



**Facultad de Ciencias de la Vida y Tecnologías
Tecnologías de la Información
Proyecto Integrador**

Tema:

Modelos de aprendizaje de máquina en la detección de patrones de adicción a las redes sociales en estudiantes de secundaria.

Autora:

Isabella Verónica Aguilar Aguilera

Director de proyecto de titulación:

Ing. Jorge Iván Pincay Ponce, PhD.

2025-2



Declaración de autoría

DECLARACIÓN DE AUTORÍA

Quien suscribe la presente:

AGUILAR AGUILERA ISABELLA VERÓNICA

Estudiante de la Carrera de **Tecnologías de la información**, declaro bajo juramento que el siguiente proyecto cuyo título: **“MODELOS DE APRENDIZAJE DE MÁQUINA EN LA DETECCIÓN DE PATRONES DE ADICCIÓN A LAS REDES SOCIALES EN ESTUDIANTES DE SECUNDARIA”**, previa a la obtención del Título de Ingeniero en Tecnologías de la Información, es de autoría propia y ha sido desarrollado respetando derechos intelectuales de terceros y consultando las referencias bibliográficas que se incluyen en este documento.

Isabella Aguilar
Aguilar Aguilera Isabella Verónica



Certificación del director de trabajo de graduación

	NOMBRE DEL DOCUMENTO: CERTIFICADO DE TUTOR(A).	CÓDIGO: PAT-04-F-004
	PROCEDIMIENTO: TITULACIÓN DE ESTUDIANTES DE GRADO BAJO LA UNIDAD DE INTEGRACIÓN CURRICULAR	REVISIÓN: 1
		Página 1 de 1

CERTIFICACIÓN

En calidad de docente tutor de la Facultad de Ciencias de la Vida y Tecnología de la Universidad Laica "Eloy Alfaro" de Manabí, CERTIFICO:

Haber dirigido, revisado y aprobado preliminarmente el Trabajo de Integración Curricular bajo la autoría de la estudiante **Isabella Verónica Aguilar Aguilera**, legalmente matriculado en la carrera de tecnologías de la Información, período académico 2025 (2), cumpliendo el total de 384 horas, cuyo tema del proyecto es **"Modelos de aprendizaje de máquina en la detección de patrones de adicción a las redes sociales en estudiantes de secundaria"**.

La presente investigación ha sido desarrollada en apego al cumplimiento de los requisitos académicos exigidos por el Reglamento de Régimen Académico y en concordancia con los lineamientos internos de la opción de titulación en mención, reuniendo y cumpliendo con los méritos académicos, científicos y formales, y la originalidad de este, requisitos suficientes para ser sometida a la evaluación del tribunal de titulación que designe la autoridad competente.

Particular que certifico para los fines consiguientes, salvo disposición de Ley en contrario.

Manta, 26 de enero de 2026.

Lo certifico,

Ing. Pincay Ponce Jorge Ivan, PhD.
Docente Tutor
Facultad de Ciencias de la Vida y Tecnología
Carrera Tecnologías de la Información



Dedicatoria

A mis padres, con todo el amor y gratitud que mi corazón puede albergar, por ser el pilar fundamental sobre el cual se ha construido mi vida. Gracias por su amor incondicional, por cada sacrificio que hicieron en silencio, por su entrega diaria y por estar presentes en cada paso de mi camino. Gracias por creer en mí incluso en los momentos en que yo misma dudaba, por enseñarme que la constancia, el esfuerzo y la honestidad son los verdaderos motores del crecimiento personal y profesional. Todo lo que soy y lo que he logrado se lo debo, en gran parte, a su ejemplo y a su infinito apoyo.

A mi hermana, compañera de vida, confidente y amiga incondicional. Gracias por tu compañía constante, por tu cariño que nunca ha faltado y por tus palabras que, en los momentos más difíciles, supieron reconfortarme y darme fuerza para seguir adelante. Tu presencia ha sido un bálsamo en mis días grises y una alegría en mis días de triunfo. Eres, sin duda, una de mis mayores bendiciones.

Y con un amor que trasciende el tiempo y el espacio, dedico este logro académico a mis queridos angelitos del cielo, cuya memoria vive profundamente arraigada en mi ser:

A mi abuelito, el Dr. Luis Aguilera Andrade, ejemplo de sabiduría, rectitud y vocación de servicio. Su legado de trabajo, compromiso y amor por la familia ha sido una guía luminosa en mi camino. Aunque ya no esté físicamente, su presencia me acompaña cada día, impulsándome a ser mejor y a honrar su memoria con mis actos.

A mi tía, la Ing. Nathali Aguilera Palma, mujer fuerte, brillante y generosa, que dejó en mí una huella imborrable. Su ejemplo de superación, su dulzura y su empuje siguen siendo un faro que me inspira. Cada meta que alcanzo lleva también su nombre, porque en cada logro suyo encontré el valor para alcanzar los míos.

Y a mi tío el Sr. Francisco Aguilar Sánchez, cuya alegría y nobleza lograron llenar mi infancia de momentos inolvidables. Gracias por los recuerdos que guardo con tanto cariño, por



las risas compartidas y por enseñarme que la bondad puede cambiar el mundo. Su recuerdo permanece vivo en cada gesto de amor que comparto.

Este trabajo, más que un requisito académico, para mí es un símbolo de gratitud hacia quienes me formaron, me acompañaron y me amaron profundamente. A todos ustedes, gracias por ser parte de mi historia. Los llevo conmigo en cada paso, en cada logro y en cada sueño cumplido. Este triunfo también les pertenece.

Hoy y siempre, los llevo en mi mente, en mis decisiones y, sobre todo, en mi corazón.



Agradecimientos

En primer lugar, elevo mi gratitud a Dios, fuente infinita de sabiduría, fortaleza y amor. Gracias, Señor, por acompañarme en cada paso de este camino, por darme luz en los momentos de oscuridad, fuerza en los instantes de debilidad y esperanza cuando el panorama parecía incierto. Tu presencia ha sido el pilar invisible que ha sostenido mis sueños y el hecho de haber llegado hasta aquí es una muestra palpable de tu fidelidad y misericordia.

Con un gran respeto y sincera gratitud, extendiendo mi más sincero reconocimiento a la Universidad Laica Eloy Alfaro de Manabí, institución que me permitió conseguir las herramientas académicas y humanas necesarias para poder construir y culminar mi formación profesional. Gracias por ser el espacio donde pude crecer, aprender y proyectar mis aspiraciones.

Mi especial agradecimiento a la Dra. Dolores Muñoz Verduga, decana de la Facultad de Ciencias de la Vida y Tecnologías, por su liderazgo, dedicación y compromiso con la calidad educativa, por confiar en mí y creer en mis habilidades, lo cual ha sido un impulso invaluable en esta etapa académica.

Asimismo, al Dr. Jorge Pincay Ponce, tutor de tesis, por su acompañamiento, orientación constante y valiosos aportes en el desarrollo de este trabajo investigativo. A cada uno de los docentes que formaron parte de esta travesía universitaria, gracias por su entrega, exigencia académica y vocación de servicio; han dejado una huella imborrable en mi formación personal y profesional.

A mis padres, que han sido el soporte más firme en cada etapa de mi vida. Gracias por su amor inmenso, por su paciencia inagotable, por sus sabios consejos y por cada uno de los sacrificios que hicieron por mí sin pedir nada a cambio. Ustedes me han enseñado, con su ejemplo, que el esfuerzo, la dedicación y el amor incondicional son los cimientos de todo gran logro. Este triunfo es tanto mío como suyo.



A mi hermana, por ser una compañera incondicional de vida. Gracias por tu presencia constante, por tus palabras de aliento en los días difíciles y por ser parte fundamental de mi motivación. Tu apoyo ha sido un refugio seguro y una fuente continua de inspiración.

Con especial cariño, dedico este trabajo a mis amados seres queridos que me acompañan desde el cielo, cuya memoria vive eternamente en mi corazón:

A mi abuelito, el Dr. Luis Aguilera Andrade, por enseñarme a mantenerme firme ante la adversidad y actuar siempre con ética, rectitud y compromiso. Su ejemplo de vida me guía en cada decisión importante.

A mi tía, la Ingeniera Nathali Aguilera, cuyo recuerdo me impulsa a seguir luchando por mis sueños con valentía y ternura. Su legado vive en cada meta que alcanzo.

Y a mi tío Francisco Aguilar, por todo el amor compartido, por su bondad, por las sonrisas que aún me acompañan y por todos y cada uno de los momentos que atesoro con profunda gratitud en mi corazón.

A mis amigos y compañeros, gracias por su apoyo sincero, por las palabras que llegaron en el momento justo, por el compañerismo y las experiencias compartidas que enriquecieron este proceso.

Finalmente, extendiendo mi agradecimiento a todas las personas que, de una u otra manera, aportaron a mi crecimiento personal y profesional. Cada gesto, cada palabra, cada enseñanza y cada muestra de afecto han sido parte esencial de este logro que hoy con tanto orgullo comparto.

Gracias infinitas a todos. Este logro es también suyo.



ÍNDICE GENERAL DE CONTENIDO

Declaración de autoría.....	2
Certificación del director de trabajo de graduación	3
Dedicatoria	4
Agradecimientos.....	6
Abstract	11
Resumen	13
Introducción	14
Ubicación y Contextualización de la Problemática.....	14
Planteamiento del problema	15
Objetivos	18
Objetivo general	18
Objetivos específicos.....	18
Justificación.....	19
CAPÍTULO I	21
MARCO TEÓRICO	21
1.1. Antecedentes de investigaciones relacionadas al tema presentado	21
1.2. Bases teóricas	23
1.2.1. Adicción a redes sociales.....	23
1.2.2. Adicción a redes sociales en adolescentes.....	24
1.2.3 Componentes de la adicción a redes sociales	26
1.3 Factores psicosociales asociados al uso problemático de redes sociales.....	28
1.4 Redes sociales y rendimiento académico en estudiantes de secundaria.....	29
1.5 Aprendizaje de máquina aplicado al análisis del comportamiento digital.....	32
1.5.2 Aprendizaje no supervisado en estudios educativos.....	34
1.5.3 Ventajas del aprendizaje de máquina frente a métodos tradicionales.....	36
1.6 Modelos de aprendizaje de máquina utilizados en la detección de adicción digital	38
1.6.1 Análisis Exploratorio de Datos (EDA).....	40
1.6.2 Análisis de Componentes Principales (PCA)	41
1.6.3 Análisis de clústeres	43
1.6.4 Reglas de asociación	45
CAPÍTULO II.....	48
MARCO INVESTIGATIVO	48
2.1 Tipo de Investigación	48
2.2. Métodos de Investigación.....	49
2.3. Herramientas de recolección de datos	50



2.3.1. Encuesta	50
2.4. Fuentes de Información de datos.....	52
2.4.1. Fuentes primarias - Fuentes secundarias	52
2.5. Instrumental Operacional	54
2.5.1. Estructura y características de los instrumentos de recolección de datos.....	54
2.6. Estrategia Operacional para la recolección y tabulación de datos	58
2.6.1. Plan de recolección, tabulación, análisis e interpretación de los datos	58
2.7. Plan de Muestreo.....	61
2.7.1. Segmentación - Técnica de muestreo - Tamaño de la muestra.....	61
2.8. Presentación y Análisis de los resultados	63
2.8.1. Presentación y Descripción de los resultados obtenidos	63
2.8.1.1 Caracterización de la población estudiada	63
2.8.1.2 Intensidad y frecuencia del uso de redes sociales	65
2.8.1.3 Resultados asociados a variables psicosociales.....	66
2.8.1.4 Resultados asociados a variables psicosociales referentes al clúster	68
2.8.1.5 Resultados del análisis de reglas de asociación.....	70
2.8.2. Informe final del análisis de los resultados	71
CAPÍTULO III	73
MARCO PROPOSITIVO	73
3.1. Introducción	73
3.2. Descripción de la propuesta	74
3.3. Determinación de recursos	75
3.3.1. Humanos.....	75
3.3.2. Tecnológicos.....	76
3.3.3. Económicos (presupuesto)	77
3.4. Etapas de OSEMN	79
3.4.1. Obtaining Data (Obtener Datos).....	79
3.4.1.1 Recopilación de datos iniciales	79
3.4.1.2 Descripción de los datos.....	80
3.4.1.3 Exploración de datos	81
3.4.2. Scrubbing Data (Limpiar Datos)	82
3.4.2.1. Selección de datos	82
3.4.2.2. Limpieza de datos.....	83
3.4.2.3. Construcción de nuevos datos	83
3.4.2.4. Integración de datos	85
3.4.2.5. Formato de datos	87
3.4.3. Calidad de los datos.....	89



3.4.3.1. Imputación de valores faltantes	89
3.4.3.2. Combinación de diferentes conjuntos de datos	91
3.4.4. Exploring Data (Explorar Datos)	93
3.4.5. Modeling (Modelar)	94
3.4.6. Interpreting Results (Interpretar Resultados)	96
CAPÍTULO IV	98
HALLAZGOS CLAVES.....	98
4.1 Hallazgos relacionados con la caracterización del comportamiento digital.....	98
4.2 Hallazgos derivados del análisis de componentes principales (PCA)	98
4.3 Hallazgos asociados a la segmentación de estudiantes mediante clústeres	99
4.4 Hallazgos del análisis de reglas de asociación	100
4.5 Integración de hallazgos y aporte del aprendizaje de máquina	100
4.6 Validación técnica del modelo implementado	101
CAPÍTULO V	103
CONCLUSIONES Y RECOMENDACIONES	103
5.1 Conclusiones	103
5.2 Recomendaciones.....	104
TRABAJOS FUTUROS	106
REFERENCIAS BIBLIOGRÁFICAS	108
ANEXOS	121

ÍNDICE DE TABLAS

Tabla 1. Recursos humanos empleados en la propuesta	75
Tabla 2. Recursos tecnológicos empleados en la propuesta	76
Tabla 3. Presupuesto a invertir en el proyecto.....	78
Tabla 4. Variables derivadas construidas para el análisis.....	84
Tabla 5. Conjuntos de datos integrados para el análisis	91

ÍNDICE DE ILUSTRACIONES

Ilustración 1. Diagrama de adicción conductual en redes sociales.....	23
Ilustración 2. Manifestaciones de la adicción a redes sociales en adolescentes y su impacto psicoeducativo.....	26
Ilustración 3. Componentes de la adicción a redes sociales según la Escala Bergen (BSMAS)27	



Ilustración 4. Factores psicosociales asociados al uso problemático de redes sociales en adolescentes	29
Ilustración 5. Impacto del uso de redes sociales en el rendimiento académico de estudiantes de secundaria	31
Ilustración 6. Aplicación del aprendizaje de máquina en el análisis del comportamiento digital en contextos educativos	33
Ilustración 7. Aplicación del Aprendizaje No Supervisado en Estudios Educativos	35
Ilustración 8. Ventajas del Aprendizaje de Máquina frente a los Métodos Tradicionales en el Análisis Educativo.....	37
Ilustración 9. Modelos de Aprendizaje de Máquina no Supervisados para la Detección de la Adicción Digital en Estudiantes	39
Ilustración 10. Análisis Exploratorio de Datos (EDA) como Base del Estudio de la Adicción Digital	40
Ilustración 11. Análisis de Componentes Principales (PCA) aplicado a la Detección de la Adicción Digital	43
Ilustración 12. Análisis de Clústeres para la Identificación de Perfiles de Uso Digital en Estudiantes	44
Ilustración 13. Reglas de Asociación para la Identificación de Patrones de Riesgo en la Adicción Digital	46
Ilustración 14. Resumen general de los datos obtenidos	63
Ilustración 15. Patrones de consumo digital.....	65
Ilustración 16. Variables psicosociales.....	66
Ilustración 17. Análisis del Clúster	68
Ilustración 18. Análisis de las reglas de asociación	70
Ilustración 19. Datos luego del tratamiento	85
Ilustración 20. Integración de múltiples conjuntos de datos mediante modelo relacional en Power BI.....	86
Ilustración 21. Estandarización y formateo de los datos en Power BI.....	87
Ilustración 22. Aplicación de la metodología OSEMN para los datos	89
Ilustración 23. Evaluación de la calidad de los datos posterior a la imputación de valores faltantes	90
Ilustración 24. Tendencias generales del trabajo	92
Ilustración 25. Análisis exploratorio descriptivo del uso de redes sociales en estudiantes.....	93
Ilustración 26. Segmentación de estudiantes mediante clustering.....	95
Ilustración 27. Reglas de asociación con mayor relevancia analítica.....	97

Abstract



Context: The excessive and compulsive use of social media among secondary school students has become a relevant issue in the digital era, due to its negative effects on academic performance, emotional well-being, and social relationships. Platforms such as Instagram, TikTok, and Facebook significantly influence adolescents' digital behavior, increasing the risk of technological dependence.

Method: This research adopted a quantitative approach supported by machine learning models to detect behavioral patterns associated with social media addiction. The validated **Bergen Social Media Addiction Scale (BSMAS)** was applied to secondary school students in the city of Manta, Ecuador, collecting data on psychosocial variables such as self-esteem, emotional state, and perception of the school environment. The data were analyzed using exploratory data analysis techniques and predictive modeling.

Results: The analysis allowed the identification of risk patterns related to problematic social media use, revealing significant relationships between usage intensity, emotional variables, and repetitive digital behaviors. The implemented models demonstrated an adequate capacity to segment risk profiles and detect early indicators of digital addiction.

Conclusions: The findings confirm the potential of machine learning as a support tool for the early detection of addictive behaviors in educational contexts. Furthermore, this study provides evidence for the design of preventive strategies aimed at promoting digital well-being and responsible technology use among adolescents, contributing to informed decision-making within educational institutions.

Keywords: social media addiction, machine learning, adolescents, digital behavior, artificial intelligence, education, digital well-being.



Resumen

Contexto: El uso excesivo y compulsivo de las redes sociales en estudiantes de secundaria se ha consolidado como una problemática relevante en la era digital, debido a sus efectos negativos sobre el rendimiento académico, el bienestar emocional y las relaciones sociales. Plataformas como Instagram, TikTok y Facebook influyen de manera significativa en el comportamiento digital de los adolescentes, generando riesgos asociados a la dependencia tecnológica.

Método: La investigación empleó un enfoque cuantitativo apoyado en modelos de aprendizaje de máquina para la detección de patrones conductuales vinculados a la adicción a redes sociales. Se aplicó la escala validada Bergen Social Media Addiction Scale (BSMAS) a estudiantes de secundaria de la ciudad de Manta, Ecuador, recolectando información sobre variables psicosociales como autoestima, estado emocional y percepción del entorno escolar.

Resultados: El presente análisis permitió identificar los distintos patrones de riesgo que se encuentran asociados al uso problemático de redes sociales, logrando así evidenciar relaciones significativas entre la intensidad de uso, variables emocionales y comportamientos digitales repetitivos. Los modelos implementados demostraron una capacidad adecuada para segmentar perfiles de riesgo y detectar indicios tempranos de adicción digital.

Conclusiones: Los resultados presentados confirman el gran potencial que posee el aprendizaje de máquina como herramienta de apoyo para la detección temprana de conductas adictivas en contextos educativos. Asimismo, el estudio aporta evidencia para el diseño de estrategias preventivas orientadas al bienestar digital y al uso responsable de la tecnología en adolescentes, contribuyendo a la toma de decisiones informadas por parte de las instituciones educativas.

Palabras clave: adicción a redes sociales, aprendizaje de máquina, adolescentes, comportamiento digital, inteligencia artificial, educación, bienestar digital.



Introducción

Ubicación y Contextualización de la Problemática

En el contexto digital actual, el uso intensivo de redes sociales se ha convertido en una práctica generalizada entre los adolescentes principalmente en estudiantes de nivel secundario. Plataformas reconocidas como Instagram, TikTok, Facebook y WhatsApp han logrado adquirir un papel protagónico en la vida cotidiana de los jóvenes, como medios de comunicación y como espacios de expresión personal, construcción de identidad y acceso a contenidos de entretenimiento (Sarman & Tuncay, 2023).

No obstante, cuando el uso de estas plataformas se convierte excesivo, se empiezan a evidenciar una gran serie de consecuencias negativas que afectan distintas dimensiones del desarrollo adolescente, entre ellas el desempeño académico, la estabilidad emocional y las relaciones sociales. Diversas investigaciones a nivel mundial han señalado que una exposición prolongada a redes sociales puede alterar en un nivel severo los hábitos esenciales del estudiante, como lo es el descanso, la concentración y la interacción social, incrementando el riesgo de problemas emocionales y académicos. Además, se ha observado una creciente correlación entre el uso inadecuado de redes sociales y la aparición de síntomas asociados al estrés, la ansiedad, la depresión e incluso la autoimagen distorsionada (Castro Gutierrez, 2022).

Esta problemática se manifiesta con especial intensidad en instituciones educativas de ciudades intermedias como Manta (Ecuador), donde se observa una creciente disponibilidad de dispositivos móviles y acceso a internet entre los adolescentes, sin que esto vaya necesariamente acompañado de una formación adecuada en competencias digitales, autocontrol emocional y hábitos de consumo tecnológico saludables. En contextos educativos donde existe amplio acceso a dispositivos móviles, los estudiantes pueden desarrollar patrones de uso problemático de redes sociales, priorizando la interacción digital sobre sus responsabilidades escolares y familiares (Soria & Villegas-Villacres, 2024).

El entorno educativo actual enfrenta grandes desafíos para abordar esta realidad, especialmente debido a la falta de monitoreo sistemático del comportamiento digital de los



estudiantes, la escasa intervención institucional frente a señales de alarma y la inexistencia de herramientas tecnológicas que permitan identificar los casos de riesgo de manera oportuna y efectiva. Las medidas tradicionales de control parental o sanción disciplinaria resultan insuficientes frente a una problemática que requiere enfoques más sofisticados, preventivos e integrales (Bautista-Quispe et al., 2023).

En este marco, se hace evidente la necesidad de incorporar soluciones tecnológicas avanzadas que permitan comprender y anticipar el comportamiento de los estudiantes en el entorno digital. Entre estas soluciones, el aprendizaje de máquina o machine learning en inglés emerge como una herramienta innovadora con gran potencial para detectar patrones ocultos en grandes volúmenes de datos y generar modelos predictivos que identifiquen indicios de adicción a redes sociales. Al aplicar algoritmos de inteligencia artificial al análisis del comportamiento digital, es posible generar alertas tempranas, segmentar grupos de riesgo y diseñar estrategias de intervención más efectivas y personalizadas (Estrada Araoz et al., 2020).

La presente investigación se inscribe dentro de este enfoque multidisciplinario, integrando elementos de la ciencia de datos, la psicología educativa y la tecnología educativa para ofrecer una propuesta de intervención concreta. El objetivo principal de este proyecto es lograr desarrollar un modelo de aprendizaje de máquina que permita, a partir de la información recolectada mediante encuestas estructuradas, detectar patrones asociados al uso problemático de redes sociales en estudiantes de secundaria (Quintana, 2023).

Con ello, se aspira a sentar las bases para una gestión más eficiente del bienestar estudiantil en la era digital, promoviendo un uso consciente, equilibrado y saludable de la tecnología entre los adolescentes.

Planteamiento del problema

En los últimos años, se ha observado una tendencia creciente y preocupante en el comportamiento digital de los adolescentes: el aumento sostenido del tiempo que dedican al uso de redes sociales. Esta conducta, que en un principio podía considerarse parte del proceso natural de adaptación a los avances tecnológicos y a las nuevas formas de comunicación digital,



ha logrado derivar en numerosos casos hacia un patrón de uso mucho más problemático, con rasgos que se asemejan a las adicciones conductuales. Este tipo de adicción, caracterizada por una pérdida progresiva de control sobre el comportamiento y por una interferencia significativa en otras áreas de la vida cotidiana, afecta de manera particular a la población estudiantil en etapa secundaria (Beneth-Benavides & Paz-Saavedra, 2025).

Estudios recientes en el ámbito de la educación han documentado que los adolescentes que hacen un uso excesivo e inadecuado de plataformas como TikTok, Instagram o Facebook tienden a desarrollar una sintomatología compleja. Entre los efectos más reportados se encuentran: irritabilidad constante, dificultades para desconectarse de las redes sociales, aislamiento social, disminución del interés por actividades académicas, reducción en el rendimiento escolar, alteraciones del ciclo del sueño y dependencia emocional respecto a la interacción digital (Laveriano Varas, 2023).

Sin embargo, a pesar de la magnitud de esta problemática, muchas instituciones educativas aún no cuentan con mecanismos eficaces para detectar a tiempo estas conductas de riesgo. Los métodos tradicionales de monitoreo, como la observación directa por parte de los docentes o las intervenciones del personal psicopedagógico actualmente conocido como DECE en las instituciones educativas, suelen quedarse cortos ante un fenómeno que, en muchos casos, pasa desapercibido o se manifiesta de forma muy sutil.

Además, los estudiantes suelen mostrar habilidades para disimular los síntomas o no los identifican como perjudiciales, lo que dificulta aún más su detección temprana. A esto se suma la falta de herramientas tecnológicas diseñadas específicamente para el entorno escolar ecuatoriano, que permitan recoger, procesar y analizar datos de manera automatizada y generar alertas oportunas sobre posibles casos de adicción a redes sociales (Romero-Méndez & Romero-Méndez, 2024).

Ante este escenario, se plantea la necesidad urgente de adoptar enfoques innovadores que integren tecnologías emergentes en la gestión educativa. En particular, el uso de modelos de



aprendizaje de máquina representa una alternativa prometedora para abordar este desafío. Estas tecnologías permiten analizar grandes volúmenes de datos, identificar patrones de comportamiento digital y construir modelos predictivos que podrían detectar con alto grado de precisión aquellos estudiantes que se encuentran en riesgo de desarrollar una adicción a las redes sociales (Salas Blas, 2024).

En función de lo expuesto, surge la siguiente interrogante central de la investigación:

¿De qué manera puede la implementación de modelos de aprendizaje de máquina facilitar la detección de patrones de adicción a redes sociales en estudiantes de nivel secundario?

Responder a esta pregunta de investigación permitiría no solo profundizar en la comprensión del fenómeno desde una perspectiva científica y tecnológica, sino también establecer una base empírica sólida para el diseño e implementación de estrategias preventivas y de intervención educativa más eficientes. (Aguilar, 2024)



Objetivos

Objetivo general

Elaborar modelos de aprendizaje de máquina en la detección de patrones de adicción a las redes sociales en estudiantes de secundaria.

Objetivos específicos

1. Aplicar una encuesta validada BSMAS, enfocado en las prácticas de uso de redes sociales, para obtener información fiable y contextualizada.
2. Caracterizar los datos obtenidos con base en el Análisis Exploratorio de Datos.
3. Implementar modelos de aprendizaje de máquina no supervisados, para el análisis de los riesgos de adicción digital por parte de los estudiantes.
4. Formular recomendaciones prácticas y sostenibles para el uso saludable de redes sociales en entornos escolares, orientadas a estudiantes, padres y docentes. Con base en los resultados fiables reportados por los modelos.



Justificación

La presente investigación posee una destacada relevancia en los ámbitos académico, social y tecnológico, al centrarse en una problemática emergente de gran impacto en la realidad contemporánea: el uso desmedido de redes sociales por parte de adolescentes en edad escolar. Este fenómeno, que se ha intensificado con la proliferación de dispositivos móviles y el acceso masivo a internet, constituye un desafío complejo y multifactorial que aún no ha sido abordado con el rigor metodológico ni con las herramientas tecnológicas que su magnitud exige.

