

COMPARANDO DOWNSCALING DINÁMICO Y ESTADÍSTICO EN APLICACIONES PALEOCLIMÁTICAS

Francisco GÓMEZ BAEZA¹, Juan José GÓMEZ NAVARRO¹ y Juan Pedro MONTÁVEZ¹

¹*Universidad de Murcia.*

francisco.gomez4@um.es, jjgomeznararro@um.es, montavez@um.es

RESUMEN

La baja resolución espacial de los Modelos de Circulación General (GCM) supone un cuello de botella que limita su aplicabilidad en estudios centrados en escalas regionales o locales, lo que requiere el uso de técnicas de downscaling. En este trabajo utilizamos una simulación de 500 años con un Modelo Climático Regional (RCM) anidado a un GCM para comparar las técnicas de downscaling dinámico y estadístico, evaluando así la capacidad de este último de reproducir las principales características de las variables que se intentan simular. Para llevar a cabo el downscaling estadístico, usamos 40 años de datos para calibrar un modelo basado en redes neuronales artificiales con el fin de reproducir dos variables diarias de interés: temperatura máxima y precipitación. Posteriormente usamos esa calibración para extender esas series hasta cubrir el periodo completo de 500 años. Los resultados muestran una alta correlación temporal entre las variables obtenidas por ambos métodos, así como similar covariabilidad espacial entre localizaciones. Concretamente, para la temperatura máxima, la correlación es de 0.89, apreciándose además un ciclo anual, con valores más altos en verano que en invierno. Para la precipitación el dato desciende a 0.6, lo cual se debe fundamentalmente a limitaciones en la red neuronal para reproducir los eventos más extremos. Estos resultados indican que, si bien el downscaling dinámico no puede ser completamente sustituido por un enfoque estadístico, éste permite obtener una primera aproximación al comportamiento de ciertas variables evitando o minimizando gran parte del coste computacional.

Palabras clave: Simulación climática, downscaling dinámico, downscaling estadístico, red neuronal artificial.

ABSTRACT

The coarse spatial resolution of General Circulation Models (GCMs) is a bottleneck that limits its applicability in studies focused on regional to local scales, demanding the implementation of downscaling techniques. In this work, we use a 500-year simulation with a Regional Climate Model (RCM) nested to a GCM to compare dynamical and statistical downscaling, thus evaluating the ability of the latter to mimic the main characteristics of the variables that are being simulated, but at a lower computational cost. To carry out the statistical downscaling, we use 40 years of data to calibrate a model based on Artificial Neural Networks in order to reproduce two daily variables of interest: maximum temperature and precipitation. We then use this

calibration to extend the series to span the entire 500-year period. The results show a high temporal correlation between the variables obtained by both methods, as well as a similar spatial covariabilities across locations. Specifically, for the maximum temperature, the correlation is 0.89, albeit with a marked annual cycle and higher values in summer than in winter. For precipitation, correlation diminishes to 0.62, mainly due to limitations in the neural network to reproduce the most extreme events. These results indicate that, although dynamic downscaling can not be completely substituted by a statistical approach, the latter is still useful to obtain a first approximation to the behavior of certain variables, avoiding or minimizing the computational cost that the former entails.

Key words: Climate Simulation, Dynamic Downscaling, Statistical Downscaling, Artificial Neural Network.

1. INTRODUCCIÓN

Los modelos climáticos globales (GCMs por sus siglas en inglés) son una de las principales herramientas que tenemos hoy en día para estudiar el clima. Sin embargo implementan una baja resolución espacial que demanda el uso de técnicas de downscaling.

Por un lado, el downscaling dinámico se basa en el uso de un modelo climático regional o RCM. Los RCMs han mostrado mejoras en los procesos mesoescalares en regiones con fuertes forzamientos superficiales (topografía compleja, heterogeneidad en usos del suelo, interfase tierra-mar, etc) (Gómez Navarro, 2011). Asimismo, aportan información sobre fenómenos que no cubren los GCM, como los episodios extremos de contaminación, o la precipitación convectiva que conduce a episodios extremos de lluvia.

