

Jornadas de Automática

Diseño y modelado con procesos Gaussianos de un sensor blando

Muñoz, V.^{a,*}, Ballester, C.^a, Copaci, D.^a, Moreno, L.^a, Blanco, D.^a

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

To cite this article: Muñoz, V. and Ballester, C. and Copaci, D. and Moreno, L. and Blanco, D. 2024. Diseño y modelado con procesos Gaussianos de un sensor blando. Jornadas de Automática, 45. <https://doi.org/10.17979/ja-cea.2024.45.10864>

Resumen

En este estudio, se presenta el diseño y modelado de un sensor blando piezoresistivo utilizando hilos de poliamida recubiertos de plata. Estos sensores destacan por su flexibilidad, bajo coste y fácil integración en textiles, lo que los hace ideales para aplicaciones en tecnología vestible. Se evalúan diferentes recubrimientos, identificando la silicona como la mejor opción para mejorar la sensibilidad y la relación señal/ruido. El montaje experimental incluye un banco de pruebas especializado para medir la respuesta del sensor bajo diversas condiciones de deformación. Se han aplicado Procesos Gaussianos (GP) para modelar la histéresis tensión-deformación, mostrando un rendimiento excepcional en la predicción y manejo de la incertidumbre. Las pruebas de validación cruzada confirman la eficacia de los GP en la caracterización del sensor, proporcionando una herramienta poderosa para aplicaciones de monitoreo de movimientos humanos y asistencia tecnológica. Este trabajo contribuye al avance de los sensores blandos, ofreciendo soluciones prácticas y precisas para su implementación en textiles inteligentes.

Palabras clave: Identificación de sistemas no lineales, Aprendizaje automático, Filtrado y suavizado, Estimación de sistemas en tiempo continuo, Soft Sensing, Tecnología de asistencia e ingeniería de rehabilitación.

Design and Gaussian processes modeling of a soft sensor

Abstract

In this study, the design and modeling of a piezoresistive soft sensor using silver-coated polyamide yarns is presented. These sensors stand out for their flexibility, low cost and easy integration into textiles, making them ideal for wearable technology applications. Different coatings are evaluated, identifying silicone as the best option to improve sensitivity and signal-to-noise ratio. The experimental setup includes a specialized test bench to measure the sensor response under various deformation conditions. Gaussian Processes (GP) have been applied to model the stress-strain hysteresis, showing exceptional performance in prediction and uncertainty handling. Cross-validation tests confirm the effectiveness of GPs in sensor characterization, providing a powerful tool for human motion monitoring and assistive technology applications. This work contributes to the advancement of soft sensors, offering practical and accurate solutions for implementation in smart textiles.

Keywords: Nonlinear system identification, Machine Learning, Filtering and smoothing, Continuous time system estimation, Soft Sensing, Assistive technology and rehabilitation engineering.

1. Introducción

En los últimos años, la tecnología vestible ha experimentado un gran avance, gracias al cambio de estructuras robóticas rígidas por robots más blandos, adaptables y flexibles. Este cambio ha sido impulsado por el desarrollo de materiales

inteligentes, que cambian sus propiedades químicas o físicas como respuesta a ciertos estímulos externos. Una de las aplicaciones de los sensores blandos es en la creación de sistemas vestibles que permitan monitorizar los movimientos del cuerpo humano (Nasiri and Khosravani, 2020). En este campo, la

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

diferencia fundamental entre los sensores rígidos y los sensores blandos radica en su capacidad para adaptarse a los movimientos naturales del cuerpo humano sin restringirlos, proporcionando una experiencia de usuario totalmente integrada y cómoda. Con la integración de los sensores blandos en textiles, se pueden crear exotrajes vestibles para detección del movimiento humano (Wang et al., 2019) o asistencia (Araromi et al., 2017) entre otros.

Entre todas las posibles categorías de sensores blandos, los sensores de tensión-deformación han suscitado una gran atención, empleando diversos materiales para el análisis de la deformación: resistivos, capacitivos, piezoeléctricos y triboeléctricos. Los sensores de deformación capacitivos, por ejemplo, han demostrado un notable porcentaje de elongación, utilizando materiales innovadores como electrodos arrugados basados en nanotubos de carbono y cintas dieléctricas. Del mismo modo, los sensores piezoeléctricos se utilizan comúnmente en el ámbito de las aplicaciones biomédicas, utilizando técnicas de polarización autoalineadas para fabricar sensores blandos basados totalmente en fibras (Li et al., 2020).

