

Capítulo 3

Micro-Sistema inmune artificial

Puntualmente, el objetivo primordial de esta tesis fue diseñar e implementar un micro-sistema inmune artificial que solucione problemas de optimización. A este algoritmo se le denominó micro-SIA. Los algoritmos abstraídos de los modelos observados en la respuesta adaptativa del sistema inmune biológico son varios, no obstante el que se utilizó en esta tesis fue el del principio inmunológico de la selección clonal en donde se establece que los mejores anticuerpos, seleccionados de acuerdo a su afinidad, clonarán más y mutarán menos que los peores. Las etapas de clonación y mutación del SIA son procesos medulares en el funcionamiento del algoritmo, debido a que ante la ausencia de un operador de cruza, la proliferación de las mejores soluciones y la maduración de las mismas permiten un balance entre la exploración del espacio de búsqueda y la explotación de las soluciones más prometedoras. Considerando lo anteriormente expuesto, en este nuevo algoritmo se aportaron los mecanismos que permitieron reducir drásticamente el número de individuos en la población inicial del SIA sin afectar su desempeño.

3.1 Propuesta de solución

Realizando una revisión de los trabajos citados en el estado del arte, numeral 2.3 del capítulo anterior, es posible encontrar similitudes en el diseño de un algoritmo con un tamaño de población reducido:

1. Población inicial de 3 a 5 individuos. Ninguno de estos trabajos considera un crecimiento de la población en alguna etapa del algoritmo, como sucede con la clonación del SIA.
2. Se requiere de una convergencia nominal y de un proceso de reinicialización. La convergencia nominal se alcanza cuando se ha cumplido cierto número de iteraciones, generalmente predefinidas, funcionando como un ciclo interno en el micro-algoritmo. El proceso de reinicialización permite incorporar las mejores soluciones encontradas, una vez concluida la convergencia nominal, a la nueva población de trabajo que se ejecutará al incrementarse una iteración en el ciclo externo.
3. Es necesario considerar elitismo para preservar, al menos, al mejor individuo obtenido al término de la convergencia nominal.
4. Otro punto en común que comparten estas realizaciones es que el micro-algoritmo que se utiliza para optimización mono-objetivo puede adecuarse para manejar restricciones y para optimización con múltiples objetivos.

Considerando las similitudes anteriores, se propone un esquema general para diseñar (o adaptar en su caso) un algoritmo estándar a un modelo de micro población. Este esquema se muestra en la figura 3.1. Se puede apreciar que existen dos ciclos de funcionamiento: uno interno que se ejecutará mientras no se haya alcanzado la convergencia nominal y uno externo que se efectuará hasta que se alcance el criterio de paro general del algoritmo.

Todos los diferentes parámetros involucrados son importantes para el algoritmo, por ejemplo, Goldberg en [5] asevera que son tres los parámetros de control fundamentales de un algoritmo genético y que deben sintonizarse para garantizar su buen funcionamiento: la probabilidad de mutación, la probabilidad de cruce y el tamaño de la población inicial. En el SIA no hay operador de cruce, por lo que la mutación es uno de los parámetros más sensibles, especialmente si se reduce drásticamente el número de individuos de una población.

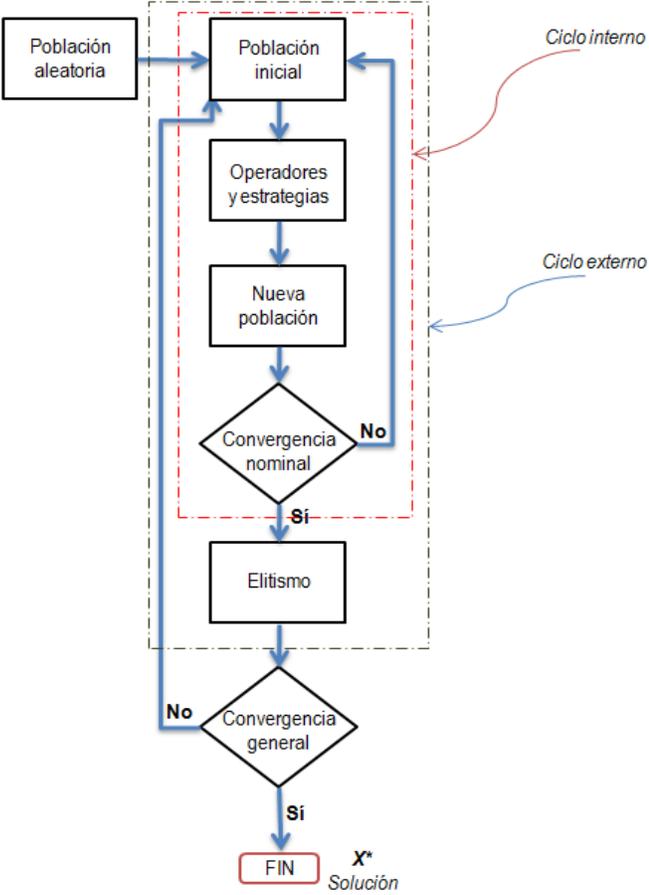


Figura 3.1. Esquema general de un micro algoritmo bioinspirado.

La metodología generalizada consta de 3 partes fundamentales:

1. *Definir el número de individuos de la población.* En dependencia a la complejidad del problema a resolver, será necesario realizar ajustes en el tamaño de la micro población. En la primera generación del algoritmo, los individuos de la población se obtienen de manera aleatoria, éstos se copian a la población inicial del ciclo interno del micro algoritmo (refiérase a la figura 3.1).

Durante el proceso de evolución, generación tras generación, la población se mantendrá con un número estático, es decir, el tamaño de la población no crece ni se disminuye de manera dinámica (en este modelo que no es particular de algún algoritmo), aunque se debe considerar la inclusión de individuos nuevos en cada

generación; éstos pudieran ser obtenidos aleatoriamente, o bien, pudieran ser tomados del conjunto de individuos evolucionados dentro del ciclo interno.

2. *Definir el criterio de la convergencia nominal y aplicar los operadores y estrategias del algoritmo bioinspirado en su versión estándar.* El criterio más utilizado para la convergencia nominal es definir un número de generaciones máximas a realizar. Al alcanzar la convergencia nominal es necesario un proceso de reinicialización para conformar una nueva población de trabajo inicial.

