

Jornadas de Automática

Métodos de control robusto y predictivo para una caminata estable en el robot humanoide TEO

Lipa, G.^{a,*}, Muñoz Yañez-Barnuevo, J.^b, Monje, C. A.^a, Balaguer, C.^a

^aDepartamento de Ingeniería de Sistemas y Automática, RoboticsLab, Universidad Carlos III de Madrid, Av. de la Universidad, 30, 28911 Leganés, Madrid, España.

^bCentro de Automática y Robótica, Consejo Superior de Investigaciones Científicas (CSIC), 28049 Madrid, España.

To cite this article: Gerson Lipa, Jorge Muñoz, Concepción A. Monje, Carlos Balaguer, 2024. Robust and Predictive Control Methods for Stable Walking in the Humanoid Robot TEO. Jornadas de Automática, 45. <https://doi.org/10.17979/ja-cea.2024.45.10912>

Resumen

Un aspecto fundamental para lograr una caminata estable en cualquier robot humanoide es el control de la estabilidad durante la marcha. Este trabajo analiza algunas estrategias de control para asegurar una marcha estable en el robot humanoide TEO. En investigaciones previas, se utilizó el modelo del péndulo invertido lineal para la generación de trayectorias estables, tomando en cuenta el criterio de estabilidad del punto de momento zero (ZMP). Según este criterio, el ZMP debe mantenerse dentro de una región de estabilidad para garantizar una marcha equilibrada, lo que requiere un control continuo de este valor durante toda la trayectoria.

Palabras clave: Modelado, Métodos de identificación y control, Control predictivo, Control robusto (caso lineal), Mecatrónica humana y robótica, Tecnología robótica.

Robust and Predictive Control Methods for Stable Walking in the Humanoid Robot TEO

Abstract

A fundamental aspect to achieve a stable gait in any humanoid robot is the control of stability during walking. This paper analyzes some control strategies to ensure a stable gait in the TEO humanoid robot. In previous research, the linear inverted pendulum model was used for the generation of stable trajectories, taking into account the stability criterion of the zero moment point (ZMP). According to this criterion, the ZMP must be maintained within a stability region to ensure a balanced gait, which requires continuous control of this value throughout the trajectory.

Keywords: Modeling, Identification and control methods, Predictive control, Robust control (linear case), Human and Robot Mechatronics, Robotics technology.

1. Introducción

En el estudio llevado a cabo por (Lipa et al., 2023), se delineó una trayectoria viable para el robot TEO, utilizando como base el modelo del péndulo invertido lineal (Figura 1). Este enfoque implicó el cálculo de las trayectorias de cada pierna, teniendo en cuenta las restricciones de movilidad de las articulaciones y las holguras inherentes al sistema.

Este robot humanoide usado como plataforma en este contexto (ver Figura 1), está equipado con 28 grados de libertad distribuidos en sus extremidades, cuello y torso. Cada articulación es impulsada por motores brushless de la marca Maxon, con potencias que oscilan entre 60 y 120 vatios. Los sensores CUI amt-203, que funcionan como encoders absolutos y relativos, junto con los sensores de posición Hall integrados en los

*Autor para correspondencia: glipa@ing.uc3m.es
Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

motores, proporcionan información crucial para el control y la retroalimentación del sistema. Además, la integración de cuatro sensores Jr3 de fuerza-par en tobillos y muñecas permiten una interacción sensorial.

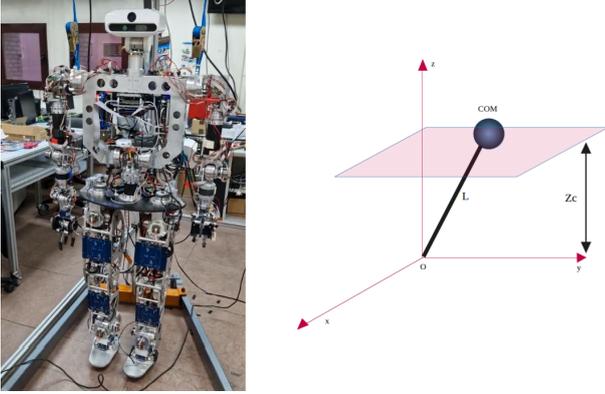


Figura 1: Robot humanoide TEO (Izquierda), Modelo del péndulo invertido (Derecha)

