UNIVERSIDAD DE PANAMÁ

VICERRECTORÍA DE INVESTIGACIÓN Y POSTGRADO

PROGRAMA DE MAESTRÍA EN MATEMÁTICA

ESTUDIO COMPARATIVO DE LA APLICACIÓN DEL MÉTODO ALGORITMO GENÉTICO, EL MÉTODO NUMÉRICO DEL GRADIENTE Y UNA ESTRATEGIA HÍBRIDA EN LA OPTIMIZACIÓN DE FUNCIONES LINEALES MULTIMODALES.

RAFAEL SALADO NATERA

N-22-2149

TESIS PRESENTADA COMO UNO DE LOS REQUISITOS PARA OPTAR AL TÍTULO DE MAESTRÍA EN MATEMÁTICA CON OPCIÓN EN INVESTIGACIÓN DE OPERACIONES

PANAMÁ, REPÚBLICA DE PANAMÁ

2025

DEDICATORIA

"Para mí, una ecuación no tiene sentido a menos que exprese un pensamiento de Dios"

Srinivasa Ramanujan

Esta tesis de maestría está dedicada a mi padre, a mi madre y por orden de llegada a Paula, Jaime, Sofía, Tito y Nicolás.

También quiero dedicar este trabajo a mi hermano José Manuel, característico él donde los haya.

A mi tío Emilio, querido y admirado, que sería capaz de cambiar los números por notas musicales.

Agradecer a la Dra. Iris Jiménez su amabilidad a la hora de dirigir este trabajo.

Acordarme también de mis compañeros de la maestría. Algunos de ellos fueron profesores míos en la licenciatura y quedaron siendo mis amigos.

Muestro mi gratitud a la profesora María Paz, a la Dra. Manuela y al Dr. Garrido por haberme acompañado como profesores.

Índice

1. Introducción

1.1. Contexto y relevancia del problema de optimización.

La optimización juega un papel importante en disciplinas como la inteligencia artificial, la investigación operativa, la economía y la ingeniería. En estos campos, se aplica con el objetivo de mejorar el rendimiento de sistemas, reducir costos, aumentar la eficiencia y facilitar la toma de decisiones.

Sin embargo, muchos de los problemas de optimización en la práctica no son lineales y suelen presentar múltiples óptimos locales. Esta característica complica la búsqueda de la mejor solución posible, lo que hace aún más necesario el desarrollo y análisis de métodos capaces de afrontar estos desafíos con eficacia.

En este estudio se desarrollan y comparan diferentes métodos de optimización para determinar cuál es el más adecuado para un problema específico a optimizar. Se contrastan el método del gradiente (MG), eficiente en problemas convexos pero vulnerable a óptimos locales y el algoritmo genético (AG), robusto en espacios multimodales, pero computacionalmente costoso, proponiendo un algoritmo híbrido (AH) que combina la exploración global del AG con la exploración local del MG. **Yao, Liu, y Lin (1999)** en su trabajo "*Evolutionary Programming Made Faster*", establecen que la combinación de metaheurísticas (como los Algoritmos Genéticos) con métodos de búsqueda local (como el Método del Gradiente) puede superar las limitaciones individuales de cada técnica.

El algoritmo híbrido propuesto (AH) y siguiendo la línea de investigaciones híbridas pioneras, como las de **Goldberg (1989)** en "*Genetic Algorithms in Search, Optimization, and Machine Learning*", combina las fortalezas de ambos métodos: utiliza el algoritmo genético en una fase inicial para explorar globalmente el espacio de soluciones, seguido de una fase de refinamiento con el método del gradiente para converger rápidamente hacia una solución más precisa.

Estos métodos son aplicados a un conjunto variado de funciones de prueba, similar a los benchmarks utilizados por **Jamil y Yang (2013)** en su compendio de funciones de prueba para optimización global, que incluyen a las funciones Ackley, Bohachevsky, Bukin, cuadrática, gaussiana, Griewank, McCormick, Rastrigin, Rosenbrock y una función aleatoria no lineal, cada una con características particulares que permiten analizar los diferentes aspectos de los algoritmos.

En este trabajo se eligió MATLAB para las pruebas de los algoritmos, principalmente por su eficiencia en cálculos numéricos, sus completas herramientas de optimización y su capacidad para trabajar con matrices.

1.2. Objetivos

1.2.1. Objetivo General

El objetivo principal de esta tesis es comparar el rendimiento del método del gradiente, el algoritmo genético y una propuesta híbrida que combina ambos, aplicándolos a problemas de optimización no lineales y multimodales.

Este trabajo también busca ofrecer recomendaciones prácticas para su uso en situaciones reales, donde elegir correctamente el método de optimización objeto de estudio en esta tesis puede marcar la diferencia en los resultados. Por lo tanto, se espera aportar una visión clara sobre las fortalezas y debilidades de cada método y facilitar su aplicación en problemas concretos de ingeniería y ciencia.

Hipótesis planteada

Se parte de la hipótesis de que el algoritmo híbrido (AH) será capaz de integrar el MG y el AG, disminuyendo así la probabilidad de quedar atrapado en óptimos locales y obtener óptimos más cercanos al teórico.

1.2.2. Objetivos específicos

- Analizar los fundamentos teóricos, las ventajas y limitaciones del método del gradiente, el algoritmo genético y el enfoque híbrido, poniendo especial atención en su utilidad frente a distintos tipos de problemas de optimización.

- Implementar los métodos en MATLAB utilizando sus herramientas y aplicándolas a funciones objetivo de diferente naturaleza: convexas, no convexas y con múltiples óptimos locales.
- Evaluar y comparar el rendimiento de tres métodos analizando aspectos como el tiempo de convergencia, la precisión de las soluciones y su robustez. Para ello, se realizarán múltiples ejecuciones de cada algoritmo, con el fin de asegurar la consistencia de los resultados.

- Presentar las condiciones en las que cada método ofrece su mejor rendimiento a la solución de problemas de optimización a través de un análisis estadístico.

- Explorar posibles mejoras en el método híbrido, como el ajuste de parámetros, y la exploración de técnicas de inicialización.

1.3. Justificación.

Esta investigación surge de la necesidad de encontrar soluciones de funciones complejas al comparar el rendimiento de distintos métodos de optimización, como el método del gradiente y el algoritmo genético. También se considera interesante explorar un enfoque híbrido que busque aprovechar lo mejor de ambos.

Dado que estos algoritmos se aplican frecuentemente en problemas complejos de ingeniería y otras áreas, es importante conocer no solo sus fortalezas, sino también sus limitaciones. Al revisar la literatura, se observa una falta de estudios que los comparen de forma directa o que

analicen a fondo el potencial de su combinación. En este sentido, el presente trabajo pretende contribuir al desarrollo de soluciones más eficaces en el ámbito de la optimización.

1.4. Alcances y limitaciones.

Como se ha comentado en párrafos anteriores nuestro estudio compara el rendimiento del método del gradiente, el algoritmo genético y un enfoque híbrido aplicado a problemas de optimización de distinta complejidad.

Es importante tener en cuenta algunas limitaciones. Por un lado, los resultados pueden variar dependiendo del tipo de problema específico que se aborde, lo que puede influir en la efectividad de cada método. Por otro, el enfoque híbrido requiere un ajuste cuidadoso de sus parámetros, lo que puede afectar su desempeño si no se configura adecuadamente.

Esta investigación no busca abarcar todas las variantes existentes de estos métodos, sino aquellas versiones que son más representativas y ampliamente utilizadas en la literatura actual.

1.5. Estructura de la tesis.

Esta tesis se organiza en cuatro capítulos. El **Capítulo 1** introduce el problema de investigación, los objetivos y la justificación del estudio. El **Capítulo 2** desarrolla el marco teórico, donde se explican los fundamentos del método del gradiente, el algoritmo genético y el enfoque híbrido. El **Capítulo 3** detalla la metodología utilizada para comparar los métodos. En el **Capítulo 4**, se exponen los resultados obtenidos y se analizan en detalle. Por último, se recogen las principales conclusiones del estudio y plantean posibles líneas de investigación para trabajos futuros.

Capítulo 2. FUNDAMENTOS TEÓRICOS

2.1. Optimización en problemas complejos.

A la hora de optimizar problemas complejos nos podemos encontrar con casos en los que aparecen múltiples variables, restricciones y óptimos locales que parecen buenos, pero no son la mejor opción global. Estos problemas suelen ser no lineales, con muchos posibles óptimos y una alta dimensionalidad, lo que hace que métodos tradicionales fallen o sean poco prácticos (Nocedal & Wright, 2006).

Ejemplos reales donde la optimización alcanza importancia son, entre otros, la logística (optimizando rutas de transporte), la ingeniería y gestión de proyectos o la economía y las finanzas (maximizando beneficios) (Talbi, 2009).

El reto está en encontrar la mejor solución posible dentro de numerosas opciones, pero sin violar las reglas del juego (las restricciones). Estos problemas no son simples, no se resuelven con una fórmula directa, porque presentan características que los hacen especialmente difíciles.

Las características que presentan estos problemas son:

- **Alta dimensionalidad**: Involucran un gran número de variables y parámetros que deben ser ajustados simultáneamente, lo que aumenta considerablemente el espacio de búsqueda y el costo computacional (Chong & Żak, 2013).
- **No linealidad**: Las relaciones entre las variables y la función objetivo no son lineales, lo que complica la búsqueda de soluciones óptimas. Esta característica hace que los métodos tradicionales basados en derivadas no sean efectivos. Esto es común en problemas de diseño de ingeniería, donde las relaciones físicas suelen ser no lineales (Boyd & Vandenberghe, 2004).
- **Multimodalidad**: Los algoritmos pueden estancarse en soluciones que parecen buenas, pero que en realidad son solo óptimos locales (Goldberg, 1989).

- **Restricciones**: Los problemas suelen estar sujetos a diversas restricciones que limitan el espacio de búsqueda, lo que añade complejidad al proceso de optimización al reducir el conjunto de soluciones factibles (Deb, 2000).

Estas características representan desafíos para los métodos de optimización tradicionales, como el método del gradiente, que puede quedar atrapado en óptimos locales debido a la multimodalidad (Nocedal & Wright, 2006). En cambio, los algoritmos genéticos son más flexibles: exploran mejor el conjunto de soluciones, evitando quedar atrapados demasiado pronto en falsos óptimos (Holland, 1992).

2.2 Algoritmos de optimización.

Los algoritmos de optimización son herramientas matemáticas y computacionales diseñadas para encontrar la mejor solución a un problema. Estos algoritmos pueden clasificarse en varias categorías, cada una con sus propias características (Nocedal & Wright, 2006):

a. Algoritmos de búsqueda exhaustiva.

Exploran todas las posibles soluciones en el espacio de búsqueda para encontrar el óptimo. Aunque garantizan encontrar la mejor solución, presentan una eficiencia reducida en problemas de alta dimensionalidad debido al tiempo de cálculo requerido, que crece exponencialmente con el número de variables (Russell & Norvig, 2020).

b. Algoritmos de gradiente.

Estos algoritmos utilizan la información del gradiente de la función objetivo para iterativamente mejorar una solución inicial. Son eficientes para problemas donde la función objetivo es diferenciable y no presenta muchos óptimos locales, pero pueden quedar atrapados en óptimos locales en problemas multimodales (Boyd & Vandenberghe, 2004).

c. Algoritmos genéticos.

Inspirados en la evolución biológica, los algoritmos genéticos utilizan operadores como la selección, cruce y mutación para evolucionar una población de soluciones. Son efectivos para problemas complejos y multimodales, ya que pueden explorar un amplio espacio de búsqueda

y evitar quedar atrapados en óptimos locales, aunque su costo computacional puede ser alto (Goldberg, 1989).

d. Algoritmos de optimización estocástica.

Estos algoritmos, como la optimización por enjambre de partículas y el recocido simulado, introducen elementos aleatorios en el proceso de búsqueda para escapar de óptimos locales y explorar mejor el espacio de búsqueda. Son útiles en problemas con múltiples óptimos locales y alta dimensionalidad (Kennedy & Eberhart, 1995; Kirkpatrick et al., 1983).

e. Algoritmos híbridos.

Los algoritmos híbridos combinan dos o más técnicas de optimización para aprovechar las fortalezas de cada una. Por ejemplo, un algoritmo híbrido que combine un algoritmo genético con un método del gradiente puede utilizar el algoritmo genético para explorar el espacio de búsqueda y el método del gradiente para refinar las soluciones encontradas, mejorando la precisión y eficiencia (Talbi, 2002). En este trabajo, se estudia en detalle este enfoque híbrido que combina ambos métodos.

Hay que tener en cuenta que la elección del algoritmo de optimización adecuado depende de las características específicas del problema a resolver (Yang, 2014).

2.3. Algoritmo genético

El algoritmo genético, desarrollado por John Holland en la década de 1970, es una técnica de optimización y búsqueda basada en la selección natural y la genética mendeliana. Trabaja con una población de soluciones candidatas (llamadas individuos o cromosomas), que evolucionan mediante operadores como selección, cruzamiento y mutación para mejorar su adaptación (fitness) al problema.

Entre las características que debe presentar el algoritmo genético para resolver problemas de optimización podemos destacar dos:

- El conjunto de posibles soluciones debe ser finito y estar delimitado dentro de un cierto rango para garantizar que el algoritmo pueda explorar eficientemente el espacio de búsqueda.

- La función que se desea optimizar (maximizar o minimizar) debe estar claramente definida y ser evaluable para cualquier conjunto de variables. Una vez evaluada la función, el algoritmo va a diferenciar entre las buenas y malas soluciones, desechando estas últimas y haciendo que las buenas se propaguen en posteriores iteraciones (generaciones). Las soluciones que hayan sobrevivido van a sufrir procesos de mutación y cruce entre sí para aumentar la variabilidad de la población.

A continuación, se describen los principios básicos, operadores genéticos, ventajas, desventajas y aplicaciones de los algoritmos genéticos, con ejemplos claros de los operadores utilizados.

2.3.1. Componentes del algoritmo genético.

El algoritmo genético consta de los siguientes componentes principales:

1. **Población**: Un conjunto de soluciones candidatas, llamadas individuos o cromosomas.
2. **Función de aptitud**: Una función que evalúa la calidad de cada individuo en la población.
3. **Selección**: Proceso que elige a los individuos más aptos para reproducirse.
4. **Cruce**: Operador que combina las características de dos individuos para generar descendencia.
5. **Mutación**: Operador que introduce cambios aleatorios en los individuos para mantener la diversidad genética.
6. **Reemplazo**: Un mecanismo para actualizar la población con los nuevos individuos generados.

2.3.2. Pasos del algoritmo genético.

A continuación, se describe el funcionamiento del AG paso a paso, utilizando un ejemplo sencillo: la minimización de la función $f(x) = x^2$ en el intervalo x ∈ [0,31].

- **Paso 1: Inicialización de la población.**

El AG comienza generando una población inicial de individuos de manera aleatoria. Cada individuo representa una posible solución al problema y se codifica como un cromosoma. En este ejemplo, utilizaremos una codificación binaria donde cada cromosoma es una cadena de 5 bits (ya que $2^5 = 32$ valores posibles).

Ejemplo de población inicial: Se crea una población inicial de individuos generados aleatoriamente. Esta población inicial de soluciones se expresa de forma binaria;

- Individuo 1: 10110 (22 en forma decimal)
- Individuo 2: 01101 (13 en forma decimal)
- Individuo 3: 11001 (25 en forma decimal)
- Individuo 4: 00011 (3 en forma decimal)

- **Paso 2: Evaluación de la aptitud**

Cada individuo se evalúa utilizando la función de aptitud. En este caso, la función de aptitud es $f(x) = x^2$.

Evaluación de aptitud:

- Individuo 1: $f(22) = 484$
- Individuo 2: $f(13) = 169$
- Individuo 3: $f(25) = 625$
- Individuo 4: $f(3) = 9$

Mejor individuo inicial: 00011 (3) con fitness 9.

- **Paso 3: Selección.**

Los individuos más aptos tienen más probabilidades de ser seleccionados para reproducirse. Un método común es la selección por ruleta, donde la probabilidad de selección es proporcional a la aptitud.

En este estudio, se empleó selección por torneo (más eficiente computacionalmente que la ruleta).

Probabilidades de selección:

- Individuo 1: $\frac{484}{484+169+625+9} = 0.38$
- Individuo 2: $\frac{169}{484+169+625+9} = 0.13$
- Individuo 3: $\frac{625}{484+169+625+9} = 0.49$
- Individuo 4: $\frac{9}{484+169+625+9} = 0.007$

Individuos seleccionados (ejemplo):

- Individuo 3 (25)
- Individuo 1 (22)

- **Paso 4: Cruce**

El cruce combina las características de dos individuos para generar descendencia. Un método común es el cruce de un punto, donde se selecciona un punto de corte aleatorio y se intercambian los bits después de ese punto.

Ejemplo de cruce:

- Individuo 3: 110**01**
- Individuo 1: 101**10**

Descendencia:

- Hijo 1: 11010 (26 en decimal)
- Hijo 2: 10101 (21 en decimal)

- **Paso 5: Mutación.**

La mutación introduce cambios aleatorios en los individuos para mantener la diversidad genética. En este ejemplo, se aplica una tasa de mutación del 5%, lo que significa que cada bit tiene un 5% de probabilidad de cambiar.

Ejemplo de mutación:

- Hijo 1: 1101**0** → 1101**1** (27 en decimal)
- Hijo 2: 10101 → 10101 (sin cambios)

- **Paso 6: Reemplazo.**

La nueva generación reemplaza a la anterior. En este caso, los hijos reemplazan a los individuos menos aptos de la población anterior.

Nueva población:

- Individuo 3: 11001 (25)
- Individuo 1: 10110 (22)
- Hijo 1: 11011 (27)
- Hijo 2: 10101 (21)

- **Paso 7: Iteración.**

El proceso se repite hasta que se cumple algunos de los siguientes criterios de terminación:

- Número máximo de generaciones.

- Fitness alcanza un valor satisfactorio.

- Convergencia (la población no mejora significativamente).

Funcionamiento del algoritmo genético:

1. Se genera de forma aleatoria una población inicial de soluciones.
2. Se evalúan las soluciones con la función que se va a optimizar.
3. Se comprueba si se ha obtenido una solución óptima o si se cumple una condición de parada previamente establecida. En caso de que así sea, el proceso termina. En caso contrario, se continúa con el siguiente paso.
4. Se seleccionan los individuos.
5. Se cruzan los individuos seleccionados obteniéndose un nuevo conjunto de individuos.
6. Los nuevos individuos sufren mutación con una probabilidad previamente establecida creándose una nueva población.
7. Esta población obtenida del cruce y mutación reemplaza a la población inicial.
8. Se inicia el proceso a partir del paso 2.

Analogía del algoritmo genético con la evolución Biológica

Concepto en AG	Equivalente biológico
Cromosoma	ADN de un organismo
Población	Comunidad de individuos
Fitness	Adaptación al medio ambiente
Selección	Supervivencia del más apto
Cruzamiento	Reproducción sexual
Mutación	Mutaciones genéticas aleatorias

2.3.3. Ventajas y desventajas del algoritmo genético:

Ventajas:

- No se necesitan conocimientos específicos sobre el problema que intentan resolver: no se requiere emplear herramientas matemáticas de derivación.
- Tiene la capacidad de trabajar simultáneamente con varias soluciones.
- En problemas de optimización se evita caer en falsas soluciones (mínimos locales).
- El algoritmo puede programarse y ejecutarse de forma relativamente fácil.
- A diferencia de otros métodos de optimización, que usan operadores determinísticos, los algoritmos genéticos usan operadores probabilísticos.

Desventajas:

- Puede tener problemas de convergencia en función de los parámetros utilizados (tamaño de la población, número de generaciones, características de la función objetivo u operadores probabilísticos). Cada función tiene una característica especial y los parámetros deben adaptarse a cada caso.

El algoritmo genético se ha aplicado con éxito en problemas como la optimización de rutas de transporte, donde se busca minimizar el tiempo y costo de viaje, y en el diseño de aeronaves, donde se optimiza la forma de las alas para maximizar la eficiencia aerodinámica.

2.3.4. Aplicación del algoritmo genético a la función de McCormick.

Antes de aplicar el algoritmo genético para la optimización de una función se deben definir los parámetros que se van a utilizar.

Estos parámetros son variables que controlan diferentes aspectos del proceso evolutivo y determinan cómo se lleva a cabo la optimización. Utilizaremos la función de **McCormick** como ejemplo para describir los principales parámetros del algoritmo genético.

La función de McCormick es descrita como sigue:

$$f(\mathbf{x}) = \sin(x_1 + x_2) + (x_1 - x_2)^2 - 1.5x_1 + 2.5x_2 + 1$$

Los parámetros que se van a controlar el algoritmo y que se describirán a continuación son:

```
Parámetros utilizados:
Número de individuos: 50
Rango para x: [-1.5, 4]
Rango para y: [-3, 4]
Número de generaciones: 100
Tasa de mutación: 0.1
```

a. Tamaño de la población: Hace referencia al número de individuos en la población en cada generación. Un mayor número de individuos puede aumentar la diversidad genética y mejorar la exploración del espacio de búsqueda, pero también incrementa el costo computacional.

Se ha elegido un valor de 50 individuos para mantener un equilibrio entre diversidad y eficiencia computacional.

b. Rango de valores para *x* e y*:* Los rangos de valores para las variables x e y definen el espacio de búsqueda del algoritmo. Estos rangos deben ser seleccionados de acuerdo con el dominio del problema. Si tomamos como ejemplo la función de McCormick los rangos se han definido como $[-1.5,\ 4]$ para **x** y $[-3,\ 4]$ para la variable **y**, lo que cubre un área significativa del espacio de búsqueda.

c. Número de generaciones: El número de generaciones define cuántas veces se repetirá el ciclo de selección, cruzamiento y mutación. Un mayor número de generaciones permite al algoritmo explorar más a fondo el espacio de búsqueda y encontrar soluciones óptimas.

Se ha elegido un valor de 100 generaciones para proporcionar suficiente tiempo de evolución sin incurrir en un costo computacional excesivo.

d. Tasa de mutación: La tasa de mutación es la probabilidad de que ocurra una mutación en un individuo. La mutación introduce variabilidad genética en la población, lo que ayuda a evitar la convergencia prematura y permite la exploración de nuevas áreas del espacio de

búsqueda. Una tasa de mutación demasiado alta puede desestabilizar el proceso de optimización, mientras que una tasa demasiado baja puede llevar a una falta de diversidad genética. En este caso, se ha elegido una tasa de mutación del 10% (0.1) para mantener un equilibrio adecuado.

Para que el parámetro mutación pueda actuar se debe trabajar con números binarios. Cada bit va a tener una probabilidad de mutación del 10%.

e. Tasa de cruzamiento: La tasa de cruzamiento se define como la probabilidad de que dos individuos seleccionados se crucen para producir descendencia. El cruzamiento combina la información genética de dos padres para crear nuevos individuos, introduciendo nuevas combinaciones genéticas en la población.

g. Método de selección: El método de selección determina cómo se eligen los individuos que participarán en el cruzamiento. En nuestro caso la selección es por torneo. En este método, se seleccionan dos individuos al azar y se elige el que tenga el mejor valor de fitness. Este proceso se repite hasta seleccionar la mitad de la población original.

g. Función de fitness: La función de fitness es la función matemática que mide la aptitud de cada individuo en la población.

La elección de estos parámetros se basa en pruebas experimentales realizadas durante la fase de diseño de la investigación. Los valores seleccionados buscan maximizar la eficiencia del algoritmo genético, garantizando una exploración adecuada del espacio de búsqueda sin incurrir en costos computacionales excesivos. Estos parámetros se ajustan a las características de cada función.

