

Optimización Multiobjetivo de la Estructura de una Silla utilizando un Híbrido de Redes Neuronales Artificiales y NSGA-II

A. Alvarado-Iniesta, DJ Valles-Rosales, A Del Valle, JL García-Alcaraz, ND Pérez-González

¹Departamento de Ingeniería Industrial y Manufactura, Universidad Autónoma de Ciudad Juárez.

²Department of Industrial Engineering, New Mexico State University

Resumen

Se presenta un híbrido de redes neuronales artificiales y NSGA-II para la optimización multiobjetivo del diseño de una silla estándar con respecto a medidas estructurales. Los objetivos a optimizarse son la deformación y peso de la silla. Se realizan simulaciones por computadoras para obtener ambas respuesta de interés. Las variables de diseño se establecen en base a optimización de dimensiones. Redes neuronales artificiales son empleadas para mapear la relación entre las variables de diseño y los variables de salida. Después, NSGA-II es usado para encontrar el conjunto de soluciones óptimas de Pareto. Los resultados muestran que la metodología empleada brinda al diseñador versatilidad y robustez de escoger diferentes escenarios de acuerdo con las necesidades actuales de diseño en términos de estructura de la silla.

Palabras Claves: Redes Neuronales Artificiales, Optimización Multiobjetivo, NSGA-II, Optimización Estructural.

Introducción

La optimización estructural se define como hacer un ensamble de materiales destinados a sostener cargas de “la mejor” manera (Christensen & Klarbring 2009). Mejor podría referirse a que la estructura sea lo más ligera posible, es decir, minimizar su peso, o hacer la estructura tan firme como sea posible. Por lo tanto, un conjunto de medidas sobre el rendimiento estructural podría estar integrado por: el peso, la rigidez, la carga crítica, el estrés, el desplazamiento y la geometría. Por lo tanto, un problema de optimización estructural

podría ser formulado por la elección de una de ellas como una función objetivo que debe ser maximizada o minimizada (Christensen & Klarbring 2009). En la mayoría de los problemas de optimización del mundo real, varios objetivos deben ser optimizados simultáneamente con el fin de obtener una solución satisfactoria (peso, rigidez, etc.) (Stadler 1986). Estos objetivos suelen estar en conflicto y son no conmensurables (Coello & Christiansen 2000). A diferencia de los problemas con un solo objetivo, los problemas multi-objetivo normalmente tiene no sólo una, sino un

conjunto de soluciones, que son igualmente satisfactorias. Esto lleva a la búsqueda de un conjunto de soluciones que conforman el conjunto óptimo de Pareto, cuyos elementos correspondientes son llamados no dominados o no inferiores.

En general, los problemas de optimización estructural podrían dividirse en tres clases: optimización de tamaño, forma, y topología (Christensen y Klarbring 2009). Varios trabajos han sido publicados sobre este tema. Por ejemplo, Narayanan y Azarm (1999) presentaron una mejora mediante el uso de un algoritmo genético multiobjetivo para la optimización del diseño de estructuras y vigas. En 2000, Coello y Christiansen propusieron un algoritmo genético multiobjetivo para la optimización del diseño de estructuras. Abe et al. (2004) presentaron un estudio para la determinación de la construcción de un neumático óptimo basado en el análisis de elemento finito (FEA) y el algoritmo genético (GA). Del mismo modo, Rodríguez et al. (2005) trabajaron en la optimización multiobjetivo del bastidor de una motocicleta chopper basados en GA y FEA. En 2007, Weigang y Weiji trabajaron en la optimización del diseño de una estructura pilón de un avión usando un algoritmo interactivo multiobjetivo por enjambre de partículas. Lee et al. (2012) presentaron un algoritmo evolutivo multiobjetivo paralelo para la optimización del diseño de placas compuestas multicapa. Recientemente, Quaglia et al. (2014) presentaron un enfoque de optimización multiobjetivo para equilibrar la eficiencia energética y el rendimiento estructural en casas de campaña desplegadas.

