

Comparación de heurísticas para la optimización multiobjetivo de procesos de fabricación mecánica

Heuristics comparison for multi-objective optimization of mechanical manufacturing processes

Teresa Pérez-Sosa¹, Michel Fernández-González², Ramón Quiza³

¹ Centro de Estudio de Fabricación Avanzada y Sostenible (CEFAS), Universidad de Matanzas, Cuba. Email: teresa.perez@umcc.cu

² Electromedicina, Matanzas, Cuba. Email: michelfernandez.mtz@infomed.sld.cu

³ Centro de Estudio de Fabricación Avanzada y Sostenible (CEFAS), Universidad de Matanzas, Cuba, Email: ramon.quiza@umcc.cu

RESUMEN

La optimización de los procesos mecánicos de fabricación es un aspecto clave en la industria moderna, el cual contribuye significativamente al logro de productos eficientes y competitivos. No obstante, la selección de un único objetivo de optimización no es factible en la mayoría de las aplicaciones prácticas. Por el contrario, la optimización multiobjetivo comúnmente ofrece una representación más verídica de las condiciones reales a nivel productivo. Adicionalmente, la compleja naturaleza física de los procesos de manufactura hace a que modelos involucrados sean altamente no lineales y ruidosos, dificultando el cumplimiento de las condiciones comúnmente requeridas por las técnicas de optimización analíticas y numéricas. Por consiguiente, las heurísticas inspiradas en procesos o sistemas naturales, se han convertido en una alternativa popular para solucionar problemas reales de optimización multiobjetivo. Este trabajo presenta la comparación de seis heurísticas de optimización ampliamente utilizadas: SMOCE, NSGA-III, MOEA/D, MOPSO, SPEA-II y PESA-II. Tres procesos de fabricación diferentes fueron utilizados como casos de estudio: a proceso de torneado multipasada, un proceso de soldadura con arco sumergido y un proceso de conformación en caliente. Los resultados obtenidos fueron comparados teniendo en cuenta no sólo su calidad sino también la eficiencia computacional del proceso de optimización.

Palabras clave: Optimización multiobjetivo; Heurísticas; Procesos de fabricación.

ABSTRACT

Optimization of mechanical manufacturing processes is a key issue in modern industry, which significantly contributes to obtain efficient and competitive products. Nevertheless, selecting a single optimization goal is not suitable in most of practical applications. Conversely, multi-objective optimization often offers a more realistic representation of actual workshop conditions. Moreover, the complex physical nature of manufacturing process makes the involved models highly nonlinear and noisy, hindering the fulfilling of requirements usually demanded by analytical or numerical optimization techniques. Consequently, heuristics inspired in natural processes or systems, have become a popular choice for solving real-world multi-objective optimization problems. This paper presents the comparison of six widely used multi-objective optimization heuristics: SMOCE, NSGA-III, MOEA/D, MOPSO, SPEA-II and PESA-II. Three different manufacturing processes were considered as study cases: a multi-passes turning process, a submerged arc welding process, and a hot forming process. Obtained outcomes were compared by considering not only the quality of the results but also the computational efficiency of the optimization process.

Keywords: Multi-objective optimization; Heuristics; Manufacturing processes.

1. INTRODUCCIÓN

La optimización de los procesos tecnológicos juega un papel fundamental en la manufactura moderna, al permitir obtener productos más competitivos, dentro de un mercado caracterizado por su exigencia y dinamismo (Quiza *et al.* 2014). No obstante, en la práctica industrial, deben optimizarse, simultáneamente, varios objetivos, que usualmente son conflictivos. El enfoque de optimización multiobjetivo, a posteriori, presenta la ventaja de no requerir ninguna información sobre preferencias o valoraciones relativas, con respecto a los diferentes objetivos, sino que éstos son optimizados, obteniendo el conjunto de soluciones no dominadas (o frontera de Pareto), que son óptimos en el sentido más amplio de que ninguna otra solución, en el espacio de búsqueda restringido considerado, es capaz de mejorar uno de los objetivos sin empeorar, a la vez, otro (Yang *et al.* 2014). Este enfoque ha mostrado ser especialmente conveniente en la optimización de procesos de manufactura (Quiza *et al.* 2006).

