

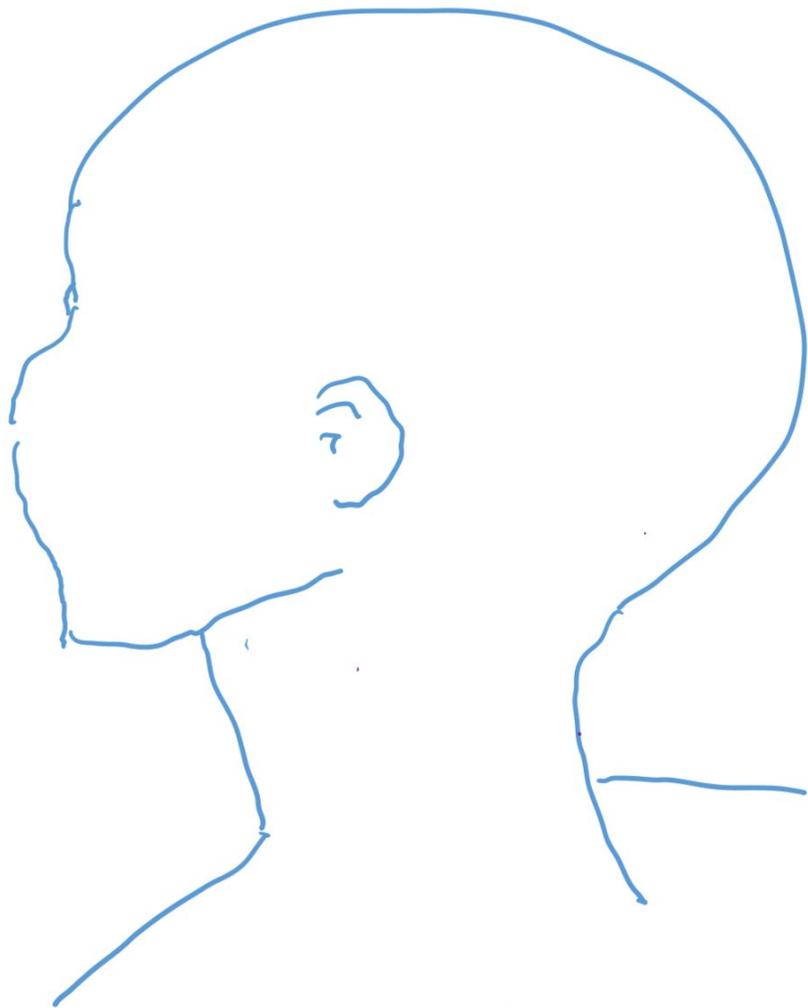
Inteligencia Artificial:

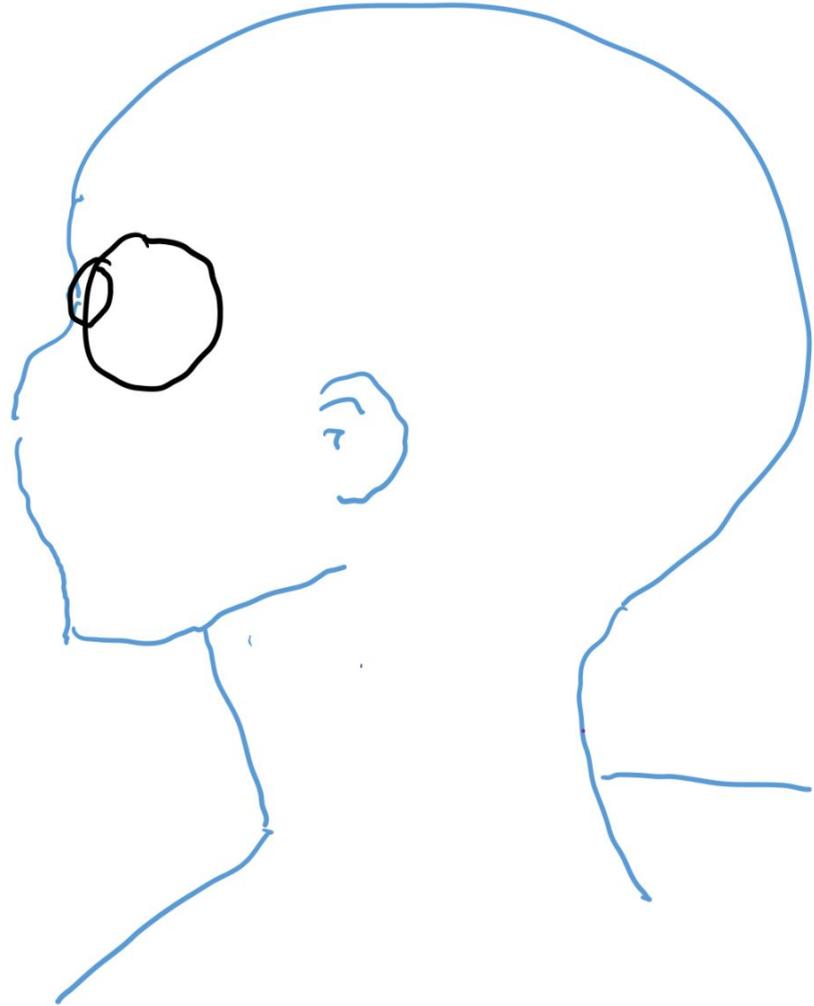
¿Que tienen que ver la **Estadística**
y la **Neurociencia** con la
modelización en **Física**?

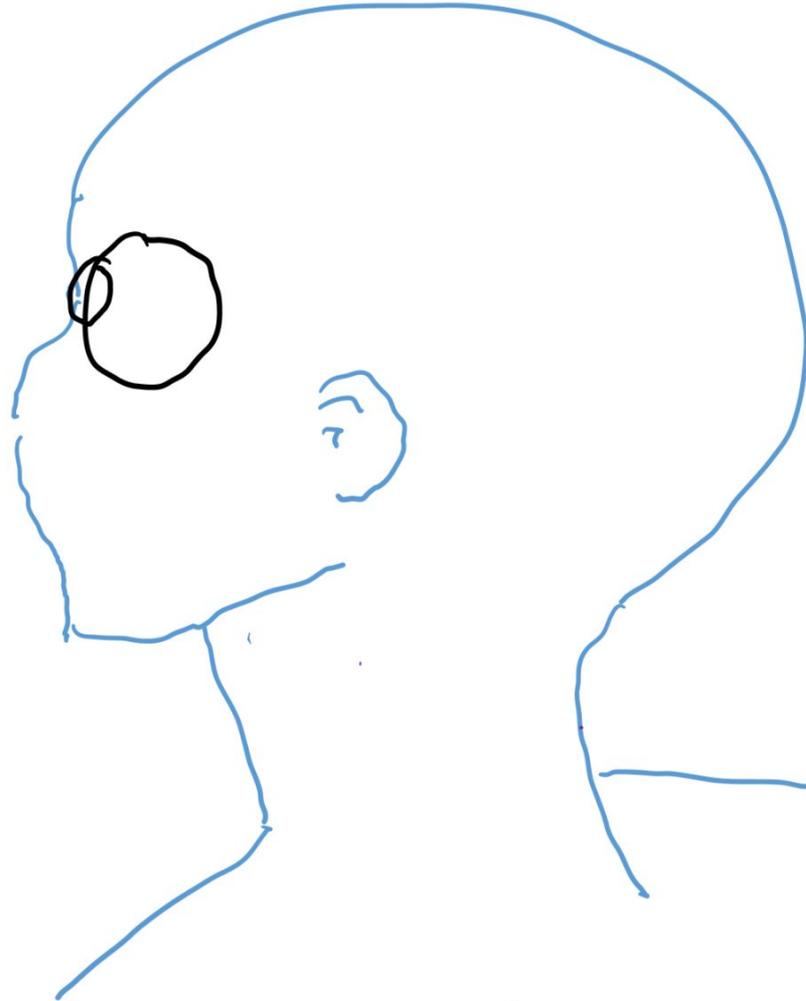
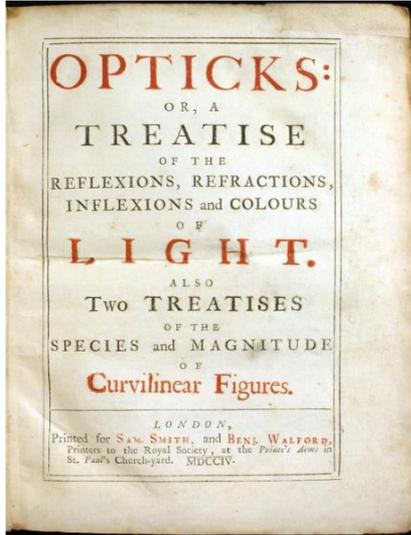
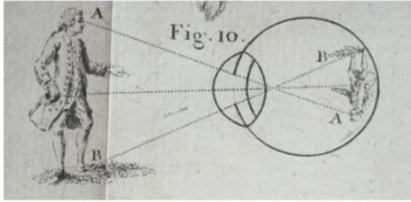
Moderador: J. Malo (UV)

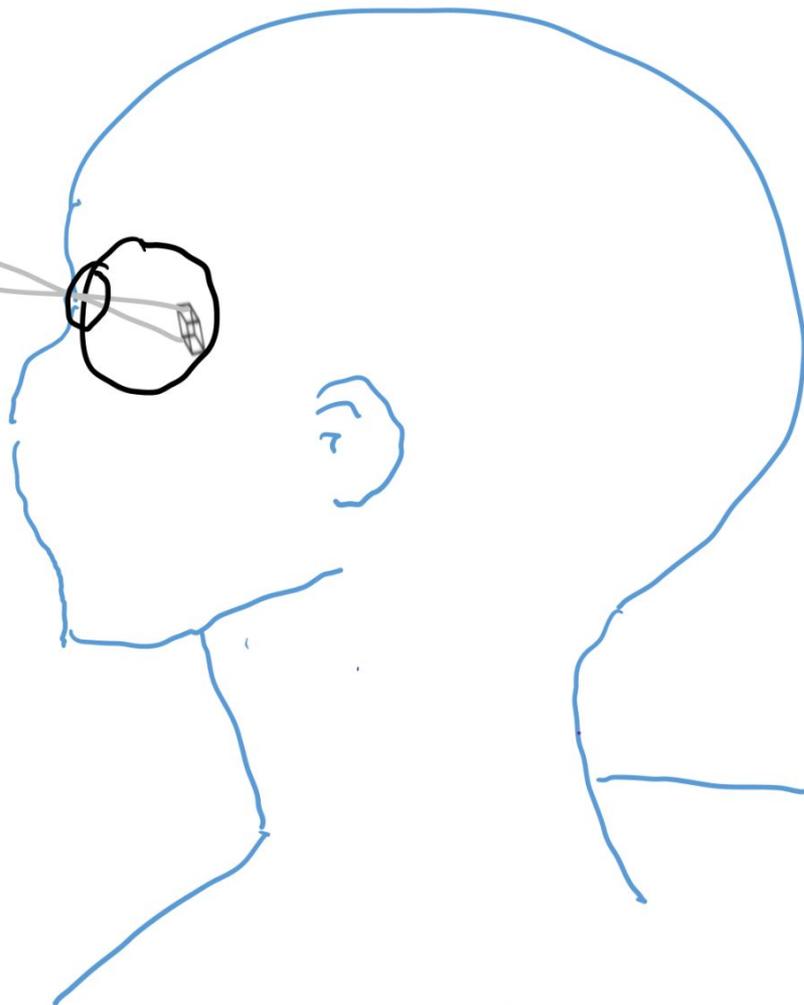
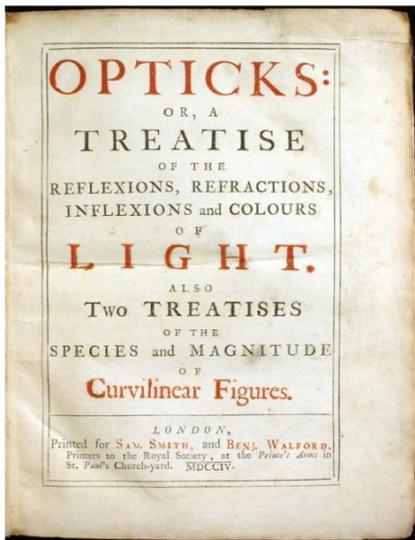
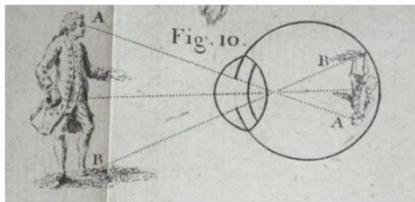
Ponentes: M. Martínez-García (UJI), A. Gómez-Villa (UAB), G. Mateo (UV),
A. Martín (UPF), E. Díaz (UV), V. Laparra (UV)

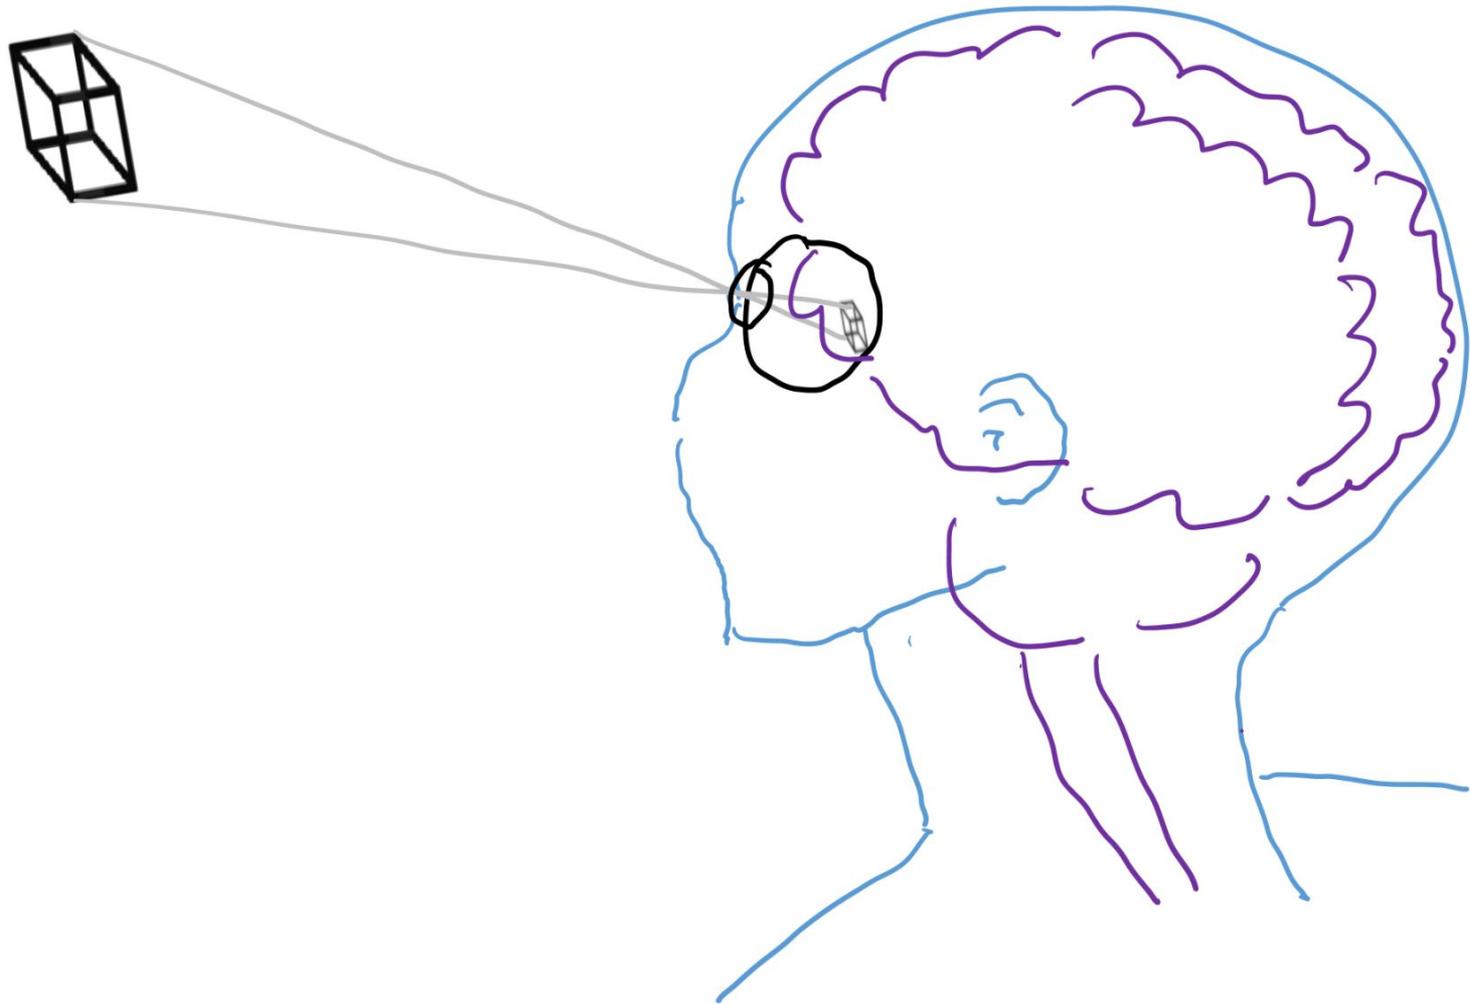
Escola d'Estiu Erasmus de la Facultat de Física (E³f) 2021

