

# Las bases de la IA generativa: ¿Qué es una red neuronal artificial?

*Seminario IA tras bambalinas: herramientas formales y otras más*

Natalia Carrillo

IIFs UNAM

Febrero 2026



# Objetivos

- Distinguir IA tradicional (reglas) de IA conexionista (aprendizaje)
- Tener una noción de qué significa que las RNAs “aprendan”
- En qué se parece una RNA y el cerebro
- Cómo llegas de una RNA a un LLM y de allí a un chatbot como ChatGPT

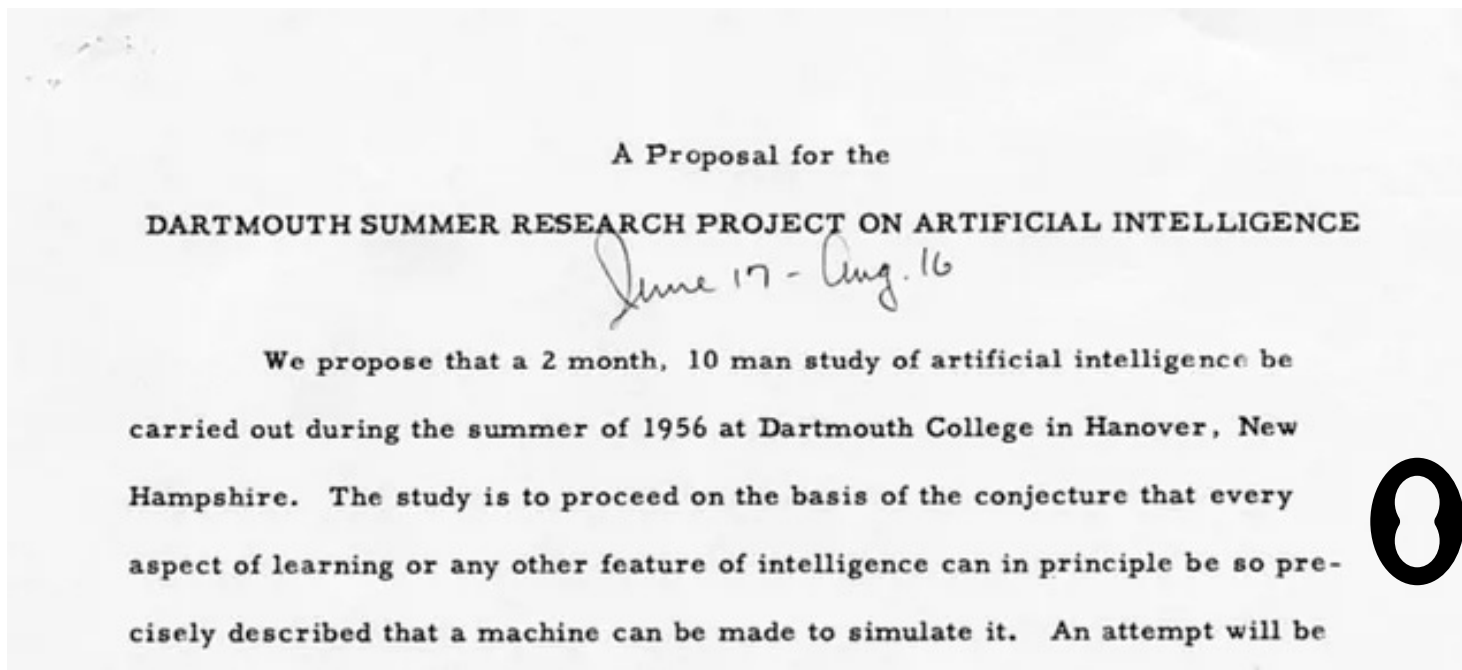
# Tipos de IA

¿Qué es lo nuevo de la IA generativa?

