

# Organización y caracterización de patrones de variabilidad de la precipitación global por medio de mapas auto organizados esféricos multicapa de redes neuronales

Darío Alberto Huggenberger

Universidad Tecnológica Nacional-Facultad Regional Delta

## Abstract

*Se aborda el problema de la variabilidad en la precipitación. Se propone el uso de mapas autoorganizados de redes neuronales de Kohonen para la organización, tipificación y clasificación de señales. Para evitar los problemas de borde en las redes planas rectangulares, inconsistentes con la topografía casi esférica de la Tierra, se configuró un mapa de red con neuronas distribuidas en la superficie de una esfera. Con el objetivo de sintetizar y organizar las señales en orden de complejidad y detalle se configuró una red en cuatro capas esféricas con progresiva reducción del número de neuronas. Se utilizó una técnica de compresión de señales entrenando la red por recirculación. Se pretende simular características de los procesos de percepción y abstracción.*

*En el trabajo se describe la metodología, algoritmos y criterios empleados en la configuración y operación de la red sobre señales climáticas. Se presenta, a modo de ejemplo, su aplicación a la organización de señales de precipitación global. Se muestra cómo las síntesis elaboradas en las distintas capas de la red son representativas de señales individuales con diferente nivel de complejidad y detalle en función de la capa de la cual se extrae la señal abstraída por la red.*

## Palabras clave

Redes neuronales, mapas auto organizados, variabilidad en la precipitación.

## Introducción

El problema de la clasificación, caracterización y organización de patrones de señales climáticas es de los más analizados y de más amplia variedad de tratamiento en las ciencias de la Tierra. Se abordará el problema desde la perspectiva de las redes neuronales, es decir, desde un intento de simular la operación del sistema nervioso, en particular el de la corteza del cerebro humano. En el presente trabajo nos concentraremos en una variante de la aplicación de redes no supervisadas o

mapas auto organizados, conocidos como “mapas de Kohonen” [1].

Desde los años 80 el uso de redes neuronales se fue ampliando hasta alcanzar el dominio de las ciencias de la atmósfera [2]. En general las aplicaciones de redes neuronales basadas en mapas auto organizados de Kohonen se centran en el objetivo de la clasificación de patrones sinópticos [3], zonificación climática [4], en el que se combina la aplicación de mapas auto organizados con componentes principales, o clasificación de patrones de variables hidrológicas [5]. Los mapas auto organizados se han aplicado también en la clasificación de situaciones sinópticas en condiciones de potencial cambio climático [6]. También se han aplicado a la clasificación de patrones de circulación sobre la base de datos de viento en altura [7], a la clasificación de imágenes de satélite [8], clasificación de distribuciones de precipitación [9] o de situaciones propicias para el desarrollo de heladas [10].

Las redes de Kohonen se ofrecen como una herramienta útil para clasificar, caracterizar pero esencialmente organizar patrones de señales. Simulan el proceso de especialización de una red neuronal a partir de un estado neutro por medio de la presentación de ejemplos a la red y configuran patrones de pesos sinápticos progresivamente adaptados a los ejemplos presentados. Se ha observado que los llamados “mapas auto organizados de Kohonen” pueden implementar características de la sensación, percepción y abstracción [11].

## Metodología

Entre las funciones del sistema nervioso se encuentran la sensación, la percepción y la abstracción como respuestas a los estímulos. En lo que sigue se entenderá por “estímulo” la señal expresada como una serie temporal. La “sensación” será la actividad resultante del estímulo sobre neuronas de la primera capa de la red expresado como la integración de la serie temporal en un único valor numérico. La “percepción” consistirá en el patrón de respuesta de la red a la sensación en términos de una replicación de la secuencia de valores numéricos. El entrenamiento permitirá que se maximice la similitud de esta secuencia replicada con la señal de entrada o estímulo. La “abstracción”, en cambio, se relacionará con el patrón de actividad remanente de las neuronas de la red que permitirá reconstruir una imagen interna estable y representativa de los estímulos, lo que se expresará en la secuencia de pesos sinápticos que elaborarán la respuesta de la red. Las relaciones de vecindad establecerán una organización interna de las abstracciones sintetizadas por la red a la vez que permitirá hacer una clasificación cuando los patrones tipificados se proyecten sobre la base de datos original.

Uno de los problemas de las redes bidimensionales planas radica en los condicionamientos de borde que impone un plano con límites laterales. Este problema se manifiesta de manera más intensa si se procura simular una geometría como la de la superficie de la Tierra. Este efecto de borde se procura resolver por medio de una red bidimensional de neuronas equidistantes en términos angulares en la superficie de una esfera de radio unitario. Algunas redes esféricas se han desarrollado en los últimos años como mapas autoorganizados (Self Organizing Maps SOM) en formatos 3DSOM [12], HSOM [13] en un complejo formato helicoidal, GeoSOM orientados al uso de la tierra [14][15][16][17] en los que se ha planteado el problema de la visualización

de los clusters [18] y SSOM [19][20][21] incluyendo múltiples esferas [22].

En nuestro modelo, desarrollado completamente en código propio, las ubicaciones se definen por medio de vectores de módulo unitario que identifican la localización de las neuronas en la red. La configuración de esta red de neuronas equidistantes se confecciona por medio de la siembra aleatoria de puntos en la superficie de una esfera a los que se asignó fuerzas eléctricas repulsivas simuladas numéricamente a modo de cargas positivas distribuidas sobre una esfera de metal. Permitido el movimiento libre de estos puntos-carga, se deja que las neuronas se distribuyan de manera que el campo eléctrico interno de la esfera sea nulo y los puntos-carga adquieran posiciones de equilibrio estable. Las neuronas de la red se ubican finalmente en las coordenadas angulares estables de los puntos-carga y se identifica su posición por los ángulos cenital y azimutal en la red.

Otro de los aspectos singulares del método propuesto es aplicar recirculación al entrenamiento de la red [23]. Este procedimiento consiste en interconectar las neuronas visibles por medio de pesos sinápticos diferentes dirigidos desde las neuronas visibles o sensibles hacia las ocultas y desde las neuronas ocultas o internas a las visibles. La información recibida sobre las neuronas visibles o estímulo es sintetizada por cada una de las neuronas ocultas a modo de sensación integrada en un único parámetro. Un patrón de pesos sinápticos inversos, es decir de las neuronas ocultas dirigidos a las visibles, devuelve un conjunto de imágenes a modo de percepciones o respuestas primarias a la sensación original generadas a partir del parámetro escalar sensación y de los pesos sinápticos de las neuronas. Entre todas las respuestas o percepciones primarias, se selecciona aquella con máxima similitud a la señal original o estímulo. Los mismos pesos sinápticos directos generan una nueva síntesis interna escalar como reflexión de la percepción

primaria seleccionada sobre la neurona interna que la generó. El procedimiento de recirculación consiste en modificar los pesos directos e inversos de manera que los parámetros que definen la imagen interna de la sensación directa y de la percepción reflejada converjan a un mismo valor, a la vez que la percepción primaria se aproxime progresivamente a la señal presentada como estímulo externo. En la medida que el proceso de iteración evoluciona, la percepción primaria se estabiliza constituyéndose en percepción definitiva, o simplemente percepción, y el patrón de pesos sinápticos configura una abstracción estable a la que se puede recurrir en dos sentidos: como patrón de referencia para futuras percepciones y como estímulo para entrenar capas más internas de la red evocando en ausencia el patrón original que configuró el estímulo. En el método original de Hinton la red interna es de menor dimensión que la externa, pero no de una única neurona, por lo tanto lo que se obtiene es una compresión de la información de entrada en un esquema de memoria distribuida. La memoria distribuida permite que la información original no se pierda de manera total si se altera la información contenida en una de las neuronas, pero también dificulta la interpretación de los patrones de pesos sinápticos o abstracciones almacenadas en la red. Al utilizar una única neurona como síntesis interna, se pierde el beneficio de la distribución llevando en cambio la compresión al límite y posibilitando que el patrón de pesos sinápticos almacenado en esa única neurona pueda ser interpretado como una síntesis de los ejemplos presentados a la red.

