

## Desarrollo de un módulo para la prevención de la hipertensión usando el paradigma IoT y aprendizaje automático

Juan Antonio Alor-Hernandez<sup>1</sup>, Nancy Aracely Cruz Ramos<sup>1</sup>,  
Giner Alor-Hernández<sup>1</sup>, José Luis Sánchez-Cervantes<sup>2</sup>,  
Lisbeth Rodríguez-Mazahua<sup>1</sup>

<sup>1</sup>Instituto Tecnológico de Orizaba  
División de Investigación y Estudios de Posgrado,  
México

{msc.jalor, dci.ncruz}@ito-depi.edu.mx,  
{giner.ah, jose.sc, lisbeth.rm}@orizaba.tecnm.mx

**Resumen.** La hipertensión, también conocida como asesino silencioso es un síndrome clínico cuya principal característica es el aumento de la presión arterial, a su vez es una de las principales causas de enfermedades cardiovasculares y cerebrovasculares. En este trabajo se describe el desarrollo de un módulo para la prevención e identificación de hipertensión mediante técnicas de Aprendizaje Automático e Internet de las cosas. El módulo obtiene información mediante el uso de una pulsera inteligente que se encarga de monitorizar la presión arterial de cada individuo para determinar si una persona es hipertensa o normotensa. El principal beneficio del módulo, es que realiza una monitorización en tiempo real de la presión arterial permitiendo identificar, prevenir y controlar la presión arterial alta, mediante el uso de recomendaciones médicas apropiadas, con el propósito de lograr disminuir las muertes por esta enfermedad.

**Palabras clave:** Aprendizaje automático, hipertensión, internet de las cosas, inteligencia artificial, wearable.

## Development of a Module for the Prevention of Hypertension Using the IoT Paradigm and Machine Learning

**Abstract.** Hypertension, also known as the silent killer, is a clinical syndrome whose main characteristic is the increased blood pressure, which in turn is one of the main causes of cardiovascular and cerebrovascular diseases. This paper describes the development of a module for the prevention and identification of hypertension using Machine Learning and Internet of Things techniques. The module obtains information using a smart bracelet that is responsible for monitoring the blood pressure of each being to determine if a person is

hypertensive or normotensive. The main benefit of the module is that it performs real-time monitoring of blood pressure, allowing the identification, prevention, and control of high blood pressure, using appropriate medical recommendations, with the purpose of reducing deaths from this disease.

**Keywords:** Machine learning, hypertension, internet of things, artificial intelligence, wearable.

## 1. Introducción

La hipertensión es un síndrome clínico cuya principal característica es el aumento de la presión arterial sistémica y se considera como la enfermedad crónica más común, así como el factor de riesgo más importante de enfermedades cardiovasculares y cerebrovasculares.

La hipertensión es la principal causa prevenible de muerte prematura en todo el mundo. Según los datos de la Organización Mundial de la Salud (OMS) la hipertensión afecta más de 250 millones de personas adultas en todo el mundo [1]. Muchos factores conducen a la hipertensión, incluido el estrés occipital y la tensión laboral.

Uno de los principales problemas relacionados con los tratamientos para las condiciones de hipertensión arterial es la detección tardía de personas aparentemente sanas. Algunos estudios demuestran que, entre los individuos con hipertensión, más del 35% desconocían su condición [2]. Por lo anterior, se hace necesario el desarrollo de mecanismos que permitan reconocer la hipertensión lo antes posible, cuyo principal beneficio sea ayudar a las personas a monitorizar en tiempo real la presión arterial y así prevenir, identificar y controlar los niveles de hipertensión.

De esta manera el paciente llevará un tratamiento adecuado y así evitará que se presenten daños irreversibles en el cuerpo humano. Recientemente, la convergencia tecnológica en el cuidado de la salud se ha vuelto relevante porque es una alternativa prometedora para el tratamiento de pacientes con enfermedades crónicas.

Puntualmente, el Internet de las cosas (IoT) logra esquematizar un panorama de tecnologías, que en este trabajo se enfocan al autocuidado y promoción de los hábitos saludables.

La contribución de este trabajo es el desarrollo de un módulo que realiza el proceso de prevención e identificación de hipertensión mediante técnicas de Aprendizaje Automático e Internet de las Cosas (IoT), esto con el fin de lograr disminuir las muertes por esta enfermedad.

Este trabajo está estructurado de la siguiente manera: la sección 2 presenta los trabajos relacionados con la hipertensión y tecnologías basadas en IoT; la sección 3 describe la arquitectura utilizada para el desarrollo del módulo basado en el paradigma IoT; la sección 4 presenta las funcionalidades del módulo; finalmente, la sección 5 presenta las conclusiones y el trabajo futuro.

