

Reconocimiento de movimientos finos de la mano basado en señales de electromiografía usando algoritmos de aprendizaje automático supervisados

José Miguel Figarola, Yelile Iga Valdés,
Victor González, Javier Mauricio Antelis Ortíz,
Omar Mendoza Montoya

Tecnológico de Monterrey,
Facultad de Ciencias Escuela de Ingeniería y Ciencias,
México

{A01632557,A01634978,A01382698,
mauricio.antelis,omendoza83}@tec.mx

Resumen. El artículo describe la implementación de un sistema de clasificación de movimientos finos de la mano utilizando señales electromiográficas superficiales (sEMG). El objetivo es controlar una órtesis robótica para la rehabilitación de pacientes con enfermedades cardiovasculares e infartos cerebrales. Para lograr esto, se utilizó un enfoque de Aprendizaje Automático e Incremental y se llevó a cabo un experimento de laboratorio con 30 sujetos sanos. Se compararon diferentes clasificadores y se encontró que el Análisis Discriminante Lineal (LDA) y la Máquina de Soporte Vectorial Lineal (SVML) tuvieron un rendimiento sobresaliente. Además, se utilizó la técnica de Inicio Rápido o Warm Start y Ajuste Parcial o Partial Fit para mejorar la exactitud del modelo, lo que permitió adaptarlo a datos de pacientes sin entrenamiento previo y disminuir el tiempo de entrenamiento y procesamiento. Los resultados del estudio mostraron que LDA tuvo un rendimiento promedio del $94.8\% \pm 3.21$ para modelos individuales y SMVL con $93.4\% \pm 3.69$ para un modelo generalizado, lo que indica un rendimiento sobresaliente entre los clasificadores. Además, al utilizar técnicas de Inicio Rápido y Ajuste Parcial, la exactitud en la fase de pruebas aumentó hasta un 8% en el modelo MLP3, pasando de un 58.09% a un 61.42%. En general, el estudio demostró la viabilidad de implementar Aprendizaje Automático y Aprendizaje Incremental en la detección y clasificación de movimientos finos de la mano utilizando señales sEMG para una Interfaz Cerebro-Computador (ICC) para la rehabilitación de pacientes con enfermedades cardiovasculares e infartos cerebrales.

Palabras clave: Aprendizaje incremental, inicio rápido, ajuste parcial, EMG, movimientos finos de la mano.

Recognition of Fine Hand Movements based on Electromyography Signals Using Supervised Machine Learning Algorithms

Abstract. The article describes the implementation of a fine hand movement classification system using surface electromyographic (sEMG) signals. The goal is to control a robotic orthosis for the rehabilitation of patients with cardiovascular diseases and cerebral infarctions. To achieve this, a Machine Learning and Incremental Learning approach was used, and a laboratory experiment was carried out with 30 healthy subjects. Different classifiers were compared, and it was found that Linear Discriminant Analysis (LDA) and Linear Support Vector Machine (SVML) had outstanding performance. In addition, the Quick Start or Warm Start and Partial Fit techniques were used to improve the accuracy of the model, which allowed it to be adapted to patient data without previous training and reduced training and processing time. The study results showed that LDA had an average performance of $94.8\% \pm 3.21$ for individual models and SMVL with $93.4\% \pm 3.69$ for a generalized model, indicating outstanding performance among classifiers. Furthermore, by using Quick Start and Partial Fit techniques, the accuracy in the testing phase increased by up to 8% in the MLP3 model, from 58.09% to 61.42%. Overall, the study demonstrated the feasibility of implementing Machine Learning and Incremental Learning in the detection and classification of fine hand movements using sEMG signals for a Brain-Computer Interface (BCI) for the rehabilitation of patients with cardiovascular diseases and cerebral infarctions.

Keywords: Incremental learning, warm start, partial fit, EMG, fine hand movements.

1. Introducción

Los problemas cardiovasculares e infartos cerebrales son muy comunes, crean afectaciones neurológicas y otras complicaciones [6]. En Estados Unidos cada 40 segundos ocurre un caso, un total de 805,000 al año y 1 de cada 5 son silenciosos por lo que pasan desapercibidos [5]. Yu et al. definen un ataque cerebrovascular como una alteración en el suministro de sangre al cerebro y esto afecta el rendimiento motor [17].

Esto puede generar limitaciones en rutinas diarias; National Washington Post y Journal of Stroke and Cerebrovascular Diseases estimaron un costo promedio de \$20,396 a \$43,652 USD por día en el hospital por un accidente cerebrovascular y un total del \$17.5 billones de USD en Estados Unidos [16]. El uso de biomécanica y robótica ha generado grandes resultados como en la rehabilitación de extremidades inferiores.

Esto puede prevenir la fatiga y el esfuerzo en los pacientes y el personal de atención [14]. Por lo que es necesario encontrar nuevas técnicas y tecnologías que ayuden a reducir los costos y mejorar los resultados en la rehabilitación de pacientes que han sufrido problemas cardiovasculares e infartos cerebrales.

