Panorama: Deep Learning

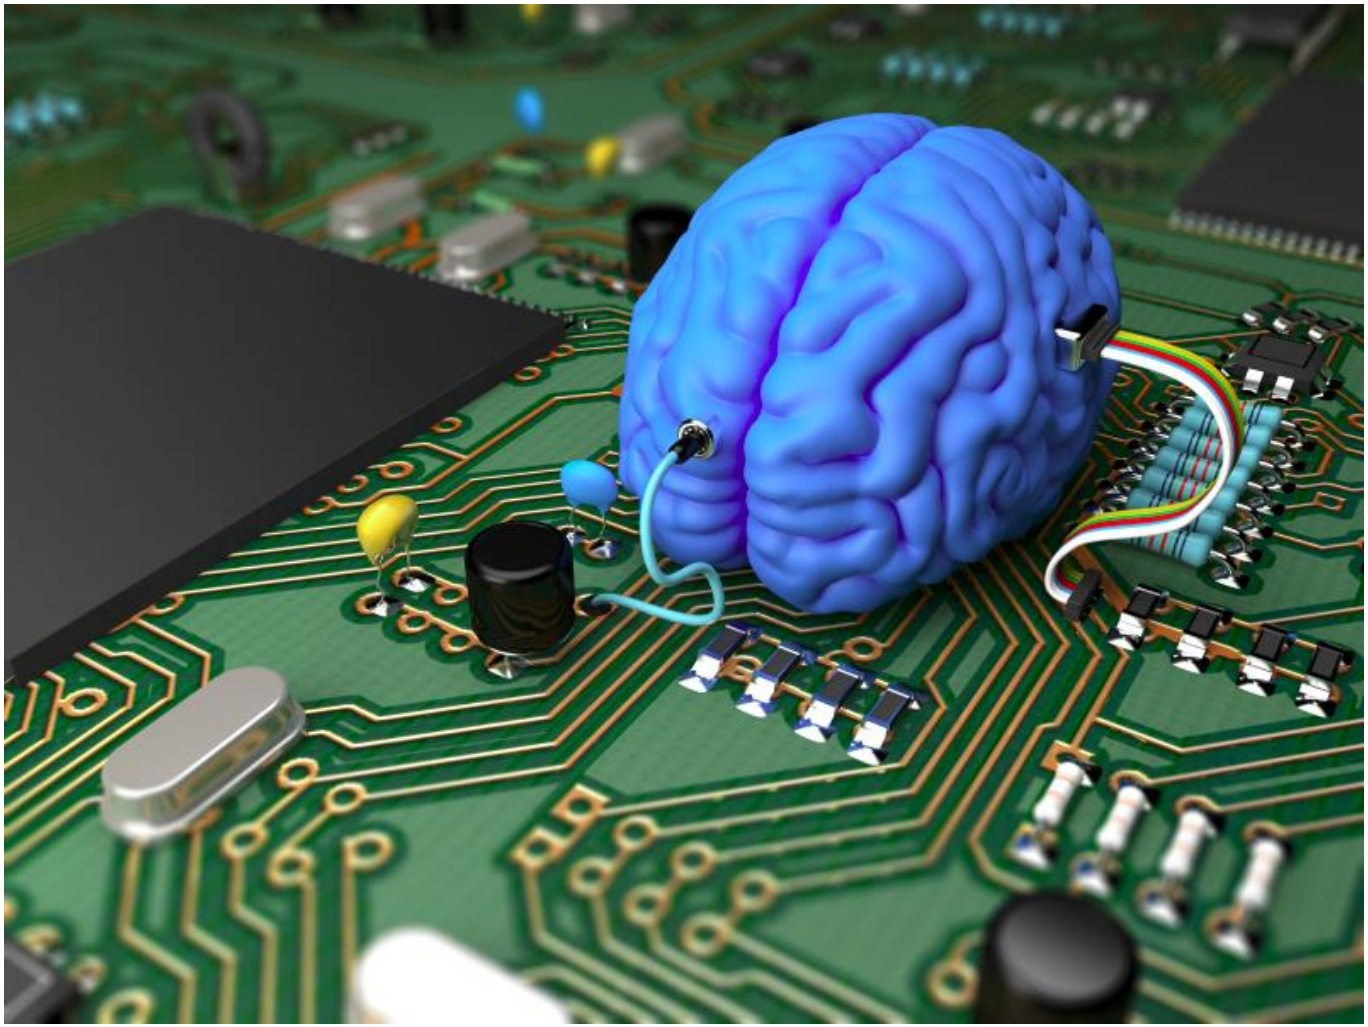

Master Universitario Oficial **Data Science**

con el apoyo del

Lara Lloret Iglesias

Santander, Octubre 2017

Links

- https://github.com/laramaktub/Panorama-Deep-Learning

- https://datasciencehub.ifca.es/

Inteligencia Artificial

La inteligencia artificial nació en 1950, con un conjunto de expertos que querían conseguir que los ordenadores "pensaran"

"El esfuerzo de automatizar tareas intelectuales normalmente llevadas a cabo por humanos"

Esto incluye lo que luego se denominó Machine Learning y Deep Learning, pero también sistemas que no aprenden propiamente:

→ Primeros programas de ajedrez – Symbolic AI

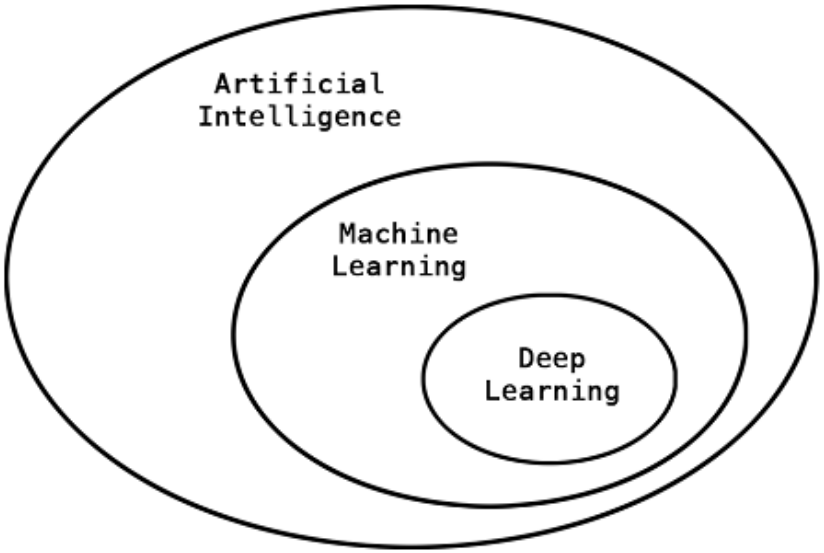

Machine learning

El Machine learning surge de una serie de preguntas:

¿Puede un ordenador ir más allá de "lo que sabemos como ordenarle"?
¿Puede de verdad aprender una tarea concreta "a su manera"?

