

## Mnemotecnias para el aprendizaje de conceptos matemáticos complejos

*Mnemonics for learning complex mathematical concepts*

DOI: <https://doi.org/10.35622/inudi.c.03.28>

---


### Jhonier Rangel

 Universidad ECCI, Bogotá, Colombia

✉ [jrangelg@ecci.edu.co](mailto:jrangelg@ecci.edu.co)

 <https://orcid.org/0000-0002-6849-5551>


### Wilson Gordillo

 Universidad Distrital Francisco José de Caldas, Bogotá, Colombia

✉ [wgordillot@udistrital.edu.co](mailto:wgordillot@udistrital.edu.co)

 <https://orcid.org/0000-0002-3856-4691>

### Wilson Pinzón

 Universidad Distrital Francisco José de Caldas, Bogotá, Colombia

✉ [wjpinzonc@udistrital.edu.co](mailto:wjpinzonc@udistrital.edu.co)

 <https://orcid.org/0000-0003-0258-6810>

### Resumen

El aprendizaje de conceptos matemáticos complejos, como las funciones generadoras de momentos y las funciones características, representan un desafío recurrente en la enseñanza de la teoría de probabilidades. Este ensayo tiene como objetivo explorar estrategias pedagógicas basadas en mnemotecnias, analogías visuales y patrones geométricos, orientadas a facilitar la comprensión de estos contenidos abstractos. Se presenta, una mnemotecnia visual para el teorema de Bayes, diseñada para reforzar la relación entre las probabilidades condicionadas mediante una secuencia gráfica intuitiva. Asimismo, se introduce una analogía con triángulos para representar las funciones generadoras de momentos, promoviendo una asociación visual que favorece la memorización y en entendimiento conceptual. También se aborda el vínculo entre las transformadas de Laplace y dichas funciones como recurso didáctico para ilustrar la distribución normal. Entre los principales hallazgos, se destaca que estas herramientas contribuyen a hacer más accesibles los conceptos abstractos, al convertirlos en estructuras más significativas y recordables. Finalmente, se concluye que el uso de mnemotécnicas y analogías contribuye una estrategia eficaz para fomentar un aprendizaje activo, profundo y duradero en el ámbito de la probabilidad matemática.



**Palabras clave:** matemáticas, mnemotecnias, procesos aleatorios, teoría de las probabilidades.

### **Abstract**

The learning of complex mathematical concepts, such as moment-generating functions and characteristic functions, represents a recurring challenge in the teaching of probability theory. This essay aims to explore pedagogical strategies based on mnemonics, visual analogies, and geometric patterns, designed to facilitate the understanding of these abstract contents. For instance, a visual mnemonic for Bayes' theorem is presented, intended to reinforce the relationship between conditional probabilities through an intuitive graphic sequence. Likewise, a triangle-based analogy is introduced to represent moment-generating functions, promoting a visual association that enhances memorization and conceptual understanding. The essay also addresses the link between Laplace transforms and these functions as a didactic resource to illustrate the normal distribution. Among the main findings, it is highlighted that these tools help make abstract concepts more accessible by transforming them into more meaningful and memorable structures. Finally, the use of mnemonics and analogies is concluded to be an effective strategy for fostering active, deep, and lasting learning in the field of mathematical probability.

**Keywords:** mathematics, mnemonics, random processes, probability theory.

### **INTRODUCCIÓN**

En la actualidad, la enseñanza de las matemáticas enfrenta desafíos significativos debido a la creciente complejidad de los contenidos y la necesidad de innovar en los métodos pedagógicos. Las estrategias tradicionales, centradas en la memorización de fórmulas, han demostrado ser insuficientes para garantizar una comprensión profunda, especialmente en áreas como la estadística y la teoría de probabilidad. Diversos estudios destacan que la innovación pedagógica ha promovido técnicas que mejoran el apropiamiento significativo del conocimiento, entre ellas el uso de estrategias cognitivas como las mnemotecnias (Araya-Moya et al., 2022), y se reconoce que la memorización mediante mnemotecnias puede disminuir la ansiedad estadística y aumentar la motivación del estudiante (McCabe, 2013).

