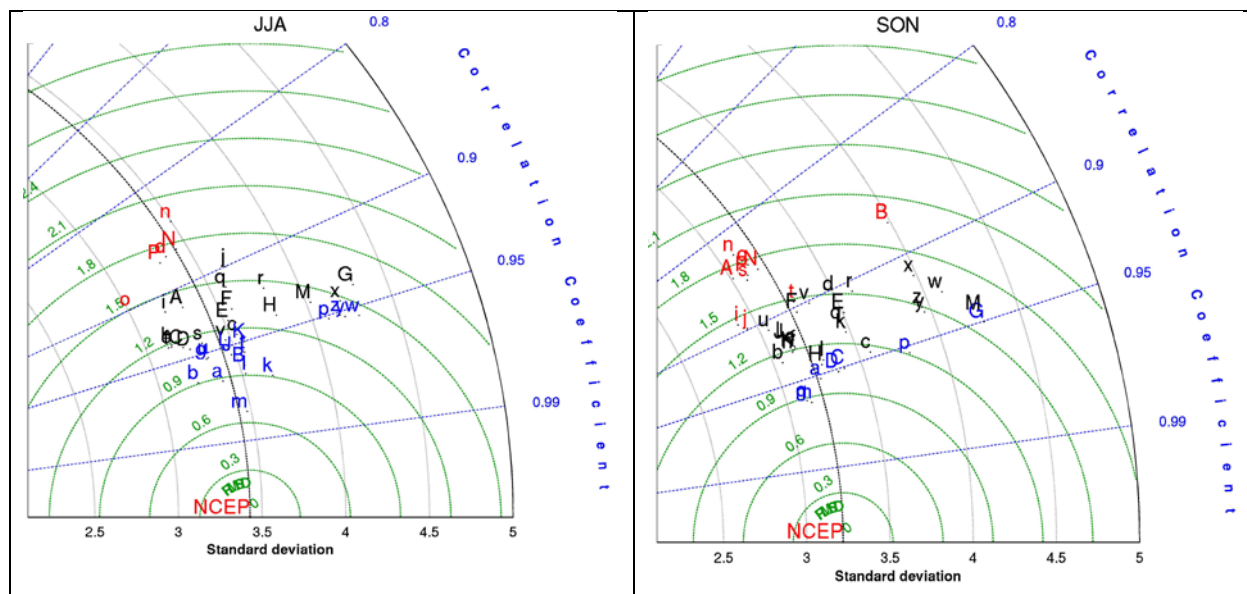


Figura 4.11. Diagramas de Taylor para la comparación de los campos medios de la SLP anual y estacional simulada por los modelos respecto al reanálisis NCEP, durante el periodo de 1950-2005. Los diferentes modelos están especificados como en la Tabla 2.1. En color azul se indican a los modelos con $r > 0.95$, y en rojo aquellos con $r < 0.9$.

4.3.2 Análisis de los modos de variabilidad estacional

La Figura 4.12 muestra los 3 primeros patrones de variabilidad de la SLP del NCEP, en cada estación del año, obtenidos a partir de los REOFs para el periodo 1950-2005. Estos modos explican en conjunto el 66.46%, 61.18%, 65.63% y 62.85% de la varianza total acumulada para las estaciones de DEF, MAM, JJA y SON, respectivamente. Como puede apreciarse en la Figura 4.12, DEF y MAM muestran patrones espaciales similares de sus REOF, con diferencias respecto a los de JJA y SON, muchos más similares entre ellos.

Los resultados mostrados en la primera columna en la Figura 4.12, indican que el primer modo de variabilidad rotado (REOF1) se caracteriza por el dominio de un fuerte y amplio centro de correlación positiva en el océano Pacífico central, consistente con el fenómeno ENSO, siendo JJA la estación en la que este núcleo es más intenso y extenso con el mayor porcentaje de varianza explicada (36.35%). Este patrón se mantiene esencialmente en otoño, aunque explicando algo menos de varianza (32.7%). En DEF y MAM, este primer modo (explicando un 27.12% y un 22.4% de la varianza, respectivamente) presenta una estructura más dipolar, con un amplio centro de correlaciones positivas sobre el Pacífico tropical este, y otro núcleo, más reducido, de correlaciones negativas al noroeste de la región de estudio.

El porcentaje de varianza explicada por el segundo modo de variabilidad rotado (REOF2), para las estaciones de DEF, MAM, JJA y SON, es 26.62%, 19.91%, 17.37% y 20.19% de la varianza, respectivamente, siendo DEF la estación en la que este porcentaje es mayor, y JJA en la que es menor. En las cuatro estaciones el REOF2 muestra un patrón típico de la circulación de Walker, con un centro de correlaciones positivas sobre el Pacífico tropical suroccidental, entre 120°E y 165°W, y otro, de menor intensidad, con correlaciones negativas, que se extiende hasta la costa oeste del continente americano.

El REOF3 para DEF y MAM, explica un 12.72% y 18.87% de la varianza total, respectivamente, y muestra un centro de correlaciones positivas en torno a los 160°W y 20°N, más desplazado hacia el noreste en DEF, y un centro de correlaciones negativas sobre América. En cambio, el REOF3 para JJA y SON (con 11.91% y 9.96% de varianza explicada, respectivamente), muestra un fuerte centro de correlaciones positivas situado en el extremo este del área de estudio, que se debilita a medida que se extiende hacia la zona central del océano Pacífico hasta los 150°W. Adicionalmente, en JJA se observa un centro de correlaciones negativas al noroeste del área, mientras que en SON se tienen correlaciones negativas alrededor de los 180°E y 30°S.

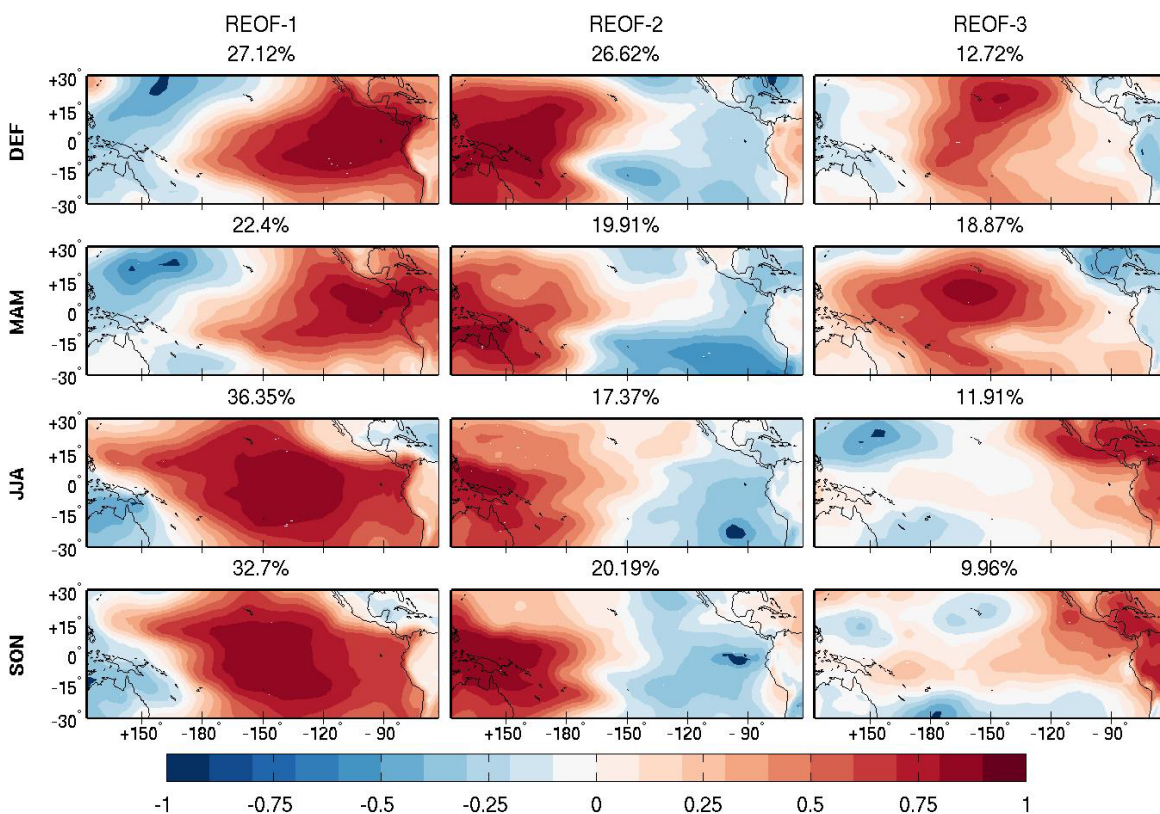


Figura 4.12. Factores de carga de los tres primeros REOFs de la SLP estacional de los datos de reanálisis NCEP en el período 1950-2005.

A continuación se presenta la evaluación de los REOFs de la SLP para cada estación del año obtenidos de los GCMs del CMIP5 en comparación con los del NCEP. Teniendo en cuenta el alto porcentaje de varianza explicada por los dos primeros modos de variabilidad y por motivos de brevedad, solo se examinan los resultados correspondientes a los dos primeros REOFs.

Invierno

Los patrones espaciales asociados a los dos modos principales de variabilidad, obtenidos a partir de las simulaciones de 40 modelos del CMIP5, en DEF, para el periodo 1950-2005, se muestran en las Figuras 4.13 y 4.14, respectivamente. Además, la Figura 4.15 muestra los diagramas de Taylor correspondientes a la comparación de los dos primeros REOFs de las simulaciones respecto los del NCEP. Para el modo de variabilidad asociado al REOF1 del NCEP (Figura 4.13), la mayoría de los modelos sobrestiman la varianza asociada en comparación con la del REOF1 del NCEP (27.12%, Figura 4.12), siendo las simulaciones del GFDL-CM2.1 (s), CESM1(FASTCHEM) (h), GFDL-ESM2M (v), CanESM2 (o) y MPI-ESM-MR (K), las que presentan los mayores valores (43.76%, 41.6%, 40.56%, 38.12% y 37.41%, respectivamente). Los valores más bajos en la varianza explicada, y más próximos a los del REOF1 del NCEP, son los de las simulaciones del CMCC-CESM (j), CNRM-CM5 (m), HadGEM2-CC (B), HadGEM2-ES (C), FIO-ESM (r) y MRI-CGCM3 (M), , , con porcentajes de 28.6%, 27%, 29.05%, 27.12%, 26.74% y 25.97%, respectivamente. Adicionalmente, los modelos GFDL-CM2.1 (s) y GFDL-ESM2M (v) se caracterizan por la presencia de un marcado patrón dipolar, con correlaciones negativas en forma de herradura al oeste, entre los 120°E-150°W, y positivas en la zona oriental del área de estudio.

Durante el invierno, todos los modelos son capaces de reproducir las características observadas asociadas al fenómeno ENSO, ya descrito anteriormente, aunque existen ciertas discrepancias respecto al grado de realismo de los patrones espaciales simulados, esencialmente debido a la localización y extensión de los centros de máxima correlación. Además como se ha comentado, los modelos sobrestiman la varianza de la SLP asociada a este patrón. Las simulaciones que mejor reproducen la distribución espacial de los patrones de correlación para el REOF1 del NCEP, las encabezan los modelos MIROC5 (H) y CMCC-CMS (I) con máximos coeficientes de correlación espacial de 0.96, como se muestra en el diagrama de Taylor correspondiente (Figura 4.15), seguidos por el HadGEM2-ES (C) y el CNRM-CM5 (m), con correlación de 0.95, los cuales muestran además los RMSE más bajos (entre 0.13 y 0.14). Estos modelos se caracterizan por la presencia de un centro de correlación positivo bien definido sobre

el océano Pacífico, junto con un débil patrón de correlación negativa que se extiende desde Australia hasta los 170°W. En cambio el modelo GFDL-ESM2G (u), con una correlación de 0.74, y un RMSE de 0.31, es el que presenta mayores diferencias respecto al REOF1 del NCEP (Figura 4.15).

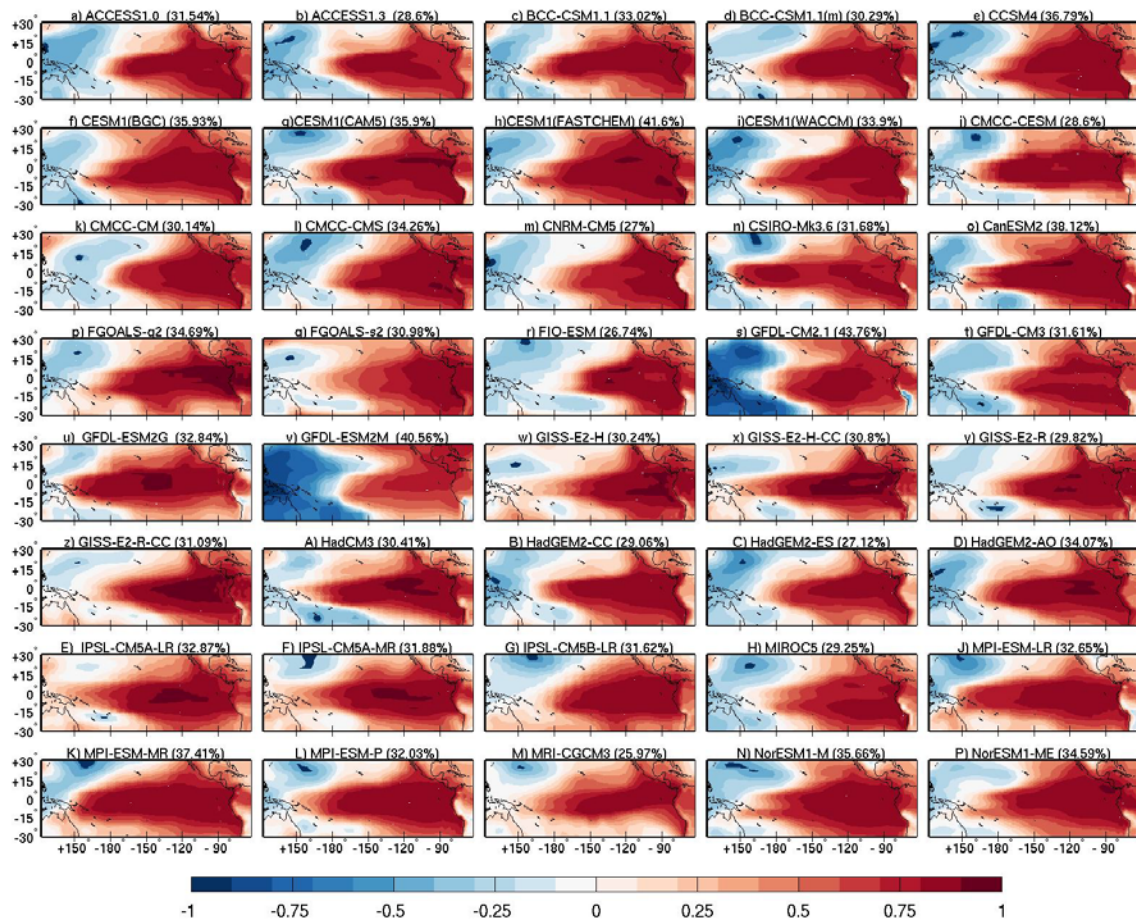


Figura 4.13. Patrón espacial de variabilidad asociado al REOF1 de invierno de la SLP del NCEP obtenido a partir de las simulaciones de cuarenta modelos del CMIP5 durante el periodo 1950-2004.

Para el patrón de variabilidad asociado al REOF2 de invierno del NCEP (Figura 4.14), los modelos presentan valores de varianza explicada más cercanos al del NCEP (26.62%). Aun así, los modelos FIO-ESM (r), GISS-E2-R (y), CCSM4 (e), GFDL-CM3 (t) y MIROC5 (H) son los que presentan los mayores porcentajes de varianza explicada, (41.59%, 33.97%, 30.13%, 29.97% y 29.97%, respectivamente), con marcadas sobrestimaciones para los dos primeros. De hecho, para estos modelos, este patrón es el REOF1. Por otro lado, las simulaciones del HadGEM2-AO (D), MPI-ESM-MR (K), CSIRO-Mk3.6.0 (n) y el GFDL-CM2.1 (s), presentan los porcentajes de varianza más bajos (16.37%, 13.54%, 13.16% y 12.96%, respectivamente),

muy por debajo de la del ROF2 del NCEP (26.02%). Como se aprecia en el diagrama de Taylor (Figura 4.15), las simulaciones que mejor reproducen la distribución espacial de los patrones de correlación para este modo del NCEP son las del CNRM-CM5 (m), CESM1(FASTCHEM) (h) y BCC-CSM1.1 (c), con coeficientes de correlación superiores a 0.92, y RMSE < 0.18, si bien, el BCC-CSM1.1 (c) subestima de forma marcada la varianza explicada por este patrón (19.7%). Por otro lado, el coeficiente de correlación espacial más bajo se obtiene para el FIO-ESM (r) y el HadGEM2-AO (D), con valores de 0.68.

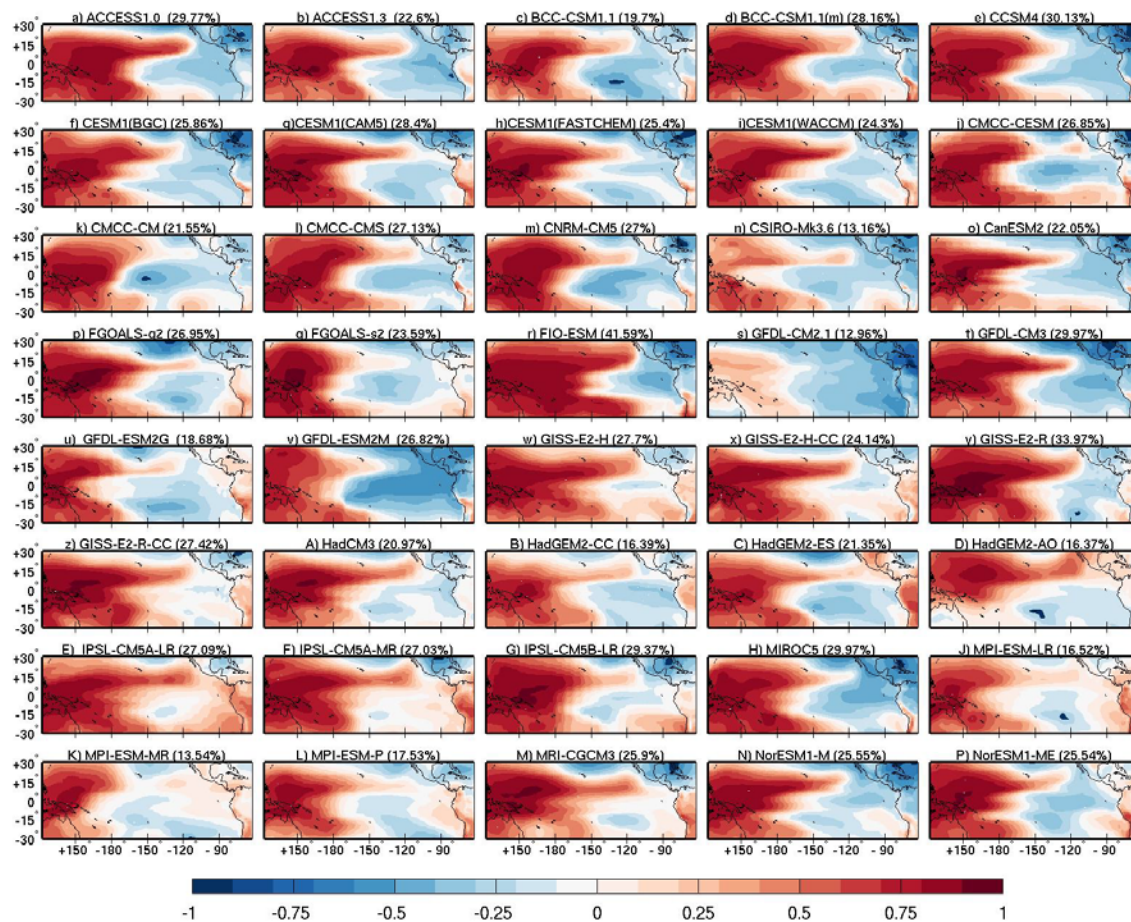


Figura 4.14. Como la Figura 4.13 pero para el REOF2 de invierno del NCEP.

Cabe señalar que aunque la gran mayoría de las simulaciones presenta altos valores en los coeficientes de correlación espacial, a algunos modos tienden a distorsionar en cierto grado los campos espaciales de los patrones de correlación del segundo modo de variabilidad. Para DEF esta distorsión espacial está encabezada por el GFDL-CM2.1 (s), el cual presenta el menor porcentaje de la varianza explicada para el REOF2 (12.96%), y el RMSE más alto respecto al NCEP. El REOF2 de este modelo se caracteriza por la presencia de un fuerte patrón de

correlación negativa que se cubre toda la zona desde el continente americano hasta 150°W, en el extremo sur, y hasta los 120°E en el extremo norte. En este caso, el centro de correlación positivo del patrón espacial es demasiado débil en comparación con el del REOF2 del NCEP.

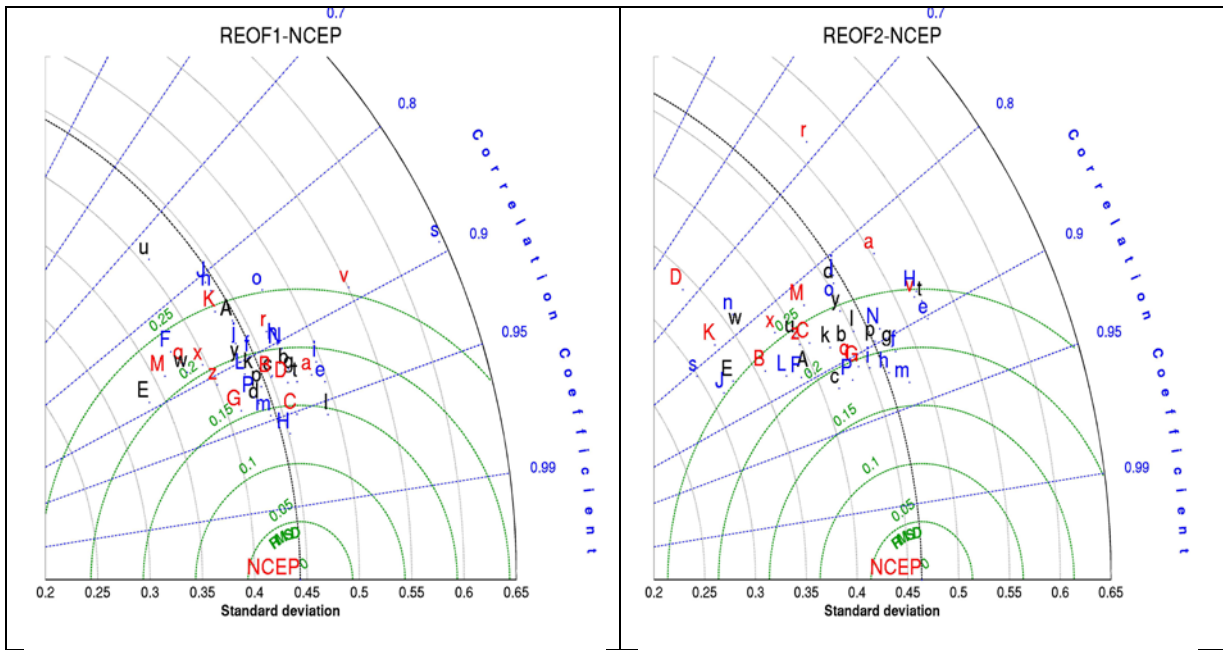


Figura 4.15. Diagramas de Taylor para la comparación de los modos principales de variabilidad de la SLP de invierno simulados por los modelos respecto a los REOF1 y REOF2 obtenidos de los datos de reanálisis del NCEP durante el periodo 1950-2005. Los diferentes modelos están especificados como en la Tabla 2.1.

Primavera

Las Figuras 4.16 y 4.17, muestran los patrones espaciales de los modos de variabilidad asociados a los dos primeros REOFs del NCEP para la SLP en primavera (MAM) correspondientes a los 40 modelos del CMIP5 considerados. Al igual que en la estación de DEF, estos dos primeros modos de variabilidad en MAM también están asociados al ENSO. En la Figura 4.16, de nuevo puede apreciarse cómo los modelos sobrestiman la varianza explicada por el primer modo de variabilidad de la SLP de NCEP en primavera (22.4%), siendo las simulaciones del GFDL-ESM2M (v), CanESM2 (o), IPSL-CM5A-LR (E), NorESM1-ME (P) y CESM1(BGC) (f) las que presentan los mayores porcentajes de la varianza asociada (42.88%, 34.97%, 34.94%, 34.12% y 32.87%, respectivamente). Por el contrario, las simulaciones del BCC-CSM1.1 (c), HadGEM2-AO (D), CNRM-CM5 (m), IPSL-CM5B-LR (G) y HadGEM2-CC

(B) presentan los modos que explican los porcentajes de varianza más pequeños y cercanos a los del REOF1 del NCEP (22.53%, 21.81%, 20.7%, 19.93% y 19.5%, respectivamente).

En general, la mayoría de los GCMs reproducen aceptablemente los patrones de variabilidad más importantes de la circulación atmosférica en el área de estudio. Así para el REOF1, casi todos los modelos muestran correlaciones positivas altas sobre la mitad oriental, y correlaciones negativas más débiles en el oeste. Sin embargo, algunas simulaciones como las del modelo CMCC-CMS (l) y el GFDL-ESM2M (v) son incapaces de reproducir los patrones espaciales del REOF1 de la SLP del NCEP en MAM. El diagrama de Taylor correspondiente a MAM (Figura 4.18) muestra que los coeficientes de correlación espacial entre los REOFs simulados y el observado se mantiene por encima de 0.79, pero ninguno supera el umbral de 0.95. Los modelos con mejor habilidad en la reproducción de este patrón del reanálisis son el CCSM4 (e), CESM1(WACCM) (i), FGOALS-s2 (q), FGOALS-g2 (p), MIROC5 (H) y CESM1(BGC) (f), con $r > 0.93$ y $RMSE < 0.19$, y con valores de desviación, que excepto para el MIROC5 (H), son muy cercanos a la del REOF1 del reanálisis.

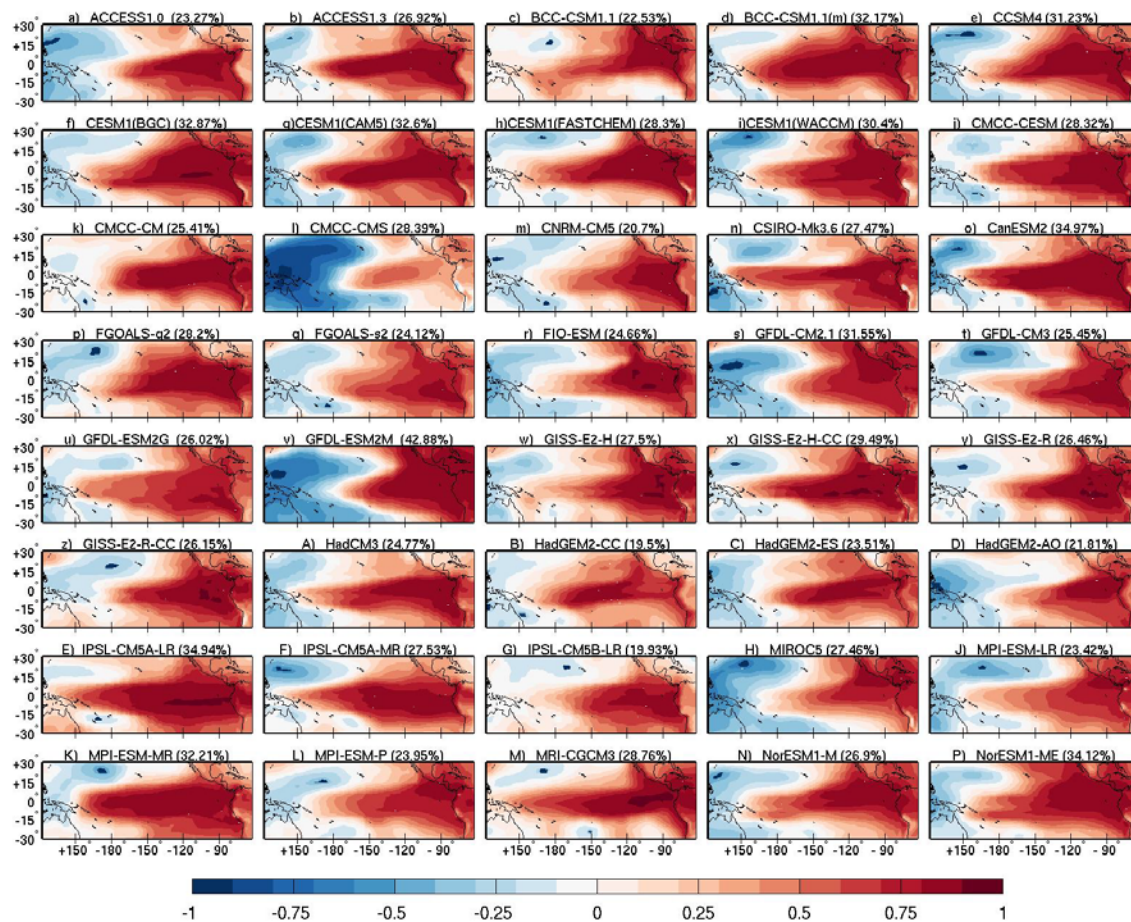


Figura 4.16. Como en la Figura 4.13 pero para el REOF1 de primavera (MAM).

Los resultados relativos al REOF2 para todos los GMCs analizados en MAM se muestran en la Figura 4.17. En ella se observa que para un gran número de modelos es aceptable la representación de los patrones espaciales asociados a este modo de la SLP, aunque más de la mitad sobrestiman la varianza explicada por este modo para la SLP del NCEP (19.91%). Las simulaciones que más fallan en la representación del segundo patrón de variabilidad del NCEP son las del CMCC-CMS (l), CNRM-CM5 (m), CSIRO-Mk3.6 (n), FGOALS-g2 (p), GFDL-ESM2G (u) y HadGEM2-CC (B), que se destacan por la presencia de una región con factores de carga negativos muy elevados, situada sobre un gran parte del océano Pacífico y el continente americano. El porcentaje de varianza explicado por cada uno de ellos es de 40.36%, 28.22%, 29.93%, 32.38%, 26.02% y 18.82%, respectivamente. Por otro lado, los modelos FIO-ESM (r) y GISS-E2-H (w), con bajas varianzas explicadas, de 10,59% y 13,92 %, respectivamente, muestran patrones con centros de correlación más débiles y limitados sobre el Pacífico oriental. En la Figura 4.18b se presenta el diagrama de Taylor para este REOF2 del NCEP. Se observa que la mayor coherencia espacial entre el reanálisis y las simulaciones la lideran los modelos CESM1(FASTCHEM) (h) y GISS-E2-H-CC (x), con coeficientes de correlación en torno a 0.90, y RMSE < 0.21 (Figura 4.18). En cambio los modelos con el mayor grado de discrepancia son el IPSL-CM5A-LR (E), con el menor coeficiente de correlación espacial mostrado, de 0.63 y RMSE de 0.38, y el CMCC-CMS (l), con el máximo RMSE de 0.43, la mayor diferencia en desviación estándar respecto a la del NCEP, y una correlación espacial relativamente baja de 0.72.

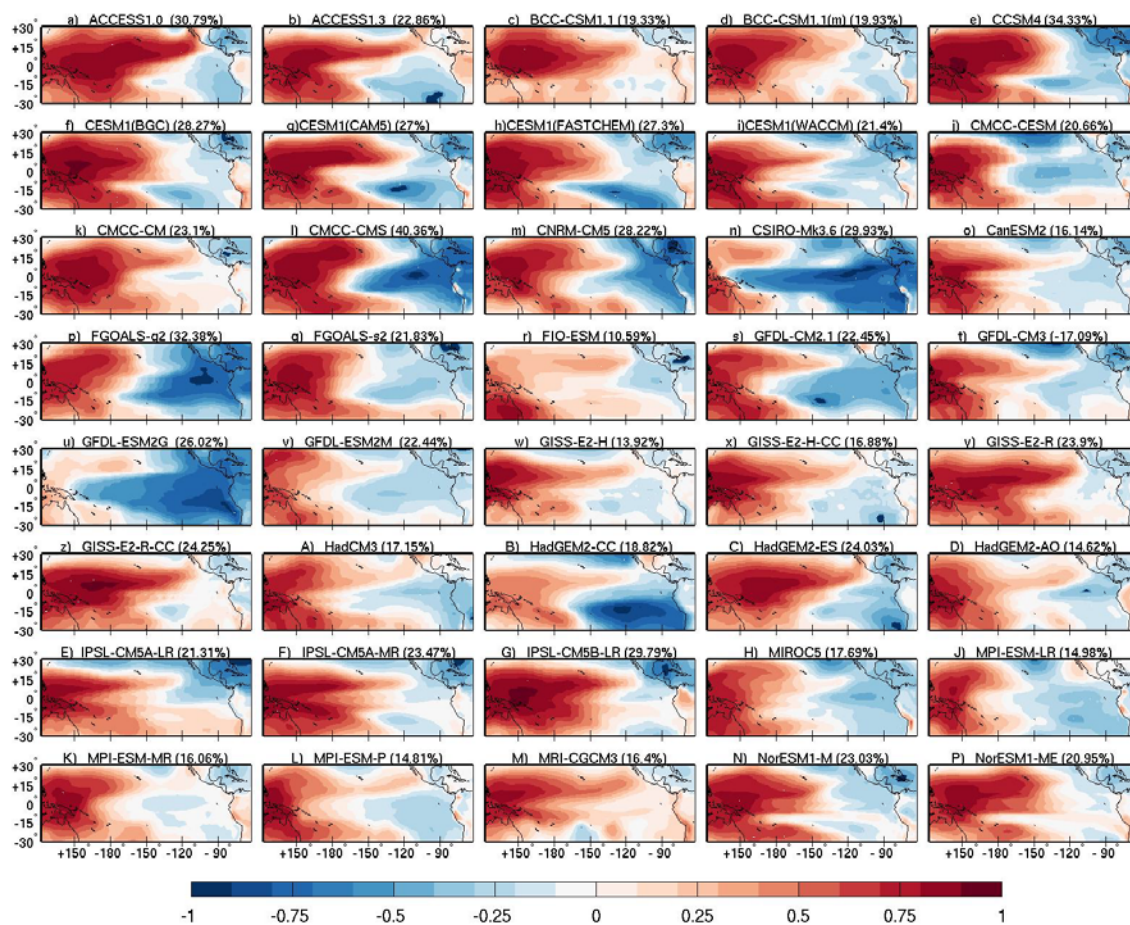


Figura 4.17. Como en la Figura 4.14 pero para el REOF2 de primavera (MAM).

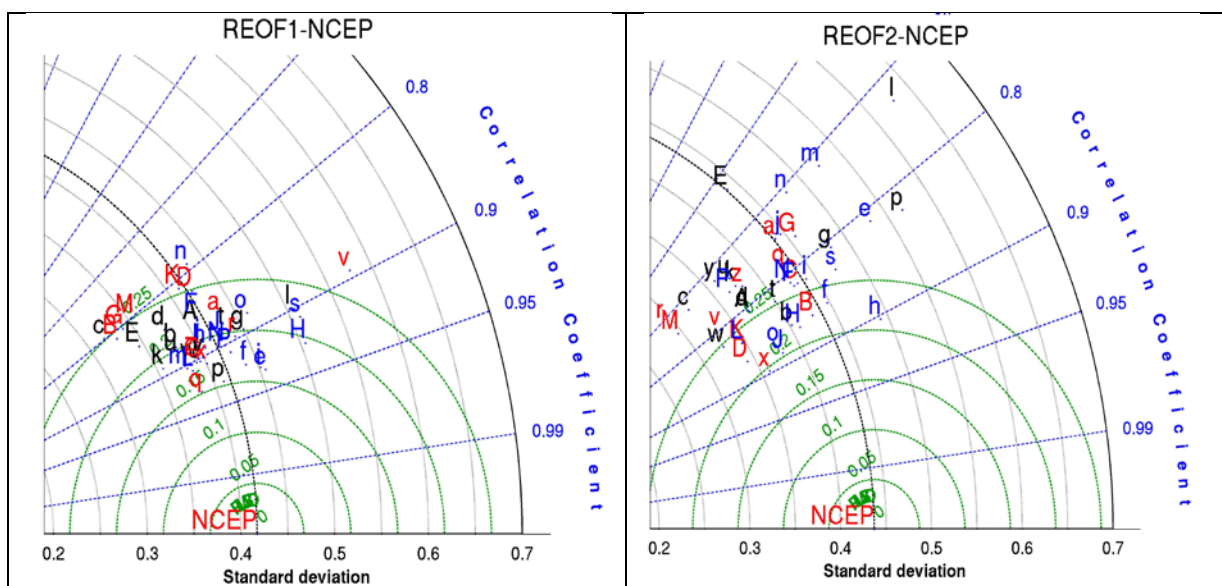


Figura 4.18. Como en la Figura 4.15 pero para primavera (MAM).

Verano

Para JJA, los dos principales modos de variabilidad de la SLP obtenidos de los modelos del CMIP5 (Figura 4.19 y Figura 4.20), muestran patrones similares a los del NCEP, manteniéndose esencialmente las configuraciones espaciales de DEF y MAM. Para casi todos los modelos, sus respectivos REOF1, excepto para el ACCESS1.0 (a), están asociados al primer modo de la reanálisis, íntimamente asociado al fenómeno ENSO. En la Figura 4.19, puede observarse que, a diferencia de lo que ocurre en DEF y MAM, un elevado número de modelos subestima la varianza explicada por este modo de variabilidad para la SLP del NCEP (36.35%). Destacan las simulaciones de los modelos IPSL-CM5A-MR (F), MPI-ESM-P (L), CMCC-CESM (j), MPI-ESM-MR (K) y MPI-ESM-LR (J), como las que capturan los mayores valores en la varianza explicada, con valores de 45.66%, 44.85 %, 41.82 %, 41.07 % y 40.85%, respectivamente; mientras que las simulaciones del HadGEM2-AO (D), MRI-CGCM3 (M), NorESM1-M (N), ACCESS1.0 (a) y HadGEM2-CC (B), presentan los porcentajes más bajos en la varianza explicada para este modo, con valores de 25.29 %, 24.76 %, 24.76 %, 22.46 % y 20.07%, respectivamente.

En la Figura 4.21 se muestra el diagrama de Taylor correspondiente a la comparación del primer modo de variabilidad de los modelos respecto al REOF1 del NCEP en JJA. Las simulaciones que mejor reproducen la distribución espacial de los patrones de correlación para el REOF1 del NCEP son: el CNRM-CM5 (m) con coeficiente de correlación espacial de 0.95, seguido por el CESM1(FASTCHEM) (h) con $r = 0.93$, y las simulaciones del MPI-ESM-MR (K), CESM1(BGC) (f), IPSL-CM5B-LR (G), HadGEM2-ES (C) y CESM1(WACCM) (i) con un coeficiente de correlación de 0.97, y un RMSE menor que 0.17. La mayoría de las simulaciones hacen una buena representación del primer modo de variabilidad de la SLP del NCEP en JJA, con excepción del GISS-E2-R-CC (z) y IPSL-CM5A-LR (E) que presentan los coeficientes de correlación más bajos (0.64) y los máximos RMSE (en torno a 0.32).

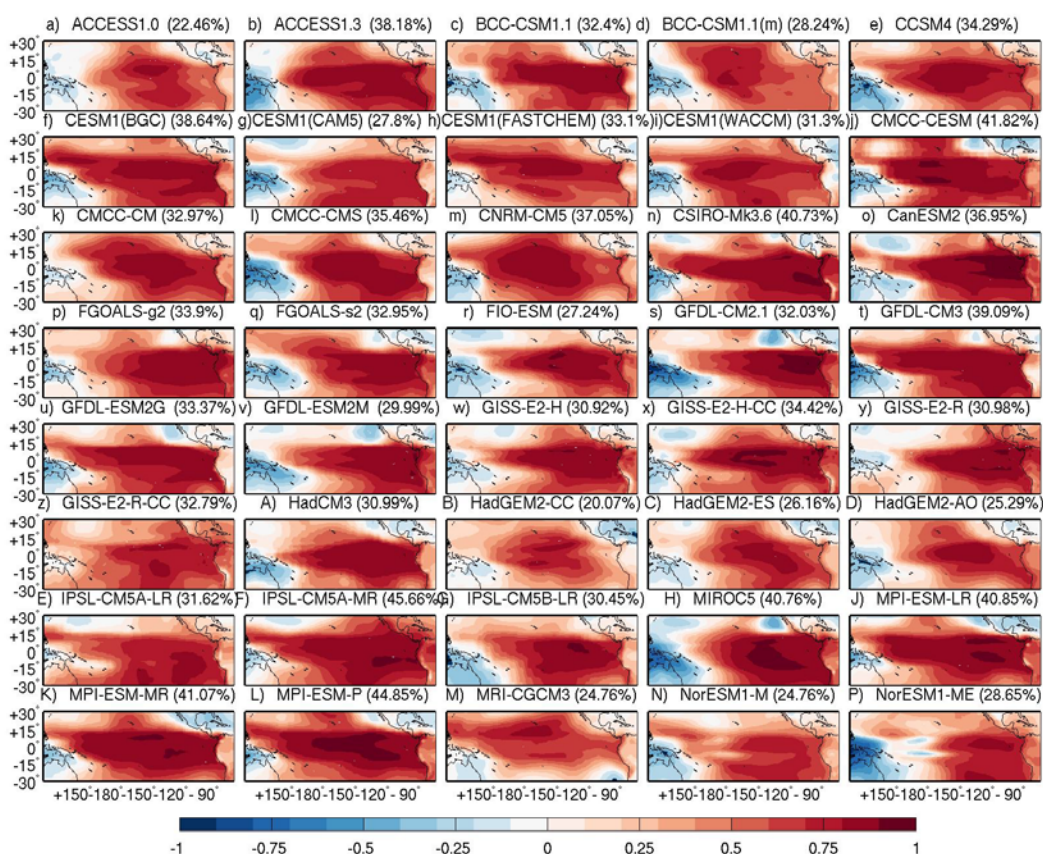


Figura 4.19. Como en la Figura 4.13 pero para el REOF1 de verano (JJA).

Para el segundo modo de variabilidad de JJA (Figura 4.20), los modelos tienden a explicar porcentajes de varianza más bajos que el del REOF2 del NCEP (17.37%). Las simulaciones del FGOALS-g2 (p), CESM1(WACCM) (i), CCSM4 (e), GISS-E2-R-CC (z) y ACCESS1.0 (a) muestran los evados porcentajes de varianza explicada (30.58%, 27.41%, 24.71%, 24.41% y 22.91%, respectivamente) frente al del REOF2 del NCEP (17.37%), presentando patrones espaciales con fuertes correlaciones positivas sobre todo el Pacífico; mientras que las simulaciones de los modelos CSIRO-Mk3.6.0 (n), CanESM2 (o), MPI-ESM-P (L), MRI-CGCM3 (M) y MPI-ESM-MR (K) presentan los porcentajes más bajos de la varianza explicada, con valores de 11.82%, 11.67%, 11.56%, 10.72% y 10.27%, respectivamente, caracterizadas por mostrar un centro de correlaciones positivas sobre Australia. En la Figura 4.21, el diagrama de Taylor correspondiente muestra que un gran número de modelos presentan altos coeficientes de correlación, con máximos valores para los patrones simulados por los modelos ACCESS1.0 (a) y HadGEM2-ES (C), con $r = 0.95$, seguidos del IPSL-CM5B-LR (G) y CESM1(WACCM) (i) con $r=0.93$. En el extremo opuesto se observa que la simulación del MRI-CGCM3 (M), con un

coeficiente de correlación de sólo 0.64 y un valor máximo del RMSE de 0.30, es la que presenta mayor grado de deformación del segundo modo de variabilidad para JJA.

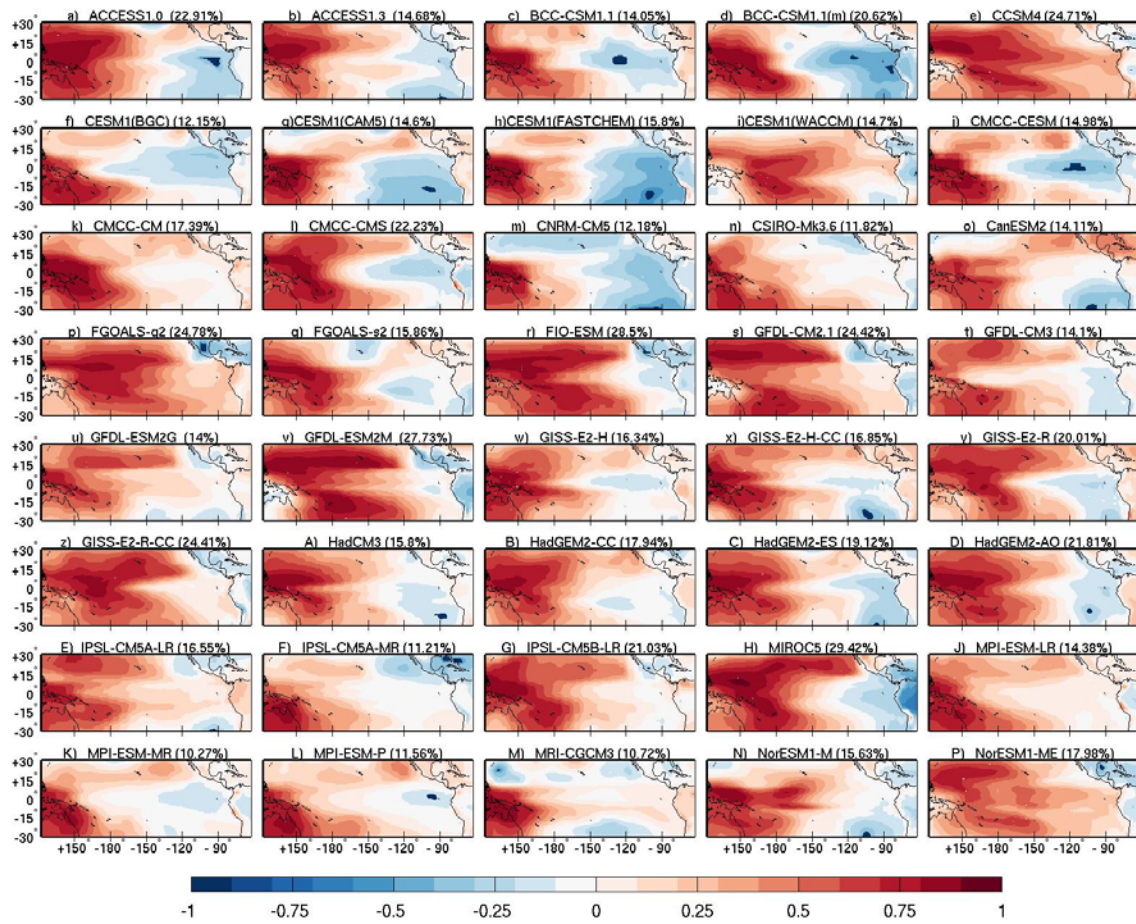


Figura 4.20. Como en la Figura 4.14 pero para el REOF2 de verano (JJA).

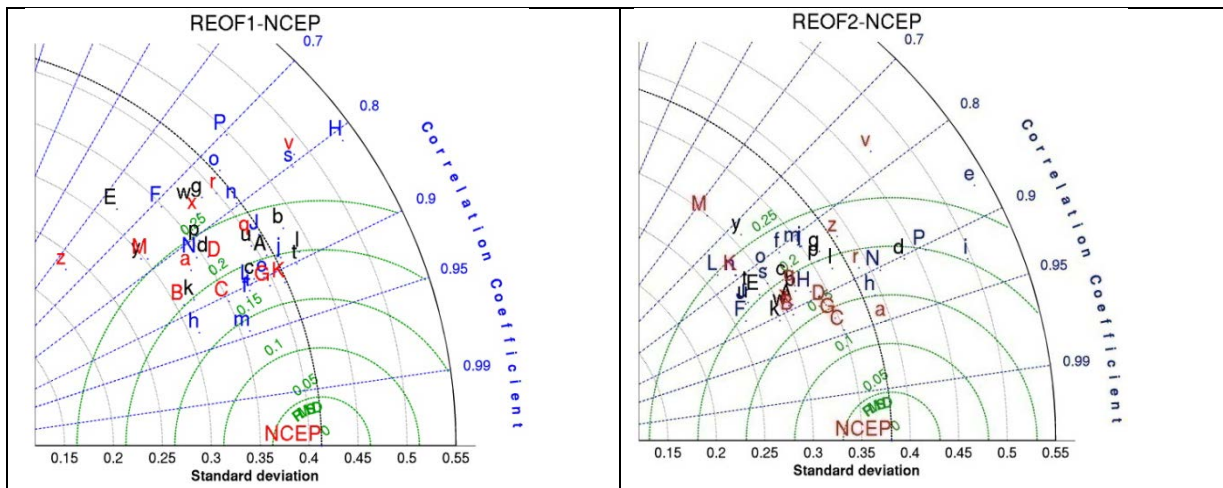


Figura 4.21. Como en la Figura 4.15 pero para verano (JJA).

Otoño

Los patrones espaciales de los dos principales modos de variabilidad, obtenidos a partir de las simulaciones de 40 modelos del CMIP5 en SON, para el periodo 1950-2005, se muestran en las Figuras 4.22 y 4.23. En ambos casos, los patrones obtenidos presentan un razonable parecido con los del NCEP, estando en todos los casos los REOF1 de los modelos asociados al REOF1 del NCEP. Similar situación se tiene para los REOF2.

Para el REOF1 (Figura 4.22) se tiene que los modelos son capaces de reproducir las características observadas de la SLP del NCEP, al igual que en las otras estaciones del año. Las simulaciones de los modelos de I GFDL-CM2.1 (s), CMCC-CMS (l), MIROC5 (H), CSIRO-Mk3.6.0 (n) y GFDL-ESM2M (v), con varianzas explicadas de 46.85%, 44.55 %, 42.08 %, 41.09% y 40.46%, respectivamente, sobrestiman la varianza explicada por este modo frente al del REOF1 del NCEP (32.72%). Por otro lado, los valores más bajos en la varianza explicada por el REOF1, se obtienen para las simulaciones del CMCC-CESM (j), IPSL-CM5B-LR (G), BCC-CSM1.1 (c), ACCESS1.0 (a) y NorESM1-M (N), con valores de 28.71%, 25.93%, 24.59%, 24.32% y 20.67%, respectivamente.

La Figura 4.24 presenta los diagramas de Taylor correspondientes a la comparación de los REOF1 y REOF2 de los modelos con los del NCEP, para SON. Los resultados muestran que los máximos coeficientes de correlación entre los patrones simulados y el del reanálisis, para el REOF1, lo encabeza el modelo CCSM4 (e), con una de correlación espacial de 0.93 y desviación estándar de 0.43, presentando además el menor RMSE (0.16), seguido por las simulaciones de los modelos CESM1(BGC) (f), GFDL-CM3 (t) y CMCC-CESM (j), con coeficientes de correlación del orden de 0.90 y RMSE de 0.19 en los tres casos. Las simulaciones de GFDL-CM2.1 (s) y GFDL-ESM2M (v) también muestran el evados coeficientes de correlación (próximos a 0.9), y bajos valores de RMSE (0.25 y 0.26, respectivamente, pero presentan, junto con el MIROC5 (H) las máximas diferencias respecto a la desviación estándar del NCEP, con valores de desviación superiores a 0.52. Por el contrario, los modelos con los coeficientes de correlación más bajos son GISS-E2-H (w), IPSL-CM5A-LR (E) y CanESM2 (o) con valores de 0.62, 0.62 y 0.58, respectivamente. Además estas últimas simulaciones presentan también los máximos valores para los RMSE (por encima de 0.32).