IA simbólica vs. IA subsimbólica

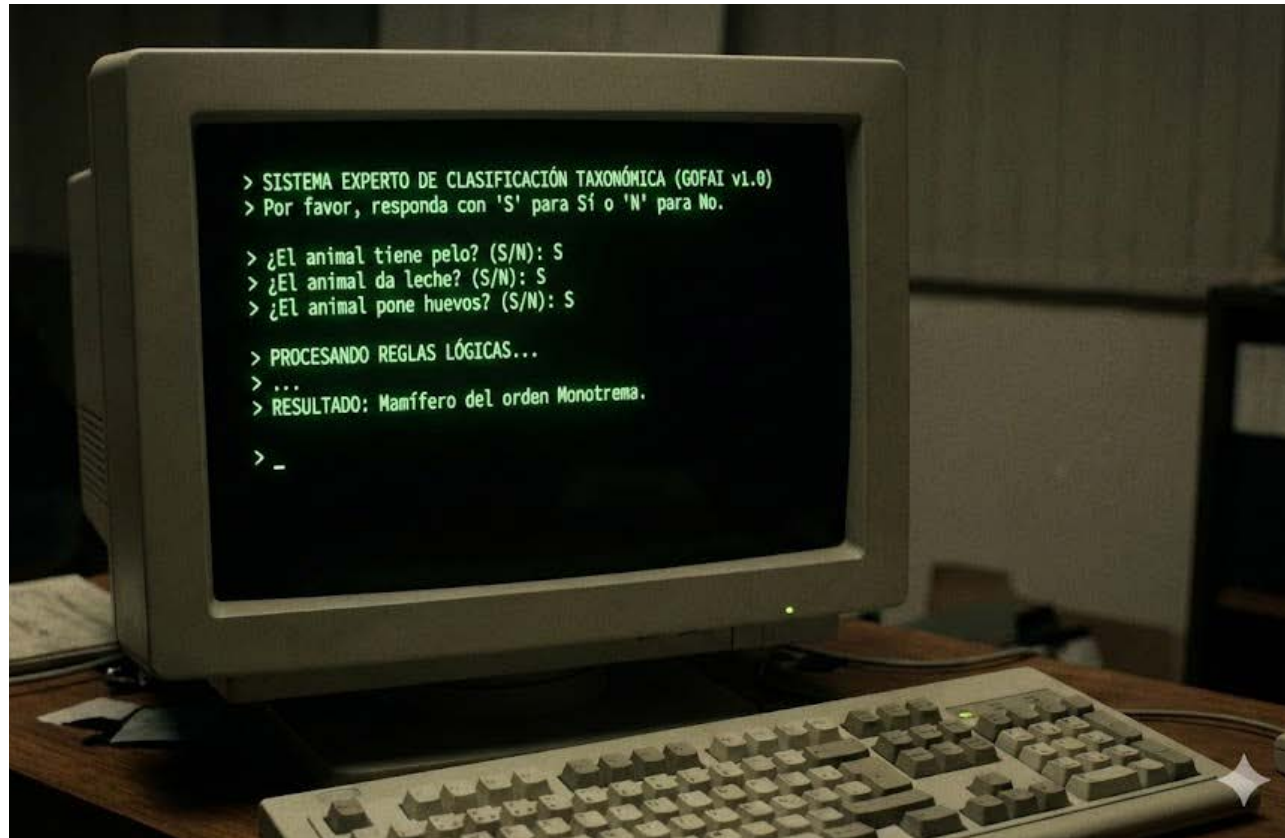
# Inicios de la IA basada en lógica: GOFAI / IA Simbólica

- Término Inteligencia Artificial lo acuña McCarthy para la reunión de 1956 Dartmouth



# Programa IA tradicional (GOFAI/simbólica)

Python



# Programa IA tradicional (GOFAI/simbólica)

```
# SISTEMA EXPERTO TAXONÓMICO (MODELO GOFAI)
def identificar_animal(tiene_pelo, da_leche, pone_huevos):
    # Regla 1: Identificación de Clase
    if tiene_pelo or da_leche:
        clase = "Mamífero"
        # Regla 2: Sub-clasificación lógica
        if pone_huevos:
            return f"RESULTADO: {clase} (Orden Monotrema)"
        else:
            return f"RESULTADO: {clase} (Placentario)"
    # Regla 3: Identificación de Sauropsida
    elif pone_huevos:
        return "RESULTADO: Sauropsida (Reptil o Ave)"
    # Salida por defecto (Fallo de reglas)
    else:
        return "RESULTADO: Datos insuficientes"

# Ejecución de prueba
print(identificar_animal(tiene_pelo=True, da_leche=True, pone_huevos=True))
```