En el ciclo interno controlado por la convergencia nominal se utilizan los operadores y estrategias particulares definidas para el algoritmo bioinspirado en su versión estándar siendo posible implementarlo sin cambios o en otro caso realizar modificaciones que mejoren el desempeño del algoritmo con respecto a un problema en particular. Debido a que la calidad de las soluciones generadas al término de la convergencia nominal depende de los operadores y estrategias, el número de generaciones para alcanzar la convergencia nominal seguramente será diferente al cambiar de un algoritmo bioinspirado a otro.

3. *Aplicar elitismo para garantizar la convergencia.* Algunos de los individuos obtenidos al término de la convergencia nominal, generalmente los mejores o al menos el mejor en base a la aptitud, deben ser copiados a la población inicial que se completa con individuos generados aleatoriamente (para mantener la diversidad) y se incrementa una generación más en el ciclo externo hasta que se alcance la condición de paro general del algoritmo. Es significativo mencionar que depende mucho de la naturaleza de los algoritmos bioinspirados, con respecto a los operadores y estrategias internas, para determinar cuántos individuos deben ser copiados como parte del elitismo a la población inicial después, además de que éste garantiza la convergencia del micro algoritmo según lo comprobó Goldberg en [5].

3.2. Micro-Sistema Inmune Artificial para optimización sin manejo de restricciones

La propuesta presentada en este trabajo de tesis para la optimización mono-objetivo y sin manejo de restricciones se muestra en el diagrama de la figura 3.2. Está basada en el principio de selección clonal del SIA y toma algunos conceptos funcionales de CLONALG [24], aunque los operadores sensibles del algoritmo son totalmente diferentes.

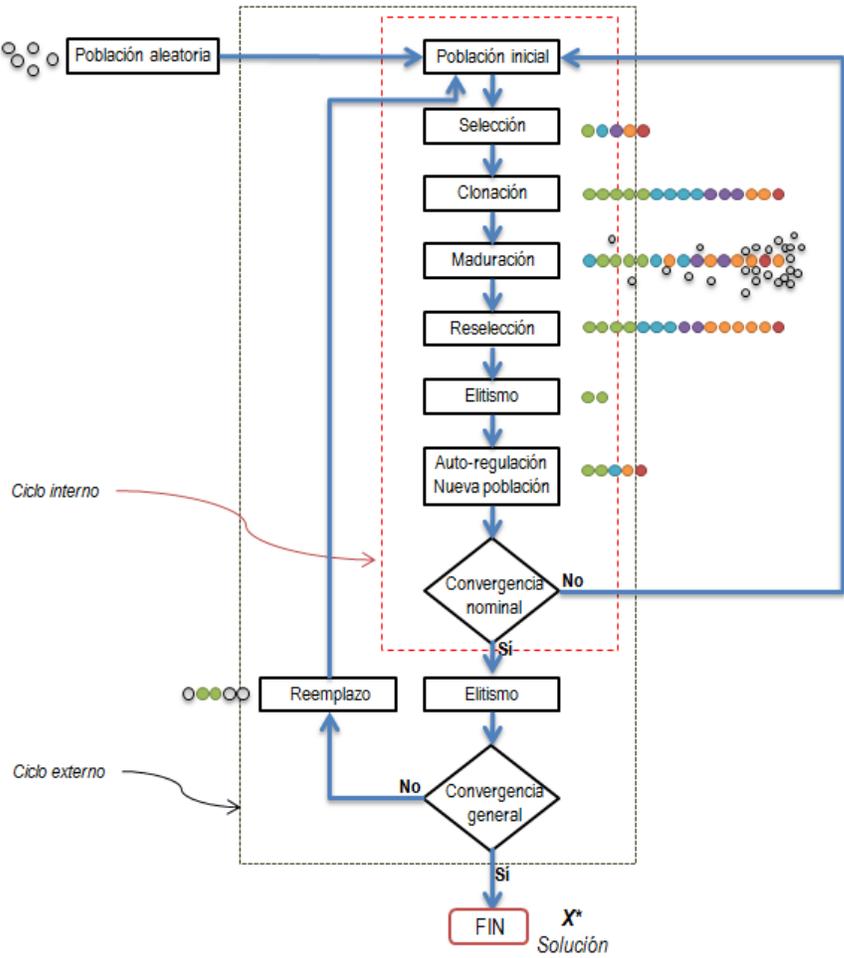


Figura 3.2. Micro – Sistema Inmune Artificial (micro-SIA) sin manejo de restricciones.

El algoritmo funciona de la siguiente manera:

1. *Generar aleatoriamente una población de 5 anticuerpos (individuos).* Al comienzo del algoritmo, para la primera generación, los 5 anticuerpos (Ab) generados aleatoriamente se copian directamente a la población inicial. Previamente se fijó que para alcanzar la convergencia nominal se realizaran 10 iteraciones (generaciones). Para alcanzar la convergencia general o criterio de paro del algoritmo, se utilizaron 1000 ó 2000 iteraciones (generaciones) de acuerdo a la función de prueba, tal y como se comentará en los resultados experimentales.

2. *Utilizar una selección basada en ranking.* Para ordenarlos con respecto a afinidad, cada uno de estos anticuerpos se evaluará en la función objetivo, que en la terminología del SIA es propiamente el antígeno (Ag). El anticuerpo de mayor afinidad será el mejor individuo, debido a que en la evaluación inicial es el que representa la mejor solución. En el micro-SIA a este individuo se le nombró *BestAb*.

3. *Realizar la clonación de todos los anticuerpos.* Para tal propósito se utiliza

$$N_c = \sum_{i=1}^n (n - (i - 1)) \quad (3.1)$$

en donde N_c es el número de clones que se generarán para cada anticuerpo, n es el número total de anticuerpos de la población, i es el anticuerpo corriente, comenzando con el de mayor afinidad (*BestAb*). Considerando una población de 5 anticuerpos se obtendrá una población con crecimiento controlado de 15 clones: el anticuerpo *BestAb* obtendrá 5 clones, el segundo anticuerpo del ranking clonará 4 veces, y así sucesivamente hasta llegar al peor anticuerpo que sólo obtendrá un clon.