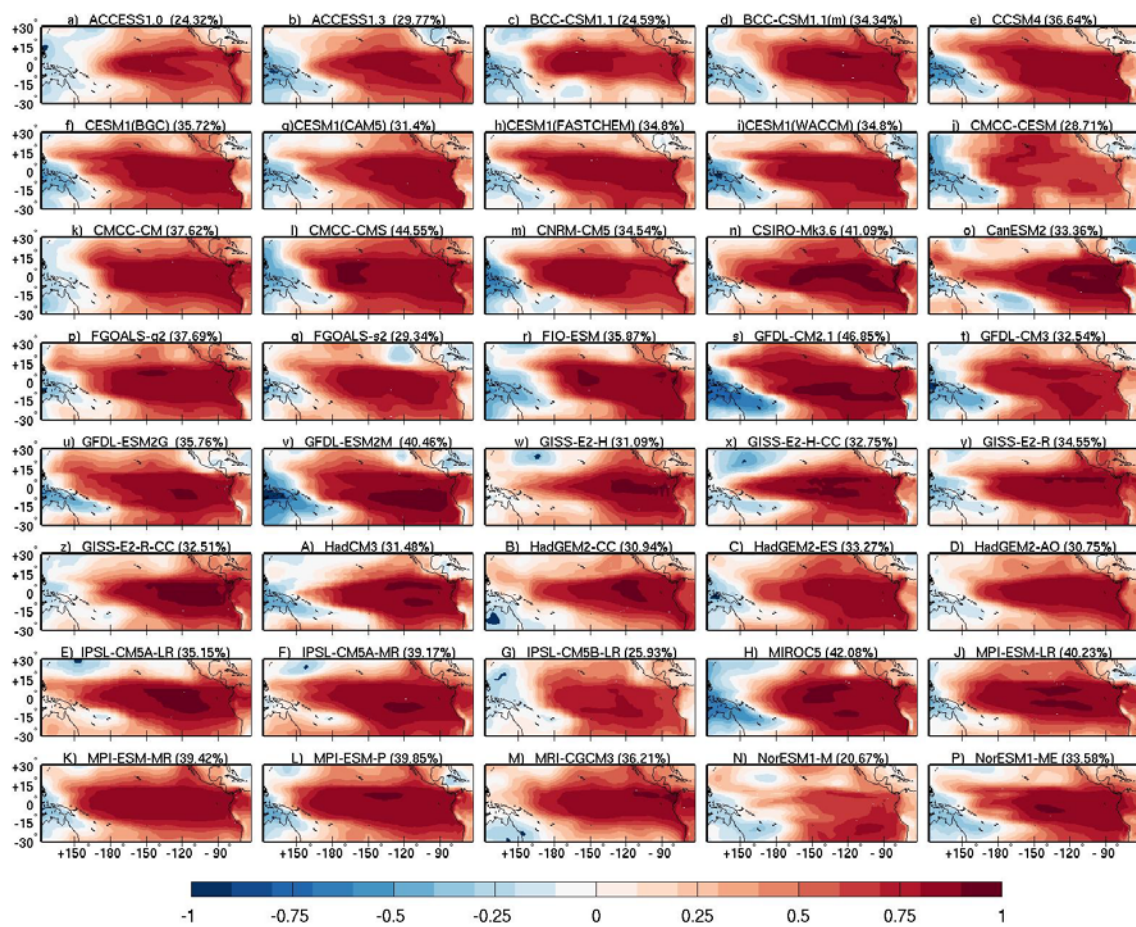


Figura 4.22. Como en la Figura 4.13 pero para el REOF1 de otoño (SON).

Para el REOF2 (Figura 4.23), todos los modelos reproducen el centro de correlaciones positivas en el Pacífico occidental, y un elevado número de ellos presenta además el núcleo de correlación negativo en el Pacífico oriental que muestra el REOF2 del NCEP en SON. Las simulaciones del MIROC5 (H), FIO-ESM (r), GISS-E2-R-CC (z), GISS-E2-H (w) y CMCC-CESM (j) son las que capturan la mayor cantidad de varianza para el REOF2, con valores de 25.5%, 25.18%, 23.25%, 23.12% y 22.59%, respectivamente, bastante cercanos al porcentaje de varianza explicado por este modo para los datos del NCEP (20.19%). En cambio las de los modelos MPI-ESM-MR (K), GFDL-ESM2G (u), IPSL-CM5A-LR (E), GFDL-ESM2M (v) y MPI-ESM-P (L), capturan los porcentajes más bajos de la varianza explicada, con 13.79%, 13.2%, 13.15%, 12.58% y 12.37%, respectivamente, caracterizándose por la menor extensión del centro de correlaciones positivas en el área occidental del Pacífico.

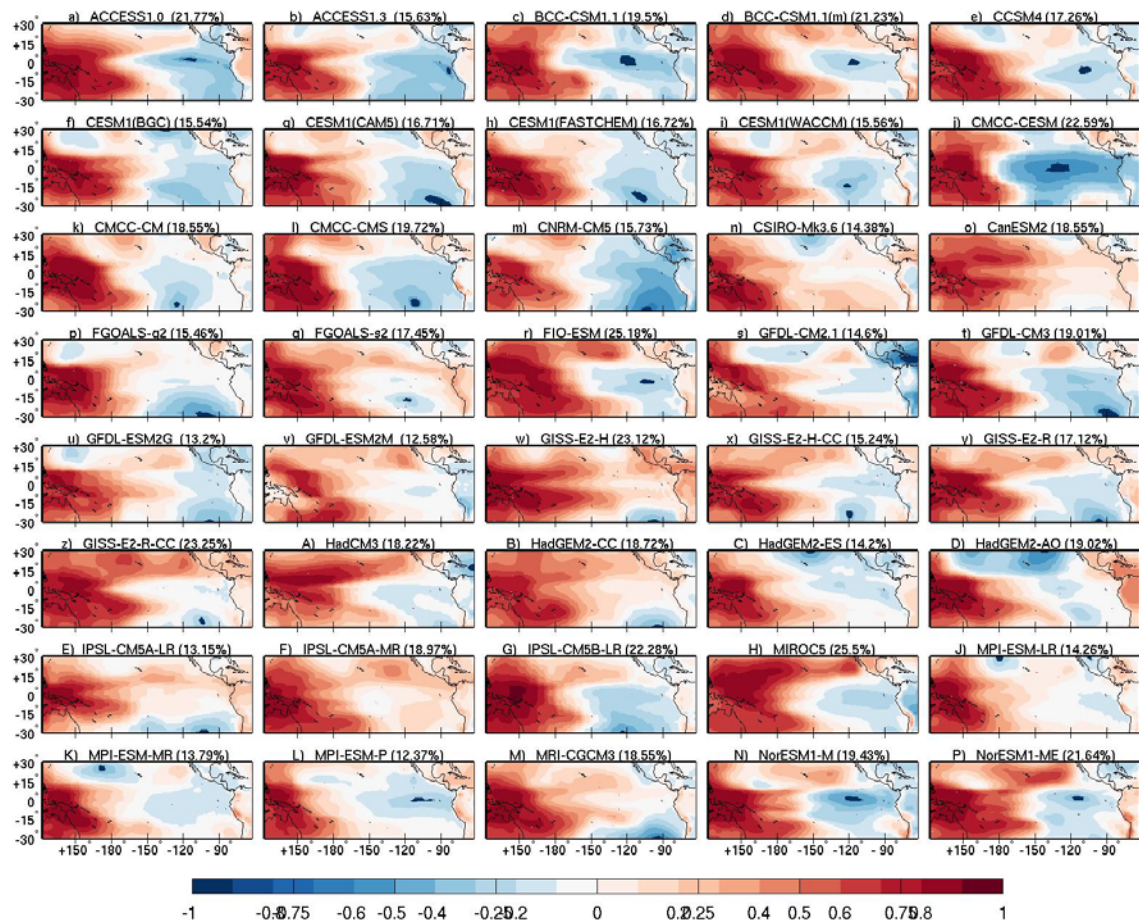


Figura 4.23. Como en la Figura 4.14 pero para el REOF2 de otoño (SON).

En la Figura 4.24 se muestra el diagrama de Taylor, con los parámetros correspondientes al análisis de comparación de los resultados obtenidos por las simulaciones de 40 GCMs del CMIP5 con los generados por los reanálisis del NCEP para el REOF2, durante el periodo de 1950-2005, en SON. Se aprecia que las simulaciones que mejor reproducen la distribución espacial de los patrones de correlación para este modo del NCEP vienen encabezadas por el modelo CESM1(FASTCHEM) (h), con el máximo coeficiente de correlación espacial (0.93) y el menor RMSE, seguido por las simulaciones de CMCC-CM (k), CESM1(BGC) (f), CMCC-CMS (l), IPSL-CM5B-LR (g) y ACCESS1.3 (b), con coeficientes de correlación del orden de 0.90, y RMSE de 0.16. Como modelos que peor representación obtienen del modo, se tiene el GFDL-ESM2M (v), que presenta los valores más bajos de correlación (0.60), de desviación estándar de 0.27 y RMSE más alto (0.32). El CMCC-CESM (j) es la única simulación cuya desviación estándar (0.47) supera la del NCEP (0.42).

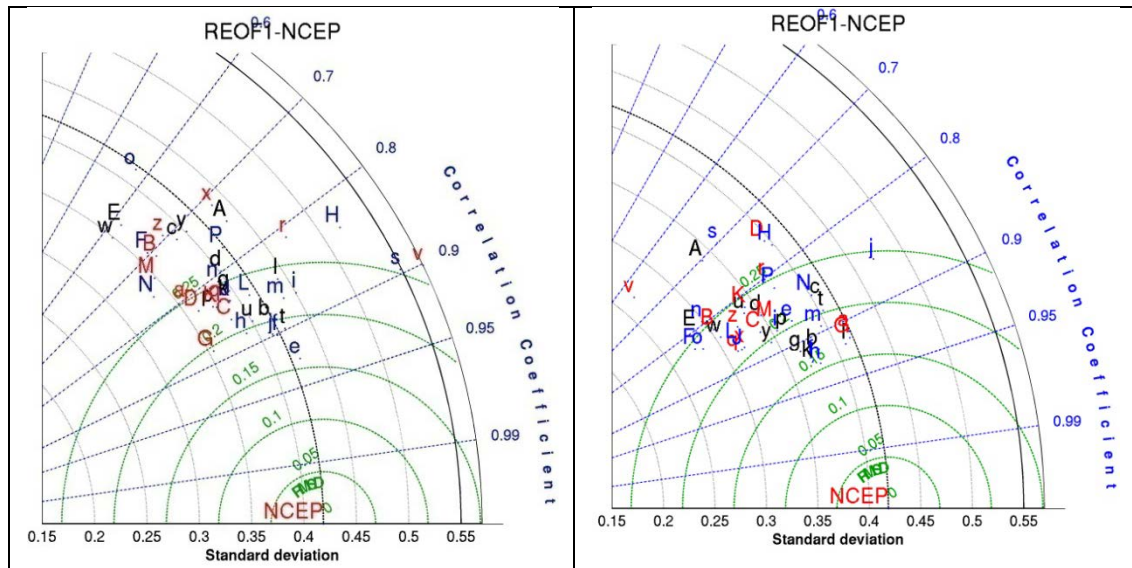


Figura 4.24. Como en la Figura 4.15 pero para otoño (SON).

4.4 Conclusiones

En ese capítulo se han evaluado en detalle la habilidad de los GCMs para simular la SLP en la zona tropical en el Pacífico, cuya influencia es básica para describir la variabilidad climática en el área de estudio en la que se enmarca esta tesis, y es de particular importancia pues esta variable será empleada como predictora de la precipitación en el modelo de *downscaling*. Así, se han comparado las salidas históricas (de 1950-2005) de los GCMs con los datos de SLP del reanálisis NCEP y con los datos observacionales del HadSLP2. Todos los datos se han llevado a una rejilla común igual a la de los datos del NCEP ($2.5^\circ \times 2.5^\circ$).

Se ha evaluado la reproducibilidad del campo medio de la SLP tanto en base mensual como estacional. En general, los GCMs reproducen el patrón espacial de este campo medio, sin que haya desviaciones de más de 10 hPa, con cierto predominio de subestimaciones de la SLP en el Pacífico tropical occidental, y sobrestimaciones en el área continental occidental, sobre todo los Andes. El modelo HadCM3 destaca por ser el único que muestra de forma sistemática sobrestimaciones sobre casi todo el área. Respecto a la varianza, las variaciones no suelen ser significativas, siendo los modelos del GISS los que suelen subestimar de forma más general, marcada y significativa y los del GFDL (sobre todo el GFDL-ESM2M) los que tienden a sobrestimarla.

Se ha analizado la reproducibilidad de los principales modos de variabilidad de la SLP, caracterizados por los primeros REOFs del NCEP, tanto en base mensual como para las cuatro estaciones del año. Para el análisis mensual, los resultados muestran que la mayoría de los modelos tienden a hacer una buena representación de los dos primeros modos de variabilidad. En general, casi todos los modelos exhiben valores superiores de la varianza total explicada por el primer modo de variabilidad respecto al obtenido a partir de las bases de datos de reanálisis y observacional, mientras que el segundo tiende a presentar valores más parecidos a los obtenidos a partir de estas bases. Además, para la mayoría de los modelos, la correlación espacial entre el segundo modo de variabilidad y las bases observacionales presentan valores por encima de 0.9, mientras que para el REOF1, un número elevado de los modelos presentan valores de estas correlaciones por debajo de 0.9, aunque una gran mayoría se mantienen por encima de 0.8. De manera análoga existe una mayor dispersión en los valores de RMSE para los primeros REOFs de los modelos que para los REOF2, estando en cualquier caso acotados entre 0.25 y 0.1.

Para el análisis estacional, las simulaciones históricas de los 40 modelos del CMIP5 considerados representan de forma aceptable las principales características de la SLP del NCEP. Al igual que en el análisis mensual, el primer modo de variabilidad de los GCMs tiende a sobrestimar la varianza explicada, mientras que el segundo tiende a mostrar valores más parecidos o a subestimarla. De manera general, es durante el invierno cuando los dos primeros modos de variabilidad de la SLP son mejor reproducidos, para la primavera y el otoño, el primer modo de variabilidad tiende a ser mejor reproducido, mientras que lo contrario ocurre durante el verano, siendo esta estación la que muestra, para algunos modelos, una reproducibilidad más deficiente. En cualquier caso, los patrones de variabilidad caracterizados por los REOFs en los modelos esencialmente capturan la variabilidad mostrada por los REOFs del NCEP, siendo difícil establecer un rango que determine qué modelos son mejores en la reproducción de los mismos de forma general, pues hay diferencias en el comportamiento de los modelos según la época del año.

No existen en la bibliografía trabajos relativos a la evaluación de la SLP del Pacífico tropical en el CMIP5, aunque sí existen diversos trabajos dedicados a la evaluación de la SST, y en particular al fenómeno ENSO. Ya que la SLP en esta región está fuertemente ligada a la SST, cierta comparación de nuestros resultados puede hacerse a través de estos estudios sobre la SST. Así, Bellenger et al. (2014) muestran una mejora sustancial en la representación del campo medio de la SST en esta región en los modelos del CMIP5 respecto a los del CMIP3, aunque

también muestran que un número considerable de modelos presenta ciertas deficiencias en la reproducción del ciclo estacional, lo que concuerda con la acertada representación de la SLP aunque con ciertas diferencias estacionales. Por otra parte, Kim and Yu (2012) muestran también una adecuada representación en los modelos de los modos de ENSO central y oriental, aunque todavía existe problemas relativos en cuanto a la captura de la intensidad de los ENSO orientales. Este resultado puede estar relacionado con la sobrestimación de la varianza del primer modo de variabilidad por la mayoría de los GCMs. Yin et al. (2012) también muestran que durante las estaciones de transición, existe problemas con la forma en la que los modelos describen el paso de la Zona de Convergencia Intertropical (ITCZ), aunque en general, consideran que la variabilidad de la SST y su influencia en la precipitación son aceptablemente modeladas por un considerable número de modelos, lo cual pone de manifiesto una adecuada representación de la influencia de la SLP sobre la precipitación dadas el fuerte acoplamiento entre estas variables en la región en estudio.

CAPÍTULO 5

DOWNSCALING DE LA PRECIPITACIÓN

En este capítulo se desarrollan los modelos de *downscaling* estadístico (DS) para la precipitación estacional en Sudamérica mediante la técnica de regresión por componentes principales (PCR), siguiendo fundamentalmente el esquema desarrollado por Li and Smith (2009) y Palomino-Lemus et al. (2015). Para ello, se analizan los modos de variabilidad de la presión a nivel del mar (SLP) estacional en la región tropical y su influencia en la precipitación de Sudamérica. De este análisis se obtendrán las variables predictoras de la precipitación, que serán utilizadas en los modelos de regresión. La habilidad de los modelos DS generados, para simular la precipitación estacional de Sudamérica, será evaluada tanto a escala espacial de rejilla, como a escala regional para diferentes zonas seleccionadas.

5.1 Modos de variabilidad de la SLP estacional

En este apartado se analizan los patrones espaciales de los principales modos de variabilidad de la SLP estacional comprendida en la región tropical [30°S-30°N, 180°O-30°O], obtenidos a partir de un PCA aplicado a las anomalías estacionales de la SLP de los datos de reanálisis del NCEP para el periodo 1950-2010, que serán usados como variables predictoras en la obtención del modelo de *downscaling* estadístico (DS) de la precipitación. Para cada estación, se han extraído los diez primeros modos de variabilidad (Figuras 5.1 y 5.2), que en conjunto explican el 88.8%, 84.7%, 89.7% y 85.5% de la varianza total acumulada de los datos para las estaciones de invierno (DEF), primavera (MAM), verano (JJA) y otoño (SON), respectivamente. Como puede verse, este porcentaje es elevado para todas las estaciones, aunque es en invierno y en verano cuando resulta mayor. Se analizarán en primer lugar los resultados obtenidos por el PCA para estas dos estaciones y posteriormente para la primavera y el otoño.

Invierno y verano

En la Figura 5.1 se presentan los patrones espaciales de variabilidad (EOFs) de la SLP, junto con sus respectivas series temporales asociadas (PCs), correspondientes a las estaciones de invierno y verano. Además, con el fin de explorar el significado físico de los modos encontrados, la Tabla 5.1 presenta las correlaciones existentes entre las PCs normalizadas de los 10 primeros modos de variabilidad en DEF y JJA con los principales índices de teleconexión. Los resultados muestran que el primer modo de variabilidad (EOF1), para ambas estaciones, se caracteriza por la presencia de un patrón dominante de correlaciones positivas fundamentalmente localizado en el Pacífico tropical. Sin embargo, existen diferencias en este primer modo de la SLP encontrado en invierno y el de verano. Para DEF, este modo explica el 31.5% de la varianza total de los datos de SLP, y está caracterizado por un fuerte gradiente de correlación positivas, centrado alrededor de los 150°W-10°S en el Océano Pacífico, que se extiende hacia el Atlántico tropical norte. Para JJA, el EOF1 explica un 46.8% de la varianza total de los datos, mostrando un centro de correlaciones más intensas positivas desplazado hacia el sur, alrededor de 120°W-15°S. Este primer modo de variabilidad se encuentra asociado al fenómeno ENSO tanto en DEF como en JJA. Prueba de ello son los elevados valores de correlación lineal obtenidos entre su serie PC1 y los índices de teleconexión asociados al ENSO y al SOI (Tabla 5.1), encontrándose los valores más altos para el CENSO ($r = -0.71$ y -0.86 para DEF y JJA, respectivamente), seguido por los índices de El Niño4 ($r = -0.68$) y el Niño3.4 ($r = -0.65$) para DEF, y por el ONI ($r = -0.83$) y el Niño3.4 ($r = -0.82$) para JJA.

El segundo modo de variabilidad, EOF2, para DEF y JJA explica un 16.9% y 11.9% de la varianza total de los datos, respectivamente. Para DEF, el patrón espacial de este modo muestra dos centros de acción muy bien definidos pero de signos contrarios. Uno de ellos con correlaciones positivas localizado en el extremo noroccidental de la región de estudio, y el otro con correlaciones negativas que se extiende desde el Golfo de México, cubriendo toda centro América hasta los 150°W a proximadamente (Figura 5.1). Adicionalmente la serie temporal asociada a este modo, la PC2, muestra una fuerte variabilidad con tendencias negativas en los primeros 30 años y positivas en los últimos 20 años. Además, como muestra la Tabla 5.1, está fuertemente correlacionada con el índice WP ($r = 0.80$), y débilmente correlacionado con el SOI ($r = -0.36$).

El EOF2 para JJA, muestra una estructura espacial caracterizada por la presencia de un fuerte gradiente de correlaciones positivas que se distribuye a lo largo y ancho de toda la región, extendiéndose desde los 30°N hasta los 30°S, con correlaciones más débiles en el extremo oeste del área de estudio. Además, se evidencia un pequeño centro de correlaciones negativas en el extremo suroeste del área, aproximadamente alrededor de los (175°W-25°S). La serie PC2 asociada a este modo, muestra una tendencia negativa en los primeros 20 años, seguida de una leve tendencia positiva. En lo que respecta a la relación de esta PC con los índices de teleconexión (Tabla 5.1) aparecen correlaciones más débiles que en invierno, pero significativas, con el índice WHWP ($r = -0.30$) y con el TNI ($r = -0.29$)

Los terceros EOFs, tanto para DEF como para JJA, siguen captando un porcentaje considerable de la varianza explicada (Figura 5.1), con valores del 12.3% en DEF y 8.6% en JJA. En invierno, su patrón espacial muestra un fuerte núcleo de correlaciones positivas en el noroeste, centrado alrededor de los 15°N-40°W, el cual llega a extenderse, aunque debilitado, por todo el norte de Sur América, hasta el norte de Chile. Adicionalmente también aparece un gradiente de correlaciones negativas, que se distribuye por todo el extremo sur entre los 170°W-90°W, limitado hasta los 10°S por un débil gradiente de correlaciones positivas. La serie PC3 en invierno presenta un comportamiento irregular, con fuerte tendencia positiva hasta 1997, y negativa durante los últimos 10 años, interrumpida por eventos asociados al ENSO, en varias ocasiones. Adicionalmente, para la PC3 en invierno, se encuentran importantes correlaciones negativas con el índice AMM ($r = -0.63$), el ATLTRI ($r = -0.54$) y el TNA ($r = -0.52$), y más débiles con los índices MEI, NAO y EOFAC ($r = 0.41, 0.42$ y 0.43 , respectivamente).

El EOF3 de JJA exhibe dos centros de correlaciones muy bien definidos. El primero de ellos, con correlaciones negativas, se encuentra localizado al noreste de la región de estudio, entre los 30°N-10°S, rodeado por un gradiente de correlación positivo cuyo centro de acción se encuentra en la parte noroccidental, y que se debilita entre 120°W y 90°W, hasta llegar a la costa oeste de América del Sur. La serie temporal normalizada asociada a este modo, la PC3 (Figura 5.1), muestra una fuerte tendencia negativa en la primera mitad del periodo de análisis y positiva en la segunda. Después haber eliminado la tendencia, se pueden ver coeficientes de correlación significativamente altos entre la PC3 y el índice TNA ($r = 0.65$) así como con el AMON y el ATLTRI, ambos con el mismo coeficiente de correlación ($r = 0.64$). El cuarto y quinto modos de variabilidad (EOF4 y EOF5) de DEF, explican un 8.8% y un 5% de la varianza, respectivamente. El EOF4, muestra un dipolo zonal con centros de correlaciones negativas. El

primero de ellos presenta forma de herradura, y se distribuye por todo el suroeste y el noroeste, siendo truncado por un débil patrón de correlaciones positivas centrado entre los 150°W y 15°S. el segundo de ellos muestra un gradiente de correlaciones negativas que cubre la totalidad del continente suramericano incluida en la región de estudio, así como la zona atlántica por debajo de los 20°N. Adicionalmente se aprecia o tra que pequeña región con correlaciones positivas localizada más al norte, cubriendo el Golfo de México, Florida y la mayoría de las islas del Caribe. En cambio, el EOF5 para DEF, presenta una estructura espacial poco definida, destacándose únicamente un gradiente con correlaciones positivas al norte de Chile, y otro frente a las costas de Suramérica. La serie PC4, asociada al EOF4, presenta de manera general una marcada tendencia negativa, mostrando valores importantes de correlación con los índices WHWP, El Niño1+2 y el Niño3 ($r = -0.53$, -0.44 y -0.43 , respectivamente). También presenta correlaciones moderadas positivas con el NP ($r = 0.48$) y de menor valor con el SOI ($r = 0.42$). La PC5 de invierno, asociada al EOF5, presenta una tendencia negativa los primeros 15 años del periodo de estudio, y positiva los años restantes, mostrando correlaciones moderadas ($r = 0.35$) con los índices ATLTRI y AMM.




Figura 5.1. Factores de carga para los diez primeros modos de variabilidad obtenidos mediante un PCA de los datos estacionales de invierno (DEF) y verano (JJA) de la SLP del reanálisis del NCEP y sus series PCs correspondientes, en el período 1950-2010.

Por otra parte, el cuarto y quinto modos de variabilidad obtenidos para la SLP de verano, explican un 6.5% y un 4.1% de la varianza, respectivamente, un poco menos que para el invierno. Estos dos modos conjuntamente solo representan el 10.6% de la varianza total en JJA, y aunque es relativamente menos que los anteriores, sus características espaciales y temporales presentan interés. El EOF4 en verano, se caracteriza por un centro de correlaciones negativas

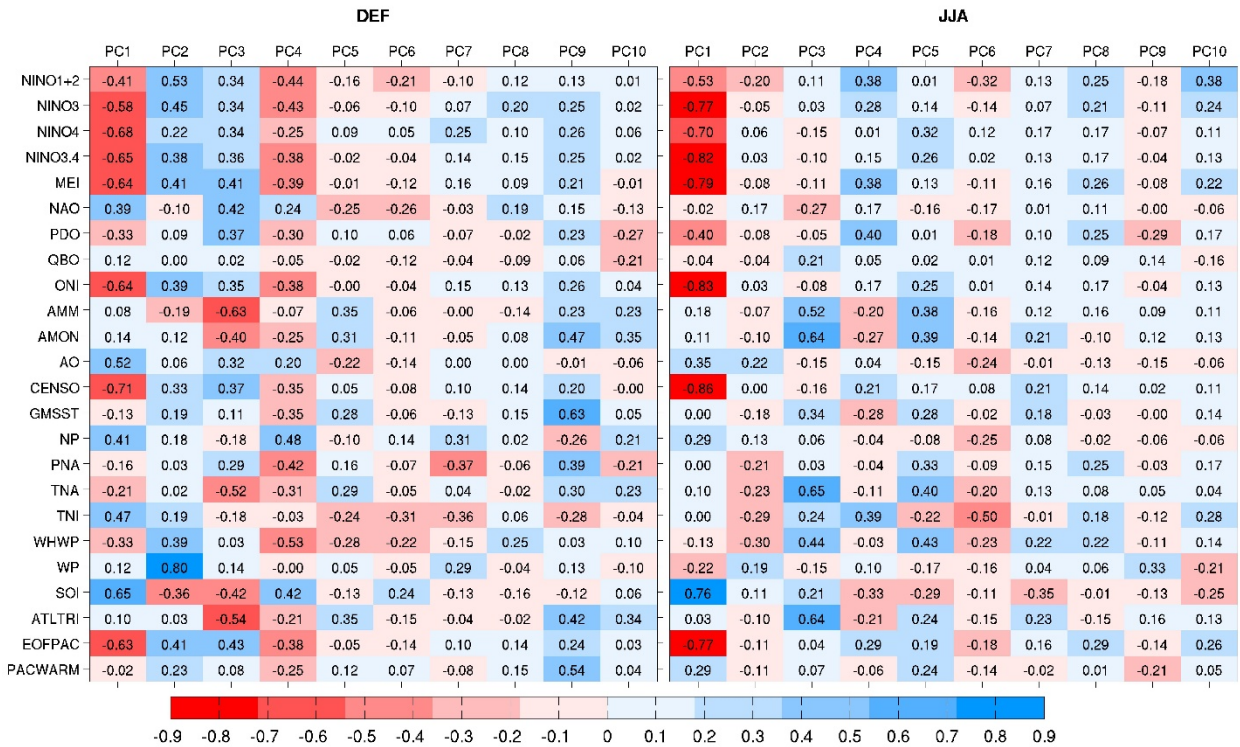
frente a la costa oeste de Chile, y un patrón irregular de correlaciones positivas al este, que se extiende en una franja ecuatorial hasta los 120°W. La serie temporal asociada, PC4 de verano, muestra una predominante tendencia positiva durante aproximadamente los primeros cuarenta años del periodo de estudio, que desaparece en los últimos 20 años. Por su parte, el centro de correlación más fuerte del EOF5 en JJA es positivo, y se encuentra localizado al este de Brasil. Su serie temporal asociada muestra un cambio abrupto hacia 1970 y una suave tendencia positiva a partir de ese año. Los coeficientes de correlación entre la PC4 e n JJA y los índices de teleconexión PDO, TNI, NINO1+2 y MEI presentan valores de 0.4, 0.39, 0.38 y 0.38, respectivamente. Por su parte, la PC5 en JJA presenta coeficientes de correlación de 0.43 y 0.40 con los índices WHWP y TNA, y ligeramente más débil con el AMON ($r = 0.39$).

Los últimos cinco modos de variabilidad para DEF explican un 4.2%, 3.4%, 2.8%, 2% y 1.9% de la varianza restante, representando conjuntamente un 14.3% de la varianza total en invierno. Aunque la varianza explicada por ellos es relativamente baja, sus patrones espaciales y temporales presentan características interesantes. Los EOFs 7, 8 y 9, muestran patrones de correlación negativa en la zona continental, especialmente en Sudamérica, mientras que el EOF6 muestra correlaciones positivas en esta región. Además, en el extremo sur, frente a las costas de Chile, sobresale un pequeño centro de correlaciones positivas para los EOFs 6 a 9, que en el EOF10 se ubica desplazado a la zona continental. Adicionalmente, los coeficientes de correlación entre las PCs asociadas a estos cinco últimos modos y los índices de teleconexión también son importantes en algunos casos. Destaca la PC9 en DEF al presentar coeficientes de correlación de 0.63, 0.54, 0.47 y 0.42 con los índices del GM SST, PACWARM, AMON y ATLTRI, respectivamente. Le sigue la PC7 en DEF con valores de correlación, más débiles pero significativos, con el índice PNA ($r = -0.37$) y el TNI ($r = -0.36$).

Finalmente, los últimos cinco modos de variabilidad para JJA explican conjuntamente el 11.8% de la varianza total de los datos. El EOF6 muestra un centro llamativo de correlaciones negativas por encima de los 10°N, que se extiende desde el oeste de la región de estudio hasta las costas de California, y un segundo centro de signo contrario sobre toda cordillera de los Andes. La serie PC6 asociada presenta una tendencia general positiva. Los EOF7, EOF8, EOF9 y EOF10, se caracterizan por presentar débiles centros de correlación irregularmente distribuidos tanto positivos como negativos. En lo que respecta al grado de relación entre estas últimas cinco PCs de verano con los índices de teleconexión, se encuentran valores de correlación muy moderados. Cabe destacar la PC6 que presenta relación con el TNI ($r = -0.5$), la PC10 con El

Niño1+2 ($r = 0.38$), la PC7 con el SOI ($r = -0.35$), la PC9 con el WP ($r = 0.33$) y la PC8 con el índice EOFPAC ($r = 0.29$).

Tabla 5.1. Coeficientes de correlación lineal entre las PCs de los diez primeros modos de variabilidad de la SLP estacional de invierno (DEF) y verano (JJA) procedentes de los datos de reanálisis del NCEP, con algunos de los principales índices de teleconexión. Los valores significativos al nivel de confianza del 95% se indican con (*).



Primavera y otoño

De forma análoga al análisis de los modos de variabilidad realizado anteriormente para el invierno y verano, se muestran a continuación los resultados correspondientes a la primavera y el otoño. La Figura 5.2 presenta los patrones espaciales y sus PCs asociadas para los primeros 10 modos de variabilidad de la SLP en primavera (MAM) y otoño (SON), obtenidos a partir del PCA descrito con anterioridad. Los resultados del análisis muestran que el primer EOF representa un modo dominante que explica un 25.4% de la varianza total de los datos en MAM, y un considerable mayor porcentaje (42%) en SON. Ambos patrones espaciales son muy parecidos entre sí y a los EOF1s correspondientes al invierno y verano, con un centro de correlaciones positivas que se extiende por todo el Océano Pacífico, y que en el caso de MAM alcanza el Atlántico tropical norte.

Las series PCs asociadas a este primer modo, tanto para MAM como para SON, revelan fluctuaciones interanuales y una tendencia positiva en los últimos 30 años. En la Tabla 5.2 se muestran los valores de los coeficientes de correlación de las series PCs, obtenidas para las estaciones de primavera y otoño, con los principales índices de teleconexión. Para ambas estaciones, las series temporales PCs1 se correlacionan fuertemente con los índices tradicionales del ENSO. El otoño además, presenta mayores valores de correlación que la primavera para esta primera PC, alcanzándose los valores de -0.81 con el CENSO, -0.80 con el MEI, -0.78 con el NIÑO4, -0.75 con el ONI y 0.75 con el SOI. Mientras que para la estación de MAM, los valores obtenidos son -0.71 para el CENSO, -0.67 con el NIÑO4 y el EOFAC y 0.67 con el SOI.

El segundo modo de variabilidad (EOF2) explica el 16.1% y 12.4% de la varianza total de la SLP de primavera y otoño, respectivamente. En este caso los patrones espaciales asociados a este EOF2 difieren entre las dos estaciones. El EOF2 para MAM se caracteriza por un patrón dipolar de correlaciones de signo opuesto, con un centro de correlaciones negativas localizado en el extremo oeste del área de estudio y un centro de correlaciones positivas que se extiende desde el Golfo de México, cubriendo toda Centro América, la zona oceánica del noreste y el norte de Sudamérica. La serie temporal PC2 asociada a este modo, muestra una importante variabilidad decadal, y los valores más altos de correlación aparecen con el índice WHWP ($r = -0.62$) y la PNA ($r = -0.61$).

El segundo modo de variabilidad para otoño muestra una estructura espacial parecida al EOF2 en verano, caracterizado por la presencia de un fuerte gradiente de correlaciones negativas que se distribuye a lo largo y ancho del área de influencia de la ZCIT. La PC2 asociada a este modo, presenta una fuerte tendencia negativa hasta 1990, seguida de una fuerte tendencia positiva. Este modo presenta correlaciones importantes con los índices GMSST ($r = 0.63$), TNA ($r = 0.61$) y WHWP ($r = 0.56$).

El tercer EOF para MAM explica un 10.4% de la varianza, dominado principalmente por factores de carga positivos situados al noroeste del área de estudio y de valor más débil en el Océano Atlántico y sobre Sudamérica. La PC3 asociada a este modo presenta una tendencia negativa a partir de 1975, mostrando sólo débiles correlaciones negativas con los índices de teleconexión.

El tercer modo de variabilidad para SON explica el 6.8 % de la varianza, exhibiendo una estructura irregular en los centros de acción de los factores de cargas positivos y negativos, resaltando un centro de correlaciones al norte del Atlántico. La PC3 para SON muestra una fuerte tendencia negativa desde 1950 al 1970, y positiva a partir de 1975. Además, los valores más altos para los coeficientes de correlación con los índices de teleconexión (Tabla 5.2) se obtienen para el AMM, TNA, AMON y el ALTRI ($r = 0.55, 0.45, 0.40$ y 0.40 , respectivamente).

La varianza conjunta explicada por los siete últimos EOFs de MAM suma un 31.8% de la varianza total de los datos, lo que supone un porcentaje no despreciable. Cada modo de variabilidad presenta características espaciales y temporales particulares. El EOF4 en MAM muestra un patrón espacial similar al EOF3 en SON aunque la intensidad de los centros de acción es diferente en cada caso. El EOF5 en MAM, muestra dos regiones con correlaciones negativas, y un núcleo bien definido de correlaciones positiva frente a la costa oeste de Chile y Perú. La serie PC4 asociada presenta una importante tendencia positiva en la segunda mitad del periodo de estudio, mientras que la PC5 muestra una tendencia negativa desde el inicio del registro que se prolonga hasta el año 2000. Los mayores valores de correlación entre estas PCs en MAM y los índices de teleconexión se encuentran para la PC4 con el NAO ($r = -0.5$) y el AO ($r = -0.43$); y para la PC5 con el TNI ($r = -0.43$).

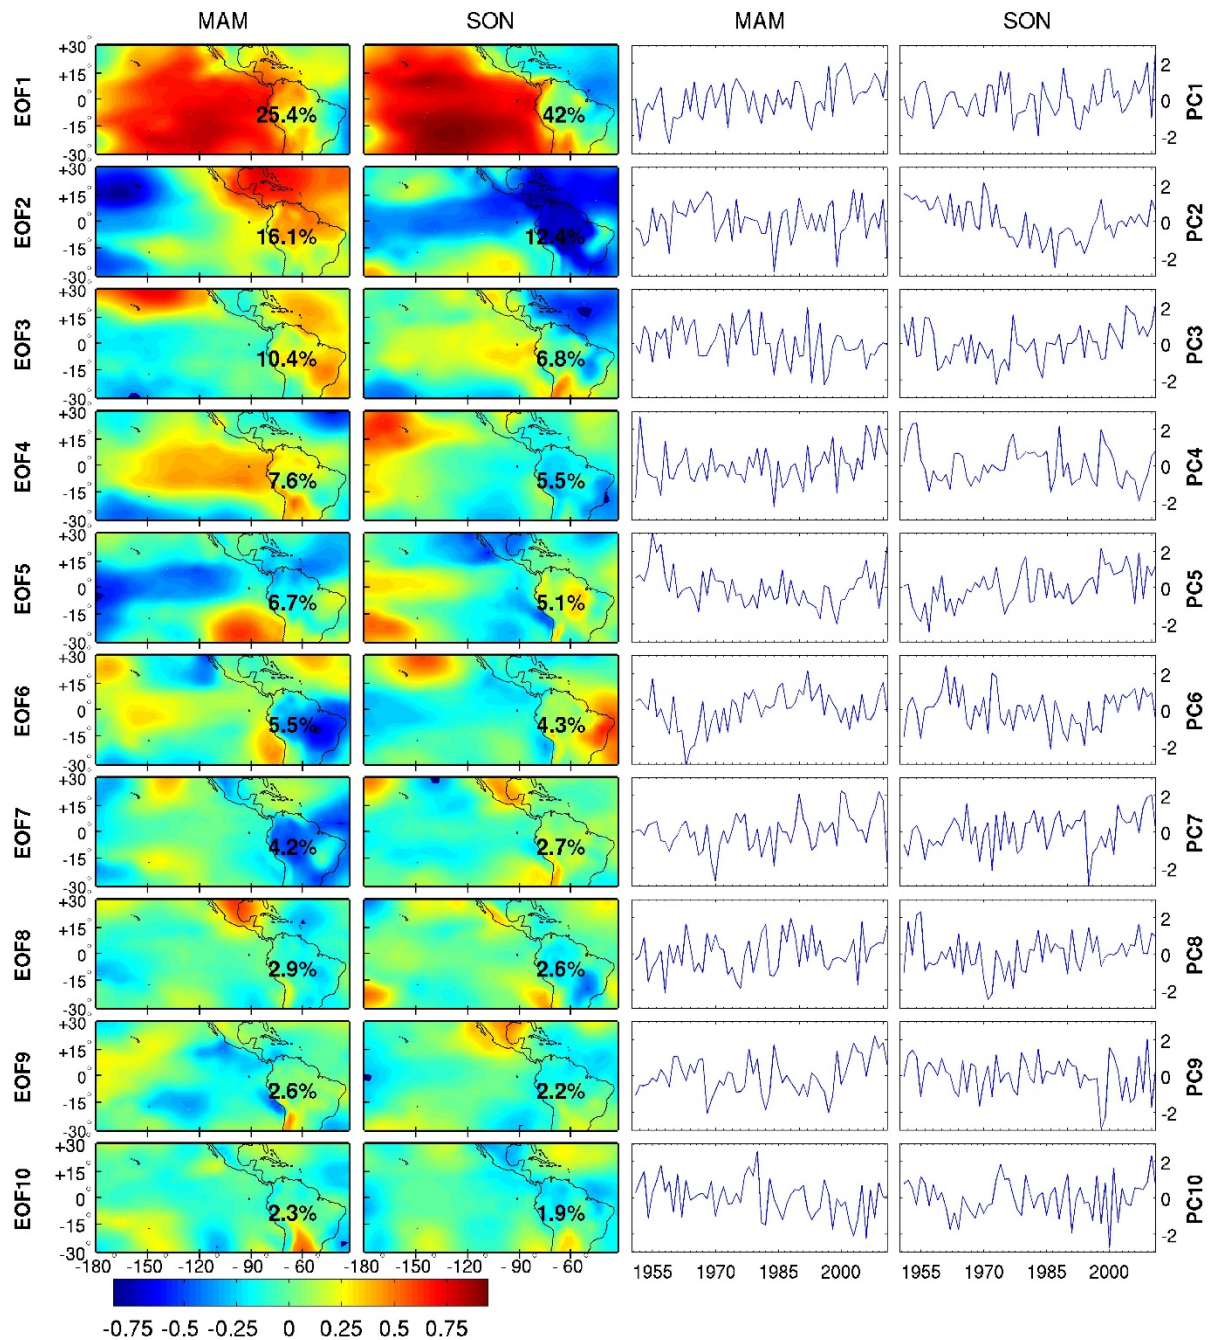


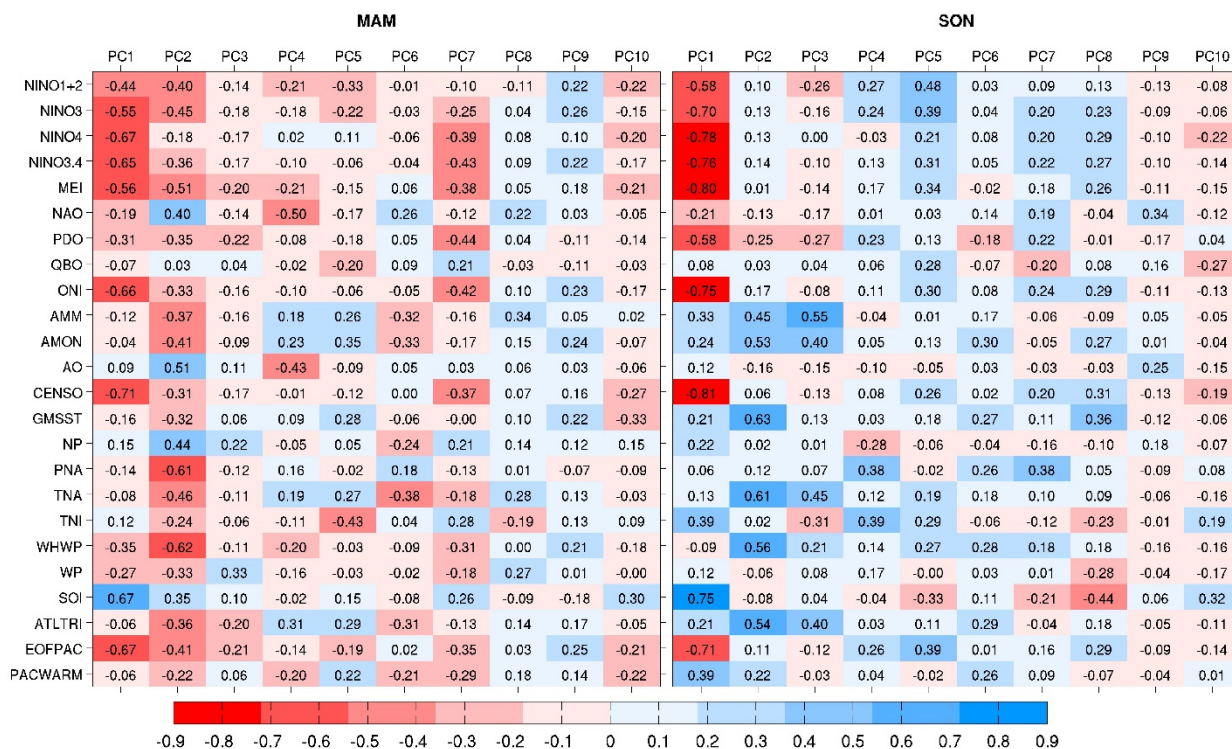
Figura 5.2. Factores de carga para los diez primeros modos de variabilidad obtenidos mediante un PCA de los datos estacionales de primavera (MAM) y otoño (SON) de la SLP del reanálisis del NCEP y sus series PCs correspondientes, en el período 1950-2010.

En los EOF6 y EOF7 en MAM destaca un centro de correlaciones negativas posicionado en sobre la mayor parte de Sudamérica, con gradientes de correlaciones positivos poco definidos. El EOF8 en MAM también muestra un centro de correlaciones positivas importantes sobre México. Los EOF9 y EOF10 en MAM presentan centros de correlación negativa y positiva muy

dispersos. En lo concerniente al grado de relación lineal entre las series PCs normalizadas en primavera y los índices de teleconexión (Tabla 5.2), se evidencia que, en general, los coeficientes de correlación obtenidos para estas últimas PCs tienen valores mucho más moderados. La PC7 presenta las mayores correlaciones, que aparecen con la PDO ($r = -0.44$), el NIÑO3.4 ($r = -0.43$), y el ONI ($r = -0.42$).

Finalmente, los últimos siete modos de variabilidad obtenidos para la SLP de otoño, explican, en conjunto, el 24.3% de la varianza total de los datos. De nuevo, aunque la contribución por separado de estos modos es baja, el conjunto contribuye significativamente. El EOF4 en SON (5.5% de la varianza explicada), muestra un patrón parecido al EOF3 en MAM, aunque los centros de acción se encuentran un poco desplazados y debilitados en la parte atlántica de la región. Algo similar ocurre con el EOF6 en SON y MAM. Los EOF5, EOF7, EOF8, EOF9 y EOF10, se caracterizan por la presencia de gradientes de correlación dispersos, y un poco más débiles, cuyos centros de acción más fuertes se sitúan, en su mayoría, sobre la zona continental. De nuevo aparecen similitudes con los patrones espaciales encontrados en primavera, como las encontradas entre el EOF7 en SON y el EOF8 en MAM, que muestran centros de correlación positivos sobre Centro América y sobre la cordillera de los Andes. En lo relacionado a las series PCs para estos últimos modos en SON, de nuevo se encuentran coeficientes de correlación de valor moderado con los índices de teleconexión (Tabla 5.2). Cabe destacar la PC5 en SON que presenta el coeficiente más alto con el NIÑO1+2 ($r = 0.48$), seguida de la PC8 con el SOI ($r = -0.44$), la PC4 con el índice TNI ($r = 0.39$) y el PNA ($r = 0.38$), y las PC7, PC9, PC10 y PC6 con los índices PNA ($r = 0.38$), NAO ($r = 0.34$), SOI ($r = 0.32$) y AMON ($r = 0.30$), respectivamente.

Tabla 5.2. Coeficientes de correlación lineal entre las PCs de los diez primeros modos de variabilidad de la SLP estacional de primavera (MAM) y otoño (SON) procedentes de los datos de reanálisis del NCEP, con algunos de los principales índices de teleconexión. Los valores significativos al nivel de confianza del 95% se indican con (*).



5.2 Relación entre los modos de variabilidad de la SLP y la precipitación

En este apartado se analiza la relación entre los distintos modos de variabilidad obtenidos para la SLP estacional, mostrados en la Sección 5.1, y la precipitación estacional en la región tropical del continente Americano, mediante un análisis de correlación lineal. Para cada estación del año, se analiza la distribución espacial de los coeficientes de correlación entre los datos de precipitación en rejilla procedentes del GPCC y cada una de series temporales (PCs) asociadas a los diez modos de variabilidad principales de la SLP del NCEP. Además, para evaluar la significación de las correlaciones encontradas se usa la técnica de *bootstrapping* con remplazo, explicada en el Capítulo 3, mostrando los valores de correlación significativos al nivel de confianza del 95% entre la precipitación y las PCs de la SLP estacionales, y se indica el porcentaje de área de América tropical que supera este nivel de significación. En una segunda parte de este apartado, se lleva a cabo un análisis similar para las distintas zonas (ZN1 a ZN10) que se establecieron en el Capítulo 2 (Figura 2.5), utilizando los valores de la precipitación estacional en cada una de ellas.

5.2.1 Resultados para cada punto de rejilla

Invierno

La Figura 5.3 muestra la distribución espacial de los coeficientes de correlación entre la datos de precipitación en rejilla procedentes del GPCC y cada una de series temporales (PCs) asociadas a los diez modos de variabilidad principales de la SLP (a-j) y su significación estadística al nivel de confianza del 95% (k-t), para la estación de invierno.

El mapa de correlaciones de la PC1 en DEF con la precipitación en DEF (Figura 5.3a), está dominado por una amplia banda de correlaciones positivas que arranca desde el suroeste y norte de Brasil y se extiende hasta el norte de Nicaragua. En esta área destacan dos centros principales que presentan los valores más altos de correlación positiva (por encima de 0.6), situados al oeste, norte, y sobre la cordillera de los Andes en Colombia, y otro al norte de Brasil, que alcanza el este de Venezuela, y cubre en su totalidad a Guyana, Surinam y Guayana Francesa. Además, la mayor parte de estas correlaciones positivas son estadísticamente significativas al 95% (Figura 5.3k), lo que muestra la influencia del primer modo de variabilidad de la SLP sobre la precipitación de estas regiones. Adicionalmente, también aparecen correlaciones negativas significativas, con valores de correlación de hasta -0.5 sobre todo México, y un poco más débiles al sureste de Brasil, Uruguay y Paraguay. Dado que, como se vio en el análisis de los modos principales de variabilidad (Sección 5.1), la PC1 está relacionada, fundamentalmente, con el fenómeno ENSO, este resultado indica que existe una clara asociación entre el ENSO y la variabilidad de la precipitación en invierno en la zona de América tropical. Es evidente que este modo de variabilidad de la SLP presenta correlaciones significativas en la mayoría de la región, pero cuando se realiza el re-muestreo (Figura 5.5k), se obtienen correlaciones significativas solo sobre el 40.9%, de la región, siendo esta primera PC de la SLP la que correlaciona más extensamente con la precipitación de la región de estudio.

