

# Comparación de dos estrategias para utilizar metamodelos en optimización vía simulación


Shirley Marbella Rojas Minjarez<sup>A</sup>, Esmeralda Niño Pérez<sup>B</sup>,  
Ma. Guadalupe Villarreal Marroquín<sup>C</sup>, Mauricio Cabrera Ríos<sup>D</sup>

<sup>A</sup> Departamento de Ingeniería Industrial, Instituto Tecnológico de los Mochis.

<sup>B</sup> Facultad de Ingeniería Mecánica y Eléctrica, FIME, UANL.

<sup>C</sup> Department of Integrated Systems Engineering, The Ohio State University.

<sup>D</sup> Industrial Engineering Department, University of Puerto Rico at Mayagüez.  
mauricio.cabrera1@upr.edu



## RESUMEN

*En optimización vía simulación (OvS) se busca obtener el mejor valor posible de una respuesta de interés a partir de la manipulación de variables de decisión asociadas con un modelo computacional del sistema bajo estudio. Una manera de lograrlo es construir un modelo empírico que represente la variación de la respuesta de interés en función de las variables de decisión para después optimizar este nuevo modelo. A un modelo empírico construido a partir de datos generados por otro modelo (de simulación), se le conoce como metamodelo. Este trabajo compara dos estrategias, en la primera se construye un metamodelo único el cual intenta representar la variabilidad global del proceso, mientras que la segunda utiliza uno que se va adaptando iterativamente y logra una alta fidelidad local. La primera estrategia es la más difundida en la práctica de OvS con metamodelos, sin embargo, este estudio apunta a que se puede lograr un mejor desempeño en optimización con la segunda estrategia.*

## PALABRAS CLAVES

Metamodelo, Optimización de Simulaciones, Redes Neuronales Artificiales.

## ABSTRACT

*In Optimization via Simulation (OvS) the aim is to obtain the best possible value of a response of interest through the manipulation of decision variables associated to the computational model of a system under study. One way to carry out OvS is to build an empirical model that maps out the response as a function of the decision variables to, then, optimize such model. An empirical model fitted to data generated by another (simulation) model, is called a metamodel. In this work, two strategies are compared, in the first a global representation is sought through the creation of a metamodel in one iteration. In the second strategy, the focus is on the iterative construction of a metamodel with emphasis on local representation. The first strategy is the most popular way to use metamodels in OvS. The results of this study suggest, however, that the second strategy might lead to a more effective optimization.*

## KEY WORDS

Metamodel, Simulation Optimization, Artificial Neural Network.

## INTRODUCCIÓN

La necesidad de optimizar en el quehacer ingenieril es indudable. Diariamente se requiere tomar decisiones, preferentemente óptimas, sobre diseños, condiciones de operación, configuración de sistemas, asignación de recursos limitados, selección de equipo y materiales, entre muchas otras. Para tomar estas decisiones por lo general se requiere experimentar. Sin embargo, la experimentación dentro de sistemas industriales ya existentes es por lo general costosa y poco conveniente. Por supuesto, en sistemas que aún no están construidos, la experimentación no es ni siquiera una opción. Afortunadamente, con el desarrollo de computadoras y paquetes computacionales cada vez más poderosos se ha facilitado la creación de modelos de simulación tanto de fenómenos físicos como de eventos discretos en prácticamente todas las modalidades de la ingeniería. Es, entonces, muy conveniente utilizar estos modelos para representar y optimizar procesos y sistemas industriales.

Capitalizando en las fortalezas de ambas disciplinas, optimización y simulación, es deseable conjuntar estos métodos para poder tomar mejores decisiones. El área que se ha encargado de hacer esta conjunción se denomina Optimización via Simulación (Optimization via Simulation en inglés) y a la cual se le referirá como OvS en este artículo. En este trabajo se comparan dos estrategias para OvS basadas en el uso de metamodelos. Los metamodelos son, en general, modelos empíricos creados con datos generados por modelos computacionales, esto es, son modelos de modelos. Un ejemplo de un modelo empírico es una ecuación de regresión y un ejemplo de modelo computacional, es uno de simulación por computadora de flujo de materiales. En OvS es común utilizar el modelo de simulación para tratar configuraciones determinadas por medio de variables controlables y obtener estimaciones de una medida de desempeño de interés. Al tratar varias configuraciones se generan datos con los cuales se puede ajustar un metamodelo. El uso de un metamodelo pretende facilitar la labor de optimización, que implica encontrar la configuración que provea el mejor valor posible de la medida de desempeño de interés.