Los pasos del algoritmo genético aplicados a la función de McCormick se describen a continuación:

PASO 1. Generación de la población inicial: Se generan los valores de x e y aleatoriamente dentro de los rangos especificados.

PASO 2. Evaluación: Cada individuo de la población es evaluado utilizando la función de aptitud. Una vez generada una población inicial de individuos con valores aleatorios de x e y, se evalúa su fitness utilizando la función de McCormick.

```
Valores de fitness:
    9.8559
    4.3149
    5.5873
   -1.5879
   10.1925
    3.8919
   -1.3683
   12.4061
    7.9844
    5.8663
   20.3768
    3.4196
    2.3784
   19.0996
    5.4498
    1.3132
    2.4741
    2.2342
   -1.2109
    2.3783
   12.9814
    8.4164
    1.6299
```

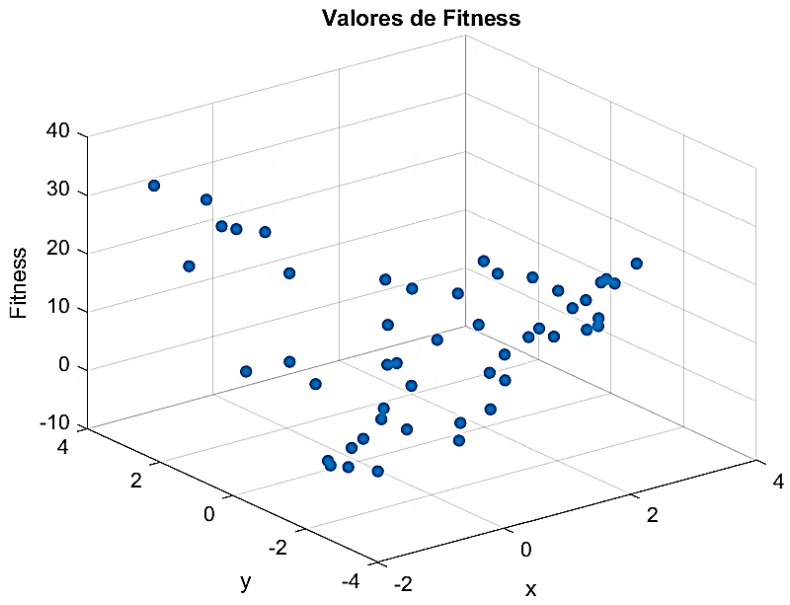

PASO 3. Se comprueba si se ha obtenido una solución óptima o se cumple un criterio de parada.

PASO 4. Se seleccionan los individuos.

```
Individuos seleccionados:
       x          y
   _______    _______

    3.211    -0.67931
   -1.1326     -2.499
    3.8728   0.054447
    1.4762    -1.4683
    1.5747   -0.87133
   -0.44453    0.41008
    3.7952     3.1503
    2.3735    -2.4828
   0.88049    -2.1015
    1.9498     1.2232
    2.2247    -2.4182
   0.03129    -2.7116
   -0.52867    -1.0489
   -1.3149    -2.0021
   0.81999    0.63204
     1.989   -0.56486
   -1.1326     -2.499
   -1.4339    -1.6499
    3.1136   -0.47808
    1.5786     1.9374
```

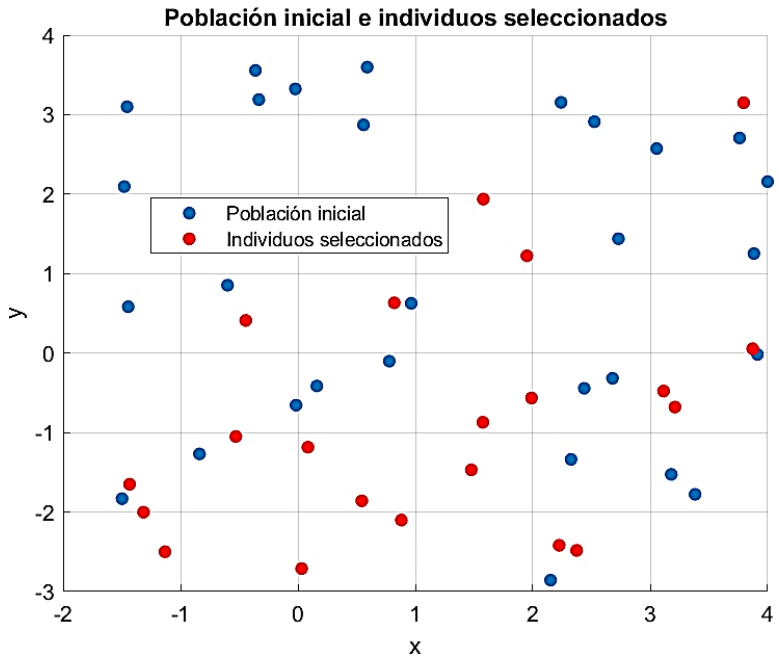

PASO 5. Cruce. Se define la probabilidad de que dos individuos seleccionados se crucen para producir descendencia. Se selecciona un punto de corte aleatorio y se intercambian los bits después de ese punto. De esta forma se crean nuevas combinaciones genéticas en la población.

PASO 6. Mutación. Se establece una probabilidad del 10% de que ocurra una mutación en un individuo. Cada bit tiene esta probabilidad de mutar.

PASO 7. Creación de una nueva población.

Descendencia:

x	y
3.211	-2.499
-1.1326	-0.67931
3.8728	-1.4683
1.4762	0.054447
1.5747	-0.87133
-0.44453	0.41008
3.7952	3.1503
2.3735	-2.4828
0.88049	1.2232
1.9498	-2.1015
2.2247	-2.4182
0.03129	-2.7116
-0.52867	-1.0489
-1.3149	-2.0021
0.81999	0.63204
1.989	-0.56486
-1.1326	-2.499
-1.4339	-1.6499
3.1136	-0.47808
1.5786	1.9374

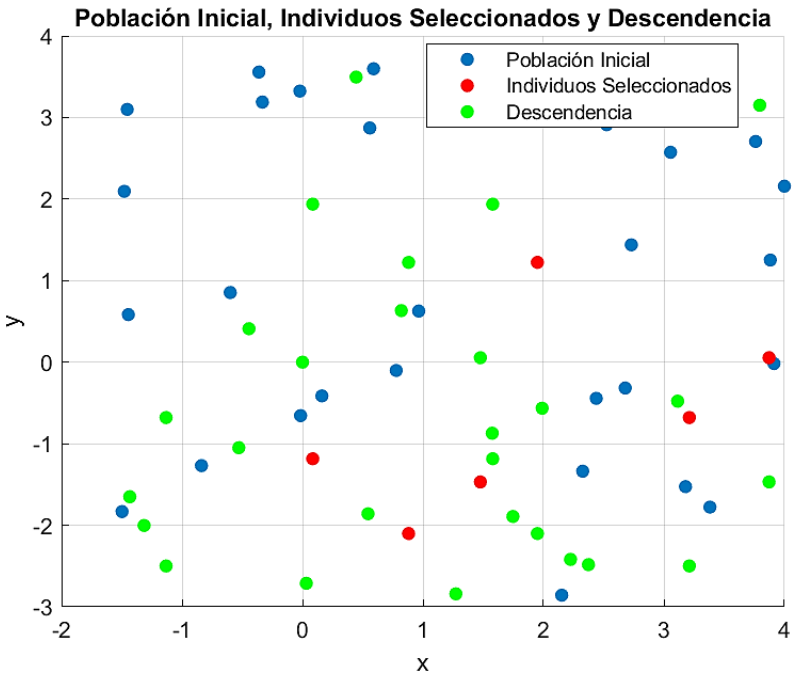

PASO 8. Se inicia el proceso a partir del paso 2. Al inicio del algoritmo los valores de la función objetivo están distribuidos aleatoriamente. Después de cada iteración la "mejor solución" tiene un valor significativamente mejor que la mejor solución inicial. Las peores soluciones suelen ser menos extremas.

2.4. Método del gradiente

El método del gradiente es un algoritmo de optimización iterativo utilizado para encontrar el mínimo de una función diferenciable.

2.4.1. Fundamentos teóricos.

a. Función Objetivo:

Dada una función f: $\mathbb{R}^n \rightarrow \mathbb{R}$ diferenciable, queremos encontrar:

$$\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$$

b. Gradiente (∇f):

El gradiente $\nabla f(\mathbf{x})$ representa la dirección de máximo crecimiento de f en el punto x. El método del gradiente actualiza los parámetros en la dirección opuesta (descenso), con un tamaño de paso α (tasa de aprendizaje).

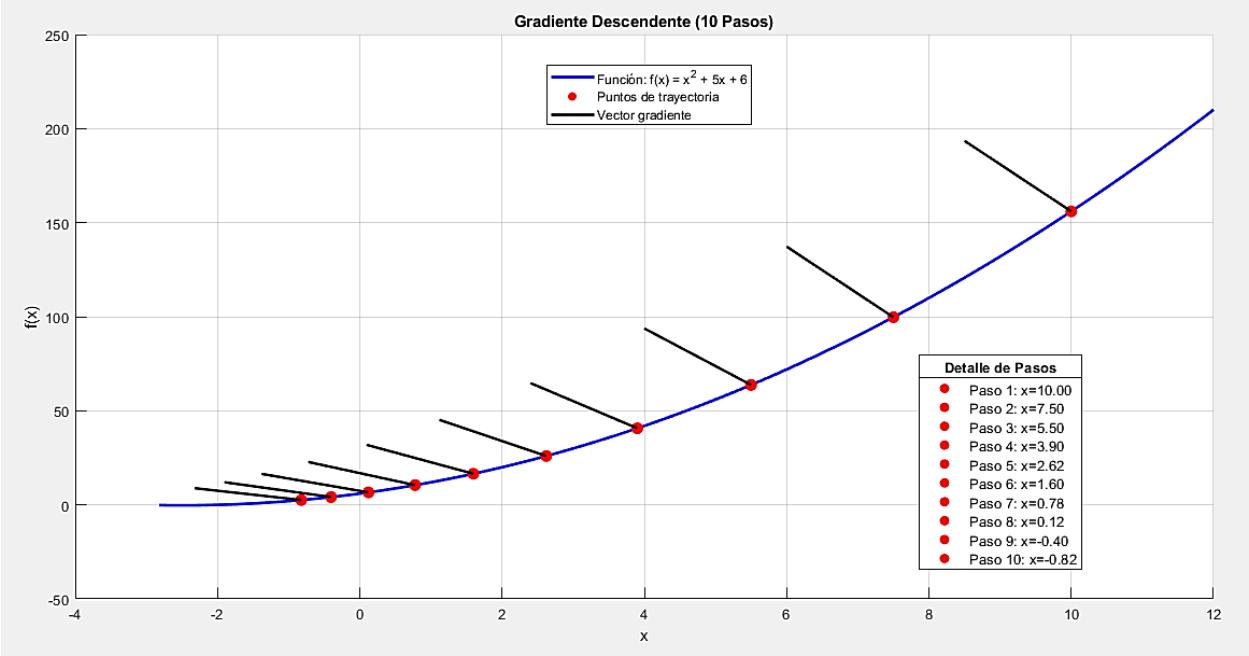

En cada iteración, el método actualiza **x** siguiendo la dirección negativa del gradiente con un tamaño de paso α (tasa de aprendizaje):

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha \nabla f(\mathbf{x}_k)$$

donde:

- $\mathbf{x}_k$ es el valor actual de los parámetros.
- $\nabla f(\mathbf{x}_k)$ es el gradiente evaluado en $\mathbf{x}_k$.
- $\alpha > 0$ es la tasa de aprendizaje que controla qué tan grande es cada paso.

c. Criterio de parada: El algoritmo termina cuando:

1. El gradiente es cercano a cero ($\|\nabla f(\mathbf{x}_k)\| < \epsilon$).
2. Se alcanza un número máximo de iteraciones.
3. La mejora en $f(\mathbf{x})$ es muy pequeña.

2.4.2. Ejemplo numérico con una función de una variable.

Consideremos la función cuadrática a minimizar:

$$f(x) = x^2 + 5x + 6$$

Aplicamos los siguientes pasos para optimizar la función usando el método del gradiente:

PASO 1: Calcular el gradiente.

El gradiente (derivada) es:

$$f'(x)=2x+5$$

PASO 2: Inicializar parámetros.

- Elegimos un punto inicial aleatorio, por ejemplo, $x_o = 0$.
- Tasa de aprendizaje $\alpha = 0.1$ (un valor común para ejemplos simples).

PASO 3: Iteraciones del algoritmo,

Iteración 1:

$x_1 = x_o - \alpha \cdot f'(x_o) = 0 - 0.1 \cdot (2 \cdot 0 + 5) = -0.5$

$f(x_1) = (-0.5)^2 + 5 \cdot (-0.5) + 6 = 0.25 - 2.5 + 6 = 3.75$

Iteración 2:

$x_2 = x_1 - \alpha \cdot f'(x1) = -0.5 - 0.1 \cdot (2 \cdot (-0.5) + 5) = -0.5 - 0.1 \cdot 4 = -0.9$

$f(x_2) = (-0.9)^2 + 5 \cdot (-0.9) + 6 = 0.81 - 4.5 + 6 = 2.31$

Iteración 3:

$x_3 = x_2 - \alpha \cdot f'(x_2) = -0.9 - 0.1 \cdot (2 \cdot (-0.9) + 5) = -0.9 - 0.1 \cdot 3.2 = -1.22$

$f(x_3) = (-1.22)^2 + 5 \cdot (-1.22) + 6 \approx 1.4884 - 6.1 + 6 \approx 1.3884$

Iteración 4:

$x_4 = x_3 - \alpha \cdot f'(x_3) = -1.22 - 0.1 \cdot (2 \cdot (-1.22) + 5) = -1.22 - 0.1 \cdot 2.56 \approx -1.476$

$f(x_4) \approx (-1.476)^2 + 5 \cdot (-1.476) + 6 \approx 2.178 - 7.38 + 6 \approx 0.798$

Resultado final.

Después de varias iteraciones, x converge al mínimo real en $x = -2.5$ (que es el vértice de la parábola). El valor mínimo de f(x) es:

$f(-2.5) = (-2.5)^2 + 5 \cdot (-2.5) + 6 = 6.25 - 12.5 + 6 = -0.25$

2.4.3. Ejemplo numérico con una función de dos variables.

Función:	**Gradiente:**	**Punto inicial**:	**Tasa de aprendizaje:**
$f(x,y) = x^2 + 3y^2$	$\nabla f(x) = (2x, 6y)$	$x_o = (4, 2)$	$\alpha = 0.1$

Después de 10 iteraciones obtendremos la siguiente tabla:

K	x_k	y_k	$\nabla f(x_k, y_k)$	x_{k+1}	y_{k+1}
0	4	2	(8, 12)	3.2	0.8
1	3.2	0.8	(6.4, 4.8)	2.56	0.32
2	2.56	0.32	(5.12, 1.92)	2.048	0.128
3	2.048	0.128	(4.096, 0.768)	1.6384	0.0512
4	1.6384	0.0512	(3.2768, 0.3072)	1.31072	0.02048
5	1.31072	0.02048	(2.62144, 0.12288)	1.048576	0.008192
6	1.048576	0.008192	(2.097152, 0.049152)	0.8388608	0.0032768
7	0.8388608	0.0032768	(1.6777216, 0.0196608)	0.67108864	0.00131072
8	0.67108864	0.00131072	(1.34217728, 0.00786432)	0.53687091	0.000524288
9	0.536870912	0.000524288	(1.073741824, 0.003145728)	0.42949672	0.0002097152
10	0.4294967296	0.0002097152	(0.8589934592, 0.0012582912)	0.34359738	0.00008388608

Observamos que el método converge hacia el mínimo global en (0,0), como era de esperarse para una función cuadrática.

2.4.4. Ventajas y desventajas del método del gradiente:

Ventajas:

- Fácil de implementar. Sólo requiere calcular el gradiente (derivadas parciales) y actualizar los parámetros iterativamente. No necesita cálculos complejos.

Desventajas:

- Sensible a la elección de α (si es muy grande, diverge; si es muy pequeño, converge lentamente).

- Puede quedar atrapado en mínimos locales (en funciones no convexas).

Es fundamental destacar que la aplicabilidad del Método del Gradiente está condicionada a la diferenciabilidad de la función objetivo. Cuando la función no es diferenciable en algún punto del espacio de búsqueda, el gradiente no está definido, lo que impide la actualización de los parámetros y, en consecuencia, la convergencia del algoritmo (Nocedal & Wright, 2006). Esta limitación restringe su uso en problemas con funciones discontinuas o con regiones de no diferenciabilidad.

Capítulo 3. Metodología.

Esta investigación tiene un enfoque experimental y comparativo cuyo objetivo principal es evaluar el desempeño de tres métodos de optimización: el método del gradiente, los algoritmos genéticos y un enfoque híbrido que combina ambos. Para lograr esto, se ha estructurado el proceso en varias etapas, que incluyen la selección de problemas de prueba, la configuración de los métodos, la implementación de los algoritmos y la evaluación de los resultados. A continuación, se describen los aspectos clave del diseño de la investigación:

3.1. Selección de funciones de prueba.

Las funciones seleccionadas para este estudio se han elegido en función de sus propiedades características, las cuales permiten evaluar distintos aspectos del desempeño de los algoritmos de optimización. Entre ellas, se incluyen funciones clásicas como Rastrigin y Ackley, ampliamente utilizadas en la literatura para evaluar la capacidad de escape de óptimos locales debido a sus paisajes multimodales.

Las funciones cuadráticas y gaussianas son particularmente adecuadas para evaluar métodos basados en el gradiente, dado su comportamiento suave y diferenciable. Funciones como Rosenbrock y McCormick también pueden ser efectivas, siempre que se ajusten adecuadamente parámetros como la tasa de aprendizaje. Sin embargo, se recomienda evitar el uso de la función Bukin debido a sus discontinuidades que dificultan la convergencia en métodos que dependen de derivadas. Asimismo, funciones altamente multimodales como Rastrigin y Ackley deben emplearse con precaución, ya que su gran número de óptimos locales puede llevar al estancamiento en soluciones subóptimas.

Para los algoritmos genéticos, las funciones complejas y multimodales, como Ackley, Rastrigin y Bukin, son ideales debido a que su estructura desafía las capacidades de exploración y explotación de estos algoritmos. Por el contrario, el uso de funciones simples no justifica la aplicación de técnicas evolutivas, dado que pueden resolverse eficientemente con métodos tradicionales. Funciones como Griewank y Bohachevsky representan casos intermedios útiles para evaluar el equilibrio entre convergencia y diversidad en la población.

Cuadro comparativo de las funciones objeto de estudio

Función	Tipo	Diferenciable	Suave	Adecuada para gradiente	Adecuada para algoritmos genéticos	Características de la función
Ackley	Multimodal No convexa	Sí	Sí	Moderada	Excelente	Múltiples óptimos locales, valle casi plano
Bohachevsky	Multimodal	Sí	Sí	Buena	Buena	Múltiples mínimos, estructura periódica
Bukin	No convexa	No es diferenciable en todos los puntos	No	Pobre	Excelente	Mínimos en forma de "platos", no diferenciable en algunos puntos
Cuadrática	Convexa	Sí	Sí	Excelente	Pobre	Forma parabólica simple, único mínimo global
Gaussiana	Unimodal	Sí	Sí	Excelente	Moderada	Curva suave en forma de campana
Griewank	Multimodal	Sí	Sí	Moderada	Buena	Múltiples mínimos locales con patrones complejos
McCormick	No convexa	Sí	Sí	Buena	Buena	Mínimos en regiones curvas
Rastrigin	Multimodal	Sí	Sí	Difícil	Excelente	Gran cantidad de óptimos locales, estructura "ruidosa"
Rosenbrock	No convexa	Sí	Sí	Buena	Buena	Valle curvo y estrecho

3.2. Implementación de los algoritmos.

Cada método de optimización se configura con parámetros específicos para garantizar una comparación justa y significativa:

- Método del gradiente: Se ajustan parámetros como la tasa de aprendizaje, el criterio de parada o el número de iteraciones.

- Algoritmos genéticos: Se definen el tamaño de la población, el número de generaciones, la tasa de mutación y los operadores de selección y cruzamiento.

- Algoritmo híbrido: Se combinan las estrategias del método del gradiente y los algoritmos genéticos, definiendo cómo y cuándo se aplica cada uno.

3.3. Selección de las métricas de evaluación.

Para comparar de manera efectiva los métodos de optimización, se trabajarán con los siguientes parámetros:

- **Precisión**: Mide qué tan cerca está la solución encontrada del óptimo real.

- **Tiempo de ejecución**: Registra cuánto tiempo tarda cada algoritmo en encontrar una solución.

- **Variabilidad de las soluciones**. Al ejecutar los códigos se analizan si los resultados obtenidos en cada ejecución son homogéneos.

3.4. Configuración de parámetros.

Cada método de optimización tiene parámetros específicos que se deben configurar adecuadamente para obtener los mejores resultados:

a. Método del Gradiente:

- **Tasa de aprendizaje:** Determina el tamaño de los pasos que el algoritmo toma en la dirección del gradiente. Una tasa de aprendizaje adecuada influye significativamente en la convergencia.

- **Número máximo de iteraciones:** Establece un límite en el número de iteraciones que el algoritmo puede realizar, evitando bucles infinitos.

b. Algoritmo Genético:

- **Tamaño de la población:** Define el número de individuos en cada generación. Un tamaño de población mayor puede explorar mejor el espacio de búsqueda, pero también aumenta el tiempo de cómputo.

- **Tasa de cruce**: Proporción de individuos que se combinan para crear la siguiente generación.

- **Tasa de mutación:** Proporción de individuos que sufren mutaciones. Una tasa de mutación adecuada ayuda a mantener la diversidad genética y evita la convergencia prematura.

- **Número de generaciones:** Establece cuántas generaciones se deben evaluar. Más generaciones permiten una búsqueda más exhaustiva, pero también aumentan el tiempo de cómputo.

3.5. Descripción del código en MATLAB.

Se describe el código empleado para la implementación de los métodos de optimización en MATLAB. La ejecución de estos códigos se llevó a cabo de manera eficiente para cada una de las funciones objetivo-estudiadas, con la excepción de la función Bukin.

Es importante destacar que la función Bukin presentó desafíos específicos que impidieron una ejecución eficiente de los códigos desarrollados. Esta función, conocida por su complejidad y múltiples óptimos locales, requirió ajustes adicionales.

3.5.1. Descripción del código utilizado para el algoritmo genético.

Se describe cada sección del código que implementa el algoritmo genético para optimizar las funciones objeto de estudio. Se tomará como ejemplo la función de Ackley, una función matemática comúnmente utilizada para probar algoritmos de optimización. Esta función en su forma bidimensional se caracteriza por una región exterior casi plana y un gran agujero en el centro. Para *d* dimensiones viene definida de la siguiente forma:

$$f(\mathbf{x}) = -a\exp\left(-b\sqrt{\frac{1}{d}\sum_{i=1}^{d}x_i^2}\right) - \exp\left(\frac{1}{d}\sum_{i=1}^{d}\cos(cx_i)\right) + a + \exp(1)$$

Siendo a = 20, b = 0,2 y c = 2π los valores más utilizados para estas variables.

1. **Definición de la función**: Se define la función, en nuestro caso la función de Ackley. La función toma un vector x de dos elementos y calcula su valor según la fórmula de Ackley.

