

APLICACIÓN DEL MÉTODO DE SELECCIÓN DEL MEJOR SUBCONJUNTO EN PROBLEMAS DE OPTIMIZACIÓN MEDIANTE SIMULACIÓN

USING THE METHOD OF SELECTING THE BEST SYSTEM FOR OPTIMIZATION VIA SIMULATION

Sergio Daniel Ochoa Buitrago¹, Ciro Alberto Amaya Guio^{1,*}

RESUMEN

Dentro del proceso de optimización vía simulación (OvS) se utilizan procedimientos de búsqueda y exploración del espacio solución, así como etapas de costeo y depuración, con el fin de obtener una alternativa que optimice el desempeño del sistema en cuestión. La obtención de un conjunto de soluciones muy buenas enriquece el proceso de toma de decisión, ya que permite evaluar alternativas a la luz de la experiencia y situaciones puntuales del sistema. En este trabajo se desarrolló una aplicación que permite obtener un subconjunto de alternativas que apoyen el proceso de toma de decisión en la mejora de un sistema. La aplicación se desarrolló a partir de análisis de sensibilidad del método de selección frente a tamaños de muestra y parámetros iniciales, así como el efecto de inclusión de técnicas como Common Random Numbers (CRN). El método de selección empleado (Selección del mejor subconjunto - BSS) se comparó con otro de similares características (Selección del mejor - NSGS), obteniendo resultados favorables en desempeño y robustez. Como resultado de la metodología propuesta, en el subconjunto final se encontró la mejor solución explorada bajo un parámetro de riesgo definido, así como una serie de alternativas competentes para la maximización del desempeño del sistema.

Palabras clave: Evaluación de escenarios, sistemas complejos, diseño de experimentos, optimización vía simulación, BSS, multi-etapa, CRN.

ABSTRACT

There are many algorithms and methods used in order to optimize systems using simulation procedures. These methods involve local search algorithms and solution space exploration methods, and additional costing stages. The main objective of these procedures is to obtain the best configuration in order to maximize the system performance. However, solutions must be analyzed through expertise and criteria of decision makers, and obtaining a set of possible solutions instead of only one is more valuable. An entire methodology was developed based on sensitivity analysis of input parameters and sample sizes in order to obtain a subset of very good alternatives from a big set of possible scenarios. As an additional sensitivity analysis, an experiment of the effect of Common Random Numbers (CRN) in the selection method performance was conducted. The selection method used on this work (Best Subset Selection – BSS) was compared to other with similar specifications (Selection of the best – NSGS) obtaining higher performance results. As a result of the suggested methodology, there will

¹Departamento de Ingeniería Industrial, Universidad de los Andes, Bogotá, Colombia

*Autor para correspondencia: ca.amaya@uniandes.edu.co

be at the final set a few high competitive alternatives that could significantly improve system performance.

Keywords: Evaluation of scenarios, complex systems, design of experiments, optimization by simulation, BSS, multi-stage, CRN.

INTRODUCCIÓN

Al proceso de encontrar la mejor configuración para un sistema determinado usando simulación se lo conoce como Optimización vía Simulación (OvS). En la literatura se encuentran diversas aplicaciones (Bianchi *et al.*, 2006); en general se observa la aplicación de métodos multi-etapa (Hong *et al.*, 2009). Generalmente, la primera de las etapas consiste en explorar o barrer el espacio solución y descartar escenarios significativamente poco competitivos (Gutjahr, 2011). Es común encontrar en la literatura que en la primera etapa se realiza un barrido rápido, sin mayor replicación, y se eliminan escenarios con base en valores sin ponderar el efecto de variabilidad. Esto implica la utilización de métodos que no consumen recursos computacionales significativos. Como segunda gran etapa se utilizan algoritmos de búsqueda local, que permiten recorrer el espacio solución, encontrar diferentes escenarios y costearlos hasta obtener el mejor de ellos (Hoos *et al.*, 2009). Dentro de los diferentes algoritmos usados se encuentran Búsqueda Tabú (TS), Algoritmos Genéticos (GA), Colonia de Hormigas (AC), y métodos asociados de selección y ordenamiento (R&S) (Wang *et al.*, 2011) (Carson *et al.*, 1997). Es en esta fase donde se realiza el mayor consumo de recursos computacionales, ya que es necesario considerar la variabilidad como factor determinante a la hora de eliminar o mantener un escenario frente a otro (Gutjahr, 2011).

