

UNIVERSIDAD DE CANTABRIA

E.T.S INGENIEROS DE CAMINOS, CANALES Y PUERTOS

Dpto. de Ciencias y Técnicas del Agua y del Medio Ambiente



TESIS DOCTORAL

**Metodologías para el análisis de la climatología
del oleaje: pasado, presente y futuro**

**Methodologies for the analysis of wave climate:
past, present and future**

Autor:

Jorge Pérez García

Directores:

Dra. Melisa Menéndez García

Dr. Fernando J. Méndez Incera

Instituto de Hidráulica Ambiental “IH Cantabria”

Julio 2015

Sólo si nos detenemos a pensar en las pequeñas cosas llegaremos a comprender las grandes

José Saramago

Preface

This thesis proposes new methodologies to simulate and characterize wave climate considering different temporal and spatial scales. Firstly, a method to characterize the area of influence of local wave climate is developed. Then, a statistical weather-type approach to simulate local multivariate sea states from regional pressure fields is defined. Next, the ability of global climate models (GCMs) to simulate historical and future climate is assessed. Lastly, these methodologies are combined to generate high-resolution multi-model regional wave climate projections in Europe. The main advantages of these methods are low computational cost and simplicity maintaining accuracy.

Acknowledgements

At the end of this thesis, after many years of effort, I can conclude that this journey has been a very enriching experience. I ought to thank the people who made it possible.

First of all, I would like to thank my supervisors Melisa and Fernando who also directed my thesis in the Master in Coastal Engineering and Ports. Melisa has tutored me since my first day at IH Cantabria with infinite patience and understanding. Fernando has contagious good mood and great ideas that make research much easier. “Thanks” would indeed be a small word to express my gratitude. Their guidance and motivation at every stage of my thesis has pushed me to this very point.

I am indebted to Iñigo Losada and Raúl Medina for the opportunity they gave me years ago trusting me to work at IH Cantabria. I am also thankful to IH Cantabria as an institution, it has been a second home.

I definitely also like to thank all those people who have been important source of motivation and positive criticism for me during these years: To my fellows from the wave climate and climate change group, I have learned from them the advantages of working with an exceptional team. Former comrades like Antonio Tomas, Roberto, Omar, Cristina, Paula, Killo, Borja and Yanira, and the new ones like Ana, Alexandra, Jose, Javi, Adrián, Carmen, Manu, Pedro and Nico.

To the people from the IT team: Iñaki, Felipe, Mauri, David and Emilio; because whenever I needed something they were right there with me.

To the rest of the IH people, Bea, Alba, Pablo, María and many others that make coming to work much more enjoyable.

To my friends, especially Borja, Eliana, Dani and Rubén. Among the few ones that are able to (occasionally) make me stop thinking about work.

Also thanks to the people from Santa Cruz: James Durning, Joyce Rice, Patrick Barnard, Li Erikson, Patrick Limber, Christine Hegermiller and Sean Vitousek; they were awesome hosts during my stay at the USGS.

And thanks to all the people who helped me directly or indirectly and that I unfortunately forgot to mention; they know that if they do not appear here is because of my poor memory.

Lastly I would like to greatly thank my family. My parents Guillermo and Pilar who have worked hard to help me get here; my brothers Rodrigo and Paula for being always

supportive; my grandparents for their constant concern; my yet little niece Matilda who has brought a great joy to the family; and also my indirect family Carmela.

I am who I am because of them.

Jorge Pérez García

July 2015

Contents

Preface	v
Acknowledgements	vii
Contents	ix
List of Figures	xiii
List of Tables	xix
List of Acronyms	xxi
0. Resumen en español	1
0.1. Introducción	2
0.1.1. Motivación	2
0.1.2. Estado del arte	2
0.1.2.1. Datos atmosféricos globales	3
0.1.2.2. Datos de oleaje globales	5
0.1.2.3. Regionalización (Downscaling)	5
0.1.3. Objetivos	6
0.1.4. Marco metodológico	8
0.1.5. Organización de la tesis	10
0.2. ESTELA: un método para evaluar el origen y el tiempo de propagación de la energía del oleaje	11
0.2.1. Introducción	11
0.2.2. Metodología	12
0.2.2.1. Criterios geográficos	12
0.2.2.2. Reconstrucción espectral	13
0.2.2.3. Evaluación del flujo de energía efectiva	15
0.2.2.4. Ganancia/Pérdida de energía	17
0.2.3. Resultados	18
0.3. Metodología de regionalización a partir de tipos de tiempo para clima marítimo	22
0.3.1. Introducción	22
0.3.2. El método de downscaling estadístico	23
0.3.3. Caso de estudio	25

0.3.3.1. Datos	25
0.3.3.2. Definición del predictor	26
0.3.3.3. Técnica de downscaling estadístico	26
0.3.3.4. Validación del método de downscaling estadístico	29
0.3.4. Aplicaciones del downscaling estadístico	30
0.3.4.1. Caracterización del oleaje	30
0.3.4.2. Hindcast de oleaje	33
0.3.4.3. Proyecciones de oleaje	34
0.4. Evaluando la habilidad de los modelos climáticos globales de CMIP3 y CMIP5 en el Atlántico Noreste	36
0.4.1. Introducción	36
0.4.2. Datos	37
0.4.2.1. Datos atmosféricos de reanálisis	37
0.4.2.2. Modelos climáticos globales	37
0.4.3. Metodología	38
0.4.3.1. Área de estudio	39
0.4.3.2. Clasificación de tipos de tiempo	39
0.4.3.3. Evaluación del desempeño de los GCMs	40
0.4.4. Resultados	42
0.4.4.1. Habilidad de los GCMs para representar climatologías . .	42
0.4.4.2. Habilidad de los GCMs para modelar la variabilidad climática	45
0.4.4.3. Consistencia de las proyecciones futuras	46
0.5. Proyecciones estadísticas multi-modelo del oleaje en Europa	50
0.5.1. Introducción	50
0.5.2. Datos	51
0.5.2.1. Datos atmosféricos históricos	51
0.5.2.2. Datos de oleaje históricos	51
0.5.2.3. Datos atmosféricos de Modelos Climáticos Globales . .	52
0.5.3. Métodos	52
0.5.3.1. Marco metodológico	52
0.5.3.2. Clasificación de tipos de tiempo	53
0.5.3.3. Técnica de downscaling	54
0.5.3.4. Selección del ensemble de modelos climáticos globales .	56
0.5.4. Resultados	58
0.5.4.1. Cambios proyectados en los tipos de tiempo	58
0.5.4.2. Cambios proyectados en el oleaje	58
0.6. Conclusiones y futuras líneas de investigación	63
0.6.1. Contribuciones principales	63
0.6.1.1. Sumario de “ESTELA: un método para evaluar el origen y el tiempo de propagación de la energía del oleaje”	63
0.6.1.2. Sumario de “Metodología de regionalización a partir de tipos de tiempo para clima marítimo”	64
0.6.1.3. Sumario de “Evaluando la habilidad de los modelos climáticos globales de CMIP3 y CMIP5 en el Atlántico Noreste”	64
0.6.1.4. Sumario de “Proyecciones estadísticas multi-modelo del oleaje en Europa”	65

0.6.2. Futuras líneas de investigación	66
1. Introduction	69
1.1. Motivation	69
1.2. State of knowledge	71
1.2.1. Global atmospheric data	71
1.2.2. Global wave data	72
1.2.3. Downscaling	74
1.3. Goals	74
1.4. Methodology framework	76
1.5. Organization of the thesis	78
2. ESTELA: a method for evaluating the source and travel time of the wave energy reaching a local area	79
2.1. Introduction	80
2.2. Methodology	81
2.2.1. Geographic criteria	82
2.2.2. Spectrum reconstruction	83
2.2.3. Effective energy flux assessment	85
2.2.4. Gain/loss of energy	86
2.3. Results	87
2.4. Summary and conclusions	93
3. A weather-type statistical downscaling framework for ocean wave climate	95
3.1. Introduction	96
3.2. The statistical downscaling method	98
3.3. Case study	101
3.3.1. Data	101
3.3.1.1. Predictor	101
3.3.1.2. Predictand	101
3.3.2. Predictor definition	103
3.3.3. Statistical downscaling method	104
3.3.3.1. Weather Type classification	104
3.3.3.2. Relationship between predictor and predictand	105
3.3.4. Validation of the statistical downscaling method	106
3.4. Applications of the statistical downscaling	108
3.4.1. Wave climate characterization	108
3.4.2. Wave climate hindcast	111
3.4.3. Wave climate projections	114
3.5. Summary and conclusions	114
4. Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region	117
4.1. Introduction	118
4.2. Data	120
4.2.1. Atmospheric reanalysis data	120
4.2.2. Global climate models	120

4.3.	Methods	122
4.3.1.	Study area	123
4.3.2.	Classification of weather types	124
4.3.3.	Evaluation of the performance of GCMs	125
4.3.3.1.	Similarity of synoptic situations	125
4.3.3.2.	Interannual variability	128
4.3.3.3.	Consistency of future projections	128
4.4.	Results	129
4.4.1.	Skill of GCMs to perform climatologies	129
4.4.2.	Skill of GCMs to perform climate variability	132
4.4.3.	Consistency of future projections	135
4.5.	Conclusions	139
5.	Statistical multi-model climate projections of surface ocean waves in Europe	141
5.1.	Introduction	142
5.2.	Data	143
5.2.1.	Historical atmospheric data	143
5.2.2.	Historical wave data	144
5.2.3.	Global Climate Models atmospheric data	144
5.3.	Methods	145
5.3.1.	Framework	145
5.3.2.	Weather type classification	146
5.3.3.	Statistical downscaling technique	147
5.3.4.	Selection of the ensemble of Global Climate Models	148
5.4.	Results	151
5.4.1.	Projected changes in the weather types	151
5.4.2.	Projected wave climate changes	152
5.5.	Summary and conclusions	155
6.	Summary and future research	157
6.1.	Summary of contributions	157
6.1.1.	Summary of “ESTELA: a method for evaluating the source and travel time of the wave energy reaching a local area”	157
6.1.2.	Summary of “A weather-type statistical downscaling framework for ocean wave climate”	158
6.1.3.	Summary of “Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region”	158
6.1.4.	Summary of “Statistical multi-model climate projections of surface ocean waves in Europe”	159
6.2.	Future research topics	160
Bibliography		163

List of Figures

0.1.	Forzamiento radiativo en W m^{-2} proyectado a lo largo del siglo 21 a partir de escenarios SRES y RCPs (Fuente: Figura 1-4 del AR5 WGII)	4
0.2.	Marco metodológico de la tesis	8
0.3.	Criterios geográficos para un punto objetivo P [10°W, 39°N] en el Atlántico Noreste. El área geográfica seleccionada se representa en verde y el área que se desprecia se representa en rojo	13
0.4.	<i>Izquierda</i> Un ejemplo del círculo máximo entre un punto de origen en Canadá y un punto de destino cerca de Portugal. <i>Derecha</i> Espectro de energía del oleaje en el punto de origen. Se muestra coloreada la sección transversal seleccionada, que representa la energía de las olas que se propagan a lo largo del círculo máximo entre TP y SP	16
0.5.	<i>Izquierda</i> Malla polar de baja resolución centrada en un punto de destino P [10°W, 39°N] en el Océano Atlántico Nordeste. <i>Derecha</i> diagrama de ganancia/pérdida de energía	17
0.6.	Flujo de energía eficaz medio en 1993-2012 para el sitio A. La zona coloreada se define por el conjunto de puntos de origen que satisfacen los criterios geográficos. El tiempo de viaje se representa por las líneas grises y negras	19
0.7.	Áreas de ganancia/pérdida de energía en 1993-2012 para el sitio A	20
0.8.	Los gráficos superiores muestran el flujo de energía media efectiva para el sitio C durante NAO + (<i>izquierda</i>) y NAO- (<i>derecha</i>). Los gráficos inferiores muestran el flujo de energía media efectiva para el sitio D durante el invierno (<i>izquierda</i>) y el verano (<i>derecha</i>) boreales	21
0.9.	Diagrama de flujo que representa la metodología de downscaling estadístico	24
0.10.	Los 100 tipos de tiempo representados por los campos de SLP (hPa) obtenidos a partir de la clasificación atmosférica	27
0.11.	(a) probabilidad de ocurrencia estacional de los 100 tipos de tiempo (clasificación mostrada en la figura 0.10) para NCEP-NCAR reanálisis-I en el periodo de calibración (1960-1999). (b) Probabilidad de ocurrencia de las condiciones actuales (1960-1999) de los tipos de tiempo en NCEP-NCAR reanálisis-I, 20CR reanálisis, y el modelo climático EC-EARTH, de izquierda a derecha	28
0.12.	<i>Izquierda</i> Varios patrones (WT35, WT100, WT29 y WT2 de la clasificación de WTs mostrada en la figura 0.10; la escala de rojos representa los SLPG y las líneas representan el campo de SLP (línea discontinua por debajo de 1.013 hPa y continua por encima). <i>Centro</i> Distribución asociada de altura de ola significante horaria y periodo medio en la ubicación GA. <i>Derecha</i> Distribución asociada de altura de ola significante y dirección en la ubicación GA	29

0.13. Comparación de series temporales y diagramas de dispersión de los parámetros de estado de mar mensuales: H_s , H_{p95} , T_m , $H_s^2 T_m$, θ_{FE} en el periodo 2001-2009 en la localización GA. Las líneas continuas muestran las series temporales del hindcast GOW. Las líneas discontinuas representan los parámetros mensuales obtenidos a partir de la metodología de downscaling propuesta	31
0.14. Distribución de H_s y θ_m asociadas a cada tipo de tiempo en la ubicación al oeste de Irlanda. Las unidades de la distancia radial están en m con la misma escala que en la figura 0.12 (los incrementos de H_s son 2 m)	32
0.15. (a) Series temporales de la reconstrucción histórica de H_s mensual a partir de 20CR (1900-1960); NCEP-NCAR reanálisis-I para el periodo de calibración (1960-2000) y el periodo de validación (2001-2013); y el invierno 2013-2014 (línea roja) para las dos localizaciones analizadas. (b) La reconstrucción de H_s de invierno (DEFM) a partir de 20CR (negro) y NCEP-NCAR reanálisis-I (azul) en la ubicación de IR y el índice climático NAO de invierno (verde)	34
0.16. GCMs de CMIP3 y ENSEMBLES ordenados por la habilidad para modelar situaciones sinópticas (habilidad mayor, SI menor). El RE medio está representado por un punto negro	43
0.17. GCMs de CMIP5 ordenados por la habilidad para modelar situaciones sinópticas (habilidad mayor, SI menor). El RE medio está representado por un punto negro	44
0.18. Habilidad de los GCMs de CMIP3 y ENSEMBLES (a) y CMIP5 (b) para simular la variabilidad interanual (habilidad mayor, SI menor)	47
0.19. Diagramas de cajas de los dos indicadores de consistencia para los escenarios B1, A1B y A2	48
0.20. Diagramas de cajas de los dos indicadores de consistencia para los escenarios RCP2.6, RCP4.5, RCP6.0 y RCP8.5	49
0.21. Los 100 tipos de tiempo representados por los campos medios 3-diarios de SLP (mb)	55
0.22. H_s , en metros (<i>superior</i>) y T_{02} , en segundos (<i>inferior</i>) asociados a cada tipo de tiempo	57
0.23. Cambios en frecuencia de los tipos de tiempo para diferentes escenarios (rcp2.6 <i>superior</i> , rcp4.5 <i>medio</i> y rcp8.5 <i>inferior</i>) y periodos de tiempo (2010-2039 <i>izquierda</i> , 2040-2069 <i>medio</i> y 2070-2099 <i>derecha</i>) respecto al periodo de referencia (1975-2004). Los puntos en los tipos de tiempo indican que más del 80 % de los modelos coinciden en el signo del cambio .	59
0.24. Cambios en H_s media en el Atlántico Noreste, en metros, para diferentes escenarios (rcp2.6 <i>superior</i> , rcp4.5 <i>medio</i> y rcp8.5 <i>inferior</i>) y periodos de tiempo (2010-2039 <i>izquierda</i> , 2040-2069 <i>medio</i> y 2070-2099 <i>derecha</i>) respecto al periodo de referencia (1975-2004). Las áreas sin sombreado indican que más del 80 % de los modelos coinciden en el signo del cambio	60
0.25. Cambios en T_{02} medio en el Atlántico Noreste, en segundos, para diferentes escenarios (rcp2.6 <i>superior</i> , rcp4.5 <i>medio</i> y rcp8.5 <i>inferior</i>) y periodos de tiempo (2010-2039 <i>izquierda</i> , 2040-2069 <i>medio</i> y 2070-2099 <i>derecha</i>) respecto al periodo de referencia (1975-2004). Las áreas sin sombreado indican que más del 80 % de los modelos coinciden en el signo del cambio)	61

0.26. Cambios en flujo de energía medio en las costas europeas, en kWm^{-1} , para diferentes escenarios (rcp2.6 <i>superior</i> , rcp4.5 <i>medio</i> y rcp8.5 <i>inferior</i>) y periodos de tiempo (2010-2039 <i>izquierda</i> , 2040-2069 <i>medio</i> y 2070-2099 <i>derecha</i>) respecto al periodo de referencia (1975-2004). Las áreas sin sombreado indican que más del 80 % de los modelos coinciden en el signo del cambio)	62
1.1. Representation of spatial domains (global, regional and local)	70
1.2. Simulations and projections of annual mean GMST (global mean surface air temperature) anomalies relative to 1986–2005. (Source: Figure 11.25a AR5 WGI)	70
1.3. Projected radiative forcing in W m^{-2} over the 21st century from the SRES and RCP scenarios (Source: Figure 1-4 AR5 WGII)	73
1.4. Methodological framework of the thesis	76
2.1. Flowchart representing the ESTELA methodology	81
2.2. Geographic criteria for a target point P [10°W , 39°N] in the North-East Atlantic Ocean. The selected geographic area is represented in green and the neglected area is represented in red	83
2.3. <i>Left</i> An example of the great circle between a target point near Portugal and a source-point in Canada. <i>Right</i> Wave energy spectrum at the source point. The selected cross section of wave energy that will propagate along the great circle between TP and SP is coloured	86
2.4. Polar grid with coarse resolution centred in a target point P [10°W , 39°N] in the North-East Atlantic Ocean (<i>left</i>) and diagram of gain/loss of energy (<i>right</i>)	87
2.5. Mean effective energy flux from 1993 to 2012 for site A. The coloured area is defined by the group of source points that satisfy the geographic criteria. The travel time is represented by the grey and black lines	89
2.6. Gain/loss of energy areas from 1993 to 2012 for site A	90
2.7. Mean effective energy flux in 1996 (<i>upper left</i>), 1998 (<i>upper right</i>), boreal winter (<i>lower left</i>) and summer (<i>lower right</i>) for site A	90
2.8. Mean effective energy flux for site B. The upper chart shows the aggregation of years from 1993 to 2012. The lower charts show January (<i>left</i>) and August (<i>right</i>) months of 1998	91
2.9. The upper charts show the mean effective energy flux for site C during NAO+ (<i>left</i>) and NAO- (<i>right</i>). The lower charts show the mean effective energy flux for site D during boreal winter (<i>left</i>) and summer (<i>right</i>)	92
3.1. Flowchart representing the statistical downscaling methodology	98
3.2. Selected spatial domain of SLP predictor (only black grid points are considered). Red circles show the locations of the analyzed predictand (local wave climate)	102
3.3. (<i>left</i>) Scatterplot and quantile-quantile plot and (<i>right</i>) time series of significant wave height (m) from buoy records versus GOW hindcast for a location in (a) west Ireland and (b) Norwest Spain. Buoy records are in red and GOW data in black	103
3.4. The 100 weather types represented by the SLP fields (hPa) obtained from the atmospheric classification	105

3.5. (a) Seasonal probability of occurrence of the 100 weather types (classification shown in Figure 3.4) for the NCEP-NCAR reanalysis-I for the calibration period 1960–1999. (b) Probability of occurrence for the present conditions (1960–1999) of the weather types from the NCEP-NCAR reanalysis-I, 20CR reanalysis, and climate model EC-EARTH, from left to right	106
3.6. Several patterns (WT35, WT100, WT29, and WT2 from the WT classification shown in Figure 3.4) with the associated distribution of hourly significant wave height and mean period and distribution of the significant wave height and mean direction at GA location. The contours represent the SLP field (dashed below and continuous over 1013 hPa) and the red scale represents the SLPG	107
3.7. Time series comparison and scatterplots of the monthly sea-state parameters: H_s , H_{p95} , T_m , $H_s^2 T_m$, θ_{FE} in the period 2001–2009 at the IR location. Solid lines show the GOW hindcast time series. Dashed lines represent the monthly parameters obtained from the downscaling framework proposed	108
3.8. Time series comparison and scatterplots of the monthly sea-state parameters: H_s , H_{p95} , T_m , $H_s^2 T_m$, θ_{FE} in the period 2001–2009 at the GA location. Solid lines show the GOW hindcast time series. Dashed lines represent the monthly parameters obtained from the downscaling framework proposed	109
3.9. Wave climate characterization at the (<i>top</i>) west Irish location and (<i>bottom</i>) northwest Spanish location associated with WT classification (shown in Figure 3.4). (<i>left</i>) The mean significant wave height (units in m), (<i>middle</i>) standard deviation of the significant wave height (units in m), and (<i>right</i>) mean wave energy flux direction (units in °) associated with each WT	110
3.10. Distribution of H_s and θ_m associated with each weather type at the west Irish location (shown in Figure 3.4). The units of the radial distance are in m with the same scale as in Figure 3.6 (H_s increments are 2.0 m)	111
3.11. (a) Time series of the monthly H_s historical reconstruction from 20CR (1900–1960), NCEP-NCAR reanalysis-I for the calibration period (1960–2000) and the validation period (2001–2013) and the winter 2013–2014 (red line) for the two target points. (b) Winter H_s (DJFM) reconstruction from 20CR (black) and NCEP-NCAR reanalysis-I (blue) at IR location and the NAO winter climate index (green)	113
3.12. Box plots of H_s winter (DJFM) for present climatology (1980–2010), historical reconstructed periods (1900–1930, 1930–1960), and future projected climate scenarios (2070–2100) for the EC-Earth model. On each box, the central mark is the median, the edges of the box are the lower (Q1) and upper (Q3) quartiles (interquartile range, IQR), and the whiskers extend to the higher values, within the range defined by Q1+1.5(IQR) and Q3+1.5(IQR)	115
4.1. Flowchart representing the methodology	123
4.2. Spatial domain of the study area	124
4.3. The 100 weather types represented by the SLP fields (mbar). Right panels show the most frequently occurring weather types in winter and summer .	126

4.4.	Relative frequency of the 100 weather types in the reference period for NCEP/NCAR reanalysis (quasiobservations) and four GCMs. The darker blue colors being weather types with high frequency and the lighter blue the less frequent weather types	127
4.5.	Bias of 20C3M (<i>left</i>) and historical (<i>right</i>) ensembles. The small dots indicate agreement on the sign for more than 80 % of the models	130
4.6.	GCMs of CMIP3 and ENSEMBLES sorted out by performance to model synoptic situations (the higher performance, the lower <i>SI</i>). The mean <i>RE</i> is represented by a black dot	131
4.7.	GCMs of CMIP5 sorted out by performance to model synoptic situations (the higher performance, the lower <i>SI</i>). The mean <i>RE</i> is represented by a black dot	132
4.8.	GCMs of CMIP3 and ENSEMBLES performance to model synoptic situations on each season 1 UKMO-HadGEM2; 2 ECHAM5/MPI-OM; 3 MIROC3.2(hires); 4 MRI-CGCM2.3.2; 5 ECHAM5C/MPI-OM; 6 CGCM3.1(T63); 7 INGV-SXG; 8 CSIRO-Mk3.5; 9 CGCM31T47; 10 CSIRO-Mk3.0; 11 ECHO-G; 12 EGMAM; 13 GFDL-CM2.0; 14 GISS-AOM; 15 IPSL-CM4; 16 EGMAM2; 17 UKMO-HadCM3C; 18 IPSL-CM4v2; 19 INM-CM3.0; 20 PCM; 21 BCCR-BCM2.0; 22 CCSM3; 23 GISS-ER; 24 FGOALS-g1.0; 25 CNRM-CM3; 26 CNRM-CM33	133
4.9.	GCMs of CMIP5 performance to model synoptic situations on each season 1 ACCESS1.0; 2 EC-EARTH; 3 HadGEM2-AO; 4 HadGEM2-CC; 5 HadGEM2-ES; 6 MPI-ESM-P; 7 CMCC-CM; 8 GFDL-CM3; 9 MPI-ESM-LR; 10 CMCC-CMS; 11 CESM1(CAM5); 12 MIROC4h; 13 CSIRO-Mk3.6.0; 14 GFDL-ESM2M; 15 MPIESM-MR; 16 HadCM3; 17 GFDL-ESM2G; 18 CNRM-CM5; 19 ACCESS1.3; 20 INM-CM4; 21 CanESM2; 22 CanCM4; 23 NorESM1-M; 24 CMCC-CESM; 25 GISS-E2-R; 26 MRI-ESM1; 27 GISS-E2-H; 28 IPSL-CM5A-MR; 29 BCC-CSM1.1; 30 CCSM4; 31 MRI-CGCM3; 32 CESM1(BGC); 33 CESM1(FASTCHEM); 34 MIROC5; 35 IPSL-CM5A-LR; 36 BNU-ESM; 37 MIROC-ESM; 38 MIROC-ESM-CHEM; 39 FGOALS-s2; 40 BCC-CSM1.1(m); 41 IPSL-CM5B-LR; 42 FGOALS-g2	134
4.10.	GCMs of CMIP3 and ENSEMBLES (a) and CMIP5 (b) performance to simulate interannual variability (the higher performance, the lower <i>SI</i>)	136
4.11.	Box plots of the two indicators of consistency for scenarios B1, A1B and A2. Numbering in accordance with Figure 4.8	137
4.12.	Box plots of the two indicators of consistency for scenarios RCP2.6, RCP4.5, RCP6.0 and RCP8.5. Numbering in accordance with Figure 4.9	138
4.13.	Changes of A2 (<i>left</i>) and RCP8.5 (<i>right</i>) ensembles in 2070–2099 towards the reference period (20C3M, historical). The small dots indicate agreement on the sign for more than 80 % of the models	139
5.1.	Flowchart representing the methodology to obtain wave climate projections	145
5.2.	The 100 weather types represented by the 3-day averaged SLP fields (mb)	147
5.3.	H_s , in meters (<i>top</i>) and T_{02} , in seconds (<i>bottom</i>) associated to each weather type	149
5.4.	Relative frequencies of weather types during the control period (1979–2004) for reanalysis (<i>left</i>) and the ensemble of GCMs (<i>right</i>)	152

-
- 5.5. Changes in the frequency of the weather types for different scenarios (rcp2.6 *top*, rcp4.5 *middle* and rcp8.5 *bottom*) and time periods (2010-2039 *left*, 2040-2069 *middle* and 2070-2099 *right*) towards the reference period (1975-2004). Dots in the weather types indicate agreement on the sign of change of more than 80 % of the models 153
 - 5.6. Changes in mean significant wave heights in the Eastern North Atlantic, in meters, for different scenarios (rcp2.6 *top*, rcp4.5 *middle*, and rcp8.5 *bottom*) and time periods (2010-2039 *left*, 2040-2069 *middle*, and 2070-2099 *right*) towards the reference period (1975-2004). No shadowed areas indicate agreement on the sign of change of more than 80 % of the models 154
 - 5.7. Changes in mean T_{02} wave periods in the Eastern North Atlantic, in seconds, for different scenarios (rcp2.6 *top*, rcp4.5 *middle*, and rcp8.5 *bottom*) and time periods (2010-2039 *left*, 2040-2069 *middle*, and 2070-2099 *right*) towards the reference period (1975-2004) 155
 - 5.8. Changes in mean energy flux along the European coastline, in kWm^{-1} , for different scenarios (rcp2.6 *top*, rcp4.5 *middle*, and rcp8.5 *bottom*) and time periods (2010-2039 *left*, 2040-2069 *middle*, and 2070-2099 *right*) towards the reference period (1975-2004). No shadowed areas indicate agreement on the sign of change of more than 80 % of the models 156

List of Tables

4.1.	Analyzed CMIP3 and ENSEMBLES GCMs names, institutions, countries, atmospheric resolutions and runs	121
4.2.	Analyzed CMIP5 GCMs names, institutions, countries, atmospheric resolutions and runs	122
5.1.	Evaluation of the performance of the CMIP5 GCMs. Selected GCMs in bold	151

List of Acronyms

20C3M Twentieth Century Climate in Coupled Models
20CR Twentieth Century Reanalysis
AR4 IPCC Fourth Assessment Report
AR5 IPCC Fifth Assessment Report
CET Center for Enabling Technologies
CFSR Climate Forecast System Reanalysis
CFSv2 Climate Forecast System Version 2
CIRES Cooperative Institute for Research In Environmental Sciences
CMIP3 Coupled Model Intercomparison Project phase 3
CMIP5 Coupled Model Intercomparison Project phase 5
COWCLIP	.. Coordinated Ocean Wave Climate Project
EA East Atlantic pattern
ECMWF European Centre for Medium-Range Weather Forecasts
EOF Empirical Orthogonal Function
ERA-40 40-year ECMWF Reanalysis
ESG Earth System Grid
ESRL Earth System Research Laboratory
ESTELA a method for Evaluating the Source and Travel-time of the wave Energy reaching a Local Area
GCM Global Climate Model
GOW Global Ocean Waves
GSHHG Global Self-consistent Hierarchical High-resolution Geography Data-base
IFS Integrated Forecasting System

- IPCC** Intergovernmental Panel on Climate Change
- JONSWAP** . . JOint North SeaWAve Project
- KMA** K-Means Algorithm
- LAM** Limited Area Model
- MDA** Maximum-Dissimilarity Algorithm
- NAM** Northern Annular Mode
- NAO** North Atlantic Oscillation
- NCAR** National Center for Atmospheric Research
- NCEP** National Centers for Environmental Prediction
- NNR** NCEP/NCAR Reanalysis
- NOAA** National Oceanic and Atmospheric Administration
- PC** Principal Component
- PCA** Principal Component Analysis
- PCMDI** Program for Climate Model Diagnosis and Intercomparison
- PNA** Pacific North America teleconnective index
- PSD** Physical Sciences Division
- RCM** Regional Climate Model
- RCP** Representative Concentration Pathway
- SAM** Southern Annular Mode
- SAR** Synthetic Aperture Radar
- SD** Statistical Downscaling
- SLP** Sea Level Pressure
- SLPG** squared SLP Gradients
- SRES** Special Report on Emission Scenarios
- UNEP** United Nations Environment Programme
- VOS** Voluntary Observing Ship
- WCRP** World Climate Research Programme
- WDCC** World Data Center for Climate
- WMO** World Meteorological Organization
- WRF** Weather Research and Forecasting model
- WT** Weather Type

A mi familia

Capítulo 0

Resumen en español

Con el objetivo de lograr una mayor difusión dentro de la comunidad científica, esta tesis doctoral ha sido redactada en inglés. Sin embargo, la normativa de estudios de doctorado de la Universidad de Cantabria, aprobada por Junta de Gobierno de 12 de marzo de 1999 y actualizada a 18 de diciembre de 2013, exige que aquellas tesis redactadas en un idioma diferente al español incluyan un resumen de la misma en español. A continuación se presenta un resumen de la tesis manteniendo una estructura similar a la del documento en inglés.

0.1. Introducción

0.1.1. Motivación

El sistema climático está gobernado por una serie de fenómenos que se producen a escalas espaciales y temporales muy distintas. Por ejemplo, el clima a escala local está condicionado por el clima a escala regional, y este a su vez por el clima a escala global. De la misma forma, la evolución climática se ha de estudiar en función de distintas escalas de tiempo de interés como estacionalidad, interanualidad, y cambios a largo plazo. Además, para analizar los cambios a largo plazo, el estudio de las tendencias históricas se ha de complementar con el estudio de la evolución del clima ante distintos escenarios de desarrollo socioeconómico y emisiones de gases de efecto invernadero. La acción conjunta de estos fenómenos es la que produce los cambios a escala local en las variables de clima marítimo (e.g. oleaje y viento). Por ejemplo, un incremento en la energía del oleaje que alcanza las costas podría producir retrocesos en las playas, una reducción en la operatividad de los puertos, o incrementos de los caudales de rebase en las estructuras costeras, así como una alteración en las comunidades intermareales. El conocimiento de estas variaciones tiene una importancia fundamental para la sociedad, ya que permite desarrollar medidas de adaptación. De esta forma, se podría reducir el impacto económico y social negativo que pueden provocar la variabilidad climática y el cambio climático.

0.1.2. Estado del arte

Esta tesis se centra en el estudio del clima marítimo. En este documento el término clima marítimo se refiere a los procesos del sistema climático terrestre que informan sobre las condiciones del oleaje generado por viento. Para estudiar el clima marítimo es necesario disponer de bases de datos de atmósfera (e.g. viento y presión atmosférica) y de oleaje (e.g. altura de ola significante y periodo medio). Estas bases de datos han de servir para estudiar la variabilidad temporal y espacial del clima. Para estudiar la variabilidad temporal se necesitan bases de datos históricas, que permiten analizar el clima en el pasado, y proyecciones a partir de escenarios de cambio climático, que permiten analizar el clima en el futuro. Para estudiar la variabilidad espacial se requieren bases de datos de una resolución adecuada a los fenómenos a estudiar, esto obliga a analizar las relaciones entre el clima a escala global y el clima a escala local mediante técnicas de regionalización o “downscaling”.

0.1.2.1. Datos atmosféricos globales

El estudio del clima en el pasado se puede basar en distintas fuentes de datos como, por ejemplo, observaciones visuales, medidas instrumentales y bases de datos generadas a partir de modelos. Todas estas bases de datos presentan limitaciones. Las observaciones visuales son heterogéneas espacial y temporalmente; los datos instrumentales (e.g. anemómetros y satélites) cubren períodos de tiempo cortos y están concentradas en pocos lugares; y las bases de datos generadas con modelos presentan errores importantes en áreas complejas o ante condiciones climáticas excepcionales. Una manera de evitar estas limitaciones es utilizar datos de reanálisis. Los reanálisis combinan modelos numéricos similares a los que se utilizan en predicción meteorológica con asimilación de datos instrumentales para realizar reconstrucciones del sistema climático de hasta varias décadas. Al combinar las fortalezas de las distintas fuentes de datos, los reanálisis consiguen proporcionar representaciones homogéneas del sistema climático en el pasado con una distribución espacial uniforme. Por ejemplo, NCEP/NCAR Reanalysis I (NNR, Kalnay et al. 1996), ECMWF 40 year Reanalysis (ERA-40, Uppala et al. 2005), NCEP Climate Forecast System Reanalysis (CFSR, Saha et al. 2010) y NOAA-CIRES twentieth Century Reanalysis (20CR, Compo et al. 2011) han sido utilizados en esta tesis por distintos motivos. NNR y ERA-40 son útiles para validar resultados ya que han sido ampliamente utilizados por la comunidad científica, CFSR proporciona resultados con una resolución espacial muy alta (aproximadamente 0.3°) y 20CR cubre un periodo de tiempo muy extenso (aproximadamente 150 años).

El clima en el futuro ha de estudiarse teniendo en cuenta el efecto del cambio climático. Para el grupo intergubernamental de expertos sobre cambio climático (Intergovernmental Panel on Climate Change, IPCC), el término “cambio climático” denota un cambio en el estado del clima a lo largo del tiempo, tanto si es debido a la variabilidad natural como si es consecuencia de la actividad humana. Las proyecciones de modelos climáticos globales (Global Climate Models, GCMs) son una herramienta muy útil para estudiar los cambios en el sistema climático global ante distintos escenarios de concentraciones de gases de efecto invernadero en la atmósfera. El análisis de las proyecciones permite comprender de manera más sistemática la cronología y magnitud de los impactos vinculados a diferentes magnitudes y tasas de cambio climático y evaluar los riesgos a los que se enfrenta la sociedad. Sin embargo, las diferencias en los resultados en función del GCM utilizado suponen un reto al utilizar esta información. El proyecto de intercomparación de modelos acoplados (Coupled Model Intercomparison Project, CMIP) se inició en 1995 y desde entonces ha proporcionado a la comunidad científica la oportunidad de estudiar y comparar los resultados de los GCMs. Los resultados de los GCMs se enfrentan a incertidumbres muy grandes pero, a pesar de ello, sus resultados han sido esenciales en los dos

últimos informes del IPCC. Las dos últimas fases del CMIP han sido el CMIP3 (Meehl et al. 2007) y el CMIP5 (Taylor et al. 2012). En el CMIP3 se estudiaron los escenarios de cambio climático del informe especial de escenarios de emisiones (Special Report on Emission Scenarios, SRES, Nakicenovic and Swart 2000) utilizados en el cuarto informe del IPCC (Fourth Assessment report, AR4). Para el SRES se desarrollaron 40 futuros plausibles basados en varias asunciones sobre cambio demográfico, desarrollo económico y cambio tecnológico. Estos escenarios se agruparon en cuatro familias (A1, A2, B1 y B2) que exploran vías de desarrollo alternativas incorporando toda una serie de fuerzas originantes demográficas, económicas y tecnológicas, junto con las emisiones de gases de efecto invernadero resultantes. En el CMIP5 se estudiaron los caminos de concentración representativa (Representative Concentration Pathways, RCPs, Moss et al. 2010) que se utilizan en el quinto informe del IPCC (Fifth Assessment Report, AR5). Los RCPs incluyen el RCP2.6, el RCP 4.5, el RCP 6.0 y el RCP 8.5 que representan, respectivamente niveles bajos, intermedios, altos y muy altos de emisiones. Los RCPs presentan como principales novedades una información más detallada y la exploración explícita de políticas de mitigación. La figura 0.1 muestra la comparación entre SRES y RCPs a lo largo del siglo 21 en función de la evolución del forzamiento radiativo.

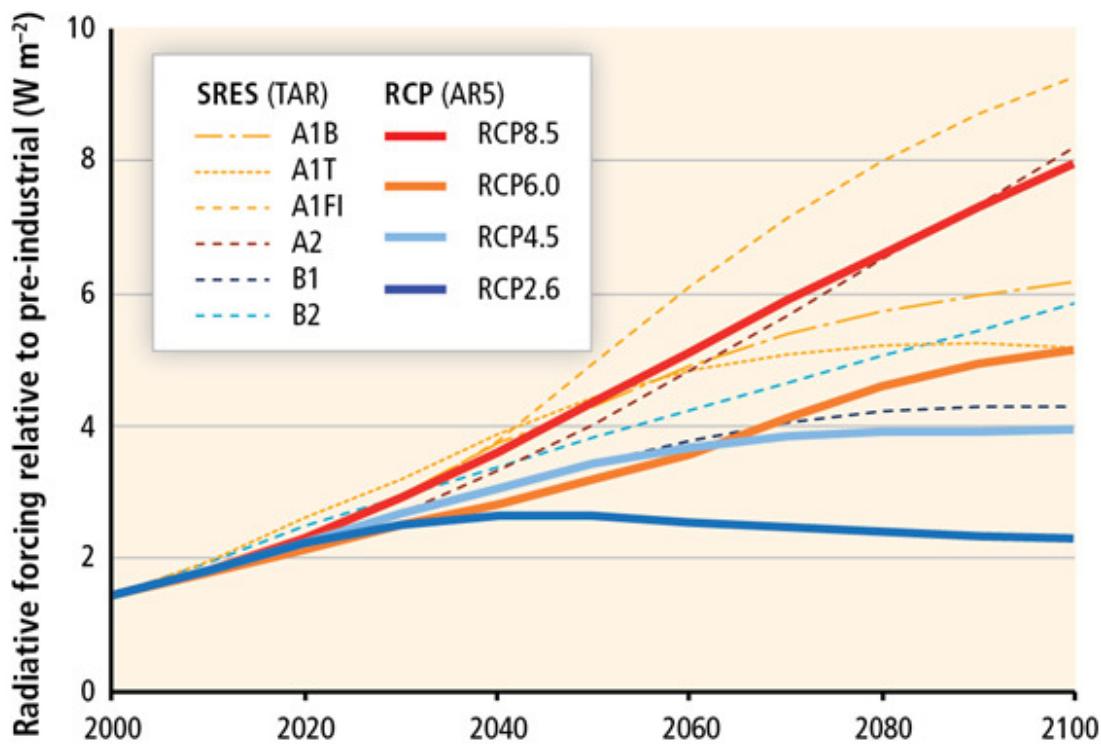


Figura 0.1: Forzamiento radiativo en W m^{-2} proyectado a lo largo del siglo 21 a partir de escenarios SRES y RCPs (Fuente: Figura 1-4 del AR5 WGII)

0.1.2.2. Datos de oleaje globales

Los reanálisis y GCMs proporcionan información de un gran número de variables. Algunas de estas variables (e.g. temperatura y humedad) son esenciales para estudiar el sistema climático y su variabilidad. Otras variables, además, son los forzamientos más importantes para ejecutar un modelo de oleaje (i.e. viento superficial, cobertura de hielo y corrientes). Sin embargo, los reanálisis y los GCMs presentan limitaciones para el estudio específico del clima marítimo. Los GCMs no proporcionan ningún parámetro del oleaje y los reanálisis se limitan a los parámetros más básicos. Para estudiar la climatología del oleaje suele ser necesario recurrir a reconstrucciones numéricas. Existen numerosas reconstrucciones de oleaje globales realizadas con modelos numéricos como WAVEWATCH III (Tolman and Chalikov 1996). Por ejemplo, Reguero et al. (2012) desarrollaron una reconstrucción del oleaje de 1948 a la actualidad calibrada con datos de satélite y Raschke and Arduin (2013) reconstruyeron los años 1994 a 2012 utilizando parametrizaciones basadas en Arduin et al. (2010).

Los cambios en el oleaje pueden generar impactos severos en las zonas costeras, sin embargo, se ha dedicado mucha menos atención a los cambios en el oleaje que a los cambios en el nivel medio del mar, especialmente en cuanto a proyecciones climáticas. Los pocos estudios de oleaje globales existentes (e.g. Mori et al. 2010, Semedo et al. 2013, Wang et al. 2014) han usado distintas técnicas y bases de datos. COWCLIP (Coordinated Ocean Wave Climate Project) es un proyecto que trata de coordinar las proyecciones de oleaje para poder estudiar sus incertidumbres. Los principales objetivos de COWCLIP son tres: 1) apoyar la intercomparación, validación y acceso a los datos de proyecciones de oleaje basadas en CMIP5; 2) definir una guía de buenas prácticas para desarrollar proyecciones de oleaje regionales; y 3) involucrar a la comunidad de oleaje en la comunidad climática. Un hito en la historia de COWCLIP ha sido la generación del primer ensemble multi-modelo basado en estudios de la comunidad (Hemer et al. 2013a). Este estudio combina los resultados de cinco estudios previos (cuatro dinámicos y uno estadístico) para obtener una estimación de las incertidumbres en las proyecciones de oleaje. Este ensemble se basa en un conjunto de simulaciones de GCMs más grande que el de cualquier estudio previo, sin embargo, estas simulaciones suponen sólo una pequeña parte de las simulaciones disponibles en CMIP5.

0.1.2.3. Regionalización (Downscaling)

Las bases de datos globales proporcionan información de gran calidad pero tienen una resolución espacial demasiado baja para estudios regionales o locales. Es habitual que los requerimientos de estudios locales requieran generar reconstrucciones regionales *ad*

hoc con mayor resolución. Cuando se necesita mayor resolución espacial hay que recurrir a técnicas de regionalización o “downscaling”. El downscaling se refiere a técnicas que derivan información de pequeña escala (en un emplazamiento o una región) a partir de datos a una escala espacial mayor. Existen dos alternativas principales: métodos estadísticos y métodos dinámicos. En el caso del oleaje, el downscaling dinámico se basa en anidar mallas de resolución creciente en un modelo numérico. Las mallas de mayor resolución requieren, a su vez, que la resolución de los forzamientos sea también más alta. Es decir, es necesario utilizar downscalings de reanálisis o GCMs. En el caso de los GCMs la comunidad científica ha desarrollado modelos climáticos regionales (Regional Climate Models, RCMs) que utilizan datos de GCMs como condiciones de contorno. El problema es que solo hay simulaciones de RCMs para algunos GCMs y únicamente en algunas regiones debido al enorme esfuerzo computacional que requieren. En el caso de los reanálisis es común utilizar modelos de área limitada (Limited Area Models, LAM) como el WRF (Skamarock et al. 2008) para generar reconstrucciones regionales (e.g. Menendez et al. 2014). En resumen, los downscaling dinámicos de oleaje (e.g. Charles et al. 2012) requieren un gran esfuerzo computacional. Los downscaling estadísticos (e.g. Casas-Prat et al. 2014; Izaguirre et al. 2012; Wang et al. 2004), se basan en relaciones estadísticas entre un predictor y un predictando. Son menos costosos computacionalmente pero necesitan ser alimentados de datos ya generados para definir la relación estadística entre el predictor (la situación atmosférica) y el predictando (las condiciones de oleaje). Además, varias decisiones en la definición del predictando son subjetivas. Esto hace que habitualmente los resultados obtenidos a partir de downscaling estadístico se vean con mayor escepticismo que los generados a partir de downscaling dinámico. Por ello, es necesario reducir la subjetividad y presentar validaciones robustas para evitar esta problemática.

0.1.3. Objetivos

A partir del análisis del estado del arte se observa que:

- Los reanálisis proporcionan datos atmosféricos históricos de gran calidad. Hay varios reanálisis disponibles con distintas características pero, en general, todos proporcionan una reconstrucción precisa del clima pasado.
- Los GCMs proporcionan proyecciones ante escenarios de cambio climático pero no proporcionan información sobre el oleaje. Además, las incertidumbres son grandes ya que se observan discrepancias importantes en los resultados de distintos GCMs.

- Existen reconstrucciones históricas de oleaje modeladas numéricamente a partir de datos de reanálisis. Estas reconstrucciones son capaces de representar el oleaje histórico con gran precisión.
- Hay muy pocos estudios de proyecciones de oleaje y se basan en un pequeño número de GCMs. La incertidumbre en las proyecciones de oleaje prácticamente no ha sido estudiada.
- La resolución de las bases de datos globales suele ser demasiado baja para analizar impactos costeros, y los estudios regionales a más alta resolución son escasos. En los downscalings dinámicos el coste computacional es muy alto, y en los downscalings estadísticos definir la relación predictor predictando es un proceso complejo.

En función de estos puntos, los objetivos de esta tesis se centran en técnicas para obtener oleaje con alta resolución espacial; y en proyecciones de oleaje ante escenarios de cambio climático para estudiar el oleaje futuro. Estos propósitos se concretan en cuatro objetivos principales e interdependientes:

Objetivo 1: Desarrollar un método que permita estudiar la influencia del oleaje global en el oleaje local. Este método debe ser capaz caracterizar de forma objetiva el área de influencia para cualquier localización. En especial, debe identificar las áreas donde se genera/disipa la energía que llega a un punto objetivo y los tiempos de propagación de esa energía.

Objetivo 2: Desarrollar un método de downscaling estadístico capaz de reproducir el oleaje local a partir de las situaciones sinópticas en su área de influencia. Este método ha de tener un bajo coste computacional para permitir evaluaciones multi-modo y ser capaz de reproducir el oleaje multivariado de forma realista.

Objetivo 3: Analizar la climatología simulada por GCMs, estudiando tanto su habilidad para reproducir la climatología del pasado como la consistencia de sus proyecciones futuras. El análisis ha de establecer en un conjunto de indicadores para determinar qué modelos proporcionan, *a priori*, simulaciones más creíbles.

Objetivo 4: Definir una metodología para realizar proyecciones de oleaje regionales multi-modo. Se ha de definir un método objetivo para seleccionar el ensemble y mostrar la aplicación práctica para varios escenarios de cambio climático. Se busca mejorar la comprensión del clima y proporcionar estimaciones del cambio climático futuro que puedan ser útiles para aquellos que estudian sus posibles consecuencias.

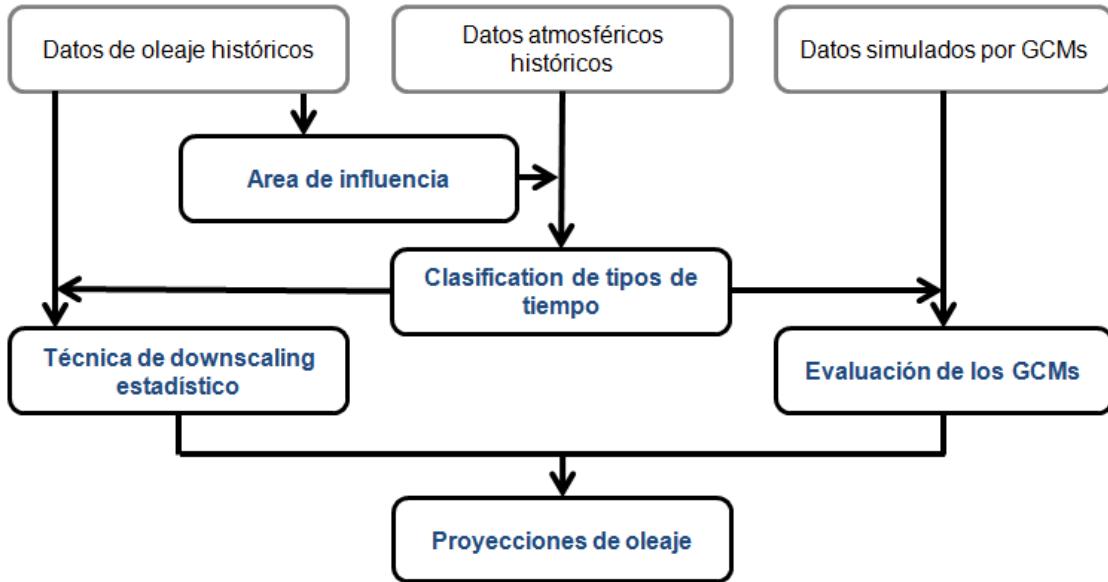


Figura 0.2: Marco metodológico de la tesis

0.1.4. Marco metodológico

La figura 0.2 sintetiza las relaciones entre las metodologías presentadas en esta tesis. Se utilizan tres fuentes de datos: datos de oleaje históricos, datos atmosféricos históricos y datos atmosféricos simulados por GCMs. En primer lugar se estudia el área de influencia del oleaje local (capítulo 2). Después se genera una clasificación de tipos de tiempo a partir de los datos atmosféricos en la región de interés. Esta clasificación se utiliza para dos fines: 1) cada tipo de tiempo se vincula con las condiciones de oleaje históricas de una reconstrucción numérica para obtener la relación estadística empírica entre circulación atmosférica y oleaje; 2) se vuelcan los datos de GCMs en la clasificación y se evalúan las frecuencias de presentación para comprobar qué GCMs son más fiables. Finalmente, se aplica la relación estadística entre situaciones atmosféricas y oleaje a un ensemble de GCMs para generar proyecciones de oleaje.

Delimitar correctamente el área de influencia del oleaje local, i.e. la extensión del área en que las condiciones atmosféricas tienen un efecto significativo en el oleaje local, es esencial para estudios de downscaling. En los downscalings dinámicos es importante para ajustar el tamaño de las mallas de detalle y en los downscalings estadísticos es importante para definir el área del predictor. En zonas ampliamente estudiadas como Europa y América del Norte el área de influencia puede ser definida por un experto a partir de estudios climáticos previos. Sin embargo, en zonas menos estudiadas, como África o América del Sur, es necesario realizar numerosas pruebas para llegar a una solución aceptable. En esta tesis desarrollamos una metodología llamada ESTELA para simplificar el proceso de definir el área de influencia. La metodología ESTELA permite definir las áreas de generación/dispersión y los tiempos de propagación de la energía del

oleaje que llega a cualquier punto en el globo. Además, ESTELA permite estudiar cómo varían estas zonas en diferentes escalas temporales (e.g. estacionalmente y largo plazo). Esta información ayuda a definir un área de influencia en base a criterios objetivos y reduce considerablemente el tiempo necesario para ello.

Un downscaling estadístico no se limita a conocer el área de influencia; definir las variables a utilizar como predictor y predictando es también un aspecto clave. La mayoría de trabajos de downscaling estadístico orientados al oleaje se basan en modelos de regresión entre la presión a nivel del mar (Sea Level Pressure, SLP) y la altura de ola significante. Se utiliza la SLP como predictor ya que es una variable razonablemente bien simulada por los modelos y tiene una relación muy fuerte con el oleaje. Hay otros métodos de downscaling estadístico como los basados en tipos de tiempo y los generadores estocásticos (Giorgi et al. 2001). En esta tesis se desarrolla un modelo de downscaling estadístico basado en una clasificación de tipos de tiempo. Este enfoque es directamente aplicable al oleaje multivariado ya que cada tipo de tiempo se puede asociar a varios predictandos. Esto permite analizar otros parámetros aparte de la altura de ola, como el periodo de pico o la dirección que también son importantes para estudiar el clima marítimo. Además, es posible analizar los cambios atmosféricos y en el oleaje de forma conjunta.

Una clasificación de tipos de tiempo es especialmente adecuada para estudiar cambios en la climatología a largo plazo. El estudio de las proyecciones de los GCMs permite identificar el tipo de situaciones sinópticas que van a cambiar en el futuro. Además, si la clasificación se genera en base a un buen predictor del oleaje, permite asociar esos cambios a cambios en el oleaje. El mayor problema es la incertidumbre en los resultados de los GCMs. Esta incertidumbre está parcialmente justificada porque los inevitables pequeños errores en las condiciones iniciales de una simulación climática provocan grandes errores en la distribución temporal de las situaciones sinópticas. Es decir, eventos climáticos como el Niño no van a coincidir temporalmente para distintos GCMs pero las frecuencias de ocurrencia de estos eventos sí deben coincidir. Por ello, para decidir qué GCMs son más apropiados para un downscaling estadístico, no se pueden comparar directamente las series históricas pero sí las frecuencias de los tipos de tiempo. En el pasado se pueden estudiar las condiciones climáticas que resultan de los GCMs comparándolas con datos de reanálisis y en el futuro se pueden analizar sus resultados comparándolos entre sí. Comparar las simulaciones históricas de los GCMs con reanálisis sirve para comprobar su capacidad para representar la climatología histórica y su variabilidad. Comparar las proyecciones futuras entre sí sirve para comprobar qué modelos predicen cambios futuros inconsistentes con el resto. En esta tesis se han desarrollado un conjunto de índices para estudiar los GCMs en base a tres aspectos: la climatología del pasado, la variabilidad climática y la consistencia de las proyecciones futuras. Estos índices han sido aplicados a las simulaciones de SLP de los GCMs del CMIP3 y del

CMIP5. Los resultados sirven para tener una medida de la incertidumbre de los GCMs e identificar qué situaciones sinópticas no son bien simuladas por los modelos.

Una forma de profundizar en el estudio de las proyecciones de cambio climático es utilizar un ensemble de GCMs seleccionados en base a algún criterio objetivo. Por ejemplo, utilizar sólo los “mejores” GCMs para evitar que los resultados estén condicionados por modelos *a priori* menos fiables, o utilizar todos los GCMs. En ambos casos se debe evaluar la variabilidad inter-modelo que resulte del conjunto de GCMs utilizado. En esta tesis se ha tratado de desarrollar proyecciones de oleaje regionales teniendo en cuenta los factores expuestos. Para ello, se han combinado la técnica de downscaling estadístico y el análisis de los GCMs. La técnica de downscaling estadístico permite utilizar un ensemble muy grande y el análisis de los GCMs evita elegir los GCMs “a ciegas”. En esta tesis, esta metodología ha sido aplicada en Europa para obtener proyecciones regionales de oleaje multi-modelo.

0.1.5. Organización de la tesis

Esta tesis está formada por 6 capítulos. Los cuatro capítulos centrales corresponden cada uno a un artículo publicado (o aceptado) en revistas del primer cuartil en ciencias atmosféricas y/o oceanográficas. El doctorando es el autor principal en tres de los cuatro artículos y coautor en uno de ellos. Los artículos mantienen su contenido original pero su formato ha sido adaptado al de esta tesis.

El capítulo 0.1 “Introducción” presenta los objetivos de la tesis y enlaza los artículos que componen la tesis. El capítulo 0.2 “ESTELA: un método para evaluar el origen y el tiempo de propagación de la energía del oleaje” estudia la propagación del oleaje y el desarrollo de una herramienta para comprender el origen de la energía del oleaje local y sus tiempos de propagación. El capítulo 0.3 “Metodología de regionalización a partir de tipos de tiempo para clima marítimo” desarrolla un método estadístico basado en una clasificación de tipos de tiempo para obtener oleaje a partir de patrones atmosféricos. El capítulo 0.4 “Evaluando la habilidad de los modelos climáticos globales de CMIP3 y CMIP5 en el Atlántico Noreste” analiza la habilidad de los modelos climáticos globales (GCMs, por sus siglas en inglés) para representar la climatología a escala regional mediante tipos de tiempo. El capítulo 0.5 “Proyecciones estadísticas multi-modelo del oleaje en Europa” combina las metodologías anteriores para obtener proyecciones de clima marítimo regionales ante escenarios de cambio climático. Por último, el capítulo 0.6 “conclusiones y futuras líneas de investigación” revisa los principales resultados de la tesis y sugiere aspectos prioritarios para desarrollar en el futuro.

0.2. ESTELA: un método para evaluar el origen y el tiempo de propagación de la energía del oleaje

Este apartado constituye un resumen del artículo Perez et al. (2014a): Perez, J., Menendez, F. J., Menendez, M., Losada, I. J. (2014). ESTELA: a method for evaluating the source and travel time of the wave energy reaching a local area. Ocean Dynamics, 64(8), 1181–1191. <http://doi.org/10.1007/s10236-014-0740-7>

0.2.1. Introducción

Las características del oleaje a escala local están dominadas por olas generadas localmente (mar de viento) y olas de tormentas distantes (swell). Por ello, la necesidad de datos de oleaje precisos ha fomentado estudios sobre la generación y la propagación del oleaje. Los estudios realizados por Barber and Ursell (1948), Munk (1947), Munk et al. (1963), y Snodgrass et al. (1966) contribuyeron de manera significativa a la base científica y presentaron algunos de los paradigmas aceptados en la actualidad, por ejemplo, propagación siguiendo círculos máximos y pequeña disipación de los swells. Desafortunadamente, estos estudios estaban limitados por la disponibilidad de mediciones in situ, i.e., un pequeño número de estaciones concentradas en las zonas costeras y cubriendo un periodo de tiempo corto.

Estudios más recientes (e.g. Collard et al. 2009) aprovechan la cobertura global que ofrecen los datos de radar de apertura sintética (Synthetic Aperture Radar, SAR) pero se enfrentan a restricciones similares debido a la grosera resolución espacial y temporal de estos datos. A pesar de las limitaciones de los datos, los estudios sobre la variabilidad espacio-temporal del clima marítimo han dado lugar a grandes mejoras en la física de los modelos numéricos de oleaje. Las mejoras en las formulaciones y la disponibilidad de una mayor potencia de cálculo han resultado en bases de datos de oleaje históricas de alta calidad (e.g. Rascale et al. 2008; Reguero et al. 2012). Los datos homogéneos y continuos de estas reconstrucciones históricas permiten superar las limitaciones de los datos instrumentales siendo una herramienta útil para mejorar nuestra comprensión de la propagación del oleaje.

En este estudio, se propone una metodología basada en los datos de una reconstrucción numérica. La aplicación de nuestro método proporciona información de dónde se genera/disipa la energía, el tiempo que tarda en llegar, y la variabilidad temporal de la zona de influencia. Se prevé que esta información pueda ayudar al diseño de estudios de downscaling estadísticos o dinámicos. En ambos casos, la definición de la zona de interés es un problema que puede consumir mucho tiempo y es comúnmente resuelto por el

criterio (subjetivo) de un experto. Este estudio presenta una técnica rápida y objetiva para delimitar el área de generación del oleaje que induce el clima marítimo local.

0.2.2. Metodología

La metodología, que se denomina en lo sucesivo ESTELA (a method for Evaluating the Source and Travel-time of the wave Energy reaching a Local Area), tiene por objeto caracterizar el área de influencia de un punto de destino específico. El proceso implica cuatro pasos secuenciales: En primer lugar, se aplican criterios geográficos para limitar el estudio en el dominio espacial relevante. En segundo lugar, la reconstrucción espectral proporciona información de frecuencia-dirección. En tercer lugar, la evaluación de la energía del oleaje revela características importantes de la energía del oleaje que llega al punto de destino. Finalmente, se obtienen las áreas de ganancia/pérdida de energía.

Este método requiere datos de oleaje homogéneos. En este estudio, se ha utilizado una base de datos global de parámetros de oleaje (Rascl and Arduin 2013; Rascl et al. 2008). Esta base de datos fue obtenida mediante el modelo numérico de oleaje WAVEWATCH III en su versión 4.04 forzada por los vientos de CFSR (Climate Forecast System Reanalysis, Saha et al. 2010). El modelo utiliza una parametrización llamada TEST451 (Arduin et al. 2010), con mejoras significativas en la disipación del oleaje. El espectro de oleaje del modelo se discretiza en 24 direcciones y 31 frecuencias y los resultados se proporcionan con resolución temporal 3-horaria en una malla de 0.5° de resolución espacial. Esta reconstrucción proporciona parámetros como altura de ola significante, periodo de pico, dirección media y dispersión direccional para un máximo de seis particiones del espectro: el mar de viento y cinco swells en el caso más general. En este estudio, utilizamos 20 años, de 1993 a 2012, de espectros de oleaje reconstruidos a partir de estas particiones.

0.2.2.1. Criterios geográficos

Los criterios geográficos se aplican para limitar el área de estudio despreciando los sistemas de oleaje separados del punto objetivo por una masa de tierra. Estos criterios se basan en la suposición de que las olas en aguas profundas viajan a lo largo de círculos máximos, lo que reduce el esfuerzo computacional en los siguientes pasos de la metodología. Sin embargo, este supuesto tiene varias limitaciones debido a la interacción dinámica de las olas con su entorno. Por ejemplo, las interacciones ola-corriente no siempre son insignificantes en aguas profundas, y procesos como la refracción y la difracción pueden ser importantes en aguas poco profundas. A fin de tener en cuenta estas limitaciones, sólo despreciamos un punto de origen cuando el área representada por ese punto

está claramente bloqueada por tierra, es decir, hay una masa de tierra que bloquea todas las direcciones en un sector direccional $\alpha \pm \Delta$, donde α es la dirección del círculo máximo entre un punto de origen y el punto de destino y Δ determina la anchura del sector direccional. Usamos:

$$\Delta = \max \left(5, \arctan \left(\frac{dx/2 + dy/2}{r} \right) \right), \quad (0.1)$$

donde el Δ mínimo es 5° , dx y dy son la resolución espacial de la base de datos de oleaje, y r es la distancia entre un punto de origen y el punto de destino. La figura 0.3 muestra el área válida para un punto de destino en el Atlántico Noreste. El área seleccionada abarca toda la cuenca del Atlántico Norte y una sección del Atlántico Sur, mientras que el Mar del Norte y el Mar Caribe no están incluidos.

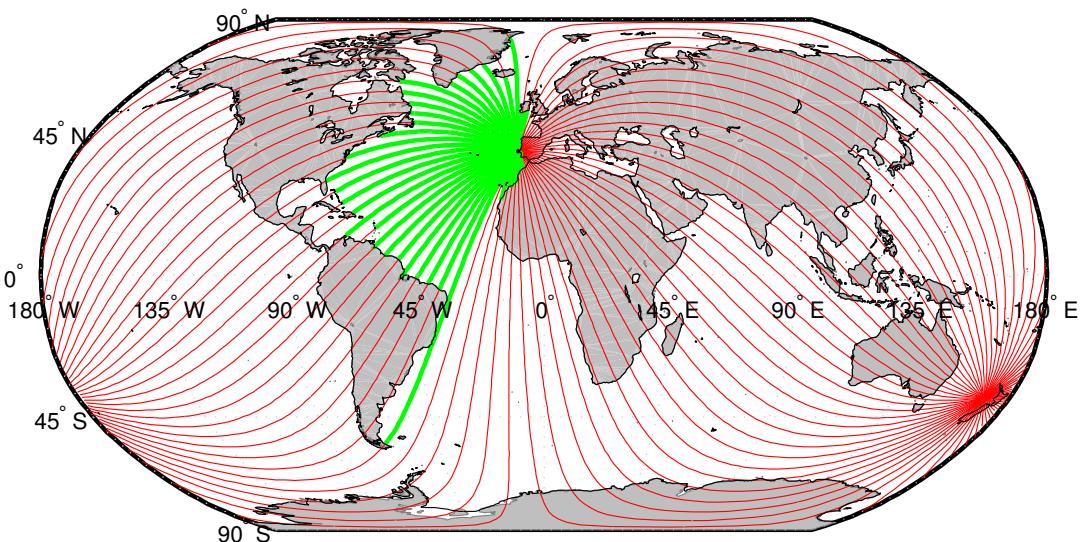


Figura 0.3: Criterios geográficos para un punto objetivo P [10°W, 39°N] en el Atlántico Noreste. El área geográfica seleccionada se representa en verde y el área que se desprecia se representa en rojo

0.2.2.2. Reconstrucción espectral

La práctica común para describir un estado de mar es utilizar un conjunto reducido de estadísticos tales como la altura de ola y la dirección media. Estos estadísticos, sin embargo, no representan completamente la complejidad del clima marítimo. En algunas regiones los estados de mar son el resultado de varios trenes de ondas que viajan en diferentes direcciones. El espectro de oleaje bidimensional caracteriza la distribución de la energía del oleaje entre las diferentes frecuencias y direcciones y se considera una descripción completa de las olas (promediadas en fase) en la superficie del océano.

El concepto de partición espectral introducido por Gerling (1992) permite la identificación de sub-picós dentro del espectro de oleaje bidimensional. El cálculo de los estadísticos de estos segmentos conserva información direccional y representa una considerable reducción de datos. Por consiguiente, estos parámetros se han convertido en un resultado habitual de los modelos de oleaje. El esquema de particiones en WAVEWATCH III se basa en el método de Hanson and Phillips (2001), implementado como se describe en Tracy et al. (2007).

Con el fin de reconstruir el completo espectro de frecuencias dirección, utilizamos cuatro parámetros por cada partición. Esos parámetros son altura de ola significante (H_s), periodo de pico (T_p), dirección media (θ) y dispersión direccional (σ). Cualquier partición puede ser vista como un espectro unimodal definido por estos parámetros, y el espectro multimodal puede obtenerse mediante la agregación de estos espectros unimodales. Reconstruimos el espectro de frecuencias dirección siguiendo:

$$E(f, \theta) = \sum_{i=0}^5 \rho g S_i(f) D_i(\theta), \quad (0.2)$$

donde ρ es la densidad del agua y g es la aceleración debida a la gravedad. $S_i(f)$ y $D_i(\theta)$ son el espectro de oleaje unidimensional y la distribución direccional para una partición i .

El espectro de oleaje unidimensional $S_i(f)$ se define como un espectro JONSWAP (JOint North SeaWAve Project, Hasselmann et al. 1973), donde la cantidad de energía está determinada por H_{s_i} y la distribución sobre las frecuencias depende de T_{p_i} . Se ha utilizado una forma del espectro JONSWAP con un parámetro de pico $\gamma = 3.3$, ya que no hay medidas de dispersión frecuencial en la base de datos utilizada. No obstante, las pruebas mostraron que esta suposición tiene un efecto despreciable en la evaluación de la energía del oleaje efectiva que alcanza un punto de destino. En cuanto a la distribución direccional $D(\theta)$ se asume una expresión de tipo coseno (e.g. Holthuijsen 2007; Mitsuyasu et al. 1975):

$$D(\theta) = A_2 \cos^{2s} \left(\frac{\theta - \alpha}{2} \right) \quad \text{for } -180^\circ < \theta - \alpha < 180^\circ, \quad (0.3)$$

donde θ es la dirección media y α es la dirección entre el punto de origen y el punto de destino. A_2 y s son dos parámetros que controlan la anchura de la distribución y dependen del parámetro de dispersión direccional:

$$s = \frac{2}{\sigma^2} - 1, \quad (0.4)$$

$$A_2 = \Gamma(s+1) \left/ \left[\Gamma\left(s + \frac{1}{2}\right) 2\sqrt{\pi} \right] \right. . \quad (0.5)$$

Se realizó un análisis simple para evaluar la reconstrucción espectral comparando los espectros reconstruidos con los espectros originales del modelo numérico. La evaluación en diferentes lugares y periodos mostró resultados consistentes. Los espectros reconstruidos capturan correctamente la distribución direccional. La distribución de frecuencias también está razonablemente bien representada, aunque se encuentran algunas discrepancias para las frecuencias más altas. Esto era esperable ya que se utilizan dos parámetros (θ y σ) para representar la distribución direccional y un solo parámetro (Tp) para representar la distribución frecuencial.

