

Algoritmos Evolutivos y Punto de Funcionamiento Aplicados a un Problema Real de Optimización Multiobjetivo en Diseño de Sistemas de Seguridad

M. Méndez¹, B. Galván², D. Greiner², G. Winter²

Resumen— La aplicación de Algoritmos Evolutivos Multiobjetivo (AEMOs) a problemas del mundo real que identifican en los espacios de decisión u objetivos, un vector solución o Punto de Funcionamiento (PF) (el cual define el estado actual del sistema), puede no ser lo más conveniente. Por ejemplo, podemos admitir que en este tipo de problemas, un decisor pueda considerar elevado el costo computacional de alcanzar el frente completo de Pareto y preferir aquella porción o región del frente de soluciones que domine al PF. En este trabajo se aplica el método WP-TOPSISGA (mezcla NSGAII, el método de Toma de Decisiones Multicriterio TOPSIS y el PF) y se estudian sus bondades (conducir la búsqueda hacia la región de interés y clasificar las soluciones según TOPSIS) sobre un problema real de ingeniería en Diseño de Sistemas de Seguridad. Se ha usado el Sistema de Contención por Inyección en Spray de una central nuclear de generación eléctrica, para el cual se han definido en el espacio de los objetivos, varios Puntos de Funcionamiento, minimizándose los objetivos coste y no-disponibilidad.

Palabras clave— Algoritmos Evolutivos Multiobjetivo, Toma de Decisiones, Decisor, Punto de Funcionamiento, TOPSIS, Preferencias.

I. INTRODUCCIÓN

Numerosos problemas industriales, económicos u otros, pueden definir en los espacios de la decisión o de los objetivos, un Punto de Funcionamiento (PF) [16][17], o solución estable y realizable de trabajo no necesariamente eficaz o Pareto óptima. La aplicación a este tipo de problemas, de Algoritmos Evolutivos Multiobjetivo (AEMOs) (altamente eficientes y capaces de obtener frentes óptimos de Pareto, amplios y bien distribuidos), como paso preliminar a la toma de decisión, puede no ser el enfoque más apropiado. De hecho, un decisor puede estar más interesado en guiar la búsqueda de soluciones hacia una pequeña porción del frente óptimo de Pareto, por ejemplo aquella cuyas soluciones do-

minan al PF (Región dominante del Punto de Funcionamiento R_d -PF [16]). Con este punto de vista, el método WP-TOPSISGA [16] (combina la segunda generación de AEMOs (NSGAII [3][4]), el método ampliamente conocido de Toma de Decisiones Multicriterio TOPSIS [13] y el PF), ha mostrado excelentes resultados al aplicarse al conocido problema test de la Mochila Multiobjetivo en variables binarias [14][15][19][22][25] (0-1MOKP, siglas en inglés de Multiobjective Knapsack Problem).

En este trabajo se pretende experimentar el método WP-TOPSISGA, en un Problema de Optimización Multiobjetivo (POM) real de ingeniería en Diseño de Sistemas de Seguridad. En particular, se ha utilizado el Sistema de Contención por Inyección en Spray (SCIS) de una central nuclear de generación eléctrica [5][10][11].

En la evaluación de resultados se han comparado los métodos WP-TOPSISGA y NSGAII, utilizando la métrica relativa $C(A,B)$ [24], para medir el porcentaje de soluciones de B que son dominadas por al menos una solución de A (menor valor de $C(A,B)$, mejor). No obstante, remarcamos que es conveniente hacer balance entre el amplio frente producido por NSGAII con la exploración e identificación de soluciones en la zona de interés (la R_d -PF) realizada por WP-TOPSISGA.

En la sección siguiente se exponen nociones y conceptos básicos para situar el presente trabajo en perspectiva. La sección 3 describe el método de Ayuda a la Decisión Multicriterio TOPSIS. La sección 4 presenta los detalles de diseño e implementación del algoritmo WP-TOPSISGA. En la sección 5 se resumen el problema de Optimización Multiobjetivo en Diseño de Sistemas de Seguridad y los resultados obtenidos. Por último, la sección 6 recoge las conclusiones del trabajo.

II. DEFINICIONES

Un POM es aquel que corresponde a una cierta realidad industrial, económica u otra y sobre el que un decisor desea optimizar simultáneamente varios objetivos usualmente en conflicto entre sí. De manera general un POM se puede representar (en términos de minimización) de la siguiente forma:

¹Dpto. de Informática y Sistemas, Universidad de Las Palmas de Gran Canaria (ULPGC), Edif. de Informática y Matemáticas. Campus de Tafira, CP 35017 Las Palmas G.C. E-mail: mmendez@dis.ulpgc.es.

²División de Computación Evolutiva (CEANI), Inst. Univ. de Sistemas Inteligentes (IUSIANI), Universidad de Las Palmas de Gran Canaria (ULPGC), Edif. Polivalente. Campus de Tafira, CP 35017 Las Palmas G.C. E-mail: bgalvan@step.es, dgreiner@iusiani.ulpgc.es, gabw@step.es

$$\begin{cases} \min. & F(x) = f_1(x), f_2(x), \dots, f_k(x) \\ \text{s.a.} & \\ & g_j(x) \leq 0 \quad j \in (1, 2, \dots, m) \\ & h_q(x) = 0 \quad q \in (1, 2, \dots, p) \\ & B_{\text{inf}} \leq x_l \leq B_{\text{sup}} \quad l \in (1, 2, \dots, n) \end{cases}$$

$F(x)$ es el vector de objetivos a minimizar y $k \geq 2$ representa el número de objetivos.