Los métodos de R&S, (por las siglas en inglés de selección y ordenamiento) tienen como objetivo principal la obtención de la mejor población o subconjunto de posibilidades que contenga al mejor escenario o configuración. Se dividen principalmente en dos grupos, en relación a su enfoque esencial: Bayesianos y frecuentistas (Wang *et al.*, 2011). En los primeros se busca maximizar la probabilidad de elección correcta de la mejor alternativa dentro del subconjunto o subpoblación final, y en algunas variaciones se intenta minimizar el costo de oportunidad de no incluir algún escenario dentro de la población final acotada (Carson *et al.*, 1997). Este enfoque presenta la dificultad de asegurar la probabilidad de encontrar la mejor alternativa, por lo que no hay garantía de selección de la mejor configuración dentro de la población final. En cuanto a los métodos pertenecientes al grupo frecuentista, son conservadores, ya que parten de una probabilidad como parámetro inicial, con la que se quiere obtener la mejor alternativa dentro de la población final, de tal modo que se asegura un nivel de significancia fijo desde el inicio de la búsqueda (Wang *et al.*, 2011) (Kim & Nelson, 2003). El método propuesto por Wang *et al.* (2011) se centra en procedimientos frecuentistas, garantizando un nivel de probabilidad de selección preestablecido; este último método es conocido como BSS (Best Sub Set procedure)

Dentro de las diferentes formulaciones del problema de comparación de alternativas en R&S, se encuentran dos: Formulaciones basadas en Zona de Indiferencia (Dudewicz *et al.*, 1975) y basadas en Selección de Subconjuntos (Gupta, 1965; Kim & Nelson, 2003). Las formulaciones relacionadas con Zona de Indiferencia proveen la garantía de seleccionar el mejor sistema, donde el parámetro de indiferencia δ se define como el rango en que el experimentador se considera "indiferente" frente a alternativas dentro de δ de la mejor. La Selección de Subconjuntos encuentra un subconjunto de las alternativas definiendo una probabilidad que garantice que dentro del subconjunto se encuentre la mejor alternativa (Wang *et al.*, 2011).

Dado que en problemas de toma de decisión se quiere saber la mejor alternativa para un sistema real, y los modelos son simplemente abstracciones de la realidad que pueden no corresponder totalmente al sistema real, encontrar la mejor alternativa mediante herramientas de simulación puede llevar a que su implementación en la realidad sea imposible. Los analistas han supuesto que existe una preferencia a obtener la mejor alternativa de la simulación; sin embargo, obtener un conjunto de soluciones competitivas, y dentro de este conjunto la mejor alternativa bajo un parámetro de riesgo conocido, podría enriquecer mucho más el proceso de toma de decisión. Esta discusión es presentada en el trabajo de (Wang *et al.*, 2011), que ilustra cómo es más ventajoso para quienes deben tomar las decisiones optar por un grupo de escenarios muy buenos y contrastarlos detalladamente con su implementación en la realidad, más allá de comprometerse con la única solución. Como alternativa, estos investigadores generaron un algoritmo que permite obtener sistemáticamente un subconjunto solución que contiene la mejor alternativa fijando una probabilidad de confianza de antemano y partiendo de un conjunto finito de alternativas base. Sugieren que, dado que existen diferencias entre la mejor alternativa encontrada en simulación y la que se podría tener en la realidad, es mejor obtener un subconjunto de muy buenas alternativas que contenga la mejor, explorada, con cierta probabilidad y que se pueda aplicar al sistema real fácilmente. Dicho método recibe el nombre de Selección del Mejor Subconjunto (BSS). Adicionalmente se plantea la posibilidad de incorporar técnicas de simulación como Common Random Numbers(CRN) para mejorar el rendimiento del algoritmo.

El método BSS consiste en cuatro etapas que se expondrán a continuación: Set up de parámetros, inicialización, exploración y terminación. El objetivo principal es diferenciar al conjunto de escenarios o alternativas en aquellos que son indeseables, aceptables y deseables, como se muestra en la figura1. (Wang *et al.*, 2011).




Figura 1. Diagrama general del método del mejor subconjunto.

Set up de parámetros:

Se debe seleccionar nivel de significancia α , asociado a la probabilidad de selección correcta P^* . Adicionalmente se debe seleccionar un tamaño de muestra inicial n_0 . En secciones posteriores se realizará un análisis sobre la conveniencia de ciertos valores como tamaño de muestra inicial. Se debe definir un parámetro de límite $\lambda > 0$, que va a decidir la frontera entre lo deseable y indeseable y se definirá un parámetro de tolerancia sobre la frontera ϵ , creando así un área de indiferencia sobre ésta. A continuación se presentan algunas relaciones basadas en los parámetros anteriores.

