




System to reduce the rate of patients not-adherence to medical treatment for diabetes using Machine Learning


Nicole Vasquez Silva¹; Joao Arroyo Solis²; Esther Aliaga Cerna³


^{1,2,3}Peruvian University of Applied Sciences, Perú, u201815508@upc.edu.pe, u201619716@upc.edu.pe, pcsieali@upc.edu.pe

Abstract - Measuring adherence to medical treatment in diabetic patients can be a costly and time-consuming process, with commonly used methods including pill counts, self-report questionnaires, and daily reminder phone calls. Based on this, we propose a mobile system that utilizes a supervised predictive Machine Learning algorithm. This system reduces the analysis period while identifying the probability of non-compliance with medical treatment. Furthermore, it permits physicians to monitor and control their patients conveniently and intuitively. Our proposal underwent validation with diabetes care and prevention experts, as well as patients. The study findings indicated that 72% of adult diabetes patients were able to enhance their adherence to prescribed treatments through utilizing the mobile application.




Keywords— *mobile solutions, machine learning, android, adherence, diabetes, endocrinology, and health.*

¹ <https://orcid.org/0000-0002-9194-8117>

² <https://orcid.org/0000-0001-5985-1449>

³ <https://orcid.org/0000-0002-9906-2943>

Sistema para reducir la tasa de pacientes no adheridos al tratamiento médico de la diabetes usando Machine Learning

Nicole Vasquez Silva⁴; Joao Arroyo Solis⁵; Esther Aliaga Cerna⁶

^{1,2,3}Peruvian University of Applied Sciences, Perú, u201815508@upc.edu.pe, u201619716@upc.edu.pe, pcsieali@upc.edu.pe

Resumen— *Las formas más comunes para medir el cumplimiento al tratamiento médico en pacientes diabéticos conllevan gran esfuerzo de costo y tiempo en la recolección de datos y obtención de resultados, las más comunes son conteo de píldoras, cuestionarios de autoinformes y recordatorios diarios por llamadas telefónicas. En base a esto, se propone un sistema móvil basado en un algoritmo predictivo supervisado de Machine Learning, el cual reduce la duración del análisis e identifica el riesgo de no cumplimiento al tratamiento médico; asimismo, permite al médico llevar un control y seguimiento más exacto e intuitivo de sus pacientes. La validación de nuestra propuesta se realizó con médicos especialistas en el cuidado y prevención de la diabetes y pacientes. Los resultados mostraron que el 72 % de pacientes adultos con diabetes pueden mejorar su adhesión con la aplicación.*

Palabras Claves—*Solución Móvil, Machine Learning, Android, Adherencia, Diabetes, Endocrinología, MHealth.*

I. INTRODUCCIÓN

Debido al incremento del 20% de la población diabética en el Perú, el sector salud viene impulsando el crecimiento de herramientas de control y seguimiento con el uso de la información proporcionada por el paciente para cubrir la baja tasa de adherencia al tratamiento médico diabético en pacientes adultos [1]. Por esta razón, los datos obtenidos son recolectados gracias a modelos de autoinforme, como el de Morisky Gren - 8, que facilita la identificación del estado de cumplimiento de la medicación en el tratamiento diabético. Asimismo, el proceso de la recolección y análisis de los datos implica un gran esfuerzo y tiempo para la obtención de resultados, lo cual conlleva a que este proceso se dificulte, ya sea por la falta de personal que apoye en las actividades de medición de la adherencia o por la cantidad de pacientes que atiende un especialista a lo largo del día.

El uso de tecnologías móviles en el monitoreo y seguimiento del tratamiento diabético aportan precisión en la recolección de datos. Estos sistemas ayudan a la población en la interpretación del estado médico, así también la simplificación en el análisis y reducción del tiempo en la consulta del paciente. Además, el control de la adherencia permite reducir la probabilidad de abandono al tratamiento médico, pues en el Perú, según el Acta Médica Peruana, solo el 38% de pacientes diabéticos cumple correctamente su prescripción médica [2]. Estas condiciones producen predicciones más valiosas para el análisis de resultado, pues se personaliza y se toma en cuenta los valores reales del cumplimiento.

