Universidad Industrial de Santander

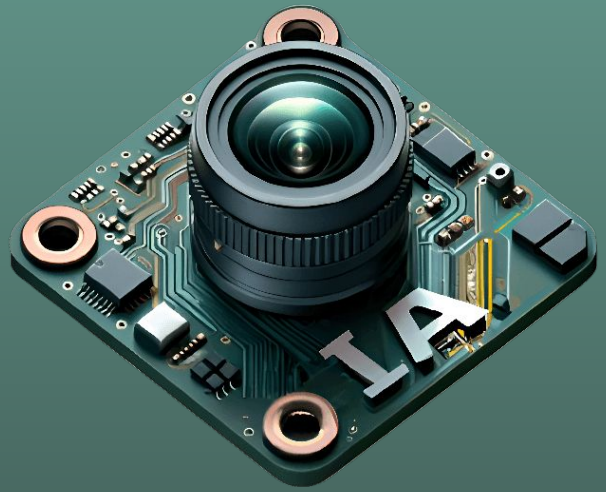

Semillero de Investigación
"Hands - on"
Computer Vision

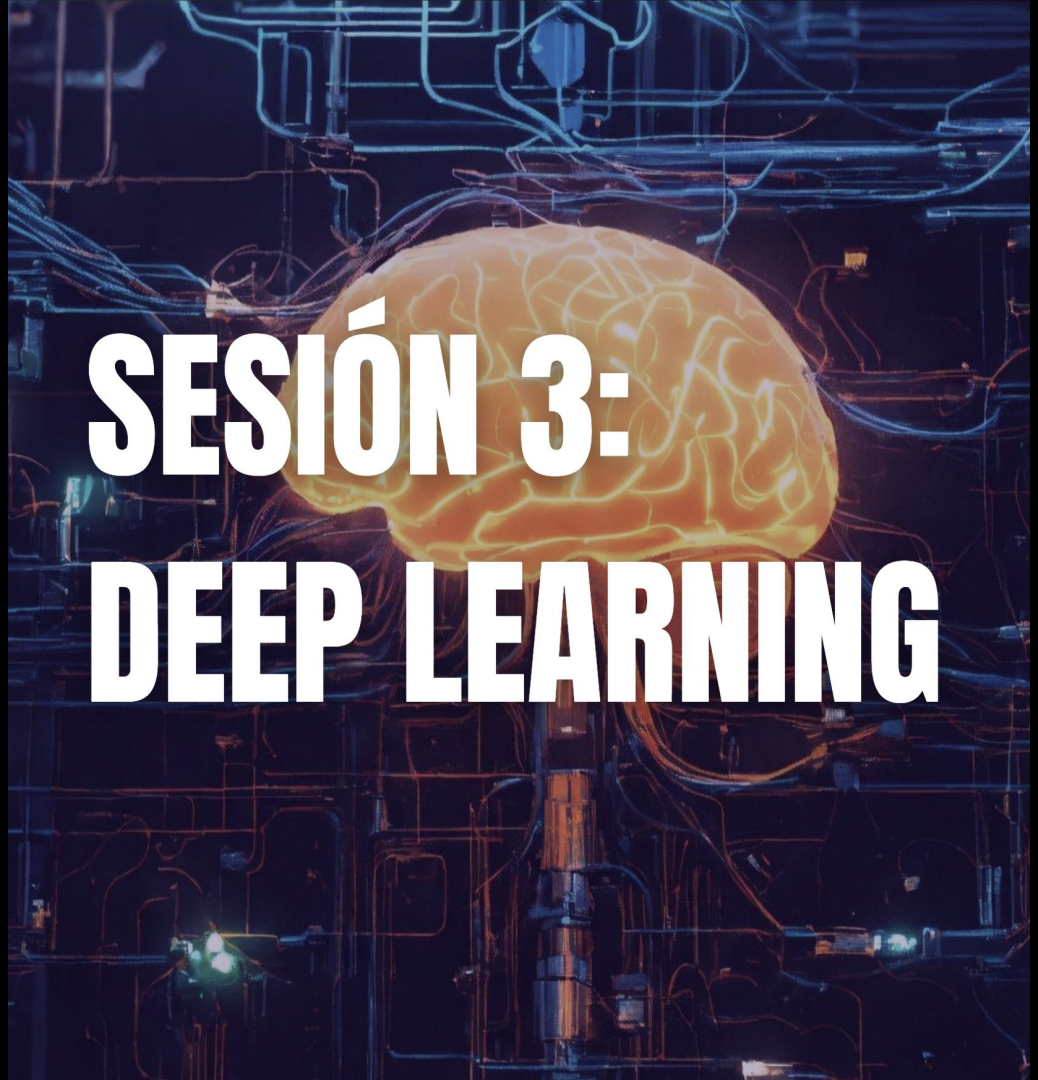
SESIÓN 3:
DEEP LEARNING

Contenidos

1. ¿Que es el Deep Learning?
2. Aplicaciones
3. Fundamentos
4. No-linealidad
5. Losses
6. Backprograpation, SGD
7. Interpretación de W
8. Redes neuronales convolucionales
9. Deep Learning: HOY

1. ¿Que es el Deep Learning?

Deep Learning

"El aprendizaje profundo permite a los **modelos computacionales**, que están compuestos por **múltiples capas de procesamiento**, aprender **representaciones de datos** con múltiples niveles de abstracción."

Deep Learning by Y. LeCun et al. Nature 2015

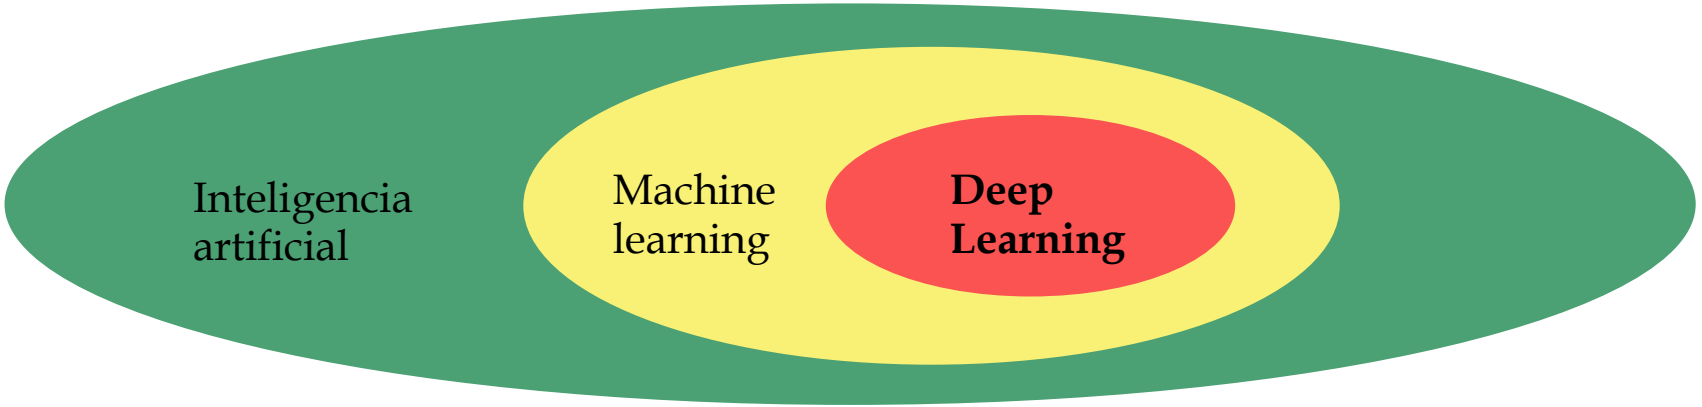

Antes del Deep Learning

Extractor de características diseñado manualmente

clasificador

gato (60%)

