

**CLASIFICACIÓN DE GESTOS MANUALES UTILIZANDO IMÁGENES
TIEMPO-FRECUENCIA Y ENFOQUES DE VALIDACIÓN**

DIRECTOR: ING. JORGE LUIS AROCA TRUJILLO

CAMILO ANDRES CHAPARRO MACIAS

MAICOL ESTIVEN CARDOZO SANCHEZ

CORPORACION UNIVERSITARIA DEL HUILA – CORHUILA

INGENIERÍA MECATRÓNICA

NEIVA

2024

Tabla de Contenidos

1	Descripción del Trabajo	3
2	Justificación	4
3	Marco Teórico	5
3.1	Principios Aerodinámicos y Desafíos en Drones a Pequeña Escala.. ¡Error! Marcador no definido.	
3.2	Innovaciones Biométricas en el Diseño de Alas	5
3.3	Morfología de Alas y Colas Biomorficas	5
3.4	Configuración de Alas en Tándem y Optimización de Fuerza..... ¡Error! Marcador no definido.	
3.5	Sensores Distribuidos y Monitoreo Avanzado	5
3.6	Pieles Sensoriales Inteligentes y Percepción Multifuncional	¡Error! Marcador no definido.
3.7	Técnicas de Diseño de Experimentos (DoE) y Optimización..... ¡Error! Marcador no definido.	
4	Objetivos	7
4.1	Objetivo General	7
4.2	Objetivos Específicos.....	7
5	Metodología	8
5.1	Análisis de la Eficiencia Aerodinámica de Alas Biomiméticas	8
5.2	Estudio de la Maniobrabilidad y Estabilidad de Configuraciones de Alas y Colas Biomorficas	8
5.3	Evaluación del Impacto de Sensores Distribuidos en el Control de Vuelo..... ¡Error! Marcador no definido.	
6	Presupuesto	10
7	Bibliografía	11
8	Plan de trabajo a desarrollar	12
8.1	Preparación y Planificación.....	12
8.2	Simulación Computacional y Diseño de Prototipos	12
8.3	Pruebas Experimentales y Evaluación	13
8.4	Optimización y Validación Final.....	13
9	Cronograma.....	15

1 Descripción del Trabajo

El presente anteproyecto Los avances en robótica e inteligencia artificial han impulsado la creación de tecnologías innovadoras en campos como la rehabilitación asistida por robots, la biorretroalimentación, la ergonomía y la neurofisiología (Barsotti et al., 2015; Crea et al., 2016). Estas tecnologías se centran en comprender la coordinación muscular, definida como el proceso en el que los músculos se activan y contraen para generar fuerza en las articulaciones, ya sea de forma consciente o automática (De Luca, 1997; Enoka, 2008).

El progreso tecnológico ha estimulado el desarrollo de técnicas de procesamiento de señales, particularmente aquellas relacionadas con señales electromiográficas (EMG) no periódicas y transitorias (Farina et al., 2014; Hwang et al., 2018). Estas técnicas encuentran aplicaciones en el diagnóstico de enfermedades neuromusculares, interacción hombre-máquina, experiencias de juego, detección de lenguaje de señas, realidad virtual, diseño de exoesqueletos y dispositivos y sistemas de monitoreo para personas con amputaciones, como las prótesis mioeléctricas (Castellini et al., 2014; Jiang et al., 2012).

La adquisición y procesamiento de señales EMG son cruciales en la clasificación de las posturas de agarre de las manos, identificando características relevantes en los patrones de contracción muscular (Kyranou et al., 2018; Krasoulis et al., 2017). El preprocesamiento de la señal EMG para eliminar armónicos, extracción de características usando ventanas de tiempo y transformación de la señal EMG al dominio de frecuencia a través de la transformada de Fourier (FT) convencional, extrayendo características como magnitud, fase y densidad espectral de potencia (PSD) (Phinyomark et al., 2012; Phinyomark et al., 2013).

2 Justificación

Los avances en robótica e inteligencia artificial han impulsado el desarrollo de tecnologías innovadoras con un gran potencial para mejorar la calidad de vida de las personas con discapacidades en las extremidades superiores (Barsotti et al., 2015; Crea et al., 2016). Estas tecnologías se enfocan en comprender la coordinación muscular, un proceso fundamental en el que los músculos se activan y contraen para generar fuerzas en las articulaciones, ya sea de forma consciente o automática (De Luca, 1997; Enoka, 2008).

