

Ajuste multiobjetivo de controladores robustos considerando soluciones casi óptimas relevantes

Alberto Pajares, Xavier Blasco, Juan Manuel Herrero, Sergio Garcia-Nieto
 Instituto de Automática e Informática Industrial, Universitat Politècnica de València,
 Camino de Vera S/N, 46022, Valencia, España, alpafer1@upv.es

Resumen

En este trabajo se muestra la utilidad de las soluciones casi óptimas relevantes en el ajuste mediante optimización multiobjetivo de controladores robustos ante incertidumbre en el modelo. Una posibilidad muy común para este ajuste es incorporar la incertidumbre en el proceso de optimización, por ejemplo, incorporando la evaluación de la robustez durante el proceso. El principal problema de este enfoque es que tiene un alto coste computacional. Para evitar este problema, en este trabajo se propone analizar la incertidumbre en la etapa de decisión tanto para las soluciones óptimas como para las casi óptimas relevantes. Estas soluciones alternativas proporcionan mayor diversidad, pudiendo resultar controladores más robustos que los óptimos. Se muestra un ejemplo de diseño multivariable mediante dos controladores PI. El proceso a controlar es un modelo lineal de dos entradas y dos salidas donde la incertidumbre se ha modelado con un conjunto de cincuenta escenarios (posibles modelos alternativos). El ejemplo muestra que existen zonas de prestaciones en las que los controladores casi óptimos relevantes pueden obtener una mayor robustez que los controladores óptimos.

Palabras clave: Optimización multiobjetivo, control robusto, incertidumbre en el modelo.

1. Introducción

Para el diseño del sistema control de un proceso, el diseñador debe escoger una estructura para el controlador y ajustar sus parámetros. Una forma de abordar el ajuste de estos parámetros consiste en formular el problema como un problema de optimización.

En general, existen diferentes objetivos que se desean alcanzar: buenas prestaciones, bajo esfuerzo de control, etc. Muchos de estos objetivos entran en conflicto y, por tanto, surge un problema de optimización multiobjetivo (MOP [5, 8], por sus siglas en inglés).

Es común que el modelo del proceso a controlar,

utilizado en el diseño y ajuste del controlador, tenga cierto grado de incertidumbre. Dicha incertidumbre impactará en las prestaciones reales del control diseñado. Por tanto, para obtener un buen controlador es deseable que, además de conseguir un buen rendimiento (satisfacer todos los objetivos de forma adecuada), sea robusto (insensible a las incertidumbres de dicho modelo). En procesos con incertidumbre, un controlador óptimo para el modelo nominal puede dejar de serlo, o incluso ser totalmente inadecuado, cuando se implemente en el proceso real.

Por ello, es muy conveniente para el diseñador analizar la incertidumbre e incorporarla en el procedimiento de ajuste del controlador. Un enfoque habitual, cuando se considera incertidumbre paramétrica, consiste en considerar cada parámetro como una variable aleatoria. Cada combinación de parámetros es considerado como un escenario posible. Mediante el análisis de cada controlador en los diferentes escenarios que caracterizan la incertidumbre, es posible elegir un controlador con un rendimiento adecuado que sea robusto ante incertidumbre, es decir, en todos los escenarios. Obtener dichos controladores robustos supone incorporar, en el proceso de optimización, los diferentes escenarios a considerar [1, 3, 2, 9]. Sin embargo, este enfoque aumenta considerablemente el coste computacional en la etapa de optimización, haciéndola, en muchos casos muy costosa e incluso inabordable computacionalmente. Por ello, en este trabajo se propone analizar la robustez de los controladores en la etapa de decisión pero sobre un conjunto limitado de soluciones (las óptimas y las casi óptimas relevantes). Este enfoque tiene un coste computacional abordable y ofrece soluciones adecuadas.

Este trabajo se estructura de la siguiente forma. En la Sección 2 se presenta los conceptos básicos y la metodología propuesta para el uso de las soluciones óptimas y casi óptimas. En la Sección 3 se presenta la aplicación a un ejemplo de diseño de controladores robustos para un modelo lineal multivariable. Finalmente en la Sección 4 se resumen las conclusiones del trabajo.