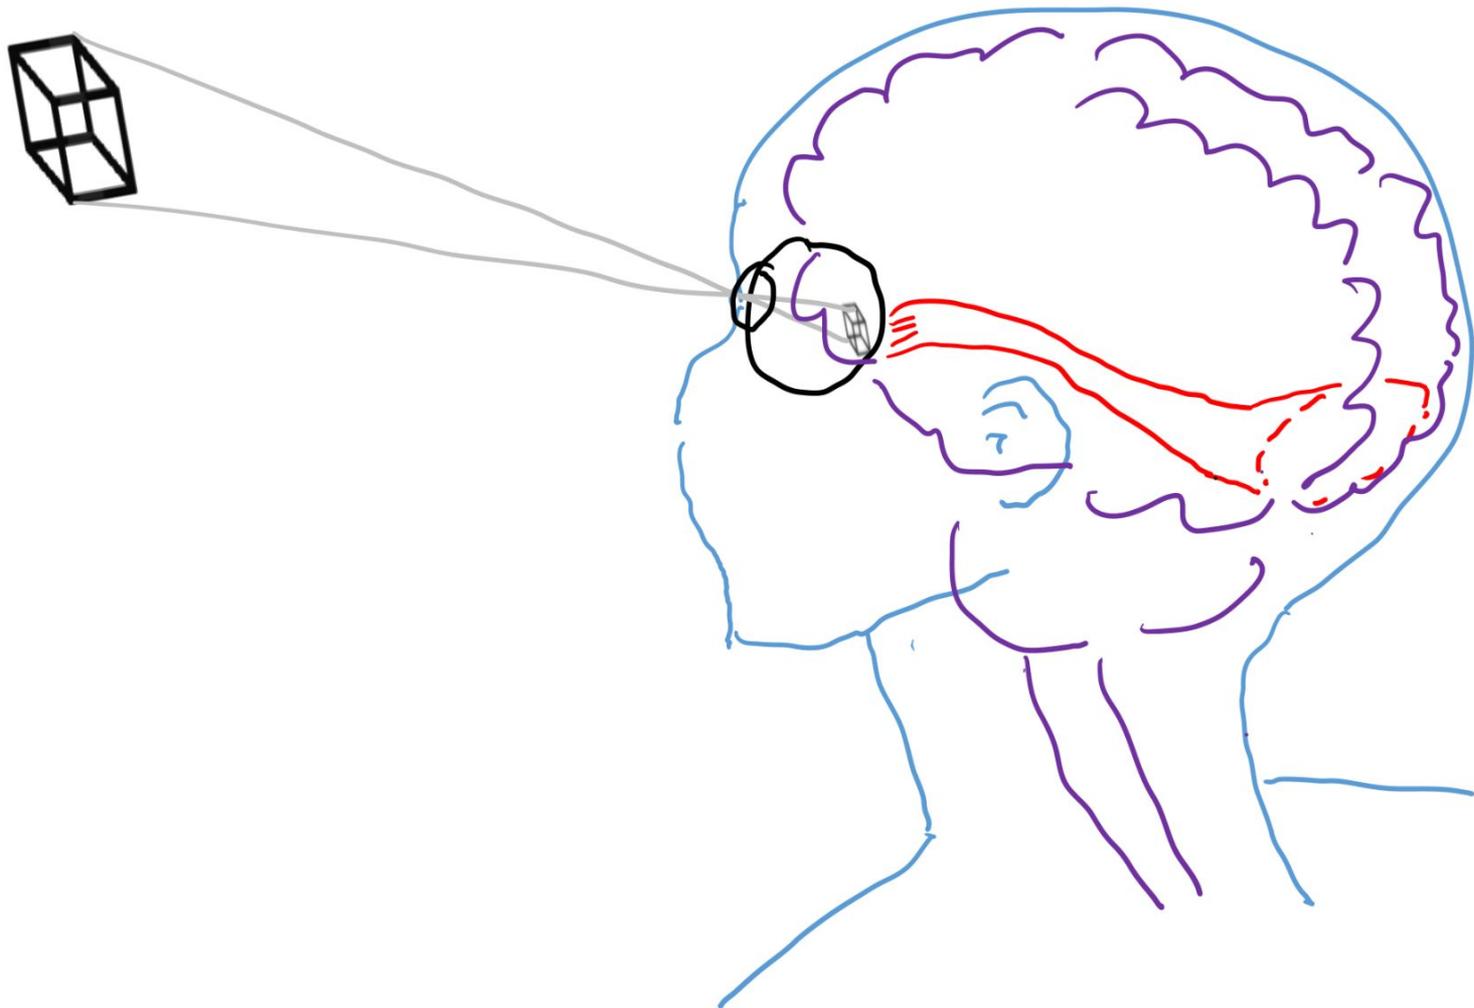


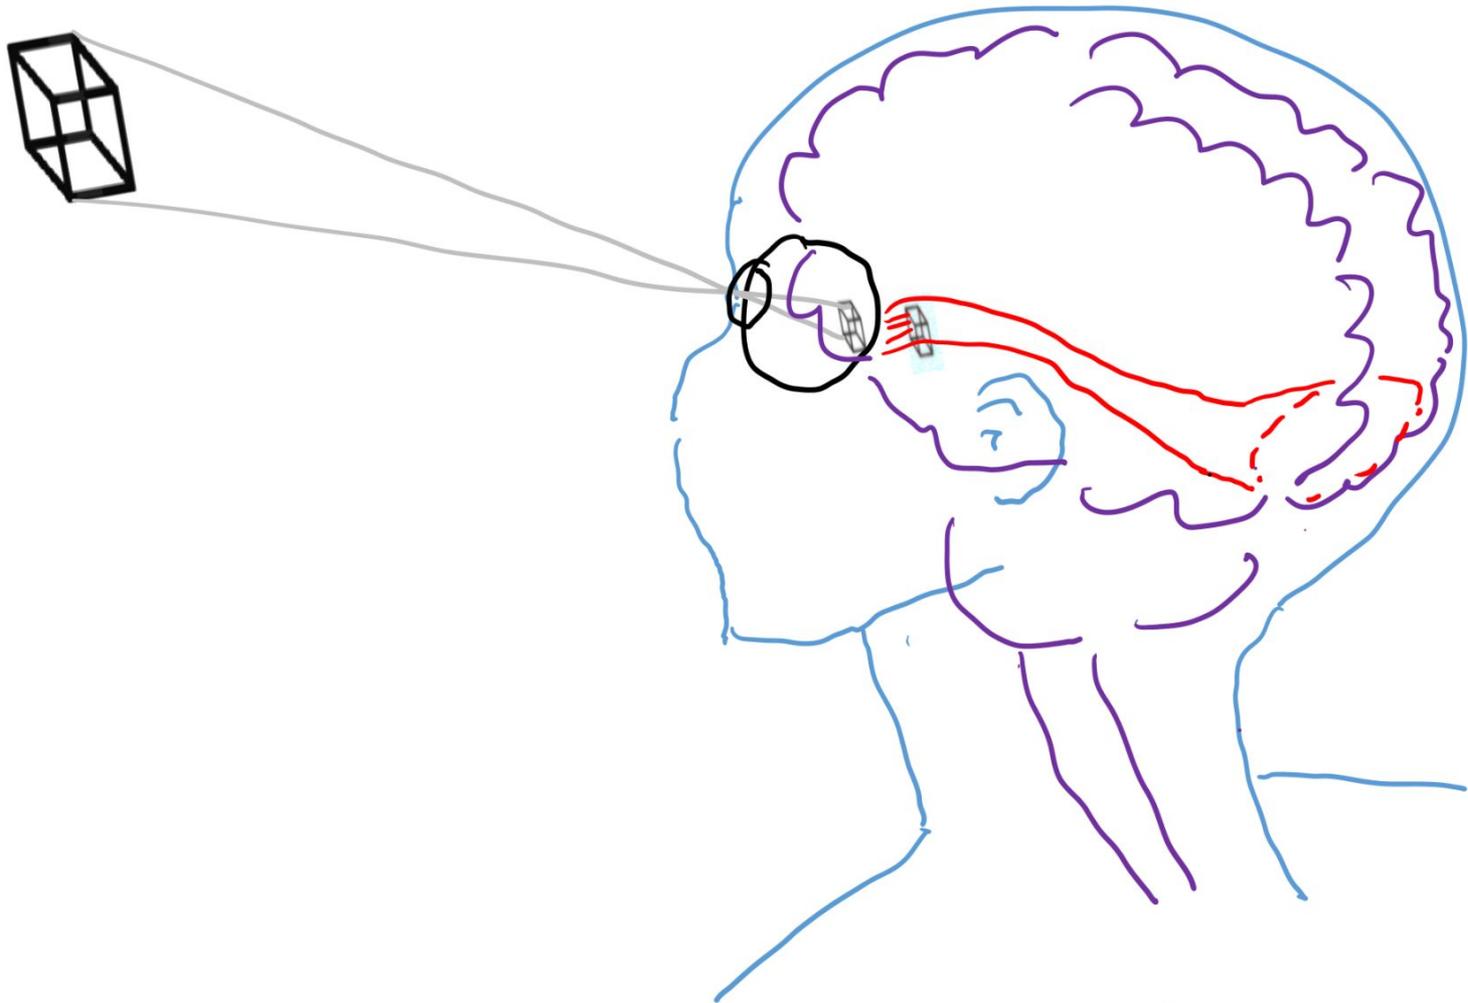


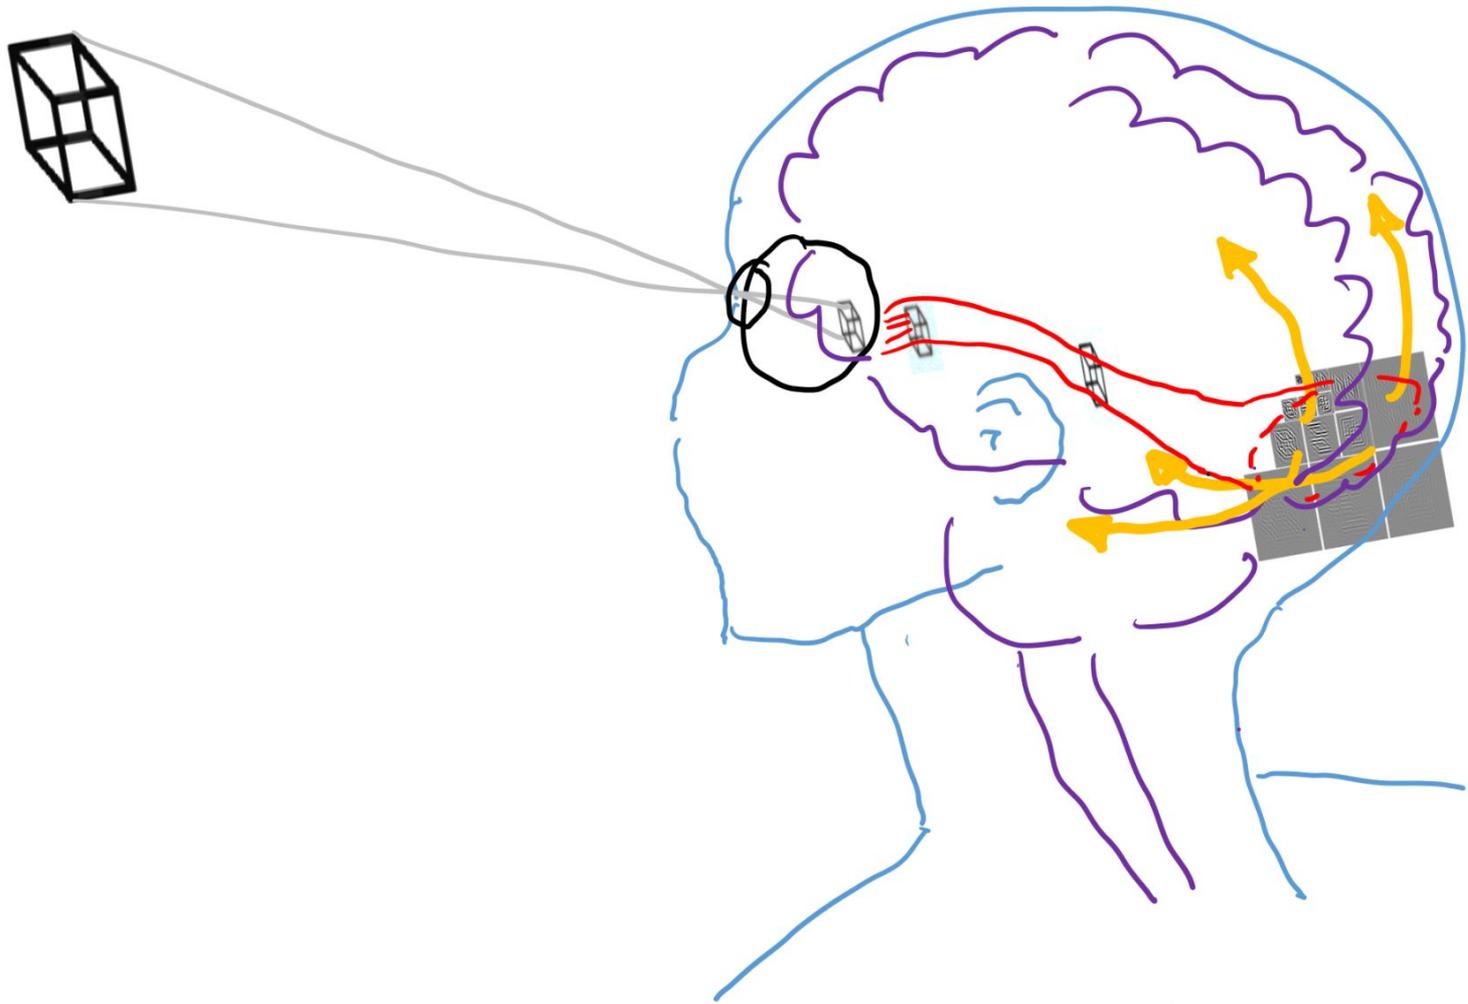


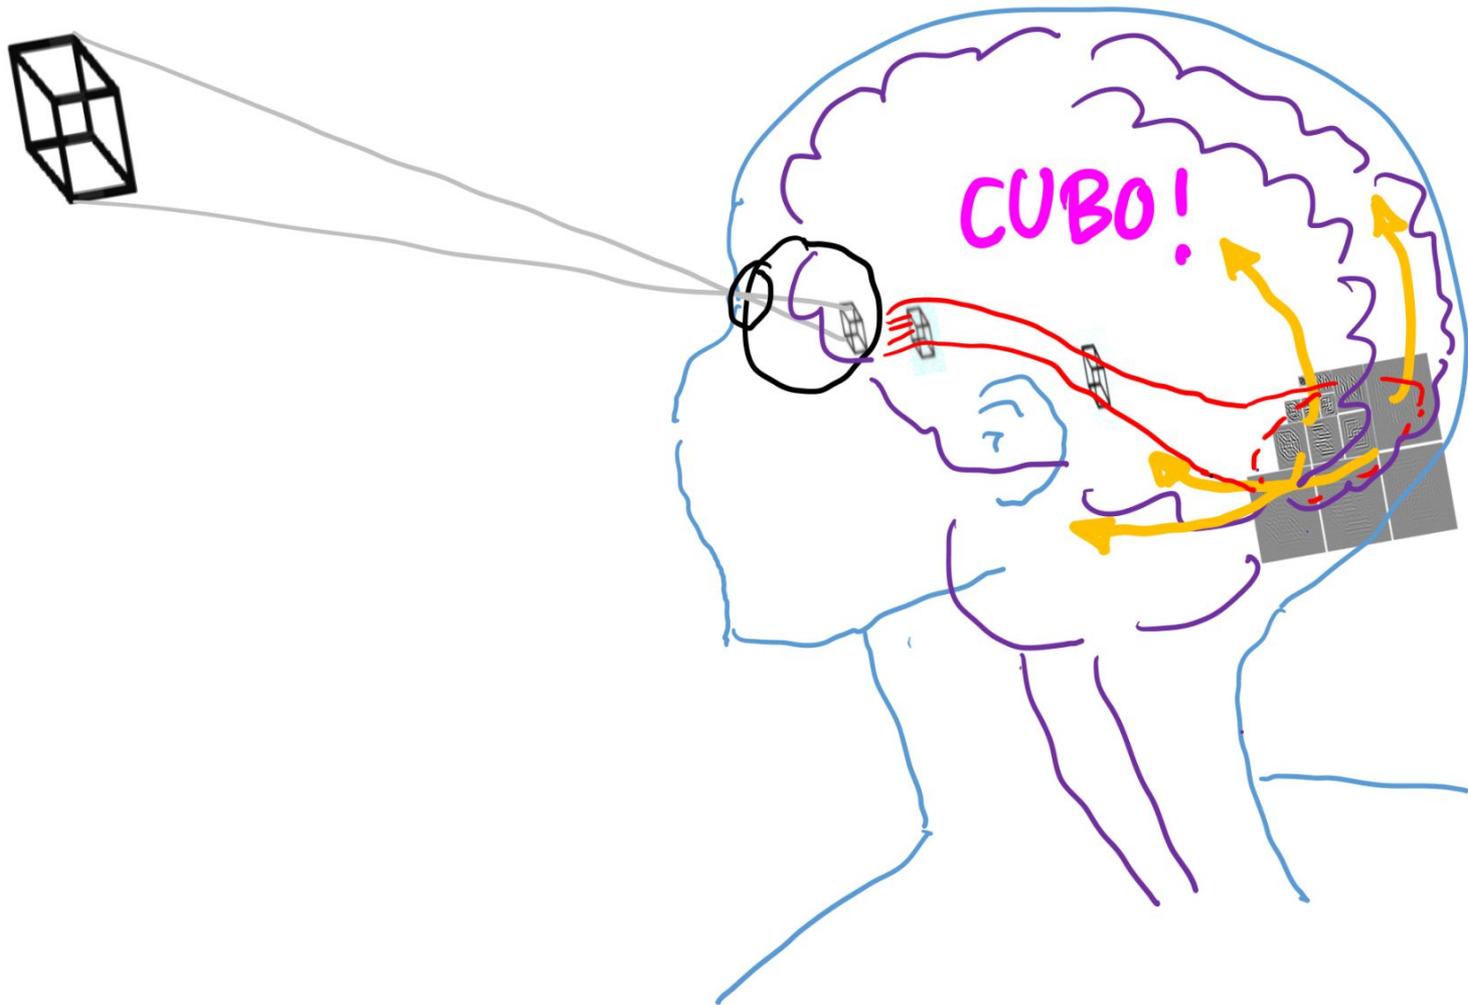








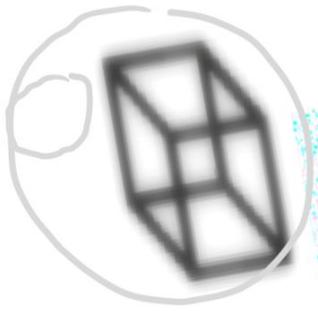
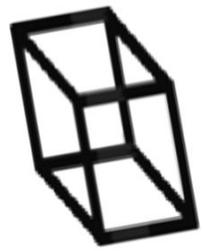




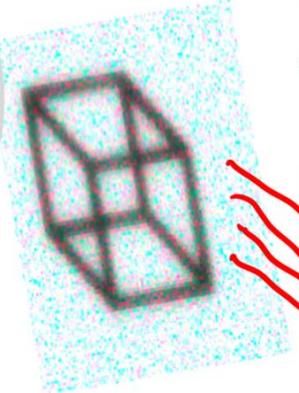
MEDIDA

ANALISIS

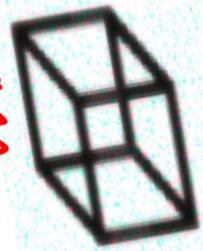
ABSTRACCION Y TEORIA



OJO

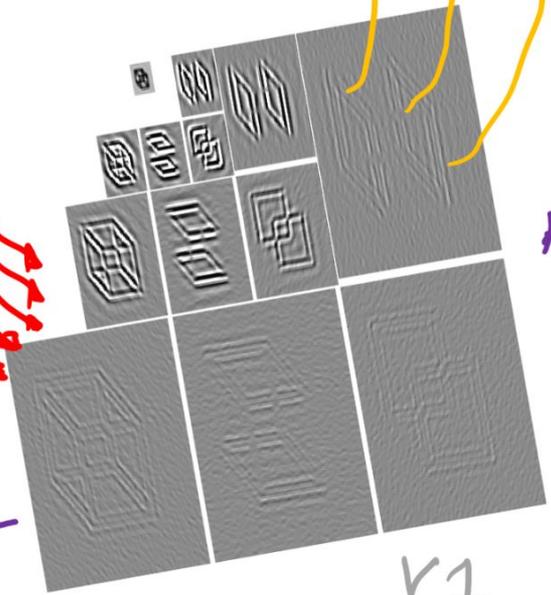


ELIMINA RUIDO
+ EXTRAE
CARACTERIST.



RETINA

LGN



CUBO

IT

V1

- Esteve et al. arxiv 20
- Li et al. arxiv 21
- Martinez et al. PLOS 18
- Martinez et al. Front. Neurosci. 19
- Bertaluccio et al. Sci. Rep. 20

VER = ELABORAR
TEORIA!

- Medidas
- Hipótesis
- Inferencias y decisiones
- Errores en la teoría (ilusiones)

HUM!

PONENTES

* Mariua Martinez-Garcia (UJI) ——— Inteligencia artificial? aprendiendo de la biología

* Alex Gomez-Villa (UAB) ————— Las neuronas artificiales hacen cosas increíbles!

* Gonzalo Mateo (UV) ————— Las neuronas artificiales simulan procesos físicos

* Adriau Martiu (UPF) ————— Errores de percepción en neuronas artificiales

* Emiliano Diaz (UV) ————— Inferencia Causal a partir de datos

* Valero Laparra (UV) ————— IA a debate!

PONENTES

* Mariua Martinez-Garcia (UJI) ———— Inteligencia artificial? aprendiendo de la biología

* Alex Gomez-Villa (UAB) ———— Las neuronas artificiales hacen cosas increíbles!

* Gonzalo Mateo (UV) ———— Las neuronas artificiales simulan procesos físicos

* Adriau Martiu (UPF) ———— Errores de percepción en neuronas artificiales

* Emiliano Diaz (UV) ———— Inferencia Causal a partir de datos

* Valero Laparra (UV) ———— IA a debate!

