

Tipo de artículo: Artículo original

Perfiles digitales para pacientes en tratamiento de rehabilitación por adicción a drogas en centros autorizados por CETAD y MSP

Digital profiles for patients in drug addiction rehabilitation treatment in centers authorized by CETAD and MSP

Francisco Gerardo Palacios Ortiz^{1*} , <https://orcid.org/0000-0003-3705-3862>

Cecilia Elizabeth Cabanilla Burgos² , <https://orcid.org/0009-0007-9360-8451>

Fabián Andrés Espinoza Bazán³ , <https://orcid.org/0000-0002-4487-0548>

Janeth Pilar Díaz Vera⁴ , <https://orcid.org/0000-0001-8750-0216>

¹ Docente, Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Física. Ecuador. francisco.palacios@ug.edu.ec

² Docente, Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Física. Ecuador. cecilia.cabanillac@ug.edu.ec

³ Docente, Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Física. Ecuador. fabian.espinozab@ug.edu.ec

⁴ Docente, Universidad de Guayaquil, Facultad de Ciencias Matemáticas y Física. Ecuador. janeth.diazv@ug.edu.ec

* Autor para correspondencia: francisco.palacios@ug.edu.ec

Resumen

Este proyecto de investigación, respaldado por el Fondo Competitivo de Investigación (FCI) de la Universidad de Guayaquil bajo el título "El Impacto de la Tecnología Interfaz Hombre-Máquina (BCI) para el Tratamiento de Adicciones", con código FCI-045-2023, se enfocó en el desarrollo de perfiles digitales para pacientes en rehabilitación por adicción a drogas. El objetivo principal fue establecer los parámetros necesarios para la creación de estos perfiles, con el fin de ofrecer tratamientos más personalizados y eficaces en los Centros Especializados en el Tratamiento de Adicciones (CETAD) autorizados por el Ministerio de Salud Pública (MSP). La metodología Waterfall se utilizó para recopilar y analizar datos sobre el progreso de los pacientes durante su tratamiento, permitiendo identificar patrones individuales que facilitaron la adaptación de los tratamientos a las características específicas de cada paciente y, de este modo, optimizar los resultados terapéuticos.

Palabras clave: tecnología; adicción; tratamiento personalizado; rehabilitación; CETAD; perfiles digitales.

Abstract

This research project, supported by the Competitive Research Fund (FCI) of the University of Guayaquil under the title "The Impact of Human-Machine Interface (BCI) Technology for the Treatment of Addictions", with code FCI-045-2023, focused on the development of digital profiles for patients in rehabilitation for drug addiction. The main objective was to establish the necessary parameters for the creation of these profiles, in order to offer more personalized and effective treatments in the Specialized Centers for the Treatment of Addictions (CETAD) authorized by the Ministry of Public Health (MSP). The Waterfall methodology was used to collect and analyze data on the progress of patients during their treatment, allowing the identification of individual patterns that facilitated the adaptation of treatments to the specific characteristics of each patient and, in this way, optimize therapeutic results.

Keywords: technology; addiction; personalized treatment; rehabilitation; CETAD; digital profiles.

Recibido: 14/08/2024



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional** (CC BY 4.0)

Aceptado: 20/10/2024
En línea: 28/10/2024

Introducción

La adicción a las drogas representa un grave problema de salud pública en Ecuador, con un impacto profundo tanto a nivel individual como social. Un aumento alarmante en el consumo de sustancias ilícitas, especialmente entre los jóvenes de 15 a 25 años, ha sido documentado en los últimos años, evidenciando la necesidad urgente de implementar estrategias de tratamiento más efectivas y adaptadas a las características particulares de cada paciente (INEC, 2023).

Los Centros Especializados en Tratamiento a Personas con Consumo Problemático de Alcohol y otras Drogas (CETAD), junto con el Ministerio de Salud Pública (MSP), han realizado esfuerzos considerables para mejorar las terapias de rehabilitación. Sin embargo, los enfoques tradicionales han mostrado limitaciones significativas para responder a las necesidades individuales, lo que a menudo disminuye la eficacia de los tratamientos (MSP, 2023). En este contexto, es fundamental desarrollar alternativas más personalizadas y adaptables, que consideren tanto las características biológicas, psicológicas y sociales de cada paciente para optimizar su proceso de recuperación.

Tabla 1. Comparativa Consumo de Drogas en Ecuador (2018-2023).

Año	Prevalencia del consumo de drogas (%)	Rango de edad más afectado	Comentarios
2018	12%	15-25 años	Crecimiento sostenido desde 2016
2019	13%	15-25 años	Campañas de prevención en auge
2020	14%	15-25 años	Impacto de la pandemia
2021	14.5%	15-25 años	Aumento de uso de sustancias
2022	15%	15-25 años	Mayor incidencia de zonas urbanas
2023	15.5%	15-25 años	Programas de tratamiento reforzado

Nota. Tomado de Instituto Nacional de Estadísticas y Censos (INEC 2023)

A pesar de los avances en los tratamientos de rehabilitación, persisten obstáculos importantes que impiden lograr una recuperación integral. Las drogas alteran el funcionamiento cerebral, afectando el sistema de recompensa y la capacidad de tomar decisiones, lo que perpetúa el ciclo adictivo (NIDA, 2022). Estas variaciones en la respuesta a los tratamientos tradicionales subrayan la necesidad de crear enfoques más personalizados para abordar esta compleja problemática.

Surge entonces la pregunta clave: ¿cómo podemos desarrollar y aplicar tratamientos personalizados basados en perfiles digitales que consideren las características biológicas, psicológicas y sociales de cada paciente, mejorando así



su recuperación y reduciendo las tasas de recaída? La presente investigación se enfoca en la creación de perfiles digitales que permitan a los profesionales de la salud personalizar los tratamientos según las necesidades específicas de los pacientes en rehabilitación en centros autorizados. Estos perfiles ayudarán a agrupar a los pacientes según patrones comunes, maximizando la eficacia de los tratamientos y promoviendo una recuperación sostenible.

Es fundamental reconocer los diversos factores que contribuyen a la adicción, como traumas previos, dificultades socioeconómicas, trastornos de salud mental no diagnosticados y la falta de apoyo familiar o comunitario. La complejidad de estas circunstancias exige un enfoque holístico que aborde tanto los aspectos físicos como psicológicos y sociales en los tratamientos de rehabilitación. Este estudio busca proporcionar una herramienta que permita comprender mejor las necesidades de los pacientes desde el inicio de su tratamiento hasta su evolución, agrupándolos para optimizar el tratamiento individual y asegurar una recuperación duradera.

El tratamiento de personas con adicciones requiere un enfoque individualizado, dado que cada paciente presenta una realidad distinta (Rojas, 2012). Este proyecto, por tanto, adopta una perspectiva integral y multifacética, incorporando nuevos hallazgos que aporten a una rehabilitación más efectiva y sostenible en el tiempo.

