

Escuela Superior Politécnica del Litoral

Facultad de Ingeniería en Mecánica y Ciencias de la Producción

Predicción de superficies de contacto en tareas robóticas repetitivas

INGE-2617

Proyecto Integrador

Previo la obtención del Título de:

Ingeniero en Mecatrónica

Presentado por:

Luis Hernán Campos Guzmán

Guayaquil - Ecuador

Año: 2024

Dedicatoria

El presente proyecto se lo dedico a mis hermanos y a mis padres, siempre estuvieron allí para apoyarme a pesar de todos los inconvenientes que tuve al hacer mi tesis.

Agradecimientos

Le agradezco a Dios por las personas que puso en mi camino para poder completar esta faena y también a mis profesores por tenerme paciencia y velar por el bienestar mío y de este proyecto. ¡Gracias a todos por su ayuda!

Declaración Expresa

Yo Luis Hernán Campos Guzmán acuerdo y reconozco que:

La titularidad de los derechos patrimoniales de autor (derechos de autor) del proyecto de graduación corresponderá al autor o autores, sin perjuicio de lo cual la ESPOL recibe en este acto una licencia gratuita de plazo indefinido para el uso no comercial y comercial de la obra con facultad de sublicenciar, incluyendo la autorización para su divulgación, así como para la creación y uso de obras derivadas. En el caso de usos comerciales se respetará el porcentaje de participación en beneficios que corresponda a favor del autor o autores.

La titularidad total y exclusiva sobre los derechos patrimoniales de patente de invención, modelo de utilidad, diseño industrial, secreto industrial, software o información no divulgada que corresponda o pueda corresponder respecto de cualquier investigación, desarrollo tecnológico o invención realizada por mí durante el desarrollo del proyecto de graduación, pertenecerán de forma total, exclusiva e indivisible a la ESPOL, sin perjuicio del porcentaje que me corresponda de los beneficios económicos que la ESPOL reciba por la explotación de mi innovación, de ser el caso.

En los casos donde la Oficina de Transferencia de Resultados de Investigación (OTRI) de la ESPOL comunique al autor que existe una innovación potencialmente patentable sobre los resultados del proyecto de graduación, no se realizará publicación o divulgación alguna, sin la autorización expresa y previa de la ESPOL.

Guayaquil, 21 de mayo del 2024.


Campos Guzmán Luis Hernán

Evaluadores

Marcelo Rodolfo Fajardo Pruna, PhD

Profesor de Materia

Carlos Xavier Saldarriaga Mero, PhD

Tutor de proyecto

Resumen

En la robótica industrial, se busca que los autómatas interactúen eficientemente con diversas superficies durante la ejecución de tareas repetitivas. Este proyecto tiene como objetivo dotar a un robot de la capacidad para predecir la superficie de contacto con la que interactúa, optimizando su configuración para mejorar el desempeño y prolongar su vida útil, reduciendo el tiempo entre mantenimientos. Para ello, se utilizó el software MATLAB para realizar simulaciones y recopilar datos, con los cuales se elaboró un conjunto de datos (DataSet). Estos datos se emplearon para entrenar un modelo de machine learning “CatboostClassifier” que permitió al robot predecir la superficie de contacto. Los resultados mostraron una precisión del 91% en la clasificación de materiales, lo que indica que, en 91 de cada 100 ocasiones, el robot identificó correctamente la superficie. Las conclusiones indican que, aunque se logró una predicción exitosa, el modelo presenta dificultades al diferenciar entre materiales con coeficientes de fricción similares, como el latón y el teflón, siendo la clasificación confiable en su mayoría.

Palabras clave: Machine learning, CatboostClassifier, robot industrial, estimación de parámetros.

Abstract

In industrial robotics, the goal is for robots to interact with various surfaces while executing repetitive tasks efficiently. This project aims to allow a robot to predict the contact surface with which it interacts, optimizing its configuration to improve performance and extend its useful life, reducing the time between maintenance. MATLAB software was used to perform simulations and collect data, creating a data set. These data were used to train a machine learning model, “CatboostClassifier,” that allowed the robot to predict the contact surface among several materials. The results showed a 91% accuracy in classifying materials, indicating that the robot correctly identified the surface in ninety-one out of one hundred cases. The conclusions suggest that, although a successful prediction was achieved, the model has difficulties differentiating between materials with similar friction coefficients, such as brass and Teflon, with the classification primarily reliable.

1. Keywords: Machine learning, CatboostClassifier, industrial robot, Parameter Estimation.

Índice general

Resumen.....	I
Abstract.....	II
Índice general.....	III
Abreviaturas.....	V
Simbología.....	VI
Índice de figuras.....	VII
Índice de tablas.....	X
Capítulo 1.....	1
1. Introducción.....	2
1.1 Definición del problema.....	3
1.2 Justificación del problema.....	5
1.3 Objetivos.....	7
1.3.1 Objetivo general.....	7
1.3.2 Objetivos específicos.....	7
1.4 Marco Teórico.....	7
1.4.1 Estado del Arte.....	12
Capítulo 2.....	14
2. Metodología.....	15
2.1 Requerimientos de Diseño.....	15
2.2 Selección de alternativas.....	15
2.2.1 Alternativa 1 – Arboles de Decisión.....	15

2.2.2	Alternativa dos – Redes Neuronales.....	16
2.2.3	Alternativa tres – CatBoost Classifier	16
2.3	Selección de alternativa para solución al problema.....	17
2.4	Metodología de diseño.....	17
2.5	Diseño conceptual.....	18
2.6	Cálculos representativos	19
2.7	Simulaciones.....	19
Capítulo 3.....		20
3.	Resultados y análisis.....	21
3.1	Costos.....	56
Capítulo 4.....		58
4.	Conclusiones y recomendaciones	59
4.1.1	Conclusiones.....	59
4.1.2	Recomendaciones	60
Referencias.....		62
Apéndice A		65

Abreviaturas

AHRS	Attitude and Heading Reference Systems
DC	Direct Current
DH	Denavit-Hartenberg (D-H)
ESPOL	Escuela Superior Politécnica del Litoral
MIT	Instituto Tecnológico de Massachusetts
ML	Machine Learning
MSRL	Multipurpose Supernumerary Robotic Limbs
SRLs	Supernumerary Robotic Limbs

Simbología

Kg	Kilogramo
m	Metro
N	Newton
rad	Radian
s	segundo

Índice de figuras

Figura 2.1. Diagrama de proceso de metodología	18
Figura 2.2. Ilustración de entorno virtual llevado a cabo en Simscape	19
Figura 3.1. Robot interactuando con material.....	22
Figura 3.2. Fuerza de Amortiguamiento de los 6 materiales	22
Figura 3.3. Fuerza de fricción en eje "X" de los 6 materiales.....	23
Figura 3.4. Fuerza de fricción en eje "Y" de los 6 materiales.....	23
Figura 3.5. Fuerza de fricción en eje "Z" de los 6 materiales	24
Figura 3.6. Fuerza Normal a superficie de contacto	24
Figura 3.7. Aceleración del punto de contacto en eje "X"	25
Figura 3.8. Aceleración del punto de contacto en eje "Y"	25
Figura 3.9. Aceleración del punto de contacto en eje "Z"	26
Figura 3.10. Aceleración angular del punto de contacto en eje "X"	26
Figura 3.11. Aceleración angular del punto de contacto en eje "Y"	27
Figura 3.12. Aceleración angular del punto de contacto en eje "Z"	27
Figura 3.13. Velocidad angular del punto de contacto en eje "X"	28
Figura 3.14. Velocidad angular del punto de contacto en eje "Y"	28
Figura 3.15. Velocidad angular del punto de contacto en eje "Z"	29
Figura 3.16. Posición en "X" del punto de contacto	29
Figura 3.17. Posición en "Y" del punto de contacto	30
Figura 3.18. Posición en "Z" del punto de contacto.....	30
Figura 3.19. Velocidad en "X" del punto de contacto	31
Figura 3.20. Velocidad en "Y" del punto de contacto	31
Figura 3.21. Velocidad en "Z" del punto de contacto.....	32
Figura 3.22. Componente 1 de Cuaternión en punto de contacto.....	32

Figura 3.23. Componente 2 de Cuaternión en punto de contacto.....	33
Figura 3.24. Componente 3 de Cuaternión en punto de contacto.....	33
Figura 3.25. Componente 4 de Cuaternión en punto de contacto.....	34
Figura 3.26. Fuerza de control en eje "X"	34
Figura 3.27. Fuerza de control en eje "Y"	35
Figura 3.28. Fuerza de control en eje "Z"	35
Figura 3.29. Torque de control en eje "X"	36
Figura 3.30. Torque de control en eje "Y"	36
Figura 3.31. Torque de control en eje "Z"	37
Figura 3.32. Fuerza de controlador esfuerzo en forma en "X"	37
Figura 3.33. Fuerza de controlador esfuerzo en forma en "Y"	38
Figura 3.34. Fuerza de controlador esfuerzo en forma en "Z"	38
Figura 3.35. Torque de controlador esfuerzo en forma en "X".....	39
Figura 3.36. Torque de controlador esfuerzo en forma en "Y"	39
Figura 3.37. Torque de controlador esfuerzo en forma en "Z"	40
Figura 3.38. Fuerza de controlador esfuerzo en "X"	40
Figura 3.39. Fuerza de controlador esfuerzo en "Y"	41
Figura 3.40. Fuerza de controlador esfuerzo en "Z"	41
Figura 3.41. Momento de controlador esfuerzo en "X"	42
Figura 3.42. Momento de controlador esfuerzo en "Y"	42
Figura 3.43. Momento de controlador esfuerzo en "Z"	43
Figura 3.44. Aceleración articular de la junta #1	43
Figura 3.45. Aceleración articular de la junta #2.....	44
Figura 3.46. Aceleración articular de la junta #3.....	44
Figura 3.47. Aceleración articular de la junta #4.....	45

Figura 3.48. Aceleración articular de la junta #5.....	45
Figura 3.49. Aceleración articular de la junta #6.....	46
Figura 3.50. Aceleración articular de la junta #7.....	46
Figura 3.51. Velocidad articular de la junta #1.....	47
Figura 3.52. Velocidad articular de la junta #2.....	47
Figura 3.53. Velocidad articular de la junta #3.....	48
Figura 3.54. Velocidad articular de la junta #4.....	48
Figura 3.55. Velocidad articular de la junta #5.....	49
Figura 3.56. Velocidad articular de la junta #6.....	49
Figura 3.57. Velocidad articular de la junta #7.....	50
Figura 3.58. Posición articular de la junta #1.....	50
Figura 3.59. Posición articular de la junta #2.....	51
Figura 3.60. Posición articular de la junta #3.....	51
Figura 3.61. Posición articular de la junta #4.....	52
Figura 3.62. Posición articular de la junta #5.....	52
Figura 3.63. Posición articular de la junta #6.....	53
Figura 3.64. Posición articular de la junta #7.....	53

Índice de tablas

Tabla 3.1. Densidades relativas al Acero.....	21
Tabla 3.2. Agrupación de datos para DataSet.....	55
Tabla 3.3. Matriz de confusión	56
Tabla 3.4. Costos del proyecto.....	57

Capítulo 1

1. Introducción

Actualmente, la robótica se ha convertido en un área de gran utilidad para los seres humanos. Entre los múltiples avances que se pueden lograr en este campo, una de las principales áreas en desarrollo es asignar tareas dinámicas a los robots. El objetivo frecuente es emular el comportamiento humano en los robots para prever cómo deberían actuar de manera adecuada y cómo no deberían hacerlo. Esto permite que el robot ejecute las tareas asignadas de acuerdo con los movimientos de las personas [1]. En el ámbito industrial, los sistemas robóticos han demostrado ser una herramienta invaluable para la automatización y mejora de la productividad en diversos sectores [2].

No obstante, las tendencias actuales en las demandas de los consumidores y la sociedad están orientadas hacia productos personalizados y en volúmenes de producción reducidos. Estas exigencias impulsan la necesidad de desarrollar sistemas que sean tanto flexibles como adaptables [3].

La implementación efectiva de sistemas robóticos requiere una comprensión detallada tanto del entorno en el que operan como de la cinemática y dinámica del propio robot. La descripción cinemática y dinámica de los robots está bien establecida y respaldada por una sólida base teórica en la literatura científica. Sin embargo, la descripción del entorno y de las tareas a realizar es un área de estudio más compleja, cuya dificultad varía en función de las propiedades y requisitos específicos del entorno y la tarea. En las arquitecturas de control con cumplimiento, es esencial configurar numerosos parámetros para determinar el comportamiento dinámico entre el efector final del robot y el entorno. Tradicionalmente, estos parámetros son establecidos de manera manual por el usuario, según las características y necesidades específicas de la tarea. Este enfoque ha demostrado ser eficaz en entornos bien definidos y estructurados. No obstante, en entornos no estructurados o desconocidos, las características de las tareas y del entorno cambian continuamente, lo que a su vez altera las

especificaciones de fuerza y posición requeridas. Esto implica la necesidad de ajustes constantes en los parámetros del controlador. Un ejemplo claro de esta situación es el proceso de desensamblaje en la cadena de reciclaje, donde se reciben productos de diversos tipos y condiciones, requiriendo especificaciones personalizadas de fuerza o trayectorias. El problema surge cuando los parámetros fijos, determinados inicialmente para una tarea específica, no son adecuados en entornos cambiantes, lo que puede llevar a resultados inadecuados o a un rendimiento deficiente. Para estas situaciones es necesario predecir la superficie con la que esté interactuando el robot para que así pueda realizar de forma más eficiente las tareas repetitivas que se tiene previsto que cumpla. Se propone desarrollar una función de predicción que permita al sistema robótico poder realizar sus tareas de una manera más eficiente, pudiendo distinguir entre las superficies de trabajo con las cuales se desenvuelve día a día, y de esta manera lograr tener un desempeño más eficiente y óptimo [4].

A nivel industrial, los robots se utilizan extensamente debido a su capacidad para repetir secuencias de manera indefinida en la fabricación de productos específicos. Su gran precisión y alta repetitividad los hacen ideales para numerosas tareas en este ámbito. Para asegurar un desempeño exitoso, es fundamental llevar a cabo un modelado dinámico del robot, ya que esto permite realizar ajustes precisos en los movimientos de la automatización involucrada. [5]

1.1 Definición del problema

En la actualidad, las industrias robóticas enfrentan un desafío crítico relacionado con la interacción de autómatas con materiales diversos en la ejecución de tareas repetitivas. El problema radica en que los comportamientos de los robots varían significativamente dependiendo del tipo de superficie con la que interactúan, lo que afecta negativamente la eficiencia y la precisión del proceso automatizado. Los requerimientos específicos para abordar

este problema incluyen la capacidad de predecir con precisión el tipo de superficie con la que el robot va a interactuar. Esta predicción debe ser lo suficientemente robusta para adaptarse a las variaciones en el entorno y los materiales, permitiendo que el robot ajuste su comportamiento de manera óptima y eficaz en tiempo real. Las restricciones en este contexto incluyen la necesidad de mantener una alta precisión en la identificación de superficies sin comprometer la velocidad de operación del robot. Además, la solución debe ser compatible con los sistemas de control existentes y ser implementable sin requerir una reestructuración completa de la infraestructura robótica actual. [4]

Las variables de interés en este estudio comprenden los diferentes tipos de superficies, las características de interacción entre el robot y estas superficies, y los parámetros de control que afectan el comportamiento del robot. Es crucial desarrollar un modelo predictivo que pueda integrar estas variables de manera efectiva, proporcionando resultados precisos que puedan ser utilizados para ajustar los parámetros del robot automáticamente.

La importancia de resolver este problema radica en los beneficios sustanciales que aportaría a la industria robótica. Una solución eficaz permitiría mejorar significativamente la eficiencia operativa, reducir el desgaste y el mantenimiento de los robots, y aumentar la precisión en tareas repetitivas. Además, esta capacidad de adaptación y optimización contribuiría a una mayor flexibilidad en las líneas de producción, facilitando la transición hacia una manufactura más personalizada y adaptable a las demandas del mercado actual.

Este problema es altamente susceptible de observación, medición y análisis. Se pueden implementar ensayos controlados donde los robots interactúen con una variedad de superficies, recopilando datos sobre su comportamiento y los resultados obtenidos. Estos datos permitirán desarrollar y refinar los modelos predictivos, evaluando su precisión y eficacia en condiciones reales de operación. El análisis de estos datos proporcionará información valiosa sobre las

relaciones entre las variables involucradas y ayudará a identificar las mejores estrategias de control adaptativo.

1.2 Justificación del problema

Resolver el problema de la interacción de robots industriales con distintas superficies de contacto es crucial para optimizar la eficiencia y precisión en la ejecución de tareas repetitivas en la industria. En muchos procesos industriales, los robots deben realizar la misma tarea repetidamente, pero con la complejidad añadida de tener que interactuar con materiales y superficies variadas. Esta variabilidad en las superficies de contacto afecta significativamente el desempeño de los robots, ya que la interacción no es uniforme y puede resultar en errores, ineficiencias y un mayor desgaste de los equipos.

El núcleo del problema radica en la incapacidad de los robots actuales para reconocer y adaptarse automáticamente a diferentes tipos de superficies. Esta falta de adaptabilidad conduce a un rendimiento subóptimo y puede incrementar los costos operativos debido a la necesidad de intervenciones manuales para ajustar los parámetros de control del robot. Además, los errores en la interacción con superficies inadecuadas pueden resultar en daños tanto al robot como a los materiales manipulados, afectando negativamente la calidad del producto final y la seguridad del entorno de trabajo.

La importancia de resolver este problema es multifacética. En primer lugar, mejorar la capacidad de los robots para identificar y adaptarse a distintas superficies incrementará significativamente la eficiencia operativa. Los robots podrán realizar tareas con mayor precisión y rapidez, reduciendo el tiempo de inactividad y los costos asociados con el mantenimiento y la reparación. En segundo lugar, esta adaptabilidad contribuirá a la calidad del producto, ya que se minimizarán los errores y daños en la manipulación de materiales. En tercer lugar, un sistema de predicción y ajuste automático de parámetros de interacción

aumentará la flexibilidad de las operaciones industriales, permitiendo una mayor personalización y adaptabilidad en las líneas de producción.

Implementar una solución que permita a los robots industriales predecir y reconocer el tipo de superficie con la que van a interactuar, y ajustar su comportamiento en consecuencia, es una necesidad apremiante. Tal sistema no solo resolvería los problemas de eficiencia y precisión mencionados, sino que también facilitaría la integración de nuevas tecnologías y procesos dentro del entorno industrial. La capacidad de adaptación autónoma de los robots es un paso hacia la creación de fábricas inteligentes y altamente automatizadas, que pueden responder dinámicamente a las demandas cambiantes del mercado y las variaciones en los procesos de producción.

En términos de impacto económico, la justificación para resolver este problema es clara. La reducción en los tiempos de inactividad, el ahorro en costos de mantenimiento y reparación, y la mejora en la calidad del producto final pueden traducirse en significativos beneficios financieros para las empresas. Además, al mejorar la seguridad y reducir la necesidad de intervención manual, las empresas pueden optimizar el uso de sus recursos humanos, enfocando el talento en tareas más estratégicas y de mayor valor agregado.

Desde una perspectiva tecnológica, abordar este problema también contribuirá al avance del campo de la robótica industrial. El desarrollo de algoritmos de predicción y sistemas de control adaptativo avanzados no solo resolverá el problema inmediato de interacción con superficies variables, sino que también sentará las bases para futuras innovaciones en la automatización industrial. Estas innovaciones podrían incluir robots con capacidades avanzadas de aprendizaje y adaptación, capaces de operar en entornos aún más complejos y dinámicos.

1.3 Objetivos

1.3.1 Objetivo general

Predecir el comportamiento de un robot en tareas repetitivas simulando la interacción de distintas superficies de trabajo para optimizar el funcionamiento con base a los datos generados en la simulación.

1.3.2 Objetivos específicos

1. Analizar las tareas repetitivas que va a realizar el robot con los distintos materiales con los que estará en interacción.
2. Desarrollar una simulación dinámica del comportamiento del robot en interacción con su espacio de trabajo a la hora de realizar una tarea repetitiva.
3. Generar la base de datos necesaria para el algoritmo de predicción a partir de las simulaciones realizadas.
4. Desarrollar un algoritmo de predicción con los datos recolectados de tal forma que el robot pueda predecir qué tipo de material es aquel con el que esta interactuando a la hora de realizar una tarea robótica.

