



Diseño de un sistema embebido de clasificación de movimientos de los dedos de la mano, empleando electromiografía superficial en antebrazo

Alfredo José Sanabria Solano

Universidad del Rosario y Escuela Colombiana de Ingeniería Julio Garavito
Facultad de Ingeniería Biomédica, Maestría en Ingeniería Biomédica
Bogotá, Colombia
2021

Diseño de un sistema embebido de clasificación de movimientos de los dedos de la mano, empleando electromiografía superficial en antebrazo

Alfredo José Sanabria Solano

Tesis de grado presentada como requisito para optar al título de:
Magister en Ingeniería Biomédica

Director(a):

Ph.D., Doctor, Alvaro David Orjuela Cañón

y

Ph.D., Doctor, Oscar Julian Perdomo Charry

Universidad del Rosario y Escuela Colombiana de Ingeniería Julio Garavito
Facultad de Ingeniería Biomédica, Maestría en Ingeniería Biomédica
Bogotá, Colombia

2021

(Agradecimientos)

Quiero agradecer a mi familia que han sido el principal apoyo en momentos de flaqueza y debilidad ya que con sus consejos, enseñanzas y tolerancia me han brindado ese respaldo incondicional para culminar esta etapa de mi vida.

Quiero agradecer a mis tutores por ser siempre la mano dura pero incondicional al momento de enfrentar este camino y poder llevarlo a buen termino.

A mi esposa por estar a mi lado cada noche, cada tarde, cada fin de semana y permitirme terminar este camino que un día inicié y hoy culmina con este trabajo.

y

A mi hija, por ser el motivo para levantarme cada día y salir a la lucha. Es por un mejor futuro para ti que hoy este trabajo es concluido y nuevas aventuras empiezan.

Contenido

Lista de figuras	9
Lista de tablas	11
1. Introducción	12
1.1. Revisión de literatura	13
1.2. Justificación	15
1.3. Planteamiento del problema	17
2. Objetivo	20
2.1. Objetivo General	20
2.2. Objetivos específicos	20
3. Metodología	21
3.1. Bases de datos	21
3.1.1. Base de Datos Ninapro	22
3.1.2. Base de datos propia	25
3.2. Extracción de características	26
3.2.1. Características basadas en el dominio del tiempo (TD)	27
3.2.2. Características basadas en el dominio de la frecuencia (FD)	28
3.3. Clasificadores	29
3.3.1. Clasificador tipo perceptrón multicapa (MLPC)	30
3.3.2. Redes convolucionales	30
3.3.3. Transferencia de Aprendizaje (Transfer learning)	33
3.3.4. Validación de los modelos (Leave One Out - LOO)	34
3.3.5. Evaluación de los resultados	34
3.3.6. Evaluación del tiempo de ejecución del algoritmo	35
3.4. Sistema embebido	36
4. Resultados	39
4.1. MLPC	39
4.2. Redes Convolucionales	42
4.3. Transferencia de aprendizaje	44
5. Discusión	46

A. Carta de respuesta del comité de ética	49
B. Consentimiento Informado para los voluntarios en la captura de las señales	51
Bibliografía	58

Lista de Figuras

1-1. Número de artículos por año.	13
1-2. Configuración típica de un quirófano de neurocirugía. Muestra (1) la posición del cirujano, (2) instrumentadora, (3) instrumentadora circulante, (4) Anestesia, (5) microscopio, (6) Mesa de instrumentos, (7) pantallas, (8) mesa de paciente, (9) Cámaras	15
1-3. Disposición y delimitación de los espacios en una sala de cirugía.	16
1-4. Posición del microscopio y su uso durante la cirugía. Ejemplo de la necesidad de interactuar con el equipo de parte de la instrumentadora para saber los requerimientos del cirujano en el campo quirúrgico (Kantor et al., 2021) . . .	17
1-5. Cirujano interactuando con un sistema de navegación (cirugía guiada por imágenes – Marca Medtronic (StealthStation Surgical Navigation - Navigation — Medtronic, n.d.))	17
1-6. Ejemplo de una infección de sitio operatorio.(Cho et al., 2008)	18
3-1. Captura de la señal de EMG con la manilla MYO de Thalmic Labs	22
3-2. Movimientos de los dedos empleados para la captura de las señales de electromiografía (Solano, 2021)	24
3-3. Configuración de la base de datos, archivos generados por cada sujeto	26
3-4. Extracción de características de las señales	27
3-5. Extracción de los espectrogramas de las subventanas de cada canal, y apilamiento en una sola imagen por cada tipo de movimiento	29
3-6. Imágen de ejemplo de un espectrograma obtenido de una captura	30
3-7. Modelo de red Convolutacional # 1	31
3-8. Modelo de red Convolutacional # 2	31
3-9. Modelo de red Convolutacional # 3	32
3-10. Modelo de red Convolutacional # 4	32
3-11. Modelo de red Convolutacional # 5	32
3-12. Curvas de perdidas y precisión del modelo de red neuronal	33
3-13. Modelo de transferencia del conocimiento	34
3-14. Modelo de LOO (Leave One Out)	35
3-15. Representación de la matriz de confusión	35
3-16. Representación del tiempo transcurrido para ejecutar la acción completa del clasificador	36

3-17. Modelo del sistema embebido	37
3-18. Teclas de las funciones rápidas del sistema de imágenes	38
4-1. Gráfica de los resultados del clasificador MLPC empleando el método LOO .	40
4-2. Matriz de Confusión de los datos de la Base de datos NINAPRO mediante el uso del clasificador MLPC	41
4-3. Resultados de las configuraciones de los modelos del Clasificador CNN	43
4-4. Resultados de las configuraciones de los modelos 4 y 5, Clasificador CNN . .	44

Lista de Tablas

3-1.	Características de la población en la muestra de la base de datos	23
3-2.	Características de los sujetos de prueba empleados en la captura de señales de EMG	25
3-3.	Definición matemática de características, dado que X_k es la señal k ésima y N es el número de muestras en un segmento	28
3-4.	Hyperparámetros del Clasificador MLPC	30
4-1.	Tabla de resultados del clasificador MLPC	39
4-2.	Hyperparámetros encontrados mediante la exploración del clasificador MLPC	40
4-3.	Matriz de Confusión de los datos de la Base de datos capturada mediante el uso del clasificador MLPC en formato de representación de datos	41
4-5.	Resultados de la precisión de los modelos de CNN. Nota: Cada Configuración (Cnfg) - Hace referencia a la configuración del modelo de LOO definida en la figura 3-14	42
4-4.	Resultados de las diferentes configuraciones del clasificador MLPC	42
4-6.	Resultados de cada modelo	43
4-7.	Hyperparámetros de la CNN	43
4-8.	Resultados de la precisión obtenida, Transfer Learning	44
4-9.	Resultados de precisión de los diversos clasificadores estudiados	45
4-10.	Tiempos de ejecución de cada tipo de clasificador. Tiempos en segundos (s) .	45

1. Introducción

Las salas de cirugía son de los ambientes en donde se aplican más protocolos de seguridad y de control, comparados incluso con ambientes como la aeronáutica (Hales et al., 2008). Uno de los protocolos de estricto control en las salas de cirugía del mundo o incluso aquí en Colombia, es el de esterilidad. Este protocolo previene las infecciones de sitio operatorio, las complicaciones posteriores a la cirugía, o las infecciones que pueden resultar en tratamientos incluso más complejos que los originales a los que se sometía el paciente, en primera instancia (Restrepo et al., 2011). Una de las fuentes de contaminación que se ha visto con mayor frecuencia se da por el uso de equipos fuera del campo quirúrgico tales como equipos de cómputo, equipos de visualización de imágenes, entre otros. Estos equipos proveen información al cirujano durante el procedimiento, información que es vital en momentos específicos para la toma de decisiones clínicas (Jimenez et al., 2017). Poder interactuar con estos equipos, desde el ambiente quirúrgico, se ha tornado en una necesidad imperativa tanto para la industria como para los equipos médicos. En la búsqueda de soluciones a esta necesidad, se ha encontrado que la electromiografía superficial es una de las mejores opciones de bajo costo y facilidad de implementación (Tsuboi et al., 2017).

La electromiografía superficial ha sido por años uno de los métodos no invasivos, más eficientes y fáciles para construir sistemas de interacción entre sujetos y máquinas (Akhlaghi et al., 2016). El uso de la electromiografía superficial como método para manipular equipos, o prótesis de sujetos en condiciones de discapacidad, se ha convertido en un recurrente sistema de interacción (Anam and Al-Jumaily, 2017; Celadon et al., 2016; Tsuboi et al., 2017). La detección de los movimientos de la mano es uno de los retos más interesantes, al permitir manipulaciones más finas y más complejas (Alam et al., 2018; Behrenbeck et al., 2019). La relación con diversos sistemas mediante la interpretación de las activaciones musculares ha permitido crear diversos elementos de uso cotidiano, desde juegos para pequeños o adultos y llegando a desarrollos tales como exoesqueletos, o incluso interacción con elementos de maquinaria pesada (Behrenbeck et al., 2019; Park et al., 2018; Putra et al., 2019). Uno de los gremios que ha intentado incorporar este tipo de interacciones máquina-humano es el gremio médico, ya que hay situaciones donde la interacción física no es la más apropiada (Patel et al., 2019). Uno de estos momentos es el ámbito quirúrgico, ámbito en el que preservar la esterilidad del cirujano es de vital importancia, dada las implicaciones de contaminación y posteriores cuidados del paciente (Nishikawa et al., 2003). Y es en este punto, en el que el presente trabajo centra los esfuerzos. La búsqueda de un método de interacción con cierto

tipo de máquinas empleadas en el quirófano, para que el médico pueda de manera autónoma seleccionar la imagen que desea ver, o el método de visualización que más le aporte para el momento de la cirugía en el que se encuentre (Jimenez et al., 2017).

1.1. Revisión de literatura

Al revisar el estado actual de la tecnología en detección de los movimientos de la mano, mediante el uso de electromiografía superficial en el antebrazo, detectamos tendencias que apoyan el interés de la presente investigación (Fu et al., 2018; Quivira et al., 2018). Una revisión de literatura realizada en bases de datos tales como Academic Search Complete, IEEE, Ebsco HOST y Scopus ¹ permitió evidenciar un incremento en los artículos publicados en las bases de datos, entre los años 2016 y 2021 (Ver figura 1-1). Uno de los elementos que más llama la atención de la revisión realizada, es el bajo número de artículos que buscan evaluar los sistemas propuestos con el enfoque en la detección de los dedos. (Akhlaghi et al., 2016; Tsuboi et al., 2017).




Figura 1-1.: Número de artículos por año.

Los trabajos que se encuentran en la literatura se concentran en métodos de extracción de características de la electromiografía y clasificadores basados en datos previamente capturados (Anam and Al-Jumaily, 2017; Tsuboi et al., 2017), donde la clasificación se hace posterior a la adquisición y con aplicaciones que distan de un entorno real donde puedan usarse dichos sistemas. Dentro de la misma revisión es posible observar, que las técnicas empleadas para la clasificación de características extraídas de las señales de sEMG, se emplean algoritmos como las redes neuronales (Anam and Al-Jumaily, 2017; Quivira et al., 2018), mostrando robustez de la técnica frente a otro tipo de clasificadores. Otro de los hallazgos de la revisión de la literatura es el tipo de hardware empleado en la gran mayoría de los artículos, donde

¹Cadena de búsqueda empleada - Finger AND movement AND (detection OR recognition) AND Surface AND (EMG OR electromyography)

prevalece el uso de equipos de cómputo grandes, como computadores portátiles y sistemas de cómputo de escritorio, reduciendo la portabilidad del sistema Akhlaghi et al. (2016); Liu et al. (2016); Villarejo Mayor et al. (2017). La revisión de la literatura, permitió evidenciar que la electromiografía superficial (sEMG) es el método más empleado por los investigadores, sin embargo en varias ocasiones se mencionó la manilla MYO. Esta manilla, gracias a sus características tiene un gran potencial, por su flexibilidad y facilidad para la adquisición de los datos y aún existe un fuerte interés en su aplicabilidad, ya que se pudieron evidenciar investigaciones posteriores al fin de la producción de la manilla (Fu et al., 2018). Dado que un sistema de electromiografía portable, implica un reto adicional, fuera del objeto de la presente investigación, se prefirió emplear la tecnología que ya contaba con todos los elementos necesarios para cumplir con el objetivo principal de esta investigación.