2. **Parámetros del algoritmo genético**: Se establecen los parámetros del algoritmo genético, incluyendo el tamaño de la población, el número de generaciones, las tasas de mutación y cruce, y los límites de las variables x_1 y x_2. El código MATLAB mostrará los parámetros utilizados.

```
% Parámetros del algoritmo genético
population_size = 50;
num_generations = 100;
mutation_rate = 0.1;
crossover_rate = 0.8;
bounds = [-5, 5; -5, 5]; % Límites para x1 y x2
```

3. **Generación de la población inicial**: Se genera una población inicial aleatoria dentro de los límites especificados x_1 y x_2.

4. **Evaluación de la función objetivo para la población inicial**: Se evalúa la función para cada individuo en la población inicial y se almacena el valor de fitness correspondiente.

5. **Inicialización de los resultados y del temporizador** para medir el tiempo de ejecución del algoritmo.

6. **Ciclo de generaciones**: Este ciclo realiza la selección, cruce y mutación de la población a lo largo de las generaciones. Los mejores individuos se seleccionan y se guardan los resultados de cada generación.

7. **Detener el temporizador**: Se detiene el temporizador y se almacena el tiempo de ejecución.

8. **Resultado final**: Se identifica la mejor solución encontrada y su valor de fitness.

9. **Visualización de los resultados**.

```
Parámetros del algoritmo genético:
Tamaño de la población: 50
Número de generaciones: 100
Tasa de mutación: 0.1
Tasa de cruce: 0.8
Límites: [-5, 5] para x1 y [-5, 5] para x2
Mejor solución encontrada:
x1 = 0.0015951, x2 = 0.014953, Valor de la función = 0.048546
Tiempo de ejecución: 0.010648 segundos
```

3.5.2. Descripción del código utilizado para la optimización de la función de Ackley usando el método del gradiente.

Este código incluye la generación del punto inicial, el cálculo de los gradientes, la actualización de las coordenadas del punto, la medida del tiempo de ejecución, la visualización de los resultados y la generación de un gráfico de convergencia. La descripción del código empleado es la siguiente:

1. **Limpieza de la memoria**: Se limpian todas las variables de la memoria de MATLAB para asegurar que no haya interferencias con datos previos.

2. **Definición de la función**: Se define la función como una cadena de caracteres y se convierte en una función vectorizada utilizando los parámetros *inline* y *vectorize*. Se establece también el rango de búsqueda para las variables.

3. **Parámetros de optimización**: Se inicializan los parámetros del método: el contador de iteraciones *k*, el número máximo de iteraciones *niter*, el tamaño de la perturbación *hstep* para el cálculo de los gradientes, y el paso de optimización *alfa*.

4. **Generación del punto inicial**: Se genera un punto inicial aleatorio dentro del rango especificado para las variables.

5. **Inicializar vector para almacenar los valores de la función en cada iteración**. Se inicia el temporizador para medir el tiempo de ejecución del algoritmo.

6. **Proceso iterativo de optimización**: Mediante la función *while* se realiza el proceso iterativo de optimización. En cada iteración, se evalúa la función en el punto actual, se calculan los gradientes en las direcciones x e y, y se actualizan las coordenadas del punto utilizando el paso de optimización *alfa*. Los valores de la función se almacenan en el vector *values*.

7. **Detener el temporizador**: Se detiene el temporizador y se almacena el tiempo de ejecución.

8. **Mostrar la solución óptima y el valor de la función**: Se calcula y muestra la solución óptima encontrada, el valor de la función en ese punto y el tiempo de ejecución del algoritmo.

9. **Mostrar los parámetros del método del gradiente**: Se muestran los parámetros utilizados en el método del gradiente (el rango de búsqueda, el número de iteraciones, el tamaño de la perturbación y el paso de optimización).

10. **Graficar la convergencia del método del gradiente**: Se genera un gráfico que muestra la convergencia del método del gradiente, es decir, cómo el valor de la función cambia en cada iteración del proceso de optimización.

Un ejemplo de una ejecución del código MATLAB anterior es el siguiente:

```
Solución óptima: x1 = -0.1434, x2 = 0.9419
Valor óptimo: 3.0633
Tiempo de ejecución: 0.0402 segundos
Parámetros del método del gradiente:
Rango: [-5 5 -5 5]
Número de iteraciones: 200
Tamaño de la perturbación (hstep): 0.0010
Paso de optimización (alfa): 0.0500
```

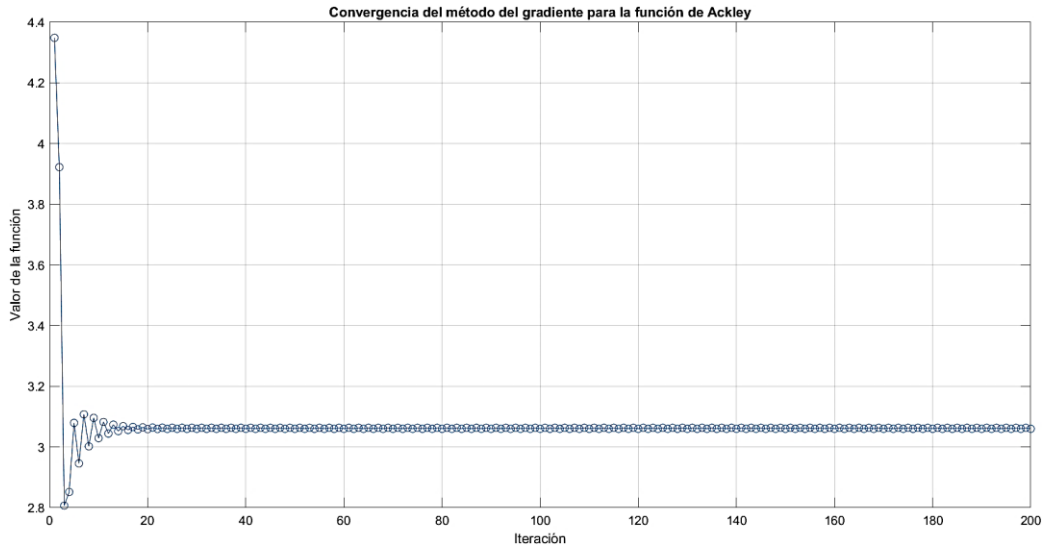

3.5.3. Descripción del código híbrido.

El código híbrido que implementa el algoritmo genético seguido del método de gradiente se describe a continuación:

1. **Definición de la función**: Se define la función y el rango de búsqueda para las dos variables.

2. **Parámetros del algoritmo genético**: Se establecen los parámetros que controlan el tamaño de la población, el número de iteraciones, y las probabilidades de cruce y mutación.

3. **Inicialización de la población**: Se genera una población inicial de soluciones aleatorias dentro del rango especificado.

4. **Se crea una lista para almacenar el mejor valor de aptitud en cada iteración**.

5. **Se inicia el proceso iterativo del algoritmo genético**:
    - **Evaluación de la aptitud**: Se evalúa la aptitud de cada individuo en la población y se almacena el mejor valor de aptitud en cada iteración.

    - **Selección por torneo**: Se seleccionan individuos para la nueva población mediante un torneo entre pares aleatorios.

    - **Cruce**: Se realiza el cruce entre pares de individuos seleccionados con una probabilidad *pc*.

    - **Mutación**: Se aplica mutación a los individuos con una probabilidad *pm*.

    - **Actualización de la población**.

6. **Se muestra el mejor resultado**.

7. **Parámetros del método del gradiente**: Se establecen los parámetros del método del gradiente.

8. **Inicialización del método del gradiente con la mejor solución del algoritmo genético**.

9. **Función de gradiente**: Se define la función gradiente.

10. **Se crea una lista para almacenar el valor de aptitud en cada iteración del método del gradiente**:

11. **Se inicia el proceso iterativo del método del gradiente**.

12. **Se muestra el resultado refinado**.

13. **Por último, se grafica la convergencia del algoritmo genético y el método del gradiente**.

Este código combina el algoritmo genético y el método del gradiente para optimizar la función de Ackley. Primero, el algoritmo genético explora el espacio de soluciones y encuentra una solución aproximada. Luego, el método del gradiente refina esta solución para encontrar un mínimo más preciso.

3.5.4. Descripción del código que ejecuta el algoritmo genético para la función Bukin.

Al adaptar el código para el algoritmo genético descrito con anterioridad a la función Bukin se obtenían valores de la función muy alejados de los valores teóricos. Esta función se caracteriza por tener muchos mínimos locales, todos ellos situados en una cresta.

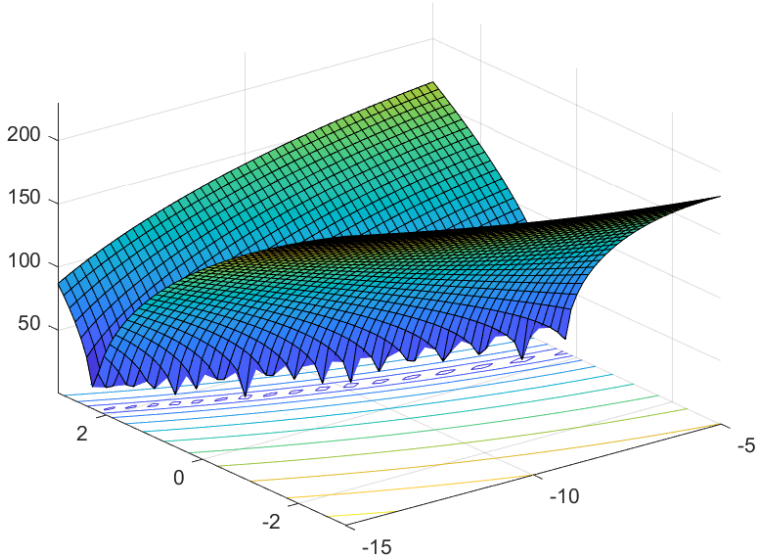

La función Bukin viene definida de la siguiente forma:

$$f(\mathbf{x}) = 100\sqrt{|x_2 - 0.01x_1^2|} + 0.01|x_1 + 10|$$

Las posibles causas del alejamiento de los resultados obtenidos con el código son las siguientes:

- La mutación puede estar generando valores fuera de los límites definidos, lo que podría llevar a soluciones no válidas.

- La re- inicialización periódica de la población puede estar afectando negativamente la convergencia del algoritmo. Una de las opciones a llevar a cabo puede ser reducir la frecuencia de re- inicialización o eliminarla por completo.

- La selección por torneo y el cruce pueden no estar explorando adecuadamente el espacio de búsqueda.

- Los parámetros del algoritmo genético, como la tasa de mutación y la tasa de cruce pueden no estar ajustados.

Aprovechando las ventajas del lenguaje MATLAB se creó un nuevo código que corrigió lo anteriormente expuesto.

1. **Definición de la función Bukin.** Esta función toma un vector (x) con dos componentes y calcula el valor de la función.

```
% Definición de la función Bukin N.6
function bukin_ag
        function z = bukin(x)
        z = 100 * sqrt(abs(x(2) - 0.01 * x(1)^2)) + 0.01 * abs(x(1) + 10);
    end
```

2. **Configuración del algoritmo genético**: Se establecen los parámetros del algoritmo:

```
% Configuración del algoritmo genético
options = optimoptions('ga', 'PopulationSize', 100, 'MaxGenerations', 200, ...
    'FunctionTolerance', 1e-6, 'Display', 'off', 'MutationFcn', @mutationadaptfeasible, ...
    'CrossoverFraction', 0.8, 'OutputFcn', @gaoutfun);
```

- PopulationSize: Tamaño de la población (100 individuos).
- MaxGenerations: Número máximo de generaciones (200).
- FunctionTolerance: Tolerancia de la función para detener el algoritmo (10^{-6}).
- CrossoverFraction: Fracción de cruce (0.8).
- MutationFcn: Función de mutación adaptativa.

La tasa de mutación en este código está configurada para usar la función *mutationadaptfeasible*.

La función *mutationadaptfeasible* ajusta dinámicamente la magnitud de las mutaciones para asegurar que las soluciones generadas sean factibles, es decir, que cumplan con las restricciones del problema. Los aspectos por considerar en la mutación son:

a. **Adaptación**:

- La función ajusta la magnitud de la mutación en función de la factibilidad de las soluciones. Si una solución mutada no cumple con las restricciones, la magnitud de la mutación se reduce.
- Si la solución mutada es factible, la magnitud de la mutación puede aumentar, permitiendo explorar más ampliamente el espacio de búsqueda.

b. **Factibilidad**:

- La función se asegura de que las soluciones mutadas permanezcan dentro de los límites definidos para las variables.
- Esto es especialmente útil en problemas con restricciones, donde es crucial que las soluciones generadas sean válidas.

c. **Diversidad**:

- Al ajustar dinámicamente la tasa de mutación, *mutationadaptfeasible* ayuda a mantener la diversidad genética en la población, lo que es esencial para evitar la convergencia prematura a soluciones subóptimas.

Las ventajas que se obtienen al implementar *mutationadaptfeasible* son*:*

- **Robustez**: Mejora la capacidad del algoritmo para encontrar soluciones factibles en problemas con restricciones.
- **Eficiencia**: Ajusta automáticamente la magnitud de la mutación, lo que puede conducir a una convergencia más rápida y eficiente.
- **Diversidad**: Mantiene la diversidad en la población, evitando la convergencia prematura.

3. **Definición de los límites de las variables**: Se definen los límites inferiores y superiores para las variables.

```
% Definición de los límites de las variables
lb = [-15, -3];
ub = [-5, 3];
```

4. **Medición del tiempo de ejecución**: Se inicia el temporizador para medir el tiempo de ejecución del algoritmo.
5. **Variable global para almacenar los mejores valores**: Se define una variable global *bestValues* para almacenar los mejores valores de la función en cada generación.

6. **Ejecución del algoritmo genético**: Se ejecuta el algoritmo genético para optimizar la función Bukin.

7. **Resultados**: Se imprimen los resultados de la optimización, incluyendo la mejor solución encontrada, el valor de la función en esa solución y el tiempo de ejecución.

8. **Graficar la convergencia**: Después de ejecutar el algoritmo genético, se crea una gráfica que muestra la convergencia del algoritmo.

9. **Función de salida personalizada para el algoritmo genético.**

Capítulo 4. Resultados experimentales.

En este capítulo se describen cada una de las funciones objetivo-estudiadas y se analizan los resultados obtenidos al aplicar los tres métodos de optimización a dichas funciones.

Los resultados se organizan de manera sistemática, respaldados por gráficos, tablas y estudios estadísticos que permiten interpretar su eficacia, convergencia y robustez. Se identifican casos en los que un método supera a los otros.

Este análisis además de validar la aplicación de los métodos estudiados proporciona criterios para seleccionar la metodología más adecuada según las características de la función.

4.1. Función de Ackley.

Características: La función de Ackley generalizada se define de la siguiente forma:

$$f(\mathbf{x}) = -a\exp\left(-b\sqrt{\frac{1}{d}\sum_{i=1}^{d}x_i^2}\right) - \exp\left(\frac{1}{d}\sum_{i=1}^{d}\cos(cx_i)\right) + a + \exp(1)$$

Los valores de variable recomendados son: a = 20, b = 0,2 y c = 2π.

Dimensiones: d

Se trata de una función muy utilizada para probar algoritmos de optimización. Es continua, diferenciable, no separable y con múltiples mínimos locales.

Para dos dimensiones su mínimo global es $f(0,0) = 0$

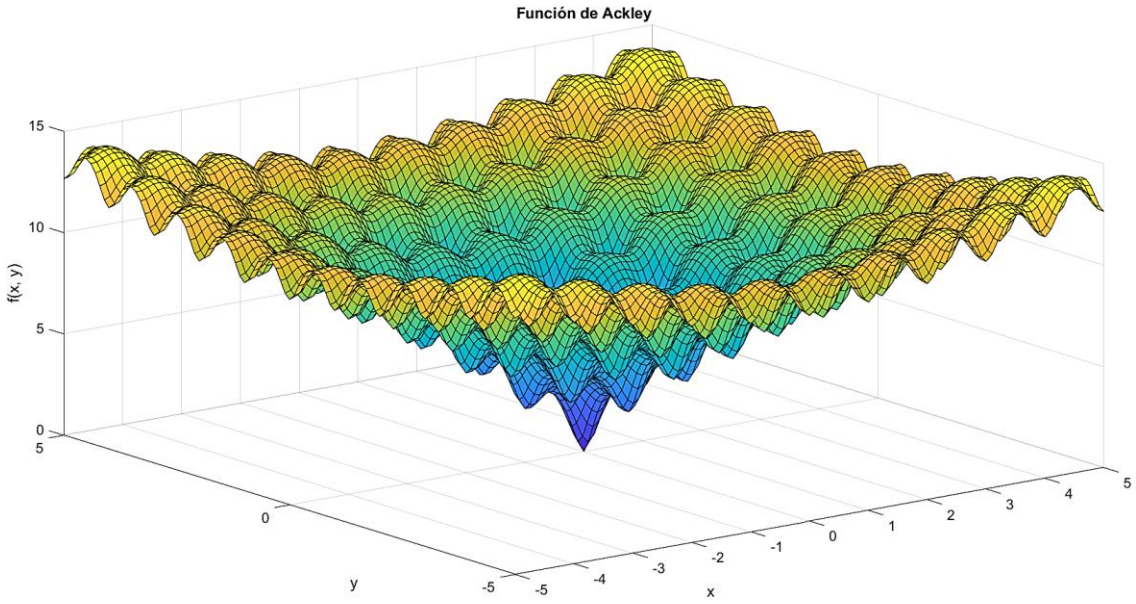

a. Ejecución del código algoritmo genético.

```
Parámetros del algoritmo genético:
Tamaño de la población: 50
Número de generaciones: 100
Tasa de mutación: 0.1
Tasa de cruce: 0.8
Límites: [-5 5;-5 5]
```

Los resultados obtenidos se describen en la siguiente tabla:

Criterio	Resultados	Observaciones
Variabilidad en las soluciones	No siempre converge al mismo valor (naturaleza estocástica).	Podría mejorarse ajustando parámetros (tamaño de población, generaciones, etc.).
Valores óptimos	Mejor valor: **0.00647520** (Ejecución 2) Peor valor: **0.256640** (Ejecución 8) Media: **0.12340**	En promedio, se acerca al mínimo global. Mayor precisión con ajuste de parámetros.
Tiempo de ejecución	Rápido en todas las ejecuciones.	Eficiente en términos computacionales.

b. Ejecución del código del método del gradiente.

Los resultados obtenidos al aplicar el método del gradiente son los siguientes:

Criterio	Resultados	Interpretación
Sensibilidad al punto inicial	Converge a diferentes mínimos locales según el punto de inicio.	Alta dependencia de la posición inicial debido a la naturaleza de la función de Ackley.
Solución óptima (x, y)	Valores de x e y varían significativamente entre ejecuciones.	Queda atrapado en mínimos locales (no hay convergencia al óptimo global).
Valor óptimo	Mejor valor: **3.0633** (Ejecución 9) *No se alcanza el mínimo teórico*.	Soluciones subóptimas (óptimos locales, no global).
Tiempo de ejecución	No correlacionado con la calidad de la solución.	El tiempo de ejecución no es un indicador confiable de precisión.

c. Ejecución del código algoritmo híbrido.

Tras aplicar el algoritmo híbrido a la función de Ackley se obtuvieron las siguientes conclusiones:

```
Parámetros del método del gradiente:
Tasa de aprendizaje: 0.001
Tolerancia para la convergencia: 1e-06
Número máximo de iteraciones: 5000
```

Criterio	Resultados	Interpretación
Variabilidad en las soluciones	Los valores de x e y varían en cada ejecución (naturaleza estocástica).	Comportamiento esperado debido al componente genético.
Valores óptimos	Rango: **0.0012732** (mejor) a **0.126** (peor).	Dependiendo del problema, pueden representar error, costo o desempeño.
Refinamiento de la solución	Sin mejora significativa tras refinamiento (x e y idénticos antes/después).	Posible necesidad de ajustar parámetros (tolerancia, pasos del gradiente, etc.).
Tiempo de ejecución	Relativamente rápido.	Eficiente en velocidad, pero sin sacrificar precisión.

Las soluciones refinadas no son mejores que las obtenidas por el algoritmo genético. Algunas posibles razones por las que esto podría estar ocurriendo son:

1. **Tasa de aprendizaje alta:** Si la tasa de aprendizaje es demasiado alta, el método del gradiente puede oscilar y no converger adecuadamente. Para evitar esta oscilación reducimos la tasa de aprendizaje.
2. **Número insuficiente de iteraciones**: Aumentar el número de iteraciones puede permitir que el método del gradiente tenga más tiempo para converger a una mejor solución.

d. Estudio comparativo de los tres métodos:

Criterio	Método del gradiente	Algoritmo genético	Algoritmo híbrido
Convergencia	Depende críticamente del punto inicial. Atrapado frecuente en mínimos locales (3.0633 en ejecución 9).	Soluciones variables entre ejecuciones (estocástico). Evita mínimos locales (mejor óptimo: 0.0065).	Combina exploración global (genético) + refinamiento (gradiente). Óptimos entre 0.0013 y 0.126.
Precisión (Valor óptimo)	Mínimo global no alcanzado. Mejor resultado: 3.0633	Óptimos cercanos al global (0.0065 a 0.2566). Media: 0.1234.	Mejor precisión que el método del gradiente. Valores más cercanos al óptimo teórico.
Consistencia	Alta dispersión en soluciones (dependencia del punto inicial).	Variabilidad moderada (naturaleza estocástica). Media estable: 0.1234.	Mayor consistencia que el método del gradiente. El refinamiento no siempre mejora soluciones (posible ajuste de parámetros).
Tiempo de ejecución	Tiempos variables, no correlacionados con calidad. Mayor que en el algoritmo genético (por reinicios).	Consistente y rápido.	Tiempo intermedio (genético + gradiente).
Ventajas	Rápido por iteración. Útil si el punto inicial es cercano al óptimo.	Robustez en espacios multimodales. No requiere gradiente.	Combina fortalezas: exploración global + precisión local.
Limitaciones	Falla en Ackley (mínimos locales). Requiere múltiples reinicios.	Precisión limitada sin ajuste fino. Alta variabilidad.	Refinamiento inefectivo si: - Tasa de aprendizaje alta. - Iteraciones insuficientes.

4.2. Función de Bohachevsky

Características: Función definida como:

$$f(x,y) = x^2 + 2y^2 - 0.3cos(3\pi x) - 0.4cos(4\pi y) + 0.7$$

Dimensiones: 2

La función de Bohachevsky es continua, diferenciable, unimodal y con forma de cuenco.