El siguiente modo de variabilidad de la SLP que presenta mayor porcentaje de área continental con correlaciones significativas con la precipitación, al nivel de confianza del 95%, está asociado a la PC3. El mapa espacial de correlaciones (Figura 5.3c) presenta un patrón parecido, salvo algunas diferencias, al de la PC1 (Figura 5.3a), pero con signos de correlación opuesta. Está caracterizado por la presencia de correlaciones negativas al norte de Sudamérica, que se extienden desde Colombia hasta Guayana Francesa, mientras que las correlaciones

positivas se sitúan en el norte de México, la Península de Yucatán, y centro de Brasil. En conjunto, un 31.1% del área continental de estudio muestra correlaciones significativas (Figura 5.3m). A este modo, le sigue la PC4 (Figura 5.3d y 5.3n), que con un 24.6% del área con correlaciones significativas se caracteriza por la presencia de valores más bajos de correlación y más localizados que en el caso de las anteriores componentes principales, pero que regionalmente presenta correlaciones significativas positivas con la precipitación en Venezuela, Guyana, Surinam y Guayana Francesa, y negativas al noreste de Argentina y en el extremo sur de Brasil.

Adicionalmente, la correlación entre la PC2 de la SLP de invierno y la precipitación en DEF (Figura 5.3b), presenta, de manera general, valores bajos, mostrando solo correlaciones significativas de signo positivo en Florida, algunas islas del Caribe y el oeste de Ecuador; y negativas en Guyana, Surinam y en la desembocadura del río Amazonas al norte de Brasil. Estas zonas representan el 16% área total (Figura 5.3l).

Por otra parte, el resto de PCs de la SLP de invierno (PC5, PC8, PC7, PC10, PC9 y PC6), presentan porcentajes más bajos de áreas con correlaciones significativas (14.7%, 14.7%, 12.4, 11.5%, 10.8% y 8.9%, respectivamente). Cabe destacar las correlaciones entre la PC5 de la SLP y la precipitación (Figura 5.3e y 5.3o), para la que aparecen dos centros de correlación significativos de signos opuestos situados al este de Brasil y sur de Brasil y Paraguay, así como la PC8 (Figura 5.3h y 5.3r), para la que se muestra un extenso centro de correlaciones negativas significativas al este de Brasil. El resto de PCs de la SLP muestran correlaciones débiles con la precipitación, que aunque en algunos casos son significativas, identifican regiones muy localizadas y dispersas sobre el área de estudio.

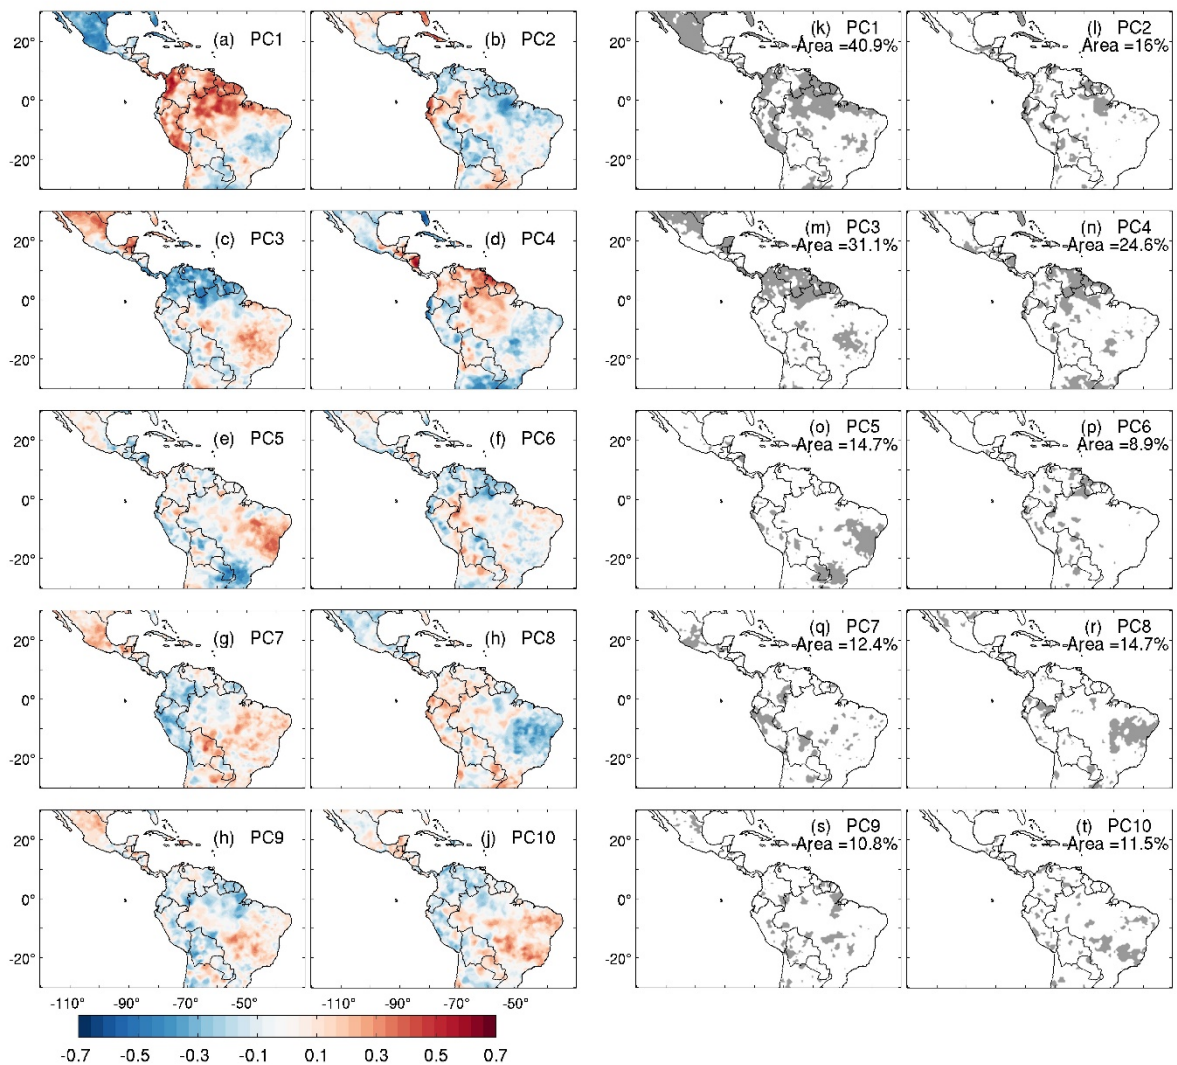


Figura 5.3. (a-j) Patrones espaciales de los coeficientes de correlación entre la precipitación de invierno y las 10 primeras PCs de la SLP en invierno. (k-t) Correlaciones estadísticamente significativas al nivel de confianza del 95% (sombreado gris) y porcentaje de área ocupado por las mismas.

Primavera

Para la primavera, la Figura 5.4 muestra los patrones de correlación obtenidos entre la precipitación y las PCs de la SLP. Destacan los mapas obtenidos para las PCs 4, 1 y 2, que muestran los mayores porcentajes de área con coeficientes de correlación significativos al 95%. La PC4 de la SLP, con un 23.7% de área continental significativa (Figura 5.4d y 5.4n), se caracteriza por la presencia de dos centros de correlación con signos opuestos, uno con valores positivos ocupando gran parte del este de Brasil, y otro con valores negativos más al sur, ocupando los límites entre Brasil y Paraguay. También es posible apreciar zonas muy dispersas con coeficientes de correlación con signos intercalados. Adicionalmente, la PC1 (Figura 5.4a y

5.4k) y la PC2 (Figura 5.4b y 5.4l) de la SLP, con un 17.6% y un 16.7% de porcentajes de áreas con correlaciones significativas, respectivamente, muestran un patrón de correlaciones positivas muy similar y significativas al noreste de Brasil. Para la PC1, este centro de correlaciones se extiende hasta el extremo oeste de Colombia, mientras que para la PC2, presenta una región con valores negativos al oeste de Ecuador y el extremo sureste de Brasil. En el norte, para la PC2, se aprecia un débil gradiente de correlaciones positivas significativas en México.

El resto de componentes también presentan valores de correlación significativos pero espacialmente muy dispersos y localizados en áreas muy pequeñas. Cabe destacar la PC9 (Figura 5.4i y 5.4s), que muestra correlaciones significativas en el centro-oeste y sur de Brasil, y la PC10 (Figura 5.4j y 5.4t) que muestra influencia significativa sobre el noreste de Argentina.

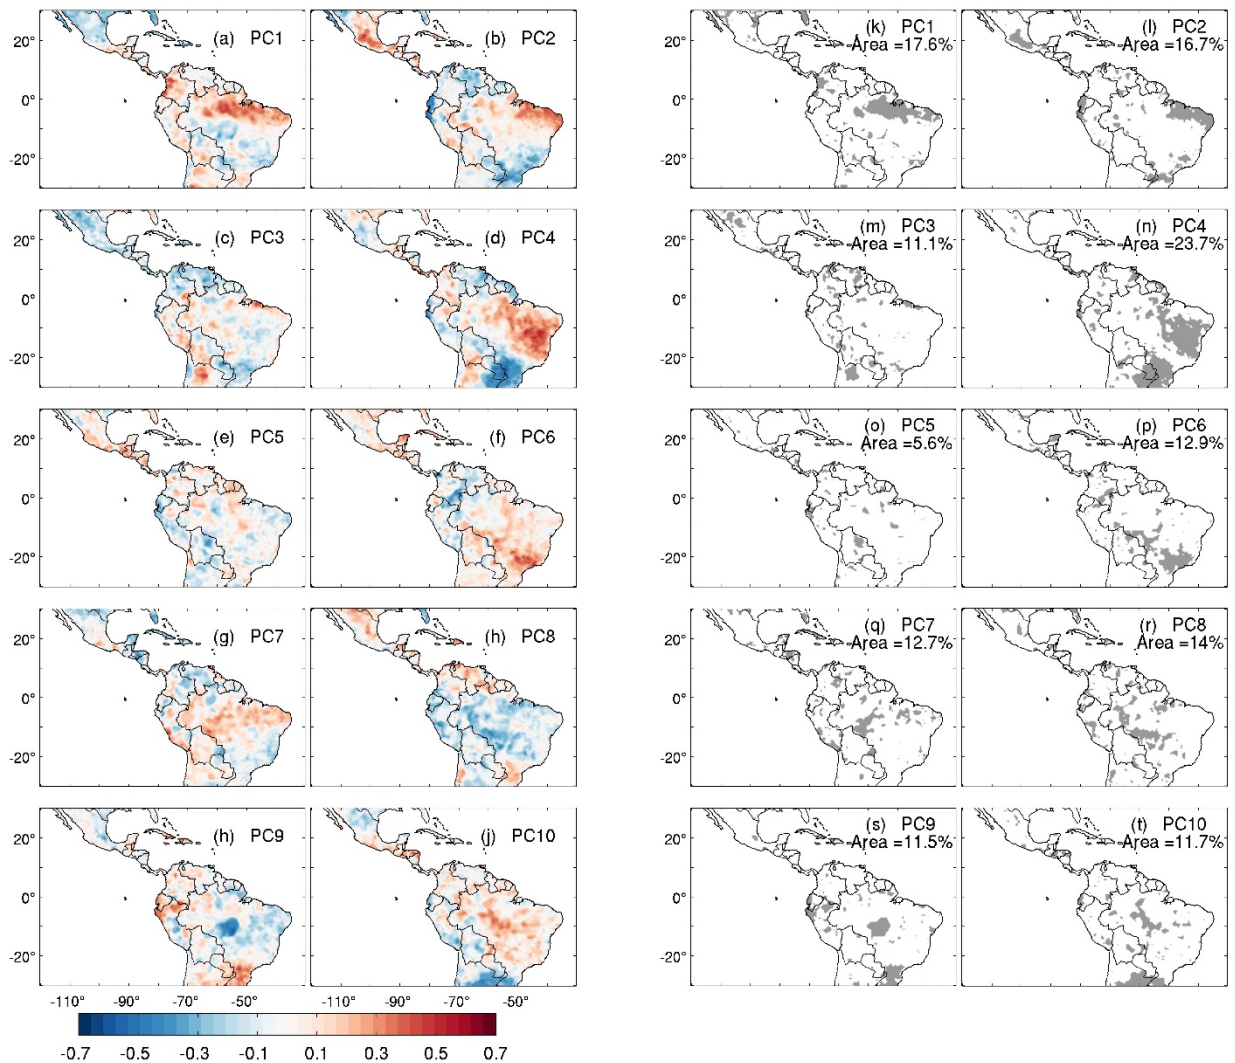


Figura 5.4 (a-j) Patrones espaciales de los coeficientes de correlación entre la precipitación de primavera y las 10 primeras PCs de la SLP en primavera. (k-t) Correlaciones estadísticamente significativas al nivel de confianza del 95% (sombreado gris) y porcentaje de área ocupado por las mismas.

Verano

Los patrones de correlación entre la precipitación y las PCs de la SLP en JJA son mostrados en la Figura 5.5. Hay que destacar que en verano, es la PC5 (Figura 5.5e y 5.5p) la que presenta mayor porcentaje de área correlacionada significativamente (34.6%), presentando un fuerte gradiente de correlaciones negativas que cubre a aproximadamente toda Sudamérica central. Le sigue la PC1 (Figura 5.5a y 5.5k), con un 30.3% de área con correlaciones significativas, unas positivas, que se extienden desde el noroeste, pasando por todo el oeste de centro América, la zona norte y oeste de Colombia, y el extremo norte de Brasil, Guyana, Surinam y Guayana Francesa, y otras negativas localizadas por debajo de los 10°S y con máximos valores concentrados sobre el este de Bolivia, y el suroeste de Brasil.

Otro patrón que presenta un alto porcentaje de correlaciones significativas, aunque más dispersas, es la PC3 (Figura 5.5c y 5.5m), con un 23.4% de área. Este se caracteriza fundamentalmente por la presencia de coeficientes de correlación negativa significativa sobre el sur de Brasil y norte de Argentina. El resto de PCs exhiben patrones de correlación dispersos, aunque significativos para muchas regiones muy localizadas del área de estudio.

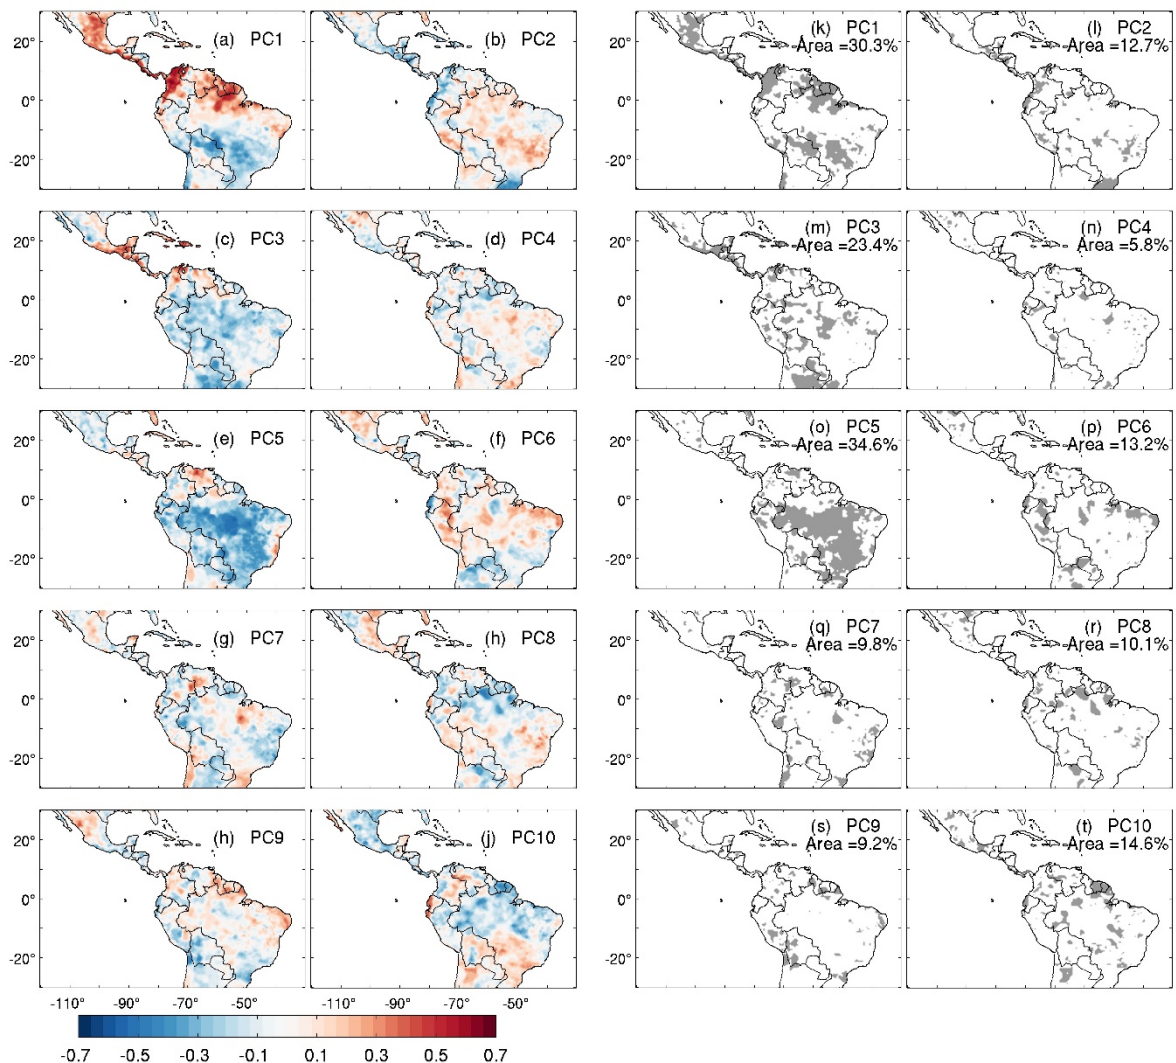


Figura 5.5. (a-j) Patrones espaciales de los coeficientes de correlación entre la precipitación de verano y las 10 primeras PCs de la SLP en verano. (k-t) Correlaciones estadísticamente significativas al nivel de confianza del 95% (sombreado gris) y porcentaje de área ocupado por las mismas.

Otoño

De manera análoga a las estaciones anteriores, la Figura 5.6 muestra los patrones espaciales de los coeficientes de correlación entre la precipitación y las primeras 10 PCs en SON, así como la significación estadística de dichas correlaciones. La PC1 (Figura 5.6a y 5.6k) es la que presenta mayor área significativamente correlacionada (28.4%) con la precipitación, abarcando casi toda la zona del norte de Sudamérica y el oeste de centro América, hasta la Península de Yucatán con valores de correlación positivos. Aparecen correlaciones negativas significativas al noreste de Argentina y sur de Paraguay. Le sigue la PC8 (Figura 5.6h y 5.6r), con un porcentaje de área correlacionada significativamente de 17.1%, y que presenta

nuevamente el dipolo meridional mostrado por la PC4 en MAM pero cambiado de signo, destacándose un fuerte patrón de correlaciones positivas al sur de Brasil y Paraguay, y noreste de Argentina, y correlaciones negativas al este de Brasil. Adicionalmente, aparece otro gradiente de correlaciones positivas al suroeste de Bolivia y Perú. Los patrones de correlación restantes en SON, muestran correlaciones más débiles y una dispersión espacial acusada para aquellas que alcanzan la significación.

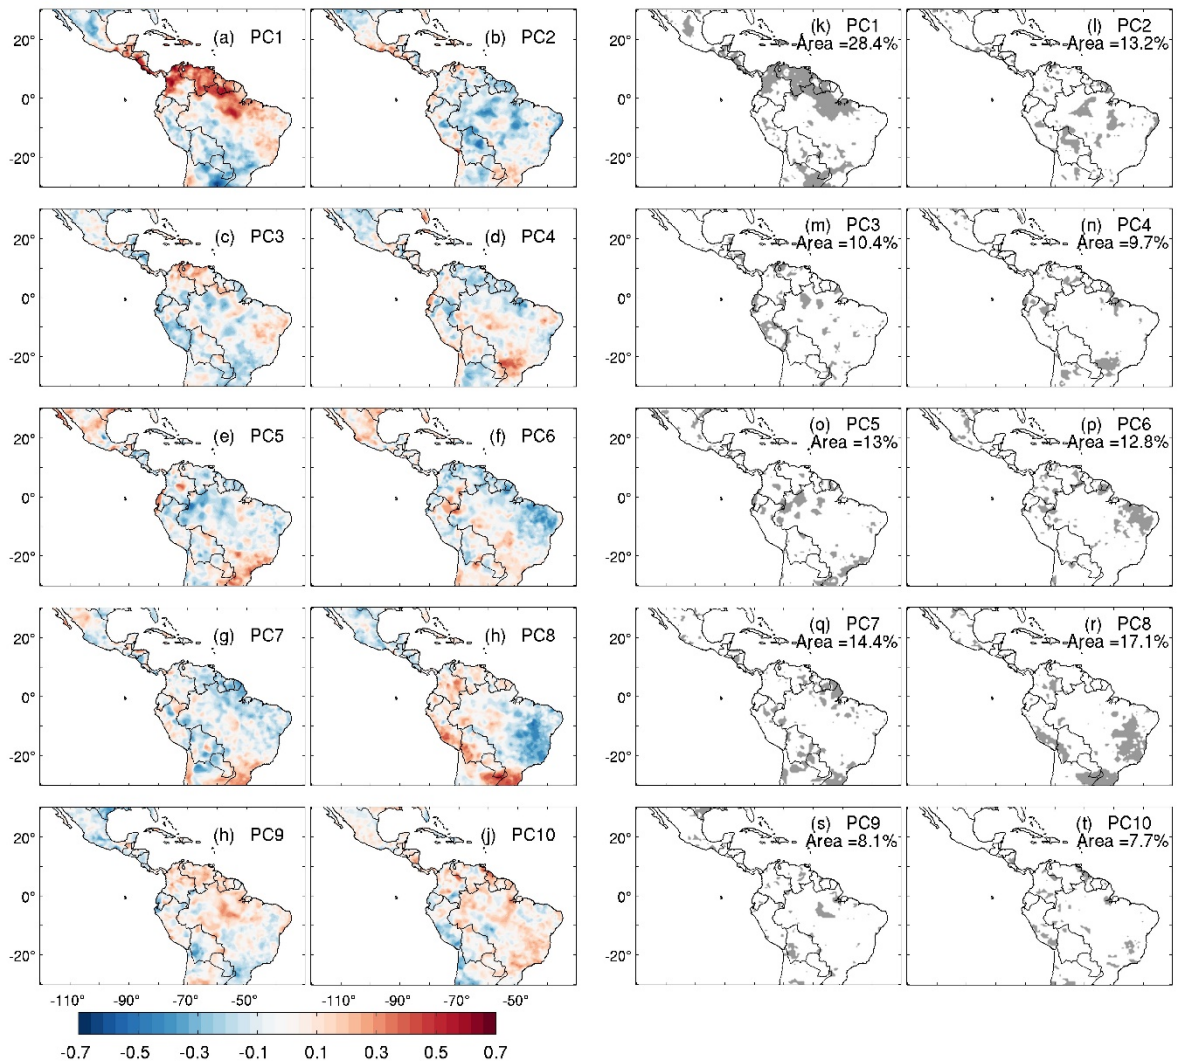


Figura 5.6. (a-j) Patrones espaciales de los coeficientes de correlación entre la precipitación de otoño y las 10 primeras PCs de la SLP en otoño. (k-t) Correlaciones estadísticamente significativas al nivel de confianza del 95% (sombreado gris) y porcentaje de área ocupado por las mismas.

5.2.2 Resultados para cada zona seleccionada

Como se ha comentado al comienzo del apartado 5.2, en este apartado se presentan los resultados obtenidos para las 10 zonas seleccionadas dentro de la región de estudio, cuya localización se mostró en la Figura 2.5. Los coeficientes de correlación entre las series PCs

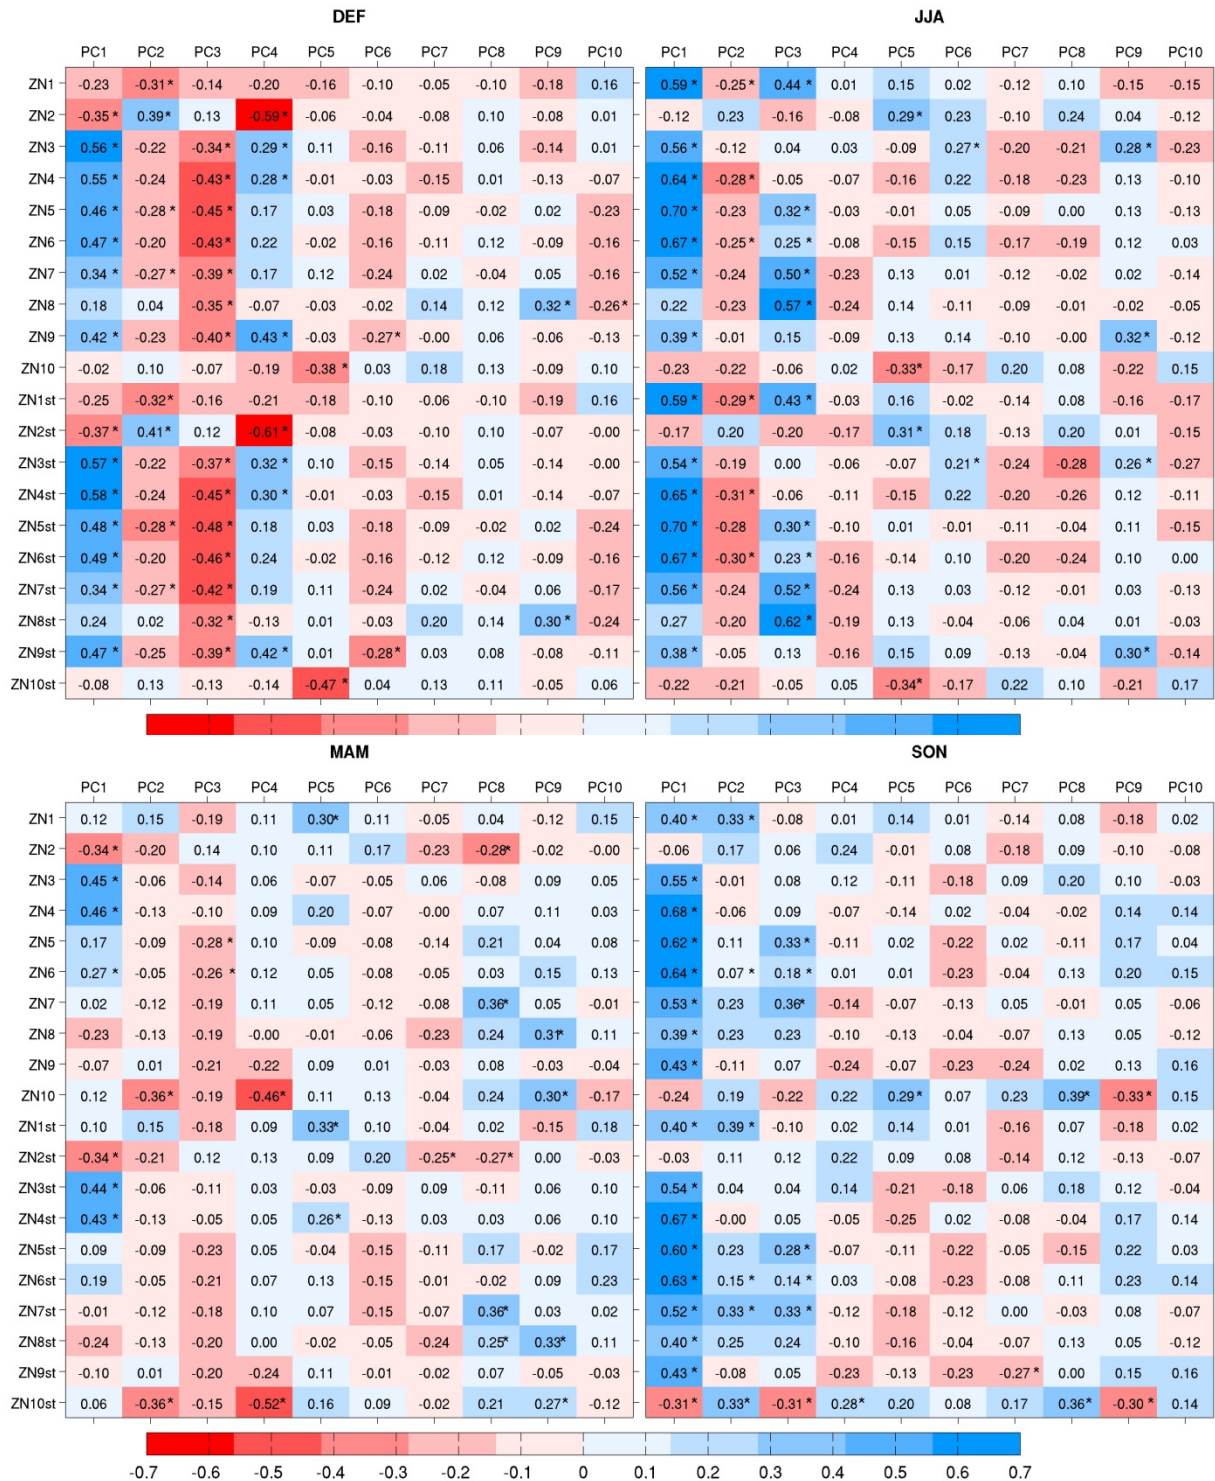
correspondientes a los 10 primeros modos de variabilidad de la SLP y la precipitación estacional regional para cada una de las 10 zonas seleccionadas (ZN1 a ZN10) durante el periodo (1950–2010) se muestran en la Tabla 5.3. Adicionalmente, en la parte inferior de cada panel de la Tabla 5.3, correspondiente a cada estación del año, se muestran los valores de estas correlaciones cuando se han eliminado las tendencias en las series de precipitación regional (ZN1st a ZN10st). Los resultados obtenidos (con y sin tendencias) son muy similares, indicando que las correlaciones obtenidas no están dominadas por la presencia de tendencias lineales. En primer lugar, cabe destacar que, exceptuando la PC7 y 8 en DEF, la 4, 7, 8 y 10 en JJA, y la 6 y 10 en SON, todas las restantes PCs están vinculadas significativamente a una o más de las series regionales de precipitación. Tanto en el análisis con tendencias como sin tendencias, los máximos coeficientes de correlación en DEF y MAM son mayoritariamente capturados por las cuatro primeras PCs, mientras que en JJA y SON lo son por las tres primeras PCs. En el análisis con tendencias, la PC1 recoge los máximos valores en los coeficientes de correlación para la mayoría de las zonas seleccionadas, siendo positivos en un gran número de ellos en las cuatro estaciones y alcanzando su valor máximo ($r = 0.7$) para la ZN5 en JJA. Los resultados también indican que para la PC2 predominan las correlaciones negativas en todas las estaciones, mientras que para la PC3 prevalecen sólo las correlaciones negativas en DEF y MAM y positivas en JJA y SON. El resto de las PCs también presenta altos valores de correlación dependiendo de la zona considerada. También hay que resaltar que aunque DEF no contenga los máximos coeficientes de correlación a nivel regional, esta estación del año sí captura el mayor número de zonas con correlaciones significativas, seguida de JJA, mientras que MAM y SON, presentan el menor número de zonas con correlaciones significativas.

La PC1 asociada al EOF1, caracterizada por un patrón dominante consistente con el fenómeno ENSO, muestra que la región del norte de Colombia (ZN5) en JJA presenta el máximo coeficiente de correlación ($r = 0.7$), seguido por el noroeste de Colombia (ZN4) en SON ($r = 0.68$) y la zona central de Colombia (ZN6) en JJA ($r = 0.67$). La región correspondiente a Florida (ZN2) en MAM y DEF, muestra también un coeficiente de correlación significativo y relativamente alto pero negativo ($r = -0.35$ y -0.34 , respectivamente) con la PC1. Además esta misma región (ZN2) en DEF, junto con la región limítrofe entre Brasil, Argentina y Paraguay (ZN10) en MAM se destacan por presentar los máximos coeficientes de correlación con la PC2. La PC3 en JJA presenta altos coeficientes de correlación positivos ($r > 0.43$), en la región del Caribe (ZN8), el extremo norte entre Venezuela y Colombia (ZN7) y los límites entre Guatemala y el sur de México (ZN1). Mientras que en DEF presenta altas correlaciones negativas ($r < -0.43$)

en las cuatro regiones seleccionadas de Colombia (ZN3, ZN4, ZN5 y ZN6). En DEF, la PC4 también se destaca con altos coeficientes de correlación positivos en el extremo este del norte de Suramérica (ZN9) ($r = 0.43$), y negativos en Florida (ZN2) con ($r = -0.59$). Cabe destacar que, en general los resultados obtenidos para las correlaciones entre la precipitación en las diferentes regiones seleccionadas y las 10 primeras PCs de la SLP, son coherentes con los resultados mostrados en las Figuras 5.3 a 5.6, correspondientes a la Sección 5.2.1, donde se presentan los resultados de las correlaciones para cada punto de rejilla mediante mapas que muestran su distribución espacial en cada estación del año.

Tabla 5.3. Coeficientes de correlación entre las series PCs correspondientes a los 10 primeros modos de variabilidad de la SLP y la precipitación estacional regional (ZN1 a ZN10) o la precipitación estacional sin tendencia (ZN1st a ZN10st), para cada una de las 10 zonas seleccionadas, en el periodo 1950–2010. Los valores significativos al nivel de confianza del 95% se indican en con ().*

5 DOWNSCALING DE LA PRECIPITACIÓN



5.3 Modelos de *downscaling* estadístico para la precipitación

Teniendo en cuenta los resultados presentados en la Sección 5.2, que permiten establecer ciertas vinculaciones entre la SLP y la precipitación, se han usado las series PCs correspondientes a los 10 primeros modos de variabilidad de los datos estacionales de SLP de

reanálisis del NCEP como variables predictoras, y las series de precipitación estacional observada como predictandos, para construir un modelo de *downscaling* estadístico (DS) obtenido por el método de regresión por componentes principales (PCR), siguiendo el método usado en Li and Smith (2009) y Palomino-Lemus et al. (2015). En este apartado se presentan los resultados del modelo obtenido para simular la precipitación estacional durante el periodo 1950-2005. El periodo 1950-1993 ha sido utilizado para calibración y el 1994-2010 para validación. En primer lugar se analizan los resultados obtenidos en cada punto de rejilla de la región de estudio. A continuación, teniendo en cuenta las consideraciones que se hicieron en el Capítulo 2 relativas al establecimiento de 10 zonas climáticas dentro de la región de estudio, se analizan los resultados obtenidos por el modelo DS en cada una de ellas.

5.3.1 Resultados para cada punto de rejilla

En la Figura 5.7 se muestra la distribución espacial de los coeficientes de correlación entre los datos de precipitación observados y los generados con el modelo DS en cada punto de rejilla, para cada estación del año, durante los periodos de calibración (1950-1993) y validación (1994-2010). La validación del modelo revela que la habilidad de la simulación varía considerablemente con la estación del año y la zona considerada. De forma general, en invierno (DEF) y en verano (JJA) el modelo DS proporciona coeficientes de correlación más altos, tanto para el periodo de calibración como para el de validación, que en primavera (MAM) y otoño (SON).

Los coeficientes de correlación más altos ($r > 0.8$) para DEF en el periodo de validación, se observan en el sur de América central, en la región noroccidental de Colombia, noroeste de Ecuador y extremo occidental de Perú. También se identifica otro fuerte núcleo de altas correlaciones que se extiende desde el este de Venezuela y cubre Guyana, Surinam, Guayana Francesa y norte de Brasil. Adicionalmente se encuentran fuertes valores de correlación en zonas más dispersas, como Florida y el extremo sur de la región de estudio, entre los límites de Paraguay, Brasil y Argentina. En cambio, en el periodo de validación, los coeficientes de correlación más bajos se sitúan principalmente desde el sur de México, pasando por la península de Yucatán, hasta Honduras. También se aprecian valores bajos al sureste, de Colombia, centro de Venezuela y sobre gran parte de los países del Hemisferio Sur ubicados en la zona de estudio.

En verano también se identifica una gran extensión con altos valores de correlación ($r > 0.7$), sobre todo en el extremo oeste de la costa centro americana hasta el sur de México, el oeste y norte de Colombia y sobre la costa oeste de Ecuador. Adicionalmente es posible apreciar, otra región con correlaciones superiores a 0.8, al sur de Surinam y Guayana Francesa. En SON también se aprecian zonas con altos valores en los coeficientes de correlación, ubicadas principalmente sobre la región andina de Colombia, norte de Venezuela, la región limítrofe entre Paraguay, Brasil y Argentina, y otra pequeña zona en el límite entre Argentina y Bolivia. Por último, cabe destacar que en primavera es cuando se obtienen los valores más bajos de correlación, de forma que los núcleos de correlaciones más elevadas tienen poca extensión y están dispersos por toda la región de estudio.

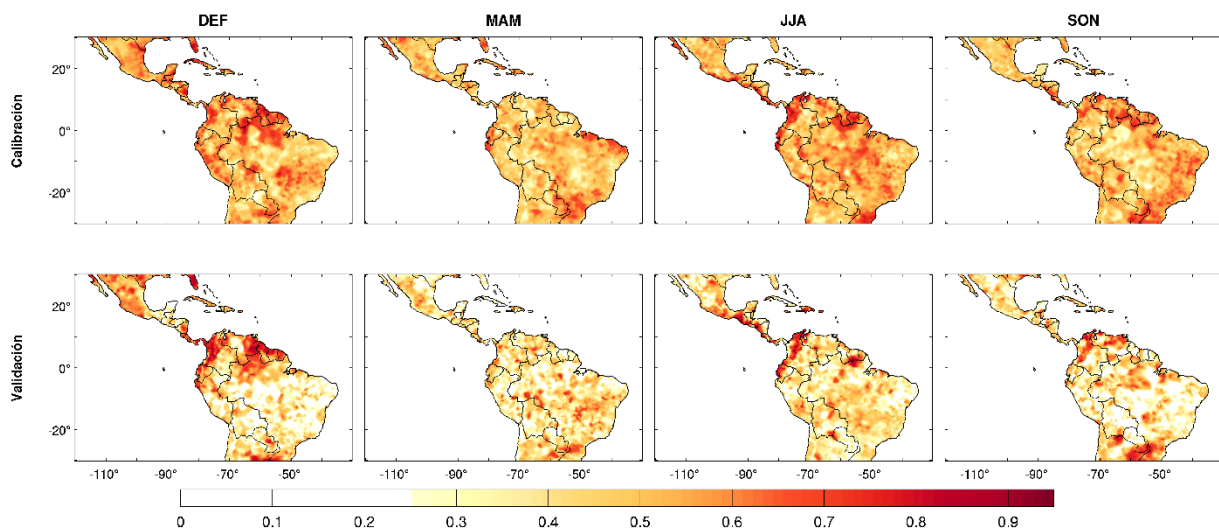


Figura 5.7. Distribución espacial de los coeficientes de correlación entre los valores estacionales de precipitación observados y simulados por el modelo DS para cada punto de rejilla durante los períodos de calibración (1950-1993) y validación (1994-2010).

Para cuantificar las diferencias y evaluar la estabilidad del modelo DS por punto de rejilla, en el presente trabajo se ha utilizado como indicador el porcentaje de la raíz del error cuadrático medio (RMSE). La distribución espacial del porcentaje de RMSE para cada estación del año durante los periodos de calibración y validación se muestra en la Figura 5.8, donde se evidencia que hay una gran similitud entre el periodo de calibración y el de validación. Se observa que hay regiones con errores relativamente grandes en todas las estaciones, sobre Chile, zona costera de Perú, suroeste de Bolivia y, dependiendo de la estación, sobre diferentes extensiones de Brasil (zona muy extensa en verano) y de México (fundamentalmente en invierno

y primavera). De forma general, los errores son más altos en verano y más bajos en invierno sobre la mitad sur de la zona de estudio, mientras que en el extremo norte sucede lo contrario.

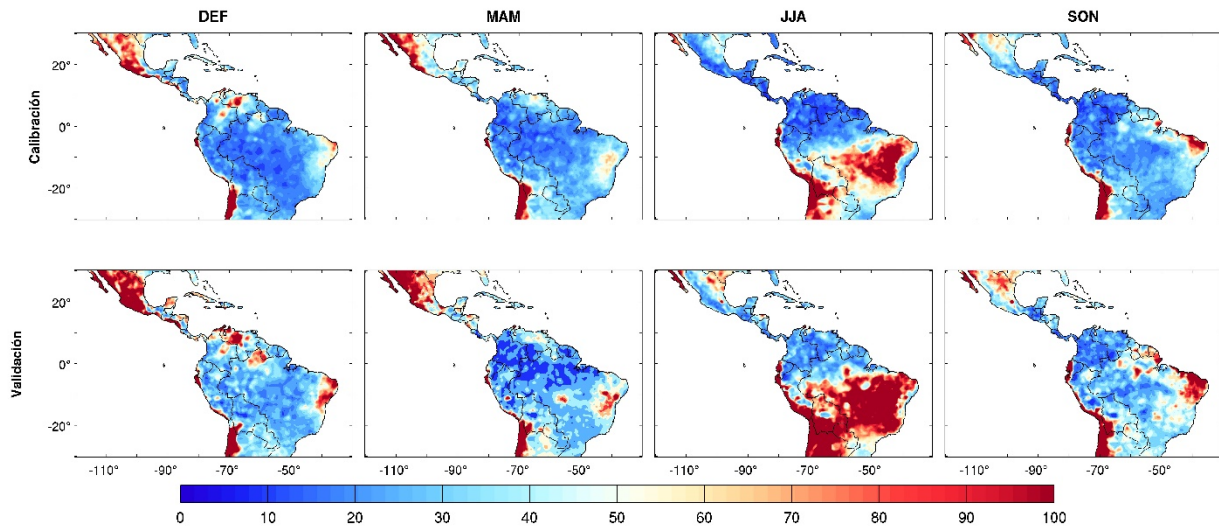


Figura 5.8. Distribución espacial del porcentaje de RMSE entre los valores estacionales de precipitación observados y simulados por el modelo DS para cada punto de rejilla, durante los periodos de calibración (1950-1993) y validación (1994-2010).

Para llevar a cabo una comparación directa entre los valores simulados y observados en cada punto de la rejilla, en la Figura 5.9 se muestra la distribución espacial de la precipitación estacional simulada (mapas del panel superior) y observada (mapas del panel central) durante el periodo de validación (1994-2010), así como la distribución espacial de las diferencias porcentuales entre ambos campos (mapas del panel inferior). Esta comparación pone de manifiesto que el modelo DS proporciona una buena representación de los campos medios de la precipitación estacional. Así, los valores máximos de precipitaciones en la región, que superan los 2.200 mm y se ubican en un área relativamente pequeña al oeste de Colombia, se reproducen adecuadamente en todas las estaciones.

En la Figura 5.9b puede observarse que las diferencias entre los valores simulados y observados son relativamente pequeñas en casi la totalidad de la región de estudio, en todas las estaciones del año. La mayor discrepancia está asociada con las zonas que experimentan extrema sequedad o falta de información, tales como el extremo oeste de Sudamérica, donde se aprecian zonas tanto de subestimación como de sobreestimación en todas las estaciones. Estos resultados son coherentes con los obtenidos por Eden et al. (2012) y Edén y Widmann (2014), quienes encuentran sesgos mayores del 10% en la mayoría de los trópicos y en las zonas donde la calidad

de la red de observación es pobre. En JJA también es posible apreciar que el modelo DS sobreestima sustancialmente la cantidad de lluvias en la zona limítrofe entre Bolivia, Chile, Argentina y Paraguay, además de en una pequeña región en el centro de Brasil (alrededor de los 15°S-45°W). En el extremo noroeste de México se aprecian fuertes sobreestimaciones porcentuales de la precipitación en DEF y MAM, que se debilitan al adentrarse en el país, mientras que en JJA y SON el modelo proporciona una más moderada subestimación (entre 20% y -40%) de la precipitación en esta región.

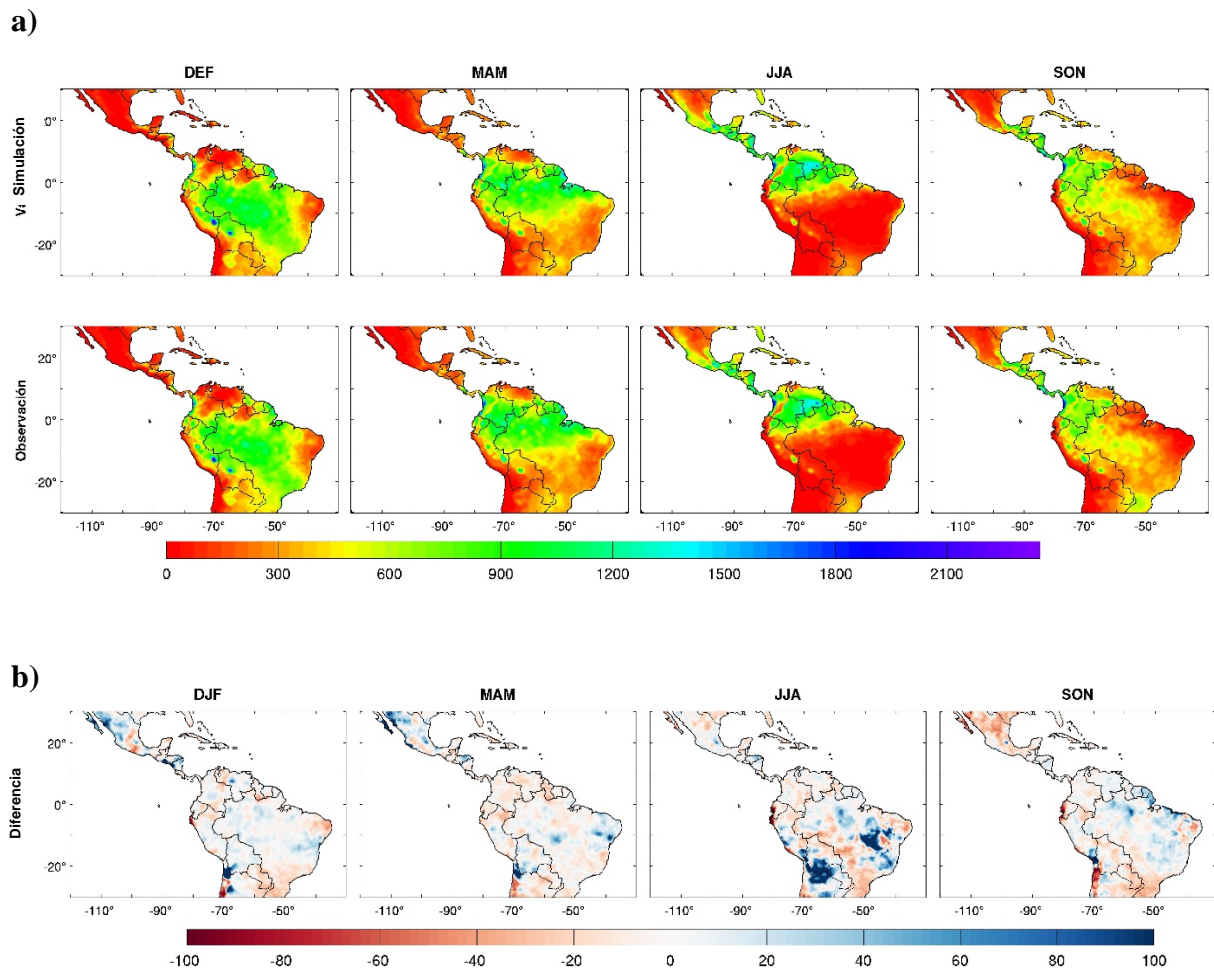


Figura 5.9. a) Distribución espacial de la precipitación estacional (mm) simulada y observada durante el periodo de validación (1994-2010). b) Distribución espacial de la diferencia (%) entre ambos campos.

5.3.2 Resultados para cada zona seleccionada

En este apartado se analizan los resultados obtenidos por el modelo DS para cada una de las zonas seleccionada (ZN1 a ZN10), de forma análoga a lo realizado en el apartado anterior para cada punto de rejilla. Estas zonas, además de su poseer las características comentadas en el

Capítulo 2 (apropiada cobertura de datos coherencia climática), presenta un comportamiento adecuado del DS.

En las Figuras 5.10 y 5.11 se muestran las series de precipitación regional observada y simulada con el modelo DS obtenido en cada una de las 10 zonas seleccionadas, para cada estación del año, durante los periodos de calibración (1950-1993) y validación (1994-2010). En ambas Figuras también se muestran los intervalos de confianza al 95%, obtenidos mediante la técnica de re-muestreo no paramétrica de *bootstrapping* para 1 000 réplicas simuladas por el modelo en cada zona. La Tabla 5.4 resume la habilidad del modelo DS para cada zona, mostrando los coeficientes de correlación (r) así como los porcentajes de RMSE (ρ) entre los valores de la precipitación estacional simulados y observados, tanto en el periodo de calibración como en el de validación. De forma general, los resultados evidencian que la capacidad predictiva de los modelos durante el periodo de calibración se mantiene relativamente bien durante el periodo de validación, aunque cabe añadir que existe una cierta estacionalidad de esta capacidad de predicción de los modelos DS. En la Tabla 5.4 se puede apreciar que en el periodo de calibración, el verano (JJA) es la estación que presenta el mayor número de regiones con altos valores de los coeficientes de correlación, seguida por invierno (DEF) y otoño (SON); en primavera (MAM) es cuando se encuentran los más bajos coeficientes de correlación entre la precipitación simulada y observada regionalmente. Este mismo patrón de ordenamiento se ve reflejado en el periodo de validación con excepciones en algunas regiones. Los valores de los coeficientes de correlación entre la precipitación regional estacional simulada y observada para las estaciones de DEF, MAM, JJA y SON, en el periodo de calibración oscilan entre 0.77 y 0.56, 0.70 y 0.34, 0.85 y 0.56, y 0.76 y 0.58, respectivamente, mientras que en el periodo de validación varían entre 0.90 y 0.10, 0.71 y -0.17, 0.91 y 0.28, y 0.84 y -0.14.

Tabla 5.4. Coeficientes de correlación (r) y porcentajes de RMSE (ρ) entre los valores de la precipitación estacional simulados y observados en cada una de la regiones seleccionadas durante los periodos de calibración (1950-1993) y validación (1994-2010).