El objetivo de este trabajo es presentar y comparar dos estrategias de OvS para crear metamodelos que

sean después objeto de optimización. La primera estrategia consiste en construir un metamodelo en una sola iteración que intenta representar la variación global. La segunda estrategia involucra la construcción de un metamodelo que iterativamente aumente su complejidad apuntando hacia una alta fidelidad local. La primera estrategia es una práctica común en OvS, con un énfasis en buscar una representación fiel en todo el rango de variación de las variables de decisión y favoreciendo modelos con poca complejidad. La segunda estrategia ha sido propuesta por nuestro grupo de investigación para dar prioridad a la optimización y no a la representación. Con esta segunda estrategia es permisible tener una excelente representación local aun cuando ésta sea muy compleja y no necesariamente una buena representación a nivel global.

La comparación de ambas estrategias se realiza a través de un caso de moldeo por inyección en el cual se modela la fabricación de la carátula de un teléfono celular. La calidad de los métodos se discute a la luz del valor de la solución encontrada así como en términos de la complejidad del mismo.

## ANTECEDENTES

El objetivo de los métodos de OvS es proveer una estructura para determinar los valores de variables controlables con el fin de optimizar una función de las salidas de un modelo de simulación.<sup>2</sup> Una rutina de optimización utiliza la salida del simulador como función objetivo dependiente de las entradas que fueron introducidas en el modelo y, en base a ésta y a evaluaciones anteriores, propone un nuevo conjunto de valores en las variables controlables. Este procedimiento continúa hasta que se cumpla un criterio de terminación.<sup>3</sup> La figura 1 muestra un diagrama genérico de OvS.

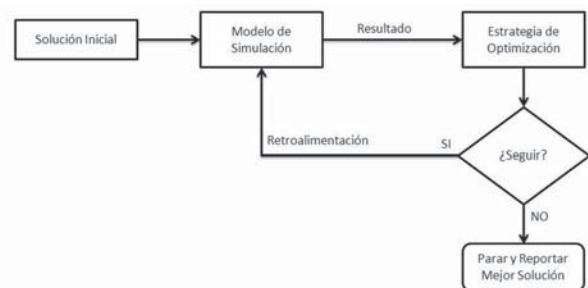


Fig. 1. Diagrama de optimización via simulación.

Existen diferentes métodos de OvS en la literatura. Estos métodos incluyen técnicas como programación no lineal, métodos de superficie de respuesta, aproximación estocástica, búsqueda aleatoria, ordenamiento y selección, metaheurísticas, entre otras. Revisiones de literatura comprensivas acerca de técnicas de optimización aplicadas a la simulación bajo diferentes enfoques se pueden encontrar en.<sup>2, 4-9</sup>

De particular interés en este trabajo son los métodos de OvS que utilizan metamodelos. Una revisión amplia del uso de metamodelos se puede encontrar en la referencia.<sup>10</sup> La regresión lineal estándar aparece como una de las técnicas más populares para este fin. Más recientemente las Redes Neuronales Artificiales (RNAs) han ganado popularidad también.<sup>11</sup> Buot *et al.*<sup>12</sup> utilizaron una RNA dentro del problema de minimizar la ocupación de dos zonas del área de embarque de una empresa chilena; Altıparmak *et al.*<sup>13</sup> construyeron una RNA para determinar el tamaño óptimo de los espacios de almacenaje en una línea de ensamble asincrónica; Martin y Simpson<sup>14</sup> desarrollaron un método basado en metamodelos kriging adaptativos con el objeto de representar lo mejor posible toda la superficie de respuesta; Cheng y Currie<sup>15</sup> utilizaron aproximación Bayesiana para construir una serie de regresiones cuadráticas; Moniaci y Pasero<sup>16</sup> utilizaron una RNA para representar la efectividad de una línea de producción. Dado el éxito del uso de metamodelos y a que hemos reportado la efectividad de usar diseño de experimentos para optimización aplicada a la simulación de fenómenos físicos y químicos en otras publicaciones,<sup>1, 17-22</sup> se decidió hacer uso de ambas técnicas en la construcción de una estrategia de OvS en la que un metamodelo se construye iterativamente para favorecer la búsqueda de una solución óptima.