Más aún, el análisis de resultados se vuelve un problema difícil cuando el paciente no tiene una relación cercana con su

médico, lo que resulta en una inexacta precisión de recopilación de información. Además, los modelos actuales se basan en cuestionarios enfocados en el consumo de medicamentos, así como a la psicología del paciente, es decir no abarca todas las actividades que involucra su control médico, como las de alimentación, actividad física y periodicidad de los exámenes. Por lo general, los autoinformes son difíciles de medir, debido a que este proceso se realiza con preguntas cualitativas de sí y no, lo que dificulta la correcta interpretación y está sujeto a la respuesta del paciente, sin estar completamente seguros [3].


Existen soluciones que proponen diferentes técnicas para monitorear y controlar el cumplimiento al tratamiento de la diabetes, las más comunes que basan en notificaciones o recordatorios [4], conteo de píldoras [5] y mensajes personalizados de motivación [6]. Aunque muchas de estas soluciones lograron una mejora en el cumplimiento del tratamiento, en su mayoría no son capaces de predecir el riesgo de abandono al tratamiento que tiene un paciente, dado que solo se enfocan en el cumplimiento rutinario. Por otro lado, las soluciones que utilizan modelos de aprendizaje automático supervisado solo se enfocan en la evolución y predicción de la enfermedad y no en la adherencia de paciente [7].


Para superar este problema, usamos un modelo de Random Forest, en TensorFlow, llamado Decision Forest con el fin de predecir el riesgo de abandono al tratamiento en pacientes diabéticos, este modelo es consumido por un API dentro de una aplicación móvil desarrollada en Flutter que brinda mayor usabilidad y obtención de datos en los hábitos del paciente. Nuestro trabajo se enfoca en la recolección de datos rutinarios declarados por el paciente y asociados a la adherencia a sus actividades prescritas por el médico, con esta información la aplicación utiliza el modelo Decision Forest previamente entrenado para la predicción del posible riesgo de deserción al tratamiento, utilizamos el servicio de Firebase para facilitar la adaptabilidad y eficiencia del Back-end en dispositivos móviles.

Nuestras principales contribuciones se basan en:

- Desarrollar una aplicación nativa para Android usando el Framework de Flutter.
- Construir un modelo predictivo con el algoritmo Random Forest para la predicción del riesgo de abandono al tratamiento médico que toma como base el modelo de auto informe de Morisky-Green.

⁴  <https://orcid.org/0000-0002-9194-8117>

⁵  <https://orcid.org/0000-0001-5985-1449>

⁶  <https://orcid.org/0000-0002-9906-2943>

- Presentar un análisis sobre el tratamiento, adherencia y cumplimiento de la diabetes respecto a la usabilidad de tecnologías no invasivas.

Este artículo está organizado de la siguiente forma: la Sección II describe la literatura relacionada a las tecnologías móviles, variables de la adherencia y el uso de modelos de Machine Learning en la salud. La Sección III muestra el aporte de la construcción del modelo predictivo que consume la aplicación móvil. La sección IV evalúa con expertos relacionados al problema la factibilidad de nuestro enfoque. Finalmente se describen las principales conclusiones alcanzadas.

II. LITERATURA RELACIONADA

La recopilación de información médica por algoritmos predictivos presenta diferentes desafíos para el cálculo e interpretación final de los resultados. Estos problemas incluyen, el gran esfuerzo y tiempo en el análisis de resultados, la buena relación con su médico, el abandono de su tratamiento, entre otros. En la siguiente sección, se presentan las variables asociadas a la adherencia, las tecnologías móviles similares y el uso de modelos de Machine Learning.

A. Variables asociadas a la adherencia

Un artículo de salud pública demostró la relación que existe entre la calidad de vida y la adherencia asociada al tratamiento frente variables demográficas asociadas a los pacientes. Para el estudio se evaluó a través de la encuesta Morisky-Green a 100 pacientes diabéticos con tres variables importantes: nivel de educación, sexo y edad. Los resultados señalaron que el 65% de pacientes con deficiencia en adherirse al tratamiento fueron mujeres, mayores de 45 años, con estudios secundarios, asimismo, el riesgo general de abandonar el tratamiento se debe al analfabetismo sobre la enfermedad padecida por el paciente [8].

Además, un análisis de la revista Medicina de Familia – SEMERGEN, menciona en el artículo “Adherencia a un estilo de vida saludable en pacientes con diabetes mellitus tipo 2 en España” que menos de la cuarta parte de los pacientes diabéticos de una muestra de 415 pacientes sigue una adecuada alimentación y actividad física favorable asociada a su enfermedad. Los resultados demostraron que los pacientes que no realizan actividades físicas o una adecuada alimentación cuentan con un bajo control de su enfermedad y alto riesgo de abandonar su tratamiento [9].

