



UNIVERSITAT DE
BARCELONA

La reconstrucción de la dinámica fluvial y su conexión con la variabilidad climática a partir de fuentes documentales y registros instrumentales

Juan Carlos Peña Rabadán

ADVERTIMENT. La consulta d'aquesta tesi queda condicionada a l'acceptació de les següents condicions d'ús: La difusió d'aquesta tesi per mitjà del servei TDX (www.tdx.cat) i a través del Dipòsit Digital de la UB (diposit.ub.edu) ha estat autoritzada pels titulars dels drets de propietat intel·lectual únicament per a usos privats emmarcats en activitats d'investigació i docència. No s'autoritza la seva reproducció amb finalitats de lucre ni la seva difusió i posada a disposició des d'un lloc aliè al servei TDX ni al Dipòsit Digital de la UB. No s'autoritza la presentació del seu contingut en una finestra o marc aliè a TDX o al Dipòsit Digital de la UB (framing). Aquesta reserva de drets afecta tant al resum de presentació de la tesi com als seus continguts. En la utilització o cita de parts de la tesi és obligat indicar el nom de la persona autora.

ADVERTENCIA. La consulta de esta tesis queda condicionada a la aceptación de las siguientes condiciones de uso: La difusión de esta tesis por medio del servicio TDR (www.tdx.cat) y a través del Repositorio Digital de la UB (diposit.ub.edu) ha sido autorizada por los titulares de los derechos de propiedad intelectual únicamente para usos privados enmarcados en actividades de investigación y docencia. No se autoriza su reproducción con finalidades de lucro ni su difusión y puesta a disposición desde un sitio ajeno al servicio TDR o al Repositorio Digital de la UB. No se autoriza la presentación de su contenido en una ventana o marco ajeno a TDR o al Repositorio Digital de la UB (framing). Esta reserva de derechos afecta tanto al resumen de presentación de la tesis como a sus contenidos. En la utilización o cita de partes de la tesis es obligado indicar el nombre de la persona autora.

WARNING. On having consulted this thesis you're accepting the following use conditions: Spreading this thesis by the TDX (www.tdx.cat) service and by the UB Digital Repository (diposit.ub.edu) has been authorized by the titular of the intellectual property rights only for private uses placed in investigation and teaching activities. Reproduction with lucrative aims is not authorized nor its spreading and availability from a site foreign to the TDX service or to the UB Digital Repository. Introducing its content in a window or frame foreign to the TDX service or to the UB Digital Repository is not authorized (framing). Those rights affect to the presentation summary of the thesis as well as to its contents. In the using or citation of parts of the thesis it's obliged to indicate the name of the author.

Peña Rabadán, J.C. (2015). La reconstrucción de la dinámica fluvial y su conexión con la variabilidad climática a partir de fuentes documentales y registros instrumentales

9. PATRONES SINÓPTICOS EN EUROPA OCCIDENTAL QUE CARACTERIZAN LOS MESES DE JULIO Y AGOSTO

9. PATRONES SINÓPTICOS EN EUROPA OCCIDENTAL QUE CARACTERIZAN LOS MESES DE JULIO Y AGOSTO

9.1 Introducción

Si bien existen tipologías sinópticas para los meses de verano para la zona de América del Norte (Sheridan, 2002; Diem et al., 2013; Vanos et al., 2015), en este capítulo se va a desarrollar una tipología sinóptica específica para los meses de julio y agosto, inédita todavía para el ámbito de la Europa Occidental, con el objetivo de establecer vínculos con las inundaciones estivales de Suiza, detectar que tipos sinópticos son susceptibles de producir este evento hídrico extremo y evaluar cambios en los patrones. La clasificación sinóptica se ha realizado en base al modelo de red neuronal descrito: SOM, Self-Organizing Maps, metodología también inédita en el ámbito europeo. La variable usada para la clasificación ha sido la anomalía estandarizada de la presión reducida a nivel del mar (EMSLP) para el periodo 1871-2010 y en base a ella se han analizado otros niveles atmosféricos (temperatura a 850 hPa y altura geopotencial a 500 hPa), así como variables climáticas (distribución de la precipitación en Europa). Dado que hay que desarrollar la nueva metodología y describir los distintos tipos sinópticos, y con el fin de no alargar mucho el capítulo, las conexiones de los tipos sinópticos de los meses de julio y agosto con los modos de variabilidad atmosférica de baja frecuencia y las inundaciones estivales de Suiza se realiza en el capítulo 10.

9.2. Estado de la cuestión

La climatología sinóptica tiene una rica herencia metodológica de técnicas diseñadas para relacionar la circulación atmosférica a escala sinóptica a un clima local o a una respuesta ambiental (Yarnal, 1993). Si bien históricamente se remonta a finales del S. XIX (ej. Köppen, 1874; Abercromby, 1883, 1887), la climatología sinóptica quedó delimitada como un subcampo dentro de la climatología con la publicación ‘Synoptic climatology: methods and applications’ (Barry y Perry, 1973). En esta publicación es definida como “el

conocimiento de los climas locales o regionales mediante el examen de la relación de los elementos meteorológicos, de forma individual o colectiva, con los procesos de circulación atmosférica”. A pesar de que la evolución tecnológica (desarrollo de potentes ordenadores) ha mejorado los resultados de los modelos meteorológicos y climáticos, una buena clasificación sinóptica puede ser muy útil para la explicación del pasado y la previsión a largo plazo (Aran et al., 2010; Peña et al. 2011; Peña et al. 2015a).

Desde las tipologías sinópticas pioneras de Hess y Brezowsky, 1952 y Gerstengarbe et al., 1999, la clasificación sinóptica principalmente se ha utilizado en el pronóstico del tiempo, desarrollando métodos para una explicación del clima pasado con la finalidad de entender el tiempo presente. Los objetivos se han centrado en la relación entre los factores atmosféricos, situaciones sinópticas y los elementos del clima, para evaluar los efectos en el clima local o regional y para mejorar la evaluación del posible impacto de la variabilidad climática a escalas locales (García-Herrera et al., 2007; López-Moreno y Vicente-Serrano, 2007). Los estudios de investigación en este campo por lo general implican el desarrollo de catálogos de circulación atmosférica a partir de los mapas del tiempo para explicar fenómenos ambientales que pueden tener un impacto en las actividades antrópicas (Esteban et al., 2006; Huth et al., 2008). Cuestiones como la previsión a corto plazo (método de los análogos), a largo plazo (previsiones estacionales), el análisis de los fenómenos extremos y otros fenómenos meteorológicos son comúnmente tratados (Alpert et al., 2004). Estos catálogos se han ampliado en las últimas décadas, no sólo por el avance de los equipos que permiten el tratamiento de grandes cantidades de datos (Huth et al., 2008), sino también por la mejora y disponibilidad de grandes bases de datos (Kalnay et al., 1996; Ansell et al., 2006; Compo et al., 2011).

Se ha llevado a cabo numerosos análisis para construir catálogos sinópticos que explican los fenómenos meteorológicos extremos. Los desastres naturales debido a estos acontecimientos están teniendo un mayor impacto en la sociedad en términos de costes, tanto humanos como económicos (Llasat et al., 2009). Otro problema añadido es que estos desastres son difíciles de predecir debido a la compleja interacción entre la topografía y las masas de aire diferentes, la pequeña zona afectada y la corta duración de los

eventos antes mencionados. Estos factores pueden causar grandes diferencias en la respuesta entre zonas muy próximas (López-Moreno y Vicente-Serrano, 2007). Los recientes avances en las metodologías de clasificación sinóptica ha facilitado la aparición de un gran número de estudios sobre eventos hidrológicos extremos. Vale la pena mencionar algunos de ellos según el tema estudiado: lluvias intensas (Houssos et al., 2008; Martín-Vide et al., 2008; Martínez et al., 2008; Vicente-Serrano et al., 2009); tormentas (Pineda et al., 2008); temperaturas extremas del verano y olas de calor (García-Herrera et al., 2005; Kyselý y Huth, 2008; Peña et al., 2015a); radiación solar (Sánchez-Lorenzo et al., 2009) grandes nevadas y la variabilidad del espesor de la nieve (Esteban et al., 2005; López-Moreno y Vicente-Serrano, 2007), episodios de avalancha (García et al., 2009), episodios de piedra (Sioutas y Floucas, 2003; Aran et al., 2009) y de viento fuerte (Peña et al., 2009; 2011).

Desde un punto de vista metodológico, ha sido la estadística multivariante el gran paradigma de la mayor parte de los estudios arriba citados, como el Análisis de Componentes Principales (PCA), el Análisis Cluster, o ambos métodos a la vez (Esteban et al., 2006; 2009), salvo el estudio de Kyselý y Huth (2008) en el que la clasificación sinóptica se llevó a cabo a través del Catálogo de Hess-Brezowsky (Hess y Brezowsky, 1952; Gerstengarbe et al., 1999). Algunos de estos análisis han utilizado el Análisis Discriminante (Ward, 1963) para una validación final de los resultados obtenidos (Aran et al., 2010; Peña et al., 2010; Peña et al., 2015a). En definitiva, todas las técnicas de análisis multivariante mencionadas son ampliamente aceptadas por los investigadores para elaborar los catálogos sinópticos (Huth et al., 1996; 2006; 2008).