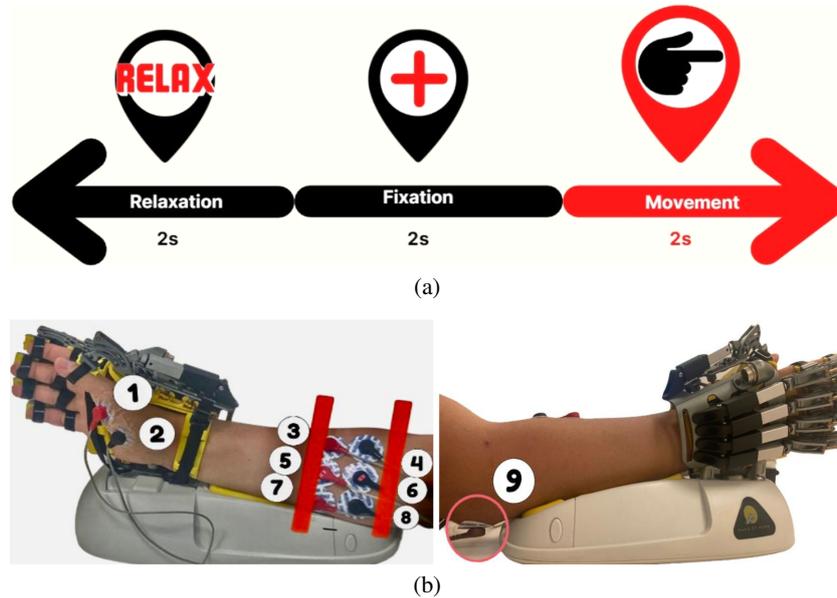


Fig. 1. (a) Descripción visual de cada época. (b) Orientación de los electrodos.

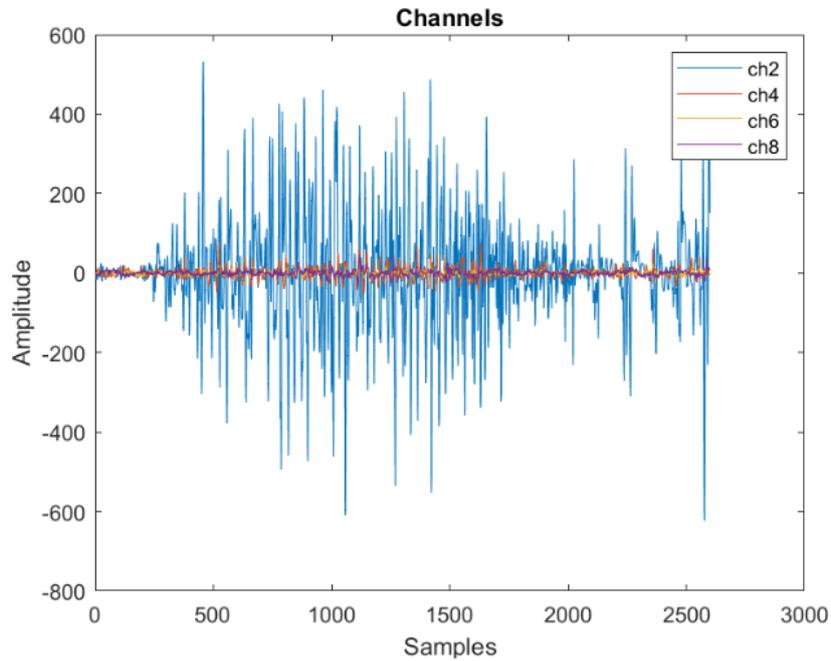
Además, es importante encontrar formas de mejorar la calidad de vida de estos pacientes y reducir el impacto de estas afecciones en su vida diaria. La biomécanica y la robótica pueden ser una solución efectiva para estos problemas y deben seguir siendo investigadas y desarrolladas para su uso en la práctica clínica.

1.1. Trabajos relacionados

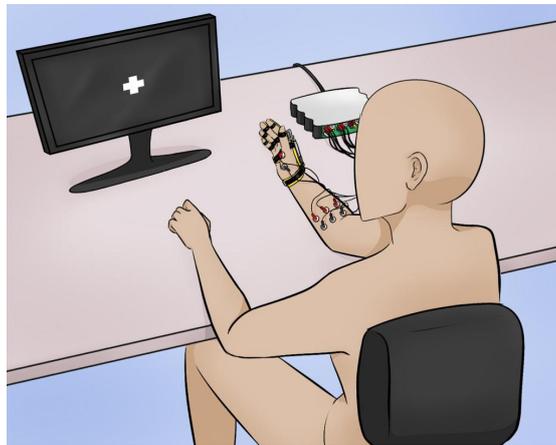
La investigación de Hazarika et al. combinó Análisis de Correlación Canónica (CCA) y K-Vecinos Más Próximos (KNN) para crear un método de clasificación de movimientos finos de la mano utilizando señales EMG [10], que podría ser útil en la rehabilitación de pacientes con enfermedades cardiovasculares y accidentes cerebrovasculares. El Aprendizaje Incremental se define como la capacidad de ajustar el modelo de acuerdo con nuevos ejemplos, sin la necesidad de un conjunto de entrenamiento adecuado antes del proceso de aprendizaje [7].

Redes Neuronales, el Perceptrón Multicapa y el Bosque Aleatorio son modelos de aprendizaje que pueden tener un gran impacto en la precisión del entrenamiento y la prueba cuando se aplica el Aprendizaje Incremental [9]. También se ha propuesto el uso de órtesis impulsadas por señales EMG con un gran rendimiento para medir movimientos compuestos de la mano [2].

Durante los últimos años, se ha estudiado la detección y clasificación de movimientos de la mano o movimientos finos de la mano utilizando señales EMG. En un estudio realizado por Lee et al. se entrenó una Red Neuronal con 4 capas y 1,000 neuronas en cada capa, utilizando 18 características en el dominio del tiempo, obteniendo una precisión media del 95 %.



(a)



(b)

Fig. 2. (a) Movimiento del pulgar por canal. (b) Gráfico del experimento.

Además, su Máquina de Soporte Vectorial Radial tuvo una precisión del 87,4 %, y utilizaron 10 participantes para crear su conjunto de datos [12]. Otro estudio, realizado por Ahsan et al. clasificó 4 gestos de la mano con una Red Neuronal que utiliza retropropagación durante el entrenamiento para lograr un mejor rendimiento. Los datos también se generalizaron para evitar el sobreajuste y se creó un conjunto de datos de 10 sujetos [1].

Tabla 1. Resultados de un sujeto independiente.