Las medidas de desempeño estructural son puramente mecánicas; por ejemplo, no se consideran aspectos funcionales, económicos, estéticos, o ergonómicos. Para estructuras mecánicas, la optimización se realiza comúnmente por medio de métodos con base en simulaciones computacionales, como el análisis del elemento finito (FEA). Los modelos FEA requieren mucho esfuerzo, y no son adecuados para grandes análisis repetitivos que con frecuencia son necesarias en un algoritmo de optimización. Por lo tanto, se emplean modelos de sustitución basados en diversas metodologías (modelos de kriging, superficie de respuesta, redes neuronales artificiales) por su capacidad para aprender y de mapear la compleja relación no lineal entre las variables de diseño y las respuestas de interés. Recientemente, varios investigadores han combinado FEA, modelos de sustitución y algoritmos evolutivos para obtener buenas soluciones en diferentes problemas de optimización en ingeniería. Por ejemplo, Rodríguez et al. (2005), combinaron FEA y algoritmos evolutivos para la optimización del diseño de un bastidor de motocicleta. Magnier y Haghghat (2010) presentaron un artículo sobre la optimización del diseño de edificios mediante el uso de GA y redes neuronales artificiales (ANN) como modelo de sustitución. En el 2013, Serafinska et al. trabajaron en la optimización del diseño estructural de neumáticos mediante FEA y ANN. Bahraminasab et al. (2014) propusieron la optimización del diseño de un implante de rodilla usando la metodología de superficie de respuesta (RSM) y FEA. En el mismo año, Asadi et al. (2014) presentaron un artículo de la

optimización multiobjetivo de la retroadaptación de edificios con GA y ANN. Cazacu y Grama (2014) presentaron un trabajo en el que optimizan la topología, el tamaño y la forma de estructuras planas utilizando GA y FEA. Del mismo modo, estas metodologías se han aplicado en procesos de manufactura, como el moldeo por inyección de plástico (Chen et al 2010;. Cheng et al 2013;. Kitayama y Natsume 2014).

En este artículo, simulaciones computacionales (FEA), ANN y algoritmos genéticos multiobjetivo se aplican para la optimización estructural de una silla

convencional. Las variables de diseño consideradas se refieren a las dimensiones de la silla (optimización de dimensiones). Non-Dominated Sorting Genetic Algorithm (NSGA-II), propuesto por Deb et al. (2002) se utiliza para encontrar el conjunto de soluciones óptimas de Pareto. Las medidas de rendimiento son el peso y el desplazamiento de la silla. Por lo tanto, sólo los aspectos mecánicos se consideran en el problema de optimización. La siguiente sección explica la metodología seguida y los resultados obtenidos y las conclusiones se presentan en la última sección del documento.

Metodología

La metodología utilizada se divide en 3 etapas. La etapa 1 se centra en la recolección de datos a través de simulaciones computacionales. La etapa 2, es el híbrido de Redes Neuronales Artificiales (ANN) y la implementación de Non-Dominated Sorting Genetic Algorithm (NSGA-II). La última etapa es la validación de los resultados.

Fase 1: Recolección de datos

La Figura 1 muestra la silla para optimizar en función del diseño del marco.

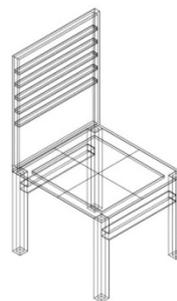


Figura 1. Estructura de la Silla

Las variables de diseño consideradas y sus rangos de diseño se muestran en la Tabla 1.

Así mismo, la Figura 2 muestra una representación de cada variable en el diseño de la silla.

Variable	min	max	
Ancho del asiento x_1	1	10	mm
Ancho del soporte del asiento x_2	0	10	mm
Dimensión de la pata x_3	15	50	mm
Ancho de la pared de la pata x_4	10	100	%
Ancho del soporte de patas x_5	0	40	mm

Tabla 1. Variables de diseño

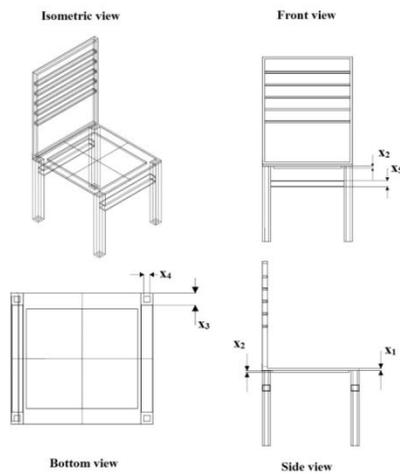


Figura 2. Variables de diseño

Un diseño factorial fraccionado se emplea para la recolección de datos; además, se añaden algunas corridas adicionales para el conjunto de datos basado en el enfoque de Morris y Mitchell (1995).

