HABILIDAD DE LOS MODELOS CLIMÁTICOS GLOBALES PARA EL DESARROLLO DE PROYECCIONES REGIONALES

Jorge PÉREZ GARCÍA, Melisa MENÉNDEZ GARCÍA, Fernando J. MÉNDEZ INCERA Instituto de Hidráulica Ambiental "IH Cantabria". Universidad de Cantabria perezgj@unican.es, menendezm@unican.es, mendezf@unican.es

RESUMEN

Los modelos climáticos globales (GCMs) pueden ser usados para conectar predicciones de gran escala con dinámicas regionales mediante métodos de regionalización (downscaling). Debido a que una de las principales fuentes de incertidumbre para estimar proyecciones regionales es la elección del GCM, el objetivo de este estudio es evaluar la habilidad de los GCMs en el dominio español.

Es bien sabido que la variabilidad estacional e interanual de las variables superficiales oceánicas está ligada a los patrones de circulación atmosférica. Una de las variables que resume la dinámica sinóptica atmosférica y refleja de manera directa la interacción atmósfera- océano es la presión a nivel del mar (SLP). En este trabajo se investiga la habilidad de los GCMs para reproducir la variable SLP. El método de análisis se basa en un conjunto de tests para estudiar si los GCMs son capaces de reproducir los patrones espaciales y su transición temporal con respecto a la realidad en una región del sur de Europa. Tres factores importantes han sido analizados: la habilidad de los GCMs para reproducir las situaciones sinópticas más importantes, la habilidad de los GCMs para reproducir la variabilidad histórica a escala inter-anual y la consistencia de las simulaciones de los GCMs para el siglo XXI.

Los resultados de este análisis indican que UKMO-HadGEM2, ECHAM5/MPI-OM, MIROC32HIRES y MRI-CGCM2.3.2 son los GCMs con mayor destreza y se recomienda su uso para la estimación de proyecciones regionales multi-modelo.

Palabras clave: Escenarios, Modelos climáticos globales, Regionalización, Tipos de tiempo, Variabilidad climática, Proyecciones.

ABSTRACT

Global climate models (GCMs) can be used to connect global scale from relatively coarse resolution to regional dynamics at higher spatial resolution that can be conducted by downscaling methods. Because one of the main sources of uncertainty in estimating regional projections is the choice of the GCM, the aim of this study is to evaluate the skill of GCMs around the Spanish domain.

It is well known that the seasonal and interannual variability of surface ocean variables is linked to the atmosphere circulation patterns. One variable that summarizes the synoptic atmospheric dynamics and directly reflects the atmosphere-ocean interaction is the sea level pressure (SLP). This paper investigates the reliability of GCMs to reproduce the variable SLP. The analysis is based on a set of tests to study whether GCMs are able to reproduce the spatial patterns and temporal transition in a region of southern Europe. Three important factors have been analyzed: the skill of GCMs to reproduce the most important synoptic situations, the historical inter-annual time-scale variability and the consistency of GCMs experiments during 21st century projections.

The results of this analysis indicate that UKMO-HadGEM2, ECHAM5/MPI-OM, MIROC32HIRES and MRI-CGCM2.3.2 are the most skilled GCMs and are recommended for the estimation of regional multi-model projections.

Key words: Scenarios, Global climate models, Downscaling, Weather types, Climate variability, Projections.

1. INTRODUCCIÓN

En los últimos años los GCMs se han convertido en una de las herramientas más utilizadas para mejorar la comprensión del clima y proporcionar estimaciones del cambio climático futuro que puedan ser útiles para aquellos que estudian sus posibles consecuencias (IPCC, 2007). Los GCMs son modelos numéricos capaces de evaluar el efecto que los cambios en los forzamientos climáticos (concentración de gases de efecto invernadero, irradiancia solar, etc.) producen en un gran número de variables a escala global. Por ello, constituyen la base para las proyecciones climáticas regionales (obtener variables que los GCMs no simulan directamente y/o aumentar la resolución).

El principal problema que presentan los GCMs es la elevada incertidumbre a la que están sujetos. Al margen de la incertidumbre inherente a los escenarios de emisión de gases de efecto invernadero en proyecciones futuras y el efecto de estos gases y los aerosoles en la dinámica del sistema (Van Vuuren *et al.*, 2011), la habilidad de los GCMs en la generación de proyecciones de cambio climático para periodos futuros está condicionada por las distintas formulaciones y/o métodos de resolución de las ecuaciones que describen la dinámica de la atmósfera y océano, los esquemas numéricos, las parametrizaciones de procesos físicos, las resoluciones espaciales y temporales empleadas, la interacción de subsistemas como los usos del suelo, etc.

