

Regresión de la Cinemática de un Brazo Robótico Blando mediante Procesos Gaussianos Aproximados

Relaño, C.^{a,*}, Muñoz, J.^a, Monje, C.A.^a

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

To cite this article: Relaño, C., Muñoz, J., Monje, C.A. 2023. Regression of the Kinematics of a Soft Robotic Arm by Approximate Gaussian Processes. XLIV Jornadas de Automática, 471-476. <https://doi.org/10.17979/spudc.9788497498609.471>

Resumen

La identificación adecuada del sistema es esencial para lograr un buen rendimiento de las tareas y una buena interacción con el entorno mediante la robótica blanda. Aunque se han utilizado técnicas analíticas tradicionales basadas en modelos, a veces resultan insuficientes. Los métodos basados en datos son una alternativa prometedora. Sin embargo, su uso en robótica blanda ha sido limitado y poco explorado. Este trabajo explora el uso de procesos Gaussianos para identificar la cinemática directa e inversa de un brazo robótico blando de dos grados de libertad accionado por tres tendones.

Palabras clave: Robótica blanda, Brazo robótico blando, Procesos Gaussianos, Aprendizaje automático, Identificación de robots blandos

Regression of the Kinematics of a Soft Robotic Arm using Approximate Gaussian Process

Abstract

Proper system identification is essential to achieve good task performance and environmental interaction using soft robotics. While traditional model-based analytical techniques have been used, they are sometimes insufficient. Data-driven methods are a promising alternative. However, their use in soft robotics has been limited and little explored. This work addresses the use of Gaussian processes to identify the direct and inverse kinematics of a two-degree-of-freedom soft robotic arm driven by three tendons.

Keywords: Soft robots, Soft robotic arm, Gaussian processes, Machine learning, Soft robot identification

1. Introducción

La robótica blanda es un área de investigación centrada en el uso de nuevos materiales inspirados en organismos biológicos; estas características aportan la flexibilidad y adaptabilidad necesarias para operar en espacios o situaciones poco accesibles para otros robots. Por este motivo, está adquiriendo cada vez más importancia y reconocimiento debido a sus posibilidades en comparación con los robots tradicionales de eslabones rígidos, motores y engranajes. Algunos ejemplos que se pueden encontrar de robots blandos basados en biomimética son el robot blando tipo pulpo de (Laschi and Cianchetti, 2014) o el pez robótico blando fabricado con actuadores de elastómero dieléctrico de (Shintake et al., 2018). Además, esta área de

la robótica está en constante expansión, y surgen nuevos materiales o procesos que permiten la creación de nuevos robots blandos, como se ve en la revisión de (Cho et al., 2009).

Entre sus principales ventajas se encuentran mayores grados de libertad, modularidad y escalabilidad, y diseños que permiten reconfiguración y soluciones a los retos actuales de la robótica (Lee et al., 2017). Sin embargo, el uso de materiales blandos y deformables también crea dificultades. En robótica blanda, no es fácil obtener una fórmula para la cinemática y el control debido a la naturaleza inherente de los materiales, ya que se deforman o flexionan de forma no lineal. Estas dificultades provocan inicialmente que la precisión y fiabilidad de estos robots sea inferior a la de sus homólogos rígidos, ya que la de-

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

formación y flexión que se produce en estos enlaces suele ser despreciable.

La no linealidad del sistema provoca principalmente estas desventajas debido a sus propiedades físicas. Para superar este problema, se tiende a utilizar suposiciones y simplificaciones para linealizar el sistema y poder controlarlo más fácilmente. Sin embargo, estas suposiciones y simplificaciones a veces implican una abstracción matemática significativa del modelo real, perdiendo información importante. Esto complica la identificación del sistema para obtener un modelo matemático del mismo, que desempeña un papel vital en la optimización, el control, el diagnóstico de procesos y la predicción y simulación de escenarios del mundo real.

De este problema surge la necesidad de utilizar metodologías capaces de proporcionar una cinemática precisa y controlar estos sistemas complejos.

1.1. Identificación

La identificación en robótica implica modelar la cinemática directa, cinemática inversa o dinámica del robot, dependiendo del problema específico a resolver. Este trabajo se enfoca en la solución de la cinemática directa e inversa, que determina la posición final del extremo del robot y las entradas necesarias para lograr una posición dada, respectivamente.