Una vez realizadas las pruebas experimentales, se pudo verificar la alcanzabilidad del robot, la cual está principalmente limitada por su propio hardware. Es importante mencionar la dificultad de mantener la estabilidad en la marcha a lo largo de la trayectoria, debido en gran parte a la complejidad propia del sistema, incluyendo las holguras y la flexibilidad estructural. Tras analizar e identificar el sistema, se obtuvo su función de transferencia, a la cual se aplicó finalmente un control proporcional sencillo. Sin embargo, este no resultó viable para el seguimiento preciso de las trayectorias requeridas, ya que en la caminata es fundamental garantizar la estabilidad de una forma mucho más rápida y robusta de la que se pudo lograr con el control clásico.

Existen diversos métodos de control utilizados para el seguimiento de la trayectoria deseada, basados en el modelo del péndulo invertido lineal (LIPM) ((Irfan et al., 2018), (Kelly and Ruina, 2015), (Ranganayakulu et al., 2017)) o en otros tipos de patrones ((Romualdi et al., 2022), (García et al., 2021), (Garcia and Morari, 1982)). Además es crucial garantizar la robustez del control sobre el sistema para lograr una caminata fiable ((Gazar et al., 2021)).

Dado que el sistema anterior presentaba limitaciones, se realizó un nuevo modelo para evitar repetir errores, de manera que el primer objetivo principal es identificar correctamente el sistema, incluyendo los polos y ceros, ya que esto permitirá diseñar un controlador adecuado. En el enfoque del artículo anterior (Lipa et al., 2023), se aproximó el sistema a uno de segundo orden, por lo tanto, buscaremos mejorar la identificación.

Se realizaron pruebas iniciales utilizando un Controlador de Modelo Interno (IMC) robusto aplicado al ZMP. Este controlador fue seleccionado por su capacidad para manejar incertidumbres y perturbaciones.

Por otro lado, el Control Predictivo basado en Modelo (MPC) es un método de control que utiliza un modelo matemático del sistema para anticipar su comportamiento futuro y calcular la secuencia óptima de acciones de control que minimiza un criterio de rendimiento específico, mientras cumple con restricciones operativas. A diferencia de otros enfoques de

control, el MPC tiene la capacidad inherente de gestionar eficazmente tanto restricciones de entrada como de estado. Esta característica lo hace particularmente adecuado para aplicaciones donde es esencial cumplir con ciertos límites operativos, como en el caso de la locomoción de robots humanoides.

1.1. Control por modelo Interno (IMC)

El Controlador de IMC robusto que se basa en la inclusión del modelo de la función de transferencia del sistema dentro del propio controlador. Esta técnica permite anular el comportamiento del sistema mediante cancelaciones polo-cero y luego añadir el comportamiento deseado. Para implementar este controlador, solo se necesita el modelo del sistema y el comportamiento deseado.

El inconveniente surge cuando la función de transferencia es de fase no mínima. En este caso, la inclusión de un cero en el semiplano positivo haría que el sistema sea inestable en el controlador, debido a la aparición de un polo en el semiplano positivo.

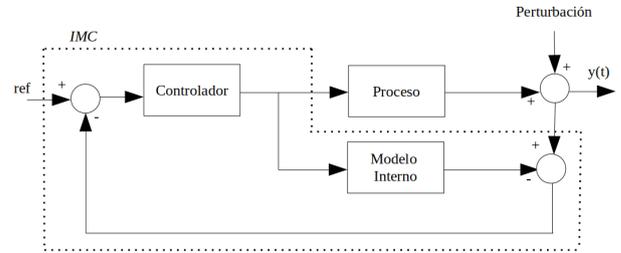


Figura 2: Esquema del controlador de modelo interno

Para solucionar este problema, se diseña el controlador ignorando los ceros de fase no mínima y los retardos del sistema. Posteriormente, se agrega un filtro que permita hacer el sistema realizable. El comportamiento final del sistema debería aproximarse a la función propuesta como objetivo; sin embargo, si el sistema tiene ceros de fase no mínima o retardos, el sistema final no se adecuará completamente al comportamiento deseado.