4. *Realizar la maduración de los clones a través de un proceso de mutación.* La probabilidad de mutación se fijará al principio de la convergencia nominal para cada grupo de clones obtenidos del mismo anticuerpo. Esta probabilidad se determina de manera proporcional a la afinidad del anticuerpo que originó los clones y disminuirá en cada generación, así el grupo de clones del anticuerpo *BestAb* mutará menos que los demás grupos de clones que se generaron de los restantes anticuerpos. El único clon que se

obtuvo del peor anticuerpo tendrá la mayor posibilidad de mutar. Obsérvese la siguiente relación matemática

$$prob_mutation(i) = \frac{Aff(i)}{\sum_{i=1}^n Aff(i)} \quad (3.2)$$

en donde i es el anticuerpo que permitirá establecer la probabilidad de mutación para el grupo de clones que se obtuvieron de él mismo y n es el total de anticuerpos de la población.

Para disminuir uniformemente la probabilidad de mutación en cada generación dentro de la convergencia nominal se utiliza la siguiente ecuación:

$$if\ prob \leq \frac{prob_mutation(i)}{generation} \text{ then apply mutation} \quad (3.3)$$

en donde $random\ prob \in [0,1]$ y $generation$ es la generación corriente dentro de la convergencia nominal, es decir, $int\ generation \in [1,10]$ y no se desea dividir entre 0.

Para la variación que afecta los clones, se diseñaron dos operadores sencillos y que permiten explotar mayormente el espacio de búsqueda al realizar diferentes tamaños de paso en el proceso de mutación. Varios aspectos fueron considerados para implementar estos operadores: el número de clones, la generación corriente dentro de la convergencia nominal y el rango permisible de valores de las variables de decisión. La aplicación de estos operadores de mutación se realiza con una probabilidad de 0.5 sobre cada variable de decisión de un clon (en el micro-SIA, todo el vector de soluciones es mutado):

$$x' = x + \frac{(\alpha \cdot range \cdot generation)}{N_C} \quad (3.4)$$

o bien,

$$x' = x + \frac{(\alpha \cdot range)}{(generation \cdot N_C)} \quad (3.5)$$

donde x' es la variable de decisión mutada, x es la variable de decisión a mutar, α es un número aleatorio con distribución uniforme donde $random\ \alpha \in [0,1]$, $generation$ es la generación corriente dentro de la convergencia nominal y Nc es el número total de clones. El valor de α se debe computar para cada variable de decisión del clon.

En el caso de los 5 clones obtenidos de $BestAb$, $range \in [LB, UB]$ es un número aleatorio entre el límite inferior (LB) y el límite superior (UB) de los valores que pueden tomar las variables de decisión y se mantiene constante para toda la dimensión del clon a mutar, es decir, $range$ será el mismo para todas las variables de decisión del clon. Para los restantes clones que se obtuvieron de los 4 anticuerpos del ranking, $range$ es cualquier variable de decisión del anticuerpo $BestAb$, cuya posición dentro de la dimensión del vector se obtiene aleatoriamente.

5. *Efectuar nuevamente una selección basada en ranking.* Los 15 clones se ordenan utilizando ranking con respecto a su afinidad evaluando a cada uno de éstos en el antígeno (Ag), siendo el mejor clon el que tenga la mayor afinidad. Si aún no se ha alcanzado la convergencia nominal, los dos mejores clones se seleccionarán (elitismo) y la nueva población se completará con otros 3 clones seleccionados aleatoriamente de la población de clones maduros. Los restantes clones se eliminarán, proveyendo una auto-regulación dentro de la convergencia nominal, manteniendo una población de trabajo de 5 anticuerpos (Ab). La nueva población será ahora la población inicial y el algoritmo repetirá sus pasos hasta concluir las 10 iteraciones de la convergencia nominal que a su vez representan el ciclo interno del micro-SIA.

6. *Reinicialización del algoritmo.* Si se alcanzó la convergencia nominal, se mantendrán los dos mejores clones madurados y se generarán otros tres anticuerpos de manera aleatoria (*reemplazo*) para completar la población inicial y reiniciar la convergencia nominal hasta que el ciclo externo del algoritmo cumple con la condición de parada general.

3.2.1 Primera fase de experimentación

El análisis y comparación de algoritmos bioinspirados debe realizarse considerando cuáles son las propiedades que se buscan. No es posible mejorar todas las propiedades al mismo tiempo, ya que por lo general están relacionadas entre sí y puede ocurrir que la mejora de una provoque que otra se vea afectada. De todas las posibles propiedades que pudiera presentar un algoritmo bioinspirado, generalmente se buscan las cuantificables: eficiencia, efectividad, eficacia y robustez.

La eficiencia se mide en términos de la cantidad de recursos empleados, es decir, el costo computacional. La eficacia se define como la probabilidad de alcanzar una solución óptima. La efectividad representa la calidad de las soluciones entregadas por el algoritmo. Por último, la robustez es la variabilidad del comportamiento de un algoritmo dado, es decir, qué tan estable es para resolver un problema y qué tan sensible es al momento de variar sus parámetros.

Los operadores de mutación diseñados para el micro-SIA tienen características de uniformidad y permiten pasos pequeños y grandes. Al aplicar el operador de la ecuación 3.5 la variación será mayor que cuando se aplica el operador de la ecuación 3.6. Estos operadores aceleran la convergencia y permiten una mayor exploración del espacio de búsqueda, así como una explotación de las soluciones prometedoras.

Las primeras aproximaciones probadas en el micro-SIA utilizaban el único operador de mutación no uniforme propuesto por Nunes de Castro *et al* en [24], sin embargo para el algoritmo con población reducida no entregó buenos resultados debido a que no converge al óptimo aún aumentando el número de individuos hasta 10.

Para la primera experimentación y con respecto al micro-SIA sin manejo de restricciones, se utilizaron las funciones citadas en [32]. Se trata de funciones con múltiples variables (dimensión 30) y óptimo en cero, a excepción de $f08$. Se recomienda referirse al anexo A para revisar estas funciones. La elección de este test de prueba se debió a que las funciones abordadas en [32] se resuelven utilizando el algoritmo de evolución diferencial lo que presupone que las funciones son complejas y a la vez ejemplifican un referente actual de experimentación.

