

Aplicación Móvil para Predecir la Probabilidad de Pertenecer al Grupo de Riesgo Cardiovascular Utilizando Machine Learning

Omar CHAVEZ OLIVERA

Escuela de Ingeniería de Sistemas y Computación, Universidad Peruana de Ciencias Aplicadas
Lima, Peru.

U201523075@upc.edu.pe

Luis GALINDO HONORES

Escuela de Ingeniería de Sistemas y Computación, Universidad Peruana de Ciencias Aplicadas
Lima, Peru.

U201516808@upc.edu.pe

Alfredo BARRIENTOS PADILLA

Escuela de Ingeniería de Sistemas y Computación, Universidad Peruana de Ciencias Aplicadas
Lima, Peru.

pcsiabar@upc.edu.pe

Miguel CUADROS GALVEZ

Escuela de Ingeniería de Sistemas y Computación, Universidad Peruana de Ciencias Aplicadas
Lima, Peru.

pcsimcua@upc.edu.pe

RESUMEN

El uso de aplicaciones móviles para ayudar en la salud de las personas es cada vez más común, así lo demuestran investigaciones publicadas en los últimos años. Sin embargo, esta puede ser complementada con el uso de técnicas y algoritmos de machine learning para ayudar a resolver un problema en particular. Debido a ello el presente estudio se centra en la creación de una aplicación móvil que tiene por principal funcionalidad la predicción de pertenecer al grupo de riesgo cardiovascular en personas mayores de 50 años. Para lograr esto se ha investigado sobre distintas variables y algoritmos de machine learning que permiten lograr esta tarea. Es así como se decidió que el motor de inferencia sería un modelo ensamblado, donde el metaclasificador final es un modelo de Naive Bayes y los modelos base son Random Forest y Logistic Regression. El proceso de validación de la aplicación lo realizó un especialista en cardiología, el cual comprobó el nivel de precisión del modelo.

Palabras clave: Machine Learning, Aplicaciones móviles, feature selection

1 INTRODUCCIÓN

Las enfermedades cardiovasculares son la principal causa de muerte en todo el mundo. Se estima que han muerto 17,9 millones de personas debido a estas solo en el año 2019. Por otro lado, también se sabe que más de las tres cuartas partes de las muertes causadas por este tipo de mal se producen en países bajo y medios [1].

En la actualidad se han creado distintas aplicaciones con orientación al campo de la medicina, las cuales tratan de ayudar a mejorar algún aspecto de la calidad de vida de las personas en general o de las que ya sufren algún tipo de mal. Por ejemplo, la

aplicación “Diabetes: M” es usada para que los datos de los glucómetros independientes y bombas de insulina puedan importarse por Bluetooth o Wi-Fi para analizarse [2]. Por otro lado, se tiene la aplicación “HeartHab”, la cual tiene como principal propósito apoyar a la tele rehabilitación cardiaca de sus usuarios [3].

El uso de técnicas y algoritmos de machine learning permite predecir un resultado a partir de un conjunto de datos, para ello, la computadora aprende a identificar patrones dentro del dataset que luego los aplica en datos desconocidos para dar un resultado. [4] Existen estudios en los que se han usado estos algoritmos para predecir el riesgo cardiovascular de las personas, normalmente en estos se hace referencia a varios algoritmos como: Support Vector Machine, Random Forest, Decision Tree, K-nn, entre otros [6], [7].

Debido a lo anterior expuesto, la propuesta del proyecto es la creación de una aplicación móvil que permita realizar la predicción del riesgo cardiovascular, para lograr esto se hará uso de un modelo de machine learning ensamblado, utilizando feature selection y ensamblaje de algoritmos.

2 ESTADO DEL ARTE

Se realizaron investigaciones sobre aplicaciones móviles, en las que se evidencia cómo estas monitorean y ayudan a mejorar la calidad de vida del paciente. También de cómo es que se han entrenado distintos algoritmos de machine learning, qué técnicas se usaron para mejorar su rendimiento y el conjunto de datos que normalmente es usado.

