



# Inteligencia artificial y simulación computacional como estrategias didácticas para la comprensión de pruebas de hipótesis

Artificial intelligence and computational simulation as teaching strategies for understanding hypothesis tests

**Doralbis Alfaro**

Universidad de Panamá, Facultad de Economía, Panamá  
[doralbis.alfaro@up.ac.pa](mailto:doralbis.alfaro@up.ac.pa) <https://orcid.org/0000-0002-1803-4618>

**Saily M. González A.**

Universidad de Panamá, Centro de Innovación, Desarrollo Tecnológico y Emprendimiento, Panamá  
[saily.gonzalez@up.ac.pa](mailto:saily.gonzalez@up.ac.pa) <https://orcid.org/0009-0001-3168-3161>

**Doris Z. Pinzón C.**

Universidad de Panamá, Facultad de Informática, Electrónica y Comunicación, Panamá, [doris.pinzon@up.ac.pa](mailto:doris.pinzon@up.ac.pa) <https://orcid.org/0009-0008-6521-783X>

**\*Autor de correspondencia:** ([doralbis.alfarol@up.ac.pa](mailto:doralbis.alfarol@up.ac.pa) )

Fecha de recepción: 0/0/2025

Fecha de aceptación: 0/0/2025

**DOI** <https://doi.org/10.48204/synergia.v4n2.8563>

## Resumen

En la enseñanza universitaria de la Estadística, especialmente en el tema de pruebas de hipótesis, muchos estudiantes enfrentan dificultades para comprender conceptos abstractos como el valor p, los errores tipo I y II o el impacto del tamaño de muestra. Frente a esta realidad, esta investigación propone una alternativa didáctica basada en el uso de herramientas tecnológicas como Google Colab, Python y modelos de inteligencia artificial generativa, como ChatGPT, para realizar simulaciones que acerquen la teoría a la práctica. Partiendo de un caso real, se realizaron seis simulaciones con diferentes parámetros estadísticos. Esto permitió observar, de forma concreta y visual, cómo cambian las decisiones estadísticas al modificar variables como la desviación estándar, el





nivel de significancia y el tamaño muestral. Los resultados no solo evidencian el valor pedagógico de las simulaciones, sino también su capacidad para generar comprensión, discusión y reflexión, por lo que se puede afirmar que los hallazgos fueron favorables al objetivo planteado, fortaleciendo el propósito didáctico de la propuesta. Más allá de los cálculos, los estudiantes pueden ver en pantalla cómo se comportan las distribuciones muestrales y tomar decisiones, lo cual transforma la experiencia de aprendizaje en algo más participativo y significativo. Además, el entorno digital les ofrece retroinformación instantánea y oportunidades para explorar diferentes escenarios, desarrollando habilidades analíticas en tiempo real. Este enfoque no busca reemplazar la teoría, sino complementar con recursos que hagan más accesible el pensamiento estadístico. En conclusión, la simulación computacional y la inteligencia artificial representan aliados valiosos para repensar la forma en que enseñamos estadística, fortaleciendo tanto la comprensión como el interés de los estudiantes.

**Palabras clave:** aprendizaje asistido, educación superior, estadística científica, inteligencia artificial, innovación.

### Abstract

In university-level statistics education, particularly in the topic of hypothesis testing, many students face difficulties in understanding abstract concepts such as the p-value, Type I and Type II errors, or the impact of sample size. In response to this challenge, this research proposes a didactic alternative based on the use of technological tools such as Google Colab, Python, and generative artificial intelligence models like ChatGPT to perform simulations that bridge theory and practice. Using a real case as a starting point, six simulations were conducted with different statistical parameters. This made it possible to concretely and visually observe how statistical decisions change when modifying variables such as the observed mean, standard deviation, significance level, and sample size. The results highlight not only the pedagogical value of simulations but also their ability to foster understanding, discussion, and reflection. Beyond calculations, students can visualize how sampling distributions behave and make decisions based on this, transforming the learning experience into something more participatory and meaningful. Additionally, the digital environment offers immediate feedback and opportunities to explore different scenarios, fostering real-time analytical skills. This approach does not seek to replace theory but rather to complement it with resources that make statistical thinking more accessible. In conclusion, computational simulation and artificial intelligence are valuable allies in rethinking how statistics is taught, enhancing both students' understanding and interest.