Por otro lado, el downscaling estadístico utiliza modelos estadísticos para relacionar la circulación a gran escala de los GCMs con la evolución de variables meteorológicas locales. Para ello, se obtienen una serie de relaciones empírico-estadísticas que se calibran primero en un período de control, para ser aplicadas posteriormente a un período más extenso. El método que se va a emplear en este estudio para realizar dicho calibrado se basa en el uso de redes neuronales artificiales (ANN).

La principal ventaja del downscaling estadístico es su bajo coste computacional. Sin embargo, es posible encontrarse con un problema de estacionaridad, es decir, que las condiciones climáticas presentes en cierto período, bajo las cuales se han calibrado las relaciones estadísticas correspondientes, no sean las mismas condiciones presentes en otro período distinto de tiempo al que se quiera aplicar esta simulación. Con el enfoque dinámico, en cambio, no hay que lidiar este problema, ya que se basa en las relaciones físicas que el modelo es capaz de resolver de forma consistente con el GCM correspondiente; su gran desventaja es el elevado coste computacional.

En este estudio vamos a utilizar los datos obtenidos a partir de una simulación de 500 años con un RCM anidado a un GCM para realizar un downscaling estadístico sobre la península ibérica (PI). El objetivo principal es comparar los resultados obtenidos mediante ambos métodos, evaluando así la capacidad del modelo estadístico de

reproducir las principales características del RCM a un coste computacional considerablemente menor.

2. MÉTODOS

Para este estudio hemos utilizado dos series de datos climáticos producidas mediante dos modelos climáticos distintos. El primero de ellos es ECHO-G, un GCM que acopla el modelo atmosférico ECHAM4 con el modelo oceánico HOPE-G (Legutke and Voss, 1999). El segundo modelo es un RCM, una versión del modelo mesoescalar de 5ª generación (MM5) de la *Penn State University/National Center for Atmospheric Research*. Se trata de un modelo diseñado para simular circulaciones atmosféricas mesoescalares que ha sido ampliamente utilizado en estudios regionales de cambio climático (Fernández et al., 2007; Gómez-Navarro et al., 2013, 2015), y que está anidado con ECHO-G para el dominio de la PI (Gómez Navarro et al., 2011). El trabajo aquí desarrollado utiliza una pequeña parte de las series de datos proporcionadas por estos dos modelos para calibrar un modelo estadístico sobre la PI, y posteriormente compararlo con los datos totales obtenidos directamente del RCM. El modelo estadístico empleado se basa en una red neuronal artificial (ANN). Una ANN está compuesta por una serie de neuronas, o unidades simples de proceso, interconectadas entre sí mediante unos pesos ω_{ij} en base a una determinada topología. Se agrupan en capas, comenzando con una capa de entrada de datos, y terminando con una capa de salida que devuelve los resultados, encontrando entre ellas una o más capas ocultas (Gutierrez et al. 2004). Para este estudio se utiliza una ANN conocida como perceptrón multicapa o MLP. Este tipo de redes pueden contener tantas capas ocultas como queramos, pero en este caso y por simplicidad, usaremos solo una. En los nodos o neuronas de la capa de entrada de esta MLP se introducen una serie de variables que llamaremos predictoras. Esta información se propaga hacia delante, donde cada uno de los nodos siguientes la recibe de forma progresiva y calcula un valor de salida para la siguiente capa. En este caso, la tercera y última capa tendrá una sola neurona con el valor de la variable de salida, o variable predictando, que queramos calcular en un determinado punto del grid.

