

Universidad Autónoma de Baja California
Instituto de Ingeniería
Maestría y Doctorado en Ciencias e Ingeniería



**Software para Detección de Movimientos
Humanos en Señales WiFi utilizando
Algoritmos de Aprendizaje de Máquina**

Tesis que para obtener el grado de:

MAESTRO EN CIENCIAS

Presenta

Emmanuel López Hernández

Director de Tesis:

Dr. Félix Fernando González Navarro

Codirector de Tesis:

Dra. Brenda Leticia Flores Ríos

Dedicatorias

Agradezco a Dios por la vida recibida, su amor, y cada oportunidad nueva de crecer, aprender y ser mejor.

Gracias a mis padres, hermanos, y seres queridos, quienes con su amor, paciencia y dedicación me han motivado a alcanzar esta nueva meta en la vida y a nunca darme por vencido.

A mis profesores, que siempre estuvieron brindándome su apoyo y conocimiento de manera constante; por las clases impartidas, sus anotaciones, comentarios, aclaración de dudas y correcciones. Y por haberme otorgado las herramientas académicas necesarias para seguirme forjando como profesional e investigador de provecho.

Y finalmente, a mis compañeros, con quienes compartí las arduas horas de clase, por los tiempos de trabajo en equipo, de investigación y estudio.

En definitiva, gracias por estar presentes en esta etapa tan difícil y disfrutable a la vez, y motivarme a siempre dar lo mejor e ir por más.

Reconocimientos

Se agradece el apoyo de la Universidad Autónoma de Baja California (UABC) por el tiempo de formación recibido y calidad en la enseñanza de sus docentes; así como la oportunidad brindada de crecer profesionalmente.

Al Instituto de Ingeniería por su apoyo docente y formación de investigadores preparados para afrontar nuevos desafíos en la ciencia y tecnología; también por la facilitación de áreas de experimentación y materiales necesarios para el desarrollo del proyecto.

Al Dr. Félix Fernando González Navarro, por su labor como asesor, y constante exigencia para el alcance de los objetivos y metas en tiempo y forma; por su instrucción y tiempo dedicado en la presente investigación, sobretodo en el tema de Aprendizaje Máquina, parte fundamental de la solución de software desarrollada.

A la Dra. Brenda Leticia Flores Ríos, por su esmero, tiempo y dedicación en la asesoría brindada, y su instrucción en torno a la metodología de investigación implementada. Sus constantes comentarios y directrices orientados hacia la mejora de los objetivos a alcanzar.

Resumen

En la actualidad el uso de tecnologías de red, software y Data Mining es común en diferentes ámbitos: académicos, empresariales, salud, etc. Por ello, se ha pensado y desarrollado una solución de software que contempla el manejo de señales WiFi bajo el estándar IEEE 802.11n (WiFi 4) utilizado ampliamente en las comunicaciones inalámbricas, que además haga uso de los datos recolectados del medio ambiente a través de algoritmos de aprendizaje máquina con el fin de realizar una correcta detección de actividades humanas, aprovechando los beneficios de cada una de estas disciplinas.

Se ha denominado WIFIALR a la presente solución de software, que es capaz de identificar entre diferentes tipos de actividades al interior: GO TO BED, FALL, PICK UP, RUN, SIT DOWN, STAND UP y WALK empleando técnicas de aprendizaje máquina. Como resultado de la ejecución del software, se genera una alerta a través de consola de comandos y mediante una interfaz de ventana, las cuales son mostradas al usuario como respuesta de la actividad humana realizada a través de la LOS (Linea de Visión, por sus siglas en inglés), de dos dispositivos WiFi de transmisión y recepción. Esta solución tiene un gran potencial en cuanto a asistencia médica se refiere, especialmente para personas con discapacidad y adultos mayores con riesgos de sufrir caídas o de realizar actividades arriesgadas para su salud; en cuanto al tema de seguridad, se puede emplear para prevención de robos a casas habitación; así como en el ambiente laboral en fábricas, para evitar riesgos y accidentes laborales, y alertar sobre una violación al espacio seguro, o una acción de movimiento inseguro.

Contenido

1	Introducción	1
1.1	Evolución de WiFi	1
1.2	Planteamiento del problema	2
1.3	Justificación	4
1.4	Objetivos	6
1.4.1	Objetivo General	6
1.4.2	Objetivos Específicos	6
1.4.3	Metas	7
1.5	Estructura del documento	7
2	Marco Teórico	8
2.1	Seguridad	8
2.1.1	Definición	8
2.1.2	Teoría del autocontrol	9
2.1.3	Seguridad en el interior	10
2.2	Cuidado de la salud	12
2.2.1	Definición	12
2.2.2	Cuidado de adultos mayores	12
2.3	Alertas preventivas mediante software	13
2.3.1	Definición	13
2.3.2	Aplicaciones	14
2.4	Señales WiFi	15
2.4.1	Definición	15
2.4.2	Principio Básico del Sistema de Detección Inalámbrica	18
2.4.3	Uso de señales WiFi en el Reconocimiento de la Actividad Humana	19
2.4.4	Seguridad con WiFi	21
2.4.5	Resultado de Revisión de la Literatura	22
2.4.6	Reflexión de lo encontrado	29

3	Materiales y Métodos	31
3.1	Dispositivos utilizados	31
3.1.1	Características técnicas	32
3.1.2	Adaptadores de red	33
3.2	Metodología	34
3.2.1	Especificaciones Tecnológicas	34
3.2.2	Metodología para Data Mining	36
3.3	Caracterización del Sujeto	38
3.4	Especificación de Actividades	39
4	Resultados y Discusión	43
4.1	Generación de Modelos de Aprendizaje de Máquina	43
4.2	Diseño y Desarrollo de Software	51
4.2.1	Roles del Sistema	55
4.2.2	Proceso de desarrollo de prototipos	55
4.2.3	Diseño de la Base de Datos	56
4.3	Actividades nuevas para el Modelo	58
5	Conclusiones	62
5.1	Conclusiones	62
5.2	Trabajo Futuro	63
A	Resultados preliminares del Laboratorio	65
B	Resultados en Domicilio Particular	70
B.1	Evidencia de las actividades realizadas por los Sujetos de Prueba	70
B.2	Sujeto 1	73
B.3	Sujeto 2	75
B.4	Sujeto 3	79
C	Iteraciones del Prototipado	85
C.1	Iteración 1: 13 de Octubre de 2020	85
C.2	Iteración 2: 02-11-2020	88
C.3	Iteración 3: 01-01-2021	90
C.4	Iteración 4: 17-03-2021	93
C.5	Iteración 5: 01-05-2021	94
C.6	Iteración 6: 12-06-2021	96
D	Evidencia de WIFIALR en Rx	99
E	Productos Académicos de Investigación	103

Referencias

109

Lista de Figuras

2.1	Listado de los tres delitos más frecuentes por Entidad Federativa (extracto) en 2014.	11
2.2	Hogares afectados por delitos (con víctimas y sin víctimas).	11
2.3	Pérdidas monetarias promedio anuales (2018), en pesos, a consecuencia de delitos. El robo en casa habitación fue de \$5,684.00 de pérdida, en promedio (INEGI, 2019).	12
2.4	Vista previa de la aplicación de un escenario Wireless Sensor Network para el cuidado de la salud (Alemdar & Ersoy, 2010).	14
2.5	Sistema MIMO (Viswanathan, 2014).	17
2.6	Analogía entre RSS y CSI (Zhou <i>et al.</i> , 2015).	18
2.7	Reflexión de la señal inalámbrica por actividad humana (Wang <i>et al.</i> , 2015).	20
2.8	Pruebas experimentales de transmisión (Dayal <i>et al.</i> , 2016).	20
2.9	Caminando (Wang <i>et al.</i> , 2015).	21
2.10	Cayendo (Wang <i>et al.</i> , 2015).	21
2.11	Sentándose (Wang <i>et al.</i> , 2015).	21
2.12	Modelo del Sistema Wireless Sensing, propuesto por Wang <i>et al.</i> (2018).	23
3.1	Izquierda: Colocación de Tx o Transmisor con 1 antena. Derecha: Colocación de Rx o Receptor con tres antenas. Lugar: Laboratorio de Pruebas.	32
3.2	Izquierda: Colocación de Tx o Transmisor con 1 antena. Derecha: Colocación de Rx o Receptor con tres antenas. Lugar: Domicilio Particular.	32
3.3	Dispositivo de hardware Intel® NUC Kit D54250WYKH.	33
3.4	Interior del dispositivo NUC Rx: El adaptador de red Intel 5300 es visible en la parte superior de la imagen.	33
3.5	Metodología que va desde el desarrollo de software mediante Prototipado hasta la implementación del Modelo de Clasificación.	34

LISTA DE FIGURAS

3.6	Mapa de Distribución del Laboratorio de Pruebas de Inteligencia Artificial.	36
3.7	Mapa de Distribución del Domicilio Particular.	37
3.8	Arquitectura de tres capas del Software.	37
3.9	Actividad GO TO BED. Sujeto de pruebas 3.	40
3.10	Actividad FALL. Sujeto de pruebas 3.	40
3.11	Actividad PICK UP. Sujeto de pruebas 2.	40
3.12	Actividad RUN. Sujeto de pruebas 1.	41
3.13	Actividad SIT DOWN. Sujeto de pruebas 2.	41
3.14	Actividad STAND UP. Sujeto de pruebas 3.	41
3.15	Actividad WALK. Sujeto de pruebas 1.	42
4.1	Conversión de .dat a DataFrame de Python.	43
4.2	Fragmento de datos preprocesados.	44
4.3	Muestras de 6 Principales Componentes de la Actividad RUN evidenciando la existencia de ruido.	45
4.4	Características en el Dominio del Tiempo.	45
4.5	Ejemplo de matriz de training X.	45
4.6	Ejemplo de vector de clases Y, de training.	46
4.7	Resultados de Validación de Modelos en Training.	46
4.8	Resultados de Validación de Modelos con 42 muestras de datos nunca antes vistos.	47
4.9	Matriz de Confusión para Support Vector Machine.	49
4.10	Matriz de Confusión para: Nearest Neighbors (parte superior izquierda), Gaussian Naive Bayes (parte superior derecha), Linear Discriminant Analysis (parte inferior izquierda) y Neural Network (parte inferior derecha).	50
4.11	Interfaz de Anaconda Navigator 1.9.12.	51
4.12	Explorador de variables del Entorno de Spyder.	53
4.13	Algunos elementos del proyecto WIFIALR en el repositorio de GitHub del autor.	54
4.14	Modelo de Prototipos (Poonam, 2018).	57
4.15	Modelo Entidad-Relación de la Base de Datos.	57
4.16	Catálogo de las actividades.	58
4.17	Tabla de alertas que se envían como respuesta al usuario al identificar la actividad realizada.	58
4.18	Tabla de valores mínimos y máximos de cada subcarrier de la Amplitud de la señal.	58
4.19	Amplitud de la Actividad GO TO BED por cada Antena de Rx.	59
4.20	Primeros dos subcarriers de cada una de las antenas de Rx: A, B y C. Actividad GO TO BED.	60

LISTA DE FIGURAS

4.21	Evidencia de la Actividad GO TO BED por Consola.	61
4.22	Evidencia de la Actividad GO TO BED por Ventana de Alerta. . .	61
A.1	Izquierda: Heatmap de Actividad GO TO BED. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.	66
A.2	Izquierda: Heatmap de Actividad FALL. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.	66
A.3	Izquierda: Heatmap de Actividad PICK UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.	67
A.4	Izquierda: Heatmap de Actividad RUN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.	67
A.5	Izquierda: Heatmap de Actividad SIT DOWN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.	68
A.6	Izquierda: Heatmap de Actividad STAND UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.	68
A.7	Izquierda: Heatmap de Actividad WALK Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.	69
B.1	Actividad GO TO BED. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.	71
B.2	Actividad FALL. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.	71
B.3	Actividad PICK UP. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.	72
B.4	Actividad RUN. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.	72
B.5	Actividad SIT DOWN. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.	73
B.6	Actividad STAND UP. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.	73
B.7	Actividad WALK. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.	74
B.8	Izquierda: Heatmap de Actividad GO TO BED. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.	74
B.9	Izquierda: Heatmap de Actividad FALL. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.	75
B.10	Izquierda: Heatmap de Actividad PICK UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.	75
B.11	Izquierda: Heatmap de Actividad RUN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.	76

LISTA DE FIGURAS

B.12 Izquierda: Heatmap de Actividad SIT DOWN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.	76
B.13 Izquierda: Heatmap de Actividad STAND UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.	77
B.14 Izquierda: Heatmap de Actividad WALK Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.	77
B.15 Izquierda: Heatmap de Actividad GO TO BED. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.	78
B.16 Izquierda: Heatmap de Actividad FALL. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.	78
B.17 Izquierda: Heatmap de Actividad PICK UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.	79
B.18 Izquierda: Heatmap de Actividad RUN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.	79
B.19 Izquierda: Heatmap de Actividad SIT DOWN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.	80
B.20 Izquierda: Heatmap de Actividad STAND UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.	80
B.21 Izquierda: Heatmap de Actividad WALK. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.	81
B.22 Izquierda: Heatmap de Actividad GO TO BED. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.	81
B.23 Izquierda: Heatmap de Actividad FALL. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.	82
B.24 Izquierda: Heatmap de Actividad PICK UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.	82
B.25 Izquierda: Heatmap de Actividad RUN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.	83
B.26 Izquierda: Heatmap de Actividad SIT DOWN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.	83
B.27 Izquierda: Heatmap de Actividad STAND UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.	84
B.28 Izquierda: Heatmap de Actividad WALK. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.	84
C.1 Versión preliminar del Modelo Entidad-Relación de base de datos.	87
C.2 Versión preliminar de Arquitectura de software de 3 capas.	87
C.3 Evidencia de los datos almacenados.	88
C.4 Pruebas con SVM y 10-fold cross validation.	90
C.5 Segunda versión del Modelo Entidad-Relación de base de datos.	91
C.6 Segunda versión de Arquitectura de software de 3 capas.	92

LISTA DE FIGURAS

C.7	Evidencia de reconocimiento de actividad por consola.	97
C.8	Evidencia de reconocimiento de actividad en ventana de alerta. . .	97
D.1	Scripts para la ejecución de WIFIALR.	99
D.2	Comandos de ejecución de WIFIALR.	100
D.3	Interfaz gráfica para selección de archivos .dat.	101
D.4	Evidencia de la actividad GO TO BED a través de la terminal. . .	101
D.5	Evidencia de la actividad GO TO BED a través de una alerta gráfica.	101
D.6	Izquierda: Heatmap de Amplitud de la Actividad realizada. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.	102

Lista de Tablas

3.1	Características en el Dominio del Tiempo extraídas de CSI	38
3.2	Descripción de las Actividades Especificadas	39
4.1	Especificación de requerimientos	52
4.2	Roles del Sistema	55
4.3	Resultados de Actividades Identificadas	59

Capítulo 1

Introducción

1.1 Evolución de WiFi

Hoy en día es muy común tomar el celular o la computadora y acceder a cualquier tipo de información en internet; pero anteriormente esto no era posible debido tanto a la tecnología de los dispositivos, como a la tecnología de las redes. Entre los principales cambios evolutivos a la tecnología WiFi basada en los estándares 802.11 definidos por la IEEE, se mencionan los siguientes:

Desde fines del siglo XX surge la necesidad de establecer un mecanismo de conexión inalámbrica compatible entre distintos dispositivos; hasta que en 1999 las empresas 3com, Airones, Intersil, Lucent Technologies, Nokia y Symbol Technologies crean la Wireless Ethernet Compatibility Alliance (WECA), actualmente Wi-Fi Alliance; con el objetivo de promover la tecnología inalámbrica con compatibilidad de equipos. Wi-Fi es entonces, una marca de la Wi-Fi Alliance, que cumple con los estándares 802.11 de la IEEE ([TECNOLOGÍA, 2019](#)).

En 1999, la norma 802.11a, sienta las bases de su futura estandarización; luego le suceden los estándares 802.11b (WiFi 2), 802.11g (WiFi 3) y 802.11n (WiFi 4). Cada actualización implica actualizaciones con velocidades de transmisión más elevadas. De 11 Mbps de WiFi 2 hay un salto hasta 600 Mbps en WiFi 4. Después sigue el estándar 802.11ac (WiFi 5), cuya velocidad de transmisión puede alcanzar teóricamente los 6.9 Gbps ([DPA, 2019](#)).

En 2004 se usa por primera vez una red WiFi certificada en un avión comercial.

En 2009, se libera el estándar 802.11n (WiFi 4), que multiplica por 9 el ratio máximo de transmisión mediante la tecnología MIMO (de 54 Mbps a 450 Mbps).

1.2 Planteamiento del problema

En 2013, WiFi 5, alcanza una velocidad máxima superior a 1 Gbps (TECNOLOGÍA, 2019).

A partir del año 2019, con el vigésimo aniversario del estándar, comienza la nueva fase del WiFi, 802.11ax también llamada WiFi 6, Estándar que utiliza bandas de frecuencia de 2.4 y 5 Ghz; contando con las siguientes ventajas (DPA, 2019):

- Reduce los tiempos de latencia mediante OFDMA (Acceso Múltiple por División de Frecuencias Ortogonales).
- Envío y recepción de más datos al mismo tiempo.
- Aumento de eficacia en entornos con numerosos dispositivos conectados a la red inalámbrica.

1.2 Planteamiento del problema

La presente investigación se enmarca en dos áreas donde se requiere detectar movimientos o actividades humanas de forma automática. En temas de seguridad y cuidado o monitoreo de personas. Para ello se presentan a continuación algunos trabajos relacionados los cuales dan cuenta de la importancia de ofrecer soluciones tecnológicas.

Se cita como ejemplo el siguiente extracto de una nota periodística en México titulada “Visibilidad de los delitos”, de Martínez Galván (2019):

¿Qué ocurre cuando te asaltan o roban sin violencia en una zona deshabitada o poco habitada? O cuando tu casa ha sido robada estando alguien dentro de ella o sola. O cuando te asaltan en el trayecto hacia tu escuela o casa. O te roban el auto. Cuando ocurre alguno de estos delitos, las víctimas tienen dos opciones: van con la autoridad y denuncian el hecho, o se quedan calladas y no dicen ni hacen nada. Es decir, nadie se entera de lo ocurrido.

Y luego continúa mencionando que los delitos de bajo impacto, como los de asalto a casa habitación generalmente pasan desapercibidos:

Por desgracia, los delitos de bajo impacto, sobre todo robos y asaltos, a personas o casa habitación, e incluso, autos, son invisibles. La mayoría de ellos no deja huella y cuando hay secuelas (heridas o marcas visibles en el cuerpo) no

1.2 Planteamiento del problema

sabemos el origen de las mismas.

Otro, en la nota periodística “Ola de robos en viviendas y vehículos” [Hernández \(2019\)](#), menciona:

La inseguridad se ha incrementado, van al alza los robos a casas-habitación y vehículos, el problema se acentúa en la colonia el Calichal y en el centro, dijo el regidor Baltazar Tello Pérez. Reiteró el regidor que desafortunadamente la ola de robos está al orden del día, van al alza los asaltos en comercios, casa-habitación y vehículos.

En cuanto a la salud de personas mayores, de acuerdo a la nota “Caídas son un riesgo mortal para adultos mayores en México” ([infobae, 2019](#)), se menciona el riesgo que conlleva las caídas para los adultos mayores en México:

Las caídas se han convertido en un riesgo mortal para los adultos mayores en México, pues 46% de la población de más de 60 años en el país ha sufrido algún percance que le ha dejado secuelas o provocado su fallecimiento. Según datos publicados por el Instituto Nacional de Geriátrica (INGER), 40% de los adultos mayores que ha sufrido una caída fallece en los siguientes dos años por complicaciones relacionadas con el incidente.

Como podemos constatar, se han detectado dos problemas específicos a resolver:

- La seguridad de los hogares. No únicamente se contempla una solución para los hogares, sino también para entornos laborales o en habitaciones restringidas, donde se prohíbe el acceso a ciertas personas o en determinados momentos del día.
- Los riesgos de caídas en adultos mayores. Que requieren cuidados especiales en hospitales, o en casas particulares, y ante el inminente riesgo para ellos de sufrir caídas, tropiezos, etc. No solamente se busca para los adultos mayores, también para cualquier persona que requiera cuidados especiales: enfermos, personas discapacitadas, en recuperación, etc.

En general, se desea mejorar las condiciones de seguridad del ambiente y las personas tanto de la tercera edad como incapacitadas, respectivamente.

1.3 Justificación

Esta investigación se justifica en términos de seguridad debido a riesgos tanto delincuenciales como físicos en personas con capacidades disminuidas como, por ejemplo: adultos mayores, enfermos, entre otros. Tal como se mencionó en el apartado anterior. Por otra parte, se requiere que la aplicación logre funcionar de manera autónoma; es decir, sin la intervención del usuario. Como ejemplo de aplicaciones que actualmente se usan se encuentran:

- Sensor infrarrojo. De acuerdo con [Ann & Theng \(2014\)](#), el sensor infrarrojo proyecta rayos infrarrojos en el entorno y los recaptura para calcular y medir la profundidad o distancia de cada rayo. Un ejemplo de esto sería el sensor Kinect de Microsoft. Algunas de las ventajas de este son un bajo costo, alta frecuencia de muestreo, capacidad de combinar información visual y de profundidad; procesos de reconocimiento ligeros, robustos y económicos. Sin embargo, presenta desventajas como problemas visuales y algunos que aún persisten para los sensores infrarrojos, tales como oclusiones y limitaciones del punto de vista del sensor.
- Dispositivos vestibles (wearable). Son aquellos dispositivos que se colocan en alguna parte del cuerpo y que interactúan con el usuario dependiendo de la actividad física que esté realizando, por ejemplo: las pulseras y relojes inteligentes utilizados al correr o que controlan nuestro estado de salud; los zapatos deportivos inteligentes con Sistema de Posicionamiento Global (GPS), etcétera ([dispositivoswearables, 2019](#)).

Retomando a [Ann & Theng \(2014\)](#), algunos dispositivos vestibles requieren uno o múltiples sensores para ser adheridos al cuerpo humano. La actividad física humana se identifica fácilmente a través del análisis de los datos generados desde varios sensores vestibles, después de ser procesados y clasificados por algún algoritmo de reconocimiento. Entre los sensores comúnmente usados en los dispositivos vestibles se encuentran:

- Acelerómetro. Se trata de un instrumento actualmente incluido en muchos teléfonos inteligentes, utilizado para detectar las vibraciones generadas al mover, o sacudir el teléfono. Un ejemplo práctico de su uso es cuando se da lectura a vibraciones, para saber qué tan suave es un carro durante una prueba de manejo ([Mundo, 2015](#)). También con ellos, se logra determinar la orientación del usuario en el mapa con la ayuda del GPS, y ofrecen opciones de control para juegos al inclinar la pantalla ([Ramírez, 2019](#)).
- Magnetómetro. Muchos smartphones cuentan con este tipo de sensores, los cuales miden el campo magnético de la Tierra, logrando identificar hacia

dónde está el norte. Además, junto con el GPS, ayuda a identificar la posición de usuario en el mapa y hacia que dirección mira. También es capaz de detectar ciertos metales como níquel, hierro y acero, mediante el uso de algunas aplicaciones móviles (Mundo, 2015).

- Giroscopio. Es otro de los instrumentos incluidos en muchos móviles inteligentes actuales. Permite el uso de la fuerza de gravedad de la Tierra para medir la orientación del teléfono. Con esta herramienta, se han desarrollado juegos con experiencias de realidad aumentada, y otras aplicaciones que permiten utilizar el celular como un nivelador (Mundo, 2015). Trabaja en conjunto con el acelerómetro y otros sensores para proporcionar información de donde se encuentra el teléfono y sobre su movimiento o rotación (Ramírez, 2019).

En cuanto a los dispositivos vestibles, a continuación se mencionan algunos ejemplos de este tipo de dispositivos:

- Gafas Inteligentes. Con las cuales se toman fotografías y videos que se reproducen en alta definición, de lo que el usuario ve (dispositivoswearables, 2019).
- Accesorios y complementos. Relojes, anillos, pulseras que se encienden al identificar la huella digital, y que guardan la información de la actividad diaria del usuario por ejemplo, el kilometraje al correr o caminar, ritmo cardíaco, ciclos de sueño, entre otros (dispositivoswearables, 2019).
- Industria Textil. Prendas que le indican o mandan una señal al smartphone del usuario para alertar sobre determinadas actividades que éste hace por ejemplo, al jugar golf, o que miden el kilometraje, ritmo cardíaco, etc. (dispositivoswearables, 2019).
- SmartBand. Por su precio y comodidad, suelen preferirse para hacer ejercicio. Incorporan una serie de sensores que miden la actividad diaria del usuario: los pasos al caminar, kilometraje, calorías quemadas, etc. (Móvil, 2014).

Estos dispositivos interactúan con el smartphone incluso pudiendo enviar los datos recolectados por Internet, otorgándole al usuario información sobre su actividad física, condición de salud, tipo de actividad realizada, información de su ambiente, etc. Algunas de las ventajas que ofrecen son la flexibilidad en proporcionar ubicación independiente y en monitorear a las personas sin afectar su estilo de vida; costo económico, compacto y poco consumo de energía. Entre las desventajas están la oclusión y la precisión de la ubicación. Por otra parte,

tratándose de un sistema de reconocimiento de actividad humana, el usuario debe traerlos puestos en varias partes del cuerpo, y si olvida ponerse uno puede afectar el reconocimiento de la actividad que se esté realizando.

Los sensores infrarrojos tienen la desventaja de la oclusión, y limitaciones del rango de vista del sensor, lo cual limita su potencial, en caso de que un obstáculo se interponga muy cerca del sensor. Mientras que, en el caso de los dispositivos vestibles, se tienen que presionar botones para que el usuario los pueda utilizar, además de que debe llevarlos puestos, con el inconveniente de que se olvide ponerse alguno y por ende, la obtención de datos sea limitada.

De esta manera el propósito de la presente investigación es desarrollar una solución que permita interactuar con los dispositivos de hardware y redes, mediante las señales inalámbricas para detectar a las personas que se encuentren dentro de un área determinada, y también, el tipo de acción que están llevando a cabo; esto sin que el usuario tenga que presionar botones, o llevar puestos sensores encima. Por ejemplo: Si entra un intruso a una habitación restringida, que se pueda avisar mediante una alerta, que una persona se encuentra dentro en ese momento realizando una determinada actividad (caminar, correr, etc.); y en el caso de una persona de la tercera edad dentro de un domicilio, que se pueda monitorear su actividad (recoger algo, sentarse, levantarse, caer, permanecer en el suelo, etc.) para avisar mediante una alerta, que la persona dentro del área permanece acostada, se ha levantado o incluso ha sufrido una caída, y así poder tomar acción inmediata. Si no hay nadie en la habitación, simplemente, la tecnología de detección de actividades registra el suceso como “Sin actividad”.

1.4 Objetivos

1.4.1 Objetivo General

Desarrollar una aplicación capaz de arrojar mensajes de alerta, como respuesta a las actividades detectadas en una habitación por una persona, mediante el uso de señales inalámbricas y algoritmos de aprendizaje de máquina.

