

Nuevo enfoque algorítmico para la mejora en convergencia y dispersión de algoritmos evolutivos biobjetivos que aproximan al completo el frente de Pareto.

**Antonio Borrego Ortega**

Mariano Luque Gallego

Rubén Saborido Infantes

I Iberian Conference on MCDM/A (IMCDM/A)

mayo de 2025

## Indice

- 1 Conceptos básicos.
- 2 Motivación.
- 3 Enfoque algorítmico.
  - Resultados.
- 4 Conclusión y trabajo futuro.

## ¿Qué es un problema de optimización multiobjetivo (MOP)?

Se define como


$$\begin{array}{ll} \text{maximizar} & \mathbf{f}(\mathbf{x}) = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x}))^T \\ \text{s.a} & \mathbf{x} \in \Omega \subseteq \mathbb{R}^m, \end{array} \quad (1)$$

- $\mathbf{x}$  es una solución  $m$ -dimensional en la región factible  $\Omega$ .
- $Z = f(\Omega)$  constituye el espacio objetivo.
- $\mathbf{f} : \Omega \rightarrow \mathbb{R}^k$  es un vector  $k$ -dimensional en el espacio objetivo  $\mathbb{R}^k$ .

## Solución Eficiente y frente de Pareto óptimo (POF)

Una solución  $\mathbf{x} \in \Omega$  se dice que domina a una solución  $\bar{\mathbf{x}} \in \Omega$  si:


- $f_i(\mathbf{x}) \leq f_i(\bar{\mathbf{x}})$  para todo  $i = 1, \dots, k$ ,  $f_j(\mathbf{x}) < f_j(\bar{\mathbf{x}})$
- $\mathbf{x}$  es una solución **eficiente** si no existe ninguna solución  $\bar{\mathbf{x}} \in \Omega$  que la domine.



- El conjunto de todas las soluciones eficientes se denomina conjunto eficiente (**E**).
- La imagen de dicho conjunto por  $f$ ,  $f(E)$ , se denomina **POF**

## Vector ideal y vector nadir

- *Vector ideal*  $\mathbf{z}^* = (z_1^*, z_2^*, \dots, z_k^*)^T$  es el vector objetivo con  $z_i^* = \min_{\mathbf{x} \in E} f_i(\mathbf{x}) = \min_{\mathbf{x} \in \Omega} f_i(\mathbf{x})$ ,  $i = 1, 2, \dots, k$ .
- *Vector nadir*  $\mathbf{z}^{nad} = (z_1^{nad}, z_2^{nad}, \dots, z_k^{nad})^T$  es el vector objetivo con  $z_i^{nad} = \max_{\mathbf{x} \in E} f_i(\mathbf{x})$ ,  $i = 1, 2, \dots, k$ .



## Función de logro de Wierbizcki

- Punto de referencia:  $\mathbf{q} = (q_1, \dots, q_k)^T$ .
- Vector de pesos:  $\boldsymbol{\mu} = (\mu_1, \dots, \mu_k)^T$ ,  $\mu_i > 0$  ( $i = 1, \dots, k$ )
- $\rho > 0$ , que debe ser un valor pequeño, es el denominado término aumentado.

$$s(\mathbf{q}, \mathbf{f}(\mathbf{x}), \boldsymbol{\mu}) = \max_{i=1, \dots, k} \{ \mu_i (f_i(\mathbf{x}) - q_i) \} + \rho \sum_{i=1}^k \mu_i (f_i(\mathbf{x}) - q_i) \quad (2)$$

## Aplicación

Fijados un punto  $\mathbf{q}$  y un vector de pesos  $\boldsymbol{\mu}$ , obtener  $\min_{\mathbf{x} \in \Omega} s(\mathbf{q}, \mathbf{f}(\mathbf{x}), \boldsymbol{\mu})$  equivale a encontrar la una solución eficiente asociada a dicho punto y dicho vector.


# ¿Qué es un Algoritmo Evolutivo?

- Un **algoritmo evolutivo** es un algoritmo inspirado en el proceso de la evolución biológica.
- La rama que estudia la aplicación de dichos algoritmos en optimización multiobjetivo se conoce como **EMO**.
- Los algoritmos EMO son enfoques basados en población.
- Estos algoritmos buscan encontrar soluciones óptimas a problemas complejos mediante procesos de **selección**, **mutación** y **reproducción**.
- El objetivo es mejorar gradualmente las soluciones a lo largo de un conjunto de generaciones.

# Esquema flujo EMO


## Pasos en un EMO

- 1 Inicialización
- 2 Evaluación
- 3 Selección
- 4 Recombinación y Mutación
- 5 Reemplazo
- 6 Repetir



## Objetivos de un EMO sin preferencias

- Convergencia sobre el frente de Pareto del problema.
- Diversidad en los óptimo de Pareto que se obtienen para mostrar una distribución uniforme del POF.



## Marco Algorítmico AS-MOEA

- Marco algorítmico que permita establecer un **equilibrio** entre convergencia y diversidad.
- **Adaptable** a cualquier EMO sin preferencias.
- Mejore o mantenga el comportamiento del EMO de partida en términos de convergencia, dispersión y uniformidad de soluciones.
- Problemas bi-objetivos.

## Estructura general

- **Fase 1:** Estudiar la aproximación del POF obtenida inicialmente por el EMO y dividirla en subregiones.
- **Fase 2:** Continuar el proceso de optimización del tramo del POF que encontramos en cada subregion de manera local aplicando al función de logro.

## Notación

- $N$ , tamaño de la población.
- $P^h$ , población en el espacio objetivo obtenida en la generación  $h$  del algoritmo.
- $NG_T = NG_{T_1} + NG_{T_2}$ ,  $NG_{T_1} = p \cdot NG_T$ ,  $0 < p < 1$ .

