



Facultad de Ciencias Económicas y Empresariales.

Estrategias de estudio en matemáticas de grados no STEM

Amalia Hernández García

5º E3 + Analytics

Director: José Luis Arroyo Barriguete.

Madrid, 2024-25

Resumen

Este estudio explora las estrategias de estudio empleadas por estudiantes universitarios de grados no STEM al enfrentarse a asignaturas con contenido matemático. A partir de una encuesta diseñada específicamente para esta investigación, se recogieron respuestas de 152 estudiantes sobre aspectos como el uso de la memoria, el tiempo dedicado al estudio, el tipo de soporte utilizado (papel o digital), la dificultad percibida y el rendimiento académico. Mediante un análisis de clúster jerárquico, se identificaron tres perfiles diferenciados: Esforzados, Memorísticos y Eficientes. Posteriormente, se aplicaron contrastes estadísticos y modelos de árboles de regresión para analizar las diferencias entre grupos y determinar qué combinaciones de factores explican mejor el rendimiento y la percepción de dificultad. Los resultados muestran que el perfil del estudiante es el principal factor explicativo, y que la estrategia de estudio utilizada también puede desempeñar un papel relevante, aunque su impacto varía según el contexto. Estos hallazgos ofrecen orientaciones útiles para mejorar los procesos de enseñanza y promover una mayor adaptación metodológica en contextos no STEM.

Palabras Clave

estrategias de estudio, aprendizaje matemático, clúster jerárquico, rendimiento académico, dificultad percibida, soporte digital

Abstract

This study examines the study strategies used by non-STEM university students when approaching mathematics-related subjects. Based on a survey specifically designed for this research, responses were collected from 152 students regarding memory use, study time, the type of support used (paper or digital), perceived difficulty, and academic performance. A hierarchical cluster analysis identified three distinct student profiles: Dedicated, Rote Learners, and Efficient. Statistical tests and regression tree models were then applied to explore group differences and determine which factor combinations best explain academic performance and

perceived difficulty. The results indicate that the student profile is the main explanatory factor, while the study strategy may also play a relevant role, although its impact varies depending on the context. These findings provide useful guidance for improving teaching processes and supporting better methodological adaptation in non-STEM environments.

Key Words

study strategies, mathematics learning, hierarchical clustering, academic performance, perceived difficulty, digital support

Graphical abstract

(1) Pregunta de investigación

¿Cómo influyen las estrategias de estudio y los perfiles de alumnado en la dificultad percibida y el rendimiento en matemáticas? ¿Qué relación existe con variables como el género o la especialidad de bachillerato?

(2) Revisión de la literatura

Se identifican variables clave: tiempo dedicado al estudio, uso de la memoria, estrategia del estudio (papel vs. digital) y factores personales (tipo de bachillerato)

(3) Hipótesis de investigación

H1: Existen distintos perfiles de estudiantes en función de sus hábitos de estudio (tiempo y memoria).
H2: El perfil de estudiante está relacionado con el rendimiento académico en matemáticas.
H3: El perfil de estudiante está relacionado con la dificultad percibida en el estudio de matemáticas.
H4: La estrategia de estudio utilizada (soporte digital o papel) influye en el rendimiento académico y la dificultad percibida.

(4) Estimación de los modelos (árboles de regresión)

Se construyeron dos modelos predictivos mediante árboles de regresión para analizar el efecto combinado del perfil del estudiante y la estrategia de estudio

Modelo I: Dificultad percibida

H1: El perfil del estudiante influye significativamente en la dificultad percibida. 

H3: Se observaron diferencias claras de dificultad entre clústeres. 

H4: El soporte influye según el perfil, con diferencias entre estrategias. 

Modelo II: Rendimiento

H1: El clúster 3 muestra el mejor rendimiento; los clústeres segmentan bien 

H2: Los clústeres explican diferencias en rendimiento 

El efecto del soporte es secundario respecto al perfil del estudiante. 

Contenido

Introducción.....	1
Motivación del trabajo	1
Relevancia del tema	2
Objetivos de la investigación.....	3
Revisión de la literatura	4
Influencia de la especialidad de bachillerato en la percepción de dificultad y rendimiento en matemáticas	6
Relación entre soporte de estudio, tiempo de dedicación y rendimiento en matemáticas	7
Uso de la memoria y preferencia por enfoques teóricos o prácticos en matemáticas	9
Motivación en la elección del grado y su impacto en el rendimiento en matemáticas ..	10
Hipótesis de Investigación	11
Material y Métodos	13
Diseño del estudio	13
Participantes.....	13
Variables independientes del modelo	14
Formulación del análisis.....	23
Enfoque metodológico general.....	23
Modelo de segmentación: clustering jerárquico	23
Contrastes entre grupos.....	25
Modelos predictivos: árboles de regresión	26
Resultados y Discusión	27
Segmentación del alumnado	27
Descripción de los perfiles obtenidos	27
Comparación de los perfiles en dificultad y rendimiento	29
Relación entre los perfiles y variables cualitativas.....	31
Modelos predictivos	33
Árbol de regresión para la dificultad percibida.....	33
Árbol de regresión para el rendimiento.....	36
Conclusiones	39
Evaluación de las hipótesis.....	41
Declaración respecto al uso de Chat GPT u otras herramientas de IAG	44
Referencias	45
Anexos	47
Anexo 1: encuesta	47

Introducción

Motivación del trabajo

Este Trabajo de Fin de Grado (TFG) tiene como objetivo analizar las estrategias de estudio que utilizan los estudiantes de grados no STEM (Ciencia, Tecnología, Ingeniería y Matemáticas) para estudiar matemáticas. Este análisis se enmarca dentro del Objetivo de Desarrollo Sostenible (ODS) número 4, que promueve una educación de calidad, equitativa e inclusiva, con el fin de contribuir al desarrollo sostenible. Por lo tanto, la importancia de este estudio radica en entender los desafíos específicos que enfrentan estos estudiantes y proponer estrategias que puedan mejorar su rendimiento académico.

Este TFG forma parte de un proyecto de investigación más amplio, que incluye 4 TFGs diferentes, cada uno centrado en un tipo de asignatura dentro de los grados no STEM. El proyecto está enmarcado en el ámbito del proyecto de innovación docente "Non-Binary Approaches to Higher Education: Quantitative Analysis and Fact-Based Research" (Ref. 221, U. Sevilla) y la Cátedra Santalucía de Analytics for Education de la Universidad Pontificia Comillas. Este enfoque multidisciplinario busca avanzar no solo en el área de la investigación educativa, sino también ofrecer recomendaciones prácticas para mejorar la enseñanza de materias que, tradicionalmente, se perciben como difíciles.

Las matemáticas son fundamentales en muchas carreras universitarias, incluso en aquellas fuera del ámbito STEM, como Administración y Dirección de Empresas (ADE) o Business Analytics (BA). En muchas disciplinas de Ciencias Sociales, las habilidades cuantitativas son esenciales para tomar decisiones basadas en datos, optimizar recursos o realizar análisis financieros, entre otras actividades. Sin embargo, los estudiantes de estas áreas suelen ver las matemáticas como una materia difícil y poco relevante para su carrera, lo que genera barreras importantes en su aprendizaje. Incluso los estudiantes con buen rendimiento pueden tener dificultades para enfrentarse a esta asignatura (Carbonero Martín & Navarro Zavala, 2006). Este

proyecto busca analizar esas barreras desde el punto de vista de las estrategias de estudio utilizadas por los estudiantes de la Universidad Pontificia de Comillas ICADE, identificando los factores que influyen en su rendimiento y cómo mejorar la experiencia educativa.

Según Gallego Gil y Nevot Luna (2008), personalizar las estrategias pedagógicas según los estilos de aprendizaje es clave para superar las barreras en el aprendizaje de las matemáticas. Por eso, este TFG pretende aportar datos empíricos que ayuden a romper con esta dinámica negativa y fomentar una enseñanza más inclusiva.

Relevancia del tema

El aprendizaje de las matemáticas no solo es fundamental para el desarrollo académico de los estudiantes, sino también para su futura inserción en un mercado laboral que cada vez valora más las habilidades analíticas. Competencias matemáticas como el razonamiento lógico, el análisis de datos y la resolución de problemas son esenciales en áreas tan diversas como la economía, la gestión empresarial y otras ciencias sociales. Diversos estudios previos, como los de Gallego Gil y Nevot Luna (2008) y Arroyo Barrigüete et al. (2020), han demostrado que los estudiantes que emplean estrategias de estudio inadecuadas suelen encontrar limitaciones en su aprendizaje de las matemáticas, lo que afecta negativamente su rendimiento académico y contribuye a desigualdades formativas.

Arroyo Barrigüete et al. (2020) también destacan que, en el contexto de titulaciones dobles como Derecho y ADE, la segmentación de los perfiles de los estudiantes mediante análisis de clúster puede poner en evidencia diferencias importantes en el rendimiento y las estrategias empleadas para abordar materias cuantitativas. Estos hallazgos son fundamentales para personalizar las intervenciones pedagógicas que puedan reducir las desigualdades y mejorar la enseñanza de las matemáticas en grados no STEM. Además, como se mencionó anteriormente, este trabajo se enmarca en el Objetivo de Desarrollo Sostenible (ODS) número 4, que busca

garantizar una educación inclusiva, equitativa y de calidad. Analizar cómo los estudiantes de grados no STEM enfrentan el aprendizaje de las matemáticas permitirá diseñar intervenciones que mejoren su experiencia educativa y contribuyan a reducir las desigualdades en el acceso al conocimiento matemático.

Objetivos de la investigación

El presente estudio tiene como objetivo principal analizar las estrategias de estudio utilizadas por los estudiantes de grados no STEM en el aprendizaje de las matemáticas, con el fin de identificar aquellas que se correlacionan con un mejor rendimiento académico. El estudio de estas estrategias es esencial para la formulación de políticas y enfoques pedagógicos fundamentados en evidencia, lo que permite desarrollar métodos más realistas y apropiados (Vásquez Córdova, 2021). Para desarrollar esta investigación, nos centraremos en una serie de factores y en su incidencia en el rendimiento académico y/o en otros factores influyentes.

En esta investigación se explorará la relación entre la especialidad de bachillerato cursada y la percepción de dificultad en matemáticas a nivel universitario. Se busca determinar si la formación previa en determinadas áreas influye en cómo los estudiantes perciben la complejidad de esta materia en su educación superior, proporcionando información relevante para adaptar estrategias pedagógicas más eficaces.

Asimismo, se evaluará cómo el soporte de estudio utilizado—ya sea papel, digital o una combinación de ambos—junto con el tiempo dedicado al estudio, afectan el rendimiento académico en matemáticas. Comprender estas dinámicas permitirá identificar qué métodos resultan más efectivos para mejorar el aprendizaje y el desempeño en esta disciplina.

Otro aspecto clave de este análisis será la relación entre el uso de la memoria y la preferencia por el enfoque teórico o la resolución de problemas en matemáticas. Este estudio permitirá entender si los estudiantes que dependen más de la memorización tienen un

rendimiento diferente en comparación con aquellos que priorizan el razonamiento y la aplicación práctica de los conceptos matemáticos.

Por último, se examinará el impacto de la motivación en la elección del grado universitario y su efecto en el rendimiento académico en matemáticas. Identificar cómo la motivación influye en el desempeño puede aportar información valiosa para diseñar estrategias que fomenten un aprendizaje más efectivo y satisfactorio en los estudiantes.

Revisión de la literatura

El aprendizaje de las matemáticas en la universidad no es algo sencillo, ya que no depende solo de lo difícil que pueda ser la materia, sino de varios factores que influyen en cómo los estudiantes enfrentan el estudio. Uno de esos factores son las estrategias de aprendizaje que utilizan, las cuales tienen una relación directa con su rendimiento académico (Carbonero Martín & Navarro Zavala, 2006). Sin embargo, este rendimiento no se puede ver solo desde esa perspectiva, ya que factores como los métodos de enseñanza, los recursos que se usan, la forma en que se evalúa a los estudiantes y aspectos personales como la motivación, expectativas, creencias y actitudes también juegan un papel importante (Rosário et al., 2005).

Las matemáticas son importantes no solo en áreas STEM (Ciencia, Tecnología, Ingeniería y Matemáticas), sino también en grados no STEM, ya que ayudan a desarrollar habilidades clave como el pensamiento lógico y la capacidad para resolver problemas. Estas habilidades son muy valoradas en el ámbito profesional (Northern Illinois University, s.f.). Además, aplicar el enfoque STEM en la educación promueve una enseñanza interdisciplinaria que hace que los conocimientos matemáticos se puedan aplicar a situaciones reales, lo que mejora la comprensión y la utilidad de las matemáticas en el ámbito académico y profesional (Prat & Sellas, 2021).