Además, la integración de otros materiales puede mejorar las propiedades de los sensores blandos. Por ejemplo, la inclusión de grafeno mejora la sensibilidad y selectividad del sensor en varios diseños (Jin et al., 2020). En el trabajo presentado en (Kamat et al., 2021) se desarrollaron estructuras de polidimetilsiloxano infundidas con tinta de grafeno mediante un método de impresión 3D. Para mejorar la precisión y reducir la histéresis, (Tocco et al., 2022) desarrolló sensores de deformación resistivos compuestos de silicona-textil y (Atalay et al., 2017) diseñó sensores textiles capacitivos utilizando una mezcla de tejido de punto conductor y elastómero de silicona.

La relación no lineal entre el estiramiento mecánico y las variaciones de resistencia en los sensores elásticos requiere técnicas sólidas de identificación del sistema. Los modelos analíticos a menudo se quedan cortos en la encapsulación de comportamientos más complejos encontrados en los datos experimentales, dirigiendo así la atención hacia métodos basados en datos (Sun and Ge, 2021). Tradicionalmente, estos métodos basados en datos consistían en el uso de técnicas como el análisis y la regresión de componentes principales, la regresión de mínimos cuadrados parciales (PLS), la máquina de vectores de soporte (SVM) y la red neuronal artificial (ANN). Los últimos avances en este campo han aprovechado algoritmos más complejos para mejorar el modelado de materiales elásticos. Algunos trabajos recientes indican una tendencia hacia la utilización de técnicas más avanzadas de aprendizaje automático para el modelado de sensores blandos, con un enfoque en la extracción de características y la selección de variables para modelos más precisos e interpretables (Shen et al., 2020). El uso de Autoencoders (AEs) ha demostrado ser muy prometedor, como en (Guo et al., 2020), donde AEs Variacional mejora los métodos tradicionales *just-in-time* mediante la incorporación de la incertidumbre variable en la medición de la similitud. Por otra parte, el estudio presentado en (Yan et al., 2020) utiliza AEs apiladas junto con el análisis de información mutua, filtrando eficazmente las características irrelevantes y conservando aquellas que aportan información del sistema para una detección suave eficiente.

Los Procesos Gaussianos (GP) son muy utilizados en tareas de regresión, debido a su capacidad para modelar la incer-

tidumbre, asimilar el conocimiento previo y gestionar sistemas complejos. Concretamente, destaca su uso en *soft sensing* para procesos industriales, debido principalmente a su capacidad predictiva (Guo et al., 2020). El trabajo de (Liu et al., 2015) demuestra la utilización de múltiples modelos de GP para representar un proceso industrial, con un mecanismo para la conmutación automática entre ellos. Además, el enfoque en (Dai et al., 2023) combina AEs para la representación de datos latentes, empleando posteriormente GPs para tareas de regresión. La aplicación de GPs se extiende a modelar el comportamiento de histéresis en actuadores piezoeléctricos, como se explora en (Tao et al., 2019). Esta metodología ha visto mejoras en (Meng et al., 2022), donde el uso de entradas de alta dimensión sirve como un medio eficaz para la extracción de características.

En este estudio, proponemos un nuevo diseño de sensor blando piezoresistivo que utiliza hilos comerciales de poliamida recubiertos de plata. El uso de este tipo de sensores blandos ofrece ventajas como su flexibilidad, coste y facilidad de integración, lo que los convierte en candidatos prometedores para diversas aplicaciones en tecnología vestible. Primero, se analiza la respuesta de la fibra de nailon recubierta de plata cuando se recubre con una capa extra de silicona y grafeno, tras el diseño y montaje de un banco de pruebas sensorizado. A continuación, aplicamos técnicas de GPs para modelar la histéresis tensión-deformación de los datos y obtener la identificación del sistema. Utilizamos una entrada de alta dimensión, que sirve como método eficaz para la extracción de características. De esta forma, se evita el uso de arquitecturas complejas que imposibilitarían la identificación del sistema en tiempo real. La adaptabilidad del hilo facilita la creación de prendas sensorizadas capaces de ajustarse al cuerpo humano, sin necesidad de restringir los movimientos naturales. Además, otras ventajas como el poco peso, la facilidad de procesamiento de la señal, la adaptabilidad entre usuarios y los pocos costes de fabricación mejoran la integración de esta tecnología en aplicaciones reales.