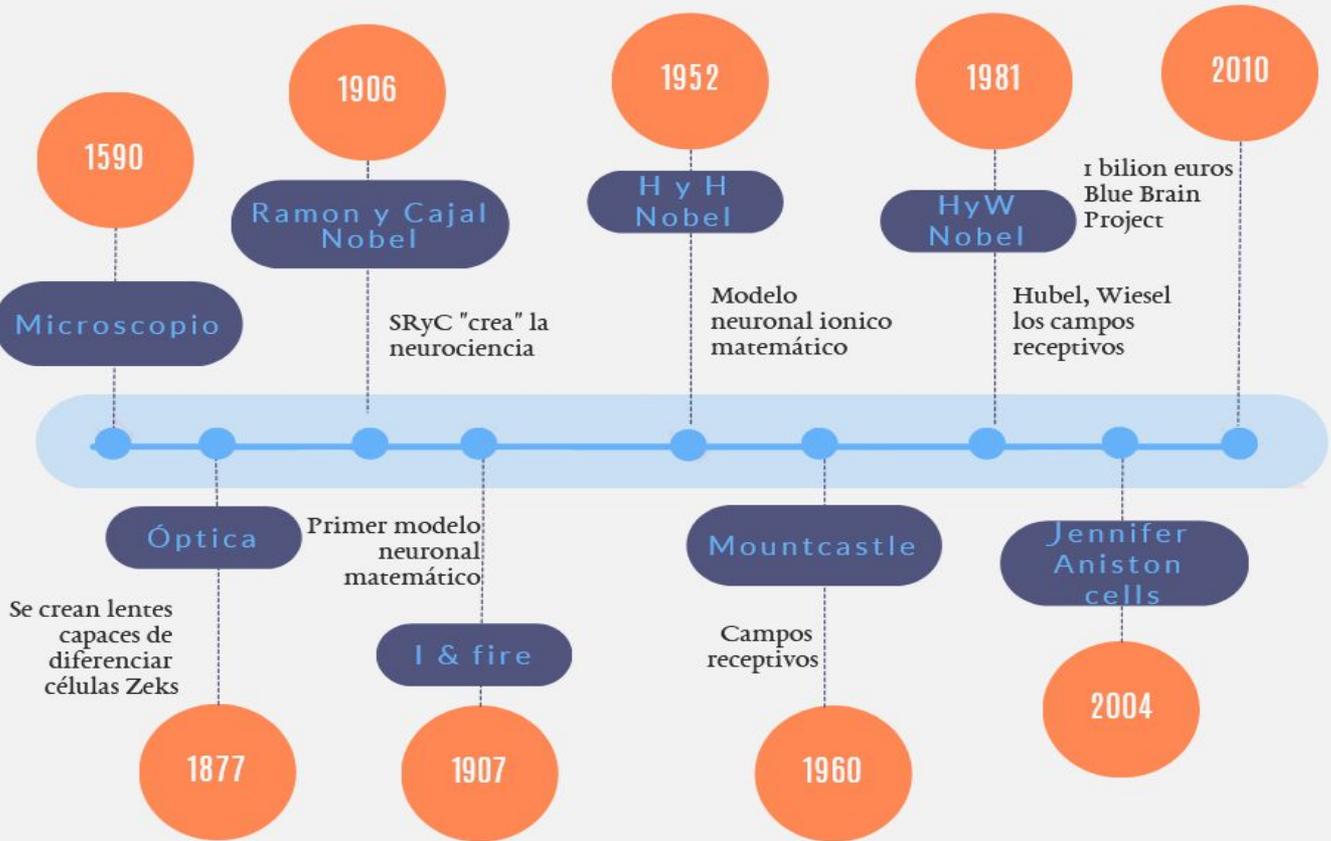
Sistemas Inteligentes

Aprendiendo de la biología

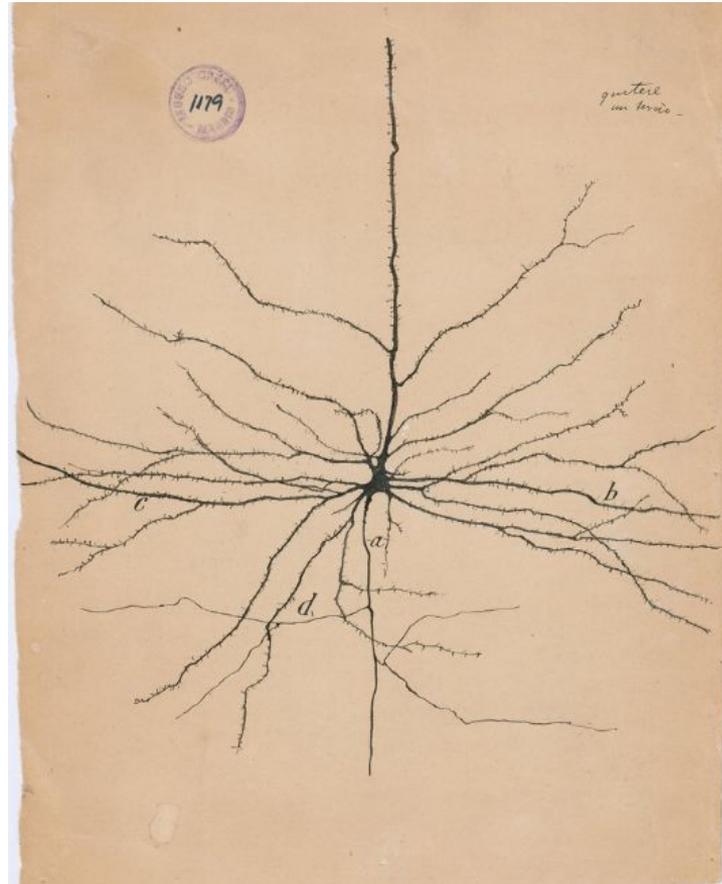
Marina Martínez-García



Neuro Historia



Santiago Ramón y Cajal



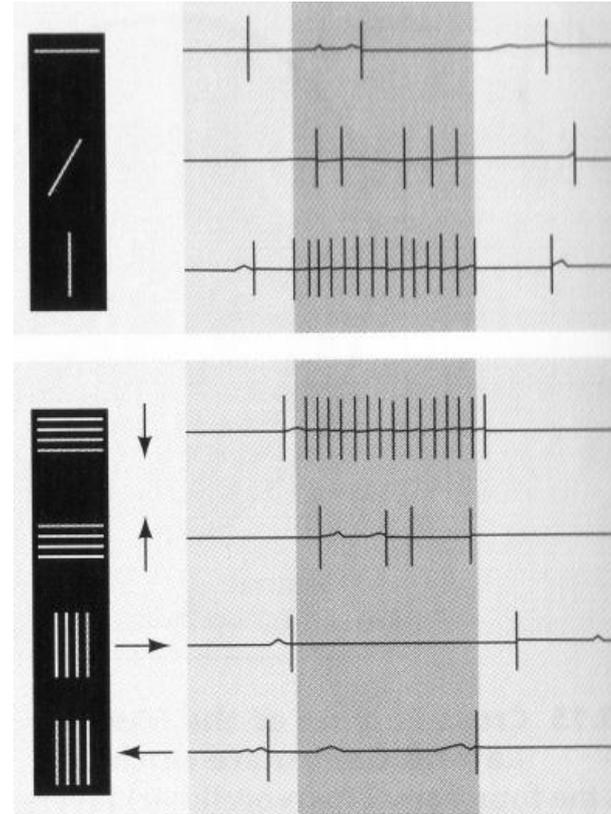
Campo receptivo

De una neurona sensorial es la región particular del espacio sensorial (visual, sonido, superficie del cuerpo ...) en el que un estímulo provoca cambios en la tasa de disparo de la neurona. Se han identificado campos receptivos para las neuronas del sistema auditivo, el sistema somatosensorial, y el sistema visual

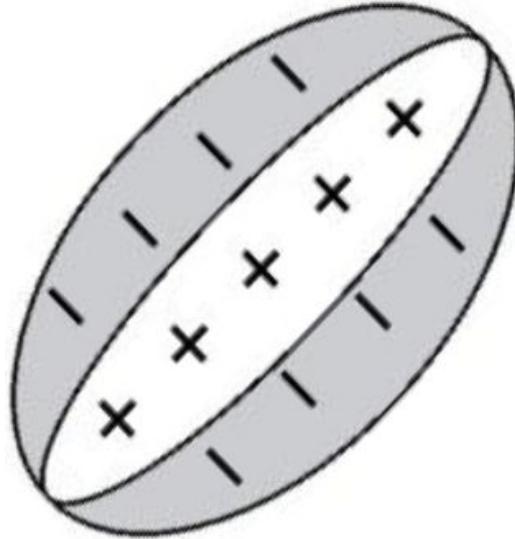


Campo receptivo Visual

En los años 80 Daugman y Marcelja propusieron que los campos receptivos de las células del córtex visual primario (V1) podían ser modelados con un funciones Gabor-2D.



- Localizados en el espacio
- Orientación
- Ancho de banda



**Oriented
receptive field
of a neuron in
primary visual
cortex (V1)**

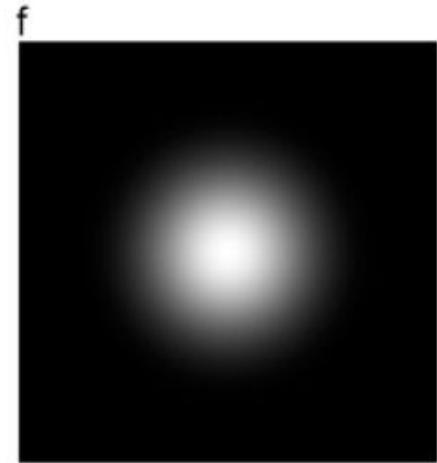
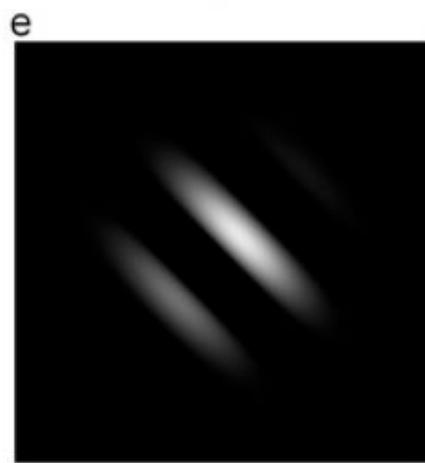
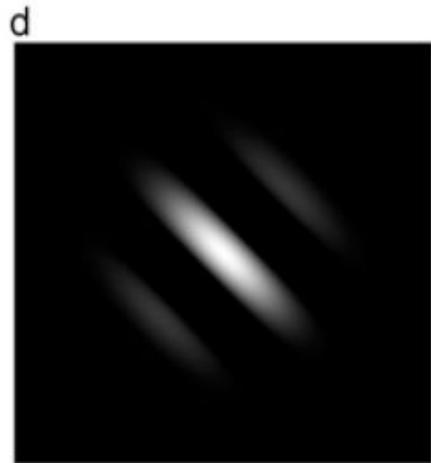
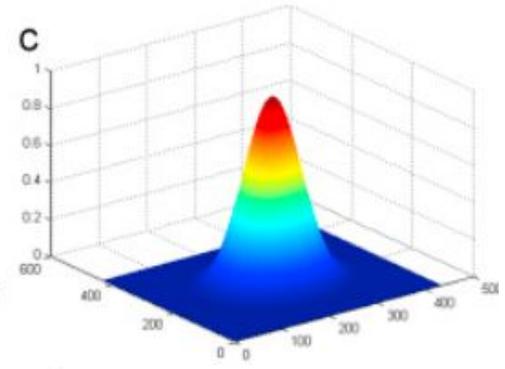
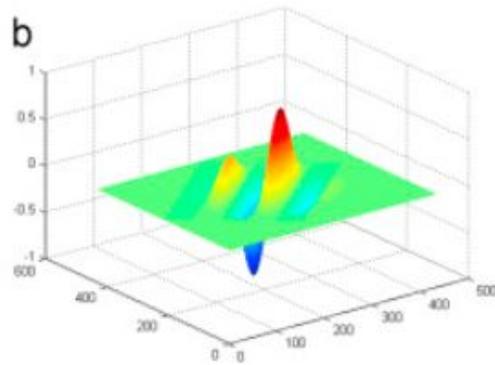
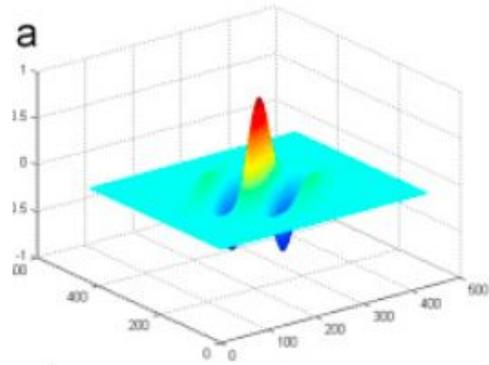
Filtros de Gabor

Siguiendo los pasos de Daugman y Marcelja, para modelar los campos receptivos de las neuronas se usa un coseno y una función gaussiana. Un Gabor es el producto de la dos

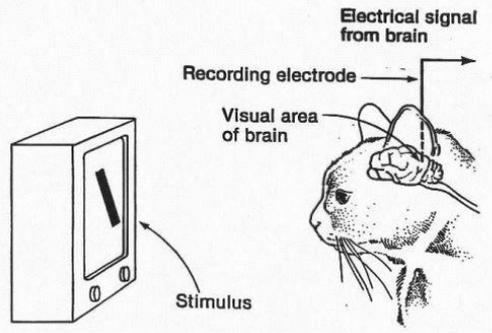
$$Gabor(x, y) = \begin{cases} \text{cosinus}(\lambda, \varphi) & \cos\left(2\pi\frac{x}{\lambda} + \varphi\right) \\ \text{gaussiana}(\gamma, \sigma) & \exp\left(-\frac{x^2 + \gamma^2 y^2}{2\sigma^2}\right) \end{cases}$$

Resulta una función que depende de las siguientes variables
 $(x, y, \lambda, \varphi, \gamma, \sigma)$.

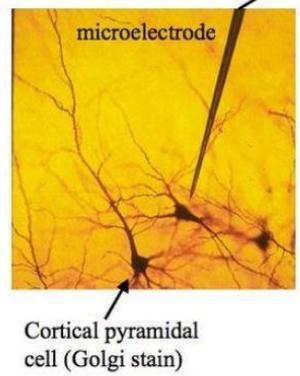
Filtros de Gabor



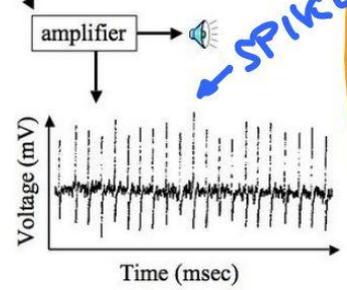
RESPUESTA (DE UNA NEURONA)



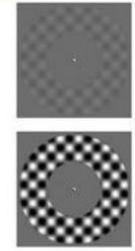
Single-cell electrophysiology



Microscope pictures neuron with microelectrode

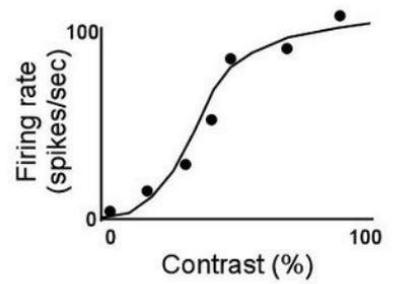
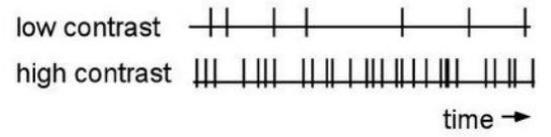


← SPIKES

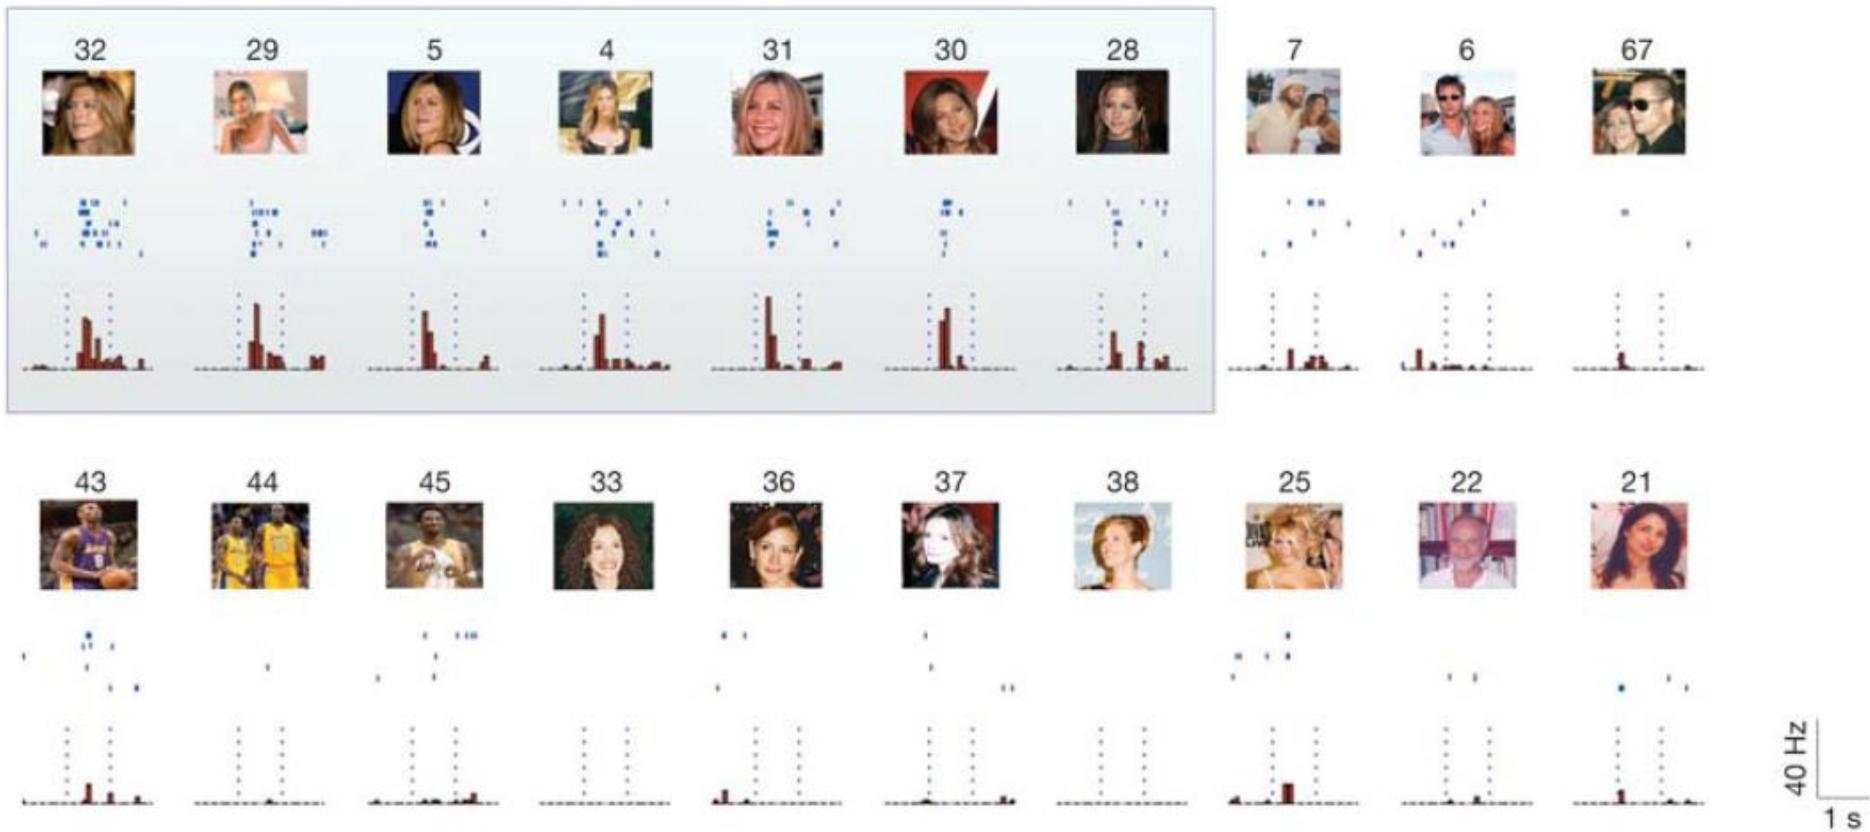


TASA

Firing rate: visual responses



Experimentos Hubel y Wiesel



Invariant visual representation by single neurons in the human brain. Q.Quiroga et al Nat 200

