



UNIVERSIDAD TÉCNICA DE AMBATO

**FACULTAD DE INGENIERÍA EN SISTEMAS, ELECTRÓNICA E
INDUSTRIAL**

**CARRERA DE INGENIERÍA EN SISTEMAS COMPUTACIONALES E
INFORMÁTICOS**

Tema:

**SISTEMA DOMÓTICO PARA PERSONAS CON CAPACIDAD LIMITADA
DE MOVIMIENTO EN LA EXTREMIDAD SUPERIOR DERECHA
UTILIZANDO RECONOCIMIENTO DE GESTOS DE LA MANO Y
ALGORITMOS DE MACHINE LEARNING.**

Trabajo de Titulación Modalidad: Proyecto de Investigación, presentado previo a la
obtención del título de Ingeniero en Sistemas Computacionales e Informáticos

ÁREA: Inteligencia artificial

LÍNEA DE INVESTIGACIÓN: Tecnologías de la Información

AUTOR: Ronnie Julian Martinez Velasco

TUTOR: Ing. Rubén Nogales, Mg.

Ambato - Ecuador

septiembre – 2022

APROBACIÓN DEL TUTOR

En calidad de tutor del Trabajo de Titulación con el tema: SISTEMA DOMÓTICO PARA PERSONAS CON CAPACIDAD LIMITADA DE MOVIMIENTO EN LA EXTREMIDAD SUPERIOR DERECHA UTILIZANDO RECONOCIMIENTO DE GESTOS DE LA MANO Y ALGORITMOS DE MACHINE LEARNING, desarrollado bajo la modalidad Proyecto de Investigación. por el señor Ronnie Julian Martinez Velasco, estudiante de la Carrera de Ingeniería en Sistemas Computacionales e Informáticos, de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial, de la Universidad Técnica de Ambato, me permito indicar que el estudiante ha sido tutorado durante todo el desarrollo del trabajo hasta su conclusión, de acuerdo a lo dispuesto en el Artículo 15 del Reglamento para obtener el Título de Tercer Nivel, de Grado de la Universidad Técnica de Ambato, y el numeral 7.4 del respectivo instructivo.

Ambato, septiembre 2022.

Ing. Rubén Nogales, Mg.

TUTOR

AUTORÍA

El presente Proyecto de Investigación titulado: SISTEMA DOMÓTICO PARA PERSONAS CON CAPACIDAD LIMITADA DE MOVIMIENTO EN LA EXTREMIDAD SUPERIOR DERECHA UTILIZANDO RECONOCIMIENTO DE GESTOS DE LA MANO Y ALGORITMOS DE MACHINE LEARNING, es absolutamente original, auténtico y personal. En tal virtud, el contenido, efectos legales y académicos que se desprenden del mismo son de exclusiva responsabilidad del autor.

Ambato, septiembre 2022.



Ronnie Julian Martinez Velasco

C.C. 0503029951

AUTOR

APROBACIÓN TRIBUNAL DE GRADO

En calidad de par calificador del Informe Final del Trabajo de Titulación presentado por el señor Ronnie Julian Martinez Velasco, estudiante de la Carrera de Ingeniería en Sistemas Computacionales e Informáticos, de la Facultad de Ingeniería en Sistemas, Electrónica e Industrial, bajo la Modalidad Proyecto de Investigación, titulado SISTEMA DOMÓTICO PARA PERSONAS CON CAPACIDAD LIMITADA DE MOVIMIENTO EN LA EXTREMIDAD SUPERIOR DERECHA UTILIZANDO RECONOCIMIENTO DE GESTOS DE LA MANO Y ALGORITMOS DE MACHINE LEARNING, nos permitimos informar que el trabajo ha sido revisado y calificado de acuerdo al Artículo 17 del Reglamento para obtener el Título de Tercer Nivel, de Grado de la Universidad Técnica de Ambato, y al numeral 7.6 del respectivo instructivo. Para cuya constancia suscribimos, conjuntamente con la señora Presidente del Tribunal.

Ambato, septiembre 2022.

Ing. Pilar Urrutia, Mg.
PRESIDENTE DEL TRIBUNAL

Dr. Julio Balarezo
PROFESOR CALIFICADOR

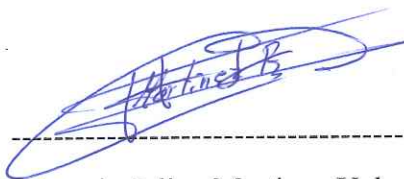
Ing. David Guevara, Mg.
PROFESOR CALIFICADOR

DERECHOS DE AUTOR

Autorizo a la Universidad Técnica de Ambato, para que haga uso de este Trabajo de Titulación como un documento disponible para la lectura, consulta y procesos de investigación.

Cedo los derechos de mi Trabajo de Titulación en favor de la Universidad Técnica de Ambato, con fines de difusión pública. Además, autorizo su reproducción total o parcial dentro de las regulaciones de la institución.

Ambato, septiembre 2022.



Ronnie Julian Martinez Velasco

C.C. 0503029951

AUTOR

DEDICATORIA

El presente proyecto esta dedicado en primer lugar a quien guio mi camino y puso a las personas correctos en el momento oportuno para poder cumplir con esta meta, DIOS.

A mi madre Cecilia Velasco y mi hermano Jhon Concha quienes con su amor, dedicación y abnegación han sabido guiarme, apoyarme incondicionalmente y sobre todo confiar en mi aun a pesar de las adversidades

A mi tutor por su guía y apoyo durante todo mi proceso de formación, ya que con sus conocimientos y consejos me permitieron culminar con éxito esta meta, además de su amistad incondicional.

AGRADECIMIENTO

A ti, DIOS, te doy gracias y te alabo, porque me has dado fuerza y sabiduría para llegar a este punto de mi formación académica, además de tu gran amor y misericordia.

A mi madre y hermano por ser siempre el motor que impulsa mis sueños y esperanzas, quienes estuvieron siempre a mi lado en los días y noches más difíciles durante mis horas de estudio. Siempre han sido mis mejores guías.

Sus palabras fueron sabias, sus conocimientos rigurosos y precisos, a mis profesores, les debo mis conocimientos. Donde quiera que vaya, los llevaré conmigo en mí transitar profesional. Gracias por su paciencia, por compartir sus conocimientos de manera profesional, por su dedicación perseverancia y tolerancia.”

Mis amigos y compañeros de clase, no puedo dejar de recordar cuantas tardes y horas de trabajo nos juntamos a lo largo de nuestra formación, no puedo dejar de agradecerles por su apoyo y constancia, al estar en las horas más difíciles, por compartir horas de estudio. Gracias por estar siempre allí.

Al Ing. Santiago Ayala y Lic. María del Carmen Sánchez por ser un gran apoyo en mi vida profesional como personal, ya que sus consejos y apoyo fueron de vital importancia.

ÍNDICE GENERAL DE CONTENIDOS

RESÚMEN EJECUTIVO	xii
ABSTRACT.....	xiii
CAPITULO I: MARCO TEÓRICO.....	1
1.1. Tema de Investigación.....	1
1.2. Antecedentes investigativos	1
1.2.1. Contextualización del problema	1
1.2.2. Delimitación	2
1.3. Antecedentes Investigativos	3
1.4. Fundamentación Teórica	11
1.4.1. Sensores no invasivos.....	11
1.4.2. Protocolos de comunicación.....	13
1.4.3. Brokers MQTT.....	13
1.4.4. Medio de transmisión inalámbrico.	14
1.4.5. Interacción Humano Computadora	14
1.4.6. Domótica	15
1.4.7. Modelo Ciber Físico.....	15
1.4.8. SVM.....	15
1.4.9. ANN.....	15
1.4.10. Aprendizaje Automático.....	15
1.4.11. Inteligencia Artificial.....	15
1.5. Objetivos.....	16
1.5.1. Objetivo General	16
1.5.2. Objetivos Específicos	16
CAPITULO II: METODOLOGÍA.....	17
2.1. Materiales	17
2.1.1. Humanos.....	17

2.1.2.	Institucionales.....	17
2.1.3.	Otros.....	17
2.2.	Métodos.....	18
2.2.1.	Modalidad de la investigación.....	18
2.2.2.	Población y muestra	18
2.2.3.	Recolección de la información	19
CAPITULO III resultados y discusión.....		20
3.1.	Desarrollo de la propuesta.....	20
3.1.1.	Modelo de reconocimiento de gestos de la mano (HGR)	20
3.1.2.	Protocolo de comunicación	25
3.1.3.	Control de luz, persiana y puerta.....	27
3.2.	Experimentación	28
3.2.1.	Primer subsistema	28
3.2.2.	Segundo Subsistema.....	29
3.2.3.	Tercer Subsistema	30
3.2.4.	Control de actuadores.....	32
3.3.	Resultado.....	33
CAPITULO IV Conclusiones y Recomendaciones		38
Bibliografía.....		40

ÍNDICE DE TABLAS

Tabla 1.	Cadenas de búsqueda.....	5
Tabla 2.	Criterios de inclusión y exclusión	6
Tabla 3.	Características de LMC y Kinect	12
Tabla 4.	Matriz PUGH para selección de ordenadores IoT	13
Tabla 5.	Características de Brokers MQTT	14
Tabla 6.	Medios de transmisión inalámbricos.	14
Tabla 7.	Recursos económicos	17
Tabla 8.	Resultados de la evaluación de los gestos del Sistema Domótico	33
Tabla 9.	Evaluación del tiempo del modelo de HGR	34
Tabla 10.	Tiempo teórico de entrega del Sistema Domótico	34

ÍNDICE DE GRÁFICOS

Figura 1. Esquema del Sistema Domótico	20
Figura 2. Esquema de captura y reconocimiento de los gestos de la mano	21
Figura 3. Estructura principal	21
Figura 4. Estructura secundaria	22
Figura 5. Estandarización si el número de muestras es menor a 70	23
Figura 6. Estandarización si el número de muestras es mayor a 70	23
Figura 7. Estandarización de muestras de n a 70.....	24
Figura 8. Extracción de características por ventanas dentro de un canal.....	25
Figura 9. Arquitectura MQTT Publicador/Suscriptor	26
Figura 10. Control del actuador mediante la placa Esp8266.....	27
Figura 11. Esquema del primer subsistema	29
Figura 12. Esquema del segundo subsistema	30
Figura 13. Esquema del tercer subsistema	31
Figura 14. Reconocimiento de gestos por usuario	35
Figura 15. Tasa de reconocimiento por gestos	35
Figura 16. Matriz de confusión del modelo de HGR en línea con ANN	36

RESÚMEN EJECUTIVO

Las personas con discapacidades físicas (DF) tienen problemas para realizar actividades cotidianas, lo que afecta su independencia. En este contexto, una persona con DF puede comunicarse mediante gestos de la mano o gestos faciales, entre otros. Sin embargo, la selección de las características y patrones que separan un gesto de otro no es un problema trivial. En este sentido, se propone un sistema domótico (SD) en tiempo real que funciona con tres subsistemas. El primer subsistema reconoce los gestos de la mano utilizando un modelo de aprendizaje automático e información de infrarrojos. El modelo de aprendizaje automático consta de módulos de preprocesamiento, extracción de características, clasificación y postprocesamiento. El segundo subsistema transmite el mensaje entre los subsistemas. Por último, el tercer subsistema activa el funcionamiento de los actuadores mediante gestos. El modelo HGR se entrenó con 6.720 observaciones y se probó fuera de línea con 1.680 observaciones, lo que arrojó una tasa de precisión del 92,759%. Además, el SD se probó en línea con 1.500 observaciones de 10 usuarios cuyas personas no formaban parte del conjunto de datos de entrada ni de las pruebas del modelo. Las pruebas en línea arrojan un índice de precisión del 84,07%. Una vez reconocido el gesto de la mano, se envía de forma inalámbrica a una placa Esp8266 a través del protocolo MQTT. La placa Esp8266 activa el funcionamiento de varios actuadores. El broker mosquitto embebido en una raspberry pi gestiona el envío y recepción de mensajes entre el ordenador donde se reconoce el gesto y la placa Esp8266. El tiempo de respuesta teórico del SD es de 118,87 ms.