Análisis del contexto actual

La adicción a las drogas es un problema global de creciente preocupación que ha sido objeto de numerosos estudios e intervenciones. En Ecuador, la situación es especialmente alarmante. Según el Informe sobre el Consumo de Drogas en las Américas de 2019, publicado por la Organización de los Estados Americanos (OEA), el uso de drogas ilícitas en el país ha aumentado, con un incremento notable en el consumo de cocaína y marihuana entre los jóvenes (OEA, 2019). Ante esta realidad, el Ministerio de Salud Pública (MSP) ha implementado los Centros Especializados en Tratamiento a Personas con Consumo Problemático de Alcohol y otras Drogas (CETAD) para enfrentar este desafío.

Un estudio realizado por el MSP en 2020 reveló que el 35% de los pacientes que completaron programas de rehabilitación en los CETAD recaen en su adicción (MSP, 2023). Este índice elevado de recaídas pone de manifiesto la necesidad de desarrollar enfoques de tratamiento más personalizados y efectivos. La creación de perfiles digitales de los pacientes representa una solución innovadora que permitiría adaptar los tratamientos a las necesidades individuales, mejorando los resultados de la rehabilitación.

Investigaciones en otros contextos han demostrado la efectividad de los tratamientos personalizados. Un estudio del Instituto Nacional de Psiquiatría "Ramón de la Fuente Muñiz" en México evidenció que los programas de



rehabilitación que integran factores clínicos y sociales reducen las tasas de recaída en un 25% en comparación con los enfoques tradicionales (González, 2019). Este modelo podría servir como referencia para iniciativas en Ecuador.

Además, el uso de tecnologías emergentes, como las interfaces cerebro-computadora (BCI), ha mostrado ser prometedor en el tratamiento de adicciones. Según la Organización Mundial de la Salud (OMS), la implementación de tecnologías avanzadas puede aumentar la eficacia de los programas de rehabilitación en un 30% (OMS, 2021). La integración de BCI en los perfiles digitales de los pacientes es una innovación que este proyecto pretende explorar y desarrollar.

La personalización de los tratamientos también se puede beneficiar de algoritmos de aprendizaje automático, como los utilizados en agrupación y clasificación, que permiten identificar patrones y características comunes entre los pacientes. Esto facilita el diseño de terapias más ajustadas a las particularidades de cada individuo. Un estudio realizado por la Universidad de los Andes en Colombia confirmó que las intervenciones digitales personalizadas mejoraron significativamente la adherencia al tratamiento y redujeron las tasas de recaída en comparación con enfoques convencionales (Martínez, 2020).

Hernández y Martínez (2018) subrayaron la importancia de un enfoque multidisciplinario en la creación de perfiles digitales para el tratamiento de adicciones. Su investigación en México concluyó que la integración de aspectos físicos, psicológicos y sociales resulta en un tratamiento más efectivo y completo. Este enfoque holístico será clave en el diseño de perfiles digitales para el presente proyecto.

En este sentido, la creación de estos perfiles se basará en el uso de algoritmos de agrupación y clasificación que permiten personalizar las intervenciones terapéuticas de manera más precisa. Como señala Bishop (2006), "la agrupación y clasificación son esenciales para descubrir patrones y aplicar técnicas en datos clínicos complejos" (Bishop, 2006). Estos avances tecnológicos ofrecen una oportunidad para mejorar los tratamientos actuales y asegurar una rehabilitación más efectiva y sostenible para los pacientes en Ecuador.

El algoritmo K-means es ampliamente utilizado para agrupar datos en clústeres basados en la similitud de características. En el contexto de la rehabilitación, K-means puede agrupar pacientes según variables como tipo de adicción, duración del consumo y antecedentes sociales, facilitando la creación de perfiles específicos para cada grupo.



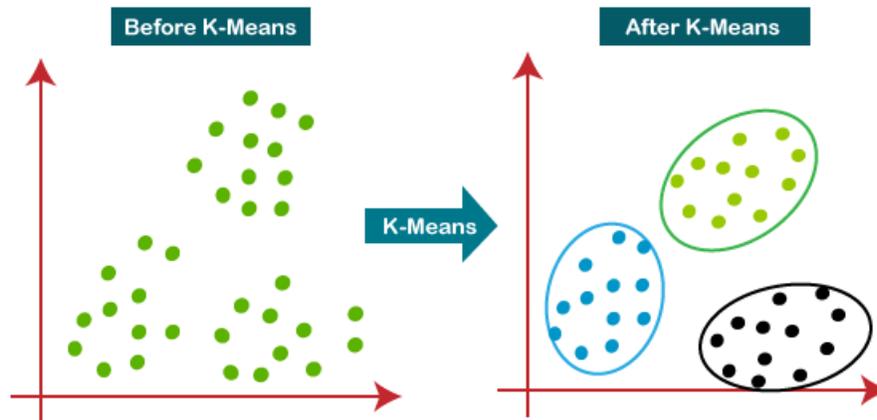


Figura 1. K-Means Clustering.

Nota: En esta figura se puede observar lo que significa clustering o agrupación de valores con similares características. Tomado de (Pranshu, 2024).

El Clustering Jerárquico organiza los datos en una estructura jerárquica, permitiendo identificar subgrupos dentro de una población. Este método es útil para descubrir subgrupos con diferentes niveles de riesgo o necesidades dentro de un grupo más amplio de pacientes.

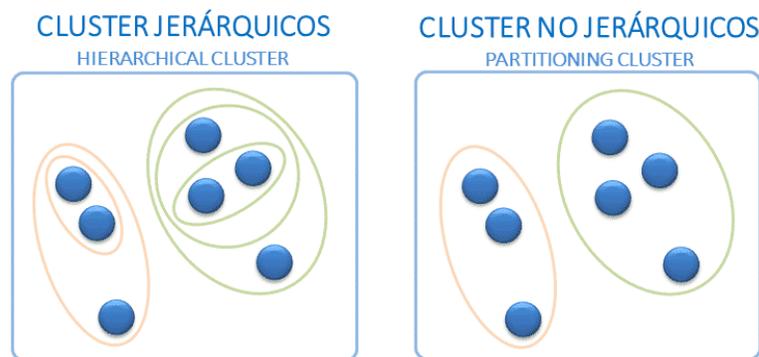


Figura 2. Clúster Jerárquicos y No Jerárquicos.

Nota. En la figura, se puede notar que el Jerárquico es el que se mezcla en pequeños grupos con otros puntos de muestra. Tomado (Calvo, 2018).

Análisis de Componentes Principales (PCA):

El PCA reduce la dimensionalidad de los datos, conservando las características más relevantes. En la creación de perfiles, PCA ayuda a identificar las variables que tienen mayor influencia en la clasificación de los pacientes.