2. Aplicación de las soluciones casi óptimas en problemas de control robusto

En este trabajo, se desea ajustar una estructura de control \mathbf{x} (vector con los parámetros de los controladores que se deben ajustar) utilizando un enfoque de optimización multiobjetivo y considerando incertidumbre en el modelo del proceso. Asumimos que la incertidumbre está asociada a los parámetros ξ de dicho modelo (vector con el valor de los parámetros del modelo). En la formulación del problema se incorpora la incertidumbre en forma de escenarios. Un escenario viene definido por una combinación de valores de los parámetros $\xi = [\xi_1, \xi_2, \dots, \xi_p]$, donde p es el número de parámetros donde se considera la incertidumbre.

Dado un determinado escenario ξ , un problema de optimización multiobjetivo puede definirse como:

$$\min_{\mathbf{x} \in Q} \mathbf{f}(\mathbf{x}, \xi) \tag{1}$$

donde Q viene determinado por todas las restricciones del problema, por ejemplo, puede definirse como:

$$\underline{x}_i \leq x_i \leq \bar{x}_i, \quad i = [1, \dots, k] \tag{2}$$

$\mathbf{x} = [x_1, \dots, x_k]$ es el vector de decisión en el dominio $Q \subset \mathbb{R}^k$ (k es el número de variables de decisión) y $\mathbf{f}: Q \rightarrow \mathbb{R}^m$ (m es el número de objetivos de diseño) el vector de funciones objetivo $\mathbf{f}(\mathbf{x}, \xi) = [f_1(\mathbf{x}, \xi), \dots, f_m(\mathbf{x}, \xi)]$. x_i y \bar{x}_i son los límites inferior y superior de cada componente de \mathbf{x} .

La función $\mathbf{f}(\mathbf{x}, \xi)$ incorpora diferentes objetivos que miden la calidad del control. En adelante, para simplificar la notación, en el escenario nominal $\hat{\xi}$, el vector de funciones objetivos $\mathbf{f}(\mathbf{x}, \hat{\xi})$ se representa como $\mathbf{f}(\mathbf{x})$. Al resolver un MOP se obtiene un conjunto de soluciones óptimas, llamado conjunto de Pareto (definido en [7, 5]). En este trabajo denotaremos como P_Q^ξ al conjunto de Pareto obtenido para el escenario ξ . Además de las soluciones óptimas, existe un conjunto de soluciones casi óptimas (ver definición en [10]) que pueden ser útiles para el diseñador, por ejemplo, pueden tener buenas características de robustez. Estas soluciones tienen unas prestaciones similares a las óptimas. Sin embargo, encontrar todas las soluciones casi óptimas puede aumentar considerablemente el número de alternativas obtenidas y, por lo tanto, incrementar notablemente el coste computacional de los algoritmos de optimización.

Además, con un número elevado de soluciones se dificulta la etapa de decisión.

Para limitar el número de soluciones manejadas en la optimización y en la fase de decisión, se propone considerar únicamente las soluciones no dominadas en su vecindad (ver definición en [6]). El concepto de vecindad hace referencia a la cercanía en el espacio de decisión (o espacio de parámetros). Consideramos que controladores con valores muy similares en sus parámetros no aportan soluciones radicalmente diferente. Por tanto, las soluciones casi óptimas relevantes (las no dominadas en su vecindad) son soluciones alternativas cercanas a las óptimas en prestaciones (espacio de objetivos) pero sensiblemente diferente en el espacio de parámetros. Esta mayor diversidad de soluciones favorece la localización de soluciones interesantes para la robustez. En [6] se ha desarrollado ya un algoritmo (algoritmo nevMOGA¹) para localizar simultáneamente soluciones óptimas y casi óptimas sin incrementar sustancialmente el coste computacional. En este trabajo tratamos de explotar el uso de estas soluciones casi óptimas para mejorar el análisis de robustez.

Denotaremos como $P_{Q,n}^\xi$ al conjunto de soluciones óptimas y casi óptimas no dominadas en su vecindad para el escenario ξ . Este conjunto puede contener infinitas soluciones. Por ello, normalmente el diseñador obtiene el conjunto discreto $P_{Q,n}^{\xi,*} \subset P_{Q,n}^\xi$, de tal forma que caracterice adecuadamente $P_{Q,n}^\xi$. nevMOGA obtiene el conjunto $P_{Q,n}^{\xi,*}$.