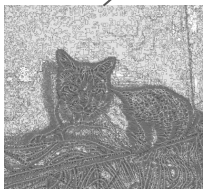

LBP

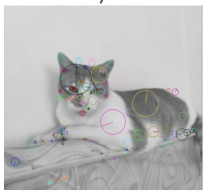

SIFT

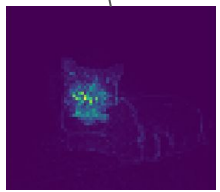

SSIM

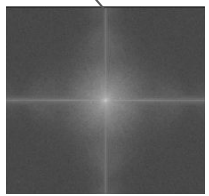

FOURIER

Con Deep Learning

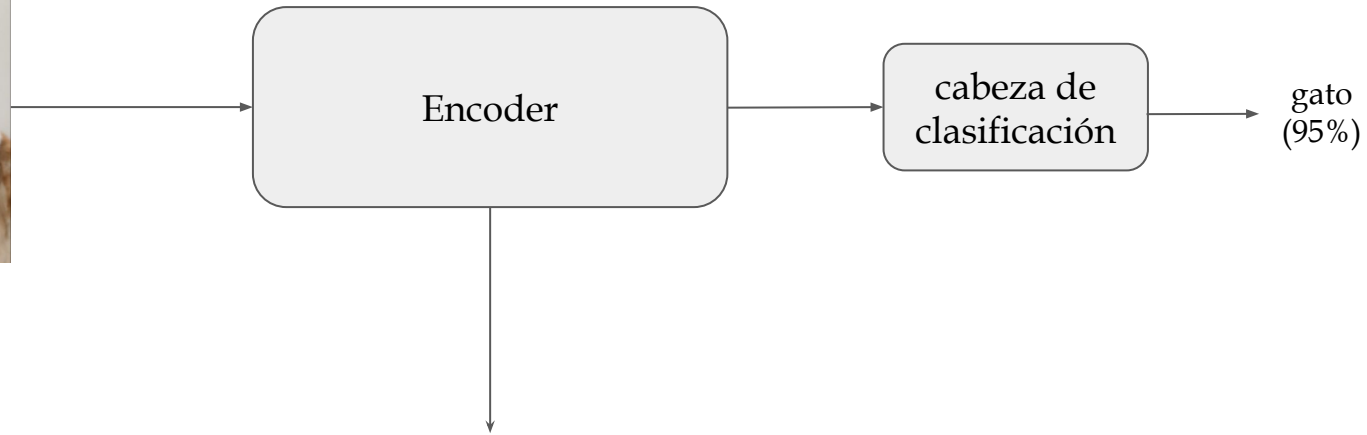

extrae representaciones subyacentes a partir de los datos

Deep Learning go brrr

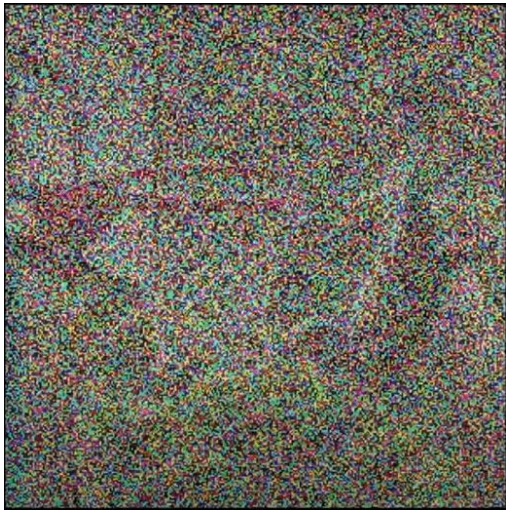

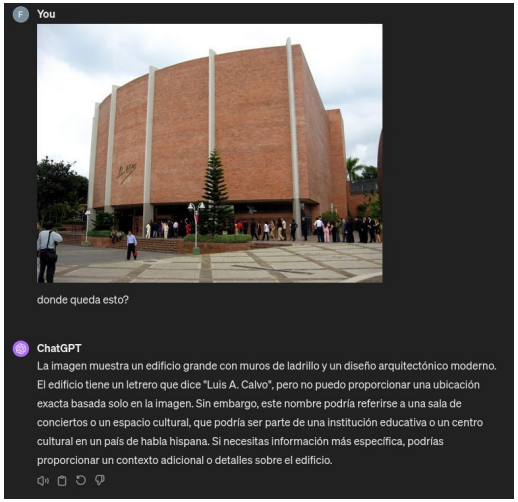

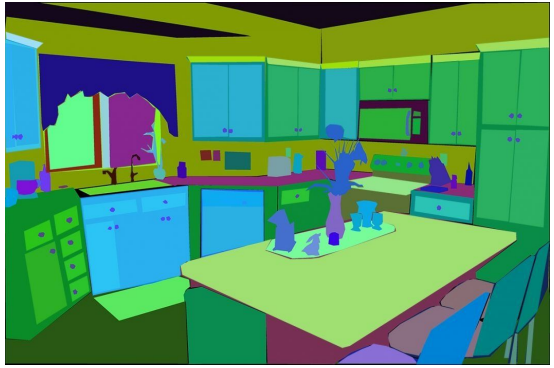

Deep Learning go brrr

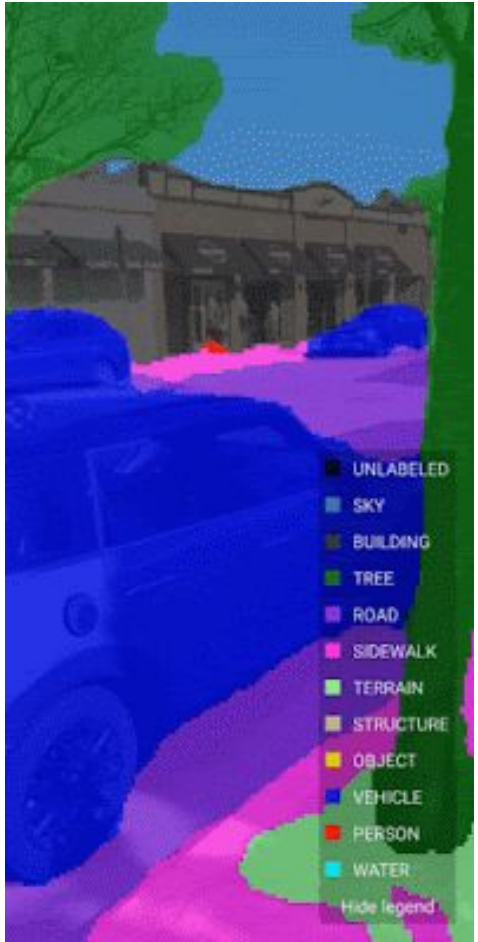

Deep Learning go brrr

Deep Learning go brrr

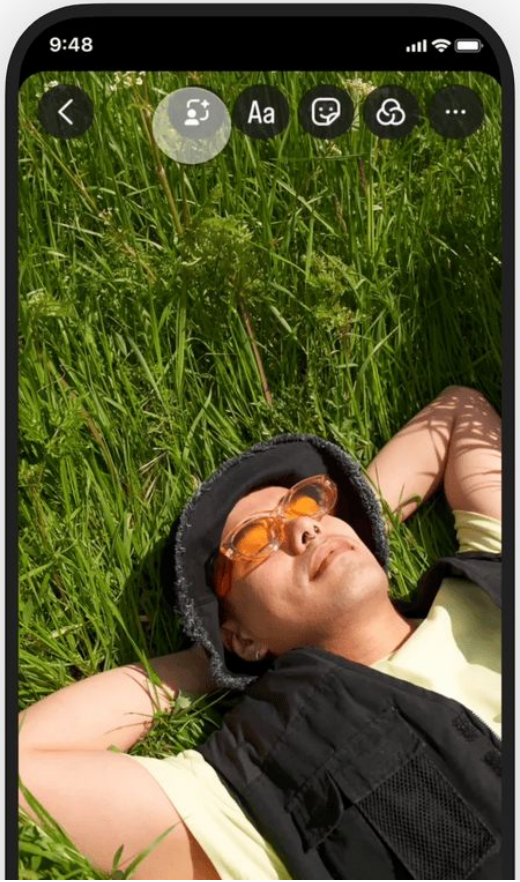

Deep Learning go brrr

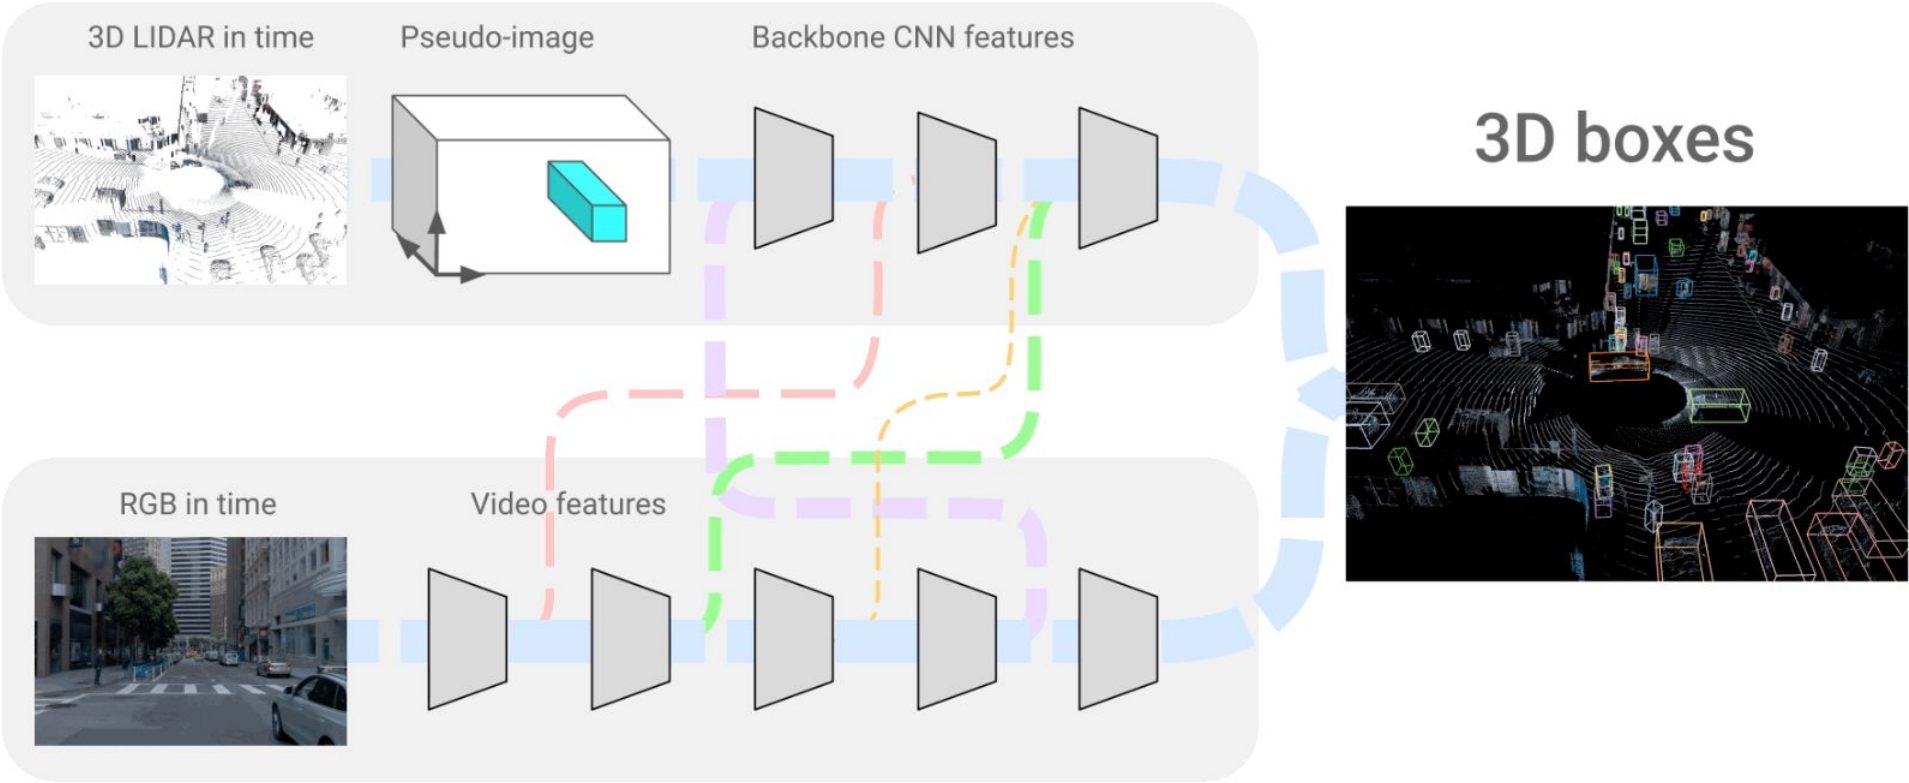

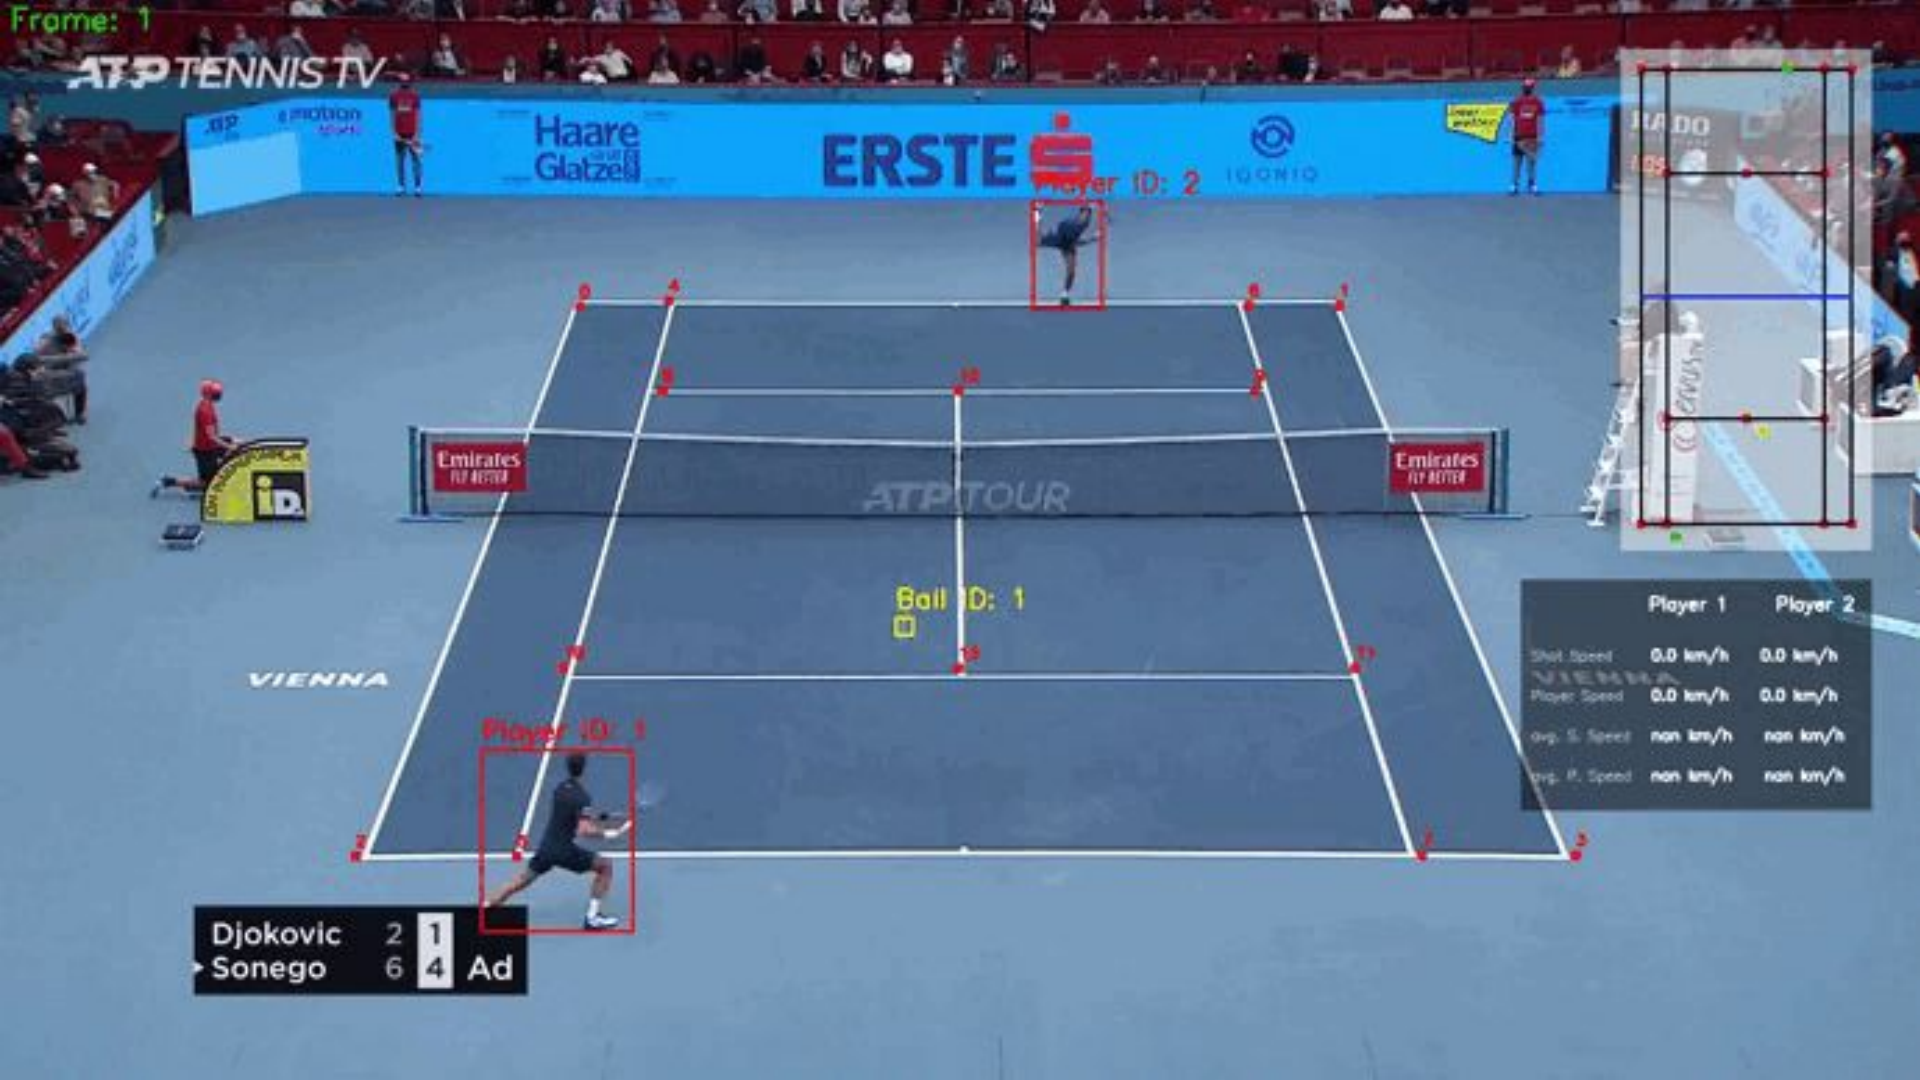
Frame: 1
ATP TENNIS TV
Haare Glatzel
ERSTE
Player ID: 2
Emirates
Emirates
ATPTOUR
VIENNA
Ball ID: 1
Player ID: 1
Player 1
Player 2
Shot Speed 0.0 km/h 0.0 km/h
Player Speed 0.0 km/h 0.0 km/h
avg. S. Speed nan km/h nan km/h
avg. P. Speed nan km/h nan km/h
Djokovic 2 1
Sonego 6 4 Ad

Protein folding prediction

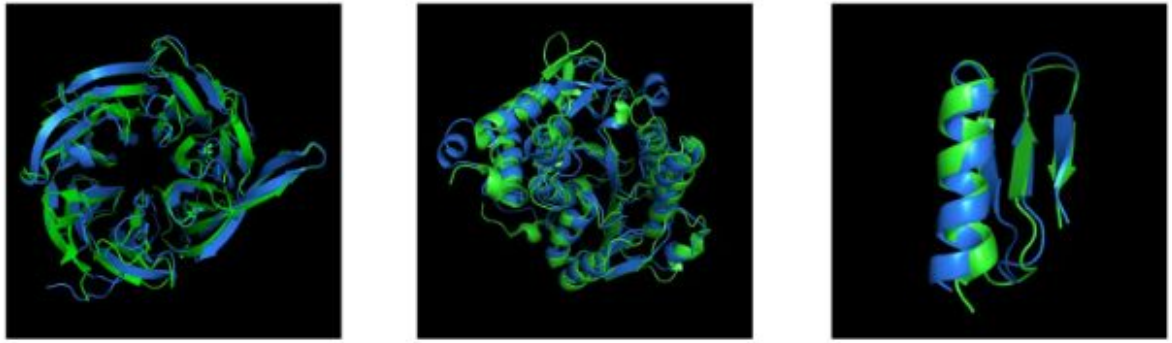

(Jumper et al., 2021)

Plasma confinement

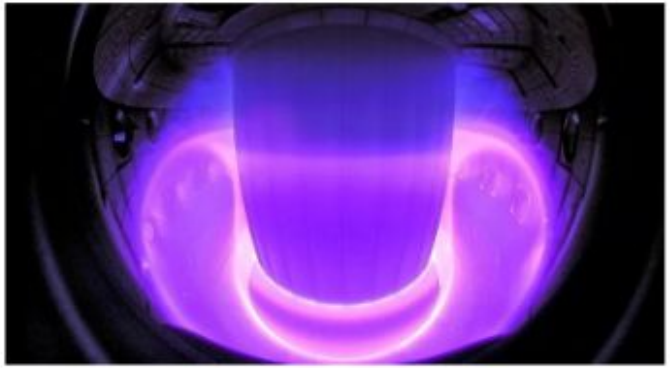

(Degrave et al., 2022)

segmentación en la web!

https://semillerocv.github.io/models/segment.html

2. ¿Cómo funciona?

El perceptrón

Imagen

tensor de $32 \times 32 \times 3$

(3072 números)

f(x,W)

W

parámetros de pesos

$$\begin{bmatrix} p_1 \\ p_2 \\ p_3 \\ \vdots \\ p_{10} \end{bmatrix}$$

10 números dando probabilidades de clase

El perceptrón

$$f(x,W) = W^T x$$

Imagen Vectorizada

tensor de 3072×1

(3072 números)

$f(x,W)$

W

parámetros de pesos

$$\begin{bmatrix} p_1 \\ p_2 \\ p_3 \\ \vdots \\ p_{10} \end{bmatrix}$$

10 números dando probabilidades de clase

El perceptrón

$$f(x,W) = W^T x$$

1x10 — 3072x10 — 3072x1

Imagen Vectorizada

tensor de 3072×1

(3072 números)

f(x,W)

W

parámetros de pesos

$$\begin{bmatrix} p_1 \\ p_2 \\ p_3 \\ \vdots \\ p_{10} \end{bmatrix}$$

10 números dando probabilidades de clase

El perceptrón

$$\hat{y} = \underset{1x10}{f(x,W)} = \underset{3072x10}{W^{T}}\overset{3072x1}{x} + \underset{1x10}{b}$$

Imagen Vectorizada

tensor de 3072×1

(3072 números)

f(x,W)

W

parámetros de pesos

$$\begin{bmatrix} p_1 \\ p_2 \\ p_3 \\ \vdots \\ p_{10} \end{bmatrix}$$

10 números dando probabilidades de clase

Funciones de activación

se pueden expresar como aplicar una función a la salida:

$$\hat{y} = f(\mathbf{x}, \mathbf{W}) = g(\mathbf{W}^{T}\mathbf{x} + \mathbf{b})$$

cualquier función puede ser aplicada, pero se espera que se aplique una **función no-lineal**

El perceptrón multicapa

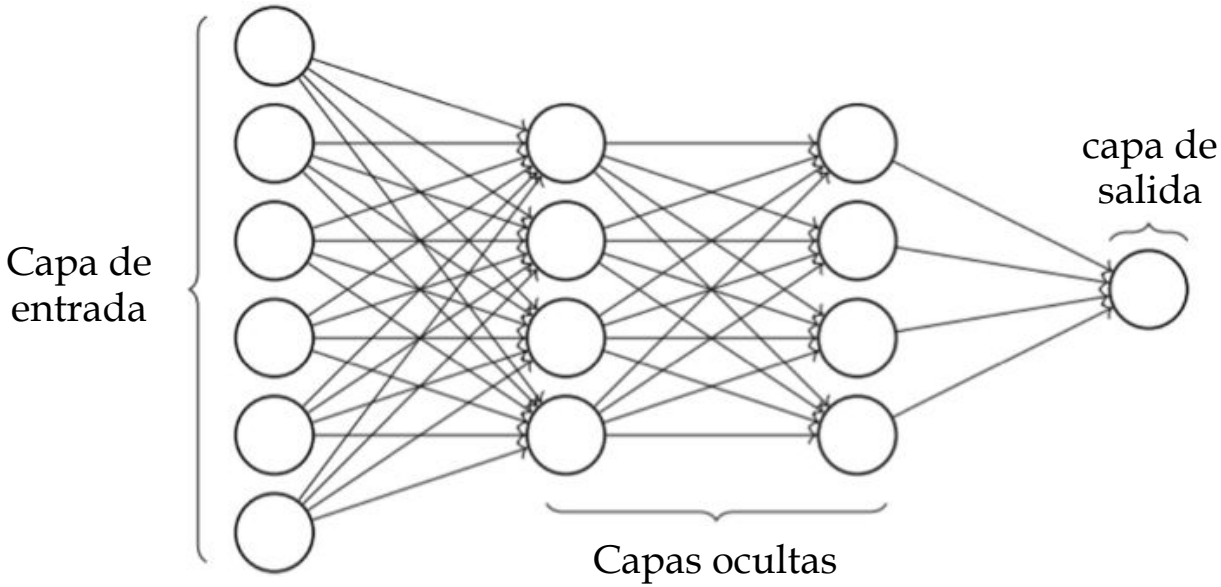

El perceptrón multicapa

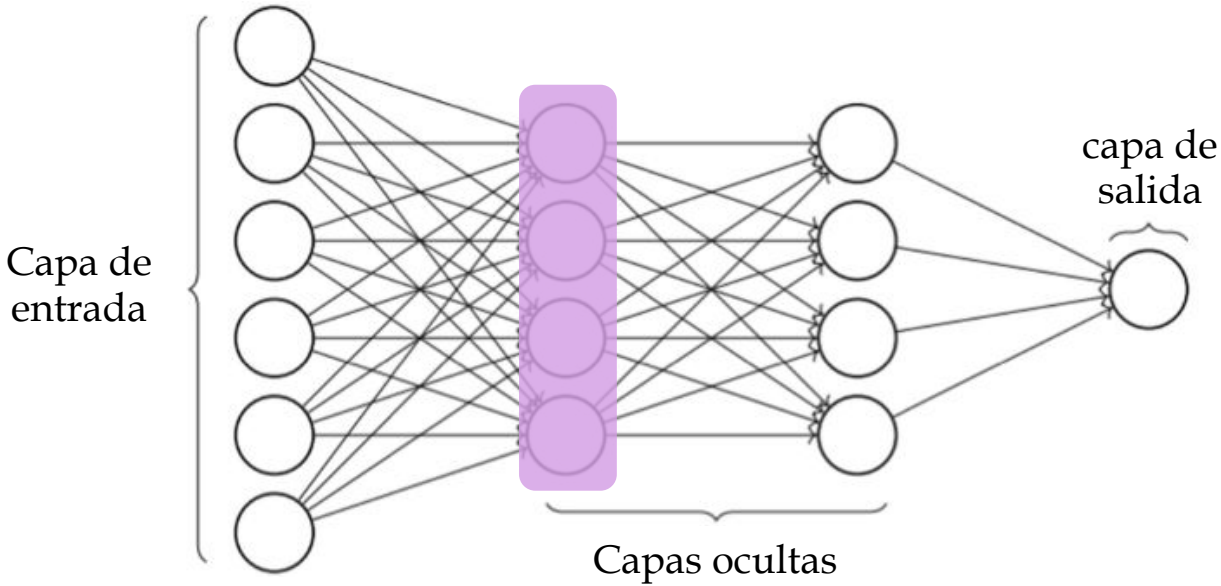

$$\hat{y} = g(W_3^\intercal \cdot g(W_2^\intercal \cdot g(W_1^\intercal \cdot X + b_1) + b_2) + b_3$$

