



DESCRIPCIÓN DE LA METODOLOGÍA DE DOWNSCALING ESTADÍSTICO FICLIMA



ÍNDICE

| | | |
|-------|--|----|
| 1 | LA SIMULACIÓN DEL CLIMA FUTURO | 3 |
| 2 | CONSIDERACIONES GENERALES SOBRE EL DOWNSCALING ESTADÍSTICO | 5 |
| 3 | LA METODOLOGÍA <i>FICLIMA</i> DE DOWNSCALING..... | 7 |
| 3.1 | PRIMER PASO: LA TÉCNICA DE ANÁLOGOS | 9 |
| 3.2 | SEGUNDO PASO..... | 10 |
| 3.2.1 | Temperatura: Análisis con Regresión Lineal Múltiple..... | 10 |
| 3.2.2 | Precipitación: Aproximación Estadística | 11 |
| 4 | REFERENCIAS..... | 13 |

1 LA SIMULACIÓN DEL CLIMA FUTURO

Las herramientas más potentes desarrolladas para la generación de las proyecciones futuras del clima son los Modelos de Circulación General (o GCM por las siglas de *General Circulation Models*) (Huebener et al., 2007). A día de hoy, estos GCMs trabajan a resoluciones espaciales de unos 200 km con lo que una resolución tan grande como esta provoca que la información suministrada sobre el clima sea inadecuada si vamos a usar ésta como variable de entrada para un modelo de impacto (von Storch 1994; Mearns et al., 1997) – el problema es que los estudios de impacto son esenciales para el diseño de las políticas de adaptación que tratan de minimizar los impactos negativos del cambio climático y de aprovechar los positivos. Así, y para poder resolver este desajuste, en las últimas décadas se ha realizado un esfuerzo considerable en el desarrollo de diferentes estrategias que permitan inferir información de alta resolución a partir de las variables de baja resolución, es decir, 'proyectar de forma precisa la información disponible a gran escala sobre la escala regional' (von Storch et al., 1993). Estas estrategias se denominan *técnicas de downscaling* (o de regionalización o de reducción de escala).

Existen dos grandes familias distintas para realizar el downscaling (Murphy, 1999; Fowler et al., 2007). En el denominado *downscaling dinámico* (Giorgi et al., 2001; Christensen et al., 2007), los campos de alta resolución se obtienen anidando un modelo climático regional (o RCM por *Regional Climate Model*) dentro del propio GCM (Giorgi et al., 1994; Jones et al., 1997), o utilizando un GCM de resolución variable (la denominada *stretching technique*) (Déqué and Piedelievre, 1995). En el *downscaling estadístico* (Wilby et al. 2004; Imbert and Benestad 2005), los predictandos de alta resolución (las variables de superficie) se obtienen aplicando relaciones previamente identificadas en el clima observado entre estos predictandos y campos predictores de gran escala a las salidas de los GCMs.

Ambos métodos tienen sus ventajas y sus desventajas, y ambos requieren algunas suposiciones iniciales que no pueden ser verificadas en un contexto de cambio climático (Giorgi et al., 2001) y por lo tanto contribuyen por sí mismos a la cascada de incertidumbre que se manifiesta en las simulaciones finales del clima. Así y todo, se pueden utilizar varios criterios para ayudar en la selección del enfoque más adecuado dependiendo de la aplicación final (Wilby et al., 2004).

La necesidad de tener en cuenta las incertidumbres propias de un escenario climático (debido a razones tales como las propias incertidumbres en las condiciones iniciales de los campos atmosféricos, en los escenarios de forzamiento, en la sensibilidad climática de los GCMs, o en su fiabilidad al llevar a cabo una reducción de escala) en un marco general de evaluación de riesgos conduce a la necesidad de proyecciones climáticas probabilísticas. En este contexto, los métodos estadísticos son una opción muy buena a la hora de realizar un downscaling. Sus necesidades relativamente pequeñas en términos de datos disponibles de los GCMs y de recursos computacionales los hacen muy relevantes para conseguir el procesamiento de la creciente cantidad de simulaciones disponibles de GCMs. Además, cuando se necesita información local de muy alta resolución, los métodos estadísticos funcionan mejor que los dinámicos (al menos a día de hoy – van der Linden y Mitchell, 2009), debido a que la resolución de los modelos dinámicos actuales (ya sean anidados o de tipo *stretched*) es todavía demasiado grande (y al hecho de que los modelos climáticos regionales no utilizan las observaciones locales que implícitamente permitirían capturar las características meteorológicas locales). La mayor capacidad de diagnóstico de los métodos estadísticos aplicados a escala local está unánimemente aceptada en el marco de la predicción meteorológica operativa, donde los sistemas de reinterpretación estadísticos son la principal

herramienta para la obtención de la información local.