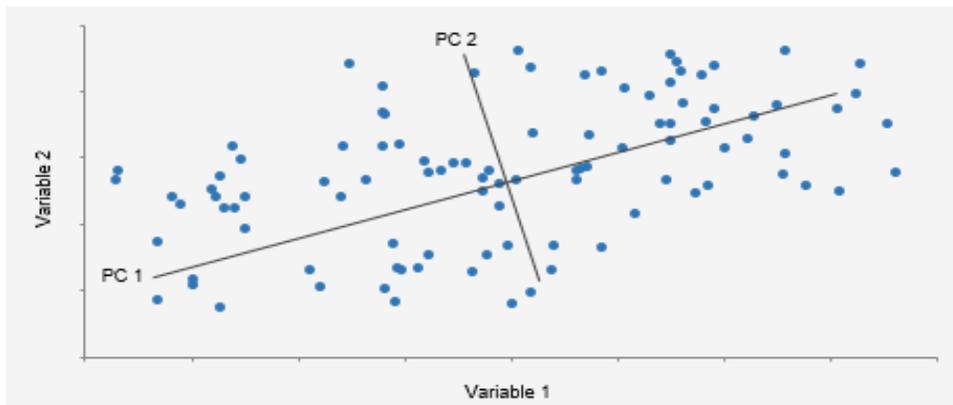


Figura 3. Análisis de Componentes Principales (PCA).

Nota. En esta figura se evidencia la separación de muestras por medio de los componentes en este caso vemos 2, PC1 y PC2. Tomado de (Entendidos, 2021)

El uso de estos algoritmos no es meramente teórico, ya que ha sido aplicado con éxito en estudios similares. Por ejemplo, un estudio realizado por Chekroud et al. (2016) utilizó técnicas de machine learning para predecir la respuesta al tratamiento antidepresivo en pacientes, agrupándolos en clústeres según sus características clínicas y demográficas. Este estudio demostró que la personalización del tratamiento basada en estos grupos mejoró significativamente los resultados terapéuticos (Chekroud et al. 2016).

Es crucial que el desarrollo de perfiles digitales cumpla con las normativas y estándares legales, especialmente en relación con la privacidad y seguridad de los datos. En Ecuador, la Ley Orgánica de Protección de Datos Personales (2021) establece los requisitos para la recolección, almacenamiento y tratamiento de datos personales, garantizando la privacidad y seguridad de la información de los pacientes (Ecuador, 2021).

A continuación, se presenta la Tabla 2, que muestra las cinco provincias de Ecuador con los mayores índices de consumo de drogas:

Tabla 2. Tabla de porcentaje de índice de consumo.

Provincia	Índice de Consumo (%)
Guayas	35%
Pichincha	30%
Manabí	25%
Los Ríos	20%
Esmeraldas	18%

Fuente: (MSP, porcentaje de índice de consumo, 2020)



Materiales y métodos

Para el desarrollo de este proyecto, se ha optado por la metodología Cascada (Waterfall) debido a su enfoque estructurado y secuencial. La metodología Waterfall es ideal para este trabajo porque facilita la definición y especificación detallada de los requisitos desde el inicio, permitiendo un proceso ordenado y bien planificado en cada etapa del desarrollo. Esta metodología asegura que cada fase del proyecto se complete antes de pasar a la siguiente, lo que proporciona claridad y organización en el desarrollo y garantiza que los requisitos del proyecto se gestionen de manera efectiva y meticulosa.

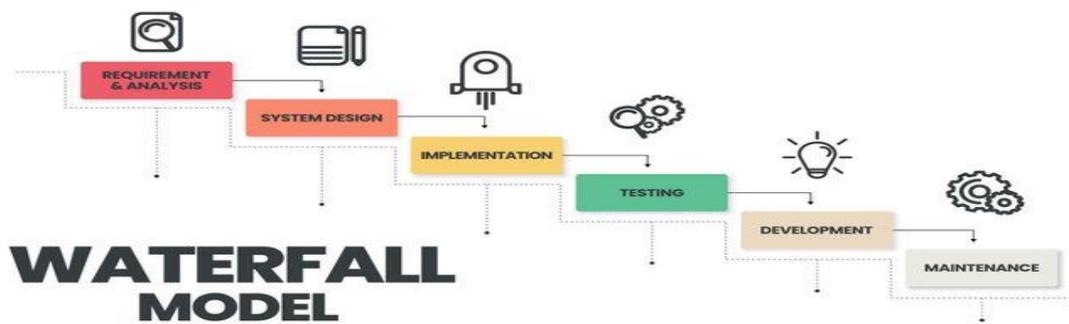


Figura 4. Metodología Waterfall.

Nota. Este gráfico representa la Metodología Waterfall que utilizaremos (Coworkingfy, 2023).

La naturaleza lineal de la metodología Cascada proporciona un entorno sencillo y práctico que facilita una planificación precisa y un control detallado en cada fase del proyecto. Este enfoque asegura que se cumplan los requisitos y especificaciones en cada etapa antes de proceder a la siguiente, minimizando los riesgos y garantizando que todos los aspectos críticos del proyecto sean abordados de manera ordenada y meticulosa. A continuación, se detallan las fases de la metodología Cascada que se implementarán en el proyecto de creación de perfiles digitales para pacientes en rehabilitación:

Recopilación de requisitos

En esta fase, se trabajó en la identificación de las variables que pueden ser útiles en este proyecto y que serán el fundamento para realizar el desarrollo de los perfiles digitales de los pacientes de los CETAD's. Se coordinaron reuniones y entrevistas con los especialistas para conocer mejor el proceso y el tratamiento de los pacientes que ingresan al CETAD, así como los indicadores actuales y las variables que forman parte del estudio. Para ello, se presenta a continuación los diferentes planes de visitas que se realizaron para obtener información relevante en este proceso:



Tabla 3. Cronograma de visitas al Centro de Rehabilitación.

Fecha de visita	Hora de visita	Actividad realizada
20/05/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2021
22/05/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2021
23/05/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2021
28/05/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2021
31/05/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2021
03/06/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2022
05/06/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2022
07/06/2024	11:00 - 14:30	Revisión de carpetas de pacientes del año 2022
12/06/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2022
13/06/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2023
18/06/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2023
20/06/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2023
24/06/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2023
27/06/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2024
02/07/2024	12:00 - 13:30	Revisión de carpetas de pacientes del año 2024

Fuente: Datos de la Investigación

Se separaron las carpetas de los pacientes que habían completado al menos seis meses de tratamiento para evaluar su desempeño durante el proceso, siguiendo cada una de las fases del tratamiento, que son:

Fase 1. Evaluación y Admisión: Un equipo de profesionales, incluyendo psicólogos y médicos, realiza una evaluación exhaustiva del paciente para determinar el nivel y tipo de adicción, así como su salud física y mental, y cualquier problema subyacente que pueda afectar el tratamiento. Con base en esta evaluación, se obtiene un panorama más claro del caso y, posteriormente, el paciente es admitido tras firmar un acuerdo de compromiso.