Palabras clave: Sistema Domótico, reconocimiento de gestos de la mano, MQTT, leap motion controller

ABSTRACT

People with physical disabilities (PD) have problems carrying out daily activities, affecting their independence. In this context, a person with PD can communicate through hand gestures or facial gestures, among others. However, selecting the features and patterns that separate one gesture from another is not a trivial problem. In this sense, a real-time domotic system (DS) that works with three subsystems is proposed. The first subsystem recognizes hand gestures using a machine learning model and infrared information. The machine learning model consists of preprocessing, feature extraction, classification, and postprocessing modules. The second subsystem relays the message between the subsystems. Finally, the third subsystem activates the operation of the actuators by gestures. The HGR model was trained using 6720 observations and tested offline with 1680 observations, giving an accuracy rate of 92.759%. Additionally, the DS was tested online with 1500 observations from 10 users whose persons were not part of the input dataset or model testing. Online testing gives an accuracy rate of 84.07%. Once the hand gesture is recognized, it is sent wireless to an Esp8266 board through the MQTT protocol. The Esp8266 board activates the operation of several actuators. The mosquitto broker embedded in a raspberry pi manages the sending and receiving of messages between the computer where the gesture is recognized and the Esp8266 board. The theoretical response time of the DS is 118.87 ms.

Keywords: Domotic System, hand gesture recognition, MQTT, leap motion controller.

CAPITULO I: MARCOTEÓRICO

1.1. Tema de Investigación

SISTEMA DOMÓTICO PARA PERSONAS CON CAPACIDAD LIMITADA DE MOVIMIENTOS EN LA EXTREMIDAD SUPERIOR DERECHA UTILIZANDO RECONOCIMIENTO DE GESTOS DE LA MANO Y ALGORITMOS DE MACHINE LEARNING.

1.2. Antecedentes investigativos

1.2.1. Contextualización del problema

Los Sistemas Domóticos (SD) permiten la autonomía de personas con Discapacidad Física (DF). En este contexto, un SD ayuda a una persona con DF a realizar las actividades de la vida diaria sin necesidad de que otra persona los asista. La autonomía para realizar actividades cotidianas incrementa la autoestima y mejora la calidad de vida de las personas con DF [1, 2]. La flexibilidad de los SD permite el uso de una gran cantidad de periféricos tanto de entrada para obtener información, como de salida (actuadores) para ejecutar una acción específica, como abrir una puerta o encender una bombilla. Los SD no se limitan a las personas con una DF concreta. Por el contrario, muchas personas con diferentes tipos de DF pueden beneficiarse de tener una gran variedad de periféricos de entrada. Del mismo modo, la interfaz persona-ordenador (HCI) de un SD puede adaptarse a las necesidades específicas de cada DF, permitiendo el control del entorno y la comunicación [3].

En [4] expone que, hasta enero de 2022 en Ecuador existen 471.205 personas con discapacidad, de las cuales el 45,66% corresponde a DF. En el porcentaje de la población con DF existen patologías como afasia, espasticidad y déficits motores causados por Enfermedades Cerebrovasculares (ECV), Lesiones Medulares (LM), entre otras. Las ECV se clasifican en isquémicas y hemorrágicas [5], entre ellas la ECV isquémica es la causante de la limitada capacidad de movimiento en las personas que la padecen. Las LM provocan la pérdida de sensibilidad y función

motora en las extremidades superiores, inferiores o en todo el cuerpo. Según la Organización Mundial de la Salud (OMS), las personas con una lesión medular tienen entre 2 y 5 veces más probabilidades de morir durante el primer año [6]. El normal rendimiento de las funciones motoras se restablece en raras ocasiones tras esta clase de patologías y después de un largo tiempo de rehabilitación, limitando el cumplimiento de actividades de la vida diaria [7, 8]. Por lo tanto, la forma de comunicación de las personas con DF es mediante movimientos corporales, también conocidos como gestos.

La generación de gestos es una forma de expresar sentimientos hacia otros seres humanos [9]. Inconscientemente, las personas necesitan comunicarse con el mundo que les rodea desde el momento en que nacen. En este sentido, las personas con DF pueden utilizar gestos para realizar actividades cotidianas. Estos gestos proporcionan datos enriquecidos que se pueden utilizar para el reconocimiento, lo que permite capturar información a través de diferentes dispositivos. Los dispositivos pueden clasificarse en sensores que cubren partes del cuerpo y dispositivos que no requieren contacto directo.

El SD propuesto pretende ayudar a las personas con DF a recuperar su independencia a través de los gestos de la mano. Además, el SD captura los gestos ejecutados por el usuario con él (LMC). El LMC proporciona una secuencia de imágenes y posiciones espaciales que representan el movimiento realizado [10]. En este caso, las posiciones espaciales es la información a utilizar para reconocer los gestos OPEN HAND, CLOSE HAND, WAVE IN, WAVE OUT y PINCH. Una vez capturada la señal producida por el gesto, esta será preprocesada para su reconocimiento posterior mediante algoritmos de Machine Learning. Finalmente, la etiqueta resultante del reconocimiento será enviada a través de la red Wi-Fi al dispositivo IoT que se encargará del accionar de los actuadores correspondientes.

1.2.2. Delimitación

Línea de investigación: Tecnologías de la información.

Sub líneas de investigación: Procesamiento de la información.

1.3. Antecedentes Investigativos

En este trabajo, se realizó una revisión exhaustiva de la literatura en bases de datos científicas como IEEE Xplore, ACM digital library, Springer y Science Direct para la investigación. Las cadenas de búsqueda se crearon con palabras clave como Domotics, Raspberry Pi, Hand Gesture Recognition, SVM, ANN, IoT, Leap Motion Controller, LMC dentro de los años 2016 – 2021. En este contexto, la **Tabla 1.** describe las cadenas de búsqueda utilizadas y el número de artículos obtenidos por cadena.

	Revista	Cadena	Número de artículos
Cadena 1	IEEE Xplore	("All Metadata":LMC) AND ("All Metadata":SVM) 2016 - 2020	4
	SCOPUS	(TITLE-ABS-KEY (lmc) AND TITLE-ABS-KEY (svm)) AND PUBYEAR > 2015	12
	SPRINGER Link	"LMC" and "SVM" within 2016 - 2021	116
	ACM Digital Library	[All: lmc] AND [All: svm] AND [Publication Date: (01/01/2016 TO 12/31/2021)]	17
Cadena 2	IEEE Xplore	("All Metadata":Leap Motion Controller) AND ("All Metadata":ANN) AND ("All Metadata":Raspberry Pi)	0
	SCOPUS	(TITLE-ABS-KEY (leap AND motion AND controller) AND TITLE-ABS-KEY (ann)AND TITLE-ABS-KEY (raspberry AND pi)) AND PUBYEAR > 2015	0
	SPRINGER Link	"Leap Motion controller" and "ANN" and "raspberry pi" within 2016 - 2021	16
	ACM Digital Library	[All: leap motion controller] AND [All: ann] AND [All: raspberry pi] AND [Publication Date: (01/01/2016 TO 12/31/2021)]	1117
	IEEE Xplore	("All Metadata": LEAP MOTION	1

Cadena 3		CONTROLLER) AND ("All Metadata": RASPBERRY PI)	
	SCOPUS	(TITLE-ABS-KEY (leap AND motion AND controller) AND TITLE-ABS-KEY (raspberry AND pi)) AND PUBYEAR > 2015	2
	SPRINGER Link	"LEAP MOTION CONTROLLER" and "RASPBERRY PI" within 2016 - 2021	25
	ACM Digital Library	[All: leap motion controller] AND [All: raspberry pi] AND [Publication Date: (01/01/2020 TO 12/31/2021)]	850
Cadena 4	IEEE Xplore	("All Metadata": MACHINE LEARNING) AND ("All Metadata":DOMOTIC) AND ("All Metadata":LEAP MOTION CONTROLLER)	0
	SCOPUS	(TITLE-ABS-KEY (machine AND learning) AND TITLE-ABS-KEY (domotic) AND TITLE-ABS-KEY (leap AND motion AND controller)) AND PUBYEAR > 2015	0
	SPRINGER Link	"MACHINE LEARNING" and "domotic" and "LEAP MOTION CONTROLLER" within 2016 - 2021	0
	ACM Digital Library	[All: machine learning] AND [All: domotic] AND [All: leap motion controller] AND [Publication Date: (01/01/2016 TO 12/31/2021)]	35
Cadena 5	IEEE Xplore	("All Metadata":MACHINE LEARNING) AND ("All Metadata":DOMOTIC) AND ("All Metadata":LEAP MOTION CONTROLLER) AND ("All Metadata":IoT)	0
	SCOPUS	(TITLE-ABS-KEY (machine AND learning) AND TITLE-ABS-KEY (0 8 domotic) AND TITLE-ABS-KEY (leap AND motion AND controller) AND TITLE-ABS-KEY (iot)) AND PUBYEAR > 2015	0

	SPRINGER Link	"Machine Learning" and "Domotic" and "Leap Motion Controller" and "IoT" within 2016 - 2021	0
	ACM Digital Library	[All: machine learning] AND [All: domotic] AND [All: leap motion controller] AND [All: iot] AND [Publication Date: (01/01/2016 TO 12/31/2021)]	21
Cadena 6	IEEE Xplore	("All Metadata":hand gesture recognition) AND ("All Metadata":svm) AND ("All Metadata":raspberry pi)	0
	SCOPUS	(TITLE-ABS-KEY (hand AND gesture AND recognition) AND TITLE-ABSKEY (svm) AND TITLE-ABS-KEY (raspberry AND pi)) AND PUBYEAR > 2015	0
	SPRINGER Link	"Hand Gesture Recognition" and "SVM" and "Raspberry pi" within 2016 - 2021	64
	ACM Digital Library	[All: hand gesture recognition] AND [All: svm] AND [All: raspberry pi] AND [Publication Date: (01/01/2016 TO 12/31/2021)]	1770
Total			4050

Tabla 1. Cadenas de búsqueda

Elaborado por: Ronnie Martinez

El objetivo de la revisión de literatura fue definir la existencia de SD que usen LMC para controlar dispositivos IoT como una ayuda para personas con DF. En este sentido, la revisión de literatura da como resultado 4050 artículos académicos donde utilizan las palabras claves expuestas anteriormente. De los 4050 artículos se eliminaron 3845 artículos que usan modelos de machine learning y dispositivos IoT como formas de automatización en ambientes industriales y manejo de sistemas robóticos, pero ninguna emplea SD para ayudar a personas con DF. Como resultado se tiene 205 artículos restantes de los cuales se discriminaron 149. Los 149 artículos son discriminados porque usan LMC y algoritmos de machine learning para reconocimiento de gestos de la mano (HGR) como ayuda para comunicación a través de lenguaje de señas, pero ningún artículo implementa SD. Del análisis

anterior se tiene 56 artículos resultantes, de los cuales 50 exponen SD que utilizan algoritmos de machine learning, dispositivos IoT que puedan ser utilizadas por personas sin DF. Finalmente, se usaron 6 artículos donde los autores crearon SD utilizando algoritmos de Machine Learning y dispositivos IoT con un enfoque para personas sanas como para personas con DF. Sin embargo, no hay evidencia de SD que integren los métodos mencionados y los datos de LMC en un único modelo ciber físico. La **Tabla 2.** muestra los criterios de inclusión y exclusión utilizados para seleccionar los artículos más relevantes para la investigación.

Inclusión	<ul style="list-style-type: none"> - Artículos que usan algoritmo de machine learning y reconocimiento de gestos - Artículos que implementa SD - Artículos que usen ordenadores IoT - Publicaciones que utilicen LMC para adquisición de datos.
Exclusión	<ul style="list-style-type: none"> - No emplean SD para personas con DF. - No presentan implementación solo modelos de machine learning. - Implementan SD solo para personas sanas.