Existen numerosos trabajos en los que se han tratado de evaluar cuantitativa o cualitativamente los GCMs para distintas variables a escala regional, (por ej. Perkins *et al.* 2007; Maxino *et al.*, 2007), y en concreto en la península ibérica (por ej. Errasti *et al.*, 2010; Brands *et al.*, 2011). El análisis de sus resultados muestra que la calidad de cada modelo varía enormemente en función de la variable y la región consideradas.

En este estudio se ha comprobado la capacidad de los GCMs para representar los patrones sinópticos más importantes en la región de influencia del dominio español. Para ello se han utilizado las anomalías de la presión media a nivel del mar puesto que son un buen predictor para variables superficiales oceánicas (Wang y Swail, 2006).

El objetivo final es determinar los GCMs más apropiados para realizar proyecciones de variables superficiales oceánicas en España.

El documento se compone de esta introducción, una descripción de las bases de datos utilizadas y el área de estudio, la explicación de la metodología empleada, la exposición de los resultados obtenidos y la presentación de las conclusiones.

2. DATOS Y AREA DE ESTUDIO

2.1. Datos de modelos climáticos

Para este estudio se ha catalogado y posteriormente almacenado la información disponible de presión a nivel del mar a escala diaria, de 26 GCMs aceptados por el IPCC para varios escenarios de

cambio climático. El escenario 20C3M (emisiones del siglo XX) utilizado como control y 3 escenarios (Nakicenovic *et al.*, 2000) representativos del espectro de evoluciones más probables de las emisiones de gases de efecto invernadero: B1 (emisiones bajas), A1B (emisiones intermedias) y A2 (emisiones altas). Se han utilizado solo las simulaciones SRES para las que existían datos 20C3M asociados y viceversa, en total, 44 simulaciones del escenario 20C3M, 43 del A1B, 19 del A2 y 26 del B1. Los modelos que se han utilizado, el centro de investigación al que pertenecen, el país en que se encuentra dicho centro y el número de simulaciones aparecen reflejados en la Tabla 1.

Estos datos se han obtenido de los resultados de los modelos enviados al Program for Climate Model Diagnosis and Intercomparison (PCMDI) en el Lawrence Livermore National Laboratory en los Estados Unidos (http://www-pcmdi.llnl.gov/ipcc/about_ipcc.php) y de la base de datos CERA del World Data Center for Climate (WDCC) en Hamburgo (http://cera-www.dkrz.de/CERA/).

Modelo (Institución)	País	Nº simulaciones B1-A1B-A2
BCCR-BCM2.0 (Bjerknes Centre for Climate Research)	Norway	1-1-1
CCSM3 (National Center for Atmospheric Research)	USA	2-2-2
CGCM3.1(T47) (Canadian Centre for Climate Modelling and Analysis)	Canada	0-3-0
CGCM3.1(T63) (Canadian Centre for Climate Modelling and Analysis)	Canada	1-1-0
CNRM-CM3 (Centre National de Recherches Météorologiques)	France	1-1-1
CNRM-CM33 (Centre National de Recherches Météorologiques)	France	0-1-0
CSIRO-MK3.0 (CSIRO Atmospheric Research)	Australia	1-1-1
CSIRO-MK3.5 (CSIRO Atmospheric Research)	Australia	1-1-1
ECHAM5/MPI-OM (Max-Planck-Institute for Meteorology)	Germany	3-4-3
ECHAM5C/MPI-OM (Max-Planck-Institute for Meteorology)	Germany	0-3-0
ECHO-G (University of Bonn)	Germany	1-1-1
EGMAM (Freie Universitaet Berlin, Institute for Meteorology)	Germany	3-3-3
EGMAM2 (Freie Universitaet Berlin, Institute for Meteorology)	Germany	0-1-0
FGOALS-g1.0 (Institute of Atmospheric Physics)	China	3-3-0
GFDL-CM2.0 (Geophysical Fluid Dynamics Laboratory)	USA	1-1-1
GISS-AOM (Goddard Institute for Space Studies)	USA	1-1-0
GISS-ER (Goddard Institute for Space Studies)	USA	1-1-1
INGV-SXG (Istituto Nazionale di Geofisica e Vulcanologia)	Italy	0-1-0
INM-CM3.0 (Institute of Numerical Mathematics)	Russia	1-1-1
IPSL-CM4 (Institut Pierre Simon Laplace)	France	1-1-1
IPSL-CM4v2 (Institut Pierre Simon Laplace)	France	0-3-0
MIROC3.2 hires (Center for Climate System Research, NIES y RCGC)	Japan	1-1-0
MRI-CGCM2.3.2 (Meteorological Research Institute)	Japan	1-1-1
PCM (National Center for Atmospheric Research)	USA	2-0-1
UKMO-HadCM3C (Met Office Hadley Centre)	UK	0-2-0
UKMO-HadGEM2 (Met Office Hadley Centre)	UK	0-3-0