## 2. Trabajos relacionados

Sazonov *et al.* [3] desarrollaron un control remoto de sistema de cuidado de la salud conformado por un sensor de bioseñal y un microcontrolador. Se concluyó, que muchos de los problemas se evitan si se mantiene un control y compromiso con el cuidado.

Janjua *et al.* [4] propuso un sistema de monitorización de la PA el cual se colocó en el pecho y midió la rigidez arterial calculando el tiempo de tránsito del pulso. El análisis de Bland-Altman mostró que el algoritmo del dispositivo es compatible con el grado C de los estándares de la British Hypertensive Society para la estimación de la presión arterial sistólica. Ni *et al.* [5] desarrolló un cinturón con un sistema de monitorización continua para leer datos de ECG.

Con el 93.33% de precisión se pudo diferenciar a los pacientes que tenían hipertensión de los que eran sanos. Afeni *et al.* [6] desarrolló un sistema predictivo de hipertensión para aquellos pacientes en tratamiento, utilizando el clasificador Naive Bayes. El clasificador Naive Bayes mostró el mejor desempeño para el diagnóstico de hipertensión. Ruíz *et al.* [7] propuso un nuevo modelo basado en BPM, IoT, principios de teledetección y usabilidad.

Se obtuvo la información del paciente (evolución y tratamiento de su enfermedad). Como resultado, se presentó un modelo flexible que logró ayudar a los médicos a proporcionar un tratamiento preciso en cada momento. Irizarry *et al.* [8] realizó un estudio del uso de la aplicación *MyBP*, el cual consto de tres fases. Se concluyó que la eficacia y la viabilidad de *MyBP* como complemento de la medicina estándar dependen del compromiso del paciente.

Thangada *et al.* [9] realizó estudios que demostraron cómo las aplicaciones para teléfonos inteligentes tratan de mejorar el manejo de la hipertensión. Comparó los resultados de la PA entre pacientes que usaban un sistema de monitorización de PA en el hogar contra un grupo que llevaban el control desde una aplicación. Encontraron que el 72,3% de los pacientes hipertensos que usaban la aplicación alcanzaban una PA <140/90 mmHg>, mientras que el 39,9% del otro grupo alcanzaron una PA <140/90 (0,0001)>.

Singh *et al.* [10] propuso un enfoque de aprendizaje híbrido para la generación de reglas de clasificación para diagnosticar la hipertensión entre individuos diabéticos. Se realizó un entrenamiento con el modelo SVM y se extrajeron reglas de los aprendices basados en árboles C4.5, RF, XGBoost. El modelo obtuvo un 74,7% de precisión y un valor del área bajo la curva (AUC) de 0,810 para la clase positiva. Carvajal *et al.* [11] diseñaron un clasificador GT2 FL para medir los niveles del pulso, posteriormente desarrollaron un hardware del clasificador en el Jetson Nano Development Board.

Se concluyó que el clasificador GT2 FL propuesto logra una mejor clasificación en comparación con los clasificadores difusos de intervalo tipo 2 y tipo 1. En continuación con el trabajo anterior Guzmán *et al.* [12] desarrollaron un clasificador de niveles de presión arterial. Se obtuvieron 45 muestras de presión sistólica y 45 muestras de presión diastólica. Posteriormente se realizó el entrenamiento de la red neuronal, los resultados arrojaron que el sistema tipo 2 realiza una mejor clasificación (99,408%) que el sistema tipo 1 (98%).

Kitt *et al.* [13] analizaron la aplicación *Cardiogram* (reloj Apple®). Estos dispositivos portátiles se probaron en niños, mujeres embarazadas y en personas con fibrilación auricular, se concluyó que los dispositivos portátiles no son confiables en este tipo de población. Mankar *et al.* [14] analizaron diferentes técnicas de aprendizaje automático.

Se recopiló un conjunto de datos de 23,095, se realizó la evolución con seis técnicas de clasificación diferentes para predecir el resultado de la hipertensión. El modelo Random Tree Forest superó significativamente a todos los demás. Wu *et al.* [15] generó un algoritmo ML para predecir los resultados en pacientes jóvenes con hipertensión. Se obtuvieron los siguientes resultados 0,757 (IC del 95%, 0,660 a 0,854) para el modelo ML, para el modelo de regresión de Cox y el de puntuación de riesgo de Framingham recalibrado se obtuvo 0,723 (IC del 95%, 0,636 a 0,810) y 0,529 (IC del 95%, 0,403 a 0,655).

