



*Asesorías y Tutorías para la Investigación Científica en la Educación Puig-Salabarría S.C.
José María Pino Suárez 400-2 esq a Lerdo de Tejada, Toluca, Estado de México. 7223898476*

RFC: ATI120618V12

Revista Dilemas Contemporáneos: Educación, Política y Valores.

<https://www.dilemascontemporaneoseduccionpoliticayvalores.com/>

Año: XII

Número: 3

Artículo no.: 5

Período: 1 de mayo al 31 de agosto del 2025

TÍTULO: Estudio del uso de tecnologías en estudiantes universitarios utilizando la técnica K-means.

AUTORES:

1. Máster. Wendy Guadalupe Azuara García.
2. Dra. Martha Patricia Silva Payró.
3. Dr. Guillermo De los Santos Torres.

RESUMEN: El presente trabajo tuvo como objetivo aplicar técnicas de minería de datos para identificar patrones de conducta relacionados al uso de tecnologías en estudiantes de pregrado a partir de datos previamente recolectados de una universidad pública del sureste mexicano. Este proyecto fue desarrollado con un enfoque cuantitativo para guiar las etapas del estudio, y se analizó el modelo de agrupación con el algoritmo K-means, empleando la herramienta Orange. De los resultados obtenidos se destacan tres agrupaciones realizadas por el algoritmo de acuerdo con la edad de los estudiantes. Con esto se concluye que existe un patrón general relacionado con factores pedagógicos en jóvenes de 20 a 25 años que interfiere en su proceso de apropiación de tecnologías.

PALABRAS CLAVES: base de datos, educación superior, tecnologías de la información.

TITLE: Study of the use of technologies in university students using the K-means technique.

AUTHORS:

1. Master. Wendy Guadalupe Azuara García.
2. PhD. Martha Patricia Silva Payró.
3. PhD. Guillermo De los Santos Torres.

ABSTRACT: The objective of this work was to apply data mining techniques to identify behavioral patterns related to the use of technologies in undergraduate students from data previously collected from a public university in southeastern Mexico. This project was developed with a quantitative approach to guide the stages of the study, and the clustering model was analyzed with the K-means algorithm, using the Orange tool. From the results obtained, three clusters made by the algorithm stand out according to the age of the students. With this, it is concluded that there is a general pattern related to pedagogical factors in young people from 20 to 25 years old that interferes in their process of appropriation of technologies.

KEY WORDS: databases, higher education, information technology.

INTRODUCCIÓN.

La falta de uso y apropiación de innovaciones tecnológicas en los estudiantes universitarios trae como consecuencia una disminución en el rendimiento académico de los alumnos, provocando en el peor de los escenarios la deserción. Es por esta razón que este fenómeno ha sido motivo de investigación desde que comenzaron las clases a distancia (Castro-Villagrán *et al.*, 2016).

La tecnología aún no está al alcance de toda la población, a pesar de que forma parte de la sociedad actual en cualquier lugar del mundo, hablando en específico de los jóvenes que cursan la educación superior en México.

Esto se vio exacerbado por el distanciamiento social debido a la pandemia de COVID-19, que implicó cambios en los patrones de enseñanza y aprendizaje en las instituciones educativas, pasando repentinamente del aprendizaje presencial a entornos interactivos virtuales. Como resultado, en ese periodo se presentaron retrasos e inasistencias por parte de los estudiantes a través de plataformas virtuales, debido a la falta de internet, equipos informáticos, habilidades técnicas insuficientes y una comunicación escasa o ausente entre maestros y estudiantes. En ese sentido, el uso de tecnologías en los estudiantes de educación superior ha sido un problema por diversos factores que en este trabajo se denominan barreras para el uso de tecnologías y sus innovaciones, mismas que se irán presentando en los párrafos posteriores.

La primera barrera es la aludida económica, que de acuerdo con Martínez (2021), se refiere a la capacidad de compra de artículos tecnológicos como una computadora o dispositivo móvil, así como contratar servicio de internet en el hogar, ya que hay muchas personas que no cuentan con recursos económicos suficientes y tienen que ponderar entre adquirir recursos tecnológicos o solventar sus necesidades básicas como ropa y comida.

Otra es la barrera del acceso, Arellano-Becerril y González-Zermeño (2021) y Castro-Villagrán *et al.* (2016) hacen alusión a la necesidad de infraestructura pública para el uso de las tecnologías, ya que actualmente existen comunidades rurales y suburbanas principalmente, que cuentan con servicio de internet, pero la calidad es deficiente, siendo un impedimento para los estudiantes.

La tercera barrera es la pedagógica y se refiere a la preparación del docente para la materia que imparte, capacitaciones a estudiantes y docentes para el uso de tecnologías, así como el uso de *softwares* académicos para que los profesores puedan impartir sus clases de manera ágil y oportuna. En este factor se incluyen las percepciones de los estudiantes sobre los profesores y su percepción personal en cuanto a habilidades y aptitudes para cursar las materias en línea (Pérez-López *et al.*, 2021); así mismo dentro de la barrera pedagógica se incluye el estrés académico en estudiantes, provocado por la carga académica, exámenes, horarios de clases y el tiempo de entrega de trabajos escolares (Álvarez *et al.*, 2018).

Por último, la barrera del ambiente académico también llamada como ambiente organizacional por Troche (2019), esclarece que si bien los aspectos como edad, sexo o estado civil no contribuyen de forma significativa al rendimiento en los cursos en línea, existen otros atributos considerados de suma importancia como la percepción que tienen los estudiantes sobre su contexto escolar actual en los entornos virtuales; es decir, sus experiencias en cuanto a la interacción con los compañeros y profesores, el uso de tecnologías desde casa, y el servicio de internet. Se puede decir, que en esta barrera se involucran aspectos motivacionales que son importantes para la formación académica del estudiante (Muñoz-Vidal y Beltrán-Véliz, 2020).