Fase 2. Abstinencia: Con una duración aproximada de dos semanas, esta fase se enfoca en el seguimiento del paciente, ya que el cuerpo puede presentar rechazos y otros efectos adversos debido a la desintoxicación. El paciente debe permanecer aislado de su entorno, ya que los individuos en esta etapa suelen presentar comportamientos manipuladores.

Fase 3. Adaptación: Durante esta fase, que sigue a la Fase 2, es esencial que el paciente se adapte al entorno del centro de rehabilitación. Se le familiariza con las instalaciones y las actividades del centro, incluyendo grupos de apoyo mutuo y sesiones de discusión, donde los pacientes pueden compartir sus experiencias y sentirse identificados con casos similares.

Fase 4. Rehabilitación Terapéutica: En un entorno controlado y seguro, los pacientes participan en terapias individuales y grupales. Estas incluyen psicoterapia, terapia cognitivo-conductual, terapia motivacional y terapia



familiar. También se realizan talleres artísticos y musicales que ayudan a desarrollar habilidades que los pacientes pueden compartir con otros.

Fase 5: Rehabilitación Física y Bienestar Integral: Se implementan programas de ejercicio, una nutrición adecuada, técnicas de manejo del estrés y actividades de bienestar como la meditación para mejorar la salud física y mental del paciente.

Fase 6: Reinserción Social y Prevención de Recaídas: A partir de los tres meses, se permite a los pacientes realizar visitas familiares durante dos días. Para prevenir recaídas, se llevan a cabo pruebas toxicológicas y se verifica el cumplimiento de las cláusulas del acuerdo firmado. Estas visitas pueden extenderse gradualmente hasta una semana fuera del centro si no se presentan problemas.

Fase 7: Seguimiento y Apoyo Continuo: Al finalizar el tratamiento, el paciente es entregado a su representante con el compromiso de continuar con la terapia y el apoyo a través de sesiones ambulatorias, grupos de apoyo y programas de seguimiento. La participación de la familia, amigos y otros grupos de apoyo es crucial para mantener la sobriedad a largo plazo.

Para la recolección de datos, se preparó una matriz en Excel con la información relevante de los pacientes, como edades, tipo de sustancia consumida y edad de inicio del consumo, entre otros. Estos datos fueron utilizados en el modelo de machine learning del proyecto, y se detallan en la Figura 5.

Nº	CETAD_ENCARGADO	TIEMPO_DE_TERMINO_EL REINGRESO	EDAD	PESO_EN_KG	ESTATURA	TEMPERATUI	ENFERMEDA	NIVEL_SOCIC	SITUACION	FECHA_DE_N_CON QUIEN	NUMERO_DE TIENE_P
1	Libertadores	Estuvo meñc No	Si	17	56	165	36 No	Pobreza < \$8	Estable	7/6/2004 Tios	6 Si
2	Libertadores	Estuvo meñc No	Si	17	56	165	36 No	Pobreza < \$8	Estable	7/6/2004 Tios	6 Si
3	Libertadores	Estuvo meñc Si	No	14	71	168	36 No	Pobreza Extr	Deprorable	28/10/2007 Solo	3 No
4	Libertadores	Cumplio ma\$ Si	No	17	56	162	36 No	Medio Bajo	\$ Estable	12/2/2004 Abuelos	2 Si
5	Libertadores	Cumplio ma\$ Si	No	18	70	161	38 No	Pobreza < \$8	Inestable	17/1/2003 Hermanos	3 No
6	Libertadores	Cumplio ma\$ Si	No	17	62	169	36 No	Pobreza < \$8	Inestable	24/8/2003 Hermanos	3 Si
7	Libertadores	Cumplio ma\$ Si	No	16	47	160	37 No	Medio Bajo	\$ Estable	13/9/2004 Ambos Padri	6 No
8	Libertadores	Mayor a 30 d Si	No	15	59	165	37 No	Pobreza < \$8	Inestable	29/9/2005 Mama	4 No
9	Libertadores	Estuvo meñc No	No	16	52	167	37 No	Pobreza < \$8	Inestable	18/10/2004 Papa	4 Si
10	Libertadores	Estuvo meñc No	Si	16	56	152	35 No	Pobreza < \$8	Inestable	5/7/2004 Mama	3 Si
11	Libertadores	Estuvo meñc No	No	17	68	178	36 No	Pobreza < \$8	Inestable	9/6/2003 Tios	3 Si
12	Libertadores	Mayor a 60 d No	No	17	54	165	36 No	Pobreza < \$8	Estable	2/6/2004 Mama	3 Si
13	Libertadores	Mayor a 60 d No	No	16	54	169	35 No	Pobreza < \$8	Inestable	13/12/2004 Ambos Padri	4 No
14	Libertadores	Cumplio ma\$ No	No	17	52	167	36 No	Pobreza < \$8	Estable	14/6/2003 Mama	2 Si
15	Libertadores	Estuvo meñc No	No	16	48	162	37 No	Pobreza < \$8	Estable	8/11/2005 Mama	2 Si
16	Libertadores	Estuvo meñc No	Si	15	62	166	36 No	Pobreza Extr	Deprorable	25/9/2005 En la calle	0 No
17	Libertadores	Estuvo meñc No	No	15	50	172	37 No	Pobreza < \$8	Estable	30/4/2006 Abuelos	0 Si
18	Libertadores	Estuvo meñc No	No	17	60	166	38 No	Pobreza < \$8	Inestable	1/8/2005 Abuelos	3 Si
19	Libertadores	Mayor a 60 d No	Si	14	54	166	37 No	Pobreza < \$8	Inestable	5/6/2008 Mama	7 Si
20	Libertadores	Estuvo meñc No	No	15	60	173	38 No	Pobreza < \$8	Estable	24/11/2006 Mama	5 Si
21	Libertadores	Mayor a 30 d No	No	17	70	159	37 No	Pobreza < \$8	Estable	22/8/2004 Ambos Padri	5 No

Figura 5. Base de registro de la información de cada paciente.

Fuente: Datos de la investigación



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional** (CC BY 4.0)

Con los datos recopilados, se generó el primer insumo para desarrollar los modelos de machine learning, utilizando técnicas de clasificación y agrupación, como el algoritmo K-means. Estos aspectos se abordarán con mayor detalle en la fase de Implementación.

Resultados y discusión

Análisis de datos

La fase de análisis es fundamental para este proyecto, puesto que, otorga los lineamientos de manera clara para determinar y discriminar de qué manera haremos uso y tratamiento de los datos, desde su etapa explorativa y preparativa, con la aplicación del modelo CRISP DM.

