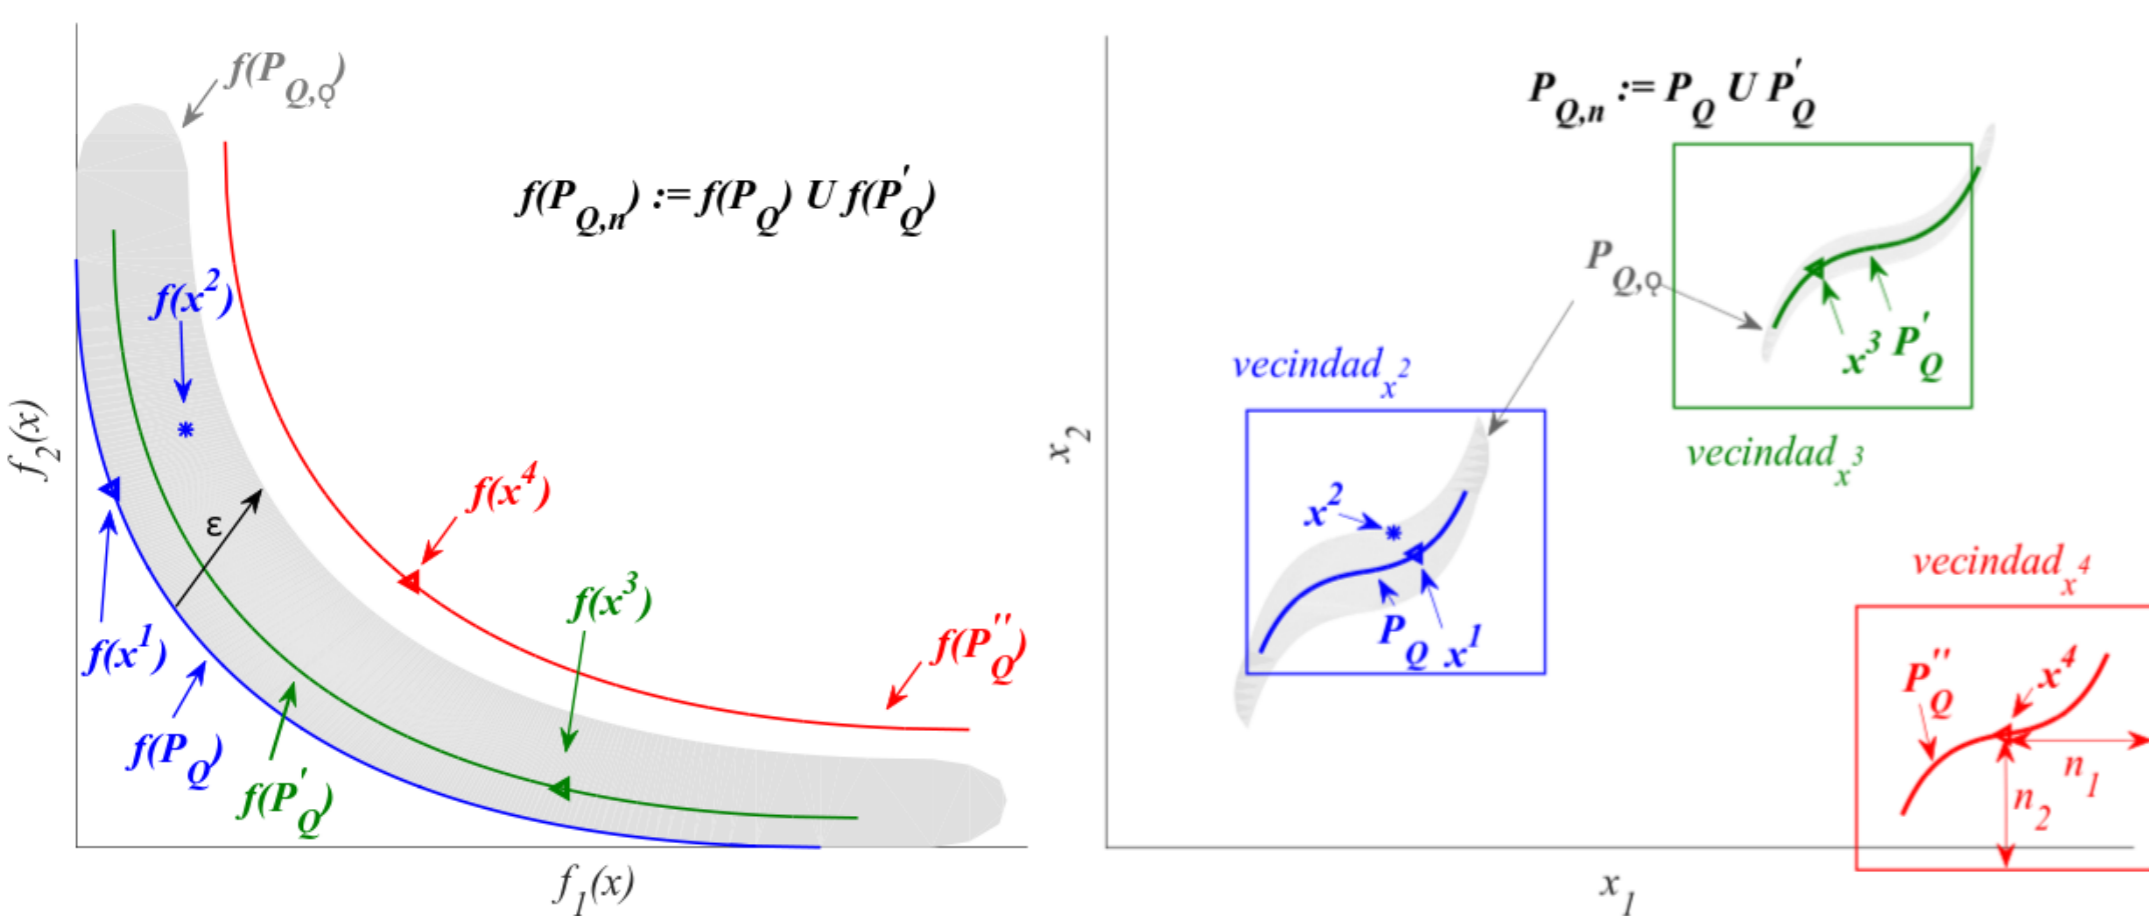


Introducción:

- Un Problema de Optimización Multiobjetivo (MOP) busca caracterizar un frente de Pareto.
- Pero las soluciones multimodales o soluciones sub-óptimas significativamente diferentes (no vecinas) son soluciones de interés que podrían ser descartadas en un MOP clásico.
- Por ello se presenta en este trabajo un nuevo algoritmo (nevMOGA) que obtiene no solo las soluciones óptimas del frente de Pareto sino también las sub-óptimas no dominadas en su vecindad.
- Estas soluciones son potencialmente útiles para el diseñador por sus buenas prestaciones y diferenciación con el resto de soluciones. Su estudio puede informar de: la buena elección o no de los objetivos, sobre-parametrización del problema, etc.
- La utilidad de estas soluciones se observa claramente cuando se agregan objetivos de diseño para simplificar la etapa de decisión, ya que de esta forma aparece una multimodalidad artificial y se definen unas preferencias a priori al agregar objetivos.
- Para este nuevo algoritmo es necesario definir la vecindad (hasta cuando consideramos que dos soluciones son similares) en el espacio de parámetros y ϵ (que consideramos como soluciones sub-óptimas) en el espacio de objetivos.



