

# Wearable Full-Body Inertial Measurement with Task Classification Using Deep Learning

Jeremías Gaia, Eugenio Orosco and Carlos Soria

**Abstract**— In this work, an embedded system is developed for the non-invasive sensing and storage of biomechanical variables of people. It takes advantage of wearable technology, distributing sensors in strategic points of the body, ergonomically and functionally. The results are verified by recording and analysing tasks performed by six subjects to form a database. These tasks include being stood up, sitting down or standing up from a chair, going upstairs and downstairs and walking. Additionally, a convolutional neural network is tested for offline task classification. This work aims to initiate a process that ends in assistance-oriented applications, for the development of better injury rehabilitation techniques and support for elder people, among others. In this way, it seeks to open a path towards an improvement in the living conditions of people with and without reduced activities of daily living capacity.

**Index Terms**—Embedded systems, Inertial Measurement, Non-invasive sensing, Deep learning.

## I. INTRODUCCIÓN Y DESCRIPCIÓN DEL PROBLEMA

El auge tecnológico está permitiendo innovaciones nunca antes pensadas, la tecnología en vestimenta (*wearable technology*, en inglés), ha tomado relevancia en diferentes campos de aplicación [1][2]. El poder determinar el comportamiento de las personas en las actividades cotidianas es importante y puede ayudar a mejorar su calidad de vida.

La información sensorial de actividades realizadas por sujetos puede usarse con fines deportivos [3], para asistencia de personas [4][5], para el cuidado de personas mayores [6] y pacientes con enfermedades crónicas [7]. En cuestiones asociadas a labores limitadas (por discapacidad), o cuidado de personas de avanzada edad, las tecnologías de sensado en vestimenta presentan un aporte sustancial a la problemática en cuestión.

La tradición, los usos y costumbres o la misma cultura de una región hacen que muchas veces personas de avanzada edad vivan en soledad. Esta condición puede darse de dos maneras: o bien viven en casa propia sin compañía, o bien viven en familia, pero pasan mucho tiempo solos [8]. Esta última condición se da cuando los responsables a cargo del adulto mayor se ausentan del hogar por largos períodos de tiempo. Ambas condiciones pueden concluir en un abandono total o parcial de estas personas, cuyas capacidades normalmente se ven reducidas.

Los autores pertenecen al Instituto de Automática (UNSJ-CONICET), Av. San Martín (Oeste) 1109, San Juan, Argentina. CP: J5400ARL.(email: jeregaia2014@gmail.com.; eorosco@inaut.unsj.edu.ar; csoria@inaut.unsj.edu.ar ).

Este complejo entorno hace que la forma de cuidar a los mayores haya cambiado de forma radical. El sistema de sensado inercial en vestimenta propone sortear esas dificultades con un dispositivo ergonómico y sencillo de colocar, con el fin de mejorar las condiciones de vida de las personas con capacidades reducidas.

Las personas en proceso de rehabilitación luego de una lesión o una cirugía necesitan de ayuda para recuperar progresivamente sus capacidades. En el trabajo [9]; **Error! No se encuentra el origen de la referencia.**, se aborda la evaluación de las capacidades motrices de personas que sufrieron un accidente cerebro vascular (ACV). Los procedimientos aplicados para recuperar las zonas afectadas son cuidadosamente seleccionados para cada caso particular. Tener un sistema de medición apropiado, permite evaluar el estado de las capacidades motrices del paciente. También es deseable cuantificar o predecir el efecto de las intervenciones al proceso de recuperación, y la capacidad de recuperación de un paciente [10]. Algunos tratamientos de rehabilitación post operatorio insumen un largo tiempo. La observación del profesional a cargo podría ser acompañada por nuevas tecnologías. De esta forma, se evaluaría de manera no invasiva y objetiva el desempeño de la persona durante los ejercicios de rehabilitación.

El reconocimiento de la actividad humana (HAR, por sus siglas en inglés), es un área de investigación importante en el análisis de comportamiento humano [1]. La investigación en estas áreas emplea diferentes algoritmos de aprendizaje automático para reconocer actividades simples y complejas, como caminar, correr, cocinar, etc. Dentro del reconocimiento de actividad, la clasificación de tareas juega un papel fundamental. El proceso de clasificación requiere de entrenar, probar y evaluar algoritmos de aprendizaje automáticos, tales como redes neuronales convolucionales (CNN) y redes neuronales recurrentes (RNN), entre otros. El aprendizaje de las redes neuronales se basa en datos obtenidos de diversos tipos de sensores. Los más difundidos son acelerómetros, giróscopos y magnetómetros [11].

En un pasado reciente, el entrenamiento de redes neuronales requería de un gran esfuerzo computacional previo al entrenamiento. Esto se debía a que las redes eran entrenadas en base a características de las señales de los sensores, extraídas manualmente por los investigadores. Hoy en día, la técnica conocida como aprendizaje profundo (Deep Learning) evita este trabajo [12]. Las redes neuronales convolucionales basadas en Deep Learning (DNN, Deep neural networks) cumplen la

doble tarea de, extraer características de los datos de entrada, y aprender de ellas. El trabajo realizado por [13] explica el funcionamiento de las DNN y propone un algoritmo de procesamiento para realizar reconocimiento de actividad humana. En su mayoría, los algoritmos propuestos para HAR, son evaluados con conjuntos de datos conocidos, tales como el Skoda [14] y el Daily and Sports Activities [15].

El sistema de sensado inercial en vestimenta aquí planteado tiene como objetivo final atender de manera especial la problemática del cuidado de personas mayores o con capacidades reducidas. En este trabajo se aborda una primera etapa desarrollando la electrónica requerida para la adquisición de datos bajo ciertos protocolos de ejecución. Estos protocolos no son más que una lista de tareas de la vida cotidiana de una persona. Adicionalmente, se probó la utilidad de los datos obtenidos en las pruebas para el entrenamiento de redes neuronales basadas en Deep Learning. De esta manera, se busca dar puntapié inicial a un proceso que termine en aplicaciones orientadas a la asistencia, en el desarrollo de mejores técnicas de rehabilitación post operatorio, rehabilitación de lesiones y acompañamiento de personas mayores entre otros.