La propuesta consiste en obtener este conjunto, evaluar los objetivos en todos los escenarios que describen la incertidumbre del modelo y, a partir de esta información, obtener una medida de robustez asociada a cada controlador.

Para ello, se define un conjunto de escenarios \mathcal{U} . Se evalúan los objetivos para todos escenarios $\xi \in \mathcal{U}$. Se debe definir un criterio para evaluar la robustez.

Para este análisis, se propone obtener el valor supremo para cada objetivo de forma independiente $\mathbf{f}_U^{max}(\mathbf{x})$ ([3], ver ecuación (3)), considerando todos los escenarios $\xi \in \mathcal{U}$.

$$\mathbf{f}_U^{max}(\mathbf{x}) = [\sup_{\xi \in \mathcal{U}} f_1(\mathbf{x}, \xi), \dots, \sup_{\xi \in \mathcal{U}} f_m(\mathbf{x}, \xi)] \tag{3}$$

Con este criterio, se considera que una solución \mathbf{x}^1

¹disponible en Matlabcentral <https://es.mathworks.com/matlabcentral/fileexchange/71448-nevmoga-multiobjective-evolutionary-algorithm>

es más robusta que otra \mathbf{x}^2 si, $\mathbf{f}_{\mathcal{U}}^{max}(\mathbf{x}^1)$ es mejor que $\mathbf{f}_{\mathcal{U}}^{max}(\mathbf{x}^2)$. En este punto, puesto que $\mathbf{f}_{\mathcal{U}}^{max}$ es un vector, se puede aplicar el concepto de dominancia utilizado en optimización multiobjetivo, y decir, que una \mathbf{x}^1 es más robusta que \mathbf{x}^2 si, \mathbf{x}^1 domina a \mathbf{x}^2 para el vector de objetivos definidos en (3): $\mathbf{x}^1 \prec \mathbf{x}^2$.

Este enfoque tiene un coste computacional significativamente menor que los enfoques tradicionales. En los enfoque tradicionales, donde se considera la incertidumbre, se analiza la incertidumbre en el etapa de optimización. Un ejemplo de ello sería optimizar $\mathbf{f}_{\mathcal{U}}^{max}(\mathbf{x})$. Bajo este enfoque, cada controlador debe ser evaluado sobre el conjunto de escenarios \mathcal{U} . Así, el coste computacional aumenta en aproximadamente $|\mathcal{U}|$ (número de escenarios planteados). Sin embargo, en el enfoque planteado en este trabajo, solo se evalúa el conjunto de escenarios \mathcal{U} sobre los controladores previamente obtenidos en la etapa de optimización. De este modo el coste computacional es sensiblemente inferior.

3. Ejemplo: control de un sistema lineal multivariable con incertidumbre

En esta sección se presenta un ejemplo de diseño de controladores robustos para un proceso lineal con incertidumbre aplicando optimización multiobjetivo.

3.1. Descripción del problema

El modelo utilizado en este ejemplo se define en [4]:

$$\begin{pmatrix} y_1(s) \\ y_2(s) \end{pmatrix} = G(s) \begin{pmatrix} u_1(s) \\ u_2(s) \end{pmatrix} \tag{4}$$

$$G(s) = \begin{pmatrix} \frac{K_{11}e^{-\theta_{11}s}}{\tau_{11}s+1} & \frac{K_{12}e^{-\theta_{12}s}}{\tau_{12}s+1} \\ \frac{K_{21}e^{-\theta_{21}s}}{\tau_{21}s+1} & \frac{K_{22}e^{-\theta_{22}s}}{\tau_{22}s+1} \end{pmatrix} \tag{5}$$

donde y_1 y y_2 son las salidas del proceso a controlar y u_1 y u_2 son las acciones de control. Las entradas y salidas del modelo están normalizadas. La incertidumbre está asociada a todos los retardos, ganancias y constantes de tiempo del modelo. Por lo tanto, los escenarios quedan definidos por el vector ξ del siguiente modo:

$$\xi = [K_{11}, \theta_{11}, \tau_{11}, K_{12}, \theta_{12}, \tau_{12}, K_{21}, \theta_{21}, \tau_{21}, K_{22}, \theta_{22}, \tau_{22}] \tag{6}$$

y se define el escenario nominal $\hat{\xi}$ como:

$$\hat{\xi} = [5, 100, 40, 1, 10, 4, -5, 10, 4, 5, 100, 40] \tag{7}$$

En este ejemplo, se plantea una estructura de control multilazo con controladores 1DOF-PI. La técnica DRGA (matriz de ganancias relativas dinámica) presentada en [4] sugiere el emparejamiento off-diagonal. Por ello, se utilizará el emparejamiento: $y_1 - u_2$ and $y_2 - u_1$ (ver ecuación (8)). Todo el sistema es simulado en tiempo discreto con un periodo de muestreo $T_s = 0.1$ segundos.