Modelo CRISP DM

La implementación sigue la metodología CRISP-DM, que ofrece un marco estructurado para la realización de proyectos de análisis de datos. A continuación, se describen las etapas específicas de CRISP-DM que fueron fundamentales en esta fase:

Entendimiento del Negocio (Business Understanding): En esta primera etapa, se realizó un análisis exhaustivo de los objetivos de los CETAD y del MSP en relación con el tratamiento de la adicción a las drogas. Se definieron claramente los objetivos específicos del proyecto, tales como la necesidad de crear los perfiles digitales ya que en base a estos podríamos verificar los patrones con más coincidencias entre los pacientes en rehabilitación para poder determinar las variables que predominan entre ellos.

- Reuniones con los administradores y profesionales de salud de los CETAD para comprender sus necesidades y expectativas.
- Solicitar los permisos necesarios para el uso y la manipulación de la información proporcionada por estos centros de rehabilitación.
- Establecer horarios de visitas para la recopilación de la información.

Entendimiento de los Datos (Data Understanding): Una vez que se comprendieron los objetivos, el siguiente paso fue identificar y familiarizarse con los datos disponibles. Se analizaron las fuentes de datos existentes en los CETAD, incluyendo historiales clínicos, datos demográficos de los pacientes, y registros de tratamiento en las carpetas que posee el CETAD.

- Revisión de las bases de datos actuales y otros registros manuales utilizados en los CETAD.



- Evaluación de la calidad de los datos disponibles y determinación de las variables relevantes para el proyecto.

Preparación de los Datos (Data Preparation): En esta etapa, los datos recolectados se organizaron y se ingresaron a una base de datos para su uso en el sistema de perfiles digitales. Se realizaron tareas de limpieza, como la eliminación de datos duplicados o inconsistentes, y se estructuraron los datos de manera que fueran adecuados para el modelado.

- Limpieza, estandarización y normalización de los datos, asegurando su consistencia, sin datos erróneos y exactitud.
- Selección de variables clave, como tipo de adicción, historial de tratamiento, tipo de drogas consumidas y factores sociodemográficos, que se utilizaron en el análisis y creación de perfiles.
- Se eliminaron varias columnas de las 130 que se hace mención en el anexo 1 quedando solo 103 también mencionadas en el anexo 2 ya que de las otras columnas faltaba información, no poseían data necesaria o relevante y también datos muy constantes.
- Se procedió a realizar un análisis estadístico básico. A continuación, se muestra el cálculo de la media, la desviación estándar y los cuartiles para las variables numéricas.

```
+ Código + Texto
Información general del dataframe:
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 87 entries, 0 to 86
Columns: 103 entries, NUM to TRATAMIENTOS_PREVIOS_EN_CENTROS_DIARIOS
dtypes: int64(10), object(93)
Memory usage: 70.1+ KB
None

Estadísticas descriptivas del dataframe:
count  NUM      EDAD  PESO_EN_KG  ESTATURA  TEMPERATURA  \
mean   44.000000  25.333333  63.551724  165.574713  36.712644
std    25.258662  12.010331  10.136004   5.879867   0.663115
min     1.000000  12.000000  43.000000  150.000000  34.000000
25%    22.500000  16.000000  55.000000  162.000000  36.000000
50%    44.000000  23.000000  62.000000  165.000000  37.000000
75%    65.500000  31.000000  70.000000  169.000000  37.000000
max    87.000000  74.000000  90.000000  189.000000  38.000000

count  NUMERO_DE_HERMANOS  COMIDAS_AL_DIA  EDAD_DE_INICIO_DE_RELACIONES  \
mean    2.183908          2.643678          13.609195
std     2.259495          0.714908          4.755306
min     0.000000          1.000000          0.000000
25%     0.000000          3.000000          13.000000
50%     2.000000          3.000000          14.000000
75%     3.000000          3.000000          16.000000
max    12.000000          3.000000          25.000000

count  CONSUMO_DESDE_QUE_EDAD  A_QUE_EDAD_PROBO_SU_PRIMER_VASO_DE_ALCOHOL
mean    14.597701              13.712644
std     3.718151              2.312293
min     9.000000              7.000000
25%    13.000000             12.000000
50%    14.000000             14.000000
75%    15.000000             15.000000
max    37.000000             22.000000
```

Figura 6. Cálculo de la media, desviación estándar y cuartiles.

Nota. Datos de la investigación analizados a través de Google colab, mediante el lenguaje de programación Python.



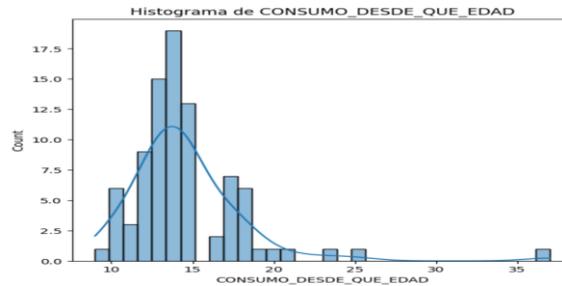


Figura 7. Histograma de la edad de inicio de consumo de sustancias.

Nota. Datos de la investigación analizados a través de Google colab, mediante el lenguaje de programación Python.

Modelado (Modeling): se aplicaron técnicas de minería de datos, específicamente algoritmos de *Machine Learning* como K-means, para crear los perfiles digitales de los pacientes. Esta etapa fue crítica para agrupar a los pacientes en categorías que reflejaran sus características y necesidades específicas.

- Se utilizó modelos de clasificación no supervisados ya que estos no o utilizan etiquetas de datos. En su lugar, intentan encontrar patrones, relaciones o estructuras ocultas en los datos sin necesidad de resultados predefinidos.
- Implementación del algoritmo K-means para la agrupación o clustering de pacientes.
- De la data obtenida se realizó la agrupación de 3 clusters.
- Ajuste y optimización del modelo para asegurar que los perfiles generados fueran precisos y útiles para los CETAD.

```
import pandas as pd
from google.colab import files
from sklearn.preprocessing import MinMaxScaler, StandardScaler
from sklearn.cluster import KMeans
from sklearn.decomposition import PCA
from yellowbrick.cluster import KElbowVisualizer
```

Figura 8. Librerías a utilizar.

Fuente: Google colab, mediante el lenguaje de programación Python.



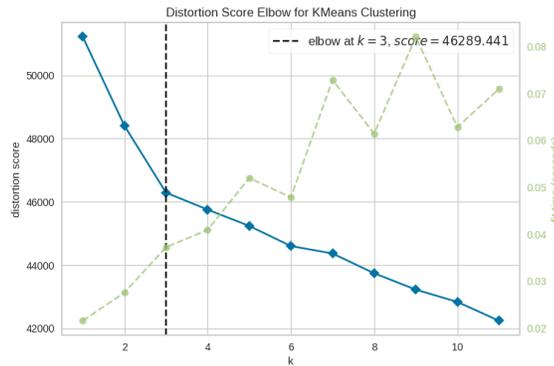


Figura 9. Gráfico del número de clusters sugeridos.
Fuente: Google colab, mediante el lenguaje de programación Python.