2. Montaje experimental

2.1. Descripción del material

En este estudio, hemos utilizado el hilo conductor de poliamida recubierto de plata Shieldex[®] 235/36 x2 HCB (Shieldex[®]-Metallized Technical Textiles, 2023-05-05), diseñado específicamente para aplicaciones en sensores textiles inteligentes y vestibles.

La Figura 1 presenta el material empleado en esta investigación. El hilo Shieldex consta de dos hilos de poliamida trenzados entre sí con una resistencia inferior a 80 Ω/m , como se muestra en la Figura 1(a). Está disponible comercialmente en forma de bobina, lo que facilita su integración en tejidos a través de la costura y permite el desarrollo de sensores textiles, como se muestra en la Figura 1(b). La elección de la poliamida como material de base proporciona elasticidad y flexibilidad, esenciales para adaptarse a diversas formas y movimientos. Las nanofibras de plata que recubren la poliamida dotan de conductividad al material, de modo que cuando se le somete a una tensión externa, el contacto entre las fibras varía y, por lo tanto, varía la conductividad del material.

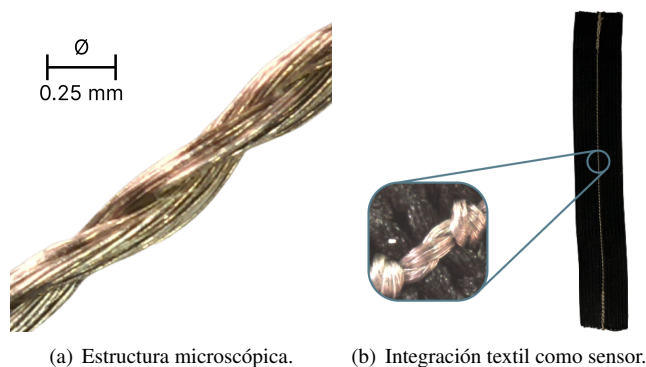


Figura 1: Estructura microscópica e integración textil del hilo de poliamida recubierto de plata Shieldex[®] 235/36 x2 HCB.

2.2. Banco de pruebas

Para facilitar el estiramiento controlado del hilo de poliamida recubierto de plata, se diseñó y montó un banco de pruebas especializado. El banco consta de dos componentes esenciales: una parte mecánica responsable del alargamiento del hilo y el soporte del sensor, y una sección electrónica dedicada a la instrumentación del sensor y el procesamiento de datos.

La Figura 2 muestra el esquema mecánico del banco de pruebas desarrollado. Este montaje incluye una pieza móvil, que se mueve mediante el giro de un motor paso a paso y un tornillo sin fin. Un extremo del material se conecta a una célula de carga, lo que permite medir de la tensión a la que está sometido el material, mientras que el otro extremo se fija a un soporte del carrito móvil. Además, un imán situado en este carrito, acoplado a un sensor de posición de efecto hall que se encuentra fijo, permite medir y controlar con precisión el alargamiento del hilo.

Los elementos esenciales que componen el banco de pruebas son:

1. El hilo de poliamida recubierto de plata, descrito anteriormente.
2. El soporte para el cable de poliamida recubierto de plata en el carro móvil, que permite su estiramiento.
3. El sensor de célula de carga EMS20 y el acondicionador de señal EMS169, fabricados por EMSYST, con una sensibilidad nominal de $1,0 \pm 2\%$ mV/V.
4. El sensor de posición basado en el efecto Hall, NSE5310, que fue fabricado por ams AG, con una interfaz I2C, y resolución de $0,488\ \mu\text{m}$.
5. El raíl que permite colocar el sensor de posición fija en la posición deseada, según la longitud del cable.
6. El componente magnético necesario para que funcione el sensor de posición.
7. El motor paso a paso híbrido bifásico serie 17HS (tamaño 42mm, 1,8 grados), y el driver A4988.
8. El tornillo sin fin que transforma el movimiento del rotor del motor en movimiento lineal del carrito móvil.
9. El carrito móvil que permite estirar la rosca y sirve de soporte para todos los componentes móviles.
10. El soporte principal del banco de pruebas que une todos los elementos.

