

Jornadas de Automática

Gestión de escenarios ponderados en entornos estocásticos usando control predictivo basado en modelo

Hernández-Rivera, Andrés^{a,*}, Velarde, Pablo^b, Zafra-Cabeza, Ascensión^a, Muros, Francisco Javier^{a,b}, Maestre, José M.^a

^aDepartamento de Ingeniería de Sistemas y Automática, Universidad de Sevilla, Camino de los Descubrimientos, s/n, 41092, Sevilla, España.

^bDepartamento de Ingeniería, Universidad Loyola Andalucía, Avda. de las Universidades, s/n, 41704, Dos Hermanas, Sevilla, España.

To cite this article: Hernández-Rivera, Andrés, Velarde, Pablo, Zafra-Cabeza, Ascensión, Muros, Francisco Javier, Maestre, José M. 2025. Management of weighted scenarios in stochastic environments using model predictive control. *Jornadas de Automática*, 46. <https://doi.org/10.17979/ja-cea.2025.46.12266>

Resumen

Este artículo presenta una formulación detallada del control predictivo basado en modelo con escenarios ponderados (WS-MPC, por sus siglas en inglés) orientada a sistemas lineales con incertidumbres. El enfoque propuesto combina técnicas de optimización robusta y generación de múltiples escenarios dinámicos del sistema, asignando una ponderación diferenciada al escenario de peor caso dentro del problema de control. Esta estrategia permite una mayor resiliencia ante perturbaciones estocásticas y modelado incierto, mejorando la capacidad del controlador para anticiparse a comportamientos no esperados. El WS-MPC adapta dinámicamente las acciones de control en función de la evolución de todos los escenarios considerados, manteniendo la factibilidad y estabilidad del sistema ante condiciones desfavorables. Los resultados de simulación demuestran que el enfoque propuesto incrementa la robustez operativa del sistema y proporciona una respuesta más segura y confiable frente a variaciones inesperadas. En particular, este controlador se ha implementado en un caso de estudio académico centrado en la gestión del inventario de una tienda.

Palabras clave: Control predictivo, sistemas estocásticos, escenarios ponderados, control probabilístico y robusto, control óptimo.

Management of weighted scenarios in stochastic environments using model predictive control

Abstract

This paper presents a detailed formulation of scenario-weighted model predictive control (WS-MPC) tailored for linear systems under uncertainty. The proposed approach combines robust optimization techniques with generating multiple dynamic scenarios of the system and assigning differentiated weights to the worst-case scenario within the control problem. This strategy enhances the system's resilience to stochastic disturbances and modeling uncertainties, improving the controller's ability to anticipate unexpected behaviors. Furthermore, WS-MPC dynamically adjusts control actions based on the evolution of all considered scenarios, while ensuring system feasibility and stability under unfavorable conditions. Simulation results demonstrate that the proposed method increases the operational robustness of the system and provides a safer and more reliable response to unexpected variations. In particular, this controller has been implemented in an academic case study focused on store inventory management.

Keywords: Predictive control, stochastic system, weighted scenarios, probabilistic and robust control, optimal control.

*Autor para correspondencia: ahernandez2@us.es

1. Introducción

Las incertidumbres representan un desafío fundamental para el diseño y la implementación de estrategias de control automático en áreas como las finanzas, la ingeniería biomédica y los sistemas industriales complejos. En estos entornos, la optimización robusta (Ben-Tal et al., 2009; Bertsimas et al., 2011) y estocástica (Shapiro et al., 2021; Birge and Louveaux, 2011) constituyen herramientas esenciales para la toma de decisiones en presencia de incertidumbre.

La optimización robusta se orienta a garantizar la viabilidad del sistema ante los escenarios más adversos, proporcionando soluciones que minimizan la sensibilidad frente a perturbaciones paramétricas. Por su parte, la optimización estocástica incorpora explícitamente el carácter aleatorio de las incertidumbres mediante distribuciones de probabilidad, y busca optimizar el rendimiento esperado sujeto a restricciones probabilísticas.