Teniendo en cuenta lo expuesto en párrafos anteriores, cabe destacar que este trabajo busca contribuir en la tarea de mejorar las condiciones de vida de aquellas personas que tengan algún tipo de capacidad reducida. Esto está en concordancia con algunas investigaciones previamente realizadas por el grupo de investigación [16][17].

El resto de este artículo se organiza de la siguiente manera. En la Sección II se detallan las partes que componen al sistema y como éstas interactúan entre sí. Posteriormente, en la Sección III se realiza una descripción de la metodología para el registro de datos. Allí se explican los protocolos de ejecución de tareas, y la red neuronal propuesta para la clasificación de las mismas. En la Sección IV se presentan los resultados obtenidos de las pruebas realizadas, y un análisis de éstos. Finalmente, en la Sección V se detallan las conclusiones obtenidas.

## II. MATERIALES

### A. Componentes que Integran el Sistema

El Sistema de sensado inercial en vestimenta integra cuatro sensores vestibles IMU (*Inertial Measurement Unit*) GY-521 [18], un sensor IMU 01B V3 de la empresa Pololu, y un microcontrolador Tiva TM4C123GH6PMI de 32 bits de Texas Instruments [19]. Este último se encuentra embebido en un kit de desarrollo Tiva C Series TM4C123G LaunchPad [20]. Los sensores GY-521 combinan en un mismo chip un giróscopo de 3 ejes y un acelerómetro de 3 ejes, para lograr un dispositivo que permite registrar movimientos en 6 grados de libertad. Estos sensores se encuentran protegidos con cápsulas impresas en material PLA de impresión 3D (Fig. 1).




Fig. 1. Cápsulas contenedoras de los sensores inerciales. a) Diseño 3D de las cápsulas; b) Fotografía de la impresión real.




Fig. 2. Interacción de los distintos componentes del sistema.

Se diseñó una placa de circuito impreso (PCB, en inglés Printed Circuit Board) para conectar los elementos con el Launchpad. La IMU 01B se encuentra montada sobre el PCB, al igual que una memoria SD, conexiones del bus I2C hacia los sensores GY-521 y una conexión serie para futuras aplicaciones inalámbricas. Tanto el PCB como el Kit Tiva C, se encuentran contenidos en una carcasa impresa en el mismo material de las cápsulas de los sensores externos.

### B. Interacción de Componentes

La unidad de procesamiento es el centro de todo el sistema. Allí se encuentran el microcontrolador y toda la electrónica anexa necesaria. La forma en la que los componentes del sistema se relacionan entre sí puede verse en la Fig. 2. Los sensores se comunican con la unidad de procesamiento a través de un bus I2C bajo un protocolo Maestro-Esclavo, donde es el microcontrolador quien establece los tiempos de lectura para cada sensor. La unidad de procesamiento se comunica con la tarjeta Micro SD a través del módulo UART del microcontrolador. La tarjeta Micro SD almacena los archivos de prueba y un archivo llamado README. Los primeros contienen el registro generado por los sensores durante una prueba. El archivo README contiene un índice que indica el último archivo de datos guardado en memoria. Esto tiene una doble funcionalidad, llevar la cuenta de archivos en memoria, y saber cuál es el nombre del siguiente archivo de prueba para no sobrescribirlos.

Al ser energizado el sistema se enciende un led de estado, el cual indica con una luz verde cuando la inicialización de hardware fue exitosa. Caso contrario, el led de estado se colocará en rojo, por ejemplo, cuando no se insertó la memoria SD. Para comenzar la adquisición de datos se presiona un pulsador de inicio dedicado para esto en la unidad de procesamiento. El sistema lee de la memoria SD el archivo README y crea un archivo de registro de datos con el nombre correspondiente. Por ejemplo: si el índice del archivo README es igual a 3, quiere decir que existen 3 archivos de prueba en memoria, y que el próximo archivo generado debe

llamarse “Archivo 4”. A partir de ese instante, se comienza el registro de la prueba durante un tiempo preestablecido.

En la unidad de procesamiento también se encuentra prevista la conexión para un módulo ESP8266, que dote al sistema de conexión Wifi. En esta versión del sistema, esta conexión no es utilizada debido a cuestiones de consumo de energía.

### III. METODOLOGÍA PARA EL REGISTRO DE DATOS

En esta sección, se detallan los protocolos de ejecución aplicados para adquisición de datos, y una breve descripción de la red neuronal convolucional propuesta. Como se mencionó en la Sección I, estos protocolos son una lista de tareas de la vida cotidiana de una persona, tales como sentarse y levantarse de una silla, caminar, y subir y bajar escaleras. Estas actividades las realizaron distintos sujetos en cada sesión de grabado de datos (en adelante, “prueba”). Mantener condiciones de prueba homogéneas, como tiempos de ejecución, disposición de sensores y formas de ejecución permiten la conformación de una base de datos idónea para su utilización posterior en procesamiento de datos y clasificación de patrones.

En primer término, con el sistema apagado, se colocan los encapsulados de sensores en vestimenta en aquellos puntos de interés determinados por el experto. Por disposición del equipo de investigación, para las pruebas realizadas los sensores están dispuestos en cada brazo y cada pierna. Además, el sensor de referencia montado en la unidad de procesamiento es colocado en el torso a la altura media del cuerpo parte frontal, como se observa en la Fig. 3. Los sensores (S0-S3) fueron posicionados aproximadamente a la altura del primer tercio de longitud de cada extremidad. De esta manera, se pretende obtener el movimiento compuesto de traslación y rotación realizados por los miembros superiores e inferiores durante la ejecución de la tarea.

Se aplicó el protocolo de adquisición de datos a 6 personas, 5 varones y una mujer, de edades entre 24 y 36 años, con un promedio de altura de 1.74 mts. Del total de personas evaluadas, uno presentaba una amputación de miembro superior (Fig. 3a). Las demás personas no presentaban patologías motrices. Digitalizar señales de grupos poblacionales patológicos y no patológicos es de utilidad en futuros trabajos de investigación. La base de datos [21] permitiría discriminar alteraciones motrices basadas en la extracción de características de las señales registradas.

Es de suma importancia mantener siempre una misma orientación de los sensores, al igual que mantener un orden respecto del lugar donde se coloca cada sensor, ya que se facilita el posterior estudio de los datos obtenidos. Es por esto que, al momento de la colocación de los sensores, se tuvo especial cuidado en mantener la ubicación mostrada en la Fig. 4a, y la orientación de la Fig. 4b. La duración de cada prueba es de 68 segundos, al cabo de los cuales el sistema toma 1500 muestras (Se entiende por “muestra” la lectura de los 5 sensores). Esto hace un total de 22 muestras por segundo, cantidad suficiente para describir las dinámicas estudiadas.