Tabla 1: Modelos climáticos globales analizados.

2.2. Datos de reanálisis atmosférico

Existen varias bases de datos procedentes de reanálisis que cubren el mundo en su totalidad. La base de datos utilizada en este trabajo procede del proyecto de reanálisis I de NCEP-NCAR (NCEP:

National Centers for Atmospheric Prediction; NCAR: National Center for Atmospheric Research). El reanálisis (Kalnay et al, 1996) constituye la reconstrucción más larga y actual (1948-presente) de diversos parámetros atmosféricos, ampliamente validada y utilizada por la comunidad científica. Este reanálisis mundial se genera con simulación numérica mediante el empleo de modelos similares a los que se usan para predicción del tiempo, e incluye un proceso de asimilación de datos. La asimilación de datos incluye mediciones tomadas en superficie y en altitud a lo largo de toda la superficie terrestre así como medidas de observaciones en buques y procedentes de satélite. Los resultados se proporcionan en una malla de cobertura global de, aproximadamente, 1.875° de resolución espacial y resolución temporal de 6 horas. Esta base de datos se ha utilizado para caracterizar los patrones sinópticos de circulación atmosférica y para validar las simulaciones del siglo XX de los GCMs.

2.3. Área de estudio

Se ha seleccionado un área que cubre la zona de influencia de los patrones de circulación atmosférica sobre variables oceánicas a lo largo del litoral de la península ibérica. Se extiende de 25° N a 65° N y de 52.5° W a 15° E. Dado que los modelos utilizan mallas irregulares de distintas resoluciones espaciales, para obtener una comparación coherente, los GCMs se han interpolado a la misma rejilla de 2.5°x2.5° utilizada en el reanálisis.

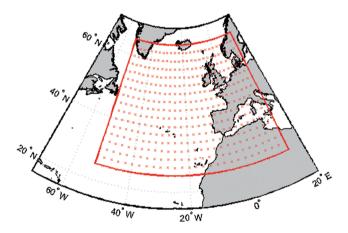


Fig. 1: Área de estudio.

3. METODOLOGÍA

3.1. Clasificación de patrones de circulación atmosférica (tipos de tiempo)

Los tipos de tiempo se definen en función de los campos de presiones a nivel del mar (SLP). Para ello, se analizan las anomalías 3-diarias de presiones en cada uno de los nodos del área de estudio. Por anomalía de presiones se entiende la diferencia entre la presión atmosférica en cada nodo y la presión atmosférica media en el dominio.

Los campos de anomalías de SLP son sintetizados utilizando varias herramientas de minería de datos (componentes principales y K-medias) para obtener n tipos de clima representativos (Camus *et al.*, 2011). El análisis de las componentes principales sirve para reducir la dimensionalidad del problema conservando el máximo de varianza de los datos. Este método estadístico descompone una

determinada variable numérica espaciotemporal en una combinación lineal de modos o funciones ortogonales numéricas (EOFs). Estos modos espaciales definen la nueva base de proyección y representan aquellas direcciones del espacio donde los datos tienen la mayor varianza. Las proyecciones sobre esta nueva base son las componentes principales (PCs). La proyección de los datos sobre cada modo temporal explica una determinada varianza de los mismos. En este caso se han seleccionado las PCs que explican el 95% de la varianza y sobre estas PCs se ha aplicado K-medias. La técnica K-medias permite dividir el espacio en n clases, que se representan por su centroide, cada una de las cuales agrupa un conjunto de estados de la atmósfera de características similares.