El siguiente esquema sintetiza el procesamiento de la señal por cada neurona de la red propuesta. Un señal o estímulo (datos) proviene de un ambiente en el que está inmersa la red. Esos estímulos se expresan por medio de un vector (**X0**, notados los vectores en negrita). Un conjunto de pesos directos

(**Wd**) pondera y conduce el estímulo desde la neurona visible o sensible que lo recibe hacia una neurona interna. En ella la sensación (Y1) se obtiene como producto escalar

$$Y1 = \mathbf{Wd} \cdot \mathbf{X0}$$

entre la señal o estímulo y los pesos directos. A partir de los pesos inversos (**Wi**), dirigidos desde la misma neurona interna hacia la visible, se elabora la percepción (**X2**)

$$\mathbf{X2} = Y1 \mathbf{Wi}$$

como producto de un vector por un escalar. La reflexión hacia la capa visible se interpreta como si esta respuesta primaria formase parte del ambiente, es decir que a partir del producto escalar con los mismos pesos sinápticos directos se configura una segunda síntesis interna (Y3)

$$Y3 = \mathbf{Wd} \cdot \mathbf{X2}$$

Los coeficientes Y1 y Y3 minimizan su diferencia asimilándose la sensación directa o primaria (Y1) a la sensación perceptiva o secundaria (Y3) conjuntamente con la convergencia de la percepción primaria (**X2**) hacia el estímulo (**X0**).

$$\begin{aligned} \text{Estímulo } \mathbf{X0} &\rightarrow \mathbf{Wd} \rightarrow \text{Sensación } Y1 = \mathbf{Wd} \cdot \mathbf{X0} \\ \text{Percepción } \mathbf{X2} &= Y1 \mathbf{Wi} \leftarrow \mathbf{Wi} \\ \mathbf{Wd} &\rightarrow \text{Imagen perceptiva } Y3 = \mathbf{Wd} \cdot \mathbf{X2} \end{aligned}$$

Así a la presentación de sucesivos patrones a la red a modo de estímulos, diferentes en aspectos singulares pero con elementos similares que los hacen de algún modo generalizables, la red responde internamente con síntesis de los estímulos en términos de sensaciones y reflexiones en la capa interna a modo de percepciones, tanto más realistas cuanto más se asimilen al estímulo a la vez que la sensación directa o síntesis del estímulo sobre las neuronas internas converge con la síntesis

de la percepción primaria sobre la misma neurona interna. Simultáneamente se configura la abstracción como patrón estable de pesos sinápticos sobre la base de la cual se elaboran las percepciones a los distintos estímulos.

Percepción ( $X_2$ )  $\rightarrow$  Estímulo ( $X_0$ )  
Sensación ( $Y_1$ )  $\leftrightarrow$  Imagen perceptiva ( $Y_3$ )

De este modo la percepción ( $X_2$ ) se elabora progresivamente como una respuesta de la red al estímulo ( $X_0$ ), que a la vez conserva la form del patrón de pesos inversos ( $W_i$ ) que se interpretará como abstracción, del cual el estímulo sólo difiere en un factor de escala en tanto al final del entrenamiento  $Y_1=Y_3$  y se interpretará como un estímulo típico o representativo el resultante de  $X_2=Y_1W_i$ . Es decir que la actividad neuronal impuesta por el estímulo resulta análoga y vinculada a través de la percepción a la actividad interna de la red. En cierta medida la percepción establece un isomorfismo entre la respuesta al ambiente y la abstracción interna en términos de actividad neuronal.

La estructura de la percepción se encuentra así caracterizada por los patrones vectoriales de pesos sinápticos inversos ( $W_i$ ), que devuelven la sensación ( $Y_1$  directa,  $Y_3$  perceptiva) como asimilación en el sentido de similitud al estímulo recibido en la capa de entrada a la red al reconstruir la señal original a partir de un único parámetro escalar.

Entre todas las percepciones de la red, el entrenamiento de Kohonen selecciona la que presenta un máximo de similitud en la respuesta. Luego especializa algunas neuronas, ubicadas en un entorno de aquella que responde con mayor similitud al patrón de entrada, delimitado por una función de vecindad. En consecuencia los pesos sinápticos inversos adquieren la forma típica de la señal de entrada, es decir, no los aspectos singulares de cada señal, sino los aspectos más generales y relevantes que la caracterizan. Por lo tanto

los patrones de pesos inversos ( $W_i$ ) contienen una representación abstracta de la señal de origen, donde el término "abstracción" se utiliza en el sentido no de representar una señal en especial sino los aspectos típicos, generales y relevantes para su reconocimiento y organización, que además persisten como una característica adquirida de la red al entrenamiento. De esta manera la red configura una abstracción como resultante del proceso mismo de percepción. En otras palabras, la percepción opera como un mecanismo primario de abstracción.

Al finalizar el entrenamiento se presenta nuevamente los estímulos a la red. Aplicando la misma definición de distancia entre los patrones individuales de información o estímulos y las percepciones elaboradas a partir de las abstracción, se identifica entre las respuestas perceptivas la más parecida a cada estímulo. De este modo el estímulo resulta vinculado a la neurona que lo representa y se obtiene una clasificación de las señales de entrada a través de las percepciones resultantes de la red en términos de los patrones de pesos sinápticos de la capa interna. Estos patrones de pesos inversos son residentes a modo de abstracciones y resultan organizados por vecindad.

Una de las ventajas adicionales de la red es la robustez en el sentido de no depender sensiblemente de las funciones de ajuste iterativo que definen el ritmo de entrenamiento y el radio de vecindad. Se ha probado distintas funciones de vecindad y velocidades de aprendizaje pero no se ha obtenido diferencias apreciables ni relevantes en las conclusiones entre las distintas pruebas. Las características de las funciones de velocidad y vecindad han sido, en todos los casos probados, de carácter monótono decreciente.

Entre las desventajas de la metodología, y quizá la principal, está la fuerte dependencia de la inicialización aleatoria de las neuronas en la red, de los patrones de pesos sinápticos y de la selección al azar de ejemplos. Estos procesos están

condicionados por el sistema de cómputo, de allí que el uso de distintos procesadores y aún de diferentes inicializaciones con un mismo sistema pueda conducir a resultados numéricamente diferentes, pero estas diferencias se expresan en las neuronas de la red representativas de cada patrón de señales, no del patrón mismo, de la clasificación ni de la organización. De allí que los procesos que involucran inicializaciones al azar, si se realizan utilizando el mismo sistema de cómputo, facilita el análisis haciendo referencia siempre a las mismas neuronas. En cualquier repetición del experimento en otro procesador estos números y la distribución en la red pueden variar, pero no serán alteradas en forma significativa la caracterización, clasificación y organización de patrones.

