

BIOINFORMÁTICA

2013 - 2014

PARTE I. INTRODUCCIÓN

- Tema 1. Computación Basada en Modelos Naturales

PARTE II. MODELOS BASADOS EN ADAPTACIÓN SOCIAL (Swarm Intelligence)

- Tema 2. Introducción a los Modelos Basados en Adaptación Social
- Tema 3. Optimización Basada en Colonias de Hormigas
- Tema 4. Optimización Basada en Nubes de Partículas (Particle Swarm)

PARTE III. COMPUTACIÓN EVOLUTIVA

- Tema 5. Introducción a la Computación Evolutiva
- Tema 6. Algoritmos Genéticos I. Conceptos Básicos
- Tema 7. Algoritmos Genéticos II. Diversidad y Convergencia
- **Tema 8. Algoritmos Genéticos III. Múltiples Soluciones en Problemas Multimodales**
- Tema 9. Estrategias de Evolución y Programación Evolutiva
- Tema 10. Algoritmos Basados en Evolución Diferencial (Differential Evolution – DE)
- Tema 11. Modelos de Evolución Basados en Estimación de Distribuciones (EDA)
- Tema 12. Algoritmos Evolutivos para Problemas Multiobjetivo
- Tema 13. Programación Genética
- Tema 14. Modelos Evolutivos de Aprendizaje

PARTE IV. OTROS MODELOS DE COMPUTACIÓN BIOINSPIRADOS

- Tema 15. Sistemas Inmunológicos Artificiales
- Tema 16. Otros Modelos de Computación Natural/Bioinspirados

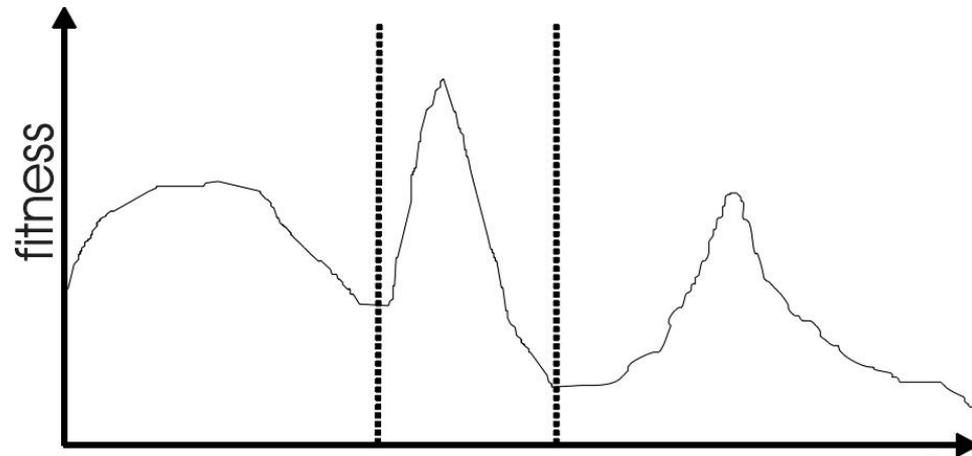
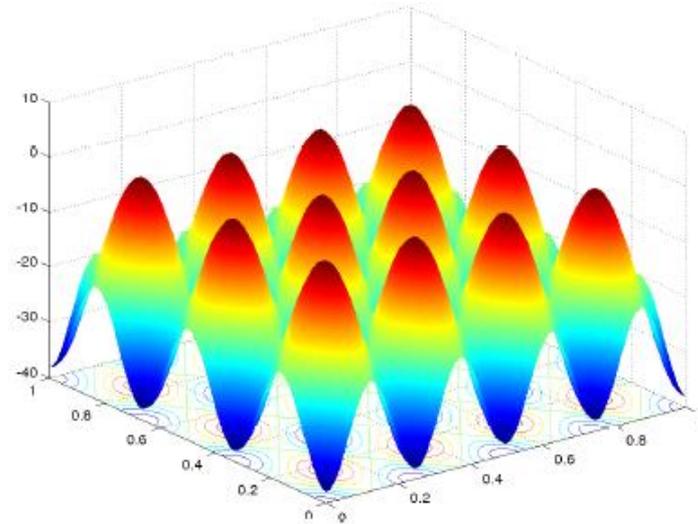
BIOINFORMÁTICA