Tabla 2. Criterios de inclusión y exclusión

Elaborado por: Ronnie Martinez

En [11] se propone una Interfaz Cerebro-Ordenador (BCI) para controlar dispositivos domóticos a través de un deletreador P300. El sistema propuesto trabaja con señales EEG utilizadas para la extracción de características y, finalmente, la clasificación. La señal capturada contiene la acción deseada por el

usuario, y el sistema BCI decide cuál de todos los objetos debe controlar. Se utilizó el sistema BCI 2000 g. Tec para adquirir un registro completo de potenciales evocados P300. Se aplicó un filtro de paso de banda con frecuencias de corte de 0,1-20 Hz. Los segmentos de datos se agruparon por canal para cada intensificación, generando un único vector de características igual a cada estímulo. Las características obtenidas se utilizaron para derivar los pesos para el Análisis Discriminante Lineal por Pasos (SWLDA), que se utilizó como método de clasificación. Se utilizaron dos fases para el experimento. La fase offline se realizó en dos sesiones durante dos semanas con tres usuarios. Una sesión fue de entrenamiento y la otra de prueba, con diez ejecuciones cada una. La fase online se llevó a cabo con un único usuario que realizó seis ejecuciones. Informan de un valor medio del 83% en la fase offline, mientras que alcanza el 90% de precisión en la fase online.

En [12], la pulsera Myo-Armband es una forma sencilla e inalámbrica de controlar un entorno doméstico. Además, los dispositivos eléctricos y electrónicos del hogar se controlan mediante módulos Zigbee. Las actividades que se realizan en los SD son abrir y cerrar las persianas, encender y apagar las luces y cerrar toda la casa. Estas acciones responden a cada señal enviada por la pulsera. Se adquirieron las señales de 10 individuos seleccionados al azar, y cada señal se repitió cinco veces. Se tomaron sesenta muestras de cada electrodo del brazalete y de cada eje de coordenadas de las aceleraciones lineales y angulares. A continuación, se suman los valores de las ocho señales de los electrodos para obtener una única señal. El mismo proceso se utiliza para las señales de aceleración lineal y angular. Finalmente, utilizan una red neuronal Feed-Forward para clasificar con el algoritmo Levenberg Mar-quardt para el entrenamiento. La red neuronal consta de 3 capas. Una capa de entrada con 18 neuronas, una capa oculta con ocho neuronas y una capa de salida con tres neuronas. El reconocimiento lineal utiliza una ventana deslizante, y el algoritmo se implementó en C++ con los pesos sinápticos previamente entrenados en MATLAB. La red neuronal tiene una precisión del 83,33% en el reconocimiento y la clasificación de las señales electromiográficas.

En [13, 14], los autores proponen en dos partes un SD controlado por comandos de voz. Los comandos de voz utilizan un modelo acústico y de lenguaje entrenado en la primera parte de este proyecto. La voz del usuario se captura en una aplicación móvil desarrollada en Android Studio. Los archivos de audio se envían por sockets utilizando el protocolo FTP. Se eligió Raspberry Pi como servidor FTP y Arduino Uno como placa de adquisición y envío de señales. Una vez recibido el archivo de audio en formato MP4, el sistema lo transforma en WAV. En este caso, el proceso de reconocimiento se basa en redes bayesianas, concretamente en modelos ocultos de Markov (HMM). El modelo utilizado para el reconocimiento en la versión 2.1 presenta una precisión del 100% en las fases de entrenamiento y del 83% en la fase de prueba. El sistema permite la adquisición y el reconocimiento de comandos de voz, el control de la luz, la medición de la temperatura, la emulación del funcionamiento de la nevera, la notificación en tiempo real y la consulta de la base de datos.

En [15], implementan un SD controlado por voz. El SD utiliza bibliotecas de código abierto para la detección de palabras clave, el reconocimiento de voz y la integración de dispositivos inteligentes. Además, el protocolo MQTT permite la comunicación entre dispositivos. El SD utiliza la Raspberry Pi 3 para el Centro de Reconocimiento Inteligente (IRC) y un micrófono con una tarjeta de audio USB para capturar las órdenes de voz. El IRC realiza la detección de palabras clave utilizando la biblioteca Snowboy. Además, los autores utilizan CMUSphinx para entrenar un modelo acústico y lingüístico con la lengua portuguesa. No informan de los resultados del entrenamiento. El modelo entrenado se encarga del reconocimiento del habla y de la transformación de audio a texto. El texto obtenido es indexado a un actuador que realizará una acción específica. Por último, el IRC convierte el texto con la acción reconocida en audio como respuesta para el usuario. Mediante múltiples comandos de voz se evaluó la capacidad de interpretación del sistema. En la fase de pruebas preliminares se ha obtenido un 95% de precisión.

En [16] se propone un sistema de control domótico a través del reconocimiento de gestos de la mano enfocado a personas inmóviles y encamadas. En primer lugar, el sistema graba un vídeo del gesto a través de una cámara con una resolución de

1280x720. El vídeo se envía para ser procesado por un circuito cerrado de televisión (CCTV) instalado en la habitación del paciente. En segundo lugar, se extrae el gesto y se reconoce el mismo. Para el reconocimiento utilizan una red neuronal convolucional con tres capas convolucionales y 2 capas de Max Pooling. La salida de la última capa alimenta un Softmax. La función de sustracción de fondo proporcionada por OpenCV permite extraer la máscara del primer plano en movimiento y segmentar la mano. Se crea un conjunto de datos con imágenes de la mano izquierda y derecha a diferentes profundidades. El conjunto de datos consta de 6 gestos, con un total de 12000 imágenes de 64 píxeles con etiquetas específicas. En este caso, el 80% del conjunto de datos se utiliza para el entrenamiento del clasificador y el 20% restante para las pruebas. Al final, se ajusta el modelo y se define el número de épocas y pasos, con un total de 50 épocas con 6000 pasos para el entrenamiento y 3000 pasos para las pruebas con una precisión media del 99,97%.

En [17], desarrollan un modelo predictivo para optimizar y planificar hogares inteligentes. El modelo utiliza datos del exterior y del interior de la vivienda. La simulación de diferentes escenarios de una casa a escala proporciona esta información. Los datos del exterior son la temperatura y la humedad, mientras que los del interior son los estados de los actuadores. Los autores procesan los datos recogidos para extraer automáticamente la información que el sistema necesita para responder a los eventos externos. Un sistema central controla la interrelación entre dos subsistemas con funciones específicas. El primer subsistema permite el control de las propiedades fundamentales del hogar inteligente, como el aire acondicionado y los dispositivos automatizados, entre otros. En este contexto, el protocolo MQTT realiza el envío y recepción de mensajes entre el sistema anfitrión y el subsistema de control. El segundo subsistema ayuda en la gestión y configuración de los experimentos a través de una interfaz remota, la recogida de datos y un agente encargado de obtener escenarios del mundo real. El subsistema de gestión se comunica mediante peticiones REST porque no necesita estar cerca del entorno físico de simulación. Entrenaron cuatro regresores de aprendizaje automático para el modelo predictivo resultante. Las bibliotecas Keras y scikit-learn proporcionaron modelos regresores LSTM, KNN y SVM para el entrenamiento. Además, los

autores crean el modelo DNN, que consta de cinco capas y 128 neuronas en cada capa, pérdida de Huber y Relu como función de activación. Para el primer entrenamiento y prueba cuentan con un conjunto de datos de 300 registros. Informan de una precisión del 79% para DNN, del 70% para KNN, del 64% para LSTM y del 42% para SVR. El segundo entrenamiento y prueba aumenta el conjunto de datos a 4000 registros. En el mismo sentido, informan de una precisión del 95% para KNN, del 89% para DNN, del 87% para LSTM y del 22% para SVR. El entrenamiento y las pruebas con los dos registros SVR siempre obtuvieron el porcentaje de precisión más bajo.

Los principales problemas que se encontraron en estos SD son los siguientes. En primer lugar, los SD que funcionan con servicios en la nube almacenan una gran cantidad de información que puede ser vulnerada. Las empresas externas recopilan esta información mediante el monitoreo constante de los hogares. Empleados dentro de las empresas que prestan estos servicios tienen acceso a esta información, como es el caso de AMAZON [18]. Por esta razón, el acceso a esta información viola la privacidad de los datos de cada usuario [19]. En segundo lugar, los SD controlados por la voz tiene problemas de implementación y usabilidad. Este tipo de SD necesita un modelo de reconocimiento de voz entrenado para su correcto funcionamiento. El modelo de reconocimiento trabaja con una gran cantidad de datos para el entrenamiento y las pruebas en un solo idioma. La gran cantidad de datos necesarios para el modelo de reconocimiento hace que la implementación de este tipo de SD sea un reto [20]. Además, los SD controlados por voz son obsoletas para las personas que sufren afasia como resulta de una ECV. En tercer lugar, los SD que trabajan con dispositivos invasivos, como Myo Armband, sensores EEG, entre otros, no son adecuadas para las personas con DF. La principal razón es la necesidad de un contacto directo de la piel con la superficie del sensor, lo que provoca sudoración e incomodidad durante un uso prolongado. Por último, los SD controlados por cámaras de CCTV superan el problema existente con los dispositivos invasivos, pero se limita al control desde una zona específica por su instalación estática, además del costo de implementación a diferencia de LMC. En este contexto, los SD existentes generan problemas para las personas con DF.

Por estas razones, se propone un SD centrado en el reconocimiento de los gestos de la mano con LMC para controlar el entorno de las personas con DF. El LMC es un dispositivo de bajo coste, preciso y dedicado a capturar el movimiento de la mano [21, 22]. Además, LMC tiene un rango de interacción de 150 grados de ancho por 60 cm de alto con una precisión de 0,01 mm [10]. En primer lugar, el SD utilizará el LMC para captar la información de los gestos de la mano del usuario. En segundo lugar, los algoritmos de aprendizaje automático obtendrán la información de los gestos para su reconocimiento. A continuación, MQTT permitirá la comunicación segura entre dispositivos y se implementará en una Raspberry Pi 3. Por último, la placa Esp8266 controlará los diferentes actuadores según la etiqueta que reciba.

1.4.Fundamentación Teórica

1.4.1. Sensores no invasivos

Según [23] los sensores no invasivos se dividen en dos categorías. La primera categoría son aquellos que cubren parte del cuerpo como Myo Armband o guantes inteligentes. La segunda categoría no necesita de un contacto físico. En este sentido, entre los dispositivos sin contacto se encuentra Leap Motion Controller, Microsoft Kinect, entre otros. Leap Motion Controller es un dispositivo pequeño y preciso que captura información de los movimientos de las manos y de los dedos de forma óptica. Kinect es un dispositivo que reconoce gestos, siluetas, además de distinguir el esqueleto completo de usuario. La **Tabla 3.** describe las características de los dos dispositivos.

Características	Kinect	LMC
Superficie del espacio de trabajo	6m ²	1.16m ²
Campo de visión	Horizontal 57° Vertical 43°	Izquierda-derecha 150°
Precisión	Centímetros	Centésima de milímetro
Tecnología	1 transmisor de infrarrojos 1 cámara de infrarrojos de 0,3 megapíxeles	3 transmisores de infrarrojos 2 cámaras de

	1 cámara RGB (rojo, verde, azul) 4 micrófonos direccionales	infrarrojos de 1,3 megapíxeles
Frecuencia de actualización de la imagen	9 a 30 Hz	200 Hz
Reconocimiento	Movimientos del cuerpo Reconocimiento facial Reconocimiento vocal	Movimientos de las manos Movimientos de los dedos

Tabla 3. Características de LMC y Kinect

Elaborado por: [24]

A pesar de ser dispositivos especializados a capturar información sin la necesidad de un contacto físico, LMC genera un mayor porcentaje de precisión al capturar gestos de la mano sin comprometer la facilidad de movimiento en comparación con Kinect [21].

1.4.1. IoT

La evolución del internet en la actualidad es el internet de las cosas. Esto significa que cualquier cosa u objeto se interconecten entre sí, en cualquier momento o lugar. Además, el internet de las cosas proporciona servicios avanzados con base en tecnologías de la información [25]. El control entre cosas u objetos se puede realizar a través de placas IoT como Raspberry Pi, Arduino, entre otras. En este contexto, Una placa IoT está diseñada para funciones dedicadas con entradas y salidas tanto análogas como digitales. Su funcionamiento está basado en lenguajes de programación. En este sentido, existe una gran variedad de ordenadores IoT. La **Tabla 4.** muestra una evaluación de 4 ordenadores en función de sus características.

