
Patrones de desempeño académico: Un modelo para educación básica y media haciendo uso de minería de datos

Academic performance patterns: A model for basic and secondary education using data mining

Andrés Eduardo Blanco Niño.^a
andresblancon@usantotomas.edu.co

Wilmer Darío Pineda.^b
wilmarpineda@usta.edu.co

Resumen

En la actualidad, el uso de herramientas tecnológicas para realizar análisis del desempeño académico de los estudiantes se ha convertido en una necesidad fundamental para la toma de decisiones informadas dentro del sistema educativo, especialmente en el contexto posterior a la crisis del COVID-19. La pandemia reveló la importancia de entender no solo los resultados académicos, sino también sus habilidades fundamentales y los factores socioemocionales que influyen en el aprendizaje de los estudiantes. En este sentido, la presente investigación se centra en identificar los patrones de desempeño académico de los estudiantes del colegio Bilingüe José Max León en el área de matemáticas, prestando especial atención a los factores que afectan su rendimiento.

El análisis de los datos sobre el rendimiento académico en matemáticas proporcionará información valiosa que permitirá al departamento del área optimizar sus planes de acción, matrices curriculares y prácticas pedagógicas. Asimismo, será de gran utilidad para las direcciones de sección y el departamento de psicología, quienes podrán conformar grupos de apoyo y diseñar estrategias de prevención que atiendan las necesidades específicas de los estudiantes.

Palabras clave: Minería de datos, rendimiento académico, pruebas estandarizadas, patrones de desempeño académico.

1. Introducción

La Constitución Política de Colombia de 1991, en sus artículos 67 y 68, establece que la educación es un derecho fundamental y un servicio público que el Estado está obligado a garantizar. Asimismo, confiere al Estado la responsabilidad de supervisar y velar por la calidad y el cumplimiento de este derecho. Con el objetivo de evaluar la calidad y eficiencia de las instituciones educativas, el Ministerio de Educación Nacional (MEN) ha implementado diversas estrategias de evaluación que permiten monitorear tanto a instituciones públicas como privadas, además de desarrollar iniciativas para mejorar la calidad de la educación en el país.

El Colegio Bilingüe José Max León es una institución educativa privada que se esfuerza por alcanzar altos estándares de calidad en su formación, alineándose con su visión institucional. Para respaldar esta visión, el colegio ha obtenido una acreditación de nivel 4 en el marco del modelo EFQM (European Foundation for Quality Management), un sistema de certificación que ayuda a las organizaciones a gestionar el cambio y mejorar su rendimiento. Esta certificación es administrada por la Fundación Colombia Excelente.

En consonancia con su visión, el colegio ha identificado la necesidad de desarrollar una política de gestión de datos que le permita tomar decisiones más informadas en aspectos curriculares y administrativos. Esta política busca aprovechar la información generada, tanto interna como externamente, para mejorar

^aEstudiante

^bDirector proyecto de grado

la toma de decisiones. Entre los tipos de datos considerados se incluyeron los resultados académicos en las pruebas evaluar para avanzar, que surgieron como parte de la estrategia del ministerio de mitigar el impacto del COVID 19, así como el seguimiento emocional mediante la herramienta Habilmind, que atiende las necesidades socioemocionales de los estudiantes, así como la valoración de sus habilidades fundamentales. También se utilizaron los cuestionarios auxiliares de las pruebas Evaluar para Avanzar, que permitieron obtener información relevante sobre las habilidades y condiciones de los estudiantes, facilitando una comprensión más profunda de su contexto y necesidades específicas. Finalmente, se crearon perfiles de rendimiento y patrones de desempeño que facilitarán la toma de decisiones personalizadas y la adaptación de estrategias educativas.

Esta iniciativa es de gran relevancia para las instituciones educativas, ya que establece un almacén de datos que proporciona información valiosa para la toma de decisiones fundamentadas. Al vincular datos académicos, emocionales, familiares y sociodemográficos, el colegio puede desarrollar estrategias educativas más efectivas y centradas en las necesidades de sus estudiantes, contribuyendo así a la mejora continua de la calidad educativa en el país.

En el contexto actual, las instituciones educativas buscan constantemente mejorar sus servicios a través de la implementación de estándares de calidad en sus procesos de enseñanza-aprendizaje. Surge, entonces, la pregunta fundamental: ¿Es posible generar patrones de desempeño académico que permitan caracterizar a la población estudiantil por cohortes y, a partir de esta caracterización, desarrollar planes de mejora tanto en el ámbito curricular como administrativo, con el propósito de elevar los niveles de rendimiento académico de los estudiantes?

2. Marco teórico y revisión de literatura

2.1. Minería de Datos: Conceptos y Aplicaciones

Ante el creciente volumen y diversidad de datos disponibles, ha surgido la necesidad de desarrollar métodos eficientes para analizar grandes volúmenes de información, lo que hace impracticable el procesamiento manual. Este desafío ha originado un campo de estudio conocido como **minería de datos**.

Según Witten y Frank (2000), la minería de datos consiste en extraer conocimiento útil y comprensible, previamente desconocido, a partir de grandes volúmenes de datos almacenados en distintos formatos. Orallo (2004) amplía esta definición, describiendo la minería de datos como el proceso de convertir datos en conocimiento.

2.1.1. Clasificación de los Datos

La minería de datos puede aplicarse a distintos tipos de información:

- **Datos estructurados:** provienen de bases de datos relacionales y otras estructuras (por ejemplo, bases de datos espaciales, temporales, textuales, multimedia).
- **Datos no estructurados:** incluyen información obtenida de la web y otros repositorios de documentos (Orallo, 2004).

2.1.2. Aplicaciones de la Minería de Datos en Educación

Durán y Costaguta (2007) propusieron un modelo para adaptar los estilos de enseñanza a los estilos de aprendizaje de los estudiantes mediante tareas descriptivas de minería de datos. Utilizaron el software WEKA, aplicando el algoritmo *FarthestFirst* para detectar estilos de aprendizaje y configurar dos *clusters* principales.

2.2. Rendimiento Académico: Análisis y Factores Determinantes

El rendimiento académico ha sido estudiado con el propósito de mejorar la calidad educativa y satisfacer las necesidades de formación tanto en niveles básicos como superiores. Navarro (2003) define el

rendimiento académico como una red compleja de procesos cognitivos que afectan los resultados en el aprendizaje, sugiriendo también la necesidad de revisar métodos de evaluación y currículos.

Martínez (2015) desarrolló un modelo para clasificar perfiles estudiantiles en programas superiores usando **árboles de decisión**. Los árboles de decisión asignan una clase predefinida a ejemplos basados en sus atributos, generando un modelo de clasificación que evalúa su precisión con datos de prueba (Timarán Pereira et al., 2015).

2.2.1. Matemática en Árboles de Decisión

La construcción de árboles de decisión implica el cálculo de la **entropía** y la **ganancia de información** de los atributos. La **entropía** $I(T)$ mide la incertidumbre en un sistema, y se calcula como:

$$I(T) = - \sum_{i=1}^m p_i \log_2(p_i)$$

Donde:

- $I(T)$: entropía del conjunto T , con s ejemplos y m clases C_i .
- $p_i = \frac{s_i}{s}$: probabilidad de que un ejemplo pertenezca a la clase C_i .

La **ganancia de información** $G(T, A)$ resultante del particionamiento del conjunto T usando el atributo A se calcula como:

$$G(T, A) = I(T) - E(A)$$

Aquí, $E(A)$ es la entropía después de particionar T en subconjuntos S_j , y se define como:

$$E(A) = \sum_{j=1}^n \frac{|S_j|}{|T|} I(S_j)$$

2.2.2. Índice de Impureza de Gini

Para los árboles de clasificación, se utiliza el **índice de impureza de Gini** para evaluar la pureza de los nodos. La impureza de Gini de un nodo con K clases es:

$$Gini(p) = 1 - \sum_{i=1}^K p_i^2$$

Donde p_i es la proporción de ejemplos de la clase i en el nodo. Este índice ayuda a seleccionar los predictores que minimizan la impureza en cada división.

2.3. Técnicas de Ensamble: Bagging y Bosques Aleatorios

2.3.1. Bagging (Bootstrap Aggregating)

El método *bootstrap*, o bagging, es útil para reducir la varianza en modelos de árboles de decisión. El bagging consiste en crear múltiples conjuntos de entrenamiento mediante remuestreo con reemplazo, entrenar un modelo en cada conjunto, y promediar las predicciones:

$$\hat{f}_{bag}(x) = \frac{1}{B} \sum_{b=1}^B \hat{f}_b^*(x)$$

2.3.2. Bosques Aleatorios

Los **bosques aleatorios** son una extensión del método de bagging, diseñados para mejorar la precisión de los modelos de árboles de decisión al reducir la correlación entre los árboles en el ensamble. El bagging o *bootstrap aggregating* promedia las predicciones de múltiples árboles construidos a partir de muestras de entrenamiento generadas mediante remuestreo con reemplazo. Sin embargo, cuando algunos predictores son particularmente fuertes en su capacidad para predecir el resultado, los árboles tienden a ser similares entre sí, afectando la independencia entre ellos y limitando la reducción de varianza en el modelo final.

Para abordar este problema, los bosques aleatorios introducen una selección aleatoria de predictores en cada división del árbol. Este enfoque ayuda a que los árboles en el ensamble tengan estructuras más variadas y, por lo tanto, predicciones menos correlacionadas, mejorando así la estabilidad del modelo final.

2.3.2.1 Selección de Predictores en Bosques Aleatorios En los bosques aleatorios, cada árbol se construye de forma que en cada nodo solo se considere un subconjunto aleatorio de los p predictores disponibles. Si m es el número de predictores seleccionados aleatoriamente en cada nodo, entonces m se establece generalmente como $m = \sqrt{p}$ para problemas de clasificación y $m = \frac{p}{3}$ para problemas de regresión. Esta selección aleatoria de predictores en cada división permite que los árboles individuales sean menos similares entre sí, lo que mejora la precisión del ensamble.

La ventaja de esta técnica es que limita el uso de predictores dominantes en las divisiones iniciales de los árboles, lo que favorece que otros predictores también contribuyan a las decisiones del modelo. De este modo, los árboles son menos correlacionados, y el promedio de sus predicciones es más confiable.

2.3.2.2 Algoritmo de Bosques Aleatorios El algoritmo de los bosques aleatorios se puede resumir en los siguientes pasos:

1. Para cada árbol b en el ensamble (donde $b = 1, \dots, B$):

- Se genera una muestra bootstrap del conjunto de datos original.
- A partir de esta muestra, se construye un árbol de decisión. En cada nodo:
 - Se selecciona aleatoriamente un subconjunto de m predictores.
 - Se elige el predictor que mejor divide los datos en función de una métrica como la ganancia de información o el índice de Gini.

2. Cada árbol realiza una predicción individual, y el modelo final se obtiene tomando el promedio de las predicciones en el caso de regresión, o una votación mayoritaria en el caso de clasificación.

2.3.2.3 Ventajas de los Bosques Aleatorios Los bosques aleatorios presentan varias ventajas importantes:

- **Reducción de la varianza:** al utilizar múltiples árboles con menor correlación, el promedio de sus predicciones tiene menor varianza que un solo árbol.
- **Robustez ante el sobreajuste:** los bosques aleatorios son menos propensos a sobreajustarse al conjunto de entrenamiento, ya que cada árbol se entrena en una muestra diferente del conjunto de datos y utiliza solo una parte de los predictores en cada división.
- **Manejo de datos de alta dimensionalidad:** los bosques aleatorios pueden manejar conjuntos de datos con muchos predictores sin problemas de sobreajuste, especialmente cuando se utiliza un valor reducido de m para seleccionar predictores en cada nodo.

2.3.2.4 Importancia de las Variables en Bosques Aleatorios Además de proporcionar predicciones precisas, los bosques aleatorios ofrecen una medida de importancia de las variables que permite

identificar los predictores más relevantes. Esto se calcula a partir de la disminución promedio en el índice de impureza de Gini o la ganancia de información en cada árbol.

Dado que cada predictor se evalúa varias veces en distintas partes del ensamble, la importancia de una variable se determina promediando el impacto que tiene en la calidad de las divisiones a través de todos los árboles. Esto es útil en contextos donde es necesario interpretar el modelo y comprender qué variables contribuyen más al resultado.

2.4. Boosting

El **boosting** es un método de aprendizaje secuencial que mejora las predicciones combinando múltiples modelos débiles (en este caso, árboles de decisión) en un modelo fuerte. En el contexto de árboles de clasificación, boosting construye los árboles de manera secuencial, ajustando cada árbol a los residuos del modelo construido hasta ese momento. En cada iteración b , el árbol ajustado $\hat{f}_b(x)$ intenta corregir los errores del modelo acumulado previamente.

La actualización de la función de predicción en cada iteración se realiza de la siguiente manera:

$$\hat{f}(x) \leftarrow \hat{f}(x) + \lambda \hat{f}_b(x)$$

Donde:

- λ : es el parámetro de reducción (*shrinkage*), que controla la tasa de aprendizaje, es decir, cuánto de la predicción del árbol actual se incorpora al modelo final. Valores pequeños de λ conducen a un aprendizaje más lento pero suelen mejorar la precisión.
- $\hat{f}_b(x)$: es el árbol ajustado en la iteración b , entrenado para reducir los residuos actuales.

Después de B iteraciones, el modelo final se representa como:

$$\hat{f}(x) = \sum_{b=1}^B \lambda \hat{f}_b(x)$$

2.4.1. Parámetros Clave de Boosting

El método de boosting se define por varios hiperparámetros importantes que controlan la complejidad y el rendimiento del modelo. Entre ellos destacan:

1. **Número de árboles B** : el número total de iteraciones o árboles en el modelo final. Un número grande de árboles puede mejorar la precisión, pero aumenta el riesgo de sobreajuste si λ no es suficientemente pequeño.
2. **Shrinkage λ** : también conocido como la tasa de aprendizaje, regula la contribución de cada árbol al modelo final. Valores típicos están en el rango de 0.01 a 0.1. Un λ pequeño requiere un mayor número de árboles B para lograr buenos resultados, pero mejora la generalización del modelo.
3. **Profundidad d de los árboles**: controla la complejidad de cada árbol individual. En boosting, se prefieren árboles poco profundos (por ejemplo, con $d = 1$, también llamados *stumps*), ya que esto permite que el modelo combine muchas predicciones simples en lugar de depender de árboles complejos.

2.4.2. Intuición del Proceso de Boosting

1. Inicialmente, se comienza con una predicción constante (por ejemplo, el promedio de la variable objetivo en problemas de regresión o una clase base en clasificación).
2. En cada iteración b , se entrena un árbol de decisión para predecir los residuos (errores) del modelo actual.
3. La predicción del árbol ajustado

en cada paso se incorpora al modelo con un peso λ , lo cual permite ajustar gradualmente el modelo en lugar de hacer cambios abruptos. 4. Al final, el modelo final combina todas las predicciones ajustadas, formando una estimación que captura las tendencias principales del conjunto de datos mientras evita el sobreajuste.

2.4.3. Ventajas y Limitaciones

El método de boosting ofrece varias ventajas, como la mejora de la precisión y la reducción del sesgo. Sin embargo, también puede ser propenso al sobreajuste si se utilizan demasiados árboles o si λ es demasiado grande. Además, boosting puede ser más lento en comparación con otros métodos debido a su naturaleza secuencial.

2.5. Método de Selección de Variables Lasso

El *Least Absolute Shrinkage and Selection Operator* (Lasso) es un método de regularización y selección de variables que busca mejorar la interpretabilidad del modelo y manejar situaciones en las que el número de predictores p es grande. A diferencia de la regresión Ridge, que aplica una penalización en la suma de los cuadrados de los coeficientes, Lasso aplica una penalización ℓ_1 , es decir, la suma de los valores absolutos de los coeficientes. Esta penalización tiene la ventaja de que permite que algunos coeficientes sean exactamente iguales a cero, lo que facilita la selección de variables.

2.5.1. Función Objetivo de Lasso

La estimación de los coeficientes en el modelo Lasso se obtiene minimizando la siguiente función objetivo:

$$\sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 + \lambda \sum_{j=1}^p |\beta_j|$$

donde:

- y_i : Variable respuesta para la observación i .
- x_{ij} : Valor del predictor j en la observación i .
- β_j : Coeficientes del modelo.
- λ : Parámetro de regularización que controla el nivel de penalización sobre los coeficientes.

2.5.2. Propiedades del Método Lasso

El término de penalización ℓ_1 , dado por $\sum_{j=1}^p |\beta_j|$, induce esparsidad en el modelo, lo que significa que, para valores suficientemente grandes de λ , algunos coeficientes β_j se vuelven exactamente cero. Esta propiedad permite la selección de un subconjunto de predictores relevantes, generando modelos más interpretables y manejables.

2.5.3. Formulación Alternativa

La formulación de Lasso puede expresarse como un problema de minimización sujeto a una restricción:

$$\min_{\beta} \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^p \beta_j x_{ij} \right)^2 \quad \text{sujeto a} \quad \sum_{j=1}^p |\beta_j| \leq s$$

donde s es un valor que determina el presupuesto de magnitud total de los coeficientes. Esta restricción limita el tamaño de los coeficientes, promoviendo la selección de variables en función de la penalización.

2.5.4. Ventajas de Lasso

Debido a la capacidad del método Lasso para reducir algunos coeficientes a cero, se obtiene un modelo *esparso*, que solo incluye las variables más importantes, mejorando la interpretabilidad y facilitando la implementación en contextos donde la simplicidad del modelo es crucial.

2.6. Aplicaciones en Educación y Resultados

Timarán Pereira et al. (2015) usaron árboles de decisión para identificar factores en el rendimiento académico de estudiantes universitarios en Colombia. Los resultados revelan la relevancia de la acreditación institucional y variables académicas en el rendimiento estudiantil. Otros estudios en el país han explorado el impacto de factores como el promedio acumulado y las pruebas Saber 11 en la deserción y éxito académico.