Cabe mencionar que debido a que muchas de las técnicas propuestas en la literatura pueden resultar un reto para personas con conocimientos modestos de optimización y programación, se ha buscado automatizar este proceso. Actualmente varios paquetes comerciales de simulación tanto de eventos discretos como de fenómenos físicos, contienen módulos de optimización que utilizan, entre otras, estrategias metaheurísticas.<sup>11</sup> Con estas estrategias en general se gana rapidez a un costo de perder certeza sobre la optimalidad de las soluciones encontradas.

Estos módulos aumentan grandemente la capacidad del usuario para optimizar, sin embargo es común que no permitan la construcción de funciones objetivo o de restricciones funcionales. Creemos que la flexibilidad y transparencia de los problemas de optimización pueden contribuir mucho al proceso creativo de diseño de procesos y sistemas y que, por tanto, son características deseables en los métodos de optimización aplicada a la simulación.

## DESCRIPCIÓN DE LAS ESTRATEGIAS EN COMPARACIÓN

Las dos estrategias de OvS basadas en metamodelos que se comparan en este trabajo se muestran esquemáticamente en las figuras 2 y 3.

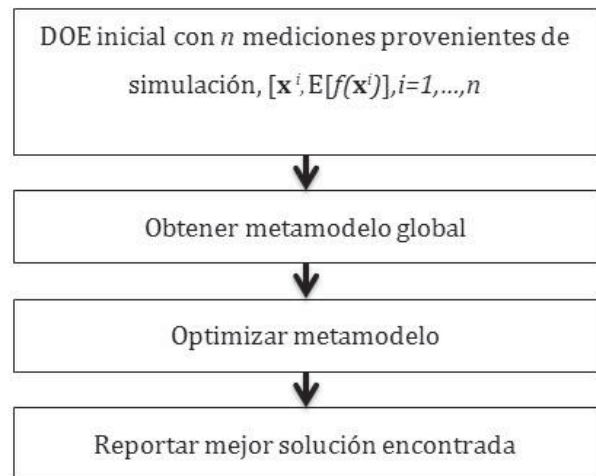


Fig. 2. Estrategia de OvS de una sola iteración con un metamodelo global.

### Estrategia 1: método de una sola iteración para construir un metamodelo que aproxime a nivel global

La primera estrategia (figura 2) consiste de una sola iteración y construye un metamodelo que intenta representar la variación global.

Como se puede apreciar en la figura 2, este método comienza con un diseño experimental (DOE) con n puntos experimentales (combinación de valores de variables controlables) y n evaluaciones del modelo de simulación. Después, la información del DOE (valores de variables controlables) y los resultados de la simulación (valores de función objetivo) son utilizados para aproximar la respuesta de interés de manera global por medio de un metamodelo.

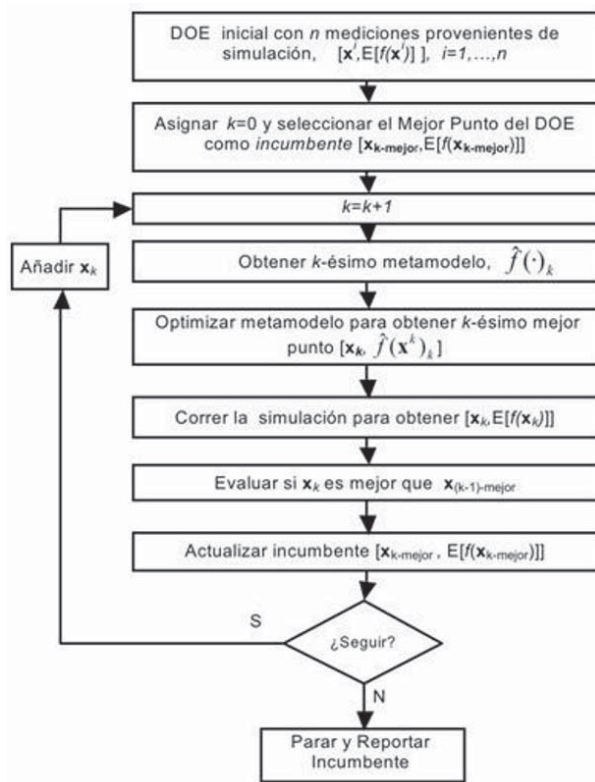


Fig. 3. Estrategia de OvS desarrollada por Villarreal y Cabrera-Ríos.<sup>1</sup>

Posteriormente, el metamodelo es optimizado para encontrar una solución atractiva al problema en estudio. Y finalmente, la mejor solución es reportada al tomador de decisiones.