Fig. 3. Disposición de los sensores (S0-S3) en el cuerpo. a) Sujeto de prueba sin patologías motrices; b) Sujeto de prueba con amputación de miembro superior.




Fig. 4. Ubicación y orientación de sensores. a) Ubicación de los sensores en el cuerpo; b) Orientación de los ejes coordenados de los sensores.

#### A. Protocolos de Ejecución

En esta subsección se explican los procedimientos protocolares para la ejecución de acciones realizadas por los sujetos. Estas acciones básicas y naturales que una persona puede realizar están determinadas en concordancia con [11]. Los protocolos de ejecución de la base de datos son 1) Caminata, 2) Subir y bajar escaleras, 3) Sentarse y levantarse, los cuales implican estados de ejecución que son i) reposo de pie, ii) Subir, iii) Girar, iv) Bajar, v) Caminar, vi) Sentado, vii) Sentando, viii) Levantarse. De estos protocolos surgen las tareas a clasificar por la red neuronal, listadas en la Tabla I.

##### 1) Caminata

Se solicitó a cada persona ejecutar una caminata en línea recta de aproximadamente 60 metros. Tanto antes de comenzar la caminata como unos segundos antes de terminarla, se espera un breve tiempo en posición de reposo (de pie). De esta manera, es posible identificar los dos estados de posición de reposo y de caminata. Las pausas entre cambios de estados facilitan el procesamiento de la información, evitando transiciones confusas en la base de datos.

##### 2) Subir y bajar escaleras

Para esta prueba se solicitó al sujeto que realizara la siguiente secuencia. Partiendo desde la parte inferior de las escaleras, la persona debía contabilizar 5 segundos, e iniciar el ascenso. Una vez alcanzada la cima, debía esperar 5 segundos, girar sobre su eje (predisponiéndose a bajar), esperar nuevamente 5 segundos e iniciar el descenso de la escalera. Esta secuencia se repitió tantas veces como fue posible, teniendo en cuenta que el sujeto debía terminar la prueba en posición de reposo (de pie) en alguno de los extremos de la escalera. La escalera contaba con 22 escalones.

##### 3) Sentarse y Levantarse

El sujeto parte de la posición de reposo (de pie), cuenta hasta cinco y se sienta. Una vez sentado vuelve a contar hasta cinco y se levanta. Este procedimiento se repite tantas veces como sea posible, teniendo en cuenta que el sujeto debe finalizar la prueba de pie.

TABLA I

LISTA DE TAREAS QUE LA RED NEURONAL DEBE CLASIFICAR	
Tarea	Descripción
Parado	El sujeto está de pie.
Subir	El sujeto está subiendo escaleras.
Girar	El sujeto está girando sobre su eje.
Bajar	El sujeto está bajando escaleras.
Caminar	El sujeto está caminando.
Sentando	El sujeto está ejecutando la acción de sentarse.
Sentado	El sujeto está sentado.
Parando	El sujeto está ejecutando la acción de pararse

### B. Red Neuronal Convolutional

Las redes neuronales convolucionales (CNN, en inglés), son un tipo de red neuronal artificial con aprendizaje supervisado. Una CNN con una sola capa extrae características de la señal de entrada a través de una operación de convolución de la señal con un filtro (o núcleo). En una CNN, la activación de una unidad representa el resultado de realizar la operación de convolución entre el núcleo y la señal de entrada. Al calcular la activación de una unidad en diferentes regiones de la misma entrada, es posible detectar patrones capturados por los núcleos, independientemente de dónde ocurra el patrón. Una representación de la red neuronal propuesta se muestra en la Fig. 5.

Las capas de convolución en una dimensión (*conv1d*) se pueden ver como filtros, capaces de eliminar valores atípicos, filtrar los datos o actuar como un detector de características. La convolución se realiza operando matemáticamente con la señal de entrada y una matriz denominada “núcleo” (o *kernel*, en inglés). Los denominados “filtros” que se utilizan en las capas de convolución son conjuntos de núcleos. Inicialmente, los núcleos toman valores aleatorios y se ajustan automáticamente mediante técnicas de propagación hacia atrás (*backpropagation*, en inglés) a medida que el entrenamiento avanza. Por lo tanto, los filtros son una parte propia del entrenamiento, y el programador solo especifica el tamaño de los núcleos y la cantidad de éstos. En el presente trabajo se utilizaron 30 núcleos de tamaño 1x10.

Luego de la primera etapa de convolución se aplicó una capa de submuestreo denominada *maxpooling*, con el objetivo de reducir el tamaño de la próxima capa de neuronas. Esta técnica consiste en recorrer el arreglo resultante de la primera convolución en ventanas de, en este caso, 5 valores y preservar solamente el más alto de ellos. Este proceso asegura que sólo las características más importantes detectadas en la primera capa serán ingresadas en la siguiente.

La capa *dropout* desactiva aleatoriamente algunas neuronas de la red. Las neuronas desactivadas no se toman en cuenta durante el entrenamiento, lo que obliga a las neuronas cercanas a no generar dependencia con las neuronas desactivadas. Este método ayuda a reducir el sobre entrenamiento que pueda producirse, evitando la formación de parámetros muy específicos con los datos de entrenamiento. La capa *flatten* convierte el vector 2D de salida de la capa *dropout* en un vector unidimensional. Este vector pasa por dos capas densas (*Dense*), las cuales funcionan como capas ocultas de la red.

Todas las capas de la red neuronal implementada utilizan una función de activación ReLu (*rectified linear unit*, en inglés), con excepción de la última capa densa, la cual utiliza la función de activación Softmax. Esta función transforma las salidas de la capa en una representación en forma de probabilidades, de tal manera que el sumatorio de todas las probabilidades de las salidas de 1. Esta capa, para el caso de la clasificación, debe tener tantas neuronas como tareas se desee clasificar. El valor de probabilidad de salida más alto, será aquel que corresponda a la tarea que la red estima que el sujeto estuvo realizando, de acuerdo con los datos de entrada recibidos.