# Programa de IA tipo GOFAL

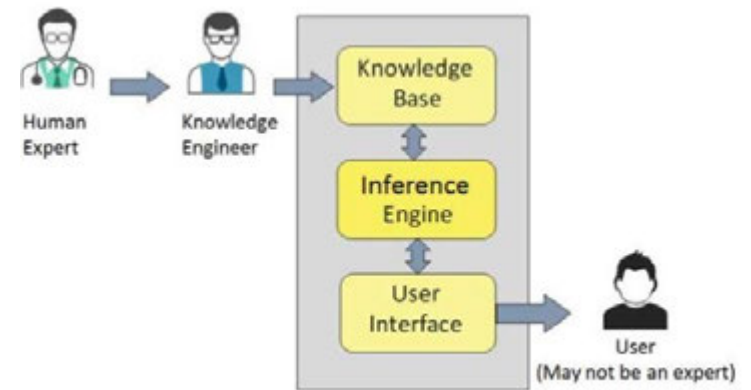

## Características

- Representación Simbólica Localista: Cada variable (tiene\_pelo, pone\_huevos) es un símbolo con un significado semántico unívoco.
- Lógica Top-Down (De arriba hacia abajo): El programador debe conocer las reglas de la taxonomía de antemano e introducirlas manualmente.
- Transparencia (Explicabilidad): Si el sistema falla, un humano puede leer el código y encontrar exactamente qué regla es incorrecta.
- Rigidez: Si introducimos un dato ambiguo (ej. "tiene algo de pelo"), el sistema arrojará un error o una clasificación falsa.

# Ejemplo: sistemas expertos

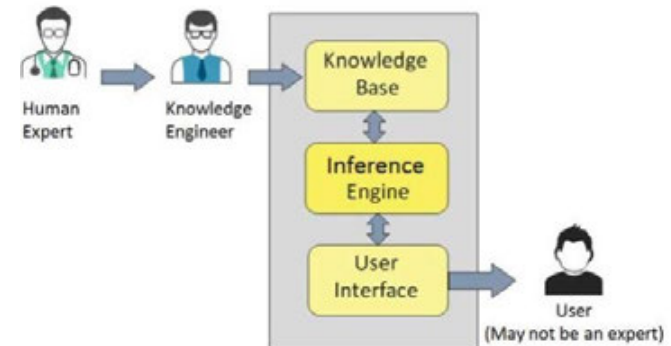
## MICYN 1970

- MYCIN es un **sistema experto** capaz de identificar las bacterias que causaban la infección en los pacientes y sugería los antibióticos y las dosis adecuadas para el peso de cada paciente.



# Reglas

- MYCIN fue creado a partir de una serie de reglas causa-efecto, su base de datos consta de alrededor de unas **500 reglas**
- “IF-THEN” structure
  - Si x entonces y:



A rule, and an English paraphrase generated by the system:

```
(defrule 52
  if (site culture is blood)
    (gram organism is neg)
    (morphology organism is rod)
    (burn patient is serious)
  then .4
  (identity organism is pseudomonas))
Rule 52:
If
  1) THE SITE OF THE CULTURE IS BLOOD
  2) THE GRAM OF THE ORGANISM IS NEG
  3) THE MORPHOLOGY OF THE ORGANISM IS ROD
  4) THE BURN OF THE PATIENT IS SERIOUS
Then there is weakly suggestive evidence (0.4) that
  1) THE IDENTITY OF THE ORGANISM IS PSEUDOMONAS
```

# Conclusión parcial

- La IA simbólica/tradicional/GOFAI/basada en lógica, pretende reproducir comportamiento inteligente **insertando reglas para manipular ciertos símbolos**, de manera que al introducir uno los símbolos la máquina puede seguir las reglas (algoritmo) y darnos una respuesta inteligente (p.e. clasificar)
  - Asume que sabemos o que podemos explicitar las reglas o algoritmos detrás del comportamiento inteligente/racional (RACIONALIDAD IDEAL)
  - Conocemos el funcionamiento de una IA basad en lógica en el sentido que nosotros le introdujimos las reglas que sigue, y determinamos con qué tipos de símbolos van a operar.