Los valores B_{inf} y B_{sup} son respectivamente los límites inferior y superior de la variable x_l . Los valores de x_l que verifican estas restricciones definen el *espacio de búsqueda* (figura 1 izquierda).

Las restricciones $g_j(x) \leq 0$ y $h_q(x) = 0$ representan respectivamente m restricciones de desigualdad y p restricciones de igualdad. Los valores de x que satisfacen el conjunto de las $(m+p)$ restricciones, definen el *espacio realizable* S (figura 1 centro).

El vector $x = (x_1, x_2, \dots, x_n) \in S$ es un vector solución de n variables de decisión.

En el marco de la Optimización Multiobjetivo, con frecuencia el decisor razona en términos de la evaluación de una solución según cada objetivo, situándose en el espacio de los objetivos. Para representar el conjunto de soluciones realizables, en el espacio de los objetivos, es preciso determinar la imagen de cada solución realizable del espacio de decisión. Obtenemos así un conjunto $Z = f(S)$ (figura 1 derecha) definido como:

$$\begin{cases} Z = \{z = (z_1, z_2, \dots, z_k) \in R^k : \\ z_1 = f_1(x), z_2 = f_2(x), \dots, z_k = f_k(x), \forall x \in S\} \end{cases}$$

donde Z representa el conjunto de soluciones realizables en el espacio de los objetivos y $z = (z_1, z_2, \dots, z_k)$ una solución realizable en el espacio de los objetivos.

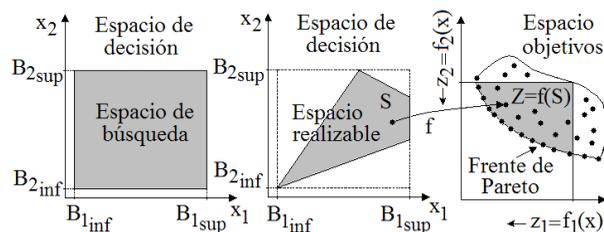


Fig. 1. Espacios de búsqueda, realizable y de los objetivos.

Definición 1 (Dominancia de Pareto) Una solución $x^t = (x_1^t, x_2^t, \dots, x_n^t)$ domina una solución $x^u = (x_1^u, x_2^u, \dots, x_n^u)$ si se verifican las siguientes condiciones:

1. $z_i^t \leq z_i^u \quad \forall i \in (1, 2, \dots, k)$
2. $\exists i \in (1, 2, \dots, k)$ tal que $z_i^t < z_i^u$

Definición 2 (Pareto óptima) Una solución $x^* \in S$ es Pareto óptima¹ si y solo si no existe una solución $x \in S$ tal que $x \in S$ domine $x^* \in S$. Una solución

¹El concepto de óptimo de Pareto lo formuló Vilfredo Pareto [20] a finales del siglo XIX.

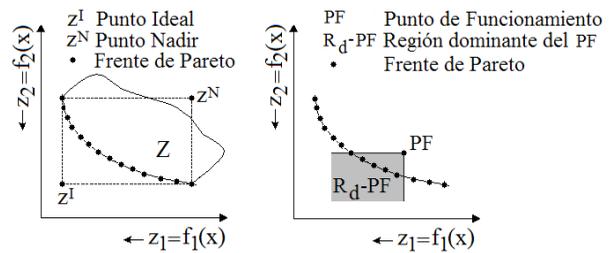


Fig. 2. Puntos Ideal, Nadir (izquierda) y PF (derecha).

Pareto óptima también es conocida como solución eficaz o solución no-dominada.

Definición 3 (Conjunto de Pareto) En general, en un POM no existe una única solución $x^* \in S$ Pareto óptima, si más bien un conjunto de soluciones denominado conjunto de Pareto o conjunto eficiente.

Definición 4 (Frente de Pareto) El conjunto de soluciones en el espacio de los objetivos que son imágenes del conjunto de Pareto, se denomina frente de Pareto (figura 1 derecha).

Definición 5 (Punto Ideal z^I) Es un vector solución $z^I = (z_1^I, z_2^I, \dots, z_k^I)$, construido con los mejores valores función objetivo de todas las soluciones del espacio de los objetivos (figura 2 izquierda). Este punto es en general inalcanzable.

Definición 6 (Punto Nadir z^N) Es un vector solución $z^N = (z_1^N, z_2^N, \dots, z_k^N)$, construido con los peores valores función objetivo de todas las soluciones del frente de Pareto (figura 2 izquierda). Este punto puede ser alcanzable o inalcanzable.

Definición 7 (Punto de Referencia z^*) Es un vector solución $z^* = (z_1^*, z_2^*, \dots, z_k^*)$, que define la meta a alcanzar por cada función objetivo.