CLF	Media	Std	Min	Max
LDA	90.78 %	±3.22	86.32 %	94.86 %
SVML	88.14 %	±3.70	82.92 %	93.47 %
SVMR	88.42 %	±3.84	82.43 %	92.99 %
MLP1	88.04 %	±3.94	82.43 %	93.19 %
MLP2	87.78 %	±3.84	82.43 %	92.78 %
MLP3	88.26 %	±3.56	83.06 %	92.57 %
NNET1	88.32 %	±3.71	83.13 %	93.26 %
NNET2	87.99 %	±3.53	82.64 %	92.5 %
NNET3	88.99 %	±3.26	84.38 %	93.2 %

A diferencia de la mayoría de los estudios de EMG que se centran en discapacidades, Junior et al. propusieron diferentes modelos de Aprendizaje Automático y selección de características de Análisis de Componentes Principales (PCA) para clasificar 4 gestos de la mano de un sujeto diagnosticado con parálisis cerebral y un sujeto sano, obteniendo una precisión del 89,55 % con el sujeto 1 y del 93,13 % con el sujeto 2 [15].

Por último, Muhammad et al. intentaron obtener una comparación entre diferentes clasificadores, cuyo rendimiento no fue tan alto como en los estudios mencionados anteriormente, pero que sigue una de las ideas principales de este artículo [13].

Este artículo no se limita únicamente en crear modelos de clasificación, como Redes Neuronales o Máquinas de Soporte Vectorial, sino que evalúa y compara su rendimiento. El objetivo principal del estudio es mejorar los modelos de clasificación utilizando técnicas de Aprendizaje Incremental como Ajuste Parcial e Inicio Rápido.

Esto implica utilizar un clasificador previamente entrenado y ajustado para adaptarse a nuevas entradas, lo que puede reducir significativamente el tiempo necesario para entrenar y ajustar los parámetros del modelo.

2. Métodos y materiales

2.1. Descripción del experimento

El experimento consistió en que el participante utilizara una órtesis de mano robótica y se colocaran electrodos de EMG en su antebrazo. Se realizaron 40 épocas por clase y cada una contenía 3 imágenes diferentes para que el participante respondiera a la instrucción dada en un tiempo limitado de 2 segundos por imagen. El experimento duró 24 minutos y se realizaron 240 pruebas en total.

- Relax: Se le pidió al participante que relajara el brazo para evitar ruido en la señal.
- +: La cruz de fijación exhorta al participante a prestar atención y concentrarse en la siguiente instrucción.
- Movement: Despliega que dedo flexionar o cerrar la mano, solo una vez.

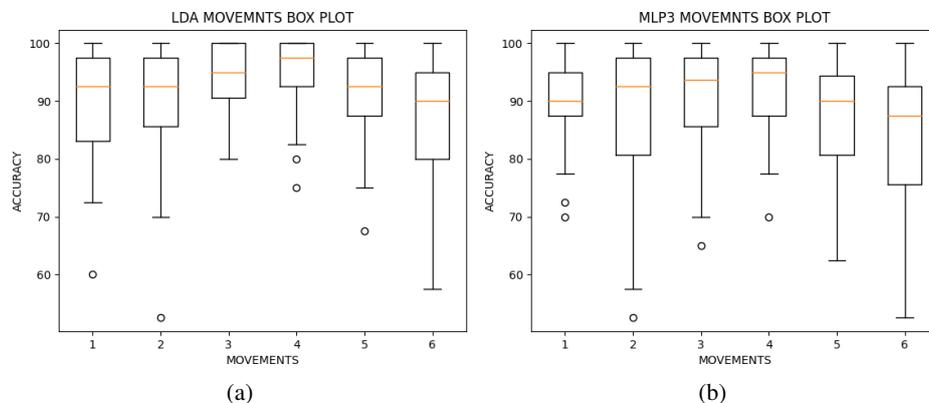


Fig. 3. (a) Diagrama de Caja de los Movimientos de LDA en USI. (b) Diagrama de Caja de los Movimientos de MLP3 en USI.

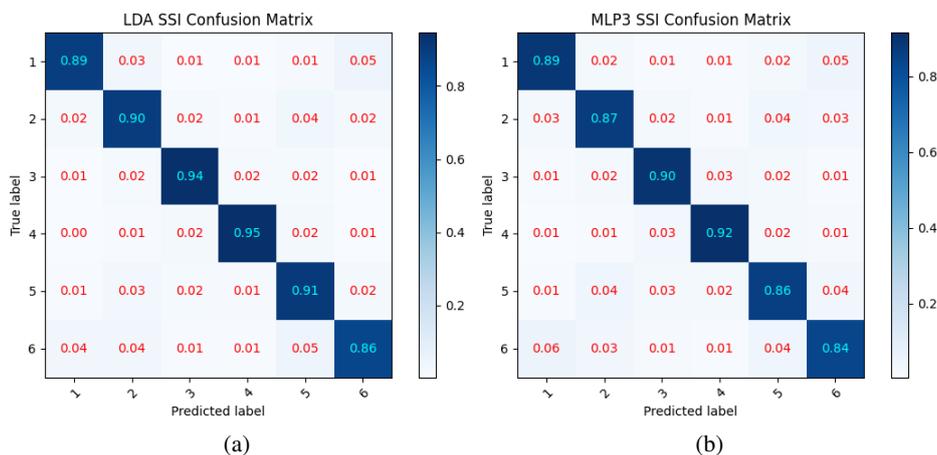


Fig. 4. (a) Matriz de Confusión de LDA en USI. (b) Matriz de Confusión de MLP3 en USI.

En el estudio mencionado, se utilizó un protocolo aprobado por el comité de ética institucional de la Universidad Tecnológico de Monterrey. Los datos de EMG se registraron durante 3 minutos mientras los sujetos realizaban contracciones isométricas en el músculo flexor digitorum superficialis y profundus, así como en el músculo opponens pollicis, en diferentes niveles de esfuerzo.