0.2.2.3. Evaluación del flujo de energía efectiva

La evaluación del flujo de energía efectiva se basa en las características del espectro y la ubicación del punto de origen y el punto de destino. Aquí, el flujo de energía efectiva se define como la energía del espectro que viaja hacia el punto de destino, y se estima para obtener mapas de energía efectiva.

La figura 0.4 muestra, en un tiempo t , la parte del espectro que contribuye a la energía efectiva (derecha) para un círculo máximo en particular (izquierda). La posición del punto de origen con respecto al punto de destino se define por la distancia r y el ángulo α . La densidad espectral radiada hacia el punto de destino se determina por $E(f; r, \alpha, t)$, i.e., la sección transversal del espectro $E(f, \theta; r, \alpha, t)$ en la dirección α . A fin de no sobrestimar la importancia de la energía desde los puntos de origen lejanos, se puede considerar una tasa de decaimiento espacial μ . Un límite inferior teórico para μ viene dado por la teoría viscosa, dando, en aguas profundas (Ardhuin et al. 2009; Collard et al. 2009; Dore 1978)

$$\mu = 2 \frac{\rho_a}{\rho_w g c_g} \left(\frac{2\pi}{T} \right)^{\frac{5}{2}} \sqrt{2\nu_a}, \quad (0.6)$$

donde $\rho_a/\rho_w = 0.0013$ es la relación entre la densidad del aire y la densidad del agua, $c_g = \frac{gT}{4\pi}$ es la velocidad de grupo y ν_a es la viscosidad del aire (para una superficie limpia $\nu_a = 1.4 \cdot 10^{-5} \text{ m}^2\text{s}^{-1}$).

La disipación viscosa es responsable de una considerable pérdida de energía de las frecuencias más altas. Sin embargo, la disipación de frecuencias más bajas está dominada por otros procesos. Sólo corregimos la disipación viscosa, porque puede ser considerada independiente de las condiciones atmosféricas y oceánicas durante la propagación. Por

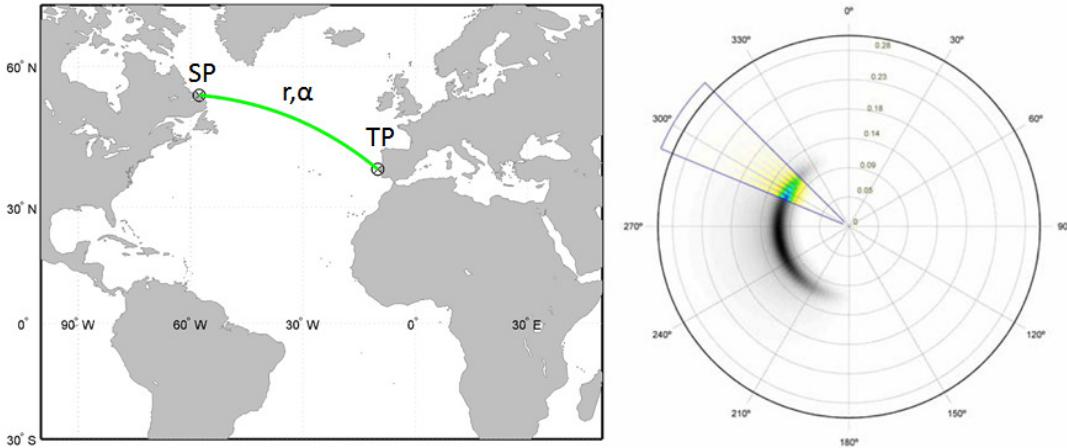


Figura 0.4: *Izquierda* Un ejemplo del círculo máximo entre un punto de origen en Canadá y un punto de destino cerca de Portugal. *Derecha* Espectro de energía del oleaje en el punto de origen. Se muestra coloreada la sección transversal seleccionada, que representa la energía de las olas que se propagan a lo largo del círculo máximo entre TP y SP

otra parte, conocer las regiones donde la pérdida de energía no puede ser explicada por la disipación viscosa es tan interesante como conocer las regiones donde se genera la energía.

El flujo de efectivo de la energía (F) y el tiempo de viaje (τ) en cualquier momento (t) y la posición (r, α) son entonces:

$$F_{(r,\alpha,t)} = \int_0^\infty E_{(f;r,\alpha,t)} e^{-\mu r} c_g df, \quad (0.7)$$

$$\tau_{(r,\alpha,t)} = r \frac{\int_0^\infty E_{(f;r,\alpha,t)} e^{-\mu r} df}{F_{(r,\alpha,t)}}. \quad (0.8)$$

El flujo de energía eficaz y el tiempo de viaje para una serie de N estados de la mar se pueden obtener fácilmente. El flujo de energía efectiva es la suma de los flujos de energía válidos dividido por el número de estados de mar y el tiempo de viaje se obtiene a partir de la media ponderada de la celeridad grupo:

$$\overline{F_{(r,\alpha)}} = \frac{\sum_{i=1}^N F_{(r,\alpha,t_i)}}{N}, \quad (0.9)$$

$$\overline{\tau_{(r,\alpha)}} = r \frac{\sum_{i=1}^N F_{(r,\alpha,t_i)} \frac{\tau_{(r,\alpha,t_i)}}{r}}{\sum_{i=1}^N F_{(r,\alpha,t_i)}}, \quad (0.10)$$

0.2.2.4. Ganancia/Pérdida de energía

El flujo de energía efectiva sirve para caracterizar la propagación del oleaje. Con el fin de analizar la generación y disipación del oleaje, esta información debe ser puesta en una malla polar con centro en el punto de destino. En una malla polar, la ganancia/pérdida de energía en cada celda (ΔF) puede verse como la diferencia entre el flujo entrante y el flujo saliente en la dirección del círculo máximo. Este punto de vista lagrangiano, similar a los modelos de oleaje primera generación, se muestra en la figura 0.5. Hay que tener en cuenta que este enfoque agrega el efecto de la generación y disipación del oleaje con el efecto de olas que cruzan el círculo máximo.

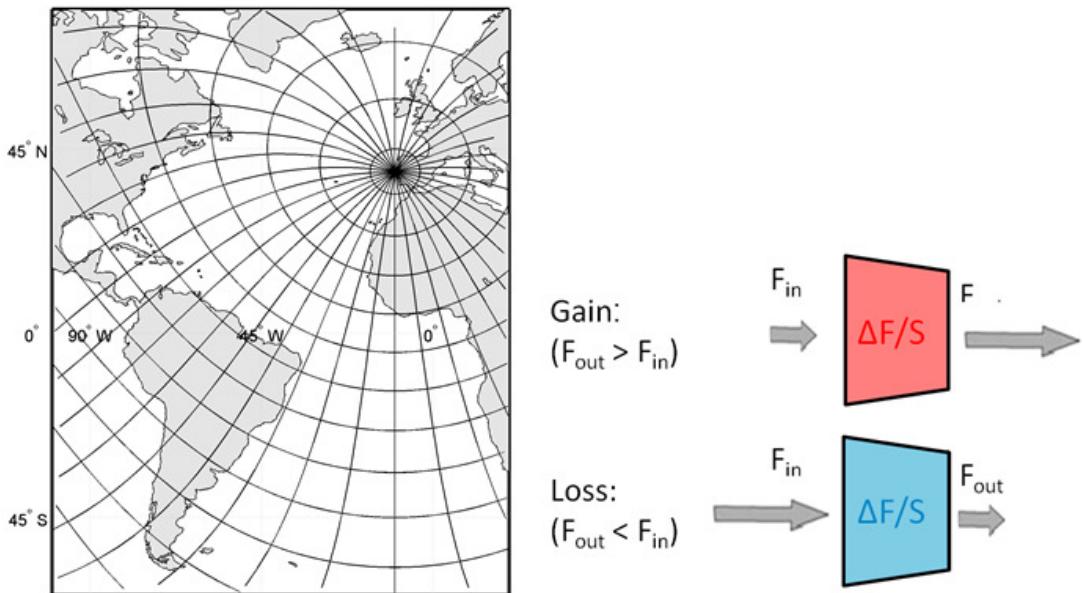


Figura 0.5: Izquierda Malla polar de baja resolución centrada en un punto de destino P [10°W, 39°N] en el Océano Atlántico Nordeste. Derecha diagrama de ganancia/pérdida de energía

Con el fin de reducir la influencia de la discretización, $\overline{\Delta F_{(r,\alpha)}} = \overline{\Delta F_{(r_{out},\alpha)}} - \overline{\Delta F_{(r_{in},\alpha)}}$ se divide por la superficie de la celda. Esta superficie es la intersección entre una cuña esférica y un segmento esférico

$$S = S_{total} \frac{S_{wedge}}{S_{total}} \frac{S_{segment}}{S_{total}} = 4\pi R^2 \frac{\lambda}{2\pi} \frac{|\cos(\frac{r_{in}}{R}) - \cos(\frac{r_{out}}{R})|}{2}, \quad (0.11)$$

donde R es el radio de la Tierra, λ es el ángulo de la cuña y r_{in} y r_{out} son las distancias entre el punto de destino y los lados de la célula. Los valores $\overline{\Delta F_{(r,\alpha)}}$ se muestran en los mapas ESTELA de ganancia/pérdida.

0.2.3. Resultados

Con el fin de demostrar la idoneidad del método ESTELA en cualquier lugar, se seleccionan cuatro puntos de destino: (i) el sitio A [131°W, 46°N] cerca del estado de Oregón (EE.UU.), en el Pacífico nororiental; (ii) el sitio B [80°W, 8°S] cerca de la costa peruana, en el Pacífico Central-Este; (iii) el sitio C [10°W, 44°N] cerca de la costa noroccidental española, en el Atlántico nororiental; y (iv) el sitio D [55.5°E, 5.5°S] cerca de las Islas Seychelles, en el Océano Índico.

El sitio A se ve afectado por la actividad de los ciclones extra-tropicales del Pacífico Norte. Algunos autores han explicado un aumento de la energía de las olas debido a la intensificación de la borrasca de las Aleutianas y una fuerte variabilidad interanual del oleaje relacionada con el índice teleconectivo PNA (Bromirski 2005; Graham and Diaz 2001). El sitio B se encuentra en una región tropical, afectada por los vientos alisios y por swells de grandes períodos que atraviesan todo el Océano Pacífico (Young 1999). El sitio C es un lugar abierto expuesto a las tormentas extratropicales del Atlántico Norte. Algunos autores (e.g. Izaguirre et al. 2010; Woolf 2002) han encontrado que una gran fracción de la energía de las olas a lo largo de la costa Atlántica europea se puede asociar a la oscilación del Atlántico Norte (NAO). El clima del oleaje en el sitio D está claramente afectado por la actividad de ciclones tropicales en el Océano Índico y la penetración de olas del Océano Austral ha sido identificada previamente (Alves 2006; Young 1999).

La figura 0.6 muestra el flujo de energía efectiva y los tiempos de viaje medios de 1993 a 2012 en el sitio A. El área coloreada muestra el flujo de energía efectiva (kW/m/grado). Las líneas rojas muestran los círculos máximos de 16 sectores direccionales y las líneas negras representan el tiempo de viaje (τ) en días. Las zonas rojas y amarillas representan las regiones con mayor energía transmitida hacia el punto de destino, mientras que en las áreas de color azul oscuro la energía efectiva es insignificante. El mapa ESTELA revela dos regiones importantes: una región muy energética al oeste del punto de destino que cubre el Océano Pacífico Norte a partir de 30°N, y una región en el suroeste del Pacífico cerca de Australia y Nueva Zelanda. La segunda es el origen de swells que viajan durante 9-14 días desde el sur-suroeste para llegar al sitio A. Parte de la energía del oleaje de esta región es bloqueada por las islas de la Polinesia, a pesar de ello, es esperable que las olas que llegan al punto de destino desde esta región sean swells muy regulares.

La figura 0.7 muestra las áreas de generación (en rojo) y las áreas de disipación (en azul). En esta figura, la complejidad de la zona norte se hace más evidente. Hay olas de 3 días del noreste, olas de 6 días desde suroeste e importantes mares de viento locales. Por otra parte, la generación y disipación de los swells del sur es fácilmente identificable.

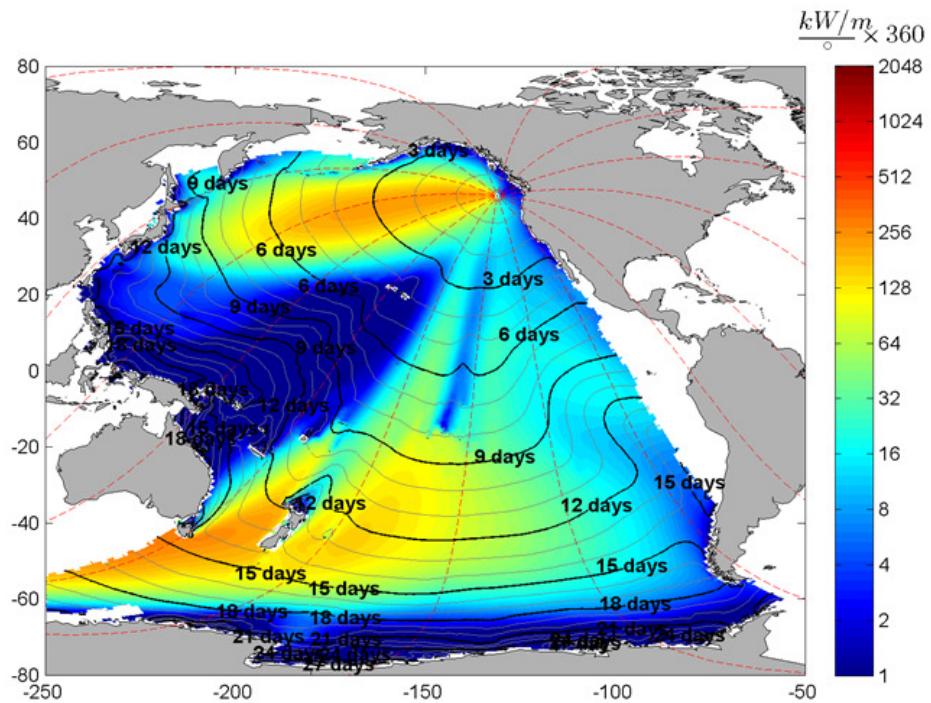


Figura 0.6: Flujo de energía eficaz medio en 1993-2012 para el sitio A. La zona coloreada se define por el conjunto de puntos de origen que satisfacen los criterios geográficos. El tiempo de viaje se representa por las líneas grises y negras

La atenuación del oleaje debido a las pequeñas islas de la Polinesia francesa demuestra la importancia de las obstrucciones para los modelos de oleaje espectrales como se indica en Tolman (2003) y Chawla and Tolman (2008).

El análisis de los mapas ESTELA para diferentes períodos de tiempo puede utilizarse para estudiar la variabilidad del oleaje local. El patrón espacial en los años 1996 y 1998 (no mostrado) es bastante similar al de la 0.6. La intensidad de F, sin embargo, es diferente entre los mapas, siendo 1996 un año de baja energía mientras que 1998 presenta los valores más grandes de los 20 años analizados. Los mapas ESTELA durante el invierno y el verano también son muy diferentes entre sí. En invierno, la zona norte es claramente dominante, mientras que la energía del hemisferio sur es casi insignificante en la proximidad del punto de destino. Por el contrario, en verano (invierno austral), la energía en el hemisferio norte disminuye mientras que la energía de los swells del hemisferio sur aumenta. Los mapas ESTELA revelan que la variabilidad interanual del clima marítimo en el sitio A no es tan grande como las variaciones estacionales.

En el sitio B (no mostrado) el mapa ESTELA resultante de los 20 años muestra un impresionante patrón espacial. Se identifican dos familias de áreas de generación de

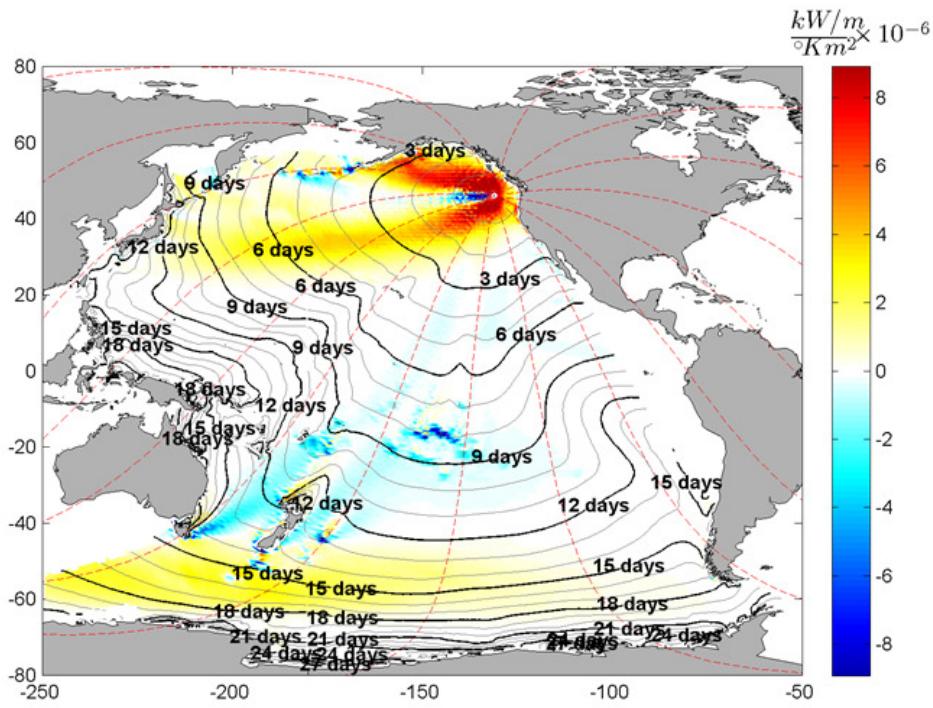


Figura 0.7: Áreas de ganancia/pérdida de energía en 1993-2012 para el sitio A

oleaje, una en cada hemisferio. Las dos áreas de influencia para el sitio B muestran tiempos de viaje de hasta 2 semanas. Es interesante hacer notar que los sitios A y B se ven afectados por olas de las mismas zonas extra-tropicales del Océano Pacífico. El efecto de estas olas es, sin embargo, claramente diferente. El sitio B está muy expuesto a los vientos del oeste del hemisferio sur, que generan olas del sur y suroeste en el sitio B. La energía de las olas en el hemisferio norte también es relevante pero se limita a un sector direccional estrecho entre la península de California y las Islas Galápagos. Los mapas ESTELA también muestran que swells con gran energía del hemisferio norte pueden alcanzar el sitio B o ser inexistentes dependiendo del mes del año.

La figura 0.8a muestra los mapas ESTELA del sitio C para valores positivos y negativos de la Oscilación del Atlántico Norte (NAO). La serie del índice NAO obtenida del Centro de Predicción del Clima se ha utilizado para analizar la influencia de este índice climático en el flujo de energía efectiva. Los resultados muestran que la fase positiva de la NAO (NAO+) se caracteriza por olas grandes y de periodos grandes, mientras que la fase negativa (NAO-) se caracteriza por olas más pequeñas y un cambio dirección de noroeste a oeste. Este resultado concuerda con Izquierdo et al. (2010), que encontró una gran influencia de la NAO en la altura de las olas extremas en el Atlántico nororiental, y puede estar relacionado con los vientos más fuertes y desplazados hacia el norte durante

NAO+ y los vientos más débiles y desplazados hacia el sur durante NAO- (Dupuis et al. 2006; Le Cozannet et al. 2011).

La figura 0.8b muestra los mapas de ESTELA para el sitio D durante el invierno (DEF) y el verano (JJA) boreales. Se pueden identificar tres familias de swells: oleaje muy energético del suroeste generado en una región de intensos vientos en el Océano Austral (más intenso durante el invierno austral); oleaje del este en la zona tropical del Océano Índico, una región con alta incidencia de ciclones tropicales, y oleaje del norte que solamente aparece durante los meses del invierno boreal. El mapa ESTELA revela que el oleaje del norte puede llegar a la región tropical del Océano Índico, en contraste con los resultados de Alves (2006).

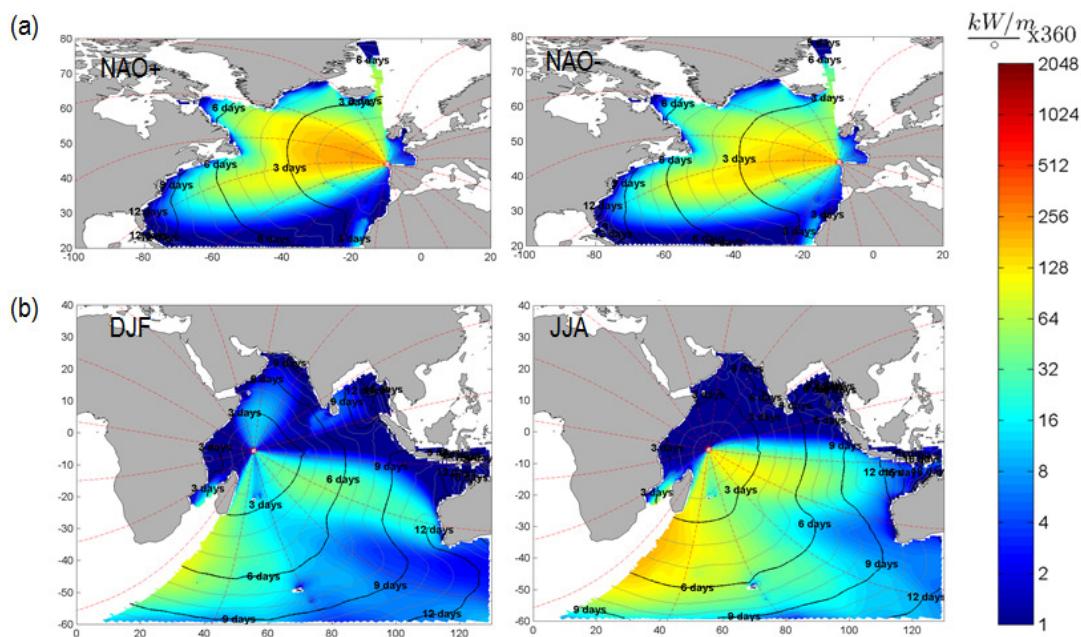


Figura 0.8: Los gráficos superiores muestran el flujo de energía media efectiva para el sitio C durante NAO + (izquierda) y NAO- (derecha). Los gráficos inferiores muestran el flujo de energía media efectiva para el sitio D durante el invierno (izquierda) y el verano (derecha)

0.3. Metodología de regionalización a partir de tipos de tiempo para clima marítimo

Este apartado constituye un resumen del artículo Camus et al. (2014b): Camus, P., Menendez, M., Mendez, F. J., Izaguirre, C., Espejo, A., Canovas, V., Perez, J., Rueda, A., Losada, I. J., Medina, R. (2014). A weather-type statistical downscaling framework for ocean wave climate. Journal of Geophysical Research: Oceans, 119(11), 7389–7405. <http://doi.org/10.1002/2014JC010141>

0.3.1. Introducción

Operaciones de transporte marítimo, logística de estructuras marinas, erosión costera, o riesgo de inundaciones son algunos ejemplos en los que conocer el comportamiento del oleaje multivariado es esencial. El oleaje se ha caracterizado tradicionalmente a partir de observaciones y resultados de modelos numéricos. Las observaciones son los datos más fiables; sin embargo, los registros son cortos y están muy dispersos espacialmente. Los resultados de modelos numéricos son computacionalmente costosos y requieren batimetrías y campos de viento de alta calidad. El downscaling estadístico (Statistical Downscaling, SD), basado en relaciones empíricas entre predictores atmosféricos de gran escala y un predictando local, es una buena alternativa cuando se dispone de datos atmosféricos. La principal ventaja del enfoque estadístico es que es computacionalmente poco costoso; por lo tanto, es adecuado para una caracterización rápida del predictando, para conseguir simulaciones a largo plazo, o para desarrollar múltiples realizaciones para diferentes condiciones de forzamiento (e.g. escenarios de cambio climático). Algunas hipótesis son inherentes al enfoque de “pronóstico perfecto” del SD: (i) la variabilidad de la variable local debe ser explicada por la conexión estadística, (ii) los cambios en el clima medio deberían encontrarse dentro del rango de su variabilidad natural, y (iii) las relaciones deben ser estacionarias. Las series de observaciones largas; la explicación física de la relación entre el predictor regional y el predictando local; y las simulaciones de modelos climáticos globales (GCMs) cumplen con estas condiciones (Wilby et al. 2004).

Se pueden aplicar diferentes enfoques para desarrollar un modelo SD. Giorgi et al. (2001) clasifica los métodos en: (i) funciones de transferencia, (ii) enfoques de tipo meteorológico, y (iii) generadores de tiempo estocástico. Otros aspectos relevantes de un método SD son la elección de las variables y el dominio espacial del predictor (Fowler et al. 2007). En el caso del oleaje, los campos de presión a nivel del mar (Sea Level Pressure, SLP) y los campos de gradientes de SLP al cuadrado han demostrado ser buenos predictores (Casas-Prat et al. 2014; Wang et al. 2012). Esto es especialmente relevante para las

aplicaciones de proyecciones climáticas, ya que se cree que en los GCMs la SLP presenta sesgos más pequeños que los campos de viento (Caires et al. 2006).

Las aplicaciones SD para analizar oleaje se limitan generalmente a proyecciones climáticas de altura de ola significante (H_s). Concretamente, la mayoría de los trabajos existentes se basan en modelos de regresión lineal multivariada entre el predictor SLP y la H_s a escala estacional u horaria (Casas-Prat et al. 2014; Wang et al. 2012; Wang and Swail 2006; Wang et al. 2004) o modelos de extremos, modelando la variabilidad interanual utilizando covariables definidas por los predictores de SLP (Caires et al. 2006; Izaguirre et al. 2010; Wang and Swail 2006; Wang et al. 2004). Sin embargo, H_s no es la única variable de interés para estudiar el oleaje. Se requieren otros parámetros de estado de mar (e.g. periodo de pico y dirección media) para analizar los efectos del cambio climático en las estructuras costeras (Suh et al. 2012) o energía de las olas (Hemer et al. 2010b). Además, la dirección es particularmente crítica para estimar, por ejemplo, la erosión costera.

En este trabajo, se presenta un marco SD basado en tipos de tiempo. Los modelos estadísticos encuentran difícil reproducir el oleaje en zonas dominadas por swells (Hemer et al. 2012). Para superar este problema, se incluye la historia reciente de las condiciones atmosféricas responsables de los swells en el área de estudio en la definición del predictor. Se establece una relación estadística entre los tipos de tiempo y la distribución de probabilidad completa del clima marítimo multivariado local. El modelo SD se aplica en dos lugares en el Océano Atlántico Norte, en las costas irlandesas y españolas. En estos lugares, se valida el modelo SD y se muestran algunas aplicaciones.

0.3.2. El método de downscaling estadístico

El diagrama de flujo que se muestra en la figura 0.9 resume el método estadístico propuesto. Los pasos de la metodología son: (1) recopilación de datos históricos para predictor y predictando; (2) definición del predictor a escala diaria; (3) clasificación de las condiciones del predictor en un número reducido de tipos de tiempo; (4) establecimiento de la relación entre predictor y predictando; y (5) validación del modelo estadístico.

En primer lugar, se requieren datos históricos atmosféricos (predictor) y de clima marítimo (predictando) para definir el modelo estadístico entre predictor y predictando.

En cuanto a la definición del predictor a escala diaria, las variables son la SLP y los gradientes cuadrados de SLP. El dominio espacial y la cobertura temporal del predictor se deben especificar para cada lugar donde se hace un downscaling de oleaje. El dominio espacial debe cubrir el área de la cuenca oceánica de generación de las olas que llegan

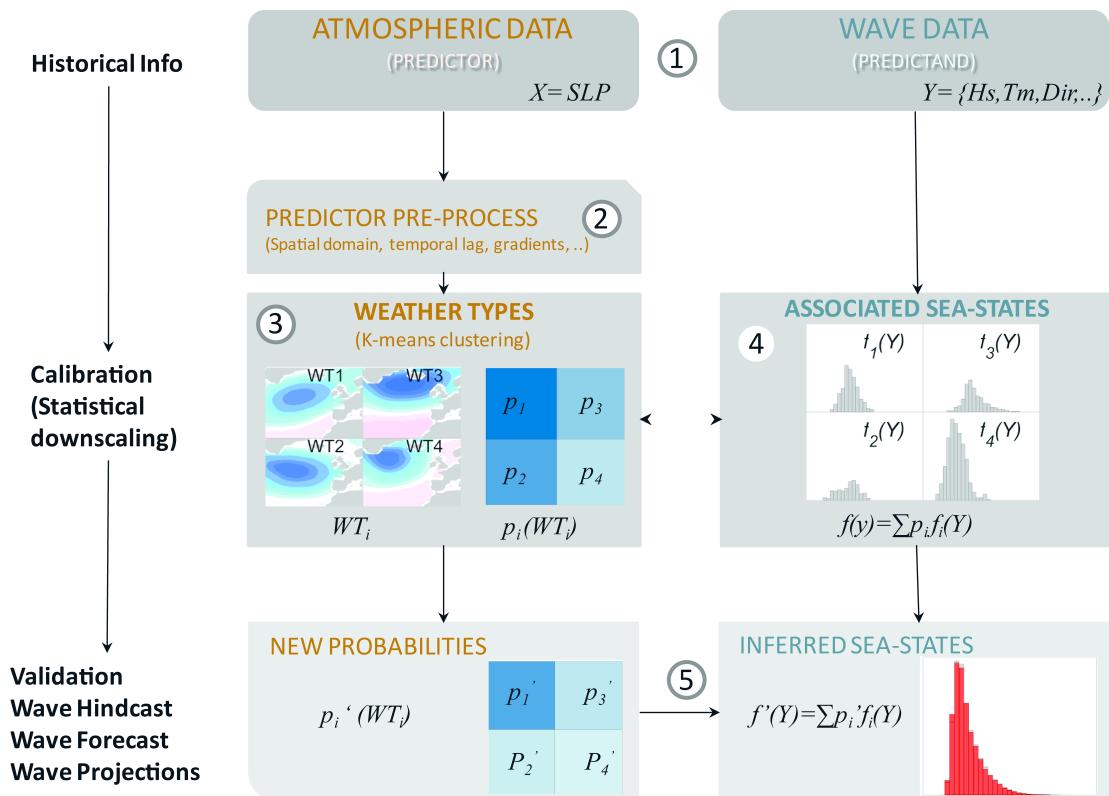


Figura 0.9: Diagrama de flujo que representa la metodología de downscaling estadístico

a ese lugar en particular. Las condiciones atmosféricas históricas recientes deben ser incluidas en el predictor con el fin de tener en cuenta los procesos de generación y propagación de las olas que llegan a esa ubicación específica.

En el tercer paso, la base de datos del predictor SLP se divide en un cierto número de grupos, llamados tipos de tiempo (Weather Types, WTs), aplicando una técnica de clasificación. Cada WT representa un patrón de circulación atmosférica sinóptica. La clasificación de WTs se obtiene combinando tres técnicas de minería de datos: en primer lugar, se aplica un análisis de componentes principales (Principal Component Analysis, PCA) al predictor con el fin de reducir la dimensionalidad de los datos y simplificar el proceso de clasificación. En segundo lugar, el predictor en el espacio de las funciones empíricas ortogonales (Empirical Orthogonal Functions, EOFs) se clasifica utilizando el algoritmo k-medias (K-Means Algorithm, KMA). Por último, el conjunto de los WTs se organiza utilizando un criterio de similitud.

El cuarto paso consiste en definir la relación estadística entre predictor y predictando. El predictando se define como los parámetros de estado de mar en la ubicación de interés. Las distribuciones de probabilidad de las diferentes variables $f_i(y)$, tales como la distribución univariada del parámetro H_s o la distribución conjunta de H_s y periodo medio (T_m), se calculan para cada WT. Esta relación estadística se establece para un periodo

de calibración. Aunque los métodos de downscaling estadístico a veces se calibran por separado para cada estación, en nuestro enfoque, el proceso de clasificación se realiza para todo el periodo de calibración debido al hecho de que los futuros climas estacionales pueden no corresponder exactamente con los actuales (Maraun et al. 2010). Por lo tanto, las distribuciones marginales y conjuntas (funciones de densidad de probabilidad empírica) de los parámetros de estado de mar y cualquier estadístico derivado pueden ser estimados para el periodo de calibración completo de la siguiente manera:

$$f(y) = \sum_{i=1}^M p_i \cdot f_i(y), \quad (0.12)$$

donde p_i es la probabilidad de ocurrencia del WT i ésimo. p_i se estima a partir del número de situaciones de predicción atmosféricas diarias representadas por cada WT, de modo que $\sum_{i=1}^M p_i = 1$, donde M es el número de tipos de tiempo.

El paso final de la definición del modelo de downscaling estadístico es la validación. La estimación de los parámetros de estado del mar para un periodo de tiempo fuera del periodo de calibración se basa en las nuevas probabilidades de los WTs. Las distribuciones de parámetros de estado de mar para un nuevo periodo de tiempo se puede estimar como:

$$f'(y) = \sum_{i=1}^M p'_i \cdot f_i(y), \quad (0.13)$$

siendo p'_i la probabilidad del WT i ésimo para el nuevo periodo. Los parámetros de estado de mar mensuales se calculan en base a la distribución de los estados de mar asociados a cada WT y las probabilidades de los WTs en el periodo de validación.

0.3.3. Caso de estudio

0.3.3.1. Datos

Los campos SLP globales de NCEP/NCAR reanálisis-I (Kalnay et al. 1996), se utilizan como predictor en el modelo SD. Este reanálisis abarca desde 1948 hasta el presente, sin embargo, es menos fiable durante la primera década (1948-1957). Por lo tanto, en este trabajo sólo se utilizan los datos de 1960 a 2013. Los datos de SLP utilizados consisten en campos 6-horarios en una rejilla de $2.5^\circ \times 2.5^\circ$.

En el modelo SD se requieren datos históricos de oleaje local para el predictando. La información histórica de oleaje utilizada en este trabajo proviene de la base de datos

de oleaje GOW (Global Ocean Waves, Reguero et al. 2012). GOW ha sido generado con el modelo de tercera generación III (Tolman 2009). Aquí, se utiliza oleaje de una simulación regional GOW en el área atlántica europea. El dominio espacial regional abarca desde 27.25°N a 57.25°N y 20°W a 37°E, con una resolución de 0.25°. Esta simulación proporciona parámetros de estado de mar horarios (altura de ola significante, periodo medio, periodo de pico, y dirección media) de 1948 a 2013.

Los dos sitios de estudio seleccionados se encuentran en el Atlántico Noreste: uno en la costa oeste de Irlanda (IR, lon = 11.25°W, lat = 53.25°N) y otro en la costa noroeste de España (GA, lon = 9.25°W, lat = 43.5°N). Las series de parámetros de oleaje GOW en ambos sitios se han comparado con registros de boyas para validar los datos. La validación muestra una buena concordancia entre datos numéricos y observaciones, con una correlación superior a 0.9 y un sesgo bajo (0.014 y 0.354 m para las boyas española e irlandesa, respectivamente).

0.3.3.2. Definición del predictor

El área seleccionada como dominio espacial del predictor abarca desde 25°N a 70°N y desde 52.5°W a 10°E. Este dominio cubre la actividad de tormentas en el Océano Atlántico Norte, que es la fuente de los swells en la costa noroeste de Europa (Alves 2006). Las variables utilizadas para el predictor en el modelo estadístico son los campos de SLP y los gradientes de SLP al cuadrado (SLPG), que representan el viento geostrófico. Los puntos de tierra de la malla del dominio seleccionado no se consideran para evitar la fuerte variabilidad de SLPG sobre Groenlandia y otras regiones terrestres. El predictor se define como la media 3-diaria de SLP y la media 3-diaria de SLPG, calculadas cada día durante el periodo de tiempo de calibración. Esto es, el predictor asociado con un cierto día corresponde a la media obtenida utilizando el mismo día y los 2 días anteriores.

0.3.3.3. Técnica de downscaling estadístico

En primer lugar, se aplica el análisis PCA a los datos diarios de SLP y SLPG en el periodo de calibración. En este ejemplo, el periodo de calibración es un periodo representativo de 40 años de 1960 a 1999. En este estudio, se considera una varianza del 95 %, que corresponde a las primeras 38 PCs.

Se establece un número de patrones $M = 100$ en la aplicación de KMA. La selección de un centenar de clases se realiza con base en un compromiso entre una fácil caracterización de climatologías sinópticas y la mejor reproducción de parámetros de estado de mar mensuales (validación del modelo). La figura 0.10 muestra los 100 WTs, organizados en

una red bidimensional. En la figura, los WTs están representados por las isobaras. Los sistemas de altas presiones respecto a la presión del aire a nivel del mar media (1.013 hPa) se muestran en una escala de color rojo y los sistemas de bajas presiones en una escala azul. Los patrones similares se encuentran juntos, variando suavemente desde una celda a otra.

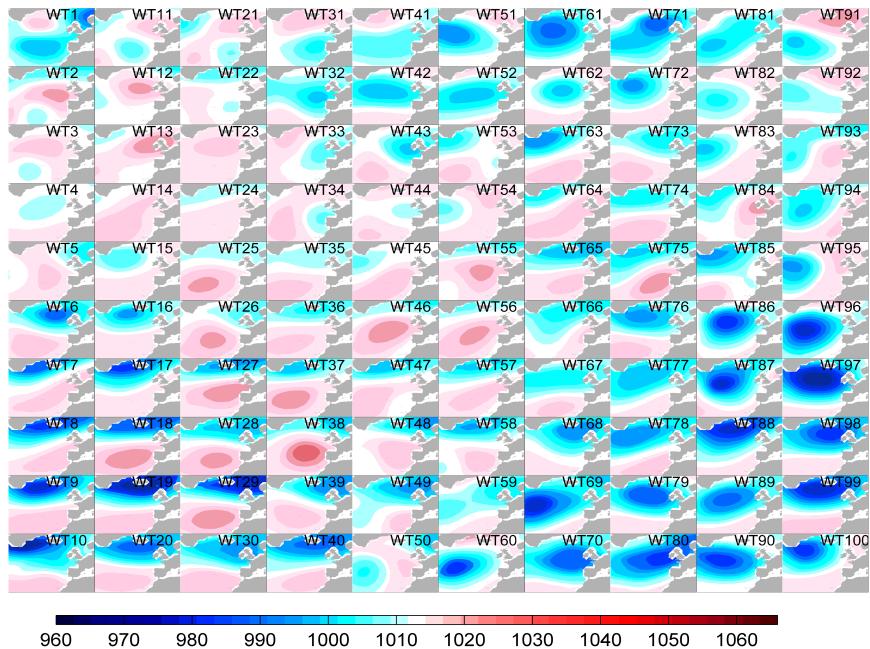


Figura 0.10: Los 100 tipos de tiempo representados por los campos de SLP (hPa) obtenidos a partir de la clasificación atmosférica

La variabilidad estacional o interanual se puede analizar utilizando la clasificación de tipos de tiempo. La figura 0.11 muestra gráficamente la probabilidad estacional y total de los WTs de NCEP-NCAR reanálisis-I durante el periodo de calibración de 40 años. El color azul oscuro indica WTs con alta frecuencia y el azul más claro indica WTs con baja frecuencia. La mayor variabilidad de los WTs se produce en invierno, mientras que los patrones sinópticos en verano, correspondientes a situaciones de altas presiones, se concentran en varios WTs ubicados en el centro de la clasificación. Los patrones en el resto de estaciones cubren una gama más amplia de los WTs. Los WTs en las esquinas de la cuadrícula, que se detectan sólo en invierno (DEF), corresponden a un centro de baja presión sobre el Atlántico Norte.

Además de ser una descripción de los estados atmosféricos, la clasificación es también una herramienta para la comprensión de los procesos atmosféricos y el vínculo entre la circulación atmosférica y el clima de superficie (Huth 2010). En esta sección, se describe

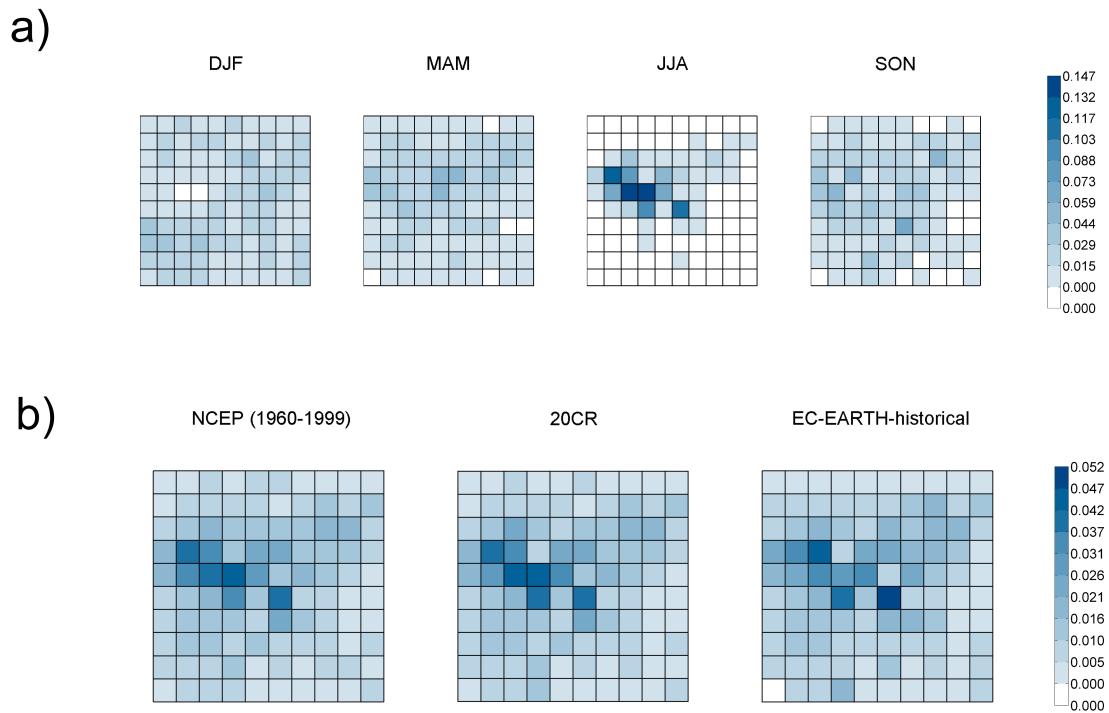


Figura 0.11: (a) probabilidad de ocurrencia estacional de los 100 tipos de tiempo (clasificación mostrada en la figura 0.10) para NCEP-NCAR reanálisis-I en el periodo de calibración (1960-1999). (b) Probabilidad de ocurrencia de las condiciones actuales (1960-1999) de los tipos de tiempo en NCEP-NCAR reanálisis-I, 20CR reanálisis, y el modelo climático EC-EARTH, de izquierda a derecha

la relación no lineal entre predictor (X , condiciones atmosféricas) y predictando (Y , oleaje local). Los datos de oleaje locales de los dos lugares seleccionados se proyectan en la clasificación de WTs. Los parámetros de estado de mar horarios H_s , T_m , dirección media del oleaje (θ_m), indicador del flujo de energía del oleaje ($H_s^2 T_m$), y las componentes x e y del indicador de flujo medio de energía, que corresponden a los campos de los predictores diarios representados por cada WT se han proyectado en cada WT durante el periodo de calibración.

La figura 0.12 presenta las distribuciones conjuntas $f_i(H_s, T_m)$ y $f_i(H_s, \theta_m)$ en GA asociadas con cuatro WTs diferentes. El WT dominante en verano (WT35) representa una situación atmosférica neutral, con sistemas de altas y bajas presiones débiles. La H_s más probable es aproximadamente 1.5 m; el T_m correspondiente es aproximadamente 7 s; y la θ_m es NW, aunque una amplia gama de direcciones de SW a NE son probables. WT97, un patrón que sólo se produce en invierno, representa un sistema de bajas presiones intensas en el Atlántico nororiental, con importantes SLPG. El patrón atmosférico se refleja en los estados de mar asociados. H_s es de alrededor de 9 m, T_m alrededor de 12 s, y θ_m es principalmente W. La H_s y el T_m asociados con WT35 y WT97 son claramente diferentes, lo que se refleja en un oleaje predominantemente tipo swell en invierno y tipo

sea en verano. WT29 es un patrón de invierno con un centro de baja presión localizado al norte que genera olas del noroeste muy energéticas (H_s inferior pero T_m mayor que WT97) en la ubicación GA. WT2 representa un centro de alta presión local y las olas del mar asociadas son, principalmente, de dirección noreste.

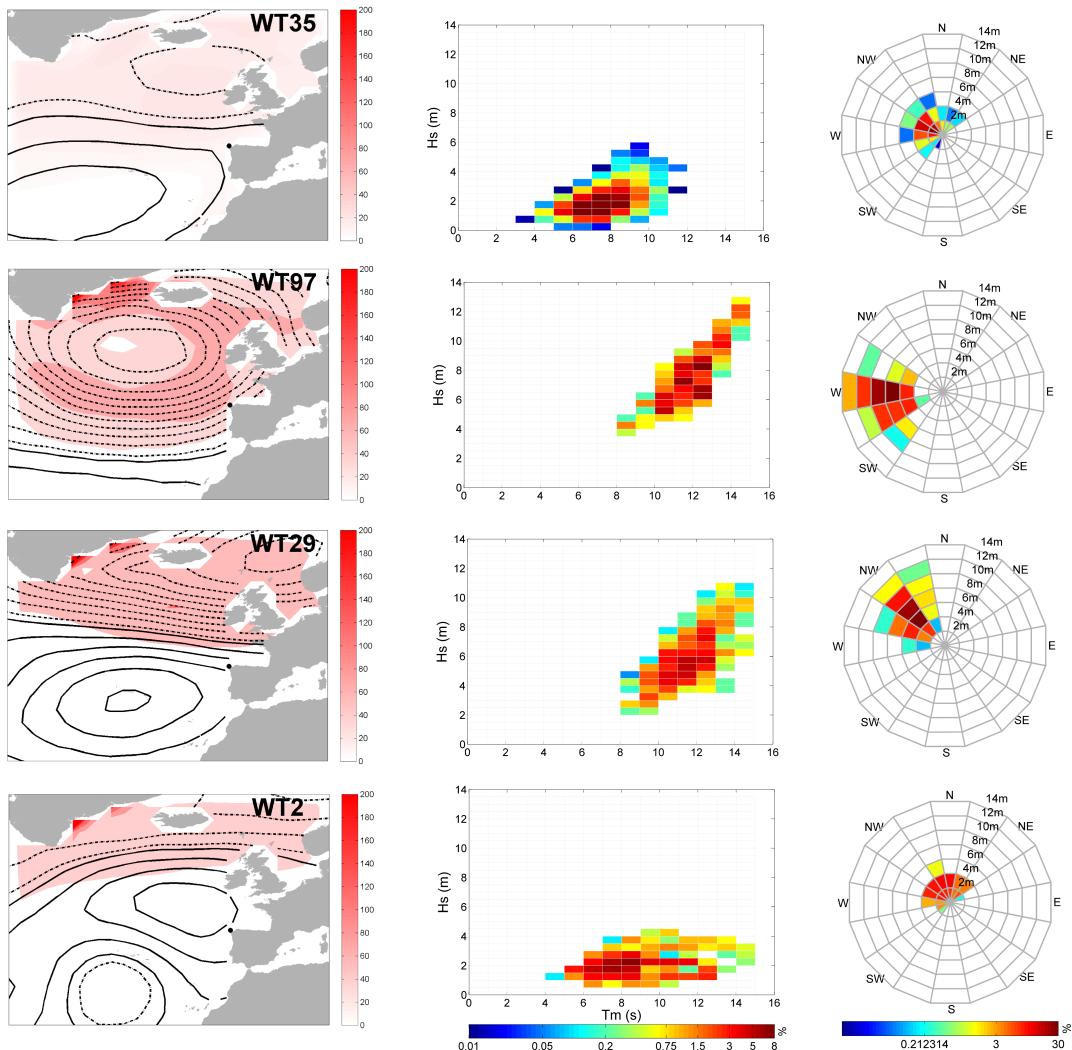


Figura 0.12: Izquierda Varios patrones (WT35, WT100, WT29 y WT2 de la clasificación de WTs mostrada en la figura 0.10; la escala de rojos representa los SLPG y las líneas representan el campo de SLP (línea discontinua por debajo de 1.013 hPa y continua por encima). *Centro* Distribución asociada de altura de ola significante horaria y periodo medio en la ubicación GA. *Derecha* Distribución asociada de altura de ola significante y dirección en la ubicación GA

0.3.3.4. Validación del método de downscaling estadístico

Con el fin de verificar la habilidad del método SD para predecir el oleaje multivariado, se realiza un análisis de validación en el periodo 2000-2013, comparando las estimaciones

del modelo de downscaling estadístico con los parámetros obtenidos a partir de las quasi-observaciones (datos de oleaje GOW).

Los parámetros H_s media, percentil 95 de H_s (H_{p95}), T_m , $H_s^2 T_m$, y la dirección media del flujo de energía de las olas (θ_{FE}) se validan mediante la distribución de parámetros-estado de mar correspondiente asociado a cada WT durante el periodo de calibración. La figura 0.13 muestra la comparación en la localización española. El oleaje mensual simulado del modelo SD es capaz de reproducir los datos cuasi-reales, incluso para los valores máximos y mínimos mensuales locales de todos los parámetros de estado de mar analizados. Aunque se pueden encontrar algunas discrepancias durante meses específicos, la variabilidad interanual de todos estos parámetros de estado de mar es bien reproducida en las dos localidades estudiadas. Se calcula el coeficiente de correlación (ρ), la raíz del error cuadrático medio (RMS), el índice de dispersión (SI) y el sesgo para cada variable validada. Se puede observar que el rango del coeficiente de correlación es de entre 0.80 y 0.97. El RMS es de aproximadamente 0.3 m para H_s , 0.3 s para T_m , 30 m²s para $H_s^2 T_m$ y 11 para θ_{FE} . Las mayores diferencias se encuentran en H_{p95} (RMS = 0.81 en la ubicación IR y RMS = 0.78 en la ubicación GA) y θ_{FE} (RMS = 12.48 en la ubicación IR y RMS = 9.34 en la ubicación GA).

0.3.4. Aplicaciones del downscaling estadístico

0.3.4.1. Caracterización del oleaje

Además de la obtención de las situaciones sinópticas más representativas en el Atlántico nororiental, la clasificación atmosférica organizada ofrece la posibilidad de representar una variable de oleaje local en un lugar determinado en la red 2-D mediante la proyección del valor de la variable asociada a cada mapa WT. De esta forma, se establece una conexión entre los patrones de circulación en el Océano Atlántico Norte y el oleaje local.

Alturas de ola significante medias más grandes, por lo general asociadas con grandes varianzas, se relacionan con los tipos de tiempo con centros de bajas presiones intensos en ambas esquinas inferiores de la clasificación. En el caso de la ubicación de Irlanda, los patrones con olas más grandes corresponden a los modos de NAO positivos, con un centro de baja presión intensa alrededor de Islandia (WTs en la parte inferior izquierda de la clasificación). En el caso de la ubicación española, las olas más energéticas pueden estar asociadas con el patrón NAO positivo estándar y el patrón de EA positivo, en la esquina inferior derecha de la red (i.e. el WT97 descrito previamente como un patrón de invierno). WTs asociados a EA generan olas muy energéticas con dirección media oeste-suroeste, debido a que estos patrones espaciales están relacionados con vientos

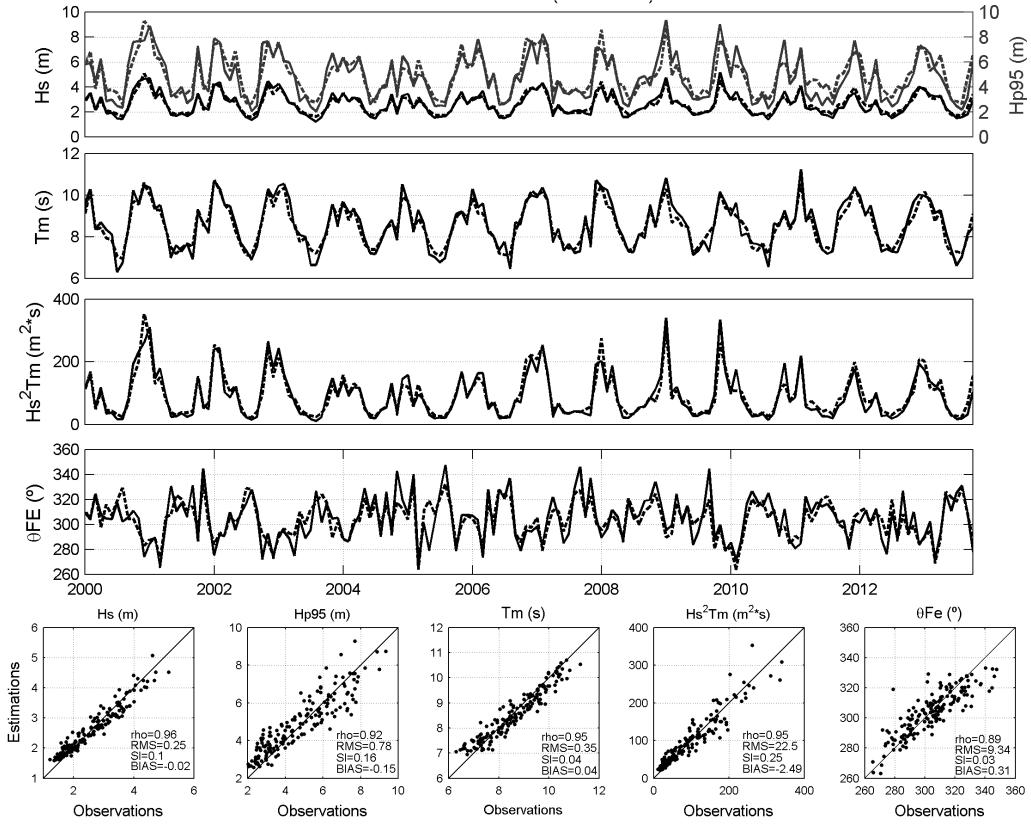


Figura 0.13: Comparación de series temporales y diagramas de dispersión de los parámetros de estado de mar mensuales: H_s , H_{p95} , T_m , $H_s^2 T_m$, θ_{FE} en el periodo 2001-2009 en la localización GA. Las líneas continuas muestran las series temporales del hindcast GOW. Las líneas discontinuas representan los parámetros mensuales obtenidos a partir de la metodología de downscaling propuesta

del oeste, mientras que los WTs de NAO están asociados con olas ligeramente menos energéticas con dirección noroeste. Los diferentes oleajes asociados con estos patrones NAO y EA reflejan que gran parte de las anomalías del oleaje en el Atlántico Norte, principalmente en la parte norte, se explica por la NAO; mientras que gran parte del resto de las anomalías en la parte sur está relacionada con EA (Woolf 2002). En el caso de olas asociadas con los patrones predominantes en verano, que se encuentran en el medio de la red KMA, las frecuentes condiciones de altas presiones generan olas de dirección norte-noreste.

La figura 3.10 muestra la distribución bidimensional de H_s y θ_m para los 100 WTs en la ubicación irlandesa. Los WTs más destacados son los correspondientes a los estados de mar más energéticos. Como se describe anteriormente, las mayores alturas de ola significante se asocian con patrones de bajas presiones, situados en las esquinas de la celosía KMA. La ubicación del centro de baja presión en el Atlántico Norte distingue el origen de las olas, lo cual se refleja principalmente en la dirección de las olas. Por ejemplo, centros de baja presión en el norte (patrones NAO positivos) generan olas

del oeste en la ubicación irlandesa y del noroeste en la ubicación española (e.g. WT19 y WT29). Los periodos más altos asociados con estos WT también se detectan en la ubicación española debido a una distancia mayor respecto a la zona de generación (no se muestran las distribuciones asociadas de H_s y T_m). Centros de baja presión en el sur (patrones EA positivos) están vinculados a olas que vienen del suroeste en la ubicación irlandesa o desde el oeste en la ubicación española (e.g. WT87 y WT97). Este cambio hacia el sur en la dirección de las olas está relacionado con un patrón EA positivo (Charles et al. 2012). La energía de las olas es más destacable si la posición de estos centros está más cerca de la ubicación estudiada (WT29 genera olas más enérgicas en la ubicación irlandesa, mientras WT97 genera olas más enérgicas en la ubicación española). Los patrones neutrales están asociados con olas poco energéticas (bajos valores de H_s y T_m) provenientes de una gama más amplia de direcciones, debido a que el predictor caracteriza patrones regionales mientras estas olas son generadas por fenómenos locales. Varios WTs representan situaciones particulares, por ejemplo, WT1, se caracteriza por un centro de alta presión a la latitud de la ubicación irlandesa, que genera olas locales del norte en esta ubicación. Estas diferencias en la dirección de las olas se detectan en la caracterización del oleaje mediante los valores medios de H_s y θ_{FE} asociados con cada WT.

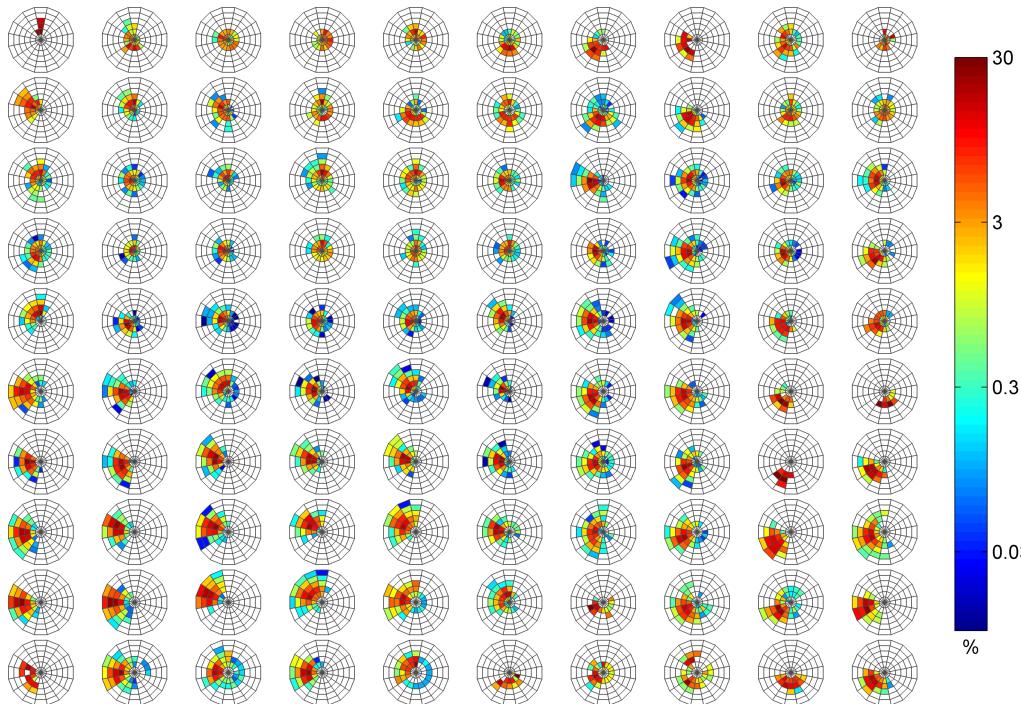


Figura 0.14: Distribución de H_s y θ_m asociadas a cada tipo de tiempo en la ubicación al oeste de Irlanda. Las unidades de la distancia radial están en m con la misma escala que en la figura 0.12 (los incrementos de H_s son 2 m)

0.3.4.2. Hindcast de oleaje

Se ha generado una reconstrucción histórica de largo plazo de oleaje local a partir de los datos de SLP del reanálisis del siglo XX (20CR, Compo et al. 2011) creado por NOAA ESRL/PSD. Los campos de SLP están disponibles con resolución temporal 6-horaria y resolución horizontal de 2° . La figura 0.15a muestra la media mensual reconstruida de H_s en los dos sitios de estudio desde 1900. La figura 0.15b muestra la comparación entre la H_s de invierno (DEFM) del downscaling estadístico de 20CR (negro) y del downscaling estadístico de NCEP reanálisis-I (azul). Esta comparación revela un buen acuerdo entre ambas reconstrucciones y una gran habilidad para simular la variabilidad del clima. La ubicación GA (2.63 m de H_s media y 3.44 m de H_s media en invierno para 1900-2010) no presenta H_s tan grandes como la ubicación IR (3.24 y 4.24 m, respectivamente). Un punto interesante es que, mientras que la ubicación GA muestra variaciones interanuales homogéneas con máximos a lo largo de todo el periodo, los mayores valores en IR se observan durante el periodo 1970-2000. Nuestras H_s medias en las dos ubicaciones son similares a las de Bertin et al. (2013) para el periodo 1900-2008 (3.2 m en IR y 2.6 m en GA) pero difieren de las de Wang et al. (2012) para el periodo 1958-2001 (2.9 m en IR y 2.4 m en GA). Sin embargo nuestras H_s medias son similares a las olas de un downscaling dinámico a partir de MSC50 (Cox and Swail 2001) para el mismo periodo (3.2 m en IR y 2.6 m en GA). Por otro lado, el análisis de las tendencias lineales de H_s revela aumentos para 1958-2001 (0.5 y 0.15 cm/año en las ubicaciones IR y GA, respectivamente) similares a los encontrados con el modelo SD por Wang et al. (2012), 0.45 cm/año en IR y 0.10 cm/año en GA, y los datos MSC50 (0.50 cm/año en IR y 0.10 cm/año en GA), pero nuestra tendencia estimada en la ubicación IR (0.019 cm/año) para el siglo XX difiere de Bertin et al. (2013), que encontró mayores tendencias positivas en el Atlántico Nordeste (0.6 cm/año en IR). Es de destacar que después del periodo 1958-2000, caracterizado por un aumento en la intensidad del oleaje, las tendencias estimadas en los últimos 30 años (1980-2009) son significativamente negativas en los dos sitios para la H_s media y la H_s de invierno (-0.23 cm/año para H_s media y -1.78 cm/año para H_s de invierno en IR y -0.17/-0.96 cm/año, respectivamente, en GA).

El método SD proporciona una herramienta para actualizar la información de oleaje a partir de resultados numéricos con bajo costo computacional. Aquí, se ha reconstruido el invierno 2013-2014, un invierno especialmente intenso con un “jet stream” fuerte que causó fuertes oleajes que afectaron a Portugal y España. Las líneas rojas en la figura 0.15 indican las H_s medias mensuales estimadas. Se muestran las olas más grandes que llegan a las costas europeas en el invierno 2013-2014, llegando a 5 m, en la ubicación GA y 6 m en lugar de IR. Observamos que el modelo SD también se puede utilizar como una herramienta de pronóstico de una manera similar.

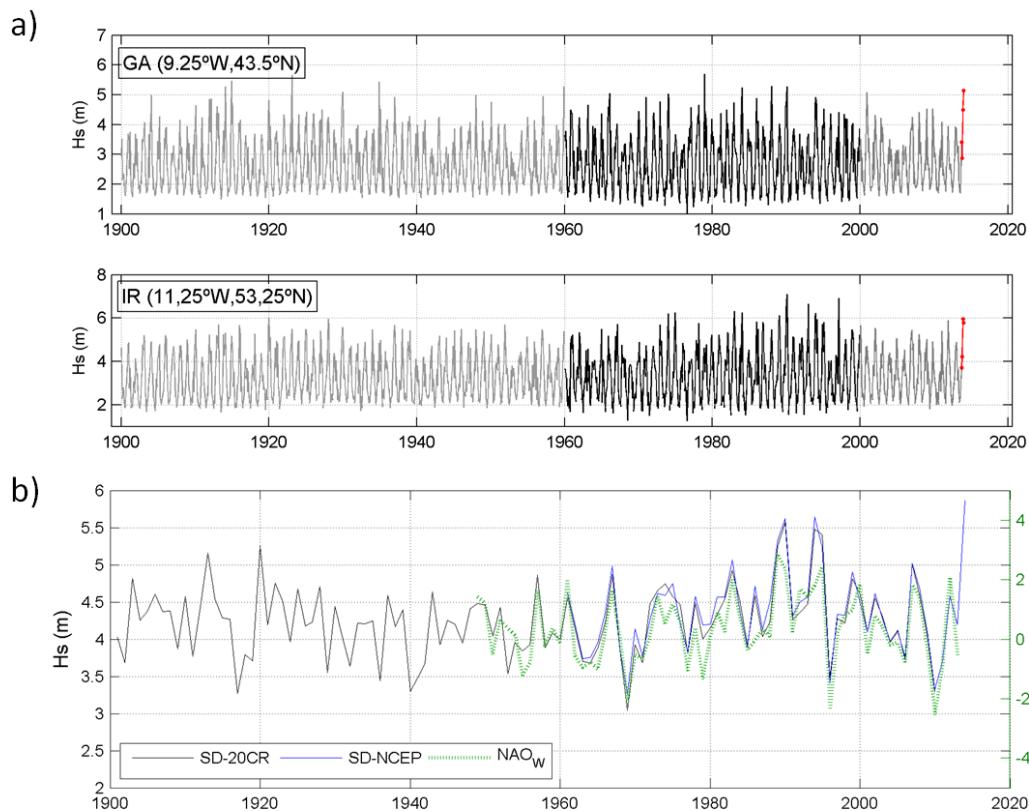


Figura 0.15: (a) Series temporales de la reconstrucción histórica de H_s mensual a partir de 20CR (1900-1960); NCEP-NCAR reanálisis-I para el periodo de calibración (1960-2000) y el periodo de validación (2001-2013); y el invierno 2013-2014 (línea roja) para las dos localizaciones analizadas. (b) La reconstrucción de H_s de invierno (DEFM) a partir de 20CR (negro) y NCEP-NCAR reanálisis-I (azul) en la ubicación de IR y el índice climático NAO de invierno (verde)

0.3.4.3. Proyecciones de oleaje

Aplicando el modelo SD se pueden obtener proyecciones futuras de oleaje local a partir de las salidas de un GCM. Usamos el GCM EC-Earth (Hazeleger et al. 2012), de un consorcio europeo con la colaboración de 27 instituciones. Los datos de SLP se obtienen de experimentos de CMIP5 para diferentes escenarios de cambio climático. Los escenarios utilizados son llamados historical (condiciones históricas), RCP2.6 (escenario de mitigación con bajas emisiones) y RCP8.5 (escenario de emisiones muy altas).

Se ha detectado un ligero descenso en la H_s de invierno futura en relación al presente, siendo la H_s de invierno de RCP8.5 mayor que la de RCP2.6. Las proyecciones de oleaje estadísticas basadas en un ensemble de CMIP5 también muestran una disminución general de la H_s anual en las latitudes medias del Atlántico Norte para el periodo 2080-2099 en relación con el periodo 1980-1999 para el escenario RCP8.5 (Wang et al. 2014). Es interesante destacar que los valores proyectados en 2070-2099 en lugares GA e IR

no muestran variaciones en la media y la varianza diferentes a los reconstruidos en el pasado.