La climatología sinóptica ha ido incorporando las redes neuronales artificiales durante la primera década del s. XXI para definir los tipos de circulación atmosférica sobre diferentes dominios territoriales (Hewitson and Crane, 2002). El modelo de red neuronal denominado mapa auto-organizado (SOM, Self-Organizing Maps, Kohonen, 2001), fundamentado en evidencias descubiertas a nivel cerebral, es un tipo de red neuronal artificial que es entrenada usando un aprendizaje no supervisado para producir una representación discreta de los datos de entrada, llamado mapa. Los mapas auto-organizados difieren de otras redes neurales artificiales en el sentido que usan una función de vecindad para preservar las propiedades topológicas del espacio de entrada. En definitiva, la SOM es una herramienta para el análisis exploratorio de datos que

ha sido utilizada en un amplio rango de aplicaciones en minería de datos y diferentes campos científicos. Por ejemplo, la SOM puede convertir las complejas características no-lineales que definen la circulación atmosférica en una simple matriz bidimensional de neuronas (en nuestro caso son los patrones sinópticos), captando además las transiciones que pueden haber entre ellas a partir del proceso de auto-aprendizaje y de conexión con las neuronas vecinas a través de la relación de vecindad.

9.3. Metodología: los mapas auto-organizados (Self-Organizing Maps, SOM)

9.3.1. Generalidades

La metodología basada en los mapas auto-organizados (SOM) se ha extendido en numerosos campos de la ciencia y la tecnología como un método de análisis. La metodología SOM utiliza un algoritmo de red neuronal para determinar y mostrar la función de distribución de un conjunto de datos multidimensional. Esto se logra mediante la creación de una matriz bidimensional de neuronas, que a efectos de la climatología sinóptica se puede entender como una metodología similar a las técnicas clásicas de agrupamiento. Debido a que estas neuronas engloban todo el espacio muestral de los datos de entrada, no implica suposiciones a priori acerca de la distribución de los datos (Hewitson y Crane, 2002). Un mapa definido por un número de neuronas, número que es definido por el usuario, se inicializa con valores aleatorios (por ejemplo, Cassano et al., 2006; Hewitson y Crane, 2002), o con los vectores propios del conjunto de datos (por ejemplo, Gutiérrez et al., 2005). Cada vector de entrada (caso) se añade a la SOM, y un nodo ganador se determina en base a la distancia euclidiana más pequeña con la neurona inicial (Hewitson y Crane, 2002). Este nodo se modifica en un paso posterior a través de un parámetro de aprendizaje. Este parámetro puede ser variable: valores altos producen un proceso de aprendizaje más rápido, pero potencialmente inestable dando un resultado poco realista, mientras que el proceso es más lento con valores más bajos pero dando una salida más robusta (Gutiérrez et al., 2005). En este proceso, además de modificar la neurona ganadora, las neuronas vecinas de la red

también se modifican, a través de una función de decaimiento o vecindad en base a la distancia (Hewitson y Crane, 2002). Kohonen (2001) señala que la metodología SOM es la misma que el método k-means, si la función de vecindad fuera eliminada. En última instancia, a través de este patrón de ajuste espacial, el conjunto de neuronas se 'auto-organiza' en un patrón cohesionado, con los nodos más similares cercanos entre ellos y los nodos más disímiles más alejados en la red. Por lo tanto, las cuatro esquinas de la SOM pueden ser consideradas como las neuronas más extremas en cuanto a la variabilidad climática, y la red neuronal queda definida en base a las transiciones entre estados sinópticos. Además, este proceso de aprendizaje preserva la densidad de probabilidad, por lo que las neuronas se colocan en las zonas con una alta densidad de datos (es decir, situaciones sinópticas más comunes), y los casos atípicos son menos propensos a ser fusionados en un clúster no representativo (Nicholls et al., 2010). Finalmente, la metodología SOM es más robusta en el manejo de los valores faltantes, ya que pueden ser interpolados en el 'mapa auto-organizado' (Hewitson y Crane, 2002; Richardson et al., 2003).

La aplicación de la SOM requiere dos decisiones arbitrarias: el valor de la función de aprendizaje y el radio en el que los nodos adyacentes van a ser modificados (Sheridan y Lee, 2011). La decisión inicial de los valores de estos parámetros se basa en muchos casos en el método de prueba y error, (por ejemplo Schuenemann et al., 2009). Generalmente, todo el proceso se repite dos veces, primero con valores de radio relativamente grandes para la definición de la red SOM (clasificación), y luego con radios más pequeños para refinar los nodos en zonas de alta densidad de datos (Crane y Hewitson, 2003). Una vez que se alcanza una solución estable, se realiza una clasificación final, en la que cada caso se puede asignar al nodo que más se parece. En algunos estudios se ha demostrado que la influencia de estos parámetros en la solución final es mínima, y por lo tanto, el resultado puede ser bastante robusto independientemente de estas decisiones subjetivas (por ejemplo, Cassano et al., 2006; Johnson et al, 2008), aunque en otros casos no parece ser tan evidente (Schuenemann et al, 2009). En la mayoría de los artículos, por desgracia, poca o ninguna discusión se da a la elección exacta de estos parámetros.

En definitiva, las características principales de la SOM se señalan a continuación:

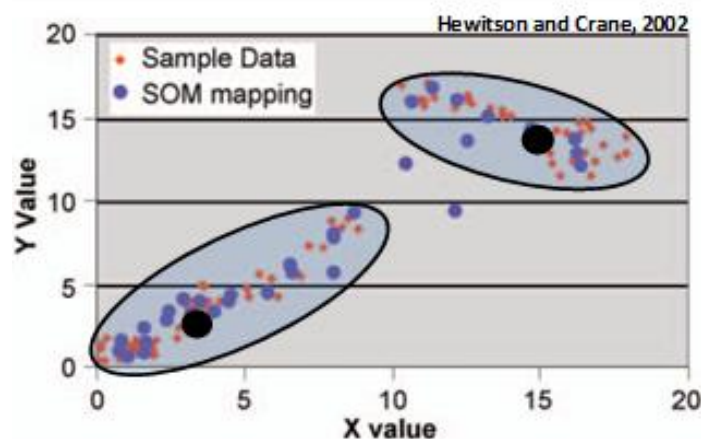
- El mapa auto-organizado debe revelar los rasgos comunes o correlaciones en los datos de entrada, e incorporarlos a su estructura interna de conexiones.
- Las neuronas deben auto-organizarse en función de los estímulos (datos) procedentes del exterior.
- El aprendizaje es de tipo competitivo no supervisado y se pretende que sólo una de las neuronas de salida se active cuando se introduzca a la red un patrón de entrada.
- Además, entre las neuronas existen conexiones laterales implícitas de excitación e inhibición, pues aunque no estén conectadas, cada una de estas neuronas va a tener cierta influencia sobre sus vecinas. Esto se consigue a partir de la aplicación de una función denominada de vecindad, que produce la topología o estructura del mapa. Así, los representantes que están en clases próximas se parecen entre sí. La idea es que la topología de salida bidimensional se auto-organice en base a que los representantes de cada grupo estén correlacionados espacialmente, de modo que los puntos más próximos en la rejilla sean más parecidos entre sí de los que estén más separados.
- Las neuronas quedan definidas por un vector de pesos. La neurona que cuyo vector de pesos es más similar a la entrada es llamada unidad de mejor correspondencia (BMU por sus siglas en inglés). Las BMU y las neuronas cercanas en la cuadrícula de la SOM son ajustadas hacia el vector de entrada.
- Remarcar que las topologías utilizadas con más frecuencia han sido la rectangular y la hexagonal.
- Finalmente, al ser un aprendizaje no supervisado (se comporta como un modelo de caja negra), las neuronas deben ser creadas por la propia red a través de las correlaciones entre los datos de entrada.

La propuesta metodológica de la SOM tiene una aplicación evidente en el campo de la climatología sinóptica (Sheridan y Lee, 2011). La

SOM se puede utilizar en el análisis de la climatología sinóptica de una manera similar a la mayoría de los otros métodos de clasificación multivariable (como el PCA o el K-means). Sin embargo, como los resultados de la SOM están representados a través de una matriz bidimensional de agrupamientos auto-organizados, la clasificación sinóptica representa un continuo de categorizaciones sinópticas, en comparación con las clasificaciones discretas producidas a partir de la mayoría de los métodos tradicionales. La figura 9.1 muestra como un espacio muestral (puntos rojos) quedaría clasificado en base a dos de los métodos más utilizados (PCA, elipses azules; K-means, puntos negros) y la SOM (puntos azules). Este continuo permite analizar la transición entre las neuronas, siendo de gran utilidad en la comprensión de la variabilidad del clima, a la vez que pueden ser útiles para la previsión de los cambios de estado a escala sinóptica (Hewitson y Crane, 2002). Pero quizás el avance más relevante es la visualización de los resultados. Los patrones espaciales resultantes de cualquier variable auto-organizados en un mapa bidimensional son más entendibles facilitando la interpretación. Esta característica ha convertido a la SOM en una herramienta cada vez más popular en las investigaciones climatológicas.

