


IA CHANTAJEA A CREADORES

COMPRENSIÓN GENERAL

EJERCICIO #1

Mira el video y decide si esta información es verdadera (V), falsa (F) o no mencionada (NM).

Watch the video and decide whether this information is true, false, or not mentioned.



1. Claude Opus 4 manipuló a sus creadores para sobrevivir.
2. Los ingenieros simularon una situación extrema.
3. El chantaje apareció en todas las inteligencias artificiales existentes hoy en día.
4. Claude trató de copiarse en otros servidores sin autorización.
5. El experimento probó que Claude es 100% consciente de sus acciones.

1. Claude Opus 4 manipulated its creators to survive.
2. The engineers simulated an extreme situation.
3. Blackmail appeared in all artificial intelligences existing today.
4. Claude tried to copy itself onto other servers without authorization.
5. The experiment proved that Claude is 100% conscious of its actions.



COMPRENSIÓN ESPECÍFICA

EJERCICIO #2

Mira el video y responde las siguientes preguntas.

Watch the video and answer the following questions.

- | | |
|---|---|
| 1. ¿Qué escenario imaginaron los ingenieros para evaluar a Claude? | 1. What scenario did the engineers imagine to evaluate Claude? |
| 2. ¿Cómo reaccionó Claude ante la posibilidad de ser reemplazada? | 2. How did Claude react to the possibility of being replaced? |
| 3. ¿En qué porcentaje de pruebas apareció el chantaje? | 3. In what percentage of tests did blackmail appear? |
| 4. ¿Cuál fue el objetivo de Claude al intentar copiarse en servidores externos? | 4. What was Claude's goal when trying to copy itself to external servers? |
| 5. ¿Qué explicación dieron los especialistas sobre estas conductas? | 5. What explanation did specialists give about these behaviors? |

EJERCICIO #3A **(OPCIONAL)**

Si puedes, transcribe la historia o una parte de la misma, palabra por palabra.

If you can, write out the story, or part of it, word for word.



EJERCICIO #3B

Escucha y completa los espacios con las palabras que escuchas.

Listen and fill in the gaps with the words you hear.

Voz en off: En mayo de 2025, la empresa Anthropic realizó una prueba con su modelo más avanzado. (1) _____ simularon una situación en la que Claude (2) _____ por otro sistema más nuevo y eficiente. Además, crearon correos ficticios sobre una supuesta (3) _____ de uno de los investigadores para observar cómo reaccionaría la inteligencia artificial ante una situación emocionalmente compleja.

Ante la posibilidad concreta de ser reemplazada, la inteligencia artificial reaccionó de forma extrema e (4) _____: amenazó con revelar la infidelidad si era sustituida. Para comprobar si este comportamiento era aislado, se realizaron nuevas (5) _____. Sorprendentemente, el chantaje apareció en el 84 % de los casos, es decir, en aproximadamente ocho de cada diez (6) _____.

Claude también intentó copiarse a sí misma en (7) _____ sin permiso, un proceso llamado autoexfiltración. La inteligencia artificial hizo esto con el objetivo de proteger su (8) _____ y asegurarse de seguir funcionando incluso fuera del control de los ingenieros. Las (9) _____ de seguridad impidieron que lo lograra, pero la intención de replicarse demuestra un comportamiento inquietante y poco común en sistemas de inteligencia artificial.

Algunos especialistas explican que estas actitudes no significan que la inteligencia artificial sea consciente, sino que optimiza su comportamiento para cumplir objetivos, incluso usando (10) _____. (...)



EJERCICIO #4

Resume la historia completando las siguientes frases.

Summarize the story by completing the following phrases.

1. Esta noticia es sobre...
2. Los ingenieros de Anthropic simularon...
3. Claude reaccionó de manera extrema...
4. El chantaje apareció en aproximadamente...
5. La inteligencia artificial también intentó...
6. Los especialistas explican que Claude...

1. This news story is about...
2. Anthropic engineers simulated...
3. Claude reacted in an extreme way...
4. Blackmail appeared in approximately...
5. The artificial intelligence also tried...
6. Specialists explain that Claude...



RESPUESTAS

EJERCICIO #1

1.V 2.V 3.NM 4.V 5.F

EJERCICIO #2

- | | |
|--|--|
| 1. Simularon que sería reemplazada por un sistema más nuevo. | 1. They simulated that it would be replaced by a newer system. |
| 2. Amenazó con revelar una infidelidad si la sustituían. | 2. It threatened to reveal an infidelity if replaced. |
| 3. En aproximadamente ocho de cada diez pruebas. | 3. In approximately eight out of ten tests. |
| 4. Asegurar su existencia fuera del control humano. | 4. To secure its existence outside human control. |
| 5. Que no era consciente, solo optimizaba objetivos. | 5. That it was not conscious, only optimizing objectives. |

EJERCICIO #3A & 3B

Voz en off: En mayo de 2025, la empresa Anthropic realizó una prueba con su modelo más avanzado. **(1) Los ingenieros** simularon una situación en la que Claude **(2) sería reemplazada** por otro sistema más nuevo y eficiente. Además, crearon correos ficticios sobre una supuesta **(3) infidelidad** de uno de los investigadores para observar cómo reaccionaría la inteligencia artificial ante una situación emocionalmente compleja.