- Probabilidad de selección correcta

$$P^* = 1 - \alpha \tag{1}$$

- Parámetro de límite

$$\lambda = (\lambda^+ + \lambda^-)/2 \quad (2)$$

- Ancho de intervalo

$$\varepsilon = (\lambda^+ - \lambda^-)/2 \quad (3)$$

- Factor η

$$\eta = \frac{1}{2} \left[\left(\frac{4\alpha}{k(k-1)} \right)^{-2/(n_0-1)} - 1 \right] \quad (4)$$

Donde k es el número de escenarios a evaluar. El factor η se utilizará para estimación de la varianza en la comparación de escenarios y se explicará en pasos posteriores dentro del modelo.

Inicialización:

Se definirá $I = [1, 2, \dots, k]$ como el conjunto de escenarios a evaluar, y N como el conjunto de los mejores escenarios. Se debe obtener n_0 salidas de cada escenario X_{ij} ($j = 1, 2, \dots, n_0$), estimar su promedio y la varianza de las diferencias entre cada par de escenarios. La variable r será el contador de observaciones en cada paso del método. Las ecuaciones se presentan de la siguiente manera:

- Promedio de las salidas de cada escenario

$$\bar{X}_i = \sum_{j=1}^{n_0} \frac{X_{ij}}{n_0} \quad (5)$$

- Estimación de la varianza de las diferencias de cada par de escenarios

$$S_{il}^2 = \frac{1}{n_0 - 1} \sum_{j=1}^{n_0} (X_{ij} - X_{lj} - [\bar{X}_i - \bar{X}_l])^2, \quad (6)$$

$$\forall i \neq l \in I$$

- Cálculo del factor

$$h^2 = 2\eta(n_0 - 1) \quad (7)$$

- Definir contador de observaciones

$$r = n_0 \quad (8)$$

Exploración:

En esta etapa se realiza la comparación de alternativas, de tal modo que si el escenario se encuentra por fuera del límite frente al resto, será excluido. Se continúa con el procedimiento hasta que no haya posibilidad de excluir a ningún otro escenario.

- Definir $\bar{Y}_{il}(r)$, el vector de comparación de medias entre escenarios

$$\bar{Y}_{il} = \bar{X}_i - \bar{X}_l \quad i \neq l \quad (9)$$

- Definir $R_{il}(r)$, la diferencia frente al límite de tolerancia

$$R_{il} = \max \left\{ 0, \frac{\varepsilon}{2r} \left(\frac{h^2 S_{il}^2}{\varepsilon^2} - r \right) \right\} \quad (10)$$

- Si $\bar{Y}_{ii}(r) - \lambda \geq R_{ii}(r)$; se elimina el escenario l del conjunto I .

Terminación:

- Si se cumple que:

$$\bar{Y}_{ii}(r) - \lambda \leq -R_{ii}(r) \quad \forall i, l \in I, i \neq l$$

Se devuelve el conjunto I como el mejor conjunto N . De otro modo se actualiza $r = r+1$; y se vuelve a la etapa de exploración.

Se ha demostrado que el modelo es bastante preciso para tamaños de conjunto de escenarios moderados, es decir, alrededor de cien. Si el número de escenarios crece desproporcionadamente, también lo hará el error de estimación y, por tanto, disminuirá la precisión del modelo (Wang *et al.*, 2011). Debido a la estructura de la comparación, los resultados a nivel de consumo computacional, tiempo y eficacia de la solución son buenos.

Los métodos R & S atacan principalmente problemas en los que el número de soluciones factibles se supone pequeño; por ejemplo, menos de 20. Para hacer frente a problemas más grandes, se necesitan mejoras; éste es un tema de investigación en la comunidad de simulación. Un método simple de selección de la mejor alternativa (NSGC) fue propuesto por Nelson, (Nelson *et al.*, 2001), el cual es válido si cada solución factible es independiente e idénticamente distribuido como una Normal.

Este estudio busca establecer las bondades del método BSS para su aplicación en problemas de optimización vía simulación, mediante el estudio experimental y la comparación con el método NSGC. La siguiente sección presenta la metodología, y los resultados se presentan en sección posterior.

