

Información Importante

La Universidad Santo Tomás, informa que el(los) autor(es) ha(n) autorizado a usuarios internos y externos de la institución a consultar el contenido de este documento a través del Catálogo en línea de la Biblioteca y el Repositorio Institucional en la página Web de la Biblioteca, así como en las redes de información del país y del exterior con las cuales tenga convenio la Universidad.

Se permite la consulta a los usuarios interesados en el contenido de este documento, para todos los usos que tengan **finalidad académica**, nunca para usos comerciales, siempre y cuando mediante la correspondiente cita bibliográfica se le dé crédito al trabajo de grado y a su autor.

De conformidad con lo establecido en el Artículo 30 de la Ley 23 de 1982 y el artículo 11 de la Decisión Andina 351 de 1993, la Universidad Santo Tomás informa que “los derechos morales sobre documento son propiedad de los autores, los cuales son irrenunciables, imprescriptibles, inembargables e inalienables.”

Centro de Recursos para el Aprendizaje y la Investigación, CRAI-Biblioteca

Universidad Santo Tomás, Bucaramanga

2018

**Clasificación de gestos de la lengua de señas colombiana a partir del análisis de señales
electromiográficas usando redes neuronales artificiales.**

Elvis Humberto Galvis Serrano

Tesis para optar por el título de Maestría en Redes y Sistemas de Comunicaciones

Director:

Ivan Javier Sánchez Galvis

Codirector

Yudy Natalia Flórez Ordóñez

Universidad Santo Tomás, Bucaramanga

División de Ingenierías y Arquitectura

Maestría en Redes y Sistema de Comunicaciones

2018

Tabla de contenido

	Pág.
Resumen	6
Abstract	7
1. Introducción	8
1.1 Pregunta de Investigación.	12
2 Objetivos	12
2.1 Objetivo general	12
2.2 Objetivos específicos.....	12
3. Estado Del Arte	13
3.1 Reconocimiento de lenguaje de señas por herramientas tecnológicas.....	13
3.1.1Técnicas de visión por computadora.....	15
3.1.2Técnicas empleando sensores	16
3.1.3Técnicas empleando mediciones de señales electromiográficas.....	18
3.2 Herramienta software desarrollada por el grupo UNITEL.....	20
4. Marco Conceptual	23
4.1 Manilla Myo Armband.....	23
4.2 Señales electromiográficas	25
4.3 Transformada Wavelet	26
4.4 Redes neuronales Artificiales RNA	28
4.5 Validación cruzada o cross-validation	29
5. Metodología	31
5.1 Fase 2. Clasificación de los gestos del alfabeto de señas.....	32

CLASIFICACIÓN DE GESTOS LSC USANDO REDES NEURONALES	3
5.1.1Escenario 1	33
5.1.2Escenario 2	34
5.1.3Escenario 3	35
5.1.4Escenario 4	35
5.1.5Escenario 5	36
5.1.6Escenario 6	36
5.2 Fase 3. Evaluación de la reproducibilidad del clasificador	37
6. Resultados y Análisis	39
6.1 Resultados de reproducibilidad del clasificador en cada uno de los escenarios	39
6.2 Resultado de reproducibilidad por letra en el escenario 2	41
7. Conclusiones	45
8. Trabajos futuros	46
9. Divulgación de resultados	47
10. Referencias	48

Lista de Tablas

	Pág.
Tabla 1. <i>Comparación de soluciones existentes [7]</i>	10
Tabla 2. <i>Valores de precisión en cada uno de los escenarios</i>	39
Tabla 3. <i>Valores de precisión en cada de los gestos del Escenario 2</i>	42
Tabla 4. <i>Valores de precisión en cada de los gestos del Escenario 2</i>	43
Tabla 5. <i>Gestos del alfabeto con menor precisión</i>	44

Lista de Figuras

	Pág.
Figura 1. Distribución de la Población sorda según estrato	8
Figura 2. Diagrama del reconocimiento de gestos [15]	16
Figura 3. Módulo de Adquisición	21
Figura 4. Directorio y archivo guardado.	21
Figura 5. Registro de los datos EMG, de la letra E.	21
Figura 6. Módulo de visualización.....	22
Figura 7. Señales de la manilla Myo en tiempo real.	23
Figura 8. Señales IMU emitidas por la manilla Myo.	24
Figura 9. Componentes de la manilla Myo- www.myo.com/start	25
Figura 10. Señal electromiografías normalizadas [32]	26
Figura 11. Red neuronal multicapa	29
Figura 12. Validación cruzada en minería de datos	30
Figura 13. Directorio y archivo guardado.	32
Figura 14. Etapas del módulo de clasificación.....	33
Figura 15. Señales de la letra A, en cada uno de los escenarios.	37
Figura 16. Matriz de confusión del Escenario 2	39
Figura 17. Gesto del alfabeto de Señas Colombiano	42

Resumen

Las Tecnologías de la Información generan espacios de inclusión entre personas sordas y personas oyentes mediante el procesamiento de imágenes o de señales adquiridas por dispositivos como Kinect, Leap Motion, cámaras de video e imágenes, guantes con sensores EMG y/o la Manilla Myo Armband. El presente proyecto de maestría tiene como finalidad clasificar los 27 gestos del alfabeto del lenguaje de señas colombiano a partir del análisis de señales electromiográficas utilizando redes neuronales artificiales. Se ha tomado como base el *know-how* que el grupo de investigación UNITEL de la Facultad de Ingeniería de Telecomunicaciones tiene en cuanto al procesamiento y clasificación de señales EMG. Se utilizó la transformada Wavelet Packet Transform- WPT para construir una matriz de características que permitió crear seis escenarios de entrenamiento la red neuronal para la clasificación de gestos de la lengua de señas colombiana. Los resultados obtenidos fortalecen las investigaciones en esta línea de trabajo dentro del grupo de investigación UNITEL. El valor de precisión obtenido en cada uno de los escenarios usando validación cruzada y matrices de confusión permite medir indirectamente la reproducibilidad del clasificador, pues en cada uno de ellos la data de registros del EMG involucra de manera inter-sujeto los registros de los 13 sujetos. En conclusión, el análisis de señales electromiografías de miembro superior capturadas por la manilla Myo Armband mediante Redes Neuronales permite clasificar los gestos del alfabeto de la lengua de señas colombiano, teniendo en cuenta escenarios inter e intra sujetos.

Palabras claves: Lengua de Señas Colombiana LSC, Matlab, Myo Armband, Redes Neuronales, Validación cruzada, Wavelets.

Abstract

Information Technologies generate inclusion spaces between deaf people and hearing people through the processing of images or signals acquired by devices such as Kinect, Leap Motion, video and image cameras, gloves with EMG sensors and / or the Myo Armband handle. The purpose of this project is to classify the 27 gestures of the Colombian sign language alphabet based on the analysis of electromyographic signals using artificial neural networks. It is based on the know-how that the research group UNITEL of the Faculty of Telecommunications Engineering has regarding the processing and classification of EMG signals. The Wavelet Packet Transform-WPT transform was used to build a matrix of characteristics that allowed creating six training scenarios for the neural network for the classification of gestures of the Colombian sign language. The results obtained strengthen research in this line of work within the UNITEL research group. The accuracy value obtained in each of the scenarios using cross-validation and confusion matrices allows the reproducibility of the classifier to be measured indirectly, since in each of them the EMG record data involves inter-subject records of the 13 subjects. In conclusion, the analysis of upper limb electromyography signals captured by the Myo Armband handle through Neural Networks allows classifying the gestures of the Colombian sign language alphabet, taking into account inter and intra subjects scenarios.

Keywords: Colombian Sign Language; Myo Armband; Neural Networks; Cross Validation; Wavelet.

1. Introducción

La sordomudez, es la imposibilidad que tiene una persona de hablar y de oír. Este síndrome es generalmente ocasionado por la existencia de una sordera congénita o adquirida en los primeros días o meses de vida; a muy temprana edad causa que la persona no pueda reconocer sus propios sonidos y por lo tanto sea incapaz de hablar.[1].

Las personas con este síndrome pueden comprometer seriamente el desarrollo emocional, cognitivo, social y económico. La falta de capacidad de comunicarse fácilmente con las demás personas puede causar situaciones que generen bajo rendimiento escolar, sensación de soledad, aislamientos, frustración, y desempleo.

