

Reconocimiento de trayectorias del brazo usando sensores de aceleración y giroscopio

Pedro López-Rodríguez, José Ruiz-Pinales, Juan Gabriel Aviña-Cervantes,
José Luis López-Ramírez, José Guadalupe Beltrán-Hernández

Universidad de Guanajuato,
División de Ingenierías, Campus Irapuato Salamanca,
Departamento de Ingeniería Electrónica,
México

{p.lopez.rodriguez, pinales, avina,
jl.lopezramirez, jg.beltranhernandez}@ugto.mx

Resumen. Debido a la gran variedad de dispositivos inteligentes existentes en la actualidad los cuales están dotados con un gran número de sensores como: giroscopios, acelerómetros, magnetómetros, termómetros, entre otros. Dichos sensores son utilizados en el desarrollo y diseño de interfaces hombre-máquina cuya finalidad puede ser el monitoreo de la actividad del usuario, manipulación o manejo de una máquina sin interacción físicamente con la misma. Este trabajo presenta el reconocimiento de 12 trayectorias distintas y continuas del brazo utilizando datos precedentes de los tres ejes del sensor de aceleración y giroscopio del brazalete Myo™. Para realizar el reconocimiento de la trayectoria, se ha implementado y entrenado una red neuronal convolucional para la clasificación de las trayectorias. Finalmente, se realizó una validación cruzada para validar la funcionalidad del sistema propuesto y cuyos resultados obtenidos han sido del 99.97% de exactitud durante la clasificación.

Palabras clave: Acelerómetro, giroscopio, inteligencia artificial, redes neuronales convolucionales.

Arm Trajectory Recognition using Acceleration and Gyroscope Sensors

Abstract. Due to the great variety of intelligent devices existing today which are equipped with many sensors such as: gyroscopes, accelerometers, magnetometers, thermometers, among others. These sensors are used in the development and design of human-machine interfaces, whose aim could be to monitor user activity, manipulate or operate a machine without physically interacting with it. This work presents the recognition of 12 different and continuous trajectories of the arm using the data from the three axes of the acceleration sensor and gyroscope of the Myo™ armband. To perform trajectories recognition,

a convolutional neural network has been implemented and trained. Finally, a cross validation was performed to validate the functionality of the proposed system and whose results have been 99.97% accurate during classification.

Keywords: Accelerometer, gyroscope, artificial intelligence, convolutional neural networks.

1. Introducción

Al hablar del reconocimiento de gestos se hace referencia al proceso mediante el cual se realiza la comprensión y clasificación de movimientos significativos de las manos, brazos, la cara y en algunas ocasiones movimientos con la cabeza. El reconocimiento de gestos se ha convertido en un campo de investigación de gran importancia, ya que se utiliza en el desarrollo de interfaces hombre-máquina.

El desarrollo acelerado de dispositivos inteligentes (teléfonos, pulseras, relojes, etc.) y a su vez dotados de una gran cantidad de sensores (aceleración, giroscopio, presión, etc.) ha promovido una constante evolución en el desarrollo de interfaces hombre-máquina [10, 18, 23, 36]. Incluso se pueden encontrar patentes donde se utilizan dispositivos inteligentes para el reconocimiento de escritura utilizando los sensores de aceleración que se encuentran en dichos dispositivos [26, 33]. Otra área que ha sido de interés para los investigadores o desarrolladores de aplicaciones (App) inteligentes es la utilización de datos de los sensores de dichos dispositivos para realizar inferencias en diferentes aspectos de la vida [34]. Comúnmente se desarrollan aplicaciones para el monitoreo de la salud, registro del estado físico y de seguridad [17, 28, 29].

Para llevar a cabo la tarea de reconocimiento de la actividad humana mediante el uso de sensores o por el uso de otros medios de medición de la actividad, se deben tener en cuenta dos acciones principalmente. La primera acción que se tiene que atender para llevar a cabo el reconocimiento, es realizar la segmentación de las actividades durante el monitoreo. Para el caso de señales eléctricas como es el caso del presente trabajo, es llevar a cabo una segmentación en pasos de tiempo de la señal, dicha tarea se puede realizar mediante el uso de ventanas deslizantes de longitud fija y dividir cada señal en segmentos iguales. Sin embargo, al realizar la acción de segmentación por ventaneo surge la cuestión sobre la longitud de la ventana para tener una buena precisión del reconocimiento o clasificación de la señal. Para llevar a cabo esta tarea, se han planteado diferentes soluciones [18, 19, 22].

