

VALIDACIÓN DE UN MODELO DE ANÁLOGOS PARA LA PREDICCIÓN DE PRECIPITACIÓN Y NIEVE EN LA SIERRA DE GUADARRAMA

Álvaro SUBIAS¹, Álvaro PASCUAL¹, María Luisa MARTÍN², Francisco VALERO¹, María Yolanda LUNA³

¹*Dpto. Astrofísica y CC. de la Atmósfera. Facultad de CC Físicas. Universidad Complutense de Madrid.*

Ciudad Universitaria s/n. 28040 Madrid. Spain. a.depascual@fis.ucm.es.

²*Escuela Universitaria de Informática de Segovia. Universidad de Valladolid. Pza. Sta. Eulalia 9-11. 40005 Segovia. Spain.*

³*Agencia Estatal de Meteorología. Madrid. C/ Leonardo Prieto Castro, 8. 28040, Madrid. Spain.*

subias@fis.ucm.es, a.depascual@fis.ucm.es, mlmartin@eii.uva.es, valero@fis.ucm.es

RESUMEN

Los modelos meteorológicos dinámicos presentan claras dificultades a la hora de predecir correctamente variables altamente dependientes de las parametrizaciones o de procesos a escala local y regional, como son la precipitación y la nieve. Como alternativa, los modelos estadísticos permiten realizar estimaciones basándose en las relaciones estadísticas entre las variables de predicción (predictores) y las variables a predecir (predictandos) sin ofrecer información de los procesos físicos (lineales o no lineales) que se encuentran involucrados. Los modelos de análogos son un tipo de modelos estadísticos que se basan en el reconocimiento de patrones atmosféricos y búsqueda de situaciones meteorológicas similares en una base de datos histórica. La inclusión de diferentes variables en la búsqueda de análogos incluye una heterogeneidad que debe ser matemáticamente tenida en consideración para la optimización de los resultados. El presente trabajo muestra la calibración de un modelo de análogos aplicado a la predicción de precipitación y nieve en un entorno de orografía compleja. Los resultados del modelo son valorados desde el punto de vista probabilista para 38 observatorios localizados en el entorno de la Sierra de Guadarrama (área central de la Península Ibérica).

Palabras clave: Análogos, Precipitación, Nieve, Función de distancia.

ABSTRACT

Dynamic meteorological models have drawbacks in forecasting highly dependent variables of parameterizations or local processes, such as precipitation and snow. Alternatively, statistical models give estimations based on statistical relationships between input variables and output variables without information about related (lineal or non lineal) physical processes. The statistical analog models are based on finding similar atmospheric situations in an historical data base to any particular atmospheric situation to be modeled. The addition of different variables in the analog searching, includes heterogeneity that should be taken into account in the mathematical methodology in order to optimize the analog model. The present work shows the calibration process of an analog model for forecasting of precipitation and snow in a complex terrain. Several probabilistic results are shown in an area with 38 stations in the Sierra of Guadarrama (inner area of the Iberian Peninsula).

Palabras clave: Analogs, Precipitation, Snow, Distances.

1. INTRODUCCIÓN

La resolución de los métodos numéricos de predicción meteorológica suele ser un escalón en el proceso de predicción, ya que los procesos de escalas inferiores al tamaño de la malla de trabajo inducen efectos locales que pueden modificar fuertemente la predicción original. Con objeto de evitarlo, se han desarrollado diversos métodos de reducción de escala (conocidos en inglés como métodos “downscaling”) que permiten aumentar la resolución dada por un modelo teniendo en consideración parte de los efectos locales que se originan en las diferentes escalas. Las herramientas estadísticas son comúnmente utilizadas en diversas estrategias de downscaling ya que permiten encontrar las relaciones estadísticas existentes entre los procesos de escala sinóptica y sus consecuencias regionales. Uno de los métodos que puede utilizarse en este sentido es el conocido como método de análogos (Lorenz, 1969). Este método ha sido utilizado para predicción de lluvia, si bien no ha sido tan ampliamente aplicado para la predicción de otras variables como la nieve o el viento.