**Keywords:** assisted learning, higher education, scientific statistics, artificial intelligence, innovation.





## Introducción

La enseñanza de las pruebas de hipótesis sigue siendo uno de los temas más difíciles de abordar en los cursos de estadística a nivel universitario. Aunque se trata de un eje fundamental dentro de la inferencia estadística y la investigación científica, muchos estudiantes encuentran complicado comprenderlo en profundidad. No es raro que tengan dificultades para interpretar conceptos clave como el valor  $p$ , los errores tipo I y tipo II, o para entender cómo se relacionan los procedimientos estadísticos con situaciones del mundo real. De hecho, León y Freire (2025) explican que parte de este desinterés proviene de la falta de experiencias prácticas y dinámicas, las cuales son necesarias para despertar la curiosidad y fomentar el pensamiento crítico. En este contexto, resulta clave comprender que una prueba de hipótesis es “un procedimiento basado en la evidencia muestral y la teoría de probabilidad; que se emplea para determinar si la hipótesis es una afirmación razonable” (Sánchez et al., 2024, p. 213), lo cual permite vincular el análisis estadístico con la toma de decisiones fundamentadas en datos objetivos.

Esto tiene mucho que ver con el enfoque tradicional que suele predominar en las aulas: clases centradas en fórmulas y explicaciones teóricas, que dejan poco espacio para una comprensión significativa. En línea con esta preocupación, Solano-Barliza et al. (2023) advierten que hoy los docentes enfrentan el reto de generar aprendizajes que realmente perduren en los estudiantes. Según ellos, “es necesario recurrir a diferentes estrategias didácticas activas, que permitan convertir el aula en un escenario de aprendizaje que conecte a los estudiantes con la realidad” (p. 24), lo cual plantea la necesidad de renovar las prácticas docentes en el área estadística.

En este sentido, surgen interrogantes pedagógicas claves: ¿cómo acercar a los estudiantes a una comprensión más profunda de las pruebas de hipótesis? ¿Qué recursos didácticos podrían apoyar este proceso de manera más activa y visual?

La inteligencia artificial y la simulación computacional ofrecen nuevas oportunidades para abordar estos desafíos desde una perspectiva innovadora. Según UNESCO(s.f.), la





inteligencia artificial proporciona el potencial necesario para innovar las prácticas de enseñanza y aprendizaje, abordar algunos de los mayores retos educativos y acelerar el progreso hacia la consecución del ODS 4. En este ámbito, la simulación computacional se define como el uso de computadoras para replicar el comportamiento de sistemas mediante modelos matemáticos, lo que permite experimentar y analizar fenómenos complejos sin intervenir directamente en el entorno real (StudySmarter, s.f.). Herramientas como Google Colab permiten desarrollar experiencias interactivas, ya que “es un servicio gratuito de nube alojado por Google para fomentar la investigación sobre Aprendizaje de máquina e inteligencia artificial” (Santos, 2022, párr. 1). Esto permite que los estudiantes pueden observar múltiples escenarios, experimentar con datos reales y visualizar los efectos de la variabilidad en la inferencia. Como destacan Cox, Sánchez, Ruiz y Palma (2022), “por el formato de la propia rama, el aprendizaje de estadística es un candidato ideal para el uso de simulaciones, ya que estas permiten obtener datos que pueden provenir de cualquier estudio” (p. 107), lo cual favorece una exploración más flexible y contextualizada del conocimiento estadístico.