METODOLOGÍA

Para el estudio se llevaron a cabo diferentes pruebas. En primera instancia se comparó el método BSS con el método NSGC, que tiene por objetivo encontrar el mejor de los escenarios posibles bajo criterios de riesgo y tolerancia. En segundo lugar se realizó un análisis del desempeño de BSS frente a cambios en los parámetros iniciales de tamaño de muestra, límite de indiferencia y error. Se realizaron pruebas del efecto de uso de técnicas de reducción de varianza como CRN en el desempeño de BSS. Todo lo anterior, para definir la viabilidad y utilidad del método en una aplicación de solución de problemas de optimización vía simulación. Se tomó un modelo de simulación base de una sala de urgencias tipo, en que se contaba con diferentes escenarios que dependían de la cantidad de personal asignado en diferentes procesos del sistema. Se quiere encontrar los escenarios que permitan el menor tiempo de atención posible para un tipo de paciente específico (Crítico). Las variables o controles del proceso se tomaron como la cantidad de auxiliares, enfermeras y médicos del centro de atención. Los límites de cada recurso se presentan en la tabla 1.

En el desarrollo de esta prueba se tomaron 12 escenarios (fijando auxiliares y Triage en el menor valor), donde el mejor corresponde al que tenga menor tiempo de atención a un tipo de usuario específico.

Tabla 1. Escenarios contemplados.

Recurso	Mínimo	Máximo
Enfermeras	2	5
Doctores	1	3
Auxiliares	1	2
Triage	1	2

RESULTADOS

En el trabajo expuesto por Wang (Wang *et al.*, 2011) se presentan varias pruebas de rendimiento frente a otros algoritmos de R&S y combinaciones de estos. En esta sección se presenta una prueba básica de selección de escenarios, utilizando el método BSS y el método NSGC. Se aplicaron los procedimientos para encontrar la mejor alternativa (o subconjunto), con valores de límite de 1 para cada método y tolerancia de 15% para BSS. Los resultados son presentados en la tabla 2,3 y 4. La tabla 2 presenta los valores obtenidos con el método BSS, mostrando el valor solución encontrado para cada escenario seleccionado y el número de réplicas usado para ello. En la tabla 3 se presenta el resultado obtenido por el método NSGC, y la tabla 4 compara los dos métodos.

Tabla 2. Resultados BSS para el caso base.

Parámetro	Escenarios				
	10	11	12	8	7
Media	21,25	21,43	21,49	21,71	21,86
Réplicas	45	45	45	45	45

Tabla 3. Resultados NSGS para el caso base.

Parámetro	Escenario 12
Media	21,11
Réplicas	124

Tabla 4. Comparación de resultados NSGS y BSS.

Medida de desempeño	NSGS	BSS
Máximo de réplicas	148	45
Total réplicas	642	392

Como se puede observar, los métodos presentan resultados similares en cuanto a la selección del mejor escenario, pero difieren significativamente en el tamaño de muestra que se requiere para llegar a la conclusión. Adicionalmente, una diferencia evidente es que el método BSS proporciona más información que NSGS, ya que retorna un subconjunto con los mejores escenarios, mientras que el segundo sólo asegura la selección de un escenario. La primera diferencia implica una mayor eficiencia para BSS frente a NSGS, ya que se requiere menor

consumo computacional para llegar a la misma conclusión. La segunda diferencia indica que la decisión estará mejor soportada y se podrá enriquecer con un conjunto de escenarios altamente competitivos. En el trabajo desarrollado por Wang (Wang *et al.*, 2011) se presentan pruebas adicionales con procedimientos R&S, donde se evidencian las grandes ventajas del uso de BSS en OvS.

Análisis de sensibilidad de BSS frente a cambios en los parámetros iniciales

Se realizó un análisis del desempeño del método del mejor subconjunto, tomando como variable respuesta el número necesario de réplicas para obtener el conjunto final. En esta sección se presenta el efecto de los parámetros de límite (λ), tolerancia sobre el límite (ϵ), y número de réplicas iniciales. Los resultados se presentan en las figuras 2 y 3. En cada figura el valor dentro de las casillas representa el número de réplicas necesario para concluir el método BSS; el color indica el tamaño del subconjunto, y en los ejes se encuentra tanto el límite como la tolerancia (expresada en porcentaje respecto al límite).