Para la obtención de la frontera de Pareto, las heurísticas inspiradas en procesos naturales han resultado ser mucho más efectivas que los métodos numéricos, ya que permiten llegar a la solución en una única ejecución y, además, no requieren cumplir con los requisitos de continuidad, suavidad y unimodalidad exigidos por los métodos iterativos (Coello *et al.*, 2007). Dentro de las heurísticas más utilizadas se destacan aquellas basadas en poblaciones, que contienen un conjunto de soluciones que va, en concordancia con determinadas reglas, cambiando con el tiempo hasta converger al frente de Pareto (Ishibuchi *et al.* 2008).

A pesar de sus ventajas, las heurísticas de optimización tienen el inconveniente de que ninguna de ellas puede reclamar el ser universalmente más eficiente que las otras, ya que la ventaja en determinado grupos de problema se ve siempre contrarrestada por pérdidas de eficiencia en la solución de otros grupos de problemas (Wolpert y Macready 1997), Esto hace que la única forma de evaluar la eficacia y la eficiencia de las heurísticas de optimización multiobjetivos, sea con respecto a determinados problemas específicos.

El presente trabajo propone la comparación de diversas heurísticas en la optimización multiobjetivo de tres procesos típicos de manufactura mecánica: maquinado, soldadura y conformado.

2. MATERIALES Y MÉTODOS

Descripción de los Casos de Estudio

El primer caso e estudio considerado es el torneado multipasada (Quiza *et al.* 2009). En dicho proceso se considera el cilindrado de un escalón de longitud, $L = 180$ mm, desde un diámetro inicial, $D_0 = 150$ mm, hasta un diámetro final, $D = 100$ mm.

Las variables de decisión del problema considerado son la cantidad de pasadas, N ; el avance, f , y la velocidad de corte, V . Cada una de ellas, está restringida por los intervalos admitidos por la herramienta utilizada. En el caso del problema considerado:

$$0,5 \text{ mm} \leq a \leq 6,0 \text{ mm} ; \quad (1a)$$

$$0,15 \text{ mm/rev} \leq f \leq 0,55 \text{ mm/rev} ; \quad (1b)$$

$$250 \text{ m/min} \leq V \leq 400 \text{ m/min} . \quad (1c)$$

En el caso de la profundidad de corte, como la variable de decisión es la cantidad de pasadas, se transforma la restricción, haciendo uso de la relación, $a = (D_0 - D)/(2N)$, de lo cual resulta que:

$$N = (D_0 - D)/(2a) ;$$

$$N_{\min} = \lceil (D_0 - D)/(2a_{\max}) \rceil = \lceil (150 - 100)/(2 \cdot 6,0) \rceil = 5 ;$$

$$N_{\max} = \lfloor (D_0 - D)/(2a_{\min}) \rfloor = \lfloor (150 - 100)/(2 \cdot 0,5) \rfloor = 50 ;$$

quedando, entonces, el dominio de la cantidad de pasada como:

$$5 \leq N \leq 50 . \quad (1d)$$

Las funciones objetivos consideradas fueron el tiempo de corte, τ , y el gasto herramental, ξ . El primero de ellos está dado por la expresión:

$$\tau = W/M ; \quad (2)$$

donde $M = 1000afV$, es la velocidad de remoción de material y $W = \pi(D^2 - d^2)L$, es el volumen de material removido. Por su parte, el consumo herramental viene dado por:

$$\xi = \tau / T ; \quad (3)$$

donde $T = 5,48 \cdot 10^9 / (a^{0,460} f^{0,969} V^{3,46})$ es la vida útil de la herramienta, que depende de los parámetros de corte según la conocida Ley de Taylor.

Como restricciones adicionales, se consideraron la fuerza de corte:

$$F = 6560a^{1,10} f^{0,917} V^{-0,286} \leq 5000 \text{ N} ; \quad (4)$$

y la potencia de corte:

$$P = FV / (6 \cdot 10^4) \leq 7,5 \text{ kW} . \quad (5)$$

El segundo caso de estudio se enfoca a la optimización de un proceso de forjado en caliente de una pieza a partir de un disco (Quiza *et al.* 2014). Se consideraron dos variables de decisión: la temperatura de la pieza forjada, T , y la velocidad de forjado, V , las cuales de considerarán en los rangos:

$$900 \text{ }^\circ\text{C} \leq T \leq 1200 \text{ }^\circ\text{C} ; \quad (6a)$$

