



GRUPO ESPAÑOL DE DECISIÓN MULTICRITERIO



UNIVERSIDAD
DE MÁLAGA

Algoritmo Evolutivo de Optimización Multiobjetivo basado en Niveles de Aspiración y Reserva (ERAL)

Sandra González-Gallardo, R. Saborido, A.B. Ruiz, M. Luque
Departamento de Economía Aplicada
(Matemáticas)
Universidad de Málaga
sandragg@uma.es

Introducción

El algoritmo ERAL

Experimentos computacionales

Conclusiones

Introducción - Definiciones

- ▶ Los problemas de optimización multiobjetivo son problemas que optimizan varios objetivos en conflicto, simultáneamente.
- ▶ *Algoritmos Evolutivos de Optimización multiobjetivo* (EMO algorithms) resuelven problemas de optimización multiobjetivo generando un conjunto de soluciones no dominadas que aproximan la frontera Pareto. Estas soluciones deben estar uniformemente distribuidas y estar suficientemente cerca de la misma.
- ▶ *EMO algoritmos basados en descomposición:*
 - ▶ MOEA/D [7, 8, 10, 16]
 - ▶ NSGA-III [2, 6]
 - ▶ GWASF-GA [12] y su versión mejorada A-GWASF-GA [4, 9].

- ▶ Un *decisor (DM)* es una persona experta en el dominio del problema que debe dar sus preferencias para localizar la solución más preferida del problema como solución final del problema.
- ▶ Las preferencias se incluyen en la resolución del problema en los llamados enfoques EMO basados en preferencias.
- ▶ Su principal objetivo es aproximar solo el conjunto de soluciones Pareto óptimas que corresponden con las preferencias del decisor: *región de interes (ROI)*.
- ▶ Algunos ejemplos: WASF-GA [11] y IRA-EMO [13].

Evolutionary algorithm based on Reservation-Aspiration Levels (ERAL).

- ▶ Las preferencias se expresan mediante dos puntos dados por el decisor:
 - ▶ Valores deseados para las funciones objetivo.
 - ▶ Valores aceptables de las funciones objetivo para el decisor.
- ▶ ERAL aproxima la ROI que incluye las soluciones Pareto óptimas verificando las preferencias dadas por el decisor.

- ▶ Un *punto de referencia*, denotada por $\mathbf{q} = (q_1, \dots, q_k)^T \in \mathbb{R}^k$, es un punto en el que cada q_i es un valor deseado para la función objetivo f_i dado por el decisor ($i = 1, \dots, k$).
 - ▶ **Alcanzable**: si $\mathbf{q} \in Z$ o \mathbf{q} es dominado por un vector objetivo Pareto óptimo.
 - ▶ **Inalcanzable**: si $\mathbf{q} \notin Z$ o \mathbf{q} domina los vectores objetivo Pareto óptimo.

Trabajando con preferencias

La función de logro de Wierzbiki's [14] se define como sigue:

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

donde:

- ▶ \mathbf{q} es un punto de referencia.
- ▶ $\mu = (\mu_1, \dots, \mu_k)^T$, con $\mu_i > 0$ para $i = 1, \dots, k$, es un vector de pesos.
- ▶ ρ es un número real positivo asegurando que una solución que minimiza esta función sobre la región factible S es siempre una solución Pareto óptima del problema original.

Trabajando con preferencias

- ▶ Preferencias en ERAL: dos puntos de referencia:
 - ▶ Punto de aspiración $\mathbf{q}^a = (q_1^a, \dots, q_k^a)^T$: valores deseados para las funciones objetivo, es decir, valores a alcanzar si es posible.
 - ▶ Punto de reserva $\mathbf{q}^r = (q_1^r, \dots, q_k^r)^T$: valores considerados como aceptables por el decisor, es decir, valores por encima de los cuales las funciones objetivos no son admisibles.




Figure: ROI definida por \mathbf{q}^a y \mathbf{q}^r .

Idea principal

- ▶ ERAL aproxima la ROI definida por el decisor a través de los puntos de referencia.
- ▶ En primer lugar, se obtiene una aproximación de la ROI definida por el punto de reserva, usando un conjunto de vectores de pesos.
- ▶ En segundo lugar, el procedimiento se reconsidera dependiendo de la relación de dominancia entre las soluciones no dominadas encontradas hasta el momento con respecto a \mathbf{q}^r y \mathbf{q}^a .
- ▶ Requisitos: \mathbf{q}^a y \mathbf{q}^r , $W = \{\boldsymbol{\mu}^1, \dots, \boldsymbol{\mu}^{N_\mu}\}$ con N_μ vectores de pesos, $G_T = G_p + G_{1-p}$ número de generaciones.