¿Puede sorprendernos?

En lugar de darle nosotros ciertas reglas codificadas…

¿Puede aprender automaticamente mirando a los datos?

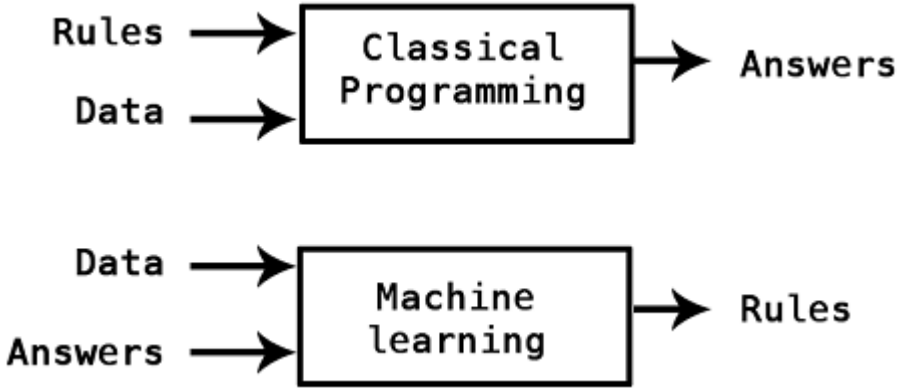

Machine Learning

El principal objectivo en Machine Learning (y en Deep learning) es ser capaces de transformar los datos de una manera significativa, o en otras palabras: **encontrar una representación "útil"** de los mismos que nos permita resolver el problema con mayor facilidad.