Machine Learning para detectar problemas cardiovasculares

Se hace referencia al conjunto de datos, dataset en inglés, de enfermedades cardíacas de Cleveland (CHDD, por sus siglas en inglés), el cual, contiene variables que permiten determinar si una persona tiene problemas cardiovasculares [4,5,8]. En cuanto a los algoritmos de machine learning usados para detectar problemas cardiovasculares existen varios que cumplen esta tarea de manera satisfactoria como: Regresión Logística, Naive Bayes, Tree-J48, Random Tree y Random Forest [7]. Por otro lado, se ha identificado que los algoritmos pueden mejorar su precisión si al momento de entrenar se usa la técnica de feature selection, la cual consiste en encontrar la combinación de variables más apropiada para un modelo provocando que este sea más preciso al momento de predecir la variable objetivo [6, 8]. Pese a que el uso de feature selection ayuda a optimizar los modelos, estos aún pueden mejorar si se usan técnicas de ensamblado de algoritmos, esto queda evidenciando en [4] donde usando la técnica de ensamblado stacking se obtiene mejores resultados en la predicción, en [9] se evidencia que usando el ensamblador voting se obtiene un predictor con una precisión de casi 90.00%, finalmente en [5] se entrenó el algoritmo de Decision Tree el cual fue combinado con el ensamblador Boosting obteniendo una precisión del 82.17%.

Aplicaciones Móviles médicas

Las aplicaciones móviles son cada vez más usadas en el mundo. Algunas de estas permiten registrar y monitorear valores importantes como el nivel de glucosa en la sangre, la nutrición, los ejercicios realizados y peso corporal del paciente [2]. En [10] los autores demostraron que los pacientes con cardiopatía congénita mejoraron su calidad de vida al usar la aplicación móvil “mHealth”, ya que esta permitió la detección temprana de nuevos diagnósticos de arritmias, hipertensión e insuficiencia cardíaca, dando origen a respuestas terapéuticas más rápidas. La aplicación “HeartHab” demostró que a través del uso de conceptos psicológicos y un diseño de interfaz se puede lograr que los pacientes sigan las indicaciones de sus médicos, haciendo que mejore su salud [3]. Los autores en [11] hablan de cómo una aplicación móvil puede ayudar a los pacientes con hipertensión, ya que esta posee ciertos parámetros que permiten emitir mensajes que alerten al paciente al no encontrarse dentro de los parámetros normales establecidos por los autores. Para [12] se demostró que una aplicación móvil apoyada por un modelo de machine learning puede detectar el cáncer de piel de manera eficaz. En [13] se hace uso de una aplicación móvil la cual permite monitorear el estado de salud, los triglicéridos, lípidos, entre otros indicadores, con la intención de mejorar la calidad de vida del paciente. En [14] se menciona cómo es que una aplicación móvil desarrollada en Android se puede utilizar para el examen de trastornos motores del sistema nervioso central que ocurren en pacientes que padecen Huntington. En [15] los autores demuestran una aplicación móvil, la cual es usada para monitorear la presión arterial y la frecuencia cardíaca de una persona.

3 DESARROLLO

La propuesta está compuesta por una aplicación móvil, la cual hace uso de un algoritmo ensamblado de machine learning para determinar la probabilidad de pertenecer al grupo de personas con riesgo cardiovascular.

Modelo predictivo: El desarrollo del modelo de machine learning fue realizado usando la técnica de ensamblado stacking,

ya que de acuerdo con lo observado se puede obtener mejores modelos usando esta [4,5,9]. Al emplear esta técnica se tiene modelos base y metaclasificadores, donde el output de los modelos base es usado como input por los metaclasificadores. Se denomina como metaclasificador a aquel modelo que usa como input para la predicción de otro modelo. El proceso de entrenamiento de los modelos inicia con un reconocimiento de los datos que contiene el CHDD, en el cual, se consideraron solo las variables que son marcadores, factores de riesgo y algunos procedimientos, ya que el modelo entrenado simula a un médico el cual no posee el resultado de todos los procedimientos que se encuentran en CHDD. Las variables escogidas fueron:

Tabla I. Variables que fueron usadas para el entrenamiento del modelo predictivo

Nombre de la variable	Descripción
Sex	Género del individuo
Trestbps	Presión arterial
Chol	Colesterol
Fbs	Glucosa en ayunas
Thalach	Frecuencia cardíaca
Ca	Resultados del examen de Fluoroscopia
Thal	Estado del corazón
Cp	Tipo de dolor en el pecho
Num	Variable objetivo, diagnóstico final.