En la tabla 3.1 se reportan los resultados obtenidos experimentalmente para esta primera fase. Se listan los resultados de 20 corridas para cada función. Para todos los casos se utilizó una población fija de 5 anticuerpos y 10 generaciones para alcanzar la convergencia nominal, así como una representación real. Para realizar estas pruebas se utilizó una PC con procesador *Quad Core* a 2.66 MHz, con 2MB de memoria. La intención de este experimento fue probar estadísticamente la convergencia del micro-SIA al óptimo conocido.

Tabla 3.1. Resultados experimentales del micro-SIA para problemas de optimización sin restricciones.

Función	Ciclo externo	Generaciones de la convergencia nominal	Óptimo conocido	Mejor solución Micro-SIA	Peor solución Micro-SIA	Media Micro-SIA
<i>f01</i>	1000	10	0.0	0.0	0.000022	0.000009
<i>f02</i>	1000	10	0.0	0.0	0.000017	0.000008
<i>f03</i>	1000	10	0.0	0.0	0.000002	0.000001
<i>f04</i>	1000	10	0.0	0.0	0.000012	0.000005
<i>f05</i>	1000	10	0.0	0.0	0.000028	0.000012
<i>f06</i>	2000	10	0.0	0.0	0.000032	0.000015
<i>f07</i>	2000	10	0.0	0.0	0.000027	0.000013
<i>f08</i>	2000	10	-12596.5	-12569.5	-12569.57	-12569.496
<i>f09</i>	2000	10	0.0	0.0	0.000033	0.000013
<i>f10</i>	2000	10	0.0	0.0	0.000011	0.000007
<i>f11</i>	2000	10	0.0	0.0	0.000013	0.000004

En la tabla 3.1, la columna *Ciclo externo* se refiere al número de generaciones que se fijaron para alcanzar la convergencia general del micro-SIA, que a su vez es la condición de paro del mismo. La columna *Generaciones de la convergencia nominal* presenta el número de generaciones del ciclo interno del micro-SIA que se fijaron para alcanzar esta convergencia limitada. La columna *Óptimo conocido* es la mejor solución documentada en [32]. Se observa que en todas las funciones utilizadas se convergió al óptimo. La medida del error promedio es mínima en todos los casos. Obsérvese que para las funciones *f06*, *f07*, *f08*, *f09*, *f10* y *f11* fue necesario aumentar el número de generaciones en el ciclo externo para converger al óptimo.

En la figura 3.3 se estima el comportamiento del micro-SIA resolviendo solamente $f01$ en 5 corridas diferentes; se hizo de esta manera para facilitar la legibilidad de la gráfica. En el eje de las abscisas se asentaron las 1000 generaciones del ciclo externo.

Recordando que el óptimo conocido es 0.0, se puede apreciar cómo el algoritmo al principio realiza pasos grandes y posteriormente se realiza una búsqueda más exhaustiva con pasos más reducidos. El comportamiento reflejado es el esperado considerando que los operadores de mutación se diseñaron para cumplir con este propósito. En esta tesis se maneja el término *aptitud* y *afinidad* de manera equivalente para las figuras gráficas, recordando que en la terminología del SIA propiamente debe utilizarse *afinidad*.

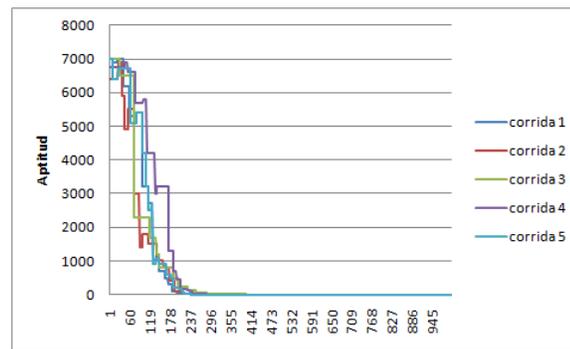


Figura 3.3. Comportamiento del micro-SIA con 5 corridas diferentes para $f01$.

En la figura 3.4 se detalla cómo el micro-SIA se aproxima al óptimo de $f01$ en las últimas 100 generaciones de una corrida. Al paso de las generaciones, la probabilidad de mutación disminuye de acuerdo a la ecuación 3.2, por lo que en la figura 3.4 se aprecia que la aptitud (se trata de un problema de minimización para el caso de $f01$) tiende hacia el óptimo particular (0.0) y ya no efectúa cambios abruptos que obliguen al micro-SIA a explorar nuevamente el espacio de búsqueda, más bien, se explotan las mejores soluciones al acercarse a la condición de paro del algoritmo. El comportamiento anterior es muy conveniente para escapar de los óptimos locales.

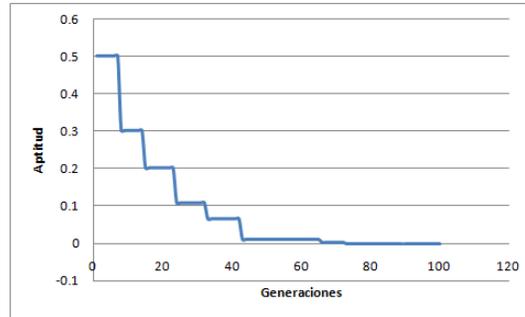


Figura 3.4. Detalle del funcionamiento del micro-SIA en las últimas 100 generaciones de una corrida para resolver $f01$.

Con respecto al comportamiento del micro-SIA durante las 10 generaciones establecidas para alcanzar la convergencia nominal, en la figura 3.5 se muestran 5 corridas diferentes para resolver $f01$. Esta figura sólo hace referencia a la primera convergencia nominal del algoritmo. Se observan las variaciones grandes debido a que la probabilidad de mutación es alta, de acuerdo a la ecuación 3.2, cuando inicia el algoritmo.