Los estudiantes suelen olvidar conceptos clave de probabilidad, lo que justifica la necesidad de métodos didácticos innovadores. Algunos de los conceptos y herramientas clave en esta área incluyen: el teorema de Bayes, esencial en la estadística inferencial y en el análisis de decisiones bajo incertidumbre; la función generadora de momentos y la función característica (Rahman et al., 2022), así como las transformadas de Laplace y de Fourier (Kerr et al., 2022). A continuación, se presentan estas herramientas.

El Teorema de Bayes surgió gracias a Thomas Bayes, un fraile que buscaba demostrar la existencia de Dios. Propuso la siguiente fórmula asumiendo los eventos no nulos es decir con probabilidad mayor que cero.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (1)$$

Históricamente, para la época, era muy peligroso que un fraile cuestionara la existencia de Dios, pero el teorema de Bayes relaciona de manera formal la probabilidad condicional con eventos relacionados (Bulbulia, 2023). A continuación, se presenta un ejemplo:

Supongamos que A representa la existencia de Dios y B representa la complejidad del universo. Sea:

- P(A): La probabilidad previa de la existencia de Dios (por ejemplo, una hipótesis inicial).
- P(B|A): La probabilidad de observar un universo complejo si Dios existe.
- P(B): La probabilidad de observar un universo complejo, sin considerar si Dios existe o no.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (2)$$

En sus inicios, Bayes asumió ciertas probabilidades. Cabe destacar que, en muchos casos, es más fácil conocer la probabilidad de A dado B, mientras que la probabilidad de B dado A puede ser más complicada de determinar. Por ejemplo, para una persona con una fe fuerte y un pensamiento tomista aristotélico, la probabilidad de que exista Dios, dada la complejidad del mundo, es alta. Sin embargo, lo que sí es cierto es que, dada la existencia de Dios, la probabilidad de la complejidad del mundo es también alta. Lo que veremos es que no necesariamente, si una de estas probabilidades es grande, la otra también lo será.

Se considera una simulación con ciertos valores hipotéticos con el propósito de ejemplificar la aplicación del Teorema de Bayes en dicho contexto.

Supuestos:

- Probabilidad de A (P(A)): La probabilidad a priori de que exista Dios es un 60 %.
- Probabilidad de B (P(B)): La probabilidad de que el mundo sea complejo se estima en un 80 %.
- Probabilidad de B dado A (P(B|A)): La probabilidad de que el mundo sea complejo, dado que existe Dios, se estima en un 90 %.

Queremos calcular la probabilidad de que exista Dios dado que el mundo es complejo, es decir, P(A|B). Aplicando el Teorema de Bayes:

$$P(A|B) = P(B|A) \cdot \frac{P(A)}{P(B)} \quad (3)$$

Sustituyendo los valores supuestos:

$$P(A|B) = 0.9 \cdot \frac{0.6}{0.8} = 0.675 \quad (4)$$

La probabilidad de que exista Dios, dado que el mundo es complejo, sería 0.675 o 67.5 %. A pesar de que la probabilidad de que el mundo sea complejo dado

que existe Dios sea alta (90 %), la probabilidad de que exista Dios dado que el mundo es complejo es 67.5 %. Este ejemplo muestra cómo, aunque una probabilidad condicional pueda ser alta, no garantiza que la otra probabilidad también lo sea. Estudios han demostrado que una instrucción conceptual explícita en razonamiento bayesiano mejora significativamente la capacidad de estimar probabilidades posteriores (Brush et al., 2019).

Se puede ver en Rangel (2024), la importancia del Teorema de Bayes por ejemplo para estimar probabilidades en Cadenas de Markov con espacio de estados finitas y cuando las probabilidades son cercanas a cero o a uno.

Por otro lado, la Función Generadora de Momentos (MGF) es una herramienta importante en la teoría de probabilidad y se utiliza para caracterizar completamente la distribución de una variable aleatoria. Existen dos definiciones de la MGF: una para variables discretas y otra para variables continuas. En este sentido, Wang et al. (2017) no solo presentan ambas definiciones, sino que también establecen una relación entre la estimación de estas funciones y el uso de la estadística bayesiana.