La capacidad de analizar y clasificar la actividad muscular a través de señales electromiográficas (EMG) tiene amplias aplicaciones en diversos campos, como el diagnóstico de enfermedades neuromusculares, la interacción hombre-máquina, las experiencias de juego, la detección de lenguaje de señas, la realidad virtual, el diseño de exoesqueletos y los sistemas de monitoreo para personas con amputaciones (Castellini et al., 2014; Jiang et al., 2012).

Particularmente, el procesamiento de señales EMG no periódicas y transitorias ha sido un área de gran interés en la comunidad científica, ya que estas señales contienen información valiosa sobre la actividad neuromuscular (Farina et al., 2014; Hwang et al., 2018). El desarrollo de técnicas avanzadas de procesamiento de señales ha permitido extraer características relevantes de estas señales, como magnitud, fase y densidad espectral de potencia (PSD), lo que ha sido fundamental para la clasificación de patrones de actividad muscular (Phinyomark et al., 2012; Phinyomark et al., 2013).

La clasificación de posturas de agarre manual a partir de señales EMG es de especial interés, ya que estas habilidades motoras finas son esenciales para la independencia y la calidad de vida de las personas con discapacidades en las extremidades superiores (Kyrano et al., 2018; Krasoulis et al., 2017). La identificación de características relevantes en los patrones de contracción muscular durante diferentes posturas de agarre puede facilitar el desarrollo de tecnologías asistidas, como prótesis mioeléctricas y sistemas de control de exoesqueletos, lo que permitiría a estas personas recuperar mayor autonomía y participar más activamente en sus actividades diarias.

Además, el uso de técnicas de procesamiento de señales en el dominio del tiempo y la frecuencia, como la transformada de Fourier de corto tiempo (STFT), ha demostrado ser una herramienta eficaz para extraer características relacionadas con la frecuencia de las señales EMG, como momento espectral, centroide de frecuencia, integración de densidad espectral de potencia, varianza del centroide de frecuencia, magnitud espectral promedio, coeficientes autorregresivos y coeficientes espectrales (Phinyomark et al., 2012; Phinyomark et al., 2013).

Estas características extraídas de los espectrogramas STFT pueden ser utilizadas como insumo para modelos de clasificación de patrones de agarre manual, lo que podría tener un impacto significativo en el desarrollo de tecnologías de asistencia y rehabilitación para personas con discapacidades en las extremidades superiores..

3 Marco Teórico

La coordinación muscular es un proceso fundamental en el que los músculos se activan y contraen para generar fuerzas en las articulaciones, ya sea de forma consciente o automática (De Luca, 1997; Enoka, 2008). Esta capacidad de los músculos para coordinar sus movimientos es esencial para la realización de tareas motoras finas, como el agarre y manipulación de objetos.

Las señales electromiográficas (EMG) son ampliamente utilizadas para el estudio de la actividad muscular, ya que pueden proporcionar información valiosa sobre los patrones de activación y reclutamiento de unidades motoras (Farina et al., 2014; Hwang et al., 2018). El procesamiento y análisis de estas señales EMG ha sido un campo de investigación activo, con aplicaciones en diversos ámbitos, como el diagnóstico de enfermedades neuromusculares, la interacción hombre-máquina, las experiencias de juego, la detección de lenguaje de señas, la realidad virtual y el diseño de tecnologías asistivas (Castellini et al., 2014; Jiang et al., 2012).

Una de las aplicaciones clave del análisis de señales EMG es la clasificación de patrones de agarre manual, una habilidad motora fina esencial para la independencia y la calidad de vida de las personas con discapacidades en las extremidades superiores (Kyranou et al., 2018; Krasoulis et al., 2017). La identificación de características relevantes en los patrones de contracción muscular durante diferentes posturas de agarre puede facilitar el desarrollo de tecnologías asistivas, como prótesis mioeléctricas y sistemas de control de exoesqueletos, permitiendo a estas personas recuperar mayor autonomía y participar más activamente en sus actividades diarias.

El procesamiento de señales EMG no periódicas y transitorias ha sido un tema de gran interés en la investigación, ya que estas señales contienen información valiosa sobre la actividad neuromuscular (Farina et al., 2014; Hwang et al., 2018). Técnicas avanzadas de procesamiento de señales, como la transformada de Fourier de corto tiempo (STFT), han demostrado ser efectivas para extraer características relacionadas con la frecuencia de las señales EMG, como el momento espectral, el centroide de frecuencia, la integración de densidad espectral de potencia, la varianza del centroide de frecuencia, la magnitud espectral promedio, los coeficientes autorregresivos y los coeficientes espectrales (Phinyomark et al., 2012; Phinyomark et al., 2013).