Kario *et al.* [16] realizó la implementación de dispositivos portátiles. Validaron dispositivos de muñeca tipo reloj para la medición de la PA, los dispositivos HEM6410T-ZM y HEM-6410T-ZL cumplían con los criterios de validación cuando se usaban en posición sentada con la muñeca al nivel del corazón. Welykholowa *et al.* [17] desarrolló un dispositivo no invasivo para la medición de la PA. Se analizaron 73 artículos, la mayoría de los estudios utilizaron ECG. Varios prototipos introdujeron modalidades basadas en fotoplestismografía para mejorar la evaluación de la hipertensión

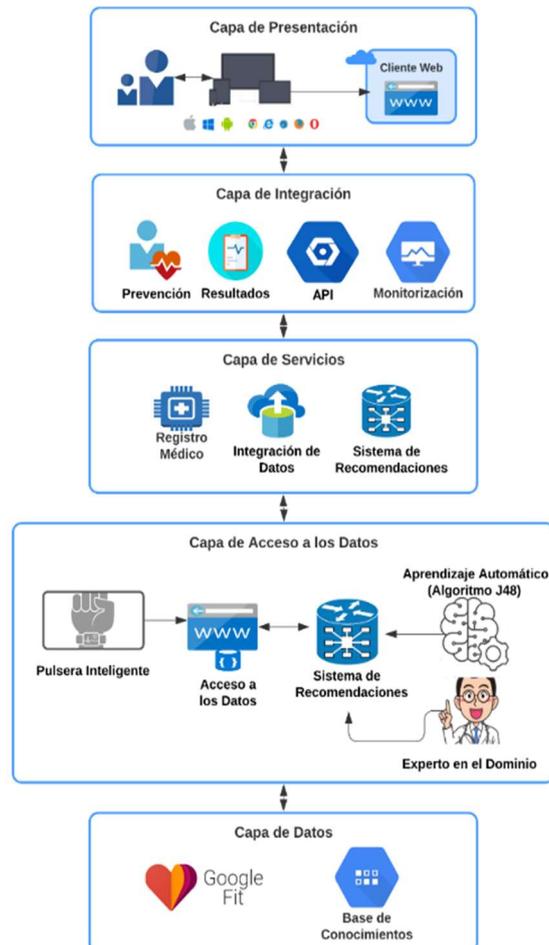
Una de estas modalidades es la recolección simultánea de ECG con PPG para estimar PAT. Se concluyó que las tecnologías actuales enfrentan limitaciones para incorporar con éxito PPG y ECG en un solo dispositivo portátil. Tsoi *et al.* [18] propuso la predicción de los valores de PA a partir de grabaciones de voz de la vocal a. Se entrenó una CNN con dos grupos para predecir los valores de PA.

Se obtuvo una precisión de 93,7% y el RMSE de 0,236. Se concluyó que se requieren más acciones antes del lanzamiento oficial de aplicaciones de IA para prácticas clínicas. Zhang *et al.* [19] realizó un estudio para evaluar el uso de una pulsera de autocontrol durante las 24 horas. Los resultados arrojaron que no existieron diferencias entre los usuarios y no usuarios de dispositivos en relación con las mediciones de la salud cardiovascular.

### 3. Arquitectura del módulo para la prevención de la hipertensión

En este trabajo se desarrolló una aplicación web que realiza el proceso de identificación de la hipertensión mediante dispositivos *wearables*, Aprendizaje Automático e IoT. La aplicación web aplica algoritmos de clasificación dentro del aprendizaje automático, los cuales permiten predecir una o más variables discretas, basándose en otros atributos de un conjunto de datos.

El esquema general de la aplicación comienza con la extracción de información relevante mediante la pulsera inteligente, así mismo almacena datos sensibles que son de suma importancia para el usuario, se implementa un mecanismo automático para el almacenamiento de dichos datos como son la frecuencia cardíaca, presión arterial, pulso del volumen sanguíneo y temperatura en la piel.



**Fig. 1.** Arquitectura de la aplicación web para la detección y prevención de la hipertensión.

Una vez extraída la información, mediante el uso de la *Api* de Google Fit™ se obtiene un conjunto de datos que debe validarse por expertos del dominio, de modo que se utilice posteriormente por un algoritmo aprendizaje automático para su clasificación. A continuación, se muestra se describe las principales funciones del módulo:

- **Monitorización:** Permite al usuario, mediante el uso de *wearables*, medir las siguientes variables fisiológicas: Frecuencia Cardíaca, Conteo de Pasos, Distancia Recorrida, Calorías Quemadas, Minutos Activos, Temperatura en la piel, Oxigenación en la Sangre y Presión Arterial. Estas variables se utilizan como parámetros para predecir si una persona es hipertensa o no, mediante el uso del algoritmo de aprendizaje automático J48.