El método de análogos se basa en la búsqueda, en una base de datos histórica, de situaciones de gran escala similares a una situación de análisis determinada (Pascual et al., 2012). Así la estimación se obtiene mediante el análisis estadístico de variables regionales en aquellas fechas del pasado cuyo patrón atmosférico a gran escala presenta mayor similitud con un patrón atmosférico de análisis determinado. La comparación entre patrones atmosféricos se realiza mediante el establecimiento de una función de distancia que cuantifica la similitud entre el patrón atmosférico de análisis y todos los patrones atmosféricos pertenecientes a una base de datos histórica. La forma en que se define la función de distancia presenta una elevada influencia sobre la carga computacional del modelo; así pues, resulta técnica común utilizar en este proceso el análisis de componentes principales (PCA) para reducir la redundancia (y por tanto la dimensionalidad) de la base de datos de gran escala, de manera que se simplifica la carga computacional del modelo.

En qué medida un patrón de gran escala es o no análogo a otro queda además definido por las variables físicas que son incluidas en la comparación de ambos patrones. Existen modelos de análogos que utilizan una variable para definir el estado de la atmósfera como la altura de geopotencial o la presión a nivel del mar (Zorita et al. 1999, Pascual et al. 2012) y modelos que incluyen en la búsqueda de análogos múltiples variables que se consideran estrechamente relacionadas con el predictando (Fernández-Ferrero et al. 2010). Sin embargo, la inclusión de diferentes variables en la función de distancia incluye una heterogeneidad que no es matemáticamente tenida en consideración, de modo que en el proceso de búsqueda de análogos se confiere la misma importancia a las diferencias de unos u otros campos independientemente de su relación estadística real con el predictando. En el presente trabajo se muestra una metodología que pretende calibrar la importancia de las diferentes variables incluidas en un modelo de análogos, mostrando asimismo los resultados de la aplicación del modelo para la predicción de precipitación y nieve en un entorno de orografía compleja como es el área de la Sierra de Guadarrama.

2. DATOS Y METODOLOGÍA

Las variables observacionales que se utilizan en este trabajo son la precipitación en forma de lluvia (unidades de mm) y en forma de nieve (variable dicotómica). Estos datos se han obtenido a partir de bases de datos de mediciones in-situ proporcionadas por la Agencia Estatal de Meteorología (AEMET) en 38 observatorios de la Sierra de Guadarrama (Fig. 1). Después de un estudio de

homogeneidad, finalmente se han considerado series temporales con valores diarios desde el 1 de enero de 1961 hasta el 31 de octubre de 2010 en los meses de enero, febrero, marzo, noviembre y diciembre. De todos los observatorios considerados, únicamente Navacerrada presenta mediciones en todo el rango temporal considerado. Ello se verá reflejado en la calidad de los resultados de la predicción.