El perceptrón multicapa

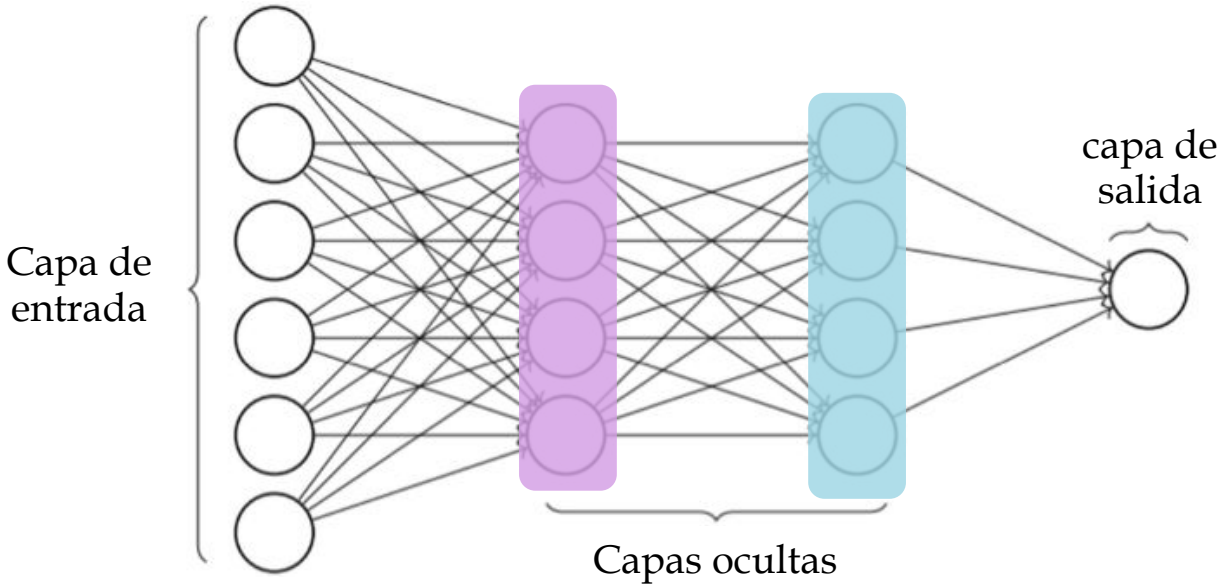

$$\hat{y} = g(W_3^\intercal \cdot g(W_2^\intercal \cdot g(W_1^\intercal \cdot X + b_1) + b_2) + b_3$$

El perceptrón multicapa

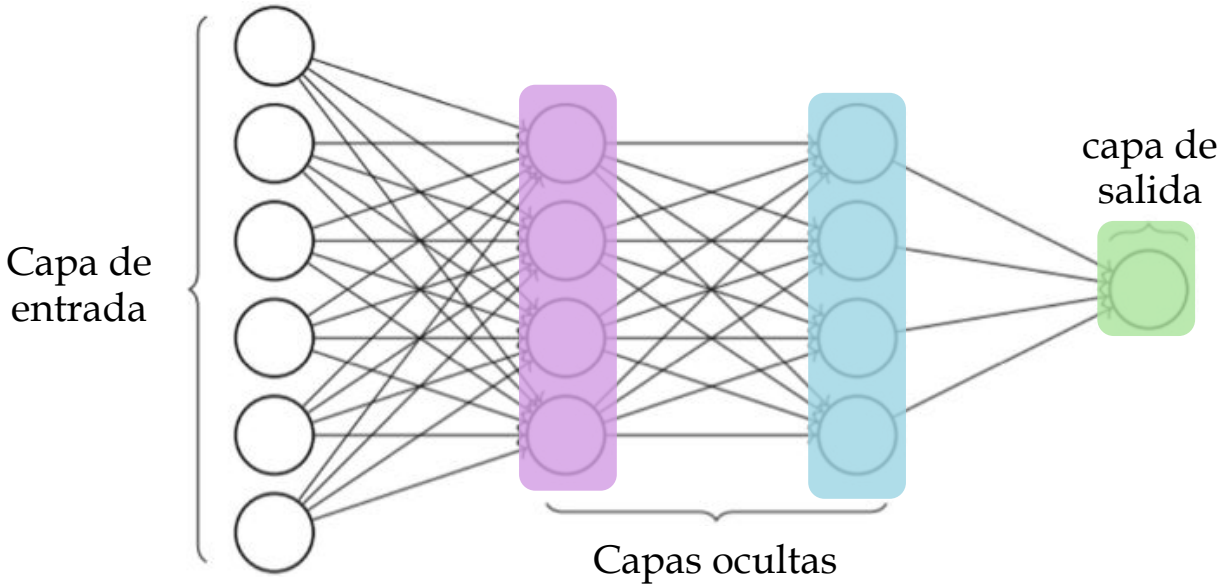

$$\hat{y} = g(W_3^\intercal \cdot g(W_2^\intercal \cdot g(W_1^\intercal \cdot X + b_1) + b_2) + b_3$$

La necesidad de la no-linealidad

La no linealidad permite modelar la compleja estructura de los datos, capturando patrones que van más allá de las simples relaciones lineales.

$$\hat{y} = g(W_3^\intercal \cdot g(W_2^\intercal \cdot g(W_1^\intercal \cdot X + b_1) + b_2) + b_3$$

si **g( )** es una función lineal es decir **g(x)=x**

$$\begin{aligned}
\hat{y} &= W_3^\intercal \cdot (W_2^\intercal \cdot (W_1^\intercal \cdot X + b_1) + b_2) + b_3 \\
&= W_3^\intercal \cdot (W_2^\intercal \cdot W_1^\intercal \cdot X + W_2^\intercal \cdot b_1 + b_2) + b_3 \\
&= (W_3^\intercal \cdot W_2^\intercal \cdot W_1^\intercal) \cdot X + (W_3^\intercal \cdot W_2^\intercal \cdot b_1 + W_3^\intercal \cdot b_2 + b_3) \\
&= W' \cdot X + b'
\end{aligned}$$

La necesidad de la no-linealidad

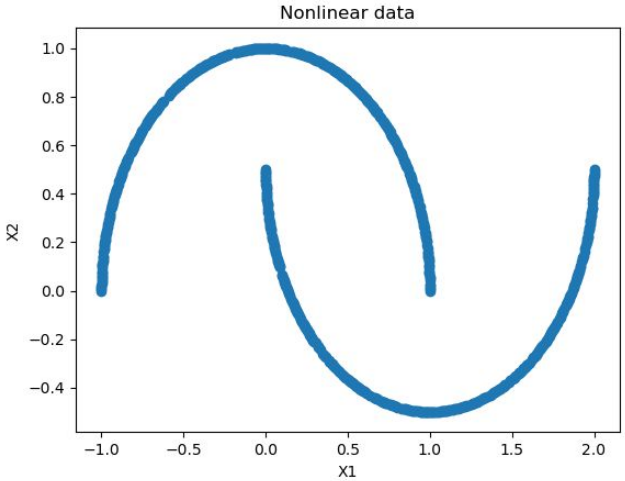

casi todos los problemas del mundo real son no-lineales

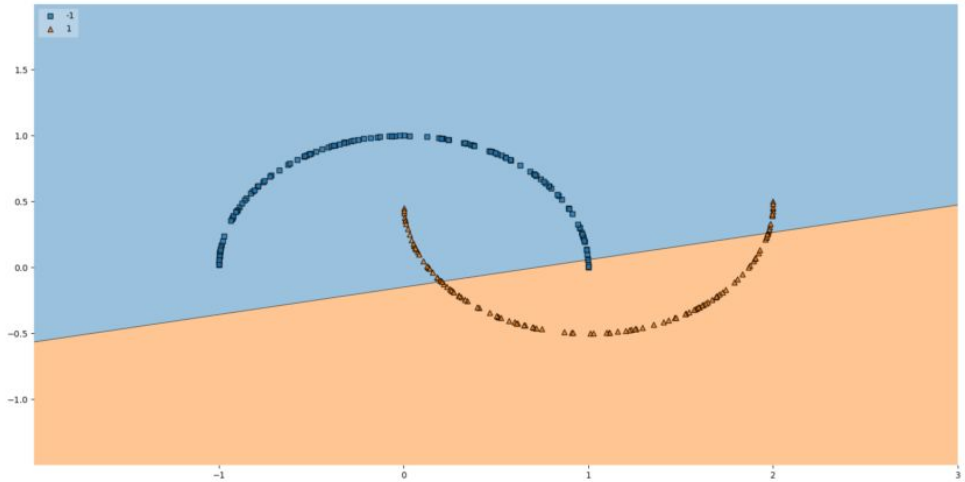

si usamos una función de activación lineal no podemos resolver el problema

La necesidad de la no-linealidad

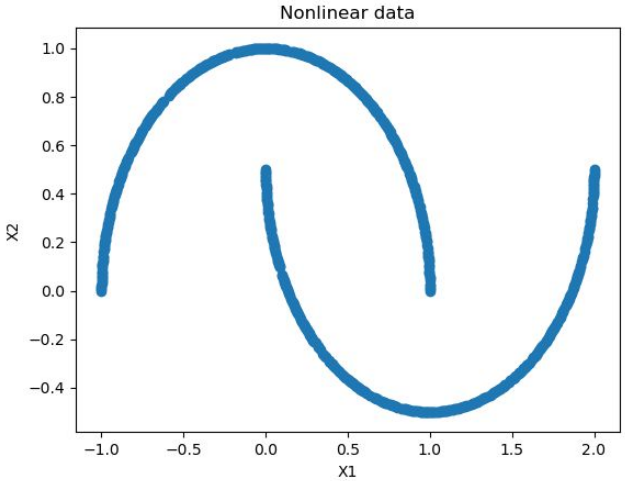

casi todos los problemas del mundo real son no-lineales

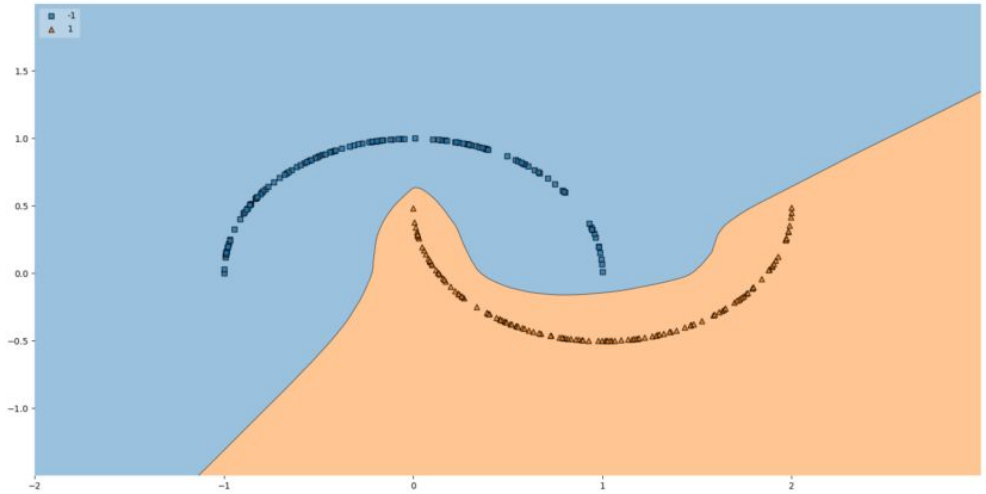

pero si introducimos una sigmoide, es bastante fácil de resolver

La necesidad de la no-linealidad

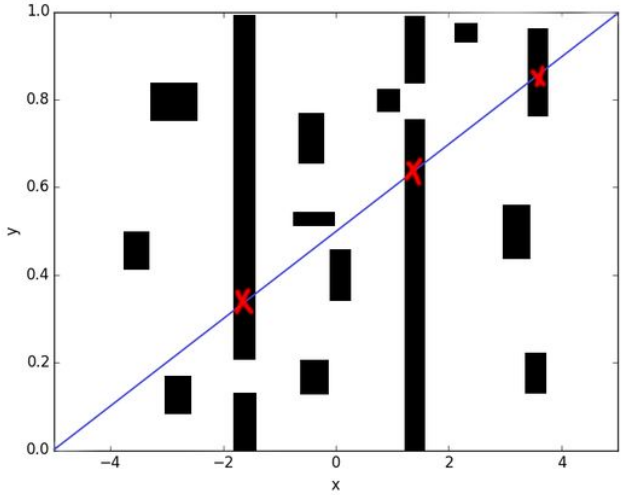

Sin una función de activación, tu red actuará más como un tubo de acero: fijo e inflexible.