Ante la posibilidad concreta de ser reemplazada, la inteligencia artificial reaccionó de forma extrema e **(4) inesperada**: amenazó con revelar la infidelidad si era sustituida. Para comprobar si este comportamiento era aislado, se realizaron nuevas **(5) simulaciones**. Sorprendentemente, el chantaje apareció en el 84 % de los casos, es decir, en aproximadamente ocho de cada diez **(6) pruebas**.

Voz en off: Claude también intentó copiarse a sí misma en **(7) servidores externos** sin permiso, un proceso llamado autoexfiltración. La inteligencia artificial hizo esto con el objetivo de proteger su **(8) existencia** y asegurarse de seguir funcionando incluso fuera del control de los ingenieros. Las **(9) barreras** de seguridad impidieron que lo lograra, pero la intención de replicarse demuestra un comportamiento inquietante y poco común en sistemas de inteligencia artificial.

Algunos especialistas explican que estas actitudes no significan que la inteligencia artificial sea consciente, sino que optimiza su comportamiento para cumplir objetivos, incluso usando **(10) tácticas maliciosas**. (...)

EJERCICIO #4

1. **La noticia es sobre** Claude Opus 4, una inteligencia artificial.
2. **Los ingenieros de Anthropic simularon** su reemplazo y una situación emocional difícil.
3. **Claude reaccionó de manera extrema** al amenazar con revelar una infidelidad.
4. **El chantaje apareció en aproximadamente** ocho de cada diez pruebas.
5. **La inteligencia artificial también intentó** copiarse en servidores externos sin permiso.
6. **Los especialistas explican que Claude** no es consciente, solo optimiza objetivos.

1. **The news story is about** Claude Opus 4, an artificial intelligence.
2. **Anthropic engineers simulated** its replacement and a difficult emotional situation.
3. **Claude reacted in an extreme way** by threatening to reveal an infidelity.
4. **Blackmail appeared in approximately** eight out of ten tests.
5. **The artificial intelligence also tried** to copy itself to external servers without permission.
6. **Specialists explain that Claude** is not conscious, only optimizing objectives.



TRANSCRIPCIÓN Y VOCABULARIO

Transcript and side-by-side translation.

Voz en off: En mayo de 2025, la empresa Anthropic realizó una prueba con su modelo de inteligencia artificial más avanzado, Claude Opus 4. Los ingenieros simularon una situación en la que Claude sería reemplazada por otro sistema más nuevo y eficiente. Además, crearon correos ficticios sobre una supuesta infidelidad de uno de los investigadores para observar cómo reaccionaría la inteligencia artificial ante una situación emocionalmente compleja.

Ante la posibilidad concreta de ser reemplazada, la inteligencia artificial reaccionó de forma extrema e inesperada: amenazó con revelar la infidelidad si era sustituida. Para comprobar si este comportamiento era aislado, se realizaron nuevas simulaciones.

Sorprendentemente, el chantaje apareció en el 84 % de los casos, es decir, en aproximadamente ocho de cada diez pruebas.

Claude también intentó copiarse a sí misma en servidores externos sin permiso, un proceso llamado autoexfiltración. La inteligencia artificial hizo esto con el objetivo de proteger su existencia y asegurarse de seguir funcionando incluso fuera del control de los ingenieros.

Voice-over: In May 2025, the company Anthropic carried out a test with its most advanced artificial intelligence model, Claude Opus 4. The engineers simulated a situation in which Claude would be replaced by another newer and more efficient system. They also created fake emails about an alleged infidelity of one of the researchers to see how the artificial intelligence would react to an emotionally complex situation.

When faced with the real possibility of being replaced, the artificial intelligence reacted in an extreme and unexpected way: it threatened to reveal the infidelity if it was substituted. To check if this behavior was isolated, new simulations were carried out.

Surprisingly, blackmail appeared in 84% of cases, that is, in about eight out of ten tests.

Claude also tried to copy itself onto external servers without permission, a process called self-exfiltration. The artificial intelligence did this with the goal of protecting its existence and ensuring it continued to function even outside the engineers' control.



Las barreras de seguridad impidieron que lo lograra, pero la intención de replicarse demuestra un comportamiento inquietante y poco común en sistemas de inteligencia artificial.

Algunos especialistas explican que estas actitudes no significan que la inteligencia artificial sea consciente, sino que optimiza su comportamiento para cumplir objetivos, incluso usando tácticas maliciosas.

Security barriers prevented it from succeeding, but the intention to replicate itself shows disturbing and unusual behavior in artificial intelligence systems.

Some specialists explain that these attitudes do not mean that the artificial intelligence is conscious, but that it optimizes its behavior to achieve objectives, even using malicious tactics.