En Colombia, según el último CENSO poblacional realizado en el 2005, por el Departamento Nacional de Estadística [2]; Colombia posee una población total de 44.549.000 habitantes, de los cuales el 1,02%, equivalente a 455.718 personas, poseen alguna discapacidad auditiva. El 43,80% de estas personas, pertenecen al estrato uno y decrece conforme aumenta el estrato, llegando a un 0.10% de personas discapacidades de visión en el estrato 6. Ver Figura 1




Figura 1. *Distribución de la Población sorda según estrato*

Fuente: <http://www.insor.gov.co/observatorio/estadisticas-basicas-poblacion-sorda-colombiana/>

Por lo tanto, al realizar un análisis de la figura anterior se puede concluir que existe una relación entre el número de personas con discapacidad auditiva y su poder adquisitivo. Esta relación puede estar fundamentada en la prevención de enfermedades auditivas, diagnósticos tempranos, o exposición a trabajos causales de enfermedad sonora, como obreros expuestos a intensidad de ruido muy altos y también puede estar asociado a los elevados costos en los tratamientos etc. Estos elementos describen un problema social considerable en el cual es posible realizar aportes para minimizar los impactos que se pueden generar desde diversos frentes, entre estos el cultural, social, tecnológico, entre otros.

Los avances en las TIC, así mismo con el acceso a estas, ha despertado el interés en la comunidad científica de realizar investigaciones que tengan como propósito el mejoramiento de la calidad de vida de las personas sordas, buscando facilitar la inserción en un contexto de comunicación con personas oyentes. En la literatura se encuentran varios dispositivos que caracterizan gestos de diferentes lenguaje de señas, mediante el procesamiento de imágenes o de señales tales como: el Kinect [3], el Leap motion [4], cámaras de video e imágenes [5] y el brazalete Myo Armband [6]. Este último, es uno de los dispositivos con mayor precisión a la hora de caracterizar gestos del alfabeto de señas de Sri Lankan (Sinhala) Sign Language [7].

Estudios previos señalan que las señales emitidas por la manilla Myo, ha sido caso de estudio en varios países. En Brasil, clasificaron las 20 letras estáticas del alfabeto de señas brasileiro (LIBRAS), por medio de máquinas binarias de soporte vectorial (SVM) [8]. En Indonesia, se implementó un sistema que mejora el rendimiento y la precisión de clasificación del sistema de lengua de señas Indonesia (ISLS), al combinar los datos provenientes del Leap Motion, con los electrodos EMG del brazalete Myo, utilizando como clasificador probabilístico, Naive Bayes. [6]. En Tailandia se registraron 10 gestos del lenguaje de señas tailandés con electrodos

similares a los de la manilla Myo y por medio de un modelo no lineal de redes neuronales se obtuvo una precisión de más del 95% de coincidencia con la salida.[9]. En Sri Lanka, como se menciona anteriormente, se realizó una investigación que compara la exactitud de soluciones basadas en TI como: Kinect con un 90%, Data Glove 80%, Leap Motion del 95% al 98%, procesamiento de imágenes 90%, y dispositivos que combinan EMG con IMU como es el caso de la manilla Myo con un 98% de exactitud.

En la Tabla 1 se presenta una comparación de las tecnologías TIC mencionadas anteriormente referente a la exactitud, movilidad y la conveniencia del usuario. Se observa que las señales electromiografías EMG y las señales de unidad de medición inercial (*Inertial Measurement Unit- IMU*), que son implementadas en la manilla MYO, son las que poseen mayor exactitud a la hora de caracterizar gestos, 98%, razón que motiva aún más la investigación realizada.

Tabla 1. Comparación de soluciones existentes [7]

Device/ Technology	Accuracy (around)	Mobility	User Convenience
Kinect	90%	Not a mobile device	Sign should be performed in front of the device
Data Glove	80%	Most are wired to a computer	Cumbersome device
Leap Motion	95%-98%	Can be attached to a mobile device	Sign should be performed in front of the device
Image Processing	90%	Not a mobile solution	Sign should be performed in front of a camera
EMG & IMU based solutions	98%	Can be enhance as mobile solutions	User should stick the pods or wear the device

El grupo de investigación UNITEL de la Facultad de Ingeniería de Telecomunicaciones de la Universidad Santo Tomás, cuenta con una línea de investigación y experiencia reconocida en el procesamiento de señales e imágenes biomédicas. El presente trabajo de maestría tomó como base el know-how que el grupo UNITEL tiene en el procesamiento de señales EMG. La clasificación de gestos de señas Colombiano se realizó usando el módulo de caracterización de señales EMG de una herramienta software diseñada e implementada en Matlab en el Marco de un Proyecto de Investigación de Convocatoria Interna.

Se empleó la data de registros de señales de EMG del grupo conformada por 13 sujetos con discapacidad: 4 sujetos entre 10 y 20 años, 6 sujetos entre 21 y 40 años y 3 sujetos mayores de 40 años. Los participantes son procedentes de la asociación de sordos de Santander ASORSAN en Bucaramanga y la fundación para la inclusión laboral educativa y social del Magdalena Medio- ILESMAG en Barrancabermeja y han firmado el consentimiento informado para la realización de investigaciones en ésta área.

A diferencia del proyecto realizado previamente por el grupo UNITEL, donde la clasificación de los 27 gestos del alfabeto del lenguaje de señas colombiano se realizó intra-sujeto, es decir analizando los registros de las señales EMG de los 27 gestos emitidas por un mismo sujeto, el presente proyecto de maestría propone clasificar inter-sujeto las 27 gestos del alfabeto de señas a partir de la conformación de matrices de registros de señales de EMG por cada letra provenientes de cada uno de los trece sujetos, permitiendo evaluar la reproducibilidad del clasificador diseñado.

1.1 Pregunta de Investigación.

Como se menciona anteriormente existen varias investigaciones que han empleado diversas tecnologías para caracterizar diversos alfabetos de señas, no obstante, no se tiene conocimiento que exista una investigación específica que haya presentado una aproximación con el alfabeto de señas colombiano. Por tanto, el presente proyecto de maestría tiene como pregunta a resolver ¿El análisis de señales electromiografías de miembro superior capturadas por la manilla Myo Armband mediante Redes Neuronales, pudiese clasificar los gestos del alfabeto de la lengua de señas colombiano?

2 Objetivos

2.1 Objetivo general

- Clasificar gestos del alfabeto del lenguaje de señas colombiano a partir del análisis de señales electromiográficas utilizando redes neuronales artificiales.

2.2 Objetivos específicos

- Elaborar una base de datos con señales electromiográficas adquiridas en el antebrazo de personas con dificultades en el habla usando la manilla Myo Armband con el propósito de entrenar un clasificador de aprendizaje supervisado.
- Diseñar un clasificador de redes neuronales a partir de las características extraídos del procesamiento de señales electromiográficas.

- Evaluar la reproducibilidad del clasificador diseñado utilizando validación cruzada y matrices de confusión para diferentes tipos de usuario.

3. Estado Del Arte

3.1 Reconocimiento de lenguaje de señas por herramientas tecnológicas

Gracias al concepto de tecnología vestible, más conocida como *Wearable*, se están desarrollando diferentes dispositivos electrónicos incorporados en nuestro cuerpo, como prendas de vestir, para realizar funciones concretas como los smartwatches o relojes inteligentes que nos da información de la distancia recorrida, la profundidad del sueño, miden el ritmo cardiaco, controlan el televisor [10] etc, las zapatillas de deportes con GPS, que nos indica los pasos dados, el ritmo cardiaco, en qué posición de una cancha es donde más se mueve el jugador etc, las gafas Google Glass [11] expertas en realidad aumentada, que toman fotos, graban video, integra funciones de GPS, sin utilizar las manos, simplemente implementando comandos de voz; siendo útil en investigación por su procesamiento, tamaño y facilidad de portabilidad, por ejemplo, se estudia para visualizar el ECG y la frecuencia cardíaca cerca del campo de visión de un cirujano que usa las gafas [12], y por último la manilla Myo Armband un pulsera diseñada por la empresa Thalmic Labs que puede controlar diferentes dispositivos de forma inalámbrica, con tan sólo gestos y movimientos.

Esta última detecta la actividad mioeléctrica producidas por los movimientos musculares del antebrazo de una persona, las cuales son enviadas a un PC o teléfono inteligente mediante un módulo bluetooth y dentro del receptor se traducen esas señales a acciones con las que puede

controlar diferentes aplicaciones o dispositivos, como por ejemplo controlar un dron, mover un dispositivo detonador de bombas, controlar luces o la persiana de una casa, mover objetos en aplicaciones de realidad virtual, para el control de la navegación de robots [13], en fin para manipular cualquier dispositivo electrónico basado en computadora.