Otra característica de la red propuesta es estar conformada por cuatro capas esféricas. La capa externa de neuronas sensibles transfiere los estímulos (series temporales originales escaladas  $X_0$ ) como sensación a la primera capa de neuronas. Esta capa externa se configura sobre la base de  $N_0=18142$  puntos de grilla sobre la superficie de la Tierra y los estímulos se expresan como series temporales correspondientes a cada uno de esos puntos de grilla. La primera capa interna se conforma sobre 256 neuronas dispuestas sobre una red esférica. Se ha observado que algunas de las neuronas de la primera capa son representativas de muy pocos puntos de grilla sobre el Globo, por lo que se asume que el número de grados de libertad es menor que el número de neuronas en la primera capa de la red.

La segunda capa de la red contiene 64 neuronas y se conecta con las 256 neuronas de la primera capa. Las percepciones generadas por los pesos inversos asociados a las neuronas de la primera capa permiten reconstruir las señales a modo de una abstracción primaria  $X_2$ . Estas abstracciones de la primera capa interna se presentan como ejemplos a la segunda capa de 64 neuronas configurándose, por

medio del mismo procedimiento aplicado a las series temporales de entrada a la primera capa, un mapa de red que contiene abstracciones más profundas y generales. De la misma manera se configura y entrena una tercera capa de 16 neuronas, que recibe ejemplos generados en la segunda capa de 64 neuronas. Finalmente una cuarta capa de cuatro neuronas recibe como estímulos los ejemplos configurados sobre las 16 neuronas de la tercera capa de modo que la cuarta capa contiene las abstracciones más generales. Los procedimientos de entrenamiento de las capas interiores operan a modo de organización de las abstracciones elaboradas en las capas exteriores de la red.

En la aplicación que se presenta a modo de ejemplo de operación, sobre la base de una esfera con  $N_1$  (256) neuronas en la primera capa se efectúan  $500 \cdot N_1$  lecturas de series seleccionadas en forma aleatoria a partir de una base de datos. El primer proceso de recirculación se elabora a partir del producto escalar entre un vector  $j$  de entrada  $X_0(j)$  (estímulo), seleccionado entre las  $N_0$  (18142) series temporales o señales, y un vector aleatorio de pesos directos (de la entrada a la neurona  $i$ -ésima de la red)  $Wd(i)$  diferente para cada neurona  $i$  (256) de la capa. Se genera así un campo escalar

$$Y_1(i) = Wd(i) \cdot X_0(j) \quad (\text{sensación directa})$$

sobre las neuronas de la red que es transformado por medio de una tangente hiperbólica en el intervalo  $(-1, 1)$ . Para cada  $i$ -ésima neurona la sensación directa  $Y_1$  genera patrones  $X_2(i)$  por medio de un vector de pesos inversos para cada neurona  $Wi(i)$  a partir del producto

$$X_2(i) = Y_1(i) \cdot Wi(i) \quad (\text{percepción}).$$

La percepción genera una segunda imagen interna

$$Y_3(i) = Wd(i) \cdot X_2(i) \quad (\text{sensación perceptiva})$$

a través de los pesos sinápticos directos  $Wd(i)$ . Se comparan, en términos de una norma euclidiana, los vectores  $X0(i)$  con  $X2(i)$  (estímulo con percepción) seleccionando entre las  $N1$  neuronas la  $i^*$  cuya percepción se ajusta mejor al estímulo recibido (distancia mínima). Simultáneamente se compara la sensación directa con la sensación percibida ( $Y1(i^*)$  con  $Y3(i^*)$ ) y modifican los pesos sinápticos  $Wd(i^*)$  y  $Wi(i^*)$  de manera tal que de forma iterativa la percepción se aproxime al estímulo y simultáneamente la sensación directa y la perceptiva converjan.

Entre todas las percepciones se selecciona la que más se aproxima al estímulo ( $i^*$ ). La actualización o ajuste iterativo no se limita a la “neurona ganadora”  $i^*$  sino que se desarrolla en un entorno considerando el ángulo entre la neurona seleccionada y las próximas, y teniendo también en cuenta el número de iteraciones desarrolladas hasta el momento. El entorno se define a partir de un ángulo inicial de valor  $\pi$  en radianes, lo cual abarca toda la esfera en la primera actualización y luego disminuye en forma lineal con el número de iteraciones ( $h$ ) hasta un ángulo de 0.01 radianes, lo que delimita una única neurona al cabo de  $Nit$  iteraciones, cuyos pesos sinápticos serán actualizados.

$$\varphi_r(h) = \pi + (0.01 - \pi) * h / Nit$$

Dentro de este entorno de radio  $\varphi_r$ , donde en esta topografía el coeficiente  $\varphi_r$  expresa una distancia angular, se actualizan los pesos sinápticos de las neuronas que se encuentran a una distancia angular  $\varphi < \varphi_r$  de la neurona  $i^*$  seleccionada. Se define como ritmo de entrenamiento en función del ángulo al factor

$$R(\varphi, h) = 1 / (1 + \varphi / \varphi_r)^3,$$

de manera tal que el ritmo de aprendizaje vale 1 en el centro del sector, es decir para la neurona seleccionada, y 1/8 en la periferia, siendo nulo fuera del radio de

actualización. Por otra parte el ritmo de entrenamiento decrece con el número de iteraciones. Se adopta como 0.2 la velocidad de entrenamiento inicial y 0.01 el ritmo de aprendizaje final asignando una pendiente lineal dada por el número de iteraciones.

$$\alpha(h) = 0.2 + (0.01 - 0.2) * h / Nit$$

Las señales son series temporales ( $T$  pesos sinápticos con subíndice  $t$  para cada tiempo en la serie) ubicadas sobre una grilla en la superficie de la Tierra con  $N0$  entradas (con subíndice  $j$ ). El peso directo aplicado a las series temporales desde la entrada  $j$  a la neurona interna  $i$  se actualiza de acuerdo con la ecuación

$$Wdijth = Wdijth-1 + \alpha(h)R(\varphi, h)X2ijt(Y1ij - Y3ij).$$

En esta ecuación iterativa  $Wdijth$  es el peso sináptico directo (de la capa externa a la interna) de la neurona interna  $i$  correspondiente a la entrada o señal  $j$  en el tiempo  $t$  y en la presentación del ejemplo o paso iterativo  $h$ . Tiene el mismo significado el coeficiente  $Wdijth-1$  pero correspondiendo al paso iterativo anterior.  $R(\varphi, h)$  es el ritmo de aprendizaje dependiente de la distancia angular entre la neurona que presenta la mejor percepción de la entrada y la que está siendo actualizada en la red, y dependiente también del número de iteraciones o ejemplos presentados hasta la etapa  $h$  de entrenamiento.  $\alpha(h)$  es el ritmo de aprendizaje dependiente del número de iteraciones,  $X2ijt$  es el valor al tiempo  $t$  de la percepción  $X2(i)j$  de la señal  $j$  en la neurona  $i$ ,  $Y1ij$  e  $Y3ij$  son las imágenes internas en la neurona  $i$  provenientes de la entrada  $X0(i)j$  y de la percepción  $X2(i)j$  respectivamente.

