

EVALUACIÓN BAYESIANA DE UN MÓDULO DE APRENDIZAJE PARA LA COMPETENCIA «RESUELVE PROBLEMAS DE CANTIDAD» EN EDUCACIÓN SECUNDARIA.

Ronald Gamarra-Salinas^{*1}, Julia Cecilia Yon-Delgado*, Ángel Amado Romero-Cahuana*, Claudia Patricia Yon-Delgado**, Wilder Felinto Flores-Córdova*

*Universidad Nacional Intercultural de la Amazonia, Pucallpa, Perú.

**E.P. Little Winners, Lima, Perú.

RESUMEN

Se evalúa el efecto de un módulo de aprendizaje sobre la competencia «resuelve problemas de cantidad» en 79 estudiantes de segundo año de educación secundaria de la I.E.I. N.º 64095 «Elías Aguirre», Yarinacocha, Ucayali, Perú, mediante un diseño de un solo grupo con medición pretest–postest. El instrumento de 20 ítems, organizado en cuatro dimensiones con escala ordinal de cuatro niveles, presentó una consistencia interna de $\alpha = 0.907$ (muestra piloto, $n = 15$). Se empleó un modelo bayesiano de regresión logística ordinal cuya distribución a priori para el coeficiente de intervención fue $\beta \sim N(\text{logit}(0.60), 1)$, especificada a partir del juicio consensuado de cinco expertos; la inferencia se realizó mediante NUTS con 4 cadenas y 2 000 iteraciones, verificándose la convergencia con $R\text{-hat} \leq 1.01$ y $ESS \geq 400$. Las medias posteriores de β oscilaron entre 1.678 y 1.953 en las cuatro dimensiones, con intervalos de credibilidad al 95 % que excluyen el cero y probabilidad posterior $P(\beta > 0) = 1.000$ en todos los casos, indicando un desplazamiento estadístico sólido hacia niveles superiores de logro tras la intervención.

PALABRAS CLAVES: módulo de aprendizaje, resolución de problemas de cantidad, consistencia interna, inferencia bayesiana, regresión logística ordinal.

MSC: 62C10.

ABSTRACT

The effect of a learning module on the competency «solves quantity problems» is evaluated in 79 second-year secondary students at I.E.I. No. 64095 «Elías Aguirre», Yarinacocha, Ucayali, Peru, using a single-group pretest–posttest design. The 20-item instrument, organized into four dimensions with a four-level ordinal scale, showed internal consistency $\alpha = 0.907$ (pilot sample, $n = 15$). A Bayesian ordinal logistic regression model was used with prior distribution $\beta \sim N(\text{logit}(0.60), 1)$ elicited from five experts; inference was carried out via NUTS with 4 chains and 2 000 iterations, with convergence verified through $R\text{-hat} \leq 1.01$ and $ESS \geq 400$. Posterior means of β ranged from 1.678 to 1.953, with 95 % credibility intervals excluding zero and $P(\beta > 0) = 1.000$ in all dimensions, indicating a statistically robust shift toward higher achievement levels following the intervention.

KEYWORDS: learning module, quantity problem solving, internal consistency, Bayesian inference, ordinal logistic regression.

1. INTRODUCCIÓN

Según los resultados de la más reciente ronda del Programa para la Evaluación Internacional de Estudiantes (PISA), el Perú ocupa el puesto 64 entre 79 países participantes en el área de matemática, con un promedio de 400 puntos. Este valor supera los 387 obtenidos en 2015, pero permanece de modo significativo por debajo de la media OCDE y de países latinoamericanos de mayor rendimiento, como Chile (452) y Colombia (412). El 60.3 % de los estudiantes peruanos evaluados no alcanza el nivel 2 de la escala PISA, es decir, no logra aplicar procedimientos elementales ni interpretar resultados matemáticos en situaciones cotidianas [10].