La gran variedad de aplicaciones en las que se puede implementar la manilla Myo y la facilidad de transmitir el movimiento de los músculos del antebrazo, ha inspirado a la implementación de este dispositivo en el proyecto para facilitar la comunicación entre las personas sordas y las personas oyentes. Según estadísticas de la Organización Mundial de la Salud, cerca de 360 millones de personas en el mundo “padecen de pérdida de la audición discapacitante”; lo que es cercano al 5% de la población actual [1]. Ahora bien, la necesidad de comunicación es algo inherente a la definición del ser humano y, como cita la British Broadcasting Corporation -BBC en su artículo “Las 5 cosas menos conocidas sobre la sordera”; la tecnología ha contribuido en los últimos años a facilitar la interacción de las personas con discapacidad auditiva, ampliando su panorama de estrategias, métodos y herramientas [14]

Es en este sentido, desde el área de Tecnologías de la Información y las Comunicaciones (TIC) se han venido desarrollando innovaciones que contribuyen a facilitar la interacción de estas personas con discapacidad; ya sea con el uso de audífonos, implantes cocleares, integración de TIC en el lenguaje de señas, entre otros. El punto focal del estado de arte consultado está asociado al reconocimiento de lenguaje de señas (ya sea entre personas con discapacidad o entre discapacitados y no discapacitados). Es importante precisar que el lenguaje de señas no es universal, en cada país se encuentran diferencias en símbolos, léxico y gramática; lo que obliga a realizar adaptaciones particulares a las necesidades [14].

Como cita [8] el reconocimiento del lenguaje de señas (SLR- Sign Language Recognition por sus siglas en inglés) apoyado por herramientas tecnológicas; se ha venido desarrollando en tres grandes frentes, basado principalmente en la forma como se adquieren los datos. Estos son:

1. El uso de técnica de visión por computadora, centrada en la adquisición y reconocimiento de patrones en las imágenes (gestos).
2. El uso de guantes especializados con sensores capaces de registrar los movimientos de las manos y los dedos.
3. El uso de mediciones de señales electromiográficas (EMG) para proveer características de clasificación.

3.1.1 Técnicas de visión por computadora

En cuanto al sistema de reconocimiento de lenguaje de señas basado en visión por computadora, es posible relacionar la identificación de los gestos de la mano, comúnmente encontrados en la literatura con el acrónimo (*Hand Gesture Recognition- HGR*). Como se cita en [15], las técnicas asociadas al HGR se centran en dos posibles tipos:

- Basadas en las características observables, se basa en las relaciones temporales, tanto de gestos estáticos como dinámicos. Estos se caracterizan por:
 - Gestos estáticos (postura de las manos/poses): Caracterizados por la orientación, la forma, ángulos de flexión de los dedos, la posición relativa al cuerpo y el contexto ambiental.
 - Gestos dinámicos (gestos de las manos): Orientación, forma, ángulos de flexión de los dedos, posición/trayectoria, velocidad de movimiento, dirección de movimiento y escala.

- Basadas en la interpretación, se encuentra aquellos relacionados con emblemas (p.e. el dedo arriba indicando que todo está bien), ilustraciones (usar un dedo para indicar una dirección), reguladores (levantar y agitar la mano para solicitar un turno), entre otros.

3.1.2 Técnicas empleando sensores

El reconocimiento de gestos de la mano se puede analizar revisando la Figura 2; donde se identifica la herramienta de medición o registro (sensor), un proceso de extracción de características, la clasificación y la identificación (etiquetado).




Figura 2. Diagrama del reconocimiento de gestos [15]

En cuanto a sensores, el trabajo presentado en [16] detallan ampliamente cuales y en qué consisten (específicamente aplicados al reconocimiento de gestos). A continuación, se resaltan algunos de estos: (1) Basados en estímulos eléctricos como las *touch-screen*, (2) basados en estímulos ópticos como las cámaras digitales y sistemas que integran conjuntos de estas (p.e.: sistemas de estéreo visión para 3D), (3) Basados en escaneo como los sistemas que emplean radar o laser, (4) Basados en sistemas acústicos, como sensores de ondas ultrasónicas, sistemas de triangulación, entre otros.

A continuación, se presenta el panorama de técnicas y herramientas utilizadas para llevar a cabo cada uno de los reconocimientos (gestos y posturas).

- Modelo Oculto de Markov (*Hidden Markov Model- HMM*): Esta es la técnica más utilizada para llevar a cabo funciones de HGR. Consiste es un modelo estadístico en el cual el sistema es modelado y asumido como un proceso de Markov con parámetros desconocidos. Esta técnica puede ser utilizado para reconocimiento de patrones dado que los parámetros ocultos son identificados usando datos observables. Para desarrollarlo se utilizan características temporales y espaciales de las imágenes. Por ejemplo [17] recurre a un descriptor de Fourier y el análisis de desplazamiento para caracterizar especial/temporalmente las imágenes. El algoritmo extrae la forma de la mano y la procesa. Complementando lo anterior, [18] dispone un modelo extendido; recurriendo al IOHMM (Input/Out Hidden Markov Model). La literatura considera esta aproximación discriminativa. [19], por su parte, presenta un modelo de localización de gestos recurriendo al uso de ángulos de movimiento a lo largo de la trayectoria de la mano. Experiencias complementarias son mostradas en [20] y [21].

Experiencias más recientes son presentada por ejemplo en el trabajo de [22], quienes recurren al diseño sistema de reconocimiento de gestos para sordos, utilizando un marco de trabajo basado en modelos modificados del HMM y la herramienta Kinect de Microsoft. El framework que proponen en este trabajo presenta las estrategias de extracción, modelamiento y reconocimiento de patrones; integrándose con la técnica PCA.

Finalmente, [23] presenta una solución que mezcla los HMM con la observación de estados Gaussianos, con lo que se logra clasificar 15 signos dinámicos del lenguaje de señas Persa. Los autores de esta experiencia citan más del 98% de tasa de reconocimiento.

- Redes neuronales artificiales y otros métodos basados en aprendizaje. El trabajo desarrollado en [24] utiliza una red neuronal artificial con retardo (TDNN) para el aprendizaje de trayectorias

de movimiento en 2-D. La clasificación en TDNN es dinámica y permite realizar una serie de decisiones locales. Este es un buen antecedente al desarrollo de esta línea.

Otras técnicas se asocian a métodos basados en eigen-espacios, ajustes de curvas, entre otros. De otra parte, la adquisición asociada a guantes con sensores también se encuentra documentada en la literatura. Por ejemplo la experiencias realizada por (Zhang LG, Chen Y, Fang G, Chen X, Gao W, 2004) y (Lokhande P, 2015); citadas por [25] ilustran el uso (o combinación) de esta tecnología basadas en sensores de deflexión, acelerómetros y otros sensores de propósito específico, para realizar el registro de los movimientos de manos y dedos. Otra experiencia en esta línea de registro de los movimientos se presenta en [26].

3.1.3 Técnicas empleando mediciones de señales electromiográficas

Particularmente sobre el uso de la herramienta Myo Armband en el reconocimiento de patrones para el lenguaje de señas existen en la literatura, varias aproximaciones que se han considerado en esta revisión. Una de estas es la presentada en [8], quienes recurren a los conceptos de Machine Learning y la caracterización de las señales EMG, para caracterizar y clasificar letras (particularmente del alfabeto de señas brasileiro – LIBRAS). Se logra evidenciar en los resultados presentados que se requiere profundizar sobre las letras que contienen movimiento, revisando no solo las señales EMG sino también los IMU propios de la manilla Myo.

En esta misma línea, [27], presentan una experiencia basada en la herramienta Myo, para clasificar gestos en tiempo real usando los sensores EMG. Esa investigación tiene como trabajo proyectado el aplicar este hardware al control de manos robóticas de precisión. La experiencia

recurrió al uso de Máquinas de Soporte Vectorial (SVM) con el apoyo de la función Round-based kernel (RBF).

En estados unidos se desarrolló un sistema de reconocimiento de signos SLR (Sign Language Recognition) para clasificar un conjunto de 50 palabras comunes del lenguaje de signo americano ASL (American Sign Language), con las señales de electromiografía y del acelerómetro que transmite la manilla Myo. En este estudio se utilizó como clasificador, máquinas de soporte vectorial SVM (Support Vector Machine) [28] .

En términos generales, existen avances en la literatura sobre el reconocimiento de patrones, movimiento, señales mioeléctrica, entre otros; para apoyar la interacción de las personas con discapacidad auditiva o sordera. En este panorama se encuentran plataformas tecnológicas como cámaras especializadas, Microsoft Kinect, Leap Motion, Myo Armband, guantes con sensores, entre muchos otros; que facilitan el registro para futuro procesamiento, clasificación e identificación de patrones, que finalmente permitan facilitar el reconocimiento del lenguaje de señas facilitando el dialogo entre hablantes y personas con discapacidad.

La información presentada fue consultada en diferentes bases de datos científicas como: IEEE, Scopus, Science Direct, google Scholar etc, sobre proyectos de investigación que implementan dispositivos tecnológicos como: Kinect, Leap Motion, guantes, Cámaras, y el dispositivo Myo Armband, para mejorar la comunicación entre personas sordas y personas oyentes.