La segunda acción para realizar es una extracción de características de la señal segmentada para tener una buena clasificación o reconocimiento de la señal. Esta acción puede ser mediante el uso de metodologías tradicionales como la FFT (*Fast Fourier Transform*) [15], transformada wavelet [15], modelos autorregresivos [30], entropía espectral [25], etc. Sin embargo, con el desarrollo de la inteligencia artificial (AI por sus siglas en inglés), se tiene un enfoque diferente en la extracción de características basada en el aprendizaje profundo o *Deep Learning*, cuya idea principal radica en el aprendizaje automático de las

características directamente de los datos en bruto [18,23]. Sin embargo, se puede hacer uso de algunas técnicas de filtrado o preprocesamiento de la señal como parte de un suavizado de los datos, cuya finalidad es tener una señal lo más limpia posible para el uso de técnicas de AI [36].

En este trabajo, se propone una arquitectura de red neuronal convolucional (CNN por sus siglas en inglés) para el reconocimiento de trayectorias del brazo utilizando datos procedentes de un acelerómetro o giroscopio. La razón de usar CNNs es que éstas pueden llevar a cabo de manera óptima la tarea de extracción de características directamente sobre los datos en bruto sin necesidad de usar métodos heurísticos de extracción de características, lo cual podría ayudar a resolver algunos problemas debido a oscilaciones transitorias como es descrito en [15]. Además, las CNNs constituyen una de las más poderosas herramientas para la clasificación de patrones, señales, imágenes, etc.

2. Trabajos relacionados

Como ya se ha mencionado, existen trabajos previos relacionados al reconocimiento de gestos, escritura o trayectorias de la mano mediante el uso de dispositivos como relojes o celulares inteligentes, pulseras, guantes o algún otro equipo especializado dotado de un gran número de sensores, dentro de los cuales se encuentran el acelerómetro y giroscopio [3, 8, 10]. Estos últimos, fueron los utilizados para el desarrollo del presente trabajo, cuya finalidad es medir el cambio de aceleración y orientación en los movimientos de la mano o brazo respectivamente. Para poder realizar el reconocimiento de los movimientos, se tiene como primer paso, realizar la segmentación (comienzo y final) de cada gesto o trazo de forma adecuada, esta acción puede realizarse de forma automática como en [12] o mediante una inspección visual de la señal y realizarlo de forma manual [27]. En nuestro estudio, la segmentación se realizó de forma automática haciendo uso de la pantalla táctil de una laptop, la cual se utilizó como plantilla de trabajo para la realización de los diferentes trazos y así recopilar la información únicamente durante la realización del trazo mediante la técnica *PenUp-PenDown*, tal y como se plantea en [3].

En [12] utilizaron un teléfono inteligente para adquirir la señal del acelerómetro y giroscopio, realizando un preprocesamiento de los datos antes de utilizar el método DTW (*Dynamic Time-Warping*) como sistema de reconocimiento [1]. En [27], presentan un método capaz de reconocer la flexión de los dedos de la mano utilizando un guante dotado por acelerómetros y de un giroscopio Para la etapa de reconocimiento en [27], los autores utilizaron cinco clasificadores: Red Neuronal Estática (FNN) [13], Support Vector Machines (SVM) [5], k-Nearest Neighbors (kNN) [7], Long Short-Term Memory (STM) [16] y Gated Recurrent Unit (GRU) [6].