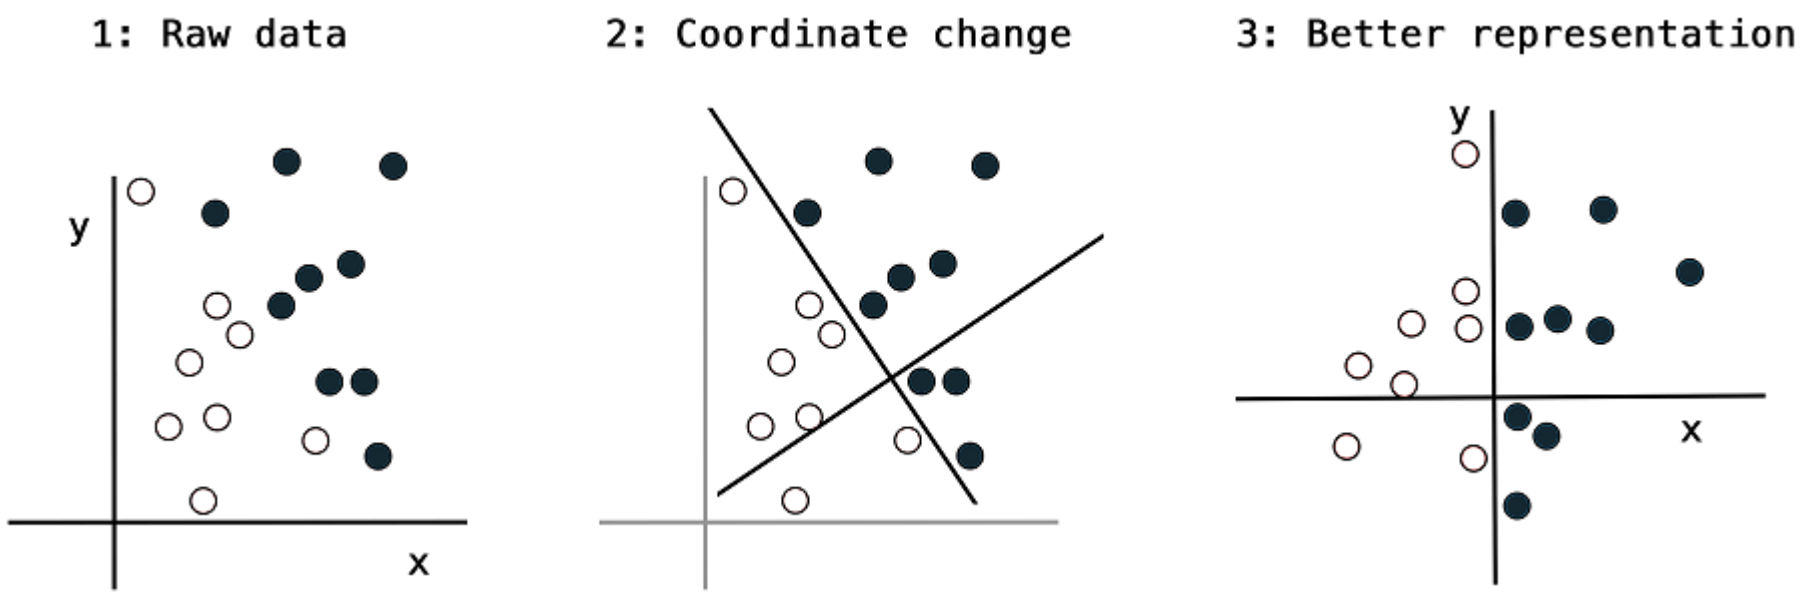

Machine learning

What We See

08	02	22	97	38	15	00	40	00	75	04	05	07	78	52	12	50	77	91	08
49	49	99	40	17	81	18	57	60	87	17	40	98	43	69	48	04	56	62	00
81	49	31	73	55	79	14	29	93	71	40	67	53	88	30	03	49	13	36	65
52	70	95	23	04	60	11	42	69	24	68	56	01	32	56	71	37	02	36	91
22	31	16	71	51	67	63	89	41	92	36	54	22	40	40	28	66	33	13	80
24	47	32	60	99	03	45	02	44	75	33	53	78	36	84	20	35	17	12	50
32	98	81	28	64	23	67	10	26	38	40	67	59	54	70	66	18	38	64	70
67	26	20	68	02	62	12	20	95	63	94	39	63	08	40	91	66	49	94	21
24	55	58	05	66	73	99	26	97	17	78	78	96	83	14	88	34	89	63	72
21	36	23	09	75	00	76	44	20	45	35	14	00	61	33	97	34	31	33	95
78	17	53	28	22	75	31	67	15	94	03	80	04	62	16	14	09	53	56	92
16	39	05	42	96	35	31	47	55	58	88	24	00	17	54	24	36	29	85	57
86	56	00	48	35	71	89	07	05	44	44	37	44	60	21	58	51	54	17	58
19	80	81	68	05	94	47	69	28	73	92	13	86	52	17	77	04	89	55	40
04	52	08	83	97	35	99	16	07	97	57	32	16	26	26	79	33	27	98	66
88	36	68	87	57	62	20	72	03	46	33	67	46	55	12	32	63	93	53	69
04	42	16	73	38	25	39	11	24	94	72	18	08	46	29	32	40	62	76	36
20	69	36	41	72	30	23	88	34	62	99	69	82	67	59	85	74	04	36	16
20	73	35	29	78	31	90	01	74	31	49	71	48	86	81	16	23	57	05	54
01	70	54	71	83	51	54	69	16	92	33	48	61	43	52	01	89	19	67	48

What Computers See

Deep Learning

Deep Learning: Una forma de aprender una representación óptima para nuestros datos, en multiples etapas (capas)

Lo "profundo" del Deep Learning no es una referencia a ningún tipo de comprensión "más profunda" lograda por un enfoque distinto, sino que simplemente representa esta idea de capas sucesivas de representaciones - cuántas capas contribuyen a un modelo de los datos se denomina "profundidad" del modelo

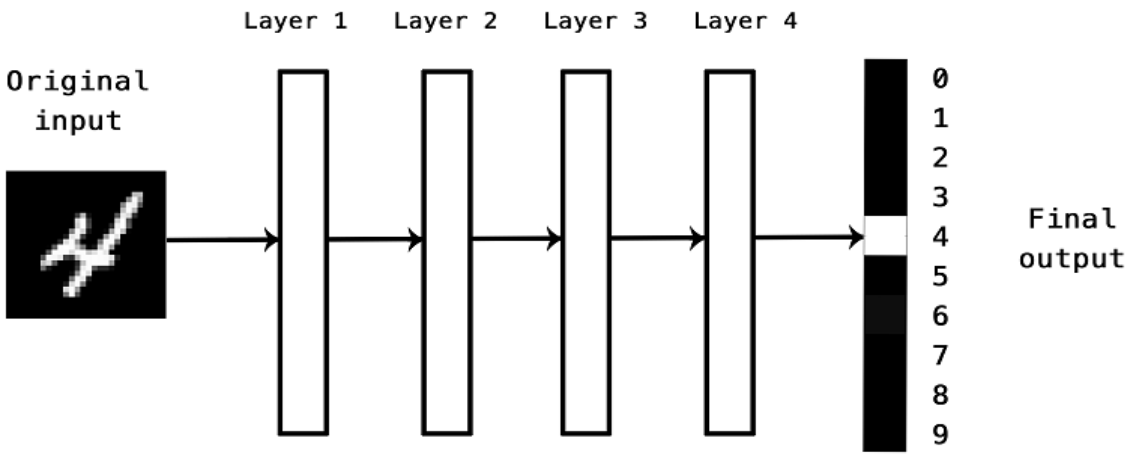

En Deep Learning, estas representaciones en capas son (casi siempre) aprendidas a través de modelos llamados "**redes neuronales**", estructuradas en capas apiladas una tras otra.

¿Por qué neuronal?

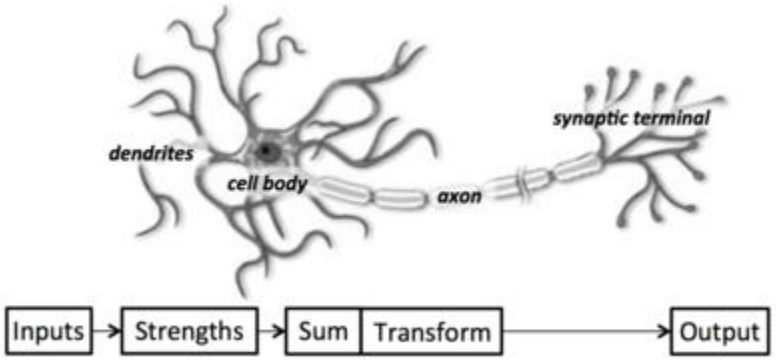

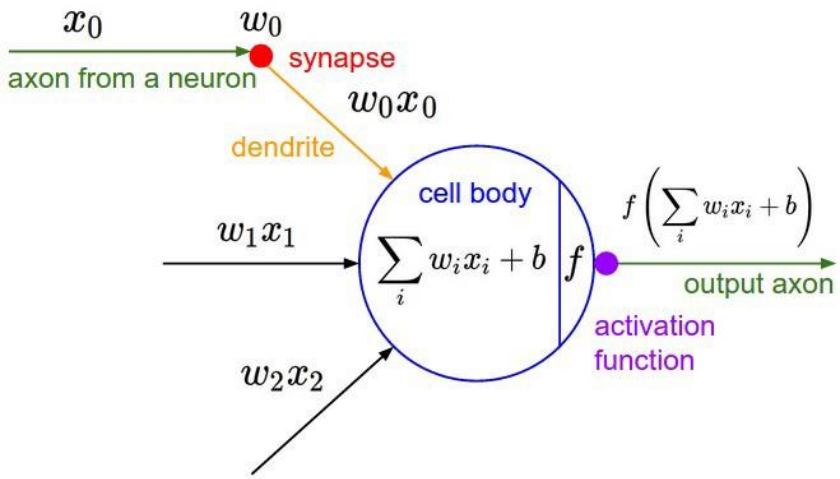

Las redes neuronales son un **marco matemático** para aprender representaciones significativas a partir de los datos