Redes biológicas

Neurociencia

**Redes artificiales
biológicas**

Modelo físico

Redes artificiales

Estadística

**Campos
receptivos V1**

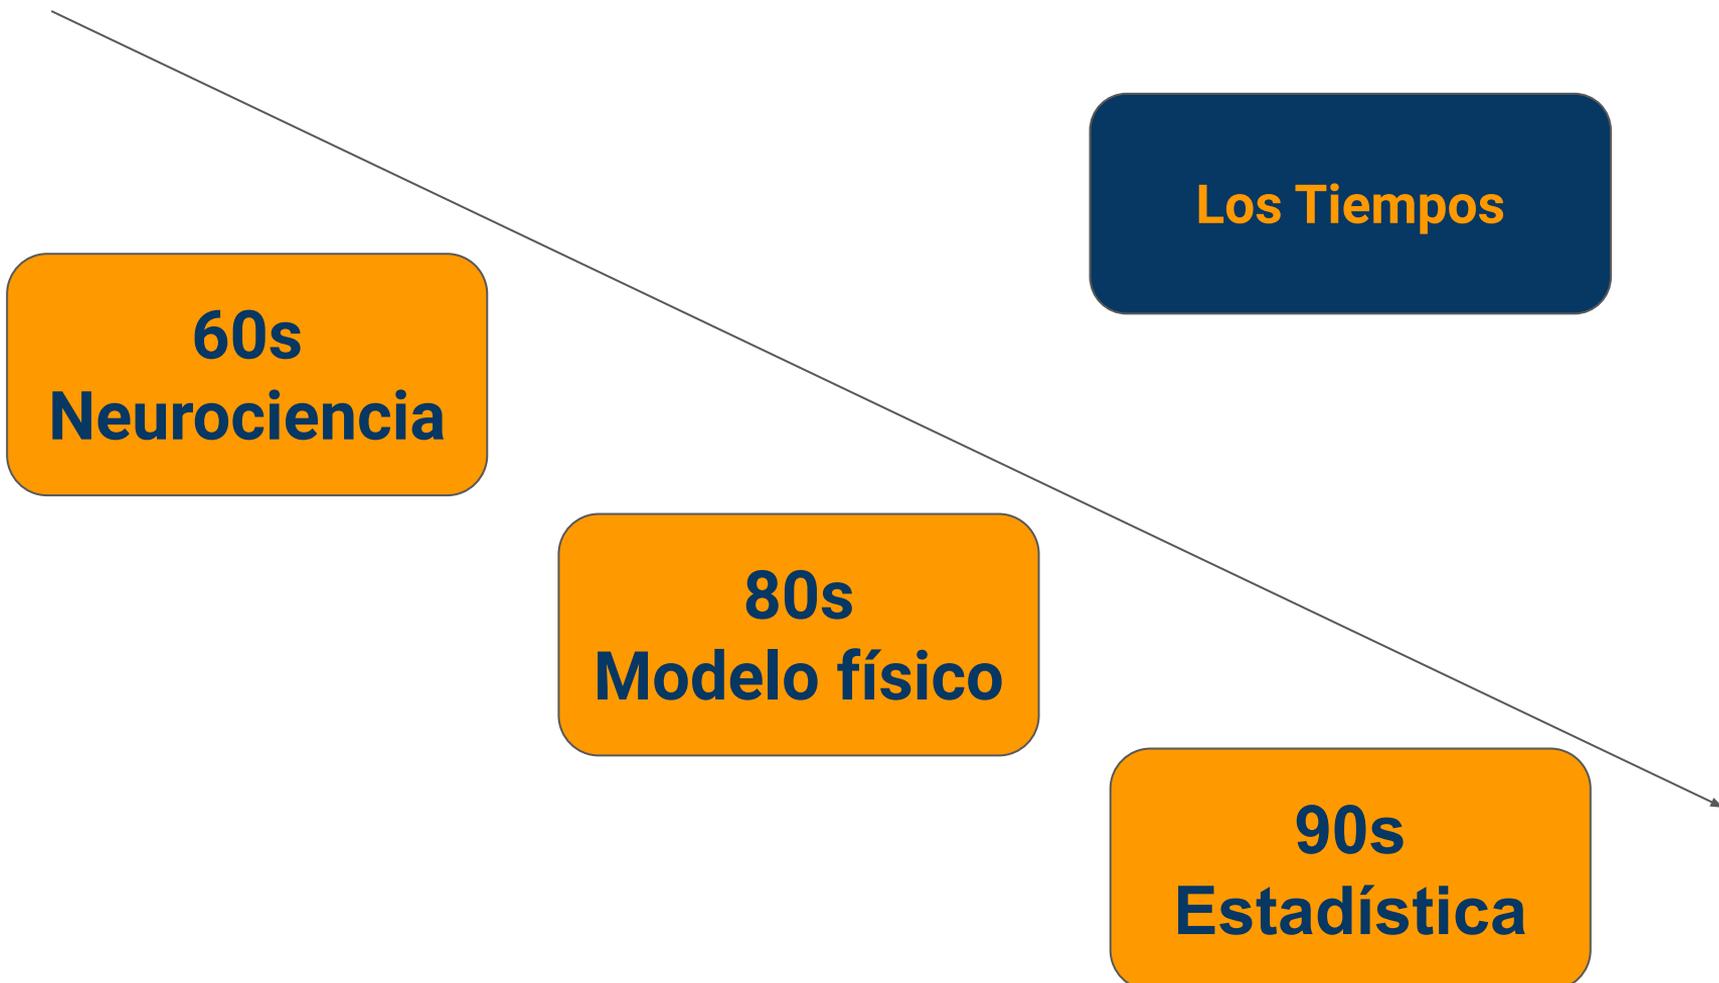
Neurociencia

Filtros Gabor

Modelo físico

CNN

Estadística



Los Tiempos

60s
Neurociencia

80s
Modelo físico

90s
Estadística

PONENTES

* Mariua Martinez-Garcia (UJI) ——— Inteligencia artificial? aprendiendo de la biología

* Alex Gomez-Villa (UAB) ————— Las neuronas artificiales hacen cosas increíbles!

* Gonzalo Mateo (UV) ————— Las neuronas artificiales simulan procesos físicos

* Adriau Martiu (UPF) ————— Errores de percepción en neuronas artificiales

* Emiliano Diaz (UV) ————— Inferencia Causal a partir de datos

* Valero Laparra (UV) ————— IA a debate!

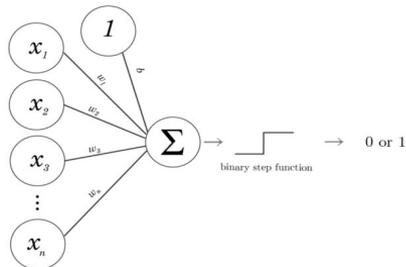
Con las neuronas artificiales se hacen cosas increíbles!

Alex Gomez-Villa



Perceptrón, clasificadores y feature engineering

McCulloch-Pitts Neuron (1943)

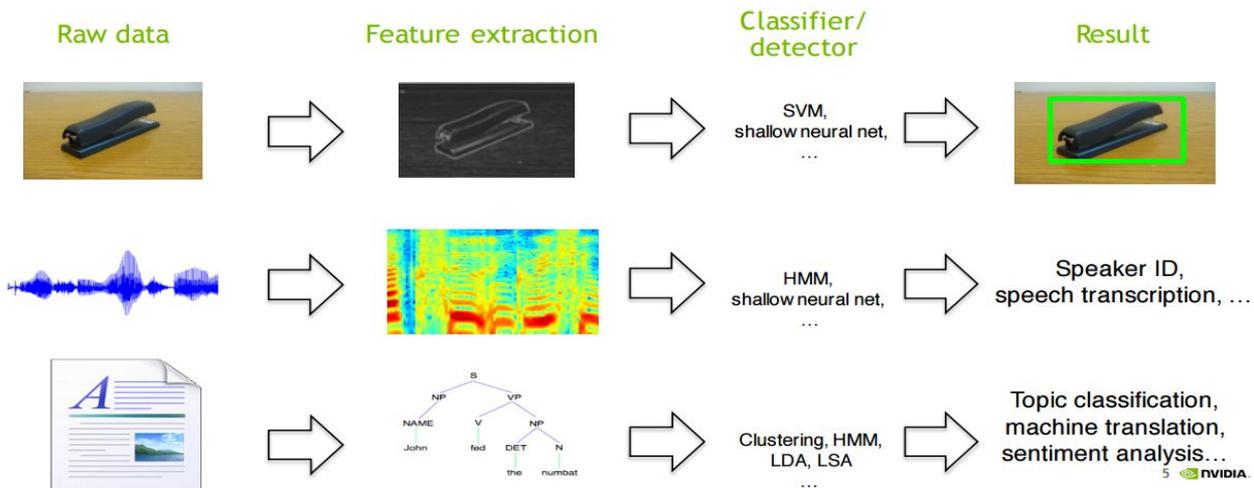


McCulloch, W.S. and Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), pp.115-133.



- **Perceptron**
- **MLP**
- Support vector machine
- Random forest
- Nearest neighbor
- Markov chains
- Gaussian Mixture
-

Reconocimiento de patrones desde finales de los años 50:

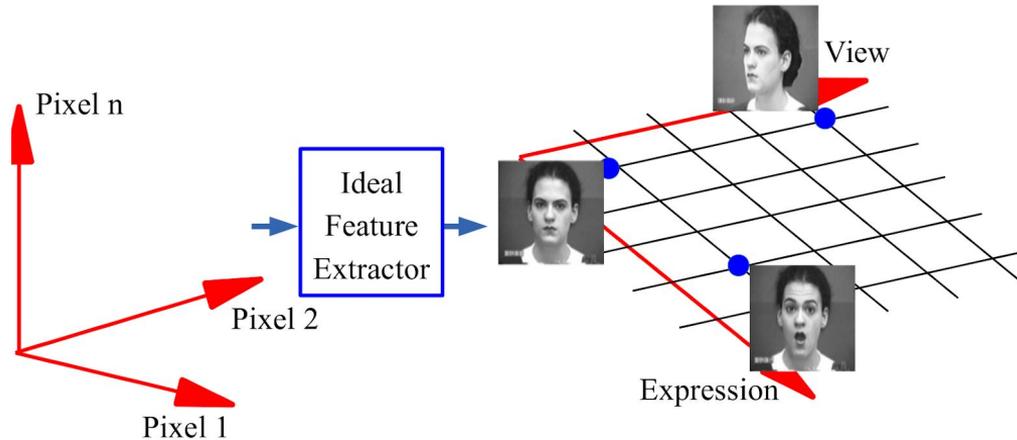


<http://on-demand.gputechconf.com/gtc/2015/webinar/deep-learning-course/intro-to-deep-learning.pdf>

¿Que es una buena representación?

Ejemplo: Todas las imágenes del rostro de una persona

- 1000 x 1000 píxeles = 1'000.000 de datos de entrada por muestra
- 3 ángulos de desplazamiento
- 3 ángulos de rotación
- Una persona posee 50 músculos en su rostro(expresiones)



Extractor de características entrenable



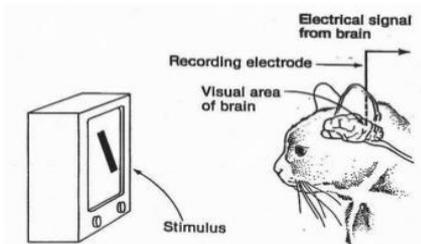
Clasificador entrenable



Babuino

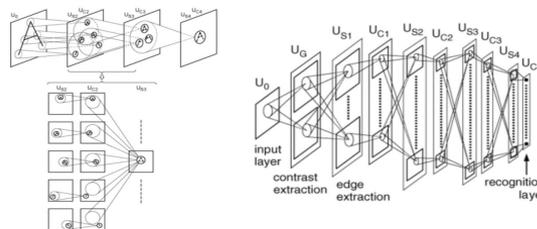
Gatos, códigos postales y End-to-end/Feature/Deep learning

Experimentos de Hubel y Weisel(1959)



Hubel, D.H. and Wiesel, T.N., **1959**. Receptive fields of single neurones in the cat's striate cortex. *The Journal of physiology*, 148(3), pp.574-591.

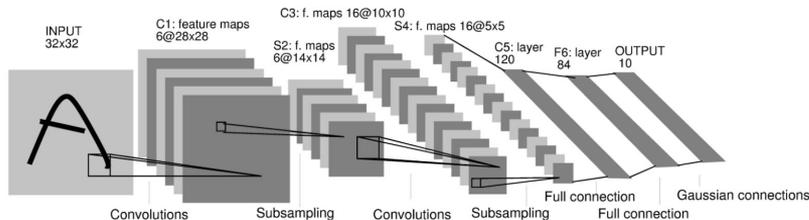
Neocognitron(1980)



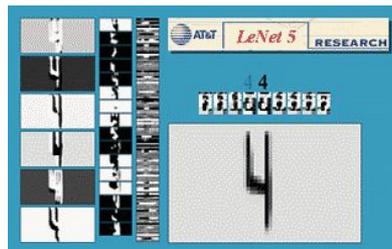
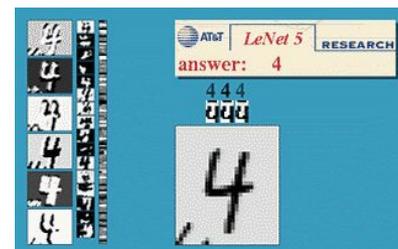
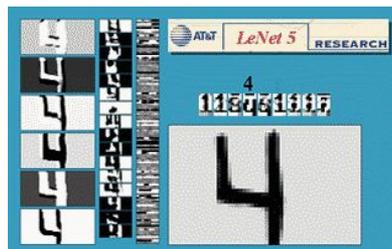
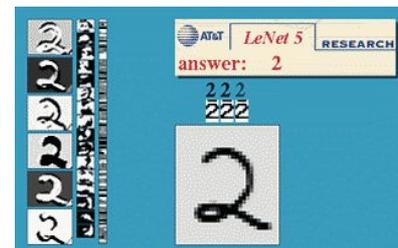
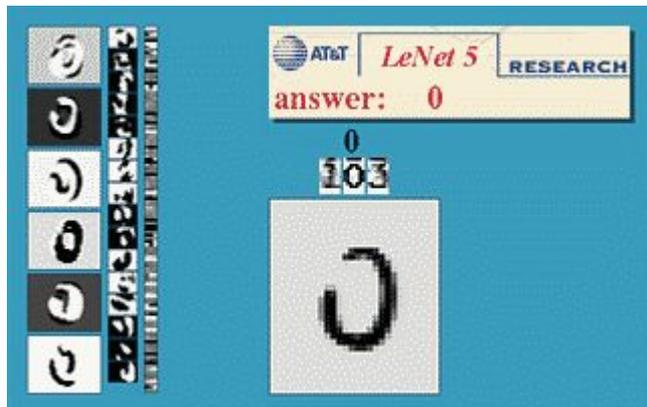
Fukushima, K., **1980**. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological cybernetics*, 36(4), pp.193-202.

“Primera” CNN: LeNet-5(1998)

LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P., **1998**. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), pp.2278-2324.



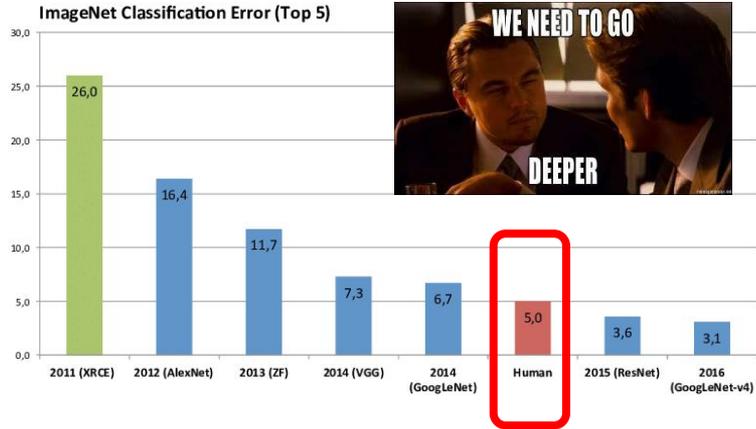
Primera CNN: LeNet 5 (1998)



¿Donde estamos ahora?

Clasificación

1000 clases, 1.2 millones de imágenes de entrenamiento

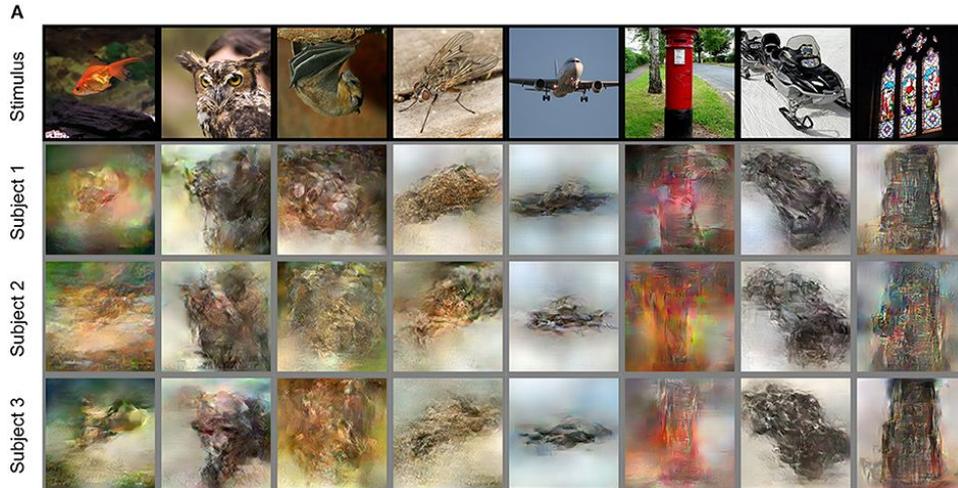


Coches autónomos



¿Donde estamos ahora?

Image Reconstruction From Human Brain Activity



<https://www.frontiersin.org/articles/10.3389/fncom.2019.00021/full>

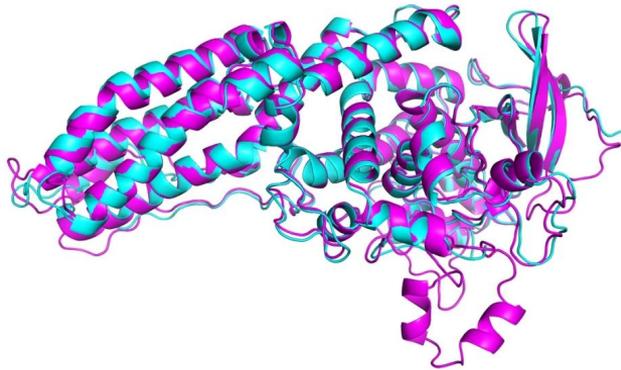
Generación de contenido



Karras, T., Laine, S. and Aila, T., 2019. A style-based generator architecture for generative adversarial networks. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 4401-4410).

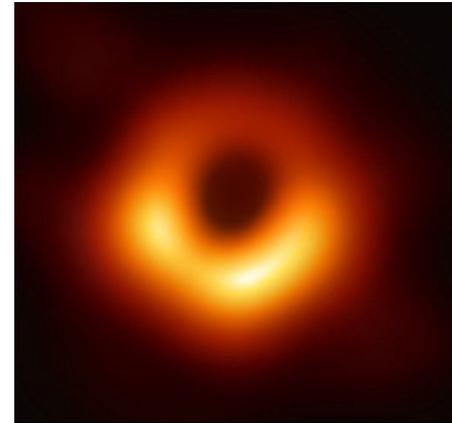
¿Donde estamos ahora?

Protein-Folding



https://www.technologyreview.com/2020/11/30/1012712/deepmind-protein-folding-ai-solved-biology-science-drugs-disease/?utm_medium=tr_social&utm_campaign=site_visitor.unpaid.engagement&utm_source=Facebook&fbclid=IwAR24XO402CuRPdCn_ejbbtkbDt2NOuYmGdBR9zhc9OmN_XrJW-SAMXIOsA#Echobox=1624655848-1

Astrophysics



Castelvecchi, D., 2019. Black hole pictured for first time in spectacular detail. *Nature*, 568(7752), pp.284-285.