En [8], se presenta un algoritmo llamado 2-DifViz, que convierte los movimientos inerciales de la mano realizados en el aire (capturados con la pulsera Myo™) en secuencias de coordenadas (x, y) a un plano Cartesiano 2-D, para después realizar el reconocimiento de los dígitos comprendidos en $Z=\{0,1, \dots,$

9}, dibujados en el aire mediante la implementación de modelos de aprendizaje profundo como lo son las Gated Recurrent Unit (GRU) [6] y las Convolutional Neural Networks (CNN) [24] mediante las cuales obtuvieron un reconocimiento promedio del 96.7% usando la métrica de exactitud (*Accuracy*). En [23], se utilizaron como sistema de adquisición de señales un reloj inteligente dotado con un acelerómetro, diseñaron un sistema capaz de clasificar 10 gestos o trazos continuos mediante la implementación de un modelo de red neuronal convolucional, obteniendo un reconocimiento del 97.3%.

Como se puede observar en [8, 18, 21, 23, 36], la implementación de modelos de aprendizaje profundo se obtienen resultados de reconocimiento muy prometedores para los sistemas de reconocimiento de gestos, trazos, escritura a mano o simplemente los movimientos de la mano, haciendo uso de las señales de un acelerómetro o giroscopio.

Para el presente trabajo, se optó por realizar 12 gestos continuos utilizando el brazo, mismos que se implementaron en [12], con la diferencia de utilizar el brazalete Myo™ como sistema de captura de información sobre los movimientos de la mano. Para el procesamiento y reconocimiento de los gestos, se implementó y diseñó una CNN. Los resultados obtenidos en este trabajo de investigación son presentados en la sección 4.

3. Redes neuronales convolucionales

Las Redes Neuronales Convolucionales (CNN por sus siglas en inglés) son redes neuronales jerárquicas cuya estructura está inspirada en el sistema visual biológico [24]. La principal diferencia entre las redes neuronales clásicas o estándar y las CNN es que además de utilizar capas completamente conectadas utilizan capas convolucionales, donde se utilizan filtros de aprendizaje que se deslizan a lo largo de los datos de entrada. De forma general una arquitectura CNN puede ser descrita de la siguiente manera:

Capa Convolutiva: para un sistema unidimensional, la convolución entre dos vectores $x \in \mathbb{R}^n$ y $f \in \mathbb{R}^m$ es un vector $c \in \mathbb{R}^{n-m+1}$, donde el vector f también conocido como filtro de convolución, el cual se desliza a lo largo del vector x , obteniéndose el producto escalar en cada paso y cuyos valores obtenidos forman la salida de la capa convolutiva. De tal forma que $c_i = f^T x_{i:i+m-1}$, donde cada elemento de c es calculado como el producto escalar entre el vector f y un subsegmento de x .

No-linealidad: para aprender la no-linealidad de los sistemas, la capa convolutiva suele estar acompañada de una función de activación no-lineal aplicada puntualmente a la salida. Comúnmente se utilizan tres funciones de activación: sigmoide, tangente hiperbólica y ReLU (Rectified Linear Unit).

Capa de agrupamiento (*Pooling*): esta capa comúnmente sigue a una capa convolutiva, cuyo objetivo es reducir la dimensión de la representación obtenida después de la convolución. Para realizar esta tarea existen dos maneras, obtener un máximo o un promedio de pequeños bloques rectangulares de los datos.

Capa completamente conectada (*Fully connected*): después de realizar el proceso en las capas convolucionales, es necesario que la salida de estas capas sea convertida en un vector el cual será usado en la clasificación. Para que una arquitectura CNN pueda aprender dependencias no-lineales, se pueden utilizar una o más capas completamente conectadas para realizar la clasificación.

Capa *Soft-Max*: Finalmente, la salida obtenida en la última capa se pasa a través de una capa *Soft-Max* que obtiene la estimación de la probabilidad de las clases. De forma general estas son las capas presentes en una arquitectura CNN, las cuales son acopladas para formar una red CNN, que puede ser entrenada como un todo.

3.1. Arquitectura implementada

En este trabajo, se ha propuesto la arquitectura CNN mostrada en la Fig. 1, donde se puede observar que las señales provienen del brazalete Myo™ el cual cuenta con una Unidad de Medición Inercial (UMI) dotada con un acelerómetro, un giroscopio y un magnetómetro. Una vez realizada la captura de las señales, estas son enviadas a la red neuronal convolucional para su posterior procesamiento y clasificación. La arquitectura de la CNN propuesta en la Fig. 1, es descrita a continuación.

