

METAHEURÍSTICAS BIOINSPIRADAS PARA LA SEGMENTACIÓN DE IMÁGENES




**Directores: Dr. Juan Humberto Sosa Azuela
Dr. Erik V. Cuevas Jiménez**

**José Valentín Osuna Enciso
Doctorado en Ciencias de la Computación**



Objetivos e hipótesis




Optimización



Algoritmos metaheurísticos




Estado del arte



Algoritmo propuesto



Segmentación



Resultados




Bibliografía

Proponer un algoritmo de optimización bioinspirado que mejore al menos uno de los problemas que presentan los algoritmos actuales, y el cual será aplicado en el análisis de imágenes, particularmente en el área de segmentación.

Objetivos: general y particulares



Determinar el mejor de tres algoritmos de propósito general en el problema de la segmentación con mezcla de funciones de Gauss.



Proponer una metaheurística bioinspirada y comparar su desempeño con tres heurísticas de propósito general.



Aplicar la propuesta a segmentación de imágenes.

Las metaheurísticas existentes dañan la diversidad de la población conforme crece el número de dimensiones, por lo que debe existir una metaheurística capaz de mantener tal diversidad.

Definición de un problema de optimización:

$$\min_{\mathbf{x} \in S} f(\mathbf{x})$$

donde

$$S = \{\mathbf{x} \in \mathbb{R}^n : h_j(\mathbf{x}) = 0, g_k(\mathbf{x}) \geq 0, l_i \leq x_i \leq L_i\}$$


$$j = 1, 2, \dots, J, k = 1, 2, \dots, K, i = 1, \dots, n$$

con el vector de decisión

$$\mathbf{x} = \{x_1, x_2, \dots, x_n\}^T$$

con l, L sus límites. El mínimo global está dado:

$$f(\mathbf{x}^*) \leq f(\mathbf{x}), \forall \mathbf{x} \in S$$



Taxonomía:

Nombre	Inspiración	Operadores	Autor(es)	Año
<i>Particle Swarm Optimiz</i>	Escuelas de peces, enjambres de aves	Posición, velocidad	Kennedy & Eberhart	1995
<i>Differential Evolution</i>	Evolución	Mutación, Cruza y Selección	Storn & Price	1996
<i>Harmony Search</i>	Orquesta buscando armonía	Improvisación, Selección mejor armonía	Geem et al	2001
<i>Bacterial Foraging Algorithm</i>	Bacterias en su búsqueda de alimento	Reproducción, Eliminación y dispersión, Selección	Passino	2002
<i>ElectroMagnetism Like Mechanism</i>	Atracción y repulsión entre partículas cargadas	Fuerza total, Movimiento Búsqueda en un vecindario	Birbi & Fang	2003
<i>Artificial Bee Colony Optimization</i>	Abejas mieleras en su búsqueda de alimento	Búsqueda, Selección de fuente por observadores explotación, abandono	Karaboga	2005
<i>Gravitational Search</i>	Ley de gravitación de Newton	Fuerza, Aceleración, Velocidad	Rashedi <i>et al</i>	2009

Pueden aplicarse a
funciones discontinuas,
con ruido, etc.

Pocos parámetros
de sintonización

Ventajas

Pueden funcionar en
esquemas de caja negra

Por ser poblacionales tienen
más posibilidad de no quedar
atrapados en óptimos locales

La sintonización de
parámetros a prueba y
error

Pérdida de diversidad con
incrementos en la
dimensión del problema

Desventajas

No existe garantía de
encontrar soluciones
óptimas en un tiempo finito

1) Alostasis:

Proceso a través del cual los organismos se ajustan activamente a eventos externos.


2) ¿Cómo se ajustan?

Cambiando '*setpoints*' y otras variables de control.


3) ¿Para qué se ajustan?

Para la supervivencia del organismo.

4) Diagrama de flujo:






5) Ejemplo:



Optimización Alostática:

Algoritmo propuesto (3/19)



Generador nums aleatorios: rand

$$m = \left(\frac{1}{D}\right) \cdot \left[\psi \left(1.1 - \frac{1}{e^{\psi \cdot [f(b^{best}) - f(b_i^{new})]}} \right) \right]$$

$$a_j = \left(\frac{1}{N_b}\right) \cdot \sum_{i=1}^{N_b} b_{j,i}; \quad j = 1, \dots, D$$

$$b_{j,g1} = a_j - m + (2 \cdot m \cdot \text{rand});$$

$$b_{j,g2} = a_j \cdot \text{rand};$$


$$b_{j,g3} = b_j^{best} - m + (2 \cdot m \cdot \text{rand});$$

$$\psi \in [0.01, 2.5]$$

Optimización Alostática:


-El 'valor de *fitness*' evalúa la capacidad de cada condición corporal (**individuo**) para alcanzar un estado de salud estable (**solución buena**).