$$10 \text{ mm/s} \leq V \leq 50 \text{ mm/s} . \quad (6b)$$

Los objetivos de optimización seleccionados son el tiempo de forjado, t , que describe la productividad, y la energía total consumida, E . El primero viene dado por:

$$t = S/V . \quad (7)$$

donde S es el recorrido de la estampa móvil. La energía, por su parte, se calcula sumando la energía térmica y la mecánica:

$$E = F_{\max} S + cm(T - T_0) ; \quad (8)$$

donde F_{\max} es la fuerza máxima de forjado; $c = 486 \text{ J/(m}\cdot\text{K)}$ es el calor específico del metal; $m = 5,81 \text{ kg}$ es la masa de la pieza forjada; y $T_0 = 25 \text{ }^\circ\text{C}$ es la temperatura ambiente. La fuerza máxima se determinó a partir de simulaciones realizadas por el método de elementos finitos, obteniendo la expresión:

$$F_{\max} = 151,7 - 0,1123T + 0,2775V . \quad (9)$$

Adicionalmente, se considerará como restricción que esta fuerza máxima no supere lo admitido por el mecanismo de la prensa:

$$F_{\max} \leq F_{\text{adm}} = 54 \text{ MN} . \quad (10)$$

El tercer caso de estudio, se refiere a la optimización de un proceso de soldadura bajo fundente (La Fé et al. 2017). Se consideran como variables de decisión los parámetros del proceso de soldadura: la corriente, I ; el voltaje, U ; y la velocidad de avance de la soldadura, S , las cuales se definen en los intervalos:

$$200 \text{ A} \leq I \leq 300 \text{ A} ; \quad (11a)$$

$$20 \text{ V} \leq U \leq 30 \text{ V} ; \quad (11b)$$

$$41 \text{ m/h} \leq S \leq 85 \text{ m/h} . \quad (11c)$$

Como objetivos se consideran la velocidad de deposición, D , a maximizar, y la razón de dilución, L , a ser minimizada. La primera se calcula, como:

$$D = \rho S A_D ; \quad (12)$$

donde $\rho = 7850 \text{ kg/m}^3$, y A_D es el área de la costura del metal depositado, que se calcula por la expresión empírica:

$$A_D = -0,1627 + 0,0314I + 0,1675U - 0,0693S ; \quad (13)$$

Por su parte, la dilución se determina como:

$$L = 100\% \cdot A_B / (A_B + A_D) ; \quad (14)$$

donde A_B es el área de la costura del metal base, que se determina por la expresión empírica:

$$A_B = -8,9073 + 0,0501I + 0,3308U - 0,0906S . \quad (15)$$

Adicionalmente, se consideran dos restricciones, que involucran las dimensiones de la costura. En primer lugar, se requiere que el ancho del cordón, B :

$$B = 3,5046 + 0,0180I + 0,1780U - 0,0693S ; \quad (16)$$

esté dentro del intervalo establecido por las normas técnicas de fabricación:

$$6,6 \text{ mm} \leq B \leq 9,0 \text{ mm} . \quad (17)$$

También se requiere que la penetración, P :

$$P = -1,7003 + 0,0120I + 0,0543U - 0,0070S ; \quad (18)$$

sea superior al espesor de la plancha:

$$P \geq 2,2 \text{ mm} . \quad (19)$$

Heurística Empleadas

Para la optimización se emplearon seis heurísticas de las más reportadas en la literatura especializada:

- MOEA/D: Multiobjective Evolutionary Algorithm Based on Decomposition (Zhang y Li 2007).
- MOPSO: Multi-Objective Particle Swarm Optimization (Coello et al. 2004).
- NSGA3: Nondominated Sorting Genetic Algorithm (Deb y Jain 2014).
- PESA2: Pareto Archived Evolutionary Algorithm (Corne et al. 2002).
- SMOCE: Simple Multi-Objective Cross-Entropy (Haber et al. 2017).
- SPEA2: *Strength Pareto Evolutionary Algorithm* (Zitzler et al. 2001).

En la Tabla 1, se muestran los parámetros utilizados, por dichos algoritmos, para cada uno de los casos de estudio considerados. Dichos parámetros fueron seleccionados para garantizar de que las medias de los tiempos de ejecución, con las diferentes heurísticas, no se diferenciaron más de un 10%. Se realizaron 25 réplicas de cada proceso de optimización.