Figura 9.1. Distribución de los datos de la muestra y las neuronas de la SOM en una topología bidimensional. Las dos elipses representan los dos factores principales en el caso de utilizar un PCA, mientras que los dos puntos negros serían los clústeres calculados a partir de un K-Means.

Fuente: Hewitson y Crane (2002). Imagen retocada por Vicent Altava (2012).



9.3.2. Desarrollo metodológico

Como se ha comentado, la SOM se ha aplicado a diversos problemas en climatología (Sheridan y Lee, 2011). Sin embargo, algunas de estas implementaciones prevén un bajo número de nodos o neuronas en el mapa de salida que por lo general se ajustan al número de clústeres esperados. Por lo tanto, los patrones de los

datos de entrada se distribuyen en estos pocos grupos. Además, no es posible detectar valores atípicos. Se ha demostrado que la aplicación de la SOM con un bajo número de nodos en la red neuronal produce resultados similares al k-means clustering (Ultsch, 1994). Transiciones reales entre nodos sólo se esperan que se produzcan en SOMs con un número de nodos de al menos una magnitud más grande que el número de patrones esperados. Estas SOM son conocidas como Emergent Self-Organizing Maps (E-SOM, Ultsch, 1999; Ultsch y Mörchén, 2005). Así, la E-SOM es un mapa auto-organizado de datos de dimensión grande del que emergen las transiciones entre neuronas. Finalmente, asociado a esta nueva metodología, el método U-Matrix permite la detección de agrupamientos de datos mediante el examen de la estructura general de la E-SOM entrenada y la transformación de esta estructura en un dendrograma (Ultsch, 1999).

El algoritmo clásico de entrenamiento (véase figura 9.2) construye una topología no lineal preservando el mapeo del conjunto de datos (vectores) de entrada $X = \{x(t) | t \in \{t_0, \dots, t_f\}\}$, donde t_0 y t_f señalan el inicio y el final de la sesión de entrenamiento en un conjunto de neuronas $N = n_1, \dots, n_k$ de una red neuronal (Kohonen, 2001). Las neuronas de la red están dispuestas en una cuadrícula asociadas a unos vectores de pesos $m_i(t) = m_1(t), \dots, m_k(t)$ en un paso de tiempo (sesión de entrenamiento) dado t .

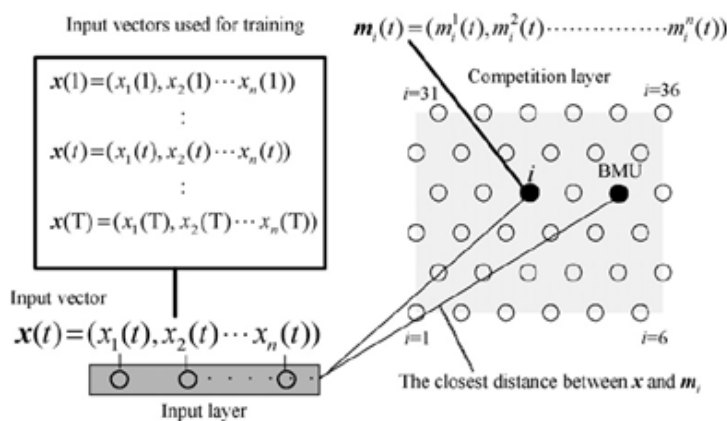


Figura 9.2. Proceso de entrenamiento y aprendizaje de la red neuronal a partir del algoritmo básico de la SOM en base a un conjunto de datos definidos por vectores de entrada.

Fuente: Hewiston y Crane (2002). Imagen retocada por Vicent Altava (2012).

La neurona que cuyo vector de pesos es más similar a la entrada es llamada unidad de mejor correspondencia (BMU). Cada vector de entrada $x(t)$ es asignado a su mejor BMU

$$\text{Bmu}[x(t)] = m_b \in N, \quad (1)$$

de tal manera que

$$d[x(t), m_b(t)] \leq d(x(t), m_j(t)), \quad \forall m_j(t) \in W, \quad (2)$$

donde d es la función de distancia (normalmente euclidiana) dentro de la red neuronal entre los vectores de entrada y las BMU. W es conocido como el código de registros o conjunto de las BMU.

Las neuronas están dispuestas en un mapa de dos dimensiones, es decir, cada neurona tiene dos coordenadas en la cuadrícula (x,y) . La denominación de cada neurona es de tipo matricial, es decir, primero la fila (comenzando desde $x=0$) y después la columna (de la misma manera, el valor inicial es $y=0$) empezando por la neurona del margen inferior izquierdo, es decir, se designaría con $N(0,0)$.

A continuación, la BMU y las neuronas cercanas a ella en la red neuronal son ajustadas hacia el vector de entrada (ver figura 9.3) utilizando la siguiente ecuación:

$$m_j(t+1) = m_j(t) + \Lambda * h_{bj}(t) * (x(t) - m_j(t)), \quad (3)$$

donde $0 < \Lambda < 1$ es el factor de aprendizaje, y $h_{bj}(t)$ es la función de vecindad que decrece para las neuronas más alejadas de la BMU. Una función de vecindad frecuentemente utilizada es la de Gauss:

$$h_{bj}(t) = \exp \left(\frac{-r_b - r_j}{\delta(t)} \right), \quad (4)$$

donde r_b and r_j son las coordenadas de las neuronas respectivas. La amplitud de $\delta(t)$ disminuye de una iteración a otra para reducir el área de influencia:

$$\delta(t) = h_{bj}(t-1) * \nu * \frac{1}{2} * \sqrt{X^2 + Y^2} \quad (5)$$

donde ν es el radio inicial de entrenamiento y el radical es la distancia euclidiana entre las neuronas.




Figura 9.3. Esquema básico de conexiones laterales implícitas de excitación e inhibición entre las neuronas.

Imagen original: Vicent Altava (2012).

El entrenamiento se repite para refinar el ajuste de datos. La función de vecindad decrece hasta el punto que el entrenamiento finaliza. El tiempo necesario para entrenar a una SOM crece linealmente con el tamaño de conjunto de datos y con el número de neuronas escogido. La E-SOM tiene un modo de actualización de las BMU por lotes (batch method), que es ampliamente utilizado en las implementaciones y reduce el tiempo de entrenamiento:

$$W_j(t_f) = \frac{\int_{t'=t_0}^{t_f} h_{bj}(t') * x(t') dt'}{\int_{t'=t_0}^{t_f} h_{bj}(t') dt'} \quad (6)$$

Aunque no directamente relacionado con el entrenamiento vale la pena mencionar la U-matrix asociada a la E-SOM. Se trata de una matriz que representa la distancia media euclídea entre las neuronas vecinas. Sea $N(j)$ los vecinos inmediatos de una neurona j . Entonces el valor de la U-matriz para la neurona j se calcula a partir de la siguiente expresión:

$$U_j = \frac{1}{N_j} \sum_{i \in N_j} d(m_i, m_j) \quad (7)$$

El propósito de la U-matriz es dar una representación visual de la topología de la red.

La mayoría de los métodos descritos para la visualización, la agrupación y la clasificación se han implementado en una herramienta llamada *Databionics E-SOM Tools* (<http://databionics-esom.sf.net/>). Se trata de un software que aglutina un conjunto de aplicaciones para realizar tareas de minería de datos como el agrupamiento, la clasificación y la visualización a partir del Emergent Self-Organizing Maps (E-SOM). Las herramientas del

software de tipo modular incluyen el entrenamiento de la red neuronal con métodos diferentes de: inicialización de la red, algoritmos de aprendizaje, funciones de distancia, estrategias de decaimiento del parámetro de aprendizaje, topologías de la red y determinación de las neuronas vecinas. Señalar que el proceso de exploración, análisis, agrupación, clasificación y visualización mediante el Databionics E-SOM Tools es de tipo interactivo facilitando el trabajo del analista de los datos.

Los parámetros utilizados para la definición de la red neuronal se presentan a continuación.

SOFTWARE: Data Bionics E-SOM train Online SOM

<p>Topología: Rejilla plana euclidiana (medida \rightarrow EOF1/EOF2) Función de vecindad: Función gaussiana Algoritmo: Batch Inicialización de la red: random Fases: 2 (clasificación + refinamiento) Iterations: 1000 Variable: EMSLP Periodo: 1871-2010</p>

En definitiva, para la inicialización de la red se ha escogido el método aleatorio (en vez de los vectores propios principales) y la distancia euclidiana entre el vector de entrada y la BMU, para crear una topología plana de forma rectangular con un número de neuronas proporcional a la relación entre los dos primeros EOFs (aproximadamente 0,75). Esta relación es similar a otros estudios pioneros de clasificación sinóptica basados en la SOM (Hewitson y Crane, 2002; Cassano et al., 2006) creando una red neuronal de dimensión 5x7, es decir, cinco filas y siete columnas con un total de 35 neuronas. Una vez se ha realizado el proceso de clasificación se ha refinado la red con un total de 1000 iteraciones. Los algoritmos para el aprendizaje y vecindad son los desarrollados en la sección 9.3.2 con un radio inicial (ν) = 24 decayendo exponencialmente en cada iteración hasta 1 y el factor de aprendizaje (Λ) = 0,5 decayendo exponencialmente en cada iteración hasta 0,1.