**Conexionismo**

# Otra manera de aproximar el problema

## Imitar el tejido


“The idea behind neural computing is that by modeling the major features of the brain and its operation, we can produce computers that exhibit many of the useful properties of the brain”

(Beale y Jackson 1990, 39)



# Conexionismo

Warren McCulloch y Walter Pitts (1943)





- En lugar de buscar una racionalidad ideal, busquemos imitar las estrategias de la naturaleza para producir comportamiento inteligente
  - REDES DE NEURONAS (SNC)
  - *A Logical Calculus of the Ideas Immanent in Nervous Activity* (McCulloch y Pitts 1943).
  - Perceptrón (Rosenblatt 1957) aprendizaje

# Neurona

## Neurona artificial

Pero, ¿cómo las neuronas apoyan el comportamiento inteligente/adaptativo?




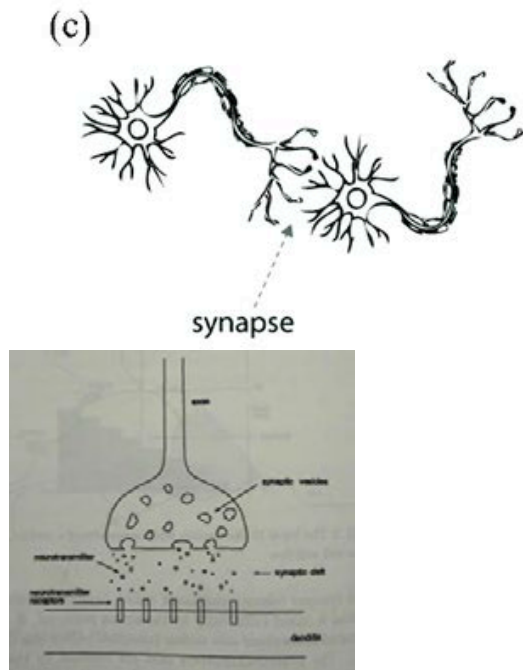
Capacidad de mandar y recibir señales

Adaptan la forma en la que mandan y reciben señales de acuerdo al entorno  
— APRENDEN!

# Conexión entre neuronales artificiales

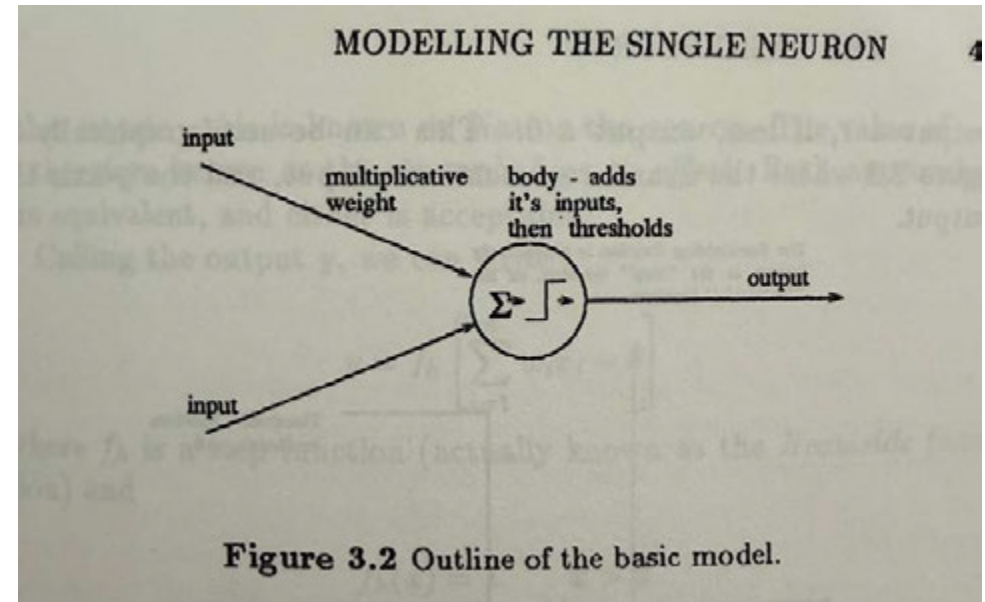
[https://www.google.com/search?q=synapsis+video+simulation&ogq=synapsis+video+simulation&gs\\_lcrp=EgZjaHJvbWUyBggAEEUYOTIHCAEQIRigAdlBCDcxODNqMGo0qAIAAsAIA&sourceid=chrome](https://www.google.com/search?q=synapsis+video+simulation&ogq=synapsis+video+simulation&gs_lcrp=EgZjaHJvbWUyBggAEEUYOTIHCAEQIRigAdlBCDcxODNqMGo0qAIAAsAIA&sourceid=chrome)