0.4. Evaluando la habilidad de los modelos climáticos globales de CMIP3 y CMIP5 en el Atlántico Noreste

Este apartado constituye un resumen del artículo Perez et al. (2014b): Perez, J., Menendez, M., Mendez, F. J., Losada, I. J. (2014). Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region. Climate Dynamics, 43(9-10), 2663–2680. <http://doi.org/10.1007/s00382-014-2078-8>

0.4.1. Introducción

Los resultados de modelos climáticos globales (GCMs) se utilizan en muchos estudios para entender los cambios en la dinámica del clima y determinar los efectos del cambio climático. Por otra parte, los GCMs se utilizan como base para muchos experimentos de downscaling dinámicos y estadísticos, para obtener información de variables que los GCMs no simulan directamente, como olas o mareas meteorológicas (e.g. Marcos et al. 2011) o no simulan con suficiente resolución (e.g. nieve y precipitación). Uno de los principales retos asociados con el uso de GCMs es la incertidumbre estructural de los modelos. Sin contar la incertidumbre de los forzamientos de los escenarios de cambio climático, la habilidad de los diferentes GCMs está determinada por los diferentes métodos utilizados para resolver las ecuaciones que describen la dinámica atmosférica y oceánica. Una evaluación sistemática del desempeño de los modelos es, por lo tanto, obligada para proporcionar una mayor confianza en el uso de GCMs.

El objetivo principal de este estudio es definir una metodología para evaluar la calidad de los GCMs en una región. El método, por lo tanto, puede ayudar a los usuarios de GCMs en la elección del modelo más apropiado para estudiar cambios en la dinámica del clima, evaluar impactos, o hacer downscaling de variables superficiales. Un procedimiento común para evaluar la capacidad de los GCMs es comparar los resultados de las simulaciones de modelos con reconstrucciones históricas (reanálisis) u observaciones. Esto se puede lograr mediante el análisis de las diferencias entre las climatologías medias o incluso la función de densidad de probabilidad completa. Trabajos recientes han evaluado la habilidad de los GCMs para reproducir la climatología sinóptica (e.g. Belleflamme et al. 2013; Lorenzo et al. 2011) mediante el uso de métodos de clasificación. Los métodos de clasificación de la circulación atmosférica han demostrado ser una herramienta útil y eficiente computacionalmente para la validación de los GCMs (Huth 2000). El estudio de la climatología sinóptica de los patrones de circulación o tipos de clima tiene en cuenta la variabilidad natural del clima y permite la evaluación de las relaciones espaciales entre diferentes ubicaciones.

En este trabajo, se caracterizan los patrones sinópticos de los campos de presión al nivel del mar (SLP). La SLP proporciona información de las condiciones climáticas de superficie y ha sido considerado un predictor mejor que otras variables para downscaling (e.g. Busuioc et al. 2001; Frías et al. 2006; von Storch et al. 1993). Teniendo esto en cuenta, se ha evaluado el desempeño de un conjunto de GCMs en el Atlántico nororiental. La metodología, basada en tipos de tiempo y métricas estadísticas, analiza no sólo la habilidad de los GCMs para reproducir climatologías medias sino también la variabilidad interanual. Además, también se evalúa la consistencia de simulaciones futuras. Este método se ha aplicado a 68 modelos de CMIP3 a CMIP5, proporcionando información útil sobre la calidad de los GCMs en Europa.

0.4.2. Datos

0.4.2.1. Datos atmosféricos de reanálisis

La evaluación del desempeño de los GCMs requiere la comparación con observaciones históricas. Los reanálisis atmosféricos son largas reconstrucciones climáticas históricas que pueden ser considerados como datos quasi-reales dado que integran múltiples mediciones instrumentales y han sido ampliamente validados contra observaciones independientes. Hoy en día, hay varias bases de datos globales de reanálisis atmosféricos. En este trabajo, utilizamos los datos de SLP 6-horaria obtenidos de tres reanálisis globales que abarcan la mayor parte del siglo XX: NCEP/NCAR I (NNR, Kalnay et al. 1996), ECMWF 40-year Reanalysis (ERA-40, Uppala et al. 2005) y NOAA-CIRES twentieth Century Reanalysis V2 (20CR, Compo et al. 2011). En este estudio, NNR ha sido seleccionado para caracterizar los patrones sinópticos de la circulación atmosférica, ya que ha sido ampliamente validado por la comunidad científica, cubre un periodo histórico grande y llega hasta el presente, no obstante, ERA-40 y 20CR también han sido comparados con los GCMs.

0.4.2.2. Modelos climáticos globales

En este estudio, se ha utilizado la presión a nivel del mar diaria de 68 GCMs. Estos modelos se han dividido en dos grupos en función de qué generación de escenarios se han simulado. Un grupo incluye 26 modelos de los proyectos CMIP3 y ENSEMBLES y el otro incluye 42 modelos del CMIP5. Las tablas 4.1 y 4.2 (capítulo 4) muestran los nombres de los modelos que han sido utilizados, así como los centros de investigación y los países a los que pertenecen, la resolución atmosférica y el número de simulaciones futuras analizadas (runs). Se han utilizado datos de 1961-1990 (periodo de referencia)

para caracterizar las condiciones del pasado reciente y se han utilizado proyecciones de 2010-2100 para representar las condiciones futuras, ya que son periodos de tiempo disponibles en la mayoría de los modelos.

Las simulaciones analizadas en modelos del CMIP3 y ENSEMBLES se llaman 20C3M (Twentieth Century Climate in Coupled Models) para las condiciones pasadas recientes; y SRES B1, SRES A1B y SRES A2 (Informe Especial sobre Escenarios de Emisiones, Nakicenovic and Swart 2000) para los escenarios futuros. Los tres escenarios seleccionados se toman generalmente para representar concentraciones bajas, medias y altas de CO₂, respectivamente. Se estudiaron un total de 44 simulaciones de 20C3M, 43 de A1B, 19 de A2 y 26 de B1. Para los 42 modelos de CMIP5, los experimentos analizados se llaman historical para las condiciones pasadas recientes y RCP2.6, RCP4.5, RCP6.0 y RCP8.5 (Representative Concentration Pathways, RCPs, Moss et al. 2010) para el futuro. Los cuatro RCPs seleccionados incluyen un escenario de mitigación (RCP2.6) que lleva a un nivel muy bajo de forzamiento, dos escenarios intermedios de estabilización (RCP4.5/RCP6.0) y un escenario de emisiones muy altas (RCP8.5) que conduce a altos niveles de concentración de gases de efecto invernadero (van Vuuren et al. 2011). Esto hace un total de 136 simulaciones historical, 48 de RCP2.6, 83 de RCP4.5, 31 de RCP6.0 y 63 de RCP8.5.

0.4.3. Metodología

Primero se seleccionan los datos de reanálisis y GCMs. Después se define el área de estudio y los campos de SLP se preprocesan al dominio espacial en la región seleccionada. Con el fin de obtener indicadores estimados del desempeño de los GCMs, se lleva a cabo una clasificación de tipos de tiempo (Weather Types, WTs) a partir de los datos de reanálisis. La frecuencia relativa de cada grupo de situaciones sinópticas se evalúa tanto para los datos de reanálisis como para los GCMs en varios periodos de tiempo. Por último, los diferentes índices estadísticos se calculan al comparar las frecuencias relativas. La comparación entre la frecuencia histórica observada y simulada indica la habilidad de los GCMs para simular el clima del pasado reciente. Los resultados de esta comparación se utilizan para analizar la similitud de las situaciones sinópticas y la capacidad de los GCMs para reproducir la variabilidad climática. Por otro lado, la comparación entre la frecuencia histórica y futura de los WTs a partir de GCMs determina las magnitudes simuladas de cambio. Estas magnitudes de cambio se utilizan para analizar la consistencia de las proyecciones futuras.

0.4.3.1. Área de estudio

Se ha seleccionado un área en el Atlántico noreste de 25°N a 65°N y de 52.5°W a 15°E. En esta región, muchas variables están altamente correlacionadas con los campos de presiones, como olas de viento (Izaguirre et al. 2012), precipitación (Rodríguez-Puebla and Nieto 2010), nieve (Seager et al. 2010) y producción de cereales (Rodríguez-Puebla et al. 2007). Dado que los datos de GCMs se proporcionan en mallas de diferentes resoluciones espaciales, con el fin de hacer una comparación coherente, todos los datos de SLP se han interpolado mediante interpolación bilineal a una malla de 2.5° x 2.5°, idéntica a la malla de los datos de NNR.

0.4.3.2. Clasificación de tipos de tiempo

Para evaluar el desempeño de los GCMs, por lo general se comparan las climatologías medias de GCMs con las de reanálisis. Sin embargo, la comparación de climatologías medias ignora la variabilidad climática de la circulación atmosférica, que provoca una gran variedad de situaciones meteorológicas. La evaluación de los GCMs mediante una clasificación de tipos de tiempo reduce este problema, ya que la clasificación tiene como objetivo agrupar situaciones meteorológicas similares minimizando la variabilidad dentro de cada grupo.

En primer lugar, procesamos cada campo de anomalías de SLP 3-diarias promediadas, $SLPA(x, t) = SLP(x, t) - SLP(t)$, donde t representa cada intervalo de 3 días y $SLP(t)$ es la SLP media en el intervalo de 3 días en el dominio espacial. Después, aplicamos el análisis de componentes principales (PCA) a los campos de SLP 3-diarios procesados de NNR de 1950 a 1999. PCA ayuda a la técnica de custerización al reducir las dimensiones conservando gran parte de la varianza de los datos. En este caso, once componentes han explicado más de 95 % de la varianza. Con el fin de obtener un conjunto de climatologías sinópticas, el algoritmo k-medias se ha aplicado sobre estos modos. La técnica k-medias divide el espacio de datos en N clases, que están representadas por sus centroides. Cada clase representa un grupo de estados atmosféricos de características similares. Forzamos el algoritmo k-medias para comenzar la selección en base a máxima disimilitud (Snarey et al. 1997) y el número de clases se ha ajustado a $N = 100$. Se aplica un criterio de proximidad sobre los $N = 100$ WTs obtenidos y los centroides se visualizan en una cuadrícula de 10 x 10 elementos. El criterio de proximidad se basa en la minimización de la suma de las distancias euclídeas entre cada centroide y sus vecinos. Esta organización ayuda a interpretar los resultados ya que los WTs de características similares aparecen cerca unos de otros.

0.4.3.3. Evaluación del desempeño de los GCMs

La información sobre el clima obtenida a partir de la clasificación sinóptica de NNR se ha utilizado para evaluar la habilidad de los GCMs. En primer lugar, se ha calculado la frecuencia relativa de cada uno de los 100 WTs para NNR, usado como patrón de referencia. Las frecuencias relativas se estiman a partir del número de estados atmosféricos 3-diarios que se pueden atribuir a cada WT, caracterizado por su centroide, durante el periodo de referencia de 30 años (del 1 de enero de 1961 hasta el 31 de diciembre de 1990). La distancia euclíadiana en el espacio reducido de las EOFs se ha utilizado para evaluar qué centroide es el más cercano. Después, las bases de datos ERA-40, 20CR y GCMs se proyectan sobre los 100 WTs derivados de NNR, y se estiman sus frecuencias relativas para cada WT.

Se han aplicado índices objetivos para medir las diferencias entre las frecuencias del patrón de referencia y las de los GCMs en el mismo periodo de las simulaciones historical/20C3M. Se han utilizado para este propósito el índice de dispersión y una métrica basada en la entropía relativa. El índice de dispersión (*SI*) es el error cuadrático medio normalizado por la frecuencia media:

$$SI = \sqrt{\frac{\sum_{i=1}^N (p_i - p'_i)^2}{N}} \Bigg/ \frac{\sum_{i=1}^N (p_i)}{N}, \quad (0.14)$$

siendo p_i la frecuencia relativa del WT i ésimo del reanálisis para el periodo de referencia, p'_i la frecuencia relativa del WT i ésimo de una simulación de un GCM para el periodo de referencia y N el número de WTs. Este índice se ha utilizado para comparar las frecuencias relativas de cada simulación de cada GCM con las del reanálisis durante el periodo de referencia. La métrica basada en la entropía relativa (*RE*) se define aquí como:

$$RE = \sum_{i=1}^N p_i \left| \log \frac{p_i}{p'_i} \right|, \quad (0.15)$$

Valores bajos de *SI* y *RE* indican un alto grado de similitud y, por tanto, un buen desempeño del GCM. El índice *RE* se ha utilizado para analizar la habilidad de los GCMs para simular WTs de baja probabilidad de ocurrencia. El análisis de estas situaciones, que podrían estar asociadas a eventos extremos, requiere un índice relativo, como *RE* ya que *SI* da más importancia a las situaciones que ocurren comúnmente. Sin embargo, *RE* puede divergir fácilmente si un modelo tiene cero ocurrencias para un WT particular. En estos casos, se supone un valor mínimo de 0.5 ocurrencias.

Este análisis se ha hecho anual y estacionalmente. El patrón de referencia representa la frecuencia relativa de cada tipo de tiempo para las condiciones pasadas. NNR se ha utilizado para derivar este patrón aunque ERA-40 y 20CR muestran características similares. Por ejemplo, las frecuencias obtenidas de ECHAM5 (CMIP3) y ACCESS1.0 (CMIP5), proporcionan bajo *SI* y *RE* ya que tanto las situaciones muy comunes como las poco comunes están bien reproducidas. Alternativamente, CNRM-CM3 (CMIP3) y FGOALS-g2 (CMIP5) muestran menos similitud con el patrón de referencia de reanálisis y consecuentemente mayor *SI* y *RE*. Hay que tener en cuenta que aquí y de ahora en adelante, *SI* y *RE* son interpretados en valores relativos (i.e. valores bajos o altos en comparación con los de otros GCMs).

La habilidad de un modelo para representar el estado climático es la prueba más importante para evaluar su calidad. Por esta razón, a menudo se utilizan climatologías medias en un periodo de varias décadas para comparar GCMs con observaciones. Sin embargo, es importante señalar que la varianza (i.e. la variabilidad interanual) es también un requisito para un buen desempeño del modelo. Se ha analizado la habilidad de GCMs para representar la variabilidad climática interanual debido a que es un indicador de su capacidad para responder a las condiciones cambiantes. La magnitud de la variabilidad interanual se ha medido para cada WT mediante la evaluación de la desviación estándar de los 30 valores anuales de frecuencia relativa durante el periodo de referencia (1961-1990). La comparación de los valores de variabilidad del reanálisis con los que corresponden a cada GCM se lleva a cabo por el índice de dispersión de las desviaciones estándar de los *N* tipos de tiempo (*stdSI*).

$$stdSI = \frac{\sqrt{\frac{\sum_{i=1}^N (std(p_i) - std(p'_i))^2}{N}}}{\frac{\sum_{i=1}^N std(p_i)}{N}}, \quad (0.16)$$

Cuanto menor sea el *stdSI* mejor será la capacidad del GCM para simular la variabilidad climática interanual.

El buen desempeño de los modelos a partir del clima actual no garantiza necesariamente predicciones fiables del clima futuro (Reichler and Kim 2008). Esto se debe principalmente a que las proyecciones consideran futuras forzamientos de gases de efecto invernadero fuera del rango utilizado en el periodo histórico de la validación.

Para evaluar la consistencia entre proyecciones futuras de GCMs, se ha dividido el siglo XXI en tres periodos diferentes: corto plazo (2010-2039), medio plazo (2040-2069) y largo plazo (2070-2099); mientras se evalúa qué modelos predicen variaciones inconsistentes en cada uno de estos periodos, es decir, magnitudes de cambio mucho mayores o mucho menores que las de la mayoría de los modelos. Se asume la hipótesis de estacionariedad

en la dinámica del clima, es decir, la clasificación de WTs sigue siendo válida durante todo el siglo 21. Para cada simulación y periodo de tiempo futuro analizados, se han calculado dos indicadores de la magnitud del cambio respecto a las simulaciones en el periodo de referencia. La magnitud del cambio en la frecuencia de situaciones sinópticas se ha evaluado mediante SI y la magnitud del cambio en la variabilidad interanual ha sido analizada mediante $stdSI$. En caso de existir varias simulaciones del mismo modelo se ha utilizado la magnitud media de cambio. Para cada escenario, periodo futuro y métrica, se han calculado los cuartiles de las magnitudes de cambio. El rango intercuartílico (RIC) es la diferencia entre el cuartil superior ($Q3$, percentil 75) y el cuartil inferior ($Q1$, percentil 25). En este estudio, se considera que los modelos con magnitudes de cambio menores que $Q1 - 1.5(RIC)$ o superiores a $Q3 + 1.5(RIC)$ tienen un comportamiento excesivamente diferente al del resto de GCMs.

0.4.4. Resultados

0.4.4.1. Habilidad de los GCMs para representar climatologías

La capacidad de los GCMs para representar la frecuencia relativa de situaciones sinópticas en el periodo de referencia puede ser evaluada por comparación directa con el patrón de referencia. El sesgo que se ha estimado en los conjuntos de simulaciones 20C3M (CMIP3 y ENSEMBLES) e historical (CMIP5) es pequeño para todos los WTs. Esto indica una buena capacidad de los modelos para reproducir situaciones sinópticas comunes, es decir climatologías medias. Las simulaciones del CMIP5 ($SI = 0.37$, $RE = 0.07$) muestran mejores índices que las de CMIP3 ($SI = 0.45$, $RE = 0.08$). Sin embargo, se encuentran algunas discrepancias en WTs inusuales asociados a bajas presiones profundas centradas sobre diferentes zonas del Atlántico Norte y WTs asociados a estados atmosféricos relativamente estables. Los primeros se sobreestiman, mientras que los últimos tienden a ser subestimados ligeramente.

Los resultados de los GCMs individuales se resumen en la figura 0.16 para simulaciones 20C3M y en la figura 0.17 para simulaciones historical. En ambas figuras los modelos se han clasificado de acuerdo a su SI y el número de simulaciones analizadas para cada modelo se muestra entre paréntesis. El SI de los modelos con sólo una simulación está representado por las pequeñas líneas negras verticales. Cuando hay varias simulaciones disponibles estas líneas negras verticales representan el valor medio de SI , mientras que las horizontales representan el intervalo entre el SI mínimo y el máximo. El RE medio está representado por un punto negro. Los valores de SI y RE también se han obtenido para los reanálisis ERA-40 ($SI = 0.16$, $RE = 0.10$) y 20CR ($SI = 0.26$,

$RE = 0.14$) durante el periodo de referencia. 20CR también ha sido analizado en 1901-1930 ($SI = 0.30$, $RE = 0.18$) y en 1931-1960 ($SI = 0.30$, $RE = 0.19$). Las puntuaciones similares para diferentes periodos del siglo XX apoyan el uso de la misma clasificación sinóptica en el siglo XXI. Estos valores de SI y RE proporcionan un indicador de buen desempeño para comparar con los GCMs. Los valores de SI de los reanálisis se han representado en las figuras por líneas de puntos verticales. Se puede observar que ERA-40 es muy similar a NNR mientras que 20CR presenta diferencias más grandes. Esto era esperable dado que 20CR solamente asimila datos de presión superficial.

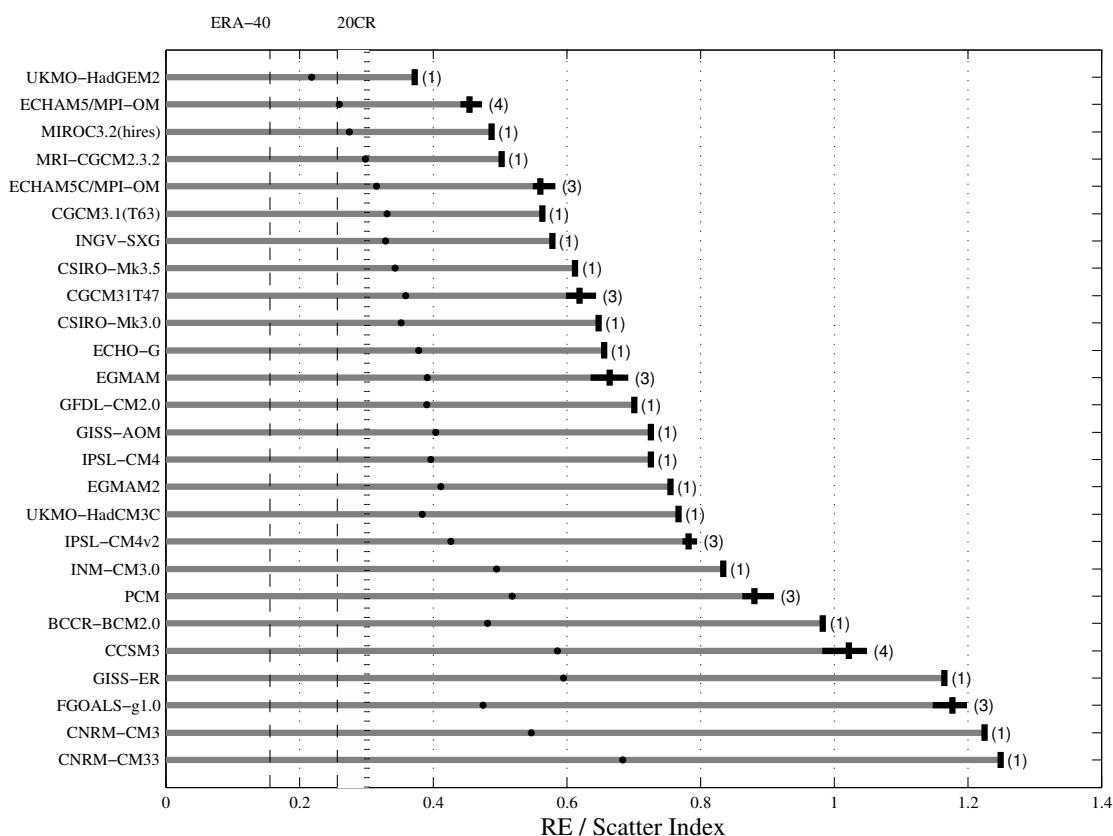


Figura 0.16: GCMs de CMIP3 y ENSEMBLES ordenados por la habilidad para modelar situaciones sinópticas (habilidad mayor, SI menor). El RE medio está representado por un punto negro

Los modelos que mejor reproducen las frecuencias de los WTs para simulaciones de 20C3M, con SI inferior a 0.5 y RE menor que 0.3, son: UKMO-HadGEM2 ($SI = 0.37$, $RE = 0.22$), ECHAM5/MPI-OM ($SI = 0.46$, $RE = 0.26$) y MIROC32HIRES ($SI = 0.49$, $RE = 0.28$). Alternativamente, los cinco modelos que tienen SI mayor que 1 y, por lo tanto, tienen un desempeño peor, son: CCSM3, GISS-ER, FGOALS-G1.0, CNRM-CM3 y CNRM-CM33. Para los modelos CMIP5, hay nueve modelos con SI inferior a 0.5. Tres de ellos: ACCESS1.0 ($SI = 0.33$, $RE = 0.19$), EC-EARTH ($SI = 0.36$, $RE = 0.21$) y HadGEM2-CC ($SI = 0.37$, $RE = 0.21$) tienen SI y RE inferiores al mejor modelo para

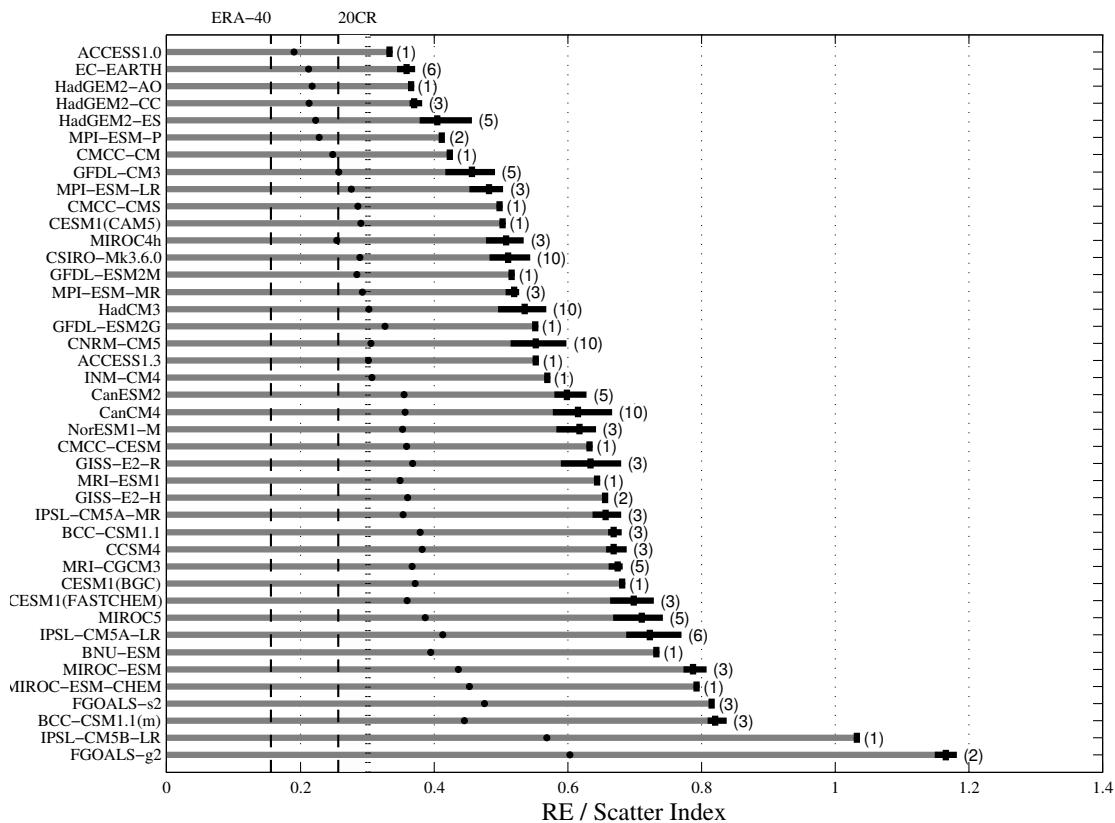


Figura 0.17: GCMs de CMIP5 ordenados por la habilidad para modelar situaciones sinópticas (habilidad mayor, SI menor). El RE medio está representado por un punto negro

simulaciones 20C3M. Los otros seis: HadGEM2-ES, MPI-ESM-P, CMCC-CM, GFDL-CM3, MPI-ESM-LR y CMCC-CMS presentan valores de SI un poco mayores, pero RE es aún menor que 0.3. Hay que tener en cuenta que, solo dos modelos CMIP5: IPSL-CM5BLR ($SI = 1.03$, $RE = 0.57$) y FGOALS-g2 ($SI = 1.17$, $RE = 0.60$), muestran un SI mayor que uno.

Las diferencias entre simulaciones de un mismo modelo son un orden de magnitud menor que las diferencias entre modelos. Esto muestra que la variabilidad interna está bien considerada mediante el uso de un periodo de 30 años. Por otra parte, los resultados son cualitativamente similares para los dos indicadores (SI y RE) que se han utilizado para analizar la representación de las situaciones sinópticas, lo que indica que el desempeño del modelo es consistente para las dos medidas. Los valores medios de ambos índices revelan una mejora en los modelos CMIP5 ($SI = 0.61$, $RE = 0.34$) con respecto al conjunto de los modelos analizados de CMIP3 y ENSEMBLES ($SI = 0.76$, $RE = 0.41$). Además, los valores de RE son más pequeños para los modelos CMIP5 que para los modelos CMIP3 con valores similares de SI , lo que indica que los modelos CMIP5 han mejorado su capacidad para detectar situaciones sinópticas con baja frecuencia relativa.

0.4.4.2. Habilidad de los GCMs para modelar la variabilidad climática

Los frecuencias de los GCMs también se han evaluado estacionalmente. Las calificaciones de *SI* de ERA-40 y 20CR son muy similares en el otoño (0.34 vs. 0.35, respectivamente) y el invierno (0.34 vs 0.39), siendo las diferencias ligeramente mayores en primavera (0.30 vs. 0.40). Las mayores diferencias se encuentran en verano (0.31 vs. 0.59). Los valores de *RE* no se incluyen debido a que varios WTs tienen cero ocurrencias en algunas estaciones.

Para los modelos de CMIP3 y ENSEMBLES el diagnóstico en primavera y otoño es análogo al anual excepto por diferencias menores. En ambas estaciones, la mayoría de los modelos muestran un desempeño muy similar con *SI* entre 0.5 y 1. Solo tres modelos en primavera y siete modelos de otoño muestran *SI* notablemente mayores. Por el contrario, en invierno y verano las diferencias son más grandes. En invierno algunos modelos de ENSEMBLES: EGMAM (*SI* = 0.76), EGMAM2 (*SI* = 0.71) y UKMO-HADCM3C (*SI* = 0.80) se comportan tan bien como los mejores modelos. FGOALS-G1.0 muestra resultados de baja calidad (*SI* = 3.70) en verano y por ello funciona mal en la escala anual. Por otro lado, CCSM3 y PCM sólo muestran bajo *SI* en verano, y presentan resultados peores en el resto de estaciones. Una observación similar ocurre con los modelos de la Commonwealth Scientific and Industrial Research Organisation (CSIRO), siendo el *SI* de CSIROmk35 y CSIROmk30, el primero y el tercero más bajos en esta estación. Para modelos de CMIP5 las estaciones que muestran discrepancias más grandes con respecto a la valoración global son también el invierno y el verano, siendo el diagnóstico de la primavera y el otoño similar a la evaluación global. Curiosamente, los modelos CMIP5 que proporcionan el peor diagnóstico en invierno son algunos de los mejores modelos en verano. Por ejemplo, el *SI* de CCSM4 en verano es sólo ligeramente mayor que el de 20CR. Por el contrario, IPSL-CM5B-LR y FGOALS-g2 son los modelos de rendimiento más pobre a escala anual y durante el verano, pero desempeñan bien en invierno. INM-CM4, el modelo con el tercer mayor *SI* en verano, es uno de los mejores modelos en las otras estaciones. El análisis estacional muestra que el desempeño de los modelos depende de la estación, especialmente en verano e invierno, lo que indica que, en algunos casos, los modelos más adecuados dependerán de los propósitos.

El análisis de la variabilidad interanual se ha basado en el índice *stdSI*. Como se muestra en la figura 0.18, en la que se ha mantenido el orden de los GCMs de las figuras anteriores, los valores *stdSI* de ERA-40 (*stdSI* = 0.17) y 20CR (*stdSI* = 0.21) son más parecidos que su *SI*. Los resultados de las simulaciones 20C3M (Figura 0.18a), muestran que UKMO- HadGEM2 (*stdSI* = 0.24) y ECHAM5/MPI-OM (*stdSI* = 0.27) proporcionan los resultados de mayor calidad, con *stdSI* inferior a 0.3, mientras que CNCM33 y GISS-ER son los que proporcionan resultados de menor calidad con *stdSI* mayores

de 0.6. Para las simulaciones históricas de los modelos de CMIP5 (Figura 0.18b) los valores de *stdSI* son ligeramente mejores que los de simulaciones 20C3M. Cinco modelos: ACCESS1.0, MPIESM-P, EC-EARTH, HadGEM2-CC y HadGEM2-ES tienen *stdSI* inferiores a 0.3. Por otra parte, no existen modelos con *stdSI* mayor de 0.6 y sólo dos modelos: IPSL-CM5BLR y FGOALS-g2 exceden 0.5. Los resultados obtenidos para la variabilidad interanual confirman los obtenidos a partir de la similitud de situaciones sinópticas, siendo los modelos de más alto y más bajo rendimiento los mismos para ambos análisis.

0.4.4.3. Consistencia de las proyecciones futuras

El análisis de las proyecciones futuras se hace de una manera diferente al análisis del clima del pasado. Las simulaciones históricas pueden ser comparadas con los datos de reanálisis, pero las proyecciones futuras solo pueden ser comparadas entre sí. El análisis de las proyecciones futuras se puede utilizar para detectar modelos con comportamiento anómalo pero no para determinar qué modelos son los mejores. Los resultados de la consistencia de las proyecciones futuras se han sintetizado en la figura 0.19 para los tres escenarios SRES considerados (B1, A1B y A2) y en la figura 0.20 para los cuatro RCPs (RCP2.6, RCP4.5, RCP6.0 y RCP8.5). Para cada escenario, las magnitudes de cambio de la frecuencia de las situaciones sinópticas y las magnitudes de cambio en la variabilidad interanual se muestran durante tres períodos futuros. En cada caja, la marca central es la mediana y los bordes son el primer y el tercer cuartil. Los puntos rojos numerados representan modelos con magnitudes de cambio fuera del rango definido por $Q1 - 1.5(RIC)$ y $Q3 + 1.5(RIC)$.

Para los escenarios SRES, se muestran solo los períodos medio y largo plazo porque pocas simulaciones cubren el corto plazo. Para estos escenarios, INM-CM3 (19), GISS-ER (23) y CNRM-CM3 (25) muestran magnitudes de cambio notablemente altas para algunas combinaciones de escenario, indicador y periodo de tiempo. Para CMIP5 (Figura 0.20) se muestra también el corto plazo porque hay información para el siglo XXI completo. En este caso hay dos grupos diferentes de modelos con magnitudes anómalas de cambio. HadGEM2-AO (03), GFDL-CM3 (08), IPSL-CM5A-MR (28), IPSL-CM5A-LR (35), MIROC-ESM-CHEM (38), FGOALS-s2 (39) y FGOALS- g2 (42), muestran en varios casos altas magnitudes de cambio, mientras que, MPI-ESM-MR (15), INM-CM4 (20), MRI-CGCM3 (31) y BCC-CSM1.1 (m) (40) muestran en algunos casos bajas magnitudes de cambio. Los resultados indican que las magnitudes de cambio y su dispersión son más grandes en el largo plazo que en el corto plazo y para escenarios de altas emisiones, por ejemplo, A2 y RCP8.5, que para escenarios de bajo nivel de emisiones. Es interesante observar la relación entre la capacidad de los modelos para reproducir el clima actual

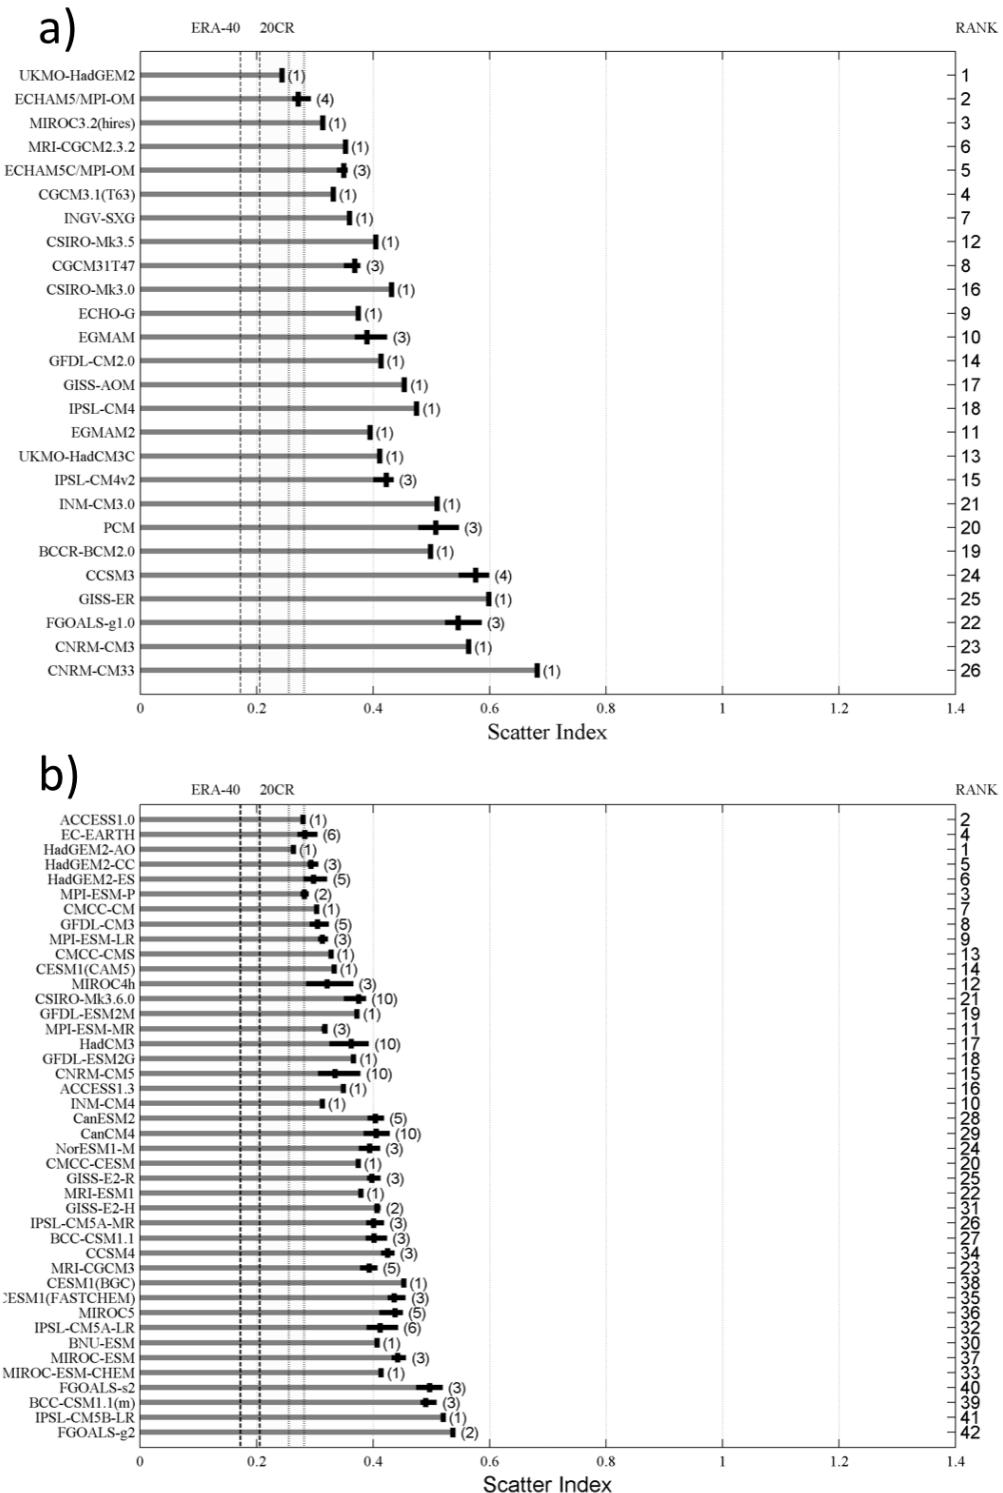


Figura 0.18: Habilidad de los GCMs de CMIP3 y ENSEMBLES (a) y CMIP5 (b) para simular la variabilidad interanual (habilidad mayor, *SI* menor)

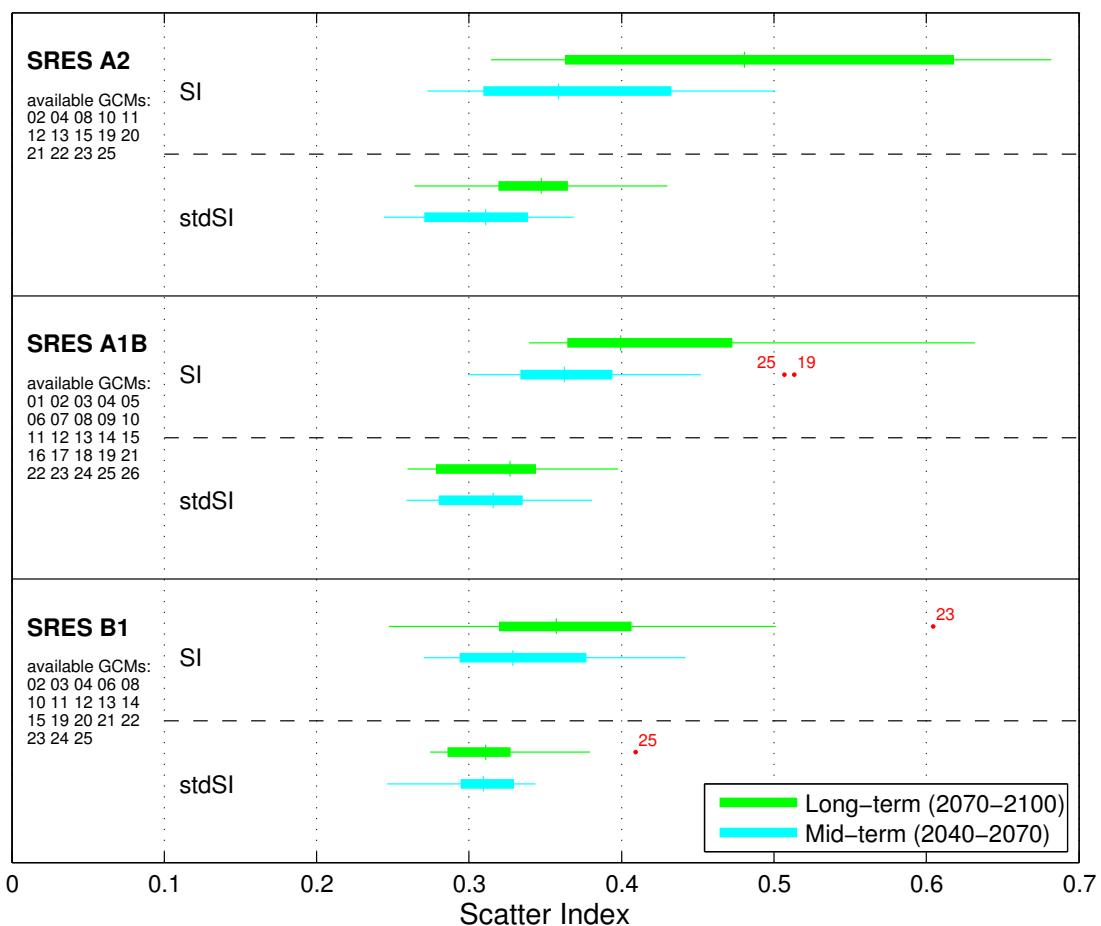


Figura 0.19: Diagramas de cajas de los dos indicadores de consistencia para los escenarios B1, A1B y A2

(números mayores, peor desempeño) y la consistencia de sus simulaciones futuras. Los modelos con magnitudes anómalas del cambio pertenecen en su mayoría al grupo de modelos con poca habilidad en el periodo de referencia. En consecuencia, la dispersión se reduce cuando se consideran modelos con alta habilidad en el periodo de referencia. Por ejemplo, se obtiene una reducción del 30 % en la dispersión considerando sólo la mitad superior de los modelos; aquellos con mejor desempeño. Sin embargo, algunos modelos que funcionan razonablemente bien en el pasado reciente presentan magnitudes anómalas de cambio. Esto puede indicar que estos modelos no pueden simular la variabilidad climática asociada a cambios más grandes en los forzamientos durante el siglo 21.

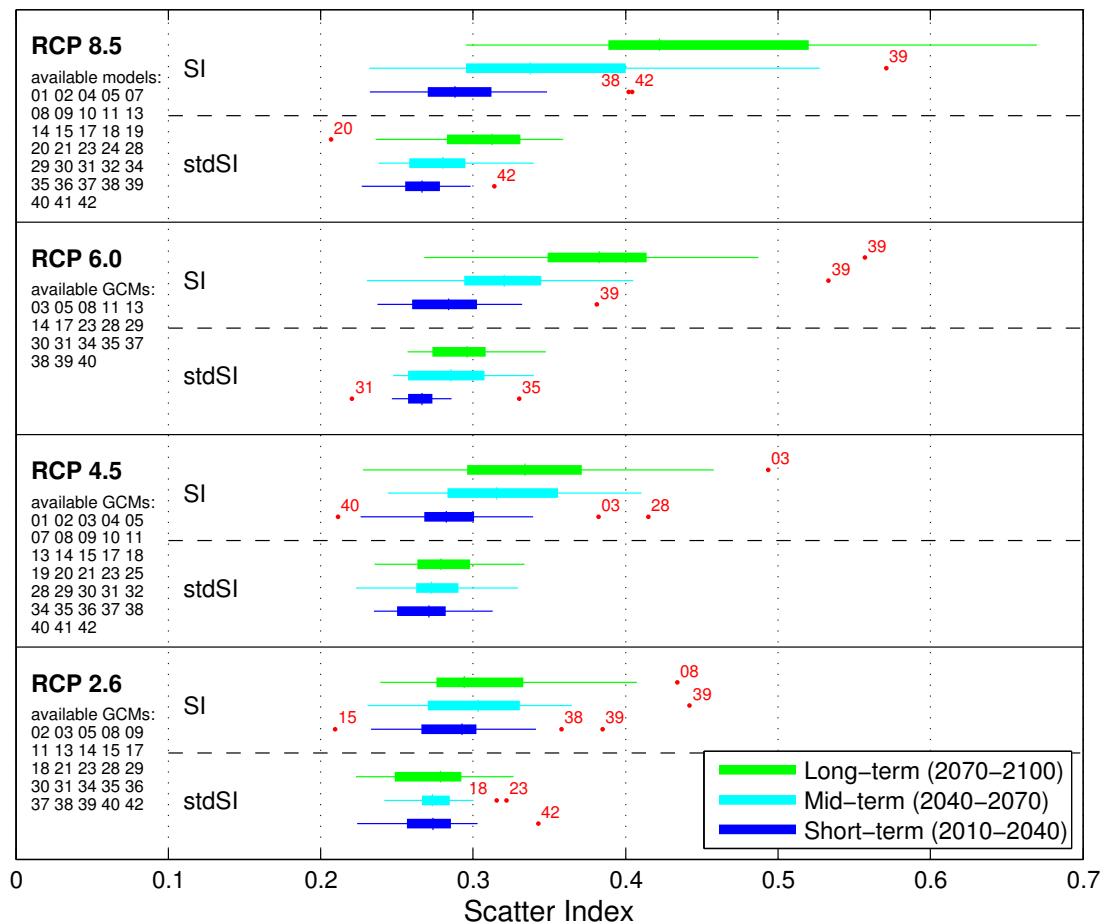


Figura 0.20: Diagramas de cajas de los dos indicadores de consistencia para los escenarios RCP2.6, RCP4.5, RCP6.0 y RCP8.5

0.5. Proyecciones estadísticas multi-modelo del oleaje en Europa

Este apartado constituye un resumen del artículo Perez et al. (2015): Perez, J., Menendez, M., Camus, P., Mendez, F. J., Losada, I. J. (2015). Statistical multi-model climate projections of surface ocean waves in Europe. Ocean Modelling, in press <http://doi.org/10.1016/j.ocemod.2015.06.001>

0.5.1. Introducción

El oleaje futuro a menudo se estima extrapolando tendencias obtenidas a partir de datos históricos (e.g. Menéndez et al. 2008). Sin embargo, este enfoque no parece apropiado para cambios a largo plazo en el siglo XXI. Los incrementos en las concentraciones de gases de efecto invernadero pueden conducir a cambios que no son capturados en las tendencias históricas. En este contexto, los Modelos Climáticos Globales (GCMs) se han convertido en valiosas herramientas para estimar los cambios en el clima para diferentes escenarios futuros. Sin embargo, los GCMs no simulan el oleaje. Además, la resolución de campos de viento superficiales derivados de GCMs es a menudo demasiado grosera para forzar modelos de oleaje regionales.

Hay dos enfoques diferentes para generar proyecciones regionales de oleaje. El downscaling dinámico, basado en la anidamiento de modelos numéricos, es quizás la metodología más utilizada (e.g. Erikson et al. 2015; Hemer et al. 2013b; Mori et al. 2010; Semedo et al. 2013). Un enfoque alternativo es el downscaling estadístico. Laugel et al. (2014) demostraron que las proyecciones estadísticas pueden reproducir el oleaje tan bien como las proyecciones dinámicas. Wang et al. (2009) encontraron similitudes sustanciales entre ambos enfoques en los cambios futuros proyectados; sin embargo, los métodos estadísticos obtuvieron mejores resultados en la reproducción del clima medio y la variabilidad interanual observada. Por otra parte, los enfoques dinámicos son muy costosos computacionalmente. Por lo tanto, la mayoría de los estudios de proyecciones de oleaje dinámicos se basan en solo uno o unos pocos GCMs (e.g. Laugel et al. 2014; Mori et al. 2010; Semedo et al. 2013). Por el contrario, los enfoques estadísticos son mucho más baratos, por lo que permiten estudiar un gran número de simulaciones. El análisis de múltiples GCMs y escenarios climáticos es muy importante porque las incertidumbres en cascada pueden provocar que los resultados de dos simulaciones sean muy diferentes. Además, un ensemble grande proporciona proyecciones más sólidas y una medida de la incertidumbre (Gleckler et al. 2008).

En este trabajo, se presenta un downscaling estadístico de oleaje multivariado basado en tipos de tiempo (WTs). Este método se basa en un marco de downscaling estadístico capaz de reproducir la variabilidad estacional e interanual del oleaje (Camus et al. 2014b) y define un conjunto óptimo de modelos teniendo en cuenta la habilidad de los GCMs (Perez et al. 2014b). La aplicación de este método se demuestra a través de proyecciones climáticas de oleaje en Europa con una resolución espacial de hasta 0.125° (menos de 15 km de la costa).

0.5.2. Datos

0.5.2.1. Datos atmosféricos históricos

Los reanálisis están diseñados para proporcionar representaciones globales del sistema atmósfera - océano - superficie terrestre - hielo marino durante un largo período histórico de tiempo. CFSR (Climate Forecast System Reanalysis, Saha et al. 2010) es un reanálisis de gran calidad debido a su alta resolución y avanzadas técnicas de asimilación de datos. A partir de 2011, CFSR ha sido continuado por el modelo operacional CFSv2 (Climate Forecast System Version 2, Saha et al. 2014). Utilizamos vientos superficiales, cobertura de hielo, y campos de presión a nivel del mar de CFSR y CFSv2. Los datos de CFSR y CFSv2 están disponibles a partir de 1979 con resolución horaria. Los vientos y la cobertura de hielo globales, con resolución horizontal de $\sim 0.3^{\circ}$ ($\sim 0.2^{\circ}$ para CFSv2), fueron utilizados como forzar una reconstrucción numérica de oleaje. Los campos de SLP, con una resolución horizontal de 0.5° , se utilizaron para crear una clasificación de WTs.

0.5.2.2. Datos de oleaje históricos

En este estudio, se ha generado una reconstrucción numérica de oleaje de 1979 a 2013 con resolución horaria para disponer de datos históricos de oleaje. En esta reconstrucción se ha utilizado el modelo de oleaje WAVEWATCH III (versión 4.18, Tolman 2014) en una configuración multigrid. El multigrid se compone de varias mallas regulares con anidamiento bidireccional: una malla global (1° latitud x 1.5° de longitud), una malla que cubre el Océano Atlántico (0.5° x 0.5°) y una malla en la zona cercana a la costa europea (0.125° x 0.125°). Las pequeñas mallas que cubren los archipiélagos de Cabo Verde, Canarias y Azores (0.125° x 0.125°) se utilizan para mejorar la modelización de los efectos de sombra que generan esas islas. Los vientos y la cobertura de hielo fueron interpolados a partir de datos CFSR y CFSv2. La batimetría, la máscara tierra-mar, y las

mallas de obstrucciones para cada malla se obtuvieron utilizando el software automatizado de generación para WAVEWATCH III (Chawla and Tolman 2008). Utilizamos este software con batimetría etopo1 (Amante and Eakins 2009) y líneas de costa de GSHHG (Global Self-consistent Hierarchical High-resolution Geography Database, Wessel and Smith 1996).

Los espectros del oleaje se definieron en WAVEWATCH III por 32 frecuencias y 24 direcciones. WAVEWATCH III fue implementado utilizando la parametrización TEST451 (Ardhuin et al. 2010) debido a que las alturas de ola obtenidas con TEST451 (e.g. Rasle and Ardhuin 2013) tienen sesgos más pequeños que las obtenidas con parametrizaciones más antiguas. La validación con boyas y datos de altímetría (no mostrada) confirmó un buen acuerdo de esta reconstrucción con las observaciones. Por ejemplo, la comparación entre alturas de ola significante medidas por altímetro y modeladas muestra una correlación de 0.95 y un índice de dispersión de menos de 0.2 en la malla europea. El mejor acuerdo se encuentra en el Océano Atlántico, mientras que el peor acuerdo se encuentra en algunas cuencas semicerradas, como el Mar de Alborán y el Mar Adriático.

0.5.2.3. Datos atmosféricos de Modelos Climáticos Globales

Analizamos campos de SLP diarios de GCMs del CMIP5 para estudiar los cambios en la circulación atmosférica. Los datos de los experimentos históricos en 1975-2004 se utilizan para caracterizar recientes condiciones pasadas. Los datos de los RCPs (Representative Concentration Pathways, Moss et al. 2010) en 2010-2100 se utilizan para representar las condiciones futuras. Estos periodos de tiempo fueron elegidos porque se superponen con los datos disponibles de la mayoría de GCMs. Los tres RCPs seleccionados incluyen un escenario de mitigación que lleva a un nivel muy bajo de forzamiento radiativo (RCP2.6), un escenario medio de estabilización (RCP4.5) y un escenario de altas emisiones (RCP8.5) que conduce a altos niveles de concentración de gases de efecto invernadero (van Vuuren et al. 2011). Se analizan todas las simulaciones disponibles (en el momento en que se llevó a cabo este trabajo) para estos escenarios. Esto dio lugar a un total de 42 GCMs con 137 simulaciones históricas, 56 simulaciones RCP2.6, 98 simulaciones RCP4.5 y 72 simulaciones RCP8.5.

0.5.3. Métodos

0.5.3.1. Marco metodológico

Esta metodología requiere tres fuentes de datos: datos de oleaje históricos, datos atmosféricos históricos y datos atmosféricos simulados por GCMs. En primer lugar, se

realiza una clasificación automatizada de WTs utilizando los datos atmosféricos históricos de un reanálisis. Esta clasificación se utiliza para dos propósitos: 1) cada WT se vincula a las condiciones históricas de oleaje correspondientes de una reconstrucción histórica de oleaje con el fin de obtener una relación estadística empírica entre la circulación atmosférica y el oleaje; 2) las frecuencias históricas y futuras de cada WT se analizan para seleccionar el mejor ensemble de GCMs y proyectar los cambios en la frecuencia de los WTs para ese ensemble. Por último, las proyecciones climáticas de oleaje se obtienen aplicando la relación estadística entre las condiciones atmosféricas y el oleaje a los datos atmosféricos de los GCMs.

0.5.3.2. Clasificación de tipos de tiempo

Existen varias metodologías para hacer una clasificación de WTs. Una clasificación puede ser subjetiva (e.g. Lamb 1972) o en base a algoritmos automatizados. En este trabajo, se aplica una clasificación de WTs automatizada. La clasificación de WTs se basa en dos pasos principales: la definición del predictor y la técnica de agrupación.

El predictor se construye con los campos de SLP de CFSR y CFSv2 durante el periodo de 1979 a 2013. Las resoluciones espaciales y temporales de los GCMs son demasiado groseras para permitir una comparación directa con el reanálisis atmosférico. Por lo tanto, los campos de SLP diarios obtenidos de los datos de reanálisis horarios fueron interpolados a una malla de $1^\circ \times 1^\circ$. La energía del oleaje en las cuencas oceánicas se propaga miles de kilómetros durante varios días (e.g. Snodgrass et al. 1966). En consecuencia, las condiciones atmosféricas durante el tiempo de propagación de las olas han sido tenidas en cuenta (Camus et al. 2014a). Por ello, el predictor que representa un día está compuesto por el promedio de SLP y gradientes de SLP al cuadrado durante ese día y los dos días anteriores. Los gradientes de SLP al cuadrado, relacionados con los vientos geostróficos, se incluyen porque han demostrado ser un buen predictor de las olas oceánicas (Wang et al. 2014). Los límites espaciales del predictor deben incluir la zona donde se producen los procesos más importantes de generación/dispersión del oleaje. Dado que el objetivo de este trabajo es caracterizar proyecciones de oleaje regionales en Europa, se han comprobado los mapas ESTELA (Perez et al. 2014a) en los lugares más al norte, sur, este y oeste de las costas europeas para seleccionar un área del predictor desde 20°N a 80°N y desde 60°W a 50°E .

La técnica de agrupación se describe en Camus et al. (2014b) y se basa en tres pasos: En primer lugar, se aplica un análisis de componentes principales al predictor con el fin de reducir la dimensionalidad de los datos. Los datos proyectados en la base de componentes principales (Principal Components, PCs) se clasifican en orden creciente

de varianza explicada. La dimensionalidad de los datos se reduce manteniendo sólo las PCs que explican el 95 % de la varianza. En segundo lugar, el predictor en el espacio de las funciones empíricas ortogonales (Empirical Orthogonal Functions, EOFs) se agrupa utilizando el algoritmo k-medias. Los predictores diarios se agrupan en N grupos que minimizan la distancia total dentro de los grupos. Cada grupo está formado por campos predictores similares y representado por un centroide que se define como la media de estos campos. Finalmente, los WTs se disponen en una cuadrícula que minimiza las diferencias entre WTs contiguos.

Los campos predictores diarios se agrupan en ciertos patrones de circulación atmosférica. El principal objetivo de esta clasificación es representar correctamente la relación empírica entre la circulación atmosférica y el oleaje a lo largo de las costas europeas. Este objetivo requiere un gran número de patrones de circulación atmosférica debido a que WTs similares pueden generar oleajes muy diferentes en lugares específicos, especialmente en las zonas afectadas por una batimetría compleja y la costa. Después de las pruebas preliminares, se ha determinado que $N = 100$ WT cumple el compromiso entre un número significativo de WTs y un número mínimo de datos por grupo. Las proyecciones de oleaje no son especialmente sensibles a pequeñas diferencias en el número de los WTs, sin embargo, un número más pequeño de WTs no es suficiente para estimar tanto los patrones espaciales como sus intensidades, y un mayor número de WT puede resultar en algunos WTs sin datos. La figura 0.21 muestra los 100 WTs, representados por el promedio 3-diario de los campos de SLP, organizados en una cuadrícula bidimensional. El método de agrupación identifica diferentes sistemas de bajas presiones: los patrones sinópticos en la esquina superior derecha de la red (e.g. WTs 51, 61, 71) se corresponden con centros de bajas presiones localizados en la región polar; los patrones en el medio de la red (e.g. WTs 46, 56, 57) se corresponden con centros de bajas presiones situados hacia el sur; y los patrones sinópticos más suaves se encuentran alrededor del WT 38.

0.5.3.3. Técnica de downscaling

La clasificación de WTs descrita en el apartado anterior se puede utilizar para vincular las condiciones atmosféricas (predictor) al oleaje (predictando). En este trabajo, cada WT está vinculado al oleaje multivariado de una reconstrucción numérica de oleaje de 1979 a 2013. El enlace se deriva mediante la asociación del estado del mar horario, es decir, parámetros como la altura de ola significante (H_s) y el periodo medio espectral de segundo orden (T_{02}), con el WT que ocurre en el mismo día. La distribución de probabilidad de un determinado parámetro de estado de mar para cada WT se define asociando los estados de mar horarios con los campos predictores diarios correspondientes a ese WT. La distribución de probabilidad total se define como la suma de la probabilidad

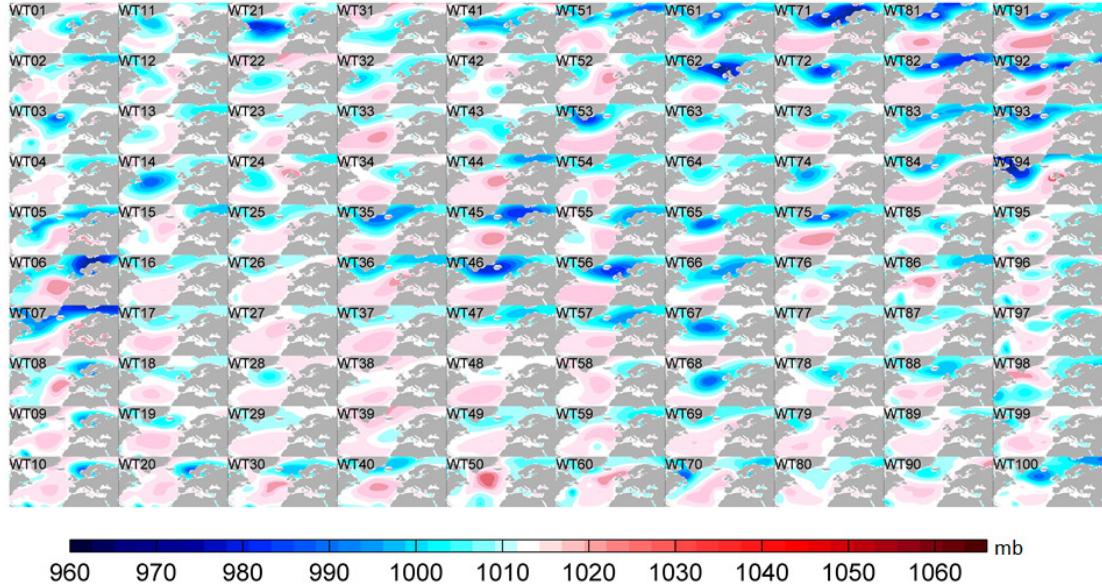


Figura 0.21: Los 100 tipos de tiempo representados por los campos medios 3-diarios de SLP (mb)

de ocurrencia de cada WT multiplicada por su distribución asociada. Una descripción detallada de este procedimiento y la validación en una localización en Irlanda y otra en España se presenta en Camus et al. (2014b).

La figura 0.22 muestra la H_s media y el T_{02} medio en el Atlántico Norte asociados con cada WT. Comparando las Figuras 0.21 y 0.22, la relación predictor-predictando se puede entender fácilmente. La posición de los centros de baja presión se refleja en el patrón espacial de H_s y T_{02} . Por ejemplo, los WTs 51, 61 y 71 generan olas muy energéticas a lo largo de las costas de Noruega e Inglaterra, mientras que los WTs 46 y 56 están asociados con las olas más grandes a lo largo de las costas francesas y españolas. El efecto de los diferentes patrones de bajas presiones también puede ser detectado en los campos de T_{02} . Cabe destacar que las borrascas más profundas están asociadas con períodos y alturas de ola más grandes.

La relación entre el predictor y predictando se puede extrapolar al futuro si asumimos la hipótesis de estacionariedad, es decir, las frecuencias relativas de los WTs pueden variar con el tiempo, pero la relación predictor-predictando permanece constante. Con este supuesto, la distribución $f(y)$ de diferentes variables (e.g. H_s) en un nuevo periodo de tiempo se puede obtener de la siguiente manera:

$$f(y) = \sum_{i=1}^N p_i f_i(y), \quad (0.17)$$

donde p_i es la frecuencia relativa del WT i ésimo durante el nuevo periodo, $f_i(y)$ es la distribución condicional del predictando para el WT i ésimo y N es el número de WTs. Las nuevas frecuencias (p_i) se calculan mediante la asignación de cada situación atmosférica al WT más parecido en el espacio de las EOFs.

0.5.3.4. Selección del ensemble de modelos climáticos globales

Las simulaciones históricas y futuras de los GCMs de CMIP5 se proyectan en la clasificación de WTs y se evalúa su climatología. La proyección se realiza después de interpolar los resultados de cada modelo a una cuadrícula $1^\circ \times 1^\circ$ común. Se han seguido la metodología e índices propuestos por Perez et al. (2014b) para analizar la fiabilidad de los diferentes GCMs. En esta metodología se analizan tres factores: 1) la habilidad de los GCMs para reproducir situaciones sinópticas históricas, 2) la habilidad de los GCMs para reproducir la variabilidad climática histórica (interanual y estacional), y 3) la consistencia de los GCMs en proyecciones del siglo XXI.

Los resultados de este análisis se resumen en la Tabla 5.1 de Perez et al. (2014b). Con el fin de examinar una amplia gama de procesos estudiamos ocho índices diferentes: SI , RE , $stdSI$, SI_{DJF} , SI_{MAM} , SI_{JJA} , SI_{SON} y *consistency*. Cuando hay varias simulaciones disponibles, se considera el valor medio del índice. La habilidad de reproducir situaciones sinópticas históricas y la variabilidad del clima se estudió mediante la comparación de los GCMs y CFSR durante el periodo de control de 1979 a 2004. Este periodo se eligió porque CFSR comienza en 1979 y la mayoría de las simulaciones históricas de GCMs terminan en 2005. El índice de consistencia analiza la magnitud de los cambios entre el experimento histórico para el periodo de referencia (1975-2004) y los RCPs para tres periodos de treinta años durante el siglo XXI (2010-2039, 2040-2069 y 2070-2099).

Dada la variabilidad entre los GCMs, los resultados de la evaluación de los GCMs se utilizan para generar un ensemble reducido. Se han definido umbrales para los ocho índices estudiados. Los GCMs que superan cualquiera de esos umbrales se excluyen del ensemble reducido. Los umbrales seleccionados para todos los índices (excepto *consistency*) son el valor medio del índice más una desviación estándar. Para *consistency*, se consideran dos umbrales, el primer cuartil menos 1.5 veces el rango intercuartílico (RIC) y el tercer cuartil más 1.5 RIC. El ensemble se genera simplemente promediando las frecuencias relativas de los GCMs individuales. El ensemble reducido obtenido utilizando estos umbrales se compone de 17 de los 42 modelos iniciales. Este ensemble ofrece resultados con buen acuerdo con la climatología histórica y de gran consistencia. Por lo tanto, es razonable suponer que las predicciones futuras basadas en este ensemble serán más fiables que las producidas a partir de un solo GCM o un conjunto sin filtrar. Es importante

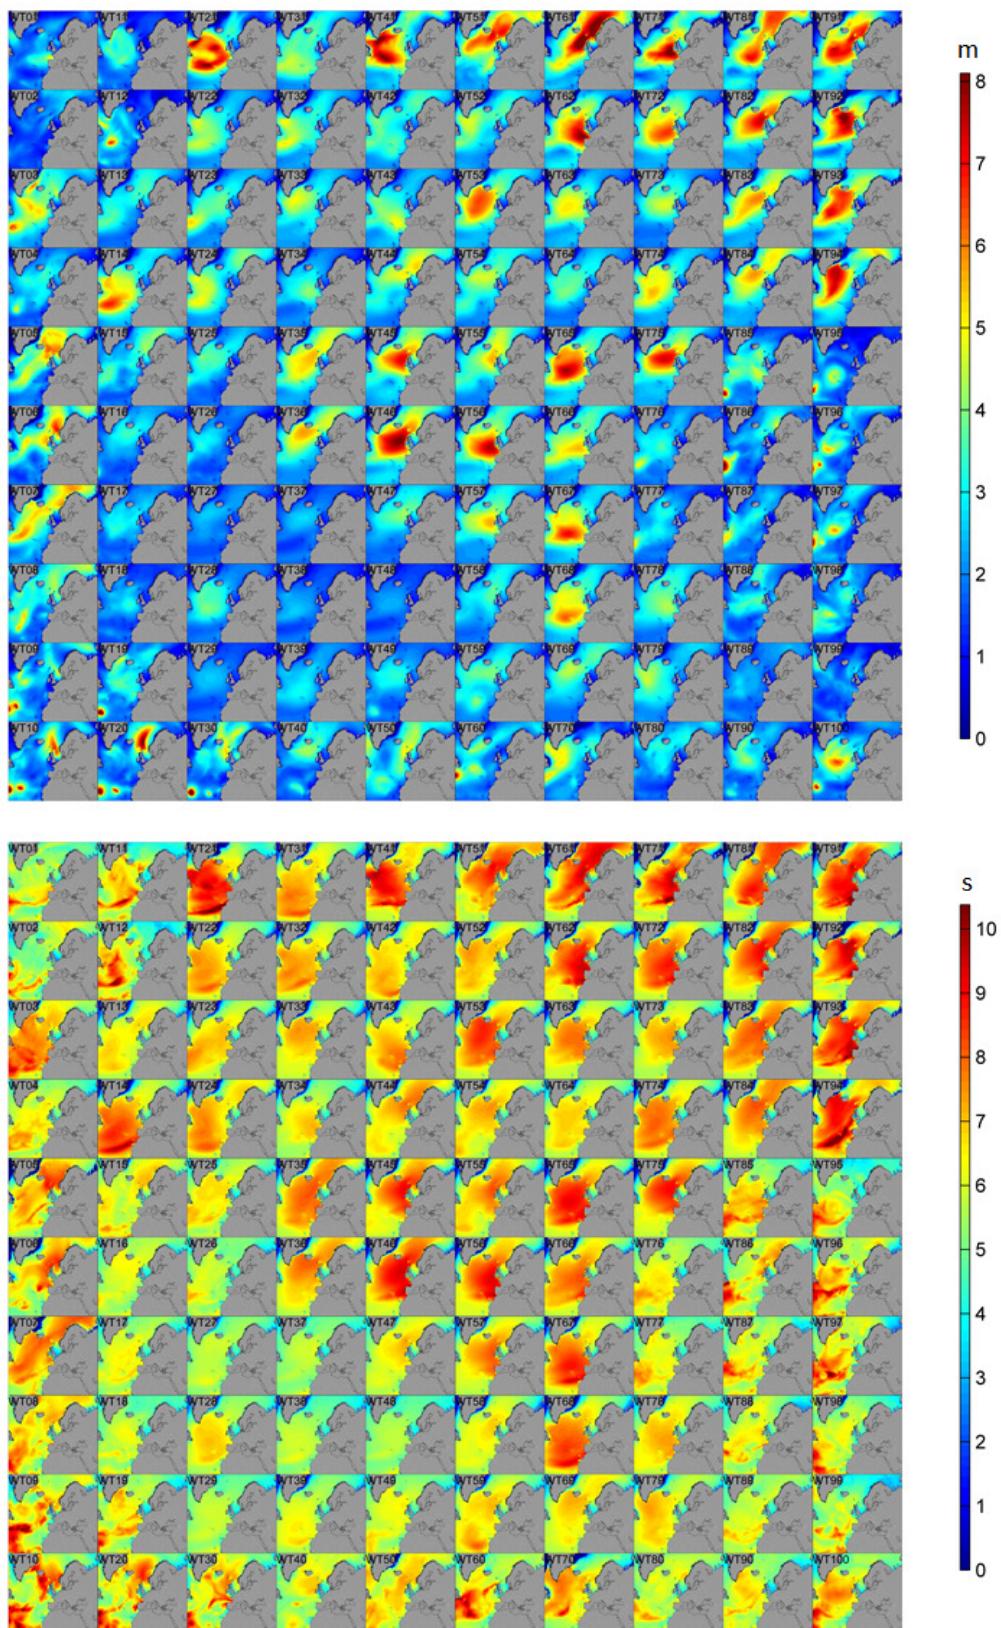


Figura 0.22: H_s , en metros (superior) y T_{02} , en segundos (inferior) asociados a cada tipo de tiempo

señalar, sin embargo, que el ensemble podría especificarse de manera diferente de acuerdo a necesidades específicas. Por ejemplo, el uso de todos los GCMs disponibles puede dar una mejor medida de la variabilidad inter-modelo. Las frecuencias obtenidas a partir de CFSR y el ensemble reducido de GCMs son muy similares, pero se pueden encontrar diferencias de poca importancia. Por ejemplo, las frecuencias de los WTs 44, 45, 46 y 65, asociados con grandes olas, son subestimadas por el conjunto de GCMs.