Para entender cómo todos estos factores interactúan en el aprendizaje, Dunkin y Biddle (1974) proponen un modelo que se divide en tres fases: presagio, proceso y producto. La fase de presagio involucra todos los factores previos al proceso de enseñanza, como los conocimientos previos, la motivación y las expectativas del estudiante, y el contexto educativo en el que se encuentran. Estos factores influyen en el proceso de enseñanza-aprendizaje, que es la dinámica que ocurre en el aula y las estrategias de estudio que los estudiantes eligen. Finalmente, estos elementos afectan el producto, que en este caso son los resultados académicos, como las calificaciones.

El aprendizaje de las matemáticas no es algo pasivo. Los estudiantes interpretan su entorno educativo basándose en sus propias experiencias y motivaciones. Biggs (1987, 1993a, 1993b) menciona que este proceso, conocido como "meta-aprendizaje", lleva a los estudiantes a desarrollar un enfoque personal para estudiar, lo que impacta directamente en su rendimiento final. Así, la forma en que los estudiantes perciben su entorno educativo y las estrategias que usan no solo afectan cómo entienden las matemáticas, sino también cómo enfrentan la asignatura en general.

Aparte de cómo las estrategias de estudio afectan el rendimiento académico, hay estudios que han demostrado que aprender matemáticas también ayuda a desarrollar habilidades analíticas y de resolución de problemas, lo cual es esencial para la formación profesional de los estudiantes (Pérez Gómez et al., 2008). Además, el aprendizaje de las matemáticas desde una edad temprana fomenta habilidades cognitivas importantes, como el razonamiento lógico y la capacidad de análisis. Valtierra Lacalle (2015) explica que la competencia matemática no solo es la habilidad para resolver problemas matemáticos específicos, sino también la capacidad de tomar decisiones y comprender fenómenos en la vida diaria y en el entorno profesional. Esto es importante no solo para el ámbito académico, sino también para la vida cotidiana y el trabajo profesional.

Por todo esto, es crucial analizar en profundidad cómo las estrategias de estudio afectan el rendimiento en matemáticas, teniendo en cuenta tanto los factores individuales como los contextuales que intervienen en este proceso. Este estudio tiene como objetivo proporcionar evidencia sobre cómo diferentes elementos, desde la especialidad de bachillerato hasta las preferencias por métodos teóricos o prácticos, pueden influir en cómo los estudiantes enfrentan el aprendizaje de las matemáticas y su desempeño en esta disciplina.

Influencia de la especialidad de bachillerato en la percepción de dificultad y rendimiento en matemáticas

El análisis de la relación entre la especialidad de bachillerato cursada y el rendimiento en matemáticas a nivel universitario es fundamental para entender cómo la formación previa afecta la manera en que los estudiantes perciben y enfrentan la dificultad de esta materia. Según Hernández Álvarez (2016), aunque el Bachillerato de Ciencias Sociales está más orientado a grados relacionados con áreas como economía y finanzas, los estudiantes que provienen del Bachillerato de Ciencias suelen tener una base más sólida en matemáticas, lo que facilita su desempeño en esta asignatura. Esta diferencia en la formación previa puede influir en la confianza y la actitud con la que los estudiantes abordan las matemáticas en la universidad.

Investigaciones recientes han explorado esta relación, como el estudio comparativo realizado por Arroyo Barrigüete et al. (2023), quienes encontraron que los estudiantes que provienen del Bachillerato de Ciencias tienen una mejor comprensión relacional en matemáticas en comparación con aquellos que provienen del Bachillerato de Ciencias Sociales. Esto sugiere que los estudiantes con una formación más intensiva en matemáticas están mejor preparados para afrontar las asignaturas cuantitativas en la universidad.

Sin embargo, la percepción de dificultad en matemáticas no solo depende de la formación académica previa, sino también de factores emocionales y cognitivos. Gómez Chacón (2009) señala que las reacciones emocionales de los estudiantes pueden afectar los procesos de aprendizaje y su disposición para enfrentar la materia con confianza. La percepción de dificultad, entonces, actúa como una actitud evaluativa que puede influir en cómo los estudiantes abordan el estudio de las matemáticas, lo que a su vez impacta en su rendimiento académico y en las estrategias de aprendizaje que adoptan.

Estos hallazgos resaltan la importancia de comprender el impacto de la especialidad de bachillerato en la transición a la educación universitaria y en la adaptación de los estudiantes a las exigencias matemáticas de sus grados. Dado que la base de conocimientos previa influye en la percepción de dificultad y en el rendimiento, es fundamental analizar qué estrategias pueden implementarse para mejorar la preparación matemática de los estudiantes de grados no STEM, especialmente aquellos que provienen de itinerarios educativos con menor carga cuantitativa.

Relación entre soporte de estudio, tiempo de dedicación y rendimiento en matemáticas

El tiempo que los estudiantes dedican al estudio es un factor clave en su rendimiento académico. Rosario et al. (2005) encontraron que cuando los estudiantes invierten más tiempo en su aprendizaje personal, su interés por la materia aumenta, lo que también mejora sus resultados. Esto sugiere que, además de ser una cuestión de cantidad, el tiempo de estudio también está relacionado con una mayor motivación e implicación del estudiante.

La relación entre el tiempo de estudio y los resultados académicos es compleja. No se trata solo de la cantidad de tiempo que se dedica al estudio, sino también de la calidad de ese tiempo. Hurtado de la Peña y López Esteban (2017) concluyen que, aunque los estudiantes que invierten más tiempo en el estudio suelen obtener mejores resultados, lo importante es cómo

gestionan y organizan ese tiempo. La calidad de las estrategias de estudio y la forma en que se organiza el tiempo de aprendizaje son determinantes para optimizar el rendimiento académico.

El uso de herramientas tecnológicas en la enseñanza de las matemáticas, como software interactivo y plataformas digitales, ayuda a los estudiantes a concentrarse más en los aspectos conceptuales de los problemas. Al reducir la carga de trabajo rutinario, estas herramientas facilitan la resolución de problemas complejos. Además, fomentan un aprendizaje más dinámico y un enfoque más práctico en la aplicación de conceptos matemáticos (Morales & Cuevas Valencia, 2022).

La transformación digital en la enseñanza de las matemáticas ha sido un avance importante en la aplicación de nuevas metodologías y recursos pedagógicos. Armas Real (2023) destaca que las tecnologías, como el software educativo y las plataformas digitales, facilitan el aprendizaje de conceptos matemáticos difíciles al permitir que los estudiantes interactúen de forma más directa con los contenidos. También promueven un aprendizaje más dinámico y flexible, que permite a los estudiantes aplicar mejor los conocimientos en diferentes contextos.

Aunque el uso de dispositivos electrónicos en el estudio ofrece ventajas como mayor accesibilidad y dinamismo, su impacto en el aprendizaje efectivo todavía se está debatiendo. Aún falta determinar cómo la elección del tipo de soporte de estudio afecta específicamente al rendimiento en matemáticas. Algunos estudios sugieren que leer en papel puede favorecer una mejor retención de información y mayor concentración (CERLALC, 2020). Es posible que ciertos tipos de contenido o métodos de evaluación se beneficien más del uso de un soporte tradicional, mientras que otros aprovechen mejor las herramientas digitales interactivas.

Este estudio se enfocará en analizar la relación entre el tipo de soporte de estudio utilizado por los estudiantes de grados no STEM y su rendimiento en matemáticas. Se comparará el uso de papel, dispositivos electrónicos y una combinación de ambos. Entender estos efectos

permitirá identificar las estrategias más efectivas para mejorar el aprendizaje de las matemáticas en estudiantes universitarios.

Uso de la memoria y preferencia por enfoques teóricos o prácticos en matemáticas

Una de las cuestiones clave en la enseñanza de las matemáticas es la estrategia de aprendizaje utilizada por los estudiantes. Arroyo Barrigüete et al. (2020) mencionan que algunos alumnos tienden a adoptar un enfoque memorístico para estudiar matemáticas, lo que podría explicar su bajo rendimiento en comparación con otras asignaturas, donde este tipo de enfoque resulta más efectivo. Esto resalta la importancia de promover estrategias de aprendizaje que prioricen la comprensión y el razonamiento, en lugar de la repetición mecánica de procedimientos.

La memoria de trabajo juega un papel fundamental en el rendimiento académico en matemáticas. Según Hernández Suárez et al. (2021), la capacidad de almacenar y manipular información en la memoria de trabajo está muy relacionada con el desempeño de los estudiantes en tareas matemáticas complejas. Este hallazgo sugiere que una mayor capacidad de memoria de trabajo permite gestionar mejor la información necesaria para resolver problemas matemáticos, lo que a su vez lleva a un mejor rendimiento en la asignatura.

La relación entre la teoría y la práctica en la evaluación de la resolución de problemas matemáticos es compleja. Cárdenas Lizarazo et al. (2011) destacan que la evaluación en matemáticas, especialmente en la resolución de problemas, muestra diferencias notables entre los enfoques teóricos y prácticos. Mientras que en la teoría se fomenta el desarrollo de habilidades cognitivas más avanzadas, en la práctica, los estudiantes a menudo se enfrentan a evaluaciones centradas en procedimientos mecánicos. Estas diferencias en la evaluación pueden afectar las estrategias de aprendizaje que los estudiantes adoptan, llevándolos a priorizar enfoques más algorítmicos en lugar de enfoques que promuevan el razonamiento profundo.

La elección de una u otra estrategia no depende únicamente de las preferencias del alumno, sino también de cómo se presentan y evalúan los contenidos dentro del sistema educativo. En sistemas educativos donde la evaluación está muy centrada en la memorización, los estudiantes tienden a desarrollar estrategias de aprendizaje basadas en la repetición y la retención de fórmulas y definiciones. Por el contrario, en contextos donde la evaluación pone énfasis en la resolución de problemas y la aplicación de conceptos, los estudiantes pueden estar más inclinados a desarrollar habilidades de razonamiento y análisis.

Dado que el rendimiento en matemáticas puede estar influenciado por la estrategia de aprendizaje adoptada, este estudio analizará cómo el uso de la memoria, la preferencia por la teoría o la resolución de problemas, impacta los resultados académicos de los estudiantes de grados no STEM. Comprender esta relación permitirá proponer estrategias de enseñanza más alineadas con el desarrollo de habilidades analíticas y de resolución de problemas en el aprendizaje de las matemáticas.

Motivación en la elección del grado y su impacto en el rendimiento en matemáticas

La motivación es un factor clave en el rendimiento académico y en la persistencia de los estudiantes a lo largo de su carrera universitaria. Tejedor Tejedor (2003) identificó que la motivación hacia la carrera elegida es uno de los principales determinantes del éxito académico, solo precedido por las calificaciones previas y las condiciones de la docencia. Además, factores como el entorno socio-familiar y el tiempo dedicado al estudio también son esenciales en el desempeño académico de los estudiantes.

La motivación intrínseca, especialmente cuando se basa en la elección vocacional, tiene un impacto directo en la experiencia educativa de los estudiantes. Según Alarcón Montiel (2019), los estudiantes que eligen su carrera profesional por vocación y afinidad con la disciplina tienden a disfrutar más de sus estudios y obtener mejores resultados académicos, particularmente en

asignaturas clave como las matemáticas. Cuando la elección de carrera está alineada con los intereses y pasiones del estudiante, esto fomenta una experiencia educativa más satisfactoria y genera un mayor compromiso con los estudios.

La motivación también juega un papel importante en el rendimiento académico, especialmente en disciplinas como las matemáticas. Calle Chacón et al. (2020) sostienen que la motivación es el motor que impulsa la conducta humana, y por lo tanto, un estudiante motivado estará más dispuesto a dar lo mejor de sí mismo. Este tipo de motivación intrínseca, derivada de la afinidad por la materia, permite a los estudiantes enfrentar los desafíos académicos con mayor persistencia y dedicación, lo que se traduce en mejores resultados en áreas clave como las matemáticas.

En el caso de los estudiantes de grados no STEM, la relación entre motivación y rendimiento en matemáticas puede ser diferente. Dado que las matemáticas no son el foco principal de sus estudios, aquellos estudiantes sin una motivación intrínseca hacia la materia pueden percibirla como más difícil. Comprender cómo la motivación influye en su disposición para aprender matemáticas es crucial, ya que esta información puede ser valiosa para desarrollar estrategias de enseñanza que fomenten una actitud más positiva hacia la asignatura y, por ende, un mejor rendimiento académico.