Cabe resaltar que la variable “Num”, es la variable objetivo, esta cuenta con 5 valores: 0, 1, 2, 3 y 4. Donde 0 representa la ausencia de algún mal cardíaco y 1, 2, 3 y 4 la presencia de uno, debido a esto se procedió a transformar esta variable a solo dos valores. Donde 0 representa la ausencia y todos los registros que contenían 1, 2, 3 y 4 tomaron el valor de 1, para representar la presencia de un mal cardíaco.

Después de identificar las variables con los que se entrenarán los modelos, se inició el entrenamiento, para ello, se usaron los modelos de Support Vector Machine, Random Forest, Naive Bayes y Logistic Regression. Estos serán los algoritmos base de nuestro modelo ensamblado del tipo stacking y para su entrenamiento se usó la técnica de feature selection, la cual, consiste en generar distintas combinaciones de datasets a partir de uno. Así mismo, se estableció que la cantidad mínima y máxima de variables es de 3 y 8 respectivamente para cada dataset generado. Para determinar el número de combinaciones se aplicó la siguiente fórmula, en la cual “n” es el número de variables que contiene el dataset original:

$$2^n - \left(\frac{n!}{1!(n-1)!} \right) - \left(\frac{n!}{2!(n-2)!} \right) - 1 = 2^n - \left(\frac{n^2 + n}{2} + 1 \right)$$

Fórmula 1. Permite determinar la cantidad de combinación de acuerdo con la cantidad de variables

Se obtuvo que las siguientes combinaciones son con las que los modelos consiguieron mejor precisión, para determinar la precisión se usó la técnica de cross-validation, validación cruzada en español.

Tabla II. Modelos y combinación de variables que hace que tengan una mejor precisión.

Modelo	Combinación de variables	Precisión	Estabilidad (+/-)
Support Vector Machine	'Trestbps', 'Thalach', 'Sex', 'CP', 'FBS', 'CA', 'Thal'	84.00%	5.00%
Random Forest	'Sex', 'CP', 'FBS', 'CA', 'Thal'	82.00%	4.00%
Naive Bayes	'Chol', 'Thalach', 'Sex', 'CP', 'CA', 'Thal'	83.00%	1.00%
Logistic Regresion	'Chol', 'Thalach', 'Trestbps', 'Sex', 'FBS', 'CA'	80.00%	2.00%

Después de obtener la combinación de variables que hace a cada modelo más preciso, se procedió a agregar la predicción de cada uno al CHDD, haciendo que este gane más información, a este nuevo dataset lo llamaremos CHDD2. Las 4 columnas agregadas se denominaron:

- SVC: Resultado de la predicción del modelo Support Vector Machine.
- RFC: Resultado de la predicción del modelo Random Forest.
- GNB: Resultado de la predicción del modelo Naive Bayes.
- LGR: Resultado de la predicción del modelo Logistic Regresion.

