

Aplicación de modelos de redes neuronales artificiales a la determinación de movimientos en una presa bóveda

F.J. Riquelme, J. Fraile, D. Santillán, R. Morán & M.A. Toledo Muncio

Escuela Técnica Superior de Ingenieros de Caminos, Canales y Puertos, UPM, Madrid, España

ABSTRACT: The complexity of the dam-foundation makes difficult to interpret the records of auscultation. It is not easy to make a prognosis of the behavior of the dam in accordance with the different situations that may occur over the life of the dam. Nor is it easy to interpret the deviations observed from the values estimated by numerical or statistical modeling. Neural networks offer the possibility of treating the whole dam foundation as a complex system which rules of behavior are established solely on the basis of the observed behavior without making simplifying assumptions.

It has shaped the radial movement in different seasons of the pendulums available in a dam vault, which has been used as test case. We analyzed the response of the dam complex models growing. The simplest considered only as parameters determining the behavior reservoir level and a moving average of ambient temperatures (simple model). In order to model applicable to any pendulum of any dam, has raised the consideration of various means mobile temperature, so that is the model itself that determines the weight of each moving average (model general). Have also been raised as data models that incorporate the values of the movements measured immediately prior (short-term models).

The comparison of results obtained through each of the previous models of neural networks with statistical and numerical models commonly used that allows the use of neural network models useful for the interpretation of auscultation. The submission details the results obtained and the accuracy of the prognosis of each of the models studied. Models are expected to analyze incorporate additional time variable (dynamic models), to capture the effect of drift. This research is part of the R&D financed by the Ministerio de Ciencia e Innovación: estudio de la seguridad de presas e identificación de escenarios de riesgo mediante sistemas inteligentes, reference number 048/RN08/04.5.

1 INTRODUCCIÓN Y OBJETIVOS

A la hora de emitir juicios o valoraciones sobre el estado de funcionamiento de una presa es obligado hacer, entre otras muchas cosas, un análisis por-menorizado de los resultados que ofrece la instrumentación instalada. Este análisis, realizado con las herramientas convencionales ha resultado difícil, ya que la respuesta de la estructura presa-cimiento depende de un conjunto de variables, muchas de ellas no conocidas con profundidad, y con interrelaciones de dependencia entre ellas no sujetas a leyes puramente deterministas. Ello ha llevado a análisis probabilísticos con interpretaciones de cada uno de los parámetros basados en variables clave como el nivel de embalse o las temperaturas.

Todo este escenario se ve agravado en muchas ocasiones por la incertidumbre en la validez de los datos obtenidos bien por errores de lectura, defectos en los aparatos, etc. Además, con la interpretación tradicional es difícil modelar condicionantes como la puesta en obra, la heterogeneidad

del cemento o las características de los materiales utilizados en la construcción. Sobre estos suele existir información generada durante el proceso de control de calidad de la obra pero su interpretación depende de la habilidad del individuo que realiza el análisis de los datos (Calarasu et al., 2008).

Las redes neuronales permiten detectar las relaciones entre los distintos parámetros involucrados en fenómenos complejos, en los que un análisis puramente determinista puede dejar de lado factores de indudable importancia para caracterizar el comportamiento final del problema.

Estas circunstancias han motivado que este tipo de sistemas hayan sido utilizados recientemente para tratar de comprender y analizar fenómenos tan complejos como el modelo de respuesta de cuencas hidrológicas, el transporte de sedimentos y de elementos solubles.

Diversos autores han indagado en el uso de las redes neuronales en estructuras de todo tipo. En particular, las aplicaciones a presas resultan especialmente propicias para estas metodologías por la complejidad de las variables involucradas.

En (Ahmadi and Chouinard 2003) se utilizan redes neuronales como alternativa a los métodos estadísticos tradicionales para el análisis de variables de monitorización de presas y detección de posibles anomalías en desplazamientos, tensiones y flujos. Un análisis preliminar mostró que la temperatura del hormigón es en este caso el mejor predictor de los desplazamientos de los péndulos.