	DSP Texas	Arduino Mega	Arduino uno	Rasberry Pi
Servicios de Internet	5	5	5	5
Software libre	1	5	5	5
Interfaz de usuario	5	5	5	5
Entradas / salidas	5	5	3	4
Protocolo de comunicación	3	5	5	5
Disponibilidad en el mercado	2	5	5	5

costo	2	4	5	3
Frecuencia de trabajo	3	2	1	5
Total	22	34	31	37

Tabla 4. Matriz PUGH para selección de ordenadores IoT

Elaborado por: [14]

Raspberry Pi tiene características superiores con relación a otras placas utilizadas para trabajos con internet de las cosas según la Tabla 4. Al tener 37 puntos en su valoración será utilizada como central de administración de envío y recepción de mensajes.

1.4.2. Protocolos de comunicación

Reglas que ayuda a que dos o más dispositivos a transmitir información entre sí. En este contexto, existen una gran variedad de protocolos IoT que son utilizados para implementaciones de SD como MQTT. MQTT es un protocolo especializado para aplicaciones IoT. El protocolo MQTT tiene una velocidad de transmisión más alta, una pérdida mínima de batería y trabaja eficientemente con un ancho de banda mínimo superando a HTTP [26, 27, 28].

1.4.3. Brokers MQTT

El Broker MQTT es un software que administra los mensajes recibidos dentro de una arquitectura publicador/suscriptor. Cada mensaje es filtrado para determinar quién está suscrito a un tema específico y enviar el mensaje a los clientes suscritos. Existe una gran variedad brokers diseñados para diferentes entornos. La **Tabla 5.** muestra los brokers de código abierto más utilizados y su característica.

Tecnología	EMQ X	HiveMQ	Mosquitto	VerneMQ
Características				
Clúster	Si	no	No	Si
Calificador GitHub	6500	450	3958	2196
Tendencia de motores de Búsqueda en la WEB	-	2	6	-
Velocidad promedio de los mensajes (msg/seg)	400.12	391.24	282.78	216.06
Perdida promedio de mensajes (%)	1.75	0	0	5.34
Promedio de mensajes duplicados (%)	8.52	0.14	0.03	0.02

Tabla 5. Características de Brokers MQTT

Elaborado por: [29] [30]

1.4.4. Medio de transmisión inalámbrico.

Los medios de transmisión inalámbricos (sin conductor físico) utilizan el aire para enviar ondas electromagnéticas. La **Tabla 6.** muestra los medios de transmisión inalámbrica más utilizados y sus características.

Tecnología	Alcance	Velocidad	Aplicación	Tipo de Red
NFC	Meno a 3 metros	400 kbs	Intercambio de datos entre dispositivos	PAN
Bluetooth	Menor a 30 metros	700 kbs	Sustitución de cable	PAN
Wi-Fi	Entre 4 y 50 metros	72 Mbps	Internet	LAN
ZigBee	Entre 10 y 300 metros	250 kbs	Radio Difusión Digital de Bajo Consumo	WPAN

Tabla 6. Medios de transmisión inalámbricos.

Elaborado por: [31]

La tecnología Wi-Fi tiene una mayor velocidad de transmisión para un SD que trabaja en tiempo real. Además, la instalación de un SD que trabaje de forma inalámbrica reduce el costo de instalación.

1.4.5. Interacción Humano Computadora

Es el campo que se encarga de comprender las varias reglas de los seres humanos en su intento de comunicación con las computadoras y explorar formas creativas de diseñar interfaces basadas en computadoras para mejorar la usabilidad y la calidad de la experiencia del usuario [32].

1.4.6. Domótica

Se conoce como domótica a la etapa de control y supervisión de los hogares en donde prevalecerán la interconectividad entre dispositivos, propietarios y servicios externos [33].

1.4.7. Modelo Ciber Físico

Simbolizan una composición tanto de procesos físicos, así como recursos computacionales, definiéndolo más específicamente como un sistema inteligente que incluye redes de ingeniería interactivas entre componentes físicos y computacionales [34].

1.4.8. SVM

En [35] establece que la Máquina de Vectores de Soporte (SVM) lleva a cabo la clasificación encontrando el hiperplano que maximiza el margen entre clases y para hacerlo establece el margen y las ecuaciones de decisión de frontera y maximizarlos o minimíalos.

1.4.9. ANN

Una red neuronal artificial se define como un sistema compuesto de muchos elementos simples de procesamiento que operan en paralelo y cuya función es determinada por la estructura de la red, así como el peso de las conexiones, donde el procesamiento se realiza en cada uno de los nodos o elementos de cómputo [36].

1.4.10. Aprendizaje Automático

Es una rama de la inteligencia artificial que permite que los ordenadores a través del diseño de sistemas puedan aprender a partir de datos como un modo de entrenamiento, mejorando con la experiencia y con el tiempo se refine el modelo permitiendo que a futuro pueda predecir [35, 37].

1.4.11. Inteligencia Artificial

Tiene como principal objetivo lograr que una máquina tenga una inteligencia de tipo general simulando la inteligencia humana [38].

1.5.Objetivos

1.5.1. Objetivo General

Desarrollar un sistema domótico para personas con capacidad limitada de movimientos en la extremidad superior derecha en tiempo real utilizando algoritmos de machine learning.

1.5.2. Objetivos Específicos

- Diseñar un sistema domótico que funcione en tiempo real y permita reconocer 5 gestos de la mano para activar el funcionamiento del actuador.
- Identificar el clasificador con el porcentaje de exactitud más alto durante el reconocimiento de gestos de la mano.
- Crear un sistema domótico con reconocimiento de gestos de la mano en tiempo real para personas con capacidad limitada de movimientos en la extremidad superior derecha

CAPITULO II: METODOLOGÍA

2.1. Materiales

2.1.1. Humanos

- Docente Tutor.
- Investigador.

2.1.2. Institucionales

- Facultad de Ingeniería en Sistemas, Electrónica e Industrial.
- Repositorio.
- Biblioteca Virtual.

2.1.3. Otros

El proyecto será financiado en su totalidad por el investigador.

N.º	Detalle	Unidad	Cantidad	V. unitario	Valor total
1	Internet	Mes	6	25	150
2	Computadora	c/u	1	1300	1300
3	Leap Motion Controller	c/u	1	102.99	102.99
4	Medios de Almacenamiento	c/u	2	10	20
5	Licencia de software MATLAB	c/u	1	55	55
6	Servomotor de 180º	c/u	2	10	20
7	Servomotor de 360º	c/u	2	10	20
8	Fines de Carrera	c/u	4	2	8
9	Leds	c/u	4	0.05	0.20
Subtotal					1676.19
Imprevistos (10%)					167.61
Total					1843.80

Tabla 7. Recursos económicos

Elaborado por: Ronnie Martinez

2.2.Métodos

2.2.1. Modalidad de la investigación

Investigación de campo. - Las muestras adquiridas para su procesamiento otorgarán información estadística que permitirá determinar el nivel de exactitud del modelo de reconocimiento de gestos.

Investigación bibliográfica. - Para la implementación del modelo se necesita la revisión de diversa bibliografía para identificar las características de clasificadores que se usara en el procesamiento de la información.

Investigación experimental. - Para obtener un bajo porcentaje de error en el reconocimiento se necesita procesar la información en diferentes clasificadores, así como filtros obteniendo la mejor combinación posible.

Modalidades especiales. - Se pretende generar un modelo de machine learning que permita reconocer gestos realizados con la mano mediante la utilización de datos espacial para la implementación de un sistema domótico.

2.2.2. Población y muestra

La investigación cuenta con una población desconocida pues el modelo deberá ser capaz de reconocer el gesto de cualquier persona. Para ello, se aplica la fórmula de la muestra desconociendo su tamaño de la población.

$$n = \frac{Z^2 pq}{d^2}$$

En donde:

Z = nivel de confianza,

p = probabilidad de éxito, o proporción esperada

q = probabilidad de fracaso

d = precisión (error máximo admisible en términos de proporción)

$$Z = 1.96$$

$$p = 0.5$$

$$q = 0.5$$

$$d = 0.13$$

$$n = 55.85 \approx 56$$

El tamaño de la muestra poblacional es de 56 personas. Para la selección de la muestra se utilizó el método probabilístico aleatorio simple, es decir escogiendo de forma aleatoria tantos usuarios como se requiera para completar la muestra.

2.2.3. Recolección de la información

La técnica utilizada para la recolección de información del presente proyecto de investigación será la observación mediante medios estructurados. Se utilizó software especializado y enfocado a la recolección de la información. Una muestra de 56 usuarios de diferentes edades de la Universidad Técnica de Ambato realizó 5 gestos específicos con las manos sobre el sensor Leap Motion Controller (LMC). Los gestos son CLOSE HAND, WAVE IN, WAVE OUT y PINCH. Cada gesto se repite 30 veces. Las posiciones espaciales y las direcciones en los ejes x, y, z de cada dedo es la información capturada y almacenada. El dataset se utilizó para el entrenamiento y testeo de dos modelos de Machine Learning que reconoce gestos de la mano. En este sentido, el conjunto de datos utilizado contiene 8400 filas de 56 usuarios. [39].

CAPITULO III

RESULTADOS Y DISCUSIÓN

3.1.Desarrollo de la propuesta

El SD se implementa en *tres etapas*. En la primera etapa, el sistema captura y reconoce los gestos de las manos. En la segunda etapa, se establece el protocolo de comunicación a través de MQTT. Y la tercera etapa consiste en la programación de la placa esp8266 para controlar la luz, la persiana y la puerta de acuerdo con el gesto realizado por el usuario. La **Figura 1.** muestra el esquema de funcionamiento del SD.

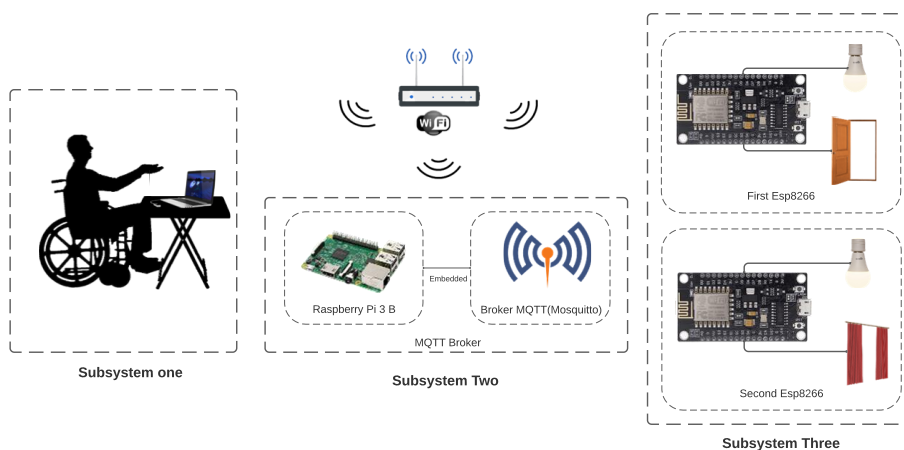


Figura 1. Esquema del Sistema Domótico

Elaborado por: Ronnie Martinez

3.1.1. Modelo de reconocimiento de gestos de la mano (HGR)

El reconocimiento del gesto de la mano se realiza a través de modelos de aprendizaje automático. Los modelos trabajan con el conjunto de datos de [39] para el entrenamiento y las pruebas. El conjunto de datos contiene 8400 muestras de 56 usuarios. En este sentido, los modelos constan de 5 módulos, como se muestra en la **Figura 2.** Los módulos son la *adquisición de datos, el preprocesamiento, la extracción de características, la clasificación y el postprocesamiento.*

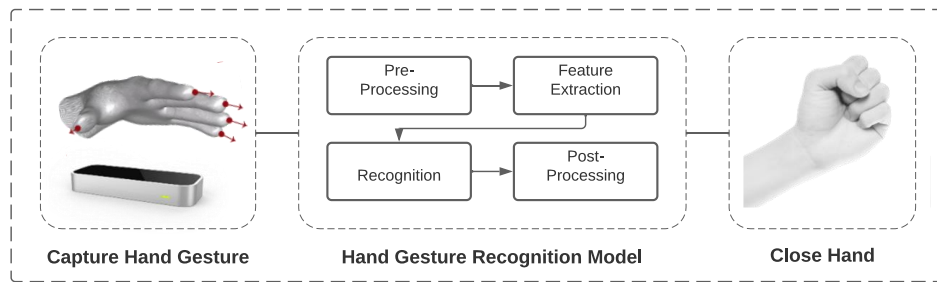


Figura 2. Esquema de captura y reconocimiento de los gestos de la mano

Elaborado por: Ronnie Martinez

3.1.1.1. Adquisición de datos.

Se selecciono LMC para la adquisición de datos. El LMC realiza un seguimiento constante de los objetos, pero inicia la grabación cuando la mano se encuentra dentro de su campo de visión. La información capturada son las posiciones espaciales y las direcciones de la mano en diferentes instantes de tiempo. Esta información es interpretada por código MEX, enviada a código MATLAB y almacenada en una estructura de MATLAB. La **Figura 3.** muestra la información almacenada en la estructura principal.