A nivel nacional, la Evaluación Censal de Estudiantes (ECE) posiciona a la región Ucayali en el penúltimo lugar entre las 26 regiones evaluadas en matemática de segundo grado de secundaria: el 58.1 % de los estudiantes se ubica en el nivel previo al inicio, el 29.9 % en inicio, el 8.0 % en proceso y únicamente el 4.1 % en el nivel satisfactorio. Este perfil de rendimiento refleja un déficit pronunciado en la competencia «resuelve problemas de cantidad», entendida en el Currículo Nacional del Ministerio de Educación del Perú (MINEDU) como la capacidad de desarrollar modelos de solución numérica, comprender el sentido numérico y de magnitud, construir el significado de las operaciones y aplicar estrategias de cálculo y estimación en contextos variados [15].

Los estudiantes del segundo año de la I.E.I. N.º 64095 «Elías Aguirre», del distrito de Yarinacocha, manifestaban dificultades específicas para operar con números enteros y para trasladar situaciones problemáticas del entorno a expresiones numéricas formales, habilidades nucleares de la competencia seleccionada. En respuesta a este diagnóstico, se diseñó un módulo de aprendizaje de doce sesiones estructuradas de manera secuencial en torno a los cuatro ejes de la competencia, con enfoque centrado en resolución de problemas y trabajo colaborativo mediado por el docente.

¹ Email: rgamarras@unia.edu.pe

Puesto que la muestra fue seleccionada de forma no probabilística, condición frecuente en estudios de intervención educativa con acceso restringido [4][5], el análisis estadístico se apoyó en un modelo bayesiano de regresión logística ordinal. La inferencia bayesiana permite incorporar el juicio de expertos como distribución a priori y estimar la distribución a posteriori de los parámetros del modelo sin exigir aleatoriedad en la muestra [7][8]. El objetivo del estudio fue evaluar, mediante dicho modelo, el efecto del módulo sobre los niveles de logro de la competencia «resuelve problemas de cantidad» antes y después de su aplicación, cuantificando la incertidumbre del estimador mediante intervalos de credibilidad bayesianos.

2. PRELIMINARES

La inferencia bayesiana combina una distribución a priori $g(\theta)$, que codifica el conocimiento disponible sobre el parámetro θ antes de observar los datos, con la función de verosimilitud $f(x|\theta)$, que cuantifica la compatibilidad de los datos observados x con el valor θ , para producir la distribución a posteriori $h(\theta|x)$ mediante el Teorema de Bayes [9][12]:

$$h(\theta / x) = f(x / \theta) \cdot g(\theta) / f(x) \quad (1)$$

El denominador $f(x) = \int f(x|\theta) g(\theta) d\theta$ actúa como constante de normalización y garantiza que $h(\theta|x)$ sea una distribución de probabilidad propia. A diferencia de la inferencia frecuentista, los parámetros se tratan como variables aleatorias, lo que permite formular enunciados probabilísticos directos sobre su valor y obtener estimaciones puntuales, intervalos y probabilidades posteriores en una misma operación. Las distribuciones a priori pueden ser informativas, cuando provienen de estudios previos o de expertos, o débilmente informativas, en cuyo caso los datos dominan la inferencia. Un resultado estándar de la teoría bayesiana establece que, cuando el tamaño muestral crece, la distribución a posteriori converge hacia la verosimilitud independientemente del prior elegido, lo que confiere robustez a las conclusiones ante variaciones razonables de la especificación inicial [7].

La regresión logística ordinal modela la probabilidad acumulada de que la variable de respuesta ordinal Y no supere la categoría i [1][6]. Dada la codificación ascendente $Y \in \{1, 2, 3, 4\} = \{\text{En inicio, En proceso, Logro previsto, Logro destacado}\}$, el modelo de probabilidades proporcionales se expresa como:

$$\text{logit } P(Y \leq i | X) = \alpha_i - \beta X, \quad i = 1, 2, 3 \quad (2)$$

donde α_i son los umbrales de corte (parámetros de intercepción propios de cada categoría, con la restricción de ordenamiento $\alpha_1 < \alpha_2 < \alpha_3$), X es la variable predictora dicotómica ($X = 0$: pretest; $X = 1$: postest), y β es el coeficiente de regresión asociado a la intervención. La función logit se define como $\text{logit}(p) = \ln(p/(1-p))$ y su inversa, la función logística, como $\text{logistic}(z) = 1/(1 + e^{-z})$. La suposición de proporcionalidad implica que el efecto de X sobre el logit acumulado es el mismo para todos los umbrales, lo que simplifica la interpretación: un único coeficiente β caracteriza el efecto de la variable predictora sobre toda la distribución ordinal.

