





## Análisis predictivo del rendimiento en Cálculo Diferencial a partir de evaluaciones diagnósticas y propedéuticas en estudiantes de Ingeniería

### Predictive Analysis of Performance in Differential Calculus Based on Diagnostic and Preparatory Assessments in Engineering Students

María de la Luz Delgadillo Torres <sup>a</sup>, Mariana Bárcenas Castañeda <sup>a</sup>, María de los Ángeles Vargas Hernández <sup>a</sup>,  
Arturo Aguilar Pérez <sup>b</sup>

<sup>a</sup>Ingeniería Química y Bioquímica, TecNM/ Tecnológico de Estudios Superiores de Ecatepec, 55210, Ecatepec de Morelos, Estado de México, México.

<sup>b</sup>Centro Tecnológico Aragón, Facultad de Estudios Superiores Aragón, Universidad Nacional Autónoma de México, México.

#### Resumen

El aprendizaje de las matemáticas en la ingeniería constituye la base para desarrollar competencias de razonamiento lógico, modelación y resolución de problemas. Considerando su importancia, el presente estudio tiene como objetivo analizar el impacto de las evaluaciones diagnósticas e introductorias como predictores del rendimiento en Cálculo Diferencial en estudiantes de nuevo ingreso a ingeniería del Tecnológico de Estudios Superiores de Ecatepec (TESE). Aplicando tres momentos de evaluación: examen inicial (EI), evaluación al término del curso propedéutico (EC) y evaluación final de la asignatura de Cálculo Diferencial (ED). Los resultados mostraron una correlación positiva significativa entre las fases, con un incremento progresivo en las calificaciones y tamaños de efecto grandes según la prueba  $t$  y el índice de Cohen. El modelo de regresión lineal múltiple presenta 61.6 % de variabilidad en el desempeño final, confirmando la pertinencia de EI y EC como predictores confiables. Estos hallazgos validan la utilidad de implementar diagnósticos tempranos y cursos propedéuticos como herramientas para identificar a estudiantes en riesgo y fortalecer las estrategias docentes.

**Palabras clave:** Evaluación Diagnóstica; Análisis Longitudinal; Regresión Múltiple; Matemáticas en Ingeniería; Análisis Estadístico.

#### Abstract

The learning of mathematics in engineering constitutes the foundation for developing competencies in logical reasoning, modeling, and problem-solving. Considering its importance, the present study aims to analyze the impact of diagnostic and introductory assessments as predictors of performance in Differential Calculus among first-year engineering students at the Tecnológico de Estudios Superiores de Ecatepec (TESE). Three evaluation stages were applied: initial exam (EI), assessment at the end of the preparatory course (EC), and final evaluation of the Differential Calculus course (ED). The results showed a significant positive correlation among the phases, with a progressive increase in grades and large effect sizes according to the  $t$ -test and Cohen's  $d$  index. The multiple linear regression model explained 61.6% of the variability in final performance, confirming the relevance of EI and EC as reliable predictors. These findings validate the usefulness of implementing early diagnostics and preparatory courses as tools to identify at-risk students and strengthen teaching strategies.

**Keywords:** Diagnostic Assessment; Longitudinal Analysis; Multiple Regression; Mathematics in Engineering; Statistical Analysis.

\*Autor para la correspondencia: [ldelgadillo@tese.edu.mx](mailto:ldelgadillo@tese.edu.mx)

Correo electrónico: [mbarcenast@tese.edu.mx](mailto:mbarcenast@tese.edu.mx) (Mariana Bárcenas-Castañeda), [maria\\_vargas@tese.edu.mx](mailto:maria_vargas@tese.edu.mx) (María de los Ángeles Vargas-hernández), [arturoaguilar855@aragon.unam.mx](mailto:arturoaguilar855@aragon.unam.mx) (Arturo Aguilar-Pérez).

## 1. Introducción

La matemática constituye un pilar fundamental en la formación de los ingenieros, al ser una disciplina que permite desarrollar competencias de pensamiento lógico, modelación y resolución de problemas en contextos diversos. Su dominio es indispensable para comprender asignaturas como cálculo, álgebra lineal y ecuaciones diferenciales, las cuales sustentan la aplicación de herramientas computacionales, la optimización de procesos y la interpretación de fenómenos en áreas de la ingeniería, la física y la informática, entre otras (Ryan et al., 2025).

En la educación superior, el cálculo diferencial se ha identificado como una de las asignaturas con mayores índices de reprobación y deserción, situación que obedece a la heterogeneidad de los conocimientos previos adquiridos en el nivel medio superior y a la dificultad que enfrentan los estudiantes para establecer conexiones entre sus saberes y las nuevas demandas académicas. Esta problemática afecta la permanencia y éxito en los programas de ingeniería, lo cual justifica la necesidad de contar con mecanismos de predicción temprana que permitan identificar a los estudiantes en riesgo de no aprobar la asignatura para orientarlos de manera oportuna (De Winter & Dodou, 2011).