1.4 Marco Teórico

A continuación, se detallan los términos y conceptos que más se utilizarán en este proyecto:

Cinemática Directa

La cinemática directa en robótica se enfoca en determinar la posición y orientación del efector final de un robot a partir de los valores conocidos de sus variables articulares. Este enfoque es esencial para mi tesis porque proporciona la base para predecir y controlar los movimientos del robot, asegurando que pueda interactuar correctamente con diversas superficies en un entorno industrial. El proceso implica el uso de longitudes de los eslabones y

ángulos de las articulaciones del robot para calcular su ubicación exacta en el espacio tridimensional. Para lograr esto, se aplican modelos matemáticos que describen la geometría del robot, utilizando matrices de transformación y coordenadas homogéneas. Entre los métodos más reconocidos para resolver la cinemática directa se encuentra el Convenio Denavit-Hartenberg (D-H), que estandariza la notación de las matrices de transformación, simplificando así los cálculos. La aplicación práctica de la cinemática directa es vital para el control y la programación de robots. Permite predecir y planificar los movimientos del robot para alcanzar posiciones deseadas con precisión. Esta capacidad es crucial en tareas como ensamblaje, soldadura y manipulación de objetos, donde la precisión y la repetibilidad de la posición del efector final son fundamentales. En el contexto de mi tesis, este conocimiento se aplica para desarrollar un sistema de predicción que permita al robot ajustar su comportamiento según el tipo de superficie con la que va a interactuar, mejorando así la eficiencia y efectividad de sus operaciones.[6]

Parámetros Denavit-Hartenberg (DH) en Robótica

Los parámetros Denavit-Hartenberg (DH) son una notación estándar utilizada en robótica para describir la geometría de un robot en términos de las posiciones y orientaciones relativas de sus eslabones y articulaciones. Estos parámetros simplifican el proceso de modelado cinemático de un robot, permitiendo una representación uniforme y sistemática de su estructura. Los cuatro parámetros DH son:

- Ángulo de Torsión
- Distancia de Enlace
- Ángulo de Enlace
- Desplazamiento de Enlace

Estos parámetros se utilizan para construir matrices de transformación homogénea que describen la posición y orientación de cada eslabón del robot en relación con el anterior, facilitando así el análisis y control del robot.[7]

Cinemática Inversa

La cinemática inversa es otro concepto fundamental que se utiliza en mi investigación. Esta rama de la cinemática se centra en determinar las variables articulares necesarias para que el efector final del robot alcance una posición y orientación específicas en el espacio tridimensional. Es complementaria a la cinemática directa y esencial para la programación de movimientos precisos en entornos dinámicos. Para resolver problemas de cinemática inversa, se utilizan métodos numéricos y algebraicos que permiten calcular los ángulos de las articulaciones o las extensiones lineales necesarias para posicionar el efector final en una ubicación deseada. Estos cálculos son críticos para ajustar el robot a las distintas superficies de contacto que encontrará en su entorno de trabajo, asegurando que pueda adaptar su comportamiento de manera óptima.[6]

Cinemática Diferencial

La cinemática diferencial en robótica se enfoca en el análisis de los movimientos infinitesimales de un robot y es fundamental para el desarrollo de mi tesis. Este campo describe cómo las velocidades de las articulaciones del robot se relacionan con la velocidad del efector final, que es la parte del robot que interactúa directamente con el entorno, como una pinza o una herramienta. Entender estas relaciones es crucial para predecir y ajustar los movimientos del robot en tiempo real, especialmente cuando interactúa con distintas superficies. La base de la cinemática diferencial radica en el uso del jacobiano, una matriz que relaciona las velocidades articulares con las velocidades lineales y angulares del efector final. Esta matriz se deriva de la relación entre las coordenadas articulares del robot y las coordenadas de su efector

final, obtenida a través de la cinemática directa. El jacobiano permite transformar vectores de velocidad en el espacio de las articulaciones al espacio cartesiano y viceversa, lo cual es esencial para controlar y ajustar el comportamiento del robot en diferentes escenarios. De esta manera, la cinemática diferencial se aplica en el control de robots, la planificación de trayectorias y la estimación de errores. En el control, permite diseñar esquemas que ajusten las velocidades articulares para seguir trayectorias deseadas del efector final. Este control es crucial para adaptar el robot a las diferentes superficies con las que interactuará. En la planificación de trayectorias, la cinemática diferencial ayuda a prever y evitar singularidades, asegurando movimientos suaves y eficientes, lo cual es indispensable para la precisión y repetibilidad en tareas repetitivas. En la estimación de errores, facilita la corrección de desviaciones en tiempo real, mejorando la robustez del sistema.[7]

Ecuación Dinámica de un robot

La Ecuación Dinámica de un robot es una representación matemática que describe el comportamiento del sistema robótico en términos de sus movimientos y las fuerzas o torques que actúan sobre él. Esta ecuación es fundamental para el control y análisis de robots, ya que permite predecir cómo responderá el robot ante diferentes comandos y condiciones externas.

$$\mathbf{M}(\mathbf{q})\ddot{\mathbf{q}} + \mathbf{C}(\mathbf{q}, \dot{\mathbf{q}})\dot{\mathbf{q}} + \mathbf{G}(\mathbf{q}) = \boldsymbol{\tau} \quad (1.1)$$

La matriz de inercia $\mathbf{M}(\mathbf{q})$ describe cómo la masa del robot está distribuida y cómo esta distribución cambia con la configuración del robot. La matriz de Coriolis $\mathbf{C}(\mathbf{q}, \dot{\mathbf{q}})$ representa los efectos de las fuerzas no lineales debidas al movimiento. El vector de fuerzas gravitatorias $\mathbf{G}(\mathbf{q})$ toma en cuenta la influencia de la gravedad sobre el robot, además de ello la letra $\boldsymbol{\tau}$ simboliza el vector de torques o fuerzas que actúan sobre el robot. Modelar un sistema robótico con esta ecuación permite diseñar algoritmos de control que aseguren movimientos precisos y estables del robot, compensando por las fuerzas dinámicas y garantizando el cumplimiento de

tareas específicas bajo diversas condiciones operativas. Es esencial para aplicaciones avanzadas de robótica, incluyendo manipuladores industriales, robots móviles y robots humanoides.[8]

Control de Fuerza del Efecto Final

El Control de Fuerza del Efecto Final en robótica es una técnica crítica para regular la interacción entre un robot y su entorno, y es fundamental para el desarrollo de mi tesis. Este tipo de control es esencial en aplicaciones donde el robot debe manipular objetos con precisión y delicadeza, como en tareas de ensamblaje, pulido, o manipulación de objetos frágiles. Entender y aplicar el control de fuerza es crucial para garantizar que el robot pueda interactuar adecuadamente con distintas superficies, ajustando su comportamiento según las características del entorno.[9] El efecto final, que es la parte del robot que interactúa directamente con el entorno, como una pinza, una herramienta de soldadura o una broca, necesita regular las fuerzas y torques que aplica. El control de fuerza asegura que estas interacciones sean adecuadas para la tarea en cuestión, evitando daños tanto al objeto manipulado como al propio robot. Para mi investigación, este control es esencial para desarrollar un sistema que permita al robot ajustar automáticamente su fuerza en función del tipo de superficie con la que interactúa.[8] Este control se logra mediante sensores de fuerza/torques instalados en el efecto final, que miden las fuerzas y momentos aplicados. Los datos recolectados por estos sensores son enviados a un controlador que ajusta los movimientos del robot en tiempo real para mantener las fuerzas dentro de los límites deseados. Este proceso es complejo, ya que requiere la integración de la cinemática y dinámica del robot con los modelos de interacción del entorno, lo que es esencial para que el robot pueda adaptarse a diferentes superficies de manera eficiente y segura.[9]

Existen varios métodos de control de fuerza, incluyendo el control por impedancia y el control por admisión, que son directamente aplicables a mi tesis. El control por impedancia

regula la relación entre la fuerza aplicada y la deformación del objeto, similar a un sistema masa-resorte-amortiguador. Este método es útil para tareas donde la precisión en la fuerza es crítica. Por otro lado, el control por admisión ajusta la velocidad del efector final en respuesta a las fuerzas medidas, facilitando la adaptación a entornos variables y no estructurados, que es un aspecto clave para manejar superficies de contacto diversas.[8]

En el contexto de investigación, estos métodos permitirán desarrollar un sistema predictivo y adaptativo que mejore la interacción del robot con diferentes superficies. Al implementar sensores de fuerza y algoritmos de control avanzados, el robot podrá ajustar su fuerza de manera autónoma, optimizando su desempeño en tareas repetitivas y reduciendo el riesgo de daños o errores.

1.4.1 Estado del Arte

Miembros robóticos supernumerarios multipropósito para uso industrial y Aplicaciones domésticas

En los últimos años, se han logrado avances importantes en la robótica, especialmente en el desarrollo de extremidades robóticas supernumerarias (SRLs). Un proyecto destacado fue desarrollado en el MIT por Davenport y Parietti, bajo la supervisión del Prof. Harry Asada, en colaboración con Boeing. Estas SRLs, diseñadas para la industria aeroespacial, cuentan con múltiples grados de libertad y pueden manejar cargas pesadas gracias al uso de actuadores elásticos en serie, lo que les permite distribuir el peso a las piernas del usuario y evitar la sobrecarga de brazos o espalda. Su diseño se basa en las características de los brazos humanos, en términos de torque y elasticidad. El control de estas extremidades utiliza filtros de Kalman para estimar con precisión la trayectoria de movimiento. Por otro lado, las extremidades supernumerarias portátiles (MSRL) se diseñaron para entornos industriales y domésticos donde las cargas son menores. Utilizan servomotores DC y el sistema AHRS de Madgwick para la

estimación de estado, lo que reduce la carga computacional en los microcontroladores, permitiendo que los MSRL sean más compactos y económicos que las SRLs. Estos avances son especialmente relevantes para la predicción de superficies de contacto en tareas robóticas repetitivas, tema central de mi tesis. La implementación de algoritmos de estimación y la integración de sensores son fundamentales para optimizar el rendimiento de los robots en diversos entornos industriales, como lo demuestra el uso de tecnologías avanzadas como los filtros de Kalman y el sistema AHRS.[10] [11]

Optimización del controlador basada en el aprendizaje para tareas robóticas repetitivas

El control dinámico en la automatización robótica se ha basado tradicionalmente en modelos, cuyo rendimiento depende de una representación precisa del sistema. No obstante, la creciente complejidad de los sistemas robóticos hace que esta modelización sea un desafío, lo que con frecuencia resulta en condiciones de operación subóptimas. Muchas aplicaciones industriales generan grandes cantidades de datos de movimiento repetitivo bajo estas condiciones, los cuales contienen información valiosa. Un sistema de automatización inteligente debe ser capaz de aprender de estos datos no óptimos para mejorar su funcionamiento. En respuesta a esta necesidad, se propone un algoritmo de optimización basado en aprendizaje para tareas robóticas repetitivas. Se diseña una función de coste que equilibra la precisión en el seguimiento de trayectorias y la suavidad del movimiento. El enfoque utiliza datos de movimiento para estimar el gradiente y la Hessiana, permitiendo la optimización sin depender de un modelo dinámico. Los experimentos realizados con un sistema de nano posicionamiento levitado magnéticamente demuestran la eficacia del algoritmo en tareas repetitivas. Este avance en la automatización robótica aprovecha los datos no óptimos para optimizar el control y mejorar la eficiencia del sistema, ofreciendo una alternativa a los métodos tradicionales basados en modelos, especialmente en sistemas donde la modelización precisa es compleja.[12]

Capítulo 2

2. Metodología

En este capítulo se describe la metodología utilizada para lograr los objetivos establecidos. Se exploran conceptos que incluyen los requisitos de diseño, las soluciones propuestas y el desarrollo actual del proyecto.

2.1 Requerimientos de Diseño

Para poder llevar a cabo la simulación que se tiene prevista se necesitarán los siguientes elementos que conforma la tabla mostrada a continuación:

Tabla 2.1

Requerimientos del diseño

Tipo de requerimiento	Detalles del requerimiento
Computación	<ul style="list-style-type: none"> • Una computadora con los recursos computacionales necesarios para poder llevar a cabo varios cálculos matemáticos. • Contar con el software de Matlab y de las librerías necesarias implicadas (Simscape).
De Control	<ul style="list-style-type: none"> • Contar con la programación suficiente para poder implementar el control en el robot a simular dentro del entorno virtual. • Software de Simulink y leve conocimiento de álgebra de bloques.

2.2 Selección de alternativas

2.2.1 Alternativa 1 – Árboles de Decisión

Los árboles de decisión son modelos no paramétricos utilizados para la clasificación y regresión en machine learning, estructurados de forma jerárquica, donde cada nodo representa una partición basada en una variable y cada rama conduce a una decisión. A medida que se avanza por las ramas, se clasifican los datos en subconjuntos hasta alcanzar un nodo terminal,

el cual contiene la clase o resultado final. La construcción de un árbol de decisión comienza con la selección de una variable que mejor divida el conjunto de datos en cada paso, utilizando algoritmos como la partición binaria recursiva. Luego, para evitar el sobreajuste y mejorar la generalización del modelo, se realiza un proceso de poda, donde se eliminan ramas que no aportan significativamente a la clasificación. Este proceso de división y poda asegura que el modelo sea más preciso y eficiente, utilizando métricas como la entropía o el índice Gini para evaluar la calidad de las divisiones.[13]

2.2.2 Alternativa dos – Redes Neuronales

Las redes neuronales artificiales son modelos de procesamiento de información inspirados en el funcionamiento del cerebro humano, caracterizados por su estructura no lineal y su capacidad para aprender y adaptarse a nuevas situaciones. Estas redes se componen de unidades simples llamadas neuronas, organizadas en capas, y tienen la habilidad de modificar sus conexiones sinápticas en función de la experiencia, lo que les otorga plasticidad y tolerancia a fallos. Las redes neuronales son útiles en el reconocimiento de patrones, especialmente en problemas complejos que involucran datos no lineales. El proceso de implementación de una red neuronal implica la creación de una estructura multicapa donde las señales se transmiten de una capa de entrada a una capa de salida, con capas ocultas intermedias que procesan la información. Durante el entrenamiento, las conexiones sinápticas se ajustan mediante el aprendizaje supervisado o no supervisado, con el objetivo de minimizar el error entre la salida deseada y la obtenida. Este enfoque iterativo permite que las redes aprendan y generalicen para tareas como la clasificación y la predicción de datos complejos.[14]

2.2.3 Alternativa tres – CatBoost Classifier

CatBoost Classifier es un algoritmo de aprendizaje automático basado en el método de boosting de gradiente, diseñado específicamente para manejar de manera eficiente características categóricas, lo que lo hace especialmente útil en problemas donde los datos

incluyen variables no numéricas. Al igual que otros métodos de boosting, *CatBoost* construye múltiples árboles de decisión de manera secuencial, donde cada nuevo árbol corrige los errores cometidos por los árboles anteriores. Sin embargo, lo que diferencia a *CatBoost* de otros algoritmos es su enfoque innovador para gestionar variables categóricas y su capacidad para evitar el sobreajuste sin necesidad de preprocesamiento extenso de los datos. El algoritmo implementa técnicas avanzadas que minimizan el sesgo y la variación en el proceso de entrenamiento, lo que resulta en un modelo robusto y preciso, incluso con datos ruidosos. *CatBoost* es particularmente eficaz en aplicaciones como la clasificación y regresión, y se destaca por su facilidad de uso y eficiencia computacional en comparación con otros algoritmos de boosting. Este enfoque le permite ser ampliamente utilizado en diversas áreas, como la predicción de aprobaciones de préstamos, promociones de personal, y otras tareas de análisis predictivo donde se involucran datos complejos.[15]

2.3 Selección de alternativa para solución al problema

Dada la efectividad del algoritmo de clasificación *CatBoost*, se lo eligió para dar solución al problema. La elección no solo se debió a que es un modelo de *machine learning* que permitió trabajar con grandes volúmenes de datos y garantizar su convergencia en la mayoría de los casos al clasificar distintas categorías, sino también porque fue más sencillo de aplicar en comparación con una red neuronal y, a su vez, más elaborado que un árbol de decisiones, el cual no es tan robusto.

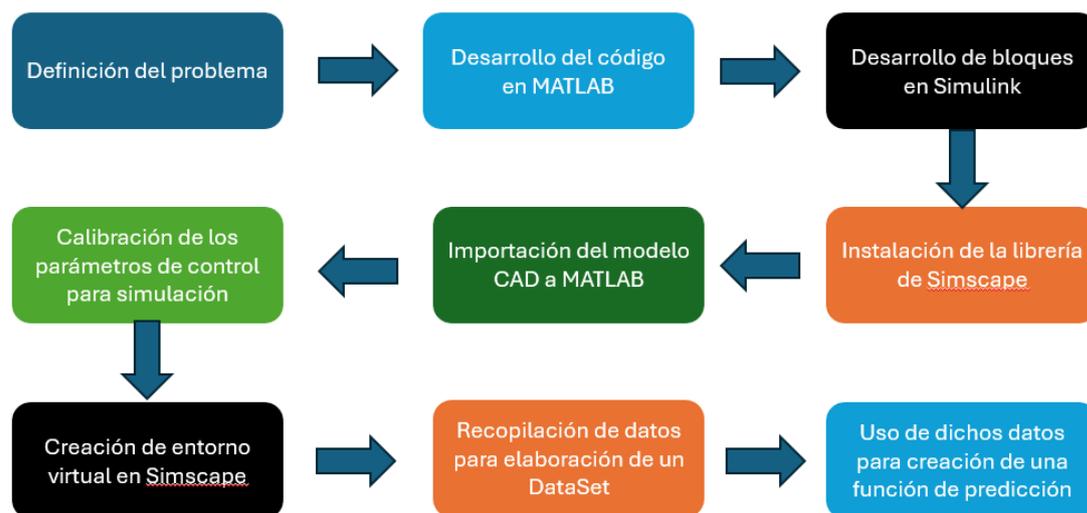
2.4 Metodología de diseño

Para llevar a cabo la simulación primero se planteó el problema a resolver, seguido de ello se elaboró un código en MATLAB que permitiera manipular los parámetros y demás subyacentes que implica el control de un robot para realizar una tarea. Para ello también se crearon otros *scripts* y demás funciones dentro del programa que permitieron establecer parámetros de control para la simulación que se lleva a cabo. A su vez se hizo uso de la

herramienta de Simulink y sus librerías (en especial Simscape que precisamente permite crear virtualmente objetos con los cuales puede interactuar el robot durante la simulación) con el fin de representar el sistema a trabajar de la mejor manera posible, una vez que se tuvo el ambiente virtual listo para simular las condiciones a las cuales el robot sería expuesto se procedió a tomar datos de estas con el fin de eventualmente crear una función de predicción.

Figura 2.1.

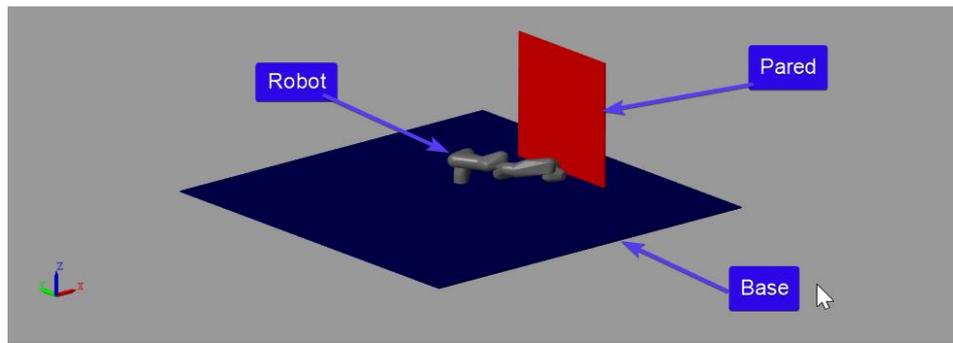
Diagrama de proceso de metodología



2.5 Diseño conceptual

Como se puede apreciar en la figura adjunta más abajo el entorno de simulación que se realizó representa a un robot una base de apoyo que representa al suelo y una pared con la cual más tarde el autómata tendrá que interactuar con el fin de recolectar los datos necesarios en la simulación.