Durante el entrenamiento, se utiliza el algoritmo de optimización de velocidad de aprendizaje adaptativo “Adam”.




Fig. 5. Representación esquemática de la red neuronal propuesta.

El mismo está diseñado específicamente para entrenar redes neuronales profundas, y se implementó con los parámetros recomendados por los creadores del método en [22], esto es,  $\alpha = 0,001$ ,  $\beta_1 = 0,9$ ,  $\beta_2 = 0,999$  y  $\epsilon_1 = 10^{-8}$ . El vector de salida utilizado para el entrenamiento de la red contenía las etiquetas de cada actividad identificadas con números enteros del 1 al 9. Debido a esto, la función de pérdida (o función de puntaje de optimización) elegida es una de entropía cruzada que permite trabajar con etiquetas conformadas por enteros. En la literatura, esta función se encuentra como *sparse categorical crossentropy*. Por su parte, el número de iteraciones de entrenamiento fue determinado experimentalmente según la convergencia de la precisión, quedando en 25.

Distintos indicadores son utilizados para evaluar el desempeño de las redes neuronales. Los más conocidos son la exactitud, precisión, sensibilidad, la medida F (*F1 Score*) y matriz de confusión. Las definiciones para estos conceptos se basan en que las actividades pueden ser clasificadas como: positivo verdadero (PV) y negativo verdadero (NV) cuando son correctamente reconocidas, o falso positivo (FP) y falso negativo (FN) cuando no son correctamente clasificadas.

La exactitud es una medida de los casos correctamente clasificados. Su definición es:

$$Exactitud = \frac{PV + NV}{PV + NV + FP + FN} \quad (1)$$

Por su parte, la precisión (también llamada valor predictivo positivo), es la cantidad de predicciones positivas que se hicieron, sobre el total de casos positivos.

$$Precisión = \frac{PV}{PV + FP} \quad (2)$$

La sensibilidad, o tasa de positivos verdaderos, es la proporción de predicciones positivas correctas respecto de los casos positivos totales.

$$Sensibilidad = \frac{PV}{PV + FN} \quad (3)$$

La medida F, más conocida como *F1 Score*, es una medida adicional de exactitud, que considera la sensibilidad y la precisión.

$$F_1 \text{ score} = \frac{\text{Precisión} * \text{Sensibilidad}}{\text{Precisión} + \text{Sensibilidad}} \quad (4)$$

Una visualización rápida del rendimiento de la red para clasificar tareas es la matriz de confusión. Se trata de una tabla de doble entrada, en la que se puede ver en cuántos de los casos una tarea fue clasificada correctamente, y cuántas veces esta tarea fue clasificada de forma incorrecta.

Las tareas a clasificar por la red se listan en la Tabla I. Estas tareas surgen de los protocolos de ejecución detallados en la subsección II-D.

#### IV. RESULTADOS

Se presentan a continuación los resultados obtenidos de las pruebas realizadas, para cada una de las tareas detalladas en la sección anterior. La forma de exposición es de manera descriptiva de cada estado de ejecución.

##### 1) Análisis descriptivo y paramétrico

En esta sección se describe cómo los movimientos realizados por los sujetos se manifiestan en cambios de las señales registradas. Además, se exponen algunos parámetros representativos de las señales.

##### a) Subir y bajar escaleras

El movimiento realizado para subir y bajar escaleras, y el de caminata, son movimientos simétricos respecto del plano sagital del cuerpo. Dada esta condición, analizar lo sucedido en uno de los lados del cuerpo es representativo del comportamiento de ambos.

La Fig. 6 muestra la señal obtenida en el giróscopo ubicado en la pierna derecha del sujeto de prueba. Se observa cómo luego del primer ascenso a la escalera (muestras 80 a 350 aprox), el sujeto se frena (muestras 350-380) y ejecuta un giro sobre su eje (muestras 380-430). Este giro se ve reflejado en un aumento progresivo de la amplitud de la señal, distinto a los cambios bruscos que se produjeron durante el ascenso. Este cambio gradual se nota mayormente en el eje X.

Existe una concordancia entre la cantidad de escalones que debió subir el sujeto y los picos de amplitud que presenta la gráfica de las piernas. Esta última afirmación surge de un análisis más profundo de la Fig. 6, en conjunto con las señales obtenidas para los acelerómetros del lado derecho del cuerpo (Fig. 7 y Fig. 8). Respecto a la discriminación subir o bajar las escaleras, se observa a partir del registro que las excursión positiva y negativas son distintas para el giróscopo. El registro de los acelerómetros presenta diferencias menos apreciables, aunque se verifican picos de aceleración distintos entre subir y bajar. Se realizó, además, un análisis frecuencial de los movimientos de subida y bajada. Para ello, se calculó el módulo en  $\mathbb{R}^3$  de la señal acelerómetro y giróscopo en cada extremidad. Se procesó para cada sujeto el espectro de frecuencia del módulo de la señal. La Fig. 9 muestra el espectro correspondiente a las figuras 6 y 8 en los segmentos donde el sujeto subía la escalera. En ella se observa que las componentes frecuenciales dominantes coinciden tanto en el acelerómetro como en giróscopo. Por su parte, la Fig. 10 muestra el espectro para aquellos segmentos de las figuras 6 y 8 donde el sujeto descendía de la escalera. En ella no se aprecia un pico de frecuencia. En el giróscopo, debido a que los movimientos captados por el sensor durante el descenso son de baja frecuencia.

##### a) Caminata

Como se mencionó en III-A, la caminata es un movimiento simétrico que puede describirse analizando lo sucedido en uno de los lados del cuerpo. Las mediciones registradas por los acelerómetros ubicados en el lado derecho del sujeto con amputación de miembro superior se muestran en la Fig. 11 y la Fig. 12 y la. Por su parte, los registros de los giróscopos para este caso, se pueden visualizar en la Fig. 13 y la Fig. 14.

Durante la caminata, el eje X de los acelerómetros es colineal al vector de la gravedad la mayor parte del tiempo. Así, su valor medio se encuentra alrededor del valor de la aceleración de la gravedad ( $9,8 \text{ m/s}^2$ ). Se distingue que los pasos dados forman picos de amplitud en las señales obtenidas. De esta forma, se podría establecer el número de pasos dados por la persona.