Las evaluaciones diagnósticas y los cursos propedéuticos son herramientas que manifiestan las fortalezas y debilidades de los estudiantes en el área matemática. Diversas investigaciones han demostrado que los exámenes diagnósticos aplicados en el inicio del primer año universitario son predictores significativos del rendimiento académico, al mismo tiempo aportan información útil para la planeación didáctica (Lee et al., 2008; Hieb et al., 2015). En este sentido, la aplicación de pruebas diagnósticas específicas ha permitido evidenciar que los resultados de los estudios previos no siempre explican de manera suficiente el desempeño en matemáticas avanzadas, por ello, es importante implementar instrumentos de evaluación temprana para fortalecer sus conocimientos (Mahata et al., 2025).

Por otro lado, el análisis de errores matemáticos detectados en pruebas diagnósticas constituye un recurso complementario que posibilita mejorar los procesos de retroalimentación formativa y optimizar las estrategias pedagógicas en ingeniería. La clasificación estructurada de estos errores contribuye a fortalecer la enseñanza y a proponer intervenciones focalizadas, incrementando así la pertinencia del proceso educativo (García, 2025).

Bajo este contexto, el presente estudio se orienta al análisis del impacto de las evaluaciones diagnósticas y propedéuticas como predictores del rendimiento en cálculo diferencial en estudiantes de nuevo ingreso a la carrera de ingeniería. Para tal fin, se aplicaron tres momentos de evaluación en el Tecnológico de Estudios Superiores de Ecatepec (TESE): un examen inicial (EI), la evaluación al término del curso propedéutico de matemáticas (EC) y la evaluación final de la

asignatura de cálculo diferencial (ED). Los datos fueron procesados mediante estadística descriptiva, pruebas de hipótesis, análisis de medidas repetidas y regresión múltiple, con el propósito de construir un modelo predictivo que aporte evidencia empírica y que permita fundamentar estrategias docentes y curriculares encaminadas a mejorar la eficiencia terminal y reducir los índices de reprobación en ingeniería.

### 1.1. Procedimientos estadísticos

#### 1.1.1. Coeficiente Alfa de Cronbach

El método de consistencia interna es el más utilizado para estimar la fiabilidad de pruebas, escalas o test; cuando se implementan diferentes reactivos que midan el mismo atributo. El coeficiente Alfa de Cronbach es un modelo de consistencia interna, ampliamente utilizado para establecer la confiabilidad de las correlaciones entre las variables que conforman una escala de apreciación. En la ecuación 1, se muestra la fórmula de obtención del coeficiente alfa de Cronbach (Ledesma et al., 2002; González-Pazmiño, 2015):

$$\alpha = \frac{K}{K-1} \left[ 1 - \frac{\sum S_i^2}{S_T^2} \right] \quad (1)$$

Donde:  $\alpha$  es el Coeficiente de confiabilidad,  $K$  representa el número de ítems del instrumento,  $\sum S_i^2$  es la sumatoria de las varianzas de los ítems y  $S_T^2$  es la varianza total del instrumento.

La fiabilidad calculada dependerá del número y la covarianza entre los ítems; es decir, el coeficiente calcula la fiabilidad del test en función de dos términos: el número de ítems (longitud de la prueba) y la proporción de la varianza total de la prueba generada por la covarianza entre sus reactivos (Ledesma et al., 2002). Cabe resaltar que, la consistencia interna se considera aceptable cuando se obtiene un valor de Alfa de Cronbach dentro del intervalo de 0.7-1, en donde el resultado varía con base a la población analizada. Es decir, se considera una relación débil cuando  $\alpha < 0.7$ , aceptable un  $\alpha \geq 0.7$ , bueno si  $\alpha \geq 0.8$  y excelente si  $\alpha \geq 0.9$  (Tuapanta et al., 2017; Oviedo et al., 2005).

#### 1.1.2. Variables descriptivas

##### 1.1.2.1. Medidas de tendencia central

Las medidas de tendencia central son parámetros estadísticos empleados para resumir un conjunto de valores, expresado en un solo término numérico. Asimismo, como su nombre lo indica, es el elemento ubicado en el centro del conjunto de valores; las medidas comúnmente utilizadas son: media, mediana y moda, las cuales se describen a continuación (Quevedo, 2011):

a) **Media.** La media o promedio aritmético ( $\mu$ ), es la suma de todos los datos dividido entre el número de datos; tal como se muestra en la Ecuación 2.

$$\mu = \frac{\sum_1^N X_i}{N} = \frac{X_1 + X_2 + X_3 + \dots + X_n}{N} \quad (2)$$

En la cual,  $\sum_1^N X_i$  es la suma del dato 1 hasta N datos y  $N$  es el Número total de datos.

- b) **Mediana.** Es el valor de la variable que se encuentra en la posición central, al ordenar los valores de acuerdo con su magnitud.
- c) **Moda.** Es el valor que se repite con mayor frecuencia en la serie de datos.

### 1.1.2.2. Medidas de variabilidad

Las medidas de variabilidad o dispersión son números que indican la movilidad entre la variable con respecto a otra. Los valores de variabilidad son utilizados para resumir en un valor único, la dispersión presente entre una serie de datos. Las medidas de variabilidad más comunes son: rango, desviación estándar y varianza (Quevedo, 2011).