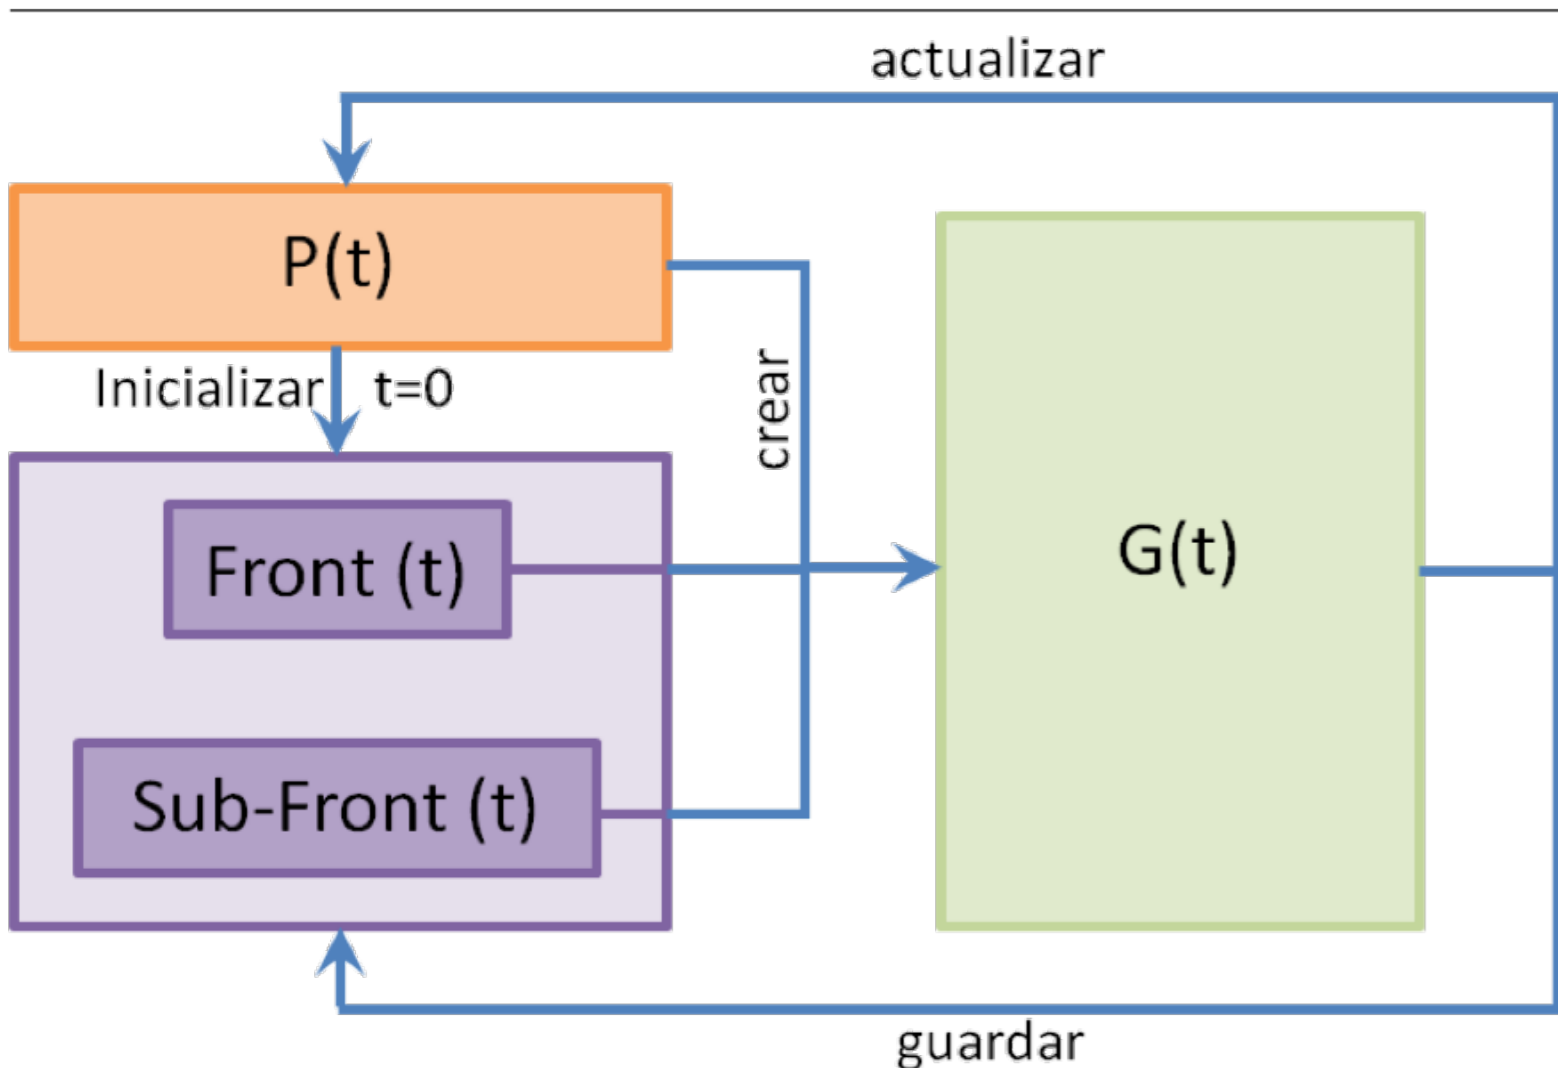
Las soluciones óptimas y sub-óptimas no dominadas en su vecindad ($P_{Q,n}$) son los conjuntos P_Q y P'_Q . x^2 es descartada porque esta dominada por una solución vecina x^1 . El conjunto P_Q'' es descartado porque no se consideran soluciones sub-óptimas.