Tabla 1. Parámetros utilizados por cada heurística

Heurística	Parámetro	Caso de estudio		
		1	2	3
MOEA/D	Tamaño de población	95	20	56
	Generaciones	190	40	112
	Tamaño de archivo		10	
	Gamma		0,5	
MOPSO	Tamaño de población	300	20	55
	Generaciones	600	40	110
	Tamaño del repositorio		100	
	Pesos de inercia		0,5	
	Razón de amortiguamiento de los pesos de inercia		0,99	
	Coefficiente de aprendizaje personal		1	
	Coefficiente de aprendizaje global		2	
	Razón de inflación		0,1	
Razón de mutación		0,1		
NSGA3	Tamaño de población	70	17	40
	Generaciones	140	34	80
	Número de divisiones		10	
	Porcentaje de cruzamiento		0,5	
	Porcentaje de mutación		0,5	
	Razón de mutación		0,02	
PESA2	Tamaño de población	150	12	42
	Generaciones	300	24	84
	Tamaño de archivo		20	
	Factor de inflación		0,1	
	Beta de deselección		1	
	Beta de selección		2	
	Porcentaje de cruzamiento		0,5	
Gamma		0,15		
SMOCE	Tamaño de población	1000	100	500
	Generaciones	2000	200	1000
	Razón de élite		0,5	
	Intervalos de histograma		10	
SPEA2	Tamaño de población	90	8	37
	Generaciones	180	16	74
	Tamaño de archivo		50	
	Porcentaje de cruzamiento		0,7	
	Gamma		0,1	

3. ANÁLISIS DE LOS RESULTADOS

Caso de estudio 1: Torneo multipasada

Como resultado de aplicar las diferentes heurísticas de optimización al problema de torneado multipasada, se obtienen los correspondientes frentes de Pareto. Como se puede observar en ellos (Fig. 1), hay una buena coincidencia entre los diversos frentes. Dentro de ellos, los puntos situados en el extremo izquierdo de la curva, corresponden a soluciones donde se prioriza el ahorro herramental por encima de la productividad, mientras que, en los puntos de la derecha, la relación entre los objetivos es justamente la contraria.

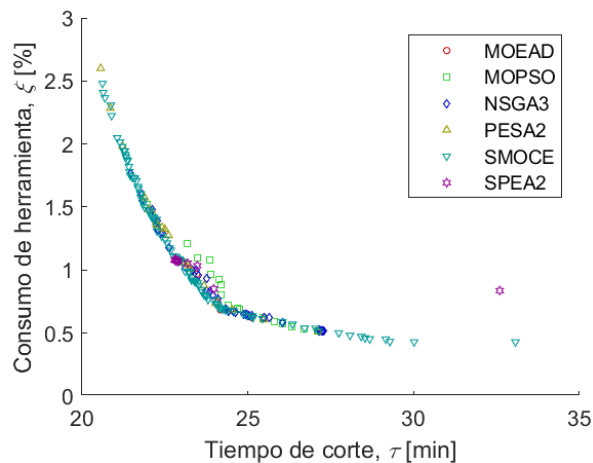


Figura 1. Frontera de Pareto para el caso de estudio de torneado multipasada




Figura 2. Comparación de la calidad de los resultados de la optimización del caso de estudio de torneado multipasada

Para una comparación más estricta de los resultados obtenidos, para cada una de las heurísticas, se calculó el hiperárea de cada uno de los frentes de Pareto, obtenidos en cada una de las réplicas del proceso de optimización. Se seleccionó esta métrica de calidad porque refleja tanto la convergencia como la diversidad del frente de Pareto (Jiang *et al.* 2014). Se determinó, posteriormente, el valor medio de dichas hiperáreas y su intervalo de confianza para un 95% de confiabilidad (Fig. 2).

Como se puede observar, MOPSO y SMOCE tienen un comportamiento marcadamente superior al resto de las heurísticas, no sólo por los valores medios sino también por la menor dispersión de los resultados obtenidos.

Caso de estudio 2: Forjado en caliente

Los resultados de la optimización del caso de estudio de forjado en caliente, muestran una elevada coincidencia en los frentes de Pareto obtenidos por las diversas heurísticas (Fig. 3). Las soluciones situadas en la zona derecha de la curva, corresponden a los regímenes menos consumidores de energía, pero menos productivos. Los situados en la zona izquierda, por el contrario, corresponden a los regímenes de forjado más productivos, pero también más consumidores de energía.