- a) **Rango.** Es la diferencia entre la variable de mayor valor y la de menor valor. Es decir; Máximo-Mínimo.
- b) **Varianza.** Se simboliza como  $\sigma^2$  o  $S^2$ , se define como la media de las diferencias cuadradas de  $n$  elementos con respecto a su media aritmética, tal como se presenta en la Ecuación 3.

$$S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{N} \quad (3)$$

En donde  $X_i$  es la observación número  $i$  de la variable  $\bar{X}$  es el promedio o media de la variable y  $N$  es el número total de datos.

- c) **Desviación estándar.** Medida de dispersión que indica la diferencia con respecto a la media. Específicamente, es la raíz cuadrada de la varianza, Ecuación 4:

$$S = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{N}} \quad (4)$$

### 1.1.3. Prueba de hipótesis

La hipótesis de investigación es una posible respuesta a la pregunta de indagación; dicha respuesta, puede ser verdadera o falsa. Por lo cual, la investigación se desarrolla para calcular el valor correspondiente a la hipótesis de investigación; esto es, se efectúan estudios para obtener resultados que den respuesta a la pregunta de investigación y que al mismo tiempo contribuyan para establecer si las suposiciones planteadas son refutadas o aceptadas. Para demostrar la validez de una hipótesis, es necesario establecer el termino de hipótesis estadísticamente (Inzunsa-Jiménez, 2013; Escalante, 2010).

En el mismo orden, cambiar el enfoque de Neyman-Pearson, instituye que las pruebas de hipótesis se plantean como un proceso de decisión de dos conjeturas. Es decir, se considera una hipótesis alternativa ( $H_1$ ) como la negación o propuesta contraria a la hipótesis nula ( $H_0$ ). Las regiones de rechazo y aceptación se definen de acuerdo con la distribución muestral del estadístico de prueba y considerando los siguientes tipos de errores (Inzunsa-Jiménez, 2013; Escalante, 2010):

- **Error tipo 1:** Rechazar  $H_0$  cuando  $H_0$  sea verdadera. Es decir, la probabilidad dependerá del nivel de significancia;  $P(\text{rechazar } H_0 | H_0 \text{ es cierta}) = \alpha$  (nivel de significancia).
- **Error tipo 2:** No rechazar  $H_0$  cuando  $H_0$  sea falsa. Es decir, la probabilidad dependerá del nivel de significancia;  $P(\text{rechazar } H_0 | H_0 \text{ es falsa}) = \beta$

El nivel de significancia se determina antes de realizar la prueba estadística y permite establecer los límites que separan la región de rechazo y la de no rechazo de la hipótesis nula ( $H_0$ ). Si el valor obtenido en la prueba cae dentro de la región de rechazo, se concluye que la  $H_0$  debe rechazarse; en caso contrario, no se rechaza la hipótesis nula (Inzunsa-Jiménez, 2013; Escalante, 2010).

### 1.1.4. Prueba t de Student

La prueba t de Student (Ecuación 5) para muestras relacionadas es un procedimiento estadístico ampliamente utilizado para comparar dos dimensiones estudiadas sobre el mismo grupo de estudio. Permitiendo establecer si la diferencia observada entre las medias alcanzadas en dos momentos de la valoración es significativa, considerando la hipótesis nula como la igualdad de medias. En el ámbito educativo, se emplea para determinar el efecto de una intervención didáctica o curso propedéutico al diferenciar los resultados previos y posteriores de los estudiantes en una misma asignatura (Kim, 2015). La fórmula general para el estadístico  $t$  en muestras dependientes es:

$$t = \frac{\bar{D}}{\frac{S_D}{\sqrt{n}}} \quad (5)$$

En la cual,  $\bar{D}$  es la media de las diferencias entre pares de observaciones,  $S_D$  desviación estándar de las diferencias y  $n$  el número de pares de observaciones.

### 1.1.5. Tamaño del efecto de Cohen (d)

El tamaño del efecto es una medida estadística que cuantifica la magnitud de las diferencias entre dos grupos o condiciones de estudio. El índice  $d$  de Cohen (Ecuación 6), se interpreta de acuerdo con los siguientes rangos:  $d=0$  a  $d=0.4$  corresponde a un efecto pequeño,  $d \geq 0.5$  a un efecto mediano y  $d \geq 0.8$  un efecto grande. Su empleo en investigaciones educativas facilita la identificación del impacto real de las estrategias de enseñanza sobre el rendimiento académico (Lakens, 2013; Sullivan-Feinn, 2012).

$$d = \frac{\bar{X}_1 - \bar{X}_2}{S_p} \quad (6)$$

Considerando que,  $\bar{X}_1, \bar{X}_2$  son las medias de los dos grupos o mediciones y  $S_p$  es la desviación estándar combinada.