La tecnología que es presentada cada día a nivel mundial, ha permitido avanzar en las capacidades de cálculo de los sistemas de manera más veloz y con un menor consumo energético. Esto se evidencia con la aparición de nuevos sistemas donde se puede implementar una red neuronal de pocas o múltiples capas, que se utiliza actualmente en sistemas de aprendizaje automático (*machine learning*), o más allá con el aprendizaje profundo (*deep learning*) (Behrenbeck et al., 2019; Zhang et al., 2017). Estos sistemas ofrecen implementaciones más portables a las encontradas en la literatura y hace parte de los objetivos que propone en el presente trabajo. Como criterio de selección de la tecnología, la portabilidad del sistema de cómputo es prioritario para el uso de hardware especializado en la implementación de sistemas basados en redes neuronales ², como las actuales unidades de cómputo neuronales portables. (Alam et al., 2018; Tan and Le, 2019)

La revisión de la literatura nos ha permitido enfocar esta investigación en los sistemas de clasificación de datos de electromiografía con énfasis en los movimientos de los dedos de la mano (Celadon et al., 2016; Stapornchaisit and Koike, 2018). La revisión nos ha permitido acceder a una base de datos para plantear los diseños de los clasificadores y poder probar los diferentes tipos de modelos y mecanismos de clasificación (Liu et al., 2016; Yang et al., 2016; Atzori et al., 2014).

Las investigaciones relacionadas con el manejo de dispositivos tecnológicos a distancia, y más aún en ámbitos como las cirugías, siguen apareciendo en las revisiones de literatura (Kubat and Berlengi, 2017). Los sistemas de control basados en la electromiografía superficial siguen siendo parte de las interfaces humano-computador más difundidas y de fácil aplicación en diversos contextos. (Qi et al., 2019). Por su particularidad y facilidad de implementación, las bandas de captura de las señales de electromiografía siguen atrayendo investigaciones en las que son usadas incluso en ambientes tales como las cirugías (Muhammad et al., 2020).

²www.intel.com/content/www/us/en/developer/tools/neural-compute-stick/overview.html

1.2. Justificación

Las neurocirugías como todas las otras especialidades de la cirugía, han tenido una evolución muy importante en los últimos años. La cirugía guiada por imágenes hace parte de estas evoluciones de la técnica en casos complejos. Cirugías tales como la neuronavegación, la cirugía de estimulación cerebral profunda, los implantes y biopsias por estereotáxia, exigen la interacción con sistemas de planeación y de imágenes, con reconstrucciones tridimensionales, planeación de trayectorias, entre otras necesidades. Adicional a esta necesidad, el cirujano y asistentes, requieren interactuar con estos equipos de manera remota, ya que la barrera de esterilidad no debe romperse por ningún motivo. Una configuración de una sala se puede apreciar en la Figura 1-2. Los diversos equipos en sala, no pueden “esterilizarse” por lo que la barrera de esterilidad se compromete cada que se emplean. Para poder superar este requerimiento, se emplean diversas opciones desde sistemas inalámbricos hasta integrar una persona adicional en el proceso. Sin embargo, todas estas interacciones, pese a sus grandes ventajas, no han permitido alcanzar la velocidad ni ventajas del uso de las diversas máquinas de manera autónoma por parte del cirujano.




Figura 1-2.: Configuración típica de un quirófano de neurocirugía. Muestra (1) la posición del cirujano, (2) instrumentadora, (3) instrumentadora circulante, (4) Anestesia, (5) microscopio, (6) Mesa de instrumentos, (7) pantallas, (8) mesa de paciente, (9) Cámaras

Como se puede observar en la Figura 1-2 y 1-3, las pantallas, y demás interacciones se encuentran aisladas de las manos de sus principales usuarios. Cirujanos, para corregir la orientación y/o visualización, instrumentadoras, para predecir los requerimientos de los cirujanos, por ejemplo.

Existen otros sistemas de interacción (Gülmez et al., 2021), sin embargo los altos costos

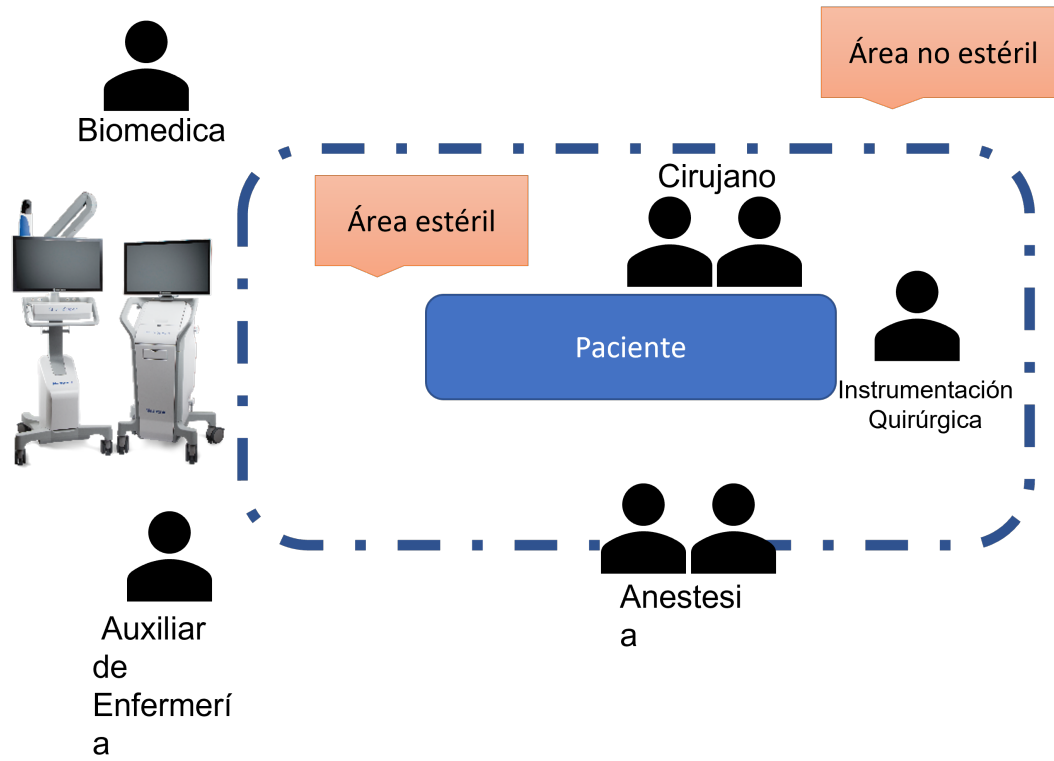


Figura 1-3.: Disposición y delimitación de los espacios en una sala de cirugía.

de estos, los requerimientos técnicos de las interfaces requeridas, limitan su aplicabilidad y difusión en los múltiples quirófanos, incluso en nuestros mismos países. Un ejemplo de estas interfaces, se hace con los microscopios de las salas de cirugía, como se puede apreciar en la Figura 1-4. Sin embargo, tal y como se ve en la Figura 1-5, interacciones donde se requiere una modificación de la visualización o simplemente interacciones más finas, las actuales interfaces quedan limitadas.

Actualmente en Colombia, este tipo de cirugías, son siempre acompañadas por un agente externo que sirve como manipulador de los sistemas de navegación, como se puede observar en la figura 1-5. Esto ha generado un incremento en el costo de los procedimientos, asociados al pago de los servicios de esta persona de acompañante. Debido a todas estas particularidades enunciadas, más alternativas en este campo de la neurocirugía son necesarias para brindar soluciones en las diferentes etapas. El presente trabajo pretende cubrir una de estas necesidades.

Las infecciones del sitio operatorio (ISO) (Ver figura 1-6) en neurocirugía son eventos frecuentes, clínicamente relevantes, con implicaciones importantes en morbilidad y mortalidad para los pacientes y en los costos para el sistema de salud. Es por esta razón, el manejo




Figura 1-4.: Posición del microscopio y su uso durante la cirugía. Ejemplo de la necesidad de interactuar con el equipo de parte de la instrumentadora para saber los requerimientos del cirujano en el campo quirúrgico (Kantor et al., 2021)



Figura 1-5.: Cirujano interactuando con un sistema de navegación (cirugía guiada por imágenes – Marca Medtronic (StealthStation Surgical Navigation - Navigation — Medtronic, n.d.))

adecuado de las ISO es fundamental (García-Casallas et al., 2020). Existen muchos métodos para prevenir y enfrentar las ISO. En el marco de esta investigación planteamos un método de interacción con los equipos externos al área estéril de manera inalámbrica, de fácil uso, lavable y que quede cubierto en todo momento para que en ningún momento de la cirugía quede expuesto al campo estéril del paciente(Caba et al., 2021).

1.3. Planteamiento del problema

El presente trabajo contiene una propuesta para la realización de un trabajo de grado para maestría que tiene como objetivo definir un modelo de clasificación mediante redes neuronales de los movimientos de los dedos de la mano, empleando electromiografía superficial en el antebrazo, permitiendo obtener un sistema portable con el uso de hardware especializado para este fin.



Figura 1-6.: Ejemplo de una infección de sitio operatorio.(Cho et al., 2008)

Así mismo, se busca implementar un clasificador en un sistema portable, por lo que se enfoca en redes neuronales artificiales de tamaño moderado, empleadas como técnica del aprendizaje automático, o evaluando una arquitectura de tamaño mayor con el uso de aprendizaje profundo. De estos algoritmos solo se utiliza y se emplea el de mejor desempeño, teniendo como base la comparación de la eficacia del sistema propuesto (Sharif et al., 2020).

Como tal, este trabajo explora tres tipos de clasificadores basados en diferentes propuestas de arquitectura de redes neuronales artificiales. El primero los perceptrones multicapa (MLPC, por sus siglas en inglés), el segundo las redes neuronales y finalmente, la transferencia de aprendizaje empleando redes neuronales de gran capacidad de clasificación. La extracción de características y la construcción de las imágenes necesarias para entrenar los modelos, hacen

parte de la investigación del presente trabajo. La comparación de los resultados obtenidos de estos modelos, nos permitirá definir cuál es el mejor modelo de clasificación de los movimientos de los dedos de la mano, para los fines de esta investigación.

2. Objetivo

2.1. Objetivo General

Implementar un sistema embebido basado en modelos de redes neuronales para la clasificación de movimiento de los dedos, empleando electromiografía superficial a la altura del antebrazo, para permitir la interacción de sistemas en un área de cirugía, con los profesionales del área de la salud, desde el área estéril.

2.2. Objetivos específicos

- Desarrollar modelos basados en redes neuronales, que permitan la clasificación de los movimientos de los dedos, empleando características extraídas de registros de electromiografía de superficie.
- Implementar algoritmos basados en redes neuronales artificiales en un sistema de cómputo embebido, que permita clasificar los movimientos de los dedos de la mano.
- Establecer un protocolo de adquisición de capturas, con sujetos sanos en el laboratorio.
- Validar la sensibilidad y especificidad del sistema desarrollado, mediante pruebas establecidas tanto para los registros en base de datos, como los registros obtenidos para el presente estudio.

3. Metodología

Cuatro numerales componen el eje principal de esta investigación. En el primer numeral se revisan las bases de datos existentes y las características de las poblaciones en estas, de tal manera que podamos construir una base de datos propia y así probar los modelos construidos tanto con las bases de datos existentes como con la construida. Al revisar la literatura y las bases de datos, se establece el protocolo a seguir con los datos obtenidos en las bases de datos y se extraen los parámetros de la población requerida, de manera que se puedan seguir los mismos parámetros y de igual modo conseguir comparación de resultados y permitir una repetibilidad.

En el segundo numeral se revisan los métodos de la extracción de características de las señales de electromiografía superficial y la identificación de algoritmos actuales, que han planteado métodos para clasificar los movimientos de los dedos de la mano.

En el tercer numeral se realiza el diseño del clasificador. Se proponen tres tipos de clasificadores: los basados en perceptrones multicapa (MLPC), los modelos de redes neuronales convolucionales y finalmente la transferencia de aprendizaje empleando redes convolucionales previamente entrenadas.

Finalmente, el último numeral explicará el método para construir el modelo de manera embebido. Los elementos que se emplean, la unidad central de procesamiento empleada y el elemento empleado para transferir los datos clasificados en una señal interpretable por el sistema de equipo biomédico en el quirófano.

3.1. Bases de datos

Una revisión de la literatura permite establecer cuales son los métodos de captura de las señales de electromiografía superficial. La revisión de estas bases de datos permite conocer las características de la población involucrada y las protocolos de captura de las señales.