Figura 2.2. Ilustración de entorno virtual llevado a cabo en Simscape



2.6 Cálculos representativos

Para poder realizar la simulación se tuvo que llevar a cabo cálculos de cinemática directa, cinemática inversa y parametrización de trayectorias. Así mismo se hizo uso de bloques en Simulink para poder representar todas las operaciones mencionadas anteriormente y demás.

2.7 Simulaciones

Se realizaron numerosas simulaciones en las cuales se pudo recopilar la información necesaria a través de los datos que se iban generando con cada iteración e interacción con el entorno virtual.

Capítulo 3

3. Resultados y análisis

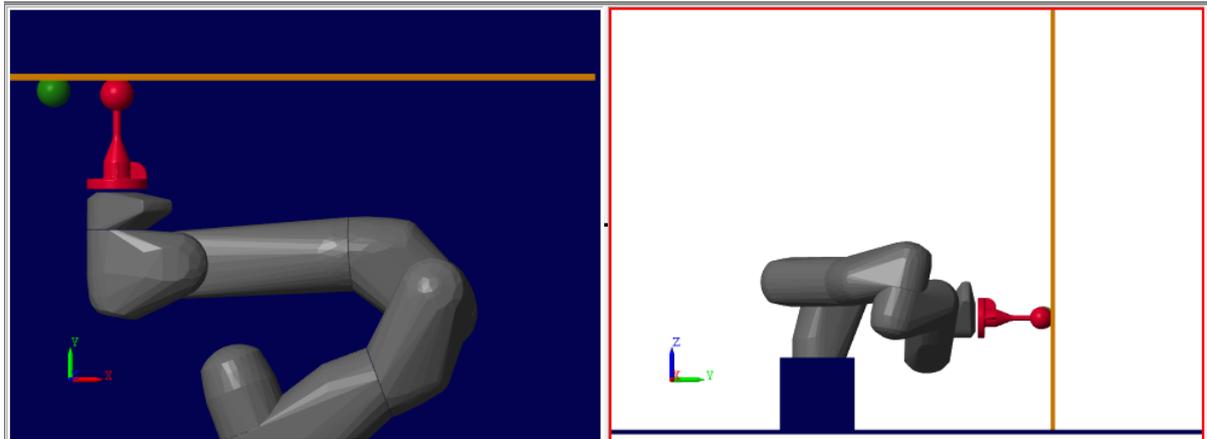
Después de aplicar la metodología mencionada en el capítulo anterior se tomaron en cuenta varios materiales para llevar a cabo diferentes simulaciones y extraer datos de ella para la creación de un *DataSet*. Para visualizar dichos resultados utilizamos gráficas superpuestas una encima de otra por cada material, en cada una de ellas se tiene un título con las iniciales T1 S1, que representan la tarea que estaba realizando el robot en dicha simulación (en este caso la tarea 1 es lijar) y el número de la simulación en donde esto ocurrió respectivamente.

Tabla 3.1.

Densidades relativas al Acero

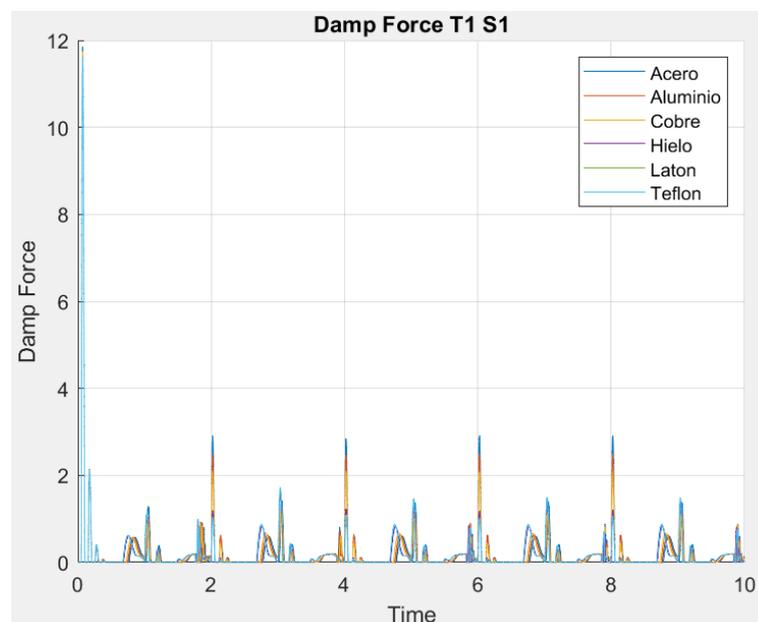
Material	Densidad [Kg/m3]	μ_s	μ_k
Acero	7850	0.74	0.57
Aluminio	2699	0.61	0.47
Cobre	8960	0.53	0.36
Hielo	920	0.028	0.09
Latón	8400	0.51	0.44
Teflón	2200	0.04	0.04

Nota. En las simulaciones que se llevaron a cabo el efector final del robot interactuó con cada uno de estos materiales.

Figura 3.1.*Robot interactuando con material*

Nota. Los datos de coeficientes de fricción y densidad se los ingresó al software para que se configure el entorno virtual acorde a lo requerido.

Después de realizar 21 simulaciones por cada material para las dos tareas que tenía previsto realizar el robot se obtuvieron los siguientes resultados, para los cuales siempre el eje horizontal representa el tiempo medido en segundos y el eje vertical la correspondiente unidad del sistema internacional para la variable, si se trata de fuerza es el Newton:

Figura 3.2.*Fuerza de Amortiguamiento de los 6 materiales*

Al analizar la fuerza de amortiguamiento, se observa que las fluctuaciones entre los diferentes materiales son mínimas. Esto indica la necesidad de examinar otras variables que puedan ofrecer una mayor diferenciación entre ellos.

Figura 3.3.

Fuerza de fricción en eje "X" de los 6 materiales

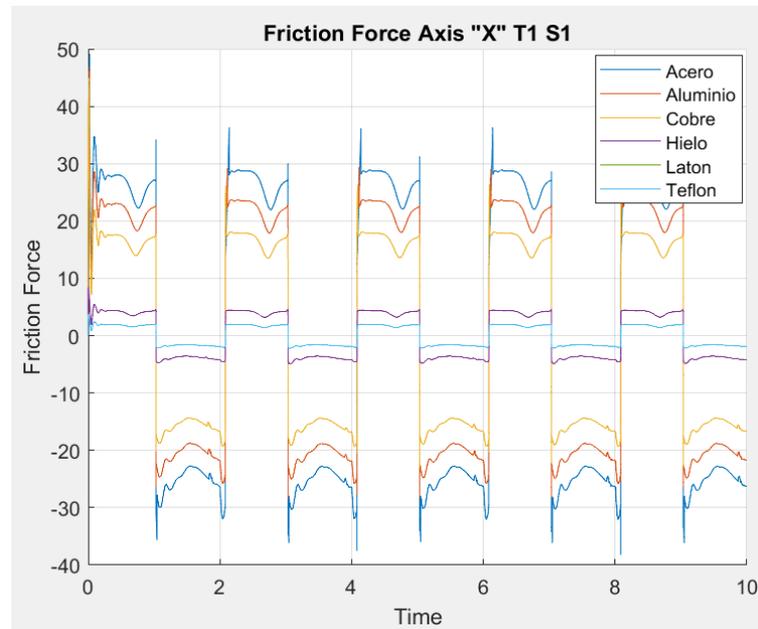


Figura 3.4.

Fuerza de fricción en eje "Y" de los 6 materiales

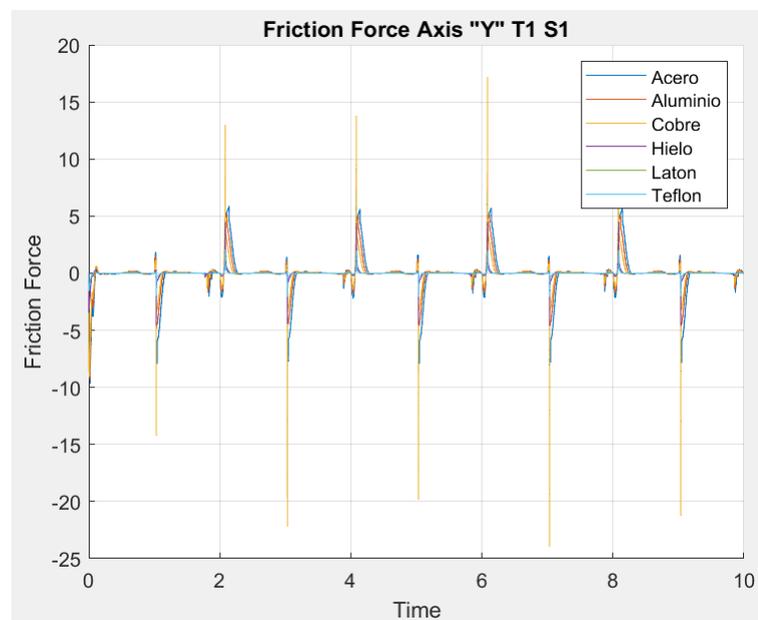
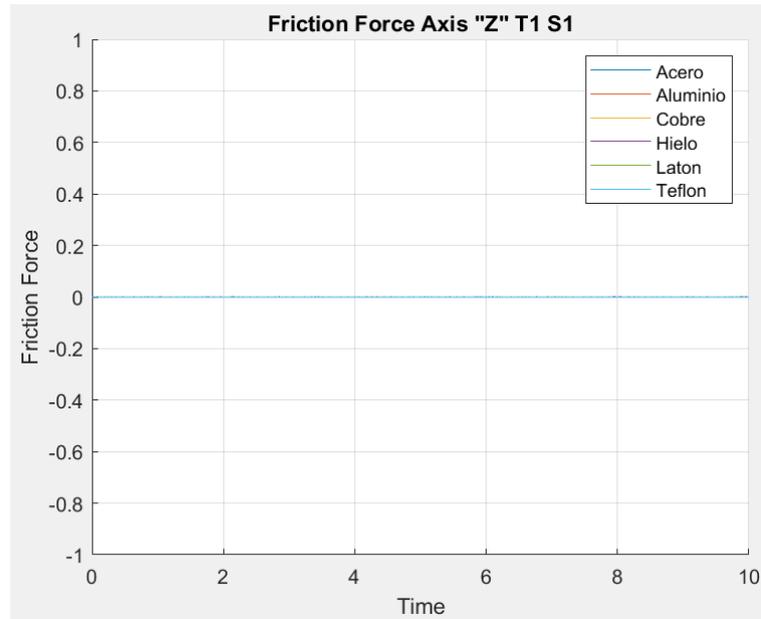


Figura 3.5.

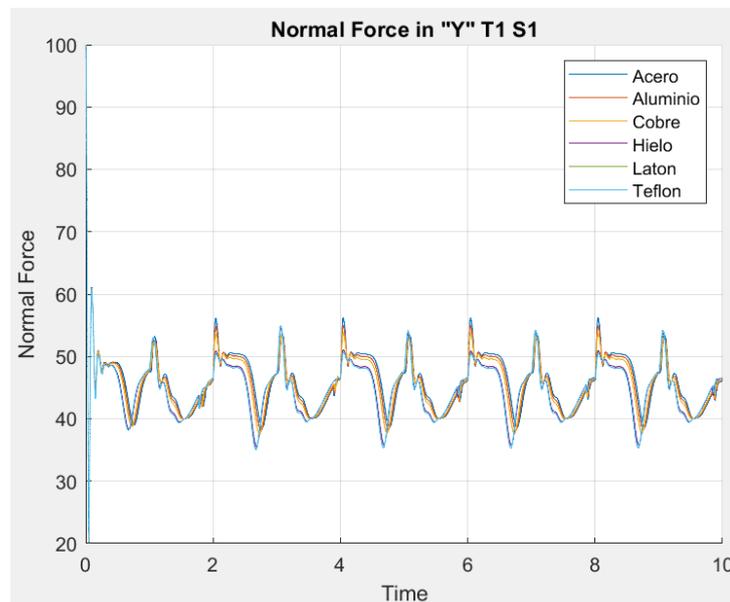
Fuerza de fricción en eje "Z" de los 6 materiales



Las gráficas de la fuerza de fricción en los tres ejes revelan que el eje "X" es el más relevante, ya que permite diferenciar entre los materiales, aunque el latón y el teflón muestran valores similares. Era de esperarse que el eje "X" proporcionara resultados más significativos, dado que el movimiento en la tarea impuesta ocurre principalmente en dicho eje.

Figura 3.6.

Fuerza Normal a superficie de contacto



La gráfica muestra que la fuerza normal en el eje "Y" es similar para acero, aluminio, cobre, hielo, latón y teflón, con oscilaciones periódicas entre 40 y 60 Newtons. Las diferencias entre materiales son mínimas, indicando que el eje "Y" no es un factor clave para diferenciarlos en esta tarea.

Figura 3.7.

Aceleración del punto de contacto en eje "X"

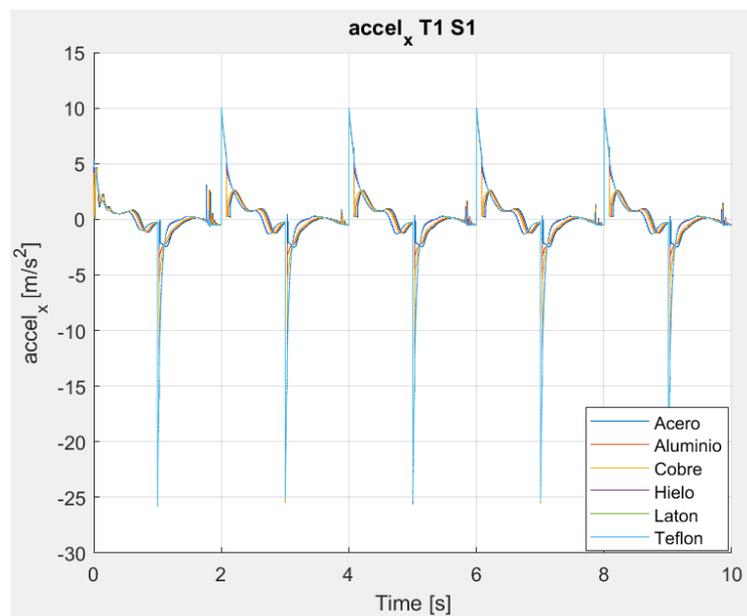


Figura 3.8.

Aceleración del punto de contacto en eje "Y"

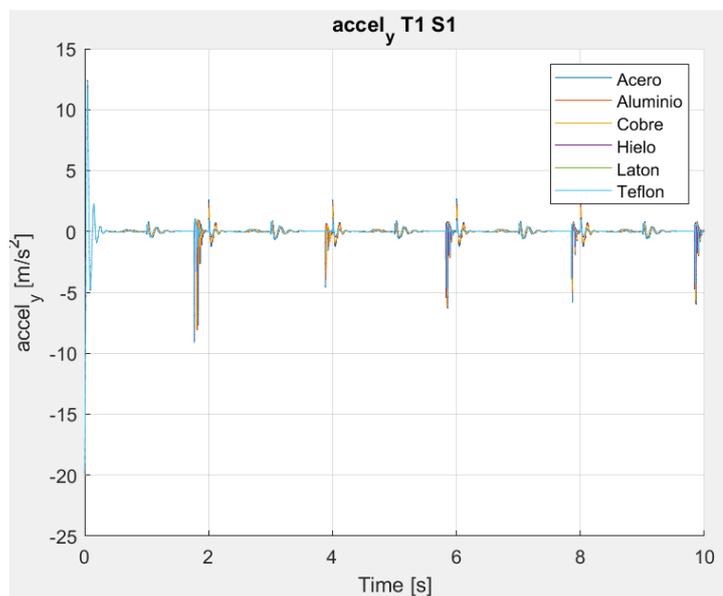
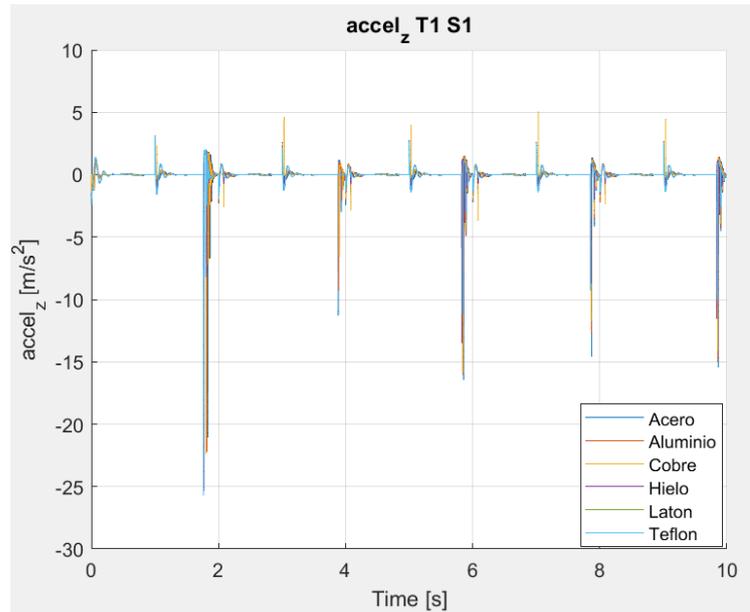


Figura 3.9.

Aceleración del punto de contacto en eje "Z"



Las gráficas de aceleración muestran que el eje "X" presenta las mayores variaciones entre materiales, destacando el comportamiento del acero. En los ejes "Y" y "Z", las diferencias son mínimas y los patrones similares, indicando que las variaciones significativas de aceleración ocurren principalmente en el eje "X".

Figura 3.10.

Aceleración angular del punto de contacto en eje "X"

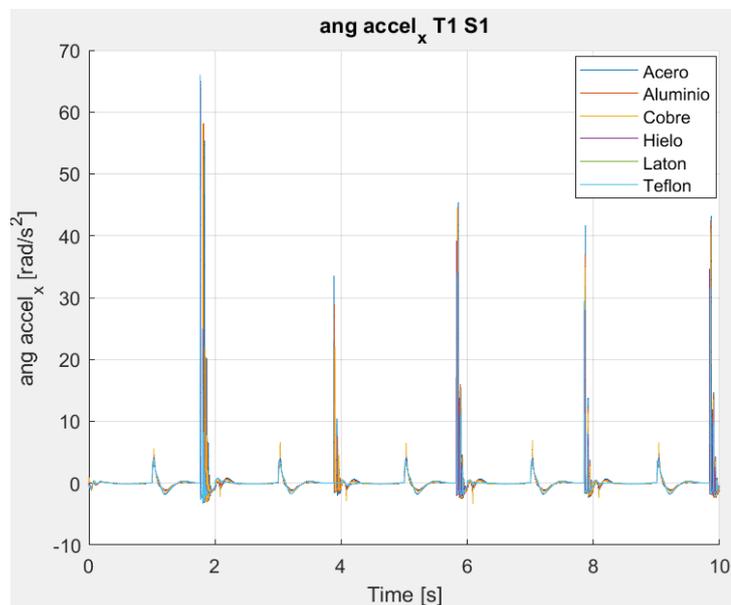
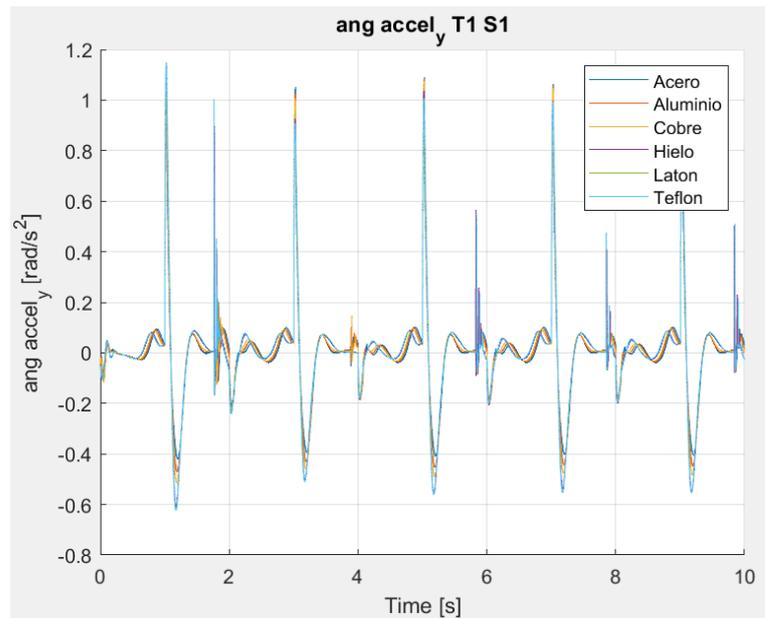
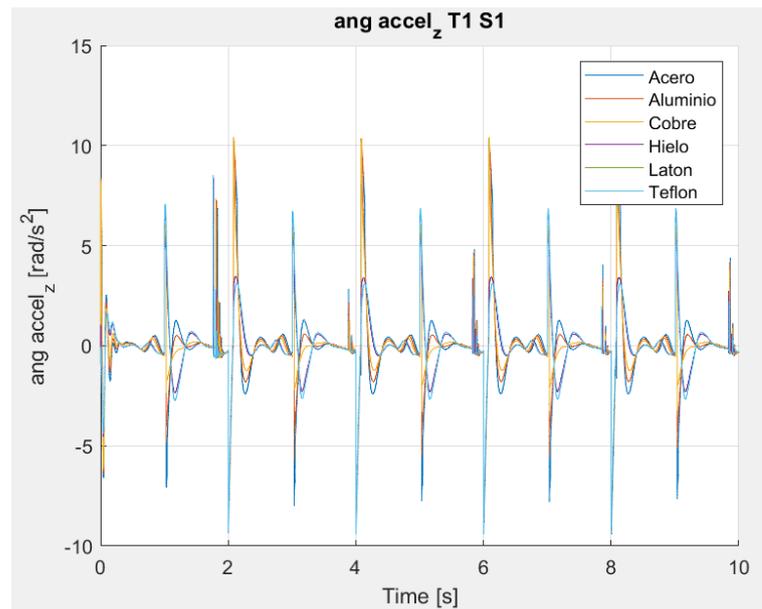


Figura 3.11.