B. Modelos de Machine Learning y su aporte en la salud

Un estudio analizó la previsibilidad de la adherencia a la medicación que se centra en factores que utilizan la asistencia sanitaria en escenarios predictivos para identificar a pacientes que no cumplen con su tratamiento. Este experimento se desarrolló en pacientes de entre 40 y 70 años, como conclusión se demostró que la información histórica mejora la predicción de cambios repentinos en la adherencia, pues se analiza longitudinalmente la adherencia y el entrenamiento de modelos al utilizar información de comportamientos anteriores [10].

Según un estudio transversal que reclutó a 446 pacientes para medir la adherencia a la medicación, el estado emocional, creencias y medicaciones, forman parte de los cuatro

principales factores de riesgo asociados con la disminución de adherencia. En el artículo comparan 3 modelos de aprendizaje automático donde señalan que, la educación, la angustia psicológica, las creencias y el conocimiento sobre la medicación están correlacionados en mayor impacto a la adherencia en pacientes que padecen una enfermedad crónica [11].

C. Tecnologías móviles para el seguimiento y control de diabetes

Diversas soluciones para el control y seguimiento de la adherencia han sido desarrolladas y clasificadas dentro del término *MHealth*. Un estudio reciente demostró un mejor cumplimiento en la medicación del tratamiento diabético a través de una aplicación con recordatorios diarios instalado en el teléfono del paciente. La aplicación móvil fue utilizada por 75 pacientes diabéticos, donde el 73% mejoró de forma significativa el consumo diario de sus medicamentos. Las alertas fueron enviadas con una frecuencia diaria por la tarde y si era necesario reprogramadas por el usuario. Asimismo, los datos de la medicación eran guardado en la misma aplicación y visualizados por el paciente [12].

Por otro lado, el artículo “Teléfonos inteligentes y aplicaciones para controlar el nivel de hemoglobina glicosilada (HbA1c) en la diabetes” demostró que el uso de tecnologías móviles mejora directamente el cumplimiento y regulación de los niveles de glucosa óptimo que debe tener un paciente diabético. Fueron 998 pacientes participantes divididos en dos grupos, el grupo control conformado por 454 participantes y el grupo experimental conformado por 545 pacientes. El grupo experimental evaluó constantemente 10 soluciones asociadas al control y monitoreo de la glucosa, los resultados mostraron que el grupo experimental mejoró o mantuvo estable sus niveles de glucosa durante el monitoreo constante y uso de las soluciones móviles; a diferencia del grupo de control, donde sus niveles de glucosa disminuyeron notoriamente ($0,10 \pm 126$ ml/dl vs $0,10 \pm 145$ ml/dl) [13].

Asimismo, el estudio “Desarrollo y evaluación de una intervención de salud móvil personalizada para mejorar la adherencia en pacientes con diabetes tipo 2” tiene como objetivo el desarrollo y evaluación de aceptabilidad y eficacia preliminar de una intervención personalizada de cumplimiento de *mHealth* y el control de atención (AC) sobre las rutinas del paciente, como el cumplimiento de la medicación, la presión arterial sistólica (PAS), la presión arterial diastólica (PAD) y la hemoglobina A 1c (HbA 1c), con un periodo de 3 meses en 42 pacientes que inicialmente no cumplieron con su tratamiento médico para dividirse en 2 fases, una formativa que recopila información cualitativamente y otra de eficacia clínica con el apoyo de un dispositivo móvil (*MHealth*) para personalizar el tratamiento de los pacientes y evidenciar la aceptación y mejora de resultado clínico de la intervención personalizada de pacientes con Hipertensión arterial (HTA) no controlada y Diabetes tipo 2 (DT2) que inicialmente no cumplieron con sus tratamientos.

III. APORTE

A. Algoritmo de Machine Learning (Random Forest)

La elección del modelo Random Forest se basó en sus ventajas frente a otros modelos de Machine Learning supervisados. Este algoritmo es especialmente robusto en la gestión de *datasets* con un número limitado de muestras y

múltiples variables, como es el caso del presente estudio. Además, Random Forest permite identificar la importancia de cada variable en el proceso de predicción, lo que facilita la interpretación clínica de los factores que influyen en la adherencia al tratamiento. A diferencia de otros modelos como SVM o redes neuronales, Random Forest reduce significativamente el riesgo de sobreajuste y ofrece un buen equilibrio entre precisión y simplicidad en la implementación, aspectos clave para la integración en sistemas móviles de apoyo médico.