-La población se forma de la siguiente manera:



Optimización Alostática:

-Operador combinación:



Optimización Alostática:

Individuo promedio

$$a_j = \left(\frac{1}{N_b} \right) \cdot \sum_{i=1}^{N_b} b_{j,i}; \quad j = 1, \dots, D$$

$$error = f(\mathbf{b}^{best}) - f(\mathbf{b}_i^{new})$$

Modificación aplicada
a cada individuo

$$m = \left(\frac{1}{D} \right) \cdot \left[\psi \left(1.1 - \frac{1}{e^{\psi \cdot [error + \psi]}} \right) \right]$$

considerando

$$\psi \in [0.01, 2.5]$$

Funciones de modificación:

$$m = \left(\frac{1}{D}\right) \cdot \left[\left(\psi - \frac{1}{e^{\psi \cdot [error]}}\right)\right]$$

$$error = f(\mathbf{b}_i^{new}) - f(\mathbf{b}^{best})$$

$$m = \left(\frac{1}{D}\right) \cdot \left[\psi \left(1 - \frac{1}{e^{\psi \cdot [error]}}\right)\right]$$

$$error = \frac{f(\mathbf{b}_i^{new}) - f(\mathbf{b}^{best})}{f(\mathbf{b}_i^{new}) + f(\mathbf{b}^{best})}$$

$$m = \left(\frac{1}{D}\right) \cdot \left[\psi \left(1.1 - \frac{1}{e^{\psi \cdot [error]}}\right)\right]$$

$$\psi \in [0.01, 2.5]$$

$$m = \left[\left(\frac{\psi}{1000 \cdot e^{(k/maxIter)}}\right)\right]$$

$$m = \left[\psi \left(1.1 - \frac{1}{e^{\psi \cdot [error+1]}}\right)\right]$$

$$m = \left[\psi \left(1.1 - \frac{1}{e^{\psi \cdot [error+\psi]}}\right)\right]$$

Optimización Alostática:

-Operadores Colectivo


B1, B2 y B3:

$$b_{j,g1} = a_j - m + (2 \cdot m \cdot rand);$$


$$b_{j,g2} = a_j \cdot rand;$$

$$b_{j,g3} = b^{best}_j - m + (2 \cdot m \cdot rand);$$


$$j = 1, \dots, D$$




Mejor individuo, Rosenbrock:



Mejor *fitness*, Rosenbrock:



Diversidad, Rosenbrock:



Resultados 100D de OA:

Función	OA, psi=0.3	ED	CAA	EPA
1	3.9937e+01 (3.9784e+01)	2.8111e+03 (3.5080e+02)	1.7251e+02 (5.8904e+01)	1.0767e+05 (8.9322e+04)
2	2.0153e-01 (2.1385e-01)	5.1985e+00 (1.8561e-01)	2.4390e+00 (2.8947e-01)	1.1669e+01 (1.9576e+00)
3	2.2451e+01 (8.7356e+00)	3.4139e+03 (5.2993e+02)	3.4263e+01 (1.0817e+01)	3.4967e+05 (5.6244e+05)
4	5.2603e-01 (2.8725e-01)	8.9312e+00 (1.2930e+00)	2.4199e-01 (2.2824e-01)	5.2478e+01 (7.3364e+01)
5	1.5258e-05 (2.7152e-06)	5.2726e-01 (1.1193e-01)	8.4341e-02 (1.6004e-01)	6.8711e+01 (2.1799e+01)
6	3.0538e+00 (9.9117e+00)	8.4072e+02 (1.3958e+02)	1.9633e-02 (1.8448e-02)	4.3811e+03 (5.6858e+03)
7	-4.1774e+04 (5.7504e+01)	-4.2249e+04 (4.5965e+02)	-3.5223e+04 (5.9198e+02)	-2.6671e+04 (2.2475e+03)
8	9.7196e+02 (9.2946e+01)	3.0037e+02 (4.4951e+01)	1.3751e+03 (5.9054e+01)	2.8357e+03 (4.2894e+02)
9	1.3576e-03 (3.4269e-04)	3.9315e+02 (6.3160e+01)	1.0474e-02 (9.8546e-03)	5.4899e+03 (3.5969e+03)
10	6.7798e+00 (2.7762e+00)	2.3094e+02 (1.1615e+01)	6.7935e+01 (9.7376e+00)	4.9508e+02 (6.5788e+01)

Resultados 100D de OA:

Función	OA, psi=0.3	ED	CAA	EPA
11	1.8086e+00 (9.2076e-01)	6.0672e+02 (8.7775e+01)	2.4329e+01 (1.6413e+01)	2.6970e+03 (2.1486e+03)
14	3.7938e-01 (4.9215e-02)	2.9838e+00 (2.3765e-01)	2.2803e+00 (3.3528e-01)	1.5363e+01 (1.9354e+01)
15	4.5978e-01 (1.1898e+00)	1.0725e+03 (1.4678e+02)	2.1421e-02 (2.3505e-02)	4.0177e+03 (5.5961e+03)
16	3.7021e-02 (3.8228e-03)	1.9893e+01 (1.5149e+00)	8.6896e-02 (1.4243e-02)	4.1133e+01 (2.0366e+01)
17	5.3581e+01 (1.1847e+02)	3.8127e+04 (8.4861e+03)	1.4744e+00 (1.7633e+00)	4.3295e+05 (3.2494e+05)
18	5.0800e+01 (2.8239e+00)	8.8140e+01 (2.1994e+00)	9.0230e+01 (1.8684e+00)	5.3605e+01 (3.7288e+00)
19	4.9159e-03 (1.0869e-02)	8.8592e+00 (6.0165e-01)	4.1150e-04 (5.8258e-04)	2.9297e+01 (4.4660e+01)
20	1.3294e-01 (1.7048e-01)	1.6428e+01 (8.9242e+00)	3.1873e-03 (5.9887e-03)	2.3198e+02 (1.2498e+02)
30	5.7384e+00 (2.6671e-01)	2.8653e+01 (1.0156e+00)	1.8596e+01 (1.4224e+00)	9.1529e+00 (4.6464e+00)
32	1.2442e-02 (5.2781e-03)	2.1790e+01 (1.5733e+00)	1.6697e+00 (6.5168e-01)	1.4608e+01 (7.0252e+00)

Resultados al variar ψ :

Función	OA, $\psi=0.3$	OA, $\psi=1.3$	OA, $\psi=0.2$
1	3.99370595e+01 (3.97840241e+01)	3.65635774e+02 (5.46665259e+01)	1.20528443e+02 (6.81504329e+01)
2	2.01533760e-01 (2.13851416e-01)	9.36711603e-02 (8.57429358e-03)	2.09833748e-01 (2.39451788e-01)
3	2.24510175e+01 (8.73561036e+00)	6.95499582e+01 (8.92068696e+00)	2.09818169e+01 (7.94207524e+00)
4	5.26031667e-01 (2.87252811e-01)	6.88058634e-02 (8.28388686e-02)	8.27743915e-01 (2.18042124e-01)
5	1.52587638e-05 (2.71529472e-06)	1.22284499e-02 (2.64796678e-03)	1.91957578e-04 (4.83905483e-05)
6	3.05382399e+00 (9.91179182e+00)	4.95833607e-02 (7.72306355e-03)	4.84854211e-02 (1.12139207e-01)
7	-4.17743139e+04 (5.75046437e+01)	-4.18982593e+04 (8.31630400e-03)	-4.18715772e+04 (1.62255719e+01)

Ventajas al comparar el algoritmo propuesto con ED, CAA y EPA:

- 1) Sólo un parámetro para sintonizar (ψ).
- 2) Conforme crece el número de dimensiones, la diversidad de la población se mantiene (grupo B3) y por lo tanto se mantiene la capacidad de exploración.
- 3) Se introduce el concepto de individuo promedio, logrando con esto que individuos muy buenos ó individuos muy malos no tengan influencia en el proceso de búsqueda.
- 4) Consideramos que los grupos B1 y B2 ayudan en el proceso de explotación.

**Segmentación como
un problema de optimización (Mezcla de
funciones de Gauss):**

$$f(\mathbf{y}) = \min_{\mathbf{y} \in S_y} \sqrt{\sum_{j=0}^L \left[\sqrt{y_j} - \sqrt{h_j} \right]^2}$$


donde

$$S_y = \left\{ \mathbf{y} \in \mathbb{R}^n : \sum_{j=0}^L y_j = 1 \right\}, \mathbf{y} = \sum_{i=1}^K \frac{A_i}{\sigma_i \sqrt{2\pi}} \cdot e^{\left[\frac{-(L-\mu_i)^2}{2 \cdot \sigma_i^2} \right]}$$

$$\mathbf{y} = \{y_0, y_2, \dots, y_L\}^T \text{ y } \mathbf{x} = \{A_1, \mu_1, \sigma_1 \dots, A_K, \mu_K, \sigma_K\}^T$$