Definición 8 (Punto de Funcionamiento PF [16]) Es un vector solución $x^{PF} = (x_1^{PF}, x_2^{PF}, \dots, x_n^{PF})$ de un problema real Multiobjetivo, que identifica una solución estable de funcionamiento (o trabajo), no necesariamente efectiva o Pareto óptima. El PF también se define como aquel vector solución $x^{PF} = (x_1^{PF}, x_2^{PF}, \dots, x_n^{PF})$ de un problema real Multiobjetivo, que determina el estado actual del sistema. La imagen de x^{PF} , define el PF en el espacio de los objetivos ($z^{PF} = (z_1^{PF}, z_2^{PF}, \dots, z_k^{PF})$), ver la figura 2 derecha.

Se define la Región dominante del PF (R_d -PF) [16], como aquel subconjunto de soluciones (subregión) del frente de Pareto, que dominan al PF (figura 2 derecha).

Axioma 1 (De pertenencia [16][17]) Si una solución $z^{PF} = (z_1^{PF}, z_2^{PF}, \dots, z_k^{PF})$ definida en el espacio de los objetivos, es el PF de un problema real Multiobjetivo, entonces $z^{PF} = (z_1^{PF}, z_2^{PF}, \dots, z_k^{PF})$ pertenece al conjunto realizable de soluciones en el espacio de los objetivos Z .

Axioma 2 (De pertenencia [18]) Si una solución $x^{PF} = (x_1^{PF}, x_2^{PF}, \dots, x_n^{PF})$ definida en el espacio de decisión, es el PF de un problema real Multiobjetivo, entonces $x^{PF} = (x_1^{PF}, x_2^{PF}, \dots, x_n^{PF})$ pertenece

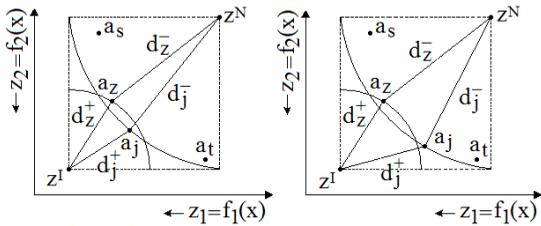


Fig. 3. Método TOPSIS: situación general y dilema.

al conjunto realizable de soluciones en el espacio de decisión S .

III. MÉTODO TOPSIS

El método TOPSIS fue propuesto por Hwang y Yoon [13] para la resolución de problemas de ayuda multicriterio a la decisión (problemas con un número finito de soluciones), y está fundado en el axioma de Zeleny [23]: *es racional elegir una acción (solución) lo más próxima a la ideal o lo más alejada de la anti-ideal (nadir)*. En la situación más general (figura 3 izquierda), TOPSIS establece que se debe elegir aquella acción (a_j) con menor distancia a la acción ideal (z^I) y mayor distancia a la acción anti-ideal (z^N).

Sin embargo la figura 3 (derecha), muestra que la acción a_z es la más cercana a la acción ideal, mientras que la acción a_j es la más alejada de la acción anti-ideal, aquí, TOPSIS afronta el dilema de trabajar con la acción ideal o la anti-ideal. TOPSIS resuelve el dilema, utilizando el concepto de *similitud al ideal* [2].

En cuanto a las distancias, éstas se calculan para un valor particular de la métrica p (con: $1 \leq p \leq \infty$) en la ecuación de la función distancia:

$$L_p = \left[\sum_{i=1}^k w_i^p |v_{ji} - z^I|^p \right]^{\frac{1}{p}} \quad (1)$$

donde v_{ji} es el valor normalizado de la acción a_j implementada para el criterio f_i , z^I es el vector cuyas coordenadas corresponde al punto de referencia (con TOPSIS este punto corresponde a la acción ideal o la anti-ideal) y w_i es el vector de pesos acorde a las preferencias del decisor con $\sum_{i=1}^k w_i = 1$ y $w_i \geq 0$ para todo i .

El método se compone de un procedimiento de 6 etapas:

1. Se construye una matriz de decisión del problema, de forma que un conjunto n de acciones o soluciones $A=(a_j, j=1,2,\dots,n)$ es comparado con respecto a un conjunto k de criterios (objetivos) $F=(f_i, i=1,2,\dots,k)$. La utilidad $f_i(a_j)$, que para un decisor tiene la alternativa j , con respecto al criterio i , se recoge en la evaluación $x_{ji}=f_i(a_j)$.
2. El decisor asigna a los criterios un peso $w_i \geq 0$ según sus preferencias.

3. Se normalizan las evaluaciones x_{ji} y se obtienen los valores v_{ji} .
4. Se determina la acción ideal $z^I = (v_1^I, v_2^I, \dots, v_k^I)$, construida con las mejores acciones de cada criterio y la acción anti-ideal $z^N = (v_1^N, v_2^N, \dots, v_k^N)$ construida por las peores acciones de cada criterio.
5. Se calculan los valores de las distancias Euclídeas de cada acción respecto las acciones ideal y anti-ideal según:

$$d_j^I = \sqrt{\sum_{i=1}^k w_i (v_{ji} - z^I)^2} \quad j = 1, 2, \dots, n \quad (2)$$

$$d_j^N = \sqrt{\sum_{i=1}^k w_i (v_{ji} - z^N)^2} \quad j = 1, 2, \dots, n \quad (3)$$