- ▶ **Paso 1.** Las primeras generaciones de ERAL ($G_p = p \cdot G_T$) se hacen utilizando en WASF-GA ¹ el conjunto de vectores de pesos W y q^r como punto de referencia.

¹A. B. Ruiz, R. Saborido, and M. Luque. A preference-based evolutionary algorithm for multiobjective optimization: the weighting achievement scalarizing function genetic algorithm. *Journal of Global Optimization*, 62:101–129, 2015

Algoritmo ERAL

- ▶ **Paso 1.** Las primeras generaciones de ERAL ($G_p = p \cdot G_T$) se hacen utilizando en WASF-GA ¹ el conjunto de vectores de pesos W y \mathbf{q}^r como punto de referencia.
- ▶ **Paso 2.** Analizamos la relación de dominancia entre las soluciones no dominadas con respecto a \mathbf{q}^r y \mathbf{q}^a .

¹A. B. Ruiz, R. Saborido, and M. Luque. A preference-based evolutionary algorithm for multiobjective optimization: the weighting achievement scalarizing function genetic algorithm. *Journal of Global Optimization*, 62:101–129, 2015

Algoritmo ERAL

- ▶ **Paso 1.** Las primeras generaciones de ERAL ($G_p = p \cdot G_T$) se hacen utilizando en WASF-GA ¹ el conjunto de vectores de pesos W y \mathbf{q}^r como punto de referencia.
- ▶ **Paso 2.** Analizamos la relación de dominancia entre las soluciones no dominadas con respecto a \mathbf{q}^r y \mathbf{q}^a .
 - ▶ $\mathbf{D}^r = \{\mathbf{x} \in P^{G_p} / \mathbf{f}(\mathbf{x}) \text{ dominando a } \mathbf{q}^r\}$.

¹A. B. Ruiz, R. Saborido, and M. Luque. A preference-based evolutionary algorithm for multiobjective optimization: the weighting achievement scalarizing function genetic algorithm. *Journal of Global Optimization*, 62:101–129, 2015

Algoritmo ERAL

- ▶ **Paso 1.** Las primeras generaciones de ERAL ($G_p = p \cdot G_T$) se hacen utilizando en WASF-GA ¹ el conjunto de vectores de pesos W y \mathbf{q}^r como punto de referencia.
- ▶ **Paso 2.** Analizamos la relación de dominancia entre las soluciones no dominadas con respecto a \mathbf{q}^r y \mathbf{q}^a .
 - ▶ $\mathbf{D}^r = \{\mathbf{x} \in P^{G_p} / \mathbf{f}(\mathbf{x}) \text{ dominando a } \mathbf{q}^r\}$.
 - ▶ $\mathbf{D}^a = \{\mathbf{x} \in P^{G_p} / \mathbf{f}(\mathbf{x}) \text{ dominando a } \mathbf{q}^a\}$.

¹A. B. Ruiz, R. Saborido, and M. Luque. A preference-based evolutionary algorithm for multiobjective optimization: the weighting achievement scalarizing function genetic algorithm. *Journal of Global Optimization*, 62:101–129, 2015

Algoritmo ERAL

- ▶ **Paso 1.** Las primeras generaciones de ERAL ($G_p = p \cdot G_T$) se hacen utilizando en WASF-GA ¹ el conjunto de vectores de pesos W y \mathbf{q}^r como punto de referencia.
- ▶ **Paso 2.** Analizamos la relación de dominancia entre las soluciones no dominadas con respecto a \mathbf{q}^r y \mathbf{q}^a .
 - ▶ $\mathbf{D}^r = \{\mathbf{x} \in P^{G_p} / \mathbf{f}(\mathbf{x}) \text{ dominando a } \mathbf{q}^r\}$.
 - ▶ $\mathbf{D}^a = \{\mathbf{x} \in P^{G_p} / \mathbf{f}(\mathbf{x}) \text{ dominando a } \mathbf{q}^a\}$.
 - ▶ $\mathbf{D}^{r,a} = \{\mathbf{x} \in P^{G_p} / \mathbf{f}(\mathbf{x}) \text{ dominando a } \mathbf{q}^r \text{ y dominados por } \mathbf{q}^a\}$.