**y K es el número de clases, L es el número de niveles de
gris, A_i , μ_i , σ_i son la altura, media y desviación estándar
de la clase i .**

Segmentación como un problema de optimización:






Segmentación usando optimización alostática:





Imagen	Clases	OA $\mu(\sigma)$			Otsu $\mu(\sigma)$		
		T_1	T_2	T_3	T_1	T_2	T_3
233	2	98(1.09)	NA	NA	90(0)	NA	NA
Q24a	2	117(1.94)	NA	NA	125(0)	NA	NA
Im001_1	3	105(1.36)	154(0.54)	NA	97(0)	148(0)	NA
Im002_1	3	97(2.81)	154(0.63)	NA	96(0)	148(0)	NA
61060	4	84(1.18)	157(0.96)	241(1.89)	91(0)	162(0)	215(0)
253036	4	142(1.77)	189(3.84)	232(3.61)	138(0)	191(0)	222(0)

Método	Distancia Hausdorff	
	μ	σ
AO	2.1364	0.6535
OTSU	2.4655	2.6779e-015

Segmentación usando optimización alostática:









Segmentación usando optimización alostática:



CAA

ED

EPA



Resultados experimentales 1:

Algoritmo	Distancia		Iteraciones		Evaluaciones de la función objetivo		Tiempo de ejecución (seg)	
	μ	σ	μ	σ	μ	σ	μ	σ
CAA	0.1161	0.0023	95	23	8586	2090	0.7819	0.1871
ED	0.1161	0.0022	76	17	6954	1595	0.4980	0.1146
OEP	0.1534	0.0950	107	151	9556	13656	0.5328	0.7283

Resultados experimentales 2:

Algoritmo	Distancia Hausdorff	
	μ	σ
CAA	2.0600	0.0654
ED	2.1064	0.5477
OEP	2.1947	0.2365

- 1) El algoritmo propuesto tiene una mejor convergencia comparado con ED, EPA y CAA para un conjunto de funciones de prueba de dos hasta cien dimensiones.**
- 2) El algoritmo propuesto dio buenos resultados al utilizarse para resolver un problema de segmentación.**
- 3) De acuerdo a la literatura, los algoritmos ED, EPA y CAA no se habían comparado al realizar segmentación con mezcla de funciones de Gauss, por lo que una parte de este trabajo se encaminó a llenar tal vacío en la literatura.**

- 1) Se propone una nueva metodología que mejora la diversidad de la población conforme crece el número de dimensiones del problema a resolver.**
- 2) Se determina experimentalmente cual de tres algoritmos metaheurísticos da buenos resultados en una familia de problemas (segmentación usando una mezcla de funciones), información que se añade a las bases del conocimiento.**

Publicados revista:

1. OSUNA-ENCISO, V., CUEVAS, E. and SOSSA, H., 2013. A comparison of nature inspired algorithms for multi-threshold image segmentation. *Expert Systems with Applications*, 40(4), pp. 1213-1219.
2. CUEVAS, E., OSUNA-ENCISO, V., ZALDIVAR, D., PÉREZ-CISNEROS, M. and SOSSA, H., 2012. Multithreshold segmentation based on artificial immune systems. *Mathematical Problems in Engineering*, 2012.
3. CUEVAS, E., ZALDÍVAR, D., PÉREZ-CISNEROS, M., SOSSA, H. and OSUNA, V., 2013. Block matching algorithm for motion estimation based on Artificial Bee Colony (ABC). *Applied Soft Computing Journal*, 13(6), pp. 3047-3059.

Publicados congreso:

1. OSUNA, V., CUEVAS, E. and SOSSA, H., 2013. Segmentation of blood cell images using evolutionary methods.
2. CUEVAS, E., SOSSA, H., OSUNA, V., ZALDIVAR, D. and PÉREZ-CISNEROS, M., 2013. Fast circle detection using harmony search optimization.

Enviados:

1. OSUNA-ENCISO, V., CUEVAS, E. and SOSSA, H., 2013, A bio-inspired evolutionary algorithm: Allostatic Optimization, ASOC-D-13-00400, *Applied Soft Computing*. MAR/13
2. OSUNA-ENCISO, V., CUEVAS, E. and SOSSA, H., 2013, Image Segmentation using an evolutionary method based on Allostatic Mechanisms, NACO-D-13-00090, *Natural Computing*. SEP/13

D. Karaboga, An idea based on honey bee swarm for numerical optimization, Technical report,-TRO6, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.