La principal ventaja de la modelización con ANN es su versatilidad y capacidad para aprender a partir de una serie de datos de entrenamiento. En este caso dichas series son las obtenidas a partir de los modelos global y regional anteriormente descritos. Por un lado, extraemos diversas variables físicas de la simulación obtenida a partir del modelo global, las cuales se usan como predictoras y, por tanto, las introduciremos en las neuronas de la primera capa de la ANN. En la Tabla 1 tenemos un resumen de dichas variables predictoras, en total 21, junto a los niveles en altura, medidos en hPa, para los que se toman. Por otro lado, del RCM se extraen los datos diarios de temperatura máxima y precipitación de los 40 años comprendidos entre 1950 y 1989, los cuales usaremos como predictando del modelo. Los datos correspondientes a este período los utilizaremos para calibrar y validar la ANN.

El objetivo de la calibración es encontrar una geometría óptima para la red, lo que conlleva calcular los pesos de las conexiones entre neuronas. Para este cálculo hacemos uso del paquete *neuralnet* de R (<https://cran.r-project.org/web/packages/neuralnet>). El método de aprendizaje que éste utiliza es

conocido como retropropagación (backpropagation) o propagación hacia atrás de errores (Anastasiadis et al., 2005).

Variable	Nivel (hPa)
Presión a nivel del mar	Superficie
Temperatura	1000, 850, 700, 500
Altura geopotencial	1000, 850, 700, 500
Viento zonal	1000, 850, 700, 500
Viento meridional	1000, 850, 700, 500
Humedad relativa	1000, 850, 700, 500

Tabla 1: Variables predictoras que se utilizan para calibrar la ANN.

Para estructurar la ANN es necesario determinar el número de neuronas presentes tanto en la capa de entrada como en la capa oculta. Para ello se establece, en primer lugar, un ranking que nos ordene las variables predictoras de la Tabla 1 según su correlación con la variable predictando, empleando para ello una ANN con una única neurona en la capa oculta. A continuación se va a aumentando este número hasta encontrar finalmente una combinación de variables predictoras y neuronas en la capa oculta que maximice la correlación con la variable predictando.

Una vez concluido el proceso de calibración y calculados los pesos y la arquitectura de la ANN se lleva a cabo un proceso de validación cruzada. El objetivo de la validación es evaluar la capacidad del modelo de reproducir nuevos patrones del problema, esto es, de obtener resultados similares con datos predictores correspondientes a un período temporal distinto al empleado en el proceso de calibración.

Si al comparar los errores resultantes de ambos procesos obtenemos que el error de validación es mayor que el error de calibración, decimos que se ha producido un problema de sobreajuste en el período de calibración. Esto en la práctica significa que la red únicamente ha memorizado los datos suministrados, y por ende no es capaz de generalizar lo aprendido a nuevos períodos temporales. Este problema puede ser causado por un excesivo número de parámetros o una arquitectura inadecuada. Es por tanto imprescindible mantener un equilibrio entre la complejidad del modelo, y el número de datos disponible, de forma que el modelo no sea nunca más complejo que el conjunto de datos a los que representa.

Una vez calibrada y validada la ANN, podemos aplicar los resultados al período 1501-1989. Los datos resultantes de este proceso serán los que comparemos con los datos de temperatura máxima y precipitación obtenidos mediante downscaling dinámico para ese mismo período. Los puntos sobre los que se va a centrar el estudio se muestran en la Figura 1. Estos puntos han sido escogidos de manera que representan cualitativamente diversos regímenes pluviométricos de la PI.

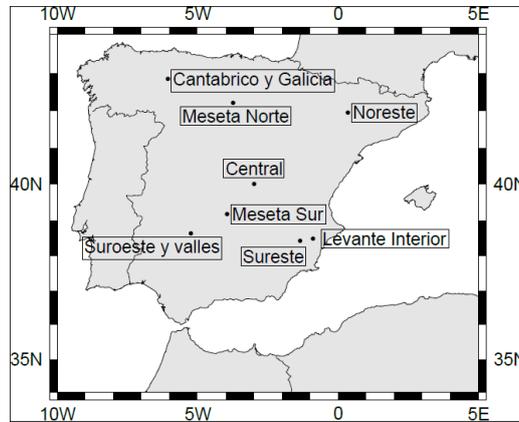


Figura 1: Puntos de la PI sobre los que particularizaremos nuestro estudio

3. RESULTADOS

3.1. Simulación de la temperatura máxima en un solo punto

El proceso de calibración y validación aplicado a la temperatura máxima en un punto central de la PI arroja una estructura óptima con una capa de entrada compuesta por 8 variables predictoras y una capa oculta con 8 neuronas.