Este marco teórico sugiere que la minería de datos y técnicas de ensamble como bagging, bosques aleatorios y boosting pueden ser herramientas efectivas para comprender y mejorar el rendimiento académico, proveyendo información útil para decisiones curriculares y estrategias de apoyo.

3. Metodología

El tipo de estudio realizado fue explicativo, dado que se caracterizó a los estudiantes a partir de los patrones de desempeño académico identificados, así como su relación con los factores socioemocionales.

Para llevar a cabo esta investigación, se utilizó el proceso estándar de minería de datos conocido como Cross Industry Standard Process for Data Mining (CRISP-DM). Este proceso consta de seis etapas esenciales que se detallan en la figura 1.




Figura 1: La metodología CRISP-DM en ciencia de datos. Tomado de <https://www.example.com>

3.1. Comprensión del Problema

La evaluación pedagógica desempeña un papel fundamental en todas las instituciones educativas, ya que constituye una de las principales herramientas para la construcción de contenidos que enriquecen el conocimiento de los estudiantes. Este proceso contribuye a lograr una enseñanza y aprendizaje más eficaz a lo largo de los distintos grados académicos. A través de la evaluación, se identifican las fortalezas y debilidades de los estudiantes, lo que permite comprender las causas detrás de un rendimiento académico por debajo de lo esperado y, en consecuencia, personalizar el proceso de enseñanza y aprendizaje.

Más allá de lo académico, la evaluación también debe considerar el desarrollo socioemocional del estudiante, estrechamente vinculado con su desarrollo cognitivo. El seguimiento de este aspecto permite reconocer posibles dificultades en las relaciones interpersonales de los niños, niñas y adolescentes, contribuyendo así a prevenir situaciones de acoso escolar. En los últimos años, este aspecto ha adquirido una importancia creciente, especialmente debido al confinamiento impuesto por la pandemia de COVID-19, que puso de manifiesto la necesidad de prestar mayor atención al bienestar socioemocional.

En este contexto, las investigaciones de Durlak et al. (2011) sobre el aprendizaje social y emocional (SEL) cobran especial relevancia. Sus estudios demuestran que las intervenciones en SEL no solo mejoran el rendimiento académico en áreas como matemáticas y lectura, sino que también influyen positivamente en el desarrollo cognitivo al fortalecer habilidades como la atención, la memoria y el razonamiento. Además, Durlak et al. (2011) destacan la importancia de un clima de aula positivo para favorecer el aprendizaje socioemocional y cognitivo, ya que este ambiente permite a los estudiantes sentirse más seguros y motivados para explorar y aprender. Dentro de este marco, el desarrollo de habilidades de autorregulación, como la capacidad de controlar los impulsos, manejar el estrés y mantener la atención, se vuelve crucial para el éxito académico y el bienestar emocional.

El impacto de la pandemia en el aprendizaje, documentado en el informe de la UNESCO (2024), reafirma la importancia del SEL. Dicho informe revela que el área de matemáticas fue la más afectada, con un impacto particularmente significativo en las mujeres. El extenso cierre de los centros educativos en la región provocó una pérdida de aprendizaje considerable, estimada entre un 60 % y un 100 % de un año escolar en algunos casos. Esta situación exige implementar estrategias que aborden las necesidades socioemocionales de los estudiantes, junto con las académicas, para una recuperación integral.

En respuesta a esta situación, y con el objetivo de evaluar y fortalecer el componente socioemocional, se implementó en el colegio una herramienta psicosocial.

3.2. Introducción a la Base de Datos

La base de datos que se utilizó se compone de la información obtenida del directorio institucional, donde se encuentra información del estudiante, así como de las pruebas de evaluación de habilidades del programa Habilmind (Logros). Estas pruebas evalúan el desarrollo y los requisitos previos necesarios para adquirir habilidades clave de aprendizaje. Además, se incluye un screening de bienestar emocional, el cual es un análisis de las emociones más presentes ante una situación de malestar, el nivel de desarrollo de las habilidades resilientes y la presencia de alteraciones conductuales. La base de datos también integra los resultados de las pruebas de matemáticas de las pruebas “Evaluar para Avanzar” y los cuestionarios auxiliares de dichas pruebas, que son una estrategia del gobierno nacional para mejorar la calidad de la educación en Colombia. Se trata de una plataforma que ofrece a los docentes, directivos, instituciones y estudiantes herramientas para evaluar la calidad educativa y fortalecer los procesos de enseñanza.

3.2.1. Evaluación de habilidades

El Colegio Bilingüe José Max León ha implementado, en los grados cuarto a undécimo, el test de habilidades fundamentales a través del programa Logros. Este test es un diagnóstico focalizado en las habilidades fundamentales que condicionan los tres pilares del aprendizaje, las cuales se presentan en la tabla 1 (León, 2022).

Tabla 1: Descripción de las Dimensiones y Habilidades

Dimensión	Descripción	Habilidad
Razonamiento Verbal	Evalúa la capacidad del niño, niña y adolescente, a través del lenguaje oral o escrito.	1. Vocabulario 2. Lectura comprensiva básica 3. Seguimiento de información extensa
Razonamiento Matemático	Evalúa la actitud reflexiva y la lógica general que favorece el pensamiento analítico y la toma de decisiones.	1. Captación de hechos matemáticos 2. Juicio crítico y matemático 3. Solución a problemas matemáticos
Lectura Mecánica	Evalúa las habilidades que condicionan la lectura, herramienta básica para el aprendizaje a lo largo de la vida.	1. Capacidad visual 2. Discriminación visual 3. Lectura rápida y precisa

La escala de medición de cada una de las habilidades es la siguiente:

- **Verde:** Alumnos cuyo resultado entre 7 y 9 indica que han desarrollado la habilidad que se encuentra bajo análisis por encima de lo esperado, para asegurar el aprendizaje en el curso actual.
- **Amarillo:** Alumnos con resultado entre 4 y 6 refiere que han desarrollado la habilidad en el nivel esperado, para el nivel de exigencia del curso actual.
- **Rojo:** Alumnos con resultado entre 1 y 3 indica que el desarrollo de esa habilidad se encuentra por debajo de lo esperado, para afrontar el reto académico actual.

3.2.2. Evaluación de bienestar emocional

El screening de bienestar emocional se plantea como una herramienta clave que aportará al centro información clave acerca de los niveles de bienestar emocional de su alumnado para la prevención y detección de dificultades para poder intervenir dentro del centro educativo. Para ello, es fundamental implicar al equipo docente y trabajar de manera conjunta (León, 2022).

Esta evaluación tiene en cuenta 3 grupos de emociones, las cuales se describen a continuación:

A. Emociones causales

- **Miedo:** Es necesaria dado que permite la supervivencia y evita peligros.
- **Tristeza:** Se presenta ante la pérdida de algo o de alguien. Es una de las emociones más duraderas.
- **Ira:** Aparece cuando las cosas no suceden como nos gustaría y se cree que podría haber sido evitado si alguien lo hubiera tenido en cuenta y hubiera actuado de otra forma.
- **Ansiedad:** Surge ante la percepción de una amenaza y permite prepararse para enfrentarse a ella.

B. Factores de protección emocional

- **Expresividad emocional:** Capacidad para identificar la emoción experimentada, nombrarla y expresarla de manera equilibrada y respetuosa.
- **Pesimismo / Optimismo:** Sistema de creencias que filtra la manera en que se interpretan las situaciones vividas.
- **Autoestima:** Es la evaluación que hacemos de nosotros mismos y nuestra vida.

- **Motivación / Desmotivación:** Movimiento interno que nos orienta hacia la búsqueda de un satisfactor.
- **Sinceridad:** Capacidad de expresarse de manera libre sin fingir su emoción.

C. Manifestaciones conductuales

- **Alteraciones del sueño:** Mide la alteración del sueño que influirá en el descanso insuficiente.
- **Alteraciones en la alimentación:** Mide posibles alteraciones nutricionales relacionadas con la ingesta desequilibrada por exceso o defecto de calorías.
- **Agresividad / Disruptividad:** Mide la dificultad para gestionar la ira que se traduce en comportamiento agresivo, generando dificultad para relacionarse con el entorno.
- **Aislamiento social:** Mide la tendencia a la búsqueda de la soledad llevada a su extremo.
- **Abuso de pantallas:** Mide el nivel de riesgo de un uso abusivo de la tecnología.

Las emociones son necesarias para el correcto desarrollo del estudiante, ya que permiten construir la personalidad de cada uno de manera individual. Sin embargo, mantenerlas por un tiempo prolongado o con una intensidad alta puede convertirse en problemas que es necesario intervenir de manera oportuna.

En (Durlak et al., 2011) el meta-análisis se centra en programas de aprendizaje socioemocional (SEL) que buscan desarrollar la capacidad de los estudiantes para comprender, manejar y expresar sus emociones de manera saludable. Esto implica reconocer que las emociones son fundamentales para el desarrollo del estudiante, pero que también necesitan ser reguladas para evitar que se conviertan en un obstáculo. Se muestra que los programas SEL reducen los problemas de conducta, como la agresividad y la disrupción en el aula. Esto indica que, al aprender a manejar sus emociones, los estudiantes pueden mejorar su comportamiento y su adaptación al entorno escolar.

Escala de medición del bienestar emocional

La escala de medición del bienestar emocional se presenta a continuación:

- **Verde:** Alumnos cuyo resultado entre 7 y 9 indica un nivel de riesgo bajo, situación dentro de lo esperado.
- **Amarillo:** Alumnos con resultado entre 4 y 6 indican un nivel de riesgo medio o moderado que requiere vigilancia y probablemente intervención.
- **Rojo:** Alumnos con resultado entre 1 y 3 indican un nivel de riesgo elevado que requiere intervención prioritaria.

3.2.3. Cuestionarios Auxiliares Evaluar para Avanzar

Este material está diseñado para proporcionar información detallada sobre las habilidades socioemocionales de los estudiantes, así como sobre sus condiciones socioeconómicas, aspectos especialmente relevantes en el contexto de la crisis sanitaria provocada por el COVID-19.

Los cuestionarios incluyen una guía para interpretar las respuestas y lineamientos claros para realizar una interpretación adecuada de los resultados, facilitando así la identificación de necesidades específicas y la implementación de estrategias de apoyo efectivas.

3.2.4. Prueba de Matemáticas Evaluar para Avanzar

La prueba de matemáticas de Evaluar para Avanzar emplea un enfoque de diseño basado en evidencias como metodología. Este enfoque propone una serie de pasos que permiten desglosar y construir un vínculo entre las competencias que se desean evaluar y las tareas o preguntas que debería realizar el estudiante para demostrar su comprensión.

El primer paso consiste en identificar los elementos específicos del área de conocimiento (o habilidades y destrezas) que se espera que los estudiantes dominen. A este proceso se le denomina afirmación, la cual se extrae, directa o indirectamente, de los estándares educativos.

El segundo paso implica determinar aquello que el estudiante debe mostrar para inferir que posee las habilidades descritas en la afirmación. Es decir, se enfoca en la formulación de aspectos observables en los estudiantes, los cuales permiten recopilar información sobre el nivel de adquisición de las competencias descritas en las afirmaciones. Este paso se conoce como evidencias, ya que articula lo que el estudiante debería saber en función de las tareas específicas que se le solicitan.

El último paso en este proceso es interpretar las evidencias recolectadas a través de las tareas o actividades desarrolladas por el estudiante. Esta interpretación permite realizar un análisis detallado del nivel de dominio de las competencias esperadas, estableciendo una retroalimentación útil para orientar futuras acciones educativas. En este sentido, las evidencias no solo funcionan como prueba del conocimiento adquirido, sino también como un recurso que guía el desarrollo y refuerzo de habilidades específicas en los estudiantes.

Para el área de matemáticas se agrupan los procesos matemáticos referidos en los estándares básicos de competencia en tres competencias: comunicación, modelación y representación, razonamiento y argumentación, y planteamiento y resolución de problemas. Adicionalmente, en el área se plantean estas competencias en cada uno de los componentes del área: numérico-variacional, espacial-métrico y aleatorio.

A continuación, se presenta un modelo de construcción de las preguntas en el área de matemáticas.

Pregunta: 7 | I_1460330

- ▶ **Competencia**
- ▶ **Afirmación**
- ▶ **Evidencia**
- ▶ **Componente**
- ▶ **Estándar asociado**
- ▶ **¿Qué evalúa?**
- ▶ **Respuesta correcta**
- ▶ **Justificación de la respuesta correcta**

La opción A es la respuesta correcta, porque reorganizando la información de las asistencias se observa que:

Grado	Febrero	Marzo	Abril	Total
Quinto	2	1	1	4
Sexto	3	2	3	8
Séptimo	2	2	2	6
- ▶ **Opciones no válidas**

Es posible que los estudiantes que eligen la opción B totalizan todas las inasistencias de cada mes. Posiblemente, los estudiantes que eligen la opción C promedian las inasistencias mensuales y ubican este valor para todos los grados.

Es posible que los estudiantes que eligen la opción D consideran que los estudiantes que han faltado en dos meses solo se cuentan una vez.

Figura 2: Ejemplo Estructura Construcción Preguntas Matemáticas Pruebas Evaluar para Avanzar

3.3. Preparación de los Datos

Una vez consolidado el almacén de datos, se llevo a cabo un proceso de limpieza y preparación de los datos. Esto aseguro que los datos sean de alta calidad y estén listos para su análisis.

3.3.1. Estructuración de la Base de Datos para la Integración de Evaluaciones

Para construir una base de datos unificada que integre las dos evaluaciones trabajadas con el programa habilmind, se utilizó inicialmente SQL para depurar y estructurar los datos. A continuación, se describe el proceso.

Archivos de Origen. La información se extrajo de tres archivos en Excel, detallados a continuación:

1. **Directorio de Estudiantes:** Contiene información de todos los estudiantes del colegio, incluyendo variables como apellidos, nombres y código único de cada estudiante.
2. **Resultados de Bienestar Emocional:** Incluye variables de nombres y apellidos de los estudiantes, junto con los resultados de evaluación en áreas como Miedo, Ansiedad, Ira, Tristeza, Optimismo, Autoestima, Expresividad, Motivación, Sueño, Alimentación, Pantallas, Disruptividad, Aislamiento y Sinceridad.
3. **Resultados de Habilidades Fundamentales:** Proporciona nombres y apellidos de los estudiantes y los resultados de evaluación en habilidades fundamentales como:
 - Habilidad de vocabulario (CUM)
 - Habilidad de Lectura comprensiva básica (CRM)
 - Habilidad de Seguimiento de Información extensa (CSM)
 - Habilidad de Captación de hechos matemáticos (CSS)
 - Habilidad de Juicio crítico matemático (ESS)
 - Habilidad de Solución de retos matemáticos (NSS)
 - Habilidad de Captación Visual (CUF)
 - Habilidad de Discriminación Visual (EUF)
 - Habilidad de Lectura rápida y precisa (NTS)

Asignación del código de estudiante Dado que los archivos de resultados de las pruebas no contienen el código de estudiante, se desarrolló un proceso para integrar esta información en los resultados:

- **Directorio de estudiantes:** Se extraen los nombres, apellidos y código de cada estudiante y se guarda en un archivo plano con punto y coma (;) como delimitador de columnas. Este archivo se almacena en formato ANSI, ya que los nombres y apellidos contienen caracteres especiales como tildes y la letra "ñ".
- **Resultados de bienestar emocional:** Se exportan los datos en un archivo plano con el mismo delimitador y formato ANSI para preservar los caracteres especiales.
- **Resultados de habilidades fundamentales:** Igualmente, se exporta a un archivo plano con punto y coma (;) y codificación ANSI.

Estandarización y procesamiento de nombres. Para conectar las tres fuentes de datos y unificar la información, se siguieron los siguientes pasos en SQL:

- **Inversión de orden de nombres:** El directorio de estudiantes está registrado en el formato "apellidos y nombres," mientras que los archivos de resultados presentan los datos en el formato "nombres y apellidos". Para hacer coincidir los datos, se empleó un conjunto de instrucciones SQL que separa y organiza los nombres en "primer apellido", "segundo apellido", "primer nombre" "segundo nombre".
- **Creación de columnas separadas:**
 - Se desglosaron los nombres en hasta cuatro columnas para manejar estudiantes con múltiples nombres.
 - Se eliminaron espacios adicionales.
- **Estandarización de caracteres especiales:**
 - Se actualizaron las tildes y se reemplazaron términos comunes con caracteres alterados (como "nino" por "niño", "nunez" por "nuñez", etc.) para evitar conflictos de codificación.
 - Finalmente, se eliminaron las tildes de todos los nombres y apellidos para asegurar una comparación sin errores de acentuación.

Resumen del proceso SQL

1. Formato de nombres y apellidos: Convertir a formato “apellidos y nombres.”
2. Conteo de palabras en el campo: Separación en cuatro columnas para nombres compuestos.
3. Eliminación de espacios: Remover espacios extra.
4. Corrección de nombres múltiples: Ajuste de nombres múltiples para lograr coincidencias precisas.
5. Actualización de tildes y ajustes en nombres: Reemplazo de caracteres incorrectos y eliminación de tildes.

3.3.2. Reestructuración y consolidación de los resultados de las pruebas evaluar para avanzar de matemáticas

Descarga de Resultados En una segunda fase, se descargaron los resultados de las pruebas “Evaluar para Avanzar” desde la plataforma del ICFES, en la cual se evaluó el área de matemáticas. Esta descarga incluyó 46 carpetas comprimidas, cada una con dos archivos en formato .xls: un reporte y una sábana.

Contenido del Archivo de Reporte. El archivo de reporte contiene un resumen detallado de los resultados por cada sesión en línea presentada por los estudiantes, desglosado en:

- Componente evaluado.
- Promedio de porcentaje de respuestas correctas por componente.
- Competencia evaluada.
- Promedio de porcentaje de respuestas correctas por competencia.
- Desglose por ítem (con clave correcta y opciones de respuesta).
- Indicador de dificultad.
- Porcentajes de respuestas correctas, omisiones y respuestas por opción (A, B, C y D).