De acuerdo con lo expuesto por Bogarín *et al.* (2016) desde la aparición de las *plataformas e-learning* (*Moodle, Classroom, Microsoft Teams*, etc.) y el modo de aprendizaje virtual que ello conlleva, las técnicas de minería de datos han sido de utilidad para investigaciones con temas académicos, puesto que en los últimos años han contribuido al descubrimiento de conocimiento que no puede ser identificado con métodos estadísticos convencionales. En el ámbito educativo han permitido analizar diversos tipos de problemas como la deserción, el rendimiento académico, el comportamiento estudiantil, entre otros.

Es en ese sentido, que en este trabajo se propone hacer uso de técnicas de minería de datos, debido a que su uso en el ámbito educativo ha sido de gran utilidad en los últimos años, ya que como refiere Menacho (2017), no únicamente se obtienen datos estadísticos sino que permite deducir fenómenos sociales a través de un análisis profundo de datos que da como resultado la construcción de patrones de datos con información novedosa y potencialmente útil que no se puede percibir en un análisis superficial de la información. La minería de datos permite descubrir información que se encuentra oculta y que a través de la búsqueda de patrones que para el contexto de esa investigación son patrones de conducta puede ser expuesta y analizada (Rosado y Verjel, 2017).

Con los resultados obtenidos de la aplicación de la minería de datos se pretende brindar información útil acerca de la situación actual de los estudiantes para facilitar la toma de decisiones de la institución y poder proponer soluciones que mejoren las prácticas educativas como lo mencionan Paredes-Chacín *et al.* (2020) a manera de ejemplo:

- Planificación de programas académicos y cursos de formación continua en línea, tanto para estudiantes como para docentes.
- Adopción de nuevos enfoques formativos basados en metodologías activas, considerando para su desarrollo el uso de recursos electrónicos, mensajería en línea y redes académicas.

Como consecuencia, los estudiantes también se verán beneficiados porque se podrán implementar recursos que favorezcan su aprendizaje en función de sus necesidades. Es por todo lo anterior, que el objetivo de

este trabajo es aplicar la técnica de agrupamiento de minería de datos, para identificar patrones de conducta relacionados con factores que obstaculizan la apropiación tecnológica en estudiantes de nivel superior, durante las clases virtuales en época de pandemia.

DESARROLLO.

Marco Referencial.

El estudio de las percepciones de los alumnos con relación al uso de tecnologías no solo es un problema que se presenta en México, es un tema de carácter global, siendo objeto de estudio desde diferentes enfoques, hablando particularmente de la minería de datos, que de acuerdo con Vallejo *et al.* (2018) a través de la exploración de grandes bases de datos y con la identificación de patrones se pueden explicar determinados comportamientos y plantear variedad de contribuciones en el ámbito educativo; sin embargo, cualquier análisis que se realice con esta técnica dependerá del enfoque de la investigación, las herramientas tecnológicas que se ocupen, así como la metodología a aplicar (ver Tabla 1).

Tabla 1. Estudios de minería de datos educativa.

Título	Técnicas de minería de datos	Metodología de minería de datos	Herramienta de minería de datos	Objetivo	Autores
Patrones que identifican a estudiantes universitarios desertores aplicando minería de datos educativa.	Clasificación con el algoritmo de árboles de decisión.	Proceso de Extracción, Transformación y Carga de datos (ETL).	WEKA	Analizar las características de un potencial desertor universitario.	(Urbina-Nájera <i>et al.</i> , 2018).
Modelos predictivos de riesgo académico en carreras de computación con minería de datos educativo.	Clasificación con árboles de decisión.	Proceso KDD	WEKA	Analizar el desempeño estudiantil para generar modelos predictivos de riesgo académico.	(Ayala <i>et al.</i> , 2021).
Minería de datos educativos: análisis del desempeño de estudiantes de ingeniería en las pruebas Saber-Pro.	Agrupación con el algoritmo K-means, clasificación con árboles de decisión, reglas de	CRISP-DM	WEKA	Estudiar los factores que influyen en el desempeño de las pruebas Saber-Pro, agrupación del tipo de estudiantes y	(Oviedo y Jiménez, 2019).

Título	Técnicas de minería de datos	Metodología de minería de datos	Herramienta de minería de datos	Objetivo	Autores
	asociación con el algoritmo a priori.			predicción del desempeño de las pruebas.	
Proceso KDD como apoyo a las estrategias del proyecto Sistema de Acompañamiento para el Rendimiento Académico (SARA).	Clasificación con árboles de decisión.	Proceso KDD	Orange	Identificar características comunes en el ámbito personal y socioeconómico que permitan predecir si un estudiante está en riesgo de deserción.	(Calvache-Fernández <i>et al.</i> , 2018).
Estudio de variables que influyen en la deserción de estudiantes universitarios de primer año, mediante minería de datos.	Clasificación con árboles de decisión, métodos bayesianos y redes neuronales.	CRISP-DM	WEKA	Analizar la deserción de los estudiantes y obtener un modelo de clasificación.	(Zarria <i>et al.</i> , 2016).

Tal y como se muestra en el análisis bibliográfico de la Tabla 1, considerando diferentes autores que han realizado trabajos de minería de datos en la educación, son diversos los temas y propósitos académicos para la aplicación de minería de datos; por otro lado, desde la perspectiva tecnológica la herramienta más usada para la aplicación de minería de datos es WEKA; sin embargo, esto no quiere decir que sea la única herramienta que se pueda ocupar, ya que cada vez hay una mayor variedad de herramientas que pueden ser implementadas; asimismo, se observa que en los trabajos referidos la técnica de clasificación mediante árboles de decisión es de uso frecuente.