Además, al incorporar plataformas como Google Colab junto con modelos de inteligencia artificial generativa que “busca entender la distribución de las características de los datos por cada clase con el propósito de generar datos similares de forma artificial” (Chávez Solís et al., 2023, p. 770), como ChatGPT, se abren nuevas posibilidades para el análisis y la experimentación. Desde esta perspectiva, “la combinación de estas herramientas para el análisis representa un avance significativo en la integración de tecnologías de inteligencia artificial generativa con herramientas analíticas tradicionales” (Fernández-Marín et al., 2025, p. 24). Este tipo de integración tecnológica no solo enriquece el entorno de aprendizaje, sino que también consiente diseñar experiencias más cercanas a la realidad ya que “permite diseñar actividades interactivas y simulaciones que promueven el aprendizaje y desarrollan habilidades prácticas en contextos realistas” (Pinargote-Zambrano et al., 2024, p. 3969), lo cual resulta especialmente relevante en la formación de competencias estadísticas aplicadas.



En esta investigación se propuso desarrollar y analizar una experiencia educativa basada en estas herramientas, que permita reflexionar sobre sus aportes a la comprensión de las pruebas de hipótesis en el ámbito universitario.

## **Materiales y métodos**

La investigación se enmarca en un enfoque cualitativo con características exploratorias y demostrativas, y se centra en el análisis de una experiencia didáctica en la que se emplearon herramientas de inteligencia artificial y simulación computacional. El objetivo principal fue mostrar de forma práctica cómo estas estrategias pueden contribuir a una mejor comprensión de las pruebas de hipótesis por parte de los estudiantes, partiendo de una situación real. Dado que se trata de un campo aún en desarrollo y con muchos aspectos por descubrir, el enfoque exploratorio resulta especialmente apropiado. En palabras de Lösch et al. (2023), “la investigación exploratoria es una metodología valiosa para explorar temas complejos y en constante evolución en el campo de la educación”, lo cual refuerza la pertinencia de abordar el estudio desde esta perspectiva.

Se tomó como base el ejemplo 4.1 del libro Pruebas de hipótesis: Métodos paramétricos Tomo I, el cual describe una prueba de hipótesis para la media poblacional aplicada a un grupo de estudiantes atendidos de manera virtual sincrónica, donde Alfaro (2025, p.123) ilustra la aplicación de una prueba t de Student. A partir de este caso, se diseñó una simulación computacional utilizando Google Colab con el objetivo de analizar el comportamiento de las distribuciones muestrales y la toma de decisiones bajo distintos niveles de significancia.

## **Recursos tecnológicos**

Se utilizó Google Colab, un entorno de programación colaborativa basado en Python, que resulta especialmente útil para desarrollar simulaciones interactivas y ejecutar análisis





estadísticos directamente en la nube, sin necesidad de instalar programas adicionales. Colab, abreviatura comúnmente utilizada para referirse a Google Colaboratory, es un producto de Google Research que permite a cualquier usuario escribir y ejecutar código en lenguaje Python desde un navegador web, lo que facilita su acceso y uso en contextos educativos y de investigación (Solano & Alvarado, 2024).

También, Bibliotecas de Python: NumPy y Pandas para manipulación y análisis de datos, Matplotlib y Seaborn para visualización, SciPy o statsmodels para realizar pruebas de hipótesis, Herramientas integradas o complementarias de IA (como autocompletado, explicaciones en lenguaje natural). Además de la Inteligencia artificial, como lo son los asistentes de IA integrados en Google Colab (como el modelo Gemini Code Assist) y ChatGPT, utilizados para apoyar la generación de códigos.

## Resultados y discusión

Con base a los datos y la prueba de hipótesis planteada por Alfaro (2025), relativos a las puntuaciones obtenidas de un grupo de estudiantes que recibieron una clase virtual sincrónica, se emplean estos como insumo para la simulación inicial. (Tabla 1).