¹A. B. Ruiz, R. Saborido, and M. Luque. A preference-based evolutionary algorithm for multiobjective optimization: the weighting achievement scalarizing function genetic algorithm. *Journal of Global Optimization*, 62:101–129, 2015

- ▶ **Paso 3.** Dependiendo del número de soluciones en D^r , D^a y $D^{r,a}$ se distinguen tres escenarios:

Algoritmo ERAL

- ▶ **Paso 3.** Dependiendo del número de soluciones en D^r , D^a y $D^{r,a}$ se distinguen tres escenarios:
 - ▶ **Escenario 1:** Si $D^r = \emptyset \Rightarrow \mathbf{q}^r$ y \mathbf{q}^a son inalcanzables.
 - ▶ Las últimas G_{1-p} generaciones se hacen usando en WASF-GA los vectores de pesos en W y \mathbf{q}^r .

Algoritmo ERAL

- ▶ **Paso 3.** Dependiendo del número de soluciones en D^r , D^a y $D^{r,a}$ se distinguen tres escenarios:
 - ▶ **Escenario 1:** Si $D^r = \emptyset \Rightarrow \mathbf{q}^r$ y \mathbf{q}^a son inalcanzables.
 - ▶ Las últimas G_{1-p} generaciones se hacen usando en WASF-GA los vectores de pesos en W y \mathbf{q}^r .
 - ▶ **Escenario 2:** Si $D^a \neq \emptyset \Rightarrow \mathbf{q}^r$ y \mathbf{q}^a son alcanzables.
 - ▶ Las últimas G_{1-p} generaciones se ejecutan usando en WASF-GA los vectores de pesos en W y \mathbf{q}^a .

- ▶ **Paso 3.** Dependiendo del número de soluciones en D^r , D^a y $D^{r,a}$ se distinguen tres escenarios:
 - ▶ **Escenario 1:** Si $D^r = \emptyset \Rightarrow \mathbf{q}^r$ y \mathbf{q}^a son inalcanzables.
 - ▶ Las últimas G_{1-p} generaciones se hacen usando en WASF-GA los vectores de pesos en W y \mathbf{q}^r .
 - ▶ **Escenario 2:** Si $D^a \neq \emptyset \Rightarrow \mathbf{q}^r$ y \mathbf{q}^a son alcanzables.
 - ▶ Las últimas G_{1-p} generaciones se ejecutan usando en WASF-GA los vectores de pesos en W y \mathbf{q}^a .
 - ▶ **Escenario 3:** Si $D^{r,a} \neq \emptyset$ y $D^a = \emptyset \Rightarrow \mathbf{q}^r$ es alcanzable y \mathbf{q}^a es inalcanzable.
 - ▶ $q^{min,i}$: el mínimo valor alcanzado por la función objetivo f_i de $D^{r,a}$.
 - ▶ Se define un nuevo punto de aspiración:
 $\mathbf{q}^a = (q^{min,1}, q^{min,2}, \dots, q^{min,k})$.
 - ▶ En las últimas G_{1-p} generaciones se ejecuta usando en WASF-GA los vectores de pesos en W y $\hat{\mathbf{q}}^a$.

Adaptaciones de ERAL

Los vectores de pesos se pueden adaptar en las últimas G_{1-p} generaciones teniendo en cuenta las características del frente Pareto siguiendo las adaptaciones:

- ▶ A-GWASF-GA \Rightarrow Adapt-ERAL

M. Luque, S. Gonzalez-Gallardo, R. Saborido, and A. B. Ruiz. Adaptive Global WASF-GA to handle many-objective optimization problems. *Swarm and Evolutionary Computation*, 54:100644, 2020.

- ▶ AdaW \Rightarrow AdaW-ERAL

M. Li and X. Yao. What weights work for you? Adapting weights for any Pareto front shape in decomposition-based evolutionary multiobjective optimisation. *Evolutionary Computation*, 28(2):227–253, 2020.

- ▶ NSGA-III [2] y MOEA/D-DE [7] usando restricciones.
- ▶ Problemas test DTLZ [3], UF [17], WFG [5], y ZDT [18].
 - ▶ Problemas 2D : DTLZ1-4, DTLZ7, UF1-7, WFG1-9, ZDT1-4 y ZDT6.
 - ▶ Problemas 3D: DTLZ1-4, DTLZ7, UF8-10, y WFG1-9.
 - ▶ Problemas 5D: DTLZ1-4, DTLZ7 y WFG1-9.
- ▶ Tamaño de la población N : 50, 91, y 210 para problemas con dos-, tres-, y cinco-objetivos, respectivamente.