De igual manera, se pueden apreciar diferentes métodos de minería de datos, como es el caso de la metodología, KDD (Proceso de extracción del conocimiento, por sus siglas en inglés *Knowledge Discovery in Databases*) o la metodología CRISP-DM (*Cross Industry Standard Process for Data Mining*). Los métodos previamente mencionados se encuentran estructurados por etapas y cada etapa está compuesta de diferentes tareas cuyo propósito es obtener modelos a partir de los datos recopilados, y para ello es

indispensable que el análisis sea realizado con grandes volúmenes de datos para tener un análisis representativo del contexto de estudio (Gironés *et al.*, 2017).

Metodología.

El presente trabajo tiene un enfoque metodológico cuantitativo, siendo de utilidad para el estudio de fenómenos sociales debido a que se caracteriza por atender a un problema, generar objetivos en el estudio y requerir de instrumentos para la recolección de información que sirvan para medir las variables propuestas en la investigación.

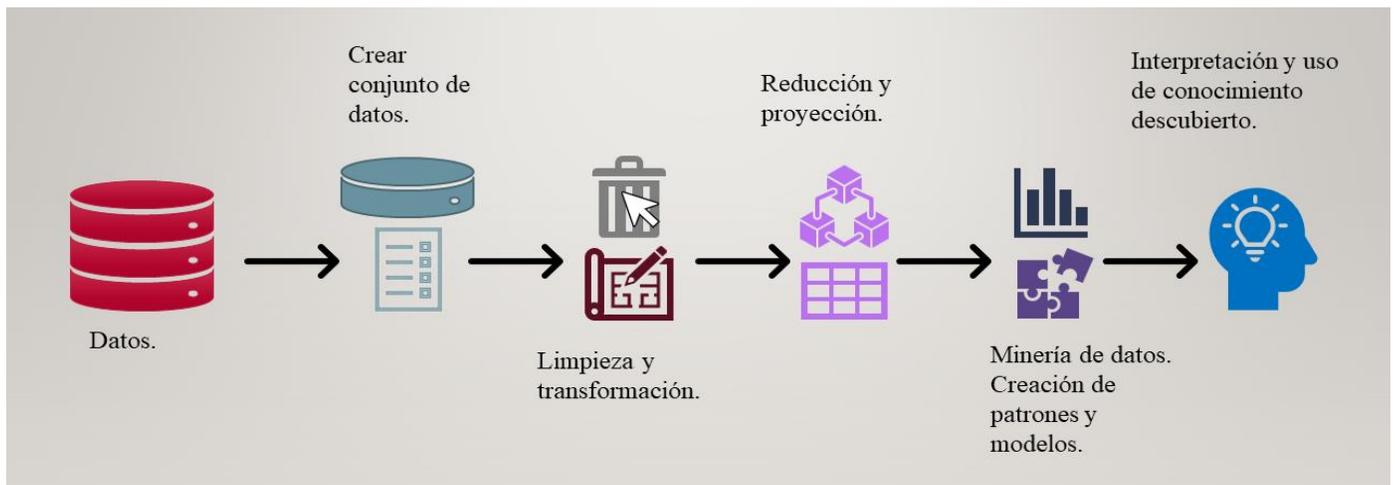
Por lo anterior, la fuente de los datos estadísticos para este trabajo se basó en una encuesta aplicada con *Google Forms*, en el periodo de mayo a diciembre del 2020. De acuerdo con el número de encuestas realizadas, se contempló un universo compuesto por 1070 estudiantes, de una universidad del sureste de México, considerando aspectos sobre el perfil de los estudiantes como edad, género, Licenciatura, División Académica, así como recursos personales disponibles, percepciones del alumno referentes a la modalidad de clases a distancia y su experiencia con respecto a las clases virtuales en época de pandemia. Este cuestionario estuvo dividido en siete secciones:

1. Generalidades.
2. Recursos disponibles.
3. Tiempo de uso de recursos tecnológicos.
4. Recursos tecnológicos utilizados por el profesor.
5. Percepciones de los estudiantes
6. Evaluación de actividades.
7. Experiencias y sugerencias.

De la aplicación de encuestas se extrajo información para generar un *dataset* para la aplicación de minería de datos. Existen diferentes métodos para la aplicación de minería de datos; sin embargo, en este conjunto de datos se aplicó el proceso de extracción del conocimiento, por sus siglas en inglés KDD (Knowledge

Discovery in Databases), que consiste en una serie de pasos expuestos en un inicio por Fayyad *et al.* (1996) y posteriormente, ha sido retomado por otros autores que concuerdan con los pasos de aplicación del método y ha sido de utilidad en diferentes áreas del conocimiento como el ámbito académico. Por lo anterior, este método es un elemento integral para el descubrimiento de conocimientos partiendo de una base de datos en la que se realizan actividades como el preprocesamiento, submuestreo y transformación de los datos (ver figura 1).

Figura 1. Fases del proceso KDD.



Por otro lado, la técnica aplicada en este trabajo fue la de *clustering* conocida como agrupación, utilizando el algoritmo *K-means*, aplicando durante el desarrollo la herramienta libre *Orange* versión 3.27.1. Finalmente, los resultados fueron analizados e interpretados para determinar la validez del conocimiento obtenido.

Proceso metodológico.

Esta investigación se apegó a los pasos que se proponen originalmente en esta metodología y que fueron descritos previamente para un mayor entendimiento, que de acuerdo con su aplicación en la herramienta seleccionada en este apartado se describe la ejecución de las etapas del proceso metodológico aplicando la base de datos de los estudiantes.

Aplicación del proceso KDD.

Aprender el dominio de la aplicación.

La herramienta con la que se interactuó fue *Orange* versión 3.27.1, y al abrir la aplicación, la primera ventana que aparece es la de bienvenida; en ella se pueden seleccionar los documentos recientes con los que se ha trabajado, revisar la documentación para aprender a usar sus instancias de trabajo o bien se puede iniciar el trabajo.