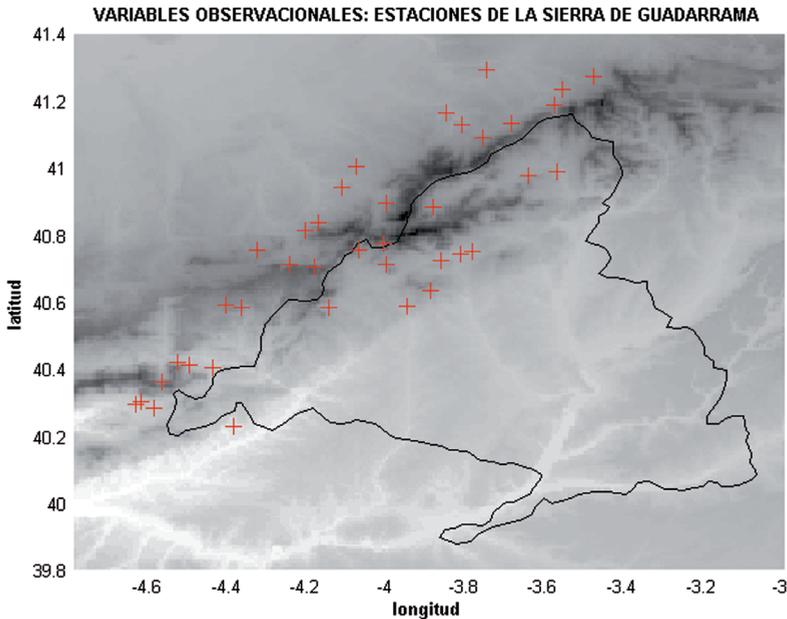


FIG. 1: Situación de los observatorios (en cruces rojas) utilizados en este estudio.

Las variables de gran escala se han obtenido a partir de Reanálisis ERA-40, desde 1961 hasta 2002 y ERA-Interim desde 2002 hasta 2008 (Gibson et al., 1997; Simmons and Gibson, 2000). Estos datos han sido proporcionados por el Centro Europeo de Predicción a Medio Plazo (ECMWF). Las variables utilizadas consisten en datos de altura geopotencial (Z), temperatura (T) y humedad relativa (HR) al nivel de 850 hPa, dada la altura media de la Sierra de Guadarrama. Estos datos están dispuestos en una malla de $1.2^\circ \times 1.2^\circ$ de latitud por longitud, cubriendo 19.2°N a 60°N de latitud y 51.6°W a 15.6°E de longitud, teniendo en total 1995 nodos espaciales.

Previo al desarrollo del método de análogos utilizado, se aplica al conjunto de datos de gran escala un análisis de componentes principales con objeto de reducir la dimensionalidad espacial de los datos, disminuyendo así la gran cantidad de grados de libertad con la que se trataba (Joliffe, 1986; Preisendorfer, 1988). Brevemente, sea f una matriz ($n \times p$) representando una variable de gran escala de n observaciones independientes en p puntos espaciales. Consideraremos el campo F que representa las anomalías estandarizadas de f .

$$(1) \quad F_t = \frac{f_t - \bar{f}}{\sigma_f}$$

La matriz de covarianza de F se diagonaliza para encontrar sus autovectores $\mathbf{u}_k = (u_{k1}, \dots, u_{kp})$. Los correspondientes autovalores λ_k dan una medida de la varianza de los datos proyectados en las

distintas direcciones \mathbf{u}_k , que ordenamos según orden decreciente de variabilidad. La proyección del campo de anomalías F sobre el autovector k constituye la *componente principal* k -ésima, de manera que

$$(2) F_{ix} = \sum_{k=1}^p \lambda_k s_{ik} u_{kx}$$

En la literatura, los autovectores \mathbf{u}_k son conocidos como *loadings*, y las componentes principales s_k son conocidas como *scores*. Para el histórico de datos escribiremos s_{ik} , mientras que para la predicción a un día de la variable auxiliar (que denotaremos mediante la variable , f .) escribiremos \hat{s}_k .

Pascual et al. (2012) presenta la metodología de predicción por análogos teniendo en cuenta para la predicción de la variable regional la utilización de una sola variable a gran escala. En este trabajo, se tenía en cuenta funciones de distancia de forma que se utilizaba aquella que minimizaba los errores entre los scores históricos y predicho así como el desarrollo de un estudio de sensibilidad referido al número óptimo de análogos a utilizar para predecir. Aquí, se muestra la metodología de análogos teniendo en cuenta varias variables de gran escala para la predicción de la variable regional. Para ello, se hace necesario ajustar las diferentes funciones de distancia para cada variable a gran escala entre los diferentes scores anteriormente definidos, de forma que nos proporcione una mejor predicción tanto de la lluvia como de la nieve. Estudiaremos un modelo de análogos con 3 variables de gran escala, Z , T y HR . Procediendo de forma análoga Pascual et al. (2012), se calculan las distancias individuales de las diferentes variables a tener en cuenta. Así, se obtienen para las diferentes variables de gran escala seleccionadas, las distancias siguientes:

$$(3) d_{Zt}^2 = \sum_{k=1}^{r_z} \lambda_{zk} (\Delta Z_{tk})^2$$

$$d_{Tt}^2 = \sum_{k=1}^{r_t} \lambda_{\tau k} (\Delta T_{tk})^2$$

para el geopotencial, la temperatura y la humedad relativa, respectivamente. A partir de ellas, se construye una distancia total como una combinación de cada una de las funciones de distancia de las variables a tener en cuenta:

$$(4) d_t \equiv \alpha d'_{Zt} + \beta d'_{Tt} + \gamma d'_{Ht}$$

donde reescalamos las distancias de las variables para que tomen valores entre 0 y 1 para poder compararlas en un mismo orden de magnitud. Aunque este procedimiento no es estrictamente necesario debido a que este reescalado podría realizarse a través de una redefinición de las constantes α , β y γ , resulta útil trabajar con distancias adimensionales para interpretar los coeficientes en términos del peso de cada una de las variables en la distancia total. Tomamos las distancias como:

$$(5) d'_{Zt} = \frac{d_{Zt}}{\max(d_{Zt})} \quad d'_{Tt} = \frac{d_{Tt}}{\max(d_{Tt})} \quad d'_{Ht} = \frac{d_{Ht}}{\max(d_{Ht})}$$

Con modelos contruidos con funciones de distancia proporcionales se obtiene la misma ordenación de fechas por distancias, de forma que la predicción de precipitación a partir de fechas análogas es la misma. Sin pérdida de generalidad, podemos tomar la relación $\alpha + \beta + \gamma = 1$, para los

pesos, teniendo cada peso un porcentaje de cada variable sobre el total de la distancia d_i , que por construcción vuelve a tomar valores entre 0 y 1. La ecuación (4) define un plano π cuyo vector normal es $(1, 1, 1)$. Los pesos deben de ser todos positivos, $\alpha, \beta, \gamma \geq 0$, ya que en caso contrario, las fechas análogas serían aquellas que presentasen mayor distancia respecto a la variable cuyo peso fuese negativo. Por tanto, el conjunto de pesos está dado por el subconjunto de puntos del plano π cuyas coordenadas son no negativas. Como resultado de esto, vemos que el espacio de pesos (α, β, γ) consiste en un *simplex* (Hatcher, 2002) y se definirá un modelo de análogos de tres variables por cada punto de este *simplex*.

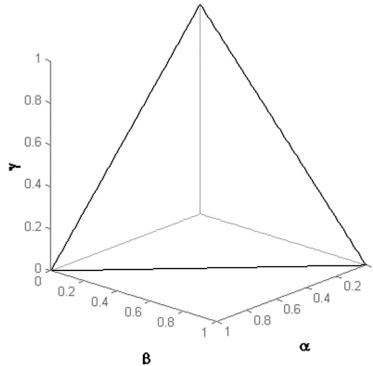


FIG. 2: Representación del simplex obtenido con el método de análogos con tres variables.

La Figura 2 se puede interpretar como sigue: cada punto del interior de este espacio representa combinaciones de 3 variables cuyas coordenadas son todas no nulas y, por tanto, representan modelos de 3 variables. Las aristas representan modelos de dos variables debido a que en estos puntos una de las coordenadas se anula. Finalmente, cada vértice representa un modelo de única variable (Pascual et al., 2012), de forma que el modelo de la altura geopotencial, Z , se corresponde con el vértice $(1, 0, 0)$, el modelo de temperatura, T , con $(0, 1, 0)$ y el modelo de humedad relativa, HR , con $(0, 0, 1)$.

El modelo de análogos desarrollado se ha validado realizando crosvalidación. Los resultados se exponen en términos de *Brier Skill Scores* (BSS) obtenidos (Brier, 1950) utilizando como modelo de referencia la climatología.