### 1.1.6. Prueba de normalidad Shapiro–Wilk

La prueba de Shapiro–Wilk (W), es implementada para verificar el supuesto de normalidad en los datos, especialmente cuando el tamaño de la muestra es pequeño o moderado. Evaluando la hipótesis nula considerando los valores de distribución normal (Ecuación 7). Un valor  $p \geq 0.05$  indica que no se rechaza la normalidad, mientras que un valor

inferior indica desviaciones significativas. Su aplicación es fundamental para determinar la pertinencia de las pruebas paramétricas en la comparación de medias (Razali-Wah, 2011).

$$W = \frac{[\sum_{i=1}^n a_i X_{(i)}]^2}{\sum_{i=1}^n (X_i - \bar{X})^2} \quad (7)$$

Sabiendo que,  $X_{(i)}$  son los valores ordenados de menor a mayor,  $a_i$  coeficientes obtenidos de los valores esperados de una distribución normal estándar y  $n$  es el número de observaciones.

*1.1.7. Prueba de Friedman*

La prueba de Friedman (Ecuación 8), es una técnica estadística no paramétrica que se utiliza para comparar tres o más mediciones relacionadas sobre un mismo grupo de sujetos, asimismo, permite identificar si existen diferencias significativas entre las medianas de las mediciones. En investigaciones educativas, se utiliza para evaluar la evolución del rendimiento académico en diferentes momentos de un curso o programa (Eisinga et al., 2017).

$$x_F^2 = \frac{12}{nk(k+1)} \sum_{j=1}^k R_j^2 - 3n(k+1) \quad (8)$$

Considerando que,  $k$  es el número de condiciones o fases y  $R_j$  es la suma de rangos para la condición  $j$ .

*1.1.8. Coeficiente de concordancia de Kendall (W)*

El coeficiente de concordancia de Kendall (W) es implementado para determinar que tanto coinciden en la valoración varios sujetos en diferentes fases de medición aplicada al mismo conjunto de estudio. Su valor varía entre 0 y 1, donde un valor cercano a la unidad refleja una alta concordancia. El coeficiente (Ecuación 9), permite establecer la consistencia de los resultados obtenidos en distintos momentos de evaluación y valorar si la progresión de los estudiantes mantiene un patrón estable (Legendre, 2005; Tomczak & Tomczak, 2014).

$$W = \frac{12S}{k^2(n^3 - n)} \quad (9)$$

El termino  $S$  representa la suma de cuadrados de las desviaciones de las sumas de los rangos respecto a su media (Ecuación 10).

$$S = \sum_{j=1}^k \left[ R_j - \frac{n(k+1)}{2} \right]^2 \quad (10)$$

*1.1.9. Regresión lineal múltiple y colinealidad (VIF)*

La regresión lineal múltiple es un método estadístico que permite predecir el valor de una variable dependiente a partir de la combinación de dos o más variables independientes. El ajuste del modelo se realiza mediante el procedimiento de mínimos cuadrados ordinarios y su capacidad explicativa se mide con el coeficiente de determinación ( $R^2$ ), el cual señala la proporción de la variabilidad de la variable dependiente

atribuible a los predictores. Cuando existe una alta correlación entre las variables independientes puede surgir el problema de colinealidad, afectando la interpretación de los coeficientes estimados. Para detectar este problema se calcula la inflación de la varianza (VIF), en el cual los valores mayores a 10 evidencian una colinealidad considerable. El modelo de regresión múltiple se define en la Ecuación 11 (Akinwande et al., 2015; Hair et al., 2019):

$$\hat{Y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 \quad (11)$$

En donde  $\hat{Y}$  es la variable dependiente,  $\beta_0$  constante (intercepto del modelo),  $\beta_1$  y  $\beta_2$  coeficiente de regresión,  $x_1$  y  $x_2$  variables independientes. Los coeficientes y la constante se calculan por medio de mínimos cuadrados ordinarios (OLS), como se presenta en las Ecuaciones 12.

$$\sum Y = n\beta_0 + \beta_1 \sum x_1 + \beta_2 \sum x_2 \quad (12a)$$

$$\sum x_1 Y = \beta_0 \sum x_1 + \beta_1 \sum x_1^2 + \beta_2 \sum x_1 x_2 \quad (12b)$$

$$\sum x_2 Y = \beta_0 \sum x_2 + \beta_1 \sum x_1 x_2 + \beta_2 \sum x_2^2 \quad (12c)$$

La Ecuación 12a representa la suma de los valores observados de la variable dependiente ( $Y$ ) en función de la constante y las variables independientes ponderadas por sus coeficientes. La Ecuación 12b se obtiene al multiplicar la ecuación del modelo (Ecuación 11) por  $x_1$ , obteniendo la relación entre  $Y$  y la primera variable independiente  $x_1$ . Finalmente, la Ecuación 12c se obtiene de manera análoga al multiplicar la Ecuación 11 por  $x_2$ , estableciendo la relación entre  $Y$  y la segunda variable independiente  $x_2$ . Estas tres ecuaciones simultáneas conforman el sistema normal de ecuaciones que permite estimar los parámetros  $\beta_0$ ,  $\beta_1$  y  $\beta_2$  mediante la resolución algebraica del modelo de regresión lineal múltiple.