Field ▲	Value
palmPosition	[-55.9022,115.9586,79.6956]
palmNormal	[0.3473,0.9225,0.1687]
palmDirection	[-0.2458,0.2631,-0.9329]
is_left	1
is_right	0
palmVelocity	[1.1921e-07,1.1921e-07,1.1921e-07]
palmWidth	84.2500
sphere_center	[-52.2741,121.8880,41.1861]
sphere_radius	47.9163
wrist_position	[-37.3352,93.1740,142.9873]
arm_elbowPosition	[-67.4689,62.2587,389.2315]
arm_wristPosition	[-37.3352,93.1740,142.9873]
arm_direction	[0.1205,0.1237,-0.9850]
pointable	1x5 struct

Figura 3. Estructura principal

Elaborado por: Ronnie Martinez

Cada estructura principal guarda una estructura secundaria. La estructura secundaria contiene las posiciones, direcciones y velocidades de cada uno de los 5 dedos en los ejes X, Y, Z. La **Figura 4.** Muestra la información dentro de la estructura secundaria.

Fields	position	velocity	direction
1	[-92.4540,169.3548,69.7411]	[1.1921e-07,1.1921e-07,1.1921e-07]	[-0.5012,0.5744,-0.6472]
2	[-79.3164,167.8523,19.4857]	[1.1921e-07,1.1921e-07,1.1921e-07]	[0.1583,0.8041,-0.5731]
3	[-41.1017,135.3981,9.9868]	[1.1921e-07,1.1921e-07,1.1921e-07]	[-0.2311,0.6682,-0.7072]
4	[-75.6450,151.2366,-16.9730]	[1.1921e-07,1.1921e-07,1.1921e-07]	[-0.0880,0.5097,-0.8558]
5	[-66.5704,137.6270,-13.4487]	[1.1921e-07,1.1921e-07,1.1921e-07]	[-0.2485,0.4266,-0.8696]
6			

Figura 4. Estructura secundaria

Elaborado por: Ronnie Martinez

La estructura formada se limita a una ventana de 300 muestras. Se consideran dos escenarios para formar la estructura. En primer lugar, si las muestras capturadas son inferiores a la ventana establecida y el usuario retira la mano, la estructura guarda la información obtenida en este intervalo de tiempo. En segundo lugar, si las muestras capturadas son iguales a la ventana establecida y se sigue detectando la mano, la estructura guarda la información capturada dentro del intervalo de tiempo, y se forma una nueva estructura. El segundo escenario se repite hasta que el usuario retira la mano. Por último, la estructura de los dos escenarios se envía al módulo de preprocesamiento.

3.1.1.2.Preprocesamiento.

El preprocesamiento recibe la estructura con las posiciones y direcciones espaciales de las puntas de los dedos y la muñeca. Una estructura tiene un número (n) de muestras, pero se estandariza a 70 muestras ($m = 70$). En este sentido, se considera dos posibles escenarios.

- El número de muestras es menor a 70 ($n < 70$)

En este caso, de cada estructura se obtiene el número de muestras faltantes m_f . Después, se calcula el promedio \bar{X} de todos los valores que se encuentran dentro de cada estructura. Para finalmente repetir \bar{X} dentro m_f hasta $m = 70$. La **Figura 5.** muestra el proceso de estandarización si el número de muestras es menor a 70.




Figura 5. Estandarización si el número de muestras es menor a 70

Elaborado por: Ronnie Martinez

- El número de muestras es mayor a 70 ($n > 70$)

En este caso, se toma el número de muestras n existentes dentro de la estructura. Después, Se divide n para el número de muestras deseado m . El valor obtenido de la división v_{new} es redondea a un nuevo valor v_{round} . Finalmente, se calcula el promedio \bar{X} de los valores que se encuentran dentro del rango $v_{round} + 1$. Este proceso se repite hasta recorrer el vector completo y el número de muestras n sea igual al número de muestras m . La **Figura 6.** muestra el proceso de estandarización si el número de muestras es mayor a 70.

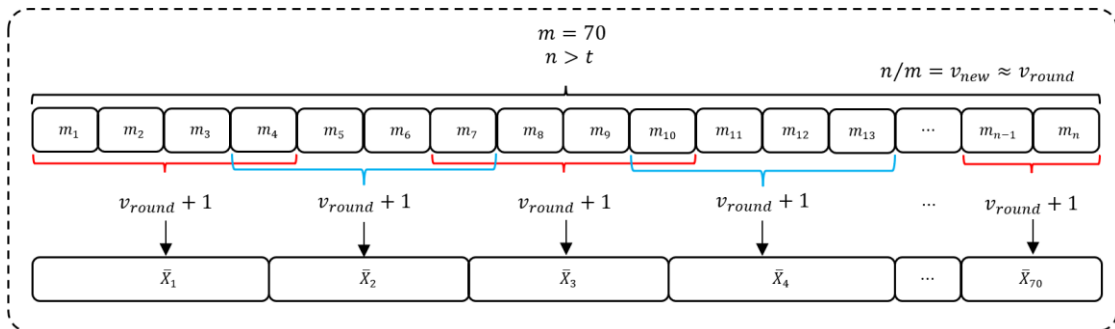




Figura 6. Estandarización si el número de muestras es mayor a 70

Elaborado por: Ronnie Martinez

La estandarización realizada conserva las características de las señales entrantes. La **Figura 7.** muestra el cambio del número de (n) a 70 muestras.



Grafica con n muestras donde $n > 70$



Grafica con n muestras donde $n = 70$

Figura 7. Estandarización de muestras de n a 70

Elaborado por: Ronnie Martínez

Después, las nuevas señales resultantes se normalizan para reducir su amplitud y pasan al módulo de extracción de características.

3.1.1.3.Extracción de características.

Este módulo trabaja con cuatro funciones de extracción de características. Estas son Variance (VAR), Slope Sign Change (SSC), Enhanced Wavelength (EWL), y Standard Deviation (SD) [40] por sus siglas en inglés. Las características se extraen por ventanas dentro de la señal por cada canal. La señal se divide en ventanas de 20 con pasos de 15. Los canales son las coordenadas X, Y, Z de cada dedo. El número total de canales es igual a 15 para posiciones espaciales y 15 para direcciones. La **Figura 8.** muestra la extracción de características por ventanas dentro de un canal. El uso de estas funciones aumenta el rendimiento y la exactitud del modelo porque caracteriza mejor la señal del gesto de la mano. Las características extraídas entran en el módulo de clasificación.




Figura 8. Extracción de características por ventanas dentro de un canal

Elaborado por: Ronnie Martinez

3.1.1.4. Clasificación

El módulo de clasificación utiliza algoritmos de aprendizaje automático. En este trabajo se prueban la máquina de vectores de apoyo (SVM) y la red neuronal artificial (ANN). En primer lugar, los dos clasificadores reciben la señal dividida en ventanas. Después, los clasificadores devuelven una etiqueta por cada ventana introducida. A continuación, un vector guarda las etiquetas resultantes. Por último, el vector de etiquetas entra en el módulo de postprocesamiento.

3.1.1.5. Postprocesamiento.

El módulo de postprocesamiento funciona con un algoritmo que vuelve a recibir el vector de etiquetas. El algoritmo recorre todo el vector y compara etiqueta por etiqueta. Este proceso devuelve un vector de etiquetas mejorado. La etiqueta que representa el gesto es el modo del vector de etiquetas. La etiqueta resultante se enviará a través del protocolo de comunicación.

3.1.2. Protocolo de comunicación

Una comunicación inalámbrica entre el PC, la Raspberry Pi3 y la Esp8266, es establecida. La **Figura 9.** muestra la comunicación entre dispositivos. Los tres dispositivos se comunican a través de un router dedicado. Además, el SD trabaja con

MQTT porque es un protocolo especializado en la comunicación entre dispositivos IoT. La arquitectura MQTT funciona con publicadores y suscriptores. Además, se utiliza la Raspberry Pi 3 como dispositivo intermediario. En este dispositivo se ha instalado un broker. El broker gestiona el envío y la recepción de mensajes entre el editor y el suscriptor.

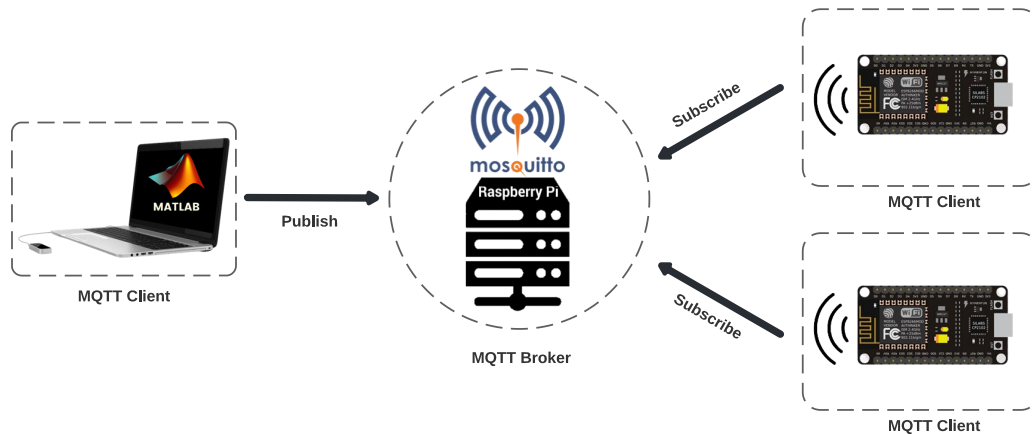


Figura 9. Arquitectura MQTT Publicador/Suscriptor

Elaborado por: Ronnie Martinez

3.1.2.1. Broker.

El broker implementado es Mosquitto. Se seleccionó este broker por ser de código abierto. Además, el SD no trabaja en un entorno agrupado (cluster). En este caso, Mosquitto envía mensajes de forma eficiente en entornos de servidores no agrupados. Adicionalmente, tiene un bajo porcentaje de mensajes duplicados y perdidos de acuerdo con la **Tabla 5**. Además, el broker contiene una configuración de usuarios y contraseñas y la contraseña de cada usuario está encriptada como medida de seguridad.

3.1.2.2. Publicador.

El PC es el publicador del mensaje al broker. El PC utiliza el complemento "MQTT in MATLAB". Este complemento permite la comunicación entre el PC y el Broker a través de MQTT. La máquina publicadora envía el usuario, la contraseña y el puerto como parámetros. Si la conexión tiene éxito, el dispositivo donde se reconoce el gesto transmite la etiqueta, el tema de suscripción y la calidad de servicio (QoS) al broker. La QoS establecida por el publicador es 0 por el enfoque del SD. Pero si la

conexión entre el PC y el bróker no se produce, entonces la máquina donde se reconoce el gesto no podrá publicar el tema de suscripción ni la etiqueta que representa el gesto reconocido.

3.1.2.3. Suscriptores.

Los suscriptores del broker son las placas Esp8266. Las placas suscriptoras utilizan la librería Arduino "PubSubClient". Esta librería permite la conexión entre la placa Esp8266 y el broker vía MQTT. Los suscriptores envían su nombre de usuario, contraseña y el tema al que desean suscribirse. Si los datos introducidos son correctos, el broker permite la conexión. Una vez aceptada la conexión, el suscriptor espera un mensaje del broker. Pero si la conexión entre la placa Esp8266 y el bróker falla, entonces la máquina suscriptora no podrá recibir el mensaje publicado de acuerdo con su tema de suscripción, en tanto los actuadores no se activan y las acciones no se llevan a cabo.