La ecuación que sigue es equivalente a la anterior pero para los pesos inversos.

$$Wijth = Wijth-1 + \alpha(h)R(\varphi, h)Y1ij(X0ijt - X2ijt)$$

En ella  $W_{ijth}$  es el peso inverso (de la capa interna a la externa) desde la neurona  $i$  a la entrada  $j$  al tiempo  $t$  en el paso iterativo  $h$ . Puede verse que en esta segunda ecuación se ajusta en forma iterativa la percepción al estímulo siendo la sensación directa un factor de escala.

Es relevante en este punto observar que las matrices  $W(i,t)(j)$  sólo son funciones de  $j$  durante el proceso de entrenamiento. Cuando el aprendizaje concluye, la matriz  $W(i,t)$  se estabiliza resultando el patrón de pesos sinápticos dependiente de la neurona, cada una de las cuales ha almacenado un vector  $W_i(t)$  que tipifica un conjunto de señales.

La determinación del conjunto de patrones de entrada mejor representado por cada neurona se realiza por medio de una medida de distancia euclidiana entre el patrón de entrada a la capa  $X_0(i)$  y el patrón reconstruido por cada neurona de la capa

$$Y_{1i} * W_i(i),$$

seleccionando como neurona más representativa aquella cuyo patrón reconstruido es más próximo al patrón de origen, es decir, aquella neurona que ofrece la mejor percepción del estímulo de entrada.

Las posiciones de las neuronas han sido definidas por vectores  $V_{mijk}$ , donde  $m$  identifica la neurona en la posición angular azimutal y cenital  $ij$ , y  $k$  recorre los  $T$  pesos sinápticos que vinculan cada neurona con el patrón de entrada. Como es típicamente requerido entre 100 y 500 iteraciones por cada neurona oculta de la red de Kohonen, se ha implementado  $500 * N_1$  iteraciones para entrenar la red. El entrenamiento es realizado en forma aleatoria seleccionando series de tiempo en puntos de grilla sobre la Tierra. De esta manera se espera que cada serie correspondiente a cada punto de grilla sea presentada a la red un número mínimamente representativo de veces. La neurona que responde con la percepción

más parecida al estímulo y sus vecinas son especializadas en reconocer un patrón que presenta características similares. De tal manera se obtiene patrones de pesos sinápticos como síntesis globales y son identificadas las señales originales que presentan similitud con los patrones característicos, las que a su vez son organizadas en el mapa de la red. Es pertinente observar que no todos los datos son presentados a la red durante el entrenamiento. Si se considera que el experimento “presentar una serie” se realiza  $500 * N_1$  veces sobre 256 neuronas a partir de  $N_0 = 18142$  señales o puntos de grilla, la probabilidad de que un punto sea seleccionado vale  $1/N_0$ , con lo cual es asociable a un experimento de Poisson con esperanza

$$\lambda = 500 * N_1 / N_0 = 500 * 256 / 18142.$$

La probabilidad de que un punto no forme parte de ninguna muestra vale entonces

$$p = \text{Exp}(-\lambda),$$

que en nuestra aplicación resulta 0.000863, con lo que se obtiene  $N_0 * p = 16$  el valor esperado de puntos no presentados a la red, número pequeño en proporción con el valor  $N_0 = 18142$  (del orden de  $256^2$ ) puntos de grilla con escaso o nulo efecto sobre el entrenamiento.

El entrenamiento de la segunda capa se desarrolla mostrando al azar los patrones de abstracciones almacenadas en la primera capa y reconstruidos a partir de los pesos inversos

$$X_2(i) = Y_1(i) W_i(i).$$

Los patrones  $X_2(i)$  operan como señales que relacionan las  $N_1 = 256$  neuronas de la primera capa como señales proyectadas sobre las  $N_2 = 64$  neuronas de la segunda capa, las que así se especializan en reconocer determinados patrones  $W_i(i)$  de la primera. El proceso se realiza de la misma manera tras  $500 * N_2$  iteraciones. El

entrenamiento de la tercera capa se realiza siguiendo el mismo procedimiento, mostrando  $500 \cdot N_3 = 8000$  veces a  $N_3 = 16$  neuronas de la tercera capa las 64 reconstrucciones a partir de las abstracciones que relacionan la segunda capa con la primera. El entrenamiento de la cuarta capa se efectúa mostrando los 16 patrones que relacionan la tercera con la segunda capa a las cuatro ( $N_4$ ) neuronas de la cuarta por medio de  $500 \cdot N_4 = 2000$  iteraciones.

El proceso de identificación de patrones parte de reconstruir las series de las capas sucesivas a partir de la activación de las neuronas entrenadas en las capas más profundas, lo que se obtiene multiplicando un patrón de pesos sinápticos  $W_i(i)$  por el coeficiente  $Y_1(i)$  correspondiente. Luego se compara los patrones reconstruidos internos con las series de pesos sinápticos inversos multiplicadas por los “coeficientes de sensación”  $Y$  de las capas más externas, a modo de reconstrucción de abstracciones, hasta llegar a la fuente original de datos o capa externa sensible. En este proceso en primer lugar se reconstruyen los patrones de asociación que vinculan la capa cuatro con la capa tres. Los cuatro patrones  $W_i(i)_4$  de la capa cuatro se multiplican por los coeficientes  $Y_1(i)_4$  para generar cuatro patrones

$$Y_1(i)_4 W_i(i)_4$$

con los cuales se comparan los 16 patrones

$$Y_1(i)_3 W_i(i)_3$$

de la tercera capa, vinculando los patrones sinápticos  $W_i(i)_3$  de la capa tres con el más próximo, en términos de distancia euclidiana, de los cuatro reconstruidos a partir de la capa cuatro. El mismo procedimiento se aplica para configurar los patrones de asociación entre la capa tres y la capa dos, entre la capa dos y la capa uno, y entre la capa uno y la fuente de datos, que podría llamarse la capa cero o sensible. De esta manera los dieciséis

patrones correspondientes a las neuronas de la tercera capa quedan identificados como diferencialmente asociados a cada una de las cuatro neuronas más profundas de la cuarta capa de acuerdo con un criterio de similitud euclidiano. Las neuronas de la tercera capa se asocian de la misma manera con las neuronas de la segunda capa a través de los patrones.

$$Y_1(i)_2 W_i(i)_2$$

De forma similar se identifican las neuronas de la primera capa, definidas por sus patrones

$$Y_1(i)_1 W_i(i)_1,$$

como asociadas con las neuronas de la segunda. Finalmente se asocian los patrones  $W_i(i)_1$  y sus parámetros  $Y_1(i)_1$  con las series originales  $X_0(j)$  de datos. Se define así sobre el Globo cuatro grandes regiones por medio de los patrones más generales o abstracciones más profundas identificados en la cuarta capa de neuronas. A su vez la tercera, segunda y primera capas definen áreas más delimitadas, las que describen en forma cada vez más detallada el comportamiento de las series temporales de datos.

En lo que sigue, la referencia a los números de capa se hará en forma de texto (uno, dos, tres...), mientras que la referencia a las neuronas se hará en formato numérico (1, 2, 3...).