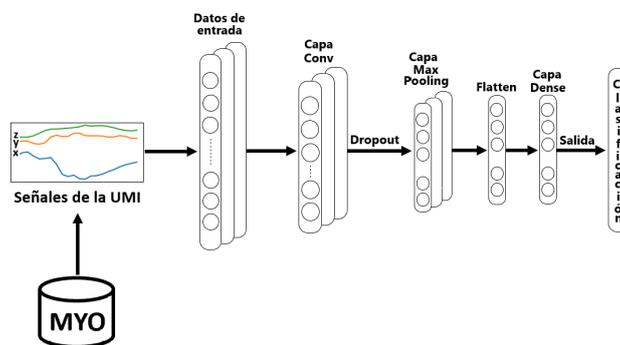


Fig. 1. Arquitectura propuesta de la Red Neuronal Convolucional (CNN).

La arquitectura mostrada en la Fig. 1 consta de una capa convolucional con 16 filtros convolucionales de tamaño 1×3 usando una función de activación ReLU para la extracción de características. Después de la capa convolucional se ha utilizado un *dropout* con una tasa de 0.9 para evitar el sobre-aprendizaje. Finalmente se ha implementado una capa completamente conectada (Dense) con función de activación *Soft-Max* para realizar la clasificación en 12 clases.

Esta arquitectura fue entrenada durante 50 épocas (*epochs*) usando el optimizador Adam y un tamaño de lote (*batch size*) de 32 y una tasa de aprendizaje de 10^{-5} .

La arquitectura presentada en este trabajo se implementó partiendo de los trabajos [18,21,23], sin embargo, la arquitectura final es diferente a los trabajos mencionados anteriormente. Para llevar a cabo la selección del número de capas, la función de activación, tasa de dropout, tipo de pooling, etc., así como otros hiper-parámetros se partió de los estudios [4,9,11,20]. Sin embargo, el diseño final de la arquitectura se obtuvo básicamente de forma empírica, es decir, a prueba y error hasta lograr encontrar el diseño de la arquitectura que presentó el más alto rendimiento.

4. Experimentación y resultados

Para poder desarrollar y probar el rendimiento del sistema propuesto en este estudio, se ha desarrollado una base de datos lo suficientemente amplia para tener un grupo de datos para entrenamiento y otro para prueba. La adquisición de las señales fue mediante el uso de una interfaz comercial llamada Myo™, dispositivo portátil desarrollado por Thalmic Labs Inc., la cual es un brazalete de un material expandible que le permite estirarse y contraerse, permitiendo así adaptarse a la fisionomía de cada usuario. Este brazalete está dotado con una Unidad de Medición Inercial (UMI) y 8 sensores para la medición de señales de electromiograma (EMG). La UMI del brazalete Myo™ consiste en un acelerómetro, un giroscopio y un magnetómetro, todos entregando señales tridimensionales. Este dispositivo puede ser conectado a un dispositivo (computadora, Tablet, celular, etc.) y cuya frecuencia de muestreo para cada sensor de la UMI es de 50Hz y de 200Hz para los sensores EMG. Este brazalete ha sido utilizado en diversos trabajos de investigación [2,8,14,32,36] obteniéndose buenos resultados, por tal motivo se optó por utilizar el brazalete Myo™.

Para el presente trabajo, se optó por realizar el reconocimiento de 12 gestos (t_1-t_{12}), los cuales se presenta en la Fig. 2. Para el análisis experimental de

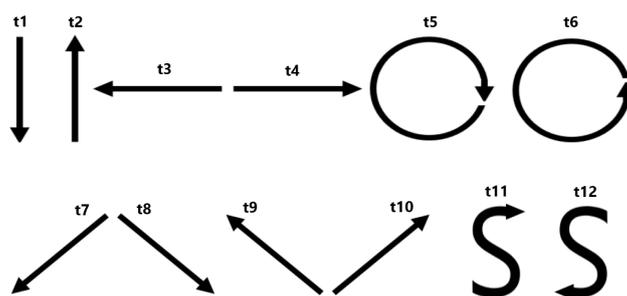


Fig. 2. Gestos planificados y capturados para formar la base de datos.

las señales, es común realizar un preprocesamiento a las mismas, que permita extraer ciertas propiedades o características propias de un conjunto de datos.