Aceleración angular del punto de contacto en eje "Y"

**Figura 3.12.**

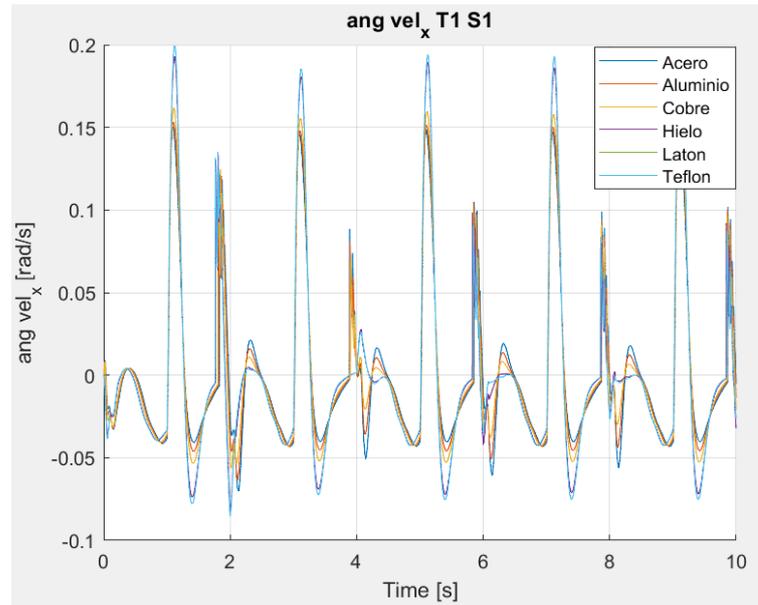
Aceleración angular del punto de contacto en eje "Z"



Las aceleraciones angulares en los ejes "X", "Y", y "Z" muestran fluctuaciones mínimas y patrones similares entre materiales. Aunque pueden complementar el análisis, estas variaciones no parecen ser determinantes para la clasificación. Se considera su incorporación, pero otras variables probablemente tendrán mayor relevancia en la clasificación final.

Figura 3.13.

Velocidad angular del punto de contacto en eje "X"

**Figura 3.14.**

Velocidad angular del punto de contacto en eje "Y"

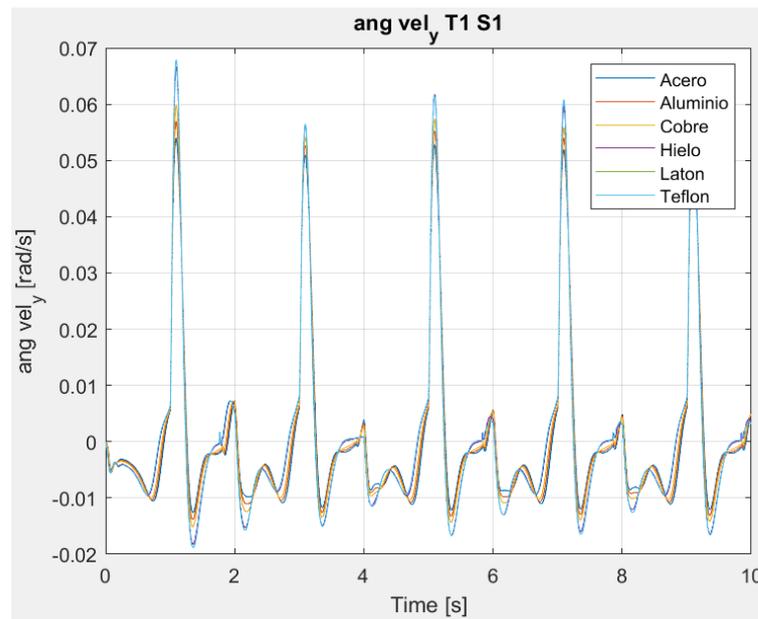
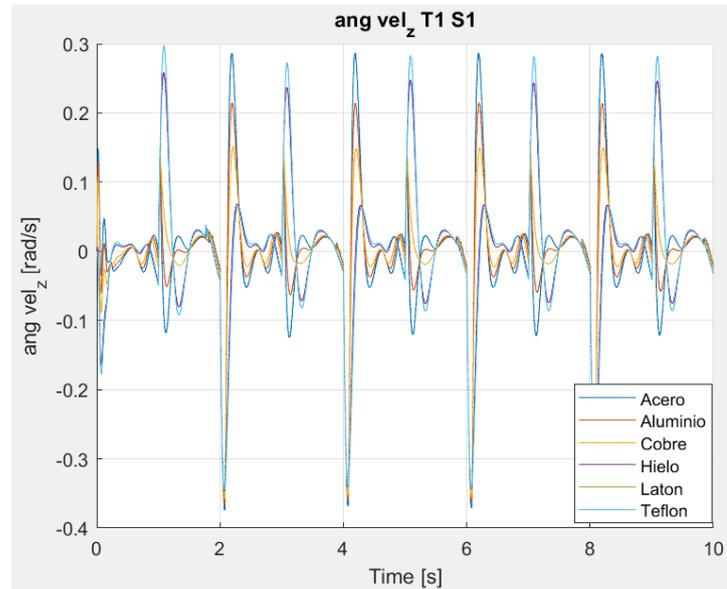


Figura 3.15.

Velocidad angular del punto de contacto en eje "Z"



Las velocidades angulares en los ejes “X”, “Y”, y “Z” presentan comportamientos cíclicos regulares con diferencias mínimas entre los materiales. Estos patrones sugieren que las variaciones en la velocidad angular no aportan información significativa para diferenciar materiales, siendo variables complementarias en el análisis general, pero no decisivas.

Figura 3.16.

Posición en "X" del punto de contacto

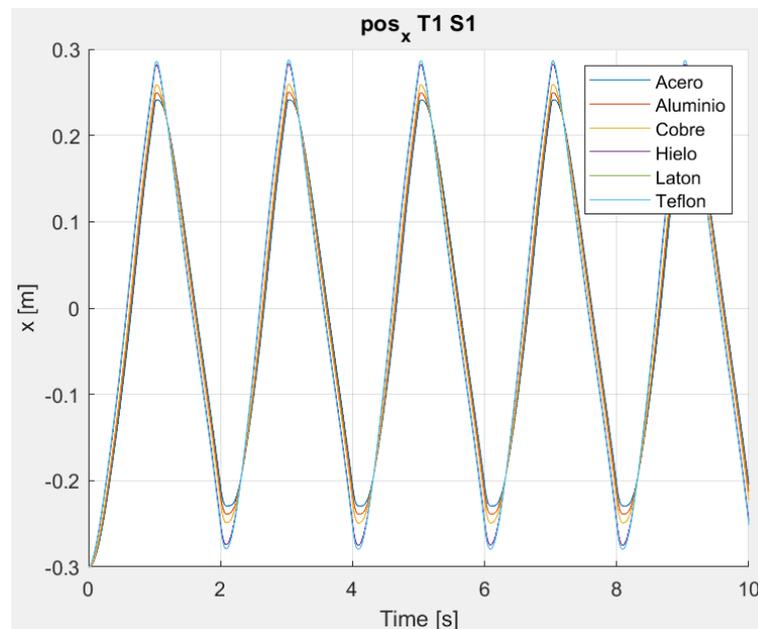
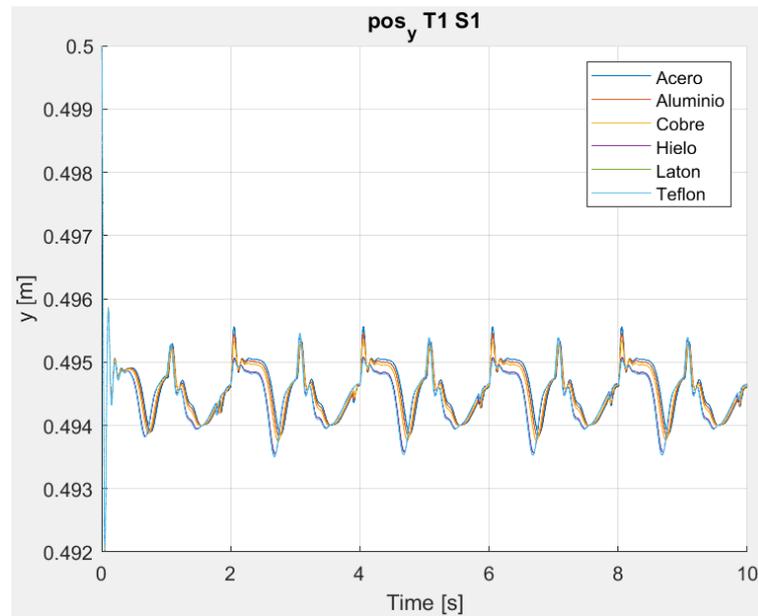
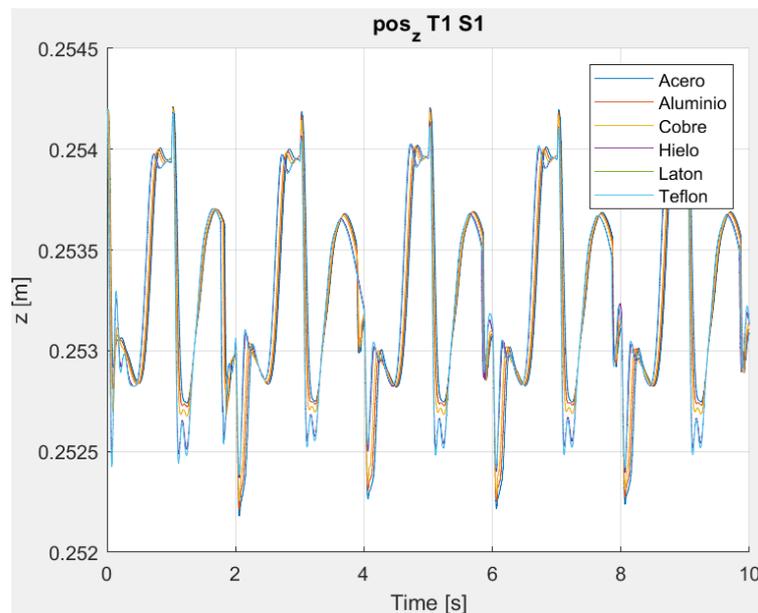


Figura 3.17.

Posición en "Y" del punto de contacto

**Figura 3.18.**

Posición en "Z" del punto de contacto



Las gráficas muestran la posición en los ejes "X", "Y", y "Z" para distintos materiales. En el eje "X", el patrón es sinusoidal con amplitudes similares entre materiales. En los ejes

“Y”, y “Z”, las variaciones son mínimas, mostrando ligeras fluctuaciones, pero con diferencias insignificantes entre los materiales.

Figura 3.19.

Velocidad en "X" del punto de contacto

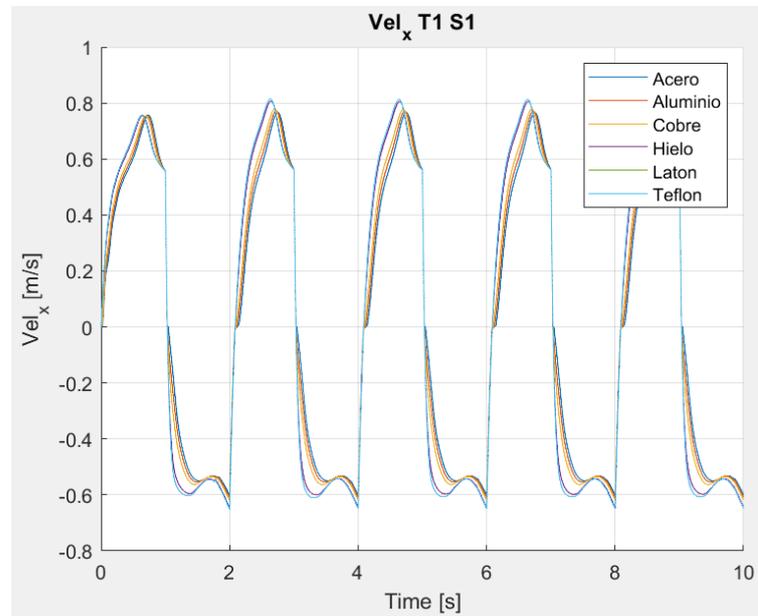


Figura 3.20.

Velocidad en "Y" del punto de contacto

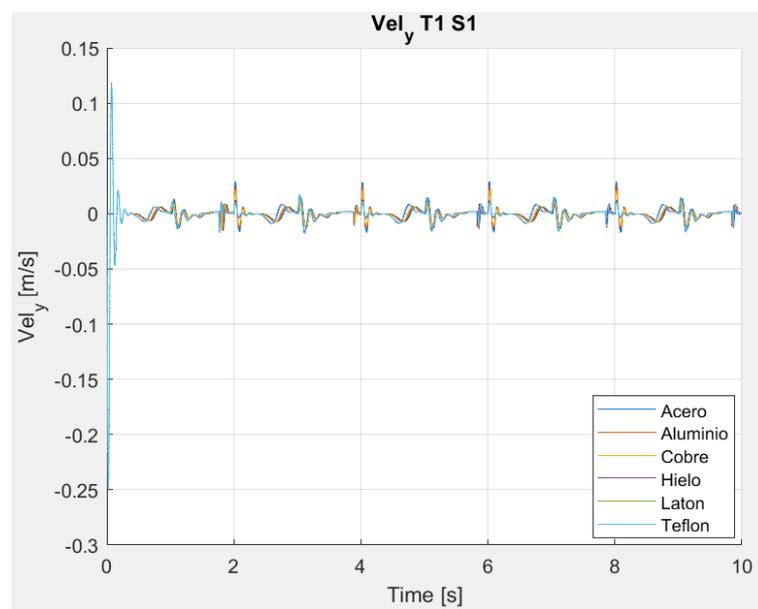
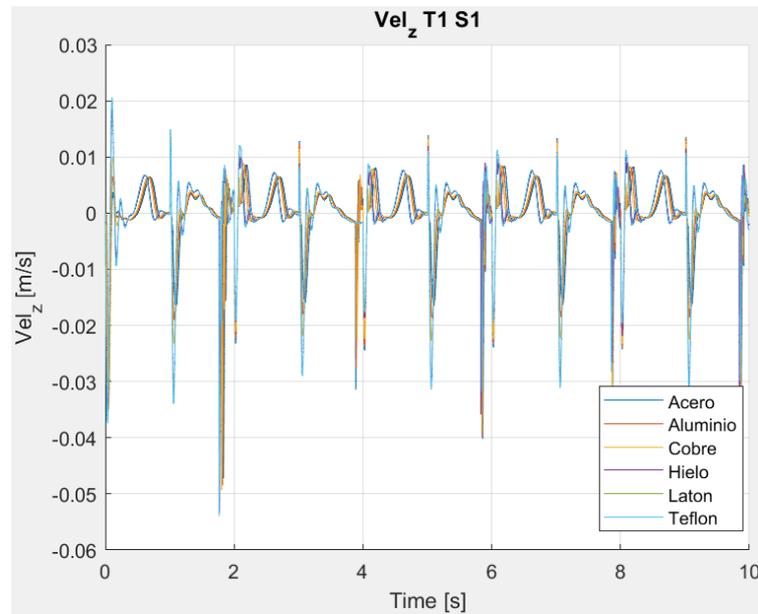


Figura 3.21.

Velocidad en "Z" del punto de contacto



Las gráficas de velocidad en los ejes “X”, “Y”, y “Z” muestran un comportamiento cíclico. En el eje “X”, las variaciones son más pronunciadas, con amplitudes mayores y bien definidas. En los ejes “Y” y “Z”, las fluctuaciones son mucho más pequeñas y los cambios entre materiales son mínimos, indicando poca variabilidad.

Figura 3.22.

Componente 1 de Quaternión en punto de contacto

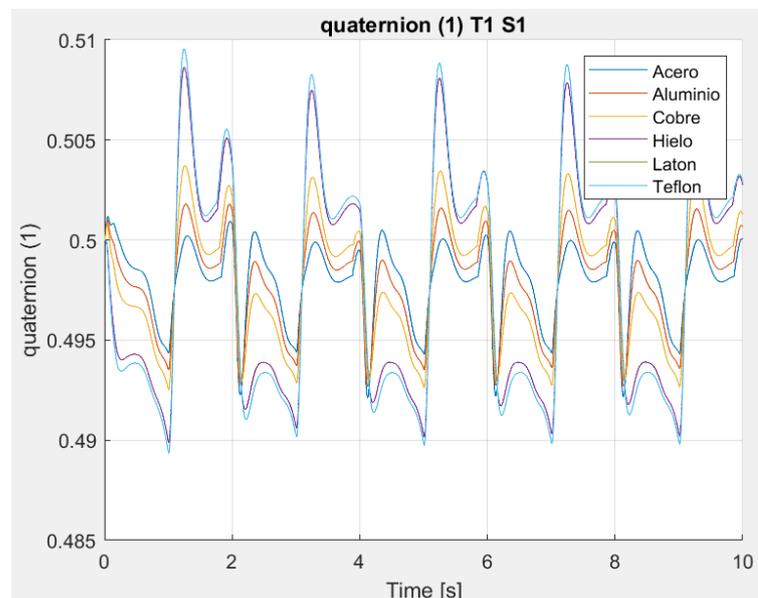
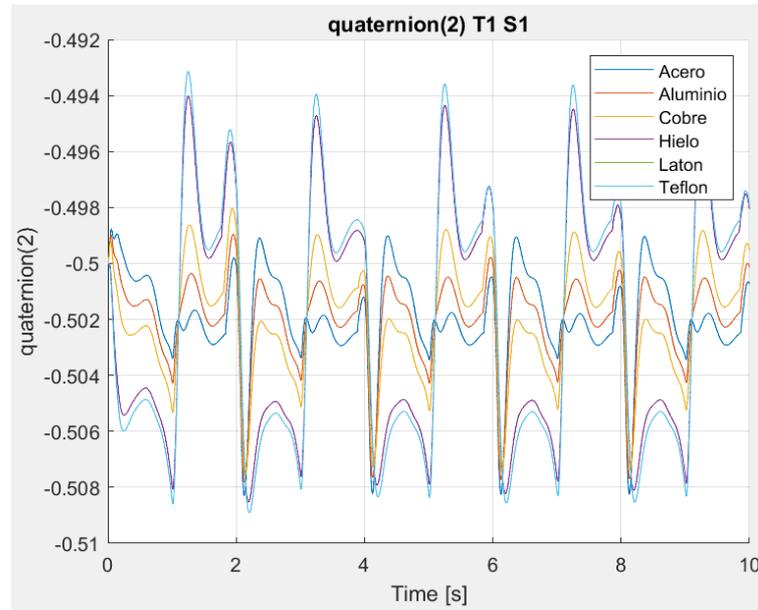


Figura 3.23.

