

Jornadas de Automática

Robustez del control híbrido neuro-PD ante incertidumbres y perturbaciones

Juan Daniel Muñoz-Navarrete^{a,*}, Matilde Santos^b

^aEscuela de Informática, Universidad Nacional de Educación a Distancia (UNED), 28040 Madrid, España.

^bInstituto de Tecnología del Conocimiento, Universidad Complutense de Madrid, 28040 Madrid, España.

To cite this article: Muñoz-Navarrete, J.D., Santos, M.. 2026. Robustness of neuro-PD hybrid control under uncertainties and disturbances. Jornadas de Automática, 47. <https://doi.org/10.17979/ja-cea.2026.47.13645>

Resumen

Este trabajo presenta el desarrollo y validación de un sistema de control híbrido para un manipulador robótico de dos grados de libertad (2-GDL). El esquema propuesto combina una Red Neuronal Artificial (ANN) de tipo Perceptrón Multicapa (MLP), encargada de aproximar la dinámica inversa para la linealización del sistema, con un regulador Proporcional-Derivativo (PD) para cerrar el lazo de realimentación. La robustez de la arquitectura se evalúa mediante pruebas de estrés que incluyen incertidumbre paramétrica en la masa del eslabón distal, ruido gaussiano en los sensores y perturbaciones externas de torque. Los resultados, validados íntegramente en simulación, demuestran que el control híbrido mitiga eficazmente la deriva característica de los modelos basados puramente en aprendizaje automático, logrando un seguimiento de trayectoria preciso incluso ante variaciones del 900 % en la carga del robot.

Palabras clave: Robustez, Robótica, Control, Control híbrido neuro-PD, Redes neuronales

Robustness of neuro-PD hybrid control under uncertainties and disturbances

Abstract

This work presents the development and validation of a hybrid control system for a two-degree-of-freedom (2-DOF) robotic manipulator. The proposed scheme integrates a Multi-Layer Perceptron (MLP) Artificial Neural Network (ANN), designed to approximate the inverse dynamics for system linearization, with a Proportional-Derivative (PD) regulator to close the feedback loop. The robustness of the architecture is evaluated through stress tests involving parametric uncertainty in the distal link mass, Gaussian sensor noise, and external torque disturbances. The results, validated exclusively through simulation, demonstrate that the hybrid controller effectively mitigates the drift characteristic of purely machine learning-based models, achieving precise trajectory tracking even under 900 % variations in the robot's load.

Keywords: Robustness, Robotics, Control, Hybrid neuro-PD control, Neural networks

1. Introducción

El control de manipuladores de múltiples grados de libertad (GDL) es un desafío persistente debido a su dinámica no lineal y acoplada (esto último significa que el movimiento de una coordenada afecta dinámicamente a las otras). Tradicionalmente, se han empleado modelos analíticos de Euler-Lagrange (Craig, 2009) para implementar estrategias de

Control por Par Calculado (*Computed-Torque Control*, CTC). Sin embargo, la eficacia de estos métodos clásicos (Machado et al., 1993; Markiewicz, 1973) se ve comprometida en entornos reales debido a la incertidumbre paramétrica y las perturbaciones externas. Aunque el uso de Redes Neuronales Artificiales (ANN) permite aproximar la dinámica inversa sin un modelo previo, estas soluciones suelen presentar problemas de deriva (acumulación de error posicional) y falta de estabi-

*jmunoz2115@alumno.uned.es

Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0)

Correos electrónicos: jmunoz2115@alumno.uned.es (Juan Daniel Muñoz-Navarrete), msantos@ucm.es (Matilde Santos)

lidad en condiciones no vistas durante el entrenamiento (Lewis et al., 2020). Para superar estas limitaciones, este artículo propone un esquema de control neuro-híbrido. La propuesta integra un Perceptrón Multicapa (MLP) (Popescu et al., 2009) para la compensación activa de no linealidades y un regulador Proporcional-Derivativo (PD) sintonizado bajo el criterio de amortiguamiento crítico (Lewis et al., 2003) para asegurar la estabilidad del lazo cerrado.