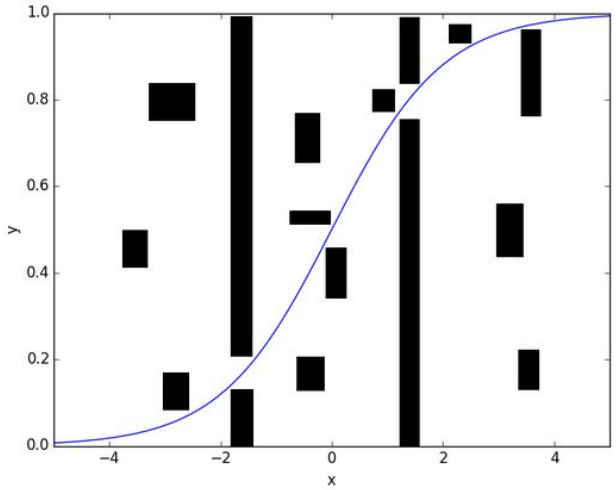

La función de activación otorga flexibilidada la red, permitiéndole adaptarse a diferentes problemas

Funciones de activación comunes

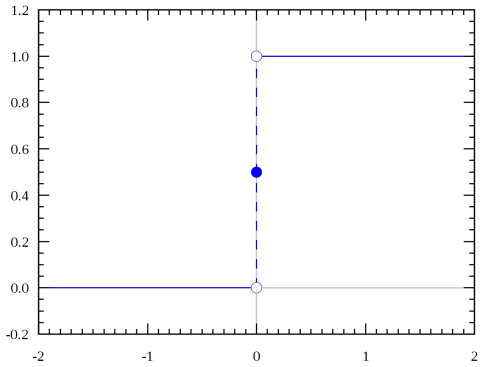

$$g(x) = \begin{cases} 0 & \text{if } x > 0 \\ 1 & \text{if } x \leq 0 \end{cases}$$

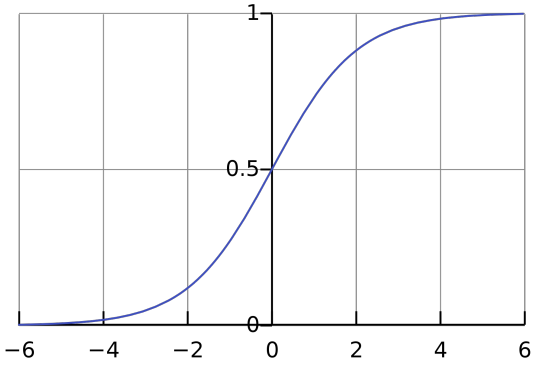

$$g(x) = \frac{1}{1 + e^{-x}}$$

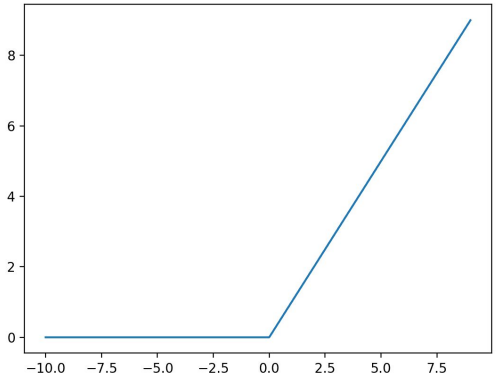

$$g(x) = \max(0, x)$$

¿Cómo escoger la función de activación?

la función de activación define el comportamiento de las características aprendidas por la red

modelo entrenado con RELU

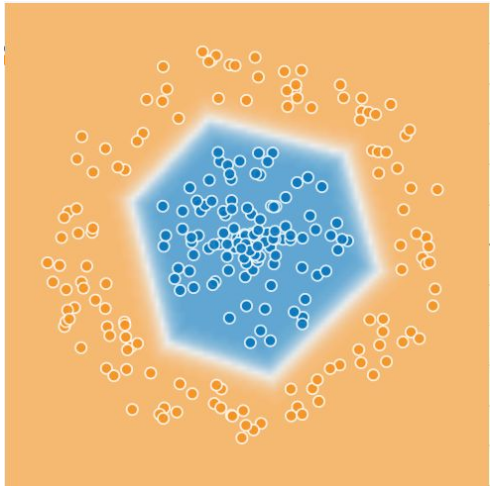

resulta en una composición de rectas

modelo entrenado con SIGMOID

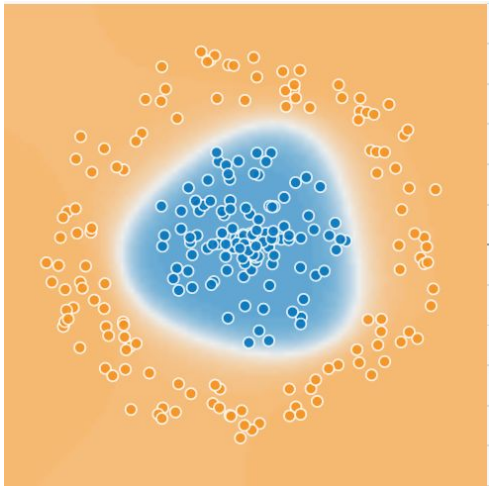

resulta en una composición de curvas

demo tensorflow

https://playground.tensorflow.org/

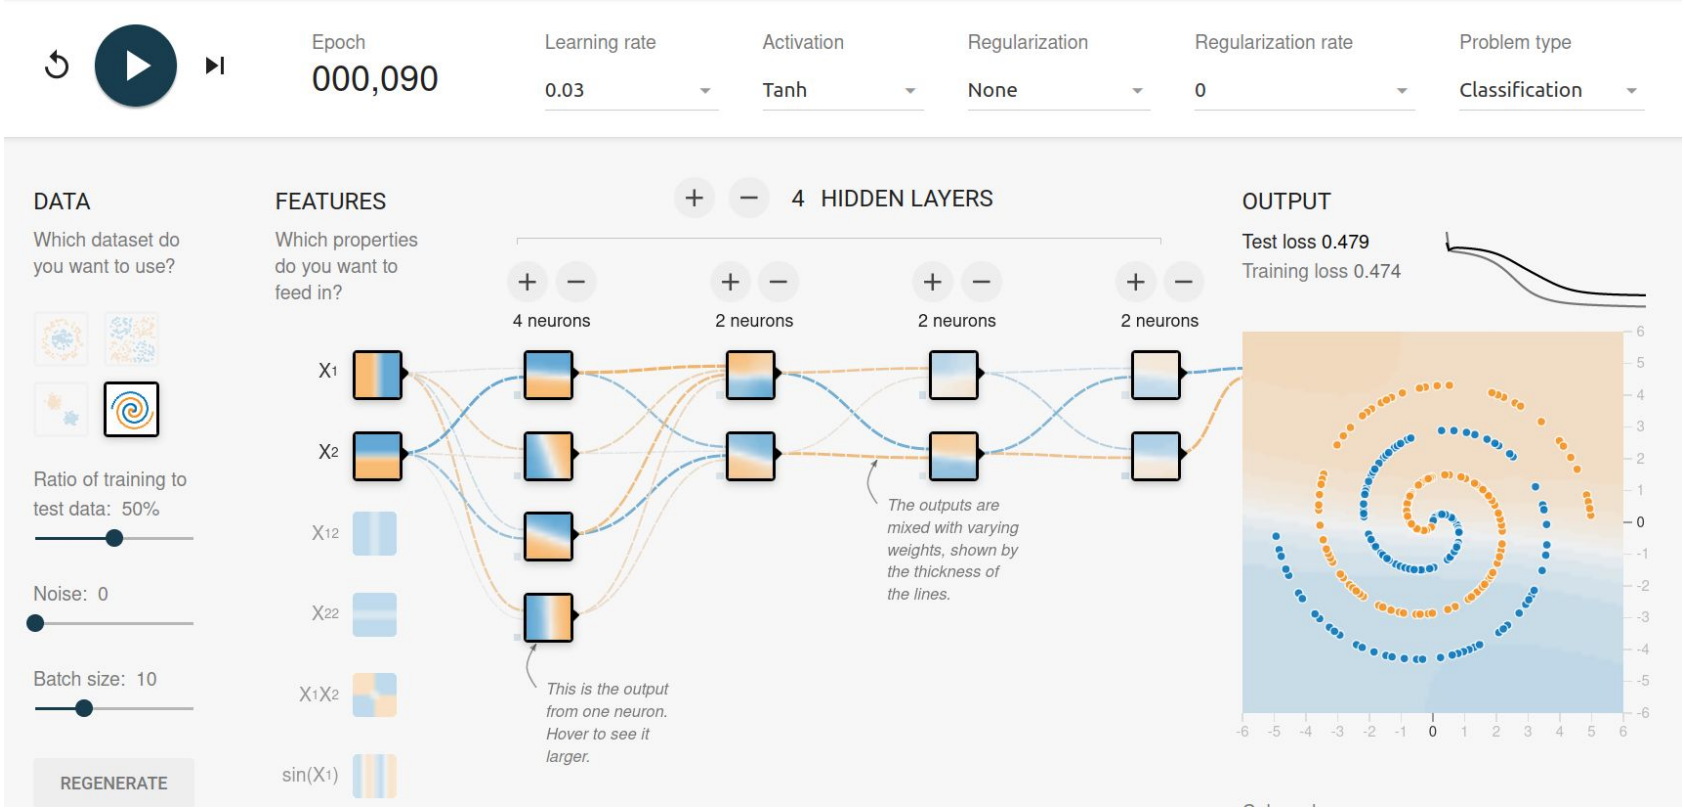

¿Cómo escoger la función de activación?

la función de activación define el comportamiento de las características aprendidas por la red

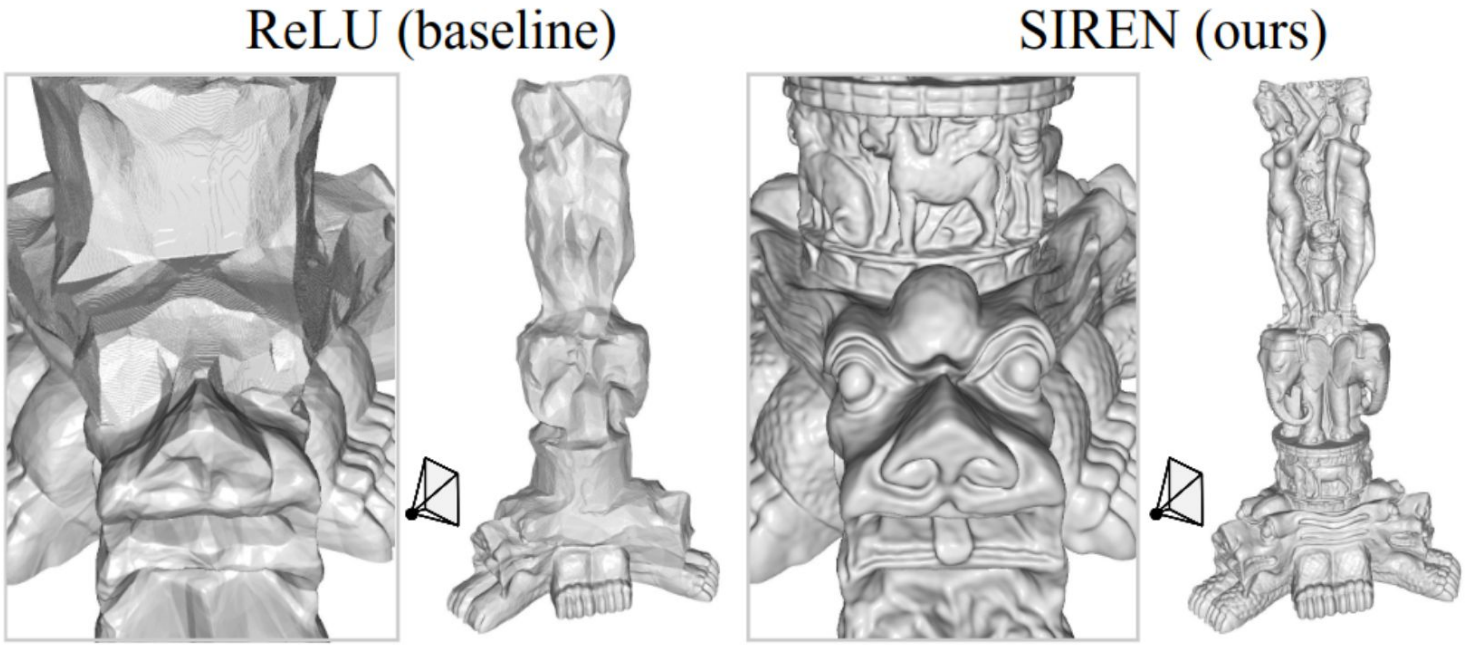

¿Cómo escoger la función de activación?

habitualmente en la capas ocultas se usa la RELU y en la capa de salida, en la que se define la tarea se usa función de activación específica

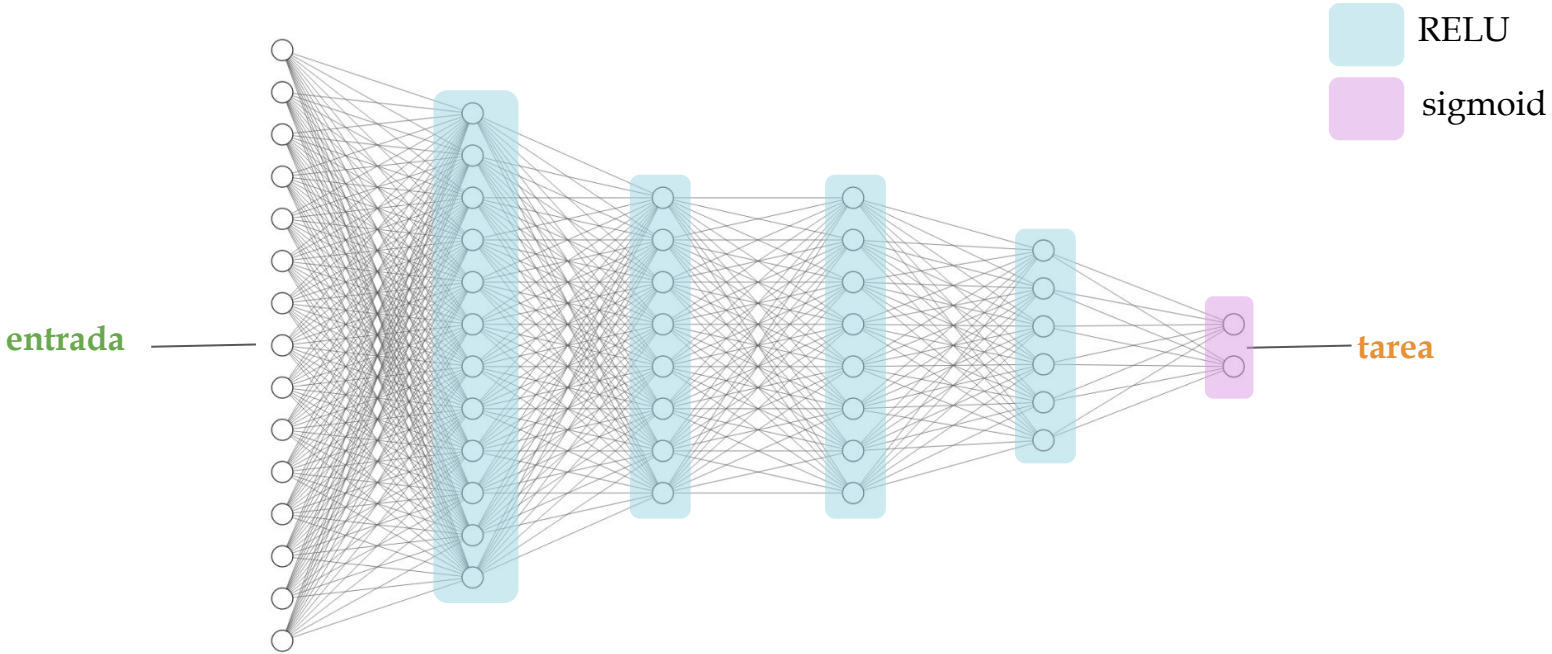

Función de costo

para escoger los pesos W debemos medir el error de nuestra red

Imagen Vectorizada

tensor de 3072×1

(3072 números)

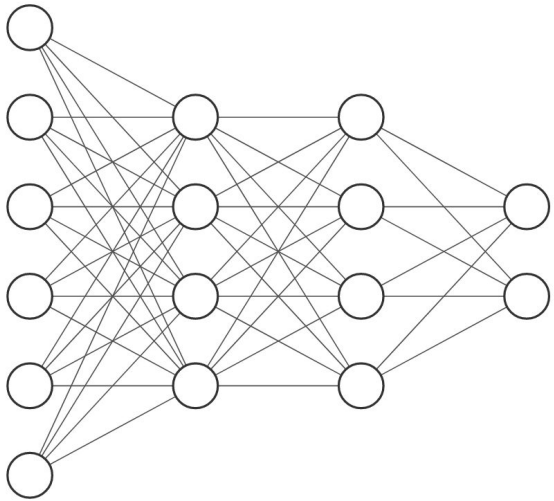

perro 0.6

gato 0.4

Función de costo

para escoger los pesos W debemos medir el error de nuestra red

Imagen Vectorizada

tensor de 3072×1

(3072 números)

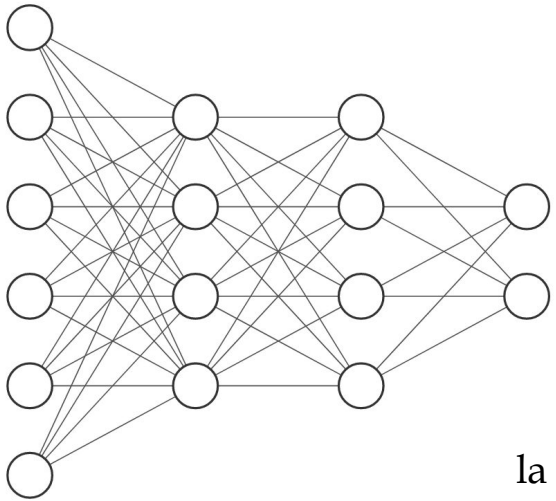

perro 0.6

gato 0.4

la salida de la red debe ser:

perro 0

gato 1

Función de costo

para escoger los pesos W debemos medir el error de nuestra red

$$\mathcal{L} = \frac{1}{N} \sum_i L_i(f(x_i, W), y_i)$$

Función de costo

para escoger los pesos W debemos medir el error de nuestra red

$$\mathcal{L} = \frac{1}{N} \sum_i L_i(f(x_i, W), y_i)$$

la función de costo debe ser derivable

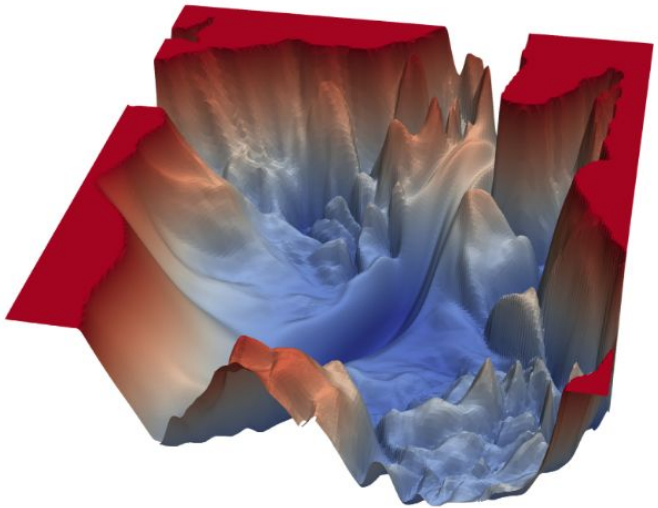

función de costo de una VGG16

Función de costo

Función de costo comunes

Binary Cross Entropy

$$-\frac{1}{N}\sum_{i=1}^{N} y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)$$