Durante las últimas décadas, los estudios estadísticos del clima de largo plazo han detectado cambios relativamente pequeños en comparación con la variabilidad interanual. Esta variabilidad ofrece una forma indirecta de evaluar la estabilidad de las relaciones estadísticas utilizadas para la reducción de escala en un contexto climático futuro. En ese contexto se pueden identificar dos requisitos obligatorios para el buen funcionamiento de una metodología de downscaling estadístico: el primer requisito es que el rendimiento debe ser igualmente bueno en diferentes escalas de tiempo (diario, estacional, anual, decadal,...) (Wilby y Wigley, 1997). El segundo requisito es que prácticamente todas las posibles situaciones de los predictores que aparezcan en el posible clima futuro proporcionado por las simulaciones de los GCMs deben estar dentro del rango de aplicabilidad de las relaciones estadísticas que ha determinado el periodo de calibración del método.

Considerando las ventajas y los inconvenientes de ambos métodos, el equipo de investigación de la Fundación para la Investigación del Clima (FIC) decidió desarrollar una técnica de downscaling estadístico. La metodología desarrollada por la FIC, denominada FICLIMA, ha sido probada contra otras técnicas en diferentes proyectos científicos, tanto europeos (*Statistical and Regional dynamical Downscaling of Extremes for European regions*, STARDEX, 2002-2005; *Climate change and its impacts at seasonal, decadal and centennial timescales*, ENSEMBLES, 2004-2009) como nacionales (Primer programa nacional de Generación de escenarios regionalizados de cambio climático para España, coordinado por AEMET, 2007 - 2008; Programa coordinado para la generación de escenarios regionalizados de cambio climático: Regionalización estadística, ESTCENA, 2009 - 2012), y se ha aplicado en diferentes regiones del mundo (Península Ibérica, Canarias, Europa, América Central, América del Sur, Asia Central,...) y para diferentes variables meteorológicas (temperatura, precipitación,...) con excelentes resultados.

Las técnicas estadísticas de downscaling consisten en establecer relaciones empíricas entre campos de baja resolución, denominados *predictores* y las variables de superficie, llamadas *predictandos*. Estas técnicas se pueden clasificar en cuatro grupos principales: generadores de tiempo atmosférico (mediante simulación estocástica, es decir, intrínsecamente, generación de una serie de valores diarios en consonancia con la climatología), funciones de transferencia (basados en modelos de regresión, tanto lineales como no lineales, con el objetivo de establecer relaciones entre predictandos locales y predictores de escala larga), selección de análogos (que consiste en la selección de entre un conjunto de datos de los n patrones atmosféricos más similares o análogos al día problema), y tipos de tiempo (basados en el establecimiento previo de un número finito de grupos obtenidos mediante similitud sinóptica entre los campos de baja resolución).

La metodología FICLIMA combina dos tipos de técnicas estadísticas: el primer paso es una selección de análogos (o estratificación por análogos), y en un segundo paso se emplean funciones de transferencia sobre los días seleccionados en el primer paso.

El propósito de este documento es presentar una visión general sobre la metodología FICLIMA y sus fundamentos; en todo caso, si se necesita una explicación más profunda sobre el procedimiento teórico desarrollado se puede acudir a

<http://www.ficlima.org/generacion-de-escenarios-locales/>

donde se puede encontrar información más completa sobre la metodología y también algunos ejemplos concretos de proyectos internacionales en los que ha sido aplicada.

2 CONSIDERACIONES GENERALES SOBRE EL DOWNSCALING ESTADÍSTICO

Tanto el desarrollo de una metodología estadística de downscaling como la selección de los posibles predictores a emplear deben llevarse a cabo a partir de una base de consideraciones teóricas y siempre teniendo en cuenta la aplicación final de los datos regionalizados. Hay cuatro ideas básicas que siempre deben ser tenidas en cuenta:

1. El problema de la *estacionariedad*: en un contexto de cambio climático, las relaciones entre predictores y predictandos podrían cambiar. Así, los predictores deben estar físicamente vinculados a los predictandos, porque las relaciones físicas entre ellos no cambiarán. Además, deben tener en cuenta todos los forzamientos físicos de estos predictandos.
2. Las características y las limitaciones de los GCMs: las metodologías a desarrollar serán aplicadas sobre las salidas proporcionadas por los GCMs, por lo tanto los predictores finalmente seleccionados deben elegirse de entre aquellos que sean bien simulados por los propios GCMs. También se tendrá que tener en cuenta tanto la resolución temporal como la espacial de los GCMs con los que se vaya a trabajar, ya que varían de unos a otros.
3. La metodología estadística debe ser lo suficientemente no-lineal como para poder recoger las fuertes relaciones no-lineales que unen a los predictores con los predictandos que determinan la climatología local.
4. En aplicaciones relativas al cambio climático es preferible no usar ningún tipo de estratificación estacional a la hora de seleccionar los predictores: en un escenario de cambio climático, las características climáticas de las estaciones del año pueden cambiar. Eso conduciría a que las relaciones predictor / predictando detectadas en un grupo de datos pertenecientes al presente (o pasado reciente) y establecidas en una estación del año concreta con características climáticas específicas podrían no aplicarse en el futuro si las características de tal estación del año cambian.

