



Modelización mediante redes neuronales artificiales cuánticas aplicadas a la gestión de riesgos naturales

Rafael Cosano Carbonell¹

Recibido: 15 de octubre del 2020 / Enviado a evaluar: 15 de diciembre del 2020 / Aceptado: 20 de abril del 2022

Resumen. Este trabajo trata de mostrar como la modelización y predicción mediante redes neuronales artificiales cuánticas puede ser de gran ayuda para gestionar los riesgos naturales de forma más eficiente. Las redes neuronales, o inteligencia artificial, permiten extrapolar el funcionamiento neuronal del cerebro humano a todo tipo de modelizaciones y predicciones de la realidad mediante un entrenamiento y adaptación a cada riesgo en concreto (climáticos, sísmicos, geomorfológicos/geológicos...). Su flexibilidad y plasticidad permite que los resultados incluyan un gran número de elementos y valores que no son posibles encontrar en otros modos de modelización. Este trabajo se realiza desde el punto de vista geográfico, y no pretende mostrar cálculos ni modelizaciones matemáticas, si no que busca mostrar un marco teórico que incluya el máximo de elementos sobre los cuales pueda construirse una base para una modelización posterior.

Palabras clave: Red neuronal artificial; predicción; entrenamiento; riesgos; cuántico.

[en] Modeling using quantum artificial neural networks applied to natural risk management

Abstract. This paper tries to show how modeling and prediction through quantum neural networks can be of great help in managing natural risks more efficiently. Neural networks, or artificial intelligence, allow extrapolating the neuronal functioning of the human brain to all types of modeling and predictions of reality through training and adaptation to each specific risk (climatic, seismic, geomorphological / geological, ...). Its flexibility and plasticity allow the results to include a large number of elements and values that cannot be found in other modeling modes. This work is carried out from the geographical point of view, and it does not intend to show calculations or mathematical modeling, but it seeks to show a theoretical framework that includes the maximum of elements on which a base for a later modeling can be built.

Keywords: Artificial neuronal network; prediction; training; risks; quantic.

¹ E-mail: rafaelcosano111@hotmail.com

[fr] Modélisation par réseaux de neurones artificiels quantiques appliquée à la gestion des risques naturels

Résumé. Ce travail a pour but de montrer comment la modélisation et la prédiction au moyen de réseaux neuronaux quantiques peut aider à gérer les risques naturels de forme plus efficace. Les réseaux neuronaux, ou intelligence artificielle, permettent d'extrapoler le fonctionnement neuronal du cerveau humain à toutes sortes de modélisation et prédictions de la réalité par un entraînement et une adaptation à chaque risque spécifique (climatiques, sismiques, géomorphologiques/géologiques...). Sa souplesse et plasticité permettent aux résultats d'inclure un grand nombre d'éléments et de valeurs qu'il n'est pas possible de trouver dans d'autres modes de modélisation. Ce travail est réalisé d'un point de vue géographique et n'essayer pas d'utiliser des calculs ni de modélisations mathématiques, mais plutôt de montrer un cadre théorique qui inclue le maximum d'éléments sur lesquels construire une base pour une modélisation ultérieure.

Mots-clés: Réseau neuronal artificiel; prévision; entraînement; risques; quantique.

Cómo citar. Cosano Carbonell, R. (2022): Modelización mediante redes neuronales artificiales cuánticas aplicadas a la gestión de riesgos naturales. *Anales de Geografía de la Universidad Complutense*, 42(1), 53-63.

Sumario. 1. Introducción. 1.1. Entrenamiento de una RNA. 1.2. Sistemas inteligentes basados en redes probabilísticas Bayesianas. 1.3. Computación cuántica aplicada a las RNA. 2. Objetivos, hipótesis de trabajo y metodología. 3. Estructura de red neuronal artificial para la modelización de eventos meteorológicos extremos y algoritmos de cálculo de riesgo climático. 4. Reflexiones a la manera de conclusiones. 5. Referencias.

1. Introducción


Hoy día la predicción está basada en la extrapolación de datos recogidos durante una serie más o menos larga de tiempo, que van desde el pasado hasta el presente, y que se someten a un tratamiento estadístico. Estos datos pueden ser cualitativos, basados en información y datos indirectos del pasado, y cuantitativos, basados en información y datos directos acumulados durante un período más o menos largo de tiempo. Es por ello por lo que la mayoría de las ciencias, que necesitan saber qué ocurrirá en el futuro, recurrirán a estos datos en cualquiera de sus formatos, debido a que para ellas la predicción tiene una gran importancia.