Crear un conjunto de datos destino.

Se definió como fuente de datos a la encuesta aplicada a estudiantes de la Institución de Educación Superior que se tiene como caso de estudio. Este *dataset* fue obtenido en formato .csv y está compuesto por un total de 1,070 registros de personas que respondieron una encuesta conformada por siete secciones y 43 cuestionamientos. Para el caso de este trabajo, la integración de los datos no considera una selección y conjunto de información de diferentes fuentes, puesto que los datos relevantes son extraídos de una sola base de datos.

Limpieza y procesamiento de los datos.

Para llevar a cabo las tareas de este apartado, se realizó una visualización y exploración de los datos que permitió verificar la calidad del conjunto de datos considerando los siguientes criterios:

- Tipos de errores. Se destaca principalmente el uso de caracteres especiales como sustitutos de ciertas letras o por el uso de palabras acentuadas y el desfase de respuestas dadas por los alumnos, originado por modificaciones realizadas a la encuesta durante el periodo de aplicación.
- Campos vacíos. Debido a las modificaciones realizadas al cuestionario de la encuesta, hubo campos vacíos en algunas de las respuestas dadas por los alumnos, porque cuando participaron en la encuesta las preguntas no existían.
- Duplicidad de datos. En lo que respecta a este criterio, se detectaron 15 encuestas duplicadas.

En la etapa de limpieza y procesamiento de datos, se inició con un *dataset* compuesto por 1,070 encuestas y concluyó con una eliminación de 50 encuestas por las inconsistencias detectadas, de las cuales 34 fueron por campos vacíos, 1 por ser una encuesta de prueba y 15 por duplicidad de respuestas. Dejando un total de 1,020 encuestas que serán de utilidad para la aplicación de minería de datos; lo que permite concluir, que a pesar de esta depuración se cuenta con un número considerable para la aplicación de minería de datos.

Reducción y proyección de los datos.

En esta etapa, se cambió la nomenclatura desde las preguntas generales hasta las preguntas referentes a la investigación.

Este cambio en la nomenclatura se tuvo que realizar para lograr una proyección de datos eficiente en la herramienta de minería de datos que se implementó.

Posteriormente, se realizó un cambio en preguntas abiertas de la encuesta, donde los estudiantes comparten sus opiniones y experiencias acerca de las clases virtuales. Para este caso, se buscó representar estas respuestas con tres categorías: sugerencias, desagrado y conformidad.

Con respecto a la reducción de datos, únicamente se eliminó una columna del *dataset* que contenía la fecha y hora en la que cada estudiante realizó la encuesta.

Selección de funciones y algoritmos de minería de datos.

Debido a que se busca la relación entre estudiantes universitarios y los factores que impiden el uso de tecnologías, la función de los datos guardará relación con el modelo de agrupamiento o *clustering*, tal y como se mostró en el apartado de metodología; asimismo, la función seleccionada previamente da origen a la elección del algoritmo que se puede ocupar para la aplicación de minería de datos (ver tabla 2).

Tabla 2. Selección del algoritmo de minería de datos.

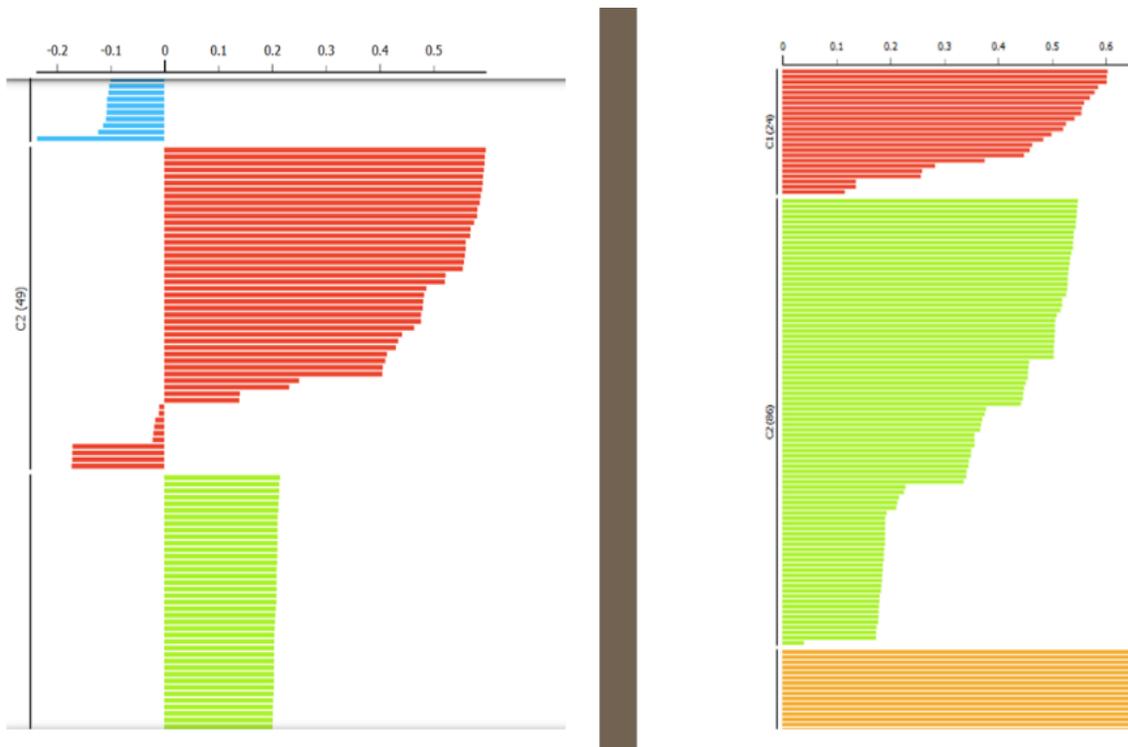
Técnica	Algoritmo	Descripción
Agrupamiento (<i>clustering</i>)	K-means	Es un método no supervisado empleado para crear grupos en un conjunto de datos, generando como resultado un nuevo conjunto de datos, pero adicionando una nueva variable llamada categoría.

