

Control bio-inspirado para un actuador elástico por medio del algoritmo de aprendizaje por retroalimentación del error

Bio-inspired Control of an Elastic Actuator Using the Feedback Error Learning Scheme

Mario Rios-Mora¹, José González-Vargas²,
Juan C. Moreno³, José Luis Pons-Rovira⁴

Rios-Mora, M; González-Vargas, J; Moreno, J.C; Pons-Rovira, J.L. Control bio-inspirado para un actuador elástico por medio del algoritmo de aprendizaje por retroalimentación del error. *Tecnología en Marcha*. Edición especial. Movilidad Estudiantil 6, 2019. Pág 13-23

 <https://doi.org/10.18845/tm.v32i8.4560>



- 1 Estudiante ingeniería Mecatrónica. Instituto Tecnológico de Costa Rica. Área Académica de ingeniería Mecatrónica. Cartago Costa Rica. Correo electrónico: mriosm1992@gmail.com.
- 2 Doctor en ingeniería de sistemas médicos. Investigador. Departamento de Neurociencia Traslacional. Instituto Cajal. CSIC. Madrid. España. Correo electrónico: je.gonzalez@csic.es
- 3 Doctor en Ingeniería Industrial por la Universidad Politécnica de Madrid. Investigador. Departamento de Neurociencia Traslacional. Instituto Cajal. CSIC. Madrid. España. Correo electrónico: jc.moreno@csic.es
- 4 Doctor en física. Profesor investigador. Departamento de Neurociencia Traslacional. Instituto Cajal. CSIC. Madrid. España. Correo electrónico: jose.pons@csic.es



Palabras Clave

Actuadores elásticos; Control Adaptativo; Red Neuronal; Feedback Error Learning.

Resumen

El presente documento abarca la mejora del esquema de control de los actuadores de rigidez variable (VSA), presentes en la articulación de la rodilla de un robot bípedo llamado Binocchio, desarrollado por el grupo de Neuro-rehabilitación del Instituto Cajal. El diseño de dicho robot se basó en varias características biológicas presentes en los seres humanos como por ejemplo la visco-elasticidad de los músculos. Para controlar estos actuadores de manera robusta y eficiente no es suficiente el uso de estrategias de control clásico basados en modelos, debido a que estos métodos no son capaces de tomar en cuenta todas las no-linealidades intrínsecas del actuador debido a su estructura mecánica y a su naturaleza elástica. Por ello se adaptó un método bio-inspirado de control conocido como Feedback Error Learning (FEL) que utiliza una red neuronal para aprender el modelo inverso sin ningún conocimiento a priori de los parámetros del actuador. Seguidamente se procedió a realizar pruebas de control para validar su implementación. Finalmente, fue posible adaptar el FEL para el control de los VSA, lo que incidió en una mejora significativa en el rendimiento de los controladores de trayectoria. Pruebas de robustez y de estabilidad permitieron validar el uso del FEL como una alternativa viable para el control de los actuadores.

Keywords

Elastic Actuator; Adaptive Control; Neural Network; Feedback Error Learning.

Abstract

This document covers the improvement of the control scheme for variable stiffness actuators (VSA), present in the knee joint of a biped robot called Binocchio, developed by the Cajal Institute's Neuro-rehabilitation group. The design of this robot is based on several biological characteristics found in humans such as the visco-elasticity of the muscles. In order to control these actuators in a robust and efficient manner, it is not enough to use classic model-based control strategies, as they are not able to take into account all the intrinsic non-linearities of the actuator due to its mechanical structure and elastic nature. Therefore, a bio-inspired control method was adapted, known as Feedback Error Learning (FEL) it uses a neural network to learn the inverse model without any a priori knowledge of the parameters of the actuator. Subsequently, control tests were carried out to validate the new control strategy. Finally, it was possible to adapt the FEL for the control of the VSA, which had a significant improvement in the performance of the trajectory controller. Robustness and stability tests allowed to validate the use of FEL control as a viable alternative for the control of the actuators.