Aplicamos esta topología al estudio del período completo 1501-1989. En la Figura 2 se muestran, en primer lugar, las medias móviles de ambas series temporales con una ventana de 2 décadas. Es evidente la existencia de un bias positivo de 1 °C. Sin embargo, sí que reproduce bien la variabilidad temporal, capturando los principales máximos y los mínimos a lo largo de todo el período.

Una manera de analizar en detalle la causa de este sesgo es visualizando la serie diaria para un período más corto de tiempo. En la Figura 3 representamos la temperatura máxima diaria en el año 1501. Se puede apreciar cómo en realidad este sesgo

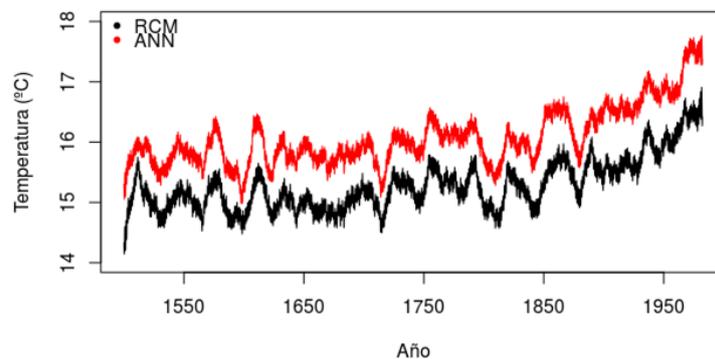


Figura 2: Media móvil de 20 años de la temperatura máxima (°C), en el punto central de la PI, para el período 1501-1989. La línea roja es la correspondiente al downscaling estadístico, mientras que la negra es la obtenida mediante downscaling dinámico.

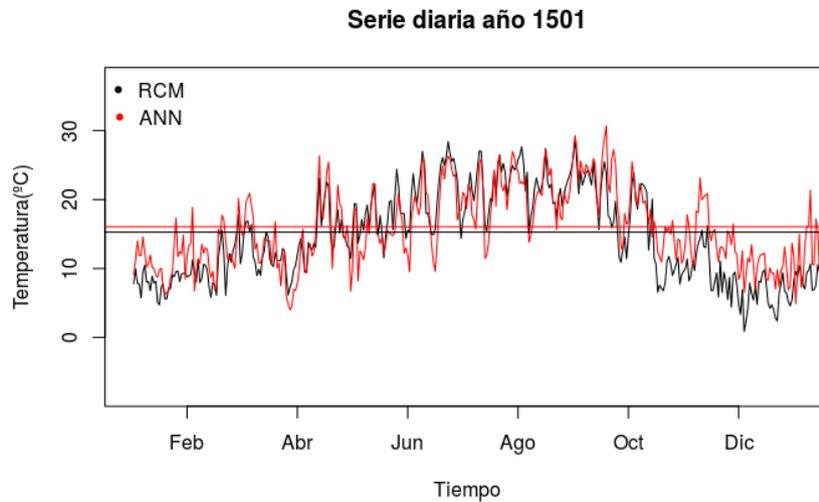


Figura 3: Valores diarios de temperatura máxima en el año 1501 correspondientes a las series obtenidas a partir del downscaling estadístico (rojo) y dinámico (negro).

sobreviene por un factor de estacionalidad, de modo que el ciclo anual no está correctamente representado por la ANN. Así, en los meses de verano la temperatura máxima estimada se ajusta mucho mejor al dato dinámico, mientras que en invierno la ANN tiende a sobreestimar la temperatura. En concreto, en muchos días de invierno la diferencia es de más de 5 °C, mientras que en verano, hay muy pocos días en los que el dato estadístico se quede por debajo. Esto da lugar a que el sesgo anual quede promediado en aproximadamente 1 °C.