Hipótesis de Investigación

A partir de la revisión de la literatura sobre los factores que influyen en el rendimiento académico en matemáticas y las estrategias de estudio utilizadas por estudiantes de grados no STEM, se plantean las siguientes hipótesis de investigación:

Hipótesis 1 (H1): Existen perfiles diferenciados de estudiantes en función del uso de la memoria y el tiempo dedicado al estudio de matemáticas.

Esta hipótesis se fundamenta en estudios previos que evidencian la existencia de distintos estilos de aprendizaje y estrategias de estudio entre los estudiantes, lo que puede reflejarse en patrones observables mediante técnicas de segmentación como el análisis de clústeres.

Hipótesis 2 (H2): El perfil de estudiante está relacionado con el rendimiento académico en matemáticas.

Diversas investigaciones han señalado que las estrategias de estudio y el tiempo invertido se asocian directamente con los resultados académicos. Por ello, se espera que los perfiles obtenidos expliquen en parte el rendimiento de los estudiantes.

Hipótesis 3 (H3): El perfil de estudiante está relacionado con la dificultad percibida en el estudio de matemáticas.

La percepción de dificultad puede estar influida por factores como el esfuerzo requerido o la eficiencia en la estrategia de estudio, por lo que se espera encontrar diferencias en función del perfil del estudiante.

Hipótesis 4 (H4): La estrategia de estudio utilizada (soporte digital o papel) influye en el rendimiento académico y la dificultad percibida.

Esta hipótesis se apoya en estudios que analizan el impacto de los soportes utilizados para estudiar en la comprensión y retención de contenidos. Se espera que el tipo de soporte tenga un efecto modulador, especialmente en estudiantes menos eficientes.

Material y Métodos

Diseño del estudio

El objetivo principal es analizar los factores que influyen en el rendimiento en matemáticas de estudiantes de grados no STEM, haciendo especial hincapié en factores como las estrategias de estudio utilizadas o el tiempo dedicado. Para ello, se empleó un cuestionario, dirigido a estudiantes de los dobles grados con componente de Business Analytics de la Universidad Pontificia de Comillas ICADE, y se realizó un análisis estadístico de los datos recogidos a través del software R. El contenido exacto de las preguntas y respuestas ofrecidas en dicha encuesta se encuentran en el Anexo 1 de este trabajo.

El estudio busca describir la relación entre variables como el grado cursado, el género, la especialidad de bachillerato, el soporte de estudio empleado (papel o dispositivos electrónicos), el tiempo dedicado al estudio, con el rendimiento académico y la dificultad percibida en matemáticas. Asimismo, se exploran patrones de comportamiento mediante técnicas de segmentación no supervisada (clustering) y se construyen modelos predictivos a través de árboles de regresión.

Participantes

Tal y como se menciona en la introducción, los destinatarios de la encuesta fueron estudiantes universitarios matriculados en alguno de los dobles grados con componente de Business Analytics ofrecidos en una Universidad Pontificia de Comillas. Estos son: Administración de Empresas y Business Analytics (E2+BA), Derecho y Business Analytics (E3+BA) y Relaciones Internacionales y Business Analytics (E6+BA). Todos ellos eran mayores de edad en el momento de la recogida de datos, concretamente de cursos académicos de 3º, 4º y 5º de grado

universitario. La encuesta estuvo disponible entre el 21 de marzo y el 11 de abril de 2024, y fue respondida por un total de 156 personas.

Tras una primera revisión de los datos, se eliminaron aquellas respuestas que estaban incompletas en las variables clave del análisis. Posteriormente, se aplicó un proceso de limpieza y transformación de datos. Por ejemplo, la variable relativa al uso de dispositivos electrónicos o papel durante el estudio fue recodificada en categorías más comprensibles (e.g., “Todo en papel”, “Mitad y mitad”, “Mayoría disp. electr.”), en lugar de mantener únicamente los valores numéricos originales de la encuesta.

Asimismo, se transformaron algunas preguntas de respuesta múltiple, como los motivos para haber elegido el grado, en variables binarias independientes. Estas modificaciones se realizaron tanto manualmente en el archivo Excel como mediante un preprocesamiento inicial con R, donde también se filtraron las observaciones incompletas, se seleccionaron las variables relevantes y se ajustaron los niveles de los factores.

Tras este proceso, la muestra definitiva utilizada para el análisis quedó compuesta por 152 estudiantes.

Variables independientes del modelo

Tras el procesamiento de los datos y una primera caracterización de la muestra, se seleccionaron las variables independientes que se han utilizado para construir los modelos del presente trabajo. Las variables han sido seleccionadas en función de su relevancia teórica, su presencia en la literatura revisada, y su disponibilidad en la base de datos final.

La tabla 1 recoge un resumen de las principales variables independientes incluidas en los modelos, especificando su nombre, su tipología y una breve descripción de su contenido y codificación. A continuación, se desarrolla una explicación individual de cada una de ellas.

Tabla 1. Variables independientes del modelo

Fuente: elaboración Propia

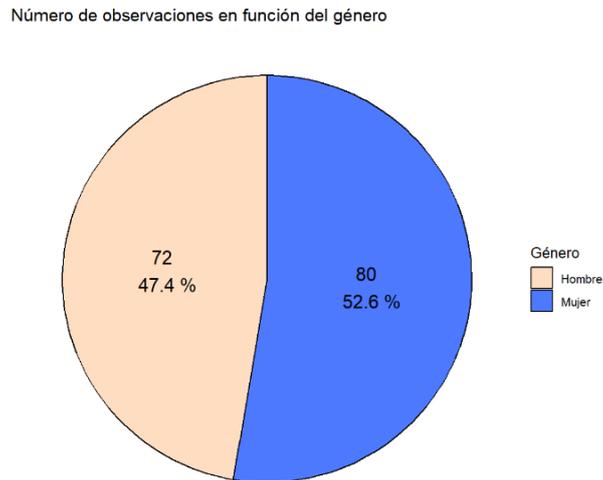
Nombre Factor	Nombre Variable	Descripción
Género	Hombre Mujer	Variable dicotómica que indica el género del encuestado.
Especialidad Bachillerato	Ciencias Ciencias_Sociales Bach_Internacional Otras	Variable categórica que recoge la modalidad de bachillerato cursada.
Grado	E2+BA E3+BA E6+BA	Variable categórica que identifica el doble grado en el que está matriculado el estudiante.
Curso	3 4 5	Variable ordinal que representa el curso académico del alumno (de 3º a 5º)
Estrategia de estudio	Solo dispositivos elect. Mayoría disp. electr. Mitad y mitad Mayoría en papel Todo en papel	Variable ordinal que indica el tipo de soporte empleado para el estudio de matemáticas. Se recodificó en cinco categorías: solo uso de dispositivos electrónicos, mayoría del estudio en dispositivos electrónicos, la mitad en papel y la mitad con dispositivos electrónicos, mayoría del estudio en papel y todo el estudio en papel.
Tiempo de estudio	0-10	Variable ordinal (escala 0 a 10) que mide el tiempo dedicado a estudiar las asignaturas de Matemáticas con respecto a otras asignaturas del doble grado del encuestado
Uso de la memoria	0-10	Variable ordinal (escala 0 a 10) que mide el grado en que el alumno considera que tuvo que aprender nada de memoria (0) o que lo aprendió todo de memoria (10), en el estudio de las asignaturas de matemáticas
Importancia de la teoría	1-6	Variable ordinal que refleja el porcentaje aproximado de tiempo de estudio dedicado a la teoría frente a la práctica, codificada en intervalos del 0% al 100%. 0% teoría – 100% problemas (1) 20% teoría – 80% problemas (2) 40% teoría – 60% problemas (3) 60% teoría – 40% problemas (4) 80% teoría – 20% problemas (5) 100% teoría – 0% problemas (6)

De las 152 observaciones válidas, 80 (52,6%) corresponden a mujeres y 72 (47,4%) a hombres. La muestra se encuentra, por tanto, relativamente equilibrada en términos de género, con una ligera mayoría de participantes femeninas. Esta distribución queda reflejada en la Figura

3.1, que representa el número de observaciones en función del género mediante un gráfico de sectores.

Figura 3.1. Proporción de género en la muestra total

Fuente: elaboración propia a partir de los resultados de la encuesta.

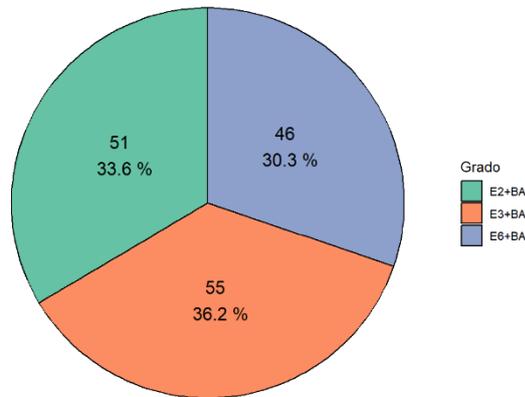


En lo que respecta a la distribución de los participantes según el doble grado que cursan, el más representado en la muestra es Derecho y Business Analytics (E3+BA), con 55 estudiantes (36,2% del total). Le siguen Administración de Empresas y Business Analytics (E2+BA), con 51 observaciones (33,6%), y Relaciones Internacionales y Business Analytics (E6+BA), con 46 (30,3%). Aunque las tres titulaciones presentan una representación relativamente equilibrada, el predominio del grado E3+BA puede tener cierta influencia en los resultados globales. Esta distribución queda reflejada en la Figura 3.2.

Figura 3.2. Número de observaciones en función del grado cursado

Fuente: elaboración propia a partir de los resultados de la encuesta.

Número de observaciones en función de Grado

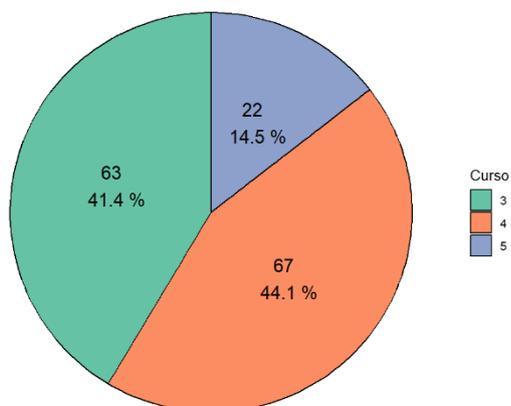


En cuanto a la distribución por curso académico, la mayoría del alumnado encuestado se encuentra cursando cuarto, con un total de 67 estudiantes (44,1%). Le sigue el tercer curso, con 63 participantes (41,4%). Por último, el número de estudiantes de quinto curso asciende a 22, lo que representa el 14,5% de la muestra. Esta distribución pone de manifiesto una mayor representación de los cursos intermedios en el momento de recogida de datos. Toda esta información se recoge en la Figura 3.3.

Figura 3.3. Número de observaciones en función del curso académico

Fuente: elaboración propia a partir de los resultados de la encuesta

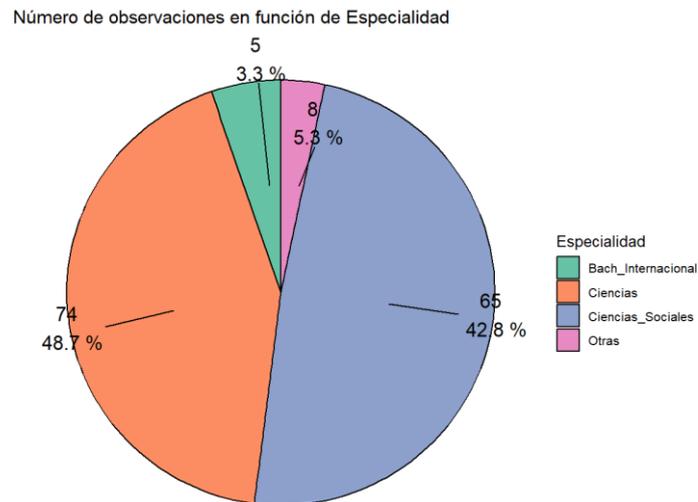
Número de observaciones en función de Curso



Respecto a la especialidad cursada en bachillerato, se observa una ligera mayoría de estudiantes procedentes de la modalidad de Ciencias, con un total de 74 observaciones (48,7%). Le sigue de cerca la especialidad de Ciencias Sociales, con 65 estudiantes (42,8%). El resto de participantes se distribuye entre el Bachillerato Internacional (5 observaciones, 3,3%) y otras especialidades no especificadas (8 observaciones, 5,3%). Esta información se refleja en la Figura 3.4, que muestra la distribución de la especialidad de bachillerato entre los encuestados.