Contenido del Archivo de Sábana. El archivo de sábana presenta un consolidado de los estudiantes que realizaron la prueba, con información relevante como:

- Identificación del estudiante (ID), nombres y apellidos.
- Total de respuestas correctas y porcentaje de respuestas correctas por estudiante.
- Porcentaje de omisiones.
- Fecha de presentación y modalidad.
- Información detallada por ítem, incluyendo componente, competencia, afirmación y evidencia.

Integración de Datos en un Archivo Consolidado. Se creó un archivo .xls donde se unifican los datos de todas las sábanas, añadiendo en cada hoja el grado del estudiante como una característica adicional.

- Con Python, se excluyen las filas innecesarias (casillas vacías y otra información no requerida) y se almacenan los datos en un nuevo DataFrame.
- Se selecciona una fila específica para renombrar las columnas de forma uniforme y se eliminan las columnas no esenciales para la identificación de los estudiantes o las preguntas.
- La base de datos se transpone para estructurar los identificadores de las preguntas adecuadamente.

Organización en Formato Long o Tidy. Los datos se reorganizan en un formato "long" ó "tidy", donde cada respuesta de estudiante a cada pregunta ocupa una fila separada, facilitando el análisis posterior.

Combinación de Datos. Finalmente, se realiza una fusión (merge) para combinar los datos principales con las descripciones de las preguntas. A partir de este paso, se diseñó una función en Python que automatiza este proceso en todas las hojas del archivo consolidado.

Esta metodología permite manejar eficientemente la información y facilita la generación de reportes detallados y el análisis de desempeño por ítem, competencia, componente y evidencia.

Para unificar las llaves de todos los archivos, se utiliza Python para asociar los códigos de los estudiantes con los archivos de directorio y el resultado final del proceso previo. Esto implicó realizar los siguientes pasos de procesamiento:

- **Eliminación de espacios:** Se eliminan los espacios en los nombres para facilitar la coincidencia.
- **Estandarización de la estructura:** Los nombres se reorganizan en el formato Apellidos y Nombres utilizando una función de coincidencias aproximadas.
- **Normalización de caracteres:** Se eliminan las tildes y se reemplaza la letra "ñ" por "n" para evitar inconsistencias.
- **Incorporación del grado:** Se añade el grado del estudiante como parte de la información unificada.

Este proceso asegura que todos los archivos queden bajo una misma estructura, facilitando su manejo y procesamiento posterior.

3.3.3. Reestructuración y Consolidación de los Resultados de las Pruebas Evaluar para Avanzar Cuestionarios Auxiliares

Descarga de Resultados. Se descargaron los resultados de los cuestionarios auxiliares de las pruebas Evaluar para Avanzar desde la plataforma del ICFES. Esta descarga incluyó 33 carpetas comprimidas, cada una con dos archivos en formato .xls: un reporte y una sábana.

del Archivo de Reporte. El archivo de reporte contiene un resumen detallado de los resultados por cada sesión en línea presentada por los estudiantes, desglosado en:

- Componente evaluado.
- Competencia evaluada.
- Porcentajes de omisiones y respuestas por opción (A, B, C y D).

Contenido del Archivo de Sábana. El archivo de sábana presenta un consolidado de los estudiantes que realizaron la prueba con las siguientes columnas:

- Identificación del estudiante (ID), nombres y apellidos (anonimizados).
- Porcentaje de omisiones.
- Fecha de presentación y modalidad.
- Información detallada por ítem, incluyendo componente, competencia, afirmación, evidencia y la respuesta de cada estudiante.

Integración de Datos en un Archivo Consolidado. Se creó un archivo .xls por cada sección donde se unifican los datos de todas las sábanas, añadiendo en cada hoja el grado del estudiante como una característica adicional.

- Con Python, se excluyen las filas innecesarias (casillas vacías y otra información no requerida) y se almacenan los datos en un nuevo DataFrame.

- Se selecciona una fila específica para renombrar las columnas de forma uniforme y se eliminan las columnas no esenciales.
- La base de datos se transpone para estructurar los identificadores de las preguntas adecuadamente.
- Se filtra y transforma las respuestas en formato largo, creando una columna de respuestas.
- Se cuenta la frecuencia de cada respuesta para cada pregunta y se identifica la respuesta más común para cada pregunta.
- Se combina esta respuesta con la información original de cada estudiante.
- Se realiza este proceso para cada uno de los archivos y se unifican en un solo archivo agregando el grado para cada fila.

3.3.4. Construcción de la Base de Datos Final

Para construir la base de datos final, se integran los tres archivos consolidados: la base final de habilidades y socioemocional, la base final de la prueba de matemáticas y la base final del cuestionario. A partir de estos archivos, se realiza un proceso de pivoteo tomando como clave principal el Código del Estudiante, lo que permite estructurar y relacionar toda la información de manera unificada y organizada en una sola base de datos.

3.4. Técnicas de análisis de datos

En este estudio, se emplearon Random Forest y Gradient Boosting, dos métodos basados en árboles de decisión, para analizar los patrones de desempeño académico y su relación con los factores socioemocionales. Esta elección se fundamenta en la capacidad de estos métodos para manejar datos con un gran número de variables, incluyendo interacciones complejas entre ellas, lo cual es crucial en el contexto educativo donde múltiples factores influyen en el aprendizaje. Timaran (2015), por ejemplo, utilizó este tipo de métodos para predecir el abandono escolar en estudiantes universitarios con base en sus características sociodemográficas y académicas. De manera similar, Martínez (2015) empleó árboles de decisión para identificar los factores que predicen el éxito en cursos de matemáticas en estudiantes de ingeniería de sistemas. En este estudio, se obtuvo que las variables socioemocionales, como el miedo y la ansiedad, interactúan con las competencias académicas, como la comunicación y la resolución de problemas, para influir en el rendimiento académico de los estudiantes. Los métodos de árbol de decisión son especialmente adecuados para capturar estas interacciones complejas y proporcionar una comprensión integral de los factores que contribuyen al éxito académico.

Por otra parte Random Forest y Gradient Boosting ofrecen un buen balance entre interpretabilidad y precisión. Permiten identificar las variables más importantes que influyen en el rendimiento académico, al tiempo que proporcionan predicciones precisas. Esta capacidad de interpretación es valiosa para comprender los factores que contribuyen al éxito académico y para diseñar intervenciones pedagógicas efectivas.

Los métodos basados en árboles de decisión, especialmente Random Forest, son robustos ante el sobreajuste, un problema común en el aprendizaje automático. Esta robustez es importante en este estudio para asegurar que los resultados sean válidos y aplicables a otros estudiantes o instituciones.

Random Forest y Gradient Boosting son capaces de manejar datos con clases desbalanceadas, una situación que puede presentarse en el análisis del rendimiento académico cuando hay más estudiantes en una categoría de rendimiento que en otras.

Si bien modelos como redes neuronales podrían aplicarse al análisis del rendimiento académico, en este estudio se optó por técnicas con las que se tiene mayor dominio para asegurar un análisis riguroso y una correcta interpretación de los resultados. La exploración de otras técnicas de aprendizaje automático se deja como una posible línea de investigación futura.

4. Análisis Exploratorio de Datos

4.1. Habilidades fundamentales

En esta etapa, se realiza un análisis exploratorio de los datos de acuerdo a la base de datos *Resultado de habilidades fundamentales* y con la codificación del estudiante como llave de enlace, se inicia la exploración de datos. Esta es una base con 693 filas y 14 columnas, una de ellas vacía, por lo cual procedemos a eliminarla haciendo uso del método `drop()` del paquete `pandas`.

La base de datos posee 13 columnas, en donde podemos encontrar:

1. **Grupo:** Curso al que pertenece el estudiante para el año académico 2021-2022.
2. **Grado:** Grado en el que se encuentra el estudiante para el año académico 2021-2022.
3. **Nombre:** Nombre del estudiante.
4. **Codigo_Estudiante:** Código del estudiante asignado desde su matrícula.

Además, se encuentra la valoración por cada una de las habilidades evaluadas. Las columnas 5, 6 y 7 hacen referencia al razonamiento del Lenguaje, las columnas 8, 9 y 10 a habilidades relacionadas al razonamiento matemático, y las columnas 11, 12 y 13 a habilidades lectoras. Estas habilidades están puntuadas en una escala de 1 a 9:

5. **CUM:** Habilidad de vocabulario.
6. **CRM:** Habilidad de Lectura comprensiva básica.
7. **CSM:** Habilidad de Seguimiento de Información extensa.
8. **CSS:** Habilidad de Captación de hechos matemáticos.
9. **ESS:** Habilidad de Juicio crítico matemático.
10. **NSS:** Habilidad de Solución de retos matemáticos.
11. **CUF:** Habilidad de Captación Visual.
12. **EUF:** Habilidad de Discriminación Visual.
13. **NTS:** Habilidad de Lectura rápida y precisa.

Se realiza un resumen de los datos mediante la función `describe()` del paquete `Pandas` por cada una de las habilidades evaluadas, filtradas por grados. Para su lectura, se agrupan de acuerdo a cada uno de los pilares del aprendizaje y sus correspondientes habilidades.

En la figura 3 se presentan los resúmenes de las habilidades en la dimensión de razonamiento verbal:

Grado	CUM								CRM								CSM							
	count	mean	std	min	25 %	50 %	75 %	max	count	mean	std	min	25 %	50 %	75 %	max	count	mean	std	min	25 %	50 %	75 %	max
4°	106	4.31	1.82	1	3	4	6	9	106	3.82	2.19	1	2	4	5	8	106	4.25	1.78	1	4	4	5	8
5°	113	4.19	1.92	1	3	4	5	9	113	4.13	2.56	1	1	4	6	9	113	3.79	1.97	1	2	4	4	9
6°	93	4.78	2.18	1	3	5	6	9	93	3.96	2.65	1	2	3	5	9	93	3.73	2.00	1	2	3	5	8
7°	94	4.53	1.70	1	3.25	5	6	9	94	5.23	3.01	1	2	6	8	9	94	5.57	2.53	1	4	5	7	9
8°	89	3.80	1.46	1	3	4	5	7	89	5.72	2.94	1	2	6	8	9	89	6.13	2.64	1	4	7	9	9
9°	52	4.13	1.60	1	3	4	5	7	52	7.25	2.22	1	6	8	9	9	52	6.42	2.45	1	5	7	9	9
10°	48	3.58	1.87	1	2	4	5	8	48	5.38	2.94	1	4	5.5	7.5	9	48	5.85	2.41	1	4	6	9	9
11°	52	3.75	1.82	1	2	3.5	5.25	7	52	7.10	2.17	1	7	7	9	9	52	6.90	2.29	1	5	7.5	9	9

Tabla 2: Resumen descriptivo de las habilidades asociadas a razonamiento del lenguaje

A partir de los datos obtenidos se realiza una tabla resumen para el promedio, la desviación estándar y el coeficiente de variación, como se evidencia en la figura 4.

Para la habilidad de vocabulario, se observa una mayor variabilidad de la habilidad en los estudiantes de décimo grado.

Grado	Mean CUM	Std CUM	Coefficient of Variation (%)	Mean CRM	Std CRM	Coefficient of Variation (%)	Mean CSM	Std CSM	Coefficient of Variation (%)
4°	4.31	1.82	42.27	3.82	2.19	57.43	4.25	1.78	41.80
5°	4.19	1.92	45.71	4.13	2.56	61.90	3.79	1.97	51.91
6°	4.78	2.18	45.58	3.96	2.65	66.85	3.73	2.00	53.62
7°	4.53	1.70	37.42	5.23	3.01	57.52	5.57	2.53	45.37
8°	3.80	1.46	38.32	5.72	2.94	51.38	6.13	2.64	43.07
9°	4.13	1.60	38.62	7.25	2.22	30.65	6.42	2.45	38.18
10°	3.58	1.87	52.08	5.38	2.94	54.77	5.85	2.41	41.24
11°	3.75	1.82	48.65	7.10	2.17	30.60	6.90	2.29	33.24

Tabla 3: Resumen variabilidad de las habilidades asociadas a razonamiento del lenguaje

Se observa mayor variabilidad en la habilidad de lectura comprensiva básica en los estudiantes de grado sexto.

Asimismo, se observa mayor variabilidad en la habilidad de Seguimiento de Información extensa en los estudiantes de grado sexto.

En todas las habilidades de la dimensión de razonamiento verbal, se observan coeficientes de variación superiores al 30%, lo que nos indica una poca representatividad de la media.




Figura 3: Diagramas de Caja para las Habilidades de Razonamiento del Lenguaje por Grado

Para los grados 4° a 9°, en la habilidad de vocabulario, se observa que el 25% de los estudiantes presentan un desarrollo por debajo de lo esperado para afrontar el grado actual. Para los grados décimo y undécimo, un porcentaje del 40% se encuentra por debajo del nivel esperado.

En la habilidad de lectura comprensiva básica, preocupa el desempeño de los grados 4° a 8°, ya que se evidencian porcentajes mayores al 30% de estudiantes que no tienen el desarrollo esperado para el grado.

Para la habilidad de seguimiento en información extensa, el 75% de los estudiantes de grados 4° a 11° poseen un adecuado desarrollo. Se debe prestar atención a los estudiantes de grado 5° y 6°, donde el 50% de los estudiantes no poseen un adecuado desarrollo de la habilidad.

Para el grado cuarto, salvo los casos atípicos, los estudiantes presentan un adecuado desarrollo de sus competencias.

El diagrama de caja nos muestra datos atípicos en la habilidad de vocabulario (CUM) en quinto grado para aquellos estudiantes que obtuvieron el puntaje máximo. También se observan datos atípicos en lectura comprensiva básica (CRM) en estudiantes de grado noveno y undécimo. En el seguimiento de Información extensa (CSM), se observan datos atípicos en los grados cuarto y quinto.

Dentro de la dimensión de razonamiento matemático se obtiene la siguiente tabla resumen

Para la habilidad de captación de hechos matemáticos, se observa una dispersión muy alta en todos los grados; sin embargo, el grado décimo es el que presenta una mayor dispersión.

En cuanto a la habilidad de juicio crítico matemático, se observa un mejor desempeño en comparación con la habilidad de captación de hechos matemáticos. Sin embargo, el coeficiente de variación en todos los grados no permite una representatividad de la media para la descripción de los resultados.

En el grado octavo, podemos observar que es el grado con menor dispersión en la solución de retos matemáticos y presenta una de las medias más altas.

Grado	CSS								ESS								NSS							
	count	mean	std	min	25 %	50 %	75 %	max	count	mean	std	min	25 %	50 %	75 %	max	count	mean	std	min	25 %	50 %	75 %	max
4°	106	4.50	1.40	2	4	4	5	9	106	5.30	2.05	1	4	5	7	9	106	6.50	2.15	3	6	7	8	9
5°	113	3.96	1.95	1	3	4	5	9	113	4.53	2.06	1	3	5	6	9	113	6.55	2.36	2	5	7	9	9
6°	93	4.08	2.35	1	2	3	5	9	93	4.61	2.23	1	2	5	6	9	93	6.42	2.69	2	4	8	9	9
7°	94	4.68	2.83	1	3	5	7	9	94	5.70	2.48	1	4	6	9	9	94	6.99	2.31	1	5	8	9	9
8°	89	4.93	2.72	1	3	5	7	9	89	6.98	2.43	1	5	9	9	9	89	7.76	2.01	1	7	9	9	9
9°	52	5.54	2.60	1	3	5	7.5	9	52	6.44	2.60	1	4.75	6	9	9	52	7.46	2.45	1	6.5	9	9	9
10°	48	4.48	3.06	1	1	4	6	9	48	6.50	2.89	1	4	9	9	9	48	6.85	2.97	1	4	9	9	9
11°	52	4.94	2.99	1	1	5	6.75	9	52	7.33	2.37	2	5	9	9	9	52	7.60	2.59	2	8.25	9	9	9

Tabla 4: Resumen descriptivo de las habilidades asociadas a razonamiento matemático

Grado	Mean CSS	Std CSS	Coefficient of Variation (%)	Mean ESS	Std ESS	Coefficient of Variation (%)	Mean NSS	Std NSS	Coefficient of Variation (%)
4°	4.50	1.40	31.01	5.30	2.05	38.71	6.50	2.15	33.05
5°	3.96	1.95	49.07	4.53	2.06	45.41	6.55	2.36	36.04
6°	4.08	2.35	57.57	4.61	2.23	48.27	6.42	2.69	41.93
7°	4.68	2.83	60.52	5.70	2.48	43.56	6.99	2.31	33.01
8°	4.93	2.72	55.17	6.98	2.43	34.84	7.76	2.01	25.91
9°	5.54	2.60	46.96	6.44	2.60	40.36	7.46	2.45	32.77
10°	4.48	3.06	68.31	6.50	2.89	44.43	6.85	2.97	43.30
11°	4.94	2.99	60.56	7.33	2.37	32.40	7.60	2.59	34.12

Tabla 5: Resumen variabilidad de las habilidades asociadas a razonamiento matemático




Figura 4: Diagramas de Caja para las Habilidades de Razonamiento Matemático por Grado

Para la dimensión de razonamiento matemático, se evidencia que la habilidad de captación de hechos matemáticos presenta un desarrollo adecuado en los estudiantes de grado cuarto, salvo algunos resultados atípicos. Para los grados 7° a 9°, se observa que el 75 % de los estudiantes se encuentran en el nivel esperado. Es relevante prestar atención a los resultados obtenidos en la escuela media, ya que en el caso de los estudiantes de grado décimo, el 50 % se encuentra por debajo de lo esperado para este grado.

En cuanto a la habilidad de juicio crítico matemático, se observa que el 75 % o más de los estudiantes de los grados 7° a 11° se encuentran o en el nivel esperado o por encima de este. Es fundamental revisar estrategias que permitan mejorar los resultados en el grado sexto.