Es imprescindible que las series reproduzcan este ciclo anual, pero en términos de validación de resultados podemos prescindir de él, ya que lo que nos interesa es que la ANN sea capaz de reproducir la variabilidad diaria del RCM. Así pues, para llegar a este resultado, calculamos la misma serie diaria pero aplicando un filtro de Fourier para eliminar las frecuencias superiores al año. El resultado para el año 1501 se muestra en la Figura 4.

Para el período completo, la correlación entre ambas series es de 0.89 si consideramos el ciclo anual, mientras que tras aplicar el filtro anteriormente descrito, esta desciende hasta 0.76. Es decir, el ciclo anual aumenta la correlación, pero aún tras haber eliminado este efecto, la ANN es capaz de predecir bien la variabilidad diaria de temperatura para todo el período de estudio, independientemente de la época del año.

3.2. Simulación de la precipitación en un solo punto

Tras repetir el proceso de calibración de la ANN para la precipitación, el resultado es una estructura que tiene en cuenta 9 de las variables predictoras en la capa de entrada y usa sólo 3 neuronas en la capa oculta.

Aplicamos este resultado al período completo 1501-1989 y, como antes, calculamos la media móvil con una ventana de 2 décadas (Figura 5). La buena covariabilidad temporal que existe entre ambas es notable. Sin embargo, la ANN infraestima la

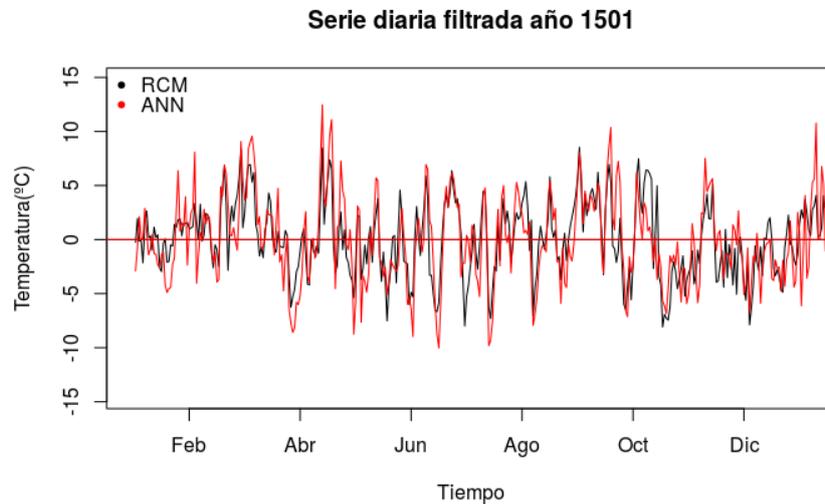


Figura 4: Análoga a la figura 3, pero tras eliminar el ciclo anual.

precipitación. Para analizar este hecho en más detalle representamos en la Figura 6 la serie para los dos primeros años (1501-1502). En ella se observa que, a nivel diario, la ANN es capaz de predecir gran parte de la variabilidad del RCM. Sin embargo, cuando el dato en alguno de estos días es muy elevado, la ANN tiene dificultades para simularlo; de hecho infraestima la mayoría de días extremos, lo que da lugar al sesgo antes mencionado. El dato de correlación para el período completo es de 0.62. Es