$$\begin{aligned} u_2(s) &= Kc_1 (e_1(s) + \frac{1}{Ti_1} \frac{1}{s} e_1(s)) \\ u_1(s) &= -Kc_2 (e_2(s) + \frac{1}{Ti_2} \frac{1}{s} e_2(s)) \end{aligned} \tag{8}$$

donde Kc_i son las ganancias proporcionales y Ti_i son los tiempos integrales en segundos. $e_1 = r_1 - y_1$ y $e_2 = r_2 - y_2$ son los errores en las salidas, siendo r_1 y r_2 las referencias en bucle cerrado.

Una vez definido el sistema de control, se define el MOP sobre el escenario nominal $\hat{\xi}$ (ver ecuación (9)). Se eligen dos objetivos de diseño. El primero, f_1 evalúa el desempeño de cada una de las salidas aplicando el ISE (integral del error cuadrático). El segundo, f_2 evalúa los esfuerzos de control del sistema aplicando el ISU (integral de la acción de control al cuadrado). Para evaluar los objetivos de diseño se introducen escalones unitarios en la referencia r_1 y r_2 de forma independiente. El tratar estos dos objetivos de forma independiente permite escoger un controlador compensado en prestaciones y esfuerzo de control. Las restricciones sobre f_1 y f_2 determinan la zona de interés del diseñador.

$$\min_{\mathbf{x}} \mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}) \ f_2(\mathbf{x})] \tag{9}$$

donde:

$$f_1(\mathbf{x}) = \int_0^{t_f} \underbrace{e_1^2 + e_2^2}_{r_1=1 \ r_2=0} dt + \int_0^{t_f} \underbrace{e_1^2 + e_2^2}_{r_1=0 \ r_2=1} dt \tag{10}$$

$$f_2(\mathbf{x}) = \int_0^{t_f} \underbrace{u_1^2 + u_2^2}_{r_1=1 \ r_2=0} dt + \int_0^{t_f} \underbrace{u_1^2 + u_2^2}_{r_1=0 \ r_2=1} dt \tag{11}$$

$$t_f = 1000 \text{ seg.}$$

sujeto a:

$$\bar{\mathbf{x}} \leq \mathbf{x} \leq \underline{\mathbf{x}}$$

$$f_1(\mathbf{x}) < 300 ; f_2(\mathbf{x}) < 200 \tag{12}$$

$$\mathbf{x} = [Kc_1 \ Ti_1 \ Kc_2 \ Ti_2]$$




Figura 1: Espacio de objetivos. En azul se representa el valor de la función objetivo f para el escenario nominal $\hat{\xi}$. En rojo se representa $f_{\mathcal{U}}^{max}$. Los círculos son los controladores óptimos sobre $\hat{\xi}$. Los puntos son los controladores casi óptimos relevantes.

$$\bar{x} = [-0.1, 1000, 2.5, 1000]; \underline{x} = [-1, 1, 0.1, 1]$$

Para tener en cuenta la incertidumbre, se considera un conjunto de escenarios/modelos. Cada escenario se obtiene variando los parámetros del escenario nominal $\hat{\xi}$ aleatoriamente $\pm 20\%$. En este caso, se definen un conjunto de escenarios \mathcal{U} formado por 50 modelos. De este modo, para un ajuste particular x de la estructura de control, $f_{\mathcal{U}}^{max}(x)$ es el valor supremo para cada objetivo de forma independiente para el conjunto de 50 escenarios planteados.