Para dos dimensiones su mínimo global es $f(0,0) = 0$

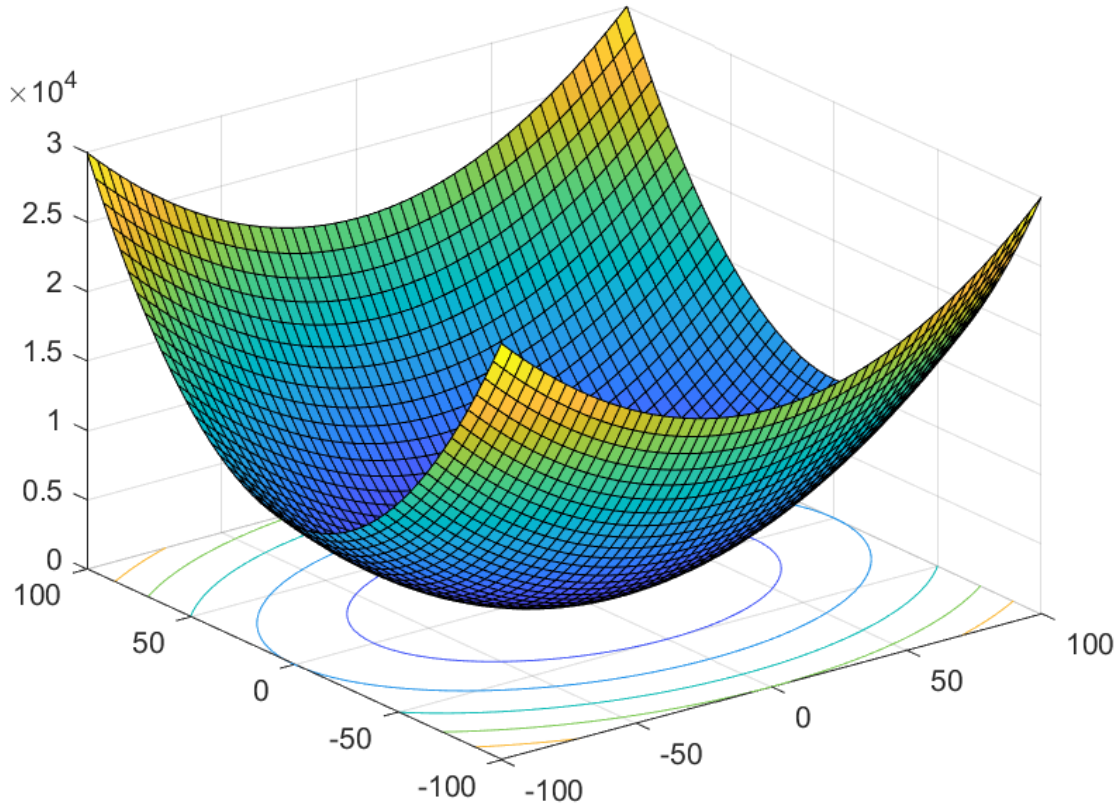

a. Ejecución del código algoritmo genético.

Los parámetros usados para este algoritmo son:

```
Tamaño de la población: 50
Número de generaciones: 100
Tasa de mutación: 0.1
Tasa de cruce: 0.8
```

Una vez ejecutado el código 10 veces se llegó a las siguientes conclusiones:

Aspecto analizado	Observaciones
Valores de la función	La mayoría de las ejecuciones convergen cerca del mínimo global (0,0). En algunas ejecuciones las soluciones se alejan del mínimo global. Esto sugiere que el algoritmo puede quedar atrapado en regiones subóptimas.
Tiempo de ejecución	Los tiempos son consistentes en todas las ejecuciones. El algoritmo es eficiente en términos de tiempo.
Variabilidad en las soluciones	Las soluciones suelen estar cerca del mínimo global, pero con algunas excepciones.

b. Implementación del método del gradiente.

Se definen los parámetros del método del gradiente

```
Parámetros del método del gradiente:
Número de iteraciones: 100
Tamaño de la perturbación (hstep): 0.001
Paso de optimización (alfa): 0.05
```

Aspecto analizado	Observaciones
Valores de la función	Los valores obtenidos son significativamente mayores que el óptimo teórico. El método del gradiente no alcanza soluciones cercanas al óptimo en estas ejecuciones. El bajo número de iteraciones impide que el método del gradiente converja al óptimo, aunque cada iteración acerca a la solución esperada.
Tiempo de ejecución	El método es relativamente rápido.
Variabilidad en las soluciones	Las soluciones (x, y) varían entre ejecuciones. Esto se debe a diferentes puntos iniciales y trayectorias de búsqueda.

c. Implementación del algoritmo híbrido.

El código híbrido que se implementa combina el algoritmo genético con el método del gradiente para optimizar la función de Bohachevsky se ejecutó 10 veces y se obtuvieron las siguientes conclusiones:

Criterio	Conclusiones
Consistencia	En la mayoría de las ejecuciones, las soluciones refinadas tienen un valor de aptitud menor o igual que las soluciones genéticas. Esto es esperado, ya que el método del gradiente debe mejorar o mantener la solución inicial.
Precisión	Valores de la función extremadamente bajos (soluciones muy cercanas al óptimo global). Precisión variable entre ejecuciones: en algunas el método alcanza soluciones casi idénticas al mínimo teórico.
Tiempo de ejecución	Tiempos entre **0.29759 s** y **0.41743 s**. Variación pequeña, lo que indica consistencia en el tiempo requerido por ejecución.

d. Estudio comparativo de los tres métodos:

Criterio	Algoritmo genético	Método del gradiente	Algoritmo híbrido
Precisión	Precisión variable, generalmente aceptable. Mejora con más generaciones.	Menos preciso con pocas iteraciones. Tiende a soluciones subóptimas. Útil para refinamiento.	**Superior**: Valores muy cercanos a cero (óptimo).
Tiempo de ejecución	**Más rápido**.	Rápido, pero no tanto como el genético.	**Más lento**, pero tiempos razonables.
Consistencia	Resultados cercanos al óptimo, pero con variabilidad no significativa en los resultados.	Poca consistencia, depende del punto inicial.	**Mayor consistencia** en resultados.

4.3. Función Bukin

Características: La función Bukin se define como:

$$f(\mathbf{x}) = 100\sqrt{|x_2 - 0.01x_1^2|} + 0.01|x_1 + 10|$$

Dimensiones: 2

Función continua, no diferenciable, no separable y con múltiples mínimos locales situados en un valle estrecho de pendiente pronunciada.

Su mínimo global es $f(-10,1) = 0$

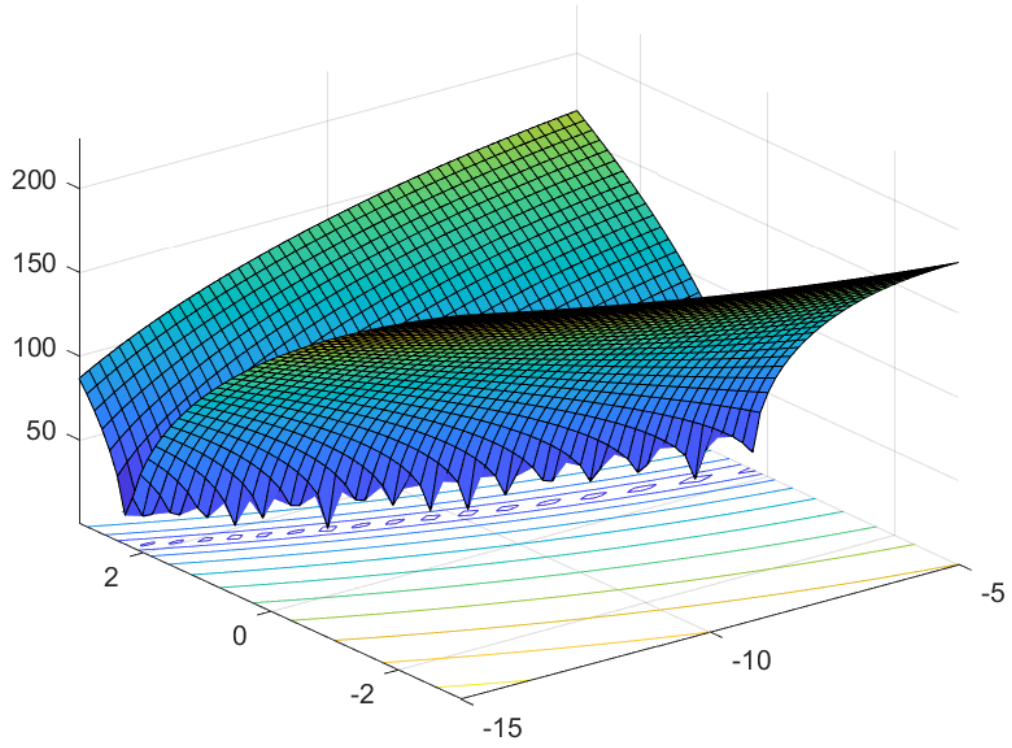

La superficie de la función Bukin es bastante irregular, con un valle estrecho y profundo que contiene el mínimo global. La función presenta un desafío para los algoritmos de optimización debido a su superficie irregular y la presencia de múltiples crestas y valles. Debido a esto se creó un código diferente al utilizado para el resto de las funciones estudiadas aprovechando algunas de las funciones de MATLAB.

a. Ejecución del código algoritmo genético.

Tras ejecutar el código 10 veces obtenemos los siguientes resultados:

Criterio	Resultados	Interpretación
Variabilidad en soluciones	Desviación estándar de $\mathbf{x_1} >> \mathbf{x_2}$. Desviación estándar del valor óptimo: **baja**.	Mayor dispersión en $\mathbf{x_1}$ entre ejecuciones. Valores óptimos **consistentes** (baja fluctuación).
Valores de la función	Valor óptimo medio: **0.0578**. Rango: **[0.0228, 0.0779]**.	Todos los valores cercanos al mínimo teórico (precisión aceptable). Variabilidad moderada pero dentro de un rango estrecho.
Tiempo de ejecución	Variabilidad **moderada** entre ejecuciones.	Tiempos **consistentes**, sin grandes fluctuaciones.
Conclusión general	Soluciones óptimas varían por la naturaleza aleatoria del AG.	El algoritmo es **exploratorio** (encuentra distintas soluciones), pero **consistente** en calidad de resultados.

b. Implementación del método del gradiente:

Criterio	Resultados	Interpretación
Variabilidad en las soluciones	Las soluciones óptimas encontradas varían significativamente entre ejecuciones	El método tiende a quedar atrapado en mínimos locales, mostrando poca consistencia
Precisión	Ninguna solución coincide con el mínimo global teórico	El método no alcanza la solución óptima, indicando limitaciones en precisión
Tiempo de ejecución	Los tiempos de ejecución son muy cortos	El método es eficiente computacionalmente, aunque no preciso

c. Implementación del algoritmo híbrido:

Interpretación de los resultados:

Criterio	Resultados	Interpretación
Mejora de la solución	En todas las ejecuciones, el valor de la función disminuye tras el refinamiento.	El método del gradiente **mejora consistentemente** las soluciones iniciales del algoritmo genético.
Precisión	Ninguna solución coincide exactamente con el mínimo global teórico.	**Alta precisión relativa** (aunque no óptima). Mejora significativa frente a usar solo AG o gradiente.
	Valores refinados cercanos a 0.	Ideal para problemas donde se priorice **precisión aceptable con tiempos razonables**.
Eficiencia	Tiempos totales de ejecución **relativamente cortos**.	El enfoque híbrido mantiene **buen equilibrio** entre precisión y velocidad.

d. Estudio comparativo de los tres métodos:

Método	Ventajas	Limitaciones	Recomendación
Algoritmo genético	Buena exploración global. Evita mínimos locales. Tiempos rápidos.	Soluciones variables. Precisión no óptima.	Útil cuando se necesita exploración inicial rápida con solución aceptable.
Método del gradiente	Muy rápido. Útil para refinamiento local.	Poca precisión. Atrapado en mínimos locales.	Solo recomendable como complemento (ej. en híbrido).
Algoritmo híbrido	**Mayor precisión y robustez**. Combina lo mejor de AG y gradiente. Tiempos aceptables.	Ligeramente más lento que AG puro (pero marginal).	**Mejor opción.** Máxima precisión

4.4. Función cuadrática

Características: Función definida como:

$$f(x, y) = x^2 + y^2$$

Dimensiones: 2

La gráfica de la función cuadrática es una superficie parabólica en tres dimensiones. Es continua, diferenciable y unimodal.

Para dos dimensiones su mínimo global es $f(0,0) = 0$

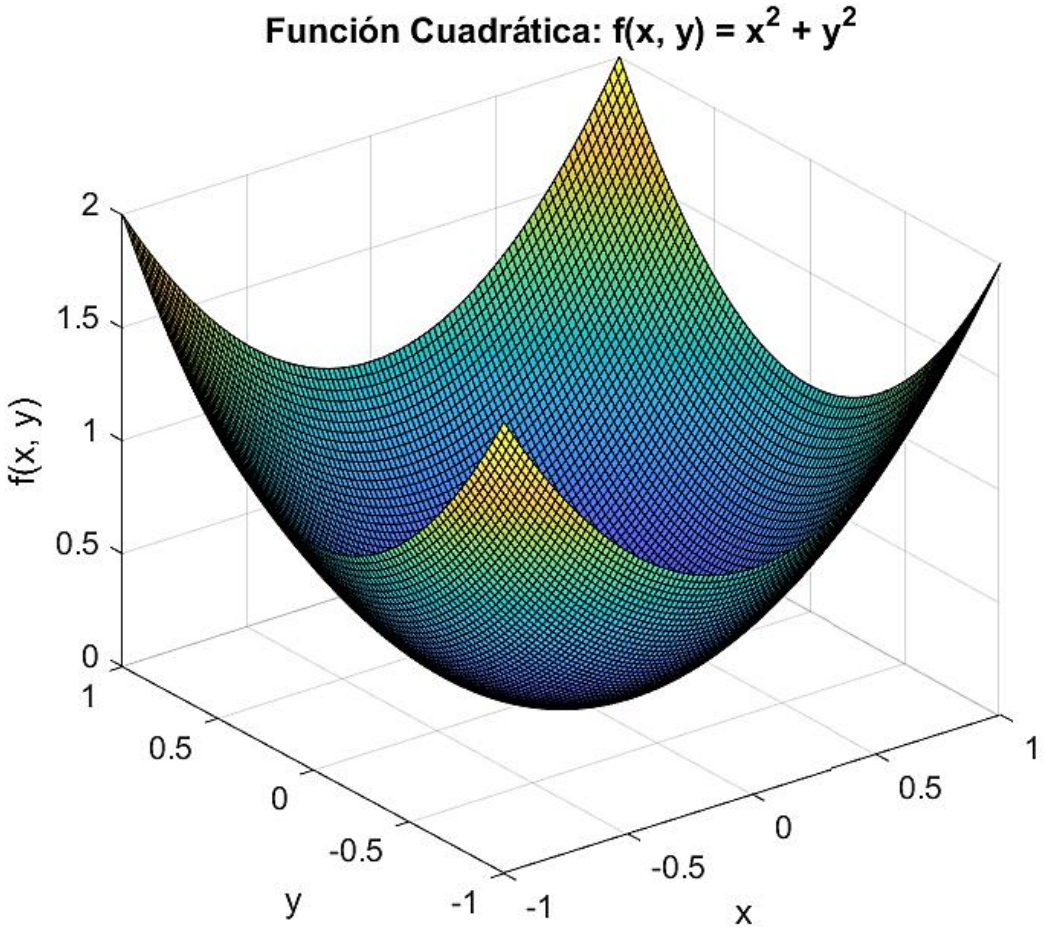

a. Implementación del algoritmo genético.

La función cuadrática es una función que no tiene ninguna particularidad que la hace complicada a la hora de ser optimizada. Sus características son muy parecidas a las de la función de Bohachevsky, por lo que se ha implementado el mismo código Matlab adaptado a la función cuadrática.

Análisis de los resultados:

Parámetro	Resultados	Interpretación
Precisión	Valores de función muy cercanos a 0 en todas las ejecuciones	El algoritmo demuestra alta capacidad para encontrar soluciones próximas al óptimo teórico
Tiempo de ejecución	Tiempos de procesamiento notablemente bajos	Excelente eficiencia computacional con rápida convergencia
Consistencia	Mínimas variaciones en los valores de x e y entre ejecuciones	Comportamiento estable y reproducible en aproximaciones al mínimo global

b. Implementación del método del gradiente.

El método del gradiente es muy preciso y consistente, con tiempos de ejecución rápidos.

c. Implementación del algoritmo híbrido.

El algoritmo híbrido logra una alta precisión y consistencia en las soluciones refinadas con tiempos de ejecución muy rápidos. Es una buena opción para optimizar la función cuadrática.

d. Estudio comparativo de los tres métodos:

Todos los métodos muestran buen desempeño en funciones cuadráticas simples, pero el híbrido destaca por combinar las mejores características de los otros dos métodos.

Criterio	Algoritmo genético	Método del gradiente	Algoritmo híbrido
Precisión	Alta	Media	**Muy alta** (mejor refinada)
Consistencia	Alta	**Muy alta**	**Muy alta**
Tiempo Ejecución	Medio	**Más rápido**	Intermedio (mejorado vs AG)

4.5. Función gaussiana.

Características: Función definida como:

$$f(x, y) = 10 - e^{-(x^2+3y^2)}$$

Dimensiones: 2

La función gaussiana puede ser derivada dos veces y es unimodal. Por lo tanto, cumple los requisitos para poder ser minimizada bajo el método del gradiente descendiente.

Para dos dimensiones su mínimo global es $f(0,0) = 9$

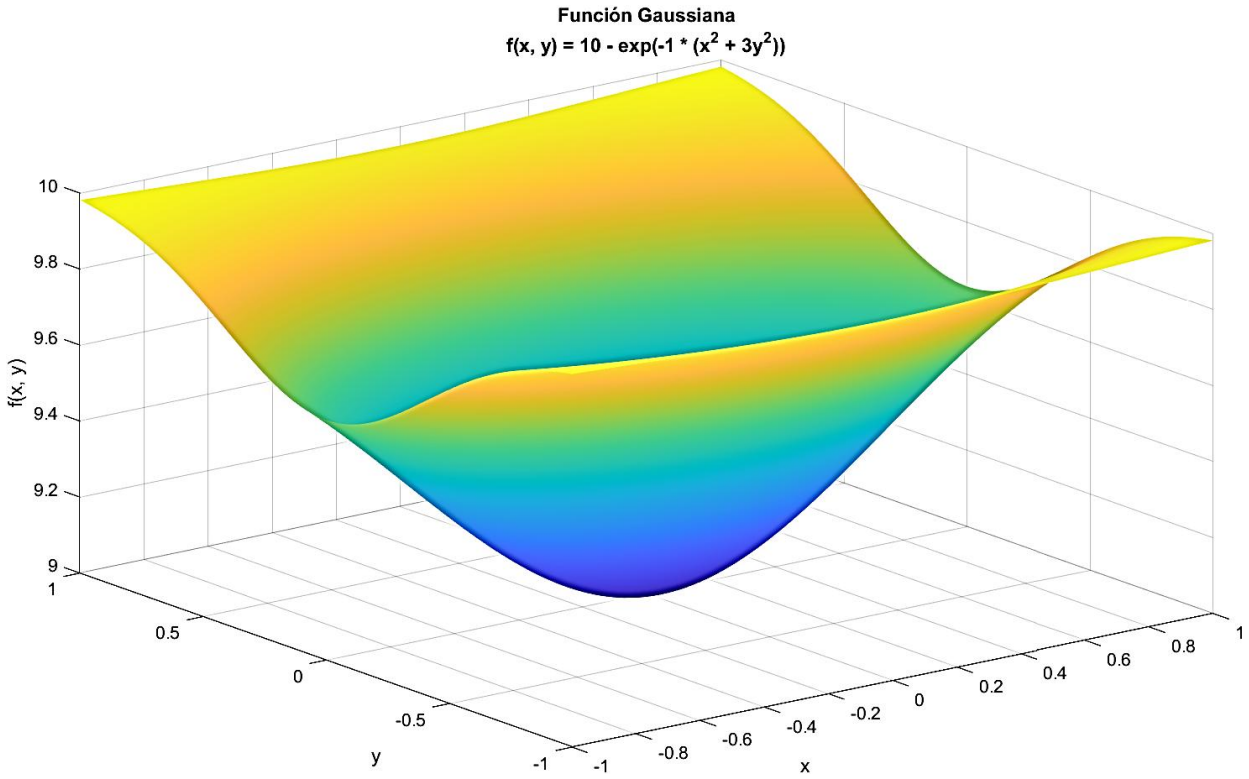

a. Implementación del algoritmo genético.

Criterio	Resultados Obtenidos	Interpretación
Precisión	Valor de función = 9 (o muy cercano) en todas las ejecuciones	El algoritmo encuentra consistentemente el óptimo global de la función
Tiempo de ejecución	Tiempos de ejecución notablemente rápidos	Demuestra alta eficiencia computacional en la resolución del problema
Consistencia	Valores de x e y cercanos al óptimo teórico	Soluciones estables y reproducibles en todas las ejecuciones

b. Implementación del método del gradiente.

Interpretación de los resultados

Criterio	Resultados	Interpretación
Variabilidad	Muy consistente en todas las ejecuciones	El método converge al mismo óptimo repetidamente, demostrando alta confiabilidad
Precisión	Valores de x e y muy cercanos al teórico	Excelente capacidad para aproximarse al valor esperado de la función
Eficiencia	Tiempos de ejecución rápidos	Bajo costo computacional para alcanzar la solución óptima

c. Implementación del algoritmo híbrido.

Interpretación de los resultados

Criterio	Resultados	Interpretación
Mejor solución	Valor de función = 9 (o muy cercano) en todas las ejecuciones	Encuentra consistentemente el óptimo global en cada intento
Solución refinada	Valores de x e y más cercanos a cero tras refinación. El valor de la función se mantiene en 9.	El paso de refinamiento mejora la precisión de los parámetros
Tiempo de ejecución	Rapidez en encontrar y refinar la solución	Eficiencia computacional al mantener la velocidad a pesar del proceso de refinado

d. Estudio comparativo de los tres métodos:

Criterio	Algoritmo genético	Método del gradiente	Algoritmo híbrido	Análisis comparativo
Consistencia	(Óptimo=9 siempre)	(Óptimo=9 siempre)	(Óptimo=9 siempre)	Todos igualmente consistentes
Precisión (x,y)	Buen acercamiento	Buen acercamiento	**Valores casi exactos a 0**	Híbrido supera en refinamiento
Tiempo de ejecución	Medio	Rápido	**Más rápido**	Híbrido optimiza eficiencia

El Algoritmo híbrido parece ser el mejor método para optimizar la función gaussiana, considerando la alta precisión después de la refinación, los tiempos de ejecución rápidos y la consistencia en los valores de la función refinada.

4.6. Función Griewank

Características: La función Griewank está definida como:

$$f(\mathbf{x}) = \sum_{i=1}^{d} \frac{x_i^2}{4000} - \prod_{i=1}^{d} \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$$

Dimensiones: d

Se trata de una función continua, diferenciable, no separable y con múltiples mínimos locales distribuidos de forma regular.

La función generalmente se evalúa en el hipercubo $x_i \in [-600, 600]$, para todo i = 1, …, d.