A diferencia de las aproximaciones más recientes en la literatura, que proponen esquemas adaptativos (Sierra-García and Santos, 2021) o se enfocan en la sintonización de controladores para trayectorias nominales (Lussón-Cervantes et al., 2025), la principal contribución de este artículo es demostrar experimentalmente la robustez de un esquema neuro-híbrido frente a incertidumbres paramétricas severas. Mientras estudios actuales subrayan la vulnerabilidad y la falta de estabilidad de las redes neuronales puras ante condiciones no vistas durante el entrenamiento (Lewis et al., 2020), nuestra propuesta garantiza el seguimiento preciso y anula la deriva posicional incluso ante variaciones de carga del 900 % y perturbaciones impulsivas de torque. Esto se logra integrando un MLP para la compensación dinámica no lineal con un regulador PD sintonizado analíticamente al amortiguamiento crítico. Cabe destacar que la validación de esta propuesta se ha llevado a cabo en un entorno puramente simulado, quedando la implementación física como trabajo futuro. El resto del artículo se organiza de la siguiente manera: la Sección 2 revisa el estado del arte; la Sección 3 detalla la metodología y el modelado; la Sección 4 presenta el desarrollo experimental y los resultados obtenidos; y la Sección 5 resume las conclusiones y propone futuras líneas de investigación.

2. Estado del arte

La literatura en control robótico ha transitado desde modelos rígidos hacia aproximadores flexibles. El método de CTC se estableció como el estándar para lograr la linealización por realimentación, permitiendo tratar un sistema no lineal como un conjunto de sistemas lineales desacoplados (Sharkawy and Koustoumpardis, 2019; Spong et al., 2020). Sin embargo, la efectividad del CTC depende críticamente de la exactitud del modelo dinámico, específicamente de la precisión en el cálculo de las matrices de inercia y los vectores de fuerzas centrífugas y de Coriolis (Siciliano et al., 2009). Ante la dificultad de obtener modelos exactos, autores como Haykin impulsaron el uso de las ANN como aproximadores universales (Haykin, 1994). En esta línea, también se han propuesto neuro-controladores evolucionados genéticamente para aprender modelos cinemáticos de forma independiente a la morfología del robot, superando los óptimos locales asociados a los métodos clásicos de descenso de gradiente (H. et al., 2009). No obstante, críticas como las del autor Lewis en (Lewis et al., 2020) sobre la falta de robustez de las redes puras han motivado la aparición de esquemas híbridos. En este contexto, se ha demostrado que la combinación de redes neuronales adaptativas con reguladores Proporcional-Integral-Derivativo (PID) mejora significativamente la respuesta transitoria y la robustez del control frente a perturbaciones externas y variaciones drásticas de masa en sistemas no lineales (Sierra-García and Santos, 2021).

Investigaciones recientes (Lussón-Cervantes et al., 2025; Receanu, 2013) sugieren que el regulador PD no debe verse solo como un controlador de posición, sino como un mecanismo de compensación de errores de modelado. En este sentido, el análisis de Okubanjo (Okubanjo et al., 2017) sobre manipuladores de 2-GDL subraya que el diseño del regulador (ganancias proporcional y derivativa en caso del PD) que cierra el lazo de realimentación es clave para la integridad mecánica. Lewis (Lewis et al., 2003) formaliza esta idea demostrando que el amortiguamiento crítico es el estado óptimo para evitar sobreimpulsos en sistemas robóticos.

A diferencia de los estudios centrados en precisión nominal (Machado et al., 1993; Markiewicz, 1973), trabajos de autores como Nguyen (Nguyen-Tuong et al., 2008) y Spong (Spong et al., 2020) se orientan hacia la recuperación de la trayectoria tras perturbaciones externas y ruido sensorial. Este artículo se inscribe en esta última tendencia, profundizando en el comportamiento del sistema ante condiciones de estrés paramétrico extremo.

3. Metodología

La metodología propuesta integra el modelado dinámico analítico, el uso de redes neuronales artificiales para la aproximación de funciones y la teoría de control lineal.