TEMA 8: ALGORITMOS GENÉTICOS III: PROBLEMAS MULTIMODALES

1. **PROBLEMAS MULTIMODALES**
2. **EVOLUCIÓN EN PROBLEMAS MULTIMODALES**
3. **MODELOS DE AGs MULTIMODALES**

1. PROBLEMAS MULTIMODALES

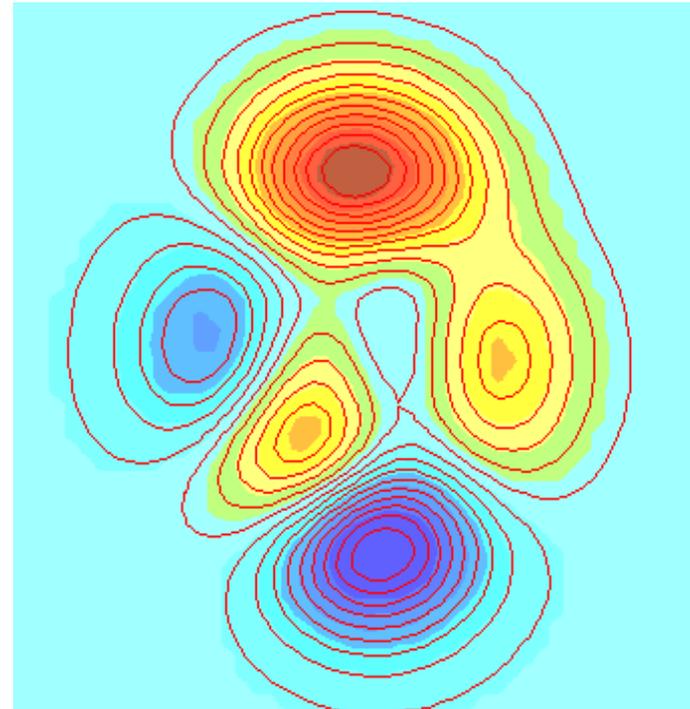
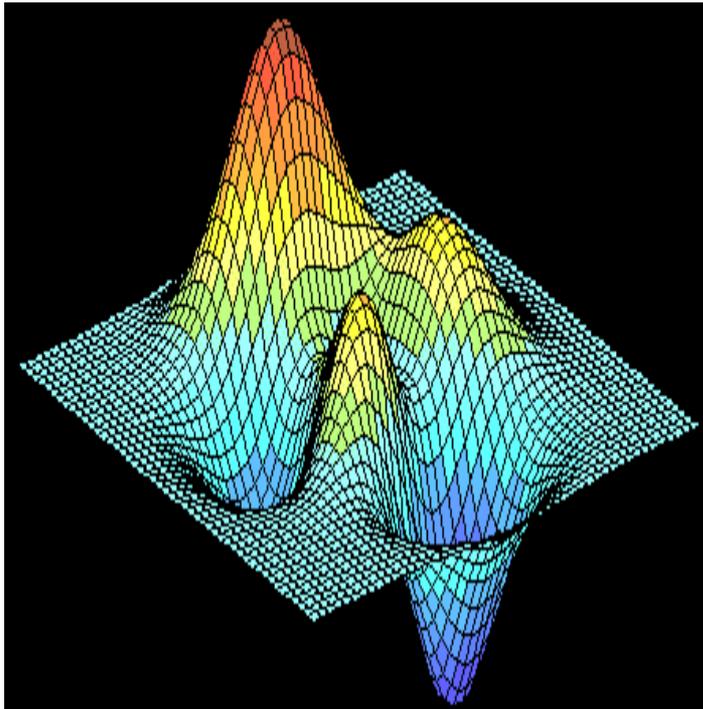
- Muchos problemas interesantes tienen más de una solución localmente óptima.
- En la resolución del problema se desea obtener varios de esos óptimos locales o globales.
- Son problemas que tienen múltiples óptimos locales o múltiples óptimos globales (múltiples soluciones al problema).



1. PROBLEMAS MULTIMODALES

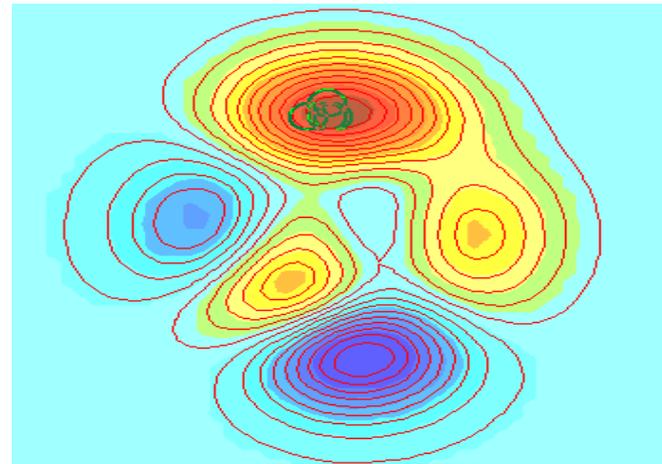
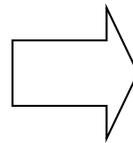
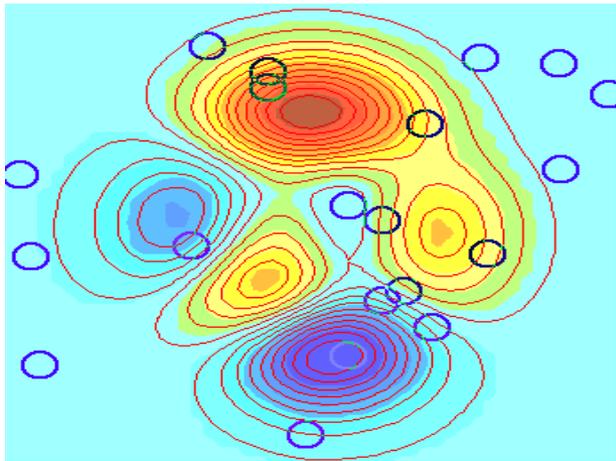
- Ejemplo: Encontrar el máximo de la función $z = f(x, y)$

$$z = f(x, y) = 3*(1-x)^2*\exp(-(x^2) - (y+1)^2) - 10*(x/5 - x^3 - y^5)*\exp(-x^2-y^2) - 1/3*\exp(-(x+1)^2 - y^2).$$



2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES

- Se comienza con una población inicial que proporciona un muestreo aleatorio del espacio solución.
- El proceso evolutivo suele provocar la convergencia de toda la población a una zona restringida del espacio de búsqueda, abandonando la exploración del resto de óptimos locales **deriva genética**.