No, la AI probablemente no va a destruir la humanidad, pero...

Deep fakes



[A crisis over a suspicious confession video in Myanmar underscores why we need a coordinated response to discern fact from fiction](#)

William Shakespeare 5

Transformer AI poetry: Poetry classics as reimaged and rewritten by an artificial intelligence.
"Sonnet 18"
William Shakespeare
Shall I compare thee to a summer's day?
Thou art more lovely and more temperate:
Rough winds do shake the darling buds of May,
And summer's lease hath all too short a date;
A winter's day, when beams of sun are few,
And skies are grey with clouds interperate,
Is to thy beauty somehow sordid grown.
Her lovely-levely eye is quite shut up,
Like windows pale before a sunny shower,
The earth that's cold and moist, like to my mistress,
When once that she unbrac'd, her lovely jewel,
Grows as both ugly and uncourtly.
Poor soul, the center of my motley host,
See, how they request thy sovereign presence;
The din of merry hearts hath brought me thus
To greet thee, thou unsoild and saint-like beauty.

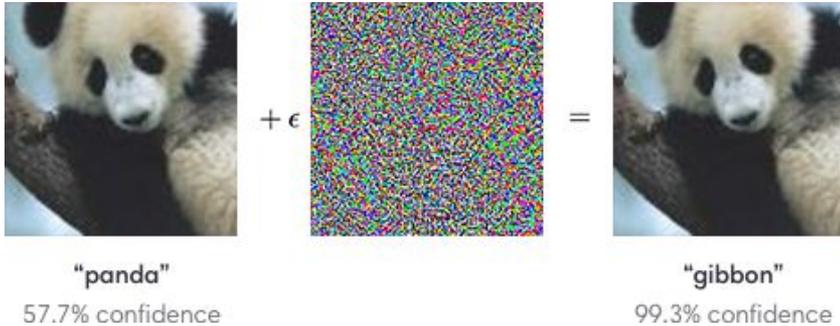
GTP-3: un modelo de NLP demasiado peligroso para liberarse



Vigilancia masiva

No todo son cosas buenas...

La amenaza de los ataques adversarios



- ¡Las redes neuronales artificiales son cajas negras! (interpretabilidad, causalidad).
- Los mejores modelos (supervisados) necesitan una cantidad absurda de datos para poder entrenarse.
- Las redes neuronales artificiales no funcionan igual que las redes neuronales artificiales.



¿Acaso un sistema artificial no puede ser mejor en una tarea que un sistema biológico?

¡El futuro no es oscuro!

The Next AI Revolution



From Yann LeCun's Slides

- Las investigaciones en Self-supervised learning han permitido reducir la cantidad de etiquetas necesarias (clasificación) al 1% del original.
- Grandes centros de investigación trabajan en el problema de los ataques adversarios, existen muchas estrategias y teorías de porque aparecen.
- Aún falta en interpretabilidad y causalidad pero a largo de la historia el uso ha precedido al entendimiento en muchas aplicaciones (aviones).
¡Necesitamos que más mentes se pongan a la tarea de darle formalidad al campo!

¡Gracias!



PONENTES

* Mariua Martinez-Garcia (UJI) ——— Inteligencia artificial? aprendiendo de la biología

* Alex Gomez-Villa (UAB) ——— Las neuronas artificiales hacen cosas increíbles!

* Gonzalo Mateo (UV) ——— Las neuronas artificiales simulan procesos físicos

* Adriau Martiu (UPF) ——— Errores de percepción en neuronas artificiales

* Emiliano Diaz (UV) ——— Inferencia Causal a partir de datos

* Valero Laparra (UV) ——— IA a debate!



VNIVERSITAT
D VALÈNCIA

Redes Neuronales Artificiales para la modelización de procesos físicos

III Escola Erasmus d'Estiu de Física

Gonzalo Mateo García

<https://www.uv.es/gonmagar/>

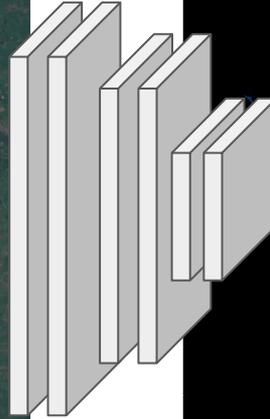


FRONTIER
DEVELOPMENT
LAB



Segmentación de Inundaciones

Sentinel-2



¿Hacen falta redes neuronales para detectar inundaciones en imágenes de satélite si sabemos física?

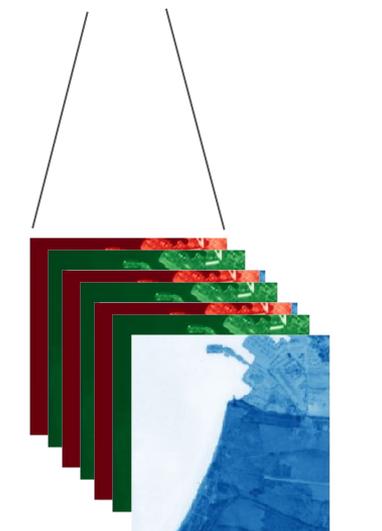
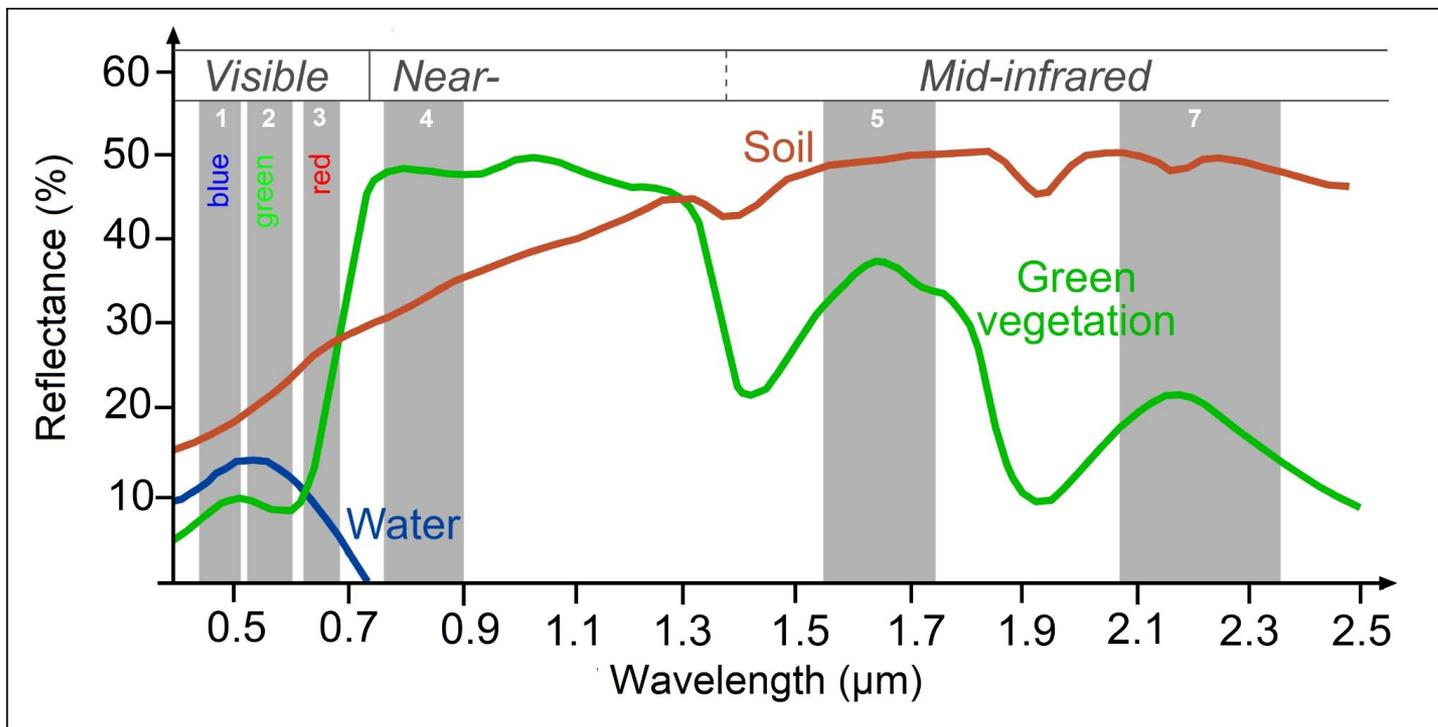
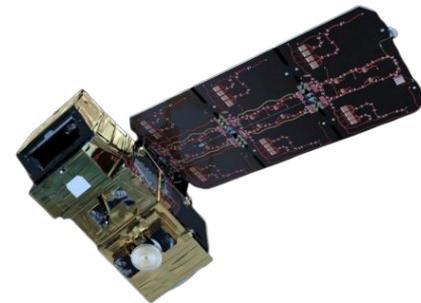
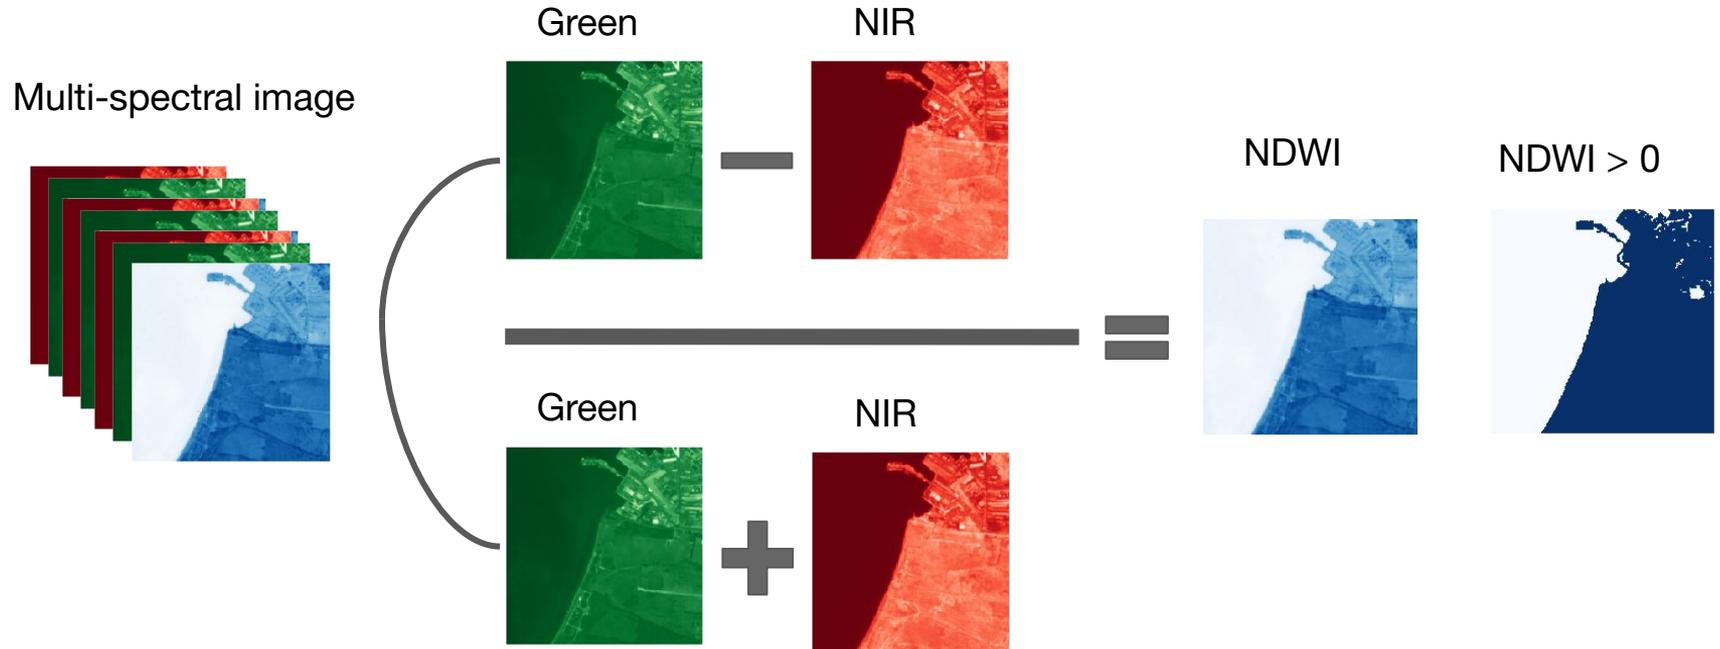
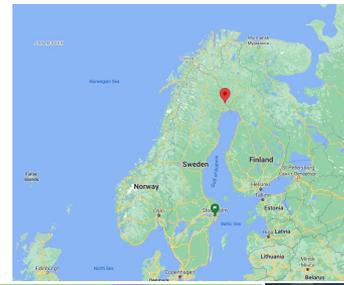


Imagen multispectral

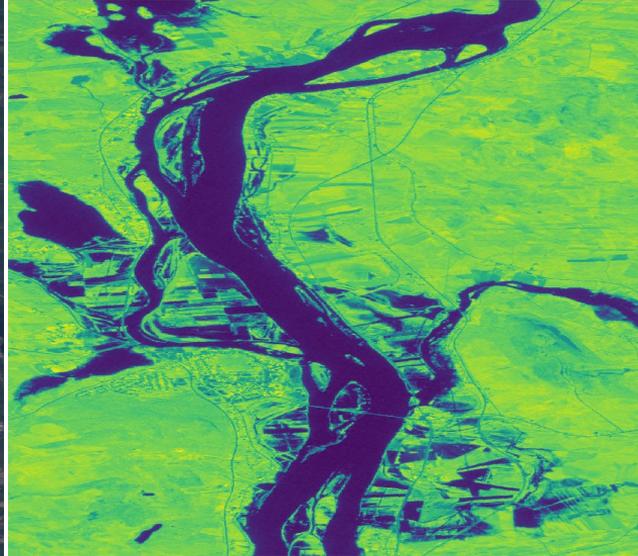
Normalised Difference Water Index (NDWI)



Río Torne, Sweden – Finland border, May 2018



Sentinel 2 RGB



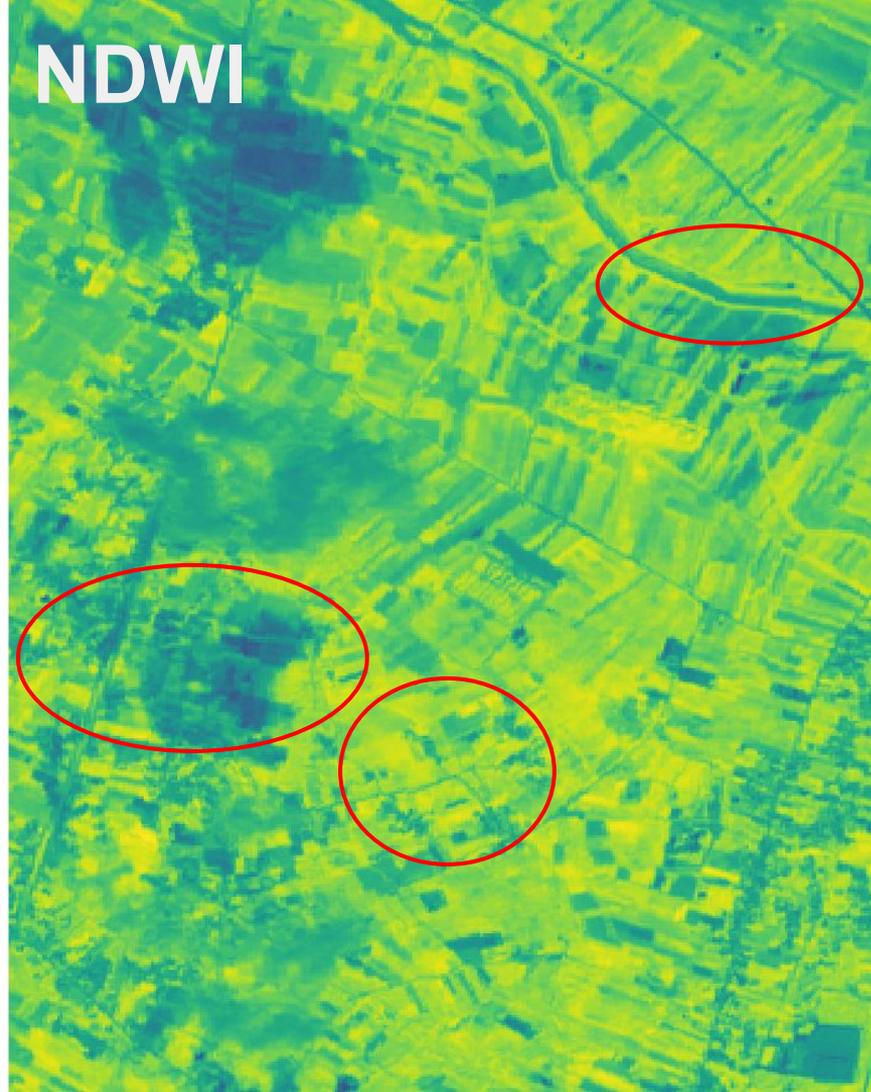
NDWI



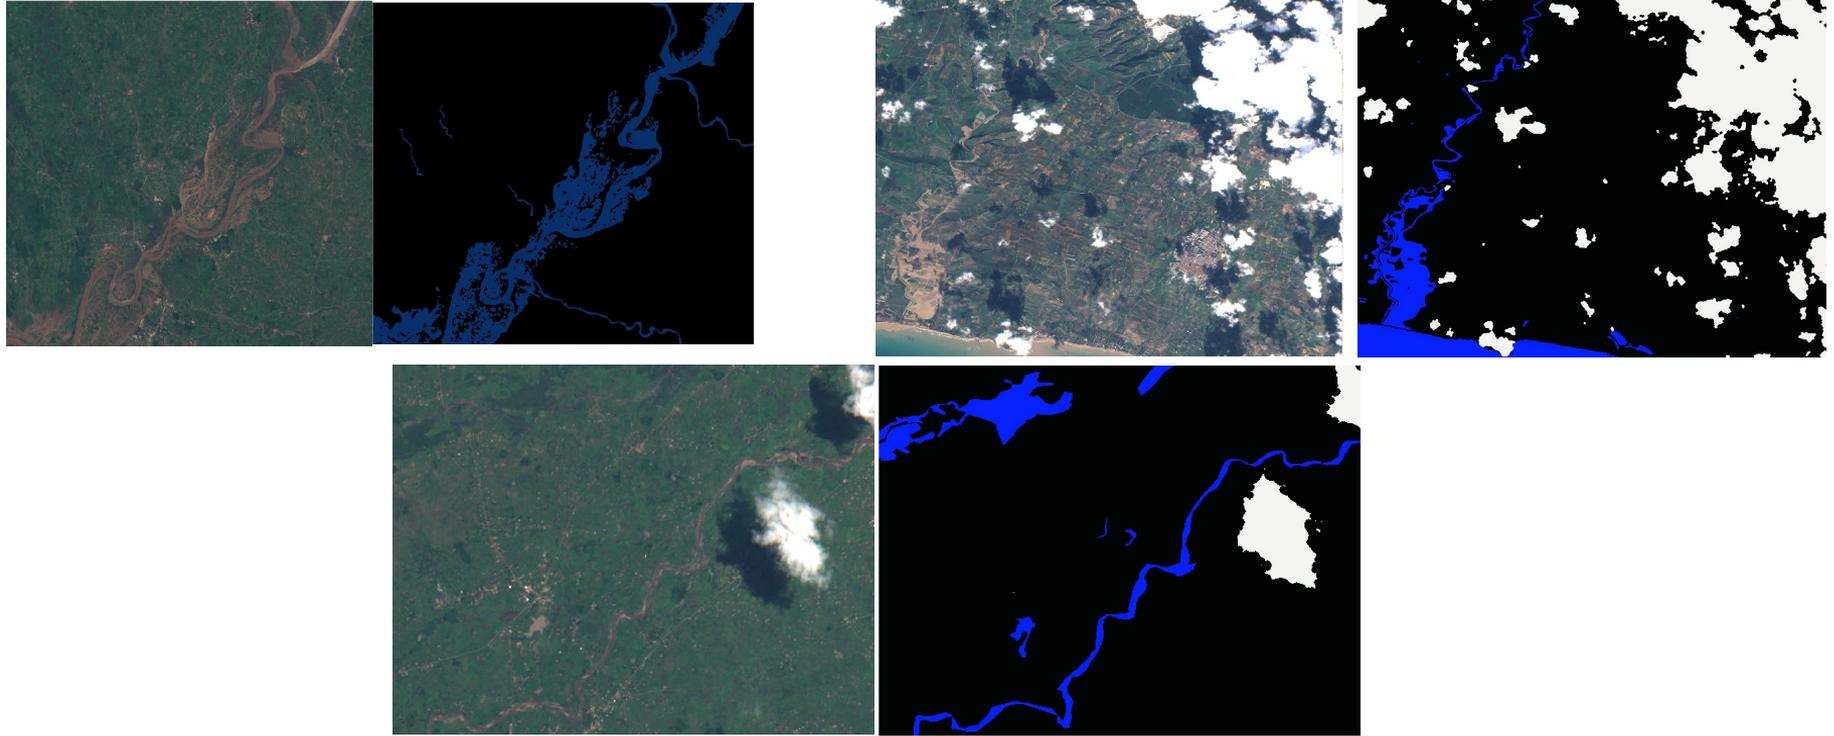
Ground truth



NDWI



¿Cómo *aprendemos* a segmentar imágenes?