Los datos se analizaron con el software MATLAB y en Python, y se realizaron pruebas estadísticas para evaluar las diferencias en la actividad muscular en función de la intensidad del esfuerzo. La figura 1 muestra la configuración de los electrodos utilizados en el experimento.

La adquisición de señales se realizó con un dispositivo de adquisición g.USBamp (g.tec, Austria) y los electrodos desechables Kendall (CardinalHealth, Canadá). Además, se aplicó un filtro Butterworth pasa-bandas de 8° orden con unas frecuencias de 1200Hz, > 5Hz, < 200Hz y un filtro Notch de Butterowrth de 4° orden a una

Tabla 2. Resultados de dejar un participante fuera.

CLF	Media	Std	Min	Max	Test
LDA	60.25 %	±0.8	59.26 %	61.52 %	55.25 %
SVML	65.32 %	±0.94	64.04 %	66.61 %	55.54 %
SVMR	73.74 %	±0.8	72.78 %	75.02 %	56.93 %
MLP1	80.8 %	±0.87	79.59 %	81.95 %	51.5 %
MLP2	82.33 %	±0.91	81.02 %	83.57 %	53.083 %
MLP3	83.06 %	±0.93	81.69 %	84.3 %	53.42 %
NNET1	81.77 %	±0.99	80.51 %	83.22 %	52.94 %
NNET2	82.35 %	±0.91	81.11 %	83.63 %	52.82 %
NNET3	82.89 %	±0.99	81.49 %	84.24 %	52.5 %

frecuencia de 1200Hz, > 58Hz, < 62 Hz para eliminar el ruido y una referencia bipolar se agregó para cada par de electrodos. Este estudio se basa en trabajos previos como el de Kyung-Jin You et al. debido a la configuración de electrodos utilizada en la adquisición de EMG [11].

2.2. Preprocesamiento

En esta etapa se obtuvieron épocas de 6 segundos a partir de la primera instrucción visual y cada una tenía una marca, esta época se redujo a una época de 2,2 segundos o 2600 muestras como en la figura 2 y se aplicó una corrección de línea base dado un preestímulo y estímulo para cada canal $ID \in \{1 : \text{Fixation}; 101 : \text{Thumb}; 102 : \text{Index}; 103 : \text{Middle}; 104 : \text{Ring}; 105 : \text{Little}; 106 : \text{Hand}; 200 : \text{Relaxation}\}$.

Por lo tanto, al final de la adquisición de datos y el preprocesamiento de datos, obtuvimos para cada participante una matriz de datos tridimensional S con 4 canales, 2600 muestras y 240 épocas, y un vector con una etiqueta para el movimiento de cada época que es representada por $y \in \{1 : \text{Thumb}; 2 : \text{Index}; 3 : \text{Middle}; 4 : \text{Ring}; 5 : \text{Little}; 6 : \text{Hand}\}$.

2.3. Extracción y selección de características

La extracción de características implica identificar características de una partición de datos [4]. Para entrenar un modelo, los datos crudos se analizaron con varias métricas numéricas, y se seleccionaron 10 características por canal en el dominio del tiempo, lo que resultó en un total de 40 características por prueba.

Mientras que Geethanjali et al. intentaron extraer al menos 7 características para una ICC [8], Arteaga et al. intentaron extraer 6 características de dominio de tiempo [3]. En este caso, seleccionamos 10 características, incluyendo Valor Cuadrático Medio, Varianza, Desviación Estándar, Valor Absoluto Máximo, EMG Integrada, Detector de Logaritmo, Cruce por Cero, Longitud de Onda, Integral Simple al Cuadrado, y Entropía de Wavelet.

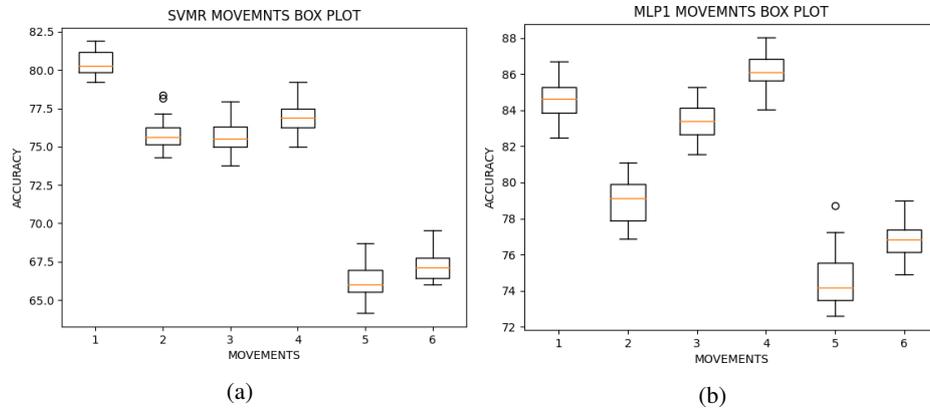


Fig. 5. (a) Diagrama de Caja de los Movimientos de SVMR en DUPF. (b) Diagrama de Caja de los Movimientos de MLP1 en DUPF.