3.2 Herramienta software desarrollada por el grupo UNITEL

La herramienta software empleada fue diseñada y desarrollada en Matlab, está compuesta de cuatro módulos: 1) Módulo de adquisición, 2) Módulo de visualización, 3) Módulo de caracterización y 4) Módulo de traducción

Módulo de adquisición

Este módulo permite capturar las señales EMG que se generan al realizar con la manilla Myo cada una de los gestos del alfabeto de señas colombiano permitiendo también registrar los datos de la persona a quien se le realiza la toma de datos. En la figura 3 se observa la interfaz principal del módulo, para iniciar el registro de las señales se debe diligenciar inicialmente los datos de nombre, sexo, mano que se utiliza para la realización del alfabeto de señas, edad, letra a realizar y el tiempo en segundos que durará el registro de las señales por cada letra. Una vez diligenciado estos datos, se procede a pulsar el botón INICIAR, y de forma automática el módulo graba durante el tiempo establecido, todas las señales que emite la manilla Myo y los datos de la persona quien realizó la toma del registro.

Las señales registradas son almacenadas en carpetas en el directorio predeterminado >REGISTRO_PACIENTES> NOMBRE. Para nombrar cada archivo se utilizó la siguiente estructura: tres primeras letras del nombre de la persona que realizó el registro, la letra registrada, la fecha de la toma del registro, seguido de la extensión. mat. ejemplo VAL_E_18-Nov-2017.mat. En la figura 4 se observa un ejemplo del nombre del archivo guardado y el directorio donde se guardó el archivo.



Figura 3. Módulo de Adquisición




Figura 4. Directorio y archivo guardado.

En la figura 5 se presentan los primeros datos registrados de las señales de los ocho sensores electromiografos, cuando se realizó el movimiento de la letra E. Cada columna representa los datos registrados de cada uno de los ocho sensores EMG.

```
K>> a.emg_log(1:20,:)
ans =
    0    0.0078   -0.0156   -0.0078    0    0   -0.0078    0
    0   -0.0156    0    0   -0.0156   -0.0156    0   -0.0078
    0.0078    0    0.0078    0    0   -0.0078    0   -0.0078
   -0.0078   -0.0078    0.0078    0   -0.0078    0    0.0078    0
   -0.0156   -0.0156   -0.0234    0   -0.0156    0.0156   -0.0078   -0.0078
   -0.0078    0    0    0    0   -0.0234   -0.0078   -0.0078
   -0.0156    0   -0.0156   -0.0078    0    0    0   -0.0078
   -0.0156   -0.0078    0.0078    0    0   -0.0156   -0.0156   -0.0078
    0    0   -0.0078   -0.0078    0.0156   -0.0156    0    0
    0.0078   -0.0078   -0.0078    0   -0.0078   -0.0078    0    0.0078
   -0.0078   -0.0156   -0.0078   -0.0156   -0.0078   -0.0078    0.0078   -0.0156
    0    0   -0.0156    0    0    0    0    0   -0.0156
   -0.0156   -0.0156    0    0   -0.0078   -0.0078   -0.0078    0.0078
    0    0   -0.0078   -0.0156   -0.0078    0.0078    0   -0.0156
    0.0078    0.0078   -0.0078    0   -0.0078    0.0078   -0.0078    0.0078
    0   -0.0078   -0.0078    0   -0.0156    0    0.0078   -0.0078
   -0.0078   -0.0156    0    0    0    0    0.0156   -0.0156
    0   -0.0078    0   -0.0156    0   -0.0156   -0.0078    0
   -0.0234   -0.0078    0.0078    0    0    0    0.0078   -0.0078
```

Figura 5. Registro de los datos EMG, de la letra E.

Módulo de visualización de señales

Este módulo permite visualizar como su nombre lo indica, las señales de EMG adquiridas y almacenadas previamente en el archivo. mat, también se visualizan las señales del giroscopio, acelerómetro, de orientación registradas por la manilla Myo, se visualiza también una señal promedio (resultante del promedio de las 8 señales del EMG), y los datos del sujeto. Si bien en este proyecto solo se emplean las 8 señales del EMG, se ha realizado la adquisición de estas señales para futuras investigaciones.

El módulo inicia seleccionando el archivo. mat a través del menú Archivo (flecha roja), una vez es cargado el archivo. mat los datos son visualizados en la interfaz. La interfaz cuenta adicionalmente con los botones “+” y “-” utilizados para aumentar o disminuir el número de muestras a visualizar. En figura 6 se presenta los registros tomados en una de las personas colaboradoras mientras realizaba la letra V.




Figura 6. Módulo de visualización

Módulo de caracterización

El módulo de caracterización emplea la transformada Wavelet (Wavelet Packet Transform-WPT) para la extracción de características y redes neuronales para la clasificación de las señales. En el apartado de metodología se describirá más detalladamente.

Módulo de traducción

El módulo de traducción permite que la persona una vez ubique el dispositivo Myo Armband en su antebrazo y realice cualquier letra del alfabeto de señas, de manera automática se visualice en la interfaz la letra del alfabeto de señas colombianas que acaba de realizar (Figura 7). Es importante resaltar que en el proyecto se entrenó una red neuronal por cada uno de las 13 personas a las cuales se les realizó el registro de señales de EMG por cada letra del alfabeto.




Figura 7. Señales de la manilla Myo en tiempo real.

4. Marco Conceptual

4.1 Manilla Myo Armband

La manilla Myo Armband, es un brazalete diseñado por la compañía Thalmic Labs acaba, en su página web <https://www.myo.com/>, se encuentra información acerca de su uso, aplicaciones, tutorial y demás. A manera general la manilla Myo transmite por Bluetooth, señales de giroscopio, acelerómetro, orientación y ocho señales electromiográficas, generadas

por la contracción muscular, las cuales pueden ser procesadas y clasificadas para identificar el tipo de gesto realizado. Estas señales EMG son adquiridas a una frecuencia de muestreo de 200 Hz, es decir, que se obtienen 200 muestras por segundo de adquisición mientras que las señales IMU (inertial measurement unit) son muestras a 50 Hz.

La Myo cuenta con la Unidad de Medición Inercial (IMU), del inglés *inertial measurement unit*, es un dispositivo electrónico que mide e informa acerca de la velocidad, orientación y fuerzas gravitacionales de un aparato, usando una combinación de acelerómetros y giróscopos.




Figura 8. Señales IMU emitidas por la manilla Myo.

Fuente: <http://diagnostics.myo.com/>

La manilla Myo Armband cuenta con su cable de conexión USB, un adaptador Bluetooth, Clips que permiten la sujeción al antebrazo de una persona, y una tarjeta con la página web en donde se puede descargar la respectiva aplicación para su funcionamiento (Figura 9).



Figura 9. Componentes de la manilla Myo- www.myo.com/start

Adicionalmente al hardware se requiere de diversos softwares para el uso adecuado de la manilla Myo Armband

- **Myo Connect:** Es el software controlador de la manilla Myo Armband, necesario para recibir e interpretar las señales electromiográficas y a su vez para gestionar las aplicaciones que se deben instalar para la manipulación de ciertos programas como el Vlc, Media player, el mouse, diapositivas de PowerPoint entre muchos.
- **MyoSDK:** Es un conjunto de herramientas de desarrollo de software que permite a los desarrolladores, crear aplicaciones que incorporen la manilla Myo.
- **Myo SDK MATLAB MEX Wrapper:** Es un conjunto de librerías .m que permite acceder a los datos transmitidos por la manilla Myo y poder realizar postproceso de señal, desde Matlab.

4.2 Señales electromiográficas

Las señales electromiográficas (EMG) son datos o señales eléctricas que muestran el comportamiento del sistema biológico muscular que compone el cuerpo humano, son señales eléctricas producidas por un músculo durante el proceso de contracción y relajación [29]. Esta señal provee información en tiempo y en frecuencia acerca de la actividad neuromuscular

presente en el músculo activo correspondiente a la suma de la actividad de un número mayor de unidades motoras más pequeñas denominadas unidades motoras [30]. De otra forma, se ha podido evidenciar que la señal EMG tiene una amplitud típica entre 0 y 6mV, y la frecuencia útil está en el rango de 0 a 500Hz con la mayor cantidad de energía concentrada entre los 50 y los 150Hz [31]. Las señales EMG es una señal compleja, la cual e ve afectada por las propiedades anatómicas y fisiológicas del músculo, el control del sistema nervioso periférico, así como también las características de la instrumentación que se usa para la detección y la observación.