La predicción no es tal si no está apoyada en una serie de datos y estadísticas que acaben conformando patrones de comportamiento. Se trata de buscar regularidades y repeticiones. Estos datos estadísticos deben ser continuos, sin espacios vacíos entre ellos, y además se debe buscar un solapado entre ellos; esa continuidad nos llevará a la generalización. En este sentido la generalización es sumamente importante, ya que nos ayudará a visualizar ideas sobre algo que aún no conocemos, aunque con una base en lo conocido. Podemos utilizar generalización como extrapolación. Ésta generará patrones que serán la génesis que nos llevará al inicio de la puesta en marcha de una Red Neuronal Artificial, en adelante RNA. Este sistema será capaz de procesar inputs exteriores e información que estructurará internamente una red con funcionamiento prácticamente idéntica a una red neuronal biológica (Gutiérrez, J.M. et al., 2004).

Una RNA se puede definir como un número determinado de neuronas autoorganizadas en diferentes capas, y que tienen múltiples conexiones entre ellas

mediante enlaces que tendrán un determinado peso de información introducido externamente.

Figura 1. Dibujo de una neurona biológica.



Fuente: Elaboración propia.

Cuando se trata de definir el funcionamiento de una neurona biológica, su estructura está basada en la sinapsis que transmite la información desde la parte final de un axón a las diferentes dendritas de otra neurona. Hay que tener en cuenta que la sinapsis es algo virtual, no tangible, que no existe realmente como conexión, sino que es una acción u orden que permite que la conexión se efectúe mediante los neurotransmisores químicos. Cuando lo extrapolamos a una RNA y tratamos de generar un sistema de alta complejidad similar al biológico, hay que hacerlo mediante un entrenamiento de las neuronas artificiales, que les dará la capacidad de almacenar una cantidad de información sobre un ámbito determinado, a la cual se le dará un peso determinado, lo que permitirá que la neurona sea capaz de generar una solución a los diferentes problemas que se le vayan planteando (Gutiérrez, J.M. et al., 2004).

Este sistema está basado en algoritmos matemáticos no lineales que parten de datos que han sido introducidos con antelación. El proceso trata de reproducir el funcionamiento de nuestro cerebro, y éste es capaz de reconocer patrones, hacer extrapolaciones y tener la capacidad de tomar decisiones, que serán implementadas con bases estadísticas y experiencias del pasado. Este sistema en red tiene una alta capacidad de predicción, y en el caso que nos ocupa irá dirigida a la Gestión de Riesgos Naturales, y más concretamente en relación con los eventos meteorológicos extremos.

1.1. Entrenamiento de una RNA

Cuando hablamos de entrenamiento en el ámbito de las RNA, nos referimos al proceso de aprendizaje que se debe implementar en el conjunto de la red neuronal, y empieza por intentar reducir al máximo el ruido que producen errores en la salida. Además, este entrenamiento debe ser supervisado y es necesario que se trabaje con datos dobles de entrada y salida. Cuando ya hemos determinado el problema o evento sobre el que queremos trabajar, deberemos buscar e implementar un número elevado de patrones que posean la máxima relación posible. Deberemos resolver un problema y eso nos llevará a poder modelizar con un alto grado de exactitud (Basogain, X. 2008).

Hasta el momento estamos hablando de RNA con un comportamiento clásico, esto es, con una salida de datos binarios, aunque más adelante se hablará de la posibilidad de que estos datos puedan ser tratados con computación cuántica.

Si entramos brevemente en el manejo matemático, la función que supervisa la transferencia de las neuronas será una sigmoideal². Para que el sistema sea lo más sencillo posible, aunque no por ello menos eficiente, deberemos utilizar el menor número posible de capas ocultas³ constituidas de pocas neuronas.

El formato de red más adecuado en el entrenamiento será el que constituya un perceptrón multicapa⁴ con más neuronas en la entrada y menos en la salida, lo que ayudará a minimizar los errores en la salida. En el caso de que estos se produzcan se utilizará el método de “la propagación hacia atrás” o backpropagation⁵ (Gajate Martín, A. 2010) (Torrubia Caravaca, S. 2010).