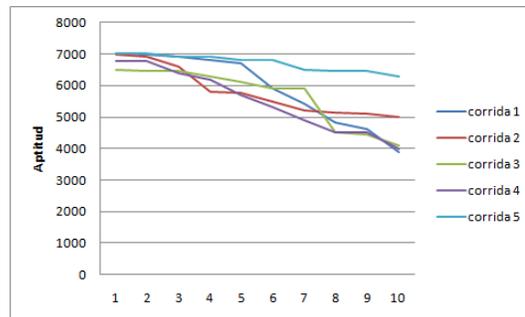


Figura 3.5. Primera convergencia nominal del micro-SIA con 5 corridas diferentes para resolver $f01$.

En las 5 corridas presentadas en la gráfica, se observa que no existe la posibilidad de un error de convergencia prematura, dado que en las pruebas realizadas se obtuvieron en todos los casos individuos diferentes. Este apartado es muy importante debido a que se aprecia que se mantiene la diversidad de los individuos y no se propicia un estancamiento de la búsqueda. Aún obteniendo individuos idénticos o muy parecidos al término de la convergencia nominal, el ruido estocástico generado antes de conformar la nueva población ayuda al algoritmo a escapar de una convergencia prematura. Una diversidad muy amplia, es decir, que los individuos varíen su

información en gran medida, también representa una problemática que obligaría a la búsqueda a quedarse en un óptimo local. Con este experimento se observa que la diversidad propiciada en el micro-SIA mantiene un balance correcto entre la exploración y la explotación. En la figura 3.6 se muestran los diferentes comportamientos del micro-SIA para resolver $f01$, $f02$, $f05$, $f06$, $f09$, $f10$ y $f11$, en una sola corrida.

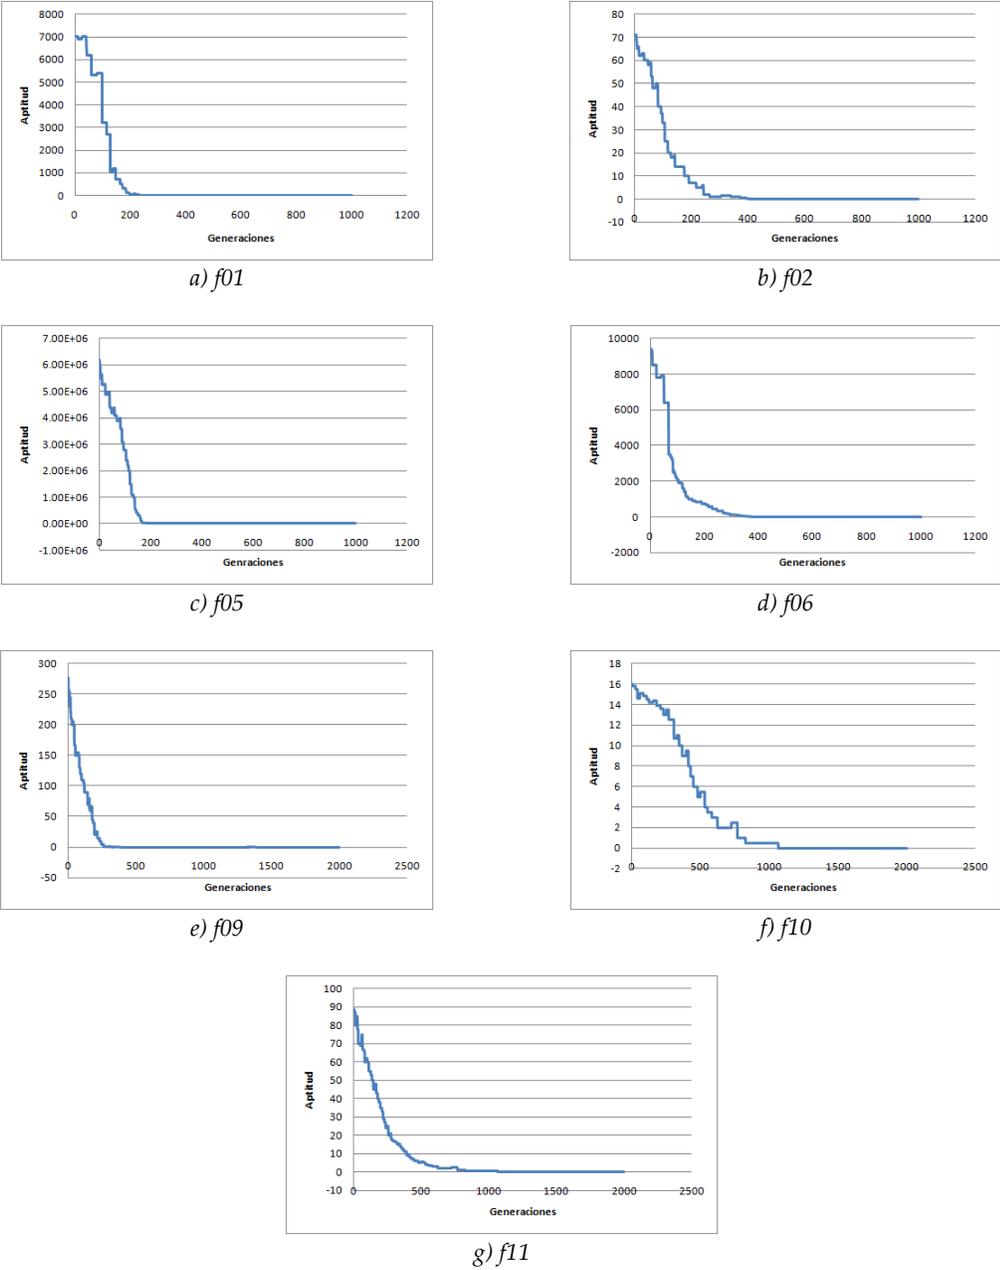


Figura 3.6. Comportamiento del micro-SIA para resolver $f01$, $f02$, $f05$, $f06$, $f09$, $f10$ y $f11$.

3.2.2 Segunda fase de experimentación

Para la segunda fase de los experimentos, se procedió a realizar una comparación entre el SIA en su versión estándar (CLONALG) y el micro-SIA. Sólo se utilizaron tres funciones del test de prueba del numeral 3.2.1. Para esta comparación se ejecutaron ambos algoritmos en la misma PC de los experimentos anteriores, ésta tiene un procesador *Quad Core* a 2.66 MHz y 2MB de memoria. La intención de este experimento fue revisar el número de evaluaciones a la función objetivo y el tiempo de ejecución del algoritmo para converger al óptimo. En la tabla 3.2 se listan los resultados experimentales obtenidos en esta fase.