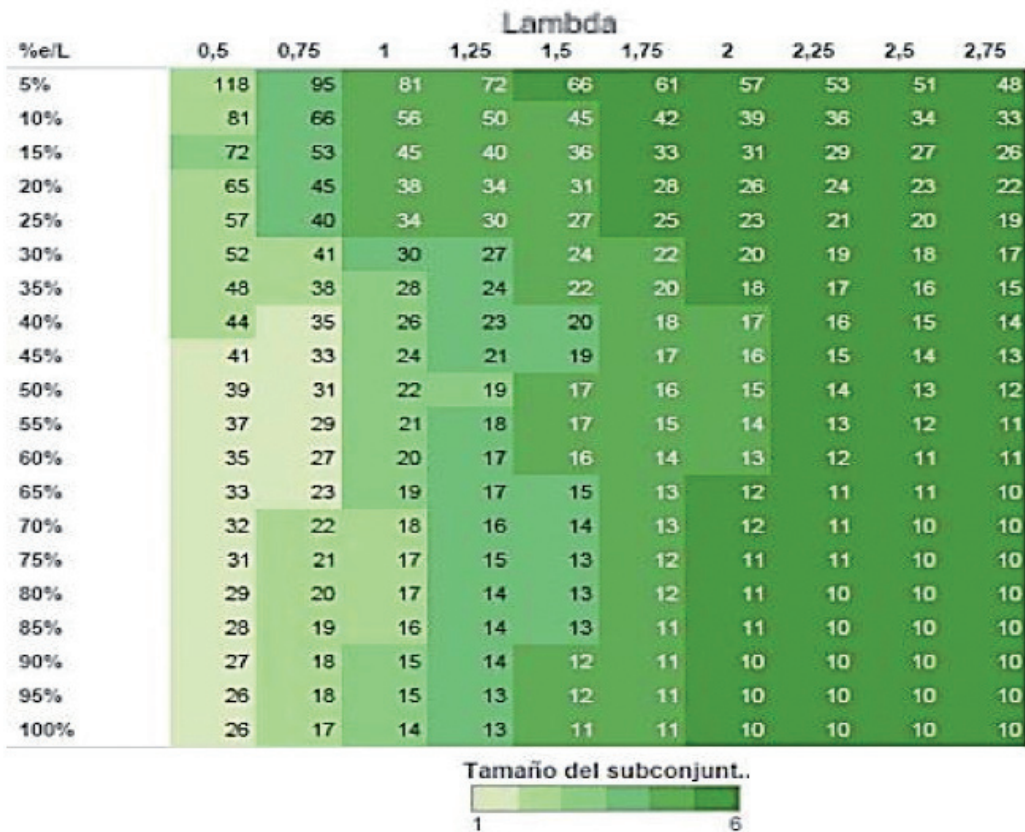


Figura 2. Máximo de réplicas y tamaño de subconjunto versus límite y tolerancia. $N_0=10$.