Figura 10. Señal electromiográfías normalizadas [32]

4.3 Transformada Wavelet

Conocida en español como transformada ondícula, es una representación matemática de una señal en términos de versiones trasladadas y dilatadas de una onda finita, utilizada para el procesamiento y análisis de señales. Provee más información que la transformada de Fourier en las señales no estacionarias, debido a la capacidad de descomposición simultánea en el dominio del tiempo y de la frecuencia (o más propiamente de una "escala"). La transformada Wavelet de una función $f(t)$ se reconoce como la descomposición de dicha señal en un conjunto de

funciones $\Psi_{S,T}(t)$, las cuales conforman una base denominadas wavelets. La descripción de estas señales se muestra en la ecuación 1, fundamentado en lo citado en [33].

$$W_f(s, \tau) = \int f(t) \Psi_{s,\tau}^*(t) dt \quad (1)$$

Este tipo de señales (wavelets) son producidas a partir del desplazamiento y escalamiento de una función base, denominada *Wavelet madre*, la cual es presentada en la ecuación 2 (s es el factor de escalamiento y τ factor de desplazamiento en tiempo).

$$\Psi_{s,\tau}^*(t) = \frac{1}{\sqrt{s}} \Psi\left(\frac{t-\tau}{s}\right) \quad (2)$$

La teoría de wavelets, comprende: la definición de wavelet como una familia de funciones finitas, la Transformada Wavelet Continua (CoWT), la Transformada Wavelet Discreta (DWT), la Transformada Wavelet Discreta Estacionaria (SWT) y la Transformada Wavelet Compleja (CWT). Si bien la DWT, es una herramienta poderosa para algunas aplicaciones de procesamiento de señales, presenta algunos inconvenientes, tales como: Sensibilidad al corrimiento, es poco direccionable y no contiene información sobre la fase. Con la finalidad de resolver estas limitaciones, se han desarrollado extensiones de la versión estándar de la DWT tales como, la Transformada Wavelet de Paquetes (WPT) y la Transformada Wavelet Estacionaria (SWT) [34].

En el presente trabajo se aplicó la Transformada Wavelet de Paquetes empleando la Multiscale Wavelet Packet propuesto por [35] R. N. Khushaba disponible en la toolbox de Matlab.

4.4 Redes neuronales Artificiales RNA

Las redes neuronales son técnicas de aprendizaje de máquina que por medio de modificación iterativas de la fuerza de interconexión de neuronas se puede relacionar las entradas con las salidas deseadas de un sistema. Existen dos enfoques, el aprendizaje supervisado y el no supervisado. En el primero se entrena un modelo para generar predicciones de una respuesta a partir de un conjunto de datos de entrada etiquetados. Por su parte, en el aprendizaje no supervisado, se busca clasificar un conjunto de datos a partir de similitudes entre estos, pero sin información de etiquetación.

Las redes neuronales se utilizan para reconocer patrones, incluyendo imágenes, manuscritos y secuencias de tiempo. Tienen la capacidad de aprender y mejorar su funcionamiento. En la Figura se presenta una estructura de red multicapa, en donde la capa de entrada es la 0 y tiene m_0 neuronas. La capa de salida es la capa L -ésima y tiene m_L neuronas, por lo tanto, se puede afirmar que la red tiene L capas [36]. En el presente trabajo se utilizó la técnica de Redes Neuronales de aprendizaje supervisado porque permite etiquetar a qué clase corresponde cada uno de los datos de entrada.




Figura 11. Red neuronal multicapa

Fuente: www.um.edu.ar/ojs-new/index.php/RUM/article/download/22/24

4.5 Validación cruzada o cross-validation

Es una técnica utilizada en proyectos de inteligencia artificial para validar modelos. Evalúa los resultados de un análisis estadístico y garantiza la independencia entre los datos de entrenamiento y los datos de prueba. Consiste en repetir y calcular la media aritmética obtenida de las medidas de evaluación sobre diferentes particiones. Se utiliza en entornos donde el objetivo principal es la predicción y se quiere estimar la precisión de un modelo que se llevará a cabo a la práctica [37].

La Figura 12 muestra gráficamente un ejemplo del proceso de validación cruzada para determinar la validez de un modelo de minería de datos [38] con $N=5$ folds. Los datos fueron separados en 5 subconjuntos de tamaño aproximadamente iguales, de los cuales $N-1$, ósea 4 son utilizados para el entrenamiento del modelo y el restante para validación. Esto se repite N veces, 5, pero variando los datos pertenecientes a cada grupo.



Figura 12. Validación cruzada en minería de datos

Fuente: Análisis de minería de datos distribuida [38]

Matrix de confusión: Es una herramienta que permite la visualización del desempeño de un algoritmo que se emplea en aprendizaje supervisado, que sirve para observar si el sistema está confundiendo dos o más gestos. Las columnas de la matriz representan el número de predicciones de cada una de las letras del alfabeto de señas colombiano, mientras que cada fila representa a las instancias en la letra real.

5. Metodología

El presente proyecto se desarrolló en tres fases principales: (a) Organización de la data de registros de señales electromiográficas. La data estaba conformada por 13 sujetos con discapacidad: 4 sujetos entre 10 y 20 años, 6 sujetos entre 21 y 40 años y 3 sujetos mayores de 40 años. (b) Clasificación de los gestos del alfabeto de señas empleando la Wavelet Packet Transform y redes Neuronales. Para esto se empleó la herramienta software diseñado e implementado en Matlab en el Marco de un proyecto de Investigación de Convocatoria Interna y se definieron seis escenarios de clasificación. (c) Evaluación de la reproducibilidad del método de clasificación utilizando la técnica de validación cruzada y matrices de confusión.

Fase 1. Organización de la data de registros de señales electromiográficas

La data de registros de los 13 sujetos fue organizada con el propósito de armar 27 matrices de señales de EMG, cada matriz representa un mismo gesto del alfabeto de señas Colombiano capturado de los 13 sujetos (es decir, se tiene la matriz de la A, la matriz de la B, etc). Es importante resaltar que los registros empleados en la investigación previa estaban organizados por sujeto y no por gesto del alfabeto de señas.

Las señales registradas se organizaron en carpetas en el directorio predeterminado para cada letra, ejemplo > \LETRAS_REGISTRADAS\LETRA_A. Para nombrar cada archivo se utilizó la siguiente estructura: La letra registrada, la fecha de la toma del registro y el nombre de la persona, seguido de la extensión.mat. ejemplo A_18-Nov-2017_JONNATAN ALVAREZ CASTAÑO.mat (Ver Figura 13)

MAESTRIA > PROYECTO > MATLAB Y MYO ARMBAND > LETRAS_REGISTRADAS > LETRA_A

Nombre	Fecha de modificación	Tipo	Tamaño
A_11-Nov-2017_DANNY GRAZZIANI	11/11/2017 12:05 p. m.	Microsoft Access ...	49 KB
A_11-Nov-2017_IRUBEN	11/11/2017 10:58 a. m.	Microsoft Access ...	54 KB
A_11-Nov-2017_LAURA TATIANA DELGA	11/11/2017 11:54 a. m.	Microsoft Access ...	49 KB
A_18-Nov-2017_CARLOS FELIPE MENDEZ...	18/11/2017 11:46 a. m.	Microsoft Access ...	54 KB
A_18-Nov-2017_JAIR SANCHEZ ESMERAL	18/11/2017 11:36 a. m.	Microsoft Access ...	62 KB
A_18-Nov-2017_JONNATAN ALVAREZ CA...	18/11/2017 12:25 p. m.	Microsoft Access ...	3 KB
A_18-Nov-2017_RAFael ANTONIO URREA	18/11/2017 11:57 a. m.	Microsoft Access ...	53 KB
A_18-Nov-2017_VALDIIR DE JESUS VERGA...	18/11/2017 12:33 p. m.	Microsoft Access ...	50 KB

Figura 13. Directorio y archivo guardado.

5.1 Fase 2. Clasificación de los gestos del alfabeto de señas

La clasificación de los gestos del alfabeto de señas se realiza empleando el módulo de caracterización de la herramienta software descrita previamente. En el presente trabajo de maestría se plantearon **seis escenarios de configuración** de entrenamiento del clasificador. Antes de presentar los escenarios se describe a manera general el funcionamiento del módulo en la figura 14.

La entrada al módulo de clasificación es la data de registro de señales electromiográficas adquiridas de los 13 sujetos al realizar cada uno de 27 gestos del alfabeto, esa data es organizada en matrices, una matriz por cada letra. Inicialmente se utiliza la transformada Wavelet Packet Transform- WPT, para extraer las características del registro de señales. Como salida de la WPT se obtiene la matriz de características (Figura 14A). Posteriormente las matrices de características, se apilan conformando una única matriz X. Finalmente se crea una matriz T del mismo tamaño de la matriz de características X, compuestas con unos y ceros, que sirve para identificar a que gesto pertenece cada fila de características (Figura 14B).

Luego de obtener las matrices de características, se entrenó la red neuronal supervisada utilizando la Toolbox de Matlab. La entrada y salida a la red neuronal corresponden a las

matrices transpuestas de características X' y de unos y ceros T' generadas a la salida del proceso de la WPT. Al finalizar, se obtiene los parámetros de red entrenada (Figura 14C).