El presente trabajo introduce una posible alternativa que combina las ventajas de ambos enfoques en el que se formulan escenarios ponderados (WS, por sus siglas en inglés), en la cual se generan múltiples realizaciones posibles de las variables inciertas (van Overloop et al., 2008), y se asigna a cada una un peso en función de su probabilidad o criticidad. Esta estrategia permite integrar robustez frente a casos extremos sin perder la capacidad de capturar la variabilidad estadística del sistema, obteniendo así soluciones más equilibradas. Particularmente, los *enfoques híbridos probabilístico-robustos* (van Ackooij et al., 2020) han ganado atención por su capacidad de ofrecer resiliencia sin incurrir en el excesivo conservadurismo característico del enfoque robusto clásico.

Este marco se adapta especialmente bien al control predictivo basado en modelo (MPC, por sus siglas en inglés), una técnica ampliamente utilizada en la industria por su capacidad para gestionar restricciones, retardos, perturbaciones y dinámicas complejas (Maciejowski, 2002; Camacho et al., 2025). El MPC resuelve, en cada instante de tiempo, un problema de optimización sobre un horizonte de predicción finito N_p , y aplica únicamente la primera acción de control, actualizando la estrategia de forma recursiva en un esquema de horizonte deslizante (Grosso et al., 2014).

No obstante, el MPC convencional no incorpora explícitamente las incertidumbres, lo cual puede comprometer la viabilidad de las restricciones en presencia de perturbaciones. Para abordar esta limitación, se han desarrollado variantes como el min-max MPC, que optimiza frente al peor caso, aunque suele conducir a soluciones excesivamente conservadoras (Velarde et al., 2017). Alternativamente, el MPC multiescenario (MS-MPC) ha sido propuesto como una solución intermedia, evaluando múltiples trayectorias del sistema generadas por muestreo o datos históricos, y determinando una única secuencia de control común a todas ellas (Tian et al., 2017; Velarde et al., 2023).

En esta línea, este trabajo propone un enfoque de MPC con escenarios ponderados al peor caso, el cual extiende la formulación probabilístico-robusta a sistemas dinámicos. La idea central consiste en generar un conjunto representativo de escenarios de incertidumbre y asignar un peso mayor a aquellos que representan condiciones operativas críticas. Este enfoque permite mejorar la resiliencia frente a perturbaciones

severas, al tiempo que se mantiene un buen desempeño bajo condiciones nominales.

Comparado con otras estrategias como el MPC estocástico clásico —basado en restricciones probabilísticas o *chance constraints* (Arcari et al., 2023)—, el min-max MPC (Cialfiori and Fagiano, 2012), o el MPC robusto distribucional (Mark and Liu, 2020; Coppens and Patrinos, 2021), el enfoque propuesto evita suposiciones restrictivas sobre la distribución exacta de las incertidumbres y reduce el conservadurismo mediante la asignación ponderada de pesos, lo cual resulta en una formulación más flexible y efectiva para aplicaciones prácticas.

La principal contribución de este trabajo consiste en presentar la formulación del MPC con escenarios ponderados (WS-MPC), que amplía el marco probabilístico-robusto y demuestra su efectividad mediante un estudio comparativo con tres enfoques de referencia: MPC determinista (Camacho et al., 2012), min-max MPC (Bemporad et al., 2003) y un caso ideal con conocimiento perfecto de la incertidumbre, que sirve como cota superior de desempeño. Es importante remarcar que, tras una búsqueda bibliográfica exhaustiva, no se han encontrado antecedentes del uso de la técnica propuesta.

El resto del artículo se estructura de la siguiente manera: la sección 2 introduce la formulación propuesta del WS-MPC, detallando la construcción de los escenarios, el esquema de ponderación y la formulación del problema de optimización. En la sección 3 se describe el caso de estudio empleado para validar la propuesta, mientras que la sección 4 presenta los resultados comparativos con otras estrategias de control. Finalmente, en la sección 5 se resumen las conclusiones principales y posibles líneas futuras de investigación.

2. Estrategia de MPC basada en escenarios ponderados

La estrategia de control propuesta gestiona la incertidumbre del sistema mediante una formulación basada en escenarios, la cual se aplica a un sistema dinámico general en tiempo discreto descrito por:

$$x_j(k+1) = Ax_j(k) + Bu(k) + D\omega_j(k), \quad \forall j \in \{1, \dots, N_s\}, \quad (1)$$

donde $x_j(k) \in \mathbb{R}^{n_x}$ representa el estado del sistema bajo el escenario $j \in \{1, \dots, N_s\}$ en el instante k , $u(k) \in \mathbb{R}^{n_u}$ es la acción de control común aplicada a todos los escenarios, y $\omega_j(k) \in \mathbb{R}^{n_\omega}$ corresponde a una perturbación aditiva asociada al escenario j .