0.5.4. Resultados

0.5.4.1. Cambios proyectados en los tipos de tiempo

La clasificación de WTs de CFSR se ha utilizado para analizar la circulación atmosférica histórica en Europa y predecir los cambios en la misma. Los cambios proyectados en la frecuencia relativa de los WTs durante siglo XXI se calculan para varios escenarios utilizando los datos de los GCMs. Se han analizado tres escenarios futuros (RCP2.6, RCP4.5 y RCP8.5) en tres periodos futuros (2010-2039, 2040-2069 y 2070-2099) respecto al periodo de referencia (1975-2004). Cada simulación se compara con su propia representación del periodo de referencia en el análisis de los cambios. La figura 0.23 muestra los patrones de cambio del ensemble con respecto al periodo de referencia para diferentes escenarios y periodos de tiempo. El patrón de los cambios es bastante consistente a través de escenarios y épocas. Sin embargo, los escenarios de altas emisiones conducen a cambios más intensos que los de escenarios de bajas emisiones y los cambios a largo plazo son más grandes que los cambios a corto plazo. Es notable un aumento en las frecuencias de un grupo de WTs en la parte inferior izquierda de la clasificación (e.g. 27, 36, 37, 47 y 57). Estos WTs corresponden a situaciones con gradientes suaves de SLP y olas pequeñas. También se puede ver una disminución en la frecuencia de WTs asociados con olas grandes (e.g. 45, 46, 55 y 56). Como resultado de estos cambios en la frecuencia de los WTs, se espera una intensificación del anticiclón de las Azores y una disminución del sistema de bajas presiones en Islandia. Estos cambios coinciden con los cambios proyectados en SLP reportados por Wang et al. (2014).

0.5.4.2. Cambios proyectados en el oleaje

La técnica de downscaling estadístico se aplica a las frecuencias de WTs de los GCMs para obtener cambios en el oleaje. Los cambios en el corto (2010-2039), medio (2040-2069) y largo plazo (2070-2099) se calculan con respecto al periodo de referencia (1975-2004). La figura 0.24 muestra cambios proyectados en la H_s media en el Atlántico Norte en una malla de 0.5°. Puede verse una disminución de H_s en todas las áreas excepto en el

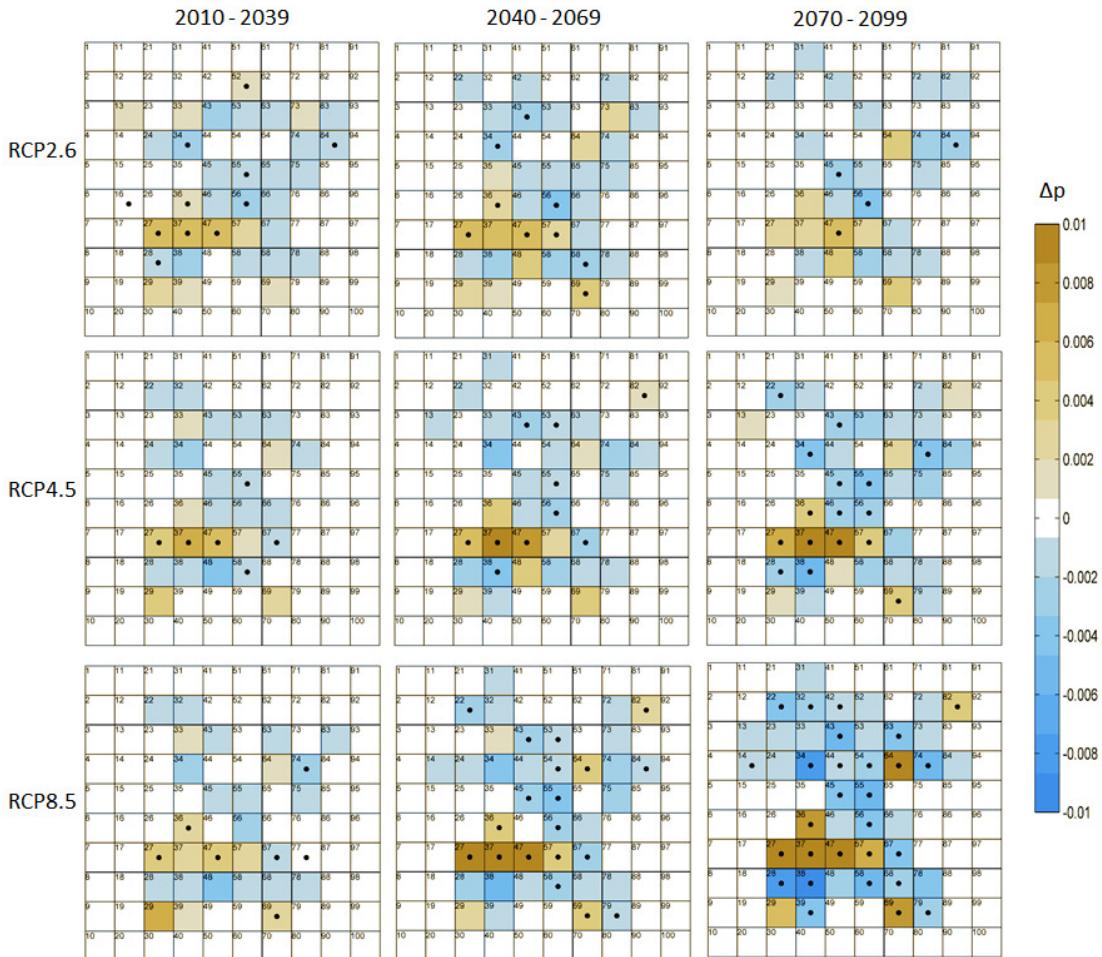


Figura 0.23: Cambios en frecuencia de los tipos de tiempo para diferentes escenarios (rcp2.6 superior, rcp4.5 medio y rcp8.5 inferior) y períodos de tiempo (2010-2039 izquierda, 2040-2069 medio y 2070-2099 derecha) respecto al período de referencia (1975-2004). Los puntos en los tipos de tiempo indican que más del 80 % de los modelos coinciden en el signo del cambio

norte, donde pueden encontrarse pequeños aumentos. El aumento en las costas noruegas se produce principalmente por la intensificación de WT82. Los aumentos en las costas de Groenlandia y Rusia deben ser analizados cuidadosamente, ya que se encuentran en áreas a menudo cubiertas por hielo, y por lo tanto pueden estar asociados con cambios en la cobertura de hielo. El comportamiento para todos los escenarios es similar en el corto plazo con pequeñas reducciones en la altura de las olas, pero difiere en el medio y largo plazo. En el largo plazo, especialmente para RCP8.5, las disminuciones de altura de ola son mucho más grandes, alcanzando valores de 10 cm en las latitudes alrededor de 40°N. Estos resultados son consistentes con estudios previos de Hemer et al. (2013a), Wang et al. (2014) y Mori et al. (2010), sin embargo, Wang et al. (2014) encontraron disminuciones más pequeñas cercanas a la costa y Mori et al. (2010) encontraron aumentos en el Mar Cantábrico. La figura 0.25 muestra los cambios en T_{02} en el Atlántico Norte con una resolución espacial de 0.5°. Los cambios en el periodo medio son consistentes

con los cambios en la altura de las olas. Hay una clara disminución de T_{02} , excepto en algunas zonas costeras del norte. Se encuentran disminuciones máximas de 0.1 s para RCP8.5 en el largo plazo. Las disminuciones en el periodo medio encontradas por Hemer et al. (2013a) son más grandes (>0.2 s) y se extienden más al norte y al sur.

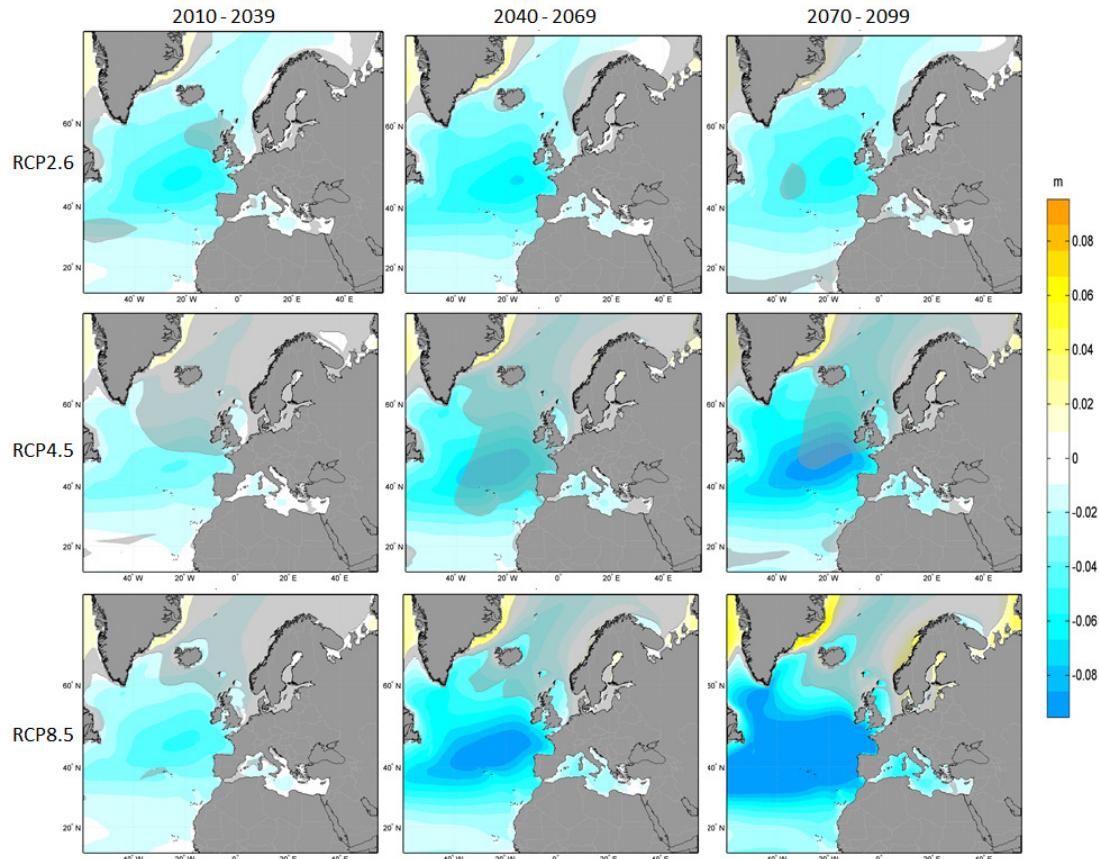


Figura 0.24: Cambios en H_s media en el Atlántico Noreste, en metros, para diferentes escenarios (rcp2.6 superior, rcp4.5 medio y rcp8.5 inferior) y periodos de tiempo (2010-2039 izquierda, 2040-2069 medio y 2070-2099 derecha) respecto al periodo de referencia (1975-2004). Las áreas sin sombreado indican que más del 80 % de los modelos coinciden en el signo del cambio

Aunque la altura de ola significante y el periodo medio son los parámetros más utilizados para describir la variabilidad del oleaje, el método también se puede aplicar para estimar cambios en variables agregadas (e.g. flujo de energía). La figura 0.26 muestra los cambios en el flujo medio de energía a lo largo de las costas europeas en una malla de 0.125° . Se puede ver una clara disminución de energía media tanto en la sub-cuenca del Atlántico Norte como en el Mar Mediterráneo. Los cambios en el Mediterráneo son menores que en el Atlántico en magnitud, pero son relativamente grandes. Como era de esperar, las disminuciones más grandes se producen para RCP8.5 en el largo plazo. El flujo de energía del oleaje es proporcional a $H_s^2 T_{02}$, por lo tanto, los cambios con el mismo signo en H_s y T_{02} son mucho más intensos en el flujo de energía de las olas. La variabilidad inter-modelo para H_s , T_{02} y el flujo de energía de las olas es mayor para RCP4.5 y RCP8.5

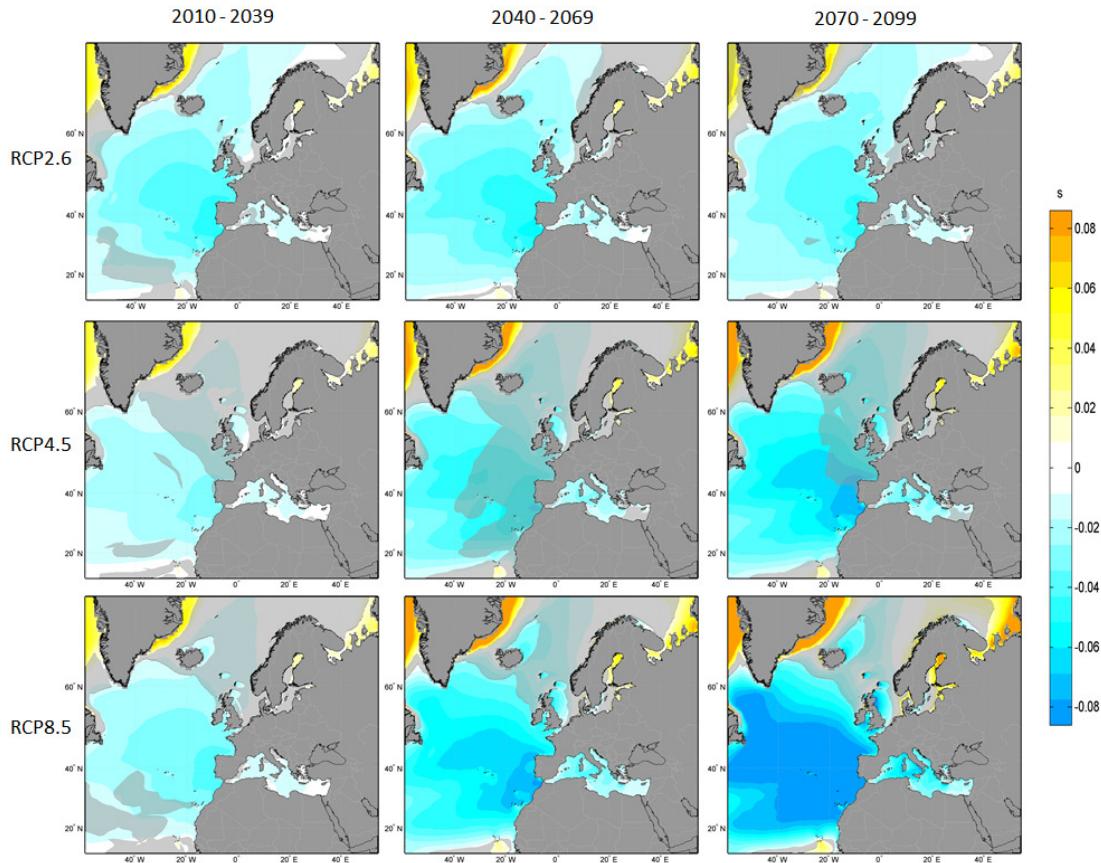


Figura 0.25: Cambios en T_{02} medio en el Atlántico Noreste, en segundos, para diferentes escenarios (rcp2.6 superior, rcp4.5 medio y rcp8.5 inferior) y períodos de tiempo (2010-2039 izquierda, 2040-2069 medio y 2070-2099 derecha) respecto al período de referencia (1975-2004). Las áreas sin sombreado indican que más del 80 % de los modelos coinciden en el signo del cambio)

que para RCP2.6, especialmente en las zonas del norte.

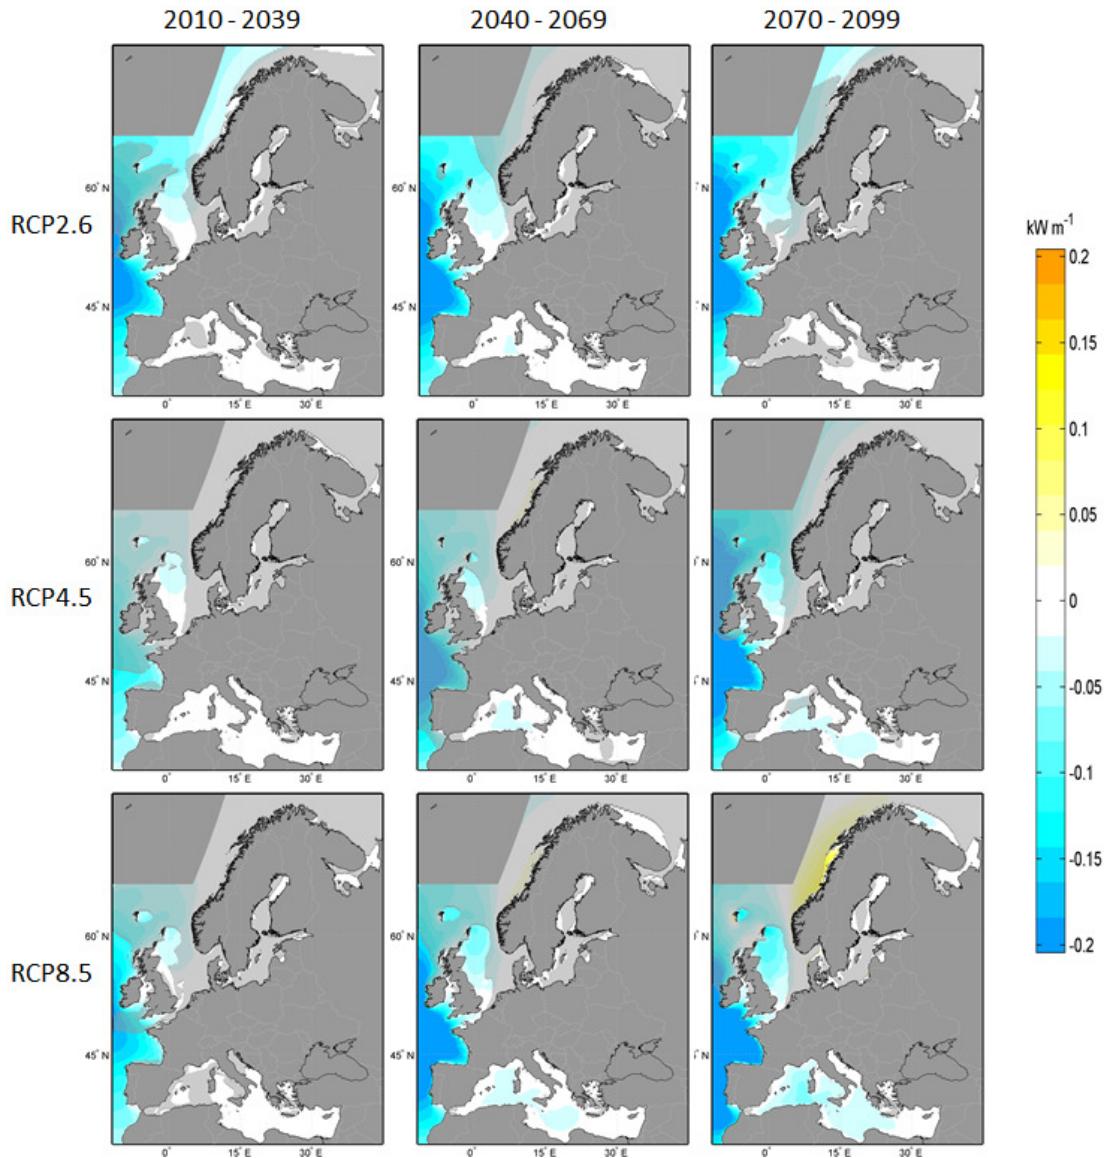


Figura 0.26: Cambios en flujo de energía medio en las costas europeas, en kW m^{-1} , para diferentes escenarios (rcp2.6 superior, rcp4.5 medio y rcp8.5 inferior) y períodos de tiempo (2010-2039 izquierda, 2040-2069 medio y 2070-2099 derecha) respecto al período de referencia (1975-2004). Las áreas sin sombreado indican que más del 80 % de los modelos coinciden en el signo del cambio)

0.6. Conclusiones y futuras líneas de investigación

0.6.1. Contribuciones principales

Este trabajo ha dado lugar a varias contribuciones en forma de cuatro artículos y más de diez presentaciones en conferencias. Algunas investigaciones relacionadas con esta tesis, pero no incluidas en ella, dieron lugar a dos artículos adicionales en los que el doctorando es coautor: Camus et al. (2014a) y Mentaschi et al. (2015). Camus et al. (2014a) busca índices de predictor óptimos para las condiciones de oleaje locales. Mentaschi et al. (2015) utiliza ideas derivadas del downscaling estadístico para mejorar el modelado de los obstáculos no resueltos en los modelos de oleaje. A continuación se muestran las conclusiones de los cuatro artículos principales.

0.6.1.1. Sumario de “ESTELA: un método para evaluar el origen y el tiempo de propagación de la energía del oleaje”

- ESTELA proporciona una representación sencilla y objetiva del oleaje que afecta a un área local basada en solo dos parámetros: el flujo de energía efectiva y el tiempo de viaje de la energía de las olas. Los requerimientos computacionales de ESTELA son muy bajos debido a que se basa en datos precalculados.
- Como no siempre hay datos espectrales disponibles, se ha propuesto un método sencillo para reconstruir el espectro completo a partir de estadísticos de particiones del espectro derivadas de modelos numéricos. Los espectros reconstruidos muestran un buen acuerdo con los espectros de salida directa y pueden ser útiles para una variedad de aplicaciones.
- Los resultados ofrecen una nueva herramienta para entender las zonas de generación de oleaje y la extensión de propagación de los swells en los océanos. Por ejemplo, los mapas ESTELA muestran los efectos de la representación de pequeñas islas en el oleaje en lugares remotos y la variabilidad temporal de las áreas de generación del oleaje.
- Los mapas ESTELA pueden utilizarse para caracterizar la huella del oleaje. Esto es muy útil para automatizar la definición del dominio espacial del predictor en un downscaling estadístico o para definir la extensión de las mallas de alta resolución en un downscaling dinámico.

0.6.1.2. Sumario de “Metodología de regionalización a partir de tipos de tiempo para clima marítimo”

- Se propone un esquema de regionalización estadística para proyectar oleaje en base a tipos de tiempo. La relación estadística se establece entre el predictor atmosférico, definido por los campos de SLP y los gradientes de SLP al cuadrado, y el oleaje local.
- El oleaje multivariado local puede ser caracterizado basándose en su relación física con las condiciones atmosféricas.
- La ventaja del método es el bajo tiempo de cálculo para caracterizar oleaje sin información de campos de viento y batimetría.
- La validación del modelo demuestra que es posible reproducir la variabilidad estacional e interanual de H_s , H_{p95} , T_m , $H_s^2 T_m$, y θ_{FE} . Por tanto, el método propuesto es una herramienta útil para la evaluación de impactos costeros.
- El modelo es fiable para producir reconstrucciones históricas largas. La SLP del reanálisis 20CR se ha utilizado para reconstruir oleaje local en el siglo 20, obteniendo estadísticos y tendencias de acuerdo con trabajos previos de otros autores (Bertin et al. 2013; Cox and Swail 2001; Wang et al. 2012).
- La actualización de la reconstrucción de oleaje en el invierno 2013-2014 muestra la aplicabilidad del método para predicción estacional.
- El modelo de dowscaling estadístico es una herramienta útil para obtener proyecciones de oleaje a partir de ensambles con un bajo coste computacional.

0.6.1.3. Sumario de “Evaluando la habilidad de los modelos climáticos globales de CMIP3 y CMIP5 en el Atlántico Noreste”

- Se ha desarrollado una metodología para analizar el desempeño de los GCMs en base a tipos de tiempo y métricas estadísticas. El método analiza la capacidad de los modelos para reproducir tres características: las climatologías sinópticas históricas, la variabilidad interanual y la consistencia de las proyecciones futuras. El uso de métricas estadísticas permite una estimación cuantitativa del desempeño de los GCMs.
- La calidad de los GCMs depende del área de estudio y la variable considerada. El desempeño de los GCMs también varía dependiendo de la estación analizada. Por lo tanto, la elección de los modelos más adecuados depende de los fines específicos (e.g. estudios que se centran en la altura de las olas extremas durante el invierno

o el deshielo durante el verano). Por el contrario, a partir del análisis llevado a cabo la importancia de la resolución atmosférica no está clara. Los modelos con resolución más alta no siempre son los mejores.

- Las pequeñas diferencias en los índices entre ejecuciones del mismo modelo indican que la metodología es robusta, ya que no se ve afectada considerablemente por la variabilidad natural del clima.
- Pueden observarse diferencias notables en las simulaciones futuras, incluso entre los modelos mejor valorados. Por lo tanto, se recomienda el uso de ensambles o grupos multimodelo ya que disminuyen los efectos de las simulaciones individuales, lo que nos permite tener una mayor confianza en los resultados.

0.6.1.4. Sumario de “Proyecciones estadísticas multi-modelo del oleaje en Europa”

- Se ha desarrollado y aplicado un downscaling estadístico regional de condiciones atmosféricas a oleaje multivariado en la sub-cuenca del Atlántico Norte y el Mar Mediterráneo. El método se basa en un enfoque de tipos de tiempo. Esto permite una fácil visualización de tipos de tiempo y el oleaje asociado. Las principales ventajas de este método son su bajo coste computacional y simplicidad. La fácil aplicación para ensambles permite el análisis multi-modelo para varios escenarios climáticos futuros. El método permite la detección de las condiciones atmosféricas sinópticas que se espera que sean más o menos frecuentes en el futuro. También se pueden analizar cambios futuros en el predictor responsable de los cambios en el oleaje.
- Los resultados muestran una disminución general de las alturas de ola y períodos medios en el Atlántico Norte y el Mediterráneo. Los descensos, que se encuentran en todos los escenarios analizados, son mayores para el largo plazo y escenarios de altas emisiones. Nuestros resultados coinciden con otros estudios basados en ensambles, tanto downscalings estadísticos (e.g. Wang et al. 2014) como dinámicos (e.g. Hemer et al. 2013a). Se pueden encontrar algunas diferencias entre este estudio y otros estudios basados en un solo GCM.
- La reducción tanto en altura de ola y periodo produce una clara disminución de la energía media del oleaje en las costas europeas. Esta reducción puede afectar a la rentabilidad de los proyectos de extracción de energía de las olas.

0.6.2. Futuras líneas de investigación

Las metodologías descritas en este trabajo permiten todavía avances en su desarrollo. La línea más importante de trabajo en este punto es desarrollar la técnica de downscaling para ser aplicable a escala global. El objetivo final es obtener proyecciones globales de oleaje a alta resolución basadas en un multi-modelo. Se identifican cuatro temas que requieren trabajo adicional: 1) la definición de la zona y el tiempo de duración de los predictores; 2) la selección de la variable del predictor; 3) el estudio de nuevos predictandos; y 4) la incertidumbre en las proyecciones climáticas de oleaje.

1. La metodología ESTELA ha hecho más fácil definir el área y periodo de tiempo de los predictores. Sin embargo, en lugares donde varias familias de oleaje están presentes, la elección de un predictor óptimo no es evidente. Por ejemplo, en Oregón (EE.UU.), las olas suelen llegar desde el hemisferio norte con un tiempo de viaje de una semana, pero en verano, las olas del hemisferio sur, con tiempos de viaje de dos o tres semanas se vuelven más importantes. Con un predictor de una semana las olas del sur no son capturadas correctamente y con dos o tres semanas los resultados en el hemisferio norte empeoran. Camus et al. (2014a) presenta el primer paso para resolver este problema; el predictor se compone de una parte local y una parte regional, que representan condiciones de mar de viento y mar de fondo respectivamente. Esta idea puede ser ampliada utilizando un predictor para cada componente del espectro.
2. La selección de SLP y gradientes de SLP al cuadrado como predictor ofrece buenos resultados en muchas regiones. En algunas áreas, sin embargo, la cobertura de hielo también es importante. Obviamente, la cobertura de hielo tiene que ser considerada para reconstruir el oleaje en lugares que a menudo están cubiertos por hielo; pero además, tiene que ser considerada para reconstrucciones en otros lugares, cuando pueda esperarse presencia de hielo en las áreas de generación o de propagación.
3. Las proyecciones de oleaje presentadas en el apartado 0.5 se centran en la altura de ola significante media, periodo medio y energía media de las olas. Sin embargo, los cambios en el espectro son más útiles para estudiar, por ejemplo, impactos en el transporte de sedimentos o la operatividad portuaria. Por otra parte, los cambios en los extremos pueden producir impactos más grandes que los cambios en el clima medio. La técnica de downscaling presentada ha demostrado ser útil para estudiar variabilidad espectral (Espejo et al. 2014) y extremos (Rueda et al. 2015). El trabajo futuro se propone estudiar cambios en el espectro y extremos para escenarios de cambio climático. La reconstrucción espectral presentada en Perez et al. (2014a) se debería mejorar en futuros trabajos.

4. La selección del ensemble de GCMs puede responder a una serie de necesidades.

En los downscalings dinámicos es necesario utilizar un pequeño número de modelos con el fin de reducir el coste computacional. En los downscalings estadísticos es posible utilizar todos los modelos disponibles, aunque algunos de ellos parecen ser mejores que otros. Con el fin de estudiar la incertidumbre, el análisis de un gran número de GCMs parece ser el mejor enfoque. Si las diferencias se deben a las incertidumbres en el clima o a los malos resultados de algunos modelos es una cuestión que sigue abierta.

Chapter 1

Introduction

1.1. Motivation

The intergovernmental panel on climate change (IPCC) defines the climate system as “the highly complex system consisting of five major components: the atmosphere, the hydrosphere, the cryosphere, the land surface and the biosphere, and the interactions between them”. Wave climate is the part of climate focused in the description of wind-waves.

Wave climate is governed by a series of phenomena that occur at very different spatial and temporal scales, mainly in the atmosphere, the hydrosphere and the cryosphere. These phenomena can be classified according to their space scales in global or macroscale (thousands of kilometers); regional or mesoscale (kilometers) and local or microscale (meters). These scales are interdependent; local climate is affected by regional climate, and regional climate is affected by global climate (Figure 1.1). For example, surface ocean waves can propagate over thousand of kilometers before reaching the coast. Coastal waves are the result of transformation processes during the propagation and local processes such as refraction and wave breaking. Also, the climatic evolution has to be studied according to different time scales such as seasonality, inter-annual variability and long-term changes. Furthermore, in order to analyze long-term changes, the study of historical trends has to be complemented with the study of the climate change. For the IPCC, the term “climate change” denotes a change in the state of climate over time, whether it is due to natural variability or as a consequence of human activity. This change must be identifiable (for example, by statistical analysis) following a change in the mean and/or the variability of its properties, and persist for a prolonged period, usually decades or longer periods. Little doubt exists about the importance of human policies in the evolution of climate. For example, increasing concentrations of greenhouse

gases are related to global warming and sea level rise. The anthropogenic influence on climate evolution can be studied through different socio-economic development scenarios (Figure 1.2).

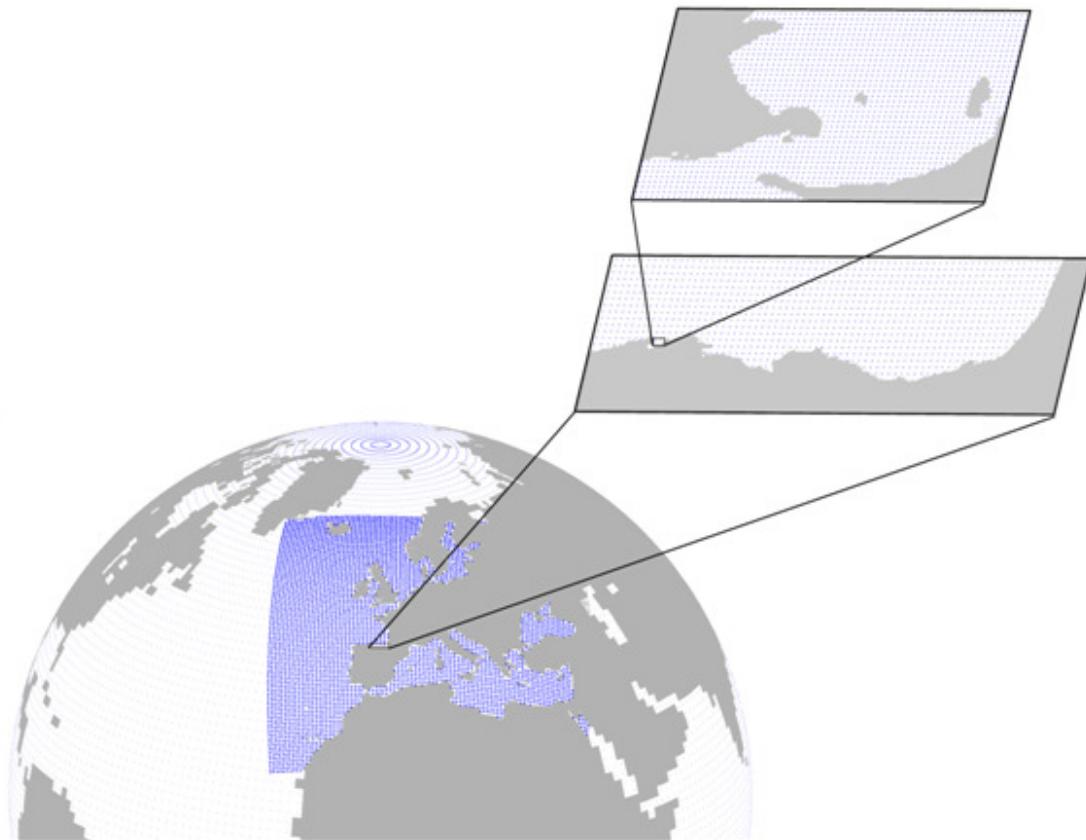


Figure 1.1: Representation of spatial domains (global, regional and local)

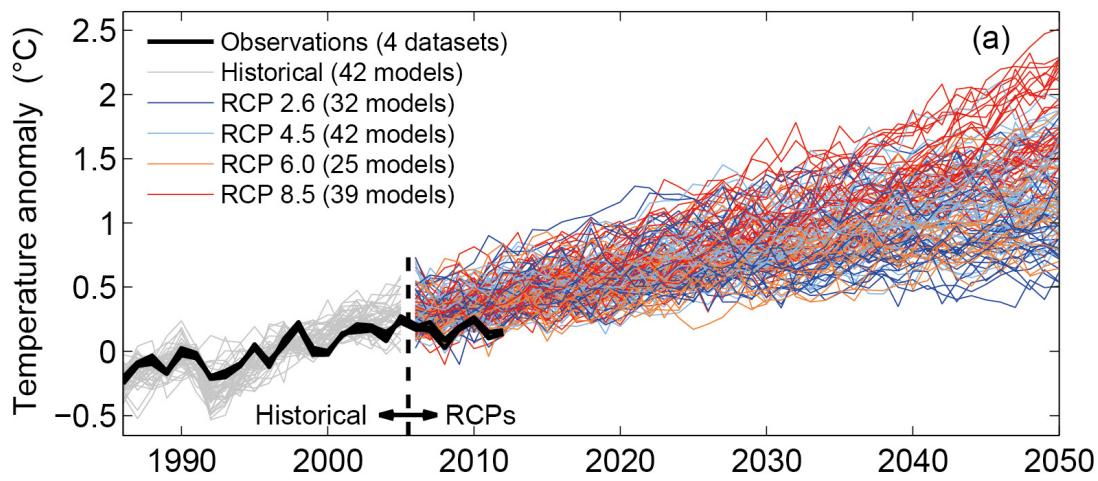


Figure 1.2: Simulations and projections of annual mean GMST (global mean surface air temperature) anomalies relative to 1986–2005. (Source: Figure 11.25a AR5 WGI)

This combination of phenomena produces local changes in wave climate. For example, an increase in wave energy reaching the coast could produce beach erosion, reductions in the operation of ports, increased overtopping in coastal structures and alterations in

intertidal communities. Knowledge of these variations is of paramount importance for society, as it allows developing adaptation and mitigation measures. Thus, the economic and social negative impact of climate variability and climate change can be reduced.

1.2. State of knowledge

This thesis focuses on the study of wave climate. In order to study wave climate, it is necessary to use atmospheric databases (e.g. wind and atmospheric pressure) and wave databases (e.g. significant wave height and mean period). These databases are to be used to study temporal and spatial climate variability. Temporal variability can be analyzed through historical databases to study the climate in the past and through projections for climate change scenarios to study the climate in the future. Spatial variability can be studied through global low-resolution and regional high-resolution databases. High-resolution data can be generated from low resolution data through downscaling techniques.

1.2.1. Global atmospheric data

Historical climate can be studied from several data sources, for example, visual observations, instrumental measurements and databases generated from models. All databases have limitations; visual observations are spatially and temporally heterogeneous; instrumental data (e.g. anemometers and satellites) cover short periods of time and are concentrated in a few places; and databases generated by models show significant errors in complex areas or in exceptional weather conditions. These limitations can be avoided by using reanalysis data. Reanalysis combine numerical models similar to those used in weather forecasting with instrumental data assimilation for reconstructions of the climate system of up to several decades. By combining the strengths of the different sources of data, reanalysis provide homogeneous representations of the climate system in the past with a uniform spatial distribution. For example, NCEP/NCAR Reanalysis I (NNR, Kalnay et al. 1996), 40 year ECMWF Reanalysis (ERA-40, Uppala et al. 2005), NCEP Climate Forecast System Reanalysis (CFSR, Saha et al. 2010) and NOAA - CIRES twentieth Century Reanalysis (20CR, Compo et al. 2011) have been used in this thesis for several reasons. NNR and ERA-40 are useful to validate results as both have been widely used by the scientific community; CFSR provides results with very high spatial resolution (about 0.3°); and 20CR covers a long period of time (about 150 years).

Future climate has to be studied taking into account climate change. Projections of global climate models (GCMs) are a very useful tool for studying changes in the global climate system under different scenarios of concentrations of greenhouse gases in the atmosphere. The analysis of the projections is important to understand the timing and magnitude of impacts associated with different magnitudes and rates of climate change and to assess the risks that the society faces. However, differences in the results depending on the GCM used pose a challenge to use this information. The Coupled Model Intercomparison Project (CMIP) started in 1995 and since then has provided the scientific community the opportunity to study and compare the results of GCMs. The results of GCMs face very large uncertainties but, nevertheless, their results have been essential in the IPCC reports. The last two phases of the CMIP have been CMIP3 (Meehl et al. 2007) and CMIP5 (Taylor et al. 2012). In CMIP3, the scenarios from the Special Report on Emission Scenarios (SRES, Nakicenovic and Swart 2000) used in the fourth IPCC assessment report (AR4) were studied. SRES includes 40 plausible futures based on various assumptions about demographic change, economic development and technological change. These scenarios are grouped into four families (A1, A2, B1 and B2) that explore alternative development pathways incorporating a range of demographic, economic and technological driving forces, along with resulting emissions of greenhouse gases. In CMIP5, the Representative Concentration Pathways (RCPs, Moss et al. 2010) used in the fifth IPCC report (AR5) were studied. RCPs include RCP2.6, the RCP 4.5, the RCP 6.0 and 8.5 RCP representing respectively low, middle, high and very high emission levels. RCPs presented as major developments over SRES more detailed information and explicit exploration of mitigation policies. Figure 1.3 shows the comparison of SRES and RCPs throughout the 21st century in terms of the evolution of radiative forcing.

1.2.2. Global wave data

Reanalysis and GCMs provide information from a large number of variables. Some of these variables (e.g. temperature and humidity) are essential to study the climate system and its variability. Other variables are also the most important forcings to run a wave model (i.e. surface wind, currents and ice cover). However, reanalyses and GCMs have limitations for studying wave climate. GCMs do not provide any wave parameter and reanalyses just provide the most basic parameters. In order to study the climatology of waves, usually it is needed using numerical reconstructions. There are numerous reconstructions of global wave made with numerical models as WAVEWATCH III (Tolman and Chalikov 1996). For example, Reguero et al. (2012) developed a wave

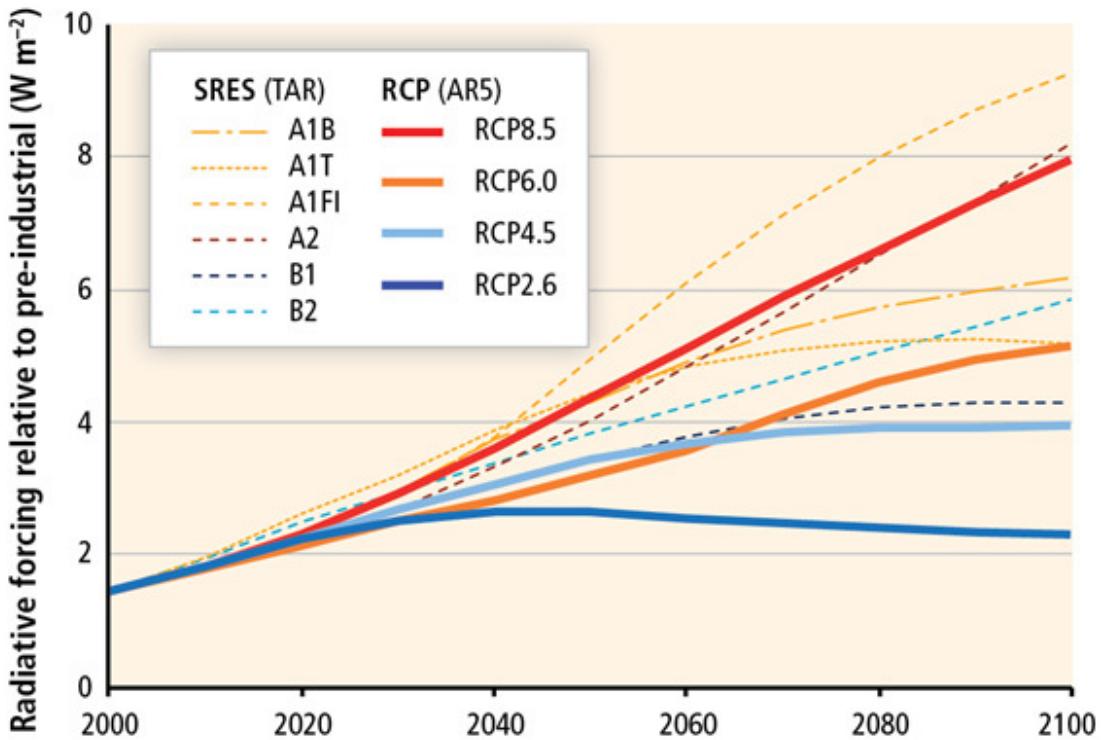


Figure 1.3: Projected radiative forcing in W m^{-2} over the 21st century from the SRES and RCP scenarios (Source: Figure 1-4 AR5 WGII)

hindcast calibrated with satellite data from 1948 to now and Raschle and Ardhuin (2013) modeled the years 1994-2012 using settings based on Ardhuin et al. (2010).

Changes in the waves can cause severe impacts on coastal areas; however, wave projections have been less studied than sea level projections. The few global studies (e.g. Mori et al. 2010, Semedo et al. 2013, Wang et al. 2014) have used different techniques and databases. COWCLIP (Coordinated Ocean Wave Climate Project) is a project that seeks to coordinate wave projections to study their uncertainties. The main objectives of COWCLIP are three: 1) providing a systematic, community-based framework and infrastructure to support validation, intercomparison, documentation and data access for wave climate projections forced from CMIP5 datasets; 2) to describe best practice for regional wave climate projections, and; 3) engaging interests of the wave community into the wider climate community and ultimately developing coupled wind-wave Atmosphere-Ocean global climate models to support quantification of wind-wave driven feedback in the coupled climate system. A milestone in the history of COWCLIP has been the first multi-model ensemble based on community studies (Hemer et al. 2013a). This study combines the results of five previous studies (four dynamic and one statistical) to obtain an estimate of the uncertainties in wave projections. This ensemble is based on a set of simulations of GCMs larger than any previous study. These simulations, however, represent only a small part of the simulations available on CMIP5.

1.2.3. Downscaling

Global databases provide high-quality information but their spatial resolution is too low for regional or local studies. The higher spatial resolution may be obtained by downscaling. Downscaling refers to techniques that derive small scale information (on a node or region) from data at a larger spatial scale. There are two main alternatives: statistical methods and dynamical methods.

Dynamical downscaling is based on numerical modeling using nested meshes with increasing resolution. In the case of GCMs scientific community has developed regional climate models (RCMs) using data from GCMs as boundary conditions. The problem is that there are only simulations of RCMs for a few combinations of GCM and region because of the enormous computational effort required. In the case of reanalysis it is common to use limited area models (LAM) like WRF (Skamarock et al. 2008) to generate regional reconstructions (e.g. Menendez et al. 2014). In the case of wave models it is common to generate *ad hoc* regional reconstructions with higher resolution to fulfill the requirements of local studies. Dynamical downscaling can be used to model historical waves (e.g. Bertin et al. 2013) and future wave climate projections (e.g. Grabemann and Weisse 2008). The main problem is that high resolution meshes of wave models also need high resolution forcings (e.g. downscaling of reanalysis or GCMs). In summary, dynamic downscaling require great computational effort.

Statistical downscaling (e.g. Casas-Prat et al. 2014, Izaguirre et al. 2012, Wang et al. 2004), are based on statistical relationships between predictor and predictand. They are less computationally expensive than dynamical downscaling. However, they need to use available data to define the statistical relationship between predictor (the atmospheric situation) and predictand (the wave conditions). A problem of statistical downscaling is that several choices in the definition of the predictor are subjective. This makes statistical downscaling commonly less accepted than dynamical downscaling. Stronger validation and reduction of subjectivity are needed to overcome this problem.

1.3. Goals

The analysis of the state of the knowledge shows that:

- The historical atmospheric reanalysis provide high-quality data. There are several reanalyses available with different characteristics, but generally all provide accurate reconstructions of past climate.

- The GCMs provide projections to scenarios of climate change but do not model waves. In addition, significant discrepancies are observed in the results of different GCMs due to cascading uncertainties.
- There are historical reconstructions of wave climate modeled numerically using reanalysis data as forcings. These reconstructions are able to represent the historical wave climate with high accuracy.
- There are very few studies of wave projections and they are based on a small number of GCMs. The uncertainty in wave projections has been little studied.
- The resolution of global databases is usually too low to analyze local impacts and regional studies at higher resolution are scarce. In dynamic downscalings, the computational cost is very high, and, in statistical downscalings, defining the relationship predictor-predictand is a complex process.

Based on these points, the objectives of this thesis focus on improve downscaling techniques and generating wave projections for climate change scenarios. These aims are specified in four main interdependent objectives:

Objective 1: Develop a method to study the influence of global wave climate in local wave climate. This method must be able to objectively characterize the area of influence for any location. In particular, it must identify areas where energy reaching the point is generated/dissipated and the propagation times of that energy.

Objective 2: Develop a statistical downscaling method that can reproduce the local wave climate from synoptic situations in their area of influence. This method must have a low computational cost and be able to reproduce the multivariate wave climate realistically.

Objective 3: Analyze the climate simulated by global climate models, studying both the ability to reproduce historical climate and the consistency of their future projections. The analysis has to be based on a set of indexes that indicate which models provide, *a priori*, more credible simulations.

Objective 4: Define a methodology for multi-model regional wave projections. An objective method has to be defined to select the ensemble and the practical application for various scenarios of climate change has to be shown. Improve understanding of the climate and provide estimates of future climate change that may be useful to those studying the possible consequences.

Figure 1.4 summarizes the relationships between the methodologies presented in this thesis. Three data sources are used: historical wave data, historical atmospheric data and atmospheric data simulated by GCMs. First, the area of influence of the local wave

is studied. Then a weather type classification is generated from atmospheric data in the region of interest. This classification is used for two purposes: 1) Each weather type is linked to historical conditions from a wave hindcast in order to establish the empirical statistical relationship between atmospheric circulation and waves. 2) Atmospheric data from GCMs are dumped in the classification and the relative frequencies are evaluated to see which GCMs are more reliable. Finally, the statistical relationship between atmospheric conditions and waves is applied to an ensemble of GCMs in order to generate projections of wave climate.

1.4. Methodology framework

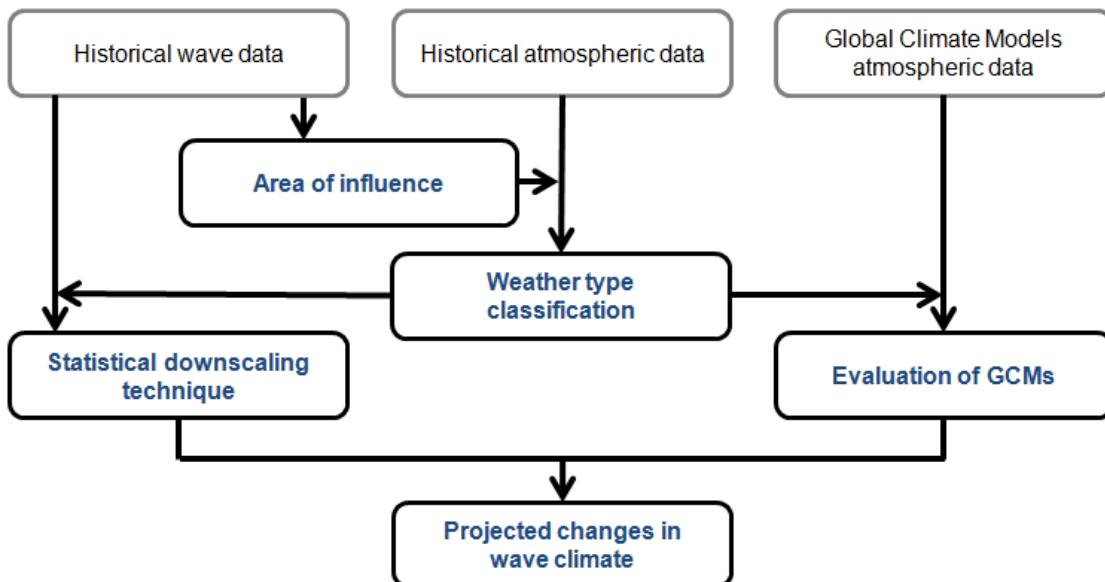


Figure 1.4: Methodological framework of the thesis

A proper definition of the area of influence of the local waves, i.e. the extent of the area where weather conditions have a significant effect on the local waves, is essential for downscaling studies. In dynamic downscaling it is important to limit the size of the high-resolution meshes and; in statistical downscaling, it is important to define the area of the predictor. In widely studied areas such as Europe and North America the area of influence may be defined by an expert from previous climate studies. However, in less studied areas, such as Africa or South America, extensive testing is necessary to reach an acceptable solution. In this thesis we develop a methodology called ESTELA to simplify the process of defining the area of influence. ESTELA methodology can be used to define the areas of generation/dissipation and propagation times of wave energy reaching any point on the globe. In addition, ESTELA allows studying how these areas vary in a number of time scales (e.g. seasonally and long-term). This information helps

to define an area of influence based on objective criteria and considerably reduces the time required for it.

A statistical downscaling is not limited to know the area of influence; defining the variables to be used as a predictor and predictand is also a key issue. Most statistical downscaling works focused on wave climate are based on regression models between sea level pressure (SLP) and significant wave height. SLP is used as a predictor because it is a variable reasonably well simulated by the models and has a very strong relationship with ocean wind-waves. There are other methods of statistical downscaling as those based on weather types and stochastic generators (Giorgi et al. 2001). This thesis develops a statistical downscaling model based on a classification of weather types. This approach is directly applicable to multivariate waves as each weather type can be associated with several predictands. This allows analyzing other parameters apart from the wave height (e.g. peak period or direction) that are also important to study the wave climate. In addition, the atmospheric changes and the waves can be analyzed together.

A weather type classification is particularly suited to study long term changes in climate. The classification can be used to study projections from GCMs in order to identify the type of synoptic situations that will change in the future. Also, if the classification has been generated based on a good predictor of the wave climate, these changes can be associated to changes in wave climate. The biggest problem is the uncertainty in the results of GCMs. It is necessary to evaluate model performance; however, the historical series of events are not directly comparable because small differences in the initial conditions of a climate simulation cause large differences in the timing of synoptic situations. That is, climate events such as El Niño will not coincide temporally for different GCMs but the frequencies have to be similar. The mean frequencies of the weather types can be analyzed in order to decide what GCMs are more appropriate for statistical downscaling. In the past, climatic conditions from GCMs can be studied comparing with reanalysis data and, in the future, their results can be analyzed against each other. Comparison of the historical simulations from GCMs with reanalysis is used for evaluating their ability to represent the historical climate and its variability. Comparison of future projections to each other is used to check which models predict future changes inconsistent with the rest. In this work we have developed a set of indices to study the GCMs based on three aspects: historical mean climate, historical variability, and consistency of future projections. These indices have been applied to simulations of SLP from CMIP3 and CMIP5 GCMs. The results provide a measure of uncertainty in GCMs and identify synoptic situations that are not well simulated by the models.

One way to enhance the study of climate change projections is to select an ensemble of GCMs based on an objective criterion. For example, using only the "best" GCMs

to prevent results are conditioned by less reliable models, or use all GCMs. In both cases, the inter-model variability resulting from the set of GCMs should be assessed. This thesis has aimed to develop regional wave climate projections taking into account the above factors. To this end, the statistical downscaling technique and the analysis of GCM have been combined. The statistical downscaling technique allows to use a very large ensemble and the analysis of GCMs prevents choose them “blindly”. In this thesis, this methodology has been applied in Europe for obtaining regional multi-model projections of wave climate.

1.5. Organization of the thesis

This thesis consists of 6 chapters. The four main chapters each corresponding to a paper published (or accepted) in journals in the first quartile in atmospheric and/or ocean sciences. The PhD candidate is the lead author on three of the four papers and co-author on one of them. Papers retain their original content, but its format has been adapted to this thesis.

Chapter 1 “Introduction” presents the objectives of the thesis and links the papers included in the thesis. Chapter 2 “ESTELA: a method for Evaluating the Source and Travel time of the wave Energy reaching a Local Area” studies wave propagation and develops of a tool to understand the origin of the local wave energy and propagation times. Chapter 3 “A weather-type statistical downscaling framework for ocean wave climate” develops a statistical method based on a classification of weather types to in order to obtain waves from atmospheric patterns. Chapter 4 “Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region” analyzes the ability of global climate models (GCMs) to represent regional climate through weather types. Chapter 5 “Statistical multi-model climate projections of surface ocean waves in Europe” combines the above methodologies in order to obtain projections of regional wave climate under climate change scenarios. Finally, Chapter 6 “Summary and future research” reviews the main results of the thesis and suggests priority areas to be developed in the future.

Chapter 2

ESTELA: a method for evaluating the source and travel time of the wave energy reaching a local area

Abstract

The description of wave climate at a local scale is of paramount importance for offshore and coastal engineering applications. Conditions influencing wave characteristics at a specific location cannot, however, be fully understood by studying only local information. It is necessary to take into account the dynamics of the ocean surface over a large “upstream” wave generation area. The goal of this work is to provide a methodology to easily characterize the area of influence of any particular ocean location worldwide. Moreover, the developed method is able to characterize the wave energy and travel time in that area. The method is based on a global scale analysis using both geographically and physically based criteria. The geographic criteria rely on the assumption that deep water waves travel along great circle paths. This limits the area of influence by neglecting energy that cannot reach a target point, as its path is blocked by land. The individual spectral partitions from a global wave reanalysis are used to reconstruct the spectral information and apply the physically based criteria. The criteria are based on the selection of the fraction of energy that travels towards the target point for each analysed grid point. The method has been tested on several locations worldwide. Results provide maps that inform about the relative importance of different oceanic areas to the local wave climate at any target point. This information cannot be inferred from local

This chapter is based on Perez et al. (2014a): Perez, J., Mendez, F. J., Menendez, M., Losada, I. J. (2014). ESTELA: a method for evaluating the source and travel time of the wave energy reaching a local area. *Ocean Dynamics*, 64(8), 1181–1191. <http://doi.org/10.1007/s10236-014-0740-7>

parameters and agrees with information from other approaches. The methodology may be useful in a number of applications, such as statistical downscaling, storm tracking and grid definition in numerical modelling.

2.1. Introduction

Wave characteristics at a local scale play a major role in a wide range of issues (e.g. maritime works, navigation routes, offshore structures design, harbour operability, ecosystem distribution and flooding risk). These conditions are dominated by locally generated waves (wind sea) and waves from distant storms (swells). Hence, the need for accurate wave data has long encouraged studies on wave generation and propagation of global ocean swells. Studies by Barber and Ursell (1948), Munk (1947), Munk et al. (1963), and Snodgrass et al. (1966) contributed significantly to the scientific basis and introduced some of the currently accepted paradigms, e.g. great circle propagation and small dissipation of swells. Unfortunately, these earlier studies were limited by the availability of in situ measurements, i.e. a small number of stations concentrated in coastal areas and covering a short time period with long gaps.

More recent studies (e.g. Collard et al. 2009) take advantage of the global coverage offered by Synthetic Aperture Radar data but they face similar constraints due to the coarse spatial and temporal resolution of these data. Despite the data limitation, studies on space and time variability of wave climate have lead to a huge improvement in the physics of numerical wave models. The improved physics and the availability of higher computational power have resulted in high-quality wave hindcast databases (e.g. Raschle et al. 2008; Reguero et al. 2012). The homogeneous and continuous data from wave hindcasts overcome the limitations of instrumental data being a useful tool in order to improve our understanding of wave propagation around the globe.

In this study, we propose a methodology based on hindcast data for evaluating the area of influence at any particular location and time period. Other studies have introduced different approaches to analyse characteristics of wave generation and propagation. For instance, Devaliere et al. (2009) shows a wave tracking algorithm to identify existing wave systems and Alves (2006) uses a numerical model to evaluate the contribution of swells from different ocean basins to the global wind–wave climate. Application of our method provides different information such as where the energy is generated/dissipated, how long it takes to arrive, and the variability of the area of influence between seasons or years. It is anticipated that these information can be used to aid the design of statistical or dynamical downscaling studies. Statistical downscaling methods are based on the relationship between the local wave climate and the atmospheric patterns over a region

(e.g. Casas-Prat et al. 2014; Izaguirre et al. 2012; Wang et al. 2004), and dynamical downscaling is performed to focus model resolution in the desired areas (Tolman 2008). In both cases, the definition of the area of interest is a time-consuming problem, commonly solved by subjective expert criterion. This study presents a fast and objective technique to study the wave generation area that induces local wave climate.

The rest of the chapter is organized as follows: Section 2.2 explains the methodology and is structured into four subsections: “geographic criteria”, “spectrum reconstruction”, “energy flux assessment” and “net energy generation areas”. In Section 2.3, some results in the North-East Pacific, Central-East Pacific, North-West Atlantic and Indian Ocean are presented. Finally, some conclusions are given in Section 2.4.

2.2. Methodology

The methodology, which is henceforth referred to as ESTELA (a method for Evaluating the Source and Travel-time of the wave Energy reaching a Local Area), is intended to characterize the influence area for a specific target point. The process is summarized in a diagram in Figure 2.1 and involves four sequential steps: First, geographic criteria are applied to limit the study into the relevant spatial domain. Second, the spectral reconstruction provides frequency–direction information. Third, the wave energy assessment reveals important characteristics of the wave energy that reaches the target point. Finally, the areas of gain/loss of energy are obtained.

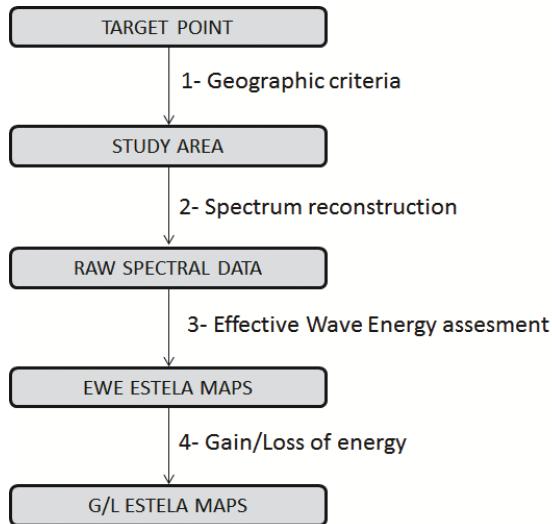


Figure 2.1: Flowchart representing the ESTELA methodology

This method requires homogeneous wave data. In this study, a global wave parameter database (Rascle and Ardhuin 2013; Rascle et al. 2008) has been used. This database was obtained by the numerical wave model WAVEWATCH III in its version 4.04 forced by

winds from the Climate Forecast System Reanalysis (Saha et al. 2010). The model uses a parameterization called TEST451 (Ardhuin et al. 2010), with significant improvements for swell dissipation. The wave spectrum of the model is discretized using 24 directions and 31 frequencies and the results are provided in a spatial grid at 0.5° resolution and 3-h time resolution. The available catalogue from this hindcast includes parameters such as significant wave height, peak period, mean direction and directional spread for up to six partitions of the spectrum, the wind sea and five swell trains in the more general case. In this study, we use 20 years, from 1993 to 2012, of wave spectra reconstructed from these partitions.

2.2.1. Geographic criteria

The geographic criteria are applied to limit the study area by neglecting wave systems separated from the target point by land. These criteria rely on the assumption that deep water waves travel along great circle paths, which reduces the computational effort in the following steps of the methodology. This assumption has, however, several limitations due to the dynamic interaction of waves with their environment. For example, wave-current interactions are not always negligible in deep water, and processes such as refraction and diffraction may be important in shallow waters. The great circle assumption may therefore neglect contributions by energy from some cells, sited behind groups of small islands or that are partially blocked by land, to overall energy at the target point.

In order to take these limitations into account, we only neglect a source point when the area represented by that grid point is clearly blocked by land, i.e. there is a land mass that blocks all the directions in a directional sector $\alpha \pm \Delta$, where α is the direction of the great circle between a source point and the target point and Δ determines the width of the directional sector. We use

$$\Delta = \max \left(5, \arctan \left(\frac{dx/2 + dy/2}{r} \right) \right), \quad (2.1)$$

where the minimum Δ is 5° , dx and dy are the spatial resolution of the hindcast, and r is the distance between a source point and the target point.

Figure 2.2 shows the valid area for a target point in the North-East Atlantic Ocean. The selected area covers the whole North Atlantic basin and a section of South Atlantic Ocean, whilst the North Sea and the Caribbean Sea are not included. Note that the valid area includes all the grid points where the wave energy that reaches the target point can be generated or transformed.

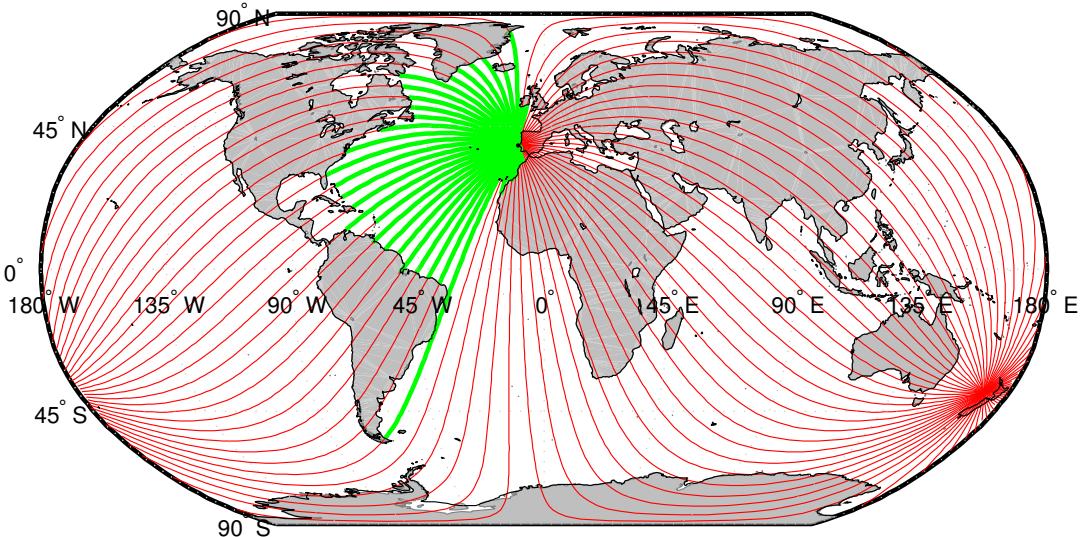


Figure 2.2: Geographic criteria for a target point P [10°W , 39°N] in the North-East Atlantic Ocean. The selected geographic area is represented in green and the neglected area is represented in red

2.2.2. Spectrum reconstruction

The common practice to describe a specific sea state is to use a reduced set of statistics such as the significant wave height and the mean direction. These statistics, however, do not represent the complex wave climate in some regions, where sea states are the result of several wave trains travelling in different directions. The two-dimensional wave spectrum characterizes the distribution of the wave energy among different frequencies and directions and it is considered a complete description of (phase averaged) waves on the ocean surface.

The concept of spectral partitioning introduced by Gerling (1992) allows for the identification of sub-peaks within the two-dimensional wave spectrum. The computation of the statistics of these segments represents a considerable data reduction that preserves directional information. Consequently, these parameters have become usual output from wave models. The partitioning scheme in WAVEWATCH III is based on the method of Hanson and Phillips (2001), implemented as described in Tracy et al. (2007).