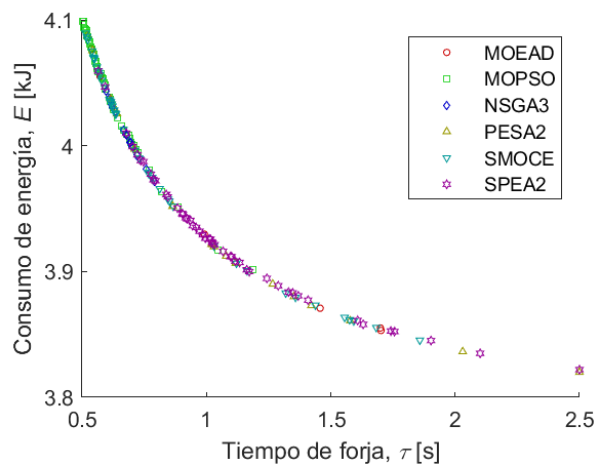


Figura 3. Frontera de Pareto para el caso de estudio de forjado en caliente

En la comparación de la calidad de los frentes de Pareto obtenidos (Fig. 4), se observa que un mayor número de heurísticas (MOPSO, PESA2, SMOCE y SPEA2) ofrecen resultados satisfactorios, con baja dispersión en sus resultados.




Figura 4. Comparación de la calidad de los resultados de la optimización del caso de estudio de forjado en caliente

Caso de estudio 3: Soldadura bajo fundente

Los resultados de la optimización de la soldadura bajo fundente, muestran una mayor dispersión en los frentes de Pareto obtenidos (Fig. 5). Las soluciones situadas en la derecha de la curva son la más productivas, pero que requieren mayor consumo energético, mientras que las situadas en la izquierda, son menos productivas pero menos demandantes desde el punto de vista energético.

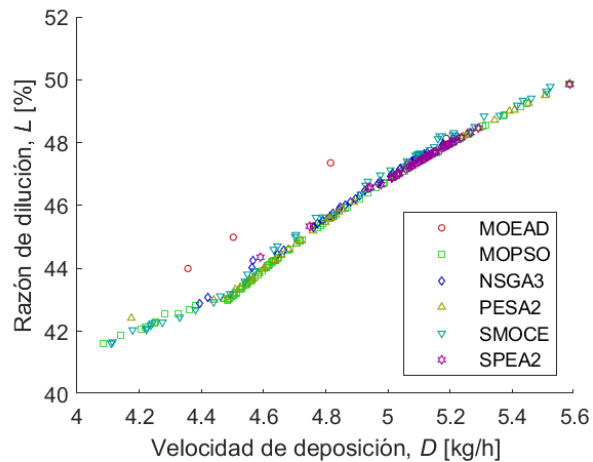


Figura 5. Frontera de Pareto para el caso de estudio de soldadura bajo fundente

Con respecto a la calidad de los frentes de Pareto obtenidos (Fig. 6), se nota una diferencia entre MOPSO, PESA2 y SMOCE y el resto de las heurísticas, al mostrar, aquellas, resultados con mayores hiperáreas y menores dispersiones.




Figura 6. Comparación de la calidad de los resultados de la optimización del caso de estudio de soldadura bajo fundente

4. CONCLUSIONES

Como conclusiones del trabajo, se ha arribado a los siguiente:

1. Las seis heurísticas utilizadas han mostrado ser capaces de solucionar los tres problemas de optimización multiobjetivo de procesos de manufactura mecánica, considerados como casos de estudio.

2. El rendimiento de las heurísticas depende de la complejidad de los problemas analizados. Así, en el caso de estudio 2, computacionalmente menos complejos de los otros, se pudo observar menos diferencia entre el rendimiento de las heurísticas. Por el contrario, en los otros dos casos de estudio, dos o tres heurísticas muestran un rendimiento muy superior al resto.
3. Las heurísticas MOPSO y SMOCE han mostrado ser capaces de resolver, satisfactoriamente, los tres casos de estudio considerados.

5. CONFLICTO DE INTERESES

El presente trabajo ha sido llevado a cabo gracias al financiamiento del proyecto “Heurísticas inteligentes para optimización multiobjetivo con aplicación a los procesos industriales”, asociado al Programa de Ciencias Básicas. Los autores declaran no tener constancia de ningún conflicto de intereses relacionado con el trabajo.