A diferencia de los enfoques tradicionales (Schildbach et al., 2014), que optimizan sobre un modelo nominal o una media de realizaciones posibles, esta estrategia genera un conjunto de N_s escenarios ($\omega_j, \forall j \in \{1, \dots, N_s\}$) que representan diferentes trayectorias posibles del sistema. Estos escenarios se construyen previamente a partir de distribuciones de probabilidad que reflejan el conocimiento *a priori* sobre la incertidumbre. Se asume que las variables aleatorias que modelan dicha incertidumbre son independientes e idénticamente distribuidas (IID) en un espacio de probabilidad. Un número suficiente de muestras IID puede obtenerse de forma empírica o mediante generadores de números aleatorios.

Según Giulioni (2015), cuando se implementa un MS-MPC se requiere un número mínimo de escenarios que viene

dado por la siguiente ecuación:

$$N_s \geq \frac{z + 1 + \ln\left(\frac{1}{\beta}\right) + \sqrt{2(z + 1) \ln\left(\frac{1}{\beta}\right)}}{\delta_x}, \quad (2)$$

donde δ_x es un nivel de incumplimiento de restricciones asumible, z es el número de acciones de control y β es el nivel de confianza.

Una vez se tiene el conjunto de escenarios, en lugar de resolver un problema de control independiente para cada uno de ellos, se plantea una única acción de control común a todos. Lo novedoso en esta formulación es que el escenario más adverso recibe una ponderación adicional en la función de optimización del MPC. Es decir, a diferencia del caso equiprobable, donde todos los escenarios tienen el mismo peso $\lambda_j = 1/N_s$, aquí se asigna un mayor valor λ_{peor} al escenario más desfavorable, mientras que los restantes comparten un peso uniforme. La determinación del peor caso se realiza en cada instante de predicción, al comprobar, para el sistema que se está tratando, cuál sería la mayor perturbación aditiva $\omega_j(k)$. La ponderación de cada escenario j se define como:

$$\lambda_j = \begin{cases} \frac{\lambda_{\text{peor}}}{(N_s - 1) + \lambda_{\text{peor}}}, & \text{si } j = \text{peor caso,} \\ \frac{1}{(N_s - 1) + \lambda_{\text{peor}}}, & \text{en otro caso,} \end{cases} \quad (3)$$

donde λ_j representa el peso relativo asignado al escenario j . En el caso particular en que $\lambda_{\text{peor}} = 1$, se recupera la formulación equiprobable tradicional con $\lambda_j = 1/N_s, \forall j \in \{1, \dots, N_s\}$.

El problema de control se plantea como la minimización del coste esperado a lo largo de un horizonte de predicción finito, considerando la evolución del sistema bajo todos los escenarios ponderados:

$$\min_{u(k:k+N_p-1)} \sum_{j=1}^{N_s} \lambda_j \sum_{i=k}^{k+N_p-1} \left[|x_j(i) - x_{\text{ref}}(i)|_Q^2 + |u(i)|_R^2 \right], \quad (4)$$

donde $|x|_Q^2 = x^T Q x$ y $|u|_R^2 = u^T R u$ son penalizaciones cuadráticas sobre el error de seguimiento y el esfuerzo de control, respectivamente.

La optimización a lo largo del horizonte de predicción N_p está sujeta a la dinámica del sistema para cada escenario j :

$$x_j(i + 1) = A x_j(i) + B u(i) + D \omega_j(i), \quad (5)$$

$$x_j(i) \in \mathcal{X}, \quad u(i) \in \mathcal{U}, \quad (6)$$

$$\forall j \in \{1, \dots, N_s\}, \quad \forall i \in \{k, \dots, k + N_p - 1\},$$

donde \mathcal{X} y \mathcal{U} representan los conjuntos de restricciones admisibles para estados y acción de control, respectivamente. Cada trayectoria $x_j(i)$ depende de la realización específica de la perturbación $\omega_j(i)$ asociada a cada escenario j , reflejando distintas posibles evoluciones del sistema bajo incertidumbres y perturbaciones estocásticas.