El número de tipos de clima considerado se ha fijado en 100, como solución de compromiso entre un número de clases suficientemente grande como para contener situaciones que en el presente son poco probables pero pueden aparecer con mayor frecuencia en las próximas décadas, y a la vez, que el número de datos en cada clase sea representativo. Los 100 tipos de clima y los histogramas asociados se han representado en una cuadrícula 10x10 organizada mediante mapas autoorganizativos (Kohonen *et al.*, 2000). Los mapas auto-organizativos (SOM) facilitan la interpretación de resultados al permitir que los tipos de tiempo de características similares se muestren agrupados según un criterio de proximidad. En la figura 2 se muestran a la izquierda los 100 tipos de tiempo considerados (representados por la anomalía de SLP en pascales) y a la derecha el tipo de tiempo más frecuente y el menos frecuente junto a su probabilidad de ocurrencia en el periodo 1961-1990.

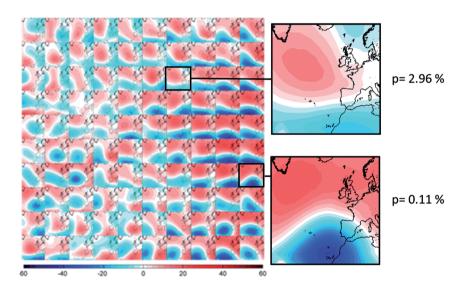


Fig. 2: Tipos de tiempo y probabilidad de ocurrencia del más y el menos frecuente.

3.2. Similaridad de situaciones sinópticas

La capacidad de los GCMs para simular el clima medio en el siglo XX es la prueba más común para evaluar la calidad de las simulaciones y por ello existen numerosas metodologías, como la basada en PDFs propuesta por Perkins *et al.* (2007), para evaluar la calidad de una simulación en una localización concreta. La principal deficiencia que presentan estas metodologías es que no evalúan las relaciones espaciales entre los distintos nodos, pero para realizar un downscaling estadístico basado en tipos de tiempo, no basta con analizar si se representa de forma adecuada el clima medio

en cada localización por separado, es necesario evaluar la capacidad de los GCMs para representar las distribuciones espaciales del predictor.

Por ello, se ha evaluado la calidad de los GCMs para representar las situaciones sinópticas en el área de estudio, tomando como referencia las probabilidades de ocurrencia para cada uno de los 100 tipos de tiempo del reanálisis atmosférico durante un periodo control de 30 años (desde el 1 de enero de 1961 al 31 de diciembre de 1990). Sin embargo, es necesario emplear índices objetivos que midan las discrepancias entre estas probabilidades y las del mismo periodo para las simulaciones del escenario 20C3M de cada GCM. Para esta comparación se han utilizado el scatter index (SI) y la entropía relativa (RE).

El scatter index resulta de la adimensionalización del error cuadrático medio dividiéndolo por la probabilidad media.

$$SI = \sqrt{\frac{\sum_{1}^{N} (p_{ij} - p_i^{'})^2}{N}} / \frac{\sum_{1}^{N} (p_i^{'})}{N}$$

Siendo p_i' la probabilidad media del tipo de tiempo i del reanálisis en el periodo control, p_{ij} la probabilidad media del tipo de tiempo i de la simulación de un GCM j en ese mismo periodo y N el número de tipos de tiempo considerados. Este índice se ha utilizado para comparar en el periodo control las probabilidades de ocurrencia medias de cada simulación de cada GCM con las del reanálisis (que se consideran datos cuasi-reales). El análisis se ha llevado a cabo tanto para las medias anuales como para las estacionales, considerando: invierno (diciembre, enero y febrero), primavera (marzo, abril y mayo), verano (junio, julio y agosto) y otoño (septiembre, octubre y noviembre).

La entropía relativa se define mediante la expresión:

$$RE = \sum_{1}^{N} p_{ij} \left| \log \frac{p_{ij}}{p_{i}} \right|$$

donde p_i', p_{ij} y N son los mismos parámetros que los descritos para el SI. Este índice permite analizar la capacidad de los GCMs para simular situaciones extremas, esto es, situaciones que por definición tienen una baja probabilidad de ocurrencia. En un análisis mediante scatter index tienen más peso las situaciones más frecuentes, por tanto, si sólo se usara dicho índice, la incapacidad de los modelos para simular situaciones poco probables pasaría desapercibida. El análisis de estas situaciones, que están asociadas a los eventos extremos, requiere un índice relativo como la entropía relativa.