Componente 2 de Quaternión en punto de contacto

**Figura 3.24.**

Componente 3 de Quaternión en punto de contacto

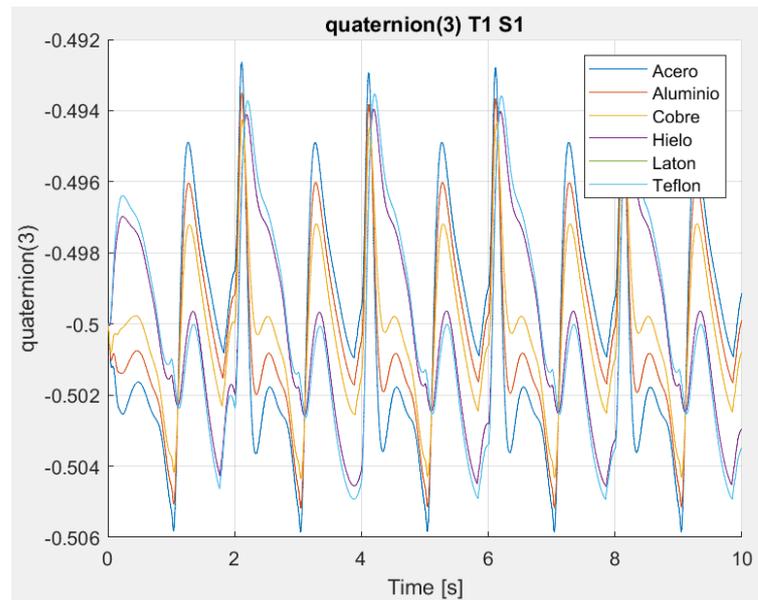
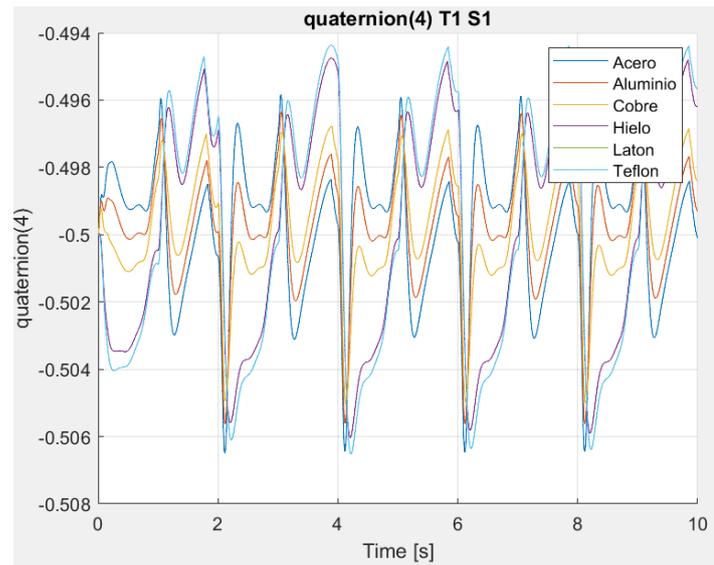


Figura 3.25.*Componente 4 de Cuaternión en punto de contacto*

Las gráficas de los cuaterniones 1, 2, 3 y 4 muestran un comportamiento cíclico con patrones consistentes entre los materiales. Aunque existen ligeras diferencias en las amplitudes de los picos, especialmente entre materiales como hielo y acero, las variaciones son mínimas, lo que indica una similitud general en el comportamiento rotacional para todos los materiales.

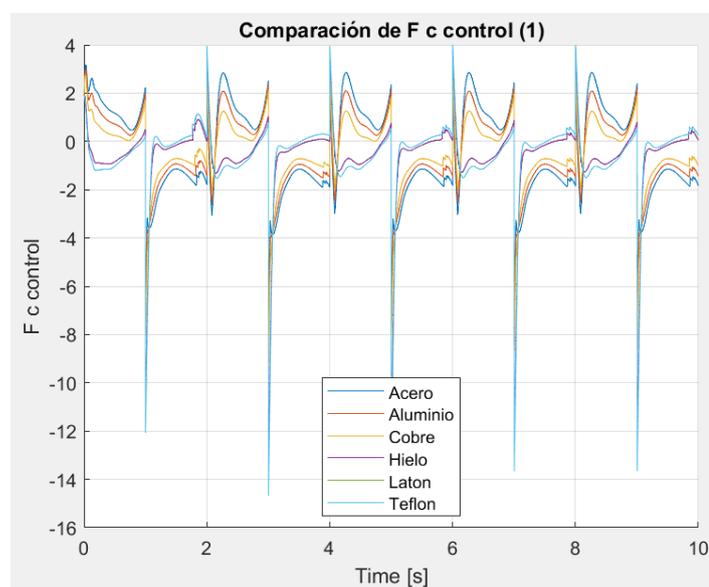
Figura 3.26.*Fuerza de control en eje "X"*

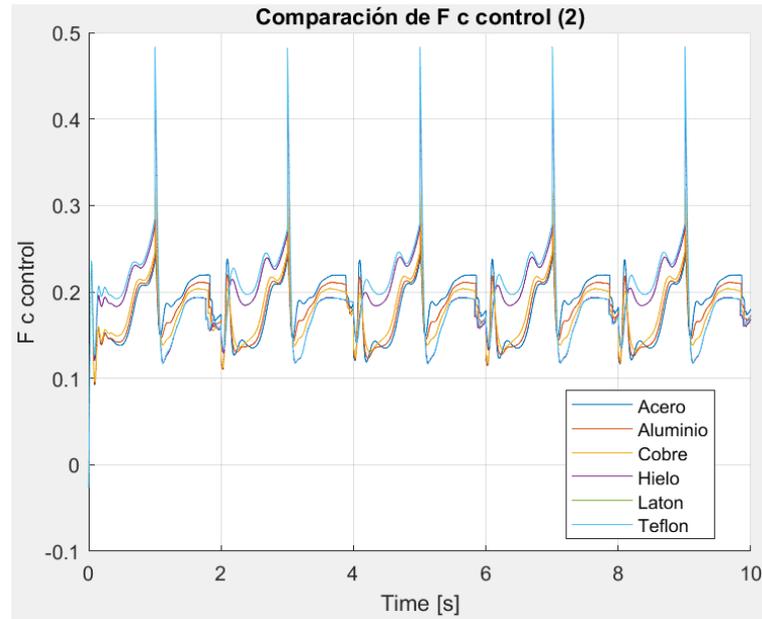
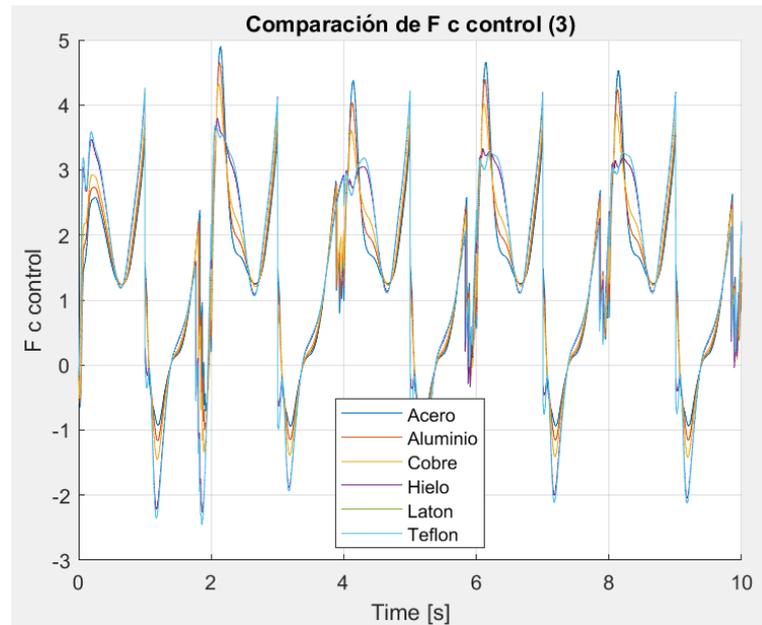
Figura 3.27.*Fuerza de control en eje "Y"***Figura 3.28.***Fuerza de control en eje "Z"*

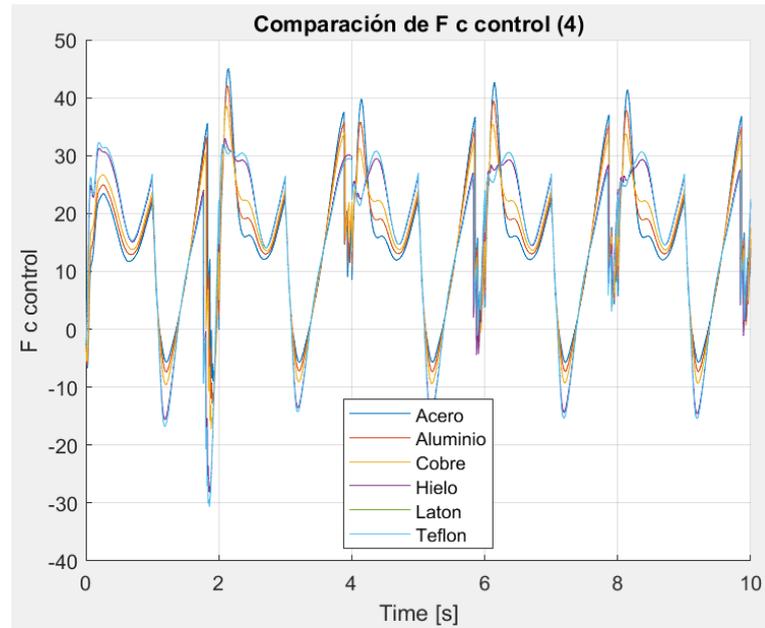
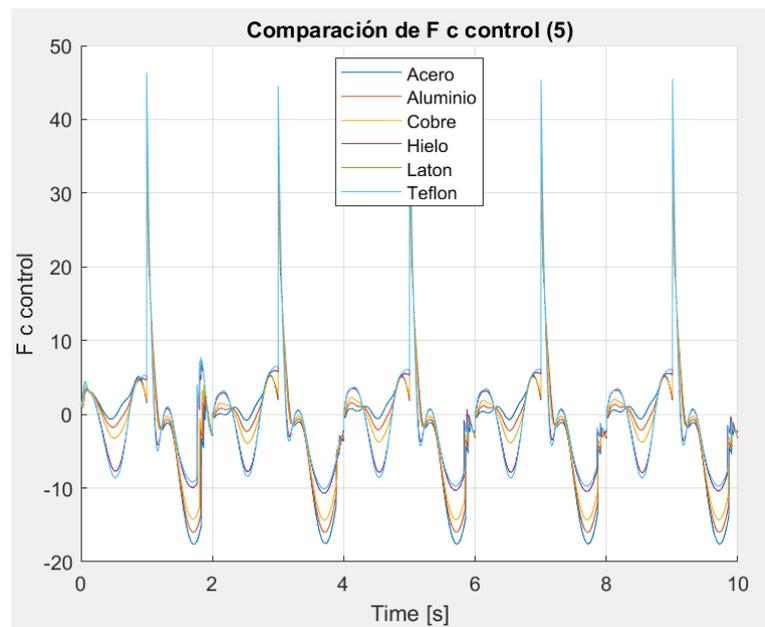
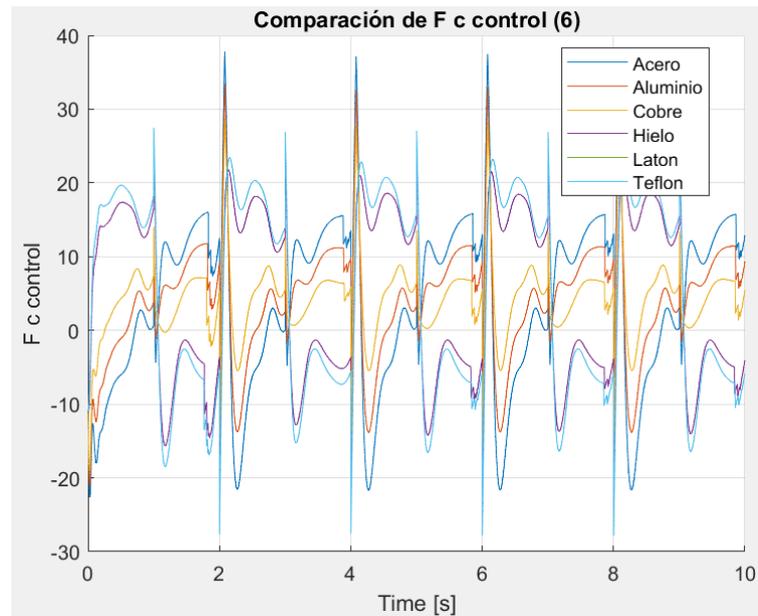
Figura 3.29.*Torque de control en eje "X"***Figura 3.30.***Torque de control en eje "Y"*

Figura 3.31.*Torque de control en eje "Z"*

Las seis gráficas muestran componentes de fuerzas y momentos en los ejes "X", "Y", y "Z" para distintos materiales. Aunque las fluctuaciones son cíclicas, se observan diferencias entre los materiales, especialmente en la amplitud de los picos y valles. El acero presenta las mayores variaciones, mientras que el hielo y el latón muestran comportamientos más uniformes.

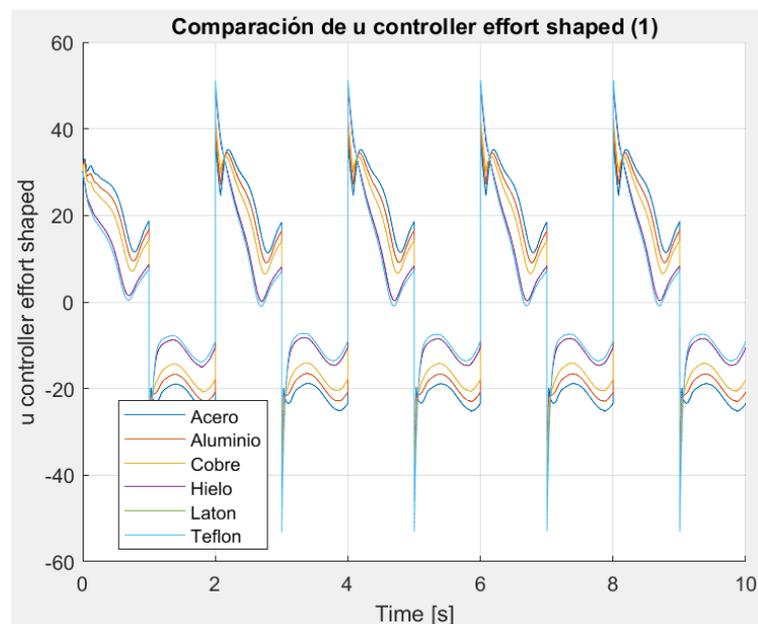
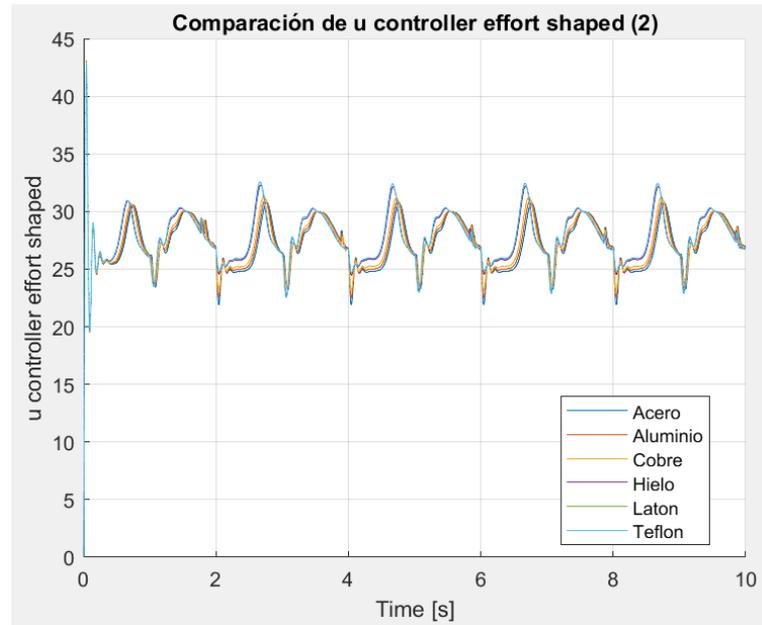
Figura 3.32.*Fuerza de controlador esfuerzo en forma en "X"*

Figura 3.33.

Fuerza de controlador esfuerzo en forma en "Y"

**Figura 3.34.**

Fuerza de controlador esfuerzo en forma en "Z"

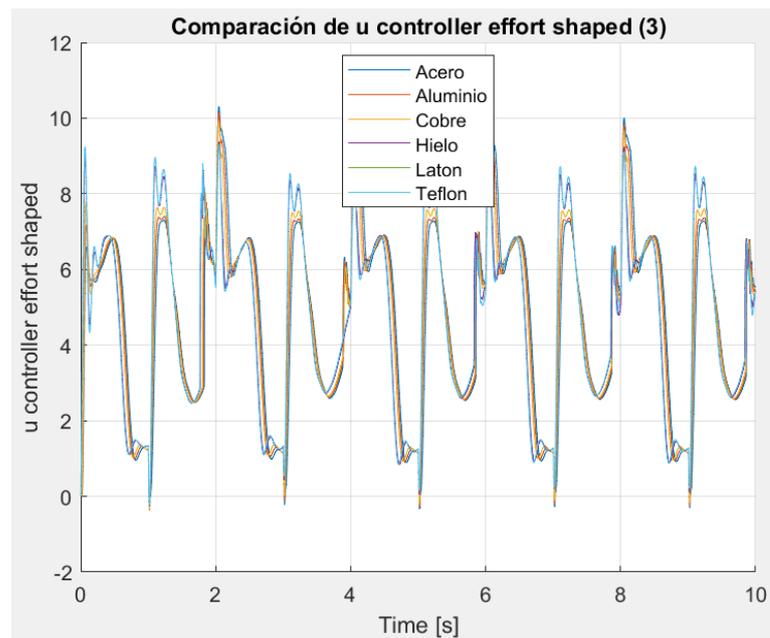
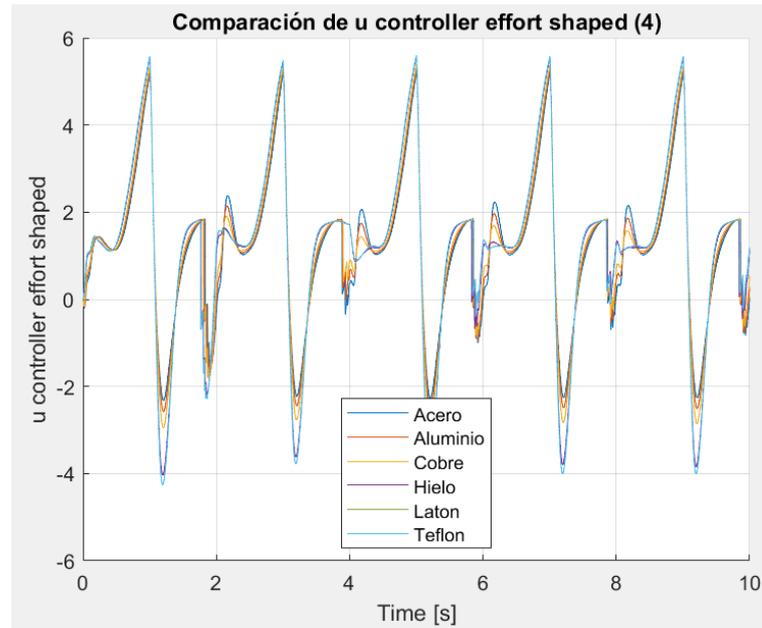


Figura 3.35.