De acuerdo con todas estas ideas pueden establecerse algunas consideraciones para la selección de los predictores:

- Según la idea 1: La selección de los predictores debe llevarse a cabo sobre la base de consideraciones teóricas, en lugar de utilizar análisis empíricos que podrían dar lugar a relaciones que no estuvieran físicamente fundamentadas lo que podría no ser aplicable en el futuro debido al problema de la estacionariedad. Los predictores deben ser forzamientos físicos de los predictandos, o al menos, deben estar físicamente vinculados a los predictandos. En otras palabras, las relaciones identificadas entre los predictores y los predictandos deben ser las que mejor reflejen los vínculos físicos entre ambos, con el fin de asegurar en lo posible la estacionariedad de estas relaciones. Si se cumplen estos requisitos, debe obtenerse una buena capacidad de diagnóstico a escala diaria, por lo tanto es esta capacidad diaria de simulación la que debe ser estudiada, ya que se exige para asegurar la estabilidad de las relaciones estadísticas en el futuro.
- Según idea 2: Los predictores deben ser variables de campo (asociadas a campos físicos atmosféricos) y no valores discretos puntuales ya que los campos son mejor

- simulados por los GCMs.
- Según la idea 2: Los predictores tienen que ser relativos a la atmósfera libre y no valores de superficie ya que son mejor simulados por los GCMs.
 - Según la idea 2: Los predictores deben ser variables que sean bien simuladas por los GCMs. El método de downscaling que vamos a emplear es una adaptación del método que se utiliza para producir predicciones operativas meteorológicas diarias. En la versión desarrollada para predicción operativa se utilizan muchos predictores, ya que se ha demostrado que todos ellos son capaces de mejorar la fiabilidad del pronóstico, pero algunos de ellos no se pueden utilizar en simulaciones climáticas, ya que, a pesar de que se ha demostrado que mejoran las simulaciones generadas por los modelos numéricos responsables de la predicción operativa para los próximos días, y de ahí su utilidad en la predicción meteorológica, son demasiado dependientes de las condiciones iniciales como para ser campos bien simulados por los GCMs para las próximas décadas.
 - Según la idea 2: Trabajar a una escala temporal y / o espacial mayor que la proporcionada por los GCMs implica que parte de la información generada por estos se va a desperdiciar. Muchos de los forzamientos físicos de los predictandos sólo pueden ser capturados trabajando a escalas temporales y espaciales tan pequeñas como sea posible. Esto podría ser especialmente relevante para la simulación de episodios extremos, como las precipitaciones extremas. Es por eso por lo que, en nuestra opinión, se debe trabajar a escalas diaria y sinóptica, porque estas son precisamente las escalas en las que los modelos de circulación general proporcionan información.
 - Según la idea 3: El método estadístico empleado debe incluir procedimientos que tengan en cuenta la no linealidad de las relaciones entre la mayoría de los predictores y los predictandos.
 - Según la idea 4: Creemos que es mejor no asumir ningún tipo de clasificación estacional al definir las relaciones entre predictores y predictandos. Los análisis de sensibilidad llevados a cabo con esta técnica de downscaling pero empleando clasificación estacional no mejoran los resultados, probablemente debido a que las relaciones que se establecen no reflejan los vínculos físicos entre variables.

El desarrollo de la metodología FICLIMA de downscaling estadístico y la selección de los predictores a emplear han tenido en cuenta todo el marco conceptual presentado en esta sección.

3 LA METODOLOGÍA FICLIMA DE DOWNSCALING

En términos generales, la metodología FICLIMA estima campos meteorológicos de superficie de alta resolución para un día "x" (el día problema) en dos pasos: el primer paso es una técnica de análogos (Zorita et al., 1993); en el segundo paso, la información de superficie de alta resolución se calcula de formas diferentes para la precipitación (utilizando un enfoque probabilístico) y para la temperatura (utilizando regresiones lineales múltiples). En la figura 3.1 podemos ver un breve resumen de la metodología.

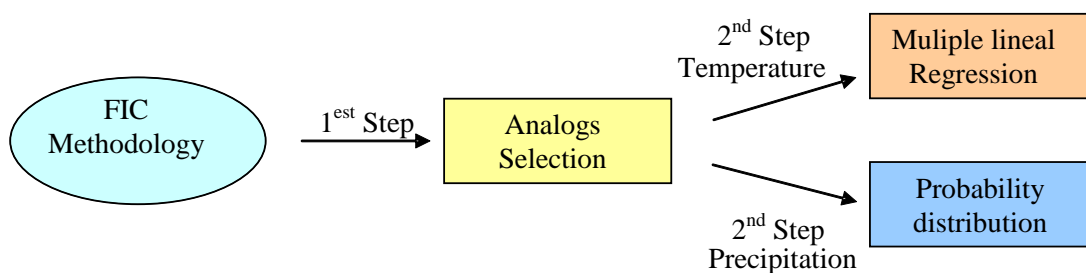


Figura 3.1. Breve resumen de la metodología FICLIMA.

