

Redes neuronales para el análisis de márgenes de seguridad mediante códigos BE+U

M. Villamizar, S. Martorell (*), J.F. Villanueva, S. Carlos, A. Sánchez,
V. Serradell, R. Mendizabal, F. Pelayo, I. Sol.

Universidad Politécnica de Valencia
Camino de Vera, s/n. 46022 Valencia, España
marville@doctor.upv.es, (*) smartore@iqn.upv.es, jovillo0@iqn.upv.es

Resumen

La cada vez mayor capacidad de cálculo está permitiendo aportar nuevas herramientas de análisis dentro del contexto de evaluación de seguridad de centrales nucleares mediante la utilización de herramientas de cálculo realistas con estimación de las incertidumbres asociadas, en inglés conocido como BE+U (Best Estimate + Uncertainties). Un ejemplo de particular importancia es la evaluación de márgenes de seguridad correspondientes a secuencias accidentales del APS (Análisis Probabilista de Seguridad) mediante códigos termohidráulicos tipo RELAP, TRACE, etc., atendiendo de manera explícita al efecto de las incertidumbres de todo tipo.

En dicho contexto es particularmente importante, en primer lugar, diagnosticar, es decir, caracterizar y priorizar las incertidumbres epistémicas más significativas y su contribución a la incertidumbre en la estimación de dicho margen. En segundo lugar, resulta altamente deseable poder establecer un modelo que, partiendo del análisis anterior, permita propagar el efecto de las incertidumbres de entrada sobre la estimación de dicho margen de seguridad como variable de salida del modelo. Utilizando los resultados de la propagación de la incertidumbre es posible realizar un análisis de sensibilidad utilizando el método de descomposición de la varianza (Saltelli, 2000).

En esta ponencia se presenta el uso de herramientas “Soft Computing”, en concreto el uso de Redes Neuronales Artificiales (RNA) y el método de descomposición de la varianza como análisis de sensibilidad, que permite comprender y modelar las relaciones entre las variables inciertas de entrada “inputs” (definidas por funciones de distribución de parámetros del modelo termohidráulico) y la variable de salida “outputs”, e.g. la PCT (peaking clad temperatura). La presentación se desarrolla sobre un accidente LOCA grande en un PWR como caso de aplicación.

La ponencia forma parte del trabajo de colaboración enmarcado en el proyecto de investigación STN/2369/08/640 financiado por el Consejo de Seguridad Nuclear.

1. Introducción

El uso de códigos termohidráulicos BE (Best estimate) está siendo ampliamente utilizado en el análisis de seguridad nuclear con el objetivo de estudiar la respuesta de los sistemas nucleares en operación y accidente. Uno de los problemas derivados del

uso de estos códigos termohidráulicos es el elevado coste computacional. La mayoría de los códigos emplean en la simulación del comportamiento de la planta ante un determinado accidente, tiempos computacionales muy elevados, incluso de varios días. Como consecuencia de ello resulta interesante la aplicación de métodos predictivos, tales como las Redes Neuronales Artificiales RNA, que permiten obtener los valores de variables críticas termohidráulicas, (como por ejemplo la Temperatura Máxima de Vaina) para unas determinadas condiciones iniciales.

El caso abordado en la presente ponencia, es la simulación de los fenómenos más relevantes durante un escenario de accidente LBLOCA. El accidente tipo LBLOCA corresponde a una “gran rotura” (a partir de 6” hasta Doble guillotina) en la barrera de presión del refrigerante del reactor PWR que provoca una tasa de pérdida de refrigerante, por unidad de tiempo, superior a la capacidad total de los sistemas de aporte en operación normal. Dicho accidente se caracteriza por el comportamiento de la Temperatura de Vaina, durante todo el transitorio LBLOCA.

A la hora de estudiar estos transitorios es importante integrar las incertidumbres aleatorias y epistémicas, propias del sistema, las cuales están asociadas a los modelos y parámetros de los códigos deterministas y probabilistas usados para simular el comportamiento del sistema. Este procedimiento permite obtener mediante simulación soluciones físicamente reales y una mejor descripción de las interacciones en sistemas complejos, permitiendo modelizar los parámetros de entrada en todo su espectro de variación. Por tanto, sus soluciones pueden ser utilizadas en construcción de modelos predictivos, que permitan estimar comportamientos de los parámetros comparables con los obtenidos mediante la simulación, con un adecuado equilibrio entre precisión y esfuerzo computacional.