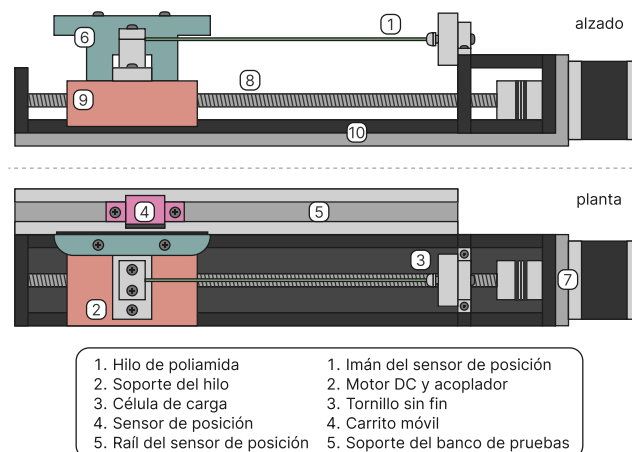


Figura 2: Banco de pruebas desarrollado, diseñado para realizar mediciones precisas de la elongación del sensor. Capaz de realizar pruebas repetibles, midiendo simultáneamente la tensión, la deformación y los cambios de resistencia del material.

3. Adquisición y procesamiento de datos

3.1. Filtrado de la señal

Para medir la resistencia del hilo de poliamida recubierto de plata, se empleó una configuración estándar de divisor de tensión. Esta configuración permite medir la caída de tensión a través del hilo. La resistencia del hilo, R , se obtiene utilizando la ecuación (1)

$$R = \frac{R_{\text{fixed}} \cdot V_R}{V - V_R}, \quad (1)$$

donde R_{fixed} es la resistencia fija del divisor de tensión, V_R representa la caída de tensión medida a través del hilo y V es la tensión de alimentación de entrada.

Los datos analógicos obtenidos de los sensores presentan un nivel considerable de ruido, lo que disminuye notablemente la calidad general de los datos y puede impedir la eficacia de las técnicas de aprendizaje automático empleadas para la caracterización de los hilos. Para mitigar este problema, se incorporó un filtro Kalman en tiempo real, que se encarga de suavizar la señal y eliminar el ruido.

3.2. Recubrimientos adicionales

Para mejorar las propiedades del material como sensor, se han realizado experimentos con dos recubrimientos adicionales: el recubrimiento conductor GRAPHIT33 de Kontax Chemie y el recubrimiento translúcido de silicona de platino PLASTIL GEL-25 de Polytek. Cada sensor se sometió a cuatro pruebas, dos pulsos incrementales de 60 y 120 segundos de periodo, y dos pulsos decrementales con los mismos periodos. El tiempo total de cada prueba fue de 40 minutos, con un incremento de deformación fijado en 0,48 mm y un valor máximo de deformación de 4,8 mm. La tensión inicial aplicada se calibró en 100g. En la Figure 3 se muestra la respuesta de los sensores con los recubrimientos adicionales y sin recubrimiento, en la que se observa una mejora significativa en la relación señal/ruido con el recubrimiento de silicona.

Para cuantificar la mejora en las propiedades del material, se han calculado dos métricas clave. En primer lugar, se calcula el *Gauge Factor* (GF) (2a), que mide el cambio relativo de la resistencia del material como respuesta a una deformación mecánica. Después, para evaluar el ruido en la señal de resistencia, R , se calcula el *Signal-to-Noise Ratio* (SNR) (2b), que cuantifica la fuerza de la señal relativa a la interferencia de ruido de fondo, R_{noise} .

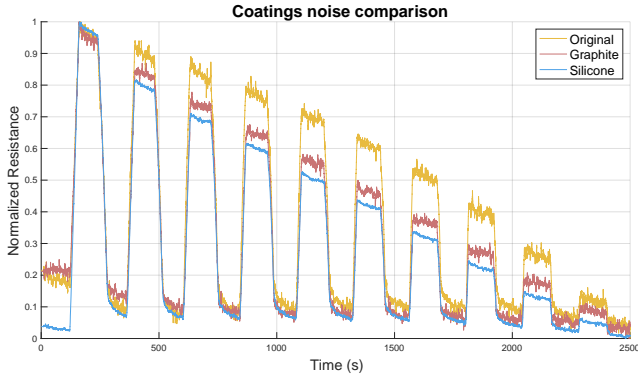


Figura 3: Respuesta de los sensores con recubrimientos adicionales y sin recubrimiento sometidos a una señal de impulso decremental.

$$GF = \frac{dR/R}{dL/L} = \frac{dR/R}{\varepsilon_a} \quad (2a)$$

$$SNR = 10 \cdot \log_{10} \left(\frac{R}{R_{noise}} \right) \quad (2b)$$

La Tabla 1 recoge los datos calculados para cada uno de los sensores evaluados. Se puede observar que el recubrimiento de silicona demuestra mejores propiedades tanto en GF como en SNR.