3.2. Resultados y discusión

Esta sección muestra los resultados obtenidos al aplicar la metodología al problema definido. La Figura 1 muestra el valor de los objetivos para el conjunto $P_{Q,n}^{\hat{\xi},*}$ obtenido. Los círculos representan los controladores óptimos obtenidos ($P_Q^{\hat{\xi},*}$). Los puntos representan los controladores casi óptimos obtenidos. En azul, se muestra la evaluación de los objetivos sobre el modelo nominal $\hat{\xi}$. En rojo, se representa el rendimiento de dichos controladores sobre el conjunto de escenario \mathcal{U} mediante $f_{\mathcal{U}}^{max}$. Existen controladores que obtiene un $f_{\mathcal{U}}^{max}$ que se encuentra fuera de la escala de la figura, corresponden controladores con valores con f_1 muy bajos y f_2 muy altos (zona superior izquierda).

Para mostrar la utilidad de las soluciones casi óptimas, en la Figura 1 se selecciona la Zona 1. Además, se observa la degradación de los controladores seleccionados (mediante $f_{\mathcal{U}}^{max}$) sobre el conjunto de escenarios \mathcal{U} . En esta zona se observa

Tabla 1: Parámetros de los controladores x^1 y x^2

	Kc_1	Ti_1	Kc_2	Ti_2
x^1	-0.47	9.12	0.71	824.0
x^2	-0.33	192.0	0.93	866.2

Tabla 2: Rendimiento de los controladores x^1 y x^2

	f	$f_{\mathcal{U}}^{max}$
x^1	[90.7, 115.24]	[204.3, 193.2]
x^2	[117.6, 121.2]	[184.3, 161.2]

que existen controladores casi óptimos (puntos) con una menor degradación, y por lo tanto más robusto, que los controladores óptimos (círculos). Los controladores óptimos obtienen una robustez sensiblemente inferior en la Zona 1. Para llevar a cabo un análisis más profundo, se selecciona el controlador óptimo x^1 y casi óptimo x^2 . Se han seleccionado estos controladores debido a la diferencia significativa en sus parámetros. Como se observa, x^1 obtiene un mejor rendimiento sobre el modelo nominal. Sin embargo, x^2 es un controlador más robustos que x^1 (menor $f_{\mathcal{U}}^{max}$). Los parámetros de dichos controladores se observan en la Tabla 1 y su rendimiento en la Tabla 2.

En la Figura 2 se observa la respuesta obtenida por los controladores seleccionados sobre el modelo nominal. Como se puede observar estos controladores obtienen respuestas significativamente diferentes. x^2 tiene un menor error sobre y_1 , con un menor esfuerzo de control sobre u_1 . Sin embargo, x^1 tiene un menor error sobre y_2 , con un menor esfuerzo de control sobre u_2 . Por lo tanto, el controlador casi óptimo x^2 proporciona una nueva alternativa similar en prestaciones a la óptima.

Para analizar las características de robustez de cada controlador, en la Figura 3 se observa la respuesta envolvente obtenida por los controladores x^1 y x^2 sobre los 50 modelos definidos. Como se puede observar, x^2 obtiene un mejor rendimiento sobre y_1 en ambos ensayos. Además, tiene una acción de control menos agresiva sobre u_1 y u_2 . x^1 obtiene un mejor rendimiento sobre y_2 cuando se introduce el escalón sobre r_1 . Cuando el escalón se introduce sobre r_2 , x^1 tiene un menor error. Sin embargo, tiene una sobreoscilación significativamente mayor debido a la acción de control más agresiva en u_1 . Con todo ello, x^2 obtiene un mejor $f_{\mathcal{U}}^{max}$ (ver Tabla 2), y por lo tanto, una mayor robustez.




Figura 2: Respuesta de los controladores x^1 y x^2 sobre $\hat{\xi}$. A la izquierda respuesta ante escalón unitario sobre r_1 . A la derecha respuesta ante escalón unitario sobre r_2 .

4. Conclusiones

En este trabajo se muestra la utilidad de las soluciones casi óptimas relevantes en el diseño multiobjetivo de controladores robustos.

Se utiliza el algoritmo nevMOGA [6] para caracterizar los controladores óptimos y casi óptimos no dominados en su vecindad. En la etapa de decisión, estos controladores se analizan para todos los escenarios de incertidumbre. Esta metodología es computacionalmente eficiente en comparación con los enfoques tradicionales que incorporan todos los escenarios de incertidumbre en la etapa de optimización.