En la habilidad de solución de retos matemáticos, se observa que el 75 % de los estudiantes de todos los grados se encuentran por encima de un resultado igual o superior a 4. Es importante para disminuir la dispersión reforzar el trabajo con los estudiantes que aparecen como datos atípicos dentro de sus grupos.

Dentro de la dimensión de lectura mecánica, se obtiene la siguiente tabla resumen:

Grado	CUF								EUF								NTS							
	count	mean	std	min	25 %	50 %	75 %	max	count	mean	std	min	25 %	50 %	75 %	max	count	mean	std	min	25 %	50 %	75 %	max
4°	106	5.74	2.15	1	4	6	8	9	106	7.14	1.96	1	6	8	9	9	106	4.46	2.25	1	3	4	6	9
5°	113	6.22	2.27	1	5	7	8	9	113	7.18	1.61	1	6	7	8	9	113	3.90	2.05	1	2	4	5	9
6°	93	5.63	2.17	1	4	6	7	9	93	7.25	1.42	1	7	7	8	9	93	4.44	2.41	1	2	5	6	9
7°	94	7.02	1.92	4	5	8	9	9	94	7.14	1.69	1	6	8	8	9	94	5.00	2.19	1	4	5	6	9
8°	89	7.61	1.71	1	7	8	9	9	89	7.39	1.55	1	7	8	8	9	89	5.12	2.06	1	4	5	6	9
9°	52	7.42	1.91	2	7	8	9	9	52	7.75	1.17	4	8	8	8	9	52	5.98	2.12	1	5	6	8	9
10°	48	7.08	1.72	3	5.75	8	9	9	48	7.60	1.23	4	7	8	8	9	48	5.23	2.08	1	4	5	7	8
11°	52	7.17	1.64	2	6	8	8	9	52	7.65	1.14	5	7	8	8	9	52	5.54	1.64	1	5	5	6	9

Tabla 6: Resumen descriptivo de las habilidades lectoras

Esta dimensión es la que presenta menor dispersión en las habilidades de captación y discriminación

Grado	Mean CUF	Std CUF	Coefficient of Variation (%)	Mean EUF	Std EUF	Coefficient of Variation (%)	Mean NTS	Std NTS	Coefficient of Variation (%)
4°	5.74	2.15	37.45	7.14	1.96	27.43	4.46	2.25	50.46
5°	6.22	2.27	36.44	7.18	1.61	22.44	3.90	2.05	52.49
6°	5.63	2.17	38.53	7.25	1.42	19.58	4.44	2.41	54.20
7°	7.02	1.92	27.31	7.14	1.69	23.66	5.00	2.19	43.90
8°	7.61	1.71	22.48	7.39	1.55	20.96	5.12	2.06	40.11
9°	7.42	1.91	25.77	7.75	1.17	15.09	5.98	2.12	35.43
10°	7.08	1.72	24.34	7.60	1.23	16.22	5.23	2.08	39.69
11°	7.17	1.64	22.89	7.65	1.14	14.84	5.54	1.64	29.58

Tabla 7: Resumen Variabilidad de las habilidades lectoras

visual. Para la habilidad de lectura rápida y precisa, se observa un mejor desempeño en los estudiantes de grado undécimo. Es importante revisar los valores obtenidos en los grados de 4° a 6°.




Figura 5: Diagramas de Caja para las Habilidades Asociadas a la Lectura Mecánica por Grado

El diagrama nos muestra que en la habilidad de captación visual en los grados 7° a 9°, el 100% de los estudiantes se encuentran en el nivel esperado o por encima de lo esperado.

Se observa en la discriminación visual que el 75% de los estudiantes en los grados 6°, 8°, 10° y 11° se encuentran por encima de lo esperado. Sin embargo, es la habilidad con mayor cantidad de valores atípicos dentro de los diferentes grados.

Para la habilidad de lectura rápida y precisa, llama la atención la cantidad de datos atípicos dentro del grado undécimo.

De acuerdo al número de datos faltantes, se establece un gráfico de correlaciones para establecer un posible modelo que nos permita la imputación de los datos faltantes. Sin embargo, no se observan una correlación alta entre ninguna de las habilidades.




Figura 6: Mapa de Calor de las Correlaciones de las Habilidades Evaluadas

4.2. Screening Emocional

De acuerdo a la base de datos Screening Emocional y con la codificación del estudiante como llave de enlace, se inicia la exploración de datos. Esta base cuenta con 788 filas y 17 columnas.

La base de datos posee 17 columnas donde podemos encontrar:

1. **Grado:** Grado en el que se encuentra el estudiante para el año académico 2021-2022.
2. **Nombre:** Nombre del estudiante.
3. **Código Estudiante:** Código del estudiante asignado desde su matrícula.

Las columnas 4, 5, 6 y 7 hacen referencia a las emociones causales, las columnas 8, 9, 10, 11 y 12 a los factores de protección emocional y las columnas 13, 14, 15, 16 y 17 a manifestaciones conductuales. Estas emociones están puntuadas en una escala de 1 a 9.

- | | | |
|-------------------------|-----------------------------|------------------------------|
| 4. MI: Miedo | 9. AE: Autoestima | 14. PA: Pantallas |
| 5. AN: Ansiedad | 10. EX: Expresividad | 15. DI: Disruptividad |
| 6. IR: Ira | 11. MO: Motivación | 16. AI: Aislamiento |
| 7. TR: Tristeza | 12. SU: Sueño | 17. SI: Sinceridad |
| 8. OP: Optimismo | 13. AL: Alimentación | |

Se realiza un resumen de los datos mediante la función describe() del paquete Pandas por cada una de las emociones evaluadas, filtradas por grados, para su lectura se agrupan de acuerdo a cada grupo de emociones. A continuación, se presentan los resúmenes de las emociones en la categoría de Emociones Causales.

Grado	Mean MI	Std MI	CV MI (%)	Mean AN	Std AN	CV AN (%)	Mean IR	Std IR	CV IR (%)	Mean TR	Std TR	CV TR (%)
Cuarto	5.84	1.80	30.86	6.17	1.86	30.19	6.75	1.75	25.97	6.29	1.91	30.38
Décimo	3.25	2.80	86.12	2.87	2.59	90.45	3.76	3.24	86.17	2.60	2.65	102.04
Noveno	4.96	2.34	47.08	4.61	2.38	51.58	5.16	2.47	47.80	4.38	2.67	61.08
Octavo	5.60	2.12	37.93	5.57	2.07	37.18	6.06	2.10	34.64	5.75	2.35	40.92
Quinto	5.70	1.68	29.51	5.64	1.93	34.27	6.01	1.74	28.99	6.20	1.94	31.25
Sexto	6.15	1.74	28.37	6.13	1.96	31.91	6.38	1.88	29.55	6.46	2.01	31.15
Séptimo	5.99	1.78	29.71	5.98	2.02	33.83	5.92	2.03	34.37	6.45	2.11	32.69
Undécimo	4.59	2.45	53.38	3.87	2.12	54.92	5.08	2.49	49.00	4.07	2.38	58.57

Tabla 8: Resumen Variabilidad de las Emociones Causales

Existe una tendencia en la que los grados superiores presentan niveles medianos más altos de estas emociones (miedo, tristeza, ira y ansiedad) en comparación con los grados inferiores. Esto podría indicar una mayor carga emocional o estrés en los estudiantes de grados avanzados.

En todos los gráficos, observamos una gran variabilidad en cada grado, lo que sugiere que las emociones no son uniformes en cada grupo, sino que varían significativamente entre estudiantes.

Los valores atípicos son más frecuentes en los grados inferiores (Quinto y Cuarto), lo cual podría interpretarse como una menor frecuencia de casos extremos en estos grupos.

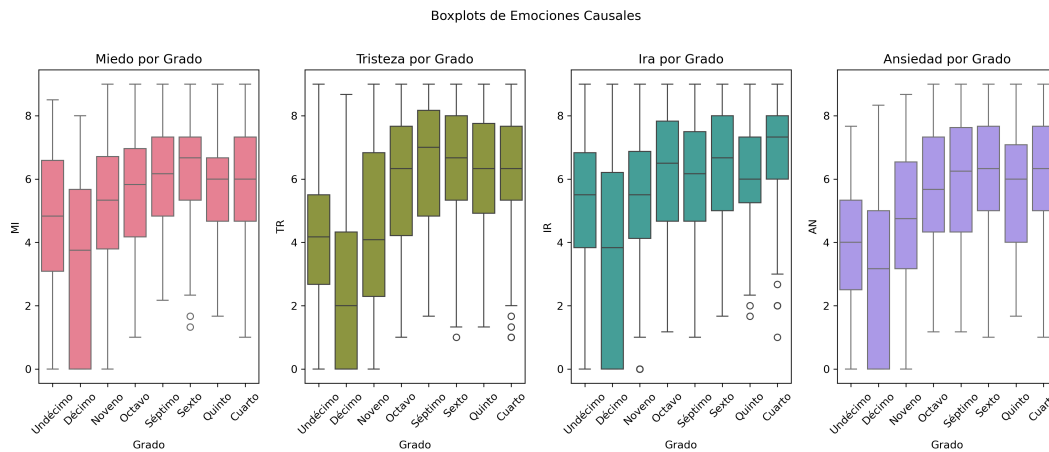


Figura 7: Diagrama de Caja para las Emociones Causales

Para los factores de protección emocional muestran una tendencia a aumentar en los grados inferiores, lo cual podría indicar una mayor espontaneidad y percepción positiva entre los estudiantes más jóvenes. A continuación se presenta tabla de resumen de los factores de protección emocional

Grado	Mean OP	Std OP	CV OP (%)	Mean AE	Std AE	CV AE (%)	Mean EX	Std EX	CV EX (%)	Mean MO	Std MO	CV MO (%)	Mean SU	Std SU	CV SU (%)
Cuarto	6.20	1.84	29.70	6.85	1.75	25.54	7.15	1.65	23.08	6.45	1.82	28.22	6.35	1.90	29.92
Décimo	4.35	2.10	48.28	3.90	2.00	51.28	4.20	2.15	51.19	4.00	2.25	56.25	3.95	2.12	53.67
Noveno	5.70	2.05	35.96	5.45	1.95	35.78	5.60	2.00	35.71	5.50	2.10	38.18	5.45	2.20	40.37
Octavo	6.00	1.80	30.00	6.25	1.85	29.60	6.45	1.95	30.23	6.50	1.92	29.54	6.30	2.05	32.54
Quinto	6.50	1.90	29.23	6.75	1.85	27.41	7.00	1.80	25.71	6.80	1.95	28.68	6.75	2.10	31.11
Sexto	6.80	1.85	27.21	7.05	1.80	25.53	7.25	1.70	23.45	7.00	1.75	25.00	7.10	2.00	28.17
Séptimo	6.60	1.88	28.48	6.95	1.92	27.63	6.85	1.87	27.30	7.05	1.90	26.95	6.90	1.85	26.81
Undécimo	4.80	2.15	44.79	4.70	2.10	44.68	4.85	2.20	45.36	4.65	2.18	46.88	4.75	2.25	47.37

Tabla 9: Resumen Variabilidad de los factores de Protección Emocional por Grado

La motivación parece estar más presente en grados intermedios, mientras que la sinceridad disminuye en grados inferiores. Esto podría relacionarse con cambios en la autoexpresión y el deseo de compartir experiencias conforme los estudiantes avanzan en edad.

La autoestima muestra un patrón bastante estable entre los grados, con una leve tendencia al alza en grados superiores.

Los grados superiores presentan valores atípicos en varias dimensiones, lo cual podría reflejar la variabilidad en cómo los estudiantes mayores perciben y expresan estos factores de protección emocional, como lo podemos ver en el siguiente gráfico

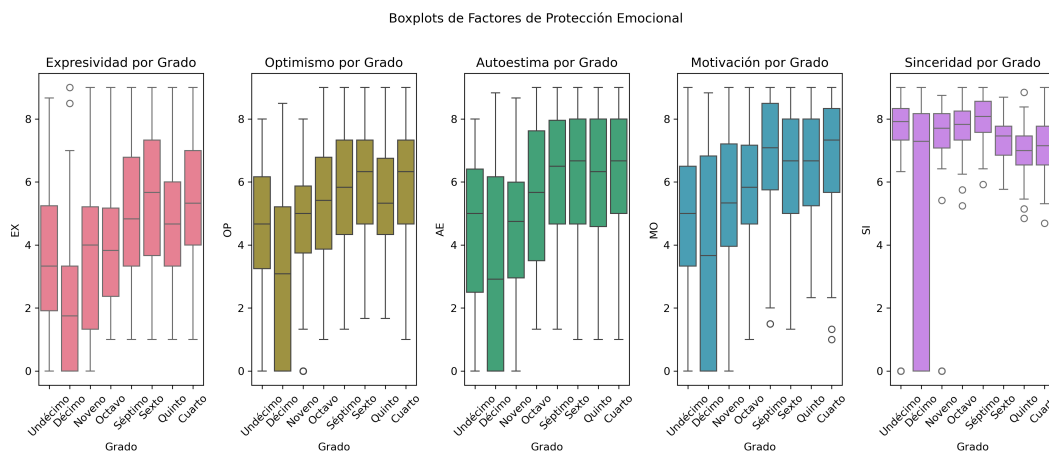


Figura 8: Diagrama de Caja de los Factores de Protección Emocional

Los estudiantes de grados inferiores parecen tener patrones de sueño y alimentación más estables y adecuados en comparación con los estudiantes de grados superiores.

A continuación se presenta tabla resumen de las manifestaciones conductuales

Grado	Mean AL	Std AL	CV AL (%)	Mean PA	Std PA	CV PA (%)	Mean DI	Std DI	CV DI (%)	Mean AI	Std AI	CV AI (%)	Mean SI	Std SI	CV SI (%)
Cuarto	6.15	1.85	30.08	6.35	1.72	27.13	6.45	1.68	26.05	6.55	1.74	26.56	6.60	1.80	27.27
Décimo	4.20	2.15	51.19	4.10	2.05	50.00	4.00	2.25	56.25	4.05	2.10	51.85	4.15	2.20	53.01
Noveno	5.50	2.00	36.36	5.60	2.10	37.50	5.65	2.05	36.28	5.55	2.00	36.04	5.50	2.15	39.09
Octavo	6.25	1.95	31.20	6.40	2.00	31.25	6.30	1.85	29.37	6.20	1.90	30.65	6.35	2.05	32.28
Quinto	6.80	1.90	27.94	6.95	1.85	26.62	7.05	1.80	25.53	6.90	1.95	28.26	6.85	2.10	30.66
Sexto	7.10	1.80	25.35	7.00	1.70	24.29	7.15	1.85	25.87	7.05	1.75	24.82	7.20	2.00	27.78
Séptimo	6.75	1.85	27.41	6.85	1.90	27.74	6.80	1.87	27.50	6.95	1.82	26.18	7.00	1.88	26.86
Undécimo	4.65	2.20	47.31	4.75	2.15	45.26	4.85	2.10	43.30	4.70	2.05	43.62	4.60	2.00	43.48

Tabla 10: Resumen Variabilidad de las Manifestaciones Conductuales por Grado

Las conductas disruptivas y el aislamiento son más prevalentes en grados superiores, lo cual podría estar relacionado con el aumento de las presiones académicas y sociales en los estudiantes mayores.

El uso de pantallas es mayor en los grados intermedios, lo que puede relacionarse con el aumento de actividades sociales y recreativas digitales a esas edades.

El siguiente gráfico muestra las tendencias mencionadas.

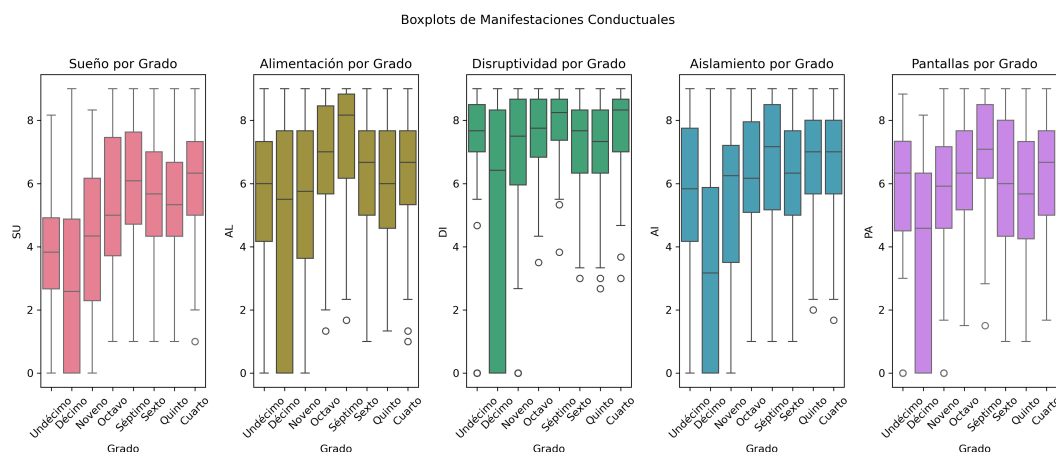


Figura 9: Diagrama de Caja de las Manifestaciones Conductuales por Grado

En general podemos decir que grado décimo presenta la mayor dispersión en casi todas las variables, lo cual podría interpretarse como un periodo de mayor inestabilidad emocional y conductual en los estudiantes.

Los grados Cuarto a Sexto muestran mayor consistencia en sus respuestas, sugiriendo un desarrollo emocional y conductual más estable en estas edades.

Las variables relacionadas con el aislamiento, la disruptividad y el uso de pantallas muestran alta variabilidad en los grados superiores, lo cual podría reflejar diferencias en las formas de socialización y adaptación de los estudiantes.