Diseño experimental

- ▶ Número máximo de generaciones $G_T = 400, 600, \text{ y } 800$.
- ▶ Seis pares de \mathbf{q}^r y \mathbf{q}^a se generan aleatoriamente para cada problema.
- ▶ En ERAL, $p = 0.6$, $G_p = 240, 360, \text{ y } 480$.
- ▶ La métrica utilizada es el hypervolumen (HV).
- ▶ 10 ejecuciones independiente se hacen para cada algoritmo, cada problema y cada par de niveles de preferencias \mathbf{q}^r y \mathbf{q}^a .

- ▶ Las tablas muestran la media del HV normalizado en las 60 ejecuciones independientes.
- ▶ El algoritmo con el mejor valor del HV se resalta en gris.
- ▶ Wilcoxon rank-sum test [15]: El número de problemas para los que la media del HV de ERAL es significativamente mejor que (\blacktriangle), igual a (\odot), o peor que (\blacktriangledown) la media del HV del resto de algoritmos indicados.

Resultados

	ERAL	Adapt-ERAL	AdaW-ERAL	cNSGA-III	cMOEA/D-DE
ZDT1	0.312165	0.308950	0.312097	0.033540	0.033247
ZDT2	0.315462	0.301031	0.315303	0.035532	0.032672
ZDT3	0.264606	0.263677	0.263629	0.100879	0.107209
ZDT4	0.262439	0.251519	0.261923	0.135729	0.088389
ZDT6	0.321833	0.282529	0.321832	0.040547	0.033258
DTLZ1	0.268410	0.248618	0.251158	0.184671	0.047143
DTLZ2	0.308894	0.308782	0.308891	0.041209	0.032225
DTLZ3	0.281903	0.256901	0.278311	0.165407	0.017478
DTLZ4	0.279099	0.277408	0.307951	0.068421	0.067121
DTLZ7	0.264279	0.264270	0.264272	0.110798	0.096381
UF1	0.256288	0.247120	0.239971	0.128314	0.128308
UF2	0.273412	0.268791	0.273006	0.117618	0.067173
UF3	0.176749	0.155086	0.203300	0.167302	0.164229
UF4	0.231336	0.250745	0.284974	0.102634	0.080311
UF5	0.188029	0.182681	0.224625	0.157101	0.130896
UF6	0.185287	0.223413	0.175621	0.155760	0.126585
UF7	0.343821	0.241429	0.277026	0.067704	0.053353
WFG1	0.186270	0.189801	0.226501	0.030068	0.100694
WFG2	0.284954	0.282962	0.284759	0.073809	0.073516
WFG3	0.245462	0.243980	0.245453	0.133846	0.131259
WFG4	0.312273	0.310428	0.312500	0.033714	0.031085
WFG5	0.246825	0.246834	0.246820	0.136243	0.123278
WFG6	0.265481	0.263599	0.273305	0.099507	0.098108
WFG7	0.294587	0.283030	0.295603	0.068986	0.057794
WFG8	0.179413	0.177196	0.180587	0.065579	0.063892
WFG9	0.309856	0.314398	0.323509	0.034465	0.017772
	15/26	1/26	10/26	0/26	0/26

Resultados

	ERAL	Adapt-ERAL	AdaW-ERAL	cNSGA-III	cMOEA/D-DE
DTLZ1	0.295427	0.302241	0.295516	0.075096	0.031720
DTLZ2	0.313179	0.311728	0.310213	0.035496	0.029384
DTLZ3	0.290967	0.287716	0.289795	0.080680	0.050843
DTLZ4	0.238018	0.230525	0.234331	0.077804	0.052655
DTLZ7	0.288185	0.280372	0.303615	0.064925	0.062902
UF8	0.079415	0.063133	0.038694	0.050908	0.084516
UF9	0.161201	0.163661	0.188460	0.145893	0.157452
WFG1	0.122455	0.107503	0.129868	0.051597	0.088576
WFG2	0.077273	0.043045	0.034822	0.034413	0.027113
WFG3	0.089667	0.089745	0.089787	0.030848	0.033286
WFG4	0.037027	0.036371	0.037661	0.168835	0.053439
WFG5	0.115685	0.110300	0.107348	0.157546	0.175787
WFG6	0.204346	0.198139	0.201911	0.037557	0.024713
WFG7	0.147657	0.146507	0.147511	0.040079	0.018245
WFG8	0.170475	0.159384	0.170141	0.311600	0.188400
WFG9	0.133397	0.144890	0.144585	0.227356	0.166439
	6/16	1/16	4/16	3/16	2/16

