

Conformación del algoritmo CMA-es para la estimación de parámetros del motor de inducción asíncrono trifásico

Lara-Ordaz H., Hernández-Romero N., Seck Touh-Mora J.C. y Medina-Marín J.
herbertlara@hotmail.com, nor.her.00@gmail.com, jseck@uaeh.edu.mx, jmedina@uaeh.edu.mx
Área Académica de Ingeniería del Instituto de Ciencias Básicas e Ingeniería de la
Universidad Autónoma del Estado de Hidalgo

Resumen—El CMA-es (Covariance Matrix Adaptation evolution strategy) es un método de optimización relativamente nuevo y hasta el momento de elaborar este trabajo no existe literatura que reporte el uso de esta técnica para la obtención de parámetros del motor de inducción. Los resultados de este método son comparados con los obtenidos por otras técnicas evolutivas como los Algoritmos Genéticos (AGs) y los Cúmulos de Partículas (PSO Particle Swarm Optimization) para presentar las ventajas del CMA-es.

Índice de Términos— Estimación de parámetros, motor de inducción, algoritmos genéticos, optimización por cúmulo de partículas, estrategia evolutiva de adaptación de la matriz de covarianza.

I. INTRODUCCIÓN

El uso del motor de inducción asíncrono se ha incrementado debido a sus características de robustez, confiabilidad, mínimo mantenimiento y operación estable en ambientes extremos y peligrosos.

Los parámetros del motor de inducción son necesarios para observar y predecir su comportamiento a través de modelos matemáticos pero la información proporcionada por el fabricante no incluye estos datos.

Una forma de obtener estos valores es mediante pruebas de laboratorio, realizando mediciones de resistencia y reactancia de estator, prueba de vacío y prueba de rotor bloqueado [2]; pero éstas pruebas no son sencillas de efectuar y en muchos casos los resultados obtenidos no son lo suficientemente precisos.

II. ALGORITMOS EVOLUTIVOS.

A. Algoritmos Genéticos

Los AGs son técnicas evolutivas para la optimización de problemas a través de una búsqueda guiada por los mecanismos de la genética molecular. Los AGs permiten que una población evolucione; cada uno de los individuos contribuye con su material genético para la generación de los nuevos individuos. Con esto se trata de alcanzar un estado de máximo fitness (aptitud) [3].

B. Optimización por cúmulo de partículas (PSO).

Es una técnica estocástica inspirada en la inteligencia colectiva observada en la cooperación de un grupo de individuos homogéneos.

Los bancos de peces o rebaños de animales representan ejemplos de sistemas naturales con un comportamiento impresionante, libre de colisiones y movimientos sincronizados; es por ello que se puede deducir que la naturaleza resuelve problemas de optimización como la obtención de alimentos, para que un grupo de animales evite a un depredador o para cambiar de lugar a una colonia [1][7].

Estrategia Evolutiva de Adaptación de la Matriz de Covarianza (CMA-es).

En el algoritmo de adaptación de la matriz de covarianza, la población es generada mediante una distribución normal multi-variable Ec. (1)

$$x \sim N_k(\mathbf{m}, \mathbf{C}) \quad (1)$$

Esto es si N_k es un vector k-dimensional con una distribución normal y x si tiene una distribución N_k , entonces existe el vector de medias \mathbf{m} y la matriz de covarianza \mathbf{C} cuya interpretación geométrica se identifica por su única (hiper-) elipse cuyos ejes principales corresponden a los eigenvalores de la matriz \mathbf{C} .

Por ésta razón es posible realizar lo que se denomina una eigen-descomposición de la matriz de covarianza.

$$\mathbf{C} = B(D^2)B^T \quad (2)$$

Donde B y D son matrices.

En la Ec. (3) se muestra la obtención de la nueva población.

$$x_k^{(g+1)} \sim \mathbf{m}^{(g)} + \sigma^{(g)} N_k(\mathbf{0}, \mathbf{C}^{(g)}) \quad (3)$$

Donde σ es tamaño del paso y $N_k(\mathbf{0}, \mathbf{C}^{(g)})$ es una distribución normal multivariable con media cero y matriz de covarianza \mathbf{C} simétrica y positiva.