El *Brier Skill Score* se define como:

$$(6) \text{ BSS} = 1 - \text{BSBref}$$

Siendo BS el *Brier Score* que a su vez se define como:

$$(8) \text{ BS} = \frac{1}{N} \sum_{i=1}^N (p_i - o_i)^2$$

Donde el valor N representa el número de observaciones de que se dispone para realizar la validación, p_i es la probabilidad estimada por el modelo de un determinado evento y o_i es la probabilidad observada del evento (0/1 dependiendo de la ocurrencia No/Si del evento). De esta forma el BS es un estadístico que evalúa la exactitud de las probabilidades estimadas por un modelo

y sus valores se distribuyen en el rango $[0,1]$ siendo el valor 0 el asociado a un modelo perfecto. El BSS resulta de la comparación de los BS obtenidos para el modelo de estudio y un modelo que se toma como referencia. La interpretación del BSS es una comparación de los modelos incluidos, donde la obtención de valores negativos esta asociada con una mejor estimación de las probabilidades por parte del modelo de referencia y la obtención de valores positivos se asocia con la obtención de BS menores para el modelo de estudio (siendo 1 el máximo valor posible), en el caso de obtenerse BSS mayores que 0, se acostumbra a interpretar el BSS como el porcentaje de mejora (en tanto por uno) que se obtiene de las estimaciones. Comúnmente para la evaluación de modelos meteorológicos se utilizan como modelos de referencia las estimaciones climáticas (basadas en la frecuencia observacional de un evento) o los modelos de persistencia (basados en la aceptación de un comportamiento persistente de la atmósfera).

3. RESULTADOS

3.1. Modelo de análogos con varias variables para la lluvia

Estudiamos los resultados de distintos modelos construidos a partir de una colección de combinaciones (α, β, γ) . Para cada terna y en función de la variación del número de análogos (hasta un máximo de 60) se elaboran diferentes modelos. Se analizan los resultados obtenidos de BSS, seleccionando para cada terna el número de análogos óptimo. Los resultados obtenidos son comparados con aquellos derivados del modelo con una única variable, Z .

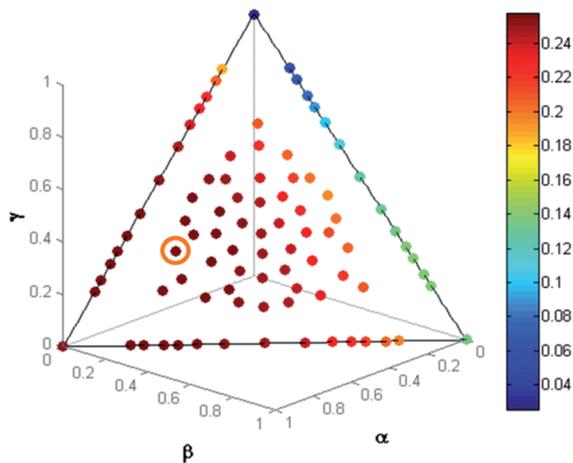


FIG. 3: Resultados de BSS para el simplex obtenido mostrando la mejor combinación en el modelo de análogos para la lluvia (círculo rojo).

Para la predicción de lluvia, la terna óptima de la muestra de combinaciones probada es la que tiene pesos $(0.57, 0.14, 0.28)$ en un modelo con 37 análogos (Fig. 3). Una de las características que se observa en la Figura 3 es la distribución relativamente suave del BSS entre los diferentes puntos cercanos del simplex. Esta suavidad aporta información sobre la significatividad estadística de los resultados, producto del registro temporal ya que los valores de BSS se obtienen a partir de la validación de cada modelo a lo largo de periodos superiores a 25 años en todos los observatorios. Los

pesos obtenidos para la optimización de la predicción pueden ser interpretados como la proporción en la que cada una de las variables aporta información no correlacionada en el modelo de análogos. Así la variable Z aporta más de la mitad de la información en la predicción (57%), mientras que T y HR presentan un aporte más reducido (14 y 29%, respectivamente), siendo la humedad relativa la segunda variable que mayor información aporta en la predicción y quedando la temperatura como la variable que comparativamente menor información aporta.