¡Sinapsis!



# Estado de 1 neurona

Una neurona no escucha con la misma intensidad a cada una de las neuronas de las que recibe señal.



$$\begin{aligned} \text{total input} &= \text{weight on line 1} \times \text{input on 1} + \\ &\quad \text{weight on line 2} \times \text{input on 2} + \dots + \\ &\quad \text{weight on line } n \times \text{input on } n \\ &= w_1x_1 + w_2x_2 + w_3x_3 + w_4x_4 + \dots + w_nx_n \\ &= \sum_{i=1}^n w_i x_i \end{aligned}$$

# Como calcular el estado de la neurona

## A partir de los estados y pesos de las neuronas de entrada

Calling the output  $y$ , we can write

$$y = f_h \left[ \sum_{i=1}^n w_i x_i - \theta \right]$$

where  $f_h$  is a step function (actually known as the *Heaviside function*) and



$$f_h(x) = 1 \quad x > 0$$

$$f_h(x) = 0 \quad x \leq 0$$

so that it does what we want. Note that the function produces only a 1 or a 0, so that the neuron is either on or off.


# Aprendizaje Hebbiano

“neurons that fire together, wire together” Hebb 1949






# Aprendizaje Hebbiano


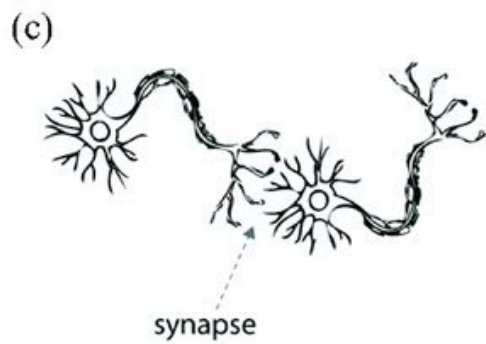


# Aprendizaje Hebbiano



# Aprendizaje Hebbiano





# Aprendizaje de 1 neurona

Que recibe señal de otras neuronas

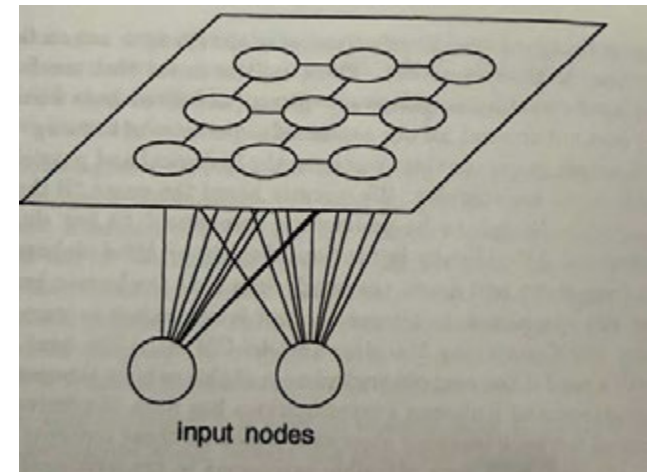


## 4. Adapt weights—modified version

	if correct	$w_i(t + 1) = w_i(t)$
	if output 0, should be 1 (class A)	$w_i(t + 1) = w_i(t) + \eta x_i(t)$
	if output 1, should be 0 (class B)	$w_i(t + 1) = w_i(t) - \eta x_i(t)$