Por medio de simulaciones computacionales, la técnica del análisis del elemento finito (FEA) se utiliza para calcular la deformación (mm) en el asiento de la silla cuando se aplica una fuerza de 2000N en él, la Figura 3 muestra una representación. El peso (Kg) de la silla se da automáticamente por la simulación. El material seleccionado para toda la silla es Plástico ABS.

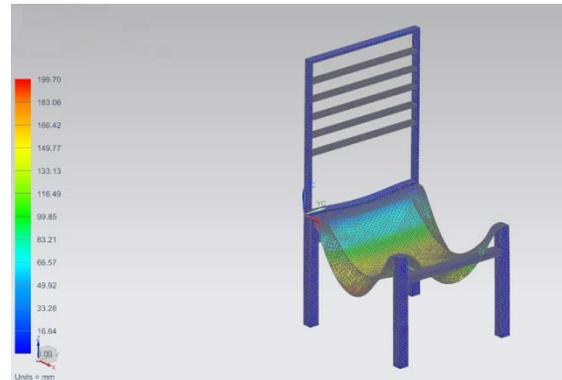


Figure 3. FEA de la silla

Un total de 48 pares de datos de entrada-salida se obtuvieron de las simulaciones. La

Figura 4 muestra una representación de los datos para las variables de salida.

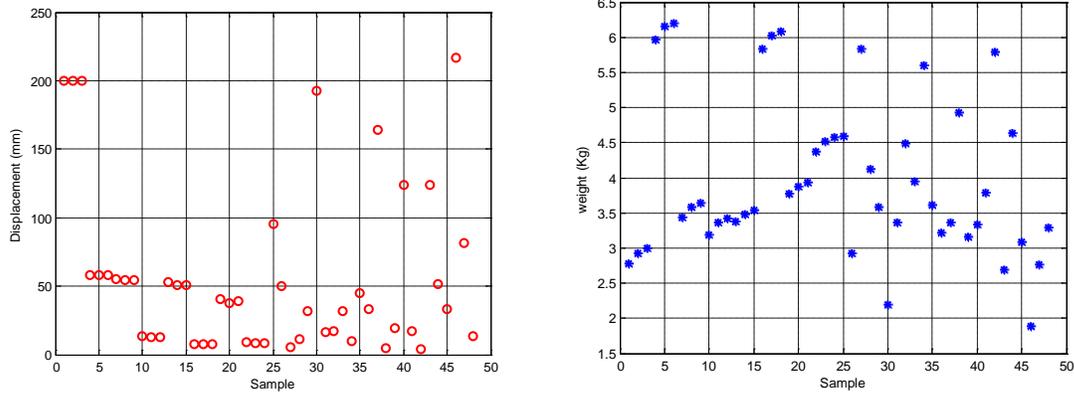


Figura 4. Datos de salida

Como se ve de la Figura 4, el rango de desplazamiento esta entre 0 y 220 mm aproximadamente, y el peso de la silla es de 1,5 a 6,5 kg.

Fase 2: Híbrido de redes neuronales artificiales y NSGA-II

El problema de optimización multiobjetivo se define como,

Encontrar X^*

$$= [Asiento(x_1^*), Soporte\ del\ Asiento(x_2^*), Pata(x_3^*), \% \ offset(x_4^*), Soporte\ de\ patas(x_5^*)]$$

$$Min f(X) = [f_1(X), f_2(X)]$$

s. a.

$$1 \leq x_1 \leq 10 \text{ milímetros}$$

$$0 \leq x_2 \leq 10 \text{ milímetros}$$

$$15 \leq x_3 \leq 50 \text{ milímetros}$$

$$10 \leq x_4 \leq 100 \quad \%$$

$$0 \leq x_5 \leq 40 \text{ milímetros}$$

(1)

Siendo $f_1(X)$ la función de costo que representa el valor de la deformación (mm), y $f_2(X)$ el peso de la silla (kg).

La Figura 5 muestra una representación gráfica del híbrido de ANN y NSGA-II.