El siguiente mapa de calor muestra el coeficiente de variación entre las variables emocionales y conductuales en cada grado




Figura 10: Gráfico de Calor de los Coeficiente de Variación de las Variables Socioemocionales

La variabilidad alta en ciertas emociones y comportamientos en grados superiores (especialmente en décimo) puede reflejar la influencia de cambios emocionales, presión académica o transición hacia etapas más avanzadas de la vida escolar. Los grados con menor variabilidad (como cuarto y séptimo) muestran una estabilidad relativa en emociones y hábitos, lo que podría ser una ventaja para desarrollar intervenciones preventivas antes de que enfrenten mayores desafíos emocionales en grados superiores. Los patrones observados en el uso de pantallas y hábitos de sueño también sugieren que es importante promover un estilo de vida saludable, especialmente en grados donde estos hábitos comienzan a volverse más variables.

4.3. Prueba Matemáticas Evaluar para Avanzar

Para las pruebas de matemáticas se determinó el porcentaje de respuestas correctas de cada uno de los estudiantes como se muestra a continuación

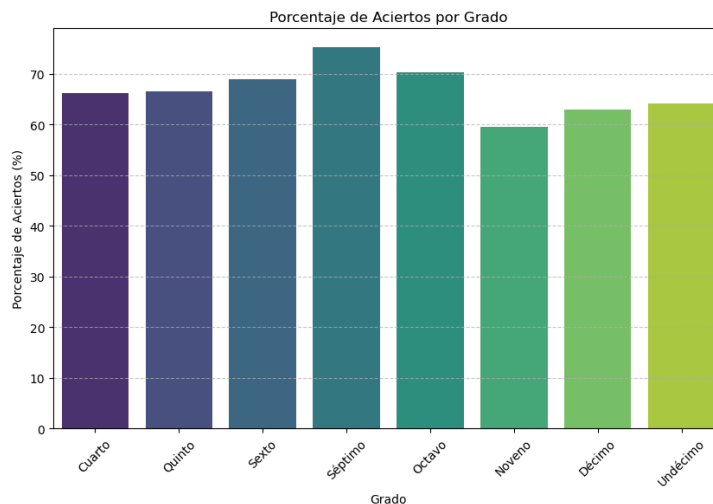


Figura 11: Distribución De los Porcentajes de Aciertos en la Prueba de Matemáticas Evaluar para Avanzar

Los porcentajes de aciertos parecen disminuir en los grados superiores. Se observa que los estudiantes de

Cuarto a Séptimo grado tienden a tener un porcentaje de aciertos más alto (cerca o por encima del 70 %), mientras que los grados Octavo a Undécimo muestran una ligera disminución, alcanzando porcentajes entre 60 % y 65 %.

A continuación se puede observar la distribución de los resultados




Figura 12: Diagrama de Caja de los Porcentajes de Aciertos en la Prueba de Matemáticas

Los grados cuarto a séptimo tienen medianas más altas en el porcentaje de aciertos, rondando cerca del 70%-75 %, lo que nos indica que el 50 % de los estudiantes obtuvieron porcentajes de acierto mayores a estos valores.

A partir de octavo grado, se observa una disminución en la mediana del porcentaje de aciertos, lo que coincide con el análisis previo y refuerza la idea de una posible tendencia descendente en los grados superiores.

Los grados quinto y sexto presentan una amplia dispersión en el porcentaje de aciertos, como se ve en los rangos intercuartílicos relativamente grandes y la longitud de los bigotes, lo que indica mayor variabilidad en los resultados dentro de estos grados.

En los grados superiores, aunque la mediana es menor, la dispersión parece ser más compacta en comparación con algunos de los grados inferiores, lo cual sugiere una mayor homogeneidad entre los estudiantes en estos niveles, aunque con un rendimiento más bajo.

Los valores atípicos en grados inferiores se encuentran en el rango bajo (por debajo del 50 %), lo que indica que existen estudiantes que necesitan apoyo adicional.

Para profundizar en las fortalezas y debilidades presentadas en la prueba se analizaron los resultados por

competencias y por componentes.

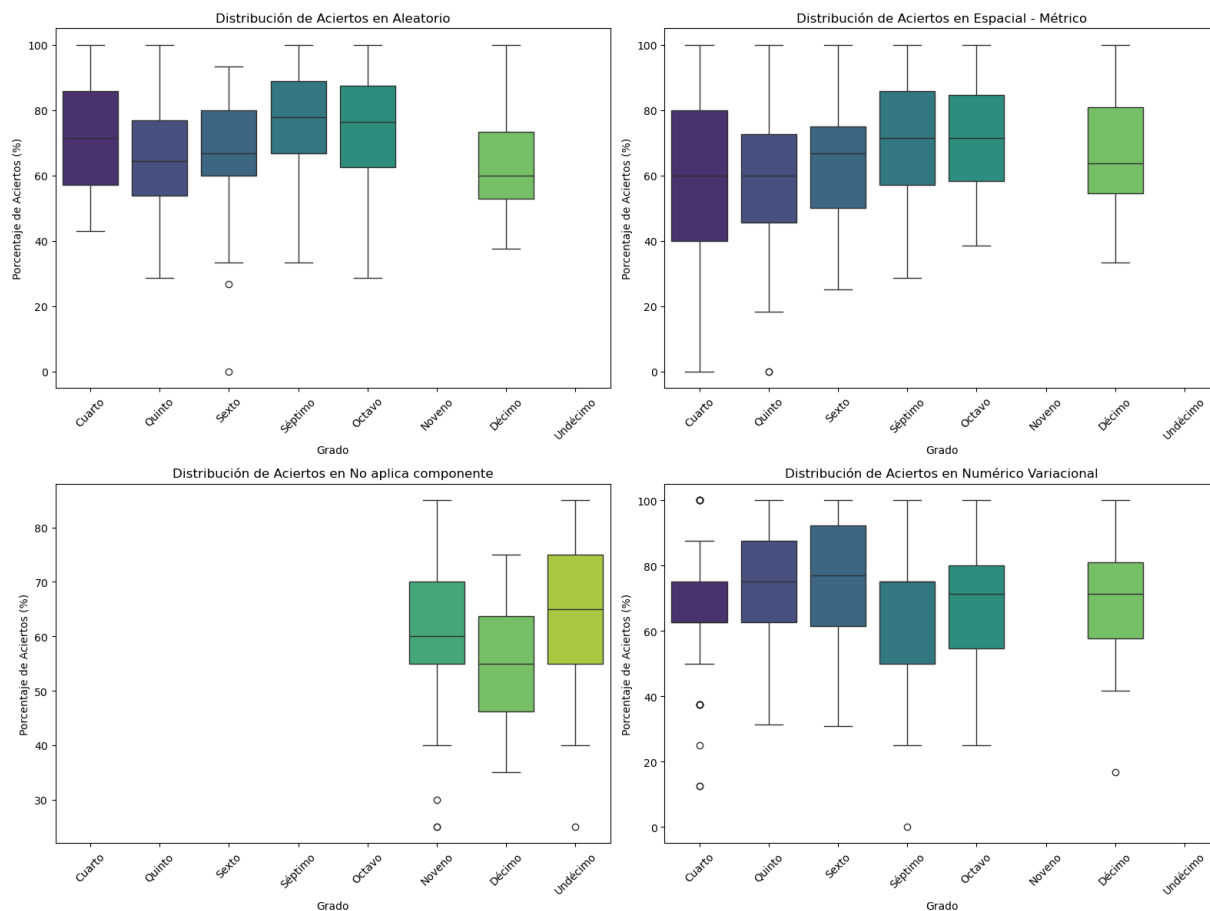


Figura 13: Diagramas de Cajas para la Distribución por Componentes en cada Grado

Para el componente aleatorio los grados cuarto a séptimo presentan medianas relativamente altas, cerca del 70 %-80 %, lo cual sugiere un rendimiento sólido en estos grados.

En décimo y undécimo la mediana baja respecto a los otros grados, especialmente en Décimo, lo cual indica una dificultad en este componente para los estudiantes de grados superiores.

Hay valores atípicos en quinto y sexto grado en el extremo inferior, indicando estudiantes con un rendimiento considerablemente bajo en este componente.

En el componente geométrico-Métrico se observa mayor variabilidad en los grados cuarto y séptimo, para los grados superiores se observa una mediana estable con una pequeña disminución en grado undécimo, el único grado que presenta valores atípicos en la parte baja lo que sugiere que algunos estudiantes presentan dificultades significativas en esta área.

Para el componente numérico-variacional los grados cuarto a octavo presentan una alta variabilidad, con medianas cerca del 60 %-70 %.

Este gráfico presenta mayor número de valores atípicos en distintos grados lo que indica que algunos estudiantes tienen rendimientos significativamente distintos en este componente.

Para grado cuarto es significativamente compacta la caja, lo cual indica una mayor homogeneidad en los desempeños en este componente.

Por último, en las pruebas de los grados superiores, algunas preguntas no fueron catalogadas por componentes específicos. Al revisar las evidencias, no fue posible en todos los casos determinar a cuál componente correspondían, lo que implica que los resultados de los tres componentes anteriores se encuentran mezclados en esta sección.

Por otra parte podemos ver las tendencias en las competencias en cada grado en el siguiente gráfico.



Figura 14: Distribución Por Competencias de los Aciertos en la Prueba de Matemáticas por Grado

Para grado cuarto las competencias de comunicación (especialmente en el componente aleatorio) presentan un alto porcentaje de aciertos, sugiriendo que los estudiantes en este grado son fuertes en esta área.

Por otro lado, resolución de problemas - numérico variacional tiene un porcentaje más bajo en comparación con otras competencias, lo que podría indicar que los estudiantes de cuarto grado encuentran más desafíos en tareas numéricas complejas.

Para grado quinto las competencias de comunicación y razonamiento en el componente aleatorio muestran niveles altos de desempeño, similar a grado cuarto.

Se observa una disminución en el rendimiento en resolución de problemas - espacial - métrico, lo que podría sugerir dificultades en la aplicación de habilidades espaciales en la resolución de problemas.

Para grado sexto las competencias de comunicación y razonamiento - aleatorio se mantienen como áreas fuertes, con un porcentaje de aciertos alto. la resolución de problemas - numérico variacional sigue siendo una competencia con un desempeño más bajo, lo que puede indicar una dificultad consistente en temas numéricos a medida que los estudiantes avanzan.

Para grado séptimo el patrón es similar al de sexto grado, con un rendimiento fuerte en comunicación y razonamiento - aleatorio. Las competencias espaciales y numéricas en resolución de problemas muestran

un rendimiento más bajo, lo que sugiere que esta puede ser una oportunidad para mejorar el rendimiento de los estudiantes de este grado.

En grado octavo comunicación y razonamiento - aleatorio continúan siendo áreas de fortaleza. Se observa una disminución en resolución de problemas - espacial - métrico y numérico variacional, lo que sugiere una tendencia en la que las habilidades en resolución de problemas más complejos decaen conforme los estudiantes avanzan en los grados.

En el caso de grado noveno, no se especifica el componente correspondiente a cada competencia; sin embargo, se observa que los estudiantes presentan mayores dificultades en la formulación y ejecución de procesos matemáticos.

En grado décimo, los estudiantes son evaluados en una amplia gama de competencias, con más subcategorías. Se observa una disminución general en los porcentajes de aciertos en varias competencias, lo cual refuerza la tendencia de disminución en el rendimiento a medida que los estudiantes avanzan.

Para grado undécimo, no se especifica el componente correspondiente a cada competencia; sin embargo, se observa que los estudiantes presentan fortaleza para la competencia de argumentación.

En general los estudiantes de la institución evidencian mayores fortalezas en comunicación y razonamiento aleatorio en grados inferiores, lo cual puede ser un reflejo de un enfoque más fuerte en habilidades de comunicación y razonamiento en edades tempranas.

Para los grados superiores se evidencia una disminución del rendimiento en resolución de problemas geométricos y numéricos donde los estudiantes de octavo en adelante muestran un rendimiento decreciente en estas competencias.

4.4. Cuestionario Auxiliar Evaluar para Avanzar

Debido a que la base de datos de los cuestionarios auxiliares se encontraba anonimizados, el análisis exploratorio se centrara en la distribución de las respuestas por competencia y grado

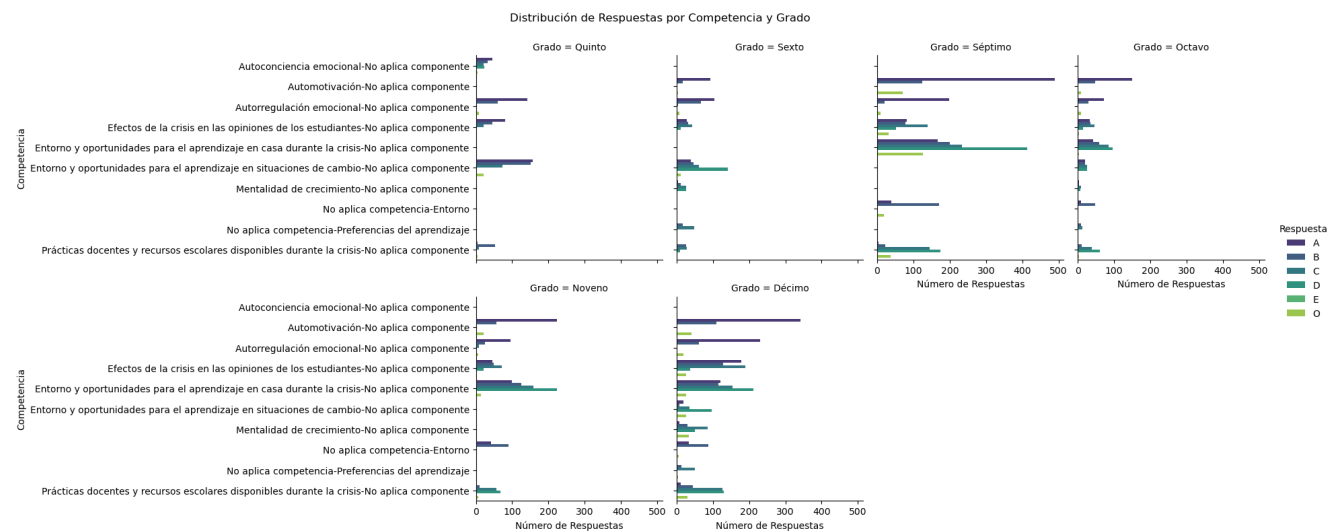


Figura 15: Distribución por Competencias y Grado de los Cuestionarios Auxiliares

Para los grados cuarto y quinto, la tendencia en el desarrollo de competencias emocionales es positiva. Las competencias de autoconciencia y autorregulación emocional muestran una alta concentración de respuestas en las opciones A y B, lo que indica que los estudiantes presentan una auto percepción emocional favorable y un manejo regulado de sus emociones. Sin embargo, respecto a la percepción de oportunidades de aprendizaje y recursos disponibles, se observa mayor dispersión, especialmente en el área de "prácticas docentes y recursos escolares". Esto sugiere que algunos estudiantes perciben limitaciones en estos aspectos o necesitan mayor apoyo.

En cuanto a la percepción del impacto de la crisis del COVID-19, las respuestas presentan cierta variabi-

lidad, comprensible dado que cada estudiante vivió la crisis de manera distinta. Aun así, la concentración de respuestas en las opciones A y B indica que, en general, los estudiantes mantienen una perspectiva moderadamente positiva o neutral al respecto.

En sexto grado, los estudiantes reportan una percepción positiva en cuanto a automotivación y autorregulación emocional, señal de autoconfianza y estabilidad emocional. Sin embargo, la percepción sobre el entorno de aprendizaje y los recursos disponibles durante la crisis muestra dispersión en las respuestas, lo que sugiere necesidades o expectativas insatisfechas en algunos estudiantes. La percepción sobre la mentalidad de crecimiento también varía considerablemente, lo que indica que algunos estudiantes podrían requerir apoyo adicional para fomentar una visión positiva del aprendizaje y el crecimiento personal. Asimismo, la preferencia mayoritaria en la opción D que se refiere a Preferencias del Aprendizaje sugiere que las estrategias de enseñanza podrían ajustarse para alinearse mejor con las preferencias de los estudiantes.

En séptimo grado, la automotivación y la autorregulación emocional se perciben positivamente, con una alta concentración en la opción A. No obstante, la competencia de entorno y oportunidades de aprendizaje en casa durante el COVID-19 muestra una alta concentración en la opción D, lo que refleja insatisfacción con el entorno de aprendizaje en casa. Las opiniones sobre el impacto de la crisis y el entorno general son variadas, lo cual podría deberse a diferencias en el acceso a recursos o en el apoyo emocional y académico recibido.

Los estudiantes de octavo grado también reportan una autopercepción positiva en automotivación y autorregulación emocional. Al igual que en grados anteriores, la mayoría expresa insatisfacción con el entorno de aprendizaje en casa (opción D), señalando posibles limitaciones o carencias en este ámbito. Las competencias relacionadas con el impacto de la crisis y el aprendizaje en situaciones de cambio presentan una gran dispersión, lo cual refleja experiencias diversas.

Para el noveno grado, se mantiene una percepción positiva en cuanto a automotivación y autorregulación emocional, en línea con los grados anteriores. La alta concentración de respuestas en la opción D respecto al entorno y oportunidades para el aprendizaje en casa evidencia dificultades en este aspecto, sugiriendo que los estudiantes podrían beneficiarse de apoyos adicionales para mejorar su experiencia educativa en casa. Las opiniones sobre los efectos de la crisis se encuentran diversamente distribuidas, indicando interpretaciones diversas de esta experiencia.

Por último, los estudiantes de décimo y undécimo grado muestran una percepción positiva y consolidada en automotivación y autorregulación emocional, tendencia observada en toda la institución. Sin embargo, una cantidad considerable de estudiantes percibe el entorno de aprendizaje en casa como insuficiente, lo que refuerza la necesidad de mejoras para apoyar mejor el aprendizaje remoto. Las opiniones sobre el impacto de la crisis y el aprendizaje en contextos de cambio son variadas, lo que sugiere una amplia gama de experiencias entre los estudiantes.

5. Aplicación y Resultado de los Modelos Estadísticos

5.1. Árboles de Clasificación para las habilidades

Un árbol de clasificación utiliza la medida de impureza de Gini para clasificar los registros en las categorías del campo objetivo. Las predicciones se basan en combinaciones de valores en los campos de entrada.