Torque de controlador esfuerzo en forma en "X"

**Figura 3.36.**

Torque de controlador esfuerzo en forma en "Y"

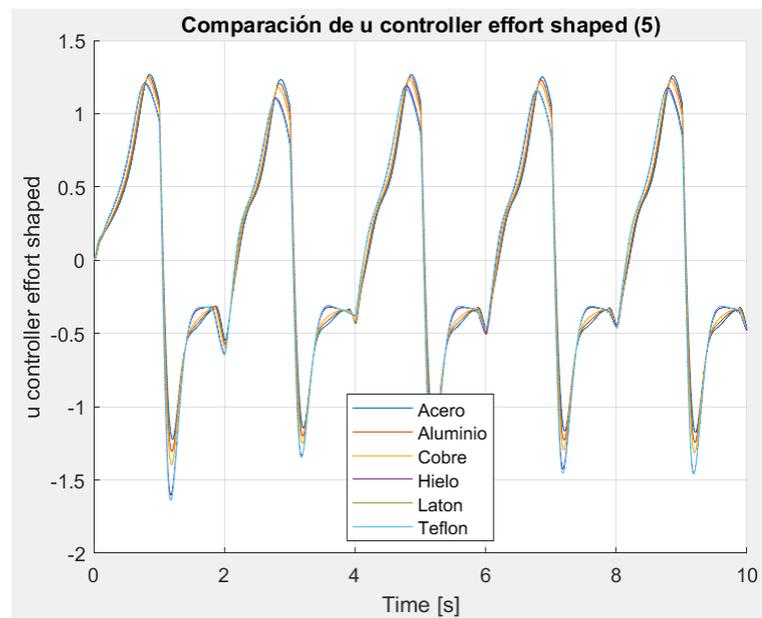
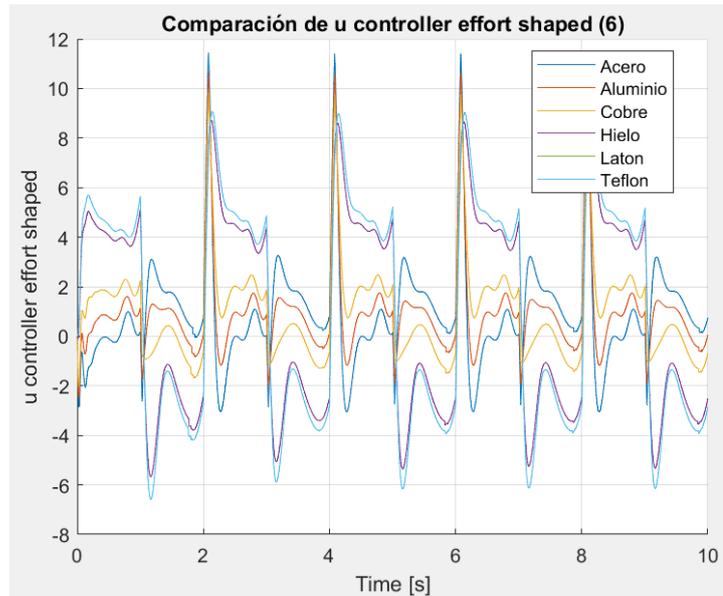


Figura 3.37.

Torque de controlador esfuerzo en forma en "Z"



Las gráficas muestran los componentes de esfuerzo del controlador para diferentes materiales en los ejes "X", "Y", y "Z". Los patrones son cíclicos con ligeras variaciones en amplitud y forma entre materiales. El acero y el hielo presentan las mayores diferencias, mientras que el latón y el teflón exhiben comportamientos más consistentes y menos fluctuantes.

Figura 3.38.

Fuerza de controlador esfuerzo en "X"

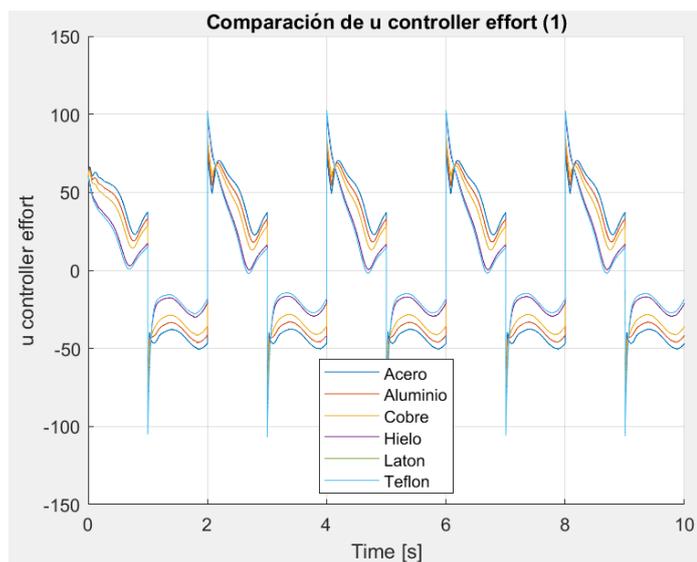
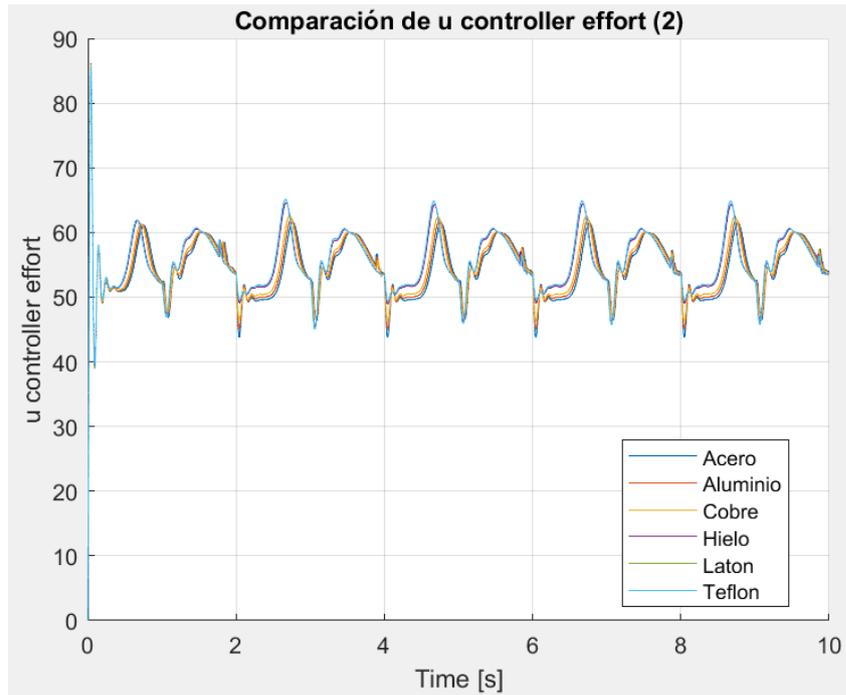


Figura 3.39.

Fuerza de controlador esfuerzo en "Y"

**Figura 3.40.**

Fuerza de controlador esfuerzo en "Z"

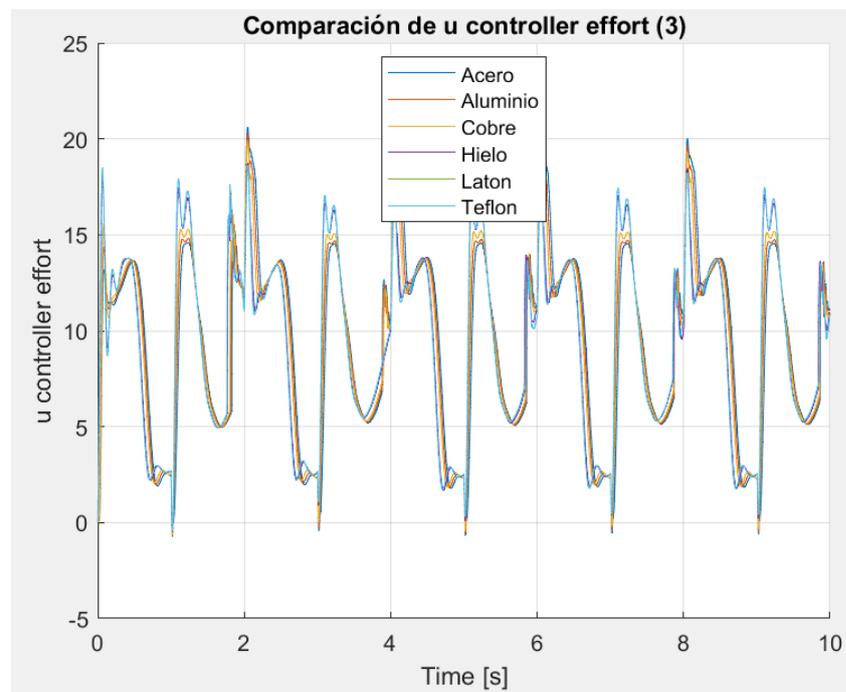
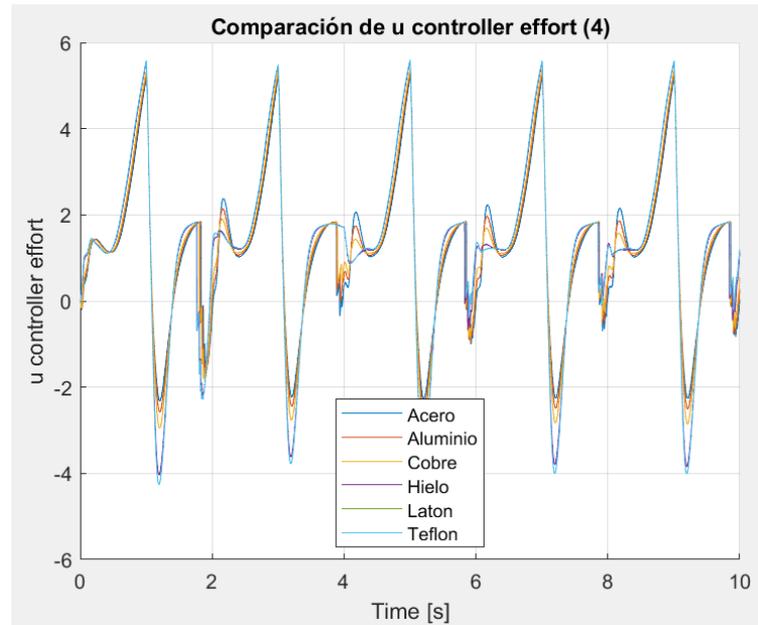


Figura 3.41.

Momento de controlador esfuerzo en "X"

**Figura 3.42.**

Momento de controlador esfuerzo en "Y"

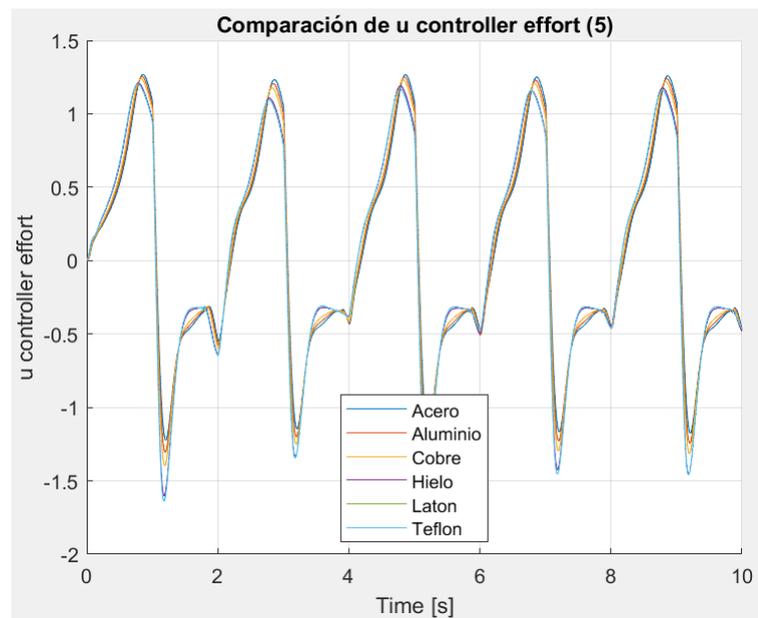
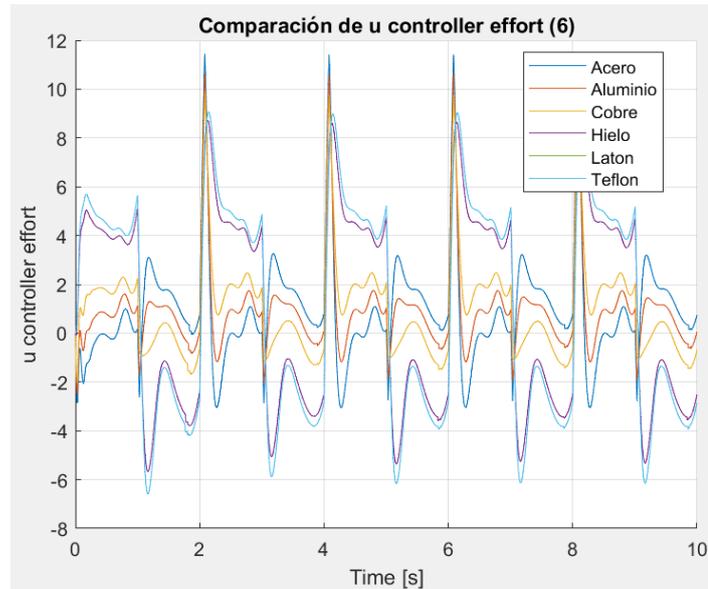


Figura 3.43.*Momento de controlador esfuerzo en "Z"*

Las gráficas de esfuerzo del controlador muestran fluctuaciones cíclicas en los ejes "X", "Y", y "Z" para distintos materiales. Los valores varían significativamente, especialmente en el acero y el hielo, que presentan picos más pronunciados. Otros materiales como el cobre y el latón muestran comportamientos más uniformes, con menor amplitud en los picos.

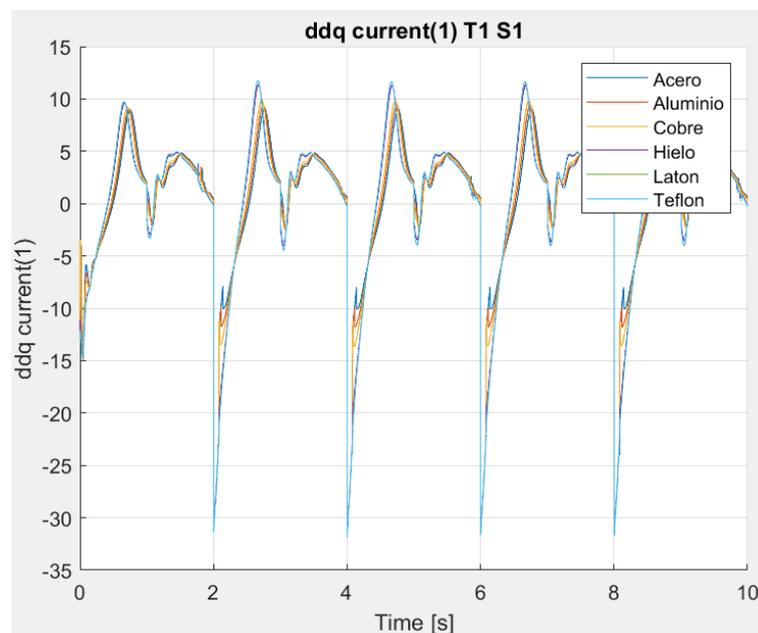
Figura 3.44.*Aceleración articular de la junta #1*

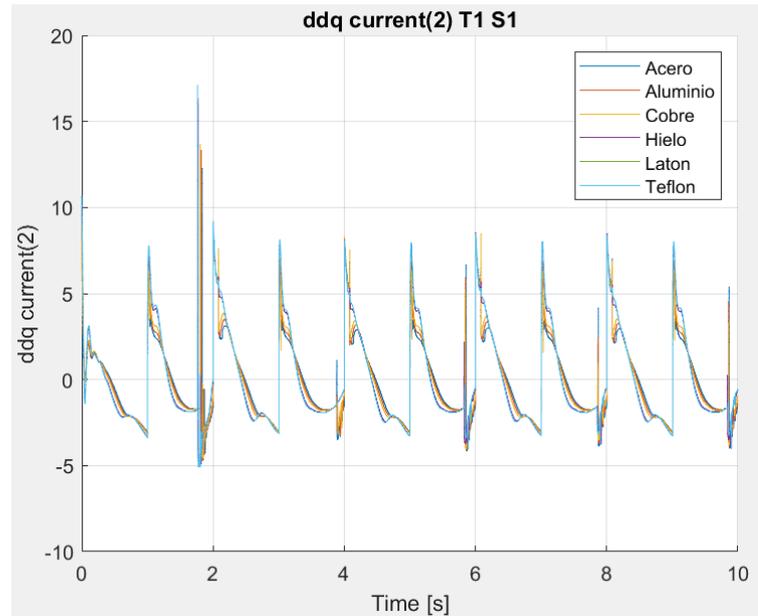
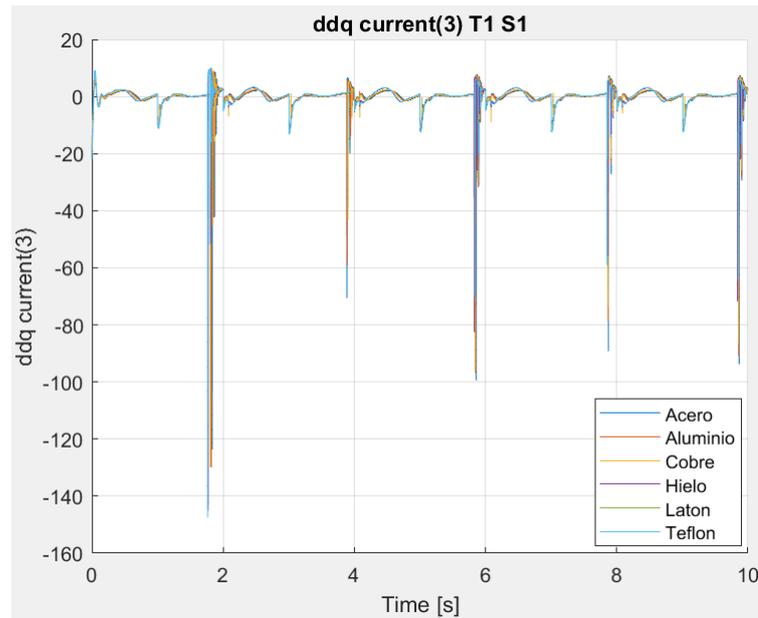
Figura 3.45.*Aceleración articular de la junta #2***Figura 3.46.***Aceleración articular de la junta #3*