Actualmente el uso impropio de las redes sociales ha propiciado severas perturbaciones en la concentración, organización temporal y el desempeño de tareas académicas impactando directamente el ámbito educativo e interponiendo desafíos notables a las instituciones educativas. (Bedoya Denegri, 2021)

Desde una perspectiva académica, esta investigación representa un aporte valioso al estudio interdisciplinario del comportamiento digital juvenil. Al integrar elementos teóricos y prácticos provenientes de la psicología del desarrollo, la pedagogía, las ciencias de la educación y la ciencia de datos, se construye un enfoque robusto que permite analizar el fenómeno desde múltiples dimensiones. Además, se introduce una propuesta metodológica innovadora al aplicar modelos de aprendizaje de máquina, lo cual constituye un avance significativo en la aplicación de tecnologías emergentes en el ámbito educativo. Esta integración no solo mejora la precisión en la detección de patrones de riesgo, sino que también permite el diseño de sistemas predictivos que podrían ser replicables y escalables en diferentes contextos escolares. (Chapilliquen Lopez, 2023)

En el plano social, esta investigación pretende convertirse en un insumo para la sensibilización y reflexión de los diferentes actores del sistema educativo como padres de familia, docentes, autoridades institucionales y responsables de políticas públicas acerca de los efectos nocivos del uso desregulado de redes sociales. Desde una perspectiva social, el estudio aporta evidencia para orientar acciones preventivas dirigidas a estudiantes, docentes y familias, fortaleciendo el uso responsable de las tecnologías digitales. (Rufino Vargas, 2021)



En cuanto a la dimensión tecnológica, se demuestra que las herramientas basadas en inteligencia artificial, ~~y~~ específicamente en aprendizaje de máquina pueden utilizarse con fines éticos, educativos y preventivos, alejándose de los usos comerciales o invasivos que frecuentemente se asocian a estas tecnologías. Asimismo, el desarrollo de estos sistemas desde una perspectiva contextualizada y adaptada a la realidad educativa ecuatoriana marca un precedente para futuras investigaciones e intervenciones en el ámbito nacional y regional. (Lorenzo-Rumbo et al., 2025)

Por todo lo expuesto, este estudio no solo resulta pertinente, sino también sumamente necesario y oportuno, en tanto responde a una problemática actual que afecta transversalmente a la juventud. Debido a la combinación del enfoque científico riguroso con herramientas tecnológicas de vanguardia, se busca generar un impacto positivo tanto a nivel institucional como comunitario.

Este impacto se traduce en la promoción de un uso más responsable, equilibrado y consciente de las tecnologías digitales, en el fortalecimiento del rol de la escuela como espacio de contención y orientación, ~~y~~ en la generación de nuevas políticas educativas basadas en evidencia. (Arias & Fernández, 2025)



CAPÍTULO I

MARCO TEÓRICO

1.1. Antecedentes de investigaciones relacionadas al tema presentado

En los últimos años, la creciente preocupación por los efectos del uso excesivo de redes sociales sobre la salud mental de los adolescentes ha motivado múltiples investigaciones tanto a nivel global como regional. La literatura científica ha comenzado a identificar una relación directa entre el tiempo prolongado dedicado a plataformas como Instagram, TikTok, Facebook y otras similares, y la aparición de trastornos emocionales, cognitivos y conductuales en jóvenes en etapa escolar (Bautista-Quispe et al., 2023).

En este contexto, los trabajos desarrollados por Kuss y Griffiths (2022) son especialmente relevantes, ya que permiten comprender la adicción a las redes sociales como una forma de adicción comportamental. Según estos autores, quienes desarrollan una dependencia hacia dichas plataformas manifiestan síntomas comparables entre los principales conductuales se encuentran la ansiedad ante la desconexión, la necesidad constante de interacción digital y la dificultad para controlar el tiempo de uso.

A nivel regional, América Latina también ha sido escenario de investigaciones que han corroborado esta problemática. Un estudio llevado a cabo en Colombia por González y Gutiérrez (2020) identificó que el 64% de los adolescentes encuestados empleaban redes sociales por un tiempo superior a las cuatro horas diarias. Estas conductas pueden derivar en un deterioro significativo del bienestar psicológico y del desempeño académico del estudiante, afectando su desarrollo integral.

En el caso específico de Ecuador, la investigación realizada en 2022 por la reconocida Universidad de Cuenca, la cual se enfocó en análisis del impacto del uso de redes sociales, particularmente en las redes más conocidas que son Instagram y TikTok, en estudiantes de secundaria. Los resultados de la investigación revelaron que cerca del 45% de los adolescentes encuestados presentaban signos de dependencia emocional relacionados con el uso excesivo de estas plataformas, destacando comportamientos como la necesidad constante de aprobación



mediante likes, el monitoreo compulsivo de notificaciones, y sentimientos de ansiedad o vacío cuando no se accedía a las redes. Esta realidad evidencia la urgencia de la implementación estrategias preventivas adaptadas al contexto educativo ecuatoriano. (Ramírez Acosta, 2022)

Por otro lado, la irrupción de tecnologías emergentes, como la inteligencia artificial, ha generado nuevas oportunidades para el análisis y abordaje de este tipo de fenómenos. En particular, los modelos de aprendizaje automático han sido utilizados para detectar patrones de comportamiento adictivo con resultados prometedores.

Investigaciones como la de Hussain et al. (2021) han demostrado que es posible entrenar algoritmos capaces de predecir el riesgo de adicción digital a partir del análisis de variables cuantificables, como el tiempo de uso, la frecuencia de interacción con contenidos, y factores psicoemocionales recolectados mediante encuestas estructuradas.

La justificación de la presente propuesta radica en la creciente necesidad de contar con herramientas metodológicas capaces de manejar grandes volúmenes de datos multivariantes y de identificar de forma más fácil y eficiente las relaciones complejas que existen entre factores que, en muchos casos, no son evidentes mediante análisis estadísticos tradicionales.

Los métodos tradicionales de estadística descriptiva y correlacional, aunque son útiles para establecer tendencias generales, presentan limitaciones al momento de captar interacciones no lineales o efectos combinados de múltiples predictores sobre una variable dependiente como la predisposición a la adicción digital. En este sentido, el aprendizaje automático se presenta como una alternativa poderosa para identificar estructuras ocultas, establecer jerarquías de variables y generar modelos con capacidad predictiva. (Lovón et al., 2024)


1.2. Bases teóricas

1.2.1. Adicción a redes sociales

La adicción a las redes sociales ha sido conceptualizada en diversos estudios como una manifestación específica de las adicciones comportamentales, en la cual el individuo desarrolla una relación patológica con el uso de plataformas digitales como Instagram, Facebook, TikTok, entre otras. Este tipo de adicción se caracteriza por la utilización excesiva, repetitiva y descontrolada de estas aplicaciones, generando una interferencia significativa en múltiples aspectos de la vida cotidiana del usuario, especialmente en los ámbitos personal, académico, social y emocional. (Alarcón Allain, 2021)

Este fenómeno no implica únicamente un alto consumo de tiempo en línea, sino también la aparición de síntomas psicológicos y conductuales que reflejan una pérdida de control sobre el uso de dichas plataformas. Entre los indicadores más conocidos se encuentra la ansiedad generada por la desconexión, también conocida como FOMO que significa Fear of Missing Out, misma que se manifiesta como una preocupación constante por perderse actualizaciones, interacciones o publicaciones relevantes. A esto se suma la necesidad compulsiva de revisar notificaciones, responder mensajes o interactuar en redes, lo cual con frecuencia interrumpe las rutinas normales de estudio, trabajo o descanso. (Castro Gutierrez, 2022)

Ilustración 1. Diagrama de adicción conductual en redes sociales



Nota: Fuente elaboración propia

La ilustración 1 muestra el modelo conceptual de la adicción conductual aplicada al uso de las redes sociales, destacando la interrelación entre los factores emocionales, cognitivos y comportamentales que intervienen en el desarrollo de la dependencia digital. El esquema permite visualizar cómo el uso intensivo y desregulado de las plataformas digitales puede derivar en una pérdida progresiva del control sobre el comportamiento, generar ansiedad ante la desconexión y producir efectos negativos en el bienestar emocional de los individuos.

Asimismo, muchas personas en especial los adolescentes que logran desarrollar esta dependencia por lo general, tienden a descuidar sus obligaciones académicas, laborales o sociales, priorizando la actividad en línea por encima de sus responsabilidades reales. Gracias a lo mencionado anteriormente, la situación puede derivar en un deterioro significativo del rendimiento académico, así como en la pérdida de interés por las relaciones interpersonales fuera del entorno virtual. Paralelamente, se han documentado efectos negativos en la salud mental, tales como trastornos del sueño, niveles elevados de estrés, depresión, irritabilidad, disminución de la autoestima y sensación de aislamiento, todos ellos asociados al uso excesivo y desregulado de las redes sociales. (Aliaga Paredes, 2023)

1.2.2. Adicción a redes sociales en adolescentes

La dependencia a las redes sociales en la población adolescente se ha consolidado como una problemática emergente de creciente interés en los ámbitos académico, educativo y psicológico, impulsada por la expansión acelerada del uso de plataformas digitales en este grupo etario. La adolescencia, al ser una etapa marcada por intensas transformaciones biológicas, emocionales, cognitivas y sociales, configura un periodo de especial susceptibilidad frente al desarrollo de conductas adictivas de tipo comportamental, entre las cuales destaca el uso problemático de las redes sociales. (Sümen & Evgin, 2021a)

En este proceso evolutivo, los adolescentes atraviesan una fase crucial de construcción de su identidad personal y social, donde la búsqueda de aceptación, pertenencia y validación externa adquiere una relevancia central. Las redes sociales, al proporcionar respuestas inmediatas a través de indicadores como “me gusta”, comentarios, visualizaciones y seguidores,



funcionan como potentes reforzadores positivos que incentivan la reiteración continua de la conducta digital. (Bilgin et al., 2020)

La literatura científica señala que la adicción a las redes sociales en adolescentes no se define únicamente por la cantidad de tiempo de conexión, sino por la incapacidad de controlar el uso, la dificultad para autorregular la frecuencia de acceso y la aparición de malestar emocional cuando no es posible interactuar con estas plataformas. Entre las manifestaciones más habituales se identifican la ansiedad ante la desconexión, la irritabilidad, la revisión compulsiva de notificaciones, la interferencia del uso digital en las obligaciones escolares y la pérdida de interés por actividades recreativas no vinculadas a la tecnología. Estos comportamientos evidencian patrones característicos de una adicción comportamental. (Marengo et al., 2022)

De igual manera, el uso problemático de redes sociales se asocia con afectaciones al bienestar psicológico de los adolescentes, reflejadas en mayores niveles de ansiedad, estrés, síntomas depresivos y una autoestima disminuida. En numerosos casos, las plataformas digitales son empleadas como mecanismos de regulación emocional, actuando como una vía de escape frente a emociones negativas como el aburrimiento, la tristeza o la frustración. Esta dependencia emocional del entorno digital refuerza un círculo de uso compulsivo, en el que el alivio temporal obtenido al conectarse fortalece la conducta adictiva en el largo plazo. (Adorjan & Ricciardelli, 2021)

Desde la perspectiva educativa, la adicción a las redes sociales constituye un reto relevante, dado que diversos estudios han establecido una relación directa entre el uso excesivo de estas plataformas y el deterioro del rendimiento académico. La exposición constante a estímulos digitales favorece la multitarea, limita la capacidad de concentración prolongada y afecta negativamente procesos cognitivos clave como la atención y la memoria. A ello se suma el impacto del uso nocturno de redes sociales en la calidad del sueño, lo que genera fatiga cognitiva y reduce el desempeño escolar durante la jornada educativa. (Keles et al., 2020)

Ilustración 2. Manifestaciones de la adicción a redes sociales en adolescentes y su impacto psicoeducativo



Nota: Fuente elaboración propia

La Ilustración 2 revela una problemática profunda la utilización desmedida de las redes sociales por adolescentes se manifiesta en síntomas de ansiedad y dependencia emocional. Observamos también, el impacto en el rendimiento académico y el bienestar general, todo esto entrelazado.

1.2.3 Componentes de la adicción a redes sociales

La adicción a las redes sociales ha sido analizada desde diversas perspectivas teóricas; no obstante, uno de los marcos conceptuales con mayor aceptación y respaldo empírico en la investigación científica es el desarrollado a partir de la Escala de Adicción a Redes Sociales de Bergen. Este instrumento se sustenta en el enfoque de la adicción comportamental y permite evaluar el uso problemático de las redes sociales mediante un conjunto de criterios claramente definidos, validados y ampliamente utilizados en estudios internacionales. (Keles et al., 2020)

La BSMAS concibe la adicción a las redes sociales como un fenómeno multidimensional, compuesto por seis elementos fundamentales que reflejan distintos aspectos

conductuales, emocionales y cognitivos asociados al uso excesivo de estas plataformas. Dichos componentes, analizados de manera integrada, facilitan la identificación de patrones de consumo digital disfuncionales y la evaluación sistemática del riesgo de dependencia. (Özyírmídokuz et al., 2025a)

La aplicación de este modelo resulta particularmente relevante en la población adolescente, ya que en esta etapa confluyen procesos de maduración psicoemocional, búsqueda de identidad y una alta exposición a entornos digitales. Esta interacción incrementa la probabilidad de desarrollar conductas problemáticas vinculadas al uso de redes sociales. En este sentido, la escala BSMAS ofrece una herramienta sólida para comprender y medir dichas dinámicas. A continuación, se presentan los seis componentes que estructuran este instrumento de evaluación.

Ilustración 3. Componentes de la adicción a redes sociales según la Escala Bergen (BSMAS)



Nota. Elaboración propia con base en el modelo de adicción conductual de la Bergen Social Media Addiction Scale (BSMAS).

La ilustración 3 expone de forma clara los seis componentes que estructuran la adicción a las redes sociales de acuerdo con la Escala de Bergen como lo es la saliencia, tolerancia, modificación del estado de ánimo, abstinencia, recaída y conflicto. Cada uno de estos elementos

representa una dimensión particular del comportamiento adictivo, evidenciando que la adicción digital trasciende el mero tiempo de uso y se configura a partir de la interacción de procesos emocionales, cognitivos y conductuales.

1.3 Factores psicosociales asociados al uso problemático de redes sociales

El uso problemático de las redes sociales en la adolescencia no puede interpretarse únicamente a partir del tiempo de conexión o de la frecuencia de acceso a las plataformas digitales, sino que debe abordarse como un fenómeno complejo y multidimensional en el que confluyen diversos factores psicosociales. Estos elementos inciden tanto en la predisposición al desarrollo de conductas adictivas como en la forma en que los adolescentes se relacionan con el entorno digital, convirtiéndose en aspectos clave para la identificación temprana de riesgos asociados a la adicción a las redes sociales. (Johar & Patel, 2024)

Entre los factores psicosociales de mayor relevancia se encuentran la autoestima, el estado emocional, los niveles de ansiedad, los hábitos de sueño y la percepción del contexto escolar. Durante la adolescencia la etapa crucial e importante en los jóvenes, la autoestima se encuentra en un proceso de formación y consolidación, lo que incrementa la sensibilidad frente a la opinión externa y a los mecanismos de validación social. En este escenario, las redes sociales, al ofrecer recompensas inmediatas mediante me gusta, comentarios y seguidores, pueden intensificar la dependencia emocional y fomentar una búsqueda constante de aprobación, elevando el riesgo de desarrollar un uso compulsivo. (Huang, 2022)

El estado emocional del adolescente constituye otro factor determinante en la aparición del uso problemático de redes sociales. Diversas investigaciones evidencian que niveles elevados de ansiedad, estrés o sintomatología depresiva se asocian con una mayor tendencia a utilizar estas plataformas como mecanismos de evasión o regulación emocional. En este contexto, las redes sociales funcionan como una estrategia de afrontamiento que proporciona un alivio temporal frente a emociones negativas; no obstante, este alivio inmediato refuerza el uso excesivo y contribuye a la consolidación de patrones adictivos a largo plazo. (Keles et al., 2020)

Ilustración 4. Factores psicosociales asociados al uso problemático de redes sociales en adolescentes



Nota: Fuente elaboración propia

La ilustración 4 sintetiza los principales factores psicosociales que influyen en el uso problemático de redes sociales en adolescentes, destacando la autoestima, el estado emocional, la ansiedad, los hábitos de sueño y el clima escolar. Estos factores interactúan de manera conjunta, incrementando la vulnerabilidad del adolescente al desarrollo de conductas adictivas digitales y afectando su bienestar emocional, académico y social.

1.4 Redes sociales y rendimiento académico en estudiantes de secundaria

El uso de las redes sociales se ha incorporado de forma significativa en la rutina diaria de los estudiantes de secundaria, consolidándose como uno de los principales medios de interacción social, comunicación y entretenimiento. Si bien estas plataformas pueden ofrecer beneficios como el acceso rápido a información y el fomento del aprendizaje colaborativo, su utilización excesiva o inadecuada se ha vinculado con efectos adversos sobre el rendimiento académico, particularmente cuando interfiere con los procesos cognitivos y las responsabilidades escolares. (Cebollero Salinas et al., 2021)



Uno de los impactos más relevantes del uso intensivo de redes sociales en el ámbito académico está relacionado con la disminución de la atención y la capacidad de concentración. La exposición permanente a estímulos digitales, notificaciones y contenidos breves favorece la realización de múltiples tareas de manera simultánea, lo que dificulta el mantenimiento de una atención sostenida, necesaria para actividades como la lectura comprensiva, la resolución de problemas y el estudio autónomo. Esta fragmentación atencional afecta el procesamiento profundo de la información y limita la consolidación de aprendizajes significativos. (Copez-Lonzoy et al., 2023)

De igual manera, el uso problemático de redes sociales repercute negativamente en la gestión del tiempo académico. Los estudiantes que dedican una cantidad excesiva de horas a estas plataformas suelen presentar dificultades para planificar sus actividades escolares, cumplir con tareas y prepararse adecuadamente para evaluaciones. La procrastinación asociada al uso de redes sociales puede generar retrasos reiterados en el cumplimiento de las obligaciones académicas, incrementando los niveles de estrés y afectando el desempeño escolar. (Aguilar, 2024)

Otro factor de gran relevancia es el impacto del uso nocturno de redes sociales sobre los hábitos de sueño de los estudiantes de secundaria. La interacción digital antes de dormir altera la calidad y la duración del descanso, provocando fatiga, somnolencia diurna y una disminución del rendimiento cognitivo durante la jornada escolar. La privación del sueño se asocia con dificultades en la memoria, la atención y la regulación emocional, capacidades fundamentales para un proceso de aprendizaje eficaz. (Bedoya Denegri, 2021)

Asimismo, el uso excesivo de redes sociales puede incidir en la motivación académica y en la valoración que los estudiantes otorgan a las actividades escolares. La preferencia por la gratificación inmediata que brindan las plataformas digitales puede disminuir el interés por tareas académicas que requieren esfuerzo sostenido, disciplina y concentración prolongada. En algunos casos, la interacción virtual llega a priorizarse por encima del compromiso con el

proceso educativo, lo que se traduce en una menor participación en el aula y un rendimiento académico inferior. (Chapilliquen Lopez, 2023)

Desde una perspectiva educativa, resulta imprescindible analizar la relación que existe entre el uso de redes sociales y el rendimiento académico considerando tanto los riesgos como las oportunidades que estas herramientas digitales ofrecen. La identificación de patrones de uso problemático permite diseñar estrategias pedagógicas orientadas a promover un uso responsable de la tecnología, fortalecer las habilidades de autorregulación y fomentar un equilibrio saludable entre la vida digital y las exigencias académicas. (Rufino Vargas, 2021)

Ilustración 5. Impacto del uso de redes sociales en el rendimiento académico de estudiantes de secundaria



Nota: Fuente elaboración propia

La ilustración 5 evidencia la forma en la que el uso intensivo de redes sociales influye negativamente en el rendimiento académico de los estudiantes de secundaria, logrando así evidenciar problemas de concentración, alteraciones del sueño y fatiga cognitiva. Estos factores contribuyen a un bajo desempeño escolar, reforzando la relación entre el uso problemático de plataformas digitales y las dificultades en el proceso de aprendizaje.



1.5 Aprendizaje de máquina aplicado al análisis del comportamiento digital

El aprendizaje de máquina se constituye como un campo central de la inteligencia artificial, enfocado en el diseño de algoritmos capaces de aprender a partir de los datos e identificar patrones, relaciones y tendencias sin requerir una programación explícita para cada caso. En el ámbito del comportamiento digital, su relevancia se ha incrementado de manera notable como consecuencia del crecimiento acelerado del volumen de datos generados por la interacción de los usuarios con plataformas digitales, redes sociales y entornos virtuales. (Salas Blas, 2024)

Analizar el comportamiento digital con ayuda de técnicas de aprendizaje automático abre la puerta a superar las limitaciones de los métodos estadísticos clásicos, sobre todo cuando se trata de contextos complejos, donde intervienen muchas variables que se relacionan entre sí de forma no lineal. En estudios sobre el uso problemático de las redes sociales, este tipo de técnicas ayuda a entender conductas complejas, identificar perfiles de riesgo y detectar a tiempo posibles patrones adictivos, lo que permite tener una visión más amplia y completa del fenómeno. (Bautista-Quispe et al., 2023)

En el contexto educativo, el aprendizaje de máquina ha sido ampliamente utilizado para examinar patrones de uso de tecnologías digitales, rendimiento académico y variables de bienestar psicosocial en estudiantes. A partir del procesamiento de datos obtenidos mediante encuestas, registros de actividad y escalas psicométricas, es posible identificar grupos de estudiantes con características similares, analizar la interacción entre variables y construir modelos explicativos que respalden la toma de decisiones pedagógicas. (Ramírez Acosta, 2022)

De manera general, las técnicas de aprendizaje de máquina se agrupan en aprendizaje supervisado, no supervisado y aprendizaje por refuerzo. En el análisis del comportamiento digital, el aprendizaje no supervisado adquiere un papel destacado, ya que permite descubrir patrones latentes en los datos sin la necesidad de contar con etiquetas previas. Herramientas

como el análisis exploratorio de datos, la reducción de dimensionalidad y los métodos de agrupamiento o clústeres facilitan la segmentación de usuarios y la identificación de estructuras subyacentes en conjuntos de datos complejos, como aquellos vinculados a la adicción a las redes sociales. (Soria & Villegas-Villacres, 2024)

Adicionalmente, el aprendizaje de máquina posibilita el análisis de las relaciones existentes entre variables psicosociales, emocionales y académicas, permitiendo comprender cómo estas interactúan en la configuración del comportamiento digital de los estudiantes. La integración de estas técnicas con herramientas de análisis y visualización de datos, como Power BI, fortalece la interpretación de los resultados y facilita la comunicación de los hallazgos de forma clara y accesible para distintos actores del ámbito educativo. (Alarcón Allain, 2021)

Ilustración 6. Aplicación del aprendizaje de máquina en el análisis del comportamiento digital en contextos educativos



Nota: Fuente elaboración propia

La ilustración 6 representa la integración del aprendizaje de máquina en el análisis del comportamiento digital, mostrando cómo los datos generados por el uso de redes sociales son procesados mediante algoritmos para identificar patrones, realizar agrupamientos y apoyar



procesos de clasificación y predicción. Este enfoque permite comprender conductas complejas y sustentar la toma de decisiones educativas orientadas a la prevención del uso problemático de redes sociales.

1.5.2 Aprendizaje no supervisado en estudios educativos

El aprendizaje no supervisado representa una de las categorías fundamentales del aprendizaje de máquina y se distingue por el análisis de conjuntos de datos que carecen de etiquetas o clasificaciones previamente establecidas. A diferencia del aprendizaje supervisado, este tipo de enfoque no busca predecir una variable en particular, sino más bien descubrir patrones, estructuras internas, relaciones entre variables y grupos naturales dentro de los datos. En el campo educativo, ha ganado mucha relevancia por su capacidad para analizar fenómenos complejos, con muchas dimensiones y gran diversidad, como suele ocurrir en los entornos escolares. (Castro Gutierrez, 2022)

En la investigación educativa, el aprendizaje no supervisado se utiliza principalmente con fines exploratorios, permitiendo analizar comportamientos, perfiles y dinámicas que no siempre son detectables mediante métodos tradicionales de análisis estadístico. A partir de datos obtenidos de encuestas, escalas psicométricas, registros académicos o plataformas digitales, estas técnicas facilitan la identificación de grupos de estudiantes con características similares sin imponer categorías predefinidas. Este enfoque resulta especialmente pertinente cuando se examinan variables psicosociales, emocionales y conductuales, cuya interacción suele ser compleja, no lineal y difícil de modelar mediante enfoques clásicos. (Laveriano Varas, 2023)

Una de las aplicaciones más comunes del aprendizaje no supervisado en educación es la segmentación de estudiantes mediante técnicas de agrupamiento o clustering. Estos métodos permiten organizar a los estudiantes en grupos homogéneos con base en patrones compartidos de comportamiento, rendimiento académico, uso de tecnologías digitales o bienestar emocional. En investigaciones relacionadas con el uso problemático de redes sociales, por ejemplo, el análisis de clústeres posibilita la identificación de perfiles diferenciados como usuarios

moderados, intensivos o con alto riesgo de conducta adictiva sin necesidad de definir estas categorías de manera anticipada. (Aliaga Paredes, 2023)

Otra aplicación relevante es la reducción de dimensionalidad, cuyo propósito es simplificar conjuntos de datos complejos conservando la información más significativa. Técnicas como el análisis de componentes principales (PCA) permiten identificar las variables con mayor influencia en un fenómeno educativo determinado, reduciendo la redundancia de información y facilitando la interpretación de los resultados. Este tipo de análisis resulta especialmente útil cuando se trabaja con escalas psicométricas extensas o con múltiples indicadores relacionados con el comportamiento digital y el rendimiento académico. (Ccorahua Estrada, 2023)

Ilustración 7. Aplicación del Aprendizaje No Supervisado en Estudios Educativos



Nota: Fuente elaboración propia

La ilustración 7 evidencia de manera sintética el uso del aprendizaje no supervisado en el ámbito educativo, destacando su capacidad para analizar datos sin etiquetas predefinidas provenientes de encuestas, registros académicos, escalas psicométricas y el uso de tecnologías digitales. A través de técnicas como el clustering y la reducción de dimensionalidad (PCA), se



visualiza cómo es posible identificar patrones ocultos, segmentar estudiantes en perfiles con características similares y detectar tendencias relevantes en el comportamiento académico y digital.