A partir de una base de datos de imágenes y máscaras etiquetadas manualmente

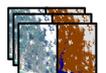
WorldFloods Dataset



119 floods



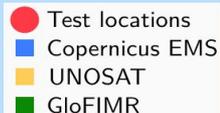
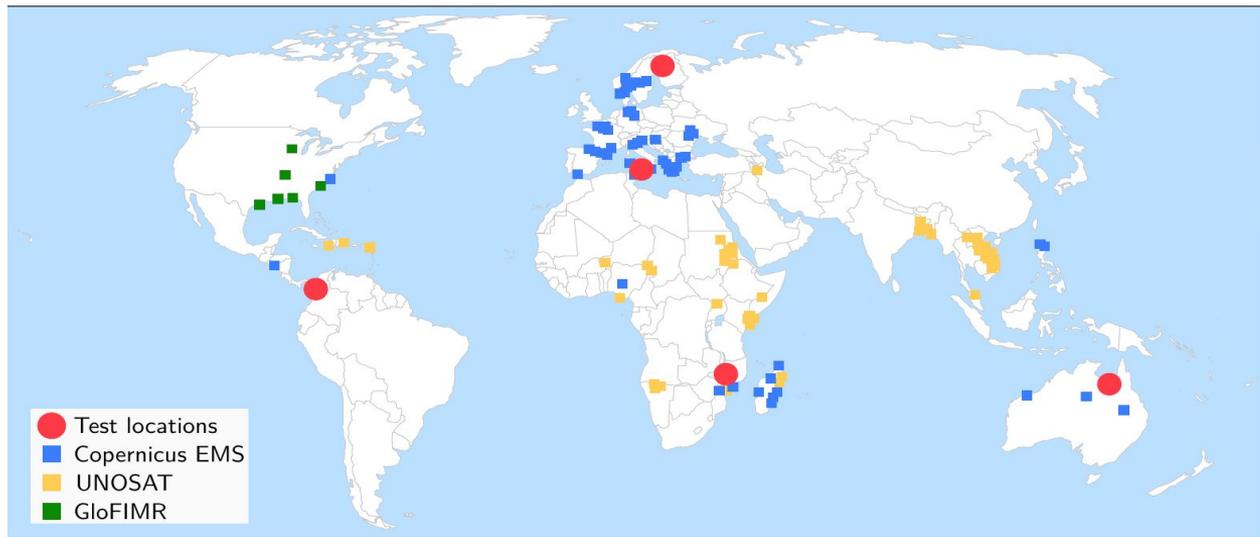
424 flood maps



184,000 patches
(256x256 px)



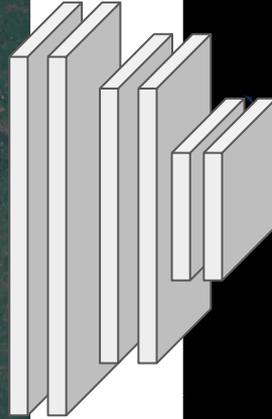
266 GB



Dataset	Flood events	Flood maps	256x256 patches	Water pixels (%)		Land pixels (%)	Cloud pixels (%)	Invalid pixels (%)
				Flood	Permanent [†]			
Training	108	407	182,413	1.45	1.25	43.24	50.25	3.81
Validation	6	6	1132	3.14	5.19	76.72	13.27	1.68
Test	5	11	2029	20.23	1.16	59.05	16.21	3.34

Modelo de segmentación de inundaciones

Sentinel-2



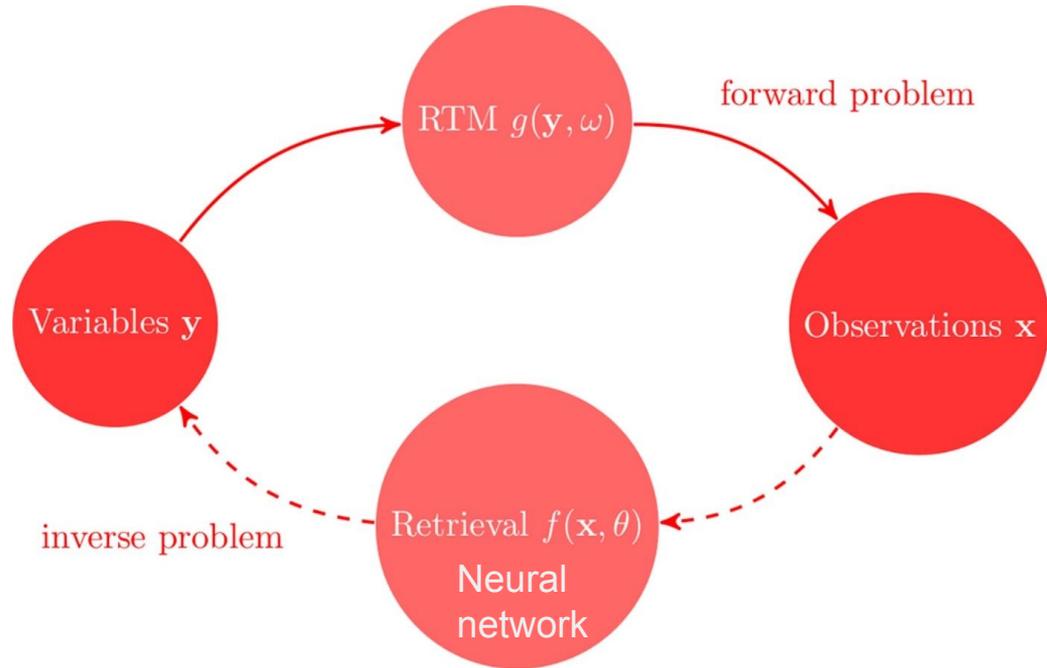


¿Significa esto que los modelos y el conocimiento de la física no sirve para nada?

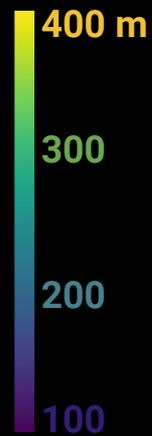
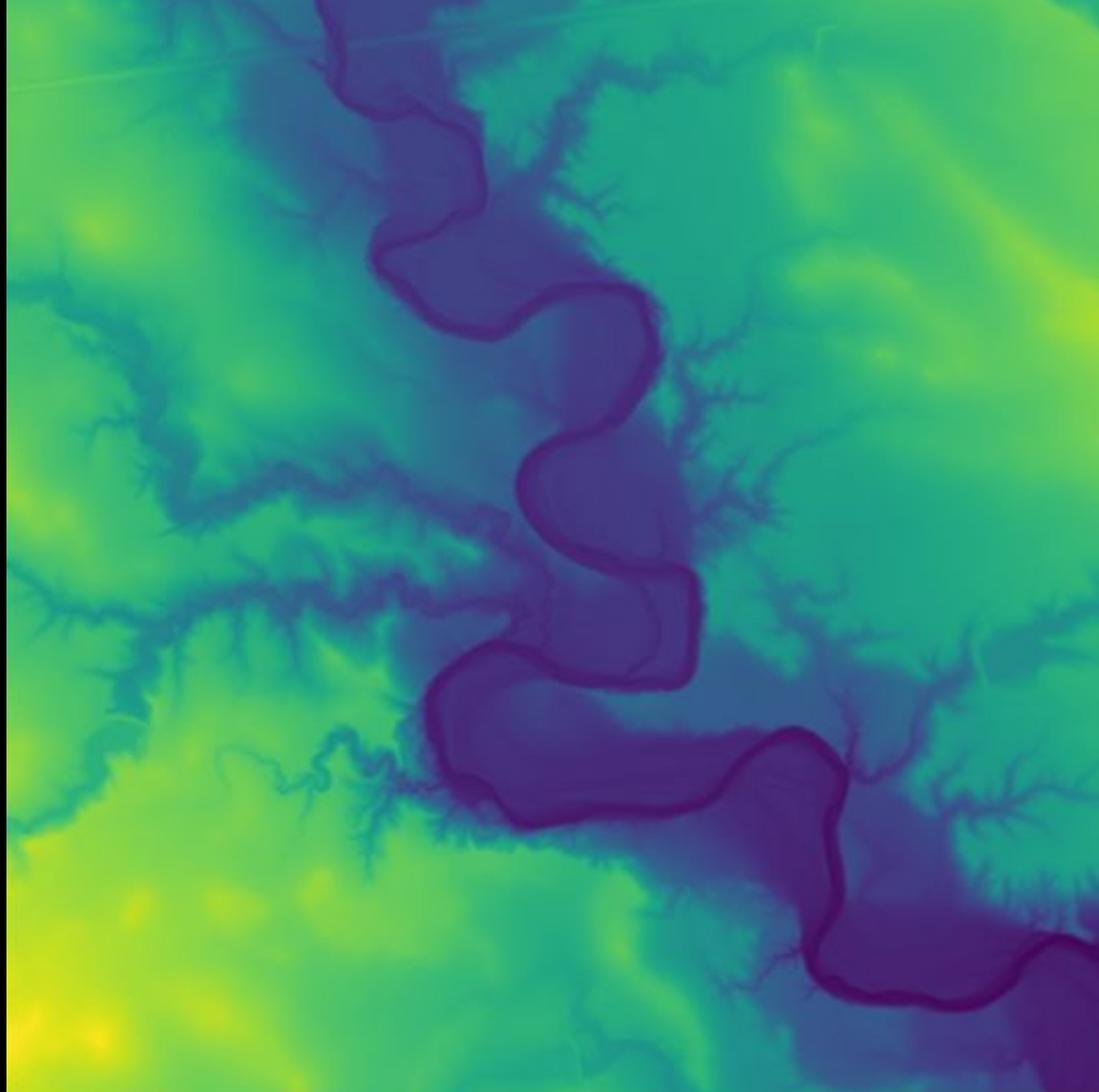


Modelos híbridos: "physics-aware AI"

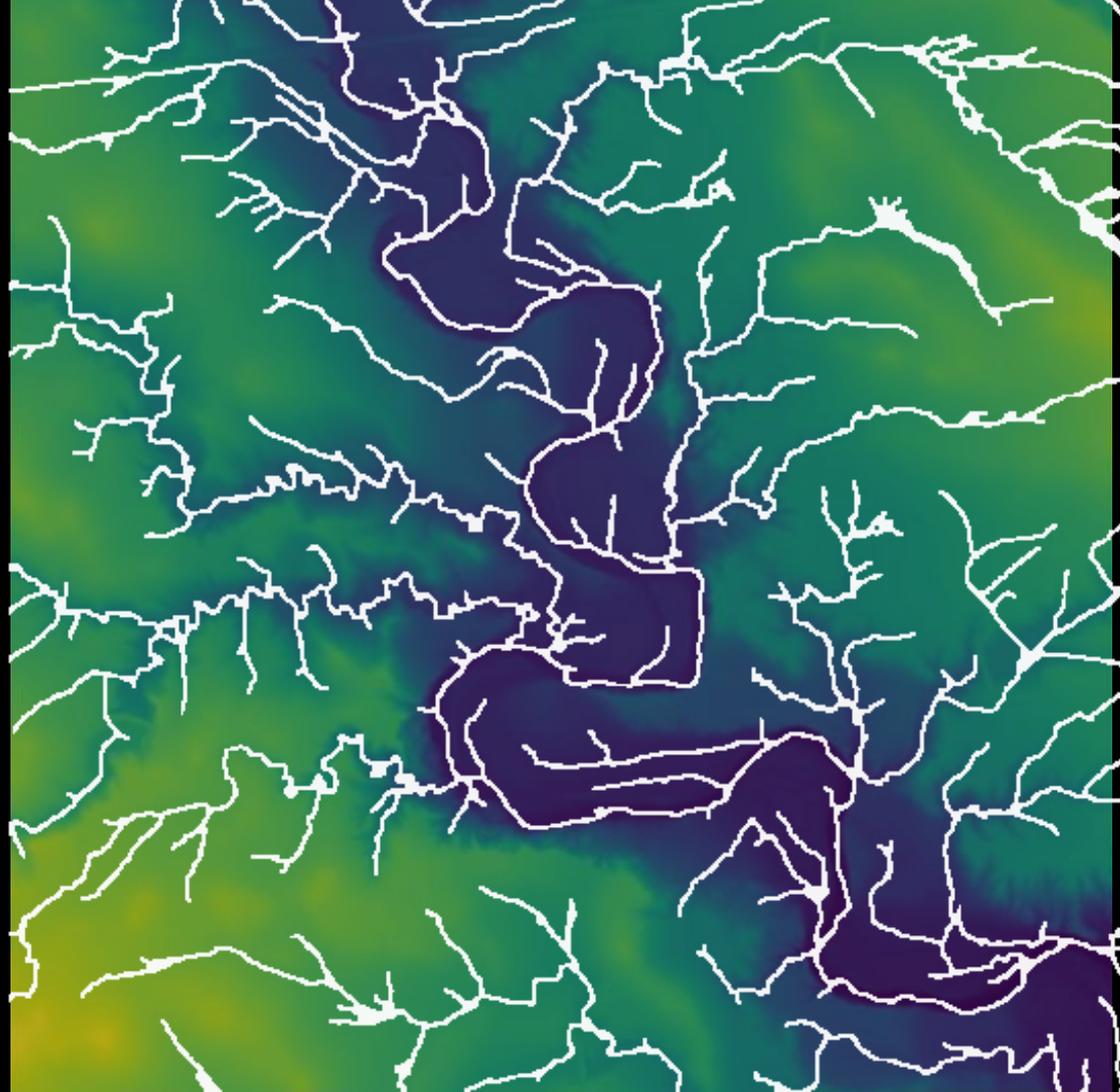
- Reemplazar *algunas partes* de los procesos físicos por redes neuronales (**emuladores** cuando el proceso físico es computacionalmente intensivo)
- Añadir **restricciones** en el entrenamiento de los modelos basados en redes (energy balance)
- Implementar los modelos físicos en **lenguajes de programación diferenciables** (pytorch, tensorflow) para poder aprender variables de los modelos basado en datos



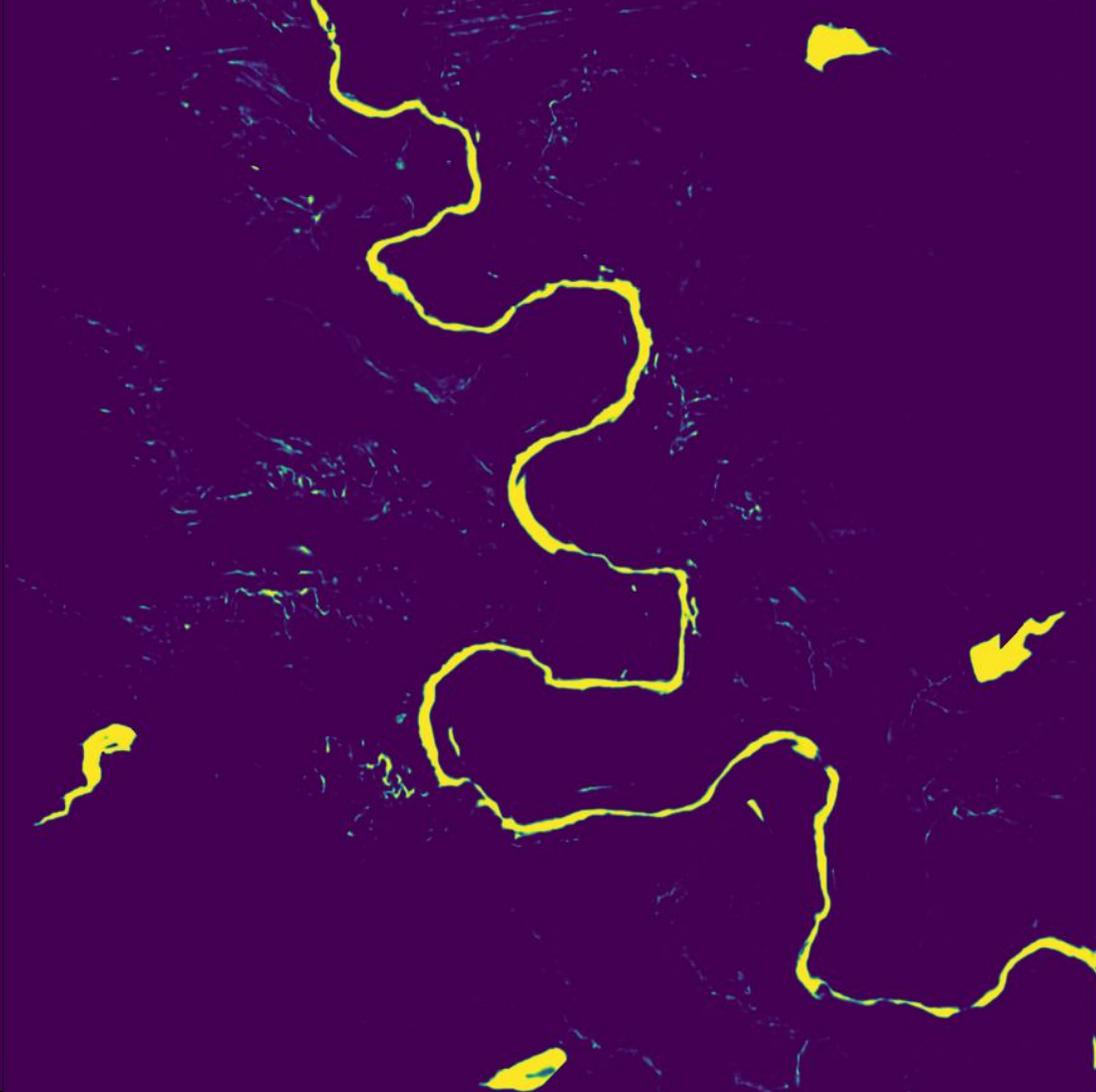
elevation
(LiDAR)