Se procedió a entrenar los metaclasificadores, para esto se escogió los mismos algoritmos base como metaclasificadores y como dataset de entrenamiento se usó el CHDD2. Al igual, que con los modelos base, se usó feature selection para encontrar la combinación de variables que mejore al metaclasificador en su predicción y, también, se utilizó la técnica de cross-validation para obtener la precisión y sensibilidad de cada modelo. Se obtuvieron los siguientes resultados:

Tabla III. Metaclasificadores y combinación de variables que hace que tengan una mejor precisión

Modelo	Combinación de variables	Precisión	Estabilidad (+/-)
Support Vector Machine	'Trestbps', 'FBS', 'SVC', 'RFC', 'GNB', 'LGR'	87.00%	8.00%
Random Forest	'Sex', 'Chol', 'FBS', 'Thalach', 'CA', 'RFC', 'GNB'	88.00%	6.00%
Naive Bayes	'Sex', 'Trestbps', 'Chol', 'FBS', 'Thalach', 'Thal', 'RFC', 'LGR'	87.00%	2.00%
Logistic Regresion	'Sex', 'Trestbps', 'Chol', 'FBS', 'Thalach', 'Thal', 'RFC', 'GNB'	86.00%	8.00%

De acuerdo con los resultados de la Tabla III, se observa que el modelo de Naive Bayes es el que tiene la mejor precisión y es el más estable, por lo que este fue el modelo escogido para ser implementado en el sistema "Medicare Perú".

Sistema Medicare Perú

El sistema, el cual fue llamado Medicare Perú, consiste en una aplicación móvil la cual permite calcular la probabilidad de pertenecer al grupo de personas con riesgo cardiovascular y mostrar información relacionada con el IMC. Así mismo se implementó una aplicación web que permite la gestión de los módulos teniendo en cuenta el modelo de negocio. El sistema consta de 5 roles y 5 módulos:

Roles del Sistema:

1. **Administrador:** Usuario del sistema que puede gestionar todo el sistema.
2. **Administrador Clínica:** Usuario que cuenta con acceso a la aplicación web, puede administrar los pacientes y doctores asociados a la clínica a la que pertenece.
3. **Paciente:** Usuario que cuenta con acceso a la aplicación móvil, puede determinar su probabilidad de pertenecer al grupo de personas con riesgo cardiovascular. Puede dar su código de suscripción a su médico o personas interesadas en su salud para que estos estén al tanto de esta.
4. **Interesado:** Usuario que se encuentra interesado en la salud de un usuario con rol "Paciente". Pueden ser familiares o amigos del paciente.
5. **Doctor:** Comparte las mismas cualidades que el rol "Interesado". Sin embargo, este tiene que ser registrado por un "Administrador de clínica", ya que un doctor está asociado a una clínica.

Los módulos son:

1. **Autenticación:** Este módulo expone servicios para autenticar al usuario, registrar usuarios y gestionar sesión. La sesión, se mantiene activa si es que el usuario utiliza de manera frecuente la aplicación, es decir, el usuario no tiene que iniciar sesión de nuevo si ya lo ha hecho anteriormente. A su vez, permite actualizar la contraseña y registrar usuarios externos al sistema con rol de interesado.
2. **Clínica:** Este módulo permite a un usuario con rol de administrador gestionar las clínicas que se hayan afiliado al sistema. Permitiendo al administrador agregar una clínica, actualizar la información de una o inhabilitar en caso ya no desee estar afiliada.
3. **Notificación:** Este módulo permite avisar al paciente sobre ciertas interacciones que hubo en relación con su perfil como suscripciones o revisiones. También permite registrar dispositivos móviles en los que el paciente haya iniciado sesión, esto es necesario para que el sistema sepa a qué dispositivos enviar la notificación.
4. **Usuario:** Este módulo permite la gestión de usuarios con rol administrador de clínica, interesado, paciente o doctor. Esto incluye la capacidad de poder agregar, actualizar o inhabilitar. Así mismo a través de este módulo un interesado o doctor se puede suscribir a un paciente para que tenga acceso a su perfil, permitiéndoles observar información relacionada a la salud del paciente. También permite observar información relacionada a la clínica a la que se encuentra afiliada.
5. **Paciente:** Este módulo permite integrar el perfil del usuario con su perfil de paciente, esto es sólo para los

usuarios con rol paciente. Esto habilita las opciones de diagnóstico, mediante la cual un paciente puede determinar su probabilidad de pertenecer al grupo de personas con riesgo cardiovascular, calcular su IMC y observar información relacionada a su salud.