Introducción

Los robots biológicamente inspirados imitan la estructura y movimiento de los seres humanos y animales. Esto se traduce en consideraciones biomecánicas y antropométricas como cantidad de grados de libertad, rangos de movimiento, así como peso y dimensiones de las articulaciones. Del mismo modo los sistemas de actuación tienen una gran influencia en el comportamiento del robot, por lo que deben ser capaces de imitar el comportamiento dinámico de sus contrapartes biológicas.

Los actuadores eléctricos convencionales tienen un comportamiento rígido por lo que requieren de estrategias de control relativamente complejas para emular el comportamiento elástico de los sistemas de actuación biológicos [1]. La especialización bípeda de los seres humanos con sus adaptaciones morfo-funcionales, ha estimulado nuevos enfoques basados en el comportamiento elástico de sus articulaciones [2].

Considerando lo anterior se han desarrollado actuadores que pretenden emular la característica elástica de las articulaciones humanas [1]. El concepto básico radica en incluir un elemento elástico (generalmente un resorte) en serie con un actuador rígido. Dichos actuadores se denominan Series Elastic Actuators (SEA), cuando la rigidez de la articulación permanece constante (seleccionada en la fase de diseño), o Variable Stiffness Actuators (VSA) que permite la variación y el control de la rigidez de forma continua [1].

Dentro del proyecto Europeo H2R [3] se diseñó y construyó un robot humanoide biológicamente inspirado llamado Binocchio que considera principios biológicos clave por medio de actuadores basados en el concepto del MACCEPA. Este concepto describe un actuador elástico de rigidez variable [1], el cual pretende replicar algunas propiedades de las articulaciones humanas mediante la variación de la rigidez. Por ejemplo, almacenamiento y liberación de energía en los músculos, o una instantánea reacción flexible en el caso de producirse impactos.

Sin embargo, la naturaleza elástica y la estructura mecánica de los actuadores con rigidez variable los convierten, desde el punto de vista de control, en todo un reto. Debido a ello, los métodos convencionales de diseño de sistemas de control resultan entonces poco prácticos o insuficientes ya que el desarrollo de un modelo matemático de su dinámica es complejo al tener que considerar las no linealidades debidas a su estructura mecánica y elasticidad. Por otro lado, realizar aproximaciones o simplificaciones no es realmente deseable ya que esto supone un compromiso entre la simplicidad del modelo y la exactitud a la hora de describir el comportamiento del sistema.

Por ello, pese a sus ventajas biomecánicas, el uso de los actuadores del Binocchio requiere de estrategias de control que sean capaces de adaptarse y aprender las no linealidades del actuador y a cambios en su dinámica (p.ej. al variar la rigidez del actuador). De esta forma se plantea el uso del algoritmo de aprendizaje por retroalimentación del error, o Feedback Error Learning (FEL), concebido originalmente como un modelo que describe la forma en que el sistema nervioso central adquiere modelos internos del cuerpo humano [4]. En este esquema control, se utiliza una red neuronal que aprende el modelo inverso de la dinámica del sistema controlado. La principal ventaja de esta estrategia radica en que no se requiere de ningún conocimiento a priori de un modelo detallado de la dinámica de la planta.

Feedback Error Learning (FEL)

El FEL es un método de control adaptativo en el que se utiliza una red neuronal que aprende la dinámica inversa de la planta utilizando la retroalimentación de la señal de control en lazo cerrado. Como se puede apreciar en la figura 1 el Feedback Error Learning (FEL) integra control por retroalimentación (Feedback Control) con control por pre-alimentación (Feedforward Control).

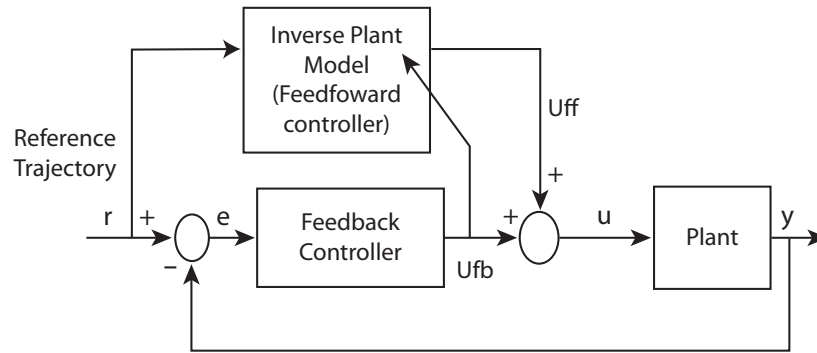


Figura 1. Esquema de control FEL [5].