De acuerdo con el tipo de problema, el algoritmo comienza con la iniciación de la dimensión N_{dim} del problema y a partir de ahí se determina el tamaño de la población λ y el número de padres μ . El tamaño del paso σ inicial es de 0.5 que es propuesto por el autor del método; a continuación se requiere generar un vector aleatorio de medias \mathbf{m} y las matrices $B = I, D = I, \mathbf{C} = BD^2B^T$. Otros parámetros que se calculan antes de iniciar las iteraciones son el vector de ponderaciones ω_i , varianza efectiva μ_{ef} , deslizamiento d_σ para la actualización de σ y factores de aprendizajes para la matriz de covarianza c_c, c_1, c_μ y para el control del tamaño c_σ .

Para el ciclo de iteraciones, el autor propone los criterios de finalización: número máximo de evoluciones $St_{Ev} = 1000(N_{dim})^3$ y valor mínimo de error $St_{fit} = 1 \times 10^{-10}$. Dentro del ciclo, a continuación se determina la nueva población. Aplicando la (2) en (3) se obtiene:

$$x_k^{(g+1)} \sim \mathbf{m}^{(g)} + \sigma^{(g)} BDZ_k \quad (4)$$

Donde Z_k es un vector de números aleatorios.

Dada la población actual, se evalúa a través de la función objetivo, que corresponde al modelo del circuito equivalente del motor de inducción asíncrono en estado permanente (fig. 1).

Se crea un índice ordenado que proporciona a los mejores individuos μ de la población λ y que se representa como $i:\lambda$. La selección y recombinación se efectúa a través del vector de medias aplicando el vector de ponderaciones y el vector de mejores descendientes:

$$\mathbf{m} = \sum_{i=1}^{\mu} \omega_i x_{i:\lambda} \quad (5)$$

La ecuación para determinar la nueva matriz de covarianza es:

$$\begin{aligned} \mathbf{C}^{(g+1)} = & (1 - c_1 - c_\mu) \mathbf{C}^{(g)} + \\ & c_1 (\mathbf{p}_c \mathbf{p}_c^T + \delta(h_\sigma) \mathbf{C}^{(g)}) + \\ & c_\mu \sum_{i=1}^{\mu} \omega_i [(y_{i:\lambda})(y_{i:\lambda})^T] \end{aligned} \quad (6)$$

El diagrama presenta una forma simple del algoritmo CMA-es:

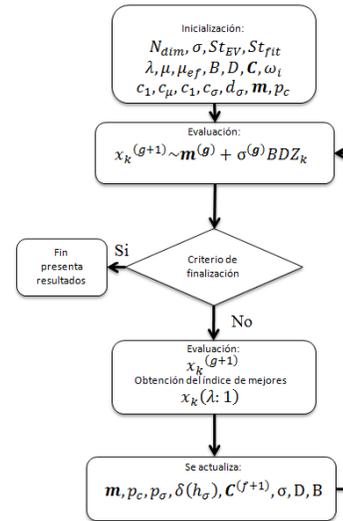


Figura 1: Diagrama de flujo del CMA-es.

III. FUNCIÓN OBJETIVO.

La función objetivo se obtiene del modelo correspondiente al circuito equivalente mostrado en la figura 2.

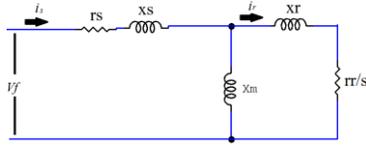


FIGURA 2: CIRCUITO EQUIVALENTE DEL MOTOR DE INDUCCIÓN ASÍNCRONO.

Donde los parámetros a estimar son las resistencias del estator y rotor R_s, R_r , las reactancias del estator y rotor X_s, X_r y la reactancia magnetizante X_m . Las expresiones requeridas son el par electromagnético y el factor de potencia [6].

$$\tau_e(s) = \frac{3p}{\omega_s} (i_r(s))^2 \left(\frac{R_r}{s_d} \right) \quad (7)$$

$$pf_{PC}(s) = \cos[\text{ang}(i_s(s))] \quad (8)$$

Donde p es el número de polos, ω_s velocidad angular, i_s, i_r corriente del estator y rotor, s_d deslizamiento.