En (Tayfur and Swiatek 2005), se desarrolla un modelo de redes neuronales y otro de elementos finitos para comparar los resultados con las mediciones de flujos a través de una presa de materiales sueltos. Ambos modelos fueron calibrados y verificados utilizando un piezómetro en una sección de la presa, y obtuvieron resultados satisfactorios comparados con las mediciones de niveles de agua de los piezómetros. El estudio reveló que los modelos de redes neuronales pueden ser una buena herramienta para estudiar sub-presiones. Las variables de entrada usadas fueron el nivel de aguas arriba, el nivel de aguas abajo y la identificación numérica de los piezómetros.

El modelo de elementos finitos representa el mejor entendimiento del fenómeno físico del proceso. Las relaciones entre las variables de entrada y salida están bien definidas, obteniendo mejores resultados mientras más exhaustivo sea el conocimiento de los parámetros que intervienen en el fenómeno, lo que no es fácil, dada la complejidad de las relaciones entre parámetros.

El modelo de redes neuronales es un modelo más simple, que tiene la ventaja de reconocer patrones de relaciones entre variables cuando se alimenta con una colección suficiente de datos. Desde el punto de vista práctico, el uso de redes neuronales podría ser útil para la detección de anomalías en los regímenes de filtraciones, permitiendo tomar medidas inmediatas. Sin embargo se debe destacar que las redes neuronales son una caja negra que no aportan una relación explícita entre las distintas variables. Además, las redes neuronales proporcionan resultados satisfactorios dentro del rango de datos utilizado para su entrenamiento, pero fuera del mismo el resultado no resulta fiable.

En (Wen et al., 2004), entendiendo a las presas como un sistema vital e inteligente, se propone un esquema de manejo, proceso y análisis de información en tiempo real, en el que modelos de redes neuronales y lógica difusa se usan para crear una interfaz que pueda analizar y evaluar las características de funcionamiento de las presas. Estos modelos biónicos en una primer etapa capturan la información del entorno y el interior de las presas mediante una sistema de sensores distribuidos de forma adecuada en el cuerpo de presa y sus cimientos. Toda esta información es concentrada en una unidad de procesamiento central, que analiza y busca indicios de anomalías y, si las encuentra,

propone de forma dinámica contra-medidas al departamento de toma de decisiones, el que finalmente las implementa.

En (Salvaneschi et al., 1996) se destacan las ventajas de los sistemas de inteligencia artificial debido a la subjetividad involucrada en la interpretación de los datos de monitorizaciones de presas entre los cuales destaca el difícil manejo de grandes cantidades de información muchas veces incierta o incompleta, la necesidad de criterio ingenieril, conocimiento de la estructura particular, experiencia en el desarrollo de estructuras en general, y conocimientos generales de ingeniería para interpretar los datos. En (Calarasu et al., 2008), se pretende minimizar la subjetividad de los expertos humanos en la monitorización y predicción del comportamiento de las estructuras hidráulicas.

En esta investigación se pretende definir una metodología de análisis de datos de auscultación mediante el uso de redes neuronales y estudiar la calidad de los resultados obtenidos en comparación con los resultados de los modelos convencionales.

2 CASO PILOTO

Se usa como caso piloto de esta investigación a la Presa de la Baells que está situada en el río Llobregat en Barcelona. Es una presa de bóveda de 3 centros y doble curvatura. Tiene una altura de 102.35 m sobre cimiento, una longitud de coronación de 403 m, un espesor en el pic de presa de 20 m y de 4 m en el arco superior. Tiene una relación cuerda/altura de 2.75 (Fig. 1).




Figura 1. Presa de la Baells. Perfil.




Figura 2. Esquema de los péndulos en la presa. Se señala con un círculo la cota más alta del péndulo estudiado.