- **Detección:** Mediante el uso de la *Api* de Google Fit™ y el uso de técnicas de aprendizaje automático, las variables que se obtienen del *wearable* y extraídas de la API, se usan para predecir y detectar si una persona es hipertensa o no, estos resultados se consultan en la aplicación Web como parte integral del módulo.
- **Prevención:** Se implementan recomendaciones médicas que ayudan al usuario a realizar acciones, procedimientos o tratamientos, que mejoren la salud del usuario que lo requiera.

La aplicación Web para la detección de hipertensión tiene una arquitectura basada en capas para una mejor escalabilidad, robustez y fácil mantenimiento. Esta arquitectura en capas y sus módulos se describen en la Figura 1.

La aplicación Web tiene como objetivo medir la actividad física diaria y otros factores para detectar la posible hipertensión por parte del paciente. A continuación, se explican los componentes y funcionalidades de la arquitectura.

**a) Aplicación Web:** La aplicación incorpora un módulo de monitorización para comprobar las constantes vitales y la actividad física del paciente y capturar sus síntomas diarios. Asimismo, la aplicación se apoya en un sistema de alertas y recomendaciones para el seguimiento de los pacientes. Las estadísticas sobre el estado de salud del paciente se presentan a través de las siguientes gráficas:

- **Patrones de actividad.** Recolecta los datos de las actividades diarias mediante los sensores del dispositivo.
- **Minutos activos.** Son los minutos contabilizados por Google Fit™ durante los cuales el paciente realiza cualquier tipo de actividad física (por ejemplo, caminar, spinning, entrenamiento de fuerza, entre otros). Estos minutos se registran de forma automática, manual o a través de aplicaciones de terceros conectadas con Google Fit™.
- **Calorías quemadas.** La aplicación calcula cuántas calorías queman los pacientes de forma constante en función de factores como el sexo, la altura y el peso. Este cálculo indica aproximadamente el total de calorías quemadas e incluye la tasa metabólica basal, no solo las calorías quemadas durante el ejercicio.
- **Recuento de pasos.** Conteo total de pasos cada vez que se realiza una actividad física.
- **Distancia recorrida.** Calcula la distancia total recorrida en los últimos días caminando o corriendo.
- **Frecuencia cardíaca.** Calcula la frecuencia cardíaca media del paciente en los últimos días.
- **Oxigenación en la sangre.** Calcula la hemoglobina en porcentaje en la sangre del paciente.
- **Temperatura.** Calcula la temperatura en la piel del paciente en los últimos días.

**b) Sistema de recomendaciones:** La aplicación tiene dos repositorios: La nube de Google Fit y una base de conocimientos. En Google Fit™, el sistema de la app

almacena los datos del paciente recogidos por los sensores del wearable, mientras que la base de conocimientos incluye un conjunto de reglas para detectar la hipertensión.

- c) **Sensores y dispositivos del internet de las cosas:** La aplicación registra wearables para monitorizar las variables biométricas del paciente. Dichos dispositivos se sincronizan con la plataforma de Google Fit™ para el almacenamiento de datos. Los wearables recogen los datos del paciente en tiempo real y estos datos se utilizan posteriormente para detectar la hipertensión.

La arquitectura de la aplicación se divide en cinco capas, que se explican a continuación.

**Capa de presentación.** Recibe las peticiones de los usuarios introducidas a través de un navegador (Chrome, Safari y Firefox) para los sistemas operativos más populares (es decir, Windows, MacOS X y Linux). Sin embargo, dada la modularidad y escalabilidad de la arquitectura, las capacidades de la capa de presentación pueden extenderse a otras plataformas y dispositivos, ya que la capa de integración más baja proporciona una API basada en servicios.

**Capa de integración.** Ofrece una API para acceder a diversas funcionalidades de las capas más bajas, por lo que ofrece un bajo acoplamiento entre el usuario y la funcionalidad del sistema. A grandes rasgos, esta capa permite a la aplicación introducir nuevos pacientes añadiendo una nueva plataforma o soporte de dispositivo a través de la capa de presentación.

Además, la capa de integración sirve tanto de aislamiento de enlaces como de mecanismo de seguridad para acceder a los procesos y funciones de la capa de servicios. Asimismo, esta capa incluye el acceso a los cuatro servicios principales para la gestión de hipertensión: 1) detección, 2) prevención, 3) pronósticos y 4) tratamiento.

**Capa de servicios.** Incluye tres servicios: 1) integración de datos, 2) sistema de recomendaciones y 3) registros médicos. El servicio de integración de información es un orquestador de la información procedente de diferentes fuentes de datos, y anonimiza los datos sensibles utilizados en las recomendaciones.

Por su parte, el sistema de recomendación utiliza diferentes algoritmos de recomendación para generar y proporcionar recomendaciones médicas específicas para el tratamiento de la hipertensión. Por último, el servicio de registros médicos controla los expedientes electrónicos de los pacientes, despliega dicha información a través de la capa de presentación y guarda y recupera los datos a través de la capa de acceso a datos.