El par de arranque se calcula con un valor $s_d = 1$, el par a plena carga y factor de potencia a plena carga con el valor proporcionado por el fabricante. Para calcular el par máximo se obtiene el deslizamiento correspondiente a través de la (9) [5].

$$s_{dM} = \frac{R_r}{\sqrt{R_{Th}^2 + (X_{Th} + X_r)^2}} \quad (9)$$

Los valores de referencia necesarios y que el fabricante proporciona son: par de arranque τ_A^F , par a plena carga τ_{PC}^F , par máximo τ_M^F y factor de potencia a plena carga fp_{PC}^F . Donde el índice "F" indica valores de fábrica, a continuación se empleará el índice "C" para denotar valores calculados.

$$F_1 = \frac{\tau_A^F - \tau_A^C}{\tau_A^F} \quad F_2 = \frac{\tau_{PC}^F - \tau_{PC}^C}{\tau_{PC}^F}$$

$$F_3 = \frac{\tau_M^F - \tau_M^C}{\tau_M^F} \quad F_4 = \frac{fp_{PC}^F - fp_{PC}^C}{fp_{PC}^F}$$

Expresiones 10, 11, 12 y 13.

La diferencia del trabajo realizado por [6] es que se propone una expresión más en la función objetivo obtenida a partir del ensayo en vacío. Las pérdidas por fricción y vendaval pueden reducir el deslizamiento hasta un valor de $s_{red} = 0.001$.

Entonces cuando el deslizamiento tiende a ser cero, el factor de potencia también tiende a cero; esto es:

$$fp_r = \lim_{s \rightarrow 0} \cos[\text{ang}(i_s(s))] = 0 \quad (14)$$

La expresión corresponde al factor de potencia con deslizamiento reducido:

$$F_5 = \cos[\text{ang}(i_s(s_{red}))] \quad (15)$$

Así la función objetivo queda definida por:

$$F_{obj} = F_1^2 + F_2^2 + F_3^2 + F_4^2 + F_5^2 \quad (16)$$

Se ha establecido que los 4 parámetros a obtener están directamente relacionados con la función objetivo definida en la Ec. (16). Cabe aclarar que se hace la suposición de que las reactancias de rotor y estator son iguales [6] y además se aplicó la restricción $R_r, R_s, X_r, X_s, X_m > 0$ en la conformación del CMA-es.

IV. PRUEBAS Y RESULTADOS.

Los datos del motor al que se le aplican las estrategias evolutivas para la identificación de parámetros se muestran en la tabla I. [6]

TABLA I
DATOS DE LOS MOTORES DE INDUCCIÓN ASÍNCRONOS.

Datos del fabricante	V	f	p	τ_A	τ_{PC}	τ_M	fp_{PC}	s_{PC}
Motor de 5 Hp	400V	50Hz	2	15Nm	25Nm	43Nm	0.8	0.07
Motor de 40 Hp	400v	50Hz	2	260Nm	190Nm	370Nm	0.8	0.09

Se realizaron 50 pruebas de búsqueda de parámetros del motor de inducción y se presenta el resultado de la que mejor evolucionó en cada estrategia.

Las configuraciones de cada algoritmo se presentan en las siguientes tablas.

TABLA II
CONFIGURACIÓN DEL ALGORITMO GENÉTICO.

Max. Ev.	individuos	mutación	prob. cruce
600	200	10%	100%
espacio de búsqueda	Rs, Rr, Xs, Xr	Xm	
	0-10	0-100	

TABLA III
CONFIGURACIÓN DEL ALGORITMO PSO.

Max. Ev.	individuos	Fac. soc .y comp.	Fac. inercia

500	40	C_{ij}	0.9 a 0.3
espacio de búsqueda	Rs, Rr, Xs, Xr		Xm
	0-10		0-100

Como se aprecia en las tablas I y II, se requieren del número de individuos y valores característicos para la configuración del algoritmo.

TABLA IV
CONFIGURACIÓN DEL ALGORITMO CMA-es.

Max. Ev.	individuos
256000	NO APLICA
espacio de búsqueda	Rs, Rr, Xs, Xr, Xm
	NO APLICA

En la tabla IV se observa que no es necesario un espacio de búsqueda o alguna configuración propia del método.

Los valores obtenidos por cada algoritmo se presentan en las tablas V y VI.

TABLA V
RESULTADOS PARA EL MOTOR DE 5 HP.

	Rs	Rr	Xs=Xr	Xm
AG	1.393E-05	2.20538	5.7776	95.5192
PSO	6.025E-07	2.2058	5.7810	95.8371
CMA-es	2.64E-13	2.2057	5.7793	95.6679

TABLA VI
RESULTADOS PARA EL MOTOR DE 40 HP.