1.4.2 Objetivos Específicos

- Objetivo 1. Determinar los algoritmos de aprendizaje de máquina que reconozcan los tipos de actividades humanas con un mínimo de error.

- Objetivo 2. Determinar cuál es el modelo de clasificación con la mejor tasa de reconocimiento para nuevos movimientos.

1.4.3 Metas

- Desarrollar un software para la detección de actividades usando redes WiFi.
- Contar con una publicación arbitrada nacionalmente/internacionalmente, mediante la participación en Congresos Nacionales de Computación.
- Un Derecho de Autor. Registrando el software desarrollado.
- Documento de tesis. Al ser este aprobado por el Comité Académico.

1.5 Estructura del documento

- Capítulo 1. Introducción.
- Capítulo 2. Marco Teórico. Se refiere a las palabras clave, conceptos, teorías para abordar la temática; así como mostrar los resultados de la Revisión de la Literatura y una reflexión de lo que existe y/o se investigó.
- Capítulo 3. Materiales y Métodos. Trata de la Metodología utilizada para el desarrollo del proyecto; los elementos tanto de hardware como de software a utilizar; y la caracterización del sujeto, aquel que llevará a cabo las pruebas simulando un ambiente real.
- Capítulo 4. Resultados y Discusión. En esta sección se describen los algoritmos de Data Mining, Machine Learning y los resultados de las pruebas llevadas a cabo durante las etapas del desarrollo del Modelo: Preprocesamiento, Extracción de Características, Clasificación, así como la Selección y Validación de Modelos; también se expone tanto la Metodología de Prototipado, que es la implementada para el desarrollo del software, como las herramientas para la gestión de tareas, análisis, diseño y desarrollo del mismo; por último se describen los experimentos realizados tanto para los datos de entrenamiento como para los datos nuevos para el Modelo, incluyendo gráficos y alertas generadas.
- Capítulo 5. Conclusiones. Lo que se concluye en base a los resultados obtenidos, el estado del desarrollo del software, así como lo que se prevé a futuro en cuanto a los alcances del software en diferentes escenarios en el interior.

Capítulo 2

Marco Teórico

En la actualidad, el tema de la seguridad se ha vuelto crucial para salvaguardar tanto los bienes materiales que tenemos, como la salud de los adultos mayores, personas incapacitadas por alguna enfermedad, limitación física, etc.

El propósito del presente Marco Teórico es establecer las teorías, variables, definiciones, aplicaciones, etc., sobre la seguridad mediante el uso de señales WiFi, especialmente en el hogar; tanto de las personas mayores, como de los bienes materiales en una habitación; con el fin de asentar las bases para el desarrollo de la investigación y la elaboración del producto final: una aplicación enfocada en la seguridad, mediante la detección de actividades en una habitación a través de señales WiFi con un dispositivo emisor de señal (Tx), y uno de recepción (Rx); y que arrojará como resultado señales o alertas de seguridad, basadas en la actividad realizada de una persona.

2.1 Seguridad

2.1.1 Definición

De acuerdo con el Diccionario de Cambridge ([Cambridge, 2019b](#)), sobre la definición de seguridad, se dice:

protection of a person, building, organization, or country against threats such as crime or attacks by foreign countries

Lo anterior se refiere a la protección de una persona, construcción, organización o país, contra amenazas tales como el crimen y ataque de otros países.

La seguridad se ha vuelto un tema muy importante hoy en día, debido a que existen muchos crímenes que se perpetran por falta de implementación de medidas de seguridad adecuadas en hogares, así como en oficinas, instituciones, etc.

2.1.2 Teoría del autocontrol

Cuando hablamos de seguridad, también vale la pena hablar de la delincuencia, ya que es la razón por la cual se propone la implementación de medidas de seguridad, para evitar que intrusos perpetren acciones delictivas al entrar en domicilios, hogares, oficinas, etc.

Dentro de este marco resulta de interés hablar de la teoría de autocontrol definida por Gottfredson y Hirschi (1990), como parte de su teoría general del crimen, debido a que a través de ella es posible conocer las causas que llevan a un perpetrador a cometer el delito de asalto a casa habitación.

Cuando Gottfredson y Hirschi usan el término, el autocontrol se refiere a la capacidad de renunciar a los placeres inmediatos o a corto plazo que tienen algunas consecuencias negativas y la capacidad de actuar en favor de los intereses a más largo plazo (Patino, 2019).

Entonces se infiere que cuando una persona no logra renunciar a estos actos de placer inmediato, significa que no tiene un buen autocontrol. Las causas de ello se explican a continuación con la siguiente definición de la teoría del autocontrol:

Dicha teoría está conformada por una serie de características, comprobables a través de resultados observables, en torno a los hechos del delito. Dichas características son que los delitos requieren un mínimo esfuerzo por parte del delincuente, pues su meta es inmediata; y sus resultados ocurren más por el aprovechamiento de una oportunidad simple, que por cualquier tipo de plan elaborado (Akers *et al.*, 2013).

Lo anterior se traduce en mínimas ganancias para los criminales, ya que éstos suelen buscar gratificaciones inmediatas; pero implican altos costos para las víctimas.

Dentro del contexto anterior, se estima que los perpetradores son impulsivos, aman el riesgo y experimentar sensaciones, además que cuentan con una mínima formación y comportamientos desviados.

De acuerdo con Gottfredson y Hirschi (1990), las personas más propensas a cometer delitos son las que tienen un autocontrol bajo. Esto último se da como resultado de una limitada educación desde niños tanto en la familia, como en las instituciones educativas. El autocontrol se adquiere desde la edad temprana en el niño y se permanece relativamente estable hasta lo largo de su vida.

Estos autores también mencionan que otro elemento que favorece el delito, es la oportunidad para delinquir, aunque esto es secundario en la teoría.

2.1.3 Seguridad en el interior

El tipo de acto delictivo, objeto de estudio de nuestro Marco Teórico, se centra en los robos a casa habitación.

El robo a casa habitación es un delito, a través del cual, un delincuente, se apodera de bienes ajenos, al invadir propiedades privadas, ya sean casas, departamentos, entre otros (Aguirre, 2017).

En 2014, la Secretaría de Gobernación en México, en el Programa Nacional de Seguridad Pública 2014-2018, refirió que entre los delitos más comunes que más afectan el patrimonio de las personas, se encuentran: robo al transeúnte, robo a casa habitación, robo a negocio y robo de vehículos (SEGOB, 2014).

En el artículo de Aguirre (2017) se menciona que, de acuerdo con datos de la Encuesta Nacional de Victimización y Percepción sobre Seguridad Pública (Envipe), del INEGI (2015), sobre el delito de robo a casa habitación:

En ese sentido, el robo a casa habitación es un delito que causa preocupación en la sociedad y que está presente entre los ilícitos comunes. La Encuesta Nacional de Victimización y Percepción sobre Seguridad Pública (Envipe) 2015 del Instituto Nacional de Estadística y Geografía (INEGI) señala que el robo a casa habitación fue el tercer delito con más frecuencia en el estado de Baja California (Aguirre, 2017). Tal como se indica en la Figura 2.1.

En la Figura 2.2 se muestra que, en los resultados más recientes de Envipe (2019), durante 2018, 33.9% de los hogares en México, fueron víctimas de un delito (INEGI, 2019).

Otros resultados, también de INEGI (2019), muestran que en el mismo año, 2018, hubo pérdidas monetarias a consecuencia de haber sido víctima de uno o

2.1 Seguridad

Entidad	1era Más Frecuente	2da Más Frecuente	3era Más Frecuente
NACIONAL	Robo o asalto en la calle o en el transporte público	Extorsión	Fraude
Aguascalientes	Robo parcial de vehículo	Extorsión	Amenazas
Baja California	Extorsión	Robo parcial de vehículo	Robo en su casa habitación

Figura 2.1: Listado de los tres delitos más frecuentes por Entidad Federativa (extracto) en 2014.




Figura 2.2: Hogares afectados por delitos (con víctimas y sin víctimas).

más delitos, y también gastos realizados, como consecuencia de daños a la salud. Tanto los gastos de pérdidas monetarias, como médicos, ascendieron a 184.3 mil millones de pesos. En la Figura 2.3, se observa entre los delitos que causaron pérdidas monetarias durante el año 2018, el delito de robo en casa habitación.

En el artículo de [Aguirre \(2017\)](#), se menciona también que el robo a casa habitación, consta de varias modalidades, como el forzar las cerraduras e infiltrarse al domicilio, sea que estén presentes los que ahí viven, o no; entrar por la fuerza; ingresar mientras los moradores están dormidos; o anestesiarlos con algún químico.

En conclusión, el delito de robo a casa-habitación, representa uno de los delitos más comunes y que afectan mucho a las personas que habitan un hogar; y no solamente ocurre en el hogar, también en otros tipos de ambiente como el empresarial, en las oficinas, en un edificio de carácter privado, etc. Por lo tanto, es importante asegurar la protección tanto de las personas que habitan el hogar, o que trabajan en una oficina; como los bienes materiales en dichos domicilios.




Figura 2.3: Pérdidas monetarias promedio anuales (2018), en pesos, a consecuencia de delitos. El robo en casa habitación fue de \$5,684.00 de pérdida, en promedio (INEGI, 2019).

2.2 Cuidado de la salud

2.2.1 Definición

Investigando nuevamente en el Diccionario de Cambridge, pero esta vez sobre la definición de cuidado de la salud, se menciona: *the set of services provided by a country or an organization for the treatment of the physically and the mentally ill* (Cambridge, 2019a).

Entendiéndose como el conjunto de servicios provistos por un país o una organización para el tratamiento de enfermedades físicas y mentales.

El cuidado de la salud hoy en día es un tema muy importante, sobre todo para el cuidado de adultos mayores, personas físicamente incapacitadas, etc. por el hecho de que necesitan asistencia médica, o requieren ser auxiliadas en caso de alguna caída, por ejemplo.

2.2.2 Cuidado de adultos mayores

De acuerdo a un Boletín Informativo del Instituto Nacional de Geriátría (Enero, 2019), las caídas son uno de los principales riesgos de salud y mortandad entre adultos mayores; el índice de estos percances ha aumentado en la última década.

2.3 Alertas preventivas mediante software

Datos del Estudio Nacional de Salud y Envejecimiento en México (2015), muestran que el 46% de personas mayores a 60 años ha sufrido una o varias caídas. Dichas lesiones y sus consecuencias aumentan el peligro de mortalidad y afectan la calidad de vida de estas personas. De acuerdo a este mismo estudio, sólo 9 de cada 100 personas había tenido un accidente por caída, mientras que en 2016 aumentó a 11.

Según [Tinoco \(2019\)](#), el aumento de accidentes en adultos mayores está relacionado al envejecimiento poblacional, y a las condiciones de salud que enfrenta la población de adultos mayores. También menciona que en México se utilizan tres veces más sedantes que en otros países, lo que trae repercusiones en la fuerza y el equilibrio de este sector.

Si una persona sufre una caída, es necesario que sea llevada a un centro médico para que se le realice una evaluación integral; también se deben considerar los medicamentos que ingiere, si tiene problemas de visión o en articulaciones, observar el ambiente donde se desenvuelve y realiza sus actividades ([Tinoco, 2019](#)).

En conclusión, los adultos mayores, necesitan de atención y cuidados, ellos al igual que las personas incapacitadas, requieren que se les esté monitoreando y sus familiares deben estar al tanto en caso de alguna caída para poder tomar las acciones necesarias para salvaguardar su vida.

2.3 Alertas preventivas mediante software

2.3.1 Definición

Con el rápido desarrollo de dispositivos comerciales WiFi en entornos interiores, cada vez más hay aplicaciones que utilizan Channel State Information (CSI). Por el hecho de que una entidad al caminar entre un transmisor y un receptor pueda generar impacto significativo en las características de la señal WiFi, la identificación de identidad puede ser factible utilizando CSI.

Es bien conocido, que los patrones naturales al caminar, y en general al realizar distintas actividades, son particulares, y se pueden caracterizar por las diferencias en la altura, masa corporal y velocidad de movimiento del ser humano. Dichas actividades pueden afectar el entorno electromagnético interior de tal forma que se podría impactar en las características de la señal WiFi. Por lo tanto, es posible identificar a una persona de un grupo de personas examinando sus características

2.3 Alertas preventivas mediante software

estadísticas representativas exhibidas en datos CSI. Sin embargo, aún existen muchos retos que faltan por afrontar en la identificación de actividad humana basada en WiFi CSI (Ding *et al.*, 2020).

2.3.2 Aplicaciones

Entre los diversos usos que se les da a las tecnologías de detección de movimiento mediante redes inalámbricas, se encuentran: el entretenimiento, viajes, industria, medicina, y el cuidado de la salud de personas dependientes, tales como adultos mayores, niños y personas enfermas.

El diseño con el que se piensan los sistemas para el cuidado de la salud, involucran la mejora del monitoreo remoto para identificar las condiciones en que se encuentra un paciente con discapacidades cognitivas y físicas, y a la vez, permitirles llevar una vida más fácil e independiente.

Identificando situaciones de emergencia de los pacientes, tales como ataques al corazón, o caídas repentinas en tan solo unos segundos o algunos minutos, será lo suficiente para salvar vidas. De esta manera, tanto proporcionar información en tiempo real y el tomar medidas generalizadas mediante los sistemas del cuidado de la salud se hallan entre los principales beneficios (Alemdar & Ersoy, 2010). Un ejemplo de ello lo vemos en la Figura 2.4.

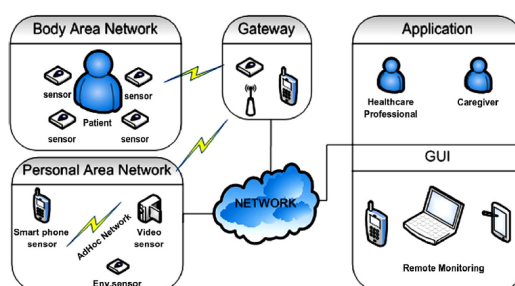


Figura 2.4: Vista previa de la aplicación de un escenario Wireless Sensor Network para el cuidado de la salud (Alemdar & Ersoy, 2010).

2.4 Señales WiFi

2.4.1 Definición

Las tecnologías de detección de movimiento han cobrado un gran auge en los últimos tiempos, prácticamente en todos los sectores de la industria, sobre todo en cuanto a seguridad y salud se refiere. Tal es el caso de las routers WiFi los cuales son usados como un medio de comunicación (Hammoshi & Alani, 2010).

Durante los últimos años se han hecho trabajos de investigación tendientes a detectar movimientos humanos en el interior, con el atractivo de evitar el uso de dispositivos portátiles o tecnologías invasivas (Zhou *et al.*, 2015). De esta manera surge el concepto de detección pasiva también conocido como *Device-free*, utilizado para referirse a la libertad del usuario para no utilizar en su cuerpo algún tipo de sensor o radar. Ello le confiere a esta tecnología un gran número de aplicaciones por ejemplo: vigilancia y seguridad, detección de intrusos, monitoreo de personas de la tercera edad, cuidados de la salud a distancia, y una manera innovadora de interacción humano-máquina (Chen *et al.*, 2019; Tan *et al.*, 2018). Esto representa una ventaja ante el uso de cámaras de vigilancia que invaden la privacidad de la persona, en el caso de adultos mayores, o cuidados de la salud; también es mejor en cuanto al uso de la tecnología portátil (wearable devices), que presentan la desventaja que al usuario se le puede olvidar colocarse alguno de los sensores portátiles; solo por citar algunos ejemplos.

En el presente trabajo se combina el uso de los adaptadores de red Intel 5300 instalados en dos computadoras habilitadas como Transmisor (Tx) y Receptor (Rx) de señales WiFi para la extracción y análisis de la información del estado del canal de la señal (CSI por sus siglas en inglés). Con ello se logra la identificación de actividades humanas mediante técnicas de aprendizaje máquina. Una vez que el usuario realiza alguna de las actividades en la LOS, se notifica al usuario sobre ésta a través de un mensaje en consola de comandos y mediante una ventana de diálogo en una pantalla de computadora. El estándar utilizado es el WiFi 802.11n, también llamado WiFi 4. Este soporta una tasa de transferencia de datos de hasta 600 Mbps y frecuencias de banda de 2.4 GHz y 5 GHz (Deniau *et al.*, 2017).

Los dispositivos inalámbricos de los estándares IEEE 802.11n/ac proveen de señales CSI. Dichos estándares utilizan un sistema de Múltiple Entrada Múltiple Salida (MIMO por sus siglas en inglés) para un mayor rendimiento, al aumentar la ganancia de diversidad, la ganancia de arreglos y la ganancia de multiplexación (Wilson & Dobre, 2016).

Los conceptos sobre el manejo de las señales WiFi, a considerar relacionados de la presente investigación, son los siguientes:

- RF (Radio Frequency). De acuerdo con [Scarpati \(2021\)](#), es una medida que representa la tasa de oscilación del espectro de radiación electromagnética u ondas de radio electromagnéticas para rangos de frecuencias desde 300 GHz hasta bajas de 9 kHz. Con el uso de antenas y transmisores, un campo de RF se puede usar para varios tipos de comunicaciones y transmisiones inalámbricas. Se componen por diferentes subportadoras, cada una de las cuales varía dependiendo de los cambios de su entorno ([Qian et al., 2014](#)).
- Subportadora (Subcarrier). De acuerdo con [Zhou et al. \(2015\)](#), es la división que hace CSI de las señales de diferentes longitudes de onda por OFDM (Multiplexación por División de Frecuencias Ortogonales). Es decir, cada una de las divisiones de la señal RF que se dirigen desde el dispositivo transmisor hacia cada una de las antenas del dispositivo receptor, llevando consigo información de amplitud y fase.
- RSS (Received signal strength). Según como indica [Hsieh et al. \(2019\)](#), es la medida de la potencia presente en una señal de radio recibida. Depende de la potencia transmitida y la distancia entre el transmisor y el receptor, de la siguiente manera:

$$RSS(dbm) = 10 \log \frac{P_r}{P_{ref}} \quad (2.1)$$

donde P_{ref} es la potencia de referencia, y P_r es la potencia recibida calculada como

$$P_r = P_t G_t G_r \left(\frac{\lambda}{4\pi d}\right)^2 \quad (2.2)$$

donde P_t es la potencia transmitida, G_t es la ganancia de la antena de transmisión, G_r es la ganancia de la antena de recepción, λ es la longitud de la onda de radio, y d representa la distancia entre el transmisor y el receptor.

Se utiliza muy a menudo para inferir información del entorno, como lo son las distancias de propagación. Actúa como un proxy para la calidad del canal y es accesible en numerosas tecnologías inalámbricas de comunicaciones, entre ellas WiFi, RFID, Bluetooth, etc. Se ha utilizado este tipo de señales para la localización en el interior, así como la detección humana “pasiva” ([Zhou et al., 2015](#)).

- MIMO (Multiple-Input Multiple-Output System). Se trata de una tecnología inalámbrica que utiliza múltiples transmisores y receptores para la transferencia de datos al mismo tiempo; la Figura 2.5 ilustra la tecnología MIMO. Los productos Wireless bajo el estándar 802.11n soportan MIMO (Intel, 2019).

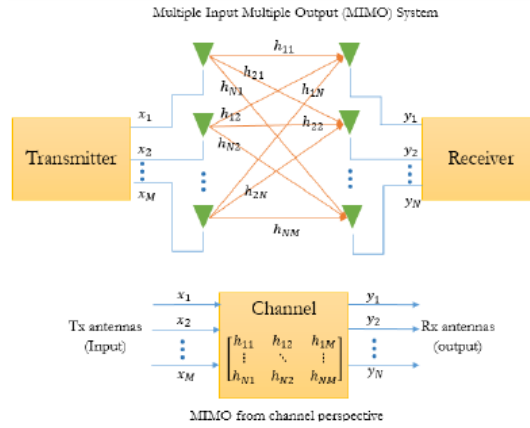


Figura 2.5: Sistema MIMO (Viswanathan, 2014).

- CSI (Channel State Information). De acuerdo con Chen *et al.* (2019), se refiere a las propiedades de un enlace de comunicación inalámbrica, el cual para el caso de la propagación WiFi, puede ser modelada como un MIMO de la siguiente manera:

$$y_i = H_i x_i + n_i, \quad i \in \{1, 2, \dots, S\} \quad (2.3)$$

donde x_i y y_i representan los vectores de la señal transmitida y recibida para el subcarrier i -th, n_i es el vector de ruido y S es el número de subcarriers. H_i se le conoce como la matriz CSI, que consiste en valores complejos definidos como:

$$H_i = |H_i| e^{j\angle H_i} \quad (2.4)$$

donde $|H_i|$ y $\angle H_i$ son la respuesta de amplitud y de ángulo, respectivamente. Estas matrices CSI se estiman dividiendo la señal de salida con una secuencia conocida de entradas. Por ejemplo, una matriz CSI estimada mediante una tarjeta Intel 5300 WiFi con 3 antenas y 30 subcarriers puede ser representada como:

$$\text{matrizCSI} = \begin{bmatrix} H_{1,1} & H_{1,2} & \cdots & H_{1,30} \\ H_{2,1} & H_{2,2} & \cdots & H_{2,30} \\ H_{3,1} & H_{3,2} & \cdots & H_{3,30} \end{bmatrix} \quad (2.5)$$

donde $H_{m,n}$ es el valor CSI para la antena m^{th} y el subcarrier n^{th} .

Existen algunas tareas importantes que se deben de considerar una vez recibida la señal por el receptor: limpieza de los datos, extracción de las características y reconocimiento de patrones.

CSI es capaz de representar propagación “multipath”, convirtiéndolo en una mejora de RSS. Dicho de otra forma, y como se muestra en la Figura 2.6, CSI es a RSS como un arcoíris lo es a un rayo solar (Zhou *et al.*, 2015):




Figura 2.6: Analogía entre RSS y CSI (Zhou *et al.*, 2015).

CSI separa las señales de diferentes longitudes de onda a través de OFDM, mientras que RSS solamente provee una amplitud de un solo valor de caminos superpuestos.

2.4.2 Principio Básico del Sistema de Detección Inalámbrica

Los Sistemas de Detección Inalámbrica combinan la tecnología de radio-frecuencia, el procesamiento de señales digitales, así como aprendizaje máquina (Machine Learning) para crear una novedosa tecnología de percepción del entorno con señales inalámbricas.

Esta tecnología recolecta información del medio ambiente mediante señales inalámbricas determinadas por el estado del entorno y utiliza tecnología de procesamiento de señales digitales para obtener estados actuales de interés de dicho entorno, lo que permite su percepción (Wang *et al.*, 2018).

Dicho en otras palabras, la Tecnología de Detección Inalámbrica le permite al usuario percibir su entorno y darse cuenta lo que está sucediendo en él, de manera que a partir de esto se tomen acciones.

2.4.3 Uso de señales WiFi en el Reconocimiento de la Actividad Humana

Existen algunas soluciones tecnológicas que ya emplean el WiFi en el hogar o entorno profesional para el reconocimiento de la Actividad Humana, por mencionar algunos, se encuentran los siguientes casos:

- El software de Aerial Technologies, del cual se dice que ofrece comodidad y mejor calidad de vida en los hogares, mediante el uso de tecnología que se implementa fácilmente en cualquier equipamiento o dispositivo de red, haciendo uso de las señales WiFi ya existentes y de inteligencia artificial con aprendizaje automático; además permite el reconocimiento de individuos, la detección del movimiento, así como la climatización inteligente, monitorear la salud y el cuidado de personas mayores, etc. (Frutos Calleja, 2017).
- Otro caso similar se expone en Adib *et al.* (2014), donde investigadores del MIT (Massachusetts Institute of Technology), entre ellos los responsables del proyecto, la profesora Dina Katabi y su alumno Fadel Adib, trabajaron para desarrollar una tecnología que permite detectar movimiento humano a través de las paredes mediante el uso de dos antenas y un receptor de señal WiFi. Resumidamente, se trata del uso de señales WiFi cuando son transmitidas de una habitación a otra; una parte de las señales es absorbida por la pared, y la otra llega hasta la otra habitación; de estas ondas que llegan hasta allí, algunas tocan objetos inertes, y otras objetos en movimiento, y precisamente la investigación consiste en el desarrollo de una tecnología que anula los reflejos en los cuerpos inertes y únicamente se queda con los reflejos de los objetos en movimiento, por ejemplo personas. Además, permite detectar los gestos de quien se encuentra en la otra habitación, por ejemplo, mover los brazos (TECNOLOGÍA, 2019).

Para profundizar un poco más en este tema, de acuerdo con el artículo de investigación de Wang *et al.* (2015), las señales WiFi están disponibles al menos en cualquier lugar (Figura 2.7), y son capaces de monitorear actividades en los alrededores. Esto se realiza utilizando los routers comerciales.

Entre las ventajas que presenta esta propuesta de reconocimiento de actividades por señales WiFi se encuentran:




Figura 2.7: Reflexión de la señal inalámbrica por actividad humana (Wang *et al.*, 2015).




- Poder trabajar en la oscuridad. Sin necesidad del uso de cámaras de video vigilancia.
- Mejor cobertura.
- Menos intrusión hacia la privacidad de las personas.
- Sin necesidad del uso de sensores (pulseras, dispositivos móviles, etc.).

El flujo WiFi propagado desde el transmisor a través de las diferentes subportadoras hasta el dispositivo receptor, permite identificar la amplitud y la frecuencia (Channel State Information – CSI), a partir de las cuales se reconoce el comportamiento de un individuo dentro de entornos cerrados. Es decir, el movimiento humano cambia la propagación de las características del medio, alterando el canal de transmisión y el CSI de la señal recibida (Dayal *et al.*, 2016). La señal viaja desde el Router hasta los equipos receptores, como se muestra en la Figura 2.8.



Figura 2.8: Pruebas experimentales de transmisión (Dayal *et al.*, 2016).

Entre las actividades que son detectadas a partir de los datos recolectados en el dispositivo receptor, se encuentran las que se muestran en las Figuras 2.9, 2.10 y 2.11.

Figura 2.9: Caminando (*Wang et al., 2015*).Figura 2.10: Cayendo (*Wang et al., 2015*).Figura 2.11: Sentándose (*Wang et al., 2015*).

2.4.4 Seguridad con WiFi

Actualmente, el número de aplicaciones desarrolladas utilizando señales inalámbricas ha incrementado la popularidad del WiFi. Entre dichas aplicaciones se encuentran:

- Detección de gestos y actividades.
- Localización en interiores.
- Detección de caídas.
- Diseño de redes.
- Detección humana.

Tratándose de la detección humana, esto es tan importante para el cuidado de niños y personas mayores, vigilancia y seguridad en el hogar, y respuestas de emergencia. Se usa muy a menudo el procesamiento de imágenes en la detección humana. Las señales propagadas en un ambiente interior detectan la presencia humana debido a su interacción con el medio ambiente. CSI provee la respuesta del canal, incluyendo amplitud y fase, para cada subcarrier o par de transmisión-recepción (Fang *et al.*, 2019).