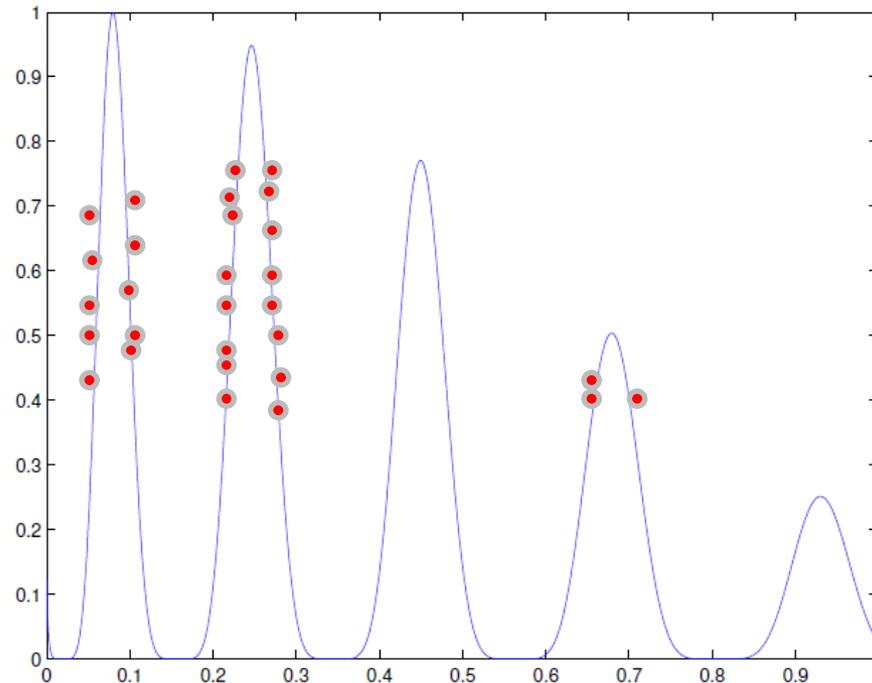


Población inicial (Gen 0)

Después de 10 generaciones

2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES

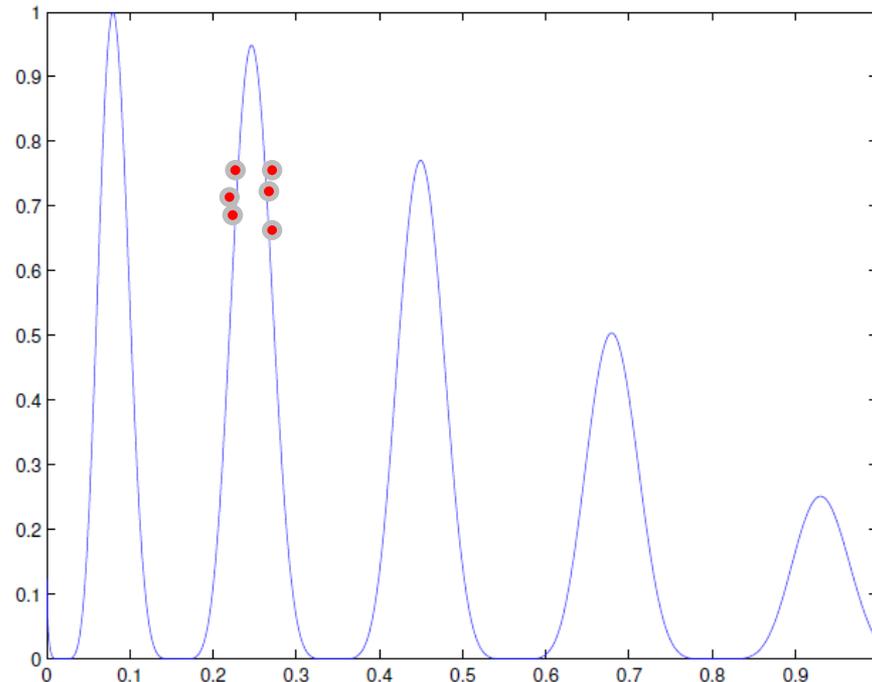
1.- Las búsquedas se focalizan en único punto