En esta ponencia el LBLOCA es simulado utilizando el código RELAP 5, con muestras que cubren la variación de los parámetros de entrada, obteniéndose mediante sucesivas simulaciones una muestra representativa de los posibles comportamientos de la temperatura dadas unas condiciones iniciales. Posteriormente, se construyen el modelo de predicción utilizando RNA, para predecir la Temperatura Máxima de Vaina, dadas unas condiciones iniciales. Finalmente, se realiza un análisis de sensibilidad utilizando el método de descomposición de la varianza para evaluar la relación entre las incertidumbres de las variables de entrada y la incertidumbre del resultado del modelo en este caso la PCT. El caso de aplicación se tiene en cuenta 37 variables y 286 simulaciones.

2. Redes neuronales

Las Redes Neuronales Artificiales (RNA), imitan determinados aspectos del funcionamiento del cerebro humano. Las RNA, han experimentado un gran desarrollo en estos últimos años gracias al descubrimiento de su excelente comportamiento en problemas de reconocimiento de patrones, predicción y clasificación, así como su no dependencia respecto a hipótesis de partida.

De forma general (Hopfield, J.J 1982), las neuronas presentan una serie de ramificaciones denominadas “dendritas” y una ramificación llamada “axón”. El axón transporta la señal de salida de la neurona hacia otras neuronas. Por otro lado, las entradas le llegan a través de las dendritas, procedentes de los axones de otras células. Las conexiones existentes entre el axón de una neurona y la dendrita de otra, se denomina “sinapsis”. Una neurona sólo se activará si la influencia colectiva de todas sus entradas supera un nivel mínimo de potencia eléctrica.

Cada neurona calcula el nivel de activación, teniendo en cuenta, la suma ponderada de los valores de entrada, además de la función de activación o de transferencia. En los perceptrones multicapa se usa como función de activación una función derivable, ya que, la derivabilidad es una condición necesaria para abordar el problema mediante el método del descenso por gradiente, (Hopfield, J.J 1982).

Las arquitecturas de la RNA varían en complejidad. Desde algunas muy simples que tienen una sólo capa neuronal (Entrada-Salida), hasta otras que están estructuradas en varias capas, y presentan mayor número de neuronas. La primera capa, en estos casos, se conoce como capa de entrada, después están la(s) capa(s) ocultas, con diversas combinaciones de neuronas y, finalmente, aparece la capa de salida.

El la Figura 1 se presenta de forma general, el esquema de funcionamiento de una red neuronal:

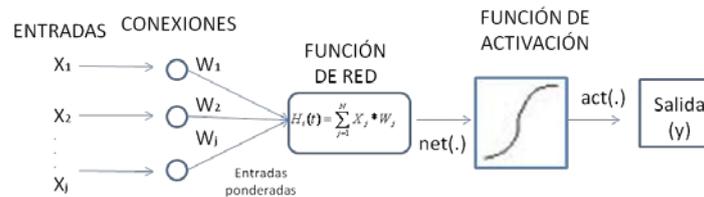


Figura 1. Esquema de funcionamiento de una red neuronal

La Figura 1 muestra que la capa de entrada está compuesta por las variables de entrada, las cuales envían la información a las neuronas de la capa o capas ocultas. En cada neurona de la capa oculta ocurre un proceso matemático denominado función de red, el cual consiste en la suma de las multiplicaciones de cada dato de información por sus pesos ponderados para determinar el potencial sináptico a introducir en la función de activación o transferencia, (Hopfield, J.J 1982).