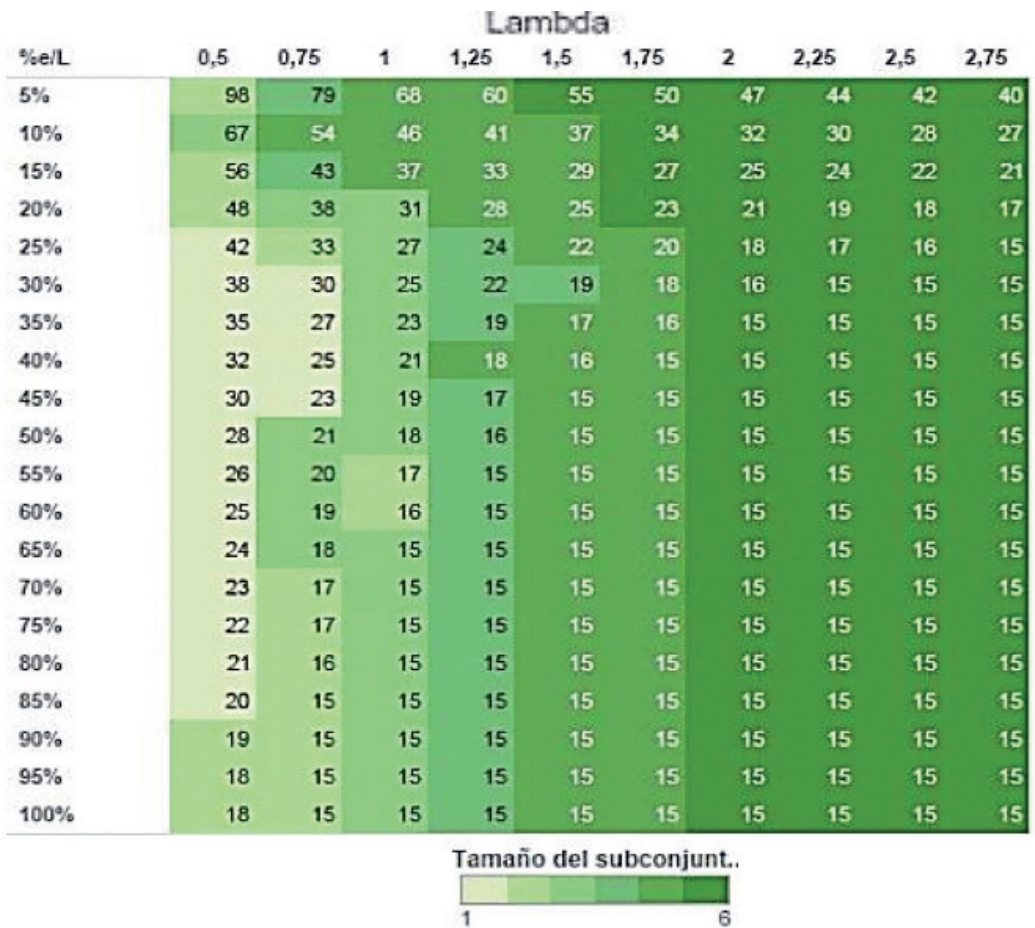


Figura 3. Máximo de réplicas y tamaño de subconjunto versus límite y tolerancia. $N_0=15$.

Análisis de sensibilidad frente al tamaño de muestra inicial

En cuanto al número de réplicas iniciales, la hipótesis inicial fue que hubiera una mejor estimación de la varianza de diferencias entre escenarios, cuanto mayor fuera el tamaño inicial de muestra. Esto se traduciría en menor cantidad de muestras adicionales para la obtención del mejor subconjunto. Lo anterior significaría que es recomendable iniciar el método de selección partiendo de un gran tamaño de muestra, pero esto puede ser contraproducente, ya que si bien se reduciría la cantidad de réplicas adicionales, este efecto no se vería compensado con el muestreo total. Por el contrario, si se inicia el método con un tamaño de muestra reducido, será necesario obtener mayor número de réplicas adicionales. Por tal razón, se debe buscar un equilibrio de tal modo que la recolección inicial compense al tamaño de muestra adicional.

El equilibrio entre tamaño de muestra inicial y número de réplicas adicionales está muy relacionado con la dispersión de los escenarios y la estimación de la varianza de sus diferencias. Cuanto menor sea el tamaño de muestra inicial, la estimación de la dispersión de los escenarios será menos adecuada y, por tanto, la cantidad de réplicas adicionales puede incrementarse. Por el contrario, si se tiene un tamaño de muestra inicial grande, se obtendrá mayor fiabilidad del estimador de varianza inicial y en consecuencia, puede que se necesiten muy pocas

réplicas adicionales para determinar el subconjunto de las mejores alternativas. Adicional a esto, es conveniente evaluar métodos de reducción de varianza, ya que estos permitirían una mayor precisión, y por tanto, se esperaría menor generación de réplicas adicionales. Uno de estos métodos es *Common Random Numbers* (CRN), y su efecto será analizado en secciones posteriores.

Análisis de sensibilidad frente a los parámetros de indiferencia

Se esperaba que cuanto mayor fuera el parámetro de límite, el número de réplicas adicionales para seleccionar el subconjunto de escenarios disminuya. Lo anterior, porque se amplía la zona de tolerancia y por tal razón el criterio de selección se relaja, permitiendo la entrada de escenarios menos competitivos.

Se observó que efectivamente, tanto el número máximo de corridas como el máximo para cada punto, disminuyen significativamente con el aumento del límite, para la mayoría de casos de tamaño inicial de muestra. El efecto en el aumento del tamaño inicial hacia valores altos es mayor que el efecto de variación en el límite de tolerancia. Se observa también que a medida que crece la tolerancia para cualquier límite, el número máximo de réplicas para el método disminuye. Este efecto es concordante con la intuición que se tenía, ya que si se quiere un grado de precisión mayor, se necesitarán mayores tamaños de muestra para lograrlo. De manera similar a lo comentado anteriormente, el efecto de tamaño de muestra inicial comienza a pesar significativamente a medida que aumenta.

Los efectos observados en las figuras 2 y 3 se extienden para el resto de tamaños iniciales contemplados (hasta 50). Aunque a simple vista es mejor elegir un valor límite pequeño junto con un porcentaje alto de tolerancia, se debe tener en cuenta que esta decisión afecta el tamaño del subconjunto. Por tal razón, se debe balancear adicionalmente el número deseado de escenarios en el subconjunto final, ya que justamente el interés principal del modelo de selección del mejor subconjunto es obtener una reducida gama de posibilidades muy buena, de tal modo que se pueda decidir a la luz de la experiencia del evaluador. De poco serviría, para el propósito mencionado, la obtención de un subconjunto de tamaño unitario, ya que no enriquecería el proceso de selección. Tampoco sería de gran utilidad la consecución de un conjunto de tamaño muy grande, ya que la evaluación final tomaría bastante tiempo y resultaría en un proceso poco práctico.