2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES

1.- Las búsquedas se focalizan en único punto

2.- Se pierde diversidad

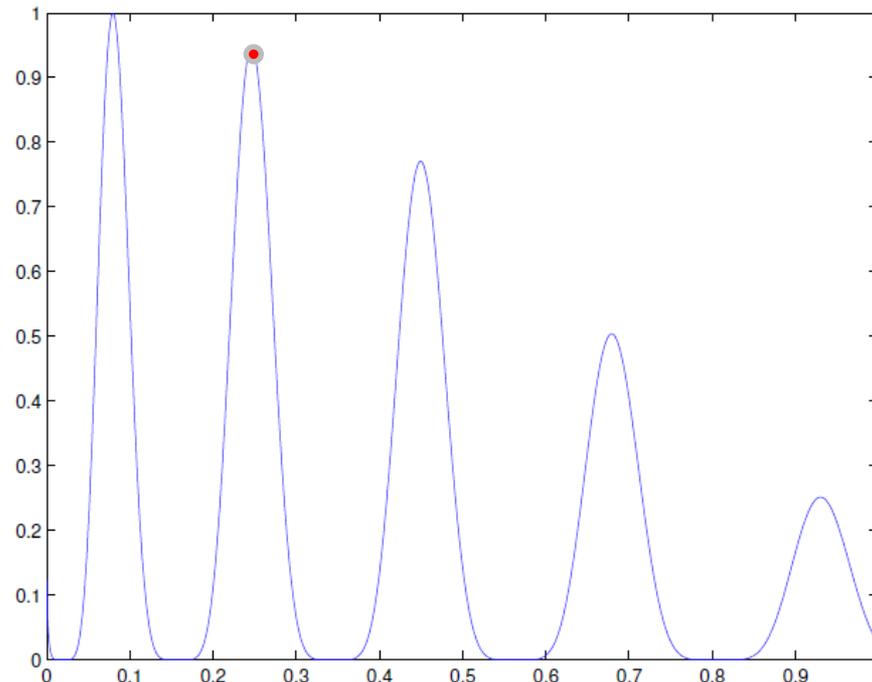


2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES

1.- Las búsquedas se focalizan en único punto

2.- Se pierde diversidad

3.- Converge prematuramente



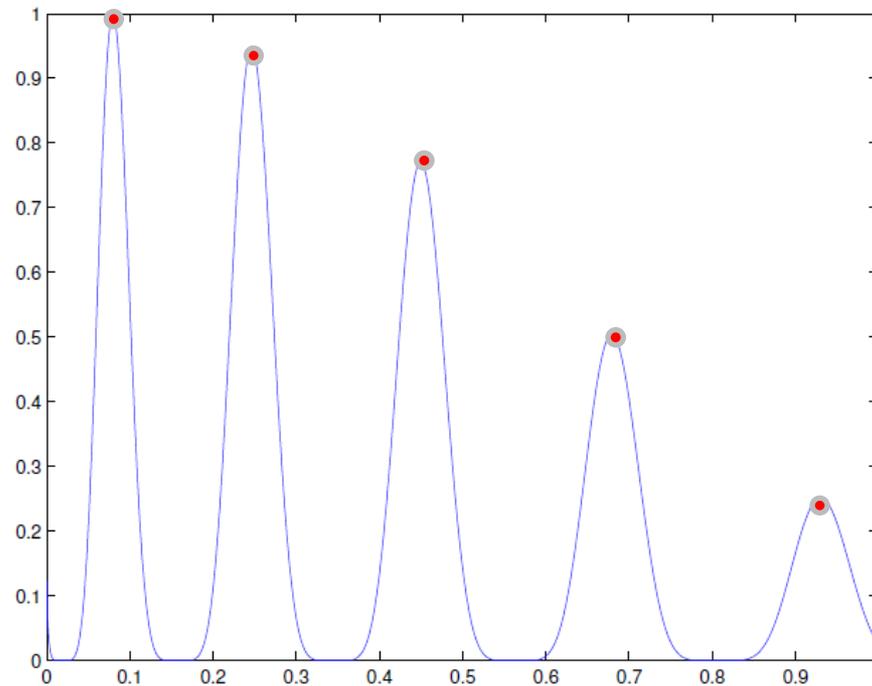
2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES

1.- Las búsquedas se focalizan en único punto

2.- Se pierde diversidad

3.- Converge prematuramente

4.- No obtienen todos los óptimos



2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES

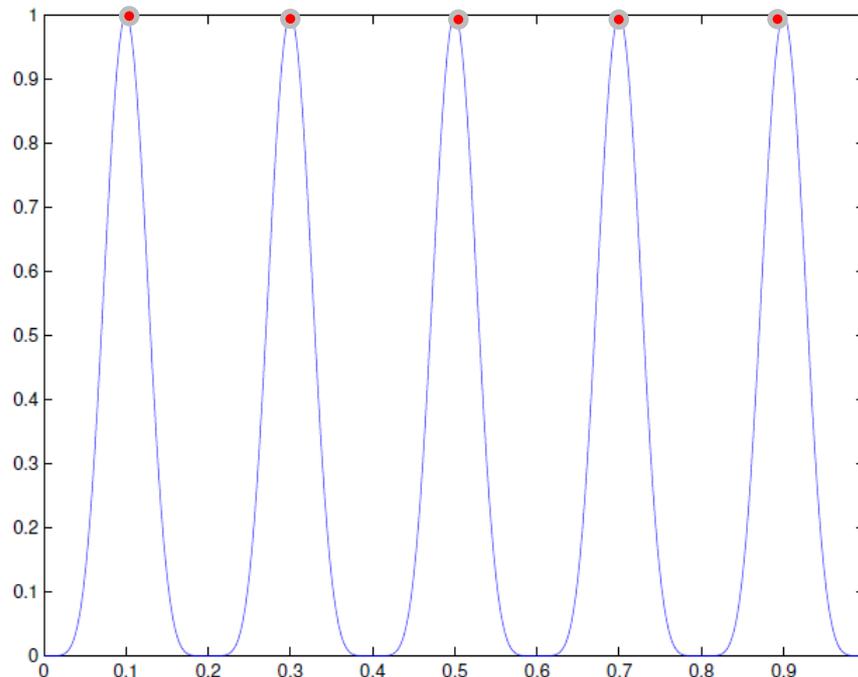
1.- Las búsquedas se focalizan en único punto