2.4.5 Resultado de Revisión de la Literatura

En la literatura revisada, que toma en cuenta a los autores que abordan la temática de la detección de movimiento mediante señales WiFi, en un rango no mayor a 10 años (2009-2019), se encuentra lo siguiente:

A. Sistemas de Identificación y Localización

Literature review on wireless sensing-Wi-Fi signal-based recognition of human activities (Wang *et al.*, 2018)

Se propone un modelo de Sistema Wireless Sensing, que combinan Radio-Frecuencia, tecnología de procesamiento de señales digitales y Machine Learning para crear una novedosa tecnología de detección de movimiento mediante señales inalámbricas, tal como se muestra en la Figura 2.12, que no requiere que las personas utilicen dispositivos o sensores, además se dice que su implementación implica un bajo costo, debido a que se pueden utilizar dispositivos inalámbricos comerciales estándar.

En este sistema, la clave es determinar cómo obtener la información del entorno a través de señales inalámbricas, para lo cual hay dos maneras principales: Mediante el uso de CSI de los dispositivos comerciales estándar WiFi y mediante la generación de señales de radio FMCW diseñada por Adib *et al.* (2014), y el dispositivo de radio del MIT USRP N210, que recolecta información del entorno.

También se mencionan algunas aplicaciones de Sensores Inalámbricos; el cuidado de la salud, y cómo en un futuro los dispositivos de monitoreo podrían ser reemplazados por dispositivos de detección inalámbrica con el fin de que se pueda dar a los familiares información sobre los signos vitales de los pacientes, de una manera pasiva, no invasiva y con alta precisión; y de la aplicación del sistema para la seguridad del hogar y oficinas, al lograr identificar actividades humanas tales como allanamiento de morada.

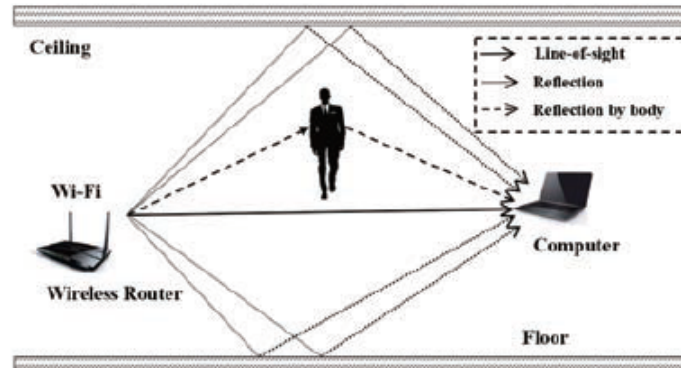


Figura 2.12: Modelo del Sistema Wireless Sensing, propuesto por Wang *et al.* (2018).

Understanding and Modeling of WiFi Signal Based Human Activity Recognition (Wang *et al.*, 2015)

En este artículo se propone un sistema llamado CARM, basado en CSI (CSI based Human Activity Recognition and Monitoring); además se mencionan algunos sistemas de reconocimiento de actividades humanas basados en señales WiFi, tales como WiSee, E-eyes, y WiHear.

CARM como tal, consta de dos dispositivos comerciales WiFi estándar: uno para el envío continuo de las señales, por ejemplo, un router; y otro que las recibe continuamente, por ejemplo, una laptop. Al momento que se lleva a cabo una determinada actividad humana en el rango de alcance de ambos dispositivos, CARM logra reconocer el tipo de actividad que se ha realizado, a partir de los valores de CSI.

Deep Learning-Based Indoor Localization Using Received Signal Strength and Channel State Information. IEEE Access, vol 7, 2019 (Hsieh *et al.*, 2019)

En esta investigación se propone el uso de métodos de aprendizaje profundo basados en MLP y 1-D CNN, para predecir la ubicación actual de una persona en un entorno interior, mediante la recolección de las señales RSS y CSI (se consideró solamente la respuesta de amplitud), entre un router con dos antenas emisoras y una tarjeta NIC Intel 5300 con tres antenas receptoras. Para ello utiliza una fase de entrenamiento y una en tiempo real.

Se construyeron cuatro redes neuronales de aprendizaje profundo, resultando en las siguientes combinaciones: MLP-RSS, MLP-CSI, CNN-RSS y CNN-CSI.

Para la recolección de las señales RSS y CSI, el equipo de trabajo diseñó una herramienta de software para el análisis de paquetes de datos escrita en C.

En los resultados, con los métodos donde se implementaron señales CSI se obtuvo una mejor precisión que en aquellos donde se utilizaron señales RSS; además se obtuvo que con la combinación de la red neuronal 1-D CNN con CSI, se consiguió el mejor desempeño con menos complejidad a comparación de otras redes.

DeFe: indoor localization based on channel state information feature using deep learning. *J. Physics: Conference Series*, vol. 1303, 2019 (Li *et al.*, 2019)

En la presente investigación se utiliza el método de fingerprinting, que está basado en CSI con el fin de implementarse para la identificación del posicionamiento en el interior.

Para las pruebas se utiliza un router TP Link y una laptop Lenovo con una tarjeta NIC 5300 y un sistema operativo Ubuntu; también se lleva a cabo la extracción de la asimetría y curtosis de la señal CSI tomando los datos obtenidos como valores iniciales; el uso de una red neuronal de aprendizaje profundo de tres capas para la fase de entrenamiento offline a partir de las características extraídas; la ejecución de un algoritmo de aprendizaje heurístico para formar una estructura RBM (Restricted Boltzmann Machine) entre las capas ocultas; logrando así la estimación de la posición en la fase de pruebas online mediante un algoritmo bayesiano basado en RBF (Radial Basis Function).

Los resultados de las pruebas permiten concluir que este nuevo método supera a otros métodos de posicionamiento como: Deepfi, ML y LAD; logrando un promedio de error inferior a los otros, pudiéndose adaptar a diversos entornos.

RoArray: Towards More Robust Indoor Localization Using Sparse Recovery with Commodity WiFi. *IEEE Trans. Mobile Computing*, July 2019 (Gong & Liu, 2019)

En el presente documento se propone el sistema ROArray, el cual es capaz de localizar con precisión un objetivo determinado, incluso con la presencia de bajos SNRs (Signal-to-Noise Ratio), situación que en otros sistemas causa que se

degrade la precisión.

La clave de ROArray es el uso de la escasa recuperación y procesamiento coherente a través de todos los dominios disponibles, como el tiempo, la frecuencia y el espacio.

En los resultados de la implementación de este sistema, se demuestra que con bajos SNRs, ROArray presenta un desempeño significativamente superior a soluciones de vanguardia, en cuanto a precisión de localización; cuando se presentan SNRs medios o altos, se alcanza una precisión comparable a dichas soluciones.

CSI Frequency Domain Fingerprint-Based Passive Indoor Human Detection. Information, vol. 9, no. 4, 2018 (Tan *et al.*, 2018)

El método que se desarrolla en este artículo se conoce como FDF-PIHD (Frequency Domain Fingerprint-based Passive Indoor Human Detection), el cual tiene como objetivo la detección de la actividad humana pasiva. Esto tiene entre otras aplicaciones, el cuidado de adultos mayores y la seguridad contra intrusos.

En particular contempla 3 tipos de escenarios: sin personas, en reposo, y en movimiento. Para su ejecución, se puede emplear cualquier router comercial que pueda enviar señales wireless; y un equipo de cómputo, que tenga una tarjeta de red Intel 5300.

Mediante esta técnica, se logran extraer ciertos datos de las señales CSI que permiten generar “fingerprints” o “huellas”, que identifican de manera única cada conjunto de datos. Con estas “huellas”, se busca determinar el estado actual del entorno, a partir de datos de entrenamiento contra datos de pruebas.

Para las pruebas se usó un Access Point, un router, y una computadora con una tarjeta de red Intel 5300 de 3 antenas. Esta última usada para fines de monitoreo; además se usó la herramienta TNS-CSI Tool, que a su vez está basada en “Linux 802.11n CSI Tool”.

Con el resultado de las pruebas que se llevaron a cabo se logra determinar que la precisión de la tasa de detección alcanza un porcentaje superior al 90%, para cualquiera de los escenarios propuestos: sin personas, en reposo o en movimiento.

WiFi CSI Based Passive Human Activity Recognition Using Attention Based BLSTM. IEEE Trans. Mobile Computing, 2019 (Chen *et al.*, 2019)

En este trabajo de investigación, se propone un enfoque basado en el aprendizaje profundo, para el reconocimiento de la actividad humana mediante el uso de señales WiFi CSI, conocido como ABLSTM (Attention Based Bi-directional Long Short-term Memory).

ABLSTM, a diferencia de LSTM que procesa las mediciones secuenciales de CSI en una sola dirección, utiliza la red BLSTM, utilizada para aprender características representativas en dos direcciones a partir de las mediciones de CSI.

Los resultados de la investigación mostraron que el enfoque propuesto alcanza el mejor desempeño de reconocimiento para todas las actividades realizadas en las pruebas, al compararla con otras metodologías como: RF (random forest), HMM (hidden Markov model), SAE (sparse autoencoder) y LSTM convencional.

B. Salud y Seguridad

Wireless sensor networks for healthcare: A survey (Alemdar & Ersoy, 2010)

Presenta un estudio enfocado a la investigación de aplicaciones inteligentes para el monitoreo, pero más que para un hogar inteligente, para el cuidado de la salud. En él se mencionan además, algunas características que se deben tomar en cuenta al diseñar sistemas de monitoreo basados en sensores de redes inalámbricas (WSNs); se describen varias aplicaciones y prototipos; y se habla de los retos para el desarrollo de soluciones de monitoreo del cuidado de la salud mediante WSNs.

SleepGuardian: An RF-based Healthcare System Guarding Your Sleep from Afar. arXiv eess.SP, 2019 (Gu *et al.*, 2020)

En este artículo se presenta una solución tecnológica conocida como "SleepGuardian", el cual es un sistema de Radio Frecuencias, que utiliza dispositivos WiFi de bajo costo, y está enfocado en el cuidado de la salud de las personas mientras duermen; se basa en el procesamiento de señales, así como técnicas de "Edge computing" y "Machine Learning".

Presenta un servicio offline enfocado a monitorear las horas de sueño; y otro online para protección del usuario en caso de algún inconveniente que ocurra mientras duerme, por ejemplo movimientos corporales anormales o bruscos. Si esto ocurre, se encarga de dar aviso a los contactos respectivos al usuario, tales como familiares o servicios de emergencia.

Entre los resultados de pruebas realizadas en entornos reales, se ha determinado que este sistema es confiable y eficiente, y que se puede integrar sin problema en instalaciones que ya cuenten con infraestructura de señales WiFi.

Danger-Pose Detection System Using Commodity Wi-Fi for Bathroom Monitoring. In *Sensors*, vol. 19, no. 4, 2019 (Zhang *et al.*, 2019)

En este artículo se muestra un Sistema, basado en CSI, de detección de personas cuando se encuentran en situaciones de peligro dentro del baño.

El Sistema utiliza dispositivos WiFi, los cuales respetan la privacidad del usuario; en contraste con otros métodos de detección de movimiento tales como cámaras RGB que además de invadir la privacidad, presentan el problema de los puntos ciegos en ambientes “Sin Línea de Visión”; o el caso de los dispositivos vestibles, que en muchos casos a los usuarios se les olvida ponérselos.

Implementa un método de detección de anomalías basado en técnicas de Machine Learning, utilizando una cantidad mínima de datos de entrenamiento, debido a que se trata de datos enfocados a condiciones de peligro.

En los resultados de las pruebas, se demostró que el Sistema logró un alto desempeño al detectar la postura de las personas en situaciones de peligro y en un entorno “Sin Línea de Visión”, en este caso el baño.

Training-Free Human Vitality Monitoring Using Commodity Wi-Fi Devices. ACM Interactive, Mobile, Wearable and Ubiquitous Technologies (IMWUT) 2018 (Li *et al.*, 2018b)

A través del siguiente artículo se desarrolla una solución basada en señales WiFi llamada WiVit, que plantea la detección humana e identificación de actividades prescindiendo de la etapa de entrenamiento y calibración.

Funciona utilizando tanto el Access Point como los dispositivos del hogar conectados a WiFi, tales como la televisión, aire acondicionado, etc., para formar pares de transmisión. Este sistema está conformado por dos módulos, los cuales son:

1. El módulo de detección de actividades. Donde, para prescindir del entrenamiento o calibración, la clave está en que además de que el receptor toma la señal enviada desde el transmisor en línea recta, también recibe las señales que

rebotan desde los objetos, como las paredes, muebles, e incluso de la persona; y a esta superposición de todas las señales de todos los caminos que convergen en el receptor se le conoce como “propagación multipath”. Cuando la persona hace un mínimo movimiento, con ello es suficiente para ocasionar cambios en la longitud del camino reflejado de esa persona.

2. El módulo de detección del área. Que es capaz de identificar en qué área se queda la persona, sin ninguna intervención humana. Esto se logra dividiendo el espacio de detección en múltiples áreas, mediante los pares de transmisión, antes mencionados, esto de acuerdo a la geografía del entorno del hogar.

Los resultados de la experimentación en los tres escenarios de prueba al interior, revelan que la precisión en la detección de actividades es mayor del 98% y la precisión de la detección del área es cercana al 100%. También se realizó una prueba de reconocimiento de actividades a corto plazo con el fin de reconocer 4 tipos de actividades distintos, dando una precisión promedio del 94.2%.

WiFiFit: A Bodyweight Exercise Monitoring System with Commodity Wi-Fi. ACM UbiComp 2018 (Li *et al.*, 2018a)

En este artículo se lleva a cabo la demostración de un sistema de detección de rutinas de ejercicios llamado WiFiFit, que hace uso de las señales WiFi; su objetivo es identificar el tipo y el número de repeticiones que la persona realiza de cada ejercicio.

Para lograr el experimento se utilizaron un par de dispositivos WiFi, uno como transmisor y otro como receptor; ambos fueron equipados con las herramienta “CSI Tool3”, para lograr recolectar información CSI. Dicho sistema aprovecha lo que se conoce como “Efecto Doppler”, que se presenta cuando debido al movimiento humano, la longitud del camino de la señal humana cambia, y se da un cambio por una frecuencia Doppler hacia la señal recibida.

Como resultado del experimento se demuestra una precisión del 95.8% en el reconocimiento de ejercicios y 99% al contar las repeticiones; además de lograr monitorear las rutinas de ejercicios evitando el uso de dispositivos invasivos gracias a las señales WiFi.

Monitoring Vital Signs and Postures During Sleep Using WiFi Signals. IEEE Internet of Things Journal, vol 5., no. 3, June 2018 (Liu *et al.*, 2018)

En esta investigación se propone el rastreo de los signos vitales humanos, tanto de la frecuencia respiratoria como de la cardíaca, mientras la persona duerme. Esto es, con el fin de obtener información que servirá como ayuda en el diagnóstico de posibles enfermedades; mediante el uso de la propia red WiFi, así como CSI, para capturar los movimientos minuciosos causados por la respiración y los latidos del corazón. De esta manera se evita el uso de dispositivos invasivos en el cuerpo o de dispositivos complejos.

El Sistema hace uso de CSI considerando el dominio de tiempo y frecuencia, para lograr la estimación de la respiración y los latidos del corazón; y funciona bien tanto para una persona como para dos personas que duermen en la misma cama.

Entre los resultados de la investigación se demuestra que el Sistema es capaz de capturar de manera precisa los signos vitales durante la etapa de sueño, así como lograr un rendimiento comparable o mejor al de las técnicas tradicionales utilizadas, sin el elemento invasivo en el cuerpo, y a bajo costo.

2.4.6 Reflexión de lo encontrado

En base a lo encontrado, se concluye que la detección por señales inalámbricas es un trabajo que aún está en vías de desarrollo, ya que aún se siguen utilizando prototipos para su uso en universidades y para fines de investigación; usualmente, se menciona sobre aplicaciones a futuro de sistemas WiFi, tanto para el cuidado de la salud, como para la seguridad del hogar. Estas investigaciones sirven de base para entender a profundidad cómo funcionan las señales inalámbricas en el entorno, y así lograr un mejor desarrollo de la solución de software para emisión de alertas a partir de señales inalámbricas.

Mediante la presente investigación, se puede observar el impacto que tienen las tecnologías de detección de movimiento en la época actual, tal es el caso preciso de las señales CSI, que se pueden propagar con tal solo utilizar algunos dispositivos de red comerciales asequibles y en cualquier hogar que cuente con Internet.

Su uso tiene un gran alcance multidisciplinario, puesto que abarca tanto tecnologías de red, desarrollo de software, Data Mining y Machine Learning; y no solo se limita a la seguridad de los hogares ante el peligro de robo a casa-habitación, o la salud en adultos mayores, también tiene otras muchas aplicaciones, como puede ser el cuidado de niños pequeños, monitoreo del sueño, identificación de

rutinas de ejercicio, peligros potenciales en el baño, etc.

Capítulo 3

Materiales y Métodos

3.1 Dispositivos utilizados

Los dispositivos de hardware que se emplean son 2 Intel NUC Kit D54250WYKH: Un transmisor (Tx) y un receptor (Rx), cada uno cuenta con un monitor, un teclado, un mouse, y un adaptador de red Intel 5300. Tal como se muestra en la Figura 3.1, en donde se instalaron ambos dispositivos con fines de realizar pruebas controladas en el Laboratorio de Inteligencia Artificial del Instituto de Ingeniería de la UABC. Además, en la Figura 3.2, se observan los mismos dispositivos que después fueron instalados para la realización de pruebas no controladas, en un domicilio particular. Los espacios de pruebas se explican mejor en la Sección 3.2.1.

Los dispositivos NUC cuentan con un disco de estado sólido MDMS-BP4e-128 de 120 GB de almacenamiento, así como un adaptador de red Intel WiFi Link 5300, Modelo 533AN_HMW, el cual está conectado a las antenas que envían y reciben las señales WiFi; y dos memorias RAM de 2 GB DDR3L.

Por cada actividad humana se generó un archivo .dat como resultado del proceso de recepción de las señales CSI en el dispositivo Rx, archivo que es leído por WIFIALR, al momento que este es ejecutado.

Mientras que en el Laboratorio de Inteligencia Artificial se llevó a cabo una sesión de recolección de datos con fines de análisis de los mismos, como se muestra en el Anexo A, en el domicilio particular es donde se llevó a cabo el registro de cada una de las rondas de actividades para la creación de la matriz de training, con un total de 20 rondas por actividad, por cada sujeto de pruebas; para el caso de la recolección de datos nuevos que nunca ha visto el Modelo, cada uno de los sujetos de prueba realizó dos veces cada actividad, dando como resultado 42 archivos .dat generados con datos de la actividad realizada.

3.1 Dispositivos utilizados



Figura 3.1: Izquierda: Colocación de Tx o Transmisor con 1 antena. Derecha: Colocación de Rx o Receptor con tres antenas. Lugar: Laboratorio de Pruebas.



Figura 3.2: Izquierda: Colocación de Tx o Transmisor con 1 antena. Derecha: Colocación de Rx o Receptor con tres antenas. Lugar: Domicilio Particular.

3.1.1 Características técnicas

A continuación se listan las características técnicas de los dispositivos Intel NUC Kit D54250WYKH ([Intel, 2021](#)):

- Procesador: Intel® Core™ i5-4250U Processor (3M Cache, up to 2.60 GHz).
- Voltaje de Entrada de Corriente Directa soportado: 12-19 VDC.
- Memoria máxima: 16 GB.
- Tipos de memoria: DDR3L-1333/1600 1.35V SO-DIMM.
- Gráficos integrados: Sí.
- Tecnología de video clara.

3.1 Dispositivos utilizados

- Configuración RAID: 2.5" SSD + mSATA SSD (RAID-0 RAID-1).
- LAN Integrada: 10/100/1000.
- Tecnología de virtualización para I/O directa: Sí.
- Instrucciones AES: Seguridad de encriptamiento y desencriptamiento de datos, rápida y segura.

La imagen que se muestra en la página oficial de Intel referente a la ficha técnica de estos dispositivos se observa en la Figura 3.3.



Figura 3.3: Dispositivo de hardware Intel® NUC Kit D54250WYKH.

3.1.2 Adaptadores de red

Cada uno de los dispositivos NUC cuenta con un Adaptador de red Intel 5300 (Ver Figura 3.4), integrado manualmente, el de Tx tiene conectada una antena de envío de señales, mientras que el de Rx tiene conectadas tres antenas para la recepción de señales.




Figura 3.4: Interior del dispositivo NUC Rx: El adaptador de red Intel 5300 es visible en la parte superior de la imagen.

3.2 Metodología

Se utiliza la Metodología de Prototipos o Prototipado, como Metodología de desarrollo rápido e iterativo, más especificada en el Capítulo 4, con la intención de planificar los objetivos a corto, mediano y largo plazo para el Desarrollo del software que lleva por nombre WIFIALR (WIFI ALERTS). Primero con el desarrollo de un prototipo funcional que servirá para la realización de las pruebas, y posteriormente un software más robusto, a miras de implementarse para la seguridad de casas habitación, monitoreo de adultos mayores, entre otras aplicaciones.

También, se utiliza una Metodología de tres capas, más detallada en la Sección 3.2.2, para la gestión de los algoritmos de Data Mining y Machine Learning, que tiene por objetivo recolectar, analizar, limpiar y utilizar los datos experimentales para la construcción, entrenamiento e implementación del Modelo de Clasificación para el software.

De manera general, las metodologías previamente descritas se simplifican como una sola Metodología de dos pasos, como se muestra en la Figura 3.5.




Figura 3.5: Metodología que va desde el desarrollo de software mediante Prototipado hasta la implementación del Modelo de Clasificación.

3.2.1 Especificaciones Tecnológicas

Además del uso del Prototipado, mencionado anteriormente, las herramientas de software utilizadas para el desarrollo de la solución son:

- Sistema Operativo: Ubuntu 14.04 LTS Desktop con ambiente gráfico.
- Lenguajes de desarrollo: Python 3.7 y JSON.
- Sistema Manejador de Base de Datos Mysql Server 8.0. Con el cual se ha creado una base de datos para la gestión de los datos que fluyen a través del software WIFIALR.
- Librerías para la gestión de señales WiFi [Forbes \(2021\)](#); [Halperin \(2014\)](#); [Narui \(2020\)](#).

- Librerías de Python:
 - pandas 1.1.5.
 - numpy 1.16.5.
 - pymysql 0.10.1.
 - sklearn 0.23.2.
 - matplotlib 3.3.1.
 - scipy 1.5.2.
 - tkinter. 8.6.10.
 - statistics.
 - tsfel 0.1.4. [Research \(2021\)](#).

Los dispositivos NUC (Tx y Rx) de manera predeterminada ya cuentan con las librerías adecuadas de envío y recepción de señales CSI. Ambos equipos han sido configurados de la siguiente manera:

- Tx. Desde aquí se envía la señal inalámbrica hacia el dispositivo Rx. Se ha configurado para el envío de 20,000 paquetes a 1 MHz.
- Rx. Permanece a la escucha de la señal enviada desde Tx; como resultado se genera un archivo .dat que contiene los datos crudos de cada uno de los 20,000 paquetes recibidos, donde cada paquete contiene a su vez 90 subcarriers de amplitud y 90 de fase (30 subcarriers de amplitud y 30 de fase por cada una de las 3 antenas receptoras del dispositivo Rx).

En cuanto al espacio de las pruebas controladas, se ha desarrollado un mapa de distribución física (Ver Figura 3.6) del Laboratorio de Pruebas de Inteligencia Artificial, del Instituto de Ingeniería de la UABC. Mientras que para el caso de las pruebas no controladas, donde participaron los sujetos de pruebas, éstas se llevaron a cabo en el área de la sala de un domicilio particular (Ver Figura 3.7).

Para las pruebas realizadas, el software es ejecutado desde un entorno virtual de Conda en una laptop Dell Inspiron 15, con Windows 10 Home Single Language, procesador Intel Core i3 a 1.90 GHz, 4 GB de RAM, sistema operativo de 64 bits y un disco de estado sólido de 1TB. También se encuentra almacenado en un entorno virtual del dispositivo Rx, cuyo proceso de captura de información de CSI fue integrado junto con las rutinas de WIFIALR para que la clasificación fuera llevada a cabo a la par de la recepción de señales CSI.




Figura 3.6: Mapa de Distribución del Laboratorio de Pruebas de Inteligencia Artificial.

3.2.2 Metodología para Data Mining

Desde un punto de vista general, son cuatro las grandes etapas que deben seguirse en la construcción de modelos de clasificación, tal como se observa en la Arquitectura propuesta de tres capas, en la Figura 3.8. Esto para asegurar el análisis de datos de forma sistemática y repetible: Preprocesamiento de Datos, Extracción de Características, Clasificación o Reconocimiento, y por último, la Selección y Validación del Modelo de Minado de Datos.

De esta forma, se explorarán las siguientes técnicas dentro de estas etapas:

- Preprocesamiento. Los datos contenidos en los archivos .dat son convertidos a DataFrames legibles por Python, donde se toma en cuenta únicamente la amplitud de la señal y se les aplica técnicas de: Imputación de datos y Eliminación de ruido; a fin de que sean más precisos, completos y otorguen mayor certeza en los resultados.
- Extracción de Características. Para la presente investigación las variables extraídas por cada subcarrier en el dominio del tiempo son las indicadas en la Tabla 3.1.
- Algoritmos de Clasificación. Se realizaron las respectivas pruebas con cinco diferentes algoritmos de clasificación, haciendo referencia a las técnicas de




Figura 3.7: Mapa de Distribución del Domicilio Particular.

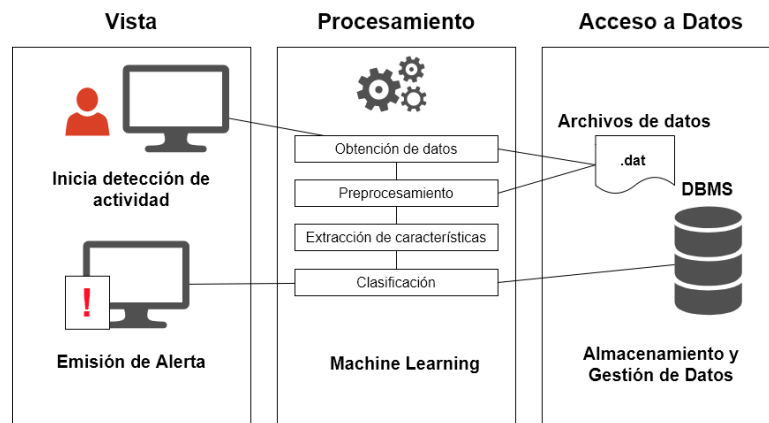


Figura 3.8: Arquitectura de tres capas del Software.

Data Mining y Machine Learning que mencionan Bishop (2007); Cios *et al.* (2007); Duda *et al.* (2000); Han *et al.* (2012): Support Vector Machine, Nearest Neighbors, Gaussian Naive Bayes, Linear Discriminant Analysis y Neural Network; de los cuáles se implementó el algoritmo de clasificación de tipo Support Vector Machine (SVM), que se encarga de construir un modelo en tiempo de ejecución a partir de una matriz de datos X y un vector de clases Y de training, y previamente generados en una sesión anterior de captura de actividades destinadas a training. Ambos archivos X y Y fueron cargados en las carpetas del sistema de archivos del equipo de Rx.

- Selección y Validación de Modelos. En la fase de training se separan los datos de entrenamiento en un porcentaje de 80% training, y 20% testing; y con rutinas en Python se estima la tasa de reconocimiento de cada uno de las técnicas mencionadas en el punto anterior; también se hizo la estimación para un conjunto de datos de testing diferentes a los de la matriz de training. Como la técnica con mejor tasa de reconocimiento con datos nunca antes vistos por el Modelo fue SVM, se optó por el uso de esta técnica.