Donde “ $Y$ ” es la variable de respuesta introductorio. Considerando el error aleatorio, calculado como (Ecuación 13):

$$e_i = Y_i - \hat{Y}_i \quad (13)$$

En el mismo tenor, la bondad de ajuste se evalúa con el coeficiente de determinación (Ecuación 14). Estadístico que mide la proporción de la variabilidad total de la variable dependiente que es explicada por el modelo de regresión. Su valor es de 0 a 1, donde valores cercanos a la unidad indican un mayor ajuste del modelo a los datos observados.

$$R^2 = 1 - \frac{SSE}{SST} \quad (14)$$

El termino  $SSE$  es la suma de cuadrado del error y  $SST$  la suma total de cuadrados.

La colinealidad se analiza mediante el factor de inflación de varianza (VIF), calculado por medio de la Ecuación 15.

Valores de VIF cercanos a 1 indican ausencia de colinealidad, mientras que valores superiores a 10 sugieren un nivel de colinealidad elevado. El VIF se utiliza para verificar que las variables independientes aporten información complementaria y no redundante, asegurando la estabilidad de los coeficientes de regresión y la validez de las inferencias (Akinwande et al., 2015; Hair et al., 2019).

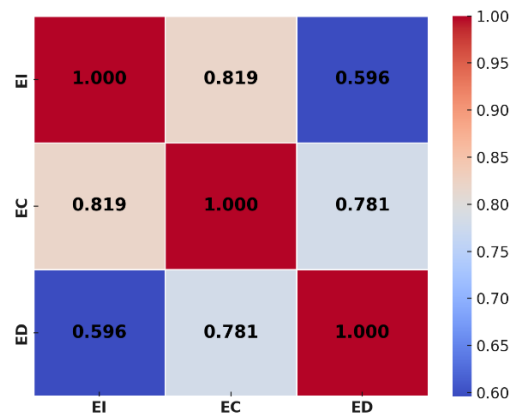
$$VIF = \frac{1}{1 - R^2} \quad (15)$$

## 2. Materiales y Método

La muestra de estudio está integrada por 26 estudiantes de nuevo ingreso a ingeniería del Tecnológico de Estudios Superiores de Ecatepec (TESE), institución perteneciente al Tecnológico Nacional de México (TecNM). El estudio consistió en aplicar un examen inicial (EI), evaluación al término curso introductorio de matemáticas (EC) y evaluación al final de curso de Cálculo Diferencial (ED). Para el criterio de apreciación se aplicó una rubrica de evaluación que considera aspectos generales como: desarrollo algebraico, aplicación de fórmulas y obtención del correcto resultado.

La rúbrica de evaluación fue validada estadísticamente, por medio del software Minitab-19, obteniendo una consistencia interna de 0.72 de Coeficiente Alfa de Cronbach, lo cual indica que existe una aceptable relación entre los parámetros y los niveles de valoración. Adicionalmente se calculó la matriz de correlación de Pearson de los tres momentos de valoración (Tabla 1). En la cual, se observa una fuerte correlación positiva entre EI-EC ( $r=0.819$ ), indicativo de que los educandos que poseen una evaluación inicial satisfactoria alcanzaron un promedio aprobatorio al término del curso introductorio (EC). De forma semejante, la correlación entre EC-ED es elevada ( $r=0.781$ ), confirmando que esta fase es un predictor sólido del rendimiento posterior. En cambio, la correlación entre EI-ED fue moderada ( $r=0.596$ ), lo cual refleja que el diagnóstico por sí solo no predice con suficiente fuerza el desempeño final. Los valores positivos de Pearson indican que los momentos de la valoración poseen una relación directa. La determinación del Coeficiente Alfa de Cronbach y la validez de relación Pearson, establecen la pertinencia y confiabilidad del instrumento aplicado para la determinación temprana del desempeño en Cálculo Diferencial.

Tabla 1. Matriz de correlación de Pearson (diagrama de calor).



Para el tratamiento muestral se calculó análisis de variables descriptivas, prueba de hipótesis, normalidad de diferencias, análisis de medidas repetidas y construcción del modelo predictivo, utilizando el software Minitab-19.


La Figura 1, presenta de forma esquemática el procedimiento experimental.



Figura 1. Procedimiento experimental.


### 3. Resultados y Discusión

Utilizando la rúbrica de evaluación se determinó las calificaciones de forma individual, para las evaluaciones iniciales (EI y EC) y valoración al término del curso de Cálculo Diferencial (ED) como se muestra en la Gráfica 1.



Gráfica 1. Evaluación individual en cada etapa de estudio.

Las evaluaciones, mostraron que en la etapa de evaluación inicial (EI) 65.4% de los estudiantes poseen calificaciones que se encuentran dentro del intervalo de 3-6 puntos, la evaluación al término del curso introductorio (EC) 61.6% de los estudiantes obtuvo de 5-7 y final del curso de Cálculo Diferencial 57.7% de los educandos alcanzó de 6-9 puntos (Gráfica 2).



Gráfica 2. Distribución de calificaciones por fase.

La Gráfica 2, es un diagrama de caja que muestra la evolución de las calificaciones alcanzadas en cada etapa de estudio. En la cual, se aprecia un desplazamiento ascendente, lo cual confirma la mejora progresiva del grupo.