Is used in binary **classifcation**

Mean Squeared Error

$$\frac{1}{n}\sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$

Is used in **regression**

Backpropagation

Queremos encontrar los pesos de la red que logren el mejor rendimiento y la menor pérdida.

$$W^* = \underset{W}{\operatorname{argmin}}\, L(W)$$

optimizamos W para encontrar los pesos óptimos

Backpropagation

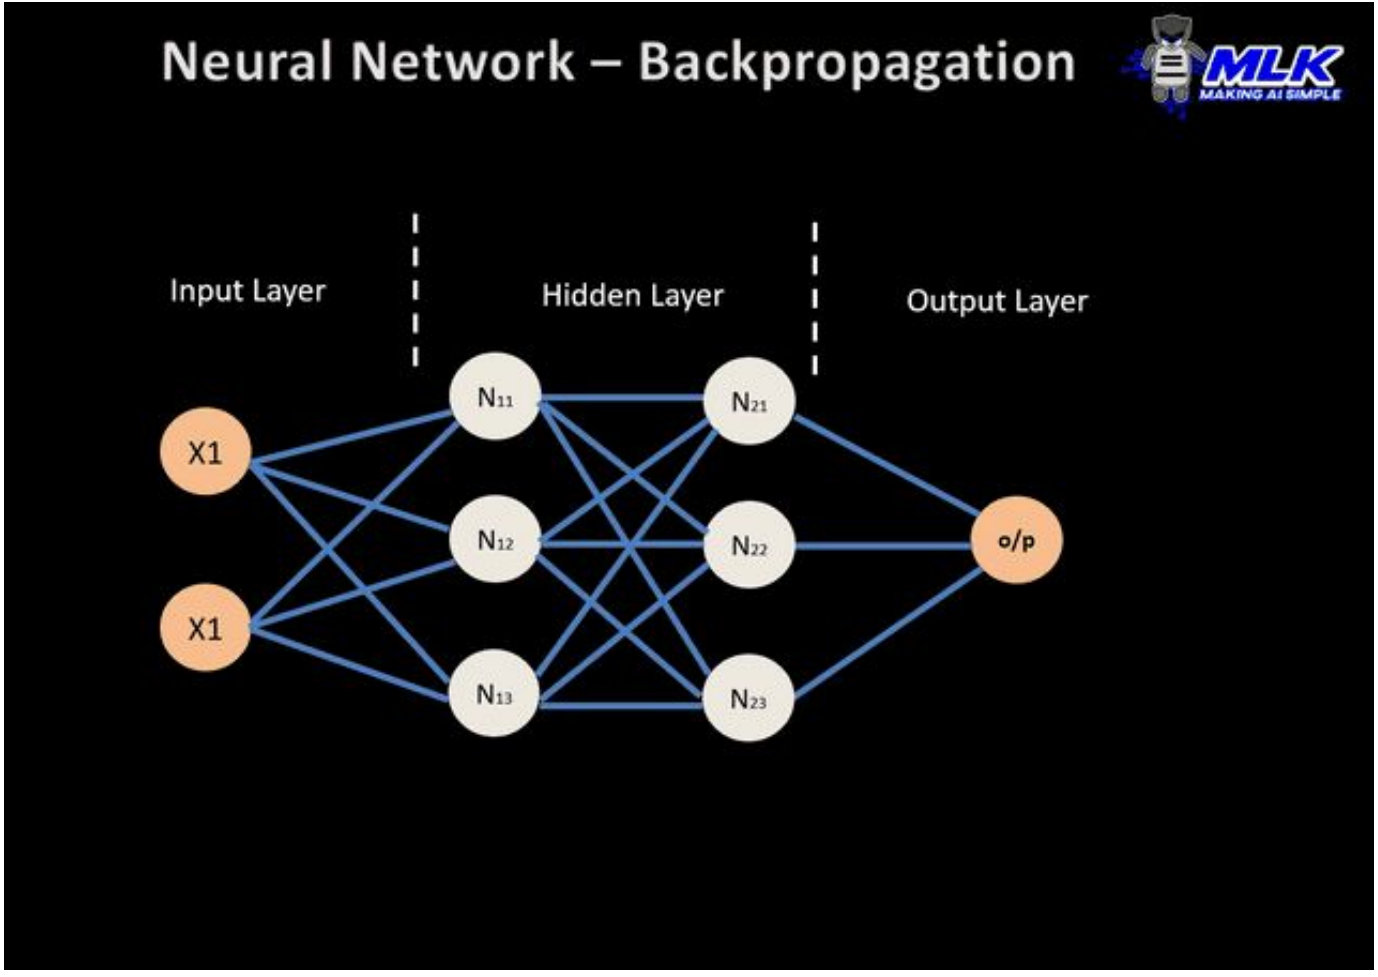

Optimizadores: SGD

Queremos encontrar los pesos de la red que logren el mejor rendimiento y la menor pérdida.

$$W^* = \underset{W}{\operatorname{argmin}}\, L(W)$$

optimizamos W para encontrar los pesos óptimos

Optimizadores: SGD

se empieza con pesos aleatorios W

en cada iteración calculamos la derivada

$$\nabla_W = \frac{\partial \mathcal{L}(W)}{\partial W}$$

este es el gradiente!

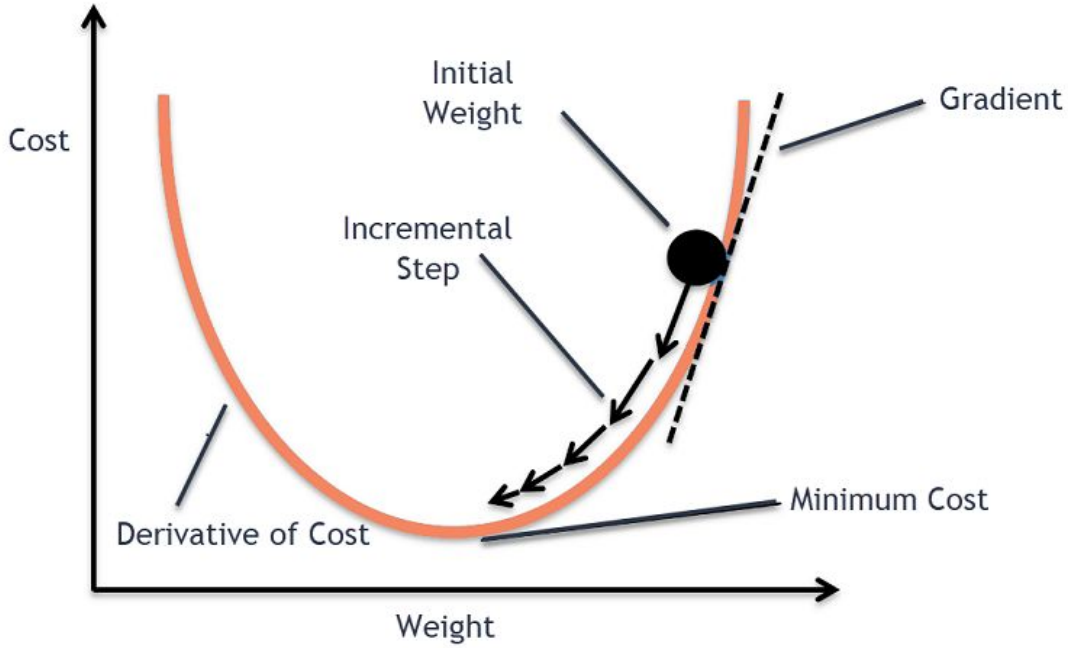

el gradiente se calcula con la regla de la cadena

Optimizadores: SGD

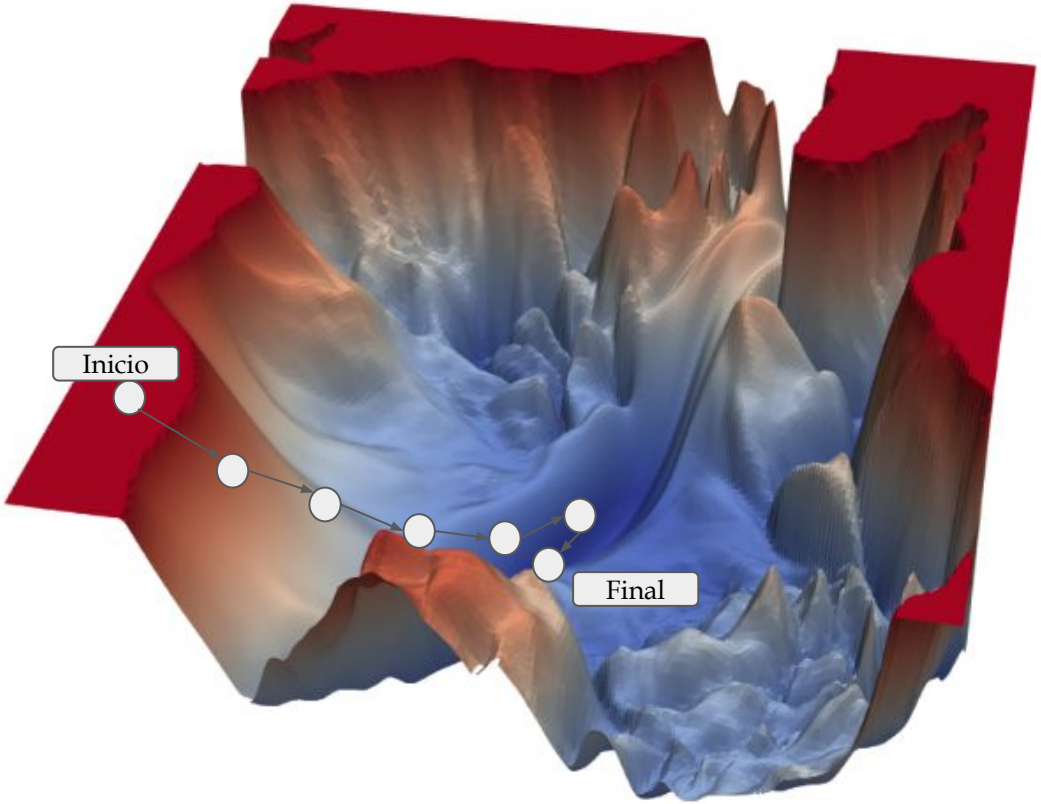

función de costo de una VGG16

overfitting, underfitting

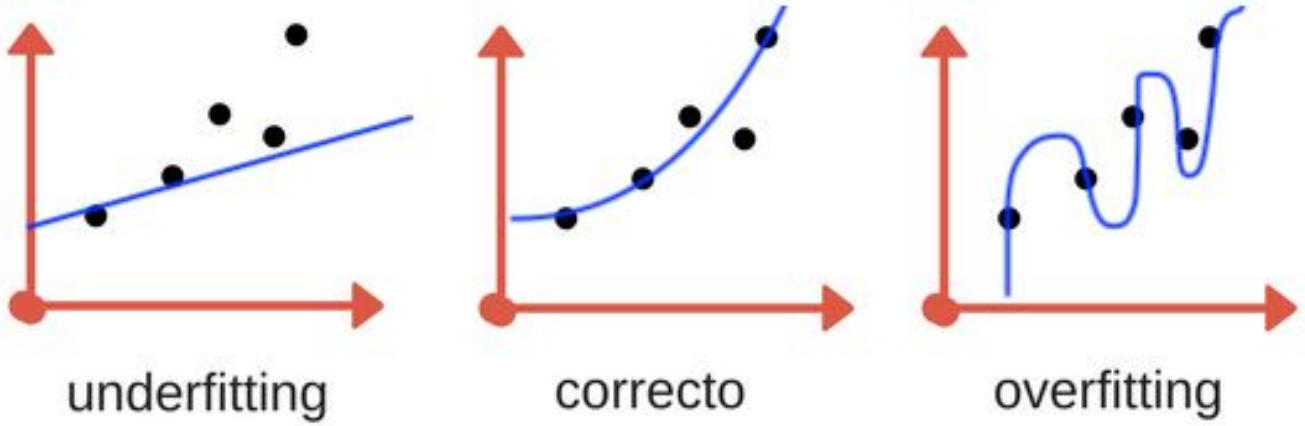

una interpretación de W*

W tiene codificada información subyacente que es extraída a partir de los datos

OpenAI

Unsupervised sentiment neuron

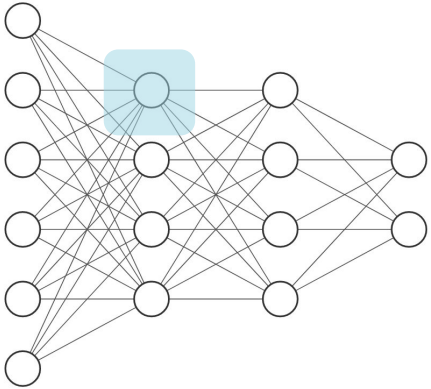

relative contributions of features on various datasets, we discovered a single unit within the mLSTM *that directly corresponds to sentiment*. In Figure 3 we show the his-

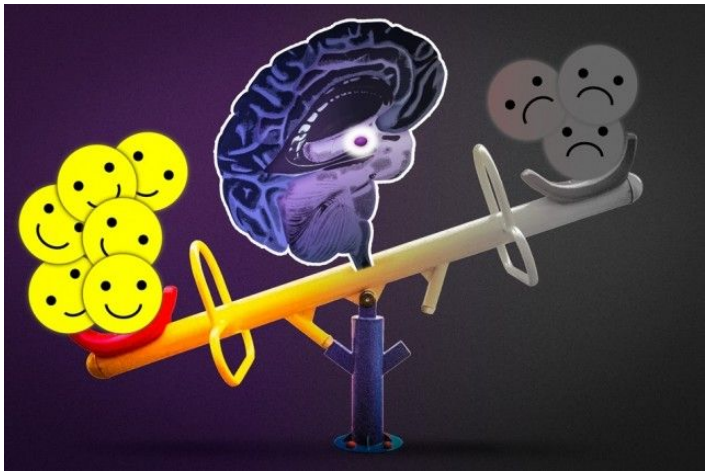

una interpretación de W*

W tiene codificada información subyacente que es extraída a partir de los datos

Unsupervised sentiment neuron

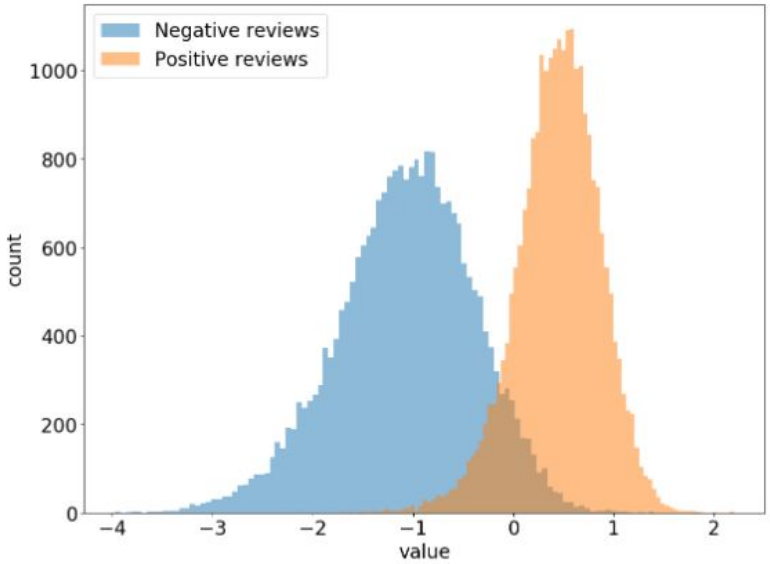

Judy Holliday struck gold in 1950 withe George Cukor's film version of "Born Yesterday," and from that point forward, her career consisted of trying to find material good enough to allow her to strike gold again. It never happened. In "It Should Happen to You" (I can't think of a blander title, by the way), Holliday does yet one more variation on the dumb blonde who's maybe not so dumb after all, but everything about this movie feels warmed over and half hearted. Even Jack Lemmon, in what I believe was his first film role, can't muster up enough energy to enliven this recycled comedy. The audience knows how the movie will end virtually from the beginning, so mostly it just sits around waiting for the film to catch up. Maybe if you're enamored of Holliday you'll enjoy this; otherwise I wouldn't bother. Grade: C