La función de red es por tanto, un sumatorio ponderado entre los valores de las variables de entrada por sus respectivos pesos. Mientras que la función de activación o transferencia generalmente son de 5 tipos: la función lineal, función de escalón, función sigmoide, función tangente hiperbólica y la función gaussiana. Por tanto, las neuronas de la capa oculta o intermedia transforman las señales recibidas mediante la aplicación de una función de activación o transferencia proporcionando un valor de salida. La Ecuación 1 presenta un tipo de función sigmoide utilizada regularmente en las redes neuronales como función de activación:

$$f(x) = \frac{1}{1 + e^{-H_i}}$$

(1)

Una vez establecida la función de activación, la red neuronal presenta una etapa de entrenamiento donde se modifican los pesos de la red de manera que coincida el valor real de la Y con el estimado por la red neuronal. La desviación entre el valor real y el estimado, es considerada el error de la red neuronal. Para disminuir el error se realiza la modificación de los pesos en un valor proporcional al gradiente decreciente de dicha función de error. La base matemática del uno de los algoritmos para modificación de los pesos es la técnica conocida como gradiente decreciente. De forma general, el algoritmo encuentra un valor mínimo de error mediante la aplicación de pasos (gradiente) descendente. Cada punto de la superficie de la función corresponde a un conjunto de valores de los pesos de la red. Con el gradiente descendente, siempre que se realice un cambio en todos los pesos de la red, se asegura el descenso por la superficie del error hasta encontrar el valle más cercano, (Hopfield, J.J 1982).

3. El método de descomposición de la varianza

El análisis de sensibilidad permite determinar los factores que más contribuyen a la variación de los datos de salida, de forma que se puede conocer qué resultados son menos estables en el modelo y, por tanto, donde hay que seguir investigando para eliminar la incertidumbre. El propósito del análisis de sensibilidad consiste en determinar las relaciones entre la incertidumbre en las variables usadas en el análisis y la incertidumbre en las variables dependientes resultantes.

El método de descomposición de la varianza es, posiblemente, el procedimiento más informativo e intuitivo con el que resumir la incertidumbre en el resultado del análisis consecuencia de la incertidumbre en las variables de entrada. Este procedimiento utiliza diferentes medidas para cuantificar esta incertidumbre tales como (Saltelli, 2000):

$$s_j = \frac{\text{Var}(E(f(\mathbf{x}) | x_j))}{\text{Var}(f(\mathbf{x}))} \quad (2)$$

y

$$T_j = \frac{E(\text{Var}(f(\mathbf{x}) | \mathbf{x}_{(-j)}))}{\text{Var}(f(\mathbf{x}))} = \frac{\text{Var}(f(\mathbf{x})) - \text{Var}(E(f(\mathbf{x}) | \mathbf{x}_{(-j)}))}{\text{Var}(f(\mathbf{x}))} \quad (3)$$

donde $\mathbf{x}_{(-j)} = (x_1, \dots, x_{j-1}, x_{j+1}, \dots, x_p)$. El numerador de la Ecuación (2) es una medida de la sensibilidad de $f(\mathbf{x})$ con respecto al factor x_j , al dividir por la varianza total de $f(\mathbf{x})$ se obtiene la fracción de la incertidumbre en $f(\mathbf{x})$ atribuida a x_j denominándose índice de sensibilidad de primer orden s_j . T_j , dado por la Ecuación (3) corresponde a la fracción de incertidumbre en $f(\mathbf{x})$ que puede ser atribuida a x_j y sus interacciones con otras variables.

En el caso de modelos puramente aditivos se cumple que $\sum s_j = 1$, mientras que para un factor dado x_j una diferencia importante en la media de T_j y s_j representa un papel importante de las interacciones para este factor en $f(\mathbf{x})$.

Un procedimiento alternativo para la evaluación directa de T_j es el uso de un meta-modelo para f el cual se denota por \hat{f} . Esta aproximación supone utilizar una muestra de tamaño n desde la distribución conjunta de \mathbf{x} (por ejemplo, una muestra aleatoria simple) y evaluar el modelo en cada uno de los n puntos. Los valores obtenidos de la evaluación del modelo pueden ser utilizados para crear un meta-modelo para f . El método que se utiliza comúnmente para la estimación de la función es desarrollar una regresión lineal utilizando un modelo lineal en cada una de las entradas, por ejemplo:

$$\mathbf{y} = f(\mathbf{x}) + \varepsilon \quad (4)$$

donde $\mathbf{y}=(y_1, y_2, \dots, y_n)$ es el vector de salida, $\mathbf{x}=[x_1, x_2, \dots, x_p]$ es la matriz de entrada y ε es el vector de error.