Sin embargo, la no linealidad de los sistemas robóticos blandos impide el uso de la metodología Denavit Hartenberg (DH) comúnmente utilizada en robótica convencional. Por lo tanto, se utilizan otras técnicas para resolver este problema.

Las técnicas basadas en aprendizaje automático han demostrado tener un excelente rendimiento en comparación con otras metodologías. En un estudio particular (Zhou et al., 2019), se utilizó una red neuronal de dos capas ocultas para la identificación del sistema en un robot de silicona elástica controlado por cuatro cables, logrando superar el modelado por elementos finitos.

Hay diversas técnicas de aprendizaje automático para identificar y controlar actuadores y sensores blandos (Relaño et al., 2023). El enfoque de este trabajo es obtener el modelo cinemático de un brazo robótico blando utilizando procesos Gaussianos.

1.2. Procesos Gaussianos

Los procesos Gaussianos (PG) son un tipo de proceso estocástico que consiste en una colección de variables aleatorias indexadas en el tiempo o el espacio. Es un algoritmo poderoso tanto para la regresión como para la clasificación, y se ha utilizado cada vez más en la modelación de sistemas dinámicos debido a sus propiedades beneficiosas, como la compensación sesgo-varianza y la fuerte conexión con las matemáticas bayesianas (Beckers, 2021). La regresión de procesos Gaussianos es una metodología estadística que utiliza procesos Gaussianos como modelos a priori para las funciones de regresión que se ajustan a los datos observados. Una de las mayores ventajas prácticas de los procesos Gaussianos es que pueden ofrecer una estimación fiable de su propia incertidumbre. En el aprendizaje automático, los procesos Gaussianos se utilizan para aprender mapeos de entrada-salida a partir de una serie de salidas, que es una forma específica de un problema de identificación de sistemas (Muñoz et al., 2023; Hewing et al., 2019).

A diferencia de otras técnicas de aprendizaje automático, como las redes neuronales, los procesos Gaussianos resultan más eficaces para descubrir la cinemática oculta subyacente del robot blando, ya que no requieren un conocimiento previo de la estructura de los datos. Por ejemplo, las redes neuronales necesitan determinar el número de capas ocultas, las neuronas por capa y las funciones de activación para poder funcionar adecuadamente.

Este trabajo se centrará en los Procesos Gaussianos Aproximados (PGA) son una clase de algoritmos cuyo objetivo es hacer más manejable el modelado de PG para grandes conjuntos de datos y espacios de entrada de alta dimensión. La creciente cantidad de datos puede hacer que los modelos de procesos Gaussianos sean computacionalmente costosos, lo que los hace inadecuados para muchas aplicaciones del mundo real. Para solucionar este problema, se utilizan métodos de PGA, que aproximan la distribución posterior del procesos Gaussianos mediante un modelo más simple y computacionalmente eficiente.

El resto del documento se organiza de la siguiente manera. En la Sección 2 se presenta la descripción del robot blando. Además, se detalla brevemente el funcionamiento, el desacople de la articulación blanda y la obtención de los datos. La Sección 3 introduce la descripción de la identificación mediante procesos Gaussianos aproximados. Los resultados realizados con la plataforma robótica se describen en la Sección 4, donde se analiza el comportamiento de la robot blando tanto en su cinemática directa como inversa, frente a diferentes entradas y salidas de pitch y yaw. Además se discuten los resultados obtenidos en ambos casos. Finalmente, la Sección 5 concluye destacando los principales logros de la investigación y trabajos futuros.