Metodologías en dos pasos similares se han aplicado antes en predicción meteorológica operativa (Woodcock 1980; Balzer 1991). Para aplicaciones en cambio climático, Enke and Spekat (1997) adoptaron una técnica parecida pero sustituyeron el primer paso de estratificación por análogos por una estratificación que usa un conjunto predefinido de patrones atmosféricos (una técnica de *clustering* o agrupamiento predefinido). La técnica de análogos puede considerarse una variante específica de la técnica de *clustering* donde cada grupo específico es calculado para cada uno de los días problema, conteniendo así los n días más análogos. Es por eso por lo que las técnicas de análogos generalmente ofrecen una mayor capacidad de diagnóstico de los efectos atmosféricos de alta resolución, en contraste con los métodos que utilizan clusters predefinidos.

En la figura 3.2 se representa una visión general de la metodología FICLIMA; aunque el país representado sea España, el fundamento básico de la metodología es el mismo para cualquier país o región del mundo.

En lo que sigue pasaremos a describir con un cierto grado de detalle los fundamentos de la metodología FICLIMA; si lo que se desea es un detalle completo de tal metodología, se recomienda acudir a Ribalaygua et al. (2013).

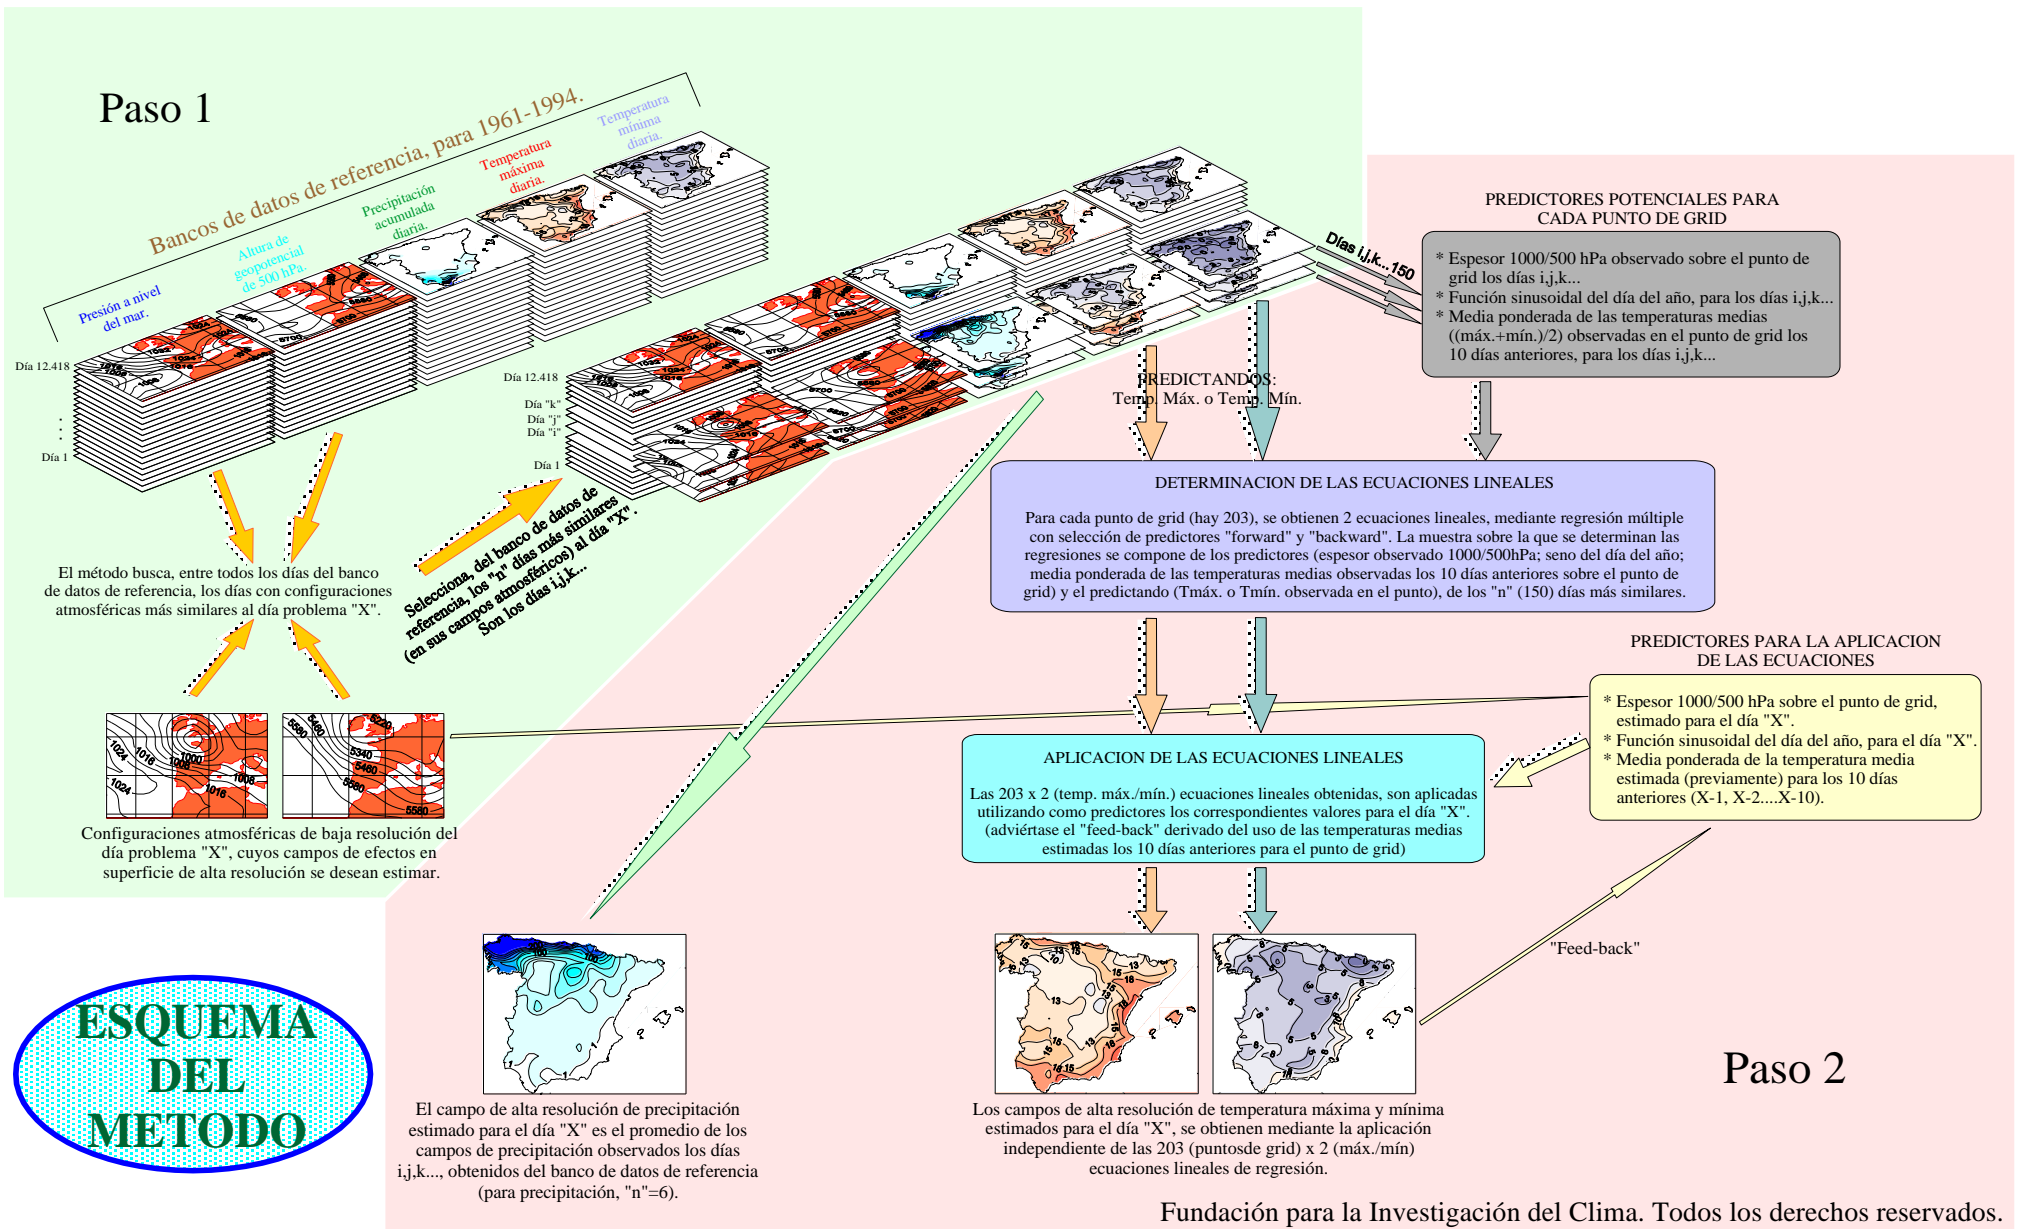


Figura 3.2 Esquema general de la metodología FICLIMA (representada para la Península Ibérica).

3.1 PRIMER PASO: LA TÉCNICA DE ANÁLOGOS

En el primer paso, los n días más similares al día problema x , identificados sobre la base de sus campos atmosféricos de baja resolución, se seleccionan a partir de un conjunto de datos de referencia. La habilidad del método depende de la extensión y la calidad de los conjuntos de datos atmosféricos y de superficie de referencia y, en particular, de la definición de medida (de distancia) utilizada para determinar la similitud entre días (Matulla et al., 2008). La medida de similitud debe contener capacidad de diagnóstico en relación con los campos de precipitación de alta resolución (en otras palabras, los campos atmosféricos de baja resolución que se consideran similares de acuerdo con la medida utilizada deben estar asociados con campos de precipitación similares pero de alta resolución). La medida de similitud también debe evaluar la semejanza de la mayor cantidad posible de forzamientos físicos asociados a la precipitación (véase idea 1, apartado anterior), asociando las configuraciones atmosféricas de baja resolución de los días contra los días con los que se va a establecer la comparación. Además de por su capacidad de diagnóstico, las variables finalmente elegidas como predictoras deben ser razonablemente bien simuladas por los Modelos de Circulación General (véase idea 2).