1.5.3 Ventajas del aprendizaje de máquina frente a métodos tradicionales

El aprendizaje de máquina presenta ventajas sustanciales frente a los métodos tradicionales de análisis estadístico, particularmente en el estudio de fenómenos complejos y multidimensionales como el comportamiento digital y el uso problemático de redes sociales en contextos educativos. Su principal aporte radica en la capacidad para analizar grandes volúmenes de datos y revelar patrones complejos que, en muchos casos, no pueden ser identificados mediante enfoques clásicos basados en supuestos lineales o relaciones previamente establecidas. (Arias & Fernández, 2025)

Una de las fortalezas más destacadas del aprendizaje de máquina es su capacidad para modelar relaciones no lineales e interacciones simultáneas entre múltiples variables. A diferencia de los métodos tradicionales, que suelen requerir supuestos estrictos sobre la distribución de los datos y la forma de las relaciones entre variables, los algoritmos de aprendizaje de máquina se adaptan de manera flexible a estructuras de datos complejas, permitiendo capturar dinámicas reales del comportamiento humano que difícilmente pueden representarse mediante modelos estadísticos convencionales. (Javier López-Fernández et al., 2025)

Asimismo, el aprendizaje de máquina se caracteriza por un enfoque exploratorio y adaptable. En particular, las técnicas de aprendizaje no supervisado permiten examinar los datos sin la imposición de categorías, etiquetas o hipótesis previas, favoreciendo el descubrimiento de patrones latentes, perfiles emergentes y agrupamientos naturales. Esta característica resulta especialmente pertinente en investigaciones educativas, donde las variables psicosociales y conductuales presentan una alta heterogeneidad y no siempre se ajustan a clasificaciones rígidas. (Brand & García, 2023)

Otra ventaja significativa es su escalabilidad y capacidad de automatización. Los modelos de aprendizaje de máquina pueden actualizarse y recalibrarse de forma continua conforme se incorporan nuevos datos, lo que posibilita análisis dinámicos y actualizados en el tiempo. En contraste, los métodos tradicionales tienden a basarse en análisis estáticos y procesos manuales, lo que limita su aplicabilidad en entornos educativos caracterizados por cambios constantes y grandes flujos de información. (Best, 2024)

Adicionalmente, la integración del aprendizaje de máquina con herramientas avanzadas de visualización de datos facilita la interpretación y comunicación de los resultados analíticos. La representación gráfica de patrones, clústeres y tendencias contribuye a que docentes, orientadores y responsables de la gestión educativa comprendan de manera más clara los hallazgos, favoreciendo su aplicación práctica en la toma de decisiones pedagógicas.

Ilustración 8. Ventajas del Aprendizaje de Máquina frente a los Métodos Tradicionales en el Análisis Educativo



Nota: Fuente elaboración propia

La ilustración 8 compara de forma visual y conceptual los métodos tradicionales de análisis de datos con el enfoque del aprendizaje de máquina, destacando las principales ventajas de este último. Se evidencia cómo el aprendizaje de máquina permite modelar relaciones no lineales, identificar patrones complejos y adaptarse dinámicamente a grandes volúmenes de



datos, superando las limitaciones de los enfoques estadísticos clásicos, que suelen basarse en supuestos rígidos y análisis estáticos

1.6 Modelos de aprendizaje de máquina utilizados en la detección de adicción digital

La detección de la adicción digital, específicamente del uso problemático de redes sociales en adolescentes, ha avanzado de manera significativa gracias a la aplicación de modelos de aprendizaje de máquina no supervisado. Este enfoque permite analizar grandes volúmenes de datos conductuales, emocionales y psicosociales sin la necesidad de etiquetas o categorías previamente definidas, lo que resulta especialmente pertinente en contextos educativos caracterizados por la diversidad y complejidad del comportamiento estudiantil. En este sentido, el aprendizaje no supervisado se consolida como una herramienta clave para la identificación exploratoria de perfiles de riesgo y para la comprensión integral del fenómeno de la adicción digital. (Boer et al., 2020)

El aprendizaje de máquina no supervisado se orienta al descubrimiento de estructuras latentes y relaciones internas presentes en los datos, sin imponer supuestos previos sobre la pertenencia de los individuos a categorías específicas. En estudios relacionados con el uso problemático de redes sociales, este enfoque permite identificar patrones de comportamiento digital a partir de variables psicosociales, emocionales y académicas, facilitando la caracterización de distintos perfiles de estudiantes sin recurrir a diagnósticos preestablecidos. (Abdel Wahed & Wahed, 2025)

Dentro de este enfoque, los métodos de agrupamiento no supervisado, como el clustering jerárquico, resultan especialmente útiles para segmentar a la población estudiantil en grupos con características similares. Estas técnicas permiten analizar la proximidad y similitud entre los estudiantes, generando agrupamientos que reflejan distintos niveles de intensidad en el uso de redes sociales y en la presencia de factores de riesgo asociados. El análisis de estos grupos facilita la comprensión de la heterogeneidad del comportamiento digital en el entorno

educativo y aporta información relevante para el diseño de estrategias preventivas diferenciadas.

(Noorulfakhri et al., 2025)

Asimismo, los métodos de reducción de dimensionalidad, como lo es el Análisis de Componentes Principales (PCA), desempeñan un papel fundamental en el aprendizaje no supervisado aplicado a la educación. Estas técnicas permiten simplificar conjuntos de datos complejos que integran múltiples variables psicosociales y académicas, identificando los factores con mayor peso explicativo en el comportamiento digital y reduciendo la redundancia de información. La aplicación de PCA contribuye a mejorar la interpretabilidad de los resultados y a facilitar el análisis posterior de los agrupamientos identificados. (Timarán Pereira, 2008)

Ilustración 9. Modelos de Aprendizaje de Máquina no Supervisados para la Detección de la Adicción Digital en Estudiantes



Nota: Fuente elaboración propia

La ilustración 9 presenta de manera integrada los principales modelos de aprendizaje de máquina utilizados en la detección de la adicción digital, destacando su aplicación en el análisis del uso problemático de redes sociales en adolescentes. Se visualizan enfoques de aprendizaje supervisado, no supervisado y aprendizaje profundo, mostrando cómo cada uno contribuye a la identificación de patrones conductuales, emocionales y psicosociales asociados al riesgo de adicción digital.

1.6.1 Análisis Exploratorio de Datos (EDA)

El Análisis Exploratorio de Datos (Exploratory Data Analysis – EDA) constituye una fase esencial dentro del proceso de análisis de datos y del aprendizaje de máquina no supervisado, cuyo propósito principal es comprender la estructura, las características y el comportamiento del conjunto de datos antes de la aplicación de técnicas analíticas más avanzadas. En investigaciones orientadas a la detección de adicción digital, el EDA proporciona una visión inicial del fenómeno, permitiendo identificar patrones preliminares y detectar posibles inconsistencias que podrían comprometer la validez de los resultados. (Farhat et al., 2020)

En el ámbito educativo, el EDA se emplea para examinar información proveniente de encuestas, escalas psicométricas como la Escala Bergen de Adicción a Redes Sociales (BSMAS), registros académicos y variables psicosociales asociadas al comportamiento digital de los estudiantes. Esta etapa incluye el análisis de estadísticas descriptivas, tales como medias, medianas, desviaciones estándar y distribuciones de frecuencia, las cuales permiten caracterizar el perfil general de la población estudiada y comprender la tendencia central y la variabilidad de las variables analizadas. (Li et al., 2021)

Una de las funciones más relevantes del EDA es la identificación de valores atípicos, datos faltantes y posibles errores de registro. En investigaciones que exponen el uso problemático de redes sociales, el presente proyecto cobra gran relevancia, ya que los errores en las escalas o datos incompletos pueden afectar la forma en que se interpretan los patrones de conducta. (Rodríguez Gómez, 2023)

Ilustración 10. Análisis Exploratorio de Datos (EDA) como Base del Estudio de la Adicción Digital



Nota: Fuente elaboración propia

La ilustración 10 representa el papel central del Análisis Exploratorio de Datos (EDA) dentro de los procesos de aprendizaje de máquina aplicados a la detección de la adicción digital en contextos educativos. Se destacan las principales fuentes de información, como encuestas, escalas psicométricas, registros académicos y variables psicosociales, así como las herramientas analíticas empleadas para comprender la estructura y calidad de los datos.

1.6.2 Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales (Principal Component Analysis – PCA) es una técnica estadística perteneciente al aprendizaje de máquina no supervisado, ampliamente empleada para la reducción de dimensionalidad en conjuntos de datos complejos. Su finalidad principal consiste en transformar un conjunto amplio de variables correlacionadas en un número reducido de nuevas variables no correlacionadas entre sí, denominadas componentes principales, los cuales concentran la mayor proporción posible de la variabilidad contenida en los datos originales. (Ruiz Pimiento et al., 2021)

En investigaciones educativas orientadas al análisis del uso problemático de redes sociales, el PCA adquiere especial relevancia debido a la diversidad y cantidad de variables involucradas, tales como factores psicosociales, emocionales, académicos y conductuales.




Instrumentos psicométricos como la Escala Bergen de Adicción a Redes Sociales (BSMAS), junto con cuestionarios relacionados con autoestima, estado emocional, hábitos de sueño y percepción del clima escolar, generan conjuntos de datos de alta dimensionalidad que pueden dificultar su análisis e interpretación directa. En este contexto, el PCA permite sintetizar la información sin perder los patrones esenciales del fenómeno estudiado. (Vera Machuca, 2025)

Desde una perspectiva metodológica, el PCA identifica combinaciones lineales de las variables originales que explican la mayor parte de la varianza total del conjunto de datos. El primer componente principal concentra la mayor cantidad de información, mientras que los componentes posteriores explican proporciones decrecientes de la variabilidad restante. Este proceso facilita la identificación de factores subyacentes relevantes en el comportamiento digital de los estudiantes, reduciendo la redundancia y el ruido presentes en los datos. (Torres & Cardenas, 2021)

En el análisis del uso problemático de redes sociales, la aplicación del PCA permite identificar dimensiones latentes asociadas a la adicción digital, como la dependencia emocional, la dificultad para el control del uso, la interferencia con las actividades académicas o las deficiencias en la regulación afectiva. Al agrupar variables relacionadas dentro de componentes principales, se obtiene una visión más clara, estructurada y comprensible de la interacción entre los distintos factores psicosociales que influyen en la conducta adictiva. (Kouvchinove Voronine, 2024)

Asimismo, el PCA desempeña un papel estratégico como etapa previa a la aplicación de otras técnicas de aprendizaje de máquina no supervisado, como el análisis de clústeres. La reducción de dimensionalidad contribuye a mejorar la eficiencia computacional de los modelos, disminuir el riesgo de sobreajuste y aumentar la interpretabilidad de los resultados. Esta ventaja resulta particularmente relevante en contextos educativos, donde se requiere combinar rigor analítico con claridad en la presentación y comprensión de los hallazgos. (Chang et al., 2020)

Ilustración 11. Análisis de Componentes Principales (PCA) aplicado a la Detección de la Adicción Digital



Nota: Fuente elaboración propia

La ilustración 11 representa de forma visual el proceso del Análisis de Componentes Principales (PCA) como técnica de reducción de dimensionalidad aplicada al estudio de la adicción digital. Se muestra cómo un conjunto de datos originales con alta dimensionalidad, compuesto por múltiples variables psicosociales, emocionales y académicas, es transformado en un número reducido de componentes principales que concentran la información más relevante.

1.6.3 Análisis de clústeres


El análisis de clústeres (cluster analysis) es una técnica de aprendizaje de máquina no supervisado cuyo propósito fundamental es agrupar observaciones en conjuntos homogéneos, denominados clústeres, de manera que los elementos dentro de un mismo grupo presenten un alto grado de similitud entre sí y, simultáneamente, una clara diferenciación respecto a los elementos pertenecientes a otros grupos. A diferencia de los enfoques supervisados, esta técnica no requiere etiquetas previas, lo que la convierte en una herramienta especialmente adecuada para la exploración de fenómenos complejos y heterogéneos, como el comportamiento digital y el uso problemático de redes sociales en adolescentes. (Hasan et al., 2025)

En el contexto educativo, el análisis de clústeres permite identificar perfiles de estudiantes a partir de la integración de múltiples variables psicosociales, emocionales, académicas y conductuales. En estudios orientados a la adicción digital, esta técnica facilita la segmentación de los estudiantes según patrones de uso de redes sociales, niveles de riesgo, estados emocionales y desempeño académico, sin imponer categorías predefinidas. De este modo, se obtiene una comprensión más natural, flexible y representativa de las dinámicas subyacentes al uso problemático de la tecnología. (Flores López, 2020)

Dentro de las técnicas no supervisadas empleadas en este tipo de análisis, el clustering jerárquico ocupa un lugar relevante debido a su capacidad para organizar los datos en una estructura jerárquica que refleja distintos niveles de similitud entre las observaciones. Este método permite explorar la relación progresiva entre los grupos mediante representaciones gráficas como los dendrogramas, los cuales facilitan la visualización de la formación de clústeres y la identificación de perfiles diferenciados de comportamiento digital. (Monreal-Pitones, 2022)

El clustering jerárquico resulta especialmente útil cuando el objetivo del análisis es comprender la estructura interna de los datos y examinar la proximidad entre los distintos perfiles identificados, sin necesidad de definir previamente el número de grupos. Esta característica lo hace particularmente apropiado para investigaciones educativas, donde el comportamiento estudiantil presenta una elevada diversidad y no siempre responde a clasificaciones rígidas o preestablecidas. (Whelan et al., 2020)

Ilustración 12. Análisis de Clústeres para la Identificación de Perfiles de Uso Digital en Estudiantes



Nota: Fuente elaboración propia

La ilustración 12 muestra de manera clara la aplicación del análisis de clústeres como técnica de aprendizaje no supervisado para segmentar a los estudiantes según su comportamiento digital. A partir de variables psicosociales y patrones de uso de redes sociales, se representan distintos grupos o clústeres, como usuarios moderados, usuarios intensivos y estudiantes con alto riesgo de adicción digital, evidenciando la diversidad de perfiles presentes en el contexto educativo

1.6.4 Reglas de asociación

Las reglas de asociación constituyen una técnica de aprendizaje de máquina no supervisado cuyo propósito es identificar relaciones frecuentes, patrones de coocurrencia y dependencias significativas entre variables dentro de grandes conjuntos de datos. Este enfoque permite descubrir qué características tienden a presentarse de manera conjunta y con qué frecuencia, extrayendo conocimiento implícito sin la necesidad de contar con etiquetas o categorías previamente definidas. Tradicionalmente empleadas en la minería de datos, las reglas de asociación han adquirido una creciente relevancia en investigaciones educativas y en el análisis del comportamiento digital. (Cedeno-Moreno & Vargas, 2020)

En el estudio de la adicción digital y el uso problemático de redes sociales en adolescentes, las reglas de asociación son aquellas que permiten identificar combinaciones frecuentes de factores psicosociales, emocionales y conductuales que suelen aparecer al mismo tiempo. Este enfoque ayuda a detectar patrones relacionales, como la presencia conjunta de baja autoestima, problemas en los hábitos de sueño y un uso excesivo de redes sociales, los cuales podrían estar ligados a un mayor riesgo de desarrollar conductas adictivas. Este tipo de análisis contribuye a comprender cómo la interacción entre múltiples variables influye en la configuración del comportamiento digital problemático. (Díaz-Ramírez, 2021)

Las reglas de asociación se formulan generalmente bajo la estructura condicional si A, entonces B, donde A y B representan conjuntos de variables o condiciones observadas en los datos. Para evaluar la relevancia de estas reglas se emplean métricas fundamentales como el soporte, la confianza y el lift. El soporte indica la frecuencia con la que una determinada combinación de variables aparece en el conjunto de datos; la confianza mide la probabilidad de que ocurra el consecuente B cuando se presenta el antecedente A; mientras que el lift evalúa el grado de dependencia entre ambas partes de la regla, permitiendo identificar asociaciones significativas que superan lo esperado por azar. (Palacios Sáez-Guinea & López Ruiz, 2022)

En el ámbito educativo, la aplicación de reglas de asociación resulta especialmente útil para el análisis de información proveniente de encuestas, escalas psicométricas y registros de comportamiento digital. Esta técnica permite identificar patrones recurrentes entre variables como ansiedad, estado emocional, hábitos de sueño, rendimiento académico, clima escolar y uso de redes sociales, ofreciendo una visión integrada y relacional del fenómeno de la adicción digital. Asimismo, complementa los hallazgos obtenidos mediante otras técnicas no supervisadas, como el Análisis de Componentes Principales y el análisis de clústeres. (Dhanalakshmi et al., 2025)

Ilustración 13. Reglas de Asociación para la Identificación de Patrones de Riesgo en la Adicción Digital



Nota: Fuente elaboración propia

La ilustración 13 representa de forma visual el uso de las reglas de asociación como técnica de aprendizaje no supervisado para descubrir relaciones frecuentes entre variables psicosociales y conductuales vinculadas a la adicción digital. Se ejemplifica cómo combinaciones de factores como el uso nocturno de redes sociales y la baja autoestima pueden asociarse con un mayor riesgo de adicción digital, destacando la lógica “si-entonces” propia de este enfoque analítico

CAPÍTULO II

MARCO INVESTIGATIVO

2.1 Tipo de Investigación

La presente investigación se clasifica como aplicada, en tanto se orienta directamente a la solución de un problema concreto, en este caso relacionado con la identificación y el análisis del comportamiento digital de los estudiantes de nivel secundario. (Javier López-Fernández et al., 2025)

En lo que respecta al desarrollo de modelos de aprendizaje de máquina en la detección de patrones de adicción a las redes sociales en estudiantes de secundaria, se adopta el marco metodológico OSEMN de la Ciencia de Datos (Obtain, Scrub, Explore, Model, Interpret), el cual establece un procedimiento sistemático que incluye la obtención de la información, su depuración, la exploración inicial, la construcción de modelos y la posterior interpretación de los resultados. (Bois & Jesus, 2025)

La estructura de OSEMN asegura un abordaje riguroso que permite transformar grandes volúmenes de datos en conocimiento significativo, útil para comprender no solo la frecuencia y la forma de uso de las redes sociales, sino también las implicaciones psicosociales que este fenómeno conlleva en el ámbito educativo. (Blanco & Pirela, 2022)

Al mismo tiempo, el estudio posee un marcado carácter bibliográfico, ya que se sustenta en la revisión y análisis de literatura científica reciente que proporciona los fundamentos teóricos y documentales necesarios para contextualizar el problema. La recopilación y examen crítico de investigaciones previas permiten describir con mayor claridad los hábitos digitales de los adolescentes, las manifestaciones de la adicción a redes sociales y las variables psicosociales asociadas, como la autoestima, el estado emocional, la percepción del entorno escolar y las habilidades sociales. (Haro Sarango et al., 2024)

De igual forma, la investigación se inscribe en un enfoque no experimental de corte transversal con enfoque analítico basado en Ciencia de Datos, dado que incorpora métodos propios de la Ciencia de Datos para la validación de los modelos planteados, verificando su



capacidad predictiva y explicativa frente al fenómeno de la adicción digital. El carácter experimental se expresa en la puesta en práctica de algoritmos de aprendizaje automático, cuyo rendimiento se contrasta mediante métricas específicas que garantizan la solidez de los hallazgos y la posibilidad de replicarlos en otros contextos educativos. (Ordoñez-Pacheco, 2025)

De manera complementaria, la aplicación de métricas y técnicas estadísticas avanzadas facilita la validación de hipótesis y la identificación de tendencias emergentes, garantizando que los resultados no solo tengan validez interna, sino también aplicabilidad práctica en la formulación de estrategias pedagógicas y de intervención. En concordancia con lo señalado por Klimenko et al. (2021), este enfoque permite fundamentar la toma de decisiones educativas en evidencias cuantificables y verificables, reduciendo la subjetividad y aumentando la confiabilidad del proceso investigativo.

2.2. Métodos de Investigación

El presente estudio se fundamenta en la aplicación del método científico inductivo-deductivo como enfoque central para el desarrollo de la investigación. Este método combina dos procesos complementarios: la inducción, que parte de la observación y el análisis de casos particulares para establecer generalizaciones o patrones recurrentes; y la deducción, que permite formular hipótesis a partir de teorías previamente establecidas y someterlas a verificación empírica. (Sümen & Evgin, 2021b)

En una primera etapa, se procede a la observación y análisis de comportamientos digitales en estudiantes de nivel secundario, identificando signos frecuentes relacionados con el uso excesivo de redes sociales, tales como la pérdida de control, la interferencia en la vida cotidiana y la necesidad compulsiva de mantenerse conectados. A partir de estas observaciones, se realiza un proceso inductivo que permite establecer tendencias generales y patrones conductuales vinculados con la adicción digital. (Sümen & Evgin, 2021b)



Posteriormente, con base en la evidencia recogida y el sustento teórico existente, se plantea una hipótesis central: existe una relación significativa entre el uso excesivo de redes sociales y la manifestación de indicadores psicosociales asociados a la adicción digital.

Esta hipótesis es sometida a prueba mediante un proceso deductivo, que implica la formulación de supuestos específicos y su contrastación a través de técnicas cuantitativas de recolección y análisis de datos. Esta estructura metodológica, que articula lo inductivo y lo deductivo, permite abordar el fenómeno de manera integral, lógica y secuencial (Mena et al., 2022).

De forma complementaria, se incorpora el análisis de datos mediante modelos de aprendizaje de máquina, con el fin de fortalecer la capacidad analítica del estudio y añadir una dimensión tecnológica al abordaje del problema. Este enfoque, propio del campo de la inteligencia artificial, permite el desarrollo de modelos computacionales capaces de aprender a partir de datos observados y generar predicciones automatizadas sobre conductas futuras. En este contexto, los algoritmos serán entrenados con variables psicosociales y conductuales obtenidas en encuestas aplicadas a estudiantes, con el objetivo de identificar perfiles de riesgo asociados a comportamientos adictivos en el uso de redes sociales. (Caner et al., 2022a)

2.3. Herramientas de recolección de datos

2.3.1. Encuesta

Para la recolección de datos primarios en el presente estudio, se empleó la técnica de la encuesta estructurada como herramienta metodológica principal, con el objetivo de obtener información cuantitativa válida y confiable directamente de la población objeto de análisis. En particular, se aplicó la Escala Bergen de Adicción a Redes Sociales BSMAS, por sus siglas en inglés, un instrumento ampliamente reconocido y validado a nivel internacional en diversos contextos culturales y lingüísticos. (Meyerhofer-Parra & González-Martínez, 2024a)

Esta escala ha demostrado contar con sólidas propiedades psicométricas, y fue seleccionada por su capacidad para evaluar de forma precisa los seis componentes esenciales



que configuran las conductas adictivas relacionadas con el uso de redes sociales: saliencia, tolerancia, modificación del estado de ánimo, recaída, abstinencia y conflicto. (Cardenas Beraun, 2020)

La saliencia hace referencia al grado de centralidad que ocupan las redes sociales en la vida del individuo, mientras que la tolerancia alude a la necesidad de incrementar el tiempo de uso para lograr los mismos efectos emocionales. Por su parte, la modificación del estado de ánimo evidencia el uso de estas plataformas como estrategia para afrontar emociones negativas o buscar placer. La recaída se relaciona con la dificultad de mantener el control sobre el uso, especialmente después de intentos fallidos de moderación. (Ramírez Acosta, 2022)

La abstinencia describe la aparición de malestar psicológico al verse privado del acceso; y el conflicto se refiere a los problemas interpersonales, académicos o familiares derivados del uso excesivo de redes sociales. (Valencia-Ortiz et al., 2023)

Con el fin de enriquecer el análisis y aportar una visión más amplia e integral del fenómeno estudiado, el instrumento fue complementado con una serie de preguntas adicionales de elaboración propia, orientadas a explorar diversas variables psicosociales relevantes que podrían actuar como factores de riesgo o de protección frente a la adicción digital. (Meyerhofer-Parra & González-Martínez, 2024b)

Entre estas variables se encuentran la autoestima, entendida como la percepción subjetiva del propio valor; el clima escolar, referido a la calidad de las relaciones e interacciones dentro del entorno educativo; los hábitos de sueño, especialmente en lo que respecta a la duración y calidad del descanso nocturno; y el nivel de ansiedad, medido a través de indicadores de tensión emocional y preocupación persistente. (Arrivillaga et al., 2024)

La encuesta fue diseñada en formato digital, utilizando plataformas en línea que permitieran su aplicación masiva, rápida y accesible, minimizando barreras geográficas o logísticas. Este formato no solo facilitó el proceso de distribución y recolección de datos, sino que también optimizó el procesamiento estadístico posterior, gracias a la exportación automática

de las respuestas a bases de datos estructuradas. Además, se garantizó en todo momento el cumplimiento de principios éticos fundamentales en la investigación social, asegurando a los participantes el anonimato, la confidencialidad de la información recolectada y el consentimiento informado previo a su participación voluntaria. (González Alcántara et al., 2021)

2.4. Fuentes de Información de datos

2.4.1. Fuentes primarias - Fuentes secundarias

Para el desarrollo riguroso y fundamentado del presente estudio, se recurrió a un proceso sistemático de recolección y análisis de información, basado en la utilización de fuentes de datos clasificadas en dos categorías fundamentales: fuentes primarias y fuentes secundarias. Esta distinción metodológica responde tanto a criterios epistemológicos como operativos, ~~y y~~ permite organizar el cuerpo informativo conforme a su origen, grado de originalidad y función dentro del proceso investigativo. (Al-Samarraie et al., 2021)

En primer lugar, se consideran fuentes primarias todos aquellos datos empíricos obtenidos de manera directa, mediante la aplicación de un instrumento de encuesta estructurada elaborado ex profeso para este estudio. Este cuestionario fue aplicado a estudiantes de nivel secundario pertenecientes a diversas instituciones educativas situadas en la ciudad de Manta, provincia de Manabí, Ecuador. La muestra fue seleccionada bajo criterios de representatividad demográfica, nivel educativo y accesibilidad, garantizando así una recolección de datos pertinente, contextualizada y alineada con los objetivos generales y específicos de la investigación. (Boer et al., 2020)

La encuesta tuvo como eje central la Escala Bergen de Adicción a Redes Sociales, la cual es reconocida a nivel internacional por su validez para medir comportamientos adictivos en entornos digitales, especialmente en adolescentes. Además, se incluyeron preguntas adicionales que permitieron explorar variables psicosociales importantes, como la autoestima, la calidad y duración del sueño, los niveles de ansiedad percibida y la percepción del ambiente



escolar. Estas variables fueron seleccionadas con base en revisiones previas que identifican su estrecha relación con el uso problemático de redes sociales, permitiendo así capturar una perspectiva más integral del fenómeno objeto de estudio. (Shannon et al., 2022)

La información obtenida a través de estas fuentes primarias constituye la base empírica del análisis cuantitativo realizado. Su carácter directo y contextual permite acceder a una visión actualizada y concreta del comportamiento digital de los jóvenes en un entorno educativo urbano, y a su vez genera evidencia que puede ser utilizada para la toma de decisiones en el ámbito pedagógico, institucional y comunitario. (Marino et al., 2020)

Por otro lado, las fuentes secundarias comprenden el conjunto de obras y documentos consultados con el objetivo de respaldar teóricamente las variables trabajadas, así como justificar la elección de técnicas de análisis, entre ellas la aplicación de métodos de aprendizaje automático. Dentro de esta categoría se incluye un amplio espectro de literatura científica compuesta por artículos de revistas indexadas, libros académicos especializados, tesis de posgrado, informes técnicos, marcos normativos y publicaciones recientes que abordan temáticas como la psicología del uso de redes sociales, la salud mental en adolescentes, el entorno escolar y la implementación de inteligencia artificial en contextos educativos. (Wong et al., 2020)

Estas fuentes permitieron construir el marco teórico-conceptual de la investigación, definiendo con precisión los constructos clave, tales como adicción conductual, alfabetización digital, bienestar psicológico, uso problemático de la tecnología, y modelo de intervención educativa. Asimismo, aportaron insumos fundamentales para seleccionar y adaptar adecuadamente la metodología cuantitativa, así como para sustentar el uso de herramientas computacionales modernas como los algoritmos de clasificación, redes neuronales o árboles de decisión en la identificación de patrones predictivos dentro de los datos recolectados. (Huang, 2022)

El análisis crítico y sistemático de estas fuentes secundarias también favoreció la triangulación teórica, al permitir la confrontación de enfoques diversos y la evaluación de tendencias emergentes en investigaciones relacionadas. Además, contribuyó al establecimiento de comparaciones entre resultados obtenidos en contextos internacionales y la realidad local observada en Manta, ampliando de esta manera el alcance interpretativo del estudio y enriqueciendo la discusión de resultados con una mirada global y actualizada. (Bozzola et al., 2022)

La articulación entre fuentes primarias y secundarias fue esencial para garantizar la solidez del diseño metodológico, la coherencia interna del estudio y la validez de sus hallazgos. Esta integración no solo permite sustentar empíricamente las afirmaciones presentadas, sino que también asegura que las conclusiones y recomendaciones derivadas se fundamenten tanto en datos concretos obtenidos en el campo como en el conocimiento acumulado y validado por la comunidad científica. (Whelan et al., 2020)

El uso complementario de ambas categorías de fuentes representa un pilar central de la investigación, al proporcionar una visión holística del fenómeno abordado, robustecer la estructura argumentativa del trabajo y dotar al estudio de un carácter interdisciplinario que conjuga teoría, evidencia empírica y análisis técnico, en favor de una comprensión profunda, contextualizada y útil para futuras investigaciones, políticas educativas y acciones preventivas orientadas al bienestar estudiantil.