La interpretación de β es la siguiente: si $\beta > 0$, entonces $\text{logit } P(Y \leq i | X=1) < \text{logit } P(Y \leq i | X=0)$ para todo i , lo que equivale a decir que $P(Y \leq i | X=1) < P(Y \leq i | X=0)$. Dicho de otro modo, un coeficiente positivo reduce la probabilidad acumulada de pertenecer a categorías inferiores en el postest y, de forma complementaria, incrementa la probabilidad de alcanzar categorías superiores. La magnitud de β determina el tamaño del efecto: valores más grandes implican un desplazamiento más pronunciado de la distribución hacia niveles de logro más altos.

En el marco bayesiano, los parámetros del modelo ($\beta, \alpha_1, \alpha_2, \alpha_3$) reciben distribuciones a priori independientes y la distribución a posteriori conjunta satisface:

$$h(\beta, \alpha_1, \alpha_2, \alpha_3 | \text{datos}) \propto f(\text{datos} | \beta, \alpha) \cdot g(\beta) \cdot g(\alpha_1) \cdot g(\alpha_2) \cdot g(\alpha_3) \quad (3)$$

Al no existir forma analítica cerrada para esta distribución, se recurre al método de Cadena de Markov Monte Carlo (MCMC). En concreto, se empleó el algoritmo No-U-Turn Sampler (NUTS), una variante adaptativa del muestreo de Hamilton que ajusta de forma automática el número de pasos de la trayectoria y evita el comportamiento de retroceso en U, logrando alta eficiencia en espacios paramétricos de dimensión moderada [14]. La convergencia de las cadenas se verificó mediante el estadístico R-hat (valores próximos a 1.00 indican convergencia entre cadenas) y el tamaño efectivo de muestra ESS (valores suficientemente altos garantizan que las muestras son representativas de la distribución a posteriori).

La consistencia interna del instrumento se cuantificó con el coeficiente alfa de Cronbach [11][13][16]:

$$\alpha = (k/(k-1)) \cdot (1 - \sum S_i^2 / S_t^2) \quad (4)$$

donde k es el número de ítems, S_i^2 la varianza del ítem i y S_t^2 la varianza total de las puntuaciones. Valores $\alpha \geq 0.80$ indican alta consistencia interna y valores ≥ 0.90 se consideran muy altos [3]. La validez de contenido, que hace

referencia al grado en que el instrumento cubre de forma consistente el dominio conceptual medido, se evaluó mediante juicio de expertos, procedimiento conceptualmente distinto de la consistencia interna [13].

3. METODOLOGÍA

La muestra estuvo integrada por 79 estudiantes del segundo año de educación secundaria de la I.E.I. N.º 64095 «Elías Aguirre», del distrito de Yarinacocha, región Ucayali, seleccionados por muestreo no probabilístico intencionado [4][5][15]. Se adoptó un diseño de un solo grupo con medición pretest–posttest: el mismo instrumento fue aplicado antes y después del módulo de aprendizaje.

El módulo de aprendizaje se implementó en dos meses lectivos mediante 12 sesiones de 90 minutos cada una, organizadas en cuatro bloques temáticos (adición, sustracción, multiplicación y división de números enteros), con una sesión introductoria operacional, una de operaciones combinadas y una de resolución de problemas contextualizados por cada operación. La metodología de cada sesión siguió el enfoque centrado en resolución de problemas del MINEDU: activación de saberes previos, presentación de una situación-problema del entorno local, trabajo en equipo con el docente como mediador, y sistematización colectiva del saber. La Tabla 3 lista las 12 sesiones y los contenidos correspondientes.