	RS	Rr	Xr=Xs	Xm
AG	0.20558	0.37395	0.51133	8.13323
PSO	0.21337	0.37481	0.51145	8.36012
CMA-ES	0.22607	0.37224	0.50535	8.23778

El costo (debido a los parámetros obtenidos por AG, PSO y CMA-es) mostrados en la tabla VII para el motor de 5Hp, son reducidos y similares; esto se debe a que en el AG y PSO el espacio de búsqueda se configuró basándose en conocimiento a priori.

TABLA VII
COSTOS GENERALES POR MOTOR Y MÉTODO.

	AG	PSO	CMA-es
Costo motor 5 Hp	0.002279433	0.002279332	0.002279144
Costo motor 40 Hp	0.00099	0.00089	0.00087

En la figura 3 se presentan las evoluciones para el caso del motor de 5 Hp y se puede observar que el CMA-es muestra en las primeras 100 iteraciones un error casi 1000 veces mayor que los errores del AG y PSO y además que logra una convergencia antes que el PSO. En la gráfica no se aprecia, pero el

CMA-es realizó 512 iteraciones mientras que el PSO 500 y el AG 600.

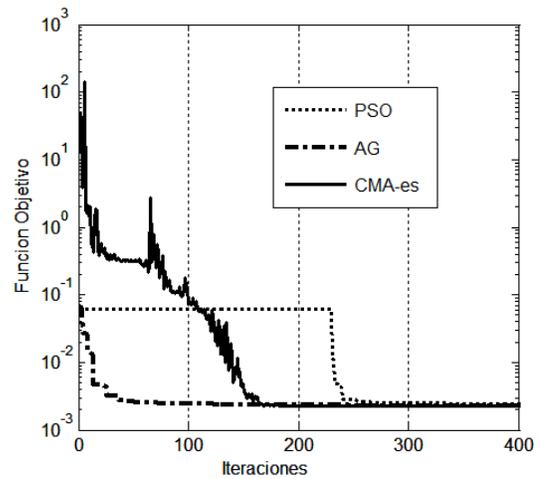


Figura 3: Diagrama semi-logarítmico del comportamiento de la función objetivo para el motor de 5Hp.

En las figuras 4, 5,6 y 7 se muestra la comparativa de los puntos alcanzados por los parámetros obtenidos por cada uno de los algoritmos y los valores proporcionados por el fabricante.

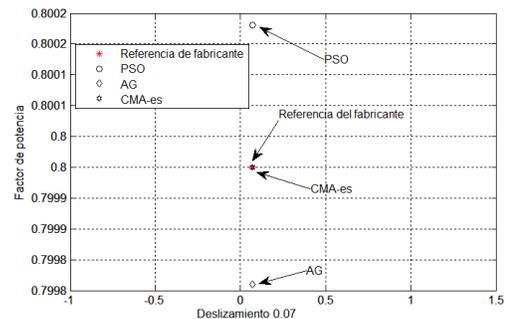


Figura 4: Comparación factor de potencia en motor de 5 Hp.

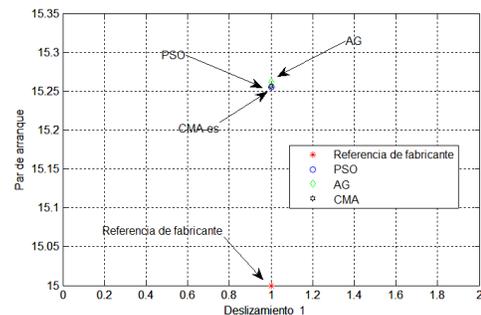


Figura 5: Comparación par de arranque en motor de 5 Hp.

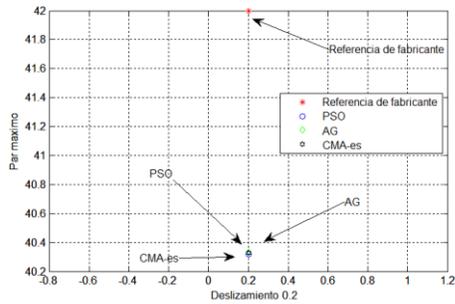


Figura 6: Comparación de par máximo en motor de 5 Hp.

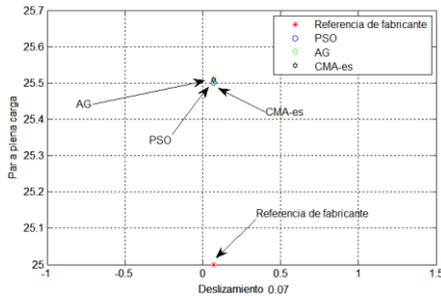


Figura 7: Comparación par a plena carga en motor de 5 Hp.