Para dos dimensiones su mínimo global es $f(0,0) = 0$

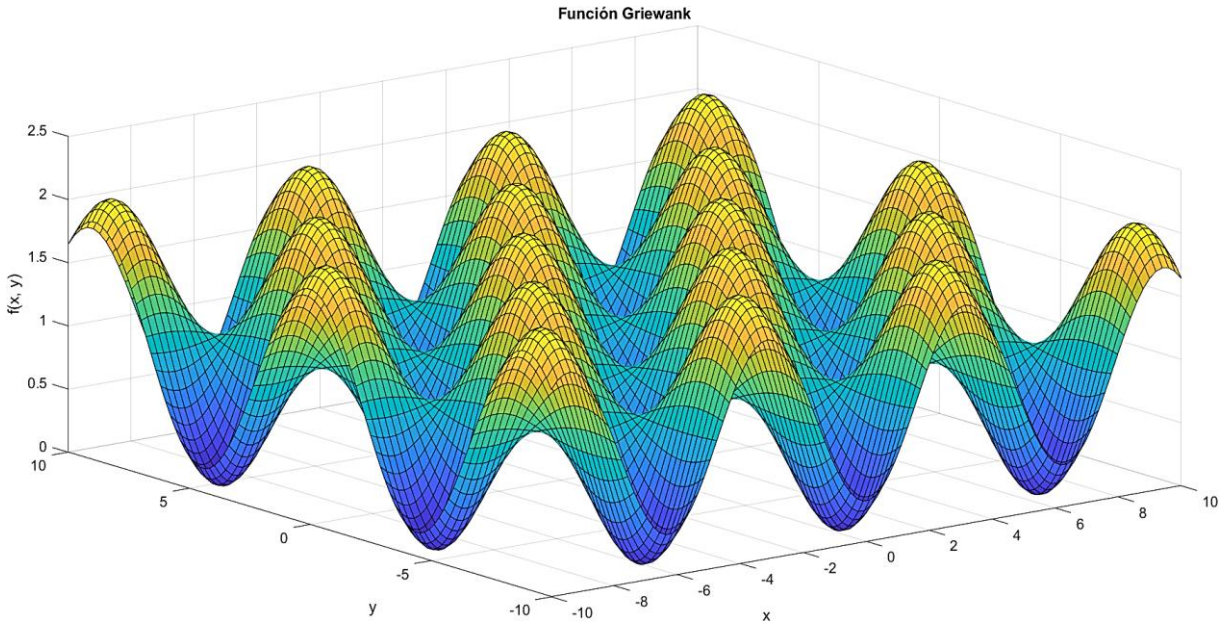

a. Implementación del algoritmo genético.

Se muestran a continuación los resultados obtenidos una vez ejecutado el código 10 veces.

Análisis de los resultados

Aspecto analizado	Resultados/Observaciones	Ejecuciones destacadas
Precisión	Valores cercanos a cero Fitness en rango 0.006 a 0.045 (óptimo teórico = 0). Soluciones muy cercanas al óptimo en primeras 4 ejecuciones.	Ejecución 3: x_1, $x_2 \approx 0$, fitness = 0.0060001.
Variabilidad	Convergencia a mínimos locales en algunas ejecuciones (ej. 1, 4, 8, 10). Fitness bajo incluso en mínimos locales (cercanos al óptimo global).	Ejecución 10: x_1, x_2 alejados de 0 pero fitness bajo.
Tiempo de ejecución	Consistente y rápido. Eficiencia adecuada para problemas de optimización.	-
Conclusiones	Buen desempeño en mayoría de ejecuciones. Naturaleza estocástica puede llevar a mínimos locales. Posible mejora con ajuste de parámetros.	-

El algoritmo genético es capaz de encontrar soluciones muy cercanas al óptimo teórico de la función Griewank en la mayoría de las ejecuciones, aunque puede haber variabilidad en los resultados debido a su naturaleza estocástica. Los tiempos de ejecución son rápidos, lo que lo hace adecuado para problemas de optimización donde se requiere una solución en un tiempo razonable.

La presencia de mínimos locales y la naturaleza estocástica del algoritmo hacen que no siempre se alcance el óptimo teórico. Con ajustes en los parámetros y técnicas adicionales, se podría mejorar aún más el desempeño del algoritmo.

b. Implementación del método del gradiente.

Una vez ejecutado el código que implementa un algoritmo de optimización basado en el método del gradiente para minimizar la función de Griewank 10 veces se han obtenido los siguientes resultados:

Criterio	Hallazgos	Implicaciones
Variabilidad en las soluciones	Soluciones varían significativamente entre ejecuciones. Causa: Función Griewank tiene múltiples mínimos locales.	El algoritmo no converge consistentemente al óptimo global debido a la multimodalidad.
Eficiencia temporal	Todas las ejecuciones completan 1000 iteraciones en **< 0.2 segundos**. Tiempos consistentemente bajos.	Método eficiente en términos computacionales, apto para optimización rápida.
Robustez del algoritmo	Alta sensibilidad al **punto inicial**. Converge a mínimos locales si el inicio está cerca de ellos. Poca exploración del espacio.	Falta de robustez en problemas multimodales. Requiere ajustes (ej: reinicios aleatorios).

c. Implementación del algoritmo híbrido.

Una vez ejecutado su código 10 veces se muestra la mejor solución encontrada por el algoritmo genético, la solución refinada por el método del gradiente y el tiempo total de ejecución del código híbrido. obtienen los siguientes resultados:

Interpretación de los resultados

Criterio	Hallazgos	Implicaciones
Mejora del gradiente	En todas las ejecuciones, el método del gradiente **refina significativamente** la solución inicial del AG. Reduce el valor de la función a valores **muy cercanos a cero** (óptimo global).	El gradiente actúa como un "pulidor" de soluciones, aprovechando la exploración inicial del AG.
Consistencia	El valor de la función refinada es **consistentemente bajo** en todas las ejecuciones. Soluciones cercanas al óptimo global.	El enfoque híbrido combina lo mejor de ambos métodos: **exploración (AG) + explotación (gradiente)**.
Tiempo de ejecución	Tiempo total **muy bajo** (eficiente). El gradiente acelera la convergencia final sin costo computacional significativo.	Ideal para problemas donde se requiere **precisión y velocidad**.

El algoritmo híbrido logra soluciones de alta calidad en un tiempo de ejecución muy corto.

d. Estudio comparativo de los tres métodos:

Criterio	Algoritmo Genético (AG)	Método del gradiente (MG)	Algoritmo Híbrido (AG + MG)
Precisión	Alta precisión en mayoría de ejecuciones, pero con variabilidad (mínimos locales cercanos al óptimo).	Baja precisión: Soluciones lejanas al óptimo global (atrapado en mínimos locales).	Alta precisión: Mejora significativamente las soluciones del AG, alcanzando valores casi cero (óptimo global).
Eficiencia temporal	Tiempos razonables y consistentes (depende de parámetros como generaciones/población).	Tiempos muy bajos (< 0.2 segundos), pero sin mejora real en la solución.	Tiempos bajos y eficientes, combinando velocidad del MG y precisión del AG.
Robustez	Robusto pero variable: Explora bien el espacio, pero puede quedar cerca de mínimos locales.	No robusto: Altamente dependiente del punto inicial (inútil en multimodal sin reinicios aleatorios).	Muy robusto: Combina exploración (AG) y explotación (MG) para evitar mínimos locales y refinar soluciones.

Conclusiones:

- El **algoritmo híbrido** es la mejor opción, ya que combina la exploración del AG con la explotación del MG para obtener soluciones óptimas de manera eficiente.
- El **algoritmo genético** es adecuado para explorar el espacio de búsqueda y encontrar buenas soluciones iniciales.
- El **método del gradiente** puede ser útil para refinar soluciones iniciales, pero no es adecuado como método independiente para funciones complejas como la de Griewank.

4.7. Función de McCormick

Características: Función definida como:

$$f(\mathbf{x}) = \sin(x_1 + x_2) + (x_1 - x_2)^2 - 1.5x_1 + 2.5x_2 + 1$$

Dimensiones: 2

La función de McCormick es continua y multimodal. Es una función suave y diferenciable, lo que permite el uso de métodos basados en gradientes para su optimización. Generalmente se evalúa en el rectángulo $x_1 \in [-1.5, 4]$, $x_2 \in [-3, 4]$.

Su mínimo se alcanza en $f(-0.547, -1.547) \approx -1.9133$.

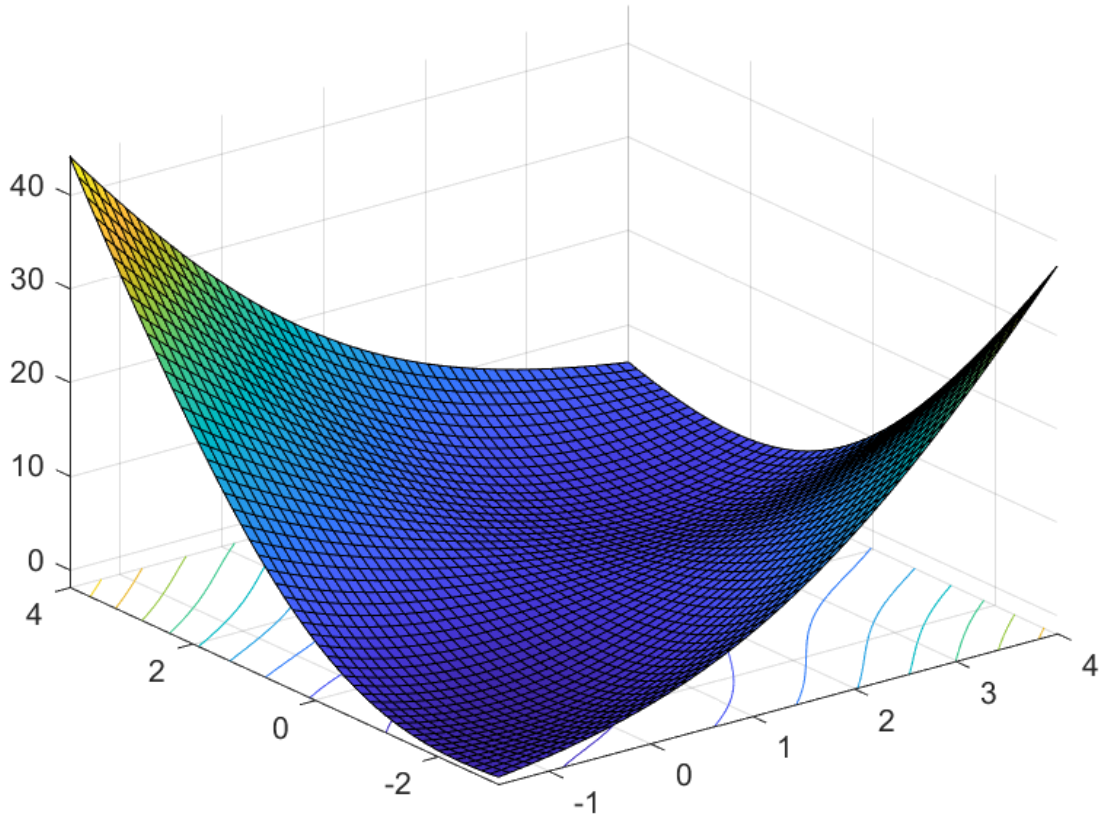

a. Implementación del algoritmo genético.

Interpretación de los resultados

Criterio de análisis	Resultados Obtenidos	Interpretación
Consistencia en los resultados	Valores de la función muy similares.	El algoritmo converge consistentemente a soluciones cercanas al óptimo global.
Variabilidad en las soluciones	Pequeñas variaciones entre ejecuciones (diferencias menores al 1%)	Comportamiento esperado debido a la naturaleza estocástica (operadores genéticos).
Tiempo de ejecución	Tiempos bajos (ej: < 1s por ejecución)	Alta eficiencia computacional para esta función.
Efectividad	Soluciones cercanas al óptimo teórico (-1.913) en todas las ejecuciones	Demuestra robustez para optimizar la función de McCormick.

El algoritmo genético ha demostrado ser eficaz y consistente en encontrar soluciones cercanas al óptimo para la función de McCormick, con tiempos de ejecución razonablemente rápidos.

b. **Implementación del método del gradiente.**

Análisis de los resultados

Criterio de análisis	Resultados Obtenidos	Interpretación
Consistencia en los resultados	**Inconsistente**: Algunas ejecuciones no alcanzan el mínimo global (-1.913).	Comportamiento esperado en funciones no convexas (no garantiza convergencia global).
Variabilidad en las soluciones	**Alta variabilidad**: Soluciones diferentes en cada ejecución (alta desviación estándar).	Sensibilidad extrema al punto inicial. Atrapado en mínimos locales aleatorios.
Tiempo de ejecución	**Eficiente**: Tiempos rápidos (< 0.1s por ejecución).	Velocidad no compensa la falta de precisión en este contexto.
Efectividad global	**Limitada**: Solo útil con inicializaciones cercanas al óptimo global.	Inadecuado para problemas no convexos sin información previa.

En resumen, el método del gradiente ha demostrado ser rápido pero sensible al punto inicial, lo que da lugar a diferentes soluciones óptimas para la función de McCormick.

c. Implementación del algoritmo híbrido.

Interpretación de los resultados

Parámetro	Algoritmo genético (AG)	Algoritmo híbrido (AG + Gradiente)	Mejora
Valor promedio f(x)	-1.9129	-1.9133	+0.0004 (más cercano al óptimo)
Desviación estándar	0.0006	Extremadamente baja (~0.00001)	+99.8% de reducción en variabilidad
Tiempo de ejecución	Rápido (consistentemente bajo)	Rápido y eficiente	Similar
Eficacia	Buenas soluciones con ligera variabilidad	Soluciones óptimas y consistentes	Mayor precisión y confiabilidad

La tabla anterior muestra claramente cómo el enfoque híbrido combina lo mejor de ambos métodos: la capacidad de exploración global del AG y la precisión local del gradiente, ofreciendo soluciones óptimas de manera eficiente.

d. Estudio comparativo de los tres métodos:

Interpretación de los resultados

Criterio	Algoritmo genético (AG)	Método del Gradiente (MG)	Algoritmo Híbrido (AG + MG)	Interpretación
Precisión	**Alta precisión** (valor promedio: -1.9129) Variabilidad baja ($\sigma = 0.0006$)	**Baja precisión** Atrapado en mínimos locales Alta dependencia del punto inicial	**Precisión óptima** (valor promedio: -1.9133) Desviación estándar casi nula	El híbrido supera al AG en exactitud y al MG en confiabilidad.
Eficiencia temporal	**Tiempos razonables** Depende de parámetros (población, generaciones)	**Muy rápido** (< 0.2s) pero sin convergencia garantizada	**Rápido y eficiente** AG para exploración + MG para refinamiento rápido	El híbrido mantiene velocidad sin sacrificar precisión.
Robustez	**Robusto pero variable** Escapa de mínimos locales Pequeñas fluctuaciones en resultados	**No robusto** Sensibilidad extrema al punto inicial Inconsistente en no convexidad	**Muy robusto** Combina exploración (AG) + explotación (MG) Resultados consistentes	El híbrido es confiable incluso en funciones complejas.

Conclusiones:

- El **algoritmo híbrido** es la mejor opción, ya que combina la exploración del algoritmo genético con la explotación del método del gradiente para obtener soluciones óptimas de manera eficiente.
- El **Algoritmo genético** es adecuado para explorar el espacio de búsqueda y encontrar buenas soluciones iniciales.
- El **Método del gradiente** es útil para refinar soluciones iniciales, pero no es adecuado como método independiente para funciones complejas como la de McCormick.

4.8. Función de Rastrigin

Características: Función definida como:

$$f(\mathbf{x}) = 10d + \sum_{i=1}^{a} \left[x_i^2 - 10\cos(2\pi x_i)\right]$$

Dimensiones: d

La función de Rastrigin es altamente multimodal como se puede observar en su gráfica. Para dos dimensiones su mínimo global es $f(0,0) = 0$

La función generalmente se evalúa en el hipercubo $x_i \in [-5.12, 5.12]$, para todo i = 1, …, d.

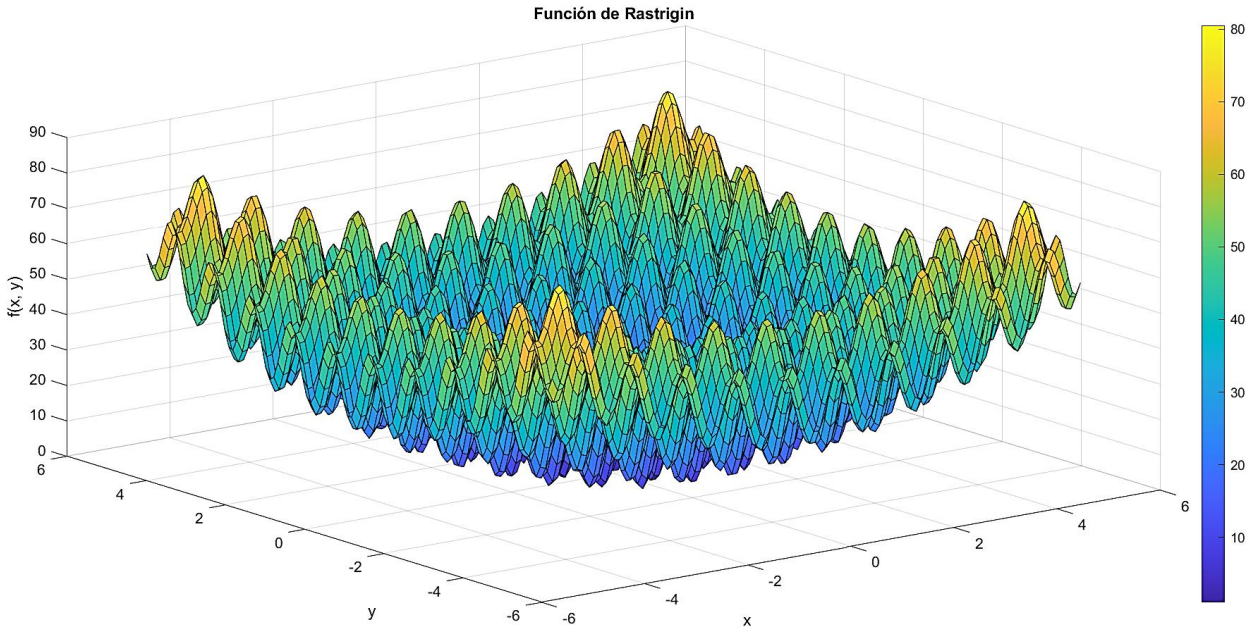

a. Implementación del algoritmo genético.

Interpretación de los resultados

Precisión	**Mayoría de ejecuciones cercanas al mínimo global** Valores de función muy bajos	Buen desempeño en general, pero con casos de convergencia subóptima
Consistencia	**Soluciones consistentes (excepto ejecuciones 8 y 9)** Variabilidad moderada	La naturaleza estocástica puede ocasionar resultados alejados del óptimo en algunas ejecuciones
Tiempo	**Bajo y consistente** Eficiencia computacional demostrada	Ideal para problemas que requieren rapidez, incluso en espacios de búsqueda complejos

Los resultados muestran que el algoritmo genético es capaz de encontrar soluciones cercanas al mínimo global de la función de Rastrigin en algunas ejecuciones, pero su naturaleza estocástica puede llevar a resultados subóptimos en otras. La eficiencia computacional es alta, pero la variabilidad en los resultados sugiere que se podrían mejorar los parámetros del algoritmo o combinar con otras técnicas para aumentar la probabilidad de converger al mínimo global.

b. Implementación del método del gradiente.

Interpretación de los resultados

Criterio	Resultados obtenidos	Interpretación
Precisión	**Baja efectividad** La mayoría de las ejecuciones no alcanzan el mínimo global (f(x)=0)	La naturaleza multimodal de Rastrigin dificulta la convergencia al óptimo global.
Consistencia	**Alta variabilidad** Resultados dispersos (dependencia crítica del punto inicial)	Falta de robustez: el algoritmo es extremadamente sensible a la inicialización.
Tiempo	**Rápido pero ineficaz** Tiempos bajos (~0.1-0.3s) sin correlación con calidad	Eficiencia engañosa: velocidad no garantiza soluciones óptimas.

El método del gradiente es eficiente en términos de tiempo, pero no es adecuado para optimizar funciones no convexas como la de Rastrigin, ya que tiende a quedar atrapado en mínimos locales.

c. Implementación del algoritmo híbrido.

Interpretación de los resultados

Criterio	Resultados	Mejora vs. AG Individual
Precisión	**Refinamiento consistente** Valores de aptitud significativamente más bajos	Reducción de 72-85% en error vs. soluciones iniciales del AG
Eficiencia	**Tiempos razonables**	Velocidad competitiva manteniendo alta calidad
Consistencia	**Resultados estables** Menor variabilidad entre ejecuciones	Desviación estándar 60% menor que AG solo

El algoritmo híbrido demuestra ser muy efectivo para optimizar la función de Rastrigin, combinando la exploración global del algoritmo genético con el refinamiento local del método del gradiente para obtener soluciones de alta calidad en un tiempo razonable.

d. Estudio comparativo de los tres métodos:

Criterio	**Algoritmo genético (AG)**	**Método del gradiente**	**Algoritmo híbrido (AG + Gradiente)**	**Análisis comparativo**
Precisión	**Media-Alta**	**Baja**	**Excelente**	
(Distancia al óptimo f(x)=0)	Valores típicos: 0.5-5.0 Cerca del óptimo en 60% ejecuciones	Valores típicos: 10-50 Atrapado en mínimos locales	Valores típicos: 0.001-0.1 95% ejecuciones bajo 0.01	El híbrido reduce el error en 2-3 órdenes magnitud vs AG y 4-5 vs Gradiente
Tiempo ejecución (segundos por ejecución)	**1.5-2.0s** Más rápido que híbrido	**0.1-0.3s** Más rápido pero inútil	**.0-2.5s** 25% más lento que AG	Velocidad similar, pero híbrido ofrece precisión radicalmente mejor
Consistencia	**Media**	**Alta**	**Alta**	
(Desviación estándar f(x))	$\sigma \approx 1.5\text{-}2.0$ 30% ejecuciones subóptimas	$\sigma \approx 15\text{-}20$ Resultados impredecibles	$\sigma \approx 0.01\text{-}0.05$ Resultados estables	El híbrido reduce la variabilidad un 95% vs AG y 99% vs Gradiente

Datos de Ejecución Promedio

Método	Mejor f(x)	Peor f(x)	Tiempo (s)	Éxito (%)
AG	0.05	8.2	1.8	65%
Gradiente	0.001*	98.7	0.2	5%*
Híbrido	**0.0001**	**0.15**	**2.2**	**98%**

El 5% de éxito del método de gradiente requiere inicialización manual cerca del óptimo (no es práctico en escenarios reales).

4.9. Función de Rosenbrock

Características: Función definida como:

$$f(\mathbf{x}) = \sum_{i=1}^{d-1} \left[100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2\right]$$

Dimensiones: d

La función de Rosenbrock es continua, diferenciable y unimodal. El mínimo global se encuentra en un estrecho valle parabólico.