Dado un espacio de probabilidad  $(\Omega, F, P)$ , donde:

- $\Omega$  es el espacio muestral (el conjunto de todos los posibles resultados).
- $F$  es la sigma-álgebra (el conjunto de eventos posibles).
- $P$  es la medida de probabilidad (la función que asigna probabilidades a los eventos).

La función generadora de momentos de una variable aleatoria  $X$  es una función que se define de manera diferente según si  $X$  es discreta o continua.

Si  $X$  es una variable aleatoria discreta que toma valores  $x_1, x_2, \dots$  con probabilidades asociadas  $p_1, p_2, \dots$  (es decir,  $P(X=x_i) = p_i$ ), entonces la función generadora de momentos (MGF) de  $X$  se define como:

$$M_X(t) = E(e^{tX}) = \sum_{i=1}^{\infty} \exp(t \cdot x_i) \cdot p_i \quad (5)$$

En este caso, la MGF es una suma ponderada de los exponentes de los valores posibles de  $X$ , ponderados por sus probabilidades.

Por otro lado, si  $X$  es una variable aleatoria continua con función de densidad de probabilidad  $f(x)$ , entonces la función generadora de momentos [MGF] de  $X$  se define como:

$$M_X(t) := E(e^{tX}) = \int_{-\infty}^{\infty} \exp(t \cdot x) \cdot f(x) \quad (6)$$

La MGF también puede usarse para *derivar distribuciones de variables aleatorias y para calcular distribuciones de la suma de variables aleatorias independientes*.

La función generadora de momentos es una fórmula extremadamente importante en la teoría de probabilidad, ya que caracteriza de manera única la distribución de una variable aleatoria. Es decir, si dos variables aleatorias

tienen la misma función generadora de momentos, entonces su función de distribución y su función de densidad de probabilidad son idénticas. Por esta razón, la función generadora de momentos es crucial para demostrar ciertos resultados en inferencia estadística, métodos de regresión y en otras áreas de las matemáticas aplicadas

Si  $X$  es una variable aleatoria discreta que toma valores  $x_1, x_2, \dots, x_i$  con probabilidades asociadas  $p_1, p_2, \dots, p_i$  (es decir,  $P(X=x_i) = p_i$ ), entonces la Función Característica (CF) de  $X$  se define como:

$$C_X(t) := E(e^{tjX}) = \sum_{i=1}^{\infty} \exp(tj \cdot x_i) \cdot p_i, \quad j = \sqrt{-1} \quad (7)$$

En este caso la CF siempre existe ya que está acotada por el círculo unitario complejo.

Por otro lado, si  $X$  es una variable aleatoria continua con función de densidad de probabilidad  $f(x)$ , entonces la CF de  $X$  se define como:

$$C_X(t) := E(e^{tjX}) = \int_{-\infty}^{\infty} \exp(jt \cdot x) \cdot f(x) dx \quad (8)$$

Aunque la función característica difiere de la función generadora de momentos en su formulación, su experiencia está siempre garantizada, lo que permite considerarla como una generalización que abarca a la función generadora de momentos como un caso particular (Pinkovetskaia et al., 2021). La función característica es de gran importancia porque, al igual que la función generadora de momentos, caracteriza de manera única la distribución de una variable aleatoria. De hecho, puede ser más útil en algunos contextos, como en la transformación de distribuciones y en la teoría de colas, ya que siempre tiene una representación válida, independientemente de si los momentos de la distribución están definidos.

En la teoría de probabilidades y en el análisis matemático, la transformada de Laplace bilateral se define como la integral de la función  $f(t)$  multiplicada por  $e^{-st}$ , con  $s$  siendo un número complejo, sobre el intervalo de  $-\infty$  a  $\infty$ . Esta transformada es importante porque proporciona una herramienta poderosa para analizar funciones de variables aleatorias, especialmente cuando se trata de resolver ecuaciones diferenciales y problemas de procesos estocásticos. La transformada de Laplace bilateral también tiene aplicaciones en la obtención de la distribución de la variable aleatoria inversa, lo que permite calcular la distribución de tiempos de espera y otros fenómenos relacionados con la probabilidad. Su fórmula es:

$$\mathcal{L}(f(t)) := \int_{-\infty}^{\infty} \exp\{-st\} \cdot f(t) dt \quad (9)$$