		Periodo de calibración				Periodo de validación			
		DEF	MAM	JJA	SON	DEF	MAM	JJA	SON
r	ZN1	0.56	0.34	0.75	0.58	0.10	0.20	0.88	0.46
	ZN2	0.75	0.68	0.56	0.61	0.87	0.22	0.39	-0.14
	ZN3	0.73	0.46	0.82	0.72	0.83	0.48	0.55	0.61
	ZN4	0.77	0.42	0.85	0.76	0.84	0.65	0.78	0.57
	ZN5	0.69	0.42	0.82	0.70	0.81	0.30	0.88	0.82
	ZN6	0.65	0.43	0.73	0.74	0.88	0.23	0.91	0.70
	ZN7	0.71	0.46	0.79	0.68	0.48	0.39	0.82	0.70
	ZN8	0.60	0.61	0.63	0.65	0.58	-0.17	0.88	0.44
	ZN9	0.74	0.53	0.62	0.71	0.90	0.03	0.42	0.34
	ZN10	0.61	0.70	0.62	0.74	0.35	0.71	0.28	0.84
ρ (%)	ZN1	44.36	24.28	13.97	12.98	51.46	38.19	16.87	14.19
	ZN2	34.85	35.31	15.97	27.54	54.49	57.24	26.54	42.62
	ZN3	15.55	11.16	13.58	11.33	18.65	12.93	17.35	15.66
	ZN4	20.18	10.94	13.48	9.74	25.78	13.98	13.24	13.94
	ZN5	37.31	20.73	12.92	13.86	41.41	19.89	16.08	15.09
	ZN6	28.60	12.44	9.52	9.47	25.51	14.72	10.41	12.72
	ZN7	42.68	35.38	36.14	28.58	97.96	40.18	36.94	26.92
	ZN8	32.66	26.95	19.71	19.38	21.08	36.92	18.86	33.46
	ZN9	30.82	33.17	12.78	18.96	35.88	42.99	19.76	27.72
	ZN10	17.93	30.57	37.88	24.59	36.44	31.48	44.52	41.72

La comparación de los resultados obtenidos en el periodo de calibración frente a los correspondientes a la misma estación del año y zona en el periodo de validación, indica que la habilidad de los modelos varía considerablemente de una región a otra. En DEF, la habilidad aumenta considerablemente en la región central de Colombia (ZN6) pasando de un $r = 0.65$ y $\rho = 28.60\%$, en el periodo de calibración, a $r = 0.88$ y $\rho = 25.51\%$ en el periodo de validación; también ocurre así en la zona limítrofe entre Venezuela y Guyana (ZN9) pasando de $r = 0.74$ a $r = 0.90$, aunque aquí el error aumenta de $\rho = 30.82\%$ a $\rho = 35.88\%$. Por el contrario, en el límite entre Guatemala y sur de México (ZN1) se obtiene la mayor pérdida de la habilidad predictiva del modelo DS, pasando de $r = 0.56$ y $\rho = 44.36\%$ a $r = 0.10$ y $\rho = 51.46\%$ para DEF. En MAM, en la región limítrofe entre Brasil, Argentina y Paraguay (ZN10) el modelo DS mantiene casi invariante sus habilidades para el periodo de calibración y validación (pasando de $r = 0.70$ y $\rho = 30.57\%$, a $r = 0.71$ y $\rho = 31.48\%$), mientras que en la región del noroeste de Colombia (ZN4), se mejora notablemente su rendimiento (pasando de $r = 0.42$ a $r = 0.65$, y aunque el error aumenta ligeramente de $\rho = 10.94\%$ a $\rho = 13.98\%$, manteniéndose bajo en ambos periodos). En JJA, un

gran número de regiones muestran altos valores de los coeficientes de correlación en el periodo de calibración ($r > 0.56$) y aunque algunas disminuyen, otras mejoran significativamente los valores de r en el periodo de validación, destacándose la región correspondiente al centro de Colombia (ZN6), que pasa de $r = 0.73$ y $\rho = 9.52\%$ a $r = 0.91$ y $\rho = 10.41\%$. En SON aunque en algunas regiones empeora considerablemente la habilidad del modelo DS en el periodo de validación, como en Florida (ZN2) y en la zona limítrofe entre Venezuela y Guyana (ZN9), destaca la mejora del modelo DS en el norte de Colombia (ZN5) (que pasa de $r = 0.70$ y $\rho = 13.86\%$ en el periodo de calibración, a $r = 0.81$ y $\rho = 15.09\%$ en el de validación).

La comparación entre las series temporales, mostradas en las Figura 5.10 y 5.11 pone de manifiesto los resultados ya comentados en términos cuantitativos, como es la habilidad del modelo DS para simular la precipitación en la región ZN1 en la estación más lluviosa JJA ($r = 0.88$ para el periodo de validación) y más moderada en SON ($r = 0.46$ para el periodo de validación), como puede apreciarse en la Figura 5.13c y 5.13d, con bajos porcentajes de error (16.87% y 14.19%, respectivamente, Tabla 5.4). La serie temporal de precipitación simulada por el modelo DS para la zona de Florida (ZN2, Figura 5.13e) presenta los mejores resultados en la estación de DEF a la hora de capturar la variabilidad temporal de la serie ($r = 0.87$, Tabla 5.4), aunque el error es considerablemente alto ($\rho = 54.49\%$, Tabla 5.4), por lo que no es capaz de representar los picos extremos de la serie observada.

Para la región ubicada al noroeste de Sudamérica, correspondiente a las zonas ZN3, ZN4, ZN5 y ZN6, los mejores resultados de la habilidad del modelo para reproducir la variabilidad interanual de la precipitación estacional, se obtienen en la estación seca (DEF, Figura 5.10i, m, q, y Figura 5.11a) y húmeda (JJA y SON, Figura 5.10k, l, o, p, s, t, y Figura 5.11c y d). Los picos de precipitación observados en el periodo de validación son mejor representados en JJA y DEF, y ligeramente subestimados (aproximadamente en un 3 %) en SON. En estas regiones las estaciones de JJA y SON, presentan en promedio los porcentajes de RMSE más bajos, mientras que estos errores aumentan considerablemente en DEF. De forma global, teniendo en cuenta el intervalo de confianza generado, cabe decir que en la región del noroeste de Sudamérica (ZN3, ZN4, ZN5 y ZN6) el rendimiento del modelo DS resulta satisfactorio para la simulación de la variabilidad estacional de la precipitación, y es capaz de simular los años más húmedos y secos, en las tres estaciones. Sin embargo, se encuentran algunas excepciones (años 2004-2005, Figura 5.10k y año 2000, Figuras 5.10m, 5.10q y 5.11a), en donde los picos de precipitación observada superan el intervalo de confianza estimado.

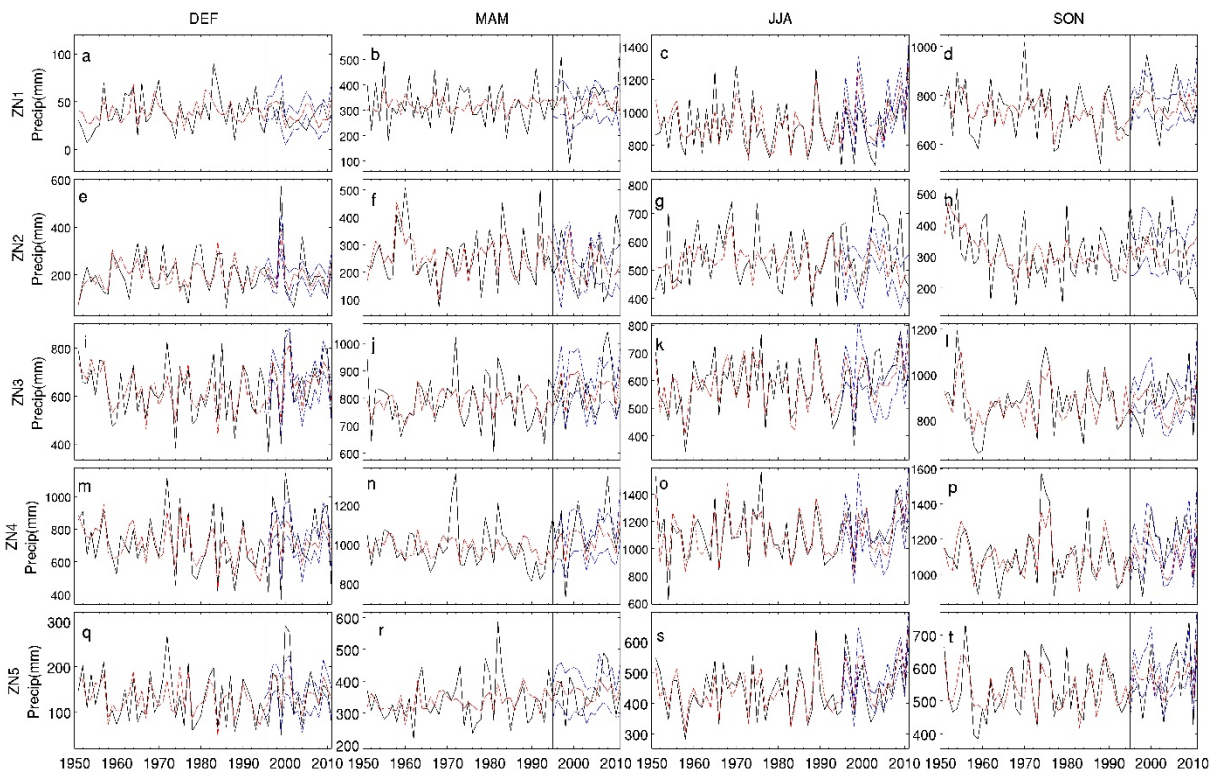


Figura 5.10. Comparación entre los valores de precipitación observados (en negro) y simulados (en rojo) para las regiones ZN1 a ZN5 durante los periodos de calibración (1950-1993) y validación (1994-2010). Las líneas azules discontinuas representan los intervalos de confianza al 95% de 1000 réplicas obtenidas por el modelo DS en cada zona.

Los resultados del modelo DS, para la región correspondiente al extremo norte en los límites entre Venezuela y Colombia (ZN7), también son relativamente satisfactorios tanto en JJA como en SON (Figura 5.11g y h), mientras que en MAM y, especialmente en DEF, se obtienen altos porcentajes de error tanto durante el periodo de calibración ($\rho = 35.38\%$ y 42.68% , respectivamente, Tabla 5.4) como, especialmente, en el de validación ($\rho = 140.18\%$ y 97.96% , respectivamente, Tabla 5.4). Cabe concluir que en esta región el modelo DS es capaz de representar la variabilidad estacional de la precipitación, con una ligera sobrestimación de la precipitación en JJA (Figura 5.11g), y subestimación en SON (Figura 5.11h). En la región del Caribe (ZN8), solo destacan los resultados obtenidos en JJA (Figura 5.14k) con $r = 0.88$ y $\rho = 18.86\%$ (Tabla 5.4). En los límites entre Venezuela y Guayana (ZN9), se obtienen buenos resultados para la simulación de la precipitación en DEF (Fig. 5.11m), con $r = 0.9$, aunque con errores relativamente altos ($\rho = 35.88\%$). Finalmente, en los límites de Brasil, Argentina y Paraguay (ZN10), la precipitación se simula con una mayor habilidad por el modelo DS en las estaciones de MAM y SON (Fig. 5.11r-5.11t), para las que se obtienen coeficientes de

correlación en el periodo de validación de 0.71 y 0.84, r respectivamente, aunque el modelo subestima la precipitación total en otoño.

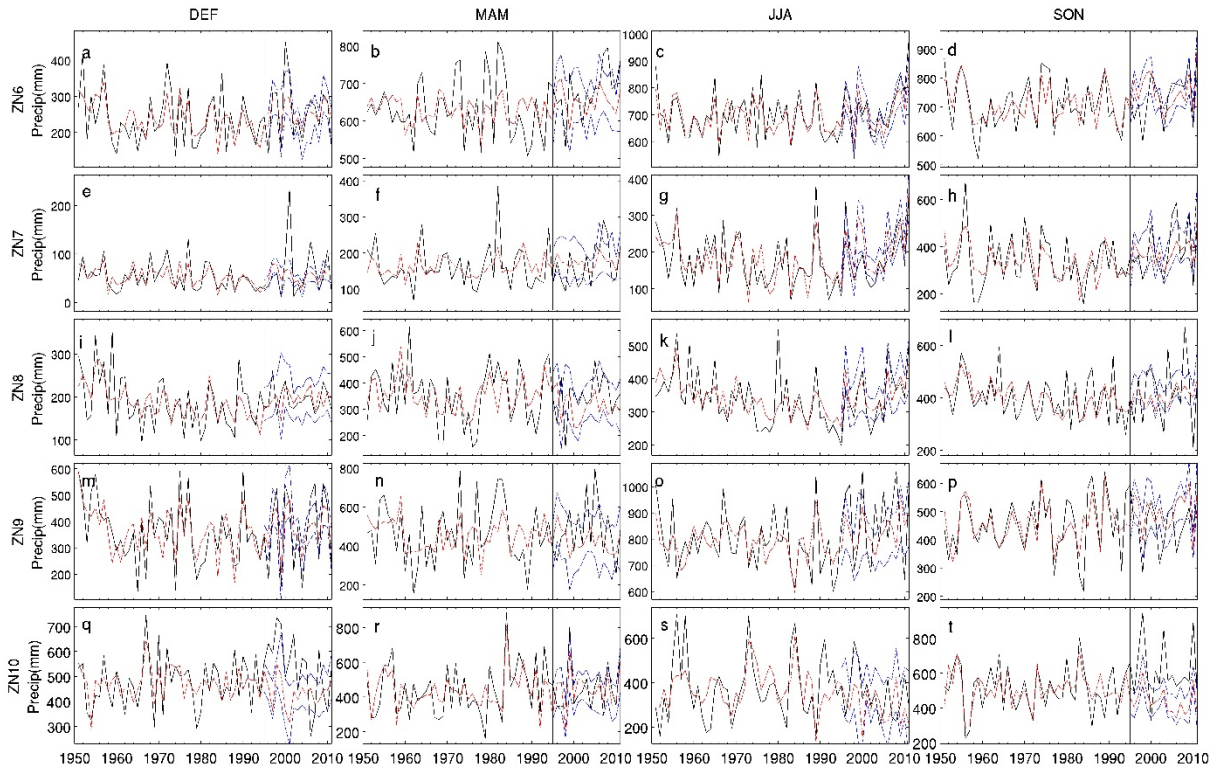


Figura 5.11 Como en la Figura 5.10 pero para las regiones ZN6 a ZN10.

5.4 Conclusiones

En este Capítulo se ha desarrollado el modelo de DS de la precipitación mediante PCR usando como predictores las series PCs de la SLP de los datos del NCEP. Estos predictores se han seleccionado de forma rigurosa en función de la significación de su correlación con la precipitación. Así, los modos de variabilidad ligados al fenómeno ENSO pueden describir forma satisfactoria la precipitación de diversas áreas de Sudamérica (Barros et al., 2000, Grimm et al., 2002, Tedeschi et al., 2013, Córdoba-Machado et al., 2015a, b). Estos últimos autores han mostrado que para el caso de la precipitación de Colombia, variabilidad del Pacífico tropical incluida en El Niño y en El Niño Modoki es suficiente para reproducir y predecir la precipitación estacional. Estos modos conducen la variabilidad de la precipitación en gran parte de la región, mediante su influencia en la circulación de Walker, cuyas variaciones son reflejadas en la SLP, quedando particularmente asociadas a la PC1. Además, otros patrones asociados a la variabilidad de la SLP sobre el continente americano y sobre el Atlántico tropical también ayudan en la

descripción del comportamiento de la precipitación en diversas áreas (por ejemplo el Alta de Panamá, baja del noreste de Brasil). Sin embargo, aunque algunas de las series PCs reflejan la influencia de ciertos patrones atlánticos extratropicales, patrones como la NAO o la SAM, estos están representados de forma limitada dada la cobertura espacial de la SLP analizada. Es posible por tanto, que la ampliación del área de estudio de la SLP pueda mejorar la configuración de predictores en un modelo DS para la precipitación en ciertas zonas.

En general, el DS muestra un funcionamiento adecuado en extensas áreas dentro del dominio analizado, más reducidas cuando se analiza el periodo de validación. Esto puede ser debido a la peor cobertura de datos en el GPCC en determinadas áreas (por ejemplo, áreas selváticas del Amazonas y Orinoco, y Andes) y, en particular en los últimos años (Capítulo 2, Figura 2.4). Cabe también señalar que el modelo muestra una habilidad en la reproducción de la precipitación más modesta durante la primavera, tanto en el periodo de calibración como de validación, lo cual puede estar relacionado con modulaciones de los patrones atmosféricos asociadas al paso de la Zona de Convergencia Intertropical (ITCZ) (Souza and Cavalcanti, 2009).

Aun así el modelo reproduce de forma muy adecuada las características del campo medio de precipitación para todas las estaciones del año. En general, las mayores discrepancias y errores tienden a presentarse en áreas y épocas con una precipitación muy baja como, por ejemplo, este de los Andes, noroeste de México y sur de Bolivia, en las que elevados cambios en porcentaje implican, sin embargo, variaciones pequeñas en valor absoluto.

Adicionalmente, se ha desarrollado el modelo DS para 10 zonas en las que existe una aceptable cobertura de datos, poseen características climáticas bien definidas y se hallan en áreas donde el DS realizado en cada punto de rejilla funciona adecuadamente. Los resultados obtenidos para estas zonas muestran una buena habilidad de l DS, particularmente para las estaciones de invierno y verano, siendo más moderada para el otoño y sobre todo, en primavera. Incluso para algunas zonas, el DS llega a simular valores extremos de la precipitación. De nuevo, para algunas zonas, las estimaciones del DS para el periodo de validación son algo peores, lo cual puede estar relacionado de nuevo con un descenso en el número de estaciones de medida incluidas en el GPCC en los últimos años.

Por tanto como consideración final, el modelo DS obtenido es capaz de reproducir adecuadamente la precipitación en gran parte de la zona de estudio. Este modelo será el empleado en el Capítulo 6 para obtener las proyecciones de la precipitación ante diversos escenarios de cambio climático en el futuro.

CAPÍTULO 6

PROYECCIONES DE LA PRECIPITACIÓN EN ESCENARIOS DE CAMBIO CLIMÁTICO

En este capítulo se analizan los resultados de los modelos de *downscaling estadístico* en la obtención de las proyecciones futuras de la precipitación (para la treintena 2071-2100) para la región de América tropical, utilizando las simulaciones de la SLP de 20 GCMs del CMIP5, para los experimentos históricos, y las trayectorias de representación representativas RCP2.6, RCP4.5 y RCP8.5, comparándolos con los cambios de la precipitación proyectados directamente por los GCMs. Los niveles de confianza del 95% para las cantidades de precipitación obtenidas mediante DS se basan en 1000 muestras *bootstrap* con la sustitución. Además los niveles de confianza para la diferencia en la precipitación en el futuro y período actual) es estimado en base a la prueba de suma de rangos de Wilcoxon-Mann-Whitney, por punto de rejilla y para las 10 zonas seleccionadas previamente.

La producción de estimaciones fiables de los cambios en las precipitaciones a escala local y regional sigue siendo un reto importante en la ciencia del clima. Es aquí donde los métodos de regionalización estadística se utilizan a menudo para reducir la brecha entre la baja resolución de los GCMs y la información en alta resolución, que es la requerida en muchos estudios.

Por otro lado, cuando no se logra entender completamente las limitaciones habilidad del GCM, para reproducir la precipitación, los métodos de downscaling estadístico se convierte en una herramienta que adopta un enfoque de prognosis perfecta (perfect prog, Maraun et al., 2010), en el que las proyecciones de la precipitación de alta resolución se basan en relaciones estadísticas del mundo real entre predictores atmosféricos a gran escala y, por ejemplo, las precipitaciones a escala local. Por lo tanto el análisis de las simulaciones históricas del conjunto de modelos climáticos usados permitirá una mejor interpretación de los cambios proyectados en las simulaciones del clima futuro. Pero antes de que pueda ser aplicado para proyectar el cambio climático futuro de las tres últimas décadas del siglo XXI (2071-2100), debe realizarse una evaluación de la capacidad del modelo para reproducir el clima presente; por lo tanto en la primera fase de este capítulo se validan los resultados de downscaling obtenidos mediante el modelo DS (obtenido en el capítulo anterior) aplicados a las salidas de las simulaciones históricas de la SLP de 20 modelos del CMIP5 en las últimas tres décadas del siglo XX (1971-2000).

6.1 Downscaling de la precipitación en clima presente

En el capítulo anterior, se obtuvieron los modelos de DS de la precipitación a partir de la aplicación de la RCP usando el periodo 1950-93 para la calibración de los mismos, y el periodo 1994-2010 para su validación. Adicionalmente, con el fin de incluir toda la información disponible, los modelos se ha recalibrado para el periodo completo de datos observacionales, tanto de la SLP como de la precipitación, 1950-2010. En la Figura 6.1, se muestra la distribución espacial de los coeficientes de correlación entre los datos de precipitación observados y los generados con el modelo DS, durante el periodo de recalibración, así como con los estimados por el modelo DS en el periodo 1971-2000, que será empleado como referencia para caracterizar la precipitación en clima presente. Tanto para el periodo de calibración 1950-1993 (Figura 5.9) y de recalibración 1950-2010 (Figura 6.1), el modelo DS muestra el mismo patrón de distribución espacial de los coeficientes de correlación, mientras que en el periodo de 1971-2000, es evidente un descenso en los coeficientes de correlación en ciertas áreas relativamente extensas, junto con áreas más limitadas y dispersas donde mejora la correlación, pero manteniéndose en esencial la misma configuración espacial de la correlación. Una mayor habilidad de predicción de la precipitación por el modelo DS se tiene para las estaciones de D EF y J JA respecto a las estaciones de MAM y SON.

Las estaciones de DEF y JJA, muestran un patrón de correlaciones similar con máximo valor en los coeficientes de correlación ($r > 0.8$), que se sitúan principalmente sobre el extremo norte, noroeste de Suramérica y al oeste de Centroamérica, en el periodo de 1971-2000 (Fig. 6.1). Se identifican elevados coeficientes de correlación tanto en DEF como en JJA sobre el Pacífico colombiano, los cuales se extiende sobre toda la cordillera hasta el extremo norte de Colombia. En DEF y JJA también se muestran fuertes correlaciones sobre Guyana, Surinam y Guayana Francesa, el norte de Brasil, y el este de Venezuela. Adicionalmente se encuentran correlaciones altas en zonas más dispersas, como en Florida (sur de Estados Unidos) y el extremo sur de América del sur, entre los límites de Paraguay, Brasil y Argentina, de forma muy similar a las del periodo de validación. Por otro lado, para las estaciones de MAM y SON también se identifican zonas con elevados valores de correlación ($r > 0.7$), sobre todo en la región limítrofe entre Paraguay, Brasil y Argentina, y el extremo oeste de Ecuador.

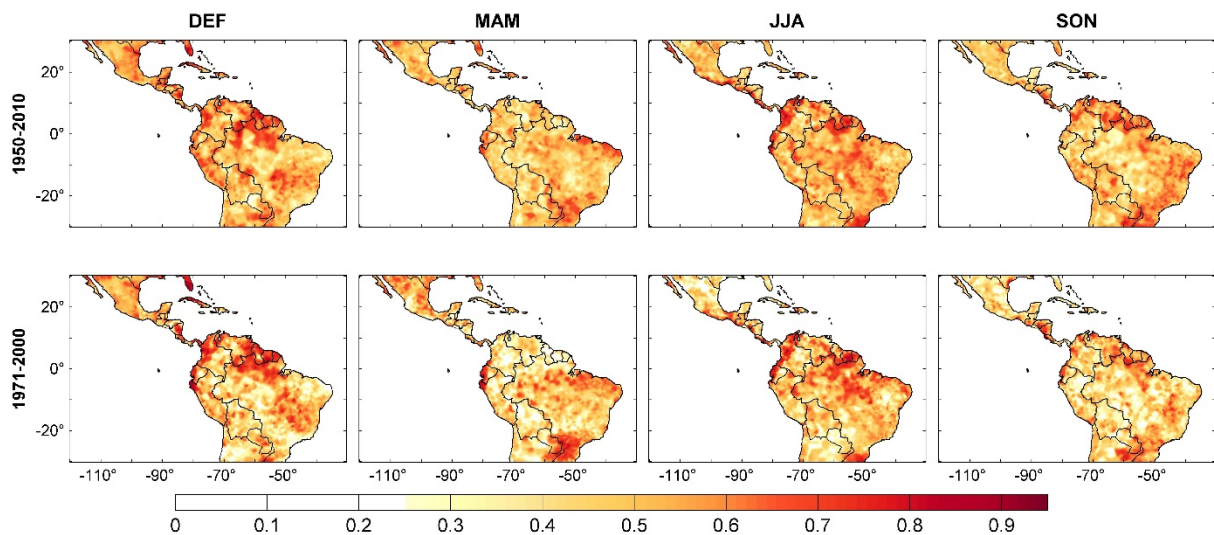


Figura 6.1. Distribución espacial de los coeficientes de correlación entre los valores observados y predichos por los modelos DS, para la precipitación estacional por punto de rejilla en las estaciones DEF, MAM, JJA Y SON, durante los periodos de recalibración 1950-2010 y 1971-2000.

En la Figura 6.2, se muestran las diferencias porcentuales respecto a la media entre los valores observados del GPCC y los resultados del modelo DS con la SLP a nivel estacional en el periodo de 1971-2000. Las diferencias en los patrones espaciales de la precipitación estacional media son algo mayores en DEF, en comparación con las otras tres estaciones, con porcentajes de sobreestimación de la precipitación superiores al 100% al sur de la área sobre los Andes, y subestimaciones del alrededor del 20% al norte de Chile y sobre México. En las estaciones de MAM, JJA y SON sólo es posible apreciar subestimaciones del 20% sobre el norte de Chile,

mientras que en el resto de las estaciones el modelo muestra una extraordinaria habilidad de predicción con diferencias porcentajes que no superan el 5%, en el periodo 1971-2000.

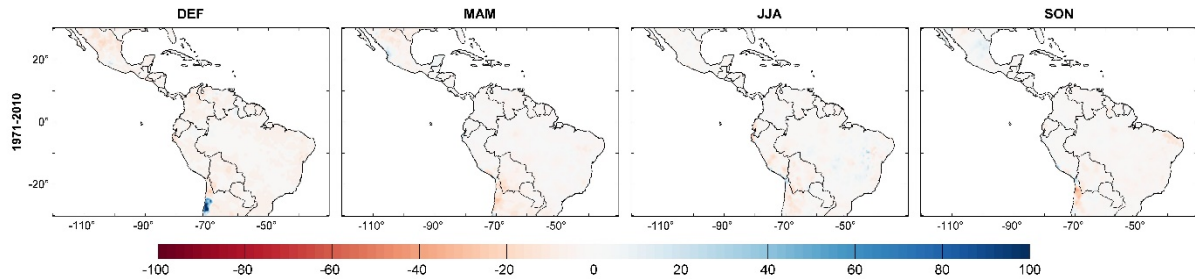


Figura 6.2. Distribución espacial de las diferencias (en porcentaje) de los campos medios entre la precipitación observada y predicha por el modelo DS durante el periodo de 1971-2000 usando los datos de SLP del reanálisis NCEP.

6.2 Evaluación de simulaciones históricas

Después de la recalibración del modelo DS en el periodo 1950-2010 y evaluar su capacidad para reproducir la precipitación por punto de rejilla, estos se aplicaron a los datos de la SLP derivados de 20 GCMs seleccionados del CMIP5 (Tabla 6.1), tanto para el clima presente (1971 a 2000), como para el clima futuro (2071 a 2100) en los escenarios RCP2.6, RCP4.5 y RCP8.5 (Figura 6.3 a Figura 6.18). De manera general, las diferencias porcentuales entre la precipitación obtenida tras el DS (precipitación DS de ahora en adelante) por los 20 GCMs respecto a la observada del GPCC en el periodo 1971-2000, no son estadísticamente significativas en un gran número de modelos (Fig 6.3 - Fig 6.6) para las cuatro estaciones. En cambio las simulaciones realizadas directamente por los GCMs (Apéndice 6.1) tergiversan fuertemente la precipitación estacional, ya que no responden ni a los valores ni a la distribución espacial de precipitación. Sin embargo, el modelo SD aplicado a las salidas de la SLP de estos GCMs muestra una alta capacidad para reproducir fielmente el campo de las precipitaciones. Así, las áreas de las zonas con diferencias significativas (de acuerdo a la prueba bilateral de suma de rangos de Wilcoxon-Mann-Whitney) entre la precipitación DS respecto a la observada del GPCC, en DEF, MAM, JJA y SON, fue en promedio de 16.79%, 20.53%, 21.80% y 20.28%, respectivamente en el periodo 1971-2000. Por lo tanto, el *downscaling* de los 20 GCMs reproduce con precisión los valores más altos y bajos de la precipitación media en la mayor parte de la zona de estudio, además están muy cerca de los observados, y con patrones espaciales muy similares a los de los datos originales.

Tabla 6.1, Listado de modelos del CMIP5, utilizados para el análisis de Downscaling, tanto para el clima presente (1971 a 2000), como para el clima futuro (2071 a 2100) en los escenarios RCP2.6, RCP4.5 y RCP8.5

			Historical	RCP2.6	RCP4.5	RCP8.5
1	a	BCC-CSM1.1(m)	1971-2000	2071-2100	2071-2100	2071-2100
2	b	BCC-CSM1.1	1971-2000	2071-2100	2071-2100	2071-2100
3	c	CanESM2	1971-2000	2071-2100	2071-2100	2071-2100
4	d	CCSM4	1971-2000	2071-2100	2071-2100	2071-2100
5	e	CESM1(CAM5)	1971-2000	2071-2100	2071-2100	2071-2100
6	f	CNRM-CM5	1971-2000	2071-2100	2071-2100	2071-2100
7	g	CSIRO-Mk3.6	1971-2000	2071-2100	2071-2100	2071-2100
8	h	FGOALS-g2	1971-2000	2071-2100	2071-2100	2071-2100
9	i	FIO-ESM	1971-2000	2071-2100	2071-2100	2071-2100
10	j	GFDL-CM3	1971-2000	2071-2100	2071-2100	2071-2100
11	k	GISS-E2-R	1971-2000	2071-2100	2071-2100	2071-2100
12	l	HadGEM2-AO	1971-2000	2071-2100	2071-2100	2071-2100
13	m	HadGEM2-ES	1971-2000	2071-2100	2071-2100	2071-2100
14	n	IPSL-CM5A-MR	1971-2000	2071-2100	2071-2100	2071-2100
15	o	MIROC5	1971-2000	2071-2100	2071-2100	2071-2100
16	p	MIROC-ESM	1971-2000	2071-2100	2071-2100	2071-2100
17	q	MPI-ESM-LR	1971-2000	2071-2100	2071-2100	2071-2100
18	r	MPI-ESM-MR	1971-2000	2071-2100	2071-2100	2071-2100
19	s	MRI-CGCM3	1971-2000	2071-2100	2071-2100	2071-2100
20	t	NorESM1-ME	1971-2000	2071-2100	2071-2100	2071-2100

Los resultados de las Figuras 6.3-6.6, muestran que la estación de invierno (DEF) es la que presenta un área menor con diferencias significativas, siendo en ese sentido en la que el DS mejor reproduce la precipitación. Particularmente el DS para los modelos BCC-CSM1.1 (b) y (n) IPSL-CM5A-MR presentan diferencias significativas sólo en 7.26% y 6.26% de la área, respectivamente (Figura 6.3). Para la primavera (MAM), el porcentaje de zonas con cambios significativos es menor en los modelos BCC-CSM1.1 (b), MPI-ESM-LR (q), MPI-ESM-MR (r) y MIROC5(o), con diferencias significativas en el 4.86%, 5.19%, 6.46%, y 10.59%, del área, respectivamente. Por otra parte, hay que resaltar, que a pesar que en el verano (JJA), los modelos tienden a mostrar una mayor área con diferencias significativas entre la precipitación DS y la observada, para los modelos MIROC5 (o), HadGEM2-ES (m), BCC-CSM1.1 (b) y HadGEM2-AO (l) estas áreas son relativamente pequeñas (11.63%, 11.56%, 10.36% y 8.46% respectivamente). Por último en otoño (SON), son los modelos (e) CESM1(CAM5), (m) HadGEM2-ES, (l) HadGEM2-AO y (b) BCC-CSM1.1, los que mejor reproducen la precipitación en 1971-2000, siendo las diferencias significativas en el 9.99%, 9.76%, 8.07% y

7.65%, respectivamente del área de estudio. De forma general, los modelos para los que la precipitación DS presenta diferencias significativas en una mayor área de la región de estudio son el GISS-E2-R (k), MIROC-ESM (p) y GFDL-CM3 (j), llegando a presentar diferencias significativas en más del 50 % del área (61.22% para el en otoño).

La mayoría de los modelos DS parecen subestimar ligeramente las precipitaciones en verano y primavera, pero en general, los resultados del DS son alentadores, excepto, y de forma clara, para el GISS-E2-R con diferencias muy marcadas entre la precipitación observada y DS en las simulaciones del GISS-E2-R en la zona central de Brasil. Esta zona es mal representada en un gran número de modelos durante el verano.

A continuación se evalúan las zonas geográficas en las que aparecen diferencias significativas más marcadas entre el promedio de la precipitación DS de los distintos modelos y el del GPCC en las distintas estaciones del año.

DEF

Los resultados de la Figura 6.3 muestran que a pesar de que los modelos DS reproducen con éxito los patrones espaciales más importantes de la precipitación en la zona de estudio en DEF, se evidencian diferencias significativas en las predicciones hechas con las simulaciones del GISS-E2-R (k) y MIROC-ESM (p), seguida de las simulaciones del CSIRO-Mk3.6 (g) y el GFDL-CM3 (j), estas últimas con diferencias más pequeñas (<+20%) pero significativas sobre un gran parte de México. Para el modelo GISS-E2-R, la Figura 6.3k, muestra que el DS sobrestiman en más de un 60% el promedio de precipitación del GPCC en las zonas ubicadas sobre los 15°N cubriendo México, y alrededor de ~+30% en la región limítrofe entre Brasil, Argentina y Paraguay. En cambio las subestimaciones más altas son del orden de ~-40%, y se ubican principalmente al norte y noreste de Suramérica, sobre la cordillera de los Andes en Colombia, Panamá, la costa norte de Brasil, y el oeste de la cordillera de los Andes peruanos. Además, para el MIROC-ESM (p), las diferencias en porcentajes muestran una fuerte subestimación de la precipitación en México (>-90%), y sobrestimación moderada sobre Perú, Ecuador, y el extremo oeste de Brasil.

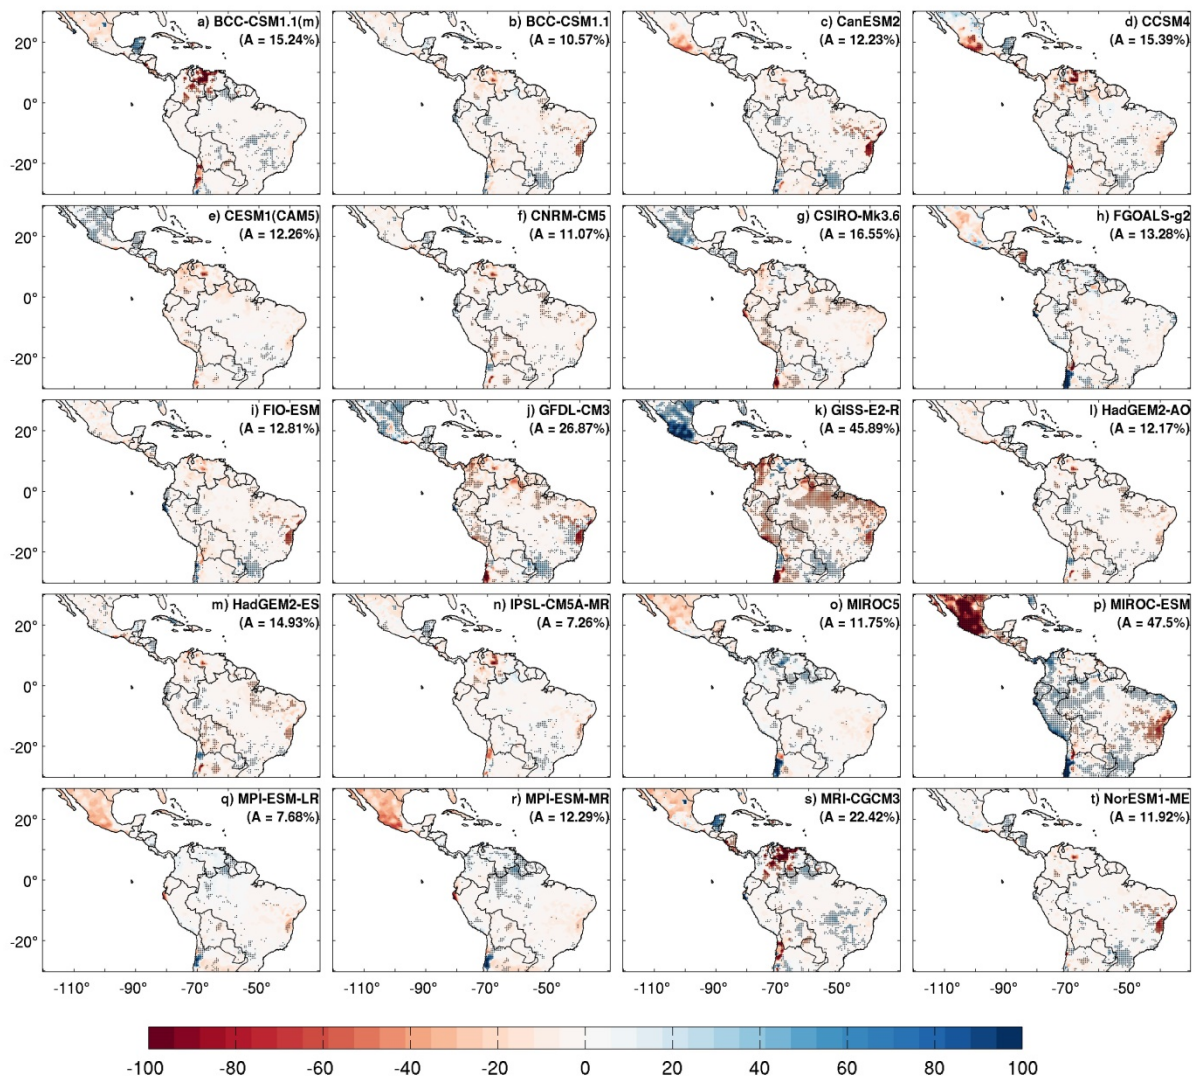


Figura 6.3. Diferencias (en porcentaje) entre los campos medios de la precipitación DS para los 20 GCMs del CMIP5 y la precipitación del GPCC (DS-obs), durante el periodo de 1971-2000 en DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95% (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por líneas.

MAM

Las diferencias porcentuales entre la precipitación simulada por el modelo DS y la observada en la primavera boreal (MAM), son mostradas en Figura 6.4. Los modelos (o) MIROC5, (q) MPI-ESM-LR, (r) MPI-ESM-MR y el (s) MRI-CGCM3, son los que reproducen con un a mayor precisión los valores máximos y mínimos de la precipitación DS, con valores muy cercanos a los observados, de tal forma que las diferencias son inferiores al 5% en la mayor parte de la zona, con algunas pequeñas zonas aisladas con diferencias porcentuales de $\pm 40\%$.

En cambio el DS de los modelos de l GISS-E2-R (k), (j) GFDL-CM3, (c) CanESM2 y (p) MIROC-ESM, no es capaz de reproducir en detalle la distribución espacial de la precipitación en la mayor parte del territorio, con marcadas diferencias porcentuales al este de Brasil, entre los 10°-20°S y 60°-40°W, y al este de la cordilleras de los Andes en Chile, con un déficit porcentual de precipitación superiores al 80% respecto a la observada (Fig. 6.4). Nuevamente el GISS-E2-R, es el modelo que peor reproduce la precipitación en América tropical, con subestimaciones significativas al norte de Brasil, al este de los Andes y en la zona del Pacífico colombiano, mientras que los mayores porcentajes de sobreestimación se sitúan sobre el extremo oeste de Chile, y entre los límites de Paraguay, Argentina y Brasil. También se identifican diferencias significativas positivas sobre las costas este y oeste de México. Por otra parte la precipitación DS estimada con los modelos GFDL-CM3 y CanESM2, muestra un patrón bipolar norte-sur con diferencias significativas de signo opuesto del orden de $\pm 70\%$, sobre la zona central de Brasil y en los límites entre Argentina y Paraguay. También es posible identificar subestimaciones significativas ($> -85\%$) al este de la cordillera de los Andes en Chile.

JJA

En JJA, hay un predominio de regiones en la que el DS subestima la precipitación, aunque en muchos casos de forma no significativa. Los modelos CESM1(CAM5) (e) y HadGEM2-AO (l) (Figura 6.5), son los que mejor simulan la precipitación media en JJA. Las mayores diferencias porcentuales (del orden de $\pm 20\%$) se aprecian sobre el extremo noroeste de Chile y Ecuador, alrededor de los 10°S, entre 60°-40°W, y en el centro de Brasil.

Por otra parte, se destacan deficiencias en la reproducción de los campos medios de la precipitación en la zona cubrada aproximadamente entre los (0°-20°S, y 60° -40°W) en muchos modelos, con subestimaciones alrededor del (-90%). El DS de los modelos GISS-E2-R (k), GFDL-CM3 (j) y MIROC-ESM (p), mostraron las mayores diferencias significativas en la zona de estudio. Las simulaciones con DS del GISS-E2-R, muestran diferencias significativas que sobrestiman la precipitación en más de un (+60%), al sur de Brasil, al igual que una pequeña franja que recorre toda la costa de Chile hasta el sur del Perú, y que reaparece nuevamente sobre Ecuador. El GISS-E2-R también subestima la precipitación en la región al norte de Suramérica y al norte de México. Por otro lado, las diferencias porcentuales más destacadas en el DS para el GFDL-CM3 y MIROC-ESM, se sitúan para cada uno, sobre todo, al norte (-40%) y al sur de Brasil (-100%), respectivamente.

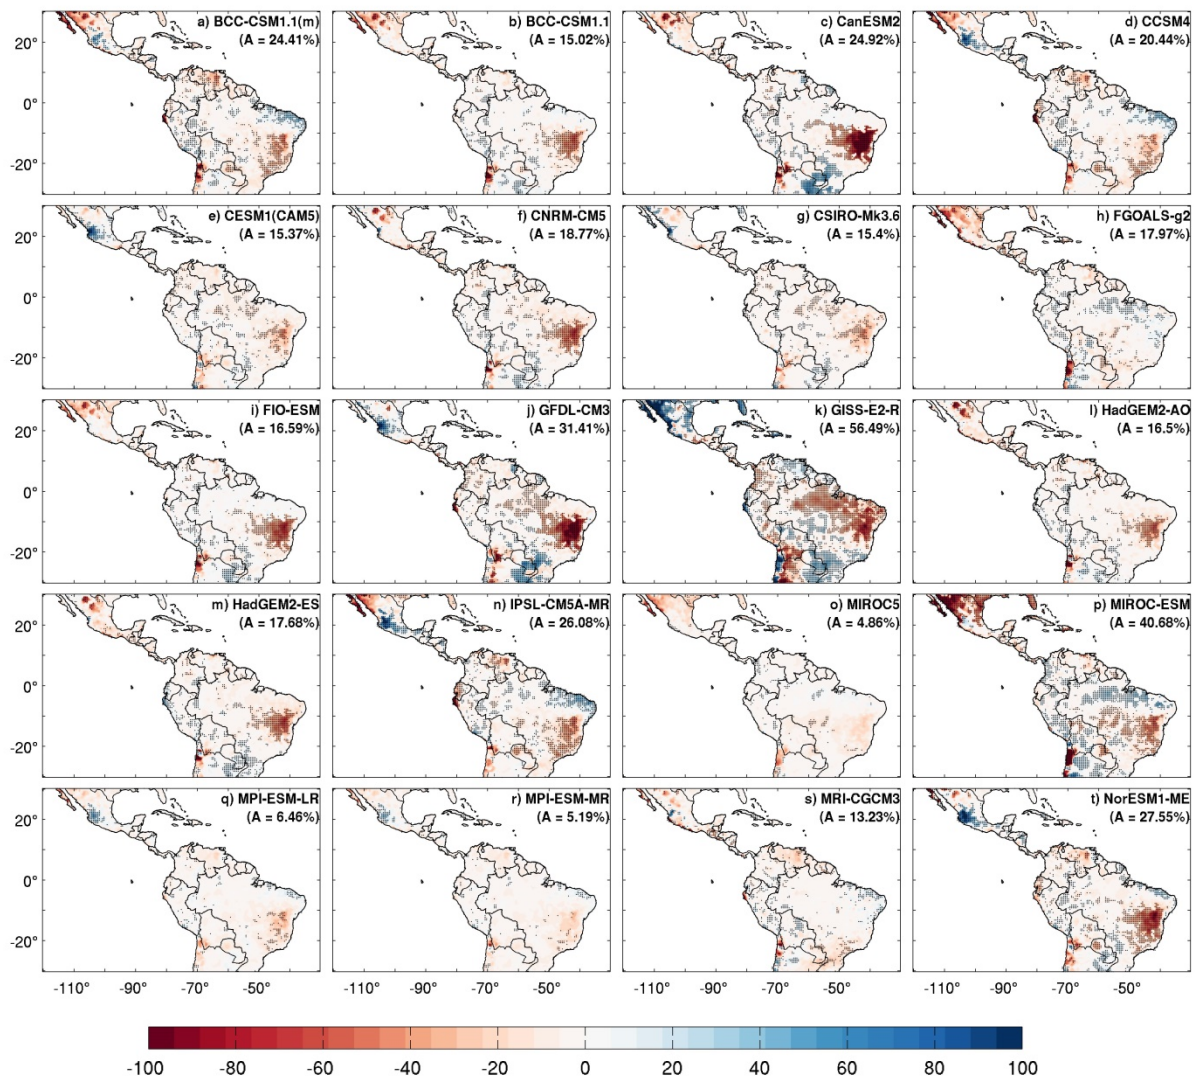


Figura 6.4. Como la Figura 6.3 pero en MAM.

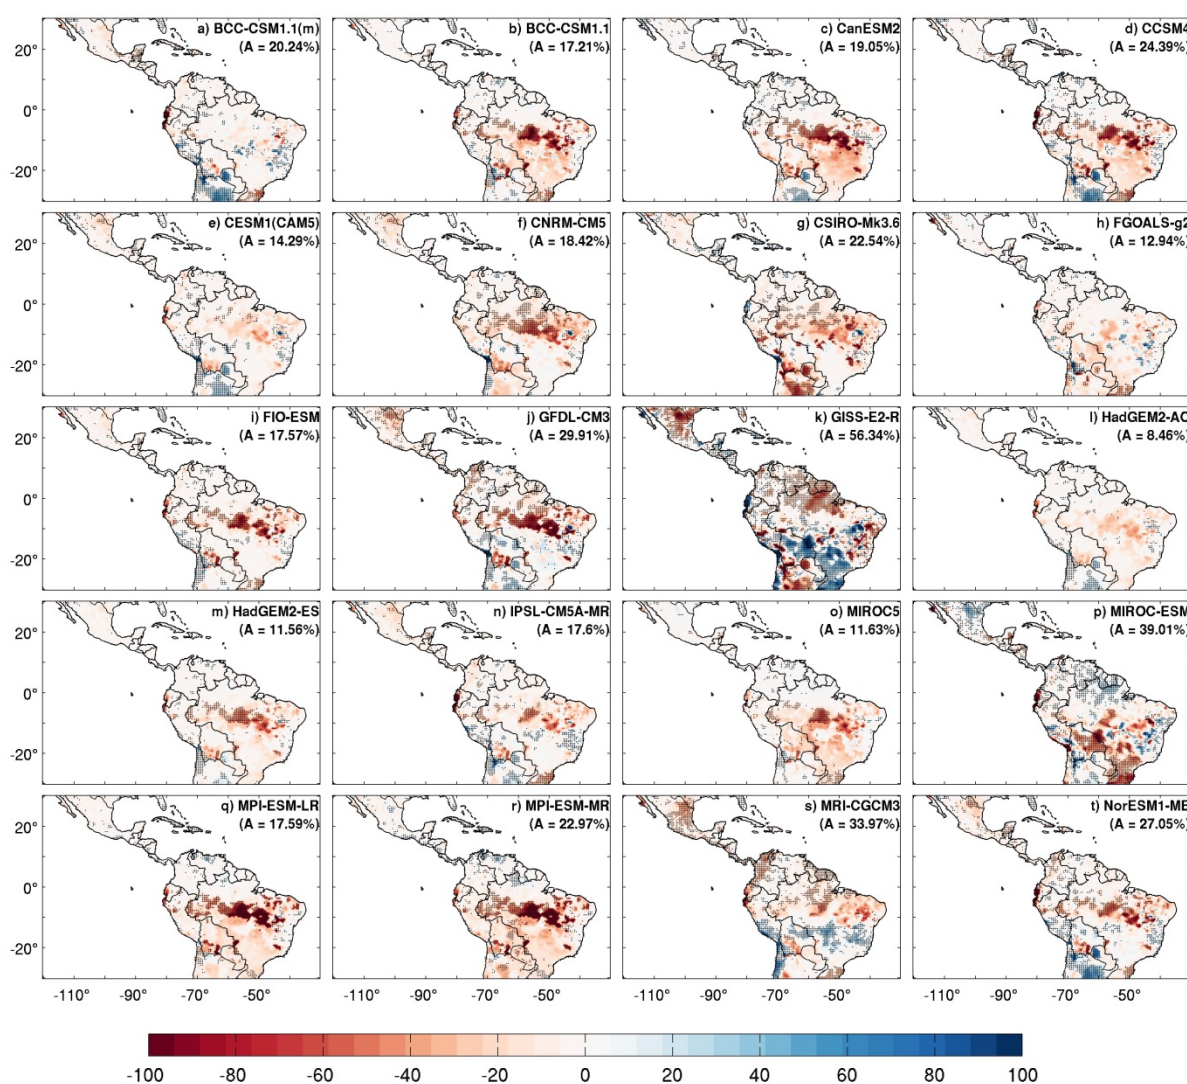


Figura 6.5, Al igual que la Figura 6.3 pero en JJA.

SON

El DS de los GCMs en SON tiende a reproducir razonablemente bien los campos medios de la precipitación (Figura 6.6). Los modelos que muestran las mayores diferencias son el GISS-E2-R(k), seguido del GFDL-CM3 (j) y el MIROC-ESM (p), principalmente en el norte de Suramérica. Las simulaciones DS del GISS-E2-R, con mayores sobrestimaciones van desde Guayana hasta el extremo este de Brasil en los 15°S. Este modelo muestra también sobrestimaciones en México y en las costas ecuatorianas y peruanas hasta el norte de Chile, con sobrestimaciones significativas en más de un +70%.