El esquema del IMC se puede observar en la Figura 2. En este esquema, G representa el modelo del sistema en función de transferencia, y C es el controlador asociado al IMC.

Para obtener el controlador, primero debemos separar las partes no invertibles del sistema, como los retardos y los ceros de fase no mínima (ver ecuación (1)). Estas partes se agrupan en G_{ninv} , lo que nos permite usar G_{inv} para diseñar el controlador.

$$G(s) = G_{inv}(s) \cdot G_{ninv}(s) \quad (1)$$

En este contexto, $G(s)$ es la función de transferencia del sistema original, $G_{inv}(s)$ representa la parte invertible del sistema, y $G_{ninv}(s)$ agrupa los elementos no invertibles. De esta manera, podemos diseñar el controlador utilizando $G_{inv}(s)$ para garantizar un comportamiento deseado y manejable.

El diseño del controlador se llevaría a cabo utilizando la ecuación (2), donde $f(s)$ es un filtro utilizado para conseguir que el sistema sea realizable y estable.

$$C = \frac{1}{G_{inv}} \cdot f(s) \quad (2)$$

El filtro tiene la forma de la ecuación (3), donde λ es un parámetro del filtro relacionado con la frecuencia de corte y n es el grado del filtro.

$$f(s) = \frac{1}{(\lambda \cdot s + 1)^n} \quad (3)$$

1.2. Control por modelo predictivo (MPC)

El Control Predictivo basado en Modelo es una técnica de control que emplea un modelo matemático del sistema para prever su comportamiento futuro y calcular la secuencia óptima de acciones de control que minimiza un criterio de rendimiento específico, respetando restricciones operativas (ver Figura 3). Básicamente, el MPC busca resolver un problema de optimización en cada iteración para determinar la mejor acción de control a seguir.

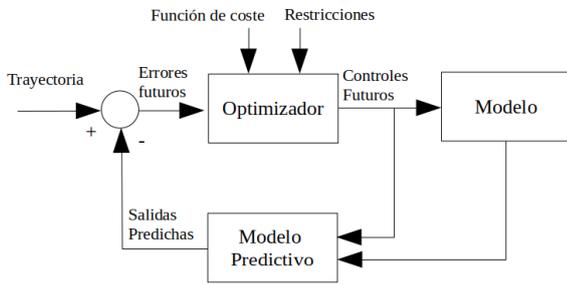


Figura 3: Esquema del controlador predictivo

Para su diseño y aplicación efectiva, es esencial disponer de un modelo del sistema que aproxime de forma precisa el comportamiento del sistema real.

Si definimos un sistema en espacio de estados, representado por la ecuación (4), donde la salida se denota como y y el estado como x , y cuyas matrices de estado son A', B', C' , entonces podemos definir las ecuaciones aumentadas (5), donde A, B, C son las matrices correspondientes a la representación aumentada del sistema.

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t), \quad x_0 = x(t_0) \\ y(t) &= Cx(t) \end{aligned} \quad (4)$$

$$A = \begin{bmatrix} A' & 0_m^T \\ C' \cdot A' & 1 \end{bmatrix}, B = \begin{bmatrix} B' \\ C' \cdot B' \end{bmatrix}, C = \begin{bmatrix} 0_m & 1 \end{bmatrix} \quad (5)$$

La relación que existe entre los incrementos o variaciones de control Δu y las salidas futuras Y , se observa en la ecuación (6).

$$Y = F \cdot x(k) + G \cdot \Delta u \quad (6)$$

Las matrices F y G , como se definen en la ecuación (7), se calculan a partir de las matrices ampliadas obtenidas anteriormente.

$$F = \begin{bmatrix} C \cdot A \\ C \cdot A^2 \\ C \cdot A^3 \\ \vdots \\ C \cdot A^{Np} \end{bmatrix}, B = \begin{bmatrix} C \cdot B & 0 & 0 & \dots & 0 \\ C \cdot A \cdot B & C \cdot B & 0 & \dots & 0 \\ C \cdot A^2 \cdot B & C \cdot A \cdot B & C \cdot B & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ C \cdot A^{Np-1} \cdot B & C \cdot A^{Np-2} \cdot B & C \cdot A^{Np-3} \cdot B & \dots & 0 \end{bmatrix} \quad (7)$$