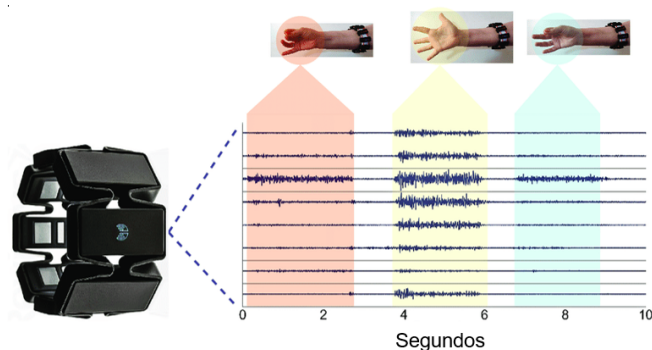


Figura 3-1.: Captura de la señal de EMG con la manilla MYO de Thalmic Labs

La revisión de literatura mostró que existen diversas bases de datos con recopilación de datos de electromiografía superficial, sin embargo para efectos de esta investigación se requiere contar con sujetos sin deficiencias conocidas, por lo que se optó emplear los datos de bases de datos NINAPRO (Liu et al., 2016; Yang et al., 2016), la cual contiene el registro de electromiografía empleando el sistema de 8 sensores de electromiografía superficial Thalmic Labs - MYO. Los datos en este repositorio son de uso libre y están destinados para el empleo en desarrollo de clasificadores de movimiento de los dedos (Atzori et al., 2014). Las características de la población se consignaron en la Tabla 3-1 que se puede observar a continuación.

3.1.1. Base de Datos Ninapro

Ninapro es una base de datos multimodal disponible públicamente para fomentar la investigación sobre manos robóticas y protésicas controladas con inteligencia artificial. Ninapro incluye electromiografía, cinemática, inercial, seguimiento ocular y datos neurocognitivos visuales y clínicos. Los datos de Ninapro son utilizados en todo el mundo por investigadores científicos, en aprendizaje automático, robótica, ciencias médicas y neurocognitivas. El conjunto de datos del Set 5 (DB5) incluye 10 sujetos sin afecciones neurológicas o físicas conocidas grabados con dos brazaletes Thalmic Myo, colocándolos en el mismo antebrazo simultáneamente.

Tabla 3-1.: Características de la población en la muestra de la base de datos

Características	Detalles
Número de Sujetos	10
Género de los sujetos	8 Hombres y 2 Mujeres
Edad Promedio	28 Años
Estatura	172 cm
Peso Promedio	68 kg
Frecuencia de muestreo	200 Hz
Resolución	8 Bits
Filtros Integrados	Notch 50Hz

En el set de datos DB5 de la Base de datos, el sujeto lleva dos brazaletes Myo, uno al lado del otro. El brazalete Superior Myo se coloca más cerca del codo con el primer electrodo en la articulación radio humeral, siguiendo la configuración del electrodo Ninapro. El brazalete Inferior Myo se coloca justo debajo del primero, más cerca de la mano. Dado que el presente trabajo, contempla únicamente el uso de un único sistema de captura, se escogen los datos entregados por el primer brazalete.

La base de datos NINAPRO en su apartado DB5 establece los parámetros con los que se obtuvieron los datos de electromiografía de 10 sujetos sanos (Atzori et al., 2014). Las capturas realizadas se hicieron en 3 diferentes experimentos, los cuales constan de 12 movimientos, 16 movimientos y 22 movimientos respectivamente (Pizzolato et al., 2017). Para el objeto de este estudio, se emplearon únicamente los movimientos del experimento A con 12 movimientos (ver Figura 3-2) dado que estos presentan suficiente simpleza y facilidad de usar en el seno del objetivo de usuario como el planteado en este trabajo de investigación (Atzori et al., 2014). En los procedimientos quirúrgicos los movimientos sencillos y que permitan realizar acciones preconfiguradas, son de gran utilidad en el proceso de estandarización de los procedimientos. Los doce movimientos (12) que se expusieron poseen esta característica y permiten que los movimientos que deba realizar el usuario sean lo suficientemente pequeños para que no se incurra en un riesgo de pérdida de esterilidad por movimientos con toda la extremidad superior por citar un ejemplo (Kubat and Berlengi, 2017).



Figura 3-2.: Movimientos de los dedos empleados para la captura de las señales de electro-miografía (Solano, 2021)

Los datos de las capturas realizadas con los brazaletes MYO, corresponden a 3 ejercicios realizados por el mismo sujeto. Como se explicó previamente, se seleccionan únicamente los datos del experimento A. En cada captura se pueden obtener los datos del acelerómetro, el giroscopio, la orientación en ángulos Euler y los datos de electromiografía (Côté-Allard et al., 2019). Todos estos datos salen del sistema en cuatro archivos CSV con una marca de tiempo. La marca de tiempo es interpretada en unidades de milisegundos para posteriormente usar los datos de manera acorde a los cálculos requeridos en función del tiempo o la frecuencia.

Los datos de las características y las imágenes de cada sujeto, son almacenadas en la carpeta de los sujetos. En el caso de los cálculos, estos se almacenan en un archivo plano, el cual como se describió, tiene un total de 73 columnas y un número de registros equivalentes al tiempo que le toma al sujeto realizar todas las tareas. En el caso de las imágenes, el número es equivalente al número de registros anteriormente descritos. Estas imágenes son almacenadas en una carpeta bajo la subcarpeta del sujeto. Las imágenes son posteriormente encapsuladas en un archivo HDF5 (High-performance data management and storage suite)¹.

¹<https://www.hdfgroup.org/solutions/hdf5/>

3.1.2. Base de datos propia

Para poder construir la base de datos propia, los sujetos invitados a participar de esta etapa son sujetos sanos, sin deficiencias neurológicas conocidas, dado que se busca imitar las condiciones de los futuros usuarios de este sistema. Los sujetos invitados siguieron los parámetros de la población empleada en la base de Datos NINAPRO (Akhlaghi et al., 2016; Behrenbeck et al., 2019; Park et al., 2018). En el diseño experimental se plantea capturar los datos de 10 sujetos, sin embargo se lograron obtener datos de 5 individuos únicamente ya que dada la coyuntura asociada a la pandemia por Covid-19 en Colombia los sujetos invitados a participar restringieron sus interacciones por ser personal de la salud, altamente expuesto. Como parte de las modificaciones que se tuvieron que seguir, se adicionaron parámetros de bioseguridad al protocolo de captura de los datos, esto con el fin de cumplir con las regulaciones dispuestas por el Ministerio Nacional de Salud.

Tabla 3-2.: Características de los sujetos de prueba empleados en la captura de señales de EMG

Características	Detalles
Número de Sujetos	5
Género de los sujetos	2 Hombres y 3 Mujeres
Edad Promedio	38 Años
Estatura	166 cm
Peso Promedio	75 kg
Frecuencia de muestreo	200 Hz
Resolución	8 Bits
Filtros Integrados	Notch 50Hz

Los criterios expuestos en la tabla **3-2** permiten determinar la elegibilidad del sujeto. En contraposición, se definieron los siguientes datos como criterios de exclusión: Edad promedio con un rango de 10 años mas o menos. El peso, la estatura y el genero no se consideraron criterios de exclusión.

Los sujetos de prueba ejecutaron doce (12) movimientos específicos (ver Figura **3-2**). Estos registros se almacenan custodiando la confidencialidad de los sujetos de prueba, para posteriormente evaluar el sistema de clasificación. Se planteó el uso de los mismos movimientos, para la captura de señales de sujetos, y dichas capturas son anexadas al estudio, para validar el clasificador propuesto. El protocolo para dichas capturas se detalla en el anexo “protocolo de captura” (Ver anexo 1) con su respectivo aval por parte del comité de etica de la Universidad del Rosario, el cual consta de una presentación del movimiento en cuestión, los tiempos estipulados para cada movimiento y el tiempo de reposo entre un movimiento y otro. Los

tiempos de adquisición y reposo fueron de 5 segundos por cada movimiento, con un reposo de 5 segundos entre cada movimiento. La elección del tiempo de captura y reposo está ligada a los protocolos empleados en la captura de los datos por parte de los investigadores de la base de datos de NINAPRO (Liu et al., 2016; Atzori et al., 2014) La captura total fue de 2 minutos por cada sujeto.

Siguiendo el mismo protocolo que se empleó para la extracción de características e imágenes de los datos obtenidos en la base de datos NINAPRO, los datos capturados son almacenados en un archivo plano CSV con las características de cada captura realizada, y las imágenes son almacenadas en una subcarpeta en un archivo HDF5 (Ver Figura 3-3).

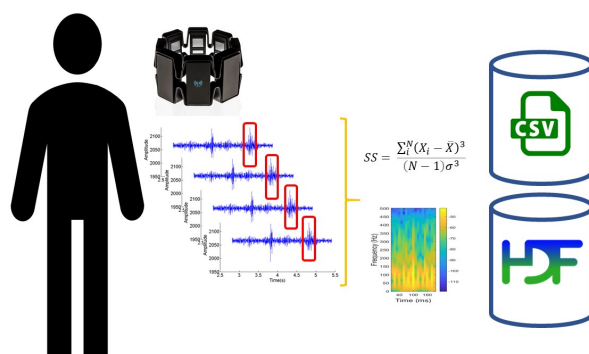


Figura 3-3.: Configuración de la base de datos, archivos generados por cada sujeto

Las bases de datos se constituyen de esta manera: 10 archivos CSV y 10 archivos HDF5 para las capturas de la base de datos NINAPRO y 5 archivos CSV y 5 archivos HDF5 para los datos capturados en este trabajo.

3.2. Extracción de características

La revisión de literatura permitió definir las características de las señales de electromiografía más usadas, ya sea por su facilidad de extracción o por la velocidad para obtener los datos requeridos. Las características se dividen en las basadas en el dominio temporal (TD) y las basadas en el dominio de la frecuencia (FD) (Khushaba et al., 2017). Las más usuales y con las que se han obtenido las mejores tasas de clasificación son: Slope sign changes (SSC), cruces por cero de la señal (ZC, del inglés zero crossing), Longitud de onda (WL, waveform length), parámetros Hjorth en el dominio tiempo (HTD del inglés Hjorth time-domain parameters), asimetría de muestras (SS, del inglés sample skewness), valor medio absoluto (MAV del inglés mean absolute value), valor de pendiente medio absoluto (MAVS, mean absolute

value slope), valor medio cuadrático (RMS del inglés root mean square). Todas estas características se pueden detallar en la Tabla **3-3**, junto a sus respectivas fórmulas matemáticas (Anam and Al-Jumaily, 2017).

3.2.1. Características basadas en el dominio del tiempo (TD)

En la caracterización de las señales de electromiografía se emplean los cálculos estadísticos mencionados en la Tabla **3-3**. Cada señal capturada es subdividida en ventanas de 200ms. La señal capturada por la MYO se obtuvo a una frecuencia de 200hz (Sharif et al., 2020). Para poder ser analizada, se dividió cada 200 ms, dejando así un total de 40 datos cada sub-ventana. Cada Sub-ventana tiene un traslape del 50 % con la ventana inmediatamente anterior, lo cual permite aumentar el número de muestras y ampliar así la base de datos obtenida (Ver Figura **3-4**). El brazalete de captura MYO al tener 8 sensores, entrega 8 señales en paralelo. La extracción aquí descrita se aplica a cada uno de los canales. Estos datos obtenidos para cada uno de los canales (Atzori et al., 2014), se concatenan de manera horizontal, permitiendo así obtener una base de datos con 10 características de datos por cada canal y una columna con la información del movimiento que se realizó. Al concatenar los datos, se obtiene así una base de datos con 73 columnas de datos. El número de registros es variable, dado que está sujeto al tiempo que le toma a cada sujeto completar la tarea. Aproximadamente cada sujeto genera 1200 registros.