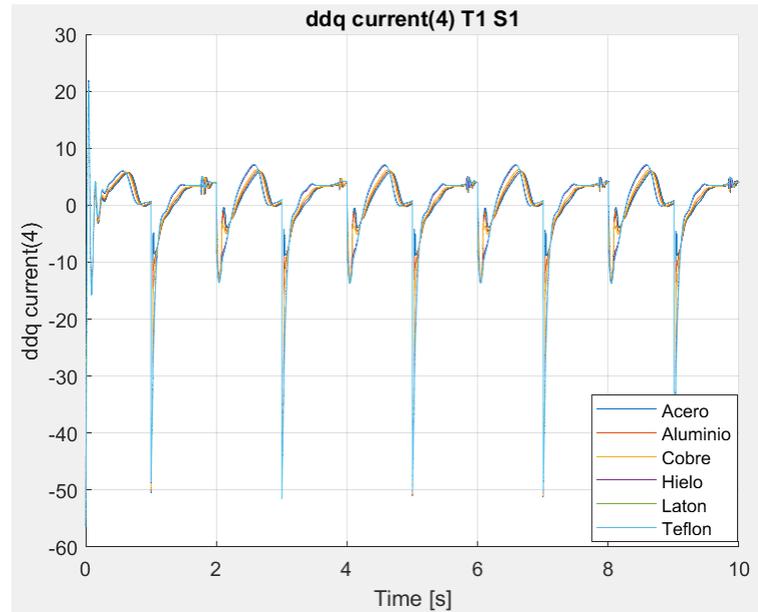
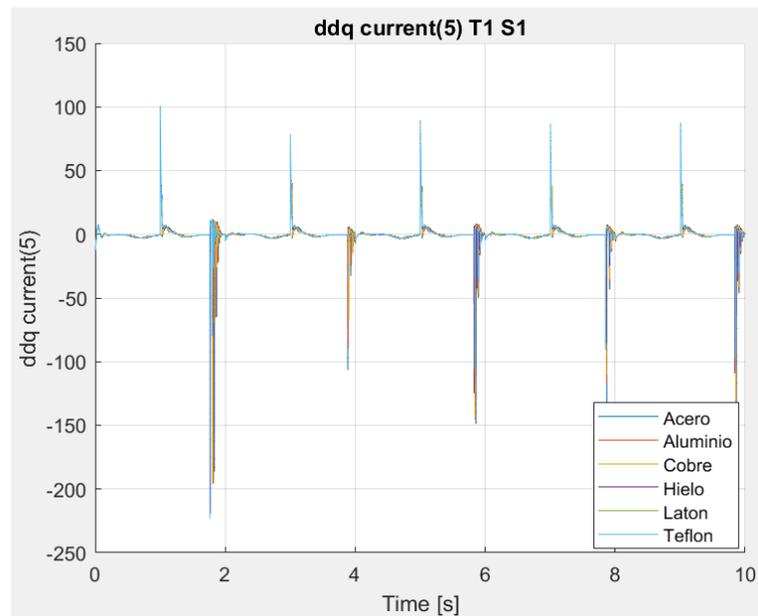
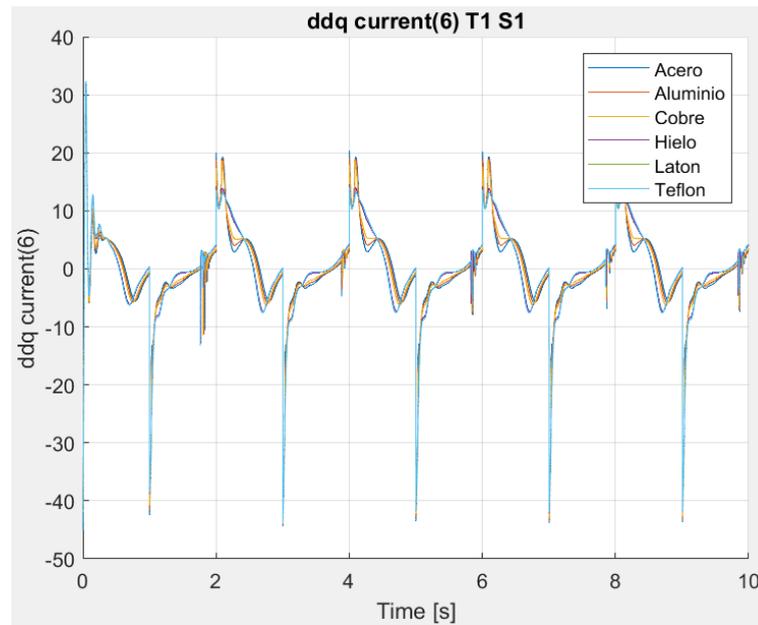
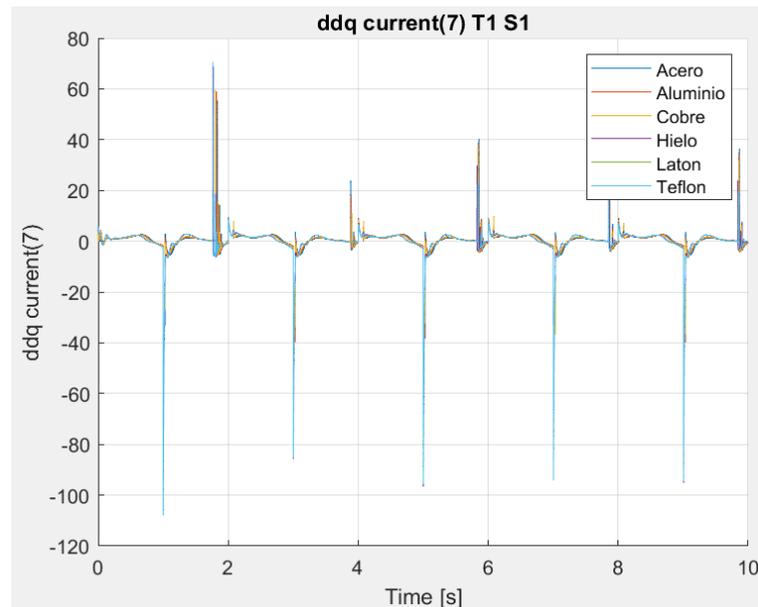
Figura 3.47.*Aceleración articular de la junta #4***Figura 3.48.***Aceleración articular de la junta #5*

Figura 3.49.*Aceleración articular de la junta #6***Figura 3.50.***Aceleración articular de la junta #7*

Las siete gráficas muestran las aceleraciones articulares del robot para distintos materiales. Se observan variaciones cíclicas bien definidas en cada aceleración, con mayores

picos en los materiales como el acero y el hielo. Los materiales como el cobre y el latón tienen comportamientos más estables y uniformes, con menor amplitud en sus variaciones.

Figura 3.51.

Velocidad articular de la junta #1

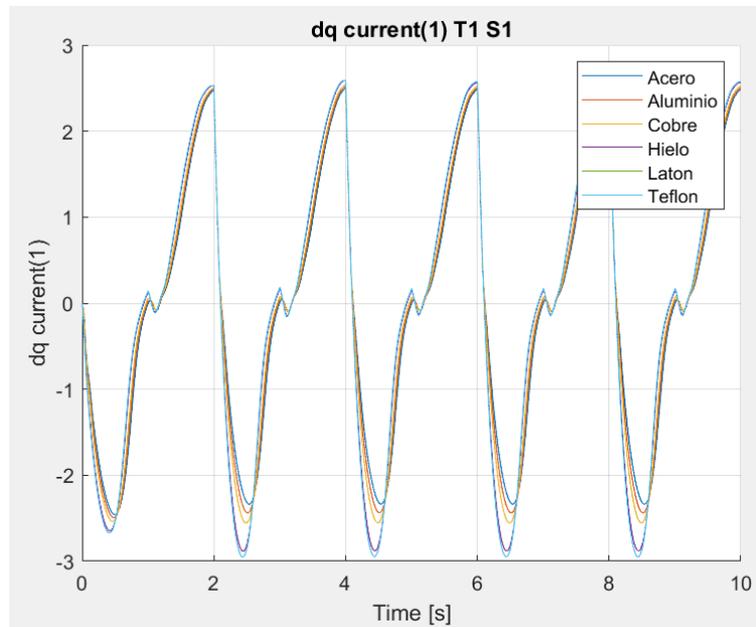


Figura 3.52.

Velocidad articular de la junta #2

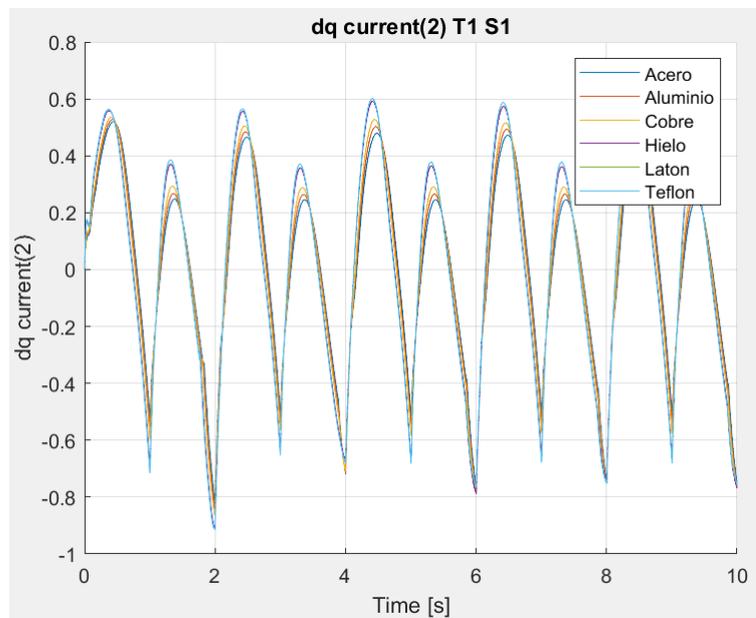


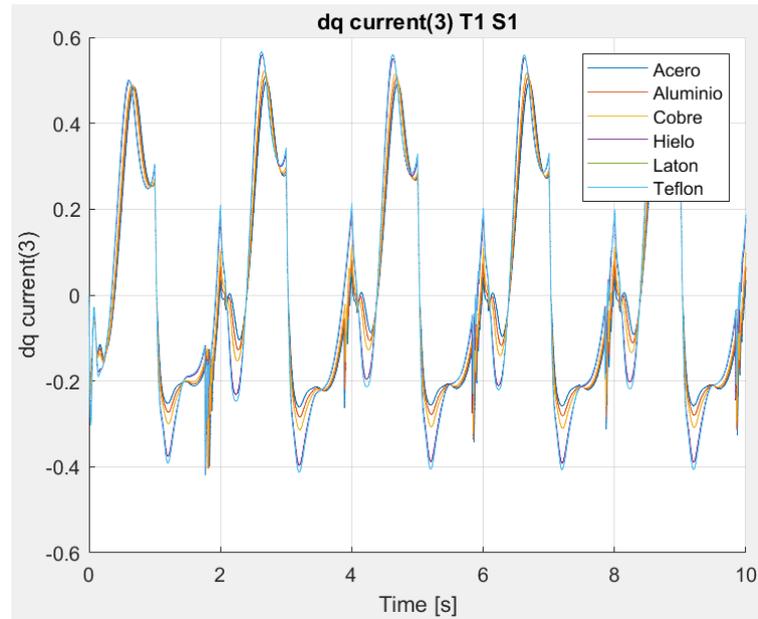
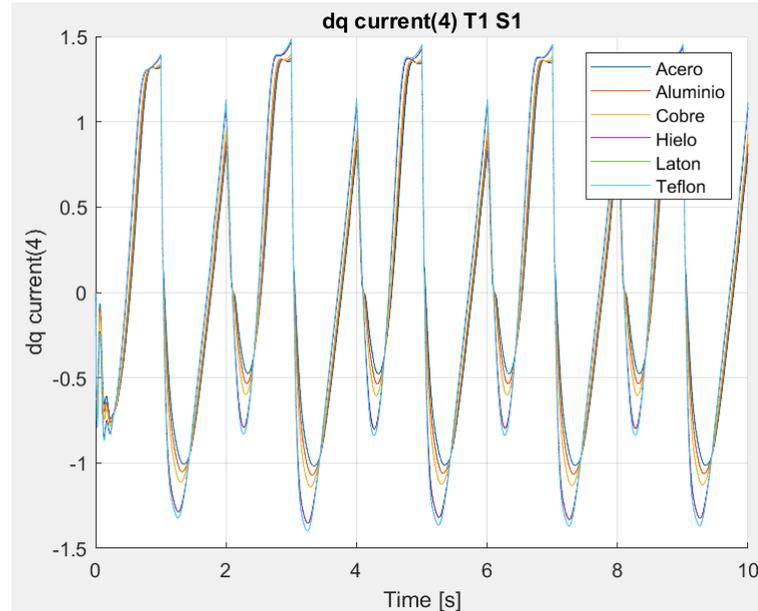
Figura 3.53.*Velocidad articular de la junta #3***Figura 3.54.***Velocidad articular de la junta #4*

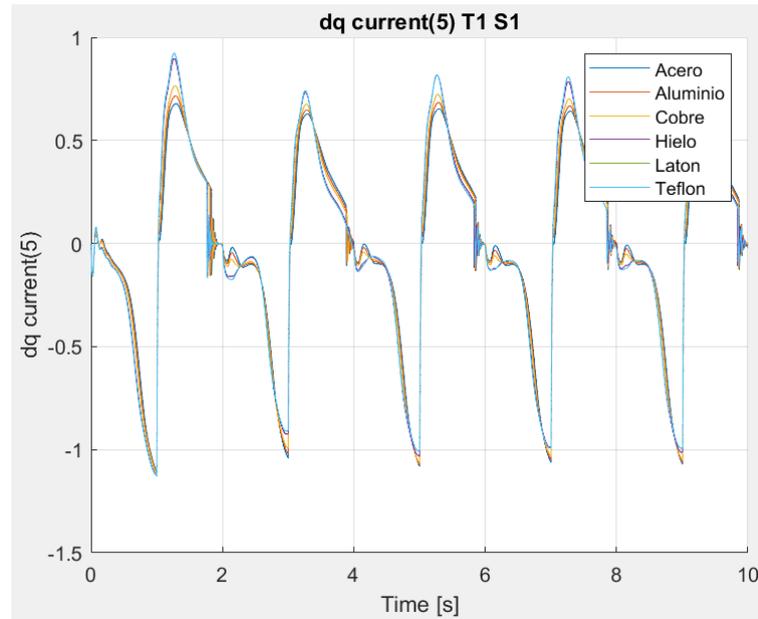
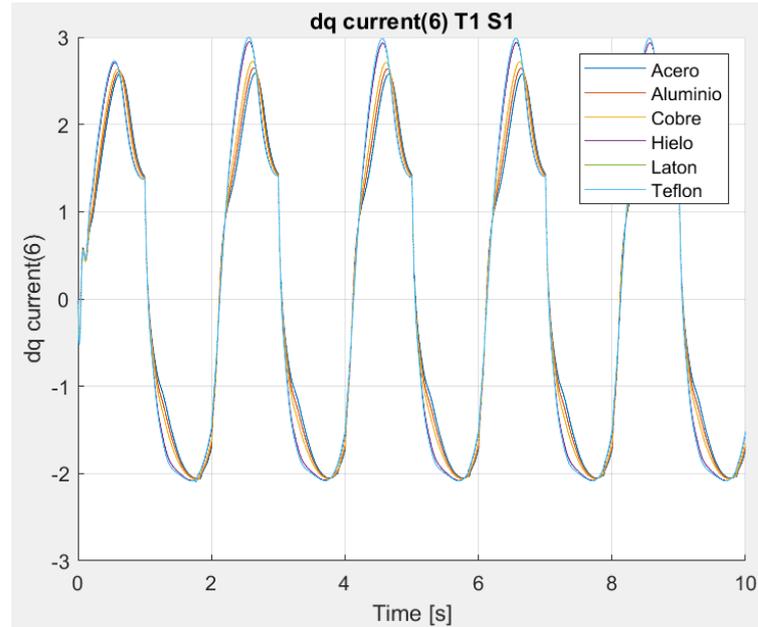
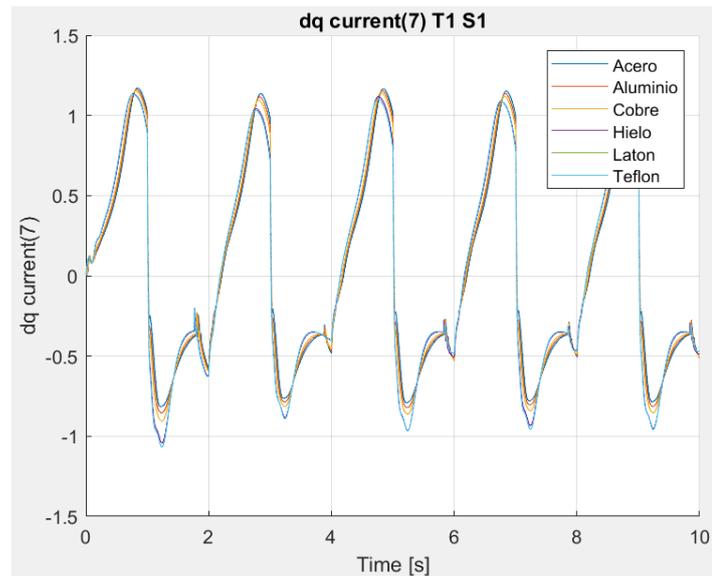
Figura 3.55.*Velocidad articular de la junta #5***Figura 3.56.***Velocidad articular de la junta #6*

Figura 3.57.*Velocidad articular de la junta #7*

En las gráficas de velocidades articulares se observan comportamientos cíclicos y oscilaciones regulares en todas las muestras. Las variaciones entre los diferentes materiales son mínimas, con un comportamiento casi idéntico para la mayoría. Las velocidades siguen patrones suaves con picos regulares, y las diferencias de amplitud son ligeramente visibles en algunos casos.

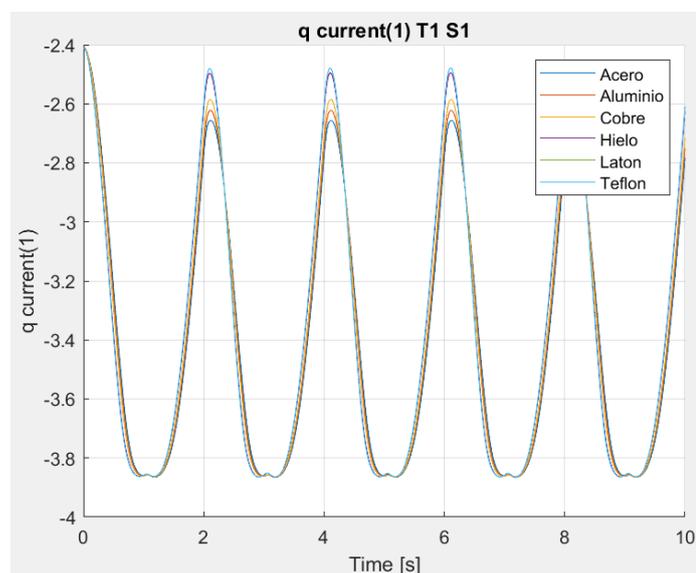
Figura 3.58.*Posición articular de la junta #1*

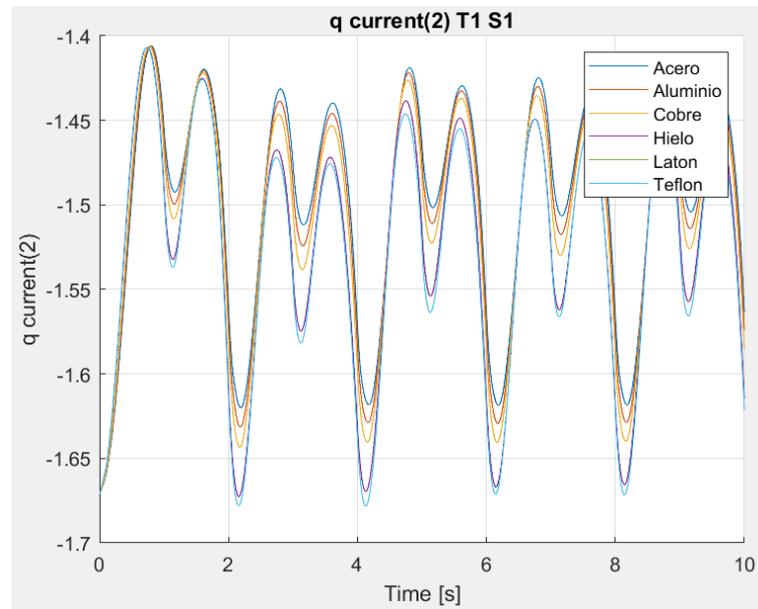
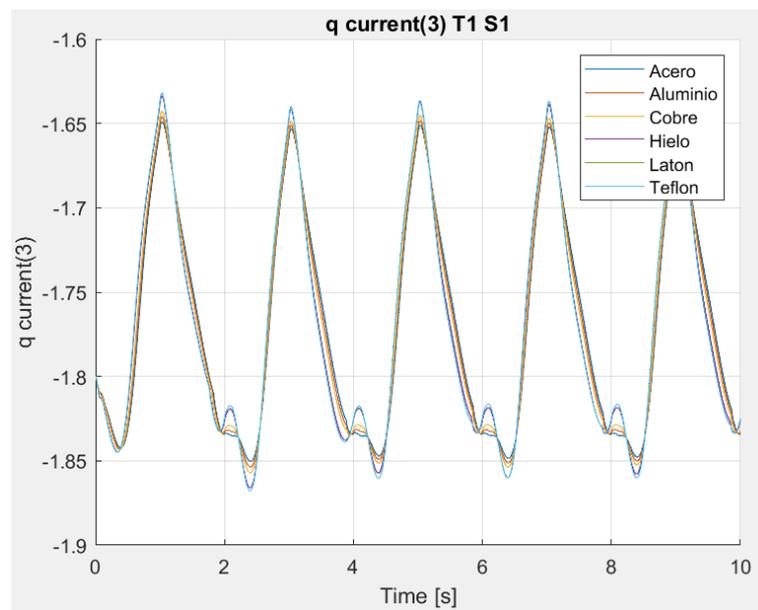
Figura 3.59.*Posición articular de la junta #2***Figura 3.60.***Posición articular de la junta #3*