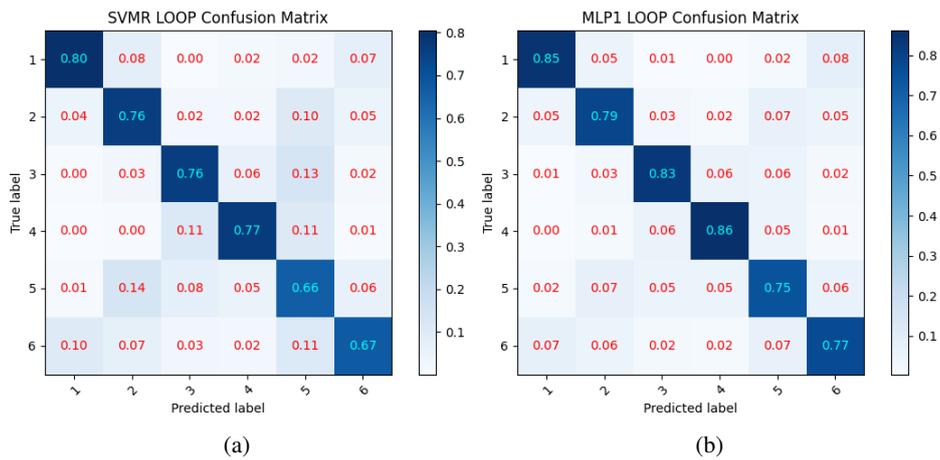


Fig. 6. (a) Matriz de Confusión de SVMR en DUPF. (b) Matriz de Confusión de MLP3 en DUPF.

Para el dominio del tiempo, se extrajeron 10 características por canal. El vector se representa como $\mathbf{x} \in \mathbb{R}^P$, con $P = 40$, indicando las 40 características totales que se plantean en la matriz X . Esta última tiene un tamaño de 240×40 . Asimismo, la matriz de etiquetas, denominada y , tiene un tamaño de 240×1 . A través del Análisis de Componentes Principales (PCA), se seleccionaron las características más significativas para el entrenamiento de los clasificadores.

2.4. Modelos de clasificación

Para entrenar modelos con múltiples datos de diferentes sujetos, se estandarizan las muestras utilizando la fórmula $z = (x - u)/s$, donde x representa las muestras de entrenamiento, s es la desviación estándar. Se seleccionan las 36 características más relevantes de la matriz de datos X , que se transforma mediante PCA.

Tabla 3. Resultados de Inicio Rápido.

CLF	0 %	10 %	20 %	30 %	40 %	50 %	60 %	70 %	80 %	90 %
MLP1	51.5	54.39	54.91	54.78	54.77	54.36	53.96	54.17	54.93	56.81
MLP2	53.08	55.91	56.42	57.28	57.55	57.19	57.08	56.71	57.29	61.39
MLP3	53.42	56.40	57.48	58.09	57.87	58.5	57.99	58.38	58.82	61.53

Se utilizan 4 modelos de clasificación diferentes para entrenar los datos con 5 K-Folds y Validación Cruzada, y se utilizan 36 características estandarizadas y seleccionadas por PCA. Los modelos son: Análisis Discriminante Lineal (LDA), Máquina de Vectores de Soporte (SVM), Perceptrón Multicapa (MLP) y Red Neuronal (NNET).

2.5. Descripción de los modelos de clasificación

Los modelos de clasificación nos permiten generar estructuras capaces de predecir etiquetas según los datos. Existen diversos tipos como bayesianos, de regresión, neuronales, entre otros. Debajo, se describen los modelos a utilizar y sus hiperparámetros.

- **LDA:** El Análisis Discriminante Lineal es un modelo de clasificación con un límite de decisión lineal ajustando las densidades condicionales a los datos usando la regla de Bayes.
- **SVM:** SVM encuentra un hiperplano en el espacio N-dimensional que clasifica los puntos de datos. Se implementaron dos SVM, ambas utilizan un coeficiente de regularización $C = 1$ y los kernels fueron lineal (SVML) y de función de base radial (SVMR).
- **MLP:** El Perceptrón Multicapa es una Red Neuronal Artificial (ANN) utilizada para resolver problemas de regresión o clasificación. Se uso una red de 4 capas; con 'tanh' como función de activación; 1,000 iteraciones máximas; 'adam' como optimizador.
 1. MLP1 tiene 100,70,30,6 neuronas por capa respectivamente.
 2. MLP2 tiene 100,100,100,6 neuronas por capa respectivamente.
 3. MLP3 tiene 150,130,130,6 neuronas por capa respectivamente.
- **NNET:** Se creó una Red Neuronal secuencial de 5 capas con Keras y TensorFlow; se utilizó 'ReLU' como función de activación y para la última capa se seleccionó la función 'Softmax'; se entrenan durante 120 épocas y tienen un tamaño de lote de 30.
 1. NNET1 tiene 36,100,70,30,6 neuronas por capa respectivamente.
 2. NNET2 tiene 36,100,100,100,6 neuronas por capa respectivamente.
 3. NNET3 tiene 36,150,130,130,6 neuronas por capa respectivamente.

Tabla 4. Resultados de Ajuste Parcial.

CLF	0 %	10 %	20 %	30 %	40 %	50 %	60 %	70 %	80 %	90 %
MLP1	51.5	56.27	56.99	56.69	56.62	56.14	55.56	56.02	56.39	61.11
MLP2	53.08	57.29	58.23	59.35	59.86	59.39	59.65	59.907	59.65	65.97
MLP3	53.42	57.69	60.10	61.43	61.04	60.95	60.45	60.93	61.25	64.72

3. Estudios de clasificación

Se realizaron 3 estudios considerando a los 30 participantes y los clasificadores se entrenaron respecto a la descripción de cada estudio para posteriormente evaluar su rendimiento.

3.1. Un sujeto independiente (USI)

Para este estudio, el entrenamiento de los modelos depende solo de un sujeto específico, es decir, se toma a uno de los 30 sujetos. Por lo tanto, las 240 pruebas del sujeto pasaron por la etapa de preprocesamiento y se aplicó la extracción y selección de características a los datos. El estudio entrenó los 9 clasificadores de forma independiente para obtener los resultados, el rendimiento y analizar el comportamiento de los clasificadores después del entrenamiento y se refleja en la tabla 1 en la sección 4.