Integrando las Regresiones no Paramétricas al análisis de sensibilidad propuesto por Saltelli (2000), se pueden obtener modelos más robustos que permiten analizar relaciones no lineales entre las variables de entrada y de salida, sin una gran cantidad de simulaciones. Una alternativa es calcular el índice de sensibilidad de Sobol actualizado por Homma y Saltelli en el 1996, en donde f y T_j se estimara a partir de modelos de regresión no paramétrica (Saltelli, 2000). En esta ocasión la regresión no paramétrica utilizada son los modelos Aditivos generalizados "GAM".

De forma general, un Modelo Lineal Generalizado (GAM) es un modelo con un predictor lineal definido a través de una suma de funciones suaves de las covariables (Hastie, T & Tibshirani, R. 1986). El nombre "Generalized Additive Model" ha sido acuñado por Hastie y Tibshirani, quienes fueron los primeros que propusieron este tipo de modelos así como diversos procedimientos para su estimación y contraste. La técnica específica de estimación que propusieron se llama backtting. El GAM tiene la ventaja de poder integrar una gran variedad de procedimientos de suavización habituales (como los arboles de regresión) pero su punto débil está en la estimación del grado de suavización del modelo.

4. Caso de aplicación

En esta ocasión se plantea el uso de redes neuronales artificiales y el método de descomposición de la varianza, para la diagnosis y prognosis del efecto de las incertidumbres en la estimación de la PCT, partiendo de de los resultados obtenidos en la simulación de transitorios termohidráulicos mediante un código "Best Estimate". Para simplificar se ha estudiado una única secuencia del APS nivel 1 de un PWR cuyo iniciador es un LOCA grande (LBLOCA), aunque puede aplicarse de forma análoga a otros escenarios accidentales. La Figura 1, muestra la secuencia accidental analizada.

Large LOCA	Injection from accumulators	LPIS	Recirculation from containment	Consequence
				OK
				CD
				CD
				CD

Figura 1. Secuencias accidentales de un LBLOCA.

El APS asume que tras producirse un LBLOCA en la rama fría de un reactor PWR se produce una despresurización que lleva a la inyección de seguridad desde los acumuladores. Si la despresurización continúa, debe producirse una segunda inyección usando al menos una de las dos bombas del sistema de inyección de baja desde el Tanque de Almacenamiento de Agua de Recarga, hasta que se produce la señal de bajo nivel. En este instante comienza la recirculación desde el sumidero de contención, siendo el tiempo máximo disponible para alineación limitado por la señal de muy bajo nivel según el APS. El transitorio ha sido simulado, como se mencionó anteriormente, con el código RELAP 5 utilizando un modelo de una instalación PWR de cuatro lazos. El modelo presenta dos lazos, uno en el que se produce la rotura y otro en el que se colapsa los tres lazos intactos de la instalación. Al analizar la barrera del combustible nuclear durante un escenario LOCA, las variables de seguridad son: la temperatura de vaina (PCT), la máxima oxidación local (LMO) y la oxidación del núcleo (CWO), y la incertidumbre está asociada a las condiciones iniciales y de contorno de los modelos. En 1989 la metodología CSAU estableció las bases para generar funciones de densidad asociadas a la carga (USNRC, 1989). Se han simulado 700 s. de transitorio, de la secuencia de la Figura 1.

La aplicación tiene por objetivo la diagnosis y prognosis del efecto de las diferentes variables en el comportamiento de la temperatura de vaina durante todo el transitorio LBLOCA, teniendo en cuenta las incertidumbres introducidas por los modelos termohidráulicos y probabilistas. En este contexto, se incluyen las incertidumbres asociadas a 26 parámetros; los más representativos para la secuencia, y que se presentan en la Tabla 1, (Frepoli, C. 2008; Lee SY & Ban CH, 2004; M.Y. Young et al., 1998; Martin, R.P. et al., 2005; Bajorek, S.M. et al., 2010; Wulff W, 1990).