Figura 3-4.: Extracción de características de las señales

Tabla 3-3.: Definición matemática de características, dado que X_k es la señal késima y N es el número de muestras en un segmento

Característica	Fórmula matemática
Slope sign changes (SSC),	$SSC = \sum_{k=1}^N Z_k, Z_k = \begin{cases} 0 & (x_k > x_{k-1} \wedge x_k > x_{k-1}) \\ 1 & (x_k < x_{k-1} \wedge x_k < x_{k-1}) \\ 0 & x_k - x_{k+1} \geq \text{humbral} \\ 0 & x_k - x_{k+1} \leq \text{humbral} \\ 0 & \text{Resto} \end{cases}$
Cruces por cero de la señal (ZC, del inglés zero crossing)	$ZC = \sum_{k=1}^N Z_k$ $Z_k = \begin{cases} 1 & (x_k x_{k+1} < 0 \wedge x_k - x_{k+1} \geq \text{humbral}) \\ 0 & \text{Resto} \end{cases}$
Longitud de onda (WL, waveform length)	$WL = \sum_{i=1}^N x_i - x_{i-1} $
Parámetros Hjorth en el dominio tiempo (HTD del inglés Hjorth time-domain parameters)	$HTD_0 = var(x(t))$ $HTD_1 = \sqrt{\frac{HTD_0(\frac{dx(t)}{dt})}{HTD_0(x(t))}}$ $HTD_2 = \frac{HTD_1(\frac{dx(t)}{dt})}{HTD_1(x(t))}$
Asimetría de muestras (SS, del inglés sample skewness)	$SS = \frac{\sum_i (x_i - \bar{X})^3}{(N-1)\sigma^3}$
Valor medio absoluto (MAV del inglés mean absolute value),	$\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i $
Valor de pendiente medio absoluto (MAVS, mean absolute value slope),	$MAVS = MAV_{k+1} - MAV_k$
Valor medio cuadrático (RMS, root mean square)	$X_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i ^2}$

3.2.2. Características basadas en el dominio de la frecuencia (FD)

Formula de la densidad energética espectral

$$E = \int_{-\infty}^{\infty} |x(t)|^2 dt \quad (3-1)$$

Las redes neuronales convolucionales requieren de imágenes como elementos para entrenamiento. La construcción de estas imágenes se realiza de la siguiente manera: Cada ventana

de 40 datos es analizada mediante un análisis de las frecuencias presentes en la señal, la extracción de las frecuencias se logra al emplear la ecuación 3-1. Cada ventana anteriormente descrita, fue empleada para construir un espectrograma con la información de frecuencias (Ver la figura 3-5). Cada imagen obtenida por cada canal, es apilada horizontalmente con la siguiente imagen para así obtener una sola imagen, con el total de los datos del movimiento descrito. Dichas imágenes, son etiquetadas, con el código del movimiento realizado, y almacenadas, bajo la base de datos del sujeto caracterizado.




Figura 3-5.: Extracción de los espectrogramas de las subventanas de cada canal, y apilamiento en una sola imagen por cada tipo de movimiento

3.3. Clasificadores

La revisión de literatura también permitió determinar los sistemas de clasificación de los movimientos. En la actualidad, los sistemas de cómputo se basan en algoritmos como linear discriminant analysis classifier (LDA) (Villarejo Mayor et al., 2017) y Support Vector Machine (SVM) (Soman et al., 2016). Entre los clasificadores que se proponen en la literatura para el estudio de estas bases de datos obtenidas, los más empleados son los clasificadores tipo MLPC (Perceptrón multicapa), redes convolucionales y clasificadores basados en transferencia de conocimientos a redes previamente entrenadas.

Cada clasificador tiene una serie de parámetros que pueden alterarse buscando obtener un mejor resultado al realizar la clasificación de los datos que se emplean. Dado que no existe un método para la elección de los parámetros, se emplea un método de exploración con cada uno de ellos (Ver tabla 3-4).

Existen detalles tales como la capa de entrada y la capa de salida de cada una de estos clasificadores. En la capa de entrada se debe parametrizar el número de variables que se reciben. En el caso de las características calculadas, son 72 variables las que se introducen, mientras que en el caso de las imágenes de los espectrogramas, para los clasificadores de

aprendizaje profundo, son imágenes de algunos cuantos píxeles (Ver la figura 3-6), los que se cargan desde el archivo HDF5 junto con su índice, identificando los movimientos realizados.

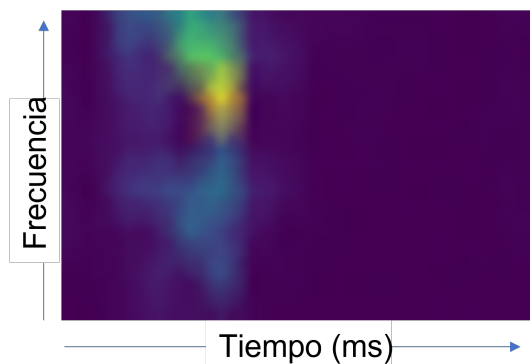


Figura 3-6.: Imagen de ejemplo de un espectrograma obtenido de una captura

Cada clasificador explorado, se detalla a continuación.

3.3.1. Clasificador tipo perceptrón multicapa (MLPC)

En el caso del clasificador tipo MLPC en la Tabla 3-4 se pueden observar los hiperparámetros escogidos y las variaciones que se propusieron de cada uno de ellos. Entre los hiperparámetros que usualmente se varían está el optimizador de pesos, el método de activación, el número máximo de iteraciones y el tipo de aprendizaje.

Tabla 3-4.: Hiperparámetros del Clasificador MLPC

Parámetro	Opción 1	Opción 2	Opción 3	Opción 4
Solver	SDG	ADAM		ADAM
alpha	0.0001	1e-5		1e-5
Activación	tanh	relu	logistics	logistics
Max Iter	10	30	50	100
Num. Hidden Layers	(10,10)	30	50	(10,10)
Learning Rate	Constant	Adaptative		Adaptative

3.3.2. Redes convolucionales

La revisión del estado del arte muestra diversas configuraciones. Se emplearon 5 modelos descritos y se modifica la capa de salida del clasificador expuesto (Simão et al., 2019) para hacerlo compatible con las 13 opciones de movimiento descritas en la figura 3-2 y el movimiento de reposo. Cada modelo de la red es evaluado mediante la configuración de las capas de cada modelo. Se pueden detallar estos modelos en las figuras 3-7 a la 3-11. De cada modelo evaluado, se extraen parámetros que permiten evaluar su capacidad de aprendizaje y su

nivel de entrenamiento, basado en los datos que se le introducen. Las curvas de precisión y perdidas para entrenamiento vs test, de estos modelos, nos permiten evaluar el modelo y su comportamiento de acuerdo con los hiperparámetros propuestos. Cada capa de cada modelo puede contener ya sea una convolución y una normalización. Otro tipo de capa puede ser una convolución 2D y una unidad de rectificación lineal. Posterior a las capas anteriormente descritas, se emplearon operaciones tales como agrupaciones (Max pooling) o reducción de la dimensionalidad (Flatten).

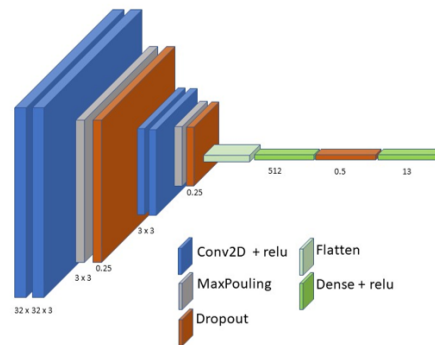


Figura 3-7.: Modelo de red Convolucional # 1

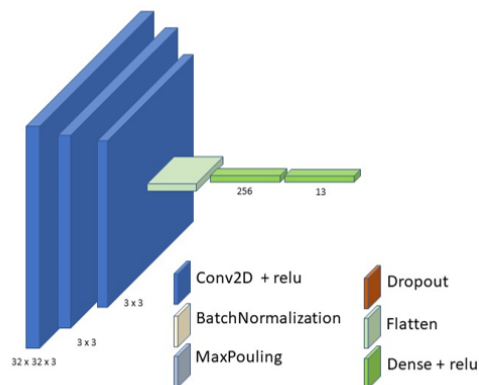


Figura 3-8.: Modelo de red Convolucional # 2




Figura 3-9.: Modelo de red Convolutacional # 3




Figura 3-10.: Modelo de red Convolutacional # 4




Figura 3-11.: Modelo de red Convolutacional # 5

Los diferentes modelos son evaluados y de cada evaluación se extraen las curvas de pérdida y la precisión del modelo (ver Figura 3-12). Estas curvas permiten evaluar la eficiencia del modelo. En las curvas se puede observar el comportamiento en cada iteración del conjunto

de datos de entrenamiento, así como el comportamiento de los datos validación. Esto permite evitar sesgos asociados al tipo de datos que es capaz de evaluar el sistema. Las curvas permiten conocer el nivel de entrenamiento del modelo (muy poco entrenado a sobreentrenamiento). Estas curvas nos entregan un dato de precisión de cada modelo evaluado en función de los datos empleados en el entrenamiento y posteriormente en la evaluación.




Figura 3-12.: Curvas de pérdidas y precisión del modelo de red neuronal

3.3.3. Transferencia de Aprendizaje (Transfer learning)

El tercer clasificador evaluado en este estudio corresponde el uso de la metodología de transferencia del aprendizaje (Transfer learning). En este tipo de clasificadores se emplea un modelo previamente entrenado y se le modifican tanto capa de entrada para que las imágenes construidas puedan ser empleadas en la clasificación y la capa de salida para que los resultados correspondan con las categorías a clasificar (Ver figura **3-13**). En el caso de la capa de salida, dado que hay 13 posibles opciones se reemplaza para obtener así la clasificación esperada. La revisión de literatura permitió definir varios modelos entre los cuales se escogieron: VGG-16², ResNet50³, y DenseNet121⁴. Estas Redes se emplearon por su alta precisión para la clasificación de imágenes y por reducir el efecto de rotación de los electrodos al momento de tomar las capturas de electromiografía (Ameri et al., 2020)

²<https://neurohive.io/en/popular-networks/vgg16/>

³<https://iq.opengenus.org/resnet50-architecture/>

⁴<https://keras.io/api/applications/densenet/>

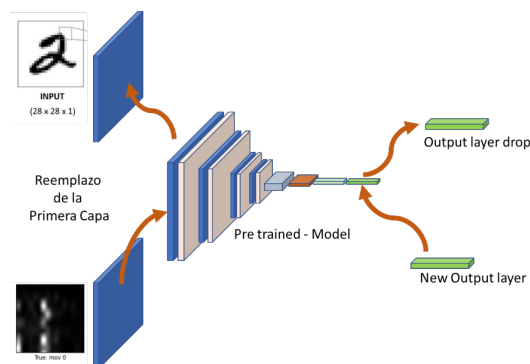


Figura 3-13.: Modelo de transferencia del conocimiento

La evaluación de los modelos de transferencia del conocimiento se hace mediante las curvas de precisión y pérdidas (ver Figura 3-12). Se obtiene un porcentaje que representa el valor de la precisión alcanzada y el nivel de pérdidas que se obtiene al emplear este modelo en específico.

3.3.4. Validación de los modelos (Leave One Out - LOO)

Todos los modelos, se evalúan mediante la combinación de sujetos de prueba y sujetos para validación. Esto permite garantizar que un sujeto que no está entre los datos de aprendizaje, sea sujeto de pruebas del modelo estudiado. Para evidenciar la precisión del clasificador propuesto, se realiza un entrenamiento del sistema empleando nueve (9) sujetos para entrenamiento y dejando un (1) sujeto para validación (método Leave one out). Este proceso se repite con cada sujeto de prueba. Las 10 configuraciones obtenidas (Figura 3-14) permiten una validación cruzada de los registros obtenidos (Bradley, 2010). Los datos restantes se destinan a la validación del clasificador. Esto permite generar un entrenamiento de la red neuronal y luego facilita la evaluación de cuantos movimientos es capaz el clasificador de reconocer y con qué efectividad puede clasificarlos. El ejercicio además permite evaluar, los diferentes parámetros empleados en la configuración del clasificador y por tanto modificarlos hasta alcanzar resultados de desempeño comparables con los que se establecen en la revisión de la literatura realizada (Sharif et al., 2020). Al variar el sujeto de validación, se obtienen 10 configuraciones de sujetos de entrenamiento y validación.

3.3.5. Evaluación de los resultados

Los resultados son expresados en forma de una matriz de confusión donde se representan las clasificaciones obtenidas versus las clasificaciones esperadas de acuerdo a la figura 3-15

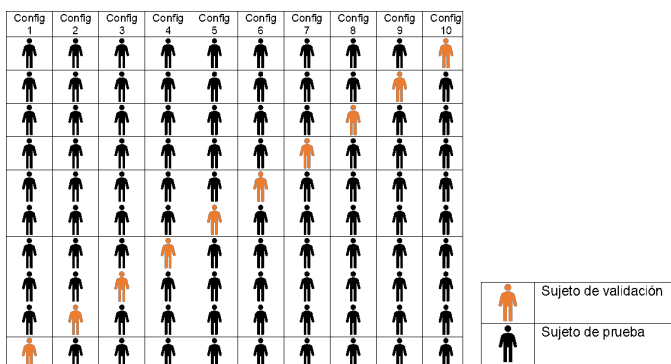


Figura 3-14.: Modelo de LOO (Leave One Out)



Figura 3-15.: Representación de la matriz de confusión

Finalmente los datos obtenidos se expresan en forma de un porcentaje de precisión. Donde VP son los verdaderos positivos, VN son los verdaderos negativos, FP son los falsos positivos y FN son los falsos negativos. La ecuación 3-2 permite calcular la precisión de los datos. Esta métrica permite comparar los resultados empleados en los diversos trabajos realizados en este mismo objetivo de investigación (Anam and Al-Jumaily, 2017)

Formula de la precisión

$$Precision = \frac{\sum VP + VN}{\sum VP + FP + VN + FN} \quad (3-2)$$

3.3.6. Evaluación del tiempo de ejecución del algoritmo

Los diferentes clasificadores son evaluados gracias a su efectividad e igualmente mediante el tiempo que les toma realizar la tarea solicitada. Para obtener este objetivo (ver figura 3-16) se evaluó el tiempo que le tomó a la misma máquina extraer una ventana de electromiografía de los 8 canales, posteriormente, extraer los datos correspondientes de esta, ya sea extracción de características, o conversión en una imagen. Posteriormente, se pasa al clasificador con objeto de que este genere un resultado evaluando el posible movimiento al cual corresponde

esta ventana escogida. Al terminar esta última acción, la plataforma de programación entrega el resultado en tiempo de ejecución de la acción realizada.