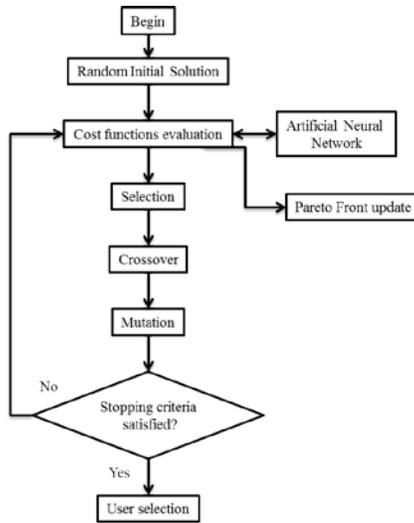


Figura 5. Híbrido ANN NSGA-II

Una red neuronal artificial con propagación hacia adelante con 5-20-1 y una 5-15-1 se desarrolla para hacer modelos aproximados entre las variables de diseño y la deformación y el peso de la silla, respectivamente. La Figura 6 muestra una representación del diseño de la NN. Los datos recolectados en la etapa 1 se utilizan para entrenar las redes mediante el uso del algoritmo de propagación hacia atrás (Backpropagation).

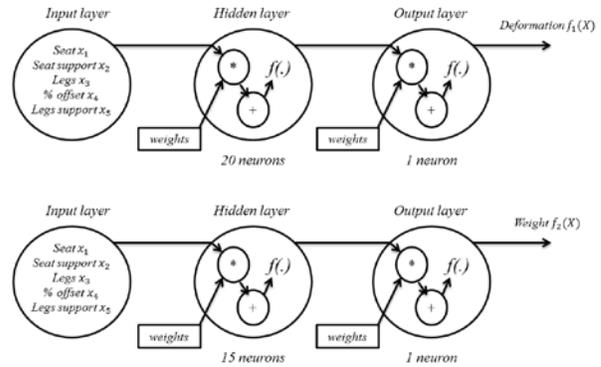


Figura 6. Redes neuronales artificiales

El procedimiento NSGA-II se muestra en la Figura 7. Los individuos se ordenan según la dominancia y crowding distance.

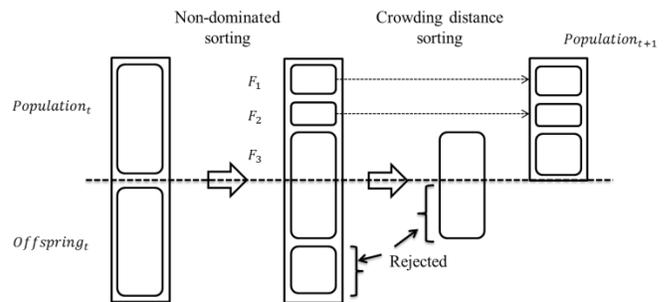


Figura 7. Procedimiento NSGA-II

Fase 3: Validación de los resultados

Una vez que se encuentra el conjunto de soluciones óptimas de Pareto, se llevan a cabo simulaciones por computadora para evaluar cada una de las soluciones obtenidas.

Resultados

Fase 2: Híbrido de redes neuronales artificiales y NSGA-II

Una vez que la red neuronal esta entrenada, es necesario que sea probada. Se emplean cinco muestras tomadas de las simulaciones para probar la capacidad de aproximación

de las redes. La Figura 8 muestra el valor de la simulación vs el valor de predicción dado por la red neuronal. El error de predicción es de alrededor de 5% en promedio; por lo tanto, la red neuronal diseñada es empleada como modelo de sustitución en la ecuación (1).

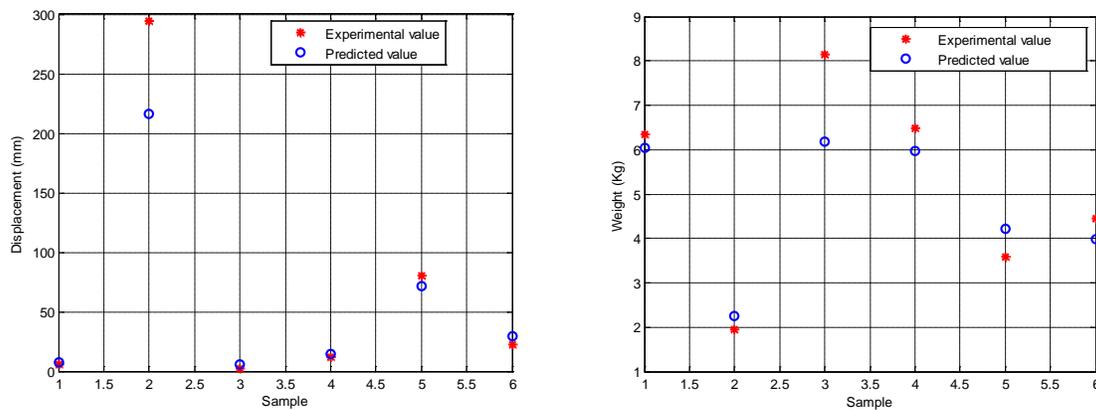


Figura 8. Muestras del ensayo

Un cruce binario simulado y una mutación polinómica se utilizan para el NSGA-II. La probabilidad de cruce es $p_c = 0,9$ y la probabilidad de mutación es $\eta_c = 0,1$. Los índices de distribución de los operadores de cruce y mutación son $\eta_c = 20$ y $\eta_p = 20$,