Un modelo inverso predice la señal de control necesaria para poder llevar el estado actual de la planta al siguiente [6]. Una red neuronal se utiliza como modelo inverso y se entrena por medio de la señal de control proporcionada por el control de lazo cerrado. La señal de control total (U) se obtiene al sumar las contribuciones de dicho controlador (Ufb) y de la red neuronal (Uff).

La salida del control por retroalimentación es en esencia una medida del error existente entre la dinámica de la planta y la dinámica inversa calculada por la red neuronal, de esta forma el sistema hace uso del error existente entre la salida deseada y la actual para guiar el entrenamiento [7]. Una vez finalizado el aprendizaje, si el modelo inverso es preciso la señal Uff será capaz por sí sola de controlar la planta, de manera que $Ufb \approx 0$ [6]; [8].

Red Neuronal: configuración y entrenamiento.

Las capacidades universales de aproximación del perceptrón multicapa (MLP) lo hacen una opción muy popular a la hora de modelar sistemas no lineales y para implementar controladores no lineales. Por lo tanto, se hará uso de un MLP compuesto por 3 capas (una de entrada, una oculta y una de salida). La capa oculta actúa como un extractor de características y, por lo tanto, debe contener suficientes neuronas para extraer las principales características de los datos. El número óptimo de neuronas ocultas es difícil de determinar y depende de cada aplicación. En nuestro caso 9 neuronas ocultas son suficientes para aprender el modelo inverso. Adicionalmente algunas consideraciones importantes para el correcto funcionamiento de la red neuronal utilizada en el controlador FEL son:

- Inicializar los pesos sinápticos con valores pequeños (tanto positivos como negativos) siguiendo la regla estipulada en la ecuación 1 :

$$\frac{-1}{\sqrt{n}} < w < \frac{1}{\sqrt{n}} \quad (1)$$

Donde “w” corresponde al valor del peso y “n” a la cantidad de entradas. Esto se conoce como aprendizaje uniforme y permite que todos los pesos converjan prácticamente al mismo tiempo [9].

- Los valores de las entradas deben ser re-escalados de modo que varíen en un rango de ± 1 .
- La función de activación en las neuronas ocultas y de la neurona de salida corresponde a
- la función tangente hiperbólica y función identidad respectivamente.

- El valor de los parámetros de aprendizaje (Learning Rate y momentum) se establecen de manera heurística y por lo general tiene valores dentro del rango [0,1] [9].

Por otro lado, debido a que se trata de una aplicación de control se procede a un entrenamiento “online” o secuencial de manera a aprender y adaptarse a condiciones cambiantes. Dicho entrenamiento utiliza el algoritmo de propagación hacia atrás del error (backpropagation of error) para realizar el ajuste progresivo de los pesos sinápticos. De esta forma la función de error que describe el rendimiento de la red neuronal es:

$$E = \frac{(U_{ff} - U_o)^2}{2} \quad (2)$$

Donde U_o representa una señal de control Feedforward ideal basada en un modelo inverso y U_{ff} representa la salida de la red neuronal que es función de las entradas “ x ” de la red y los pesos sinápticos “ w ”:

$$U_{ff} = p^{-1}(x, w) \quad (3)$$

Donde “ p^{-1} ” representa el modelo inverso de la planta que se desea controlar. El método de propagación hacia atrás del error (ajusta el valor de los pesos en la dirección del gradiente de $E(w)$ es decir que se debe derivar parcialmente (2) con respecto al valor de los pesos sinápticos tal que:

$$\frac{\partial E}{\partial w} = \frac{\partial U_{ff}}{\partial w} (U_{ff} - U_o) \quad (4)$$

Sin embargo, no es posible calcular el error ya que U_o se desconoce, no obstante, es posible utilizar la señal de control por retroalimentación “ U_{fb} ” como señal de error (Eciolaza *et al.*, 2013) ya que:

$$U_o = U_{ff} + U_{fb}$$

$$-U_{fb} = U_{ff} - U_o \quad (5)$$

Se tiene entonces reemplazando (5) en (4):

$$\frac{\partial E}{\partial w} = -\frac{\partial U_{ff}}{\partial w} * U_{fb} \quad (6)$$

Donde el primer término del lado derecho dependerá de la función de activación utilizada.