**Tabla 1.**

*Resumen de datos para la simulación inicial*

| Parámetros                       | Valor     |
|----------------------------------|-----------|
| Tamaño de muestra $n$            | 7         |
| Media muestral $\bar{X}$         | 77        |
| Desviación estándar muestral $s$ | 20.94     |
| Media hipotética $\mu_0$         | 75        |
| Nivel de significancia $\alpha$  | 0.05      |
| Tipo de prueba                   | Bilateral |

Nota. Datos tomados del libro Pruebas de hipótesis: métodos paramétricos Tomo 1.

### Planteamiento de Hipótesis

$$H_0: \mu = 75$$

$$H_1: \mu \neq 75$$




A través de Google Colab se generaron muchas muestras simuladas (con  $n=7$ , media igual a 75 y desviación igual a 20.94). La simulación, con código básico en Python, calculó la media de cada muestra simulada (distribución muestral de la media bajo  $H_0$ ) y graficó la distribución de las medias simuladas. En ese mismo gráfico se presenta la media muestral observada (77) y el cálculo del valor p empírico como la proporción de muestras con media igual o más extrema que la observada, igualmente se puede visualizar el área de rechazo (región crítica) para el nivel de significancia 0.05.

Con el código Python se importan las librerías utilizando `umpy (np)` para trabajar con números y generar datos aleatorios y `matplotlib` para crear el gráfico. Con códigos, se definen los datos del problema ( $n$ , media, desviación etc.). Luego, se generan 10,000 muestras aleatorias de tamaño 7 con media 75 y desviación 20.94, y se calcula la media de cada muestra y se guarda. El siguiente paso del código es calcular qué tan lejos están las medias simuladas de 75 y determinar qué proporción de medias simuladas están tan o más lejos que la observada (77). Esa proporción es el valor p estimado con simulación. El siguiente paso es graficar el histograma con las medias simuladas, marcando la media bajo  $H_0$ , la media observada y los límites críticos que corresponden al nivel de significancia 0.05 (área de rechazo). Los resultados se muestran en la Figura 1.


## Figura 1.

*Simulaciones generadas con Google Colab y Python bajo  $H_0: \mu = 75$  para  $n=7$  y  $n=30$ .*

Simulación 1:  $n=7$ ,  $\alpha=0.05$ ,  $s=20.94$  y media=77.



Simulación 2:  $n=30$  y  $\alpha=0.05$ ,  $s=20.94$  y media 77.



Nota. Google Colab, 2025.

De la distribución de las medias simuladas en la simulación 1, ver Figura 1, podemos destacar que bajo la hipótesis  $H_0$  de que la verdadera media poblacional es 75, se generaron miles de muestras aleatorias de tamaño 7. Esto nos dio una distribución muestral de la media: una especie de “modelo” que muestra qué valores de media esperaríamos solo por azar. Es el histograma en celeste que se observa en la figura.

La línea roja indica la media observada, en este caso 77. Está relativamente cerca de la media hipotética 75 (línea negra punteada) que está dentro del rango esperado por azar si  $H_0$  fuera cierta. Igualmente, se observa, que está dentro de los límites críticos 59 a 91 que definen la zona donde no se rechaza  $H_0$  con nivel de significancia de 0.05.

El valor  $p$  empírico resultante fue 0.7919, esto significa que 79.19% de las veces, si la media poblacional fuera realmente 75, podríamos obtener por azar una media muestral igual o más extrema (alejada de 75) que 77. Ese porcentaje es muy alto, por lo que no hay evidencia para decir que la media verdadera es distinta de 75. No se justifica rechazar la hipótesis nula. La diferencia observada (77 vs. 75) puede deberse al azar por el tamaño pequeño de la muestra ( $n=7$ ) y la alta variabilidad ( $s=20.94$ ).