3.3. Variabilidad interanual

Si bien es cierto que la habilidad de un modelo para representar el clima medio es la prueba más importante para determinar la calidad de este, esta es una condición necesaria pero no suficiente para evaluar su desempeño futuro. Para ello, también es necesario analizar la capacidad del modelo para representar la variabilidad climática natural. Si los GCMs son capaces de simular la variabilidad climática podrán responder mejor a condiciones cambiantes.

Se ha utilizado como medida de la variabilidad interanual la desviación típica. De esta forma, para cada tipo de tiempo, se ha estimado la desviación típica asociada a los 30 valores de probabilidad media anual en el periodo control. Para comparar los valores de variabilidad del reanálisis con los

correspondientes a cada GCM se volvió a recurrir al scatter index por su simplicidad y por proporcionar resultados adimensionalizados.

3.4. Consistencia de las proyecciones futuras

Centrarse excesivamente en la capacidad de los modelos para evaluar el clima pasado puede llevar a subestimar la incertidumbre y generar una excesiva confianza en los resultados. El análisis de las proyecciones, tiene como objetivo asegurar la consistencia de estas, para ello se ha dividido el siglo XXI en tres periodos: corto plazo (2010-2040), medio plazo (2040-2070) y largo plazo (2070-2100) y se ha estudiado qué modelos predicen variaciones inconsistentes en cada uno de estos periodos.

No se puede asegurar con certeza la magnitud del cambio futuro, pero como parte del proceso de downscaling se asume que el sistema climático no se verá alterado de tal manera que cambie la dinámica actual drásticamente. Por tanto, aunque haya cambios en la intensidad/ocurrencia de ciertas situaciones sinópticas se considera que el sistema climático actual se mantiene.

Para cada simulación y periodo futuro se han analizado 3 indicadores de la credibilidad del cambio: En primer lugar se ha evaluado mediante el scatter index la similaridad de las situaciones sinópticas del periodo futuro respecto al control, $SI(p_{ij})$. La mediana de los $SI(p_{ij})$ de todas las simulaciones es un estadístico robusto para estimar el orden de magnitud de este cambio, por lo que la magnitud de la diferencia respecto a este valor es el primer indicador de un cambio anómalo. En segundo lugar se han analizado los cambios en la variabilidad interanual, $SI(std(p_{ij}))$. Se ha utilizado como segundo indicador la diferencia entre este valor y la mediana de los $SI(std(p_{ij}))$ de todas las simulaciones. El tercer indicador es directamente el número de tipos de tiempo que presentan una variación superior al 50% en la frecuencia de ocurrencia.

4. RESULTADOS

Los resultados indican que los dos índices utilizados para analizar la representación de las situaciones sinópticas (RE y SI) muestran resultados cualitativamente muy parecidos. Esto indica que los modelos evalúan las probabilidades relativas tan bien (o tan mal) como las absolutas. Además puede apreciarse que la calidad de los modelos es bastante homogénea para todas sus simulaciones.

En los valores anuales destacan especialmente los modelos UKMO-HadGEM2 (SI=0.373 y RE=0.289), ECHAM5/MPI-OM (SI=0.455 y RE=0.351), MIROC32HIRES (SI=0.487 y RE=0.374) y MRI-CGCM2.3.2 (SI=0.502 y RE=0.413), por el contrario, modelos como CNRM-CM33 (SI=1.249 y RE=0.901), CNRM-CM3 (SI=1.225 y RE=0.852), FGOALS-g1.0 (SI=1.177 y RE=0.748) y GISS-ER (SI=1.165 y RE=0.855) no simulan correctamente la frecuencia de presentación de las situaciones sinópticas (Fig. 3).

Para el análisis estacional se detecta un patrón de diagnosis entre GCMs similar al anual pero con ciertas peculiaridades, especialmente en verano. En esta estación, por ejemplo, el mejor modelo en el resto de estaciones (UKMO-HadGEM2) presenta unos resultados más modestos, y el FGOALS-g1.0 muestra unos resultados especialmente malos (SI=3.704) que explican que sea uno de los peor calificados a escala anual. En cambio, otros modelos como el CCSM3 y PCM solo tienen resultados aceptables en verano siendo mucho peores en el resto de estaciones, y los modelos de la Commonwealth Scientific and Industrial Research Organisation (CSIROmk30 y CSIROmk35) solo destacan en esta estación.