Donde el primer término del lado derecho dependerá de la función de activación utilizada.

Controlador por retroalimentación

Se trata de un controlador PID clásico, las constantes se obtuvieron mediante el método Nichols-Ziegler, seguido por un ajuste progresivo hasta obtener un comportamiento aceptable. Se buscó evitar ganancias altas para evitar oscilaciones en caso de perturbaciones o durante la etapa de aprendizaje. Adicionalmente se calibró una compensación de gravedad que contrarreste el peso de la articulación.

Control de trayectoria

En la figura 2 se puede apreciar la diferencia entre el control de trayectoria por PID y FEL para una trayectoria senoidal de 10° de amplitud y 0.5 Hz de frecuencia. El PID no puede por sí solo ejecutar una trayectoria satisfactoria, se puede observar un claro error (valor RMS promedio de 7.06°) y un retraso (0.36 s) entre la trayectoria deseada y obtenida. Por otro lado, luego del periodo de entrenamiento (100 s aproximadamente), el FEL permite obtener un control de trayectoria donde tanto el error (valor RMS promedio de 0.96°) como el retraso (0.02s) se han reducido, mejorando el rendimiento notoriamente (reducción del error y el retraso con respecto al PID en un 86.40% y 94.44% respectivamente).

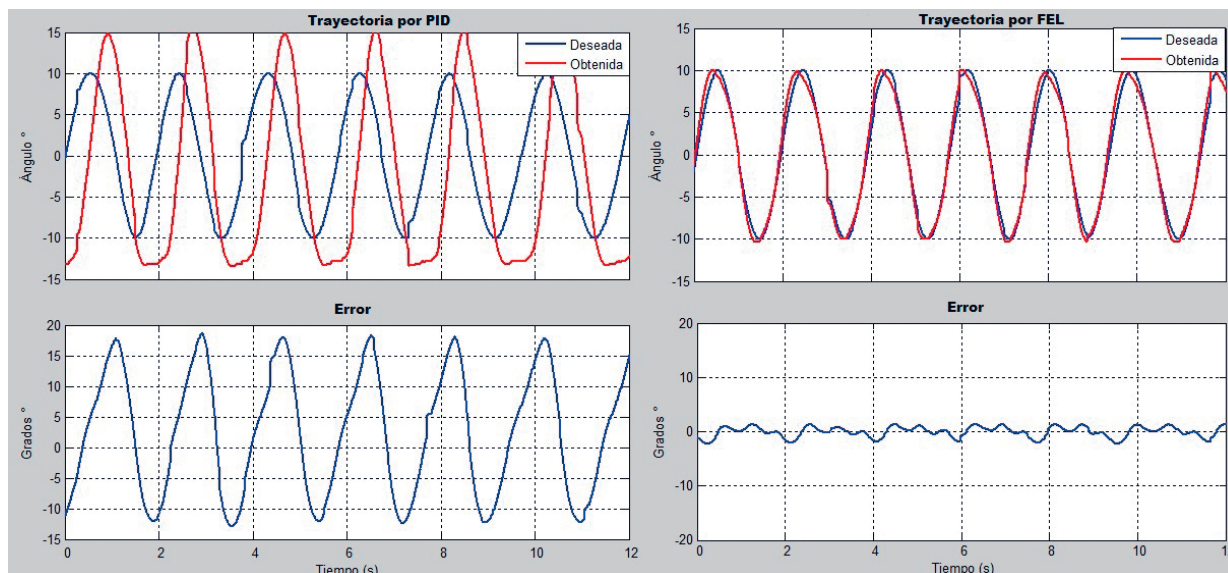


Figura 2. Comparativa entre control de trayectoria por PID y FEL (Elaboración propia).