Variable	Tipo Distribución	Variable	Tipo Distribución
Potencia Nominal (PN)	Normal	Señal Disparo Reactor (SDR)	Uniforme
Potencia Parada (PP)	Normal	Señal Inyección de Seguridad (SIS)	Uniforme
Calor Específico Combustible (CEC)	Normal	Variable	Tipo Distribución
Conductividad Térmica Combustible (CTC)	Normal	Presión Descarga (PDA)	Uniforme
Axial Peaking Factor (PF)	Normal	Volumen Llenado (VLA)	Uniforme
Hot Gap Size (HGS)	Normal	Temperatura (TA)	Normal
Variable	Tipo Distribución	Pérdidas Tubería (PTA)	LogNormal
Nivel (NP)	Normal	Variable	Tipo Distribución
Pérdidas Tubería (PTP)	LogNormal	Presión (PC)	Uniforme
Variable	Tipo Distribución	Temperatura (TC)	Uniforme
Tamaño de Rotura (TR)	LogNormal	Variable	Tipo Distribución
Coefficiente de Descarga (CD)	Uniforme	Señal Bajo Nivel Tanque (SBNT)	Uniforme
Variable	Tipo Distribución	Señal Muy Bajo Nivel Tanque (SMBNT)	Uniforme
Presión Inyección (PIS)	Uniforme	Tiempo Transición a Recirculación (TTR)	Uniforme
Caudal Inyección (CIS)	Normal	Caudal Recirculación (CRS)	Normal
Temperatura (TIS)	Uniforme	Temperatura (TRS)	Uniforme

Tabla 1. Relación de Parámetros

A partir de 286 muestras se han realizado las correspondientes ejecuciones del código para obtener el valor de la PCT considerando en primer lugar potencia nominal y repitiendo los casos con un aumento de la potencia del 10%. En la Figuras 2 y 3 se observan los distintos comportamientos de la evolución de la temperatura de vaina con una Potencia Inicial y con el incremento de potencia del 10%.

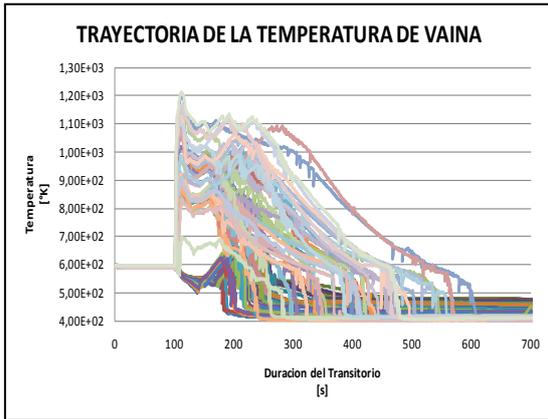


Figura. 2. Evolución de la temperatura de vaina para potencia nominal

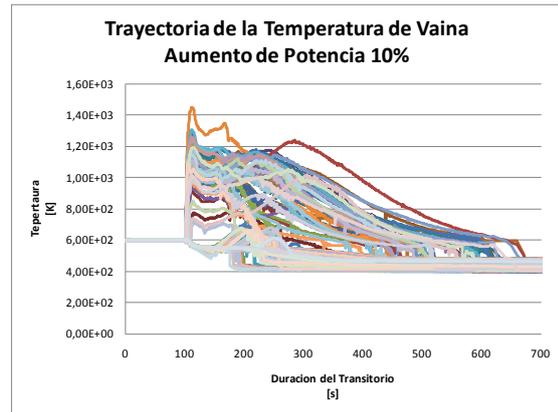


Figura. 3. Evolución de la temperatura de vaina para un Aumento de Potencias del 10%

A continuación, se diseña una red neuronal artificial utilizando como matriz de datos la evolución de la Temperatura de Vaina con potencia inicial, durante los 700 segundos simulados. El objetivo obtener la importancia de los parámetros en la predicción de la Máxima Temperatura de Vaina PCT. Se desarrolló un modelo neuronal artificial compuesto por 6 neuronas de entrada, una capa oculta de procesamiento de información compuesta por 1 neuronas, utilizando la función sigmoideal dada por la Ecuación 1, como medio de comunicación y una neurona de salida representando la variable dependientes del modelo en este caso la PCT. La red diseñada se muestra en la Figura 4, (la cual se ejecuto 30 veces).