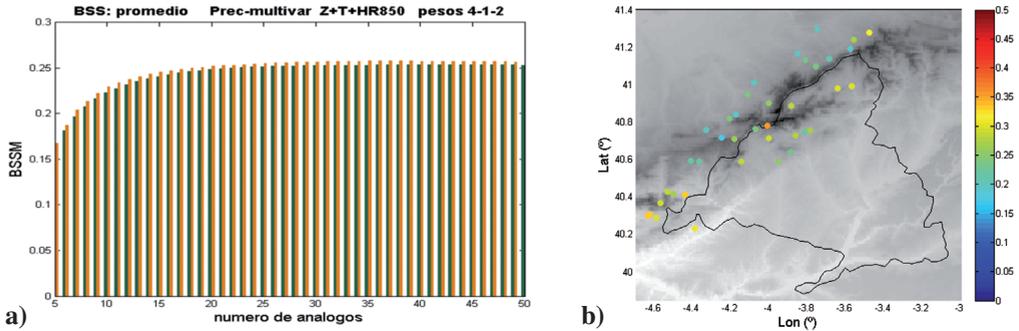


FIG. 4: (a) Resultados en términos de BSS frente al número de análogos de los modelos (0.57, 0.14, 0.29) en naranja y (1, 0, 0) en verde para lluvia para el promedio de todos los observatorios y (b) Resultados de BSS para lluvia utilizando el modelo óptimo con tres variables.

Analizando la combinación óptima y comparando los BSS obtenidos por este modelo con los obtenidos por el modelo de referencia que solo incluye Z como variable de entrada (modelo (1, 0, 0)) para diferente número de análogos (Fig. 4a), se observa la mejora de los resultados del modelo de tres variables con respecto a la de referencia. Si bien las diferencias entre el modelo de referencia y el modelo multivariable son muy pequeñas (aproximadamente mejoras de 0.4% respecto del modelo climático de referencia), estas diferencias resultan representativas ya que se obtiene el mismo resultado independientemente del número de análogos utilizado para realizar la predicción. La mejora final obtenida en el BSS a partir de la inclusión de las dos nuevas variables T y HR , resulta pequeña en comparación con la obtenida por el modelo (1, 0, 0) debida a que la información estadística aportada por estas dos variables es en gran medida redundante.

La Fig. 4b muestra la distribución espacial de los resultados de BSS para cada observatorio utilizando el modelo óptimo. Se observa de nuevo que el observatorio de Navacerrada muestra el mayor de BSS, debido a la mayor longitud de su registro temporal (Fig. 4b). Así mismo, se puede apreciar sobre la línea divisoria de la Comunidad de Madrid una zona de valores ligeramente superiores al resto de BSS. Estas diferencias de BSS se encuentran fuertemente asociadas con la calidad de datos de las series temporales de cada observatorio, lo cual incluye tanto la longitud temporal total del registro como el número de datos erróneos o inexistentes de la base de datos.

3.2. Modelo de análogos con varias variables para la nieve

Llevando a cabo un experimento similar al de la lluvia expuesto en la subsección anterior, se ha obtenido un modelo de predicción de nieve cuya sensibilidad a la inclusión de unas u otras variables es estudiada de nuevo mediante crovalidación del modelo y cálculo de los BSS para una colección de combinaciones (α , β , γ).

Un aspecto significativo que podemos comprobar en la Fig. 5 es el hecho de que el mejor BSS se obtiene para los pesos (0.60, 0.40, 0.00), que se corresponden con una combinación de 2 variables, Z (60%) y T (40%). De esta forma, se puede concluir que la inclusión de la variable HR no contribuye con información estadística alguna frente a la información aportada por las otras dos variables Z y T .