2. Material y método

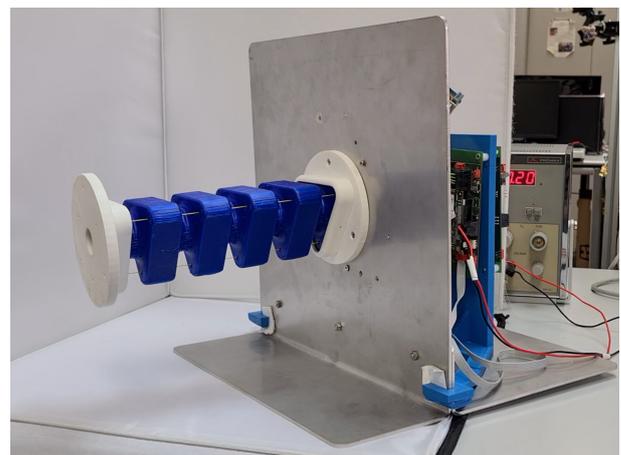


Figura 1: Brazo robótico blando

El trabajo estará enfocado en crear modelos de cinemática directa e inversa para un brazo robótico blando de dos grados de libertad (DoF) desarrollado por el RoboticsLab de la Universidad Carlos III de Madrid (Nagua et al., 2021; Relaño et al., 2022).

El brazo robótico blando tiene forma de prisma triangular con secciones cilíndricas construido con NinjaFlex, un TPU flexible impreso en 3D, Figura 1. El sistema cuenta con dos grados

de libertad controlados por tres motores Maxon EC-max 22 que enrollan y desenrollan los tendones fijados al extremo libre del brazo. Los cambios en la longitud del tendón causan flexión en el cuerpo blando, lo que altera la posición y orientación del efector final. Para obtener datos de orientación del efector final, se utiliza un IMU colocado en la punta del brazo.

En el método de desacoplamiento, se asume que, al doblarse el cuerpo blando, se producirá una curvatura constante, por lo que se podrá usar la relación $L_1 + L_2 + L_3 = 0$, donde L_i se refiere a la longitud del i -ésimo tendón. Al resolver este sistema de ecuaciones se obtienen las longitudes de los tendones resultantes como función de α y β (los ángulos de pitch y yaw, respectivamente), como se muestra en las ecuaciones 1, 2 y 3. La metodología de desacoplamiento se describe con más detalle en (Relaño et al., 2022).

$$L_1 = \frac{\alpha}{1,5} \quad (1)$$

$$L_2 = \frac{\beta}{1,732} - \frac{\alpha}{3} \quad (2)$$

$$L_3 = -\frac{\beta}{1,732} - \frac{\alpha}{3} \quad (3)$$

La longitud de los tendones se convierte en posición angular usando la fórmula del arco de una circunferencia, $L_i = \theta_i \cdot r$, donde θ_i es la posición angular del i -ésimo motor y r es el radio del torno en el que se enrolla el tendón.

Se ha proporcionado una descripción del brazo robótico blando y cómo la actuación de los motores se relaciona con las salidas de la orientación del extremo del brazo. Para desarrollar la cinemática directa, se creará una base de datos recopilando datos con los ángulos de los motores como parámetros de entrada del sistema y los ángulos de pitch y yaw como salida. Esta misma base de datos se puede utilizar para la identificación de la cinemática inversa invirtiendo las entradas y salidas. El procedimiento para obtener los datos implica variar los valores de α y β en 10 y enviar los valores θ_i al sistema para ver a qué ángulos de pitch y yaw corresponden las salidas.

3. Identificación usando procesos Gaussianos

Los procesos Gaussianos suelen ser utilizados para problemas de regresión con una única salida y . Sin embargo, en este caso, se requiere una regresión para la cinemática directa e inversa del brazo robótico blando, lo que implica dos y tres salidas, respectivamente. Para abordar este problema, se utilizará un modelo de regresión multitarea desarrollado por (Bonilla et al., 2007). Este modelo aprende una función de covarianza compartida sobre características dependientes de la entrada y una matriz de covarianza de "forma libre" sobre las tareas. Este enfoque permite una buena flexibilidad para modelar las dependencias entre tareas, al mismo tiempo que evita la necesidad de grandes cantidades de datos para el entrenamiento.

Para la PGA se elige el kernel cuadrático racional (RQ) entre las entradas x_1 y x_2 :

$$k_{RQ}(x_1, x_2) = \left(1 + \frac{1}{2\gamma}(x_1 - x_2)^T \Theta^{-2}(x_1 - x_2)\right)^{-\gamma}$$

En la ecuación anterior, Θ es un parámetro que escala la longitud y γ es un parámetro de ponderación relativa cuadrática racional. Ambos parámetros se ajustan durante el entrenamiento del modelo mediante la minimización de la probabilidad marginal utilizando el optimizador Adam. Además, tanto las entradas como las salidas se normalizan para tener media cero y varianza unitaria.