Fuente: Elaboración propia con base en datos de Zaki & Meira (2020).

Minería de datos.

En este apartado se presenta el proceso que se llevó a cabo para la ejecución del algoritmo K-means en la herramienta Orange. Se inició el proceso de minería de datos con la selección del dataset, Cuando se ejecutan los diagramas de la función Silhouette Plot, se observa la distribución de las barras de acuerdo con el número de agrupaciones establecidas. Para el caso de esta investigación, se señalaron tres agrupaciones. Los puntajes positivos representan una correcta clasificación en los *clusters*, y en cuanto a los valores negativos representan instancias que no encajan correctamente. Posteriormente, se generó nuevamente el gráfico después de ejecutar el algoritmo K-means en modo interactivo y se logró una correcta agrupación de los datos (ver figura 2).

Figura 2. Gráfica Silhouette Plot en Orange.



Fuente: Elaboración propia.

En esta representación, se observa que se realizaron tres agrupaciones, se detectaron valores que no encajaron correctamente; por lo tanto, el algoritmo K-means se tuvo que ejecutar en diversas ocasiones para realizar la agrupación correcta de los datos.

Una vez que se obtuvo información relevante para la investigación, se procede a guardar el modelo generado en la aplicación, así como los correspondientes gráficos y reportes que darán soporte al análisis e interpretación de la información.

En este apartado del desarrollo investigativo, se presentó el uso de la herramienta Orange empleada para la minería de datos y cuál es el procedimiento por seguir para la generación de los reportes correspondientes para la interpretación de la información.

Interpretación y uso del conocimiento descubierto.

Al llegar a estos dos últimos puntos del proceso KDD, significa que se obtuvo un producto terminado y que será de utilidad para la toma de decisiones de la institución académica utilizada como caso de estudio; por lo tanto, serán explicados en este apartado, exponiendo los hallazgos más importantes de los datos analizados en esta investigación.

Con el fin de detectar patrones de comportamiento en los estudiantes de la IES caso de estudio, y que se encuentran asociados a la apropiación de tecnologías durante las clases virtuales, se presentan las agrupaciones obtenidas con el algoritmo K-means, y con ello, se pretende abordar la interpretación de los resultados obtenidos.

Con el algoritmo K-means se obtuvieron tres clasificaciones que fueron organizadas por la edad de los estudiantes:

- Jóvenes 20 a 25 años.
- Adulto joven de 26 a 36 años.
- Adulto maduro de 37 a 57 años.

Estas clasificaciones se obtuvieron del uso de la variable Edad de los estudiantes y la variable Silhouette; esta última se obtiene de las pruebas realizadas y es un factor que detecta las agrupaciones obtenidas de acuerdo con las métricas establecidas (ver figura 3).

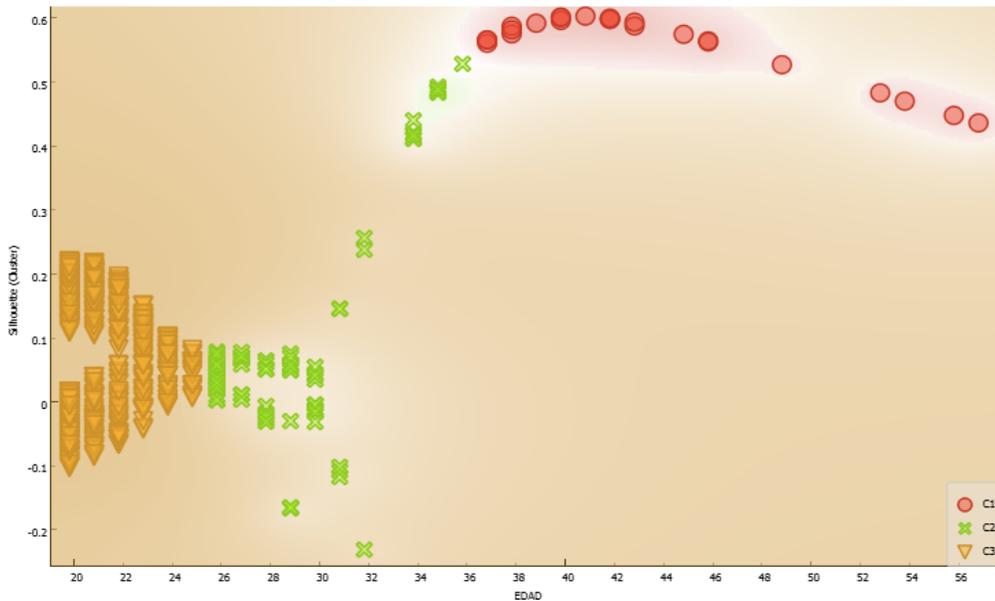


Figura 3. Gráfica Scatter Plot en Orange

En la gráfica presentada en la figura 3, se observan tres clasificaciones realizadas por edad, destacando principalmente la agrupación de color naranja sobre los jóvenes de 20 a 25; así mismo, se observa que existe una agrupación en color rojo, pero con menor presencia en la gráfica y es la de adultos maduros que oscila entre los 37 a 57 años; por lo anterior, se presenta clasificación realizada por el algoritmo K-means (ver tabla 3).

Tabla 3. Agrupación K-means.