**Capa de acceso a los datos.** Da acceso a toda la información de entrada/salida de la arquitectura y facilita el acceso a las distintas fuentes de datos desde la capa de datos. Para ello, la capa de acceso a los datos invoca los tres módulos de acceso: Historial Médico, Recomendaciones y *Wearables*.

El módulo de Historial Médico reenvía a la historia clínica electrónica del paciente y monitoriza las variables médicas y los parámetros físicos del mismo. Las recomendaciones se basan tanto en el usuario (paciente) como en los diagnósticos médicos históricos.

**Capa de datos.** Almacena todos los datos estructurados y no estructurados utilizados por las capas superiores. Al mismo tiempo, la capa de datos puede añadir nuevas fuentes

de datos al sistema. Todos los datos recibidos de un dispositivo con sensores ópticos de frecuencia cardíaca (por ejemplo, los *wearables* de Xiaomi™ o Amazfit GTR 3 Pro™) se almacenan en Google Fit™.

Posteriormente, estos datos se analizan. La base de conocimientos proporciona a la aplicación Web capacidades de razonamiento para detectar patrones y predecir posibles casos de hipertensión. Para ello, la base de conocimientos se apoya en una serie de variables médicas asociadas a un conjunto de reglas.

#### **4. Caso de estudio: monitorización de personas para la detección y prevención de hipertensión**

El caso de estudio consiste en el desarrollo de una aplicación web para la detección y prevención de hipertensión. Para la fase de pruebas, la aplicación se utilizó para supervisar el estado de salud de un paciente de 37 años durante dos meses, monitorizando sus variables biomédicas durante las actividades físicas diarias.

El caso de estudio implicó, por tanto, la prueba de concepto de las principales funcionalidades de la aplicación web. Además, se solicitó al paciente que registrara sus hábitos diarios, antecedentes personales y familiares, así como sus síntomas en la aplicación:

- a) Monitorización de las actividades físicas diarias del paciente en tiempo real mediante un dispositivo inteligente.
- b) Monitorizar la frecuencia cardíaca, calorías quemadas, recuento de pasos, distancia recorrida, frecuencia cardíaca promedio, frecuencia cardíaca en reposo, oxigenación en la sangre, temperatura y minutos de actividad física del paciente en tiempo real.
- c) Generar un informe con los datos del paciente en un periodo de tiempo determinado: minutos activos, calorías quemadas, recuento de pasos, distancia recorrida, frecuencia cardíaca media, frecuencia cardíaca en reposo, oxigenación en la sangre, temperatura y minutos de actividad física.
- d) Detectar la posible hipertensión del paciente.

##### **4.1. Características de la aplicación**

La aplicación se desarrolló en el lenguaje de programación PHP junto con el marco de trabajo AngularJS y las bibliotecas D3 CHART y CHARTJS. Además, se utilizó Google™ API Client Library para PHP para conectar con las APIs de Google™. Google API Client Library permite trabajar con las APIs de Google™ como Gmail™, en el servidor. La aplicación se configuró para recopilar los datos necesarios del paciente desde un reloj inteligente Amazfit GTR 3 Pro™ así como de un dispositivo móvil, ambos sincronizados con Google Fit™.

Obsérvese que los datos recogidos del paciente eran privados y solo se mostraban mediante la autenticación del usuario en la plataforma a través de Gmail™. El Amazfit GTR 3 Pro™ cuenta con el mismo sensor que los modelos estándar, es decir, el BioTracker PPG de seis fotodiodos y, como tal, es capaz de monitorizar la frecuencia

**Tabla 1.** Parámetros asociados con la hipertensión.

| Parámetro                     | Rango  | Descripción  |
|-------------------------------|--|--|
| Edad                          | 18-99 años   | Edad de la persona.  |
| Sexo                          | Femenino o Masculino   | El sexo de la persona.<br>(Hombre=H o Mujer=M).  |
| Presión Arterial (PAS)        | PAS: 120-129 mmHg (Normal)<br>PAD: 80-89 mmHg (Normal)   | PAS: Presión Arterial Sistólica.<br>Presión de la sangre en la arteria cuando se contrae el corazón.<br><br>PAD: Presión Arterial Diastólica.<br>Presión de la sangre en la arteria cuando el corazón se relaja entre latidos. |
| Sedentarismo                  |  | Falta de actividad física regular.<br>(Sí=1 No=0)  |
| Índice de masa corporal (IMC) | IMC < 18.5 = Insuficiente.<br>IMC > 18.5 e IMC < 24.9 = Normal o saludable.<br>IMC > 25.0 e IMC < 29.9 = Sobrepeso.<br>IMC >= 30.0 = Obesidad. | Índice de masa corporal de la persona.   |
| Alcohólico                    |  | Si la persona bebe alcohol. (Sí=1 No=0)  |
| Fumador                       |  | Si la persona fuma. (Sí=1 No=0)  |
| Antecedentes Familiares (AF)  |  | Familiares de la persona, que tuvieron hipertensión u otra enfermedad como diabetes. (Sí=1 No=0)   |
| Etnia Negra *(EN)             |  | Personas con color de piel negra. (Sí=1 No=0)  |

cardíaca, el sueño, el nivel de oxígeno en sangre, el estrés y el ritmo respiratorio, además de ciclo menstrual.