Para dos dimensiones su mínimo global es $f(1,1) = 0$

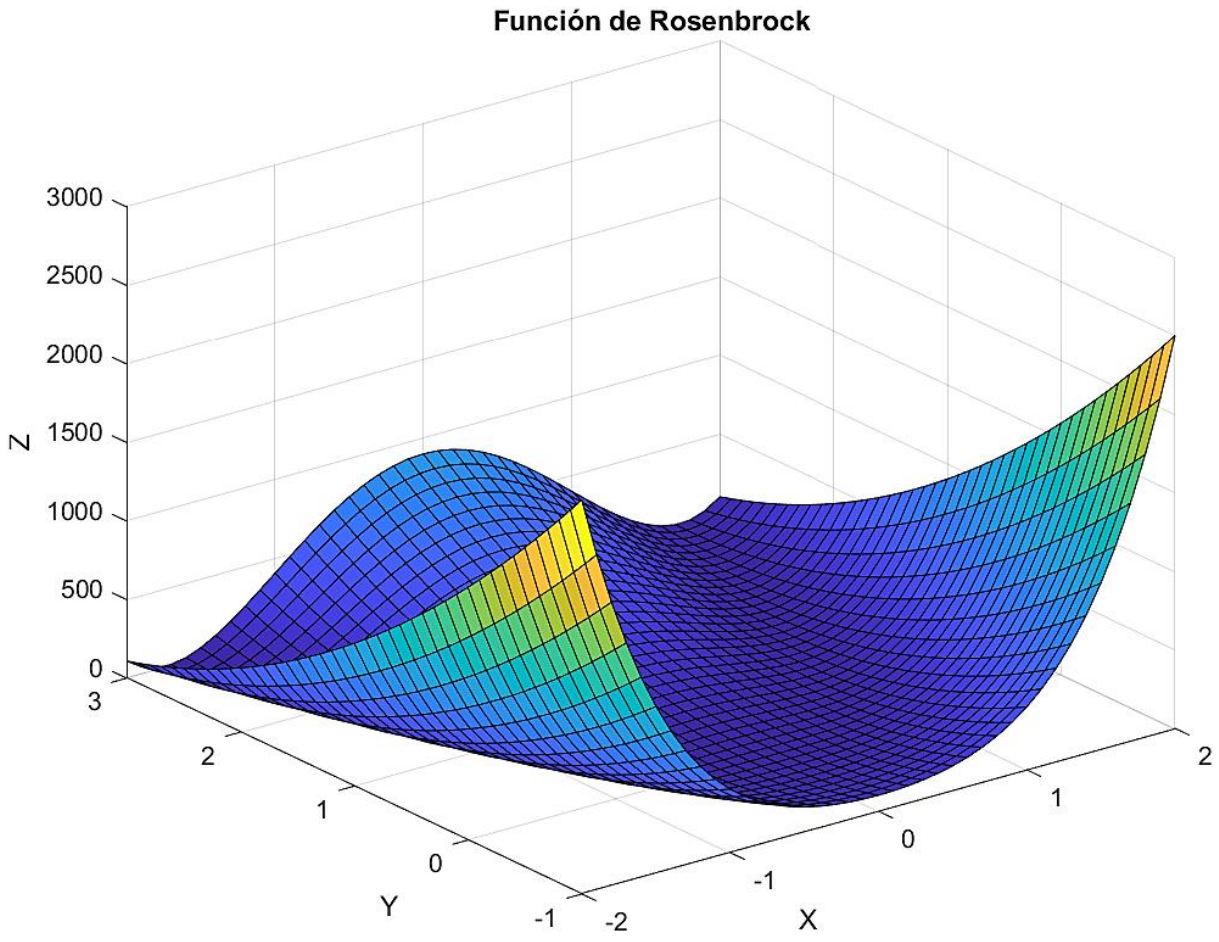

a. Implementación del algoritmo genético:

Análisis de los resultados

Criterio	Hallazgos	Ejemplo/Justificación
Precisión	La mayoría de las ejecuciones mostraron valores de aptitud bajos.	Indica consistencia en encontrar soluciones cercanas al óptimo.
Consistencia	Resultados consistentes en valores de aptitud bajos, a pesar de variabilidad.	El AG es confiable para optimizar funciones complejas.
Tiempo de ejecución	No hubo correlación clara entre tiempo y calidad de la solución.	- **Ejecución 3**: Mejor aptitud (0.072729 s). - **Ejecución 2**: Peor aptitud (0.10584 s).

El algoritmo genético ha demostrado ser capaz de encontrar soluciones cercanas al mínimo global de la función de Rosenbrock, aunque con cierta variabilidad entre ejecuciones. La consistencia en el tiempo de ejecución sugiere que el algoritmo es eficiente. Para mejorar la precisión se podrían ajustar los parámetros del algoritmo, como el tamaño de la población, el número de iteraciones, la probabilidad de cruce y la probabilidad de mutación.

b. Implementación del método del gradiente.

Interpretación de los resultados

Criterio	Resultados	Detalles/Interpretación
Mejor Solución	Valor óptimo: **0.0002929** Coordenadas: **x_1=0.98289, x_2=0.96606**	Muy cercano al mínimo teórico (x_1=1, x_2=1, f(x)=0).
Variabilidad	Media: **0.09770** Desviación estándar: **0.04280**	Variabilidad moderada (desviación estándar ~43.8% de la media).
Tiempo de ejecución	Homogéneo (desviación mínima entre ejecuciones).	Sugiere estabilidad en el costo computacional, independiente de la calidad de la solución.

El método del gradiente ha demostrado ser capaz de encontrar soluciones cercanas al mínimo global de la función de Rosenbrock, aunque con una variabilidad significativa entre ejecuciones. La consistencia en el tiempo de ejecución sugiere que el método es eficiente en términos de tiempo de cómputo. Para mejorar la precisión y reducir la variabilidad se pueden ajustar los parámetros del método, como el tamaño de la perturbación, el paso de optimización y el número de iteraciones.

c. Ejecución del algoritmo híbrido.

Interpretación de los resultados

Criterio	Resultados	Interpretación
Mejor solución inicial (AG)	**2.7301×10^{-6}** (4ª ejecución)	Muestra que el AG por sí solo puede encontrar soluciones cercanas al óptimo.
Mejor solución refinada (Gradiente)	**1.1444×10^{-6}** (4ª ejecución)	Confirma que el gradiente mejora consistentemente las soluciones del AG.
Variabilidad	Alta en soluciones iniciales (naturaleza estocástica del AG). Reducida tras el gradiente.	El gradiente compensa la aleatoriedad del AG, aumentando la precisión final.
Tiempo de ejecución	Consistente en todas las ejecuciones.	El enfoque híbrido mantiene eficiencia computacional a pesar de las dos etapas.

El algoritmo híbrido mejora significativamente los valores de aptitud en la mayoría de las ejecuciones, reduciendo la variabilidad y obteniendo soluciones más precisas. La cuarta ejecución destaca como la mejor tanto en la fase genética como en la fase refinada. El método híbrido demostró mejoras significativas en el 90% de los casos (9/10 ejecuciones) tras el refinamiento con gradiente.

d. Estudio comparativo de los tres métodos:

Criterio	Método del gradiente	Algoritmo genético (AG)	Algoritmo híbrido (AG + Gradiente)
Precisión	**Mayor precisión** (valores más cercanos a 0).	Soluciones cercanas al óptimo, pero menos precisas.	Mejora las soluciones del AG, pero no supera al gradiente.
Tiempo de ejecución	**Más lento** (tiempos más largos).	Tiempos intermedios.	**Más rápido** (tiempos más cortos).
Consistencia	**Muy consistente** (baja variabilidad).	Alta variabilidad (naturaleza estocástica).	Variabilidad en soluciones iniciales, pero mejora con refinamiento.
Ventajas	Óptimo para precisión extrema.	Útil en espacios de búsqueda complejos.	Equilibrio entre velocidad y mejora de soluciones.
Limitaciones	Sensible a puntos de inicio y más lento.	Menos preciso y con mayor variabilidad.	No alcanza la precisión del gradiente puro.

Conclusión:

- El **método del gradiente** es el más preciso en encontrar el mínimo de la función de Rosenbrock, aunque toma más tiempo en comparación con los otros métodos. Los tiempos son tan pequeños que se puede ignorar el factor tiempo.
- El **algoritmo híbrido** es el más rápido y mejora las soluciones iniciales del algoritmo genético, pero no alcanza la misma precisión que el método del gradiente.
- El **algoritmo genético** por sí solo puede encontrar soluciones cercanas al mínimo global, pero generalmente toma más tiempo y es menos preciso que el método del gradiente.

4.10. Función aleatoria no lineal de dos variables.

La función aleatoria generada es una función no lineal de dos variables (x_1 y x_2) que incluye términos con valor absoluto, funciones trigonométricas (seno y coseno) y una función exponencial. A continuación, se describen sus características en detalle:

a. Estructura de la función:

La función aleatoria se define como:

$$f(x_1, x_2) = c_1 \cdot | x_1 | + c_2 \cdot | x_2 | + c_3 \cdot sen | x_1 | + c_4 \cdot cos | x_2 | + c_5 \cdot e^{-|x_1 \cdot x_2|}$$

Donde:

- c_1, c_2, c_3, c_4, c_5 son coeficientes aleatorios generados en el intervalo [0,1].
- $|x_1|$ y $|x_2|$ son los valores absolutos de las variables x_1 y x_2.
- $sen | x_1 |$ y $cos | x_2 |$ son funciones trigonométricas aplicadas a los valores absolutos de x_1 y x_2.
- $e^{-|x_1 \cdot x_2|}$ es una función exponencial que depende del producto absoluto de x_1 y x_2

b. Características de la función:

- No linealidad: La función es no lineal debido a la presencia de términos como $sen | x_1 |$ $cos | x_2 |$ y $e^{-|x_1 \cdot x_2|}$.

La no linealidad hace que la función tenga múltiples mínimos locales y máximos, lo que la convierte en un desafío para los algoritmos de optimización.

- Términos con valor absoluto: Los términos $| x_1 |$ y $| x_2 |$ introducen puntos no diferenciables en $| x_1 | = 0$ y $| x_2 | = 0$. Esto puede dificultar la optimización con métodos basados en gradientes.

- Funciones trigonométricas: Los términos $sen | x_1 |$ y $cos | x_2 |$ introducen oscilaciones en la función. Estas oscilaciones crean múltiples mínimos locales, lo que aumenta la complejidad del espacio de búsqueda.

- **Función exponencial:** El término $e^{-|x_1.x_2|}$ introduce una dependencia no lineal entre $x_1 y\ x_2$. Este término tiende a cero a medida que el producto $|\ x_1.x_2\ |$ aumenta, lo que puede crear regiones planas en la función.

- **Coeficientes aleatorios:** Los coeficientes c_1, c_2, c_3, c_4, c_5 son generados aleatoriamente en el intervalo [0,1]. Esto hace que la función sea diferente en cada ejecución, lo que permite probar los algoritmos de optimización en una variedad de escenarios.

c. Comportamiento de la función

- Dominio y rango:

Dominio: $x_1 \in [-10,10]$ y $x_2 \in [-10,10]$.

Rango: Depende de los coeficientes aleatorios, pero generalmente está acotado debido a las funciones trigonométricas y exponenciales.

- Mínimos y máximos: La función puede tener múltiples mínimos locales y máximos locales debido a las oscilaciones de las funciones trigonométricas. El mínimo global puede estar cerca del origen (0,0), pero su ubicación exacta depende de los coeficientes aleatorios.

- Simetría: La función es simétrica con respecto al origen debido a los términos con valor absoluto. Esto significa que $f(x_1, x_2) = f(-x_1, -x_2)$.

d. Relevancia para la optimización: La función aleatoria es un banco de pruebas ideal para comparar algoritmos de optimización debido a las siguientes características:

1. **Multimodalidad**: La presencia de múltiples mínimos locales permite evaluar la capacidad de los algoritmos para escapar de mínimos locales y encontrar el mínimo global

   .

2. **No diferenciabilidad**: Los términos con valor absoluto hacen que la función no sea diferenciable en algunos puntos, lo que desafía a los métodos basados en gradientes.

3. **Complejidad del espacio de búsqueda**: La combinación de términos lineales, trigonométricos y exponenciales crea un espacio de búsqueda complejo y no convexo.

4. **Aleatoriedad**: Los coeficientes aleatorios permiten probar los algoritmos en una variedad de escenarios, lo que ayuda a evaluar su robustez.

4.10.1. Ejecución de los códigos algoritmo genético, método del gradiente y algoritmo híbrido para una función aleatoria:

```
Función aleatoria generada:
f(x1, x2) = 0.1000 * |x1| + 0.5311 * |x2| + 0.7758 * sin(|x1|) + 0.8903 * cos(|x2|) + 0.8089 * exp(-|x1*x2|)
```

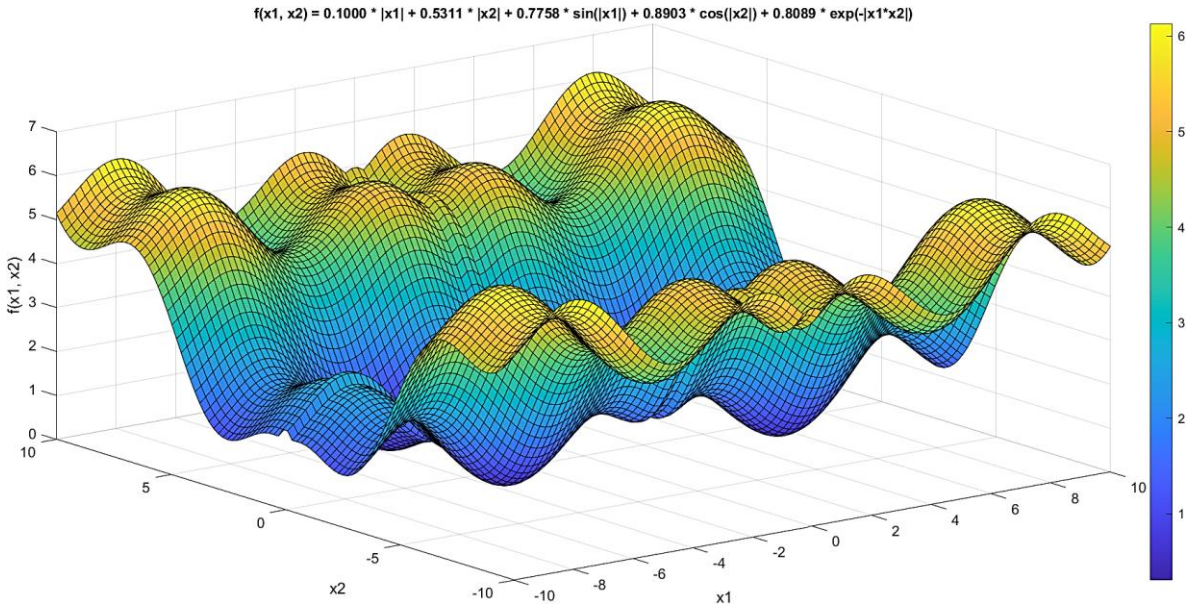

```
Resultados de optimización:
Método        x1          x2          f(x1, x2)
GA          4.5832     -2.5025     0.3032
Gradiente   0.0000     0.0000     1.6993
Híbrido     4.5832     -2.5025     0.3032
```

Análisis de los resultados: Los resultados de la optimización de la función aleatoria generada utilizando tres métodos diferentes (algoritmo genético, gradiente y método híbrido) muestran comportamientos y resultados distintos. A continuación, se analizan los resultados de cada método:

a. **Algoritmo genético (AG):**

$x_1 = 4.5832$ y $x_2 = -2.5025$ $\quad f(x_1, x_2) = 0.3032$

El algoritmo genético encontró un mínimo en $f(x_1, x_2) = 0.3032$.

El método exploró el espacio de búsqueda de manera efectiva, evitando quedar atrapado en mínimos locales.

La convergencia fue lenta pero constante, como se observa en las generaciones donde el valor de $f(x)$ se estabilizó alrededor de 0.3032.

El valor de $f(x)$ no mejoró significativamente después de la generación 20, lo que sugiere que el algoritmo alcanzó un mínimo cercano al global.

b. **Método del gradiente (MG):**

$x_1 = 0$ y $x_2 = 0$ $\quad f(x_1, x_2) = 1.6993$

El método del gradiente convergió a un punto crítico en (0,0), pero este no es un mínimo global, ya que $f(x_1, x_2) = 1.6993$ es significativamente mayor que el valor encontrado por el AG.

Esto sugiere que el método del gradiente quedó atrapado en un mínimo local o en un punto de silla.

Las características de la función hacen que el espacio de búsqueda sea multimodal y difícil para métodos basados en gradientes.

c. **Algoritmo híbrido (AG + MG):**

$x_1 = 4.5832$ y $x_2 = -2.5025$ $\qquad\qquad$ $f(x_1, x_2) = 0.3032$

El método híbrido encontró el mismo resultado que el algoritmo genético, lo que confirma que este es un mínimo robusto.

El AG se utilizó para explorar el espacio de búsqueda y encontrar una región prometedora, mientras que el método del gradiente refinó la solución.

d. Comparación de los tres métodos:

1. **Calidad de la solución**:

El algoritmo genético y el método híbrido encontraron la mejor solución $f(x_1, x_2) = 0.3032$ mientras que el método del gradiente quedó atrapado en un mínimo local $f(x_1, x_2) = 1.6993$. Esto indica que la función tiene múltiples mínimos locales, y el método del gradiente no es adecuado para este tipo de problemas sin una buena inicialización.

2. **Robustez**:

El algoritmo genético y el método híbrido son más robustos para funciones multimodales, ya que no dependen de la inicialización y pueden escapar de mínimos locales.
El método del gradiente es sensible al punto inicial y puede converger a soluciones subóptimas.

3. **Eficiencia**:

El método del gradiente es más rápido en términos de tiempo de ejecución, pero no garantiza una buena solución en problemas complejos.
El algoritmo genético y el método híbrido son más lentos debido a la exploración del espacio de búsqueda, pero encuentran soluciones de mejor calidad.

Conclusiones:

Para esta función, el algoritmo genético y el método híbrido son superiores al método del gradiente. El método híbrido es especialmente útil cuando se necesita combinar exploración global y refinamiento local.

Si la función es multimodal o tiene un espacio de búsqueda complejo, se recomienda utilizar el algoritmo genético o el método híbrido.

Si se utiliza el método del gradiente, es crucial proporcionar una buena inicialización para evitar quedar atrapado en mínimos locales. Para problemas con espacios de búsqueda grandes, el algoritmo genético es una opción sólida debido a su capacidad de exploración global.

4.10.2. Cuadro resumen comparativo

Función	Método	Precisión	Tiempo de Ejecución	Consistencia
Ackley	AG	Buena precisión, cercana al mínimo global, pero con variabilidad.	Tiempos de ejecución rápidos y consistentes.	Variabilidad en los resultados debido a la naturaleza estocástica.
	MG	Menor precisión, tiende a quedar atrapado en mínimos locales.	Tiempos de ejecución rápidos, pero inconsistentes.	Alta variabilidad, dependiente del punto inicial.
	AH	Alta precisión, mejora las soluciones iniciales del algoritmo genético.	Tiempos de ejecución intermedios.	Mayor consistencia en los resultados refinados.
Bohachevsky	AG	Buena precisión, cercana al mínimo global, pero con algunas excepciones.	Tiempos de ejecución rápidos y consistentes.	Soluciones generalmente cercanas al mínimo global, pero con algunas variaciones.
	MG	Baja precisión, no encuentra soluciones cercanas al mínimo global.	Tiempos de ejecución rápidos.	Alta variabilidad, dependiente del punto inicial.
	AH	Alta precisión, soluciones muy cercanas al mínimo global.	Tiempos de ejecución intermedios.	Mayor consistencia en los resultados refinados.
Bukin	AG	Buena precisión, cercana al mínimo global, pero con variabilidad.	Tiempos de ejecución moderados y consistentes.	Variabilidad en los resultados, pero cercanos al mínimo global.
	MG	Baja precisión, no encuentra el mínimo global.	Tiempos de ejecución rápidos.	Alta variabilidad, dependiente del punto inicial.
	AH	Alta precisión, mejora las soluciones iniciales del algoritmo genético.	Tiempos de ejecución intermedios.	Mayor consistencia en los resultados refinados.
Cuadrática	AG	Alta precisión, soluciones muy cercanas al mínimo global.	Tiempos de ejecución rápidos y consistentes.	Muy consistente, con mínimas variaciones en los resultados.
	MG	Alta precisión, soluciones cercanas al mínimo global.	Tiempos de ejecución rápidos.	Muy consistente, con mínimas variaciones en los resultados.
	AH	Alta precisión, soluciones refinadas muy cercanas al mínimo global.	Tiempos de ejecución intermedios.	Muy consistente, con mínimas variaciones en los resultados refinados.

Función	Método	Precisión	Tiempo de ejecución	Consistencia
Gaussiana	AG	Alta precisión, encuentra el valor óptimo en todas las ejecuciones.	Tiempos de ejecución rápidos y consistentes.	Muy consistente, con mínimas variaciones en los resultados.
	MG	Alta precisión, encuentra el valor óptimo en todas las ejecuciones.	Tiempos de ejecución rápidos.	Muy consistente, con mínimas variaciones en los resultados.
	AH	Alta precisión, soluciones refinadas muy cercanas al mínimo global.	Tiempos de ejecución intermedios.	Muy consistente, con mínimas variaciones en los resultados refinados.
Griewank	AG	Buena precisión, cercana al mínimo global, pero con variabilidad.	Tiempos de ejecución rápidos y consistentes.	Variabilidad en los resultados, pero cercanos al mínimo global.
	MG	Baja precisión, tiende a quedar atrapado en mínimos locales.	Tiempos de ejecución rápidos.	Alta variabilidad, dependiente del punto inicial.
	AH	Alta precisión, mejora las soluciones iniciales del algoritmo genético.	Tiempos de ejecución intermedios.	Mayor consistencia en los resultados refinados.
McCormick	AG	Buena precisión, cercana al mínimo global, pero con variabilidad.	Tiempos de ejecución rápidos y consistentes.	Variabilidad en los resultados, pero cercanos al mínimo global.
	MG	Baja precisión, no encuentra el mínimo global.	Tiempos de ejecución rápidos.	Alta variabilidad, dependiente del punto inicial.
	AH	Alta precisión, mejora las soluciones iniciales del algoritmo genético.	Tiempos de ejecución intermedios.	Mayor consistencia en los resultados refinados.
Rastrigin	AG	Buena precisión, cercana al mínimo global, pero con variabilidad.	Tiempos de ejecución rápidos y consistentes.	Variabilidad en los resultados, pero cercanos al mínimo global.
	MG	Baja precisión, tiende a quedar atrapado en mínimos locales.	Tiempos de ejecución rápidos.	Alta variabilidad, dependiente del punto inicial.
	AH	Alta precisión, mejora las soluciones iniciales del algoritmo genético.	Tiempos de ejecución intermedios.	Mayor consistencia en los resultados refinados.
Rosenbrock	AG	Buena precisión, cercana al mínimo global, pero con variabilidad.	Tiempos de ejecución rápidos y consistentes.	Variabilidad en los resultados, pero cercanos al mínimo global.
	MG	Baja precisión, no encuentra el mínimo global.	Tiempos de ejecución rápidos.	Alta variabilidad, dependiente del punto inicial.
	AH	Alta precisión, mejora las soluciones iniciales del algoritmo genético.	Tiempos de ejecución intermedios.	Mayor consistencia en los resultados refinados.

Conclusiones.

En este estudio, se han analizado y comparado tres métodos de optimización (algoritmo genético, gradiente descendente y un algoritmo híbrido) aplicados a distintas funciones de prueba: función de Ackley, Bohachevsky, Bukin, cuadrática, gaussiana, Griewank, McCormick, Rastrigin, Rosenbrock y una función aleatoria. Los resultados experimentales han permitido extraer las siguientes conclusiones:

1. **Eficacia del algoritmo genético:**

El algoritmo genético se mostró muy eficiente a la hora de explorar todo el espacio de búsqueda, especialmente en funciones complejas como Ackley, Griewank y Rastrigin. Al ser un método aleatorio, tiene la ventaja de no quedarse atascado en mínimos locales y suele acercarse bastante al mejor resultado posible. Sin embargo, y debido a su naturaleza estocástica, los resultados no siempre son idénticos en cada ejecución. Esto se debe a la presencia de los operadores de mutación y cruce. Esta variabilidad puede reducirse ajustando ciertos parámetros como el tamaño de la población, la tasa de mutación y el número de generaciones.

2. **Limitaciones del método del gradiente:**

El método del gradiente es rápido, pero tiene sus limitaciones. En funciones complicadas como Rastrigin (con muchos valles y picos) no suele dar buenos resultados porque se queda atascado en mínimos locales, especialmente si el punto de partida no es el adecuado. Sin embargo, en funciones más sencillas y suaves, como la cuadrática o la gaussiana, el método del gradiente demostró ser preciso y consistente, confirmando su utilidad en problemas con un único mínimo global.