2.5. Instrumental Operacional

2.5.1. Estructura y características de los instrumentos de recolección de datos

El presente estudio empleó como herramienta principal de recolección de datos una encuesta estructurada, diseñada específicamente para captar de manera exhaustiva las múltiples dimensiones asociadas al uso de redes sociales por parte de estudiantes de nivel secundario. El instrumento fue elaborado con base en una revisión teórica rigurosa y adaptado a las características del público objetivo, incorporando una redacción clara, accesible y libre de



tecnicismos, a fin de garantizar su comprensión por parte de adolescentes entre los 12 y 18 años de edad. (Best, 2024)

La encuesta fue aplicada en formato digital, mediante plataformas accesibles en línea, lo cual facilitó su distribución masiva, redujo los tiempos operativos de recolección y permitió preservar la confidencialidad, el anonimato y el consentimiento informado de los participantes conforme a principios éticos de la investigación social. (Huang, 2022)

La estructura del instrumento se organizó en cinco secciones temáticas, cada una de las cuales abordó diferentes aspectos clave del fenómeno investigado: desde las características sociodemográficas de los estudiantes hasta el impacto emocional y funcional del uso de redes sociales en su vida diaria. Esta organización interna del cuestionario permitió no solo delimitar claramente las variables de análisis, sino también establecer relaciones entre ellas de forma lógica y coherente, potenciando la riqueza del análisis cuantitativo. (Bedoya Denegri, 2021)

La Sección A, denominada Datos Generales, se enfocó en recopilar información básica sobre los participantes, necesaria para construir un perfil sociodemográfico inicial. En este apartado se incluyeron preguntas sobre el rango de edad clasificado en intervalos de 12-13, 14-15, 16-17 y 18 años, el género ofreciendo las opciones de masculino, femenino y una alternativa inclusiva “prefiero no decirlo”, así como el promedio diario de uso general de internet, categorizado en cuatro rangos de tiempo que van desde menos de una hora hasta más de seis horas. (Fuentes et al., 2024)

Además, se incorporó un ítem sobre el tipo de dispositivo utilizado con mayor frecuencia para acceder a redes sociales teléfono móvil, computadora, tablet u otro. Esta sección permitió identificar las condiciones tecnológicas de acceso, así como las posibles brechas de conectividad y uso según edad o género. (Chapilliquen Lopez, 2023)

La Sección B, Uso de Redes Sociales, se orientó a conocer los hábitos específicos de interacción con plataformas sociales digitales. Las preguntas en esta sección indagaron sobre el número de horas diarias dedicadas exclusivamente al uso de redes sociales, la frecuencia con



que los estudiantes revisan sus redes al día, la cantidad de redes sociales utilizadas de manera regular y la plataforma preferida entre Instagram, TikTok, Facebook, Snapchat y otras. (Pech et al., 2021)

Asimismo, se incluyó un ítem relacionado con el número promedio de notificaciones que los estudiantes reciben diariamente a través de dichas plataformas, lo cual ofrece un indicador indirecto del grado de exposición constante a estímulos digitales. Esta sección resultó esencial para evaluar la intensidad y diversidad del consumo digital, así como para delimitar el perfil de uso de los adolescentes. (Rufino Vargas, 2021)

La Sección C, titulada Hábitos de Uso, abordó los momentos del día en los que se produce el contacto con las redes sociales, así como la forma en que estas se integran o interfieren en otras actividades cotidianas. Se preguntó, por ejemplo, qué hacen los estudiantes al despertar y antes de dormir, si tienden a utilizar redes sociales mientras realizan otras tareas como estudiar o comer, ~~y~~ y con qué frecuencia publican contenido. Estas preguntas permitieron explorar el grado de internalización del uso digital en la rutina diaria y la presencia de comportamientos de multitarea, que pueden tener implicaciones importantes en términos de atención, concentración y regulación emocional. (Bautista-Quispe et al., 2023)

La Sección D, Comportamiento Emocional, se centró en analizar el vínculo afectivo y psicológico de los estudiantes con el uso de redes sociales. Se incluyeron preguntas sobre las emociones que experimentan cuando no pueden acceder a sus cuentas, el uso de estas plataformas como estrategia para afrontar estados de ánimo negativos como tristeza o aburrimiento, la percepción del tiempo invertido en redes sociales (y si este es mayor al deseado), así como los intentos realizados para reducir su uso y los resultados obtenidos. Esta sección permitió identificar indicadores tempranos de uso problemático o adictivo, así como evaluar la presencia de elementos como ansiedad, frustración, dependencia o autorregulación fallida, que son claves para la caracterización de la adicción conductual. (Ramírez Acosta, 2022)



Finalmente, la Sección E, denominada Impacto en la Vida Diaria, exploró las percepciones subjetivas de los estudiantes respecto a las consecuencias del uso de redes sociales en distintas esferas de su vida. Se consultó si consideran que estas plataformas afectan su concentración, tiempo de descanso, relaciones interpersonales o estado emocional, y qué tan frecuente sienten que interfieren directamente en su rendimiento académico (Berta Aznar-Martínez et al., 2024).

También se evaluó el nivel de importancia que le otorgan a mantenerse activos en redes sociales, lo cual aporta información relevante sobre el rol simbólico y social que estas plataformas tienen en su vida cotidiana. Esta sección contribuye de manera significativa a visibilizar las implicaciones del comportamiento digital en el bienestar psicológico, emocional y funcional de los adolescentes (Soria & Villegas-Villacres, 2024).

En cuanto a la codificación de las respuestas, la mayoría de los ítems fueron estructurados mediante escalas ordinales cerradas de tipo Likert, con opciones que oscilaban entre “nunca” y “siempre” o entre “menos de 1 hora” y “más de 6 horas”, según la naturaleza de la pregunta. Esta forma de codificación permitió convertir en datos cuantificables las percepciones y comportamientos autorreportados, lo que facilitó su análisis con herramientas como hojas de cálculo, software estadístico y modelos de aprendizaje automático (Alarcón Allain, 2021).

La implementación de este instrumento en formato digital favoreció la recolección eficiente de una gran cantidad de respuestas en un corto período de tiempo, reduciendo errores humanos en el registro, garantizando la trazabilidad de la información y permitiendo la exportación automatizada a bases de datos estructuradas. Todo el proceso se desarrolló conforme a criterios éticos, asegurando la voluntariedad de la participación, la confidencialidad de los datos y la protección de la identidad de los encuestados (Castro Gutierrez, 2022).

2.6. Estrategia Operacional para la recolección y tabulación de datos

2.6.1. Plan de recolección, tabulación, análisis e interpretación de los datos

La ejecución del presente estudio respondió a una estrategia operacional bien planificada, estructurada en fases secuenciales, que permitieron garantizar el rigor metodológico, la confiabilidad de los datos recolectados, la validez de los modelos analíticos aplicados y la claridad en la presentación de los hallazgos. Esta estrategia, sustentada en principios de investigación cuantitativa con enfoque analítico-predictivo, combinó técnicas tradicionales de levantamiento de información con herramientas contemporáneas de análisis estadístico y computacional, propias de la ciencia de datos y el aprendizaje automático. (Aliaga Paredes, 2023)

La primera fase de la estrategia consistió en el diseño y validación del instrumento de recolección de datos, proceso que requirió una cuidadosa elaboración del cuestionario estructurado, el cual se dividió en bloques temáticos que abordaban tanto variables sociodemográficas como conductuales, emocionales y funcionales vinculadas al uso de redes sociales. Este instrumento integró, como eje central, la Escala Bergen de Adicción a Redes Sociales (BSMAS), internacionalmente validada, así como ítems complementarios elaborados por el equipo investigador, con el objetivo de medir variables psicosociales como autoestima, hábitos de sueño, niveles de ansiedad, percepción del clima escolar, entre otros. (Brand & García, 2023)

La segunda fase se centró en la aplicación del instrumento en formato digital, lo cual permitió garantizar un acceso más amplio, flexible y eficiente por parte de los participantes. Para ello se usó una plataforma en línea optimizada para dispositivos móviles y computadoras, que en este caso fue Google Forms, mismo que favoreció la cobertura de estudiantes que acceden a internet desde diferentes dispositivos. La aplicación fue dirigida a estudiantes de nivel secundario pertenecientes a instituciones educativas seleccionadas de la ciudad de Manta, garantizando un muestreo de tipo intencional por conveniencia, pero con criterios de diversidad institucional, accesibilidad tecnológica y rango etario. (Veloza Gamba, 2023)

Previo a la participación, se implementó un procedimiento ético que incluyó la entrega de consentimiento informado, garantizando el respeto por la autonomía, el anonimato y la confidencialidad de la información proporcionada. Esta fase permitió obtener un conjunto de datos cuantitativos amplio, contextualizado y directamente vinculado con la población objetivo del estudio. (Boer et al., 2020)

Una vez finalizada la recolección, se dio paso a la tercera fase, correspondiente a la tabulación, organización, limpieza y preprocesamiento de los datos obtenidos. Para ello, se utilizaron herramientas informáticas especializadas como Microsoft Excel, Python (Pandas, NumPy), ~~y~~ software estadístico como SPSS, que facilitaron la sistematización de los registros, la verificación de errores, la transformación de valores atípicos y la codificación adecuada de las variables categóricas (Veloza Gamba, 2023).

Esta fase implicó tareas fundamentales como la depuración de registros incompletos, la eliminación de duplicados, la imputación de valores faltantes y la conversión de escalas cualitativas a valores numéricos compatibles con los requerimientos técnicos de los algoritmos predictivos. El preprocesamiento de los datos fue esencial para garantizar su integridad, reducir sesgos y preparar una base de datos homogénea, fiable y lista para el análisis exploratorio y predictivo posterior (Abdel Wahed & Wahed, 2025).

La cuarta fase abarcó el desarrollo del análisis exploratorio de datos EDA, por sus siglas en inglés, que permitió generar una primera aproximación diagnóstica al comportamiento de las variables estudiadas. En esta etapa se aplicaron técnicas de estadística descriptiva para caracterizar las distribuciones de frecuencia, medias, medianas, modas, desviaciones estándar y rangos intercuartílicos (Cuervo Sánchez et al., 2022).

Asimismo en la quinta fase, se emplearon gráficos de visualización como lo son los diagramas de barra, el diagrama de pastel, con el objetivo de identificar tendencias, asociaciones preliminares, posibles valores atípicos y relaciones entre las variables. Este análisis no solo facilitó una lectura comprensiva de los datos, sino que también orientó decisiones


metodológicas claves sobre qué variables incluir en los modelos predictivos y qué transformaciones aplicar para optimizar su rendimiento (Ruiz Pimiento et al., 2021).

La sexta y última fase estuvo dedicada a la interpretación de los resultados y a la elaboración de informes visuales y explicativos, con el objetivo de facilitar la comprensión de los hallazgos tanto por parte de la comunidad científica como de actores institucionales y educativos. Se desarrollaron dashboards, infografías, gráficos de barras y líneas, mapas de correlación y representaciones interactivas que permitieron ilustrar de manera clara y accesible los principales patrones encontrados (B. Aznar-Martínez et al., 2024).

La interpretación integró tanto un enfoque cuantitativo basado en las métricas y resultados de los modelos como una lectura cualitativa orientada a la reflexión sobre el impacto social, educativo y emocional de las prácticas digitales adolescentes. Esta fase también sirvió como base para la formulación de recomendaciones estratégicas, orientadas a diseñar intervenciones pedagógicas, talleres psicoeducativos, ~~y~~ y políticas escolares que promuevan un uso saludable, crítico y responsable de las redes sociales entre los jóvenes (Whelan et al., 2020).

La estrategia operacional adoptada en este estudio se caracterizó por un enfoque metodológico técnicamente mixto y científicamente riguroso, combinando procedimientos de validación tradicional con tecnologías emergentes para el análisis de grandes volúmenes de datos. Su implementación por fases aseguró un desarrollo sistemático y replicable, que no solo permitió alcanzar los objetivos planteados, sino que también aportó una base sólida para futuras investigaciones interdisciplinarias en el campo de la salud mental digital, la pedagogía tecnológica y la prevención de adicciones conductuales en contextos escolares (Mayaute & Blas, 2020).

Gráfico 1. *Proceso de obtención de los datos del estudio*



Nota: Fuente elaboración propia

El gráfico 1 resume de forma concreta las etapas seguidas para la obtención de los datos, desde la definición de la población y selección de la muestra, hasta la aplicación del instrumento BSMAS y la consolidación de la base de datos. Este procedimiento permitió asegurar la calidad y consistencia de la información utilizada en el análisis.

2.7. Plan de Muestreo

2.7.1. Segmentación - Técnica de muestreo - Tamaño de la muestra

Para el presente estudio, se implementó una estrategia de muestreo no probabilístico por conveniencia, una técnica metodológica comúnmente empleada en investigaciones de tipo exploratorio y aplicada cuando el acceso a la población total es limitado por condiciones logísticas, institucionales o éticas.



Esta modalidad de muestreo fue seleccionada teniendo en cuenta que la población objetivo se circunscribe a un conjunto específico de instituciones educativas de la ciudad de Manta, provincia de Manabí, que autorizaron formalmente la aplicación del instrumento de recolección de datos en sus establecimientos. La elección de este tipo de muestreo respondió también a la necesidad de garantizar una participación voluntaria, informada y respetuosa del entorno escolar, asegurando el cumplimiento de los principios éticos fundamentales que rigen la investigación en contextos educativos (Tapia et al., 2025).

El proceso de selección de participantes se llevó a cabo de manera directa y controlada, en coordinación con autoridades institucionales y docentes designados como enlaces, quienes facilitaron el acceso a los grupos estudiantiles. La muestra estuvo conformada por 296 estudiantes de educación secundaria, pertenecientes a tres instituciones educativas de la ciudad de Manta, Ecuador: Unidad Educativa Particular Talentos, Unidad Educativa Particular Manabí, Unidad Educativa María Montessori, quienes participaron en la aplicación del instrumento de investigación con el objetivo de analizar patrones de uso de redes sociales y variables psicosociales asociadas (Luo et al., 2021).

La segmentación interna de la muestra se realizó con base en el nivel de formación educativa de los participantes, abarcando estudiantes desde octavo año de Educación General Básica (EGB) hasta tercero de Bachillerato, es decir, jóvenes que cursan los niveles comprendidos entre el segundo ciclo de educación básica superior y la educación media. Esta segmentación respondió al interés de incluir una diversidad de etapas del desarrollo adolescente, con el fin de observar posibles variaciones en los patrones de uso de redes sociales, en las respuestas emocionales asociadas y en la percepción del impacto de estas plataformas digitales en sus actividades cotidianas (Wang & Guo, 2025).

No obstante, el tamaño muestral de 296 estudiantes se considera adecuado para la implementación de técnicas de aprendizaje de máquina no supervisado, como el Análisis de Componentes Principales, el análisis de clústeres y las reglas de asociación, ya que estos

modelos requieren un volumen suficiente de observaciones para garantizar estabilidad en los patrones identificados y consistencia en la segmentación.

En estudios de análisis multivariado y minería de datos aplicados al ámbito educativo, muestras superiores a 200 observaciones son consideradas robustas para la identificación de estructuras latentes y agrupamientos significativos, lo que respalda la suficiencia analítica del tamaño muestral utilizado en la presente investigación.

En cuanto a los criterios de inclusión, se establecieron parámetros específicos con el objetivo de asegurar la pertinencia de la muestra respecto al objeto de estudio. Se incluyeron únicamente aquellos estudiantes que contaban con acceso regular a internet, ~~y~~ ya sea mediante datos móviles o conexiones de red fija, ~~y~~ que además usaban de forma habitual redes sociales digitales como Instagram, TikTok, Facebook, entre otras. Estos criterios fueron verificados al inicio del proceso mediante una pregunta filtro incluida en el formulario, lo que permitió garantizar que los participantes estuvieran efectivamente expuestos al entorno digital que se pretendía estudiar (Olivella-Cirici et al., 2025).

Además, se realizaron esfuerzos para mantener un equilibrio razonable en la distribución por género, edad y nivel educativo, de manera que la muestra fuera lo más diversa posible dentro del marco definido, contribuyendo así a enriquecer el análisis estadístico posterior. Aunque no se trataba de un muestreo aleatorio estratificado, el enfoque adoptado se aseguró de que incluyera un rango de edades entre 13 y 17 años, ayudándonos a tener una idea más clara de cómo este grupo de edad, según la investigación, corre más riesgo de problemas con el uso de las redes sociales, podría estar lidiando con su impacto. (Cabero-Almenara et al., 2020)

2.8. Presentación y Análisis de los resultados

2.8.1. Presentación y Descripción de los resultados obtenidos

2.8.1.1 Caracterización de la población estudiada


Ilustración 14. Resumen general de los datos obtenidos

Estudiantes encuestados

296

Total_Encuestados


Distribución por género




Distribución por edad



Horas en redes sociales



Plataforma más utilizada



Nota: Fuente elaboración propia

La ilustración 14 presenta la distribución general de la población estudiada según variables sociodemográficas relevantes. Este análisis permite contextualizar los resultados de la investigación y comprender las características básicas de los estudiantes que conforman la muestra analizada.

El análisis incluyó a 296 alumnos de las instituciones Stella Maris, Talentos y Manabí. Contamos con una distribución de género muy equitativa, además de un pequeño porcentaje que decidió no declarar su identidad, respetando siempre su anonimato según el protocolo del estudio.


La mayoría de los estudiantes analizados tienen entre 12 y 15 años. Se encuentran en esa primera fase de la adolescencia donde las redes sociales y la tecnología se vuelven parte esencial de su vida social. Analizar esta edad es fundamental, ya que son quienes más sienten el impacto y la influencia de los entornos digitales actuales.

El uso más común de redes sociales entre los estudiantes es de una a tres horas diarias, seguido de cerca por quienes las usan hasta seis horas. Lo más llamativo es el grupo que declara pasar más de seis horas al día conectados. Estos patrones de uso intensivo sugieren riesgos potenciales, no solo para su equilibrio psicológico, sino también para su desempeño académico. (Reina-Parrado et al., 2025)

TikTok domina la preferencia de los estudiantes como su principal medio de entretenimiento. Mientras que Snapchat e Instagram conservan una presencia importante, Facebook registra un uso mínimo. Este cambio confirma una tendencia clara: las nuevas generaciones buscan contenidos más ágiles y visuales, alejándose de las plataformas tradicionales. (Alenezi & Faisal, 2020)

2.8.1.2 Intensidad y frecuencia del uso de redes sociales

Ilustración 15. Patrones de consumo digital



Nota: Fuente elaboración propia

En relación con el número de redes sociales utilizadas de manera habitual, los resultados indican que la mayoría de los estudiantes hace uso regular de entre dos y tres plataformas digitales, lo que sugiere una diversificación moderada en sus hábitos de consumo digital. A este grupo le sigue un porcentaje relevante de estudiantes que reporta utilizar entre cuatro y cinco

redes sociales de forma frecuente, mientras que una proporción menor manifiesta emplear más de cinco plataformas de manera simultánea.

La mayoría de los alumnos accede a sus redes entre cinco y diez veces al día. Mientras unos mantienen un perfil bajo (menos de cinco accesos), existe un segmento considerable que revisa sus plataformas más de veinte veces diarias. Este patrón de acceso frecuente es un indicador clave de uso intensivo y podría estar ligado a comportamientos problemáticos con la tecnología. (Elbasi et al., 2025)


El móvil se consolida como el dispositivo principal de acceso, superando significativamente a las computadoras y tablets. Su portabilidad y facilidad de uso son los factores clave que explican por qué los estudiantes prefieren este medio, ya que les garantiza un acceso inmediato a sus plataformas digitales desde cualquier lugar. (Khine, 2024)

El uso de dispositivos alternativos, como las consolas, es marginal frente al dominio del smartphone. Este hecho resalta que el móvil es el medio principal de interacción digital. Identificar al celular como la herramienta central nos permite comprender mejor los patrones de uso intensivo y los riesgos asociados al entorno digital en esta población. (Wu, 2020)

Del total de estudiantes encuestados, 157 fueron clasificados dentro del grupo de usuarios con uso intensivo de redes sociales, lo que equivale al 53,04 % de la muestra analizada. Este hallazgo indica que más de la mitad de los participantes presenta niveles elevados de interacción con plataformas digitales, reflejando una alta exposición cotidiana a estos entornos virtuales.

2.8.1.3 Resultados asociados a variables psicosociales

Ilustración 16. Variables psicosociales



Nota: Fuente elaboración propia

En la ilustración 16 se evidencia la intensidad del uso de redes sociales por parte de los estudiantes, reflejada en la cantidad de horas diarias de conexión. Los resultados muestran una tendencia hacia un uso prolongado, lo que constituye un indicador relevante para el análisis del riesgo de adicción digital.

Los resultados de la escala BSMAS muestran que el 59,46 % de la muestra sufre niveles elevados de malestar ante la falta de acceso a redes sociales. Los resultados que arroja la investigación nos permiten comprender como las emociones de los adolescentes van ligadas con el uso del consumo digital.

El estudio muestra que más de la mitad de los alumnos percibe su propio uso de redes como excesivo con un 56,76 %. Pero el dato que llama más la atención es que el 45,27 % declara un uso emocional intenso. Esto indica que los jóvenes recurren a las redes sociales para regular sus emociones, gracias a esto la pantalla se convierte en un recurso para modificar el estado de ánimo.

Además, el 69,26 % de los estudiantes afirma haber intentado sin éxito reducir el tiempo dedicado a redes sociales. Esta cifra evidencia que modificar la conducta digital resulta complicado.



En el ámbito académico, la distracción por redes sociales es, para la mayoría, un evento ocasional. Sin embargo, existe un grupo crítico que manifiesta una interferencia constante en sus horas de estudio. Este patrón sugiere que, aunque para muchos es una distracción manejable, para una parte importante de la muestra las redes ya representan un obstáculo real para su desempeño escolar.


El impacto de las redes sociales es más severo en la productividad académica y la concentración, donde los estudiantes presentan dificultades claras para cumplir con sus responsabilidades. Otros efectos críticos incluyen la alteración del sueño y cambios en el estado de ánimo, sugiriendo un riesgo para el equilibrio emocional. Finalmente, el ámbito social también muestra señales de deterioro, evidenciando que la influencia digital trasciende las aulas y llega a la vida personal y afectiva. (Yanto & Wedhayanti, 2025)

La importancia atribuida a la actividad en redes sociales es moderada para la mayoría de los estudiantes. No obstante, existe una diversidad de opiniones, un segmento importante le resta relevancia, mientras que una minoría la califica como muy importante. Esta variedad de percepciones es determinante, ya que el valor que cada alumno le da a su vida digital define su nivel de intensidad en el uso y su capacidad para autorregular su comportamiento en internet.

2.8.1.4 Resultados asociados a variables psicosociales referentes al clúster

Ilustración 17. Análisis del Clúster

Distribución de estudiantes según clústeres identificados mediante PCA



Distribución de estudiantes según clústeres identificados mediante análisis de componentes principales (PCA)



Nota: Fuente elaboración propia

La ilustración 17 refleja la relación entre el uso de redes sociales y variables psicosociales como el estado emocional, la ansiedad y la percepción del bienestar. Estos resultados evidencian que el comportamiento digital no solo depende del tiempo de uso, sino también de factores emocionales que influyen en la predisposición a la adicción.

El análisis de clústeres realizado a partir del análisis de componentes principales (PCA) permitió identificar tres grupos diferenciados de estudiantes, los cuales presentan comportamientos distintos en relación con el uso de redes sociales. La proyección de los datos en el espacio definido por las dos primeras componentes principales evidencia una separación visual entre los clústeres, lo que indica que las variables consideradas logran discriminar adecuadamente los perfiles de uso digital. (Caner et al., 2022b)

En términos de tamaño poblacional, el clúster 0 agrupa al mayor número de estudiantes (127 participantes), seguido por el clúster 2 con 87 estudiantes y el clúster 1 con 81 estudiantes. Esta distribución sugiere que el comportamiento representado por el clúster 0 constituye el patrón predominante dentro de la muestra analizada.


Al analizar el promedio de horas diarias de uso de redes sociales, se observan diferencias claras entre los clústeres. Al agrupar a los estudiantes por sus hábitos, encontramos

tres perfiles claros. El Clúster 0 es el más intenso, con el promedio más alto de horas de conexión. En el extremo opuesto está el Clúster 1, que agrupa a quienes tienen un uso mucho más moderado y controlado de sus redes. Finalmente, el Clúster 2 se mantiene en un punto medio: no llega a los niveles de uso intensivo del primer grupo, pero está claramente por encima del perfil más moderado. (Taş, 2023a)

La combinación del análisis visual (PCA) y las horas de uso confirma que los clústeres representan perfiles de comportamiento digital opuestos. El Clúster 0 se define por una exposición máxima a las plataformas, mientras que los Clústeres 1 y 2 muestran un descenso progresivo en el uso. Esto valida que la intensidad del consumo digital es el factor principal que diferencia a estos grupos de estudiantes. (Taş, 2023b)

2.8.1.5 Resultados del análisis de reglas de asociación

Ilustración 18. Análisis de las reglas de asociación



Nota: Fuente elaboración propia

La ilustración 18 muestra las principales reglas de asociación obtenidas, destacando combinaciones de conductas digitales con altos niveles de soporte y confianza. Estos patrones permiten identificar perfiles de riesgo y comprender cómo determinadas prácticas incrementan la probabilidad de adicción a redes sociales.



El análisis de asociación identificó vínculos clave entre el comportamiento digital y los indicadores psicosociales. Con una confianza superior al 80 % y valores de lift que descartan el azar, las relaciones encontradas son estadísticamente sólidas. Estos indicadores refuerzan la validez del estudio, confirmando que los patrones de uso están estrechamente ligados al bienestar de los estudiantes.

El análisis confirma que hay una fuerte relación entre la frecuencia de uso, el malestar que genera la desconexión y la percepción de estar usando las redes en exceso. Además, variables como la edad y el género resultan clave para entender los distintos patrones de comportamiento.