Estas características extraídas de los espectrogramas STFT pueden ser utilizadas como insumo para modelos de clasificación de patrones de agarre manual, lo que podría tener un impacto significativo en el desarrollo de tecnologías de asistencia y rehabilitación para personas con discapacidades en las extremidades superiores. Adicionalmente, la implementación de técnicas de aprendizaje automático, como las redes neuronales convolucionales (CNN), ha demostrado ser una estrategia efectiva para la clasificación de señales EMG (Atzori et al., 2014; Côté-Allard et al., 2019). Estas arquitecturas de Deep Learning son capaces de extraer características relevantes de manera automática a partir de

los espectrogramas STFT, lo que las convierte en una herramienta poderosa para la identificación precisa de patrones de actividad muscular.

En este contexto, el desarrollo de una metodología robusta y eficiente para la clasificación de posturas de agarre manual basada en el análisis de señales EMG utilizando técnicas avanzadas de procesamiento de señales y aprendizaje automático se presenta como una línea de investigación prometedora, con el potencial de contribuir significativamente al campo de la rehabilitación y la asistencia tecnológica para personas con discapacidades en las extremidades superiores.

4 Objetivos

4.1 Objetivo General

Desarrollar una metodología robusta y eficiente para la clasificación de patrones de agarre manual a partir del análisis de señales electromiográficas (EMG), utilizando técnicas avanzadas de procesamiento de señales y aprendizaje automático, con el fin de contribuir al desarrollo de tecnologías asistidas y de rehabilitación para personas con discapacidades en las extremidades superiores.

4.2 Objetivos Específicos

1. Diseñar un protocolo experimental para la adquisición de señales EMG durante la ejecución de diferentes posturas de agarre manual, considerando aspectos como la estandarización de los movimientos, la colocación de los electrodos y la calibración del sistema.
2. Implementar técnicas avanzadas de procesamiento de señales EMG, como la transformada de Fourier de corto tiempo (STFT), para la extracción de características relevantes relacionadas con la frecuencia, como el momento espectral, el centroide de frecuencia, la integración de densidad espectral de potencia, la varianza del centroide de frecuencia, la magnitud espectral promedio, los coeficientes autorregresivos y los coeficientes espectrales.
3. Diseñar y evaluar modelos de aprendizaje automático, como redes neuronales convolucionales (CNN), para la clasificación precisa de patrones de agarre manual a partir de las características extraídas de los espectrogramas STFT de las señales EMG, con el fin de identificar las posturas de agarre de manera robusta y confiable.

5 Metodología

1. Adquisición de señales EMG:

- Diseñar un protocolo experimental para la recolección de señales EMG durante la ejecución de diferentes posturas de agarre manual.
- Seleccionar los grupos musculares relevantes y colocar los electrodos de superficie de manera estandarizada.
- Registrar las señales EMG utilizando un sistema de adquisición de datos confiable y de alta calidad.
- Recopilar un conjunto de datos robusto que abarque una amplia variedad de posturas de agarre manual.

2. Procesamiento y extracción de características de las señales EMG:

- Aplicar técnicas de preprocesamiento de señales, como filtrado y normalización, para mejorar la calidad de las señales EMG.
- Implementar la transformada de Fourier de corto tiempo (STFT) para obtener los espectrogramas de las señales EMG.
- Extraer características relacionadas con la frecuencia a partir de los espectrogramas, como:
 - a. Momento espectral
 - b. Centroide de frecuencia
 - c. Integración de densidad espectral de potencia
 - d. Varianza del centroide de frecuencia
 - e. Magnitud espectral promedio
 - f. Coeficientes autorregresivos
 - g. Coeficientes cepstrales

3. Diseño y evaluación de modelos de clasificación:

- Dividir el conjunto de datos en conjuntos de entrenamiento, validación y prueba.
- Implementar modelos de aprendizaje automático, como redes neuronales convolucionales (CNN), para la clasificación de patrones de agarre manual.
- Entrenar y optimizar los modelos de clasificación utilizando las características extraídas de los espectrogramas STFT.
- Evaluar el desempeño de los modelos de clasificación mediante métricas apropiadas, como precisión, exhaustividad, puntaje-F y matriz de confusión.
- Analizar los resultados y realizar ajustes en el diseño de los modelos y la selección de características, de ser necesario, para mejorar el rendimiento.