Dada la intención de representar globalmente la variación en un diseño de experimentos, es común recurrir a metamodelos no lineales, tales como las RNAs. Se refiere al lector interesado a<sup>23</sup> para conocer más sobre este tipo de modelos. En este trabajo dos diferentes RNAs al igual que un modelo de regresión cuadrática fueron utilizados como metamodelos.

Dado que el modelo de optimización la mayoría de las veces es no convexo, un método de optimización local convergerá a una solución óptima no global. Es por esto que un método de optimización local se combina aquí con la técnica de múltiples comienzos para escapar de optimalidad local.

Una ventaja que se vislumbra con la estrategia 1 es que termina rápidamente, sin embargo, una desventaja potencial es precisamente su énfasis en encontrar una representación adecuada global.

## Estrategia 2: método iterativo para construir un metamodelo con alta fidelidad local

La segunda estrategia analizada fue propuesta por Villarreal y Cabrera-Ríos<sup>1</sup> y construye metamodelo en varias iteraciones con alta fidelidad local. La estrategia se muestra en la figura 3.

La estrategia se explica a continuación:

### Inicialización

- 1). DOE inicial: El método inicia con un DOE. Si las variables de decisión son pocas (menos de 10) y se tiene solamente restricciones laterales, se recomienda utilizar un Diseño Compósito Central (DCC). En cualquier otro caso, será necesario recurrir a otros diseños como el D-Óptimo. El DOE resultará en  $n$  corridas consistentes de combinaciones  $x^i = (x_1, x_2, x_3, \dots, x_v)^i$  de las  $v$  variables controlables (decisión) a incluir en el problema de optimización, así como su evaluación  $E[f(x^i)]$ , donde  $i=1,2,\dots,n$ . Si el DOE es replicado, entonces  $E[f(x^i)]$  será la media de las réplicas.
- 2). Solución incumbente: Se selecciona la combinación del DOE con el mínimo valor de la función objetivo. Esta combinación se convierte en la solución incumbente  $[x_{k-mejor}, E[f(x_{k-mejor})]]$ . También en este paso se inicializa un contador de iteraciones  $k:=0$ .

### Iteración Principal

- 3). Actualizar contador:  $k = k+1$ .
- 4). Obtener metamodelo: Utilizando los puntos disponibles, se construye el  $k$ -ésimo metamodelo  $\hat{f}(\cdot)_k$ . En el caso, se utiliza un metamodelo saturado, i.e. un modelo de regresión con  $(n-1)+(k-1)$  coeficientes. Las variables de entrada deberán estar escaladas en el rango  $[-1,1]$  para evitar problemas de dimensionalidad al obtener los coeficientes de regresión.
- 5). Optimizar metamodelo: Utilizando el metamodelo como función objetivo a ser minimizada sujeto a las restricciones pertinentes, se procede a utilizar la técnica de múltiples comienzos combinada con un optimizador local para obtener una solución atractiva,  $x_k$ .

- 6). Ejecutar la simulación en el nuevo punto: Estimar, vía simulación, el valor  $E[f(x_k)]$  cuidando que si el DOE inicial fue replicado, en esta estimación se tenga el mismo número de réplicas y se reporte la media.
- 7). Evaluar si el punto nuevo es mejor que el incumbente: En este caso, evaluar si  $x_k$  tiene un valor objetivo estrictamente menos a  $x_{(k-1)\text{-mejor}}$  i.e. si  $E[f(x_k)] < E[f(x_{(k-1)\text{-mejor}})]$ .
- 8). Actualizar la solución incumbente: Actualizar la solución incumbente de acuerdo a la evaluación del punto anterior. Si  $E[f(x_k)] < E[f(x_{(k-1)\text{-mejor}})]$ , entonces se asignará  $[x_{k\text{-mejor}}, E[f(x_{k\text{-mejor}})]] := [x_k, E[f(x_k)]]$ , de otra manera, la solución incumbente no cambiará.
- 9). Evaluar los criterios de terminación del método: tres criterios de terminación son evaluados: determinar si (1)  $x_k$  es parte del DOE inicial o de algunos de los puntos utilizados en previas iteraciones para construir el metamodelo, (2) el coeficiente de determinación,  $R^2=1$ , y (3) un número máximo de iteraciones se ha alcanzado.