Un análisis en el espacio frecuencial es una forma común en el procesamiento de señales, ya que de esta manera se puede determinar la respuesta de un sistema para diferentes frecuencias, aunque también se puede realizar un estudio en el tiempo [15]. Algunas de las técnicas usadas comúnmente a la hora de realizar un preprocesamiento de señales son mediante el filtrado de las mismas a fin de obtener las frecuencias características del sistema [14, 31], otra técnica de preprocesamiento es usar el error cuadrático medio [36], la Transformada Rápida de Fourier, entre otras.

Sin embargo, con los avances en algoritmos de Inteligencia Artificial es posible tomar los datos en bruto, es decir, sin realizar una tarea de extracción de características previa al procesamiento de la información. En el presente trabajo se tomaron los datos entregados por el brazalete Myo™ para después ser procesados directamente en una arquitectura CNN descrita anteriormente, Fig. 1.

La base de datos cuenta con 400 trazos por cada clase (gesto), no obstante, se ha realizado un análisis tomando diferentes números de muestras para poner a prueba la arquitectura CNN propuesta y observar cuál es la susceptibilidad que tiene la red neuronal propuesta al número de muestras. Para analizar el rendimiento de la arquitectura propuesta se ha hecho una validación cruzada k -fold, la cual es una técnica estadística muy usada para evaluar el desempeño de clasificadores. Para llevar a cabo la validación cruzada (VC), se debe dividir la totalidad de los datos en k grupos del mismo tamaño. Una vez dividida la base de datos, se utiliza $k - 1$ grupos para el entrenamiento del sistema y el restante para realizar el test. Este proceso se repite k veces utilizando para cada iteración un grupo distinto de test, generando en cada iteración un $Error_n$ cuyo promedio es utilizado como estimación final:

$$estimatorVC = \frac{1}{K} \sum_{n=1}^K (Err_n). \quad (1)$$

Para nuestro trabajo se utilizó un valor de $K = 10$, lo cual significa que, de la base de datos se tomó el 90 % de las muestras para entrenamiento y el 10 % restante es utilizado para prueba. Este valor de k es el más recomendado ya que valores más grandes pueden hacer que la varianza de la estimación aumente. La Fig. 3 muestra la curva ROC promediada para todas las clases. El área bajo la curva (AUC) es 1.0. Por lo tanto se deduce que el clasificador es capaz de separar perfectamente las clases.

Los resultados obtenidos del análisis de reconocimiento realizado se presentan en la Fig. 4, donde se puede observar el rendimiento de la arquitectura CNN propuesta para la clasificación de los 12 trazos propuestos. De este análisis se constata que a menor número de muestras se tiene un mayor rendimiento de clasificación de las señales del giroscopio con respecto a la misma cantidad de muestras usadas del acelerómetro. Sin embargo, conforme se va aumentando el número de señales el rendimiento tiende a ser el mismo.

Los resultados mostrados son referentes al promedio de la validación cruzada para los diferentes números de muestras utilizados en cada prueba realizada.

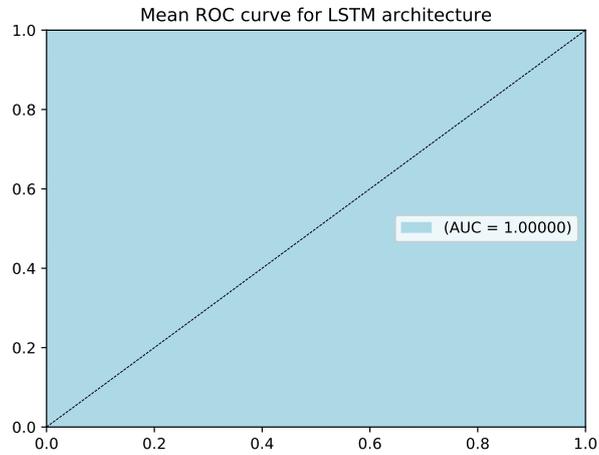


Fig. 3. Curva ROC promedio.