Asimismo, el modelo Random Forest utiliza la librería de TensorFlow: Decision Forest y usa variables demográficas y el resultado de las preguntas del cuestionario Morisky-Green para predecir el riesgo de abandono al tratamiento. El desarrollo del modelo presentó 3 fases de implementación definidas como: obtención y análisis, creación y pruebas de validación.

1) Obtención y Análisis

Se adaptó el dataset del artículo científico “Datos para: Conglomerados de no adherencia a la medicación en pacientes neurológicos” [13] que contenía datos del cuestionario SAMS (Stendal Adherence to Medication Score) relacionado a la medición de la adherencia de las enfermedades crónicas. El dataset que posee una muestra de 429 pacientes fue modificado y ajustado al cuestionario Morisky-Green con 8 preguntas que determinan el nivel de Tendencia a adherirse. Asimismo, se utilizó la plataforma Google Colab para el análisis de los datos obtenidos, donde la tendencia que muestra el dataset es 71% de información pertenecen a hombres universitarios en su mayoría casados con tendencia a no adherirse al tratamiento médico y 29% de mujeres con secundaria completa viudas o divorciadas con tendencia a adherirse. Los resultados obtenidos se observan con mayor detalle dentro de la tabla 1.

TABLA I
ANÁLISIS DEL DATASET STENDAL ADHERENCE TO MEDICATION

Análisis del Dataset ajustado				
Genero	Estado Civil	Educación	Tendencia a no Adherirse	Tendencia a adherirse
hombre	casado	universitaria	20%	18%
		secundaria	15%	11%
		primaria	12%	8%
	soltero	universitaria	2%	2%
		secundaria	7%	4%
		primaria	3%	4%
	viudo o divorciado	universitaria	8%	3%
		secundaria	2%	2%
		primaria	2%	1%
mujer	casado	universitaria	3%	8%
		secundaria	5%	17%
		primaria	2%	5%
	soltero	universitaria	0%	2%
		secundaria	7%	3%
		primaria	0%	1%
	viudo o divorciado	universitaria	2%	2%
		secundaria	8%	4%
		primaria	2%	6%

2) Creación

Se utilizó Google Colab, una herramienta utilizada por científicos de datos para la creación del modelo de ML y se procedió a descargar e instalar librerías derivadas de TensorFlow, con el nombre de “Tensorflow Decision Forest”. En primer lugar, se importaron librerías de Python necesarias como Tensorflow y Keras, que se dedican a crear modelos de redes neuronales. También, una sub-librería llamada Decision Forest y Pandas para el manejo de los dataframes y “Sklearn Metrics” para la evaluación del modelo. Los datos del dataset se recogieron desde el repositorio de GitHub para la creación y entrenamiento. Se utilizaron las columnas: “age”, “sex”, “marital status”, “Education”, “Medication preparation by” y “medication (cantidad)”, “SAMS_item1”, “SAMS_item3”, “SAMS_item6”, “SAMS_item10”, “SAMS_item11”, “SAMS_item15”, “SAMS_item16”, “SAMS_item17”, “SAMS_item19”.

Luego, se realizó una sumatoria del autoinforme para calcular el porcentaje adherente de cada fila con la siguiente formula:

$$\% \text{ Adherente} = 1 - \frac{\text{Suma de SAMS de cada fila}}{36}$$

Asimismo, se implementó una nueva fila, con la peculiaridad de que si el “% Adherente” es mayor a 80 (80%), la columna indicará el valor de uno (“1”), caso contrario es cero (“0”). Después, se dividió en 2 grandes grupos de datos, con un porcentaje de setenta (70%) para el entrenamiento del modelo y el resto (30%) para las pruebas o bien llamados “tests”. Gracias al modelo entrenado, se recopiló una serie de árboles aleatorios capaces de predecir el nivel porcentaje de adherencia con la creación de 300 árboles de decisiones. En la figura 1 se observa la clasificación del algoritmo según los árboles creados, el algoritmo usa como variables principales: la edad, las preguntas de la encuesta y la medicación diaria del paciente.