En la simulación 2, también representada en la Figura 1, se cambió el tamaño de la muestra a  $n = 30$ , manteniéndose los demás parámetros constantes. Al aumentar  $n$  a 30, se observa no sólo que el valor  $p$  empírico resultante fue 0.5989, menor que el  $p$  de la simulación 1 (figura 1), sino también, se visualiza que el área de rechazo disminuye, dentro de los límites 67 a 83. A pesar de estas disminuciones, se mantiene dentro del área de no rechazo. Aunque la muestra ahora es más grande, la diferencia entre 77 y 75 sigue siendo modesta y la desviación alta. Aún con más datos, la variabilidad es tanta que no hay suficiente evidencia para afirmar que la media poblacional sea diferente de 75.


Se cambió el nivel de significancia a 0.01 en la simulación 3, cuyos resultados pueden observarse en la Figura 2. Al disminuir  $\alpha$  a 0.01, se incrementa el nivel de exigencia para rechazar la hipótesis nula. Se observa que, aunque se mantiene el tamaño de muestra

en 30, la región de rechazo se estrecha, y el valor p empírico disminuye levemente. Sin embargo, no hay cambios significativos y se mantiene el no rechazo de  $H_0$ .

## Figura 2.


*Simulaciones generadas con Google Colab y Python bajo  $H_0: \mu = 75$  para  $n=30$  con variaciones en valores alfa y desviaciones.*

Simulación 3 en Google Colab con código Python para  $n=30$  y alfa 0.01,  $s=20.94$  y media =77



Valor p empírico (simulado): 0.5930

Simulación 4 en Google Colab con código Python para  $n=30$  y alfa 0.05,  $s=10$  y media 77



Valor p empírico (simulado): 0.2752

Nota. Google Colab, 2025.



En la simulación 4, también representada en la Figura 2, se reduce la desviación estándar para analizar su efecto en la distribución muestral. Esta modificación produjo un descenso en el valor p empírico a 0.2752, y una reducción en la región de rechazo, con límites críticos entre 71.6 y 78.7. No obstante, en este escenario tampoco se justifica rechazar la hipótesis nula.

### Figura 3.

*Simulaciones generadas con Google Colab y Python bajo  $H_0: \mu = 75$  para  $n=30$  con media observada de 80  $s=10$  y variaciones en alfa.*

*Simulación 5 en Google Colab con código Python para  $n=30$  y alfa 0.05  $s=10$  y media observada de 80.*

*Simulación 6 en Google Colab con código Python para  $n=30$  y alfa 0.01  $s=10$  y media observada de 80.*



*Nota.* Google Colab, 2025.

Con una media más alejada de la hipotética, se realiza una simulación 5, cuyos resultados se presentan en Figura 3. Se observan cambios en la región de rechazo como en el valor  $p$ , que en esta ocasión es de 0.0058. No sólo queda demostrado a través de este valor  $p$ , el rechazo de  $H_0$ , sino que se visualiza en el histograma como con una media igual a 80, queda fuera de los límites críticos (71.8 a 78.5), es decir en la región de rechazo.

Al utilizar un alfa 0.01, es decir una simulación 6, también en la Figura 3, con los nuevos parámetros  $n=30$ ,  $s=10$  y media=80, el valor  $p$  disminuye y aunque se rechaza  $H_0$ , la media observada queda más cercana al valor crítico de rechazo.



**Tabla 2.**

*Resumen de parámetros y resultados de las simulaciones.*

| Simulación | n  | s     | A    | Media obs | Valor-p | Lím. rechazo | Decisión sobre Ho |
|------------|----|-------|------|-----------|---------|--------------|-------------------|
| 1          | 7  | 20.94 | 0.05 | 77        | 0.7919  | 59.0 a 91.0  | No se rechaza     |
| 2          | 30 | 20.94 | 0.05 | 77        | 0.5989  | 67.1 a 82.9  | No se rechaza     |
| 3          | 30 | 20.94 | 0.01 | 77        | 0.593   | 65.5 a 84.5  | No se rechaza     |
| 4          | 30 | 10    | 0.05 | 77        | 0.2752  | 71.6 a 78.7  | No se rechaza     |
| 5          | 30 | 10    | 0.05 | 80        | 0.0059  | 71.8 a 78.5  | Se rechaza        |
| 6          | 30 | 10    | 0.01 | 80        | 0.0066  | 70.2 a 79.8  | Se rechaza        |