En este proceso, lo más importante será que los datos deberán ser lo más representativos posible de los patrones, y estos tendrán que ser reconocidos por la red, que además deberá tener la capacidad de interpolar y extrapolar datos; es decir, generalizar. Las neuronas de la capa oculta intermedia serán capaces de reorganizarse y así responderán al nuevo patrón por generalización y podrán encontrar patrones similares capaces de reconocer el error y subsanarlo antes de que llegue a las neuronas de salida (Basogain, X. 2008).

² La función sigmoideal es característica de procesos naturales y de aprendizaje. La progresión de este aprendizaje es baja al principio, aunque tiene un punto de inflexión en el cual hay una aceleración en el llamado punto de transición. La forma característica de su representación es una S.

³ Las capas ocultas en una RNA son aquellas en las que se sitúan neuronas que reciben información de una capa anterior que suele ser la capa de entrada, y entregan información en la capa posterior que suele ser la de salida. Forman parte del perceptrón multicapa.

⁴ El perceptrón multicapa es una RNA que se compone de múltiples capas, incorporando capas ocultas, y que basa su funcionamiento en la no linealidad de los procesos, aunque requiere un entrenamiento muy preciso para no dar errores de salida, en cuyo caso se procederá a la retropropagación o backpropagation.

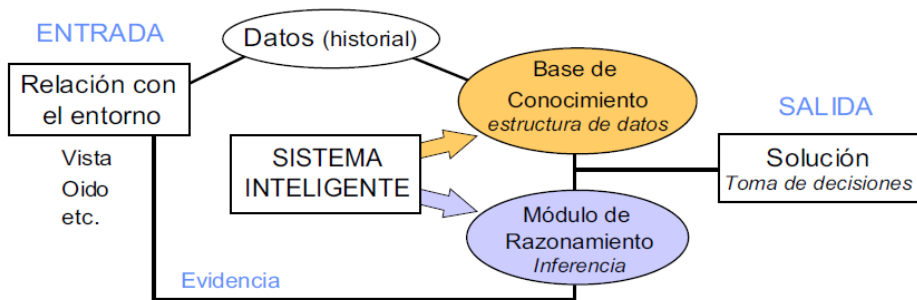
⁵ Al hilo de lo anterior, la retropropagación se basa en un algoritmo de aprendizaje que “criba” los errores de salida, que generalmente se producen en las capas ocultas y los devuelve de nuevo para ir reduciendo el ruido que lleva al error.

El proceso explicado hasta el momento está basado en un modelo de funcionamiento clásico, donde la computación sigue las reglas del 0 y 1 binarios. Esto hace que el proceso sea lento y muy mejorable, ya que sigue unas reglas de cálculo que no evolucionan de un proceso a otro hasta que éste no está acabado. El modelo binario no lo permite. La potencia de cálculo necesaria hace que en demasiadas ocasiones el modelo no pueda tener los algoritmos de salida a tiempo para poder hacer una predicción adecuada. Es por ello por lo que se quieren introducir las ventajas de la computación cuántica.

1.2. Sistemas inteligentes basados en redes probabilísticas Bayesianas

Es interesante poder introducir, aunque sea someramente, la importancia que tienen las Redes probabilísticas, a la hora de crear sistemas inteligentes que apoyen a la hora de simplificar la ingente cantidad de información de entrada que encontramos cuando queremos acometer una modelización de estas características. Estos sistemas basados en redes bayesianas⁶ nos ayudan a hacer un preprocesado rápido que vaya adoptando los primeros patrones de generalización. En cierto modo es una criba que hará que la entrada en las primeras neuronas quede lo más “limpia” posible de ruido, y que su entrega de información y pesos a las neuronas ocultas evite en lo posible procesos de backpropagation.

Figura 2. Esquema de sistema inteligente.



Fuente: Series monográficas del Instituto Nacional de Meteorología, 2004.

⁶ Las redes bayesianas modelan fenómenos a partir de variables y sus relaciones de dependencia. Es entonces cuando se produce la inferencia bayesiana; estimar la probabilidad posterior de las variables no conocidas en base a las variables conocidas. Modelizan aplicaciones para el diagnóstico, la clasificación y la predicción.