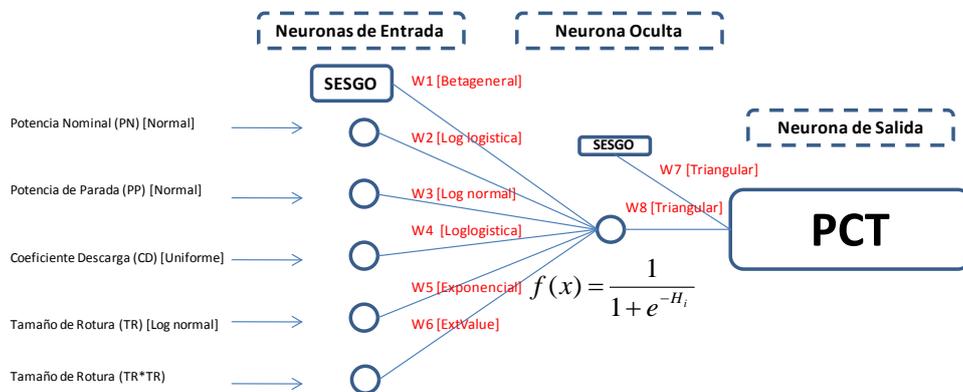


Figura 4. Estructura de la red neuronal

El análisis mediante redes neuronales se realizó utilizando la herramienta informática SPSS (SPSS, 2007). El ajuste promedio de la red neuronal fue de $R^2=94.28\%$, el análisis de importancias de las diferentes redes neuronales muestra que los resultados están dominados por orden de importancia son: el efecto cuadrático del Tamaño de Rotura (TR), Tamaño de rotura (TR), Coeficiente de Descarga (CD), Potencia Nominal (PN) y Potencia de Parada (PP).

Por tanto, el Tamaño de rotura además de su efecto cuadrático son las variables más importantes respecto al poder predictivo que tienen sobre la PCT. Finalmente, se extrae la ecuación de predicción de la red neuronal artificial que permite predecir la variable a explicar en este caso la PCT con las variables explicativas (tamaño de rotura, coeficiente de descarga etc...), para posteriormente utilizarla en la propagación de las incertidumbres. Para realizar la propagación de la incertidumbre se reemplazó en la ecuación de la red neuronal cada variable como función de distribución. Respecto a la función de distribución de los pesos, se ejecutaron 30 redes neuronales de las que se extrajeron los valores de los pesos para posteriormente ajustarlos a una función de distribución utilizando el programa @Risk. A continuación se realizaron 300 simulaciones mediante el método de muestreo Hipercubo Latino, utilizando la ecuación de predicción de la red neuronal artificial, obteniéndose de esta forma los estadísticos característicos de la PCT como son los percentiles 5%, 95%, etc. (se utilizó el programa @Risk para la propagación de la incertidumbre). La Figura 6 presenta la función de densidad de la PCT y algunos de sus estadísticos (media, 5% y 95%).

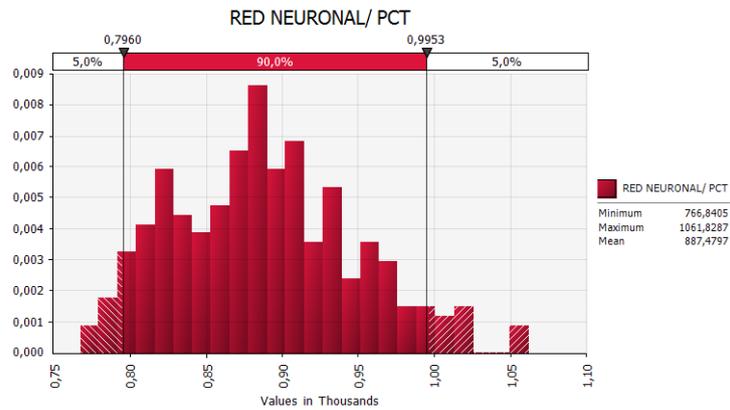


Figura 6. Propagación de las incertidumbres al cálculo de la PCT utilizando la ecuación del PLS (Software @Risk)