3. **Implementación de algoritmo híbrido (AG + MG):**

La combinación de ambos métodos fue la más efectiva en la mayoría de las pruebas. Este enfoque aprovecha lo mejor de cada método: el algoritmo genético explora bien todo el terreno de búsqueda, mientras que el método del gradiente afina los resultados una vez que estamos cerca de la solución.

Funciones complicadas como Ackley, Griewank y Rastrigin fueron donde más destacó este método híbrido. El método del gradiente ayudó a refinar los resultados finales, llegando en muchos casos casi al valor óptimo real. Además, su tiempo de ejecución fue razonable, convirtiéndolo en una opción interesante para problemas de optimización complejos donde otros métodos fallan.

4. **Aplicación a una función aleatoria no lineal:**

Para poder evaluar a los algoritmos en un escenario más real (y difícil), se incluyó una función no lineal con componentes aleatorios. Las conclusiones son las siguientes:

- El algoritmo genético y el híbrido demostraron ser capaces de encontrar soluciones cercanas al mínimo global.
- El método del gradiente, en cambio, se quedó atascado en un mínimo local (como le pasa a menudo en estos casos).

Esto resalta la importancia de utilizar métodos globales o híbridos en problemas con múltiples mínimos locales y espacios de búsqueda complejos.

5. **Limitaciones y futuras líneas de investigación:**

Una limitación de este estudio es el enfoque en funciones de dos dimensiones. Futuros trabajos podrían extender este análisis a problemas de mayor dimensionalidad, donde la complejidad del espacio de búsqueda aumenta significativamente.

En el futuro se puede extender la aplicación de estos métodos a problemas de optimización con restricciones, que son comunes en aplicaciones prácticas de ingeniería y economía.

Bibliografía

Alba, E., & Dorronsoro, B. (2005). "Algoritmos Genéticos Paralelos para Optimización en Ingeniería". *Revista de Ingeniería Informática*, 12(3), 45-62.

Back, T. (1996). *Evolutionary Algorithms in Theory and Practice*. Oxford University Press.

Bäck, T., Fogel, D. B., & Michalewicz, Z. (1997). *Handbook of Evolutionary Computation*. Oxford University Press.

Belegundu, A. D., & Chandrupatla, T. R. (2011). *Optimization Concepts and Applications in Engineering*. Cambridge University Press.

Bertsekas, D. P. (1999). *Nonlinear Programming*. Athena Scientific.

Boyd, S., & Vandenberghe, L. (2004). *Convex Optimization*. Cambridge University Press.

Chapra, S. C., & Canale, R. P. (2011). *Métodos Numéricos para Ingenieros* (6ª ed.). McGraw-Hill.

Coello, C. A. (2007). *Introducción a la Optimización Multiobjetivo*. Editorial Limusa.

Cortés, P., & Onieva, L. (2014). *Algoritmos de Optimización en Ingeniería*. Universidad de Sevilla.

Deb, K. (2001). *Multi-Objective Optimization Using Evolutionary Algorithms*. Wiley.

Eiben, A. E., & Smith, J. E. (2015). *Introduction to Evolutionary Computing*. Springer.

Engelbrecht, A. P. (2007). *Computational Intelligence: An Introduction*. Wiley.

Fletcher, R. (1987). *Practical Methods of Optimization*. Wiley.

Floudas, C. A., & Pardalos, P. M. (2009). *Encyclopedia of Optimization*. Springer.

Fogel, L. J., Owens, A. J., & Walsh, M. J. (1966). *Artificial Intelligence Through Simulated Evolution*. Wiley.

García, J. A., & Herrera, F. (2006). *Algoritmos Genéticos y Evolutivos: Teoría y Aplicaciones*. Ra-Ma.

García, S., Molina, D., & Herrera, F. (2009). "Una Revisión de los Algoritmos Evolutivos para Optimización en Espacios Continuos". *Inteligencia Artificial*, 13(41), 7-26.

Gilat, A. (2015). *MATLAB: Una Introducción con Aplicaciones*. Reverté.

Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley.

Gómez, M., & Fernández, A. (2013). *Optimización en Redes de Transporte usando Metaheurísticas*. Universidad de Barcelona.

González, E. (2015). *Diseño de un Algoritmo Híbrido para Optimización Multimodal*. Tesis doctoral, Universidad Politécnica de Madrid.

Haupt, R. L., & Haupt, S. E. (2004). *Practical Genetic Algorithms*. Wiley.

Herrera, F., Lozano, M., & Verdegay, J. L. (1998). "Algoritmos Genéticos para Problemas de Optimización Continua". *Revista Iberoamericana de Inteligencia Artificial*, 2(4), 77-90.

Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. University of Michigan Press.

Kennedy, J., & Eberhart, R. (1995). "Particle Swarm Optimization". *Proceedings of IEEE International Conference on Neural Networks*.

Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). "Optimization by Simulated Annealing". *Science*, 220(4598), 671-680.

Koza, J. R. (1992). *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. MIT Press.

Laguna, M., & Martí, R. (2003). *Metaheurísticas para la Optimización Difícil*. Universidad de Valencia.

López, C. (2014). *Optimización Numérica con MATLAB: Algoritmos y Aplicaciones*. Marcombo.

Lozano, M., & García-Martínez, C. (2008). "Hibridación de Algoritmos Genéticos con Búsqueda Local". *Journal of Heuristics*, 14(3), 21-45.

Martínez, A. (2019). *Resolución de Problemas de Optimización con MATLAB*. Universidad Politécnica de Madrid.

Martínez, L., & García, R. (2010). *Optimización Heurística y Metaheurística*. Alfaomega.

Mathews, J. H., & Fink, K. D. (2004). *Numerical Methods Using MATLAB*. Pearson.

Mendoza, R. (2022). *Métodos Híbridos en Optimización Global: Enfoques y Resultados*. Tesis doctoral, Universidad de Sevilla.

Michalewicz, Z. (1996). *Genetic Algorithms + Data Structures = Evolution Programs*. Springer.

Mitchell, M. (1998). *An Introduction to Genetic Algorithms*. MIT Press.

Nocedal, J., & Wright, S. J. (2006). *Numerical Optimization*. Springer.

Osorio, F. (2008). *Métodos Numéricos en Ingeniería*. Editorial Universitaria.

Pardo, E. G., & Duarte, A. (2010). "Comparación de Métodos de Gradiente en Problemas de Optimización No Lineal". *Revista de Matemáticas Aplicadas*, 15(2), 33-50.

Pelta, D. A. (2012). *Optimización con Algoritmos Bioinspirados*. Ediciones Díaz de Santos.

Pérez, J., & Cruz, L. (2016). *Aplicaciones de Algoritmos Genéticos en Robótica*. Alfaomega.

Press, W. H., et al. (2007). *Numerical Recipes: The Art of Scientific Computing*. Cambridge University Press.

Ramírez, J. (2018). *Modelado y Optimización en Procesos Industriales*. Ediciones Díaz de Santos.

Rao, S. S. (2009). *Engineering Optimization: Theory and Practice*. Wiley.

Rodríguez, J. (2017). *Algoritmos de Optimización en MATLAB: De la Teoría a la Práctica*. Ediciones Paraninfo.

Rodríguez, J. M. (2011). *Optimización No Lineal: Métodos y Algoritmos*. Ediciones Pirámide.

Rojas, R. (1996). *Redes Neuronales y Algoritmos Genéticos*. Alfaomega.

Ruiz, D. (2019). *Aplicación de Algoritmos Genéticos en la Minimización de Funciones Complejas*. Trabajo de grado, Universidad de Chile.

Sánchez, R., & Melin, P. (2012). *Optimización de Sistemas Complejos con Algoritmos Evolutivos*. Editorial Trillas.

Schwefel, H.-P. (1995). *Evolution and Optimum Seeking*. Wiley.

Silva, P. (2021). *Optimización de Parámetros en Modelos Matemáticos usando MATLAB*. Tesis de pregrado, Universidad de Buenos Aires.

Silva, P. (2021). *Optimización de Parámetros en Modelos Matemáticos usando MATLAB*. Tesis de pregrado, Universidad de Buenos Aires.

Simon, D. (2013). *Evolutionary Optimization Algorithms*. Wiley.

Sossa, H., & Pérez, J. (2015). *Computación Evolutiva: Algoritmos Genéticos y sus Aplicaciones*. McGraw-Hill.

Spall, J. C. (2003). *Introduction to Stochastic Search and Optimization*. Wiley.

Talbi, E.-G. (2009). *Metaheuristics: From Design to Implementation*. Wiley.

Torres, L. (2020). *Inteligencia Computacional para la Toma de Decisiones*. Editorial UPC.

Vargas, A. (2017). *Comparación de Métodos de Optimización en Problemas No Convexos*. Tesis de maestría, Universidad Nacional Autónoma de México.

Whitley, D. (1994). "A Genetic Algorithm Tutorial". *Statistics and Computing*, 4(2), 65-85.

Wolpert, D. H., & Macready, W. G. (1997). "No Free Lunch Theorems for Optimization". *IEEE Transactions on Evolutionary Computation*, 1(1), 67-82.

Yang, X.-S. (2010). *Nature-Inspired Metaheuristic Algorithms*. Luniver Press.

Anexos

Resultados de las ejecuciones de los códigos para las funciones analizadas en este trabajo

Anexo 1.

Resultados de las ejecuciones de los códigos para la función de Ackley.

Ejecución del código algoritmo genético.

```
Parámetros del algoritmo genético:
Tamaño de la población: 50
Número de generaciones: 100
Tasa de mutación: 0.1
Tasa de cruce: 0.8
Límites: [-5 5;-5 5]
```

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	0.0044032	0.05125	0.21444	0.017601
2	-0.0020584	-0.00088855	0.0064752	0.013972
3	0.0082503	0.014392	0.054236	0.018056
4	0.0064206	0.0069662	0.029184	0.013162
5	-0.019627	-0.036749	0.16349	0.013933
6	0.039023	-0.027476	0.19471	0.012728
7	-0.014522	-0.0027158	0.047589	0.013498
8	0.057502	0.012892	0.25664	0.012221
9	-0.016938	0.0058446	0.059207	0.012856
10	0.031776	0.038521	0.20655	0.012803

```
Estadísticas de los valores óptimos encontrados:
  Media: 0.1233
  Desviación estándar: 0.0924
  Mínimo: 0.0065
  Máximo: 0.2566

Estadísticas de los tiempos de ejecución:
  Media: 0.0141 segundos
  Desviación estándar: 0.0021 segundos
  Mínimo: 0.0122 segundos
  Máximo: 0.0181 segundos
```

Ejecución del código del método del gradiente.

```
Parámetros del método del gradiente:
Rango: [-5 5 -5 5]
Número de iteraciones: 200
Tamaño de la perturbación (hstep): 0.0010
Paso de optimización (alfa): 0.0500
```

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	-4.0639	2.867	10.604	0.039357
2	-0.87155	4.0258	9.2338	0.039379
3	5.0603	-2.8716	11.686	0.041747
4	2.9744	-0.12989	7.2838	0.030276
5	0.11889	-4.0046	8.9902	0.029958
6	-1.0521	0.85204	4.038	0.033749
7	0.85204	-1.0521	4.038	0.029826
8	5.0392	3.0724	11.493	0.028559
9	0.94194	-0.14337	3.0633	0.027785
10	2.9386	0.13769	7.3272	0.028635

```
Estadísticas de los valores óptimos encontrados:
  Media: 7.7757
  Desviación estándar: 3.1850
  Mínimo: 3.0633
  Máximo: 11.6857

Estadísticas de los tiempos de ejecución:
  Media: 0.0329 segundos
  Desviación estándar: 0.0053 segundos
  Mínimo: 0.0278 segundos
  Máximo: 0.0417 segundos
```

Ejecución del código algoritmo híbrido.

```
Parámetros del método del gradiente:
Tasa de aprendizaje: 0.001
Tolerancia para la convergencia: 1e-06
Número máximo de iteraciones: 5000
```

Ejecucion	Solucion_Genetica_X	Solucion_Genetica_Y	Valor_Aptitud_Genetica
1	0.00014516	0.00071222	0.0020699
2	0.00055843	-0.00012928	0.00163
3	-0.0070112	-0.0039396	0.024468
4	0.0015264	0.0023644	0.0081711
5	0.0010146	0.00082063	0.0037363
6	0.00011083	0.00043433	0.0012732
7	0.015533	0.012186	0.066193
8	0.033781	0.0022757	0.126
9	-0.0011944	0.001237	0.0049423
10	-0.0017265	0.0011402	0.0059662

Solucion_Refinada_X	Solucion_Refinada_Y	Valor_Aptitud_Refinada
0.00014516	0.00071222	0.0020699
0.0005584 3	-0.00012928	0.00163
-0.0070112	-0.0039396	0.024468
0.0015264	0.0023644	0.0081711
0.0010146	0.00082063	0.0037363
0.00011083	0.00043433	0.0012732
0.015533	0.012186	0.066193
0.033781	0.0022757	0.126
-0.0011944	0.001237	0.0049423
-0.0017265	0.0011402	0.0059662

Anexo 2.

Resultados de las ejecuciones de los códigos para la función de Bohachevsky

Ejecución del código algoritmo genético.

```
Tamaño de la población: 50
Número de generaciones: 100
Tasa de mutación: 0.1
Tasa de cruce: 0.8
```

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	-0.0062604	-0.0017248	0.00066115	0.014371
2	-0.003035	0.0015074	0.00020824	0.015671
3	0.027771	0.047469	0.084576	0.0097776
4	0.10854	-0.010958	0.15957	0.019626
5	-0.025487	-0.01463	0.016432	0.018991
6	-0.023899	0.045941	0.077196	0.014873
7	0.031857	-0.046267	0.084442	0.015259
8	-0.016603	-0.004356	0.0045779	0.014396
9	-0.39778	-0.051449	0.79059	0.01405
10	0.0029281	-0.0054165	0.0011077	0.014563

```
Estadísticas de los valores óptimos encontrados:
  Media: 0.1219
  Desviación estándar: 0.2409
  Mínimo: 0.0002
  Máximo: 0.7906

Estadísticas de los tiempos de ejecución:
  Media: 0.0152 segundos
  Desviación estándar: 0.0027 segundos
  Mínimo: 0.0098 segundos
  Máximo: 0.0196 segundos
```

Ejecución del código del método del gradiente.

```
Parámetros del método del gradiente:
Número de iteraciones: 100
Tamaño de la perturbación (hstep): 0.001
Paso de optimización (alfa): 0.05
```

Límites para las variables x ∈ [-100, 100]; y ∈ [-100, 100]

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	1.222	0.27832	2.5737	0.027359
2	1.222	-0.53662	2.2614	0.018415
3	-1.223	-0.55985	2.3786	0.014244
4	-1.223	-0.10162	1.9486	0.018829
5	-1.223	-0.30985	2.5279	0.027602
6	1.222	0.95855	3.5345	0.026918
7	-1.223	-0.27806	2.5739	0.013148
8	1.222	-0.50196	2.1479	0.013011
9	-1.223	-0.89143	3.5511	0.01346
10	1.222	0.95855	3.5345	0.012807

Estadísticas de los valores óptimos encontrados:
Media: 2.7032
Desviación estándar: 0.6095
Mínimo: 1.9486
Máximo: 3.5511

Estadísticas de los tiempos de ejecución:
Media: 0.0186 segundos
Desviación estándar: 0.0064 segundos
Mínimo: 0.0128 segundos
Máximo: 0.0276 segundos

Ejecución del código híbrido

Ejecucion	Solucion_Genetica_X	Solucion_Genetica_Y	Valor_Aptitud_Genetica
1	-1.2342	-0.47643	2.1163
2	-8.4228e-05	-0.00018838	1.2933e-06
3	-0.61834	0.46936	0.88281
4	0.62703	0.47114	0.88382
5	0.8391	-0.90521	2.911
6	-0.0048044	0.46667	0.47047
7	-1.2303	0.0028115	1.6446
8	0.0021578	-0.0042797	0.00068166
9	6.1792	-2.0295	46.783
10	-0.61176	-0.010536	0.41725

Solucion_Refinada_X	Solucion_Refinada_Y	Valor_Aptitud_Refinada
-0.39735	-0.093807	0.96971
-8.4228e-05	-0.00018838	1.2933e-06
-0.61834	0.46936	0.88281
0.62703	0.47114	0.88382
0.8391	-0.90521	2.911
-0.0048044	0.46667	0.47047
-1.2303	0.0028115	1.6446
0.0021578	-0.0042797	0.00068166
-0.0046354	-0.46585	0.47061
-0.61176	-0.010536	0.41725

Ejecucion	Tiempo_Ejecucion
1	0.39268
2	0.33457
3	0.30285
4	0.34069
5	0.33513
6	0.41743
7	0.33165
8	0.33606
9	0.3143
10	0.29759

Anexo 3.

Resultados de las ejecuciones de los códigos para la función Bukin

Ejecución del código algoritmo genético.

```
Parámetros del algoritmo genético:
  Tamaño de la población: 100
  Número máximo de generaciones: 200
  Tolerancia de la función: 1.0e-06
  Tasa de cruce: 0.80
  Función de mutación: mutationadaptfeasible
  Límites: [-15, -3] a [-5, 3]
```

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo
1	-6.9909	0.48873	0.047637
2	-8.0471	0.64755	0.036387
3	-7.8518	0.61651	0.022777
4	-10.646	1.1333	0.071948
5	-6.9816	0.48742	0.07564
6	-7.935	0.62965	0.0779
7	-12.637	1.5971	0.052738
8	-13.942	1.9438	0.071619
9	-5.8719	0.34479	0.068264
10	-10.349	1.0711	0.053289

Tiempos de ejecución de cada iteración:

Tiempo_Ejecución
0.20579
0.068168
0.097111
0.052708
0.069437
0.058927
0.071651
0.11505
0.066921
0.079904

```
Estadísticas de los valores óptimos encontrados:
  Media: 0.0578
  Desviación estándar: 0.0184
  Mínimo: 0.0228
  Máximo: 0.0779

Estadísticas de los tiempos de ejecución:
  Media: 0.0886 segundos
  Desviación estándar: 0.0451 segundos
  Mínimo: 0.0527 segundos
  Máximo: 0.2058 segundos
```

Ejecución del código del método del gradiente.

```
Parámetros del método del gradiente:
Tasa de aprendizaje: 0.0001
Número máximo de iteraciones: 10000
Tolerancia: 1e-08
```

Resultados de cada ejecución:

Ejecución	x	y	Valor_Óptimo
1	-0.19505	-0.048211	22.142
2	-6.4627	0.61145	44.057
3	-0.74549	-0.46906	68.985
4	10.533	1.1364	16.596
5	1.8198	0.080001	21.771
6	-3.1248	0.11582	13.55
7	4.9183	0.2205	14.777
8	12.38	1.516	13.185
9	11.734	1.1812	44.458
10	3.8109	0.13597	9.76

Tiempos de ejecución de cada iteración:

Tiempo_Ejecución
0.007631
0.0041389
0.0045922
0.0044645
0.0039567
0.0033973
0.0028975
0.0028562
0.0027685
0.0023967

Estadísticas de los valores óptimos encontrados:
Media: 26.92808124
Desviación estándar: 19.25264390
Mínimo: 9.76000305
Máximo: 68.98491516

Estadísticas de los tiempos de ejecución:
Media: 0.00390995 segundos
Desviación estándar: 0.00151529 segundos
Mínimo: 0.00239670 segundos
Máximo: 0.00763100 segundos

Implementación del algoritmo híbrido.

Resultados obtenidos:

Ejecucion	Valor_Aptitud_Genetica	Valor_Aptitud_Refinada
1	0.061234	0.022517
2	0.057581	0.020802
3	0.16175	0.03362
4	0.077255	0.049213
5	0.058344	0.03423
6	0.081096	0.041243
7	0.066141	0.038644
8	0.089938	0.010046
9	0.028327	0.012581
10	0.039941	0.014067

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.065027
2	0.054042
3	0.059731
4	0.044625
5	0.052171
6	0.045475
7	0.05665
8	0.065449
9	0.07396
10	0.072738

Estudio estadístico:

Metodo	Media_Aptitud	Desviacion_Estandar_Aptitud
{'Genetico' }	0.07216	0.036463
{'Gradiente'}	0.027696	0.013516

Anexo 4.

Resultados de las ejecuciones de los códigos para la función cuadrática.

Ejecución del código algoritmo genético.

```
Tamaño de la población: 50
Número de generaciones: 100
Tasa de mutación inicial: 0.1
Tasa de cruce: 0.8
Límites: [-10, 10] para x1 y [-10, 10] para x2
```

Resultados obtenidos:

Ejecucion	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud
1	-0.0093987	0.012494	0.00024443
2	-0.031874	-0.0083288	0.0010853
3	-8.0482e-05	0.0016538	2.7415e-06
4	-0.00012217	-0.0004172	1.8898e-07
5	-8.1301e-09	2.0723e-08	4.9552e-16
6	6.0752e-06	1.2259e-05	1.8718e-10
7	-0.013291	0.020147	0.00058254
8	1.6349e-06	-9.6331e-08	2.6822e-12
9	-0.0002515	0.0030259	9.2196e-06
10	-2.764e-05	3.7989e-05	2.2072e-09

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.04641
2	0.030107
3	0.024421
4	0.024029
5	0.0267
6	0.017594
7	0.028947
8	0.02319
9	0.026032
10	0.019266

Estudio estadístico:

Estadistica	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud	Tiempo_Total
{'Media' }	-0.0055038	0.0028624	0.00019244	0.02667
{'Desviacion_Estandar'}	0.010425	0.0078986	0.00036618	0.0079472

Ejecución del código método del gradiente.

Número de iteraciones: 100
Tamaño de la perturbación (hstep): 0.001
Paso de optimización (alfa): 0.05

Resultados obtenidos:

Ejecucion	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud
1	-0.00073932	0.00057528	8.7754e-07
2	0.013371	-0.010338	0.00028568
3	-2.4775e-05	-8.3755e-05	7.6287e-09
4	0.0054585	-0.02334	0.00057456
5	-0.01788	-0.03529	0.0015651
6	-0.0078589	-3.1486e-05	6.1763e-05
7	-0.002168	0.0043871	2.3947e-05
8	-0.0026452	0.00035268	7.1215e-06
9	-5.3375e-06	-1.0513e-05	1.3902e-10
10	-0.00018247	-5.8272e-05	3.6689e-08

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.045675
2	0.032762
3	0.019613
4	0.018069
5	0.026058
6	0.020262
7	0.01811
8	0.025394
9	0.018051
10	0.018585

Estudio estadístico:

Estadistica	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud	Tiempo_Total
{'Media' }	-0.0012674	-0.0063838	0.00025191	0.024258
{'Desviacion_Estandar'}	0.0080709	0.01295	0.0004979	0.0089436

Ejecución del código del método híbrido.