Tabla 3.1: Características en el Dominio del Tiempo extraídas de CSI

TDF	Equation
Mean	$\frac{1}{T} \sum_{t=1}^T x_t$
Median	The median value of x_t
Root Mean Square	$\frac{1}{N} \sqrt{\sum_{t=1}^T x_t^2}$
Variance	$\frac{1}{N-1} \sqrt{\sum_{t=1}^T (x_t - Mean)^2}$

3.3 Caracterización del Sujeto

Los sujetos de prueba son tres, todos ellos en condiciones estables de salud y sin impedimento para la realización de dichas actividades, los cuales presentan las siguientes características:

- Sujeto 1. Mujer, 8 años. No ha presentado accidentes de caídas u otro.
- Sujeto 2. Mujer, 40 años. No ha presentado accidentes de caídas u otro.
- Sujeto 3. Hombre, 30 años. Es a la vez el investigador. Tiene antecedentes de un accidente de caída y lumbalgia postraumática.

Los sujetos tienen conocimiento de cómo realizar las actividades, ya que el investigador les indicó como llevarlas a cabo; también conocen el área de pruebas del domicilio particular, debido a que viven en dicho domicilio.

3.4 Especificación de Actividades

Se ejecutaron siete actividades en la zona experimental del domicilio particular con los tres diferentes sujetos de prueba, como se muestra en la Tabla 3.2, en un lapso de 20s:

Tabla 3.2: Descripción de las Actividades Especificadas

ID	Actividad	Descripción	Figura
BE	GO TO BED	El sujeto de pruebas comienza de pie en un punto en específico marcado en el suelo para proceder a recostarse.	Figura 3.9.
FA	FALL	Representa un accidente de una persona que estando de pie, cae al suelo.	Figura 3.10.
PI	PICK UP	Significa que una persona ha levantado un objeto del suelo, desde el centro de la LOS, en este caso se utilizó una esfera.	Figura 3.11
RU	RUN	El sujeto de pruebas corre en sentido opuesto a las manecillas del reloj, alrededor del área marcada en el suelo, dentro del rango de la LOS.	Figura 3.12.
SD	SIT DOWN	Se lleva a cabo cuando el sujeto de pruebas está de pie, y después se sienta en una silla.	Figura 3.13.
SU	STAND UP	Ocurre cuando el sujeto de pruebas permanece sentado en una silla, y después se levanta de ella.	Figura 3.14.
WA	WALK	Se lleva a cabo en la misma dirección que la actividad RUN pero caminando.	Figura 3.15.

3.4 Especificación de Actividades



Figura 3.9: Actividad GO TO BED. Sujeto de pruebas 3.



Figura 3.10: Actividad FALL. Sujeto de pruebas 3.



Figura 3.11: Actividad PICK UP. Sujeto de pruebas 2.

Para cada actividad, los sujetos de prueba esperan 3s después del comienzo de la transmisión de los paquetes desde Tx. La evidencia completa de la ejecución de las siete actividades de cada Sujeto de Pruebas se encuentra en el Anexo [B](#).

3.4 Especificación de Actividades



Figura 3.12: Actividad RUN. Sujeto de pruebas 1.



Figura 3.13: Actividad SIT DOWN. Sujeto de pruebas 2.



Figura 3.14: Actividad STAND UP. Sujeto de pruebas 3.



Figura 3.15: Actividad WALK. Sujeto de pruebas 1.

Capítulo 4

Resultados y Discusión

4.1 Generación de Modelos de Aprendizaje de Máquina

En el caso del proceso para la generación del Modelo de Clasificación, se tomaron en cuenta las siguientes etapas antes mencionadas en la Sección 3.2.2:

- Preprocesamiento. En esta etapa, en el software se realizan pruebas unitarias, para observar los resultados de las técnicas de Data Mining sobre los datos:
 - Conversión del contenido de la señal de Amplitud del archivo .dat a un DataFrame en Python. Como resultado se genera una matriz como la de la Figura 4.1. Durante las primeras pruebas, estos resultados eran convertidos a archivos .csv para facilitar su lectura.

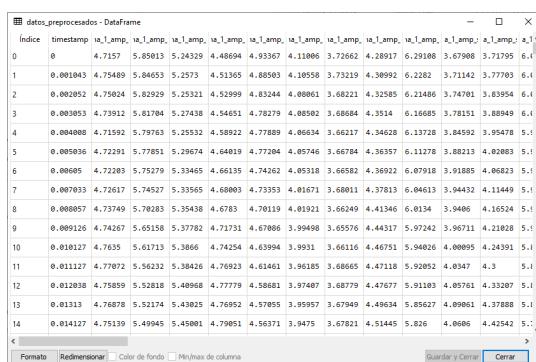
índice	timestamp	ena_l_amp_si	ina_l_amp_si	ena_l_amp_si	ina_l_amp_si	ena_l_amp_si	ina_l_amp_si	ena_l_amp_si	ina_l_amp_si	ena_l_amp_si	ina_l_amp_si
0	0	4.73916	6.78836	4.73916	3.77886	6.44177	4.73916	3.77886	3.77886	7.29188	
1	0.001043	2.94511	2.43359	4.54212	4.37179	4.37179	1.53182	4.54212	8.24569	2.69688	
2	0.002052	6.85895	0.736164	5.36814	4.71556	6.75676	4.71556	5.36814	3.74666	6.85895	
3	0.003053	5.68796	6.99564	4.15567	2.31843	4.62992	7.64822	4.15567	6.82654	8.13507	
4	0.004088	4.58542	3.94884	7.81474	5.98284	6.95114	-0.8385623	4.58542	4.58542	5.27623	
5	0.005036	6.91437	6.46855	4.76593	4.93627	0.788533	2.82773	1.92597	6.34956	8.91567	
6	0.00605	1.54957	5.83411	1.54957	4.55987	-2.68017	3.42843	1.54957	-0.847441	2.96286	
7	0.007033	6.11543	2.29289	5.38239	4.61158	-0.081584	4.61158	2.9979	4.61158	7.84889	
8	0.008057	4.93313	2.62865	7.74748	7.94343	4.24233	6.77838	1.92283	1.92283	6.15047	
9	0.009126	5.28273	4.59192	8.99884	6.95764	3.94734	5.64995	7.12797	2.97824	6.89578	
10	0.010127	6.13022	6.13022	3.74783	4.22288	1.98258	4.6496	3.5775	5.16112	2.6884	
11	0.011127	6.57589	4.98898	7.71532	5.68679	3.56559	2.59649	3.73592	6.11831	5.68679	
12	0.012038	7.16034	3.89698	8.24267	6.81954	-0.0824179	4.06732	2.92788	2.92788	6.84542	
13	0.01313	1.71666	3.65486	5.35747	6.91821	7.52875	6.66516	3.65486	4.72696	5.69666	
14	0.014127	5.61243	8.85955	7.89845	5.95181	3.98981	-1.85889	4.55459	5.95181	4.55459	

Figura 4.1: Conversión de .dat a DataFrame de Python.

4.1 Generación de Modelos de Aprendizaje de Máquina

- Imputación de datos por KNN para datos faltantes, tomando en cuenta 5 vecinos cercanos.
- Eliminación de ruido utilizando la técnica de filtro de Savitzky-Golay.

Como resultado se obtiene una mejor calidad de los datos. Figura 4.2. Estos resultados también eran originalmente convertidos a archivos .csv para facilitar su lectura.



índice	timestamp	va_1_amp	va_1_amp	va_1_amp	va_1_amp	va_1_amp	va_1_amp	va_1_amp	va_1_amp	va_1_amp	va_1_amp	va_1_amp	va_1_amp
0	0	4.7157	5.85813	5.24329	4.48604	4.93367	4.11086	3.72662	4.28917	6.29188	3.67988	3.71795	6.4
1	0.001043	4.75489	5.84653	5.2573	4.51365	4.88593	4.10558	3.73219	4.30992	6.2282	3.71142	3.77703	6.4
2	0.002052	4.75924	5.82929	5.25321	4.52999	4.83244	4.08061	3.68221	4.32585	6.21486	3.74701	3.83954	6.4
3	0.003053	4.73912	5.81704	5.27438	4.54651	4.79279	4.08592	3.68684	4.3514	6.16685	3.78151	3.88949	6.4
4	0.004008	4.71592	5.79763	5.29532	4.58922	4.77889	4.06634	3.66217	4.34628	6.13728	3.84592	3.95478	5.1
5	0.005036	4.72291	5.77851	5.29674	4.64919	4.77204	4.05746	3.66784	4.36357	6.11278	3.88213	4.02883	5.1
6	0.00605	4.72283	5.75279	5.33465	4.66135	4.74262	4.05318	3.66582	4.36922	6.07918	3.91885	4.06823	5.1
7	0.007033	4.72617	5.74527	5.33565	4.68093	4.73353	4.01671	3.68011	4.37813	6.04613	3.94432	4.11449	5.1
8	0.008057	4.73749	5.70283	5.35438	4.6785	4.70119	4.01921	3.66249	4.41346	6.0134	3.9486	4.16524	5.1
9	0.009126	4.74267	5.65158	5.37782	4.71751	4.67886	3.99498	3.65576	4.44317	5.97242	3.96711	4.21928	5.1
10	0.010127	4.7635	5.61713	5.3866	4.74254	4.63994	3.9931	3.66116	4.46751	5.94826	4.00095	4.24391	5.1
11	0.011127	4.77072	5.56232	5.38426	4.76923	4.61461	3.96185	3.68665	4.47118	5.92852	4.0347	4.3	5.1
12	0.012038	4.75859	5.52818	5.40968	4.77779	4.58681	3.97407	3.68779	4.47677	5.91183	4.05761	4.33207	5.1
13	0.01313	4.76878	5.52174	5.43025	4.76952	4.57855	3.95957	3.67949	4.48634	5.85627	4.09061	4.37888	5.1
14	0.014127	4.75139	5.49945	5.45081	4.79051	4.56371	3.9475	3.67821	4.51445	5.826	4.0606	4.42542	5.1

Figura 4.2: Fragmento de datos preprocesados.

- Extracción de Características. Originalmente se empleaban algoritmos de PCA para el análisis de las Principales Características de la señal, pero en la práctica esto resultaba en datos imprecisos, junto a que no se había trabajado correctamente la señal, la cual presentaba ruido en un inicio, tal como se muestra en la Figura 4.3.

Actualmente, ya no se emplea PCA, sino la Extracción de Características en el Dominio del Tiempo: Mean, Median, Root Mean Square y Variance, explicado en el Capítulo 3. En la Figura 4.4 se observa un vector como resultado, con esas 4 características extraídas a partir de cada uno de los subcarriers de la señal de Amplitud.

- Algoritmos de Clasificación. En el caso de la Clasificación de los datos de la matriz de training, ya de antemano se conoce de qué tipo de actividad se trata, debido a que en los archivos de shell script en el dispositivo Rx se coloca como parámetro el nombre que llevará el archivo .dat siguiendo la siguiente nomenclatura: ”{BE, FA, PI, RU, SD, SU, WA}_DDMMYY_HHMM_SS.dat”, por ejemplo, para la actividad RUN sería ”RU_210327_0906_00.dat”. Como resultado de la clasificación de datos de training, WIFIALR genera una Matriz X y un vector Y de training. -Ver Figuras 4.5, 4.6. Por otro lado, para la

4.1 Generación de Modelos de Aprendizaje de Máquina




Figura 4.3: Muestras de 6 Principales Componentes de la Actividad RUN evidenciando la existencia de ruido.

Índice	0_Mean	0_Median	0_Root mean square	0_Variance	10_Mean	10_Median	10_Root mean square	10_Variance	11_Mean	11_Median
0	5.67333	6.09016	5.92772	2.95124	3.57427	4.00381	4.4742	7.24308	3.76054	4.09074

Figura 4.4: Características en el Dominio del Tiempo.

Índice	0	1	2	3	4	5	6	7	8	9	10
0	5.67333	6.09016	5.92772	2.95124	3.57427	4.00381	4.4742	7.24308	3.76054	4.09074	4.63909
1	5.15765	5.3911	5.53784	4.0663	3.92338	4.35894	4.51661	5.00686	4.09974	4.55472	4.68481
2	-4.76603	-5.10744	5.06496	2.93874	-6.2816	-6.82954	6.70277	5.46869	-5.71851	-6.38802	6.22455
3	-0.0593505	-0.166299	2.26052	5.10641	-2.68382	-2.53708	4.84348	16.2564	-2.08436	-1.74821	4.57778
4	10.0974	10.7183	10.4804	7.88134	11.8956	12.2377	12.2263	7.97517	12.1216	12.42	12.4485
5	10.3011	10.8568	10.757	9.6014	12.4456	13.2622	12.8544	10.343	12.6282	13.5142	13.0183
6	17.0419	17.7322	17.1164	2.54685	17.4779	18.1178	17.5798	3.57296	17.713	18.3402	17.815
7	18.5071	18.8708	18.5297	0.838191	18.7816	19.2913	18.8116	1.12702	19.0221	19.5183	19.0499
8	14.7425	14.4992	14.8967	4.56814	15.1184	14.9163	15.3228	6.22193	15.3773	15.2407	15.585
9	14.3023	14.4315	14.3317	0.839091	15.461	15.6887	15.4885	0.851767	15.742	16.0088	15.7694
10	11.1652	11.9331	11.4707	6.91489	12.1787	12.8508	12.6011	10.4652	12.2903	13.0192	12.7177
11	11.4936	12.1555	11.7413	5.75633	12.5148	13.5312	12.8906	9.54759	12.5725	13.5641	12.9537

Figura 4.5: Ejemplo de matriz de training X.

4.1 Generación de Modelos de Aprendizaje de Máquina

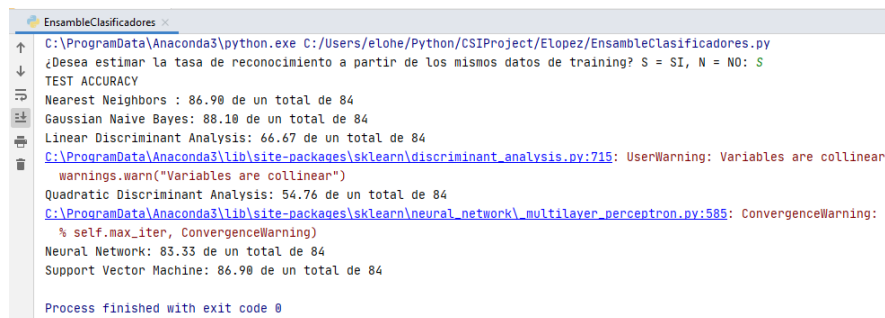
Clasificación de datos nunca antes vistos, WIFIALR da como resultado los dos tipos de alertas que se mencionan en la Sección 4.3, a partir del Modelo de Clasificación construido utilizando la Support Vector Machine.



Índice	0
0	1
1	1
2	3
3	3
4	4
5	4
6	5
7	5
8	6
9	6
10	7
11	7

Figura 4.6: Ejemplo de vector de clases Y, de training.

- Selección y Validación de Modelos. En esta etapa se realizaron pruebas para determinar cuál de los algoritmos de Clasificación propuestos da la mejor tasa de reconocimiento, por lo cual se construyó un script para probar cada uno, tomando en cuenta tanto datos de training divididos en 80%-20%, como datos nuevos nunca antes vistos. -Ver Figuras 4.7, 4.8.

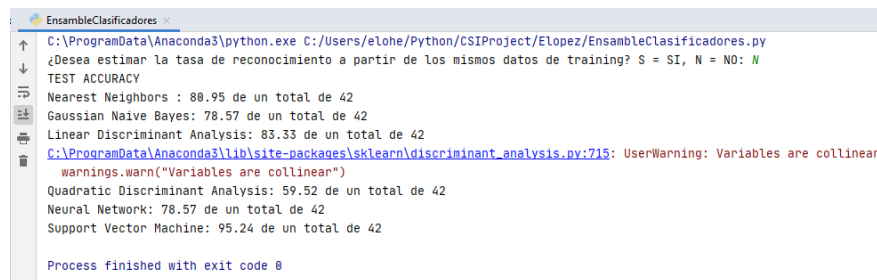


```
EnsambleClasificadores x
C:\ProgramData\Anaconda3\python.exe C:/Users/eloh/Python/CSIPProject/Elopez/EnsambleClasificadores.py
¿Desea estimar la tasa de reconocimiento a partir de los mismos datos de training? S = SI, N = NO: S
TEST ACCURACY
Nearest Neighbors : 86.90 de un total de 84
Gaussian Naive Bayes: 88.10 de un total de 84
Linear Discriminant Analysis: 66.67 de un total de 84
C:\ProgramData\Anaconda3\lib\site-packages\sklearn\discriminant_analysis.py:715: UserWarning: Variables are collinear
warnings.warn("Variables are collinear")
Quadratic Discriminant Analysis: 54.76 de un total de 84
C:\ProgramData\Anaconda3\lib\site-packages\sklearn\neural_network\multilayer_perceptron.py:585: ConvergenceWarning:
% self.max_iter, ConvergenceWarning)
Neural Network: 83.33 de un total de 84
Support Vector Machine: 86.98 de un total de 84
Process finished with exit code 0
```

Figura 4.7: Resultados de Validación de Modelos en Training.

El criterio utilizado para la selección de los mejores parámetros para cada modelo de clasificación fue experimentar comparándolos en tres ocasiones, de manera que se seleccionaron los que dieron la precisión más alta, o en caso de que haya dado la misma en más de una ocasión, se utiliza el primer conjunto de

4.1 Generación de Modelos de Aprendizaje de Máquina



```
EnsambleClasificadores
C:\ProgramData\Anaconda3\python.exe C:/Users/eIopez/Python/CSIProject/EIopez/EnsambleClasificadores.py
¿Desea estimar la tasa de reconocimiento a partir de los mismos datos de training? S = SI, N = NO: N
TEST ACCURACY
Nearest Neighbors : 80.95 de un total de 42
Gaussian Naive Bayes: 78.57 de un total de 42
Linear Discriminant Analysis: 83.33 de un total de 42
C:\ProgramData\Anaconda3\lib\site-packages\sklearn\discriminant_analysis.py:715: UserWarning: Variables are collinear
warnings.warn("Variables are collinear")
Quadratic Discriminant Analysis: 59.52 de un total de 42
Neural Network: 78.57 de un total de 42
Support Vector Machine: 95.24 de un total de 42

Process finished with exit code 0
```

Figura 4.8: Resultados de Validación de Modelos con 42 muestras de datos nunca antes vistos.

parámetros con que se realizaron pruebas:

Comparación de parámetros en Support Vector Machine

- 95.24% - kernel linear, parámetro de complejidad 1 y función de decisión "One vs Rest".
- 92.86% - kernel de función de base radial, parámetro de complejidad 10 y función de decisión "One vs Rest".
- 19.05% - kernel sigmoide, parámetro de complejidad 10 y función de decisión "One vs One".

Comparación de parámetros en Nearest Neighbors

- 80.95% - 7 vecinos cercanos, pesos de tipo uniforme y métrica de distancia Euclidiana.
- 80.95% - 5 vecinos cercanos, puntos de peso por la inversa de su distancia y métrica de distancia Euclidiana.
- 80.95% - 3 vecinos cercanos, pesos de tipo uniforme y métrica de distancia Euclidiana.

Comparación de parámetros en Gaussian Naive Bayes

- 78.57% - con un valor de suavizado de $1e-9$.
- 78.57% - con un valor de suavizado de 0.0001.
- 78.57% - con un valor de suavizado de $1e-5$.

Comparación de parámetros en Linear Discriminant Analysis

4.1 Generación de Modelos de Aprendizaje de Máquina

- 83.33% - solucionador de descomposición de valor singular y umbral absoluto de $1.0e-4$.
- 83.33% - solucionador por mínimos cuadrados y umbral absoluto de $1.0e-9$.
- 83.33% - solucionador por descomposición de eigenvalores y umbral absoluto de $1.0e-6$.

Comparación de parámetros en Neural Network

- 78.57% - estrategia de aprendizaje de tipo gradiente estocástico descendente, valor alpha de 0.0001, una capa interna y 100 nodos internos.
- 78.57% - estrategia de aprendizaje de tipo gradiente estocástico descendente, valor alpha de $1.0e-4$, una capa interna y 100 nodos internos.
- 14.29% - estrategia de aprendizaje de tipo gradiente estocástico descendente, valor alpha de $1.0e-9$, una capa interna y 7 nodos internos.

Como resultado de un análisis realizado para los valores nuevos nunca antes vistos por los modelos de Clasificación, el porcentaje de mayor precisión, en contraste con las demás técnicas utilizadas, fue para la Support Vector Machine, dando un 95.24% utilizando un kernel linear, un parámetro de complejidad de 1 y una función de decisión “One vs Rest”:

- Support Vector Machine: 95.24%
- Nearest Neighbors: 80.95%
- Gaussian Naive Bayes: 78.57%
- Linear Discriminant Analysis: 83.33%
- Neural Network: 78.57%

Para la interpretación de las clases de las matrices de confusión, se maneja la siguiente numeración para cada etiqueta de clase:

1. GO TO BED.
2. FALL.
3. PICK UP.
4. RUN.

4.1 Generación de Modelos de Aprendizaje de Máquina

5. SIT DOWN.
6. STAND UP.
7. WALK.

En la Figura 4.9 la matriz de confusión para el modelo de SVM, muestra la mayor tasa de verdaderos positivos por cada una de las 7 clases que representan cada actividad.

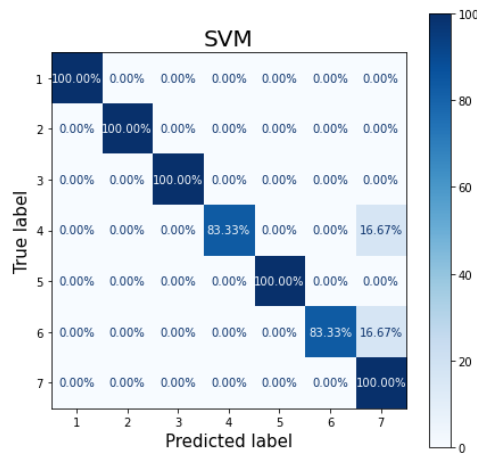


Figura 4.9: Matriz de Confusión para Support Vector Machine.

Por cada uno de los demás algoritmos de clasificación, el porcentaje de precisión fue de: 80.95% para Nearest Neighbors, con siete vecinos cercanos, pesos uniformes y utilizando la métrica de distancia Euclidiana; 78.57% para Gaussian Naive Bayes, con un valor de suavizado de $1e-9$; 83.33% para el caso de Linear Discriminant Analysis, con un solucionador de descomposición de valor singular, y un umbral absoluto de $1.0e-4$; y 78.57% para Neural Network, con una estrategia de aprendizaje de tipo gradiente estocástico descendente, valor alpha de 0.0001, con una capa interna y 100 nodos internos. Sus respectivas matrices de confusión muestran valores menores de tasas verdaderas positivas comparadas con los resultados de la SVM, tal como se muestra en la Figura. 4.10.

Se ha seleccionado el Modelo de Clasificación a partir de la Support Vector Machine, por otorgar el mejor reconocimiento en el caso de datos nunca antes vistos, alcanzando una tasa de 95.24%.

4.1 Generación de Modelos de Aprendizaje de Máquina

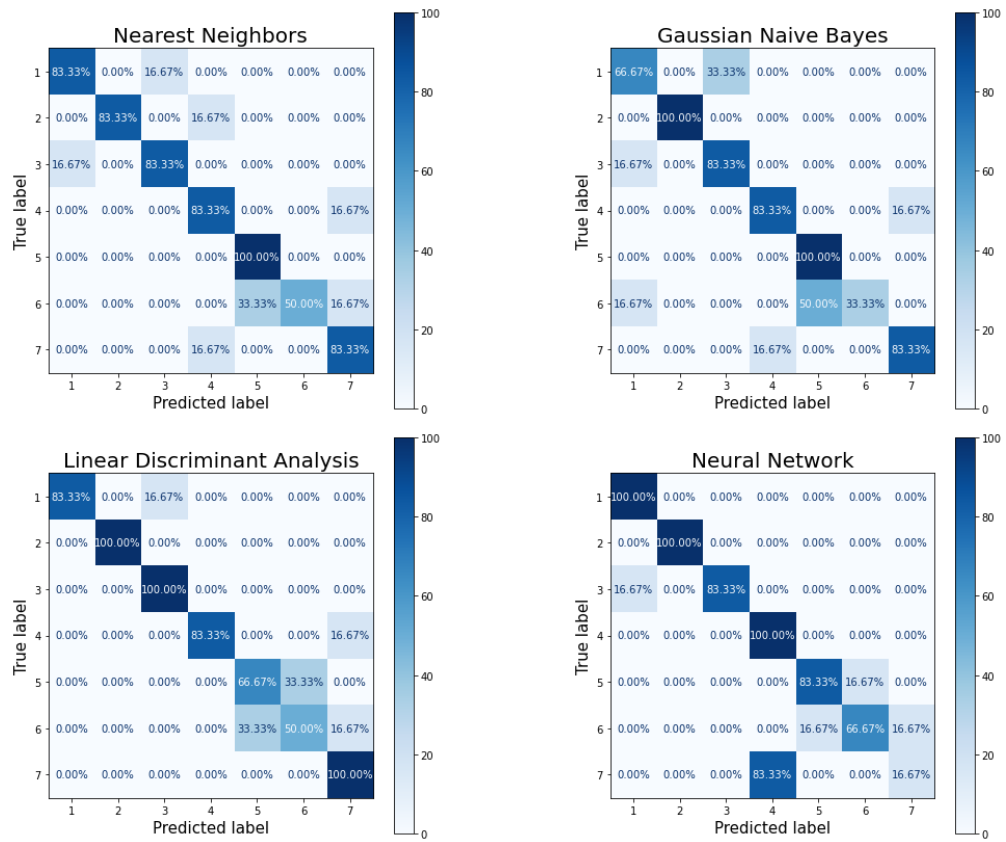


Figura 4.10: Matriz de Confusión para: Nearest Neighbors (parte superior izquierda), Gaussian Naive Bayes (parte superior derecha), Linear Discriminant Analysis (parte inferior izquierda) y Neural Network (parte inferior derecha).

Por último es importante destacar que algunas actividades son parecidas y por eso a menudo se confunden, esto puede comprobarse mediante los gráficos de amplitud, tal es el caso de actividades como RUN y WALK, o SIT DOWN con STAND UP.

4.2 Diseño y Desarrollo de Software

Para el desarrollo del software se emplea la Metodología de Prototipado, cuyos roles y procesos se definen en las subsecciones 4.2.1 y 4.2.2, respectivamente; su aplicación se detalla en el Anexo C. También se establecen los tiempos de trabajo y por último, en la subsección 4.2.3 se relata brevemente el diseño de la base de datos del sistema.

Principalmente los requerimientos establecidos para el desarrollo del software, han sido especificados en la Tabla 4.1. Estos fueron cambiando a lo largo de cada iteración, según las necesidades de desarrollo y los tiempos de entrega de cada producto de software, dando un total de 11 meses y 2 semanas de tiempo de desarrollo.