Los coeficientes de ponderación λ_j son positivos y están normalizados para garantizar:

$$\sum_{j=1}^{N_s} \lambda_j = 1. \quad (7)$$

La principal innovación de esta formulación radica en el uso de ponderaciones no uniformes λ_j de escenarios, que no solo representan la probabilidad de ocurrencia de cada realización, sino que permiten resaltar aquellos casos con mayor impacto o riesgo.

En resumen, y como se ha mencionado anteriormente, la estrategia WS-MPC ofrece un equilibrio entre enfoques robustos y estocásticos ya que se conserva la factibilidad frente a incertidumbres significativas sin ignorar su distribución probabilística.

3. Caso de estudio: control de inventario bajo incertidumbre

Para ilustrar la efectividad del enfoque propuesto, se ha considerado un ejemplo sencillo que representa un sistema dinámico de gestión de inventario en una tienda minorista. El objetivo es mantener el inventario dentro de límites operativos seguros, minimizando desviaciones respecto a un nivel de referencia deseado, en presencia de incertidumbres en la demanda.

La dinámica del sistema se representa mediante el siguiente modelo en tiempo discreto:

$$x(k + 1) = A x(k) + B u(k) + D \omega(k), \quad (8)$$

donde $x(k)$ es la cantidad de inventario disponible en el instante k , correspondiente a un día, $u(k)$ representa la cantidad de mercancía diaria adquirida para reponer el inventario, y $\omega(k)$ corresponde a la cantidad demandada (vendida) en un día. En este caso, los parámetros del sistema son constantes: $A = 1$, $B = 1$, y $D = -1$, lo que refleja una relación directa entre el estado actual, la reposición y la demanda.

Se imponen restricciones sobre el nivel de inventario y las órdenes de reposición con el fin de evitar roturas de stock y mantener el sistema dentro de límites operativos realistas. En particular, se establecen las siguientes cotas inferiores y superiores:

$$0 \leq x(k) \leq 80, \quad \forall k, \quad (9)$$

$$0 \leq u(k) \leq 50, \quad \forall k. \quad (10)$$

La incertidumbre principal del sistema proviene de la demanda diaria $\omega(k)$, la cual se ha modelado como una variable aleatoria con distribución normal truncada a valores positivos:

$$\omega(k) \sim \mathcal{N}(\mu, \sigma), \quad \mu = 10, \sigma = 6. \quad (11)$$

4. Resultados

Con el objetivo de validar la eficacia de las estrategias de control presentadas, se han realizado simulaciones correspondientes a un periodo de un año. En cada simulación, los distintos controladores deben regular el inventario de la tienda frente a una demanda incierta, siguiendo la dinámica descrita en la sección 3.

Las condiciones de simulación son las siguientes: el estado inicial del inventario se fija en $x_0 = 50$ unidades, mientras que la referencia deseada es $x_{\text{ref}} = 0$, con el fin de evitar acumulación innecesaria de stock. El horizonte de predicción del

Tabla 1: Comparación de distintos controladores con diferentes valores de ponderación para el caso WS-MPC

Controlador	λ_{peor}	Violación de restricción (%)	Func. coste J acumulada	Tiempo comp. (s) $\mu \pm \sigma$
MPC ideal	—	0	$4,629 \cdot 10^5$	$0,101 \pm 0,003$
MPC estándar	—	42,740	$1,591 \cdot 10^6$	$0,112 \pm 0,056$
WS-MPC	1	9,863	$8,931 \cdot 10^6$	$1,525 \pm 0,061$
	5	8,219	$9,141 \cdot 10^6$	$1,515 \pm 0,065$
	10	7,945	$9,335 \cdot 10^6$	$1,504 \pm 0,076$
	20	7,397	$9,459 \cdot 10^6$	$1,524 \pm 0,052$
	100	5,753	$9,953 \cdot 10^6$	$1,530 \pm 0,076$
Min-max MPC	—	0,274	$1,384 \cdot 10^7$	$0,044 \pm 0,009$

MPC se establece en $N_p = 7$ días. Para la formulación del coste, se utilizan penalizaciones cuadráticas con pesos $Q = 100$ sobre el error de seguimiento y $R = 1$ sobre el esfuerzo de control, priorizando así el seguimiento de la referencia sobre la minimización de las acciones de control.