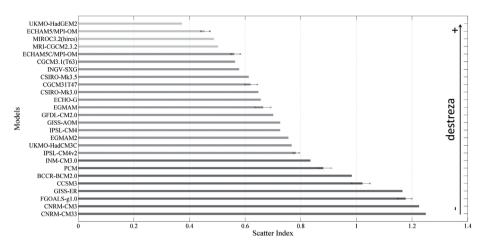


Fig. 3: GCMs ordenados en función de la similaridad de situaciones sinópticas.

Como puede verse en la figura 4 en la que se mantiene el orden de los modelos de la figura 3, los resultados obtenidos para la variabilidad interanual son semejantes a los obtenidos a la similaridad de situaciones sinópticas pero con scatter index más bajos, lo que indica que los modelos simulan mejor la variabilidad que las probabilidades medias. Los modelos CNCM33 (SI=0.682), CCSM3 (SI=0.576), y PCM (0.508) son los que proporcionan peores valores, mientras que UKMO-HadGEM2 (SI=0.244), ECHAM5/MPI-OM (SI=0.272), MIROC3.2(hires) (SI=0.314), CGCM31T63 (SI=0.332) y MRI-CGCM2.3.2 (SI=0.353) son los que obtienen una mejor valoración.

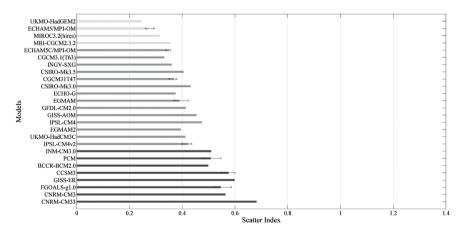


Fig. 4: Scatter index de la variabilidad interanual.

El análisis de las proyecciones futuras sólo puede emplearse para detectar comportamientos anómalos, lo que puede servir para descartar modelos pero no para determinar cuáles son los mejores. A pesar de ello, para los 3 escenarios considerados (B1, A1B y A2) y especialmente en el largo plazo (2070-2100), los resultados muestran, que modelos con poca destreza en el periodo control, presentan asimismo un comportamiento muy diferente al del resto de los modelos en las proyecciones futuras, y por lo tanto, a priori, menos creíble.

Como ejemplo, para el escenario A1B en el largo plazo, las medianas de los SI(pij), SI(std(pij)) y número de tipos de tiempo con variación superior al 50%, son 0.38, 0.3 y 32 respectivamente. No obstante, algunos modelos presentan valores muy superiores, como CNRM-CM3 (0.632, 0.398 y 46), FGOALS-g1.0 (0.613, 0.424 y 45), GISS-ER (0.604, 0.346 y 40), GFDL-CM2.0 (0.553, 0.337 y 45) y CNRM-CM33 (0.465, 0.388 y 38).

5. CONCLUSIONES

Se ha definido una metodología de análisis de la calidad de los GCMs basada en tipos de tiempo. La principal ventaja frente a otras metodologías es que permite evaluar directamente la capacidad de los GCMs para reproducir los patrones sinópticos de gran escala por lo que es especialmente adecuada para estudios de downscaling.

Tras el análisis de la calidad de los modelos, se observa un grupo de 4 modelos formado por los modelos que mejor evalúan la SLP en la zona de estudio y que son:

- UKMO-HadGEM2 del Hadley Centre for Climate Prediction and Research / Met Office, Reino Unido.
- ECHAM5/MPI-OM del Max-Planck-Institute for Meteorology, Alemania.
- MIROC3.2(hires) del Center for Climate System Research (The University of Tokyo), National Institute for Environmental Studies, and Frontier Research Center for Global Change (JAMSTEC), Japón.
- MRI-CGCM2.3.2 del Meteorological Research Institute, Japón.

Estos resultados son concluyentes para la variable SLP, ya que son similares para los distintos tests considerados y coinciden con los de otros estudios de la misma variable en la misma zona (Brands *et al.*, 2011). De esto se deduce que el método escogido para analizar la calidad de los GCMs es coherente. Por el contrario, la calidad de los modelos depende fuertemente de la zona de estudio y del predictor considerado, mostrando resultados muy diferentes a los obtenidos para otras variables o en otras zonas. En lo relativo al análisis estacional, cabe destacar que modelos que no presentan una buena calidad para la región estudiada pero muestran un buen resultado durante el verano boreal podrían ser adecuados en el hemisferio sur, especialmente en lo que se refiere a eventos extremos.