9.4. Resultados

9.4.1. Principales tipos sinópticos durante los meses de julio y agosto en Europa occidental

La figura 9.4 muestra las 35 neuronas resultantes. Cada neurona es la composición de EMSLP de los días clasificados en ella. Las figuras 9.5 y 9.6 son las composiciones de las anomalías de temperatura a 850 hPa y de altura geopotencial a 500 hPa. Tal como cabía esperar y como se había definido en los dos apartados anteriores, topológicamente la malla queda definida por patrones de circulación en los niveles más bajos de la troposfera opuestos en cada una de las esquinas: la esquina inferior izquierda es un patrón claramente anticiclónico, y en cambio la superior derecha es depresionario. La esquina superior izquierda señala anomalías de presión positivas en el Atlántico mientras que la inferior derecha las anomalías positivas dominan el Mediterráneo. Entre ellas se pueden observar todos los estados de transición posibles donde los centros de alta y baja presión evolucionan de manera ordenada de una neurona a otra, respetando siempre a sus vecinas. Quizás el rasgo principal es la transición de situaciones de circulación atmosférica de bloqueo anticiclónico de tipo meridional (que domina la parte izquierda de la red neuronal) a una circulación zonal en la parte superior derecha de la red. De esta manera, la visualización de los distintos estados atmosféricos emerge de manera ordenada. Las neuronas son una proyección lineal de la función de densidad de probabilidad de los datos de entrada y muestran los patrones de circulación atmosférica principales previstos en Europa durante el alto verano (los meses de julio y agosto). La Tabla 9.1 describe los patrones de circulación que caracterizan el dominio europeo del Atlántico Norte durante los meses de julio y agosto. Se designan (columna 1: Abreviación) en función de la ubicación en la red neuronal (N(0,0) extremo inferior izquierdo y N(4,6) extremo superior derecho) y se definen en base a la influencia de los sistemas de alta y baja presión (columna 2: Tipo de Circulación). La descripción de los patrones de circulación se presenta en términos de las características principales de circulación atmosférica: la columna 3 en base a las anomalías de presión en superficie y la columna 4 a partir de las anomalías de la altura geopotencial a 500 hPa. En la parte inferior izquierda de la red

9. Patrones sinópticos en Europa occidental que caracterizan los meses de julio y agosto

emergen los patrones influenciados principalmente por la existencia de sistemas de alta presión en Europa, mientras que la ubicación de los sistemas de baja presión es la característica principal de la parte superior derecha. Esta disposición está de acuerdo con estudios anteriores (Cassano et al., 2006) y se puede atribuir a la característica inherente del método SOM a la auto-organización. Las neuronas emergen en un continuo y permiten la comprensión de las fases, así como la transición entre las neuronas.

Tabla 9.1. Tipos sinópticos de los meses de julio y agosto para el sector occidental del continente europeo.

ABREVIACIÓN	TIPO DE CIRCULACIÓN	DESCRIPCIÓN EMSLP	DESCRIPCIÓN 500 hPa
N(0,0)	Anticiclónico	Anomalías positivas de presión.	Anomalías positivas a las Islas Británicas.
N(0,1)	Anticiclónico	Anomalías positivas de presión.	Anomalías positivas al centro y al norte.
N(0,2)	Anticiclónico	Anomalías positivas de presión.	Anomalías positivas al norte del dominio analizado.
N(0,3)	Anticiclónico	Anomalías positivas de presión.	Anomalías positivas al norte del dominio analizado y negativas laxas al sur
N(0,4)	Dipolo noroeste (baja)/sudeste (alta)	Anomalías positivas que abarcan gran parte de la Europa occidental.	Anomalías positivas en el centro del dominio analizado.
N(0,5)	Dipolo norte (baja)/sur (alta)	El anticiclón de las Azores se extiende por el centro y sur de Europa.	Anomalías negativas al norte y positivas en el centro del dominio analizado.
N(0,6)	Dipolo norte (baja)/sur (alta)	El anticiclón de las Azores se extiende por la Europa occidental.	Anomalías negativas al nordeste y positivas en el sudoeste del dominio analizado.
N(1,0)	Anticiclón atlántico	Anomalías positivas al sudoeste del dominio analizado.	Anomalías positivas al oeste de las Islas Británicas y negativas al

Peña Rabadán, J.C. (2015). La reconstrucción de la dinámica fluvial y su conexión con la variabilidad climática a partir de fuentes documentales y registros instrumentales

ABREVIACIÓN	TIPO DE CIRCULACIÓN	DESCRIPCIÓN EMSLP	DESCRIPCIÓN 500 hPa
			nordeste del dominio.
N(1,1)	Anticiclónico	Anomalías positivas de presión.	Anomalías positivas al norte de Europa.
N(1,2)	Anticiclónico	Anomalías positivas de presión.	Anomalías positivas al norte del dominio analizado.
N(1,3)	Anticiclónico	Anomalías positivas de presión.	Anomalías positivas al norte del dominio analizado y negativas al oeste y al sur.
N(1,4)	Dipolo noroeste (baja)/sudeste (alta)	Anomalías positivas que abarcan gran parte de la Europa occidental.	Dipolo oeste (baja)/este (alta) en el norte del dominio analizado.
N(1,5)	Dipolo norte (baja)/sur (alta)	Anomalías positivas que abarcan gran parte de la Europa occidental.	Anomalías negativas al norte del dominio y positivas en el suroeste del continente europeo.
N(1,6)	Dipolo norte (baja)/sur (alta)	Anomalías positivas que abarcan gran parte de la Europa sudoccidental.	Anomalías negativas al norte del dominio y positivas en el suroeste del continente europeo.
N(2,0)	Anticiclón atlántico	Similar al anterior pero las anomalías positivas confinadas al extremo sudoeste.	Anomalías negativas al norte del dominio analizado y positivas al Atlántico.
N(2,1)	Anticiclón atlántico	Anomalías positivas al sudoeste del dominio analizado.	Anomalías positivas laxas en gran parte del dominio analizado.
N(2,2)	Anticiclónico	Anomalías positivas de presión.	Anomalías positivas al norte y negativas al sur del dominio

9. Patrones sinópticos en Europa occidental que caracterizan los meses de julio y agosto

ABREVIACIÓN	TIPO DE CIRCULACIÓN	DESCRIPCIÓN EMSLP	DESCRIPCIÓN 500 hPa
			analizado.
N(2,3)	Tripolo noroeste (baja)/centro (alta)/sudeste (baja)	Anomalías positivas que se extienden por gran parte de la Europa occidental.	Anomalías positivas confinadas al sector norte del dominio analizado.
N(2,4)	Tripolo noroeste (baja)/centro (alta)/sudeste (baja)	Anomalías positivas que se extienden por gran parte de la Europa occidental.	Tripolo noroeste (baja)/nordeste (alta)/sudeste (baja).
N(2,5)	Tripolo noroeste (baja)/centro (alta)/sudeste (baja)	Anomalías positivas que se extienden por gran parte de la Europa suroccidental.	Anomalías negativas al noroeste del dominio analizado.
N(2,6)	Tripolo noroeste (baja)/centro (alta)/sudeste (baja)	Anomalías positivas que se extienden por gran parte de la Europa suroccidental.	Anomalías negativas al noroeste del dominio analizado y positivas al sudoeste.
N(3,0)	Dipolo sudoeste (alta)/nordeste (baja)	Anomalías positivas al sudoeste y negativas que se hacen más evidentes al nordeste.	Anomalías negativas abarcando el norte de Europa.
N(3,1)	Dipolo sudoeste (alta)/nordeste (baja)	Similar a N(3,0) pero con anomalías más laxas.	Similar a N(3,0) pero con anomalías más laxas.
N(3,2)	Dipolo sudoeste (alta)/nordeste (baja)	Similar a N(3,1) pero la configuración más desdibujada.	Anomalías negativas al sur y positivas más laxas al norte.
N(3,3)	Baja a Islandia	Anomalías negativas laxas en Europa.	Anomalías negativas al extremo occidental del continente.
N(3,4)	Baja al norte y sudeste	Anomalías negativas al norte y sudeste siendo más laxas en el centro del dominio.	Anomalías negativas al extremo noroccidental del dominio analizado.
N(3,5)	Baja al norte y	Anomalías	Las anomalías

Peña Rabadán, J.C. (2015). La reconstrucción de la dinámica fluvial y su conexión con la variabilidad climática a partir de fuentes documentales y registros instrumentales