Algoritmo¹:

Algorithm 1. Pseudocódigo nevMOGA.

```

1: t:=0;
2: Front(t):= ∅;
3: Sub-Front(t):= ∅;
4: Crear Población Inicial P(t) aleatoriamente
5: Calcular f(∀ x ∈ P(t))
6: Ordenar Población P(t) usando índice niching
7: Inclusión de los individuos de P(t) en Front(t)
8: Inclusión de los individuos de P(t) no incluidos en Front(t) en Sub-Front(t)
9: for t:= 1:Número de iteraciones do
10:   Crea Población G(t)
11:   Calcular f(∀ x ∈ G(t))
12:   Inclusión de los individuos de G(t) en Front(t)
13:   Inclusión de los individuos de G(t) no incluidos en Front(t) en Sub-Front(t)
14:   Actualizar P(t) con los individuos de G(t)
15:   Ordenar Población P(t)
16: end for
  
```

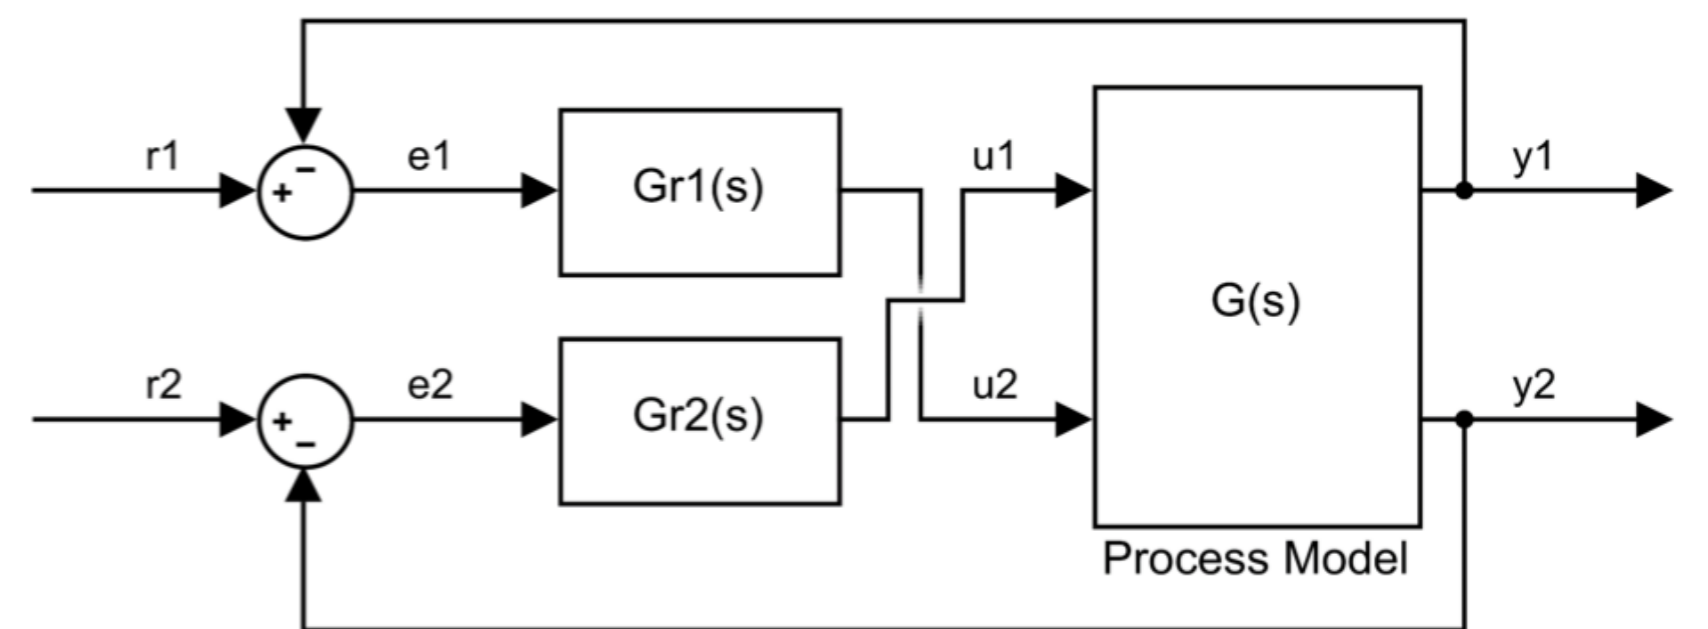


¹ Enviado a Complexity Journal (ISSN: 1099-0526)

El algoritmo está compuesto de cuatro poblaciones:

- Población $P(t)$ es la población principal y se encarga de explorar el espacio de búsqueda a lo largo de las iteraciones.
- Front(t) es el archivo donde se almacena el conjunto discreto de soluciones óptimas.
- Sub-Front(t) es el archivo donde se almacena el resto de soluciones del conjunto discreto P_{Qn} .
- $G(t)$ es una población auxiliar que se utiliza para almacenar los nuevos individuos que se generan en cada iteración.

Ejemplo:



$$Y(s) = \begin{pmatrix} y_1(s) \\ y_2(s) \end{pmatrix} = G(s) \begin{pmatrix} u_1(s) \\ u_2(s) \end{pmatrix} \quad G(s) = \begin{pmatrix} 5e^{-40} & 1e^{-4} \\ 100s+1 & 10s+1 \\ -5e^{-40} & 5e^{-40} \\ 10s+1 & 100s+1 \end{pmatrix}$$

$$u_2(s) = Kc_1(e_1(s) + \frac{1}{Ti_1 s} e_1(s)) \quad u_1(s) = -Kc_2(e_2(s) + \frac{1}{Ti_2 s} e_2(s))$$

Definición del MOP:

$$\min_x f(x) = [f_1(x) \ f_2(x)]$$

$$f_1 = \int_0^{t_f} e_1^2 + e_2^2 |_{r_1=1, r_2=0} dt + \int_0^{t_f} e_1^2 + e_2^2 |_{r_1=0, r_2=1} dt$$