Para calcular las predicciones deseadas, primero necesitamos las acciones futuras de control. Para esto, utilizamos una función de coste que busca minimizar tanto la señal de control

como el error de seguimiento. La función de coste se define como se muestra en la ecuación (8).

$$J = (R - y)^T Q_\delta (R - y) + \Delta u^T Q_\lambda \Delta u \quad (8)$$

$$Q_\lambda = I \cdot \lambda, \quad Q_\gamma = I \cdot \gamma$$

En esta ecuación, R representa la referencia deseada, y es la salida del sistema, Q_δ es la matriz de penalización del error y Q_λ es la matriz de penalización de la variación del control. Los parámetros clave del control predictivo que influyen en esta optimización son los siguientes:

Horizonte de Predicción (N_p): Este parámetro representa el número de pasos futuros que el controlador considera al predecir la salida del sistema.

Horizonte de Control (N_u): Este parámetro es el número de pasos futuros para los cuales se calculan las acciones de control.

Parámetro de Penalización del Control (λ): Este parámetro se utiliza para penalizar las variaciones en las acciones de control, ayudando a evitar cambios bruscos y mejorar la suavidad del control.

Parámetro de Penalización del Error (γ): Este parámetro penaliza la desviación de la salida del sistema respecto a la referencia deseada.

2. Identificación del sistema

Para diseñar un controlador eficaz para el robot TEO, es imprescindible lograr una representación precisa de su sistema. En un primer enfoque, abordaremos la modelización del robot en condiciones de doble apoyo, una fase crucial para entender su comportamiento dinámico. Es esencial emplear un método de identificación apropiado que nos permita capturar con precisión las características del sistema. Para iniciar este proceso, necesitamos recopilar datos del sistema que nos brinden una visión detallada de su respuesta, utilizando entradas y salidas en el ZMP.

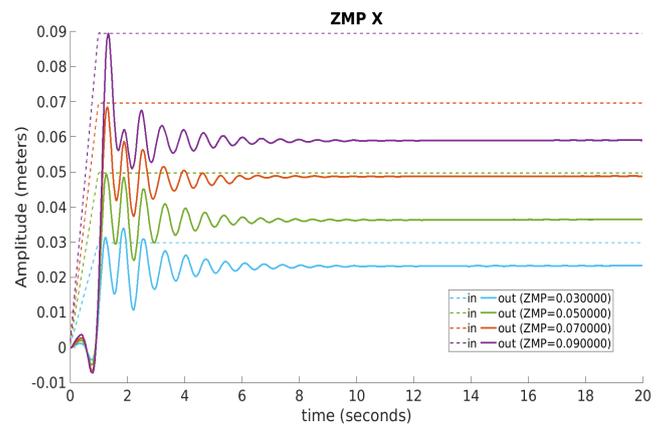


Figura 4: Datos recogidos del sistema

En la Figura 4 se puede observar la respuesta de cada sistema identificado para cada ZMP. Como se aprecia, el sistema posee una respuesta de fase no mínima, además de una sobreoscilación apreciable. Debido a la complejidad del sistema, se probaron varias alternativas de identificación (Auto-

Regresive-eXogenous (Söderström and Stoica, 1989), Output-Error (Ljung, 1987) y Box Jenkins (Box et al., 1994)). Para llevar a cabo la identificación, se optó por trabajar en el dominio del tiempo continuo utilizando la función tfest de MATLAB. En nuestro caso concreto, esta función emplea el método de estimación Output-Error, el cual minimiza la diferencia entre la salida real del sistema y la salida predicha por el modelo. Además, tfest utiliza la Transformada de Fourier para convertir los datos de tiempo en datos de frecuencia, lo que facilita la estimación precisa de las funciones de transferencia. Los sistemas que se obtuvieron de la identificación se observan en la Figura 5.