Ses.	Contenido	Ses.	Contenido
1	Adición de números enteros: operaciones	7	Multiplicación de números y signos en \mathbb{Z}
2	Adición: operaciones combinadas	8	Multiplicación: operaciones combinadas
3	Adición: resolución de problemas	9	Multiplicación: resolución de problemas
4	Sustracción de números enteros: operaciones	10	División de números enteros: operaciones
5	Sustracción: operaciones combinadas	11	División: operaciones combinadas
6	Sustracción: resolución de problemas	12	División: resolución de problemas

Tabla 3. Sesiones del módulo de aprendizaje y contenidos trabajados (en parejas para economía de espacio).

El instrumento de evaluación constó de 20 ítems de selección múltiple (cuatro alternativas) distribuidos en cuatro dimensiones de la competencia según el Currículo Nacional. Las puntuaciones por dimensión (0–5 aciertos) se convirtieron a la escala ordinal $Y \in \{1, 2, 3, 4\}$ definida en la Tabla 1. La validez de contenido fue establecida por juicio consensuado de cinco expertos en didáctica de la matemática. La consistencia interna se estimó con alfa de Cronbach sobre una muestra piloto independiente de 15 estudiantes con características similares a la muestra principal.

Variable dependiente	Dimensiones	Nº ítems	Peso	Escala ordinal Y
Resolución de problemas de cantidad	D1: Traduce cantidades a expresiones numéricas	5	1 pt/ítem	1=En inicio [0-2] 2=En proceso [3] 3=Logro previsto [4] 4=Logro destacado [5]
	D2: Comunica su expresión sobre números y operaciones	5	1 pt/ítem	1=En inicio [0-2] 2=En proceso [3] 3=Logro previsto [4] 4=Logro destacado [5]
	D3: Usa estrategias y procedimientos de estimación y cálculo	5	1 pt/ítem	1=En inicio [0-2] 2=En proceso [3] 3=Logro previsto [4] 4=Logro destacado [5]
	D4: Argumenta afirmaciones sobre las relaciones numéricas	5	1 pt/ítem	1=En inicio [0-2] 2=En proceso [3] 3=Logro previsto [4] 4=Logro destacado [5]

Tabla 1. Estructura del instrumento, escala ordinal Y y umbrales de conversión por dimensión.

Para la especificación bayesiana, los cinco expertos estimaron en sesión conjunta una probabilidad a priori de mejora del módulo de $\pi_0 = 0.60$. Este valor se transformó a escala logit: $\mu_0 = \text{logit}(0.60) = \ln(0.60/0.40) = \ln(3/2) \approx 0.405$, y se utilizó como media de la distribución a priori del coeficiente β . La desviación estándar del prior se fijó en $\sigma_0 = 1$, lo que equivale a una distribución moderada que asigna probabilidad apreciable a valores de β en el rango $[-1.6, 2.4]$. Esta especificación es coherente con la literatura bayesiana educativa, donde priors con σ entre 0.5 y 2 se consideran informativas sin imponer efectos extremos. Los parámetros de umbral recibieron distribuciones débilmente informativas $\alpha_i \sim N(0, 2)$. La Tabla 2 resume la especificación completa y los criterios de convergencia verificados.

Especificación bayesiana	Valor / Descripción
Distribución a priori de β	$\beta \sim N(\mu_0, 1)$, $\mu_0 = \text{logit}(0.60) = \ln(3/2) \approx 0.405$
Distribución a priori de α_i ($i = 1, 2, 3$)	$\alpha_i \sim N(0, 2)$, con restricción $\alpha_1 < \alpha_2 < \alpha_3$
Verosimilitud	Regresión logística ordinal proporcional de probabilidades (Ec. 2)
Algoritmo MCMC	NUTS (No-U-Turn Sampler)
Cadenas / iteraciones totales	4 cadenas \times 2 000 iteraciones (1 000 de calentamiento)
Convergencia: R-hat	≤ 1.01 en todos los parámetros
Convergencia: ESS (bulk)	≥ 400 en todos los parámetros
Software	PyMC – Python 3.12.4

Tabla 2. Especificación de distribuciones a priori y configuración del algoritmo MCMC.

4. RESULTADOS

4.1. Consistencia interna del instrumento

El coeficiente alfa de Cronbach obtenido sobre la muestra piloto ($n = 15$) fue $\alpha = 0.907$, valor que acredita una consistencia interna muy alta del instrumento. Este resultado indica que los 20 ítems miden de manera homogénea el constructo de resolución de problemas de cantidad en sus cuatro dimensiones, lo que permite confiar en que las variaciones entre pretest y postest reflejan cambios reales en el nivel de logro y no artefactos de medición.