Bajo estas condiciones, se analizan las trayectorias del sistema, los costes acumulados y la frecuencia de violaciones de las restricciones, comparando el desempeño de la estrategia con escenarios ponderados frente a alternativas clásicas como el control con demanda conocida, denominado como MPC ideal, el MPC estándar, y el min-max MPC.

De esta forma, las distintas estrategias de control implementadas son las siguientes:

- **MPC ideal:** Este caso se formula como un caso ideal con una demanda conocida que, aunque irrealizable en la práctica, permite establecer una cota inferior teórica del coste acumulado y contextualizar el desempeño de los controladores WS-MPC.
- **MPC estándar:** Esta estrategia de control calcula un escenario promedio, que luego se utiliza para predecir el comportamiento futuro del sistema. Sin embargo, es esperable que su desempeño no sea adecuado, ya que solo considera el valor medio de la demanda de inventario.
- **WS-MPC:** Esta estrategia de control presentada en la sección 2 considera 5 posibles ponderaciones λ_{peor} de la ecuación (3): 1, 5, 10, 20 y 100. Es importante destacar que el primer caso, $\lambda_{\text{peor}} = 1$, se corresponde a la implementación tradicional de un MPC basado en escenarios, MS-MPC. Nótese que todos estos casos se han implementado con 74 escenarios. Este es el número establecido por la ecuación (2) para $\delta_x = 10\%$, una única acción de control ($z = 1$) y $\beta = 0,1$.
- **Min-max MPC:** Finalmente, esta estrategia de control robusto busca garantizar el cumplimiento de las restricciones ante cualquier posible realización de la incertidumbre dentro de un conjunto predefinido. Al optimizar para el peor caso posible, el controlador genera una política altamente conservadora, priorizando la viabilidad sobre el rendimiento. En este estudio, el min-max MPC se utiliza como referencia para establecer una cota superior del coste acumulado, permitiendo así contextualizar el desempeño del enfoque propuesto (WS-

MPC) en términos de robustez y eficiencia. Este controlador se formula como:

$$\min_{u[k:k+N_p-1]} \max_{\omega[k:k+N_p-1]} \sum_{i=k}^{k+N_p-1} [x(i) - x_{\text{ref}}]_Q^2 + [u(i)]_R^2, \quad (12)$$

sujeto a las ecuaciones (8) - (10).

Estas simulaciones se han implementado empleando Matlab®, 2023b con una CPU Intel® Core™ i7-8750H de 2.20GHz y 16 GB de RAM. Los resultados de dichas simulaciones se han recogido en la tabla 1. Adicionalmente, y por simplicidad, se ha representado el año completo de simulación del sistema con tres controladores (MS-MPC, correspondiente a $\lambda_{\text{peor}} = 1$, WS-MPC con $\lambda_{\text{peor}} = 100$ y min-max MPC) en las figuras 1-3.

Como era esperable, el MPC ideal no viola restricciones al conocer exactamente las ventas que va a realizar la tienda cada día del año de simulación. Adicionalmente, y como puede apreciarse en la tabla 1, se trata de la estrategia de control que alcanza el menor valor acumulado de la función de coste (como era esperable). Es importante reiterar que esta estrategia de control se trata de un caso ideal, que nos sirve para contextualizar el comportamiento del resto de controladores.

Por otro lado, el MPC estándar de escenario promedio es el que tiene un porcentaje de violación de restricciones mayor. Esto se debe a que el algoritmo asume que la cantidad de venta diaria serán valores aproximadamente iguales a la media de la distribución de probabilidad de la estocasticidad (igual a 10 en este caso). Esto evidencia que esta estrategia no es adecuada para calcular la reposición de inventario de la tienda.