 # No son modelos del funcionamiento del cerebro #

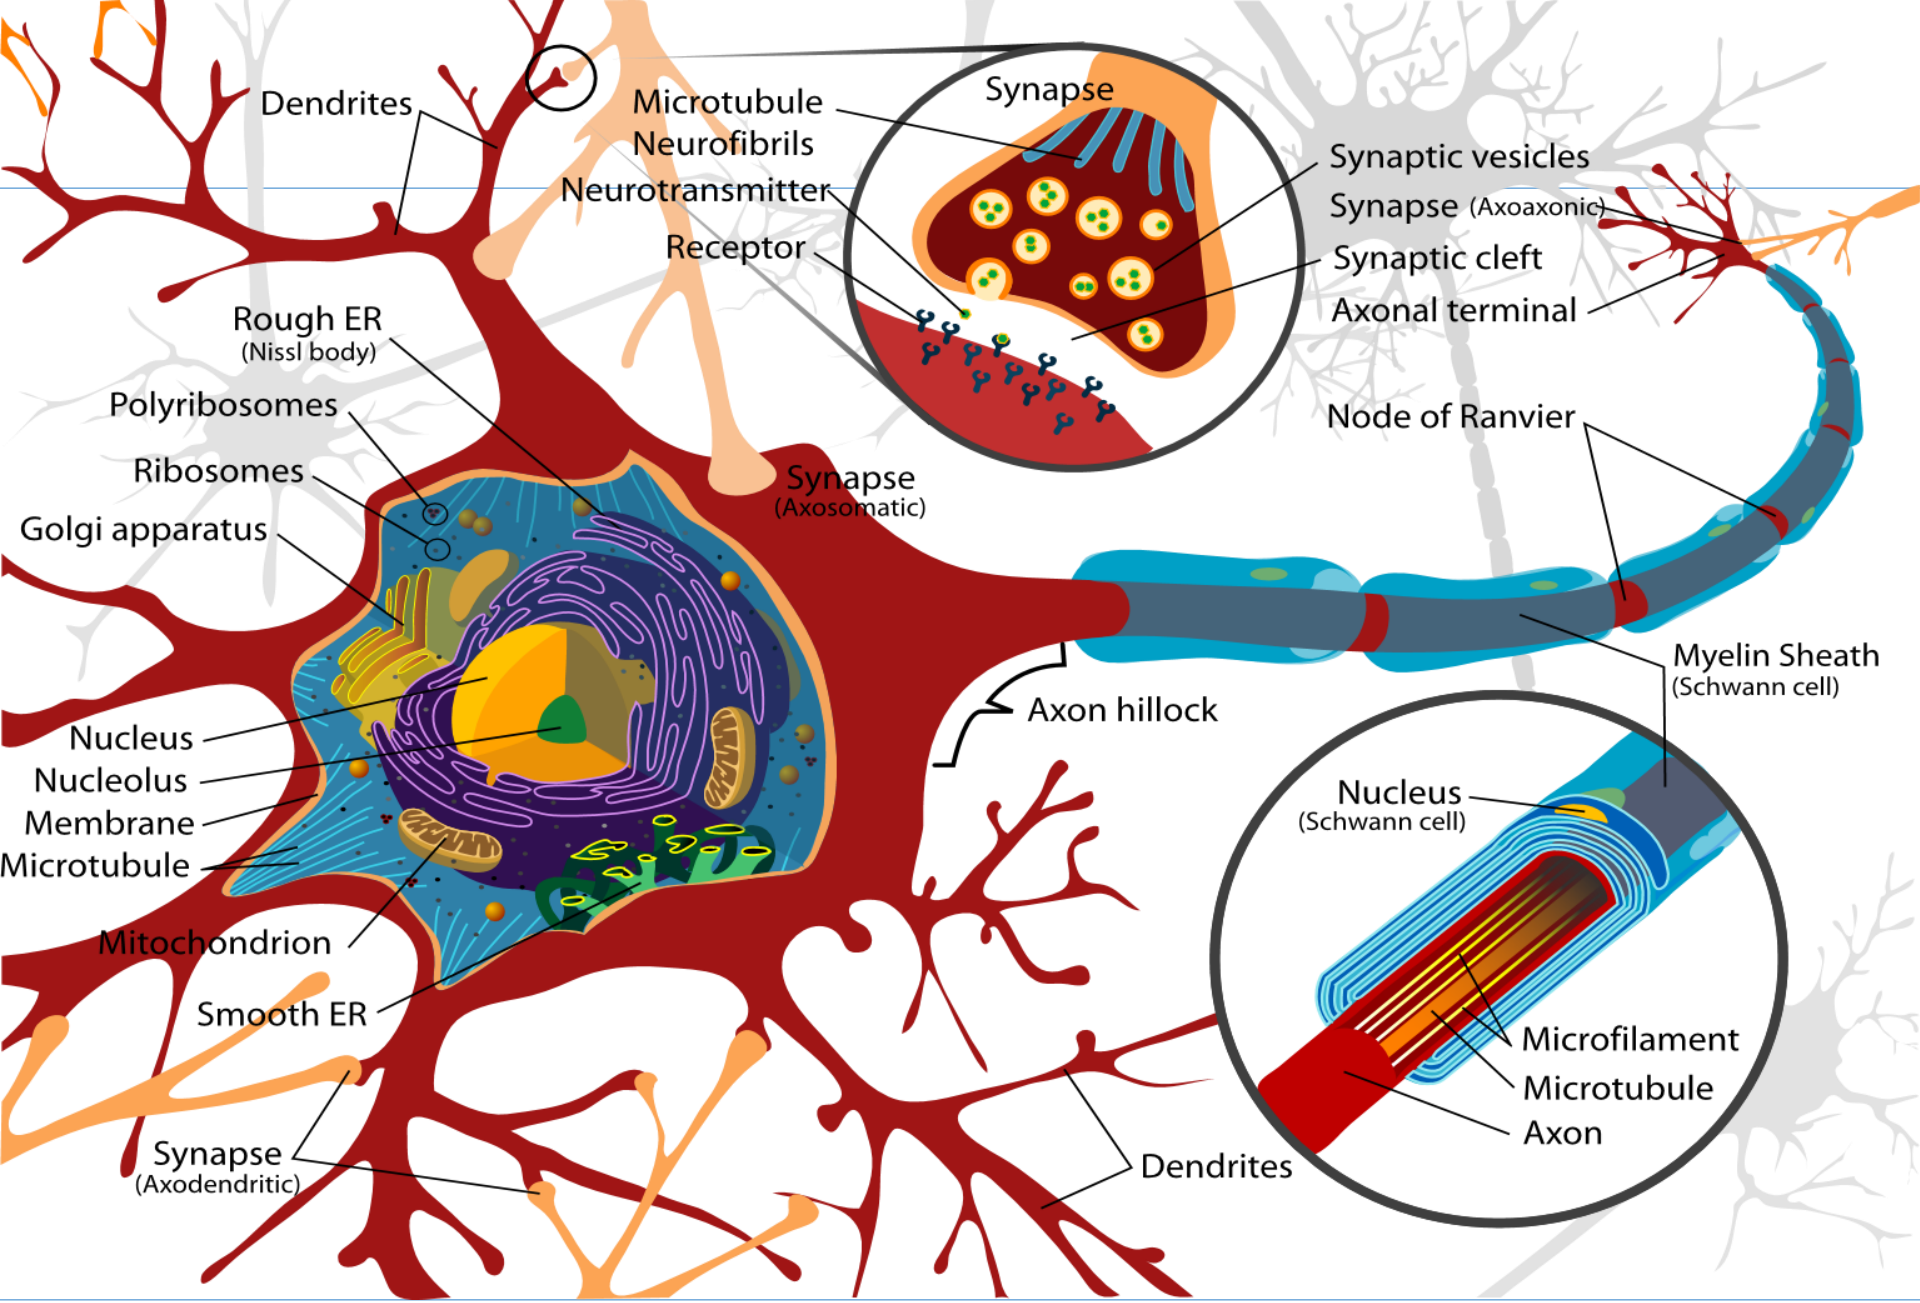
Dendrites
Microtubule
Neurofibrils
Neurotransmitter
Receptor
Synapse
Synaptic vesicles
Synapse (Axoaxonic)
Synaptic cleft
Axonal terminal
Rough ER
(Nissl body)
Polyribosomes
Ribosomes
Golgi apparatus
Synapse
(Axosomatic)
Node of Ranvier
Myelin Sheath
(Schwann cell)
Axon hillock
Nucleus
Nucleolus
Membrane
Microtubule
Mitochondrion
Smooth ER
Nucleus
(Schwann cell)
Microfilament
Microtubule
Axon
Synapse
(Axodendritic)
Dendrites