### Datos

En el presente trabajo se procurará especializar un conjunto de neuronas en el reconocimiento de patrones de precipitación global y la distribución geográfica de los campos de anomalías. La información de base consiste en 53 años de reanálisis (636 valores mensuales entre 1948 y 2000 obtenidos de la variable “prate” de la dirección [http://cola8.iges.org:9090/dods/rean\\_2d.info](http://cola8.iges.org:9090/dods/rean_2d.info), junio de 2006). Se utiliza así un conjunto de 18142 patrones de entradas, con una

resolución espacial en torno a 1.5° en latitud y longitud.

Esta variable representa la velocidad de precipitación en metros cúbicos por segundo y es ajustada la escala para representar la lluvia acumulada mensualmente en cada punto de grilla. Es sabido que la precipitación se encuentra entre las variables menos confiables o de tipo C en el reanálisis [24], casi exclusivamente calculadas de acuerdo con la física del modelo. De todas maneras esta reconstrucción contiene considerable información acerca del patrón de lluvias cubriendo regularmente el Globo, en especial los totales mensuales al integrar variabilidades de corto plazo en escala regional.

Al suprimir la media del período surge de forma natural la estructura de la onda anual como criterio de comparación. Esta etapa de análisis conduce a verificar la capacidad del proceso de la red neuronal para identificar, organizar y caracterizar patrones de onda anual, y comparar con la climatología conocida.

En el presente trabajo se procura evaluar la metodología en el sentido de observar si su aplicación conduce a patrones conocidos de variabilidad. En los archivos los datos se encuentran en las unidades SI, es decir, en  $\text{kg}/\text{m}^2\text{s}$ . Para utilizar unidades más amigables al uso habitual, se multiplicó estos valores por  $86400 \times 30.45$  a los fines de tener totales mensuales en unidades comparables a mm de precipitación. Se aplica la metodología a las series tras haber sido filtrada la media del período como promedio total de la serie en cada punto de grilla. Por lo tanto, el criterio fundamental de organización es el ciclo anual y, en modo secundario, la variabilidad de largo período. Se analiza la organización de la red en las distintas capas hasta la entrada de datos o capa cero con el fin de interpretar la síntesis en términos de las series originales.

## Resultados

Las series residuales contienen la onda anual y es esperable que éste resulte ser el criterio fundamental de agrupamiento y organización. El procedimiento conduce a los cuatro patrones que se muestran en la figura 1.

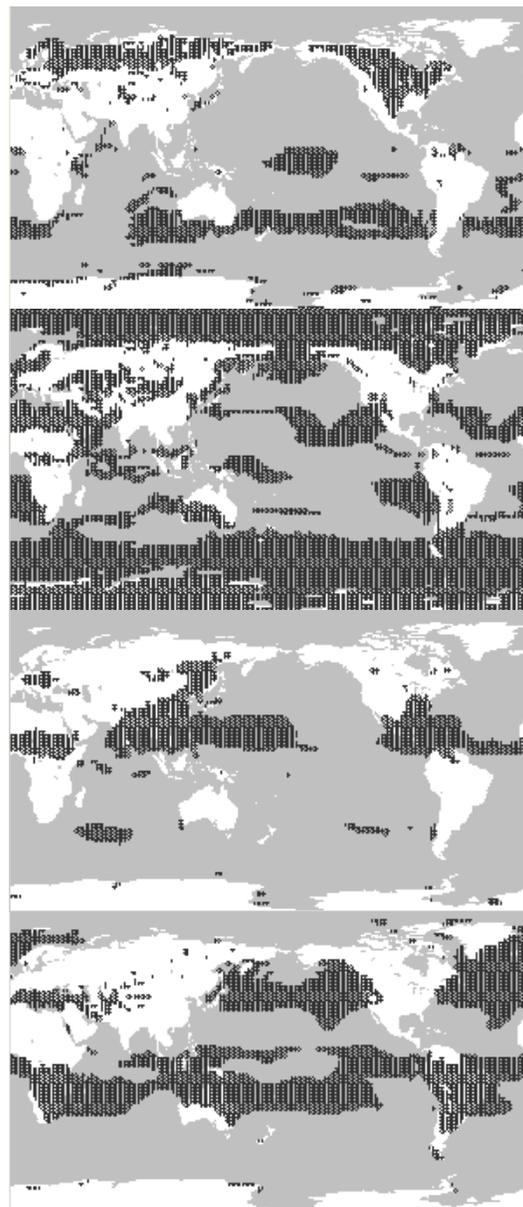


Fig. 1 Distribución global de los cuatro patrones de precipitación tras sustracción de la media. De arriba hacia abajo neuronas 1, 2, 3 y 4.

En la figura 2 se muestra la forma de la onda anual media de cada una de las cuatro reconstrucciones proporcionadas por la red neuronal en la cuarta capa.

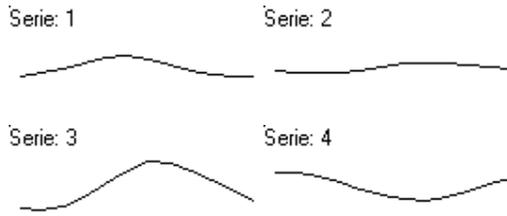


Fig.2: Forma de la onda anual correspondiente a las neuronas 1, 2, 3 y 4 de la cuarta capa.

En la figura 3 a, b, c y d se muestra las series temporales sintetizadas en los pesos sinápticos de la capa más profunda de la red.

C: 4 N: 1 Minimo:-33.mm Maximo:45.3mm

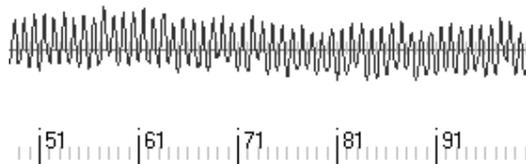


Fig. 3a Serie temporal correspondiente al patrón de la neurona 1 de la capa cuatro

C: 4 N: 2 Minimo:-17.6mm Maximo:17.8mm



Fig. 3b Serie temporal correspondiente al patrón de la neurona 2 de la capa cuatro

C: 4 N: 3 Minimo:-70.8mm Maximo:90.4mm

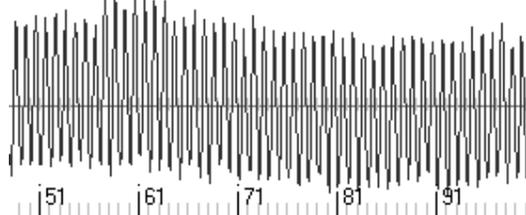


Fig. 3c Serie temporal correspondiente al patrón de la neurona 3 de la capa cuatro

C: 4 N: 4 Minimo:-41.5mm Maximo:40.3mm

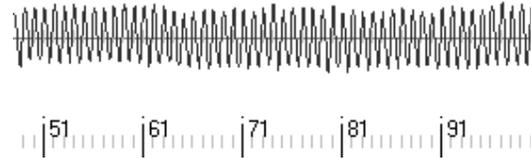


Fig. 3d Serie temporal correspondiente al patrón de la neurona 4 de la capa cuatro