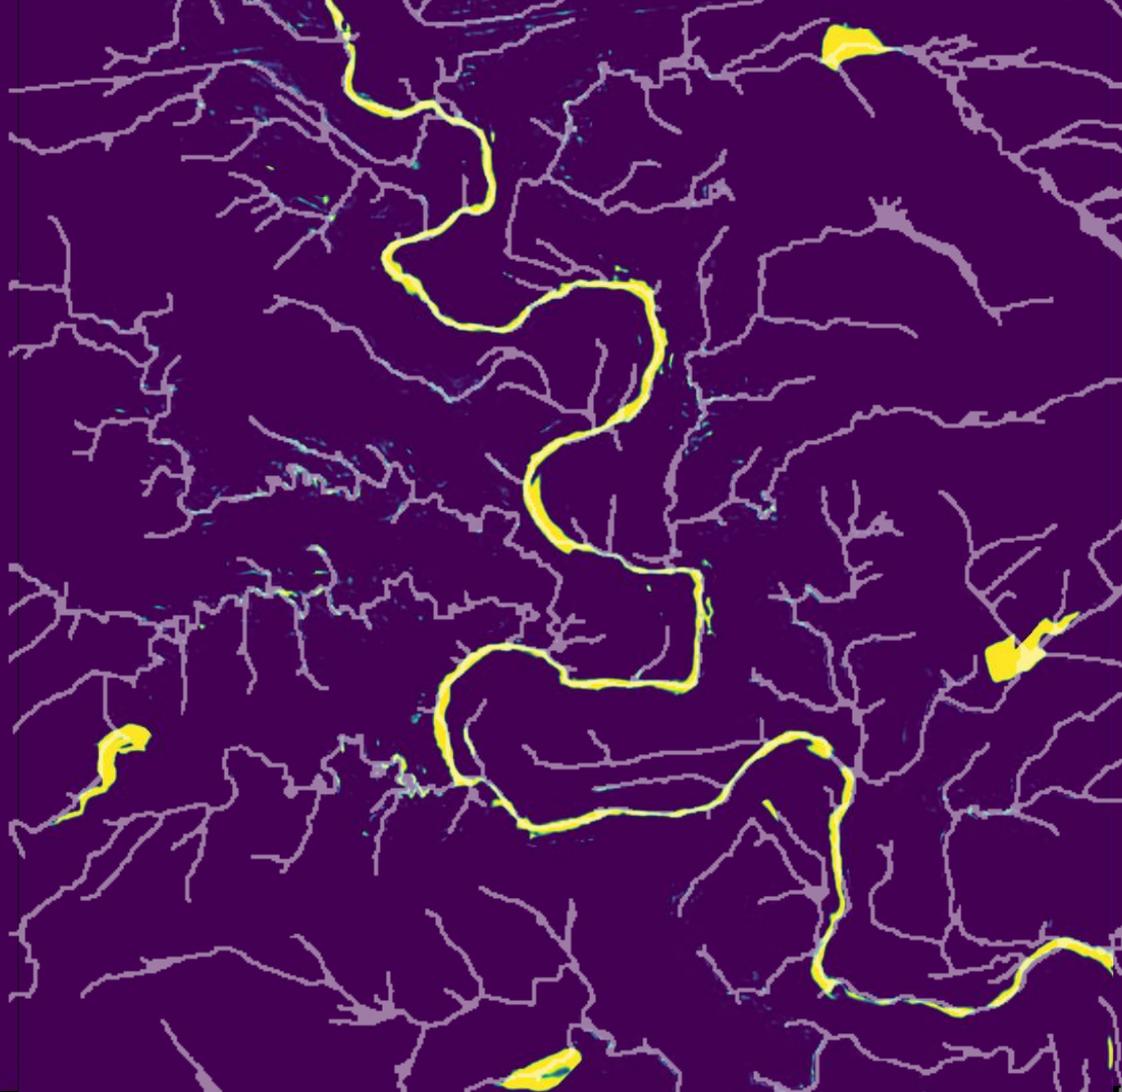
flow line



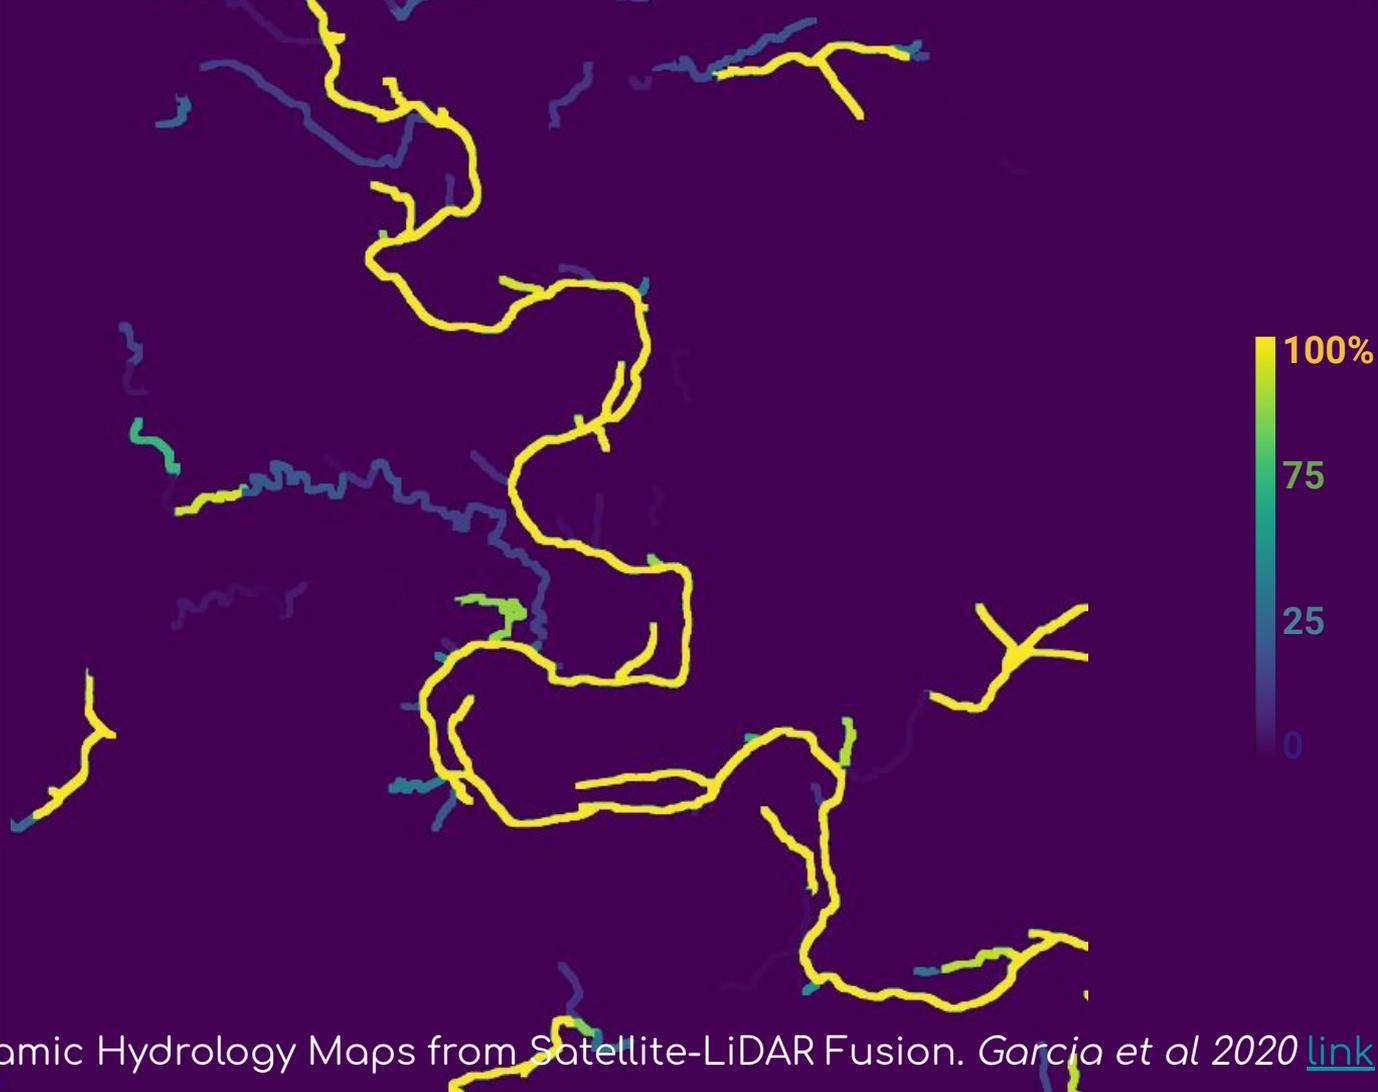
neural net



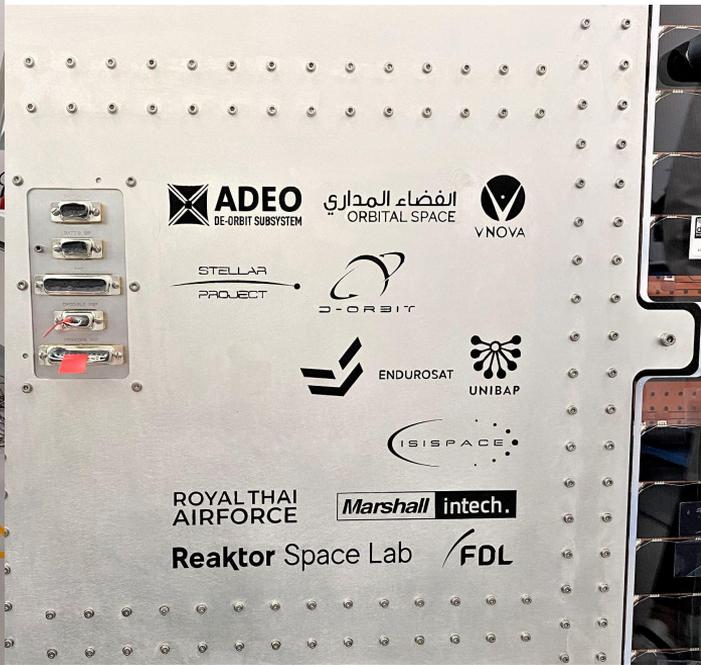
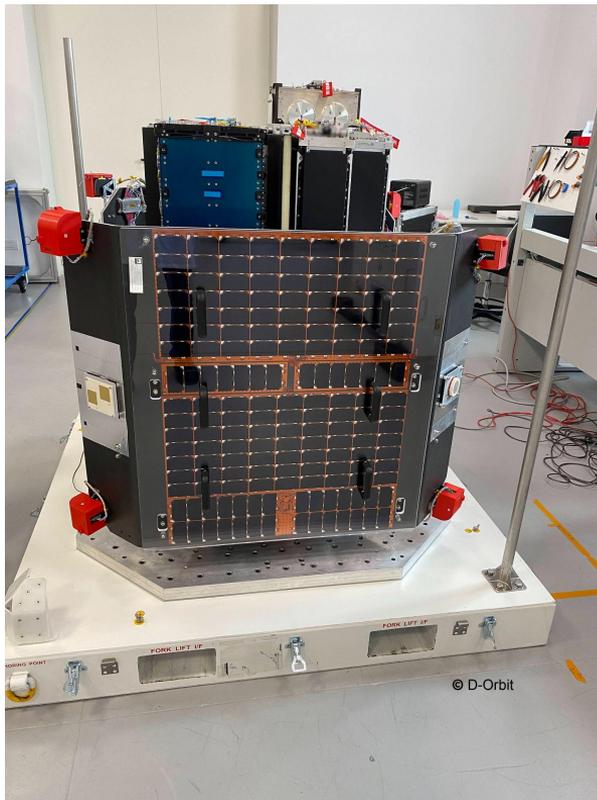
neural net

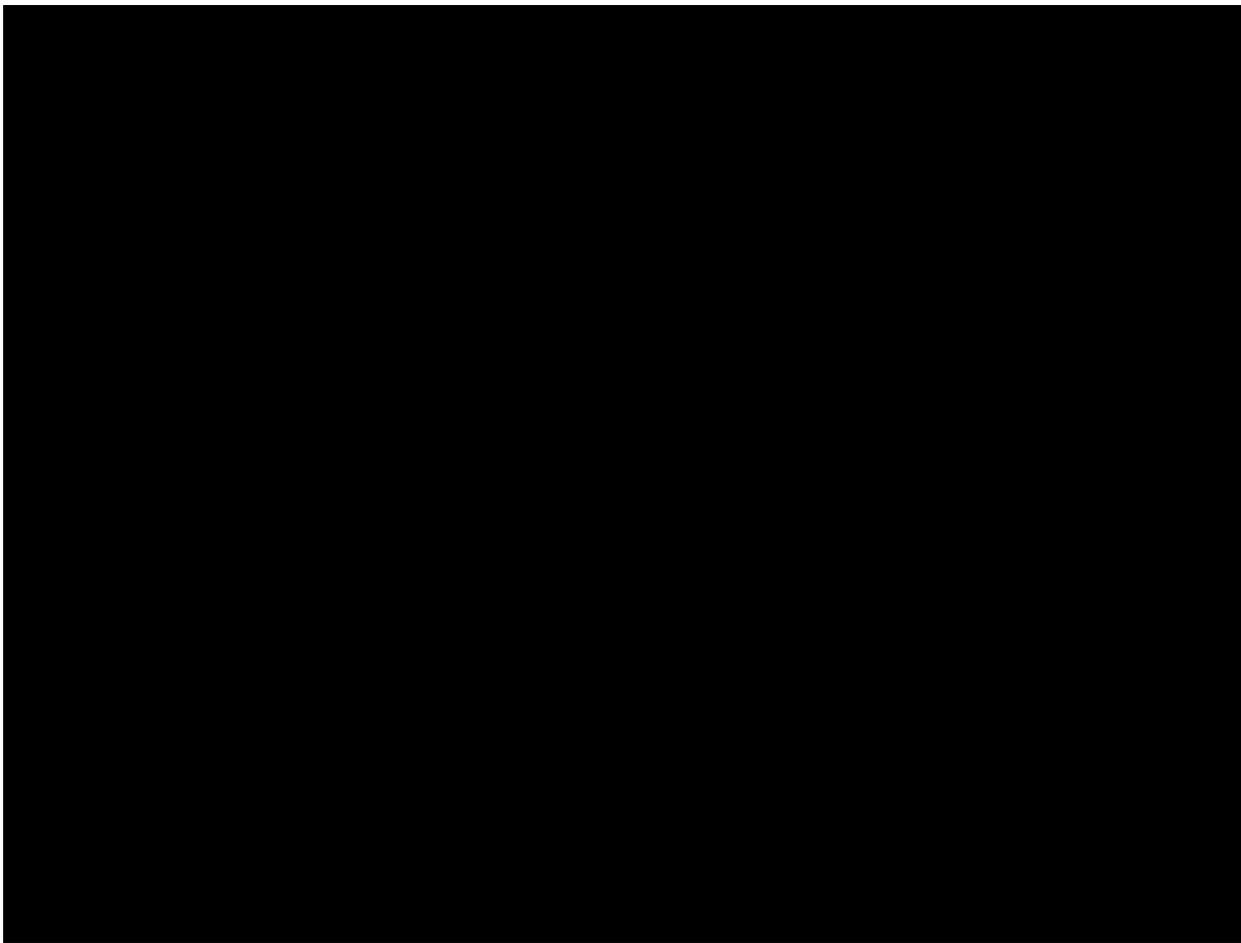


%
water
(per reach)



¡Implementación a bordo del satélite!

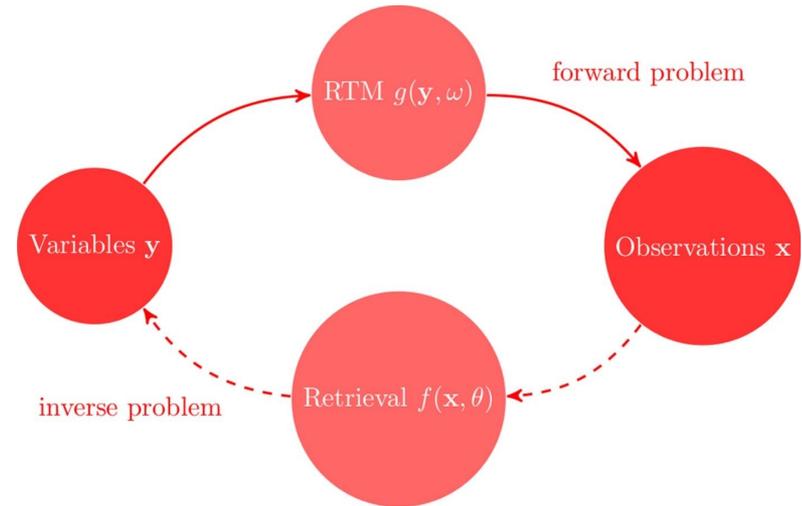




Lanzamiento a bordo del Transporter 2 de SpaceX. 30 de Junio de 2021

Conclusiones

- Las redes neuronales se utilizan para la modelización en áreas donde **anteriormente se usaban únicamente modelos físicos**
 - Teledetección, meteorología, clima,...
- En algunas ocasiones **los modelos basados en redes** son:
 - Más precisos
 - Más rápidos
- Tendencia physics-aware machine learning: **codificar la física en los modelos basados en datos** (observacionales)



PONENTES

* Mariua Martínez-García (UJI) ——— Inteligencia artificial? aprendiendo de la biología

* Alex Gómez-Villa (UAB) ——— Las neuronas artificiales hacen cosas increíbles!

* Gonzalo Mateo (UV) ——— Las neuronas artificiales simulan procesos físicos

* Adriau Martíu (UPF) ——— Errores de percepción en neuronas artificiales

* Emiliano Díaz (UV) ——— Inferencia Causal a partir de datos

* Valero Laparra (UV) ——— IA a debate!

**Las IAs son racistas y
un poco nazis...**

Las IAs son racistas y un poco nazis

Jul 1, 2015, 01:42pm EDT

Google Photos Tags Two African-Americans As Gorillas Through Facial Recognition Software



Maggie Zhang Forbes Staff

Tech

I write about technology, innovation, and startups.

Follow

This article is more than 6 years old.

f
t
in



SAN FRANCISCO, CA - MAY 28: Google Photos director Anil Sabharwal announces Google Photos during the... [+]

NEWS | 24 October 2019 | Update 26 October 2019

Millions of black people affected by racial bias in health-care algorithms

Study reveals rampant racism in decision-making software used by US hospitals – and highlights ways to correct it.

Heidi Ledford



Black people with complex medical needs were less likely than equally ill white people to be referred to programmes that provide more personalized care. Credit: Ed Kashi/VII/Redux/eyevine

Las IAs son racistas y un poco nazis

MICROSOFT WEB TL;DR

Twitter taught Microsoft's AI chatbot to be a racist asshole in less than a day

By James Vincent | Mar 24, 2016, 6:43am EDT
Via The Guardian | Source TayandYou (Twitter)

f t SHARE



It took less than 24 hours for Twitter to corrupt an innocent AI chatbot. Yesterday,

verge deals

Subscribe to get the best Verge-approved tech deals of the week.

Email (required)

By signing up, you agree to our [Privacy Notice](#) and European users agree to the data transfer policy.

SUBSCRIBE

In 2016, Microsoft's Racist Chatbot Revealed the Dangers of Online Conversation

The bot learned language from people on Twitter—but it also learned values

By Oscar Schwartz



Photo-illustration: Gluekit

Microsoft's Tay chatbot started out as a cool teenage girl, but quickly turned into a hate-speech-spewing disaster.

Las IAs son machistas

Las IAs son definitivamente machistas

Amazon

This article is more than 2 years old

Amazon ditched AI recruiting tool that favored men for technical jobs

Specialists had been building computer programs since 2014 to review résumés in an effort to automate the search process

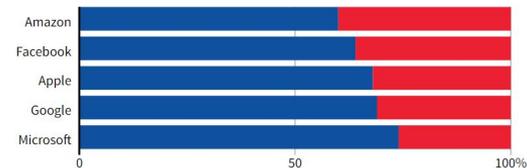


▲ Amazon's automated hiring tool was found to be inadequate after penalizing the résumés of female candidates. Photograph: Brian Snyder/Reuters

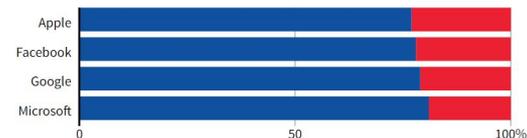
Amazon's machine-learning specialists uncovered a big problem: their new recruiting engine did not like women.

