

## Métodos estadísticos 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

El uso cada vez más extendido de herramientas de cálculo realistas con estimación de las incertidumbres asociadas, en inglés conocido como BE+U (Best Estimate + Uncertainties), la cada vez mayor capacidad de cálculo, junto con la paulatina aproximación de las técnicas de análisis deterministas y probabilistas, está permitiendo afrontar el análisis exhaustivo de secuencias accidentales y la mejora en la cuantificación de los aspectos de seguridad. 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 este contexto, las herramientas de análisis estadístico clásicas junto con nuevos métodos, tales como análisis de componentes principales, PCA (Principal Components Analysis), regresión por mínimos cuadrados parciales, PLS (Partial Least Squares) y el método de descomposición de la varianza como análisis de sensibilidad, etc., cuya aplicabilidad práctica, que no su bondad, era cuestionada hace unos años por la exigencia computacional en este tipo de análisis, se postulan hoy en día como herramientas viables de aplicación y de gran interés para la diagnosis y prognosis del efecto de las incertidumbres en la estimación de la PCT (peaking clad temperature) necesaria en los cálculos de márgenes de seguridad mediante cálculos BE+U.

En esta ponencia se presentan herramientas de análisis estadístico que permiten comprender las relaciones entre las variables de entrada "inputs" (definidas por funciones de distribución de parámetros del modelo termohidráulico) y la variable de salida "outputs", e.g. la PCT. El objetivo es identificar las variables de entrada más importantes debido al efecto que ejercen sobre las variables de salida. Además, es posible cuantificar el aporte de la incertidumbre de cada variable de entrada en la incertidumbre de los resultados. 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 debido a la gran complejidad del sistema simulado. Como consecuencia de ello resulta interesante la aplicación de métodos estadísticos que permitan valorar la interrelación entre parámetros considerados, hacer análisis predictivos y evaluar el impacto de las incertidumbres sobre una determinada variable resultado de la simulación.

El PCA es un método apropiado para identificar y clasificar diferentes tipos de comportamientos. Mientras que métodos predictivos como el PLS, permiten identificar las variables de entrada más importantes debido al efecto que ejercen sobre las variables de salida a través de la construcción de la ecuación de predicción. Además, utilizando la ecuación de predicción del PLS es posible propagar la incertidumbre de las variables de entrada en el resultado final (en este caso la PCT). 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). Este método permite determinar en qué medida las variables de entrada del modelo tienen influencia en las variables de salida, tanto individualmente, es decir en forma independiente de las otras variables (efecto de primer orden), como incluyendo tanto el efecto individual como los efectos de interacciones con las demás variables del modelo (efecto total).

El caso abordado en la presente ponencia, es el análisis estadístico de los resultados tras 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 la 35ª Reunión de la SNE (Villanueva et al., 2009) se presentó una metodología para el cálculo de márgenes de seguridad utilizando un código termohidráulico BE, así como datos y modelos del APS nivel I, además de contemplar algunas de las incertidumbres asociadas a dicho modelo. En la 36ª Reunión de la SNE (Martorell et al., 2010a) se complementa el estudio analizando de forma más exhaustiva las incertidumbres introducidas por los modelos termohidráulicos y probabilistas,

concretamente se incluyen en el estudio 26 parámetros completamente caracterizados.

En esta ocasión se plantea el uso de técnicas estadísticas multivariantes como el PLS, el PCA 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 los resultados obtenidos en la simulación de transitorios termohidráulicos mediante un código “Best Estimate”. Por tanto, el LBLOCA es simulado utilizando el código BE RELAP 5 siguiendo la metodología presentada en 35ª Reunión de la SNE (Villanueva et al., 2009), con muestras que cubren la variación de los parámetros de entrada considerados en 36ª Reunión de la SNE (Martorell et al., 2010a), obteniéndose mediante sucesivas simulaciones una muestra representativa de los posibles comportamientos de la temperatura dadas unas condiciones iniciales. A las diferentes evoluciones temporales de la Temperatura de Vaina, se aplica un PCA, teniendo como resultado una clasificación de las mismas de acuerdo a su comportamiento durante el transitorio. Se construye un modelo PLS, en el que se caracterizan por importancias los parámetros la PCT, 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. Patrones de comportamiento

El análisis de Componentes Principales, PCA (Johnson, D.E. 2000), parte de la idea de agrupar una gran cantidad de variables de partida en pocas variables representativas (llamadas componentes principales, variables latentes o factores latentes) que capturen la máxima variabilidad existente entre componentes. Esta propiedad hace del PCA un método apropiado para identificar y clasificar diferentes tipos de comportamientos.