Las herramientas de software empleadas para el Análisis, Diseño y Desarrollo en el ambiente de Windows fueron las siguientes:

- Anaconda Navigator 1.9.12. Mediante este gestor de entornos y paquetes, se ha creado un entorno virtual de Conda, tal como se muestra en la Figura 4.11, y donde se han instalado los paquetes de Python necesarios para el desarrollo de los scripts del proyecto.

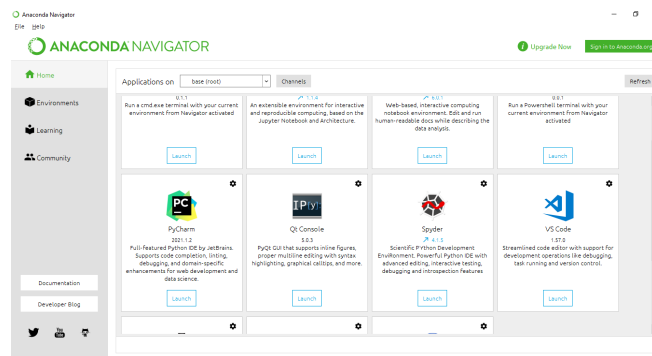


Figura 4.11: Interfaz de Anaconda Navigator 1.9.12.

- Spyder 4.1.5. Se trata de un Entorno de Desarrollo Integrado que viene incluido con la instalación de Anaconda Navigator; para fines de desarrollo

Tabla 4.1: Especificación de requerimientos

<i>Requerimientos</i>	<i>Tiempos de entrega</i>
Realizar pruebas controladas.	1 mes
Analizar comportamiento de los scripts de Hirokazu Narui y Daniel Halperin.	3 semanas
Reproducir gráficos de los scripts de Narui y Halperin.	2 semanas
Analizar los datos de las pruebas controladas, y aplicarles técnicas de Preprocesamiento.	3 semanas
Definir las funciones para la conversión de .dat a .csv en Python.	2 semanas
Definir las entidades y campos de la Base de Datos.	1 mes
Extracción de Características de los datos de las pruebas controladas.	1 mes
Desarrollo de Algoritmos de clasificación.	1 mes
Selección y Validación de Modelos.	1 mes
Selección de sujetos de prueba.	3 semanas
Definición de pruebas con sujetos de prueba.	2 semanas
Realizar pruebas con sujetos de prueba. Se llevarán a cabo 20 rondas por cada actividad, por cada sujeto de prueba.	2 semanas
Generación de alertas a partir de resultados obtenidos.	1 mes
Creación de mapa de distribución de pruebas en el hogar.	1 semana
Realizar pruebas controladas en el hogar.	1 mes

se actualizó hasta la versión 4.1.5. Resulta muy práctico para la visualización de matrices, tuplas, DataFrames, arreglos y demás conjuntos de datos. Figura 4.12.

Nombre	Tipo	Tamaño	Valor
csv_col_list	list	91	['timestamp', 'antena_1_amp_sub1', 'antena_1_amp_sub2', 'antena_1_amp_...]
csv_cols	DataFrame	(91, 1)	Column names: Column_Names
csv_headers	str	1	csi_headers.csv
database	DataBase	1	DataBase object of DataBaseConnection module
datos_crudos	DataFrame	(19991, 91)	Column names: timestamp, antena_1_amp_sub1, antena_1_amp_sub2, antena_...
datos_preprocesados	DataFrame	(19991, 91)	Column names: timestamp, antena_1_amp_sub1, antena_1_amp_sub2, antena_...
datos_sin_timestamp	DataFrame	(19991, 90)	Column names: antena_1_amp_sub1, antena_1_amp_sub2, antena_1_amp_sub3, ...
elementosTraining	str	1	N
file_len	int	1	1
file_name	str	1	BE_210321_0349_00.dat
file_path	tuple	1	('C:/Users/eliohe/Python/CSIPProject/Elopez/datos_crudos/BE_210321_0349_...')
guardarImagenes	str	1	N
i	int	1	0
mov_predecido	int64	1	1
movimiento	str	1	ALERT: A PERSON HAS GONE TO BED
nam	tuple	360	(0, 1, 2, 3, 4, 5, 6, 7, 8, 9, ...)
root	Tk	1	Tk object of tkinter module
short_name	str	1	BE_210321_0349_00
splitted	list	8	['C:', 'Users', 'eliohe', 'Python', 'CSIPProject', 'Elopez', 'datos_crud...']
vector	DataFrame	(1, 360)	Column names: 0_Mean, 0_Median, 0_Root mean square, 0_Variance, 10_Mea...

Explorador de variables Ayuda Gráficos Archivos

Figura 4.12: Explorador de variables del Entorno de Spyder.

- PyCharm Community 2020.2.5. También se trata de un Entorno de Desarrollo Integrado, se ha utilizado debido a que ha resultado más eficiente para la generación de gráficos y eficiencia en el procesamiento de grandes cantidades de datos.
- diagrams.net 14.7.7. Se ha utilizado para la creación de los Mapas de Distribución, y el diseño de la Arquitectura del Software, los cuales se incluyen en el Capítulo 3.

El Desarrollo del Software inicialmente estuvo enfocado en la generación de la Matriz X y vector de clases Y de training, mediante múltiples scripts en Python asociados a cada una de las etapas del Modelo de Clasificación; posteriormente se integró la funcionalidad de las etapas del Modelo en un script único que funciona tanto para la generación de matrices de training, como de testing, con fines de conocer la tasa de reconocimiento para estos nuevos datos; además tiene la opción de que los datos seleccionados sean tratados para fines de clasificación a partir de un Modelo de Machine Learning entrenado a partir de los datos de training,

4.2 Diseño y Desarrollo de Software

y detonar la emisión de alertas al usuario.

Actualmente existe una versión estable del proyecto WIFIALR en el repositorio de GitHub del autor: <https://github.com/RevantIE/WIFIALR>, donde se detalla tanto la ejecución de la primera versión del software que utiliza múltiples scripts, como la versión integrada, que es la que contiene la mejor funcionalidad. También muestra la ejecución del software desde la terminal de Ubuntu, hasta la identificación de la actividad realizada por el usuario (Figura 4.13).



EMMANUEL LÓPEZ HERNÁNDEZ Merge branch 'master' of https://github.com/RevantIE... c57c4b1 on Jun 16 81 commits		
idea	Eliminación de archivos no esenciales; optimización de archivos de ej...	6 months ago
datos_crudos	Actualización de scripts y archivos de imagenes	5 months ago
datos_nuevos	Eliminación de archivos que ya no se utilizan	5 months ago
db_schemas	Actualización de archivos del Modelo, base de datos e imagenes	5 months ago
imagenes	Merge branch 'master' of https://github.com/RevantIE/CSIPProject	5 months ago
modelos	Se actualiza Modelo Entidad-Relación; se añaden datos de nuevas pru...	11 months ago
scripts_de_apoyo	Se reincorpora archivo de EnsembleClasificadores a raiz	6 months ago
trn_tst	Actualización de WIFIALR, con mejora en la tasa de reconocimiento	5 months ago
.gitignore	Se añade archivo .dat de la actividad de BE en la carpeta de datos cr...	5 months ago
Amplitude.py	Eliminación de archivos no esenciales; optimización de archivos de ej...	6 months ago
AssembledModel.py	Actualización de scripts y archivos de imagenes	5 months ago
ClasesNumericas.py	Se agrega el historial de base de datos a la carpeta nueva 'db_schema...	13 months ago
Classification.py	Versión preliminar de WIFIALR	5 months ago

Figura 4.13: Algunos elementos del proyecto WIFIALR en el repositorio de GitHub del autor.

En cuanto a las Pruebas Unitarias, éstas se realizaron tomando en cuenta las etapas del Modelo de Clasificación y los resultados de los datos en cada una de estas etapas utilizando tanto el visor de variables de Spyder, como el contenido de los archivos .csv generados, esto se explica en la sección 4.1. En cuanto a las Pruebas Integrales, se llevaron a cabo mediante la ejecución del código tanto en el ambiente Windows, cuyo resultado de ejecución se aprecia en la sección 4.3, como en el ambiente de Ubuntu en el dispositivo Rx, esto último se detalla en el Anexo D.

Respecto al Mantenimiento del Software, este se actualiza tanto en el ambiente de Windows como en Ubuntu en el dispositivo Rx, y los cambios son subidos al repositorio GitHub.

4.2.1 Roles del Sistema

En la Tabla 4.2 se establecen los roles involucrados en el desarrollo del prototipo.

Tabla 4.2: Roles del Sistema

<i>Actores</i>	<i>Roles</i>	<i>Responsabilidades</i>
Emmanuel López Hernández	Investigador / Líder de proyecto	Responsable de llevar a cabo la investigación y las pruebas preliminares.
Emmanuel López Hernández	Diseñador	Responsable del diseño de la base de datos, el Modelo de capas del software e interfaces gráficas.
Emmanuel López Hernández	Desarrollador	Responsable de crear y dar mantenimiento al código.
Emmanuel López Hernández	Sujeto de Pruebas 3	Ejecución de pruebas.
Félix Fernando González Navarro	Cliente / Usuario	Responsable de proveer los requerimientos y evaluar el prototipo desarrollado.
Fátima Hernández López	Sujeto de Pruebas 1	Ejecución de pruebas.
María Celina López Hernández	Sujeto de Pruebas 2	Ejecución de pruebas.

4.2.2 Proceso de desarrollo de prototipos

De acuerdo con [García \(2013\)](#), el modelo de prototipos o modelo de desarrollo evolutivo, usado comúnmente en proyectos de desarrollo de software, se utiliza para ofrecer al usuario una vista preliminar de lo que será el sistema, buscando reducir tiempo, debido a que el prototipo debe ser construido a la brevedad posible, y dinero, ya que para el prototipo no deben invertirse muchos recursos.

El tipo de Modelo de Prototipo desarrollado en la presente investigación se conoce como Evolutionary Prototyping, que de acuerdo con [Chen et al. \(2016\)](#)

es necesario cuando los requerimientos son inciertos, las tecnologías nuevas, no existen sistemas comparables que hayan sido desarrollados antes, o que la experimentación o evaluación del diseño sea necesaria para evaluar soluciones. Se emplea debido a que sus módulos serán utilizados para construir el producto real.

Tomando como base lo descrito por Poonam (2018) y Nyandowe & Zakariyah (2014), los pasos para la creación de prototipos son los siguientes:

1. Identificación de Requerimientos. Se identifican los requerimientos y necesidades en detalle (Poonam, 2018).
2. Diseño y construcción del prototipo. Se crea un prototipo inicial, y aunque no se trate precisamente del producto final, ya contiene funciones básicas (Nyandowe & Zakariyah, 2014).
3. Evaluación del usuario. Los usuarios realizan pruebas con el prototipo y otorgan la retroalimentación sobre cualquier cambio requerido para mejorar las interacciones y la usabilidad del prototipo (Nyandowe & Zakariyah, 2014).
4. Redefinición del prototipo. Una vez que el cliente ha evaluado el modelo, si no está satisfecho con el modelo inicial, este se deshecha y se construye un nuevo modelo para las necesidades del cliente (Poonam, 2018).
5. Producto final. Se mejora el prototipo a través de la evaluación repetitiva del usuario y el ciclo continúa hasta que el prototipo es suficientemente satisfactorio para convertirse en el producto final, listo para el mercado (Nyandowe & Zakariyah, 2014).

En el Anexo C se muestra el refinamiento de requisitos y mejora del prototipo a través de sus diferentes iteraciones, siguiendo como base el Modelo de Prototipos, como se muestra en la Figura 4.14.

4.2.3 Diseño de la Base de Datos

La Base de Datos está construida en MySQL Server, a partir de un Modelo Entidad-Relación construido en MySQL Workbench 8.0 (Ver Figura 4.15). En este modelo se han construido tres tablas relacionadas a las actividades realizadas en el interior, las cuales son:

- movimientos. Representa un catálogo que incluye cada una de las actividades que se llevan a cabo en los experimentos. Es consultada al momento

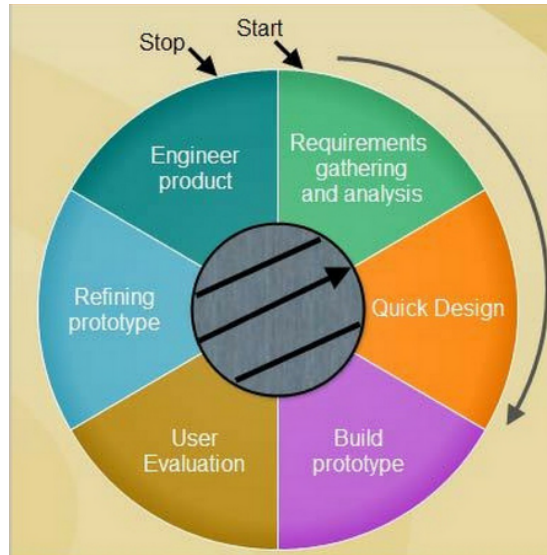


Figura 4.14: Modelo de Prototipos (Poonam, 2018).

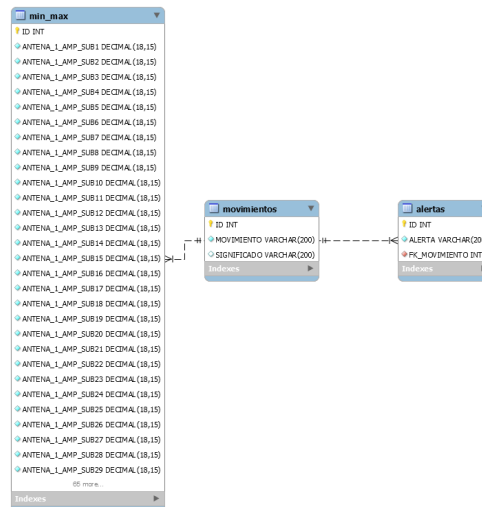


Figura 4.15: Modelo Entidad-Relación de la Base de Datos.

que el software clasifica con un valor numérico la actividad realizada. Se incluye un registro adicional "DOES NOT APPLY", para un futuro desarrollo en el caso de actividades que no apliquen (Figura 4.16).

- alertas. Contiene las notificaciones que se detonan como respuesta al usuario una vez que WIFIALR ha identificado el tipo de actividad (Figura 4.17).
- min_max. Almacena los valores máximos y mínimos de cada uno de los

4.3 Actividades nuevas para el Modelo

	ID	MOVIMIENTO	SIGNIFICADO
▶	1	BE	GO TO BED
	2	FA	FALL
	3	PI	PICK UP
	4	RU	RUN
	5	SD	SIT DOWN
	6	SU	STAND UP
	7	WA	WALK
	8	NA	DOES NOT APPLY
★	NULL	NULL	NULL

Figura 4.16: Catálogo de las actividades.

	ID	ALERTA	FK_MOVIMIENTO
▶	1	HAS GONE TO BED	1
	2	HAS FALLEN	2
	3	HAS LIFTED AN OBJECT	3
	4	HAS RUN	4
	5	HAS SAT DOWN	5
	6	HAS STOOD UP	6
	7	HAS WALKED	7
★	NULL	NULL	NULL

Figura 4.17: Tabla de alertas que se envían como respuesta al usuario al identificar la actividad realizada.

subcarriers de Amplitud (Figura 4.18). En su concepción inicial se pensó para que cuando lleguen nuevos datos, sean comparados contra los valores máximos y mínimos registrados, y posteriormente sean normalizados. Actualmente no se utiliza pero se implementará en una futura investigación.

ID	ANTENA_1_AMP_SUB1	ANTENA_1_AMP_SUB2	ANTENA_1_AMP_SUB3	ANTENA_1_AMP_SUB4
▶ 15	-5.917933333333333	4.280400000000000	-4.909299999999999	-5.810533333333333
16	10.375333333333336	20.419999999999998	11.785333333333332	11.541666666666666
17	-5.917933333333333	4.280400000000000	-4.909299999999999	-5.810533333333333
18	10.375333333333336	20.419999999999998	11.785333333333332	11.541666666666666
19	-5.572633333333333	-5.513600000000000	-5.489066666666666	-5.442300000000000
20	14.411333333333332	16.888333333333332	15.450999999999999	15.455666666666666
23	-13.018400000000000	-9.430266666666666	-6.229299999999999	-8.801133333333334

Figura 4.18: Tabla de valores mínimos y máximos de cada subcarrier de la Amplitud de la señal.

4.3 Actividades nuevas para el Modelo

Del total de las 42 actividades realizadas, se observa que 40 fueron identificadas correctamente, es decir el 95.23% del total, como se ilustra en los resultados de la Tabla 4.3. Las actividades mejor reconocidas en los tres casos son GO TO BED, FALL, PICK UP, SIT DOWN y WALK; las actividades de RUN y STAND UP son reconocidas con frecuencia.

4.3 Actividades nuevas para el Modelo

Tabla 4.3: Resultados de Actividades Identificadas

Tipos de Actividad	Cantidad de actividades identificadas		
	<i>Sujeto 1</i>	<i>Sujeto 2</i>	<i>Sujeto 3</i>
GO TO BED	2/2	2/2	2/2
FALL	2/2	2/2	2/2
PICK UP	2/2	2/2	2/2
RUN	2/2	2/2	1/2
SIT DOWN	2/2	2/2	2/2
STAND UP	2/2	2/2	1/2
WALK	2/2	2/2	2/2
TOTAL	14/14	14/14	12/14

El software también es capaz de almacenar imágenes de los Heat Maps de la amplitud de la señal a través del timestamp de 20s como se muestra en la Figura 4.19, así como de los dos primeros subcarriers de cada antena de Rx (A, B y C), como en la Figura 4.20, dentro de una carpeta predeterminada del sistema de archivos.




Figura 4.19: Amplitud de la Actividad GO TO BED por cada Antena de Rx.

En la Figura 4.21 se muestra el resultado de la identificación de la Actividad GO TO BED, donde se envía un mensaje en consola a través del monitor, al igual que un mensaje de alerta, como el de la Figura 4.22. Los mensajes están presentes en la base de datos, y son invocados al momento de la Clasificación,

4.3 Actividades nuevas para el Modelo




Figura 4.20: Primeros dos subcarriers de cada una de las antenas de Rx: A, B y C. Actividad GO TO BED.

indicando al usuario el tipo de actividad detectada.

En el Anexo A se incluyen los Heat Maps y Gráficos de Subcarriers de cada una de las actividades realizadas por el investigador en el laboratorio; en el Anexo B se encuentran los gráficos de las actividades realizadas en el domicilio particular con los tres sujetos de prueba. Para cada caso, se registra solo evidencia gráfica de un solo ejemplo de cada una de las actividades realizadas.

En base a los resultados obtenidos, se ha determinado que, con el estatus actual del software, aún hay un camino amplio por recorrer antes de implementarlo como una solución óptima en ambientes al interior, ya que todavía hace falta que se lleven a cabo nuevas pruebas en diferentes entornos interiores, replicando las medidas de las distancias y alturas de los dispositivos, así como de la ejecución de las actividades de manera similar a las representados en el experimento del

Capítulo 5

Conclusiones

5.1 Conclusiones

De acuerdo a los resultados obtenidos en el domicilio particular, se concluye que en la etapa actual del desarrollo del software, este logra en promedio reconocer correctamente las actividades realizadas, e informar al usuario mediante salidas tanto de consola como de interfaz gráfica de ventanas el resultado de la detección de actividades.

Se cumple con el Objetivo General de la presente investigación, al lograr el desarrollo de una aplicación capaz de arrojar mensajes de alerta a partir de la actividad detectada en una habitación por una persona mediante señales inalámbricas y algoritmos de Machine Learning.

Los Objetivos Específicos se cumplen, al lograr la clasificación de actividades humanas mediante los algoritmos de aprendizaje, con un mínimo de error del 4.77%, así como la emisión de alertas para notificar a los usuarios sobre la actividad realizada.

Se alcanzan las Metas establecidas (a excepción del derecho de autor), las cuales se mencionan a continuación:

- Solución de software desarrollada.
- Se logra la publicación arbitrada de dos artículos de investigación:
 - E. López, F. González, and B. Flores, Software para Emisión de Alertas Basadas en Detección de Movimiento por Señales WiFi. SOCIEDAD

MEXICANA DE CIENCIAS DE LA COMPUTACIÓN, 2020, pp. 14-21.

- E. Lopez-Hernandez, F. F. Gonzalez-Navarro, B. L. Flores-Rios and J. Caro-Gutierrez, "WIFIALR WiFi Alerts Software for Human Movements using Machine Learning Algorithms," 2021 Mexican International Conference on Computer Science (ENC), 2021, pp. 1-7, doi: 10.1109/ENC53357.2021.9534823.

- Redacción de la Tesis de grado.
- En el caso del derecho de autor, no se obtuvo debido a que aún no se ha registrado el software.

Actualmente se trabaja en los ajustes necesarios en Machine Learning para mejorar la tasa de reconocimiento del algoritmo implementado, hacer pruebas con una mayor cantidad de datos nuevos y en integrar el software al proceso de recepción de las señales CSI en el dispositivo Rx, para que funcione en tiempo real.

En cuanto a las actividades, estas se realizarán nuevamente con diferentes sujetos de prueba en un ambiente interior diferente al del experimento, con las mismas alturas y distancias entre dispositivos NUC con el fin de demostrar que el reconocimiento de actividades puede ser llevado a cabo en diferentes escenarios al interior.

Los resultados enviados a la pantalla del monitor también serán trabajados para que antes de ser enviados a la vista del usuario, se almacenen en la base de datos, es decir, la actividad realizada, junto con la fecha y la hora.

Es necesario el desarrollo de mejores técnicas de reconocimiento de actividades, posiblemente incluyendo la identificación y clasificación de imágenes, así como un mejor ajuste en los parámetros de Machine Learning, para optimizar la clasificación.

5.2 Trabajo Futuro

A futuro, la implementación del software contempla los siguientes alcances:

1. La mejora de la seguridad en casas habitación ante riesgos delincuenciales.
2. La asistencia de la salud a personas con capacidades disminuidas como ancianos, minusválidos, enfermos, etc.

5.2 Trabajo Futuro

3. La integración del software con dispositivos móviles para que la recepción de alertas tenga un mayor alcance a varios usuarios.
4. El registro del software desarrollado y la obtención del derecho de autor.

Anexos A

Resultados preliminares del Laboratorio

En este apartado, es el investigador el que asume el rol de sujeto de pruebas para una primer ronda de actividades. En este punto de la investigación el software, únicamente lograba extraer los datos, aún sin una correcta limpieza de los mismos, y aún no se había definido la manera como se ejecutarían las actividades. A continuación se muestran los Heatmaps de la Amplitud de la señal y un ejemplo de dos subcarriers de cada antena receptora, de cada una de las actividades realizadas, con las correcciones de preprocesamiento ya implementadas en el código, y por tanto un menor ruido en la señal.

- GO TO BED. Figura [A.1](#).
- FALL. Figura [A.2](#).
- PICK UP. Figura [A.3](#).
- RUN. Figura [A.4](#).
- SIT DOWN. Figura [A.5](#).
- STAND UP. Figura [A.6](#).
- WALK. Figura [A.7](#).

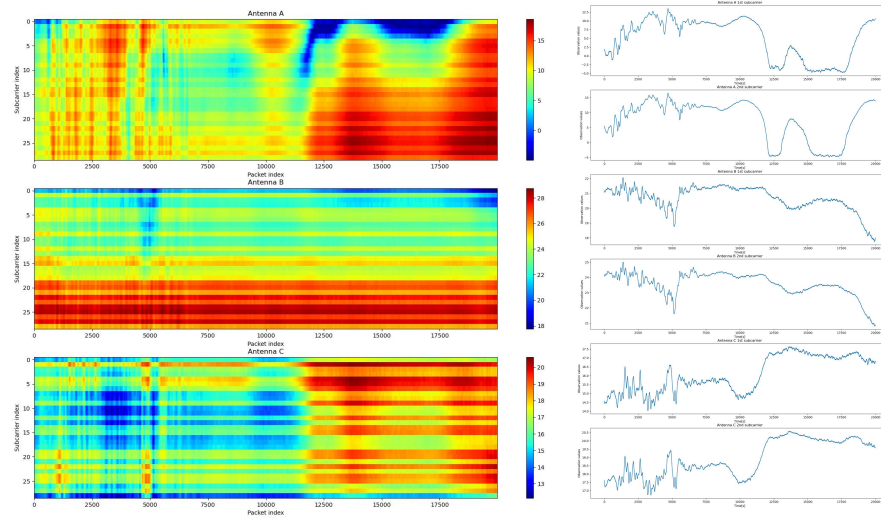


Figura A.1: Izquierda: Heatmap de Actividad GO TO BED. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.

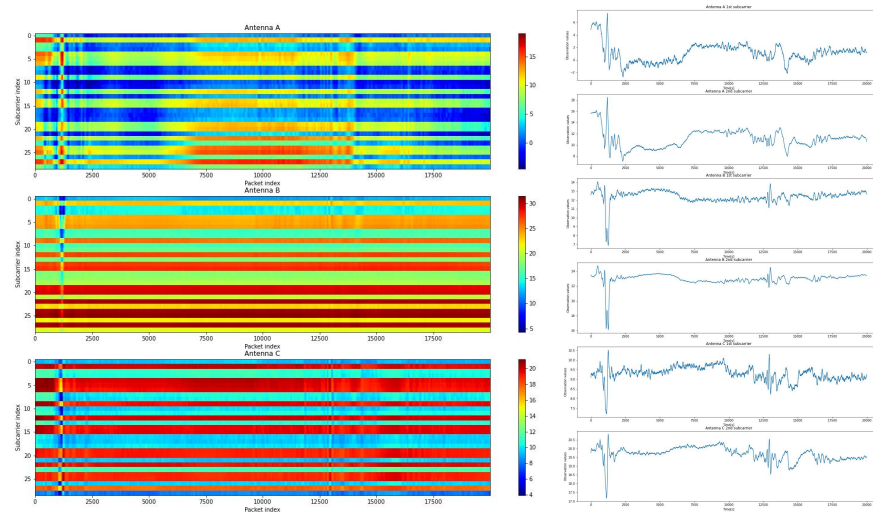


Figura A.2: Izquierda: Heatmap de Actividad FALL. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.

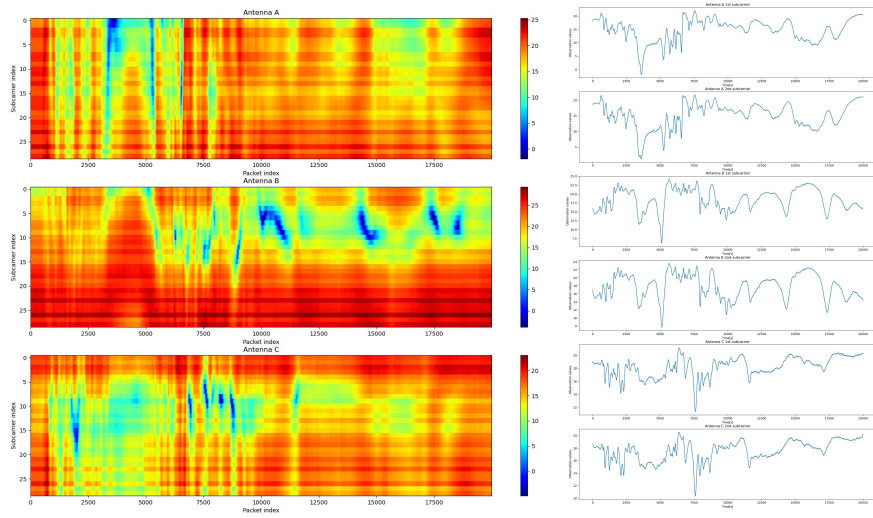


Figura A.3: Izquierda: Heatmap de Actividad PICK UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.