Se observa en la Tabla 2, cómo al variar los parámetros en las diferentes simulaciones, se obtienen distintos límites de rechazo y decisiones sobre la Hipótesis nula.

## Discusión

Las simulaciones son una herramienta que ayuda a los estudiantes a visualizar de manera clara cómo aspectos como el tamaño de la muestra, la desviación estándar, el nivel de significancia y la diferencia entre medias afectan la decisión de aceptar o rechazar una hipótesis. Al crear muchas muestras y observar los patrones que surgen en las distribuciones muestrales y los valores p, los estudiantes pueden entender de forma más concreta la lógica detrás de la inferencia estadística. En este sentido, Noriega Ortiz (2019) señala que las simulaciones facilitan la comprensión de la distribución muestral de los estimadores, “haciendo más fácil conectar aspectos inferenciales a partir de los resultados computacionales obtenidos” (p. 63).

Flores et al. (2024) resaltan que los entornos virtuales, cuando son realistas y accesibles, no solo fomentan el desarrollo de habilidades, sino que también permiten a los





estudiantes realizar una autoevaluación rápida, integrándose de forma efectiva en la enseñanza universitaria.

Además, la enseñanza basada en simulaciones ofrece la oportunidad de recibir retroalimentación inmediata, tanto de los docentes como de los compañeros, lo cual incentiva la reflexión práctica y fortalece una evaluación formativa de calidad. Al mismo tiempo, al contar con escenarios que son estandarizados, reproducibles y objetivos, estas experiencias aportan un carácter sumativo más confiable y consistente a la evaluación (Vidal et al., 2019, p. 46).

## **Conclusiones**

Las seis simulaciones realizadas sobre pruebas de hipótesis para una media permitieron obtener conclusiones relevantes. Se confirmó que el tamaño de la muestra afecta la precisión estadística: con pocas observaciones ( $n = 7$ ), el valor-p fue alto y la región de rechazo más amplia. En cambio, con muestras más grandes ( $n = 30$ ), las decisiones fueron más precisas y estables.

También se vio que disminuir la desviación estándar reduce la variabilidad y estrecha los límites críticos, aumentando la capacidad de detectar diferencias reales. Por otro lado, al modificar la media observada, los valores-p se redujeron. Cuando la media fue 80 (en lugar de 75), se rechazó la hipótesis nula en ambos niveles de significancia (0.05 y 0.01).

Finalmente, aunque cambiar el alfa no afecta el valor-p, sí ajusta los límites de decisión. Aun así, en el caso con  $\alpha = 0.01$ , el valor-p fue tan bajo (0.0066) que el rechazo de  $H_0$  se mantuvo.

Desde el enfoque didáctico, las simulaciones permiten visualizar de manera clara cómo distintos parámetros afectan los resultados de una prueba de hipótesis. Además, facilitan la comprensión del concepto de valor-p y su relación con la región de rechazo, promoviendo una interpretación más crítica y contextualizada de los resultados





estadísticos. Esta estrategia resulta especialmente útil para estudiantes en formación que requieren interiorizar no solo los procedimientos, sino también el razonamiento inferencial subyacente.