El análisis revela que el volumen de notificaciones diarias y la importancia atribuida a la actividad en redes están estrechamente vinculados. Estas asociaciones confirman que el uso problemático no depende de un solo factor, sino de una combinación de comportamientos. Contar con esta evidencia es fundamental para identificar con mayor precisión los riesgos psicosociales a los que están expuestos los jóvenes.

2.8.2. Informe final del análisis de los resultados

El análisis de los resultados obtenidos permitió identificar patrones significativos en el comportamiento de uso de redes sociales de los estudiantes que formaron parte de la investigación, así como establecer relaciones relevantes entre las variables de uso digital y diversos factores psicosociales asociados al riesgo de adicción a redes sociales. El procesamiento sistemático de los datos recolectados evidenció la presencia de comportamientos diferenciados dentro de la población estudiada, lo que respalda la pertinencia y coherencia del enfoque metodológico adoptado para el análisis del fenómeno. (Huang, 2022)

En una primera etapa, el análisis descriptivo posibilitó la caracterización general de la población de estudio, poniendo en evidencia una exposición temprana y frecuente de los estudiantes al uso de redes sociales. Los resultados indicaron que una proporción considerable de los participantes dedica varias horas diarias a estas plataformas, utiliza múltiples redes sociales de forma simultánea y accede a ellas con elevada frecuencia a lo largo del día.



Asimismo, se identificó que el teléfono móvil constituye el principal dispositivo de acceso, lo cual refuerza la idea de una disponibilidad constante e inmediata de las redes sociales en la vida cotidiana de los estudiantes, favoreciendo patrones de uso intensivo. (Cebollero Salinas et al., 2021)

En cuanto a las variables psicosociales analizadas, los resultados obtenidos a través de la escala Bergen Social Media Addiction Scale (BSMAS), junto con los indicadores complementarios, evidenciaron niveles elevados de malestar ante la imposibilidad de utilizar redes sociales, percepción de uso excesivo, uso emocional de estas plataformas y dificultades persistentes para reducir el tiempo de conexión. Estos hallazgos sugieren la presencia de comportamientos compatibles con patrones de uso problemático de redes sociales en un segmento relevante de la población estudiada, lo que refuerza la necesidad de abordar este fenómeno desde una perspectiva preventiva y educativa. (Copez-Lonzoy et al., 2023)

Posteriormente, la aplicación de técnicas de aprendizaje no supervisado permitió profundizar en el análisis de la estructura interna de los datos y en la identificación de patrones subyacentes no evidentes mediante métodos descriptivos tradicionales. A través del análisis de componentes principales (PCA), se logró reducir la dimensionalidad del conjunto de variables, conservando la información más relevante y facilitando la visualización de las relaciones existentes entre los datos. La proyección de los estudiantes en el espacio definido por las componentes principales evidenció la existencia de agrupaciones diferenciadas, lo que confirma la heterogeneidad de los comportamientos digitales presentes en la muestra analizada. (Aguilar, 2024)

Sobre esta base, el análisis de clústeres permitió identificar tres grupos claramente diferenciados de estudiantes, caracterizados por distintos niveles de intensidad en el uso de redes sociales. Uno de los clústeres se distingue por un mayor promedio de horas de uso diario y una interacción más intensa con las plataformas digitales, mientras que los otros dos grupos reflejan patrones de uso intermedio y moderado. Esta segmentación confirma la coexistencia de perfiles diversos de comportamiento digital dentro de la población estudiantil y aporta una

comprensión más precisa de la distribución del uso de redes sociales en estudiantes de secundaria. (Bedoya Denegri, 2021)

Finalmente, el análisis de reglas de asociación permitió identificar relaciones frecuentes y significativas entre variables de uso digital y variables psicosociales. Las reglas obtenidas presentaron altos niveles de confianza y valores de lift superiores a la unidad, lo que indica asociaciones consistentes entre la frecuencia de revisión de redes sociales, el malestar experimentado al no utilizarlas, la percepción de uso excesivo y determinadas características sociodemográficas. (Rufino Vargas, 2021)

CAPÍTULO III

MARCO PROPOSITIVO

3.1. Introducción

A diferencia de las propuestas tecnológicas que buscan construir plataformas o sistemas funcionales con fines de intervención directa, la presente iniciativa se orienta exclusivamente al tratamiento, modelado e interpretación de los datos recolectados, con el objetivo de generar conocimiento empírico y aportar valor analítico a la comprensión del fenómeno desde una perspectiva computacional y educativa. (Pastor et al., 2022)

Esta propuesta se basa en la utilización de algoritmos de aprendizaje de máquina como instrumento de análisis cuantitativo avanzado, a partir de la base de datos construida con los insumos empíricos recogidos mediante una encuesta estructurada. Dicha encuesta fue aplicada a estudiantes adolescentes de entre 13 y 17 años de edad y abarcó múltiples dimensiones: variables sociodemográficas como lo es la edad, género, nivel educativo, acceso a internet, variables conductuales como frecuencia de uso, plataformas utilizadas, horas conectadas, hábitos diarios y variables psicoemocionales como el estado de ánimo, ansiedad, percepción de control, efectos percibidos en la vida diaria. (Lorenzo Rumbo et al., 2025)

El análisis se realizó utilizando el lenguaje de programación Python, ampliamente reconocido por su robustez y versatilidad en tareas de análisis de datos y modelado estadístico. Se hizo uso de bibliotecas especializadas como Pandas, para la manipulación de estructuras de datos tabulares; Scikit-learn, para la construcción, ajuste y validación de los modelos de machine learning; NumPy, para operaciones matemáticas y de álgebra lineal; y Matplotlib y Seaborn, para la generación de visualizaciones gráficas que faciliten la interpretación de los resultados. A través de estas herramientas se procesaron las variables, se realizaron pruebas de consistencia interna, se imputaron valores faltantes cuando fue necesario, y se construyeron modelos iterativos que permitieron refinar las predicciones de manera progresiva. (Cabero Almenara et al., 2020)

Este capítulo describe en detalle cada una de las etapas del proceso: desde la preparación de los datos y la elección de los algoritmos, hasta la evaluación de resultados y su visualización gráfica. Asimismo, se enmarca todo el procedimiento en los principios éticos y metodológicos que rigen la investigación educativa y el análisis de datos sensibles, asegurando la confidencialidad de los participantes, el anonimato de los registros, y el uso exclusivo de la información con fines académicos y científicos. (Norambuena et al., 2022)

3.2. Descripción de la propuesta

La propuesta planteada se fundamenta en la aplicación de técnicas de aprendizaje de máquina no supervisado, integradas en un entorno de visualización analítica e interactiva, con el propósito de identificar, explorar y caracterizar patrones de comportamiento digital vinculados al uso intensivo de redes sociales. Este enfoque permite detectar estructuras subyacentes y relaciones no evidentes en los datos, sin la necesidad de categorías previamente definidas, aportando una visión más objetiva y exploratoria del fenómeno estudiado. (Bautista-Quispe et al., 2023)

Para ello, se utilizó Power BI como plataforma de consolidación, procesamiento y visualización de la información recolectada mediante la encuesta aplicada a estudiantes. A través de esta herramienta, fue posible integrar y depurar los datos, facilitando el análisis

simultáneo de variables sociodemográficas, hábitos de consumo digital, indicadores de afectación psicosocial y comportamientos asociados al uso prolongado de redes sociales. Asimismo, el uso de técnicas de análisis multivariado permitió identificar patrones complejos y perfiles de comportamiento diferenciados, los cuales se representan de manera dinámica mediante paneles interactivos, favoreciendo una interpretación integral y apoyando la toma de decisiones basada en evidencia empírica. (Mamani Añamuro, 2024)

3.3. Determinación de recursos

3.3.1. Humanos

La estructura organizativa del presente estudio contempla la participación de diferentes actores con funciones claramente definidas, cuya colaboración interdisciplinaria garantiza la rigurosidad del proceso investigativo, la solidez metodológica y la validez tanto de los análisis como de las interpretaciones obtenidas. (Soria & Villegas-Villacres, 2024)

Tabla 1. *Recursos humanos empleados en la propuesta*

Recurso humano	Rol desempeñado	Función principal
Investigadora	Analista de datos	Procesamiento, limpieza, transformación e integración de la base de datos
	Analista estadístico	Análisis descriptivo, aplicación de PCA y segmentación por clústeres
	Analista de minería de datos	Implementación del algoritmo Apriori y evaluación de métricas (soporte, confianza, lift y leverage)
	Diseñadora de visualización	Construcción de dashboards e interpretación visual de resultados en Power BI
	Responsable del análisis	Integración de resultados y apoyo a la interpretación



metodológica

Nota: Fuente Elaboración propia

Aunque la ejecución de la propuesta fue realizada por una sola persona, la desagregación de roles evidencia que el proceso analítico requirió competencias diferenciadas en análisis de datos, estadística, minería de datos y visualización. Esta organización permite demostrar que la metodología aplicada es técnica y estructurada, pero al mismo tiempo viable y replicable en contextos educativos con recursos humanos limitados, siempre que se cuente con la formación adecuada.

3.3.2. Tecnológicos

Para llevar a cabo el análisis de datos propuesto en este estudio, es necesario disponer de una infraestructura tecnológica robusta que permita manejar adecuadamente conjuntos de datos multivariados, así como ejecutar procesos complejos de entrenamiento y validación de modelos de aprendizaje automático. Esta infraestructura no solo debe garantizar capacidad de procesamiento y almacenamiento, sino también ofrecer un entorno de trabajo estable, reproducible y adecuado para la ciencia de datos aplicada en entornos educativos. (Díaz Landa et al., 2021)

Tabla 2. *Recursos tecnológicos empleados en la propuesta*

Recurso tecnológico	Descripción	Finalidad
Power BI Desktop	Herramienta de análisis y visualización de datos	Procesamiento de la base de datos, construcción de dashboards, análisis PCA y reglas de asociación
Equipo de cómputo personal	Computador con capacidad de procesamiento estándar	Ejecución del análisis de datos y almacenamiento de información



Sistema operativo	Entorno operativo del equipo de cómputo	Soporte para la ejecución de Power BI y gestión de archivos
Software de hoja de cálculo	Herramienta de apoyo para revisión preliminar de datos	Verificación, organización inicial y validación de la base de datos
Navegador web	Acceso a plataformas digitales	Consulta de información, descarga de datos y validación de resultados
Base de datos de la encuesta	Conjunto de datos obtenidos de estudiantes de secundaria	Insumo principal para el análisis del comportamiento digital
Almacenamiento digital	Espacio local del equipo	Resguardo de bases de datos, archivos de trabajo y visualizaciones

Nota: Fuente Elaboración propia

Los recursos tecnológicos empleados fueron suficientes para el desarrollo completo de la propuesta analítica, demostrando que el uso de herramientas accesibles permite aplicar técnicas avanzadas de análisis de datos y aprendizaje de máquina no supervisado. La integración de Power BI como herramienta central facilitó la ejecución conjunta del análisis y la visualización de resultados, optimizando el flujo de trabajo y reduciendo la necesidad de infraestructura especializada. Esta configuración tecnológica refuerza la viabilidad, escalabilidad y replicabilidad de la propuesta en contextos educativos con limitaciones presupuestarias. (Caner et al., 2022a)

3.3.3. Económicos (presupuesto)

Considerando que la presente propuesta metodológica se sustenta en el uso de herramientas tecnológicas de código abierto y software libre, como es el caso del lenguaje de programación Python y sus bibliotecas especializadas para el análisis estadístico y el



aprendizaje automático, los costos operativos directos asociados a la ejecución del proyecto son relativamente bajos. La utilización de estos recursos gratuitos permite contar con un entorno de trabajo robusto, actualizado y ampliamente respaldado por la comunidad científica, sin incurrir en gastos por concepto de licencias o suscripciones obligatorias, lo cual representa una ventaja significativa en términos de eficiencia económica y sostenibilidad.(Sümen & Evgin, 2021b)

Tabla 3. *Presupuesto a invertir en el proyecto*

Concepto	Descripción	Costo estimado (USD)
Licencia de software de análisis	Uso de Power BI Desktop (versión gratuita – costo referencial de implementación)	40,00
Software de apoyo	Herramienta de hoja de cálculo para validación y organización de datos	20,00
Equipo de cómputo	Uso y desgaste de computador personal durante el desarrollo del proyecto	60,00
Acceso a internet	Conectividad para recolección de datos, análisis y consultas académicas	40,00
Almacenamiento digital	Gestión y resguardo de bases de datos y archivos del proyecto	20,00
Recolección de datos	Aplicación y gestión de encuesta digital	20,00
Total		200,00

Fuente: Elaboración propia

El presupuesto estimado evidencia que la propuesta es económicamente viable, ya que puede desarrollarse con una inversión moderada de USD 200, aprovechando principalmente

herramientas digitales accesibles y recursos propios. La mayor proporción del presupuesto se concentra en el uso del equipo de cómputo y la conectividad a internet, elementos indispensables para el procesamiento y análisis de datos. Esta estructura presupuestaria demuestra que el modelo propuesto puede ser implementado en instituciones educativas con limitaciones financieras, sin requerir infraestructura tecnológica especializada ni inversiones elevadas, lo que refuerza su factibilidad y potencial de replicabilidad. (Gülü et al., 2023)

3.4. Etapas de OSEM

La metodología OSEM (Obtaining, Scrubbing, Exploring, Modeling e Interpreting) constituye un marco metodológico integral para el análisis de datos, ampliamente empleado en proyectos de ciencia de datos y aprendizaje de máquina. Este enfoque permite estructurar de manera ordenada y sistemática las fases del proceso analítico, facilitando la transformación de grandes volúmenes de datos en información significativa y confiable. Su aplicación contribuye a garantizar coherencia metodológica, rigor científico y trazabilidad en cada una de las etapas del análisis. (Chang et al., 2020)

En el contexto de la presente investigación, la metodología OSEM se adopta como guía metodológica para el análisis de los datos relacionados con el uso de redes sociales y las variables psicosociales vinculadas a la adicción a estas plataformas. A través de la ejecución secuencial de sus cinco etapas, se asegura un manejo adecuado y controlado de la información, que abarca desde la obtención y depuración de los datos hasta la exploración, modelado y posterior interpretación de los resultados. (Pansri et al., 2024)

3.4.1. Obtaining Data (Obtener Datos)

3.4.1.1 Recopilación de datos iniciales

En el marco de la investigación se recopilieron datos primarios provenientes de una muestra de 296 estudiantes de nivel secundario, con el objetivo de analizar de manera integral el uso de redes sociales, sus características sociodemográficas y las variables psicosociales asociadas a la adicción digital. Para este propósito, se empleó como instrumento principal la

Bergen Social Media Addiction Scale (BSMAS), ampliamente validada en estudios previos sobre conductas adictivas relacionadas con el uso de plataformas digitales. (Özyírmídokuz et al., 2025b)

La recolección de la información se llevó a cabo mediante encuestas estructuradas aplicadas directamente a la población de estudio, las cuales incluyeron preguntas orientadas a identificar aspectos como la edad y el género de los participantes, el número de horas diarias dedicadas al uso de redes sociales, las plataformas más utilizadas, la frecuencia de revisión de estas aplicaciones, la cantidad de redes sociales empleadas de forma simultánea y las percepciones subjetivas de los estudiantes respecto al impacto del uso de redes en su vida académica, social y personal. Una vez obtenidos, los datos fueron sistematizados en una base digital, asegurando su consistencia y organización, y posteriormente importados al entorno de Power BI para facilitar su procesamiento, visualización y análisis. (Özyírmídokuz et al., 2025b)

Esta fase resultó fundamental, ya que permitió disponer de información confiable, válida y contextualizada que refleja el comportamiento digital real de los estudiantes, constituyéndose en el insumo principal para el desarrollo del análisis exploratorio de datos y la posterior aplicación de técnicas de aprendizaje de máquina. De este modo, la obtención de datos estructurados y de calidad garantizó una base sólida para la identificación de patrones, tendencias y perfiles asociados a la adicción a redes sociales, contribuyendo al rigor metodológico y a la validez de los resultados obtenidos en la investigación. (Gülü et al., 2023)

3.4.1.2 Descripción de los datos

La información recopilada en la investigación corresponde a datos de carácter cuantitativo y categórico, los cuales fueron organizados de manera sistemática en tres dimensiones analíticas con el fin de facilitar su comprensión y posterior procesamiento estadístico. En primer lugar, se consideró la dimensión sociodemográfica, que integra variables básicas como la edad y el género de los estudiantes, elementos clave para caracterizar a la población de estudio y para identificar posibles diferencias en los patrones de uso de redes sociales según grupos etarios o de género. (Johar & Patel, 2024)

En segundo lugar, se definió la dimensión relacionada con el uso de redes sociales, la cual abarca variables directamente vinculadas al comportamiento digital de los participantes, tales como el número de horas diarias dedicadas a estas plataformas, la frecuencia con la que revisan sus redes, la cantidad de redes sociales utilizadas de manera simultánea, la plataforma de uso más frecuente y el dispositivo principal empleado para el acceso, permitiendo así describir con mayor precisión los hábitos digitales predominantes en la muestra analizada.

(Dhanalakshmi et al., 2025)

Finalmente, se incorporó la dimensión de variables psicosociales asociadas a la adicción digital, que recoge indicadores relacionados con las posibles consecuencias del uso intensivo de redes sociales en la vida cotidiana de los estudiantes, entre los que se incluyen la afectación del sueño, dificultades de concentración, alteraciones en el estado de ánimo, impacto en las relaciones sociales, malestar o ansiedad ante la imposibilidad de acceder a las redes y la presencia de intentos fallidos por reducir el tiempo de uso. (Hasan et al., 2025)

3.4.1.3 Exploración de datos

En esta fase del estudio se llevó a cabo una exploración inicial de la base de datos con el propósito de comprender en profundidad su estructura, verificar la integridad y coherencia de los registros y obtener una primera caracterización descriptiva del comportamiento digital de los estudiantes participantes. Esta revisión preliminar permitió reconocer las variables más relevantes del estudio, analizar sus distribuciones generales y detectar posibles inconsistencias o anomalías en los datos antes de avanzar hacia procesos de limpieza, transformación y análisis avanzado. De esta manera, se estableció un panorama inicial que facilitó la comprensión global del conjunto de información recolectada y su adecuación a los objetivos planteados en la investigación. (Noorulfakhri et al., 2025)

La exploración se realizó mediante la importación de la base de datos al entorno de Power BI, herramienta que permitió construir visualizaciones descriptivas iniciales, tales como tablas de frecuencia, conteos absolutos y porcentajes, orientadas a resumir las principales características de la población analizada. En esta etapa se revisaron indicadores básicos como el

número total de estudiantes encuestados (296), la distribución por género y grupos etarios, las horas diarias dedicadas al uso de redes sociales, la plataforma de uso más frecuente y la frecuencia de revisión diaria. Asimismo, se examinó la presencia de categorías atípicas o valores poco plausibles, por ejemplo, respuestas con frecuencias muy bajas o posibles incongruencias entre el tiempo reportado de uso de redes sociales y la percepción subjetiva de uso excesivo. Este análisis permitió anticipar criterios claros para la depuración posterior de los datos y la definición de reglas para el tratamiento de valores inconsistentes. (Goh et al., 2023)

La realización de esta etapa resultó fundamental desde el punto de vista metodológico, ya que la exploración inicial actúa como un mecanismo de control de calidad que garantiza que la base de datos sea adecuada para el análisis y que la información contenida sea consistente con los objetivos del estudio. Además, esta fase facilitó la identificación temprana de patrones generales, como una elevada exposición al uso de redes sociales y el predominio de determinadas plataformas digitales, lo cual fortaleció la pertinencia y justificación del empleo de las reglas de asociación. (Hoodbhoy et al., 2021)

3.4.2. Scrubbing Data (Limpiar Datos)

3.4.2.1. Selección de datos

En esta subetapa del proceso metodológico se llevó a cabo una selección rigurosa de los datos relevantes para el análisis, con el fin de asegurar la coherencia entre la información disponible y los objetivos específicos de la investigación. Para ello, se identificaron y priorizaron aquellas variables que guardan una relación directa con el fenómeno de estudio, permitiendo centrar el análisis en los factores más representativos del uso de redes sociales y de la adicción digital en estudiantes de nivel secundario. (Shameti & Cico, 2025)

En particular, se consideraron las variables sociodemográficas básicas, como la edad y el género, debido a su importancia para la caracterización de la población y para el análisis comparativo entre distintos grupos. Asimismo, se incluyeron variables vinculadas al uso de redes sociales, tales como las horas diarias de uso, la frecuencia de revisión de las plataformas,

el número de redes sociales utilizadas de manera simultánea, la plataforma de uso más frecuente y el dispositivo principal de acceso, ya que estas permiten describir con mayor precisión los hábitos digitales de los participantes. (Perdomo & Ordinez, 2024)

3.4.2.2. Limpieza de datos

Una vez definidas y seleccionadas las variables clave para el estudio, se llevó a cabo un proceso sistemático de limpieza de los datos, cuyo objetivo principal fue garantizar la calidad, consistencia y coherencia interna de la base de datos antes de su análisis avanzado. Se desarrolló un proceso exhaustivo de verificación y depuración de la base de datos, orientado a asegurar la consistencia, coherencia y confiabilidad de los registros utilizados en el análisis. Esta etapa contempló la revisión detallada de cada respuesta, garantizando su correcta categorización, codificación y alineación con las variables definidas en el instrumento de investigación. De igual manera, se procedió a la detección y eliminación de registros duplicados, incompletos o inconsistentes, con el objetivo de minimizar errores y sesgos que pudieran afectar la interpretación de los resultados. (Dabhade et al., 2021)

3.4.2.3. Construcción de nuevos datos

En este sentido, los datos primarios obtenidos a través de la encuesta estructurada fueron transformados en variables analíticas de mayor nivel de abstracción, con el fin de mejorar su representatividad, coherencia interna y utilidad para el análisis multivariado. (Razaulla et al., 2022)

A partir del conjunto de variables originales recolectadas, se procedió a la construcción de indicadores derivados, diseñados para sintetizar y representar de manera más precisa determinados comportamientos y percepciones de los participantes. Entre estos indicadores se incluyen, por ejemplo, el uso intensivo de redes sociales y la percepción de exceso de tiempo dedicado a estas plataformas, los cuales permiten capturar dimensiones clave del comportamiento digital que no se evidencian de forma aislada en las variables iniciales. (Brand & García, 2023)

La generación de estos indicadores facilitó un análisis posterior más estructurado y significativo, al reducir la complejidad del conjunto de datos y mejorar su interpretabilidad. Asimismo, estos indicadores derivados sirvieron como insumos fundamentales para el análisis multivariado y la identificación de patrones de comportamiento, contribuyendo a una comprensión más integral del fenómeno estudiado y fortaleciendo la capacidad analítica del modelo propuesto.

En la Tabla 5 se describen las principales variables construidas, las variables originales que las componen y su propósito analítico

Tabla 4. *Variables derivadas construidas para el análisis*

Variable nueva	Variables originales	Propósito analítico
Intensidad_uso	Horas_uso, Frecuencia	Medir nivel global de uso
Riesgo_psicosocial	Ítems BSMAS	Clasificación de riesgo
Perfil_digital	Uso nocturno, plataformas	Segmentación conductual


Nota: Fuente elaboración propia

Asimismo, a partir de los ítems que conforman la escala Bergen Social Media Addiction Scale (BSMAS), se construyeron variables categóricas que representaron distintos niveles de riesgo psicosocial.

Diseñar variables específicas permitió identificar patrones clave, como los intentos fallidos por disminuir el tiempo en redes sociales o la fuerte dependencia del teléfono móvil. Estos indicadores fueron fundamentales para detectar relaciones que se repetían a lo largo del análisis. A partir de ello, fue posible tener una visión más clara de cómo ciertos comportamientos digitales se vinculan con los riesgos psicosociales que afectan a la población estudiada.

Aplicamos procedimientos de normalización para asegurar que las diferencias en las escalas de los datos no sesgaran los resultados. Este ajuste fue clave para optimizar técnicas avanzadas como el PCA. Al estandarizar las variables, logramos una reducción de dimensionalidad más sólida y una segmentación de estudiantes mucho más precisa y confiable.

Ilustración 19. Datos luego del tratamiento



	Edad	Genero	Horas_Internet	Dispositivo_Principal	Horas_Red
1	12-13 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
2	14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
3	14-15 años	Masculino	4-6 horas	Teléfono móvil	4-6 horas
4	14-15 años	Femenino	4-6 horas	Teléfono móvil	1-3 horas
5	14-15 años	Masculino	1-3 horas	Teléfono móvil	1-3 horas
6	14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
7	12-13 años	Femenino	1-3 horas	Teléfono móvil	1-3 horas
8	14-15 años	Femenino	4-6 horas	Teléfono móvil	4-6 horas
9	14-15 años	Masculino	Más de 6 horas	Teléfono móvil	4-6 horas
10	12-13 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
11	14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
12	14-15 años	Femenino	1-3 horas	Teléfono móvil	1-3 horas
13	14-15 años	Femenino	4-6 horas	Teléfono móvil	1-3 horas
14	14-15 años	Femenino	4-6 horas	Teléfono móvil	1-3 horas
15	12-13 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
16	12-13 años	Masculino	1-3 horas	Tablet	1-3 horas
17	14-15 años	Masculino	Más de 6 horas	Teléfono móvil	Más de 6 horas
18	14-15 años	Femenino	Más de 6 horas	Teléfono móvil	Más de 6 horas
19	14-15 años	Masculino	Más de 6 horas	Nintendo Switch	1-3 horas
20	12-13 años	Femenino	4-6 horas	Teléfono móvil	4-6 horas
21	14-15 años	Masculino	4-6 horas	Tablet	1-3 horas

Nota: Información extraída del documento elaborado en Power BI.

La ilustración 19 representa el proceso de construcción de nuevas variables analíticas a partir de los datos originales, realizado durante la etapa de Scrubbing Data. Esta transformación permitió generar indicadores compuestos más robustos, facilitando el análisis avanzado mediante técnicas de aprendizaje de máquina.

3.4.2.4. Integración de datos


En una primera instancia, se procedió a la integración de los datos sociodemográficos de los estudiantes como lo son la edad, género y nivel educativo con las variables relacionadas con el uso de redes sociales, tales como el número de horas de uso diario, la frecuencia de revisión, la cantidad de plataformas utilizadas y el dispositivo principal de acceso. (Li et al., 2021)

Una vez finalizado el proceso de depuración y validación, los datos fueron integrados y consolidados en una única base de datos estructurada dentro del entorno de Power BI, lo que

permitió centralizar la información de manera ordenada y coherente. Esta integración facilitó la vinculación entre las distintas variables y dimensiones analizadas, asegurando la consistencia de los registros y la trazabilidad de la información a lo largo del proceso analítico. (Li et al., 2021)

Gracias a esta base unificada, fue posible realizar un análisis conjunto e integral de los datos, combinando variables sociodemográficas, hábitos de uso digital e indicadores derivados en un mismo entorno visual. Además, el uso de Power BI permitió explorar los datos de forma dinámica mediante filtros, segmentaciones y visualizaciones interactivas, lo que fortaleció la interpretación de resultados y optimizó el proceso de análisis posterior. (Kennedy et al., 2023)

Ilustración 20. Integración de múltiples conjuntos de datos mediante modelo relacional en Power BI



Nota: Información extraída del documento elaborado en Power BI.


En la ilustración 20 se evidencia el proceso de integración de los distintos conjuntos de datos generados a lo largo de la investigación. Esta etapa garantizó la coherencia, consistencia y trazabilidad de la información utilizada en las fases posteriores de exploración y modelado.