Arquitectura

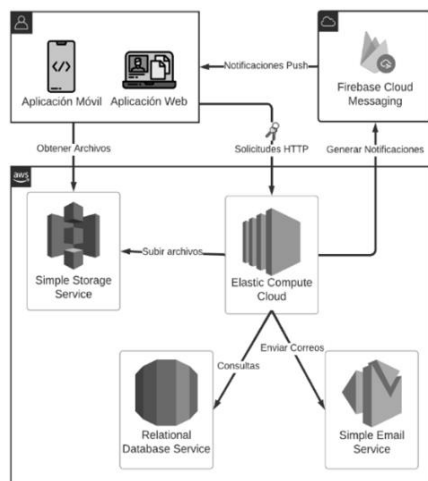


Imagen 1. Arquitectura cloud

Aplicación móvil

La aplicación móvil consiste de 3 vistas principales las cuales son: 1.Tablero, 2.Diagnóstico y 3.Menú.

En la vista “Tablero”, el paciente puede observar valores que le ayuden a identificar cuál es su estado de salud. En la parte superior de la pantalla, se encuentra la tarjeta “Riesgo Cardiovascular” que muestra el resultado de la probabilidad de pertenecer al grupo de personas con riesgo cardiovascular. Al presionar esta, se mostrará un modal, en el cual se observan las variables con las que se calculó la probabilidad. En esta vista también se observa la tarjeta del “IMC”, la cual al ser presionada muestra un formulario, en el que se ingresan datos como el peso y altura que son utilizadas para calcular el IMC. El resultado final de este cálculo se muestra en la vista “Tablero”, en la cual se ve el valor del “Peso”, “Altura” e “IMC”.




Imagen 2. Vista “Tablero”.

En la vista “Diagnóstico”, el paciente puede ingresar los valores de cada variable del formulario las cuales son: 1.Presión arterial sistólica en reposo, 2.Colesterol malo, 3.Glucosa en ayunas, 4.Frecuencia cardiaca máxima en reposo, 5.Fluoroscopia, 6.Estado del corazón (ecocardiografía) y 7.Tipo de angina. Estas son necesarias para realizar el diagnóstico y calcular la probabilidad de pertenecer al grupo de personas con riesgo

cardiovascular. Antes de realizar este cálculo se mostrará la vista “Resumen”, la cual contiene los valores ingresados para cada variable. De acuerdo al resultado, el paciente con ayuda de un doctor podrá tomar decisiones que ayuden a mejorar su calidad de vida. Este resultado se puede observar en la vista “Tablero”.




Imagen 3. Vista “Diagnóstico”.

Adicionalmente, para los usuarios de un iPhone y un Apple Watch tienen la opción de utilizar su apple watch para calcular la frecuencia cardiaca máxima en reposo. Esta funcionalidad debe ser consultada con un cardiólogo para determinar si puede ser usada y fue desarrollada con fines de proporcionar una alternativa que sea más accesible. Cuando el paciente quiera ingresar el valor de la frecuencia cardiaca máxima, se mostrará un modal en la parte superior de la pantalla en la que se pregunta si se quiere o no utilizar el apple watch para calcular dicho valor. Al presionar Sí, se mostrará una vista en la que irán apareciendo las frecuencias cardíacas hasta llegar a 5 y poder colocar el mayor valor en el formulario.

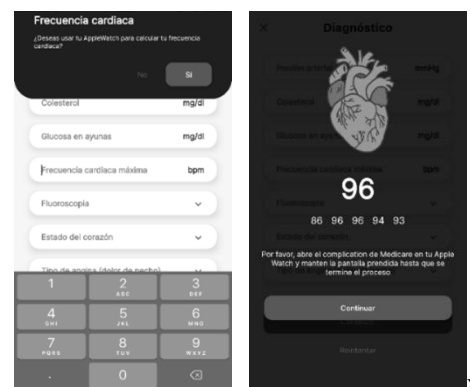


Imagen 4 y 5. Captura de la frecuencia cardiaca a través de un Apple Watch.