¿Cómo funciona una red neuronal?

Dataset entrenamiento: x (fotos de perros y gatos)
y (etiquetas “perro” o “gato”)

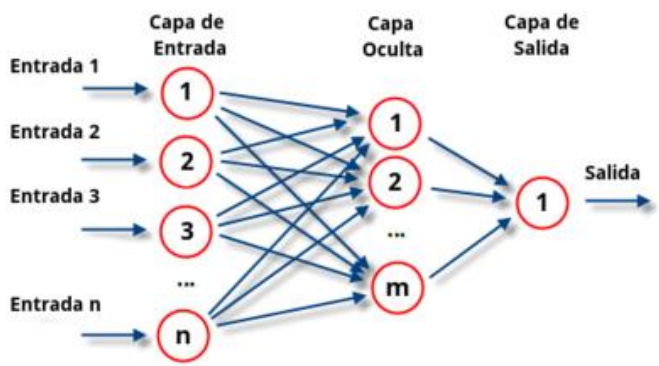

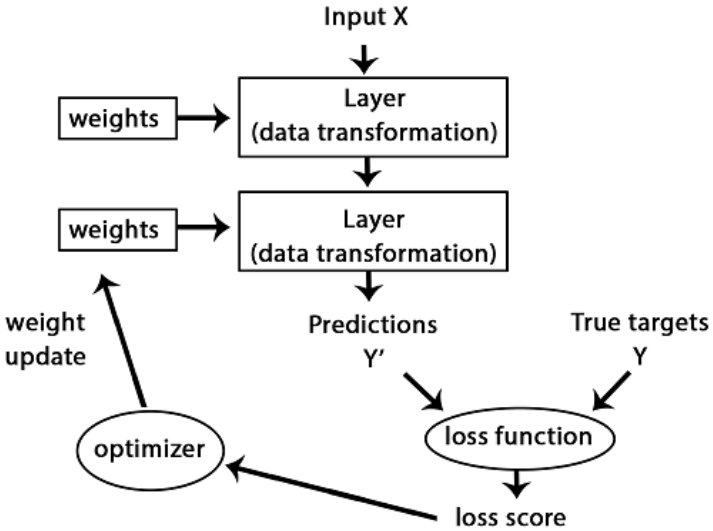

Red densamente conectada

¿Realmente es algo tan novedoso?

Las redes neuronales ya se conocían bien en 1989.

Entonces….

¿Por qué el aprendizaje profundo sólo despega después de 2012? ¿Qué cambió en esas dos décadas?

Hay tres fuerzas que han impulsado los avances en el aprendizaje automático:

- Big data.
- Hardware.
- Avances algorítmicos

Big Data

- Es un concepto que hace referencia a un conjunto de datos tan grande que las **aplicaciones informáticas tradicionales** de procesamiento de datos **no son suficientes** para tratar con ellos.
- **Un cambio cuantitativo puede llevar a un cambio cualitativo**

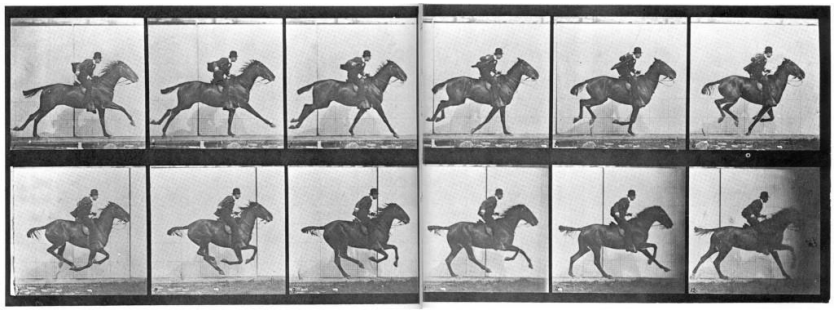

Hardware

- Entre 1990 y 2010 las CPU se han acelerado en un factor 5.000.
- Hoy en día es **posible ejecutar pequeños modelos de Deep Learning en nuestro portátil**
- A principios de la década de los 2000, empresas como **NVIDIA** y **AMD** invirtieron miles de millones de dólares en el desarrollo de chips rápidos y masivamente paralelos (**unidades de procesamiento gráfico, GPU**) para alimentar los gráficos de los **videojuegos cada vez más fotorrealistas**. Supercomputadores **baratos y de un solo propósito** diseñados para representar escenas 3D complejas en nuestra pantalla, en tiempo real.
- Un **pequeño número** de GPUs comenzaron a **reemplazar clústers masivos** de CPUs en varias aplicaciones muy paralelizables, comenzando por **simulaciones físicas**.
- Las redes neuronales que están compuestas principalmente por **muchas pequeñas multiplicaciones matriciales**, también son altamente paralelizables