Figura 3.4. Número de observaciones en función de la especialidad de bachillerato

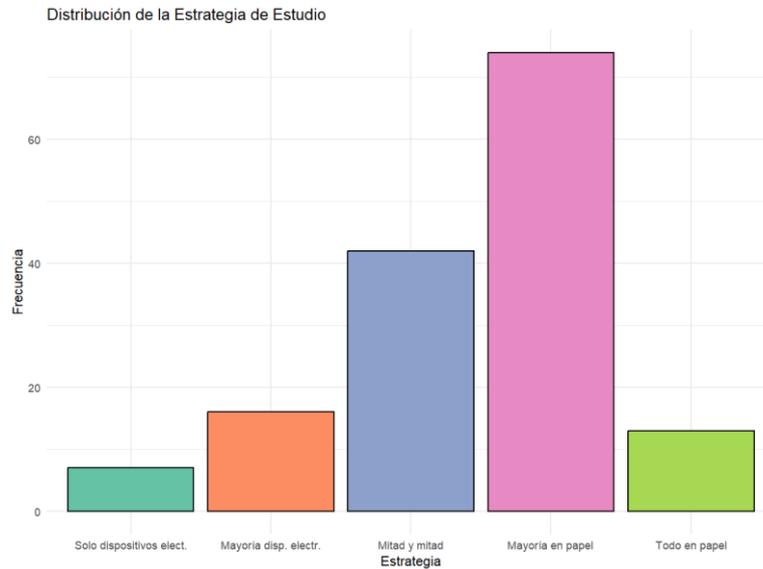
Fuente: elaboración propia a partir de los resultados de la encuesta.



En cuanto al soporte de estudio empleado para preparar matemáticas, la opción más frecuente es “Mayoría en papel”, con una clara diferencia respecto al resto de estrategias. Le siguen, a bastante distancia, quienes declaran usar “Mitad y mitad” (una combinación equilibrada de papel y dispositivos electrónicos). Las opciones menos frecuentes son “Solo dispositivos electrónicos” y “Todo en papel”, mientras que “Mayoría en dispositivos electrónicos” ocupa una posición intermedia. Esta distribución pone de manifiesto una tendencia general hacia el uso predominante del papel, aunque existen perfiles diversos entre los estudiantes. Todo ello queda representado en la Figura 3.5.

Figura 3.5. Distribución del soporte de estudio utilizado para matemáticas

Fuente: elaboración propia a partir de los resultados de la encuesta.



En relación con el tiempo que los estudiantes dedican semanalmente al estudio de matemáticas, se observa una notable dispersión en las respuestas. Tal y como se refleja en la Figura 3.6, aunque hay alumnos que declaran estudiar menos de 2 horas a la semana, también existen casos que superan ampliamente las 7 horas. El valor más frecuente (moda) corresponde a quienes estudian 8 horas semanales.

Esta heterogeneidad queda confirmada por la Figura 3.7, que muestra el gráfico de caja y bigotes (boxplot) para esta variable. Se aprecia que la mediana se sitúa ligeramente por encima de las 6 horas, mientras que el rango intercuartílico va aproximadamente de 3 a 8 horas. No se detectan valores extremos evidentes. En conjunto, los datos muestran que, si bien una parte del alumnado dedica poco tiempo al estudio de matemáticas, existe también un grupo significativo que le dedica un esfuerzo considerable.

Figura 3.6. Distribución del tiempo de estudio en matemáticas

Fuente: elaboración propia a partir de los resultados de la encuesta.

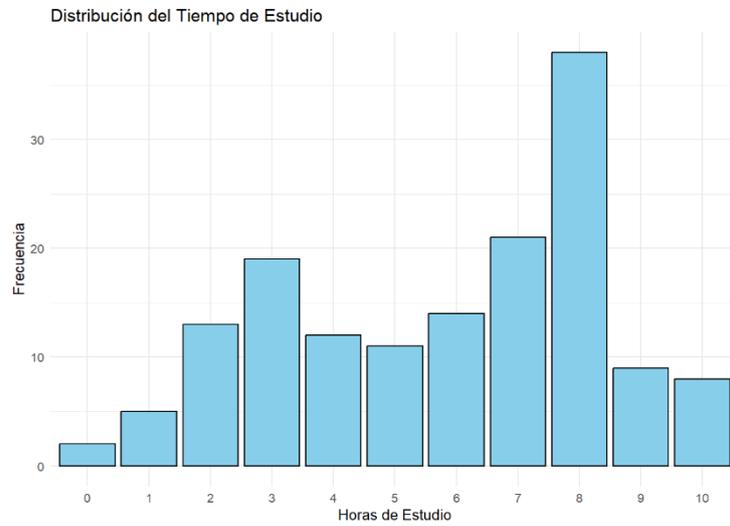
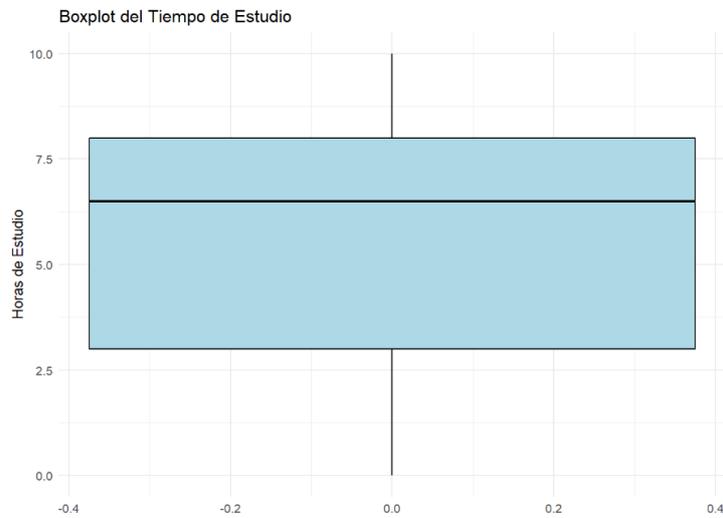


Figura 3.7. Boxplot del tiempo de estudio en matemáticas

Fuente: elaboración propia a partir de los resultados de la encuesta.



En lo que respecta al uso de la memoria, se pidió a los estudiantes que evaluaran en una escala del 0 al 10 hasta qué punto consideraban que habían tenido que aprender las matemáticas de memoria, siendo 0 “nada de memoria” y 10 “todo de memoria”. Como se observa en la Figura 3.8, las respuestas se concentran principalmente en torno a los valores intermedios, con especial frecuencia en los niveles 3 y 6. Existe también una representación considerable en los extremos

más bajos de la escala, lo que indica que una parte del alumnado no percibe la memorización como un recurso principal.

La Figura 3.9 representa el boxplot de esta variable. Se aprecia que la mediana se sitúa en torno al valor 4, mientras que el rango intercuartílico va desde aproximadamente 2 hasta 6. El gráfico confirma la tendencia central de las respuestas hacia una memoria moderada.

Figura 3.8. Distribución del uso de la memoria en matemáticas

Fuente: elaboración propia a partir de los resultados de la encuesta.

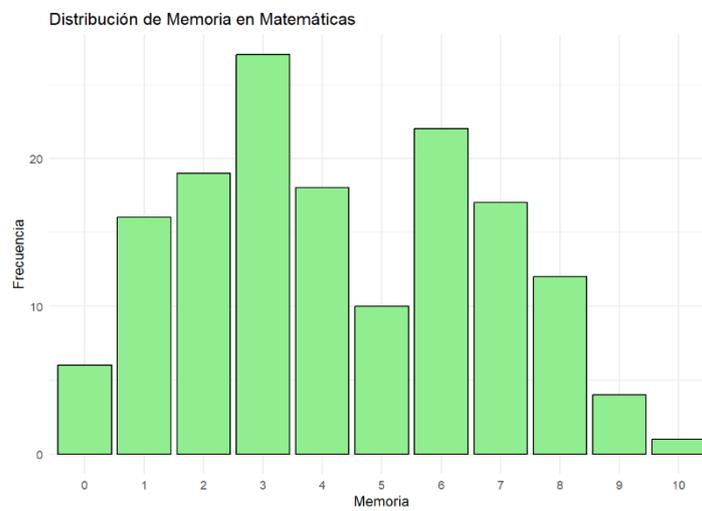
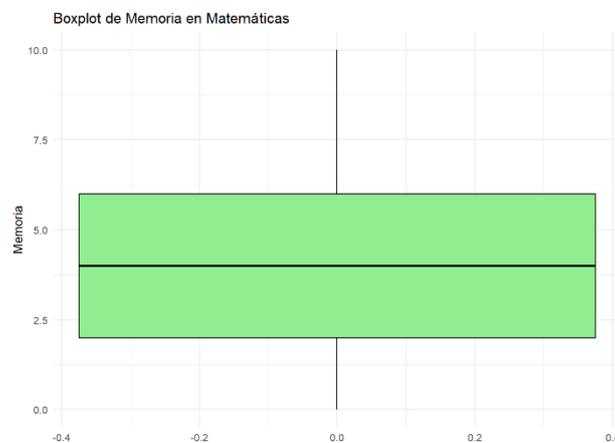


Figura 3.9. Boxplot del uso de la memoria en matemáticas

Fuente: elaboración propia a partir de los resultados de la encuesta.



En relación con la distribución del tiempo de estudio entre teoría y práctica, la mayoría de los estudiantes eligió las categorías más orientadas a la práctica, especialmente el nivel 2 (20

% teoría – 80 % práctica), seguido del nivel 3 (40 % teoría – 60 % práctica), tal y como se observa en la Figura 3.10. Esto sugiere que, para la mayoría de los participantes, el estudio de matemáticas se centra fundamentalmente en la resolución de problemas, relegando la teoría a un segundo plano. Esta tendencia se confirma en el boxplot de la Figura 3.11, donde se aprecia una clara concentración en torno a los valores bajos de la escala. La mediana se sitúa entre los niveles 2 y 3, y aunque hay algunos casos aislados que declaran dedicar más del 60 % de su tiempo a la teoría (valores 5, 6 y 7), estos aparecen como valores atípicos en el gráfico.

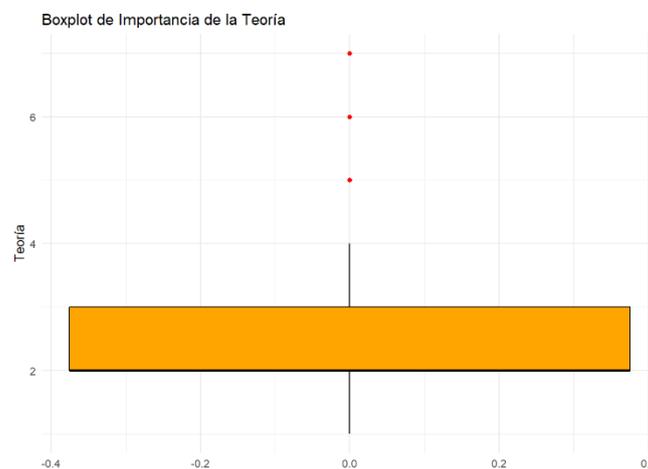
Figura 3.10. Distribución de la importancia atribuida a la teoría frente a la práctica

Fuente: elaboración propia a partir de los resultados de la encuesta.



Figura 3.11. Boxplot de la importancia atribuida a la teoría frente a la práctica

Fuente: elaboración propia a partir de los resultados de la encuesta.



Formulación del análisis

Enfoque metodológico general

El análisis se ha desarrollado en dos fases complementarias. En primer lugar, se realizó un análisis no supervisado mediante técnicas de clustering con el fin de segmentar a los estudiantes en función de su tiempo dedicado al estudio y del nivel de memorización empleado. Esta clasificación permitió construir una nueva variable categórica (Clúster) que agrupa al alumnado en perfiles de estudio distintos.

En una segunda fase, se utilizaron técnicas de regresión mediante árboles para predecir dos variables dependientes: el rendimiento académico percibido en matemáticas y la dificultad que los estudiantes dicen experimentar al enfrentarse a esta materia. En ambos casos, se emplearon como variables predictoras tanto la estrategia de estudio utilizada (papel vs. dispositivos electrónicos) como el perfil de estudiante resultante del clustering. Este enfoque permite analizar no solo si existen diferencias entre grupos, sino también si dichas variables pueden tener un valor explicativo en el rendimiento y la dificultad percibida.

Modelo de segmentación: clustering jerárquico

Con el objetivo de identificar perfiles de estudiantes con patrones similares en sus hábitos de estudio, se aplicó un análisis de clustering. Esta técnica permite agrupar individuos en función de su similitud en determinadas variables, sin necesidad de establecer categorías previas.