El proceso de integración se evidencia en el modelo relacional implementado en Power BI, el cual permitió vincular los distintos conjuntos de datos mediante claves comunes.

3.4.2.5. Formato de datos

En una primera instancia, se llevó a cabo la homogeneización de los tipos de datos, verificando que las variables numéricas, categóricas y binarias estuvieran correctamente definidas de acuerdo con su naturaleza analítica. Las variables cuantitativas, tales como el número de horas de uso diario de redes sociales, la frecuencia de revisión y los puntajes obtenidos en la escala BSMAS, fueron transformadas a formatos numéricos apropiados, lo que permitió su incorporación efectiva en análisis estadísticos, técnicas de reducción de dimensionalidad y algoritmos de aprendizaje de máquina. (Alarcón Alláin, 2021)

Ilustración 21. Estandarización y formateo de los datos en Power BI



The screenshot shows the Power BI Desktop interface with the 'Transform' ribbon active. The main view displays a table with columns: 'Edad', 'Genero', 'Horas_Internet', 'Dispositivo_Principal', and 'Horas_Red'. The table contains 21 rows of data. On the right, the 'Configuración de la consulta' pane is open, showing the 'PASOS APLICADOS' (Applied Steps) list. The steps include: 'Origen', 'Tipo cambiado', 'Columnas quitadas', 'Texto extraído después de...', 'Filas en blanco eliminadas', 'Valor reemplazado', 'Valor reemplazado1', 'Columnas con nombre ca...', 'Valor reemplazado2', 'Valor reemplazado3', 'Valor reemplazado4', 'Valor reemplazado5', 'Valor reemplazado6', 'Valor reemplazado7', 'Valor reemplazado8', and 'Valor reemplazado9'. The 'PROPIEDADES' (Properties) pane on the right shows the table name as 'REPUESTAS TESIS ISABELLA - Respuestas'.

	Edad	Genero	Horas_Internet	Dispositivo_Principal	Horas_Red
1	12-13 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
2	14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
3	14-15 años	Masculino	4-6 horas	Teléfono móvil	4-6 horas
4	14-15 años	Femenino	4-6 horas	Teléfono móvil	1-3 horas
5	14-15 años	Masculino	1-3 horas	Teléfono móvil	1-3 horas
6	14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
7	12-13 años	Femenino	1-3 horas	Teléfono móvil	1-3 horas
8	14-15 años	Femenino	4-6 horas	Teléfono móvil	4-6 horas
9	14-15 años	Masculino	Más de 6 horas	Teléfono móvil	4-6 horas
10	12-13 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
11	14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
12	14-15 años	Femenino	1-3 horas	Teléfono móvil	1-3 horas
13	14-15 años	Femenino	4-6 horas	Teléfono móvil	1-3 horas
14	14-15 años	Femenino	4-6 horas	Teléfono móvil	1-3 horas
15	12-13 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas
16	12-13 años	Masculino	1-3 horas	Tablet	1-3 horas
17	14-15 años	Masculino	Más de 6 horas	Teléfono móvil	Más de 6 horas
18	14-15 años	Femenino	Más de 6 horas	Teléfono móvil	Más de 6 horas
19	14-15 años	Masculino	Más de 6 horas	Nintendo Switch	1-3 horas
20	12-13 años	Femenino	4-6 horas	Teléfono móvil	4-6 horas
21	14-15 años	Masculino	4-6 horas	Tablet	1-3 horas

Nota: Información extraída del documento elaborado en Power BI.

La ilustración 21 muestra el proceso de estandarización y formateo de los datos, asegurando la compatibilidad entre variables y la correcta interpretación por parte de los algoritmos de aprendizaje de máquina. Este procedimiento fue clave para mantener la calidad del análisis.


Posteriormente, se procedió a la estandarización de las nomenclaturas de las variables, adoptando un esquema uniforme de nombres de campos que evitó el uso de caracteres especiales, espacios en blanco y ambigüedades conceptuales. (Laveriano Varas, 2023)

De manera complementaria, se realizó la recodificación de variables ordinales y categóricas en rangos analíticamente relevantes. Por ejemplo, las respuestas relacionadas con la percepción de uso excesivo, la interferencia de las redes sociales en el rendimiento académico y los intentos fallidos de reducción del tiempo de conexión fueron agrupadas en categorías homogéneas, lo que permitió disminuir la dispersión de las respuestas originales y mejorar la claridad interpretativa en los análisis multivariados. (Ccorahua Estrada, 2023)

Asimismo, se aplicaron procesos de normalización y escalamiento a las variables numéricas empleadas en técnicas de aprendizaje de máquina no supervisado, particularmente en el PCA. Este procedimiento garantizó que todas las variables influyeran de manera equilibrada en el análisis, evitando sesgos derivados de diferencias en las magnitudes numéricas y preservando la estructura subyacente de los datos. (Arias & Fernández, 2025)

Finalmente, todas las transformaciones ejecutadas durante esta fase fueron debidamente documentadas, registrando los criterios de formateo, estandarización, recodificación y escalamiento aplicados a cada variable. Esta documentación fortaleció la trazabilidad del proceso analítico, facilitó la replicabilidad del estudio y aseguró una interpretación adecuada de los resultados. En consecuencia, el correcto formato de los datos permitió que la base consolidada cumpliera con los requerimientos técnicos y metodológicos necesarios para el desarrollo de un análisis riguroso, consistente y confiable del comportamiento digital de los estudiantes. (Javier López-Fernández et al., 2025)

Ilustración 22. Aplicación de la metodología OSEMN para los datos



ISABELLA TESIS OFICIAL 2.0 • Guardado por última vez: 2/1/2026 a las 11:55 • ISABELLA VERONICA AGUILAR AGUILERA

Archivo Inicio Ayuda Herramientas de tablas

Nombre: REPUESTAS TESIS L...

Estructura Relaciones Cálculos Calendarios

Edad	Genero	Horas_Internet	Dispositivo_Principal	Horas_Red	Veces_Revisas	Num_Red	Plataforma_Frecuente	Notificaciones_Diarias	Revisa_Al_Despe
12-13 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas	Entre 11 y 20 veces	1	Tik Tok	Más de 50	Realizo otra actividad (est
12-13 años	Femenino	4-6 horas	Teléfono móvil	4-6 horas	Menos de 5 veces	2-3	Tik Tok	Entre 31 y 50	Realizo otra actividad (est
14-15 años	Masculino	4-6 horas	Tablet	1-3 horas	Menos de 5 veces	1	Tik Tok	Entre 10 y 30	Realizo otra actividad (est
14-15 años	Masculino	Más de 6 horas	Nintendo Switch	4-6 horas	Entre 5 y 10 veces	2-3	Tik Tok	Menos de 10	Realizo otra actividad (est
14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas	Entre 11 y 20 veces	2-3	Tik Tok	Entre 10 y 30	Realizo otra actividad (est
14-15 años	Femenino	Más de 6 horas	Teléfono móvil	Más de 6 horas	Entre 11 y 20 veces	2-3	Instagram	Más de 50	Realizo otra actividad (est
14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas	Entre 5 y 10 veces	4-5	Instagram	Más de 50	Realizo otra actividad (est
14-15 años	Prefiero no decirlo	1-3 horas	Computadora	1-3 horas	Entre 5 y 10 veces	2-3	Instagram	Menos de 10	Realizo otra actividad (est
14-15 años	Femenino	1-3 horas	Teléfono móvil	Más de 6 horas	Entre 11 y 20 veces	1	Instagram	Más de 50	Realizo otra actividad (est
14-15 años	Prefiero no decirlo	4-6 horas	Teléfono móvil	4-6 horas	Más de 20 veces	2-3	Instagram	Menos de 10	Realizo otra actividad (est
14-15 años	Femenino	4-6 horas	Teléfono móvil	4-6 horas	Entre 5 y 10 veces	2-3	Instagram	Entre 10 y 30	Realizo otra actividad (est
14-15 años	Masculino	4-6 horas	Teléfono móvil	1-3 horas	Entre 5 y 10 veces	2-3	Instagram	Más de 50	Realizo otra actividad (est
14-15 años	Masculino	1-3 horas	Teléfono móvil	1-3 horas	Entre 5 y 10 veces	2-3	Tik Tok	Entre 10 y 30	Realizo otra actividad (est
12-13 años	Femenino	Más de 6 horas	Computadora	1-3 horas	Entre 11 y 20 veces	2-3	Snapchat	Más de 50	Realizo otra actividad (est
14-15 años	Masculino	1-3 horas	Tablet	1-3 horas	Menos de 5 veces	1	Snapchat	Menos de 10	Realizo otra actividad (est
12-13 años	Masculino	1-3 horas	Teléfono móvil	Más de 6 horas	Menos de 5 veces	1	Snapchat	Más de 50	Realizo otra actividad (est
12-13 años	Masculino	1-3 horas	Tablet	Más de 6 horas	Menos de 5 veces	1	Snapchat	Menos de 10	Realizo otra actividad (est
12-13 años	Masculino	Más de 6 horas	Computadora	1-3 horas	Entre 5 y 10 veces	2-3	Snapchat	Entre 10 y 30	Realizo otra actividad (est
12-13 años	Masculino	Más de 6 horas	Tablet	4-6 horas	Menos de 5 veces	4-5	Snapchat	Más de 50	Realizo otra actividad (est
12-13 años	Masculino	4-6 horas	Computadora	Más de 6 horas	Menos de 5 veces	1	Tik Tok	Menos de 10	Realizo otra actividad (est

Tabla: REPUESTAS TESIS ISABELLA - Respuestas de formulario 1 (296 filas)

Nota: Información extraída del documento elaborado en Power BI.

La ilustración 22 representa las acciones implementadas para garantizar la calidad de los datos, incluyendo validación, detección de inconsistencias y control de valores atípicos. Este proceso fortaleció la fiabilidad de los resultados obtenidos.

3.4.3. Calidad de los datos

3.4.3.1. Imputación de valores faltantes

En una primera fase, se efectuó la detección y cuantificación de valores nulos en las distintas variables que conformaron la base de datos consolidada, empleando las herramientas de transformación de datos disponibles en Power BI. Este procedimiento permitió evaluar el grado de afectación de cada variable y establecer criterios técnicos para decidir entre la aplicación de técnicas de imputación o la exclusión de determinados registros, particularmente en aquellos casos donde la ausencia de información era considerable o comprometía la coherencia interna del análisis.(Manzanares et al., 2021)

Para las variables de carácter sociodemográfico, tales como edad y género, los valores faltantes fueron abordados mediante métodos de imputación basados en la categoría de mayor frecuencia (moda), con el objetivo de preservar la estructura poblacional de la muestra y




minimizar alteraciones en la distribución original de los datos. En cuanto a las variables cuantitativas asociadas al uso de redes sociales, como el número de horas de uso diario y la frecuencia de revisión, se aplicaron estrategias de imputación apoyadas en medidas de tendencia central, priorizando el uso de la mediana en aquellos casos donde se identificó la presencia de valores atípicos, a fin de reducir posibles distorsiones. (Best, 2024)

Respecto a las variables psicosociales derivadas de la escala BSMAS, se adoptó un enfoque de imputación conservador, asegurando que los valores estimados no influyeran de forma artificial en la clasificación de los niveles de riesgo vinculados al uso problemático de las redes sociales. Este criterio permitió mantener la coherencia conceptual de los indicadores construidos y garantizar la validez de los análisis multivariados desarrollados en etapas posteriores. (Boer et al., 2020)

Cabe destacar que todo el proceso de imputación fue ejecutado de manera controlada, sistemática y debidamente documentada, registrando los criterios específicos aplicados a cada tipo de variable. En ningún caso se recurrió a imputaciones arbitrarias ni a estimaciones carentes de sustento metodológico que pudieran distorsionar el comportamiento real de los datos. Gracias a este enfoque, fue posible conservar un mayor número de observaciones válidas, optimizando el tamaño efectivo de la muestra y fortaleciendo la solidez estadística de los modelos implementados. (Abdel Wahed & Wahed, 2025)

Ilustración 23. Evaluación de la calidad de los datos posterior a la imputación de valores faltantes



Nota: Información extraída del documento elaborado en Power BI.

La ilustración 23 evidencia la combinación final de los distintos conjuntos de datos derivados de la encuesta, el PCA, el clustering y las reglas de asociación. Esta integración permitió un análisis global y multidimensional del comportamiento digital de los estudiantes.

3.4.3.2. Combinación de diferentes conjuntos de datos

En una primera instancia, se realizó la identificación y selección de los conjuntos de datos relevantes producidos durante las etapas previas del enfoque metodológico OSEMN. Entre estos se incluyeron la base de datos original de respuestas de la encuesta, las variables psicosociales construidas a partir de la escala BSMAS, los componentes principales obtenidos mediante el Análisis de Componentes Principales (PCA), y los patrones identificados a través del análisis de reglas de asociación. (Ruiz Pimiento et al., 2021)

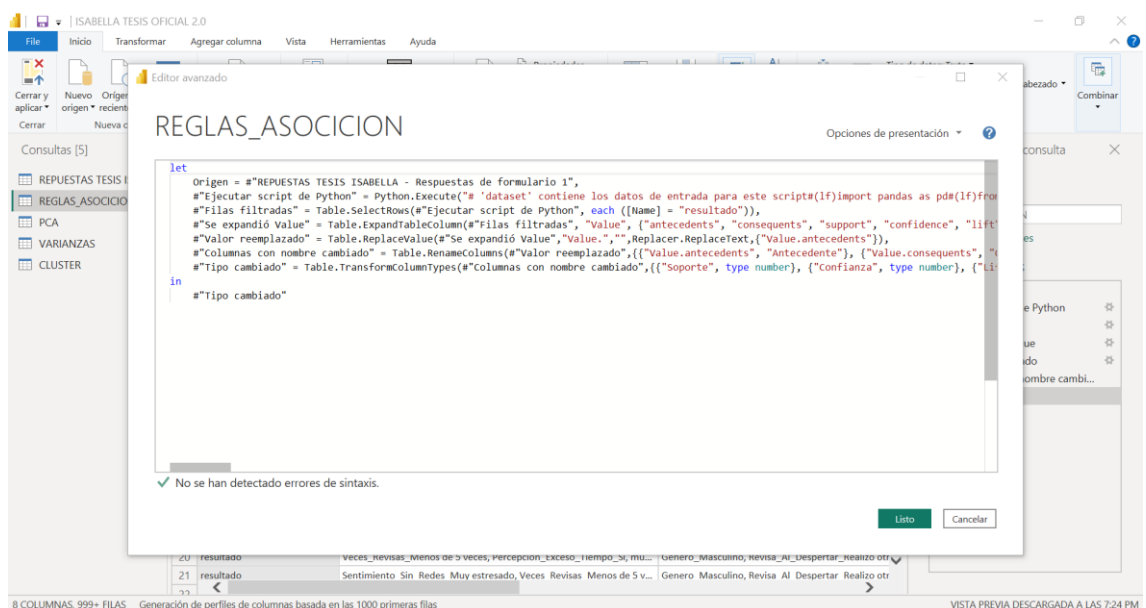
Tabla 5. *Conjuntos de datos integrados para el análisis*

Conjunto de datos	Fuente	Rol en el análisis
Datos encuesta	Encuesta	Base principal
Variables BSMAS	Escala	Riesgo psicosocial

Nota: Fuente elaboración propia.

Durante esta etapa se implementaron mecanismos de verificación cruzada con el propósito de asegurar la coherencia entre los conjuntos de datos combinados. Se revisó la consistencia de los registros, la correcta alineación de los tipos de variables y la ausencia de valores anómalos derivados del proceso de unión. Asimismo, se validó que los resultados del PCA y de los clústeres se incorporaran adecuadamente como variables adicionales dentro de la estructura final, permitiendo su utilización en análisis comparativos, segmentación de perfiles y visualización de patrones de comportamiento. (Torres & Cardenas, 2021)

Ilustración 24. Tendencias generales del trabajo



Nota: Información extraída del documento elaborado en Power BI.

En la ilustración 24 se muestran los resultados del análisis exploratorio de datos, permitiendo identificar tendencias generales, distribuciones y posibles anomalías en el comportamiento digital de los estudiantes antes de la fase de modelado.

3.4.4. Exploring Data (Explorar Datos)

En una primera instancia, se desarrolló un análisis descriptivo univariado mediante el uso de tablas dinámicas y representaciones gráficas en Power BI, lo que posibilitó caracterizar a la población objeto de estudio a partir de variables sociodemográficas como la edad y el género.. (Veluri et al., 2022)

Posteriormente, se efectuó un análisis descriptivo bivariado y multivariado centrado en las variables relacionadas con el uso de redes sociales, entre las que se incluyeron las horas de uso diario, la frecuencia de revisión, el número de plataformas empleadas, el dispositivo principal de acceso y la red social más utilizada. Mediante gráficos de barras, histogramas y tablas comparativas, se identificaron patrones recurrentes de comportamiento digital, evidenciando niveles elevados de exposición y uso intensivo de las redes sociales por parte de los estudiantes. (Santabárbara, 2021)

De forma complementaria, se exploraron las variables psicosociales derivadas de la escala BSMAS, analizando tanto su distribución como su relación con los indicadores de comportamiento digital. Este análisis permitió identificar manifestaciones relevantes de malestar ante la desconexión, uso emocional de las redes sociales y percepción de un tiempo excesivo de conexión. (Ventre et al., 2024)

Asimismo, se incorporaron técnicas de exploración multivariada, particularmente el Análisis de Componentes Principales (PCA), con el objetivo de reducir la dimensionalidad del conjunto de datos y facilitar la visualización de su estructura subyacente. La proyección de los registros en el espacio de los componentes principales permitió identificar agrupamientos naturales de estudiantes con comportamientos digitales similares, contribuyendo a una mejor comprensión de la variabilidad existente en la muestra y sirviendo como base para los procesos posteriores de segmentación. (Pilamunga et al., 2024)

Ilustración 25. Análisis exploratorio descriptivo del uso de redes sociales en estudiantes



Nota: Información extraída del documento elaborado en Power BI.

La ilustración 25 presenta la proyección de los datos en el espacio reducido generado por el PCA, donde se observan agrupamientos naturales de estudiantes. Esta distribución confirma la existencia de patrones diferenciados de comportamiento digital y respalda la pertinencia de la reducción de dimensionalidad.

3.4.5. Modeling (Modelar)

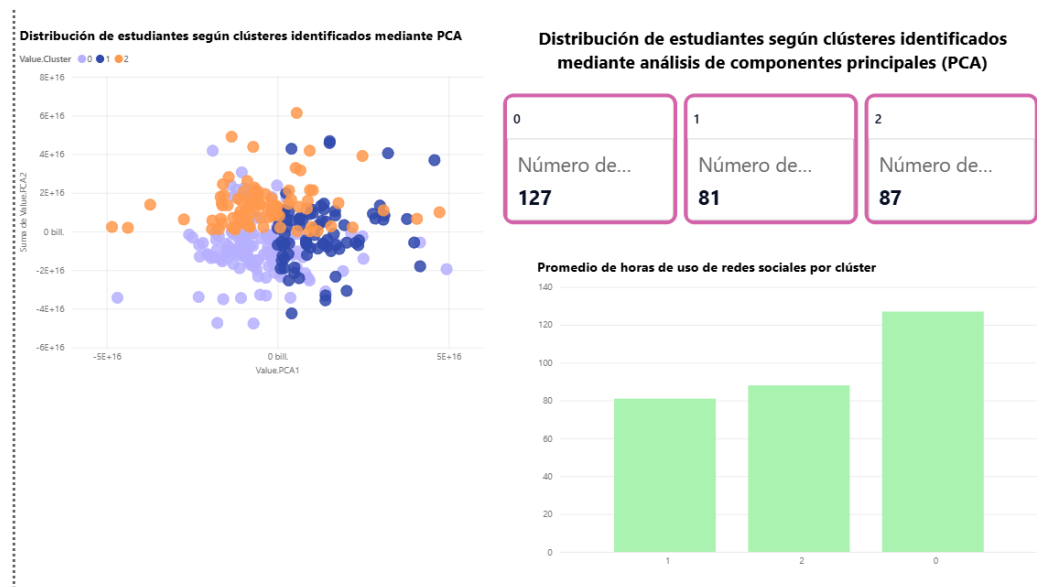
Esta etapa se sustentó en el empleo de enfoques no supervisados, cuya elección respondió a su capacidad para analizar patrones complejos sin la necesidad de contar con variables objetivo previamente etiquetadas, lo cual resulta especialmente pertinente en el estudio de conductas digitales y dimensiones psicosociales.(Valles-Coral et al., 2022)

En una primera instancia, se implementó el Análisis de Componentes Principales (PCA) como técnica de reducción de dimensionalidad, orientada a condensar la información contenida en un conjunto amplio de variables relacionadas con el uso de redes sociales y los indicadores psicosociales evaluados. Mediante este procedimiento, las variables originales, caracterizadas por altos niveles de correlación, fueron transformadas en un número reducido de componentes

principales ortogonales, conservando la mayor proporción posible de la varianza total del conjunto de datos. (Veloza Gamba, 2023)

De manera complementaria, se incorporó el análisis de reglas de asociación como técnica orientada a identificar relaciones frecuentes entre combinaciones de variables de comportamiento digital y consecuencias psicosociales. Este enfoque permitió extraer patrones de tipo condicional (“si-entonces”), evidenciando asociaciones significativas entre variables como el tiempo de uso, la frecuencia de conexión, la plataforma predominante y la percepción de exceso de tiempo, con indicadores relacionados con la dificultad para controlar o reducir el uso de redes sociales. Las reglas generadas fueron evaluadas y filtradas a partir de métricas como soporte, confianza y lift, priorizando aquellas que presentaron mayor relevancia y consistencia analítica. (Valero Cajahuanca et al., 2022)

Ilustración 26. Segmentación de estudiantes mediante clustering



Nota: Información extraída del documento elaborado en Power BI.

La ilustración 26 muestra la segmentación de los estudiantes, evidenciando perfiles diferenciados de uso de redes sociales. Estos clústeres facilitan la identificación de grupos con mayor riesgo de adicción digital.

3.4.6. Interpreting Results (Interpretar Resultados)

En primer término, los resultados obtenidos a partir del Análisis de Componentes Principales (PCA) evidenciaron que un número reducido de componentes fue suficiente para explicar una proporción considerable de la variabilidad total del conjunto de datos. Este hallazgo sugiere que el comportamiento digital de los estudiantes puede ser interpretado a través de un conjunto limitado de dimensiones fundamentales, estrechamente vinculadas con la intensidad de uso de las redes sociales, la frecuencia de interacción y las variables psicosociales asociadas al malestar ante la desconexión y al uso emocional de dichas plataformas. (Pérez González, 2021)

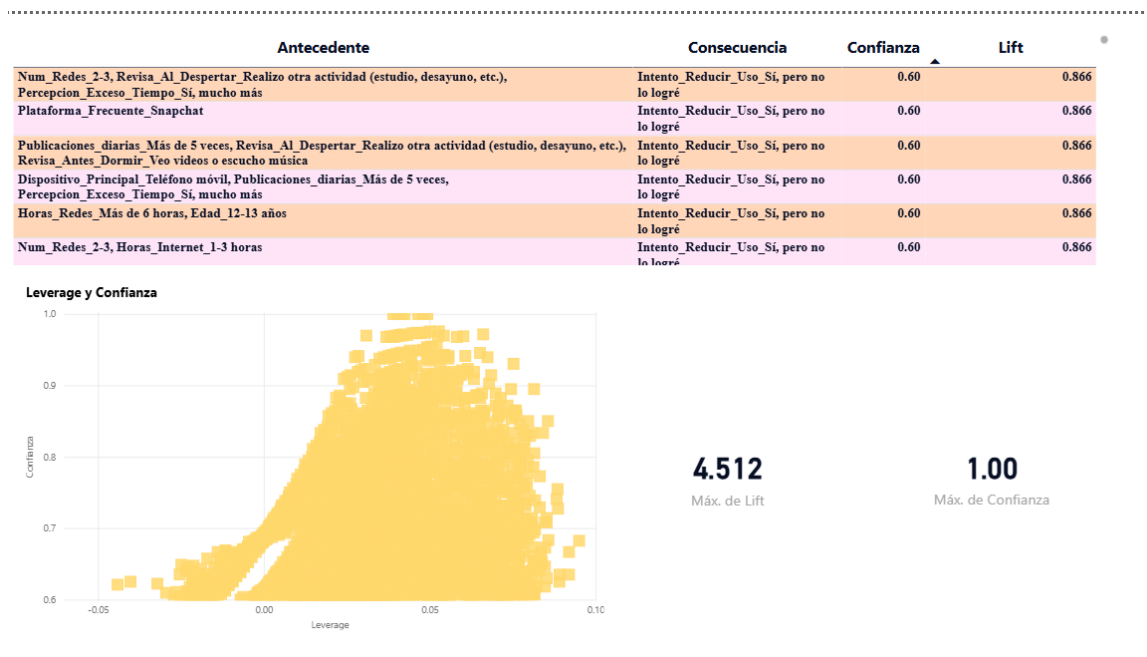
Se reconocieron perfiles que abarcan desde un uso moderado hasta un uso intensivo y potencialmente problemático, los cuales se distinguen principalmente por el tiempo de conexión, la frecuencia de revisión de las plataformas digitales y los niveles de afectación psicosocial reportados. Esta segmentación pone de manifiesto que la población estudiada presenta una marcada heterogeneidad en su comportamiento digital, lo que implica la necesidad de diseñar estrategias de intervención diferenciadas y ajustadas a las características específicas de cada perfil. (Luo et al., 2021)

De manera complementaria, el análisis de reglas de asociación permitió identificar relaciones relevantes entre combinaciones de conductas digitales y consecuencias psicosociales. Las reglas que presentaron mayores valores de soporte, confianza y lift evidenciaron que comportamientos como un elevado número de horas de uso diario, la utilización predominante del teléfono móvil como dispositivo de acceso y la percepción subjetiva de un uso excesivo de las redes sociales se asocian de forma recurrente con intentos fallidos de reducir el tiempo de conexión y con niveles elevados de malestar emocional. Estos resultados refuerzan la existencia de patrones conductuales consistentes que pueden ser interpretados como indicadores de riesgo de adicción a redes sociales. (Osorio & Enerieth, 2020)

Finalmente, la interpretación integrada de los resultados obtenidos mediante el PCA, el agrupamiento por clústeres y el análisis de reglas de asociación permitió alcanzar una

comprensión holística del fenómeno analizado, al articular la reducción de la complejidad de los datos, la segmentación de perfiles de comportamiento y la identificación de relaciones frecuentes entre variables. (Pech et al., 2021)

Ilustración 27. Reglas de asociación con mayor relevancia analítica



Nota: Información extraída del documento elaborado en Power BI.

La ilustración 27 sintetiza la interpretación global de los resultados obtenidos mediante los modelos de aprendizaje de máquina, integrando los hallazgos del PCA, el clustering y las reglas de asociación. Esta visualización permite comprender de manera integral el aporte del aprendizaje de máquina en la detección de patrones de adicción a redes sociales.