C1	C2	C3
Adulto maduro de 37 a 57 años.	Adulto joven de 26 a 36 años.	Jóvenes 20 a 25 años.
Rojo	Verde	Naranja

De acuerdo con la clasificación que ofrece el algoritmo, se identificaron ciertos aspectos relevantes para la investigación de acuerdo con los cuestionamientos realizados a los estudiantes y que se presentan a continuación:

C1. Adulto maduro de 37 a 57 años.

En esta clasificación, los estudiantes cuentan con condiciones óptimas para hacer uso de las tecnologías en sus actividades académicas, porque tienen servicio de internet en casa y equipo de cómputo de uso exclusivo para tomar clases virtuales. En lo concerniente al estrés y la ansiedad es considerada como una variable imparcial, porque las respuestas otorgadas en este cuestionamiento son de acuerdo, desacuerdo y principalmente ni en acuerdo ni en desacuerdo; por otro lado, si bien los estudiantes sienten que pueden tomar clases en línea, lo perciben como más difícil.

C2. Adulto joven de 26 a 36 años.

En esta clasificación se encuentran los estudiantes con un uso de tecnologías más generalizado o también llamado promedio, porque tienen el acceso a internet pero es deficiente el internet y el uso de la computadora se encuentra repartido entre varios miembros de la familia, lo que provoca efectos negativos en la interacción con sus compañeros y profesores, considerando que ésta fue escasa y limitada a la solicitud de tareas. Al aumentar el impacto de las limitantes descritas, también provoca un aumento en la percepción negativa hacia el estrés y ansiedad por estudiar en línea, prefiriendo el aprendizaje presencial, ya que se elimina el requerimiento de internet y equipo de cómputo y aumentaría la cercanía entre compañeros y profesores.

C3. Jóvenes de 20 a 25 años.

En esta última clase, como se mostró previamente, hay una gran parte de la población estudiantil que se identifica en este grupo y guarda relación con el hecho de que es el rango de edad promedio para estudiar una licenciatura. Este grupo se destaca principalmente, porque no cuentan con internet o tienen un servicio ineficiente, cuentan con computadora, pero es de uso compartido con otros miembros de la familia por lo

que tienen que recurrir a otros dispositivos como celular o tableta (en pocos casos). Casi todos los encuestados tienen estrés y ansiedad por la carga de responsabilidades académicas, tuvieron poca interacción con sus profesores y compañeros, además de considerar las clases virtuales más pesadas que las presenciales.

Con estas clasificaciones, se encontraron comportamientos similares entre los grupos; por ejemplo, la falta de una buena conexión a internet o la poca interacción con los profesores y compañeros. También se encontraron comportamientos distintos, que guardan relación con los cambios generacionales y que a su vez deriva, la actitud hacia las circunstancias que se viven por las clases virtuales y se perciban de forma negativa como en el caso de un estudiante joven, o de forma resiliente, como en el caso de un estudiante con edad madura.

No es lo mismo el comportamiento de un estudiante joven, en el cual su generación tiene mayor estrés y ansiedad ocasionado por querer las cosas de forma inmediata a diferencia de un adulto mayor que tiende a ser más paciente y adaptarse a su contexto. En el caso de un adulto joven, también por su edad tiene comportamientos de ambos grupos. Estas mismas conductas son las que permiten o no poder llevar clases de forma virtual.

CONCLUSIONES.

Como se mencionó previamente, el objetivo de este trabajo ha sido el de aplicar técnicas de minería de datos para identificar patrones de conducta relacionados al uso de tecnologías en estudiantes de licenciatura a partir de datos previamente recolectados de una universidad pública del sureste mexicano.

Con las agrupaciones generadas por el algoritmo K-means se encontraron comportamientos similares entre los grupos; por ejemplo, la falta de una buena conexión a internet ocasionando que el estudiante no se conecte a sus clases, tenga que acudir a un *ciber* café o gaste en datos para usar su celular. En ese sentido, se considera que los resultados obtenidos en cuanto a la barrera del acceso coinciden con lo mencionado

por Arellano-Becerril y González-Zermeño (2021), que enfatizan en la mejora de la infraestructura pública para tener un mejor servicio de internet en los hogares.

En cuanto a la barrera económica, Martínez (2021) y Zarria *et al.* (2016) mencionan la importancia de tener el poder adquisitivo o la asignación de subsidios dirigidos a estudiantes de escasos recursos para la compra de artículos escolares y equipo como una computadora o dispositivo móvil. En esta investigación, se detectó que adquirir recursos tecnológicos es más factible en estudiantes que trabajan como un adulto de 26 años o más; de lo contrario, son más propensos a compartir equipo de cómputo como en el caso de los jóvenes de 18 a 25 años, porque suelen ser dependientes económicos.

En cuanto a la barrera pedagógica, se confirma que el estrés y la ansiedad pueden ser obstáculos para un estudiante tal y como lo menciona Álvarez *et al.* (2018) y que se puede ver complementado con las aseveraciones de Pérez-López *et al.* (2021) al mencionar las habilidades y aptitudes que debe percibir el estudiante para cursar una carrera en línea. De acuerdo con los resultados obtenidos, los estudiantes consideran que a pesar de sentirse capaces o aptos para los entornos virtuales, llevar clases en línea fue estresante y requieren que la institución académica los prepare con capacitaciones para estudios en línea.

En ese sentido, se considera que el factor de la edad tuvo un papel importante para los niveles de estrés y ansiedad percibidos por el estudiante, lo cual difiere con lo expuesto por Troche (2019), puesto que explica que la edad no contribuye de forma significativa al rendimiento del estudiante en los cursos en línea; sin embargo, el estrés y la ansiedad guardan relación con los cambios generacionales; no es lo mismo el comportamiento de un estudiante joven en la cual su generación tiene mayor estrés y ansiedad ocasionado por querer las cosas de forma inmediata, a diferencia de un adulto mayor que tiende a ser más paciente y adaptarse a su contexto. En el caso de un adulto joven, también por su edad tiene comportamientos de ambos grupos; estas mismas conductas son las que permiten o no poder llevar clases de forma virtual.