Tabla 1: Tabla comparativa de las propiedades para los tres sensores desarrollados, donde se calcula el valor máximo del GF y SNR por cada prueba realizada y se realiza la media y la desviación estándar de los valores obtenidos.

Recubrimiento	GF	SNR (dB)
Original	44,18 ± 1,14	56,66 ± 0,75
Graphit	44,27 ± 0,84	57,32 ± 0,29
Silicona	49,88 ± 1,31	61,68 ± 1,81

3.3. Datos de entrenamiento

Tras determinar que la silicona es el mejor revestimiento para mejorar las propiedades del material, se realizan una serie de pruebas para obtener la respuesta del sensor a diversas señales, con un valor máximo de deformación de 9,6 mm. Estas pruebas consisten en tres señales sinusoidales a diferentes frecuencias (20 mHz, 30 mHz y 40 mHz), tres señales mixtas que incluían la suma de sinusoides (15+25 mHz, 20+30 mHz y 25+35 mHz) y una señal triangular a 50 mHz. Al analizar la relación entre los valores de resistencia y los de elongación, se observa una histéresis significativa, lo que añade no linealidad al sistema y complica la identificación del sistema.

El coeficiente de correlación de rangos de Spearman, denotado como r_s , según la ecuación (3), proporciona una evaluación no paramétrica de la correlación entre el cambio de resistencia y la deformación. Este método evalúa la fuerza y la dirección de la relación monótona entre los valores ordinales (rangos) de las variables, sin tener en cuenta sus valores numéricos específicos. Este enfoque resulta especialmente valioso para los datos no lineales, ya que da prioridad al orden de los valores sobre sus magnitudes exactas. Es muy utilizado cuando se trata de datos que presentan patrones no lineales, como en este caso marcado por una histéresis significativa.

$$r_s = 1 - \frac{6 \sum d^2}{n(n^2 - 1)} \quad (3)$$

donde d representa las diferencias entre los rangos de las variables correspondientes y n es el número de puntos de datos.

En la Tabla 2 se presentan los valores r_s de cada prueba realizada. Las señales repetitivas, como las ondas sinusoidales y triangulares, muestran valores de correlación más altos, mientras que las señales mixtas exhiben valores más bajos. Sin embargo, los valores de correlación son muy altos, lo que indica que los datos son válidos para emplear técnicas avanzadas de aprendizaje automático en la identificación de sistemas.

Tabla 2: Coeficiente de correlación por rangos de Spearman calculado (r_s) para la resistencia frente a la deformación a través de señales variadas. Los valores cercanos a 1 significan una correlación significativa en los datos, y las cifras superiores a 0,8 indican una fuerte correlación de datos.

Señal de entrada	Frecuencia (mHz)	r_s
Sinusoidal	20	0.99
	30	0.99
	40	0.99
Triangular	50	0.98
Mixtas	10+20	0.94
	15+25	0.94
	20+30	0.92

4. Modelado con procesos Gaussianos

Un Proceso Gaussiano (GP) es un proceso estocástico en el que cualquier colección finita de variables aleatorias tiene una distribución gaussiana conjunta. Se caracteriza por su función media $m(x)$ y la función de covarianza $k(x, x')$ (4), donde $f(x)$ denota la función aleatoria modelada por la GP, x es la variable de entrada o punto en el espacio de entrada, y x' es otra variable de entrada o punto en el espacio de entrada, utilizado para evaluar la función de covarianza entre dos puntos cualesquiera en el dominio de f .

$$f(x) \sim \mathcal{GP}(m(x), k(x, x')) \quad (4)$$

La función media $m(x)$ (5) representa el valor esperado de la función $f(x)$ en el punto x . A menudo se supone que es cero o una función lineal simple, aunque puede tomar formas más complejas basadas en el conocimiento previo.

$$m(x) = \mathbb{E}[f(x)] \quad (5)$$

La función de covarianza, o kernel, evalúa cómo se correlacionan los cambios en el espacio de entrada, afectando a las predicciones y estimaciones de incertidumbre del GP en diferentes puntos. Para tareas de regresión, el kernel más común es el kernel Cuadrático Racional (RQ) (6), donde σ^2 es el parámetro de varianza, l es el parámetro de escala de longitud, y α es un parámetro de mezcla de escala que controla la ponderación de las variaciones a gran y pequeña escala.