Si alguno de los criterios de determinación se cumple, el método para y se toma la solución incumbente como la salida final. Si los criterios no se cumplen, entonces se añade  $x_k$  al conjunto de puntos disponibles para construir un nuevo metamodelo, y se regresa al inicio de la iteración principal.

Una estrategia de este tipo podría resultar en múltiple corridas de simulación adicionales, sin embargo, tiene la ventaja de ir añadiendo información importante para la creación de un metamodelo y favorecer así su convergencia a una solución atractiva, como se podrá apreciar en el caso de estudio que se presenta a continuación.

## CASO DE ESTUDIO

### Descripción del problema

El caso de análisis para este trabajo consiste en la simulación del proceso de moldeo por inyección de una carátula de teléfono celular. Este modelo de simulación es uno de los ejemplos incluidos en el paquete computacional MoldflowTM y se muestra en la figura 4. El problema de optimización implica encontrar los valores a los que se deben fijar la temperatura del molde y la presión de empaçado para



Fig. 4. Carátula del teléfono celular.

minimizar el tiempo de ciclo. El tiempo de ciclo es la suma del tiempo de llenado, el tiempo de empaçado y el tiempo de enfriamiento, lo cual se relaciona con el tiempo que utiliza efectivamente el molde en el proceso de moldeo por inyección. El material utilizado para moldear esta parte fue Petrothene GA584-000: Mellenium Petrochemical Inc. Como se mencionó anteriormente la temperatura del molde y la presión de empaçado fueron las variables de decisión y fueron variadas en el rango sugerido en la base de datos de materiales de Moldflow. El rango para la temperatura del molde fue de 185°C a 225°C y para la presión de empaçado de 10 MPa a 500 MPa.

Con respecto a la optimización, el diseño de experimentos inicial para ambas estrategias en comparación fue un diseño compuesto central (DCC) de 2 variables controlables (temperatura y presión), con 9 puntos experimentales (corridas del simulador). El diseño experimental se muestra en la figura 5 y en la tabla I.

La tabla I contiene además el valor de tiempo de ciclo obtenido al correr el simulador con cada combinación de valores de las variables controlables especificado. Cabe señalar que para este ejemplo no es necesario realizar réplicas pues al no contener la simulación variables estocásticas, se obtendría, dados los mismos datos, la misma respuesta todas las veces.

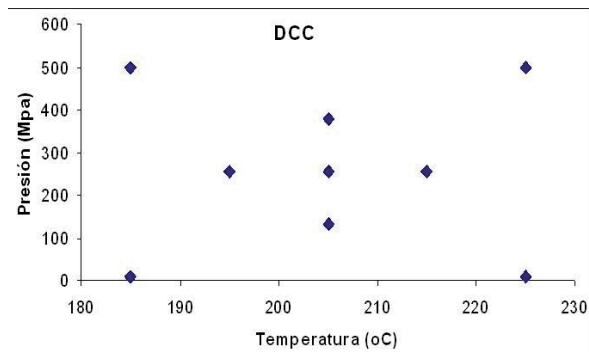


Fig. 5. Corridas del Diseño de Experimentos Inicial.

Tabla I. Diseño experimental inicial.

Temperatura (°C)	Presión (MPa)	Tiempo de Ciclo Simulado (seg)
185	10.0	4.06
185	500.0	3.87
195	255.0	3.76
205	132.5	4.02
205	255.0	4.02
205	377.5	4.02
215	255.0	4.16
225	10.0	4.20
225	500.0	4.20

Con la primera estrategia se construyeron 3 metamodelos a partir de los datos mostrados en la tabla I. El primero fue una regresión con términos lineales, cuadráticos e interacciones de segundo orden. El segundo fue una RNA de tres neuronas en la capa oculta entrenada solamente con 6 puntos del diseño experimental y validada con los 3 restantes. Mantener un conjunto de puntos de entrenamiento y otro conjunto de validación es común al aproximar por medio de RNAs.<sup>23</sup> Finalmente, el tercer modelo fue una RNA de tres neuronas en la capa oculta sin validación, entrenada con los 9 puntos del diseño experimental. Los resultados de la optimización utilizando cada uno de los metamodelos asociados con la estrategia 1 independientemente se compararon, entonces, con los resultados al aplicar la segunda estrategia como se describió en el apartado anterior.