En esta ocasión se observa que el valor medio de la PCT que se obtuvo a través de la propagación de la incertidumbre, por medio de muestreo por hipercubo latino está desplazado a valores superiores con respecto al valor medio de los valores reales obtenidos a través del RELAP, por tanto es necesario complicar el modelo incluyendo más neuronas en la capa intermedia. En la Tabla 2, se presentan los valores medios de la PCT reales y tras la propagación de la incertidumbre utilizando redes neuronales.

	Valor medio	Simulación (Propagación de la incertidumbre utilizando redes neuronales)		
	Reales por RELAP	Valor medio de la PCT	Mínimo	Máximo
PCT	759	887.4797	766,8405	1061.8287

Tabla 2. Resumen de valores medios

Como se menciona en la introducción en esta ponencia se usó el método de descomposición de la varianza de Sobol (Saltelli, A, 2000) para análisis de sensibilidad. Utilizando el GAM (Hastie, T & Tibshirani, R. 1986), en la estimación de los índices de Sobol se obtienen los siguientes resultados:

Modelo: GAM	$R^2=0.999$		
Covariable	s_i	T_i	Intervalo para el T_i al 95%
Peso W_7	0.507	0.503	[0.985, 1]
Peso W_8	0.477	0.984	[0.951, 0.982]
TR	0.00	0.007	[0.000, 0.008]

Tabla 3. Resultados del análisis de sensibilidad a la PCT utilizando la regresión no paramétrica GAM

Finalmente, el 50.7% de la incertidumbre del valor de la PCT se atribuye a la incertidumbre propia del peso W_7 y 47.7% al efecto de la incertidumbre del peso W_8 . Lo cual indica que prácticamente toda la incertidumbre de la PCT utilizando la red neuronal artificial se debe a la incertidumbre propia de los pesos de la neurona intermedia, por tanto se propone como trabajo futuro ajustar el modelo incluyendo más neuronas en la capa intermedia.

Observaciones finales

La predicción del comportamiento de determinadas variables críticas en el contexto de accidentes termohidráulicos es un problema complejo con un alto coste computacional. En la presente ponencia se propone el uso de RNA como método de predicción y una primera aproximación a su uso en la propagación de incertidumbres. La arquitectura neuronal desarrollada y entrenada mediante el algoritmo Perceptrón Multicapa permitió predecir la Temperatura Máxima de Vaina con un ajuste en promedio de $R^2=94.28\%$. Respecto a los resultados obtenidos con las redes neuronales, se observó que los parámetros más relevantes al analizar la PCT son efecto cuadrático del Tamaño de Rotura (TR), Tamaño de rotura (TR), Coeficiente de Descarga (CD), Potencia Nominal (PN) y Potencia de Parada (PP). Se observa que el valor medio de la PCT que se obtuvo a través de la propagación de la incertidumbre, por medio de muestreo por hipercubo latino esta desplazada valores superiores con respecto al valor medio de los valores reales obtenidos a través del RELAP, por tanto se propone como trabajo futuro ajustar el modelo incluyendo más neuronas en la capa intermedia. El análisis de sensibilidad ha servido para comprobar la robustez del modelo, observando cómo varían la PCT en función de las modificaciones de las variables de entrada dadas por las funciones de distribución de cada una de ellas ($TR_{[Lognormal]}$, $CD_{[Uniforme]}$, $PN_{[Normal]}$, y $PP_{[Normal]}$), y la incertidumbre de los pesos dentro de la estructura de la red neuronal propuesta (W_1 [Betageneral], W_2 [Log logistica], W_3 [Log normal], W_4 [Loglogistica], W_5 [Exponencial], W_6 [ExtValue], W_7 [Triangular] y W_8 [Triangular]) podemos concluir que la incertidumbre de los pesos W_7 [Triangular] y W_8 [Triangular] son respecto al impacto en la incertidumbres de la PCT los más importantes. Es importante resaltar que las técnicas estadísticas son de gran utilidad cuando se trabaja con modelos donde interviene una gran cantidad de variables, ya que, permiten identificar las variables más relevantes cuantificando su importancia. Acotando así, el número de variables de las que depende una variable respuesta, (en este caso la PCT) y reducir así el esfuerzo computacional para evaluarlas.