Con las evaluaciones, se calcularon los estadísticos descriptivos de las tres etapas analizadas (Tabla 2). Se aprecia un incremento progresivo en la media y mediana de las calificaciones del examen inicial, la evaluación final del propedéutico y la calificación final del curso de Cálculo Diferencial. Mientras que la calificación máxima fue mayor

en ED comparada con la evaluación inicial. La desviación estándar se mantiene aproximadamente en 2,0 unidades, indicando que las calificaciones de los estudiantes se dispersan alrededor de  $\pm 2$  puntos con respecto a la media. Asimismo, los valores cercanos a 2,0 de la desviación estándar indica que la disparidad del grupo se mantuvo relativamente constante a lo largo de todo el proceso.

Tabla 2. Estadística descriptiva.

	Media	Mediana	SD	Calificación Mínima	Calificación Máxima
EI	4.5	5	2.08	0.0	7
EC	6.15	6	1.99	2.0	10
ED	4.18	7.33	2.23	3.0	10

Consecutivamente, se efectuó la interacción entre las etapas EI-EC, EC-ED y EI-ED (Tabla 3) para calcular la prueba t y p empleando un nivel de significancia  $\alpha < 0.05$  y 25 grados de libertad ( $gl = n - 1$ , donde  $n = 26$ ). Considerando el efecto de Cohen (0.2 pequeño, 0.5 mediano, 0.8 grande). Adicionalmente, se determinó el cambio promedio entre las etapas (Media-Dif). La Tabla 3, muestra incrementos significativos en todas las comparaciones. Específicamente, la interacción EI-EC alcanzó un incremento +1.65, con  $p = 0$  y  $d = 1.34$ , EC-ED obtuvo un aumento +1.03,  $p = 0.001$  y  $d = 0.72$ , mientras que, EI-ED presentó un incremento de +1.38,  $p = 0$  y  $d = 1.38$ . Los tamaños del efecto de Cohen son grandes, confirmando que las mejoras en el desempeño académico son significativas y relevantes.

Tabla 3. Prueba t, p y Cohen.

Interacción	t	p	IC 95% Baja	IC 95% Alta	Media-Dif	Cohen (d)
EI-EC	-6.85	0.000	1.18	2.13	1.65	1.34
EC-ED	-3.69	0.001	0.48	1.57	1.03	0.72
EI-ED	-7.03	0.000	1.93	3.43	2.68	1.38

Por otro lado, la Tabla 4, presenta los coeficientes de ajuste de normalidad Shapiro-Wilk (W) para las diferencias entre fases, considerando un nivel de significancia de  $p > 0.05$  (normalidad aceptada) y 26 como número de diferencias evaluadas. Los resultados revelan que la diferencia entre EC-EI no sigue una distribución normal ( $W = 0.89$ ,  $p = 0.008$ ), por el contrario, ED-EC ( $W = 0.98$ ,  $p = 0.953$ ) y ED-EI ( $W = 0.97$ ,  $p = 0.543$ ) siguen una distribución normal, asegurando que los resultados de la prueba t son válidos y confiables.

Tabla 4. Normalidad de diferencias (Shapiro-Wilk).

Diferencia	W	p
EC-EI	0.89	0.008
ED-EC	0.98	0.953
ED-EI	0.97	0.543

También se realizó el análisis de medidas repetidas por medio de la prueba de Friedman ( $X^2$ ) y el coeficiente de concordancia de Kendall's (W). Obteniendo un valor de

Friedman  $X^2 = 34.93$  y  $p < 0.001$ , implementado  $gl=2$  y  $\alpha < 0.05$ . Mientras que, el coeficiente de concordancia es  $W=0.672$  obtenido por medio del número de estudiantes ( $N=26$ ) y número de fases ( $k=3$ ), la proximidad a la unidad de  $W$  indica una concordancia alta, sustancial y un efecto de tamaño grande, consiste con el orden de las fases EI, EC y ED. Lo cual, se confirma por medio de la prueba ANOVA, cuyo valor es  $F(2,50) = 39.03$  con  $p < 0.001$ .

**3.1. Predicción académica**

Mediante la aplicación de las ecuaciones 11 y 12, correspondientes al método de regresión lineal múltiple, se definió a  $\hat{Y}$  como la calificación esperada al concluir la asignatura de Cálculo Diferencial (ED),  $x_1=EI$  y  $x_2=EC$ . Obteniendo  $\beta_0 = 1.688$  ( $p = 0.090$ ),  $\beta_1 = -0.141$  ( $p = 0.566$ ) y  $\beta_2 = 0.995$  ( $p = 0.0006$ ); en los cuales  $\beta_0$  y  $\beta_1$  no se consideran significativos debido a que  $p > \alpha$ . Alcanzando una bondad de ajuste  $R^2 = 0.616$ , es decir, que el modelo explica el rendimiento final en cálculo vectorial en un 61.6%; el cual se considera alto para investigaciones educativas (Ozili,2023). El modelo predictor, posee un factor de inflación de varianza  $VIF=17$ , indicativo de una colinealidad muy alta entre EI y EC para predecir ED ( $\hat{Y}$ ) por medio de la Ecuación 16.