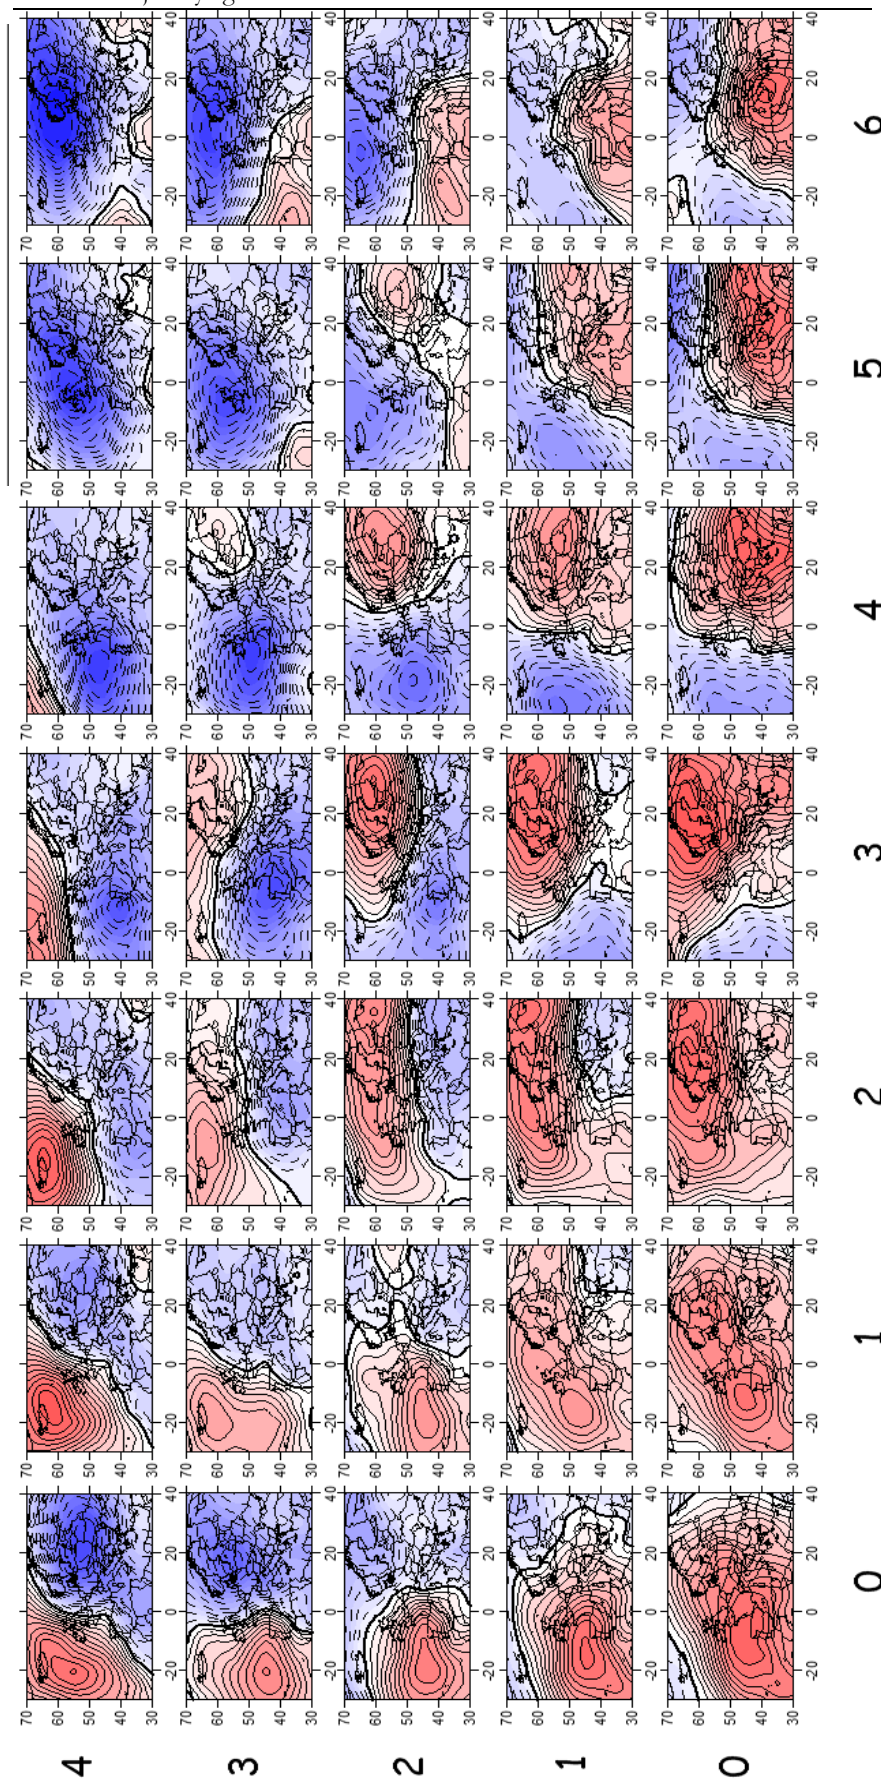
ABREVIACIÓN	TIPO DE CIRCULACIÓN	DESCRIPCIÓN EMSLP	DESCRIPCIÓN 500 hPa
	sudeste	negativas al norte y sudeste siendo más laxas en el centro del dominio.	negativas se van extendiendo por el norte del dominio analizado.
N(3,6)	Baja al norte y sudeste	Anomalías negativas al norte y sudeste siendo más laxas en el centro del dominio.	Las anomalías negativas se van extendiendo por el norte del dominio analizado.
N(4,0)	Dipolo oeste (alta)/ este (baja)	Anomalías positivas al este y negativas al oeste.	Anomalías negativas abarcando centro y norte de Europa.
N(4,1)	Dipolo oeste (alta)/ este (baja)	Similar a N(4,0) pero la configuración desplazada al este.	Similar a N(4,0) pero las anomalías negativas abarcan gran parte de Europa.
N(4,2)	Dipolo oeste (alta)/ este (baja)	Similar a N(4,1) pero la configuración desplazada al este.	Anomalías negativas en Europa.
N(4,3)	Bajas presiones al este de Europa	Anomalías negativas al este de Europa.	Anomalías negativas con una dirección sudoeste a nordeste en el dominio analizado.
N(4,4)	Baja al norte	Anomalías negativas a gran parte de Europa salvo el extremo sudoccidental.	Anomalías negativas al norte del dominio analizado.
N(4,5)	Baja al norte	Anomalías negativas a gran parte de Europa salvo el extremo sudoccidental.	Anomalías negativas al norte del dominio analizado en dirección suroeste a nordeste.
N(4,6)	Circulación zonal	Anomalías negativas al centro y norte del dominio y positivas al sur.	Disposición zonal de los centros de acción.

9. Patrones sinópticos en Europa occidental que caracterizan los meses de julio y agosto

Figura 9.4.

SOM 5 x 7 de las anomalías de presión reducida a nivel del mar para los meses de julio y agosto (sin unidades) a escala sinóptica en el dominio europeo.

Los colores azules son anomalías negativas de presión mientras que los rojos señalan anomalías positivas.