En cuanto a Google Fit™, utiliza los sensores de movimiento del reloj inteligente para sincronizarse con un dispositivo móvil y el GPS para detectar cuándo una persona está en movimiento. A continuación, utilizando los parámetros obtenidos, calcula la intensidad de la actividad física y otros datos, como las calorías quemadas.

#### 4.2. Parámetros y reglas para la detección de hipertensión

La aplicación Web monitoriza y supervisa la salud del paciente durante sus actividades diarias con una precisión similar a la del sistema de monitorización de ECG ambulatorio. Al registrar los parámetros de las constantes vitales del paciente en tiempo real, la aplicación puede detectar casos de hipertensión. La Tabla 4.2.1 enumera los principales parámetros asociados para la detección de la hipertensión y los factores de riesgo más recurrentes con base en los registros válidos de 14,495 pacientes publicados

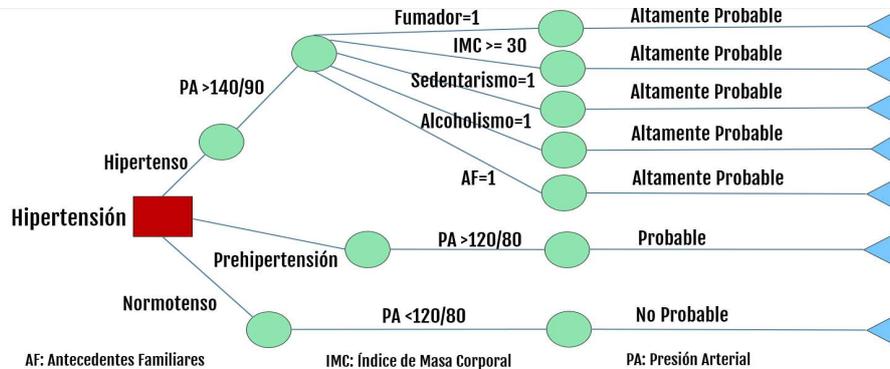


Fig. 2. Árbol de decisión para la detección de la hipertensión.

en diferentes datasets de plataformas especializadas en la ciencia de los datos como son Kaggle [20], Data Europa [21] y Dryad Data [22].

Teniendo en cuenta los parámetros mencionados anteriormente, se desarrolló un conjunto de reglas, mediante el uso del API de Weka que está basado en Java específicamente la versión 3.8.5. Se utilizó el algoritmo J48 que es una implementación open source en lenguaje de programación Java del algoritmo C4.5, esto quiere decir que tanto C4.5 y J48 son algoritmos de clasificación usados para generar árboles de decisión para la detección de hipertensión que se implementaron en el sistema de la aplicación web como se puede ver en la Figura 2.

Adicionalmente, en la Tabla 4.2.2 se muestran las métricas (coeficiente de correlación, error absoluto medio, raíz del error cuadrático medio, error relativo absoluto, raíz del error cuadrático relativo) de los algoritmos basados en árboles de decisiones que se utilizaron en los entrenamientos para la detección de hipertensión mediante el uso de la API de Weka.

A medida que se activan las reglas, se activa la acción del envío de recomendaciones para apoyar al paciente. La Figura 3 ejemplifica cómo la aplicación Web envía recomendaciones a los pacientes.

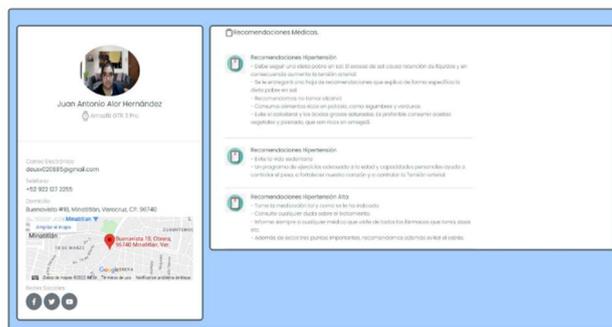
### 4.3. Monitorización del paciente

En la sección de “*Mis wearables*” de la aplicación, los usuarios pueden introducir sus datos de salud desde su reloj inteligente. Sin embargo, los usuarios también pueden sincronizar en tiempo real su dispositivo wearable con la aplicación para, finalmente, descargar un informe en PDF de sus datos de salud. En concreto, al seleccionar la opción “*Sincronizar tu cuenta de Google Fit*”, la aplicación recupera los datos almacenados en la cuenta de Google™ en la nube del usuario.