2.- Se pierde diversidad

3.- Converge prematuramente

Baja eficacia

4.- No obtienen todos los óptimos



2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES

El **Objetivo** ante problemas multimodales es preservar la diversidad en la población



Para permitir la búsqueda simultánea en diferentes áreas tenemos que limitar la competencia de las soluciones dentro de estas áreas y no fuera de ellas



La propuesta es utilizar **algoritmos de nichos o multimodales**

2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES

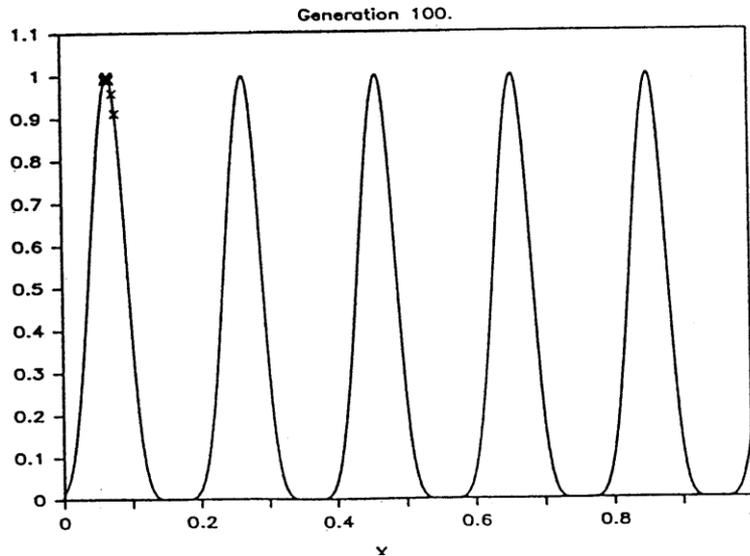
Se introduce el concepto de nichos.

Los AGs evolucionan una población que permita tener soluciones en diferentes zonas del espacio de búsqueda (nichos) (evolución con nichos).

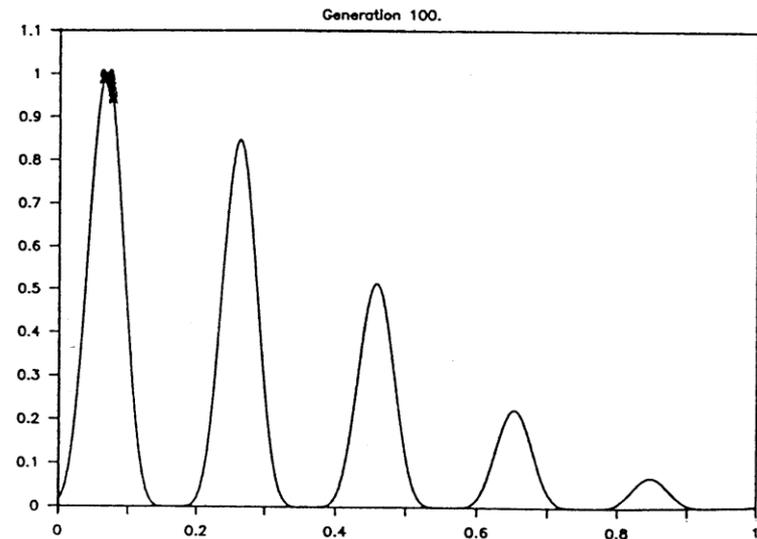
**Manejo de problemas con
Múltiples “óptimos-locales” / “soluciones”**

B. Sareni, L. Krähenbühk, Fitness Sharing and Niching Methods Revisited. IEEE Transactions on Evolutionary Computation, Vol. 2, No. 3, Septiembre 1998, 97-106.