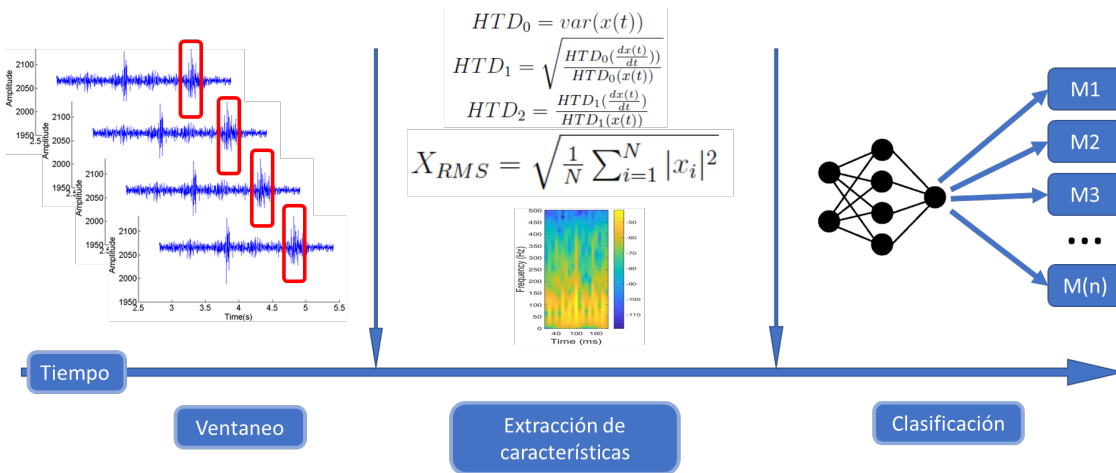


Figura 3-16.: Representación del tiempo transcurrido para ejecutar la acción completa del clasificador

Los resultados de este ejercicio son evaluados con 5 muestras aleatorias, con el fin de determinar un tiempo promedio de ejecución y los resultados son consignados en una tabla para su posterior análisis.

3.4. Sistema embebido

El mejor clasificador obtenido por medio de las bases de datos tanto NINARPO como propia de acuerdo a las pruebas de precisión, se implementa en un sistema embebido, basado en dispositivos como una Raspberry Pi (Raspberry Pi 4 Model B) y un módulo especializado para modelos de redes neuronales como el Neural Computer Stick (NCS) de Intel (Intel® Neural Compute Stick 2). Al ser estos dos sistemas embebidos, se abre la posibilidad que sea un sistema portable (Ver figura 3-17).




Figura 3-17.: Modelo del sistema embebido

El Sistema de captura transmite la señal de la electromiografía a la unidad central de procesamiento Raspberry Pi. Esta Unidad, genera la extracción de características de la señal y la entrega al clasificador escogido que se encuentra embebido en la NCS, el cual puede albergar el clasificador basado en redes convolucionales. Este genera una respuesta, la cual es interpretada nuevamente por la Raspberry Pi. De acuerdo al movimiento encontrado, una señal serial es emitida a la placa Arduino DUE. Esta se encarga de interpretar la señal y transformarla en una señal serial interpretable por un computador cualquiera como una señal de un teclado. Se escogió como señal de interpretación las funciones (F1, F2, ... F12).

Para efectos de no requerir instalar ningún software ni manipular el sistema objetivo (estación de neurocirugía), se prefiere simular el comportamiento del sistema que interactúa como un teclado USB. Esto se logró mediante el uso de un ARDUINO DUE, el cual cuenta con un puerto de programación y un puerto nativo USB. Este segundo conectado al sistema final, y el primero conectado al Raspberry Pi.

En el sistema de imágenes empleado para esta investigación, las teclas de funciones rápidas resumen las interacciones más frecuentemente empleadas por los cirujanos. Durante el procedimiento quirúrgico, cambiar las vistas de las imágenes necesarias, incrementar o disminuir los niveles de energía de ciertos dispositivos, entre otras interacciones, son acciones de frecuente uso. El permitir configurar un sistema de interacción con dichas teclas de acciones rápido, permite emular comandos en el teclado. En el caso del sistema de visualización de imágenes de neurocirugía, las teclas de funciones rápidas, permiten intercambiar las vistas, así como activar o desactivar los punteros de posición en dichas imágenes. Estas funciones

se resumen en la figura 3-18.

Teclas de acceso rápido

Tecla de acceso rápido	Resultado
<Alt> + <N>	Abrir un cuadro de diálogo para guardar un archivo de notas en un directorio de exámenes
<Alt> + <T>	Mostrar las descripciones de todas las anotaciones
<F1>	Seleccionar la perspectiva predefinida uno, si se ha guardado
<F2>	Seleccionar la perspectiva predefinida dos, si se ha guardado
<F3>	Seleccionar la perspectiva predefinida tres, si se ha guardado
<F4>	Alternar entre un punto y líneas de cruces
<F5>	Alternar giro automático 3D en la tarea PointMerge®
<F9>	Crear una anotación cuando la interfaz Annotations (Anotaciones) está abierta

Figura 3-18.: Teclas de las funciones rápidas del sistema de imágenes

El Arduino se encarga de interpretar la señal exportada por el clasificador, y la convierte en un comando o tecla función (F1, F2, ... F12). La tecla función es interpretada por el sistema de imágenes, y realiza una acción correspondiente.

4. Resultados

Los diferentes clasificadores son entrenados y evaluados con los mismos sujetos de prueba. En una primera instancia con los datos de la base de datos NINAPRO y en segundo lugar con los datos de la base de datos propia. El entrenamiento de los modelos permite determinar qué tan preciso es este proceso. Los resultados de cada método de clasificación se consignan en los siguientes apartados. Con cada clasificador, se evaluó tanto la precisión, como el tiempo que le tomó al método, llegar a la clasificación esperada. Estos dos conjuntos de resultados nos han permitido concluir cuál es el mejor sistema para resolver la pregunta problema que nos hemos planteado, en el seno de este trabajo de investigación.

4.1. MLPC

La exploración de los hiperparámetros que se describieron en la tabla 4-2, dió como resultados los descritos en la tabla 4-1. Al emplear el método de validación Leave One Out se puede observar una consistencia en los resultados observados. Estos resultados son resumidos en la Figura 4-1. Los resultados de esta evaluación oscilan entre 63.3% y 68.7%. El máximo resultado de precisión es 68.7% alcanzado con el experimento número 1.

Tabla 4-1.: Tabla de resultados del clasificador MLPC

	Promedio	Desviación estándar
Puntaje Entrenamiento EXP 1	68.7%	0.01
Puntaje Test EXP 1	63.3%	0.04
Puntaje Entrenamiento EXP 2	64.4%	0.00
Puntaje Test EXP 2	63.5%	0.02
Puntaje Entrenamiento EXP 3	66.4%	0.01
Puntaje Test EXP 3	63.3%	0.03
Puntaje Entrenamiento EXP 4	66.4%	0.01
Puntaje Test EXP 4	63.3%	0.03

Los hiperparámetros del Experimento 1, son resumidos en la tabla 4-2.




Figura 4-1.: Gráfica de los resultados del clasificador MLPC empleando el método LOO

Tabla 4-2.: Hyperparámetros encontrados mediante la exploración del clasificador MLPC

Parámetro	Hyperparámetro encontrado mediante la exploración
Solver	Adam
Alpha	0.0001
Activation	Relu
Max Iter	30
Hidden Layer Sizes	(100)
Learning Rate	Constant

Después de determinada la combinación de parámetros, se procede a generar una matriz de confusión para calcular el valor de la precisión del clasificador escogido y evaluar el movimiento con el mejor índice de precisión.

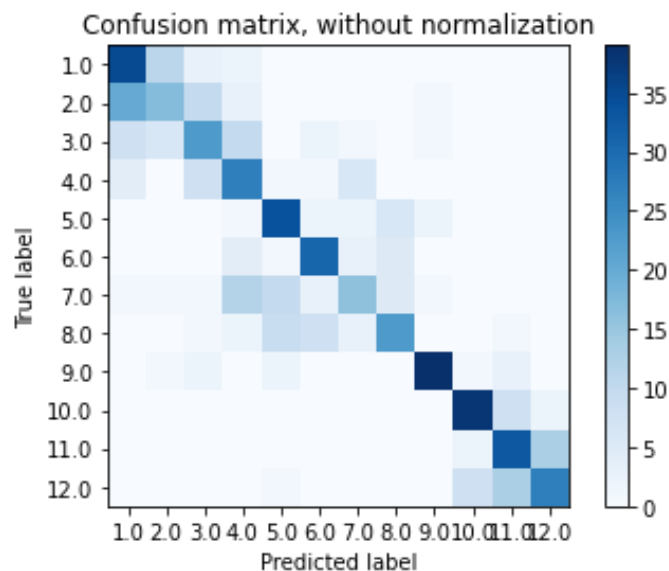


Figura 4-2.: Matriz de Confusión de los datos de la Base de datos NINAPRO mediante el uso del clasificador MLPC

El resultado de esta prueba tuvo una precisión de $63,3 \pm 3\%$ (Ver la Figura 4-2). Un análisis de esta matriz, permite determinar que los movimientos con mayor índices de precisión son los movimientos 9, 10, 1 y 5 respectivamente. El movimiento 1 corresponde a la flexión del dedo índice, el 5 a la flexión del dedo anular, el 9 a la aducción del dedo pulgar y el 10 a la abducción del dedo pulgar (ver la tabla 4-3).

Tabla 4-3.: Matriz de Confusión de los datos de la Base de datos capturada mediante el uso del clasificador MLPC en formato de representación de datos

90%	3%	0%	0%	0%	0%	3%	0%	0%	0%	2%	1%	1%
67%	29%	2%	0%	2%	0%	0%	0%	0%	0%	0%	0%	0%
57%	18%	12%	10%	4%	0%	0%	0%	0%	0%	0%	0%	0%
37%	12%	0%	27%	10%	0%	4%	2%	8%	0%	0%	0%	0%
36%	6%	6%	9%	9%	0%	0%	23%	11%	0%	0%	0%	0%
17%	0%	0%	0%	0%	47%	11%	0%	21%	4%	0%	0%	0%
7%	0%	0%	0%	0%	0%	66%	9%	18%	0%	0%	0%	0%
40%	2%	0%	0%	0%	6%	6%	12%	34%	0%	0%	0%	0%
15%	0%	0%	0%	0%	21%	19%	0%	45%	0%	0%	0%	0%
27%	0%	0%	4%	0%	2%	0%	0%	0%	60%	4%	2%	0%
25%	0%	0%	0%	0%	0%	0%	0%	0%	4%	71%	0%	0%
42%	0%	0%	0%	0%	0%	0%	0%	0%	0%	13%	35%	10%
35%	0%	0%	0%	0%	0%	0%	0%	0%	6%	24%	12%	22%

Al emplear los datos capturados, se puede apreciar que los movimientos que más alto índice de precisión presentan, son el movimiento 3, el cual corresponde a la flexión del dedo medio, el 9 que corresponde a la aducción del dedo pulgar y el movimiento 11 el cual corresponde a la flexión del pulgar. Adicional a estos movimientos, se evidencia que hay un alto grado

Tabla 4-5.: Resultados de la precisión de los modelos de CNN. Nota: Cada Configuración (Cnfg) - Hace referencia a la configuración del modelo de LOO definida en la figura 3-14

	Cnfg 1	Cnfg 2	Cnfg 3	Cnfg 4	Cnfg 5	Cnfg 6	Cnfg 7	Cnfg 8	Cnfg 9
Modelo 1	57,6	45,7	68,4	64,5	61,1	69,7	59,7	51,9	58
Modelo 2	56,5	43,7	67,3	57,3	59,8	70	50,1	45,1	55,4
Modelo 3	56,7	53,5	67,5	63,9	59,1	71	59,1	47	56,6
Modelo 4	57,6	52,9	68,7	65,6	61,3	70,5	57,5	48	58,4
Modelo 5	59,7	55,6	67,1	66,6	59,3	68,2	61,3	43,2	60,2

de precisión en la detección del estado de reposo.

