

**Diseño de una red neuronal completamente conectada para la interpolación de datos complejos, asociados a la caracterización radiológica de zonas impactadas por radionúclidos naturales.**

**JF. Benavente<sup>(1)</sup>, VM. Expósito<sup>(1)</sup>, JA Suarez<sup>(1)</sup>**

<sup>(1)</sup> Ciemat – Unidad de Vigilancia Radiológica ambiental (URA)

**RESUMEN:** El estudio de resultados experimentales asociados a estudios geológicos, en muy pocas ocasiones permitirá el uso expresiones analíticas asociadas a geometrías euclidianas clásicas. Estos resultados suelen mostrar una elevada complejidad, debido fundamentalmente a que cada medida tomada, usualmente se asocia a un volumen elevado de variables, que no pueden ser computadas en su mayoría. Por ello, se ha extendido el uso de geometrías basadas en dimensiones fractales y/o complejas redes neurales, con el objeto de extrapolar datos desde un campo de variables discretas a uno de variables continuas, interrelacionando conjuntos distintos de variables, mediante el uso de un elevado número de datos. El presente trabajo, propone una compleja estructura numérica, basada en modelos asociados a redes neuronales completamente conectadas, que permitirá establecer una relación entre variables radiológicas tomadas in situ (zona radiológicamente impactada) y datos de concentración de actividad de distintos radioisótopos asociados a cadenas de desintegración radiactivas naturales.

## 1. INTRODUCCION.

El impacto radiológico en zonas donde se ha realizado actividades de minería es debido a la manipulación de mineral. Estos materiales contienen una determinada concentración radionúclidos de las series radiactivas naturales y se depositaba sin control en escombreras a modo de los estériles (o desechos de dicho mineral) en los entornos de las minas durante su periodo de explotación.

Tanto el proceso de deposición de estériles, como las complejas características de los relieves geológicos en los entornos mineros, hacen que los procesos de caracterización de dichas zonas, sea lo suficientemente complejos implicando la necesidad del uso de un conjunto considerablemente elevado de datos, por ello, la implantación de métodos numéricos basados en inteligencia artificial, se muestra especialmente útil, debido a la alta capacidad de estos para la gestión de un alto volumen de datos.

Tras la fase de toma de datos in situ y realización de las medidas radioquímicas en el laboratorio, este trabajo se centra en el desarrollo de modelos matemáticos, basados en algoritmo de Inteligencia Artificial, mediante el uso de redes neuronales<sup>[1,2,3]</sup> complemente conectados, para la regresión de datos. El uso de dichas herramientas numéricas permitirá tanto, pasar de un campo de variables discretas a continuas, utilizando los conjuntos de datos previamente indicados, como el análisis de la importancia de las variables independientes mediante la implementación de un Algoritmos de Garson<sup>[1,2,3]</sup>.

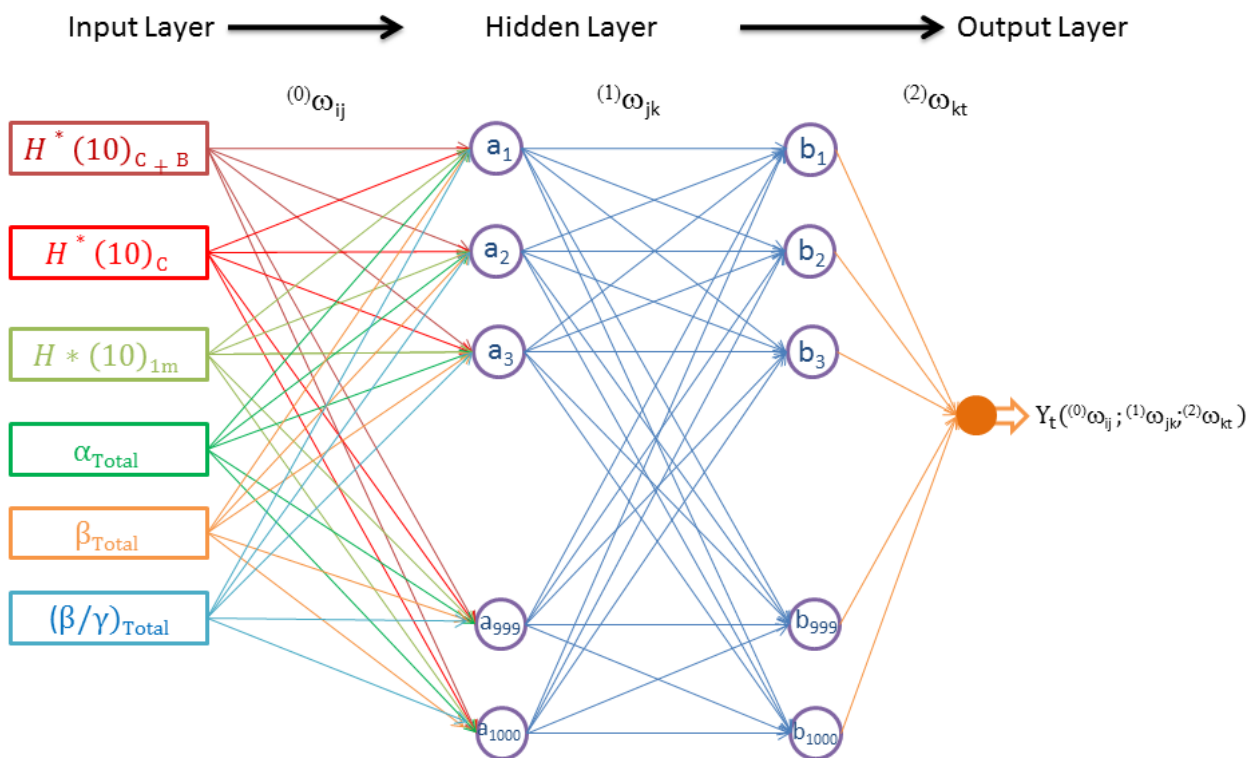
## 2. DESARROLLO/DESCRIPCIÓN.