3.1. Modelado dinámico del manipulador

Se considera un manipulador de dos grados de libertad (2-GDL) en un plano vertical, cuya configuración se ilustra en la Figura 1. Bajo la formulación de Euler-Lagrange, la dinámica se describe mediante:

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = \tau \quad (1)$$

Donde $M(q)$ es la matriz de inercia, $C(q, \dot{q})$ la matriz de fuerzas centrífugas/Coriolis y $G(q)$ el vector gravitatorio. Cabe destacar que, a diferencia de formulaciones clásicas como la de Craig (Craig, 2009), donde estos términos suelen agruparse en un único vector de fuerzas de velocidad $V(q, \dot{q})$, en este trabajo se ha optado por la representación matricial $C(q, \dot{q})\dot{q}$ derivada mediante los símbolos de Christoffel de primera especie (Siciliano et al., 2009). Aunque ambas formas son funcionalmente equivalentes, la estructura matricial permite satisfacer la propiedad de antisimetría de la matriz $(\dot{M}(q) - 2C(q, \dot{q}))$. Esta característica es fundamental en el análisis de estabilidad de Lyapunov, como se explica en (Spong et al., 2020).

Por otra parte, cabe mencionar también que en este trabajo se asume un modelo de masas puntuales en los extremos distales de cada eslabón, así como la ausencia total de fricción en las articulaciones y, además, se ha omitido la inercia rotacional de los motores.




Figura 1: Esquema de un robot de 2GDL en el plano vertical Craig (2009).

3.2. Arquitectura de la red neuronal y entrenamiento

Para evitar la dependencia de un modelo analítico exacto en tiempo real, se utiliza una Red Neuronal Artificial (ANN) de tipo Perceptrón Multicapa (MLP) (Popescu et al., 2009) para aproximar la dinámica inversa del sistema.

- **Arquitectura:** capa de entrada con 6 neuronas que corresponden a las tres variables cinemáticas para cada uno de los dos grados de libertad: posición (q_1, q_2), velocidad ($\dot{q}_1, \dot{q}_2$) y aceleración de referencia ($\ddot{q}_{ref1}, \ddot{q}_{ref2}$) de ambas articulaciones. A continuación, dispone de dos capas ocultas de 64 neuronas con activación ReLU (Nair and Hinton, 2010). Finalmente, la capa de salida consta de 2 neuronas que proporcionan los pares de fuerza compensatorios (τ_1, τ_2) que deben aplicarse a los motores de cada articulación.
- **Preprocesamiento:** los datos se han normalizado mediante Z-score para asegurar una distribución de media cero y varianza unitaria. La estandarización $z = (x - \mu)/\sigma$ es esencial para equilibrar la contribución de variables con diferentes escalas (posiciones vs. velocidades) y acelerar la convergencia del optimizador.

El conjunto de entrenamiento utilizado se ha creado a partir de 20000 muestras generadas aleatoriamente mediante el modelo dinámico nominal. Para la generación de este conjunto de datos, las variables cinemáticas se muestrearon siguiendo una distribución uniforme dentro de los siguientes rangos operativos: posiciones $q \in [-\pi, \pi]$ rad, velocidades $\dot{q} \in [-5, 5]$ rad/s, y aceleraciones $\ddot{q}_{ref} \in [-10, 10]$ rad/s². Para garantizar la reproducibilidad, se ha fijado una semilla aleatoria ($seed = 42$) en todos los códigos desarrollados. Para el entrenamiento, los hiperparámetros seleccionados se muestran en la Tabla 1.

Tabla 1: Hiperparámetros del entrenamiento del MLP.

Parámetro	Valor
Muestras de entrenamiento	20000
Tamaño de lote (<i>batch size</i>)	64
Optimizador	Adam
Tasa de aprendizaje (<i>learning rate</i>)	0,001
Función de pérdida	MSE
Épocas de entrenamiento	30
Semilla de reproducibilidad	42

Como se ve en la Tabla 1, el optimizador seleccionado es Adam, que ajusta dinámicamente la tasa de aprendizaje para mejorar la convergencia (Kingma and Ba, 2014). Tras 30 épocas se ha completado el entrenamiento de forma exitosa, ya que el error cuadrático medio (*Mean Squared Error, MSE*) decrece monótonamente hasta estabilizarse en un valor próximo a 0.