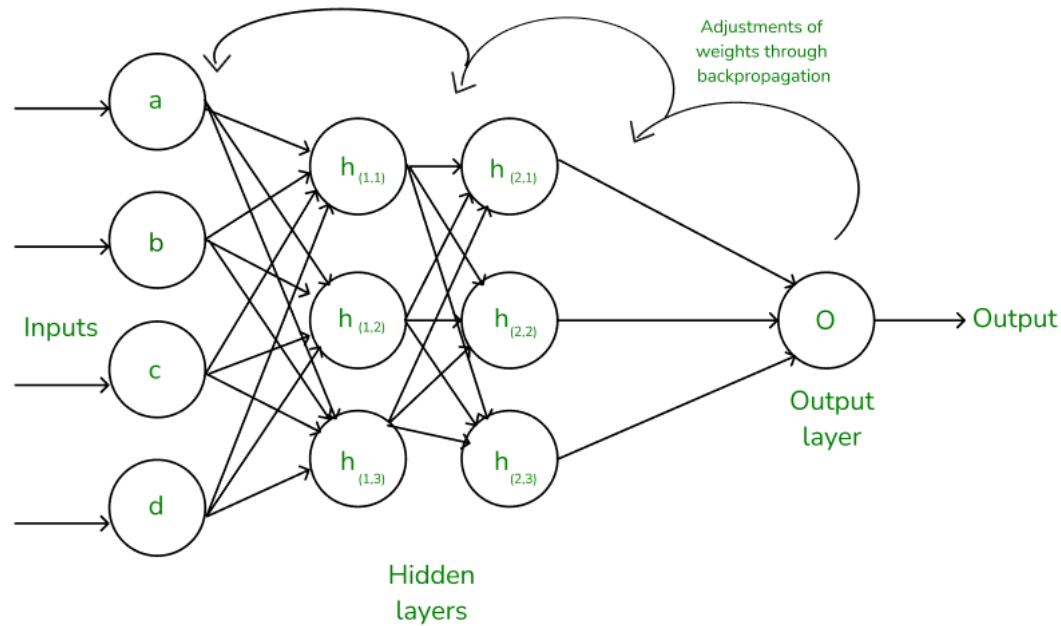
where  $0 \leq \eta \leq 1$ , a positive gain term that controls the adaption rate.