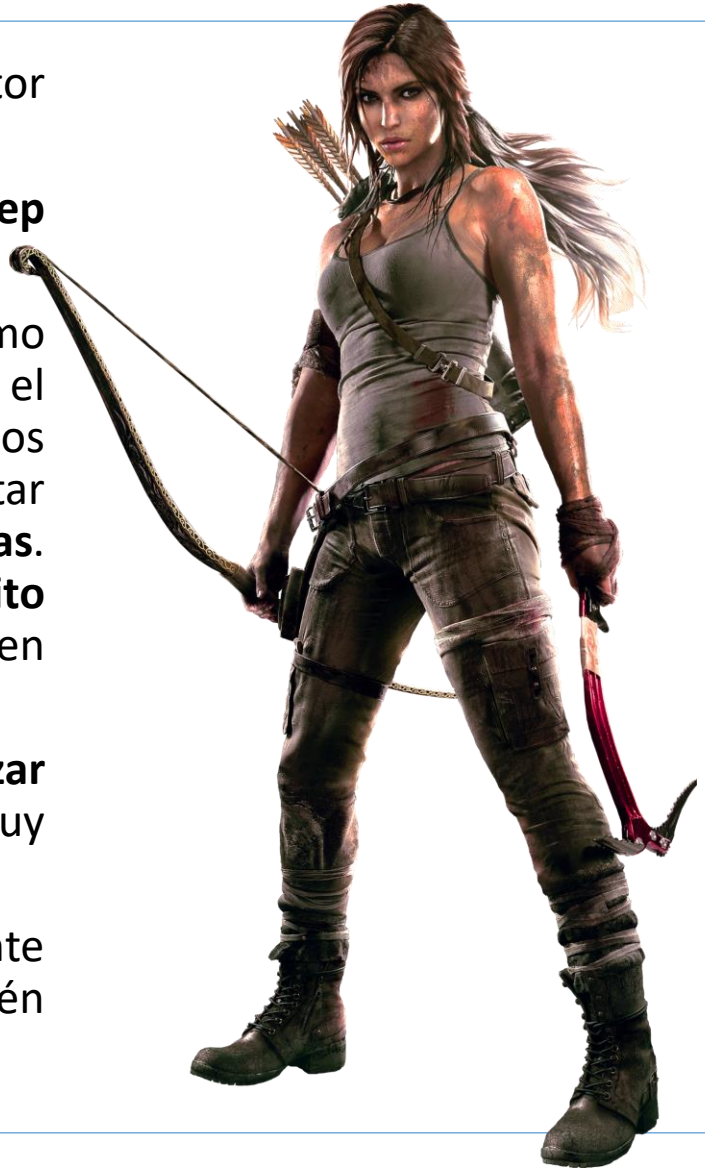

Keras

- Todos los ejemplos que vamos a ver utilizan Keras

https://keras.io/

- Keras es un marco de aprendizaje de Deep Learning para Python que permite **definir y entrenar** casi cualquier tipo de modelo de Deep Learning **de manera rápida y sencilla**.

- Keras presenta las siguientes características:

  - Permite correr el código tanto en CPU como en GPU de manera **transparente**.

  - Tiene una **API "user friendly"** que hace sencillo crear de cero cualquier modelo de Deep Learning de una manera rápida.

  - Tiene un soporte integrado para **redes convolucionales** (ConvNets) para Computer Vision.

- Keras está distribuido con una **licencia permisiva del MIT**, lo que significa que se puede usar **gratuitamente** en **proyectos comerciales**.