2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES



*Varios óptimos globales
Evolución sin nichos y sin mutación*

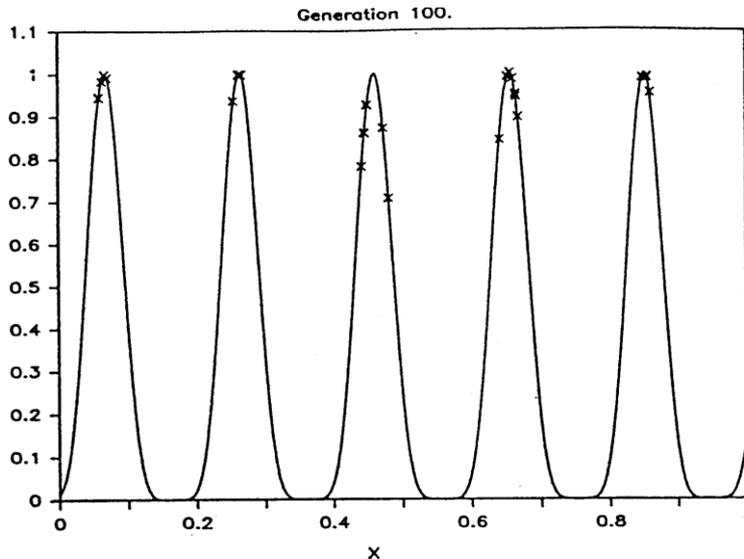


*Varios óptimos locales
Evolución sin nichos y sin mutación*

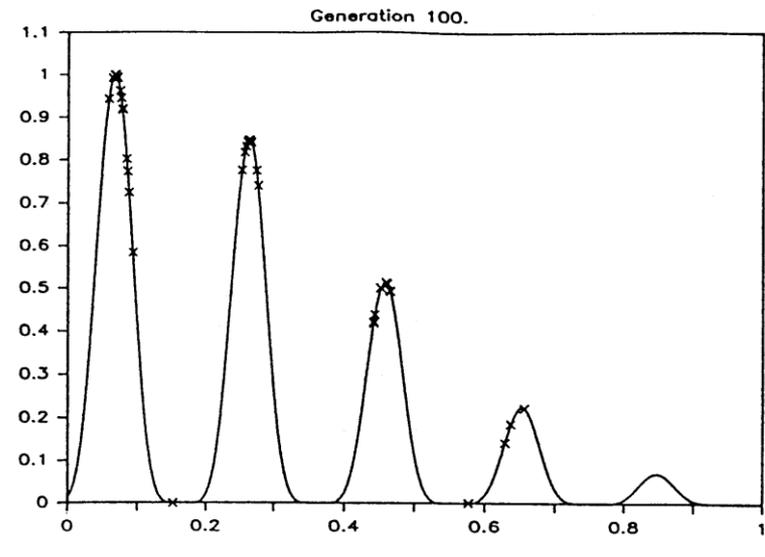
Se produce la convergencia a cualquier óptimo, debido fundamentalmente al efecto denominado deriva genética.

Propuesta alternativa: AG con nichos – AG Multimodales

2. EVOLUCIÓN EN PROBLEMAS MULTIMODALES



*Varios óptimos globales
Evolución con nichos y sin mutación*



*Varios óptimos locales
Evolución con nichos y sin mutación*

Se produce la convergencia a varios óptimos mediante técnicas de nichos.

AG MULTIMODALES

3. MODELOS DE AGs MULTIMODALES

■ Clasificación según la formación de nichos

- **Espaciales:** Formación de diferentes nichos en las poblaciones de una misma ejecución del AG.

Cuatro ejemplos:

- **Fitness Sharing (Penalización de la calidad)**
- **Clearing (Limpieza en la población)**
- **Species competition (Conservación de especies)**
- **Crowding (Agrupamiento)**

- **Temporales:** Formación de diferentes nichos a lo largo de diferentes ejecuciones del AG.

- **Sequential (Método secuencial):** Beasley, D.; Bull, D.R. y Martin, R.R. (1993). "A sequential niche technique for multimodal function optimization". *Evolutionary Computation*, Vol. 1(2): 101-125.

AGs Multimodales Espaciales

- **Fitness Sharing (Método de proporción):**

Con el método de proporción se pretende lograr la formación de subconjuntos de elementos vecinos en la población llamados nichos, asociando cada uno de ellos con óptimo (multimodalidad).

Proceso: Modifica la calidad de los individuos que pertenecen a zonas densamente pobladas.

Antes del proceso de selección se analizan los individuos de la población calculando su valor de adaptación modificado (f^*) en función de su cercanía al resto de individuos que componen la población.

Con esta nueva adaptación (f^*) se realiza el proceso de selección.

Sharing: Goldberg, D., Genetic Algorithms in Search, Optimization and Machine Learning. Addison Wesley, New York, 1989.

AGs Multimodales Espaciales

■ Fitness Sharing (Método de Proporción):

Formulación y parámetros

$$f_i^* = \frac{f_i}{\sum_{j=1}^N Sh(d(i,j))} \quad Sh(d(i,j)) = \begin{cases} 1 - \left(\frac{d(i,j)}{\sigma_{share}} \right)^\alpha & \text{Si } d(i,j) < \sigma_{share} \\ 0 & \text{Resto} \end{cases}$$

d(i, j) Distancia entre los individuos i y j.

σ_{share} Radio del nicho: determina la pertenencia o no al nicho.

α Regulador de la pendiente de la función de sharing.

Valores comúnmente utilizados (1) y (2).