## Objetivo Fase 1

- Obtener una aproximación inicial del POF.
- Identificar subregiones dentro de la aproximación.

## Generaciones Fase 1

$NG_{T_1} = p \cdot NG_T$  generaciones del algoritmo

No demasiado pequeño  $\rightarrow$  obtener una buena aproximación inicial

No demasiado grande  $\rightarrow$  que resten generaciones para la **Fase 2**.


# Enfoque algorítmico: Fase 1

## División en subregiones

- 1 Se divide  $r_1$  en  $N_s$  intervalos de misma longitud.
- 2 Estimamos el punto ideal y nadir de cada intervalo,  $\mathbf{z}^{l,r} = (z_1^{l,r}, z_2^{l,r})$  y  $\mathbf{z}^{u,r} = (z_1^{u,r}, z_2^{u,r}), r = \{1, \dots, N_s\}$ .

Finalmente se define para  $r = \{1, \dots, N_s\}$ :

$$S_r = \{\mathbf{z} = (z_1, z_2) \in Z, \text{ tal que } z_i^{l,r} \leq z_i \leq z_i^{u,r}, i = 1, 2\},$$



**Figura:** Aproximación de POF del problema IDTLZ2 por el algoritmo NSGA-III con  $N = 60$  tras  $NG_{T_1} = 250$  generaciones.

## Objetivo Fase 2

- Mejorar en términos de dispersión, convergencia y uniformidad la aproximación.
- Aproximar la parte de POF que pertenece a cada subregion localmente.

## Parámetros para cada $S_r$

- Punto de referencia,  $\mathbf{q}^r$ .
- Muestra de vectores de peso,  $\boldsymbol{\mu}^{rj}$ ,  $j = 1, \dots, n_r$ .

- $$\sum_{r=1}^{N_s} n_r = N.$$

### Cálculo de $\mu^{r,j}$ , $j = 1, \dots, n_r$


- 1 Se decide qué cantidad de vectores de peso ( $n_r$ ) se utilizan para aproximar cada  $S_r$ .
- 2 Se genera  $n_r$  de vectores igualmente distribuidos en  $(0, 1)^2$ .
- 3 Se ajustan  $\mu_1^{r,j}$  y  $\mu_2^{r,j}$  con los rangos de variación de los objetivos en dichas subregiones.

# Enfoque algorítmico: Fase 2


## Cálculo de $\mu^{r,j}$ , $j = 1, \dots, n_r$

- 1 Se decide qué cantidad de vectores de peso ( $n_r$ ) se utilizan para aproximar cada  $S_r$ .
- 2 Se genera  $n_r$  de vectores igualmente distribuidos en  $(0, 1)^2$ .
- 3 Se ajustan  $\mu_1^{r,j}$  y  $\mu_2^{r,j}$  con los rangos de variación de los objetivos en dichas subregiones.

## Cálculo de $q^r$



(a)  $q^1 = z^{l,1}$ .



(b)  $q^1 = z^{u,1}$ .


## Clasificación en fronteras

- 1 Aplicamos operadores de mutación y cruce sobre  $P^h$  generando  $N$  individuos nuevos y consideramos la población combinada  $P$  de  $2N$  individuos.
- 2 Calculamos para todo  $\mathbf{x} \in P$  el valor de  $s(\mathbf{q}^r, f(\mathbf{x}), \boldsymbol{\mu}^{r,j})$ .
- 3 Incluimos en  $F_1^h$  la solución que minimiza dicho valor y la eliminamos temporalmente de  $P$
- 4 Repetimos dicho proceso para cada vector asociado a cada subregion.
- 5  $F_1^h = P^{h+1}$

## Ajuste de subregiones


Abarcar zonas del POF no obtenidas en la aproximación inicial del EMO.

## Enfoque algorítmico: Fase 2



**Figura:** Aproximación de POF del problema IDTLZ2 aplicando AS-MOEA NSGAIII con  $N = 60$  tras 375 generaciones (250 aplicando Fase 1 y 125 aplicando Fase 2).

# Enfoque algorítmico: Fase 2



■ NSGAIII

■ ASMOEA-NSGAIII

## Métricas

- Hypervolume ( $HV$ ).
- *Spread*.
- Spacing ( $Sp$ ).

## Parámetros

- Tamaño de la población:  $N = 180$ .
- Número máximo de generaciones:  $h_{max} = 200$ .
- Número de veces que ajustamos las subregiones:  $n_a = 10$ .
- Número de subregiones consideradas:  $N_s = 3$ .
- Porcentaje de generaciones aplicadas a la cada fase: 50% ( $p = 0.5$ ).

## Problemas

Un total de 22 problemas test que proporciona PlatEMO. (ZDT, IDTLZ, DTLZ, WFG).

- Comparativa NSGAIII con ASMOEA-NSGAIII:

<b>Métrica</b>	<b>+</b>	<b>=</b>	<b>-</b>
HV	10	7	5
Spread	11	3	8
Sp	14	1	7

- Comparativa RVEA con ASMOEA-RVEA:

<b>Métrica</b>	<b>+</b>	<b>=</b>	<b>-</b>
HV	21	0	1
Spread	15	4	3
Sp	20	1	1

## Próximos enfoques

- Estudiar como definir las subregiones en problemas de 3, 5 y 8 objetivos respectivamente.
- Estudiar detalladamente el cómo escoger el número de generaciones asignados a cada Fase.
- Realizar pruebas para más algoritmos que aproximen el frente al completo.
- Estudiar como afecta el incremento en el número de subregiones para los diferentes problemas.
- Ajustar las subregiones para ampliar los extremos en caso de no tener una buena aproximación.