Durante este proceso, la aplicación de Medicare Perú, en el apple watch, debe estar abierta para que notifique a la aplicación móvil de las frecuencias cardíacas que está calculando. Así mismo, la última frecuencia cardiaca calculada se muestra en el apple watch.




Imagen 6. Captura de pantalla del Apple Watch, se observa el valor de la frecuencia cardiaca que este calcula

En la vista “Menú” se listan una serie de opciones que aparte de permitir al usuario acceder a su perfil, le permite, al adulto mayor, poder visualizar guías para que conozca más sobre el sistema, cómo utilizar la aplicación y se contacte con soporte en caso necesite ayuda. Las opciones son las siguientes:

1. Perfil: opción que muestra al perfil del usuario.
2. Manual de uso: muestra un archivo en el que se detalla cada una de las funcionalidades de la aplicación
3. Preguntas frecuentes (FAQ): muestra un archivo en el que se listan las preguntas frecuentes relacionadas a la aplicación.
4. Video: muestra un archivo audiovisual de la aplicación siendo usada.
5. Mi código QR: muestra el código QR, el cual contiene el código de suscripción del paciente para que pueda ser compartido y un usuario con rol interesado pueda suscribirse al perfil de este.
6. Acerca de nosotros: muestra una descripción de qué es Medicare Perú y las licencias de las herramientas utilizadas en la aplicación.
7. Contáctanos: muestra un formulario en el que se solicita un comentario con la pregunta que el usuario paciente tiene.



Imagen 7. Vista “Menú”.

Para los usuarios de un iPhone con iOS14 en adelante, pueden añadir al home screen el widget de Medicare Perú que muestra, de forma resumida, información que pertenece a la vista “Tablero”. El widget tiene 3 tamaños, las cuales son, pequeño, mediano y grande, y dependiendo del tamaño que se utilice el widget mostrará mayor cantidad de información.



Imagen 8 y 9. Widgets de la aplicación Medicare Perú en un iPhone.

Aplicación web

Esta aplicación fue desarrollada con el objetivo de proveer funcionalidades de gestión para los administradores del sistema. De tal manera que se pueda agregar, actualizar o deshabilitar pacientes, doctores, administradores de clínica y clínicas; los cuales son roles que están relacionados al modelo de negocio.

La aplicación web cuenta con 3 módulos administrables las cuales son: 1.Clínicas, 2.Administradores de Clínicas y 3.Pacientes. El módulo de clínicas y administradores de clínicas las puede gestionar solo los administradores del sistema, mientras que el módulo de paciente la gestiona los administradores de clínicas.

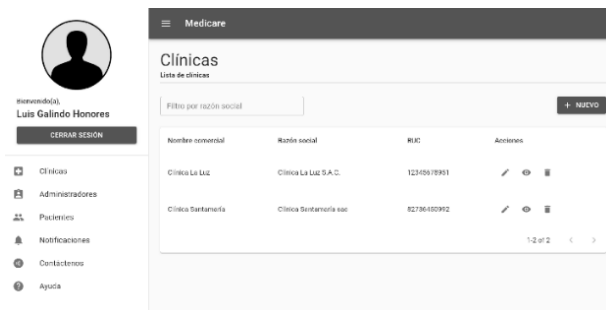


Imagen 10. Aplicación web administrativa

4 VALIDACIÓN DEL MODELO PROPUESTO

La aplicación fue mostrada a dos especialistas en cardiología, a los cuales, se le mostró las funcionalidades que esta posee.

El primer especialista comentó que a nivel visual la aplicación es llamativa y que a nivel de funcional es fácil de entender. Mencionó que la solución desarrollada cuenta con “funcionalidades que permite ayudar a mejorar la calidad de vida de una persona con problemas cardiovasculares”. Sin embargo, sugirió que, en la funcionalidad de diagnóstico, la cual utiliza el modelo de machine learning entrenado, se debería agregar variables como la edad, sedentarismo, fumador y diabetes. Los cuales, son factores de riesgo que son utilizados para determinar el riesgo cardiovascular de las personas.