La función f^ decrece en razón al número de elementos pertenecientes a su nicho contenidos en la población en un momento dado, sin embargo, crece en razón al valor de su función de evaluación. Cuando el nicho tiene un único cromosoma la función no se modifica ya que $Sh(d(i,i)) = 1$.*

AG Multimodales Temporales

■ Sequential (Nichos Secuenciales):

Proceso:

Consiste en la ejecución secuencial de AGs básicos de forma dependiente.

Con el primer AG se obtiene una solución, si su calidad está por encima de un umbral mínimo se guarda como solución del problema y se incrementa el contador de soluciones halladas.

Con esta solución, se modifica la adaptación de los individuos del siguiente AG, penalizando de esta forma las zonas ya exploradas en el AG anterior. Con esta nueva ejecución, se obtiene otra solución.

Para las siguientes ejecuciones se modificará la adaptación teniendo en cuenta todas las soluciones encontradas en pasos previos.

El proceso termina cuando tengamos las soluciones deseadas.

AG Multimodales Temporales

■ Sequential:

Formulación

$$f_n^*(x) = f_{n-1}^*(x) \times G(x, s_{n-1})$$

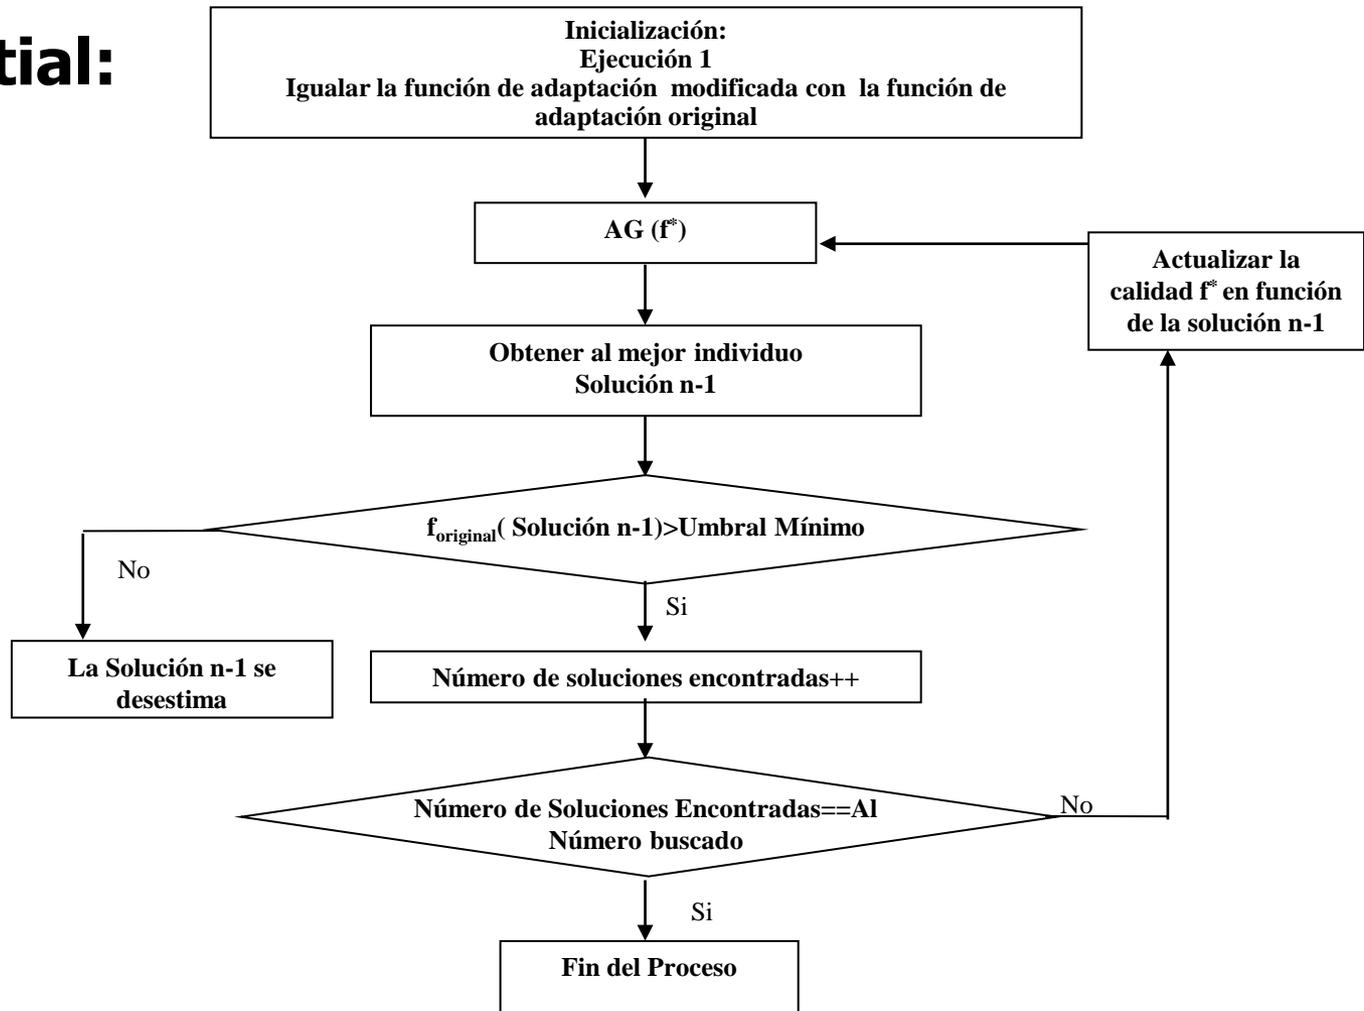
$$G(x, s_{n-1}) = \begin{cases} \left(\frac{d(x, s_{n-1})}{\sigma_{share}} \right)^\alpha & \text{Si } d(x, s_{n-1}) < \sigma_{share} \\ 1 & \text{Re sto} \end{cases}$$