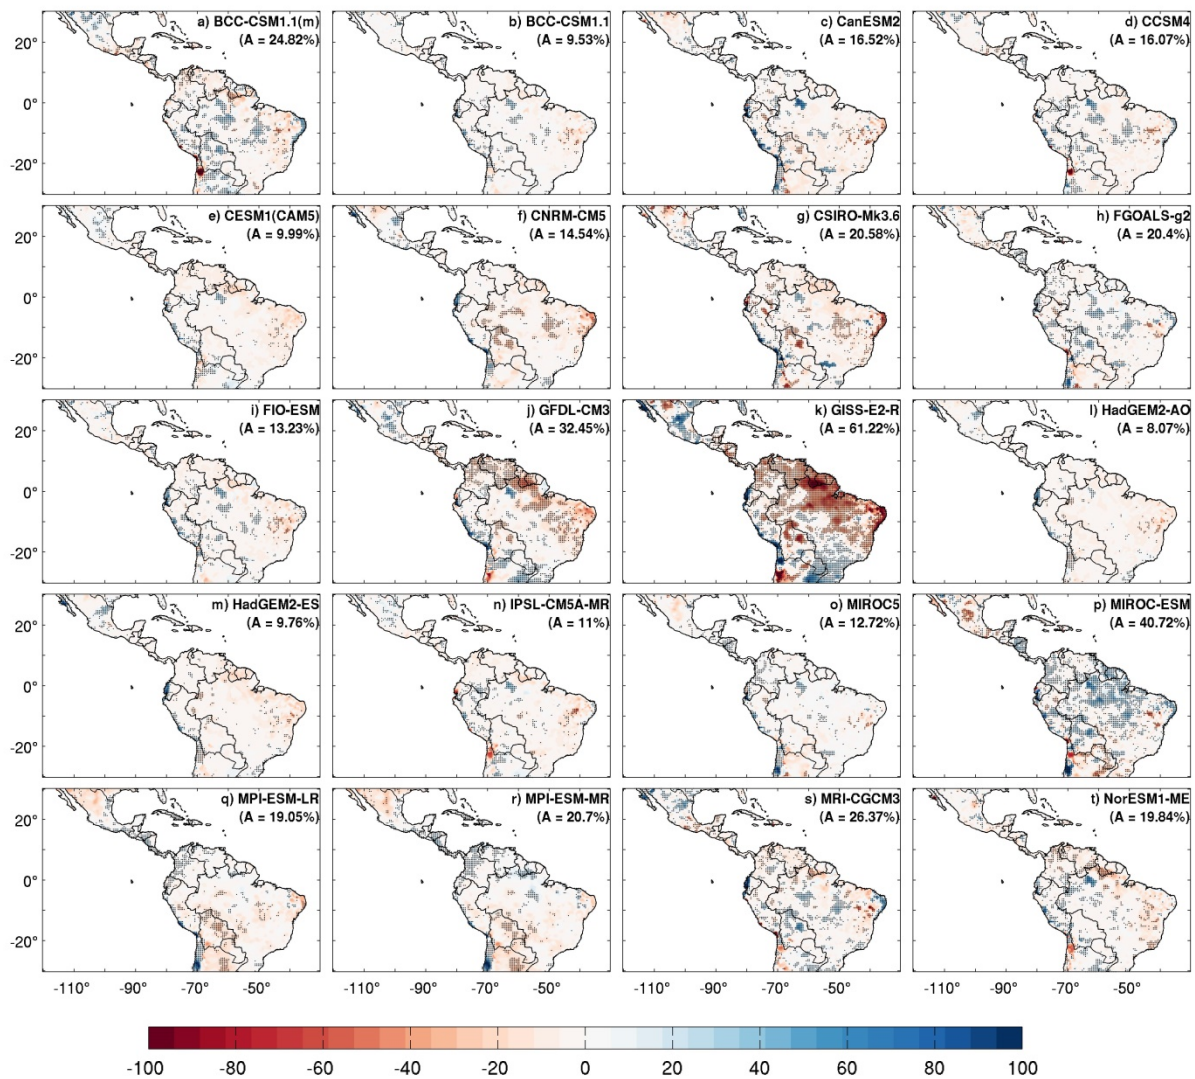


Figura 6.6. Como la Figura 6.3 para en SON.

6.3 Evaluación de los cambios proyectados en la precipitación media estacional

El modelo DS obtenido para cada punto de rejilla ha sido aplicado a las salidas de la SLP de los GCMs usados en los escenarios RCP2.6, 4.5 y 8.5 con el fin de obtener la precipitación proyectada para el periodo 2071-2100. Los resultados son los promedios estacionales de la precipitación obtenidos con cada GCM, expresándolos como diferencias en porcentaje de la precipitación futura respecto a la estimada por el modelo DS del correspondiente GCM en el periodo de referencia 1971-2000, con el fin de que los errores (desviaciones respecto a los valores reales) se cancelen al ser restadas las estimaciones (Li and Smith, 2009, Palomino-Lemus et al., 2015).

6.3.1 Cambios proyectados en la precipitación para el invierno (DEF)

Las Figuras 6.7, 6.8 y 6.9, muestran los cambios porcentuales de la precipitación media proyectada en DEF, bajo los RCP2.6, RCP4.5 y RCP8.5 respecto a la estimada en el periodo 1971-2000 por cada GCM. La significación estadística de los cambios proyectados de la precipitación respecto al presente se ha estimado en base a la prueba la prueba bilateral de suma de rangos de Wilcoxon-Mann-Whitney, indicando con un punto (·) las zonas en las que los resultados muestran cambios estadísticamente significativos (a un nivel de confianza del 95%). En general, para las 20 simulaciones proyectadas, los escenarios RCP4.5 y RCP8.5 muestran amplias zonas con cambios significativos.

Los resultados proyectados para el escenario RCP2.6, muestra un predominio de descensos muy moderados de la precipitación, aunque significativos en algunos modelos. El área afectada por cambios significativos varía desde un 2.56 % para el CSIRO-Mk3.6 (g) a 57.91 % para el HadGEM2-ES. La zonas con cambios más coherentes entre los modelos es el este de Brasil, particularmente intenso (descensos de más del 80%) en torno a los 10°S, 45°W en los modelos CanESM2 (c) y GFDL-CM3 (j). algunos modelos muestran también un descenso acusado en los Andes chilenos. El norte de México presenta descensos significativos en algunos modelos del orden de un 30% (con algunas áreas presentando mayores descensos), mientras que la zona costera suroccidental muestra aumentos (superiores al 60%) en el DS de varios modelos.

A medida que aumenta el forzamiento radiativo, el área con cambios significativos se incrementa, de tal forma que para el RCP8.5 la extensión mínima con cambios significativos supera el 40 % (DS de los modelos MPI-ESM-LR (q) y MPI-ESM-MR(r)) superando el 80 % para el Nor-ESM1-ME (t)). Este modelo es también el que presenta una mayor extensión con cambios significativos para el RCP4.5. Para este escenario, algunos modelos presentan menos zonas con cambios que en el RCP2.6 (IPSL-CM5A-MR (n), MPI-ESM-MR (r), y sobre todo el BCC-ESM1.1 (b)). Hay una mayor presencia de cambios hacia una disminución de la precipitación, que llega a ser muy marcada de nuevo en el este de Brasil (CanESM2 (c) y GFDL-CM3 (j)) y México (MIROC5 (o), NorESM1-ME (t)). Los cambios mostrados son menos coherentes en algunas áreas, así por ejemplo, el norte de Sudamérica, en la que algunos modelos muestra aumentos (CNRM-CM5, GISS-E2-R) y otros descensos (FGOALS-g2 (h), HadGEM2-AO), o incluso aparecen tendencias opuestas en áreas relativamente cercanas (MRI-CGCM3).

Para el RCP8.5, el DS de 13 modelos muestra descensos muy significativos en la mayor parte de México, sobre todo en el norte, por encima del 30%, que llegan a superar el 90% (MIROC5 (o), NorESM1-ME (t)). Para el este de Brasil (10°S, 45°N), se tiene también resultados similares con 13 modelos que muestra descensos significativos. Para el noroeste de Sudamérica (oeste de Colombia) predominan las simulaciones (12) que muestran aumentos significativos de la precipitación, que llegan en la parte más septentrional a alcanzar un aumento del 80% (HadGEM2-ES (m)).

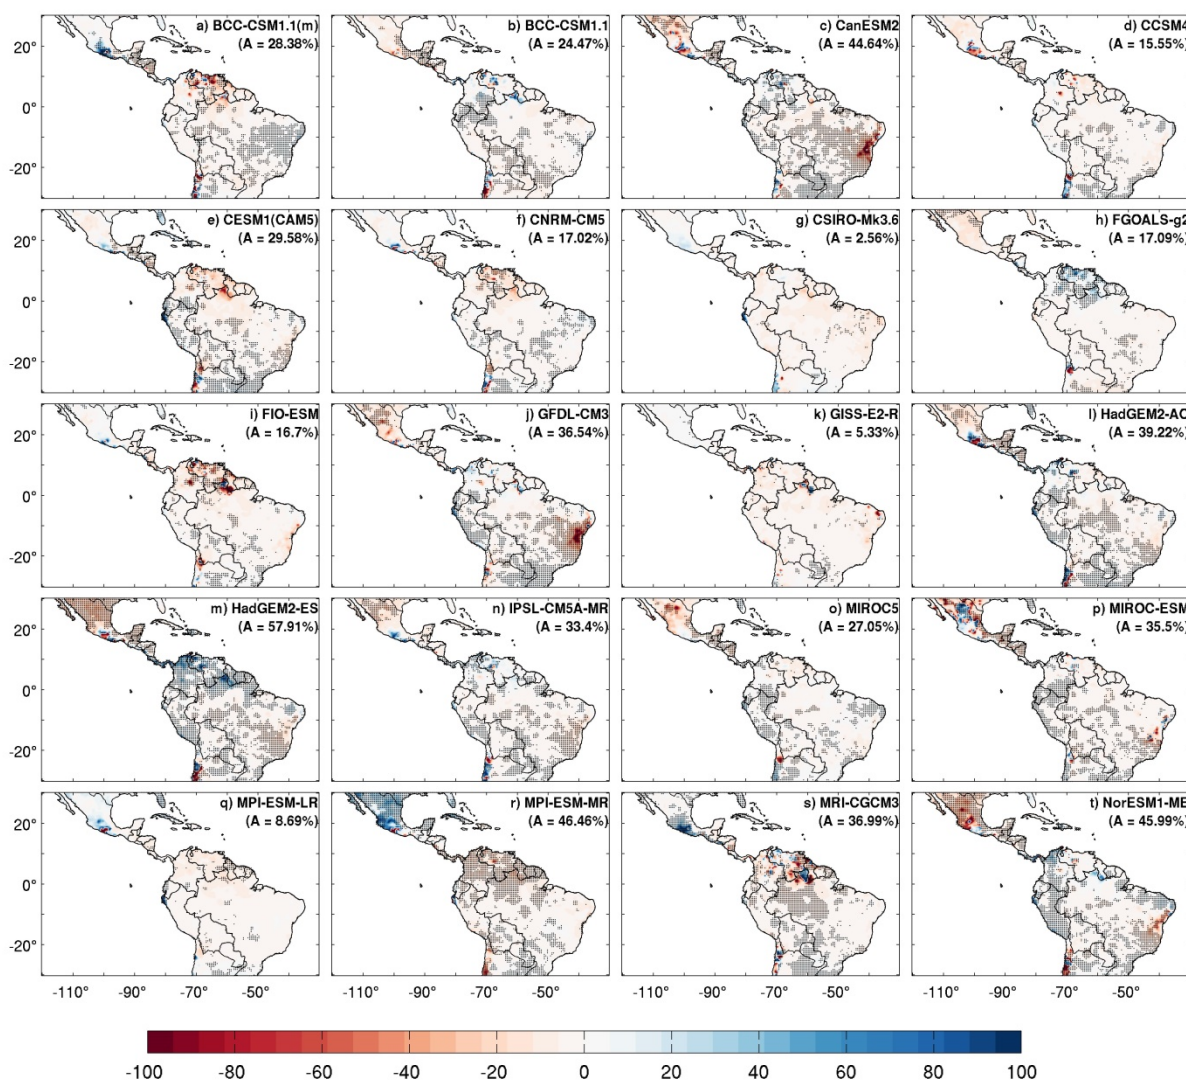


Figura 6.7. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando los 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

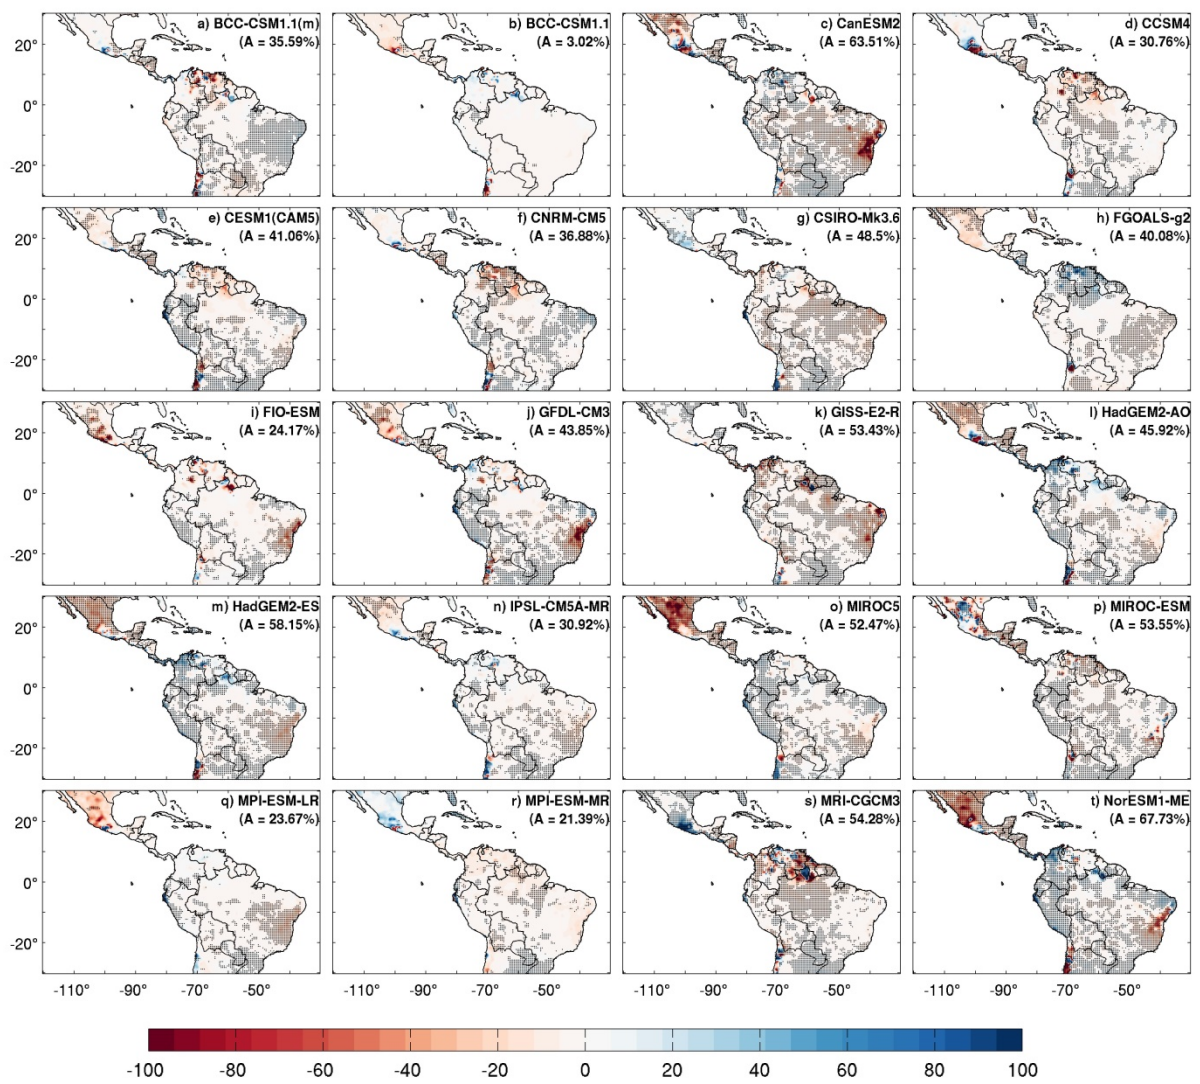


Figura 6.8. Al igual que la Figura 6.7 pero en para el escenario RCP4.5.

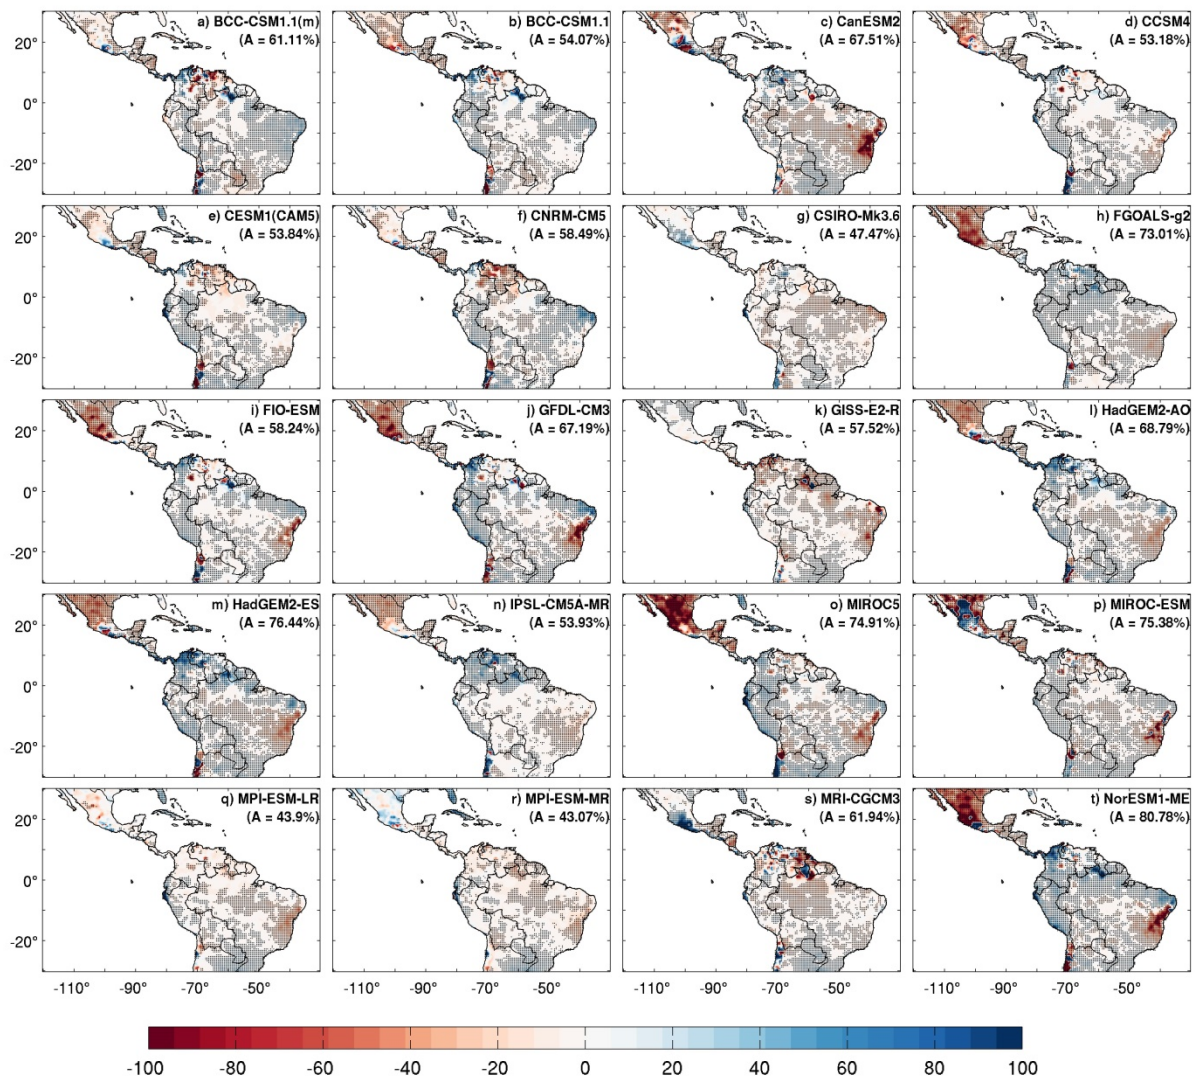


Figura 6.9. Al igual que la Figura 6.7 pero en para el escenario RCP8.5.

6.3.2 Cambios proyectados en la precipitación para la primavera (MAM)

Las figuras 6.10-6.12 muestran los cambios de la precipitación media en MAM en la final del siglo XXI (2071-2100 menos 1971-2000) bajo los escenarios RCP 2.6, 4.5 y 8.5, de acuerdo a las proyecciones obtenidas mediante la aplicación del DS a las simulaciones de los 20 GCMs del CMIP5. En general, los cambios son más heterogéneos, sin que predominen claramente las áreas con descensos.

Para el RCP2.6, la mayoría de los modelos muestra pocos cambios significativos y débiles. Para 8 de los modelos, la extensión del área con cambios no supera el 10 % (para el CCSM4 (d), CNRM-CM5 (f) y MIROC5 (o) es el 0%). Para los modelos que presentan cambios más intensos

(por ejemplo, CanESM2 (c) y GFDL-CM3 (j), como ocurría en invierno), aparecen descensos en el este de Brasil, pero a veces no significativos, y a veces incluyendo áreas con aumentos (GFDL-CM3 (j)). Para México, algunos modelos muestran aumentos muy marcados (más del 80%, CanESM2 (c), HADGEM2-AO (l)) pero que coexisten con zonas de fuerte descenso.

Para el RCP4.5, las zonas con cambios significativos son más extensas, algunos modelos presentan pocos cambios respecto al RCP2.6 (CCSM4 (d), FGOALS-g2 (h)) o menos (HadGEM2-ES (m)). Varios modelos (por ejemplo, CanESM2 (c), CSIRO-Mk3.6 (g), GISS-E2-R (k), y HadGEM2-AO (l)), tienden a mostrar cuatro áreas sobre Sudamérica, con aumentos en el norte (Venezuela, Guayana, Surinam) y sur de Brasil, Paraguay y noreste de Argentina, y descensos en el área central y norte de Brasil (más o menos extensos según el modelo) y en el sur de Bolivia, Chile y noreste de Argentina. De nuevo, la zona este de Brasil, alrededor de Bahía (10°S, 45°W), presenta un acusado descenso de precipitación (más del 70%), que se extiende hacia el norte y oeste en algunos modelos, como ya se ha comentado.

Para el RCP8.5, los resultados son muy parecidos a los del RCP4.5, pero siendo más extensas las áreas con cambios significativos y estos más intensos. Vuelve a aparecer el patrón con las cuatro áreas comentadas sobre Sudamérica. Aumenta el número de modelos (MIROC-ESM (p), MPI-ESM-LR (q), MPI-ESM-MR (r), NorESM1-ME (t), GISS-E2-R (k), CSIRO-Mk3.6 (g)) que muestran descensos marcados en la zona de Bahía, superando el 80% de descenso, aunque algunos de estos modelos presentan áreas dentro de esta región con aumentos intensos (GISS-E2-R (k), GFDL-CM3 (j)). Sobre Centroamérica, no aparece una señal clara, destacando una mayor presencia de crecimiento de la precipitación en la zona occidental de México.

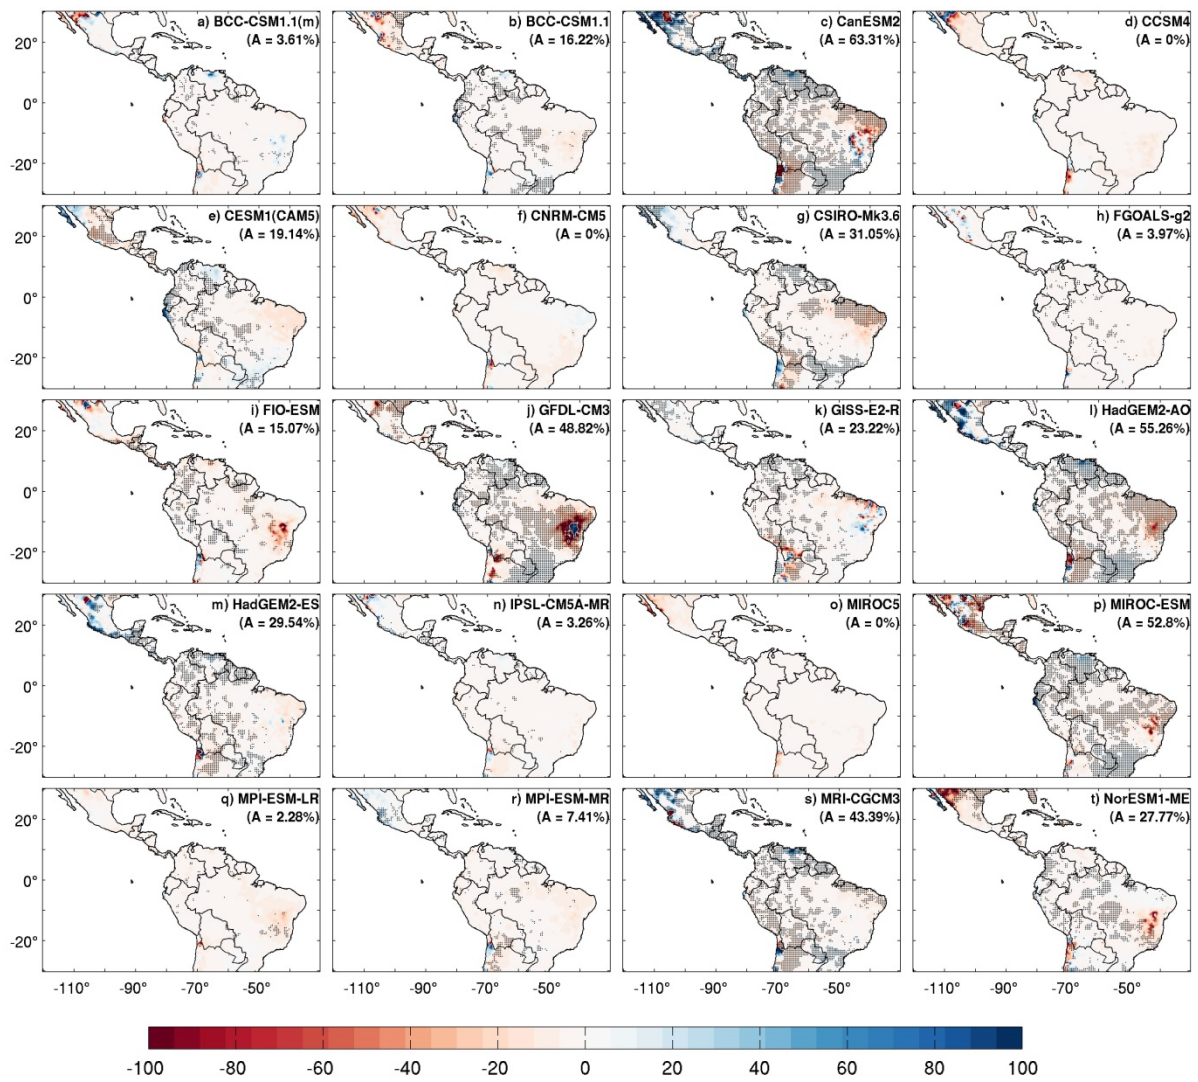


Figura 6.10. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando los 20 modelos del CMIP5 en el escenario RCP2.6 para MAM. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

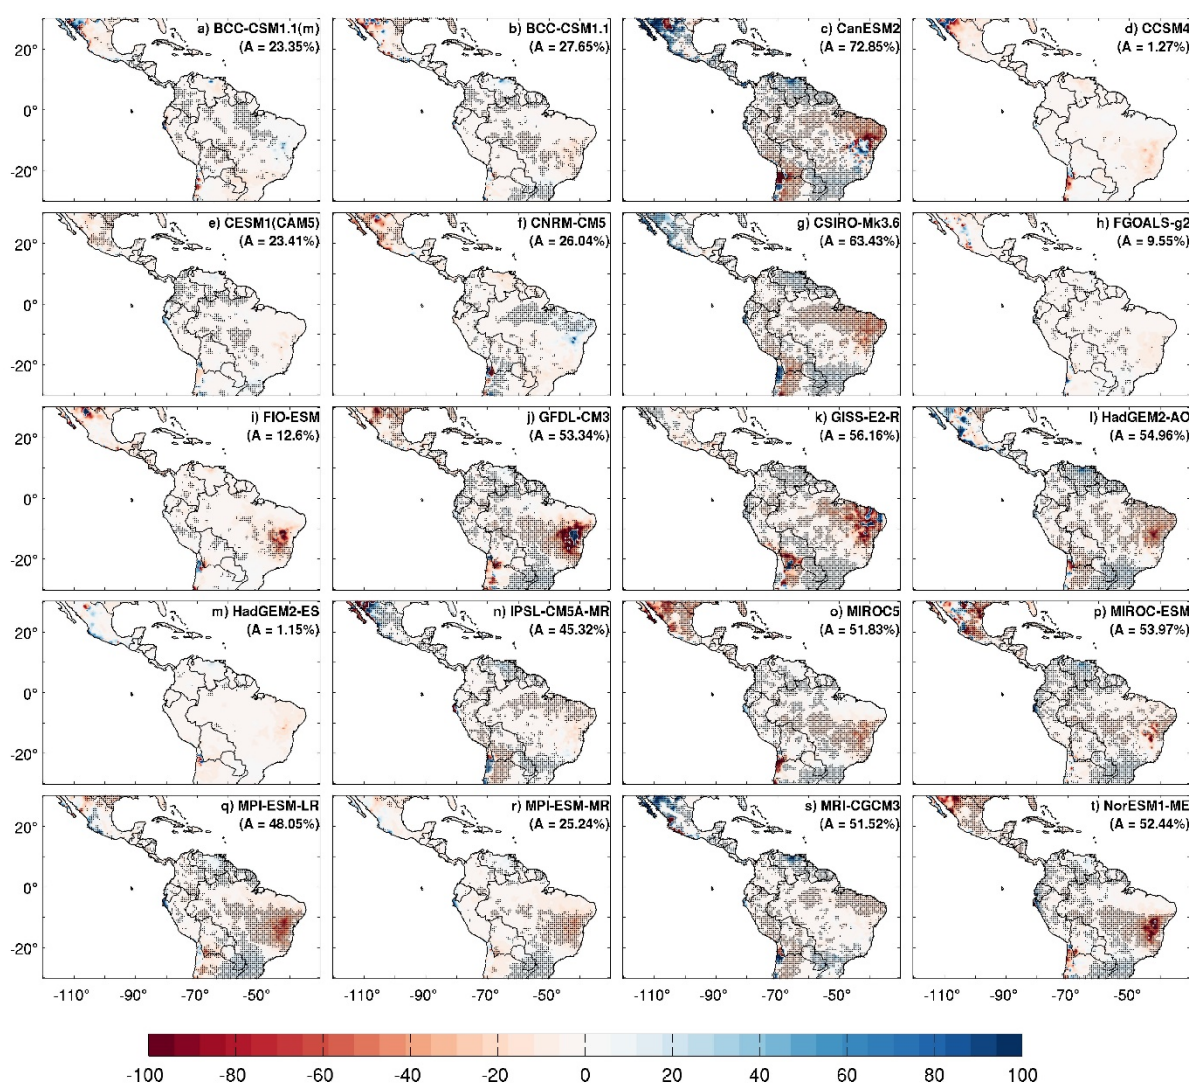


Figura 6.11. Al igual que la Figura 6.10, pero para el escenario RCP4.5.

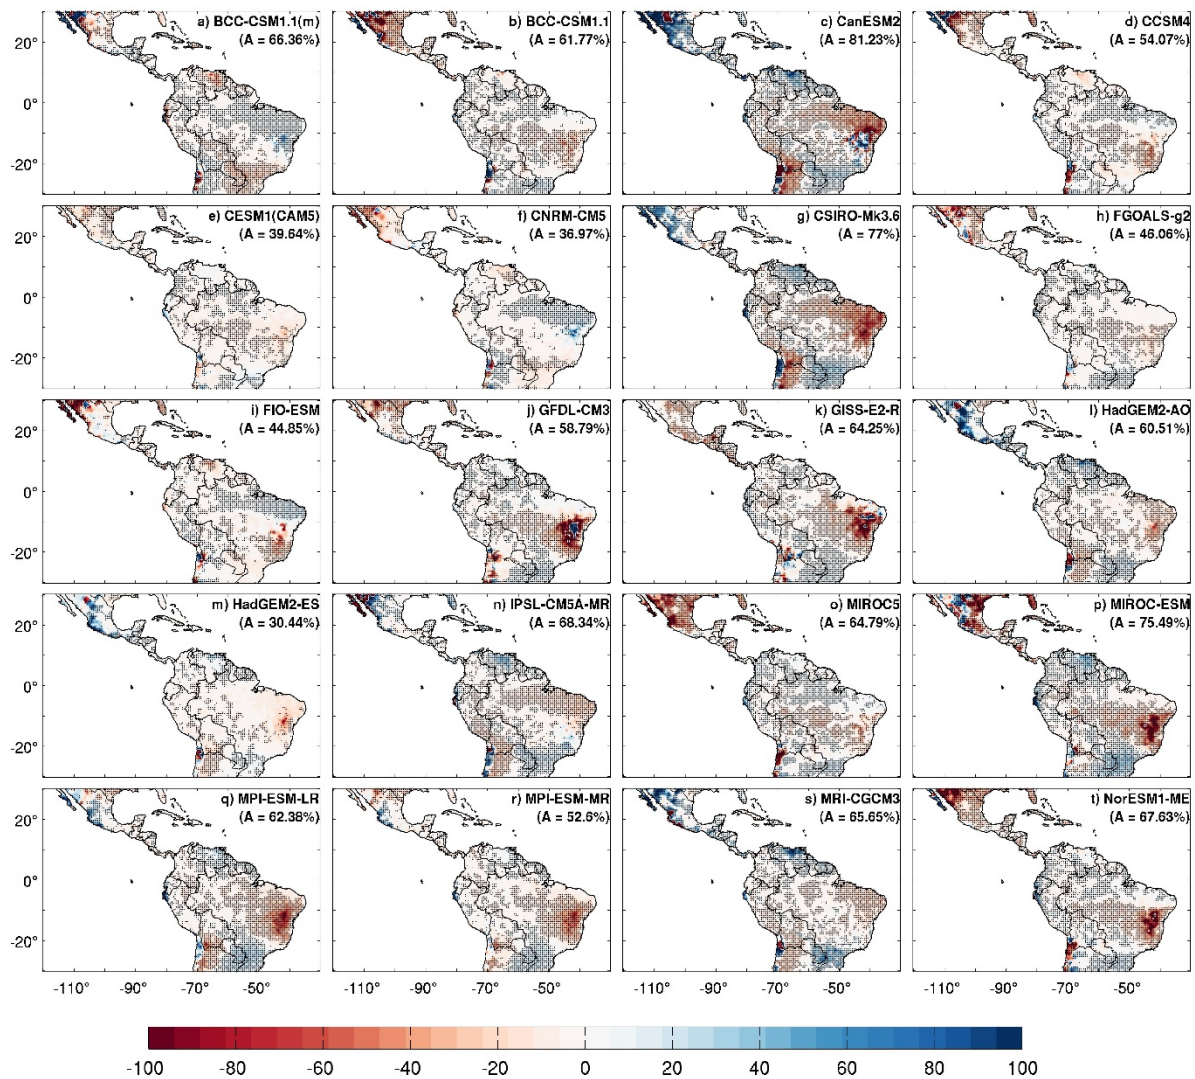


Figura 6.12. Al igual que la Figura 6.10, pero para el escenario RCP8.5.

6.3.3 Cambios proyectados en la precipitación para la verano (JJA)

Las Figuras 6. 13, 6.14 y 6.15, muestran los cambios porcentuales proyectados para el periodo 2071-2100 en la precipitación según el DS de los GCMs en los tres RC Ps en la estación de verano. Algunos modelos muestran incluso para el RCP2.6, variaciones muy intensas en la zona central de Brasil. Estos cambios se intensifican y extienden a más áreas según aumenta el forzamiento radiativo, de tal forma que para el RCP8.5, cuatro modelos (FGOALS-g2 (h), GFDL-CM3 (j), IPSL-CM5A-MR (n), MIROC-ESM (p)), muestran más de un 75 % de áreas con cambios significativos, en ciertas zonas, del 100 %.

Para el RCP 2.6, un número considerable de modelos muestra pocas áreas con cambios significativos, normalmente descensos moderados (20%) (8 modelos con menos de un 20% de área con cambio). Los modelos con cambios más marcados y extensos son CanESM2 (d), GFDL-CM3 (l), MIROC-ESM (p), caracterizados por mostrar una amplia zona sobre el centro de Brasil con descensos muy fuertes en los dos primeros (100%) y algo menos en el tercero (80%). GFDL-CM3 (j), MIROC-ESM (p) presentan también un patrón parecido en relación al norte de Sudamérica y Centroamérica, y zona más oriental de Brasil, con predominio de aumentos leves (20%) significativos de la precipitación. El modelo FIO-ESM presenta un patrón casi opuesto a los anteriores, con aumento de la precipitación en el centro de Brasil, que llegan al 100%.

Como cabía esperar, para el RCP4.5, el patrón comentado anteriormente tiende a ampliarse y a mostrarse con más claridad e intensidad en más modelos, de tal forma que al menos 10 modelos presentan descensos significativos sobre la amplia zona sobre Brasil, desde aproximadamente los 10° S, 60°W en el Mato Grosso, hasta la costa oriental y sur de Brasil, entre los que destacan por la intensidad de los descensos, junto a los anteriormente mencionados para el RCP2.6, el CanESM2(c), HadGEM2-AO (l), CSIRO-Mk3.6 (g) y MIROC5 (q). Aumentos significativos del orden de un 20-30% aparecen en la mayor parte del norte de Sudamérica y Centroamérica, aparecen de forma generalizada en los DS de los modelos GFDL-CM3 (j), HadGEM2-AO (l), MIROC5 (q) y MIROC-ESM (p), y de forma más dispersa en otros (por ejemplo, IPSL-CM5A-MR (n)). Por otro lado, modelos como el GISS-E2-R (k), apenas muestran variaciones, sólo un 10% del área con cambios muy leves.

Para el RCP8.5, para todos los modelos se tienen un considerable porcentaje de área con cambios significativos, aunque para algunos como BCC-CSM1.1 (m) (a), los cambios no son muy grandes ($\pm 20\%$). Se intensifican la cuantía y extensión de los cambios en la ya comentada área en Brasil. En mayor o menor medida, todos los modelos, excepto en FIO-ESM (i), muestran áreas con descensos en esa área, moderados en algunos casos como el BCC-ESM1.1 (m) (a), y muy intensos y amplios en los mismos modelos que para el RCP4.5. Modelos como el MPI-ESM-LR (q), MPI-ESM-MR (r), CSIRO-Mk3.6 (g) o CanESM2, presentan un patrón espacial más heterogéneo en esta zona, con áreas vecinas que muestran cambios opuestos muy fuertes ($\pm 100\%$). La señal hacia un aumento de las precipitaciones en el norte y Centroamérica también se hace más clara, estando presente en todos los modelos, siendo el noreste de México la región más afectada, con aumentos que llegan a un 60% en el CESM1(CAM5) (e) y a un 80% en

GFDL-CM3 (j) y NorESM1-LR (t). Además, en el DS de 8 modelos, el área más meridional de la zona de estudio, al norte de Argentina también muestra un aumento de la precipitación, que oscila entre el 30 % para el DS de los modelos como el HadGEM2-ES (m) al 90% del GISS-E2-R (k).

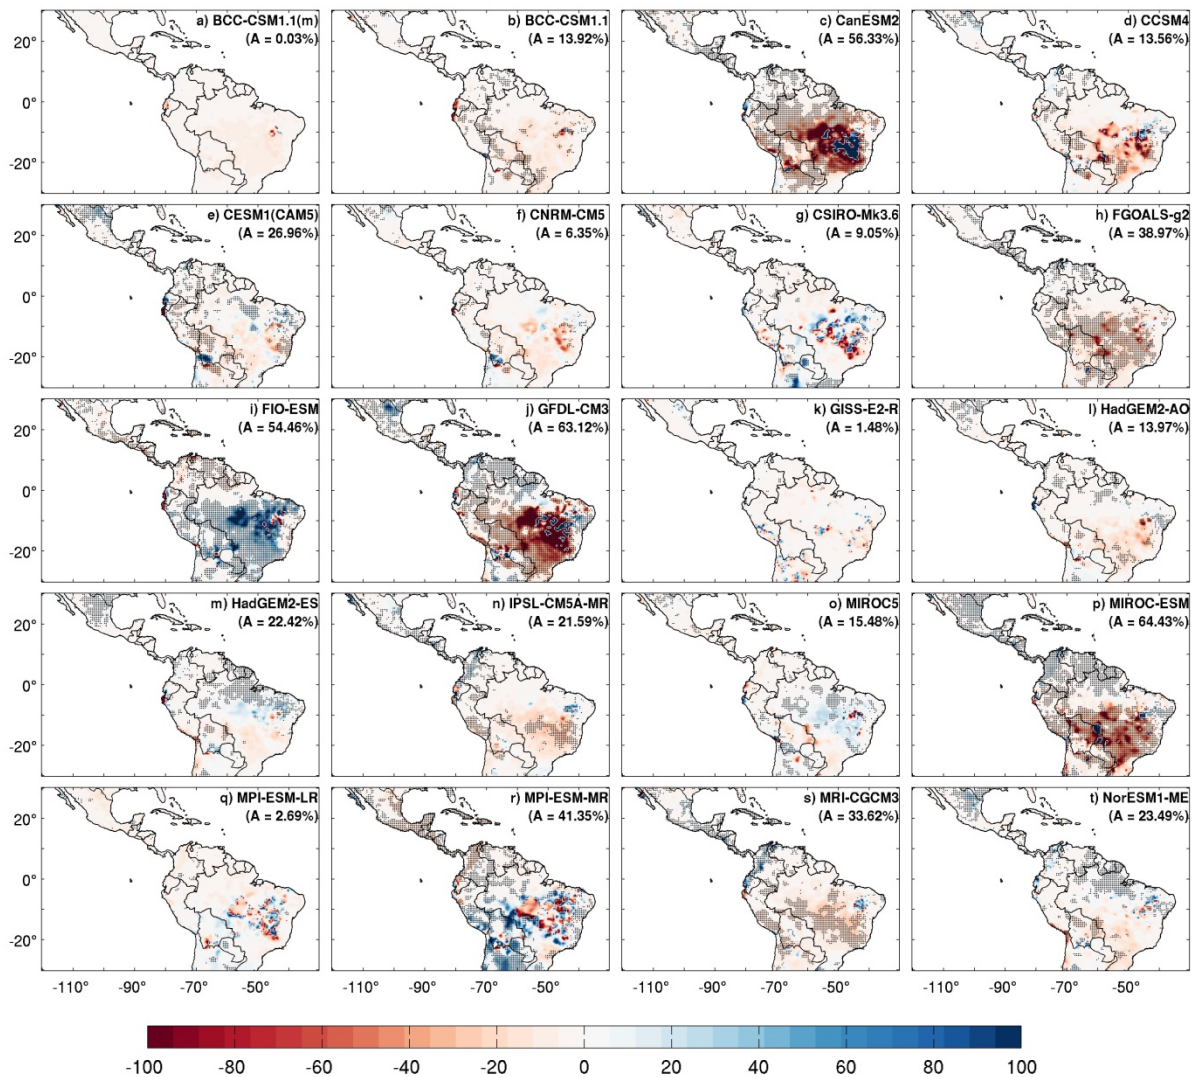


Figura 6.13. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando los 20 modelos del CMIP5 en el escenario RCP2.6 para JJA. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

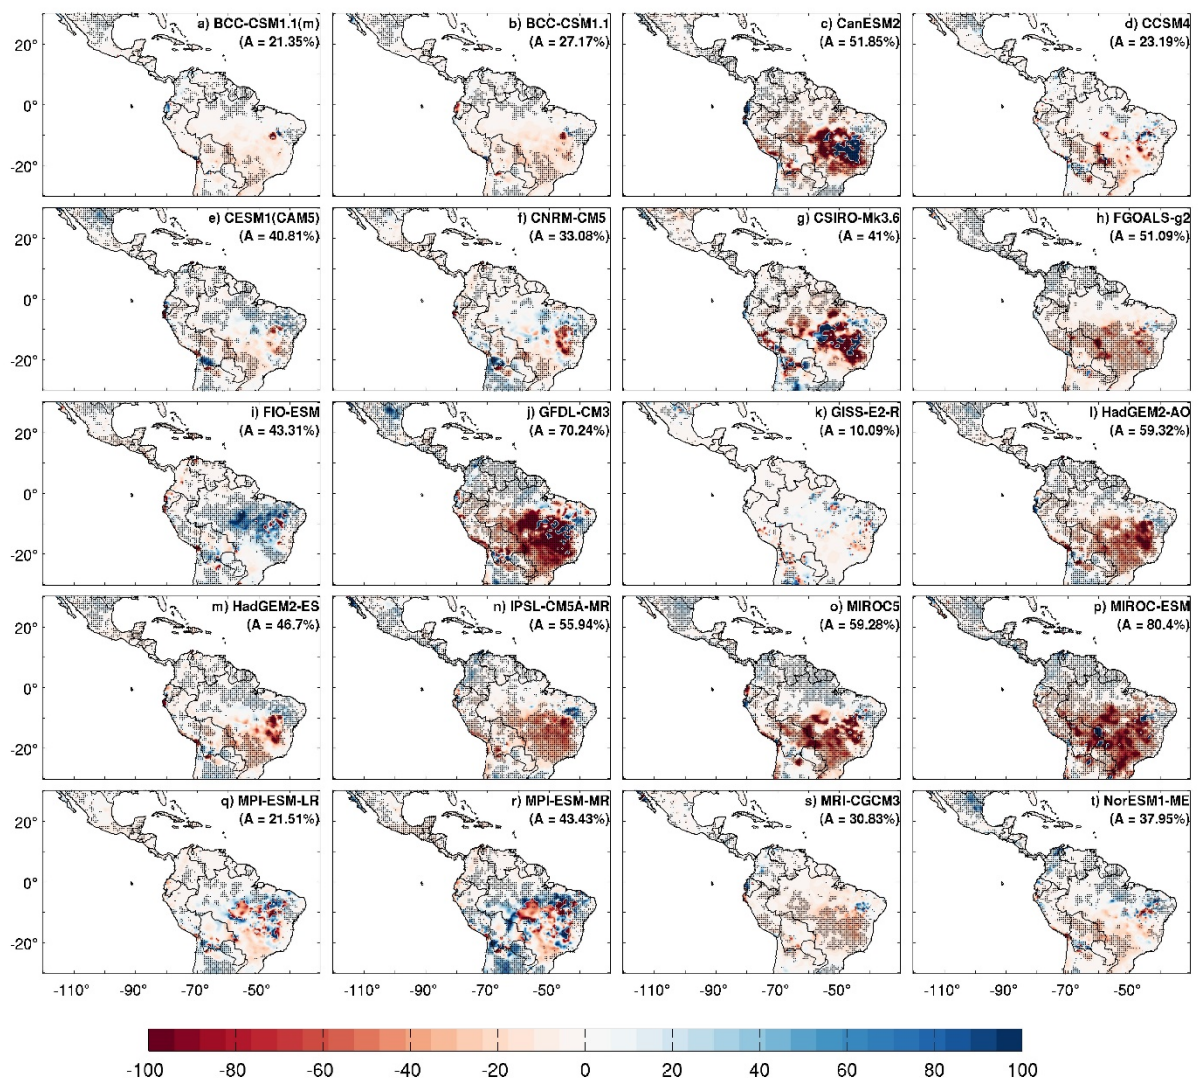


Figura 6.14. Al igual que la Figura 6.13, pero para el escenario RCP4.5.

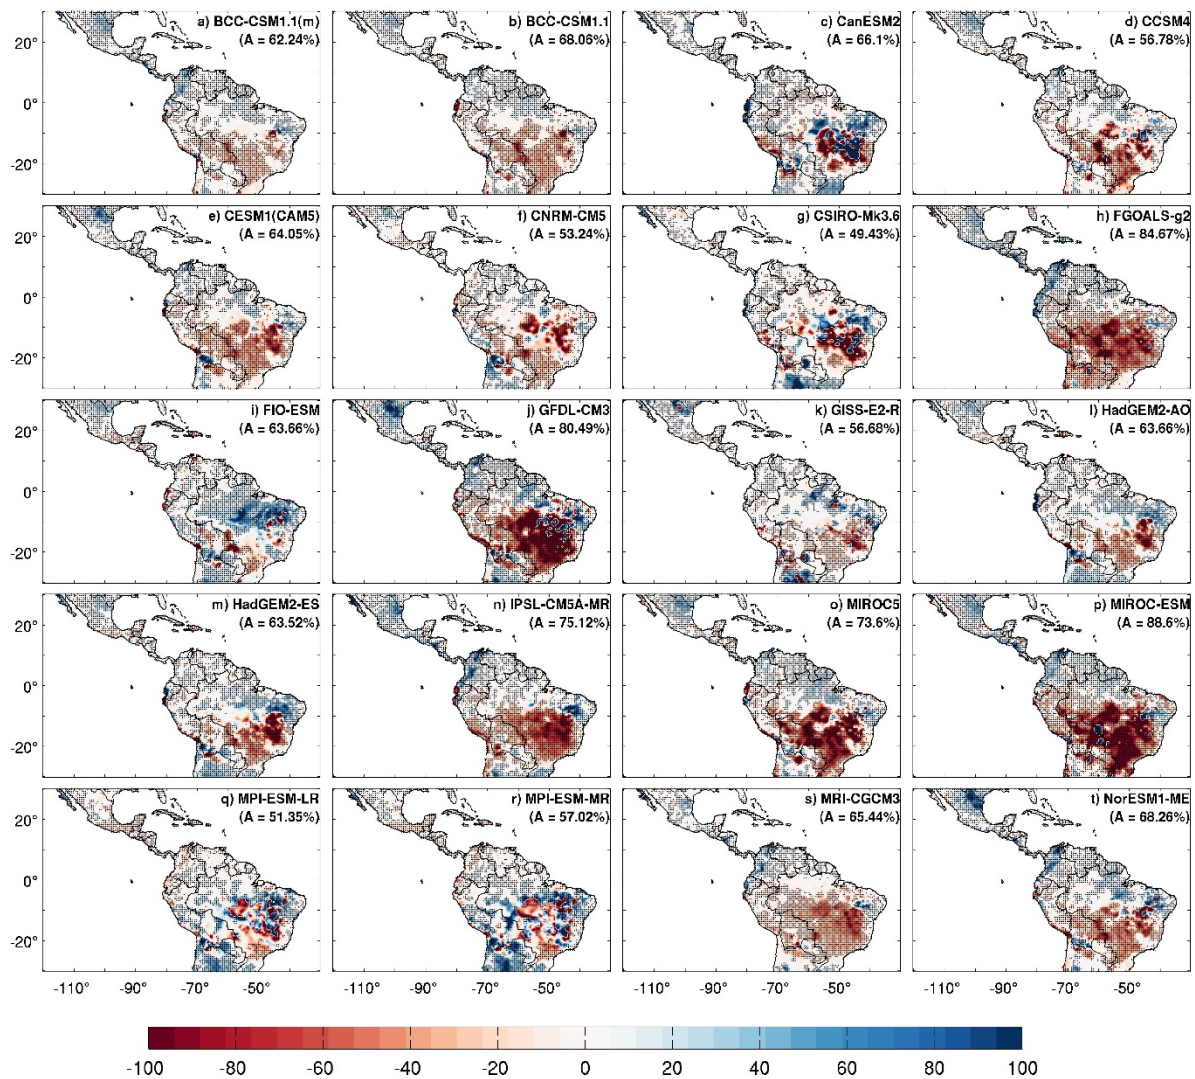


Figura 6.15. Al igual que la Figura 6.13, pero para el escenario RCP8.5.

6.3.4 Cambios proyectados en la precipitación para la otoño (SON)

Las Figuras 6.16, 6.17 y 6.18, muestran los cambios en porcentaje respecto al presente proyectados para el periodo 2071-2100 en la precipitación según el DS de los GCMs en los tres RCPs en la estación de otoño. Para esta estación hay un ligero predominio de aumentos significativos de la precipitación proyectada, y al igual que para las estaciones ya comentadas, un aumento de los cambios a medida que aumenta la concentración de gases de efecto invernadero.