Los resultados comparativos se muestran en la tabla II para la estrategia 1 con sus tres metamodelos variantes y para la estrategia 2. Se puede observar que el menor tiempo de ciclo se obtiene con la segunda estrategia, arrojando un tiempo de ciclo

de 3.76 segundos en diferentes corridas, por lo que son varias las combinaciones de tiempo y presión donde se reporta el mínimo valor en la medida de desempeño.

En este caso en particular, se contó con un punto muy competitivo desde el diseño experimental inicial y, sin embargo, la estrategia 1 no pudo llegar a soluciones dentro de ese vecindario. En contraste, la estrategia 2 llegó al mejor punto que había dado el diseño inicial y, en su ejecución generó varios puntos alrededor. En la figura 6 se puede observar gráficamente la diferencia de los resultados obtenidos con los diversos métodos y se aprecia cómo los puntos obtenidos por el método propuesto por Villarreal y Cabrera-Ríos se localizan en una región de mínimo tiempo de ciclo.

Se puede notar que el desempeño de la estrategia 2 tuvo el costo de hacer corridas adicionales, sin embargo, éstas se aprovecharon para establecer una zona atractiva de operación en el proceso simulado. La estrategia 2, como tal, no puede garantizar optimalidad global, lo cual quiere decir que tiene una naturaleza heurística. Por otro lado, la estrategia 1 que también es una heurística- presenta la ventaja de permitir una sola iteración, aunque el sacrificio es en términos de la calidad de la solución encontrada.




Fig. 6. Tiempo de ciclo vs. presión y temperatura, obtenidos al aplicar los diferentes métodos de optimización de simulaciones en estudio.

Tabla II. Resultados comparativos.

Tipo de metamodelo	Estrategia 1			Estrategia 2			
	RNA (6+3)	RNA (9)	Regresión cuadrática	Polinomio con el máximo grados de libertad			
Número de Simulaciones	9	9	9	15			
R <sup>2</sup> (último metamodelo)	76%	100%	78%	100%			
Temperatura (°C)	192.9	185	185	190.38	191.04	190.21	195
Presión (MPa)	500	281.9	500	296.36	362.02	341.35	255
Tiempo de Ciclo (segundos)	4.01	3.87	3.87	3.76	3.76	3.76	3.76

## CONCLUSIONES

En este trabajo se presentó la comparación de dos estrategias de optimización vía simulación a través de la utilización de metamodelos. La primera estrategia involucra una sola iteración y construye un metamodelo global, mientras que la estrategia 2 es iterativa y construye un metamodelo con alta fidelidad local. La comparación del desempeño de ambos métodos se realizó utilizando un caso de estudio de moldeo por inyección.

La estrategia 1 ha sido una práctica común en la literatura de optimización vía simulación, mientras que la estrategia 2 ha sido un desarrollo reciente. En este trabajo comparativo se empieza a vislumbrar que es posible encontrar mejores soluciones con un metamodelo construido iterativamente con un énfasis local. El punto importante es que tal estrategia no conlleve un número muy grande de simulaciones adicionales.

La introducción de un modelo que utiliza todos los grados de libertad disponibles es, de hecho, lo que hace posible el balance entre la calidad de solución y una convergencia en pocas corridas adicionales en la estrategia 2. Utilizar un metamodelo complicado desde un principio, sin embargo, es una práctica poco favorecida por la teoría estadística, lo que hace que estos resultados tengan una naturaleza contraintuitiva.