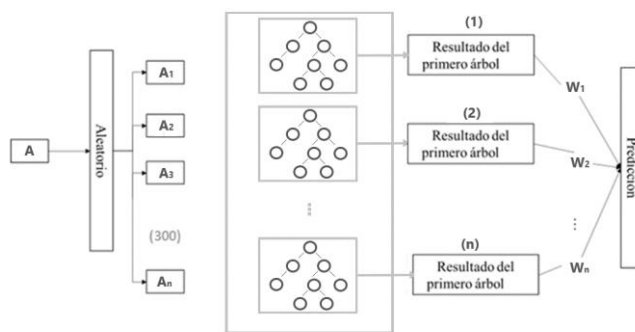


Fig. 1. Representación gráfica del algoritmo Random Forest

El algoritmo toma como referencia la tabla 2 que donde se muestran las posibles variables y las clasifica según el árbol a que pertenecen.

TABLA II
CLASIFICACIÓN DEL ALGORITMO

Variable	Combinación	Importancia de la variable	Nº Inicio	Nº nodo
medication_preparation_by	conectado	4.248712	0	0

__LABEL	0>= & <=1	4.248712	0	0
marital_status	soltero, casado, viudo o divorciado	4.157069	0	67
sex	hombre, mujer	4.139139	0	53
Education	primaria secundaria universidad o técnica (completa e incompleta)	3.959038	0	228
medication	0>=	3.871256	0	276
age	18>=	3.84566	1	320
SAMS_item19	0>= & <=4	3.751805	6	155
SAMS_item10	0>= & <=4	3.669164	15	78
SAMS_item6	0>= & <=4	3.433958	7	256
SAMS_item17	0>= & <=4	3.330655	36	151
SAMS_item1	0>= & <=4	3.101281	8	328
SAMS_item3	0>= & <=4	2.986477	12	351
SAMS_item11	0>= & <=4	2.920591	55	250
SAMS_item15	0>= & <=4	2.526133	65	375
SAMS_item16	0>= & <=4	2.086105	0	447

3) Pruebas de validación

Por último, los resultados obtenidos que demuestran la efectividad del algoritmo son plasmados en 3 indicadores importantes de gran relevancia, como el AUC (Area under the ROC Curve), la matriz de confusión y de precisión. Con ayuda de librerías como Sklearn en Python se encontraron métodos simples que ayudan a evaluar y mostrar cada uno de estos indicadores, dentro de la investigación se utilizaron funciones como: AUC (false_positive_rate, true_positive_rate, true_positive_rate), confusion_matrix (y_test, y_pred), compile (metrics=[accuracy]).

Estos indicadores se utilizaron pues permiten verificar la cantidad de falsos positivos, errores, aciertos y precisión que tiene nuestro algoritmo con la data de entrenamiento que se utilizó. Las funciones antes mencionadas mostraron un 94% de precisión del algoritmo, así como un matriz de confusión que muestra al 98% de casos acertados con tendencia a adherirse y el 67% de casos acertados con tendencia a no adherirse, en la figura 2 observa la matriz de función y en la figura 2 la curva AUC graficada.





Fig. 2. Métricas de elaboración del algoritmo de predicción de riesgo de abandono.

B. Sistema de seguimiento y control para la predicción del riesgo de abandono

La implementación y despliegue de la construcción del sistema se compone de 4 fases.

1) Diseño

El diseño de la arquitectura se basa en una arquitectura lógica que permite la visualización de la relación de cada uno de los componentes (lógicos, visuales y de almacenamiento). En la figura 3, la arquitectura lógica propuesta se encuentra compuesta por cinco capas que reflejan el flujo de datos desde la capa de usuario hasta el procesamiento de los datos y la predicción dentro del servidor del algoritmo.

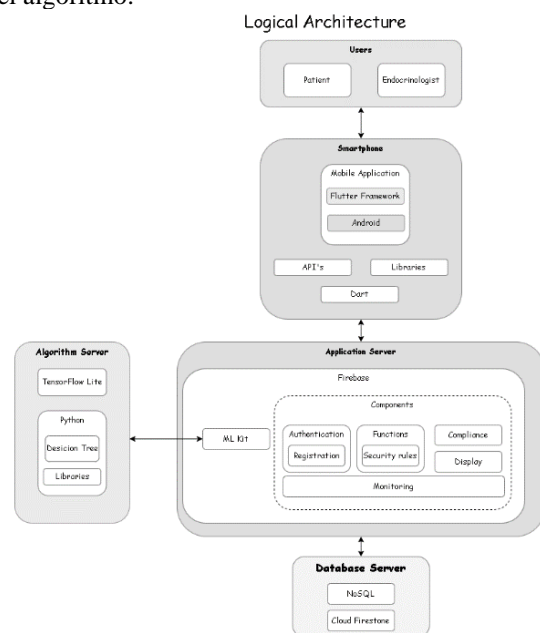


Fig. 3. Arquitectura lógica de la propuesta, Elaboración Propia

2) Software

Utilizamos tecnologías y herramientas definidas como: Android Studio, Firebase (servicios), Flutter, Dart, Python, TensorFlow (librería y servicios), Google Colab, que permitieron el seguimiento, control y predicción del riesgo de abandono al tratamiento. Asimismo, los servicios de Firebase nos permitieron realizar notificaciones personalizadas según