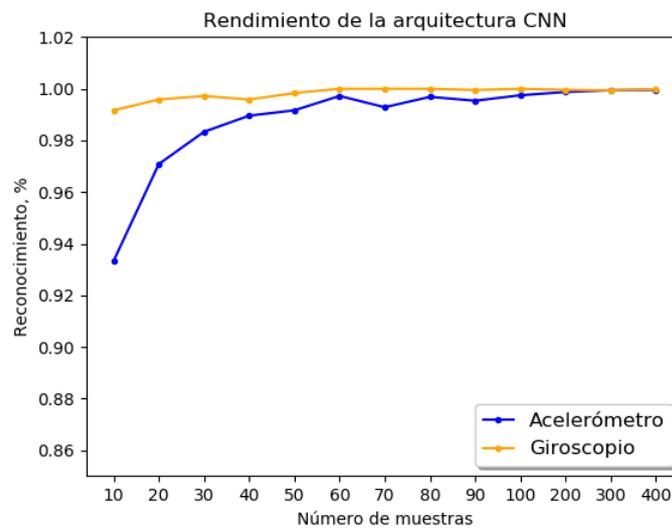


Fig. 4. Resultados de reconocimiento obtenidos para diferente número de muestras de entrenamiento.

Además, los resultados con la arquitectura propuesta han sido comparados con algunos trabajos semejantes del estado del arte, los cuales son mostrados en la Tabla 1.

Como se puede observar, los resultados obtenidos por la arquitectura CNN propuesta han logrado superar a los obtenidos en el estado del arte analizados.

Tabla 1. Análisis comparativo del porcentaje de reconocimiento en exactitud de trazos realizados con el brazo del usuario (*Método Propuesto).

Método	Accuracy (%)
CHMM [35]	99.80
CNN [23]	97.30
DTW [12]	94.00
CNN-GRU [8]	96.70
CNN*	99.97

Sin embargo, los resultados obtenidos en [8, 23, 35] se han obtenido únicamente para el reconocimiento de 10 trazos. Con respecto al presente trabajo se han realizado los mismos trazos en [12] obteniendo resultados superiores con el sistema propuesto.

5. Conclusiones

En la presente investigación, se ha propuesto un método para realizar el reconocimiento de trazos o gestos basándose en señales del acelerómetro y giroscopio. Los resultados obtenidos han demostrado que el uso de algoritmos de inteligencia artificial es posible obtener con gran precisión el reconocimiento de gestos. La arquitectura CNN propuesta demostró tener la capacidad suficiente para realizar el reconocimiento de los 12 trazos propuesto con un alto porcentaje de exactitud, por lo cual, se podría aseverar que las CNN pueden ser utilizadas en el procesamiento de señales obtenidas de acelerómetros y giroscopios. Sin embargo, ha pesar de que se tienen altos porcentajes de clasificación para ambos tipos de señales, el utilizar una cantidad pequeña de muestras del giroscopio basto para obtener un alto índice de clasificación, en comparación, al utilizar esa misma cantidad de muestras provenientes del acelerómetro.

Algunas ventajas que podemos resaltar del estudio realizado es la utilización de datos de sensores que se encuentran en una gran cantidad de dispositivos de uso común como los relojes o celulares inteligentes, así como la implementación de técnicas de AI las cuales pueden ser implementadas a través de múltiples plataformas de programación o de desarrollo de software, como lo es la librería de Keras en Python, la cual fue utilizada para nuestra implementación de la arquitectura CNN propuesta en este trabajo. Sin embargo, nuestro estudio está limitado a un dispositivo comercial (brazalete Myo™) pero que no es de uso común como lo son los relojes y teléfonos inteligentes.