Por último, en lo que respecta a la barrera del ambiente académico, los estudiantes percibieron de forma negativa su experiencia en un ambiente virtual derivado de la poca interacción con sus profesores y la falta de un buen servicio de internet y aún más en el contexto de la pandemia por COVID-19.

Por lo anterior, se coincide con Calvache-Fernández *et al.* (2018) en que este tipo de trabajos se pueden convertir en un punto de partida para generar nuevas estrategias en beneficio de los estudiantes como flexibilidad horaria, ayudas psicológicas o acompañamiento académico de modo que el estudiante se sienta motivado a continuar con su ciclo educativo.

Otro aspecto importante dentro de las investigaciones expuestas es el número de población muestra para el abordaje metodológico; es necesario que el número sea representativo de la población estudiantil y más aún cuando las técnicas que se aplicarán son para la manipulación de grandes volúmenes de datos.

Por otro lado, los perfiles de apropiación tecnológica en los estudiantes que fueron obtenidos a través de la técnica de agrupación de minería de datos indican, que el algoritmo aplicado es capaz de generar modelos consistentes de acuerdo con los resultados presentados y la base de datos utilizada.

Se pudo observar, que influyó mucho la edad que tengan los estudiantes; por ejemplo, en el caso de los recursos tecnológicos como una computadora, requieren contar con poder adquisitivo que les permita adquirir un equipo para uso personal, ya que de acuerdo con las clasificaciones existen estudiantes que cuentan con equipo de cómputo pero es de uso colectivo entre los miembros de la familia, lo que deriva un mayor impacto en el uso deficiente de tecnologías, y a la vez experiencias negativas durante clases virtuales.

También el contar con internet en casa, puede ser percibido por el estudiante como una herramienta óptima dependiendo de la eficiencia del servicio; este factor de acuerdo con los resultados fue considerado de forma influyente, puesto que el factor de accesibilidad derivado de servicio de internet se encontró presente principalmente en jóvenes de 20 a 25 años.

Se muestra, que la diferencia de edades sí influye en la madurez con la que afrontan la carga académica, permitiendo tener un mayor dominio del estrés y la ansiedad; asimismo, el aspecto pedagógico como las evaluaciones, tareas y la cátedra del profesor pueden ser percibidos por los estudiantes de forma negativa sin importar la edad del estudiante; este es el factor que más afecta la educación en plataformas virtuales, provocando que los estudiantes prefieran tomar clases presenciales. Con lo expuesto previamente, se han obtenido patrones de conducta en los estudiantes con respecto a la apropiación de tecnologías y con relación a los factores pedagógicos de accesibilidad, adquisición de dispositivos tecnológicos, así como el estrés y la ansiedad, mayormente asociado a los estudiantes de 20 a 25 años (ver Tabla 4).

Tabla 4. Patrones identificados.

Patrones	Barreras
Falta de internet o servicio ineficiente.	Acceso.
Recursos tecnológicos compartidos o ausencia de estos.	Económica.
Necesidad de capacitación para el uso de tecnologías.	Pedagógica.
Estrés y ansiedad por el uso de tecnologías y la carga académica.	
Experiencias negativas relacionadas a la interacción con profesores y compañeros, carga académica y trabajos en equipo.	Ambiente académico.

Por lo anterior, se puede decir, que en esta investigación impera una tendencia con fines descriptivos, sobre la problemática planteada referente a la apropiación tecnológica en universitarios y cómo se relaciona con los factores presentados. Con el conocimiento descubierto, la institución académica puede optar por implementar medidas de mitigación y estrategias educativas ante la situación planteada en beneficio de los estudiantes que forman parte de la comunidad universitaria.

A partir de los resultados y discusión presentados en la investigación, se enumeran las siguientes propuestas como trabajos a futuro:

- Realizar el estudio de la apropiación tecnológica en estudiantes con el nuevo esquema de clases híbridas, aplicando otros algoritmos de minería de datos como A priori o árboles de decisión, así como la aplicación de otras herramientas de minería de datos.

- Desarrollar nuevas estrategias educativas, que debido a la naturaleza de esta propuesta, se considera que debe ser realizado por especialistas en materia de educación de la institución caso de estudio, con el fin de implementar nuevas políticas educativas que permitan mitigar el problema planteado en este estudio.

REFERENCIAS BIBLIOGRÁFICAS.

1. Álvarez-Silva, L.A., Gallegos-Luna, R. M. y Herrera-López, P. S. (2018). Estrés académico en estudiantes de Tecnología Superior. UNIVERSITAS, (28), 193-209. <http://dx.doi.org/10.17163/uni.n28.2018.10>
2. Arellano-Becerril, E. y González-Zermeño, M. (2021). Análisis de la brecha digital e inclusión digital vs. Educación virtual en tiempos de pandemia COVID-19. En A. Escudero-Nahón y R. Palacios-Díaz. (Coords.), Tecnología y contingencias (pp. 72-80). Editorial Transdigital. <https://www.editorial-transdigital.org/libros/tecnologia-y-contingencias/>
3. Ayala, E., López Martínez, R. E. y Menéndez Domínguez, V. H. (2021). Modelos predictivos de riesgo académico en carreras de computación con minería de datos educativos. Revista de Educación a Distancia, 21(66), 1-36.
4. Bogarín, A., Romero, C. y Cerezo, R. (2016). Aplicando minería de datos para descubrir rutas de aprendizaje frecuentes en Moodle. Revista de Educación Mediática y TIC, 5(1), 73-92. <https://doi.org/10.21071/edmetic.v5i1.4017>
5. Calvache-Fernández, L., Álvarez-Vallejo, V. y Triviño-Arbeláez, J. (2018). Proceso KDD como apoyo a las estrategias del proceso SARA (Sistema de Acompañamiento para el Rendimiento Académico). Revista Educación e Ingeniería, 13(6), 82-89. <http://dx.doi.org/10.26507/rei.v13n26.916>
6. Castro-Villagrán, A., Cosgaya-Barrera, B. R., Sosa-González, W. E. y Ceballos, L. (2016). Los estudiantes universitarios y el uso de las TIC como herramienta de aprendizaje. Una revisión de estudios realizados en México. IC INVESTIG@CCION, (9), 36-48. <http://revistaic.instcamp.edu.mx/volumenes/volumen9#revista09-5>