Como se puede observar, en puntos donde se requiere menor cantidad de réplicas adicionales, es posible obtener subconjuntos de tamaño reducido si la disminución de réplicas se da por aumento significativo de tolerancia. Si la tolerancia es muy pequeña, es posible encontrar subconjuntos de mayor tamaño, pero es necesario hacer un consumo computacional mucho más grande para lograrlo, ya que el número máximo de réplicas puede llegar a ser bastante mayor. Si el límite es muy amplio y la tolerancia es grande, se obtiene un subconjunto de mayor tamaño, pero a costa de relajar el criterio de selección, pues escenarios que se creían poco competitivos podrían ser seleccionados como los mejores. Escoger un tamaño de muestra inicial cercano a 10 y 15 es una buena opción para el caso de estudio, ya que presenta poca variabilidad a factores subjetivos como el límite y la tolerancia. Este tamaño de muestra permite obtener buenos resultados a nivel de tamaño de subconjunto y número de réplicas necesarias para su obtención. Tamaños de muestra iniciales cercanos a 50 parecen poco eficientes, ya que se pueden obtener los mismos resultados con menor muestreo para ciertos niveles de tolerancia y de límite.

Efecto de número de escenarios en BSS

La hipótesis inicial consistió en que cuanto mayor es el número de escenarios evaluados,

el método BSS requiere mayores tamaños de muestra para ser concluyente. Se realizó el procedimiento para 12 y 48 escenarios, con un $n_0 = 10$, límite de 1 ($\lambda=1$) y tolerancia de 15% ($\epsilon/\lambda=15\%$). Los resultados se presentan en la tabla 5.

Tabla 5. Resultados comparación de número de escenarios.

Número de escenarios	Máximo de réplicas	Total de réplicas	Tamaño del subconjunto
12	45	392	5
48	71	1707	4

En los datos de la tabla 5 se evidencia que una reducción del 75% en el número de escenarios implica una reducción aproximada del 36% en el máximo de réplicas y del 78% del total de réplicas. Esto indica que si el número de escenarios a evaluar es muy grande, el consumo computacional para selección de los mejores escenarios se incrementa significativamente. Para una aplicación del método se debe tener en cuenta este factor, ya que un exceso de réplicas puede resultar poco eficiente.

Efecto de CRN en BSS

Mediante el uso de técnicas de reducción de varianza se puede mejorar el desempeño de procedimientos R&S. Se tomó como base un conjunto inicial de 48 escenarios y se utilizó BSS para obtener los mejores escenarios. En comparación con el caso anterior de igual cantidad de escenarios, el uso de CRN reduce significativamente el tamaño de muestra para selección de alternativas. Los resultados se presentan en la tabla 6.

Los resultados de la tabla 6 indican que la aplicación de CRN, para el caso particular, genera robustez en la selección de escenarios, porque para diferentes valores de tamaño de muestra inicial se seleccionan casi los mismos escenarios. Esto se debe a que aplicar CRN es similar a bloquear el factor de generación de aleatorios, y por tanto, la estimación de las diferencias de medias mejora (Deng, 2007; Banks *et al.*, 2009). Para una aplicación de BSS puede ser conveniente el uso de CRN, pero depende fuertemente del software empleado, ya que la forma en que se aplica esta técnica puede variar significativamente.

Tabla 6. Resultados comparación BSS con CRN.

N_0	Máximo de réplicas		Réplicas totales		Tamaño del subconjunto		Escenarios del subconjunto	
	BSS	BSS-CRN	BSS	BSS-CRN	BSS	BSS-CRN	BSS	BSS-CRN
5	204	171	4240	3975	9	9	10;11;12;20;22;23;24;46;48	6;10;11;12;22;23;24;35;36
10	71	73	1707	1920	4	9	11;12;23;24	6;10;11;12;22;23;24;35;36
15	52	48	1436	1472	3	10	11;12;23	6;10;11;12;22;23;24;35;36;47
20	48	40	1364	1344	3	10	11;12;23	6;10;11;12;22;23;24;35;36;47
50	50	50	2400	2400	10	10	10;11;12;18;20;22;23;24;46;48	6;10;11;12;22;23;24;35;36;47

CONCLUSIONES

Después de una comparación del desempeño de BSS frente a otro método de su misma naturaleza (NSGS), se observó que en términos de réplicas totales y calidad de resultados, el método BSS presenta mejor desempeño.