6. REFERENCIAS

- Coello, C. A., Lamont, G. B. y Veldhuizen, D. A. (2007). *Evolutionary algorithms for solving multi-objective problems* (2nd ed.). New York (UK): Springer, ISBN: 978-0-387-33254-3.
- Coello, C. A., Toscano, G. y Salazar, M. (2004). Handling multiple objectives with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, 8 (3), 256-279, doi: 10.1109/TEVC.2004.826067.
- Corne, D. W., Jerram, N. R., Knowles, J. D. y Oates, M. J. (2002). ‘PESA-II: Region-based selection in evolutionary multiobjective optimization,’ En memorias del *3rd Annual Conference on Genetic and Evolutionary Computation*.
- Deb, K. y Jain, H. (2014). An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach. Part I: Solving problems with box constraints”, *IEEE Transactions on Evolutionary Computation* 18(4), 577-601, doi: 10.1109/TEVC.2013.2281535
- Haber, R. E., Beruvides, G., Quiza, R., & Hernández, A. (2017). A simple multi-objective optimization based on the cross-entropy method. *IEEE Access*, 5(1), 22272-22281. doi: 10.1109/ACCESS.2017.2764047.
- Ishibuchi, H., Tsukamoto, N. y Nojima, Y. (2008). Evolutionary many-objective optimization: A short review. En memorias del *IEEE Congress on Evolutionary Computation*.
- Jiang, S., Ong, Y. S., Zhang, J. y Feng, L. (2014). Consistencies and contradictions of performance metrics in multiobjective optimization. *IEEE Transactions on Cybernetics*, 44(12), 2391 - 2404. doi: 10.1109/TCYB.2014.2307319
- La Fé, I., Rivas, M., Quiza, R., y Zambrano-Robledo, P. (2017). Optimización multiobjetivo de la soldadura automática bajo fundente del acero JIS 3116. *Ingeniería Mecánica*, 20(2), 77-82.
- Quiza, R., Beruvides, G. y Davim, J. P. (2014). Modeling and optimization of mechanical systems and processes. In J. P. Davim (Ed.), *Modern mechanical engineering* (pp. 169-198): Berlín (Alemania): Springer, ISBN: 978-3-642-45175-1.
- Quiza, R., Albelo, J. E. y Davim, J. P. (2009). Multi-objective optimisation of multipass turning by using a genetic algorithm. *International Journal of Materials and Product Technology*, 35(1-2), 134-144. doi: 10.1504/ijmpt.2009.025223

- Quiza, R., Rivas, M. y Alfonso, E. (2006). Genetic algorithm-based multi-objective optimization of cutting parameters in turning processes. *Engineering Applications of Artificial Intelligence*, 19 (2), 127-133. DOI: 10.1016/J.Engappai.2005.06.007.
- Yang, X. S., Koziel, S. y Leifsson, L. (2014). Computational optimization, modelling and simulation: Past, present and future. *Procedia Computer Science*, 29, 754-758. doi: 10.1016/j.procs.2014.05.067
- Wolpert, D. H. y Macready, W. G. (1997). No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1), 67-82.
- Zhang, Q. y Li, H. (2007). MOEA/D: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, 11 (6), 712-731, doi: 10.1109/TEVC.2007.892759.
- Zitzler, E., Laumanns, M. y Thiele, L. (2001). *SPEA2: Improving the strength Pareto evolutionary algorithm*, Swiss Federal Inst. Technol., Zürich, Switzerland, Tech. Rep. TIK-103.

SOBRE LOS AUTORES

Teresa Pérez Sosa, Investigadora del Centro de Estudio de Fabricación Avanzada y Sostenible (CEFAS), de la Universidad de Matanzas. Ingeniera Informática, Profesora Auxiliar y Máster en Matemática Educativa. Miembro de la Sociedad Cubana de Matemática y Computación.

Ramón Quiza, Director del Centro de Estudio de Fabricación Avanzada y Sostenible (CEFAS), de la Universidad de Matanzas. Doctor en Ciencias Técnicas y Profesor Titular. Miembro Titular de la Academia de Ciencias de Cuba, miembro de la Sociedad Cubana de Matemática y Computación, de la Unión de Informáticos de Cuba y del Capítulo Matancero de la Sociedad Económica de Amigos del País.

Michel Fernández González: Ingeniero Biomédico. Especialista del Centro Provincial de Electromedicina de Matanzas. Trabaja los temas de inteligencia artificial aplicada.