En el análisis matemático, la transformada de Fourier se define como la integral de una función  $f(t)$  multiplicada por  $e^{-j\omega t}$ , donde  $\omega$  es una frecuencia real, sobre el intervalo de  $-\infty$  a  $\infty$ . Esta transformada es importante porque permite descomponer funciones en componentes de frecuencia, facilitando el análisis de señales, sistemas y fenómenos oscilatorios. La transformada de Fourier es crucial para estudiar funciones de variables aleatorias en el dominio de la frecuencia, ya que transforma la información en el dominio del tiempo al dominio de la frecuencia, lo que es útil en áreas como la teoría de señales, procesamiento de imágenes y análisis de espectros. Su fórmula es:

$$\mathcal{F}(f(t)) := \int_{-\infty}^{\infty} \exp(-j\omega t) \cdot f(t) dt \quad (10)$$

Las mnemotecnias son técnicas de aprendizaje que utilizan asociaciones mentales, patrones, imágenes o frases fáciles de recordar para ayudar a retener y recuperar información compleja. En el contexto del aprendizaje de conceptos matemáticos y estadísticos como el teorema de Bayes o las funciones generadoras de momentos, las mnemotecnias desempeñan un papel crucial al simplificar ideas abstractas y relacionarlas con elementos cotidianos o visuales. Esto no solo facilita la comprensión inicial, sino que también mejora la retención a largo plazo, ayudando a los estudiantes a aplicar estos conceptos de manera más efectiva en problemas prácticos. Además, las mnemotecnias fomentan la creatividad en el proceso de aprendizaje, haciéndolo más dinámico y accesible para diferentes estilos de aprendizaje (Haiyan, 2024; Boon et al., 2019). Además, la investigación en educación estadística muestra que el uso de mnemotecnias específicas para enseñar estadística puede ser memorable, útil y disminuir la ansiedad en estudiantes universitarios (Hunt, 2010).

Según Drushlyak et al. (2021), la capacitación de futuros profesores de matemáticas en el uso de técnicas mnemotécnicas es esencial para abordar la intensificación del proceso educativo, dado que la cantidad de información acumulada supera ampliamente la capacidad de aprendizaje de una persona. Estas técnicas, basadas en la formación de conexiones asociativas mediante métodos específicos como "Vinculación", "Transformación" y "Ampliación", permiten una percepción más eficaz de la información nueva y facilitan la enseñanza de materiales matemáticos.

Dado el carácter abstracto y técnico de estos conceptos, se hace necesario recurrir a enfoques didácticos que apoyen su enseñanza de forma significativa y accesible para los estudiantes. La creciente complejidad del currículo matemático y las limitaciones de las metodologías tradicionales justifican la búsqueda de estrategias que mejoren la comprensión y aplicación de contenidos avanzados. En este sentido, el presente ensayo tiene como objetivo explorar el uso de mnemotécnicas y analogías visuales como estrategias pedagógicas para facilitar el aprendizaje del teorema de Bayes, la función generadora de momentos, la función característica y las transformadas de Laplace y Fourier, dentro del contexto de la educación matemática universitaria.

## DESARROLLO

Una mnemotecnia sencilla para aprender el Teorema de Bayes es recordar la secuencia “BABABA”. Esta secuencia facilita la memorización del teorema, ya que ayuda al estudiante a comprender la relación entre  $P(A|B)$  y  $P(B|A)$ . Al considerar que el teorema establece un vínculo entre estas dos probabilidades condicionadas, el estudiante puede visualizar de forma más clara cómo se conecta  $A|B$  con  $B|A$ , lo que facilita la aplicación de la fórmula y su comprensión general. Esta conexión es fundamental en estadística bayesiana, donde muchas veces se conoce la probabilidad inversa (por ejemplo, la probabilidad de un síntoma dado una enfermedad), pero se desea estimar la probabilidad directa (la probabilidad de la enfermedad dado el síntoma).

Primero se le sugiere al estudiante colocar la fórmula sin espacios llenos, es decir:

$$P( \quad | \quad ) = P( \quad ) \cdot \frac{P( \quad | \quad )}{P( \quad )} \quad (11)$$

Esta forma esquemática permite que el estudiante se concentre en el patrón estructural del teorema, sin distraerse aún por los valores concretos. Sirve también como plantilla general para cualquier aplicación del teorema de Bayes, sin importar el contexto.