La figura 8 presenta las evoluciones para el motor de 40 Hp, el CMA-es inicia con un error relativamente grande comparado con los que muestran el PSO y AG. Es importante señalar que la diferencia entre los errores se debe a que los parámetros buscados son de valores similares a los que se generan de forma aleatoria [0,1]. Remarcando que la configuración del PSO y AG es la misma mostrada en las tablas II y III, estos dos métodos están con cierta desventaja que el CMA-es. En este caso podemos advertir que la expresión adicional insertada a la función objetivo mejora el desempeño del PSO y AG.

Finalmente se aprecia que el CMA-es llega a una barrera de valor mínimo y por criterio de finalización realiza 2001 iteraciones (PSO 500 y AG 600).

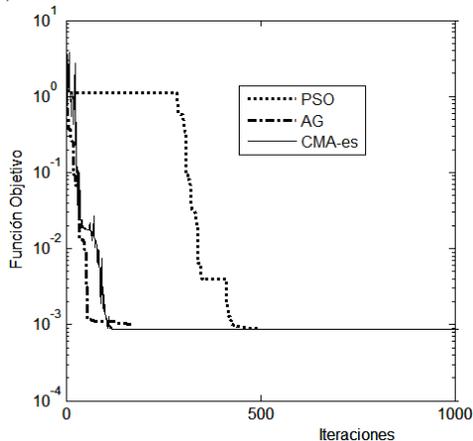


Figura 8: Diagrama semi-logarítmico del comportamiento de la función objetivo para el motor de 40 Hp.

Las figuras 9, 10, 11 y 12 muestran los diferentes puntos alcanzados por los parámetros obtenidos por cada método y con respecto a los puntos de referencia del fabricante.

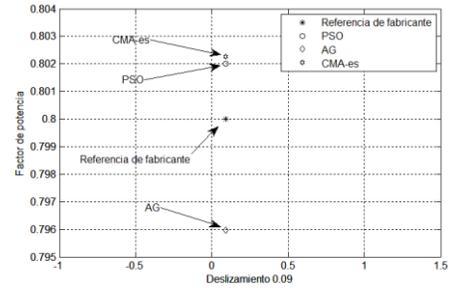


Figura 9: Comparación factor de potencia en motor de 40 Hp.

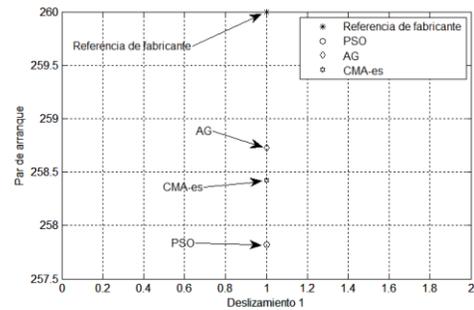


Figura 10: Comparación par de arranque en motor de 40 Hp.

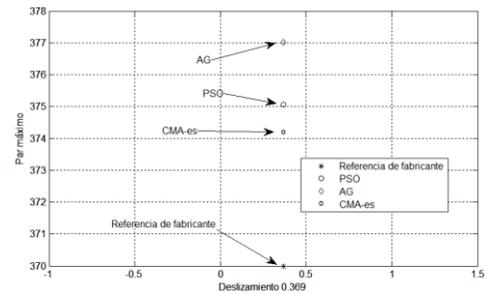


Figura 11: Comparación de par máximo en motor de 40 Hp.

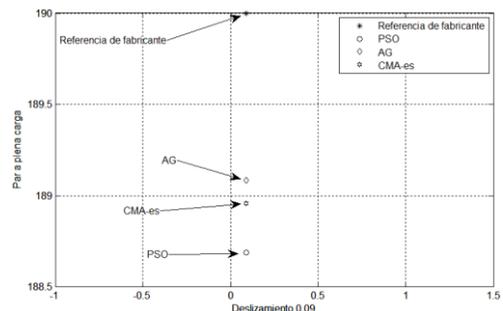


Figura 12 Comparación par a plena carga en motor de.

V. CONCLUSIONES

En este trabajo se propone el uso del CMA-es para la obtención de parámetros del modelo del circuito equivalente del motor de inducción, realizando la aplicación de una expresión de ensayo de vacío a la función objetivo para un mejor funcionamiento del CMA-es.