4. Validación y pruebas:

- Validar el rendimiento de los modelos de clasificación utilizando el conjunto de datos de prueba.
- Realizar pruebas exhaustivas con nuevos datos para evaluar la generalización y robustez de los modelos.
- Identificar y abordar cualquier limitación o desafío encontrado durante las pruebas.

5. Implementación y documentación:

- Integrar la metodología desarrollada en un prototipo funcional para su posible aplicación en tecnologías asistidas.
- Documentar detalladamente todo el proceso de investigación, incluyendo los diseños experimentales, los algoritmos implementados y los resultados obtenidos.
- Difundir los hallazgos en publicaciones científicas y presentaciones en congresos, con el fin de contribuir al avance del conocimiento en este campo.

6 Presupuesto

I. Recursos Humanos:

Investigador principal (1): \$2.000.000 por 3 meses

Investigador asociado (1): \$1.500.000 por 3 meses

Total, recursos humanos: \$3.500.000

II. Equipos y Materiales:

Dron Bioinspirado: \$3.000.000

Sistema de adquisición de datos y sensores: \$2.000.000

Equipos de cómputo y software: \$3.000.000

Materiales diversos (electrónica, instrumentación, etc.): \$1.000.000

Total, equipos y materiales: \$9.000.000

III. Gastos de Difusión y Publicación:

Publicación en revistas científicas: \$3.000.000

Participación en congresos y eventos: \$4.000.000

Total gastos de difusión y publicación: \$7.000.000

Presupuesto Total del Proyecto: \$26.500.000

7 Bibliografía

- [1] Oh, D.-C., & Jo, Y.-U. (2021). Classification of hand gestures based on multi-channel EMG by scale average wavelet transform and convolutional neural network. *International Journal of Control, Automation, and Systems*, 19(3), 1443–1450.
- [2] Ozdemir, M. A., Kisa, D. H., Guren, O., Onan, A., & Akan, A. (2020). EMG based Hand Gesture Recognition using Deep Learning. 2020 Medical Technologies Congress (TIPTEKNO).
- [3] Rabin, N., Kahlon, M., Malayev, S., & Ratnovsky, A. (2020). Classification of human hand movements based on EMG signals using nonlinear dimensionality reduction and data fusion techniques. *Expert Systems with Applications*, 149(113281), 113281.
- [4] Roland, T., Baumgartner, W., Amsuess, S., & Russold, M. F. (2017, July). Capacitively coupled EMG detection via ultra-low-power microcontroller STFT. In 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 410-413). IEEE.
- [5] Tsai, A. C., Hsieh, T. H., Luh, J. J., & Lin, T. T. (2014). A comparison of upper-limb motion pattern recognition using EMG signals during dynamic and isometric muscle contractions. *Biomedical Signal Processing and Control*, 11, 17-26.
- [6] Satti, A. T., Kim, J., Yi, E., Cho, H. Y., & Cho, S. (2021). Microneedle array electrode-based wearable EMG system for detection of driver drowsiness through steering wheel grip. *Sensors*, 21(15), 5091.
- [7] Too, J., Abdullah, A. R., Mohd Saad, N., Mohd Ali, N., & Tee, W. (2018). A new competitive binary grey wolf optimizer to solve the feature selection problem in EMG signals classification. *Computers*, 7(4), 58.
- [8] Serrezuela, R. R., Cardozo, M. Á. T., Montiel, J. J. G., Zamora, R. S., & Reyes, E. M. (2019, August). Análisis comparativo entre de MAE y RNA en señales de EMG obtenidas para control de una prótesis mano robótica. In *Memorias de Congresos UTP* (pp. 107-112)
- [9] Grandett, Y. D. C., Argote, N. S., & Serrezuela, R. R. (2020). ANALYSIS BETWEEN ELM AND ANN IN EMG SIGNALS OBTAINED FOR THE CONTROL OF A ROBOTIC HAND PROSTHESIS. *ARNP Journal of Engineering and Applied Sciences*. pp 2806-2811.
- [10] Serrezuela, R. R., Zamora, R. S., & Reyes, E. M. (2020). Control Strategy for Underactuated Multi-Fingered Robot Hand Movement Using Electromyography Signal with Wearable Myo Armband. In *Biosensors-Current and Novel Strategies for Biosensing*. IntechOpen.