3.2. Dejar un participante fuera (DUPF)

Para el estudio DUPF se toman en cuenta los 30 sujetos y se entrenan los clasificadores con 29 de los 30 sujetos, teniendo un total de 6,960 pruebas. Para este proceso se dejó fuera a cada sujeto y se entrenó con los otros 29, el participante restante se usó como datos de prueba con un total de 240 pruebas. Los resultados se muestran en la sección 4 en la tabla 2 para analizar el comportamiento de los clasificadores.

3.3. Aprendizaje incremental basado en inicio rápido y ajuste parcial

En esta sección, es crucial comprender la diferencia entre Inicio Rápido y Ajuste Parcial. En Inicio Rápido, los parámetros de los atributos ya aprendidos de los clasificadores no cambian, aunque algunos hiperparámetros pueden cambiar aquí se agregaron 30 y 50 neuronas a la segunda y tercer capa respectivamente.

Ajuste Parcial por otro lado, puede cambiar estos parámetros al aprender de los nuevos datos. El estudio siguió el mismo principio que el estudio DUPF pero los datos de prueba se dividieron en dos subconjuntos. Los resultados se registraron en la sección 4 como en los estudios 1 y 2.

3.4. Métricas de desempeño y pruebas estadísticas

Para analizar los resultados de los estudios descritos anteriormente, se utilizarán pruebas estadísticas como mecanismo para tomar decisiones cuantitativas basadas en el desempeño de los clasificadores, con el fin de detectar diferencias significativas con un nivel de significancia dado $\alpha < 0,05$.

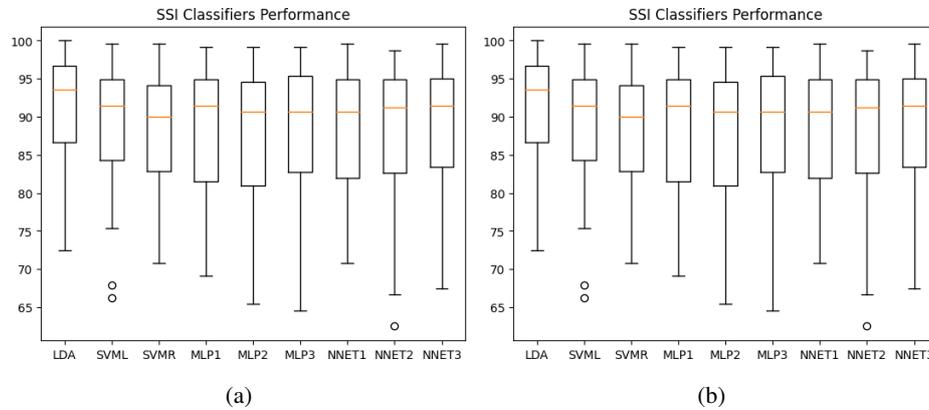


Fig. 7. (a) Rendimiento de los Clasificadores en USI. (b) Rendimiento de los Clasificadores en DUPF.

4. Resultados

4.1. Clasificación de un sujeto independiente (USI)

Para el estudio USI, cada clasificador se registró con los valores medios de su desempeño utilizando 5 K-Folds y Validación Cruzada, lo cual se muestra en la tabla 1. Como se muestra en la tabla, LDA tiene el mejor desempeño con una precisión media de validación del $90,78\% \pm 3,22$ y NNET3 con el $88,99\% \pm 3,26$. A pesar de su alto rendimiento, los demás clasificadores no se quedan atrás con su alta precisión, teniendo en cuenta que hay 6 clases.

En la tabla 1 se muestra el desempeño general de los clasificadores, así mismo se analizó por movimiento independiente y se encontró que LDA es capaz de diferenciar los movimientos 1, 5 y 6 sin dudar y MLP1 superó en los movimientos 2, 3 y 4. LDA tuvo una mejor precisión (98,33%) al clasificar los movimientos que MLP3 (72,5%). LDA es mucho mejor clasificando los movimientos 2, 3, 4 y 5.

MLP3 tiene dificultades con el movimiento 1 y ambos tienen dificultades con el movimiento 6, estos resultados se pueden ver en la figura 3. A pesar de que los clasificadores tienen dificultades para clasificar algunos movimientos, su precisión de validación es alta considerando que hay una probabilidad del 16% de acertar al azar.

Ambos diagramas de caja se pueden representar en una matriz de confusión, la cual se muestra en la figura 4, que muestra un color azul más claro en el movimiento 6 (Movimiento en el cual se complica más la clasificación) y un color azul más oscuro en los movimientos 3 y 4, donde ambos clasificadores tuvieron un gran desempeño.

4.2. Clasificación de dejar un participante fuera (DUPF)

El estudio DUPF utilizó datos de 29 sujetos para crear un conjunto de datos de entrenamiento con 6,960 pruebas y un conjunto de datos de prueba con 240 pruebas. Cada sujeto se utilizó como datos de prueba una vez.

Tabla 5. Prueba de Tukey's HSD en USI.

	Group 1	Group 2	Diff	q-value	p-value
Comparación 0	LDA	SVML	2.64	1.71	0.9
Comparación 8	SVML	SVMR	0.278	0.18	0.9
Comparación 15	SVMR	MLP1	0.38	0.24	0.9
Comparación 21	MLP1	MLP2	0.264	0.17	0.9
Comparación 26	MLP2	MLP3	0.49	0.31	0.9
Comparación 30	MLP3	NNET1	0.056	0.036	0.9
Comparación 33	NNET1	NNET2	0.34	0.22	0.9
Comparación 35	NNET2	NNET3	1.0	0.64	0.9

Se utilizaron clasificadores propuestos y se encontró que tanto MLP2 como MLP3 tuvieron un gran rendimiento en la precisión media de validación, con $82,33\% \pm 0,91$ y $83,06\% \pm 0,93$ respectivamente.