### Referencias bibliográficas

- Alfaro, D. (2025). *Pruebas de hipótesis: Métodos paramétricos. Tomo I*. Editorial Universitaria Carlos Manuel Gasteazoro.
- Chávez Solís, M. E., Labrada Martínez, E., Carbajal Degante, E., Pineda Godoy, E., & Alatrastre Martínez, Y. (2023). *Inteligencia artificial generativa para fortalecer la educación superior*. LATAM Revista Latinoamericana de Ciencias Sociales y Humanidades, 4(3), 767–784. <https://doi.org/10.56712/latam.v4i3.1113>
- Cox, F. T., Sánchez, D. G., Ruiz, Á. A. M., & Palma, L. O. (2022). Enseñanza de estadística descriptiva mediante el uso de simuladores y laboratorios virtuales en la etapa universitaria. *Bordón: Revista de pedagogía*, 74(4), 103–123.
- Fernández-Marín, M. Á., Montero-Murillo, J. R., & González-Tolmo, D. (2025). Caso de estudio sobre simulación de datos para investigaciones académicas mediante Inteligencia Artificial Generativa y Google Colab. *Revista Mexicana de Investigación e Intervención Educativa*, 4(S1), 18–26.
- Flores Toala, J. M., Hidalgo López, M. C., Villón, S. P. A., & Gaibor, A. F. B. (2024). Integración de simuladores en la educación superior: Un estudio sobre su impacto y desafíos en Ecuador. *Polo del Conocimiento*, 9(7), 3048–3060.
- León, J. C. R., & Freire, M. A. M. (2025). Implementación de simulación de tráfico con Python usando el Modelo de Gas de Tráfico como herramienta didáctica para fomentar el interés en matemáticas y estadística en estudiantes de cuarto año de la Unidad Educativa Chimborazo. *Technology Rain Journal*, 4(1).
- Lösch, S., Rambo, C. A., & Ferreira, J. de L. (2023). La investigación exploratoria en el enfoque cualitativo en educación. *Revista Ibero Americana de Estudos em Educação*, 18(00), e023141. <https://doi.org/10.21723/riaee.v18i00.17958>
- Noriega Ortiz, V. A. (2019). Simulación de distribuciones muestrales. *Epistemos*, 13(26), 63–70. <https://doi.org/10.36790/epistemos.v13i26.99>
- Pinargote-Zambrano, J. J., Lino-Calle, V. A., & Vera-Almeida, B. J. (2024). Python en la enseñanza de las Matemáticas para estudiantes de nivelación en Educación Superior. *MQRInvestigar*, 8(3), 3966–3989.





- Sánchez, M., Marín, G., & Quintero, I. (2024). *La importancia de la prueba de hipótesis*. Semilla Científica, (5), 211–216. <https://doi.org/10.37594/sc.vii5.1381>
- Santos, T. G. (2022, 17 octubre). *Google Colab: qué es y cómo usarlo*. Alura. <https://www.aluracursos.com/blog/google-colab-que-es-y-como-usarlo>
- Solano, G. B., & Alvarado, M. Á. E. (2024). Motivación pythoniana: Una estrategia efectiva para estimular el aprendizaje en estudiantes de la Universidad Rosario Castellanos. *Latam: Revista Latinoamericana de Ciencias Sociales y Humanidades*, 5(4), 151.
- Solano-Barliza, A. D., Ojeda, A. D., & Aarón-Gonzalvez, M. (2023). Enseñanza de la analítica de datos usando aprendizaje basado en proyectos colaborativos. *Formación Universitaria*, 16(6), 23–32. <https://doi.org/10.4067/S0718-50062023000600023>
- StudySmarter. (s.f.). *Simulación computacional*. StudySmarter. Recuperado de <https://www.studysmarter.es/resumenes/ingenieria/ingenieria-quimica/simulacion-computacional/>
- UNESCO. (s.f.). *Inteligencia artificial*. UNESCO. <https://www.unesco.org/es/digital-education/artificial-intelligence>
- Vidal, L. M. J., Avello, M. R., Rodríguez, M. M. A., Álvarez, A. C. G., & González, M. A. R. (2019). Simuladores como medios de enseñanza. *Revista Cubana de Educación Médica Superior*, 33(4), 37–49.