Muchos métodos estadísticos incorporan procedimientos fuertemente automatizados para seleccionar los mejores predictores y para ajustar las relaciones óptimas entre predictores y predictandos. Sin embargo, esto no es fácil de realizar para las técnicas de análogos para las que la calibración implica una tarea muy laboriosa de probar diferentes combinaciones de predictores y de medidas de similitud. No obstante, esto permite la selección de los predictores y de medidas de similitud bajo consideraciones teóricas, con el objetivo de capturar los forzamientos físicos entre los predictores y predictandos con el fin de garantizar la estacionariedad de las relaciones (véase de nuevo la idea 1, que siempre debe ser tenida en cuenta).

La medida de similitud entre dos días debe ser una variable escalar (para así poder ordenarla) y debe poder medir la semejanza entre esos dos días con respecto a los campos predictores.

Algunos de los diferentes algoritmos que tradicionalmente se han utilizado para evaluar la similitud entre los campos fueron probados en el proceso de calibración: tanto basados en el coeficiente de correlación de Pearson como varias distancias euclidianas y pseudo-euclidianas. Las medidas de similitud son necesarias no sólo para establecer el patrón general de los días que se comparan, sino también los valores de los campos a emplear en los puntos individuales considerados. Para este último requisito, los coeficientes de correlación de Pearson obtienen peores resultados que las distancias euclidianas y por lo tanto proporcionan una capacidad de diagnóstico de precipitación inferior. El buen comportamiento de las distancias euclidianas se apoya en la literatura clásica de la técnica de análogos (Martin et al., 1997; Kruizinga y Murphy, 1983).

La similitud entre dos días cualesquiera se calcula determinando el parecido entre ambos de acuerdo con los valores correspondientes que posean en los campos empleados como predictores. La similitud de los días x_i y x_j de acuerdo a cada campo predictor P se calcula con una distancia pseudo-euclídea (ecuación 1):

$$D_p(x_i, x_j) = \sqrt{\frac{\sum_{k=1}^N (P_{ik} - P_{jk})^2 \cdot W_k}{\sum_{k=1}^N W_k}} \quad \text{ecuación [1]}$$

Donde P_{ik} es el valor del predictor P del día x_i en el punto de rejilla k ; W_k es el coeficiente de ponderación del punto de rejilla k ; y N es el número de puntos de la rejilla atmosférica.

Una vez que se ha calculado $D_p(x_i, x_j)$, ésta se estandariza. La estandarización se lleva a cabo sustituyendo el valor obtenido de $D_p(x_i, x_j)$ por el percentil p , que es el centil más cercano al valor de $D_p(x_i, x_j)$ de entre el grupo de referencia de las distancias euclídeas entre los campos predictores P . Los valores de los centiles se determinan previamente, y de forma independiente para cada campo predictor P , a partir de una población de referencia de más de 3.000.000 de valores de D_p . La población de referencia se calcula aplicando la ecuación 1, con los mismos valores de W_k , a distintas parejas de días seleccionadas al azar. Si el valor más cercano a $D_p(x_i, x_j)$ es $cent_{i,j,p}$, eso significa que aproximadamente el $cent_{i,j,p}$ % de los 3.000.000 de los valores D_p son menores que $D_p(x_i, x_j)$. El uso de centiles en vez del valor original de la distancia D_p permite trabajar con magnitudes sin dimensiones y de variables igualmente ponderadas para cada predictor P (al menos inicialmente).

Después del cálculo de $D_p(x_i, x_j)$ y de su posterior estandarización (la determinación del $cent_{i,j,p}$ más cercano), la medida final de la similitud ($sim_{i,j}$) entre los días x_i y x_j se consigue mediante la inversa de una media ponderada del centil obtenido para cada uno de los centiles de los predictores P (ecuación 2):

$$sim_{i,j} = \left(\sum_{P=1}^4 w_p cent_{i,j,p} \right)^{-1} \quad \text{ecuación [2]}$$

donde w_p es el coeficiente ponderado del campo predictor P .

3.2 SEGUNDO PASO

3.2.1 Temperatura: Análisis con Regresión Lineal Múltiple

El procedimiento de cálculo de temperaturas requiere, una vez realizada la selección de los n días análogos anteriormente descritos (para la temperatura, $n = 150$), un análisis posterior mediante el uso de la regresión lineal múltiple. Aunque las relaciones predictor / predictando determinadas en este segundo paso no sean lineales, una parte importante de la no linealidad de los vínculos entre las variables de atmósfera libre y las temperaturas de la superficie se consigue con la clasificación por análogos realizada en el primer paso, que selecciona los días más similares con respecto a la precipitación y la nubosidad (dos de las variables que introducen la mayoría de la no - linealidad en las relaciones). La regresión lineal funciona muy bien para la estimación de las temperaturas máxima y mínima de la superficie debido a que la distribución estadística de estas variables puede aproximarse a una distribución normal. Es importante recordar que cuando se utiliza la regresión lineal de los predictandos se está obligado a tener la misma distribución estadística que la determinada por las variables predictoras (Bürguer 1996). En este sentido, los predictores potenciales deben tener distribuciones cercanas a la distribución normal.