Diferentes Frameworks

Evolución de las búsqueda en Google de diferentes marcos de Deep Learning

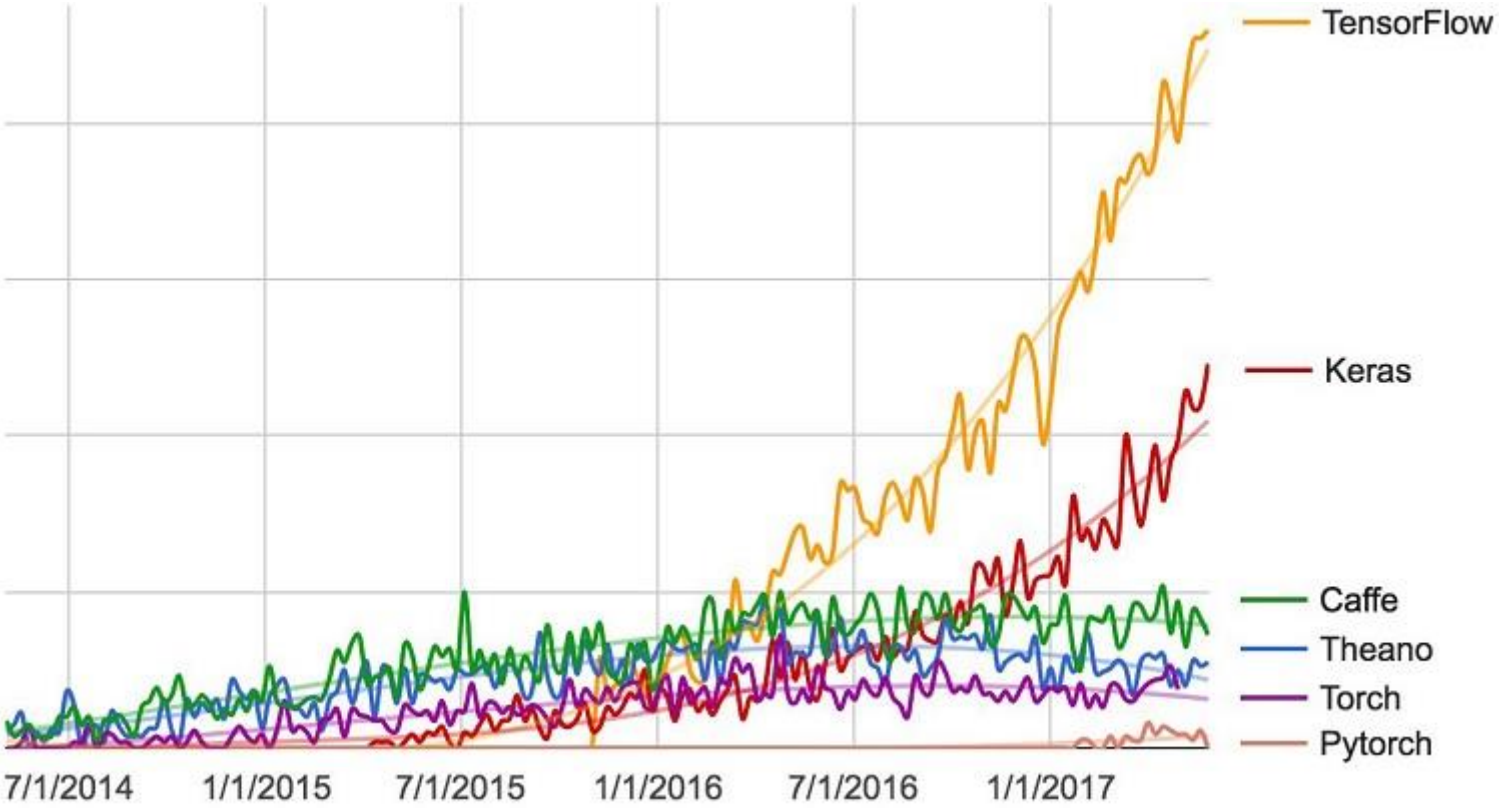

Redes Neuronales Convolucionales

La diferencia fundamental entre una capa densamente conectada y una capa de convolución es la siguiente:

- Las capas densas aprenden patrones globales en su espacio de características de entrada
- Las capas de convolución aprenden patrones locales : patrones encontrados en pequeñas ventanas 2D