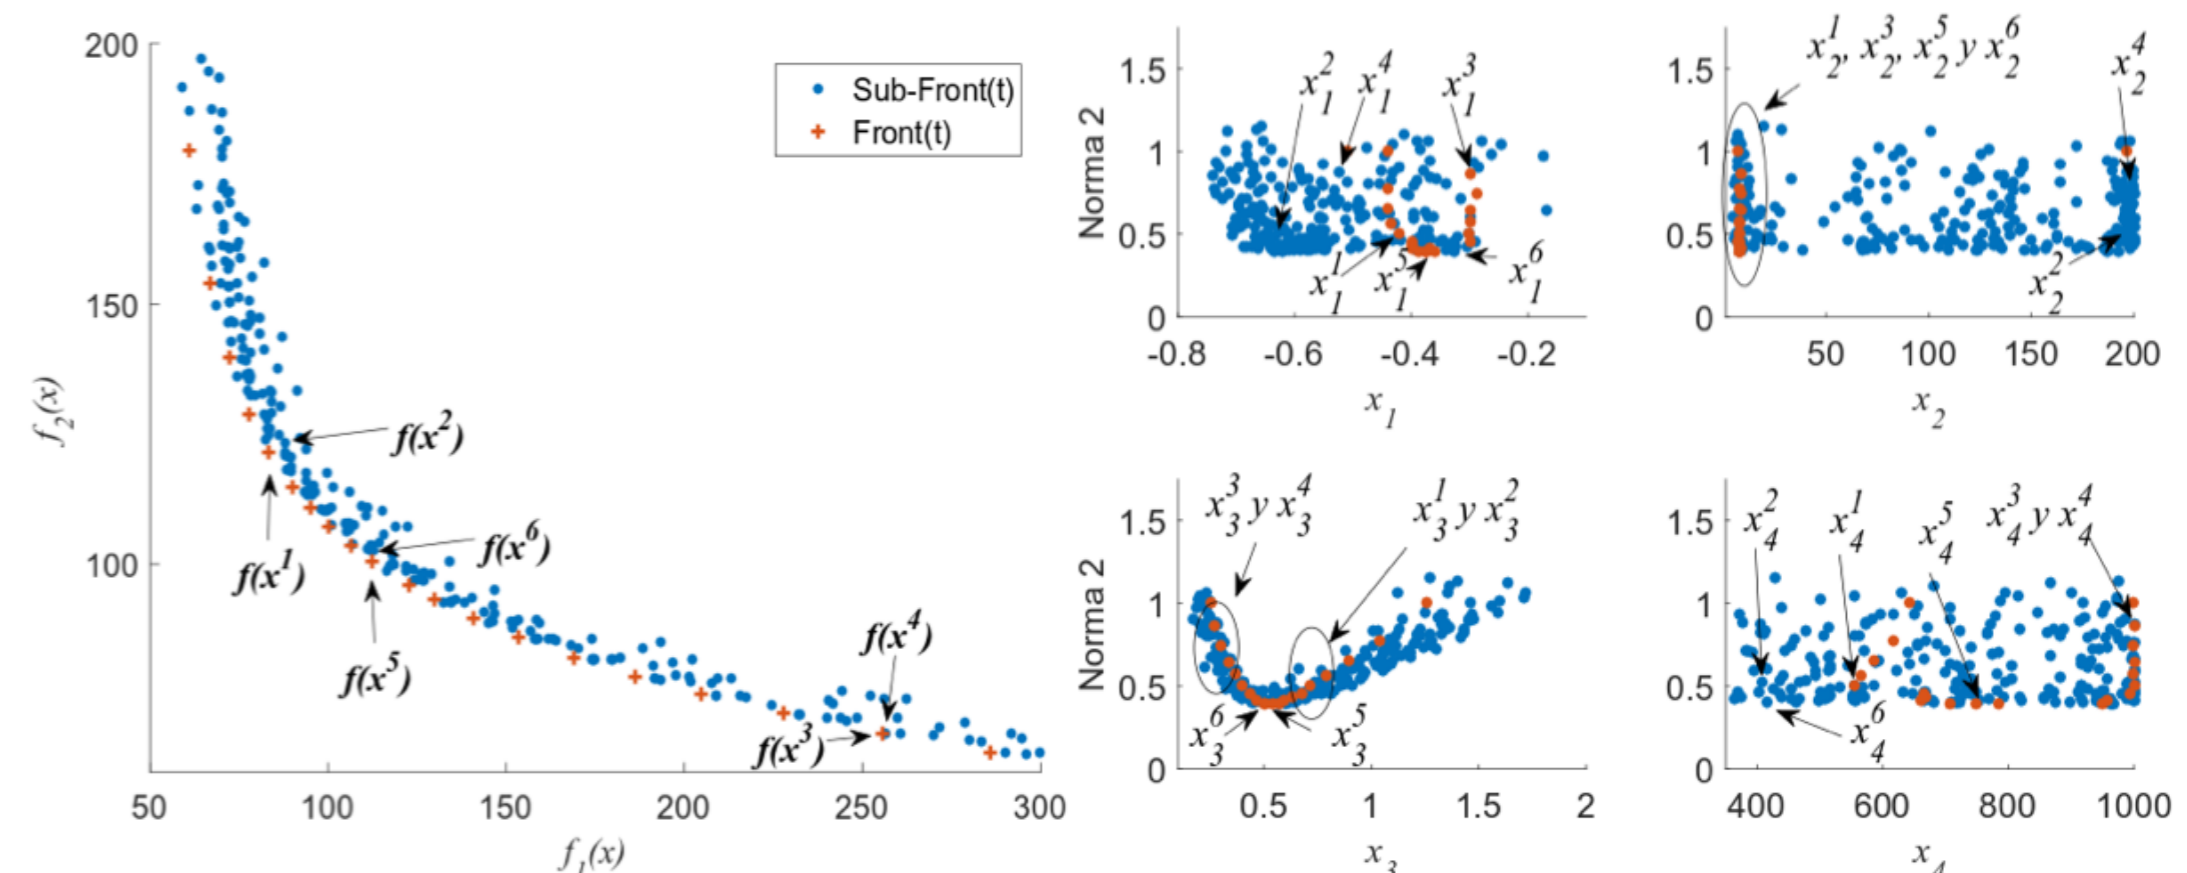
$$f_2 = \int_0^{t_f} u_1^2 + u_2^2 |_{r_1=1, r_2=0} dt + \int_0^{t_f} u_1^2 + u_2^2 |_{r_1=0, r_2=1} dt$$