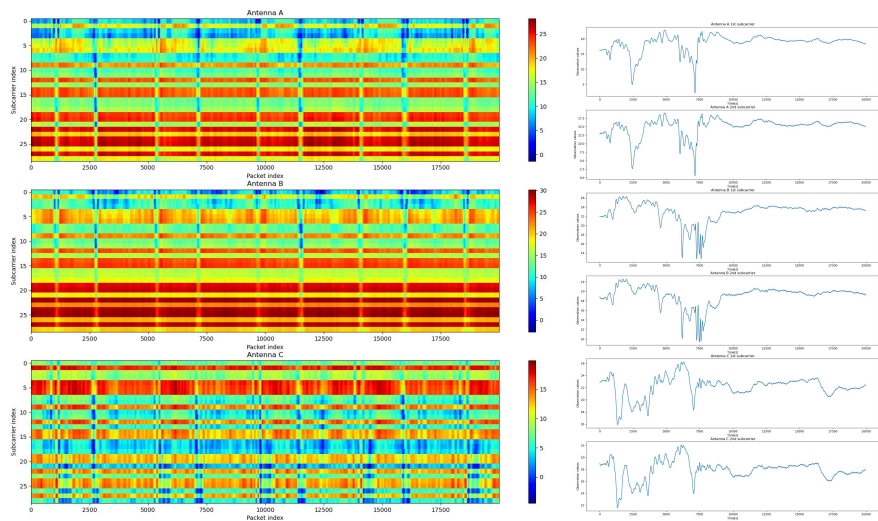


Figura A.4: Izquierda: Heatmap de Actividad RUN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.

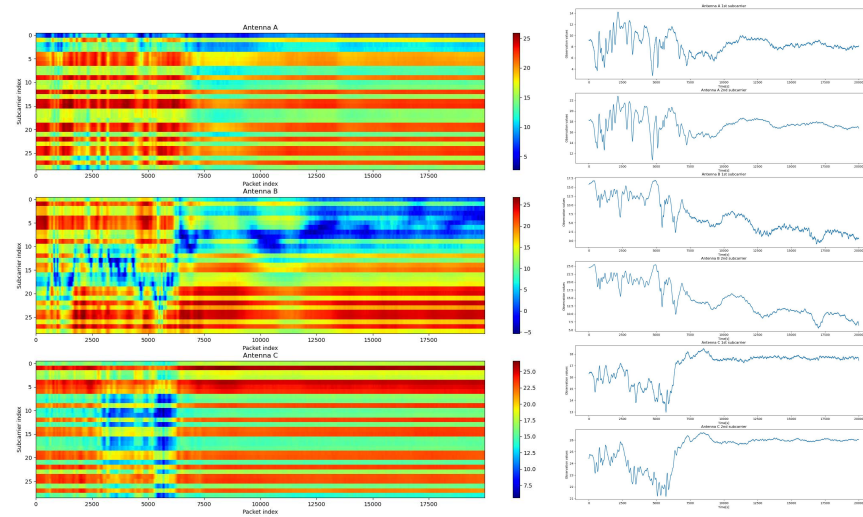


Figura A.5: Izquierda: Heatmap de Actividad SIT DOWN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.

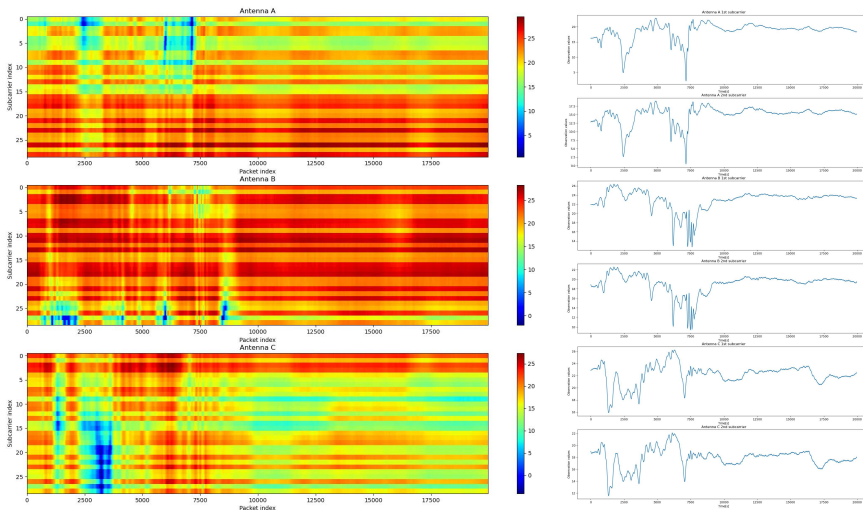


Figura A.6: Izquierda: Heatmap de Actividad STAND UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.

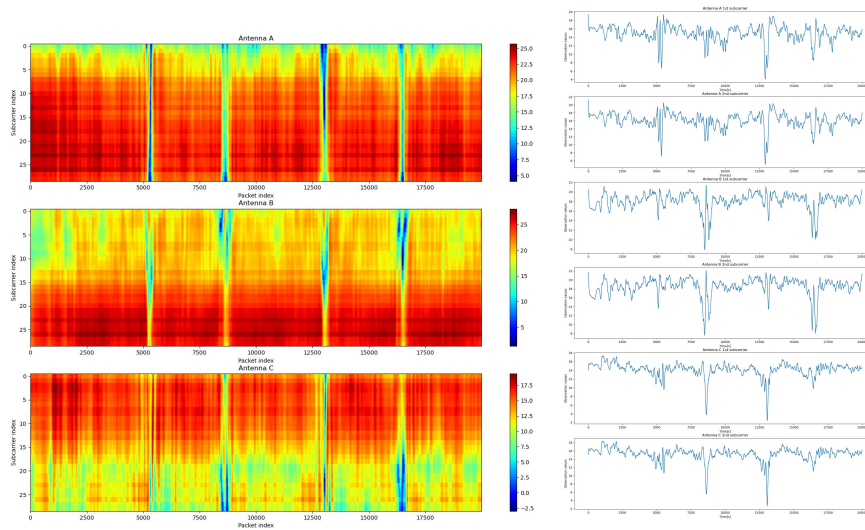


Figura A.7: Izquierda: Heatmap de Actividad WALK Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.

Anexos B

Resultados en Domicilio

Particular

B.1 Evidencia de las actividades realizadas por los Sujetos de Prueba

En esta sección se presenta la evidencia fotográfica de cada una de las actividades realizadas en el domicilio particular por cada uno de los sujetos de prueba. Como se observa en las imágenes, cada uno ejecutó las mismas actividades en el espacio de pruebas designado para ello, el cual se trata de la sala del domicilio, donde se ha dibujado en el suelo, al centro de la LOS, un cuadrado de 1m por cada uno de sus lados, alrededor del cual se realizan las actividades de RUN y WALK, y al centro las demás actividades.

- GO TO BED. Figura [B.1](#)
- FALL. Figura [B.2](#)
- PICK UP. Figura [B.3](#)
- RUN. Figura [B.4](#)
- SIT DOWN. Figura [B.5](#)

B.1 Evidencia de las actividades realizadas por los Sujetos de Prueba



Figura B.1: Actividad GO TO BED. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.




Figura B.2: Actividad FALL. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.

- STAND UP. Figura B.6
- WALK. Figura B.7

Como resultado de las actividades realizadas en el interior del domicilio particular, para recolección de datos nuevos nunca antes vistos por el Modelo, por cada uno de los sujetos de prueba se recolectó la siguiente evidencia gráfica que representa mediante un primer gráfico, la Amplitud de la señal a través de las

B.1 Evidencia de las actividades realizadas por los Sujetos de Prueba



Figura B.3: Actividad PICK UP. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.



Figura B.4: Actividad RUN. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.

tres antenas receptoras con la totalidad de los subcarriers contenidos en cada una de ellas; y por otro lado, un segundo gráfico que representa la señal individual de cada una de las señales subportadoras, tomando únicamente 6 muestras. La evidencia aquí mostrada toma únicamente un ejemplo de cada actividad de cada Sujeto de Prueba:



Figura B.5: Actividad SIT DOWN. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.



Figura B.6: Actividad STAND UP. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.

B.2 Sujeto 1

- GO TO BED. Figura [B.8](#).
- FALL. Figura [B.9](#).
- PICK UP. Figura [B.10](#).
- RUN. Figura [B.11](#).




Figura B.7: Actividad WALK. Izquierda: Sujeto de Pruebas 1; Centro: Sujeto de Pruebas 2; Derecha: Sujeto de Pruebas 3.

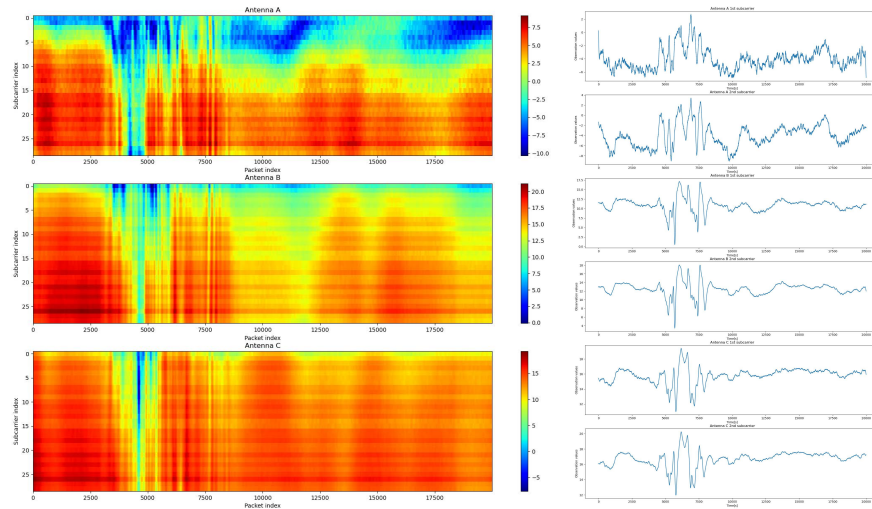


Figura B.8: Izquierda: Heatmap de Actividad GO TO BED. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.

- SIT DOWN. Figura B.12.
- STAND UP. Figura B.13.
- WALK. Figura B.14.

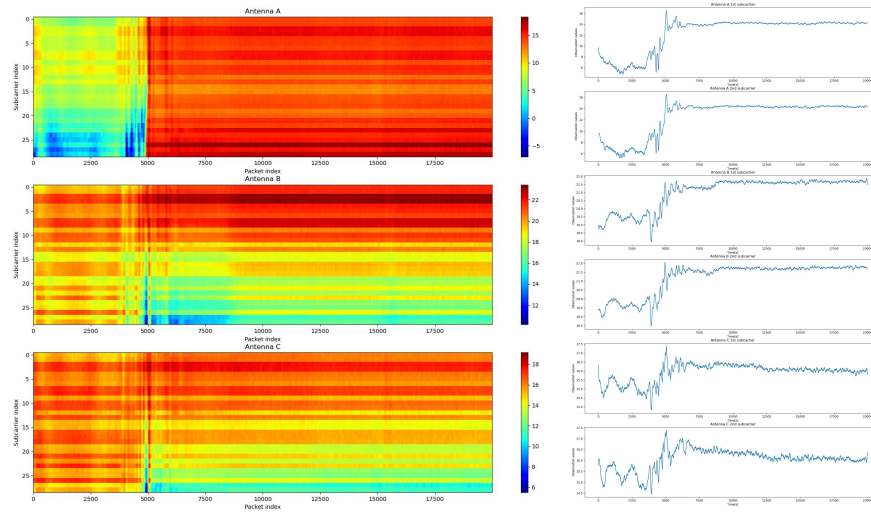


Figura B.9: Izquierda: Heatmap de Actividad FALL. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.

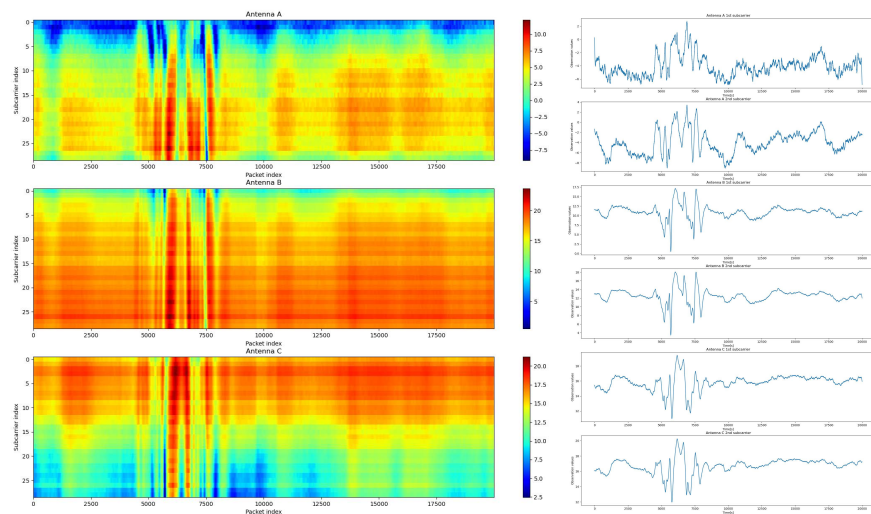


Figura B.10: Izquierda: Heatmap de Actividad PICK UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.

B.3 Sujeto 2

- GO TO BED. Figura B.15.

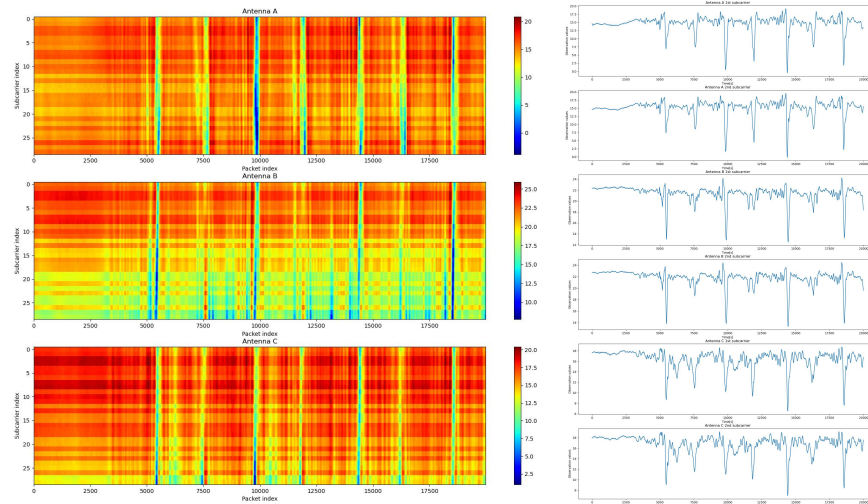


Figura B.11: Izquierda: Heatmap de Actividad RUN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.

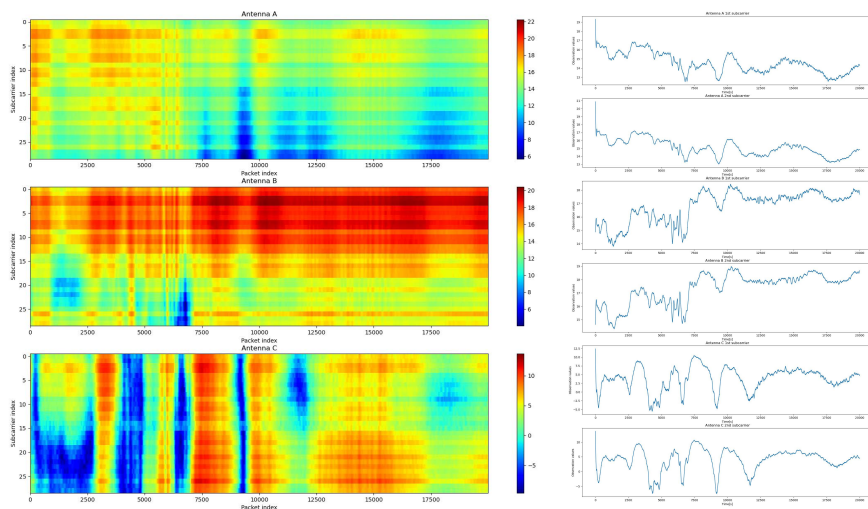


Figura B.12: Izquierda: Heatmap de Actividad SIT DOWN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.

- FALL. Figura B.16.
- PICK UP. Figura B.17.

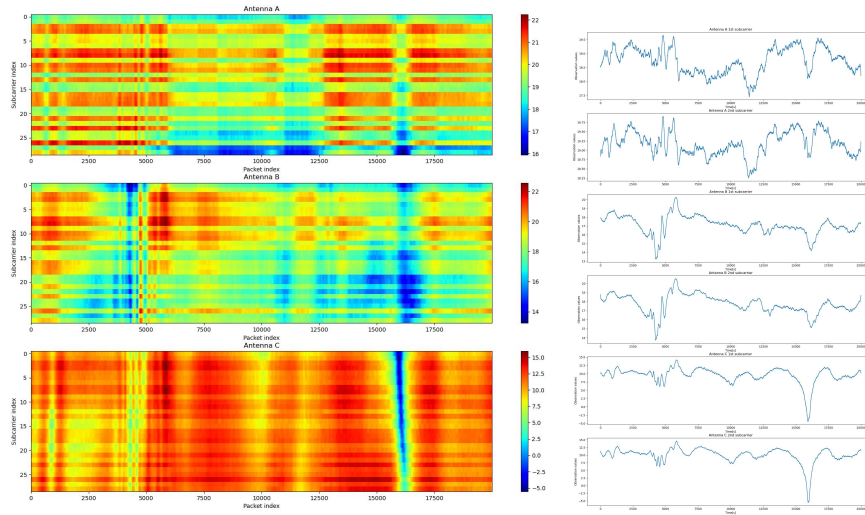


Figura B.13: Izquierda: Heatmap de Actividad STAN UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.

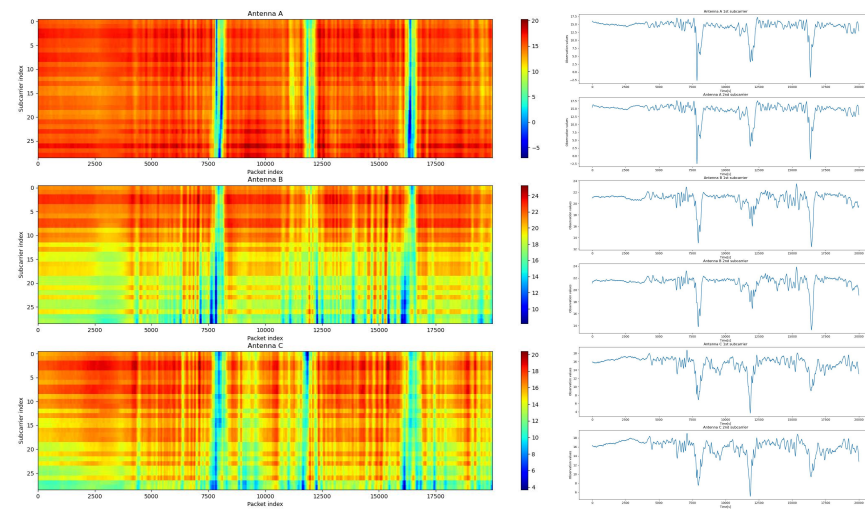


Figura B.14: Izquierda: Heatmap de Actividad WALK Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 1.

- RUN. Figura B.18.
- SIT DOWN. Figura B.19.

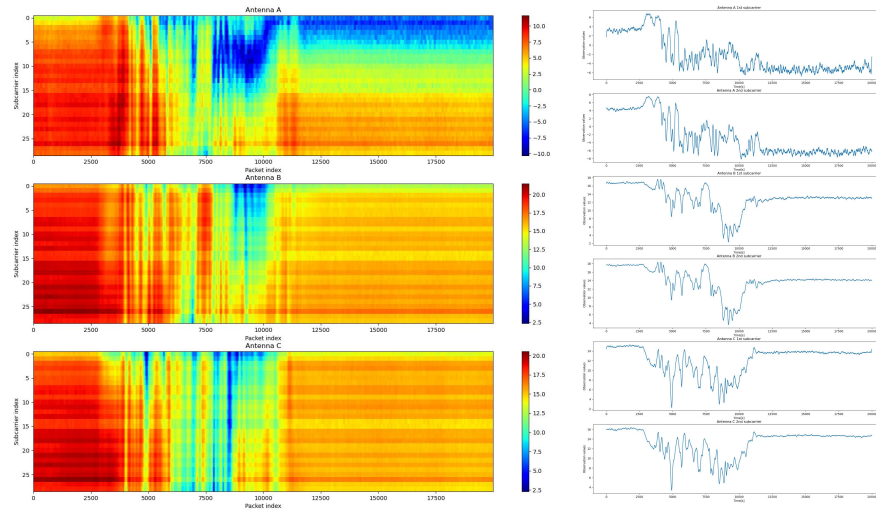


Figura B.15: Izquierda: Heatmap de Actividad GO TO BED. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.

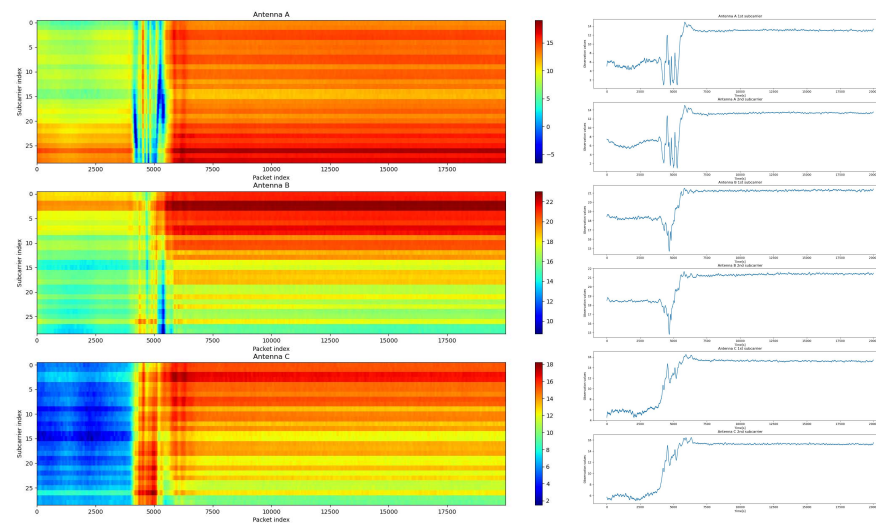


Figura B.16: Izquierda: Heatmap de Actividad FALL. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.

- STAND UP. Figura B.20.
- WALK. Figura B.21.

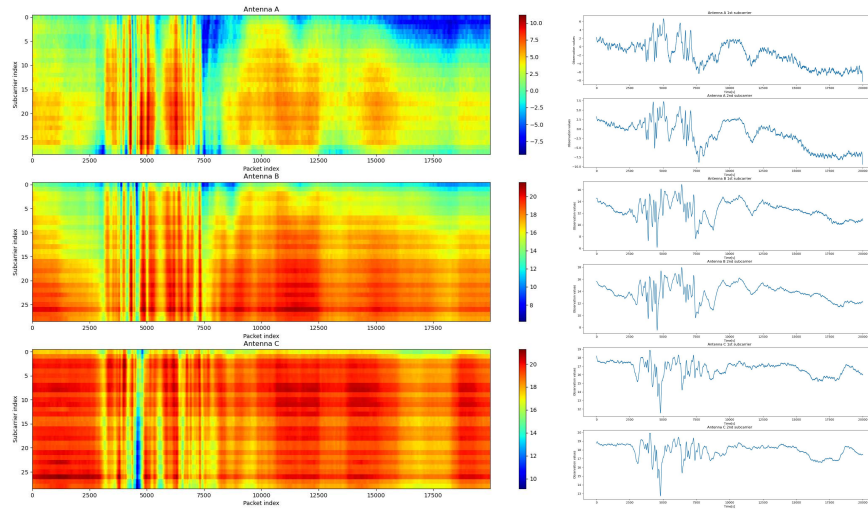


Figura B.17: Izquierda: Heatmap de Actividad PICK UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.

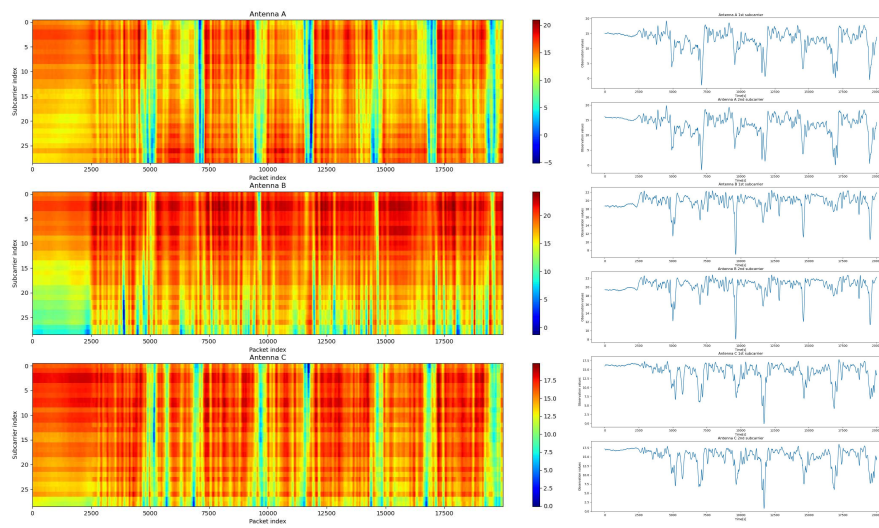


Figura B.18: Izquierda: Heatmap de Actividad RUN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.

B.4 Sujeto 3

- GO TO BED. Figura B.22.

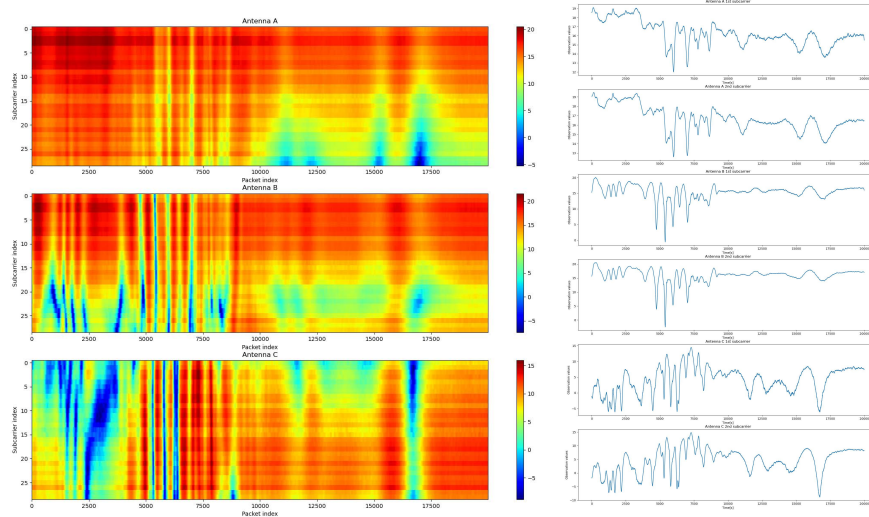


Figura B.19: Izquierda: Heatmap de Actividad SIT DOWN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.