8 Plan de trabajo a desarrollar

Objetivo Específico 1: Diseñar un protocolo experimental para la adquisición de señales EMG durante la ejecución de diferentes posturas de agarre manual, considerando aspectos como la estandarización de los movimientos, la colocación de los electrodos y la calibración del sistema.

Plan de Trabajo:

1. Realizar una revisión exhaustiva de la literatura sobre protocolos experimentales para la adquisición de señales EMG en estudios de agarre manual.
2. Identificar los grupos musculares clave involucrados en la ejecución de las diferentes posturas de agarre.
3. Establecer un plan para la colocación de los electrodos de superficie de manera estandarizada, considerando la anatomía y la ubicación de los músculos seleccionados.
4. Diseñar un conjunto de instrucciones y guías detalladas para los participantes, que incluyan la ejecución de los diferentes patrones de agarre manual de manera consistente.
5. Seleccionar y calibrar el sistema de adquisición de señales EMG, asegurando una alta calidad y resolución de las mediciones.
6. Realizar pruebas piloto con un número reducido de participantes para validar y ajustar el protocolo experimental diseñado.
7. Documentar detalladamente el protocolo experimental final, incluyendo los procedimientos de colocación de electrodos, ejecución de posturas de agarre y calibración del sistema.

Objetivo Específico 2: Implementar técnicas avanzadas de procesamiento de señales EMG, como la transformada de Fourier de corto tiempo (STFT), para la extracción de características relevantes relacionadas con la frecuencia, como el momento espectral, el centroide de frecuencia, la integración de densidad espectral de potencia, la varianza del centroide de frecuencia, la magnitud espectral promedio, los coeficientes autorregresivos y los coeficientes espectrales.

Plan de Trabajo:

1. Investigar y seleccionar las técnicas de procesamiento de señales EMG más apropiadas para la extracción de características relacionadas con la frecuencia.
2. Implementar algoritmos de preprocesamiento de señales EMG, como filtrado y normalización, para mejorar la calidad de los datos.

3. Desarrollar un módulo de cálculo de la transformada de Fourier de corto tiempo (STFT) para obtener los espectrogramas de las señales EMG.

4. Diseñar y programar algoritmos para la extracción de las características de frecuencia seleccionadas a partir de los espectrogramas, como:

- Momento espectral
- Centroide de frecuencia
- Integración de densidad espectral de potencia
- Varianza del centroide de frecuencia
- Magnitud espectral promedio
- Coeficientes autorregresivos
- Coeficientes espectrales

5. Validar y ajustar los algoritmos de extracción de características utilizando un conjunto de datos de prueba.

6. Documentar el proceso de implementación y los detalles técnicos de las técnicas de procesamiento de señales EMG utilizadas.

Objetivo Específico 3: Diseñar y evaluar modelos de aprendizaje automático, como redes neuronales convolucionales (CNN), para la clasificación precisa de patrones de agarre manual a partir de las características extraídas de los espectrogramas STFT de las señales EMG, con el fin de identificar las posturas de agarre de manera robusta y confiable.

Plan de Trabajo:

1. Investigar y seleccionar los modelos de aprendizaje automático más apropiados para la clasificación de patrones de agarre manual, con énfasis en redes neuronales convolucionales (CNN).

2. Dividir el conjunto de datos recopilado en conjuntos de entrenamiento, validación y prueba, asegurando una adecuada representación de las diferentes posturas de agarre.

3. Diseñar y desarrollar la arquitectura de los modelos de clasificación CNN, incluyendo la definición de las capas convolucionales, de agrupamiento, densas y de salida.

4. Implementar los algoritmos de entrenamiento y optimización de los modelos de clasificación CNN, utilizando las características extraídas de los espectrogramas STFT como entrada.

5. Evaluar el desempeño de los modelos de clasificación mediante métricas apropiadas, como precisión, exhaustividad, puntaje-F y matriz de confusión.

6. Analizar los resultados de los modelos de clasificación, identificar áreas de mejora y realizar ajustes en la arquitectura y los hiperparámetros, de ser necesario.
7. Documentar detalladamente el diseño, la implementación y la evaluación de los modelos de clasificación CNN desarrollados.

9 Cronograma