El segundo especialista tuvo más comentarios con respecto al tema funcional y las facilidades que brinda la aplicación. En la vista “Tablero”, recomendó que la aplicación de sugerencias de acuerdo al resultado de la predicción, como por ejemplo: Si la probabilidad obtenida es menor a 30%, “Su salud es excelente siga así”; si la probabilidad es mayor a 30% y menor a 65%, “Usted debería empezar a caminar más y considerar ir a un médico”; finalmente, si es mayor o igual a 65%, “Vaya al doctor a hacerse un chequeo completo, coma sano y comience a caminar bastante”. Para complementar lo anterior mencionado, se recomendó que se utilice los colores del semáforo como el rojo, ámbar y verde para indicar si se tiene un riesgo alto, moderado o bajo respectivamente. Durante la validación de la aplicación se mencionó que esta puede hacer uso de un Apple Watch, el especialista comentó que utilizar esta tecnología es cada vez más común y que incluso se está colocando en las guías de manejo clínico en la sociedad americana de cardiología, debido a que, estos dispositivos pueden proveer valores como la frecuencia cardiaca, nivel de oxígeno, calidad de sueño, cantidad de pasos, entre otros. Al igual que el primer especialista, nos sugirió agregar más factores de riesgo para realizar el diagnóstico, sin

embargo, a diferencia del primero, nos indicó que también se considere una variable que identifique si la persona toma bebidas alcohólicas.

5 CONCLUSIONES

La combinación de la inteligencia artificial y aplicaciones móviles ayuda a identificar si una persona es propensa a tener algún tipo de enfermedad cardíaca. La investigación presentada muestra los resultados de los entrenamientos de distintos modelos de machine learning, las funcionalidades de la aplicación móvil y los comentarios de dos especialistas en cardiología. Durante el entrenamiento de modelos se identificó que la combinación de estos, ensamblaje de modelos, permite la construcción de modelos más precisos y estables. Se observó que los modelos ensamblados de Support Vector Machine, Random Forest, Naive Bayes y Logistic Regression obtienen precisiones de 87.00%, 88.00%, 87.00% y 86.00% con una estabilidad de 8.00%, 6.00%, 2.00% y 8.00% respectivamente, Tabla III. Pese a que el modelo ensamblado Random Forest tiene una mejor precisión, este es más inestable, por lo que se escogió el modelo ensamblado Naive Bayes, ya que tiene una precisión parecida y es más estable que los demás. En cuanto a las funcionalidades de la aplicación móvil, se describió cada una de estas, las cuales permiten: Obtener el IMC, realizar el diagnóstico, obtener la frecuencia cardíaca a través de un Apple Watch, modificar la información personal y conseguir manuales o ayuda para aprender a manejar la aplicación desde la vista de "Menú". La vista principal de la aplicación es "Tablero", en esta se le da información al paciente sobre su IMC, probabilidad de pertenecer al grupo de personas con riesgo cardiovascular y el valor de las variables con las que se calculó esto. Durante el proceso de validación, ambos especialistas en cardiología coincidieron que como una oportunidad de mejora del proceso de diagnóstico se debería agregar factores de riesgo cardiovascular como la edad, sedentarismo, fumador, diabetes y una que indique si la persona toma bebidas alcohólicas. Como recomendaciones para futuros proyectos, se aconseja ponerse en contacto con una entidad de salud que pueda facilitar un conjunto de datos que tengan más factores de riesgo cardiovascular, esto con la intención de obtener un mejor modelo predictivo. También implementar una funcionalidad que dé consejos al usuario de acuerdo con los resultados obtenidos por el diagnóstico realizado por la aplicación.