En el RCP2.6, como en las estaciones anteriores, aparecen modelos que proyectan cambios muy débiles y poco extensos, afectando a menos de un 20% del territorio (CCSM4 (d), ESM1(CAM5) (e), CNRM-CM5 (f), GISS-E2-R (k), IPSL-CM5A-MR (n), NorESM1-ME (t)).

Destacan los aumentos significativos en el noreste de Brasil y en zonas cercanas al Atlántico en el norte de Sudamérica en el DS de los modelos GFDL-CM3 (j) alcanzando en ciertas áreas el 90% , HadGEM2-ES (m) con cambios del orden del 60% y HadGEM2-AO(l), y MIROC-ESM (p), con aumentos más moderados (20-30%). Estos modelos también muestran aumentos significativos en Chile y oeste de Argentina y descenso moderados en grandes áreas dentro de la franja latitudinal entre aproximadamente 2°N y 15°S. Este último aspecto es también recogido por el DS de los modelos CESM1(CAM5) (e) y FGOALS-g2 (h). Una señal bastante consistente es mostrada en la zona más oriental de Brasil, con descensos significativos en 13 modelos (aunque para algunos de forma débil y poco extendida). Para Centroamérica y otras áreas, los cambios no son significativos o poco consistentes entre modelos. Llama la atención el patrón de cambio del modelo FIO-ESM (i), casi opuesto al del GFDL-CM3 (j).

Para el RCP4.5, los resultados son muy parecidos a los de RCP2.6, habiendo una mayor extensión de áreas con cambio significativo (excepto para el MPI-ESM-LR (q) y MPI-ESM-MR (r)). El aumento de la precipitación mostrado por los modelos ya comentados para el RCP2.6, se extiende e intensifica en ellos, y aparece de forma clara en otros como el BCC-CSM1.1 (m) (a), BCC-CSM1.1 (b), MIROC5 (o) o NorESM1-ME (t), siendo pues una señal consistente entre muchos modelos.

Por último, para el RCP8.5, el DS de todos los modelos muestra un porcentaje de área con cambios significativos muy elevado, sólo el CNRM-CM5 (f) presenta menos de un 50% de área con cambios (45.9%). El aumento significativo de la precipitación en el noreste de Brasil, aparecen en 13 modelos (con extensión e intensidad variable entre ellos), indicando una elevada coherencia de este cambio. En algunos casos, el área con aumento se extiende considerablemente tanto hacia el norte, incluyendo gran parte del norte de Sudamérica, por encima del ecuador, y sur de Centroamérica, con aumentos que no suelen superar el 30%, salvo en el sur de Guyana, donde llega a superar el 100%, como hacia el sur, hacia el interior de Brasil. Aún así, un número considerable de modelos muestran descensos significativos de la precipitación en una amplia zona de Brasil en diagonal, desde Colombia, hasta su costa más meridional, que incluye también la mayor parte de Bolivia y Paraguay y en algunos casos el norte de Argentina, (p. e., GFDL-CM3 (j), CanESM2 (c), MIROC5 (q), MIROC-ESM (p)). Otras áreas con un comportamiento similar en un número considerable de modelos (15) es la zona más oriental de Brasil, con descensos de la precipitación, que en algunos casos superan el 80% (CanESM2 (c), HadGEM2-ES (m)), la costa de Ecuador, que muestra aumentos en el DS de 12 modelos (muy intensos en

IPSL-CM5A-MR (n), NorESM1-ME (t)) y, la zona de Bahía en Brasil (en casi todos los modelos, con más o menos extensión e intensidad) con aumentos de no más del 40%, y Chile y sur este de Argentina (en torno a las 25°S, 72°W) con 14 modelos reportando aumentos marcados (entre 60-80%, p.e., HadGEM2-ES (m)). No existe una señal clara para México, aunque prevalecen los descensos en la zona central (muy intensos en el CAnESM2 (c) y MIROC5 (o)) y aumentos en Baja California y este.

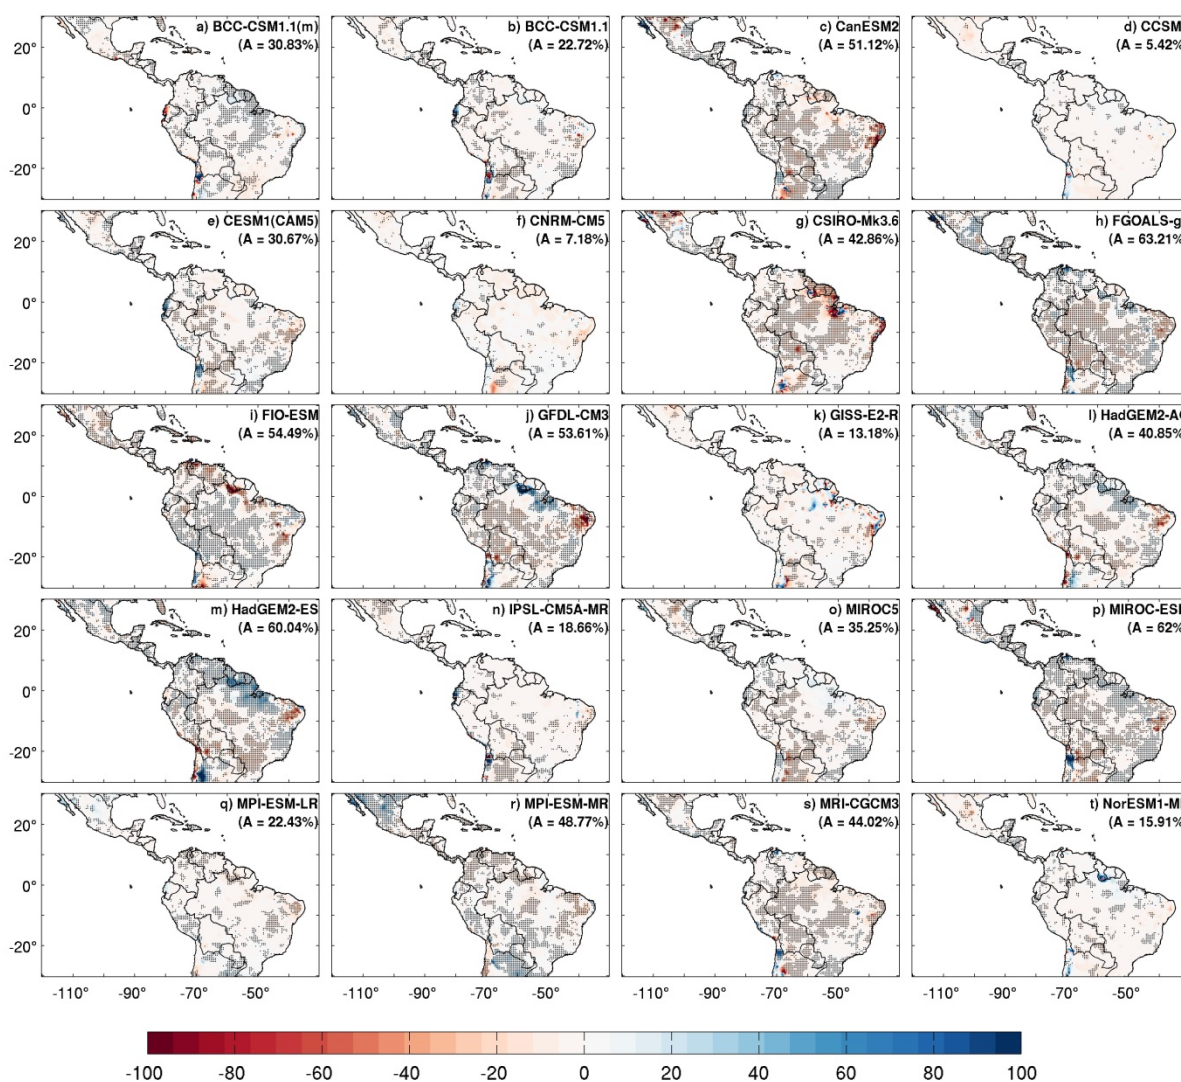


Figura 6.16. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando los 20 modelos del CMIP5 en el escenario RCP2.6 para SON. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

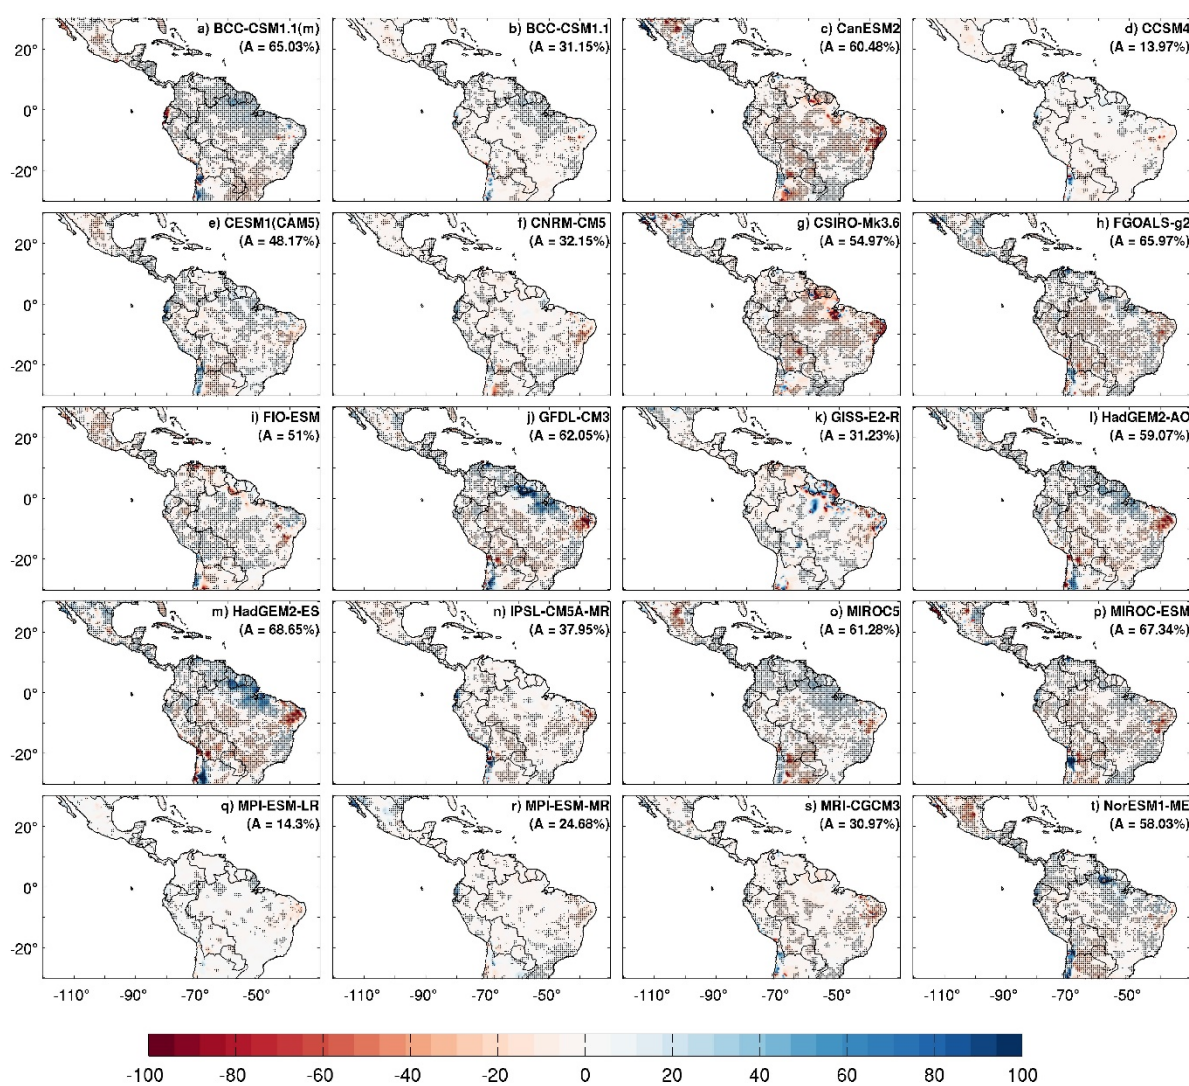


Figura 6.17. Al igual que la Figura 6.16, pero para el escenario RCP4.5.

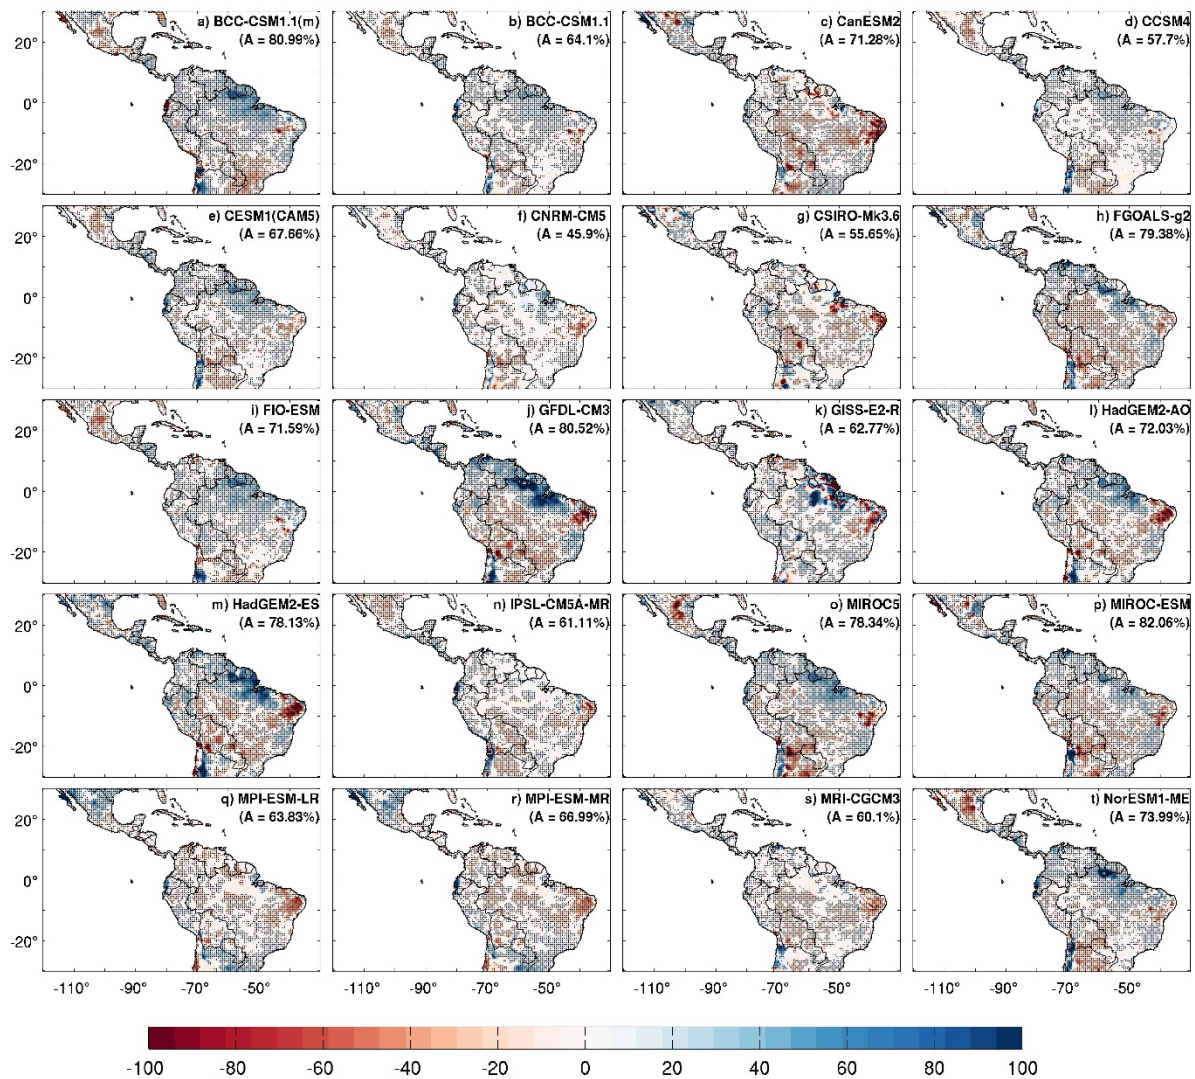


Figura 6.18. Al igual que la Figura 6.16, pero para el escenario RCP8.5.

El Apéndice A, se muestran los cambios porcentuales obtenidos comparando las salidas de los GCMs en los distintos escenarios en el periodo 20171-2100 respecto a sus salidas históricas en el periodo 1971-2000. En muchos casos, estas estimaciones contrastan de forma muy marcada con las de los GCMs, de tal forma que un GCM y su DS pueden mostrar cambios significativos muy opuestos (por ejemplo, en verano bajo el RCP8.5 para el BCC-CSM1.1 (m) (a), CESM1 (CAM5) (e) HadGEM2-AO (l), Figura 6.13 vs. Apéndice B). Como cabe esperar en el proceso de *downscaling*, el patrón espacial de cambios es menos uniforme que en los GCMs, pudiendo discernir comportamientos diferentes en zonas relativamente cercanas. Más aún, el DS tiende, en muchos casos, a mostrar un mejor acuerdo en los cambios proyectados (al menos en su signo) con diversos GCMs que estos directamente.

6.4 Análisis de las incertidumbre

El análisis de la incertidumbre en las proyecciones mediante DS se ha abordado a partir de los resultados del DS tanto en el clima presente como futuro para las distintas zonas seleccionadas (Capítulo 2 y 5). Las Figuras 6.19 a 6.34 presenta los diagramas de cajas (*box-plots*) obtenidos a partir de 1000 réplicas *bootstrap* de las estimaciones medias de la precipitación tras el DS en clima presente (1971-2000) y los tres RCPs considerados (en el periodo 2071-2100), en los que se señalan los percentiles 2.5, 25, 75 y 97.5 de estas réplicas, junto con su mediana y la media de los datos observaciones y de las salidas de los GCMs en bruto para cada una de las zonas y cada uno de los GCMs empleados. De esta forma, los *box-plot* dan una aproximación de la distribución muestral de los cambios obtenidos, y una cuantificación de los errores en las proyecciones. Así pues, el objetivo es ahora considerar más en detalle la incertidumbre en la respuesta del DS de cada modelo y sus errores, más que la discusión de los cambios proyectados en estas regiones, que ya han sido analizadas en el apartado anterior.

De manera general, para todas las estaciones del año, el DS de los modelos en clima presente da una aceptable representación del valor medio de la precipitación, con independencia de la zona y del GCM. Así, la mayoría de los valores medios de la precipitación observada caen dentro del rango intercuartílico del *bootstrap*, estando en muchas ocasiones cercana a la mediana de las estimaciones. También de forma general, se tiene que un número apreciable de GCMs presentan valores muy altos o muy bajos respecto tanto a l valor medio observacional como a l as estimaciones DS, lo cual puede deberse a una inadecuada representación de los procesos físicos asociados a la precipitación y a la baja resolución de la topografía, quedando así por encima o por debajo de los percentiles 2.5 y 97.5, de tal forma que el DS parece corregir estos importantes sesgos. Por otro lado, la amplitud de los intervalos de confianza al 95 %, determinados por los percentiles 2.5 y 97.5 del *bootstrapping*, tiende a mostrar un rango más o menos estable tanto para el presente como el futuro sin grandes diferencias entre los RCPs. Esto es, no parece haber una dependencia con el RPC, ya que el tamaño de las cajas y de los intervalos de confianza para cada región y GCM suele ser parecido, aunque ligeramente mayor para el RCP8.5, lo que indicaría algo más de incertidumbre. Debe también destacarse que las amplitudes de las incertidumbres (intervalo de confianza) muy variables según modelo y zona, e incluso estación del año, de tal forma que tiende a ser más pequeñas en periodos y zonas húmedas, pudiendo oscilar entre menos

del 20% (por ejemplo, zona 6 (zn6) en verano con el CNRM-CM5) a más del 150% (por ejemplo, zona 7, en primavera con el FGOALS-g2).

Para el invierno (Figuras 6.19 a 6.22), que es la estación seca en todas las zonas analizadas, para aquellas con menor precipitación, hay casos en las que las estimaciones DS toman valores negativos, pero estas suelen caer por debajo del percentil 2.5, o en el peor de los casos (zona 1, HadGEM2-AO, HadGEM2-ES) por debajo del percentil 25, lo cual no es de extrañar dada la naturaleza estadística del modelo. En otras situaciones, el DS da estimaciones más realistas y físicamente coherentes que el GCM, así para la zona 6 diversos GCMs dan valores promedio de la precipitación muy cercanos a cero (CSIRO-Mk3.6, GDFL-CM3, HadGEM2-AO, HadGEM-ES, MRI-CGCM3) mientras que los promedios de los DS son superiores. La anchura de la caja, es decir, el rango intercuartílico, y entre los percentiles extremos varía de una región a otra y entre los GCMs, aunque para los GCMs HadGEM2-AO, HadGEM2-ES, IPSL-CM5A-MR, MPI-ESM-LR y MPI-ESM-MR, la dispersión del *bootstrapping* (y por tanto su error estadístico) es sustancialmente más pequeña, mientras que la dispersión en modelos como el CCSM4, CSIRO-Mk3.6 y MIROC-ESM presenta en general, una mayor dispersión. Por otro lado, no parece haber una dependencia con el RPC, ya que el tamaño de las cajas para cada región y GCM suele ser parecido, aunque ligeramente mayor para el RCP8.5, lo que indicaría algo más de incertidumbre.

Para el verano (Figuras 6.23 a 6.26) se obtienen conclusiones similares. Teniendo en cuenta que esta estación es la más lluviosa en todas las zonas, la incertidumbre está más acotada, de forma que los rangos intercuartílicos del *bootstrapping* tiende a ser más pequeños en relación a la mediana. Destacan en ese sentido los resultados para los GCMs HadGEM2-AO, HadGEM2-ES, IPSL-CM5A-MR, MPI-ESM-LR y MPI-ESM-MR que muestra intervalos de confianza más pequeños.

Tanto para la primavera (Figuras 6.27 a 6.30) como para el otoño (Figuras 6.31 a 6.34), las incertidumbres tienden a crecer, con un aumento del rango intercuartílico respecto a valor medio, más acusado en primavera, lo que indicaría una peor representación de la precipitación en las estaciones de tránsito. De nuevo hay una mayor dependencia de la incertidumbre respecto al GCM, volviendo a destacar los mismos GCMs que en las estaciones de invierno y verano, con incertidumbres más acotadas (HadGEM2-AO, HadGEM2-ES, IPSL-CM5A-MR, MPI-ESM-LR y MPI-ESM-MR, aunque en menor medida para la primavera). Los modelos que muestran las

mayores incertidumbres en un mayor número de zonas son en primavera son es el FGOALS-g2, FIO—ESM y MIROC-ESM, mientras que para el otoño son el CanESM2 y el MIROC-ESM. Llama la atención que la zona 5 presenta una incertidumbre muy acotada en la mayoría de los modelos en primavera. Esta misma condición se tiene para la zona 7 en otoño.



Figura 6.19. Box-plot de la precipitación promedio de DEF (en mm) obtenido del DS para las simulaciones históricas (H) (1971-2000) y de futuro (2071-2100) para las diez regiones (filas) considerados para los cinco modelos SD indicados (columnas) bajo los tres escenarios PCR (2.6, 4.5, 8.5). Las líneas rojas representan los valores medios, "◇" es la media observada, "□" es el valor medio dado por el GCM, y "+" son valor atípicos (outliers). Los percentiles mostrados (2,5, 25, 75 y 97.5) se han determinado mediante bootstrapping de 1000 remuestreos.

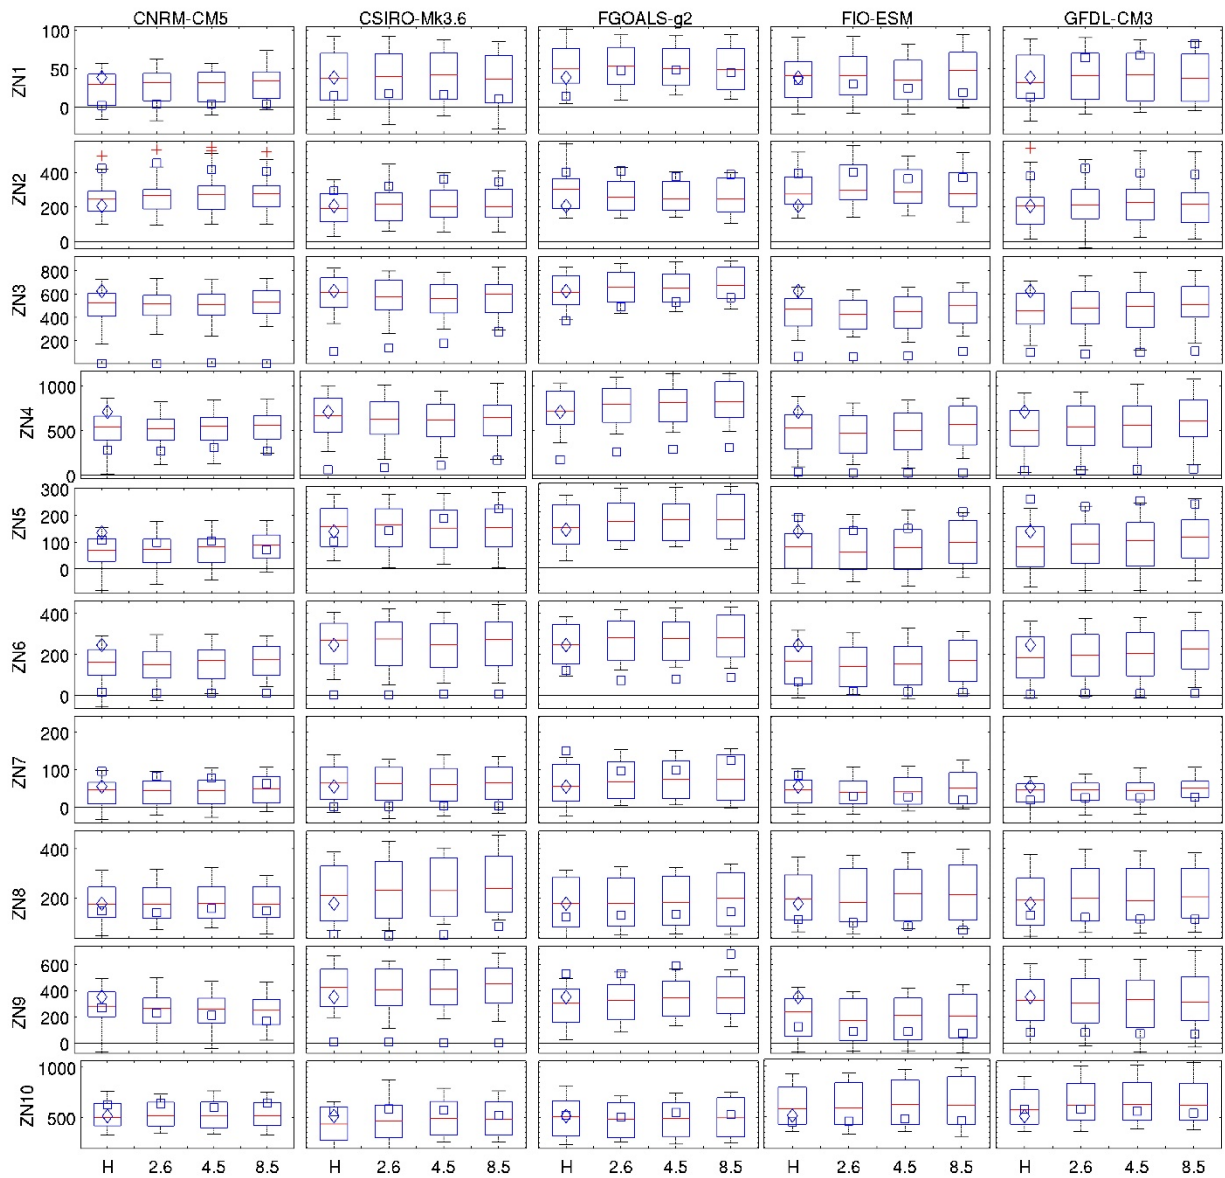


Figura 6.20. Como la Figura 6.19 para los GCMs indicados en la parte superior de cada columna.

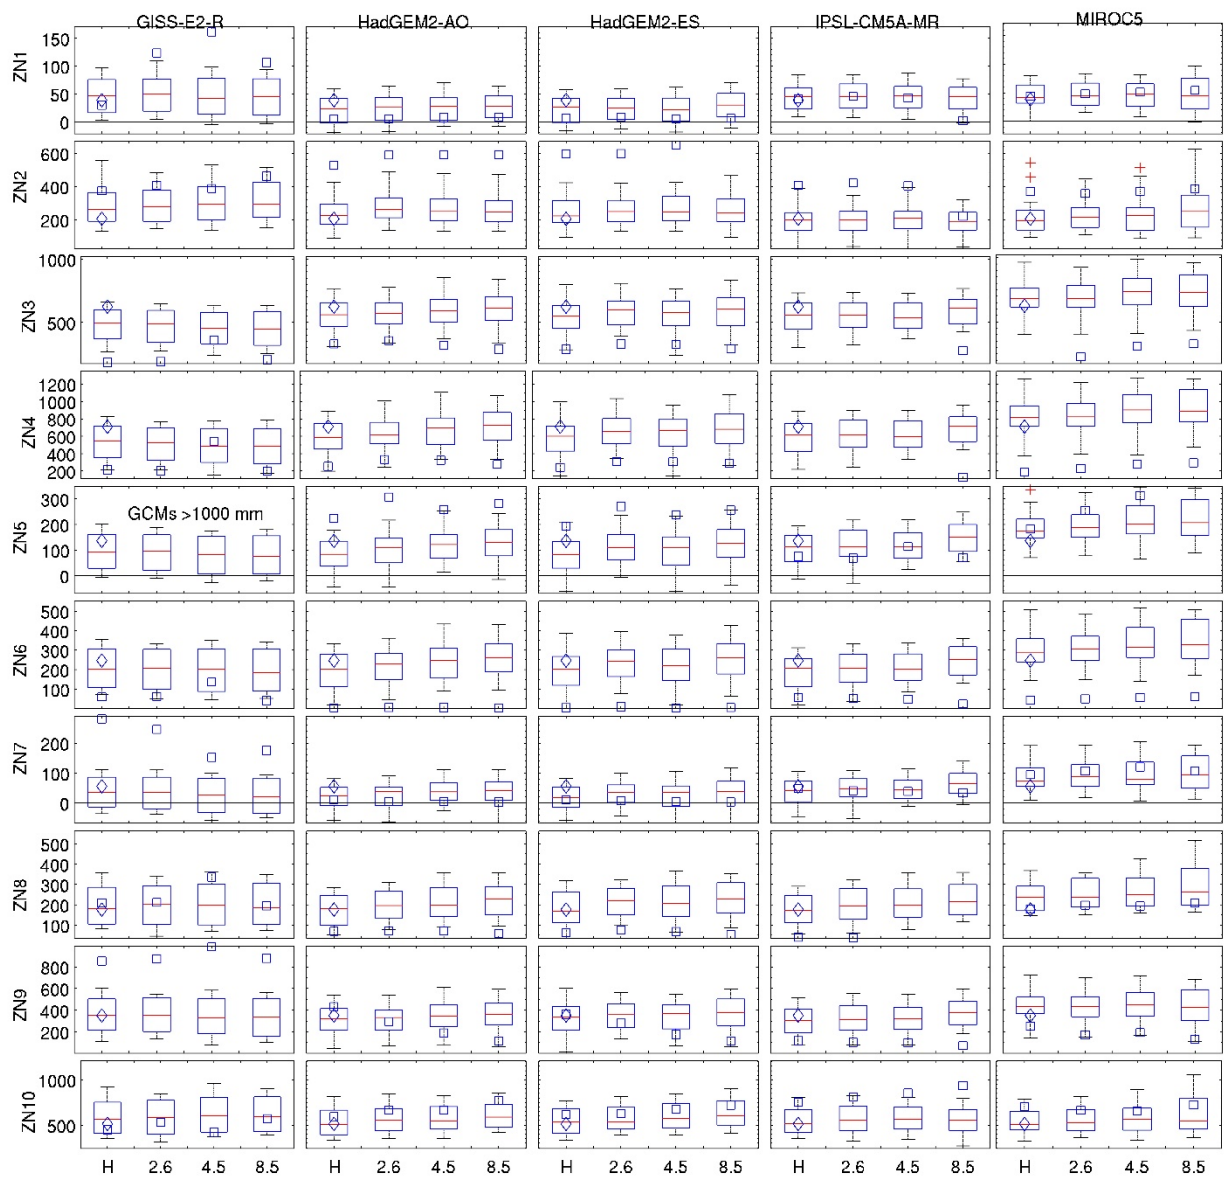


Figura 6.21. Como la Figura 6.19 para los GCMs indicados en la parte superior de cada columna.



Figura 6.22. Como la Figura 6.19 para los GCMs indicados en la parte superior de cada columna.

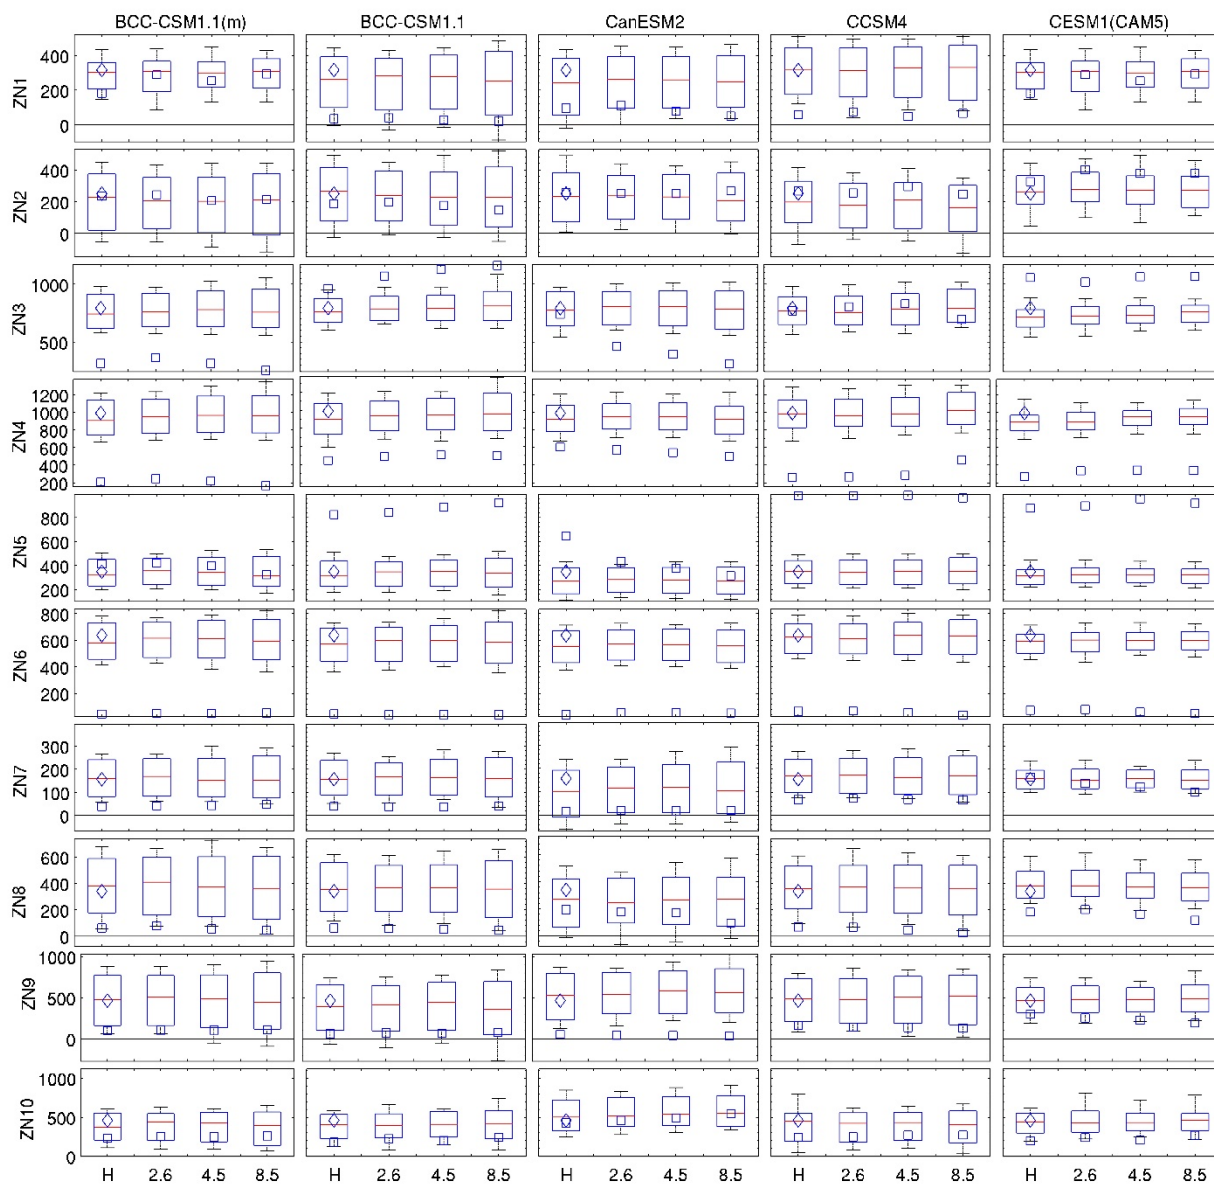


Figura 6.23. Box-plot de la precipitación promedio de MAM (en mm) obtenido del DS para las simulaciones históricas (H) (1971-2000) y de futuro (2071-2100) para las diez regiones (filas) considerados para los cinco modelos SD indicados (columnas) bajo los tres escenarios PCRs (2.6, 4.5, 8.5). Las líneas rojas representan los valores medios, "◇" es la media observada, "□" es el valor medio dado por el GCM, y "+" son valor atípicos (outliers). Los percentiles mostrados (2,5, 25, 75 y 97.5) se han determinado mediante bootstrapping de 1000 remuestreos.

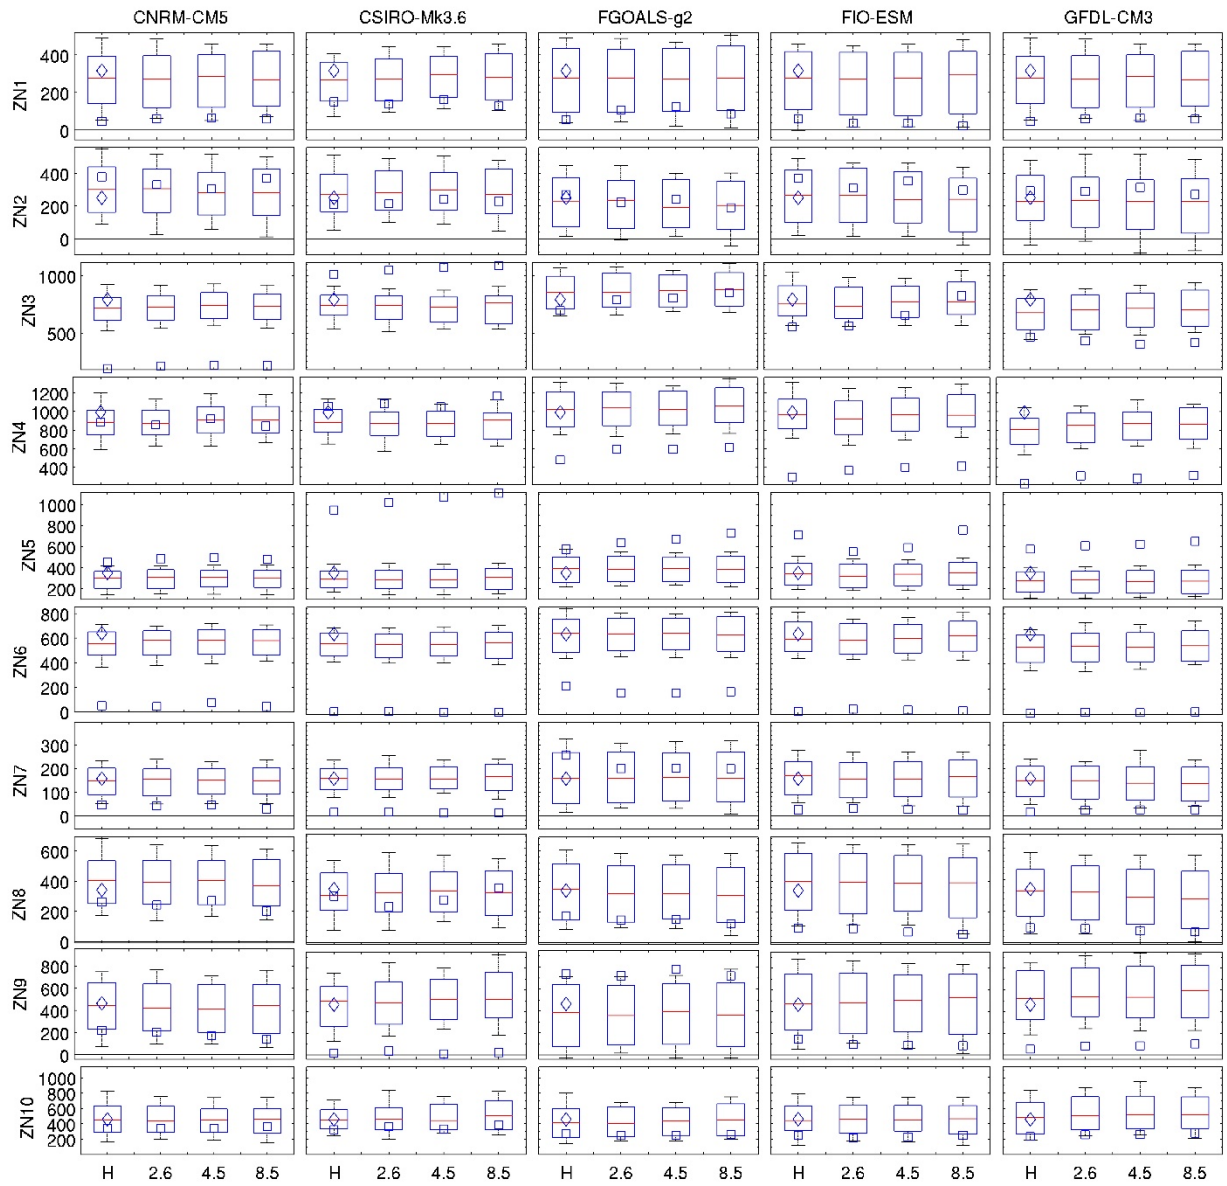


Figura 6.24. Como la Figura 6.23 para los GCMs indicados en la parte superior de cada columna.

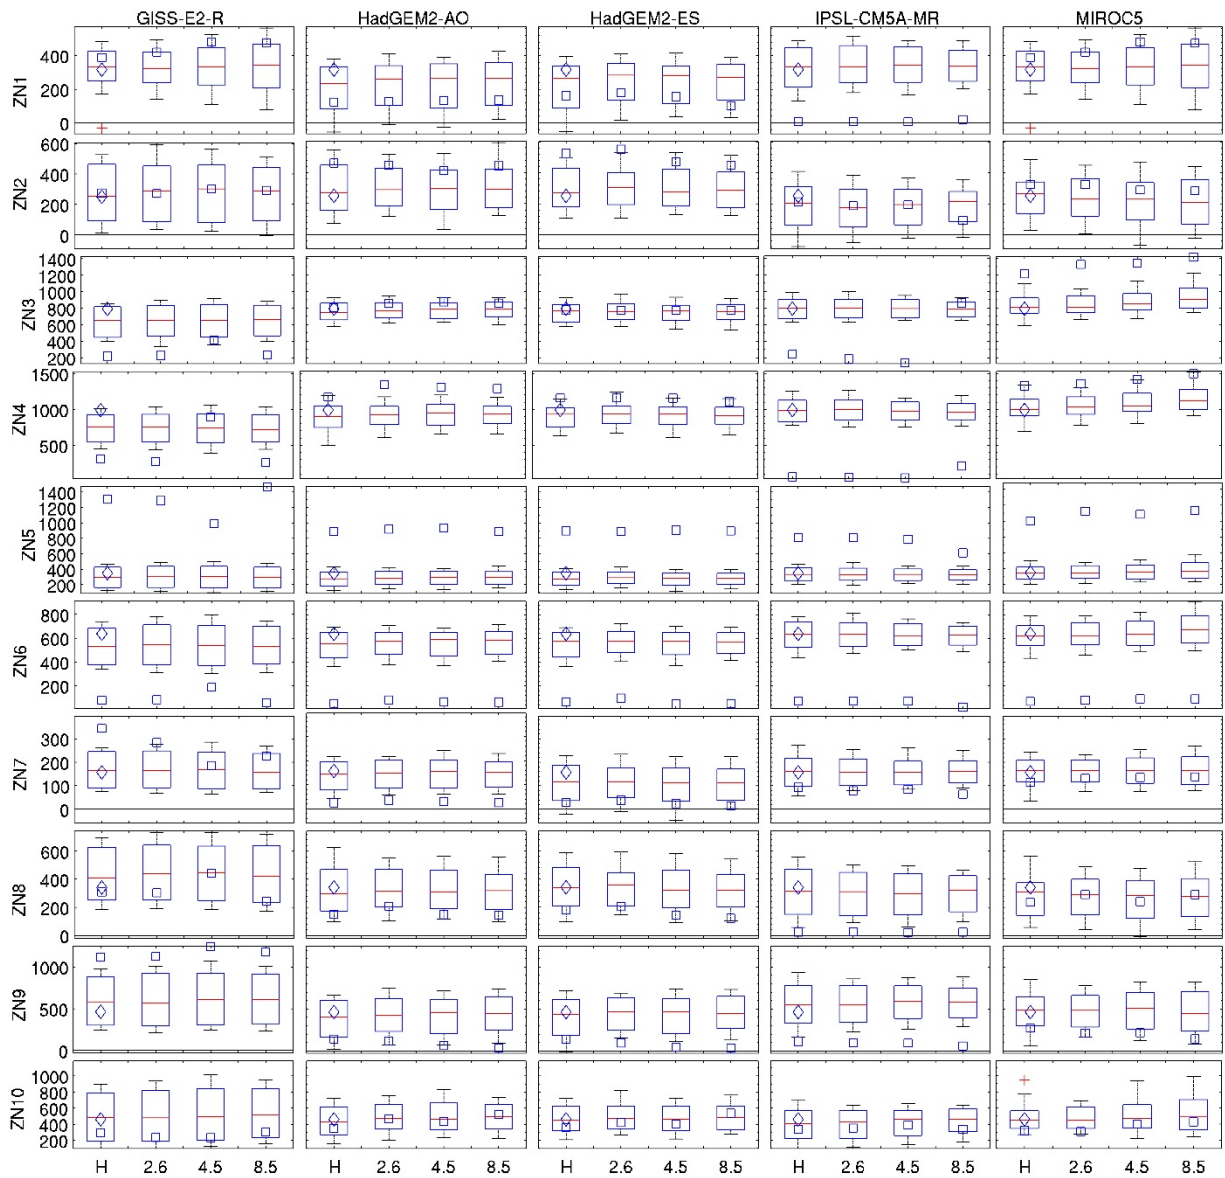


Figura 6.25. Como la Figura 6.23 para los GCMs indicados en la parte superior de cada columna.



Figura 6.26. Como la Figura 6.23 para los GCMs indicados en la parte superior de cada columna.

6.5 Conclusiones

En este capítulo se ha abordado la configuración final del modelo DS, con su recalibración con el periodo completo 1950 -2010, y se ha analizado cómo se ha aplicado a los 20 GCMs seleccionados del CMIP5 en clima presente reproduce los datos observacionales del GPCC en el periodo de referencia para clima presente 1971-2000. Así, se han obtenido las diferencias en porcentaje entre la precipitación DS y la observada, evaluando su significación con el test de Wilcoxon-Mann-Whitney. La principal consecuencia de este análisis es la adecuada

representación del campo medio de la precipitación estacional mediante el DS, de tal forma que, considerando el promedio del área para todos los DS, menos de aproximadamente el 20% del área en estudio, presenta cambios significativos de la precipitación DS respecto a las observaciones, siendo además, en general de cuantía pequeña. El invierno es la estación que presenta menos diferencias significativas, siendo en ese sentido en la que el DS mejor reproduce la precipitación. Así, el DS corrige de forma apreciable importantes desviaciones de la precipitación media mostradas por los diversos GCMs, dando una representación más acertada del campo medio de precipitación sobre el área de estudio, además de mejorar la resolución de las mismas, pasando de resoluciones en torno a los $2^\circ \times 2^\circ$ a la del GPCC, $0.5^\circ \times 0.5^\circ$.

Para el periodo 2071-2100 se han obtenido proyecciones regionalizadas de la precipitación en cada estación del año mediante el DS de los 20 GCMs seleccionados con las trayectorias de concentración representativas RCP2.6, RCP4.5 y RCP8.5. La evaluación de los cambios proyectados se ha obtenido a través de la diferencia porcentual de la precipitación DS en el periodo 2071-2100 respecto a la precipitación DS en el periodo presente 1971-2000, siguiendo el esquema de Lind Smith (2009) y Palomino-Lemus et al. (2015), y estableciendo su significación estadística mediante el test de Wilcoxon-Mann-Whitney.

En general, la extensión del área afectada por cambios significativos así como la intensidad de los mismos aumenta al aumentar el forzamiento radiativo. Los resultados para los RCP2.6 y RCP4.5 son muy parecidos en algunos modelos, obteniéndose, en general, cambios pequeños. Estos son más claros para el RCP8.5, en el cual para todas estaciones del año, hay marcadas y extensas variaciones, coherentes para el DS de un número considerable de GCMs. El invierno es la estación que parece tener menos cambios; la señal hacia un descenso de la precipitación es bastante coherente para gran parte de México, con descensos del 30 al 90% y en el oeste de Colombia con ascensos que pueden llegar a ser del 80%. Para el verano, se acentúan los cambios, estando casi toda el área afectada por cambios significativos bajo el RCP8.5. Incluso para el RCP4.5 se encuentra un descenso muy intenso y coherente sobre una amplia zona en Brasil, desde aproximadamente los 10°S , 60°W , en el Mato Grosso, hasta la costa oriental y sur de Brasil. En el RCP8.5 este cambio se incrementa en área e intensidad, apareciendo también un aumento coherente en el norte de Sudamérica y Centroamérica siendo el noreste de México la región más afectada, con aumentos que llegan a un 60%. Un número considerable de modelos también muestra un aumento de la precipitación al norte de Argentina, que oscila entre el 30% - 90%. Es interesante destacar cómo el DS de algunos modelos puede mostrar cambios

significativos de signo apuesto en zonas relativamente cercanas, mostrando el GCM un patrón de cambio mucho más uniforme. Esto puede poner de manifiesto la capacidad del DS para corregir la vasta resolución de los modelos.