La impureza de Gini es una función que penaliza una distribución equilibrada de los valores objetivo, basándose en las estadísticas de frecuencia de destino y en el número de filas de datos correspondientes a cada nodo. Los nodos hijo correspondientes a las categorías de los predictores se fusionan cuando el incremento en la impureza de Gini es tolerable dentro de un límite especificado. Para cada nodo, se selecciona el predictor que más reduce el valor de impureza de Gini para la división del nodo (IBM, 2022).

El uso de esta técnica estadística tiene como objetivo definir la probabilidad de que un estudiante sea calificado como excelente, es decir, que su calificación se encuentre entre 7 y 9 en cada una de las dimensiones de estudio, teniendo en cuenta los resultados de las emociones. Inicialmente, se construyen árboles para cada dimensión; si este modelo presenta un buen pronóstico, no se realizan ajustes adicionales. En caso contrario, se aplica la técnica de random forest (bosque aleatorio) para cada dimensión, ya que esta

técnica consiste en un conjunto de árboles de clasificación, lo que minimiza el error y aumenta la robustez del modelo (IArtificial.net, 2022).

La técnica del árbol de clasificación se basa en la imputación realizada en las habilidades de los estudiantes, dado que hay estudiantes para los cuales fue necesaria la imputación, pero que contaban con resultados en el test de bienestar emocional.

Se realizan arboles de clasificación para las tres dimensiones de habilidades, en las tres la variable objetivo es que el resultado sea excelente, teniendo como variables explicativas las variables de medidas en el Bienestar Emocional.

5.1.1. Dimensión Verbal

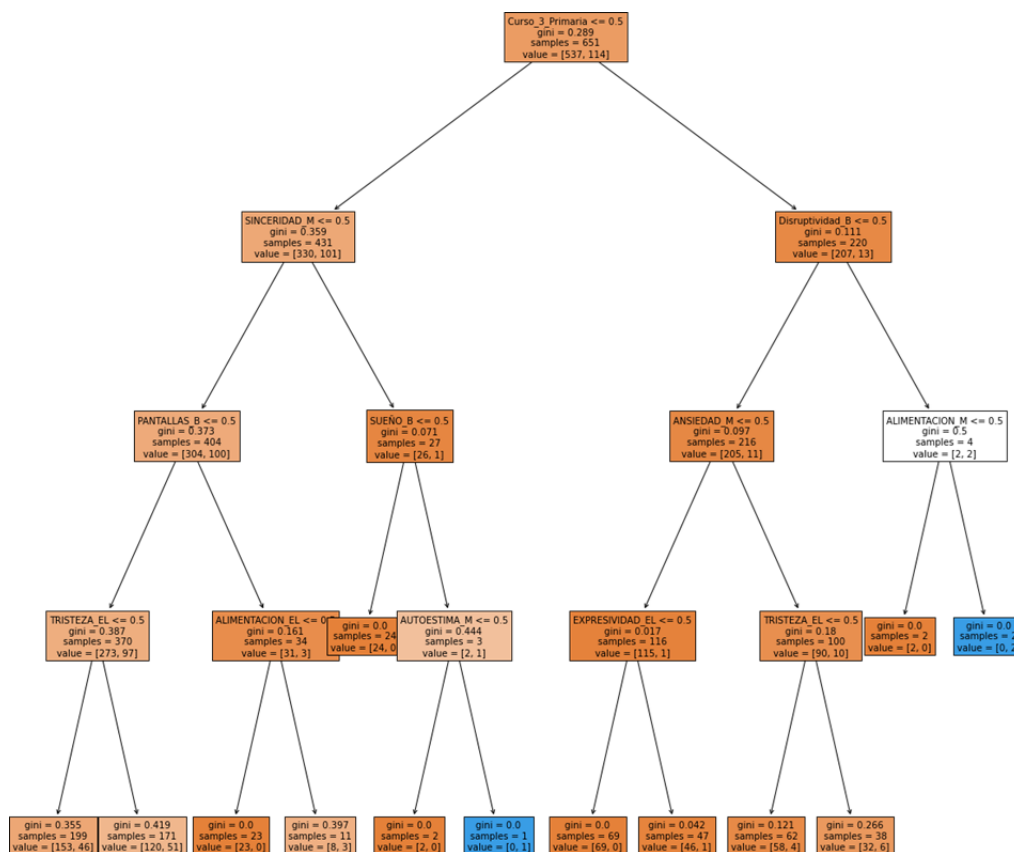


Figura 16: Árbol de decisión para la Habilidad de Razonamiento del Lenguaje

La primera división (nodo) en el árbol es la variable Curso 3 Primaria (con un umbral de 0.5), lo cual indica que esta variable es una de las más relevantes para predecir la dimensión verbal.

Las variables socioemocionales, como Sinceridad, Ansiedad, y Disruptividad, tienen un papel fundamental en la predicción de la dimensión verbal, lo cual sugiere que los factores emocionales y de comportamiento están altamente correlacionados con el rendimiento o el perfil en esta dimensión.

Con esta información se analiza que tan bueno fue el modelo para explicar la variable de obtener un resultado entre 7 y 9 para el área verbal, el resultado presenta que un 82,94 % de precisión, teniendo en cuenta las variables emocionales en los niños de primaria, dado que el árbol inicia con esta clasificación.

Este árbol de decisión ofrece una visión clara de cómo diferentes factores socioemocionales y conductuales se correlacionan con la dimensión verbal en este grupo de estudiantes. La estructura del árbol destaca la importancia de variables como la sinceridad, la ansiedad y los hábitos diarios (sueño y pantallas) en la predicción del rendimiento o perfil verbal.

5.1.2. Dimensión Razonamiento Matemático

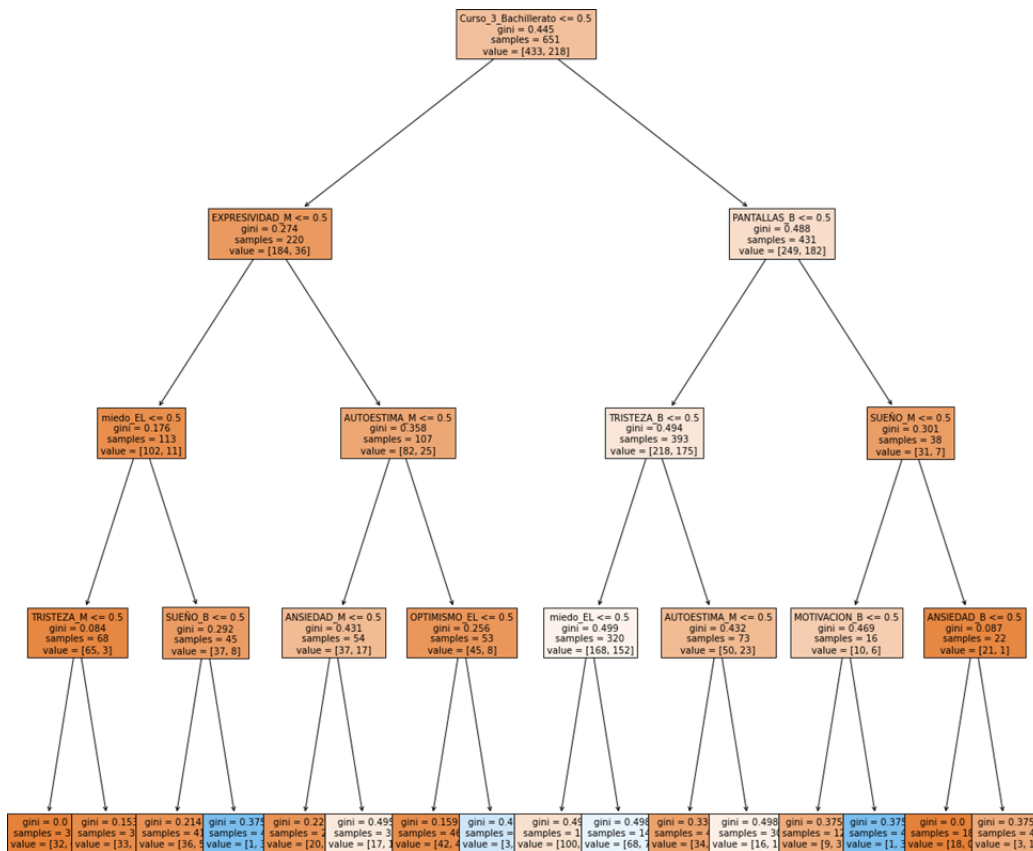


Figura 17: Árbol de decisión para la Habilidad de Razonamiento Matemático

La gráfica muestra el nodo raíz que realiza una primera subdivisión basada en el curso (curso 33), correspondiente al bachillerato, con un valor inferior a 0,5. A partir de esta división, se observan diferentes categorías emocionales: hacia la izquierda se clasifica la expresividad en nivel medio y hacia la derecha, el uso de pantallas en nivel bajo. Al profundizar en los niveles inferiores del árbol, se encuentran clasificaciones adicionales: miedo elevado, autoestima en nivel medio, tristeza en nivel bajo y sueño en nivel medio.

La gráfica muestra el nodo raíz que realiza una primera subdivisión basada en el curso (curso 3), correspondiente al bachillerato, con un valor inferior a 0,5. A partir de esta división, se observan diferentes categorías emocionales: hacia la izquierda se clasifica la expresividad en nivel medio y hacia la derecha, el uso de pantallas en nivel bajo. Al profundizar en los niveles inferiores del árbol, se encuentran clasificaciones adicionales: miedo elevado, autoestima en nivel medio, tristeza en nivel bajo y sueño en nivel medio.

Con esta estructura, se evaluó la capacidad del modelo para predecir con precisión un puntaje entre 7 y 9 en el área verbal, utilizando como factores las variables emocionales de los estudiantes de bachillerato. Los resultados indican una precisión del 68,66 %, reflejando la relevancia de las clasificaciones emocionales iniciales en el árbol para explicar los resultados en el razonamiento matemático.

Este árbol de decisión proporciona información valiosa sobre cómo los factores socioemocionales y algunos hábitos (como el sueño y el uso de pantallas) están relacionados con la dimensión de razonamiento matemático. Las variables emocionales, especialmente el miedo, la autoestima y la ansiedad, parecen ser predictores clave en esta dimensión, lo que sugiere que apoyar a los estudiantes en estas áreas podría mejorar su rendimiento en matemáticas.

5.1.3. Dimensión Lectura Mecánica

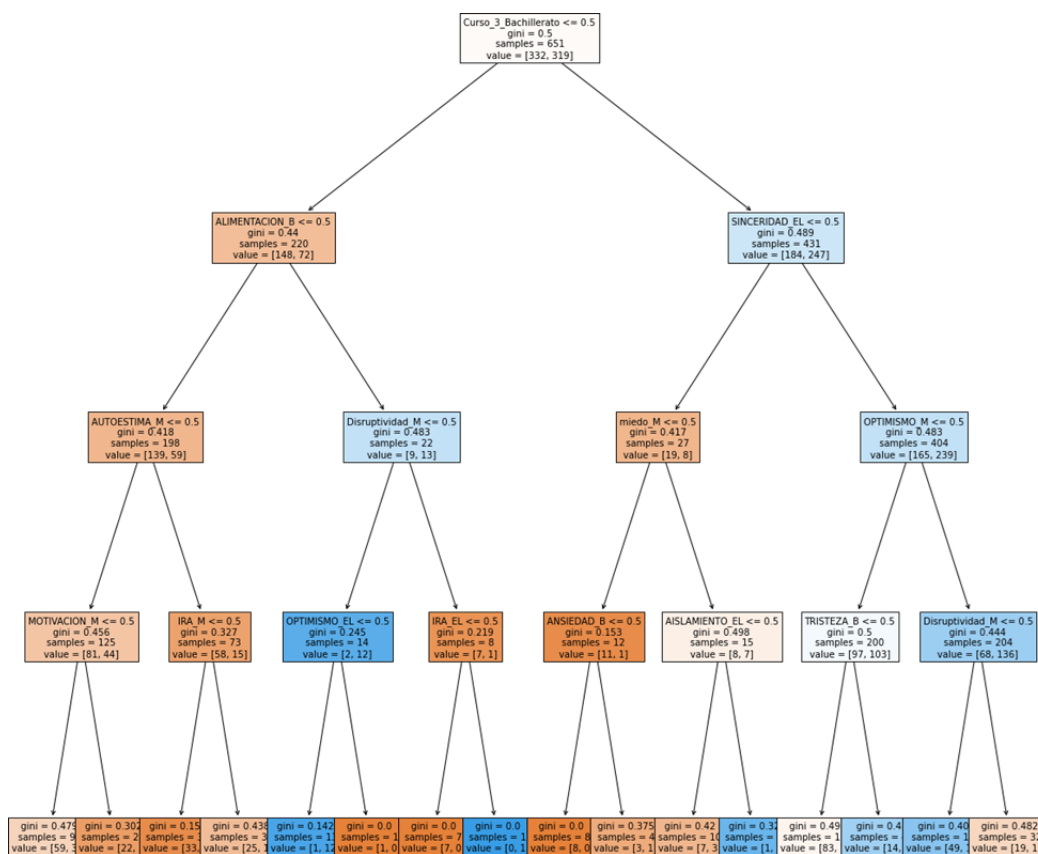


Figura 18: Árbol de Decisión para la Habilidad de Lectura Mecánica

La gráfica muestra el nodo raíz que realiza una primera subdivisión basada en el curso (curso 3), correspondiente al bachillerato, con un valor inferior a 0,5. A partir de esta división, se observa que hacia la izquierda se clasifica la alimentación en nivel bajo, mientras que hacia la derecha se encuentra la sinceridad en nivel elevado. En los niveles inferiores del árbol, se encuentran clasificaciones adicionales de emociones: autoestima en nivel medio, disruptividad en nivel medio, miedo en nivel medio y optimismo en nivel medio.

Esta estructura permite evaluar la eficacia del modelo para predecir un puntaje entre 7 y 9 en el área de lectura mecánica, tomando en cuenta las variables emocionales de los estudiantes de bachillerato. Los resultados muestran una precisión del 66,66 %, lo que refleja la relevancia de la clasificación emocional inicial en el árbol para explicar el desempeño en lectura mecánica.

El árbol de decisión para la dimensión de lectura mecánica destaca la influencia de variables socioemocionales (como autoestima, optimismo, sinceridad y ansiedad) junto con factores de bienestar y hábitos (como la alimentación y la disruptividad). Estas variables sugieren que una combinación de estabilidad emocional, hábitos saludables y actitudes positivas puede estar relacionada con un mejor rendimiento en lectura mecánica.

5.2. Árbol de Clasificación para el rendimiento en la habilidad de Captación de hechos matemáticos

Una vez consolidada la base de datos, que incluye información sobre las habilidades, el screening emocional, los resultados en matemáticas y los cuestionarios auxiliares de las pruebas Evaluar para Avanzar, se aplicaron modelos de clasificación mediante árboles de decisión, random forest y gradient boosting para identificar el modelo más adecuado, con la variable objetivo habilidad de captación de hechos matemáticos.

Puntajes de validación cruzada para Gradient Boosting ajustado				
Precisión promedio: 0.9985611510791367				
	precision	recall	f1-score	support
Alto	1.00	1.00	1.00	47
Bajo	1.00	1.00	1.00	69
Básico	1.00	1.00	1.00	93
accuracy	1.00 (209)			
macro avg	1.00	1.00	1.00	209
weighted avg	1.00	1.00	1.00	209

Puntajes de validación cruzada para Random Forest optimizado				
Precisión promedio: 0.9509852987175476				
	precision	recall	f1-score	support
Alto	1.00	0.83	0.91	47
Bajo	1.00	1.00	1.00	69
Básico	0.92	1.00	0.96	93
accuracy	0.96 (209)			
macro avg	0.97	0.94	0.96	209
weighted avg	0.96	0.96	0.96	209

Tabla 11: Resultados de Validación Cruzada y Reporte de Clasificación para Gradient Boosting y Random Forest

Elegir Random Forest parece ser una decisión prudente en este caso, ya que ofrece un equilibrio entre alto rendimiento y robustez, con menor riesgo de sobreajuste. Aunque Gradient Boosting muestra un rendimiento superior en los datos actuales, la perfección en todas las métricas es sospechosa y podría no generalizar bien a datos nuevos.

Se presenta la matriz de confusión




Figura 19: Matriz de Confusión para el Modelo Random Forest

El modelo muestra un muy buen rendimiento en todas las clases. Cada clase tiene una alta precisión con muy pocos errores de clasificación, lo cual es consistente con los buenos resultados de precisión y recall observados en el reporte de clasificación. La clase bajo tuvo dos errores al ser clasificada como alto, y la clase básico tuvo un error similar. Sin embargo, estos errores son mínimos y no parecen afectar de

manera significativa el rendimiento global del modelo.




Figura 20: Distribución de los Peso de Importancia de las variables Explicativas del modelo Random Forest

La distribución de importancia en este modelo de Random Forest nos ayuda a identificar qué factores son más determinantes para clasificar el rendimiento de un estudiante en el rendimiento en la habilidad de Captación de hechos matemáticos, la variable que mas afecta el rendimiento es la misma variable, seguida de la habilidad de Juicio crítico matemático, la habilidad de lectura comprensiva básica y de la habilidad de Seguimiento de Información extensa.