6. Se determina el ratio de similaridad D_j^I o cercanía relativa a la acción ideal a partir de la ecuación:

$$D_j^I = \frac{d_j^N}{d_j^I + d_j^N} \quad \text{con } D_j^I = [0, 1] \quad (4)$$

7. Se clasifican las acciones según el orden de preferencia: de mayor a menor similaridad D_j^I .

IV. MÉTODO WP-TOPSISGA

El método WP-TOPSISGA [16] (ver la figura 4), tiene una estructura similar a otros AEMOs e introduce dos cambios en la original formulación de NSGAI [3][4]: primero, el tamaño de la población (Q) y el del fichero de soluciones no dominadas (P) pueden diferir y segundo, el operador *crowding* de NSGAI se ha sustituido por el operador que se ha denominado *similarity* (similaridad). En cada generación t , se forma una población $R^t = P^t + Q^t$ (tamaño N para P^t y tamaño M para Q^t). Como todos los miembros de la población anterior están incluidos en R^t , el elitismo está asegurado. Luego, R^t es clasificada en base a dominancia. La siguiente población P^{t+1} se construye con las soluciones no-dominadas de R^t comenzando con el frente F_1 de rango 1 seguido por el frente F_2 de rango 2 hasta llegar a un frente F_i cuyas soluciones no caben íntegramente en la nueva población (tamaño N). Con el fin de mantener el tamaño N de la nueva población, se aplica al frente F_i el operador *similarity* en los siguientes términos: los extremos del primer frente de rango 1 definen las soluciones ideales y anti-ideales; con esta información se calcula para cada solución, la similaridad [2] a la solución ideal, a continuación y para elegir las soluciones que formarán parte del frente F_i se sigue el orden: (1) las soluciones extremas, (2) soluciones de mayor valor de similaridad y que pertenecen a la R_d -PF y (3) resto de soluciones con mayor valor de similaridad. Más tarde, se genera una nueva población de descendientes Q^{t+1} aplicando los operadores de

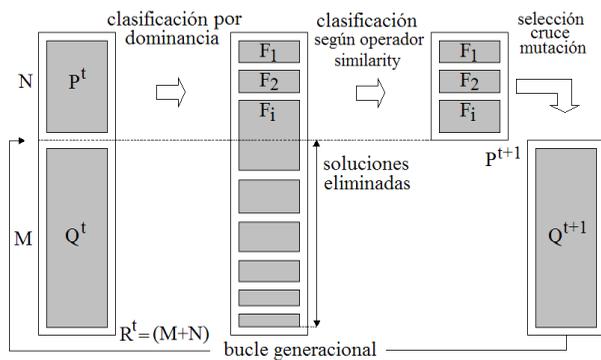


Fig. 4. Esquema de funcionamiento de WP-TOPSISGA.

selección (torneo binario con el criterio: (1) individuo de menor rango, (2) soluciones extremas, (3a) si los individuos pertenecen a la R_d -PF se elige el de mayor valor de similaridad o al azar, si ambos individuos tienen el mismo valor de similaridad, (3b) si los individuos no pertenecen a la R_d -PF se elige el de mayor valor de similaridad o al azar, si ambos individuos tienen el mismo valor de similaridad y (3c) si un individuo pertenece a la R_d -PF y el otro no, se elige el que pertenece a la R_d -PF).

Una cuestión importante es que con el método TOPSIS los valores de los pesos son estimados por el decisor acorde a sus preferencias, sin embargo con WP-TOPSISGA los valores w_i , son estimados de forma automática por interpolación en cada iteración del algoritmo en base al valor del PF, de la siguiente manera: si suponemos una cierta generación o instante t de la búsqueda y un frente óptimo resultante, como el que se muestra en la figura 5 (en términos de maximización), la elección por un decisor de la solución extrema A, indicaría que el objetivo f_2 le resulta de máxima relevancia comparada con el objetivo f_1 (en valores cuantitativos de las preferencias: $w_1=0, w_2=1$); justo lo contrario si la elección del decisor fuese la solución extrema F, ahora es f_1 comparado con f_2 , el objetivo de máxima relevancia (en valores cuantitativos de las preferencias: $w_1=1, w_2=0$). Ambas soluciones extremas A y F, definen los extremos de un intervalo cuyos valores son conocidos, si ahora la elección del decisor fuese la solución D (solución más cercana al PF), el valor de w_2^D puede ser estimado por interpolación (se utilizó, el método de los coeficientes indeterminados) según la ecuación $w_2^D = \frac{f_2^D - f_2^F}{f_2^A - f_2^F}$ y el valor de w_1^D mediante $w_1^D = 1 - w_2^D$.