La figura 1, muestra un esquema de la topología de la red neuronal desarrollada para la regresión de datos, cuyas características se resumen a continuación:

- a) **Capa de entrada** o variables independientes, compuesta por los seis valores medidos in situ, estos es:
  - a.  **$H^*(10)_{C+B}$** : Dosis equivalente ambiental (nSv), medida en contacto con blindaje de plomo de 5 cm de espesor.

- b.  $H^*(10)_C$ : Dosis equivalente ambiental (mSv) medida en contacto.
- c.  $H^*(10)_{1m}$ : Dosis equivalente ambiental (mSv), medida a un metro de la superficie del terreno.
- d.  $\alpha$ -Total: Número de cuentas medidas, asociadas a desintegraciones  $\alpha$ .
- e.  $\beta$ -Total: Número de cuentas medidas, asociadas a desintegraciones  $\beta$ .
- f.  $(\beta/\gamma)$ -Total: Numero de cuentas medidas, asociadas a desintegraciones  $\beta/\gamma$ .

Figura 1. Esquema de la Red Neural Completamente Conectada.



b) **Capa Oculta**, compuesta por un conjunto de neuronas por capas, cuya función de activación es una Función Relu, expresada de la forma:

$$a_j \left( \sum_i {}^{(0)}\omega_{ij} \cdot X_i \right) = \begin{cases} \sum_i {}^{(0)}\omega_{ij} \cdot X_i & ; \text{si } \sum_i {}^{(0)}\omega_{ij} \cdot X_i > 0 \\ 0 & ; \text{si } \sum_i {}^{(0)}\omega_{ij} \cdot X_i \leq 0 \end{cases}$$

$$b_k \left( \sum_j {}^{(1)}\omega_{jk} \cdot a_j \right) = \begin{cases} \sum_j {}^{(1)}\omega_{jk} \cdot a_j & ; \text{si } \sum_j {}^{(1)}\omega_{jk} \cdot a_j > 0 \\ 0 & ; \text{si } \sum_j {}^{(1)}\omega_{jk} \cdot a_j \leq 0 \end{cases}$$

c) **Capa de salida**, se utiliza una expresión lineal de la forma :

$$Y_{t=1} \left( \sum_k (2) \omega_{kt} \cdot b_k \right) = \sum_k (2) \omega_{kt} \cdot b_k$$

El valor óptimo de los pesos de la red  $[(n)w_{mn}]$  se obtiene minimizando la siguiente función de perdidas, durante la etapa de entrenamiento:

$$\text{Funcion Perdidas} = \frac{1}{2} \times \left( Y_t - \frac{A(Bq)}{M(Kg)} \right)^2$$