3.1.3. Control de luz, persiana y puerta

Dos placas Esp8266 son programadas para controlar diferentes actuadores. Cada placa está suscrita a un tema específico existente dentro del broker. Una placa Esp8266 controla dos actuadores diferentes, cada actuador trabaja con un gesto particular como se describe en la experimentación. La **Figura 10.** muestra cómo los diferentes actuadores fueron conectados a las placas Esp8266.

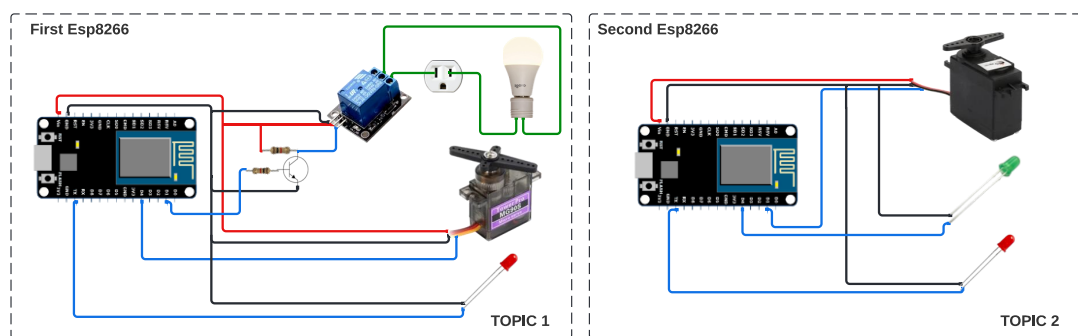


Figura 10. Control del actuador mediante la placa Esp8266

Elaborado por: Ronnie Martinez

La primera placa Esp8266 suscrita a un primer tema recibe dos etiquetas. La primera etiqueta controla el encendido y apagado de bombillas de 110 V. La segunda etiqueta controla un servomotor MG90S. El servomotor imita el funcionamiento de una

puerta real. Del mismo modo, la segunda placa Esp8266 suscrita a un segundo tema recibe dos etiquetas. La primera etiqueta controla el encendido y apagado de un LED de forma gradual. La segunda etiqueta activa un servomotor. El servomotor simula la apertura y el cierre de cortinas eléctricas.

3.2.Experimentación

Tres subsistemas forman el SD global. Además, un router dedicado proporciona la señal WI-FI para la comunicación entre los subsistemas. El router cuenta con el estándar 802.11n, seguridad WPA2-Personal, ancho de banda de red de 2,4 GHz y 72 Mbps como velocidad de envío/recepción. En este sentido, se configuró el router con un rango de direcciones IP estáticas privadas y la dirección MAC de cada dispositivo. Esta configuración permitiendo la conexión únicamente de dispositivo que se encuentren dentro de un rango de direcciones IP específico con una dirección MAC concreta.

3.2.1. Primer subsistema

El primer subsistema reconoce el gesto y publica la etiqueta que lo representa. Este sistema está desarrollado en la versión R2019a del IDE de MATLAB. Un PC DELL con sistema operativo WINDOWS 10 aloja el IDE. Este ordenador cuenta con un procesador INTEL CORE i7 de 7ª generación, 16 Gb de RAM, cuatro procesadores lógicos de 2,70 GHz, y una tarjeta de red inalámbrica Intel(R) Dual Band Wireless-AC 3165. En este sentido, un cable híbrido USB 2/3 conecta el sensor LMC con el PC. El PC controla el LMC con la versión 3.2.1 de su SDK. Los modelos HGR utilizan la información captada por LMC para alimentar los clasificadores. El primer modelo HGR utiliza una ANN multiclase como clasificador. La ANN funciona con dos capas ocultas y una capa de salida. La primera capa oculta tiene una función de activación Relu y 25 neuronas. Mientras que la segunda capa oculta tiene una función de activación Logsig y 15 neuronas. La capa de salida utiliza una función Softmax. Por último, las funciones de optimización llevan a cabo la técnica de ajuste de pesos. Las funciones de optimización son la entropía cruzada y el descenso de gradiente. La ANN se entrenó con 2000 interacciones y 1,0e1 como factor de regularización. Por otro lado, el segundo modelo de HGR utiliza SVM como clasificador. El clasificador SVM utiliza un kernel gaussiano y una escala de orden

diez como hiperparámetros. El modelo de HGR recibe la información del LMC. La información pasa por los cinco módulos descritos en la sección anterior y devuelve una etiqueta. El modelo HGR con ANN fue seleccionado para el SD porque tiene una precisión de prueba del 92,759% y una desviación estándar de 1,6. En cambio, SVM tiene una precisión del 91,413% y una desviación estándar de 1,75. Aunque los dos clasificadores no difieren significativamente en sus porcentajes de prueba, ANN es el clasificador seleccionado porque los dos clasificadores son estadísticamente diferentes. En este sentido, las desviaciones estándar de los clasificadores no se solapan.

Cuando el subsistema uno termina el reconocimiento, publica la etiqueta que representa el gesto. El complemento "MQTT in MATLAB" permite a MATLAB publicar la etiqueta y el tema a través del protocolo MQTT. MATLAB utiliza la versión 1.5 de "MQTT in MATLAB". La función PUBLISH envía la etiqueta y el tema a través de una red inalámbrica. La **Figura 11.** muestra el funcionamiento del primer subsistema.

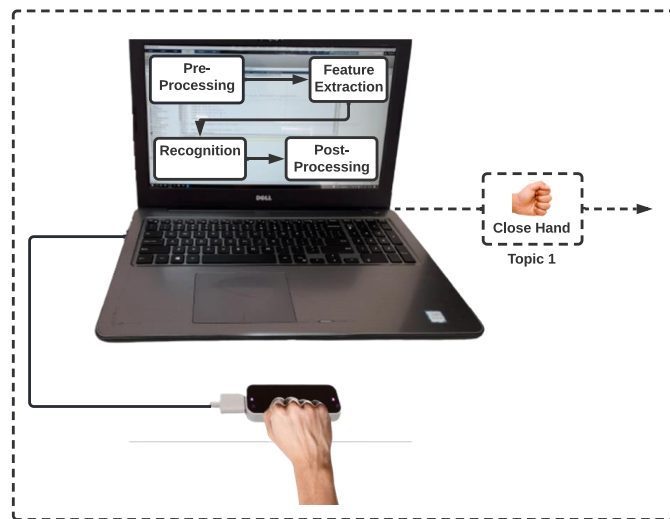


Figura 11. Esquema del primer subsistema

Elaborado por: Ronnie Martinez

3.2.2. Segundo Subsistema

El segundo subsistema está en la Raspberry Pi 3 B V1.2. El modelo Raspberry Pi 3 B tiene un procesador ARMv8 de 64-bit quad-core 1.2 GHz, 1 GB de RAM, Wi-Fi 802.11 b/g/n, alimentación de 5V/2,5 con micro USB. La Raspberry Pi funciona con

la versión 3.1.1 del broker Mosquitto. En este sentido, la Raspberry Pi recibe la etiqueta que representa el gesto y el tema de la suscripción desde el subsistema uno. En función del tema, el broker gestiona la recepción y el envío de mensajes entre los subsistemas uno y tres. El broker envía la etiqueta del gesto a todas las máquinas suscritas a ese tema. La **Figura 12.** muestra el funcionamiento del segundo subsistema.




Figura 12. Esquema del segundo subsistema

Elaborado por: Ronnie Martinez

3.2.3. Tercer Subsistema

El tercer subsistema funciona con dos placas Wi-Fi NODEMCU V2 Esp8266. Cada placa Esp8266 tiene 128 KB de RAM, pila TCP/IP, Wi-Fi 802.11 b/g/n, 15 pines digitales para cada lado, alimentación de 5V y entrada/salida de 3,3V. Las placas Esp8266 están suscritas a diferentes temas. Los temas añadidos al broker por el subsistema uno son "Habitación" y "Entrada". El tema "Habitación" contiene los gestos de CLOSE HAND y WAVE IN. Del mismo modo, el tema "Entrada" tiene los gestos WAVE OUT y PINCH. El gesto OPEN HAND define en las dos placas una acción de parada de emergencia. Del mismo modo, ambos tableros tienen un LED rojo conectado al pin 1. El LED rojo se enciende cuando la placa ESP8266 se conecta con éxito al router.

Primer Esp8266. La primera placa Esp8266 recibe los gestos de CLOSE HAND y WAVE IN. El gesto de CLOSE HAND controla el encendido y apagado de una bombilla de 110 V. La luz activa su funcionamiento a través de un relé de 5V KY-

019. Este relé controla los 110V a través de los 5V que recibe de la placa Esp8266. Entre la placa y el relé hay un transistor 2N3940. El transistor cambia la tensión enviada por la Esp8266 a los 5 voltios que necesita el relé. Del mismo modo, el gesto WAVE IN controla un servomotor MG90S a través del ping 2. El servomotor imita el funcionamiento de una puerta real.

Segundo Esp8266. La segunda tarjeta Esp8266 recibe los gestos WAVE OUT y PINCH. El gesto WAVE OUT controla un servomotor DS04-NFC. El ping 5 envía instrucciones al servomotor para que gire en el sentido de las agujas del reloj y en sentido contrario. El servomotor tiene una tensión de funcionamiento entre 4,8 y 6 V. La placa Esp8266 alimenta el servomotor a través de su ping VIN, que proporciona 5V. El servomotor simula la apertura y el cierre de las cortinas eléctricas. Del mismo modo, el gesto PINCH controla el encendido y apagado de un LED. El ping 2 de la placa Esp8266 alimenta el LED. El LED se enciende gradualmente. La **Figura13.** muestra el funcionamiento del tercer subsistema.




Figura 13. Esquema del tercer subsistema

Elaborado por: Ronnie Martinez

Además, se calculó el tiempo teórico de entrega de la etiqueta para todo el SD. El tiempo de propagación y el tiempo de transmisión forman el tiempo de entrega por sectores. En este caso, el tiempo de propagación se calcula a partir de las características del router. La división entre el alcance del router y la velocidad de propagación genera el tiempo de propagación. El alcance del router en interiores es de 50 m según el estándar 802.11n [41]. Mientras tanto, la velocidad de propagación en el aire es igual a 3×10^8 [42]. En el mismo sentido, la división entre el tamaño promedio de los paquetes y la velocidad de transmisión genera el tiempo de

transmisión. El tamaño promedio de los paquetes se calcula a partir de los datos capturados por el software Wireshark. A continuación, se fijó la velocidad media de transmisión para el PC, el ROUTER y la RASPBERRY PI en 72 Mbps. Finalmente, se suma los tiempos de entrega de las cuatro secciones del sistema para obtener el tiempo de entrega teórico de todo el SD.

3.2.4. Control de actuadores

El publicador, suscriptor y bróker se encuentra interconectados de manera inalámbrica. La arquitectura de MQTT impide que exista una conexión directa entre el publicador y el suscriptor. En este sentido, puede suscitarse problemas al momento de enviar un mensaje desde el publicador hasta el suscriptor que controla los actuadores, de la misma forma al momento que el suscriptor desea controlar los actuadores.

La sección 3.1.2.2 y 3.1.2.3 describe el comportamiento al empezar la conexión entre el publicador o el suscriptor con el broker. Sin embargo, si la conexión entre el publicador o el suscriptor con el broker se interrumpe por un problema en la red, entonces el broker conserva la sesión iniciada hasta que el publicador nuevamente se conecte. En este caso, el publicador no podrá enviar mensajes. En el caso del suscriptor, la sesión se cierra y deberá iniciar sesión nuevamente para poder recibir los mensajes del publicador. Al manejar una calidad de servicio “0” los mensajes enviados por el publicador los recibirá el bróker y lo remitirá al suscriptor una sola vez esté o no conectado. Por otro lado, si el problema de conexión con el bróker es por una falta de energía en la Raspberry Pi, el publicador y el suscriptor deberán iniciar sesión nuevamente una vez el bróker se encuentre en línea.