V. RESULTADOS EXPERIMENTALES

A. Problema de Optimización Multiobjetivo en Diseño de Sistemas de Seguridad

A.1 Descripción

La Optimización en Diseño de Sistemas de Seguridad (ODSS), es una disciplina de la ingeniería, que debido al incremento de la complejidad de los sis-

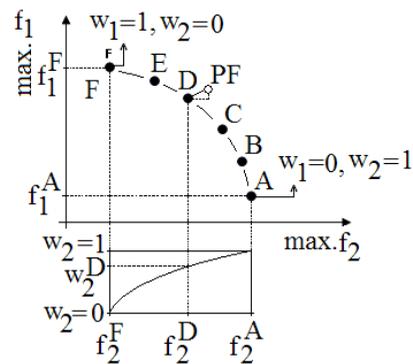


Fig. 5. Estimación de los pesos w_i según WP-TOPSISGA.

temas y a la necesidad de tener que obtener diseños óptimos más que simplemente adecuados, ha experimentado en la última década una importante evolución. En estos sistemas se debe hacer un especial énfasis al diseño de Sistemas de Seguridad (un fallo en el sistema puede implicar daño a personas), considerando alternativas de diseño y/o estrategias de mantenimiento, con la finalidad de desarrollar una optimización global. En ambos casos, métodos multiobjetivo son especialmente adecuados, pues los decisores están especialmente interesados en tomar sus decisiones en base a diferentes objetivos en conflicto.

La metodología más difundida para modelar sistemas de seguridad es el análisis de árboles de fallos. Un árbol de fallos, consiste en un diagrama booleano, compuesto fundamentalmente por puertas lógicas AND y OR que modelan la lógica de fallos del sistema. Existen muchos métodos para la evaluación cuantitativa de los árboles de fallos, en este trabajo se utilizará un método eficiente denominado método de los pesos [5][8], que proporciona límites superior e inferior exactos de la no-disponibilidad del sistema para un error preespecificado máximo.

Los métodos más utilizados en la optimización de problemas de ODSS, son los algoritmos evolutivos [6][7][9][12]. Una consideración importante, previa al uso del algoritmo evolutivo, es la codificación de las soluciones candidatas. Código binario, entero y real puede ser usado, si bien el código binario es el más utilizado [1] y el que hemos adoptado para el problema utilizado como aplicación práctica en este trabajo. No obstante, ciertos autores [21], han observado problemas de convergencia en ODSS a causa de la diferente naturaleza de las variables implicadas (variables binarias para las alternativas de diseño y variables reales en las estrategias de mantenimiento).

Como aplicación práctica de ODSS, se ha usado el Sistema de Contención por Inyección en Spray (SCIS) de una central nuclear de generación eléctrica. Este problema es de naturaleza NP-difícil y ha sido ampliamente estudiado en [5][10][11]. El SCIS de una central nuclear, es un sistema cuya misión consiste en inyectar agua borada en el interior de la contención del edificio del reactor cuan-

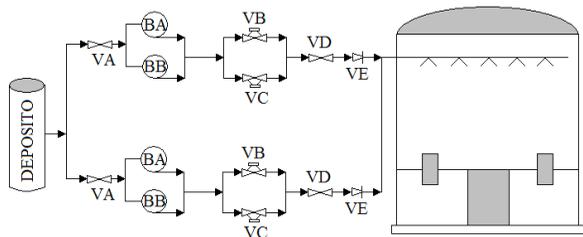


Fig. 6. Diagrama del SCIS de una central nuclear.

TABLA I
VALORES DE PARÁMETROS (NO-DISPONIBILIDAD (P) Y COSTE (C)) DEL PROBLEMA DE SCIS.

	VA, VD	VB, VC
Modelo 1	P=2.9E-3 C=50	P=3.0E-3 C=65
Modelo 2	P=8.7E-3 C=35	P=1.0E-3 C=70
Modelo 3	P=4.0E-4 C=60	—
	VE	PA, PB
Modelo 1	P=5.0E-4 C=37	P=3.5E-3 C=90
Modelo 2	P=6.0E-4 C=35	P=3.8E-3 C=85
Modelo 3	—	—

do se ha producido un accidente del tipo Pérdida de Refrigerante. Mediante aspersores situados en la parte superior del edificio, se procede a liberar el agua borada la cual arrastra la contaminación radiactiva conduciéndola a un depósito seguro para su posterior tratamiento. El sistema pasa por tanto su vida útil en espera de intervenir, siendo necesario asegurar su funcionamiento (disponibilidad) en el caso remoto de ser necesaria su intervención. En la figura 6 se puede apreciar la configuración general del sistema. La optimización que se pretende, consiste en encontrar las diferentes combinaciones de componentes técnicos existentes en el mercado, que minimicen simultáneamente la no-disponibilidad del sistema y su coste. Dado que ambos objetivos están en conflicto, es evidente que el problema es de naturaleza multiobjetivo.

Los datos adoptados han sido los de Greiner [11]. En la tabla I, se indican los valores de la no-disponibilidad (P) y coste (C) de los diferentes dispositivos del sistema que pueden encontrarse en el mercado. Tres modelos son posibles para las válvulas A y D, para el resto de válvulas y bombas sólo son posibles dos modelos. La no-disponibilidad y coste están restringidos a los valores [0.0, 1.0] y [0, 960] respectivamente.

El tamaño del espacio de búsqueda con codificación binaria simple de 32 bits es 4.294.967.296 soluciones. El número de soluciones factibles es de 82.944. En cuanto al conjunto de soluciones óptimas de Pareto, éste se compone de 178 soluciones en el espacio de decisión y 51 soluciones en el espacio de los objetivos, los valores de estas últimas se muestran gráficamente en la figura 7.