En la estación de primavera, tanto en el RCP4.5 como en el RCP8.5 (de forma más extensa, marcada y coherente) aparecen dos zonas con aumentos significativos en el noreste de Sudamérica (Venezuela, Guayana, Surinam) y sur de Brasil, Paraguay y noreste de Argentina, y descensos en el centro y norte de Brasil y en el sur de Bolivia y noreste de Argentina. La zona este de Brasil presenta marcados descensos, del 70 % en el RCP4.5 y demás del 80% en el RCP8.5. En otoño, destaca el marcado incremento de la precipitación en el noreste de Brasil, muy consistente en el RCP8.5, extendiéndose para el DS de algunos GCMs tanto hacia el norte como hacia el interior de Brasil, y que puede llegar a aumentos muy elevados (más del 80%) según la zona y el GCM. Existen también descensos muy coherentes para el área más oriental de Brasil, que pueden llegar al 80% de la precipitación y en una amplia zona en el oeste de Brasil, en diagonal desde Colombia hasta Paraguay y norte de Argentina.

En muchos casos, estas estimaciones contrastan de forma muy marcada con las de los GCMs, de tal forma que un GCM y su DS pueden mostrar cambios significativos muy opuestos. Como cabe esperar en el proceso de *downscaling*, el patrón espacial de cambios es menos uniforme que en los GCMs, pudiendo discernir comportamientos diferentes en zonas relativamente cercanas. Más aún, el DS tiende, en muchos casos, a mostrar un mejor acuerdo en los cambios proyectados (al menos en su signo) con diversos GCMs que estos directamente.

La incertidumbre de las proyecciones mediante DS se ha analizado a partir de los intervalos de confianza estimados mediante *bootstrapping* para las 10 zonas seleccionada en el Capítulo 5.

En general, el DS de los modelos en clima presente se aproxima al valor medio de la precipitación, con independencia de la zona y del GCM, de tal forma que los valores medios de la precipitación observada suelen caer dentro del rango intercuartílico del *bootstrap*. También de forma general, se tiene que un número apreciable de GCMs presentan valores muy altos o muy bajos respecto tanto al valor medio observacional como a las estimaciones DS, lo cual puede deberse a una inadecuada representación de los procesos físicos asociados a la precipitación y a la baja resolución de la topografía, quedando así por encima o por debajo de los percentiles 2.5 y 97.5, de tal forma que el DS parece corregir estos importantes sesgos. Por otro lado, la amplitud

de los intervalos de confianza al 95 %, tiende a mostrar un rango similar tanto para el presente como el futuro sin grandes diferencias entre los RCPs, aunque ligeramente mayor para el RCP8.5, lo que indicaría algo más de incertidumbre. Debe también destacarse que las amplitudes de las incertidumbres (intervalo de confianza) muy variables según modelo y zona, e incluso estación del año, de tal forma que tiende a ser más pequeñas en periodos y zonas húmedas, pudiendo oscilar entre menos del 20% a más del 150 %.

CAPÍTULO 7

CONCLUSIONES

En este capítulo se resumen las principales conclusiones obtenidas en el trabajo llevado a cabo en esta Tesis Doctoral. El estudio consiste en la obtención de proyecciones de cambio climático para la precipitación en América tropical mediante técnicas de *downscaling* estadístico. En primer lugar se ha realizado una evaluación de la SLP de los GCMs del CMIP5, ya que esta variable ha sido la usada como variable predictora de la precipitación en los modelos de *downscaling*. Mediante Regresión por Componentes Principales se construye el modelo de *downscaling*, que es finalmente aplicado a las salidas de los GCMs bajo los diferentes RCPs considerados en el periodo 2071-2100 dando lugar a las proyecciones de la precipitación.

La principal motivación de esta Tesis radica en la necesidad de mejorar el conocimiento del impacto del cambio climático en la región de América tropical, y en particular en los cambios que puedan acaecer en la precipitación. Para ello se ha llevado a cabo un *downscaling*

estadístico de la precipitación estacional en el área tomando como campo predictor la presión a nivel del mar (SLP) de la región del Pacífico tropical, ya que esta es una de las variables globales más importantes a la hora de describir el clima de la zona de estudio.

Las principales conclusiones de este estudio son:

Se han evaluado en detalle la habilidad de 40 GCMs del CMIP5 para simular la SLP en la zona tropical en el Pacífico, cuya influencia es básica para describir la variabilidad climática en América tropical. Esto es de particular importancia pues esta variable es la empleada como predictora de la precipitación en el modelo de *downscaling*. Así, se han comparado las salidas históricas (de 1950-2005) de los GCMs con los datos de SLP del reanálisis NCEP y con los datos observacionales del HadSLP2.

En la evaluación de la SLP de los 40 GCMs del CMIP5 analizados en la zona tropical del Pacífico se ha encontrado que, en general, los GCMs reproducen el patrón espacial del campo medio de la SLP, sin que haya desviaciones de más de 10 hPa, con cierto predominio de subestimaciones de la SLP en el Pacífico tropical occidental, y sobrestimaciones en el área continental occidental, sobre todo los Andes. El modelo HadCM3 destaca por ser el único que muestra de forma sistemática sobrestimaciones sobre casi todo el área. Respecto a la varianza, las variaciones no suelen ser significativas, siendo los modelos de IGSS los que suelen subestimar de forma más general, marcada y significativa y los del GFDL (sobre todo el GFDL-ESM2M) los que tienden a sobreestimarla.

En cuanto a la reproducibilidad de los principales modos de variabilidad de la SLP, caracterizados por los primeros REOFs del NCEP, los resultados muestran que la mayoría de los modelos tienden a hacer una buena representación de los dos primeros modos de variabilidad. En general, a escala mensual, casi todos los modelos exhiben valores superiores de la varianza total explicada por el primer modo de variabilidad respecto al obtenido a partir de las bases de datos de reanálisis y observacional, mientras que el segundo tiene a presentar valores más parecidos a los obtenidos a partir de estas bases. Además, para la mayoría de los modelos, la correlación espacial entre el segundo modo de variabilidad y las bases observacionales presentan valores por encima de 0.9, mientras que para el REOF1, un número elevado de los modelos presentan valores de estas correlaciones por debajo de 0.9, aunque una gran mayoría se mantienen por encima de 0.8. De manera análoga existe una mayor dispersión en los valores de RMSE para los

primeros REOFs de los modelos que para los REOF2, estando en cualquier caso acotados entre 0.25 y 0.1.

Para el análisis estacional, las simulaciones históricas de los 40 modelos del CMIP5 considerados representan de forma aceptable las principales características de la SLP del NCEP. Al igual que en el análisis mensual, el primer modo de variabilidad de los GCMs tiende a sobrestimar la varianza explicada, mientras que el segundo tiende a mostrar valores más parecidos o a subestimarla. De manera general, es durante el invierno cuando los dos primeros modos de variabilidad de la SLP son mejor reproducidos, para la primavera y el otoño, el primer modo de variabilidad tiende a ser mejor reproducido, mientras que lo contrario ocurre durante el verano, siendo esta estación la que muestra, para algunos modelos, una reproducibilidad más deficiente. En cualquier caso, los patrones de variabilidad caracterizados por los REOFs en los modelos esencialmente capturan la variabilidad mostrada por los REOFs del NCEP, siendo difícil establecer un rango que determine qué modelos son mejores en la reproducción de los mismos de forma general, pues hay diferencias en el comportamiento de los modelos según la época del año.

Se ha desarrollado el modelo de DS de la precipitación mediante PCR usando como predictores las series PCs de la SLP de los datos de NCEP. Estos predictores se han seleccionado de forma rigurosa en función de la significación de su correlación con la precipitación. Los modos de variabilidad ligados al fenómeno ENSO pueden describir forma satisfactoria la precipitación de diversas áreas de América tropical.

En general, el DS muestra un funcionamiento adecuado en extensas áreas dentro del dominio analizado, más reducidas cuando se analiza el periodo de validación (1994-2010) en todas las épocas del año. Esto puede ser debido a la peor cobertura de datos en el GPCC en determinadas áreas (por ejemplo, áreas selváticas del Amazonas y Orinoco, y Andes) y, en particular en los últimos años. Cabe también señalar que el modelo muestra una habilidad en la reproducción de la precipitación más modesta durante la primavera, tanto en el periodo de calibración (1950-93) como de validación (1994-2010), lo cual puede estar relacionado con modulaciones de los patrones atmosféricos asociadas al paso de la Zona de Convergencia Intertropical (ITCZ).

En general, las mayores discrepancias y errores tienden a presentarse en áreas y épocas con una precipitación muy baja como, por ejemplo, este de los Andes, noroeste de México y sur

de Bolivia, en las que elevados cambios en porcentaje implican, sin embargo, variaciones pequeñas en valor absoluto.

Adicionalmente, el modelo DS para 10 zonas en las que existe una aceptable cobertura de datos, con características climáticas bien definidas y en áreas donde el DS realizado en cada punto de rejilla funciona adecuadamente, muestra una buena habilidad, particularmente para las estaciones de invierno y verano, siendo más moderada para el otoño y sobre todo, en primavera. Para algunas zonas, el DS llega a simular valores extremos de la precipitación. Para algunas zonas, las estimaciones del DS para el periodo de validación son algo peores, lo cual puede estar relacionado con un descenso en el número de estaciones de medida incluidas en el GPCC en los últimos años.

El modelo DS, una vez recalibrado para el periodo completo 1950-2010, se ha aplicado a 20 GCMs seleccionados del CMIP5 en clima presente. La principal consecuencia de este análisis es la adecuada representación del campo medio de la precipitación estacional mediante el DS, de tal forma que, considerando el promedio del área para todos los DS, menos de aproximadamente el 20% del área en estudio, presenta cambios significativos de la precipitación DS respecto a las observaciones, siendo además, en general de cuantía pequeña. El invierno es la estación que presenta menos diferencias significativas, siendo en ese sentido en la que el DS mejor reproduce la precipitación. Así, el DS corrige de forma apreciable importantes variaciones de la precipitación media mostradas por los diversos GCMs, dando una representación más acertada del campo medio de precipitación sobre el área de estudio, además de mejorar la resolución de las mismas, pasando de resoluciones en torno a los $2^\circ \times 2^\circ$ a la del GPCC, $0.5^\circ \times 0.5^\circ$.

Para el periodo 2071-2100 se han obtenido proyecciones regionalizadas de la precipitación en cada estación del año mediante el DS de los 20 GCMs seleccionados con las trayectorias de concentración representativas RCP2.6, RCP4.5 y RCP8.5. La evaluación de los cambios proyectados se ha obtenido a través de la diferencia porcentual de la precipitación DS en el periodo 2071-2100 respecto a la precipitación DS en el periodo presente 1971-2000.

En general, la extensión del área afectada por cambios significativos así como la intensidad de los mismos aumenta al aumentar el forzamiento radiativo. Los resultados para los RCP2.6 y RCP4.5 son muy parecidos en algunos modelos, obteniéndose, en general, cambios pequeños. Estos son más claros para el RCP8.5, en el cual, para todas estaciones del año, hay marcadas y extensas variaciones, coherentes para el DS de un número considerable de GCMs. El

invierno es la estación que parece tener menos cambios; la señal hacia un descenso de la precipitación es bastante coherente para gran parte de México, con descensos del 30 al 90% y en el oeste de Colombia con ascensos que pueden llegar a ser del 80%. Para el verano, se acentúan los cambios, estando casi toda el área afectada por cambios significativos bajo el RCP8.5. Incluso para el RCP4.5 se encuentra un descenso muy intenso y coherente sobre una amplia zona en Brasil, desde aproximadamente los (10°S, 60°W), hasta la costa oriental y sur de Brasil. En el RCP8.5 este cambio se incrementa en área e intensidad, apareciendo también un aumento coherente en el norte de Sudamérica y Centroamérica, siendo el noreste de México la región más afectada, con aumentos que llegan a un 60%. Un número considerable de modelos también muestra un aumento de la precipitación al norte de Argentina, que oscila entre el 30%-90%. Además, el DS de algunos modelos muestra cambios significativos de signo apuesto en zonas relativamente cercanas, mostrando el GCM un patrón de cambio mucho más uniforme. Esto pone de manifiesto la capacidad del DS para corregir la vasta resolución de los modelos.

En la estación de primavera, tanto en el RCP4.5 como en el RCP8.5 (de forma más extensa, marcada y coherente) aparecen dos zonas con aumentos significativos en el noreste de Sudamérica (Venezuela, Guayana, Surinam) y sur de Brasil, Paraguay y noreste de Argentina, y descensos en el centro y norte de Brasil, y en el sur de Bolivia y noreste de Argentina. La zona este de Brasil presenta marcados descensos, del 70% en el RCP4.5 y de más del 80% en el RCP8.5. En otoño, destaca el marcado incremento de la precipitación en el noreste de Brasil, muy consistente en el RCP8.5, extendiéndose para el DS de algunos GCMs tanto hacia el norte como hacia el interior de Brasil, y que puede llegar a aumentos muy elevados (más del 80%) según la zona y el GCM. Existen también descensos muy coherentes para el área más oriental de Brasil, que pueden llegar al 80% y en una amplia zona en el oeste de Brasil, en diagonal desde Colombia hasta Paraguay y norte de Argentina.

En muchos casos, estas estimaciones contrastan de forma muy marcada con las de los GCMs, de tal forma que un GCM y su DS pueden mostrar cambios significativos muy opuestos. Como cabe esperar en el proceso de *downscaling*, el patrón espacial de cambios es menos uniforme que en los GCMs, pudiendo discernir comportamientos diferentes en zonas relativamente cercanas. Más aún, el DS tiende, en muchos casos, a mostrar un mejor acuerdo en los cambios proyectados (al menos en su signo) con diversos GCMs que estos directamente.

En cuanto al análisis de los niveles de confianza, en general, el DS de los modelos en clima presente se aproxima al valor medio de la precipitación, con independencia de la zona y del GCM, de tal forma que los valores medios de la precipitación observada suelen caer dentro del rango intercuartílico de la *bootstrap*. También de forma general, se tiene que un número apreciable de GCMs presentan valores muy altos o muy bajos respecto tanto al valor medio observacional como a las estimaciones DS, lo cual puede deberse a una inadecuada representación de los procesos físicos asociados a la precipitación y a la baja resolución de la topografía, de tal forma que el DS parece corregir estos importantes sesgos.

La amplitud de los intervalos de confianza al 95%, tiende a mostrar un rango similar tanto para el presente como el futuro sin grandes diferencias entre los RCPs, aunque ligeramente mayor para el RCP8.5, lo que indicaría algo más de incertidumbre. Debe también destacarse que las amplitudes de las incertidumbres (intervalo de confianza) son muy variables según modelo y zona, e incluso estación del año, de tal forma que tienden a ser más pequeñas en periodos y zonas húmedas, pudiendo oscilar entre menos del 20% a más del 150%.

Con los resultados obtenidos, cabe concluir que el presente trabajo contribuye a mejorar el conocimiento del impacto del cambio climático en la precipitación de América tropical, y puede permitir una mejor adaptación a las consecuencias del mismo en los países del área. Futuras investigaciones en caminadas a la reducción de las incertidumbres en los cambios proyectados en esta variable podrían beneficiarse de la ampliación del campo predictor, incluyendo variabilidad atlántica y extratropical de la SLP, así como de la consideración de otras variables predictoras adicionales como la temperatura del aire o de la superficie del mar (SST). Sería también de gran interés abordar estudios encaminados a la evaluación de la frecuencia e intensidad de eventos extremos en la región analizada ante la situación de cambio climático.

Apéndice A

DIFERENCIAS ENTRE LAS PRECIPITACION SIMULADA POR LOS GCM Y LA OBSERVADA POR GPCCC

En este apéndice se presenta el cambio porcentual entre las salidas de precipitación simulada por los 20 GCMs y los valores observaciones de precipitación del GPCC, en periodo 1971-2000. En donde para ser comparable, a las salidas de los GCM, fueron llevadas a una resolución de $2.5^{\circ} \times 2.5^{\circ}$, y se utilizaron los datos observacionales del GPCC en mismas resolución. Además los niveles de confianza para la diferencia en la precipitación simulada y la observada en presente, fue estimada en base a la prueba de suma de rangos de Wilcoxon-Mann-Whitney, para cada punto de grid, y el porcentaje de área con diferencias significativas, se indica en cada modelo. Los resultados para las figuras A1-A4, que ninguno de las salidas de las simulaciones es capaz de reproducir de manera coherente la distribución espacial de la precipitación en el presente, ratificando la importancia del uso de los modelos DS.

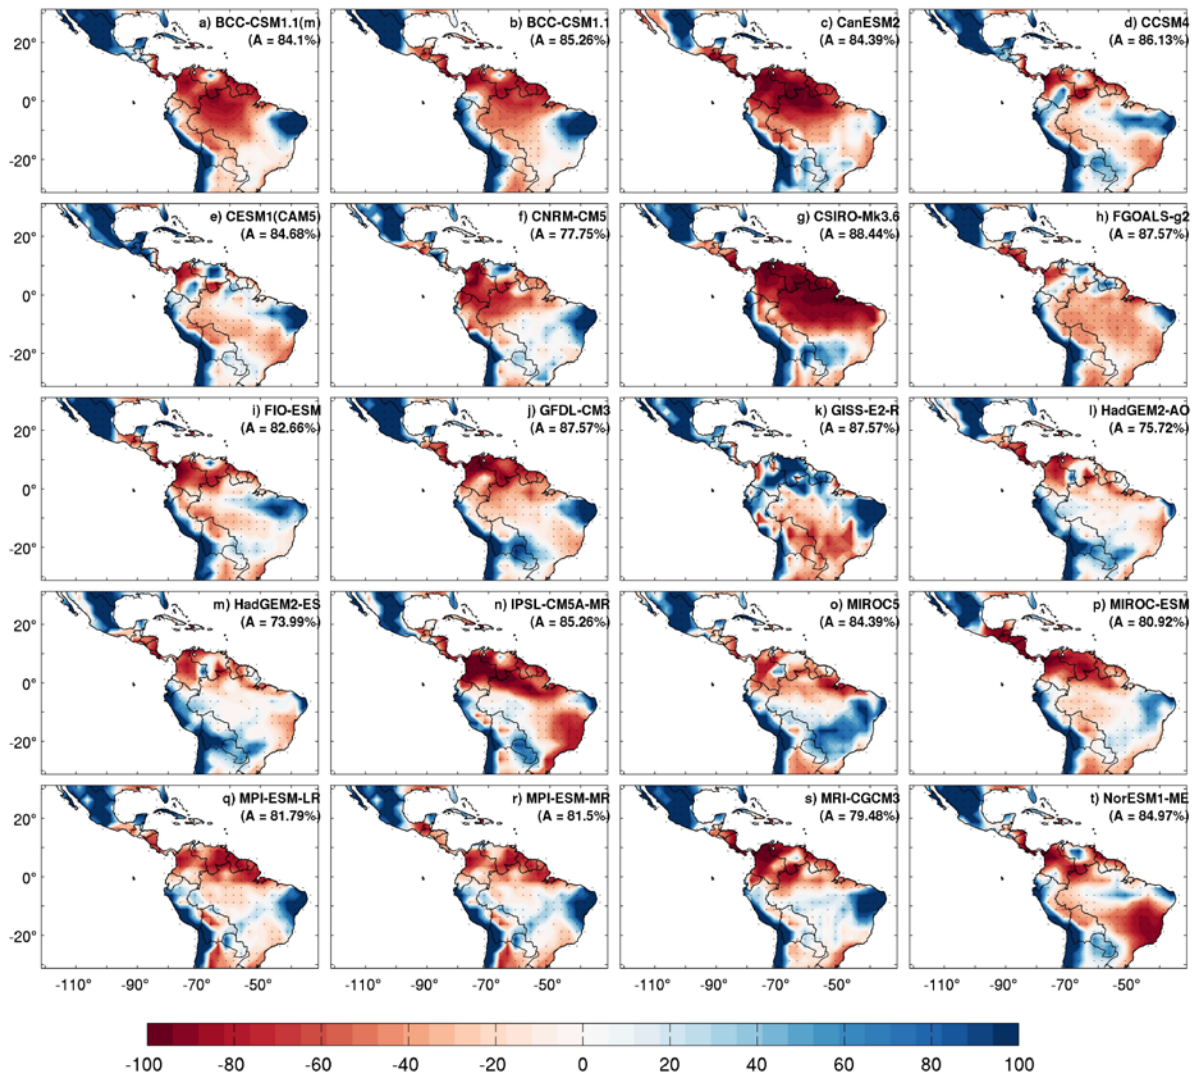


Figura A.1. Diferencias (en porcentaje) entre los campos medios de la precipitación simulada por los 20 GCMs del CMIP5 y la precipitación observada del GPCP, durante el periodo de 1971-2000 en DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95% (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

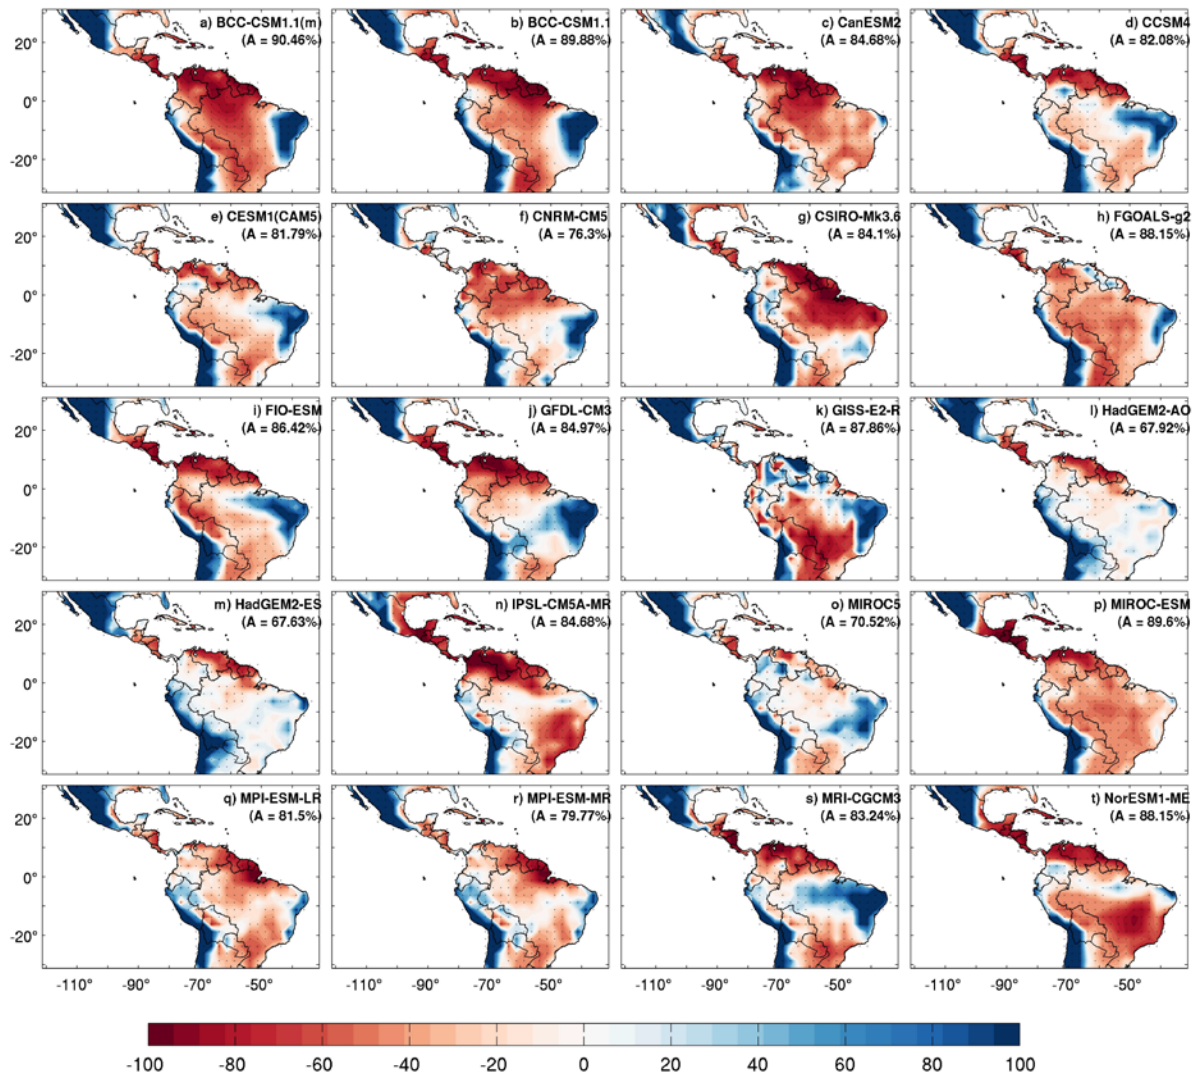


Figura A.2.. Como la Figura A.1 pero en MAM.

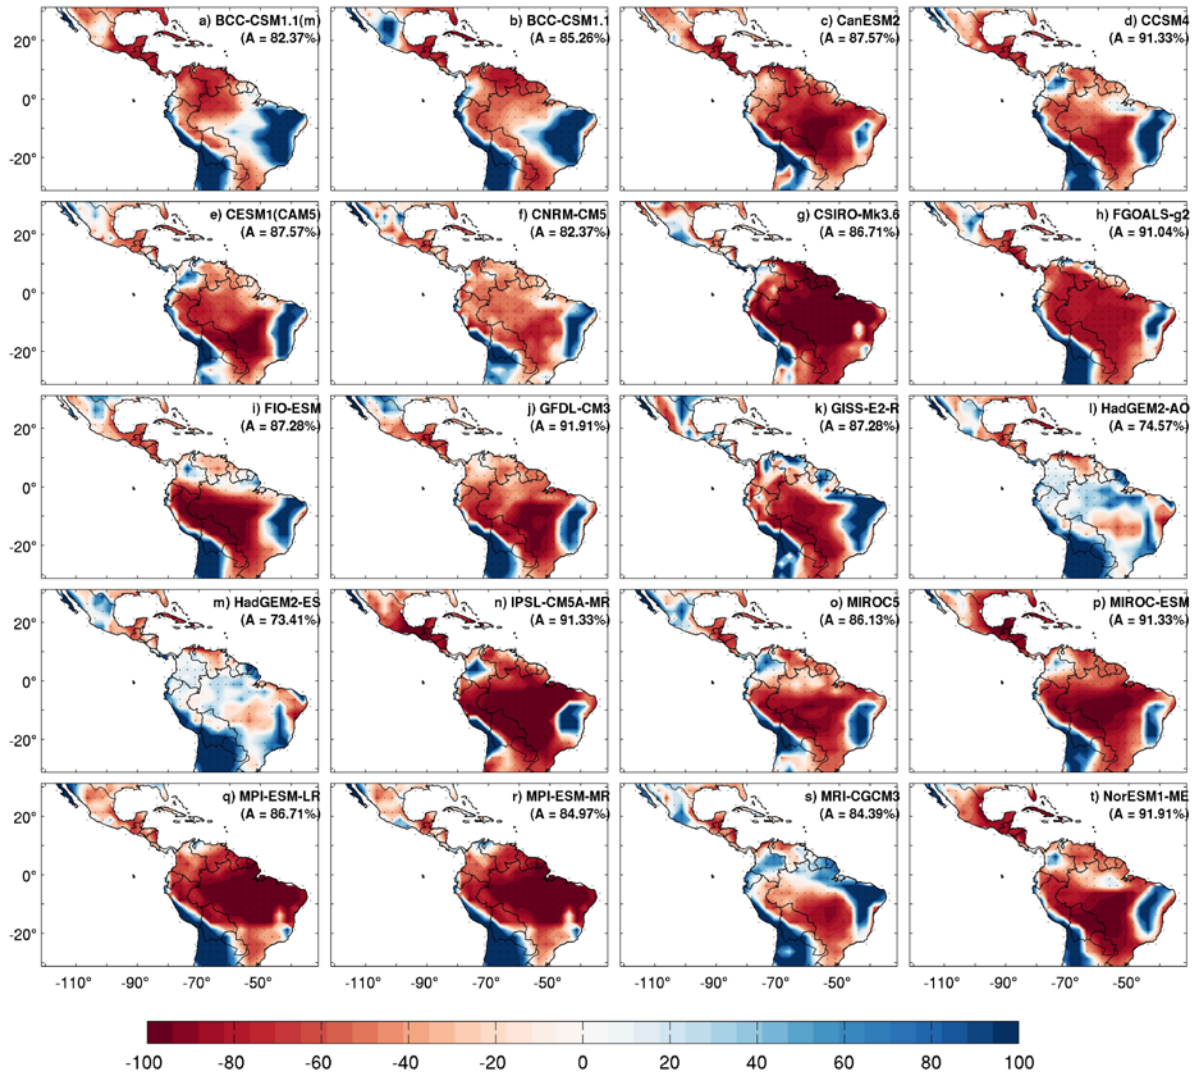


Figura A.3.. Como la Figura A.1 pero en JJA.

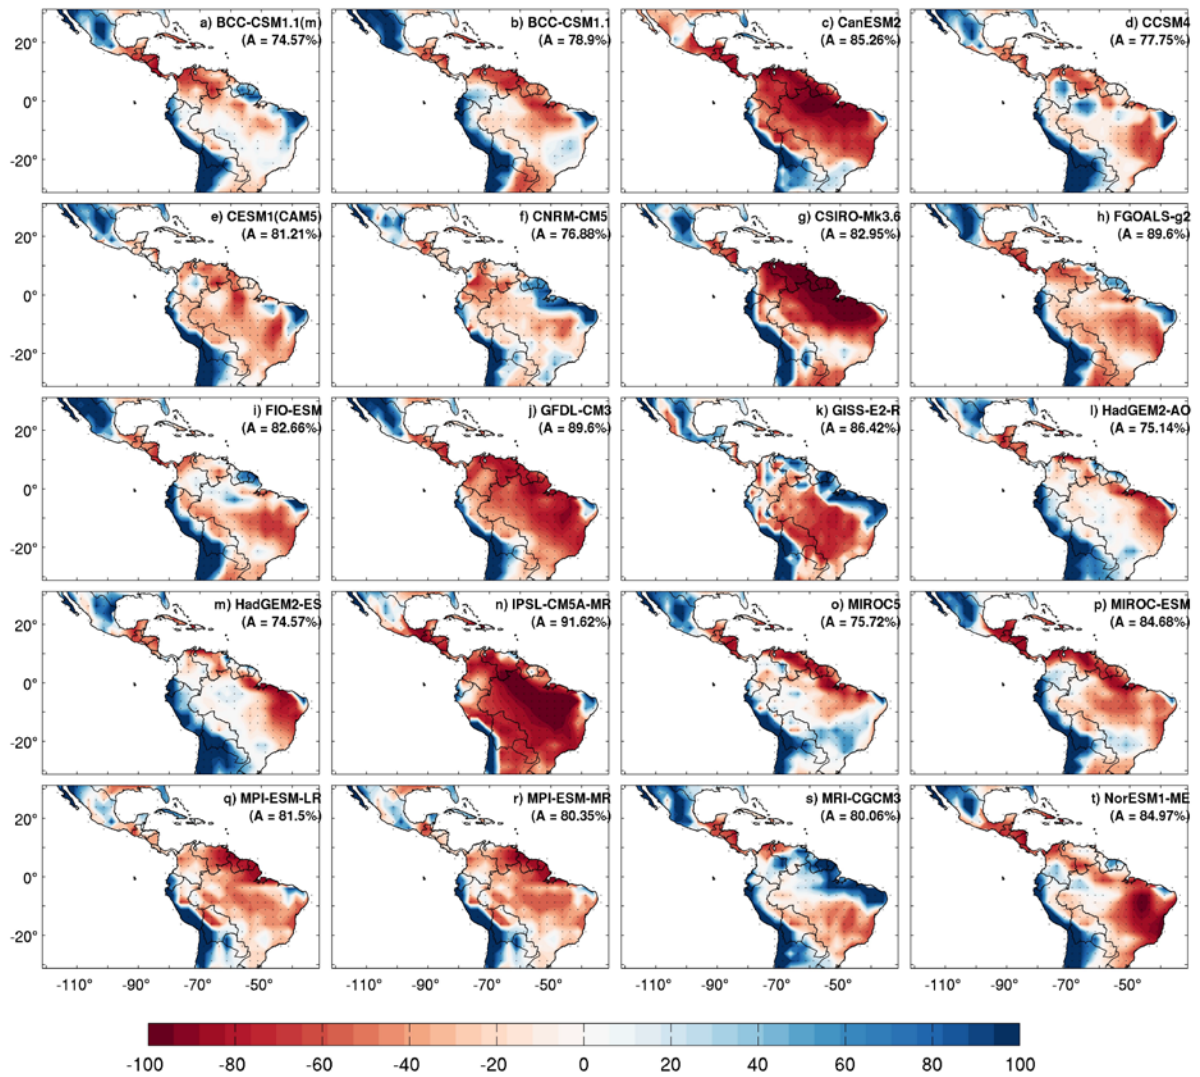


Figura A.4.. Como la Figura A.1 pero en SON.

Apéndice B

CAMBIOS PROYECTADOS EN LA PRECIPITACIÓN MEDIA ESTACIONAL SIMULADA

En este apéndice se presenta los resultados los cambios en porcentaje respecto al presente proyectados para el periodo 2071-2100 en la precipitación, según las simulaciones de 20 GCMs en los tres RCPs. Para ser comparable las salidas de la precipitación simulada todos los GCMs, fueron llevados a una resolución de $2.5^{\circ} \times 2.5^{\circ}$. Además los niveles de confianza para la diferencia en la precipitación simulada en presente respecto al futuro, fue estimada en base a la prueba de suma de rangos de Wilcoxon-Mann-Whitney, para cada punto de grid, y el porcentaje de área con diferencias significativas, se indica en cada modelo.

En invierno

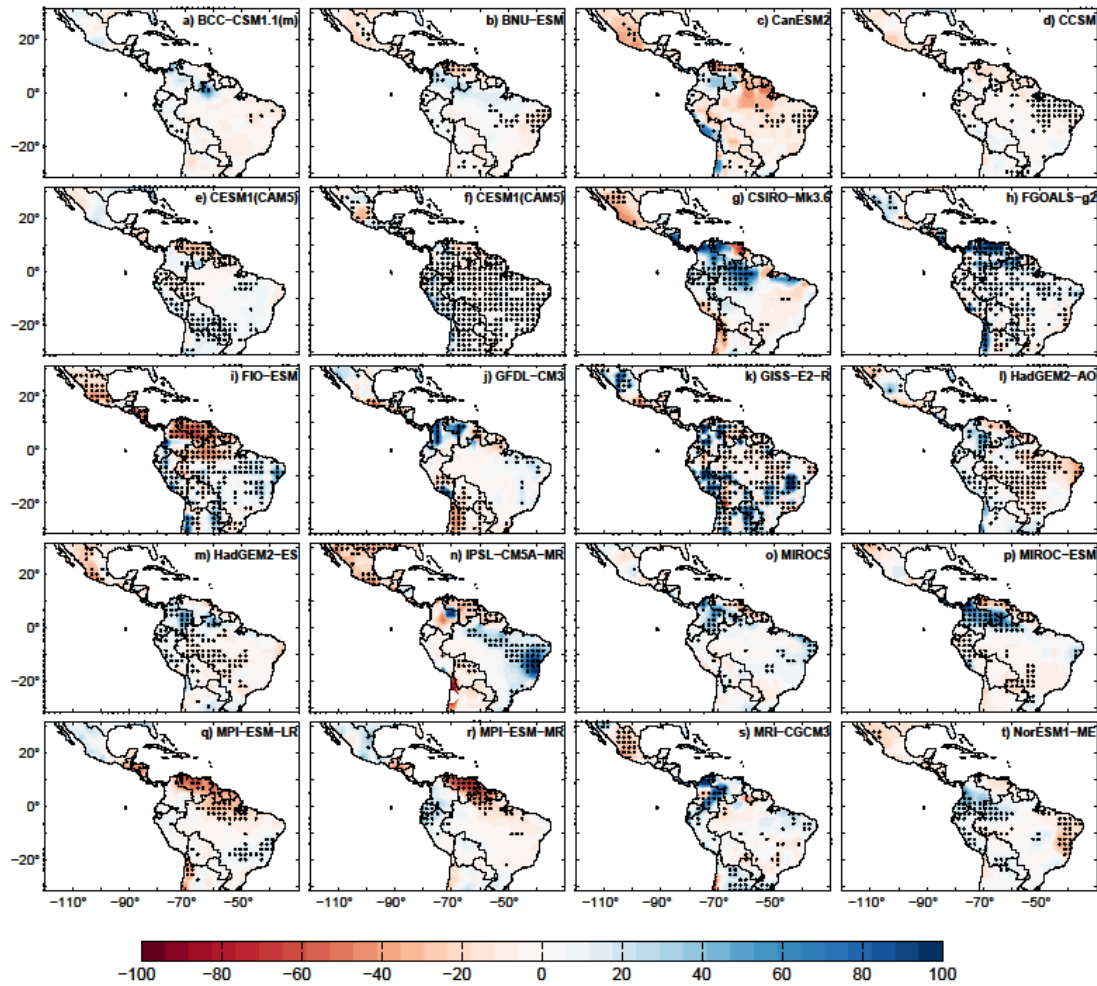


Figura B1. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando las simulaciones de precipitación de 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

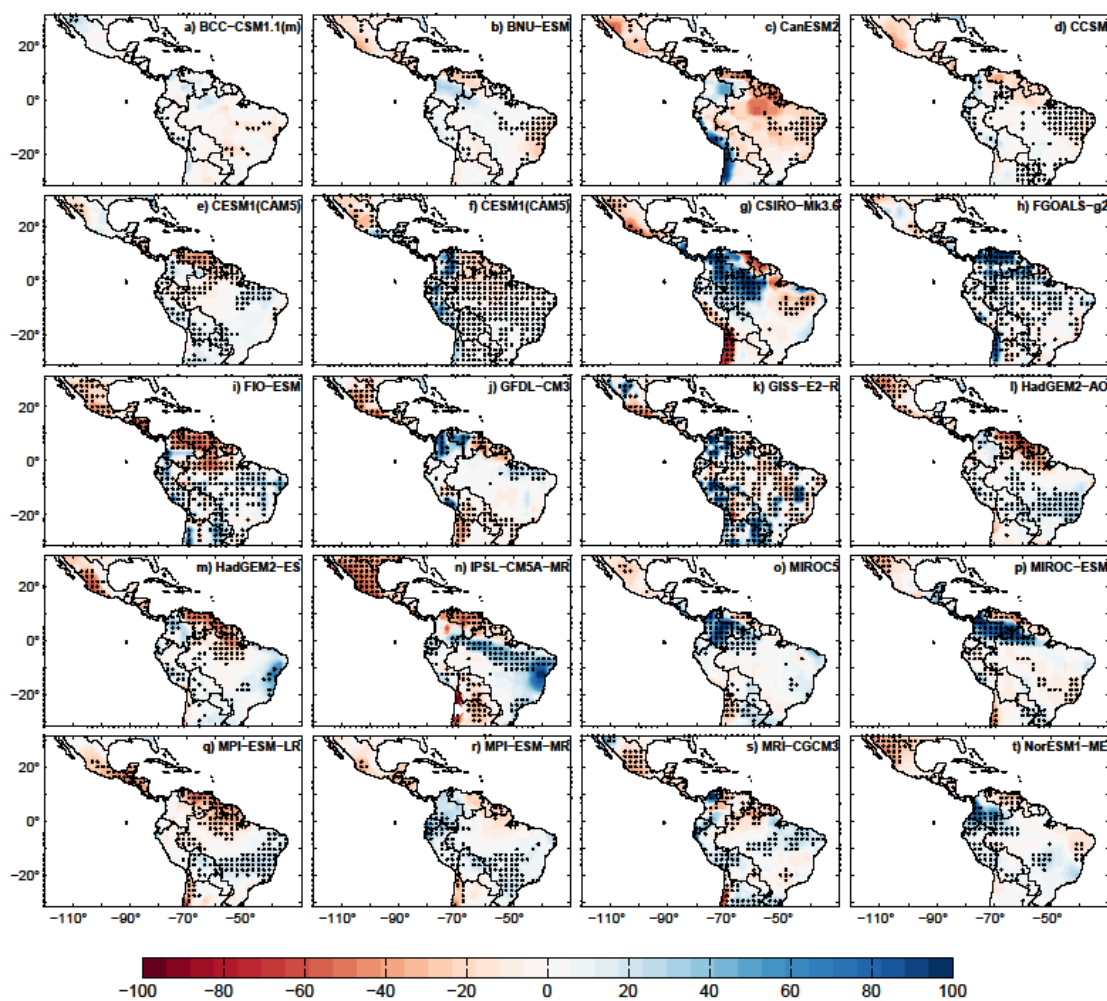


Figura B2. Al igual que la Figura B1 pero en para el escenario RCP4.5.

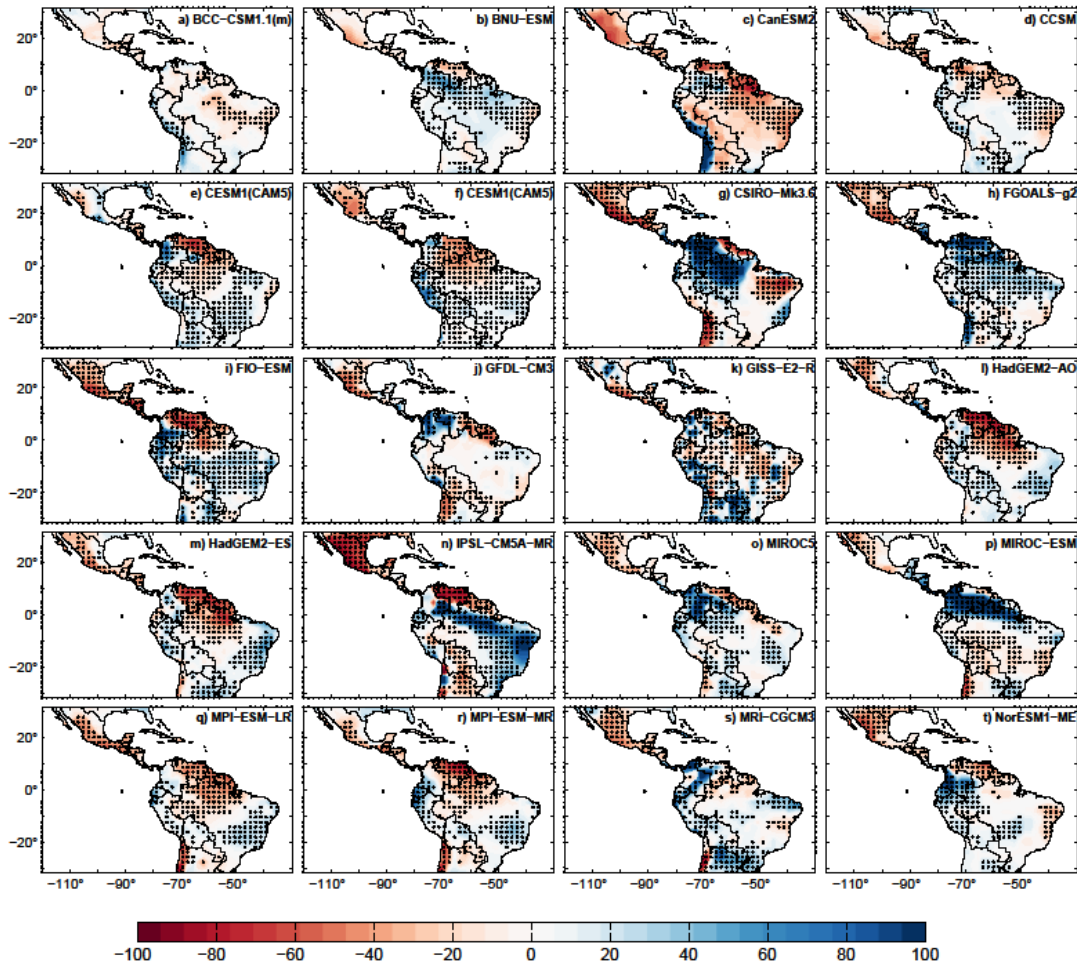


Figura B3. Al igual que la Figura B1 pero en para el escenario RCP8.5.

En primavera

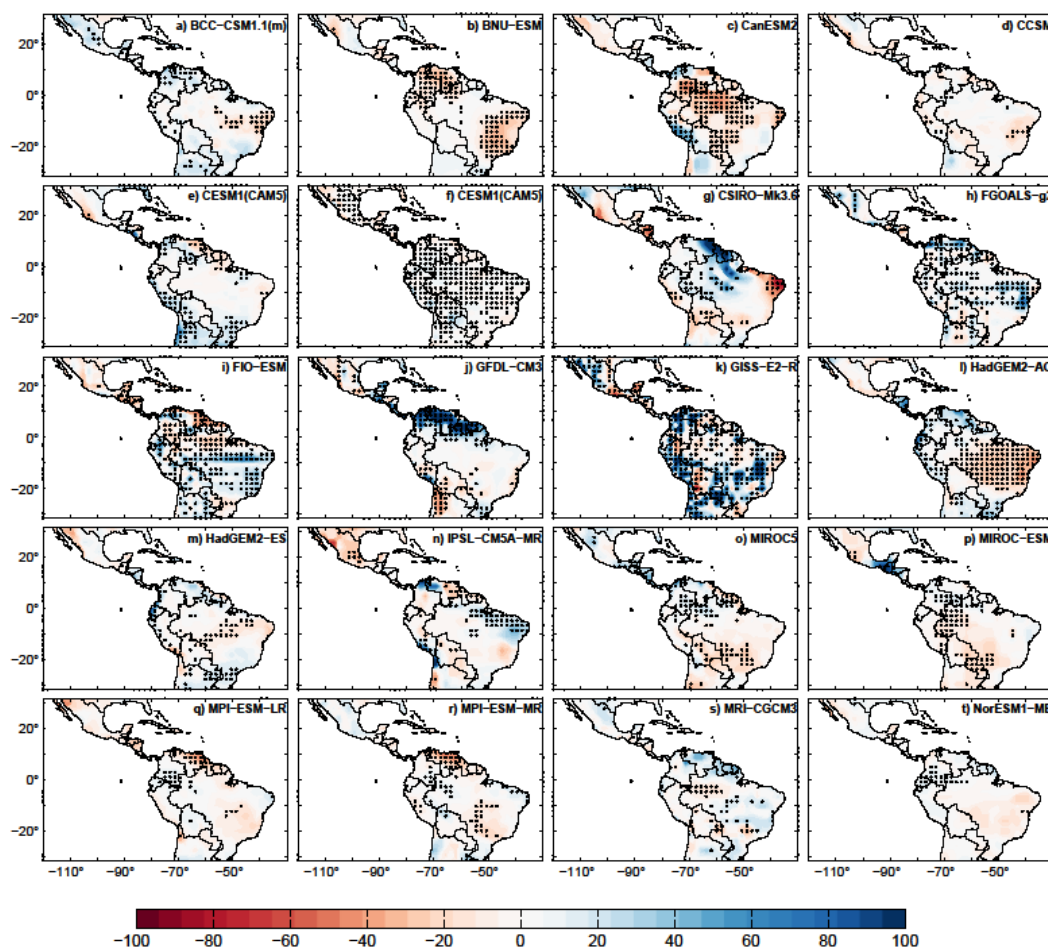


Figura B4. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando las simulaciones de precipitación de 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

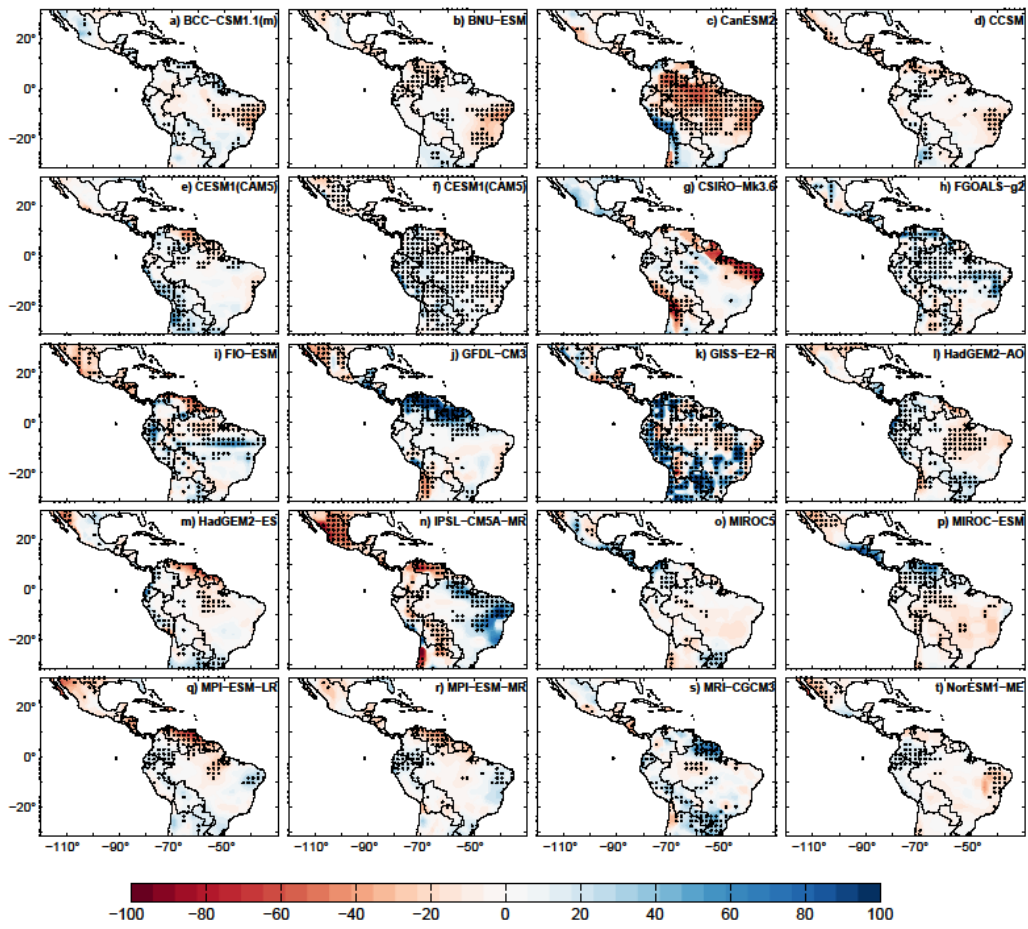


Figura B5. Al igual que la Figura B4 pero en para el escenario RCP4.5.