Resultados

	ERAL	Adapt-ERAL	AdaW-ERAL	cNSGA-III	cMOEA/D-DE
DTLZ1	0.233377	0.244917	0.232367	0.194458	0.094880
DTLZ2	0.307107	0.318787	0.305108	0.044157	0.024840
DTLZ3	0.265165	0.256079	0.261278	0.131155	0.086323
DTLZ4	0.293841	0.288255	0.295033	0.083468	0.039402
DTLZ7	0.284977	0.280613	0.287338	0.095719	0.051353
WFG1	0.292130	0.289321	0.266132	0.048856	0.103561
WFG2	0.238526	0.203094	0.212721	0.134226	0.128100
WFG3	0.296543	0.300117	0.297351	0.082385	0.023604
WFG4	0.287069	0.351871	0.284760	0.054091	0.022209
WFG5	0.230014	0.233026	0.229931	0.218068	0.088961
WFG6	0.315492	0.308980	0.313490	0.043847	0.018192
WFG7	0.206172	0.235362	0.207187	0.261683	0.089595
WFG8	0.173586	0.164849	0.176948	0.193683	0.124267
WFG9	0.307159	0.311243	0.322319	0.039245	0.020034
	4/14	5/14	2/14	2/14	0/14

Table: Problemas en los que el HV medio de ERAL, Adapt-ERAL y AdaW-ERAL es mejor que (\blacktriangle), igual a (\odot) y peor que (∇) aquellos obtenidos por cNSGA-III y cMOEA/D-DE

		cNSGA-III			cMOEA/D-DE		
2D	ERAL	\blacktriangle 24	\odot 2	∇ 0	\blacktriangle 25	\odot 1	∇ 0
	Adapt-ERAL	\blacktriangle 25	\odot 1	∇ 0	\blacktriangle 25	\odot 1	∇ 0
	AdaW-ERAL	\blacktriangle 24	\odot 2	∇ 0	\blacktriangle 25	\odot 1	∇ 0
3D	ERAL	\blacktriangle 9	\odot 4	∇ 3	\blacktriangle 8	\odot 8	∇ 0
	Adapt-ERAL	\blacktriangle 9	\odot 5	∇ 2	\blacktriangle 8	\odot 8	∇ 0
	AdaW-ERAL	\blacktriangle 9	\odot 5	∇ 2	\blacktriangle 9	\odot 7	∇ 0
5D	ERAL	\blacktriangle 11	\odot 3	∇ 0	\blacktriangle 14	\odot 0	∇ 0
	Adapt-ERAL	\blacktriangle 11	\odot 3	∇ 0	\blacktriangle 14	\odot 0	∇ 0
	AdaW-ERAL	\blacktriangle 11	\odot 3	∇ 0	\blacktriangle 14	\odot 0	∇ 0

In this presentation:

- ▶ ERAL se propone para aproximar la ROI de la PF teniendo en cuenta los puntos \mathbf{q}^r y \mathbf{q}^a dados por el decisor.
- ▶ ERAL distingue entre tres escenarios dependiendo de la relación de dominancia entre las soluciones no dominadas con respecto a los puntos \mathbf{q}^r y \mathbf{q}^a .
- ▶ ERAL y sus dos versiones, Adapt-ERAL y AdaW-ERAL (donde se adaptan los vectores de pesos), generan resultados prometedores.

Futuras líneas de investigación

- ▶ Estudiar el desempeño del algoritmo en problemas con más funciones objetivo.
- ▶ Aplicar el algoritmo ERAL en problemas reales de ingeniería y economía.