sujeto a: $f_1(x) < 300, f_2(x) < 200 \quad \underline{x} \leq \bar{x} \leq \bar{x} \quad \text{Estable BC}$

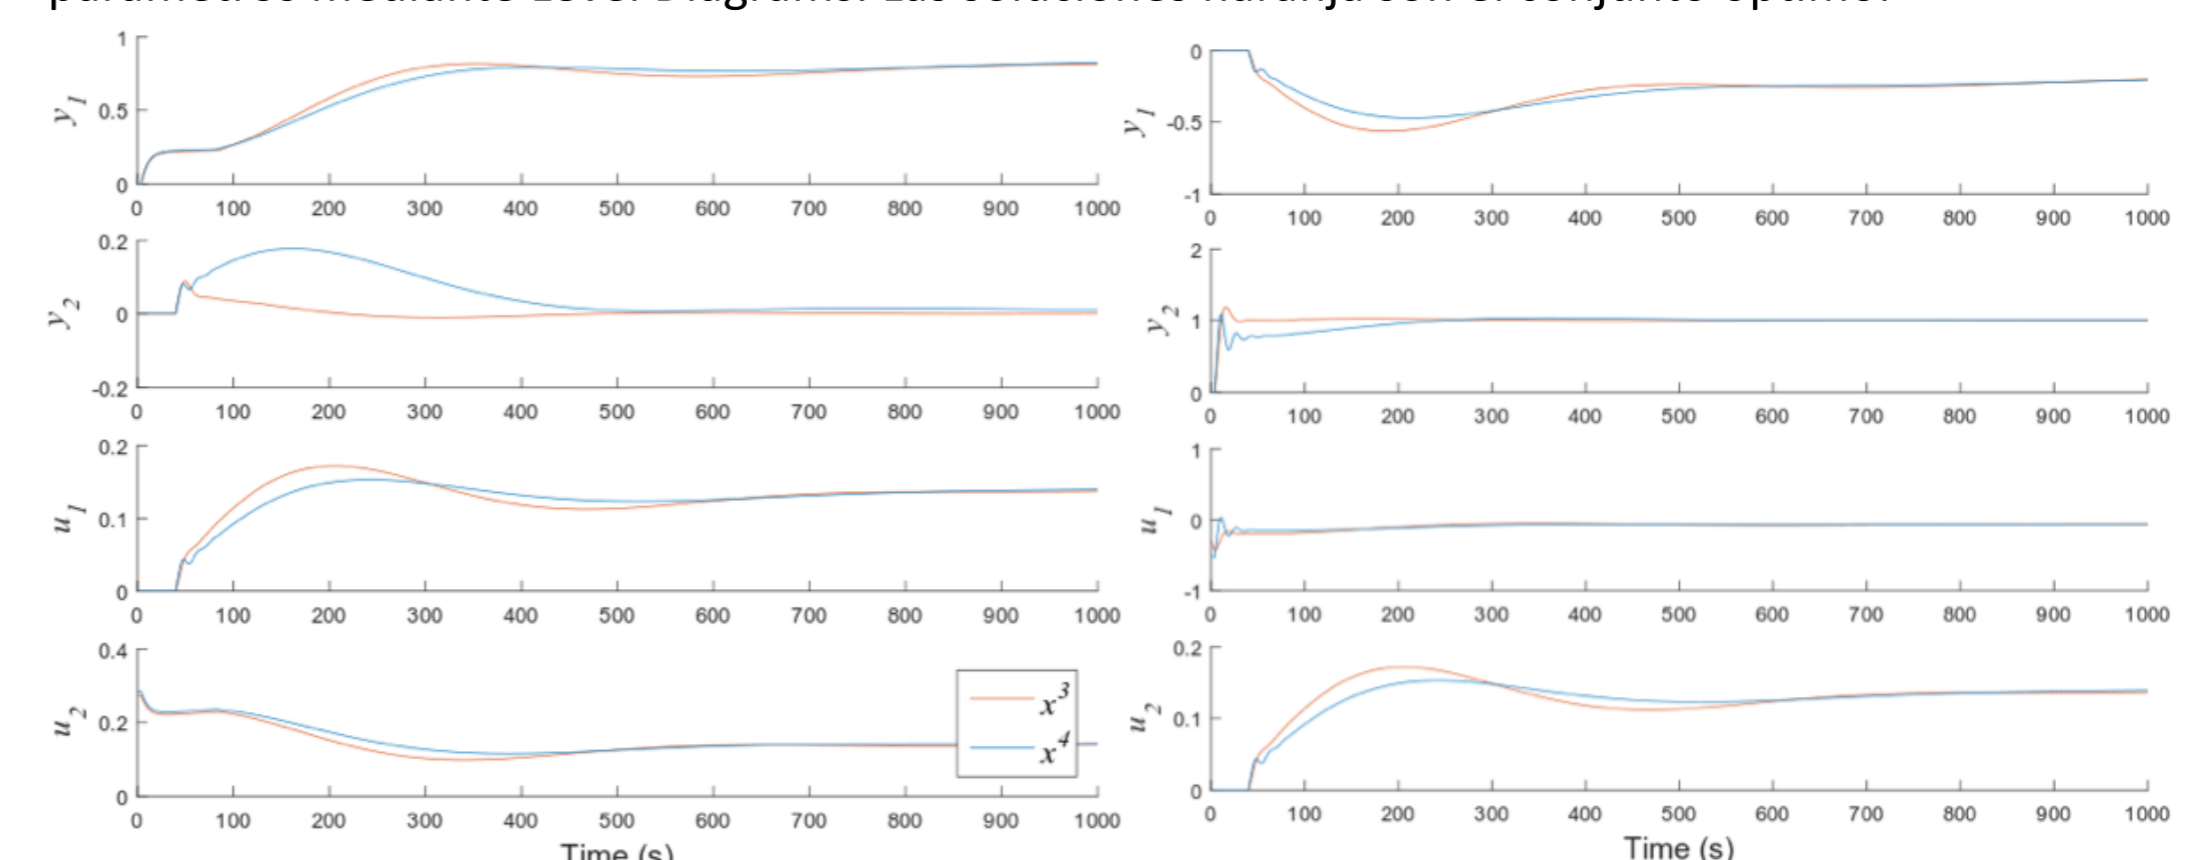
donde: $x = [Kc_1, Ti_1, Kc_2, Ti_2] \quad t_f = 1000 \text{ s}$