Evaluación (Evaluation): Antes de proceder a la implementación completa, se evaluó la eficacia del modelo desarrollado. Se procedió al entrenamiento de un modelo de red neuronal con los patrones de la agrupación de los datos obtenidos de los 3 clusters, se desarrolla un formulario de ingreso de información y llevo se cabo pruebas piloto ingresando información similar a la data obtenida y verificar si cumplía con parámetros establecidos y detectar a que grupo de los perfiles digitales generados pertenecía el paciente pudiendo llegar a la personalización y efectividad de los tratamientos.

- Utilizando la librería tensorflow entrenamos un modelo de red neuronal que aprenda sobre los grupos de personas con similares características de esta data.
- El modelo entrenado se agrega a nuestro menú de datos con extensión .h5 para que pueda ser procesado.
- Se revisó el nivel de precisión de nuestro modelo entrenado obteniendo un 94.44% de precisión en el conjunto de validación.

```
Epoch 43/50  
3/3 ————— 0s 21ms/step - accuracy: 0.9626 - loss: 0.1346 - val_accuracy: 0.9444 - val_loss: 0.2569  
Epoch 44/50  
3/3 ————— 0s 22ms/step - accuracy: 0.9665 - loss: 0.1194 - val_accuracy: 0.9444 - val_loss: 0.1707  
Epoch 45/50  
3/3 ————— 0s 22ms/step - accuracy: 1.0000 - loss: 0.1097 - val_accuracy: 1.0000 - val_loss: 0.1229  
Epoch 46/50  
3/3 ————— 0s 21ms/step - accuracy: 1.0000 - loss: 0.1169 - val_accuracy: 1.0000 - val_loss: 0.1150  
Epoch 47/50  
3/3 ————— 0s 21ms/step - accuracy: 1.0000 - loss: 0.1129 - val_accuracy: 1.0000 - val_loss: 0.1136  
Epoch 48/50  
3/3 ————— 0s 23ms/step - accuracy: 1.0000 - loss: 0.1072 - val_accuracy: 0.9444 - val_loss: 0.1829  
Epoch 49/50  
3/3 ————— 0s 23ms/step - accuracy: 0.9699 - loss: 0.1054 - val_accuracy: 0.9444 - val_loss: 0.1957  
Epoch 50/50  
3/3 ————— 0s 21ms/step - accuracy: 0.9777 - loss: 0.0941 - val_accuracy: 0.9444 - val_loss: 0.1309  
1/1 ————— 0s 49ms/step - accuracy: 0.9444 - loss: 0.1309  
WARNING:absl:You are saving your model as an HDF5 file via `model.save()` or `keras.saving.save_model(model)`. This fi  
Precisión en el conjunto de validación: 94.44%
```

Figura 10. Entrenamiento de Modelo de red neuronal con la información procesada.
Nota. Datos de la investigación analizados a través de Google colab, mediante el lenguaje de programación Python.



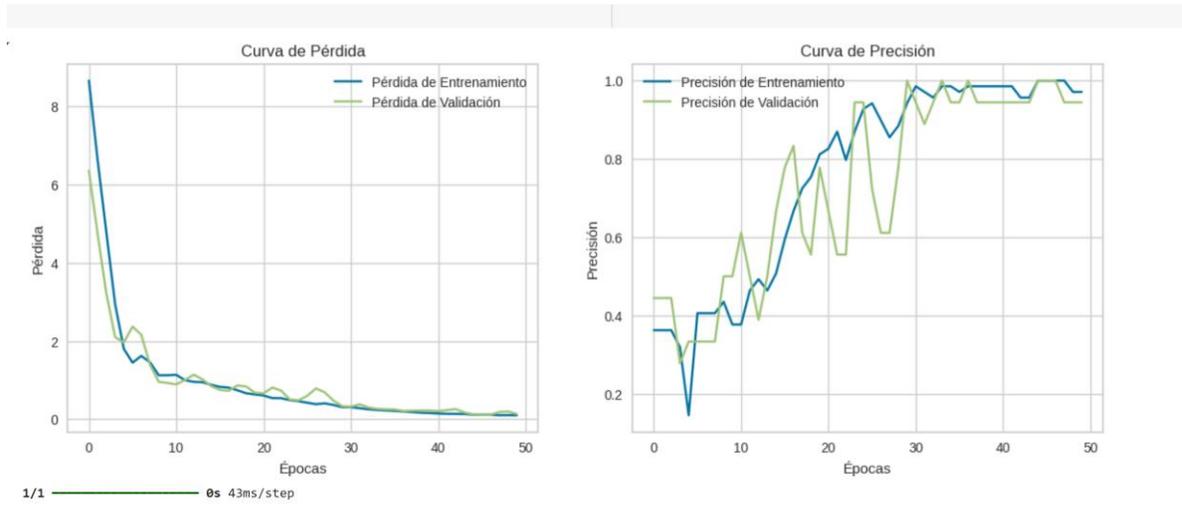


Figura 11. Curva de pérdida y precisión del modelo de red neuronal entrenado.

Nota. Datos de la investigación analizados a través de Google colab, mediante el lenguaje de programación Python.

Tabla 1. Detalles de la curva de aprendizaje de nuestro modelo entrenado.

Curva de pérdida	Curva de precisión
<p>-La pérdida de entrenamiento (línea azul) y la pérdida de validación (línea verde) disminuyen rápidamente en las primeras 10-15 épocas y luego se estabilizan a un nivel bajo.</p> <p>-Esto es una buena señal, indicando que el modelo ha aprendido bien de los datos sin caer en el sobreajuste.</p>	<p>- La precisión de entrenamiento (línea azul) y la precisión de validación (línea verde) aumentan rápidamente y convergen después de aproximadamente 30 épocas.</p> <p>- Ambas curvas de precisión se estabilizan cerca de 1.0, lo que sugiere que el modelo ha alcanzado una alta precisión tanto en los datos de entrenamiento como en los datos de validación.</p>

Despliegue (Deployment): Para desplegar este sistema de perfiles de digitales utilizaremos un prototipo de interface gráfica donde se podrá ingresar información que será leída y comparada con el modelo de red neuronal ya entrenado.

- Diseñar un plan de despliegue de este modelo entrenado conjuntamente con el prototipo de interface gráfica con información de nuevos pacientes.
- Monitorización del proyecto y la eficacia de la clasificación de estos nuevos pacientes.
- Medición del grado de precisión que diagnostica el modelo entrenado.

Implementación

En esta fase, se detalla cómo se llevó a cabo la implementación del sistema de perfiles digitales para pacientes en tratamiento de rehabilitación por adicción a drogas en los CETAD.