Se dispone de 30 años de registros de auscultación de esta presa, distribuidos de manera regular a lo largo de su vida, lo que permite estudiar su comportamiento desde su construcción. Se ha elegido esta presa como caso piloto por la cantidad de los datos disponibles.

3 VARIABLES DE ENTRADA Y SALIDA

Se estudia el comportamiento de la presa a través de los desplazamientos radiales de los péndulos, los cuales proveen de mediciones suficientemente fiables. La presa dispone de cuatro péndulos, cada uno con registros a cinco cotas distintas. Para disminuir, en la medida de lo posible, el ruido en las mediciones se estudian los desplazamiento radiales en la cota más alta de un péndulo central. En la figura 2 se muestra la ubicación del registro estudiado.

En los análisis convencionales de los datos de auscultación se explica el comportamiento de la presa a través de variables que sean capaces de representarlo de forma suficiente. Para esto, se debe tener en cuenta la existencia de deformaciones irreversibles, el efecto del nivel de embalse y el efecto diferido del ciclo térmico anual. En este sentido, se han escogido como variables de entrada de los modelos de redes neuronales las que representan estos efectos, y que se detallan en sucesivos apartados.

4 MODELO ESTADÍSTICO

El análisis de los datos de auscultación de presas se realiza normalmente a través de modelos estadísticos. Se divide el conjunto de datos en dos grupos consecutivos, el primero se usa para ajustar una función de aproximación y el segundo para validar los resultados.

4.1 Ciclo térmico anual

El primer paso en estos modelos es encontrar la onda térmica anual $T(t)$, usando para ello las

temperaturas medias diarias. Asumiendo un comportamiento periódico de las temperaturas se las representa en serie de Fourier. Usando la función de temperaturas se calculan las medias móviles de temperaturas de un período P , que tendrán la forma de la ecuación (1).

$$TMM_P(t) = \int_{t-P}^t \frac{T(s)}{P} ds \quad (1)$$

4.2 Efecto del tiempo

Existe un efecto irreversible en los desplazamientos de la presa debido a los movimientos reológicos que son más notorios en los primeros ciclos de la vida de la presa. Para modelar este efecto se usan funciones logarítmicas y exponenciales del tiempo.

4.3 Efecto del nivel de embalse

El efecto instantáneo del nivel de embalse sobre los desplazamientos se modela usando monomios de diversos grado de la cota de embalse.

4.4 Efecto agregado de variables

Se usan funciones de dos variables para modelar el efecto agregado de variables de distinta naturaleza como la temperatura y el nivel de embalse o el tiempo. Un ejemplo de estas funciones son las medias móviles de temperatura TMM_P que modifican la onda térmica anual en función de una inercia térmica asociada a un periodo de tiempo.

4.5 Ajuste y comprobación de los resultados

Se dispone de un total 1176 mediciones diarias de temperaturas, niveles de embalse y desplazamientos a lo largo de 30 años. Se usa un 60% de los datos para ajustar la función de aproximación y el 40% restante para validar el ajuste.

Aunque es usual utilizar temperaturas medias móviles de 30 días (TMM_{30}) en estos modelos, la naturaleza diversa de las presas y sus particulares características hacen necesario tantear cuál es la media móvil más apropiada para cada uno de sus péndulos. En este sentido, se ha estudiado cómo varían los resultados del ajuste usando diversas medias móviles en el caso piloto.

Se define el error relativo medio de aproximar un número n de desplazamientos δ_i mediante un valor $\hat{\delta}_i$ según la ecuación 2 y los errores máximo y mínimo según las ecuaciones 3 y 4.

$$e = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{\delta}_i - \delta_i}{\delta_i} \right| \quad (2)$$




Figura 3. Variación del error relativo medio al variar el periodo de la media móvil usada para aproximar. Se grafica el error relativo medio del 60% correspondiente al conjunto de ajuste y del 40% correspondiente a la comprobación del ajuste.