Para ello, el usuario debe autenticar su cuenta con su dirección de correo electrónico y contraseña de Google™ para permitir la sincronización de datos. A continuación, el servidor de Google Fit™ recupera de la nube los datos del wearable registrado. Por último, estos datos se muestran en forma de gráficas en la interfaz de la aplicación. La Figura 4 muestra parte del panel del paciente de la aplicación web.

**Tabla 2.** Métricas de algoritmos basados en árboles de decisiones.

| Algoritmo                          | Decision Stump | MSP    | Random Forest | Random Tree | REP Tree |
|------------------------------------|----------------|--------|---------------|-------------|----------|
| Coefficiente de correlación        | 0.2248         | 0.3588 | 0.3179        | 0.1828      | 0.2938   |
| Error absoluto medio               | 0.3966         | 0.3315 | 0.3585        | 0.3486      | 0.3653   |
| Raíz del error cuadrático medio    | 0.4497         | 0.4434 | 0.4461        | 0.5904      | 0.4492   |
| Error relativo absoluto            | 93.35%         | 78.01% | 84.37%        | 82.03%      | 85.97%   |
| Raíz del error cuadrático relativo | 97.53%         | 96.16% | 96.75%        | 128.04%     | 97.42%   |
| Número total de instancias         | 1007           | 1007   | 1007          | 1007        | 1007     |



**Fig. 3.** Ejemplo de recomendaciones emitidas por la aplicación Web de detección de hipertensión.



**Fig. 4.** Panel del paciente de las variables biométricas de la aplicación Web.

## 5. Conclusiones y trabajo a futuro

El constante incremento de personas hipertensas es un tema muy alarmante, ya que el no llevar un control adecuado de la presión arterial termina en pérdida de la vida. Es por esto que últimamente se ha apostado por invertir tiempo y conocimientos en el desarrollo de dispositivos más cómodos y menos dolorosos, que consigan ayudar no solo a las personas que ya están diagnosticadas como hipertensas sino también a aquellas que desarrollan dicha enfermedad.

En este trabajo, se presentó una aplicación web, que con ayuda de una pulsera inteligente, es capaz de detectar y prevenir la hipertensión de un individuo aplicando técnicas de Aprendizaje Automático mediante el algoritmo de clasificación J48. Como trabajo a futuro se pretende abordar más enfermedades crónico-degenerativas como son la diabetes y hepatitis, mediante el uso de wearables con actualizaciones en sus tipos de lectura y funcionalidades, que presenten las certificaciones correspondientes y avaladas por las autoridades en materia de salud.

Se pretende integrar el envío de alarmas al paciente con el objetivo de llevar a cabo las recomendaciones médicas realizadas por la aplicación. Finalmente, se integrarán más APIs de pulseras inteligentes como: Fitbit™, Polar™, así como la implementación de diversos algoritmos de aprendizaje automático para mejorar la eficiencia de la aplicación.

**Agradecimientos.** Este trabajo de investigación fue patrocinado por el Consejo Nacional de Ciencia y Tecnología de México (CONACYT) y la Secretaría de Educación Pública (SEP) de México a través del programa PRODEP. Los autores también agradecen al Tecnológico Nacional de México (TecNM) por apoyar este proyecto.

## Referencias

1. Piña, M., Araujo, G., Castillo, C.: Hipertensión arterial un problema de salud pública en México (2020)
2. Campos, I., Hernández, L., Pedroza, A., Medina, C., Barquera, S.: Hypertension in Mexican adults: Prevalence, diagnosis and type of treatment. *Ensanut MC 2016. Salud Publica Mex*, vol. 60, pp. 233–243 (2018)
3. Sazonov, E., Neuman, M. R.: *Wearable sensors: Fundamentals, implementation and applications* (2014)
4. Janjua, G., Guldenring, D., Finlay, D., McLaughlin, J.: Wireless chest wearable vital sign monitoring platform for hypertension. *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS.*, pp. 821–824 (2017)
5. Ni, H., Cho, S., Mankoff, J., Yang, J., Dey, A. K.: Automated recognition of hypertension through overnight continuous HRV monitoring. *J. Ambient Intell. Humaniz. Comput.*, vol. 9, pp. 2011–2023 (2018) doi: /10.1007/s12652-017-0471-y.