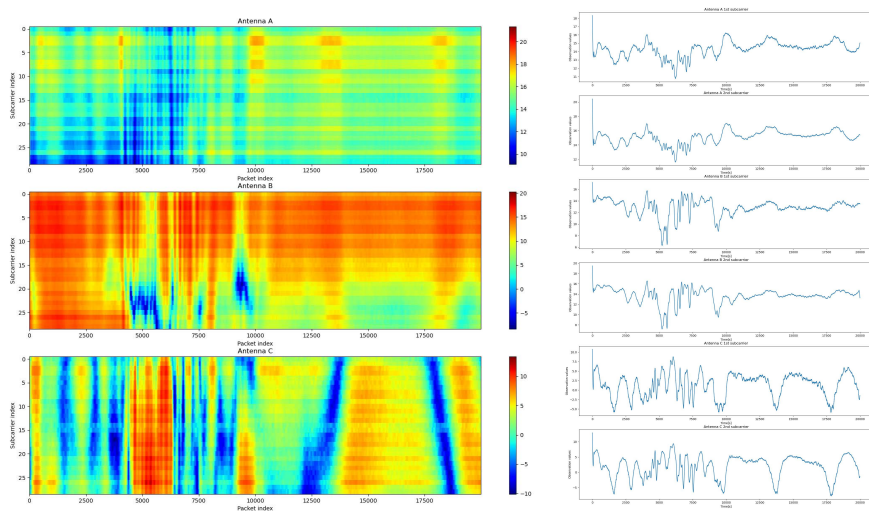


Figura B.20: Izquierda: Heatmap de Actividad STAND UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.

- FALL. Figura B.23.
- PICK UP. Figura B.24.

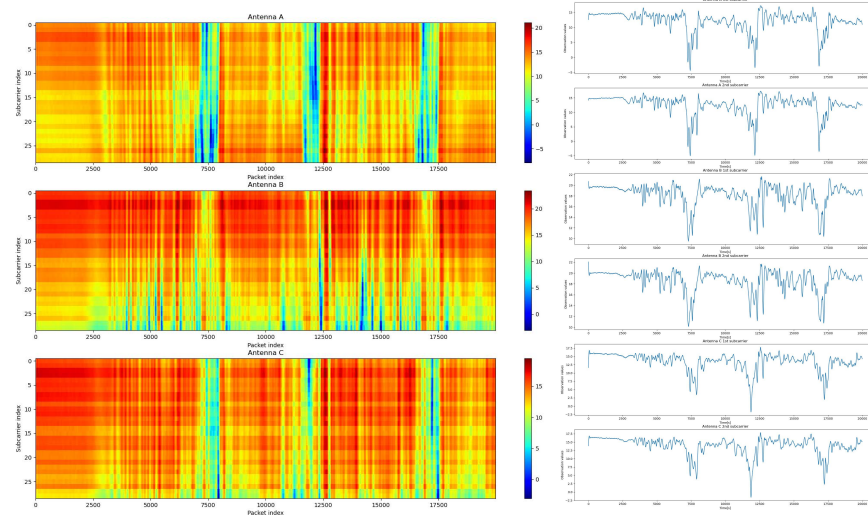


Figura B.21: Izquierda: Heatmap de Actividad WALK. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 2.

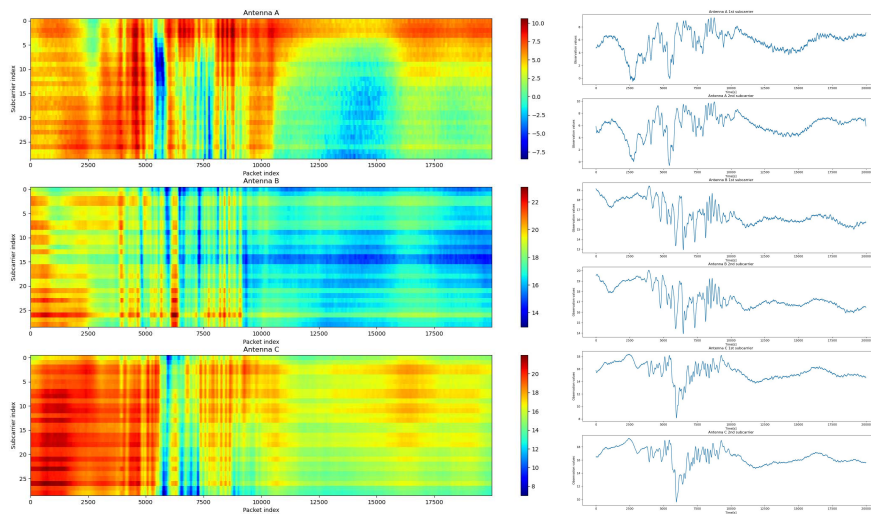


Figura B.22: Izquierda: Heatmap de Actividad GO TO BED. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.

- RUN. Figura B.25.
- SIT DOWN. Figura B.26.

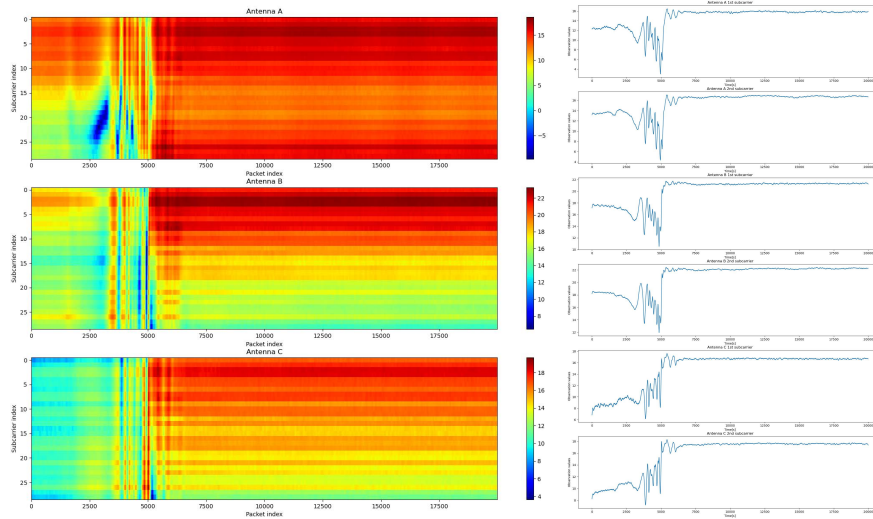


Figura B.23: Izquierda: Heatmap de Actividad FALL. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.

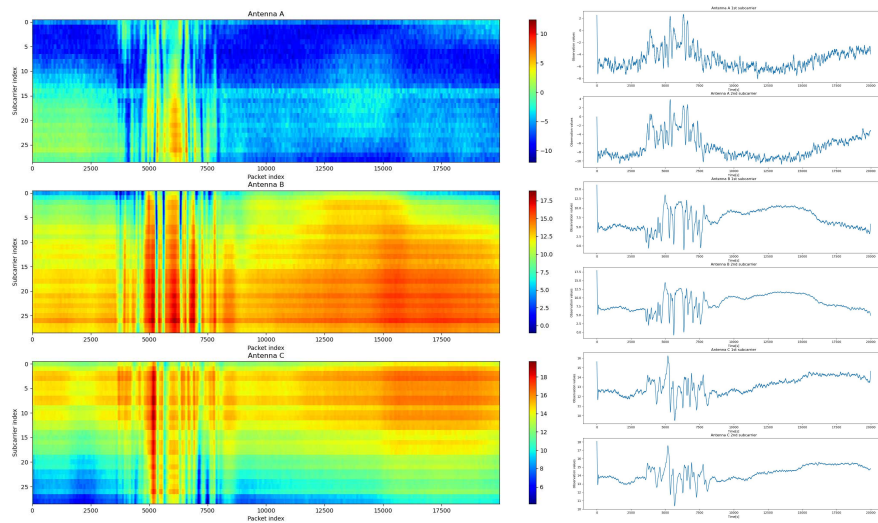


Figura B.24: Izquierda: Heatmap de Actividad PICK UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.

- STAND UP. Figura B.27.
- WALK. Figura B.28.

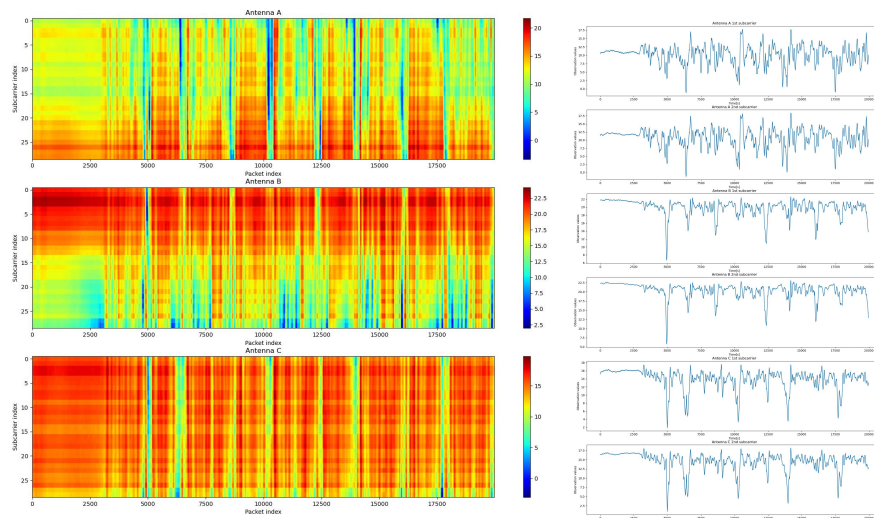


Figura B.25: Izquierda: Heatmap de Actividad RUN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.

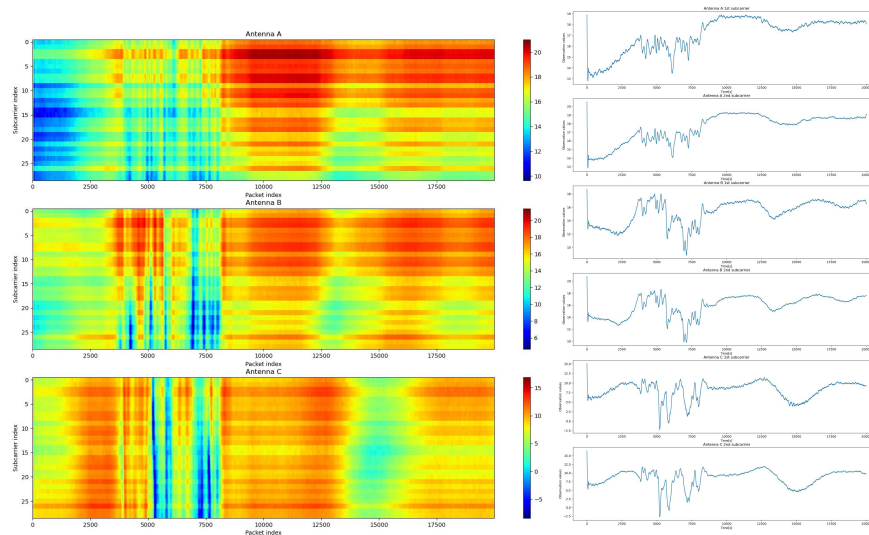


Figura B.26: Izquierda: Heatmap de Actividad SIT DOWN. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.

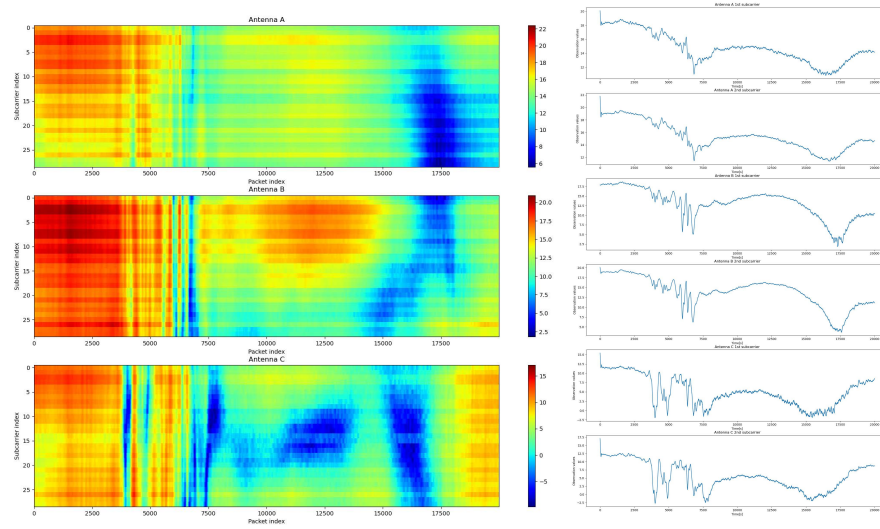


Figura B.27: Izquierda: Heatmap de Actividad STAN UP. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.

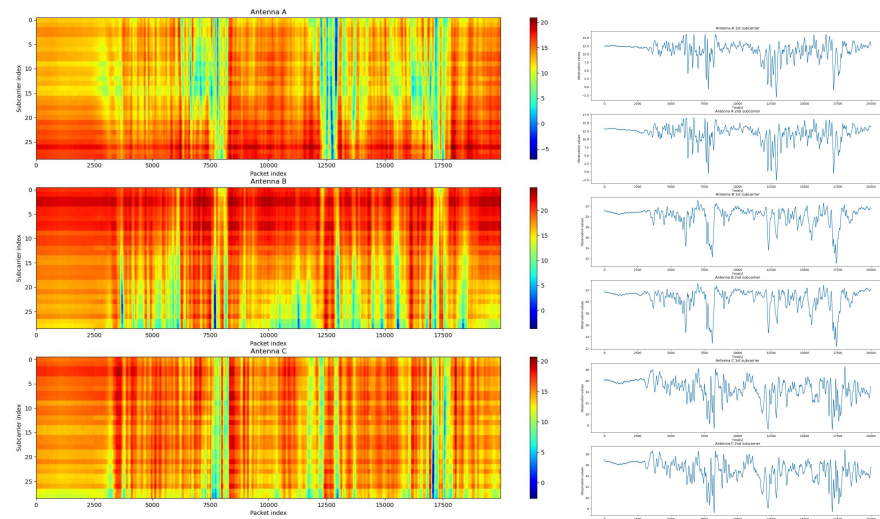


Figura B.28: Izquierda: Heatmap de Actividad WALK. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx. Sujeto 3.

Anexos C

Iteraciones del Prototipado

En este anexo, se colocan las iteraciones que componen la metodología del prototipado, mediante las cuales, se refinan tanto los requerimientos de software, como el prototipo mismo a través de los cambios en el diseño de la base de datos y del código. También se incluye la evaluación del prototipo por parte del cliente.

C.1 Iteración 1: 13 de Octubre de 2020

Objetivo: Entendimiento de la información CSI generada por cada actividad y lograr su representación gráfica para una mejor comprensión, implementar algoritmos de preprocesamiento, ejecución de pruebas en el domicilio particular, analizar los datos visualmente e incluir resultados en el Capítulo 4 de la Tesis.

Requerimientos de la Iteración

- Realizar pruebas controladas.
- Reproducir gráficos de los scripts de Narui y Halperin.
- Generación de Gráficos de PCA relacionados a CSI.
- Generación de Gráficos de la Amplitud.
- Aplicación de Imputación de datos a las pruebas controladas.
- Aplicación de Normalización a las pruebas controladas.

- Definir las funciones para la conversión de .dat a .csv en Python.
- Definir las entidades y campos de la Base de Datos.
- Analizar comportamiento de los scripts de Hirozaku Narui y Daniel Halperin, y su adaptación.
- Analizar los datos de las pruebas controladas y aplicarles técnicas de Pre-procesamiento.
- Eliminación de ruido de la señal.
- Incluir pruebas controladas con gráficos incluidos en tesis.
- Incluir pruebas no controladas con gráficos incluidos en tesis.

Diseño rápido

Como primeros diseños para el prototipo, se construye un primer diseño de la base de datos el cuál se muestra en la Figura C.1, y una primera versión de la Arquitectura de 3 capas del Modelo, como se observa en la Figura C.2. En esta primer versión, los datos son transformados de un archivo binario .dat a un archivo delimitado por comas .csv por medio de funciones en Matlab, y desde ahí se llevan a cabo los demás pasos de la capa de Procesamiento.

Construcción del prototipo

Los siguientes fueron los entregables presentados al cliente:

- crearModelo_version_01.sql: Corresponde al script para generar la base de datos en MySQL Server.
- wifialr_Modelo_version_01.mwb. Archivo de diagrama Entidad-Relación de la base de datos, hecho en Workbench (Figura C.1).
- Arquitectura de software de 3 capas - versión 01 (Figura C.2).
- DataBaseConnection.py. Clase creada en Python para la conexión con la base de datos.
- preprocesamiento.py. Script para la limpieza de los datos. Se implementan queries para insertar los resultados de técnicas de limpieza de datos, en la base de datos.
- Datos almacenados.png. Evidencia de datos insertados en la base de datos (Figura C.3).

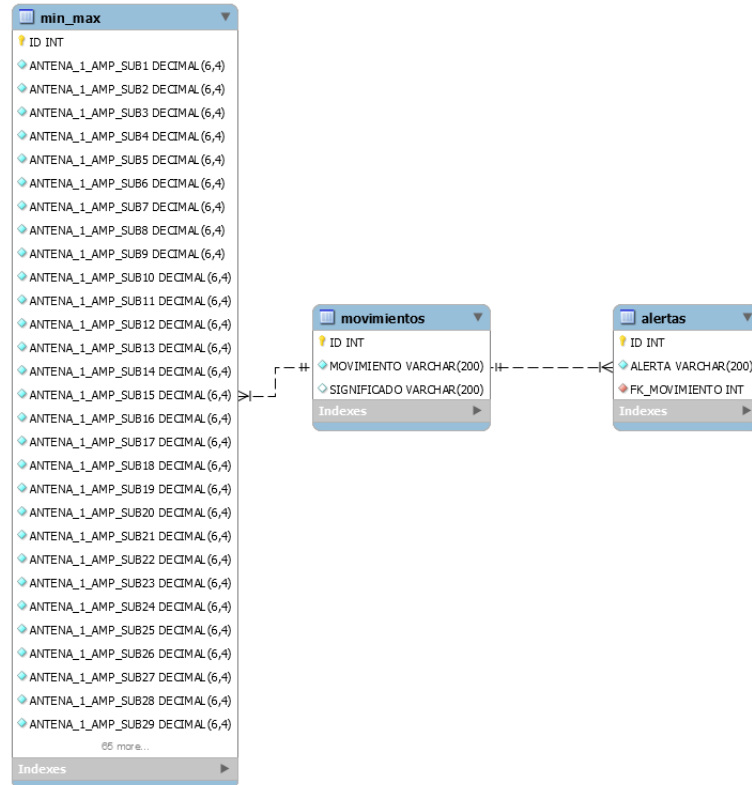


Figura C.1: Versión preliminar del Modelo Entidad-Relación de base de datos.

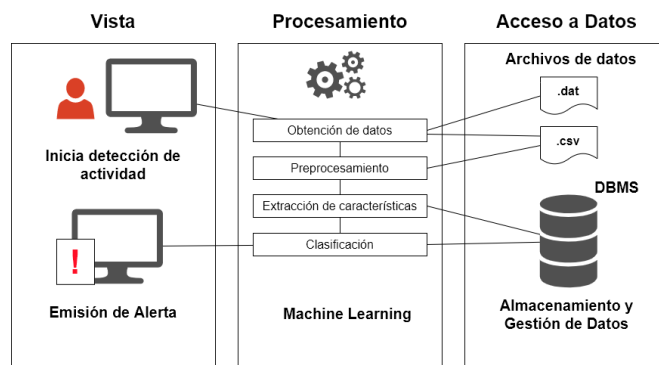


Figura C.2: Versión preliminar de Arquitectura de software de 3 capas.

Evaluación del prototipo por el cliente

Estas fueron las modificaciones sugeridas por el cliente al término de la iteración:
No aplica.

	ID	ANTENA_1_AMP_SUB1	ANTENA_1_AMP_SUB2	ANTENA_1_AMP_SUB3	ANTENA_1_AMP_SUB4	ANTENA_1_AMP_SUB5
▶	15	-5.917933333333333	4.280400000000000	-4.909299999999999	-5.810533333333333	0.825260000000000
	16	10.375333333333336	20.419999999999998	11.785333333333332	11.541666666666666	20.889666666666667
	17	-5.917933333333333	4.280400000000000	-4.909299999999999	-5.810533333333333	0.825260000000000
	18	10.375333333333336	20.419999999999998	11.785333333333332	11.541666666666666	20.889666666666667
	19	-5.572633333333333	-5.513600000000000	-5.489066666666666	-5.442300000000000	-5.282800000000000
	20	14.411333333333332	16.888333333333332	15.450999999999999	15.455666666666666	17.033999999999995

Figura C.3: Evidencia de los datos almacenados.

¿Hubo alguna parte del trabajo que no se completara durante la iteración?
 Sí, hubo cuatro tareas.

Si así fuera, ¿cuál?
 Las siguientes tareas no pudieron ser completadas:

- Análisis del comportamiento de los scripts de Hirokazu Narui y Halperin, y su adaptación.
- Incluir pruebas controladas con gráficos incluidos en tesis.
- Incluir pruebas no controladas con gráficos incluidos en tesis.

Refinamiento del prototipo

Estos son los cambios implementados para la mejora del prototipo:
 No aplica.

C.2 Iteración 2: 02-11-2020

Objetivo: Lograr al menos la ejecución de 10 o 5-fold cross-validation de al menos 2 modelos seleccionados.

Requerimientos de la Iteración

- Extracción de Características de los datos de las pruebas controladas.
- Desarrollo de Algoritmos de Clasificación.
- Proceso de almacenamiento de variables.
- Estudiar metodología para la generación de la Matriz X y el vector de clases Y.

- Conexión de Python a la base de datos en MySQL.
- Desarrollo de los modelos seleccionados.
- Selección de modelos y parámetros.
- Incluir pruebas no controladas con gráficos incluidos en tesis.
- Validación de modelos.

Diseño rápido

Se mantiene el mismo diseño del prototipo tanto para base de datos como para la Arquitectura de 3 capas.

Construcción del prototipo

Los siguientes fueron los entregables presentados al cliente:

- generarMatrizX.py. Script que toma 6 columnas de cada matriz de PCA, de cada actividad, y construye una nueva matriz, que será dividida en training y testing.
- CrossFoldValidation.py. Script que utiliza la matriz X y el vector de clases Y, implementa un algoritmo de Support Vector Machine, junto con 10-Fold-Cross Validation.
- Pruebas con SVM y 10 FCV.png. Cross validation scores, donde se muestra cómo se obtiene una tasa de reconocimiento mayor de 96% por cada fold (Figura C.4).

Evaluación del prototipo por el cliente

Estas fueron las modificaciones sugeridas por el cliente al término de la iteración: No aplica.

¿Hubo alguna parte del trabajo que no se completara durante la iteración? Sí, hubo cuatro tareas.

Si así fuera, ¿cuál?

- Desarrollo de los modelos seleccionados.
- Selección de modelos y parámetros.
- Incluir pruebas no controladas con gráficos incluidos en tesis.
- Validación de modelos.



Figura C.4: Pruebas con SVM y 10-fold cross validation.

Refinamiento del prototipo

Estos son los cambios implementados para la mejora del prototipo:
No aplica.

C.3 Iteración 3: 01-01-2021

Objetivo: Aplicación de 10 fold-crossvalidation en todos los modelos seleccionados.

Requerimientos de la Iteración

- Selección del Modelo de Data Mining.
- Validación de modelos.
- Realizar pruebas controladas en el hogar.
- Incluir pruebas no controladas con gráficos incluidos en tesis.
- Pruebas de los modelos seleccionados.
- Selección de modelos y parámetros.

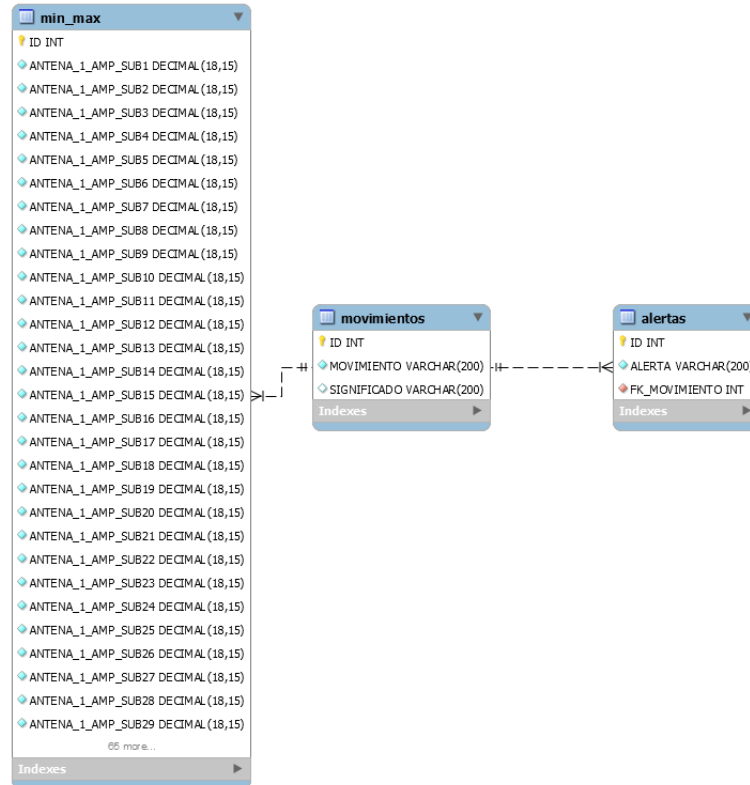


Figura C.5: Segunda versión del Modelo Entidad-Relación de base de datos.

Diseño rápido

Se construye un segundo diseño de la base de datos el cuál se muestra en la Figura C.5 donde se cambia el total de caracteres numéricos enteros y decimales para valores mínimos y máximos, y una segunda versión de la Arquitectura de 3 capas del Modelo, como se observa en la Figura C.6. En esta segunda versión, el proceso de extracción de la información de matrices se considera que debe hacerse en Python, y desde ahí llevar a cabo los demás pasos de la capa de Procesamiento. Además en la base de datos de momento no se almacenará información de las características extraídas, únicamente se mandarían a llamar los mensajes de las actividades detectadas.

Construcción del prototipo

Los siguientes fueron los entregables presentados al cliente:

- crearModelo_version_02.sql: Actualización del script para generar la base de datos en MySQL Server.