Dorigo, M., & Di Caro, G. Ant colony optimization: A new meta-heuristic. In P. J. Angeline, Z. Michalewicz, M. Schoenauer, X. Yao, & A. Zalzala (Eds.), Proceedings of the 1999 Congress on Evolutionary Computation (CEC'99) (pp. 1470–1477). Piscataway, NJ, IEEE Press, 1999.

R. Storn and K. Price. Differential evolution- a simple and efficient adaptive scheme for global optimization over continuous spaces. Technical report, 1995.

James Kennedy, Russell Eberhart, Particle Swarm Optimization, From Proc. IEEE Int'l. Conf. on Neural Networks (Perth, Australia), IEEE Service Center, Piscataway, NJ, IV:1942-1948.

Sterling, P. and Eyer, J., 1988, Allostasis: A new paradigm to explain arousal pathology. In: S. Fisher and J. Reason (Eds.), Handbook of Life Stress, Cognition and Health. John Wiley & Sons, New York.

Erik Cuevas, Daniel Zaldivar, and Marco Perez-Cisneros. 2010. A novel multi-threshold segmentation approach based on differential evolution optimization. Expert Syst. Appl. 37, 7 (July 2010), 5265-5271

Xin-She Yang, Review of Metaheuristics and Generalized Evolutionary Walk Algorithm, Optimization and Control (math.OC); Adaptation and Self-Organizing Systems (nlin.AO), Int. J. Bio-Inspired Computation, Vol. 3, No. 2, pp. 77-84, 2011.

Yaochu Jin, A Comprehensive Survey of Fitness Approximation in Evolutionary Computation, Soft Computing, 9(1), pp. 3-12, 2005.


David H. Wolpert and William G. Macready, No Free Lunch Theorems for Optimization, IEEE Transactions on Evolutionary Computation, Vol. 1, No. 1, April, 1997

N. Otsu. A threshold selection method from gray-level histograms. IEEE Transactions on Systems, Man and Cybernetics, 9(1):62–66, January 1979.

Kass, M., Witkin, A. & Terzopoulos, D. Snakes: Active contour models. International Journal of Computer Vision 1, 321-331 (1988).

Vicent Caselles, Bartomeu Coll, and Jean-Michel Morel. 1999. Topographic Maps and Local Contrast Changes in Natural Images. Int. J. Comput. Vision 33, 5-27, 1999.

- Chen Wei; Fang Kangling; , "Multilevel thresholding algorithm based on particle swarm optimization for image segmentation," *Control Conference, 2008. CCC 2008. 27th Chinese* , vol., no., pp.348-351, 16-18 July 2008
- S. P. Duraisamy and R. Kayalvizhi, "A New Multilevel Thresholding Method Using Swarm Intelligence Algorithm for Image Segmentation," *Journal of Intelligent Learning Systems and Applications*, Vol. 2 No. 3, pp. 126-138
- Battiti R., Tecchiolli G., 1994, The Reactive Tabu Search, *ORSA Journal on Computing*, 6 (2), 126-140
- K. M. Passino, "Biomimicry of bacterial foraging for distributed optimization and control," *IEEE Control Systems Magazine*, vol. 22, no. 3, pp. 52-67, 2002.
- Glover, F. "Tabu Search — Part I", *ORSA Journal on Computing* 1989 1: 3, 190-206.
- Glover, F. "Tabu Search — Part II", *ORSA Journal on Computing* 1990 2: 1, 4-32.
- Ilhem Boussaïd, Julien Lepagnot, Patrick Siarry, A survey on optimization metaheuristics, *Information Sciences*, Available online 7 March 2013, ISSN 0020-0255, 2013.
- Sezgin, M. & Sankur, B. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging* 13, 146-168, 2004.
- S. Ilker B., S.C. Fang, An Electromagnetism-like Mechanism for Global Optimization, *Journal of Global Optimization* 25: 263-282, 2003.
- Mohamad, Z.S.; Darvish, A.; Rahnamayan, S., "Eye illusion enhancement using interactive Differential Evolution," *Differential Evolution (SDE)*, 2011 IEEE Symposium on , vol., no., pp.1,7, 11-15 April 2011.
- Gupta, V.; Chi Chiu Chan; Pui Tze Sian, "A Differential Evolution Approach to PET Image De-noising," *Engineering in Medicine and Biology Society*, 2007. EMBS 2007. 29th Annual International Conference of the IEEE , vol., no., pp.4173,4176, 22-26 Aug. 2007.
- Yalcin, I.K.; Gokmen, M., "Integrating Differential Evolution and Condensation Algorithms for License Plate Tracking," *Pattern Recognition*, 2006. ICPR 2006. 18th International Conference on , vol.1, no., pp.658,661, 2006.



Gracias por su
atención