el usuario. Al nivel de implementación, la aplicación cuenta con 4 módulos dentro del desarrollo: model, common, main y screens.

3) *Almacenamiento de datos*

Se utilizó el servicio de Cloud Firestore brindado por Firebase para el manejo de los datos y la información de los usuarios (médicos y pacientes), este servicio se encuentra en la nube y permite el intercambio de información las 24h, asimismo, si se desea realizar importación o exportación de datos el servicio proporciona un entorno de administración de datos llamado Google Cloud. Además, Firebase protege la información de los datos de los pacientes, la clínica y el médico, a través de la encriptación cumple con el reglamento de la protección de datos (GDPR) de la UE.

4) *Visualización de datos*

La aplicación fue exportada a un paquete para el sistema operativo Android de extensión .apk para las pruebas y validación del funcionamiento. En ambos roles se les muestra una vista a través de dashboard resumidos con la información necesaria para la mitigación y fácil identificación del riesgo de abandono del paciente frente a su tratamiento de diabetes. Asimismo, el médico para iniciar la consulta debe crear previas prescripciones a los pacientes vinculados con el fin de obtener datos de los hábitos diarios de estos mismos basados en el seguimiento y control continuo de su médico. Esta información e indicadores son mostrados en tiempo real.

C. *Consumo del modelo dentro de la aplicación*

1) *TF Serving*

Se utilizó TensorFlow Serving, el cual pertenece a TF (TensorFlow), y es el que permite la incorporación de los datos, la limpieza, la creación del modelo y el despliegue de forma automatizada, con el nombre de pipeline. En otras palabras, TensorFlow Serving es un servidor que acepta y responde peticiones, del modo tradicional, On-Premises o Cloud con la capacidad de contener archivos necesarios para el levantamiento de un servidor en una Virtual Machine, puesto que TensorFlow-Serving no soporta TensorFlow de manera nativa y es necesario compilar TensorFlow-Serving desde la fuente de código. Por ese motivo, se descargó el modelo desde el entorno de Google Collaboratory (Colab), para ello se utilizó la función model.save, el cual guarda el modelo en la siguiente dirección ("/tmp/my_saved_model").

Para el entorno físico utilizamos un servidor virtual para levantar el servicio de TensorFlow Serving, el servicio usado AWS. Se instanció una máquina EC2 – Ubuntu para alojar el servidor ya descrito y post-consumo de este.

2) *Consumo del API*

Utilizamos *postman* para realizan las pruebas de consumo en una consulta Json (input) a recibir una respuesta (Output) que está interpretada como la predicción del % de riesgo de no-adherencia al tratamiento.

a) *Variables*

Las variables en Json que se deben enviar a la máquina virtual son: "Medication preparation by" y "medication", "SAMS_item1", "SAMS_item3", "marital status", "SAMS_item6", "SAMS_item10",

"age", "sex", "SAMS_item11", "SAMS_item15", "SAMS_item16", "Education", "SAMS_17", "SAMS_item19" y el resultado definido como: Predictions {valor de 0-1}.

Con la implementación de la aplicación, creación del algoritmo y consumo de este, el proyecto pasa a una fase de validación y experimentación.

IV. EXPERIMENTO Y VALIDACIÓN

A. *Método*

Para validar la efectividad de nuestra propuesta fue necesario el despliegue y uso de la aplicación por usuarios especialistas en la diabetes. Los participantes fueron divididos en dos grupos: pacientes y médicos endocrinólogos/nutricionistas. El primer grupo consta de 6 adultos de 40 años a más diagnosticados con diabetes, el segundo grupo conformado por 6 de endocrinólogos/nutricionistas especialistas en el tratamiento diabético y que poseen una relación paciente-médico con el primer grupo. La duración de la validación fue de 7 días calendarios en donde Los involucrados dieron su consentimiento informado. Se conto con dos (2) canales de contacto, las cuales fueron presenciales y virtuales para la interacción con cada uno de los grupos de usuarios. Todos los participantes manifestaron su consentimiento informado para el manejo de su enfermedad, tratamiento médico e información.