La regresión lineal múltiple se ejecuta independientemente para cada punto, y usa como método de selección de predictores una selección lineal del tipo *forward and backward*.

Utilizamos cuatro posibles predictores potenciales:

1. El espesor entre las capas 1000/500 hPa.
2. El espesor entre las capas 1000/850 hPa.
3. La radiación solar del día del año asociados al día problema; no sólo depende del día del año sino también de la latitud del observatorio estudiado.
4. Una media ponderada del valor diario de las temperaturas de los diez días anteriores al día problema en el observatorio estudiado.

Ambos espesores se emplean para incluir la fuerte relación entre las capas bajas de la troposfera y las temperaturas superficiales (un factor meteorológico). La radiación solar del día del año se emplea para así tener en cuenta el número de horas de luz solar y su efecto en el calentamiento y/o enfriamiento de la capa de aire en superficie (un factor estacional). Y la media ponderada de temperatura de los diez días previos se usa para tener en cuenta la influencia de la inercia de la temperatura del suelo (un factor de la influencia del terreno).

La influencia no lineal de otros factores meteorológicos importantes, como la nubosidad, la precipitación y la velocidad del viento en las capas bajas de la troposfera, se incluye a través de la primera etapa de la estratificación por análogos. La regresión se realiza para una población de n días que presentan una situación atmosférica similar.

La regresión lineal múltiple se ejecuta dos veces para cada observatorio y para cada día problema, usando como predictandos la temperatura máxima y la temperatura mínima. Esto conduce a calcular dos ecuaciones diferentes (usando el predictando y los valores de los n días análogos como predictores) que nos permitirán estimar ambas temperaturas diarias para cada observatorio y día problema.

3.2.2 Precipitación: Aproximación Estadística

Cada día problema (x_i) tiene n días análogos (a_{ij}), cada uno con una cierta similitud ($sim(a_j, x_i)$) (donde $n=30$ para precipitación). Cada día análogo (a_{ij}) tiene una precipitación observada (ρ_{ij}) y una probabilidad estimada (π_{ij}), de acuerdo a la ecuación 3.

$$\pi_{ij} = \frac{sim(a_j, x_i)}{\sum_{k=1}^n sim(a_k, x_i)} \quad \text{ecuación [3]}$$

Así, cada día problema (x_i) tiene n pares de $[\rho_{ij}, \pi_{ij}]$, y una estimación preliminar de la precipitación (p_i) puede obtenerse combinando los n pares de acuerdo a la ecuación 4.

$$p_i = \sum_{j=1}^n \rho_{ij} \pi_{ij} \quad \text{ecuación [4]}$$

Ya que se calcula como una media, esta estimación preliminar suaviza mucho los valores extremos de precipitación y sobre-estima el número de días sin precipitación.

Para resolver este problema se diseñó una estrategia que nos permitiera obtener, para un

cierto periodo (por ejemplo, un mes), series de precipitación con una distribución de probabilidad similar a la obtenida para la precipitación de todos los análogos asociados a cada día problema de ese periodo.

Con esta aproximación, y para un mes problema que tenga m días problema, hay $n \times m$ pares de precipitación y probabilidad $[\rho_{ij}, \pi_{ij}]$. Estos pares se ordenan por su ρ_{ij} , y se les clasifica de acuerdo a la ecuación 5, hasta que se forman grupos de k pares cuya suma de probabilidad π_k sea 1; de esta forma obtenemos m nuevos valores de precipitación (p'_h).

$$p'_h = \sum_{k|\sum \pi_k=1} \rho_k \pi_k \quad \text{ecuación [5]}$$

Los m nuevos valores de precipitación (p'_h) se asignan a los m días (x_i) del mes de acuerdo con las estimaciones preliminares de precipitación (p_i) obtenidas por la ecuación 4, con lo que los mayores p'_h se asocian con el día (x_i) con el mayor p_i ; el segundo mayor p'_h con el día con el segundo mayor p_i ; y así sucesivamente.

De esta forma, la distribución de probabilidad de los m nuevos valores de precipitación (p'_h) es similar a la distribución de probabilidad de los $n \times m$ valores de precipitación (ρ_k) – tal y como queremos. Este método permite una distribución empírica de cantidades de lluvia para cada día del mes a ser simulado sin tener que asumir ninguna hipótesis *a priori* sobre la distribución de probabilidad de cada mes (o tener que asumir una distribución de probabilidad concreta como pueda ser la función gamma).