En su mayoría serán procesos automáticos, y se intenta evitar en lo posible la intervención humana. Estos sistemas inteligentes o expertos se basan en la probabilidad y tratan problemas con un alto grado de incertidumbre debido al elevado número de variables que manejan. Buscan las relaciones de dependencia entre las variables que conoce, y las infiere con evidencias cuando es capaz de localizarlas. “En definitiva las redes probabilísticas combinan grafos y funciones de probabilidad para definir de forma eficiente modelos probabilísticos que contengan relaciones de dependencia deseadas para un problema y que sean tratables computacionalmente” (Gutiérrez, J.M. et al., 2004).

1.3. Computación cuántica aplicada a las RNA

El procesamiento o computación cuántica, es capaz de procesar una cantidad ingente de datos y de realizar un gran número de cálculos a la vez. A escala cuántica, los átomos pueden tener un estado de 0 y 1 igual al binario, pero también pueden poseer los dos estados a la vez, debido a la cualidad cuántica atómica de la superposición, que se detalla en el principio de incertidumbre de Heisenberg, además de poseer también el principio de ubicuidad, que se le presupone al átomo, ya que puede estar en dos lugares a la vez o bien que puede ser o no ser al mismo tiempo. Explicado de otra manera: el procesamiento cuántico no es secuencial si no simultáneo y sigue una progresión logarítmica y no aritmética como el modelo clásico.

La unidad de medida son los bits cuánticos o qubits. Este tipo de procesamiento cuántico de la información permite dar soluciones donde no tengamos información, datos o patrones previos, dado que su velocidad de cálculo permite acometer el procesamiento de esta cantidad ingente de información. A la propiedad fundamental de la superposición, se une el fenómeno cuántico del entrelazamiento, mediante el cual los diferentes estados cuánticos se describen mediante un estado único. Esto ocurre cuando intentamos medir con la máxima precisión un objeto cuántico. Una vez que el observador actúa observando, el estado del objeto será radicalmente distinto del anterior a la medición. Incluso cuando el observador piensa que va a hacer la observación, el objeto cuántico cambia. Es una cualidad intrínseca de todos los objetos cuánticos.

La superposición permite almacenar muchos más estados diferentes de 0 y 1 mediante qubits y el entrelazamiento mantendrá las relaciones en los qubits de tal forma que se conseguirá un continuo en las operaciones por qubit que de forma automática afectará al resto de qubits. Este fenómeno puede ser un hándicap para el sistema. Si el entrelazamiento es estable, esa estabilidad afectará al sistema y hará que las partículas entrelazadas hagan avanzar al sistema. Pero si por razones externas o internas las partículas se desentrelazan, unas afectarán a otras al instante y el sistema derivará a lugares y espacios que no tendrán nada que ver con el objeto de que se

quiere modelizar. Y todo esto ocurrirá a velocidades superiores a la de la luz⁷ (Rodríguez Requena, A. 2018).

El mayor reto de este tipo de computación es lograr que la superposición y el entrelazamiento cuánticos sigan ligados para que el modelo que se quiere presentar, basado en la inteligencia artificial, nos ofrezca ventajas adicionales a las que tenemos en estos momentos con la mecánica clásica y el sistema de procesamiento binario. Una de estas ventajas que radica en el entrelazamiento es el temple cuántico⁸ que nos ayudará a reducir los errores en el entrenamiento de las RNA haciendo que sea más eficiente y pudiendo reducir el uso de la backpropagation. Este tipo de aprendizaje cuántico basado en el algoritmo del temple nos puede permitir implementarlo en procesadores que únicamente ejecuten ese algoritmo para la modelización de un sistema concreto.

De este modo, estaríamos consiguiendo una mayor velocidad de cálculo en escenarios donde el tiempo de procesamiento de datos puede ser vital para anticiparse e intentar evitar desastres naturales en tiempo real.

Todo lo presentado anteriormente aún está en vías de solución, ya que los procesadores cuánticos están en sus principios, y el hecho de implementar algoritmos cuánticos a ordenadores clásicos aún no está del todo resuelto. Además, los procesadores cuánticos deben tener unos condicionantes de temperaturas de funcionamiento cercanas al cero absoluto y su soporte está basado en superconductores que nos permitan poder trabajar con los qubits, aunque ya hay algunos ejemplos de su funcionamiento y la evolución de la tecnología nos permite ser optimistas a medio plazo.

El hecho de presentarlo en este trabajo tiene el fin darle relevancia a las posibilidades que puede ofrecer en el campo que nos ocupa y muchos otros como por ejemplo el ámbito sanitario, y aunque el desarrollo posterior de este trabajo está basado en la mecánica clásica y el procesamiento binario, la idea de fondo también nos permitirá que el procesamiento de información pueda ser cuántico.