$$k(x, x') = \sigma^2 \left(1 + \frac{\|x - x'\|^2}{2\alpha l^2} \right)^{-\alpha} \quad (6)$$

Sin embargo, la complejidad computacional de los GP aumenta rápidamente a medida que crece el tamaño del conjunto de datos, lo que los hace poco prácticos para numerosas aplicaciones del mundo real. Para mitigar este problema, se emplean GP aproximados, aprovechando los puntos inductores para formar una representación condensada de todo el conjunto de datos. Este enfoque disminuye notablemente el esfuerzo computacional y las demandas de memoria, haciendo que la complejidad pase de una escala cúbica a una cuasi lineal.

5. Resultados

Las métricas utilizadas para evaluar el rendimiento de los modelos son el Error Cuadrático Medio (RMSE) (7) y el Coeficiente de Determinación (R^2) (8), donde x son los valores verdaderos, \hat{x} son los valores predichos, \bar{x} es la media, y n el número total de observaciones. RMSE y R^2 se eligen por sus medidas complementarias sobre el rendimiento del modelo de regresión. RMSE penaliza fuertemente los errores más grandes, ofreciendo una medida clara de la precisión del modelo, mientras que R^2 permite evaluar el poder explicativo del modelo.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{n}} \quad (7)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - \hat{x}_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (8)$$

Para evaluar la capacidad de los modelos para adaptarse y funcionar de forma consistente con diferentes tipos de señales, se aplicó un método de validación cruzada, donde el modelo se entrena con todas las señales disponibles excepto una, que se retiene para la prueba. Este ciclo se repite para cada señal, garantizando que cada una de ellas se utiliza individualmente como caso de prueba. Esta técnica va más allá del método más sencillo de dividir las señales en conjuntos de entrenamiento y de prueba, y ofrece una visión más clara de la capacidad del modelo para manejar diversos escenarios.

La Tabla 3 muestra las métricas calculadas para cada señal evaluada. Los resultados indican un rendimiento excepcional de los GP en la caracterización de la histéresis, con valores de R^2 superiores a 0,9 en la mayoría de los casos. La predicción en las señales sinusoidales y triangulares es particularmente precisas, debido enormemente al comportamiento repetitivo de estas señales y su alta correlación. Por otro lado, las señales mixtas presentan un rendimiento ligeramente inferior, lo que se atribuye a la mayor complejidad de estas señales y a la presencia de múltiples frecuencias.

La Figura 4 muestra la predicción en tiempo real con la incertidumbre. En las gráficas se pueden observar las diferencias en el ajuste de la predicción para las señales más regulares, como las sinusoidales y triangulares, y las señales mixtas, donde la incertidumbre es mayor. También se puede observar cómo la incertidumbre es mayor en los picos de las señales, debido a que en estos puntos la histéresis es más pronunciada.

Tabla 3: Evaluación de Procesos Gaussianos (GP) en el modelo de deformación bajo condiciones variables de frecuencias de señal de entrada.

Señal de entrada	Frecuencia (mHz)	RMSE	R^2
Sinusoidal	20	0.0550	0.9761
	30	0.0682	0.9629
	40	0.0579	0.9725
Mixta	10+20	0.0956	0.8900
	15+25	0.0596	0.9374
	20+30	0.0815	0.9053
Triangular	50	0.0705	0.9390

Los procesos Gaussianos presentan varias ventajas sobre las técnicas de regresión estándar, la más destacada de las cuales es que proporcionan estimaciones de incertidumbre para cada predicción. Esta capa de información añadida tiene un valor incalculable para la toma de decisiones, sobre todo en contextos sensibles para la seguridad. Aprovechar estos datos de incertidumbre permite a los algoritmos tomar decisiones más informadas en condiciones ambiguas o en presencia de ruido en los sensores. Además, la naturaleza no paramétrica de las GP elimina la necesidad de un conjunto predefinido de parámetros del modelo, lo que simplifica su entrenamiento. Por lo general, basta con optimizar unos pocos hiperparámetros, como la configuración del núcleo, lo que hace que las GP requieran menos recursos informáticos y sean más eficientes de entrenar que redes neuronales artificiales, sobre todo para conjuntos de datos más pequeños.