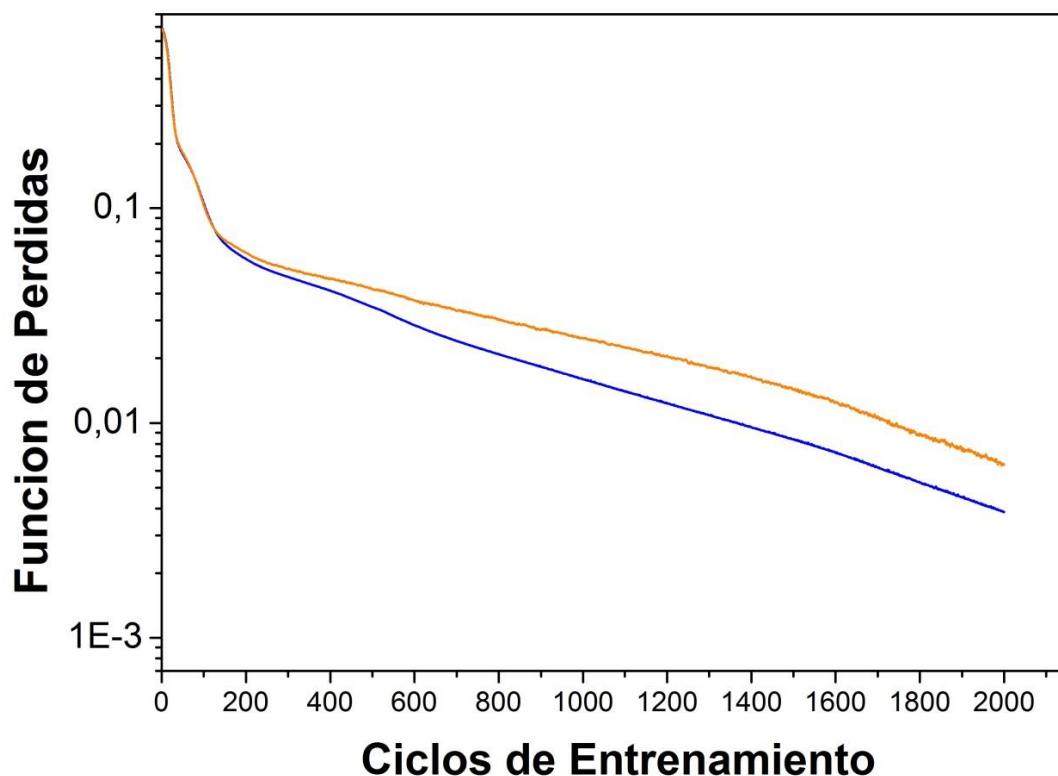
Mediante un método iterativo, denominado reducción del gradiente, expresado de la forma:

$$(n)\omega_{mn}|_{t+1} = (n)\omega_{mn}|_t - \alpha \frac{d(\text{Funcion Perdidas})}{d(n)\omega_{mn}}$$

### 3. RESULTADOS Y DISCUSIÓN.

La figura 2, muestra el proceso de convergencia hacia un mínimo de la función de perdidas asociado al modelo radioquímico del Pb-120, pertenecientes a la serie radiactiva del uranio, durante la etapa de entrenamiento.

Figura 2. Modelo del Pb-210: Línea azul (Entrenamiento), Línea Naranja (Test).



Durante el proceso de entrenamiento no se observa divergencia entre los datos de entrenamiento (Línea azul), destinado a optimizar los pesos de las relaciones sinápticas de cada neurona que componen la red, frente a los datos de testeo (Línea Naranja), lo cual implica que no existe sobredimensionamiento de la red desarrollada. Este resultado se reproduce en el resto de los radioisótopos caracterizados, tanto para la serie del uranio como la del actinio.

#### 4. CONCLUSIONES

Las redes neuronales desarrolladas en este trabajo permite asociar las medidas de radiación tomadas in-situ en zonas impactadas por minería con los resultados radioquímicos obtenidos en los laboratorios de la URAYVR del CIEMAT mediante modelos numéricos basadas en Inteligencia Artificial. La concentración de la actividad (Bq/Kg) estimadas por las redes neuronales y las obtenidas experimentalmente guarda un elevado grado de concordancia. Asimismo, los resultados obtenidos en la aplicación del algoritmo de Garson permiten conocer el peso que tienen las variables en dichos ajustes permitiendo la selección de los más idóneos en la interpretación final de los resultados.

#### 5. REFERENCIAS

- [1] Vapnik, V. (1995). The Nature of Statistical Learning Theory. Springer, New York.
- [2] Schölkopf, B., Burges, C. J. C., and Smola, A. J., editors (1998). Advances in Kernel Methods - Support Vector Learning. MIT Press, Cambridge, MA.
- [4] Cheney, W., Kincaid, D., 2002. Numerical Analysis: Mathematics of Scientific Computing. Texas University.