El PCA trabaja exclusivamente sobre la matriz de variables independientes, agrupando dichas variables en subgrupos semejantes. Esta característica permite explorar los datos en busca de patrones y/o agrupaciones entre ellos. Por ejemplo, conociendo la trayectoria a lo largo del tiempo de la Temperatura Máxima de Vaina, el PCA agrupará las series que presentan trayectorias similares.

En general, el PCA se puede definir mediante la matriz de variables independientes (datos originales),  $\mathbf{X}$ , la cual se descompone en dos matrices,  $\mathbf{T}$  (matriz de “scores”) y  $\mathbf{P}$  (matriz de “loadings”), mas una matriz  $\mathbf{E}$  residual de  $\mathbf{X}$ . La representación matricial del PCA se presenta a continuación, (Johnson, D.E. 2000):

$$\mathbf{X} = \mathbf{TP} + \mathbf{E} \quad (1)$$

En donde los “scores” especifican las relaciones existentes entre los valores originales y los “loading” definen la contribución de cada variable original sobre la componente principal.

### 3. Análisis multivariante mediante, PLS

En la actualidad las técnicas estadísticas multivariantes de proyección sobre estructuras latentes, tales como la Regresión por Mínimos Cuadrados Parciales, PLS (Geladi, P, 1986) presentan grandes ventajas a la hora de analizar las relaciones entre múltiples variables, con una pérdida mínima de información.

En el caso concreto de la regresión PLS, es un método de regresión por reducción multivariante que maximiza la covarianza. Por ser un método no paramétrico, no establece hipótesis relativas a la distribución de los datos, ni al tamaño muestral. En general permite trabajar problemas de alta complejidad (muchas variables), con poca información (número reducido de muestras) y cuyo objetivo final sea el análisis predictivo. El modelo PLS estructura la información en dos matrices, la matriz de variables independientes,  $\mathbf{X}$  y la matriz de variables dependientes,  $\mathbf{Y}$ . Cada una de ellas se descompone en dos nuevas matrices, una para los “scores” matriz  $\mathbf{T}$ , (nexo común entre ambas matrices,  $\mathbf{X}$  e  $\mathbf{Y}$ ) y una para los “loadings” (matriz  $\mathbf{P}$  para las  $\mathbf{X}$  y  $\mathbf{Q}$  para las  $\mathbf{Y}$ ). Además de una matriz residual ( $\mathbf{E}$  para las  $\mathbf{X}$  y  $\mathbf{F}$  para las  $\mathbf{Y}$ ), tal como se muestra a continuación, (Geladi, P, 1986):

$$\mathbf{X} = \mathbf{TP} + \mathbf{E} \quad (2)$$

$$\mathbf{Y} = \mathbf{TQ} + \mathbf{F} \quad (3)$$

$$\mathbf{Y} = \mathbf{BTQ} + \mathbf{F}^* \quad (4)$$

donde  $m$  es el número de muestras,  $a$  es el número de componentes principales obtenidas,  $n$  es el número de parámetros a modelar,  $\mathbf{F}^*$  es la matriz residual y  $\mathbf{B}$  son los coeficientes de la regresión PLS.

### 4. 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):

$$s_j = \frac{\text{Var}(E(f(\mathbf{x}) | x_j))}{\text{Var}(f(\mathbf{x}))} \quad (5)$$

y

$$T_j = \frac{E(\text{Var}(f(\mathbf{x}) | \mathbf{x}_{(-j)}))}{\text{Var}(f(\mathbf{x}))} = \frac{\text{Var}(f(\mathbf{x})) - \text{Var}(E(f(\mathbf{x}) | \mathbf{x}_{(-j)}))}{\text{Var}(f(\mathbf{x}))} \quad (6)$$

donde  $\mathbf{x}_{(-j)} = (x_1, \dots, x_{j-1}, x_{j+1}, \dots, x_p)$ . El numerador de la Ecuación (5) 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 (6) 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:

$$y = f(\mathbf{x}) + \varepsilon \quad (7)$$

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  $\varepsilon$  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.