6. Conclusiones

En este estudio, se ha validado con éxito el uso de hilos de poliamida recubiertos de plata para desarrollar sensores blandos de deformación. Estos sensores ofrecen multitud de ventajas, como su flexibilidad, ligereza, bajo coste y perfecta integración en textiles, lo que los hace muy prometedores para una amplia gama de aplicaciones en tecnología vestible. Además, la regresión a través de Procesos Gaussianos, es una solución viable para modelar características no lineales, como la histéresis. Los GP mostraron un rendimiento excepcional incluso con conjuntos de datos limitados, lo que demuestra su potencial para modelar con precisión los comportamientos complejos de los sensores.

Los siguientes pasos en esta línea de investigación incluyen el estudio de la repetibilidad del sensor, además de un modelado más avanzado de la fatiga del material. En cuanto a la integración del sensor en textiles, se explorarán técnicas de tejido y costura para mejorar la durabilidad y la resistencia del sensor. También se investigarán las posibles aplicaciones de estos sensores en tecnología vestible, como la monitorización de la postura y el movimiento humano.

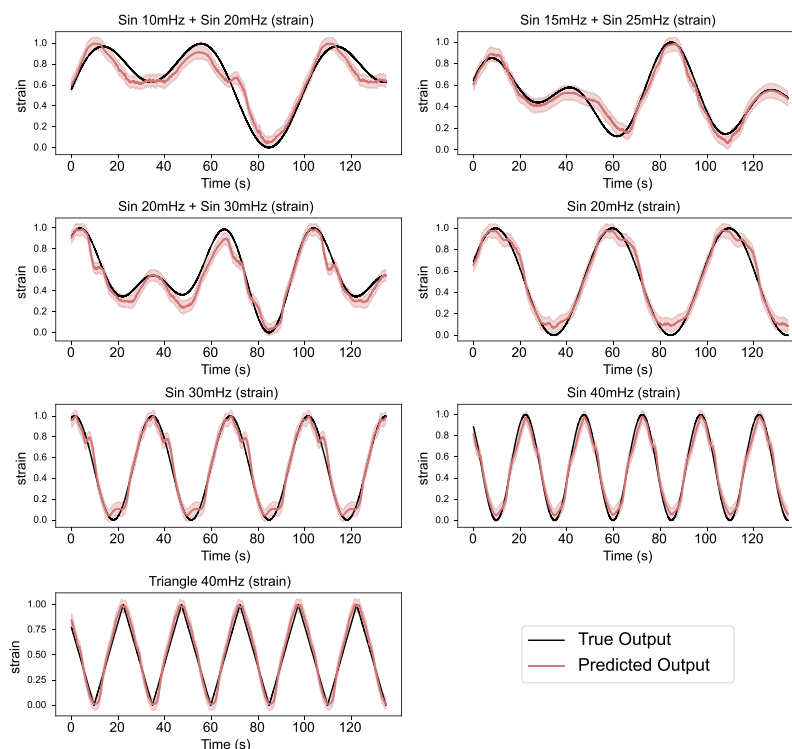


Figura 4: Predicción en tiempo real de la deformación del sensor con incertidumbre. Las gráficas muestran la predicción de los GP para las señales sinusoidales, mixtas y triangulares, con la incertidumbre representada por la sombra.