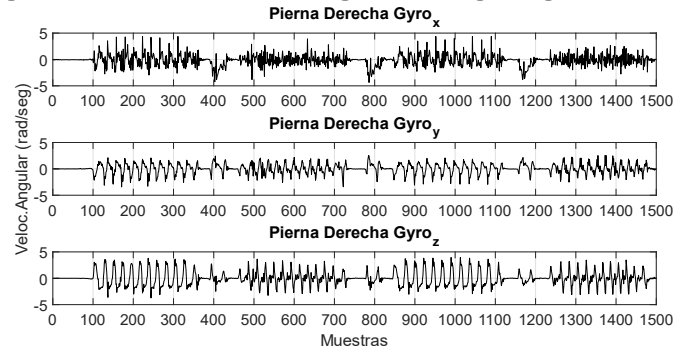


Fig. 6. Medición del giróscopo colocado en la pierna derecha de un sujeto sin patologías motrices subiendo y bajando escaleras.




Fig. 7. Medición del acelerómetro colocado en el brazo derecho de un sujeto sin patologías motrices subiendo y bajando escaleras.

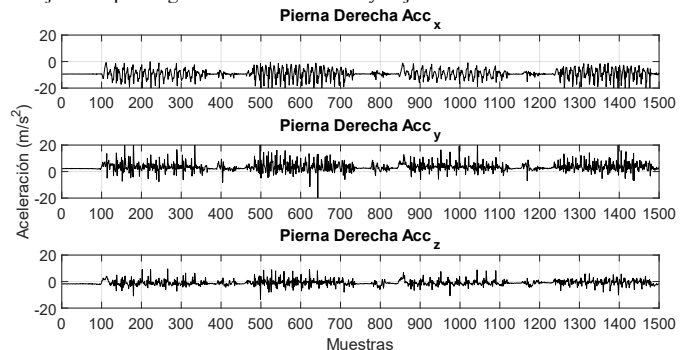


Fig. 8. Medición del acelerómetro colocado en la pierna derecha de un sujeto sin patologías motrices subiendo y bajando escaleras.

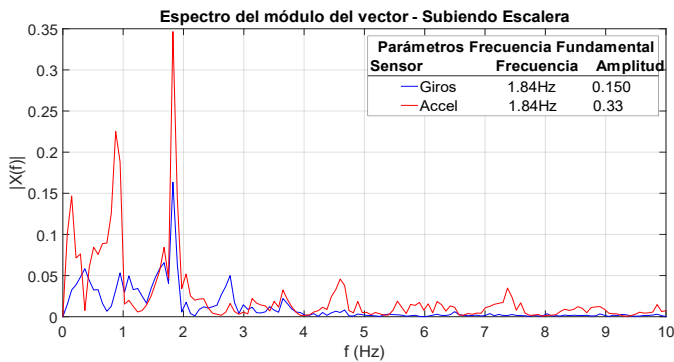


Fig. 9. Espectro del módulo de la señal de un sujeto sin patologías motrices subiendo escaleras.

El análisis frecuencial de este movimiento (

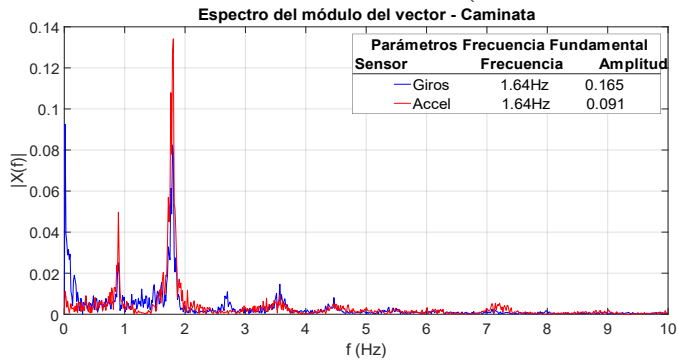


Fig. 15) permite observar que en la frecuencia fundamental coinciden los picos de amplitud para el acelerómetro y el giróscopo. Se observa que, la componente frecuencial predominante se diferencia en su valor pico del resto de los armónicos, lo cual permite establecer la frecuencia de la caminata.




Fig. 10. Espectro del módulo de la señal de un sujeto sin patologías motrices bajando escaleras.

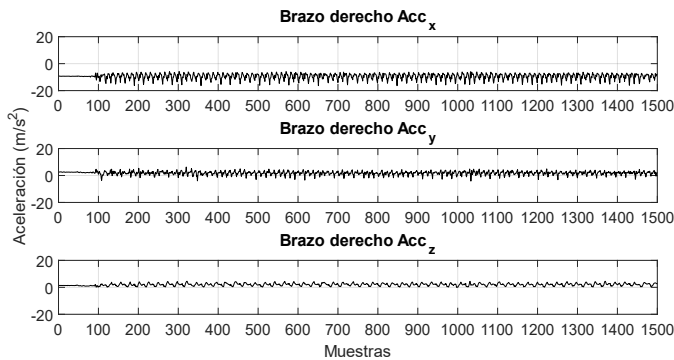


Fig. 11. Medición del acelerómetro colocado en el brazo derecho de un sujeto con amputación de miembro superior ejecutando una caminata.

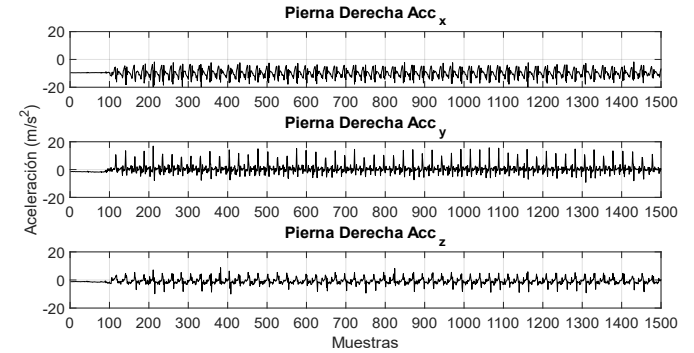


Fig. 12. Medición del acelerómetro colocado en la pierna derecha de un sujeto con amputación de miembro superior ejecutando una caminata.