Para poder trabajar con múltiples salidas en el modelo PGA, se utilizará el Modelo Lineal de Coregionalización (LMC). El LMC es una técnica estadística para modelar sistemas con múltiples salidas que están relacionadas con un conjunto común de entradas, pero con diferentes relaciones. Es una generalización del modelo de regresión lineal estándar utilizado para sistemas con una sola salida. El LMC asume que las salidas son combinaciones lineales de un conjunto de funciones base $\mathbf{g}(\cdot) = [g^{(1)}(\cdot), \dots, g^{(Q)}(\cdot)]$, que son funciones de las entradas, y un conjunto de coeficientes a específicos para cada salida. Estos coeficientes se asumen como variables aleatorias relacionadas entre sí a través de una matriz de covarianza. Esto permite que el LMC modele diferentes relaciones entre las salidas y las entradas, y capturar dependencias entre las salidas. El LMC es comúnmente utilizado en problemas donde múltiples salidas están relacionadas con un conjunto común de entradas y las relaciones entre las salidas no se conocen completamente. En este trabajo, el conjunto de coeficientes a se optimizará junto con los hiperparámetros del kernel de PG.

4. Resultados

En esta sección se realiza un análisis de los resultados obtenidos mediante la identificación del robot blando usando PGA. Para su análisis se realizarán diferentes medidas de error, como el error absoluto medio (MAE), el error porcentual absoluto medio (MAE %), y el error R-cuadrado (R^2) (Seber, 1984).

Para ambos modelos PGA el 80 % de los 6.000 puntos de datos recogidos se utilizan para el entrenamiento, el 20 % restante como datos de prueba y 128 puntos inductores. Todas las pruebas se ejecutan en una CPU Ryzen 5 3600X y una GPU Nvidia 3060.

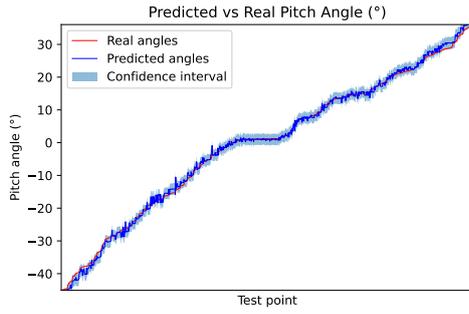
4.1. Cinemática directa

Se ha obtenido el modelo APG para los ángulos de pitch y yaw, con MAE de 0.7085 y 0.6902 y $R^2 = 0,9985$. La tabla 1 muestra el MAE, MAE %, y R^2 del modelo.

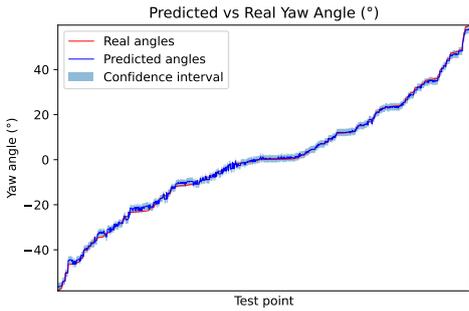
Tabla 1: Resultados de los errores de la cinemática directa mediante procesos Gaussianos

PGA	MAE	MAE %	R^2
Pitch	0.7085	0.8733	0.9985
Yaw	0.6902	0.5853	

Se muestran en la Figura 2 los resultados del conjunto de datos utilizados para pitch y yaw. Los datos se muestran ordenados para una mejor visualización del conjunto. Además, es posible observar como las predicciones se amoldan correctamente a los valores reales y como el intervalo de confianza es bastante reducido. Es decir que esta bastante convencido de la predicción.