CAPÍTULO IV

HALLAZGOS CLAVES

La exposición de los resultados se orienta a ofrecer una visión estructurada y comprensiva del fenómeno analizado, destacando cómo determinadas prácticas de uso de las redes sociales se asocian con manifestaciones de malestar emocional, dificultades en el control del tiempo de conexión y conductas de uso intensivo. (Cabero-Almenara et al., 2020)

4.1 Hallazgos relacionados con la caracterización del comportamiento digital

Uno de los hallazgos más relevantes de la investigación fue la elevada exposición de los estudiantes al uso intensivo de las redes sociales, la cual se evidenció a través de un número considerable de horas diarias de conexión, una frecuencia recurrente de revisión de las plataformas digitales y el uso predominante de dispositivos móviles como principal medio de acceso. (Cortez Castro, 2021)

Adicionalmente, se identificó que una proporción significativa de los estudiantes percibe que dedica más tiempo del que considera adecuado al uso de las redes sociales, lo que se encuentra estrechamente asociado con intentos reiterados y poco exitosos de reducir el tiempo de conexión. Este resultado sugiere la presencia de conductas de uso compulsivo, caracterizadas por una limitada capacidad de autorregulación del comportamiento digital, incluso en contextos donde existe una clara conciencia del uso excesivo. (Fuentes et al., 2024)

4.2 Hallazgos derivados del análisis de componentes principales (PCA)

El Análisis de Componentes Principales (PCA) permitió simplificar de manera significativa la complejidad del conjunto de datos original, al identificar un número reducido de

componentes capaces de explicar una proporción sustancial de la variabilidad total presente en la información analizada. Este resultado pone de manifiesto que el comportamiento digital de los estudiantes puede ser interpretado a partir de un conjunto limitado de dimensiones latentes fundamentales, estrechamente vinculadas con la intensidad de uso de las redes sociales, la frecuencia de interacción con dichas plataformas y los indicadores psicosociales de malestar asociados a la desconexión. (Pascual-Triana, 2024)

Asimismo, la reducción de dimensionalidad obtenida mediante el PCA permitió evidenciar la existencia de una estructura interna coherente en el conjunto de variables analizadas, lo que confirma la adecuada selección de los indicadores empleados y la consistencia de las transformaciones realizadas durante la etapa de Scrubbing Data. En particular, los resultados reflejan que las variables construidas capturan de forma adecuada los distintos aspectos del comportamiento digital y su relación con factores psicosociales relevantes. (Segura Delgado, 2021)

4.3 Hallazgos asociados a la segmentación de estudiantes mediante clústeres

En particular, los estudiantes clasificados en los clústeres asociados a un mayor nivel de riesgo presentan valores significativamente elevados en variables clave, tales como el número de horas de uso diario, la frecuencia de revisión de las redes sociales y la utilización de estas plataformas durante horarios nocturnos. Asimismo, estos grupos muestran mayores niveles de malestar emocional ante la imposibilidad de conectarse, lo que sugiere una relación estrecha entre el uso intensivo de las redes sociales y dificultades en la regulación emocional. (Estrada Araoz et al., 2020)

Este hallazgo pone de relieve la marcada heterogeneidad del comportamiento digital dentro de la población estudiada, descartando la existencia de un patrón uniforme de uso. En consecuencia, los resultados obtenidos a partir del agrupamiento refuerzan la necesidad de diseñar estrategias de prevención e intervención diferenciadas, ajustadas a las características

específicas de cada perfil identificado, con el fin de abordar de manera más efectiva el uso problemático de las redes sociales en el contexto educativo. (Veluri et al., 2022)

4.4 Hallazgos del análisis de reglas de asociación

El análisis de reglas de asociación permitió identificar relaciones recurrentes y estadísticamente relevantes entre diversas combinaciones de conductas digitales y variables de carácter psicosocial. Las reglas que presentaron los valores más elevados de soporte, confianza y lift evidenciaron que determinados comportamientos, tales como el uso prolongado de las redes sociales, la revisión frecuente de las plataformas al inicio del día o antes del descanso nocturno, así como la utilización intensiva del teléfono móvil como principal dispositivo de acceso, se asocian de manera consistente con intentos fallidos de reducir el tiempo de conexión y con una percepción subjetiva de uso excesivo. (Farhat et al., 2020)

Estos resultados ponen de manifiesto la existencia de patrones conductuales estables que refuerzan la relación entre el uso intensivo de las redes sociales y el riesgo de desarrollar comportamientos adictivos. En particular, la combinación de hábitos digitales repetitivos y contextos de uso poco regulados incrementa la probabilidad de que los estudiantes experimenten dificultades en la autorregulación del tiempo de conexión, así como niveles elevados de malestar emocional ante la imposibilidad de acceder a las plataformas digitales. (Zheng et al., 2023)

4.5 Integración de hallazgos y aporte del aprendizaje de máquina

La integración de los resultados obtenidos a partir del Análisis de Componentes Principales (PCA), el proceso de agrupamiento por clústeres y el análisis de reglas de asociación permitió alcanzar una comprensión integral y holística del fenómeno investigado. Esta articulación metodológica posibilitó combinar de manera efectiva la reducción de la complejidad del conjunto de datos, la identificación de perfiles diferenciados de comportamiento digital y la detección de relaciones frecuentes y significativas entre las variables analizadas, fortaleciendo la interpretación global de los hallazgos. (Pecuchova & Drlik, 2024)

La aplicación de técnicas de aprendizaje de máquina no supervisado demostró ser una estrategia metodológica pertinente y eficaz para la identificación temprana de patrones de riesgo asociados al uso problemático de las redes sociales. Este enfoque permitió superar las limitaciones del análisis descriptivo tradicional, al revelar estructuras latentes, segmentaciones conductuales y asociaciones complejas que no resultan evidentes mediante métodos convencionales, generando así conocimiento aplicado con potencial impacto en el ámbito educativo. (Hariyanto et al., 2025)

4.6 Validación técnica del modelo implementado

Con el objetivo de asegurar la coherencia metodológica, la solidez estructural y la confiabilidad estadística del modelo desarrollado, se ejecutó un proceso sistemático de validación técnica de las técnicas de aprendizaje de máquina no supervisado implementadas en la presente investigación.

En lo referente al Análisis de Componentes Principales (PCA) y al subsecuente proceso de segmentación, el modelo permitió identificar tres conglomerados claramente diferenciados dentro de la muestra compuesta por 296 estudiantes. El clúster 0 estuvo integrado por 127 estudiantes, el clúster 1 por 82 estudiantes y el clúster 2 por 87 estudiantes. Esta distribución no solo evidencia una segmentación equilibrada de la población analizada, sino que confirma que la reducción dimensional logró preservar la estructura informativa esencial del conjunto de datos, facilitando posteriormente una agrupación coherente basada en patrones de uso de redes sociales y variables psicosociales asociadas. La homogeneidad interna observada en cada clúster, junto con la adecuada diferenciación inter-grupal, respalda la estabilidad analítica y la robustez estructural del modelo.

En relación con las reglas de asociación generadas mediante el algoritmo Apriori, se obtuvo un valor máximo de lift de 4.512, lo que implica que la co-ocurrencia de determinadas variables es más de cuatro veces superior a la probabilidad esperada bajo independencia estadística. Adicionalmente, las reglas principales registraron niveles de confianza comprendidos entre 0.63 y 0.81, alcanzando incluso un valor máximo de 1.00 en combinaciones



específicas. Estos indicadores reflejan una elevada fortaleza relacional y consistencia predictiva, demostrando que las asociaciones identificadas entre variables psicosociales y patrones de uso problemático de redes sociales poseen significancia estadística y no responden a configuraciones aleatorias del conjunto de datos.



CAPÍTULO V

CONCLUSIONES Y RECOMENDACIONES

5.1 Conclusiones

A partir del objetivo general orientado a la elaboración de modelos de aprendizaje de máquina para la detección de patrones de adicción a las redes sociales en estudiantes de secundaria, se evidenció que la incorporación de técnicas de aprendizaje no supervisado permitió identificar patrones consistentes y claramente diferenciados de comportamiento digital asociados al uso problemático de estas plataformas.

En relación con el objetivo específico de aplicar la encuesta validada BSMAS para obtener datos confiables sobre el uso de redes sociales, los resultados mostraron que una proporción considerable del alumnado presenta señales que podrían estar relacionadas con una posible adicción de tipo conductual. En particular, se identificó que el 53.04 % de los estudiantes hace un uso intensivo de las redes sociales, lo cual suele ir acompañado de un alto nivel de malestar cuando no pueden conectarse, un fuerte componente emocional en su uso y varios intentos fallidos por reducir el tiempo que pasan en línea.

El análisis exploratorio de los datos permitió caracterizar la conducta digital de los estudiantes. Se observa que consultan redes sociales muchas veces cada día. La plataforma más usada es TikTok. Esta conducta impacta de forma directa en aspectos importantes de la vida académica y personal - la capacidad de concentración, la calidad del sueño y el estado de ánimo.

El propósito específico fue aplicar algoritmos de aprendizaje no supervisado que midieran el riesgo de adicción digital. El Análisis de Componentes Principales y la agrupación en clústeres mostraron perfiles de estudiante separados por su conducta digital. Aparecieron grupos cuyo promedio de horas en redes sociales superó con claridad al resto, lo que comprueba la existencia de segmentos de alta exposición al riesgo y demuestra que el aprendizaje no supervisado divide conductas en entornos educativos.



En relación con el objetivo de proponer recomendaciones prácticas y sostenibles para un uso saludable de las redes sociales en el entorno escolar, se concluye que los resultados obtenidos a través de modelos de aprendizaje automático brindan una base empírica sólida para desarrollar estrategias de prevención. Identificar perfiles de riesgo, grupos diferenciados y patrones de asociación con altos niveles de confianza permite enfocar acciones concretas hacia estudiantes, docentes y familias. Estas acciones pueden centrarse en regular el uso de redes sociales, fortalecer el bienestar emocional y prevenir conductas adictivas dentro del contexto educativo.

5.2 Recomendaciones

A partir de los resultados obtenidos en la presente investigación, se recomienda que las instituciones educativas promuevan estrategias orientadas al bienestar digital de los estudiantes, basadas en el análisis de datos y la detección temprana de patrones de uso problemático de redes sociales. El uso de modelos de aprendizaje de máquina demostró ser una herramienta eficaz para identificar conductas de riesgo, por lo que su incorporación en el ámbito educativo permitiría una gestión más preventiva y fundamentada en evidencia.

Por lo cual se sugiere que los centros escolares propongan planes que ayuden a cada alumno según sus hábitos de pantalla, para poder favorecer la concentración y el correcto desempeño académico de quienes consumen redes durante muchas horas, se resisten a limitar la conexión y muestran pérdida de sueño, atención o humor. Las acciones apuntan a reforzar la labor del tutor y del servicio de orientación.

Las instituciones deberían elaborar reglamentos internos que promuevan el uso responsable de las redes sociales. Más allá de solo establecer normas, estos reglamentos tendrían que incluir talleres donde los estudiantes aprendan a manejar sus impulsos, a usar la tecnología con conciencia y a desarrollar hábitos digitales que les beneficien. El enfoque debe estar en formar, no en restringir, alentando a que el alumnado participe de forma activa y crítica en el mundo digital.



Siguiendo la idea anterior, se proponen encuentros regulares entre profesores y alumnos basados en los hallazgos del análisis de datos. Durante estos encuentros, el alumno detecta sus hábitos digitales, valora sus logros, detecta aspectos que debe mejorar y fija objetivos personales para emplear las redes sociales con mayor equilibrio, con la guía del docente.

Por otra parte, se sugiere que las autoridades educativas impulsen la sistematización de las experiencias obtenidas a partir de la aplicación de estrategias de bienestar digital, con el fin de construir una memoria institucional. Esta documentación facilitaría la replicación de buenas prácticas, la mejora continua de las acciones implementadas y la capacitación del profesorado en el uso pedagógico de herramientas analíticas.

Finalmente, se recomienda mantener un sistema de seguimiento continuo que permita evaluar el impacto de las estrategias implementadas en indicadores como el rendimiento académico, la motivación y la permanencia estudiantil. De igual manera, se propone fomentar futuras líneas de investigación que incorporen nuevas fuentes de datos y técnicas de inteligencia artificial, con el objetivo de fortalecer la personalización de las intervenciones y ampliar el alcance del bienestar digital en el contexto educativo



TRABAJOS FUTUROS

Tomando en cuenta los resultados obtenidos y las dificultades encontradas durante esta investigación, se identifican varias posibilidades para seguir trabajando en el tema. Estas nuevas líneas permitirían ampliar, profundizar y fortalecer el análisis sobre la adicción a las redes sociales en estudiantes de secundaria, integrando una mirada más completa que combine lo tecnológico, lo educativo y lo psicosocial.

En primer lugar, valdría la pena mirar más allá del grupo del cual fue tomada la muestra. Probar con más estudiantes, de distintas instituciones, de la Costa, la Sierra, la Amazonía, de ciudades grandes y de zonas rurales. Se evidencian diferencias significativas en los patrones de uso según el contexto geográfico y socioeducativo.

Al sumar realidades distintas, los modelos no solo se ponen a prueba, también se vuelven más confiables. Permite ver si lo que funciona en un contexto realmente se repite en otro o si cambia el patrón. Así se pueden comparar hábitos digitales entre entornos educativos diferentes y tener más certeza de que los resultados no dependen solo del lugar donde se levantaron los datos, sino que reflejan comportamientos más generales.

Por otro lado, es importante también explorar el uso de modelos un poco más sofisticados de aprendizaje automático, como lo son las llamadas técnicas de aprendizaje profundo, donde se incluyen las redes neuronales artificiales, autoencoders, así como modelos híbridos supervisados y no supervisados.

Otro aspecto a tomar en cuenta es el desarrollo de estudios de tipo longitudinal, mismo que permitan analizar la evolución del comportamiento digital de los estudiantes a lo largo del tiempo. Este enfoque facilitaría la identificación de cambios progresivos en los hábitos de uso de redes sociales, la persistencia o modificación de los patrones de riesgo y el análisis del impacto de estrategias educativas y programas de intervención orientados al bienestar digital.

También valdría la pena tomar en cuenta nuevas variables al momento de analizar, como el contexto familiar, el ambiente en la escuela, el desempeño académico, e incluso aspectos



relacionados con la salud mental y el bienestar emocional de los estudiantes. Incluir estas dimensiones permitiría armar modelos de análisis más completos, que realmente reflejen la complejidad de su día a día.

Además, en futuras investigaciones se podría trabajar en el diseño, validación e implementación de sistemas tecnológicos de alerta temprana, tomando como base los modelos ya propuestos. Este tipo de herramientas ayudaría a que las instituciones educativas puedan dar un seguimiento más ético, preventivo y no invasivo al comportamiento digital de sus estudiantes.

Por último, es importante ahondar en el análisis ético, legal y normativo del uso de la inteligencia artificial y el aprendizaje automático dentro del ámbito educativo. Este análisis tendría que considerar temas clave como la privacidad y protección de datos personales, la transparencia y comprensión de los algoritmos, el consentimiento informado y el nivel de aceptación que estas tecnologías tienen entre quienes forman parte de la comunidad educativa.



REFERENCIAS BIBLIOGRÁFICAS

Abdel Wahed, S., & Wahed, M. A. (2025). AI-Driven Digital Well-being: Developing Machine Learning Model to Predict and Mitigate Internet Addiction. *LatIA*, (3), 73.

Adorjan, M., & Ricciardelli, R. (2021). Smartphone and social media addiction: Exploring the perceptions and experiences of Canadian teenagers. *Canadian Review of Sociology/Revue Canadienne de Sociologie*, 58(1), 45–64. <https://doi.org/10.1111/cars.12319>

Aguilar, M. V. (2024). Adicción a las redes sociales en estudiantes de secundaria. *Journal of Neuroscience and Public Health*, 4(4), 15–27. <https://doi.org/10.46363/jnph.v4i4.2>

Alarcón Allain, G. F. (2021). Adicción a redes sociales e inteligencia emocional en estudiantes de educación superior técnica. *Universidad Peruana de Ciencias Aplicadas (UPC)*. <https://repositorioacademico.upc.edu.pe/handle/10757/656105>

Alenezi, H. S., & Faisal, M. H. (2020). Utilizing crowdsourcing and machine learning in education: Literature review. *Education and Information Technologies*, 25(4), 2971–2986. <https://doi.org/10.1007/s10639-020-10102-w>

Aliaga Paredes, G. (2023). *Adicción a redes sociales y autoestima en adolescentes de nivel secundario de la Institución Educativa de Bryce- Huancayo 2023*.

Al-Samarraie, H., Bello, K.-A., Alzahrani, A. I., Smith, A. P., & Emele, C. (2021). Young users' social media addiction: Causes, consequences and preventions. *Information Technology & People*, 35(7), 2314–2343. (world). <https://doi.org/10.1108/ITP-11-2020-0753>

Arias, N. del R. M., & Fernández, A. L. (2025). ADICCIÓN A REDES SOCIALES Y VICTIMIZACIÓN ENTRE ADOLESCENTES. *PSICOLOGÍA UNEMI*, 9(17), 10–20. <https://doi.org/10.29076/issn.2602-8379vol9iss017.2025pp10-20p>

Arrivillaga, C., Griffiths, M. D., Rey, L., & Extremera, N. (2024). Validation of the Spanish version of the Bergen Social Media Addiction Scale (BSMAS) among Spanish adolescents. *Current Psychology*, 43(40), 31582–31591. <https://doi.org/10.1007/s12144-024-06728-5>

Aznar-Martínez, B., Casarramona Basany, A., Grané-Morcillo, J., Lorente-De-Sanz, J., Prats Fernández, M. A., & Ballester Brage, L. (2024). *Uso responsable de Internet y seguridad digital: Revisión sistemática de programas educativos Responsible Internet use and digital safety: systematic review on educational programs*. <https://doi.org/10.15581/004.47.006>



Aznar-Martínez, Berta, Casarramona-Basany, A., Grané-Morcillo, J., Lorente-De-Sanz, J., Prats-Fernández, M.-À., & Ballester-Brage, L. (2024). Uso responsable de Internet y seguridad digital: Revisión sistemática de programas educativos. *Estudios sobre Educación*, 47, 125–152. <https://doi.org/10.15581/004.47.006>

Bautista-Quispe, J. A., Velazco Reyes, B., Estrada Araoz, E. G., Córdova-Rojas, L. M., Ascona García, P. P., Bautista-Quispe, J. A., Velazco Reyes, B., Estrada Araoz, E. G., Córdova-Rojas, L. M., & Ascona García, P. P. (2023). Adicción a las redes sociales y procrastinación académica en adolescentes de educación básica regular. *Revista Universidad y Sociedad*, 15(3), 509–517.

Bedoya Denegri, C. (2021). *Adicción a las redes sociales y autoestima en adolescentes*. <https://repositorio.ulima.edu.pe/handle/20.500.12724/13803>

Beneth-Benavides, J. A., & Paz-Saavedra, L. E. (2025). Uso y adicción a redes sociales virtuales por parte de estudiantes de educación secundaria. *Education in the Knowledge Society (EKS)*, 26, e30027–e30027. <https://doi.org/10.14201/eks.30027>

Best, S. (2024). Adolescencia, salud y bienestar digital. Aportes del cuestionario de ciberagresión. *Subjetividad y Procesos Cognitivos*, 28(1), 165-188 (2024). <https://dspace.uces.edu.ar/jspui/handle/123456789/6956>

Bilgin, M., Şahin, İ., & Togay, A. (2020). Social Media Addiction in Adolescents and Parent-Adolescent Relationship. *Education and Science*, 45(202), 263–281. <https://doi.org/10.15390/EB.2020.8202>

Blanco, N., & Pirela, J. (2022). La complementariedad metodológica: Estrategia de integración de enfoques en la investigación social. *Espacios Públicos*, 18(45). <https://espaciospublicos.uaemex.mx/article/view/19296>

Boer, M., van den Eijnden, R. J. J. M., Boniel-Nissim, M., Wong, S.-L., Inchley, J. C., Badura, P., Craig, W. M., Gobina, I., Kleszczewska, D., Klanšček, H. J., & Stevens, G. W. J. M. (2020). Adolescents' Intense and Problematic Social Media Use and Their Well-Being in 29 Countries. *Journal of Adolescent Health, Understanding Adolescent Health and Wellbeing in Context: Cross-National Findings from the Health Behaviour in School-Aged Children Study*, 66(6, Supplement), S89–S99. <https://doi.org/10.1016/j.jadohealth.2020.02.014>

Bois, R. D., & Jesus, D. (2025). *Relación entre fomo y uso problemático de redes sociales en adolescentes y población general adulta*. <https://repositorio.ulima.edu.pe/handle/20.500.12724/22772>



Bozzola, E., Spina, G., Agostiniani, R., Barni, S., Russo, R., Scarpato, E., Di Mauro, A., Di Stefano, A. V., Caruso, C., Corsello, G., & Staiano, A. (2022). The Use of Social Media in Children and Adolescents: Scoping Review on the Potential Risks. *International Journal of Environmental Research and Public Health*, 19(16), Article 16.

<https://doi.org/10.3390/ijerph19169960>

Brand, V. A. G., & García, L. E. G. (2023). Adicción o uso problemático de las redes sociales online en la población adolescente. Una revisión sistemática. *Psicoespacios*, 17(31), Article 31. <https://doi.org/10.25057/21452776.1511>

Cabero Almenara, J., Martínez, S., Valencia Ortiz, R., Leiva Núñez, P. J., Orellana Hernández, M. L., & Harvey López, I. (2020). La adicción de los estudiantes a las redes sociales on-line: Un estudio en el contexto latinoamericano. *Articles publicats en revistes (Didàctica i Organització Educativa)*. <https://diposit.ub.edu/dspace/handle/2445/178270>

Cabero-Almenara, J., Pérez-Díez de los Ríos, J. L., Valencia-Ortiz, R., Cabero-Almenara, J., Pérez-Díez de los Ríos, J. L., & Valencia-Ortiz, R. (2020). Escala para medir la adicción de estudiantes a las redes sociales. *Convergencia*, 27.

<https://doi.org/10.29101/crcs.v27i83.11834>

Caner, N., Efe, Y. S., & Başdaş, Ö. (2022a). The contribution of social media addiction to adolescent LIFE: Social appearance anxiety. *Current Psychology*, 41(12), 8424–8433.

<https://doi.org/10.1007/s12144-022-03280-y>

Cardenas Beraun, M. (2020). *Uso problemático de las redes sociales y cansancio emocional en estudiantes de secundaria de un colegio de Lima Metropolitana*.

<https://repositorio.usil.edu.pe/entities/publication/23597bbf-a074-44b9-a0bf-e7d0839470c6>

Castro Gutierrez, J. (2022). Adicción a redes sociales en adolescentes de nivel secundaria de una institución educativa particular de Huancayo—2022. *Universidad Peruana Los Andes*. <http://repositorio.upla.edu.pe/handle/20.500.12848/4804>

Ccorahua Estrada, S. M. (2023). Adicción a redes sociales y bienestar psicológico en estudiantes de secundaria de dos instituciones educativas de San Juan de Miraflores, 2021.

AUTONOMA. <http://repositorio.autonoma.edu.pe/handle/20.500.13067/2436>

Cebollero Salinas, A., Cano Escoriaza, J., & Orejudo Hernández, S. (2021). Abuso de Internet y adolescentes: Gratificaciones, supervisión familiar y uso responsable. Implicaciones educativas y familiares. *Digital Education Review*, 42–59.

<https://doi.org/10.1344/DER.2021.39.42-59>



Cedeno-Moreno, D., & Vargas, M. (2020). Aprendizaje automático aplicado al análisis de sentimientos. *I+D Tecnológico*, 16(2), 59–66. <https://doi.org/10.33412/idt.v16.2.2833>

Chang, W., Ji, X., Liu, Y., Xiao, Y., Chen, B., Liu, H., Zhou, S., Chang, W., Ji, X., Liu, Y., Xiao, Y., Chen, B., Liu, H., & Zhou, S. (2020). Analysis of University Students' Behavior Based on a Fusion K-Means Clustering Algorithm. *Applied Sciences*, 10(18). <https://doi.org/10.3390/app10186566>

Chapilliquen Lopez, K. L. (2023). *Adicción a las redes sociales y autoestima en adolescentes de instituciones educativas del distrito de La Unión, 2023*.

Copez-Lonzoy, A., Vallejos-Flores, M., Capa-Luque, W., Salas-Blas, E., Montero Doig, A. M., Dias, P. C., & Bazo-Alvarez, J. C. (2023). Adaptation of the Bergen Social Media Addiction Scale (BSMAS) in Spanish. *Acta Psychologica*, 241, 104072. <https://doi.org/10.1016/j.actpsy.2023.104072>

Cortez Castro, J. L. (2021). *Estrategias metodológicas de aprendizaje en la formación profesional de los estudiantes de la escuela profesional de educación física y psicomotricidad de la Universidad Nacional del Centro del Perú*. <http://repositorio.uncp.edu.pe/handle/20.500.12894/7734>

Cuervo Sánchez, S. L., Etxague Goia, I., & Foronda Rojo, A. (2022). *Uso responsable y crítico de internet de los dispositivos digitales*. Servicio Editorial de la Universidad del País Vasco/Euskal Herriko Unibertsitatearen Argitalpen Zerbitzua. <https://doi.org/10/58709>

Dabhade, P., Agarwal, R., Alameen, K. P., Fathima, A. T., Sridharan, R., & Gopakumar, G. (2021). Educational data mining for predicting students' academic performance using machine learning algorithms. *Materials Today: Proceedings, International Conference on Sustainable Materials, Manufacturing and Renewable Technologies 2021*, 47, 5260–5267. <https://doi.org/10.1016/j.matpr.2021.05.646>

Dhanalakshmi, R., Sanjana, R. R., Reddy, Y. T. K., Samad, S. A., & Tharun, P. (2025). Breaking the Digital Grip: AI Models for Evaluating the Internet and Mobile Addiction Across All Age Groups. *2025 6th International Conference on Inventive Research in Computing Applications (ICIRCA)*, 1253–1259. <https://doi.org/10.1109/ICIRCA65293.2025.11089701>

Díaz Landa, B., Meleán Romero, R. A., & Marín Rodríguez, W. J. (2021). Rendimiento académico de estudiantes en Educación Superior: Predicciones de factores influyentes a partir de árboles de decisión. *Telos: Revista de Estudios Interdisciplinarios en Ciencias Sociales*, 23(3 (septiembre-diciembre)), 616–639.