A pesar de esto, se observan diferencias notables incluso entre los modelos mejor valorados. Por ello se aconseja la utilización de ensembles o conjuntos multimodelo, lo que permite tener una mayor confianza en los resultados al disminuir el efecto de cada simulación individual.

Agradecimientos

Este trabajo ha sido posible gracias a la financiación proporcionada por la Oficina Española de Cambio Climático mediante el proyecto C3E (200800050084091), el Ministerio de Economía y Competitividad mediante el proyecto del Plan Nacional iMar21 (CTM2010-15009) y el proyecto GRACCIE (CSD2007 00067) en el marco del programa CONSOLIDERINGENIO 2010. Agradecemos a los grupos modeladores que han generado los datos utilizados y al PCMDI y WDCC por facilitar el acceso a ellos.

REFERENCIAS

Brands S, Herrera S, San-Martín D, Gutiérrez JM (2011). Validation of the ENSEMBLES global climate models over southwestern Europe using probability density functions, from a downscaling perspective. Clim Res 48:145–161

Camus, P., Mendez, F. J., Medina, R. and Cofiño, A. S. (2011). *Analysis of clustering and selection algorithms* for the study of multivariate wave climate. Coast. Eng. (2011), doi:10.1016/j.coastaleng.2011.02.003

- Errasti, I., Ezcurra, A., Sáenz, J., & Ibarra-Berastegi, G. (2010). *Validation of IPCC AR4 models over the Iberian Peninsula*. Theoretical and Applied Climatology. 103(1-2), 61-79. doi:10.1007/s00704-010-0282-y
- IPCC, 2007: Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change [Solomon, S., D. Qin, M. Manning, Z. Chen, M. Marquis, K.B. Averyt, M.Tignor and H.L. Miller (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
- Kalnay, E.M., Kanamitsu, R., Kistler, W., Collins, D., Deaven, L., Gandin, M., Iredell, S., Saha, G., White, J., Woollen, Y., Zhu, M., Chelliah, W., Ebisuzaki, W., Higgins, J., Janowiak, K.C., Mo, C., Ropelewski, J., Wang, A., Leetmaa, R., Reynolds, R., Jenne, R., Joseph, D., (1996). *The NCEP/NCAR 40-year reanalysis project*. Bulletin of the American Meteorological Society 77, 437–470.
- Kohonen, T., Kaski, S., Lagus, K., Salojarvi, J., Honkela, J., Paatero, V., Saarela, A. (2000), "Self organization of a massive document collection," Neural Networks, IEEE Transactions on, vol.11, no.3, pp.574-585, doi: 10.1109/72.846729
- Maxino CC, McAvaney BJ, Pitman AJ, Perkins SE (2007). Ranking the AR4 climate models over the Murray Darling Basin using simulated maximum temperature, minimum temperature and precipitation. Int J Climatol 28:1097–1112.
- Nakicenovic, N., and Coauthors, 2000: *IPCC Special Report on Emissions Scenarios*. Cambridge University Press, 599 pp.
- Perkins, S. E., A. J. Pitman, N. J. Holbrook, and J. McAneney, (2007). Evaluation of the AR4 climate models' simulated daily maximum temperature, minimum temperature and precipitation over Australia using probability density functions. J. Climate, 20, 4356–4376.
- van der Linden P., and J.F.B. Mitchell (eds.) (2009). ENSEMBLES: Climate Change and its Impacts: Summary of research and results from the ENSEMBLES project. Met Office Hadley Centre, FitzRoy Road, Exeter EX1 3PB, UK. 160pp.
- van Vuuren DP, Edmonds J, Kainuma MLT, Riahi K, Thomson A, Matsui T, Hurtt G, Lamarque J-F, Meinshausen M, Smith S, Grainer C, Rose S, Hibbard KA, Nakicenovic N, Krey V, Kram T (2011). Representative concentration pathways: An overview. Climatic Change (This Issue). doi:10.1007/s10584-011-0148-z
- Wang, X.L. and V. Swail (2006). Climate change signal and uncertainty in projections of ocean wave heights. Climate Dyn., 26, 109–126, doi:10.1007/s00382–005–0080–x