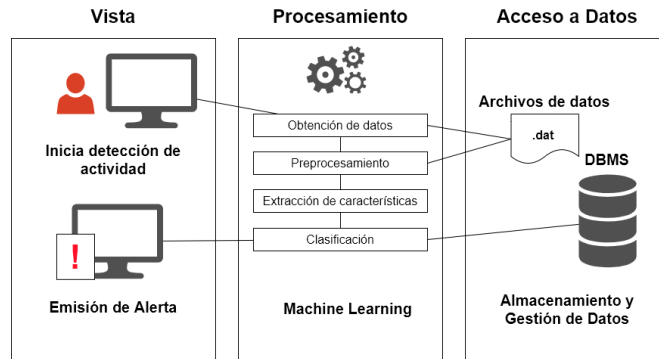


Figura C.6: Segunda versión de Arquitectura de software de 3 capas.

- wifialr_Modelo_version_02.mwb. Actualización del Modelo Entidad-Relación de la base de datos, hecho en Workbench (Figura C.5).
- Arquitectura de software de 3 capas - versión 02 (Figura C.6).
- Knn.m. Modelo de clasificación Knn con 5 vecinos cercanos, que divide los datos de training en rangos de: 60%-40%, 70%-30%, 80%-20% y 90%-10%.
- SVM.m. Modelo de clasificación de una SVM que emplea 10 KFold, con parámetros ajustables.

Evaluación del prototipo por el cliente

Estas fueron las modificaciones sugeridas por el cliente al término de la iteración:

- No utilizar 10 fold-crossvalidation, sustituir por porcentajes de training 80% y test 20%.
- Implementar de manera rápida los modelos de clasificación para observar cuáles presentan mejores resultados.

¿Hubo alguna parte del trabajo que no se completara durante la iteración?
Sí, hubo tres tareas.

Si así fuera, ¿cuál?

- Pruebas de los modelos seleccionados.
- Selección de modelos y parámetros.
- Validación de modelos.

Refinamiento del prototipo

Estos son los cambios implementados para la mejora del prototipo:

- Se implementan cambios a `EnsambleClasificadores.py` para probar la tasa de reconocimiento de los siguientes modelos de clasificación: Nearest Neighbors, Gaussian Naive Bayes, Linear Discriminant Analysis, Quadratic Discriminant Analysis, Neural Network y Support Vector Machine.

C.4 Iteración 4: 17-03-2021

Objetivo: Configuración del software en ambiente de Ubuntu, y creación del Modelo de Clasificación seleccionado.

Requerimientos de la Iteración

- Selección de Sujetos de Prueba.
- Definición de pruebas con Sujetos de Prueba.
- Realizar pruebas con Sujetos de Prueba, Se llevarán a cabo 20 rondas por cada actividad, por cada Sujeto de Prueba.
- Desarrollo y pruebas de modelos de clasificación: KNN, SVM, Neural Network.
- Definir las funciones para la conversión de `.dat` a `.csv` en Python.
- Compilar archivo en C, en el ambiente de pruebas local con Python.

Diseño rápido

Se mantiene el mismo diseño del prototipo tanto para base de datos como para la Arquitectura de 3 capas.

Construcción del prototipo

Los siguientes fueron los entregables presentados al cliente:

- `EnsambleClasificadores.py` Script para conocer la tasa de reconocimiento de cada uno de los modelos de clasificación propuestos: KNN, Gaussian Naive Bayes, Linear Discriminant Analysis, Neural Network, Support Vector Machine.
- `Classification.py`. Script para realizar la clasificación de datos nuevos, nunca antes vistos por el modelo: Se toman en cuenta los modelos que han dado mayor tasa de reconocimiento: KNN, SVM y Neural Network.

Evaluación del prototipo por el cliente

Estas fueron las modificaciones sugeridas por el cliente al término de la iteración:

- Se debe sustituir la Extracción de PCA por Extracción de características en el dominio del tiempo.
- Se debe quitar la Normalización como parte del Preprocesamiento.

¿Hubo alguna parte del trabajo que no se completara durante la iteración?
Sí, dos tareas.

Si así fuera, ¿cuál?

- Definir las funciones para la conversión de .dat a .csv en Python
- Compilar archivo en C, en el ambiente de pruebas local con Python.

Refinamiento del prototipo

Estos son los cambios implementados para la mejora del prototipo:

- Se sustituye PCA por Extracción de características en el dominio del tiempo en el script de AssembledModel.py.
- Se crea script custom_features.json que devuelve el valor de las características en el dominio del tiempo: mean, median, root mean square y variance.
- Se comenta la función de Normalización en el script de AssembledModel.py.

C.5 Iteración 5: 01-05-2021

Objetivo: Haber concluido el desarrollo de los scripts de conversión de los archivos .dat en archivos .csv, así como concluir satisfactoriamente el reconocimiento de las actividades nunca antes vistas.

Requerimientos de la Iteración

- Funciones en Python para conversión de archivos .dat a .csv.
- Generación de alertas a partir de resultados obtenidos.
- Compilar archivo en C, en el ambiente de pruebas local con Python.

- Toma de 20 muestras por cada actividad por cada Sujeto de Pruebas en el hogar.
- Toma de nuevas medidas de posición de los equipos NUC y redefinición de actividades a realizar para las nuevas pruebas.
- Validación de modelos.
- Desarrollo en Python de 3-4 modelos.
- Conversión, procesamiento y creación de Matriz X y vector Y del total de muestras nuevas.

Diseño rápido

Se mantiene el mismo diseño del prototipo tanto para base de datos como para la Arquitectura de 3 capas.

Construcción del prototipo

Los siguientes fueron los entregables presentados al cliente:

- Activity_datfile_to_csvfile.py.
- Cread_bf_file.py.
- get_scaled_csi.py.
- read_bfee.c.
- read_bfee.py.

Evaluación del prototipo por el cliente

Estas fueron las modificaciones sugeridas por el cliente al término de la iteración:

- Se debe cambiar la función de reducción de ruido actual, ya que no se suaviza la señal.
- Se deben utilizar 5 modelos de clasificación para la predicción.

¿Hubo alguna parte del trabajo que no se completara durante la iteración?
Sí, tres tareas.

Si así fuera, ¿cuál?

- Validación de modelos.
- Desarrollo en Python de 3-4 modelos.

- Conversión, procesamiento y creación de Matriz X y vector Y del total de muestras nuevas.

Refinamiento del prototipo

Estos son los cambios implementados para la mejora del prototipo:

- Se implementa Filtro Savitzky-Golay en el script de AssembledModel.py, con lo cuál se logra la reducción del ruido de la señal.
- Se implementan los siguientes modelos de clasificación: Support Vector Machine, Nearest Neighbors, Gaussian Naive Bayes, Linear Discriminant Analysis y Neural Network.

C.6 Iteración 6: 12-06-2021

Objetivo: Terminar de Validar el Modelo con el mejor Algoritmo de Clasificación de Machine Learning.

Requerimientos de la Iteración

- Creación de mapa de distribución de pruebas en el hogar.
- Realizar puebas controladas en el hogar.
- Validación de modelos.
- Desarrollo en Python de 3-4 modelos.
- Conversión, procesamiento y creación de Matriz X y vector Y del total de muestras nuevas.
- Emisión de alertas.

Diseño rápido

Se mantiene el mismo diseño del prototipo tanto para base de datos como para la Arquitectura de 3 capas.

Construcción del prototipo

Los siguientes fueron los entregables presentados al cliente:

- AssembledModel.py Script del proceso completo implementando el modelo construido.

Refinamiento del prototipo

Estos son los cambios implementados para la mejora del prototipo:

- Se realizaron pruebas con datos nuevos y se determinó junto con el cliente, usar únicamente el Modelo de Support Vector Machine por dar la mejor tasa de reconocimiento, que es de 95.24%.

Anexos D

Evidencia de WIFIALR en Rx

El software WIFIALR se encuentra instalado en un ambiente virtual de Conda, en el sistema de archivos del dispositivo Rx, como se observa en la Figura D.1.

En el ambiente de Ubuntu del dispositivo Rx, la versión de Python es la 3.8.5,

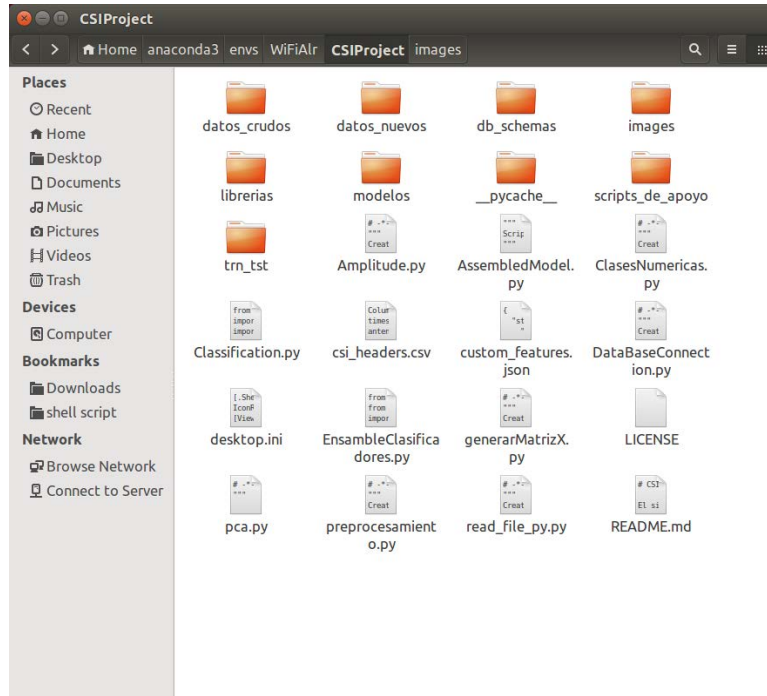
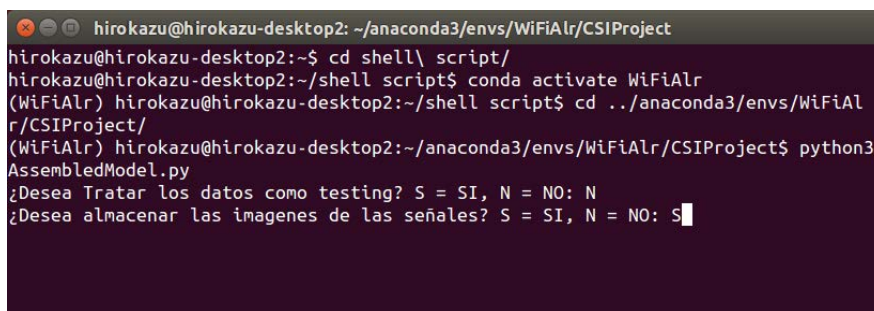


Figura D.1: Scripts para la ejecución de WIFIALR.

la de MySQL es la 14.14 Distrib 5.5.62 para debian-linux-gnu (x86_64), mientras que las librerías de Python que se encuentran instaladas son las siguientes:

- pandas 1.2.1.
- numpy 1.19.2.
- pymysql 1.0.2.
- sklearn 0.23.2.
- matplotlib 3.3.2.
- scipy 1.6.0.
- tkinter. 8.6.10.
- statistics.
- tsfel 0.1.4. [Research \(2021\)](#).

Una vez que el archivo .dat es generado, se ingresan los comandos en la terminal de Ubuntu que se indican en la Figura D.2 para la ejecución de WIFIALR.



```
hirokazu@hirokazu-desktop2: ~/anaconda3/envs/WiFiAlr/CSIPrject
hirokazu@hirokazu-desktop2:~$ cd shell\ script/
hirokazu@hirokazu-desktop2:~/shell script$ conda activate WiFiAlr
(WiFiAlr) hirokazu@hirokazu-desktop2:~/shell script$ cd ../anaconda3/envs/WiFiAlr/CSIPrject/
(WiFiAlr) hirokazu@hirokazu-desktop2:~/anaconda3/envs/WiFiAlr/CSIPrject$ python3 AssembledModel.py
¿Desea Tratar los datos como testing? S = SI, N = NO: N
¿Desea almacenar las imagenes de las señales? S = SI, N = NO: S
```

Figura D.2: Comandos de ejecución de WIFIALR.

El software procede a abrir una interfaz gráfica de ventanas donde el usuario puede elegir el archivo .dat que contiene la información de la actividad a identificar, como se muestra en la Figura D.3.

Después de que los datos son procesados y clasificados mediante el algoritmo de Machine Learning de WIFIALR, se envían los resultados a través de la pantalla de la computadora con la actividad detectada, los cuáles se muestran en las Figuras D.4, D.5.

Además, si se seleccionó previamente la opción de guardar las imágenes generadas de la señal, al terminal de desplegar las alertas, el usuario puede acceder a las imagenes de Amplitud y Subcarriers en la misma ruta donde se ejecuta el software, en la carpeta de /images. Estas se muestran en las Figura D.6.

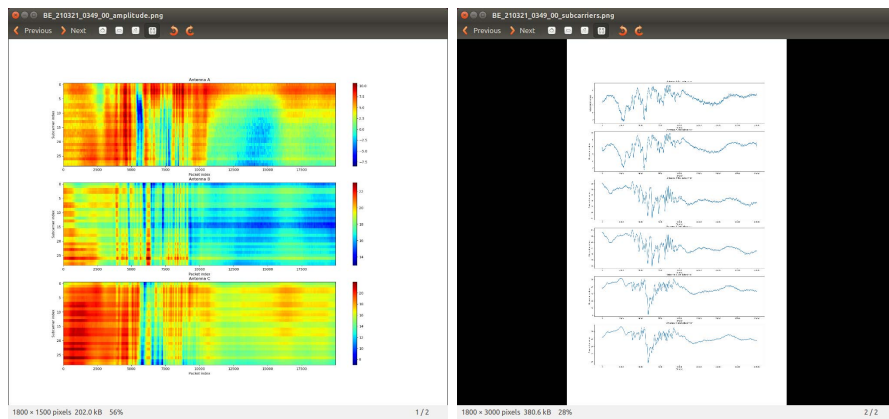


Figura D.6: Izquierda: Heatmap de Amplitud de la Actividad realizada. Derecha: Primeros dos subcarriers de cada una de las antenas de Rx.

Anexos E

Productos Académicos de Investigación

Como resultado de la presente investigación, se publicaron y obtuvieron los artículos y méritos académicos mencionados a continuación:

E. López, F. González and B. Flores, Software para Emisión de Alertas Basadas en Detección de Movimiento por Señales WiFi, SOCIEDAD MEXICANA DE CIENCIAS DE LA COMPUTACIÓN, pp. 14-21, 2020.

E. Lopez-Hernandez, F. F. Gonzalez-Navarro, B. L. Flores-Rios and J. Caro-Gutierrez, "WIFIALR WiFi Alerts Software for Human Movements using Machine Learning Algorithms," 2021 Mexican International Conference on Computer Science (ENC), 2021, pp. 1-7, doi: 10.1109/ENC53357.2021.9534823.

Ganador del 1er Lugar en el Concurso de Innovación en Ciencia y Tecnología 2021: "Desarrollos en Ciencia y Tecnología apoyados por Inteligencia Artificial" del Simposio Virtual RGMX Japón 2021, organizado por la Red Global MX, 26 de noviembre de 2021.

Referencias

- ADIB, F., KABELAC, Z., KATABI, D. & MILLER, R.C. (2014). 3d tracking via body radio reflections. In *11th USENIX Symposium on Networked Systems Design and Implementation (NSDI 14)*, 317–329, USENIX Association, Seattle, WA. 19, 22
- AGUIRRE, J.P. (2017). Robo a casa habitación. In *Pluralidad y Consenso*, 192–199. 10, 11
- AKERS, R.L. *et al.* (2013). *La generalidad de la teoría del autocontrol, una primera extensión de la teoría general del delito a los países de habla hispana*. DYKINSON. 9
- ALEMDAR, H. & ERSOY, C. (2010). Wireless sensor networks for healthcare: A survey. *Computer Networks*, 54, 2688–2710. vii, 14, 26
- ANN, O.C. & THENG, L.B. (2014). Human activity recognition: A review. In *2014 IEEE International Conference on Control System, Computing and Engineering (ICCSCE 2014)*, 389–393. 4
- BISHOP, C.M. (2007). *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer, 1st edn. 38
- CAMBRIDGE (2019a). healthcare. <https://dictionary.cambridge.org/es-LA/dictionary/english/healthcare>, (acceso: 15.02.2020). 12
- CAMBRIDGE (2019b). security. <https://dictionary.cambridge.org/es-LA/dictionary/english/security>, (acceso: 15.02.2020). 8
- CHEN, H.M., KAZMAN, R. & HAZIYEV, S. (2016). Strategic prototyping for developing big data systems. *IEEE Software*, 33, 36–43. 55
- CHEN, Z., ZHANG, L., JIANG, C., CAO, Z. & CUI, W. (2019). Wifi csi based passive human activity recognition using attention based blstm. *IEEE Transactions on Mobile Computing*, 18, 2714–2724. 15, 17, 25

- CIOS, K.J., PEDRYCZ, W., SWINIARSKI, R.W. & KURGAN, L.A. (2007). *Data Mining: A Knowledge Discovery Approach*. Springer-Verlag, Berlin, Heidelberg. 38
- DAYAL, S., NARUI, H. & DELIGIANNIS, P. (2016). Human fall detection in indoor environments using channel state information of wi-fi signals. vii, 20
- DENIAU, V., GRANSART, C., ROMERO, G.L., SIMON, E.P. & FARAH, J. (2017). Ieee 802.11n communications in the presence of frequency-sweeping interference signals. *IEEE Transactions on Electromagnetic Compatibility*, 59, 1625–1633. 15
- DING, J., WANG, Y. & FU, X. (2020). Wihi: Wifi based human identity identification using deep learning. *IEEE Access*, 8, 129246–129262. 14
- DISPOSITIVOSWEARABLES (2019). ¿que es wearable? – los dispositivos vestibles. <http://www.dispositivoswearables.net/>, (acceso: 03.12.2019). 4, 5
- DPA (2019). El wifi cumple 20 años de brindar conexión inalámbrica. <https://www.milenio.com/tecnologia/wifi-cumple-20-anos-brindar-conexion-inalambrica-internet> (acceso: 10.12.2019). 1, 2
- DUDA, R.O., HART, P.E. & STORK, D.G. (2000). *Pattern Classification (2nd Edition)*. Wiley-Interscience, 2nd edn. 38
- FANG, S.H., LI, C.C., LU, W.C., XU, Z. & CHIEN, Y.R. (2019). Enhanced device-free human detection: Efficient learning from phase and amplitude of channel state information. *IEEE Transactions on Vehicular Technology*, 68, 3048–3051. 22
- FORBES, G. (2021). Csikit. <https://github.com/Gi-z/CSiKit>, (acceso: 18.04.2021). 34
- FRUTOS CALLEJA, M. (2017). Inteligencia artificial para reconocimiento de personas y actividades a través de redes wifi. https://cincodias.elpais.com/cincodias/2017/07/13/companias/1499944277_271691.html (acceso: 22.12.2019). 19
- GARCÍA, O. (2013). Modelo de prototipos. <https://www.proyectum.com/sistema/blog/modelo-de-prototipos/>, (acceso: 13.11.2021). 55
- GONG, W. & LIU, J. (2019). Roarray: Towards more robust indoor localization using sparse recovery with commodity wifi. *IEEE Transactions on Mobile Computing*, 18, 1380–1392. 24

- GU, Y., WANG, Y., LIU, Z., LIU, J. & LI, J. (2020). Sleepguardian: An rf-based healthcare system guarding your sleep from afar. *IEEE Network*, **34**, 164–171. 26
- HALPERIN, D. (2014). linux-80211n-csitool. <https://github.com/dhalperi/linux-80211n-csitool>, (acceso: 15.03.2020). 34
- HAMMOSHI, M. & ALANI, R. (2010). A proposed model to implement load and throughput of wlan implemented as wi-fi system. In *INC2010: 6th International Conference on Networked Computing*, 1–7. 15
- HAN, J., KAMBER, M. & PEI, J. (2012). *Data mining concepts and techniques, third edition*. Morgan Kaufmann Publishers. 38
- HERNÁNDEZ, C. (2019). Ola de robos en viviendas y vehículos. <https://pulsoslp.com.mx/2019/03/02/ola-de-robos-en-viviendas-y-vehiculos/>, (acceso: 08.11.2020). 3
- HSIEH, C.H., CHEN, J.Y. & NIEN, B.H. (2019). Deep learning-based indoor localization using received signal strength and channel state information. *IEEE Access*, **7**, 33256–33267. 16, 23
- INEGI (2015). Encuesta nacional de victimización y percepción sobre seguridad pública (envipe) 2015. <https://www.inegi.org.mx/programas/envipe/2015/>, (acceso: 19.09.2019). 10
- INEGI (2019). Encuesta nacional de victimización y percepción sobre seguridad pública (envipe) 2019. <https://www.inegi.org.mx/programas/envipe/2019/>, (acceso: 19.09.2019). vii, 10, 12
- INFOBAE (2019). Caídas son un riesgo mortal para adultos mayores en México. <https://www.infobae.com/america/mexico/2019/02/11/caidas-son-un-riesgo-mortal-para-adultos-mayores-en-mexico/>, (acceso: 03.12.2019). 3
- INTEL (2019). Learn about multiple-input multiple-output. <https://www.intel.com/content/www/us/en/support/articles/000005714/network-and-io/wireless-networking.html>, (acceso: 03.12.2019). 17
- INTEL (2021). Intel® nuc kit d54250wykh. <https://ark.intel.com/products/81164/Intel-NUC-Kit-D54250WYKH>, (acceso: 01.03.2021). 32

- LI, S., LI, X., LV, Q. & ZHANG, D. (2018a). Wifit: A bodyweight exercise monitoring system with commodity wi-fi. *Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers*. 28
- LI, X., ZHANG, D., XIONG, J., ZHANG, Y., LI, S., WANG, Y. & MEI, H. (2018b). Training-free human vitality monitoring using commodity wi-fi devices. *Proc. ACM Interact. Mob. Wearable Ubiquitous Technol.*, **2**. 27
- LI, X., SHI, J. & ZHAO, J. (2019). DeFe: indoor localization based on channel state information feature using deep learning. *Journal of Physics: Conference Series*, **1303**, 012067. 24
- LIU, J., CHEN, Y., WANG, Y., CHEN, X., CHENG, J. & YANG, J. (2018). Monitoring vital signs and postures during sleep using wifi signals. *IEEE Internet of Things Journal*, **5**, 2071–2084. 28
- MARTÍNEZ GALVÁN, F.J. (2019). Visibilidad de los delitos. <https://www.excelsior.com.mx/opinion/opinion-del-experto-nacional/visibilidad-de-los-delitos/1299435>, (acceso: 08.11.2020). 2
- MUNDO, B. (2015). Ocho maneras de darle usos insospechados a tu celular. https://www.bbc.com/mundo/noticias/2015/01/150102_tecnologia_uso_distinto_de_sensores_celular_ig, (acceso: 01.05.2020). 4, 5
- MÓVIL, X. (2014). 13 razones por las que una smartband puede mejorar tu estilo de vida. <https://www.xatakamovil.com/espacio-sony/13-razones-por-las-que-una-smartband-puede-mejorar-tu-estilo-de-vida> (acceso: 20.12.2019). 5
- NARUI, H. (2020). Wifi_activity_recognition using lstm. https://github.com/ermongroup/Wifi_Activity_Recognition, (acceso: 07.11.2020). 34
- NYANDOWE, I. & ZAKARIYAH, S. (2014). Guide to evolutionary prototyping. 56
- PATINO, A.A. (2019). Teoría del autocontrol. <https://leyderecho.org/teoria-del-autocontrol/>, (acceso: 03.10.2020). 9
- POONAM (2018). Briefing on prototype model in software testing. <https://www.testorigen.com/briefing-on-prototype-model-in-software-testing/>, (acceso: 13.11.2021). viii, 56, 57

- QIAN, K., WU, C., YANG, Z., LIU, Y. & ZHOU, Z. (2014). Pads: Passive detection of moving targets with dynamic speed using phy layer information. In *2014 20th IEEE International Conference on Parallel and Distributed Systems (ICPADS)*, 1–8. 16
- RAMÍREZ, I. (2019). Giroscopio en el móvil: estos son todos los usos menos conocidos. <https://www.xatakandroid.com/aplicaciones-android/giroscopio-en-el-movil-estos-son-todos-los-usos-menos-conocidos>, (acceso: 03.10.2020). 4, 5
- RESEARCH, A.F.P. (2021). tsfel. <https://github.com/fraunhoferportugal/tsfel>, (acceso: 18.04.2021). 35, 100
- SCARPATI, J. (2021). radio frequency (rf, rf). <https://www.techtarget.com/searchnetworking/definition/radio-frequency>, (acceso: 01.12.2021). 16
- SEGOB (2014). Diario oficial de la federación. http://dof.gob.mx/nota_detalle.php?codigo=5343081&fecha=30/04/2014, (acceso: 20.05.2020). 10
- TAN, Q., HAN, C., SUN, L., GUO, J. & ZHU, H. (2018). A csi frequency domain fingerprint-based method for passive indoor human detection. In *2018 17th IEEE International Conference On Trust, Security And Privacy In Computing And Communications/ 12th IEEE International Conference On Big Data Science And Engineering (TrustCom/BigDataSE)*, 1832–1837. 15, 25
- TECNOLOGÍA, A. (2019). Los grandes hitos del wifi en sus primeros 20 años. https://www.abc.es/tecnologia/informatica/soluciones/abci-grandes-hitos-wifi-primeros-20-anos-201909301222_noticia.html, (acceso: 15.02.2020). 1, 2, 19
- TINOCO, S. (2019). Las caídas son uno de los principales riesgos de mortalidad en las personas mayores: Sosa tinoco. In *Boletín Instituto Nacional de Geriátría*, 8–9. 13
- VISWANATHAN, M. (2014). Characterizing a mimo channel – channel state information (csi) and condition number. <https://www.gaussianwaves.com/2014/08/characterizing-a-mimo-channel/>, (acceso: 01.10.2019). vii, 17
- WANG, C., CHEN, S., YANG, Y., HU, F., LIU, F. & WU, J. (2018). Literature review on wireless sensing-wi-fi signal-based recognition of human activities. *Tsinghua Science and Technology*, **23**, 203–222. vii, 18, 22, 23
- WANG, W., LIU, A.X., SHAHZAD, M., LING, K. & LU, S. (2015). Understanding and modeling of wifi signal based human activity recognition. In *Proceedings of the 21st Annual International Conference on Mobile Computing and*

- Networking*, MobiCom '15, 65–76, Association for Computing Machinery, New York, NY, USA. [vii](#), [19](#), [20](#), [21](#), [23](#)
- WILSON, S. & DOBRE, O. (2016). Chapter 9 - multicarrier transmission in a frequency-selective channel. In *Academic Press Library in Mobile and Wireless Communications: Transmission Techniques for Digital Communications*, 333–367. [15](#)
- ZHANG, Z., ISHIDA, S., TAGASHIRA, S. & FUKUDA, A. (2019). Danger-pose detection system using commodity wi-fi for bathroom monitoring. *Sensors (Basel, Switzerland)*, **19**. [27](#)
- ZHOU, Z., WU, C., YANG, Z. & LIU, Y. (2015). Sensorless sensing with wifi. *Tsinghua Science and Technology*, **20**, 1–6. [vii](#), [15](#), [16](#), [18](#)