# Arquitectura de una RNA

## Perceptrón multicapa vs. red de Hopfield




# Otras reglas de aprendizaje, más complicado



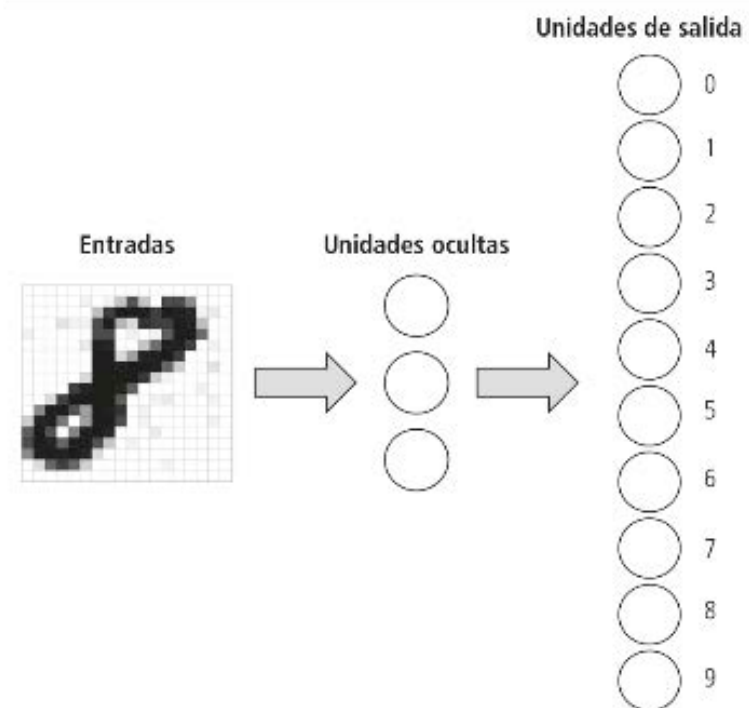
# Detector de números

## Capas ocultas - deep learning

- 324 inputs



- Sin capa oculta - 80% acierto
- Con capa oculta (50) - 95% acierto
  - 60,000 ejemplos
  - 10,000 nuevos números
  - 16,700 pesos!



# **Ejemplo: Red de Kohonen/Self Organizing Map**

**Visualización de un proceso de aprendizaje de máquina**

- <https://www.youtube.com/shorts/YbZHc0VNXrE>

# Programa IA basad en lógica vs. Conexionismo

## Características

- Representación Simbólica Localista: Cada variable (tiene\_pelo, pone\_huevos) es un símbolo con un significado semántico unívoco. **En el conexionismo, el conocimiento está distribuido y no hay un "lugar" único para el concepto "perro".**
- Lógica Top-Down (De arriba hacia abajo): El programador debe conocer las reglas de la taxonomía de antemano e introducirlas manualmente. **El sistema no "aprende" lo que es un mamífero; simplemente ejecuta una deducción lógica basada en premisas dadas.**
- Transparencia (Explicabilidad): Si el sistema falla, un humano puede leer el código y encontrar exactamente qué regla es incorrecta. **En el conexionismo (redes neuronales), el sistema funciona como una "caja negra" donde es casi imposible rastrear el "porqué" de una decisión específica.**
- Rigidez: Si introducimos un dato ambiguo (ej. "tiene algo de pelo"), el sistema arrojará un error o una clasificación falsa. **No posee la "degradación graciosa" del conexionismo, que puede manejar información imprecisa.**

# Modelos de lenguaje

# Modelos de lenguaje (sin RNAs)

En su concepción más fundamental un modelo de lenguaje busca calcular qué tan probable es que ocurra una determinada oración

siguiente elemento. Por ejemplo, usando una aproximación de orden 2, la probabilidad de una cadena con los símbolos  $w_1, w_2, \dots, w_n$  puede estimarse como:

↓  
palabras

$$\begin{aligned} p(w_1, \dots, w_n) &= p(w_1)p(w_2|w_1) \cdots p(w_n|w_{n-1}) \\ &= p(w_1) \prod_{t=2}^n p(w_t|w_{t-1}) \end{aligned}$$

La frase "Colorless green ideas" requerirá que estimemos las probabilidades  $p(\text{colorless})$ ,  $p(\text{green}|\text{colorless})$  y  $p(\text{ideas}|\text{green})$ , a partir de un gran corpus (colección de textos) de la lengua, para obtener la probabilidad total de la cadena. **A esto se le conoce como un modelo de lenguaje estadístico basado en n-gramas.**

Este tipo de probabilidades condicionales se estiman a partir de simples conteos en un corpus de entrenamiento

# LLMs

## RNA (transformer) que predice palabras

Binge ... on | - | and | of | is  
Binge **drinking** ... is | and | had | in | was  
Binge drinking **may** ... be | also | have | not | increase  
Binge drinking may **not** ... be | have | cause | always | help  
Binge drinking may not **necessarily** ... be | lead | cause | results | have  
Binge drinking may not necessarily **kill** ... you | the | a | people | your  
Binge drinking may not necessarily kill **or** ... even | injure | kill | cause | prevent  
Binge drinking may not necessarily kill or **even** ... kill | prevent | cause | reduce | injure  
Binge drinking may not necessarily kill or even **damage** ... your | the | a | you | someone  
Binge drinking may not necessarily kill or even damage **brain** ... cells | functions | tissue | neurons  
Binge drinking may not necessarily kill or even damage brain **cells,** ... some | it | the | is | long


buscamos estimar la probabilidad  $p(w|w_1, \dots, w_n)$  para generar, palabra por palabra, una secuencia que sea probable dada una entrada o contexto previo.