4 REFERENCIAS

- Balzer K (1991) Recent improvements in medium-range local weather forecasting in the Deutscher Wetterdienst. In: Lectures of the WMO training workshop on the interpretation of NWP products in terms of local weather phenomena and their verification, pp. 225-229
- Bürguer G (1996) Expanded Downscaling for Generating Local Weather Scenarios. *Clim Res* 7:118-28
- Christensen JH, Carter TR, Rummukainen M, et al. (2007) Evaluating the performance and utility of regional climate models: the PRUDENCE project. *Clim Change* 81:1-6
- Déqué M, Piedelievre JP (1995) High resolution climate simulations over Europe. *Clim Dyn* 11:321-339
- Enke W, Spekat A (1997) Downscaling climate model outputs into local and regional weather elements by classification and regression. *Clim Res* 8:195-207
- Fowler, H. J., Blenkinsop, S. and Tebaldi, C. (2007), Linking climate change modelling to impacts studies: recent advances in downscaling techniques for hydrological modelling. *Int. J. Climatol.*, 27: 1547–1578. doi: 10.1002/joc.1556
- Giorgi F, Shields Brodeur C, Bates GT (1994) Regional climate change scenarios over the United States produced with a nested regional climate model. *J Climate* 7:375-399
- Giorgi F, Francisco R (2001) Uncertainties in the prediction of regional climate change. *Global Change and Protected Areas* 9:127-139
- Huebener H, Cubasch U, Langematz U, Spanghel T, Niehörster F, Fast I, Kunze M (2007) Ensemble climate simulations using a fully coupled ocean–troposphere–stratosphere general circulation model. *Phil Trans Roy Soc A* 365: 2089–210. doi:10.1098/rsta.2007.2078.
- Imbert A, Benestad R (2005) An improvement of analog model strategy for more reliable local climate change scenarios. *Theor Appl Climatol* 82:245–255. doi:10.1007/s00704-005-0133-4
- Jones RG, Murphy JM, Noguer M, Keen B (1997) Simulation of climate change over Europe using a nested regional-climate model. II: Comparison of driving and regional model responses to a doubling of carbon dioxide. *Q J R Meteorol Soc* 123:265-292
- Kruizinga S, Murphy AH (1983) Use of an Analogue procedure to formulate objective probabilistic temperature forecasts in the Netherlands. *Mon Wea Rev* 111:2245-2254
- Martin E, Timbal B, Brun E (1997) Downscaling of general circulation model outputs simulation of the snow climatology of the French Alps and sensitivity to climate change. *Clim Dyn* 13:45-56.
- Matulla C, Zhang X, Wang XL, Wang J, Zorita JE, Wagner S, von Storch H (2008) Influence of similarity measures on the performance of the analog method for downscaling daily precipitation, *Climate Dynamics*, 30,133-144
- Mearns, LO (1997) On the statistical evaluation of climate model experiments - Comment. *Clim Change* 37:443-448
- Murphy J (1999) An evaluation of statistical and dynamical techniques for downscaling local climate. *J Climate* 12:2256-2284
- Ribalaygua, J., Torres, L., Pórtoles, J., Monjo, R., Gaitán, E. and Pino, M.R. (2013) Description and validation of a two-step analog/regression downscaling method. *Theoretical and Applied Climatology*, Volume 114, Issue 1-2, pp 253-269. Doi: 10.1007/s00704-013-0836-x. URL: <http://link.springer.com/article/10.1007/s00704-013-0836-x>
- van der Linden P, Mitchell JFB (eds.) 2009: ENSEMBLES: Climate Change and its Impacts: Summary of research and results from the ENSEMBLES project. Met Office Hadley Centre, UK. 160pp. http://ensembles-eu.metoffice.com/docs/Ensembles_final_report_Nov09.pdf (see. p 68) Accessed 10 February 2012

- von Storch, H., Zorita, E., and Cubasch U. (1993) Downscaling of Global Climate Change Estimates to Regional Scales: An Application to Iberian Rainfall in Wintertime. *Journal of Climate*, Volume 6, pp. 1161-1171
- von Storch H (1994) Inconsistencies at the interface of climate impact studies and global climate research. Max Planck Institute for Meteorology Technical Report 122.
- Wilby RL, Wigley TML (1997) Downscaling general circulation model output: a review of methods and limitations. *Prog Phys Geogr* 21:530-548
- Wilby RL, Charles SP, Zorita E, Timbal B, Whetton P, and Mearns LO (2004) Guidelines for use of Climate Scenarios Developed from Statistical Downscaling Methods. Intergovernmental Panel on Climate Change (IPCC) Task Group on Data and Scenario Support for Impacts and Climate Analysis (TGICA), available from http://ipcc-ddc.cru.uea.ac.uk/guidelines/StatDown_Guide.pdf.
- Woodcock F (1980) On the use of analogues to improve regression forecasts. *Mon Wea Rev* 108:292-297
- Zorita E, Hughes J, Lettenmaier D, Storch Hv (1993) Stochastic downscaling of regional circulation patterns for climate model diagnosis and estimation of local precipitation. Max Planck Institute for Meteorology Technical Report 109.