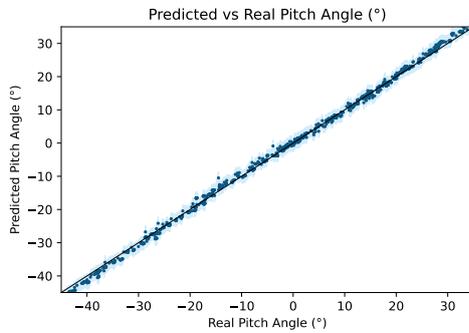


(a) R^2 obtenido para pitch

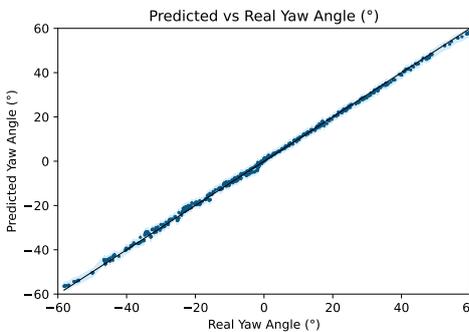


(b) R^2 obtenido para yaw

Figura 2: Resultados obtenidos con el modelo para los ángulos de pitch y yaw de la cinemática directa del robot blando



(a) R^2 obtenido para pitch

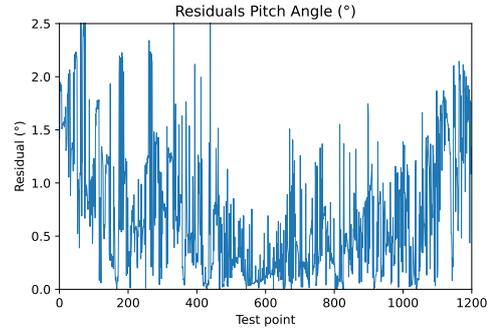


(b) R^2 obtenido para yaw

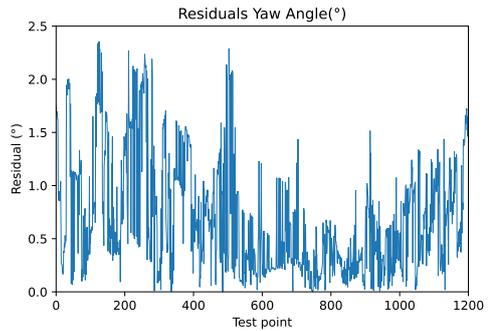
Figura 3: R^2 obtenidos con el modelo para los ángulos de pitch y yaw de la cinemática directa del robot blando.

La Figura 3 muestra los gráficos R^2 obtenidos con el modelo para los ángulos de pitch y yaw de la cinemática directa del robot blando. Se puede observar que el modelo aproxima mejor las predicciones para los valores de yaw que de pitch.

Los residuos oscilan entre 0° y $2,5^\circ$ para el modelo, como se muestra en la Figura 4. Esto también se representa en el valor MAE %, donde el modelo PGA se acerca al 1 % para pitch y al 0,6 % para yaw.



(a) Residuos para pitch



(b) Residuos para yaw

Figura 4: Residuos obtenidos con el modelo para los ángulos de pitch y yaw de la cinemática directa del robot blando.

4.2. Cinemática inversa

La identificación de la cinemática inversa es más compleja que la directa, y presenta algunos problemas que se discutirán posteriormente. A pesar de esto, resulta muy interesante ya que permite una mayor comprensión del sistema.

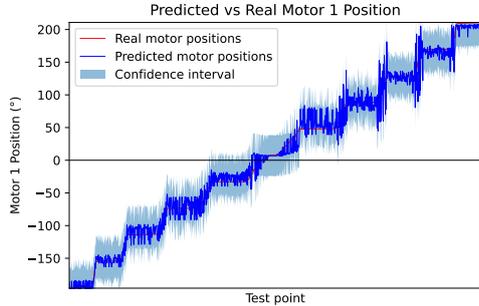
Se ha obtenido el modelo APG para los motores 1, 2 y 3; con MAE de 9,4903, 6,5550 y 6,0364 y $R^2 = 0,0,9906$. La tabla 2 muestra el MAE, MAE %, y R^2 del modelo.