una interpretación de W*

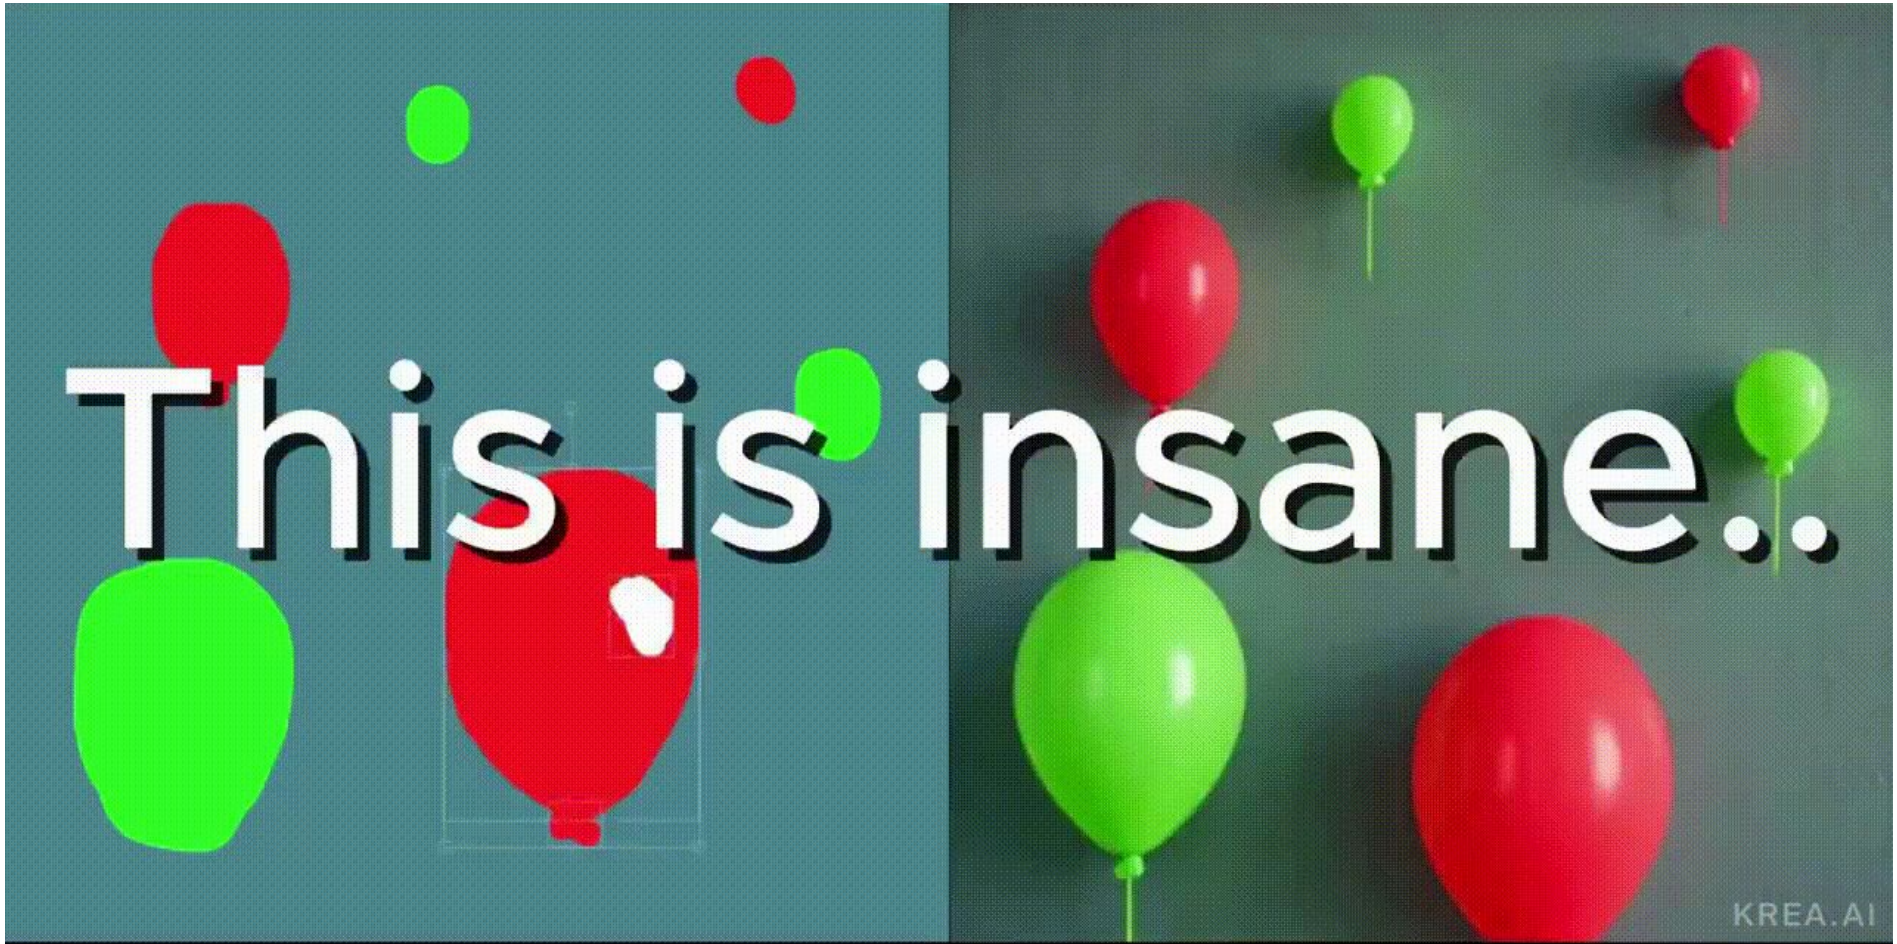

El problema de las capas lineales

el proceso de vectorización en imágenes destruye la información y relaciones espaciales

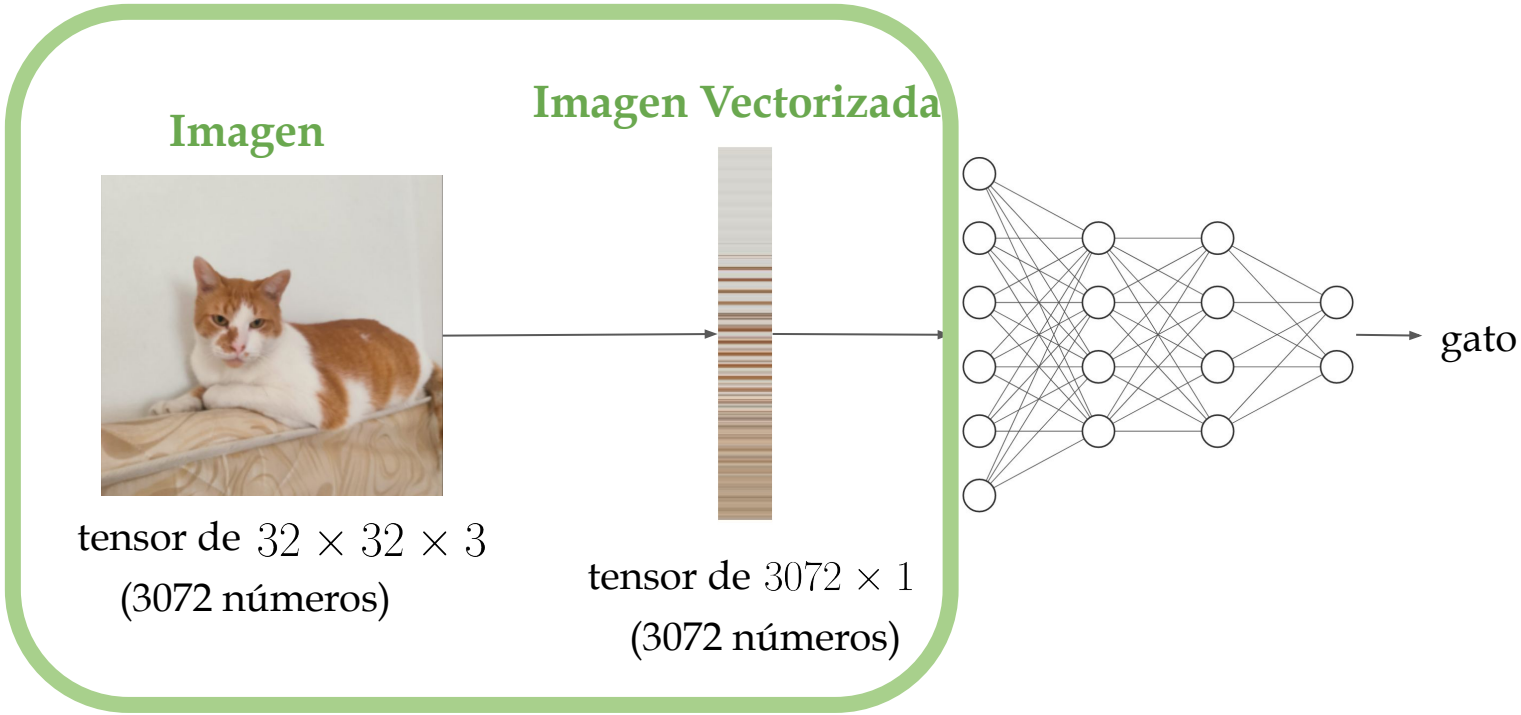

Redes Convolucionales

Las redes convolucionales solucionan este problema

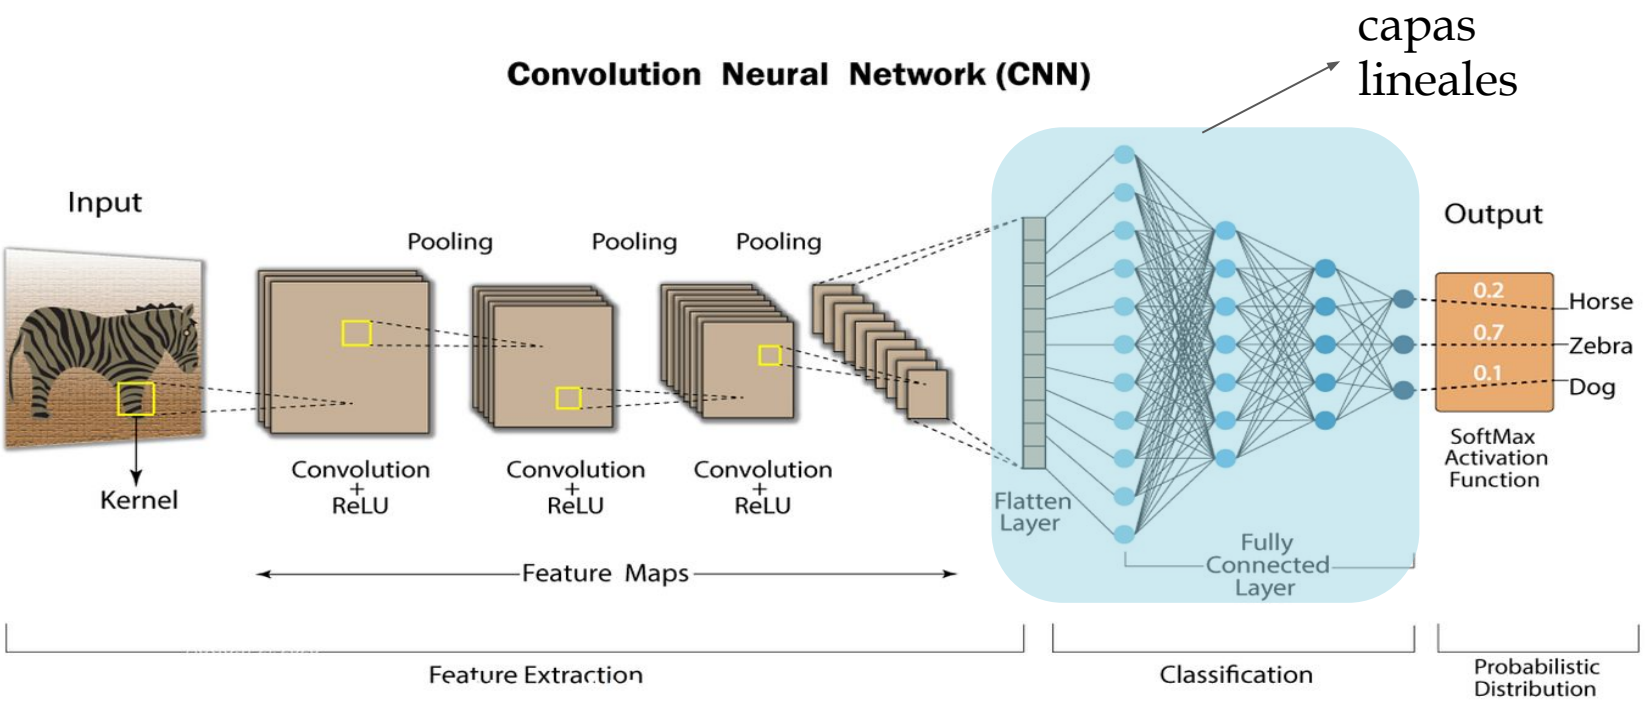

Redes Convolucionales

cada capa convolucional puede tener N cantidad de filtros diferentes

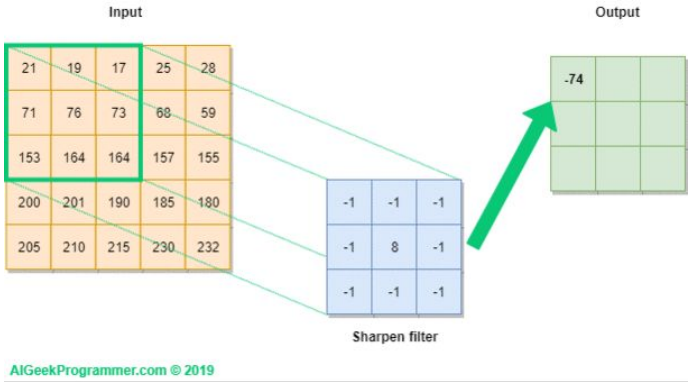

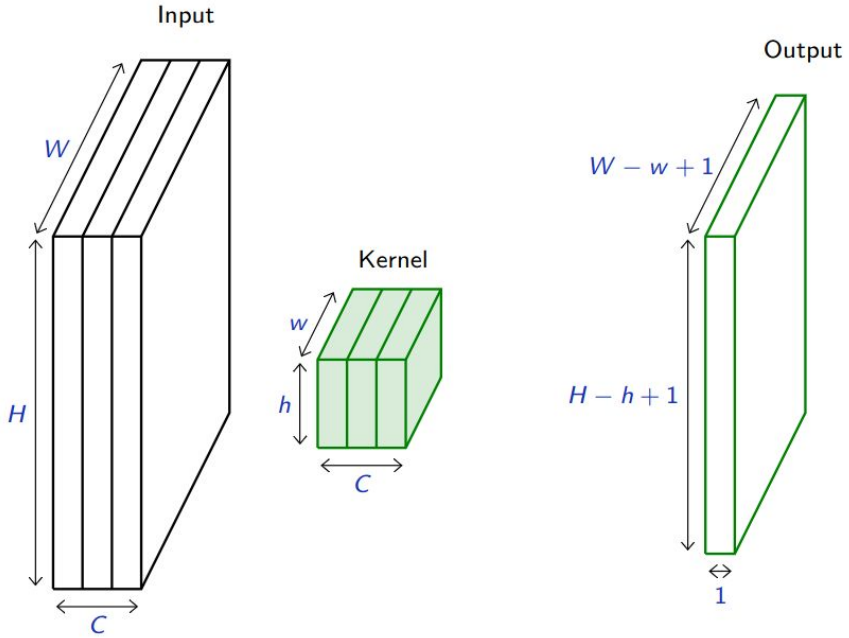

Redes Convolucionales

Capas de filtros

Cada capa se encarga de extraer características únicas de la imagen

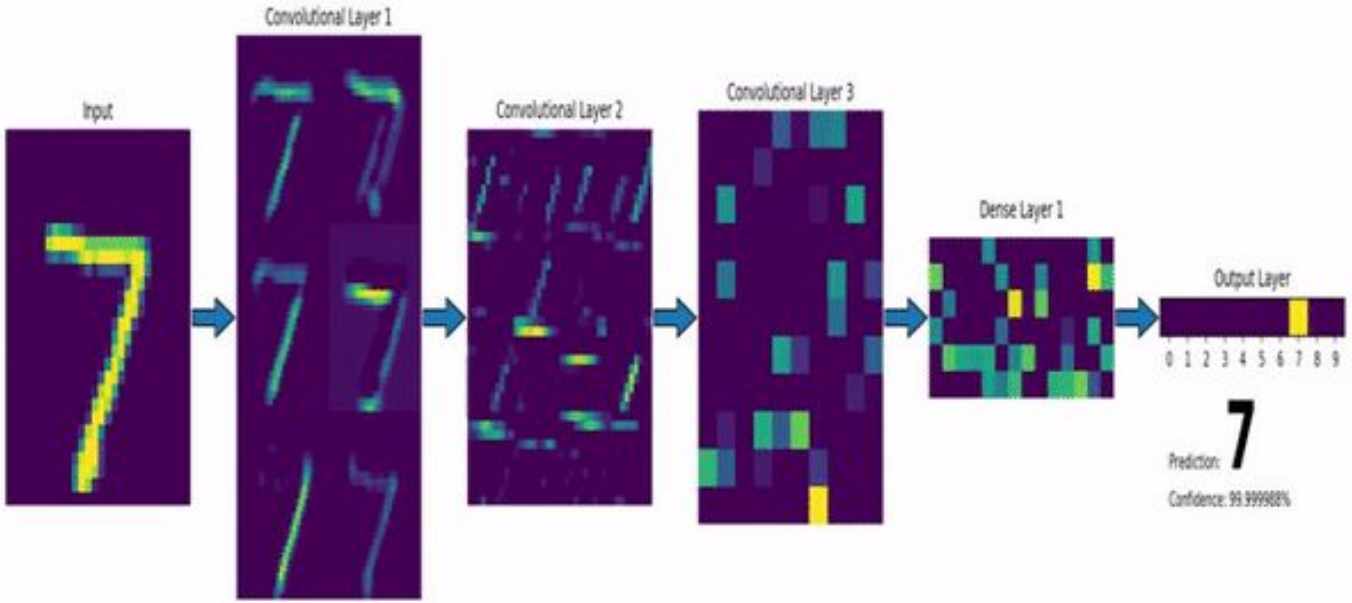

En las capas finales de una red convolucional, se resumen las características aprendidas para tomar decisiones de alto nivel