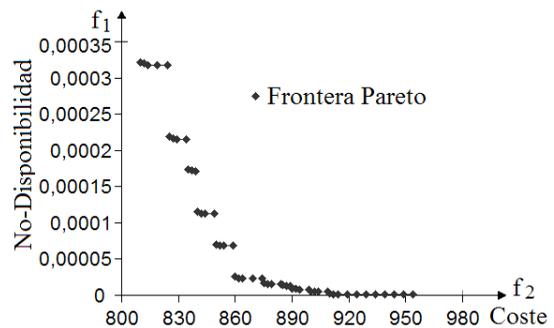


Fig. 7. Frontera de Pareto del problema de SCIS.

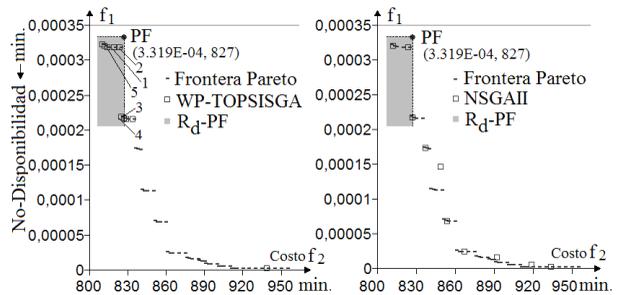


Fig. 8. Frente (N=10) con WP-TOPSISGA y NSGAII.

A.2 Configuración de parámetros

En todos los experimentos se utilizó un tamaño de la población R de 200 individuos, una probabilidad de cruce de 0.8, una probabilidad de mutación de 0.01, un valor $p=2$ para la métrica p en la ecuación (1) de la función distancia y el número máximo de generaciones (G) fue de 100. El tamaño N del fichero de soluciones no-dominadas, fue cambiado progresivamente según las secuencias N=10,15,20,30,40,50,60,100.

A.3 Resultados visuales

Las figuras 8, 9 y 10 (esta última, para mayor claridad se ha representado entre los valores 0 y 0.00005 de la no-disponibilidad), muestran los frentes alcanzados por WP-TOPSISGA (izquierda) y NSGAII (derecha) para tamaños de la población no-dominada N=10 individuos y valores del PF ($f_1=0.0003319$, $f_2=827$), ($f_1=0.0002386$, $f_2=837$), ($f_1=0.000006979$, $f_2=914$) respectivamente. Se observa que WP-TOPSISGA concentra la búsqueda de soluciones en la región de interés (la R_d -PF) y obtiene un preorden según TOPSIS (se representan sólo las cinco primeras soluciones) en las soluciones halladas. Por otro lado, NSGAII encuentra un conjunto de soluciones amplio y visualmente bien distribuido.

A.4 Comparativa

Los resultados (media después de diez experimentos) de comparar WP-TOPSISGA y NSGAII en base a la métrica relativa $C(A,B)$ [24], donde B representa el frente alcanzado con WP-TOPSISGA

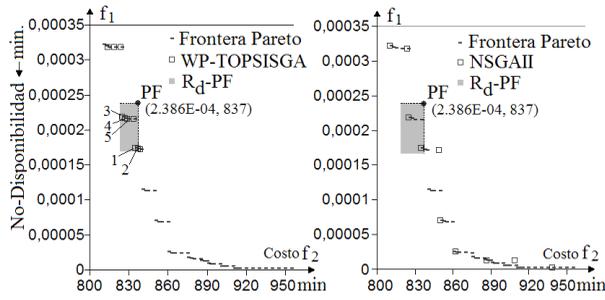


Fig. 9. Frente (N=10) con WP-TOPSISGA y NSGAI.

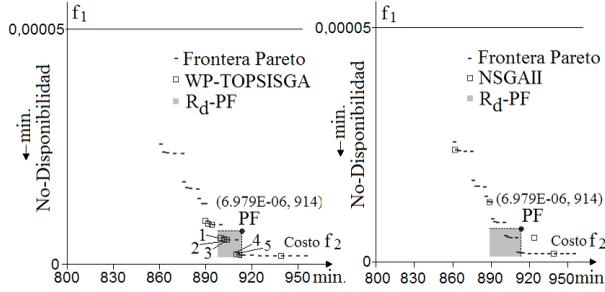


Fig. 10. Frente (N=10) con WP-TOPSISGA y NSGAI.

y A el alcanzado con NSGAI, se muestran en las tablas II, III y IV. Se observa que para tamaños pequeños (N=10,15) de la población no-dominada, la medida C(A,B) es menor (y por tanto mejor) para WP-TOPSISGA que para NSGAI, pero al incrementar el tamaño N las diferencias desaparecen (remarcamos que los operadores similarity de WP-TOPSISGA y crowding distance de NSGAI, están grandemente limitados para tamaños N de la población no-dominada próxima al tamaño real del frente de Pareto (51 soluciones), de ahí los resultados similares con ambos métodos para tamaños N cercanos o superiores a los 51 individuos)

Para una mejor interpretación de los valores de las tablas II, III, y IV, en las figuras 11, 12 y 13 se muestran gráficamente los resultados de dichas tablas.

TABLA II
VALORES (EN %) DE LA MÉTRICA RELATIVA C(A,B) (PF=0.0003319, 827), OBTENIDOS AL COMPARAR LOS FRENTE ALCANZADOS CON WP-TOPSISGA (FRENTE B) Y NSGAI (FRENTE A).