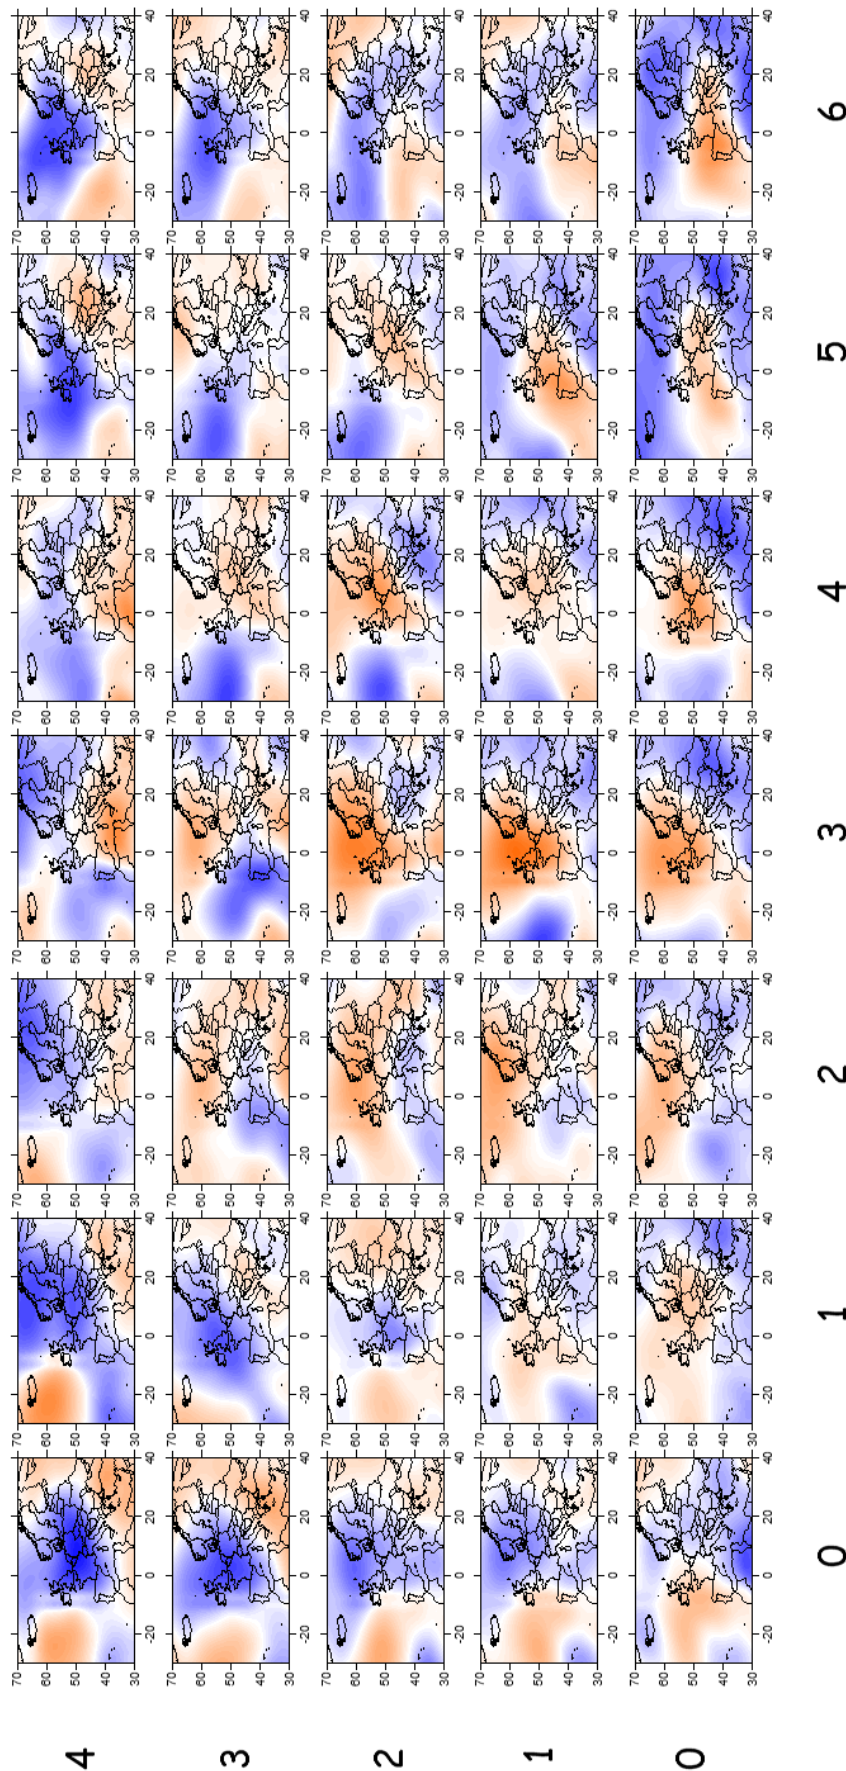


Figura 9.5.

SOM 5 x 7 de las anomalías de temperatura al nivel geopotencial de 850 hPa para los meses de julio y agosto (en °C) a escala sinóptica en el dominio europeo.

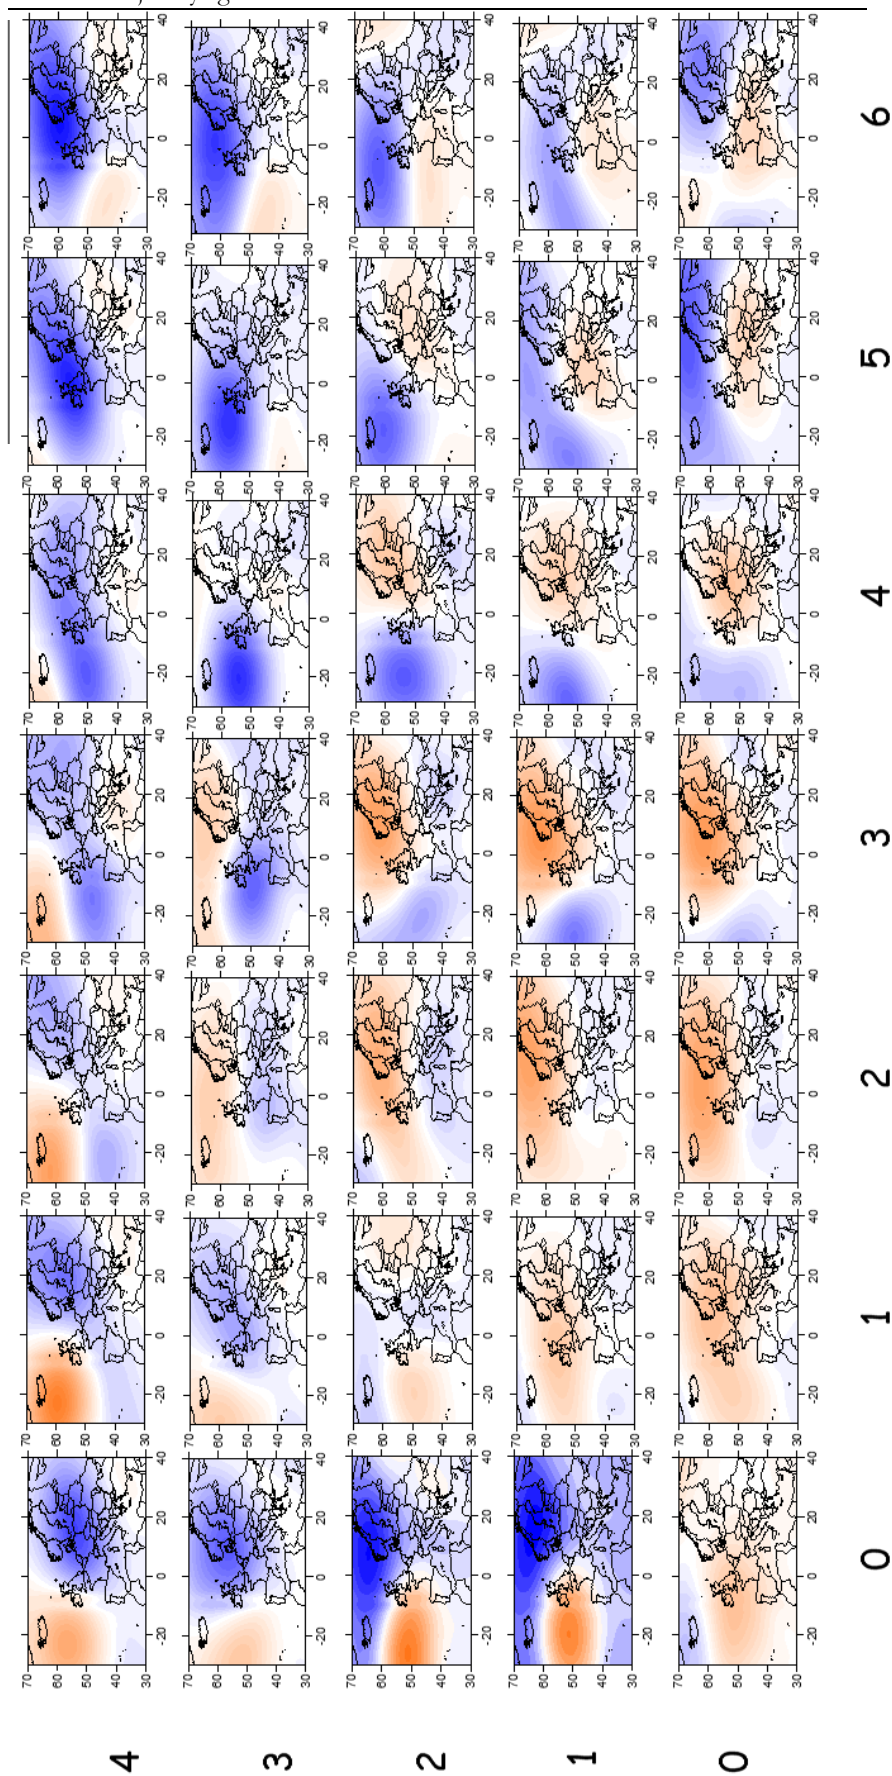
Los colores azules son anomalías negativas de temperatura mientras que los rojos son anomalías positivas.

9. Patrones sinópticos en Europa occidental que caracterizan los meses de julio y agosto

Figura 9.6.

SOM 5 x 7 de las anomalías de altura geopotencial a 500 hPa para los meses de julio y agosto (en gpm) a escala sinóptica en el dominio europeo.

Los colores azules señalan anomalías negativas de presión mientras que los rojos son anomalías positivas.



9.4.2. U-Matrix: patrones sinópticos generales

No se quiere acabar este capítulo sin mencionar otra de las potencialidades de la E-SOM. Se trata de la U-Matrix (matriz de distancias unificada) definida como la representación de la distancia euclídea entre las neuronas vecinas de un mapa auto-organizado, con la finalidad de una visualización fácil de un espacio vectorial de gran dimensión (Ultsch, 1999). La U-Matrix facilita la definición de una serie de patrones generales que aglutinan un número determinado de tipos sinópticos (o neuronas).

