

Modelos colectivos de *downscaling* probabilístico con Redes Bayesianas.

Rafael Ancell Trueba⁽¹⁾

José Manuel Gutiérrez⁽²⁾

Daniel San Martín⁽²⁾

(1) Instituto Nacional de Meteorología, rct@inm.es

(2) Universidad de Cantabria, gutierjm@unican.es; sanmartind@unican.es

Introducción

En la actualidad existe un gran interés por los métodos de *downscaling* estadístico capaces de tener en cuenta la dependencia espacial entre los predictandos, ya que son cada vez más numerosos los usuarios para los cuales el comportamiento colectivo del predictando sobre una determinada área es incluso más importante que el individual sobre una estación concreta, como ocurre en algunos modelos hidrológicos, de demanda energética, de impacto del cambio climático, etc.

Métodos deterministas

En el caso de dependencia lineal entre las variables, este problema está bien resuelto por los métodos de *downscaling* estadístico basados en regresión; por ejemplo, relacionando las Componentes Principales, tanto de los predictores como de los predictandos (Wigley, 1990), o mediante una Correlación Canónica (CCA) (Karl, 1990), etc., con resultados similares.




Figura 1.- En (a) se utiliza una Regresión Múltiple Lineal para modelar la temperatura máxima y la precipitación a escala diaria en Lugano (Suiza); mientras que, para incluir la dependencia espacial, en (b) y (c) se emplea CCA. Ilustrando que estos modelos lineales no son adecuados para la precipitación a escala de agregación diaria.

Extender esta metodología a variables que no admiten un tratamiento lineal, como por ejemplo la precipitación diaria (ver fig. 1), ha dado lugar al desarrollo de diferentes estrategias que resuelven parcialmente el problema. Entre otros, son interesantes los trabajos de Wilby (2003), Beersma (2003), Wood (2004) o Cannon (2007), en los cuales

se utilizan diferentes procedimientos para poner de manifiesto las relaciones de dependencia espacial existentes.

Métodos probabilísticos

A diferencia de los métodos deterministas, la estrategia de estos métodos consiste en modelar la distribución de probabilidad de las variables del sistema, considerando como predictor una descripción compacta del estado de la atmósfera C , generado por un modelo de circulación atmosférica (ACM). Básicamente hay dos procedimientos: el *Método de Análogos* (MA) -basado en los vecinos más cercanos (*knn*)-, y los *Weather Typing* (WT) -basados en clasificadores como *k-medias*-. De todos ellos, la técnica más popular es MA, cuya hipótesis básica es que predictores similares producen predictandos similares. Este condicionamiento es específico para cada predictor, por lo que MA es más preciso que WT, aunque pueden llegar a ser igualmente precisos cuando se utilizan en sistemas de predicción por conjuntos (EPS), Cofío (2004). Ambos métodos son *discriminativos*, ya que estiman directamente la probabilidad de cada predictando dado el predictor, e *ingenuos* ya que asumen la hipótesis de independencia condicional entre los predictandos $\{X\}$ dado el predictor C :

$$P(X_1, \dots, X_n | C) = \prod_{i=1}^n P(X_i | C)$$

En el ejemplo que se muestra a continuación (figura 2), vemos que cuando se trata con eventos cuya variabilidad espacial tiene una escala inferior a la que es capaz de resolver el predictor (como por ejemplo, eventos de ocurrencia de precipitación a escala de agregación diaria), la hipótesis de independencia condicional deja de ser válida para estaciones suficientemente próximas (como sucede cuando se trabaja con redes de observación de alta resolución), justificando la necesidad de utilizar métodos capaces de considerar estas relaciones de dependencia, como las Redes Bayesianas (RBs).

Modelo ingenuo: $p(a,b c) = p(a c)p(b c)$		
$P(a,b c=1)$	$a=0$	$a=1$
$b=0$	0.35	.31
$b=1$.17	.15

Modelo general: $p(a,b c) = p(a c)p(b a,c)$		
$P(a,b c=1)$	$a=0$	$a=1$
$b=0$.50	.17
$b=1$.03	.30

Figura 2.- En este ejemplo, cuando el estado del predictor es $c=1$, la probabilidad de lluvia simultánea en $a=San$

Sebastian y b=Fuenterrabia es de 0.3, mientras que utilizando un modelo ingenuo se obtiene la mitad: 0.15, ya que estima la probabilidad conjunta agregando modelos condicionalmente independientes.