6. Afeni, B., Aruleba, T., Oloyede, I.: Hypertension prediction system using naive bayes classifier. *Journal of Advances in Mathematics and Computer Science*, vol. 24, no. 2, pp. 1–11 (2017) doi: 10.9734/JAMCS/2017/35610.
7. Ruiz-Fernandez, D., Marcos-Jorquera, D., Gilart-Iglesias, V., Vives-Boix, V., Ramírez-Navarro, J.: Empowerment of patients with hypertension through BPM, IoT and remote sensing. *Sensors*, vol. 17, no. 10, pp. 2273, (2017) doi: 10.3390/s17102273.
8. Irizarry, T., Allen, M., Suffoletto, B. P., Einhorn, J., Burke, L. E., Kamarck, T. W., Rollman, B. L., Muldoon, M. F.: Development and preliminary feasibility of an automated hypertension self-management system. *The American Journal of Medicine*, vol. 131, no. 9, pp. 1125.e1–1125.e8, (2018) doi: 10.1016/j.amjmed.2018.04.038.
9. Thangada, N. D., Garg, N., Pandey, A., Kumar, N.: The emerging role of mobile-health applications in the management of hypertension. *Current Cardiology Reports*, vol. 20 (2018) doi: 10.1007/s11886-018-1022-7.
10. Singh, N., Singh, P., Bhagat, D.: A rule extraction approach from support vector machines for diagnosing hypertension among diabetics. *Expert Syst. Appl.*, vol. 130, pp. 188–205 (2019)
11. Carvajal, O., Melin, P., Miramontes, I., Prado-Arechiga, G.: Optimal design of a general type-2 fuzzy classifier for the pulse level and its hardware implementation. *Eng. Appl. Artif. Intell.*, vol. 97, no. 104069 (2021)
12. Guzmán, J. C., Miramontes, I., Melin, P., Prado-Arechiga, G.: Optimal genetic design of type-1 and interval type-2 fuzzy systems for blood pressure level classification. *Axioms*, vol. 8, no. 1, (2019) doi: 10.3390/axioms8010008.
13. Kitt, J., Fox, R., Tucker, K. L., McManus, R. J.: New Approaches in Hypertension Management: a Review of Current and Developing Technologies and Their Potential Impact on Hypertension Care. *Curr. Hypertens. Rep.*, vol. 21 (2019)
14. Mankar, K., Gawande, P., Thakare, A. P.: Design Remote Healthcare Monitoring System for Hypertensive Patient Based On IOT. *Int. J. Electron. Commun. Soft Comput. Sci. Eng.*, vol. 5, pp. 10–15 (2020).
15. Wu, X., Yuan, X., Wang, W., Liu, K., Qin, Y., Sun, X., Ma, W., Zou, Y., Zhang, H., Zhou, X., et. al.: Value of a machine learning approach for predicting clinical outcomes in young patients with hypertension. *Hypertension*, pp. 1271–1278 (2020)
16. Kario, K.: Management of Hypertension in the Digital Era: Small Wearable Monitoring Devices for Remote Blood Pressure Monitoring. *Hypertension*, pp. 640–650 (2020)
17. Welykholowa, K., Hosanee, M., Chan, G., Cooper, R., Kyriacou, P. A., Zheng, D., Allen, J., Abbott, D., Menon, C., Lovell, N. H., et. al.: Multimodal Photoplethysmography-Based Approaches for Improved Detection of Hypertension. *J. Clin. Med.*, vol. 9, no. 1203 (2020)
18. Tsoi, K., Yiu, K., Lee, H., Cheng, H. M., Wang, T. D., Tay, J. C., Teo, B. W., Turana, Y., Soenarta, A. A., Sogunuru, G.P.: Applications of artificial intelligence for hypertension management. *J. Clin. Hypertens.*, vol. 23, pp. 568–574 (2021)
19. Zhang, Y., Yang, N., Si, G., Zhang, Y., Dong, Z., Huang, Y., Tan, X.: What matters the adherence with BP 24-hr self-monitoring wearable device among hypertensive patients? A population-based survey. *Transl. Behav. Med.*, vol. 10, pp. 1053–1063 (2021)
20. Ulianova, S.: Cardiovascular Disease dataset. | Kaggle (2022)
21. Administração Central do Sistema de Saúde (ACSS): Hypertension Program Activity - Data Europa EU (2021)

*Juan Antonio Alor-Hernandez, Nancy Aracely Cruz Ramos, Giner Alor-Hernández, et al.*

22. Khanal, M. K., Dhungan, R. R., Bhandari, P., Gurung, Y., Paudel, K. N.: Prevalence, associated factors, awareness, treatment, and control of hypertension: Findings from a cross sectional study conducted as a part of a community based intervention trial in Surkhet, Mid-western region of Nepal. *Plos Biology*, Submit Your Research, (2017) doi: 10.1371/journal.pone.0185806.