3.3. Estrategia de control por par calculado

El núcleo de la propuesta es el esquema de Control por Par Calculado (CTC) basado en el concepto de linealización por realimentación. La ley de control se define como:

$$\tau = \text{ANN}(q, \dot{q}, \ddot{q}_{ref}) \quad (2)$$

Al haber sido entrenada mediante dinámica inversa, la red neuronal aprende el mapeo complejo de las matrices de inercia (M), las fuerzas centrífugas/Coriolis (C) y la gravedad (G) sin requerir el cálculo explícito de sus expresiones analíticas. De esta forma, la red compensa activamente estos términos prediciendo e inyectando exactamente el par (τ) que anula la dinámica natural del robot ante una aceleración demandada. Al aplicar este par al manipulador real, el sistema físico se linealiza por realimentación, logrando que las articulaciones se desacoplen y se comporten idealmente como un sistema lineal de doble integrador ($\ddot{q} \approx \ddot{q}_{ref}$) (Spong et al., 2020). El regulador PD cierra el lazo de realimentación calculando la aceleración de referencia necesaria para corregir las desviaciones:

$$\ddot{q}_{ref} = \ddot{q}_d + K_d \dot{e} + K_p e \quad (3)$$

Este diseño permite que el PD actúe sobre una dinámica simplificada, donde su única función es estabilizar el error de seguimiento (Sharkawy and Koustoumpardis, 2019; Lussón-Cervantes et al., 2025; Nguyen-Tuong et al., 2008; Receanu, 2013).

3.4. Diseño del regulador: amortiguamiento crítico

Sustituyendo la ley del PD en la dinámica linealizada, se obtiene la ecuación característica del error en lazo cerrado:

$$\ddot{e} + K_d \dot{e} + K_p e = 0 \quad (4)$$

Aplicando la transformada de Laplace, y asumiendo condiciones iniciales nulas, la ecuación característica del sistema se expresa como $s^2 + K_d s + K_p = 0$. Al comparar esta expresión matemática con la forma canónica de un sistema de segundo orden, $s^2 + 2\zeta\omega_n s + \omega_n^2 = 0$, se deduce que la frecuencia natural no amortiguada es $\omega_n = \sqrt{K_p}$ y el término de amortiguamiento es $2\zeta\omega_n = K_d$. Despejando el coeficiente de amortiguamiento ζ , se obtiene la siguiente relación analítica:

$$\zeta = \frac{K_d}{2\sqrt{K_p}} \quad (5)$$

Para evitar oscilaciones transitorias y sobreimpulsos que podrían dañar la estructura mecánica, se seleccionan las ganancias bajo el criterio de amortiguamiento crítico ($\zeta = 1$) (Lewis et al., 2003; Sharkawy and Koustoumpardis, 2019). La incorporación de un regulador PID/PD en arquitecturas

neuronales es una herramienta clave para ajustar la respuesta transitoria global del sistema ante perturbaciones e incertidumbres (Sierra-García and Santos, 2021). A partir de la derivación analítica del coeficiente de amortiguamiento mostrada en la Ecuación (5), el espacio de diseño se reduce estrictamente a los pares de ganancias que garantizan el amortiguamiento crítico ($\zeta = 1$). Dentro de esta restricción matemática, se han fijado los valores $K_p = 50$ y $K_d = 14, 14$. Esta selección toma como punto de partida rangos operativos validados en la literatura para el control de manipuladores de características similares (Lussón-Cervantes et al., 2025). Sobre esta base, se ha realizado un ajuste fino para maximizar la rapidez de recuperación del sistema ante perturbaciones garantizando, al mismo tiempo, la ausencia total de sobreelongación mecánica transitoria (*overshoot*).

4. Experimentos y resultados

Para validar el esquema neuro-híbrido, se realizaron simulaciones en Python ($dt = 0,01$ s) sobre un sistema Ubuntu 24.04 con CPU i9 y GPU RTX 3060. Se diseñaron tres escenarios de 10 s para evaluar estabilidad, robustez y rechazo de perturbaciones.

4.1. Test de ablación: lazo abierto vs. lazo cerrado

Este experimento evalúa la necesidad del regulador PD. Al emplear únicamente la red neuronal ($K_p, K_d = 0$), el error de seguimiento diverge rápidamente. Sin embargo, como se ve en la Figura 2, al incorporar el PD con amortiguamiento crítico se tiene un seguimiento preciso, demostrando que el lazo cerrado es vital para corregir los errores de aproximación de la red. En términos cuantitativos, el esquema neuro-híbrido logra un seguimiento preciso con un RMSE de 0,0198 rad y 0,0495 rad para las articulaciones 1 y 2 respectivamente, manteniendo errores máximos muy acotados (0,0542 rad y 0,1339 rad). Por el contrario, las métricas para la red neuronal pura carecen de sentido numérico, ya que la ausencia de realimentación provoca que el error se acumule y diverja hacia el infinito.