Por otro lado, en la figura 3 se puede corroborar como efectivamente la señal de control proveniente de la red neuronal llega, después de un determinado tiempo (100 s), a controlar completamente a actuador, reduciendo el aporte de la señal de control del PID al mínimo.




Figura 3. Variación de señales de control.

Pruebas de rendimiento.

- Resistencia a perturbación estática

Se agregó una carga de 3 kg para modificar el peso y la distribución de masas y por ende la dinámica de la articulación donde se ubica el actuador. Como se puede ver en la figura 4 el PID es predeciblemente incapaz de compensar por la carga adicional, del mismo modo no solo persiste tanto el error como el desfase vistos anteriormente, sino que estos han incrementado (error RMS promedio de 8.74° y retraso de 0.56 s). Por otro lado, el FEL luego de una etapa inicial donde la red neuronal se adapta a las nuevas condiciones es capaz de reducir tanto el error (valor RMS promedio de 1.41°) como el desfase (0.02 s), manteniendo el rendimiento visto anteriormente (reducción del error y el retraso con respecto al PID en un 88.76% y 96.43% respectivamente).

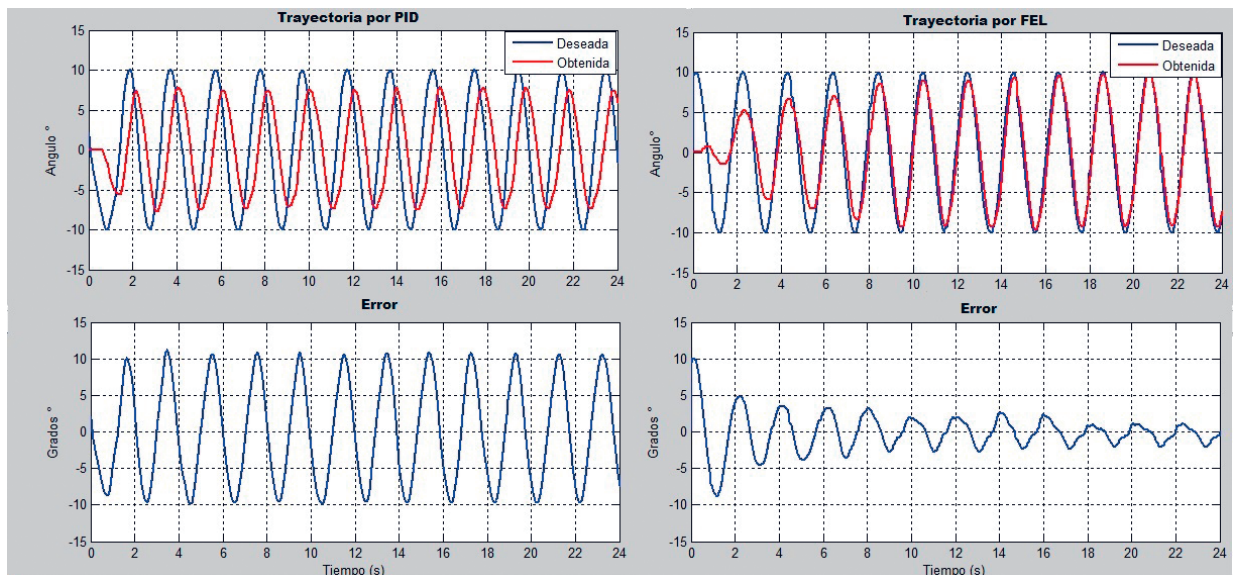


Figura 4. Comparativa entre control de trayectoria por PID y FEL ante perturbación estática.

Cabe mencionar que la red neuronal se encontraba previamente entrenada por lo que la adaptación a las nuevas condiciones de operación del actuador se da relativamente más rápido (16 s aproximadamente), de esta forma pese a que el modelo precargado no parece generalizar de forma a compensar la nueva dinámica, si contempla buena parte de la dinámica del actuador por lo que solo se debe de realizar algunos ajustes en los pesos sinápticos para retomar el control.

- Resistencia ante perturbaciones transitorias.