In order to reconstruct the full frequency–direction spectrum, we use four parameters obtained from spectral partitioning. Those parameters are significant wave height (H_s), peak period (T_p), mean direction (θ) and directional spread (σ) for one sea and up to five swells $H_{s0}, T_{p0}, \theta_0, \sigma_0, \dots, H_{s5}, T_{p5}, \theta_5, \sigma_5$. Any partition can be viewed as a unimodal spectrum given by its parameters, and the multimodal spectrum can be obtained by aggregation of these unimodal spectra. We reconstruct the frequency–direction spectrum following:

$$E(f, \theta) = \sum_{i=0}^5 \rho g S_i(f) D_i(\theta), \quad (2.2)$$

where ρ is the water density and g is the acceleration due to gravity. $S_i(f)$ and $D_i(\theta)$ are the one-dimensional wave spectrum and the directional distribution for a partition i . The one-dimensional wave spectrum $S_i(f)$ is obtained by using a JOint North SeaWAve Project (JONSWAP) spectrum (Hasselmann et al. 1973), where the amount of energy is determined by H_{s_i} and the distribution over the frequencies depends on T_{p_i} . We have used a JONSWAP spectrum shape with a peak enhancement parameter $\gamma = 3.3$, since no other measures of frequency distribution were available from the wave hindcast and testing showed that this assumption has negligible effect in the assessment of the effective wave energy reaching a target point. Regarding the directional distribution $D(\theta)$ we assume a cosine-type expression (e.g. Holthuijsen 2007; Mitsuyasu et al. 1975):

$$D(\theta) = A_2 \cos^{2s} \left(\frac{\theta - \alpha}{2} \right) \quad \text{for } -180^\circ < \theta - \alpha < 180^\circ, \quad (2.3)$$

where θ is the mean direction parameter and α is the direction between the source point and the target point. A_2 and s are two parameters controlling the width of the distribution and depend on the directional spread parameter:

$$s = \frac{2}{\sigma^2} - 1, \quad (2.4)$$

$$A_2 = \Gamma(s + 1) \left/ \left[\Gamma \left(s + \frac{1}{2} \right) 2\sqrt{\pi} \right] \right.. \quad (2.5)$$

A simple analysis to evaluate the spectrum reconstruction was performed to compare the reconstructed spectra against the original spectra from the numerical model. The evaluation in different locations and periods shows consistent results. Reconstructed spectra capture correctly the directional distribution. The frequency distribution is also represented reasonably well, although some discrepancies are found for the higher frequencies. This was expected since two parameters (θ and σ) are used to represent the directional distribution and only one parameter (T_p) is used to represent the frequency distribution.

2.2.3. Effective energy flux assessment

The effective energy flux assessment is based on the characteristics of the spectrum and the location of the source point and the target point. Here, the effective energy flux is defined as the energy of the spectrum travelling towards the target point at the group velocity, and it is estimated to achieve the Effective Wave Energy (EWE) ESTELA maps. The effective energy is corrected by the viscous dissipation that the waves are expected to suffer during the propagation between the source and target points. In order to evaluate the relative importance of the far-field regions, the effect of other dissipation mechanisms must be taken into account. This can be assessed qualitatively by analyzing the effective energy flux in the downstream points of the great circle path.

Figure 2.3 shows the relevant part of the spectrum at a time t (right) for a particular great circle (left). The position of the source point with respect to the target point is defined by the distance r and the angle α . The spectral density radiated towards the target point is determined by $E(f; r, \alpha, t)$, the cross section through the spectrum $E(f, \theta; r, \alpha, t)$ at the direction α . In order not to overestimate the importance of energy from distant source points, a spatial decay at a rate μ can be considered. A theoretical lower bound for μ is given by the viscous theory, giving, in deep water (Ardhuin et al. 2009; Collard et al. 2009; Dore 1978)

$$\mu = 2 \frac{\rho_a}{\rho_w g c_g} \left(\frac{2\pi}{T} \right)^{\frac{5}{2}} \sqrt{2\nu_a}, \quad (2.6)$$

where $\rho_a/\rho_w = 0.0013$ is the relation between air density and water density, $c_g = \frac{gT}{4\pi}$ is the group velocity and ν_a is the air viscosity (for a clean surface $\nu_a = 1.4 \cdot 10^{-5} \text{ m}^2\text{s}^{-1}$).

Viscous dissipation is responsible for a considerable loss of energy of higher frequencies. Dissipation of lower frequencies, however, is dominated by other processes. We only correct viscous dissipation because it can be considered independent of the atmospheric and oceanic conditions during the propagation. Moreover, regions where the loss of energy cannot be explained by viscous dissipation are as interesting as the regions where energy is generated.

The effective energy flux (F) and the travel time (τ) at any time (t) and position (r, α) are then:

$$F_{(r,\alpha,t)} = \int_0^\infty E_{(f;r,\alpha,t)} e^{-\mu r} c_g df, \quad (2.7)$$

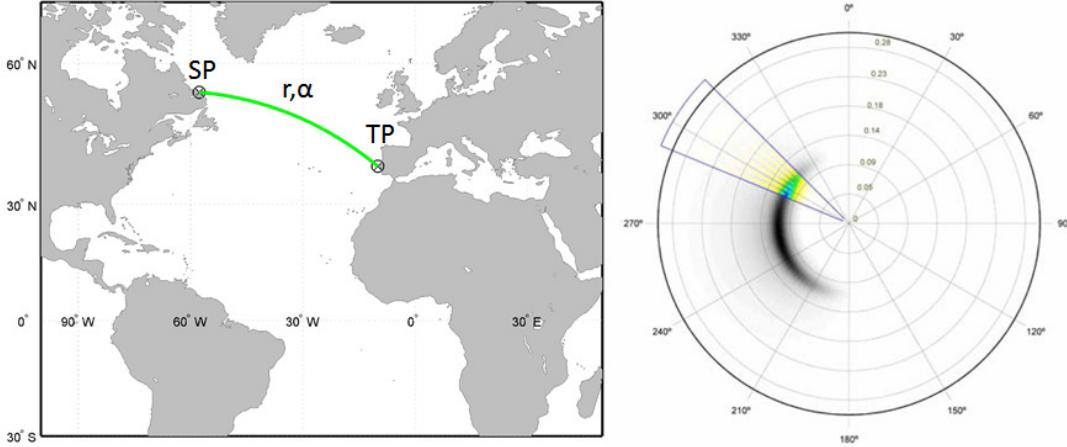


Figure 2.3: *Left* An example of the great circle between a target point near Portugal and a source-point in Canada. *Right* Wave energy spectrum at the source point. The selected cross section of wave energy that will propagate along the great circle between TP and SP is coloured

$$\tau_{(r,\alpha,t)} = r \frac{\int_0^\infty E_{(f;r,\alpha,t)} e^{-\mu r} df}{F_{(r,\alpha,t)}}. \quad (2.8)$$

The effective energy flux and the travel time over a series of N sea states can be easily obtained. The effective energy flux is the sum of the valid energy fluxes divided by the number of sea states and the travel time is obtained by using the weighted mean of the group celerity:

$$\overline{F_{(r,\alpha)}} = \frac{\sum_{i=1}^N F_{(r,\alpha,t_i)}}{N}, \quad (2.9)$$

$$\overline{\tau_{(r,\alpha)}} = r \frac{\sum_{i=1}^N F_{(r,\alpha,t_i)} \frac{\tau_{(r,\alpha,t_i)}}{r}}{\sum_{i=1}^N F_{(r,\alpha,t_i)}}, \quad (2.10)$$

2.2.4. Gain/loss of energy

The effective energy flux characterizes wave propagation. In order to analyse the wave generation and dissipation, this information must be regredded to a polar grid centred at the target point. In a polar grid, the gain/loss of energy in each cell (ΔF) can be viewed as the difference between the incoming and the outcoming flux along the great circle. This Lagrangian point of view, similar to the first-generation wave models, is shown in Figure 2.4. Note that this approach sums the effect of the traditional wave growth and dissipation with the effect of wave components that cross the great circle.

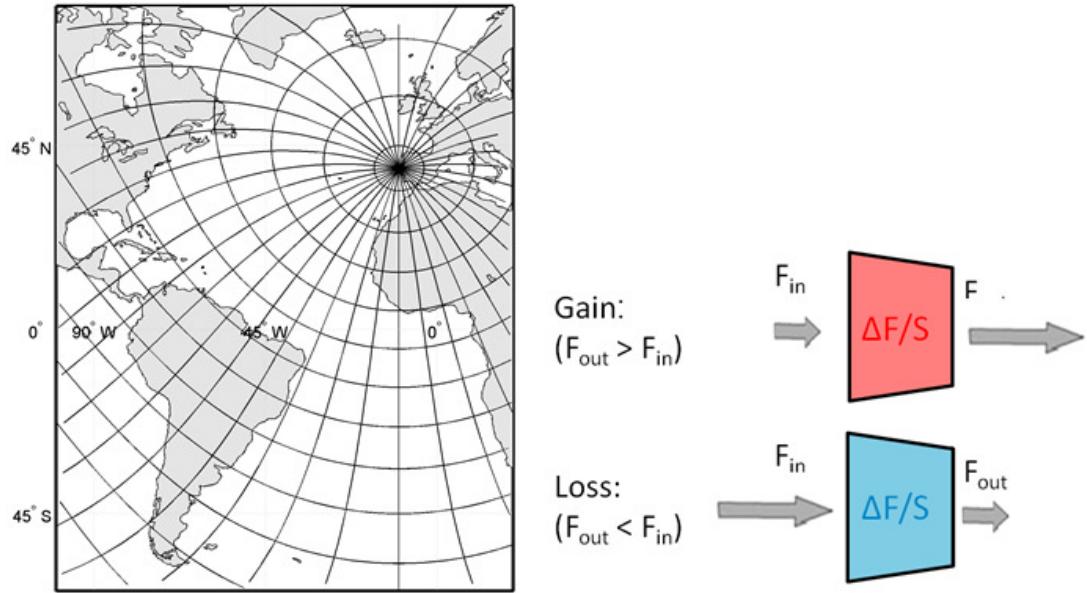


Figure 2.4: Polar grid with coarse resolution centred in a target point P [10°W, 39°N] in the North-East Atlantic Ocean (left) and diagram of gain/loss of energy (right)

In order to reduce the influence of the discretization, $\overline{\Delta F_{(r,\alpha)}} = \overline{\Delta F_{(r_{out},\alpha)} - \Delta F_{(r_{in},\alpha)}}$ is divided by the surface of the cell. The surface is the intersection between a spherical wedge and a spherical segment

$$S = S_{total} \frac{S_{wedge}}{S_{total}} \frac{S_{segment}}{S_{total}} = 4\pi R^2 \frac{\lambda}{2\pi} \frac{|\cos(\frac{r_{in}}{R}) - \cos(\frac{r_{out}}{R})|}{2}, \quad (2.11)$$

where R is the Earth radius, λ is the angle of the wedge and r_{in} and r_{out} are the distances between the target point and the sides of the cell. The $\overline{\Delta F_{(r,\alpha)}}$ values are shown in the gain/loss (G/L) ESTELA map.

2.3. Results

In order to show the suitability of the ESTELA method at any location, four target points are selected: (i) site A [131°W, 46°N] in the North-East Pacific, close to the Oregon state (USA); (ii) site B [80°W, 8°S] in the Central-East Pacific, near the Peruvian coast; (iii) site C [10°W, 44°N] in the North-East Atlantic, near the North-West Spanish coast and (iv) site D [55.5°E, 5.5°S] in the Indian Ocean, located in the Seychelles Islands.

Site A is affected by the North-Pacific extra-tropical cyclone activity. Some authors have explained higher wave energy due to intensification of the Aleutian low and a strong interannual variability of wave climate related to the Pacific North America (PNA) teleconnective index (Bromirski 2005; Graham and Diaz 2001). Site B is in a tropical

region, affected by long-period swells that cross the entire Pacific Ocean (Young 1999) and the trade winds. Atmospheric patterns related to teleconnections between tropics, extra-tropics and high latitudes are, therefore, expected to affect the variability of the wave climate in this study site (see for instance the effect of the Southern Annular Mode (SAM), on waves in the South Hemisphere described in Hemer et al. 2010a). Site C is an open location exposed to the North Atlantic extratropical storms. The strength and the direction of the westerly winds and storm tracks are the main climatic drivers at site C. Some authors (e.g. Izquierdo et al. 2010; Woolf 2002) have found that a large fraction of the wave energy along the Atlantic European coast can be associated to the North Atlantic oscillation (NAO). Wave climate of site D is clearly affected by tropical cyclone activity in the Indian Ocean and the penetration of swells from the Southern Ocean has been previously identified (Alves 2006; Young 1999).

Figure 2.5 shows the effective mean energy flux and travel time at site A from 1993 to 2012. The coloured area shows the effective energy flux ($\text{kW}/\text{m}/\text{degree}$). Red lines show the great circles of 16 directional sectors and black lines represent the travel time (τ) in days. Red and yellow areas represent the regions with the highest wave energy transmitted toward the target point whereas the effective energy of dark blue areas is negligible. The ESTELA map reveals two important regions: a clear energetic region westward of the target point covering the North Pacific Ocean from 30°N , and a region in the Southwest Pacific near Australia and New Zealand. The second one is the source of swells travelling from SSW to reach site A during 9–14 days. Some wave energy from this region is blocked due to several Polynesian islands but the waves reaching the target point from this region should be sorted swells.

Figure 2.6 shows the obtained generation areas (in red) and dissipation areas (blue). In this figure, the complexity of the northern area of influence becomes more evident. There are up to 3-day swells from the north-west, up to 6-day swells from south-west and important local wind seas. Moreover, the generation and dissipation of southern swells is easily identifiable. The wave attenuation due to the small islands in French Polynesia demonstrates the importance of obstruction grids for spectral wave models as outlined in Tolman (2003) and Chawla and Tolman (2008).

The analysis of ESTELA maps for different time periods can be used to analyse the local wave climate variability. Figure 2.7a shows the ESTELA map for the years 1996 (left) and 1998 (right). The spatial pattern in both years is quite similar to that of Figure 2.5. The intensity of F , however, is different between the maps, with 1996 being a low-energy year whereas 1998 presents the largest values in the 20 years analysed. Figure 2.7b shows the ESTELA maps during the boreal winter (December, January and February) and summer (June, July and August) seasons. These maps are quite different

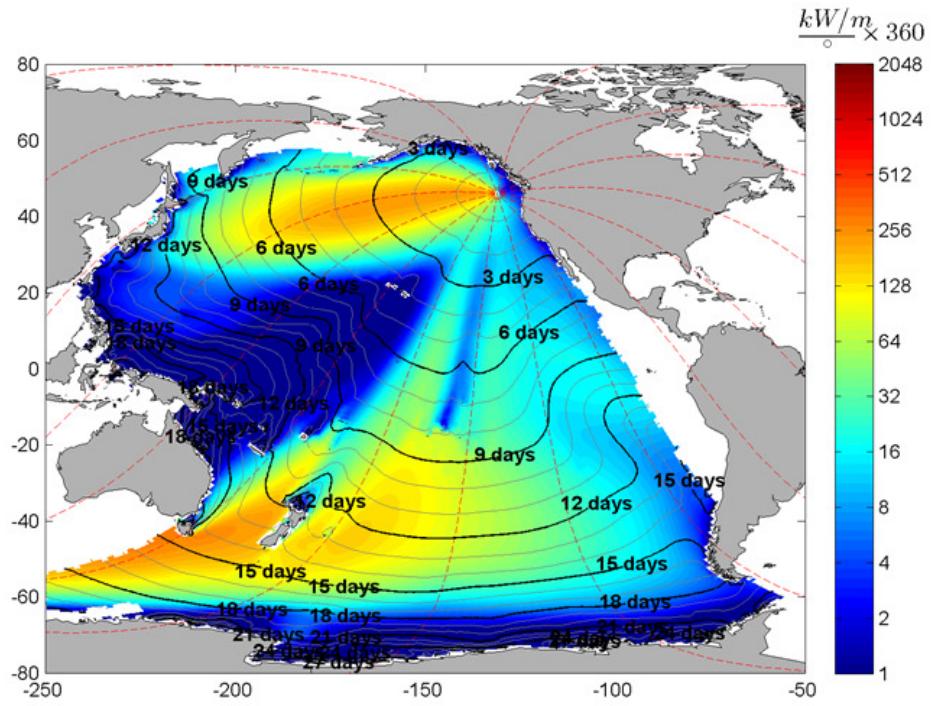


Figure 2.5: Mean effective energy flux from 1993 to 2012 for site A. The coloured area is defined by the group of source points that satisfy the geographic criteria. The travel time is represented by the grey and black lines

to each other. In winter, the northern area is clearly dominant, whilst energy from the southern hemisphere is almost negligible in the proximity of the target point. On the contrary, the energy in the northern hemisphere decreases during austral winter whereas the energy of the southern hemisphere swells increases. The ESTELA maps reveal that the interannual variability of wave climate at site A is not as large as the within a year variations.

Figure 2.8 shows the ESTELA maps for three different time periods at site B. The resulting ESTELA map for the 20 years (upper chart) shows an impressive spatial pattern. Two families of wave generation areas are identified: one from each hemisphere. The two areas of influence for site B show travel times of up to 2 weeks. It is interesting to note that sites A and B are affected by waves from the same extra-tropical areas of the Pacific Ocean. The effect of these waves is, however, clearly different in site B. This location is clearly exposed to the westerly winds of Southern hemisphere, which generate waves southward and southwest of site B. The wave energy in the northern hemisphere is also relevant but it is limited to a narrow directional sector between Californian Peninsula and Galapagos Islands. The lower charts of Figure 2.8 show the ESTELA maps for January (left) and August (right) months of 1998, an intense El Niño year and positive

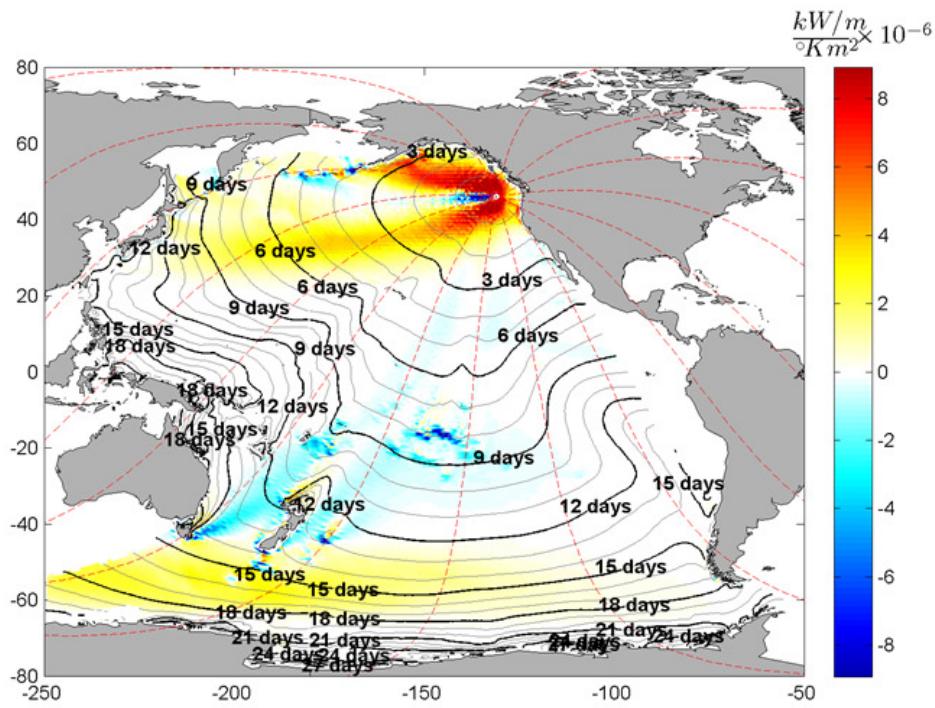


Figure 2.6: Gain/loss of energy areas from 1993 to 2012 for site A

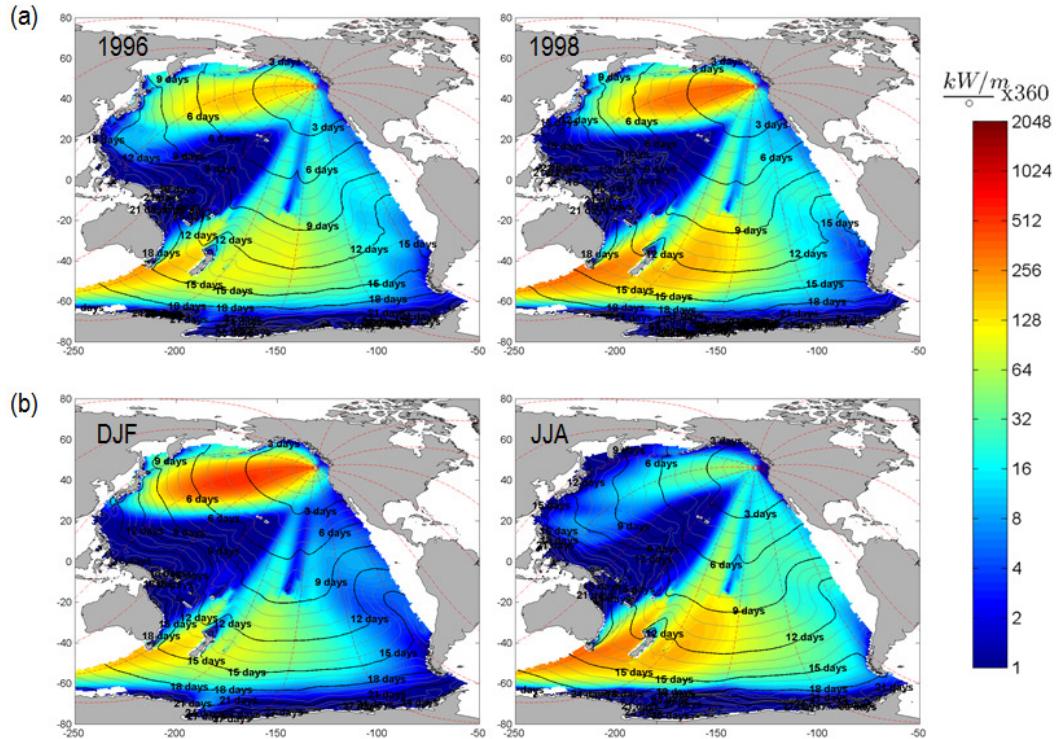


Figure 2.7: Mean effective energy flux in 1996 (upper left), 1998 (upper right), boreal winter (lower left) and summer (lower right) for site A

SAM climate index. Swells with large energy from the northern hemisphere can reach the site B or can be non-existent depending on the month of the year.

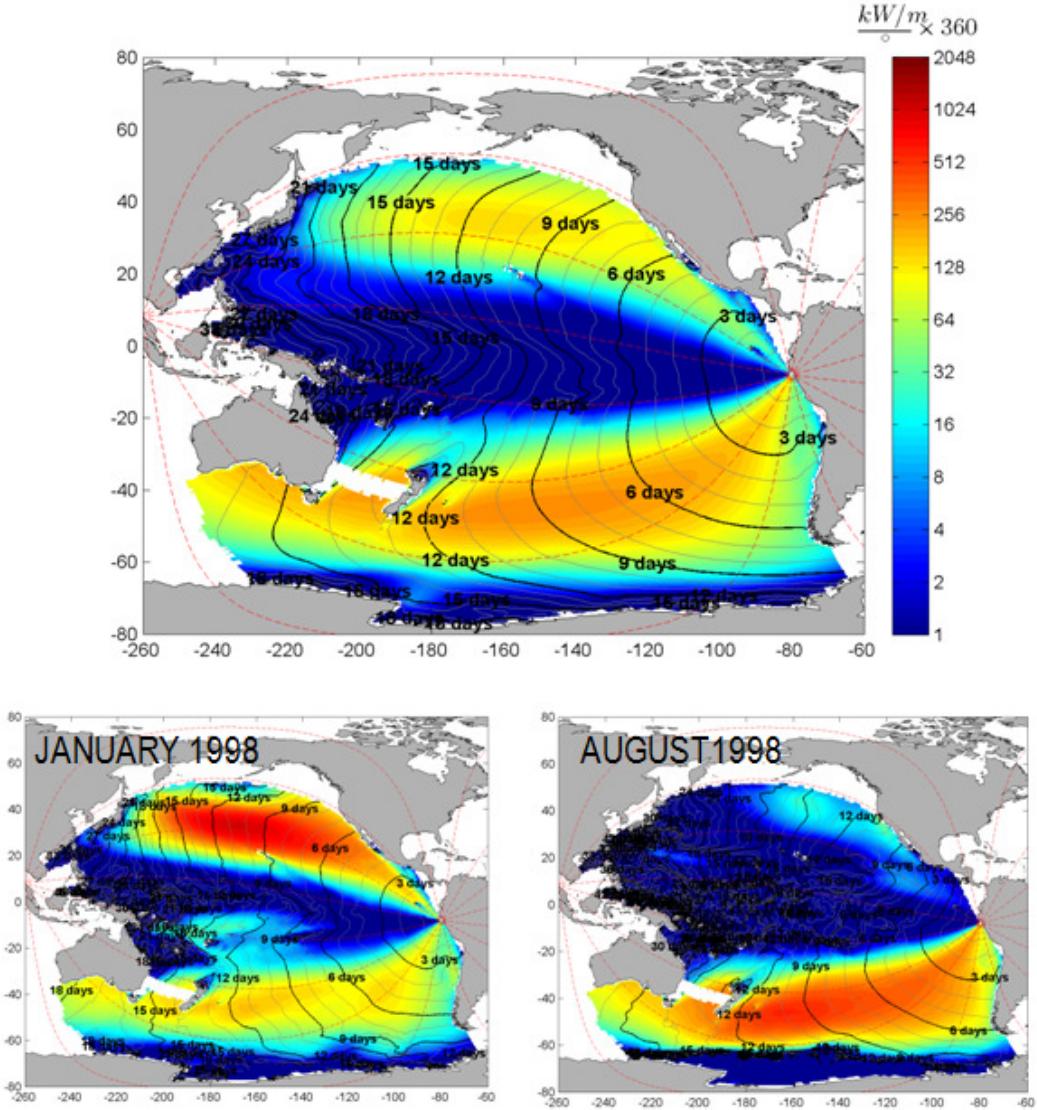


Figure 2.8: Mean effective energy flux for site B. The upper chart shows the aggregation of years from 1993 to 2012. The lower charts show January (left) and August (right) months of 1998

Figure 2.9a shows the ESTELA maps for site C during positive and negative North Atlantic Oscillation (NAO) values. The figure shows that the effective energy in northwest Spain is characterized by long-period swells under active storm periods (Espejo et al. 2014). The NAO pattern is one of the most prominent climate fluctuation patterns in the Northern Hemisphere (Hurrell et al. 2003). The NAO Index series obtained from

the Climate Prediction Center has been used to analyse the influence of this climate index in the effective energy flux. Results show that the positive phase of NAO (NAO+) is characterized by large and long-period waves whilst the negative phase (NAO-) is characterized by smaller waves and a direction shift from northwest to west. This result agree with Izaguirre et al. (2010), which found a great influence of NAO on the extreme wave height in the North-East Atlantic, and can be related to the stronger, northward-shifted winds during NAO+ and the weaker southward-shifted winds during NAO- (Dupuis et al. 2006; Le Cozannet et al. 2011).

Figure 2.9b shows the ESTELA maps for site D during the boreal winter (DJF) and summer (JJA). Three families of swells are characterized: a large southwest swell generated in a region of intense winds in the Southern Ocean (more intense during austral winter); a eastern swell in the tropical Indian Ocean, a region with high occurrence of tropical cyclones, and a northern swell only appearing during boreal winter months. The ESTELA map reveals that this northern swell family can reach the tropical Indian Ocean region, in contrast with results from Alves (2006).

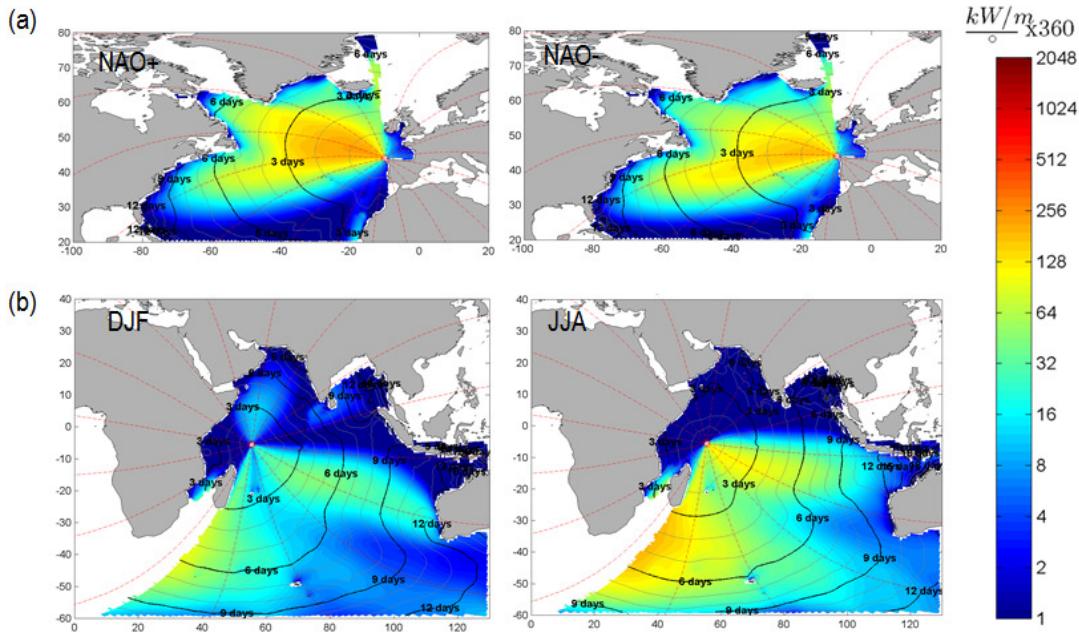


Figure 2.9: The upper charts show the mean effective energy flux for site C during NAO+ (left) and NAO- (right). The lower charts show the mean effective energy flux for site D during boreal winter (left) and summer (right)

2.4. Summary and conclusions

ESTELA provides an easy and objective representation of the wave climate affecting a local area based on only two parameters: the effective energy flux and the wave energy travel time. In order to obtain a good representation of directionality, these parameters are computed from the full frequency–direction spectrum. As spectral data is not always available, we propose a simple method to reconstruct the full spectrum from the statistics of spectral partitions derived from hindcast models. The reconstructed spectra show a good agreement with direct output spectra and may be useful for a range of applications.

The computational effort of ESTELA is very low because it is based on precomputed hindcast data. We would like to highlight, nevertheless, that the ESTELA results depend on the quality of the forcings and the physics scheme used in the wave model. In order to evaluate the importance of these choices, the results were compared with previous results (not shown) based on a different hindcast forced by NCEP-NCAR reanalysis and using Tolman and Chalikov (1996) source terms. As expected, some differences in magnitude were found, the spatial patterns, however, were qualitatively similar.

The results in the analysed locations offer a new tool for understanding regions of wave generation and the extent of swell propagation over the global ocean. For instance, the maps show the effects of model representation of small islands on the wave climate at distant locations and the time variability of wave generation areas. In this paper, we have analysed climatologies and seasonal and interannual variability but ESTELA can be used for a range of applications and in different time scales, from hours (footprints of extreme storms) to long term (climate change impact in the swell generation areas). For instance, Camus et al. (2014a) uses ESTELA maps information to characterize the footprint of the wave climate and to automate the definition of the predictor spatial domain corresponding to the swell wave component.

Chapter 3

A weather-type statistical downscaling framework for ocean wave climate

Abstract

Wave climate characterization at different time scales (long-term historical periods, seasonal prediction, and future projections) is required for a broad number of marine activities. Wave reanalysis databases have become a valuable source of information covering time periods of decades. A weather-type approach is proposed to statistically downscale multivariate wave climate over different time scales from the reanalysis long-term period. The model calibration is performed using historical data of predictor (sea level pressure) and predictand (sea-state parameters) from reanalysis databases. The storm activity responsible for the predominant swell composition of the local wave climate is included in the predictor definition. N -days sea level pressure fields are used as predictor. K -means algorithm with a postorganization in a bidimensional lattice is used to obtain weather patterns. Multivariate hourly sea states are associated with each pattern. The model is applied at two locations on the east coast of the North Atlantic Ocean. The validation proves the model skill to reproduce the seasonal and interannual variability of monthly sea-state parameters. Moreover, the projection of wave climate onto weather types provides a multivariate wave climate characterization with a physically interpretable linkage with atmospheric forcings. The statistical model is applied to

This chapter is based on Camus et al. (2014b): Camus, P., Menendez, M., Mendez, F. J., Izaguirre, C., Espejo, A., Canovas, V., Perez, J., Rueda, A., Losada, I. J., Medina, R. (2014). A weather-type statistical downscaling framework for ocean wave climate. *Journal of Geophysical Research: Oceans*, 119(11), 7389–7405. <http://doi.org/10.1002/2014JC010141>

reconstruct wave climate in the last twentieth century, to hindcast the last winter, and to project wave climate under climate change scenarios. The statistical approach has been demonstrated to be a useful tool to analyze wave climate at different time scales.

3.1. Introduction

Accurate characterization of local wave climate is required in series of sectors such as shipping, offshore industry, marine engineering, and coastal management. Wave climate variability plays a significant role in numerous geophysical processes. Operations of marine carriers, logistics of marine structures, coastal erosion, or flooding risk are some examples where multivariate behavior of waves is essential. Wave climate is traditionally characterized from two sources: observations (buoys, satellites, and voluntary observing ship (VOS) data) and outcomes from numerical models (dynamical downscaling). Buoys provide the most reliable data; however, their records are usually not longer than 20 years, have notable gaps, and are very scattered at sea. Satellite observations present a global coverage, but this source of data is only available since 1992 with a non-regular time resolution. VOS data provide the longest records of independent sea and swell parameters (Gulev and Grigorieva 2006) and reliable climate variability and trends with less inhomogeneities than wave hindcast (Gulev 2003). However, their sampling is insufficient and they require correction algorithms. The dynamical downscaling outputs are a good alternative to observations, but they require a high-quality bathymetry and wind fields and are computationally expensive.

When atmospheric data are available, an alternative to dynamical downscaling is the statistical downscaling. The statistical downscaling (SD) method typically adopts a “perfect prognosis” approach, in which high-resolution simulations of the variables of interest are based on real-world statistical relationships between large-scale atmospheric predictors and a local-scale predictand. The main advantage of the statistical approach is that it is computationally inexpensive; therefore, it is suitable for a faster predict-and characterization, to get long-term simulations, or to develop multiple realizations from different forcing conditions (i.e. outputs from climate change scenarios). Some assumptions are inherent in the perfect prognosis downscaling approach: (i) variability of the local variable should be explained by the statistical connection, (ii) changes in the mean climate should lie within the range of its natural variability, and (iii) the relationships should be stationary. Long observation time series, physical explanation of the relation between the large-scale predictor and the local predictand, and reliable predictor simulations by Global Climate Models (GCMs) fulfill these conditions (Wilby et al. 2004).

Different approaches can be applied to develop a SD model. Giorgi et al. (2001) classified the methods into: (i) transfer functions, (ii) weather-type approaches, and (iii) stochastic weather generators. The performance of the SD techniques can be found in a high number of works for different regions using a broad range of predictands. For example, Gutiérrez et al. (2013) compare the performances of different SD methods (from the analog, weather typing, and regression families) for downscaling temperatures in Spain. Each method has its own strengths and weaknesses, reproducing certain local weather statistical characteristics with more or less accuracy, being difficult to select one against the other, always depending on each particular case. Other relevant aspects which determine the skill of the SD method are the predictor choice, regarding variables and the spatial domain (Fowler et al. 2007). In the case of sea surface waves, sea level pressure (SLP) fields and the squared SLP gradient fields have demonstrated to be good predictors (Casas-Prat et al. 2014; Wang et al. 2012). This is especially relevant for applications of climate projections, since the SLP variable is supposed to be less biased than wind fields from GCMs (Caires et al. 2006).

The SD applications to analyze wave climate are usually limited to climate projections of the significant wave height (H_s), a parameter of the sea state. Most of the developed works are based on multivariate linear regression models between the SLP predictor and the H_s at seasonal or hourly scale (Casas-Prat et al. 2014; Wang et al. 2012; Wang and Swail 2006; Wang et al. 2004) or extreme models, modeling the interannual variability using covariates defined by the SLP predictors (Caires et al. 2006; Izaguirre et al. 2010; Wang and Swail 2006; Wang et al. 2004). However, H_s is not the only variable of concern to deal with wave climate processes. Other sea-state parameters (e.g. peak period and mean wave direction) are required to analyze climate change effects in coastal structures (Suh et al. 2012) or wave energy resources (Hemer et al. 2010b). For example, wave direction is particularly critical for calculating littoral drift and associated estimates of sand budgets to determine coastal erosion.

In this work, an SD framework based on weather types is presented. Statistical models find difficult to reproduce waves in swell-dominated areas (Hemer et al. 2012). To overcome this problem, the recent history of atmospheric conditions responsible for the swell component in the study area is going to be introduced in the predictor definition. A statistical relationship between the weather types and the whole probability distribution of multivariate local wave climate is established. The SD model is applied in two locations in the North Atlantic Ocean, in the Irish and the Spanish coasts. For these locations, the SD model is validated and some applications are shown: a local wave climate characterization, a long-term historical reconstruction, an update of a wave hindcast database, and the simulation of wave climate projections.

The chapter is structured as follows. Section 3.2 presents the statistical downscaling framework proposed. Section 3.3 shows the application of the method to a particular case study. This section includes the definition of the predictor and predictand, the application of the weather classification technique, the description of the relationship between the synoptic patterns and the local wave climate, and the results of the validation period. Section 3.4 presents several applications of the statistical downscaling method including the characterization, hindcast, and projection of wave climate. Section 3.5 contains the summary and conclusions.

3.2. The statistical downscaling method

Regarding wave climate, the aim of a statistical downscaling method is to estimate local waves (predictand) from global atmospheric conditions (predictor), based on a statistical relation. A weather typing method is proposed in this study. The flowchart summarizing the statistical method is shown in Figure 3.1. The steps of the methodology are: (1) collection of historical data for the predictor and predictand; (2) definition of the predictor at daily scale; (3) classification of predictor conditions in a reduced number of weather types; (4) establishing the relationship between predictor and predictand; (5) validation of the statistical model.

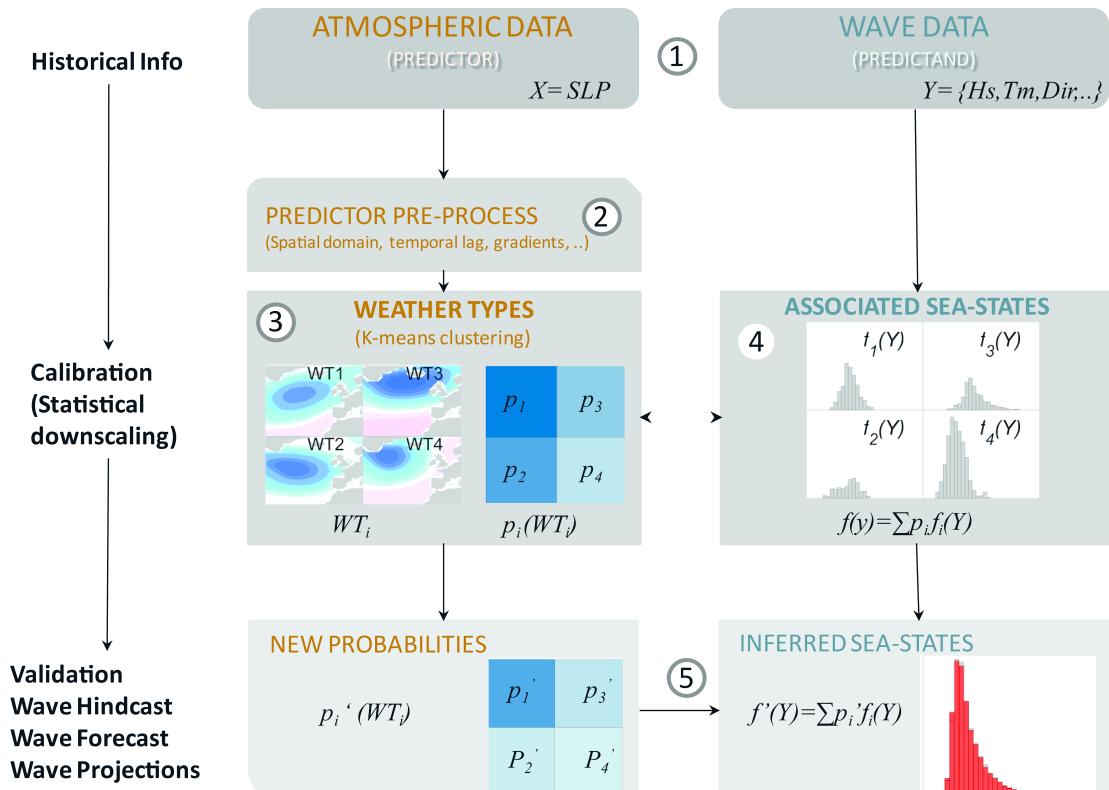


Figure 3.1: Flowchart representing the statistical downscaling methodology

First, historical data of both atmospheric predictor and wave climate predictand are required to define the statistical model between predictand and predictor.

Regarding the predictor definition on a daily scale, the variables are the SLP and the squared SLP gradients. The spatial domain and temporal coverage of the predictor should be specified for each location where waves are downscaled. Spatial domain should cover the oceanic basin area of wave generation reaching that particular location. Recent historical atmospheric conditions should be included in the predictor in order to take into account the generation and propagation processes of the waves reaching a specific location.

In the third step, the SLP predictor database is partitioned into a certain number of clusters, named weather types (WTs), applying a classification technique. Each WT represents a synoptic atmospheric circulation pattern.

WT classification is obtained combining three data mining techniques: first, a principal component analysis (PCA) is applied to the predictor variable in order to reduce the data dimensionality and simplify the classification process. Second, the predictor in the EOFs space is clustered using k-means algorithm (KMA). Finally, the set of WTs is organized using a similarity criterion.

PCA projects the original data on a new space searching for the maximum variance of the sample data. The eigenvectors (empirical orthogonal functions, EOFs) of the data covariance matrix define the vectors of the new space. The original data projections over the new vectors are the Principal Components (PCs). The EOFs are ranked in increasing order of explained variance. Therefore, a smaller number of PCs than the original data dimension is considered, keeping a high amount of variance. The KMA divides the data space into a number of clusters, each one defined by a prototype and formed by the data for which the prototype is the closest (Hastie et al. 2009). The maximum-dissimilarity algorithm (MDA) is applied to initiate the prototypes, which guarantees a deterministic classification and the most representative initial subset.

The clusters are organized in a bidimensional lattice, which allows an intuitive visualization of the classification. The algorithm, based on a similarity criterion, starts locating the clusters into a bidimensional lattice. The distance between each cluster WT_i and its closest neighbors in the lattice are calculated. Permutations of the cluster locations in the lattice are performed, calculating the sum of the distances in each permutation. The best organized lattice is the one with the minimum sum of distance (Bermejo and Ancell 2009). Results are almost similar to the self-organizing maps due to the fact that similar patterns in the original space are close in the lattice, with the advantage of

a better exploration of the data space, strengthened by an MDA initialization (Camus et al. 2011).

The fourth step consists of defining the statistical relationship between the predictor and predictand. The predictand is defined as the sea-state parameters at the location of interest. The sea states are associated with each cluster (hourly sea states during each daily predictor field represented by the corresponding cluster), allowing a nonlinear relationship. The probability distributions of different variables $f_i(y)$, such as the univariate distribution of the H_s parameter or the joint distribution of H_s and mean period (T_m), are calculated for each WT_i . This statistical relation is established for a calibration period. Although in the state of the art the statistical downscaling methods are sometimes calibrated separately for each season, in our approach, the classification process is performed for the whole calibration period due to the fact that future seasonal climates might not exactly correspond to the present ones (Maraun et al. 2010).

Hence, the marginal and joint distributions (empirical probability density functions) of the sea-state parameters and any derived statistic can be estimated for the whole calibration time period as follows:

$$f(y) = \sum_{i=1}^M p_i \cdot f_i(y), \quad (3.1)$$

where p_i is the probability of WT_i . The probability of occurrence (p_i) of a WT_i is estimated from the number of daily atmospheric predictor situations represented by each WT, so that $\sum_{i=1}^M p_i = 1$, where M is the number of weather types.

The estimation of the sea-state parameters for a time period outside the calibration period is based on the new probabilities of the WTs from the SLP predictor. The sea-state distributions for a new time period can be estimated as:

$$f'(y) = \sum_{i=1}^M p'_i \cdot f_i(y), \quad (3.2)$$

being p'_i the probability of WTs for the new time period.

The final step of the definition of the statistical downscaling model is the validation. Monthly sea-state parameters are calculated based on the distribution of sea states associated with each WT_i and the probabilities of the WTs for the validation period.

3.3. Case study

The SD model is applied in the North Atlantic region at two locations by establishing a statistical relationship between large-scale atmospheric circulation patterns and the probability distributions of several parameters of the sea states.

3.3.1. Data

3.3.1.1. Predictor

The global SLP fields of the NCEP/NCAR reanalysis-I (Kalnay et al. 1996), from the National Center for Environmental Prediction-National Center for Atmospheric Research, are used as the predictor in the SD model. This atmospheric reanalysis spans from 1948 to present. Multiple instrumental measurements were integrated in an assimilation process. Inhomogeneities were found to be caused by changes in the observing system. NCEP/NCAR reanalysis is less reliable during the earliest decade (1948–1957), due to fewer upper-air data observations (Kistler et al. 2001). After 1957, data coverage in the North Hemisphere was large enough to effectively constrain the model and avoid large inhomogeneities. However, homogeneity in the Southern Hemisphere can only be assumed after 1980 due to low data coverage (Sterl 2004). Therefore, data from 1960 to 2013 are used in this work. The used SLP data from NCEP-NCAR reanalysis-I consist of 6 hourly fields on a 2.5° by 2.5° long-lat global grid.

3.3.1.2. Predictand

Historical data of the local wave climate predictand are required in the SD model. The historical wave information used in this work is the ocean wave reanalysis database Global Ocean Waves (GOW, Reguero et al. 2012). GOW has been generated with the third generation model WAVEWATCH III, which solves the spectral action density balance equation for wave number direction spectra using finite differences (Tolman 2009). GOW encompasses several spatial domains, a global grid with a spatial resolution of 1.5° by 1° , forced by the 6 hourly wind fields of NCEP-NCAR reanalysis-I (more details in Reguero et al. 2012) and several nested regional domains around (e.g., Pacific and Atlantic American regions described in Izaguirre et al. 2013). Here we use waves from a GOW regional simulation over the European Atlantic area. The regional spatial domain spans from 27.25°N to 57.25°N and 20°W to 37°E , with a resolution of 0.25° . The European Atlantic domain is forced with wind fields from SeaWind I, a dynamic atmospheric downscaling from NCEP-NCAR reanalysis-I (Menendez et al. 2014). Outputs

provide hourly sea-state parameters (significant wave height, mean period, peak period, and mean wave direction) from 1948 to 2013.

Figure 3.2 shows the two selected study sites in the east of the North Atlantic basin: a location westward of Ireland (IR, lon=11.25°W, lat=53.25°N) and a site in the northwest coast of Spain (GA, lon=9.25°W, lat=43.5°N). GOW series of wave parameters in both sites have been compared against in situ observations in order to validate the data. Time series of hourly wave observations were obtained from the Irish Marine Buoy Network and the Spanish State Ports network. The Spanish 2246 buoy was moored in 1998 about 40 km west of A Coruña coast, at latitude 43.5°N and longitude 9.21°W. The Irish buoy M1 was deployed in 2000 about 95 km west of the Aran Islands, 53°07.6'N and 11°12.0'W. Figure 3.3 shows the validation process. The plots on the left show the scatterplot of buoy measurements and numerical results and the plots on the right show the buoy and GOW H_s hourly time series. Both tests demonstrate good agreement between the numerical data and observations, with a correlation higher than 0.9 and a low bias (0.014 and 0.354 m for the Spanish and Irish buoys, respectively). Buoy records can be used as input in the SD model. It should be noted, however, that long records and observations without gaps during specific seasons are recommended for a good statistical relationship between atmospheric patterns and local wave climate.

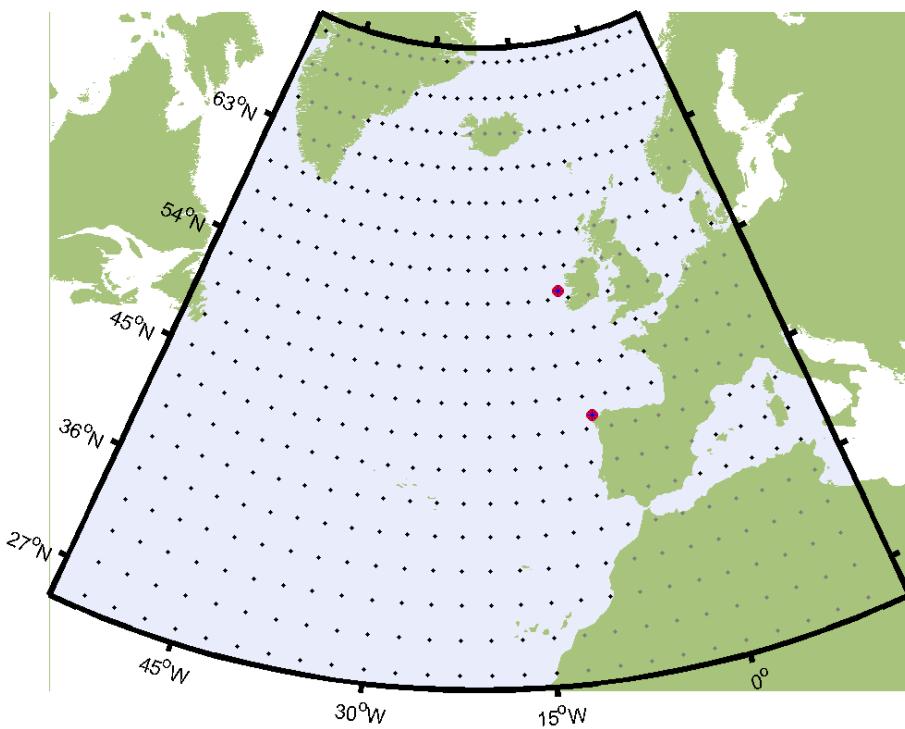


Figure 3.2: Selected spatial domain of SLP predictor (only black grid points are considered). Red circles show the locations of the analyzed predictand (local wave climate)

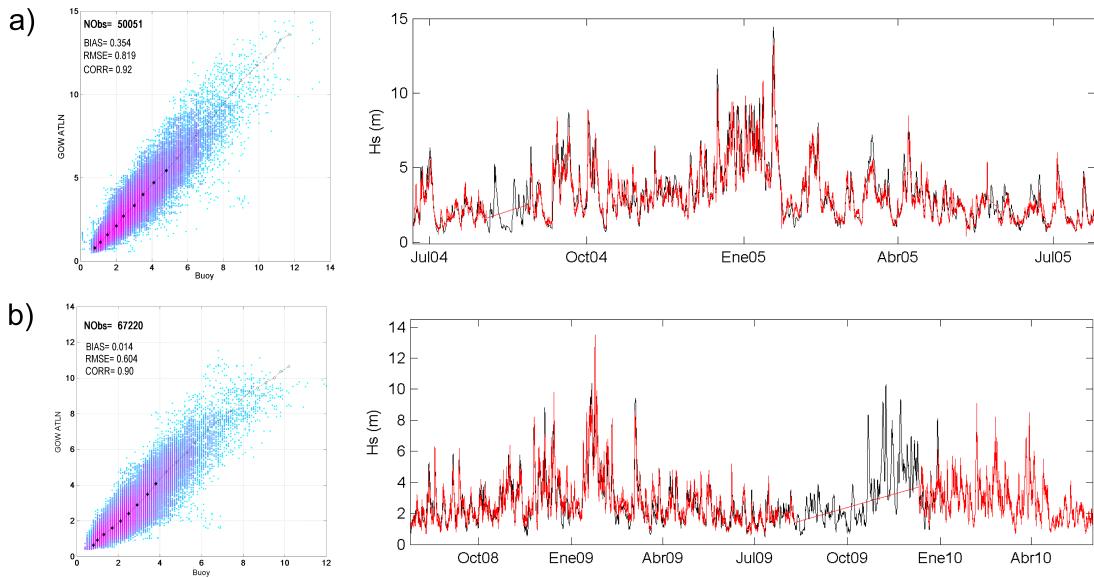


Figure 3.3: (left) Scatterplot and quantile-quantile plot and (right) time series of significant wave height (m) from buoy records versus GOW hindcast for a location in (a) west Ireland and (b) Norwest Spain. Buoy records are in red and GOW data in black

3.3.2. Predictor definition

The wave climate along the European Atlantic coast is mainly influenced by extratropical storms generated in the north and northwest of the Atlantic basin with a mean duration and an arriving time to the east Atlantic coast of about 4 days (Gulev et al. 2001). Figure 3.2 shows the area selected in the North Atlantic basin as the predictor spatial domain, from 25°N to 70°N and from 52.5°W to 10°E. The selected domain covers the storm activity in the North Atlantic Ocean which is the source of swell wave component on the northwest coast of Europe (Alves 2006). The predictor variables used in the statistical model are the SLP fields and the squared SLP gradients (SLPG), which represent the geostrophic wind conditions. The land grid points of the selected domain are disregarded, avoiding the strong variability mode of SLPG over Greenland and other onshore regions. The predictor is defined as the three daily mean SLP and three daily mean SLPG, calculated every day through the calibration time period. Thus, the predictor associated with a certain day corresponds to the average obtained using the same day and the previous 2 days.

3.3.3. Statistical downscaling method

3.3.3.1. Weather Type classification

First, the PCA analysis is applied to the SLP and SLPG daily data for the calibration period. In this example, the calibration period is a 40 year representative period from 1960 to 1999. In this study, a variance equal to 95 % is considered, which corresponds to the first 38 PCs.

A number of $M = 100$ patterns is established in the application of KMA. The selection of a hundred classes is made based on the compromise between an easy handle characterization of synoptic climatologies and the best reproduction of monthly sea-state parameters (model validation). A sensitivity analysis of the model validation has been performed considering a different number of clusters, varying between $M = 20$ and $M = 400$. Figure 3.4 shows the 100 WTs, organized in a bidimensional lattice. In the figure, the WTs are represented by the isobars. The high-pressure systems over the averaged air pressure at sea level (1013 hPa) are displayed on a red scale and the low-pressure systems on a blue scale. Similar patterns are located together, varying smoothly from one cell to another. WTs with intense low-pressure systems but different locations of the pressure center are distributed at the corners of the lattice, being identified as different circulation patterns. The standard positive North Atlantic Oscillation (NAO) mode, characterized by a strengthening of the low over Iceland and the high around Azores islands, are at the bottom left corner of the lattice, while WTs with an intense low-pressure center on the North Atlantic Ocean between 40° and 58° latitudes are located at the bottom right corner of the lattice. These latter WTs can be associated with East Atlantic (EA) positive phase situations, a north-south dipole similar to NAO but with its center located southward (deeper low at 50° - 55° and a higher subtropical high).

The seasonal or interannual variability can be analyzed using the WT classification. Figure 3.5 graphically shows the seasonal and total probability of the WTs from NCEP-NCAR reanalysis-I during the calibration period of 40 years. Darker blue color indicates WTs with high frequency and the lighter blue the most unusual. Winter season shows the largest variability of WTs while the synoptic patterns in summer are concentrated in several WTs located in the middle of the KMA lattice, corresponding to high-pressure situations. Patterns in the rest of seasons cover a wider range of WTs. The WTs in the corners of the lattice are detected only in winter (DJF), corresponding to a low-pressure center over the North Atlantic Ocean.

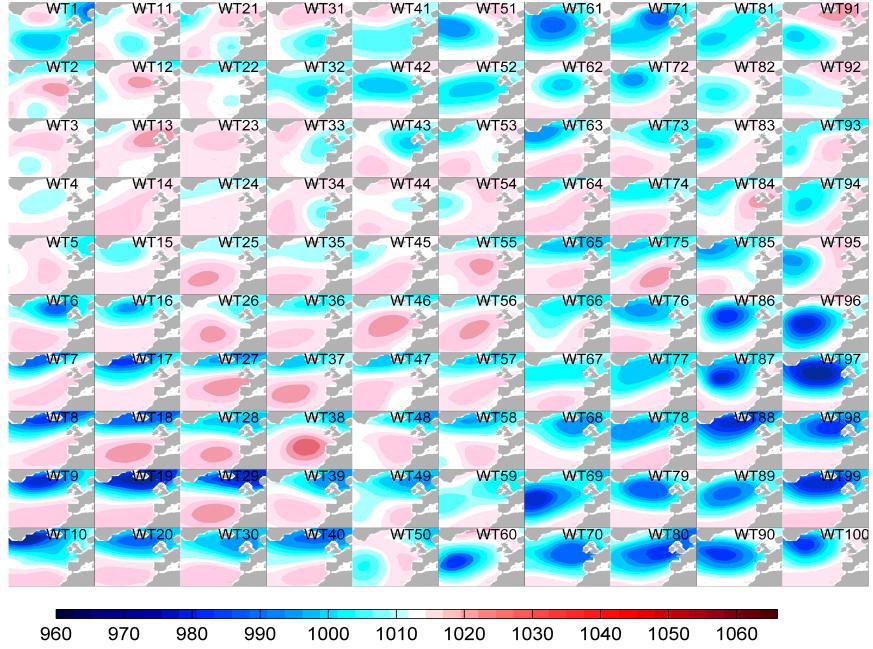


Figure 3.4: The 100 weather types represented by the SLP fields (hPa) obtained from the atmospheric classification

3.3.3.2. Relationship between predictor and predictand

Besides being a description of atmospheric states, the classification is also a tool for understanding atmospheric processes and the linkage between circulation and surface climate (Huth 2010). In this section, the nonlinear relation between predictor (X , atmospheric conditions) and predictand (Y , local wave climate) is described.

The local wave climate data of the two selected locations are projected into the WT classification. The hourly sea-state parameters H_s , T_m , mean wave direction (θ_m), wave energy flux indicator ($H_s^2 T_m$), and the components x and y of the mean energy flux indicator, corresponding to daily predictor fields represented by each WT are projected in each pattern during the calibration period.

Figure 3.6 presents local wave climate information at the northwest Spanish location associated with four different WTs. The dominant WT in summer (WT35) represents a neutral atmospheric situation, with weak high and low-pressure systems. The joint distribution $f_{35}(H_s, T_m)$ and the joint distribution $f_{35}(H_s, \theta_m)$ are also displayed. The most probable H_s is around 1.5 m, the corresponding T_m is around 7 s, and θ_m is NW, although a wide range of directions from SW to NE are probable. WT97, a pattern that only occurs in winter, is also shown in Figure 3.6, with the associated joint distributions

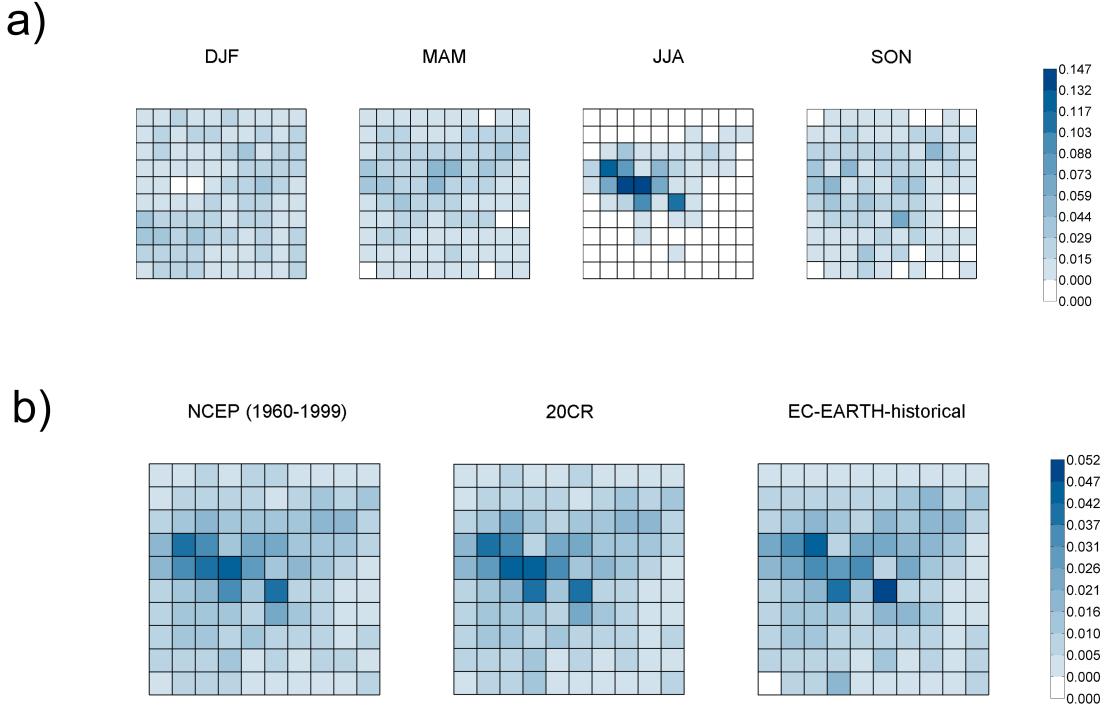


Figure 3.5: (a) Seasonal probability of occurrence of the 100 weather types (classification shown in Figure 3.4) for the NCEP-NCAR reanalysis-I for the calibration period 1960–1999. (b) Probability of occurrence for the present conditions (1960–1999) of the weather types from the NCEP-NCAR reanalysis-I, 20CR reanalysis, and climate model EC-EARTH, from left to right

$f_{97}(H_s, T_m)$ and $f_{97}(H_s, \theta_m)$. In this case, WT97 represents an intense low-pressure system in the Northeast Atlantic with important SLPG. The atmospheric pattern is reflected in the associated sea states. H_s is around 9 m, T_m around 12 s, and θ_m mainly from W. H_s and T_m associated with WT35 and WT97 are clearly different, reflecting a predominant swell nature of waves in winter and local wind origin in summer. Other two patterns are also shown in Figure 3.6. WT29 is a winter pattern with a low-pressure center located northward which generates high energetic (lower H_s but larger T_m than WT97) northwesterly waves at GA location. WT2 represents a local high-pressure center with the associated sea waves mainly with a northeast direction at GA.

3.3.4. Validation of the statistical downscaling method

In order to verify the skill of the SD method to predict multivariate wave climate, a validation analysis from 2000 to 2013 period is performed, comparing the estimations from the statistical downscaling model against the parameters obtained from the quasi-observations (GOW wave data).

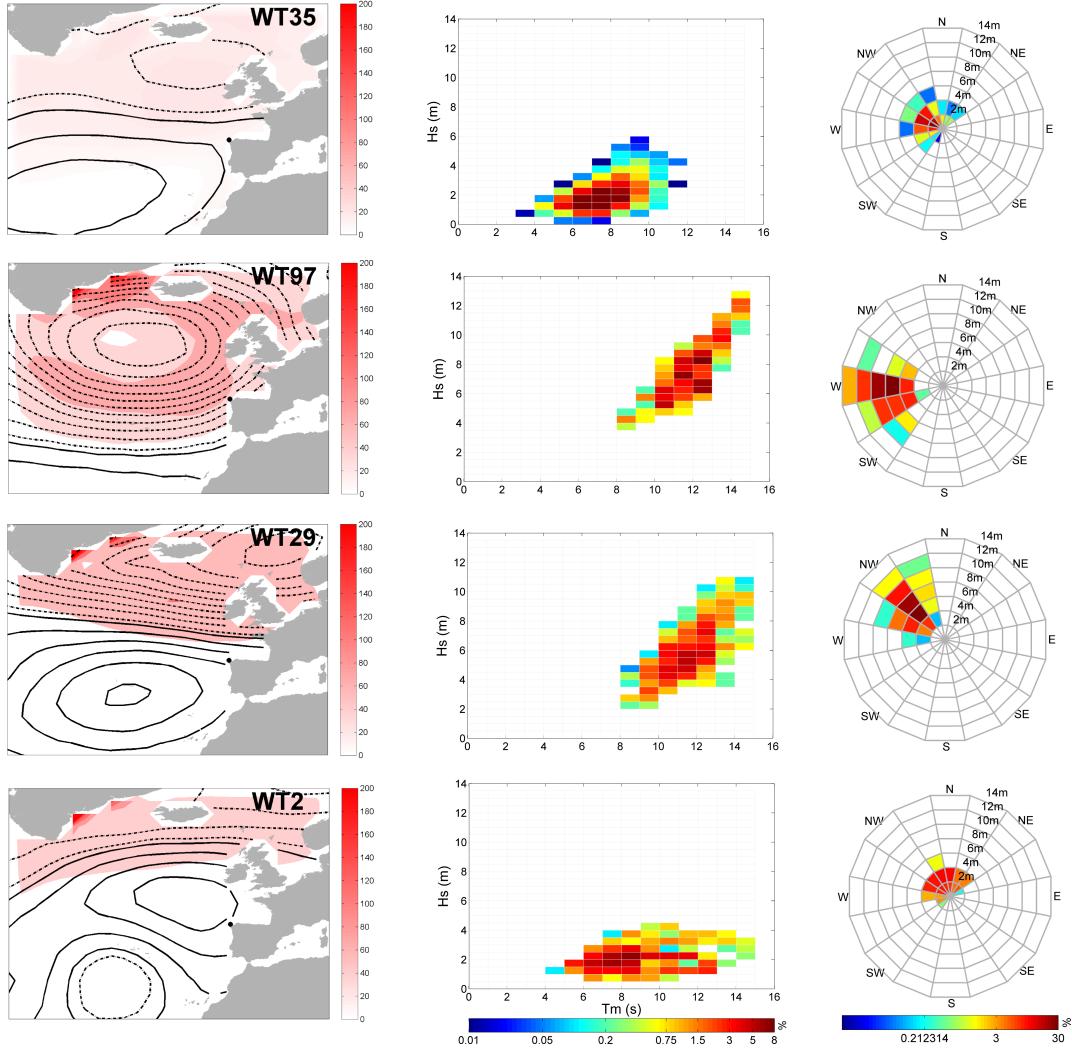


Figure 3.6: Several patterns (WT35, WT100, WT29, and WT2) from the WT classification shown in Figure 3.4) with the associated distribution of hourly significant wave height and mean period and distribution of the significant wave height and mean direction at GA location. The contours represent the SLP field (dashed below and continuous over 1013 hPa) and the red scale represents the SLPG

The mean and 95 percentile of H_s (H_{p95}), T_m , $H_s^2 T_m$, and mean wave energy flux direction (θ_{FE}) parameters are validated using the corresponding sea-state parameter distribution associated with each WT during the calibration period. Figures 3.7 and 3.8 show the comparison at the west Irish and northwest Spanish locations, respectively. The simulated monthly wave climate from the SD model is able to reproduce the quasi-real data, even for local maxima and minima monthly values of all the sea-state parameters analyzed. Although some discrepancies can be found for some specific months, the interannual variability of all these sea-state parameters is well reproduced for the two locations studied. The correlation coefficient (ρ), root mean square error (RMS), the scatter index (SI) and the bias are computed for each validated variable. It can be observed that the range of the correlation coefficient is between 0.80 and 0.97. The

RMS is about 0.3 m for H_s , 0.3 s for T_m , $30 \text{ m}^2\text{s}$ for $H_s^2T_m$, and 11° for θ_{FE} . The largest differences are found for the 95 percentile of H_s (RMS=0.81 at IR location and RMS=0.78 at GA location) and θ_{FE} (RMS=12.48 at IR location and RMS=9.34 at GA location).