Sn-1: Solución encontrada en la ejecución n-1

x: Individuo de la ejecución n

AG Multimodales Temporales

■ Sequential:



AGs Multimodales Espaciales

■ Clearing (Aclarado):

Proceso: La selección se realiza únicamente sobre los individuos dominantes de la población.

Antes del proceso de selección se clasifica la población según la adaptación de forma decreciente.

Se coge al primer individuo (el mejor) y de forma descendente se compara con el resto de la población. Aquellos individuos que están dentro de su radio de nicho (individuos dominados) son eliminados.

El proceso continua con el segundo individuo de la clasificación que aún no haya sido eliminado, y eliminará los individuos dominados por el.

El proceso terminará cuando

Clearing: Pérowski, A. (1996). Clearing procedure as a niching method for genetic algorithms. In *Proc. 1996 IEEE* tengamos los dominantes de cada nicho y con ellos se realizará la selección. *Int. Conf. Evolutionary Computation, Nagoya, Japan, 798-803.*

AGs Multimodales Espaciales

■ Clearing:

Proceso:

Ordenar P de mejor a peor

for i=0 to N-1

{

if (Fitness (P[i])>0)

{

NumGanadores=1

for j=i+1 to N-1

if (Fitness (P[j])>0) and (Distancia(P[i],P[j])< σ)

{

if (NumGanadores<Kappa)

NumGanadores ++

else

Fitness(P[j])=0

}

}

}

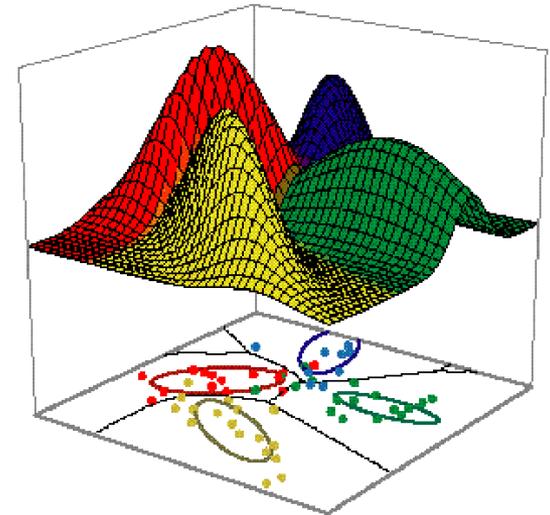
Parámetros:

σ Radio de nicho

Kappa Número de individuos que se mantienen por nicho (los mejores)

CONCLUSIONES

- El uso de AGs Multimodales permite obtener múltiples soluciones en una única ejecución manteniendo soluciones de diferentes partes del dominio.
- El uso de técnicas de nichos es una alternativa importante para evitar la convergencia en óptimos locales, así como una herramienta importante en el desarrollo de los algoritmos genéticos para problemas multiobjetivo.



BIOINFORMÁTICA

2013 - 2014

PARTE I. INTRODUCCIÓN

- Tema 1. Computación Basada en Modelos Naturales

PARTE II. MODELOS BASADOS EN ADAPTACIÓN SOCIAL (Swarm Intelligence)

- Tema 2. Introducción a los Modelos Basados en Adaptación Social
- Tema 3. Optimización Basada en Colonias de Hormigas
- Tema 4. Optimización Basada en Nubes de Partículas (Particle Swarm)

PARTE III. COMPUTACIÓN EVOLUTIVA

- Tema 5. Introducción a la Computación Evolutiva
- Tema 6. Algoritmos Genéticos I. Conceptos Básicos
- Tema 7. Algoritmos Genéticos II. Diversidad y Convergencia
- Tema 8. Algoritmos Genéticos III. Múltiples Soluciones en Problemas Multimodales
- Tema 9. Estrategias de Evolución y Programación Evolutiva
- Tema 10. Algoritmos Basados en Evolución Diferencial (Differential Evolution – DE)
- Tema 11. Modelos de Evolución Basados en Estimación de Distribuciones (EDA)
- Tema 12. Algoritmos Evolutivos para Problemas Multiobjetivo
- Tema 13. Programación Genética
- Tema 14. Modelos Evolutivos de Aprendizaje

PARTE IV. OTROS MODELOS DE COMPUTACIÓN BIOINSPIRADOS

- Tema 15. Sistemas Inmunológicos Artificiales
- Tema 16. Otros Modelos de Computación Natural/Bioinspirados