Sin embargo, SVML y SVMR tuvieron mejor rendimiento en pruebas que ambos MLP, con un $55,54\%$ y $56,93\%$ respectivamente, esto se registró en la tabla 2. En el estudio DUPF, se observó que diferentes clasificadores funcionaron mejor para diferentes movimientos. NNET1 y NNET2 obtuvieron la mejor precisión media de todos los movimientos, con $83,91\%$ y $83,23\%$ respectivamente.

SVMR tuvo un rendimiento destacado en el movimiento 3, mientras que MLP1 y SVML funcionaron mejor en los movimientos 4 y 1, respectivamente. Sin embargo, ambos SVMR y MLP3 tuvieron dificultades en los movimientos 5 y 6, al igual que en el estudio USI. Se puede ver el rendimiento por clasificador y movimiento en el diagrama de caja de la figura 5.

La matriz de confusión del estudio DUPF muestra la comparación de los clasificadores y resalta la dificultad en los movimientos 5 y 6 (Figura 6). La dominancia de SVMR con los movimientos 1 a 4 se muestra en el diagrama de caja de la Figura 5.

Aunque la precisión de prueba fue inferior a la precisión de validación, todos los clasificadores superaron la probabilidad de acierto al azar del 16% , siendo SVMR y SVML los mejores con una precisión de prueba del $56,93\%$ y $55,54\%$, respectivamente, mientras que MLP1 tuvo la precisión más baja con el $51,5\%$.

4.3. Aprendizaje incremental basado en inicio rápido y ajuste parcial

En las tablas 3 y 4, se observa que la precisión del clasificador MLP3 mejora a medida que se aumenta el porcentaje de datos utilizados para el entrenamiento. MLP3 tuvo un mejor rendimiento en ambas pruebas, con una mejora del $53,42\%$ al $61,53\%$ con Inicio Rápido y del $53,42\%$ al $64,72\%$ con Ajuste Parcial. Todos los MLP tuvieron un incremento en el número de neuronas en dos de sus cuatro capas.

Gracias a las tablas de resultados podemos ver una tendencia de convergencia después de utilizar el 40% de los datos como entrenamiento. Por lo tanto, utilizando un porcentaje de nuevos datos, la precisión de prueba puede aumentar considerablemente.

Tabla 6. Prueba de Tukey's HSD en DUPF.

	Group 1	Group 2	Diff	q-value	p-value
Comparación 0	LDA	SVML	2.29	0.08	0.9
Comparación 8	SVML	SVMR	1.39	0.36	0.9
Comparación 15	SVMR	MLP1	5.43	1.41	0.9
Comparación 21	MLP1	MLP2	0.264	0.17	0.9
Comparación 26	MLP2	MLP3	1.58	0.41	0.9
Comparación 30	MLP3	NNET1	0.47	0.12	0.9
Comparación 33	NNET1	NNET2	0.12	0.032	0.9
Comparación 35	NNET2	NNET3	0.32	0.082	0.9

4.4. Métricas de rendimiento y análisis estadísticos

El test ANOVA se usa para comparar las medias de más de dos grupos y analizar sus varianzas para verificar si son iguales. En el estudio presentado en la figura 7, se aplicó el test ANOVA para evaluar el rendimiento de los clasificadores USI y DUPF.

Aunque no se encontró una diferencia significativa entre las medias de los grupos, se utilizó la prueba HSD de Tukey para comparar los clasificadores individualmente y se realizaron 35 comparaciones en total. Como se muestra en la figura 7 de arriba, los diagramas de caja sugieren que no hay diferencias entre los clasificadores porque la media de su rendimiento es casi igual. A pesar de que parecen ser iguales, la prueba ANOVA determinará si hay una diferencia significativa.

Prueba ANOVA y prueba Tukey (HSD) para USI: La prueba ANOVA de una vía no encontró diferencias significativas entre los clasificadores en el estudio de sujetos individuales ($p > 0,946 > \alpha$), lo que respalda la hipótesis nula $H_0 = \mu_0 = \dots = \mu_p$. Tukey (HSD) permite comparaciones por grupo y también encontró que no hay diferencias significativas entre los clasificadores ($p = 0,9$), apoyando nuevamente la hipótesis nula y rechazando la hipótesis alternativa H_A .

Prueba ANOVA y prueba HSD de Tukey para DUPF: En los estudios USI y DUPF, se aplicó la prueba ANOVA y la prueba Tukey (HSD) para evaluar los clasificadores. En ambos estudios, no hubo una diferencia significativa entre los clasificadores, lo que se reflejó en los valores p que fueron mayores que α . Por lo tanto, se aceptó la hipótesis nula H_0 y se rechazó la hipótesis alternativa H_A . La prueba HSD de Tukey también mostró que no había una diferencia significativa entre los clasificadores comparados de forma independiente. En la tabla 6 se ven los resultados.

Se concluye que el rendimiento de los clasificadores no tiene diferencias significativas según las pruebas ANOVA y Tukey (HSD). Pero es relevante mencionar el estudio de Aprendizaje Incremental Basado en Ajuste de Inicio Rápido y Ajuste Parcial, donde el Perceptrón Multicapa superó a los otros clasificadores con una mejora cercana al 8 %.

5. Conclusiones

La clasificación de movimientos finos de la mano para la rehabilitación de pacientes con accidentes cerebrovasculares o neurodegenerativas es un trabajo de hace años y esto sigue evolucionando con los nuevos paradigmas de Inteligencia Artificial, los estudios muestran la efectividad de los modelos de Aprendizaje Automático en la clasificación de movimientos finos de la mano, con alta precisión y tiempo de entrenamiento reducido.

La metodología propuesta demuestra la adaptabilidad de los modelos y mantiene la generalización mientras aumenta la precisión. Los resultados obtenidos destacan el potencial de la robótica de rehabilitación para ayudar a pacientes con diversas condiciones médicas.