Tabla 3.2. Resultados experimentales de la comparación entre CLONALG y el micro-SIA, ambos casos sin manejo de restricciones.

	<i>Ab</i>	<i>Clones</i>	<i>Generaciones de la convergencia nominal</i>	<i>Ciclo externo</i>	<i>Evaluaciones a la función objetivo</i>	<i>Tiempo (segundos)</i>
CLONALG						
<i>f01</i>	50	256	N/A	1000	1,280,000	47.2
<i>f05</i>	70	312	N/A	1000	21,840,000	78.6
<i>f07</i>	70	312	N/A	1200	26,208,000	103.7
Micro-SIA						
<i>f01</i>	5	15	10	1000	750,000	14.8
<i>f05</i>	5	15	10	1000	750,000	14.2
<i>f07</i>	5	15	10	2000	1,500,000	48.3

Nótese en la tabla 3.2, que el número de anticuerpos (individuos) en la población inicial del algoritmo en su versión estándar para *f01* es de 50, mientras que para el micro-SIA en la misma función se utilizan sólo 5 individuos. Así mismo, en la etapa de clonación, para *f01* en la versión estándar la población crece hasta 256 clones, mientras que en el micro-SIA se tiene un crecimiento controlado de 15 clones. Con lo anterior, el uso de la memoria de datos en el micro-SIA se reduce al 5.85% de la utilizada por la versión estándar de CLONALG. Para el caso de *f05* y *f07*, el micro-SIA utiliza el 4.80% de los 312 clones generados en la etapa de clonación.

Con respecto al número de evaluaciones a la función objetivo, comparando los resultados, es evidente que el micro-SIA realiza menos evaluaciones para alcanzar el óptimo. Nótese que si se aumenta el ciclo externo del micro-algoritmo también crece el número de evaluaciones a la función objetivo. Considerando $f07$, el micro-SIA ejecuta 1, 500,000 evaluaciones a la función objetivo y en contraparte CLONALG verifica 26, 208,000 evaluaciones, lo que representa un menor coste computacional para la versión con micro-población. En este mismo sentido, el tiempo de ejecución del micro-SIA es también menor en tres casos reportados.

3.2.3 Tercera fase de experimentación

Esta etapa experimental de la tesis consistió en modificar el número de anticuerpos (Ab) en la población inicial. De acuerdo a la ecuación 3.1, si se varía el número de individuos iniciales, implícitamente se modificará también el número de clones a generar. El objetivo de este experimento fue observar el comportamiento del micro-SIA ante diferentes tamaños de micro-población.

Se utilizaron sólo las tres funciones del test de prueba del numeral 3.2.2: $f01$, $f05$ y $f07$. Para reportar estos resultados se mantuvo en 10 el número de generaciones para alcanzar la convergencia nominal; para alcanzar la convergencia general, en el ciclo externo del micro-SIA, se utilizaron 1000 generaciones para $f01$ y $f05$, así como 2000 para $f07$, tal y como se hizo en la primera etapa de experimentación. Se decidió fijar estos valores para las generaciones debido a que en los experimentos anteriores se obtuvieron los mejores resultados cuando éstos se utilizaron.

En la tabla 3.3 se aprecian los resultados obtenidos al finalizar este experimento. Se realizaron 20 corridas del micro-SIA y se reportan solamente los mejores y los peores resultados para las funciones citadas.

Tabla 3.3. Resultados experimentales al variar el tamaño de la micro-población del micro-SIA.

Ab	Clones	Mejor f01	Peor f01	Media f01	Mejor f05	Peor f05	Media f05	Mejor f07	Peor f07	Media f07
3	6	1.782333	24.301121	4.001221	1.478011	4.899233	2.345671	0.834078	2.665235	2.006686
4	10	0.0	0.0830000	0.0456682	0.000012	0.932121	0.0202242	0.000044	0.000421	0.000256
5	15	0.0	0.0000022	0.0000008	0.0	0.000028	0.0000011	0.0	0.000027	0.0000010
6	21	0.006789	1.004601	0.0780502	0.000333	1.004902	0.000567	0.003021	2.301202	0.009786
7	28	0.820006	8.023331	3.029821	0.670012	4.023210	2.147681	1.003415	2.550015	1.700494
10	55	2.893011	30.900189	14.221124	2.453312	18.788210	10.331881	1.899301	23.871131	9.111244

Se distingue que con una población de 5 anticuerpos y 15 clones, se convergió al óptimo en los tres casos. Las peores soluciones en las tres funciones utilizadas no son muy diferentes en valor cuando se comparan con las mejores, considerando la micro-población de 5 anticuerpos. Cuando se utilizan 4 ó 6 anticuerpos se obtienen buenas soluciones, siendo mejor utilizar 4 anticuerpos en vez de 6, por lo menos para las funciones utilizadas en este experimento. La media obtenida de las 20 corridas para cada función muestra que las mejores soluciones se obtuvieron con 5, 4 y 6 anticuerpos, respectivamente. Cuando se creció la población inicial a 7 y 10 anticuerpos, el micro-SIA no obtiene buenas soluciones. Cuando la población inicial es de sólo 3 anticuerpos, tampoco se convergió al óptimo conocido, sin embargo las soluciones encontradas no son tan malas como las que se lograron con 7 y 10 anticuerpos.

Es notorio que cuando se trabaja con muy pocos anticuerpos, durante el ciclo interno del micro-SIA la población tienen muy poca variabilidad entre individuos, por lo que la búsqueda se detiene antes de llegar al óptimo. Los clones generados bajo este esquema son muy pocos, y aún aplicándoles la mutación, no se logra un funcionamiento adecuado del algoritmo. En contraparte, cuando se utilizan más individuos en la población de trabajo, propiciando un aumento considerable en la población de clones, en la convergencia nominal se obtienen soluciones muy variadas y la búsqueda se estanca en la parte final del algoritmo. Esto se debe principalmente a que aún conservando a las mejores soluciones a través del elitismo, la mutabilidad no permite tener elementos representativos que guíen la búsqueda.