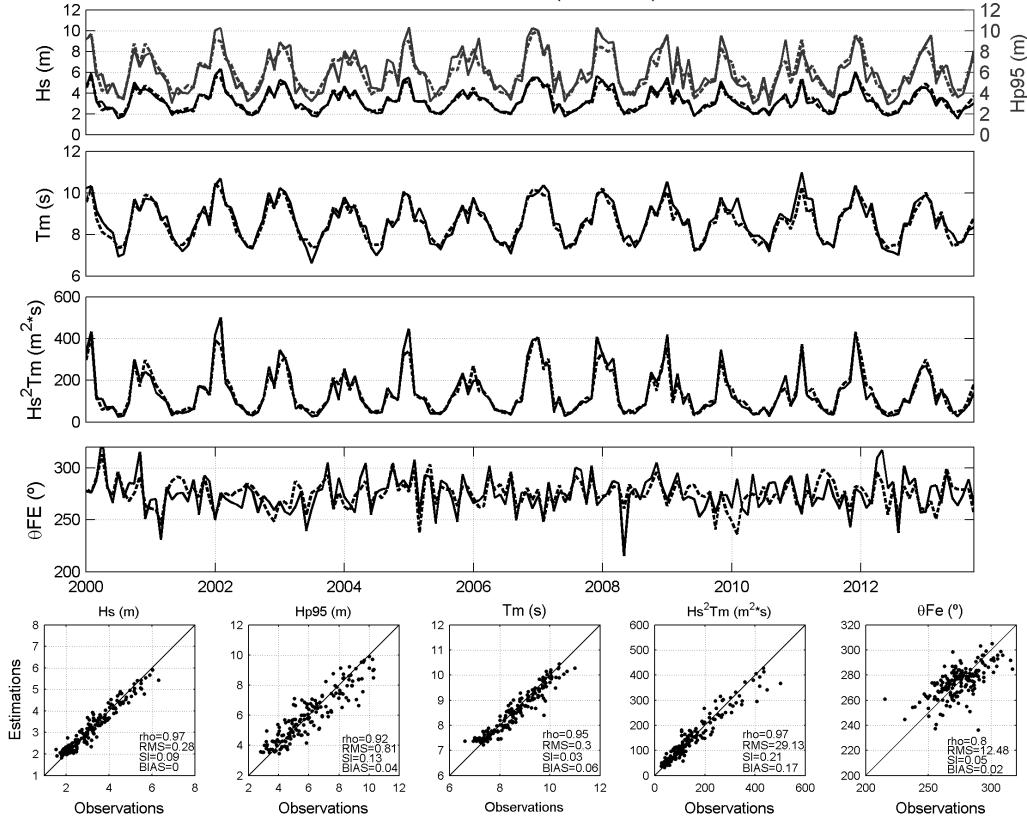


Figure 3.7: Time series comparison and scatterplots of the monthly sea-state parameters: H_s , $Hp95$, T_m , $H_s^2T_m$, θ_{FE} in the period 2001–2009 at the IR location. Solid lines show the GOW hindcast time series. Dashed lines represent the monthly parameters obtained from the downscaling framework proposed

3.4. Applications of the statistical downscaling

A wave climate characterization to better understand the drivers of the local predictand is presented. Besides, this method also provides a useful tool to obtain local wave climate outside the calibration period. A wave hindcast for the whole twentieth century and for a short-term period (last winter) or wave climate projections are described.

3.4.1. Wave climate characterization

Besides obtaining the most representative synoptic situations in the NE Atlantic, the organized atmospheric classification provides the possibility of representing a local wave

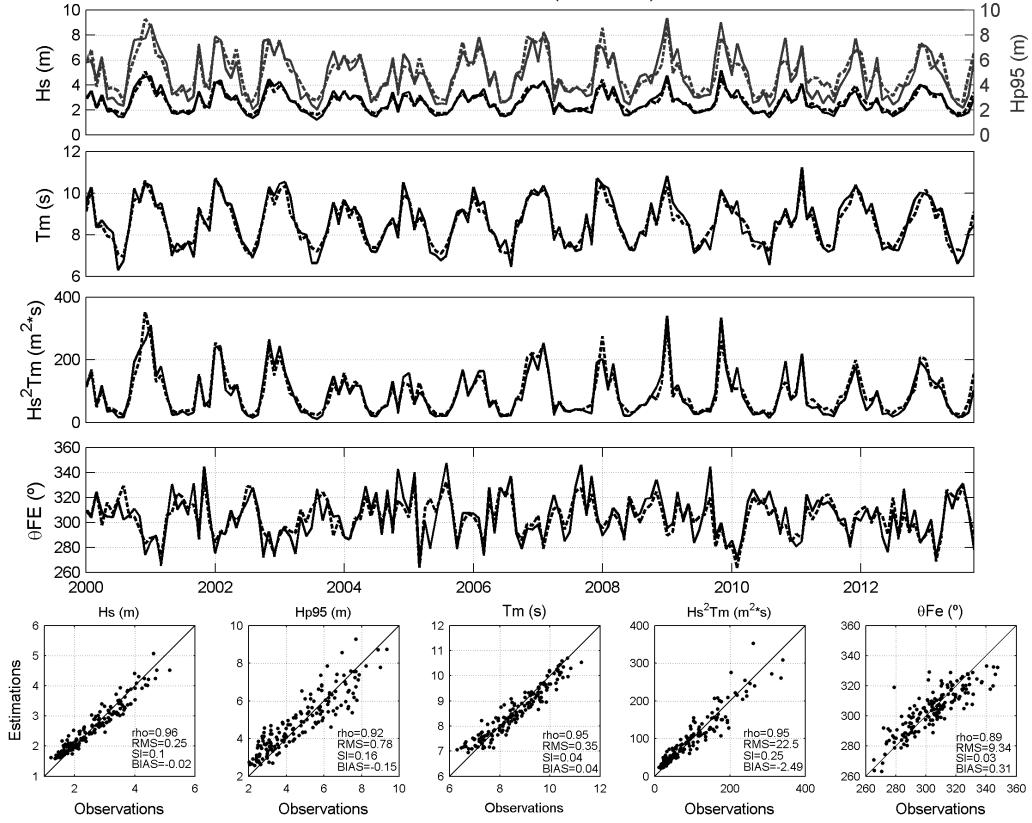


Figure 3.8: Time series comparison and scatterplots of the monthly sea-state parameters: H_s , H_{p95} , T_m , $H_s^2 T_m$, θ_{FE} in the period 2001–2009 at the GA location. Solid lines show the GOW hindcast time series. Dashed lines represent the monthly parameters obtained from the downscaling framework proposed

climate variable at a particular location on the 2-D lattice by projecting the variable value associated with each WT map. A connection between the circulation patterns on the North Atlantic Ocean and the wave climate in both locations is, therefore, established. Figure 3.9 shows the mean and standard deviation of H_s and θ_{FE} for each WT cluster at the IR and GA locations.

Larger mean significant wave heights, usually associated with high variances, are related to weather types with intense low-pressure centers at both bottom corners of the lattice. In the case of the Irish location, the patterns with larger waves correspond to positive NAO modes, with an intense low-pressure center around Iceland (left bottom WTs in the lattice). In the case of the Spanish location, the highest energetic waves can be associated with both, the standard positive NAO pattern and the positive EA pattern, showed in the WTs at the lower right corner of the lattice (i.e. the WT97 described previously as a specific winter pattern). EA WTs generate high energetic waves with a west-southwest mean direction, due to the fact that these spatial patterns are related with westerly winds, while NAO WTs are associated with slightly lower energetic waves with a northwest direction. The different wave conditions at both locations associated

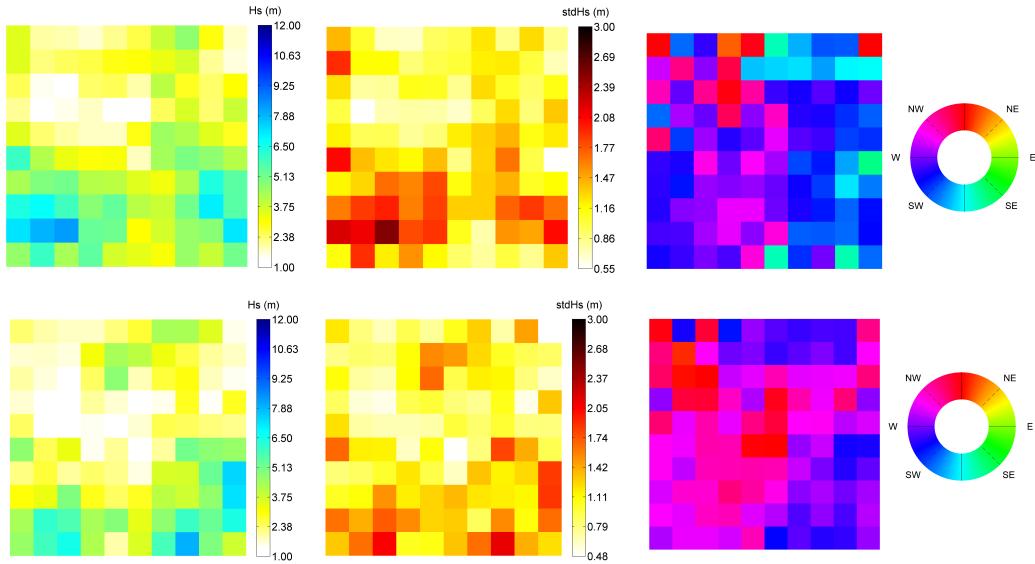


Figure 3.9: Wave climate characterization at the (*top*) west Irish location and (*bottom*) northwest Spanish location associated with WT classification (shown in Figure 3.4). (*left*) The mean significant wave height (units in m), (*middle*) standard deviation of the significant wave height (units in m), and (*right*) mean wave energy flux direction (units in $^{\circ}$) associated with each WT

with these NAO and EA patterns reflect that a large fraction of wave anomalies in the North Atlantic Ocean, mainly in the northern part, is explained by NAO; while the high fraction of the rest of anomalies in the southern part is related to EA (Woolf 2002). In the case of waves associated with the predominant summer patterns, located in the middle of the KMA lattice, a north mean energy flux direction reflects frequent high-pressure conditions that generate waves coming from north-northeast direction.

Figure 3.10 shows the bidimensional distribution of H_s and θ_m for the 100 WTs at the west Irish location. The WTs most clearly detected are the ones corresponding to the largest energetic sea states. As it is previously described, largest significant wave heights are associated with considerable low-pressure patterns, located at the corners of the KMA lattice. The location of the low-pressure center in the North Atlantic Ocean distinguishes the wave origin which it is mainly reflected in the wave direction. For example, northward low-pressure centers (positive NAO patterns) generate waves coming from the west at the Irish location and waves from the northwest at the Spanish location (e.g. WT19 or WT29). Higher periods associated with these WTs are also detected at the Spanish location due to a farther distance from the storm generation area (the associated distributions of H_s and T_m are not shown). Southward low-pressure centers (positive EA patterns) are linked to waves coming from the southwest at the Irish location or from the west at the Spanish location (e.g. WT87 or WT97). This southerly shift in wave direction is related to an EA positive pattern (Charles et al. 2012). Wave energy is more significant if the position of these centers is closer to the wave

location (WT29 generates more energetic waves at Irish location, while WT97 generates more energetic waves at Spanish location). Neutral patterns are associated with low energetic waves coming (low values of H_s and T_m) from a wider range of directions, due to the fact that the predictor characterization of regional patterns while these waves are generated by local phenomena. Several WTs represent particular situations, e.g., WT1, is characterized by a high-pressure center at the latitude of the Irish location, which generates local waves from the north at this location. These differences in the wave direction are detected in the wave climate characterization by means of the mean value of the significant wave height and mean energy flux direction associated with each WT.

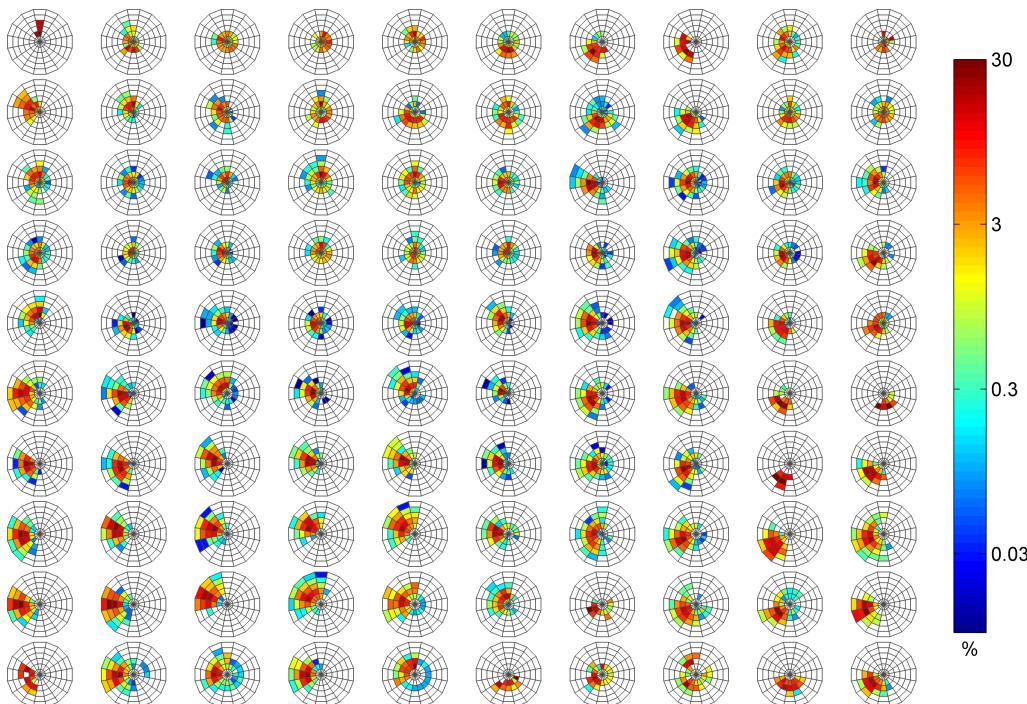


Figure 3.10: Distribution of H_s and θ_m associated with each weather type at the west Irish location (shown in Figure 3.4). The units of the radial distance are in m with the same scale as in Figure 3.6 (H_s increments are 2.0 m)

3.4.2. Wave climate hindcast

A long-term wave climate historical reconstruction and a short-term wave hindcast in winter 2013–2014 require historical or forecasted information of the synoptic circulation systems.

The local long-term wave climate historical reconstruction is derived from the twentieth century atmospheric reanalysis SLP data (20CR, Compo et al. 2011). The 20CR is a global reanalysis spanning the twentieth century, created by the NOAA ESRL/PSD. The SLP fields are available at 6 hourly temporal and 2° horizontal resolution. In

this reanalysis, pressure observations have been combined with a short-term forecast ensemble of an NCEP numerical weather prediction model. The use of the SLP fields from 20CR as a historical predictor into the SD model is validated by assessing the occurrence rates of the hundred WTs during the calibration period against the NCEP-NCAR reanalysis-I (Figure 3.5b). Once the pressure data source is considered suitable, the probability of occurrence of the WTs throughout the 20th century is estimated to reconstruct the historical wave climate.

Figure 3.11a shows the monthly mean reconstructed H_s at the two study sites since 1900. Figure 3.11b shows the comparison of winter H_s (DJFM) between the statistically downscaled 20CR (black) and the SD NCEP reanalysis-I (blue). This comparison reveals a good agreement between the wave hindcasts and a high skill to simulate the climate variability. The GA location (2.63 m mean H_s and 3.44 m winter mean H_s for 1900–2010) does not present such high wave climatologies as IR location (3.24 and 4.24 m, respectively). An interesting point is that, while GA location shows homogeneous interannual variations with maxima along the whole period, IR largest values are observed during the period 1970–2000. Several studies have already accomplished a wave climate reconstruction from 20CR on North Atlantic. Bertin et al. (2013) developed a dynamic downscaling with the numerical model WAVEWATCH III forced with wind and ice fields from 20CR. Wang et al. (2012) obtained reconstructed waves by a regression SD model using 20CR SLP as predictor. For comparison, the mean and linear trends of H_s from the proposed SD approach during several periods were assessed. We have found that our mean H_s at the two target locations are similar to those from Bertin et al. (2013) for the period 1900–2008 (3.2 m at IR and 2.6 m at GA) but differ from those of Wang et al. (2012) for the period 1958–2001 (2.9 m at IR and 2.4 m at GA). Lower estimates are obtained from the SD model of Wang et al. (2012), nevertheless our mean H_s are similar to the dynamically downscaled waves from MSC50 (Cox and Swail 2001) for the same period (3.2 m at IR and 2.6 m at GA). On the other hand, the analysis of the H_s linear trends reveals an increase for 1958–2001 (0.5 and 0.15 cm/yr at IR and GA locations, respectively) similar to those found by the SD model by Wang et al. (2012), 0.45 cm/yr at IR and 0.10 cm/yr at GA, and the MSC50 data (0.50 cm/yr at IR and 0.10 cm/yr at GA), but our estimated trend at IR location (0.019 cm/yr) for the 20th century differs from Bertin et al. (2013), who found higher positive trends on the Northeast Atlantic (0.6 cm/yr at IR). It is noteworthy that after the period 1958–2000 with an increase in wave intensity, estimated trends over the last 30 years (1980–2009) are significantly negative at the two studied points for both, mean and winter H_s (-0.23 cm/yr mean H_s trend and -1.78 cm/yr winter H_s trend at IR location and -0.17/-0.96 cm/yr, respectively, at the GA location). In order to better understand these trends, the multidecadal and interannual wave variability driven by the NAO (Woolf 2002) was

analyzed. According to Bertin et al. (2013), we have found a large positive correlation with winter NAO (Jones et al. 1997) at the IR point in the NE Atlantic (0.64 Pearson correlation, Figure 3.11b) and a weak positive correlation at the GA location in South-East Atlantic (0.035 Pearson correlation). The stronger relation between NAO and waves at IR location explains the multidecadal wave climate variability. A decrease of wave height coincides with a decline of the NAO to the 1960s, an increase of wave height in the period 1958–2000 with the NAO rise to early 1990s. Therefore, the decrease in the last 30 years could be influenced by the recent smaller NAO fall.

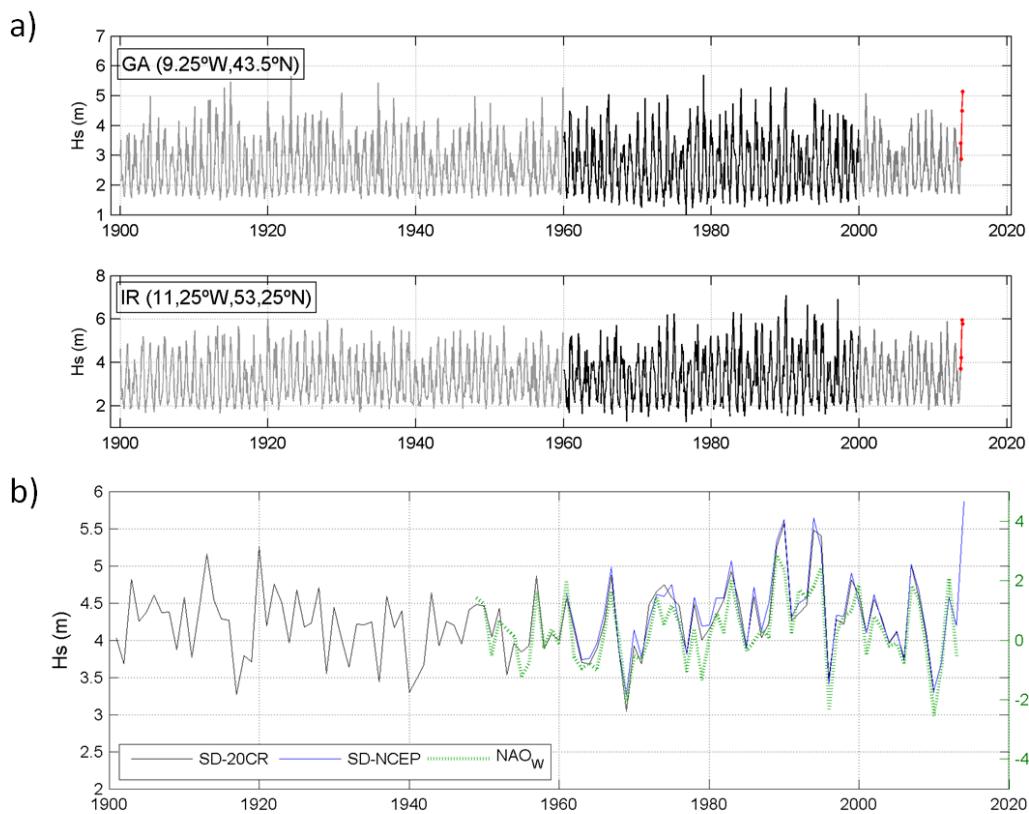


Figure 3.11: (a) Time series of the monthly H_s historical reconstruction from 20CR (1900–1960), NCEP-NCAR reanalysis-I for the calibration period (1960–2000) and the validation period (2001–2013) and the winter 2013–2014 (red line) for the two target points. (b) Winter H_s (DJFM) reconstruction from 20CR (black) and NCEP-NCAR reanalysis-I (blue) at IR location and the NAO winter climate index (green)

The SD method provides a tool to update wave climate information of numerical outcomes with low computational cost. Here, we have hindcasted the winter 2013–2014, a particularly large winter with a strong jet stream driving across the Atlantic and causing large wave storms affecting Portugal and Spain. Red lines in Figure 3.11 indicate the estimated monthly mean H_s . The larger waves which arrive to the European coast in winter 2013–2014 are shown, reaching 5 m, at GA location and 6 m at IR location. We note that the SD model can also be used as a forecast tool in a similar way.

3.4.3. Wave climate projections

The future projections of local waves from the outputs of a GCM under different climate change scenarios can be obtained applying the SD model. We use the EC-Earth GCM (Hazeleger et al. 2012), from a European consortium with collaborations of 27 Institutions. EC-Earth model is formed by the Integrated Forecast System (IFS) of the European Centre for Medium Range Weather Forecasts (ECMWF). Here we use the SLP data of the CMIP5 experiments, called historical for recent past conditions and RCPs (Representative Concentration Pathways, Moss et al. 2010) for the future runs. The selected RCPs included one mitigation scenario leading to a very low forcing level (RCP2.6) and one very high baseline emission scenario (RCP8.5), leading to high greenhouse concentration levels. Perez et al. (2014b) analyzed numerous CMIP3 and CMIP5 GCMs and found that EC-Earth is one of the most skilled in the North Atlantic region. Moreover, the EC-Earth model is able to reproduce the occurrence of the synoptic atmospheric conditions during the historical period (Figure 3.5b).

Figure 3.12 shows the resulting box plots of the estimated winter H_s of the SD model for historical, present, and projected 30 year periods at the two studied locations. A slight decrease on future winter H_s relative to the present climate time slice is detected, being winter H_s from RCP8.5 higher than RCP2.6. Ensemble CMIP5-based statistical wave projections also provide a general decrease of annual H_s in the midlatitudes of the North Atlantic for the period 2080–2099 relative to the period 1980–1999 for the RCP8.5 scenario (Wang et al. 2014). It is interesting to point out the projected values in 2070–2099 at GA and IR locations do not show variations on mean and variance different to those reconstructed in the past.

3.5. Summary and conclusions

A statistical downscaling framework to project wave climate is proposed based on weather typing. The statistical relation is established between the atmospheric predictor, defined by the SLP fields and the squared SLP gradients, and the local wave climate. The model is applied in two locations on the Atlantic coast of Europe: west Ireland and northwest Spain. Waves in these two locations are generated by storms in the North Atlantic. Therefore, the spatial domain of the predictor is defined taking into account the storm activity in this area. Three days are considered as the mean period representative of the recent atmospheric conditions responsible for waves arriving at the studied locations. Three days mean predictor fields are calculated on a day-to-day basis, associated with the last day. PCA is applied to this daily predictor to reduce the

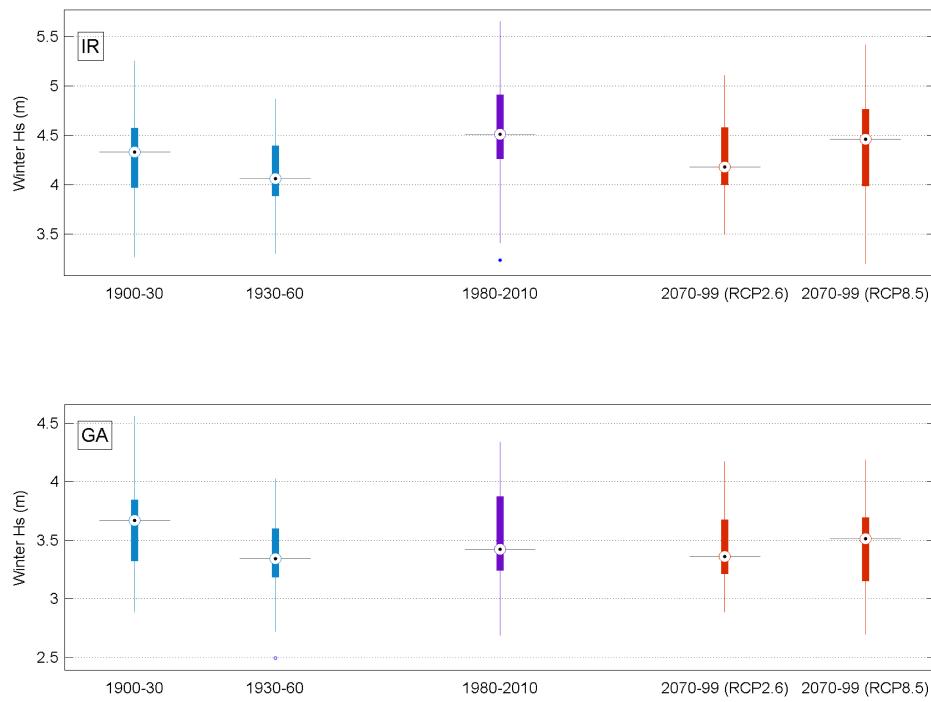


Figure 3.12: Box plots of H_s winter (DJFM) for present climatology (1980–2010), historical reconstructed periods (1900–1930, 1930–1960), and future projected climate scenarios (2070–2100) for the EC-Earth model. On each box, the central mark is the median, the edges of the box are the lower (Q1) and upper (Q3) quartiles (interquartile range, IQR), and the whiskers extend to the higher values, within the range defined by $Q1-1.5(\text{IQR})$ and $Q3+1.5(\text{IQR})$

data dimensionality and simplify the application of the classification technique. Weather types are obtained using KMA technique, with a postorganization onto a bidimensional lattice by a similarity criterion. The distribution of hourly sea states associated with each weather pattern is statistically established.

The method has been validated and several applications are shown. The following features of the proposed method are relevant: (1) The SD method is able to integrate different time and spatial scales of the wave generation and propagation processes. Statistical relationships between predictor and predictand are solved integrating 3 days history in the daily predictor over the generation area using WT approach. (2) The weather typing approach provides a physical explanation of the relation between local waves and regional synoptic atmospheric conditions. The application of the SD model at two locations northward and southward East Atlantic Ocean reveals clear associations with specific low/high-pressure systems in the Atlantic Ocean. (3) The SD method provides multivariate results of wave climate. Univariate or bivariate empirical probability density functions of different sea-state parameters are estimated using this SD

method. Other statistics, besides the mean value, can be predicted. Further research is needed to extend this approach to statistically model extreme values conditioned to a particular WT, following for instance the method proposed by Izaguirre et al. (2012).

The applied SD model provides these conclusions:

- The local multivariate wave climate can be characterized based on a physical relation with atmospheric conditions.
- The model validation proves to reproduce the seasonal and interannual variability of the monthly mean and 95 percentile of H_s , T_m , $H_s^2 T_m$, and (θ_{FE}) . Therefore, the proposed SD method is a useful tool for coastal impact assessment.
- The SD model is able to produce long historical reconstructions. SLP forcing from 20CR reanalysis is used to reconstruct local waves through the 20th century, obtaining wave statistics and trends in agreement with previous works by other authors (Bertin et al. 2013; Wang et al. 2012). Moreover, the obtained results are similar to those obtained by dynamical downscaling techniques (Bertin et al. 2013; Cox and Swail 2001) that take into account the complex processes of wave generation, propagation, and dissipation numerically. The advantage of the SD method is the low computational time to characterize wave climate without information of wind fields and bathymetry.
- The update of the local wave hindcast in the last winter shows the applicability of the SD approach for seasonal forecast.
- The SD model is a useful tool to get wave climate multimodel ensemble projections with low computational cost. A negative trend has been detected for the end of this century, in accordance with Wang et al. (2014). Nevertheless, the detected decrease is similar to modeled historical variations in the 20th century.
- Regarding future projections, we should note the limitations of the SD model from the implied assumptions of the statistical approach: A stationary statistical relationship and projected changes should lie within the range of the natural variability. SD model is unable to generate local waves from exceptional weather conditions that are not registered in the past.
- The application of this statistical method to downscale wave climate at different locations around the globe required to adapt the predictor spatial domain to the area of influence of the wave energy reaching the particular location of interest. Besides, the number of days to calculate the mean predictor fields needs to reflect the time wave energy takes to reach that particular location, strongly related to the storminess over the ocean basin.

Chapter 4

Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region

Abstract

One of the main sources of uncertainty in estimating climate projections affected by global warming is the choice of the global climate model (GCM). The aim of this study is to evaluate the skill of GCMs from CMIP3 and CMIP5 databases in the north-east Atlantic Ocean region. It is well known that the seasonal and interannual variability of surface inland variables (e.g. precipitation and snow) and ocean variables (e.g. wave height and storm surge) are linked to the atmospheric circulation patterns. Thus, an automatic synoptic classification, based on weather types, has been used to assess whether GCMs are able to reproduce spatial patterns and climate variability. Three important factors have been analyzed: the skill of GCMs to reproduce the synoptic situations, the skill of GCMs to reproduce the historical inter-annual variability and the consistency of GCMs experiments during twenty-first century projections. The results of this analysis indicate that the most skilled GCMs in the study region are UKMO-HadGEM2, ECHAM5/MPI-OM and MIROC3.2(hires) for CMIP3 scenarios and ACCESS1.0, ECEARTH, HadGEM2-CC, HadGEM2-ES and CMCC-CM for CMIP5 scenarios. These models are therefore recommended for the estimation of future regional

This chapter is based on Perez et al. (2014b): Perez, J., Menendez, M., Mendez, F. J., Losada, I. J. (2014). Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region. *Climate Dynamics*, 43(9-10), 2663–2680. <http://doi.org/10.1007/s00382-014-2078-8>

multi-model projections of surface variables driven by the atmospheric circulation in the north-east Atlantic Ocean region.

4.1. Introduction

Changes in the Earth's climate throughout the twenty-first century and their potential impacts have become a global concern during the last years. In this context, the World Meteorological Organization (WMO) and the United Nations Environment Programme (UNEP) established the Intergovernmental Panel on Climate Change (IPCC) in 1988. The IPCC has produced a series of reports which show abundant evidence of changes in the global climate system during the twenty-first century. Moreover, most of these changes are larger than those observed during the twentieth century (AR4, IPCC 2007).

The output of global climate models (GCMs) has been one of the most important sources of information since the first IPCC assessment in 1990. The outcomes from GCMs are extensively used in many studies to understand changes in climate dynamics and determine the affects of climate change on a range of impacts. Furthermore, GCMs are used as the basis for many dynamical and statistical downscaling experiments, providing refined information on variables that GCMs do not simulate directly, such as waves or storm surge (e.g. Marcos et al. 2011) or do not simulate at enough resolution (e.g. snow or precipitation). One of the main challenges associated with using GCMs is model structural uncertainty. Notwithstanding the uncertainty of the forcings for the climate change scenarios, the skill of different GCMs is determined by the different methods used to solve the equations that describe atmospheric and oceanic dynamics. A systematic evaluation of the performance of the models is, therefore, required to provide greater confidence in the use of GCMs.

One of the first opportunities for climate scientists to compare the skill of a large group of GCMs was phase 3 of the Coupled Model Intercomparison Project (CMIP3, Meehl et al. 2007). The archived data, officially known as WCRP-CMIP3 multi-model dataset, has been widely studied. For example, analysis of temperature simulations in Australia based on probability density functions (Maxino et al. 2008; Perkins et al. 2007) or studies of precipitation over the Iberian Peninsula (Errasti et al. 2011; Nieto and Rodríguez-Puebla 2006). In these studies, different statistical measures (e.g. RMSE, KS-test, BIAS, correlation indices) are used for objective spatial and quantitative comparison. There are even some studies that aggregate several statistical measures to form a single metric (e.g. Gleckler et al. 2008). Similar studies based on later coordinated multi-model experiments have helped to the process of ongoing improvement of the models. For example, the analysis of the two generations of models used in ENSEMBLES project

(Van Der Linden and Mitchell 2009) conducted by Brands et al. (2011). Recently, the efforts to reduce model uncertainty have led to a new generation of global climate models called Earth System Models as they incorporate the capability to explicitly represent biogeochemical processes that interact with the physical climate (Flato 2011). These models are the basis of the fifth phase of the Coupled Model Intercomparison Project (CMIP5, Taylor et al. 2012) constituting the most current set of coordinated climate model experiments. Several authors have analyzed subsets of CMIP5 models obtaining different rankings of models; e.g. Yin et al. (2013) studied the precipitation over South America, Brands et al. (2013) analyzed several variables in Europe and Africa and Su et al. (2013) studied precipitation and temperature over the Tibetan Plateau.

The main aim of this study is to define a methodology for evaluating the quality of GCMs in a region. The method can therefore assist GCM users in the choice of the most appropriate model to study changes in climate dynamics, to evaluate impacts or to downscale surface variables. A common procedure to evaluate the ability of GCMs is to compare outputs of model simulations against historical reconstructions (reanalysis) or observations. This can be achieved by analyzing differences between mean climatologies or even the whole probability density functions. Recent works have evaluated the skill of GCMs to reproduce synoptic climatology (e.g. Belleflamme et al. 2013; Lorenzo et al. 2011) by using classification methods. The circulation classification method has demonstrated to be a useful and computational efficient tool for the validation of GCMs (Huth 2000). The study of synoptic climatology from circulation patterns or weather types takes into account the natural climate variability and allows the evaluation of spatial relations between different locations.

In this work, we characterize the synoptic patterns from sea level pressure (SLP) fields. SLP provides information of surface climate conditions and it has been found to be a better predictor for downscaling purposes than other variables (e.g. Busuioc et al. 2001; Frías et al. 2006; von Storch et al. 1993). Taking this into account, we have evaluated the performance of a range of GCMs within the north-east Atlantic Ocean region. The methodology, based on weather types and statistical metrics, analyzes not only the skill of the GCMs to reproduce mean climatologies but also the interannual variability. Moreover, the consistency of future simulations is also evaluated. This method has been applied to 68 models from CMIP3 to CMIP5, providing useful information about the quality of the GCMs over the European region.

The rest of the paper is organized as follows. In Section 4.2, the data from the model reanalysis databases used for comparison and the analyzed GCMs are presented. Section 4.3 explains the methodology that has been developed, describing the analyzed region, the weather type classification approach and the statistical analysis of the performance

of the GCMs. The study is completed with the presentation of the results in Section 4.4, and the conclusions in Section 4.5.

4.2. Data

4.2.1. Atmospheric reanalysis data

The evaluation of the performance of the GCMs requires the comparison against historical observations. Atmospheric reanalyses are long historical climate reconstructions that can be considered to be quasi-real data as they integrate multiple instrumental measurements and have been widely validated against independent observations. Nowadays, there are several global atmospheric reanalysis databases. In this work, we use 6-hourly SLP data obtained from the three global reanalysis covering the most extensive period of the twentieth century: NCEP/NCAR Reanalysis I (NNR, Kalnay et al. 1996), ECMWF 40 year Reanalysis (ERA-40, Uppala et al. 2005) and NOAA-CIRES twentieth Century Reanalysis V2 (20CR, Compo et al. 2011).

NNR (1948-present), created by the National Centers for Environmental Prediction (NCEP) and National Center for Atmospheric Research (NCAR) has been widely used by the scientific community. This global reanalysis is generated by numerical simulation using models similar to those used for weather forecasting, and includes a data assimilation process. ERA-40 (1957–2002) was created by the European Centre for Medium-Range Weather Forecasts (ECMWF), with one version of the Integrated Forecasting System (IFS). 20CR (1871–2010) has been created by the NOAA ESRL/PSD (National Oceanic and Atmospheric Administration Earth System Research Laboratory/ Physical Sciences Division). In this reanalysis, pressure observations have been combined with a short-term forecast ensemble of an NCEP numerical weather prediction model. In this study, NNR has been selected to characterize the synoptic patterns of atmospheric circulation because it has been widely validated by the scientific community, covers a large historical period and is an up to date database, nevertheless, ERA-40 and 20CR reanalyses have also been compared with the GCMs.

4.2.2. Global climate models

In this study, the available information on daily sea level pressure from 68 GCMs has been catalogued and subsequently stored. These models have been divided into two groups depending on which generation of scenarios have been simulated. One group includes 26 models from CMIP3 and ENSEMBLES projects and the other one includes

Model	Institution	Country	Atmospheric resolution (lat x lon, number of layers)	Runs B1-A1B-A2
BCCR-BCM2.0	Bjerknes Centre for Climate Research	Norway	1.9° x 1.9°, L31	1-1-1
CCSM3	National Center for Atmospheric Research	USA	1.4° x 1.4°, L26	2-2-2
CGCM3.1(T47)	Canadian Centre for Climate Modelling and Analysis	Canada	2.8° x 2.8°, L31	0-3-0
CGCM3.1(T63)	Canadian Centre for Climate Modelling and Analysis	Canada	1.9° x 1.9°, L31	1-1-0
CNRM-CM3	Centre National de Recherches Météorologiques	France	2.8° x 2.8°, L45	1-1-1
CNRM-CM33	Centre National de Recherches Météorologiques	France	1.9° x 1.9°, L19	0-1-0
CSIRO-MK3.0	CSIRO Atmospheric Research	Australia	1.9° x 1.9°, L18	1-1-1
CSIRO-MK3.5	CSIRO Atmospheric Research	Australia	1.9° x 1.9°, L18	1-1-1
ECHAM5/MPI-OM	Max-Planck-Institute for Meteorology	Germany	1.9° x 1.9°, L31	3-4-3
ECHAM5C/MPI-OM	Max-Planck-Institute for Meteorology	Germany	3.75° x 3.75°, L19	0-3-0
ECHO-G	University of Bonn	Germany	3.9° x 3.9°, L19	1-1-1
EGMAM	Freie Universitaet Berlin, Institute for Meteorology	Germany	3.75° x 3.75°, L39	3-3-3
EGMAM2	Freie Universitaet Berlin, Institute for Meteorology	Germany	3.75° x 3.75°, L39	0-1-0
FGOALS-g1.0	Institute of Atmospheric Physics	China	2.8° x 2.8°, L26	3-3-0
GFDL-CM2.0	Geophysical Fluid Dynamics Laboratory	USA	2° x 2.5°, L24	1-1-1
GISS-AOM	Goddard Institute for Space Studies	USA	3° x 4°, L12	1-1-0
GISS-ER	Goddard Institute for Space Studies	USA	4° x 5°, L20	1-1-1
INGV-SXG	Istituto Nazionale di Geofisica e Vulcanologia	Italy	1.12° x 1.12°, L19	0-1-0
INM-CM3.0	Institute of Numerical Mathematics	Russia	4° x 5°, L21	1-1-1
IPSL-CM4	Institut Pierre Simon Laplace	France	2.5° x 3.75°, L19	1-1-1
IPSL-CM4v2	Institut Pierre Simon Laplace	France	2.5° x 3.75°, L19	0-3-0
MIROC3.2 (hires)	Center for Climate System Research, NIES and RCGC	Japan	1.12° x 1.12°, L56	1-1-0
MRI-CGCM2.3.2	Meteorological Research Institute	Japan	2.8° x 2.8°, L30	1-1-1
PCM	National Center for Atmospheric Research	USA	2.8° x 2.8°, L18	2-0-1
UKMO-HadCM3C	Met Office Hadley Centre	UK	2.5° x 3.75°, L38	0-2-0
UKMO-HadGEM2	Met Office Hadley Centre	UK	1.25° x 1.9°, L38	0-3-0

TABLE 4.1: Analyzed CMIP3 and ENSEMBLES GCMs names, institutions, countries, atmospheric resolutions and runs

42 CMIP5 models. Tables 4.1 and 4.2 show the names of the models that have been used as well as the research centers and countries that they belong to, the atmospheric resolution and the number of future simulations analyzed (runs). Data from 1961 to 1990 (reference period) have been used to characterize recent past conditions and projections from 2010 to 2100 have been taken to represent future conditions, as they are time periods available from most models.

The simulations analyzed in the CMIP3 and ENSEMBLES models are called 20C3M (Twentieth Century Climate in Coupled Models) for recent past conditions and SRES B1, SRES A1B and SRES A2 (Special Report on Emission Scenarios, Nakicenovic and Swart 2000) for future scenarios. The three selected scenarios are generally taken to represent low, medium and high CO₂ concentrations, respectively. A total of 44 20C3M simulations, 43 of A1B, 19 of A2 and 26 of B1 are studied. Eighteen models belong to CMIP3 and eight models (CNRM-CM33, ECHAM5C/MPI-OM, EGMAM, EGMAM2, IPSL-CM4v2, UKMO HadCM3C and UKMO-HadGEM2) belong to the ENSEMBLES project. Data are obtained from the results of the models sent to the Program for Climate Model Diagnosis and Intercomparison (PCMDI) at the Lawrence Livermore National Laboratory in the USA (http://www-pcmdi.llnl.gov/ipcc/about_ipcc.php) and from the CERA database of the World Data Center for Climate (WDCC) in Hamburg (<http://cera-www.dkrz.de/CERA/>).

Model	Institution	Country	Atmospheric resolution (lat x lon, number of layers)	Runs RCP2.6-RCP4.5 -RCP6.0-RCP8.5
ACCESS1.0	CSIRO-BOM	Australia	1.25° x 1.9°, L38	0-1-0-1
ACCESS1.3	CSIRO-BOM	Australia	1.25° x 1.9°, L38	0-1-0-1
BCC-CSM1.1	Beijing Climate Center	China	2.8° x 2.8°, L26	1-1-1-1
BCC-CSM1.1(m)	Beijing Climate Center	China	1.12° x 1.12°, L26	1-1-1-1
BNU-ESM	College of Global Change and Earth System Science	China	2.8° x 2.8°, L26	1-1-0-1
CanCM4	Canadian Centre for Climate Modelling and Analysis	Canada	2.8° x 2.8°, L35	0-10-0-0
CanESM2	Canadian Centre for Climate Modelling and Analysis	Canada	2.8° x 2.8°, L35	5-5-0-5
CCSM4	National Center for Atmospheric Research	USA	0.94° x 1.25°, L26	3-3-3-3
CESM1(BGC)	Community Earth System Model Contributors	USA	0.94° x 1.25°, L26	0-1-0-1
CESM1(CAM5)	Community Earth System Model Contributors	USA	0.94° x 1.25°, L26	1-1-1-1
CESM1(FASTCHEM)	Community Earth System Model Contributors	USA	0.94° x 1.25°, L26	0-0-0-0
CMCC-CESM	Centro Euro-Mediterraneo per I Cambiamenti Climatici	Italy	3.71° x 3.75°, L39	0-0-0-1
CMCC-CM	Centro Euro-Mediterraneo per I Cambiamenti Climatici	Italy	0.75° x 0.75°, L31	0-1-0-1
CMCC-CMS	Centro Euro-Mediterraneo per I Cambiamenti Climatici	Italy	1.9° x 1.9°, L95	0-1-0-1
CNRM-CM5	Centre National de Recherches Météorologiques	France	1.4° x 1.4°, L31	1-1-1-1
CSIRO-Mk3.6.0	CSIRO-QCCCE	Australia	1.9° x 1.9°, L18	10-10-10-10
EC-EARTH	EC-EARTH consortium	Various	1.1° x 1.1°, L62	1-5-0-5
FGOALS-g2	LASG-CESS	China	2.8° x 2.8°, L26	1-1-0-1
FGOALS-s2	LASG-CESS	China	1.7° x 2.8°, L26	1-0-1-3
GFDL-CM3	NOAA Geophysical Fluid Dynamics Laboratory	USA	2° x 2.5°, L48	1-0-1-1
GFDL-ESM2G	NOAA Geophysical Fluid Dynamics Laboratory	USA	2° x 2.5°, L48	1-1-1-1
GFDL-ESM2M	NOAA Geophysical Fluid Dynamics Laboratory	USA	2° x 2.5°, L48	1-1-1-1
GISS-E2-H	NASA Goddard Institute for Space Studies	USA	2° x 2.5°, L40	0-0-0-0
GISS-E2-R	NASA Goddard Institute for Space Studies	USA	2° x 2.5°, L40	0-2-0-0
HadCM3	Met Office Hadley Centre	UK	2.5° x 3.75°, L19	0-10-0-0
HadGEM2-AO	Met Office Hadley Centre	UK	1.25° x 1.9°, L38	1-1-1-0
HadGEM2-CC	Met Office Hadley Centre	UK	1.25° x 1.9°, L60	0-1-0-3
HadGEM2-ES	Met Office Hadley Centre	UK	1.25° x 1.9°, L38	4-4-4-3
INM-CM4	Institute for Numerical Mathematics	Russia	1.5° x 2°, L21	0-1-0-1
IPSL-CM5A-LR	Institut Pierre-Simon Laplace	France	1.9° x 3.75°, L39	4-4-1-4
IPSL-CM5A-MR	Institut Pierre-Simon Laplace	France	1.25° x 2.5°, L39	1-1-1-1
IPSL-CM5B-LR	Institut Pierre-Simon Laplace	France	1.9° x 3.75°, L39	0-1-0-1
MIROC-ESM	MIROC	Japan	2.8° x 2.8°, L80	1-1-1-1
MIROC-ESM-CHEM	MIROC	Japan	2.8° x 2.8°, L80	1-1-1-1
MIROC4h	MIROC	Japan	0.56° x 0.56°, L56	0-3-0-0
MIROC5	MIROC	Japan	1.4° x 1.4°, L40	3-3-1-3
MPI-ESM-LR	Max-Planck-Institut für Meteorologie	Germany	1.9° x 1.9°, L47	3-3-0-3
MPI-ESM-MR	Max-Planck-Institut für Meteorologie	Germany	1.9° x 1.9°, L95	1-1-0-0
MPI-ESM-P	Max-Planck-Institut für Meteorologie	Germany	1.9° x 1.9°, L47	0-0-0-0
MRI-CGCM3	Meteorological Research Institute	Japan	1.1° x 1.1°, L48	0-0-0-0
MRI-ESM1	Meteorological Research Institute	Japan	1.1° x 1.1°, L48	0-0-0-0
NorESM1-M	Norwegian Climate Centre	Norway	1.9° x 2.5°, L26	0-0-0-0

TABLE 4.2: Analyzed CMIP5 GCMs names, institutions, countries, atmospheric resolutions and runs

For the 42 CMIP5 models, the experiments analyzed are called historical for recent past conditions and RCP2.6, RCP4.5, RCP6.0 and RCP8.5 (Representative Concentration Pathways, Moss et al. 2010) for the future. The four selected RCPs included one mitigation scenario leading to a very low forcing level (RCP2.6), two medium stabilization scenarios (RCP4.5/RCP6.0) and one very high baseline emission scenario (RCP8.5) leading to high greenhouse concentration levels (van Vuuren et al. 2011). This makes a total of 136 historical simulations, 48 of RCP2.6, 83 of RCP4.5, 31 of RCP6.0 and 63 of RCP8.5. CMIP5 data are available through the Earth System Grid—Center for Enabling Technologies (ESG-CET), on the page (<http://pcmdi9.llnl.gov/>).

4.3. Methods

The methodology developed to study the skill of the GCMs is summarized in a diagram in Figure 4.1. Data from reanalysis and GCMs are collected first. The study area is

then defined and SLP fields are preprocessed to the spatial domain in the selected region (chart upper level). In order to get the estimated indicators of the performance of the GCMs, a weather type (WT) classification from the reanalysis data is carried out. The occurrence rate of each synoptic situation group is assessed from both the reanalysis data and the GCMs for several time periods (chart middle level). Finally, different statistical indices are computed to compare the occurrence rates (chart bottom level). The comparison between the observed and simulated historical WT frequency indicates the skill of the GCMs to simulate the recent past climate. The results of this comparison are used to analyze the similarity of the synoptic situations and the ability of the GCMs to reproduce the interannual variability. On the other hand, the comparison between the historical and future WT frequency from GCMs determine the simulated rates of change. These rates of change are used to analyze the consistency of future projections.

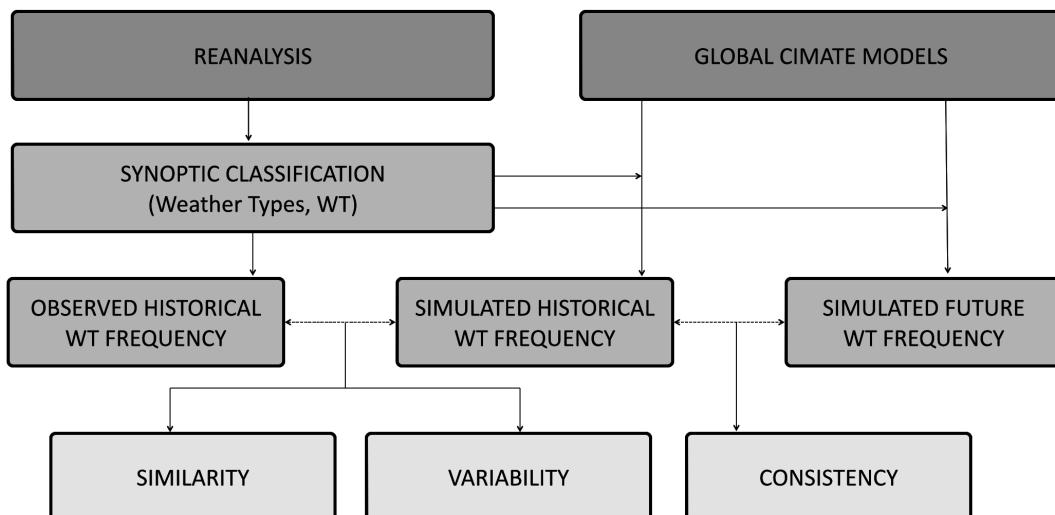


Figure 4.1: Flowchart representing the methodology

4.3.1. Study area

The domain of interest in this work is the North Atlantic. This region is dominated by the North Atlantic Oscillation (NAO), which is one of the most prominent climate fluctuation patterns in the Northern Hemisphere (Hurrell et al. 2003). NAO is usually described with an index based on the pressure difference between Iceland and the Azores and it has important influence on climate from the United States to Siberia, and from the subtropical Atlantic to the Arctic. We have therefore selected an area in the north-east Atlantic from 25°N to 65°N and from 52.5°W to 15°E. In this region, many surface variables are highly correlated with pressure fields, such as wind waves (Izaguirre et al. 2012), precipitation (Rodríguez-Puebla and Nieto 2010), snow (Seager et al. 2010) and

cereal production (Rodríguez-Puebla et al. 2007). Given the fact that data from GCMs are provided in different spatial resolution grids, in order to make a coherent comparison, all SLP data have been interpolated by means of bilinear interpolation to a grid of 2.5° latitude by 2.5° longitude, identical to the mesh of the NNR results. The analyzed spatial domain and resolution is shown in Figure 4.2.

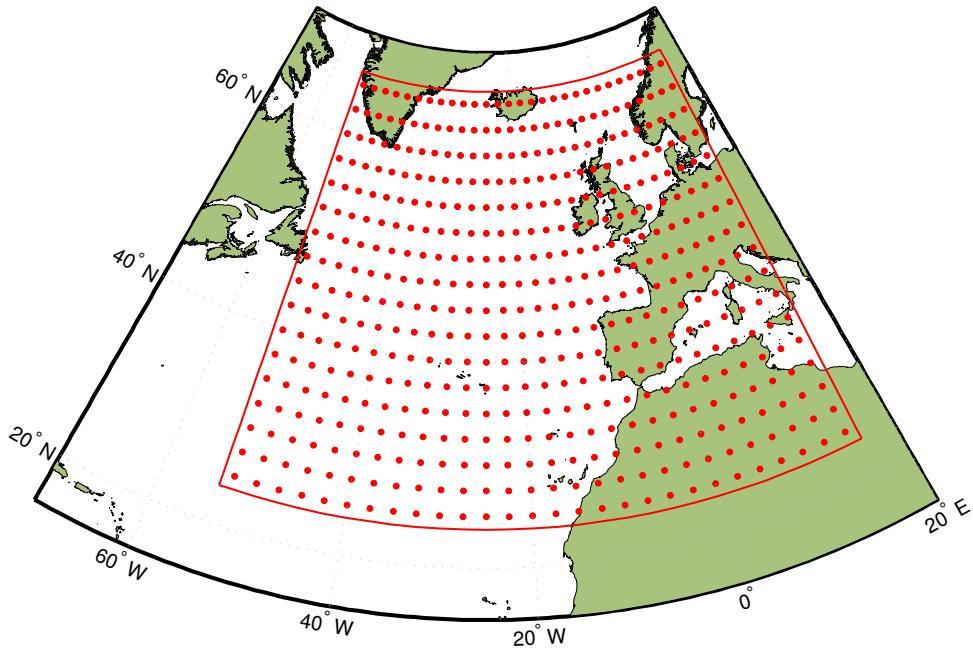


Figure 4.2: Spatial domain of the study area

4.3.2. Classification of weather types

Non-initialized simulations by GCMs aim to simulate long-term statistics of observed weather rather than day-to-day chronology. For this reason, mean climatologies from GCMs are usually compared against reanalysis to evaluate the ability of the GCMs. However, mean climatology comparison ignores the climate variability of the atmospheric circulation, which causes a wide variety of meteorological situations, even severe storm conditions. The evaluation of GCMs throughout a classification of weather types reduces this problem, since classification aims to group similar meteorological situations minimizing the variability within each group. Therefore, each group is more or less homogeneous and distinct from other groups. Many authors are aware of the importance of the models to reproduce climate variability over a region and have used atmospheric circulation type classifications (e.g. Belleflamme et al. 2013; Lee and Sheridan 2012; Pastor and Casado 2012). Here, the circulation type classification is developed by applying the

non-hierarchical clustering technique K-means (MacQueen 1967) over the SLP fields in the study region. To do this, 3-daily averaged SLP fields, $SLP(x, t)$, from the NNR are analyzed. The 3 days time scale is chosen to be able to capture mid- latitude cyclogenesis situations.

First, we process each 3-day averaged SLP field anomaly, $SLPA(x, t) = SLP(x, t) - SLP(t)$, where t represents each 3-days interval and $SLP(t)$ is the mean SLP in the 3-days interval in the spatial domain. So, two situations with similar patterns but slightly different mean SLP can be grouped together. Then, we apply principal components analysis (PCA) to the processed 3-daily SLP fields of NNR from 1950 to 1999. PCA helps the clustering technique reduce dimensions whilst conserving the maximum data variance. That is, the covariance of the SLP anomalies in the study region is used to obtain uncorrelated principal components. In this case, eleven components have explained more than 95 % of variance. In order to get a set of synoptic climatologies (weather types), the K-means algorithm has been applied over these modes. The K-means technique divides the data space into N classes, which are represented by their centroids. Each class represents a group of atmospheric states of similar characteristics. We force the K-means algorithm to start with dissimilarity-based compound selection (Snarey et al. 1997) and the number of classes has been set to $N = 100$. Tests with a different number of classes revealed that this choice does not impact our results in a significant manner. The selection of a hundred classes is made based on the compromise between the best possible characterization of synoptic climatologies, represented by the largest number of clusters and including an average number of 40 data per group. A proximity criterion is applied over the $N = 100$ obtained WTs, and the centroids are visualized in a 10 x 10 lattice (Figure 4.3). The proximity criterion is based on minimizing the sum of Euclidean distances between each centroid and its neighbors. This organization helps to interpret results since weather types of similar characteristics appear near to one another. For example, the dominant winter pattern is characterized by a low pressure center over the Azores Islands, while a high pressure center dominates the summer synoptic situation. The weather types located in the right side of Figure 4.3 are characterized by low pressures in Iceland and high pressures in the Azores Islands, which is usually associated with a positive phase of NAO.

4.3.3. Evaluation of the performance of GCMs

4.3.3.1. Similarity of synoptic situations

Here, the climate information obtained from the synoptic classification of NNR has been used to evaluate the skill of GCMs. First, the relative frequency of each of the 100

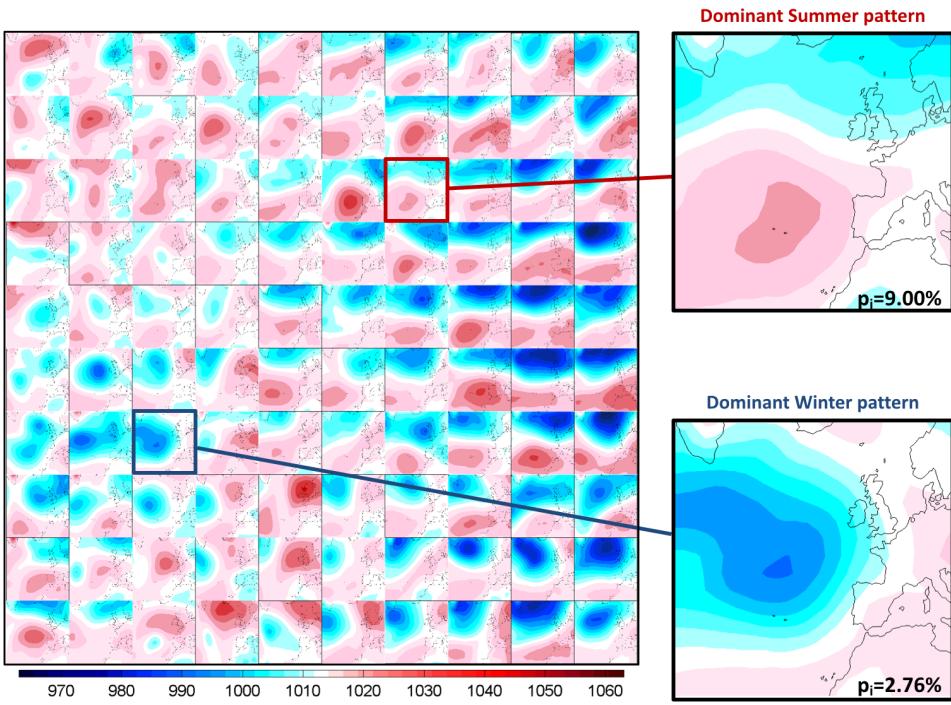


Figure 4.3: The 100 weather types represented by the SLP fields (mbar). Right panels show the most frequently occurring weather types in winter and summer

WTs has been calculated for NNR, as the reference pattern (Figure 4.4). The relative frequencies are estimated from the number of 3-day atmospheric states that can be attributed to each WT, characterized by its centroid, during the reference period of 30 years (from 1st January 1961 to the 31st of December 1990). The Euclidean distance in the reduced EOF-space has been used to assess which centroid is the closest. Then, the ERA-40, 20CR and GCMs databases are projected onto the one hundred WTs derived from NNR, and their relative frequencies for each WT are estimated.

Objective indexes to measure the differences between frequencies of the reference pattern and those for the GCMs during the same period in the historical/20C3M simulations have been applied. The scatter index and a metric based on the relative entropy have been used for this purpose. The scatter index (SI) is the root mean square error normalized by the mean frequency:

$$SI = \sqrt{\frac{\sum_{i=1}^N (p_i - p'_i)^2}{N}} \Bigg/ \frac{\sum_{i=1}^N (p_i)}{N}, \quad (4.1)$$

being p_i the relative frequency of the i th weather type from the reanalysis for the reference period, p'_i the relative frequency of the i th weather type from a GCM simulation

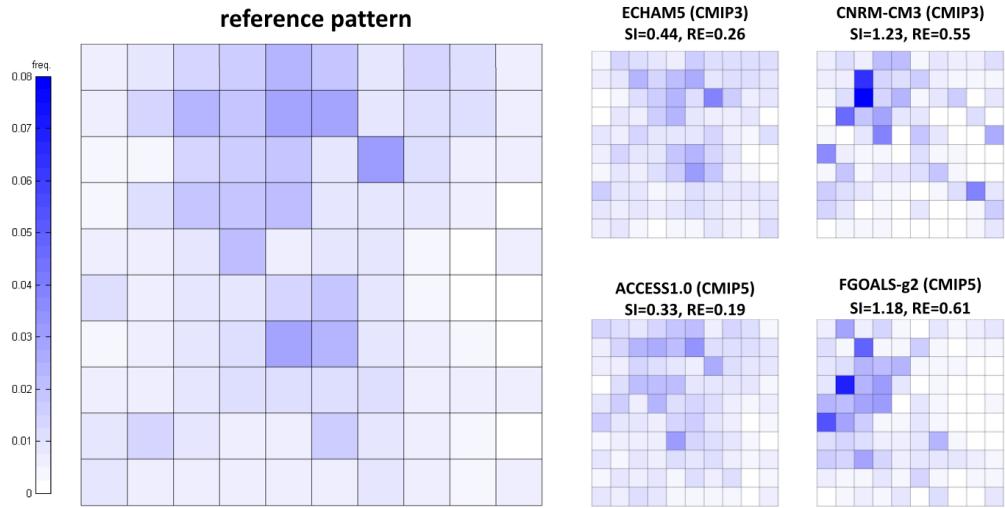


Figure 4.4: Relative frequency of the 100 weather types in the reference period for NCEP/NCAR reanalysis (quasiobservations) and four GCMs. The darker blue colors being weather types with high frequency and the lighter blue the less frequent weather types

for the reference period and N the number of weather types. This index has been used to compare the relative frequencies of each simulation of each GCM with the ones of the reanalysis during the reference period. The metric based on the relative entropy (RE) is defined here as:

$$RE = \sum_{i=1}^N p_i \left| \log \frac{p_i}{p'_i} \right|, \quad (4.2)$$

Lower values of SI and RE therefore indicate a high degree of similarity and hence a better performing GCM. The RE index has been used to analyze the skill of the different GCMs to simulate weather types of low probability of occurrence. The analysis of these situations, which could be associated to extreme events, requires a relative index, such as RE since the scatter index analysis gives more importance to commonly occurring situations. However, RE can easily diverge if a model has zero occurrences for one particular WT. In these cases, we assume a minimum value of 0.5 occurrences.

This analysis has been done both for annual time-scale as well as seasonal time-scales, considering the following distribution: winter (December, January and February), spring (March, April and May), summer (June, July and August) and fall (September, October and November). An example of the application of these indexes is shown in Figure 4.4. The reference pattern represents the relative frequency of each characterized synoptic

situation (weather type) for the recent past conditions. NNR has been used to derive this pattern although ERA-40 and 20CR show similar characteristics.

The frequencies obtained from ECHAM5 (CMIP3) and ACCESS1.0 (CMIP5), provide low *SI* and *RE* since the most common and unusual situations are well reproduced. These models show only small variations between occurrence of neighboring weather types which represent near synoptic situations and probability of occurrence. Alternatively, CNRM-CM3 (CMIP3) and FGOALS-g2 (CMIP5) show less similarity with the reanalysis reference pattern and consequently larger *SI* and *RE*. These models tend to overestimate the frequency of particular WTs associated to synoptic situations with weaker gradients between low and high pressure centers. Note that here and henceforth, *SI* and *RE* are interpreted in relative values (i.e. lowest values versus highest values across the ensemble).

4.3.3.2. Interannual variability

The skill of a model to represent the climate state is the most important test to evaluate its quality. It is for this reason that mean climatologies over several decades are often used to compare GCMs with observations. It is however, important to note that the variance (i.e. interannual variability) is also a requirement for good model performance. We have analyzed the skill of GCMs to represent interannual climate variability because it is an indicator of their ability to respond to changing conditions. The magnitude of the interannual variability has been measured for each WT by assessing the standard deviation of the 30 annual values of relative frequency over the reference period (1961–1990). The comparison of the variability values of the reanalysis with those that correspond to each GCM is conducted by the scatter index of the standard deviations of the *N* weather types (*stdSI*).

$$stdSI = \frac{\sqrt{\frac{\sum_{i=1}^N (std(p_i) - std(p'_i))^2}{N}}}{\frac{\sum_{i=1}^N (std(p_i))}{N}}, \quad (4.3)$$

The lower the *stdSI* the better the performance of the GCM to simulate the interannual climate variability.

4.3.3.3. Consistency of future projections

We have evaluated the skill of GCMs to reproduce historical climate and its variability. However, good model performance evaluated from the present climate does not necessarily guarantee reliable predictions of future climate (Reichler and Kim 2008). This is

mainly due to projections consider future greenhouse gas forcings outside the used range in the historical period of validation. Consequently, the skill of GCMs to reproduce future climate projections cannot be directly evaluated. However, multi-model ensembles are often used to analyze future projections. In order to provide information about uncertainty on the ensembles, we have evaluated the consistency between GCMs during future projections.

To assess the consistency between future projections of GCMs, we have divided the 21st century in three different periods: short term (2010–2039), mid-term (2040–2069) and long-term (2070–2099), while evaluating which models predict inconsistent variations in each of these periods, i.e. magnitudes of change much larger or much lower than those of most models. We assume the stationary hypothesis over climate dynamics, that is, the WT classification remains valid throughout the twenty-first century. For every analyzed simulation and future time period, we have calculated two metrics of the magnitude of change towards the simulations in the reference period. The magnitude of change in the frequency of synoptic situations has been evaluated through *SI* and the magnitude of change in the interannual variability has been analyzed through *stdSI*. The mean magnitude of change has been used in case of several simulations of the same model. For each scenario, future period and metric, we have computed the quartiles of the magnitudes of change. The interquartile range (IQR) is the difference between the upper quartile (Q_3 , 75 percentile) and the lower quartile (Q_1 , 25 percentile). IQR is a robust statistic to measure the dispersion of a set of data. In this study, models with magnitudes of change lower than $Q_1 - 1.5(IQR)$ or higher than $Q_3 + 1.5(IQR)$ are considered outliers, i.e. GCMs of a very different behavior compared with the rest of GCMs.

4.4. Results

4.4.1. Skill of GCMs to perform climatologies

The ability of the GCMs to represent the relative frequency of synoptic situations in the reference period can be assessed by direct comparison with the reference pattern. Figure 4.5 summarizes the bias of the GCMs for the 20C3M simulations (CMIP3 and ENSEMBLES) and the historical simulations (CMIP5). Dots in the WTs indicate agreement on the sign of the bias for more than 80 % of the models. Small bias has been estimated on GCMs over all WTs, indicating a good ability of the models to reproduce common synoptic situations, i.e. mean climatologies. The performance of these ensembles has been measured using the *SI* and *RE* indices. CMIP5 simulations ($SI = 0.37$,

$RE = 0.07$) show a general better agreement than CMIP3 ($SI = 0.45$, $RE = 0.08$). Some discrepancies, however, are found on unusual events associated to deep low pressures centered over different areas of the North Atlantic (right hand side of the figure) and relatively stable atmospheric states (WTs at the bottom of the figure). The former are over-estimated, whilst the latter tend to be slightly underestimated. Note that the overestimated WTs might be associated to extreme storm events during intense Northern Annular Mode (NAM). This overestimation is in agreement with previous studies. For instance, Gerber et al. (2008) found that climate models vaguely capture the NAM variability, over-estimating persistence on sub-seasonal and seasonal timescales.

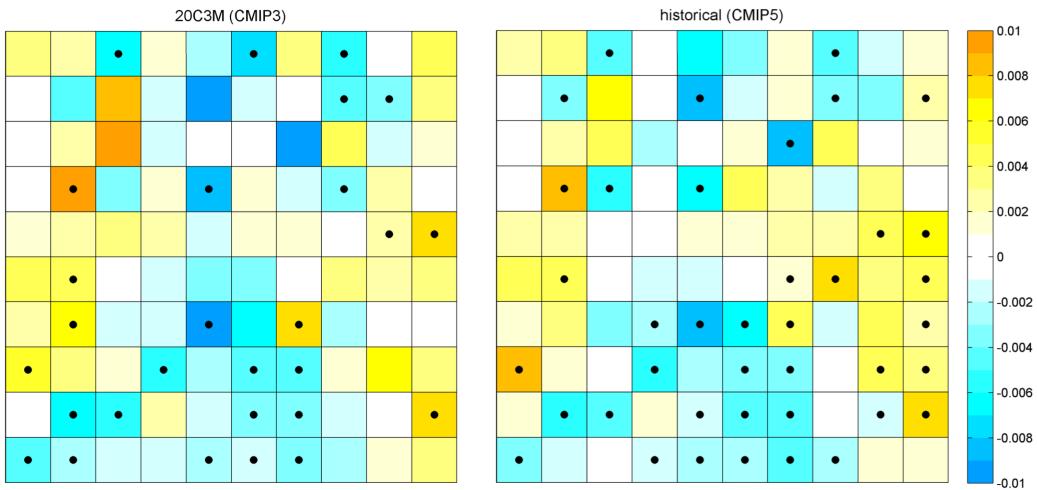


Figure 4.5: Bias of 20C3M (left) and historical (right) ensembles. The small dots indicate agreement on the sign for more than 80 % of the models

The results of individual GCMs are summarized in Figure 4.6 for 20C3M simulations and in Figure 4.7 for historical simulations. In both figures the models have been sorted according to their SI and the number of simulations analyzed for each model is shown between brackets. The SI score of the models with only one simulation is represented by the small vertical black lines. When several simulations are available these vertical black lines represent the mean value of the SI while the horizontal ones represent the range between the minimum and the maximum SI . The mean RE is represented by a black dot. The SI and RE scores have also been obtained for the reanalyses ERA-40 ($SI = 0.16$, $RE = 0.10$) and 20CR ($SI = 0.26$, $RE = 0.14$) during the reference period. 20CR has also been analyzed in 1901-1930 ($SI = 0.30$, $RE = 0.18$) and in 1931-1960 ($SI = 0.30$, $RE = 0.19$). The similar scores for different periods of the twentieth century support the use of the same synoptic classification in the twenty-first century. These values provide an indicator of SI and RE values which better represent the performance of GCMs. The SI scores of the reanalyses have been represented in the figures by vertical dotted lines. It can be observed that ERA-40 is very similar to NNR

whereas 20CR present larger differences. This was expected since 20CR only assimilates surface pressure data.