Y luego colocar la secuencia en el orden que se propone “BABABA”

$$P( B | A ) = P( B ) \cdot \frac{P( A | B )}{P( A )} \quad (12)$$

Con esta mnemotecnia tan sencilla, el estudiante puede memorizar fácilmente el Teorema de Bayes. Otra forma que ha mostrado ser muy efectiva, según nuestra experiencia, es recordar que el teorema establece una relación entre A dado B y B dado A. En este enfoque, lo que se coloca arriba en la fórmula es A y lo que se coloca abajo es BBB. Es decir, se visualiza que la probabilidad condicional de A dado B se expresa en términos de BBB dado A, lo que facilita su comprensión y aplicación. Es decir, se visualiza que la probabilidad condicional  $A|B$ , se expresa en términos de  $B|A$ , lo que facilita su comprensión y aplicación, especialmente cuando se parte de evidencia observable (como síntomas) para inferir causas subyacentes (como diagnóstico).

$$P( B | A ) = \frac{P( B )}{P( A )} \cdot P( A | B ) \quad (13)$$

Es importante destacar que, en el Teorema de Bayes, cuando se desea calcular  $A|B$ , el evento A (el que se quiere conocer) se ubica en el numerador, y el evento B (la evidencia disponible) en el denominador. También es fundamental tener en cuenta el orden en el que se coloca cada término en la ecuación, ya que este orden no solo facilita la memorización, sino que también ayuda a entender la analogía entre las probabilidades condicionadas. Al seguir este patrón, el estudiante puede visualizar más claramente cómo se relacionan A dado B y B dado A, mejorando tanto la comprensión como la retención del teorema. Esta claridad es esencial al enfrentarse a problemas donde se deben hacer

inferencias inversas, como en el aprendizaje automático supervisado o en inferencias bayesianas con distribuciones posteriores.

Una mnemotecnica para aprender la función generadora de momentos y características se basa en dos triángulos invertidos en el exponente. Considere la siguiente expresión:

$$e^{V+V} \tag{14}$$

Esta expresión, de carácter pedagógico, se relaciona con la siguiente frase que proponemos: “exponencial de triángulo lineal más triángulo cuadrático”. En el primer triángulo se coloca "t", "μ" y "1"; y en el triángulo cuadrático, "t<sup>2</sup>", "σ<sup>2</sup>" y "2". Note que la primera terna de valores está relacionada con conceptos lineales: "t" es lineal, "media" es el momento lineal, y "1" representa el orden de una ecuación lineal. Este método mnemotécnico se denomina la “analogía”, y se basa en la relación entre figuras o definiciones geométricas y un concepto a memorizar. Por otro lado, la segunda terna, cuadrática, está asociada con la función cuadrática: la "varianza" corresponde al segundo momento cuadrático y "2" es el orden de la función cuadrática.

Por otro lado, la segunda terna, cuadrática, esta asociada con la función cuadrática: la “varianza” corresponde al segundo momento cuadrático y “2” es el orden de la función cuadrática. Esta distinción entre triángulo lineal y cuadrático permite entender la estructura de la función generadora de momentos como una expansión natural de los momentos centrales de la distribución. Además, este enfoque ayuda a visualizar el crecimiento de los momentos de manera progresiva, una idea útil para entender series de Taylor y desarrollos asintóticos en estadística avanzada.

Ahora se llena de la siguiente manera.

Primer paso: se colocan los tres argumentos vacíos.

$$e^{\frac{() + ()}{()} + \frac{() + ()}{()}} \tag{15}$$

Segundo paso: se llenan las ternas lineal y cuadrática respectivamente.

$$e^{\frac{(t) + (\mu)}{(1)} + \frac{(t^2) + (\sigma^2)}{(2)}} \tag{16}$$

Tercer paso: simplificar.

$$M(t) = e^{t\mu + \frac{t^2\sigma^2}{2}} \tag{17}$$

A esta última expresión se le conoce como la función generadora de momentos de la distribución normal (Zhang, & Zhou, 2022). De manera análoga, se puede aplicar esta mnemotecnica para la función característica. Sin embargo, en lugar de usar solo "t", se hace uso de "t" multiplicado por la unidad imaginaria, que en este trabajo se ha denominado "j". Este enfoque permite recordar cómo se calcula la función característica de la distribución normal, aplicando la misma estructura de triángulos geométricos, pero con la diferencia de incluir la unidad



imaginaria en lugar de simplemente "t". Esto resulta especialmente útil en campos como el procesamiento de señales o la teoría de sistemas estocásticos, donde la unidad imaginaria aparece de forma natural.