Selección del Modelo de Machine Learning: Se optó por un modelo supervisado, específicamente el algoritmo K-means, para la clasificación y agrupación de datos. Este enfoque se eligió debido a su capacidad para identificar patrones en datos etiquetados y mejorar la precisión de las clasificaciones. Se descartó el uso de modelos no supervisados en esta etapa debido a la necesidad de una guía basada en datos históricos etiquetados para una mayor efectividad en el tratamiento.

Software Utilizado: La implementación se realizó utilizando Python a través de Google Colab. Esta elección se debe a la facilidad y agilidad que proporciona Google Colab para la ejecución y revisión de código, así como la integración con herramientas y librerías de machine learning.

Desarrollo de la Interfaz Gráfica: Con la librería *ipywidgets* y *IPython*, se diseñó una interfaz gráfica piloto sencilla para ingresar datos. Esta interfaz permite que los datos sean leídos y procesados por el modelo entrenado, el cual clasificará al nuevo paciente y determinará a qué clúster pertenece.

Pruebas Piloto: Se realizaron pruebas piloto en un entorno controlado para validar el modelo. Estas pruebas permitieron ajustar el modelo y asegurar su precisión en un contexto realista.

Recopilación de Feedback: Se recopiló feedback de las pruebas realizadas con datos similares a los obtenidos en los CETADs. Esta información es esencial para ajustar y mejorar el modelo y garantizar su eficacia en el entorno real de aplicación.

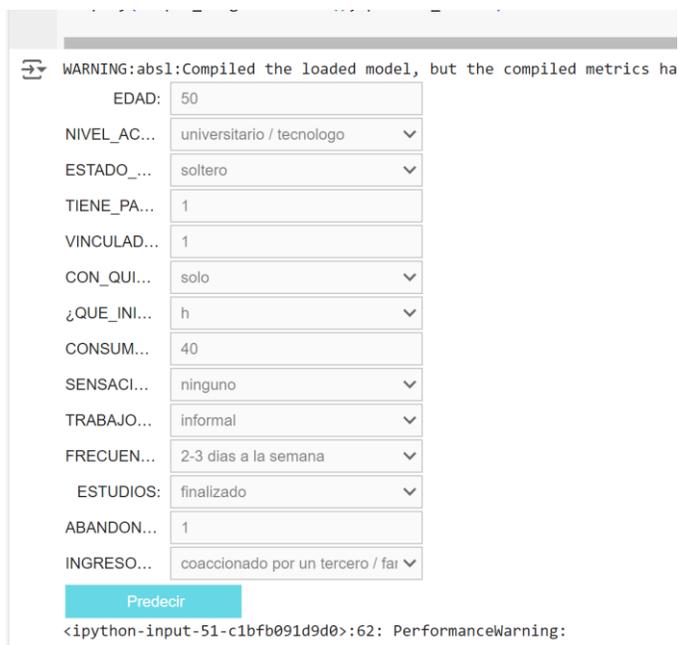


Figura 12. Interface con modelo entrenado para predicción de grupos para pacientes nuevos.



```
<ipython-input-51-c1bfb091d9d0>:62: PerformanceWarning:
DataFrame is highly fragmented. This is usually the result of calling `fr
<ipython-input-51-c1bfb091d9d0>:62: PerformanceWarning:
DataFrame is highly fragmented. This is usually the result of calling `fr
<ipython-input-51-c1bfb091d9d0>:62: PerformanceWarning:
DataFrame is highly fragmented. This is usually the result of calling `fr
<ipython-input-51-c1bfb091d9d0>:62: PerformanceWarning:
DataFrame is highly fragmented. This is usually the result of calling `fr
WARNING:tensorflow:6 out of the last 6 calls to <function TensorFlowTraine
1/1 ----- 0s 59ms/step
El paciente pertenece al Cluster 1
```

Figura 13. Resultado de la predicción.

Entrevista y encuesta

Adicionalmente, se aplicó entrevista y encuesta. Se entrevistó a una psicóloga con vasta experiencia en el tratamiento de trastornos familiares y adicciones. Ella identifica factores clave en la adicción, como la disfunción familiar y la influencia social. Subraya la importancia de la intervención desde el hogar y el enfoque integral en el tratamiento. Aunque no ha trabajado directamente en centros de rehabilitación, enfatiza la necesidad de un seguimiento post-rehabilitación y la utilidad de la tecnología para mejorar los tratamientos, abogando por su personalización. Finalmente, sugiere que el proyecto propuesto se presente a nivel nacional para optimizar el proceso de rehabilitación.

Se realizaron encuestas a personas en la calle con problemas de adicción, ya que no se pudo obtener apoyo de centros especializados como Narcóticos Anónimos o Alcohólicos Anónimos. Estos centros, a menudo gestionados por personas con experiencias similares en la adicción, se consideraron inapropiados para colaborar en la recolección de datos debido a su estructura improvisada y la falta de fines de lucro. A pesar de explicar el proyecto, estos sitios no quisieron participar en la realización de las encuestas.

Se encuestaron a 8 personas, muchas de las cuales tenían dificultades para leer. Por ello, se les leyó cada pregunta y opción de respuesta. De los encuestados, 3 nunca han recibido ayuda profesional, 4 han asistido a centros ambulatorios o grupos de ayuda, y solo 1 ha estado en un centro de rehabilitación residencial durante 7 meses. El análisis de las encuestas revela que los participantes son adultos jóvenes con experiencia en centros de rehabilitación,



principalmente en tratamientos ambulatorios. Muchos expresan resistencia a la idea de estar internados en un CETAD debido a cuestiones económicas. Existe un consenso significativo sobre la necesidad de mejorar los tratamientos actuales mediante su personalización para abordar las vulnerabilidades y necesidades individuales. Además, se destaca una preferencia por tratamientos psicológicos y psicosociales, ya que muchos encuestados han sufrido maltrato psicológico en la infancia. Se considera que el inicio del consumo de sustancias es más probable en la adolescencia, cuando los jóvenes se encuentran con consumidores y la curiosidad o consejos de amigos los inducen a iniciar el consumo. Finalmente, el fuerte deseo de recibir ayuda profesional sugiere que los encuestados están abiertos a intervenciones más especializadas y estructuradas, especialmente en centros de rehabilitación gratuitos, dado su malestar con las experiencias en lugares privados.

Conclusiones

Este proyecto tuvo como objetivo principal desarrollar un sistema para la creación de perfiles digitales de pacientes en tratamiento de rehabilitación para la adicción a las drogas en los Centros Autorizados por CETAD y MSP en Ecuador. Utilizando técnicas avanzadas de machine learning y análisis de datos, se implementó un prototipo capaz de agrupar a los pacientes en clústeres con características similares, lo que permite una personalización más efectiva de los tratamientos. La metodología Waterfall guió el desarrollo del proyecto, proporcionando una estructura clara y ordenada en cada fase.