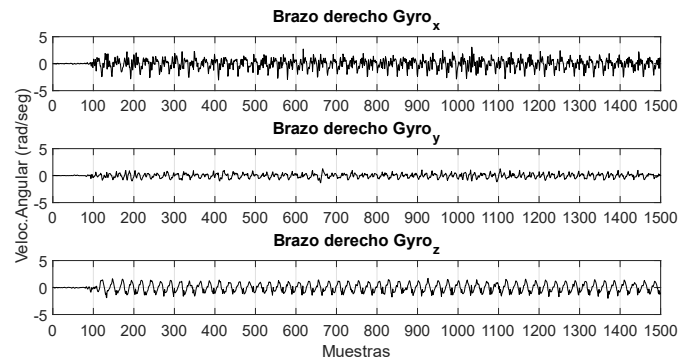


Fig. 13. Medición del giróscopo colocado en el brazo derecho de un sujeto con amputación de miembro superior ejecutando una caminata.

a) *Sentarse y levantarse*

Para el análisis de esta tarea, se visualiza el lado derecho del cuerpo del sujeto. Las señales registradas por los acelerómetros para uno de los sujetos sin patologías motrices, se muestran en la Fig. 16 y la Fig. 17. Se observa que, cuando el sujeto se encuentra en la posición de reposo (de pie), el eje X es colineal al vector de la gravedad. Esto hace que la componente de la aceleración sobre el eje X sea mayor que en los restantes. Dicha condición se debe a que para los ejes Y-Z, la amplitud de la componente vectorial de la gravedad proyectada sobre ellos, dependerá del ángulo que éstos formen con la dirección de la gravedad. Al cambiar el sujeto su posición para sentarse, el eje X del sensor ubicado en las piernas pasa de ser colineal con la dirección de la gravedad, a estar a 90° con la misma. Esto se manifiesta en una disminución de la amplitud de la aceleración en dicho eje, desde el valor máximo (9,8 m/s<sup>2</sup>) hasta cero. Dada esta situación, el eje más representativo del movimiento pasa a ser el eje Y, aumentando su amplitud a medida que la pierna se flexiona. Una vez que el sujeto alcanza la posición de sentado, el eje Y queda totalmente colineal con la gravedad.




Fig. 14. Medición del giroscopo colocado en la pierna derecha de un sujeto con amputación de miembro superior ejecutando una caminata.




Fig. 15. Espectro del módulo de la señal de un sujeto sin patologías motrices ejecutando una caminata.




Fig. 16. Medición del acelerómetro colocado en el brazo derecho de un sujeto sin patologías motrices ejecutando la tarea de sentarse y levantarse.

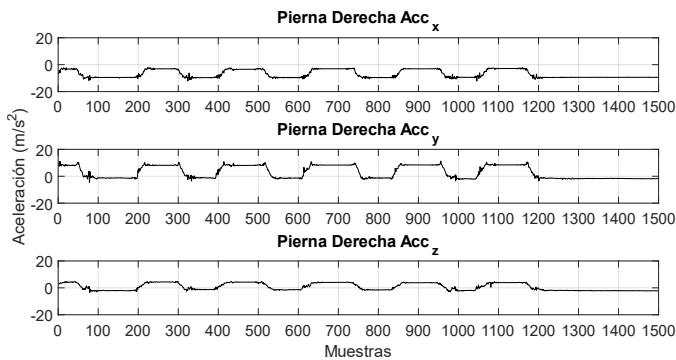


Fig. 17. Medición del acelerómetro colocado en la pierna derecha de un sujeto sin patologías motrices ejecutando la tarea de sentarse y levantarse.

## 2) Clasificación de tareas mediante Deep Learning

En esta sección se muestra el trabajo realizado para lograr la clasificación fuera de línea de tareas a través de una CNN 1-D.

### a) Red neuronal convolucional

La red neuronal implementada en este trabajo presenta la estructura mostrada en la Tabla II.

TABLA II  
CAPAS DE LA CNN IMPLEMENTADA

Capa	Forma de la salida	Cantidad de parámetros
Convolutiva (Conv 1D)	(21,30)	330
Convolutiva (Conv 1D)	(12,30)	9030
Dropout	(12,30)	0
Flatten	360	0
Dense	128	46208
Dense	8	1161
Parámetros entrenados totales	-	56729

### b) Preparación de los datos

La preparación de los datos con los que se entrenará una red es una parte fundamental del proceso. Como se mencionó en la sección II-E, el entrenamiento aplicado a la CNN es del tipo supervisado. Esta metodología de entrenamiento requiere que, antes de comenzar, se cuente con datos de entrada y salida, que la red tomará como referencia para la extracción de características y el aprendizaje de patrones.

En primer lugar, para generar estos datos se debió, realizar una clasificación manual de las tareas para cada sujeto. Posteriormente, con el registro completo de todos los sujetos, se concatenaron los valores ordenados en un arreglo que contuviera los datos de entrada y salida del conjunto. Para evitar sesgos de entrenamiento, el arreglo se separó aleatoriamente en una proporción 70% del total de los datos para el entrenamiento, y el 30% restante se usó para validación. Este último proceso se lleva a cabo solicitando al modelo que realice predicciones respecto de datos ingresados. Los datos son tomados aleatoriamente de la base de datos.

### c) Indicadores obtenidos

La Tabla III muestra los indicadores de precisión (2), sensibilidad (3) y puntaje F1 (4), obtenidos luego del entrenamiento de la red, para la clasificación de cada tarea. Además, la matriz de confusión se muestra en la Fig. 18.

TABLA III

INDICADORES OBTENIDOS LUEGO DEL ENTRENAMIENTO			
Tarea	Precisión	Sensibilidad	$F_1$ Score
Parado	0.88	0.98	0.92
Subir	0.96	0.96	0.94
Girar	0.94	0.87	0.90
Bajar	0.95	0.94	0.95
Caminar	0.99	0.98	0.99
Sentando	0.94	0.59	0.72
Sentado	0.76	0.97	0.85
Parando	0.79	0.61	0.69

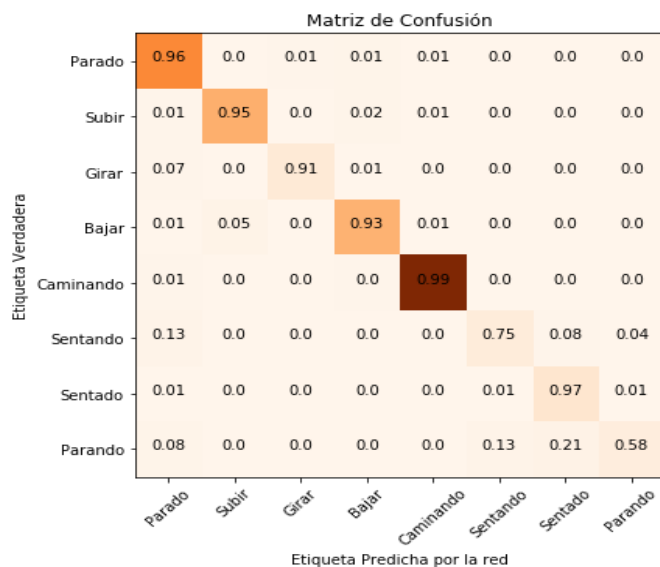


Fig. 18. Matriz de confusión.