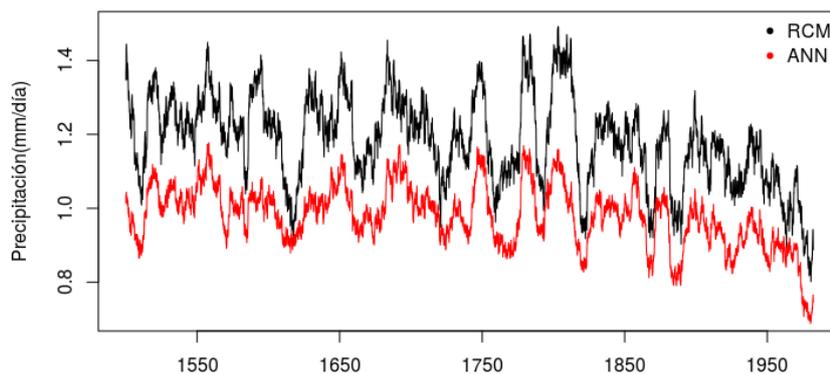


Figura 5: Media móvil de 20 años de la precipitación (mm/día), en el punto central de la PI, para el período 1501-1989. La línea roja es la correspondiente al downscaling estadístico, mientras que la negra es la obtenida mediante downscaling dinámico.

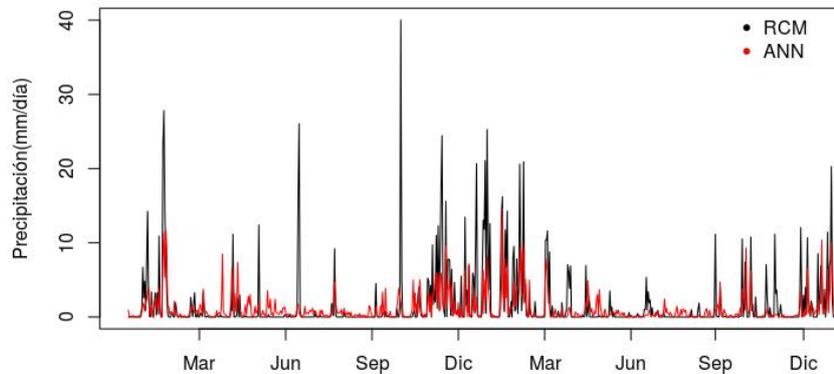


Figura 6: Niveles diarios de precipitación (mm) en el período 1501-1502 en un punto central de la PI correspondientes a las series obtenidas a partir del downscaling estadístico (rojo) y dinámico (negro).

considerablemente menor que para el caso de la temperatura máxima, lo cual indica que el modelo funciona peor para la precipitación.

3.3. Extensión del estudio a otros puntos de la PI

Es importante comprobar si el método estadístico es capaz de mantener la heterogeneidad espacial que nos proporciona el RCM. Para ello vamos a ampliar el estudio al resto de localizaciones consideradas sobre la PI.

Una manera geométrica de caracterizar la covariabilidad entre localizaciones es mediante el uso de diagramas de Taylor (Taylor, 2001) en los que no interesa tanto la representación de cada variable para cada localización, como las covarianzas entre cada una de ellas. Al tratarse de 7 localizaciones, podemos establecer hasta 21 relaciones entre ellas. En los diagramas de las figuras 7 y 8, cada punto representa la comparación entre las series de temperatura máxima o precipitación, respectivamente, para una de las parejas de localizaciones. Lo primero que nos interesa es comparar la posición en el diagrama de la nube de puntos surgida del downscaling estadístico frente a la correspondiente nube surgida del downscaling dinámico. En segundo lugar, se analiza el desplazamiento entre cada punto del diagrama correspondiente al downscaling estadístico, respecto a su posición en el diagrama correspondiente al downscaling dinámico. El resultado ideal sería que ambos diagramas fueran exactamente iguales, lo que demostraría que la ANN ha sido capaz de aprender las peculiaridades del clima regional de la misma manera que lo ha hecho el RCM.