Otro experimento realizado es la combinación de los datos de ambas bases de datos (Ninapro y datos capturados). Esta combinación busca incrementar el número de sujetos empleados en la fase de entrenamiento así como en la fase de validación. Los resultados obtenidos en estos casos se consignaron en la tabla 4-4.

Tabla 4-4.: Resultados de las diferentes configuraciones del clasificador MLPC

	Configuración 1	Configuración 2	Configuración 3
Datos Entrenamiento	Ninapro	Ninapro	Capturada
Datos Validación	Ninapro	Capturada	Capturada
Precisión	63,3 %	63,5 %	66,7 %

En el caso de los datos de las dos bases combinadas, el mejor resultado se obtiene al emplear los datos de la base de datos capturada como validación y con los datos de la base de datos capturada como datos de entrenamiento.

4.2. Redes Convolucionales

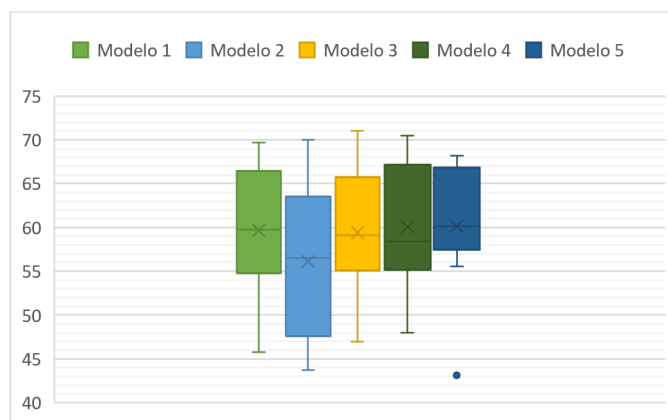
El siguiente tipo de clasificador evaluado en esta investigación es la red convolucional. Los resultados de los cinco modelos estudiados se consignaron en la tablas 4-5 y 4-6.

Como resultado de cada modelo se obtienen los datos de promedio y desviación estandar.

Estos resultados, permiten construir la gráfica en la Figura 4-3, en ella podemos observar que el modelo con menor dispersión es el modelo 5. El modelo con la mayor precisión reportada es el modelo 4.

Tabla 4-6.: Resultados de cada modelo

	Mean	Stddev
Modelo 1	59,6 %	7,6
Modelo 2	56,1 %	9
Modelo 3	59,4 %	7,3
Modelo 4	60 %	7,3
Modelo 5	60,1 %	7,6

**Figura 4-3.:** Resultados de las configuraciones de los modelos del Clasificador CNN

Los modelos que mostraron mejor resultado son el modelo 4 con una precisión del 60 % y el modelo 5 con una precisión del 60,1 %. Las curvas ¹ de precisión y pérdidas para entrenamiento vs test, de estos modelos, nos permiten evaluar el modelo y su comportamiento de acuerdo con los hiperparámetros evaluados (Ver Tabla 4-7)

Los modelos 4 y 5 de CNN son sometidos al método de validación LOO. Los resultados

¹Useful Plots to Diagnose Your Neural Network — by George V Jose — Towards Data Science, n.d.

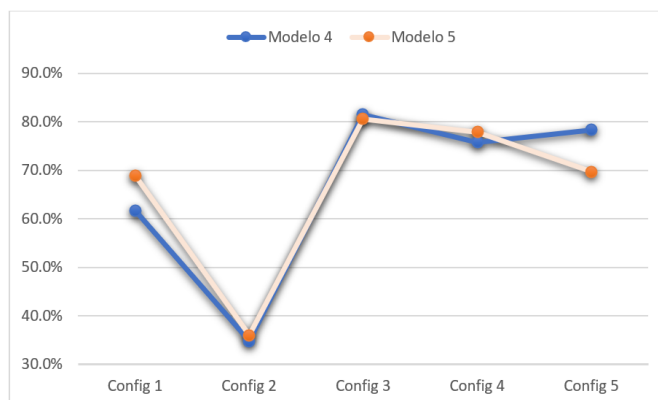
Tabla 4-7.: Hiperparámetros de la CNN

Parámetro	Opción escogida
loss	'categorical_crossentropy'
optimizer	SDG(lr = 0.001)
batch_size	128
epochs	20
validation_split	0,1

Tabla 4-8.: Resultados de la precisión obtenida, Transfer Learning

<i>Modelo</i>	Accuracy
VGG16	54,4 %
ResNet50	52,4 %
DenseNet121	52,1 %

obtenidos mediante la validación LOO son ponderados y posteriormente comparados por cada tipo de modelo de CNN empleado. La gráfica permite observar el comportamiento de la precisión de los modelos 4 y 5, con cada tipo de configuración. Los resultados se pueden observar en la figura 4-4

**Figura 4-4.:** Resultados de las configuraciones de los modelos 4 y 5, Clasificador CNN

El mejor resultado se puede observar con la tercera configuración, en la cual el sujeto de prueba es el sujeto 3. En esta configuración, tanto el modelo 4 como el modelo 5 mostraron un alto grado de precisión, llegando hasta el 80 %. El resultado obtenido para los modelos que más alto resultado de precisión presentaron, se puede observar Figura 4-4. El promedio de estos modelos es de un 63,9 % y 64,2 % de precisión.

4.3. Transferencia de aprendizaje

El uso de redes neuronales previamente entrenadas, es una técnica que facilita y aumenta las posibilidades de obtener un clasificador más ágil para detectar factores especiales en imágenes. En el caso de nuestro estudio, las tres redes VGG16, ResNet50 y DenseNet obtuvieron los resultados que se consignan en la tabla 4-8.

El resultado del entrenamiento empleando los datos de Ninapro de estas tres redes neuronales oscila el 52%, siendo 54.4% el mejor resultado para la Red neuronal VGG16. En todos los casos, se entreno la red y se valido con 30 épocas.

Los resultados de todos los clasificadores se resumen en la tabla **4-9**.

Tabla 4-9.: Resultados de precisión de los diversos clasificadores estudiados

MLPC		CNN		Transfer Learning	
Configuración 1	63,3 %	Modelo 1	59,6 %	VGG16	54,4 %
Configuración 2	63,5 %	Modelo 2	56,1 %	ResNet50	52,4 %
Configuración 3	66,7 %	Modelo 3	59,4 %	DenseNet121	52,1 %
		Modelo 4	60,0 %		
		Modelo 5	60,1 %		

La evaluación de los tiempos de ejecución de cada uno de los algoritmos se resume en la tabla **4-10**. Los tiempos para el MLPC fueron de 0.1728 ± 0.0103 , siendo el menor tiempo de todos los clasificadores. Los tiempos para las CNN y transferencia del aprendizaje fueron 0.337 ± 0.1529 y 1.3078 ± 0.0532 segundos respectivamente.

Tabla 4-10.: Tiempos de ejecución de cada tipo de clasificador. Tiempos en segundos (s)

	MLPC	CNN	Transfer Learning
Time 1	0,177	0,224	1,307
Time 2	0,171	0,201	1,275
Time 3	0,156	0,526	1,237
Time 4	0,188	0,522	1,324
Time 5	0,172	0,212	1,396
mean	0,1728	0,337	1,3078
Std	0,0103	0,1529	0,0532

5. Discusión

En el desarrollo del presente trabajo de investigación, se compararon tres tipologías de clasificadores. En primer lugar, los MLPC con 3 tipos de configuración. Los resultados de este primer tipo de clasificador varían de 63 % a 66.7 %. El clasificador que mejor desempeño demostró en el análisis, cuenta con un arquitectura resumida en la tabla **4-2**. Con una configuración de 100 capas ocultas, y con solo 30 iteraciones, este tipo de clasificador por su sencilla configuración es el más eficiente, y rápido para el tipo de requerimiento del presente trabajo.

La precisión calculada para el clasificador MLPC es de 63,5 % la cual comparada con los datos de la base de datos Ninapro (Simão et al., 2019), difiere únicamente en 0.2 %. Si se emplean únicamente los datos capturados, tanto para el entrenamiento como para la validación, empleando el mismo principio de validación cruzada (Bradley, 2010), obtenemos precisiones incluso mayores, llegando al 66,7 % (Ver la Tabla **4-9**). El clasificador que por nivel de precisión presentó los mejores resultados es el MLPC llegando a una precisión del 66,7 %.

El segundo tipo de clasificador son las redes neuronales convolucionales. Este segundo tipo de clasificador tiene una ventaja con respecto a los MLPC por cuanto su capacidad de aprendizaje y adaptación al dato de entrada es más amplio. Las señales de entrada, en este caso las imágenes de la matriz del espectrograma, pueden posicionarse o tener variaciones que este método de clasificación es capaz de obviar y por tanto mejorar su capacidad de clasificación. Siendo que solo se procesa un solo tipo de dato extraído de las señales de electromiografía, esto supondría una etapa anterior al proceso mismo de clasificación. El proceso de construir la imagen (matriz del espectrograma) es un proceso lento y puede acarrear un retraso en el proceso de clasificación en vivo, que estamos trabajando en el presente trabajo de investigación. La precisión de este tipo de clasificador osciló entre el 56,1 % y 59,6 %. La arquitectura que mejor se desempeño es la arquitectura del modelo 4 y 5. Estos modelos cuentan con una serie de 4 convoluciones seguidas de una capa de normalización seguido finalmente de un proceso de agrupamiento. Esta arquitectura se puede ver en las figuras **3-10** y **3-11**. Esto lo ubica como la segunda mejor opción para clasificar todos los movimientos estudiados. Sin embargo, este clasificador tuvo un alto desempeño, al intentar clasificar 3 movimientos puntuales (movimiento 3 el cual corresponde a la flexión del dedo medio, el 9 que corresponde a la abducción del dedo pulgar y el movimiento 11 el cual corresponde a la flexión del pul-

gar). Estos movimientos alcanzaron niveles de precisión de la clasificación superiores al 90 %.

Siendo el objetivo de este trabajo: la manipulación de sistemas de computo desde el campo quirúrgico estéril, el número de acciones a construir puede variar de acuerdo a la necesidad médica. En el caso puntual de neurocirugía, un valor de 5 movimientos, es un número que a consideración de los médicos, es suficiente para la interacción con el sistema de navegación intra-quirúrgica.

El modelo de Red Neuronal convolucional que mejores resultados entregó es el Modelo 5, obteniendo un resultado de 60,1 %. Este resultado es comparable con el resultado obtenido en la literatura, al emplear este tipo de clasificador para la detección de los movimientos de los dedos, basándose en las capturas de electromiografía del antebrazo. Resultados similares se pueden encontrar como del 61,2 % reportado por otros grupos de investigación (Simão et al., 2019)

El tercer método de clasificación aplica la técnica de transferencia del aprendizaje. Se escogieron tres redes que según la literatura tienen un alto nivel de clasificación, sin embargo las imágenes de espectrogramas de las señales de electromiografía, no contienen los mismos componentes de imágenes empleadas en otros trabajos de clasificación. Resultado de esto, el método de *Transfer Learning* obtuvo resultados más bajos, y solo alcanzó un 54,4 % en el mejor de los sistemas evaluados. Esto nos lleva a proponer como futura investigación la determinación del tipo de extracción de característica que pueda ser convertido en imagen, que aumente, y mejore estos niveles de clasificación.

En cuanto a los tiempos de cálculo de cada uno de estos clasificadores, el Modelo de MLPC presentó un tiempo de cálculo de una muestra de 170 milisegundos, mientras que los clasificadores CNN y Transfer Learning tomaron 337 milisegundos y 1300 milisegundos respectivamente (ver tabla 4-10). Para obtener estos resultados se empleó el entorno de procesamiento de Google de nombre Colab¹. La máquina asignada para esta investigación cuenta con parámetros de trabajo tales como Ram ampliada de 16000 MB, procesador Intel(R) Xeon(R) CPU @ 2.30GHz, GPU Tesla P100-PCIE-16GB ². El criterio de tiempo transcurrido para la ejecución de las rutinas se escogió para seleccionar un modelo sobre otros, con el fin de poder embeber el sistema en una plataforma de cálculo portable, y así poder usarla en el entorno escogido.

La robustez de los clasificadores evaluados ha demostrado que el planteamiento y objetivo de esta investigación tienen un desarrollo aun distante de la óptima situación que se esperaría, sin embargo, demuestra que es un sistema que resulta de sumo interés por su eficiencia en

¹<https://colab.research.google.com>

²<https://towardsdatascience.com/colab-pro-is-it-worth-the-money-32a1744f42a8>

tiempo y por su facilidad de construcción.