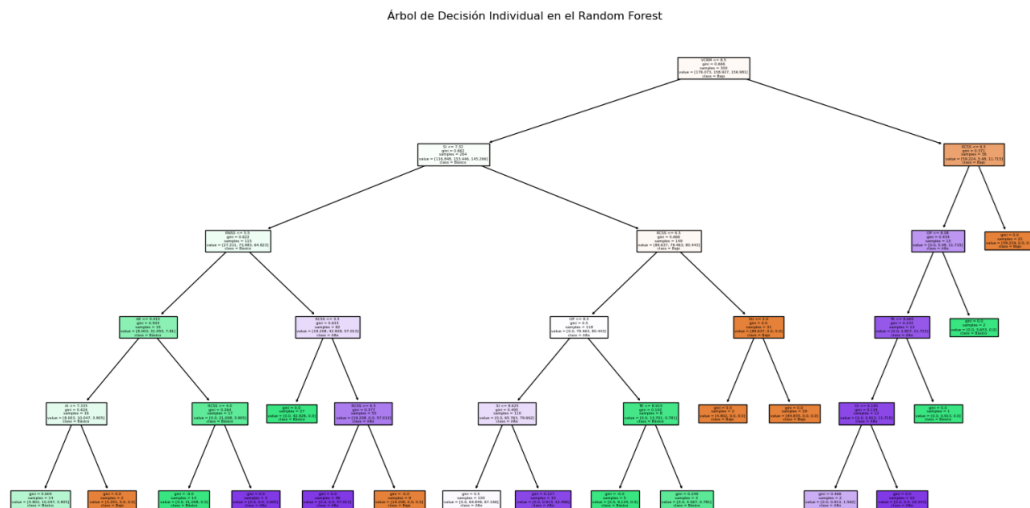


Figura 21: Árbol de Decisión para la Habilidad de Captación de Hechos Matemáticos

Observamos que las características de Habilidad de Seguimiento de Información extensa y la Habilidad de Juicio crítico matemático aparecen en el nodo raíz o en niveles superiores, lo cual sugiere que son importantes para el modelo en términos de diferenciación temprana de los niveles de rendimiento.

El árbol de decisión muestra cómo las características específicas contribuyen a predecir el nivel de Habilidad de Captación de hechos matemáticos. Las variables en los nodos superiores son las más importantes para la decisión global, mientras que las variables en nodos inferiores ayudan a refinar las predicciones para cada clase.

5.3. Árbol de Clasificación para el Desempeño en la prueba del área de Matemáticas

Una vez consolidada la base de datos final, que incluye información sobre las habilidades, el screening emocional, los resultados en matemáticas añadiendo el porcentaje de respuestas correctas y los cuestionarios auxiliares de las pruebas Evaluar para Avanzar, se aplicaron modelos de clasificación mediante árboles de decisión, random forest y gradient boosting para identificar el modelo más adecuado.

A continuación se presenta un resumen de los resultados obtenidos teniendo como variable objetivo el desempeño en la prueba de matemáticas.

Modelo	Precisión en Validación Cruzada	Parámetros Óptimos	Precisión en el Conjunto de Prueba
Decision Tree	0.5909	{'max_depth': 5, 'min_samples_leaf': 2, 'min_samples_split': 2}	0.5779
Random Forest	0.6343	{'max_depth': None, 'min_samples_leaf': 1, 'min_samples_split': 2, 'n_estimators': 100}	0.5779
Gradient Boosting	0.6020	{'learning_rate': 0.1, 'max_depth': 3, 'n_estimators': 100}	0.5779

Tabla 12: Resumen comparación Modelos Árboles de Decisión

Random Forest obtuvo la mejor precisión en validación cruzada (0.6343), indicando que puede ser el modelo más robusto en este conjunto de datos. Decision Tree mostró una precisión similar en validación cruzada y en el conjunto de prueba, lo que sugiere que es un modelo estable pero no tan preciso en comparación con el bosque aleatorio.

Gradient Boosting presentó una precisión intermedia, con la ventaja de tener un buen control sobre el sobreajuste, lo cual puede ser útil si se mejora la calidad de los datos.

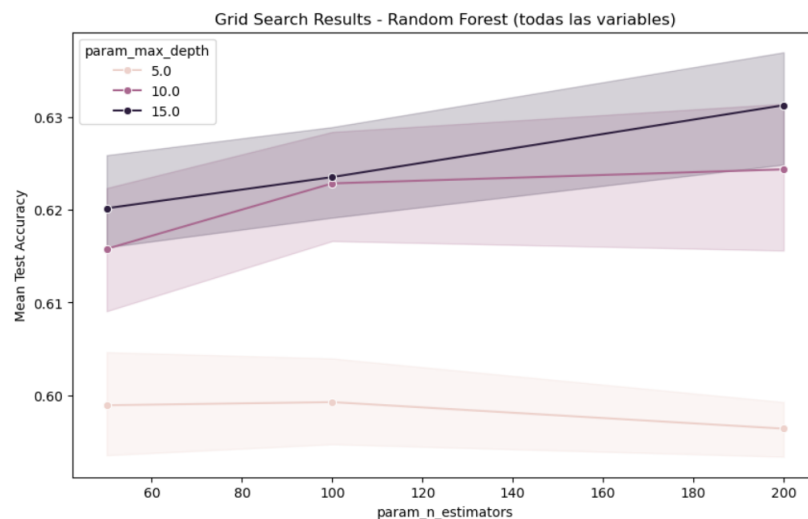


Figura 22: Gráfico de Hiperparámetros para modelo Random Forest

La profundidad de 15 parece ser la mejor opción en términos de precisión media de prueba, permitiendo que el modelo capture patrones complejos en los datos. La profundidad de 10 también ofrece un rendimiento decente, pero inferior a 15. Aunque la precisión sigue aumentando al incrementar el número de estimadores, el crecimiento parece disminuir a partir de 100 estimadores. Esto sugiere que entre 100 y 200 estimadores es un buen rango, especialmente con una profundidad de 15.

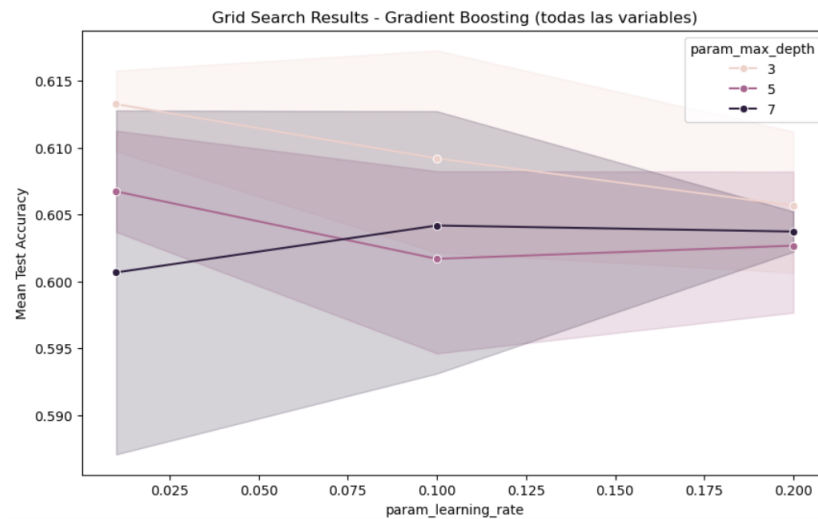


Figura 23: Gráfico de Hiperparámetros para modelo Gradient Boosting

Una profundidad de 3 parece ser la mejor opción, proporcionando una precisión media de prueba más alta y estable. Esto indica que el modelo de Gradient Boosting no necesita árboles demasiado profundos para captar los patrones relevantes. Por otra parte una tasa de aprendizaje baja, entre 0.025 y 0.05, es óptima para maximizar la precisión en los datos de prueba. Las tasas de aprendizaje más altas tienden a reducir la precisión, probablemente porque el modelo se ajusta demasiado rápido y pierde la capacidad de generalizar.

Se establecieron cuatro categorías basadas en los desempeños obtenidos por los estudiantes, en alineación con los niveles propuestos por el ICFES, para determinar su nivel de desempeño.

Se muestra a continuación el resultado de las matrices de confusión.

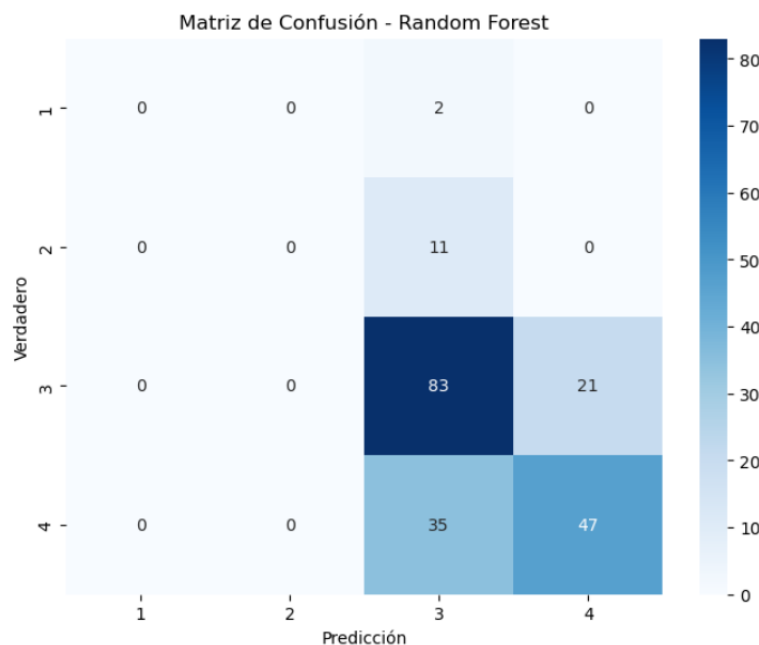


Figura 24: Matriz de Confusión del Modelo Random Forest

En general, esta matriz de confusión indica que el modelo tiene una buena capacidad para clasificar en los niveles 2 y 3, pero tiene áreas de mejora en la identificación de los niveles 1 y 4.

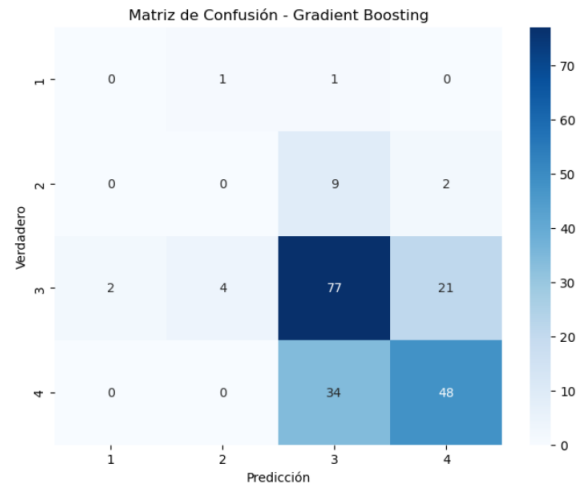


Figura 25: Matriz de Confusión Modelo Gradient Boosting

En general, el modelo de Gradient Boosting muestra un rendimiento similar al de Random Forest, con algunas mejoras en la precisión de la categoría 2, pero enfrenta los mismos desafíos en los extremos de la clasificación niveles 1 y 4.

Random Forest				Gradient Boosting			
Clase	Precision	Recall	F1-Score	Clase	Precision	Recall	F1-Score
1	0.00	0.00	0.00	1	0.00	0.00	0.00
2	0.00	0.00	0.00	2	0.00	0.00	0.00
3	0.63	0.80	0.71	3	0.64	0.74	0.68
4	0.69	0.57	0.63	4	0.68	0.59	0.63
Accuracy	0.65 (199)			Accuracy	0.63 (199)		
Macro avg	0.33	0.34	0.33	Macro avg	0.33	0.33	0.33
Weighted avg	0.62	0.65	0.63	Weighted avg	0.61	0.63	0.62

Tabla 13: Reportes de Clasificación para Random Forest y Gradient Boosting

Random Forest muestra un rendimiento ligeramente mejor en este conjunto de datos, aunque ambos modelos son comparables.

Se presenta el gráfico de los hiperparámetros

A continuación se presenta la importancia de variables predictivas




Figura 26: Distribución de las Variables de Importancia de los Modelos Random Forest y Gradient Boosting

Las características más importantes para el modelo de Random Forest son: Miedo (MI): Aparece como la característica más relevante, sugiriendo que el miedo tiene un impacto significativo en la predicción de los niveles de desempeño. Sinceridad (SI), Alimentación (AL), y Sueño (SU): Estas características

relacionadas con el bienestar emocional y físico también son muy importantes en este modelo. Habilidades de vocabulario (VCUM) e Ira (IR): También aparecen como características relevantes, indicando que variables de razonamiento del lenguaje y de emociones causales influyen en el rendimiento del modelo. En general, Random Forest parece priorizar variables que reflejan tanto el estado emocional (miedo, sinceridad, ira) como aspectos de salud (alimentación, sueño).

El modelo de Gradient Boosting destaca tanto habilidades académicas específicas (como el vocabulario y la resolución de problemas matemáticos) como factores de bienestar personal (sueño y sinceridad). Esto sugiere que el desempeño no solo depende de competencias académicas, sino también del estado físico y emocional de los estudiantes.

La fuerte presencia de variables relacionadas con la comunicación y el vocabulario indica que estas habilidades son fundamentales para el modelo. Esto es consistente con estudios que muestran cómo una buena base en comunicación y vocabulario facilita el aprendizaje en múltiples áreas.

La inclusión del componente aleatorio en las variables de comunicación sugiere una fortaleza dentro del área de matemáticas de la institución

De acuerdo a esto se construye el árbol con el modelo de Gradient Boosting ya que identifica un perfil de éxito que combina tanto competencias académicas clave (comunicación, vocabulario, y resolución de problemas) como factores de bienestar personal (sueño y sinceridad). Este equilibrio es importante para entender cómo diferentes dimensiones del desarrollo de los estudiantes se interrelacionan y contribuyen al rendimiento global.

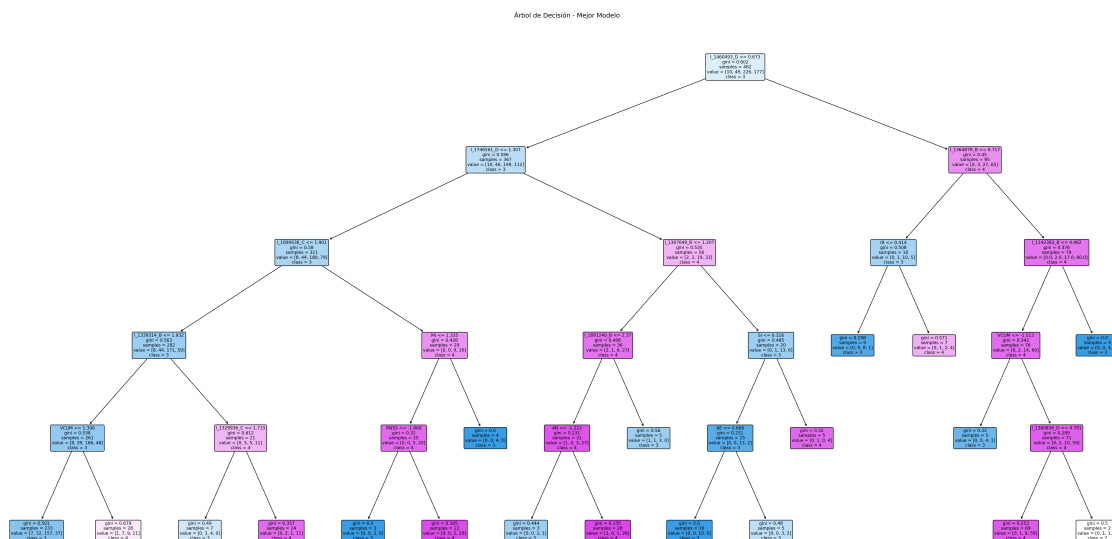


Figura 27: Árbol de Decisión del mejor modelo Gradient Boosting

5.4. Árbol de Clasificación para el Desempeño en la prueba del área de Matemáticas Haciendo Uso de Lasso

Con el objetivo de mejorar la precisión (accuracy) de los modelos de bosque aleatorio (random forest) y gradient boosting, se aplicó el método de selección de variables Lasso a ambos modelos. A continuación, se presentan los resultados obtenidos.

Random Forest tiene una ligera ventaja en la precisión global y un mejor recall en la Clase 3, lo que le permite captar más instancias correctas de la clase dominante. Sin embargo el Gradient Boosting ofrece un rendimiento ligeramente mejor en clases con menor soporte (Clases 1 y 2) y puede ser más robusto frente a desequilibrios en los datos.

2*Clase	Random Forest				Gradient Boosting			
	Precision	Recall	F1-Score	Support	Precision	Recall	F1-Score	Support
1	0.00	0.00	0.00	2	0.00	0.00	0.00	2
2	0.00	0.00	0.00	11	0.12	0.09	0.11	11
3	0.65	0.81	0.72	104	0.63	0.69	0.66	104
4	0.70	0.60	0.64	82	0.68	0.61	0.64	82
Accuracy			0.67	199			0.62	199
Macro avg	0.34	0.35	0.34	199	0.36	0.35	0.35	199
Weighted avg	0.63	0.67	0.64	199	0.62	0.62	0.62	199

Tabla 14: Comparación de Métricas de clasificación para Random Forest y Gradient Boosting usando Lasso

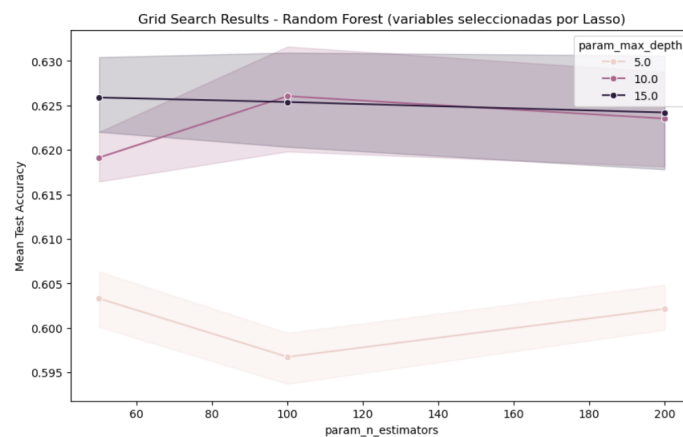


Figura 28: Gráfico de Hiperparámetros para modelo Random Forest con Lasso

El gráfico de hiperparámetros del modelo Random Forest muestra que una profundidad de 15 parece ofrecer el mejor rendimiento en términos de precisión, aunque la profundidad de 10 también es efectiva. Esto sugiere que ambas profundidades son adecuadas, pero la profundidad de 15 puede ser preferible si buscamos la máxima precisión. A partir de 100 estimadores, el rendimiento se estabiliza o incluso disminuye levemente, por lo que un número de estimadores entre 100 y 200 parece ser suficiente.