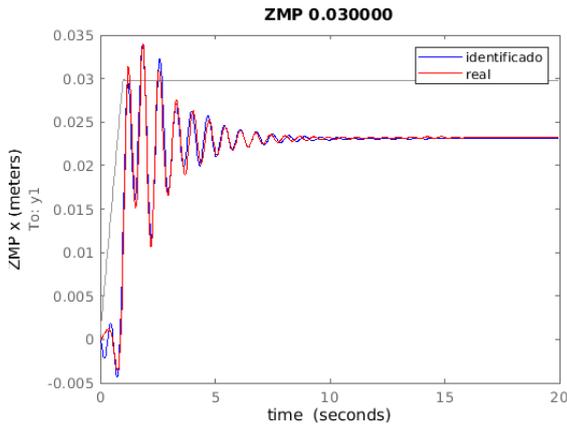


Figura 5: Sistema identificado para un zmp=0.03

A medida que crece el valor de referencia de ZMP, el error en régimen permanente y las sobreoscilaciones son mayores (debido sobre todo a la inercia y elasticidad presentes en el robot). Se estimó que el número de polos, n_p , era de 3, y el número de ceros, n_z , de 5, un valor aproximado que permite adaptarse a la dinámica del sistema en todo el rango de operación. Es importante destacar que este rango de operación debe ser igual o menor que el margen de estabilidad dentro del soporte del pie del robot.

3. Aplicación de los controladores en TEO

Para diseñar un controlador eficaz, la precisión del modelo del sistema es crucial. Esto garantiza una adaptación adecuada del controlador a la dinámica real y una corrección precisa del error. Tanto el IMC como el MPC son altamente dependientes de la precisión del modelo, lo que lo convierte en un factor determinante en los resultados finales. Por tanto, usaremos para el diseño de los controladores el sistema identificado para un zmp=0.03 (ver ecuación (9)), con ello garantizamos un comportamiento adecuado para todo el rango de trabajo.

$$G_{0.03}(s) = \frac{-132.3(s - 4.4)(s^2 - 8.3s + 51.8)}{(s + 13)(s^2 + 0.7s + 37.5)(s^2 + 1.1s + 85)} \quad (9)$$

En la Figura 6, se aprecian tres ceros en el semiplano positivo, lo que indica la presencia de ceros de fase no mínima en el sistema. Esta característica dificulta considerablemente el control del sistema.

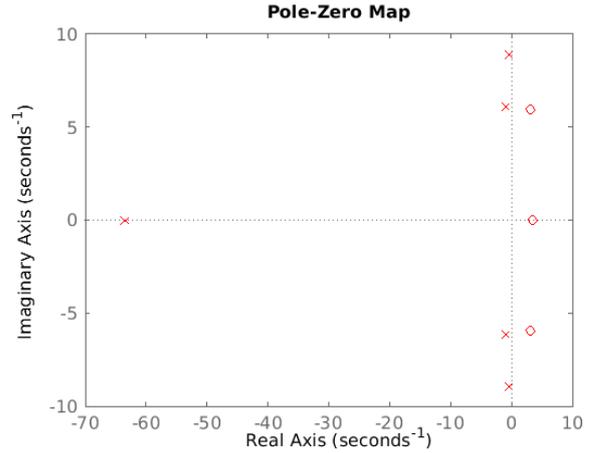


Figura 6: Polos y ceros del sistema identificado

3.1. IMC

Para obtener el controlador debemos separar el sistema en una parte invertible de la parte no invertible, según la ecuación (10).

$$G_{inv}(s) = \frac{-132.3}{(s + 13)(s^2 + 0.7s + 37.5)(s^2 + 1.1s + 85)} \quad (10)$$

$$G_{ninv}(s) = (s - 4.45)(s^2 - 8.3s + 51.8)$$

El controlador obtenido se calcularía según la ecuación (2), obteniéndose la ecuación (11).

$$G_c(s) = \frac{(s + 13)(s^2 + 0.7s + 37.5)(s^2 + 1.1s + 85)}{-132.3} \cdot f(s) \quad (11)$$

Para resolver la disparidad en el grado del polinomio en el sistema final, aplicaremos el filtro de la ecuación (3) con $n = 2$ y $\lambda = 0.3$, lo que nos dará la ecuación (12).

$$f(s) = \frac{1}{(0.3 \cdot s + 1)^2} \quad (12)$$

Así, el resultado final del controlador se visualiza en la ecuación (13).

$$G_c(s) = \frac{(s + 12.99)(s^2 + 0.713s + 37.48)(s^2 + 1.104s + 84.86)}{-132.27 \cdot (0.3 \cdot s + 1)^2} \quad (13)$$

Después de aplicar el controlador en bucle cerrado sobre la simulación, podemos observar el resultado en la Figura 7. La respuesta del sistema es rápida, aunque se puede apreciar un retraso del sistema de 2 segundos. Dado que existe un leve retraso en el tiempo, es necesario cuantificar el efecto real que se produciría en el sistema al seguir una trayectoria completa.