4.2. Test de robustez ante incertidumbre paramétrica

Se analizó la respuesta ante incrementos de la masa del eslabón distal (m_2) hasta 10,0 kg (900 % sobre el valor nominal de entrenamiento, ya que la red se entrena para unos valores concretos de longitudes y masas del robot). Se compararon dos configuraciones, manteniendo siempre amortiguamiento crítico; en el caso del control agresivo se seleccionaron sus ganancias mediante prueba-error de modo que fueran superiores a las del control estándar (x4 en K_p en este caso). Con esto:

- **Control Estándar** ($K_p = 50, K_d = 14, 14$). El sistema presenta un desfase notable y pérdida de amplitud al delegar la corrección en un lazo de baja rigidez (Figura 3a).
- **Control Agresivo** ($K_p = 200, K_d = 28, 28$). Logra ceñirse mejor a la trayectoria al aumentar la rigidez virtual de las articulaciones (Figura 3b).

Al analizar los resultados se ve que el control agresivo introduce picos de error momentáneos ante cargas extremas debido a la violenta reacción inicial frente a la inercia, evidenciando un *trade-off* necesario entre precisión y preservación mecánica.

Para cuantificar de forma rigurosa este comportamiento, la Tabla 2 recoge las métricas de Error Cuadrático Medio (RMSE) y Error Máximo Absoluto para ambas configuraciones de control. Como se observa, el control agresivo reduce consistentemente el RMSE general, pero a costa de introducir picos de error transitorios notablemente superiores ante cargas extremas (10,0 kg).

Tabla 2: Análisis cuantitativo del error de seguimiento ante variaciones de masa.

Tipo de control	RMSE (rad)	Error Máximo (rad)
Estándar ($m = 1,0$ kg)	0,0494	0,1348
Estándar ($m = 3,0$ kg)	0,2917	0,6041
Estándar ($m = 5,0$ kg)	0,5705	1,0106
Estándar ($m = 10,0$ kg)	1,0596	1,4578
Agresivo ($m = 1,0$ kg)	0,0153	0,0436
Agresivo ($m = 3,0$ kg)	0,0861	0,1843
Agresivo ($m = 5,0$ kg)	0,1974	0,3808
Agresivo ($m = 10,0$ kg)	0,6647	1,9860

4.3. Test de estrés: ruido y perturbación externa

Se sometió al sistema a ruido blanco gaussiano en los sensores ($\sigma_{pos} = 0,2$ rad; $\sigma_{vel} = 0,05$ rad/s) y a un torque disruptivo de 40 Nm en la articulación 1 durante 0,5 s. Como se muestra en la Figura 4, el sistema absorbe el ruido y, tras la perturbación, recupera la trayectoria en menos de 1,0 s sin oscilaciones. Este comportamiento valida la elección del amortiguamiento crítico ($\zeta = 1$), asegurando una recuperación eficiente y una operación estable en entornos con alta incertidumbre sensorial.

5. Conclusiones y trabajo futuro

Este estudio evalúa en simulación la eficacia del control híbrido neuro-PD para sistemas no lineales, demostrando que la integración de una red neuronal para la compensación dinámica junto a un lazo PD bajo criterio de amortiguamiento crítico garantiza estabilidad y precisión en los entornos virtuales probados. El sistema exhibe cierto grado de robustez frente a perturbaciones externas y variaciones de carga de hasta el 900 %, mitigando la deriva característica de los modelos basados puramente en aprendizaje. Dado que el presente estudio se limita a un entorno de simulación, como trabajo futuro se plantea implementar esquemas adaptativos para el ajuste dinámico de ganancias, validar la escalabilidad del método en manipuladores con mayores grados de libertad y plataformas de hardware real, y realizar un análisis comparativo exhaustivo frente a estrategias de control clásico y avanzado (tales como PID o control difuso) para cuantificar de forma más precisa la mejora de rendimiento aportada por la arquitectura propuesta.





Figura 2: Comparativa de seguimiento de trayectoria mediante test de ablación: esquema Neuro-Híbrido (azul) frente a NN Pura (rojo). Las gráficas de la columna izquierda muestran el desempeño de las articulaciones 1 (superior) y 2 (inferior) bajo el control híbrido. Las gráficas de la derecha ilustran la divergencia de la NN Pura para las articulaciones 1 y 2.



(a) Test de robustez con control estándar ($K_p = 50$; $K_d = 14, 14$).