Se observa que el criterio de clasificación adoptado por la red es la forma de la onda anual de precipitación, tanto en amplitud como en fase. La distribución geográfica de las series temporales asociadas a la neurona 1 corresponde a un patrón oceánico de latitudes medias del hemisferio sur y a un régimen continental de latitudes medias y altas del hemisferio norte. El patrón espacial de la neurona 2 corresponde a un régimen de tipo desértico, presente también en áreas polares, en Sudamérica dominante en la Patagonia y zonas áridas del Norte de Argentina y de Bolivia. La neurona 3 representa un patrón anual de precipitación de gran amplitud dominante en áreas tropicales del hemisferio norte, con lluvias en julio, que se extiende a latitudes más altas en Europa Central y en Asia Oriental. La neurona 4 expresa un patrón geográfico con predominio en zonas tropicales del hemisferio sur, con máximos en enero, pero se observa también en regiones oceánicas del hemisferio norte. El patrón correspondiente a la neurona 4 es dominante en el Centro y Norte de Argentina y el extremo sur de la Patagonia. En la figura 4 se presenta la distribución de neuronas en las capas intermedias asociadas a las cuatro neuronas de la capa más profunda de la red.

Puede verse cómo se agrupan las neuronas de las capas externas en función de proximidad a un patrón definido por las capas interiores con un ordenamiento en la primera capa más homogéneo que el observado en las series completas, es decir, sin supresión de la media.

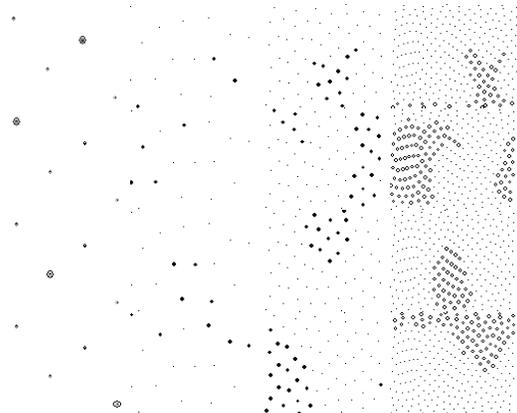


Fig. 4 Capas de neuronas asociadas con una neurona seleccionada de la capa cuatro. Se muestra la neurona seleccionada en la cuarta capa y las asociadas en las capas tres, dos y uno de izquierda a derecha en una distribución esférica uniforme en proyección cilíndrica.

En lo que sigue se analizará el detalle que proporciona la reconstrucción de la serie de precipitación a partir de las capas interiores hacia las capas más externas de la red, tanto en lo que respecta a la distribución espacial como a las características de la serie temporal reconstruida. Para ello se concentrará la atención en las neuronas que representan el comportamiento de la lluvia en Argentina.

En la figura 5 a y b se muestra la serie de pesos sinápticos de la neurona 14 de la capa tres, asociada con la neurona 4 de la capa cuatro. Puede verse que presenta la misma forma de la onda anual pero con mayor amplitud que la observada en la neurona 4 de la cuarta capa.

La distribución espacial de las regiones que representa a escala global se observa en la figura 5c.

En la figura 5d se muestra la neurona 14 en la capa tres (círculo en la parte superior izquierda del gráfico) y las neuronas asociadas en las capas dos y uno.

C: 3 N: 14 Minimo:-62.5mm Maximo:86.mm

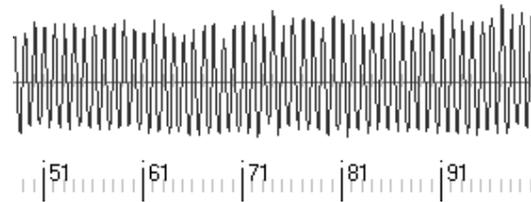


Fig. 5a Serie temporal correspondiente al patrón de la neurona 14 de la capa tres

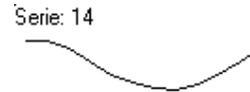


Fig. 5b Onda anual media correspondiente al patrón de la neurona 14 de la capa tres

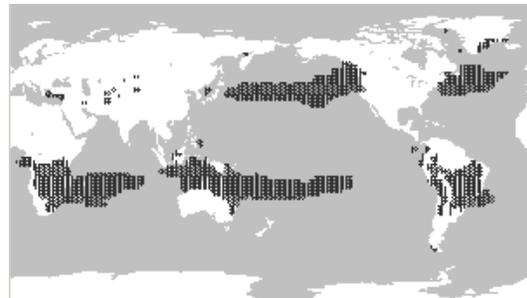


Fig. 5c Distribución global del patrón de precipitación tras sustracción de la media correspondiente a la neurona 14 de la capa tres

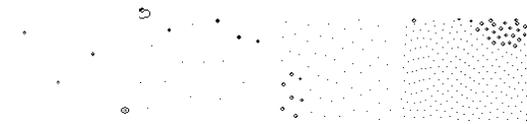


Fig. 5d Capas de neuronas asociadas con la neurona 4 de la capa cuatro y la neurona 14 de la capa tres.

Se muestra la neurona seleccionada en la cuarta capa, las asociadas y la seleccionada en la capa tres, y las asociadas en las capas dos y uno de izquierda a derecha en una distribución esférica uniforme en proyección cilíndrica.

La neurona 2 de la capa tres (figuras 6a, b, c y d) resume el patrón de onda anual de lluvia en el centro y sur de la Región Pampeana. Se destaca la disminución de la amplitud pero la conservación de forma de la onda anual. También es clara la vecindad espacial del patrón geográfico asociado a la neurona 2 con respecto al correspondiente a la neurona 14, así como también la vecindad en el mapa neuronal generado por la red.

C: 3 N: 2 Mínimo:-34.4mm Máximo:38.mm



Fig. 6a Serie temporal correspondiente al patrón de la neurona 2 de la capa tres



Fig. 6b Onda anual media correspondiente al patrón de la neurona 2 de la capa tres

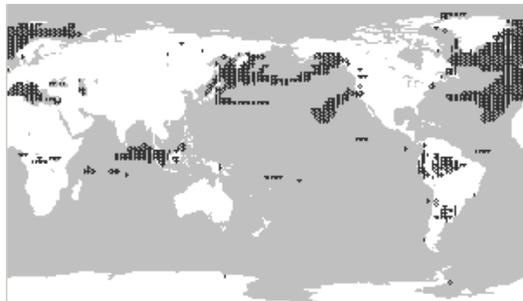


Fig. 6c Distribución global del patrón de precipitación tras sustracción de la media correspondiente a la neurona 2 de la capa tres

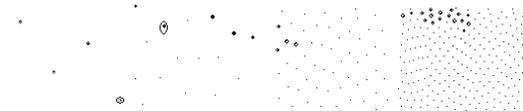


Fig. 6d Capas de neuronas asociadas con la neurona 4 de la capa cuatro y la neurona 2 de la capa tres. Se muestra la neurona seleccionada en la cuarta capa, las asociadas y la seleccionada en la capa tres, y las asociadas en las capas dos y uno de izquierda a derecha en una distribución esférica uniforme en proyección cilíndrica.