En el estudio de USI, LDA fue el mejor clasificador, logrando una precisión de validación del $90,77\% \pm 3,2$, mientras que en el estudio de DUPF, Perceptrón Multicapa y Redes Neuronales mostraron un rendimiento de validación más alto. Aunque las SVM obtuvieron la precisión de prueba más alta, necesitaron menos tiempo de entrenamiento que los MLP y NNET.

Por otro lado, el estudio de Aprendizaje Incremental utilizando Arranque de Inicio Rápido y Ajuste Parcial muestra la capacidad de los clasificadores para adaptarse a nuevos datos y rendir mejor con las entradas nunca vistas, aumentando hasta un 8 %.

Además, las pruebas estadísticas respaldan fuertemente los estudios y destacan el uso del Arranque de Inicio Rápido y el Ajuste Parcial como una herramienta para mejorar el rendimiento de los clasificadores y crear nuevos modelos en trabajos posteriores.

En resumen, estos estudios demuestran que los modelos de Aprendizaje Automático pueden ser una alternativa efectiva y de bajo costo para la rehabilitación robótica, especialmente en pacientes con problemas o riesgos cerebrales o cardiovasculares, y pueden ser adaptados para nuevos sujetos sin necesidad de una fase de entrenamiento extensa.

Referencias

1. Ahsan, M. R., Ibrahimy, M. I., Khalifa, O. O.: Electromyography (EMG) signal based hand gesture recognition using artificial neural network. In: 4th International Conference on Mechatronics, pp. 1–6 (2011) doi: 10.1109/icom.2011.5937135
2. Alshalali, T., Josyula, D.: Fine-tuning of pre-trained deep learning models with extreme learning machine. In: International Conference on Computational Science and Computational Intelligence, pp. 469–473 (2018) doi: 10.1109/csci46756.2018.00096
3. Arteaga, M. V., Castiblanco, J. C., Mondragon, I. F., Colorado, J. D., Alvarado-Rojas, C.: EMG-driven hand model based on the classification of individual finger movements. Biomedical Signal Processing and Control, vol. 58, pp. 101834 (2020) doi: 10.1016/j.bspc.2019.101834
4. Bhattacharjee, C. K., Sikder, N., Hasan, M. T., Nahid, A. A.: Finger movement classification based on statistical and frequency features extracted from surface EMG signals. In: International Conference on Computer, Communication, Chemical, Materials and Electronic Engineering, pp. 1–4 (2019) doi: 10.1109/ic4me247184.2019.9036671

5. Centers for disease control and prevention: Heart disease facts (2023) www.cdc.gov/heartdisease/facts.htm
6. Chen, Z., Venkat, P., Seyfried, D., Chopp, M., Yan, T., Chen, J.: Brain–heart interaction. *Circulation Research*, vol. 121, no. 4, pp. 451–468 (2017) doi: 10.1161/circresaha.117.311170
7. Espinoza, D. L., Eli Sanchez Velasco, L.: Comparison of EMG signal classification algorithms for the control of an upper limb prosthesis prototype. In: 17th International Conference on Electrical Engineering, Computing Science and Automatic Control, pp. 1–4 (2020) doi: 10.1109/cce50788.2020.9299208
8. Geethanjali, P., Mohan, Y. K., Sen, J.: Time domain feature extraction and classification of EEG data for brain computer interface. In: 9th International Conference on Fuzzy Systems and Knowledge Discovery, pp. 1136–1139 (2012) doi: 10.1109/fskd.2012.6234336
9. Geng, X., Smith-Miles, K.: Incremental learning. *Encyclopedia of Biometrics*, Springer US, pp. 912–917 (2015) doi: 10.1007/978-1-4899-7488-4_304
10. Hazarika, A., Dutta, L., Barthakur, M., Bhuyan, M.: Fusion of projected feature for classification of EMG patterns. In: International Conference on Accessibility to Digital World, pp. 69–74 (2016) doi: 10.1109/icadw.2016.7942515
11. KyungYou, K. J., Rhee, K. W., Shin, H. C.: Finger motion decoding using EMG signals corresponding various arm postures. *Experimental Neurobiology*, The Korean Society for Brain and Neural Science, vol. 19, no. 1, pp. 54–61 (2010) doi: 10.5607/en.2010.19.1.54
12. Lee, K. H., Min, J. Y., Byun, S.: Electromyogram-based classification of hand and finger gestures using artificial neural networks. *Sensors*, vol. 22, no. 1, pp. 225 (2021) doi: 10.3390/s22010225
13. Muhammad, F., Rashid, N., Akhtar, H., Muhammad, Z., Gilani, S. O., Ansari, U.: Evaluation of LDA, QDA and decision trees for multifunctional controlled below elbow prosthetic limb using EMG signals. In: International Conference on Robotics and Emerging Allied Technologies in Engineering, pp. 115–117 (2014) doi: 10.1109/icreate.2014.6828350
14. Physiopedia: Robotic rehabilitation for the lower extremity (2023) https://www.physio-pedia.com/Robotic_Rehabilitation_for_the_Lower_Extremity
15. Prado-Júnior, F. J., dos-Santos, F. V., Fernandes, C. A.: Classification of hand movements from EMG signals for people with motor disabilities. In: *IEEE Latin America Transactions*, vol. 18, no. 11, pp. 2019–2026 (2020) doi: 10.1109/tla.2020.9398644
16. Washington National: Why insurance: Covering the cost of stroke (2023) <https://washingtonnational.com/explore/why-insurance/how-to-cover-stroke-cost/#:~:text=According%20to%20the%20%20Journal%20of,ranges%20from%20%20%2420%2C396%20to%20%2443%2C652>
17. Yu, Z., Prado, R., Quinlan, E. B., Cramer, S. C., Ombao, H.: Understanding the impact of stroke on brain motor function: A hierarchical bayesian approach. *Journal of the American Statistical Association*, vol. 111, no. 514, pp. 549–563 (2016) doi: 10.1080/01621459.2015.1133425