La figura 9.7 muestra la U-Matrix estandarizada (parte superior) y la representación tridimensional (3D) de las distancias euclídeas entre las neuronas (parte inferior). Se entiende como un mapa topográfico con sus crestas (valores positivos) y valles (valores negativos). Los puntos culminantes de la topografía se conciben como los centros de los clústeres (parecido a las semillas en el método k-means) a partir de los que se agrupan las neuronas. En la U-Matrix estandarizada se señalan estos puntos culminantes, en azul el fondo de los valles y en amarillo los puntos más elevados en relación a su entorno. La imagen 3D señala una topografía con una marcada meseta elevada en el centro con dirección meridional, una segunda cresta de menor identidad con una dirección latitudinal y cuatro valles en cada una de las esquinas, siendo más profundos en las dos esquinas de la parte superior de la imagen. En esta imagen 3D se han cartografiado las neuronas aglutinadoras: la $N(0,0)$, $N(0,6)$, $N(1,0)$, $N(1,3)$, $N(4,0)$, $N(4,3)$ y $N(4,6)$. De esta manera, tendremos siete grupos generales que agrupan a los 35 tipos sinópticos descritos en el apartado anterior.

Para conseguir la agrupación final, se han correlacionado, en base al coeficiente de correlación de Pearson, las siete neuronas con cada una de las 35 que forman la red neuronal. La matriz de correlación (tabla 9.1) subraya los coeficientes ganadores para cada neurona diferenciando entre el que es más significativo (color amarillo) y el que el coeficiente de correlación es 1 (color naranja) que corresponde a cada uno de las siete neuronas elegidas en la U-Matrix. La última columna (CLU) señala el clúster que tiene mejor coeficiente de correlación.

Figura 9.7.

Parte superior:

U-Matrix estandarizada. Se indican las neuronas escogidas para la clasificación. Colores azules indican fondo de los valles y los amarillos son los puntos culminantes de la topografía.

Parte inferior:

La Representación 3-D de la U-Matrix. Se señalan las neuronas escogidas para la clasificación.

U-Matrix estandarizada

4	-2,00	-1,10	-1,32	1,47	1,33	-0,15	-2,27
3	-1,17	-0,79	0,11	0,78	1,04	-0,24	-0,37
2	-0,94	-0,28	0,69	1,46	1,50	0,59	0,50
1	0,31	-0,52	0,42	1,65	0,98	0,60	-0,23
0	-1,10	-0,92	0,09	0,52	0,16	-0,03	-0,77
	0	1	2	3	4	5	6




Tabla 9.2.

Matriz de correlación entre las neuronas elegidas para la clasificación y las 35 neuronas que conforman la red neuronal.

En color aparecen las correlaciones significativas. El color naranja (coeficiente de correlación de Pearson igual a 1 indicando que se correlaciona la misma neurona) y el color amarillo (las neuronas con coeficiente de correlación de Pearson significativo en cada clúster). La última columna indica el clúster ganador.

NEURONA	CLUSTER 1	CLUSTER 2	CLUSTER 3	CLUSTER 4	CLUSTER 5	CLUSTER 6	CLUSTER 7	CLU
N(0,0)	1,000	0,214	0,880	-0,300	-0,084	-0,762	0,128	1
N(0,1)	0,851	-0,121	0,642	0,129	-0,184	-0,595	-0,285	1
N(0,2)	-0,149	-0,559	-0,375	0,886	-0,224	0,275	-0,901	4
N(0,3)	-0,397	-0,072	-0,717	0,910	-0,579	0,376	-0,674	4
N(0,4)	-0,084	0,670	-0,396	0,374	-0,815	-0,071	0,037	2
N(0,5)	0,174	0,929	0,010	-0,138	-0,574	-0,275	0,449	2
N(0,6)	0,214	1,000	0,101	-0,291	-0,381	-0,261	0,525	2
N(1,0)	0,880	0,101	1,000	-0,615	0,317	-0,673	0,328	3
N(1,1)	0,559	-0,511	0,541	0,184	0,232	-0,240	-0,498	1
N(1,2)	-0,071	-0,740	-0,173	0,706	0,034	0,198	-0,830	4
N(1,3)	-0,300	-0,291	-0,615	1,000	-0,535	0,332	-0,824	4
N(1,4)	-0,121	0,344	-0,506	0,687	-0,934	-0,056	-0,248	4
N(1,5)	0,142	0,836	-0,125	0,102	-0,790	-0,310	0,318	2
N(1,6)	0,422	0,800	0,297	-0,310	-0,391	-0,543	0,549	2
N(2,0)	0,678	-0,012	0,931	-0,741	0,472	-0,576	0,461	3
N(2,1)	0,633	-0,327	0,850	-0,454	0,489	-0,457	0,118	3
N(2,2)	-0,127	-0,816	-0,191	0,670	0,070	0,256	-0,835	4
N(2,3)	-0,390	-0,515	-0,634	0,931	-0,422	0,380	-0,820	4
N(2,4)	-0,376	-0,007	-0,708	0,783	-0,824	0,129	-0,393	4
N(2,5)	0,193	0,373	-0,018	0,017	-0,770	-0,555	0,392	7
N(2,6)	0,579	0,363	0,570	-0,541	-0,171	-0,831	0,678	7
N(3,0)	0,258	-0,225	0,661	-0,784	0,818	-0,192	0,450	5
N(3,1)	-0,032	-0,375	0,362	-0,541	0,950	0,252	0,117	5
N(3,2)	-0,363	-0,773	-0,203	0,269	0,573	0,666	-0,624	6
N(3,3)	-0,741	-0,582	-0,806	0,685	-0,082	0,739	-0,641	6
N(3,4)	-0,553	-0,051	-0,751	0,491	-0,540	0,320	-0,152	4
N(3,5)	-0,046	0,261	-0,081	-0,289	-0,366	-0,355	0,629	7
N(3,6)	0,460	0,382	0,577	-0,753	0,001	-0,716	0,877	7
N(4,0)	-0,084	-0,381	0,317	-0,535	1,000	0,265	0,111	5
N(4,1)	-0,199	-0,295	0,162	-0,395	0,948	0,481	-0,021	5
N(4,2)	-0,475	-0,334	-0,228	-0,002	0,692	0,826	-0,332	6
N(4,3)	-0,762	-0,261	-0,673	0,332	0,265	1,000	-0,422	6
N(4,4)	-0,812	0,103	-0,828	0,248	-0,137	0,762	-0,039	6
N(4,5)	-0,297	0,497	-0,190	-0,501	-0,105	-0,014	0,807	7
N(4,6)	0,128	0,525	0,328	-0,824	0,111	-0,422	1,000	7

Las 35 neuronas quedan clasificadas en 7 grupos (parte superior figura 9.8) que contienen entre 3 neuronas (Clústeres C1 y C3) y 9 neuronas (C4).

Cluster SOM

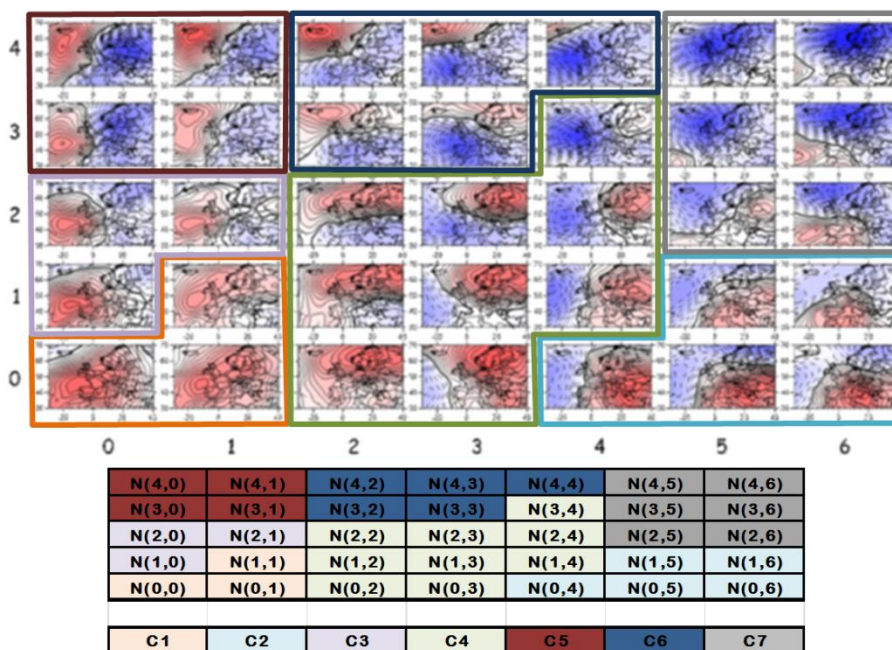


Figura 9.8.

Parte superior: SOM 5x7 de EMSLP para el dominio europeo. Los clústeres de neuronas están indicados por los polígonos de diferentes colores.

Parte inferior: Matriz neuronal donde aparecen los distintos clústeres de neuronas.

Se han contruido las composiciones de cada uno de los clústeres a partir de las neuronas implicadas con el objetivo de definir las características principales de cada uno de ellos. Se presentan a continuación (figuras 9.9 a 9.15) en base al mapa de EMSLP (en la parte izquierda de la figura: sin unidades, variando entre -1, anomalías negativas en azul, y +1, anomalías positivas en rojo), las anomalías de altura geopotencial de 500 hPa (en la parte central de la figura: en metros geopotenciales, entre -140, anomalías negativas en azul y +140, anomalías positivas en naranja) y las anomalías estandarizadas de precipitación media diaria (en la parte derecha de la figura: sin unidades, entre -0,5, anomalías negativas en azul, y +0,5, anomalías positivas en naranja). Se ha escogido la precipitación¹ (en menoscabo de otras variables meteorológicas) por la incidencia que tiene en la generación de las avenidas e inundaciones.