B. *Capacitación*

Para ambos grupos se realizó una capacitación e inepción previa sobre la funcionalidad de la aplicación. A todos los usuarios se les brindó una explicación general del proyecto y del funcionamiento de la aplicación según su rol. Asimismo, fue necesario explicar a los pacientes el uso de una conexión a internet estable en toda la validación con el fin de garantizar una mejor experiencia.

C. *Validación*

La validación de la propuesta consistió en: el seguimiento del control adherente continuo del paciente mediante la aplicación. Los usuarios de ambos grupos se creaban una cuenta dentro de la aplicación y según su grupo se realizaba la vinculación con el fin de compartir información del control y seguimiento del tratamiento médico de la diabetes del paciente. Asimismo, los médicos especialistas observaban el porcentaje de riesgo al abandono e identificar las actividades menos adherentes en los pacientes. Al finalizar la validación, se realizó una encuesta para ambos grupos con el fin de medir la satisfacción y funcionalidad de la aplicación, esta encuesta estuvo basada en la escala de Likert, donde 1 es "totalmente en desacuerdo" y 5 "totalmente de acuerdo". En la tabla 3 se muestran los resultados de la encuesta para ambos grupos.

Por otro lado, como se muestra en la figura 4, los resultados demuestran una mejora en los niveles de adherencia de los pacientes. En los primeros días se registran niveles de 63% mientras que en los últimos días niveles de 73%. Posteriormente, los pacientes y especialistas indican que el 43% se encuentra totalmente de acuerdo que los

indicadores mostrados dentro de la aplicación les permiten mitigar el riesgo de abandonar su tratamiento.

Tabla III
RESULTADOS GENERALES DE LA VALIDACIÓN

Atributo	Escala				
	Totalmente de acuerdo (5)	De acuerdo (4)	Ni de acuerdo, ni en desacuerdo (3)	En desacuerdo (2)	Totalmente en desacuerdo (1)
Tiempo de respuesta	86%	14%	0%	0%	0%
Fiabilidad	43%	52%	5%	0%	0%
Seguridad	57%	29%	10%	4%	0%
Usabilidad	50%	36%	14%	0%	0%
Funcionalidad	43%	43%	14%	0%	0%
Satisfacción General de la experiencia	75%	25%	0%	0%	0%

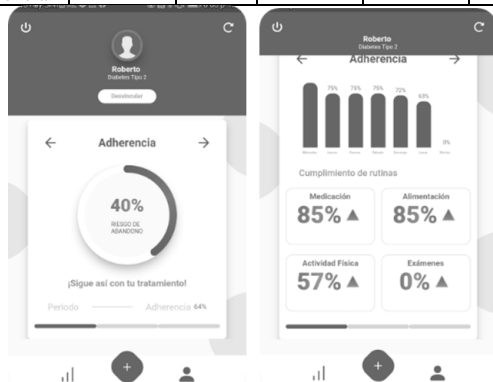


Fig. 4. Indicadores dentro de la aplicación.

CONCLUSIONES

La propuesta presentada soporta una aplicación móvil y un algoritmo que usa Machine Learning para la predicción del riesgo de abandono en paciente no-adheridos al tratamiento médico de la diabetes basado en variables cualitativas y cuantitativas en adultos mayores de 40 años. Por medio de la aplicación móvil, el paciente y el médico especialista comparten información referente a las actividades habituales que realiza el paciente a lo largo de la enfermedad, esto con el fin de mitigar el posible abandono al tratamiento y la mejorar en la comunicación bidireccional paciente-médico en las consultas. Los resultados demuestran que la adherencia de los pacientes mejora a través del constante monitoreo y control del especialista y los indicadores dentro de la aplicación en tiempo real.

La propuesta presentada contiene información relevante con el fin de ser usada en posteriores investigaciones sobre enfermedades crónicas e incluso servir como soporte en hospitales o centros médicos públicos, donde la comunicación y el monitoreo es precario.

Durante la fase de validación, el modelo identificó niveles de riesgo de abandono al tratamiento que variaron entre un 25% y un 65% según los hábitos reportados por los pacientes. Esta información permitió a los especialistas enfocar sus intervenciones en aquellos casos con mayor

probabilidad de no adherencia, demostrando el valor del sistema como herramienta de soporte en la toma de decisiones médicas.