En la figura 3.7 se presentan las tres gráficas correspondientes a este experimento. Se muestran las corridas con 3, 4, 5, 6, 7 y 10 anticuerpos para f01, f05 y f07.

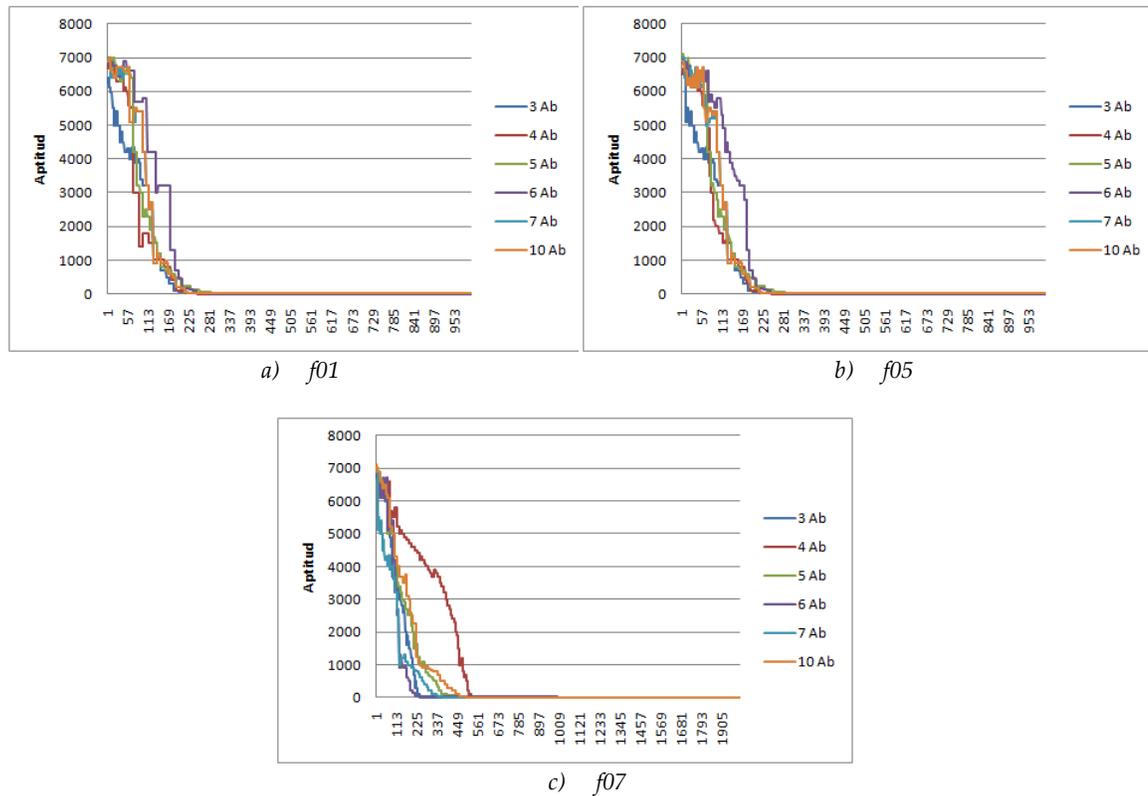


Figura 3.7. Comportamiento del micro-SIA ante diferentes tamaños de micro-población.

3.3 Micro-Sistema Inmune Artificial para optimización con manejo de restricciones

Debido a que los problemas de optimización en la vida real contienen restricciones de diferente índole, en este último experimento se decidió incluir una aproximación al manejo de restricciones para saber cómo se comporta el micro-SIA ante esta situación. Para que el algoritmo cumpliera con esta

encomienda, fue necesario incorporar un mecanismo que permitió el manejo de restricciones de igualdad, desigualdad, lineales y no lineales.

Existen mecanismos estudiados y probados, principalmente en algoritmos genéticos y estrategias evolutivas, que soportan el manejo de restricciones [31]. El más simple de estos mecanismos es el denominado *pena de muerte* que consiste en rechazar a todos los individuos infactibles, es decir, se le asignará una aptitud de cero a un individuo que no sea factible y se asignará el valor de la función de aptitud al que sí lo sea. Esta técnica es muy sencilla de implementar, no obstante la búsqueda se estanca cuando las regiones factibles del problema a optimizar son muy pequeñas o si la población inicial no tiene ningún individuo factible.

Para el manejo de espacios restringidos en el micro-SIA se utilizaron dos parámetros para seleccionar a los mejores individuos: la afinidad con respecto a la función objetivo y la cantidad de restricciones violadas. Esta metodología fue propuesta por Deb en [31]. La adecuación para el micro-algoritmo aquí propuesto sólo considera en la etapa del primer ranking (refiérase al numeral 3.2), en el ciclo de la convergencia nominal, seleccionar al mejor individuo bajo las siguientes características: como primera opción se buscará al anticuerpo factible sobre el infactible; si fuera el caso que hubiera varios factibles, seleccionar al de la mayor afinidad. Para los infactibles, se seleccionará al que tenga el menor número de restricciones violadas y mayor afinidad.

Una vez realizada la selección inicial de anticuerpos (refiérase al paso 2 del algoritmo explicado en el subtema anterior), utilizamos los mismos criterios para la segunda selección después de haber realizado la mutación de los clones (refiérase al paso 5 del mismo algoritmo).

$$fitness_i(x) = \begin{cases} f_i(x) & \text{si la solución es factible} \\ f_{peor} + \sum_{j=1}^n g_j(x) & \text{de lo contrario} \end{cases} \quad (3.6)$$

donde f_{peor} es el valor de la función objetivo de la peor solución factible de la población. Si no hay ninguna solución factible en la población, entonces f_{peor} se hace igual a cero.

3.3.1 Cuarta fase de experimentación

Se probaron dos funciones: $g01$ y $g02$, presentadas en [33]. En el anexo B de este documento de tesis es posible revisar estas funciones. En la tabla 3.4 se resumen las características de las dos funciones de prueba citadas. La función $g01$ tiene 13 variables y la función $g02$ tiene 20 variables. El óptimo global para $g01$ es -15.0. Para $g02$ el mejor óptimo global encontrado (el óptimo es desconocido) es -0.803619. En esta misma tabla, n es el número de variables de decisión, ρ el porcentaje de individuos factibles encontrados entre un millón de individuos generados aleatoriamente, DL es el número de desigualdades lineales, DNL es el número de desigualdades no lineales, IL es el número de igualdades lineales y, por último, la etiqueta INL representa el número de igualdades no lineales.