Resultados obtenidos:

Ejecucion	Mejor_Solucion_Genetica_X	Mejor_Solucion_Genetica_Y	Valor_Aptitud_Genetica
1	-0.0020779	-0.0069087	5.2047e-05
2	0.0019923	0.0057041	3.6506e-05
3	0.010455	-0.00046803	0.00010953
4	-0.0024919	0.016492	0.00027818
5	0.029688	0.063434	0.0049052
6	0.036875	0.048463	0.0037084
7	0.0033965	0.010165	0.00011487
8	-0.0079462	0.00093521	6.4017e-05
9	0.026231	-0.030606	0.0016248
10	3.4045e-05	-0.0084764	7.185e-05

Mejor_Solucion_Refinada_X	Mejor_Solucion_Refinada_Y	Valor_Aptitud_Refinada
-1.5795e-07	-5.2516e-07	3.0074e-13
5.3183e-07	1.5226e-06	2.6013e-12
-7.1219e-07	3.1881e-08	5.0823e-13
1.6261e-08	-1.0762e-07	1.1846e-14
5.3563e-07	1.1445e-06	1.5967e-12
4.7851e-07	6.2887e-07	6.2445e-13
1.5923e-07	4.7656e-07	2.5246e-13
-9.6151e-07	1.1316e-07	9.3731e-13
1.0112e-05	-1.1799e-05	2.4147e-10
2.2986e-09	-5.7231e-07	3.2754e-13

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.03167
2	0.016245
3	0.012319
4	0.012326
5	0.014509
6	0.012174
7	0.022594
8	0.016655
9	0.011811
10	0.013551

Tiempos detallados de ejecución (segundos):

Ejecucion	Tiempo_Genetico	Tiempo_Gradiente
1	0.027943	0.0021544
2	0.015423	0.0002065
3	0.011831	9.36e-05
4	0.011872	8.07e-05
5	0.011843	0.0004618
6	0.011816	0.0001857
7	0.022308	2.26e-05
8	0.01647	1.59e-05
9	0.011602	4.19e-05
10	0.013369	1.88e-05

Estudio estadístico:

Estadistica	Valor_Aptitud_Genetica	Valor_Aptitud_Refinada	Tiempo_Total
{'Media' }	0.0010965	2.4863e-11	0.016385
{'Desviacion_Estandar'}	0.0017809	7.6111e-11	0.0062847

Anexo 5.

Resultados de las ejecuciones de los códigos para la función gaussiana.

Ejecución del código algoritmo genético.

```
Parámetros del algoritmo genético:
Tamaño de la población: 50
Número de iteraciones: 100
Probabilidad de cruce: 0.7
Probabilidad de mutación: 0.01
Rango para x: [-1, 1]
Rango para y: [-1, 1]
```

Resultados obtenidos:

Ejecucion	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud
1	-0.0035852	0.0039678	9.0001
2	0.031347	-0.0070344	9.0011
3	-0.00051799	-0.00025032	9
4	0.0011455	0.0010532	9
5	-0.011012	-0.0079968	9.0003
6	0.012182	0.018808	9.0012
7	-0.00019422	-6.6337e-05	9
8	-2.9657e-06	-6.0345e-06	9
9	-0.00016975	0.00010932	9
10	0.001425	-0.00012239	9

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.045615
2	0.032664
3	0.02549
4	0.022292
5	0.025324
6	0.029882
7	0.02462
8	0.025313
9	0.021985
10	0.024916

Estudio estadístico:

Estadistica	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud	Tiempo_Total
{'Media' }	0.0030618	0.0008462	9.0003	0.02781
{'Desviacion_Estandar'}	0.011427	0.0072798	0.00048319	0.0070365

Ejecución del código del método del gradiente.

```
Parámetros del método del gradiente:
Número de iteraciones: 100
Tamaño de la perturbación (hstep): 0.001
Paso de optimización (alfa): 0.05
```

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	-0.00049353	-0.0005	9	0.018308
2	-0.00053729	-0.0005	9	0.012302
3	-0.00049994	-0.0005	9	0.012529
4	-0.00047664	-0.0005	9	0.023218
5	-0.0004806	-0.0005	9	0.021219
6	-0.00047106	-0.0005	9	0.023061
7	-0.00053788	-0.0005	9	0.012025
8	-0.00048733	-0.0005	9	0.012119
9	-0.00049327	-0.0005	9	0.011492
10	-0.00051724	-0.0005	9	0.01143

```
Estadísticas de los valores óptimos encontrados:
  Media: 9.0000
  Desviación estándar: 0.0000
  Mínimo: 9.0000
  Máximo: 9.0000

Estadísticas de los tiempos de ejecución:
  Media: 0.0158 segundos
  Desviación estándar: 0.0051 segundos
  Mínimo: 0.0114 segundos
  Máximo: 0.0232 segundos
```

Ejecución del código del método del método híbrido.

Resultados obtenidos:

Ejecucion	Mejor_Solucion_Genetica_X	Mejor_Solucion_Genetica_Y	Valor_Aptitud_Genetica
1	-0.0034938	2.6208e-05	9
2	-0.0019529	-0.0018684	9
3	0.0024966	-0.0013814	9
4	-0.008718	-0.002163	9.0001
5	0.00080735	0.0016413	9
6	0.0096375	-0.0048153	9.0002
7	-0.0028367	-0.0025404	9
8	0.0079417	-0.00045205	9.0001
9	-0.0015737	0.014804	9.0007
10	-0.0042351	0.004862	9.0001

Mejor_Solucion_Refinada_X	Mejor_Solucion_Refinada_Y	Valor_Aptitud_Refinada
-4.9205e-05	5.603e-11	9
-4.941e-05	-2.4029e-08	9
4.9569e-05	-8.4554e-09	9
-4.9466e-05	-2.8565e-10	9
4.9689e-05	3.2125e-07	9
4.9431e-05	-4.6674e-10	9
-4.9892e-05	-1.0727e-08	9
4.9851e-05	-8.1344e-11	9
-4.9733e-05	3.7618e-07	9
-4.9729e-05	5.9562e-09	9

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.030731
2	0.016099
3	0.018435
4	0.014883
5	0.028523
6	0.020094
7	0.021988
8	0.021602
9	0.019693
10	0.019734

Estudio estadístico:

Estadistica	Valor_Aptitud_Genetica	Valor_Aptitud_Refinada	Tiempo_Total
{'Media' }	9.0001	9	0.021178
{'Desviacion_Estandar'}	0.00019809	2.1718e-11	0.004994

Ejecución del código del método del gradiente.

```
Número de iteraciones: 1000
Tamaño de la perturbación (hstep): 0.0001
Paso de optimización (alfa): 0.001
```

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	126.77	-593.31	92.963	0.1857
2	16.783	-326.57	27.739	0.13588
3	150.79	-204.38	16.127	0.12832
4	44.817	131.46	5.6372	0.12949
5	470.93	-241.75	70.799	0.12593
6	-586.83	-137.07	91.076	0.12731
7	182.18	292.47	29.824	0.12013
8	-305.81	268.43	42.515	0.11972
9	-568.16	552.74	158.33	0.15032
10	-523.26	329.69	96.766	0.14019

```
Estadísticas de los valores óptimos encontrados:
  Media: 63.1774
  Desviación estándar: 47.4055
  Mínimo: 5.6372
  Máximo: 158.3287

Estadísticas de los tiempos de ejecución:
  Media: 0.1363 segundos
  Desviación estándar: 0.0197 segundos
  Mínimo: 0.1197 segundos
  Máximo: 0.1857 segundos
```

Ejecución del código del método del método híbrido.

Resultados obtenidos:

Ejecucion	Mejor_Solucion_Genetica_X	Mejor_Solucion_Genetica_Y	Valor_Aptitud_Genetica
1	12.56	-26.63	0.21693
2	25.184	-8.6487	0.19254
3	-15.688	-4.3553	0.068388
4	-9.3865	13.347	0.067374
5	0.03365	-8.9147	0.020644
6	6.2705	8.864	0.029671
7	6.3663	-0.025019	0.013737
8	9.4168	13.31	0.066576
9	-15.693	-4.4239	0.06666
10	18.849	-8.8968	0.10864

Mejor_Solucion_Refinada_X	Mejor_Solucion_Refinada_Y	Valor_Aptitud_Refinada
12.56	-26.63	0.21693
25.12	-8.8754	0.17755
-15.7	-4.4379	0.066584
-9.4201	13.316	0.066564
1.4459e-06	-8.8771	0.01972
6.28	8.8767	0.029584
6.2801	-0.0001986	0.0098647
9.4201	13.315	0.066564
-15.7	-4.4382	0.066584
18.84	-8.8771	0.1085

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.045187
2	0.030038
3	0.028429
4	0.027919
5	0.027786
6	0.017175
7	0.015409
8	0.027336
9	0.016288
10	0.02459

Estudio estadístico:

Estadistica	Valor_Aptitud_Genetica	Valor_Aptitud_Refinada	Tiempo_Total
{'Media' }	0.085116	0.082846	0.026016
{'Desviacion_Estandar'}	0.069181	0.067342	0.0087264

Anexo 6.

Resultados de las ejecuciones de los códigos para la función de Griewank.

Ejecución del código del algoritmo genético.

```
Parámetros del algoritmo genético:
Tamaño de la población: 100
Número de iteraciones: 500
Probabilidad de cruce: 0.7
Probabilidad de mutación: 0.05
Proporción de elitismo: 0.05
```

Resultados obtenidos:

Ejecucion	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud
1	-6.2836	-8.625	0.045416
2	-3.1197	4.4102	0.0078017
3	0.040582	0.14394	0.0060001
4	6.4046	0.19824	0.027366
5	-3.101	4.3821	0.0089514
6	3.1393	4.4383	0.0073963
7	3.1552	4.5083	0.0087309
8	-6.2939	0.0064337	0.0099708
9	-0.012319	8.8963	0.01989
10	3.024	-4.4897	0.014772

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.32053
2	0.22312
3	0.21898
4	0.20583
5	0.17299
6	0.16887
7	0.17224
8	0.17034
9	0.15965
10	0.16878

Estudio estadístico:

Estadistica	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud	Tiempo_Total
{'Media' }	-0.30468	1.3869	0.01563	0.19813
{'Desviacion_Estandar'}	4.314	5.0902	0.012427	0.048731

Ejecución del código del método del gradiente.

```
Número de iteraciones: 1000
Tamaño de la perturbación (hstep): 0.0001
Paso de optimización (alfa): 0.001
```

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	126.77	-593.31	92.963	0.1857
2	16.783	-326.57	27.739	0.13588
3	150.79	-204.38	16.127	0.12832
4	44.817	131.46	5.6372	0.12949
5	470.93	-241.75	70.799	0.12593
6	-586.83	-137.07	91.076	0.12731
7	182.18	292.47	29.824	0.12013
8	-305.81	268.43	42.515	0.11972
9	-568.16	552.74	158.33	0.15032
10	-523.26	329.69	96.766	0.14019

```
Estadísticas de los valores óptimos encontrados:
  Media: 63.1774
  Desviación estándar: 47.4055
  Mínimo: 5.6372
  Máximo: 158.3287

Estadísticas de los tiempos de ejecución:
  Media: 0.1363 segundos
  Desviación estándar: 0.0197 segundos
  Mínimo: 0.1197 segundos
  Máximo: 0.1857 segundos
```

Ejecución del código del algoritmo híbrido

Resultados obtenidos:

Ejecucion	Mejor_Solucion_Genetica_X	Mejor_Solucion_Genetica_Y	Valor_Aptitud_Genetica
1	12.56	-26.63	0.21693
2	25.184	-8.6487	0.19254
3	-15.688	-4.3553	0.068388
4	-9.3865	13.347	0.067374
5	0.03365	-8.9147	0.020644
6	6.2705	8.864	0.029671
7	6.3663	-0.025019	0.013737
8	9.4168	13.31	0.066576
9	-15.693	-4.4239	0.06666
10	18.849	-8.8968	0.10864

Mejor_Solucion_Refinada_X	Mejor_Solucion_Refinada_Y	Valor_Aptitud_Refinada
12.56	-26.63	0.21693
25.12	-8.8754	0.17755
-15.7	-4.4379	0.066584
-9.4201	13.316	0.066564
1.4459e-06	-8.8771	0.01972
6.28	8.8767	0.029584
6.2801	-0.0001986	0.0098647
9.4201	13.315	0.066564
-15.7	-4.4382	0.066584
18.84	-8.8771	0.1085

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.045187
2	0.030038
3	0.028429
4	0.027919
5	0.027786
6	0.017175
7	0.015409
8	0.027336
9	0.016288
10	0.02459

Estudio estadístico:

Estadistica	Valor_Aptitud_Genetica	Valor_Aptitud_Refinada	Tiempo_Total
{'Media' }	0.085116	0.082846	0.026016
{'Desviacion_Estandar'}	0.069181	0.067342	0.0087264

Anexo 7.

Resultados de las ejecuciones de los códigos para la función de McCormick.

Ejecución del código del algoritmo genético.

Parámetros del algoritmo genético:
Tamaño de la población: 50
Número de iteraciones: 200
Probabilidad de cruce: 0.7
Probabilidad de mutación: 0.01

Resultados obtenidos:

Ejecucion	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud
1	-0.55633	-1.5404	-1.913
2	-0.5472	-1.5472	-1.9132
3	-0.54753	-1.5496	-1.9132
4	-0.54794	-1.5587	-1.913
5	-0.54471	-1.5626	-1.9128
6	-0.53378	-1.5394	-1.913
7	-0.5399	-1.5482	-1.9131
8	-0.51654	-1.5243	-1.9119
9	-0.54455	-1.531	-1.9129
10	-0.551	-1.5504	-1.9132

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.076336
2	0.047196
3	0.041958
4	0.034507
5	0.038099
6	0.034255
7	0.032534
8	0.03127
9	0.030438
10	0.029557

Estudio estadístico:

Estadistica	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud	Tiempo_Total
{'Media' }	-0.54295	-1.5452	-1.9129	0.039615
{'Desviacion_Estandar'}	0.011077	0.011749	0.00038874	0.014038

Implementación del código del gradiente

Número de iteraciones: 1000
Tamaño de la perturbación (hstep): 0.0001
Paso de optimización (alfa): 0.001

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	-0.34942	-1.3635	-1.8462	0.13891
2	-0.57234	-1.5935	-1.9106	0.12089
3	2.4117	1.3367	1.3096	0.12396
4	2.6495	1.6562	1.2345	0.11695
5	2.7401	1.786	1.2824	0.11995
6	-0.52656	-1.4925	-1.9096	0.12887
7	-0.34064	-1.2569	-1.7914	0.11898
8	-0.1831	-1.2407	-1.6978	0.11359
9	1.2188	0.18487	1.6891	0.11627
10	-0.39655	-1.4519	-1.8829	0.11574

Estadísticas de los valores óptimos encontrados:
Media: -0.5523
Desviación estándar: 1.6676
Mínimo: -1.9106
Máximo: 1.6891

Estadísticas de los tiempos de ejecución:
Media: 0.1214 segundos
Desviación estándar: 0.0076 segundos
Mínimo: 0.1136 segundos
Máximo: 0.1389 segundos

Implementación del código del método híbrido

Resultados obtenidos:

Ejecucion	Mejor_Solucion_Genetica_X	Mejor_Solucion_Genetica_Y	Valor_Aptitud_Genetica	Mejor_Solucion_Refinada_X	Mejor_Solucion_Refinada_Y	Valor_Aptitud_Refinada
1	-0.5319	-1.5323	-1.9128	-0.54716	-1.5472	-1.9132
2	-0.54628	-1.5506	-1.9132	-0.54724	-1.5472	-1.9132
3	-0.54249	-1.5277	-1.9127	-0.54716	-1.5472	-1.9132
4	-0.5429	-1.5539	-1.9131	-0.54724	-1.5472	-1.9132
5	-0.54977	-1.5445	-1.9132	-0.54721	-1.5472	-1.9132
6	-0.5461	-1.545	-1.9132	-0.54716	-1.5472	-1.9132
7	-0.5447	-1.5445	-1.9132	-0.54716	-1.5472	-1.9132
8	-0.54744	-1.5467	-1.9132	-0.54718	-1.5472	-1.9132
9	-0.54804	-1.5473	-1.9132	-0.54724	-1.5472	-1.9132
10	-0.51786	-1.563	-1.9111	-0.54716	-1.5472	-1.9132

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.033875
2	0.024605
3	0.017965
4	0.015678
5	0.022007
6	0.023646
7	0.016919
8	0.013954
9	0.01689
10	0.015569

Estudio estadístico:

Estadistica	Valor_Aptitud_Genetica	Valor_Aptitud_Refinada	Tiempo_Total
{'Media' }	-1.9129	-1.9132	0.020111
{'Desviacion_Estandar'}	0.0006559	5.2813e-10	0.0060469

Anexo 8

Resultados de las ejecuciones de los códigos para la función de Rastrigin.

Ejecución del código algoritmo genético.

Resultados obtenidos:

Ejecucion	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud
1	-0.019612	0.011223	0.10119
2	-0.0030085	0.0040524	0.0050535
3	-0.00012957	0.00030698	2.2027e-05
4	-0.046942	-0.021462	0.52526
5	0.0007453	0.99307	0.99577
6	-0.0012353	0.99454	0.9953
7	-0.0017394	0.99681	0.99624
8	-1.0046	-0.022734	1.1156
9	0.99485	-0.99476	1.9899
10	0.0064648	-0.020114	0.088451

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.068926
2	0.057256
3	0.046734
4	0.047221
5	0.053737
6	0.040791
7	0.038567
8	0.036691
9	0.041383
10	0.033408

Estudio estadístico:

Estadistica	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud	Tiempo_Total
{'Media' }	-0.0075167	0.19409	0.68128	0.046471
{'Desviacion_Estandar'}	0.47152	0.63099	0.65248	0.010857

Ejecución del código del método del gradiente

```
Número de iteraciones: 1000
Tamaño de la perturbación (hstep): 0.0001
Paso de optimización (alfa): 0.001
```

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	-2.9849	-3.9798	24.874	0.24221
2	-3.9798	-4.9747	40.793	0.20683
3	0.99491	-5e-05	0.99496	0.18362
4	-0.99501	3.9797	16.914	0.14813
5	2.9848	-5e-05	8.9546	0.14971
6	-2.9849	2.9848	17.909	0.14663
7	-2.9849	2.9848	17.909	0.13946
8	2.9848	-3.9798	24.874	0.1455
9	-2.9849	-1.99	12.934	0.14583
10	-3.9798	-2.9849	24.874	0.1411

```
Estadísticas de los valores óptimos encontrados:
  Media: 19.1031
  Desviación estándar: 10.7855
  Mínimo: 0.9950
  Máximo: 40.7930

Estadísticas de los tiempos de ejecución:
  Media: 0.1649 segundos
  Desviación estándar: 0.0348 segundos
  Mínimo: 0.1395 segundos
  Máximo: 0.2422 segundos
```

Ejecución del código del método híbrido

Resultados obtenidos:

Ejecucion	Mejor_Solucion_Genetica_X	Mejor_Solucion_Genetica_Y	Valor_Aptitud_Genetica
1	-0.008635	-0.96389	1.2002
2	1.0015	0.98329	2.0254
3	0.0017135	-0.0012752	0.00090506
4	0.98602	-1.0071	2.0351
5	-0.028464	-0.98905	1.1622
6	0.98301	0.98084	2.0577
7	-0.99092	0.9952	1.9932
8	-0.0044674	1.9817	3.9972
9	-0.0082178	0.99508	1.0084
10	0.97014	0.0026609	1.1181

Mejor_Solucion_Refinada_X	Mejor_Solucion_Refinada_Y	Valor_Aptitud_Refinada
-5.8272e-07	-0.99496	0.99496
0.99496	0.99496	1.9899
1.4471e-06	-1.077e-06	6.4555e-10
0.99496	-0.99496	1.9899
-1.9304e-06	-0.99496	0.99496
0.99496	0.99496	1.9899
-0.99496	0.99496	1.9899
-8.2822e-07	1.9899	3.9798
-1.524e-06	0.99496	0.99496
0.99496	1.7948e-07	0.99496

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.043991
2	0.021095
3	0.016949
4	0.020359
5	0.022905
6	0.020698
7	0.020754
8	0.015075
9	0.024433
10	0.025397

Estudio estadístico:

Estadistica	Valor_Aptitud_Genetica	Valor_Aptitud_Refinada	Tiempo_Total
{'Media' }	1.6598	1.5919	0.023165
{'Desviacion_Estandar'}	1.0507	1.0695	0.0079479

Anexo 9

Resultados de las ejecuciones de los códigos para la función de Rosenbrock.

Ejecución del código del algoritmo genético.

Resultados obtenidos:

Ejecucion	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud
1	1.1306	1.2822	0.018551
2	0.90272	0.81974	0.011791
3	0.99387	0.98785	3.8159e-05
4	1.17	1.3638	0.031555
5	0.44563	0.18556	0.32429
6	0.72505	0.52589	0.0756
7	0.99173	0.98283	0.00011678
8	0.86566	0.75158	0.018536
9	1.0029	1.0105	0.0022101
10	0.57597	0.31269	0.21612

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.073818
2	0.10584
3	0.072729
4	0.083961
5	0.090576
6	0.068797
7	0.078374
8	0.059466
9	0.070008
10	0.065985

Estudio estadístico:

Estadistica	Mejor_Solucion_X1	Mejor_Solucion_X2	Valor_Aptitud	Tiempo_Total
{'Media' }	0.88042	0.82226	0.069881	0.076955
{'Desviacion_Estandar'}	0.23412	0.38748	0.11085	0.013497

Ejecución del código del método del gradiente.

Resultados de cada ejecución:

Ejecución	x1	x2	Valor_Óptimo	Tiempo_Ejecución
1	0.7778	0.604	0.049469	0.15927
2	0.66682	0.44308	0.11125	0.11591
3	0.7086	0.50078	0.085092	0.11386
4	0.66724	0.44364	0.11098	0.10908
5	0.67231	0.45045	0.10762	0.11265
6	0.59748	0.35501	0.16241	0.11066
7	0.66625	0.44231	0.11164	0.11165
8	0.98289	0.96606	0.0002929	0.11035
9	0.63085	0.3962	0.13659	0.11285
10	0.68151	0.46297	0.10166	0.11034

Estadísticas de los valores óptimos encontrados:
- Media: 0.0977
- Desviación estándar: 0.0451
- Mínimo: 0.0003
- Máximo: 0.1624

Estadísticas de los tiempos de ejecución:
- Media: 0.1167 segundos
- Desviación estándar: 0.0151 segundos
- Mínimo: 0.1091 segundos
- Máximo: 0.1593 segundos

Ejecución del código del método híbrido.

Resultados obtenidos:

Ejecucion	Mejor_Solucion_Genetica_X	Mejor_Solucion_Genetica_Y	Valor_Aptitud_Genetica
1	0.64489	0.41568	0.12611
2	0.54201	0.27759	0.23595
3	0.59149	0.34276	0.17192
4	0.99898	0.99783	2.7301e-06
5	0.15825	0.023862	0.70869
6	0.53804	0.30714	0.24458
7	-0.61192	0.37088	2.5996
8	0.35533	0.12134	0.41802
9	0.51668	0.27299	0.23724
10	0.23731	0.058929	0.58237

Mejor_Solucion_Refinada_X	Mejor_Solucion_Refinada_Y	Valor_Aptitud_Refinada
0.8108	0.65655	0.035868
0.77201	0.59496	0.052086
0.7898	0.62283	0.044274
0.99893	0.99786	1.1444e-06
0.69347	0.47944	0.094174
0.77608	0.60129	0.050242
0.57517	0.32872	0.18092
0.72604	0.52585	0.075218
0.76768	0.58827	0.054086
0.70534	0.49611	0.087019

Tiempos de ejecución (segundos):

Ejecucion	Tiempo_Total
1	0.050953
2	0.021624
3	0.025277
4	0.023458
5	0.022513
6	0.012987
7	0.012336
8	0.013112
9	0.012239
10	0.018821

Estudio estadístico:

Estadistica	Valor_Aptitud_Genetica	Valor_Aptitud_Refinada	Tiempo_Total
{'Media' }	0.53245	0.067389	0.021332
{'Desviacion_Estandar'}	0.75691	0.048106	0.011576