Analizamos en primer lugar la temperatura máxima como variable predictando en los diagramas izquierdo y derecho de la Figura 7. Ambas nubes de puntos tienen correlaciones comprendidas entre 0.7 y 0.99, y las desviaciones estándar y los RMSE se mantienen de un caso a otro. Esto indica bastante homogeneidad en la distribución de temperaturas máximas independientemente de la localización. Por otro lado, el desplazamiento de la nube de puntos correspondiente al downscaling estadístico

respecto al downscaling dinámico es prácticamente nulo. Analizando la variación punto a punto, se observa que la mayoría se mantienen casi en la misma posición, o como mucho con un pequeño desplazamiento. Esto nos lleva a concluir que, para la temperatura máxima, las ANNs consiguen reproducir con gran éxito la heterogeneidad espacial proporcionada por el RCM

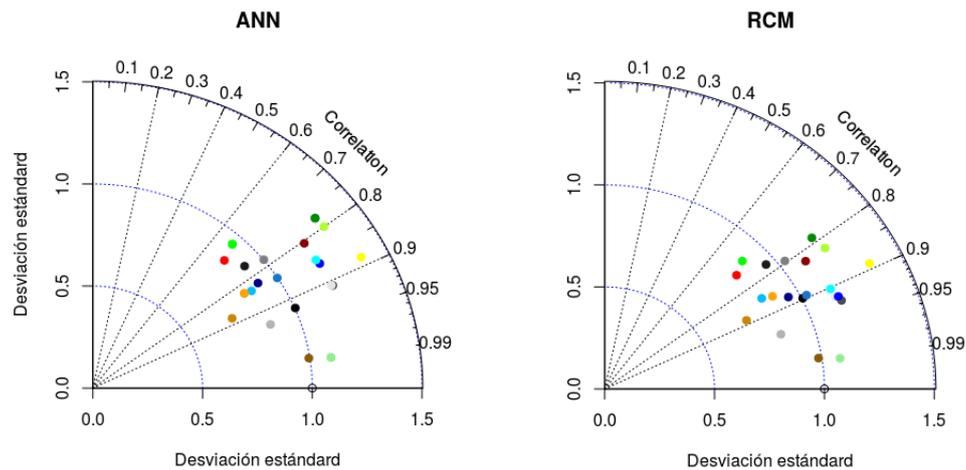


Figura 7: Comparación entre las 21 parejas de localizaciones de las series diarias de temperatura máxima obtenidas a partir del downscaling estadístico (izquierda) y dinámico (derecha).

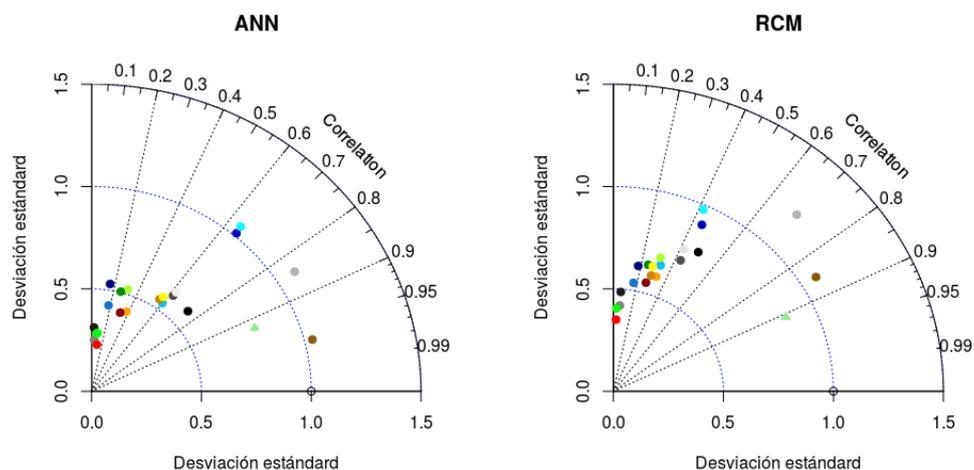


Figura 8: Comparación entre las 21 parejas de localizaciones de las series diarias de precipitación obtenidas a partir del downscaling estadístico (izquierda) y dinámico (derecha). El punto triangular representa la pareja de localizaciones SE-Levante Interior.