## REFERENCIAS

- Villarreal M.G. y M. Cabrera-Ríos. Un método adaptativo basado en metamodelos para optimización aplicada a la simulación. Memorias del IEEE 5° Congreso Internacional en Innovación y Desarrollo Tecnológico. (2007).
- Swisher J.R., P.D. Hyden, S.H. Jacobson y L.E. Schruben. A survey of simulation optimization techniques and procedures. Proceedings of the 1994 Winter Simulation Conference. pp. 119-128, (2000).
- April J., M. Better, F. Glover y J. Kelly. New Advances and applications for marrying Simulation and Optimization. Proceedings of the 2004 Winter Simulation Conference. (2004).
- Fu M.C. A tutorial review of techniques for Simulation Optimization. Proceedings of the 1994 Winter Simulation Conference. pp. 149-156, (1994).
- Andradóttir S. A review of Simulation Optimization techniques. Proceedings of the 1998 Winter Simulation Conference. pp. 151-158, (1998).
- Azadivar F. Simulation Optimization Methodologies. Proceedings of the 1999 Winter Simulation Conference. pp. 93-100, (1999).
- Fu M. C. Simulation Optimization. Proceedings of the 2001 Winter Simulation Conference. pp. 53-61, (2001).
- Ólafsson S. y J. Kim. Simulation Optimization. Proceedings of the 2002 Winter Simulation Conference. pp. 79-84, (2002).
- Fu M.C., F. Glover y J. April. Simulation Optimization: A review, new developments, and application. Proceedings of the 2005 Winter Simulation Conference. pp. 83-95, (2005).
- Barton R.R. Simulation Metamodels. Proceedings of the 1998 Winter Simulation Conference. pp. 167-174, (1998).
- April J., F. Glover, J.P. Kelly y M. Laguna. Practical introduction to Simulation Optimization. Proceedings of the 2003 Winter Simulation Conference. pp. 71-78, (2003).
- Buot G., F. Henríquez, F. Baesler y M. Ramírez. Optimización en simulación vía Inteligencia Artificial: Aplicación a un problema de manejo de material. Teoría Universidad de Bío-Bío. Vol. 10, pp. 25-32, (2001).
- Altıparmak F., B. Dengiz y A. Bulgak. Optimization of buffer sizes in assembly system using intelligent techniques. Proceedings of the 2002 Winter Simulation Conference. pp. 1157-1162, (2002).
- Martin J.D. y T.W. Simpson. Use of adaptive metamodeling for design optimization. 9th AIAA/ISSMO Symposium on Multidisciplinary Analysis and Optimization. pp. 1-9, (2002).
- Cheng R.C.H. y C.S.M. Currie. Optimization by Simulation Metamodeling Methods. Proceedings of the 2004 Winter Simulation Conference. pp. 485-490, (2004).
- Moniaci W., E. Pasero y P. Carmellino. Application of neural networks in production system

- simulation. Proceedings of the International Conference on Systems, Man and Cybernetics. Vol.1, pp. 827-831, (2005).
17. Cabrera-Ríos M., C.A. Mount-Campbell y S.A. Irani. An Approach to the Design of a Manufacturing Cell under Economic Considerations. International Journal of Production Economics. Vol.78, No.3, pp. 223-237, (2002).
18. Cabrera-Ríos M., J.M. Castro y C.A. Mount-Campbell. Multiple Quality Criteria Optimization in InMold Coating (IMC) With A Data Envelopment Analysis Approach. Journal of Polymer Engineering. Vol.22, No.5, pp. 305-340, (2002).
19. Cabrera-Ríos M., K.S. Zuyev, X. Chen, J.M. Castro y E.J. Straus. Optimizing Injection Gate Location and Cycle Time for the In-Mold Coating (IMC) Process. Polymer Composites. Vol.23, No. 5, pp. 723-738, (2002).
20. Castro C.E., M. Cabrera-Ríos, B. Lilly y J.M. Castro. Simultaneous Optimization of Mold Design and Processing Conditions in Injection Molding. Journal of Polymer Engineering. Vol.25, No.6, pp. 459-486, (2005).
21. Castro C.E., M. Cabrera-Ríos, B. Lilly y J.M. Castro. Optimization and Analysis of Variability in Injection Molding. Aceptado para su publicación en Journal of Polymer Engineering and Science. (2006).
22. Castro J.M., M. Cabrera-Ríos y C.A. Mount-Campbell. Modelling and Simulation in Re-active Polymer Processing. Modelling and Simulation in Materials Science and Engineering. Vol.12, pp. S121-S149, (2004).
23. Salazar M.A., M. Cabrera-Ríos. Pronóstico de demandas por medio de redes neuronales artificiales. Ingenierías. Vol. 10, No. 35, pp. 6-12, (2007).

#### AGRADECIMIENTOS

Los autores agradecen las becas del CONACYT y de la AMC otorgadas a las estudiantes involucradas en este trabajo, así como al apoyo de la FIME, la UANL y el Tecnológico de los Mochis.