respectivamente. El tamaño de la población es de 40, y la generación máxima se establece en 400. La Figura 9 muestra el frente de Pareto encontrado por el problema descrito en la ecuación (1).

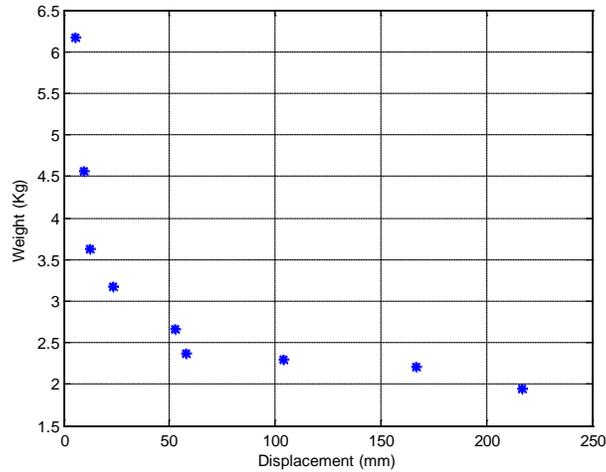


Figura 9. Frente de Pareto

Fase 3: Validación de la Solución

El valor óptimo para cada variable de diseño se muestra en la Tabla 2. Además, se muestra el valor de la función objetivo obtenido haciendo el FEA en la simulación computacional.

Tabla 2. Validación de la simulación por computadora

Solución	$f_1(X)$	$f_2(X)$	x_1	x_2	x_3	x_4	x_5
1	262.900	1.052	1.000	0.001	15.001	21.156	10.221
2	2.327	7.778	10.000	10.000	48.921	76.956	40.000
3	13.690	3.696	8.729	0.913	36.499	26.182	13.790
4	38.760	2.694	3.938	3.990	37.459	14.329	9.360
5	20.490	3.223	4.674	7.427	25.930	29.925	11.626
6	49.940	2.501	4.057	3.472	29.832	17.708	8.962
7	38.030	2.981	4.982	2.355	34.791	25.304	19.465
8	10.217	4.259	8.920	1.643	40.492	32.457	17.159
9	75.690	2.373	3.938	1.490	37.459	14.329	9.360

La Figura 10 muestra la solución 8 de la Tabla 2. Esta figura sólo muestra el desplazamiento que es igual a 10 mm.

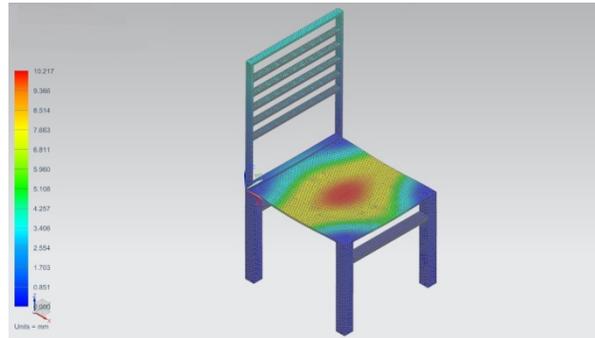


Figura 10. Solución 8

De los resultados, se observa la diferencia entre cada una de las soluciones en comparación con los dos objetivos a ser optimizados. Es decir, cualquiera de las soluciones puede ser elegida en función de la prioridad o las necesidades actuales de diseño. Si lo que se desea es un desplazamiento mínimo (calidad superior), se puede elegir la solución 2; sin embargo, el peso es el máximo dentro del conjunto de soluciones (el más caro). Por otro lado, si se

desea el peso mínimo (más barato), se puede seleccionar la solución al 1 pero siempre teniendo en cuenta que la solución tiene el desplazamiento máximo (de baja calidad). Por lo tanto, la metodología empleada da al diseñador la versatilidad y robustez de la elección de diferentes escenarios de acuerdo con las necesidades actuales de diseño con respecto a la estructura de una silla.