En aras de mejorar los resultados presentados en este trabajo se propone que una segunda fase de esta investigación se centre en el incremento del número de participantes y su dispersión en los tipos de sujetos que participan en la construcción de las bases de datos, y por tanto de los entrenamientos de los modelos escogidos. Esto ayudaría con la diversificación de los modelos.

Finalmente, en aras de mejorar aún más la diversificación de los datos de entrada para el sistema de entrenamiento, se debería hacer mediciones de los sujetos, modificando ligeramente, la posición de los electrodos, sacando de la ecuación de cálculo, la necesidad de posicionar los electrodos, exactamente, de la misma manera siempre. Una vertiente adicional es la investigación de nuevos modelos de extracción de datos y conversión en imágenes para obtener características como bordes que hacen más "únicas" las imágenes para su posterior clasificación.

A. Carta de respuesta del comité de ética

COMITÉ DE ÉTICA EN INVESTIGACIÓN DE LA UNIVERSIDAD DEL ROSARIO
SALA DE CIENCIAS DE LA VIDA

MIEMBROS

CARLOS ENRIQUE TRILLOS, PRESIDENTE
MÉDICO CIRUJANO; MSc. EPIDEMIOLOGÍA

JUAN GUILLERMO PÉREZ CARREÑO
MÉDICO BIOÉTICISTA;
SECRETARIO TÉCNICO

RAMON FAYAD NAFFAH
LIC. EDUCACIÓN; PHD MATEMÁTICAS

CARLOS ALBERTO CALDERÓN
MÉDICO; MSc. FARMACOLOGÍA

GLEIDY VANESSA ESPITIA
FONOAUDIÓLOGA, MSc Y PHD EN CIENCIAS

JAID CONSTANZA ROJAS
BACTERIOLOGA; MSc. SALUD PÚBLICA;
MSc. BIOÉTICA

KATHERIN QUINTERO PARRA
QUÍMICA FARMACÉUTICA

LUISA FERNANDA RAMÍREZ
PSICÓLOGA- PHD PSICOLOGÍA SOCIAL Y DE LA SALUD

MAGDA MILENA GAVIRIA
BIÓLOGA; MSc EN BIOLOGÍA

MARTHA ROCÍO TORRES NARVÁEZ
FISIOTERAPEUTA, MSc BIOÉTICA

ANDREA TORRES RUIZ
INGENIERA BIOMÉDICA; MSc ING. ELECTRÓNICA Y DE
COMPUTADORES

CÉSAR PAYAN GÓMEZ
MÉDICO, MSc GENÉTICA HUMANA; PHD CIENCIAS
BÁSICAS

JESUS ORLANDO CROCE
ABOGADO

KAREN JULIETH MORENO
FISIOTERAPEUTA; Esp. EPIDEMIOLOGIA

MARTHA ISABEL BAUTISTA DUEÑAS
AUXILIAR ADMINISTRATIVA



DVO005 1637-CV1313

Bogotá D. C., 26 de julio de 2021

Doctor

ALVARO DAVID ORJUELA CAÑON

Investigador Principal

Estudio: “**Diseño de un sistema embebido de clasificación de movimientos de los dedos de la mano, empleando electromiografía superficial en antebrazo**”.

Bogotá, D. C.

Respetado Investigador:

El Comité de Ética en investigación de la Universidad del Rosario (CEI-UR), evaluó de forma expedita la segunda versión de su proyecto de investigación “Diseño de un sistema embebido de clasificación de movimientos de los dedos de la mano, empleando electromiografía superficial en antebrazo”. Fecha de recepción: 16 de julio de 2021.

Luego de haber tenido en cuenta las observaciones efectuadas por el CEI-UR, se APRUEBA el protocolo en referencia junto con la información anexa.

Para el Comité de Ética es importante acompañarlo durante la ejecución del estudio. Por favor no dude en contactarnos en caso de tener alguna inquietud o de necesitar apoyo para el análisis de alguna situación específica. De igual forma le recomendamos notificar cualquier modificación en la ejecución del estudio no expuesta en la aprobación inicial del proyecto.

Cordialmente,



JUAN GUILLERMO PÉREZ MD, MSc

Secretario Técnico
(CEI-UR)

c.c. Archivo

Proyectó: Martha Isabel Bautista

Este comité se rige por los lineamientos jurídicos y éticos del país a través de las resoluciones 8430 de 1993 y 2378 de 2008 del Ministerio de Salud y Protección Social. Igualmente, se siguen los acuerdos contemplados en la declaración de Helsinki (Fortaleza, Brasil 2013) y de la Conferencia Internacional de Armonización para las Buenas Prácticas Clínicas. Recuerde visitar nuestra página web, en donde encontrará información actualizada de los procedimientos del Comité de Ética en Investigación de la Universidad del Rosario, así como cursos en ética de la investigación de acceso libre. <https://www.urosario.edu.co/Investigacion/Soporte-a-la-Investigacion/Comite-de-etica-en-investigacion/#id-tabs>

DVO005 1637-CV1313

Página 1 de 1

B. Consentimiento Informado para los voluntarios en la captura de las señales

ESTUDIO DE INVESTIGACIÓN

“Diseño de un sistema embebido de clasificación de movimientos de los dedos de la mano, empleando electromiografía superficial en antebrazo”

DOCUMENTO DE CONSENTIMIENTO INFORMADO

- Por favor, lea cuidadosamente esta información sobre el estudio de investigación titulado “Diseño de un sistema embebido de clasificación de movimientos de los dedos de la mano, empleando electromiografía superficial en antebrazo”
- Siéntase en completa libertad de preguntar al personal del estudio todo aquello que no entienda.
- Una vez haya comprendido la información, se le preguntará si desea participar del estudio. En caso afirmativo, deberá firmar este documento y recibirá una copia.

DESCRIPCIÓN GENERAL

La presente investigación busca clasificar los movimientos de los dedos gracias a la captura de señales de eléctricas generadas por los músculos a la altura del antebrazo - mejor conocida como electromiografía superficial en el antebrazo, mediante el uso de una banda de sensores de contacto, no invasivos y con transmisión de los datos de manera inalámbrica. El objeto de esta captura de datos es diseñar un método de clasificación de los movimientos de los dedos, que permita posteriormente usar este clasificador como un sistema de interacción con equipos en ámbitos donde el usuario no puede tocar el equipo con el cual desea interactuar, como por ejemplo los equipos en las salas de cirugía.

OBJETIVO DEL ESTUDIO

Implementar un sistema basado en modelos de redes neuronales para la clasificación del movimiento de los dedos, empleando electromiografía superficial a la altura del antebrazo, con objeto de permitir la interacción de sistemas de cómputo en un área de cirugía con los profesionales del área de la salud, desde el área estéril.

¿POR QUÉ FUE USTED ELEGIDO PARA PARTICIPAR EN ESTE ESTUDIO?

Para poder simular los usuarios que podrían usar este diseño, buscamos por lo menos 10 personas de una edad entre los 25 y los 60 años de edad y sin afecciones neurológicas conocidas. No existen limitantes por género. Se recomienda que los usuarios sean usuarios de sistemas de cómputo, ya que los movimientos a imitar serán similares a los usuarios de los “mouse” de los computadores. Como única limitante, es que el usuario no tenga lesiones abiertas o cutáneas en el área del registro electromiográfico.

RIESGOS Y BENEFICIOS

Los datos capturados, se realizan de manera no invasiva, mediante el uso de una banda de electromiógrafos de superficie. La banda genera una ligera presión sobre la piel, garantizando el contacto adecuado de los sensores con la piel del usuario. La presión se maneja de manera manual, por lo que la piel no debe presentar ninguna lesión. Al conceder a esta investigación la oportunidad de registrar los datos, está permitiéndonos expandir la variabilidad de datos, y mejorar el clasificador, objeto de esta investigación.

El único riesgo registrado que puede ser objeto de objeción por parte de los usuarios es el contacto directo con la piel. Por tal motivo, previo al uso y al terminar el registro, se le hará una limpieza de los sensores, con solución de alcohol al 70%. Esta limpieza permitirá que el contacto sea más aséptico. Sin embargo, como se explicó antes, los electromiografos no son invasivos por lo que no habrá lugar a intercambio de fluidos mediante el uso de la banda de detección.

La actual investigación permitirá desarrollar un clasificador, para interactuar con equipos, sin la necesidad de contacto físico con estos. Esto trae beneficios en áreas como las salas de cirugía, u otros ambientes, como plantas donde se haga uso de sistemas de cómputo en simultaneidad con productos lesivos para el usuario.

¿COMO SERÁ LA PARTICIPACIÓN EN EL ESTUDIO?

“Su participación requiere de los siguientes procedimientos, que usted podrá libremente aceptar o rechazar:

1. Se registrará en un archivo sus datos de contacto, con objeto de poder contactarle en caso de requerir un nuevo registro.
2. El lugar para realizar estos procedimientos será acordado entre el investigador y usted, de tal manera que se conserve su seguridad y tranquilidad. No se requiere de un espacio especial ya que la captura se puede realizar en cualquier ambiente.
3. Se le realizará unas preguntas relacionadas a su uso regular de sistemas de cómputo, y/o sistema de imágenes médicas preferiblemente.
4. Se le pedirá descubrir la manga del brazo donde se realizará la captura del registro de electromiografía.
5. El tiempo del registro, puede oscilar entre 15 y 30 minutos, de acuerdo a la repetibilidad de las capturas.
6. Se le presentará al sujeto, un video demostrando los movimientos a realizar, se realizará una muestra del movimiento antes de iniciar con el registro.
7. Se realizarán 3 repeticiones del mismo movimiento.
8. Se realizarán un total de 12 movimientos diferentes.
9. Al finalizar se almacenarán los movimientos en una base de datos de manera anónima, para así preservar la confidencialidad de los datos.

GARANTÍAS DE SU PARTICIPACIÓN

Participar en el estudio no tiene ningún costo. Los procedimientos que se le practiquen en este estudio tampoco tendrán costo.

Ni usted, ni otra persona involucrada en el estudio, recibirá beneficios políticos, económicos o laborales como compensación por su participación.

Su participación será completamente voluntaria y tendrá el derecho de retirarse en cualquier momento del estudio si usted así lo desea. Igualmente, si en algún momento desea que la información que usted brinda no sea utilizada por los investigadores, lo podrá comunicar y respetaremos su decisión.”

MANEJO DE LOS DATOS DE INVESTIGACIÓN

La información se mantendrá bajo estricta confidencialidad y no se utilizará su nombre o cualquier otra información que pueda identificarlo personalmente.

Toda la información que se obtenga de este estudio de investigación se utilizará únicamente con el propósito que aquí se comenta. Los investigadores de este estudio son los únicos autorizados para acceder a los datos que usted suministre. Los datos de los registros, serán empleados únicamente por los investigadores con el objeto de desarrollar el clasificador y únicamente para las pruebas del mismo. No se dará acceso a sus registros salvo su voluntario consentimiento.

Los datos obtenidos serán almacenados en el computador del investigador principal, y en la cuenta de “Google Drive” la cual nos prestará todos los beneficios de almacenamiento y seguridad con los que cuentan. Los datos de garantía de seguridad pueden verse en el siguiente link: https://www.google.com/intl/es_ALL/drive/terms-of-service/

El usuarios responsable del uso de los datos y almacenamiento es:

Alfredo Sanabria Solano. Celular de contacto: 3176405709.

ACEPTACIÓN

Por favor marque con una "X" en caso que acepte o no acepte lo siguiente:

Autorizo a los investigadores del estudio "Diseño de un sistema embebido de clasificación de movimientos de los dedos de la mano, empleando electromiografía superficial en antebrazo" para:	Acepto	No acepto
● Realizar los procedimientos descritos en este documento, necesarios para la realización del estudio de investigación		
● Comunicarse conmigo para hacer los seguimientos requeridos por el estudio		
● Comunicarse conmigo para invitarme a participar en la etapa de pruebas del clasificador realizado		

Participante

Nombre Cédula Firma Día/Mes/Año

ESPACIO RESERVADO PARA EL INVESTIGADOR

En nombre del estudio "Diseño de un sistema embebido de clasificación de movimientos de los dedos de la mano, empleando electromiografía superficial en antebrazo", me comprometo a guardar la identidad de _____ como participante. Acepto su derecho a conocer el resultado del clasificador realizado y a retirarse del estudio a su voluntad en cualquier momento. Me comprometo a manejar los resultados de esta evaluación de acuerdo a las normas para la realización de investigación en Colombia (Resolución 8430 de 1993 y Resolución 2378 de 2008) y la ley para la protección de datos personales (Ley estatutaria 1581 de 2012).