- Díaz-Ramírez, J. (2021). Aprendizaje Automático y Aprendizaje Profundo. *Ingeniare. Revista Chilena de Ingeniería*, 29(2), 180–181. <https://doi.org/10.4067/S0718-33052021000200180>
- Elbasi, E., Nadeem, M., Alzoubi, Y. I., Topcu, A. E., & Varghese, G. (2025). Machine Learning in Education: Innovations, Impacts, and Ethical Considerations. *IEEE Access*, 13, 128741–128770. <https://doi.org/10.1109/ACCESS.2025.3590134>
- Estrada Araoz, E. G., Gallegos Ramos, N. A., Estrada Araoz, E. G., & Gallegos Ramos, N. A. (2020). Funcionamiento familiar y adicción a redes sociales en estudiantes de educación secundaria de Puerto Maldonado. *Revista San Gregorio*, (40), 101–117. <https://doi.org/10.36097/rsan.v1i40.1393>
- Farhat, R., Mourali, Y., Jemni, M., & Ezzedine, H. (2020). An overview of Machine Learning Technologies and their use in E-learning. *2020 International Multi-Conference on: "Organization of Knowledge and Advanced Technologies" (OCTA)*, 1–4. <https://doi.org/10.1109/OCTA49274.2020.9151758>
- Flores López, J. C. (/). Aplicación de Machine Learning sin supervisión. *Revista Varianza*, 20.
- Fuentes, A. R., Hoz, A. B. B. de la, Cara, M. J. C., & Montes, C. del P. G. (2024). Estudio de la competencia digital en alumnado de secundaria colombiano. *Aula Abierta*, 53(2), 119–128. <https://doi.org/10.17811/rifie.20312>
- Goh, E.-K., Jeon, H.-J., Park, H., & Ok, S. (2023). Predicting Mental Health Risk based on Adolescent Health Behavior: Application of a Hybrid Machine Learning Method. *Journal of the Korean Society of School Health*, 36(3), 113–125. <https://doi.org/10.15434/kssh.2023.36.3.113>
- González Alcántara, K. E., Corominas Tortolero, R., & Silva, C. (2021). Valoración psicométrica del Cuestionario de Adicción a Redes Sociales (ARS) en adolescentes mexicanos. *Revista de Psicología Clínica con Niños y Adolescentes*, 8(3), 26–34.
- Gülü, M., Yagin, F. H., Gocer, I., Yapici, H., Ayyildiz, E., Clemente, F. M., Ardigo, L. P., Zadeh, A. K., Prieto-González, P., & Nobari, H. (2023). Exploring obesity, physical activity, and digital game addiction levels among adolescents: A study on machine learning-based prediction of digital game addiction. *Frontiers in Psychology*, 14. <https://doi.org/10.3389/fpsyg.2023.1097145>

Hariyanto, Kristianingsih, F. X. D., & Maharani, R. (2025). Artificial intelligence in adaptive education: A systematic review of techniques for personalized learning. *Discover Education*, 4(1), 458. <https://doi.org/10.1007/s44217-025-00908-6>

Haro Sarango, A., Chisag Pallmay, E. R., Ruiz Sarzosa, J. P., & Caicedo Pozo, J. E. (2024). Tipos y clasificación de las investigaciones. *Latam: revista latinoamericana de Ciencias Sociales y Humanidades*, 5(2), 39.

Hasan, F., Rahman, S. M., Rahman, Md. S., & Khatun, R. (2025). Analyzing Game Addiction in Bangladesh Through Machine Learning Techniques. *2025 International Conference on Quantum Photonics, Artificial Intelligence, and Networking (QPAIN)*, 1–6. <https://doi.org/10.1109/QPAIN66474.2025.11171979>

Hoodbhoy, Z., Masroor Jeelani, S., Aziz, A., Habib, M. I., Iqbal, B., Akmal, W., Siddiqui, K., Hasan, B., Leeflang, M., & Das, J. K. (2021). Machine Learning for Child and Adolescent Health: A Systematic Review. *Pediatrics*, 147(1), e2020011833. <https://doi.org/10.1542/peds.2020-011833>

Huang, C. (2022). A meta-analysis of the problematic social media use and mental health. *International Journal of Social Psychiatry*, 68(1), 12–33. <https://doi.org/10.1177/0020764020978434>

Javier López-Fernández, F., Mezquita, L., Vidal-Arenas, V., Monfil-Carratalá, A., Ortet, G., & Ignacio Ibáñez, M. (2025). Adicción a redes sociales, personalidad, psicopatología y género: Hallazgos transversales y longitudinales en adolescentes. *Adicciones*, 37(3), 269.

Johar, G., & Patel, R. (2024). A Machine Learning Model for Predicting Internet Addiction in Teenage and Young Students. *2024 IEEE 3rd World Conference on Applied Intelligence and Computing (AIC)*, 285–291. <https://doi.org/10.1109/AIC61668.2024.10731088>

Keles, B., McCrae, N., & Grealish, A. (2020). A systematic review: The influence of social media on depression, anxiety and psychological distress in adolescents. *International Journal of Adolescence and Youth*, 25(1), 79–93. <https://doi.org/10.1080/02673843.2019.1590851>

Kennedy, R. K. L., Salekshahrezaee, Z., Villanustre, F., & Khoshgoftaar, T. M. (2023). Iterative cleaning and learning of big highly-imbalanced fraud data using unsupervised learning. *Journal of Big Data*, 10(1), 106. <https://doi.org/10.1186/s40537-023-00750-3>

Khine, M. S. (2024). Machine Learning in Education. In M. S. Khine (Ed.), *Artificial Intelligence in Education: A Machine-Generated Literature Overview* (pp. 571–627). Springer Nature. https://doi.org/10.1007/978-981-97-9350-1_5



Kouvchinove Voronine, M. (2024). *Análisis y aplicación de técnicas de Machine Learning: Un enfoque comparativo y práctico*.

<https://repositorio.unican.es/xmlui/handle/10902/34870>

Laveriano Varas, K. (2023). Adicción a redes sociales y agresividad en adolescentes de secundaria de Lima Sur. *AUTONOMA*.

<http://repositorio.autonoma.edu.pe/handle/20.500.13067/2780>

Li, X., Zhang, Y., Cheng, H., Zhou, F., & Yin, B. (2021). An Unsupervised Ensemble Clustering Approach for the Analysis of Student Behavioral Patterns. *IEEE Access*, 9, 7076–7091. <https://doi.org/10.1109/ACCESS.2021.3049157>

Lorenzo Rumbo, A., Giménez Miralles, M., & Martín Galán, M. (2025). Impacto de la adicción a redes sociales en asistencia y rendimiento académico: Diferencias según género en estudiantes de Educación Secundaria. *epsir: European Public & Social Innovation Review*, (10), 272.

Lorenzo-Rumbo, A., Giménez-Miralles, M., & Martín-Galán, M. (2025). Impacto de la adicción a redes sociales en asistencia y rendimiento académico: Diferencias según género en estudiantes de Educación Secundaria. *European Public & Social Innovation Review*, 10, 1–14. <https://doi.org/10.31637/epsir-2025-959>

Lovón, M., Parini, A., Lovón, M., & Parini, A. (2024). Inteligencia artificial, discurso digital y lenguaje: La lingüística en la era de las nuevas tecnologías. *Lengua y Sociedad*, 23(2), 577–598. <https://doi.org/10.15381/lengsoc.v23i2.29773>

Luo, T., Qin, L., Cheng, L., Wang, S., Zhu, Z., Xu, J., Chen, H., Liu, Q., Hu, M., Tong, J., Hao, W., Wei, B., & Liao, Y. (2021). *Determination the cut-off point for the Bergen social media addiction (BSMAS): Diagnostic contribution of the six criteria of the components model of addiction for social media disorder*. <https://doi.org/10.1556/2006.2021.00025>

Mamani Añamuro, K. (2024). *Redes sociales y calidad de sueño en estudiantes de secundaria de dos instituciones educativas nacionales de Arequipa*.

<https://hdl.handle.net/20.500.12920/14643>

Manzanares, M. C. S., Hernanz, R. J. P., Yáñez, M. J. Z., López, G. A., Sánchez, R. M., Rodríguez, A. C., Martín, C., & Arribas, S. R. (2021). Eye-tracking Technology and Data-mining Techniques used for a Behavioral Analysis of Adults engaged in Learning Processes. *Journal of Visualized Experiments (JoVE)*, (172), e62103. <https://doi.org/10.3791/62103>

Marengo, D., Angelo Fabris, M., Longobardi, C., & Settanni, M. (2022). Smartphone and social media use contributed to individual tendencies towards social media addiction in



Italian adolescents during the COVID-19 pandemic. *Addictive Behaviors*, 126, 107204.
<https://doi.org/10.1016/j.addbeh.2021.107204>

Marino, C., Gini, G., Angelini, F., Vieno, A., & Spada, M. M. (2020). Social norms and e-motions in problematic social media use among adolescents. *Addictive Behaviors Reports*, 11, 100250. <https://doi.org/10.1016/j.abrep.2020.100250>

Mayaute, M. E., & Blas, E. S. (2014). Construcción Y Validación Del Cuestionario De Adicción a Redes Sociales (ars). *Liberabit. Revista Peruana de Psicología*, 20(1), 73–91.

Mena, A. J., De Oliveira Cardoso, N., Xavier, C. E., & Argimon, I. I. de L. (2022). Técnicas de Machine Learning utilizadas en estudios psicológicos con adolescentes: Una revisión sistemática. *EduPsykhé: Revista de psicología y educación*, 19(2), 23–38.

Meyerhofer-Parra, R., & González-Martínez, J. (2024a). Percepciones docentes sobre las competencias digitales y su uso para el bienestar digital: Un análisis mixto sobre la ampliación del marco DigCompEdu. *EduTec, Revista Electrónica de Tecnología Educativa*, (87), 115–133. <https://doi.org/10.21556/edutec.2024.87.2967>

Meyerhofer-Parra, R., & González-Martínez, J. (2024b). Percepciones docentes sobre las competencias digitales y su uso para el bienestar digital: Un análisis mixto sobre la ampliación del marco DigCompEdu. *EduTec, Revista Electrónica de Tecnología Educativa*, (87), 115–133. <https://doi.org/10.21556/edutec.2024.87.2967>

Monreal-Pitones, L. E. (2022). Aplicación de modelos predictivos y correlaciones. *XIKUA Boletín Científico de la Escuela Superior de Tlahuelilpan*, 10(20), Article 20. <https://doi.org/10.29057/xikua.v10i20.9073>

Noorulfakhri, Y., Mohd, Zulkarnain, S. I., Syed, Ashiqin, W. A., Wan Nor, Jaafar, B. W. Y., Wan Ahmad, & Christophe, R. (2025). *AI, Human Communication, and the Challenges of Digital Addiction*. IGI Global.

Olivella-Cirici, M., Garcia-Continente, X., Bartoli Checa, M., Serral Cano, G., & Pérez Albarracín, G. (2025). El uso problemático del teléfono móvil: Análisis transversal del perfil individual y factores asociados. *Revista Española de Salud Pública*, 97, e202305036.

Ordoñez-Pacheco, Á. F. (2025). Metodología de la Investigación Metodología académica con aplicación a las investigaciones sociales: Enfoques, tipos, métodos y diseños. *Sociedad & Tecnología*, 8(2), 335–357. <https://doi.org/10.51247/st.v8i2.484>

Osorio, A., & Enerieth, N. (2020). *El derecho de autor en la Inteligencia Artificial de machine learning (Copyright Law in the Artificial Intelligence of Machine Learning)* (SSRN



Scholarly Paper No. 3790753). Social Science Research Network.

<https://papers.ssrn.com/abstract=3790753>

Özyírmídokuz, E. K., Asim Çelik, B., & Alexandru Stoica, E. (2025a).

#GAMEADDICTED: A Machine Learning Framework for Digital Game Addiction Detection and Early Intervention. *IEEE Access*, 13, 135757–135775.

<https://doi.org/10.1109/ACCESS.2025.3587622>

Özyírmídokuz, E. K., Asim Çelik, B., & Alexandru Stoica, E. (2025b).

#GAMEADDICTED: A Machine Learning Framework for Digital Game Addiction Detection and Early Intervention. *IEEE Access*, 13, 135757–135775.

<https://doi.org/10.1109/ACCESS.2025.3587622>

Palacios Sáez-Guinea, L., & López Ruiz, R. (with Universidad de Zaragoza). (2022).

Aprendizaje automático y reglas de asociación. Universidad de Zaragoza.

Pansri, B., Sharma, S., Timilsina, S., Choonhapong, W., Kurashige, K., Watanabe, S., & Sato, K. (2024). Understanding Student Learning Behavior: Integrating the Self-Regulated Learning Approach and K-Means Clustering. *Education Sciences*, 14(12), 1291.

<https://doi.org/10.3390/educsci14121291>

Pascual-Triana, J. D. (2024). *Estudio de los aspectos éticos en Inteligencia Artificial y Machine Learning: “Data Fairness”, interpretabilidad y explicabilidad en los modelos de aprendizaje* [Doctoral thesis, Universidad de Granada].

<https://digibug.ugr.es/handle/10481/94995>

Pastor, Y., García-Jiménez, A., & López-de-Ayala, M.-C. (2022). Estrategias de regulación de uso del smartphone y uso problemático de internet en la adolescencia. *Anales de Psicología / Annals of Psychology*, 38(2), Article 2. (Quarterly).

<https://doi.org/10.6018/analesps.461771>

Pech, R. O., Saenz, R. A. C., & Uc-May, W. M. (2021). El programa gubernamental Bienestar Digital y su efecto en estudiantes del nivel medio superior de la Zona Metropolitana de Mérida, México. *Paradigma Económico*, 13(1), 91–117.

<https://doi.org/10.36677/paradigmaeconomico.v13i1.15282>

Pecuchova, J., & Drlik, M. (2024). Enhancing the Early Student Dropout Prediction Model Through Clustering Analysis of Students’ Digital Traces. *IEEE Access*, 12, 159336–159367. <https://doi.org/10.1109/ACCESS.2024.3486762>

Perdomo, L., & Ordinez, L. (2024). *Revisión de metodologías de ciencias de datos para proyectos de planificación territorial*. XXVI Workshop de Investigadores en Ciencias de la



Computación (WICC) (Puerto Madryn, 18 y 19 de abril de 2024).

<http://sedici.unlp.edu.ar/handle/10915/176264>

Pérez González, G. A. (2021). *Detección de transacciones fraudulentas en tarjetas de crédito mediante el uso de modelos de Machine Learning*. <https://hdl.handle.net/1992/53571>

Pilamunga, B. O. C., López, M. B. C., Monar, K. R. G., & Sarango, A. F. H. (2024). Chi Cuadrado y tablas de contingencia aplicado en SPSS. *Código Científico Revista de Investigación*, 5(E3), 499–513. <https://doi.org/10.55813/gaea/ccri/v5/nE3/329>

Quintana, A. L. Y. (2023). Salud mental de adolescentes: Adicción a redes sociales. *Journal of Neuroscience and Public Health*, 3(3), 409–417. <https://doi.org/10.46363/jnph.v3i3.2>

Ramírez Acosta, A. M. (2022). *Adicción a las redes sociales y su relación con la adaptación interpersonal en los adolescentes*. <https://repositorio.puce.edu.ec/handle/123456789/7535>

Razaulla, S. M., Pasha, M., & Farooq, M. U. (2022). Integration of Machine Learning in Education: Challenges, Issues and Trends. In Ch. Satyanarayana, X.-Z. Gao, C.-Y. Ting, & N. B. Muppalaneni (Eds.), *Machine Learning and Internet of Things for Societal Issues* (pp. 23–34). Springer Nature. https://doi.org/10.1007/978-981-16-5090-1_2

Reina-Parrado, M., Román-Graván, P., & Hervás-Gómez, C. (2025). Integration of Artificial Intelligence and Machine Learning in Education: A Systematic Review. *International Journal of Educational Methodology*, 11(2), 203–216. <https://doi.org/10.12973/ijem.11.2.203>

Rodríguez Gómez, D. (2023). *Análisis de datos y Machine Learning*. <https://gredos.usal.es/handle/10366/157350>

Romero-Méndez, C. A., & Romero-Méndez, D. L. (2024). Procrastinación académica, adicción a redes sociales y funciones ejecutivas: Un estudio de autorreporte en adolescentes. *Revista Panamericana de Pedagogía*, (38), 110–127. <https://doi.org/10.21555/rpp.vi38.3126>

Rufino Vargas, R. N. (2021). *Adicción a las redes sociales y autoestima en estudiantes de secundaria de la Institución Matemática San Rafael*. Carabayllo—Lima 2021.

Ruiz Pimiento, T. Z., Sanabria Álvarez, L. D., & Ceballos Ortiz, Y. Y. (2021). *Análisis del índice de correlación entre inteligencia emocional y uso problemático de redes sociales en una muestra de adolescentes del Colegio Madre del Buen Consejo en el municipio de Floridablanca*. <https://repository.unab.edu.co/handle/20.500.12749/15371>

Salas Blas, E. S. (2024). *Adicción a las redes sociales y habilidades sociales en estudiantes de secundaria*.



Santabábara, J. (2021). Cálculo del tamaño de muestra necesario para estimar el coeficiente de correlación de Pearson mediante sintaxis en SPSS. *REIRE Revista d'Innovació i Recerca en Educació*, 14(1), 1–7. <https://doi.org/10.1344/reire2021.14.132565>

Sarman, A., & Tuncay, S. (2023). The relationship of Facebook, Instagram, Twitter, TikTok and WhatsApp/Telegram with loneliness and anger of adolescents living in Turkey: A structural equality model. *Journal of Pediatric Nursing*, 72, 16–25. <https://doi.org/10.1016/j.pedn.2023.03.017>

Segura Delgado, A. (2021). *Estudio y Diseño de Técnicas para la Extracción de Reglas de Asociación Temporales* [Doctoral thesis, Universidad de Granada]. <https://digibug.ugr.es/handle/10481/69644>

Shameti, K., & Cico, B. (2025). Comparison of Methodological Approaches: CRISP-DM vs OSEMN Methodology Using Linear Regression and Statistical Analysis. In C. Bădică, M. Gušev, A. Iftene, M. Ivanović, Y. Manolopoulos, & S. Xinogalos (Eds.), *Advances in ICT Research in the Balkans* (pp. 47–60). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-84093-7_4

Shannon, H., Bush, K., Villeneuve, P. J., Hellemans, K. G., & Guimond, S. (2022). Problematic Social Media Use in Adolescents and Young Adults: Systematic Review and Meta-analysis. *JMIR Mental Health*, 9(4), e33450. <https://doi.org/10.2196/33450>

Soria, P., & Villegas-Villacres, N. de J. (2024). ADICCIÓN A LAS REDES SOCIALES Y SU RELACIÓN CON LA AUTOESTIMA EN ADOLESCENTES. *PSICOLOGÍA UNEMI*, 8(14), Article 14. <https://doi.org/10.29076/issn.2602-8379vol8iss14.2024pp19-29p>

Sümen, A., & Evgin, D. (2021a). Social Media Addiction in High School Students: A Cross-Sectional Study Examining Its Relationship with Sleep Quality and Psychological Problems. *Child Indicators Research*, 14(6), 2265–2283. <https://doi.org/10.1007/s12187-021-09838-9>

Sümen, A., & Evgin, D. (2021b). Social Media Addiction in High School Students: A Cross-Sectional Study Examining Its Relationship with Sleep Quality and Psychological Problems. *Child Indicators Research*, 14(6), 2265–2283. <https://doi.org/10.1007/s12187-021-09838-9>

Tapia, S. P. T., Pacheco, D. G. T., & Espinoza, M. D. M. (2025). Detección de Contenido Adictivo en la plataforma TikTok usando algoritmos de aprendizaje supervisado. *GEEKS DECC-REPORTS*, 8(2), Article 2. <https://doi.org/10.24133/428vw925>

Taş, İ. (2023a). The Relationship Between Social Ignore and Social Media Addiction Among Adolescents: Mediator Effect of Satisfaction With Family Life. *Youth & Society*, 55(4), 708–729. <https://doi.org/10.1177/0044118X211055210>

Taş, İ. (2023b). The Relationship Between Social Ignore and Social Media Addiction Among Adolescents: Mediator Effect of Satisfaction With Family Life. *Youth & Society*, 55(4), 708–729. <https://doi.org/10.1177/0044118X211055210>

Timarán Pereira, R. (2008). Algoritmos de reglas de asociación con generación de itemsets candidatos. *Ingeniería Solidaria*, 4(6), 49–56.

Torres, J. I. S., & Cardenas, E. G. (2021). Análisis y aplicación de algoritmos de minería de datos. *Perspectivas*, 6(21), 71–88. <https://doi.org/10.26620/uniminuto.perspectivas.6.21.2021.71-88>

Valencia-Ortiz, R., Garay-Ruiz, U., Cabero-Almenara, J., Valencia-Ortiz, R., Garay-Ruiz, U., & Cabero-Almenara, J. (2023). Uso problemático de las redes sociales: El caso de estudiantes mexicanos. *ALTERIDAD.Revista de Educación*, 18(1), 23–33. <https://doi.org/10.17163/alt.v18n1.2023.02>

Valero Cajahuanca, J. E., Navarro Raymundo, Á. F., Larios Franco, A. C., & Julca Flores, J. D. (2022). Deserción universitaria: Evaluación de diferentes algoritmos de Machine Learning para su predicción. *Revista de ciencias sociales*, 28(3), 362–375.

Valles-Coral, M. A., Salazar-Ramírez, L., Injante, R., Hernandez-Torres, E. A., Juárez-Díaz, J., Navarro-Cabrera, J. R., Pinedo, L., Vidaurre-Rojas, P., Valles-Coral, M. A., Salazar-Ramírez, L., Injante, R., Hernandez-Torres, E. A., Juárez-Díaz, J., Navarro-Cabrera, J. R., Pinedo, L., & Vidaurre-Rojas, P. (2022). Density-Based Unsupervised Learning Algorithm to Categorize College Students into Dropout Risk Levels. *Data*, 7(11). <https://doi.org/10.3390/data7110165>

Veloza Gamba, R. (2023). Desarrollo de la inteligencia emocional en el contexto de las competencias digitales en el uso de las redes sociales en los sistemas educativos latinoamericanos: Una revisión documental : Development of emotional intelligence in the context of digital competences in the use of social networks in Latin American educational systems: a documentary review. *Latam: revista latinoamericana de Ciencias Sociales y Humanidades*, 4(1), 233.

Veluri, R. K., Patra, I., Naved, M., Prasad, V. V., Arcinas, M. M., Beram, S. M., & Raghuvanshi, A. (2022). Learning analytics using deep learning techniques for efficiently



managing educational institutes. *Materials Today: Proceedings, International Conference on Advances in Materials Science*, 51, 2317–2320. <https://doi.org/10.1016/j.matpr.2021.11.416>

Ventre, L. O., Micolini, O., Ludemann, M., Carranza, A., D'Andrea, D., & Candotti, E. (2024). *Caso de estudio: Metodología para el diseño y desarrollo de sistemas embebidos distribuidos*. XXIX Congreso Argentino de Ciencias de la Computación (CACIC) (Luján, 9 al 12 de octubre de 2023). <http://sedici.unlp.edu.ar/handle/10915/164820>

Vera Machuca, C. A. (2025). *Análisis Predictivo De La Deserción Estudiantil De La Universidad Técnica De Cotopaxi, Utilizando Técnicas De Machine Learning Mediante Aprendizaje Supervisado, Para La Toma De Decisiones Oportunas* [Ecuador: Latacunga: Universidad Técnica de Cotopaxi (UTC)]. <https://repositorio.utc.edu.ec/handle/123456789/14634>

Wang, X., & Guo, Y. (2025). Do social motivations predict addiction to social media in young people? The role of flow and algorithm awareness. *Anales de Psicología / Annals of Psychology*, 41(1), Article 1. (Quarterly). <https://doi.org/10.6018/analesps.610811>

Whelan, E., Islam, A. K. M. N., & Brooks, S. (2020). Applying the SOBC paradigm to explain how social media overload affects academic performance. *Computers & Education*, 143, 103692. <https://doi.org/10.1016/j.compedu.2019.103692>

Wong, H. Y., Mo, H. Y., Potenza, M. N., Chan, M. N. M., Lau, W. M., Chui, T. K., Pakpour, A. H., & Lin, C.-Y. (2020). Relationships between Severity of Internet Gaming Disorder, Severity of Problematic Social Media Use, Sleep Quality and Psychological Distress. *International Journal of Environmental Research and Public Health*, 17(6), Article 6. <https://doi.org/10.3390/ijerph17061879>

Wu, J. (2020). Machine Learning in Education. *2020 International Conference on Modern Education and Information Management (ICMEIM)*, 56–63. <https://doi.org/10.1109/ICMEIM51375.2020.00020>

Yanto, R. N. D., & Wedhayanti, R. (2025). Correlation between the intensity of smartphone use and stress levels among students of smkn 1 penajam passer utara. *Jurnal EMPATI*, 14(6), 531–537. <https://doi.org/10.14710/empati.2025.54114>

Zheng, L., Wang, C., Chen, X., Song, Y., Meng, Z., & Zhang, R. (2023). Evolutionary machine learning builds smart education big data platform: Data-driven higher education. *Applied Soft Computing*, 136, 110114. <https://doi.org/10.1016/j.asoc.2023.110114>



ANEXOS

Anexo A

Link de la encuesta aplicada a los estudiantes de secundaria

El presente anexo contiene el instrumento de recolección de datos aplicado a los estudiantes de nivel secundario, basado en la Escala de Adicción a Redes Sociales de Bergen (BSMAS). Dicho instrumento permitió recopilar información relacionada con el uso de redes sociales y variables psicosociales relevantes para la investigación.

<https://docs.google.com/forms/d/15onKXuO09YUFTvoMTsq2NweSGB5vYGJL4s72bxDI4cA/edit#responses>

Anexo B

Base de datos utilizada en la investigación

Se presenta a través del siguiente link la base de datos utilizada para el análisis estadístico y el modelado mediante aprendizaje de máquina, garantizando el anonimato de la información y la confidencialidad de los participantes.

<https://docs.google.com/spreadsheets/d/1a7acMm5KEk0yeUAZMs4d-SW7EKnMwdIe2JjEIgGEfTE/edit?usp=sharing>



Anexo C

Reglas de asociación generadas

```
import pandas as pd
from sklearn.preprocessing import StandardScaler
from sklearn.decomposition import PCA
from sklearn.cluster import KMeans

# 1. Tomar la tabla original desde Power BI
df = dataset.copy()

# 2. Crear un ID para cada estudiante
df['ID'] = range(1, len(df) + 1)

# 3. Escoger columnas categóricas para convertirlas en numéricas
# Dejamos fuera Edad, Genero, ID y Horas_Redes (esta la queremos tal cual)
cols_categoria = [c for c in df.columns if c not in ['Edad', 'Genero', 'ID', 'Horas_Redes']]

# 4. Función para codificar texto -> números (1,2,3,...)
def codificar(serie):
    s = serie.astype(str).str.strip()
    cat = pd.Categorical(s)
    codigos = cat.codes
    codigos = pd.Series(codigos).replace(-1, pd.NA)
    return codigos + 1

# 5. Crear columnas *_num para cada variable categórica
for col in cols_categoria:
    df[col + '_num'] = codificar(df[col])

# 6. Seleccionar solo las columnas numéricas para el PCA
cols_numericas = [c for c in df.columns if c.endswith('_num')]

X = df[cols_numericas].dropna()
idx_validos = X.index

# 7. Guardar columnas descriptivas para esos mismos registros
ids = df.loc[idx_validos, 'ID']
edades = df.loc[idx_validos, 'Edad']
generos = df.loc[idx_validos, 'Genero']
horas_redes = df.loc[idx_validos, 'Horas_Redes']

# 8. Escalar datos
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X.values)

# 9. Aplicar PCA con 2 componentes
pca = PCA(n_components=2)
pcs = pca.fit_transform(X_scaled)

# 10. K-Means sobre los componentes principales
# Puedes cambiar n_clusters=3 por 2, 4, etc.
kmeans = KMeans(n_clusters=3, random_state=42, n_init=10)
clusters = kmeans.fit_predict(pcs)

# 11. Construir tabla final de CLUSTERS
clusters_df = pd.DataFrame({
    'ID': ids.values,
    'Edad': edades.values,
    'Genero': generos.values,
    'Horas_Redes': horas_redes.values,
    'PCA1': pcs[:, 0],
    'PCA2': pcs[:, 1],
    'Cluster': clusters.astype(str)
})

output = clusters_df
```