$$\bar{x} = [-0.1, 200, 10, 100] \quad \underline{x} = [-1, 1, 0, 1, 1]$$

Resultados:



Conjunto de soluciones óptimas y sub-óptimas (P_{Qn}) obtenido y representado en el espacio de parámetros mediante Level Diagrams. Las soluciones naranjas son el conjunto óptimo.



Respuesta de las soluciones x^3 y x^4 . Estas soluciones tienen un rendimiento similar siendo soluciones no vecinas, por ello tienen un comportamiento diferente.

Conclusiones:

- En este trabajo se presenta un nuevo algoritmo que tiene como objetivo encontrar las soluciones óptimas y también las soluciones sub-óptimas no dominadas en su vecindad.
- Estas soluciones nos permiten obtener mayor información para la etapa de decisión y con ello poder elegir la solución más idónea al problema con mayor criterio.
- En el ejemplo se observa como dos soluciones con rendimiento similar (aunque x^1 domina a x^2) obtienen una respuesta muy diferente (al ser soluciones no vecinas) lo que proporciona una mayor información al diseñador sobre nuevas alternativas de diseño que merecen estudio detallado.
- Por lo tanto, es útil encontrar el conjunto de soluciones sub-óptimas no dominadas en su vecindad y para ello se ha creado el algoritmo nevMOGA.

Agradecimientos:

Este trabajo ha sido parcialmente financiado por el Ministerio de Economía y Competitividad (España) mediante el proyecto DPI2015-71443-R.