	N=10	N=15	N=20	N=30
C(A,B)	2	2.6	5	6.6
C(B,A)	10	11	5	6.3
	N=40	N=50	N=60	N=100
C(A,B)	2.56	2.93	2.61	2.09
C(B,A)	2.5	2.43	2.32	2.13

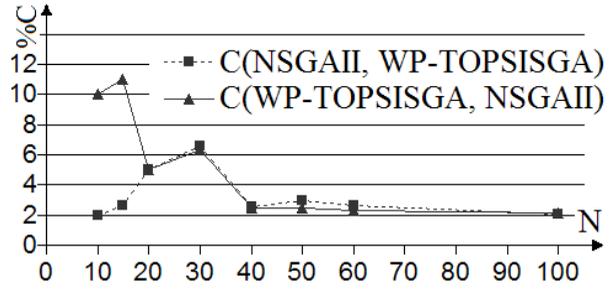


Fig. 11. Visualización gráfica de resultados de la tabla II.

TABLA III
VALORES (EN %) DE LA MÉTRICA RELATIVA C(A,B) (PF=0.0002386, 837), OBTENIDOS AL COMPARAR LOS FRENTE ALCANZADOS CON WP-TOPSISGA (FRENTE B) Y NSGAI (FRENTE A).

	N=10	N=15	N=20	N=30
C(A,B)	4	2.66	4	5.92
C(B,A)	12	11.99	4	5.26
	N=40	N=50	N=60	N=100
C(A,B)	3	3.7	3.01	2.05
C(B,A)	3.5	3.86	2.96	2.49

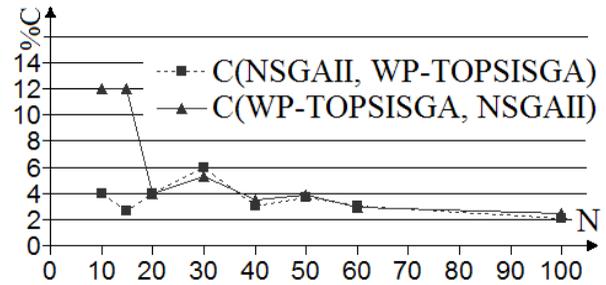


Fig. 12. Visualización gráfica de resultados de la tabla III.

TABLA IV
VALORES (EN %) DE LA MÉTRICA RELATIVA C(A,B) (PF=0.000006979, 914), OBTENIDOS AL COMPARAR LOS FRENTE ALCANZADOS CON WP-TOPSISGA (FRENTE B) Y NSGAI (FRENTE A).

	N=10	N=15	N=20	N=30
C(A,B)	4	4.02	2	6.6
C(B,A)	12	11.99	3	6
	N=40	N=50	N=60	N=100
C(A,B)	1.5	3.35	3.8	2.75
C(B,A)	1.52	3.01	3.25	2.48

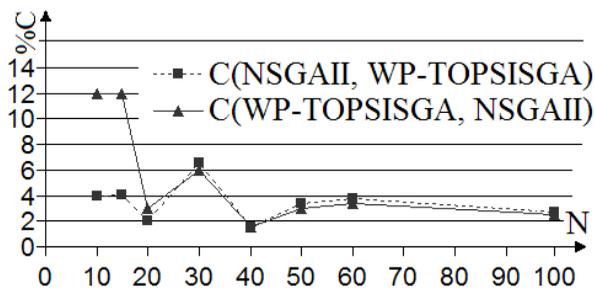


Fig. 13. Visualización gráfica de resultados de la tabla IV.

VI. CONCLUSIONES

En este artículo se investiga la aplicación de un Algoritmo Evolutivo Multiobjetivo (método WP-TOPSISGA) a un problema real de ingeniería en Diseño de Sistemas de Seguridad (se minimizan la no-disponibilidad y costo del Sistema de Contención por Inyección en Spray de una central nuclear de generación eléctrica), el cual distingue en los espacios de la decisión o de los objetivos, una solución estable y realizable de trabajo no necesariamente eficaz o Pareto óptima (Punto de Funcionamiento PF). Admitiendo que en este problema, el interés de un decisor, es aquel subconjunto de soluciones del frente de Pareto que dominan al PF (la Región dominante del Punto de Funcionamiento R_d -PF), el método WP-TOPSISGA, según los experimentos realizados, destaca por ser capaz de conducir la búsqueda de soluciones hacia dicha región, concentrándolas en la misma y clasificar las soluciones alcanzadas en base a la similaridad a la solución ideal según el método TOPSIS. Además, al comparar WP-TOPSISGA con el método NSGAI en base a la métrica $C(A,B)$, los valores (media después de diez tiradas) de la métrica son mejores para WP-TOPSISGA que para NSGAI cuando los tamaños N de la población no-dominada son pequeños, aunque las ventajas desaparecen al incrementarse el valor de N .