4.2. Distribución de niveles de logro: pretest y postest

La Tabla 4 presenta la distribución de los 79 estudiantes en cada nivel de logro, por dimensión, en el pretest y en el postest. En el pretest, el nivel En inicio concentró entre el 72.15 % (D1) y el 92.41 % (D4) de la muestra, sin presencia de logro destacado en ninguna dimensión. En proceso y logro previsto representaban en conjunto menos del 30 % en D1 y D2, y menos del 15 % en D3 y D4.

Dimensión	Momento	En inicio n (%)	En proceso n (%)	Logro previsto n (%)	Logro destacado n (%)
D1: Traduce cantidades a expresiones numéricas	Pretest	57 (72.15)	15 (18.99)	7 (8.86)	0 (0.00)
	Postest	24 (30.38)	18 (22.78)	25 (31.65)	12 (15.19)
D2: Comunica su expresión sobre números y operaciones	Pretest	59 (74.68)	16 (20.25)	4 (5.06)	0 (0.00)
	Postest	24 (30.38)	20 (25.32)	26 (32.91)	9 (11.39)
D3: Usa estrategias y procedimientos de estimación	Pretest	68 (86.08)	7 (8.86)	4 (5.06)	0 (0.00)
	Postest	30 (37.97)	16 (20.25)	24 (30.38)	9 (11.39)
D4: Argumenta afirmaciones sobre relaciones numéricas	Pretest	73 (92.41)	6 (7.59)	0 (0.00)	0 (0.00)
	Postest	40 (50.63)	17 (21.52)	15 (18.99)	7 (8.86)

Tabla 4. Distribución de estudiantes por nivel de logro en el pretest y el postest ($n = 79$).

En el postest se observó un desplazamiento generalizado y pronunciado hacia niveles superiores. El porcentaje de estudiantes en En inicio disminuyó en todas las dimensiones: -41.77 puntos porcentuales en D1, -44.30 en D2, -48.11 en D3 y -41.78 en D4. Simultáneamente, los niveles de logro previsto y logro destacado pasaron de proporciones mínimas o nulas a valores comprendidos entre 27.85 % (D4: 18.99 % + 8.86 %) y 46.84 % (D1: 31.65 % + 15.19 %) de la muestra. La dimensión de mayor avance relativo fue D1, y la de menor avance fue D4, lo que es consistente con la naturaleza más compleja de las capacidades de argumentación matemática.

4.3. Estimaciones del modelo bayesiano ordinal

La Tabla 5 presenta las estimaciones a posteriori del coeficiente β y los intervalos de credibilidad bayesianos al 95 % para cada dimensión. Todos los diagnósticos MCMC confirmaron convergencia satisfactoria ($R\text{-hat} \leq 1.01$ y $ESS \geq 400$ en todos los parámetros), garantizando la validez inferencial de las muestras MCMC.

Dimensión	β (media posterior)	IC 95 % inferior	IC 95 % superior	$P(\beta > 0)$
D1: Traduce cantidades a expresiones numéricas	1.678	1.077	2.293	1.000
D2: Comunica su expresión sobre números y operaciones	1.807	1.204	2.399	1.000
D3: Usa estrategias y procedimientos de estimación	1.953	1.286	2.609	1.000
D4: Argumenta afirmaciones sobre relaciones numéricas	1.918	1.183	2.630	1.000

Tabla 5. Resultados del modelo bayesiano de regresión logística ordinal: media posterior de β , intervalo de credibilidad al 95 % y $P(\beta > 0)$.

Los coeficientes β posteriores fueron positivos en las cuatro dimensiones, con medias entre 1.678 (D1) y 1.953 (D3). Los intervalos de credibilidad al 95 % excluyen el cero en su totalidad: el límite inferior más conservador es 1.077 (D1), lo que indica que incluso en el escenario más pesimista compatible con los datos (extremo inferior del intervalo al 95 %), el efecto del módulo sobre la distribución ordinal es positivo y sustantivo. La probabilidad posterior $P(\beta > 0)$ es 1.000 en las cuatro dimensiones, es decir, la totalidad de las muestras MCMC a posteriori respalda un efecto positivo.