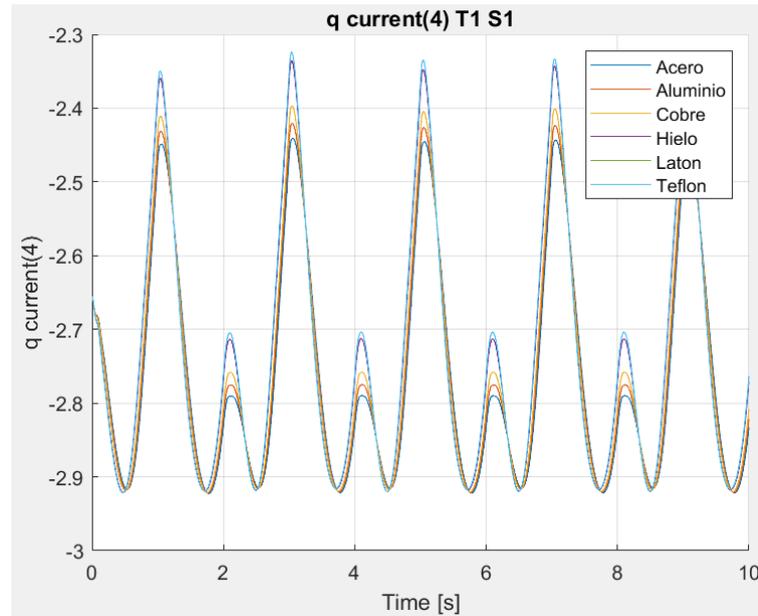
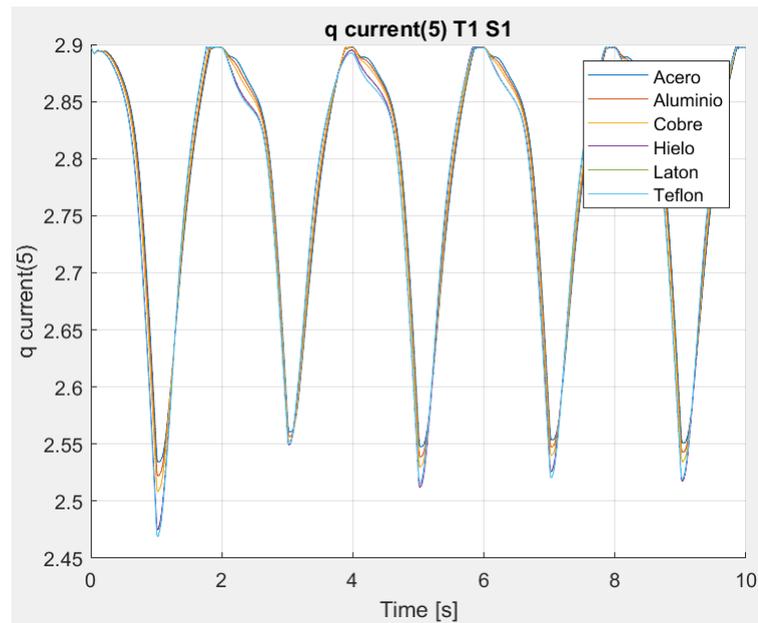
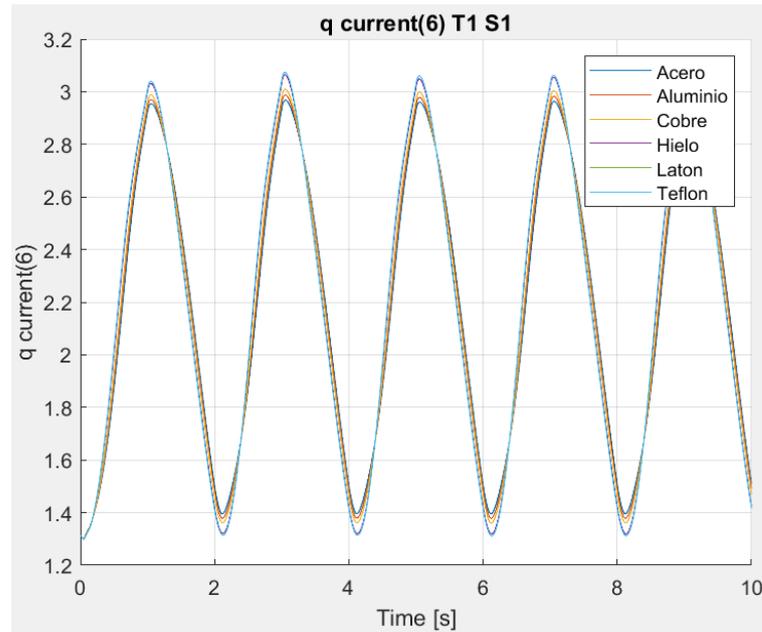
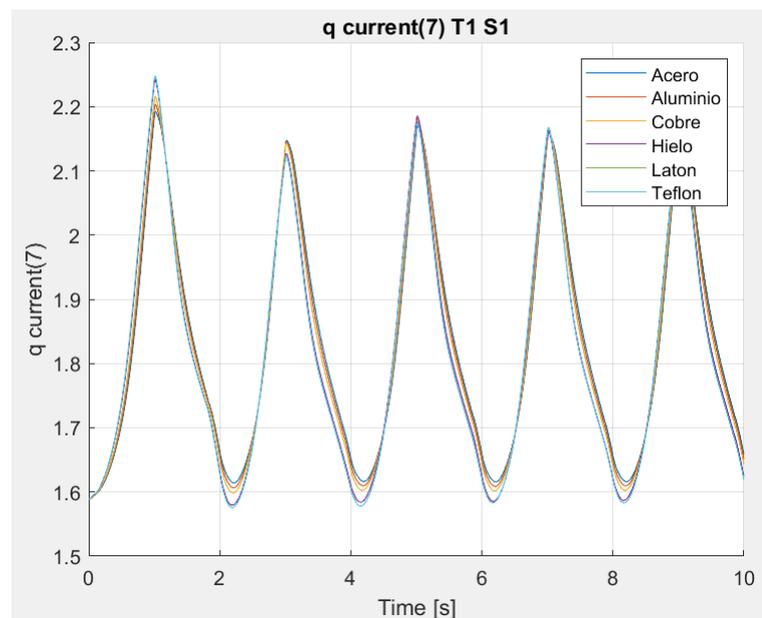
Figura 3.61.*Posición articular de la junta #4***Figura 3.62.***Posición articular de la junta #5*

Figura 3.63.*Posición articular de la junta #6***Figura 3.64.***Posición articular de la junta #7*

En las gráficas de posiciones articulares de un robot se observan oscilaciones periódicas con patrones consistentes entre materiales, aunque con pequeñas variaciones en amplitud. Todos los materiales presentan una dinámica muy similar, lo que sugiere que los efectos de las

posiciones articulares no dependen significativamente del material en cuestión para estas condiciones de movimiento.

Tras analizar toda la información obtenida, se puede afirmar que, a simple vista, no se observan patrones claros que permitan clasificar los materiales basados en los datos recopilados. En el mejor de los casos, se aprecian fluctuaciones de alrededor de 10 unidades entre las gráficas, como es el caso de la fricción. Además, se nota que los resultados para latón y teflón son prácticamente idénticos en la mayoría de las simulaciones, lo que dificulta aún más la identificación de patrones que permitan una clasificación precisa de los materiales.

Para abordar esta limitación, se creó un conjunto de datos (*DataSet*) que agrupa la información recopilada con el objetivo de entrenar un modelo de *machine learning* capaz de predecir de manera precisa la superficie de contacto. El *DataSet* se organizó de manera que el modelo pudiera procesar todas las variables de forma eficiente. En primer lugar, se recopiló la información relacionada con la tarea 1 (lijar). La primera columna corresponde al número de la simulación, que va del 1 al 21, ya que se realizaron 21 simulaciones.

La primera sección del *DataSet* incluye datos sobre el punto de contacto entre el efector final del robot y la superficie, junto con información cinemática como posición, velocidad y aceleración. En la segunda sección se agrupan los datos dinámicos, como las fuerzas y torques involucrados durante la tarea. La tercera sección cubre el espacio articular del robot, registrando la posición, velocidad y aceleración de cada una de sus articulaciones. Por último, se asigna una etiqueta numérica a cada material (del 1 al 6) para representar acero, aluminio, cobre, hielo, latón y teflón.

Los datos de cada simulación se apilan verticalmente, es decir, una simulación se coloca debajo de la anterior. Este proceso se repite hasta completar las 21 simulaciones por material. Una vez recopilada toda la información de los 6 materiales para la tarea 1, el mismo

procedimiento se aplica a la tarea 2, completando así el *DataSet*. Un ejemplo grafico de lo que se acaba de describir se muestra a continuación:

Tabla 3.2.

Agrupación de datos para DataSet

	# de Simulación	Data 1	Data 2	Data 3	Etiqueta de material
Tarea 1	1	1

	21	1
	1	2

	21	6
Tarea 2	1	1

	21	1
	1	2

	21	6

Nota. Las etiquetas usadas son números del 1 al 6 para los materiales utilizados. Ej. Acero = 1

Cabe destacar que a la hora de meter toda la información dentro del modelo clasificador lo que ve la computadora son las cifras como tal, más no el nombre de la variable con la que está tratando. Luego de haber formado la base de datos y entrenar al modelo clasificador con ella se obtuvieron los siguientes resultados:

Tabla 3.3.*Matriz de confusión*

	Acero	Aluminio	Cobre	Hielo	Latón	Teflón
Acero	125972	45	17	1	5	3
Aluminio	46	125904	44	1	37	0
Cobre	12	31	126266	0	3	1
Hielo	0	3	1	125671	15	15
Latón	7	29	4	1	90615	35412
Teflón	0	2	3	1	32520	93386

La presente matriz de confusión nos indica que de todas las clasificaciones realizadas la mayoría de ellas se las realiza con éxito. El modelo quizás presenta algo de problemas para diferenciar de mejor manera al teflón y latón, probablemente porque sus coeficientes de fricción y densidad son un tanto similares, aun así, esto indicaría que el comportamiento que se debe tener entre dichos materiales no es muy diferente por lo que se podría decir que para ambas superficies se podría establecer 1 comportamiento compartido. Por otro lado, para el modelo resulta ser bastante bueno para clasificar metales, ya que como se puede ver allí las veces que falla son escasas. La precisión que se obtuvo con *CatboostClassifier* es aproximadamente del 91%, lo cual indica que de cada 100 veces que el robot interactúa con una superficie en 91 ocasiones logra predecir con éxito el material con el que está trabajando.

3.1 Costos

Dado que para llevar a cabo este estudio todo lo que se requiere es contar con los programas necesarios para poner en marcha la simulación y demás subyacentes de la investigación, los únicos costos relacionados a dicha faena vienen a ser aquellos que estén vinculados con dichos programas, a continuación, se los detalla:

Tabla 3.4.*Costos del proyecto*

Requerimientos	Cantidad	Costo Unitario	Costo Total
Licencia de software MATLAB (Comercial)	1 licencia	\$2.150,00	\$2.150,00
Tiempo Invertido en proyecto	500 horas	\$70,00	\$35.000,00
Instrumentación requerida	10 sensores	\$250,00	\$2.500,00
Total			\$39.650,00

Capítulo 4

4. Conclusiones y recomendaciones

4.1.1 Conclusiones

El trabajo desarrollado es de gran importancia, ya que aborda un problema crítico en la robótica industrial: la necesidad de predecir con precisión las superficies de contacto para optimizar el desempeño de los autómatas en tareas repetitivas. Una de las principales fortalezas del proyecto es la alta precisión obtenida por el modelo de *CatboostClassifier*, que demostró ser efectivo en la clasificación de materiales metálicos con una tasa de acierto del 91%. Sin embargo, una debilidad identificada es la dificultad del modelo para diferenciar materiales con coeficientes de fricción similares, como el latón y el teflón. Los resultados de este trabajo contribuyen a la mejora de la eficiencia y reducción de desgaste en entornos industriales, lo que lo sitúa como una solución prometedora frente a otros estudios en robótica que no contemplan la predicción precisa de superficies. Las implicaciones de este proyecto son relevantes, ya que permiten una mayor automatización y optimización de procesos, reduciendo la intervención humana y el tiempo de mantenimiento. A futuro, se podrían realizar mejoras integrando técnicas avanzadas de aprendizaje profundo para mejorar la clasificación de materiales complejos y explorar su aplicación en entornos más dinámicos y no estructurados.

Tras aplicar las fases necesarias del proyecto, se han obtenido las siguientes conclusiones:

1. Se confirmó que la variabilidad en la fuerza de fricción medida en los distintos materiales con los que interactuó el robot era significativa, lo cual era esperable debido a los diferentes coeficientes de fricción estáticos y dinámicos de cada material. Este resultado refuerza la relevancia del modelo para aplicaciones en entornos industriales que involucren materiales diversos.

2. El modelo de *machine learning CatboostClassifier* mostró una alta precisión en la predicción de superficies de contacto, logrando una tasa de acierto del 91%. Sin embargo, se identificaron dificultades específicas para diferenciar entre latón y teflón, lo cual podría estar relacionado con la similitud en sus coeficientes de fricción.
3. La implementación del sistema de predicción permitió mejorar la eficiencia operativa del robot, ya que este pudo ajustar sus parámetros de interacción en función de la superficie detectada, optimizando así su desempeño y reduciendo el desgaste innecesario.
4. La capacidad del robot para predecir superficies de contacto con materiales metálicos demostró ser robusta y confiable, lo que sugiere que este modelo puede aplicarse en entornos industriales donde predominen estos materiales.
5. El hecho de que el latón y el teflón presenten problemas para la clasificación no solo indica que ambos materiales presentan características similares en densidad y fricción, sino que también el robot no tendrá que hacer un gran cambio en su comportamiento para interactuar con estos materiales, dando la posibilidad de optar por 1 comportamiento definido para ambas superficies.

4.1.2 Recomendaciones

Tras culminar lo planificado en la propuesta, se obtienen las siguientes recomendaciones primordiales:

1. Es necesario desarrollar modelos más avanzados que incluyan variables físicas adicionales, como la dureza y la elasticidad, para mejorar la precisión en la clasificación de materiales. Se recomienda explorar la integración de técnicas de aprendizaje profundo para abordar con mayor efectividad la predicción en entornos no estructurados y materiales con características muy similares.

2. Para mejorar la identificación de materiales complejos como el latón y el teflón, es recomendable realizar simulaciones adicionales que proporcionen más datos específicos sobre sus propiedades. Esto permitirá ajustar el modelo predictivo y superar las limitaciones actuales en la diferenciación de estos materiales.
3. Dado que el estudio solo consideró parámetros como densidad y coeficientes de fricción, futuras investigaciones deberían incluir variables adicionales, como la conductividad térmica o la rugosidad superficial, que podrían influir en la interacción entre el robot y los materiales.
4. El modelo presentado puede ampliarse para incluir la predicción en una mayor variedad de superficies industriales. Se recomienda aplicar esta metodología en diferentes industrias para evaluar su capacidad de adaptación a nuevos entornos y materiales.
5. Para replicar los resultados obtenidos en este proyecto, se recomienda, antes de utilizar *CatBoost Classifier*, generar una matriz de correlación. Esto permite verificar que las variables seleccionadas no estén correlacionadas entre sí. En este proyecto, algunas variables estaban significativamente relacionadas, ya que algunas eran la suma de otras dos. El uso de la matriz de correlación optimiza el procesamiento de los datos, reduciendo el costo computacional.

Referencias

- [1] C. Wang and J. Zhao, "Humanoid Trajectory Planning for Robot Based on Minimum-Jerk Model of Human Arm," in *2022 7th International Conference on Automation, Control and Robotics Engineering (CACRE)*, 2022, pp. 45–50. doi: 10.1109/CACRE54574.2022.9834199.
- [2] P. Kulkarni, O. Kulkarni, and J. K. Sayyad, "Tuning of a Robotic Arm using PID Controller for Robotics and Automation Industry," in *2024 6th International Conference on Energy, Power, and Environment (ICEPE)*, 2024, pp. 1–6. doi: 10.1109/ICEPE63236.2024.10668952.
- [3] K. Rezaie and A. Haeri, "Using PCA and Pareto optimality to select flexible manufacturing systems," in *2011 IEEE International Systems Conference*, 2011, pp. 538–541. doi: 10.1109/SYSCON.2011.5929062.
- [4] B. T. S. Paz, G. Sorrosal, and A. Mancisidor, "Intelligent Adaptative Robotic System for Physical Interaction Tasks," in *Proceedings - 2022 6th IEEE International Conference on Robotic Computing, IRC 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 429–430. doi: 10.1109/IRC55401.2022.00082.
- [5] M. Tadese, N. Pico, F. Yumbla, and H. Moon, "Variable Admittance Control for Compliant Collaboration in Physical Human-Robot-Environment Interaction," in *2023 20th International Conference on Ubiquitous Robots (UR)*, 2023, pp. 581–586. doi: 10.1109/UR57808.2023.10202251.
- [6] B. Siciliano, L. Sciavicco, L. Villani, and G. Oriolo, *2-Control and Signal Processing - Bruno Siciliano*. Springer London, 2010. Accessed: Sep. 12, 2024. [Online]. Available: <https://books.google.com.ec/books?id=jPCAFmE-logC>

- [7] J. J. Craig, P. Prentice, and P. P. Hall, “Introduction to Robotics Mechanics and Control Third Edition,” 2005.
- [8] Siciliano Bruno, Sciavicco Lorenzo, Villani Luigi, and Oriolo Giuseppe, *Robotics Modelling, Planning and Control*. Springer.
- [9] R. Illah, “Autonomous Mobile Robots Introduction to SIEGWART NOURBAKHSI Introduction to Autonomous Mobile Robots.”
- [10] *MMAR: 2015 20th International Conference on Methods and Models in Automation and Robotics: 24-27 August 2015, Miedzyzdroje, Poland*. Institute of Electrical and Electronics Engineers, 2015.
- [11] H. Rodríguez and C. Chérigo, “Evaluación de algoritmos de fusión de datos de medición inercial para vehículos aéreos no tripulados,” in *Proceedings of the LACCEI international Multi-conference for Engineering, Education and Technology*, Latin American and Caribbean Consortium of Engineering Institutions, 2017, pp. 1–8. doi: 10.18687/LACCEI2017.1.1.455.
- [12] X. Li *et al.*, “Learning-based controller optimization for repetitive robotic tasks,” in *IEEE International Conference on Intelligent Robots and Systems*, Institute of Electrical and Electronics Engineers Inc., Oct. 2020, pp. 7617–7622. doi: 10.1109/IROS45743.2020.9340880.
- [13] Arana Carlos, “Arana, Carlos Standard-Nutzungsbedingungen,” Buenos Aires, Feb. 2021. [Online]. Available: <https://hdl.handle.net/10419/238403>
- [14] F. Izaurieta and C. Saavedra, “Redes Neuronales Artificiales.”

- [15] A. A. Ibrahim, R. L. Ridwan, M. M. Muhammed, R. O. Abdulaziz, and G. A. Saheed, "Comparison of the CatBoost Classifier with other Machine Learning Methods," 2020. [Online]. Available: www.ijacsa.thesai.org

Apéndice A

Para realizar todos los trabajos inmersos de esta tesis se utilizó una cuenta personal de MathWorks que cuenta con acceso a las licencias necesarias de MATLAB.