## 5. Caso de aplicación

En esta ocasión se plantea el uso de técnicas estadísticas multivariantes como el PLS, el PCA 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 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 Especifico Combustible (CEC)	Normal	<b>Variable</b>	<b>Tipo Distribución</b>
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
<b>Variable</b>	<b>Tipo Distribución</b>	Pérdidas Tubería (PTA)	LogNormal
Nivel (NP)	Normal	<b>Variable</b>	<b>Tipo Distribución</b>
Pérdidas Tubería (PTP)	LogNormal	Presión (PC)	Uniforme
<b>Variable</b>	<b>Tipo Distribución</b>	Temperatura (TC)	Uniforme
Tamaño de Rotura (TR)	LogNormal	<b>Variable</b>	<b>Tipo Distribución</b>
Coefficiente de Descarga (CD)	Uniforme	Señal Bajo Nivel Tanque (SBNT)	Uniforme
<b>Variable</b>	<b>Tipo Distribución</b>	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 realiza un análisis PCA utilizando como matriz de datos la evolución de la Temperatura de Vaina con potencia inicial, durante los 700 segundos simulados. El objetivo es clasificar las diferentes trayectorias de la Temperatura de Vaina con potencia inicial. La Figura 4 muestra las diferentes agrupaciones obtenidas por el algoritmo PCA, realizado con el programa SIMCA (UMETRICS, 2002). Se puede observar que existen tres comportamientos generales, asociados a las distintas trayectorias de la Temperatura de Vaina.

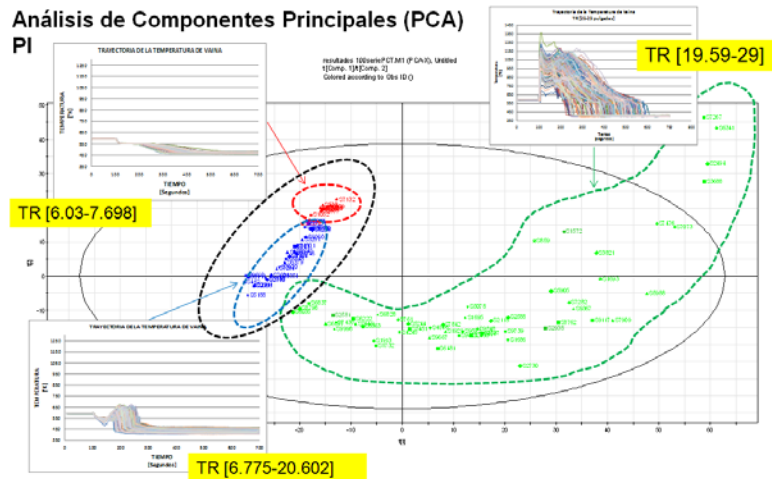


Figura 4. Tipos de evolución de la Temperatura de Vaina resultado del PCA

Al analizar las características de los diferentes parámetros en cada uno de los tres comportamientos obtenidos por el PCA, se observa que la diferencia en el comportamiento se debe básicamente al tamaño de la rotura. En la Figura 5 se presentan los 3 comportamientos de acuerdo al tamaño de la rotura.

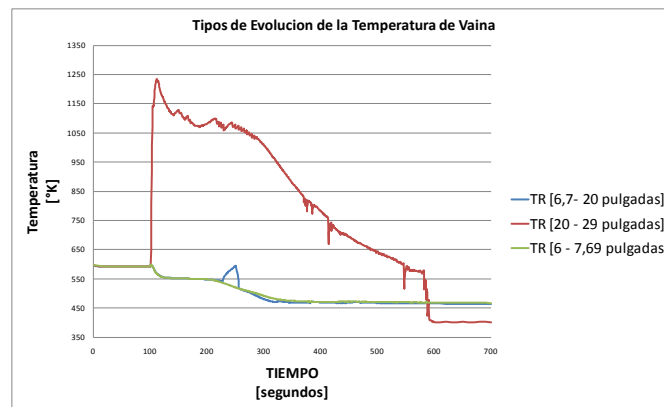


Figura 5. Tipos de evolución de la temperatura de vaina.

En esta ponencia se ha elegido un PLS 1, en donde los elementos que constituyen la matriz **X**, son los 37 parámetros mostrados en la Tabla 1, mientras que el elemento que constituyen el vector **Y** es la Temperatura Máxima de Vaina. El objetivo del modelo es obtener la importancia de los parámetros (Matriz X), en la predicción de la Máxima Temperatura de Vaina, durante el Transitorio. La regresión PLS se desarrolló con el programa SIMCA-P (UMETRICS, 2002). Como se ha indicado con anterioridad, se aplica la regresión PLS, en la obtención de un modelo que sirva para determinar las variables más significativas en la predicción de los valores de las variables **Y** (Máxima temperatura de Vaina). Una vez definido el conjunto de datos, se realiza el análisis PLS cuyos resultados se presentan a continuación. La bondad de ajuste del modelo es de  $R^2=95.3$ . Respecto al  $Q^2$  (Índice de Stone Geiser) el cual mide el aporte marginal de cada componente PLS al poder predictivo del modelo, el cual es con dos componentes del  $Q^2=95.1\%$  acumulado del PLS. La Figura 6 muestra los resultados



del cálculo de importancias de la variable  $x_i$  (donde  $i=1,\dots,32$ ) en función del poder predictivo que tiene sobre  $Y$  (PCT), (denominado VIP) al realizar la regresión PLS en donde se observa que los parámetros más significativos, en orden de importancia son: el efecto lineal y el efecto cuadrático del Tamaño de Rotura (TR), Coeficiente Descarga (CD) y Potencia Nominal (PN).