References I

- [1] N. Cliff. *Ordinal methods for behavioral data analysis*. Psychology Press, 2014.
- [2] K. Deb and H. Jain. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, Part I: Solving problems with box constraints. *IEEE Transactions on Evolutionary Computation*, 18(4):577–601, 2014.
- [3] K. Deb, L. Thiele, M. Laumanns, and E. Zitzler. Scalable multi-objective optimization test problems. In *Congress on Evolutionary Computation (2002)*, pages 825–830, 2002.
- [4] S. González-Gallardo, R. Saborido, A. B. Ruiz, and M. Luque. An improvement study of the decomposition-based algorithm Global WASF-GA for evolutionary multiobjective optimization. In F. Herrera, S. Damas, R. Montes, S. Alonso, Ó. Cordon, A. González, and A. Troncoso, editors, *Advances in Artificial Intelligence*, pages 219–229. Springer International Publishing, 2018.
- [5] S. Huband, P. Hingston, L. Barone, and L. While. A review of multi-objective test problems and a scalable test problem toolkit. *IEEE Transactions on Evolutionary Computation*, 10(5):477–506, 2007.
- [6] H. Jain and K. Deb. An evolutionary many-objective optimization algorithm using reference-point based nondominated sorting approach, Part II: Handling constraints and extending to an adaptive approach. *IEEE Transactions on Evolutionary Computation*, 18(4):602–622, 2014.

References II

- [7] H. Li and Q. Zhang. Multiobjective optimization problems with complicated Pareto sets, MOEA/D and NSGA-II. *IEEE Transactions on Evolutionary Computation*, 12(2):284–302, 2009.
- [8] K. Li, K. Deb, and S. Kwong. An evolutionary many-objective optimization algorithm based on dominance and decomposition. *IEEE Transaction Evolutionary Computation*, 19(5):694–716, 2015.
- [9] M. Luque, S. Gonzalez-Gallardo, R. Saborido, and A. B. Ruiz. Adaptive Global WASF-GA to handle many-objective optimization problems. *Swarm and Evolutionary Computation*, 54:100644, 2020.
- [10] Y. Qi, X. Ma, F. Liu, L. Jiao, J. Sun, and J. Wu. MOEA/D with adaptive weight adjustment. *Evolutionary Computation*, 22(2):231–264, 2014.
- [11] A. B. Ruiz, R. Saborido, and M. Luque. A preference-based evolutionary algorithm for multiobjective optimization: the weighting achievement scalarizing function genetic algorithm. *Journal of Global Optimization*, 62:101–129, 2015.
- [12] R. Saborido, A. B. Ruiz, and M. Luque. Global WASF-GA: An evolutionary algorithm in multiobjective optimization to approximate the whole Pareto optimal front. *Evolutionary Computation*, 25(2):309–349, 2017.

References III

- [13] R. Saborido, A. B. Ruiz, M. Luque, and K. Miettinen. IRA-EMO: Interactive method using reservation and aspiration levels for evolutionary multiobjective optimization. In K. Deb, E. Goodman, C. A. C. Coello, K. Klamroth, K. Miettinen, S. Mostaghim, and P. Reed, editors, *Evolutionary Multi-Criterion Optimization*, volume 11411 of *Lecture Notes in Computer Science*, pages 618–630. Springer, 2019.
- [14] A. P. Wierzbicki. The use of reference objectives in multiobjective optimization. In G. Fandel and T. Gal, editors, *Multiple Criteria Decision Making, Theory and Applications*, pages 468–486. Springer, 1980.
- [15] F. Wilcoxon. Individual comparisons by ranking methods. *Biometrics Bulletin*, 1(6):80–83, 1945.
- [16] Q. Zhang and H. Li. MOEA/D: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on Evolutionary Computation*, 11(6):712–731, 2007.
- [17] Q. Zhang, A. Zhou, S. Zhao, P. N. Suganthan, W. Liu, and S. Tiwari. Multiobjective optimization test instances for the CEC 2009 special session and competition. *Technical Report*, (CES-487, University of Essex and Nanyang Technological University), 2008.
- [18] E. Zitzler, K. Deb, and L. Thiele. Comparison of multiobjective evolutionary algorithms: Empirical results. *Evolutionary Computation*, 8(2):173–195, 2000.

- [19] E. Zitzler and L. Thiele. Multiobjective evolutionary algorithms: A comparative case study and the strength Pareto approach. *IEEE Transactions on Evolutionary Computation*, 3(4):257–271, 1999.

¡GRACIAS POR SU ATENCIÓN!



GRUPO ESPAÑOL DE DECISIÓN MULTICRITERIO



UNIVERSIDAD
DE MÁLAGA

Algoritmo Evolutivo de Optimización Multiobjetivo basado en Niveles de Aspiración y Reserva (ERAL)

Sandra González-Gallardo, R. Saborido, A.B. Ruiz, M. Luque
Departamento de Economía Aplicada
(Matemáticas)
Universidad de Málaga
sandragg@uma.es