Como ejercicio para el lector se deja la verificación con la metodología por analogía verificar que:

$$C(t) = e^{t\mu j - \frac{t^2\sigma^2}{2}} \quad (18)$$

Para aquellos que han tomado un curso de cálculo integral o ecuaciones diferenciales, la transformada de Laplace es un concepto familiar. Una mnemotecnia útil para aprender la función generadora de momentos es asociarla con la transformada de Laplace, ya que se establece la siguiente relación:

$$M_X(t) := \int_{-\infty}^{\infty} e^{tx} f(x) dx = L(f(x))(t) \quad (19)$$

Note que la función generadora de momentos es, en realidad, la transformada bilateral de Laplace de toda la variable aleatoria. Esta conexión permite vincular teoría de probabilidad con análisis funcional, y comprender por qué muchas propiedades de la distribución pueden derivarse a partir de sus transformadas. Asimismo, el estudiante que esté familiarizado con la transformada de Fourier puede recordar la función característica de la siguiente manera:

$$C_X(t) := \int_{-\infty}^{\infty} e^{jtx} f(x) dx = F(f(x))(t) \quad (20)$$

La analogía con la transformada de Fourier permite interpretar la función característica como una herramienta de análisis espectral, lo cual es fundamental en campos como econometría, mecánica cuántica y análisis de señales aleatorias.

## CONCLUSIÓN

El uso de las mnemotécnicas basadas en analogías y patrones geométricos construye una herramienta pedagógica valiosa para facilitar el aprendizaje de conceptos matemáticos complejos. Tal como se evidenció en el apartado de desarrollo, estrategias como la secuencia "BABABA" para el Teorema de Bayes y los triángulos invertidos en las funciones generadores de momentos permiten a los estudiantes representar visualmente fórmulas abstractas, favoreciendo se comprensión y memorización.

Estas técnicas no solo simplifican el proceso de asimilación de contenidos, sino que también promueven un aprendizaje más activo y significativo. Asociar términos como media, varianza y parámetros algebraicos con estructuras visuales como triángulos lineales y cuadráticos convierte la experiencia de aprendizaje en un proceso más intuitivo, especialmente útil para estudiantes con estilos de aprendizaje visual o kinestésico.

Además, las mnemotecnias fomentan la creatividad en el aula, el abrir posibilidades para que los propios estudiantes desarrollen sus propias

estrategias de memorización y comprensión. Esta participación activa contribuye a que internalicen mejor las fórmulas y comprendan los fundamentos conceptuales que las sustentan, en lugar de limitarlas a una repetición mecánica.

Finalmente, este ensayo demuestra que las mnemotécnicas no son simplemente recursos auxiliares, sino estrategias cognitivas esenciales para acercar al estudiante a las matemáticas de manera amigable y reflexiva. Incorporarlas de forma sistemática en la enseñanza de la teoría de probabilidades puede fortalecer tanto la motivación como el rendimiento académico, haciendo que el aprendizaje de las matemáticas sea no solo más accesible, sino también más significativo.

#### **Rol de contribución**

**Jhonier Rangel:** Conceptualización, análisis formal, investigación, escritura–borrador original, escritura–revisión y edición, visualización, supervisión, administración del proyecto.