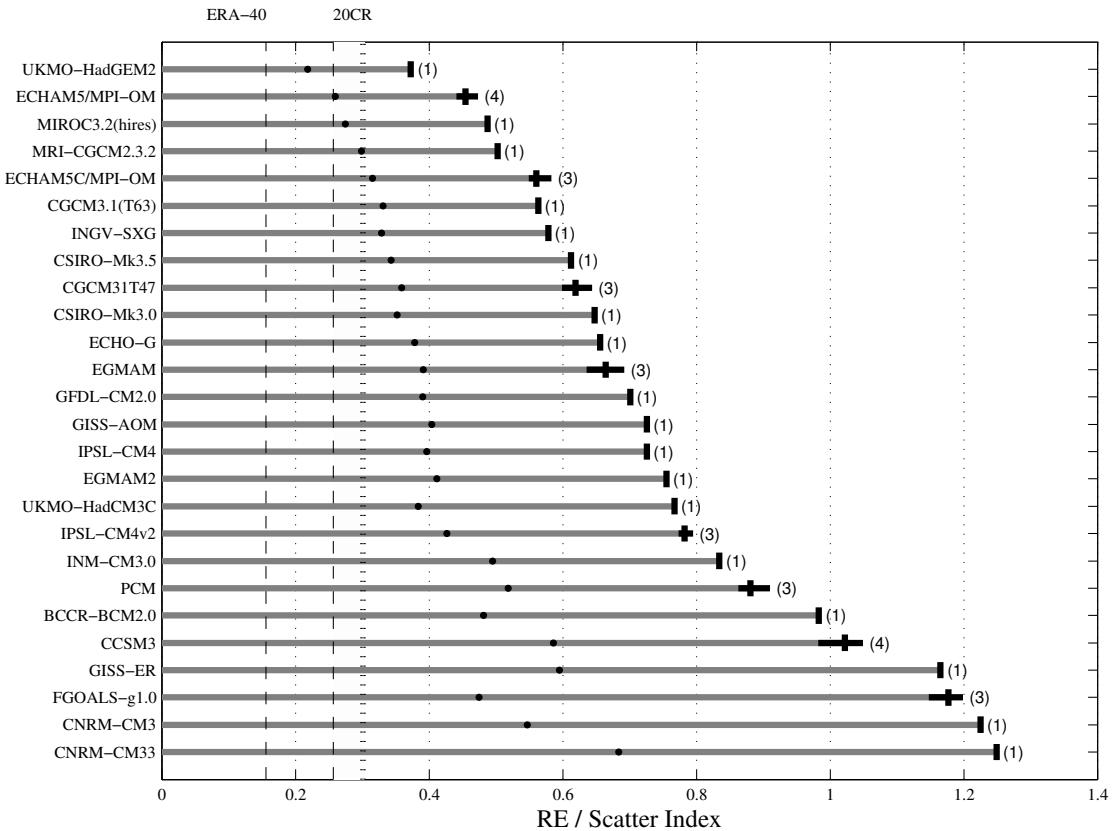


Figure 4.6: GCMs of CMIP3 and ENSEMBLES sorted out by performance to model synoptic situations (the higher performance, the lower *SI*). The mean *RE* is represented by a black dot

The models that best reproduce the occurrence rate of synoptic climatology for 20C3M simulations with *SI* lower than 0.5 and *RE* lower than 0.3, are: UKMO-HadGEM2 (*SI* = 0.37, *RE* = 0.22), ECHAM5/MPI-OM (*SI* = 0.46, *RE* = 0.26) and MIROC32HIRES (*SI* = 0.49, *RE* = 0.28). Alternatively, the five models which have *SI* larger than 1 and, therefore, have a lower simulation performance with regard to the frequency of the different synoptic situations, are: CCSM3, GISS-ER, FGOALS-g1.0, CNRM-CM3 and CNRM-CM33. For CMIP5 models, there are nine models with *SI* lower than 0.5. Three of them: ACCESS1.0 (*SI* = 0.33, *RE* = 0.19), EC-EARTH (*SI* = 0.36, *RE* = 0.21) and HadGEM2-CC (*SI* = 0.37, *RE* = 0.21) have both *SI* and *RE* lower than the best model for 20C3M simulations. The other six: HadGEM2-ES, MPI-ESM-P, CMCC-CM, GFDL-CM3, MPI-ESM-LR and CMCC-CMS have *SI* slightly larger but *RE* is still lower than 0.3. Note that, only two CMIP5 models: IPSL-CM5BLR (*SI* = 1.03, *RE* = 0.57) and FGOALS-g2 (*SI* = 1.17, *RE* = 0.60) show *SI* larger than one.

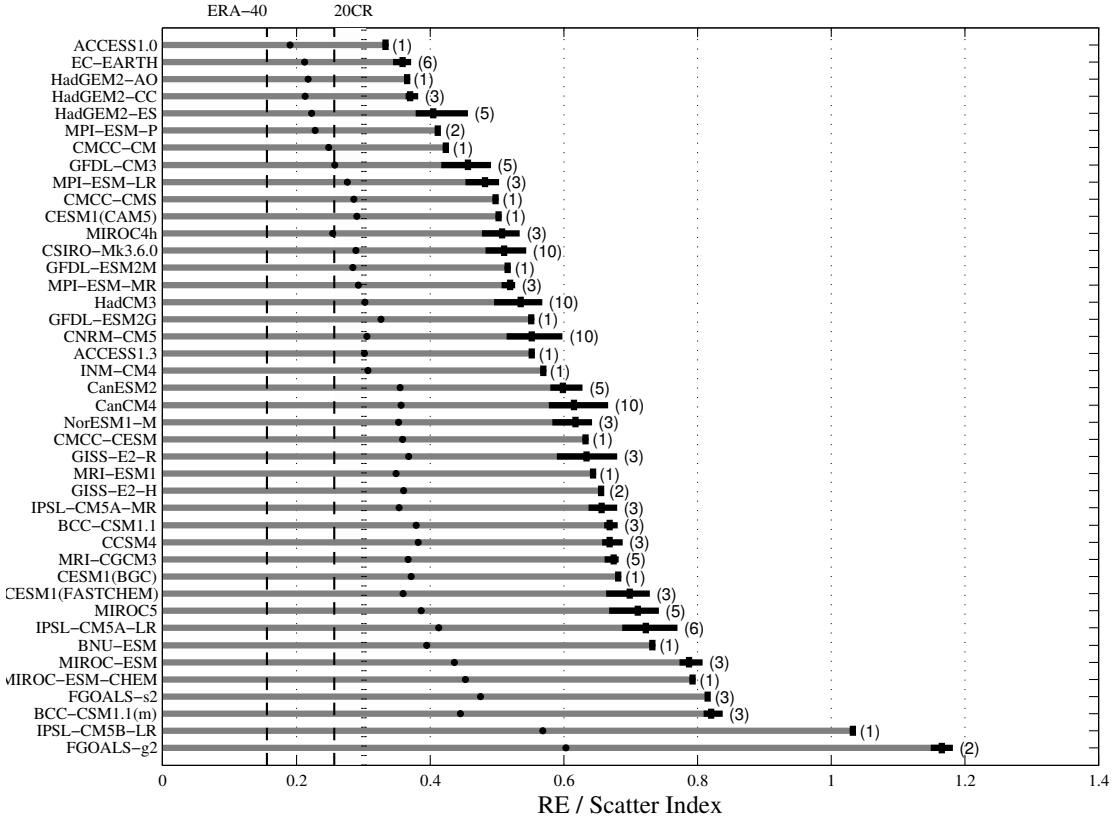


Figure 4.7: GCMs of CMIP5 sorted out by performance to model synoptic situations (the higher performance, the lower SI). The mean RE is represented by a black dot

The differences between runs of a single model are one order of magnitude lower than the differences between models. This shows that the internal variability is well taken into account by using a 30-year period. Moreover, results are qualitatively similar for the two indicators (SI and RE) that have been used to analyze the representation of the synoptic situations, indicating that the model performance is consistent across the two performance measures. The mean values of both indexes reveal an improvement in CMIP5 models ($SI = 0.61$, $RE = 0.34$) with respect to the analyzed set of models from CMIP3 and ENSEMBLES ($SI = 0.76$, $RE = 0.41$). In addition, the values of RE are smaller for CMIP5 models than for CMIP3 models with similar values of SI , indicating that CMIP5 models have improved their capacity to detect synoptic situations with low relative frequency.

4.4.2. Skill of GCMs to perform climate variability

The results of the diagnosis in each season are shown in Figures 4.8 and 4.9, with the models and simulations analyzed as in Figures 4.6 and 4.7, respectively. The SI scores for ERA-40 and 20CR are very similar in fall (0.34 vs. 0.35, respectively) and winter (0.34 vs. 0.39), being the differences slightly larger in spring (0.30 vs. 0.40). The largest

differences can be found in summer (0.31 vs. 0.59). The *RE* scores cannot be included because several WTs have zero occurrences in some seasons.

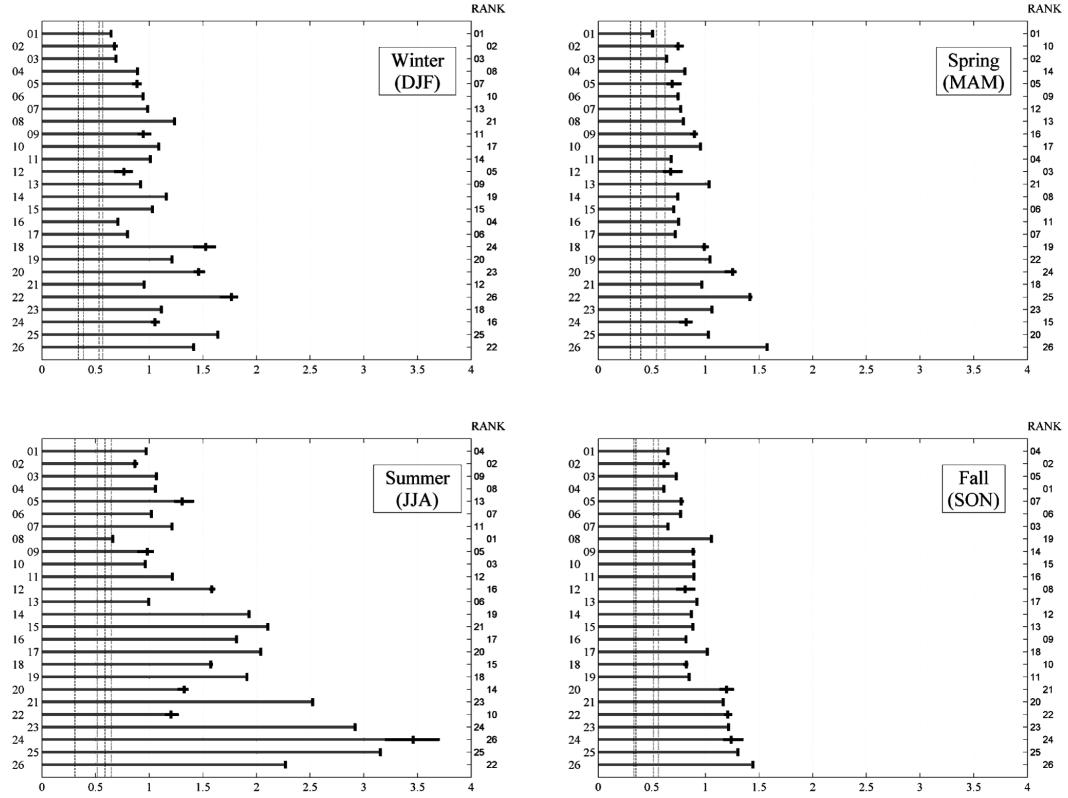
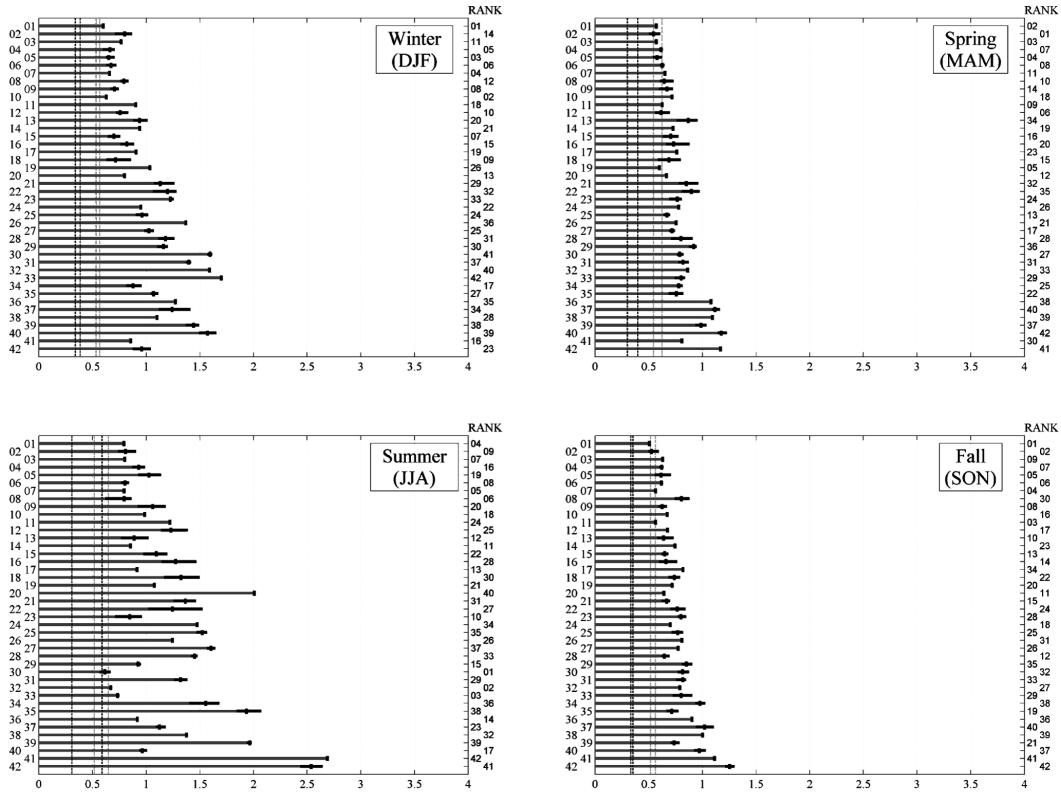


Figure 4.8: GCMs of CMIP3 and ENSEMBLES performance to model synoptic situations on each season 1 UKMO-HadGEM2; 2 ECHAM5/MPI-OM; 3 MIROC3.2(hires); 4 MRI-CGCM2.3.2; 5 ECHAM5C/MPI-OM; 6 CGCM3.1(T63); 7 INGV-SXG; 8 CSIRO-Mk3.5; 9 CGCM31T47; 10 CSIRO-Mk3.0; 11 ECHO-G; 12 EGMAM; 13 GFDL-CM2.0; 14 GISS-AOM; 15 IPSL-CM4; 16 EGMAM2; 17 UKMO-HadCM3C; 18 IPSL-CM4v2; 19 INM-CM3.0; 20 PCM; 21 BCCR-BCM2.0; 22 CCSM3; 23 GISS-ER; 24 FGOALS-g1.0; 25 CNRM-CM3; 26 CNRM-CM33

For CMIP3 and ENSEMBLES models (Figure 4.8) the diagnosis in spring and fall is analogous to the annual one except for minor differences. In both seasons, most models show very similar performance with *SI* between 0.5 and 1. Only three models in spring and seven models in fall show noticeably larger *SI*. On the contrary, in winter and summer the differences are larger. In winter some ENSEMBLES models: EGMAM (*SI* = 0.76), EGMAM2 (*SI* = 0.71) and UKMO-HADCM3C (*SI* = 0.80) perform as well as the best models. FGOALS-g1.0 shows results of lower quality (*SI* = 3.70) in summer and hence performs poorly on the annual scale. On the other hand, CCSM3 and PCM only show low *SI* in summer, and perform with lower quality in the rest of the seasons. A similar observation occurs with models from Commonwealth Scientific and Industrial Research Organisation (CSIRO), with the *SI* of CSIROmk35 and CSIROmk30, the first and third lowest on this season. For CMIP5 models (Figure



*Figure 4.9: GCMs of CMIP5 performance to model synoptic situations on each season
 1 ACCESS1.0; 2 EC-EARTH; 3 HadGEM2-AO; 4 HadGEM2-CC; 5 HadGEM2-ES;
 6 MPI-ESM-P; 7 CMCC-CM; 8 GFDL-CM3; 9 MPI-ESM-LR; 10 CMCC-CMS; 11
 CESM1(CAM5); 12 MIROC4h; 13 CSIRO-Mk3.6.0; 14 GFDL-ESM2M; 15 MPIESM-
 MR; 16 HadCM3; 17 GFDL-ESM2G; 18 CNRM-CM5; 19 ACCESS1.3; 20 INM-CM4;
 21 CanESM2; 22 CanCM4; 23 NorESM1-M; 24 CMCC-CESM; 25 GISS-E2-R; 26
 MRI-ESM1; 27 GISS-E2-H; 28 IPSL-CM5A-MR; 29 BCC-CSM1.1; 30 CCSM4; 31
 MRI-CGCM3; 32 CESM1(BGC); 33 CESM1(FASTCHEM); 34 MIROC5; 35 IPSL-
 CM5A-LR; 36 BNU-ESM; 37 MIROC-ESM; 38 MIROC-ESM-CHEM; 39 FGOALS-s2;
 40 BCC-CSM1.1(m); 41 IPSL-CM5B-LR; 42 FGOALS-g2*

4.9) the seasons that show larger discrepancies with respect to the global evaluation shown in Figure 4.7 are also winter and summer, with the diagnosis in spring and fall similar to the global evaluation. Interestingly, the CMIP5 models which provide the worst diagnostic in winter (SI larger than 1.4), namely CCSM4, CESM1(BGC), CESM1(FASTCHEM), BNU-ESM and BCC-CSM1.1(m) are some of the best models in summer. Note that the SI in summer of CCSM4 is 0.62, only slightly larger than the one of 20CR. On the contrary IPSL-CM5B-LR and FGOALS-g2 are the poorest performing models at the annual scale and during summer season but they perform well in winter. Curiously, the model with the third largest SI in summer INM-CM4 is one of the best models in the other seasons. The seasonal analysis show that the performance of the models depends on the season, especially in summer and winter, indicating that, in some cases, the most adequate models depend on the purposes.

The interannual variability analysis has been based on the *stdSI* score. As shown in Figure 4.10, in which the order of GCMs of the previous figures has been kept, the *stdSI* scores for ERA-40 (*stdSI* = 0.17) and 20CR (*stdSI* = 0.21) are more similar than their *SI*. The results for 20C3M simulations (Figure 4.10a), show that UKMO-Had-GEM2 (*stdSI* = 0.24) and ECHAM5/MPI-OM (*stdSI* = 0.27) provide the highest quality results, with *stdSI* lower than 0.3, while CNRM33 and GISS-ER are the ones that provide results of lower quality with *stdSI* larger than 0.6. For the historical simulations of the CMIP5 models (Figure 4.10b) the values of *stdSI* are slightly better than the ones for 20C3M simulations. Five models ACCESS1.0, MPIESM-P, EC-EARTH, HadGEM2-CC and HadGEM2-ES have *stdSI* lower than 0.3. Furthermore, there are no models with *stdSI* larger than 0.6 and only two models: IPSL-CM5BLR and FGOALS-g2 exceed 0.5. Results obtained for interannual variability confirm those obtained from the similarity of synoptic situations, with the models with the highest and lowest performance the same for both analyses.

4.4.3. Consistency of future projections

Analysis of future projections is made in a different way to the analysis of past climate. Historical simulations can be compared with reanalysis data, but the future projections can only be compared to each other. The analysis of future projections can be used to detect models with anomalous behavior but not to determine which models are best. The results of the consistency of future projections have been synthesized in Figure 4.11 for the three SRES scenarios considered (B1, A1B and A2) and Figure 4.12 for the four RCP (RCP2.6, RCP4.5, RCP6.0 and RCP8.5). For each scenario, the magnitudes of change of the frequency of the synoptic situations and the magnitudes of change in the interannual variability are shown for three future time periods. On each box, the central mark is the median, the edges of the box are the lower and upper quartiles and the whiskers extend to the most extreme magnitudes of change within the range defined by $Q1 - 1.5(IQR)$ and $Q3 + 1.5(IQR)$. The numbered red dots represent models with magnitudes of change outside this range.

For SRES scenarios (Figure 4.11) only the mid-term and long-term periods are shown because few simulations cover the short term period. For these scenarios, INM-CM3 (19), GISS-ER (23) and CNRM-CM3 (25) show magnitudes of change notably high for some combinations of scenario, indicator and time-period. For CMIP5 (Figure 4.12) short-term, mid-term and long-term can be shown because information for the full twenty-first century is available. In this case there are two different groups of models with anomalous magnitudes of change. HadGEM2-AO (03), GFDL-CM3 (08), IPSL-CM5A-MR (28), IPSL-CM5A-LR (35), MIROC-ESM-CHEM (38), FGOALS-s2 (39) and FGOALS-g2

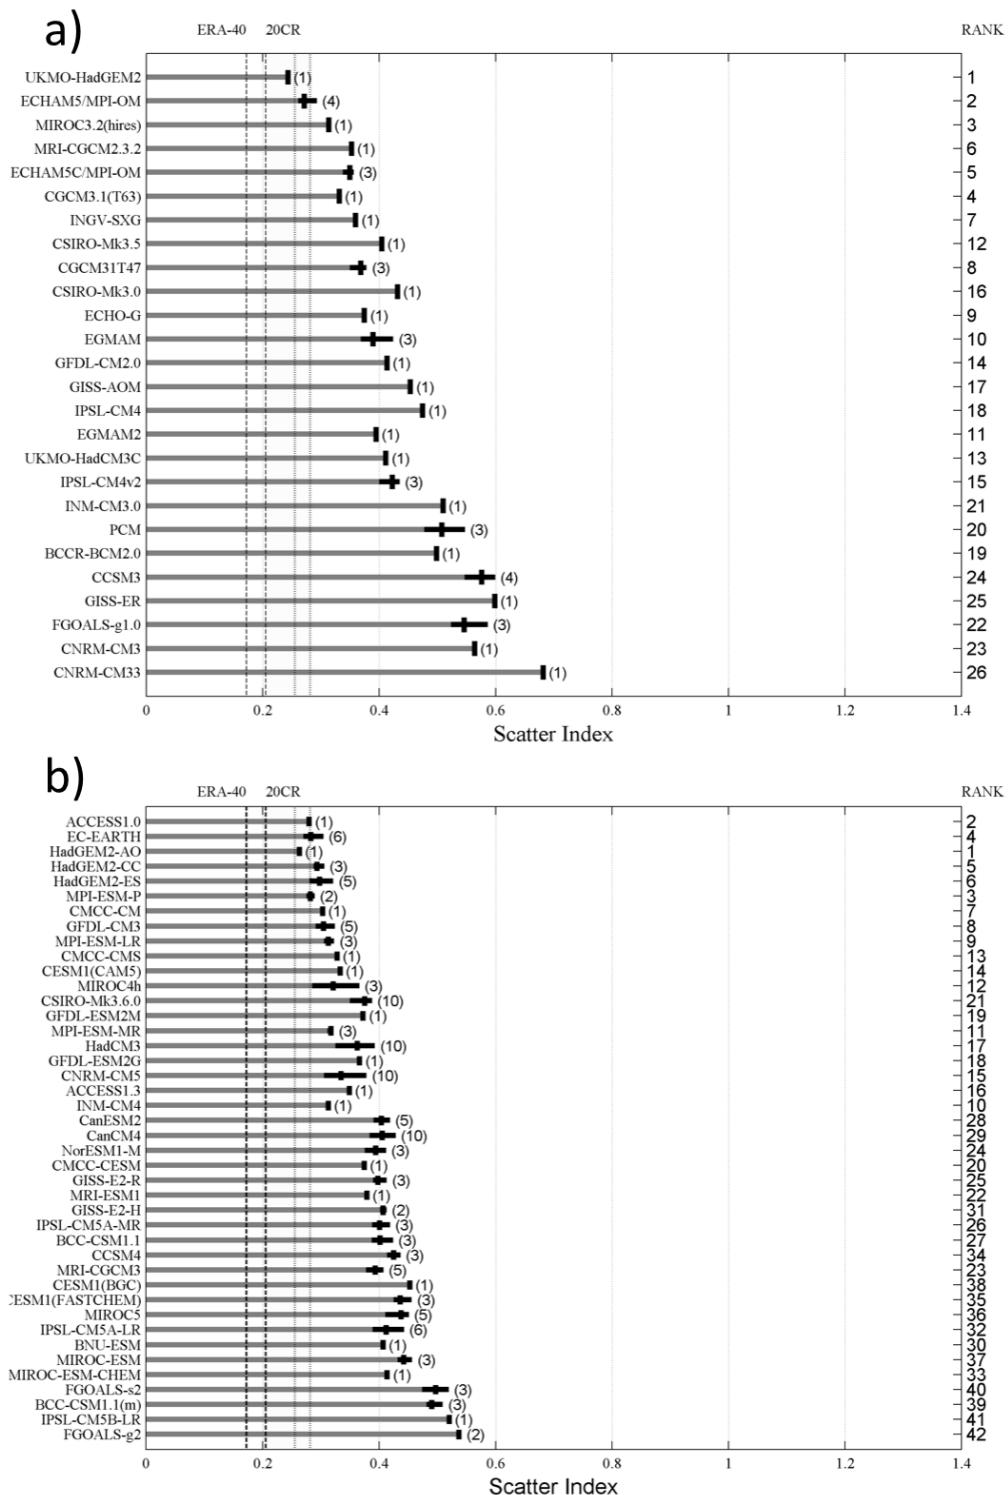


Figure 4.10: GCMs of CMIP3 and ENSEMBLES (a) and CMIP5 (b) performance to simulate interannual variability (the higher performance, the lower SI)

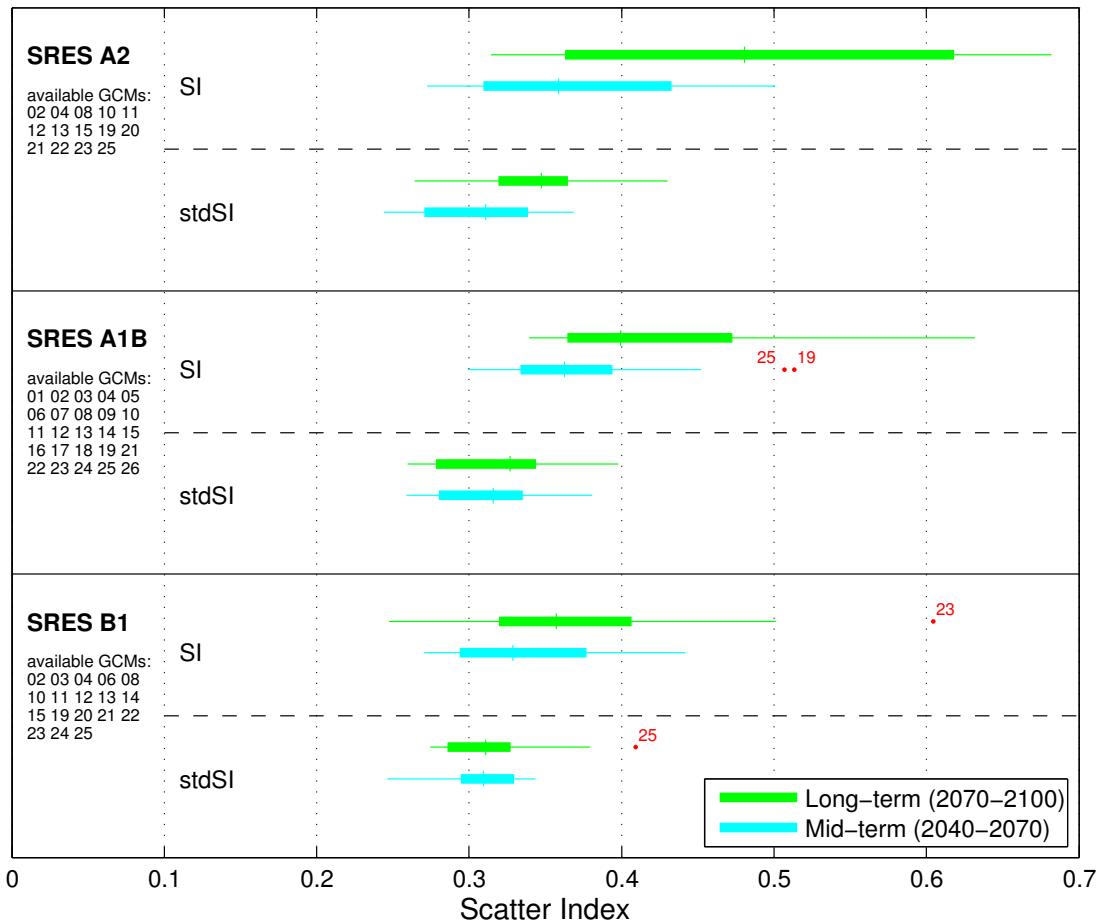


Figure 4.11: Box plots of the two indicators of consistency for scenarios B1, A1B and A2. Numbering in accordance with Figure 4.8

(42), show in several cases high magnitudes of change whereas MPI-ESM-MR (15), INM-CM4 (20), MRI-CGCM3 (31) and BCC-CSM1.1(m) (40) show in some cases low magnitudes of change. Results indicate that the magnitudes of change and their spread are larger in the long-term period than in the short-term period and for highemissions scenarios, e.g., A2 and RCP8.5, than for low-emission scenarios. It is interesting to note the connection between the ability of models to reproduce the present climate (the higher the number, the worse the performance) and the consistency of their future simulations. The models with anomalous magnitudes of change mostly belong to the group of models with low skill in the reference period. Consequently, the spread is reduced when considering models with high skill in the reference period. For instance, a 30 % reduction in spread is obtained by considering only the top half of the models; those with the best skill. However, some of the models with anomalous magnitudes of change perform reasonably well in the recent past. It may indicate that these models are unable simulate the climate variability associated to larger changes in the forcings during the twenty-first century.

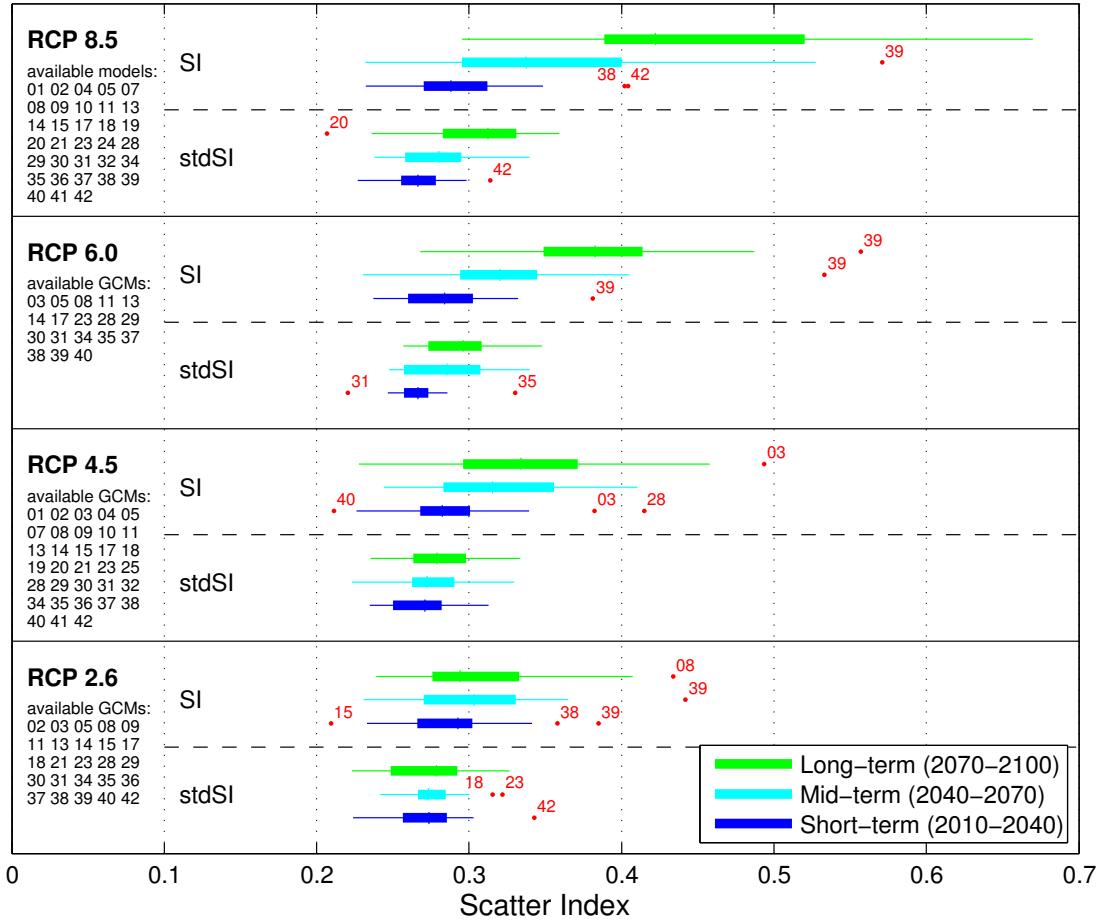


Figure 4.12: Box plots of the two indicators of consistency for scenarios RCP2.6, RCP4.5, RCP6.0 and RCP8.5. Numbering in accordance with Figure 4.9

Figure 4.13 shows in detail the long-term changes of CMIP3 and CMIP5 ensembles for the scenarios RCP8.5 and A2, respectively. Dots in the WTs indicate agreement on the sign of the change for more than 80 % of the models. Note that both, CMIP3 and CMIP5, show a similar pattern of change in the synoptic classification, with three discernible changes: i) a frequency decrease of the WTs (WTs in low right side) associated to slight positive NAO situations (modest intensification of the high and low pressure systems); ii) an increase of synoptic situations with dominance of a high center of action, very often during summer (top and middle WTs); and iii) a decrease on WTs with a clear low pressure system in the mid-North Atlantic basin (WTs in the left side). Furthermore, CMIP3 models under A2 scenario provide more homogeneous and intense changes than CMIP5 models under RCP8.5.

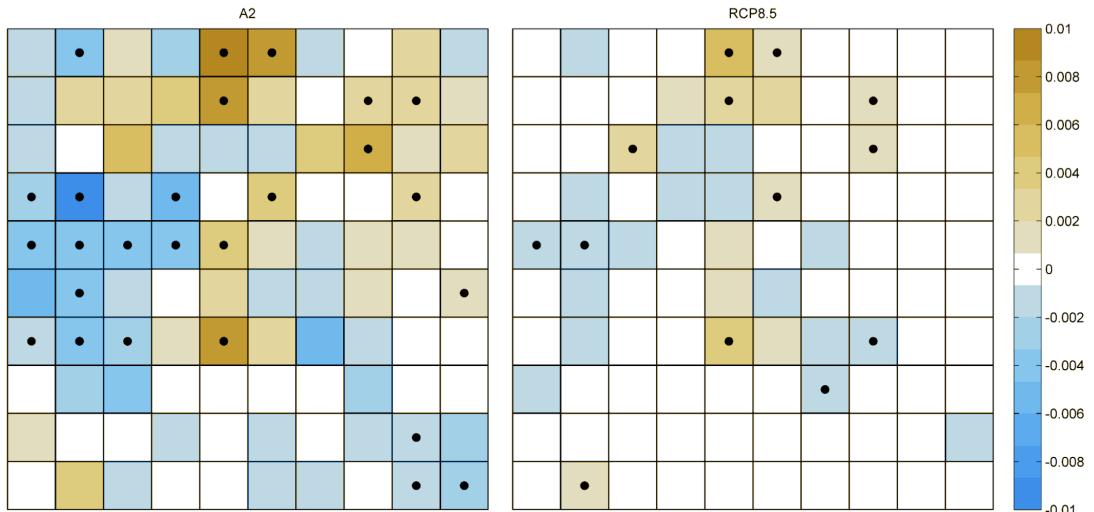


Figure 4.13: Changes of A2 (left) and RCP8.5 (right) ensembles in 2070–2099 towards the reference period (20C3M, historical). The small dots indicate agreement on the sign for more than 80 % of the models

4.5. Conclusions

A methodology to analyze the performance of GCMs based on weather types (WTs) and statistical metrics has been developed. The method analyzes the ability of the models to reproduce three characteristics: the historical synoptic climatologies, the interannual variations and the consistency of future projections. The use of statistic metrics based on the scatter index and the relative entropy allow a quantitative estimation of the GCMs performance.

The method has been applied to the Northeast Atlantic region. The three models that best simulate the recent past climate conditions from the CMIP3 and ENSEMBLES datasets are: UKMO-HadGEM2, ECHAM5/MPI-OM and MIROC3.2 (hires). Furthermore, these models are consistent during the twenty-first century for the SRES simulations analyzed. For CMIP5, seven models perform above the rest during the twentieth century: ACCESS1.0, ECEARTH, HadGEM2-AO, HadGEM2-CC, HadGEM2-ES, MPI-ESM-P and CMCC-CM. During the twenty-first century five of them are consistent but HadGEM-AO overestimates the changes for RCP45 in the short term and there are no future simulations for MPI-ESM-P.

These results are consistent with other studies of SLP in the Northern Hemisphere. For example, Walsh et al. (2008) evaluated 15 GCMs of CMIP3 over the Northern extratropical domains focusing in Greenland and Alaska. They found that ECHAM5/MPI-OM is one of the top-performing models. Errasti et al. (2011) found ECHAM5/MPI-OM and MIROC3.2 (hires) as the best CMIP3 model in the Iberian peninsula. Brands et al.

(2011) found similar results within ENSEMBLES models in the Northeast Atlantic region for the two best models (UKMO-HadGEM2 and ECHAM5/MPI-OM) and they also concluded that the two worst performing models are CNRM-CM3 and CNRMCM33. Brands et al. (2013) also obtained HadGEM2-ES outperforming the remaining models in a group of seven CMIP5 models.

These results are also fairly consistent with Cattiaux et al. (2013) that choose the geopotential height at 500 mb rather than SLP for depicting the large-scale circulation. It is important to highlight, however, that an evaluation of the quality of the GCMs depends on the study area and the considered variable, showing different results to those obtained for other variables or regions. Note that the performance of the GCMs also varies depending on the analyzed season. Therefore, the choice of the most adequate models depends on the specific purposes (e.g. studies focus on extreme wave heights during winter or ice melting during summer). On the contrary, from the analysis carried out the importance of the atmospheric resolution is not clear. The models with the highest resolution are not always performing the best.

The small differences in the skill indexes among runs of the same model indicate that the methodology is robust because it is not considerably affected by the natural variability of climate. In spite of this, notable differences can be observed in future simulations, even among the best rated models. Therefore, the use of ensembles or multimodel groups is recommended since it diminishes the effects of individual simulations allowing us to have greater confidence on the results.

Chapter 5

Statistical multi-model climate projections of surface ocean waves in Europe

Abstract

In recent years, the impact of climate change on sea surface waves has received increasingly more attention by the climate community. Indeed, ocean waves reaching the coast play an important role in several processes concerning coastal communities, such as inundation and erosion. However, regional downscaling at the high spatial resolution necessary for coastal studies has received less attention. Here, we present a novel framework for regional wave climate projections and its application in the European region. Changes in the wave dynamics under different scenarios in the Northeast Atlantic Ocean and the Mediterranean are analyzed.

The multi-model projection methodology is based on a statistical downscaling approach. The statistical relation between the predictor (atmospheric conditions) and the predictand (multivariate wave climate) is based on a weather type (WT) classification. This atmospheric classification is developed by applying the k-means clustering technique over historical offshore sea level pressure (SLP) fields. Each WT is linked to sea wave conditions from a wave hindcast. This link is developed by associating atmospheric conditions from reanalysis with multivariate local waves. This predictor-predictand relationship is applied to the daily SLP fields from Global Climate Models (GCMs) in order to project

This chapter is based on Perez et al. (2015): Perez, J., Menendez, M., Camus, P., Mendez, F. J., Losada, I. J. (2015). Statistical multi-model climate projections of surface ocean waves in Europe. *Ocean Modelling*, in press. <http://doi.org/10.1016/j.ocemod.2015.06.001>

future changes in regional wave conditions. The GCMs used in the multi-model projection are selected according to skill criteria. The application of this framework uses CMIP5-based wave climate projections in Europe. The low computational requirements of the statistical approach allow a large number of GCMs and climate change scenarios to be studied.

Consistent with previous works on global wave climate projections, the estimated changes from the regional wave climate projections show a general decrease in wave heights and periods in the Atlantic Europe for the late twenty-first century. The regional projections, however, allow a more detailed spatial characterization of the projected changes under different climate scenarios. For example, changes in significant wave heights for the RCP8.5 scenario for the 2070-99 time period indicate a general decrease of about 10 cm in Southern Europe (Portuguese, Spanish and French coasts) with respect to present conditions. This decrease is due to a higher occurrence of dominant and moderate Azores high pressure systems over the North Atlantic Ocean and a decrease in the persistence of intense low pressure systems at high latitudes.

5.1. Introduction

Reliable estimates of future wave climate parameters (i.e. significant wave height, mean wave period, mean wave direction) are essential for several applications such as coastal planning and design of coastal and offshore structures. Future wave climate is often estimated by extrapolating trends in historical data (e.g. Menéndez et al. 2008). This approach, however, does not seem appropriate for the next century. Larger concentrations of greenhouse gases may lead to changes that are not captured in historical trends. In this context, Global Climate Models (GCMs) have become valuable tools to estimate climate changes for different future climate scenarios. However, GCMs do not simulate ocean surface waves. Furthermore, the resolution of GCM-derived surface wind fields is often too coarse to force regional wave models.

There are two different approaches to generate regional wave climate projections. Dynamical downscaling, based on nesting of numerical models, is perhaps the most widely used methodology (e.g. Erikson et al. 2015; Hemer et al. 2013b; Mori et al. 2010; Semedo et al. 2013). An alternative approach is statistical downscaling, which can be conducted, for example, by means of regression methods (e.g. Wang et al. 2014) or weather pattern-based approaches (e.g. Camus et al. 2014b). Laugel et al. (2014) showed that statistical projections can reproduce wave climatology as well as dynamical projections. Wang et al. (2009) found substantial similarity between both approaches in projected future changes. However, statistical methods were reported to perform better in reproducing

the observed climate and interannual variability. Moreover, dynamical approaches are very computationally expensive. Therefore, most dynamical wave climate projections studies are based on only one or a few GCMs (e.g. Laugel et al. 2014; Mori et al. 2010; Semedo et al. 2013). On the other hand, statistical approaches are much cheaper, thus, allowing the study of a large number of simulations. Analysis of multiple GCMs and climate scenarios is extremely important because cascading uncertainties can make outputs from two simulations very different. Furthermore, a large ensemble gives more robust projections and a measure of uncertainties (Gleckler et al. 2008).

In this work, a weather type (WT) statistical downscaling for multivariate ocean wave climate is presented. This method is based on a statistical downscaling framework able to reproduce the seasonal and interannual variability of wave climate (Camus et al. 2014b) and takes into account the skill of GCMs to define an optimal ensemble of models (Perez et al. 2014b). Application of this method is demonstrated through wave climate projections in the European region with a spatial resolution up to 0.125° (less than 15 km along the coast).

The paper is presented in five sections. Following the introduction, Section 5.2 presents the databases (reanalysis, wave hindcast and GCMs) used in this study. Section 5.3 explains the methodology that has been developed, describing the WT classification, the downscaling technique, and the selection of the ensemble of GCMs. The study is completed with presentation of the results in Section 5.4 and the conclusions in Section 5.5.

5.2. Data

5.2.1. Historical atmospheric data

Reanalyses are designed to provide global gridded representations of the atmosphere – ocean – land surface – sea ice system over a long historical period of time. The National Centers for Environmental Prediction (NCEP) Climate Forecast System Reanalysis (CFSR, Saha et al. 2010) is a reanalysis dataset that represents an improvement in the field due to its high resolution and advanced data-assimilation techniques. Beginning in 2011, CFSR is extended by NCEP’s Climate Forecast System Version 2 (CFSv2, Saha et al. 2014) operational model. We use near-surface winds, ice coverage, and sea level pressure fields from CFSR and CFSv2. CFSR and CFSv2 outputs are available at an hourly time resolution from 1979 onward. Global winds and ice coverage at a horizontal resolution of $\sim 0.3^\circ$ ($\sim 0.2^\circ$ for CFSv2) were used as forcing for a wave hindcast. SLP fields at a 0.5° horizontal resolution were used to create a WT classification.

5.2.2. Historical wave data

In this study, we have conducted a wave hindcast from 1979 to 2013 with hourly resolution to provide historical wave data. This hindcast uses WaveWatch III wave model (version 4.18, Tolman 2014) in a multigrid configuration. The multigrid is composed of several regular grids with two-way nesting: a global grid (1° latitude x 1.5° longitude), a grid covering the Atlantic Ocean (0.5° x 0.5°) and a grid in the area close to the European coastline (0.125° x 0.125°). Small grids covering the archipelagos of Cape Verde, Canary Islands and Azores (0.125° x 0.125°) are also used to improve the modelling of wave shadowing effects. Winds and ice coverage were interpolated from CFSR and CFSv2 data. The bathymetry, land-sea mask, and obstruction grids for unresolved boundaries for each grid were obtained using the automated generation software for WAVEWATCH III (Chawla and Tolman 2008). We used this software with etopo1 bathymetry (Amante and Eakins 2009) and coastlines from the Global Self-consistent, Hierarchical, High-resolution Geography Database (GSHHG, Wessel and Smith 1996).

Wave spectra in WAVEWATCH III were defined by 32 frequencies ranging non-linearly from 0.0372 Hz to 0.714 Hz with a factor of 1.1 and 24 direction bins. WAVEWATCH III was implemented using the parameterization TEST451 (Ardhuin et al. 2010) because the wave heights obtained with TEST451 (e.g. Rascle and Ardhuin 2013) have smaller biases than those obtained with older parameterizations. Validation against buoys and altimeter data (not shown) confirmed a good agreement of this hindcast with observations. For example, the comparison between altimeter measured and modelled significant wave heights on the European grid show a 0.95 correlation and a scatter index of less than 0.2. The best agreement is found in the Atlantic Ocean while the worst agreement is found in some semi-enclosed basins such as the Alboran Sea and the Adriatic Sea.

5.2.3. Global Climate Models atmospheric data

We analyzed daily SLP fields from CMIP5 GCMs to study changes in atmospheric circulation. Data from historical experiments from 1975 to 2004 was used to characterize recent past conditions. Data from representative concentration pathways (RCPs, Moss et al. 2010) from 2010 to 2100 were used to represent future conditions. These time periods were chosen because they overlap with data available from most GCMs. The three selected RCPs included one mitigation scenario leading to a very low forcing level (RCP2.6), one medium stabilization scenario (RCP4.5) and one very high baseline emission scenario (RCP8.5) leading to high greenhouse concentration levels (van Vuuren et al. 2011). All the simulations available (at the time this work was conducted) for these scenarios were analyzed. This resulted in a total of 42 GCMs with 137 historical

simulations, 56 RCP2.6 simulations, 98 RCP4.5 simulations and 72 RCP8.5 simulations. The CMIP5 data used in this study were obtained via the Earth System Grid - Center for Enabling Technologies (ESG-CET, <http://pcmdi9.llnl.gov/>).

5.3. Methods

5.3.1. Framework

Figure 5.1 summarizes the methodology to obtain regional wave climate projections. This methodology requires three sources of data: historical wave data, historical atmospheric data and GCM simulated atmospheric data. First, an automated WT classification is performed using the historical atmospheric data from a reanalysis. This classification is used for two purposes: 1) Each WT is linked to corresponding historical wave conditions from a wave hindcast in order to obtain an empirical statistical relationship between atmospheric circulation and wave climate. 2) Historical and future frequencies of each WT are analyzed to select the best ensemble of GCMs and project the changes in the frequency of the WTs for this ensemble. Finally, wave climate projections are obtained by applying the statistical relationship between atmospheric conditions and wave climate to the atmospheric data from GCMs.

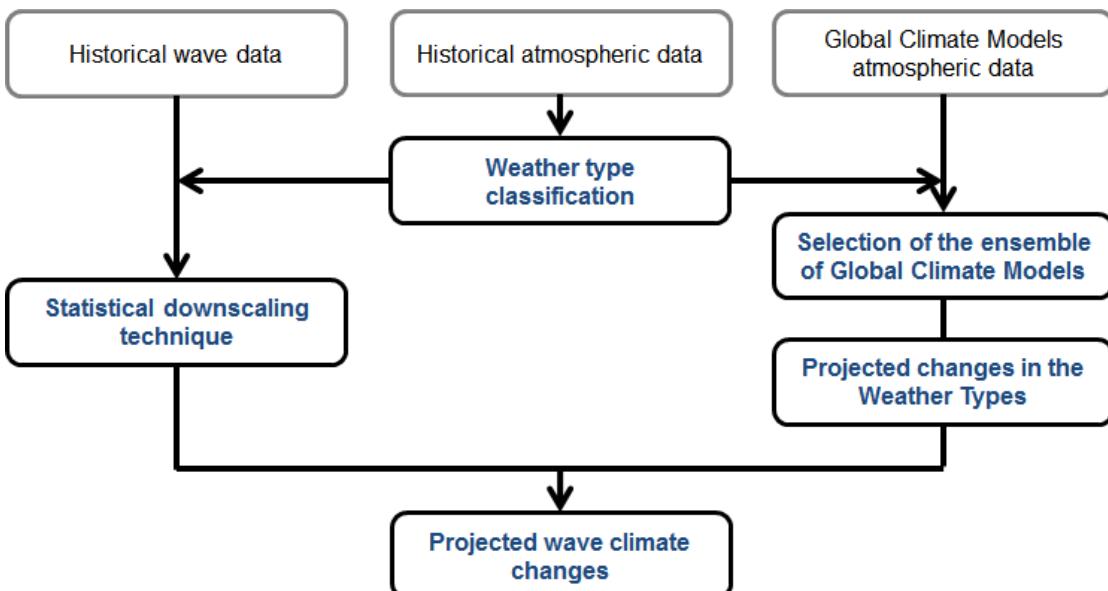


Figure 5.1: Flowchart representing the methodology to obtain wave climate projections

5.3.2. Weather type classification

There are several methodologies to make a classification of WTs. A classification can be subjective (e.g. Lamb 1972) or based on automated algorithms such as neural networks or clustering. In this work, an automated WT classification is applied. The WT classification is based on two main steps: the definition of the predictor and the clustering technique.

The predictor is constructed with the SLP fields from CFSR and CFSv2 during the period from 1979 to 2013. The spatial and time resolutions of GCMs are too coarse to allow a direct comparison with the atmospheric reanalysis. Therefore, daily SLP fields from the hourly reanalysis data were regridded to a $1^\circ \times 1^\circ$ lattice. Swell energy in ocean basins propagate for thousands of kilometers over several days (e.g. Snodgrass et al. 1966). Accordingly, the atmospheric conditions during the time of propagation of the waves have to be taken into account (Camus et al. 2014a). Consequently, the predictor representing one day is composed of the averaged SLP and squared SLP gradients over that day and the previous two days. The squared SLP gradients, related to geostrophic winds, are included because they have been shown to provide a good predictor of ocean waves (Wang et al. 2014). The spatial limits of the predictor must include the area where the most important wave generation/dissipation processes occur. ESTELA (Perez et al. 2014a) is a technique for evaluating the origin and travel time of the wave energy reaching a local area. Given that the goal of this work is to characterize regional wave climate projections in Europe, we have checked over the ESTELA maps for locations further North, west, east and southern European coasts to select an area from 20°N to 80°N and from 60°W to 50°E . Summarizing, the predictor for a specific day is the 3-day average of both SLP and squared SLP gradients in all the ocean points of the selected area.

The clustering technique is described in Camus et al. (2014b) and is based on three steps: First, a principal component analysis (PCA) is applied to the predictor in order to reduce the data dimensionality. PCA finds a new optimal basis for the data (Preisendorfer and Mobley 1988). The projected data in this new basis (principal components, PCs) is sorted in an increasing order of explained variance. Therefore, the data dimensionality is reduced by keeping only the PCs that explains the 95% of the variance. Second, the predictor in the Empirical Orthogonal Function (EOF) space is clustered using the k-means algorithm. Daily predictors are grouped into N clusters that minimize the overall within-cluster distance. Each cluster is formed by the most similar predictor fields and represented by a centroid defined as the mean of these fields. Finally, the WTs are arranged in a lattice that minimizes the differences between contiguous WTs.

Daily predictor fields are grouped in certain atmospheric circulation patterns. The main goal of this classification is to correctly represent the empirical relationship between atmospheric circulation and wave climate along the European coasts. This objective requires a large number of atmospheric circulation patterns because similar WTs can generate vastly different wave conditions at specific locations, especially in areas affected by a complex bathymetry and coastline. After preliminary tests, we have determined that $N = 100$ WTs fulfils the compromise between a significant number of WTs and a minimum number of data per group. Wave climate projections are not overly sensitive to small differences in the number of WTs, though, a smaller number of WTs is not enough to estimate both the spatial patterns and its intensities, and a larger number of WTs may result in some WTs with no data. Figure 5.2 shows the 100 WTs, represented by the 3-day averaged SLP fields, organized in a bidimensional lattice. The clustering method identifies different low pressure systems. Low pressure centers located at the north polar region can be found in the upper right corner of the lattice (e.g. WTs 51, 61, 71). Low pressure centers located southward are characterized by patterns in the middle of the lattice (e.g. WTs 46, 56, 57). The mildest synoptic patterns are located around the WT 38.

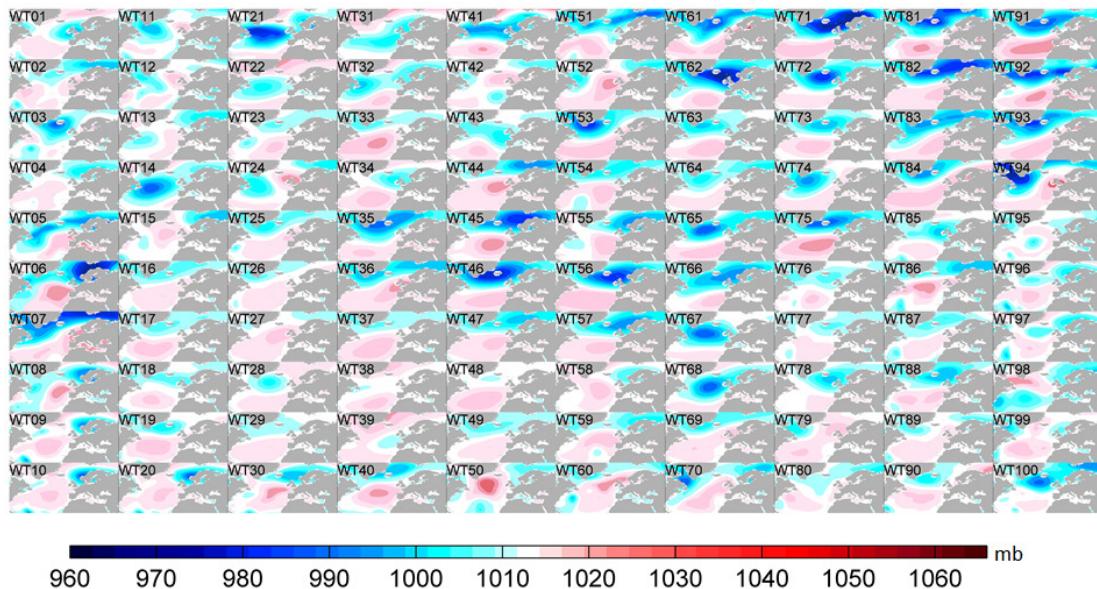


Figure 5.2: The 100 weather types represented by the 3-day averaged SLP fields (mb)

5.3.3. Statistical downscaling technique

The WT classification described in the previous section can be used to link the atmospheric conditions (predictor) to the wave climate (predictand). In this work, every WT is linked to the multivariate wave climate during the wave hindcast (1979-2013). The link is derived by associating the hourly sea-state, i.e. wave parameters such as

the significant wave height (H_s) and the second-order spectral mean period (T_{02}), with the WT at the same day. The probability distribution of a certain sea state parameter for each WT is defined associating the hourly sea states to the daily predictor fields corresponding to that WT. The total probability distribution is defined as the sum of the distribution multiplied by the probability of occurrence of each WT. A detailed description of this procedure and validation analysis at two locations in the Irish and the Spanish coasts is presented in Camus et al. (2014b).

Figure 5.3 shows mean H_s and mean T_{02} in the North Atlantic associated with each WT. Comparing Figures 5.2 and 5.3, the predictor-predictand relationship can be clearly understood. The position of the low pressure centers are reflected in the spatial pattern of H_s and T_{02} . For example, energetic waves along the Norwegian and England coasts are generated for WTs 51, 61 and 71, while the highest waves along the French and Spanish coasts are associated with WTs 46 and 56. The effect of the different low pressure patterns can also be detected in the mean wave period field. Notably, deeper lows are associated with larger wave periods as well as larger wave heights. The relationship between predictor and predictand can be extrapolated to the future if we assume the hypothesis of stationary, that is, the relative frequencies of the WTs can vary over time but the predictor-predictand relationship remains constant. With this assumption, the distribution $f(y)$ of different variables (e.g. H_s) in a new time period can be obtained as follows:

$$f(y) = \sum_{i=1}^N p_i f_i(y), \quad (5.1)$$

where p_i is the relative frequency of the i th WT during the new period, $f_i(y)$ is the conditional distribution of the predictand for the i th WT and N is the number of WTs. The new frequencies (p_i) are computed by assigning each atmospheric situation to the most similar WT in the EOF space.

5.3.4. Selection of the ensemble of Global Climate Models

The historical and future simulations from the CMIP5 GCMs are projected on the WT classification and their climatology is evaluated. The projection is made after regridding each model's output to a common $1^\circ \times 1^\circ$ grid. We have followed the methodology and performance indices proposed by Perez et al. (2014b) to analyze the reliability of different GCMs. In this methodology three factors are analyzed: 1) the skill of GCMs to reproduce historical synoptic situations, 2) the skill of GCMs to reproduce the historical

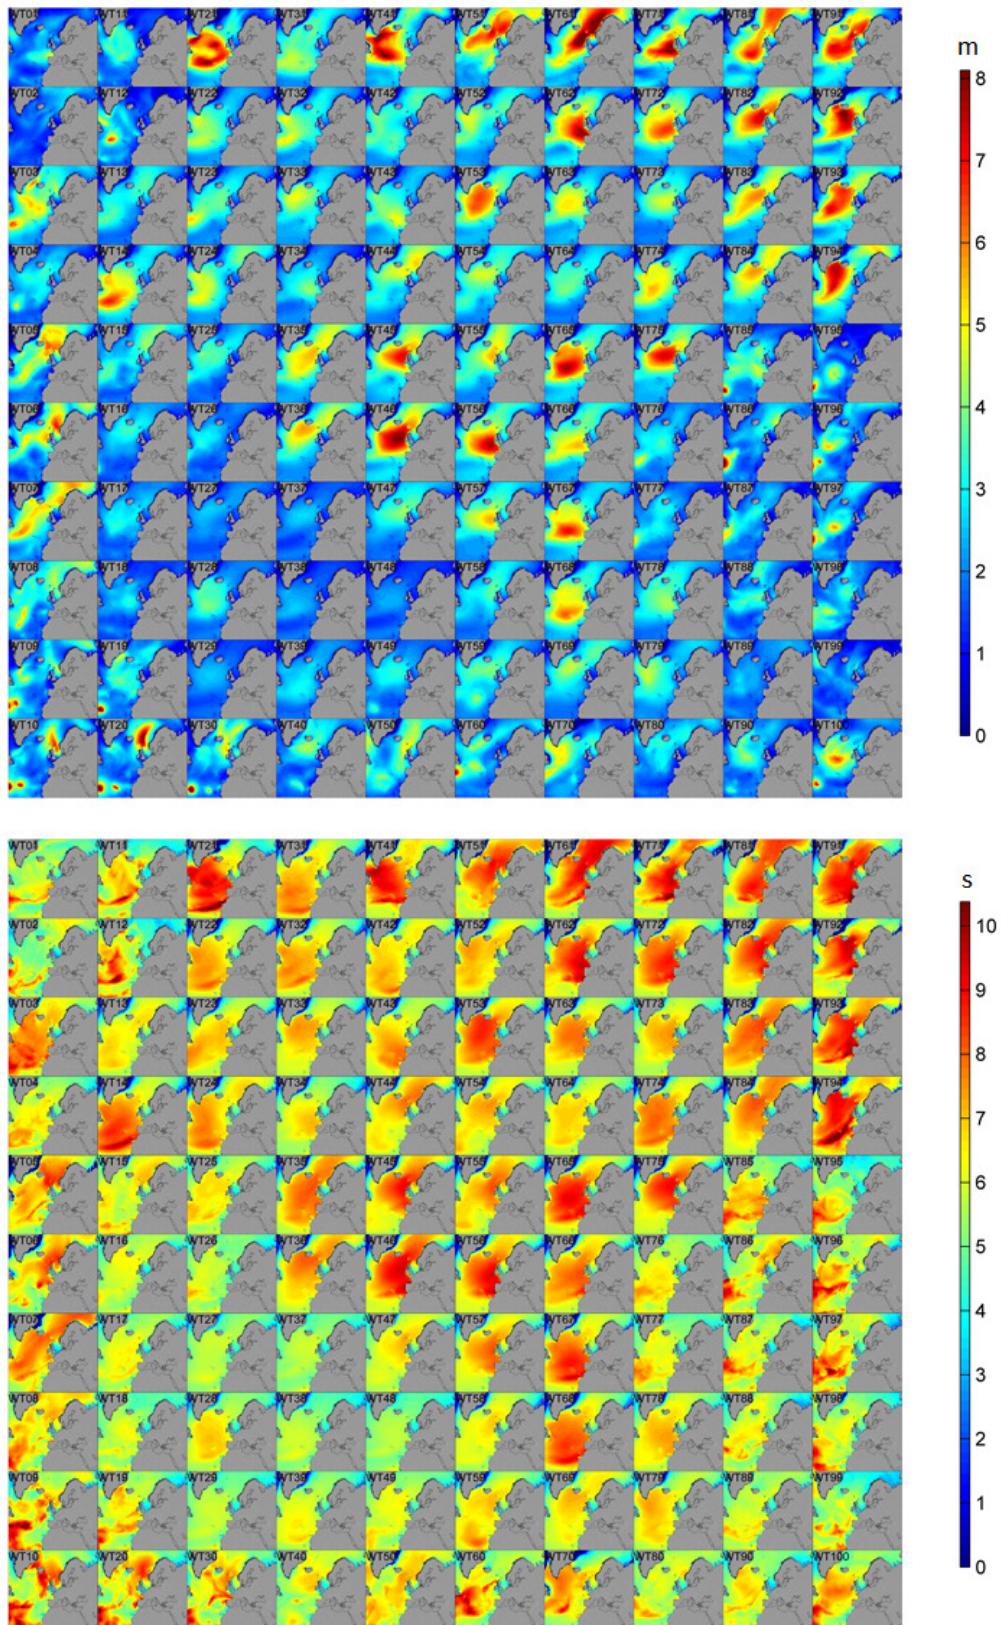


Figure 5.3: H_s , in meters (top) and T_{02} , in seconds (bottom) associated to each weather type

climate variability (interannual and seasonal), and 3) the consistency of GCMs in twenty-first century projections.

Results of this analysis are summarized in Table 5.1. In order to examine a wide range of processes we study eight different indices: SI , RE , $stdSI$, SI_{DJF} , SI_{MAM} , SI_{JJA} , SI_{SON} and *consistency*. When multiple simulations are available, the mean value of the index is considered. The skill to reproduce historical synoptic situations and climate variability are studied by comparing the GCMs to CFSR during the control period from 1979 to 2004. This period is chosen because CFSR begins in 1979 and most historical GCM simulations end in 2005. The first two indices measure the skill of the GCMs to reproduce historical synoptic situations from CFSR. SI is the root mean square error normalized by the mean frequency, and RE is a log-Euclidean distance. SI and RE measure absolute and relative differences in frequencies of the WTs, respectively. The next five indices measure the ability to reproduce the climate variability in CFSR. $StdSI$ analyzes the interannual variability and the four seasonal metrics (SI_{DJF} , SI_{MAM} , SI_{JJA} , SI_{SON}) analyze the climatology within the four seasons. The last index (*consistency*) analyzes changes in the climatology and interannual variability in order to detect GCMs with inconsistent future simulations, i.e., with a behavior vastly different than those of most GCMs. The consistency index analyzes the magnitude of changes between the historical experiment for the reference period (1975-2004) and the RCPs for three periods of thirty years during the twenty-first century (2010-2039, 2040-2069 and 2070-2099).