Capas de filtros

campo de decisión de una CNN

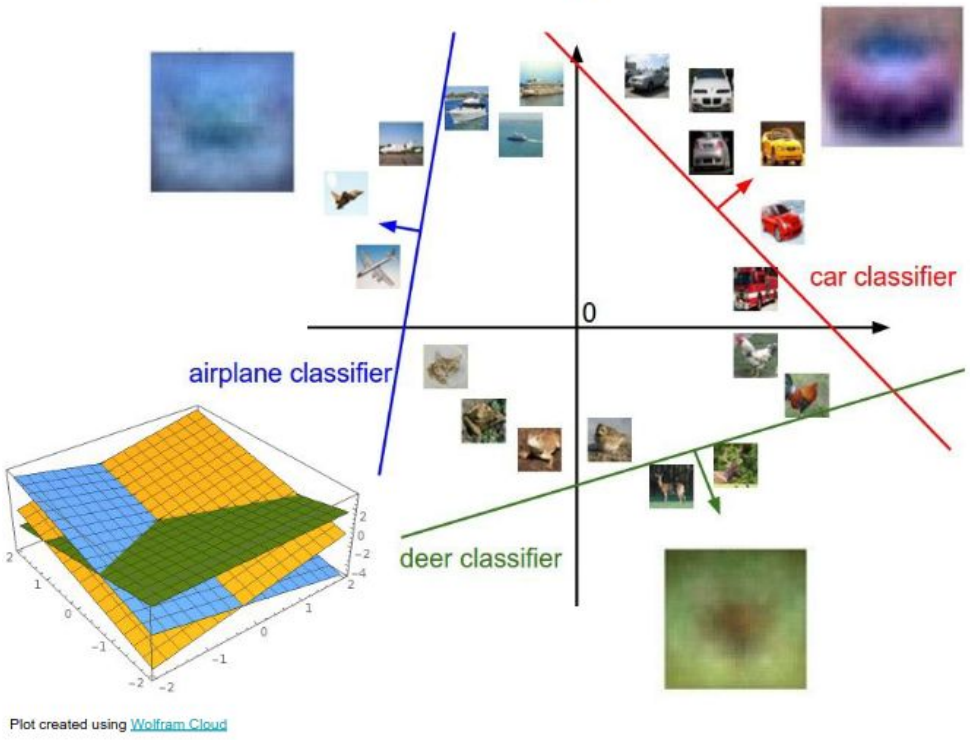

Deep Convolutional Networks

se han propuesto mucho tipos de arquitecturas CNN para cada tarea

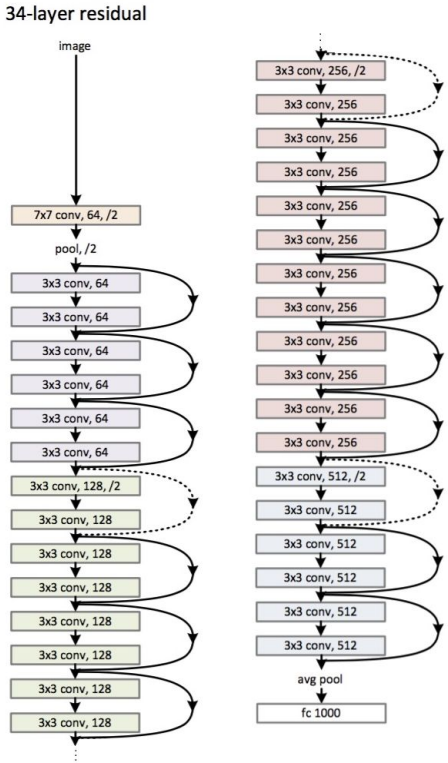

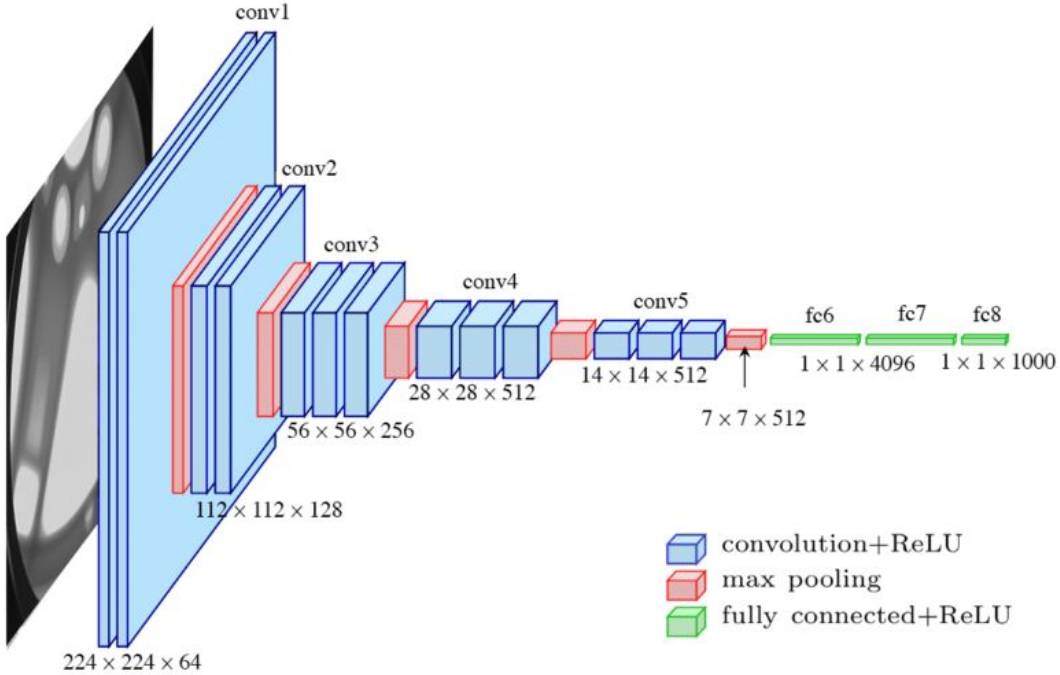

Deep Convolutional Networks

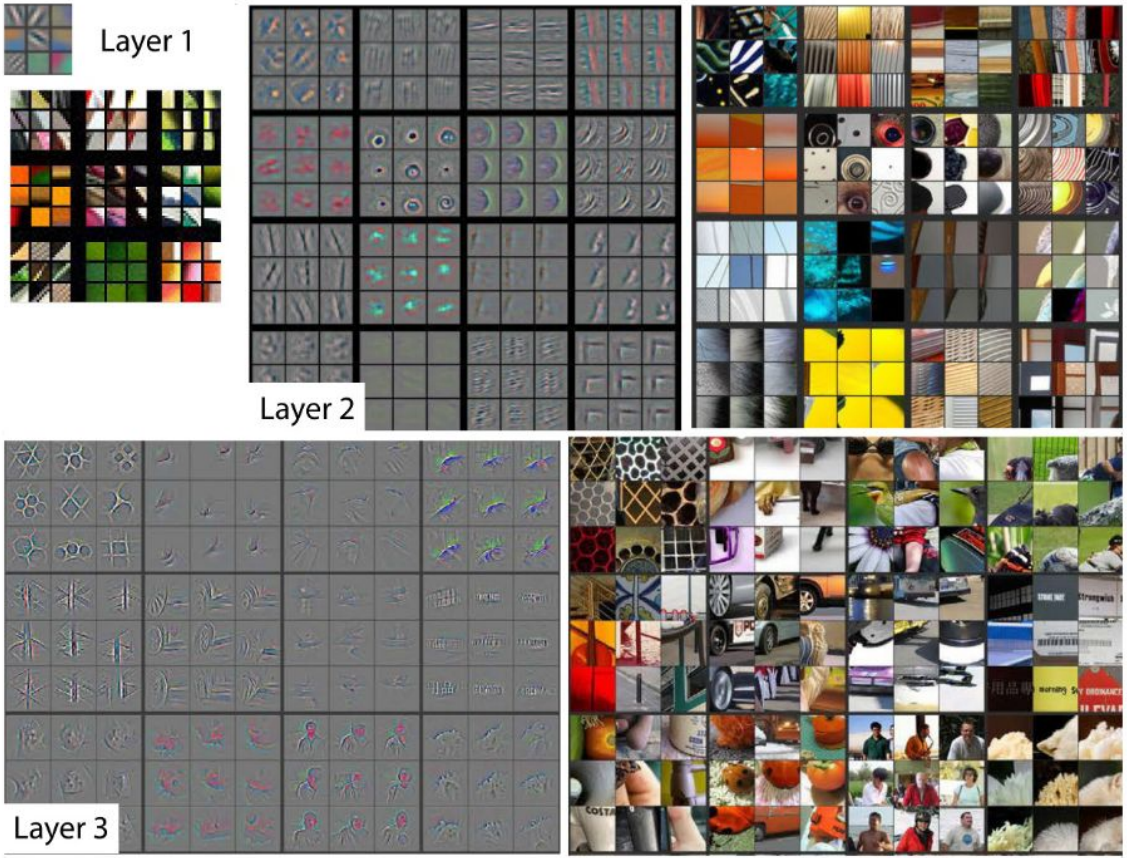

(Zeiler and Fergus, 2014)

Deep Convolutional Networks

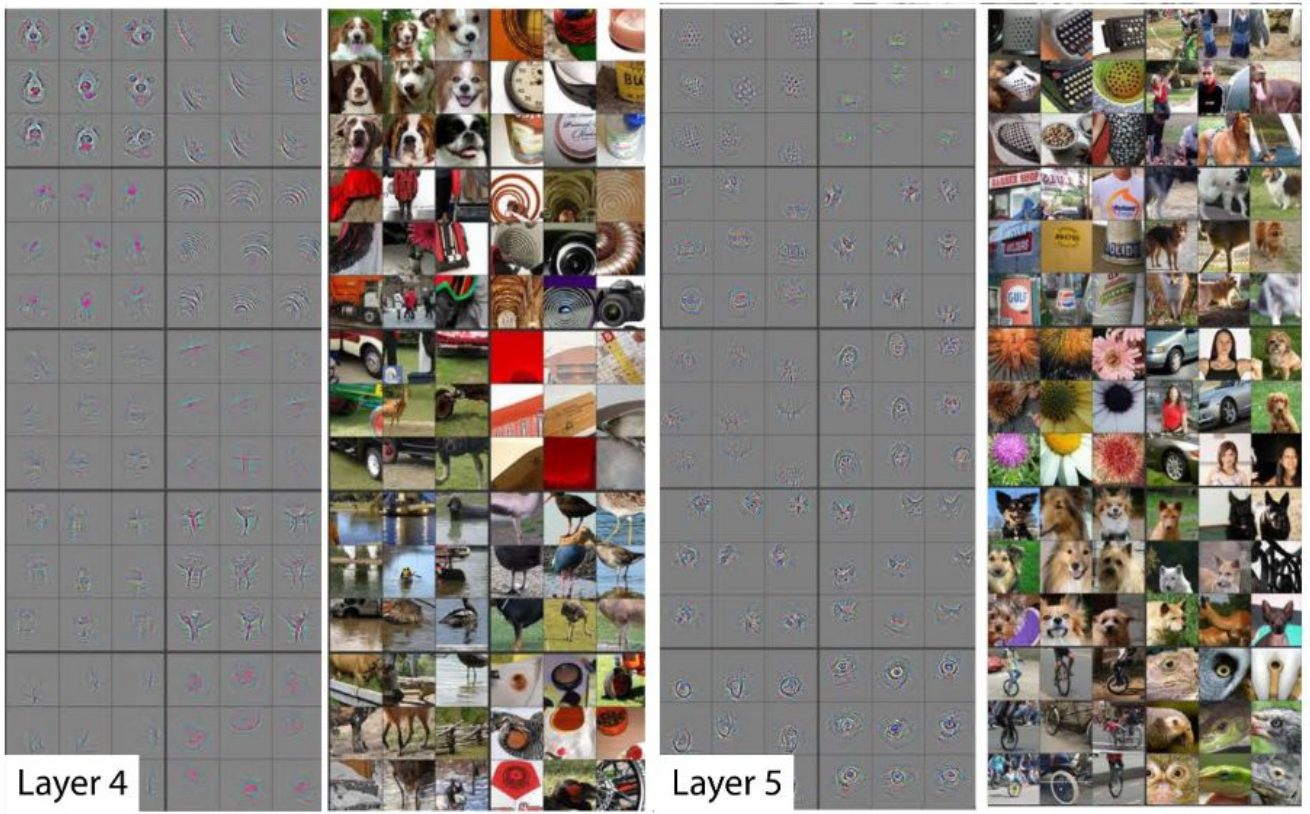

(Zeiler and Fergus, 2014)