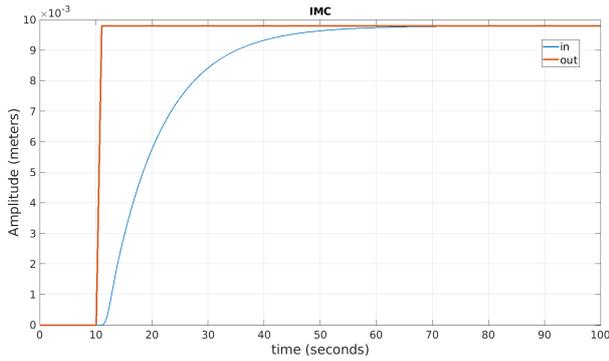


Figura 7: Respuesta simulada del sistema con controlador IMC

3.2. Model predictive control

A partir de la función de transferencia de la ecuación (13) obtenemos el sistema en espacio de estado. Luego, utilizamos las ecuaciones (4) para obtener las matrices ampliadas. Una vez obtenidas estas matrices, calculamos las matrices F y B aplicando la ecuación (7). Para obtener las predicciones de salida deseadas, es necesario conocer los valores de entrada de control necesarios para lograr la respuesta deseada. Para ello, aplicamos la optimización de la función de la ecuación (8) y obtenemos las entradas futuras deseadas. Es en este punto podemos aplicar las restricciones del sistema.

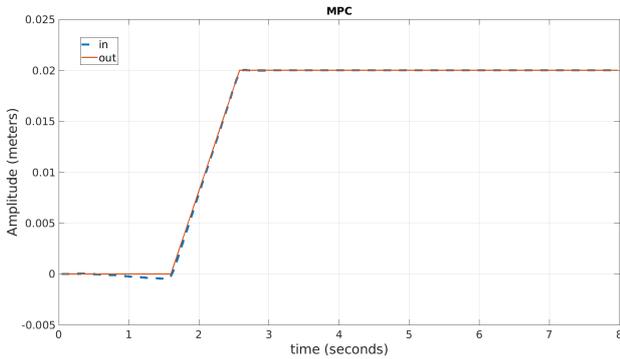


Figura 8: Respuesta simulada del sistema con controlador MPC

Los parámetros que permiten la adecuación del controlador para nuestra aplicación son $N_p = 80$, $N_u = 40$, $\gamma = 1$, y $\lambda = 1$. El resultado final se puede observar en la Figura 8, donde se aprecia que el sistema es rápido y presenta una pequeña sobreoscilación.

4. Experimentación

En esta sección, aplicaremos los controladores calculados en el apartado anterior sobre el robot real en condiciones de doble apoyo. Inicialmente, implementaremos un step con una subida en rampa para evitar fatigar el sistema. En trabajos posteriores, probaremos el seguimiento de una trayectoria específica.

4.1. Aplicación del IMC

Aplicando el controlador descrito en la ecuación (13) sobre el sistema representado por la ecuación (9) en el esquema

de IMC mostrado en la Figura 2, obtenemos la respuesta que se observa en la Figura 9.

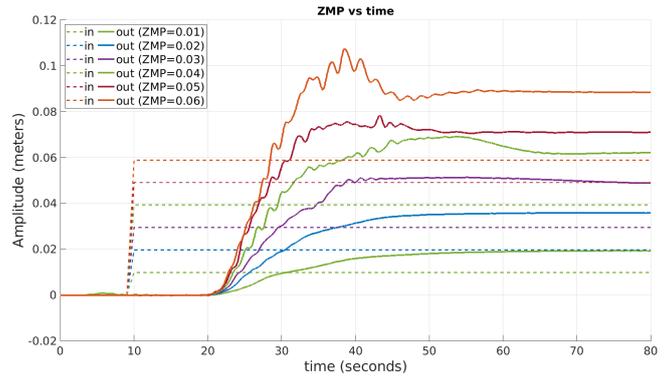


Figura 9: Respuesta real del sistema con controlador IMC

Inicialmente, se observa que el sistema no sigue la referencia establecida. A medida que aumentamos la amplitud del ZMP, el sistema muestra un comportamiento de mayor orden, lo cual se debe a las variaciones en la inclinación del robot. Esto indica que los controladores IMC, que dependen del modelo del robot, no son eficaces cuando el modelo del robot varía, resultando en un seguimiento deficiente de la trayectoria deseada.