Referencias

@RISK 5.5, Risk Analysis and Simulation Add- In for Microsoft Excel, Palisade Corporation. Version 5.5. May 2009.

Frepoli, C., An Overview of Westinghouse Realistic Large Break LOCA Evaluation Model, Science and Technology of Nuclear Installations, Volume 2008, Article ID 498737, 15 pages, (2008).

Hastie, T & Tibshirani, R. Generalized Additive Models. Source: Statist. Sci. Volume 1, Number 3 (1986), 297-310.

Hopfield, J.J. Neural networks and physical systems with emergent collective computational abilities. Proceedings of the National Academy of Sciences, 79:2554-2558, 1982.

Lee SY & Ban CH, "Code-Accuracy Based Uncertainty Estimation (CABUE) Methodology for large-Break Loss-of-Coolant Accidents", Nuclear Technology 148, 335-347, (2004).

Young, M.Y., Bajorek, S.M., Nissley, M.E. & Hochreiter, L.E. . "Application of code scaling applicability and uncertainty methodology to the large break loss of coolant". CSAU. Nucl. Eng. Des. 186 pp. 39–52, (1998).

Martin, R.P. & O'Dell, L.D. "AREVA's realistic large break LOCA analysis methodology". Nuclear Engineering and Design. 235, pp 1713-1725 (2005).

Martorell, S., Villamizar, M., Villanueva, J.F., Sánchez, A.I., Pelayo, F., Mendizábal, R., Sol, I., Carlos, S. & Serradell, V. CUANTIFICACIÓN DE MÁRGENES DE SEGURIDAD PARA SECUENCIAS DE APS. 36ª Reunión Anual Sociedad Nuclear Española. 2010a.

Martorell, S., Villamizar, M., Villanueva, J.F., Sánchez, A.I., Pelayo, F., Mendizábal, R., Sol, I., Carlos, S. & Serradell, V. APLICACIÓN DE LOS MÉTODOS PLS Y PCA AL ANÁLISIS DE RESULTADOS DE SIMULACIONES DE TRANSITORIOS TERMOHIDRÁULICOS. 36ª Reunión Anual Sociedad Nuclear Española. 2010b.

Bajorek, S.M., Hochreiter, L., Kazimi, M., Reyes, J., Smith, K. & Wallis, G. "Small break loss of coolant accident phenomena identification and ranking table (PIRT) for Westinghouse pressurized water reactors" (Proc. 9th Int. Mtg on Nuclear Reactor Thermal-hydraulics: NURETH-9 (KIM, J.H., PETERSON, P., Eds), Elsevier Science, "Code accuracy based uncertainty estimation (CABUE) methodology for large break loss of coolant accidents". CSAU 2010.

Saltelli, A., Chan, K. & Scott, E.M. Sensitivity Analysis. J. Wiley & Sons, Ltd. 2000.

SPSS Neural Networks 16. SPSS Inc. 2007.

USNRC, 1989, Quantifying Safety Margins: Application of Code Scaling, Applicability, and Uncertainty Evaluation Methodology to a Large -Break Loss-of-Coolant Accident, NUREG/CR-5249, EGG-2659, 1989 (see also Nuclear Engineering and Design, 119, 1990).

Villanueva, J. F., Carlos, S., Martorell, S. & Serradell, V. Análisis del impacto de Márgenes de seguridad de un LOCA en un PWR considerando incertidumbres en variables termohidráulicas y probabilistas. 35ª Reunión Anual SNE, 2009.

Wulff W., Boyack B.E., Catton I., Duffey R.B., Griffith P., Katsma K.R., Lellouche G.S., Levy S., Rohatgi U.S., Wilson G.E., Zuber N., "Quantifying reactor safety margins. Part 3: Assessment and ranging parameters". Nuclear Engineering and Design, 119, pp 33-65, 1990.