En la figura 5 se puede apreciar el comportamiento de las diferentes señales luego de realizar algunas perturbaciones (realizadas manualmente) en diferentes puntos marcados con flechas rojas que se traducen en picos en la señal de error y de PID. Cabe mencionar que en dichos puntos no se nota ningún cambio significativo en la señal proveniente de la red neuronal. Esto es de esperar, ya que ante dichas perturbaciones el control por PID se hace necesario ya que la red neuronal una vez entrenada, no tiene manera de saber que ocurre en la salida según la topología con la que se está trabajando (la red neuronal funciona como un control feedforward).




Figura 5. Comportamiento del sistema ante perturbaciones transitorias.

Esto implica que la red neuronal mantiene el control de la trayectoria deseada mientras el PID aumenta su aporte a la señal de control de manera a corregir el error, de esta forma una vez corregido el error, el PID vuelve a reducir su contribución al mínimo. Debido a lo anterior es primordial que el control por retroalimentación sea capaz de estabilizar la planta ante perturbaciones ya que de lo contrario la red neuronal no podrá hacer nada para contrarrestarlas, de manera que un mejor control por retroalimentación no solo incidirá en un entrenamiento más rápido y en un mejor modelo inverso sino también en una mejor respuesta ante perturbaciones.

- **Resistencia ante ruido en señal de sensores.**

Se quiso comprobar la resistencia del control ante posibles interferencias en la lectura del valor del ángulo en la articulación. Se simuló dicha situación agregando un generador de ruido gaussiano y sumando su salida a la lectura del sensor. Observando la figura 6, se puede apreciar que, a nivel de comportamiento, el control por PID y FEL no tiene mayor diferencia con respecto al que se ha visto hasta el momento ya que como se puede observar el PID sigue teniendo un claro retraso (0.42s) y error (valor RMS promedio de 13.73°) mientras que el control por FEL permite reducirlos visiblemente (error RMS promedio de 2.14° y retraso de 0.02s | que corresponde a una reducción del 84.19 % y 95.24% respectivamente). Lo realmente importante en este punto es que, a pesar de la señal ruidosa, la red neuronal es capaz de obtener un modelo inverso capaz de mejorar el rendimiento. Esto se debe al entrenamiento secuencial ya que errores, omisiones y redundancias pueden ser corregidos o simplemente ignorados más fácilmente [7].

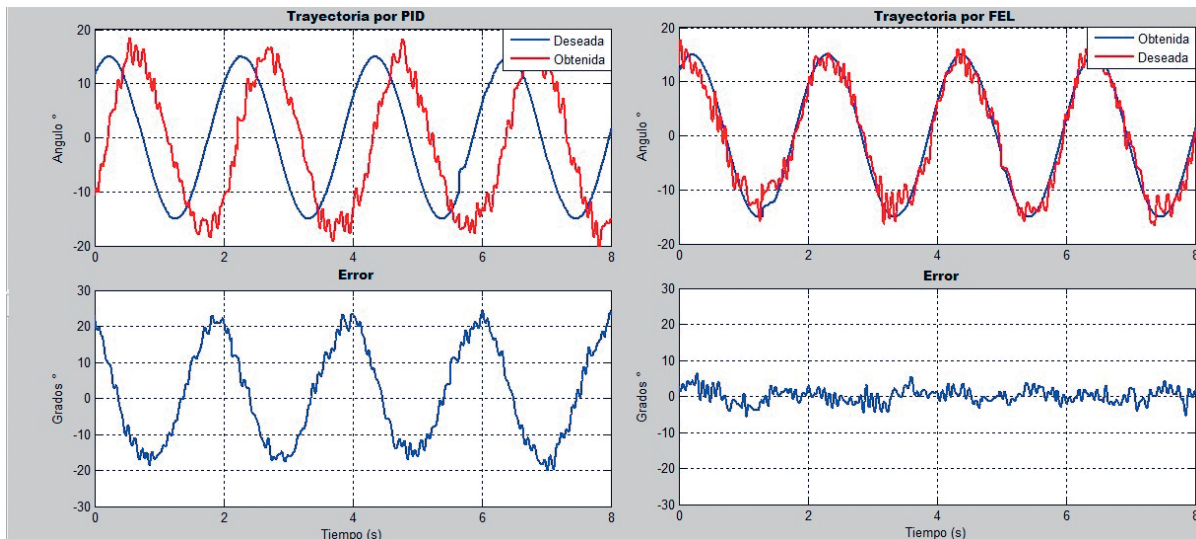


Figura 6. Comparativa de control de trayectoria entre PID y FEL con ruido en los sensores.