Tras diversas pruebas exploratorias con diferentes combinaciones de variables, se constató que muchas de ellas no generaban agrupaciones con una diferenciación estadísticamente

significativa en las variables de interés (el rendimiento y la dificultad percibida en matemáticas).

Finalmente, se seleccionaron como base del análisis las siguientes dos variables:

- **Matematicas_Memoria:** escala del 0 al 10 que mide el grado en que el estudiante considera que ha tenido que memorizar los contenidos de matemáticas.
- **Matematicas_Tiempo:** escala del 0 al 10 que recoge cuánto tiempo dedica el estudiante al estudio de matemáticas en comparación con otras asignaturas.

La elección de estas dos variables se basó en su significancia estadística, así como en su relevancia teórica en estudios sobre estrategias de estudio. Ambas representan dos dimensiones clave: el tiempo invertido en el estudio (esfuerzo) y la dependencia del aprendizaje memorístico (enfoque).

El análisis se llevó a cabo utilizando la distancia euclídea como medida de proximidad entre observaciones. Esta medida es especialmente adecuada cuando las variables son cuantitativas y están en la misma escala, como ocurre en este caso. Para el método de enlace se empleó el algoritmo de Ward (concretamente ward.D2), que minimiza la varianza dentro de cada grupo al fusionar nodos. Esta técnica tiende a generar clústeres más homogéneos y de tamaño similar, lo que facilita su interpretación.

Una vez generado el dendrograma, se optó por segmentar la muestra en tres grupos, ya que dicho corte ofrecía una solución coherente tanto desde el punto de vista gráfico como estadístico, permitiendo observar diferencias claras entre los perfiles resultantes. La nueva variable categórica generada, denominada *Cluster*, clasifica a los estudiantes en los siguientes grupos:

- **Cluster 1:** estudiantes con bajo uso de la memoria y alto tiempo de estudio.
- **Cluster 2:** estudiantes con alto uso de la memoria y tiempo moderado.
- **Cluster 3:** estudiantes con bajo uso de la memoria y bajo tiempo de estudio.

Estos perfiles se han etiquetado posteriormente como *Esforzados*, *Memorísticos* y *Eficientes*, respectivamente, en función de las características predominantes de cada grupo. La interpretación detallada de cada clúster se presenta en el capítulo 4.

Contrastes entre grupos

Una vez definidos los tres grupos resultantes del análisis de clusters, se procedió a examinar si existían diferencias significativas entre ellos en relación con variables académicas clave. Para ello, se llevaron a cabo contrastes mediante análisis de la varianza (ANOVA) de una vía, empleando como variable agrupadora la pertenencia a uno de los tres clústeres.

En concreto, se contrastaron las diferencias entre clústeres respecto a dos variables fundamentales:

- Rendimiento académico percibido en matemáticas, medido en una escala de 0 a 10.
- Dificultad percibida al estudiar matemáticas, también evaluada en una escala de 0 a 10.

En ambos casos, cuando el resultado del ANOVA indicaba diferencias significativas, se aplicaron contrastes post hoc utilizando el test de Tukey HSD, con el objetivo de identificar entre qué pares de grupos se encontraban dichas diferencias.

Además del análisis de variables numéricas, se examinó si existía alguna relación significativa entre los clústeres y dos variables categóricas: el género del estudiante y la especialidad de bachillerato cursada. Para ello, se aplicaron tests de Chi-cuadrado de independencia. En el caso de la especialidad, se filtraron previamente las observaciones para considerar únicamente las dos categorías mayoritarias (“Ciencias” y “Ciencias Sociales”), eliminando el resto para asegurar la validez estadística del contraste debido a las pocas observaciones en las otras especialidades. A su vez, se empleó la función `droplevels()` en R para evitar que las categorías eliminadas influyeran en los resultados.

Cuando los tests de independencia resultaban significativos, se interpretaron los residuos ajustados para identificar qué combinaciones concretas (por ejemplo, mujeres en el clúster 2, o estudiantes de Ciencias Sociales en el clúster 3) contribuían más al resultado global. Esto permitió enriquecer la interpretación de los perfiles definidos en el análisis de clústeres.

Modelos predictivos: árboles de regresión

En una segunda fase del análisis, se construyeron dos modelos predictivos independientes mediante árboles de regresión, con el objetivo de explorar qué variables permiten explicar mejor el rendimiento y la dificultad percibida en matemáticas. Este tipo de modelos permite representar visualmente la estructura de decisiones que separa los distintos niveles de la variable dependiente a partir de las variables predictoras, lo que facilita su interpretación y permite identificar relaciones complejas y no lineales.

Las dos variables dependientes utilizadas fueron:

- Rendimiento académico en matemáticas: medida a través de una escala de 0 a 10, en la que los estudiantes valoraban su rendimiento percibido.
- Dificultad percibida en matemáticas: igualmente medida en una escala de 0 a 10, en la que los estudiantes indicaban cuán difícil les había resultado estudiar la asignatura.

Ambas variables se mantuvieron en su escala original y no fueron transformadas, dado que el objetivo no era construir un modelo de regresión lineal ajustado, sino explorar su estructura explicativa mediante árboles de decisión.

Como variables predictoras se utilizaron dos factores categóricos obtenidos o procesados previamente:

- Cluster: variable resultante del análisis de conglomerados, que clasifica a los estudiantes en tres perfiles según su combinación de memoria y tiempo de estudio.

- *Estrategia_de_estudio*: variable ordinal que indica el tipo de soporte utilizado para el estudio de matemáticas, con cinco niveles: solo dispositivos electrónicos, mayoría en dispositivos, mitad y mitad, mayoría en papel y todo en papel.

Ambos árboles se construyeron mediante la función `rpart()` del entorno estadístico R, con el método de partición “anova”, adecuado para variables dependientes continuas, y aunque en este caso se trata de variables discretas, se ha empleado como aproximación.

Los árboles generados se podaron para evitar sobreajuste, y se exportaron como gráficos para facilitar su interpretación. La explicación detallada de la estructura de cada árbol, así como de la relevancia de cada predictor en la toma de decisiones, se desarrolla en el capítulo de resultados.

Resultados y Discusión

Segmentación del alumnado

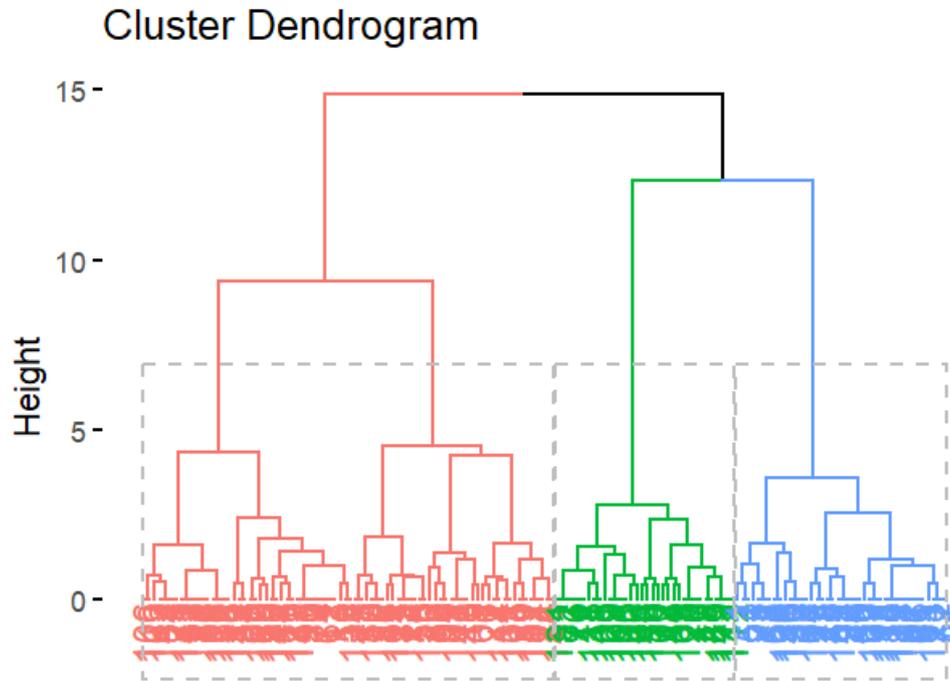
Descripción de los perfiles obtenidos

A partir del análisis descrito en el capítulo anterior, se identificaron tres grupos diferenciados de estudiantes en función de su nivel de memorización y del tiempo dedicado al estudio de matemáticas. Estos clústeres permiten representar distintos perfiles de comportamiento académico, y a cada uno de ellos se le ha asignado un nombre que resume sus principales características.

La Figura 4.1. muestra el dendrograma resultante del análisis de clusters, en el que se observa con claridad la formación de los tres grupos seleccionados.

Figura 4.1. Dendrograma del análisis de clústeres jerárquico

Fuente: elaboración propia a partir del análisis de clustering jerárquico realizado en R



El Clúster 1, compuesto por 40 estudiantes, se caracteriza por un nivel bajo de memorización (media = 2,35) y un tiempo de estudio elevado (media = 7,90). Este grupo representa a aquellos estudiantes que dedican muchas horas a estudiar, pero no dependen especialmente de la memoria. Se les ha denominado Esforzados, ya que su estrategia se basa en el esfuerzo sostenido a pesar de presentar un rendimiento que no es excelente y una elevada dificultad percibida (Véase Tabla 3).

El Clúster 2, con 78 estudiantes, presenta un nivel alto de memorización (media = 6,29) y un tiempo de estudio moderado (media = 6,17). Estos estudiantes tienen una mala estrategia de estudio: dedican al estudio un número de horas elevado y emplean en exceso la memoria, mucho más de lo razonable. Esto les lleva al peor rendimiento de los tres clusters y a una elevada dificultad percibida. Se les ha denominado Memorísticos, ya que su excesivo uso de la memoria para estudiar matemáticas, estrategia completamente errada, les lleva a un rendimiento pobre y a una percepción de dificultad elevada (Véase Tabla 3).

El Clúster 3, formado por 34 estudiantes, muestra tanto bajo nivel de memorización (media = 1,91) como bajo tiempo de estudio (media = 2,65). Este grupo refleja un perfil más eficiente (por lo que se les ha denominado Eficientes) con respecto a la asignatura, pues presentan el mejor rendimiento y los niveles más bajos de dificultad percibida (Véase Tabla 3).

La tabla 2 resume las métricas principales de cada grupo.

Tabla 2. Características medias de los clústeres según memoria y tiempo de estudio

Fuente: elaboración propia a partir del análisis de clustering jerárquico

Grupo	Media Memoria	SD Memoria	Media Tiempo	SD Tiempo
Esforzados	2.35	1.14	7.9	1.03
Memorísticos	6.29	1.48	6.17	2.29
Eficientes	1.91	1.03	2.65	1.12

Comparación de los perfiles en dificultad y rendimiento

Una vez definidos los tres perfiles de estudiantes a partir del análisis de cluster, se procedió a analizar si existían diferencias significativas entre ellos en relación con dos variables clave: la dificultad percibida al estudiar matemáticas y el rendimiento académico declarado por los propios estudiantes. Para ello, se calcularon las medias de ambas variables en cada uno de los tres grupos identificados, las cuales se recogen en la Tabla 3.

Tabla 3. Características medias de los clústeres según dificultad percibida y rendimiento académico

Fuente: elaboración propia a partir del análisis de clustering jerárquico

Grupo	Dificultad Percibida Media	Rendimiento Medio
Esforzados	7.78	6.85
Memorísticos	6.95	6.35
Eficientes	5.38	7.59

Para contrastar si los clústeres presentaban diferencias significativas en cuanto a la dificultad percibida al estudiar matemáticas y el rendimiento académico, se realizaron dos análisis de varianza (ANOVA), uno por cada variable dependiente.

En el caso de la dificultad percibida, el análisis reveló diferencias estadísticamente significativas entre grupos ($F(2,149) = 15.70$; $p < 0.001$). El test post hoc de Tukey mostró que el grupo 3 (Eficientes) presenta niveles significativamente más bajos de dificultad que los grupos 1 y 2 ($p < 0.001$ en ambos casos), mientras que no se encontraron diferencias significativas entre el grupo 1 (Esforzados) y el grupo 2 (Memorísticos) ($p = 0.060$).

Respecto al rendimiento académico, también se encontraron diferencias significativas entre los clústeres ($F(2,149) = 5.67$; $p = 0.004$). El contraste de Tukey indicó que el grupo 3 (Eficientes) obtuvo resultados significativamente mejores que el grupo 2 (Memorísticos) ($p = 0.003$). No se observaron diferencias significativas entre los grupos 1 (Esforzados) y 2 (Memorísticos), ni entre los grupos 1 (Esforzados) y 3 (Eficientes).