⁷ El fenómeno cuántico del entrelazamiento nos lleva a incluso trascender la teoría de la Relatividad, en la cual queda bien claro que la velocidad máxima a la cual pueden moverse partículas sin masa como los fotones en el vacío, es próxima a la velocidad de la luz: 300.000 Kms/sg. El entrelazamiento entre dos partículas que comparten una única función de onda, pero situadas cada una en el extremo opuesto del Universo puede romperse al instante, lo cual nos llevará a valorar velocidades no medidas ni conocidas hasta ahora.

⁸ El algoritmo del temple cuántico, básicamente, ayuda a cruzar barreras donde los qubits encuentran diferente potencial, y provoca alteraciones térmicas en los diferentes estados de los qubits. Esto proporciona más aceleración de las partículas cuando el perfil de la función está formado por crestas y valles, utilizando el efecto túnel para pasar entre ellos.

2. Objetivos, hipótesis de trabajo y metodología

El presente trabajo tiene como premisa demostrar que la predicción basada en las RNA's y dirigida a la gestión de riesgos naturales puede ser una herramienta de mucho interés, dado que está basada en patrones y probabilidades que son capaces de ofrecer una predicción mucho más ajustada, rápida y de gran ayuda a las instituciones y entes públicos y privados que precisan de una toma de decisiones rápida.

Para poder conseguirlo, los principales objetivos serán:

- Integrar de un modo lo más sencillo posible una RNA entrenada en un sistema de Gestión de riesgos naturales.
- Aplicar el sistema neuronal creado, a diferentes elementos relacionados con los riesgos naturales (clima, agua, geología...).
- Recopilar y extrapolar los diferentes resultados obtenidos.
- Analizar dichos resultados.

La metodología a seguir estará basada en la revisión bibliográfica de trabajos relacionados con la temática y el trabajo de desarrollo y aplicación de los resultados.

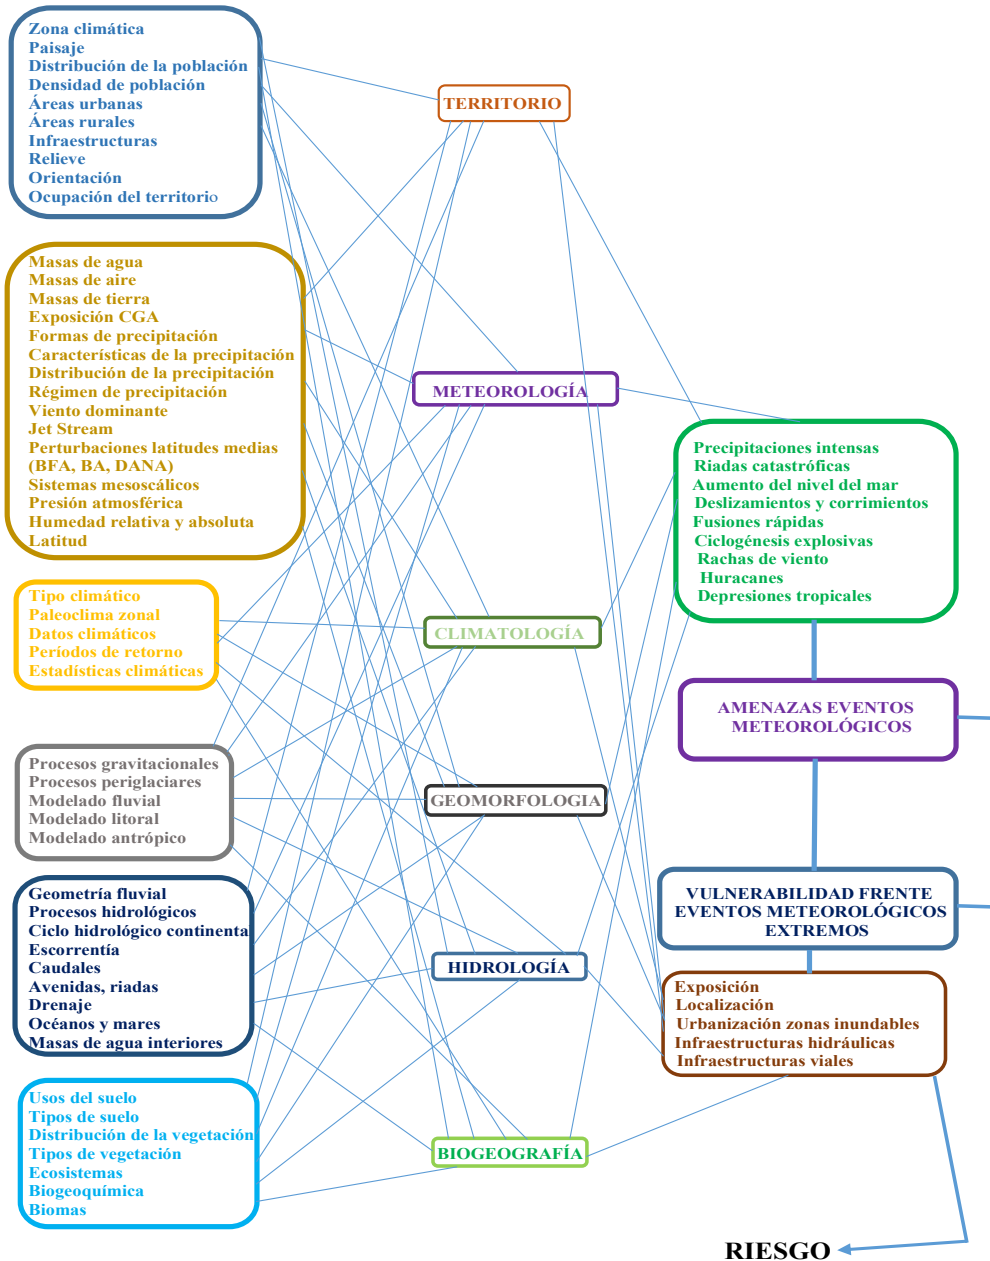
La hipótesis de trabajo estará basada en integrar adecuadamente una RNA entrenada para un elemento concreto y constatar si las variables introducidas son susceptibles de ser útiles para una posterior predicción y extrapolación de resultados.