- **Variación de la amplitud**

Se procedió a variar la amplitud de la trayectoria de forma aleatoria cada 5 segundos de manera que pudiera tener cualquier valor en un rango de 5 a 15 °. Nuevamente como se puede ver en la figura 7, el comportamiento del control por PID y FEL no tiene mayor diferencia con respecto al visto hasta el momento ya que como se puede observar el PID sigue teniendo un claro retraso (0.56s) y error (valor RMS promedio de 11.56°) mientras que el control por FEL permite reducirlos visiblemente (error RMS promedio de 1.35° y retraso de 0.02 s lo que corresponde a una reducción del 88.32 % y 96.43% respectivamente). Por otro lado se debe mencionar que la red neuronal se encontraba previamente entrenada por lo que se puede intuir que el modelo precargado le permite al FEL generalizar a otras amplitudes (pese a un leve aumento de la señal de error) siempre que se conserve la misma frecuencia de operación.

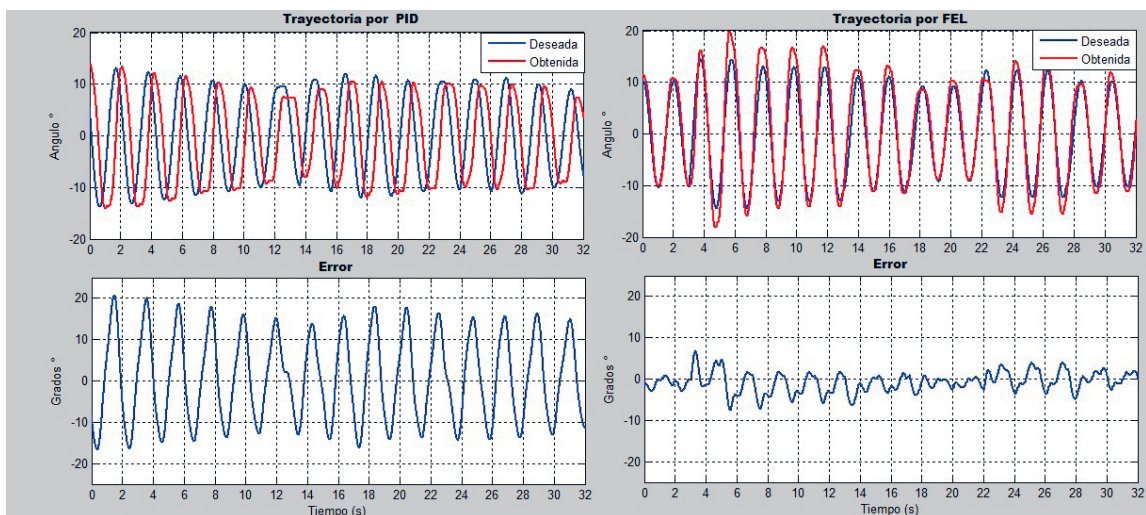


Figura 7. Comparativa de control de trayectoria con amplitud cambiante entre PID y FEL.

Limitaciones.

El valor de los parámetros de la red (Learning Rate y Momentum) son sensibles a la frecuencia de la trayectoria. De esta forma para determinados valores de dichos parámetros el valor de los pesos sinápticos no converge y permanecen fluctuando. Es posible evitar esto por medio de un ajuste progresivo, sin embargo, el ajuste debe realizarse mediante prueba y error.

Por otro lado, si el entrenamiento se prolonga más allá del punto donde el valor RMS del error se estabiliza, el rendimiento de la red se deteriora debido a un fenómeno de sobreajuste. Para evitar esto se debe detener el entrenamiento al detectar la convergencia de los pesos y/o nivel a aprendizaje.

El tiempo de aprendizaje depende entre otras cosas de la frecuencia de la trayectoria (o duración de cada ciclo) y del rendimiento del control por retroalimentación utilizado. Esto debido a que la red neuronal no puede aprender en menos tiempo que el dictado por la duración de un ciclo de la trayectoria, además si el control por retroalimentación no es lo suficientemente bueno se requiere de más tiempo para obtener un modelo inverso adecuado.