$$\hat{Y} = 1.688 - 0.141(EI) + 0.995(EC) \quad (16)$$

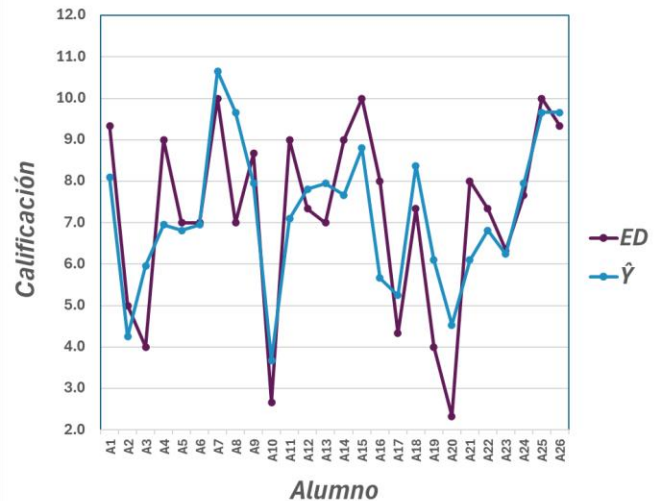
La Ecuación 16 permite realizar una predicción temprana del desempeño en cálculo diferencial a partir de las valoraciones iniciales. La Tabla 5 presenta el cálculo de las predicciones por medio de la Ecuación 16 y la obtención de la desviación correspondiente a cada participante, obtenidos mediante la aplicación de la Ecuación 13.

Tabla 5. Predicción y valores de desviación individual.

Alumno	EI	EC	ED	$\hat{Y}$	$e_i$
A1	4	7	9.3	8.1	1.2
A2	3	3	5.0	4.3	0.8
A3	5	5	4.0	6.0	-2.0
A4	5	6	9.0	7.0	2.0
A5	6	6	7.0	6.8	0.2
A6	5	6	7.0	7.0	0.0
A7	7	10	10.0	10.7	-0.7
A8	7	9	7.0	9.7	-2.7
A9	5	7	8.7	7.9	0.7
A10	0	2	2.7	3.7	-1.0
A11	4	6	9.0	7.1	1.9
A12	6	7	7.3	7.8	-0.5
A13	5	7	7.0	7.9	-0.9
A14	7	7	9.0	7.7	1.3
A15	6	8	10.0	8.8	1.2
A16	0	4	8.0	5.7	2.3
A17	3	4	4.3	5.2	-0.9

A18	2	7	7.3	8.4	-1.0
A19	4	5	4.0	6.1	-2.1
A20	1	3	2.3	4.5	-2.2
A21	4	5	8.0	6.1	1.9
A22	6	6	7.3	6.8	0.5
A23	3	5	6.3	6.2	0.1
A24	5	7	7.7	7.9	-0.3
A25	7	9	10.0	9.7	0.3
A26	7	9	9.3	9.7	-0.3

Con los valores de la Tabla 5, se construyó la Gráfica 3. En la cual, se aprecia la comparación entre las calificaciones reales alcanzadas en la asignatura de Cálculo Diferencial (ED) y el aprovechamiento estimado ( $\hat{Y}$ ) por medio del modelo de regresión lineal múltiple. En general, las curvas presentan una tendencia semejante, confirmando que el modelo explica apropiadamente la variabilidad de los datos ( $R^2 = 0.616$ ). Asimismo, se observa diferencias entre las curvas correspondientes a los residuos calculados de forma individual, los cuales no interfieren significativamente para predecir el comportamiento del grupo. La tendencia semejante entre las curvas respalda la pertinencia del uso de evaluaciones diagnósticas (EI) y del curso introductorio (EC) como predictores tempranos del rendimiento terminal de la asignatura de Cálculo Diferencial.



Gráfica 3. Comparación entre desempeño académico (ED) y valores estimados ( $\hat{Y}$ ).

**4. Conclusiones**

La presente investigación aporta evidencia sobre la pertinencia de las evaluaciones iniciales como predictores del desempeño en Cálculo Diferencial en estudiantes de nuevo ingreso a ingeniería. La aplicación conjunta de pruebas estadísticas paramétricas y no paramétricas, junto con el cálculo del coeficiente Alfa de Cronbach y la correlación de Pearson, permitió garantizar la consistencia interna de los instrumentos y la validez de las inferencias. Los resultados evidencian que las evaluaciones diagnósticas y propedéuticas

constituyen un recurso eficaz para predecir el rendimiento terminal en Cálculo Diferencial, permitiendo efectuar intervenciones tempranas y oportunas en estudiantes que se encuentran en riesgo académico. Asimismo, el modelo predictivo propuesto representa una aportación metodológica que puede orientar la planeación curricular y la toma de decisiones pedagógicas en ingeniería.