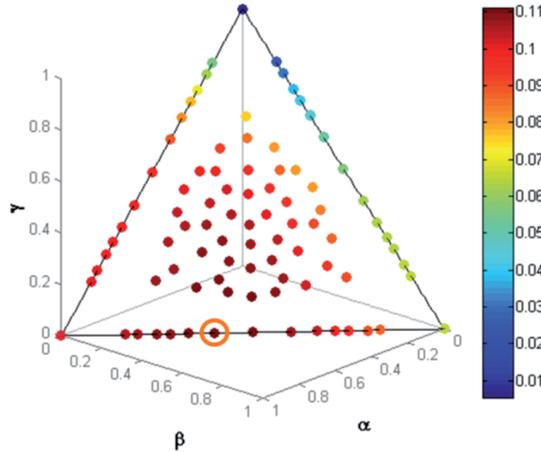


FIG. 5: Resultados de BSS para el simplex obtenido mostrando la mejor combinación en el modelo de análogos para la nieve (círculo rojo).

En el caso de nieve, los BSS para el promedio de las estaciones en función del número de análogos (Fig. 7a) muestran una mejora sustancial con el uso del modelo multivariable frente al modelo de referencia (1, 0, 0). Esta mejora es muy superior a la obtenida para el caso de lluvia (Fig. 4a) lo cual indica que la inclusión de la variable T aporta una considerable cantidad de información no redundante al modelo.

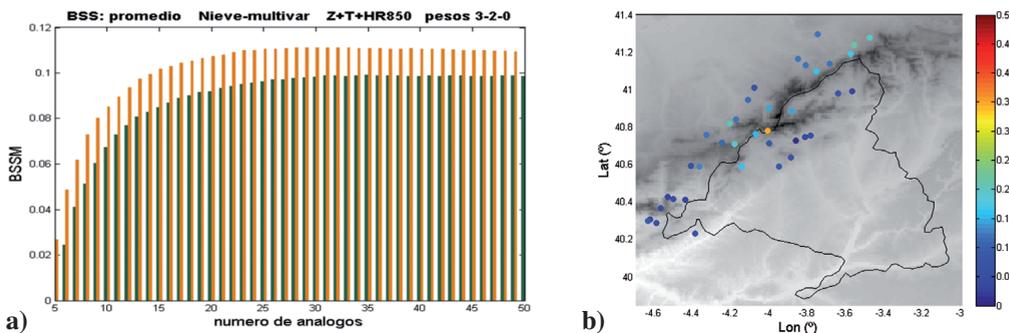


FIG. 7: (a) Resultados en términos de BSS frente al número de análogos de los modelos (0.60, 0.40, 0.00) en naranja y (1, 0, 0) en verde para nieve para el promedio de todos los observatorios y (b) Resultados de BSS para nieve utilizando el modelo óptimo con dos variables.

De forma similar al caso de la lluvia en el subapartado anterior, se muestra una comparación entre los BSS para cada una de las estaciones en un modelo de 33 análogos (Fig. 7b). Se puede observar

que los mayores BSS nuevamente se obtienen para el observatorio de Navacerrada, presentando un valor de BSS de 0.35, mientras que para el resto de observatorios el BSS se sitúa en torno a 0.1.

4. CONCLUSIONES

En el presente trabajo se ha validado la utilización de modelos de análogos multivariable para la predicción de lluvia y nieve en la Sierra de Madrid. Para ello se ha propuesto un modelo de análogos que incluye la búsqueda de distribuciones a gran escala de tres variables, geopotencial, temperatura y humedad relativa (Z , T , HR) en el nivel de 850 hPa, ponderando la importancia que se atribuye a cada una de estas variables. Como función de distancia del modelo se ha utilizado una distancia total compuesta por la combinación ponderada de cada una de las funciones de distancia particulares de las variables de gran escala utilizadas. Se ha demostrado como el espacio de pesos posibles por el modelo se reduce a un simplex bidimensional que puede ser representado por un área triangular en el que se muestran los pesos relativos de cada una de las tres variables. Se han analizado los resultados de distintos modelos en términos de Brier Skill Scores analizando qué ponderación de variables optimiza el proceso de predicción de lluvia o nieve en los 38 observatorios de estudio.