Tabla 2: Resultados de los errores de la cinemática inversa mediante procesos Gaussianos

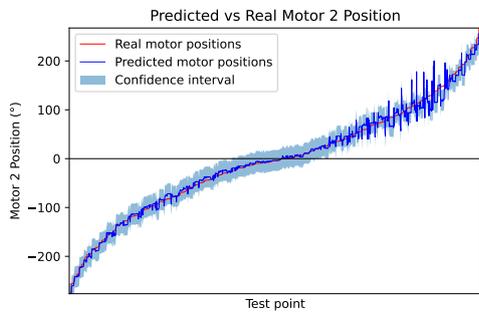
PGA	MAE	MAE %	R^2
Motor 1	9,4903	2,3343	0,9906
Motor 2	6,5550	1,2048	
Motor 3	6,0364	1,1072	

Se muestran en la Figura 5 los resultados del conjunto de datos utilizados para los motores. Los datos se muestran ordenados para una mejor visualización del conjunto. A diferencia

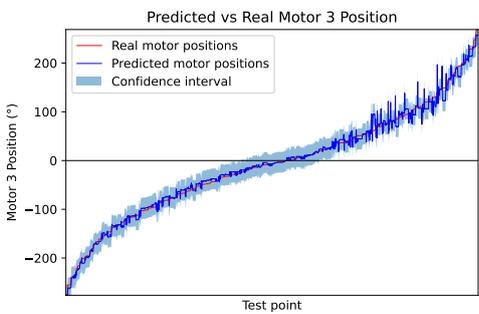
de la cinemática directa, se observa cómo el intervalo de confianza es mayor. Además, se observan resultados diferentes para el motor 1, y en los motores 2 y 3 los resultados empeoran con valores mayores que 0, los cuales representan la acción de alargar el tendón.



(a) R^2 obtenido para el motor 1



(b) R^2 obtenido para el motor 2



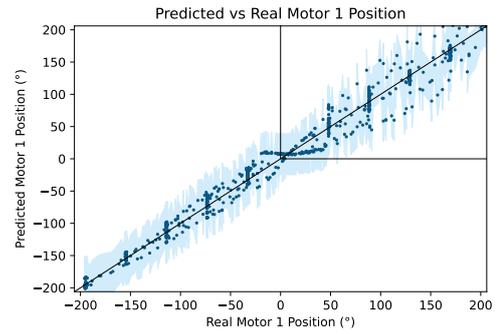
(c) R^2 obtenido para el motor 3

Figura 5: Resultados obtenidos con el modelo para los motores de la cinemática inversa del robot blando

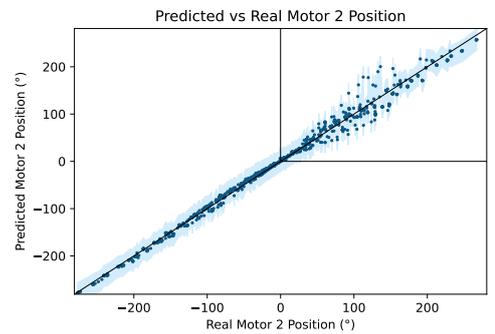
La Figura 6 muestra los gráficos R^2 obtenidos para las tres posiciones del motor para la cinemática inversa del brazo robótico blando. Además, la Figura 6(a) muestra que el PGA tiene dificultad para modelar la posición angular del primer motor en comparación con el segundo y tercer motor.

Los experimentos indican que los métodos PG son eficaces para modelar la cinemática directa e inversa del brazo robótico blando. Los modelos PG utilizan una función de covarianza compartida para múltiples salidas y son capaces de modelar sistemas no lineales y multimodales. En particular, los resultados indican que el modelo PGA es preciso en la cinemática

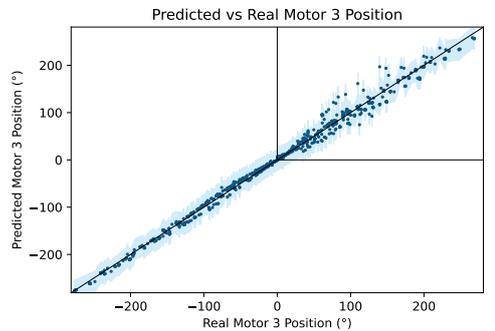
directa, a pesar de utilizar sólo 128 puntos de entrenamiento.