Los controladores casi óptimos relevantes son interesantes para el diseñador, ya que ofrecen una mayor diversidad. Esta diversidad, ofrece al diseñador nuevas alternativas con características significativamente diferentes, como por ejemplo, una mayor robustez ante incertidumbre.

El ejemplo mostrado en este trabajo muestra la utilidad de los controladores casi óptimos en el diseño multiobjetivo de controladores robustos ante incertidumbre.

Agradecimientos

Este trabajo ha sido realizado gracias al apoyo de los proyectos PID2021-124908NB-I00 y PID2020-119468RA-I00 financiados MCIN/AEI/10.13039/501100011033/ y por "FEDER Una manera de ha-

cer Europa"; y la ayuda SP20200109 (PAID-10-20) de la Universitat Politècnica de València.

English summary

Multi-objective tuning of robust controllers considering relevant near-optimal solutions

Abstract

In this paper we show the usefulness of relevant near-optimal solutions in the multi-objective optimization tuning of robust controllers in presence of model uncertainty. A very common possibility for this tuning is to incorporate uncertainty in the optimization process, for example, by incorporating the evaluation of the robustness during the process. The main problem with this approach is that it has a high computational cost. To avoid this problem, this paper proposes to analyze uncertainty at the decision stage for both optimal and relevant near-optimal solutions. These alternative solutions provide greater diversity and may result in more robust controllers than the optimal ones. An example of multivariable design using two PI controllers is shown. The process to be controlled is a two-input, two-output linear model where uncertainty has been modeled with a set of fifty scenarios (possible alternative models). The example




Figura 3: Respuesta envolvente de los controladores x^1 y x^2 sobre los 50 modelos planteados. A la izquierda respuesta ante escalón unitario sobre r_1 . A la derecha respuesta ante escalón unitario sobre r_2 .

shows that there are performance areas where relevant near-optimal controllers can obtain higher robustness than optimal controllers.

Keywords: Multi-objective optimization, robust control, model uncertainty.

Referencias

[1] Matteo Fischetti and Michele Monaci. Light robustness. In *Robust and online large-scale optimization*, pages 61–84. Springer, 2009.

[2] Carlos Ignacio Hernández Castellanos, Oliver Schütze, Jian-Qiao Sun, and Sina Oberblöbaum. Non-epsilon dominated evolutionary algorithm for the set of approximate solutions. *Mathematical and Computational Applications*, 25(1):3, 2020.

[3] Jonas Ide and Anita Schöbel. Robustness for uncertain multi-objective optimization: a survey and analysis of different concepts. *OR spectrum*, 38(1):235–271, 2016.

[4] Thomas Mc Avoy, Yaman Arkun, Rong Chen, Derek Robinson, and P David Schelle. A new approach to defining a dynamic relative gain. *Control Engineering Practice*, 11(8):907–914, 2003.

[5] Kaisa Miettinen. *Nonlinear multiobjective optimization*, volume 12. Springer Science & Business Media, 2012.

[6] Alberto Pajares, Xavier Blasco, Juan M Herrero, and Gilberto Reynoso-Meza. A multi-objective genetic algorithm for the localization of optimal and nearly optimal solutions which are potentially useful: nevmoga. *Complexity*, 2018, 2018.

[7] Vilfredo Pareto et al. *Manual of political economy*. 1971.

[8] Gilberto Reynoso-Meza, Xavier Blasco, Javier Sanchis, and Juan Manuel Herrero. *Controller tuning with evolutionary multiobjective optimization: A holistic multiobjective optimization design procedure*. Springer, 2017.

[9] Anita Schöbel. Generalized light robustness and the trade-off between robustness and nominal quality. *Mathematical Methods of Operations Research*, 80(2):161–191, 2014.

[10] Oliver Schütze, Massimiliano Vasile, and Carlos A Coello Coello. Computing the set of epsilon-efficient solutions in multiobjective space mission design. *Journal of Aerospace Computing, Information, and Communication*, 8(3):53–70, 2011.



© 2022 by the authors.
Submitted for possible
open access publication
under the terms and conditions of the Creative
Commons Attribution CC-BY-NC 4.0 licen-
se (<https://creativecommons.org/licenses/by-nc-sa/4.0/deed.es>).