Los resultados obtenidos son comparados con los que se determinan por los otros métodos clásicos como los AGs y PSO; apreciando las figuras 4, 5,6 y 7 del caso del motor de 5 Hp y las figuras 9, 10,11 y 12 del caso del motor de 40 Hp, se puede señalar que el CMA-es estima parámetros con mejor precisión general y se confirma con los valores de los costos en la tabla VII.

VI. BIBLIOGRAFÍA.

- [1] J. Brownlee, "Clever Algorithms Nature-Inspired Programming Recipes", Australia 2011 pp. 87-99.
- [2] E.H.E. Bayoumi, "Parameter estimation of cage induction motors using cooperative bacterial foraging optimization", ELECTROMOTION 2010.
- [3] R.L. Hupt& S.E. Haupt, "Practical Genetic Algorithms", WILEY-INTERSCIENCE, New Jersey 2004, pp. 27-38
- [4] N. Hansen, "The CMA Evolution Strategy: A Tutorial", 2011.
- [5] S.J. Chapman, "Máquinas Eléctricas", McGraw-Hill 2011, pp. 333-350.
- [6] I. Perez, M. Gomez-Gonzalez & F. Jurado, "Estimation of induction motor parameters using shuffled frog-leaping algorithm", Electric Engineer, 2011 Springer.
- [7] K.E. Parsopoulos& M.N. Vrahatis, "Particle Swarm Optimization and Intelligence: Advances and Applications", Information Science REFERENCE 2010.
- [8] M.D. Gregory, Z. Bayraktar& D.H. Fellow, "Fast Optimization of Electromagnetic Desing Problems Using the Covariance Matrix Adaptation Evolutionaty Strategy", IEEE TRANSACTIONS ON ANTENNAS AND PROPAGATION, VOL. 59, NO. 4, APRIL 2011

VII. CURRICULUM.



Herbert Lara Ordaz, recibió el grado maestría en ciencias computacionales en el Centro de Investigación en Tecnologías de Información y Sistemas de la UAEH.
En 2011 inicia sus estudios de doctorado en ciencias en ingeniería industrial en el Área Académica de Ingeniería del ICBI en la UAEH
herbertlara@hotmail.com



Norberto Hernández Romero, Obtiene el grado de Maestría en Ciencias en Ingeniería Eléctrica por el Instituto Tecnológico de la Laguna, México, en 2001, y el grado de Doctor en Ciencias en Ingeniería Industrial por la Universidad Autónoma del Estado de Hidalgo, en 2009.
Actualmente es profesor-investigador de tiempo Completo, en la Universidad Autónoma del Estado de Hidalgo, México.
nor.her.00@gmail.com.



El Dr. Juan Carlos Seck Tuoh Mora recibió el título de Licenciado en Matemáticas Aplicadas y Computación en 1998, y recibió el grado de Maestría y Doctorado en Ciencias en Ingeniería Eléctrica (opción Computación) por parte del Centro de Investigación y de Estudios Avanzados del Instituto Politécnico Nacional en 1999 y 2002 respectivamente. Actualmente es profesor-investigador titular del Área Académica de Ingeniería de la Universidad Autónoma del Estado de Hidalgo. Ha sido autor y coautor de más de 30 artículos de investigación en revistas científicas de alto impacto. El Dr. Juan Carlos Seck Tuoh Mora es investigador nacional nivel 2 dentro del Sistema Nacional de Investigadores del CONACYT. Su trabajo actual de investigación incluye el estudio y aplicaciones de autómatas celulares, y algoritmos evolutivos y adaptables aplicados a la optimización de sistemas dinámicos.
jseck@uaeh.edu.mx



El Dr. Joselito Medina Marín es Ingeniero en Computación, Facultad de Ingeniería, Universidad Autónoma de Guerrero, México (1996) Maestro en Ciencias especialidad en Ingeniería Eléctrica opción Computación, Centro de Investigación y de Estudios Avanzados del IPN, México (2002) Doctor en Ciencias especialidad en Ingeniería Eléctrica opción Computación, Centro de Investigación y de Estudios Avanzados del IPN, México (2005). Profesor Investigador por la Universidad Autónoma del Estado de Hidalgo, México, áreas de interés: Bases de Datos Activas, Redes de Petri, Lenguajes de Programación, Simulación, Inteligencia Artificial. Líneas de Investigación: Bases de datos activas en Inteligencia Ambiental, Aplicaciones de redes de Petri en Ingeniería Industrial, Simulación de Sistemas de Eventos Discretos.
jmedina@uaeh.edu.mx