Nombre: Alfredo José Sanabria Solano

Documento de Identidad No. 80194517

Firma: _____

Fecha (día/mes/año) _____/_____/_____

¿INFORMACIÓN O PREGUNTAS ADICIONALES?

Si en algún momento desea obtener información adicional sobre el estudio puede contactar a:

Alfredo José Sanabria Solano, Investigador principal.

Universidad del Rosario, Sede Quinta de Mutis.

Teléfono 3006403537

alfredo.sanabria@urosario.edu.col

Bibliografía

- Akhlaghi, N., Baker, C. A., Lahlou, M., Zafar, H., Murthy, K. G., Rangwala, H. S., Kosecka, J., Joiner, W. M., Pancrazio, J. J., and Sikdar, S. (2016). Real-time classification of hand motions using ultrasound imaging of forearm muscles. *IEEE Transactions on Biomedical Engineering*, 63(8):1687–1698.
- Alam, R., Rhivu, S. R., and Haque, M. A. (2018). Improved Gesture Recognition Using Deep Neural Networks on sEMG. In *2018 International Conference on Engineering, Applied Sciences, and Technology (ICEAST)*, pages 1–4.
- Ameri, A., Akhaee, M. A., Scheme, E., and Englehart, K. (2020). A Deep Transfer Learning Approach to Reducing the Effect of Electrode Shift in EMG Pattern Recognition-Based Control. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 28(2):370–379.
- Anam, K. and Al-Jumaily, A. (2017). Evaluation of extreme learning machine for classification of individual and combined finger movements using electromyography on amputees and non-amputees. *Neural Networks*, 85:51–68.
- Atzori, M., Gijsberts, A., Castellini, C., Caputo, B., Hager, A. G. M., Elsig, S., Giatsidis, G., Bassetto, F., and Müller, H. (2014). Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific Data*, 1:1–13.
- Behrenbeck, J., Tayeb, Z., Bhiri, C., Richter, C., Rhodes, O., Kasabov, N., Espinosa-Ramos, J. I., Furber, S., Cheng, G., and Conradt, J. (2019). Classification and regression of spatio-temporal signals using NeuCube and its realization on SpiNNaker neuromorphic hardware. *Journal of Neural Engineering*, 16(2).
- Bradley, E. (2010). *Leave-One-Out Cross-Validation*, pages 600–601. Springer US, Boston, MA.
- Caba, Q., Lic, G. G., et al. (2021). Estrategia de prevención de infecciones del sitio quirúrgico en neurocirugía fundamentada en factores de riesgo. Master’s thesis, Universidad Técnica de Ambato/Facultad de Ciencias de la Salud/Centro de
- Celadon, N., Dozen, S., Binder, I., Ariano, P., Farina, D., and Dovens, S. (2016). Proportional estimation of finger movements from high-density surface electromyography. *Journal of NeuroEngineering & Rehabilitation (JNER)*, 13:1–19.

- Cho, A. B., Rodrigues, L. M. R., Nicolau, R. J., Rugiero, G. M., Fukushima, W. Y., and Milani, C. (2008). Treatment of hardware exposure after severe infections in spine surgery with pedicled muscular flaps. *Clinics*, 63:277–280.
- Côté-Allard, U., Gagnon-Turcotte, G., Laviolette, F., and Gosselin, B. (2019). A low-cost, wireless, 3-D-printed custom armband for semg hand gesture recognition. *Sensors (Switzerland)*, 19(12):1–24.
- Fu, J., Xiong, L., Song, X., Yan, Z., and Xie, Y. (2018). Identification of finger movements from forearm surface EMG using an augmented probabilistic neural network. In *2017 IEEE/SICE International Symposium on System Integration, SII 2017*, volume 2018-Janua, pages 547–552, Chongqing Institutes of Green and Intelligent Technology, Chinese Academy of Sciences, Chongqing, China. Institute of Electrical and Electronics Engineers Inc.
- García-Casallas, J. C., Blanco-Mejía, J. A., Fuentes-Barreiro, Y. V., Arciniegas-Mayorga, L. C., Arias-Cepeda, C. D., and Morales-Pardo, B. D. (2020). Prevención y tratamiento de las infecciones del sitio operatorio en neurocirugía. estado del arte. *Iatreia*, 33(1):39–58.
- Gülmez, G., Cebbar, K., Kul, S., and Sayar, A. (2021). A framework for using contactless technologies in operating rooms. In *2021 International Conference on INnovations in Intelligent SysTems and Applications (INISTA)*, pages 1–6.
- Hales, B., Terblanche, M., Fowler, R., and Sibbald, W. (2008). Development of medical checklists for improved quality of patient care. *International Journal for Quality in Health Care*, 20(1):22–30.
- Jimenez, D. A., Padilla, J. B., Arango, R., and Garcia, H. F. (2017). Human-Computer Interaction for Image Guided Surgery Systems using Physiological Signals: Application to Deep Brain Stimulation Surgery. In Torres, I., Bustamante, J., and Sierra, D. A., editors, *VII Latin American Congress on Biomedical Engineering CLAIB 2016, Bucaramanga, Santander, Colombia, October 26th -28th, 2016*, pages 737–740, Singapore. Springer Singapore.
- Kantor, P., Matonti, F., Varenne, F., Sentis, V., Pagot-Mathis, V., Fournié, P., and Soler, V. (2021). Use of the heads-up ngenuity 3d visualization system for vitreoretinal surgery: a retrospective evaluation of outcomes in a french tertiary center. *Scientific Reports*, 11(1):1–11.
- Khushaba, R. N., Al-Timemy, A. H., Al-Ani, A., and Al-Jumaily, A. (2017). A Framework of Temporal-Spatial Descriptors-Based Feature Extraction for Improved Myoelectric Pattern Recognition. *IEEE Transactions On Neural Systems And Rehabilitation Engineering: A Publication Of The IEEE Engineering In Medicine And Biology Society*, 25(10):1821–1831.

- Kubat, K. D. M. B. K. and Berlengi (2017). What is the future of minimally invasive surgery in rhinology: markerbased virtual reality simulation with touch free surgeon’s commands. *Otolaryngol. Head Neck Surg.*
- Liu, J., Chen, W., Li, M., and Kang, X. (2016). Continuous recognition of multifunctional finger and wrist movements in amputee subjects based on sEMG and accelerometry. *Open Biomedical Engineering Journal*, 10:101–110.
- Muhammad, U., Sipra, K. A., Waqas, M., Tu, S., and Koubaa, A. (2020). Poster: Human-robot interaction: A myo armband using emg and imu signals. *2020 First International Conference of Smart Systems and Emerging Technologies*, pages 251–252.
- Nishikawa, A., Hosoi, T., Koara, K., Negoro, D., Hikita, A., Asano, S., Kakutani, H., Miyazaki, F., Sekimoto, M., Yasui, M., Miyake, Y., Takiguchi, S., and Monden, M. (2003). FAcE MOUSe: A novel human-machine interface for controlling the position of a laparoscope. *IEEE Transactions on Robotics and Automation*, 19(5):825–841.
- Park, J., Kim, S. J., Kyeong, S., Kim, J., and Na, Y. (2018). Feasibility of proportional EMG control for a hand exoskeleton: A Fitts’ Law approach. *IFAC-PapersOnLine*, 51(22):214–219.
- Patel, A., Ramsay, J., Imtiaz, M., and Lu, Y. (2019). EMG-based Human Machine Interface Control. In *2019 12th International Conference on Human System Interaction (HSI)*, pages 127–131.
- Pizzolato, S., Tagliapietra, L., Cognolato, M., Reggiani, M., Müller, H., and Atzori, M. (2017). Comparison of six electromyography acquisition setups on hand movement classification tasks. *PLoS ONE*, 12(10):1–17.
- Putra, D. S., Weru, Y. U. W., and Fitriady, F. (2019). Pattern recognition of electromyography (EMG) signal for wrist movement using learning vector quantization (LVQ). In M.S.M., S., editor, *1st South Aceh International Conference on Engineering and Technology, SAICOET 2018*, volume 506, Informatics Engineering, Politeknik Aceh Selatan, Tapaktuan, 23711, Indonesia. Institute of Physics Publishing.
- Qi, J., Jiang, G., Li, G., Sun, Y., and Tao, B. (2019). Intelligent human-computer interaction based on surface emg gesture recognition. *IEEE Access*, 7:61378–61387.
- Quivira, F., Koike-Akino, T., Wang, Y., and Erdogmus, D. (2018). Translating sEMG signals to continuous hand poses using recurrent neural networks. In *2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)*, pages 166–169.
- Restrepo, L. A. R., Suárez, J. C. C., and Martínez, M. E. G. (2011). Costo de las infecciones del sitio operatorio en una institución de alta complejidad. Medellín – Colombia, 2008-2009

- (Cost of operative site infections in an institution of high complexity. Medellin - Colombia, 2008-2009). *CES Salud Pública*, 2(2):169–186.
- Sharif, H., Seo, S. B., and Kesavadas, T. K. (2020). Hand gesture recognition using surface electromyography. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2020-July:682–685.
- Simão, M., Neto, P., and Gibaru, O. (2019). EMG-based online classification of gestures with recurrent neural networks. *Pattern Recognition Letters*, 128:45–51.
- Solano, A. J. S. (2021). Imagen de los movimientos de la mano. Imágenes capturadas para el presente trabajo.
- Soman, S., Jayadeva, D., Arjunan, S., Kumar, D. K., Jayadeva, Arjunan, S., and Kumar, D. K. (2016). Improved sEMG signal classification using the Twin SVM. In *2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 4507–4512.
- Stapornchaisit, S. and Koike, Y. (2018). Finger angle estimation using musculoskeletal model on thumb and index finger. In *22nd World Congress of the International Measurement Confederation, IMEKO 2018*, volume 1065, Information and Communication Department, Tokyo Institute of Technology, 4259 Nagatsuta-cho, Midori-ku, Kanagawa Yokohama, 226-8502, Japan. Institute of Physics Publishing.
- Tan, M. and Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *36th International Conference on Machine Learning, ICML 2019*, 2019-June:10691–10700.
- Tsuboi, A., Hirota, M., Sato, J., Yokoyama, M., and Yanagisawa, M. (2017). A Proposal for Wearable Controller Device and Finger Gesture Recognition using Surface Electromyography. In *SIGGRAPH Asia 2017 Posters, SA 2017*, Waseda university, Japan. Association for Computing Machinery, Inc.
- Villarejo Mayor, J. J., Mamede Costa, R., Frizera Neto, A., Freire Bastos, T., Mayor, J. J. V., Costa, R. M., Frizera Neto, A., and Bastos, T. F. (2017). Dexterous hand gestures recognition based on low-density sEMG signals for upper-limb forearm amputees. *Research on Biomedical Engineering*, 33(3):202–217.
- Yang, D., Yang, W., Huang, Q., Liu, H., Altin, C., E. R., O., Kamei, Y., Okada, S., Naik, G. R., Al-Timemy, A. H., Nguyen, H. T., Dellacasa Bellingegni, A., Gruppioni, E., Colazzo, G., Davalli, A., Sacchetti, R., Guglielmelli, E., Zollo, L., Phukpattaranont, P., Thongpanja, S., Anam, K., Al-Jumaily, A., Limsakul, C., Saggio, G., Orenge, G., Pallotti, A., Errico, V., Ricci, M., Celadon, N., Dozen, S., Binder, I., Ariano, P., Farina, D., Došen, S., Yang, X., Sun, X., Zhou, D., Li, Y., Liu, H., Torres, G. A., Benitez, V. H., Al-Timemy, A. H., Kim, M., Kim, D. S., Chung, W. K., Na, Y., Kim, S. J., Jo, S., Kim, J., Kim, S. J., Huang,

- H., Li, T., Bruschini, C., Enz, C., Koch, V. M., Justiz, J., Antfolk, C., Zhai, X., Jelfs, B., Chan, R. H. M., Tin, C., Alba-Flores, R., Hickman, S., Mirzakani, A. S., Geethanjali, P., Phinyomark, A., Scheme, E., Jarrassé, N., Nicol, C., Richer, F., Touillet, A., Martinet, N., Paysant, J., Graaf, J. B. D., Dai, C., Hu, X., Balasubramanian, S., Garcia-Cossio, E., Birbaumer, N., Burdet, E., Ramos-Murguialday, A., Purushothaman, G., and Vikas, R. (2016). Finger movements classification from grasping spherical objects with surface electromyography using time domain based features. *Australasian Physical & Engineering Sciences In Medicine*, 39(1):1–6.
- Zhang, S., Zhang, X., Cao, S., Gao, X., Chen, X., and Zhou, P. (2017). Myoelectric Pattern Recognition Based on Muscle Synergies for Simultaneous Control of Dexterous Finger Movements. *IEEE Transactions on Human-Machine Systems*, 47(4):576–582.