Tabla 1. Indicadores de bondad de aproximación del modelo estadístico de desplazamientos para el conjunto de datos de ajuste y de validación.

Indicador	Ajuste	Validación
e	0.10	0.13
e_{\max} (mm)	8.01	4.82
e_{\min} (mm)	-5.78	-4.00

$$e_{\max} = \max \left\{ \hat{\delta}_i - \delta_i \right\}_{i=1}^n \quad (3)$$

$$e_{\min} = \min \left\{ \hat{\delta}_i - \delta_i \right\}_{i=1}^n \quad (4)$$

En la figura 3 se observa que el periodo de la temperatura media móvil que produce menores errores tanto en el ajuste como en la comprobación es la TMM_{90} .

Este resultado preliminar se usará más adelante en la definición de las redes neuronales.

Se apuntan en la tabla 1 los principales indicadores de la bondad del ajuste realizado.

5 MODELOS DE REDES NEURONALES ARTIFICIALES

Antes de realizar un análisis con modelos de redes neuronales, es necesario determinar si la información disponible es suficiente para comprender el fenómeno. En este caso, la existencia de un modelo estadístico con buenos resultados permite asumir que así es.

Es necesario apuntar que se debe evitar interpolar las mediciones de la variable respuesta

(desplazamientos) pues, a priori, se desconoce lo sensible que puede ser a pequeñas variaciones de las demás variables. Respecto a los niveles de embalse, salvo casos excepcionales, suelen variar de forma lenta en el tiempo, por lo que interpolaciones lineales pueden ser apropiadas. Las temperaturas medias diarias, aunque oscilan en torno de la onda térmica anual, contienen abundante ruido intradiario, por lo que no resulta conveniente interpolarlas. En este sentido, es preferible interpolar directamente desde la ecuación de la onda térmica anual.

Para comparar los resultados de los modelos de redes neuronales con los estadísticos se usan los mismos datos de entrada y se dividen en los mismos dos conjuntos, uno de entrenamiento, correspondiente al primer 60% y otro, de validación, correspondiente al restante 40%.

5.1 Arquitectura de la red neuronal

La red se estructura en tres capas: la de entrada, donde habrá tantas neuronas como variables se usen para representar el comportamiento de la presa; la de salida, en que habrá una única variable correspondiente al desplazamiento estudiado, y la oculta, cuyo número de neuronas será objeto de estudio.

5.2 Algoritmo de aprendizaje

Se han publicado un gran número de artículos acerca de aplicaciones de redes neuronales a la ingeniería civil. La gran mayoría de estas aplicaciones están basadas en el algoritmo Back-Propagation (BP) (Budinich 1993; Habibagahi 1998; Barai and Pandey 1995; Meireles et al. 2003) que es un tipo de aprendizaje supervisado unidireccional, aunque también hay aplicaciones de otros modelos de redes neuronales más poderosos y eficientes (Adeli 2001).

El algoritmo BP consiste básicamente en extender la regla de aprendizaje por mínimos cuadrados medios a las arquitecturas multicapa. El error se minimiza en función de todos los pesos de la red, lo que se realiza a través de derivaciones sucesivas usando la regla de la cadena lo que exige que las funciones de transferencia sean derivables. En particular, para este estudio, las funciones de transferencia en la capa oculta son sigmoideas y la identidad para la capa de salida.

El algoritmo BP, de gran generalidad, se puede aplicar a multitud de problemas diferentes. Sin embargo su convergencia es lenta, por lo que sus resultados, aunque relativamente buenos, pueden ser sustancialmente mejorados. Además no garantiza que el error alcanzado sea un mínimo global, pudiendo quedar atrapado en un mínimo local.

Para solventar esta dificultad se ha optado por entrenar un mínimo de 100 veces cada red neuronal partiendo de pesos distintos en cada ocasión.