En estos momentos, el estudio muestra resultados prometedores para el reconocimiento de gestos, sin embargo, se tiene la incertidumbre si el sistema implementado en este trabajo de investigación sea lo suficientemente robusto para ponerlo a prueba en un sistema de reconocimiento de gestos utilizado en la vida diaria de las personas, como lo son los sistemas de escritura o lenguajes de señas. Pues bien, el trabajo a futuro que se tiene planeado es llevar la

implementación de nuestro sistema actual a un sistema de reconocimiento de gestos de la vida diaria.

Referencias

1. Akl, A., Valaee, S.: Accelerometer-based gesture recognition via dynamic-time warping, affinity propagation, compressive sensing. In: 2010 IEEE International Conference on Acoustics, Speech and Signal Processing. pp. 2270–2273 (March 2010)
2. Ali, S., Samad, M., Mehmood, F., Ayaz, Y., Qazi, W.M., Khan, M.J., Asgher, U.: Hand gesture based control of NAO robot using myo armband, vol. 953. Springer International Publishing (020)
3. Amma, C., Georgi, M., Schultz, T.: Airwriting: A wearable handwriting recognition system. *Personal and Ubiquitous Computing* 18(1), 191–203 (2014)
4. Baldi, P., Sadowski, P.: Understanding Dropout. Tech. rep.
5. CHRISTOPHER J.C. BURGESS: A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery* 2, 121–167 (1998)
6. Chung, J., Gulcehre, C., Cho, K., Bengio, Y.: Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling pp. 1–9 (2014), <http://arxiv.org/abs/1412.3555>
7. Cover, T., Hart, P.: Nearest neighbor pattern classification. *IEEE Transactions on Information Theory* 13(1), 21–27 (1967)
8. Dash, A., Sahu, A., Shringi, R., Gamboa, J., Afzal, M.Z., Malik, M.I., Dengel, A., Ahmed, S.: AirScript - Creating Documents in Air. In: 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR). pp. 908–913. IEEE (nov 2017)
9. Du, S.S., Wang, Y., Zhai, X., Balakrishnan, S., Salakhutdinov, R., Singh, A.: How Many Samples are Needed to Estimate a Convolutional or Recurrent Neural Network? (may 2018), <http://arxiv.org/abs/1805.07883>
10. Gkournelos, C., Karagiannis, P., Kousi, N., Michalos, G., Koukas, S., Makris, S.: Application of wearable devices for supporting operators in human-robot cooperative assembly tasks. *Procedia CIRP* 76, 177–182 (2018)
11. Gotmare, A., Keskar, N.S., Xiong, C., Socher, R.: A Closer Look at Deep Learning Heuristics: Learning rate restarts, Warmup and Distillation (oct 2018), <http://arxiv.org/abs/1810.13243>
12. Gupta, H.P., Chudgar, H.S., Mukherjee, S., Dutta, T., Sharma, K.: A Continuous Hand Gestures Recognition Technique for Human-Machine Interaction Using Accelerometer and Gyroscope Sensors. *IEEE Sensors Journal* 16(16), 6425–6432 (2016)
13. Haykin, S.: *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, USA, 1st edn. (1994)
14. He, S., Yang, C., Wang, M., Cheng, L., Hu, Z.: Hand gesture recognition using MYO armband. *Proceedings - 2017 Chinese Automation Congress, CAC 2017 2017-January*, 4850–4855 (2017)
15. Herff, C., Krusienski, D.J.: *Extracting Features from Time Series*, pp. 85–100. Springer International Publishing, Cham (2019)
16. Hochreiter, S., Schmidhuber, J.: Long short-term memory. *Neural Computation* 9(8), 1735–1780 (1997)