## 5. Referencias

- Akinwande, M., Dikko, H. & Samson, A. (2015). Variance Inflation Factor: As a condition for the inclusion of suppressor variable(s) in regression analysis. *Open Journal of Statistics*, 5(7), 754–767. <https://doi.org/10.4236/ojs.2015.57075>
- De Winter, J. & Dodou, D. (2011). Predicting academic performance in engineering using high school exam scores. *International Journal of Engineering Education*, 27(6), 1343–1351. [https://www.ijee.ie/articles/Vol27-6/19\\_ijee2519ns.pdf](https://www.ijee.ie/articles/Vol27-6/19_ijee2519ns.pdf)
- Escalante C. (2010). Prueba de hipótesis frente a intervalos de confianza. *Ciencia y Tecnología para la salud Visual y Ocular*, 8(2), 145-149.
- Eisinga, R., Heskes, T., Pelzer, B., & Te Grotenhuis, M. (2017). Exact p-values for pairwise comparison of Friedman rank sums, with application to comparing classifiers. *BMC Bioinformatics*, 18(1), 68.
- García, M. (2025). Classification of common mathematical errors using the AHP process for formative assessment in engineering students. *Education Sciences*, 15(7), 827. <https://doi.org/10.3390/educsci15070827>
- González A. & Pazmiño M. (2015). Cálculo e interpretación del Alfa de Cronbach para el caso de validación de la consistencia interna de un cuestionario, con dos posibles escalas tipo Likert. *SSOAR Open Access Repository*. 2(1), 62-67.
- Hair, J., Black, W., Babin, B., & Anderson, R. (2019). *Multivariate data analysis* (8th ed.). Cengage Learning.
- Hieb, J., Lyle, K., Ralston, P. & Chariker, L. (2015). Predicting performance in a first engineering calculus course. *International Journal of Mathematical Education in Science and Technology*, 46(1), 40–55. <https://doi.org/10.1080/0020739X.2014.936976>
- Inzuna S. & Jiménez J. (2013). Caracterización del razonamiento estadístico de estudiantes universitarios acerca de las pruebas de hipótesis. *Revista latinoamericana de investigación matemática educativa*, 6(2), 179-211. <https://doi.org/10.12802/relime.13.1622>
- Kim, T. (2015). T test as a parametric statistic. *Korean Journal of Anesthesiology*, 68(6), 540–546. <https://doi.org/10.4097/kjae.2015.68.6.540>
- Lakens, D. (2013). Calculating and reporting effect sizes to facilitate cumulative science: A practical primer for t-tests and ANOVAs. *Frontiers in Psychology*, 4, 863. <https://doi.org/10.3389/fpsyg.2013.00863>
- Ledesma, R., Molina G. & Valero P. (2002). Análisis de consistencia interna mediante Alfa de Cronbach: un programa basado en gráficos dinámicos. *Psico-USF*, 7(2), 143-152.
- Lee, S. Harrison, M., Pell, G. & Robinson, C. (2008). Predicting performance of first year engineering students and the importance of assessment tools therein. *Journal of the Higher Education Academy*, 3(1), 44–51. <https://doi.org/10.11120/ened.2008.03010044>
- Legendre, P. (2005). Species associations: The Kendall coefficient of concordance revisited. *Journal of Agricultural, Biological, and Environmental Statistics*, 10(2), 226–245. <https://doi.org/10.1198/108571105X46642>
- Mahata, A., Mohd, Z., Mistima, S. & Razali, N. (2025). An Early Detection of Students Mathematical Competency in Engineering. *Jurnal Kejuruteraan*, 37(4), 107–118. <https://www.ukm.my/jkukm/wp-content/uploads/2025/3704/07.pdf>
- Oviedo, H. & Campo, A. (2005). Aproximación del coeficiente alfa de Cronbach. *Revista colombiana de Psiquiatría*, XXXIV (4), 572-580.
- Ozili, P. (2023). The acceptable R-squared in empirical social science research. *Munich Personal RePEc Archive (MPRA) Paper No. 115769*. <https://mpra.ub.uni-muenchen.de/115769>
- Quevedo, F. (2011). Medidas de tendencia central y dispersión. *Medware*, 9(3), 1-6.
- Razali, N. & Wah, Y. (2011). Power comparisons of Shapiro–Wilk, Kolmogorov–Smirnov, Lilliefors and Anderson–Darling tests. *Journal of Statistical Modeling and Analytics*, 2(1), 21–33.
- Ryan, O., Sajadi, S., Barrera, S. & Tavakoli, R. (2025). Understanding the Effects of a Math Placement Exam on Calculus 1 Enrollment and Engineering Persistence. *Education Sciences*, 15(2), 154. <https://doi.org/10.3390/educsci15020154>
- Sullivan, G. & Feinn, R. (2012). Using effect size-or why the p value is not enough. *Journal of Graduate Medical Education*, 4(3), 279–282. <https://doi.org/10.4300/JGME-D-12-00156.1>
- Tomczak, M., & Tomczak, E. (2014). The need to report effect size estimates revisited: An overview of some recommended measures of effect size. *Trends in Sport Sciences*, 1(21), 19–25.
- Tuapanta, D., Duque, V. & Mena, R. (2017). Alfa de Cronbach para validar un cuestionario de uso de TIC en docentes universitarios. *Descubre*, 37–48. Recuperado de <https://dspace.epoch.edu.ec/handle/123456789/9807>