El suscriptor controla tanto la iluminación como el funcionamiento de una cortina y una puerta. El control de los actuadores para la iluminación se lo maneja a través de estados a nivel de código. Los estados son 1 (encendido) y 2 (apagado). Al conectarse el actuador, el foco inicia con su estado en 1. El foco cambia de estado a 2 una vez el suscriptor haya recibido el gesto CLOSE HAND. El estado cambia a 1 nuevamente cuando el suscriptor recibe el mismo gesto. En el caso del foco con un encendido gradual, los estados cambian. Los estados son 1 (encendido), 2 (medio), 3 (apagado). Al conectarse el actuador, el foco inicia con su estado en 1. El foco

cambia de estado a 2 una vez el suscriptor haya recibido el gesto PINCH. El estado cambia a 3 nuevamente cuando el suscriptor recibe el mismo gesto y regresa al estado 1 cuando recibe nuevamente el mismo gesto. El mecanismo para activar la cortina esta controla mediante un intervalo de tiempo y de forma mecánica en el caso de producirse una descompostura. Una vez el suscriptor ha recibido el gesto WAVE OUT el servomotor girar en sentido antihorario por un intervalo de tiempo determinado. Al recibir el mismo gesto, el servomotor girar en sentido horario por el mismo intervalo de tiempo. Si se produce un fallo a nivel mecánico en el servomotor, un fin de carrera detiene el funcionamiento del servomotor.

3.3. Resultado

Diez usuarios probaron el SD en línea. Cada usuario ejecutó todos los gestos 30 veces. Se obtiene un conjunto de datos de 1500 muestras. Las pruebas alcanzan una media del 84,07% de precisión en el funcionamiento del SD. La **Tabla 8.** muestra los resultados de las pruebas.

	Open Hand	Close Hand	Wave In	Wave Out	Pinch	Total reconocido por usuario de 150	Índice de precisión por usuario (%)
Usuario1	30	27	30	27	21	135	90,00
Usuario2	30	29	30	26	8	123	82,00
Usuario3	30	29	27	27	16	129	86,00
Usuario4	30	24	24	23	11	112	74,67
Usuario5	30	26	29	28	20	133	88,67
Usuario6	30	27	30	26	17	130	86,67
Usuario7	30	28	29	27	9	123	82,00
Usuario8	30	24	27	27	17	125	83,33
Usuario9	30	28	30	27	18	133	88,67
Usuario10	30	28	28	23	9	118	78,67
Total de gestos reconocidos de 300	300	270	284	261	146	1261	84,07
Índice de precisión por gesto (%)	100	90,00	94,67	87,00	48,67	84,07	

Tabla 8. Resultados de la evaluación de los gestos del Sistema Domótico

Elaborado por: Ronnie Martinez

En el mismo sentido, las pruebas online generan tiempos de respuesta por usuario para cada gesto realizado. Se tiene un tiempo medio de 88,17 milisegundos en el

modelo HGR. La **Tabla 9.** muestra los tiempos promedio obtenidos por gesto y por usuario.

	Open Hand	Close Hand	Wave In	Wave Out	Pinch	Average recognition time by user (ms)
Usuario1	78,30	84,33	73,57	72,93	62,33	74,29
Usuario2	73,70	111,70	95,27	90,80	79,43	90,18
Usuario3	75,70	73,37	72,17	95,40	113,67	86,06
Usuario4	85,00	92,77	69,83	112,13	79,83	87,91
Usuario5	146,10	89,77	93,53	78,53	81,43	97,87
Usuario6	85,50	83,53	87,30	109,57	118,20	96,82
Usuario7	79,30	92,43	98,10	95,43	97,90	92,63
Usuario8	46,30	91,47	94,83	108,67	95,23	87,30
Usuario9	72,10	99,83	83,17	75,23	98,00	85,67
Usuario10	47,30	87,10	78,53	82,00	119,70	82,93
Average recognition time by gesture (ms)	78,93	90,63	84,63	92,07	94,57	88,17

Tabla 9. Evaluación del tiempo del modelo de HGR

Elaborado por: Ronnie Martinez

Se toma el tamaño de 160 paquetes dentro del tráfico. El tiempo de entrega teórico del SD es de 30,7 ms. La **Tabla 10.** muestra los tiempos de propagación y transmisión resultantes.

Average packet size (bits)	Total transmission time of SD (ms).	Total propagation time of SD (ms)	Theoretical delivery time of SD (ms)
541,6	30,07	0,6	30,7

Tabla 10. Tiempo teórico de entrega del Sistema Domótico

Elaborado por: Ronnie Martinez

La **Figura 14.** muestra los resultados de las pruebas por gesto para cada usuario. El eje X representa los usuarios. Al mismo tiempo, el eje Y representa el número de gestos reconocidos. Los gestos CLOSE HAND, WAVE IN y WAVE OUT no difieren significativamente en el número de gestos reconocidos. En cambio, el gesto PINCH tiene un número bajo de gestos reconocidos.

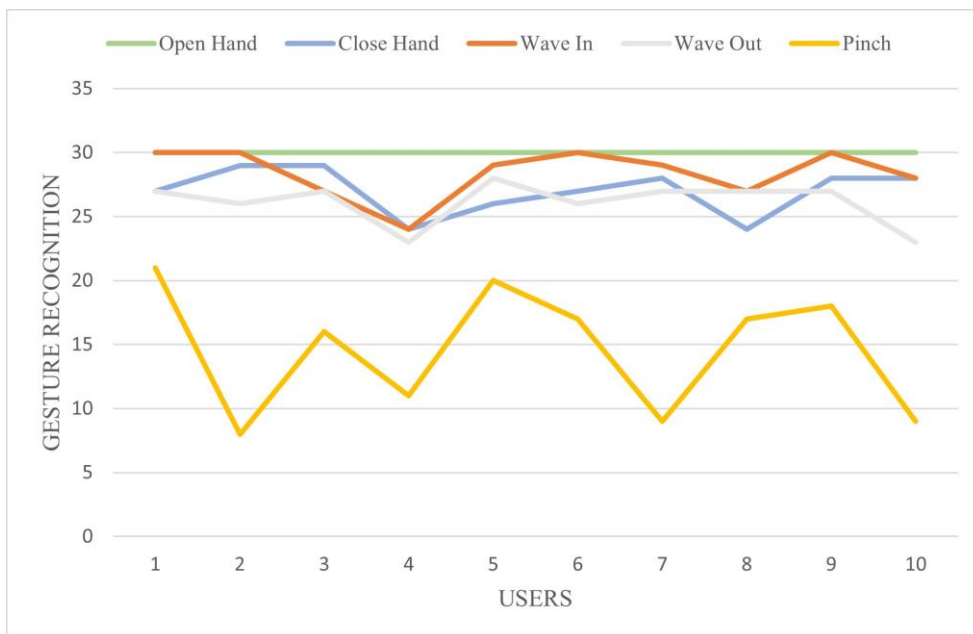


Figura 14. Reconocimiento de gestos por usuario

Elaborado por: Ronnie Martinez

La **Figura 15.** muestra el porcentaje de precisión de cada gesto reconocido por el SD. En este contexto, OPEN HAND y WAVE IN es el gesto con el mayor porcentaje de precisión, con un 100% y un 94,67% respectivamente. Por otro lado, PINCH es el gesto con el porcentaje de precisión más bajo, con un 48,67%. Los gestos CLOSE HAND y WAVE IN tiene un porcentaje de precisión de 90% y 87%.

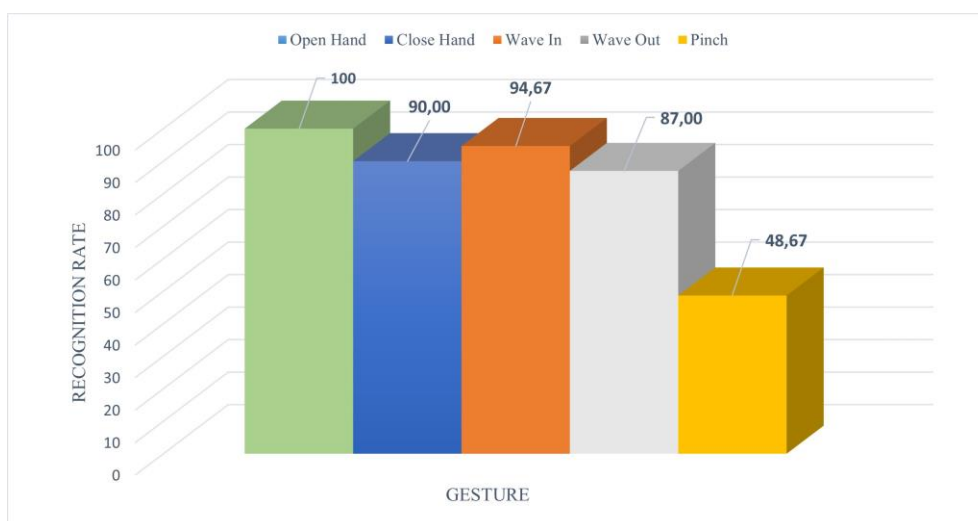


Figura 15. Tasa de reconocimiento por gestos

Elaborado por: Ronnie Martinez

La **Figura 16.** muestra la matriz de confusión de la prueba en línea del SD. La matriz resulta de la evaluación aplicada con los cinco gestos mencionados en este trabajo. Además, el SD utiliza la ANN como clasificador del sistema en línea.

On-Line HGR model with ANN

1	300					100.0%	
2	9	270	2		19	90.0%	10.0%
3	1	6	284	8	1	94.7%	5.3%
4	11	9	19	261		87.0%	13.0%
5	27	107	16	4	146	48.7%	51.3%
	86.2%	68.9%	88.5%	95.6%	88.0%		
	13.8%	31.1%	11.5%	4.4%	12.0%		
	1	2	3	4	5		

Predicted Class

Figura 16. Matriz de confusión del modelo de HGR en línea con ANN

Elaborado por: Ronnie Martinez

En relación con la literatura científica y los resultados obtenidos, se informa de que el trabajo con la CNN y una cámara de CCTV para detectar los gestos de la mano tiene una precisión de prueba del 99,97%. Sin embargo, el alcance de la señal de comunicación se limita al del dispositivo Bluetooth HC-05. Además, no informan de una prueba en línea ni del tiempo de procesamiento. Por otro lado, la literatura científica también reporta un SD que trabaja con señales de EEG y un SD con reconocimiento de voz para el idioma portugués reportan resultados de eficiencia del 90% y 95% de precisión en pruebas en línea, respectivamente, pero solo el SD con reconocimiento de voz menciona cómo obtuvieron la eficiencia de su sistema. Sin embargo, nuestro SD presenta el modelo HGR con una precisión del 92,759% en las pruebas fuera de línea con un tiempo de respuesta de 88,17 ms. En el mismo sentido, el SD tiene una precisión del 84,07% en línea con un tiempo de respuesta teórico de 118,87 ms. La precisión disminuye debido al bajo porcentaje de reconocimiento de PINCH. El HGR tiene un alto grado de confusión entre los gestos CLOSE HAND y PINCH, como se muestra en la **Figura 16.** La confusión se debe a la similitud entre la dirección y la posición de los dedos en ambos gestos. En este contexto, la tasa de

reconocimiento de nuestro SD es muy competitiva con los SD mencionados. Dado que el LMC es un dispositivo especializado en la captación de información de la mano, nuestro SD supera las desventajas de los mencionados SD como ayuda para las personas con DF y da una respuesta en tiempo real.

CAPITULO IV

CONCLUSIONES Y RECOMENDACIONES

Conclusiones

- En este trabajo, se desarrolló un SD que utiliza el reconocimiento de gestos de la mano para personas con DF. El SD funciona con tres subsistemas conectados de forma inalámbrica. El primer subsistema consiste en un sistema de reconocimiento de gestos de la mano. Este subsistema utiliza una ANN como clasificador. Además, este subsistema envía el gesto mediante el protocolo MQTT. El segundo subsistema gestiona el envío y la recepción de mensajes entre los subsistemas uno y tres con el broker mosquitto. Por último, el tercer subsistema activa diferentes actuadores en función del gesto que el broker envía en tiempo real.
- El primer subsistema se prueban dos clasificadores. Estos son ANN y SVM. Las diferencias entre estos clasificadores no son significativas porque la desviación estándar no se solapa.
- El modelo HGR se entrenó con 6480 observaciones y se probó con 1680 observaciones offline. La prueba offline tuvo una tasa de precisión del 92,759%. Además, se probó el SD en línea utilizando 1500 observaciones. Esta prueba arrojó una precisión del 84,07% con los cinco gestos detallados en las secciones anteriores. Además, se observó que el uso del gesto PINCH disminuye el porcentaje de precisión del SD. Este problema se debe a que el gesto PINCH tiene un alto grado de confusión con el gesto CLOSE HAND. Por lo tanto, cuando el SD funciona sin el gesto PINCH, aumenta su precisión hasta el 92,92%.
- Además, el tiempo medio de respuesta del SD fue evaluado. El tiempo del SD se obtiene de la suma del tiempo de entrega teórico y el tiempo de respuesta medio del modelo HGR. En este sentido, el modelo HGR genera la etiqueta que identifica el gesto en 88,17 ms. Además, el tiempo de entrega teórico del mensaje al actuador se generó en el escenario más extremo de alcance de la señal inalámbrica. El alcance máximo del router inalámbrico con un estándar 802.11n es de 50 metros, la velocidad de transmisión es de 72 Mbps y el peso

medio de los paquetes es de 541,6 bits. Como resultado, el tiempo de entrega teórico de la etiqueta entre el PC, la Raspberry Pi y la Esp8266 es de 30,7 ms. A este valor, se agregó el tiempo de respuesta del modelo HGR. En consecuencia, el SD transmite la etiqueta en un tiempo total de 118,87 ms.