17. Hong, Y.J., Kim, I.J., Ahn, S.C., Kim, H.G.: Mobile health monitoring system based on activity recognition using accelerometer. *Simulation Modelling Practice and Theory* 18(4), 446–455 (2010)
18. Ignatov, A.: Real-time human activity recognition from accelerometer data using Convolutional Neural Networks. *Applied Soft Computing Journal* 62, 915–922 (2018)
19. Ignatov, A.D., Strijov, V.V.: Human activity recognition using quasiperiodic time series collected from a single tri-axial accelerometer. *Multimedia Tools and Applications* 75(12), 7257–7270 (2016)
20. Izmailov, P., Podoprikin, D., Garipov, T., Vetrov, D., Wilson, A.G.: Averaging Weights Leads to Wider Optima and Better Generalization (mar 2018), <http://arxiv.org/abs/1803.05407>
21. Jiang, W., Yin, Z.: Human Activity Recognition Using Wearable Sensors by Deep Convolutional Neural Networks. *Proceedings of the 23rd ACM international conference on Multimedia - MM '15* pp. 1307–1310 (2015)
22. Kai Kuspa, T.P.: Classification of Mobile Device Accelerometer Data for Unique Activity Identification. In: Semantic Scholar, Corpus ID: 1404951. pp. 1–4 (2013)
23. Kwon, M.C., Park, G., Choi, S.: Smartwatch user interface implementation using CNN-based gesture pattern recognition. *Sensors (Switzerland)* 18(9), 1–12 (2018)
24. LeCun, Y., Bottou, L., Bengio, Y., Haffner, P.: Gradient-Based Learning Applied to Document Recognition. In: *Proceedings of the IEEE*. vol. 86, pp. 2278–2324 (1998)
25. Li, M., Liu, X., Liu, X.: Infrasound signal classification based on spectral entropy and support vector machine. *Applied Acoustics* 113, 116 – 120 (2016)
26. Li, R., View, M., Gu, A., Lin, S.h.: (12) Patent Application Publication (10) Pub. No.: US 2016/0018902 A1 (2016)
27. Ma, W., Hu, J., Liao, J., Fan, Z., Wu, J., Liu, L.: Finger gesture recognition based on 3d-accelerometer and 3d-gyroscope. In: Douligieris, C., Karagiannis, D., Apostolou, D. (eds.) *Knowledge Science, Engineering and Management*. pp. 406–413. Springer International Publishing, Cham (2019)
28. Mathie, M.J., Basilakis, J., Celler, B.G.: A system for monitoring posture and physical activity using accelerometers. In: *2001 Conference Proceedings of the 23rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. vol. 4, pp. 3654–3657 vol.4 (2001)
29. Mehta, D.D., Zañartu, M., Feng, S.W., Cheyne II, H.A., Hillman, R.E.: Mobile voice health monitoring using a wearable accelerometer sensor and a smartphone platform. *IEEE Transactions on Biomedical Engineering* 59(11), 3090–3096 (2012)
30. Mendez, M.O., Ruini, D.D., Villantieri, O.P., Matteucci, M., Penzel, T., Cerutti, S., Bianchi, A.M.: Detection of sleep apnea from surface ecg based on features extracted by an autoregressive model. In: *2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. pp. 6105–6108 (Aug 2007)
31. Patil, S., Kim, D., Park, S., Chai, Y.: Handwriting Recognition in Free Space Using WIMU-Based Hand Motion Analysis. *Journal of Sensors* 2016, 1–10 (2016)
32. Rawat, S., Vats, S., Kumar, P.: Evaluating and exploring the MYO ARMBAND. *Proceedings of the 5th International Conference on System Modeling and Advancement in Research Trends, SMART 2016* pp. 115–120 (2017)
33. Song, Y., Data, R.U.S.A.: (12) Patent Application Publication (10) Pub . No .: US 2014 / 0272493 A1 (2014)

34. Vu, T.H., Misra, A., Roy, Q., Wei, K.C.T., Lee, Y.: Smartwatch-based Early Gesture Detection & Trajectory Tracking for Interactive Gesture-Driven Applications. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies* 2(1), 1–27 (2018)
35. Xu, S., Xue, Y.: Air-writing characters modelling and recognition on modified CHMM. *2016 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2016 - Conference Proceedings* pp. 1510–1513 (2017)
36. Zhang, Q., Wang, D., Zhao, R., Yu, Y.: MyoSign. In: *Proceedings of the 24th International Conference on Intelligent User Interfaces - IUI '19*. pp. 650–660. ACM Press, New York, New York, USA (2019)