Para la lluvia, la mejor terna de combinaciones probada es la que tiene pesos de distribución (0.57, 0.14, 0.29) para Z , T y HR , respectivamente, obteniéndose una configuración relativamente suave del BSS con un número óptimo de 37 análogos en los puntos del simplex. Se ha comprobado asimismo que el modelo de análogos desarrollado con T , con HR o los modelos con combinaciones de las dos variables muestra peores resultados, siendo necesario incluir la variable Z , tanto para los resultados obtenidos de BSS en promedio en todo el área en estudio como para los resultados en el observatorio de Navacerrada. El método de análisis confiere entonces máxima importancia a la variable Z seleccionando ésta como la variable que mayor información estadística aporta para el proceso de predicción mediante análogos. Asimismo, la información obtenida por las variables T y HR es considerablemente inferior quedando la variable T como la que menor información relativa aporta en el proceso de predicción de lluvia mediante análogos. El observatorio de Navacerrada muestra el valor mayor de BSS, debido a la mayor longitud de su registro temporal.

Para la predicción de nieve, el método de combinación de variables a través de la función de distancia ofrece mejores resultados cualitativos que para el caso de lluvia, si bien en el caso de la nieve, los BSS son menores, ya que para lluvia se sitúan en torno a 0.25 mientras que para nieve se sitúan en torno a 0.1. El mayor BSS se obtiene para una combinación de los pesos de la forma (0.60, 0.40, 0). Esta combinación se corresponde con una composición de 2 variables, Z y T con una ponderación del 60% y 40%, respectivamente. La humedad relativa se considera despreciable y por tanto, no aporta mayor información de la que se puede obtener con las otras dos variables a través de la función de distancia. De nuevo el observatorio de Navacerrada muestra mayor BSS (≈ 0.35) que el resto de los observatorios.

Agradecimientos

Este trabajo ha sido parcialmente apoyado por los proyectos de investigación AYA2011-29967-C05-02, VA025A10-2 and CGL2011-25327. Los autores agradecen a la AEMET (Agencia Estatal de Meteorología) por proporcionar los datos de lluvia y nieve. Así mismo, agradecen al European Centre for Weather Medium Forecast (ECWMF) por proporcionar los datos de ERA40.

REFERENCIAS

Brier, G.W. (1950). "Verification of forecasts expressed in terms of probabilities". *Monthly Weather Review*, 78, 1-3.

- Fernández-Ferrero A., Sáez J., Ibarra-Berastegi G. (2010): Comparison of the Performance of Different Analog-Based Bayesian Probabilistic Precipitation Forecasts over Bilbao, Spain. *Mon. Wea. Rev.*, 138, 3107–3119.
- Gibson JK, Kallberg P, Uppala S, Hernandez A, Ñomura A y Serrano E. (1997). ERA description. Technical Report Re-analysis Project Report Series 1, ECMWF, Reading, UK.
- Hatcher A. (2002). Algebraic topology. *Cambridge University Press*, pp 556.
- Joliffe, IT. (1986). Principal Component Analysis. Springer: New York; pp 271.
- Lorenz E. N. (1969). “Atmospheric Predictability as Revealed by Naturally Occurring Analogues”. *J. Atmos. Sci.* 26, 636-646
- Pascual A., F. Valero, M. L. Martín, A. Morata, y M. Y. Luna (2012). “Probabilistic and deterministic results of the ANPAF analog model for Spanish wind field estimations”. *Atmospheric Research*, aceptado. doi: 10.1016/j.atmosres.2012.01.011.
- Preisendorfer, RW. (1998). Principal Component Analysis in Meteorology and Oceanography. Elsevier Science Publishers BV: Amsterdam; pp 425.
- Simmons, A.J., Gibson, J.K. (2000). The ERA-40 Project Plan. ERA-40 Project Report Series No. 1. ECMWF, Reading, UK.
- Zorita E., von Storch H. (1999): The Analog Method as a Simple Statistical Downscaling Technique: Comparison with more Complicated Methods, *J. Clim.* 12, 2474-2489.