Escalabilidad

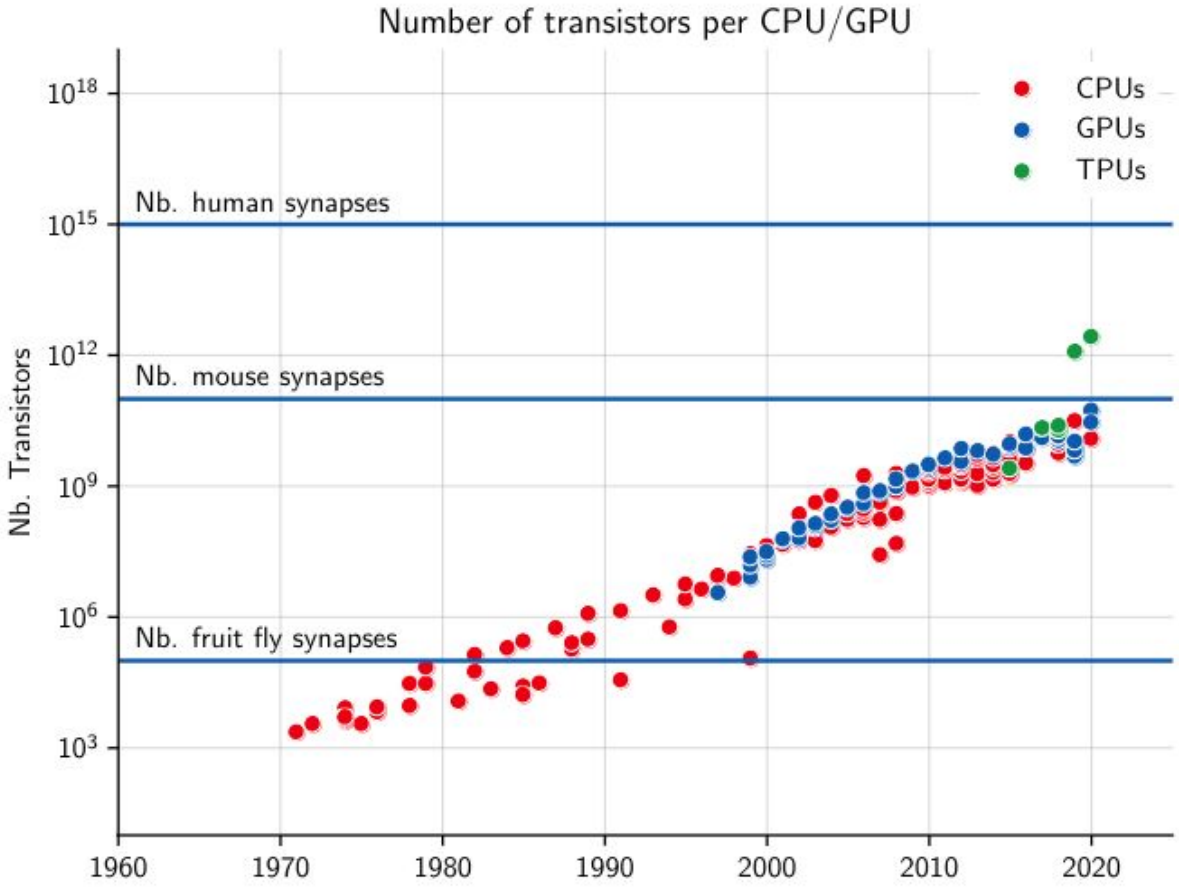

Escalabilidad

más capas lleva a un mejor rendimiento

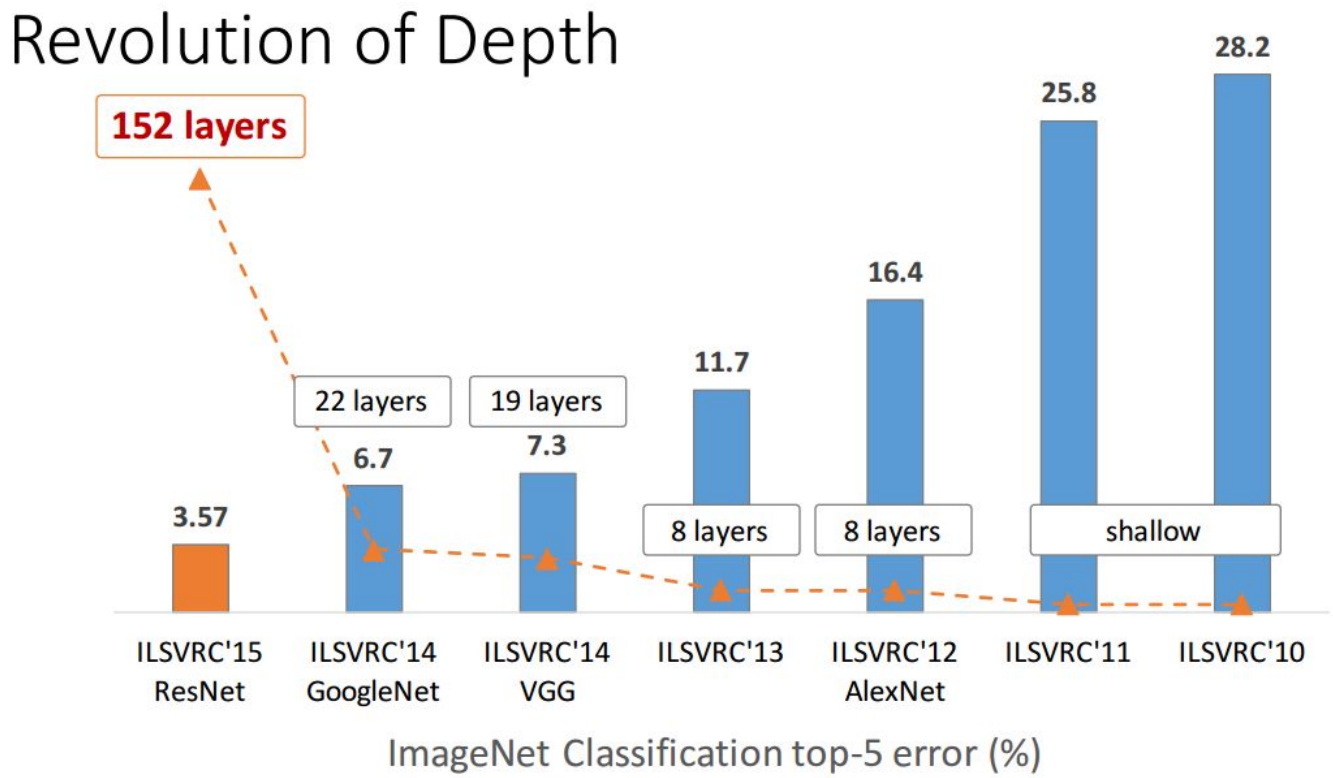

Deep Learning: Hoy

Deep Learning: Hoy

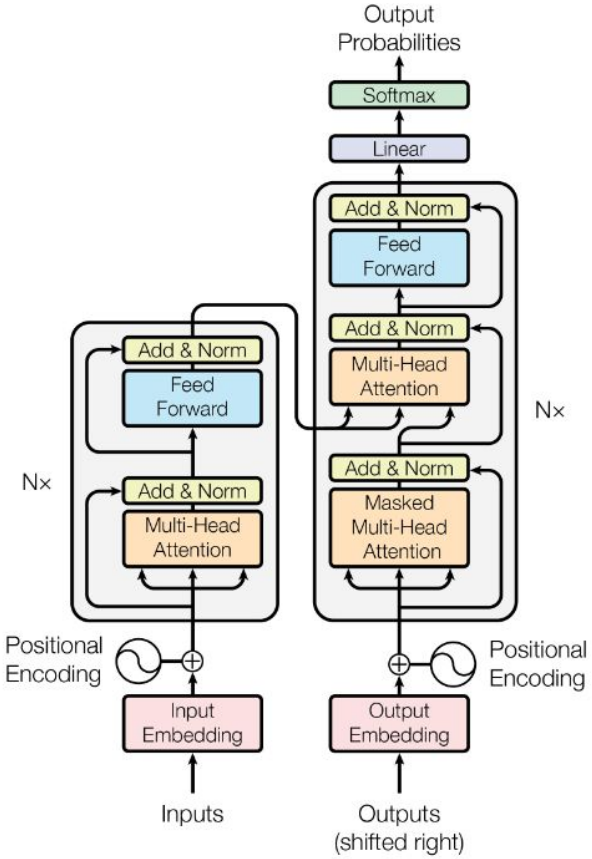

La receta

Hardware

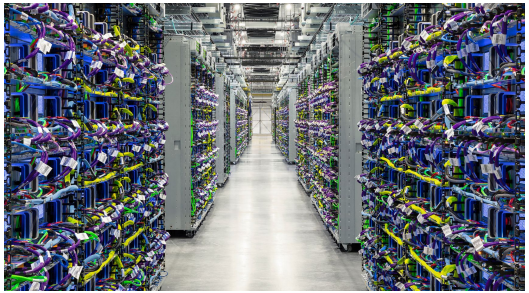

CPUs/GPUs/almacenamiento desarrollados

Datos

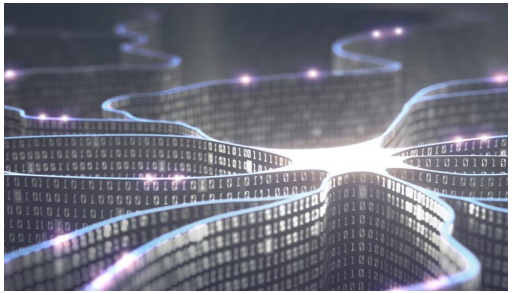

un montón de datos de “internet”

Mejoras algorítmicas

un montón de datos de “internet”

Multimodalidad

El deep learning está en todos lados

El deep learning es una herramienta general que se puede aplicar para cualquier tarea

NVIDIA GTC 2024

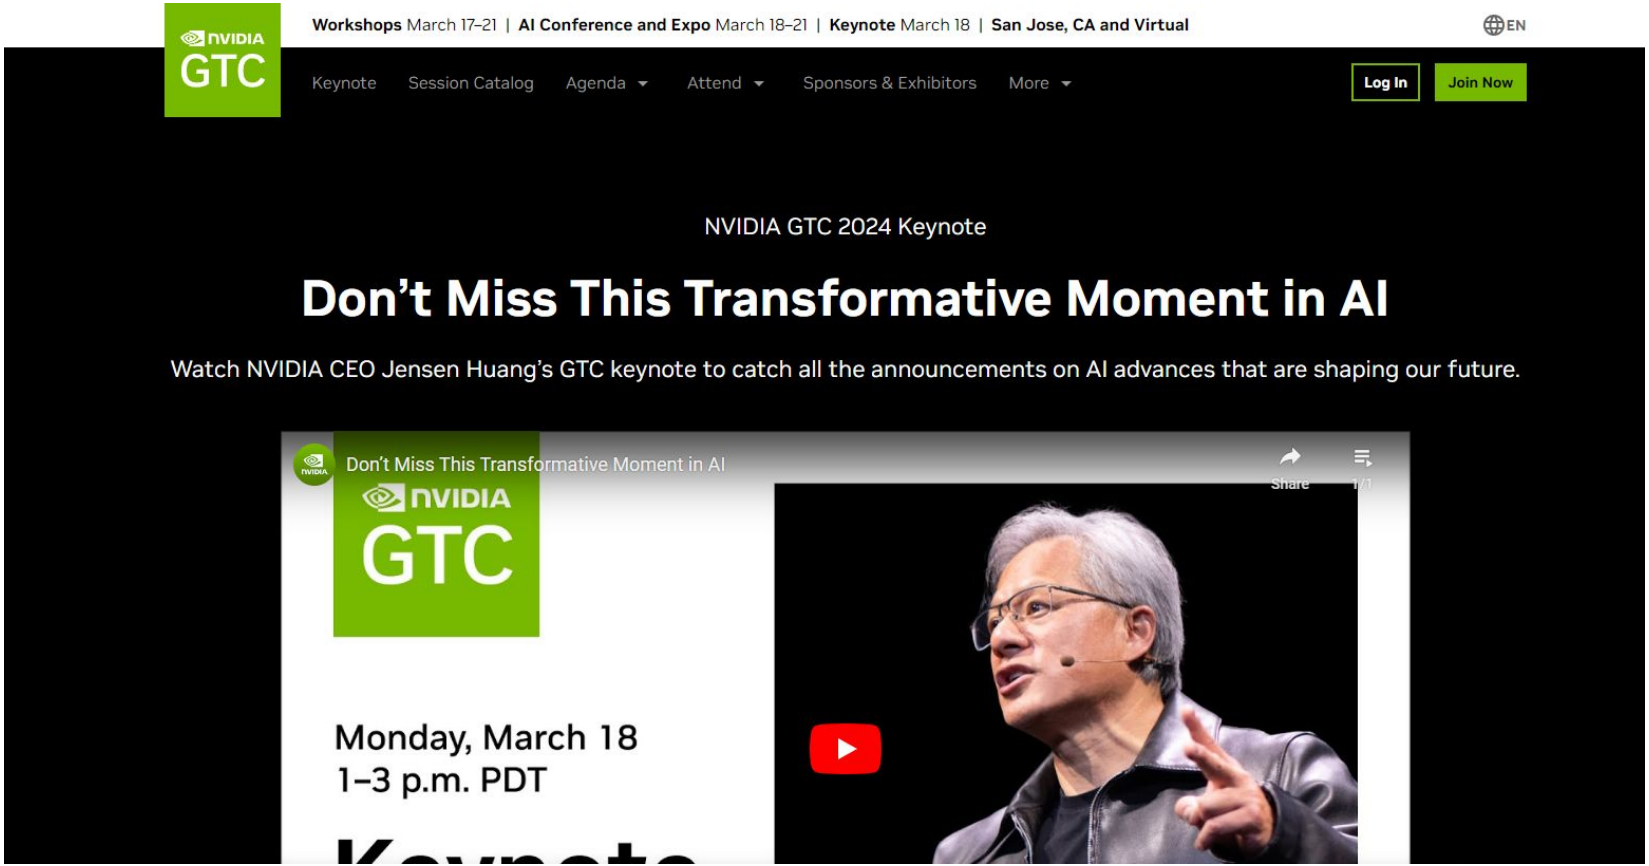

Hands-on

1. Preparación de datos
2. Definición arquitectura
3. Loss y Optimizador
4. Bucle entrenamiento
5. Evaluación

Hands-on

aproximemos la función sin(x)

Hands-on

clasificacion de imagenes con una red neuronal convolucional

```
Epoch: 0: 100%|██████████| 782/782 [01:10<00:00, 11.02it/s]
Epoch [1/30], Average Loss:for epoch[1, 2.0429]
Epoch: 1: 100%|██████████| 782/782 [01:11<00:00, 10.94it/s]
Epoch [2/30], Average Loss:for epoch[2, 1.8800]
Epoch: 2: 100%|██████████| 782/782 [01:10<00:00, 11.15it/s]
Epoch [3/30], Average Loss:for epoch[3, 1.8318]
Epoch: 3: 100%|██████████| 782/782 [01:11<00:00, 10.98it/s]
Epoch [4/30], Average Loss:for epoch[4, 1.8073]
Epoch: 4: 100%|██████████| 782/782 [01:10<00:00, 11.09it/s]
Epoch [5/30], Average Loss:for epoch[5, 1.7886]
Epoch: 5: 100%|██████████| 782/782 [01:10<00:00, 11.08it/s]
Epoch [6/30], Average Loss:for epoch[6, 1.7773]
Epoch: 6: 100%|██████████| 782/782 [01:10<00:00, 11.11it/s]
Epoch [7/30], Average Loss:for epoch[7, 1.7676]
Epoch: 7: 100%|██████████| 782/782 [01:11<00:00, 11.00it/s]
Epoch [8/30], Average Loss:for epoch[8, 1.7589]
Epoch: 8: 100%|██████████| 782/782 [01:09<00:00, 11.23it/s]
Epoch [9/30], Average Loss:for epoch[9, 1.7521]
Epoch: 9: 100%|██████████| 782/782 [01:10<00:00, 11.03it/s]
Epoch [10/30], Average Loss:for epoch[10, 1.7481]
Epoch: 10: 100%|██████████| 782/782 [01:10<00:00, 11.15it/s]
Epoch [11/30], Average Loss:for epoch[11, 1.7404]
Epoch: 11: 100%|██████████| 782/782 [01:10<00:00, 11.17it/s]
Epoch [12/30], Average Loss:for epoch[12, 1.7354]
Epoch: 12: 100%|██████████| 782/782 [01:09<00:00, 11.18it/s]
Epoch [13/30], Average Loss:for epoch[13, 1.7316]
Epoch: 13: 100%|██████████| 782/782 [01:21<00:00,  9.54it/s]
Epoch [14/30], Average Loss:for epoch[14, 1.7271]
Epoch: 14: 100%|██████████| 782/782 [01:10<00:00, 11.09it/s]
Epoch [15/30], Average Loss:for epoch[15, 1.7235]
Epoch: 15: 100%|██████████| 782/782 [01:15<00:00, 10.41it/s]
```

Actualicemos el repositorio!

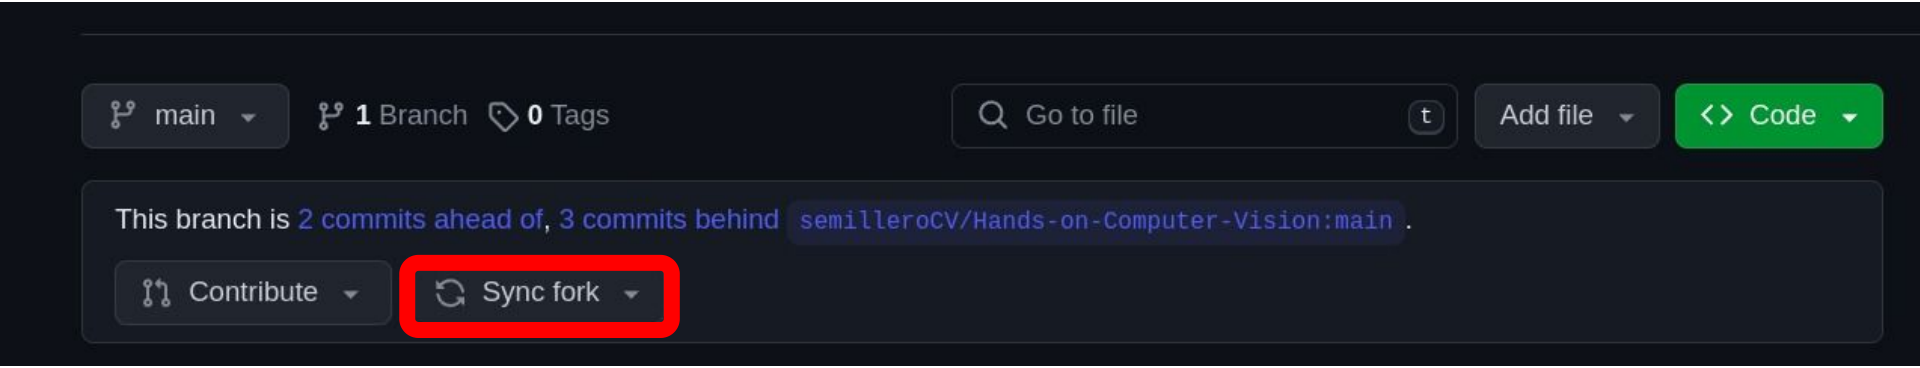

Actualicemos el repositorio!

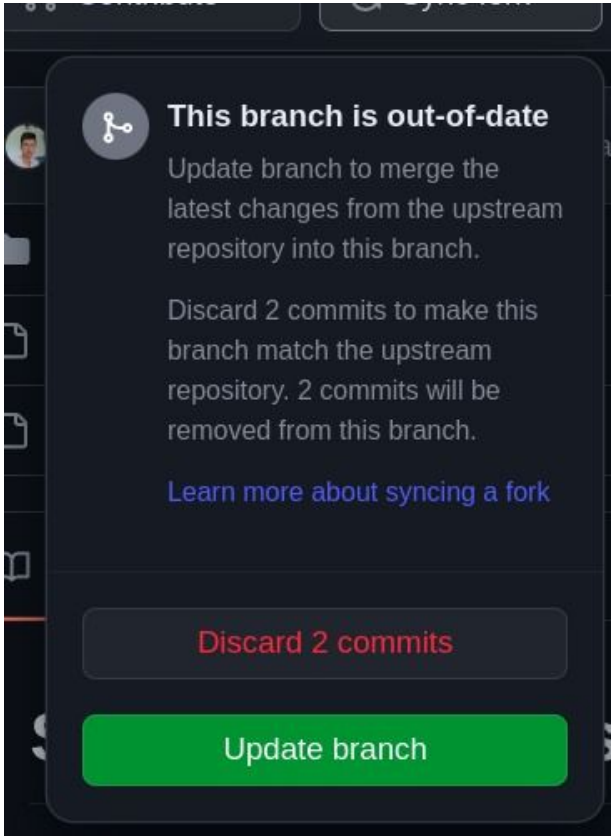

Abrelo en colab usando **“githubtocolab”**