Redes Bayesianas

Una RB es un modelo probabilístico de una función de probabilidad conjunta (JPD), definido por un grafo dirigido acíclico (DAG) y un conjunto de funciones de probabilidad condicionada, de forma que la estructura de dependencia/independencia mostrada por el DAG puede ser expresada en términos de JPD mediante el producto de varias distribuciones condicionadas, como sigue:

$$P(y_1, y_2 \dots y_n) = \prod_{i=1}^n P(y_i | \pi_i)$$

Donde π_i es el conjunto de los padres del nodo y_i en el grafo. De esta forma, las dependencias del grafo son inmediatamente traducidas al modelo probabilístico de una manera muy práctica.




Figura 3.- DAG que codifica las relaciones de dependencia entre la precipitación entre algunas estaciones de la red principal del INM, Cano (2004).

Las RBs son modelos *generativos*, esto es, estiman JPD para después inferir la probabilidad condicionada, y por lo tanto son capaces de considerar relaciones de dependencia entre los predictandos. Cuando se plantea un modelo de RB, donde $\{E\}$ es la evidencia disponible y $\{Q\}$ el conjunto de variables a predecir, el principal interés reside en modelizar $P(Q|E)$, para después calcular $P(Q|E)$. Teniendo en cuenta que en meteorología es común tener conocimiento parcial de los predictandos $\{X\}$ (por ejemplo, las estaciones automáticas pueden proporcionar información en tiempo real), podemos separarlos en dos grupos, según sean evidenciales $\{Z\}$ o no $\{Y\}$: $\{X\}=\{Z,Y\}$, y extender el concepto de que las RBs suponen una generalización de algunos de los métodos del tipo WT, Gutiérrez (2002). Una RB puede ser utilizada en la práctica para obtener $P(Q|E)$ bajo diferentes paradigmas, dependiendo de cuál es la evidencia: $E=\{C\}$, $E=\{Z\}$ o $E=\{Z,C\}$, y cuál la estimación, $Q=\{Y\}$, $Q=\{C\}$ o $Q=\{Y,C\}$. Además, en este sistema, la única variable susceptible de ser anticipada en el tiempo es el estado de la atmósfera cuando actúa como predictor (usando las predicciones de los ACMS). Por ello cuando en la

evidencia aparece C (puede aparecer solo, $E=\{C\}$, o junto con algunos predictandos, $E=\{Z,C\}$), se dice que la estimación tiene capacidad predictiva y la denominaremos paradigma de *predicción* (cuyo principal caso particular es el *downscaling*), mientras que si únicamente se conocen algunas estaciones, $E=\{Z\}$, se habla de paradigma de *diagnóstico*, uno de cuyos casos particulares es la *interpolación*; ver figura 4.




Figura 4.- Diferentes paradigmas.

Por lo tanto, las RBs permiten utilizar un único modelo para diferentes propósitos, que además, en las versiones extendido y genérico, es capaz de expresar el comportamiento colectivo del sistema.

BIBLIOGRAFÍA

- Beersma, J. and T.A., B. (2003).** Multi-site simulation of daily precipitation and temperature conditional on the atmospheric circulation. *Climate Research*, 25:121-133.
- Cannon, A. J. (2007).** Nonlinear analog predictor analysis: A coupled neural network/analog model for climate downscaling. *Neural Netw.*, 20(4):444-453.
- Cano, R., Sordo, C., and Gutiérrez, J. M. (2004).** Bayesian networks in meteorology. In J. A. Gámez, S. Moral, and A. Salmerón, eds., *Advances in Bayesian Networks*, pp. 309-327. Springer Verlag.
- Cofiño, A. S. (2004).** Técnicas Estadísticas y Neuronales de Agrupamiento Adaptativo para la Predicción Probabilística de Fenómenos Meteorológicos Locales. Aplicación en el Corto Plazo y en la Predicción Estacional. Ph.D. thesis, Universidad de Cantabria.
- Gutiérrez, J. M., Cofiño, A. S., Cano, R., and Sordo, C. (2002).** A generalization of analogue downscaling methods by bayesian networks. In *International Conference on Quantitative Precipitation Forecasting*, pp. 87-87. The World Weather Research Programme's WWRP.
- Karl, T., Wang, W., Schlesinger, M., Knight, R., and Portman, D. (1990).** A method of relating general circulation model simulated climate to the observed local climate. part i: Seasonal statistics. *J. Climate*, 3:1053-1079.
- Wigley, T., Jones, P., Briffa, K., and Smith, G. (1990).** Obtaining sub-grid-scale information from coarse-resolution general circulation model output. *Jgr*, 95:1943-1953.
- Wilby, R., Tomlinson, O., and Dawson, C. (2003).** Multi-site simulation of precipitation by conditional resampling. *Climate Research*, 23:183-194.
- Wood, A. (2004).** Hydrologic implications of dynamical and statistical approaches to downscaling climate model outputs. *Climatic Change*, 62:1573-1480.