Tabla 4. Comparaciones post hoc (Tukey) para la dificultad percibida entre clústeres

Fuente: elaboración propia a partir del análisis ANOVA y test de Tukey

Comparación	Diferencia de Medias	P-valor Ajustado	Significativo
2-1	-0.83	0.060	No
3-1	-2.39	<0.001	Sí
3-2	-1.57	<0.001	Sí

Tabla 5. Comparaciones post hoc (Tukey) para el rendimiento académico entre clústeres

Fuente: elaboración propia a partir del análisis ANOVA y test de Tukey

Comparación	Diferencia de Medias	P-valor Ajustado	Significativo
2-1	-0.50	0.328	No
3-1	0.74	0.184	No
3-2	1.24	0.003	Sí

Estos resultados permiten concluir que los perfiles de estudiantes definidos por el uso de la memoria y el tiempo de estudio están efectivamente asociados con el rendimiento y la percepción de dificultad. En concreto, los Eficientes son quienes rinden mejor y perciben menor dificultad, mientras que los Memorísticos obtienen los peores resultados y presentan niveles altos de dificultad.

Relación entre los perfiles y variables cualitativas

Además, se exploró si la pertenencia a un determinado clúster estaba relacionada con otras características de los alumnos, como el género o la especialidad de bachillerato de la que procedían. Para ello, se realizaron contrastes de independencia mediante el test de Chi-cuadrado y, posteriormente, un análisis post hoc a partir de los residuos ajustados tipificados.

En primer lugar, el contraste para la variable especialidad de bachillerato, considerando únicamente las categorías mayoritarias (“Ciencias” y “Ciencias Sociales”), mostró una asociación significativa con el clúster ($\chi^2(2) = 5,996$; $p = 0,049$) (véase Tabla 6). No obstante, el análisis post hoc reveló que ninguna celda individual presentaba diferencias estadísticamente significativas tras calcular los residuos tipificados y sus respectivos p-valores (todos $> 0,15$). Aun así, se observó una tendencia: el grupo Eficientes presentaba una mayor proporción de estudiantes procedentes

de Ciencias ($p = 0,156$), y el grupo Memorísticos una mayor proporción de Ciencias Sociales ($p = 0,313$), aunque sin alcanzar significación estadística.

En segundo lugar, el test de Chi-cuadrado para la variable género también resultó estadísticamente significativo ($\chi^2(2) = 14,833$; $p < 0,001$) (véase Tabla 7). En este caso, el análisis post hoc indicó una diferencia significativa en el grupo Esforzados, que presentaba menos hombres de lo esperado ($p = 0,0398$), y casi significativamente más mujeres ($p = 0,0512$). Estos resultados sugieren una sobrerrepresentación femenina en este grupo. En los demás grupos, las diferencias por género no alcanzaron niveles de significación estadística.

Tabla 6. Test de Chi-cuadrado y análisis post hoc por especialidad de bachillerato

Fuente: elaboración propia a partir del test de Chi-cuadrado y residuos ajustados tipificados

Clúster	Ciencias (P-valor)	Ciencias Sociales (P-valor)
Esforzados	0.8756	0.8834
Memorísticas	0.2818	0.3131
Eficientes	0.1563	0.1840

Tabla 7. Test de Chi-cuadrado y análisis post hoc por género

Fuente: elaboración propia a partir del test de Chi-cuadrado y residuos ajustados tipificados

Clúster	Hombres (P-valor)	Mujeres (P-valor)
Esforzados	0.0398	0.0512
Memorísticas	0.0690	0.0845
Eficientes	0.5999	0.618

En conjunto, estos hallazgos apoyan la existencia de ciertos patrones de género y trayectoria académica previa en la distribución de los clústeres, a pesar de que estos se

definieron únicamente en función de variables cuantitativas. Esto otorga una mayor solidez e interpretabilidad al modelo de segmentación propuesto.

Modelos predictivos

Con el objetivo de explorar de forma más precisa la relación entre las estrategias de estudio, los perfiles de estudiantes y sus resultados académicos, se han estimado dos modelos de árboles de regresión.

Árbol de regresión para la dificultad percibida

Con el objetivo de identificar los factores que explican la percepción de dificultad al estudiar matemáticas, se construyó un árbol de regresión utilizando como variables predictoras el perfil del estudiante (variable Cluster) y la estrategia de estudio empleada (variable Estrategia_de_estudio). El modelo fue generado con la función `rpart()` mediante el método "anova" y los parámetros `cp = 0.015`, `minsplit = 20` y `maxdepth = 4`.

La Figura 4.2 muestra el resultado del modelo. El nodo raíz refleja la media general de dificultad percibida en la muestra: 6,8 puntos sobre 10 ($n = 152$).

La primera división del árbol se basa en el perfil del estudiante: quienes pertenecen al clúster 3 (Eficientes) se separan del resto, presentando una dificultad media significativamente menor (5,4 puntos, $n = 34$). Dentro de este grupo, se realiza una nueva partición según la estrategia de estudio: los estudiantes que utilizan solo dispositivos electrónicos, mayoría de dispositivos electrónicos o todo en papel ($n = 7$) presentan la dificultad más baja del árbol (4 puntos), mientras que el resto del clúster 3 ($n = 27$), que emplea estrategias como mitad y mitad o mayoría en papel, alcanza una media de dificultad algo mayor (5,7 puntos).

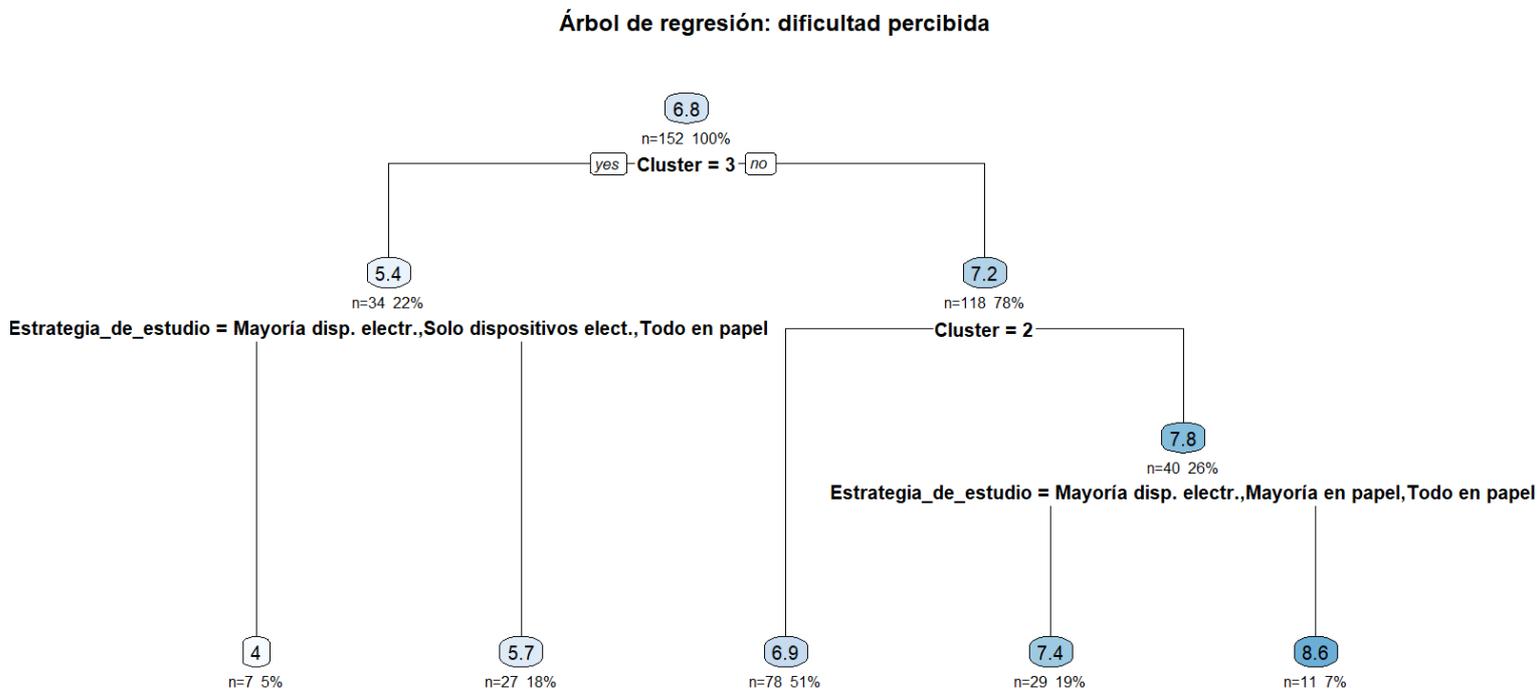
Aunque esta división puede resultar contraintuitiva -ya que agrupa metodologías opuestas como el uso exclusivo de dispositivos frente al uso exclusivo de papel-, el modelo

identifica que, dentro de este perfil de estudiantes, dichas estrategias coexisten con niveles similares y bajos de dificultad percibida. Esto podría reflejar que, en estudiantes altamente eficientes, el tipo de soporte utilizado es menos relevante para su experiencia académica.

Por otro lado, los estudiantes de los clústeres 1 y 2 (Esforzados y Memorísticos) se agrupan en la rama derecha del árbol, con una media general de dificultad percibida notablemente más alta (7,2 puntos, n = 118). Este grupo también se subdivide en función de la estrategia de estudio. Aquellos que utilizan mayoría de dispositivos electrónicos, mayoría en papel o todo en papel (n = 40) reportan una dificultad media superior (7,8 puntos), que se eleva hasta 8,6 puntos en el caso de quienes utilizan exclusivamente papel (n = 11). En cambio, quienes utilizan estrategias como mitad y mitad o solo dispositivos electrónicos presentan una dificultad algo menor (6,9 puntos, n = 78), si bien sigue siendo superior a la del grupo eficiente.

Figura 4.2. Árbol de regresión: dificultad percibida.

Fuente: elaboración propia a partir de los resultados del modelo en R.



Los resultados de este árbol de regresión permiten extraer varias conclusiones relevantes sobre la interacción entre el perfil del estudiante y la estrategia de estudio en la percepción de dificultad.

En primer lugar, se confirma que el perfil del estudiante es el principal factor que discrimina el nivel de dificultad percibida. El clúster 3, que agrupa a los estudiantes clasificados como Eficientes, presenta de forma sistemática las puntuaciones más bajas de dificultad, independientemente del soporte de estudio utilizado. Este grupo, definido por dedicar menos tiempo a estudiar y memorizar menos, parece haber desarrollado una forma de afrontar las matemáticas que les resulta menos exigente a nivel cognitivo. Es probable que cuenten con una buena base previa, una mayor familiaridad con el contenido, o estrategias de aprendizaje más automatizadas que les permiten avanzar con menor esfuerzo percibido.

Dentro de este clúster, el uso exclusivo de dispositivos electrónicos se asocia con la menor dificultad reportada (4 puntos sobre 10), lo cual refuerza la idea de que el uso intensivo de herramientas digitales puede facilitar el estudio en perfiles con una buena base y capacidad autónoma. Sin embargo, incluso cuando se emplean otras estrategias como “todo en papel” o “mayoría de dispositivos”, el nivel de dificultad sigue siendo moderadamente bajo, lo que sugiere que el tipo de soporte no es un factor limitante en los estudiantes más autónomos y organizados.

En cambio, entre los perfiles menos eficientes (Esforzados y Memorísticos), no puede afirmarse que exista una mayor sensibilidad a la estrategia de estudio empleada, ya que la variabilidad en los niveles de dificultad percibida es similar a la observada en el clúster 3 (Eficientes). En todo caso, dentro del grupo de estudiantes con mayores niveles de dificultad, se observa que aquellos que utilizan estrategias basadas exclusivamente en papel presentan valores particularmente elevados, alcanzando una media de 8,6 puntos sobre 10. Este patrón podría reflejar que ciertas metodologías más tradicionales no resultan igual de efectivas en todos

los perfiles, especialmente cuando se combinan con un esfuerzo elevado no necesariamente bien dirigido.

A su vez, el uso de estrategias mixtas como “mitad y mitad” también aparece asociado a niveles intermedios de dificultad, lo que sugiere que el tipo de soporte puede desempeñar un papel modulador en función de las características del estudiante. En definitiva, los resultados invitan a considerar que el impacto del soporte de estudio no es uniforme, y que su influencia está probablemente mediada por el perfil de aprendizaje del alumno.