4.2. Aplicación del MPC

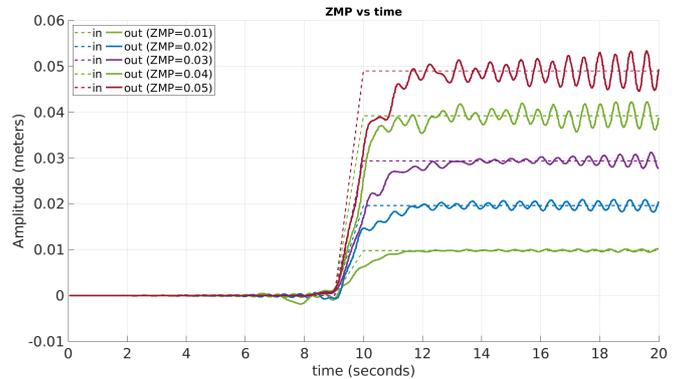


Figura 10: Respuesta real del sistema con controlador MPC

Si aplicamos el controlador calculado en la sección anterior, obtendremos la respuesta a un escalón que se muestra en la Figura 10 para diferentes valores de ZMP. En esta gráfica, se observan perturbaciones persistentes en el régimen permanente, las cuales se deben principalmente a las discrepancias entre el modelo real y el modelo identificado, así como a las aproximaciones realizadas al utilizar un modelo genérico para todos los casos.

5. Conclusiones

La implementación de los controladores IMC (Internal Model Control) y MPC (Model Predictive Control) en un robot humanoide en doble apoyo fue un proceso complejo que

implicó varios pasos clave. Primero, se obtuvo una identificación precisa del sistema, validando los modelos para asegurar que representaran fielmente la dinámica del robot en múltiples puntos de equilibrio. Se compararon varios modelos para seleccionar el más adecuado, garantizando que capturaran con precisión la dinámica del robot. Esto permitió desarrollar controladores capaces de manejar las variaciones en la dinámica del robot, proporcionando un control más fiable y rápido.

5.1. Desempeño del Controlador IMC

La aplicación del controlador IMC reveló algunas limitaciones significativas. La identificación del sistema subyacente mostró discrepancias importantes, particularmente en la ganancia ante un escalón, lo que impactó negativamente en el rendimiento del controlador. Estas discrepancias indicaron que el modelo utilizado no representaba con precisión la dinámica real del sistema, lo que llevó a un comportamiento indeseado por parte del controlador IMC. Además, el sistema presentaba un retraso o delay inicial de 2 segundos, exacerbado por la presencia de una fase no mínima en la función de transferencia. Esta característica impidió una inversión efectiva de la parte no mínima de la función de transferencia, limitando la capacidad del controlador para responder adecuadamente a los cambios en la trayectoria.

La presencia de este retraso hizo que el IMC no fuera adecuado para aplicaciones de seguimiento de trayectoria, donde la capacidad de respuesta rápida es crítica. La falta de correspondencia entre la ganancia esperada y la observada, junto con el retraso inicial significativo, resultó en un rendimiento deficiente del controlador IMC, lo que subraya la importancia de una identificación precisa y la necesidad de considerar las características específicas del sistema al diseñar controladores.

5.2. Desempeño del Controlador MPC

En contraste, la implementación del controlador MPC produjo resultados prometedores. El MPC mostró una capacidad notable para anticipar cambios en la señal de entrada y responder rápidamente, lo que es crucial para el seguimiento de trayectorias. Este comportamiento se debe a la naturaleza predictiva del MPC, que permite calcular las acciones futuras del controlador basándose en el modelo del sistema y las restricciones definidas. Sin embargo, se observaron ciertas sobreoscilaciones en el régimen permanente, lo que sugiere que el comportamiento del sistema podría estar influenciado por variaciones en el ZMP y las aproximaciones realizadas durante la identificación y diseño de los experimentos.