En cuanto a la precipitación diaria (Figura 8), la mayoría de correlaciones están comprendidas ahora entre 0 y 0.5 en el caso dinámico, y entre 0 y 0.6 en el caso estadístico, con algunos puntos con correlaciones más altas. Esto indica que los regímenes de precipitación difieren más de una localización a otra, que lo que lo hacen las temperaturas máximas, lo cual es un rasgo de la precipitación en la PI bien establecido (Gómez-Navarro et al., 2015). En cuanto a la posición realtiva de ambas nubes de puntos, hay más diferencias que en el caso anterior. El análisis punto a punto muestra como algunos apenas varían su posición, por ejemplo, el caso de la precipitación diaria en la región SE con respecto a la precipitación en el Levante Interior (punto triangular). Sin embargo, en general sí sufren un importante desplazamiento en el diagrama, lo que demuestra la dificultad que encuentra la ANN para reproducir con precisión la distribución espacial de precipitación proporcionada por el RCM.

4. CONCLUSIONES

A tenor de los resultados obtenidos, podemos confirmar la validez del enfoque basado en ANNs para realizar downscaling estadístico. Hay que tener en cuenta que en el downscaling dinámico simula el sistema climático en su conjunto, mientras que en el downscaling estadístico obtenemos un solo predictando cada vez. Además, un proceso de downscaling dinámico suele ofrecer resultados más fiables para cualquier variable ya que, al resolver las ecuaciones de movimiento para el período completo de estudio, permite esquivar las limitaciones debidas a la elección de cierto período de calibración, cuyas condiciones físicas pueden variar en un futuro y provocar que las relaciones estadísticas utilizadas dejen de ser válidas. Sin embargo, si este período de calibración se escoge adecuadamente, la ANN es capaz de reproducir la variabilidad de la temperatura máxima y de la precipitación, incluso a escala diaria. Es, en definitiva, una importante herramienta a tener en cuenta que nos permite obtener resultados en apenas unas horas y con un coste computacional mínimo.

REFERENCIAS

- Anastasiadis, A. D., Magoulas, G. D., and Vrahatis, M. N. (2005). New globally convergent training scheme based on the resilient propagation algorithm. *Neurocomputing*, 64:253–270.
- Fernández, J., Montávez, J., Sáenz, J., González-Rouco, J., and Zorita, E. (2007). Sensitivity of the MM5 mesoscale model to physical parameterizations for regional climate studies: Annual cycle. *Journal of Geophysical Research: Atmospheres*, 112(D4).
- Gómez-Navarro, J., Montávez, J., Jerez, S., Jiménez-Guerrero, P., Lorente-Plazas, R., González-Rouco, J., and Zorita, E. (2011). A regional climate simulation over the Iberian Peninsula for the last millennium. *Climate of the Past*, 7:451–472.

- Gómez-Navarro, J., Montávez, J., Wagner, S., and Zorita, E. (2013). A regional climate palaeosimulation for Europe in the period 1500–1990–part 1: Model validation. *Climate of the Past*, 9(4):1667–1682.
- Gómez-Navarro, J. J., Bothe, O., Wagner, S., Zorita, E., Werner, J. P., Luterbacher, J., Raible, C. C., and Montávez, J. (2015). A regional climate paleosimulation for Europe in the period 1500-1990-part 2: Shortcomings and strengths of models and reconstructions. *Climate of the Past*, 11(8):1077.
- Gutiérrez, J. M., Cano, R., Cofiño, A. S., and Sordo, C. M. (2004). *Redes Probabilísticas y Neuronales en las Ciencias Atmosféricas*. Ministerio de Medio Ambiente.
- Legutke, S. and Voss, R. (1999). The hamburg atmosphere-ocean circulation model ECHO-G: Technical report. *German Climate Computer Center (DKRZ)*.
- Taylor, K. E. (2001). Summarizing multiple aspects of model performance in a single diagram. *Journal of Geophysical Research: Atmospheres*, 106(D7).