En conjunto, estos resultados confirman que el perfil del estudiante es el principal determinante en la dificultad percibida, mientras que la estrategia de estudio actúa como modulador secundario cuyo impacto varía en función del tipo de alumno. La influencia del soporte de estudio, por tanto, no puede analizarse de forma aislada, sino que debe interpretarse dentro del marco más amplio del perfil de aprendizaje del estudiante.

Árbol de regresión para el rendimiento

En un segundo modelo, se analizó el rendimiento en matemáticas tomando como variables explicativas las mismas empleadas en el apartado anterior: el Cluster de pertenencia del estudiante y la Estrategia_de_estudio. El árbol de regresión fue generado también mediante la función `rpart()`, bajo el método "anova" y con los mismos parámetros de ajuste ($cp = 0.015$, $minsplit = 20$, $maxdepth = 4$). Al igual que en el caso anterior, esta combinación de parámetros fue escogida tras diversas iteraciones, ya que permitía extraer una estructura comprensible y relevante desde el punto de vista analítico.

La Figura 4.3 muestra el árbol resultante. El nodo raíz agrupa al total de estudiantes de la muestra ($n = 151$), con una media general de rendimiento declarada de 6,8 puntos sobre 10.

La primera división del árbol se realiza en función del perfil del estudiante. Se separan, por un lado, los clústeres 1 y 2 (Esforzados y Memorísticos) y, por otro, el clúster 3 (Eficientes). Este último, formado por 34 estudiantes (23% del total), presenta el rendimiento medio más alto del modelo: 7,6 puntos, lo que refuerza los resultados obtenidos en los análisis anteriores.

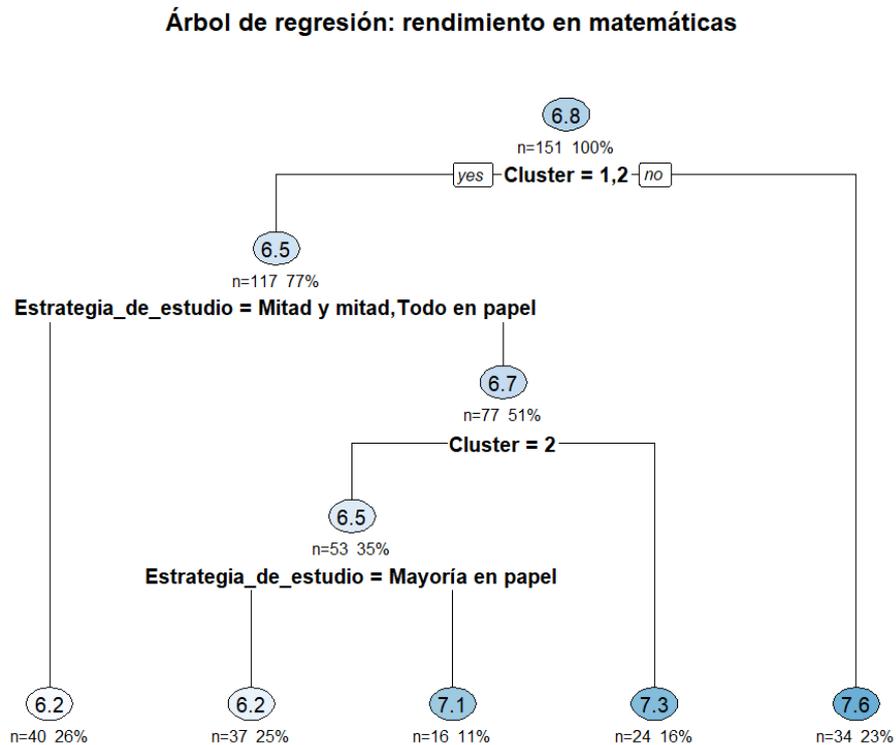
Dentro del grupo formado por los clústeres 1 y 2 ($n = 117$), el árbol introduce una segunda división basada en la estrategia de estudio. En concreto, se distinguen los estudiantes que utilizan estrategias como “mitad y mitad” o “todo en papel” ($n = 77$), quienes presentan una media de rendimiento de 6,2 puntos, frente al resto de estudiantes de estos clústeres que usan otras estrategias, con una media ligeramente superior (6,7 puntos).

Este grupo intermedio ($n = 77$) se divide a su vez en función del clúster al que pertenecen. Los estudiantes del clúster 1 (Esforzados) muestran un rendimiento medio de 7,3 puntos, mientras que el resto de estudiantes de ese subgrupo, pertenecientes al clúster 1 (Esforzados), se subdividen de nuevo según la estrategia de estudio.

Así, en el caso de los estudiantes del clúster 2 que utilizan la estrategia “mayoría en papel”, el rendimiento medio asciende a 6,2 puntos ($n = 37$), mientras que aquellos que emplean el resto de las estrategias obtienen un rendimiento más alto (7,1 puntos, $n = 16$).

Figura 4.3. Árbol de regresión: rendimiento en matemáticas.

Fuente: elaboración propia a partir de los resultados del modelo en R.



Este segundo modelo de árbol de regresión confirma, al igual que el anterior, la importancia del perfil del estudiante como principal variable explicativa del rendimiento en matemáticas. Los estudiantes clasificados como Eficientes (clúster 3) obtienen los mejores resultados, con una media de 7,6 puntos, consolidando su posición como el grupo más exitoso a nivel académico.

Entre los estudiantes de los clústeres 1 y 2 (Esforzados y Memorísticos), el rendimiento medio es inferior y se ve modulado por la estrategia de estudio utilizada. En concreto, aquellos que emplean estrategias como “mitad y mitad” o “todo en papel” presentan el menor rendimiento dentro de este grupo (media de 6,2 puntos), lo que podría estar indicando una

menor eficacia de estas estrategias en contextos donde ya existe cierta desventaja estructural en el perfil de aprendizaje.

Además, dentro de este subgrupo menos eficiente, el modelo revela diferencias entre perfiles. Los estudiantes del clúster 2 (Memorísticos) que utilizan la estrategia “mayoría en papel” alcanzan una media de rendimiento de 6,2 puntos, mientras que quienes optan por otras estrategias presentan un rendimiento superior (7,1 puntos). Este patrón sugiere que, en perfiles menos efectivos, la elección del soporte de estudio puede tener un impacto considerable en el rendimiento.

En resumen, el árbol permite observar que el rendimiento en matemáticas depende tanto del perfil general del estudiante como del tipo de estrategia de estudio empleada. Si bien los estudiantes más eficientes logran buenos resultados independientemente del método utilizado, los perfiles menos eficaces parecen beneficiarse de enfoques más modernos o digitales, mientras que el uso intensivo del papel se asocia, en términos generales, a peores resultados en estos grupos.

Conclusiones

Este trabajo ha permitido profundizar en los factores que influyen en el rendimiento académico y la dificultad percibida al estudiar matemáticas entre estudiantes de grados no STEM. Mediante una combinación de análisis descriptivo, técnicas de segmentación y modelos predictivos, se han identificado distintos perfiles de estudiantes y se han analizado sus implicaciones educativas.

La segmentación mediante análisis de clústeres reveló tres perfiles bien diferenciados: Esforzados, Memorísticos y Eficientes. Los Esforzados dedican muchas horas al estudio con

escaso uso de la memoria, los Memorísticos emplean intensivamente la memoria con una dedicación alta-moderada, y los Eficientes se caracterizan por dedicar poco tiempo y memorizar poco. Este último grupo, a pesar de su bajo nivel de esfuerzo percibido, obtiene los mejores resultados académicos y presenta los niveles más bajos de dificultad. Este hallazgo resulta especialmente relevante, pues evidencia que el rendimiento en matemáticas no está necesariamente vinculado al tiempo invertido, sino a la eficiencia, la calidad de las estrategias empleadas y, probablemente, al nivel previo en bachillerato.

Los análisis estadísticos mostraron que existen diferencias significativas entre los clústeres tanto en el rendimiento como en la dificultad percibida. En concreto, los estudiantes del clúster Eficientes superan significativamente a los Memorísticos en rendimiento, y muestran menor dificultad que los otros dos perfiles. Aunque entre Esforzados y Memorísticos no se hallaron diferencias significativas, los primeros sí parecen afrontar la asignatura con más esfuerzo pero sin una recompensa clara en cuanto a resultados académicos.

El análisis de la relación entre los clústeres y variables cualitativas como el género o la especialidad de bachillerato sugiere que, aunque los perfiles se definieron exclusivamente con variables cuantitativas, existen ciertos patrones asociados a estas características. En particular, se observó una sobrerrepresentación femenina en el grupo de Esforzados, así como una tendencia -aunque no significativa- a que los Eficientes provengan más frecuentemente de la rama de Ciencias.

Por último, los modelos predictivos mediante árboles de regresión han permitido afinar las conclusiones anteriores. En lo relativo a la dificultad percibida, el perfil del estudiante es el principal factor discriminante. El grupo de Eficientes se sitúa claramente por debajo del resto, independientemente del tipo de estrategia utilizada. Dentro de este grupo, incluso quienes utilizan estrategias muy distintas entre sí (como solo dispositivos o todo en papel) presentan niveles bajos de dificultad, lo que sugiere una alta capacidad de adaptación y autonomía. Por el

contrario, en los clústeres menos eficientes, el tipo de soporte sí influye: los estudiantes que usan papel en exclusiva, o que combinan soportes sin un patrón definido, perciben mayor dificultad, posiblemente por una falta de estructura metodológica o por un esfuerzo no optimizado.

En el modelo sobre rendimiento académico, se confirma de nuevo la relevancia del perfil del estudiante, siendo el clúster de Eficientes el que alcanza los mejores resultados (media de 7,6 puntos). Entre los estudiantes de los clústeres Esforzados y Memorísticos, el rendimiento es más variable y parece estar influido por la estrategia de estudio utilizada. En particular, se observa que aquellos que emplean estrategias como “mitad y mitad” o “todo en papel” tienden a obtener peores resultados (6,2 puntos), mientras que quienes optan por estrategias como el uso mayoritario de dispositivos electrónicos logran rendimientos más elevados (7,1 puntos). Esta diferencia es especialmente notable dentro del perfil Memorístico, lo que sugiere que, en estudiantes con estrategias cognitivas menos eficaces, la elección del soporte puede desempeñar un papel importante en el rendimiento académico.

En conjunto, este trabajo subraya que la eficiencia en el aprendizaje no depende exclusivamente del tiempo ni del esfuerzo percibido, sino de una combinación de factores que incluye el perfil cognitivo del estudiante, la coherencia en las estrategias utilizadas y la adecuación de los recursos empleados. Los resultados abren nuevas vías para mejorar el aprendizaje de las matemáticas en contextos no STEM, mediante la promoción de estrategias más personalizadas, estructuradas y adaptadas a las características reales del alumnado.

Evaluación de las hipótesis

Una vez realizado el análisis de clústeres, los contrastes estadísticos y los modelos predictivos, se procede a evaluar el cumplimiento de las hipótesis formuladas al inicio del trabajo:

Hipótesis 1 (H1): *Existen perfiles diferenciados de estudiantes en función del uso de la memoria y el tiempo dedicado al estudio de matemáticas.*

Cumplida. El análisis de clústeres permitió identificar tres perfiles diferenciados de estudiantes: Esforzados, Memorísticos y Eficientes. Estos grupos se caracterizan por patrones distintos de uso de la memoria y tiempo de estudio, lo que confirma la existencia de segmentación en la muestra en base a estas variables.

Hipótesis 2 (H2): *El perfil de estudiante está relacionado con el rendimiento académico en matemáticas.*

Cumplida. Los resultados del análisis de varianza (ANOVA) y el árbol de regresión para rendimiento mostraron diferencias significativas entre los clústeres. En concreto, los estudiantes del clúster Eficientes presentaron el mejor rendimiento medio, mientras que los Memorísticos obtuvieron los peores resultados. Esto sugiere una clara asociación entre el perfil de estudio y el rendimiento académico.

Hipótesis 3 (H3): *El perfil de estudiante está relacionado con la dificultad percibida en el estudio de matemáticas.*

Cumplida. De forma similar a la hipótesis anterior, se encontraron diferencias significativas en los niveles de dificultad percibida según el perfil de estudiante. Los Eficientes perciben menor dificultad, mientras que los Esforzados y Memorísticos muestran niveles más elevados. Esta relación también se reflejó en el modelo de árbol de regresión, donde el perfil fue la primera variable discriminante.

Hipótesis 4 (H4): *La estrategia de estudio utilizada (soporte digital o papel) influye en el rendimiento académico y la dificultad percibida.*

Cumplida parcialmente. Los modelos de árboles de regresión indicaron que la estrategia de estudio tiene un papel relevante, pero secundario. En el caso de la dificultad percibida, se observaron diferencias asociadas al tipo de soporte. Sin embargo, esta influencia fue más limitada en el rendimiento académico. Por tanto, aunque el soporte tiene cierta influencia, su impacto parece estar mediado por el perfil del estudiante y no es igual de determinante en todos los casos.