Entre las principales limitaciones de este estudio se encuentra el tamaño reducido de la muestra utilizada en la fase de validación, lo que impide generalizar completamente los resultados a una población más amplia. La validación se realizó con un grupo piloto de pacientes y especialistas, por lo que se recomienda realizar estudios adicionales con un mayor número de participantes y en diferentes contextos clínicos. Además, la adaptación del dataset original puede haber omitido variables específicas del tratamiento de la diabetes, lo cual debe ser considerado en futuras versiones del modelo.

REFERENCIAS

- [1] G. Vargas, L. Balvin, J. Marisol y F. Llanos, «Therapeutic adherence to Helicobacter pylori eradication treatment and its associated factors in a public hospital in Peru,» *Revista de Gastroenterología del Perú*, vol. 40, n° 3, pp. 1-9, Julio 2020.
- [2] J. Merino, L. Ruiz Burneo y A. Bernabé, «TYPE 2 DIABETES MELLITUS AND SLEEP CHARACTERISTICS: A POPULATION-BASED STUDY IN TUMBES, PERU,» *Revista Peruana de Medicina Experimental y Salud Publica*, vol. 39, n° 1, pp. 55 - 64, 2020.
- [3] T. Prell, J. Grosskreutz, S. Mendorf, G. H. Franke, O. W. Witte y A. Kunze, «Clusters of non-adherence to medication in neurological patients,» *Elsevier Inc.*, vol. 15, pp. 1419 - 1424, 2019.
- [4] G. Jimenez, E. Lum, Z. Huang, Y. L. Theng, B. Boehm y J. Car, «Reminders for medication adherence in Type 2 diabetes management apps,» *Journal of Pharmacy Practice and Research*, vol. 50, n° 1, pp. 78 - 81, 2020.
- [5] E. Niechciał, C. Acerini, S. Chiesa, T. Stevens, N. D. R, D. Daneman, J. Deanfield, T. Jones, F. Mahmud, S. Marshall, A. Neil y D. Dunger, «Medication adherence during adjunct therapy with statins and ACE inhibitors in adolescents with type 1 diabetes,» *Diabetes Care*, vol. 43, n° 3, pp. 1070 - 1076, 2020.
- [6] P. Zhai, K. Hayat, W. Ji, Q. Li, L. Shi, N. Atif, S. Xu, P. Li, Q. Du y Y. Fang, «Efficacy of text messaging and personal consultation by pharmacy students among adults with hypertension: Randomized controlled trial,» *Journal of Medical Internet Research*, vol. 22, n° 5, pp. 1-15, 2020.
- [7] L. Kopitar, P. Kocbek, L. Cilar, A. Sheikh y G. Stiglic, «Early detection of type 2 diabetes mellitus using machine learning-based prediction models,» *Scientific Reports*, vol. 10, n° 1, pp. 1-15, 2020.
- [8] G. Vargas, L. Balvin, J. Chaiña y F. Llanos, «Therapeutic adherence to Helicobacter pylori eradication treatment and its associated factors in a public hospital in Peru,» *NLM (Medline)*, vol. 40, pp. 224-229, 2020.
- [9] P. Unanua, A. Fernández, L. Simarro, S. Llorca, P. Martínez y M. Romero, «Adherence to healthy lifestyle

behaviours in patients with type 2 diabetes in Spain,»
Ediciones Doyma, S.L., vol. 47, pp. 161-169, 2021.

- [10] A. Galozy y S. Nowaczyk, «Prediction and pattern analysis of medication refill adherence through electronic health records and dispensation data,»
Academic Press Inc., Vols. %1 de %26-7, 2020.
- [11] J. Doupis, G. Festas, C. Tsilivigos, V. Efthymiou y A. Kokkinos, «Smartphone-Based Technology in Diabetes Management,» *Springer Publishing*, pp. 607-619, 2020.
- [12] J. Doupis, G. Festas, C. Tsilivigos, V. Efthymiou y A. Kokkinos, «Smartphone-Based Technology in Diabetes,» *Adis*, vol. 11, pp. 607-619, 2020.
- [13] M. Begoña, A. Velando, L. Pradas, N. Suleiman, G. Cañadas, L. Albendín y J. Gómez, «Smartphones and Apps to Control Glycosylated Hemoglobin (HbA1c) Level in Diabetes: A Systematic Review and Meta-Analysis,» *Journal of Clinical Medicine*, vol. 9.