Tabla 3.4. Características de las dos funciones de prueba con manejo de restricciones.

Función	n	Tipo de función	Óptimo conocido	ρ	DL	DNL	IL	INL
$g01$	13	Cuadrática	-15.0	0.0111%	9	0	0	0
$g02$	20	No lineal	-0.803619	99.8477%	1	1	0	0

Revisando ρ en esta tabla, la función $g01$ presenta una zona factible muy pequeña, es decir, encontrar individuos que cumplan todas las restricciones es complicado para este problema de minimización. Por el contrario, $g02$ tiene una zona factible muy amplia, sin embargo llegar al óptimo conocido resulta difícil debido a que este problema de maximización tiene un gran número de óptimos locales.

En la tabla 3.5 se muestran los resultados de 20 corridas para cada función, utilizando el micro-SIA.

Tabla 3.5. Resultados experimentales del micro-SIA para problemas de optimización con restricciones.

Función	Ciclo Externo	Generaciones de la convergencia nominal	Óptimo conocido	Mejor micro-SIA	Peor micro-SIA	Media micro-SIA	Error (considerando el mejor resultado)
<i>g01</i>	2000	10	-15.0	-15.0	-14.978	-14.989	0.0
<i>g02</i>	2000	10	-0.803619	-0.804090	-0.83023	-0.81025	0.000471

El algoritmo diseñado tiene un desempeño satisfactorio para ambos casos. Para el caso particular de *g01*, el micro-SIA sí obtiene el óptimo global conocido. Con respecto a *g02*, el micro-SIA se aproxima en gran medida al óptimo conocido aunque prevalece un error mínimo. En las figuras 3.8 y 3.9 se muestran las gráficas de convergencia al óptimo global del micro-SIA para *g01* y *g02*, respectivamente.

Ambas gráficas comienzan cuando se encuentra el primer individuo factible. Puede apreciarse que la convergencia en ambos casos es rápida. El micro-SIA logró escapar correctamente de los óptimos locales que tiene *g02*, lo anterior se debe a que los operadores de mutación diseñados, así como el elitismo utilizado, permiten un balance correcto entre la exploración del espacio de búsqueda y la explotación de las soluciones potenciales.

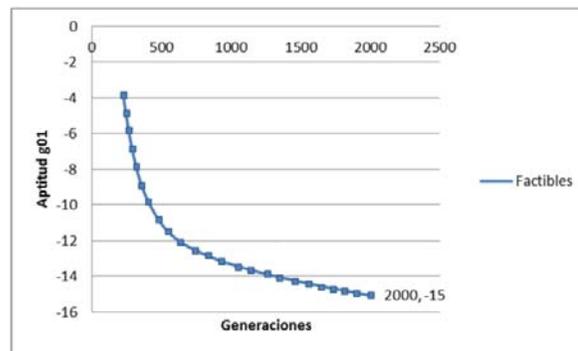


Figura 3.8. Convergencia al óptimo global del micro-SIA para *g01*.

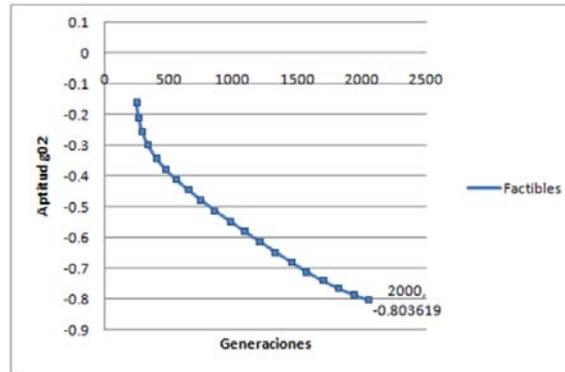


Figura 3.9. Convergencia al óptimo global del micro-SIA para g02.

En las figuras 3.10 y 3.11 se presentan las aproximaciones a la densidad de individuos factibles e infactibles encontrados por el micro-SIA, para g01 y g02, al paso de las generaciones. Estas gráficas se diseñaron para reportar los individuos encontrados cada 50 generaciones.

Es visible que en el caso de g01 son pocos los individuos factibles encontrados, sin embargo, a partir de que se encuentra el primero de éstos, la proliferación de buenas soluciones se mantiene, demostrando que el criterio utilizado para el manejo de restricciones funciona adecuadamente. Como se esperaba, de acuerdo a las características expuestas en la tabla 3.4, g02 tiene una zona factible amplia por lo que desde el principio fue posible encontrar individuos que cumplen todas las restricciones.

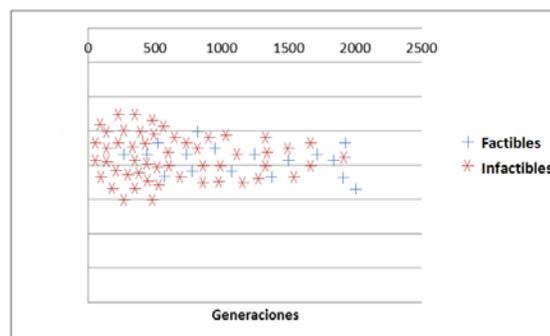


Figura 3.10. Individuos factibles e infactibles encontrados por el micro-SIA para g01.

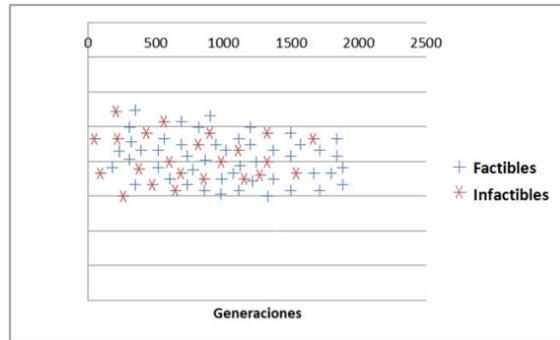


Figura 3.11. Individuos factibles e infactibles encontrados por el micro-SIA para g02.