Estas sobreoscilaciones podrían deberse a la variabilidad inherente en el sistema del robot y las aproximaciones hechas en el modelo utilizado para el controlador MPC. A pesar de estas oscilaciones, el controlador MPC demostró ser eficaz en el seguimiento de la trayectoria y en alcanzar los objetivos deseados. La capacidad del MPC para anticipar y adaptarse a las condiciones cambiantes del sistema lo convierte en una herramienta valiosa para el control de robots humanoides, aunque se requiere un análisis adicional para mitigar las sobreoscilaciones observadas.

En resumen, la experiencia con los controladores IMC y MPC en el control del robot humanoide en doble apoyo resalta la importancia de una identificación precisa del sistema y la consideración de las características específicas del sistema al diseñar controladores. Mientras que el IMC presentó limitaciones debido a problemas de identificación y retrasos, el MPC mostró un desempeño superior en términos de rapidez y capacidad de anticipación, aunque con algunos desafíos a superar en términos de sobreoscilaciones en el régimen permanente.

Agradecimientos

La investigación que ha conducido a estos resultados ha recibido financiación del proyecto SOFIA: Articulación blanda inteligente con capacidades de reconfiguración y modularidad para plataformas robóticas, con referencia PID2020-13194GBI00, financiado por financiado por MCI-N/AEI/10.13039/501100011033.

Referencias

- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., 1994. *Time Series Analysis: Forecasting and Control*. Prentice Hall.
- García, C. E., Morari, M., 1982. Internal model control: 1-a unifying review and some new results. *Ind. Eng. Chern. Proc. Res. Dev.* 21, 308.
- García, G., Griffin, R., Pratt, J., 2021. Mpc-based locomotion control of bipedal robots with line-feet contact using centroidal dynamics. In: 2020 IEEE-RAS 20th International Conference on Humanoid Robots (Humanoids). pp. 276–282.
DOI: 10.1109/HUMAN0IDS47582.2021.9555775
- Gazar, A., Khadiv, M., Prete, A. D., Righetti, L., 2021. Stochastic and robust mpc for bipedal locomotion: A comparative study on robustness and performance. In: 2020 IEEE-RAS 20th International Conference on Humanoid Robots (Humanoids). pp. 61–68.
DOI: 10.1109/HUMAN0IDS47582.2021.9555783
- Irfan, S., Mehmood, A., Razzaq, M. T., Iqbal, J., 2018. Advanced sliding mode control techniques for inverted pendulum: Modelling and simulation. *Engineering Science and Technology, an International Journal* 21 (4), 753–759.
DOI: <https://doi.org/10.1016/j.jestch.2018.06.010>
- Kelly, M., Ruina, A., 2015. Non-linear robust control for inverted-pendulum 2d walking. In: 2015 IEEE International Conference on Robotics and Automation (ICRA). pp. 4353–4358.
DOI: 10.1109/ICRA.2015.7139800
- Lipa, G. M., Muñoz, J., Łukawski, B., Monje, C. A., Balaguer, C., may 2023. Estrategia de caminata para el robot humanoide teo. In: *Actas de las Jornadas de Robótica y Bioingeniería*. pp. 163–170.
- Ljung, L., 1987. System identification: Theory for the user. *IEEE Transactions on Automatic Control* 31 (4), 22–32.
- Ranganayakulu, R., Babu, G. U. B., Rao, A. S., 2017. Fractional filter imc-pid controller design for an unstable inverted pendulum system. In: 2017 IEEE International Conference on Smart Technologies and Management for Computing, Communication, Controls, Energy and Materials (ICSTM). pp. 411–416.
DOI: 10.1109/ICSTM.2017.8089195
- Romualdi, G., Dafarra, S., L'Erario, G., Sorrentino, I., Traversaro, S., Pucci, D., 2022. Online non-linear centroidal mpc for humanoid robot locomotion with step adjustment. In: 2022 International Conference on Robotics and Automation (ICRA). pp. 10412–10419.
DOI: 10.1109/ICRA46639.2022.9811670
- Söderström, T., Stoica, P., 1989. *System Identification*. Prentice Hall.