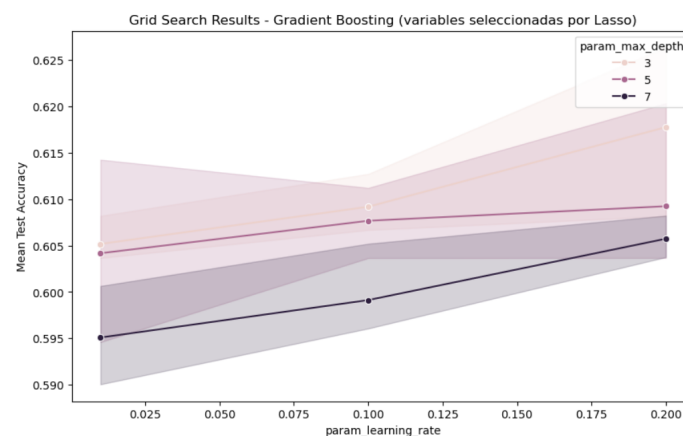


Figura 29: Gráfico de Hiperparámetros para modelo Gradient Boosting usando Lasso

Una profundidad de 3 parece ser la configuración más óptima, proporcionando una precisión media de prueba más alta y con menor variabilidad, lo que sugiere un modelo más estable y menos propenso a sobreajustarse. Las profundidades de 5 y 7 muestran un menor rendimiento y una mayor variabilidad,

especialmente con tasas de aprendizaje bajas, lo cual indica que estas configuraciones podrían llevar a un sobreajuste y menor generalización. Por otra parte la tasa de aprendizaje entre 0.1 y 0.2 es adecuada para maximizar la precisión sin comprometer la estabilidad del modelo. Tasas de aprendizaje menores (0.025 a 0.05) también ofrecen un buen rendimiento, especialmente en configuraciones de baja profundidad.

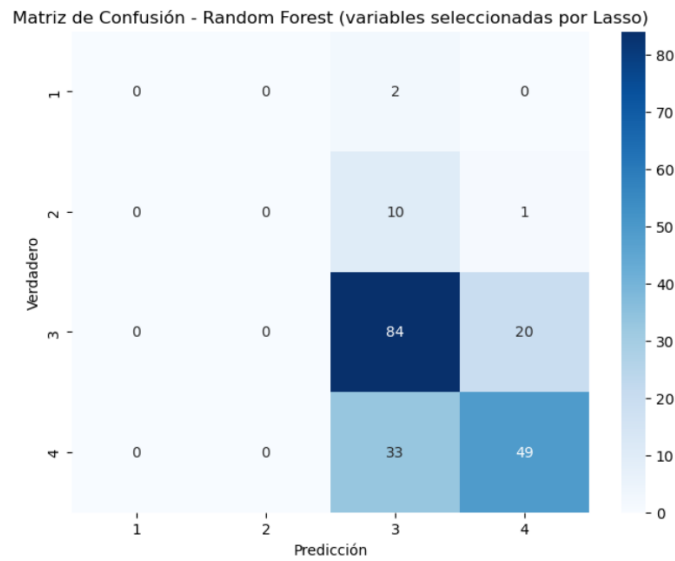


Figura 30: Matriz de Confusión del Modelo Random Forest Usando Lasso

En esta matriz de confusión, el modelo de Random Forest muestra un desempeño razonable en las clases 2, 3 y 4, aunque presenta una confusión considerable entre las clases 3 y 4. La clase 1 es la más difícil de clasificar correctamente para el modelo. La selección de variables por Lasso podría estar limitando el rendimiento del modelo en distinguir entre estas clases. Es posible que algunas variables importantes hayan sido excluidas, lo que puede estar causando que el modelo no pueda separar adecuadamente las clases.

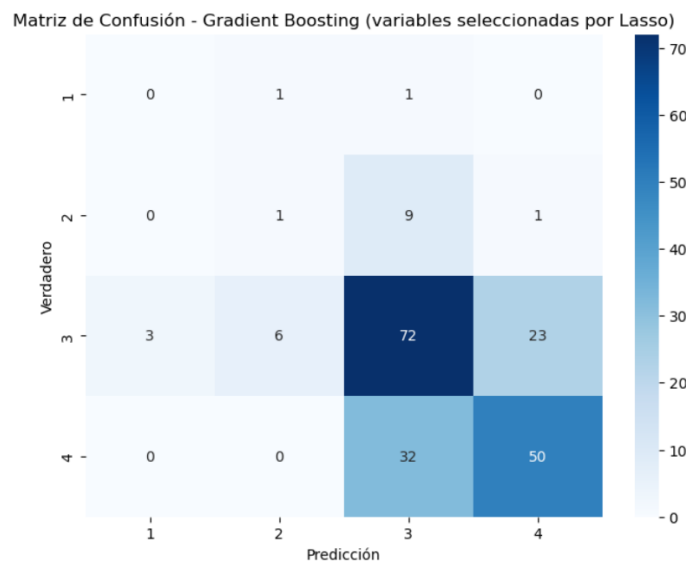


Figura 31: Matriz de Confusión del Modelo Gradient Boosting Usando Lasso

Gradient Boosting tiene un desempeño similar al de Random Forest en términos de precisión y errores de clasificación. Existe una alta confusión entre las clases 3 y 4, posiblemente debido a la similitud en sus características, sugiriendo que el modelo podría beneficiarse de un mayor número de variables o de una mejor selección de las mismas.




Figura 32: Distribución de las Variables de Importancia de los Modelos Random Forest y Gradient Boosting usando Lasso

Las variables emocionales como Miedo (MI), Aislamiento (AI) y Autoestima (AE) juegan un papel importante en ambos modelos. Estas variables son esenciales, ya que posiblemente están influyendo directamente en el desempeño o el estado emocional de los individuos en el contexto de estudio. Esto sugiere que la dimensión emocional es clave para entender los resultados. Las habilidades de lectura comprensiva y seguimiento de información (VCRM y VCSM) son relevantes para ambos modelos, destacando la importancia de las competencias cognitivas en el desempeño o comportamiento observado. Esto implica que estas habilidades específicas tienen una influencia considerable y pueden ser predictoras del éxito en los resultados de la prueba. El tiempo en pantallas (PA) y la disruptividad (DI) también son factores importantes, lo que sugiere que el entorno y el comportamiento juegan un rol en el rendimiento o el estado de los individuos. La exposición a pantallas y la presencia de comportamientos disruptivos pueden estar relacionados con los factores emocionales ya mencionados, afectando el bienestar o el rendimiento. Aunque ambos modelos identifican variables similares como importantes, existen variaciones en la importancia relativa de algunas de ellas, como las competencias específicas de comunicación-aleatorio. Esto puede deberse a las diferentes formas en que Random Forest y Gradient Boosting procesan y ponderan las características.

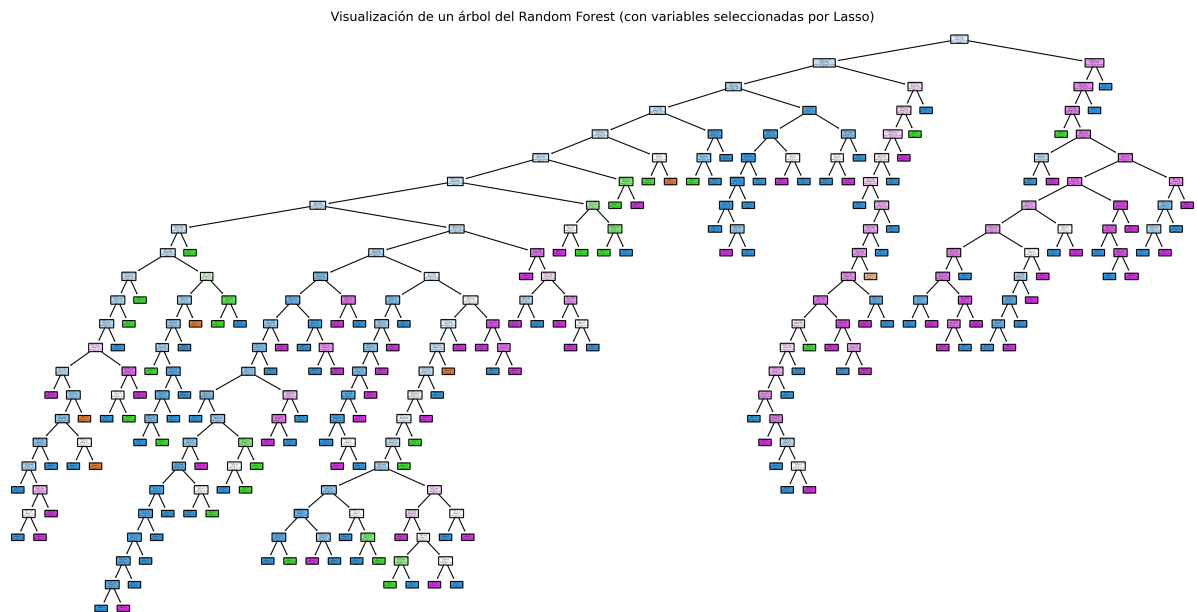


Figura 33: Árbol de Clasificación Random Forest usando Lasso

6. Discusión y Conclusiones

El análisis realizado en este estudio ha permitido identificar varios factores que afectan el rendimiento académico de los estudiantes del Colegio Bilingüe José Max León, posterior a las crisis del COVID 19 utilizando modelos de minería de datos como Random Forest y Gradient Boosting. Los resultados indican que las emociones de miedo, ansiedad y tristeza son determinantes significativos en el desempeño académico. Este hallazgo resalta la importancia de abordar el bienestar emocional de los estudiantes como parte integral de su desarrollo educativo.

Si bien este estudio se centra en el Colegio Bilingüe José Max León, los hallazgos y el modelo propuesto pueden servir como punto de partida para investigaciones similares en otras instituciones educativas. Sin embargo, es importante tener en cuenta que la adaptación del modelo a otros contextos puede requerir modificaciones. Por ejemplo, en instituciones con mayor diversidad socioeconómica, podría ser necesario incluir variables adicionales en el modelo, como el nivel de ingresos familiar o el acceso a tecnología. Asimismo, el proceso de recolección de datos podría variar en función de las características de cada institución.

Es fundamental reconocer que la generalización de los resultados a otras poblaciones puede presentar desafíos. Se necesitan estudios adicionales para validar la aplicabilidad del modelo en diferentes contextos educativos, considerando las particularidades de cada institución y las posibles diferencias culturales. Esta línea de investigación futura permitirá fortalecer la validez externa del estudio y contribuir a la mejora de la educación en un ámbito más amplio.

Las competencias de comunicación y razonamiento aleatorio han emergido como áreas de fortaleza en la mayoría de los grados, sugiriendo que los estudiantes poseen habilidades sólidas en estos aspectos y que se ha consolidado el plan de estudios de la dimensión de área de estadística. Sin embargo, se ha observado un desempeño consistentemente bajo en la resolución de problemas, tanto en lo numérico variacional como en lo geométrico-métrico, lo que señala una clara necesidad de mejorar estas competencias a medida que los estudiantes avanzan en su educación. La disminución del rendimiento en estos tipos de problemas a lo largo de los grados indica que, a pesar de las fortalezas en la comunicación, los estudiantes enfrentan dificultades en la aplicación de sus habilidades en contextos matemáticos más complejos.

Para abordar estos desafíos, se recomienda implementar estrategias pedagógicas que integren el desarrollo de habilidades matemáticas con el bienestar emocional. Esto podría incluir la incorporación de programas de apoyo emocional que ayuden a los estudiantes a gestionar el miedo y otras emociones negativas que pueden interferir en su aprendizaje. Dado que el miedo al fracaso puede llevar a la evitación de tareas desafiantes, limitando la práctica y el desarrollo de habilidades en resolución de problemas, la ansiedad puede afectar la concentración y la memoria de trabajo, dificultando la comprensión de conceptos matemáticos complejos y la tristeza puede disminuir la motivación y el interés por el aprendizaje, impactando el rendimiento en todas las áreas.

Asimismo, se sugiere realizar talleres de habilidades matemáticas específicas, enfocándose en la resolución de problemas de los componentes mencionados, para fortalecer esta competencia desde etapas tempranas, el fortalecer el trabajo de resolución de problemas a partir del modelo CPA de la metodología Singapur en todos los grados podría brindar mejores resultados de esta competencia.

No se debe dejar de lado que contar con una evaluación de las habilidades fundamentales desde el ingreso de los estudiantes permitirá generar planes de acción al departamento y así evitar que se continúe agrandando la brecha entre los estudiantes.

Además, es fundamental realizar un seguimiento continuo de las emociones y el bienestar de los estudiantes, utilizando los resultados de los cuestionarios auxiliares de las pruebas Evaluar para Avanzar, así como las baterías del programa habilmind. Estas herramientas pueden proporcionar información valiosa sobre las condiciones de los estudiantes, permitiendo a los educadores adaptar sus enfoques y estrategias a las necesidades individuales.

Es fundamental establecer en la institución una política de gestión de datos que consolide toda la información académica, sociodemográfica, así como las habilidades fundamentales y socioemocionales de los estudiantes. Esta política permitirá determinar estrategias de apoyo efectivas a lo largo del proceso académico, en lugar de limitarse a la evaluación final. Además, es crucial consolidar los resultados de las pruebas internas y externas desglosadas por competencias y componentes. Este enfoque permitirá identificar de manera precisa las áreas que requieren atención y apoyo, facilitando así la superación de

las dificultades que enfrentan los estudiantes en su trayectoria educativa.

Finalmente, la implementación de un enfoque holístico que combine el desarrollo de competencias académicas con el apoyo emocional puede ser clave para mejorar el rendimiento general de los estudiantes. Esta estrategia no solo busca optimizar el rendimiento en matemáticas, sino también contribuir al desarrollo integral de los estudiantes, preparándolos mejor para los desafíos académicos futuros.

7. Bibliografía

1. Chancúsig Taipicaña, D. M. (2020). Modelo de análisis del rendimiento académico de la Unidad Educativa Personas Con Escolaridad Inconclusa (PCEI) "Monseñor Leonidas Proaño" del cantón Latacunga, a través de minería de datos (Tesis de maestría, Universidad Técnica de Cotopaxi UTC, Ecuador, Latacunga).
2. Orallo, J. H. (s/f). INTRODUCCION A LA MINERIA DE DATOS. Pearson HispanoAmerica Contenido. Recuperado de <https://bookshelf-send.vitalsource.com/books/9788420540917>
3. Chen, M.-S., Han, J., Yu, P. S. (1996). Data mining: an overview from a database perspective. *IEEE Transactions on Knowledge and Data Engineering*, 8(6), 866–883.
4. Durán, E., Costaguta, R. (2007). Minería de datos para descubrir estilos de aprendizaje. *Revista Iberoamericana de Educación*, 42(2), 1–10.
5. Martínez, D. L. L. R., Karanik, M., Giovannini, M., Pinto, N. (2015). Perfiles de rendimiento académico: un modelo basado en minería de datos. *Campus Virtuales*, 4(1), 12–30.
6. Montes, I., Lerner, J. (2011). Rendimiento académico de los estudiantes de pregrado de la Universidad EAFIT – perspectiva cuantitativa. Universidad EAFIT. Medellín, Colombia.
7. Muñoz Ledesma, A. (2016). Modelos para la mejora del rendimiento académico de alumnos de la ESO mediante técnicas de minería de datos. Proyecto de investigación: [Nombre del proyecto].
8. Navarro, R. E. (2003). El rendimiento académico: concepto, investigación y desarrollo. REICE. *Revista Iberoamericana sobre Calidad, Eficacia y Cambio en Educación*, 1(2), 0.
9. Timarán Pereira, S. R., Hernández Arteaga, I., Caicedo Zambrano, S. J., Hidalgo Troya, A., Alvarado Pérez, J. C., et al. (2015). Descubrimiento de patrones de desempeño académico con árboles de decisión en las competencias genéricas de la formación profesional. Bogotá: Ediciones Universidad Cooperativa de Colombia. doi: <http://dx.doi.org/10.16925/9789587600490>.
10. IArtificial.net. (2022). *Random Forest (Bosque Aleatorio)*. Recuperado de <https://www.iartificial.net/random-forest-bosque-aleatorio/>
11. IBM. (2022). *IBM Cognos Analytics*. Recuperado de <https://www.ibm.com/docs/es/cognos-analytics/11.1.0?topic=tests-classification-tree>
12. León, C. J. (2022). *Colegio José Max León*. Recuperado de <https://josemaxleon.habil.tv/co/index/>
13. Tan, P.-N., Steinbach, M., & Kumar, V. (2016). *Introduction to data mining*. Pearson Education India.
14. James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning with Applications in R* (2a ed.). New York: Springer.
15. Durlak, J., Weissberg, R., Dymnicki, A., Taylor, R., & Schellinger, K. (2011). The Impact of Enhancing Students' Social and Emotional Learning: A Meta-Analysis of School-Based Universal Interventions. *Child development*, 82(1), 405–32. doi: 10.1111/j.1467-8624.2010.01564.x
16. UNESCO Office Santiago and Regional Bureau for Education in Latin America and the Caribbean. (2024). *El impacto de la pandemia en los aprendizajes de los estudiantes de América Latina y el Caribe*. UNESCO. Recuperado de <https://unesdoc.unesco.org/ark:/48223/pf0000390609>

17. UNESCO. (2023). *Herramientas para el análisis de datos educativos: Manual para personal de los ministerios de educación*. UNESCO.
Recuperado de <https://unesdoc.unesco.org/ark:/48223/pf0000388399/PDF/388399spa.pdf.multi>