Figura 14. Etapas del módulo de clasificación

5.1.1 Escenario 1

Características de la data de registros de entrada

Los registros de las señales EMG, son organizados en 27 matrices, una por cada letra del alfabeto de señas Colombiano. Para construir cada una de las 27 matrices se almacenaron las 8 señales de EMG obtenidas de cada paciente de manera apilada en la dirección vertical, obteniendo por cada letra una matriz de alrededor de 12000 muestras por 8 señales EMG.

Parámetros de la Wavelet

Se utilizó una Wavelet de 40 muestras por ventana, desplazamiento de la ventana de 10 muestras y nivel de descomposición de la función Multiscale Wavelet Packet igual a 4.

Red Neuronal

Se entrenó la red neuronal supervisada utilizando la Toolbox de Matlab, con un perceptrón de 40 neuronas en la capa oculta.

5.1.2 Escenario 2

Características de la data de registros de entrada

Igual que el escenario 1

Parámetros de la Wavelet

Se utilizó una Wavelet de 500 muestras por ventana, desplazamiento de la ventana de 50 muestras y nivel de descomposición de la función Multiscale Wavelet Packet igual a 4.

Red Neuronal

Se entrenó la red neuronal supervisada utilizando la Toolbox de Matlab, con un perceptrón de 80 neuronas en la capa oculta.

5.1.3 Escenario 3

Características de la data de registros de entrada

Los registros de las señales EMG, son organizados en 27 matrices, una por cada letra del alfabeto de señas colombiano. Para construir cada una de las 27 matrices se promediaron las 8 señales EMG de cada letra. Para realizar el promedio se tomaron, por letra, todas las señales EMG 1 de todos los sujetos y se promediaron, luego todas las señales EMG2, hasta finalizar las señales EMG 8, obteniendo una matriz de 900 filas en promedio por 8 columnas

Parámetros de la Wavelet

Se utilizó una Wavelet de 40 muestras por ventana, desplazamiento de la ventana de 10 muestras y nivel de descomposición de la función Multiscale Wavelet Packet igual a 4.

Red Neuronal

Se entrenó la red neuronal supervisada utilizando la Toolbox de Matlab, con un perceptrón de 40 neuronas en la capa oculta.

5.1.4 Escenario 4

Características de la data de registros de entrada

Escenario 3

Parámetros de la Wavelet

Se utilizó una Wavelet de 500 muestras por ventana, desplazamiento de la ventana de 50 muestras y nivel de descomposición de la función Multiscale Wavelet Packet igual a 4.

Red Neuronal

Se entrenó la red neuronal supervisada utilizando la Toolbox de Matlab, con un perceptrón de 80 neuronas en la capa oculta.

5.1.5 Escenario 5

Características de la data de registros de entrada

Los registros de las señales EMG, son organizados en 27 matrices, una por cada letra del alfabeto de señas Colombiano. Para construir cada una de las 27 matrices se promediaron las 8 señales EMG de cada letra. En este escenario se promediaron las 8 señales EMG de cada paciente, obteniendo una matriz de 12000 filas por 1 columnas

Parámetros de la Wavelet

Se utilizó una Wavelet de 40 muestras por ventana, desplazamiento de la ventana de 10 muestras y nivel de descomposición de la función Multiscale Wavelet Packet igual a 4.

Red Neuronal

Se entrenó la red neuronal supervisada utilizando la Toolbox de Matlab, con un perceptrón de 40 neuronas en la capa oculta.

5.1.6 Escenario 6

Características de la data de registros de entrada

Escenario 5

Parámetros de la Wavelet

Se utilizó una Wavelet de 500 muestras por ventana, desplazamiento de la ventana de 50 muestras y nivel de descomposición de la función Multiscale Wavelet Packet igual a 4.

Red Neuronal

Se entrenó la red neuronal supervisada utilizando la Toolbox de Matlab, con un perceptrón de 80 neuronas en la capa oculta.

En la Figura 15, se muestra los registros de las señales EMG de la letra A en cada uno de los diferentes escenarios plateados.




Figura 15. Señales de la letra A, en cada uno de los escenarios.

5.2 Fase 3. Evaluación de la reproducibilidad del clasificador

Para evaluar la reproducibilidad del clasificador se utilizó la técnica de validación cruzada y la matriz de confusión para calcular el valor de precisión.

La validación cruzada es una técnica ampliamente utilizada en proyectos de inteligencia artificial, y sirve para evaluar los resultados de análisis estadísticos y garantizar la independencia entre datos de entrenamiento y prueba de modelos generados. Es utilizada en proyectos en donde se quiere estimar la precisión de un modelo que se llevará a cabo a la práctica [39]. En el proyecto, se empleó la función *crossvalind* de Matlab, con un factor de iteración de "k=10" (k-fold cross validation), siendo este el factor más empleado en la literatura [40,41]. La red neuronal fue entrenada con el 90% de las muestras de la matriz transpuestas de características X' y supervisada con la matriz transpuesta de unos y ceros T' generadas a la salida del proceso de la Wavelet (Figura 14C). El 10% de las muestras restantes fueron empleadas para la validación. Esto se realiza 10 veces, para cada iteración de k, con distintas muestras de entrenamiento y validación.

En cada uno de los seis escenarios se calculó el valor de precisión por iteración empleando la matriz de confusión. La matriz de confusión que permite analizar y cualitativa y cuantitativamente el desempeño de un algoritmo que se emplea en aprendizaje supervisado, permite observar si el sistema está confundiendo dos o más gestos. En la Figura 15A, se observa la matriz de confusión de la iteración 1 para el escenario 2. Tanto las filas como las columnas representan los 27 gestos del alfabeto de señas. En la figura 15B se detalla una extracción de la matriz de confusión, el número superior representa el número de aciertos y el porcentaje respecto a la totalidad de los datos evaluados. Las casillas en verde son aciertos y las casillas naranjas son confusión. En la figura 15C la fila y columna gris representan el porcentaje de acierto (letra verde) y el porcentaje de error (letra roja) por cada letra, la casilla azul representa el porcentaje total de acierto y error.




Figura 16. Matriz de confusión del Escenario 2

6. Resultados y Análisis

6.1 Resultados de reproducibilidad del clasificador en cada uno de los escenarios

La Tabla 2 presenta el valor de precisión obtenido en cada una de las 10 iteraciones y el valor promedio total de las 10 iteraciones. El valor obtenido en cada uno de los escenarios permite medir indirectamente la reproducibilidad del clasificador, pues en cada de ellos la data de registros del EMG involucra de manera inter-sujeto los registros de los 13 sujetos.

Tabla 2. Valores de precisión en cada uno de los escenarios

Escenario 1		Escenario 2		Escenario 3	
k=10		k=10		k=10	
iteración 1	8,8141	iteración 1	83,5294	iteración 1	21,327
iteración 2	15,2	iteración 2	86,7227	iteración 2	20,8531
iteración 3	9,61	iteración 3	83,6975	iteración 3	22,2749
iteración 4	12,33	iteración 4	84,8739	iteración 4	21,327
iteración 5	15,22	iteración 5	85,7143	iteración 5	23,2227
iteración 6	18,26	iteración 6	83,6975	iteración 6	29,8578
iteración 7	12,5	iteración 7	85,5462	iteración 7	21,8009

Tabla 2. (Continuación)

iteración 8	13,6	iteración 8	86,8687	iteración 8	24,1706
iteración 9	14,88	iteración 9	88,0471	iteración 9	23,8095
iteración 10	17,12	iteración 10	86,8908	iteración 10	28,91
PROMEDIO	13,75	PROMEDIO	85,55881	PROMEDIO	23,75535
Escenario 4		Escenario 5		Escenario 6	
k=10		k=10		k=10	
					8,81
iteración 1	68,42	iteración 1	7,77	iteración 1	15,2
iteración 2	88,88	iteración 2	7,77	iteración 2	9,61
iteración 3	63,15	iteración 3	8,02	iteración 3	12,33
iteración 4	66,66	iteración 4	7,43	iteración 4	15,22
iteración 5	78,94	iteración 5	7,87	iteración 5	18,26
iteración 6	63,15	iteración 6	8,17	iteración 6	12,5
iteración 7	68,42	iteración 7	6,66	iteración 7	13,6
iteración 8	78,94	iteración 8	8,02	iteración 8	14,88
iteración 9	66,66	iteración 9	8,64	iteración 9	17,12
iteración 10	77,77	iteración 10	6,48	iteración 10	13,75
PROMEDIO	72,10	PROMEDIO	7,68	PROMEDIO	8,81

En el proyecto de investigación realizado por el grupo de Investigación se obtuvo un valor de reproducibilidad del clasificador intra-sujeto de 88.38%. Los parámetros de configuración de la WPT y la red neuronal fueron de 40 muestras por ventana, desplazamiento de la ventana de 10 muestras, nivel de descomposición de la función Multiscale Wavelet Packet igual a 4, y se entrenó la red neuronal supervisada utilizando un perceptrón de 40 neuronas en la capa oculta. Este framework de configuración fue utilizado en los Escenarios 1, 3 y 5. El valor de precisión es comparado y analizado frente a los resultados obtenidos en los escenarios planteados en el presente proyecto.