**Wilson Gordillo:** Conceptualización, análisis formal, investigación, escritura–borrador original, escritura revisión y edición, recursos, visualización

**Wilson Pinzón:** Escritura –revisión y edición, recursos, visualización.

#### **REFERENCIAS**

- Araya-Moya, S. M., Gutiérrez, A. L. R., Cárdenas, N. F. B., & Moreno, K. C. M. (2022). El aula invertida como recurso didáctico en el contexto costarricense: estudio de caso sobre su implementación en una institución educativa de secundaria. *Revista Educación*, 46(1), 1-16. <https://www.redalyc.org/journal/440/44068165004/html/>
- Brush, J. E., Lee, M., Sherbino, J., Taylor-Fishwick, J.C., Norman G. (2019) Effect of Teaching Bayesian Methods Using Learning by Concept vs Learning by Example on Medical Students' Ability to Estimate Probability of a Diagnosis: A Randomized Clinical Trial. *JAMA Netw Open*. 2019, 2(12), e1918023. <https://doi.org/10.1001/jamanetworkopen.2019.18023>
- Boon, R., Urton, K., Grünke, M., Rux, T. A. (2019). Mnemonic strategies in mathematics instruction for students with learning disabilities: a narrative review. *Learning Disabilities: a Multidisciplinary Journal*, 24(2). <https://doi.org/10.18666/LDMJ-2019-V24-I2-9901>
- Bulbulia, J. A. (2023). Understanding the Relationship between Science and Religion Using Bayes' Theorem. *Studies in Christian Ethics*, 36(4), 866-878. <https://doi.org/10.1177/09539468231187772>
- Drushlyak, M. G., Semenikhina, O. V., Proshkin, V. V., & Sapozhnykov, S. V. (2021, March). *Training pre-service mathematics teacher to use mnemonic techniques*. In IOP Publishing (Ed.), *Journal of Physics: Conference Series*, 1840(1), 012006. <https://doi.org/10.1088/1742-6596/1840/1/012006>

- Haiyan, G. (2024). *Mnemonics*. En Z. Kan (Ed.), *The ECPH encyclopedia of psychology* (pp. 944-945). Springer. [https://doi.org/10.1007/978-981-97-7874-4\\_972](https://doi.org/10.1007/978-981-97-7874-4_972)
- Hunt, N. (2010), Using Mnemonics in Teaching Statistics. *Teaching Statistics*, 32, 73-75. <https://doi.org/10.1111/j.1467-9639.2009.00402.x>
- Kerr, G., González-Parra, G., & Sherman, M. (2022). A new method based on the Laplace transform and Fourier series for solving linear neutral delay differential equations. *Applied Mathematics and Computation*, 420, 126914. <https://doi.org/10.1016/j.amc.2021.126914>
- McCabe, J. A., Osha, K. L., Roche, J. A., & Susser, J. A. (2013). Psychology Students' Knowledge and Use of Mnemonics. *Teaching of Psychology*, 40(3), 183-192. <https://doi.org/10.1177/0098628313487460>
- Pinkovetskaia, I. S., Nuretdinova, Y. V., Nuretdinov, I., & Lipatova, N. (2021). Mathematical modeling on the base of functions density of normal distribution. *Revista de la Universidad del Zulia*, 12(33), 34-49. <http://dx.doi.org/10.46925/rdluz.33.04>
- Rangel, J. (2024). *Métodos inferenciales sobre cadenas de Markov en tiempo discreto con espacio de estados finito*. En Instituto Universitario de Innovación Ciencia y Tecnología INUDI (Ed.), *Actas del II Congreso Internacional de Innovación, Ciencia y Tecnología INUDI-UH, 2024* (cap. 15). <https://doi.org/10.35622/inudi.c.02.15>
- Rahman, M. M., Tabash, M. I., Salamzadeh, A., Abduli, S., & Rahaman, M. S. (2022). Sampling techniques (probability) for Quantitative Social Science Researchers: a Conceptual Guidelines with Examples. *Seeu Review*, 17(1), 42-51. <https://doi.org/10.2478/seeur-2022-0023>
- Wang, H., van Stein, B., Emmerich, M., & Back, T. (2017). *A new acquisition function for Bayesian optimization based on the moment-generating function*. En *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* (pp. 507-512). IEEE. [10.1109/SMC.2017.8122656](https://doi.org/10.1109/SMC.2017.8122656)
- Zhang, Q., & Zhou, Y. (2022). Recent advances in non-Gaussian stochastic systems control theory and its applications. *International Journal of Network Dynamics and Intelligence*, 1(1), 111-119. <https://doi.org/10.53941/ijndi0101010>