Las redes neuronales artificiales son susceptibles de incurrir en sobre-entrenamiento, esto es, que más allá de un determinado número de iteraciones de aprendizaje, la red comienza a mejorar la aproximación de los datos usados para enseñarla a costa de los usados para validar el modelo. Usando un símil con el aprendizaje biológico, la red memoriza los resultados sin comprender el fenómeno de fondo. Para evitar esto, los entrenamientos se han realizado calculando los errores sobre el conjunto de aprendizaje y de verificación en cada iteración. Cuando el error en el conjunto de verificación empeora, se detiene el entrenamiento. Para evitar paradas en falso se continúa con el aprendizaje hasta seis iteraciones más allá del mínimo error en el conjunto de verificación.

Se han estudiado tres modelos de redes neuronales, en los que se han usado distintas variables de entrada y cantidad de neuronas en la capa oculta. Se ha variado la complejidad de estos modelos buscando un mejor ajuste y nuevas aplicaciones.

5.3 Modelo simple

Es el más sencillo de los modelos estudiados. En la capa de entrada incluye únicamente el nivel de embalse y una variable representativa de la temperatura. Se ha hecho variar la cantidad de neuronas en la capa oculta según la regla 2^i , $i = 1, 8$ para estudiar este efecto en la bondad de ajuste del modelo.

Usando el resultado de los modelos estadísticos, en los que se estableció que usando TMM_{90} se obtienen mejores resultados que usando directamente T , se han comparado los errores relativos obtenidos. En la figura 4 se muestran estos

resultados. Destaca el hecho de que para alcanzar una precisión semejante a la de los modelos estadísticos, este modelo necesita de unas 64 neuronas en la capa oculta.

En la figura 5 se muestra la aproximación obtenida mediante el modelo simple y 16 neuronas en la capa oculta.

5.4 Modelo general

Este modelo incorpora en la capa de entrada el nivel de embalse, la temperatura media diaria T y todas las medias móviles intra-anales de temperatura cada 30 días TMM_p . Al incorporar todas las medias móviles pretende ser más flexible que el modelo simple, pues es la propia red la que pondera la importancia de las medias móviles más apropiadas a la variable, estación de lectura y presa estudiada. En la figura 6 se muestran los resultados obtenidos al usar el modelo general para aproximar los desplazamientos radiales de los péndulos 1D y 6I en las cotas 610 y 571 respectivamente.

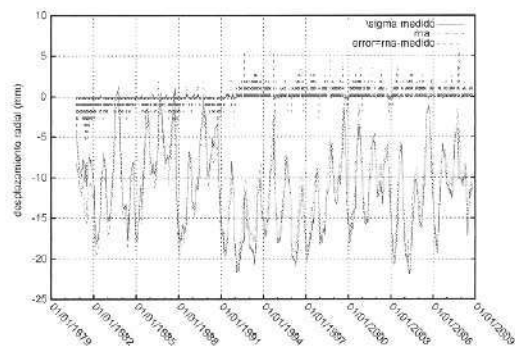


Figura 5. Desplazamiento aproximado usando el modelo simple con 16 neuronas en la capa oculta.




Figura 4. Variación del error de aproximación del desplazamiento usando temperaturas medias diarias T y media móvil de 90 días TMM_{90} .




Figura 6. Variación del error relativo al variar el número de neuronas de la capa oculta del modelo general.




Figura 7. Desplazamiento radial del péndulo 1D a la cota 610 msnm simulado con el modelo general de 128 neuronas en la capa oculta.




Figura 8. Variación del error relativo al variar el número de neuronas de la capa oculta del modelo de corto plazo.

Se observa que el error en este modelo es siempre menor que el del modelo estadístico.

En la figura 7 se muestra la aproximación realizada mediante una red neuronal de 128 neuronas en la capa oculta del modelo general para aproximar el desplazamiento radial del péndulo 1D en la cota 610 msnm.