REFERENCIAS

- [1] J.D. Andrews and R.L. Patisson, Safety-system performance, In Proceedings of the 1997 Reliability and Maintainability Symposium, 76-83. Philadelphia, Pennsylvania, 1997.
- [2] B.V. Dasarathy, Smart: Similarity measured anchored ranking technique for the analysis of multidimensional data, IEEE Trans. on Systems, Man and Cybernetics, volume (SMC-6, 10), pages 708-711, 1976.
- [3] K. Deb and S. Agrawal and A. Pratap and T. Meyarivan, A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGAI, Technical Report 200001. Indian Institute of Technology, Kanpur, 2000.
- [4] K. Deb and A. Pratap and S. Agrawal and T. Meyarivan, A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II, In IEEE Transactions on Evolutionary Computation, volume 6(2), pages 182-197, 2002.
- [5] B. Galván, Contributions to Fault Tree Quantitative Evaluation, PhD thesis, Physics Dep., Las Palmas de Gran Canaria University, Canary Islands, Spain, (In Spanish). Spain, 1999.
- [6] M. Gen and R. Cheng, Genetic Algorithms and Engi-

- neering Design, Wiley Interscience, John Wiley and Sons. USA, 1997.
- [7] D.E. Goldberg, Genetic Algorithms in Search, Optimization and Machine Learning, Addison-Wesley Publishing Co., Reading. Massachusetts, 1989.
- [8] L. González and D. García and B. Galván, An Intrinsic Order Criterion to Evaluate Large, Complex Fault Trees, IEEE Transactions on Reliability, volume 53(3), pages 297-305, 2004.
- [9] D. Greiner and G. Winter and B. Galván, Optimización Multiobjetivo en Sistemas de Seguridad: Una Comparativa entre los Algoritmos NSGAI y SPEA2, En B. Galván, G. Winter, P. Cuesta y R. Aguasca ed., Actas del IV Congreso de Fiabilidad y Confiabilidad, pages 156-165. España, 2002.
- [10] D. Greiner and B. Galván and G. Winter, Safety Systems Optimum Design by Multicriteria Evolutionary Algorithms, Evolutionary Multi-Criterion Optimization, LNCS 2632, pages 722-736. Springer-Verlag, 2003.
- [11] D. Greiner, Optimización multiobjetivo de pórticos metálicos mediante algoritmos evolutivos, Tesis Doctoral, Departamentos de Informática y Sistemas, Matemáticas Aplicada e Ingeniería Civil, Universidad de Las Palmas de Gran Canaria (ULPGC). España, 2005.
- [12] J.H. Holland, Adaptation in Natural and Artificial Systems, Ann Harbor: University of Michigan Press, 1975.
- [13] C.L. Hwang and K. Yoon, Multiple Attribute Decision Making: Methods and applications, Springer-Verlag, Berlin, 1981.
- [14] H. Ishibuchi and K. Narukawa, Performance Evaluation of Simple Multiobjective Genetic Local Search Algorithms on Multiobjective 0/1 Knapsack Problems, Proc. 2004 Congress on Evolutionary Computation (CEC'2004), volume 1, pages 441-448. IEEE Service Center, 2004.
- [15] A. Jaskiewicz, On the Performance of Multiple Objective Genetic Local Search on the 0/1 Knapsack Problem. A Comparative Experiment, IEEE Transactions on Evolutionary Computation, volume 6(4), 402-412. 2002.
- [16] M. Méndez and B. Galván, Multiple-Objective Evolutionary Algorithms Using the Working Point and the TOPSIS Method, In R. Moreno et al., ed., Lecture Notes in Computer Science, volume 4739, pages 796-803. Springer-Verlag, Berlin Heidelberg, 2007.
- [17] M. Méndez, B. Galván and G. Winter, En las Cercanías del Punto de Funcionamiento Utilizando Algoritmos Genéticos Multiobjetivo, En Actas del V Congreso Español de Metaheurísticas, Algoritmos Evolutivos y Bioinspirados (MAEB 2007). Tenerife, España, Febrero 2007.
- [18] M. Méndez, Algoritmos Evolutivos y Preferencias del Decisor Aplicados a Problemas de Optimización Multiobjetivo Discretos, Tesis Doctoral, Departamento de Ingeniería Mecánica, Universidad de Las Palmas de Gran Canaria (ULPGC). España, 2008.
- [19] M. Méndez, B. Galván, D. Salazar and D. Greiner, Multiple-Objective Genetic Algorithm Using the Multiple Criteria Decision Making Method TOPSIS, In 7th international conference on MultiObjective Programming and Goal Programming). Tours, France. June, 2006.
- [20] V. Pareto, Cours D'Economie Politique, Volumen I et II F. Rouge. Lausanne, Suisse, 1986.
- [21] R.L. Patisson and J.D. Andrews, Genetic algorithms in optimal safety system design, Proc. Inst. Mech. Engrs. Vol. 213, Part E, pages 187-197, 1999. Massachusetts, 1989.
- [22] J.D. Schaffer, Multiple Objective Optimization with Vector Evaluated Genetic Algorithms, PhD thesis, Vanderbilt University. 1984.
- [23] M. Zeleny, Multiple criteria decision making, McGrawHill, New York, 1982.
- [24] E. Zitzler and L. Thiele, Multiobjective optimization using evolutionary algorithms: A comparative case study, In A.E. Eiben et al., ed., Parallel Problem Solving from Nature (PPSN-IV, pages 292-301). Berlin, Germany. Springer, 1998.
- [25] E. Zitzler, Evolutionary Algorithms for Multiobjective Optimization: Methods and Applications, PhD thesis, Swiss Federal Institute of Technology Zurich. 1999.