El patrón de onda anual que sintetiza la neurona 1 de la capa tres (Figura 7) describe el comportamiento de la lluvia en la línea sur de la Región Pampeana y norte de la Patagonia, pero también en el extremo sur patagónico. Se conserva la forma de la onda anual pero con menor amplitud así como la vecindad geográfica y en el mapa de la red. La diferencia se establece más bien en una variación de baja frecuencia en la serie temporal en la que se observa claramente una anomalía positiva en la década de 1950 y negativa en

la de 1980. La neurona 8 de la capa 3 no tiene un patrón de onda anual que caracterice el comportamiento de la lluvia en Argentina sino en la costa atlántica ecuatorial de Brasil sobre Sudamérica, además de otras regiones del Globo, por lo que no se muestra en el trabajo. En cambio el régimen anual del sur de Entre Ríos, sudoeste de Uruguay y nordeste de Buenos Aires se expresa en la neurona 15 (no mostrada) de la capa tres, al igual que el patrón típico anual de Chaco, Formosa y Paraguay.

C: 3 N: 1 Mínimo:-33.3mm Máximo:50.6mm



Fig. 7a Serie temporal correspondiente al patrón de la neurona 1 de la capa tres



Fig. 7b Onda anual media correspondiente al patrón de la neurona 1 de la capa tres

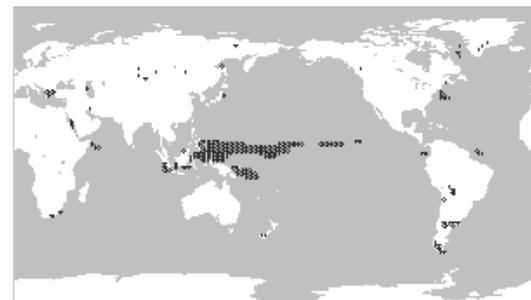


Fig. 7c Distribución global del patrón de precipitación tras sustracción de la media correspondiente a la neurona 1 de la capa tres



Fig. 7d Capas de neuronas asociadas con la neurona 4 de la capa cuatro y la neurona 1 de la capa tres. Se muestra la neurona seleccionada en la cuarta capa, las asociadas y la seleccionada en la capa tres, y las asociadas en las capas dos y uno de izquierda a derecha en una distribución esférica uniforme en proyección cilíndrica.

El máximo de precipitación se desplaza a los meses de febrero y marzo, y el mínimo hacia finales del invierno, por lo que esta neurona identifica un corrimiento de fase en la onda anual.

En la figura 8 (a, b, c y d) se presenta el patrón asociado a la neurona 44 de la capa dos, vinculada a la neurona 2 de la capa tres, y las regiones del globo con un patrón de lluvia representado por sus pesos sinápticos. Puede verse que este patrón corresponde al sur de la Región Pampeana.

C: 2 N: 44 Mínimo:-46.1mm Máximo:51.5mm



Fig. 8a Serie temporal correspondiente al patrón de la neurona 44 de la capa dos

Serie: 44

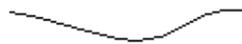


Fig. 8b Onda anual media correspondiente al patrón de la neurona 44 de la capa dos



Fig. 8c Distribución global del patrón de precipitación tras sustracción de la media correspondiente a la neurona 44 de la capa dos

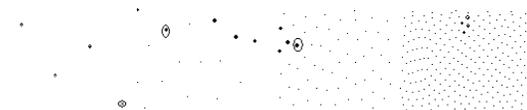


Fig. 8d Capas de neuronas asociadas con la neurona 4 de la capa cuatro, la neurona 2 de la capa tres y la neurona 44 de la capa dos. Se muestra la neurona seleccionada en la cuarta capa, las asociadas y la seleccionada en la capa tres, y las asociadas y seleccionada en la capa dos y la seleccionada y asociadas en la capa uno de izquierda a derecha en una distribución esférica uniforme en proyección cilíndrica.

Es claro también que en la serie temporal se reflejan más detalles en relación con la forma de la onda y sus variaciones interanuales.

La figura 9 corresponde a la serie de pesos sinápticos de la neurona 139 de la capa uno.

C: 1 N: 139 Mínimo:-64.9mm Máximo:64.1mm

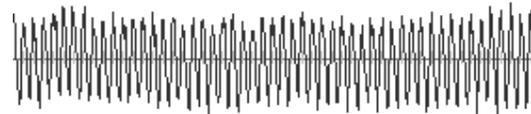


Fig. 9a Serie temporal correspondiente al patrón de la neurona 139 de la capa uno

Serie: 139

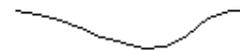


Fig. 9b Onda anual media correspondiente al patrón de la neurona 139 de la capa uno



Fig. 9c Distribución global del patrón de precipitación tras sustracción de la media correspondiente a la neurona 139 de la capa uno

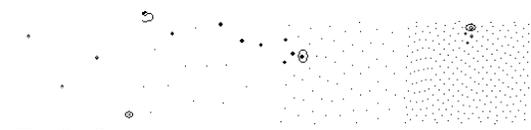


Fig. 9d Capas de neuronas asociadas con la neurona 4 de la capa cuatro, la neurona 2 de la capa tres, la neurona 44 de la capa dos y la neurona 139 de la capa uno. Se muestra la neurona seleccionada en la cuarta capa, las asociadas y la seleccionada en la capa tres, y las asociadas y seleccionada en la capa dos y la seleccionada y asociadas en la capa uno de izquierda a derecha en una distribución esférica uniforme en proyección cilíndrica.

Con una representatividad más restringida casi exclusivamente al sur de la Región Pampeana, exceptuando el

comportamiento similar de la lluvia en algunos sitios del Pacífico Norte, muestra con más detalle la serie de precipitación. En el mapa de la red se muestra la ubicación de la neurona 139 en la primera capa.

Puede observarse que la forma del ciclo anual caracterizado por la neurona cuatro de la cuarta capa persiste en los patrones sinápticos de las neuronas de las capas tres, dos y uno. Pero también puede verse un incremento en la resolución de detalles en la serie temporal y en la distribución espacial progresivamente más precisa en las sucesivas capas de la red hasta el mapa global, así como asociaciones de vecindad. Las variaciones en general se vinculan con la forma de la onda anual en amplitud, forma y fase, pero en ocasiones reflejan alteraciones de más largo período en la estructura de la serie.

Con el fin de comparar el patrón tipificado en los pesos sinápticos con las series individuales de precipitación junto con la forma de la onda anual asociada, en la figura 10 se observa la serie de lluvias correspondiente al punto de grilla ubicado a 34°S y 63°O, representativo del sudeste de Córdoba, Noroeste de Buenos Aires y sudoeste de Santa Fe.

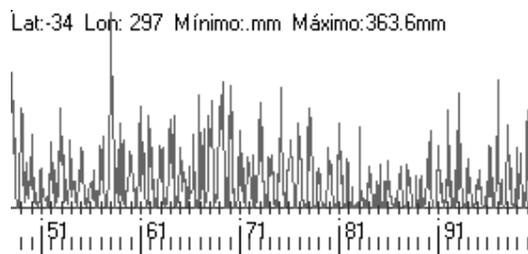


Fig. 10a. Serie temporal de anomalías de precipitación por sustracción de la media en el punto de grilla representado por (-34°S; -63°O).



Fig. 10b. Izquierda: Forma de la onda anual media de precipitación en el punto de grilla representado por las coordenadas (-34°S; -63°O). Derecha: forma de la onda anual media asociada a la neurona 139 de la primera capa de la red.