Referencias

- Araromi, O.A., Walsh, C.J., Wood, R.J., 2017. Hybrid carbon fiber-textile compliant force sensors for high-load sensing in soft exosuits, in: 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE. pp. 1798–1803. doi:[10.1109/iro.2017.8205994](https://doi.org/10.1109/iro.2017.8205994).
- Atalay, A., Sanchez, V., Atalay, O., Vogt, D.M., Haufe, F., Wood, R.J., Walsh, C.J., 2017. Batch fabrication of customizable silicone-textile composite capacitive strain sensors for human motion tracking. *Advanced Materials Technologies* 2, 1700136. doi:[10.1002/admt.201700136](https://doi.org/10.1002/admt.201700136).
- Dai, Y., Yang, C., Liu, Y., Yao, Y., 2023. Latent-enhanced variational adversarial active learning assisted soft sensor. *IEEE Sensors Journal* 23, 15762–15772. URL: <http://dx.doi.org/10.1109/JSEN.2023.3279203>, doi:[10.1109/j.2023.3279203](https://doi.org/10.1109/j.2023.3279203).
- Guo, F., Xie, R., Huang, B., 2020. A deep learning just-in-time modeling approach for soft sensor based on variational autoencoder. *Chemometrics and Intelligent Laboratory Systems* 197, 103922. doi:[10.1016/j.chemolab.2019.103922](https://doi.org/10.1016/j.chemolab.2019.103922).
- Jin, X., Feng, C., Ponnamm, D., Yi, Z., Parameswaranpillai, J., Thomas, S., Salim, N.V., 2020. Review on exploration of graphene in the design and engineering of smart sensors, actuators and soft robotics. *Chemical Engineering Journal Advances* 4, 100034. doi:[10.1016/j.cej.2020.100034](https://doi.org/10.1016/j.cej.2020.100034).
- Kamat, A.M., Pei, Y., Jayawardhana, B., Kottapalli, A.G.P., 2021. Biomimetic soft polymer microstructures and piezoresistive graphene MEMS sensors using sacrificial metal 3D printing. *ACS Applied Materials & Interfaces* 13, 1094–1104. doi:[10.1021/acsami.0c21295](https://doi.org/10.1021/acsami.0c21295).
- Li, T., Qu, M., Carlos, C., Gu, L., Jin, F., Yuan, T., Wu, X., Xiao, J., Wang, T., Dong, W., Wang, X., Feng, Z.Q., 2020. High-performance poly(vinylidene difluoride)/dopamine core/shell piezoelectric nanofiber and its application for biomedical sensors. *Advanced Materials* 33, 2006093. doi:[10.1002/adma.202006093](https://doi.org/10.1002/adma.202006093).
- Liu, Y., Chen, T., Chen, J., 2015. Auto-switch gaussian process regression-based probabilistic soft sensors for industrial multigrade processes with transitions. *Industrial & Engineering Chemistry Research* 54, 5037–5047. URL: <http://dx.doi.org/10.1021/ie504185j>, doi:[10.1021/ie504185j](https://doi.org/10.1021/ie504185j).
- Meng, Y., Wang, X., Li, L., Huang, W., Zhu, L., 2022. Hysteresis modeling and compensation of piezoelectric actuators using gaussian process with high-dimensional input. *Actuators* 11, 115. URL: <http://dx.doi.org/10.3390/act11050115>, doi:[10.3390/act11050115](https://doi.org/10.3390/act11050115).
- Nasiri, S., Khosravani, M.R., 2020. Progress and challenges in fabrication of wearable sensors for health monitoring. *Sensors and Actuators A: Physical* 312, 112105. URL: <http://dx.doi.org/10.1016/j.sna.2020.112105>, doi:[10.1016/j.sna.2020.112105](https://doi.org/10.1016/j.sna.2020.112105).
- Shen, B., Yao, L., Ge, Z., 2020. Nonlinear probabilistic latent variable regression models for soft sensor application: From shallow to deep structure. *Control Engineering Practice* 94, 104198. doi:[10.1016/j.conengprac.2019.104198](https://doi.org/10.1016/j.conengprac.2019.104198).
- Shieldex®-Metallized Technical Textiles, 2023-05-05. Shieldex® 235/36 x2 HCB. <https://www.shieldex.de/en/products/shieldex-235-36-x2-hcb-2/>. Accessed: 2023-10-13.
- Sun, Q., Ge, Z., 2021. A survey on deep learning for data-driven soft sensors. *IEEE Transactions on Industrial Informatics* 17, 5853–5866. doi:[10.1109/tii.2021.3053128](https://doi.org/10.1109/tii.2021.3053128).
- Tao, Y.D., Li, H.X., Zhu, L.M., 2019. Rate-dependent hysteresis modeling and compensation of piezoelectric actuators using gaussian process. *Sensors and Actuators A: Physical* 295, 357–365. URL: <http://dx.doi.org/10.1016/j.sna.2019.05.046>, doi:[10.1016/j.sna.2019.05.046](https://doi.org/10.1016/j.sna.2019.05.046).
- Tocco, J.D., Presti, D.L., Rainer, A., Schena, E., Massaroni, C., 2022. Silicone-textile composite resistive strain sensors for human motion-related parameters. *Sensors* 22, 3954. doi:[10.3390/s22103954](https://doi.org/10.3390/s22103954).
- Wang, J., Lu, C., Zhang, K., 2019. Textile-based strain sensor for human motion detection. *Energy & Environmental Materials* 3, 80–100. doi:[10.1002/eeem2.12041](https://doi.org/10.1002/eeem2.12041).
- Yan, X., Wang, J., Jiang, Q., 2020. Deep relevant representation learning for soft sensing. *Information Sciences* 514, 263–274. doi:[10.1016/j.ins.2019.11.039](https://doi.org/10.1016/j.ins.2019.11.039).