Los escenarios 1, 3 y 5 presentan una precisión promedio de 13.75%, 23.75% y 7.68 %, respectivamente. Estos valores de precisión están muy por debajo del valor de precisión de 88.38%. Estos resultados pueden ser atribuido al tamaño de muestras de las señales EMG empleadas en el presente proyecto y la configuración de las matrices de entrada. El escenario 3

debiese tener un valor de precisión similar al obtenido en el proyecto de investigación, sin embargo, su valor bajo de 23,75% pudo ser atribuido a la manera de realizar el promediado de señales de EMG, en este escenario se promediaron las señales EMG1 de los 13 sujetos, hasta la EMG 8 de todos los sujetos, no es posible asegurar que en los trece sujetos la posición de la manilla se realizará en la misma posición del antebrazo.

En los escenarios 2, 4 y 6, se modificó el framework de configuración de la WPT y de la red neural. Se utilizó una Wavelet de 500 muestras por ventana, desplazamiento de la ventana de 50 muestras, nivel de descomposición de la función Multiscale Wavelet Packet igual a 4 y se entrenó la red neuronal supervisada con un perceptrón de 80 neuronas en la capa oculta. Los valores de precisión en estos escenarios fueron de 85,55%, 72,10% y 8,81%, respectivamente. Los resultados de los escenarios 2 y 4 están muy cerca al valor de 88.38% obtenido en el proyecto de investigación, no obstante, en el escenario 6 no mejoró el valor de precisión, este puede ser atribuido a la configuración realizada de la matriz de registros de entrada, el tamaño de esta era de 1 columna por 12.000 filas.

6.2 Resultado de reproducibilidad por gestos en el escenario 2

La Tabla 3 clasifica cada una de los gestos del alfabeto de Señas Colombiano en un rango de precisión, según el valor obtenido. Estos datos son extraídos de la iteración 1 del escenario 2. En la Figura 17 se presenta el alfabeto de señas colombiano.




Figura 17. Gesto del alfabeto de Señas Colombiano

Fuente: <http://planpilodeaccesibilidad.blogspot.com/2008/05/alfabeto-dactilolgico-colombiano.html>

Tabla 3. Valores de precisión en cada de los gestos del Escenario 2


% DE PRECISIÓN	GESTOS
=100%	
>90%	    
80-90	         

Tabla 3. (Continuación)

70-80	       
60-70	   

La tabla 4 presenta la precisión obtenida por los gestos que presentan algún tipo de flexión-movimiento al realizar el gesto.

Tabla 4. Valores de precisión en cada de los gestos del Escenario 2

% DE PRECISIÓN	GESTOS
92,3%	
92,6%	
78,3%	
94,1%	
81,3%	

La Tabla 5 presenta los gestos con menor valor de precisión. Se presenta el gesto, el valor de precisión y los gestos y el número de confusiones con las que presentó el error.

Tabla 5. Gestos del alfabeto con menor precisión

GESTOS	% DE PRECISIÓN												
I 	66,7%	G 	2	P 	2	H 	1	J 	1	S 	1	T 	1
X 	67,9%	R 	5	G 	1	O 	1	S 	1	O 	1		
T 	68,4%	X 	3	I 	1	J 	1	K 	1				
F 	72,0%	S 	3	B 	1	C 	1	N 	1	V 	1		

7. Conclusiones

El análisis de señales electromiografías de miembro superior capturadas por la manilla Myo Armband mediante Redes Neuronales permite clasificar los gestos del alfabeto de la lengua de señas colombiano, teniendo en cuenta escenarios inter e intra sujetos.

El escenario 2 presenta los mejores resultados de precisión; en este escenario se utilizaron las 8 señales electromiografías de cada uno de los gestos de los 13 sujetos sin promediarlas.

Es importante tener en cuenta que la señal del EMG son generadas por la contracción muscular, por lo que su adquisición requiere de una correcta identificación de las regiones musculares comprometidas en la ejecución de los movimientos a clasificar y puede estar este movimiento asociado a variables como sexo, edad, o comorbilidad con diversas patologías. En el presente proyecto no se definió un protocolo de ubicación de la manilla lo cual pudiese estar afectado a los escenarios donde se promediaron las señales EMG; no se definió un protocolo con el propósito de lograr en el futuro una mayor independencia en cuanto a ubicación de la manilla en los usuarios finales.

En el presente estudio se presentó una tendencia a clasificar con mejor precisión los gestos que presentaban algún movimiento, no obstante, es difícil concluir otras tendencias, es necesario realizar un análisis más profundo teniendo en cuenta los datos de las diversas iteraciones.

La incorporación de las tecnologías de la información y las comunicaciones en el área de la salud permite brindar a personas con discapacidad desarrollos tecnológicos que aporten a la calidad de vida. El presente proyecto clasifica los gestos de señas colombianas partiendo de la adquisición de señales EMG tomadas en el antebrazo mediante el dispositivo Myo Armband.

La herramienta software desarrollada por el grupo de investigación UNITEL y compuesta por 4 módulos: 1) Módulo de adquisición, 2) Módulo de visualización, 3) Módulo de caracterización y 4) Módulo de traducción, es una herramienta de apoyo a la investigación clínica que permite investigar diversas formas de diseñar el clasificador de redes neuronales, con el propósito de aportar a la comunidad científica de metodologías de clasificación de los gestos del alfabeto de señas colombiano.

Se cuenta para futuras investigaciones con una base de datos de registros, que adicional a las 8 señales de EMG empleadas en este proyecto se almacenaron señales del giroscopio, acelerómetro, de orientación registradas por la manilla Myo.

8. Trabajos futuros

1. Ampliar la base de registros en cada uno de los grupos de edad.
2. Implementar un dispositivo hardware portátil que permita la traducción visual o sonora de la letra realizada con la manilla.
3. Desarrollar un proyecto que se integre con el descrito en el proyecto y dinamice la comunicación en el otro sentido de la comunicación, persona oyente que quiera comunicarse con una persona sorda.

9. Divulgación de resultados

- Los resultados iniciales de este trabajo fueron presentados en la modalidad de poster con el título “Sistema *domótico para personas con discapacidad motriz controlado mediante señales electromiográficas de miembro superior*” en el IX- Congreso Iberoamericano de Tecnologías de Apoyo a la Discapacidad- Iberdiscap 2017, que se llevó a cabo del 22 al 24 de noviembre de 2017, en la escuela colombiana de ingeniería Julio Garavito de la ciudad de Bogotá.
- Los resultados del proyecto fueron presentados en la ponencia titulada “Clasificación de gestos de la lengua de señas colombiana a partir del análisis de señales electromiográficas usando redes neuronales artificiales” en el II-Workshop de aplicaciones de las TIC en los sectores económicos, que se llevó a cabo el 8 de mayo del 2018, en las instalaciones de la Universidad Santo Tomas de Bucaramanga.

Referencias

- [1] (febrero). OMS | *Sordera y pérdida de la audición*. Available: <http://www.who.int/mediacentre/factsheets/fs300/es/>.
- [2] (). *Estadísticas básicas población sorda colombiana | Observatorio Social*. Available: <http://www.insor.gov.co/observatorio/estadisticas-basicas-poblacion-sorda-colombiana/>.
- [3] M. Chikkanna and R. M. R. Guddeti, "Kinect based real-time gesture spotting using HCRF," in August 2013,. DOI: 10.1109/ICACCI.2013.6637300.
- [4] G. Marin, F. Dominio and P. Zanuttigh, "Hand gesture recognition with leap motion and kinect devices," in October 2014, DOI: 10.1109/ICIP.2014.7025313.
- [5] J ayshree R. MayaIngle Pansare Computer Engineering SchofClompuStceire *et al*, "Vision-based approach for American Sign Language recognition using Edge Orientation Histogram." *2016 International Conference on Image, Vision and Computing (ICIVC)*, pp. 86-90, August, 2016.
- [6] Khamid and Adhi Dharma Wibawa, "Gesture Recognition for Indonesian Sign Language Systems (ISLS) Using Multimodal Sensor Leap Motion and Myo Armband Controllers Based-on Naïve Bayes Classifier," *2017 International Conference on Soft Computing, Intelligent System and Information Technology (ICSIIIT)*, pp. 1-6, 2017.
- [7] A. L. P. Madushanka *et al*, "Framework for sinhala sign language recognition and translation using a wearable armband," in 2016, Available: <http://ieeexplore.ieee.org/document/7829898>. DOI: 10.1109/ICTER.2016.7829898.
- [8] J. G. Abreu *et al*, "Evaluating sign language recognition using the myo armband," in 2016, Available: <http://ieeexplore.ieee.org/document/7517255>. DOI: 10.1109/SVR.2016.21.