5.5 Modelo de corto plazo

Es el modelo más complejo de los estudiados. Consta en la capa de entrada de todas las variables del modelo general más los desplazamientos de los tres días anteriores al que se predice. Es un modelo de actualización diaria, por lo tanto es el más costoso computacionalmente, ya que se entrena la red diariamente para predecir los desplazamientos del día siguiente. Incluir estos tres desplazamientos es equivalente a dar información respecto a la tendencia del movimiento del péndulo. Al igual que en el modelo general, con esta configuración se permite a la red ponderar la importancia de las distintas

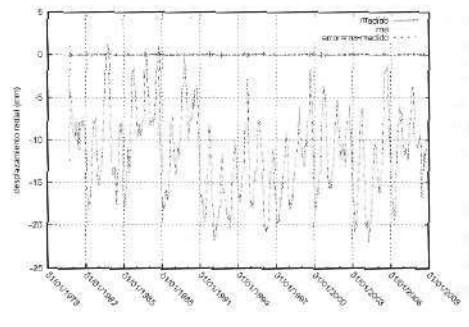


Figura 9. Desplazamiento radial del péndulo 1D a la cota 610 msnm simulado con un modelo de corto plazo.

medias móviles en el comportamiento de la presa sin que haya un preproceso fuera del ámbito de la red. Usando este modelo se obtienen resultados con errores varios ordenes de magnitud menores que con los demás modelos. Esto se debe a que se predicen los desplazamientos a muy corto plazo.

La figura 9 muestra los resultados obtenidos al usar la arquitectura del modelo de corto plazo y una capa oculta de 256 neuronas para el péndulo 1D a la cota 610 msnm.

6 CONCLUSIONES

Se ha representado el comportamiento de la presa mediante los desplazamientos de sus péndulos, y se han obtenido modelos estadísticos de estos. Se ha definido un modelo simple, uno general y uno de corto plazo para los desplazamientos de los péndulos usando redes neuronales. Se ha comprobado que con los modelos de redes neuronales se obtienen resultados que pueden ser iguales o mejores que los del modelo estadístico. Se ha constatado que el modelo general y el de corto plazo tienen un mayor coste computacional que el modelo estadístico. El modelo general tiene una mayor flexibilidad en su aplicación que el modelo simple y el estadístico.

AGRADECIMIENTOS

Los autores agradecen a la empresa Ofiteco por los datos de mediciones de la Presa de la Baells y a la Agencia Catalana del Agua.

BIBLIOGRAFÍA

Adeli, H. (2001). Neural networks in civil engineering: 1989–2000. *Computer-Aided Civil and Infrastructure Engineering* 16, 126–142.

- Ahrnadi, B. and Chouinard, L. (2003). Use of artificial neural networks for real time analysis of dam monitoring data. *Annual Conference of the Canadian Society for Civil Engineering*.
- Barai, S. and Pandey, P. (1995). Performance of the generalized delta rule in structural damage detection. *Engng Applic. Artif. Intell.* 8, 211–221.
- Budinich, M. (1993). Some notes on perceptron learning. *IEEE* —, —.
- Habibagahi, G. (1998). Reservoir induced earthquakes analyzed via radial basis function networks. *Soil Dynamics and earthquake Engineering* 17, 53–56.
- Meireles, M., Almeida, P. and Godoy, M. (2003). A comprehensive review for industrial applicability of artificial neural networks. *IEEE Transactions on Industrial Electronics* 50, 585–601.
- Salvaneschi, P., Cadei, M. and Lazzari, M. (1996). Applying ai to structural safety monitoring and evaluation. *AI in Civil and Structural Engineering* —, 24–34.
- Tayfur, G. and Swiatek, D. (2005). Case study: Finite element method and artificial neural network model for flow through jeriesko earthfill dam in poland. *Journal of Hydraulic Engineering* 131, 431–440.
- Wen, Z., Wu, Z. and Su, H. (2004). Safety monitoring system of dam based on bionics. *Proceedings of the Third International Conference on Machine Learning and Cybernetics*, 1099–1104.