Conclusiones

Este estudio presenta un híbrido de ANN y NSGA-II para la optimización multiobjetivo en el diseño de una silla en términos de diseño estructural. Simulaciones por computadora se llevan a cabo para la recolección de datos con el fin de ajustarse a un modelo de sustitución basado en redes neuronales artificiales que sustituyen las simulaciones por computadora. Después, un algoritmo multiobjetivo se utiliza para encontrar el conjunto de soluciones óptimas de Pareto. Los resultados muestran que la metodología empleada tiene la flexibilidad y robustez de considerar diferentes casos de acuerdo con las preferencias de diseño. Trabajos futuros deben centrarse en la consideración de aspectos adicionales, tales como ergonómicos y funcionales.

Referencias

- Abe A, Kamegawa T, Nakajima Y (2004) Optimization of construction of tire reinforcement by genetic algorithm. *Optimization and Engineering* 5:77-92.
- Asadi E, Gameiro da Silva M, Henggeler-Antunes C, Dias L, Glicksman L (2014) Multi-objective optimization for building retrofit: A model using genetic algorithm and artificial neural network and an application. *Energy and Building* 81:444-456.
- Bahraminasab M, Sahari B, Edwards K, Farahmand F, Hong T, Arumugam M, Jahan A (2014) Multi-objective design optimization of functionally graded material for the femoral component of a total knee replacement. *Materials and Design* 53:159-173.
- Cazacu R, Grama L (2014) Steel truss optimization using genetic algorithms and FEA. *Procedia Technology* 12:339-346.
- Chen W, Zhou X, Wang H, Wang W (2010) Multi-objective optimal approach for injection molding based on surrogate model and particle swarm optimization algorithm. *Journal of Shanghai Jiaotong University* 15:88-93.
- Cheng J, Liu Z, Tan J (2013) Multiobjective optimization of injection molding parameters based on soft computing and variable complexity method. *International Journal of Advanced Manufacturing Technology* 66:907-916.
- Christensen P, Klarbring A (2009) *An introduction to Structural Optimization*. Springer, Canada.
- Coello C, Christiansen A (2000) Multiobjective optimization of trusses using genetic algorithms. *Computers and Structures* 75:647-660.
- Deb K, Pratap A, Agarwal S, Meyarivan T (2002) A fast and elitist multiobjective Genetic Algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation* 6(2):182-197.
- Kitayama S, Natsume S (2014) Multi-objective optimization of volume shrinkage and clamping force for plastic injection molding via sequential approximate optimization. *Simulation Modelling Practice and Theory* 48:35-44.
- Lee D, Morillo C, Bugeda G, Oller S, Onate E (2012) Multilayered composite structure design optimization using distributed/parallel multi-objective evolutionary algorithms. *Composite Structures* 94:1087-1096.
- Magnier L, Haghghat F (2010) Multiobjective optimization of building design using TRNSYS simulations, genetic algorithm, and artificial neural network. *Building and Environment* 45:739-746.
- Morris M, Mitchell T (1995) Exploratory designs for computational experiments. *Journal of Statistical Planning and Inference* 43:381-402.
- Narayanan S, Azarm S (1999) On improving multiobjective genetic algorithms for design optimization. *Structural Optimization* 18:146-155.
- Quaglia C, Yu N, Thrall A, Paolucci S (2014) Balancing energy efficiency and structural performance through multi-objective shape optimization: Case study of a rapidly deployable origami-inspired shelter. *Energy and Building* 82:733-745.
- Rodríguez J, Medaglia A, Casas J (2005) Approximation to the optimum design of a motorcycle frame using finite element analysis and evolutionary algorithms. In: Bass E (ed) *Proceedings of the 2005 Systems and Information Engineering Design Symposium*. IEEE, Virginia, pp. 277-285.
- Serafinska A, Kaliske M, Zopf C, Graf W (2013). A multi-objective optimization approach with consideration of fuzzy variables applied to structural tire design. *Computers and Structures* 116:7-19.
- Stadler W (1986) Multicriteria optimization in mechanics (a survey). *Applied Mechanics Reviews* 37(2):277-286.
- Weigang A, Weiji L (2007) Interactive multi-objective optimization design for the pylon structure of an airplane. *Chinese Journal of Aeronautics* 20:524-528.