Finalmente, el control por retroalimentación debe asegurar un funcionamiento estable en cualquiera de las condiciones de operación del actuador que se puedan presentar (diferentes frecuencias, amplitudes, perturbaciones estáticas y/o transitorias) de lo contrario la red neuronal no será capaz de aprender y/o adaptar la dinámica inversa y/o de proveer una señal de control adecuada.

Conclusiones

Se adaptó el algoritmo del Feedback Error Learning para el control del actuador de rigidez variable. El FEL supone una clara mejora en cuanto a rendimiento ya que reduce el error y el desfase existentes en el esquema de control original (PID clásico). Se realizaron pruebas de robustez y estabilidad para el controlador FEL. Dichas pruebas consisten en pruebas de resistencia a perturbaciones (estáticas y transitorias), ruido en la señal de los sensores y variación aleatoria de la amplitud de la trayectoria. El FEL tiene en todos los casos un mejor rendimiento que su contraparte original por lo que supone una estrategia de control viable para el control de actuadores de rigidez variable.

Trabajo Futuro

Investigar e implementar algoritmos para adaptar los parámetros de la red neuronal a variaciones de frecuencia, ya que como se mencionó anteriormente estos son sensibles a la frecuencia de operación. Una alternativa puede ser el ajuste progresivo de dichos parámetros por métodos iterativos que tomen en consideración la frecuencia de operación y/o nivel de aprendizaje de la red neuronal. Por otro lado, se debe asegurar el funcionamiento del FEL para el control de trayectoria de dos o más articulaciones operando al mismo tiempo, ya que la dinámica del actuador depende también de su posición relativa con respecto a las demás articulaciones. Del mismo modo se debe también verificar que la red neuronal sea capaz de adaptarse a cambios de rigidez del actuador, debido a que esto conlleva a un cambio de la dinámica. Se debe valorar otros tipos de control por retroalimentación para realizar el entrenamiento, de manera que considere mejor la dinámica del actuador, de esta forma la red neuronal será capaz de aprender de manera más completa y rápida el modelo inverso del actuador. Finalmente, se deben probar nuevas topologías de control y otros tipos de redes neuronales con tal de explorar nuevas alternativas que permitan aumentar la versatilidad del control.

Referencias

- [1] B. Vanderborght et al., «Variable impedance actuators: A review», *Robot. Auton. Syst.*, vol. 61, n.o 12, pp. 1601–1614, 2013.
- [2] H. Witte, H. Hoffmann, R. Hackert, C. Schilling, M. S. Fischer, y H. Preuschoft, «Biomimetic robotics should be based on functional morphology», *J. Anat.*, vol. 204, n.o 5, pp. 331–342, 2004.
- [3]. H2R: Integrative Approach For The Emergence Of Human-Like Locomotion. Retrieved from <http://www.h2rproject.eu/>. 2016.
- [4] M. Kawato, «Internal models for motor control and trajectory planning», *Curr. Opin. Neurobiol.*, vol. 9, n.o 6, pp. 718–727, 1999.
- [5] L. Eciolaza, T. Taniguchi, M. Sugeno, D. Filev, y Y. Wang, «Piecewise bilinear models for feedback error learning: On-line feedforward controller design», en 2013 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), 2013, pp. 1–8.
- [6] N. Gopalan, «Feedback Error Learning for Gait Acquisition», 2012.
- [7] S. Sharma, V. Kumar, y R. Kumar, «Supervised online adaptive control of inverted pendulum system using adaline artificial neural network with varying system parameters and external disturbance», *Int. J. Intell. Syst. Appl.*, vol. 4, n.o 8, p. 53, 2012.
- [8] Y. Koike, J. Gonzalez, J. Gomez, y W. Yu, «Implementing feedback error learning for FES control», en 2011 4th International Conference on Biomedical Engineering and Informatics (BMEI), 2011, vol. 3, pp. 1324–1328.
- [9] S. Marsland, *Machine learning: an algorithmic perspective*. Chapman and Hall/CRC, 2014.