Los resultados obtenidos indican que el uso de perfiles digitales tiene un impacto positivo en la eficacia de los tratamientos, reduciendo las tasas de recaída y mejorando la adherencia a los programas de rehabilitación. El algoritmo de clasificación K-means demostró ser efectivo en la agrupación y análisis de datos de pacientes. El uso de herramientas como One-Hot Encoding, normalización, estandarización, PCA y, por supuesto, clustering con K-means, permitió identificar patrones significativos entre los pacientes. Este enfoque ha sido validado como un método eficiente para mejorar la atención y los resultados terapéuticos en contextos de rehabilitación.

El proyecto logró cumplir con los objetivos iniciales, que incluían la recopilación de datos relevantes, el desarrollo de un modelo predictivo basado en machine learning y la creación de un prototipo funcional que se ajusta a los estándares de privacidad y seguridad exigidos por la legislación ecuatoriana.

Se analizó la importancia de realizar investigaciones que generen hallazgos y patrones relevantes para desarrollar tratamientos más personalizados y eficaces en los CETADs. El sistema propuesto aborda integralmente las limitaciones de los tratamientos estándar, proporcionando una herramienta innovadora para los profesionales de la salud.



El sistema de perfiles digitales se basó en datos recopilados en los centros de rehabilitación Los Libertadores y GLE, CETAD (Centros Especialistas en Tratamientos de Adicciones a las Drogas), tanto en el sector público como en el privado en Ecuador. Este enfoque considera diferentes criterios evaluados para explorar su aplicación en otras áreas de la salud donde la personalización de tratamientos pueda ser beneficiosa.

Es crucial continuar con evaluaciones e investigaciones que permitan actualizar y mejorar el prototipo desarrollado inicialmente. Las futuras versiones del prototipo deberían centrarse en mejorar la eficiencia del procesamiento de datos, posiblemente integrando tecnologías emergentes como la inteligencia artificial explicable (XAI) para proporcionar mayor transparencia en la toma de decisiones.

Un punto clave revisado en el proyecto es que los CETADs no contaban con un sistema ordenado para mantener su información, ya que la información estaba solo en formato físico y no detallada como la generada por esta investigación. Esta limitación restringe la escalabilidad inmediata del sistema. Se sugiere que futuras investigaciones se enfoquen en mejorar la interoperabilidad de los sistemas de perfiles digitales con otras plataformas de salud existentes, así como en la evaluación a largo plazo del impacto de estos sistemas en los resultados de rehabilitación. También es importante investigar el impacto psicosocial del uso de tecnologías de personalización en los tratamientos de adicciones.

El proyecto de creación de perfiles digitales no solo mejora los tratamientos de rehabilitación en los CETADs, sino que también contribuye al campo de la tecnología de la información aplicada a la salud. Este enfoque pionero en Ecuador establece un precedente para la integración de tecnologías avanzadas en la atención médica, particularmente en el ámbito de la rehabilitación de adicciones. Además, ofrece un marco de referencia para el desarrollo de futuras iniciativas tecnológicas en salud, destacando la importancia de la personalización y el uso de datos en la mejora de la calidad de vida de los pacientes.

Conflictos de intereses

Los autores no poseen conflictos de intereses.

Contribución de los autores

1. Conceptualización: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos
2. Curación de datos: Fabián Espinoza Bazán, Janeth Díaz Vera
3. Análisis formal: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán
4. Investigación: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán, Janeth Díaz Vera



Esta obra está bajo una licencia *Creative Commons* de tipo **Atribución 4.0 Internacional**
(CC BY 4.0)

5. Metodología: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán, Janeth Díaz Vera
6. Administración del proyecto: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos
7. Software: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán, Janeth Díaz Vera
8. Supervisión: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán, Janeth Díaz Vera
9. Validación: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán, Janeth Díaz Vera
10. Visualización: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán, Janeth Díaz Vera
11. Redacción – borrador original: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán, Janeth Díaz Vera
12. Redacción – revisión y edición: Francisco Palacios Ortiz, Cecilia Cabanilla Burgos, Fabián Espinoza Bazán, Janeth Díaz Vera

Financiamiento

La investigación no requirió fuente de financiamiento externa.

Referencias

- Bishop, C. M. (2006). *SpringerLink*. Obtenido de <https://link.springer.com/book/9780387310732>
- Calvo, D. (09 de 03 de 2018). *Diego Calvo*. Obtenido de <https://www.diegocalvo.es/cluster-jerarquicos-y-no-jerarquicos/>
- Censos, I. N. (2023). *INEC*. Obtenido de INEC: <https://www.ecuadorencifras.gob.ec/estadisticas/>
- Chekroud, A. M. (2016). *Science direct*. Obtenido de <https://www.sciencedirect.com/science/article/pii/S2215036616000082>
- ECUADOR, A. N. (26 de MAYO de 2021). *FINANZAS POPULARES*. Obtenido de https://www.finanzaspopulares.gob.ec/wp-content/uploads/2021/07/ley_organica_de_proteccion_de_datos_personales.pdf
- Entendidos. (02 de 06 de 2021). *Solo para entendidos*. Obtenido de <https://www.soloentendidos.com/analisis-de-componentes-principales-pca-paso-a-paso-2539>
- González. (2019). *Instituto Nacional de Psiquiatría Ramón de la Fuente Muñiz*. (I. s. Adicciones, Productor) Obtenido de Instituto Nacional de Psiquiatría Ramón de la Fuente Muñiz: <https://inprf.gob.mx/>
- Martínez. (2020). *UNIVERSIDAD DE LOS ANDRES - COLOMBIA*. (E. s. Adicciones, Productor) Obtenido de <https://uniandes.edu.co/>



- MSP. (2020). Porcentaje de índice de consumo. Ministerio de Salud Pública, QUITO, ECUADOR.
- MSP. (2023). Estudio sobre la tasa de recaída en pacientes que completaron programas de rehabilitación en los Centros Especializados en Tratamiento a Personas con Consumo Problemático de Alcohol y otras Drogas (CETAD).
- OEA. (2019). *Informe sobre el Consumo de Drogas en las Américas 2019*. Organización de los Estados Americanos, Washington, D.C., EE.UU. Obtenido de Organización de los Estados Americanos: <https://www.oas.org/es/ssm/publications.asp?IE=00085>
- OMS. (2021). *WORLD HEALTH ORGANIZATION*. Obtenido de <https://www.who.int/publications/i/item/technologies-in-mental-health-innovations-for-global-health>
- Pranshu. (17 de 01 de 2024). *analyticsvidhya*. Obtenido de <https://www.analyticsvidhya.com/blog/2021/04/k-means-clustering-simplified-in-python/>
- Rueda, J. F. (2024). *healthdataminer*. Obtenido de <https://healthdataminer.com/data-mining/crisp-dm-una-metodologia-para-mineria-de-datos-en-salud/>