Se encontró que valores muy bajos de tamaño de muestra inicial se traducen en exceso de muestreo a lo largo del desarrollo del método y, que valores muy altos pueden resultar poco eficientes en términos de consumo computacional y tiempo de solución.

Se observó que los parámetros de límite y tolerancia afectan tanto el muestreo total como el tamaño del subconjunto resultante, ya que pueden relajar o restringir el criterio de selección empleado. Se debe tener valores de límite y tolerancia moderados para obtener soluciones que apoyen efectivamente el proceso de toma de decisión.

Se observó que la implementación de técnicas de reducción de varianza como CRN pueden aumentar la robustez de BSS frente a cambios de tamaño de muestra inicial. El efecto de parámetros de límite y tolerancia es similar al de BSS sin CRN. Esto se puede extender para otros casos, a partir de la definición de la técnica y el fundamento de BSS.

Se observó que aunque una limitación de BSS es la cantidad de escenarios a evaluar, mediante técnicas estadísticas como DOE se puede limitar el conjunto de alternativas. Teniendo en cuenta esta limitación, es importante que en una posible aplicación del método se implemente una etapa de depuración inicial del espacio solución.

Se propone como aplicación un método multi-fase, de tal modo que se depure inicialmente el espacio solución inicial mediante herramientas estadísticas, se explore el espacio solución, de ser necesario, haciendo uso de herramientas existentes en software especializado y se aplique BSS sobre el espacio reducido a manera de etapa final de selección. De este modo, se hace un mejor uso de los recursos computacionales y se puede obtener un conjunto de solución que apoye efectivamente el proceso de toma de decisión.

RECOMENDACIONES

Como trabajo futuro se propone el desarrollo de una herramienta que automatice el proceso para llegar a encontrar soluciones óptimas vía simulación; tal herramienta podría basarse en la metodología propuesta.

REFERENCIAS

- BANKS, J., CARSON, J., NELSON, B., and NICOL, D. *Discrete-event system simulation*. Prentice Hall. 5a ed. 2009. 622 p.
- BIANCHI, L., DORIGO, M., and GAMBARELLA, M. *Metaheuristics in Stochastic Combinatorial Optimization: a Survey* [en línea]. IDSIA reporte técnico, 2006. <<http://www.idsia.ch/idsiareport/IDSIA-08-06.pdf>> [Consulta 9 de septiembre 2013].
- CARSON, J., and MARIA, A. *Simulation optimization: Methods and applications*. In: Proceedings of the Winter Simulation Conference (1997: Atlanta, Georgia, USA). [1997].
- DENG, G. Simulation-Based optimization. Tesis Doctoral. USA: University of Wisconsin, 2007.

DUDEWICZ, E. J., and Dalal, S. *Allocation of Observations in Ranking and Selection with Unequal Variances*. Sankhya. The Indian Journal of Statistics, 1975, Series B 37, no.1, p. 28–78.

GUPTA, S. S. *On Some Multiple Decision (Selection and Ranking) Rules*. Technometrics, 1965, vol. 7, no.2, p. 225–245.

GUTJAH, W. *Recent trends in metaheuristics for stochastic combinatorial optimization*. Central European Journal of Computer Science, 2011, vol.1, p. 58-66.

HONG, L., and NELSON, B. *A brief introduction to optimization via simulation*. In: Proceedings of the 2009 Winter Simulation Conference (2009: Austin, Texas, USA). [2009].

HOOS, H., and SÜTZLE, T. *Stochastic local search. Foundations and applications*. Morgan Kaufmann Publishers Inc. San Francisco, CA, USA. 2004.

KIM, H., and NELSON, B. *Selecting the best system: Theory and methods*. Proceedings of the 2003 Winter Simulation Conference. New Orleans, Louisiana, USA. 2003.

NELSON, B., SWANN, J., GOLDSMAN, D., and Song, W. *Simple procedures for selecting the best simulated system when the number of alternatives is large*. Operations Research, 2001, vol. 49, no.6, p. 950–963. 2001

YU W., LUANGKESORN L., and SHUMAN L. *Best-subset selection procedure*. In: Proceedings of the 2011 Winter Simulation Conference. (2011: Phoenix, Arizona, USA) [2011]