Given the variability among GCMs, we use the results of the evaluation of the GCMs to generate a reduced ensemble. We defined thresholds for the eight studied indices. GCMs over any of those thresholds are excluded from the reduced ensemble. The thresholds selected for all indices (except *consistency*) are the mean value of the index plus one standard deviation. For *consistency*, we consider two thresholds, the first quartile minus 1.5 times the interquartile range (IQR) and the third quartile plus 1.5 IQR. The ensemble is generated by simply averaging the relative frequencies of the individual GCMs. The reduced ensemble obtained using these thresholds is composed of 17 of the initial 42 models. This ensemble provides results with good agreement with historical climatology and high consistency. Therefore, it is reasonable to assume that future predictions based on this ensemble would be more reliable than those produced from a single GCM or an unfiltered ensemble. It is important to note, however, that the ensemble could be specified differently according to specific needs. For example, using all the available GCMs may give a better measure of the inter-model variability. Relative frequencies during the control period for CFSR and the reduced ensemble of GCMs are shown in Figure 5.4. Frequencies obtained from these two sources of data are very similar, but

Number	Model	<i>SI</i>	<i>RE</i>	<i>stdSI</i>	<i>SI_{DJF}</i>	<i>SI_{MAM}</i>	<i>SI_{JJA}</i>	<i>SI_{SON}</i>	<i>consistency</i>
	THRESHOLDS:	0.86	0.36	0.50	1.03	1.10	2.78	1.09	Q1-1.5IQR Q3+1.5IQR
01	CMCC-CMS	0.39	0.20	0.36	0.79	0.81	0.83	0.51	V
02	MPI-ESM-LR	0.42	0.19	0.39	0.73	0.84	1.50	0.63	V
03(OUT)	MPI-ESM-P	0.42	0.18	0.39	0.68	0.72	1.53	0.68	(OUT)
04	ACCESS1.3	0.42	0.21	0.42	0.76	0.87	1.21	0.68	V
05	EC-EARTH	0.44	0.19	0.41	0.67	0.89	1.19	0.69	V
06	CMCC-CM	0.45	0.23	0.37	0.74	0.85	1.37	0.60	V
07	MPI-ESM-MR	0.46	0.20	0.38	0.60	0.81	1.73	0.55	V
08	HadGEM2-CC	0.48	0.21	0.40	0.60	0.68	1.35	0.94	V
09	ACCESS1.0	0.49	0.22	0.41	0.67	0.62	1.61	0.92	V
10(OUT)	HadGEM2-AO	0.51	0.22	0.48	0.58	0.72	1.50	1.11(OUT)	(OUT)
11	CNRM-CM5	0.52	0.23	0.42	0.72	0.81	1.42	0.94	V
12(OUT)	GISS-E2-H	0.53	0.24	0.43	0.92	0.84	1.68	0.65	(OUT)
13	HadGEM2-ES	0.53	0.22	0.42	0.61	0.74	1.61	0.94	V
14(OUT)	CESM1(CAM5)	0.55	0.25	0.47	0.71	0.73	1.30	0.98	(OUT)
15(OUT)	NorESM1-M	0.56	0.27	0.42	0.85	1.18(OUT)	1.62	0.86	(OUT)
16(OUT)	CMCC-CESM	0.58	0.28	0.48	0.99	1.16(OUT)	1.20	0.92	V
17(OUT)	MIROC-ESM-CHEM	0.58	0.30	0.50(OUT)	0.96	1.20(OUT)	1.80	1.08	(OUT)
18(OUT)	BCC-CSM1.1	0.59	0.26	0.42	0.92	1.06	2.06	0.72	(OUT)
19(OUT)	GFDL-ESM2M	0.61	0.26	0.41	0.79	0.80	1.78	0.95	(OUT)
20	GISS-E2-R	0.62	0.27	0.43	0.90	0.92	2.32	0.68	V
21	BNU-ESM	0.65	0.29	0.44	1.01	0.97	1.73	1.04	V
22(OUT)	FGOALS-g2	0.65	0.32	0.44	1.00	0.99	1.43	0.70	(OUT)
23	HadCM3	0.65	0.28	0.44	0.99	1.06	1.38	0.67	V
24	CanESM2	0.67	0.32	0.48	0.93	0.89	1.71	1.05	V
25(OUT)	MIROC-ESM	0.71	0.33	0.50(OUT)	1.00	1.06	2.32	0.90	V
26	MIROC4h	0.71	0.31	0.41	0.95	0.74	1.56	0.97	V
27(OUT)	CCSM4	0.73	0.35	0.47	1.07(OUT)	1.08	2.21	0.91	V
28(OUT)	BCC-CSM1.1(m)	0.76	0.32	0.47	1.11(OUT)	1.23(OUT)	2.28	1.01	V
29	GFDL-ESM2G	0.77	0.28	0.42	0.76	0.79	2.39	1.02	V
30(OUT)	IPSL-CM5A-MR	0.78	0.35	0.52(OUT)	0.85	1.14(OUT)	2.55	1.09(OUT)	V
31	CanCM4	0.78	0.34	0.47	0.97	0.96	2.26	1.08	V
32(OUT)	CESM1(BGC)	0.80	0.37(OUT)	0.49	1.15(OUT)	0.92	2.36	0.95	V
33(OUT)	CESM1(FASTCHEM)	0.83	0.36(OUT)	0.52(OUT)	1.01	1.10	2.71	0.89	V
34(OUT)	GFDL-CM3	0.84	0.31	0.44	0.68	0.84	3.01(OUT)	0.80	(OUT)
35(OUT)	INM-CM4	0.88(OUT)	0.31	0.44	0.84	1.04	3.36(OUT)	0.82	V
36(OUT)	IPSL-CM5B-LR	0.89(OUT)	0.35	0.47	0.67	0.93	3.52(OUT)	0.68	V
37(OUT)	IPSL-CM5A-LR	0.92(OUT)	0.39(OUT)	0.54(OUT)	0.88	1.03	3.16(OUT)	1.11(OUT)	(OUT)
38(OUT)	MIROC5	0.93(OUT)	0.32	0.41	0.92	0.93	2.52	1.04	V
39(OUT)	FGOALS-s2	0.95(OUT)	0.43(OUT)	0.58(OUT)	1.28(OUT)	1.00	2.78(OUT)	1.29(OUT)	(OUT)
40(OUT)	CSIRO-Mk3.6.0	0.98(OUT)	0.39(OUT)	0.49	1.24(OUT)	1.13(OUT)	2.80(OUT)	1.13(OUT)	V
41(OUT)	MRI-CGCM3	1.03(OUT)	0.40(OUT)	0.48	0.83	1.11(OUT)	3.42(OUT)	1.23(OUT)	(OUT)
42(OUT)	MRI-ESM1	1.08(OUT)	0.42(OUT)	0.50(OUT)	0.79	1.15(OUT)	3.78(OUT)	1.09(OUT)	V

TABLE 5.1: Evaluation of the performance of the CMIP5 GCMs. Selected GCMs in bold

minor differences can be found. For example, the frequencies of WTs 44, 45, 46 and 65, associated with large swells, are underestimated by the GCM ensemble.

5.4. Results

5.4.1. Projected changes in the weather types

The WT classification of CFSR has been used to analyze the historical atmospheric circulation over Europe and predict changes to it. Projected changes in the relative frequency of the WTs during twenty-first century are computed for several scenarios using data from GCMs. We have analyzed three future scenarios (RCP2.6, RCP4.5 and RCP8.5) in three future periods (2010-2039, 2040-2069 and 2070-2099) against the reference period (1975-2004). We compare each simulation against its own representation

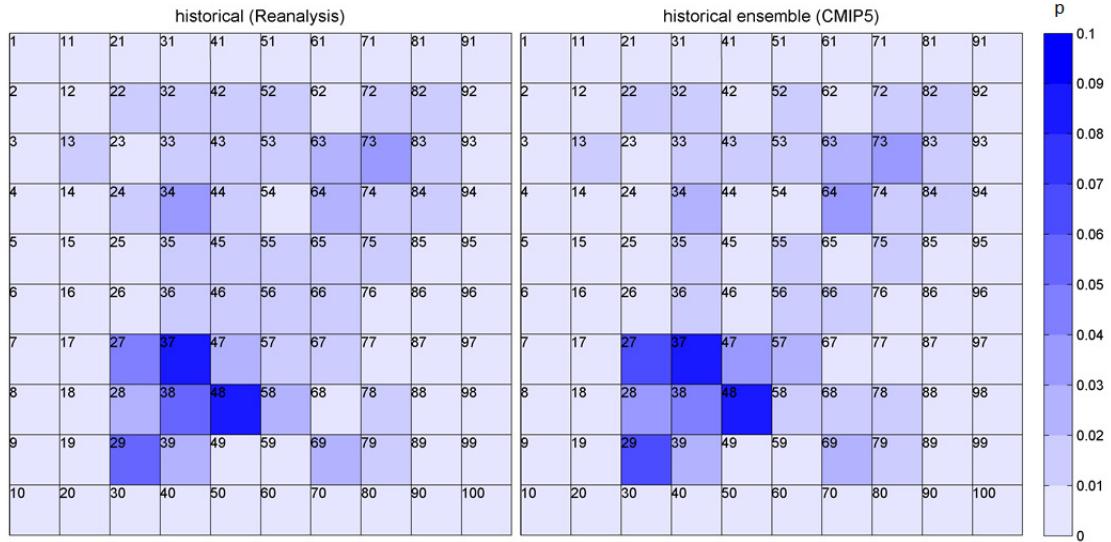


Figure 5.4: Relative frequencies of weather types during the control period (1979-2004) for reanalysis (*left*) and the ensemble of GCMs (*right*)

of the reference period when analyzing changes. Figure 5.5 shows patterns of change of the ensemble with respect to the reference period for different scenarios and time periods. The pattern of the changes is fairly consistent across scenarios and periods. However, high emissions scenarios lead to more intense changes than those of low emissions scenarios, and long-term changes are larger than short-term changes. An increase in frequencies of a group of WTs in the bottom left part of the classification (e.g. 27, 36, 37, 47 and 57) is noticeable. These WTs correspond to situations with gentle SLP gradients and small waves. A decrease in frequency of WTs associate with large waves (e.g. 45, 46, 55 and 56) can also be seen. As a result of these changes in the WT frequency, an intensification of the Azores high and a decrease of the Iceland low pressure system are expected. These changes agree with the ensemble mean of projected changes in SLP reported by Wang et al. (2014).

5.4.2. Projected wave climate changes

The statistical downscaling technique is applied to the WT frequencies from GCMs to obtain changes in wave climate. Changes in the short- (2010-39), mid- (2040-2069) and long-term (2070-2099) are computed with respect to the reference period (1975-2004). Figure 5.6 shows projected changes in the mean H_s in the North Atlantic on a grid of 0.5° . A decrease in H_s can be seen in all areas except in the north, where small increases can be found. The increase in the Norwegian coasts is mainly produced by the intensification of WT82. The increases off the coasts of Greenland and Russia should be analyzed carefully because they are found in areas often covered by ice, and may be

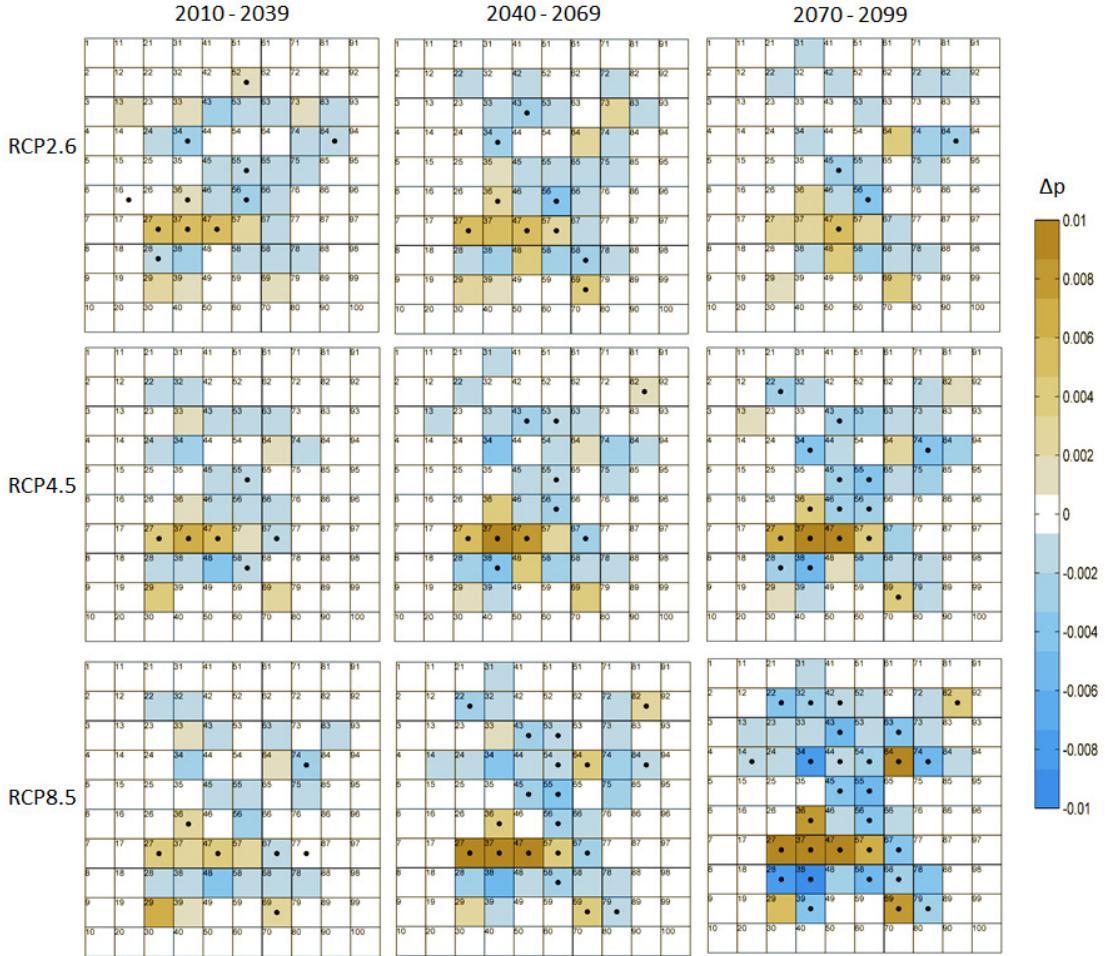


Figure 5.5: Changes in the frequency of the weather types for different scenarios (rcp2.6 top, rcp4.5 middle and rcp8.5 bottom) and time periods (2010-2039 left, 2040-2069 middle and 2070-2099 right) towards the reference period (1975-2004). Dots in the weather types indicate agreement on the sign of change of more than 80 % of the models

associated with changes in the ice coverage. The behavior for all scenarios is similar in the short-term with small reductions in wave height, but differs in the mid- and long-term. In the long-term, especially for RCP8.5, decreases in wave heights are much larger, reaching values of 10 centimeters in latitudes around 40°N. These results are consistent with previous studies of Hemer et al. (2013a), Wang et al. (2014) and Mori et al. (2010), though, Wang et al. (2014) found smaller decreases close to the coast and Mori et al. (2010) found increases in the Bay of Biscay. Figure 5.7 shows changes in T_{02} in the North Atlantic with a spatial resolution of 0.5°. Changes in mean period are consistent with changes in wave height. There is a clear decrease in T_{02} except in some northern coastal areas. Maximum decreases of 0.1 s are found for RCP8.5 in the long-term. Decreases in the mean period found by Hemer et al. (2013a) are larger (>0.2 s) and extended farther north and south.

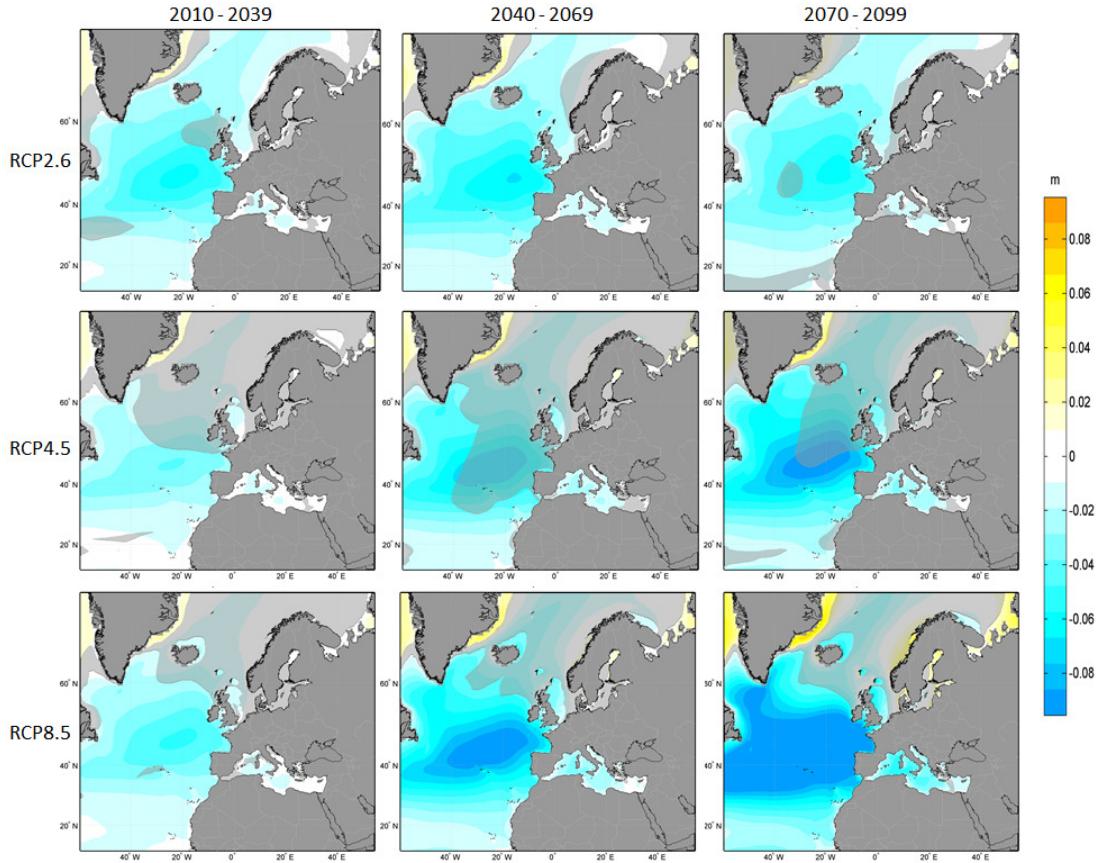


Figure 5.6: Changes in mean significant wave heights in the Eastern North Atlantic, in meters, for different scenarios (rcp2.6 *top*, rcp4.5 *middle*, and rcp8.5 *bottom*) and time periods (2010-2039 *left*, 2040-2069 *middle*, and 2070-2099 *right*) towards the reference period (1975-2004). No shadowed areas indicate agreement on the sign of change of more than 80 % of the models

Although significant wave height and mean period are the most commonly used parameters to describe wave climate variability, the method can also be applied to estimate changes in aggregated variables (e.g. wave energy flux). Figure 5.8 shows changes in the mean wave energy flux along the European coasts on a grid of 0.125° . A clear decrease in mean wave energy can be seen in both the North Atlantic sub-basin and in the Mediterranean Sea. Changes in the Mediterranean are lower in magnitude than in the Atlantic, but they are relatively large. As expected, larger decreases can be found for RCP8.5 in the long-term. Wave energy flux is proportional to $H_s^2 T_{02}$, thus, changes with the same sign in both H_s and T_{02} boost much more the wave energy flux. The inter-model variability for H_s , T_{02} and wave energy flux is larger for RCP4.5 and RCP8.5 than for RCP2.6, especially in the northern areas.

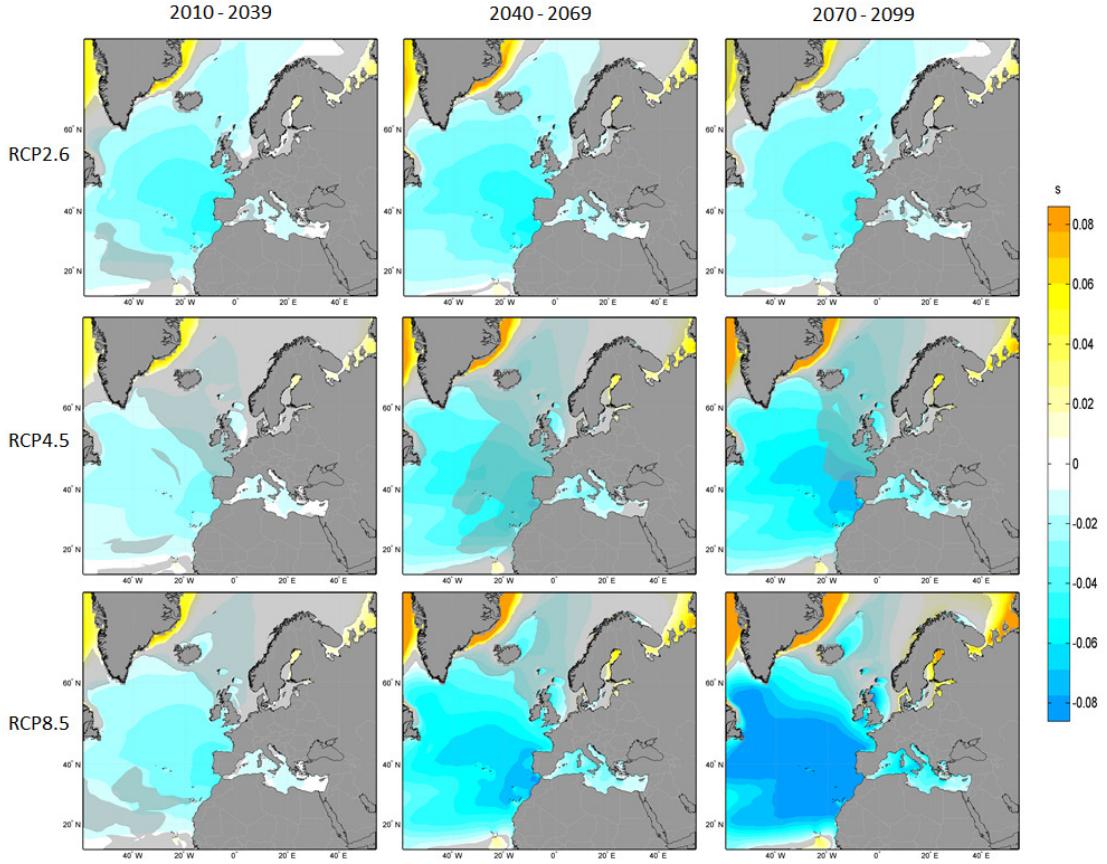


Figure 5.7: Changes in mean T_{02} wave periods in the Eastern North Atlantic, in seconds, for different scenarios (rcp2.6 top, rcp4.5 middle, and rcp8.5 bottom) and time periods (2010-2039 left, 2040-2069 middle, and 2070-2099 right) towards the reference period (1975-2004)

5.5. Summary and conclusions

A regional statistical downscaling of atmospheric conditions to multivariate wave climate has been developed and applied the North Atlantic sub-basin and the Mediterranean Sea. The method is based on a weather types approach. It allows easy visualization of weather types and associated wave climate. The main advantages of this method are its low computational cost and simplicity. The easy implementation for ensembles allows multi-model analysis for several future climate scenarios. The method allows the detection of the synoptic atmospheric conditions that are expected to be more or less frequent in the future. Future changes in the predictor responsible for changes in the wave climate can also be analyzed. Results show a general decrease in mean wave heights and periods in the North Atlantic and the Mediterranean. The decreases, found for all the analyzed scenarios, are larger for the long-term and high-emissions scenarios. Our results agree with other studies based on large ensembles, both statistical (e.g. Wang et al. 2014) and dynamical (e.g. Hemer et al. 2013a) downscaling. Some differences can be found between this study and other studies based in only one GCM. For example,

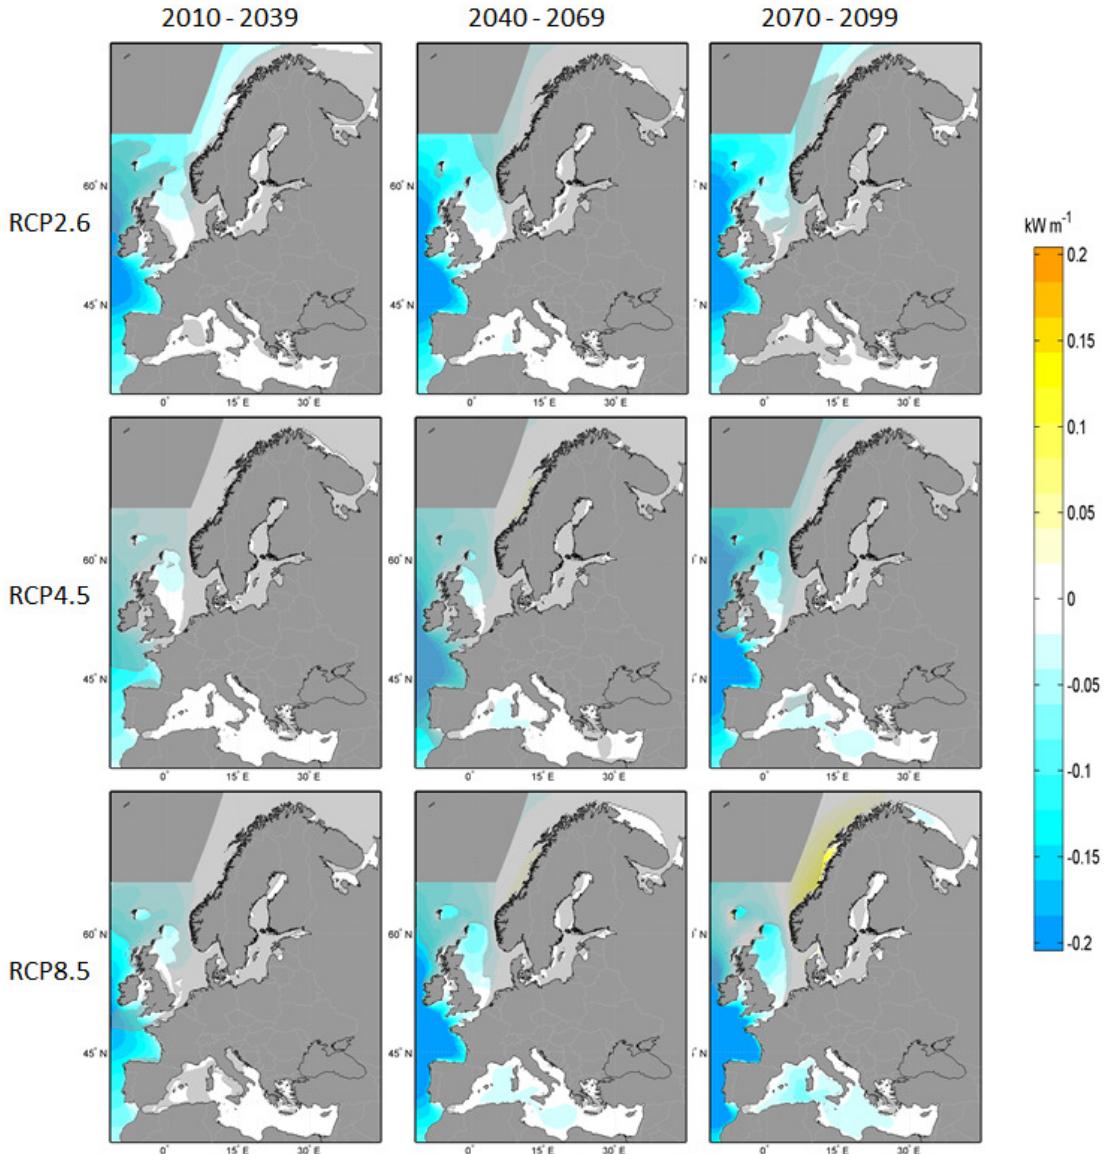


Figure 5.8: Changes in mean energy flux along the European coastline, in kW m^{-1} , for different scenarios (rcp2.6 top, rcp4.5 middle, and rcp8.5 bottom) and time periods (2010-2039 left, 2040-2069 middle, and 2070-2099 right) towards the reference period (1975-2004). No shadowed areas indicate agreement on the sign of change of more than 80 % of the models

Mori et al. (2010) found increases in the mean wave height in the Bay of Biscay. The reduction in both significant wave height and wave period produces a clear decrease in mean wave energy in the European coasts. This reduction can affect the profitability of wave energy extraction projects. Further work aims to scale-up this methodology to obtain high-resolution multi-model wave projections globally.

Chapter 6

Summary and future research

6.1. Summary of contributions

This work has yielded several contributions in the form of four papers and more than ten conference presentations. Some research related to this thesis, but not included in it, yielded to two additional papers coauthored by the PhD candidate: Camus et al. (2014a) and Mentaschi et al. (2015). Camus et al. (2014a) looks for optimal predictor indices for local wave conditions. Mentaschi et al. (2015) uses ideas derived from statistical downscaling to improve the modeling of unresolved obstacles in wave models. The summary of the results of the main four papers are showed below.

6.1.1. Summary of “ESTELA: a method for evaluating the source and travel time of the wave energy reaching a local area”

- ESTELA provides an easy and objective representation of the wave climate affecting a local area based on only two parameters: the effective energy flux and the wave energy travel time. The computational effort of ESTELA is very low because it is based on precomputed hindcast data.
- As spectral data is not always available, ESTELA proposes a simple method to reconstruct the full spectrum from the statistics of spectral partitions derived from hindcast models. The reconstructed spectra show a good agreement with direct output spectra and may be useful for a range of applications.
- The results offer a new tool for understanding regions of wave generation and the extent of swell propagation over the global ocean. For instance, the ESTELA maps

show the effects of model representation of small islands on the wave climate at distant locations and the time variability of wave generation areas.

- ESTELA maps information can be used to characterize the footprint of the wave climate. This is very useful for automating the definition of the predictor spatial domain in a statistical downscaling or to define the extent of high resolution meshes in a dynamical downscaling.

6.1.2. Summary of “A weather-type statistical downscaling framework for ocean wave climate”

- A statistical downscaling framework to project wave climate is proposed based on weather typing. The statistical relationship is established between the atmospheric predictor, defined by the SLP fields and the squared SLP gradients, and the local wave climate.
- The local multivariate wave climate can be characterized based on a physical relation with atmospheric conditions.
- The advantage of the method is the low computational time to characterize wave climate without information of wind fields and bathymetry.
- The model validation proves to reproduce the seasonal and interannual variability of the monthly mean and 95 percentile of H_s , T_m , $H_s^2 T_m$, and θ_{FE} . Therefore, the proposed SD method is a useful tool for coastal impact assessment.
- The SD model is able to produce long historical reconstructions. SLP forcing from 20CR reanalysis is used to reconstruct local waves through the 20th century, obtaining wave statistics and trends in agreement with previous works by other authors (Bertin et al. 2013; Cox and Swail 2001; Wang et al. 2012).
- The update of the local wave hindcast in the winter 2013-2014 shows the applicability of the SD approach for seasonal forecast.
- The SD model is a useful tool to get wave climate multimodel ensemble projections with low computational cost.

6.1.3. Summary of “Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region”

- A methodology to analyze the performance of GCMs based on weather types and statistical metrics has been developed. The method analyzes the ability of the

models to reproduce three characteristics: the historical synoptic climatologies, the interannual variations and the consistency of future projections. Use of statistic metrics allows a quantitative estimation of GCMs performance.

- The quality of the GCMs depends on the study area and the considered variable. The performance of the GCMs also varies depending on the analyzed season. Therefore, the choice of the most adequate models depends on the specific purposes (e.g. studies focus on extreme wave heights during winter or ice melting during summer). On the contrary, from the analysis carried out the importance of the atmospheric resolution is not clear. The models with the highest resolution are not always performing the best.
- The small differences in the skill indexes among runs of the same model indicate that the methodology is robust because it is not considerably affected by the natural variability of climate.
- Notable differences can be observed in future simulations, even among the best rated models. Therefore, the use of ensembles or multimodel groups is recommended since it diminishes the effects of individual simulations allowing us to have greater confidence on the results.

6.1.4. Summary of “Statistical multi-model climate projections of surface ocean waves in Europe”

- A regional statistical downscaling of atmospheric conditions to multivariate wave climate has been developed and applied the North Atlantic sub-basin and the Mediterranean Sea. The method is based on a weather types approach. It allows easy visualization of weather types and associated wave climate. The main advantages of this method are its low computational cost and simplicity. The easy implementation for ensembles allows multi-model analysis for several future climate scenarios. The method allows the detection of the synoptic atmospheric conditions that are expected to be more or less frequent in the future. Future changes in the predictor responsible for changes in the wave climate can also be analyzed.
- Results show a general decrease in mean wave heights and periods in the North Atlantic and the Mediterranean. The decreases, found for all the analyzed scenarios, are larger for the long-term and high-emissions scenarios. Our results agree with other studies based on large ensembles, both statistical (e.g. Wang et al. 2014) and dynamical (e.g. Hemer et al. 2013a) downscaling. Some differences can be found between this study and other studies based in only one GCM.

- The reduction in both significant wave height and wave period produces a clear decrease in mean wave energy in the European coasts. This reduction can affect the profitability of wave energy extraction projects.

6.2. Future research topics

The methodologies described in this work allow further development. The most important line of work at this point is to scale-up the downscaling technique to be applicable at a global scale. The ultimate goal is to obtain statistical high-resolution global projections of wave climate based on a multi-model. Four topics that need additional work are identified: 1) definition of the area and time span of the predictors; 2) selection of the predictor variable; 3) study of new predictands; and 4) uncertainty in wave climate projections.

1. ESTELA methodology has made easier to define the area and time span of the predictors. However, in locations where several families of waves are present, the choice of an optimal predictor is not obvious. For example, in Oregon (USA), waves usually come from the northern hemisphere with a travel time of one week, but in summer, waves from the southern hemisphere with travel times of two or three weeks become more important. With a time span of one week southern waves are not correctly captured and with two or three weeks the results in northern hemisphere become poorer. Camus et al. (2014a) presents the first step to solve this problem; the predictor is composed of a local and a regional part, representing the sea and swell conditions respectively. This idea may be expanded with a predictor for every component of the spectrum.
2. The selection of SLP and SLP gradients as predictor provides good results in most areas. In some areas, however, ice coverage is also important. Obviously, ice coverage has to be considered to reconstruct wave climate in locations that occasionally are covered by ice. Moreover, it has to be considered for reconstructions in other locations, when the generation or propagation areas may be covered by ice.
3. Wave climate projections presented in chapter 5 are focused on mean significant wave height, mean period and mean wave energy. However, changes in the full spectrum are more useful to study impacts such as sediment transport or harbor operability. Moreover, changes in extremes may produce larger impacts than changes in the mean climate. The downscaling technique presented has proven useful for wave spectral variability (Espejo et al. 2014) and extremes (Rueda et al.

2015). Future work intends to study changes in both the full spectrum and extremes for climate change scenarios. The spectrum reconstruction presented in Perez et al. (2014a) should be improved in future works.

4. The selection of the ensemble of GCMs may respond to a number of needs. In dynamical downscaling is necessary to use a small number of models in order to reduce the computational cost. In statistical downscaling is possible to use all the available models but some of them seem better than others. In order to study uncertainty, analyzing a large number of GCMs seems to be the best approach. Whether the differences are due to uncertainties in climate or poor performance of some models is a question that remains open.

Bibliography

- Alves, J.H.G., 2006. Numerical modeling of ocean swell contributions to the global wind-wave climate. *Ocean Modelling* 11, 98–122. doi:10.1016/j.ocemod.2004.11.007.
- Amante, C., Eakins, B.W., 2009. Etopo1 1 Arc-Minute Global Relief Model: Procedures, Data Sources and Analysis.
- Ardhuin, F., Chapron, B., Collard, F., 2009. Observation of swell dissipation across oceans. *Geophysical Research Letters* 36, L06607. doi:10.1029/2008GL037030, arXiv:0809.2497.
- Ardhuin, F., Rogers, E., Babanin, A.V., Filipo, J.F., Magne, R., Roland, A., van der Westhuysen, A., Queffeulou, P., Lefevre, J.M., Aouf, L., Collard, F., 2010. Semiempirical Dissipation Source Functions for Ocean Waves. Part I: Definition, Calibration, and Validation. *Journal of Physical Oceanography* 40, 1917–1941. doi:10.1175/2010JPO4324.1, arXiv:0907.4240.
- Barber, N.F., Ursell, F., 1948. The Generation and Propagation of Ocean Waves and Swell. I. Wave Periods and Velocities. doi:10.1098/rsta.1948.0005.
- Belleflamme, A., Fettweis, X., Lang, C., Erpicum, M., 2013. Current and future atmospheric circulation at 500 hPa over Greenland simulated by the CMIP3 and CMIP5 global models. *Climate Dynamics* 41, 2061–2080. doi:10.1007/s00382-012-1538-2.
- Bermejo, M., Ancell, R., 2009. Observed changes in extreme temperatures over Spain during 1957–2002, using Weather Types. *Revista de Climatología* 9, 45–61.
- Bertin, X., Prouteau, E., Letetrel, C., 2013. A significant increase in wave height in the North Atlantic Ocean over the 20th century. *Global and Planetary Change* 106, 77–83. doi:10.1016/j.gloplacha.2013.03.009.
- Brands, S., Herrera, S., Fernández, J., Gutiérrez, J.M., 2013. How well do CMIP5 Earth System Models simulate present climate conditions in Europe and Africa? *Climate Dynamics* 41, 803–817. doi:10.1007/s00382-013-1742-8.

- Brands, S., Herrera, S., San-Martín, D., Gutiérrez, J., 2011. Validation of the ENSEMBLES global climate models over southwestern Europe using probability density function, from a downscaling perspective. *Climate Research* 48, 145–161. doi:10.3354/cr00995.
- Bromirski, P.D., 2005. Wave spectral energy variability in the northeast Pacific. *Journal of Geophysical Research* 110, C03005. doi:10.1029/2004JC002398.
- Busuioc, A., Chen, D., Hellstrom, C., 2001. Performance of statistical downscaling models in GCM validation and regional climate change estimates: application for Swedish precipitation. *International Journal of Climatology* 21, 557–578. doi:10.1002/joc.624.
- Caires, S., Swail, V.R., Wang, X.L., 2006. Projection and Analysis of Extreme Wave Climate. *Journal of Climate* 19, 5581–5605. doi:10.1175/JCLI3918.1.
- Camus, P., Méndez, F.J., Losada, I.J., Menéndez, M., Espejo, A., Pérez, J., Rueda, A., Guanche, Y., 2014a. A method for finding the optimal predictor indices for local wave climate conditions. *Ocean Dynamics* 64, 1025–1038. doi:10.1007/s10236-014-0737-2.
- Camus, P., Mendez, F.J., Medina, R., Cofiño, A.S., 2011. Analysis of clustering and selection algorithms for the study of multivariate wave climate. *Coastal Engineering* 58, 453–462. doi:10.1016/j.coastaleng.2011.02.003.
- Camus, P., Menéndez, M., Méndez, F.J., Izaguirre, C., Espejo, A., Cánovas, V., Pérez, J., Rueda, A., Losada, I.J., Medina, R., 2014b. A weather-type statistical downscaling framework for ocean wave climate. *Journal of Geophysical Research: Oceans* 119, 7389–7405. doi:10.1002/2014JC010141.
- Casas-Prat, M., Wang, X.L., Sierra, J.P., 2014. A physical-based statistical method for modeling ocean wave heights. *Ocean Modelling* 73, 59–75. doi:10.1016/j.ocemod.2013.10.008.
- Cattiaux, J., Douville, H., Peings, Y., 2013. European temperatures in CMIP5: origins of present-day biases and future uncertainties. *Climate Dynamics* 41, 2889–2907. doi:10.1007/s00382-013-1731-y.
- Charles, E., Idier, D., Thiébot, J., Le Cozannet, G., Pedreros, R., Ardhuin, F., Planton, S., 2012. Present Wave Climate in the Bay of Biscay: Spatiotemporal Variability and Trends from 1958 to 2001. *Journal of Climate* 25, 2020–2039. doi:10.1175/JCLI-D-11-00086.1.

- Chawla, A., Tolman, H.L., 2008. Obstruction grids for spectral wave models. *Ocean Modelling* 22, 12–25. doi:10.1016/j.ocemod.2008.01.003.
- Collard, F., Arduin, F., Chapron, B., 2009. Monitoring and analysis of ocean swell fields from space: New methods for routine observations. *Journal of Geophysical Research* 114, C07023. doi:10.1029/2008JC005215.
- Compo, G.P., Whitaker, J.S., Sardeshmukh, P.D., Matsui, N., Allan, R.J., Yin, X., Gleason, B.E., Vose, R.S., Rutledge, G., Bessemoulin, P., Brönnimann, S., Brunet, M., Crouthamel, R.I., Grant, a.N., Groisman, P.Y., Jones, P.D., Kruk, M.C., Kruger, a.C., Marshall, G.J., Maugeri, M., Mok, H.Y., Nordli, O., Ross, T.F., Trigo, R.M., Wang, X.L., Woodruff, S.D., Worley, S.J., 2011. The Twentieth Century Reanalysis Project. *Quarterly Journal of the Royal Meteorological Society* 137, 1–28. doi:10.1002/qj.776.
- Cox, A.T., Swail, V.R., 2001. A global wave hindcast over the period 1958–1997: Validation and climate assessment. *Journal of Geophysical Research* 106, 2313. doi:10.1029/2001JC000301.
- Devaliere, E.M., Hanson, J.L., Luettich, R., 2009. Spatial Tracking of Numerical Wave Model Output Using a Spiral Search Algorithm, in: 2009 WRI World Congress on Computer Science and Information Engineering, IEEE. pp. 404–408. doi:10.1109/CSIE.2009.1021.
- Dore, B., 1978. Some effects of the air-water interface on gravity waves. *Geophysical & Astrophysical Fluid Dynamics* 10, 215–230.
- Dupuis, H., Michel, D., Sottolichio, A., 2006. Wave climate evolution in the Bay of Biscay over two decades. *Journal of Marine Systems* 63, 105–114. doi:10.1016/j.jmarsys.2006.05.009.
- Erikson, L., Hegermiller, C., Barnard, P., Ruggiero, P., van Ormondt, M., 2015. Projected wave conditions in the Eastern North Pacific under the influence of two CMIP5 climate scenarios. *Ocean Modelling* doi:10.1016/j.ocemod.2015.07.004.
- Errasti, I., Ezcurra, A., Sáenz, J., Ibarra-Berastegi, G., 2011. Validation of IPCC AR4 models over the Iberian Peninsula. *Theoretical and Applied Climatology* 103, 61–79. doi:10.1007/s00704-010-0282-y.
- Espejo, A., Camus, P., Losada, I.n.J., Méndez, F.J., 2014. Spectral Ocean Wave Climate Variability Based on Atmospheric Circulation Patterns. *Journal of Physical Oceanography* 44, 2139–2152. doi:10.1175/JPO-D-13-0276.1.
- Flato, G.M., 2011. Earth system models: an overview. *Wiley Interdisciplinary Reviews: Climate Change* 2, 783–800.

- Fowler, H.J., Blenkinsop, S., Tebaldi, C., 2007. Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *International Journal of Climatology* 27, 1547–1578. doi:10.1002/joc.1556.
- Frías, M.D., Zorita, E., Fernández, J., Rodríguez-Puebla, C., 2006. Testing statistical downscaling methods in simulated climates. *Geophysical Research Letters* 33, L19807. doi:10.1029/2006GL027453.
- Gerber, E.P., Polvani, L.M., Ancukiewicz, D., 2008. Annular mode time scales in the Intergovernmental Panel on Climate Change Fourth Assessment Report models. *Geophysical Research Letters* 35, L22707. doi:10.1029/2008GL035712.
- Gerling, T.W., 1992. Partitioning Sequences and Arrays of Directional Ocean Wave Spectra into Component Wave Systems. *Journal of Atmospheric and Oceanic Technology* 9, 444–458. doi:10.1175/1520-0426(1992)009<0444:PSAAOD>2.0.CO;2.
- Giorgi, F., Hewitson, B., Christensen, J., Hulme, M., von Storch, H., Whetton, P., Jones, R., Mearns, L., Fu, C., Arritt, R., Bates, B., Benestad, R., Boer, G., Buishand, A., Castro, M., Chen, D., Cramer, W., Crane, R., Crossly, J., Dehn, M., Dethloff, K., Dippner, J., Emori, S., Francisco, R., Fyfe, J., Gerstengarbe, F., Gutowski, W., Gyalistras, D., Hanssen-Bauer, I., Hantel, M., Hassell, D., Heimann, D., Jack, C., Jacobbeit, J., Kato, H., Katz, R., Kauker, F., Knutson, T., Lal, M., Landsea, C., Laprise, R., Leung, L., Lynch, A., May, W., McGregor, J., Miller, N., Murphy, J., Ribalaygua, J., Rinke, A., Rummukainen, M., Semazzi, F., Walsh, K., Werner, P., Widmann, M., Wilby, R., Wild, M., Xue, Y., 2001. Regional climate information-evaluation and projections, in: *Climate Change 2001: The Scientific Basis*, pp. 583–638.
- Gleckler, P.J., Taylor, K.E., Doutriaux, C., 2008. Performance metrics for climate models. *Journal of Geophysical Research* 113, D06104. doi:10.1029/2007JD008972.
- Grabemann, I., Weisse, R., 2008. Climate change impact on extreme wave conditions in the north sea: An ensemble study. *Ocean Dynamics* 58, 199–212. doi:10.1007/s10236-008-0141-x.
- Graham, N.E., Diaz, H.F., 2001. Evidence for Intensification of North Pacific Winter Cyclones since 1948. *Bulletin of the American Meteorological Society* 82, 1869–1893. doi:10.1175/1520-0477(2001)082<1869:EFIONP>2.3.CO;2.
- Gulev, S.K., 2003. Assessment of the reliability of wave observations from voluntary observing ships: Insights from the validation of a global wind wave climatology based on voluntary observing ship data. *Journal of Geophysical Research* 108, 3236. doi:10.1029/2002JC001437.

- Gulev, S.K., Grigorieva, V., 2006. Variability of the Winter Wind Waves and Swell in the North Atlantic and North Pacific as Revealed by the Voluntary Observing Ship Data. *Journal of Climate* 19, 5667–5685. doi:10.1175/JCLI3936.1.
- Gulev, S.K., Zolina, O., Grigoriev, S., 2001. Extratropical cyclone variability in the Northern Hemisphere winter from the NCEP/NCAR reanalysis data. *Climate Dynamics* 17, 795–809. doi:10.1007/s003820000145.
- Gutiérrez, J.M., San-Martín, D., Brands, S., Manzanas, R., Herrera, S., 2013. Reassessing Statistical Downscaling Techniques for Their Robust Application under Climate Change Conditions. *Journal of Climate* 26, 171–188. doi:10.1175/JCLI-D-11-00687.1.
- Hanson, J.L., Phillips, O.M., 2001. Automated Analysis of Ocean Surface Directional Wave Spectra. *Journal of Atmospheric and Oceanic Technology* 18, 277–293. doi:10.1175/1520-0426(2001)018<0277:AAOOSD>2.0.CO;2.
- Hasselmann, K., Barnett, T., Bouws, E., Carlson, H., Cartwright, D., Enke, K., Ewing, J., Gienapp, H., Hasselmann, D., Kruseman, P., Meerburg, A., Müller, P., Olbers, D., Richter, K., Sell, W., Walden, H., 1973. Measurements of wind–wave growth and swell decay during the Joint North SeaWave Project. *Erganzungsheft zur Deutschen Hydrographischen Zeitschrift* 46.
- Hastie, T., Tibshirani, R., Friedman, J., 2009. The Elements of Statistical Learning. volume 1 of *Springer Series in Statistics*. Springer New York, New York, NY. doi:10.1007/b94608.
- Hazeleger, W., Wang, X., Severijns, C., Ţăfărescu, S., Bintanja, R., Sterl, A., Wyser, K., Semmler, T., Yang, S., van den Hurk, B., van Noije, T., van der Linden, E., van der Wiel, K., 2012. EC-Earth V2.2: description and validation of a new seamless earth system prediction model. *Climate Dynamics* 39, 2611–2629. doi:10.1007/s00382-011-1228-5.
- Hemer, M.A., Church, J.a., Hunter, J.R., 2010a. Variability and trends in the directional wave climate of the Southern Hemisphere. *International Journal of Climatology* 30, n/a–n/a. doi:10.1002/joc.1900.
- Hemer, M.A., Fan, Y., Mori, N., Semedo, A., Wang, X.L., 2013a. Projected changes in wave climate from a multi-model ensemble. *Nature Climate Change* 3, 471–476. doi:10.1038/nclimate1791.
- Hemer, M.A., Katzfey, J., Trenham, C.E., 2013b. Global dynamical projections of surface ocean wave climate for a future high greenhouse gas emission scenario. *Ocean Modelling* 70, 221–245. doi:10.1016/j.ocemod.2012.09.008.

- Hemer, M.A., Wang, X.L., Church, J.a., Swail, V.R., 2010b. Coordinating Global Ocean Wave Climate Projections. *Bulletin of the American Meteorological Society* 91, 451–454. doi:10.1175/2009BAMS2951.1.
- Hemer, M.A., Wang, X.L., Weisse, R., Swail, V.R., 2012. Advancing Wind-Waves Climate Science. *Bulletin of the American Meteorological Society* 93, 791–796. doi:10.1175/BAMS-D-11-00184.1.
- Holthuijsen, L., 2007. Waves in Oceanic and Coastal Waters. Cambridge University Press, Cambridge.
- Hurrell, J.W., Kushnir, Y., Ottersen, G., Visbeck, M., 2003. An Overview of the North Atlantic Oscillation. *The North Atlantic Oscillation: Climate Significance and Environmental Impact*, 1–35.
- Huth, R., 2000. A circulation classification scheme applicable in GCM studies. *Theoretical and Applied Climatology* 67, 1–18. doi:10.1007/s007040070012.
- Huth, R., 2010. Synoptic-climatological applicability of circulation classifications from the COST733 collection: First results. *Physics and Chemistry of the Earth, Parts A/B/C* 35, 388–394. doi:10.1016/j.pce.2009.11.013.
- Izaguirre, C., Méndez, F.J., Espejo, A., Losada, I.J., Reguero, B.G., 2013. Extreme wave climate changes in Central-South America. *Climatic Change* 119, 277–290. doi:10.1007/s10584-013-0712-9.
- Izaguirre, C., Mendez, F.J., Menendez, M., Luceño, A., Losada, I.J., 2010. Extreme wave climate variability in southern Europe using satellite data. *Journal of Geophysical Research* 115, C04009. doi:10.1029/2009JC005802.
- Izaguirre, C., Menéndez, M., Camus, P., Méndez, F.J., Mínguez, R., Losada, I.J., 2012. Exploring the interannual variability of extreme wave climate in the Northeast Atlantic Ocean. *Ocean Modelling* 59-60, 31–40. doi:10.1016/j.ocemod.2012.09.007.
- Jones, P.D., Jonsson, T., Wheeler, D., 1997. Extension to the North Atlantic oscillation using early instrumental pressure observations from Gibraltar and south-west Iceland. *International Journal of Climatology* 17, 1433–1450. doi:10.1002/(SICI)1097-0088(19971115)17:13<1433::AID-JOC203>3.0.CO;2-P.
- Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., Gandin, L., Iredell, M., Saha, S., White, G., Woollen, J., Zhu, Y., Leetmaa, A., Reynolds, R., Chelliah, M., Ebisuzaki, W., Higgins, W., Janowiak, J., Mo, K.C., Ropelewski, C., Wang, J., Jenne, R., Joseph, D., 1996. The NCEP/NCAR 40-Year Reanalysis Project. *Bulletin*

- of the American Meteorological Society 77, 437–471. doi:10.1175/1520-0477(1996)077<0437:TNYRP>2.0.CO;2.
- Kistler, R., Collins, W., Saha, S., White, G., Woollen, J., Kalnay, E., Chelliah, M., Ebisuzaki, W., Kanamitsu, M., Kousky, V., van den Dool, H., Jenne, R., Fiorino, M., 2001. The NCEP–NCAR 50-Year Reanalysis: Monthly Means CD-ROM and Documentation. *Bulletin of the American Meteorological Society* 82, 247–267. doi:10.1175/1520-0477(2001)082<0247:TNNYRM>2.3.CO;2.
- Lamb, H.H., 1972. British Isles weather types and a register of the daily sequence of circulation patterns 1861–1971. Her Majesty's stationery office.
- Laugel, A., Menendez, M., Benoit, M., Mattarolo, G., Méndez, F., 2014. Wave climate projections along the French coastline: Dynamical versus statistical downscaling methods. *Ocean Modelling* 84, 35–50. doi:10.1016/j.ocemod.2014.09.002.
- Le Cozannet, G., Lecacheux, S., Delvallee, E., Desramaut, N., Oliveros, C., Pedreros, R., 2011. Teleconnection Pattern Influence on Sea-Wave Climate in the Bay of Biscay. *Journal of Climate* 24, 641–652. doi:10.1175/2010JCLI3589.1.
- Lee, C.C., Sheridan, S.C., 2012. A six-step approach to developing future synoptic classifications based on GCM output. *International Journal of Climatology* 32, 1792–1802. doi:10.1002/joc.2394.
- Lorenzo, M.N., Ramos, A.M., Taboada, J.J., Gimeno, L., 2011. Changes in Present and Future Circulation Types Frequency in Northwest Iberian Peninsula. *PLoS ONE* 6, e16201. doi:10.1371/journal.pone.0016201.
- MacQueen, J.B., 1967. Kmeans Some Methods for classification and Analysis of Multivariate Observations. 5th Berkeley Symposium on Mathematical Statistics and Probability 1967 1, 281–297. doi:citeulike-article-id:6083430.
- Maraun, D., Wetterhall, F., Ireson, A.M., Chandler, R.E., Kendon, E.J., Widmann, M., Brien, S., Rust, H.W., Sauter, T., Themeßl, M., Venema, V.K.C., Chun, K.P., Goodess, C.M., Jones, R.G., Onof, C., Vrac, M., Thiele-Eich, I., 2010. Precipitation downscaling under climate change: Recent developments to bridge the gap between dynamical models and the end user. *Reviews of Geophysics* 48, RG3003. doi:10.1029/2009RG000314.
- Marcos, M., Jordà, G., Gomis, D., Pérez, B.n., 2011. Changes in storm surges in southern Europe from a regional model under climate change scenarios. *Global and Planetary Change* 77, 116–128. doi:10.1016/j.gloplacha.2011.04.002.

- Maxino, C.C., McAvaney, B.J., Pitman, A.J., Perkins, S.E., 2008. Ranking the AR4 climate models over the Murray-Darling Basin using simulated maximum temperature, minimum temperature and precipitation. *International Journal of Climatology* 28, 1097–1112. doi:10.1002/joc.1612.
- Meehl, G.a., Covey, C., Taylor, K.E., Delworth, T., Stouffer, R.J., Latif, M., McAvaney, B., Mitchell, J.F.B., 2007. THE WCRP CMIP3 Multimodel Dataset: A New Era in Climate Change Research. *Bulletin of the American Meteorological Society* 88, 1383–1394. doi:10.1175/BAMS-88-9-1383.
- Menendez, M., García-Díez, M., Fita, L., Fernández, J., Méndez, F.J., Gutiérrez, J.M., 2014. High-resolution sea wind hindcasts over the Mediterranean area. *Climate Dynamics* 42, 1857–1872. doi:10.1007/s00382-013-1912-8.
- Menéndez, M., Méndez, F.J., Losada, I.J., Graham, N.E., 2008. Variability of extreme wave heights in the northeast Pacific Ocean based on buoy measurements. *Geophysical Research Letters* 35, L22607. doi:10.1029/2008GL035394.
- Mentaschi, L., Pérez, J., Besio, G., Mendez, F., Menendez, M., 2015. Parameterization of unresolved obstacles in wave modelling: A source term approach. *Ocean Modelling* 000, 1–10. doi:10.1016/j.ocemod.2015.05.004.
- Mitsuyasu, H., Tasai, F., Suhara, T., Mizuno, S., Ohkusu, M., Honda, T., Rikiishi, K., 1975. Observations of the Directional Spectrum of Ocean Waves Using a Cloverleaf Buoy. *Journal of Physical Oceanography* 5, 750–760. doi:10.1175/1520-0485(1975)005<0750:OOTDSO>2.0.CO;2.
- Mori, N., Yasuda, T., Mase, H., Tom, T., Oku, Y., 2010. Projection of Extreme Wave Climate Change under Global Warming. *Hydrological Research Letters* 4, 15–19. doi:10.3178/hrl.4.15.
- Moss, R.H., Edmonds, J.a., Hibbard, K.a., Manning, M.R., Rose, S.K., van Vuuren, D.P., Carter, T.R., Emori, S., Kainuma, M., Kram, T., Meehl, G.a., Mitchell, J.F.B., Nakicenovic, N., Riahi, K., Smith, S.J., Stouffer, R.J., Thomson, A.M., Weyant, J.P., Wilbanks, T.J., 2010. The next generation of scenarios for climate change research and assessment. *Nature* 463, 747–756. doi:10.1038/nature08823.
- Munk, W.H., 1947. Tracking storms by forerunners of swell. *Journal of Meteorology* 4, 45–57. doi:10.1175/1520-0469(1947)004<0045:TSBFOS>2.0.CO;2.
- Munk, W.H., Miller, G.R., Snodgrass, F.E., Barber, N.F., 1963. Directional Recording of Swell from Distant Storms. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 255, 505–584. doi:10.1098/rsta.1963.0011.

- Nakicenovic, N., Swart, R., 2000. Special report on emissions scenarios.
- Nieto, S., Rodríguez-Puebla, C., 2006. Comparison of Precipitation from Observed Data and General Circulation Models over the Iberian Peninsula. *Journal of Climate* 19, 4254–4275. doi:10.1175/JCLI3859.1.
- Pastor, M.a., Casado, M.J., 2012. Use of circulation types classifications to evaluate AR4 climate models over the Euro-Atlantic region. *Climate Dynamics* 39, 2059–2077. doi:10.1007/s00382-012-1449-2.
- Perez, J., Mendez, F.J., Menendez, M., Losada, I.J., 2014a. ESTELA: a method for evaluating the source and travel time of the wave energy reaching a local area. *Ocean Dynamics* 64, 1181–1191. doi:10.1007/s10236-014-0740-7.
- Perez, J., Menendez, M., Camus, P., Mendez, F.J., Losada, I.J., 2015. Statistical multi-model climate projections of surface ocean waves in Europe. *Ocean Modelling* 000, 1–10. doi:10.1016/j.ocemod.2015.06.001.
- Perez, J., Menendez, M., Mendez, F.J., Losada, I.J., 2014b. Evaluating the performance of CMIP3 and CMIP5 global climate models over the north-east Atlantic region. *Climate Dynamics* 43, 2663–2680. doi:10.1007/s00382-014-2078-8.
- Perkins, S.E., Pitman, a.J., Holbrook, N.J., McAneney, J., 2007. Evaluation of the AR4 Climate Models' Simulated Daily Maximum Temperature, Minimum Temperature, and Precipitation over Australia Using Probability Density Functions. *Journal of Climate* 20, 4356–4376. doi:10.1175/JCLI4253.1.
- Preisendorfer, R.W., Mobley, C.D., 1988. Principal component analysis in meteorology and oceanography. volume 425. Elsevier Amsterdam.
- Rascle, N., Arduin, F., 2013. A global wave parameter database for geophysical applications. Part 2: Model validation with improved source term parameterization. *Ocean Modelling* 70, 174–188. doi:10.1016/j.ocemod.2012.12.001.
- Rascle, N., Arduin, F., Queffeulou, P., Croizé-Fillon, D., 2008. A global wave parameter database for geophysical applications. Part 1: Wave-current-turbulence interaction parameters for the open ocean based on traditional parameterizations. *Ocean Modelling* 25, 154–171. doi:10.1016/j.ocemod.2008.07.006.
- Reguero, B., Menéndez, M., Méndez, F., Mínguez, R., Losada, I., 2012. A Global Ocean Wave (GOW) calibrated reanalysis from 1948 onwards. *Coastal Engineering* 65, 38–55. doi:10.1016/j.coastaleng.2012.03.003.

- Reichler, T., Kim, J., 2008. How Well Do Coupled Models Simulate Today's Climate? *Bulletin of the American Meteorological Society* 89, 303–311. doi:10.1175/BAMS-89-3-303.
- Rodríguez-Puebla, C., Ayuso, S., Frías, M., García-Casado, L., 2007. Effects of climate variation on winter cereal production in Spain. *Climate Research* 34, 223–232. doi:10.3354/cr00700.
- Rodríguez-Puebla, C., Nieto, S., 2010. Trends of precipitation over the Iberian Peninsula and the North Atlantic Oscillation under climate change conditions. *International Journal of Climatology* 30, n/a–n/a. doi:10.1002/joc.2035.
- Rueda, A., Camus, P., Mendez, F., Tomas, A., Luceño, A., 2015. An extreme value model for maximum wave heights based on weather types. Submitted to *Journal of Geophysical Research: Oceans*.
- Saha, S., Moorthi, S., Pan, H.L., Wu, X., Wang, J., Nadiga, S., Tripp, P., Kistler, R., Woollen, J., Behringer, D., Liu, H., Stokes, D., Grumbine, R., Gayno, G., Wang, J., Hou, Y.T., Chuang, H.Y., Juang, H.M.H., Sela, J., Iredell, M., Treadon, R., Kleist, D., Van Delst, P., Keyser, D., Derber, J., Ek, M., Meng, J., Wei, H., Yang, R., Lord, S., Van Den Dool, H., Kumar, A., Wang, W., Long, C., Chelliah, M., Xue, Y., Huang, B., Schemm, J.K., Ebisuzaki, W., Lin, R., Xie, P., Chen, M., Zhou, S., Higgins, W., Zou, C.Z., Liu, Q., Chen, Y., Han, Y., Cucurull, L., Reynolds, R.W., Rutledge, G., Goldberg, M., 2010. The NCEP Climate Forecast System Reanalysis. *Bulletin of the American Meteorological Society* 91, 1015–1057. doi:10.1175/2010BAMS3001.1.
- Saha, S., Moorthi, S., Wu, X., Wang, J., Nadiga, S., Tripp, P., Behringer, D., Hou, Y.T., Chuang, H.y., Iredell, M., Ek, M., Meng, J., Yang, R., Mendez, M.P.n., van den Dool, H., Zhang, Q., Wang, W., Chen, M., Becker, E., 2014. The NCEP Climate Forecast System Version 2. *Journal of Climate* 27, 2185–2208. doi:10.1175/JCLI-D-12-00823.1.
- Seager, R., Kushnir, Y., Nakamura, J., Ting, M., Naik, N., 2010. Northern Hemisphere winter snow anomalies: ENSO, NAO and the winter of 2009/10. *Geophysical Research Letters* 37, n/a–n/a. doi:10.1029/2010GL043830.
- Semedo, A., Weisse, R., Behrens, A., Sterl, A., Bengtsson, L., Günther, H., 2013. Projection of Global Wave Climate Change toward the End of the Twenty-First Century. *Journal of Climate* 26, 8269–8288. doi:10.1175/JCLI-D-12-00658.1.
- Skamarock, W., Klemp, J., Dudhi, J., Gill, D., Barker, D., Duda, M., Huang, X.Y., Wang, W., Powers, J., 2008. A Description of the Advanced Research WRF Version 3. Technical Report , 113doi:10.5065/D6DZ069T.

- Snarey, M., Terrett, N.K., Willett, P., Wilton, D.J., 1997. Comparison of algorithms for dissimilarity-based compound selection. *Journal of Molecular Graphics and Modelling* 15, 372–385. doi:10.1016/S1093-3263(98)00008-4.
- Snodgrass, F.E., Groves, G.W., Hasselmann, K.F., Miller, G.R., Munk, W.H., Powers, W.H., 1966. Propagation of Ocean Swell across the Pacific. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences* 259, 431–497. doi:10.1098/rsta.1966.0022.
- Sterl, A., 2004. On the (In)Homogeneity of Reanalysis Products. *Journal of Climate* 17, 3866–3873. doi:10.1175/1520-0442(2004)017<3866:OTIORP>2.0.CO;2.
- von Storch, H., Zorita, E., Cubasch, U., 1993. Downscaling of Global Climate Change Estimates to Regional Scales: An Application to Iberian Rainfall in Wintertime. *Journal of Climate* 6, 1161–1171. doi:10.1175/1520-0442(1993)006<1161:DOGCCE>2.0.CO;2.
- Su, F., Duan, X., Chen, D., Hao, Z., Cuo, L., 2013. Evaluation of the Global Climate Models in the CMIP5 over the Tibetan Plateau. *Journal of Climate* 26, 3187–3208. doi:10.1175/JCLI-D-12-00321.1.
- Suh, K.D., Kim, S.W., Mori, N., Mase, H., 2012. Effect of Climate Change on Performance-Based Design of Caisson Breakwaters. *Journal of Waterway, Port, Coastal, and Ocean Engineering* 138, 215–225. doi:10.1061/(ASCE)WW.1943-5460.0000126.
- Taylor, K.E., Stouffer, R.J., Meehl, G.a., 2012. An Overview of CMIP5 and the Experiment Design. *Bulletin of the American Meteorological Society* 93, 485–498. doi:10.1175/BAMS-D-11-00094.1.
- Tolman, H.L., 2003. Treatment of unresolved islands and ice in wind wave models. *Ocean Modelling* 5, 219–231. doi:10.1016/S1463-5003(02)00040-9.
- Tolman, H.L., 2008. A mosaic approach to wind wave modeling. *Ocean Modelling* 25, 35–47. doi:10.1016/j.ocemod.2008.06.005.
- Tolman, H.L., 2009. User manual and system documentation of WAVEWATCH-III version 3.14. Technical note .
- Tolman, H.L., 2014. User manual and system documentation of WAVEWATCH III version 4.18. NOAA / NWS / NCEP / MMAB Technical Note .
- Tolman, H.L., Chalikov, D., 1996. Source Terms in a Third-Generation Wind Wave Model. *Journal of Physical Oceanography* 26, 2497–2518. doi:10.1175/1520-0485(1996)026<2497:STIATG>2.0.CO;2.

- Tracy, B., Devaliere, E., Hanson, J., Nicolini, T., Tolman, H., 2007. Wind Sea and Swell Delineation for Numerical Wave Modeling. *Energy* 12, 231–238.
- Uppala, S.M., Kallberg, P.W., Simmons, a.J., Andrae, U., Bechtold, V.D.C., Fiorino, M., Gibson, J.K., Haseler, J., Hernandez, A., Kelly, G.a., Li, X., Onogi, K., Saarinen, S., Sokka, N., Allan, R.P., Andersson, E., Arpe, K., Balmaseda, M.a., Beljaars, a.C.M., Berg, L.V.D., Bidlot, J., Bormann, N., Caires, S., Chevallier, F., Dethof, A., Dragosavac, M., Fisher, M., Fuentes, M., Hagemann, S., Hólm, E., Hoskins, B.J., Isaksen, L., Janssen, P.a.E.M., Jenne, R., Mcnally, a.P., Mahfouf, J.F., Morcrette, J.J., Rayner, N.a., Saunders, R.W., Simon, P., Sterl, A., Trenberth, K.E., Untch, A., Vasiljevic, D., Viterbo, P., Woollen, J., 2005. The ERA-40 re-analysis. *Quarterly Journal of the Royal Meteorological Society* 131, 2961–3012. doi:10.1256/qj.04.176.
- Van Der Linden, P., Mitchell, J.F.B., 2009. ENSEMBLES: Climate Change and its Impacts: Summary of research and results from the ENSEMBLES project.
- van Vuuren, D.P., Edmonds, J., Kainuma, M., Riahi, K., Thomson, A., Hibbard, K., Hurtt, G.C., Kram, T., Krey, V., Lamarque, J.F., Masui, T., Meinshausen, M., Nakicenovic, N., Smith, S.J., Rose, S.K., 2011. The representative concentration pathways: an overview. *Climatic Change* 109, 5–31. doi:10.1007/s10584-011-0148-z.
- Walsh, J.E., Chapman, W.L., Romanovsky, V., Christensen, J.H., Stendel, M., 2008. Global Climate Model Performance over Alaska and Greenland. *Journal of Climate* 21, 6156–6174. doi:10.1175/2008JCLI2163.1.
- Wang, X.L., Feng, Y., Swail, V.R., 2012. North Atlantic wave height trends as reconstructed from the 20th century reanalysis. *Geophysical Research Letters* 39, n/a–n/a. doi:10.1029/2012GL053381.
- Wang, X.L., Feng, Y., Swail, V.R., 2014. Changes in global ocean wave heights as projected using multimodel CMIP5 simulations. *Geophysical Research Letters* 41, 1026–1034. doi:10.1002/2013GL058650.
- Wang, X.L., Swail, V.R., 2006. Climate change signal and uncertainty in projections of ocean wave heights. *Climate Dynamics* 26, 109–126. doi:10.1007/s00382-005-0080-x.
- Wang, X.L., Swail, V.R., Cox, A., 2009. Dynamical versus statistical downscaling methods for ocean wave heights. *International Journal of Climatology* 30, n/a–n/a. doi:10.1002/joc.1899.
- Wang, X.L., Zwiers, F.W., Swail, V.R., 2004. North Atlantic Ocean Wave Climate Change Scenarios for the Twenty-First Century. *Journal of Climate* 17, 2368–2383. doi:10.1175/1520-0442(2004)017<2368:NAOWCC>2.0.CO;2.

- Wessel, P., Smith, W.H.F., 1996. A global, self-consistent, hierarchical, high-resolution shoreline database. *Journal of Geology* 101, 8741–8743.
- Wilby, R.L., Charles, S.P., Zorita, E., Timbal, B., Whetton, P., Mearns, L.O., 2004. Guidelines for Use of Climate Scenarios Developed from Statistical Downscaling Methods. URL: http://www.ctn.etsmtl.ca/cours/mgc921/dgm_no2_v1_09_2004.pdf.
- Woolf, D.K., 2002. Variability and predictability of the North Atlantic wave climate. *Journal of Geophysical Research* 107, 3145. doi:10.1029/2001JC001124, arXiv:107(C10):3145.
- Yin, L., Fu, R., Shevliakova, E., Dickinson, R.E., 2013. How well can CMIP5 simulate precipitation and its controlling processes over tropical South America? *Climate Dynamics* 41, 3127–3143. doi:10.1007/s00382-012-1582-y.
- Young, I., 1999. Seasonal variability of the global ocean wind and wave climate. *International Journal of Climatology* 19, 931–950. doi:10.1002/(SICI)1097-0088(199907)19:9<931::AID-JOC412>3.0.CO;2-0.