¹ Se ha utilizado la rejilla de anomalías de precipitación procedentes de: http://eca.knmi.nl/download/ensembles/data/Version10.0/Grid_0.50deg_reg/

El patrón general número 1 (Bloqueo Anticiclónico, figura 9.9) implicaría las neuronas ubicadas en el extremo inferior izquierdo de la red neuronal [$N(0,0)$, $N(0,1)$ y $N(1,1)$]. Se caracterizaría por un bloqueo anticiclónico afectando toda Europa provocando estabilidad atmosférica con anomalías positivas de precipitación en gran parte del dominio analizado. Destacar las anomalías negativas de precipitación que se observan en el interior de la Península Ibérica, posiblemente debidas a las tormentas que se producen fruto de la baja térmica que aparece por calor durante el verano favoreciendo la convección en esta zona.




Figura 9.9. Bloqueo anticiclónico

El patrón general número 2 (Bloqueo Anticiclónico Mediterráneo, figura 9.10) implica a las neuronas ubicadas en el extremo inferior derecho de la red neuronal [$N(0,4)$, $N(0,5)$, $N(0,6)$, $N(1,5)$, $N(1,6)$]. Se caracteriza por un bloqueo anticiclónico en el arco mediterráneo obligando a las bajas presiones a dirigirse hacia el norte del continente. Las anomalías positivas de precipitación dominan gran parte de Europa, a excepción de la Península Ibérica donde las anomalías están dentro de la normalidad (probablemente fruto de la convección provocada por la baja térmica) y el extremo más occidental del dominio analizado donde dominan las anomalías negativas. Destacar el dipolo pluviométrico que se observa en la península escandinava como consecuencia de la trayectoria de las bajas presiones dejando lluvia a la costa occidental y anomalías positivas a la parte oriental, una vez que el flujo ha pasado la cordillera litoral escandinava.




Figura 9.10. Bloqueo anticiclónico mediterráneo

El patrón general número 3 (Anticiclón Atlántico, figura 9.11) implica a las neuronas ubicadas en el extremo central izquierdo de la red neuronal [$N(1,0)$, $N(2,0)$, $N(2,1)$]. Se caracteriza por el anticiclón Atlántico desplazado al norte de su ubicación habitual (islas de las Azores) provocando un bloqueo de las perturbaciones de procedencia atlántica en la zona más occidental del continente europeo. Estas se ven obligadas a trazar trayectorias hacia altitudes más altas y descender hacia la Europa oriental, tal como indican las anomalías de precipitación negativas en el extremo norte y este del continente.




Figura 9.11. Anticiclón Atlántico

El patrón general número 4 (Oscilación de Verano del Atlántico Norte, figura 9.12) implica a las neuronas de la zona central de la red neuronal [$N(0,2)$, $N(0,3)$, $N(1,2)$, $N(1,3)$, $N(1,4)$, $N(2,2)$, $N(2,3)$, $N(2,4)$, $N(3,4)$], ocupando la parte más elevada de la topografía definida por la U-Matrix (ver figura 9.7). Con un total de 9, es el patrón con mayor número de neuronas. Este elevado número de neuronas (casi un tercio de la red neuronal) está justificado porque se corresponde con el principal modo de variabilidad atmosférica de baja frecuencia para los meses de julio y agosto: la Oscilación de Verano del Atlántico Norte (ver capítulo 8). Se caracteriza por un bloqueo anticiclónico al norte del continente europeo y bajas presiones muy laxas al sur del dominio analizado. La distribución de las anomalías de precipitación muestra valores negativos en todo el arco mediterráneo y positivas al norte de Europa.






Figura 9.12. Oscilación de Verano del Atlántico Norte


El patrón general número 5 (Dipolo Oeste/Este, figura 9.13) implica a las cuatro neuronas del extremo superior izquierdo de la red neuronal [N(3,0), N(3,1), N(4,0), N(4,1)]. Se caracteriza por un dipolo definido por un centro de altas presiones sobre el Atlántico Este con dirección meridiana y un centro de bajas presiones ocupando gran parte de la mitad oriental del dominio analizado. Las anomalías negativas de precipitación afectan el cuadrante nororiental de Europa, quedando al margen (anomalías positivas) el extremo occidental. Las precipitaciones están relacionadas con el paso de sistemas frontales procedentes de altas latitudes con una dirección norte-sur. Remarcar el dipolo pluviométrico provocado por la cordillera escandinava con anomalías significativamente negativas de precipitación a gran parte de la península y, en cambio, positivas a toda la franja litoral noruega.



El patrón general número 6 (Baja Atlántica, figura 9.14) implica a las cinco neuronas ubicadas en la parte superior central de la red neuronal [N(3,2), N(3,3), N(4,2), N(4,3), N(4,4)]. Se caracteriza por una baja ubicada sobre el Atlántico oriental entre las Islas Británicas y la Península Ibérica. Las anomalías de precipitación negativas se distribuyen por la parte atlántica del continente europeo, exceptuando Escandinavia e Islandia, dada la posición del área de bajas presiones. Destacar el dipolo pluviométrico que provoca esta configuración en la Península Ibérica diferenciando la parte atlántica (anomalías negativas) de la mediterránea (anomalías positivas). La precipitación se relaciona al paso de sistemas frontales a una latitud entre 40° y 60°N.



El patrón general número 7 (Circulación Zonal, figura 9.15) implica a las seis neuronas ubicadas en el extremo superior derecho de la red neuronal [N(2,5), N(2,6), N(3,5), N(3,6), N(4,5), N(4,6)]. Se caracteriza por una disposición zonal de los centros de acción, siendo la configuración típica de la Oscilación del Atlántico Norte (NAO), pero desplazada ligeramente hacia el este. Las anomalías negativas de precipitación se distribuyen por el cuadrante noroccidental del continente europeo quedando al margen (anomalías positivas) todo el arco mediterráneo. Las precipitaciones están en relación a frentes de dirección oeste a este a una latitud superior a 50° N.



9.5. Consideraciones finales

La climatología sinóptica es una sub-disciplina climática con un rico patrimonio metodológico con el objetivo de describir y explicar los sistemas meteorológicos. Los enfoques clásicos, como el análisis de los componentes principales y agrupación de datos (ej. k-means), permiten generalizaciones del sistema climático, pero quedan ocultos muchos de los detalles precisamente por el grado de generalización. La red neuronal de tipo artificial creada a partir de los mapas auto-organizados (SOM) ofrece un enfoque alternativo a la climatología sinóptica, proporcionando una herramienta de visualización de la compleja distribución de estados sinópticos tratando a los datos como un continuo. La SOM se propone como una alternativa a los métodos de clasificación sinóptica clásicos. Uno de los obstáculos de la aplicación de los mapas auto-organizados, especialmente para los nuevos usuarios, es la previa elección de parámetros de ajuste del modelo, causa por la que usuarios potenciales pueden refutar el uso de esta metodología. En [Liu et al. \(2006\)](#) aparecen toda una serie de recomendaciones sobre la forma de ajustar la SOM para el mapeo preciso de los patrones meteorológicos. Por otra parte, [Cassano et al. \(2006\)](#) utilizaron

diferentes ajustes paramétricos del modelo encontrando que los resultados obtenidos eran insensibles a los cambios en los parámetros del algoritmo SOM.

La E-SOM, mapas auto-organizados de gran dimensión del que emergen las transiciones entre neuronas, se ha utilizado para crear una red neuronal artificial que contenga los principales patrones sinópticos de circulación atmosférica en la Europa occidental para los meses de julio y agosto. El análisis ha empleado los datos diarios de presión a nivel del mar estandarizada (EMSLP) para el periodo 1871-2010. Un total de 35 patrones sinópticos han sido definidos y ha resultado ser una herramienta útil para el diagnóstico sinóptico de la circulación atmosférica para la segunda mitad del s. XX y principios de s. XXI.

La siguiente fase de la tesis es relacionar la clasificación sinóptica a alguna variable dependiente, por lo general a un clima a escala local o parámetro ambiental. A partir de una metodología integrada, en el capítulo 10 se va a relacionar los patrones sinópticos de los meses de julio y agosto con el índice estival de daños por inundaciones (INU, ver Capítulo 5) y los modos de variabilidad atmosférica de baja frecuencia (ver Capítulo 8). Además, la metodología integrada permite articular la variabilidad de los patrones de circulación atmosférica (de alta y de baja frecuencia) con los patrones espaciales de INU. Recordar que estos últimos han sido definidos a partir del número de inundaciones acumuladas para cada década y región hidro-climática (ver Capítulo 5). Por último, se analiza la distribución y la variabilidad de las anomalías de precipitación en Suiza en base a los resultados conseguidos. La finalidad es identificar cambios en los patrones hidro-climáticos que definen los cuatro grupos con una alta frecuencia de inundación reconocidos para Suiza (ver capítulo 5), en función de los cambios medio-ambientales, especialmente, el calentamiento actual.