(a) R^2 obtenido para el motor 1



(b) R^2 obtenido para el motor 2



(c) R^2 obtenido para el motor 3

Figura 6: R^2 obtenidos con el modelo para los motores de la cinemática inversa del robot blando

La Figura 6 indica que las predicciones empeoran para valores de posición del motor superiores a cero, lo cual puede explicarse por el accionamiento del brazo robótico mediante tendones. En ciertas posiciones, alargar el tendón no afecta a la posición final del brazo ya que hay un punto en el que el alargamiento del tendón no tiene efecto en la posición final de la punta. Esta característica puede provocar que el tendón de alargamiento tenga varias longitudes diferentes para posiciones específicas sin afectar la posición final del brazo.

Este efecto se refleja en el conjunto de datos utilizados para el entrenamiento. Por lo tanto, los valores positivos de posición del motor (correspondientes al alargamiento del tendón) están más dispersos que los valores negativos (correspondientes al acortamiento del tendón). Como hay varias soluciones posi-

bles, no es un problema que el modelo no haya encontrado una solución precisa para ese rango de acción siempre y cuando se proporcione la posición final deseada.

5. Conclusiones

En este estudio se propone y valida un modelo PGA para la cinemática directa e inversa de un brazo robótico blando, el cual proporciona predicciones rápidas y precisas. La utilización de modelos PG en la cinemática de robots blandos abre interesantes líneas de investigación en robótica, como el uso de estos modelos para el control predictivo de modelos (MPC) y la Optimización Bayesiana, que aprovechan la flexibilidad de las PG para modelar funciones latentes y optimizar parámetros.

Agradecimientos

La investigación que ha conducido a estos resultados ha recibido financiación del proyecto Desarrollo de articulaciones blandas para aplicaciones robóticas, con referencia IND2020/IND-1739, financiado por la Comunidad Autónoma de Madrid (CAM) (Departamento de Educación e Investigación).

Referencias

- Beckers, T., 2021. An introduction to gaussian process models. arXiv preprint arXiv:2102.05497.
- Bonilla, E. V., Chai, K., Williams, C., 2007. Multi-task gaussian process prediction. *Advances in neural information processing systems* 20.
- Cho, K.-J., Koh, J.-S., Kim, S., Chu, W.-S., Hong, Y., Ahn, S.-H., 2009. Review of manufacturing processes for soft biomimetic robots. *International Journal of Precision Engineering and Manufacturing* 10 (3), 171–181.
- Hewing, L., Kabzan, J., Zeilinger, M. N., 2019. Cautious model predictive control using gaussian process regression. *IEEE Transactions on Control Systems Technology* 28 (6), 2736–2743.
- Laschi, C., Cianchetti, M., 2014. Soft robotics: new perspectives for robot bodyware and control. *Frontiers in bioengineering and biotechnology* 2, 3.
- Lee, C., Kim, M., Kim, Y. J., Hong, N., Ryu, S., Kim, H. J., Kim, S., 2017. Soft robot review. *International Journal of Control, Automation and Systems* 15 (1), 3–15.
- Muñoz, J., López, B., Quevedo, F., Garrido, S., Monje, C. A., Moreno, L. E., 2023. Gaussian processes and fast marching square based informative path planning. *Engineering Applications of Artificial Intelligence* 121, 106054.
- Nagua, L., Relaño, C., Monje, C. A., Balaguer, C., 2021. A new approach of soft joint based on a cable-driven parallel mechanism for robotic applications. *Mathematics* 9 (13), 1468.
- Relaño, C., Muñoz, J., Monje, C. A., 2023. Gaussian process regression for forward and inverse kinematics of a soft robotic arm. No publicado.
- Relaño, C., Muñoz, J., Monje, C. A., Martínez, S., González, D., 2022. Modeling and control of a soft robotic arm based on a fractional order control approach. *Fractal and Fractional* 7 (1), 8.
- Seber, G. A., 1984. *Linear regression analysis*. John Wiley & Sons.
- Shintake, J., Cacucciolo, V., Shea, H., Floreano, D., 2018. Soft biomimetic fish robot made of dielectric elastomer actuators. *Soft robotics* 5 (4), 466–474.
- Zhou, Y., Ju, M., Zheng, G., 2019. Closed-loop control of soft robot based on machine learning. In: 2019 Chinese Control Conference (CCC). IEEE, pp. 4543–4547.