En cuanto al control WS-MPC, puede comprobarse que, para la ponderación $\lambda_{\text{peor}} = 1$, es decir, para el caso MS-MPC tradicional, el porcentaje de incumplimiento logrado es inferior al máximo establecido del 10% (véanse las tablas 1 y 2). Adicionalmente, queda demostrado que a medida que aumenta el valor de la ponderación, el porcentaje de incumplimiento de restricciones decae sin necesidad de aumentar el número de escenarios. Esto también puede comprobarse en las figuras 1 y 2, donde puede comprobarse la reducción del incumplimiento de restricciones ante el aumento de la ponderación λ_{peor} .

En efecto, si se quisiera alcanzar el porcentaje de incumplimiento obtenido para la ponderación de 100 ($\lambda_{\text{peor}} = 100$) con un MS-MPC equiprobable, la ecuación (2) marca que el número mínimo necesario de escenarios sería de 128. Esto supondría necesitar un 73% más de escenarios frente a los 74

Tabla 2: Equivalencia entre λ_{peor} y N_s

WS-MPC λ_{peor}	Violación de restricción (%)	N_s equivalente a MS-MPC
1	9.863	74
5	8.219	89
10	7.945	93
20	7.397	100
100	5.753	128

que se emplearon, lo cual aumenta en gran medida la carga computacional del control del inventario de la tienda. Este hecho queda reflejado por la tabla 2, donde se muestran la cantidad de escenarios que serían necesarios implementar en un WS-MPC equiprobable ($\lambda_{\text{peor}} = 1$), o lo que es equivalente, un MS-MPC, para alcanzar el mismo porcentaje de incumplimiento de restricciones.

Por último, el min-max MPC calcula la estrategia de control más conservadora posible (sin considerar el MPC ideal al ser un caso teórico) al obtener un porcentaje de incumplimiento de restricciones mínimo. La contraprestación de esto será el alto valor acumulado de la función de coste, lo que, en este sistema, se traduciría en pérdidas económicas, ya que, para este caso, un nivel promedio de inventario mayor supone una mayor inversión económica.




Figura 1: Resultados de la simulación del MS-MPC ($\lambda_{\text{peor}} = 1$).Figura 2: Resultados de la simulación del WS-MPC ($\lambda_{\text{peor}} = 100$).

Figura 3: Resultados de la simulación del min-max MPC.

Por otro lado, en la figura 3 puede comprobarse el conservadurismo de esta estrategia de control, evidenciado por un mayor nivel promedio del nivel de inventario para evitar las roturas de stock, frente al resto de las contempladas.

5. Conclusiones

Los resultados obtenidos muestran que la estrategia de control predictivo basada en modelo con escenarios ponderados (WS-MPC) ofrece una solución eficaz para manejar la incertidumbre en sistemas dinámicos, logrando un equilibrio adecuado entre robustez y eficiencia computacional. A diferencia de enfoques más conservadores como el min-max MPC, el WS-MPC permite reducir significativamente el porcentaje de violaciones de restricciones sin necesidad de incrementar el número de escenarios requeridos, como ocurre en los métodos multiescenario clásicos. Esta característica lo convierte en una alternativa atractiva para aplicaciones donde los recursos computacionales son limitados y se requiere una respuesta más flexible ante variabilidad estocástica.

Además, al asignar ponderaciones diferenciales a los escenarios más críticos, el controlador es capaz de anticiparse a condiciones adversas sin comprometer el rendimiento en situaciones nominales. Esta capacidad de adaptación lo posiciona como un enfoque intermedio entre las estrategias robustas puras y las netamente estocásticas.

Como línea futura de investigación, se propone extender esta metodología a sistemas estocásticos más complejos, incluyendo aplicaciones en el ámbito biológico y en comunidades energéticas, donde la incertidumbre en la demanda y generación requiere esquemas de control que ofrezcan un balance entre robustez y estocasticidad.

Agradecimientos

Este trabajo es parte del proyecto PID2022-142069OBI00, financiado por MCIN/AEI/10.13039/501100011033/FEDER, UE y también del proyecto C3PO-R2D2 (PID2020119476RB-I00) financiado por MCIN/AEI/10.13039/501100011033.