7. Fayyad, U., Piatetsky-Shapiro, G. & Smyth, P. (1996). The KDD Process for Extracting Useful Knowledge from Volumes of Data. *Communications of the ACM*, 39(11), 27-34. <https://doi.org/10.1145/240455.240464>
8. Gironés, J., Casa, J., Minguillón, J. y Caihuelas, R. (2017). *Minería de datos Modelos y algoritmos*. Editorial UOC. <http://www.editorialuoc.com>
9. Martínez, M. (2021). La desigualdad Digital en México: un análisis de las razones para el no acceso y el no uso de internet. *Revista de Tecnología y Sociedad*, (19), 1-19. <http://dx.doi.org/10.32870/Pk.a10n19.519>
10. Menacho, C. (2017). Predicción del rendimiento académico aplicando técnicas de minería de datos. *Anales Científicos*, 78(1), 26-33. https://revistas.lamolina.edu.pe/index.php/acu/article/view/811/pdf_43
11. Muñoz-Vidal, F. & Beltrán-Véliz, J. (2020). Motivation for learning, a fundamental aspect for the comprehensive training of health sciences students amid the COVID-19 pandemic. *RFM*, 69(1), 1-2. <https://dx.doi.org/10.15446/revfacmed.v69n1.94143>
12. Oviedo, A. I. y Jiménez, J. (2019). Minería de datos educativos: Análisis del desempeño de estudiantes de ingeniería en las pruebas Saber-Pro. *Revista Politécnica*, 15(29), 128-140. <https://doi.org/10.33571/rpolitec.v15n29a10>
13. Paredes-Chacín, A. J., Inciarte, A. y Walles-Peñaloza, D. (2020). Educación superior e investigación en Latinoamérica: Transición al uso de tecnologías digitales por Covid-19. *Revista de Ciencias Sociales*, 26(3), 98-117. <https://produccioncientificaluz.org/index.php/rcs/article/view/33236>
14. Pérez-López, E., Vázquez, A. y Cambero, S. (2021). Educación a distancia en tiempos de COVID-19: Análisis desde la perspectiva de los estudiantes universitarios. *RIED. Revista Iberoamericana de Educación a Distancia*. 24(1), 331-350. <http://revistas.uned.es/index.php/ried/article/view/27855>

15. Rosado, A. y Verjel, A. (2017). Aplicación de la minería de datos en la educación en línea. Revista Colombiana de Tecnologías Avanzadas, 1(29), 92-98. http://www.unipamplona.edu.co/unipamplona/portalIG/home_40/recursos/revistas/21082017/revista_29.jsp
16. Troche de Trevisan, B. G. (2019). Estudio del Rendimiento Académico del Estudiante en Línea como Variable Predictiva del Abandono en Educación Superior: El caso de la Universitat Oberta de Catalunya (tesis doctoral). Universitat Oberta de Catalunya Barcelona España. http://openaccess.uoc.edu/webapps/o2/bitstream/10609/100346/1/Troche_de_Trevisan_Cap_2_2019.pdf
17. Urbina-Nájera, A., Téllez-Velázquez, A. y Cruz, R. (2021). Patrones que identifican a estudiantes desertores aplicando minería de datos educativa. Revista Electrónica de Investigación Educativa, 23(), 1-15. <https://doi.org/10.24320/redie.2021.23.e29.3918>
18. Vallejo, H.; Guevara, E. y Medina, V. (2018). Minería de datos. Revista Científica Mundo de la Investigación y el Conocimiento. 2(), 339-349. <http://www.recimundo.com/index.php/es/article/view/182/pdf>
19. Zarria, C., Arce, C. y Lam, J. (2016). Estudio de variables que influyen en la deserción de estudiantes universitarios de primer año, mediante minería de datos. Ciencia amazónica, 6(1), 73-84. <http://dx.doi.org/10.22386/ca.v6i1.110>
20. Zaki, M. & Meira, W. (2020). Data mining and machine learning: fundamental concepts and algorithms. Cambridge University Press. <https://doi.org/10.1017/9781108564175>

DATOS DE LOS AUTORES.

- 1. Wendy Guadalupe Azuara García.** Maestra en Administración de Tecnologías de la Información. Estudiante de posgrado (División Académica de Ciencias y Tecnologías de la Información) en la Universidad Juárez Autónoma de Tabasco, México. Correo electrónico: wendy.azgar@gmail.com

2. **Martha Patricia Silva Payró.** Doctorado en Administración Educativa. Universidad Juárez Autónoma de Tabasco. Profesora-Investigadora de la División Académica de Ciencias y Tecnologías de la Información. México. Correo electrónico: patypayro@gmail.com
3. **Guillermo De los Santos Torres.** Doctorado en Sistemas Computacionales. Universidad Juárez Autónoma de Tabasco. Profesor-Investigador de la División Académica de Ciencias y Tecnologías de la Información. México. Correo electrónico: guillermo.delosssantos@ujat.mx

RECIBIDO: 6 de febrero del 2025.

APROBADO: 20 de marzo del 2025.