Recomendaciones

- Se recomienda el uso del SD a personas que tiene problemas físicos como afasia, espasticidad y déficits motores.
- Se recomienda analizar el desarrollo del SD con la finalidad de cubrir un mayor rango de patologías físicas ya que se puede adaptar diferentes periféricos de entrada como de salida de acorde a la DF de cada usuario.
- En el futuro se recomienda el desarrollo de una APP móvil para un familiar a fin de controlar el estado de los diferentes actuadores.

BIBLIOGRAFÍA

- [1] H. Collaguazo, P. Córdova y C. Gordón, «Communication and Daily Activities Assistant System for Patient with Amyotrophic Lateral Sclerosis,» de *2018 International Conference on eDemocracy & eGovernment (ICEDEG)*, Ambato, Ecuador, 2018.
- [2] J. Errobidart, A. J. Uriz, E. Gonzalez, I. E. Gelosi y J. A. Etcheverry, «Offline domotic system using voice comands,» de *2017 Eight Argentine Symposium and Conference on Embedded Systems (CASE)*, Buenos Aires, Argentina, 2017.
- [3] N. Lopez, S. Ponce, D. Piccinini, E. Perez y M. Roberti, «From Hospital to Home Care: Creating a Domotic Environment for Elderly and Disabled People,» de *IEEE Pulse*, 2016.
- [4] Consejo Nacional para la Igualdad de Discapacidades-CONADIS, «Consejo Nacional para la Igualdad de Discapacidades-CONADIS,» Consejo Nacional para la Igualdad de Discapacidades-CONADIS, Enero 2022. [En línea]. Available: <https://www.consejodiscapacidades.gob.ec/estadisticas-de-discapacidad/>. [Último acceso: 9 Marzo 2022].
- [5] M. J. Cañizares Villalba, K. Calderón-Salavarría y D. Vásquez Cedeño, «Mortality and disability after a first episode of cerebrovascular disease in Guayaquil, Ecuado,» de *Neurología Argentina*, 2019.
- [6] Organización Mundial de Salud, «OMS,» 19 Noviembre 2013. [En línea]. Available: <https://www.who.int/es/news-room/fact-sheets/detail/spinal-cord-injury>. [Último acceso: 10 Marzo 2022].
- [7] R. Gassert y V. Dietz , «Rehabilitation robots for the treatment of sensorimotor deficits: a neurophysiological perspective,» de *Journal of NeuroEngineering and Rehabilitation*, 2018.
- [8] E. Segura, J. Grau Sánchez, D. Sanchez Pinsach, M. De la Cruz, E. Duarte, . J.

- Lluís Arcos y A. Rodríguez Fornells, «Designing an app for home-based enriched Music-supported Therapy in the rehabilitation of patients with chronic stroke: a pilot feasibility study,» de *Brain Inj.* 2021 Nov 10;35(12-13):1585-1597, 2021.
- [9] A. Machado, «Cómo hacer cosas sin palabras,» 2004. [En línea]. Available: <https://www.aacademica.org/silvia.espanol/45>. [Último acceso: 06 Marzo 2022].
- [10] Ultraleap, «Ultraleap,» Ultraleap, [En línea]. Available: <https://docs.ultraleap.com/>. [Último acceso: 2022 Enero 07].
- [11] N. Bentabet y N.-E. Berrached, «Synchronous P300 based BCI to control home appliances,» de *2016 8th International Conference on Modelling, Identification and Control (ICMIC)*, Algiers, Algeria, 2016.
- [12] S. Luna Romero, P. Delgado Espinoza, F. Rivera Calle y L. Serpa Andrade, «A Domotics Control Tool Based on MYO Devices and Neural Networks,» de *Advances in Human Factors and Ergonomics in Healthcare and Medical Devices*, Los Angeles, Estados Unidos, 2017.
- [13] . J. D. Celis Nuñez, R. A. Llanos Castro, B. Medina Delgado, . S. Sepúlveda Mora y S. A. Castro Casadiego, «Acoustic and Language Modeling for Speech Recognition of a Spanish Dialect from the Cucuta Colombian Region,» Bogota, 2017.
- [14] J. Celis, R. Llanos, S. Castro, S. Sepúlveda, B. Medina, D. Guevara, L. Camargo y J. Gómez, «Voice processing with Internet of Things for a home automation system,» de *2018 IEEE XXV International Conference on Electronics, Electrical Engineering and Computing (INTERCON)*, Lima, Peru, 2018.
- [15] G. Borba, A. Milanés y G. A. Rodrigues Barbosa, «A responsible approach towards user and personal voice assistants interaction,» de *IHC '19: Proceedings of the 18th Brazilian Symposium on Human Factors in Computing Systems*, 2019.
- [16] N. Jayaweera, B. Gamage, M. Samaraweera, S. Liyanage, S. Lokuliyana y T.

- Kuruppu , «Gesture driven smart home solution for bedridden people,» de *2020 35th IEEE/ACM International Conference on Automated Software Engineering Workshops (ASEW)*, Melbourne, VIC, Australia, 2020.
- [17] M. Mendula, S. Khodadadeh, S. Bacanli, S. Zehtabian, H. Sheikh, L. Bölöni, D. Turgut y P. Bellavista, «Interaction and Behaviour Evaluation for Smart Homes: Data Collection and Analytics in the ScaledHome Project,» de *MSWiM '20: Proceedings of the 23rd International ACM Conference on Modeling, Analysis and Simulation of Wireless and Mobile Systems*, 2020.
- [18] P. Annie, «Mail Online,» Science & Tech, 24 Abril 2019. [En línea]. Available: <https://www.dailymail.co.uk/sciencetech/article-6956531/Amazon-employees-listening-Alexa-recordings-customers-live.html>. [Último acceso: 02 Junio 2022].
- [19] N. Balta Ozkan, B. Botelerb y O. Amerighic, «European smart home market development: Public views on technical and economic aspects across the United Kingdom, Germany and Italy,» de *Energy Research & Social Science*, 2014.
- [20] R. K. Moore, «A comparison of the data requirements of automatic speech recognition systems and human listeners,» de *8th European Conference on Speech Communication and Technology, EUROSPEECH 2003 - INTERSPEECH 2003*, Geneva, Switzerland, 2003.
- [21] K. Aditya, P. Chacko, D. Kumari, D. Kumari y S. Bilgaiyan, «Recent Trends in HCI: A survey on Data Glove, LEAP Motion and Microsoft Kinect,» de *2018 IEEE International Conference on System, Computation, Automation and Networking (ICSCA)*, Pondicherry, India, 2018.
- [22] F. Weichert, D. Bachmann, B. Rudak y D. Fisseler, «Analysis of the Accuracy and Robustness of the Leap Motion Controller,» de *Department of Computer Science VII, Technical University Dortmund, Dortmund 44221*, Germany, 2013.
- [23] S. Ameer y A. Khalifa, «Chronological pattern indexing: An efficient feature extraction method for hand gesture recognition with Leap Motion,» de *Journal*

of Visual Communication and Image Representation, 2020.

- [24] J. Pauchot, L. D. Tommaso, A. Lounis, M. Benassarou, P. Mathieu, D. Bernot y S. Aubry, «Leap Motion Gesture Control With Carestream Software in the Operating Room to Control Imaging: Installation Guide and Discussion,» 2015.
- [25] L. J. Aguilar, *Internet de las cosas un futuro hiperconectado*, Bogotá: Alfaomega Alphaeditorial, 2021, p. 5.
- [26] N. Nikolov, «Research of MQTT, CoAP, HTTP and XMPP IoT Communication protocols for Embedded Systems,» de *2020 XXIX International Scientific Conference Electronics (ET)*, Sozopol, Bulgaria, 2020.
- [27] T. Yokotani y Y. Sasaki, «Comparison with HTTP and MQTT on required network resources for IoT,» de *2016 International Conference on Control, Electronics, Renewable Energy and Communications (ICCEREC)*, Bandung, Indonesia, 2016.
- [28] C. B. Gemirter, Ç. Şenturca y Ş. Baydere, «A Comparative Evaluation of AMQP, MQTT and HTTP Protocols Using Real-Time Public Smart City Data,» de *2021 6th International Conference on Computer Science and Engineering (UBMK)*, Ankara, Turkey, 2021.
- [29] M. Bender, E. Kirdan, M.-O. Pahl y G. Carle, «Open-Source MQTT Evaluation,» de *2021 IEEE 18th Annual Consumer Communications & Networking Conference (CCNC)*, Las Vegas, NV, USA, 2021.
- [30] S. Gruener, H. Koziolok y J. Rückert, «Towards Resilient IoT Messaging: An Experience Report Analyzing MQTT Brokers,» de *2021 IEEE 18th International Conference on Software Architecture (ICSA)*, Stuttgart, Germany, 2021.
- [31] J. M. P. Bermejo, «SISTEMA DE CONTROL DOMÓTICO INALÁMBRICO, PARA PERSONAS,» Ambato, 2015.
- [32] T. F. Waddell, B. Zhang y S. Sundar, «Human–Computer Interaction,» de *The International Encyclopedia of Interpersonal Communication*, Penn State

University, USA, 2015.

- [33] M. L. Seuba, Internet de las cosas, Madrid: RAMA, 2019, p. 173.
- [34] Ali Ismail Awad; Steven Furnell; Marcin Paprzycki; Sudhir Kumar Sharma, Security in Cyber-Physical Systems: Foundations and Applications, Janusz Kacprzyk, Systems Research Institute, Polish Academy of Sciences,, 2021, p. 4.
- [35] J. Sancho, Machine Learning y Deep Learning, Rama, 2020.
- [36] Eduardo Francisco Caicedo; Jesús Alfonso López, Una aproximación practica a las redes neuronales artificiales, Programa Editorial Universidad del Valle, 2017, p. 25.
- [37] J. Bell, «What Is Machine Learning?,» de *Machine Learning: Hands-On for Developers and Technical Professionals*, 2015.
- [38] Ramon López de Mántaras Badia; Meseguer González, Pedro, Inteligencia Artificial, España: Editorial CSIC Consejo Superior de Investigaciones Científicas, 2017.
- [39] R. Nogales, M. E. Benalcazar, B. Toalumbo, A. Palate, R. Martinez y J. Vargas, «Construction of a Dataset for Static and Dynamic Hand Tracking Using a Non-invasive Environment,» de *Advances and Applications in Computer Science, Electronics and Industrial Engineering*, 2021.
- [40] J. Too, A. Abdullah y N. Saad, «MathWorks,» MathWorks, 11 Diciembre 2020. [En línea]. Available: <https://la.mathworks.com/matlabcentral/fileexchange/71514-emg-feature-extraction-toolbox>. [Último acceso: 21 Junio 2022].
- [41] J. Jansons y T. Dorins, «Analyzing IEEE 802.11n standard: outdoor performanace,» de *2012 Second International Conference on Digital Information Processing and Communications (ICDIPC)*, Klaipeda, Lithuania, 2012.
- [42] J. Á. Berná Galiano, M. Pérez Polo y L. M. Crespo Martínez, Redes de

computadores para ingenieros en informática, Alicante , España: Publicaciones de la Universidad de Alicante, 2002.