Para interpretar la magnitud del efecto, considérese D3 ($\beta = 1.953$) como ejemplo. De acuerdo con el modelo (Ecuación 2), la probabilidad acumulada de estar en el nivel En inicio o inferior ($i = 1$) en el postest es $\text{logistic}(\alpha_1 - 1.953)$, frente a $\text{logistic}(\alpha_1)$ en el pretest. Dado que logistic es una función creciente, una diferencia de -1.953 en el argumento implica una reducción pronunciada en $P(Y \leq 1 \mid \text{postest})$ respecto a $P(Y \leq 1 \mid \text{pretest})$, consistente con la caída observada de 86.08 % a 37.97 % en D3.

La robustez de las estimaciones frente a la especificación del prior se infiere de la magnitud de las medias a posteriori (1.678–1.953) en comparación con la media del prior ($\mu_0 = 0.405$): las estimaciones se ubican entre 3.1 y 4.8 desviaciones estándar del prior por encima de su media, lo que evidencia que los datos ejercen una influencia dominante sobre la inferencia y que las conclusiones son insensibles a variaciones razonables en la especificación a priori.

5. CONCLUSIONES

El modelo bayesiano de regresión logística ordinal, ajustado con prior informativo $\beta \sim N(0.405, 1)$ derivado del juicio de expertos y estimado mediante NUTS con diagnósticos de convergencia satisfactorios ($R\text{-hat} \leq 1.01$; $ESS \geq 400$), proporciona evidencia estadística de que la aplicación del módulo de aprendizaje se asocia a un desplazamiento hacia niveles superiores de logro en la competencia «resuelve problemas de cantidad». Los coeficientes β positivos (1.678 a 1.953), los intervalos de credibilidad al 95 % que excluyen el cero y la probabilidad posterior $P(\beta > 0) = 1.000$ en las cuatro dimensiones constituyen evidencia bayesiana coherente y robusta del efecto de la intervención.

Desde el punto de vista pedagógico, la dimensión con mayor desplazamiento fue D3 «Usa estrategias y procedimientos de estimación y cálculo» ($\beta = 1.953$), seguida de D4 «Argumenta afirmaciones sobre las relaciones numéricas» ($\beta = 1.918$). Este resultado sugiere que el enfoque de resolución de problemas del módulo, que exige seleccionar procedimientos y justificar razonamientos, fue singular y eficaz en activar capacidades de orden aplicado. La dimensión D1 «Traduce cantidades a expresiones numéricas» ($\beta = 1.678$), si bien muestra evidencia clara de mejora, registró el menor desplazamiento relativo, lo que indica que la representación simbólica formal requiere mayor tiempo de consolidación en el contexto estudiado.

La metodología bayesiana adoptada es pertinente para este tipo de estudios, en los que el muestreo aleatorio no es factible: la incorporación explícita del conocimiento experto como prior, la estimación distribucional completa de β , en lugar de un único valor puntual, y el reporte de probabilidades posteriores directamente interpretables ofrecen una cuantificación del efecto más informativa que los contrastes de hipótesis nula clásicos. Las estimaciones son estables bajo el prior especificado, dado que los datos dominan de forma clara la inferencia. Estudios futuros con diseños cuasiexperimentales que incluyan un grupo de comparación, así como mediciones diferidas, permitirán corroborar y extender las conclusiones aquí presentadas.

RECEIVED: DECEMBER, 2025.
REVISED: MAY, 2026.