Este punto está identificado por el patrón de pesos sinápticos de la neurona 139 de la capa uno. Puede verse que esta onda anual presenta un máximo en verano y un mínimo en invierno con una pendiente abrupta en el comportamiento de la lluvia durante el proceso de cambio estacional.

Es claro que el proceso de abstracción de la red parte de patrones locales en puntos de grilla para componer patrones regionales típicos progresivamente más amplios en términos de representatividad geográfica y rescata los caracteres comunes de la onda anual en las sucesivas capas de la red. En las series de referencia en puntos de grilla puede verse que estas series puntuales contienen los caracteres de la onda anual tipificados por la abstracción resultante de la red.

### Conclusiones

Los mapas auto organizados de redes neuronales permiten una organización, clasificación y tipificación de patrones de onda anual de precipitación global. Se ha procurado interpretar la operación de la red en términos de procesos neurales como sensación, percepción y un proceso de abstracción primaria y progresiva. La configuración en varias capas facilita la organización de la información en distintos niveles de abstracción y detalle. La primera capa permite la elaboración de síntesis a partir de series puntuales. Las capas dos y tres hacen posible el análisis de vínculos remotos a partir de la similitud de patrones de anomalías. La cuarta capa posibilita la elaboración de síntesis globales en los patrones de onda anual. Se evalúa la potencialidad del método a través de la exploración de aspectos conocidos de la climatología y de las ondas anuales de precipitación. Se compara uno de los patrones temporales elaborados por la red con su serie puntual representada.

### Referencias

- [1]Kohonen T (2001) Self Organizing Maps (3° ed.) USA, Springer. (Caps. 3, 4 y 5)
- [2]Gardner MW Dorling SR (1998) Artificial Neural Networks (The Multilayer Perceptron) - a

Review of Applications in the Atmospheric Sciences. Atmospheric Environment 32 (14/15), 2627-2636.

[3]Turiasa I González M Galindo P A (2006) Competitive neural network approach for meteorological situation clustering. Atmospheric Environment, Volume 40, Issue 3, January 2006, Pp. 532-541.

[4]Malmgren BA Winter A (1999) Climate Zonation in Puerto Rico Based on Principal Components Analysis and an Artificial Neural Network. Journal of Climate Volume 12 pp. 977-985.

[5]Hall M Minns A Ashrafuzzaman A (2002) The application of data mining techniques for the regionalisation of hydrological variables. Hydrology and Earth System Sciences, 6(4), 685-694

[6]Steynor A Hewitson B (2006) The use of Kohonen self-organising maps in assessing the impact of global climate change on the runoff of the Breede River in South Africa. Geophysical Research Abstracts, Vol. 8, 00429

[7]Fayos J Fayos C (2007) Wind Data Mining by Kohonen Neural Networks. PLoS ONE. 2007; 2(2): e210. Published online February 14 2007. doi: 10.1371/journal.pone.0000210. PMID: PMC1790699

[8]Kilpatrick D Williams R Unsupervised classification of Antarctic satellite imagery using Kohonen self-organising feature map (1995). Proceedings IEEE International Conference on Neural Networks. Volume 1, Issue , Nov/Dec 1995 Page(s):32 - 36 vol.1

[9]Michaelides S Pattichis C Classification of rainfall distributions with the use of Artificial Neural Networks. Proceedings: 4th Panhellenic Conference on Meteorology, climatology and Atmospheric Physics. Athens, Greece, September 1998. pp. 251-256.

[10]Cogliati M Britos P García-Martínez R (2006) Análisis de variables agrometeorológicas en noches de heladas utilizando mapas auto organizados y algoritmos de inducción. XI Reunión Argentina de Agrometeorología. 6 a 8 de septiembre de 2006. Facultad de Ciencias Agrarias y Forestales. Universidad Nacional de La Plata.

[11]Vargas WM Huggenberger DA (2009) Una clasificación de la lluvia en el cono sur de Sudamérica desde una perspectiva global por medio de un mapa auto organizado de redes neuronales. X Congreso Argentino de Meteorología y XIII Congreso Latinoamericano e Ibérico de Meteorología. Buenos Aires, 5 al 9 de octubre de 2009.

[12]Boudjemai F Enberg PB Postaire JG (2003) Self organizing spherical map architecture for 3D object modelling. Proceedings of workshop on self-organizing maps. Kitakyushu, Japan, September 2003.

[13]Nishio H Altaf-Ui-Amin MD Kurokawa K Kanaya S (2006) Spherical SOM and Arrangement of Neurons Using Helix on Sphere IPSJ Digital Courier Vol.2 pp. 133-137.

[14]Wu Y Takatsuka M (2005) [Fast Spherical Self Organizing Map--Use of Indexed Geodesic Data Structure](#). Workshop on Self-Organizing Maps 2005, WSOM05, Paris, France, 5-8 September 2005.

[15]Wu Y Takatsuka M (2006) Spherical self-organizing map using efficient indexed geodesic data structure. Neural Networks Vol. 19 N° 6 pp. 900-910.

[16]Bacao F Lobo V Painho M (2004) Geo-Self-Organizing Map (Geo-SOM) for Building and Exploring Homogeneous Regions. En [http://www.isegi.unl.pt/ensino/docentes/fbacao/bacao\\_GisScience04.pdf](http://www.isegi.unl.pt/ensino/docentes/fbacao/bacao_GisScience04.pdf)

[17]Bacao F Lobo V Painho M (2005) The self-organizing map, the Geo-SOM, and relevant variants for geosciences. Computers & Geosciences 31 155-163.

[18]Gorriza JML (2009) Visualization of Clusters in Geo-referenced Data Using Three-dimensional Self-Organizing Maps. En <http://run.unl.pt/bitstream/10362/2631/1/TEGI0240.pdf>

[19]Sangole A Knopf GK (2003) Visualization or randomly ordered numeric data sets using spherical self-organizing feature maps. Computer & Graphics Vol. 27 N° 6 pp. 963-976.

[20]Sangole AP Leontitsis A (2006) Spherical Self-Organizing Feature Map: an Introductory Review, International Journal of Bifurcation and Chaos Vol.16 N° 11 pp. 3195-3206.

[21]Leontitsis A Sangole AP (2006) Estimating an Optimal Neighborhood Size in the Spherical Self-Organizing Feature Map. International Journal of Computational Intelligence, Vol. 18 N° 35 pp. 192-196.

[22]Wu H (2011) Spherical Topology Self-Organizing Map Neuron Network for Visualization of Complex Data. A report submitted for the degree of Master of Computing of Australian National University. The Australian National University.

[23]Hinton GE McClelland JL (1988) Learning Representation by Recirculation. American Institute of Physics. Proc. IEEE Conf on Neural Information Processing Systems, pp. 358-366.

[24]Kalnay et al. (1996) The NCEP/NCAR 40-year reanalysis project, Bull. Amer. Meteor. Soc., 77, 437-470.

#### **Datos de Contacto:**

*Darío Huggenberger. Facultad Regional Delta - Universidad Tecnológica Nacional. San Martín 1050 (2809) Campana. Buenos Aires. Argentina E-mail [dhuggenberger@frd.utm.edu.ar](mailto:dhuggenberger@frd.utm.edu.ar)*