Figura 6. Importancias de las variables en el Modelo.

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 de la regresión PLS la ecuación 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 predicción PLS cada variable como función de distribución, además del error de la regresión. Posteriormente se realizaron 300 simulaciones mediante el método de muestreo Hipercubo Latino, utilizando la ecuación de predicción del PLS, 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 7 presenta la función de densidad de la PCT y algunos de sus estadísticos (media, 5% y 95%).

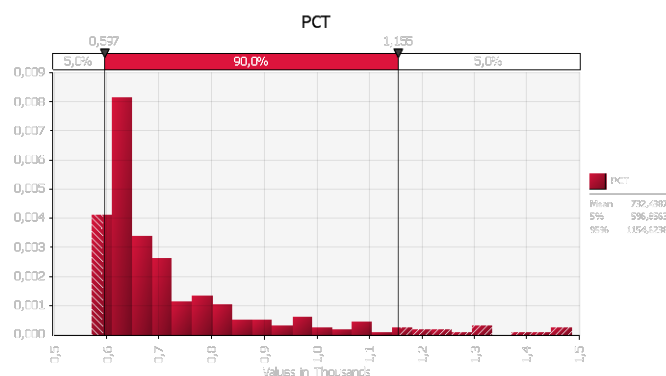


Figura 7. Propagación de las incertidumbres al cálculo de la PCT utilizando la ecuación del PLS (Software @Risk)

En esta ocasión se observa que el valor medio de la PCT obtenida a través de la propagación de la incertidumbre, por medio de muestreo por hipercubo latino se ajusta a los valores reales y predichos obtenidos a través del PLS. En la Tabla 2, se

presentan los valores medios de la PCT reales, predichos y tras la propagación de la incertidumbre.

	Valor medio		Simulación (Propagación de la incertidumbre)		
	Reales por RELAP	Predichos por PLS	Valor medio de la PCT	Percentil 5%	Percentil 95%
PCT	759	754	732.4387	596.8563	1154.6238

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%
TR*TR	0.823	0.832	(0.794, 0.906)
TR	0.175	0.192	(0.326, 0.384)
PN	0.005	0.000	(0.00, 0.136)
PP	0.001	0.000	(0.000, 0.048)
CD	0.000	0.003	(0.00, 0.021)

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

Finalmente, el 82.3% de la incertidumbre del valor de la PCT se atribuye a la incertidumbre propia del efecto cuadrático del tamaño de rotura. El intervalo de confianza TR\*TR al 95% está entre [0.79 y 0.906], lo cual indica que prácticamente toda la incertidumbre de la PCT se debe a la incertidumbre propia del TR y su interacción con otras covariables.

### Observaciones finales

Se ha analizado el comportamiento de Temperatura de Vaina durante todo el transitorio LBLOCA, identificando por PCA 3 tipos de comportamiento. Con el análisis anterior se pone de manifiesto que el Tamaño de Rotura, es el factor que condiciona el comportamiento de la Temperatura de Vaina a lo largo del tiempo. Respecto a los resultados obtenidos con PLS, se observó que los parámetros más relevantes al analizar los picos Temperatura de Vaina son el Tamaño de Rotura, Potencia Nominal y el Coeficiente de Descarga (Rotura). El análisis de sensibilidad ha servido para comprobar la robustez del modelo, observando como varían la PCT en función de las modificaciones de las variables de entrada dadas por las funciones de distribución de cada una de ellas ( $TR_{[Lognormal]}$ ,  $CD_{[Uniforme]}$  y  $PN_{[Normal]}$ ), podemos concluir que la incertidumbre del TR es la variable más importante con respecto a impacto en la incertidumbre de la PCT. 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).

Geladi, P & Kowalski, B.R. Partial Least Squares Regression. *Analytica Chimica Acta*, Elsevier Science Publishers B.V.,185(1986)1-17.

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

Johnson, D.E. *Métodos Multivariados Aplicados al Análisis de Datos*. International Thomson Editores. 2000.

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.

UMETRICS, A. B. SIMCA-P10. User Guide to SIMCA-P. 2002.

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.