Declaración respecto al uso de Chat GPT u otras herramientas de IAG

Por la presente, yo, Amalia Hernández García, estudiante de 5º E3 Analytics de la Universidad Pontificia Comillas al presentar mi Trabajo Fin de Grado titulado “Estrategias de estudio en matemáticas de grados no STEM”, declaro que he utilizado la herramienta de Inteligencia Artificial Generativa ChatGPT u otras similares de IAG de código sólo en el contexto de las actividades descritas a continuación:

1. **Brainstorming de ideas de investigación:** utilizado para idear y esbozar posibles áreas de investigación.
2. **Referencias:** usado juntamente con otras herramientas, como Science, para identificar referencias preliminares que luego he contrastado y validado.
3. **Metodólogo:** para descubrir métodos aplicables a problemas específicos de investigación.
4. **Interpretador de código:** para realizar análisis de datos preliminares.
5. **Constructor de plantillas:** para diseñar formatos específicos para secciones del trabajo.
6. **Corrector de estilo literario y de lenguaje:** para mejorar la calidad lingüística y estilística del texto.
7. **Sintetizador y divulgador de libros complicados:** para resumir y comprender literatura compleja.
8. **Creación de imágenes:** para el desarrollo del Graphical Abstract

Afirmo que toda la información y contenido presentados en este trabajo son producto de mi investigación y esfuerzo individual, excepto donde se ha indicado lo contrario y se han dado los créditos correspondientes (he incluido las referencias adecuadas en el TFG y he explicitado para que se ha usado ChatGPT u otras herramientas similares). Soy consciente de las implicaciones académicas y éticas de presentar un trabajo no original y acepto las consecuencias de cualquier violación a esta declaración.

Referencias

- Alarcón Montiel, E. (2019). Elección de carrera: motivos, procesos e influencias y sus efectos en la experiencia estudiantil de jóvenes universitarios de alto rendimiento académico. *REncuentro. Análisis de Problemas Universitarios*, 30(77), 53-74.
- Armas Real, D. A. (2024). El impacto de las tecnologías digitales en el aprendizaje de Matemáticas y Estadística: The impact of digital technologies on the learning of Mathematics and Statistics. *Revista Científica Multidisciplinar G-nerando*, 5(2).
- Arroyo Barrigüete, J. L., Carabías López, S., Curto González, T., & Borrás Palá, F. (2020). Matemáticas en el doble grado ADE-Derecho: un análisis cuantitativo de las estrategias de estudio. *Bordón: Revista de pedagogía*, 72(4), 27-42.
- Arroyo-Barrigüete, J. L., Carabias-López, S., Hernández Estrada, A., & Segura Maroto, M. (2023). Efecto de la especialidad en bachillerato en el rendimiento matemático en la universidad: Un estudio comparativo en grados de Administración de Empresas. *Revista de Educación*, 402, 115-140.
- Biggs, J. B. (1987). *Student approaches to learning and studying*. Research Monograph. Australian Council for Educational Research Ltd.
- Biggs, J. B. (1993a). From theory to practice: A cognitive systems approach. *Higher Education Research and Development*, 12(1), 73-85.
- Biggs, J. (1993b). What do inventories of students' learning processes really measure? A theoretical review and clarification. *British Journal of Educational Psychology*, 63(1), 3-19.
- Calle Chacón, L. P., García-Herrera, D. G., Ochoa-Encalada, S. C., & Erazo-Álvarez, J. C. (2020). La motivación en el aprendizaje de la matemática: Perspectiva de estudiantes de básica superior. *Revista Arbitrada Interdisciplinaria KOINONIA*, 5(1), 488-502.
- Carbonero Martín, M. Á., & Navarro Zavala, J. C. (2006). Entrenamiento de alumnos de Educación Superior en estrategias de aprendizaje en matemáticas. *Psicothema*, 18(3), 348-352.
- Cárdenas Lizarazo, J. A., Gómez del Amo, R., & Caballero Carrasco, A. (2011). Algunas diferencias entre la práctica y la teoría al evaluar la resolución de problemas en matemáticas. *Revista EMA*, 14(3), 53-65.
- Centro Regional para el Fomento del Libro en América Latina y el Caribe (CERLALC). (2020). Pantalla vs. Papel: ¿Hacia dónde va la lectura? CERLALC/UNESCO. Recuperado el 27 de febrero de 2025, de https://cerlalc.org/wp-content/uploads/2020/04/Cerlalc_Publicaciones_Dosier_Pantalla_vs_Papel_042020.pdf
- Dunkin, M. J., & Biddle, B. J. (1974). *The study of teaching*. Holt, Rinehart & Winston.
- Gallego Gil, D. J., & Nevot Luna, A. (2008). Los estilos de aprendizaje y la enseñanza de las matemáticas. *Revista Complutense de educación*, 19(1), 95-112.
- Gómez Chacón, I. M. (2009). Actitudes matemáticas: propuestas para la transición del bachillerato a la universidad. *Educación matemática*, 21(3), 5-32.
- Hernández Álvarez, L. (2016). *Estudio y análisis de los conceptos y técnicas matemáticas utilizadas en el grado de ADE*. [Trabajo Final de Grado, Universidad de Jaén] Colección de recursos educativos abiertos. <https://crea.ujaen.es/items/620477a6-259b-4d54-9d68-ea789412f8ae>.
- Hernández Suárez, C. A., Gamboa Suárez, A. A., & Prada Núñez, R. (2021). Asociación entre memoria y rendimiento en matemáticas: un estudio correlacional. *Revista Boletín Redipe*, 10(4), 190-201.

Hurtado de la Peña, M., & López Esteban, C. (2017). La influencia del uso del tiempo en el rendimiento académico en matemáticas. *Épsilon: Revista de Educación Matemática*, 34(95), 49-68.

Morales, A. F., & Cuevas Valencia, R. E. (2022). Uso de las TIC en el aprendizaje de las matemáticas en el nivel superior. *Revista Iberoamericana para la Investigación y el Desarrollo Educativo*, 12(23).

Northern Illinois University. (s.f.). Las matemáticas en las carreras profesionales y trabajos. Recuperado el 27 de febrero de 2025, de <https://www.niu.edu/mathmatters/sp/careers-jobs.shtml>

Organización de las Naciones Unidas para la Educación, la Ciencia y la Cultura (UNESCO). (2015). ODS 4: Educación de calidad.

Pérez Gómez, R., Ruiz Higuera, L., García Cruz, J. A., Callejo de la Vega, M. L., Burgués Flamarich, C., Torra Bitlloch, M., Alsina Catalá, C., & Hervás Asenjo, M. M. (2008). Competencia matemática e interpretación de la realidad. Instituto Superior de Formación del Profesorado.

Prat Moratonas, M., & Sellas Ayats, I. (2021). STEAM en Educación Infantil: Una visión desde las matemáticas. *Didacticae*, 10, 8-20.

Rosario, P., Núñez, J. C., González-Pienda, J. A., Almeida, L., Soares, S., & Rubio, M. (2005). El aprendizaje escolar examinado desde la perspectiva del «Modelo 3P» de J. Biggs. *Psicothema*, 17(1), 20-30.

Tejedor Tejedor, F.J. (2003). Poder explicativo de algunos determinantes del rendimiento en los estudios universitarios. *Revista Española de Pedagogía*, 224, 5-32.

Valtierra Lacalle, A. (2015). Renacimiento y competencia matemática. *En La Edad Moderna en Educación Secundaria* (pp. 181-192). Universidad de Murcia.

Vásquez Córdova, A. S. (2021). Estrategias de aprendizaje de estudiantes universitarios como predictores de su rendimiento académico. *Revista complutense de Educación*, 32(2).

Anexos

Anexo 1: encuesta

Encuesta sobre estrategias de estudio de materias STEM en grados no STEM

Esta encuesta forma parte de un proyecto de investigación dirigido por el profesor Jose Luis Arroyo en el marco de la Cátedra Santalucía de *Analytics for Education* y consta de 4 trabajos fin de grado diferentes, cada uno evaluando un tipo de materia. Agradecemos tu participación. Por favor, responde con la máxima sinceridad, sabiendo que las respuestas son anónimas y serán usada únicamente a nivel agregado y con una finalidad de investigación académica.

Fecha: _____

Grado (señala la opción que corresponda): E2 + Analytics / E3 + Analytics / E6 + Analytics

Curso (señala la opción que corresponda): 3º / 4º / 5º

Soy mayor de edad y acepto que mis respuestas, tratadas de forma absolutamente anónima, sean empleadas con la finalidad de investigación académica

- Sí
- No

En asignaturas de **Matemáticas** del doble grado (Álgebra y Cálculo) consideras que no tuviste que aprender nada de **memoria** (marca el 0) o lo aprendiste todo de memoria (marca el 10). Selecciona lo que corresponda.

0 1 2 3 4 5 6 7 8 9 10

En asignaturas de **Matemáticas** del doble grado (Álgebra y Cálculo) ¿aproximadamente qué **porcentaje del tiempo de estudio** dedicaste a estudiar **teoría** y que porcentaje a practicar **problemas**? Selecciona lo que corresponda.

- 0% teoría – 100% problemas (1)
- 20% teoría – 80% problemas (2)
- 40% teoría – 60% problemas (3)
- 60% teoría – 40% problemas (4)
- 80% teoría – 20% problemas (5)
- 100% teoría – 0% problemas (6)

Comparado con otras asignaturas de tu doble grado (de todas, no solo las de Analytics) ¿Cuánto **tiempo** dedicaste a estudiar las asignaturas de **Matemáticas** (Álgebra y Cálculo)? Valóralo en una escala del 0 (mucho menos) al 10 (mucho más).

0 1 2 3 4 5 6 7 8 9 10

En asignaturas de **Matemáticas** del doble grado (Álgebra y Cálculo), cuando estudiabas la asignatura ¿lo hacías usando dispositivos electrónicos o con papel y bolígrafo? Selecciona lo que corresponda.

- Solo uso dispositivos electrónicos (ordenador, tablet, etc.) (1)
- La mayoría del estudio lo hago con dispositivos electrónicos (ordenador, tablet, etc.) (2)
- La mitad en papel y la mitad con dispositivos electrónicos (3)
- La mayoría del estudio lo hago en papel (4)
- Todo el estudio lo hago en papel (5)

¿Cuál consideras que es el grado de **dificultad** de las asignaturas de **Matemáticas** (Álgebra y Cálculo)? Valóralo en una escala del 0 (extremadamente fácil) al 10 (extremadamente difícil).

0 1 2 3 4 5 6 7 8 9 10

Comparado con la **dificultad que esperabas** ¿Cuál consideras que es el grado de dificultad de las asignaturas de **Matemáticas** (Álgebra y Cálculo)? Valóralo en una escala del 0 (extremadamente más fácil de lo que esperaba al comenzar la asignatura) al 10 (extremadamente más difícil de lo que esperaba al comenzar la asignatura).

0 1 2 3 4 5 6 7 8 9 10

Centrándonos solo en la parte de **programación** en Matlab, ¿Cuál consideras que es el grado de dificultad de LA PARTE DE PROGRAMACIÓN de las asignaturas de **Matemáticas** (Álgebra y Cálculo)? Valóralo en una escala del 0 (extremadamente fácil) al 10 (extremadamente difícil).

0 1 2 3 4 5 6 7 8 9 10

¿Cuál consideras que ha sido tu **rendimiento** (nota obtenida) en las asignaturas de **Matemáticas** (Álgebra y Cálculo)? Valóralo en una escala del 0 (muy por debajo de la media de mi clase) al 10 (muy por encima de la media de mi clase).

0 1 2 3 4 5 6 7 8 9 10

¿Qué **especialidad cursaste en bachillerato**?

Ciencias Ciencias Sociales Otras _____

¿Cuál es tu **género**?

Hombre Mujer Otros _____

¿Qué nota obtuviste en la **EvAU** (fase general, escala del 0 al 10)? _____

¿Por qué elegiste un doble grado que incluía Analytics? Puedes marcar más de una:

- Me gustan las matemáticas y/o la programación
 - Se me dan bien las matemáticas y/o la programación
 - Buenas salidas profesionales
 - No era mi primera opción, pero no entré en la titulación que quería
 - Influencia de padres y/o amigos
 - Está de moda
 - Tenía una nota muy alta en EvAU y quería aprovecharla
 - Otras (especificar):
-