3. Estructura de red neuronal artificial para la modelización de eventos meteorológicos extremos y algoritmos de cálculo de riesgo climático

A la hora de extraer conclusiones sobre la estructura de la RNA que se presenta en el punto anterior, se tendrá en cuenta que las diferentes interrelaciones que se den vendrán dadas por una serie de algoritmos que nos mostrarán los datos de salida que buscamos.

Estos algoritmos están basados en extrapolaciones y generalizaciones de datos estadísticos que se tomarán teniendo en cuenta una serie de patrones relacionados con el tema que nos ocupa.

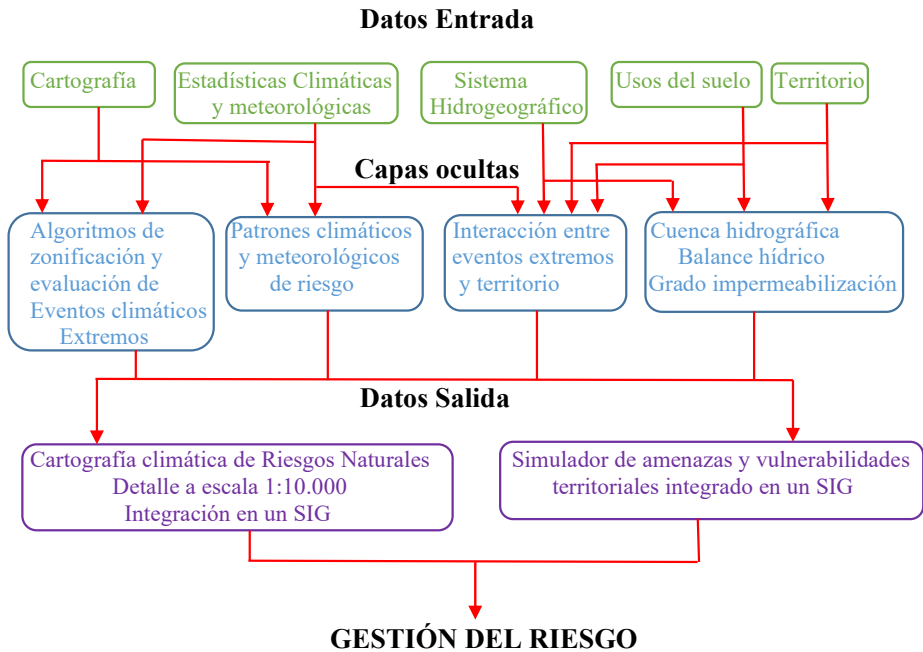
Figura 3. Estructura red neuronal artificial para la modelización climática.