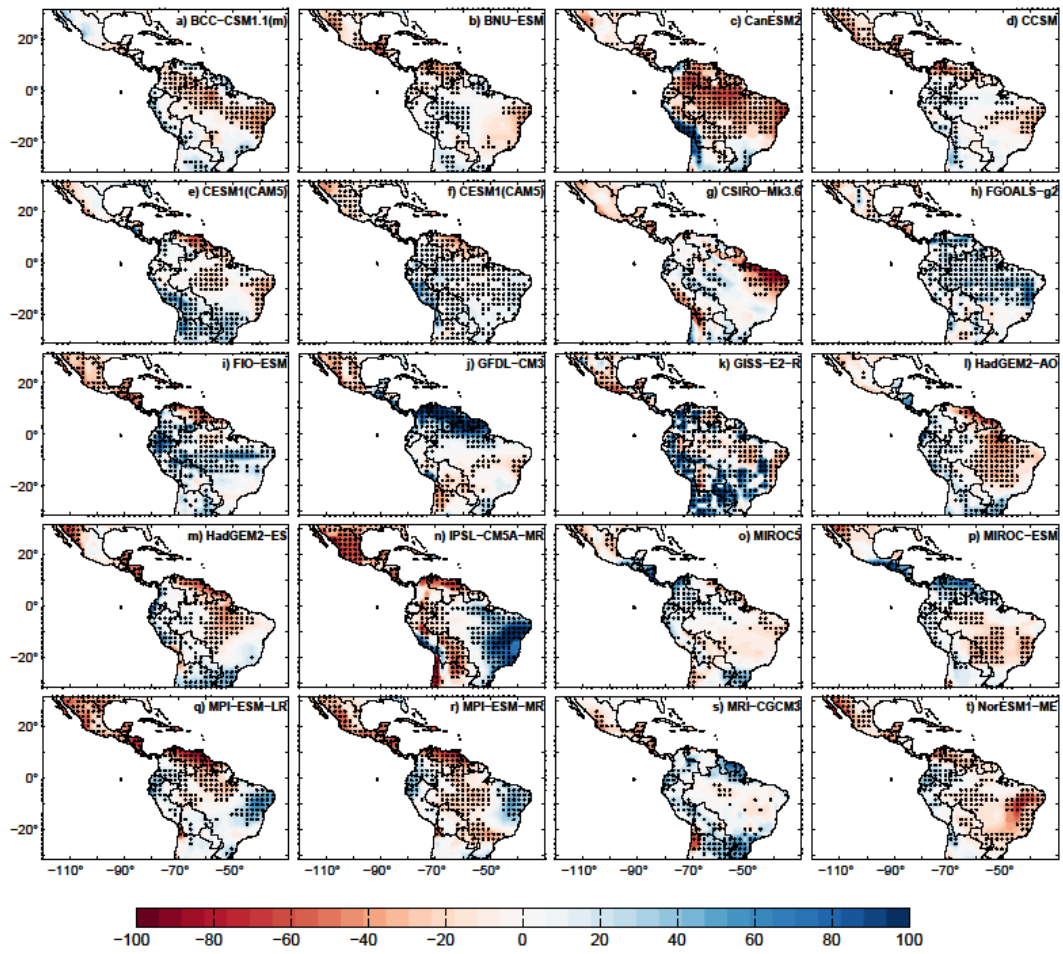


Figura B6. Al igual que la Figura B4 pero en para el escenario RCP8.5.

En verano

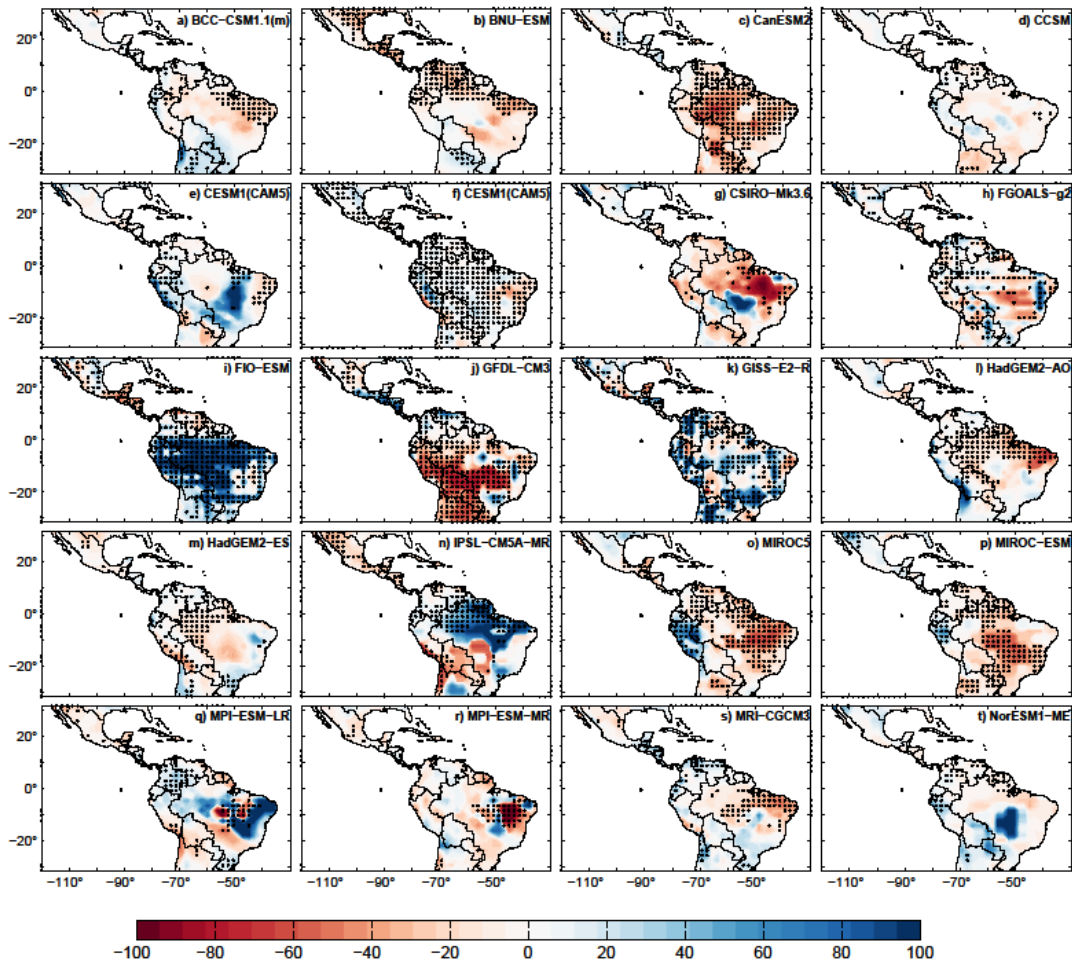


Figura B7. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando las simulaciones de precipitación de 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

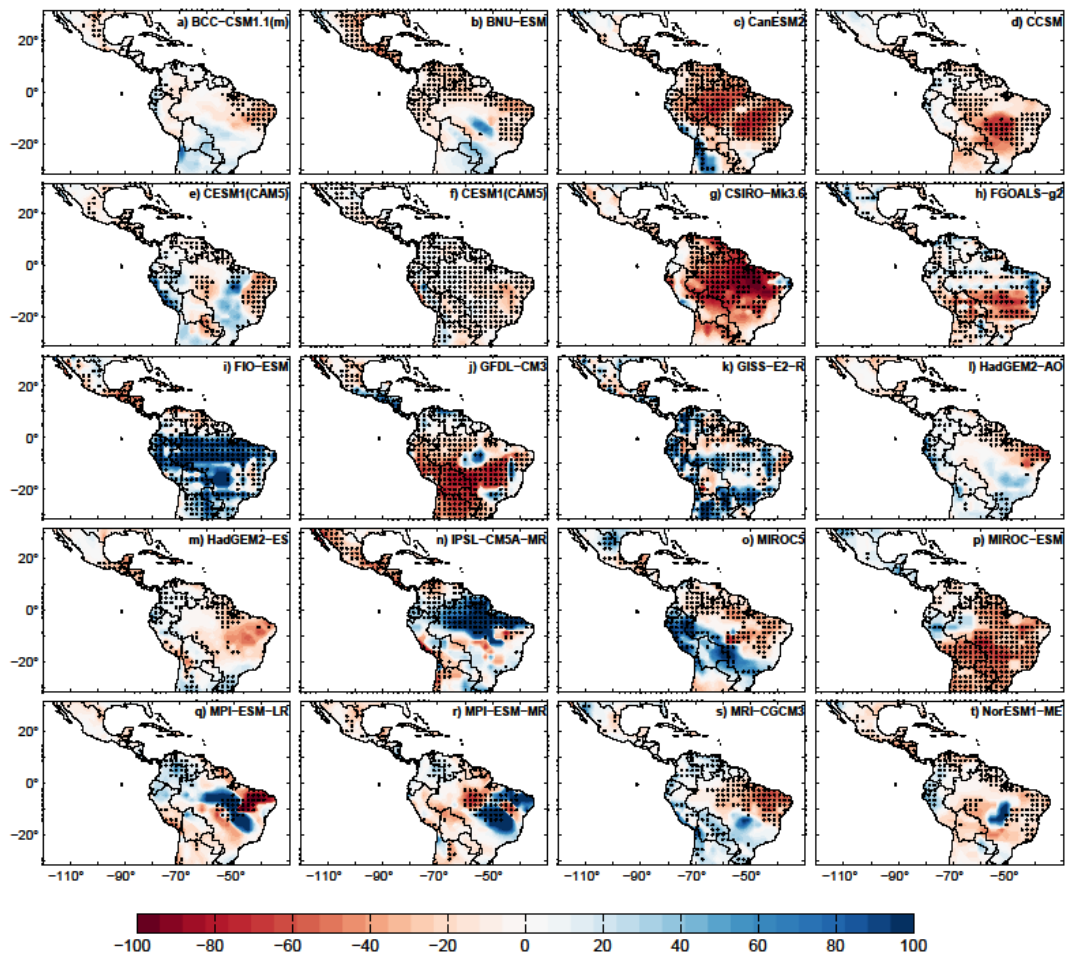


Figura B8. Al igual que la Figura B7 pero en para el escenario RCP4.5.

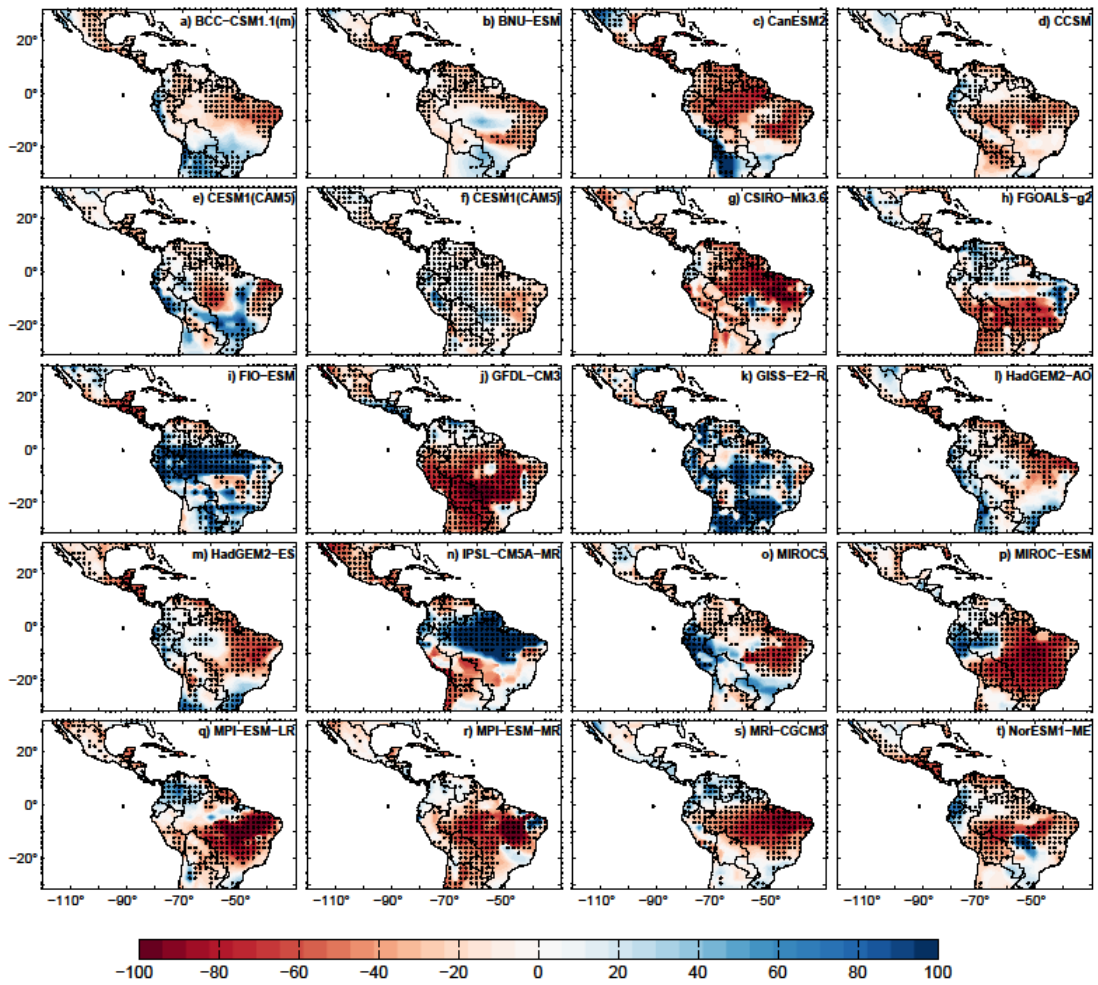


Figura B9. Al igual que la Figura B7 pero en para el escenario RCP8.5.

En otoño

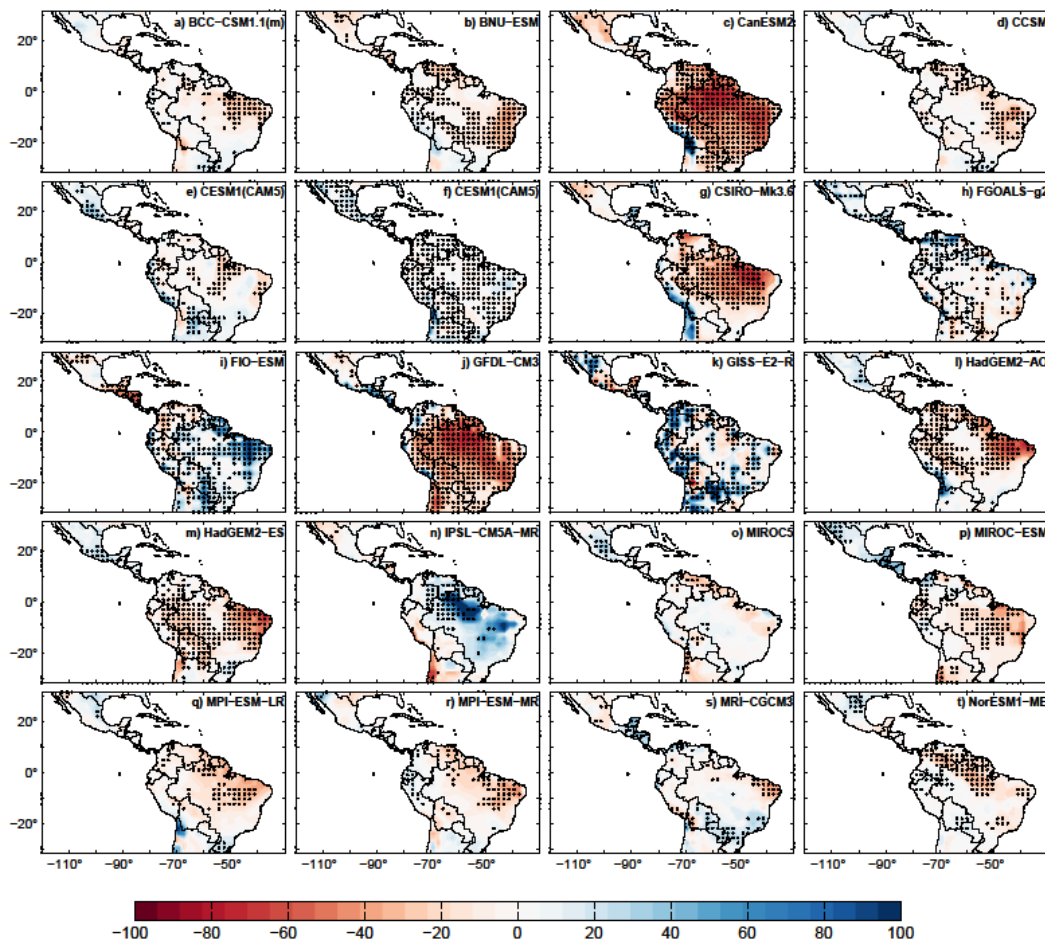


Figura B10. Cambios proyectado de la precipitación media estacional (en porcentaje) para el periodo 2071-2100 respecto al 1971-2000 usando las simulaciones de 20 modelos del CMIP5 en el escenario RCP2.6 para DEF. Las áreas donde las diferencias son significativas al nivel de confianza del 95%, (de acuerdo a la prueba no paramétrica de suma de rangos de Wilcoxon-Mann-Whitney) están marcadas por puntos.

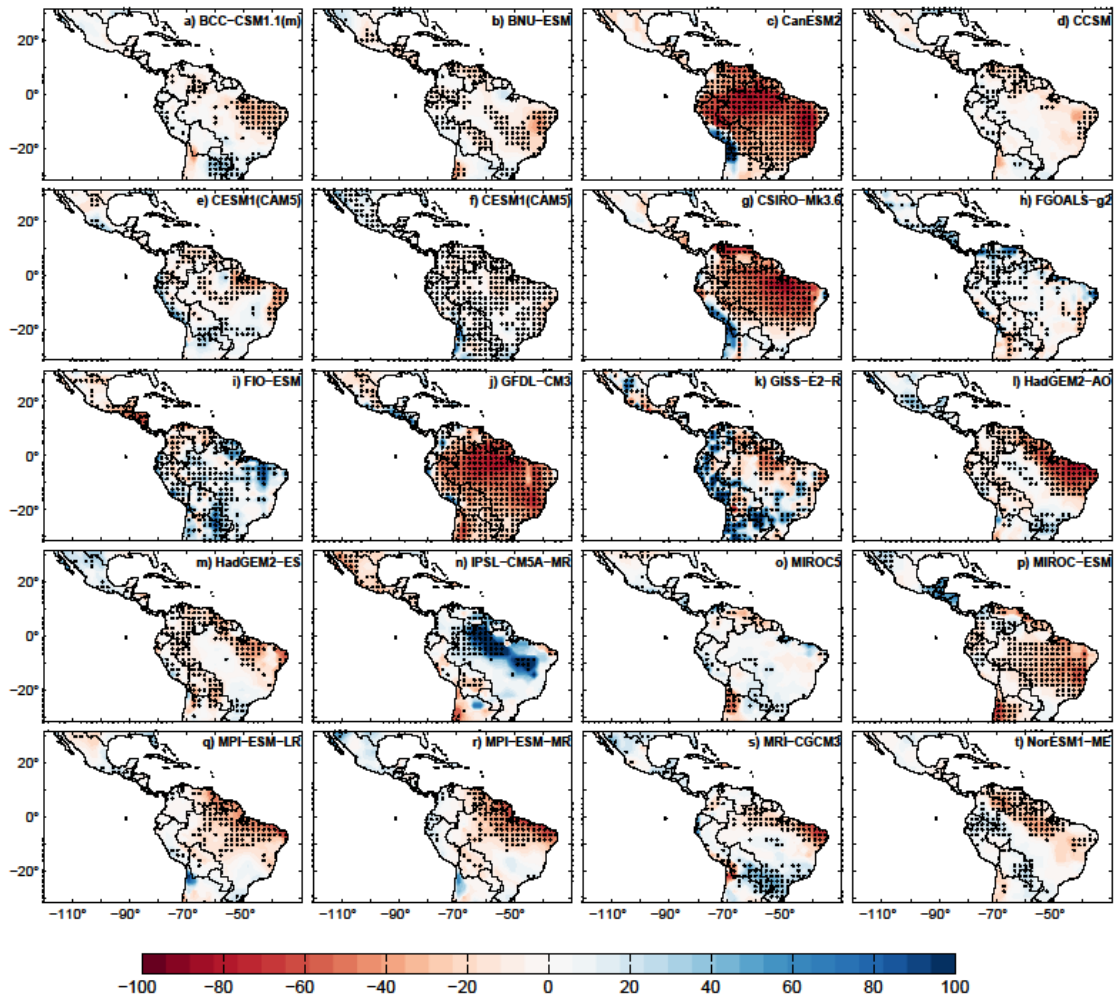


Figura B11. Al igual que la Figura B10 pero en para el escenario RCP4.5.

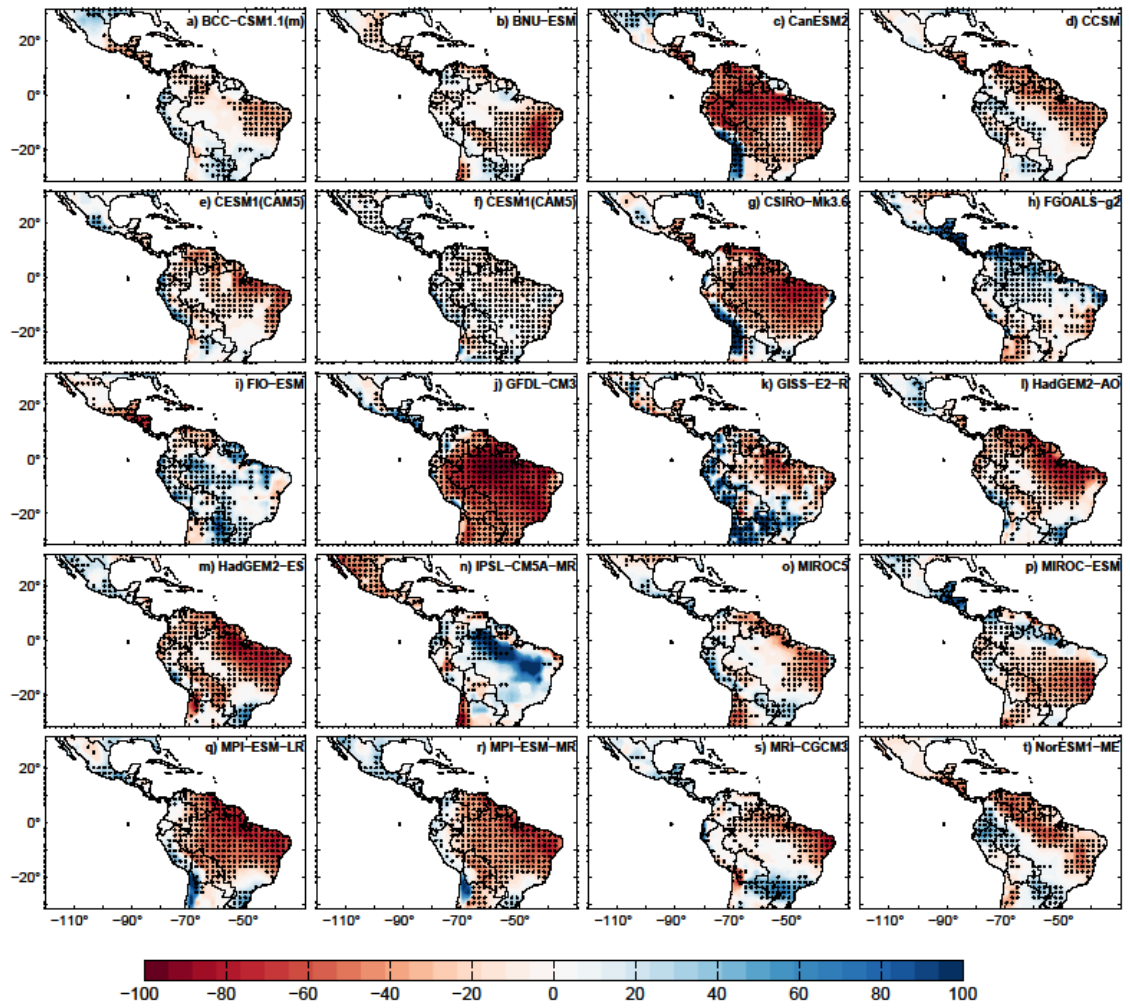


Figura B12. Al igual que la Figura B10 pero en para el escenario RCP8.5.

BIBLIOGRAFÍA

- Aceituno, P. F., 1988: On the functioning of the Southern Oscillation in the South American sector. Part I: Surface climate. *Mon. Wea. Rev.*, 116, 505–524.
- Achuta-Rao, K., Covey, C., Doutriaux, C., Fiorino, M., Gleckler, P., Phillips, T., Sperber, K., Taylor, K., 2004. An appraisal of coupled climate model simulations. In: Bader, D. (Ed.), UCRL-TR – 202550. Lawrence National Laboratory, USA (183 pp.).
- Amante, C. and B.W. Eakins, 2009. ETOPO1 1 Arc-Minute Global Relief Model: Procedures, Data Sources and Analysis. NOAA Technical Memorandum NESDIS NGDC-24. National Geophysical Data Center, NOAA. doi:10.7289/V5C8276M
- Anthony Chen, A. and Taylor, M. A. 2002. Investigating the link between early season Caribbean rainfall and the El Niño + 1 year. *Int. J. Climatol.*, 22: 87–106.
- Barnett, T.P., R. Preisendorfer. 1987. Origins and levels of monthly and seasonal forecast skill for United States surface air temperatures determined by canonical correlation analysis. *Monthly Weather Review* 115: 1825-1850.
- Barnston, A. G., and R. E. Livezey, 1987: Classification, seasonality and persistence of low-frequency atmospheric circulation patterns. *Mon. Wea. Rev.*, 115, 1083–1126.
- Bronstert, A., Kolokotronis, V., Schwandt, D., and H. Straub, 2007: Comparison and evaluation of regional climate scenarios for hydrological impact analysis: general scheme and application example. *International Journal of Climatology*, 27, 1579-1594.
- Bergant K, Kajfež-Bogataj L., 2005. N-pls regression as empirical downscaling tool in climate change studies. *Theor Appl Climatol* 81:11–23
- Bradbury, J. P. 1997. Sources of glacial moisture in Mesoamerica. *Quaternary International* 43/44:97-110.

- Bronstert A, Niehoff D, Burger G., 2002. Effects of climate and land-use change on storm runoff generation: present knowledge and modeling capabilities. *Hydrol Process* 16(2):509–529
- Buytaert W, Celleri R, and Timbe L (2009) Predicting climate change impacts on water resources in the tropical Andes: Effects of GCM uncertainty. *Geophysical Research Letters* 36: L07406.
- Cubasch U, Meehl GA, Boer GJ, Stouffer RJ, Dix M, Noda A, Senior CA, Raper S, Yap KS., 2001. Projections of Climate Change. In *Climate Change 2001: The Scientific Basis. Contribution of Working Group I to the Third Assessment Report of the Intergovernmental Panel on Climate Change*, Houghton JT, Ding Y, Griggs DJ, Noguer M, van der Linden PJ, Dai X, Maskell K (eds). Cambridge University Press: Cambridge, New York, USA; 881.
- Covey, C., Achuta-Rao, K.M., Cubasch, U., Jones, P., Lambert, S.J., Mann, M.E., Phillips, T.J., Taylor, K.E., 2003. An overview of results from the Coupled Model Intercomparison Project. *Glob. Planet. Chang.* 37, 103–133.
- Clarke LE, Edmonds JA, Jacoby HD, Pitcher H, Rieilly JM, Richels R., 2007, Scenarios of greenhouse gas emissions and atmospheric concentrations. Sub-report 2.1a of Synthesis and Assessment Product 2.1. Climate Change Science Program and the Subcommittee on Global Change Research, Washington DC
- Chen D, Achberger C, Räisänen J, Hellstrom C. 2006. Using statistical downscaling to quantify the GCM-related uncertainty in regional climate change scenarios: a case study of Swedish precipitation. *Advances in Atmospheric Sciences* 23: 54–60.
- Christensen JH, Carter TR, Rummukainen M, Amanatidis G. 2007. Evaluating the performance and utility of regional climate models: the PRUDENCE project. *Climatic Change* 81(Supplement): 1–6.
- Christensen OB, Christensen JH, MACHENHAUER B, Botzet M. 1998. Very high-resolution regional climate simulations over Scandinavia—Present climate. *Journal of Climate* 11: 3204–3229.
- Deser, Clara, Michael S. Timlin, 1997: Atmosphere-Ocean Interaction on Weekly Timescales in the North Atlantic and Pacific. *Journal of Climate*: Vol. 10, No. 3, pp.393-408.
- Draper, N.R. and Smith, H., 1981. *Applied Regression Analysis*. 2nd ed. John Wiley and Sons, 709 pp.

- Draper, N.R. and Smith, H., 1998. *Applied Regression Analysis* (3rd ed.). John Wiley.
- Dufresne, J.-L., and S. Bony, 2008: An assessment of the primary sources of spread of global warming estimates from coupled atmosphere–ocean models. *J. Climate*, 21, 5135–5144,
- Eden JM, Widmann M, Grawe D, Rast S., 2012. Skill, correction, and downscaling of GCM-simulated precipitation. *J. Clim.* 25(11): 3970–3984,
- Eden, J.M. and Widmann, M., 2014. Downscaling of GCM-Simulated Precipitation Using Model Output Statistics. *Journal of Climate*, 27(1), 312-324.
- Ernesto Muñoz, Antonio J. Busalacchi, Sumant Nigam, and Alfredo Ruiz-Barradas., 2008: Winter and summer structure of the caribbean low-level jet. *J. Climate*, 21, 1260–1276.
- Eslava J.A. 1994. *Climatología del Pacífico colombiano*. Academia Colombiana de Ciencias Geofísicas. Colección Eratóstenes, No. 1, Santa Fe de Bogotá D.C., pp 79.
- Efron, B., 1979. Bootstrap methods: another look at the jackknife. *Ann. Statist.* 7, 1-26.
- Efron, B. and Tibshirani, R.J., 1993. *An Introduction to the Bootstrap*. Chapman and Hall, New York.
- Fernandez J, Saenz J., 2003. Improved field reconstruction with the analog method: searching the cca space. *Clim Res* 24:199–213
- Fowler HJ, Kilsby CG, Stunell J. 2007. Modelling the impacts of projected future climate change on water resources in northwest England. *Hydrology and Earth System Sciences* 11 (3): 1115–1126.
- Fukuoka A. 1951. A study of 10-day forecast (A synthetic report). *The Geophysical Magazine (Tokyo)* XXII: 177–218.
- Gill PE, Murray W, Wright MH. 1981. *Practical Optimization*. Academic Press: London.
- Dickinson RE, Kennedy P. 1992. Impact on regional climate of Amazon deforestation. *Geophys Res Lett* 19: 1947-1950
- Garcia, S.R., and M.T. Kayano .2008. Some evidence on the relationship between the South American monsoon and the Atlantic ITCZ, *Theor. App. Climatol.*, doi:10.1007/s00704-009-0107-z.
- Gan, M.A., L.R. Rodrigues, and V.B. Rao (2009). *Monção na America do Sul*. Chapter 19 in *Tiempo y Clima no Brasil*, Cavalcanti I, Ferreira NJ, Justi MAG, Silva Dias MAF, (eds) Editora. Oficina de Textos, São Paulo: Brazil, pp. 297–312.

- Grimm, A.M., C. Vera, and R. Mechoso (2005). The South American Monsoon System, Chang C-P, Wang B, Lau NC-G, (eds) The Global Monsoon System: Research and Forecast, WMO/TD 1266 —TMRP: pp. 542.
http://www.wmo.int/pages/prog/arep/tmrp/documents/global_monsoon_system_IWM3.pdf.
- Grotch, S.L. and MacCracken, M.C., (1991), The use of General Circulation Models to predict regional climate change. *Journal of Climate*, 4, 286-303.
- Grimm, A.M., and M.A.F. Silva Dias (2010). Synoptic and Mesoscale Processes in the South American Monsoon. In *The Global Monsoon System: Research and Forecast*, Chang CP, Ding Y, Johnson RH, Lau G, Wang B, Yasunari Y (eds.) World Scientific Publication Company: Singapore, 239–255.
- Held, I., and B. Soden., 2006. Robust responses of the hydrological cycle to global warming. *J. Climate*, 19, 5686–5699,
- Helsel, D. R., R. M. Hirsch, *Statistical Methods in Water Resources*, Elsevier, New York, 1992.
- Heffernan O (2010) The climate machine. *Nature*, 463, 1014–1016.
- Hibbard, K .A., van Vuuren, D .P., Edmonds, J. 2011. A Primer on the Representative Concentration Pathways (RCPs) and the Coordination Between the Climate and Integrated Assessment Modeling Communities. *CLIVAR Exchanges* 56 (16), No. 2: 12-15.
- Hoerling, M. P., J. S. Whitaker, A. Kumar, and W. Wang (2001), The midlatitude warming during 1998–2000, *Geophys. Res. Lett.*, 28, 755–758,
- IPCC, 2007. *Climate Change 2007: The Physical Science Basis*. In: Solomon, S., Qin, D., Manning, M., Chen, Z., Marquis, M., Averyt, K.B., Tignor, M., Miller, H.L. (Eds.), *Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
- IPCC, 2013a. *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, 1535 pp.

- IPCC, 2013b: Annex I: Atlas of Global and Regional Climate Projections [van Oldenborgh, G.J., M. Collins, J. Arblaster, J.H. Christensen, J. Marotzke, S.B. Power, M. Rummukainen and T. Zhou (eds.)]. In: *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Stocker, T.F., D. Qin, G.-K. Plattner, M. Tignor, S.K. Allen, J. Boschung, A. Nauels, Y. Xia, V. Bex and P.M. Midgley (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, pp. 1311–1394,
- IPCC, 2014: *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part B: Regional Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Barros, V.R., C.B. Field, D.J. Dokken, M.D. Mastrandrea, K.J. Mach, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, XXX pp. <http://ipcc-wg2.gov/AR5/report/final-drafts/>
- Iman, R. L., 1994: *A Data-Based Approach to Statistics*. Duxbury Press, 348 pp.
- Jones, C., and L. M. V. Carvalho, 2002: Active and break phases in the South American monsoon system. *J. Climate*, 15, 905–914,
- Jolliffe, I.T., 2002. *Principal Component Analysis*, second edition, New York: Springer-Verlag New York, Inc.
- Jury, M., 2008: Climate influences on dengue epidemics in Puerto Rico. *Int. J. Environ. Heal. R.*, 18, 323 –334. Victor Magaña, Jorge A. A. Mador, and S. Ocorro Medina, 1999: The midsummer drought over Mexico and Central America. *J. Climate*, 12, 1577–1588.
- Kang, I.S., Jin, K., Wang, B., Lau, K.M., Shukla, J., Krishnamurthy, V., Schubert, S.D., Waliser, D.E., Stern, W.F., Kitoh, A., Meehl, G.A., Kanamitsu, M., Galin, V.Y., Satyan, V., Park, C.K., Liu, Y., 2002. Intercomparison of the climatological variations of Asian summer monsoon precipitation simulated by 10 GCMs. *Clim. Dyn.* 19, 383–395.
- Kucharski, F., et al., 2008. The CLIVAR C20C Project: Skill of simulating Indian monsoon rainfall on interannual and to decadal time scales, Does GHG forcing play a role? *Clim. Dyn.*
- Lean, J. and D. A. Warrilow. 1989. Simulation of the regional climatic impact of Amazon deforestation. *Nature*, 342:411-413.

- Li, Y. and Smith, I., 2009. A Statistical Downscaling Model for Southern Australia Winter Rainfall. *Journal of Climate*, 22(5), 1142-1158.
- Liebmann, B., and C.R. Mechoso (2010). The South American Monsoon System, Chapter 8 in *The Global Monsoon System: Research and Forecast*, 2nd Edition. C. P Chang et al., (eds.) World Scientific Publishing: Singapore. 550 pp.
- Lohmann, U., and J. Feichter., 2005: Global indirect aerosol effects: a review. *Atmos. Chem. Phys.*, 5, 715–737.
- Lorenz EN., 1956. Empirical Orthogonal Functions and Statistical Weather Prediction. Technical report, Statistical Forecast Project Report 1, Dept. of Meteor, MIT: 49.
- Magrin, G.O., Marengo, J.A., Boulanger, J.-P., Buckeridge, M.S., Castellanos, E., Poveda, G., Scarano, F.R. and Vicuña, S., 2014. Central and South America. In: *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part B: Regional Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Barros, V.R., C.B. Field, D.J. Dokken, M.D. Mastrandrea, K.J. Mach, T.E. Bilir, M. Chatterjee, K.L. Ebi, Y.O. Estrada, R.C. Genova, B. Girma, E.S. Kissel, A.N. Levy, S. MacCracken, P.R. Mastrandrea, and L.L. White (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, pp. 1499-1566.
- Marcelo E., Seluchi, A., Celeste Saulo, Matilde Nicolini, and Prakki S atyamurty, 2003: The Northwestern Argentinean Low: A Study of Two Typical Events. *Mon. Wea. Rev.*, 131, 2361–2378.
- Marengo, J.A., Ambrizzi, T., Da Rocha, R.P., Alves, L.M., Cuadra, S.V., Valverde, M.C., Torres, R.R., Santos, D.C. and Ferraz, S.E.T., 2010. Future change of climate in South America in the late twenty-first century: intercomparison of scenarios from three regional climate models. *Climate Dynamics*, 35, 1089-1113.
- Maraun, D., and Coauthors, 2010: Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Rev. Geophys.*, 48, RG3003.
- Maurer, E.P., 2007. Uncertainty in hydrologic impacts of climate change in the Sierra Nevada, California under two emissions scenarios. *Climatic Change*, Vol. 82, No. 3-4, 309-325.
- Meehl, G.A., 1997. The south Asian monsoon and the tropospheric biennial oscillation. *J. Clim.* 10, 1921–1943

- Meehl, G. A., G. J. Boer, C. Covey, M. Latif, and R. J. Stouffer, 2000: The Coupled Model Intercomparison Project (CMIP). *Bull. Amer. Meteor. Soc.*, 81, 313--318.
- Meehl GA, Washington WM, Wigley TML, Arblaster JM, Dai A (2003) Solar and greenhouse gas forcing and climate response in the 20th century. *J Clim* 16:426–444
- Meehl G A, Washington W M, Ammann C, Arblaster J M, Wigley T M L, Tebaldi C (2004) Combinations of natural and anthropogenic forcings and 20th century climate. *J Clim* 17:3721–3727
- Meehl GA, Washington WM, Collins WD, Arblaster JM, Hu A, Buja LE, Strand WG, Teng H (2005) How much more global warming and sea level rise? *Science* 307:1769–1772
- Meehl GA, Washington WM, Santer BD, Collins WD, Arblaster JM, Hu A, Lawrence D, Teng H, Buja LE, Strand WG (2006) Climate change in the 20th and 21st centuries and climate change commitment in the CCSM3. *J Clim* (in press)
- Meehl, G. A., and K. A. Hibbard, 2007: A strategy for climate change stabilization experiments with AOGCMS and ESMS. WCRP Informal Rep. 3/2007, ICPO Publ. 112, IGBP Rep. 57, 35 pp
- Meehl, G. A., C. Covey, T. Delworth, M. Latif, B. McAvaney, J. F. B. Mitchell, R. J. Stouffer, and K. E. Taylor, 2007: The WCRP CMIP3 multimodel dataset: A new era in climate change research. *Bull. Amer. Meteor. Soc.*, 88, 1383–1394.
- Moss, R. H. et al. .,2008. Towards New Scenarios for Analysis of Emissions, Climate Change, Impacts, and Response Strategies (IPCC Expert Meeting Report, IPCC, Geneva,
- Moss, R.H., J.A. Edmonds, K.A. Hibbard, M.R. Manning, S.K. Rose, D.P. van Vuuren, T.R. Carter, S. Emori, M. Kainuma, T. Kram, G.A. Meehl, J.F.B. Mitchell, N. Nakicenovic, K. Riahi, S.J. Smith, R.J. Stouffer, A.M. Thomson, J.P. Weyant, and T.J. Wilbanks., 2010. The next generation of scenarios for climate change research and assessment. *Nature*, 463, 747-756, doi:10.1038/nature08823.
- Meyer-Christoffer, A., A. Becker, P. Finger, B. Rudolf, U. Schneider U, and M. Ziese., 2011. GPCC Climatology Version 2011 at 1.0°: monthly land-surface precipitation climatology for every month and the total year from rain-gauges built on GTS-based and historic data. doi: 10.5676/DWD_GPCC/CLIM_M_V2011_100.

- North, G. R., R. F. Cahalan, and J. A. Coakley Jr. (1981), Energy balance climate models, *Rev. Geophys.*, 19, 91–121.
- North, G. R., T. Bell, R. Cahalan, and F. Moeng, 1982: Sampling errors in the estimation of empirical orthogonal functions. *Mon. Wea. Rev.*, 110, 699–706.
- Obukhov A.M. 1947. Statistically homogeneous fields on a sphere. *Uspethi Matematicheskikh Nauk* 2: 196–198.
- Pabón J.D., 2003. El cambio climático global y su manifestación en Colombia. *Cuadernos de Geografía*, v XII (1-2), pp. 111-119.
- Palomino-Lemus, R., Córdoba-Machado, S., Gámiz-Fortis, S.R., Castro-Díez, Y. and Esteban-Parra, M.J., 2015. Summer precipitation projections over northwestern South America from CMIP5 models. *Global and Planetary Change*, 131, 11-23.
- Poveda G. 2004. La hidroclimatología de Colombia., 2004. Una síntesis desde la escala interdecadal hasta la escala diurna, revista *Acad. Colomb. Cienc.* 28 (107) pp. 201–222
- Peel, M. C., Finlayson, B. L., and McMahon, T. A.: Updated world map of the Köppen-Geiger climate classification, *Hydrol. Earth Syst. Sci.*, 11, 1633–1644, doi:10.5194/hess-11-1633-2007, 2007.
- Preisendorfer, R.W., 1988. *Principal Component Analysis in Meteorology and Oceanography*. Elsevier: Amsterdam.
- Randal D. Koster, Max J. Suarez, and Mark Heiser., 2000: Variance and predictability of precipitation at seasonal-to-interannual timescales. *J. Hydrometeorol.*, 1, 26–46.
- Riahi K., Grübler A., Nakicenovic N., 2007. Scenarios of long-term socio-economic and environmental development under climate stabilization. *Technol Forecast Soc Chang* 74:887–935
- Richman MB. 1986. Rotation of principal components. *Int. J. Climatol.* 6: 293–335.
- Martin P., Hoerling, Arun Kumar, and Taiyi Xu, 2001: Robustness of the nonlinear climate response to ENSO's extreme phases. *Journal of Climate*, Vol.14, No.6, 1277-1293
- Mendes, D. and Marengo, J.A., 2010. Temporal downscaling: a comparison between artificial neural network and autocorrelation techniques over the Amazon Basin in present and future climate change scenarios. *Theoretical and Applied Climatology*, 100, 413–421.

- Mestas-Nuñez A M, Enfield DB, Zhang C., 2007 Water vapor fluxes over the Intra-Americas Sea: seasonal and interannual variability and associations with rainfall. *J Clim* 20:1910–1922.
- Murphy, B. F., & Timbal, B. (2008). A review of recent climate variability and climate change in southeastern Australia. *Int J Climatol.*, 28, 859–879.
- Trenberth, K. E., and D. P. Stepaniak, 2001: Indices of El Niño evolution. *J. Climate*, 14, 1697–1701,
- Satyamurty, P., R. Pinheiro Dos Santos, and M. A. Maringolo Lemes, 1980: On the stationary trough generated by the Andes. *Mon. Wea. Rev.*, 108, 510–520.
- Schneider, U., A. Becker, P. Finger, A. Meyer-Christoffer, M. Ziese, and B. Rudolf., 2013. GPCP's new land surface precipitation climatology based on quality-controlled in situ data and its role in quantifying the global water cycle. *Theor. Appl. Climatol.*, 115, 15–40, doi:10.1007/s00704-013-0860-x.
- Seluchi, M.E., and J.A. Marengo., 2000. Tropical–midlatitude exchange of air masses during summer and winter in South America: Climatic aspects and examples of intense events. *Int. J. Climatol.*, 20, 1167–1190.
- Seluchi, M.E., F.A. Norte, P. Satyamurty, and S.C. Chou., 2003. Analysis of three situations of the foehn effect over the Andes (zonda wind) using the Eta–CPTEC regional model. *Weather Forecast.*, 18, 481–501.
- Sevruk, B., and S. Klemm., 1989. Catalogue of national standard precipitation gauges. Instruments and observing methods, Report No. 39, WMO/TD-No. 313, 50 pp
- Simonovic, S. P., and L. Li (2003), Methodology for assessment of climate change impacts on large-scale flood protection system, *J. Water Resour. Plann. Manage.*, 129(5), 361–371.
- Smith SJ, Wigley TML., 2006. MultiGas forcing stabilization with minicam. *The Energy Journal Special issue #3*:373–392
- Stine, R. A., 1985: Bootstrap prediction intervals for regression. *J. Amer. Stat. Assoc.*, 80, 1026–1031
- Strangeways, I. 2007., *Precipitation: Theory, measurement and distribution*. Cambridge University Press, Cambridge, 290 pp

- Taylor, K. E., 2001. Summarizing multiple aspects of model performance in a single diagram, *J. Geophys. Res.*, 106(D7), 7183–7192,
- Taylor M, Alfaro E., 2005. Climate of Central America and the Caribbean. In *The Encyclopedia of World Climatology*, Oliver J (ed). Springer Press: Dordrecht, The Netherlands, 183–189.
- Taylor, K. E., R. J. Stouffer, and G. A. Meehl, 2009: A summary of the CMIP5 experiment design. *PCMDI Report*, 33 pp. [Available online at http://cmip-pcmdi.llnl.gov/cmip5/docs/Taylor_CMIP5_design.pdf.]
- Taylor, K. E., R. J. Stouffer, and G. A. Meehl., 2012: An overview of CMIP5 and the experiment design. *Bull. Amer. Meteor. Soc.*, 93, 485–498.
- Teichmann, C., Eggert, B., Elizalde, A., Haensler, A., Jacob, D., Kumar, P., Moseley, C., Pfeifer, S., Rechid, D., Remedio, A.R., Ries, H., Petersen, J., Preuschmann, S., Raub, T., Saeed, F., Sieck, K. and Weber, T. 2013. How Does a Regional Climate Model Modify the Projected Climate Change Signal of the Driving GCM: A Study over Different CORDEX Regions Using REMO. *Atmosphere*, 4, 214-236.
- Valverde Ramirez, M.C., Ferreira, N.J. and de Carvalho, H.F., 2006. Linear and nonlinear statistical downscaling for rainfall forecasting over Southeastern Brazil. *Weather Forecast*, 21, 969–989.
- Van Vuuren DP, Eickhout B, Lucas PL, den Elzen MGJ., 2006. Long-term multi-gas scenarios to stabilise radiative forcing—exploring costs and benefits within an integrated assessment framework. *Energ J* 27:201–233
- Van Vuuren DP, Den Elzen MGJ, Lucas PL, Eickhout B, Strengers BJ, Van Ruijven B, Wonink S, Van Houdt R., 2007 a. Stabilizing greenhouse gas concentrations at low levels: an assessment of reduction strategies and costs. *Clim Chang* 81:119–159
- Van Vuuren DP, Stehfest E, Den Elzen MGJ, Deetman S, Hof A, Isaac M, Klein Goldewijk K, Kram T, Mendoza Beltran A, Oostenrijk Retal., 2011a. RCP2.6: Exploring the possibility to keep global mean temperature change below 2°C. *Climatic Change*.
- Van Vuuren DP, Riahi K, Moss R, Thomson A, Nakićenović N, Edmonds J, Kram T, Berkhout F, Swart R, Janetos A et al., 2011b. Developing new scenarios as a thread for future climate research. *Global Environmental Change*

- Vera, C.S., J. Baez, M. Douglas, C. Emanuel, J.A. Marengo, J. Meitin, M. Nicolini, J. Noguez-Paegle, J. Paegle, O. Penalba, P. Salio, C. Saulo, M.A.F. Silva Dias, P.L. Silva Dias, and E. Zipser., 2006. The South American Low-Level Jet Experiment. *B. Am. Meteorol. Soc.*, 87, 63–77.
- von Storch, H., Zorita, E. and Cubasch, U., 1993. Downscaling of Global Climate Change Estimates to Regional Scales: An Application to Iberian Rainfall in Wintertime. *Journal of Climate*, 6(6), 1161-1171
- von Storch, H., Langenberg, H. and Feser, F., 2000. A Spectral Nudging Technique for Dynamical Downscaling Purposes. *Monthly Weather Review*, 128(10), 3664-3673.
- Wallace, J. M., and D. S. Gutzler., 1981: Teleconnections in the geopotential height field during the Northern Hemisphere winter. *Mon. Wea. Rev.*, 109, 784–812,
- Wang B, Ding Q, Fu X, Kang IS, Jin K, Shukla J, Doblas-Reyes F., 2005. Fundamental challenge in simulation and prediction of summer monsoon rainfall. *Geophys Res Lett* 32:L15711.
- Wang, C., and D.B. Enfield, 2001: The tropical Western Hemisphere warm pool, *Geophys. Res. Lett.*, 28, 1635-1638.
- Wang C, Enfield DB, Lee SK, Landsea CW., 2006. Influences of the Atlantic warm pool on Western Hemisphere summer rainfall and Atlantic hurricanes. *J Clim* 19:3011–3028
- Wilby, R.L. Wigley, T.M.L., (1997), Downscaling General Circulation Model output: a review of methods and limitations. *Progress in Physical Geography*, 21, 530-548.
- Wilby RL, Charles SP, Zorita E, Timbal B, Whetton P, Mearns LO. 2004. Guidelines for use of climate scenarios developed from statistical downscaling methods, Supporting material of the Intergovernmental Panel on Climate Change, available from the DDC of IPCC TGCI, 27.
- Wilby, R. L., I. Harris (2006), A framework for assessing uncertainties in climate change impacts: Low-flow scenarios for the River Thames, UK, *Water Resour. Res.*, 42, W02419.
- Wilks, D.S., 2006. *Statistical Methods in the Atmospheric Sciences*. 2nd ed., Academic Press/Elsevier, 627 pp.

- Wilks DS., 2009. A gridded multivariate weather generator and synchronization to observed weather data. *Water Resour Res* 45.
- Wise M, Calvin K, Thomson A, Clarke L, Bond-Lamberty B, Sands R, Smith SJ, Janetos A, Edmonds J., 2009. Implications of limiting CO₂ concentrations for land use and energy. *Science* 324:1183–1186
- Whyte, F. S., Taylor, M. A., Stephenson, T. S. and Campbell, J. D., 2008. Features of the Caribbean low level jet. *Int. J. Climatol.*, 28: 119–128.
- Wold, S., Esbensen, K. and Geladi, P. 1987. Principal Component Analysis. *Chemometrics Intell. Lab. Syst.* 2, 37–52.
- Schmidli, J., Frei, C. and Vidale, P. L., 2006. Downscaling from GCM precipitation: A benchmark for dynamical and statistical methods, *Int. J. Climatol.*, 26, 679–689
- Shukla, J., C. Nobre, and P. Sellers., 1990: Amazon deforestation and climate change. *Science* 247, 1322–1325.
- Solman, S.A. and Nuñez, M.N., 1999. Local estimates of global climate change: a statistical downscaling approach. *International Journal of Climatology*, 19, 835–861.
- Xu, C-Y. (1999), From GCMs to river flow: a review of downscaling methods and hydrologic modeling approaches. *Progress in Physical Geography*, 23, 229-249.
- Yang, H. and Wang, B., 2012. Reducing biases in regional climate downscaling by applying Bayesian model averaging on large-scale forcing. *Climate Dynamics*, 39(9-10), 2523 - 2532.
- Zhang, Y., J.M. Wallace, and N. Iwasaka., 1996. Is climate variability over the North Pacific a linear response to ENSO, *J. Clim.*, 9, 1468-1478.
- Zorita E, von Storch H. 1999. The analog method as a simple statistical downscaling technique: Comparison with more complicated methods. *Journal of Climate* 12: 2474–2489.
- Zorita E, von Storch H. 1997. A survey of statistical downscaling techniques. GKSS report 97/E/20, GKSS Research Center: Geesthacht.