La tabla 4 muestra la exactitud (1) obtenida en el entrenamiento y en la validación.

TABLA IV  
VALORES DE EXACTITUD OBTENIDOS

Etapa	Exactitud
Entrenamiento	0.9152
Validación	0.9348

De los resultados expuestos, se puede observar que existen estados que se clasifican con una mejor aproximación (Parado y Caminando) y otros que se pueden confundir (Sentando y Parando). Que la red interprete que el sujeto se está sentando cuando en realidad se está parando, es un error lógico, puesto que estas acciones son similares en su ejecución. Esto indica que el resultado de la CNN puede ser suficiente, pero se podría mejorar la propuesta si se plantean clasificadores anidados de este tipo, aunque aumentando la complejidad. Además, aumentar la cantidad de sujetos de prueba también aumentaría la capacidad de discriminar tareas de la CNN. Trabajos similares se centran en el desarrollo de redes neuronales convolucionales, y utilizan bases de datos públicas, tales como “mHealth”, “Skoda” y “opportunity”, para su test y validación, sin una generación propia de sistemas embebidos. En [23] se utilizan CNN’s de una dimensión para realizar HAR sobre el conjunto de datos “mHealth”, obteniendo una exactitud de 90.43%, similar a los resultados expuestos en este trabajo. Por otro lado, en [24] analizan el desempeño de distintas redes neuronales sometidos a los conjuntos de datos “Skoda” y “Opportunity”. En particular, los resultados de exactitud que se obtienen para CNN’s no superan el 80%.

## V. CONCLUSIONES

Los sistemas de sensado inercial en vestimenta aplicados a tareas de la vida cotidiana, representan un campo de aplicación con un gran potencial. Poder brindar asistencia a personas con capacidades reducidas y seguridad a sus seres queridos es una tarea que conlleva una gran responsabilidad social.

Mediante el uso de las tecnologías disponibles se logró un sistema que integra de forma completa el sensado inercial con IMU y la potencia de un microcontrolador de última generación

ARM Cortex M4 de 32 bits. De esta forma, se consiguió explotar al máximo las capacidades de los sensores, y elaborar un sistema que permita obtener una tasa de muestreo que posibilite representar las tareas ejecutadas. Las señales de los sensores presentan algún grado de discriminación entre estados de ejecución de movimientos. La realización de una base de datos, registro visual y esta clasificación de movimiento preliminar realizadas por un experto auguran una posible automatización del proceso.

La inclusión de una tarjeta de memoria como medio de almacenamiento de los archivos de prueba permite generar un respaldo de la actividad desarrollada que es independiente del uso o no de las conexiones inalámbricas previstas dentro del PCB desarrollado. Esto otorga confiabilidad al sistema puesto que no existe pérdida de información ante fallas de conexión.

Las pruebas de funcionamiento resultaron satisfactorias. La ergonomía del movimiento resulta factible usando los sensores vestibles, aunque un contrapunto es el montaje del sistema de cables. Se obtuvieron datos de los sensores que dan como resultado graficas claras y representativas de los movimientos realizados por el sujeto de prueba. Además, a través del análisis frecuencial de las señales de los distintos sujetos se logró establecer que para la caminata la frecuencia promedio de ejecución de 1.6 Hz. Para el movimiento de subir escaleras la frecuencia promedio fue 1.89 Hz, y al bajar fue de.

La clasificación fuera de línea mediante redes neuronales convolucionales presentó resultados positivos. Esto permite pensar en desarrollos que, con una baja cantidad de sensores vestibles sean capaces de determinar el estado de una persona. Esta posibilidad allanaría el camino hacia aplicaciones para mejorar las condiciones de vida de las personas con y sin capacidades reducidas.

## REFERENCIAS

- [1] Chin, Z. H., Ng, H., Yap, T. T. V., Tong, H. L., Ho, C. C., & Goh, V. T. (2019). Daily Activities Classification on Human Motion Primitives Detection Dataset. In *Computational Science and Technology* (pp. 117-125). Springer, Singapore.
- [2] Mosenia, A., Sur-Kolay, S., Raghunathan, A., & Jha, N. K. (2017). Wearable medical sensor-based system design: A survey. *IEEE Transactions on Multi-Scale Computing Systems*, 3(2), 124-138.
- [3] M. Ermes, J. Pärkkä, J. Mäntyjärvi and I. Korhonen, "Detection of Daily Activities and Sports with Wearable Sensors in Controlled and Uncontrolled Conditions," in *IEEE Transactions on Information Technology in Biomedicine*, vol. 12, no. 1, pp. 20-26, Jan. 2008.
- [4] A. Correa, A. Morell, M. Barceo and J. L. Vicario, "Navigation system for elderly care applications based on wireless sensor networks," *Proceedings of the 20th EUSIPCO*, Bucharest, 2012, pp. 210-214.
- [5] G. Diraco, A. Leone, and P. Siciliano. "An active vision system for fall detection and posture recognition in elderly healthcare". In *Proceedings of the conference on design, automation and test in Europe*, pp. 1536-1541. European Design and Automation Association. March 2010
- [6] N.K.Suryadevara, A.Gaddam, R.K. Rayudu, S.C. Mukhopadhyay, "Wireless sensors network based safe home to care elderly people": Behaviour detection, *Sensors and Actuators A: Physical*, vol 186, 2012, pp 277-283.
- [7] Atallah, B. Lo, R. King and G. Yang, "Sensor Placement for Activity Detection Using Wearable Accelerometers," 2010 International Conference on Body Sensor Networks, Singapore, 2010, pp. 24-29.
- [8] Encuesta Nacional sobre Calidad de Vida de Adultos Mayores 2012. <https://www.indec.gov.ar/ftp/cuadros/sociedad/encaviam.pdf>. pp 16-17. (Fecha de Acceso: 19/02/2019).
- [9] H.S. Jørgensen, H. Nakayama, H. O. Raaschou, T.S. Olsen, "Recovery of walking function in stroke patients: The