REFERENCIAS

- [1] AGRESTI, A. (2010). *Analysis of Ordinal Categorical Data*. Hoboken: John Wiley & Sons, Inc.
- [2] BONE SALAS, J. A. (2025). Aplicación del modelo de regresión logística para la predicción de riesgo de bajo rendimiento académico en estudiantes del noveno año de educación general básica de la unidad educativa «Capitán Edmundo Chiriboga». Tesis de Maestría, Universidad Nacional de Chimborazo.
- [3] CASTAÑEDA RODRÍGUEZ, T., LÓPEZ DOMÍNGUEZ, A., COLLAZO FRÍAS, V. D. C., y MOIRÓN VALLAR, O. M. (2024). Fiabilidad instrumental para medir la aplicación de técnicas estadísticas en cultura física: Alpha de Cronbach. *Transformación*, 20, 128–144.
- [4] CHACÓN, L. J. R., MORALES, G. E. R., LUNA, A. C. P., MEDINA, J. H. C., y CANTUÑA-VALLEJO, P. F. (2022). El Muestreo Intencional No Probabilístico como herramienta de la investigación científica en carreras de Ciencias de la Salud. *Universidad y Sociedad*, 14, 681–691.
- [5] GONZÁLEZ, O. H. (2021). Aproximación a los distintos tipos de muestreo no probabilístico que existen. *Revista Cubana de Medicina General Integral*, 37, 1–3.
- [6] GUZMÁN, G. J. H. (2025). Impacto del Financiamiento en la Competitividad de las MYPEs Manufactureras: Un Enfoque Predictivo con Regresión Logística Ordinal. *Iberoamerican Business Journal*, 9, 36–62.
- [7] LORCA, J. C., y ÁGUILA, L. C. (2024). Inferencia Bayesiana en el proceso de diagnóstico clínico: un enfoque docente para la toma de decisiones. *Revista chilena de infectología*, 41, 762–768.
- [8] NEIRA, J. E. C. (2023). Regresión logística ordinal aplicado a los factores asociados a la hipertensión arterial en pacientes de la institución prestadora de servicios de salud Expertta Salud, 2020. Tesis Doctoral, Universidad Nacional Mayor de San Marcos.
- [9] OBANDO, M. A. H. (2025). Diagramas de Venn ampliados a los complementos de los eventos para resolver probabilidad condicional y Teorema de Bayes. *Revista Torreón Universitario*, 14, 39–47.
- [10] OTZEN, T., y MANTEROLA, C. (2017). Técnicas de Muestreo sobre una Población a Estudio. *International Journal of Morphology*, 35, 227–232.
- [11] PÉREZ-LEÓN, G. (2022). Coeficiente Alfa de Cronbach: ¿Qué es y para qué sirve el Alfa de Cronbach. *GPL Research Consultores*, 20123, 572–580.
- [12] RIASCOS, Y., PÉREZ, S., GIULIANO, M., AFONSO, M. V., MOLINA, D. E., y GONZÁLEZ, J. A. (2023). Análisis de la demanda cognitiva de problemas de probabilidad propuestos en E-status. En XVIII Congreso TE&ET 2023, Hurlingham.
- [13] ROMERO, J. R. C., MONTOYA, M. R., MEDINA, M. S., ZEPEDA, G. C., y INTRIAGO, V. R. C. (2024). Análisis comparativo de los coeficientes alfa de Cronbach, omega de McDonald y alfa ordinal en la validación de cuestionarios. *Estudios y Perspectivas Revista Científica y Académica*, 4, 2738–2755.
- [14] SABOURI, S., ZOLANVARI, A., y HAGHIGHI, S. (2026). Comparing Classifiers: A Case Study Using PyCM. arXiv preprint arXiv:2602.13482.
- [15] SCHARAGER, J., y REYES, P. (2001). Muestreo no probabilístico. Pontificia Universidad Católica de Chile, Escuela de Psicología, 1, 1–3.
- [16] TOBAR, R. T., SARMIENTO, M. D. R. P., PRIETO, B. L. A., VÉLEZ, S. M., y TORRES, A. B. (2022). Análisis empírico del Coeficiente Alfa de Cronbach según opciones de respuesta, muestra y observaciones atípicas. *Revista iberoamericana de diagnóstico y evaluación psicológica*, 2, 17–30.
- [17] YUPARI-AZABACHE, I. L., DIAZ-ORTEGA, J. L., AZABACHE-ALVARADO, K. A., y BARDALES-AGUIRRE, L. B. (2022). Modelo logístico de factores asociados al Síndrome de Burnout en el personal de salud. *Enfermería global*, 21, 144–171.