6 REFERENCIAS

- [1] Cardiovascular diseases (CVDs), World Health Organization, June 11, 2021. Accessed on: September 12, 2021 [Online]. Available: [https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-\(cvds\)](https://www.who.int/news-room/fact-sheets/detail/cardiovascular-diseases-(cvds))
- [2] P. P. Brzan, E. Rotman, M. Pajnkihar y P. Klanjsek, «Mobile Applications for Control and Self Management of Diabetes: A Systematic Review,» *Journal of Medical Systems*, vol. 40, n° 9, 9 2016.
- [3] S. Sankaran, P. Dendale y K. Coninx, «Evaluating the impact of the hearthab app on motivation, physical activity, quality of life, and risk factors of coronary artery disease patients: Multidisciplinary crossover study,» *Journal of Medical Internet Research*, vol. 21, n° 4, 4 2019.
- [4] C. B. C. Latha y S. C. Jeeva, «Improving the accuracy of prediction of heart disease risk based on ensemble classification techniques,» *Informatics in Medicine Unlocked*, vol. 16, 1 2019.
- [5] V. Ramalingam, A. Dandapath, y M. Raja, «Heart disease prediction using machine learning techniques : a survey »*International Journal of Engineering & Technology*, vol 7, pp 684 – 687, 2018.
- [6] P. Dileep, K. N. Rao, P. Bodapati y R. Scholar, «An Efficient Feature Selection Based Heart Disease Prediction Model 1,» *International Journal of Advanced Science and Technology*, vol. 28, n° 9, pp. 309-323, 2019.
- [7] J. Castellanos, A. Santiago, C. Bouza y J. Maclovio, «Valoración de riesgo cardiovascular mediante modelos de clasificación» *Investigación Operacional*, vol 40, no°1, 80-87, 2019.
- [8] M. S. Amin, Y. K. Chiam y K. D. Varathan, «Identification of significant features and data mining techniques in predicting heart disease,» *Telematics and Informatics*, vol. 36, pp. 82-93, 3 2019.
- [9] V. M. Deshmukh, «Heart disease prediction using ensemble methods,» *International Journal of Recent Technology and Engineering*, vol. 8, n° 3, pp. 8521-8526, 9 2019.
- [10] D. Kauw, M. A. C. Koole, M. M. Winter, D. A. J. Dohmen, I. I. Tulevski, S. Blok, G. A. Somsen, M. P. Schijven, J. W. J. Vriend, D. Robbers-Visser, B. J. M. Mulder, B. J. Bouma y M. J. Schuurin, «Advantages of mobile health in the management of adult patients with congenital heart disease,» *International Journal of Medical Informatics*, vol. 132, 12 2019.
- [11] L. J. B. Andrews, L. Raja y S. Shanmugasundaram, «Mobile android-based remote patient monitoring system through wearable sensors,» *Journal of Discrete Mathematical Sciences and Cryptography*, vol. 22, n° 4, pp. 557-568, 5 2019.
- [12] A. Udrea, G. D. Mitra, D. Costea, E. C. Noels, M. Wakkee, D. M. Siegel, T. M. de Carvalho y T. E. C. Nijsten, «Accuracy of a smartphone application for triage of skin lesions based on machine learning algorithms,» *Journal of the European Academy of Dermatology and Venereology*, vol. 34, n° 3, pp. 648-655, 3 2020.
- [13] P. Lunde, A. Bye, A. Bergland y B. B. Nilsson, «Effects of individualized follow-up with a smartphone-application after cardiac rehabilitation: Protocol of a randomized controlled trial,» *BMC Sports Science, Medicine and Rehabilitation*, vol. 11, n° 1, 11 2019.
- [14] A. Lauraitis, R. Maskeliunas, R. Damasevicius, D. Polap y M. Wozniak, «A Smartphone Application for Automated Decision Support in Cognitive Task Based Evaluation of Central Nervous System Motor Disorders,» *IEEE Journal of Biomedical and Health Informatics*, vol. 23, n° 5, pp. 1865-1876, 9 2019.
- [15] L. J. B. Andrews, L. Raja y S. Shanmugasundaram, «Mobile android-based remote patient monitoring system through wearable sensors,» *Journal of Discrete Mathematical Sciences and Cryptography*, vol. 22, n° 4, pp. 557-568, 5 2019.