- [9] Varadach Amatanon *et al*, "Sign Language-Thai Alphabet Conversion Based on Electromyogram (EMG)," *The 7th 2014 Biomedical Engineering International Conference*, pp. 1-4, November, 2014.
- [10] V. K. Seetharamu *et al*, "TV remote control via wearable smart watch device," in Dec 2014, Available: <https://ieeexplore.ieee.org/document/7030602>. DOI: 10.1109/INDICON.2014.7030602.
- [11] Hani Altwaijry *et al*, "Recognizing Locations with Google Glass: A Case Study," *IEEE Winter Conference on Applications of Computer Vision*, pp. 167-174, 2014. DOI: 10.1109/WACV.2014.6836105.
- [12] R. Schaer *et al*, "Live ECG readings using google glass in emergency situations," in Aug 2015, Available: <https://ieeexplore.ieee.org/document/7318363>. DOI: 10.1109/EMBC.2015.7318363.
- [13] A. Holgado-Terriza Juan, "Control of home devices based on hand gestures," *International Journal of Advanced Research in Computer Science*, vol. 8, (5), pp. 510-514, 2016. Available: <https://search.proquest.com/docview/1912630919>.
- [14] R. B. Mundo. (8/08/). *Las 5 cosas menos conocidas sobre la sordera*. Available: http://www.bbc.com/mundo/noticias/2014/08/140808_salud_cinco_cosas_que_no_sabe_sordera_lv.
- [15] P. K. Pisharady and M. Saerbeck, "Recent methods and databases in vision-based hand gesture recognition: A review," *Computer Vision and Image Understanding*, vol. 141, pp. 152-165, 2015. Available: <http://www.sciencedirect.com/science/article/pii/S1077314215001794>. DOI: 10.1016/j.cviu.2015.08.004.

- [16] S. Berman and H. Stern, "Sensors for Gesture Recognition Systems," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, vol. 42, (3), pp. 277-290, 2012. . DOI: 10.1109/TSMCC.2011.2161077.
- [17] F. Chen, C. Fu and C. Huang, "Hand gesture recognition using a real-time tracking method and hidden Markov models," *Image and Vision Computing*, vol. 21, (8), pp. 745-758, 2003. Available: <http://www.sciencedirect.com/science/article/pii/S0262885603000702>. DOI: 10.1016/S0262-8856(03)00070-2.
- [18] S. Marcel *et al*, "Hand gesture recognition using input-output hidden markov models," in 2000, . DOI: 10.1109/AFGR.2000.840674.
- [19] H. Yoon *et al*, "Hand gesture recognition using combined features of location, angle and velocity," *Pattern Recognition*, vol. 34, (7), pp. 1491-1501, 2001. Available: <http://www.sciencedirect.com/science/article/pii/S0031320300000960>. DOI: 10.1016/S0031-3203(00)00096-0.
- [20] D. Kim, J. Song and D. Kim, "Simultaneous gesture segmentation and recognition based on forward spotting accumulative HMMs," *Pattern Recognition*, vol. 40, (11), pp. 3012-3026, 2007. Available: <http://www.sciencedirect.com/science/article/pii/S003132030700088X>. DOI: 10.1016/j.patcog.2007.02.010.
- [21] W. W. Kong and S. Ranganath, "Towards subject independent continuous sign language recognition: A segment and merge approach," *Pattern Recognition*, vol. 47, (3), pp. 1294-1308, 2014. Available: <http://www.sciencedirect.com/science/article/pii/S0031320313003865>. DOI: 10.1016/j.patcog.2013.09.014.

- [22] J. Zhang *et al*, "Chinese sign language recognition with adaptive HMM," in 2016, Available: <http://ieeexplore.ieee.org/document/7552950>. DOI: 10.1109/ICME.2016.7552950.
- [23] S. G. Azar and H. Seyedarabi, "Continuous hidden markov model based dynamic persian sign language recognition," in May 2016, . DOI: 10.1109/IranianCEE.2016.7585687.
- [24] M. Yang, N. Ahuja and M. Tabb, "Extraction of 2D motion trajectories and its application to hand gesture recognition," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 24, (8), pp. 1061-1074, 2002. . DOI: 10.1109/TPAMI.2002.1023803.
- [25] R. Anderson *et al*, "Sign Language Recognition Application Systems for Deaf-Mute People: A Review Based on Input-Process-Output," *Procedia Computer Science*, vol. 116, pp. 441-448, 2017. Available: <http://www.sciencedirect.com/science/article/pii/S1877050917320720>. DOI: 10.1016/j.procs.2017.10.028.
- [26] K. Li, Z. Zhou and C. Lee, "Sign Transition Modeling and a Scalable Solution to Continuous Sign Language Recognition for Real-World Applications," *ACM Trans. Access. Comput.*, vol. 8, (2), pp. 7:1–7:23, 2016. Available: <http://doi.acm.org/10.1145/2850421>. DOI: 10.1145/2850421.
- [27] K. Akhmadeev *et al*, "A testing system for a real-time gesture classification using surface EMG," *IFAC-PapersOnLine*, vol. 50, (1), pp. 11498-11503, 2017. Available: <http://www.sciencedirect.com/science/article/pii/S2405896317322000>. DOI: 10.1016/j.ifacol.2017.08.1602.
- [28] C. Derr and F. Sahin, "Signer-independent classification of american sign language word signs using surface EMG," in Oct 2017, Available: <https://ieeexplore.ieee.org/document/8122683>. DOI: 10.1109/SMC.2017.8122683.

- [29] BASMAJIAN, J. V.; DE LUCA C. J. Muscles alive. Their function revealed by electromyography. Williams & Wilkens, Baltimore, 1985.
- [30] Peter Konrad, ABC of EMG. A Practical Introduction to Kinesiological Electromyography, Noraxon INC. USA, 2005.
- [31] GERDLE, B.; KARLSSON, S.; DAY, S.; DJUPSJÖBACKA M. Acquisition, Processing and Analysis of the Surface Electromyogram. Modern Techniques in Neuroscience. Capítulo 26: p705-755. Ed. Windhorst U. & Johanson H. Springer Verlag, Berlin, 1999.
- [32] Cristhian Manuel Durán Acevedo, Aylen Lisset Jaimes Mogollón. Optimización y clasificación de señales EMG a través de métodos de reconocimiento de patrones. ITECKNE Vol. 10 Número 1 • Julio 2013 • 67 - 76
- [33] González-Acevedo, H., C. J. Arizmendi-Pereira y B. Giraldo-Giraldo, Diseño de un clasificador para pacientes en proceso de extubación; Revista Iteckne, 12(1), 131-137 (2015).
- [34] Concepción Evelin Rosas Orea, María. (2018). Método para la reducción de ruido en imágenes utilizando la Transformada Wavelet Compleja con un algoritmo de Umbral Óptimo. Available:
https://www.researchgate.net/publication/37613211_Metodo_para_la_reduccion_de_ruido_en_imagenes_utilizando_la_Transformada_Wavelet_Compleja_con_un_algoritmo_de_Umbral_Optimo
- [35] R. N. Khushaba *et al*, "Driver Drowsiness Classification Using Fuzzy Wavelet-Packet-Based Feature-Extraction Algorithm," *Tbme*, vol. 58, (1), pp. 121-131, 2011. Available: <http://ieeexplore.ieee.org/document/5580017>. DOI: 10.1109/TBME.2010.2077291.
- [36] Fernando Izaurieta and Carlos Saavedra, "Redes Neuronales Artificiales," *Academic Emergency Medicine*, vol. 21, (1), pp. 17, 2014.

- [37] Forman, G., y M. Scholz, Apples-to-apples in Cross-validation Studies: Pitfalls in Classifier Performance Measurement; SIGKDD Explor. Newsl., 12(1), 49–57 (2010).
- [38] J. J. Martínez, "Análisis de minería de datos distribuida con Weka Parallel en computadoras con múltiples procesadores físicos y lógicos," *Economía Y Administración (E&A)*, vol. 6, (2), pp. 155, 2017. . DOI: 10.5377/eya.v6i2.4307
- [39] Charles Elkan. (-12-18). *Evaluating Classifiers*. Available: <https://web.archive.org/web/20111218192652/http://cseweb.ucsd.edu/~elkan/250B/classifierval.pdf>.
- [40] Zhang, X., B. Hu, X. Ma y L. Xu, Resting-State Whole-Brain Functional Connectivity Networks for MCI Classification Using L2-Regularized Logistic Regression; IEEE Transactions on NanoBioscience, 14(2), 237–247, (2015)
- [41] Oszust, M. y M. Wysocki, Polish sign language words recognition with Kinect, 6th International Conference on Human System Interactions (HSI), 219–226, Gdansk-Polonia, 6-8 de Junio (2013).