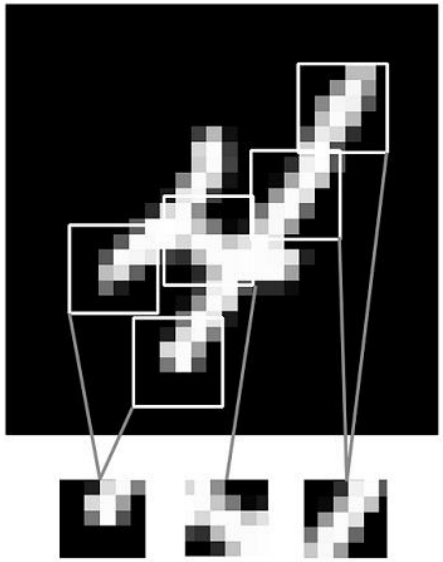

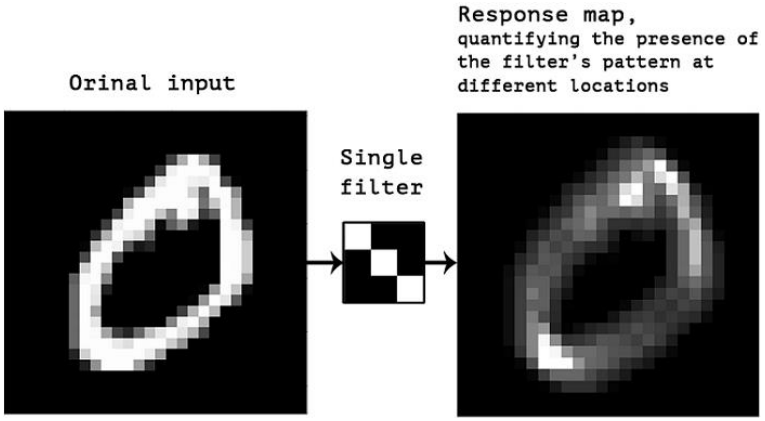

Redes Neuronales Convolucionales

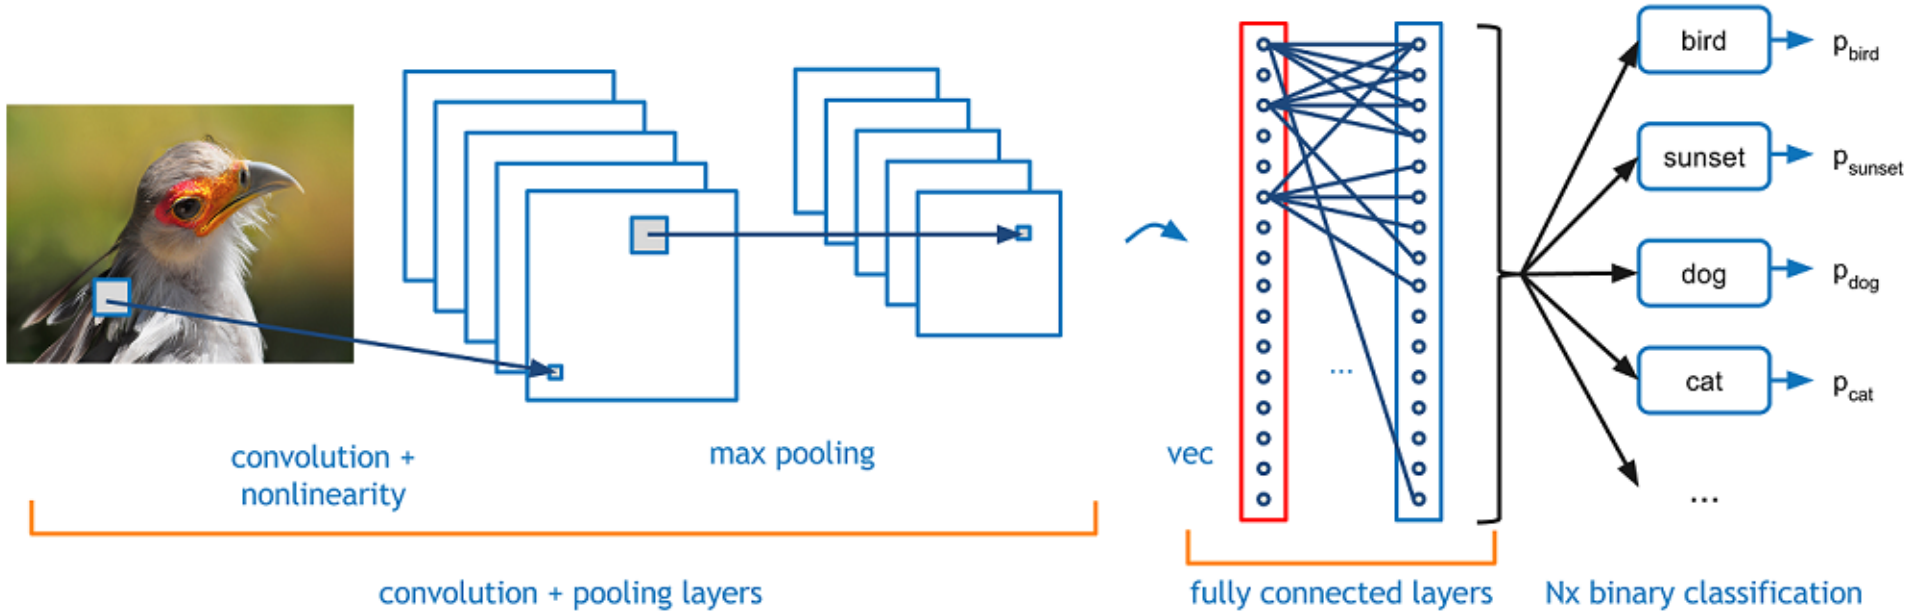

Ejemplos del mundo real: PLANTAS

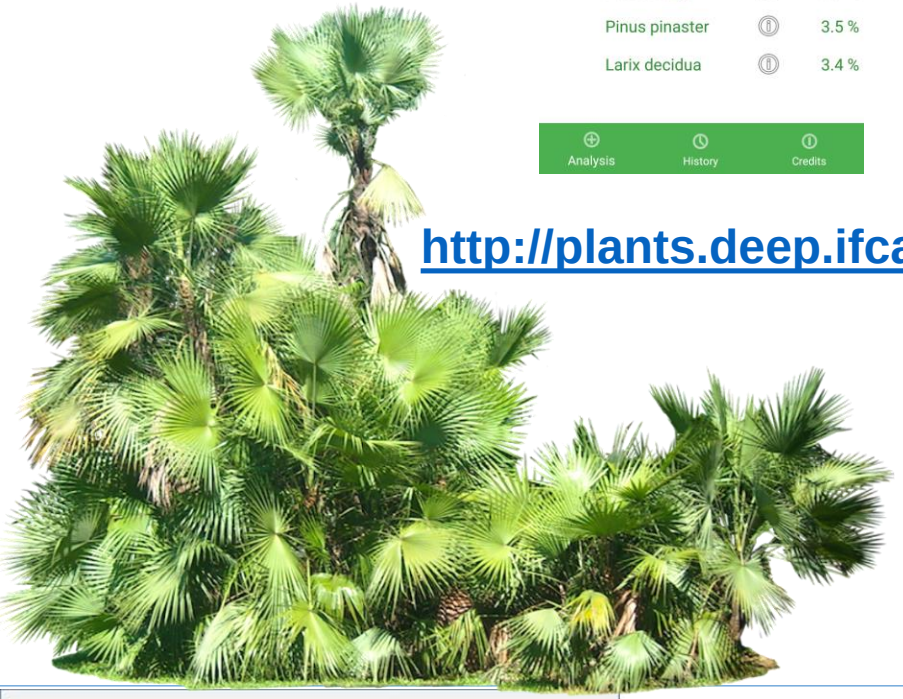

http://plants.deep.ifca.es/

Arquitectura

ResNet50

Framework

Python con Lasagne/Theano

Training dataset

PlantNet *(6K especies | 250K imágenes)*

Test datasets

- Google Search Image *(3680 species | 36K imágenes)*
- Portuguese Flora *(1300 species | 15K imágenes)*
- iNaturalist *(3K especies | 300K imágenes)*

Resultados

Resultados útiles (Top1: 59% | Top5: 74%) para más de la mitad del dataset de test.

Ejemplos del mundo real: CONUS

- **Training dataset**

  Colección de imágenes de expertos (*68 especies | 1.5K imágenes*) que cubren tres regiones diferentes:
  - Región Panámica
  - Región de África del Sur
  - Atlántico Occidental y Mediterráneo
- **Resultados**

Los resultados usando sets de imágenes de Google son prometedores

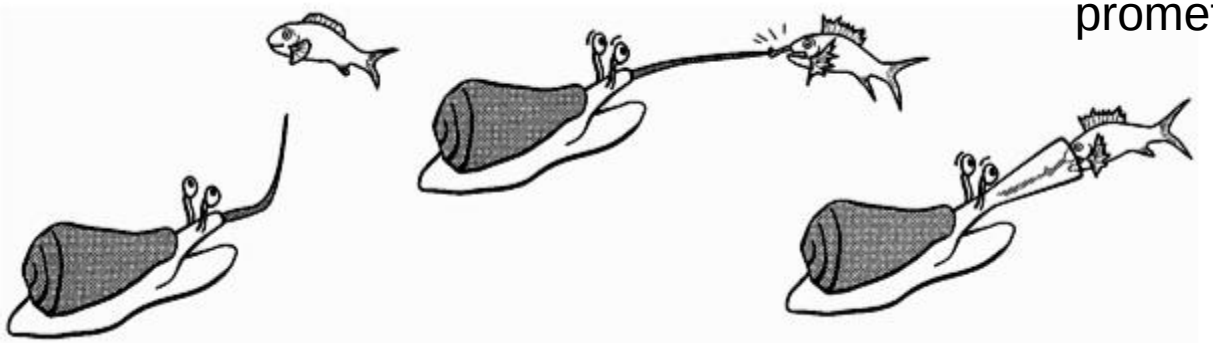

http://conus.deep.ifca.es/