- copenhagen stroke study”, Archives of Physical Medicine and Rehabilitation, vol 76, Issue 1, 1995, pp 27-32.
- [10] C.M. Stinear, W.D. Byblow, S.H. Ward, “An update on predicting motor recovery after stroke”, Annals of Physical and Rehabilitation Medicine, vol 57, Issue 8, 2014, pp 489-498.
- [11] Jain, A., & Kanhangad, V. (2017). Human activity classification in smartphones using accelerometer and gyroscope sensors. *IEEE Sensors Journal*, 18(3), 1169-1177.
- [12] Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., ... & Asari, V. K. (2019). A state-of-the-art survey on deep learning theory and architectures. *Electronics*, 8(3), 292.
- [13] F. Ordóñez and D. Roggen “ Deep convolutional and lstm recurrent neural networks for multimodal wearable activity recognition”. 2016. *Sensors*, 16(1), 115.
- [14] P. Zappi, C. Lombriser, T. Stiefmeier, E. Farella, D. Roggen, L. Benini and G. Tröster. “Activity recognition from on-body sensors: accuracy-power trade-off by dynamic sensor selection”. In *European Conference on Wireless Sensor Networks* (pp. 17-33). Springer, Berlin, Heidelberg, Jan. 2008
- [15] B. Barshan and M.C. Yüsek, (2014). “Recognizing daily and sports activities in two open source machine learning environments using body-worn sensor units”. *The Computer Journal*, 57(11), pp. 1649-1667.
- [16] A. A. Porcel, E. Bustos, E. Pérez, E. Orosco, N. M. López. “Interfaz basada en sensores inerciales para el control de dispositivos móviles”- 2013.
- [17] E. Perez, N. López, M. Dominguez, and E. Orosco (2019).” Inertial Measurement System for Upper Limb Joints Tracking”. In *World Congress on Medical Physics and Biomedical Engineering 2018*. pp. 785-789. Springer, Singapore.
- [18] MPU 6050 Register Map:  
<https://www.invensense.com/wp-content/uploads/2015/02/MPU-6000-Register-Map1.pdf>  
(Fecha de Acceso: 19/02/2019).
- [19] Tiva TM4C123GH6PMI datasheet:  
<http://www.ti.com/lit/ds/symlink/tm4c123gh6pm.pdf>  
(Fecha de Acceso: 19/02/2019).
- [20] Tiva C Series TM4C123G LaunchPad User’s Guide:  
<http://www.ti.com/lit/ug/spmu296/spmu296.pdf>  
(Fecha de Acceso: 19/02/2019).
- [21] Base de datos en GitHub:  
<https://github.com/JeremiasGaia/Registros-de-Actividad.git> (Fecha de Acceso: 19/02/2019).
- [122] D. P. Kingma and J. Ba, “Adam: A method for stochastic optimization,” arXiv preprint arXiv:1412.6980, 2014.
- [23] Ha, S., & Choi, S. (2016, July). “Convolutional neural networks for human activity recognition using multiple accelerometer and gyroscope sensors”. In *2016 International Joint Conference on Neural Networks (IJCNN)* (pp. 381-388). IEEE.
- [24] Zeng, M., Nguyen, L. T., Yu, B., Mengshoel, O. J., Zhu, J., Wu, P., & Zhang, J. (2014, November). “Convolutional neural networks for human activity recognition using mobile sensors”. In *6th International Conference on Mobile Computing, Applications and Services* (pp. 197-205). IEEE.

**Eugenio Conrado Orosco** nacido, criado y formado en San Juan, Argentina. Obtuvo su título de grado en Ingeniería Electrónica de la Facultad de Ingeniería de la Universidad Nacional de San Juan (UNSJ) en 2008. En el año 2013 recibió su Doctorado en Ingeniería de Sistemas de Control, otorgado por la misma casa de altos estudios. Fue becario de investigación y actualmente es Investigador Asistente en el Consejo Nacional de Investigaciones Científicas y Tecnológicas (CONICET). Profesor Adjunto de la cátedra Microprocesadores y Electrónica Digital III del Laboratorio de Electrónica Digital, en el departamento de Electrónica y Automática de la UNSJ. Sus fortalezas son los sistemas embebidos, procesamiento de señales y Deep Learning. Es formador de recursos humanos a nivel de grado y posgrado, así como también director de varios proyectos de investigación y transferencia tecnológica.

**Carlos Miguel Soria** nació en Tucumán, Argentina un 27 de Noviembre de 1970. En 1996 se graduó como ingeniero eléctrico de la Facultad de Ciencias Exactas de la Universidad Nacional de Tucumán (UNT). En el año 2000 se graduó como Máster en Ingeniería de Sistemas de Control en la Facultad de Ingeniería de la Universidad Nacional de San Juan (UNSJ). Obtuvo su doctorado en Ingeniería de Sistemas de Control en el mismo establecimiento. En el periodo entre los años 1997 y 2000 fue becario de investigación del programa FOMEC (Fondo para el Mejoramiento de la Calidad Universitaria) que le permitió completar sus estudios de maestría. En el período entre 2001 y 2004 fue becario del Consejo Nacional de Investigaciones Científicas y Tecnológicas (CONICET). Actualmente es profesor en la UNSJ, e Investigador Independiente del CONICET.

**Jeremías Gaia Amorós** nacido en Córdoba, Argentina, en 1995. Creció y obtuvo su educación en la provincia de San Juan. En el año 2019 recibió su título de Ingeniero Electrónico en la Facultad de Ingeniería of Universidad Nacional de San Juan (UNSJ). El mismo año comenzó sus estudios doctorales. Al mismo tiempo comenzó a colaborar como becario de investigación en el Instituto de Automática (INAUT) de la UNSJ. En 2020 obtuvo una beca doctoral del Consejo Nacional de Investigaciones Científicas y Tecnológicas (CONICET).