Fuente: Elaboración propia.

Para ello se presenta el siguiente algoritmo de cálculo que ha servido de base para construir la arquitectura de la RNA.

Figura 4. Base arquitectónica de la RNA.



Fuente: Elaboración propia, a partir del Centro Agrimed Universidad de Chile.

4. Reflexiones a la manera de conclusiones

Siempre que se intenta trabajar sobre los riesgos naturales, hay que tener en cuenta que las variables, elementos y factores que interactúan, pueden llegar a ser casi infinitos. Cuando tratamos con un sistema tan sumamente complejo como es nuestro planeta, tan interrelacionado entre sus múltiples subsistemas subyacentes, y además teniendo en cuenta que es abierto al resto del universo, el reto es inmenso. Pero eso es lo que hace aún más atractivo el intentar acercarse a él.

En el caso que nos ocupa, que son los eventos meteorológicos extremos, se ha intentado tener en cuenta un gran abanico de variables que interaccionan entre ellas. Muchas más han quedado fuera, y no por ello son menos importantes, pero se ha buscado que las que están sean las más significativas para el caso estudiado. Los subsistemas que se han expuesto están basados en la Geografía Física, con la inclusión del territorio como variable que intenta agrupar la parte más regional y humana. Hay que tener claro que la RNA que se muestra no incide directamente sobre

temas sociales y de resiliencia, sino que se queda en la parte de modelización más física. Por supuesto que los demás subsistemas son igual de importantes o incluso más, pero se ha creído conveniente incidir más en las causas, que posteriormente derivarán en los efectos. Desde este punto de vista se intenta mostrar que, si el tratamiento de los datos y la modelización inicial es lo más exacta posible, se pueden reducir en gran manera los efectos derivados.

En ningún momento se ha intentado mostrar un aparato matemático que explique las causas y que otro lado es indispensable, pero dado que se trata de buscar un punto de vista más teórico, y que por otro lado compete a otros profesionales más expertos, se espera que este extremo no tenga una mayor repercusión en el resultado final de lo que se intenta demostrar. Sí que, tanto en la arquitectura de la RNA y del algoritmo que la rige, está implícita esa vertiente más matemática.

En definitiva, se ha buscado tener una herramienta que pueda ser lo más útil posible para tratar de paliar con la suficiente antelación, eventos catastróficos, que de bien seguro seguirán ocurriendo dada la variabilidad y diversidad geográfica y climática que encontramos en esta zona del Mediterráneo en la que vivimos.

Todo lo expuesto anteriormente, tiene en cuenta el actual estado del territorio en el que vivimos: infraestructuras actuales, obras hidráulicas, ocupación del territorio, usos del suelo, desaparición de zonas inundables, estrechamiento y ocupación de cauces, y demás variables que hacen que los efectos de estos eventos sean superiores en daños a si se tuviera en cuenta una gestión del territorio encaminada a favorecer que los sistemas naturales encuentren su equilibrio. Aun así, el presente trabajo no entra en la valoración de esas causas, ya que es un tema para posteriores trabajos.

5. Referencias

- Basogain Olave, X. (2008): Redes neuronales artificiales y sus aplicaciones. Curso Dpto. Ingeniería de sistemas y automática Escuela superior de Ingeniería de Bilbao. UPV-EHU.
- Gajate Martín, A. (2010): Modelado y control neuroborroso de sistemas complejos. Aplicación a procesos de mecanizado de alto rendimiento. Tesis doctoral. Universidad de Salamanca. Dpto. Informática y automática.
- Gutiérrez, J.M. et al., (2004): Redes probabilísticas y neuronales en las Ciencias atmosféricas. Series monográficas del Instituto Nacional de Meteorología. Ministerio de Medio ambiente. Madrid.
- Torrubia Caravaca, S. (2010): Redes neuronales multimodelo aplicados al control de sistemas. Memoria del proyecto de Ingeniería técnica en Informática de sistemas. Escola d'Enginyeria de Sabadell.
- Rodríguez Requena, A. (2018): Redes neuronales cuánticas. Academia de ciencias de la Región de Murcia.