Referencias

- Arcari, E., Iannelli, A., Carron, A., Zeilinger, M. N., 2023. Stochastic MPC with robustness to bounded parametric uncertainty. *IEEE Transactions on Automatic Control* 68 (12), 7601–7615.
DOI: 10.1109/TAC.2023.3294868
- Bemporad, A., Borrelli, F., Morari, M., 2003. Min-max control of constrained uncertain discrete-time linear systems. *IEEE Transactions on Automatic Control* 48 (9), 1600–1606.
DOI: 10.1109/TAC.2003.816984
- Ben-Tal, A., Ghaoui, L., Nemirovski, A., 2009. *Robust Optimization*. Princeton University Press.
DOI: 10.1515/9781400831050
- Bertsimas, D., Brown, D. B., Caramanis, C., 2011. Theory and applications of robust optimization. *SIAM review* 53 (3), 464–501.
DOI: 10.48550/arXiv.1010.5445
- Birge, J. R., Louveaux, F., 2011. *Introduction to stochastic programming*. Springer Science & Business Media.
DOI: 10.1007/978-1-4614-0237-4
- Calafiore, G. C., Fagiano, L., 2012. Robust model predictive control via scenario optimization. *IEEE Transactions on Automatic Control* 58 (1), 219–224.
DOI: 10.1109/TAC.2012.2203054

- Camacho, E. F., Berenguel, M., Rubio, F. R., Martínez, D., 2012. Control of solar energy systems. Springer, London, England.
DOI: 10.1007/978-0-85729-916-1
- Camacho, E. F., Bordons, C., Maestre, J. M., 2025. Model Predictive Control. Third Edition. Springer-Verlag, London, England.
- Coppens, P., Patrinos, P., 2021. Data-driven distributionally robust MPC for constrained stochastic systems. IEEE Control Systems Letters 6, 1274–1279.
DOI: 10.1109/LCSYS.2021.3091628
- Giulioni, L., 2015. Stochastic model predictive control with application to distributed control systems. Ph.D. thesis, Politecnico di Milano.
- Grosso, J., Ocampo-Martinez, C., Puig, V., Joseph, B., 2014. Chance-constrained model predictive control for drinking water networks. Journal of Process Control 24 (5), 504–516.
DOI: 10.1016/j.jprocont.2014.01.010
- Maciejowski, J., 2002. Predictive control with constraints. Prentice Hall, Essex, England.
- Mark, C., Liu, S., 2020. Stochastic MPC with distributionally robust chance constraints. IFAC-PapersOnLine 53 (2), 7136–7141.
DOI: 10.1016/j.ifacol.2020.12.521
- Schildbach, G., Fagiano, L., Frei, C., Morari, M., 2014. The scenario approach for stochastic model predictive control with bounds on closed-loop constraint violations. Automatica 50 (12), 3009–3018.
DOI: 10.1016/j.automatica.2014.10.035
- Shapiro, A., Dentcheva, D., Ruszczyński, A., 2021. Lectures on stochastic programming: modeling and theory. SIAM.
DOI: 10.1137/1.9781611976595
- Tian, X., Negenborn, R. R., van Overloop, P.-J., Maestre, J. M., Sadowska, A., van de Giesen, N., 2017. Efficient multi-scenario model predictive control for water resources management with ensemble streamflow forecasts. Advances in water resources 109, 58–68.
DOI: 10.1016/j.advwatres.2017.08.015
- van Ackooij, W., Henrion, R., Pérez-Aros, P., 2020. Generalized gradients for probabilistic/robust (probust) constraints. Optimization 69 (7-8), 1451–1479.
DOI: 10.1080/02331934.2019.1576670
- van Overloop, P.-J., Weijs, S., Dijkstra, S., 2008. Multiple model predictive control on a drainage canal system. Control Engineering Practice 16 (5), 531–540.
DOI: 10.1016/j.conengprac.2007.06.002
- Velarde, P., Valverde, L., Maestre, J. M., Ocampo-Martinez, C., Bordons, C., 2017. On the comparison of stochastic model predictive control strategies applied to a hydrogen-based microgrid. Journal of Power Sources 343, 161–173.
DOI: 10.1016/j.jpowsour.2017.01.015
- Velarde, P., Zafra-Cabeza, A., Márquez, J. J., Maestre, J. M., Bordons, C., 2023. Stochastic MPC-based reconfiguration approaches for microgrids. IEEE Transactions on Control Systems Technology.
DOI: 10.1109/TCST.2023.3342135