(b) Test de robustez con control agresivo ($K_p = 200$; $K_d = 28, 28$).

Figura 3: Test de robustez realizado sobre el robot. (a) Control estándar ($K_p = 50$; $K_d = 14, 14$). (b) Control agresivo ($K_p = 200$; $K_d = 28, 28$).




Figura 4: Evolución del error ante ruido en sensores y perturbación impulsiva de torque.

Referencias

- Craig, J. J., 2009. Introduction to robotics: mechanics and control, 3/E. Pearson Education India.
- H., J. A. M., de Lope, J., Santos, M., 2009. A method to learn the inverse kinematics of multi-link robots by evolving neuro-controllers. *Neurocomputing* 72 (13), 2806–2814, hybrid Learning Machines (HAIS 2007) / Recent Developments in Natural Computation (ICNC 2007).
URL: <https://www.sciencedirect.com/science/article/pii/S0925231209001209>
DOI: <https://doi.org/10.1016/j.neucom.2008.08.021>
- Haykin, S., 1994. Neural networks: a comprehensive foundation. Prentice hall PTR.
DOI: 10.1017/S0269888998214044
- Kingma, D. P., Ba, J., 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
DOI: 10.48550/arXiv.1412.6980
- Lewis, F., Jagannathan, S., Yesildirak, A., 2020. Neural network control of robot manipulators and non-linear systems. CRC press.
DOI: 10.1201/9781003062714
- Lewis, F. L., Dawson, D. M., Abdallah, C. T., 2003. Robot manipulator control: theory and practice. CRC Press.
DOI: 10.1201/9780203026953
- Lussón-Cervantes, A., Beltrán-Aguedo, R., Bernardez-Rubio, N., 2025. Control de un robot articulado de 2 gdl. *Revista UIS Ingenierías* 24 (3), 1–14.
DOI: 10.18273/revuin.v24n3-2025001
- Machado, J. T., de Carvalho, J. M., Galhano, A. M., 1993. Analysis of robot dynamics and compensation using classical and computed torque techniques. *IEEE Transactions on Education* 36 (4), 372–379.
DOI: 10.1109/13.241614
- Markiewicz, B., 1973. Analysis of the computed torque drive method and comparison with conventional position servo for a computer-controlled manipulator. Tech. rep.
- Nair, V., Hinton, G. E., 2010. Rectified linear units improve restricted boltzmann machines. In: *Proceedings of the 27th international conference on machine learning (ICML-10)*. pp. 807–814.
- Nguyen-Tuong, D., Seeger, M., Peters, J., 2008. Computed torque control with nonparametric regression models. In: *2008 American Control Conference*. IEEE, pp. 212–217.
DOI: 10.1109/ACC.2008.4586493
- Okubanjo, A., Oyetola, O., Osifeko, M., Olaluwoye, O., Alao, P., 2017. Modeling of 2-dof robot arm and control. *Futo J Series (FUTOJNLS)* 3 (2), 80–92.
- Popescu, M.-C., Balas, V., Perescu-Popescu, L., Mastorakis, N., 07 2009. Multilayer perceptron and neural networks. *WSEAS Transactions on Circuits and Systems* 8.
DOI: 10.5555/1639537.1639542
- Receanu, D., 2013. Modeling and simulation of the nonlinear computed torque control in simulink/matlab for an industrial robot. vol 10, 95–106.
DOI: 10.3970/SL.2013.010.095
- Sharkawy, A.-N., Koustoumpardis, P., 2019. Dynamics and computed-torque control of a 2-dof manipulator: Mathematical analysis. *International Journal of Advanced Science and Technology* 28 (12), 201–212.
- Siciliano, B., Sciavicco, L., Villani, L., Oriolo, G., 2009. Robotics: modelling, planning and control. Springer.
DOI: 10.1007/978-1-84628-642-1
- Sierra-García, J. E., Santos, M., 2021. Switched learning adaptive neuro-control strategy. *Neurocomputing* 452, 450–464.
URL: <https://www.sciencedirect.com/science/article/pii/S0925231220316507>
DOI: <https://doi.org/10.1016/j.neucom.2019.12.139>
- Spong, M. W., Hutchinson, S., Vidyasagar, M., 2020. Robot modeling and control. Vol. 2. Wiley New York.
DOI: 10.1109/MCS.2006.252815