# Pasos para cocinar un LLM

## Pre-training

- Train the model to recite web pages
- Lots of compute meaning extremely expensive
- Lots of data



# Alineación/post-entrenamiento

## What is Post-Training

- Instead of repeating web pages, train model to behave certain ways



Pre-Training

Post-Training

Applications

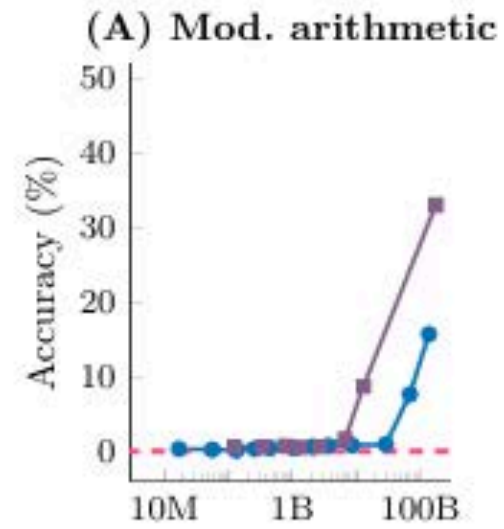
# Bigger, better, stronger

## Que transformó a una RNA multicapa en un LLM

- **Tamaño del modelo:** Se incrementa el número de parámetros en la red neuronal. Por ejemplo, pasar de GPT-2 a GPT-3 implicó un aumento de 100 veces en el tamaño del modelo, lo que resultó en mejoras significativas de rendimiento.
- **Tamaño del conjunto de datos:** Se incrementa el volumen y la calidad de los datos utilizados

# Habilidades emergentes

—●— LaMDA    —■— GPT-3    —◆— Gopher    —▲— Chinchilla    —◆— PaLM    - - - Random



Model scale (number of parameters)

Jason Wei, Yi Tay, Rishi Bommasani, Colin Raffel, Barret Zoph, Sebastian Borgeaud, Dani Yogatama, Maarten Bosma, Denny Zhou, Donald Metzler, et al. **Emergent abilities of large language models**. arXiv preprint arXiv:2206.07682, **2022**.

# ¿Cuál es el límite?

## El problema del “scaling”

BIG THINK BOOKS — JUNE 3, 2025


## Why AI today is more toddler than Terminator

In “Raising AI,” De Kai argues that today’s AIs are already more like us than we think they are.

---

### KEY TAKEAWAYS

● The outdated Hollywood stereotype of AIs as cold, logical, and emotionless blinds us to how far these machines have come. ● Instead of solving problems through rigid pre-programming, modern AI is an analog learner that adapts and evolves through experience. ● The true power of AI lies not in its hardware or code, but in how we train, nurture, and integrate it into our human society.



# Gary Marcus

## ¿Tienen solución los problemas de la IA basada en LLMs?

- Scaling has made GenAI much better at what it is good at, but not helped much with its core weaknesses around reliability, hallucinations, poor reasoning, poor planning, etc, or its challenges in the face of novelty

# Fin

## — referencias —

### De las ideas verdes incoloras hasta ChatGpt: los grandes modelos del lenguaje


**Víctor Germán Mijangos de la Cruz**

Universidad Nacional Autónoma de México, Facultad de Ciencias,  
Departamento de Matemáticas, Ciudad de México, México.  
ORCID: 0000-0002-8950-2634


**Ximena Gutierrez-Vasques**

Universidad Nacional Autónoma de México, Centro de Investigaciones  
Interdisciplinarias en Ciencias y Humanidades, Ciudad de México, México.  
ORCID: 0000-0002-1486-2774

Mijangos y Gutiérrez-Vázquez (2024)



Beale y Jackson (1990)



Mitchell (2019)