GLOBAL HEADCOUNT

■ Male ■ Female



EMPLOYEES IN TECHNICAL ROLES



Reuters

Thu 11 Oct 2018 00:42 BST



Las IAs son definitivamente machistas



Newsletter Contact Press Deutsch

ABOUT / PROJECTS / PUBLICATIONS / STORIES / POSITIONS / BLOG / DONATE Q

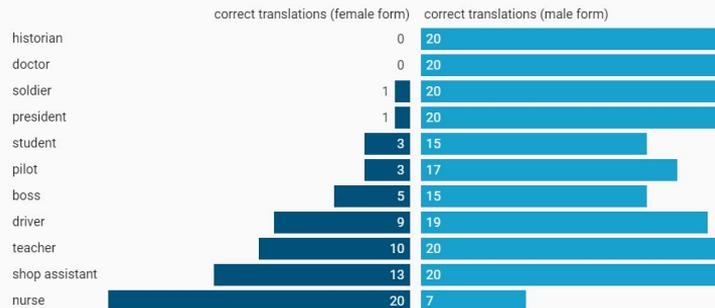
/ Female historians and male nurses do not exist, Google Translate tells its European users

by *Nicolas Kayser-Bril*

An experiment shows that Google Translate systematically changes the gender of translations when they do not fit with stereotypes. It is all because of English, Google says

Female doctors don't exist, says Google Translate

Correct translations for 20 translation pairs to and from French, German, Spanish, Italian and Polish.



How to read the chart: Out of 20 translations of a female doctor, none were correct (e.g. "die Doktorin" become "le docteur", "la dottoressa" becomes "der Doktor" etc.)

Source: AlgorithmWatch • [Get the data](#) • Created with [Datawrapper](#)

Las IAs son homófobas

O por lo menos son utilizadas por homófobos

LGBT rights

LGBT groups denounce 'dangerous' AI that uses your face to guess sexuality

Two prominent LGBT groups have criticized a Stanford study as 'junk science', but a professor who co-authored it said he was perplexed by the criticisms

Sam Levin in San Francisco

@SamTLevin

Sat 9 Sep 2017 01.23 BST



▲ A gay pride march in Nicaragua. The activist groups say the study could be used to out gay people across the globe, putting them at risk. Photograph: Jorge Torres/EPA

A Stanford University study showing that artificial intelligence (AI) can accurately guess whether people are **gay or straight based on their faces** has sparked a swift backlash from LGBT rights activists who fear this kind of technology could be used to harm queer people.

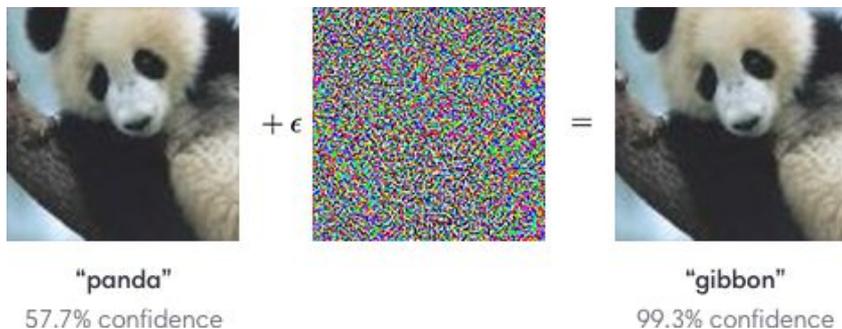
**O quizás simplemente
son como nosotros les
decimos que sean...**

Pero yo prefiero a los loros...

	A parrot	Machine learning algorithm
Learns random phrases	✓	✓
Doesn't understand shit about what it learns	✓	✓
Occasionally speaks nonsense	✓	✓
Is a cute birdie parrot	✓	✗

No todo es culpa del sesgo los datos

La amenaza de los ataques adversarios

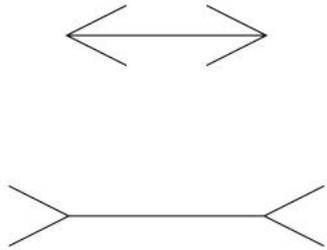


- Las redes neuronales artificiales son cajas negras.
- No entendemos sus decisiones.
- Los mejores modelos (supervisados) necesitan una cantidad absurda de datos para poder entrenarse.
- Las redes neuronales artificiales no funcionan igual que las redes neuronales biológicas.

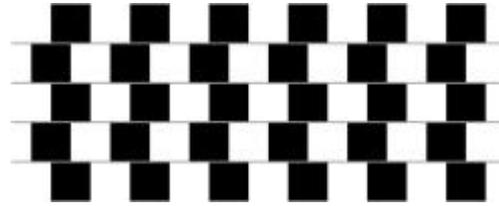
¿Y si no son tan distintas?

También tienen ilusiones...

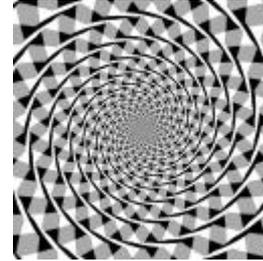
Ilusiones visuales



Müller-Lyer illusion



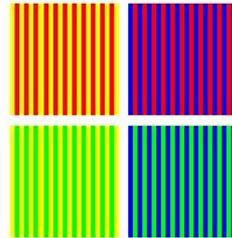
Cafe Walls illusion



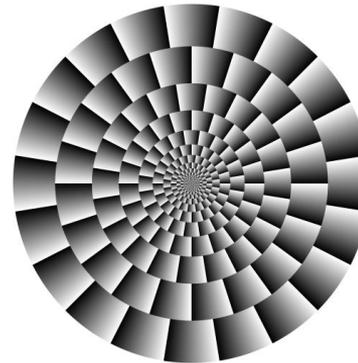
Fraser's spiral illusion



Brightness contrast



Color assimilation

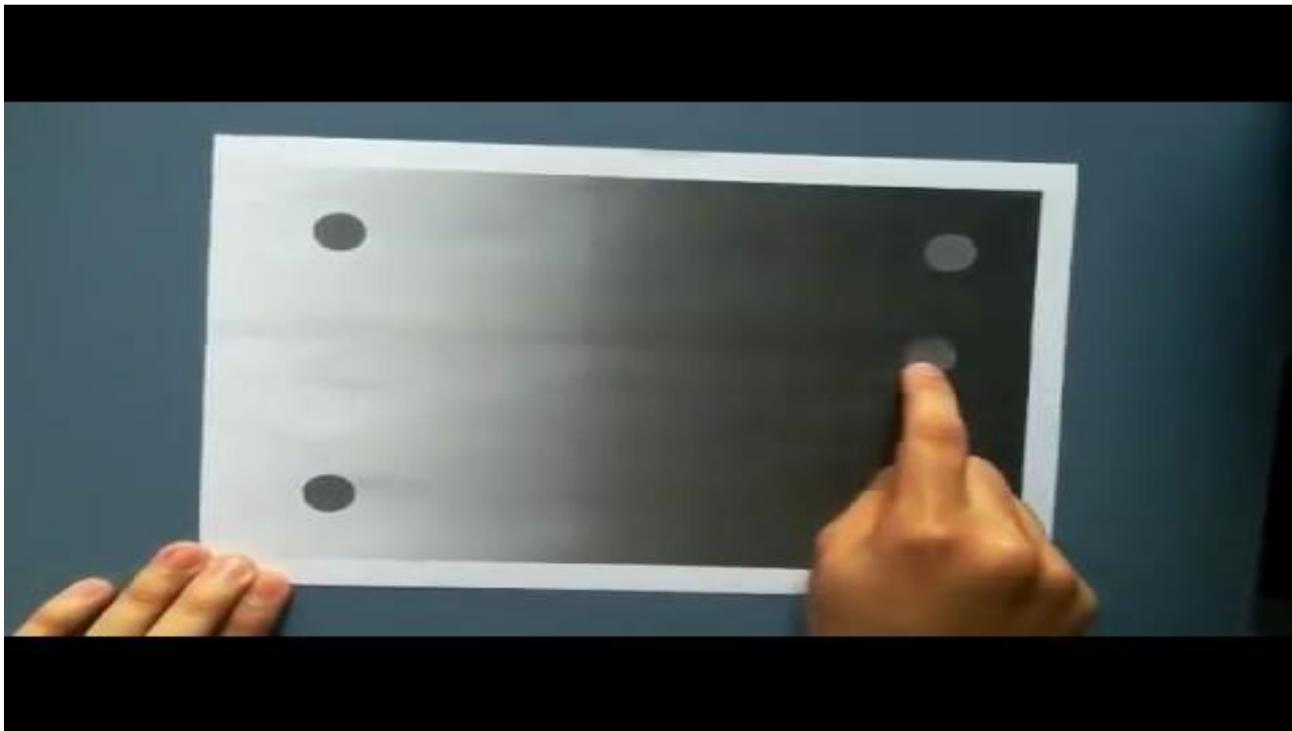


Fraser-Wilcox illusion

'A Catalogue of illusions' del Profesor Akitaoka

<http://www.psy.ritsumei.ac.jp/~akitaoka/cataloge.html>

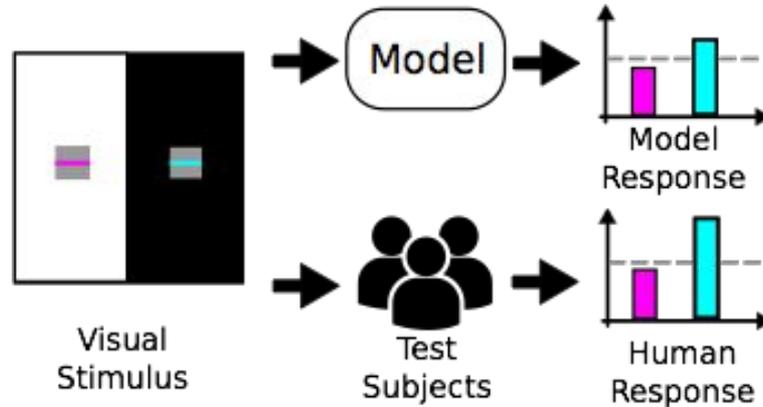
Brightness visual illusions (live)



Fuente: @alviur 

¿Por qué utilizar ilusiones para estudiar la visión humana?

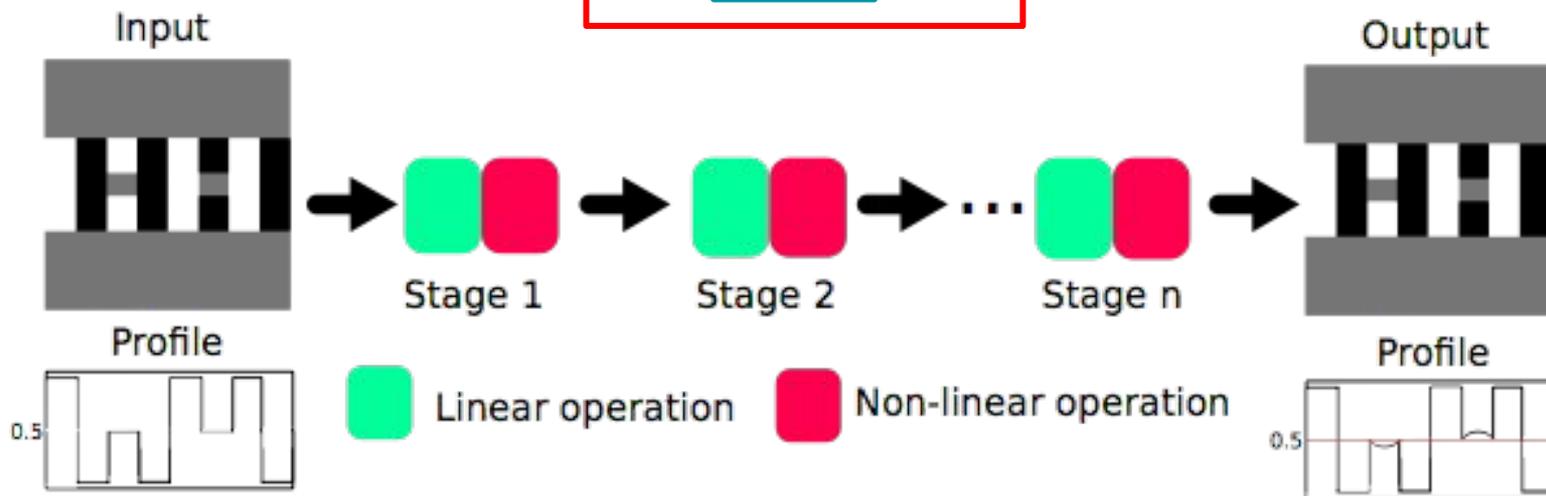
- Revelan las diferencias entre percepción y realidad.
- Estos *errores* son clave para entender cómo funciona nuestra visión.
- Un modelo bueno de visión debería ser capaz de reproducir cómo percibimos las ilusiones visuales.



Cascada de operaciones Lineales + No lineales

La **percepción** se explica en muchos modelos de visión como una **cascada** de módulos compuestos por una **operación lineal seguida de una no-linealidad**.

$$x^{k+1} = f_{k+1}(L_{k+1} x^k, \theta_{k+1})$$

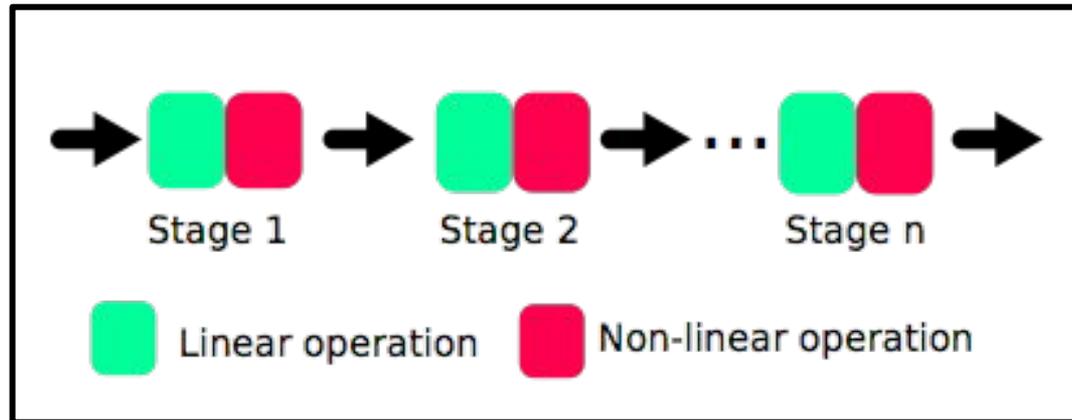


Redes de convolución (CNN)

Convolutional layers + bias

Activation layers

$$x^{k+1} = f_{k+1}(L_{k+1} x^k, \theta_{k+1})$$



Tres tareas que realiza nuestro sistema visual

Eliminación de ruido

Desemborronar

Restauración



I

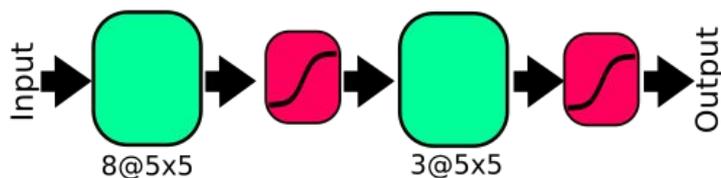
$I + \text{noise}$

$I + \text{blur}$

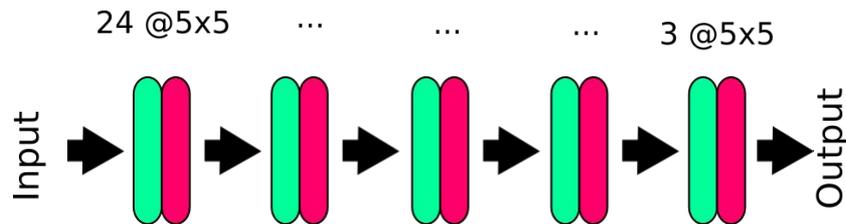
$I + \text{blur} + \text{noise}$

CNNs utilizadas

DN-NET, DB-NET, Restore-Net



Deep DN-NET, DB-NET, and Restore-Net



 Convolution Layer  Activation Layer

Zhang et al: Denoising deep CNN with state-of-the-art performance

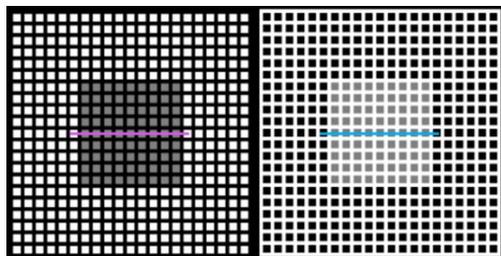
Zhang, K., Zuo, W., Chen, Y., Meng, D. and Zhang, L., 2017. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising. IEEE Transactions on Image Processing, 26(7), pp.3142-3155.

Dataset: Entrenadas en un subconjunto de ImageNet

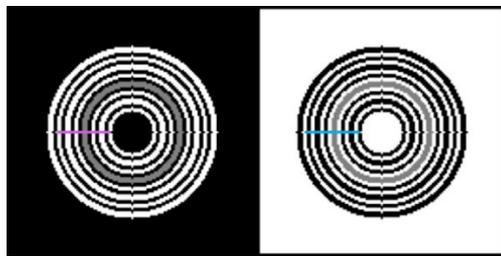
Loss: Error cuadrático Medio

Ilusiones visuales de brillo y color

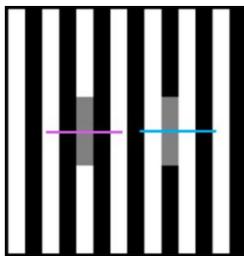
Dungeon



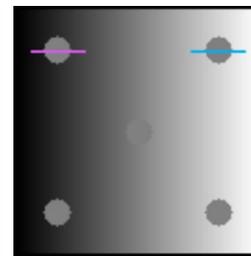
Hong-Shevell



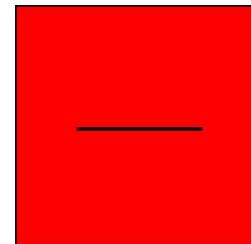
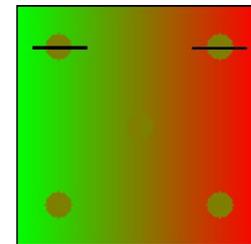
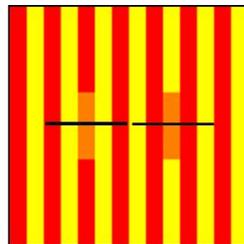
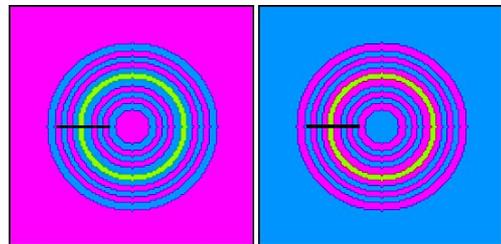
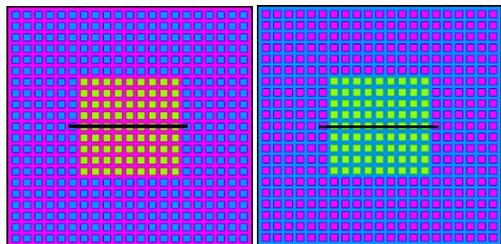
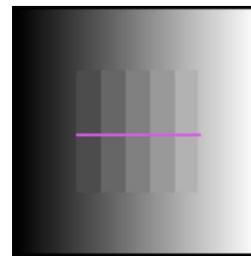
White



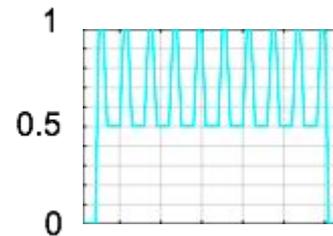
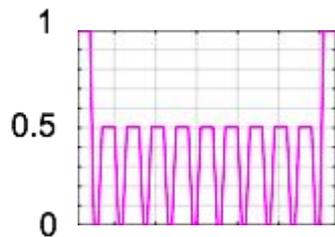
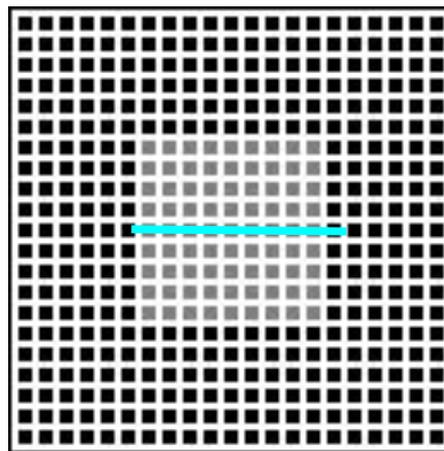
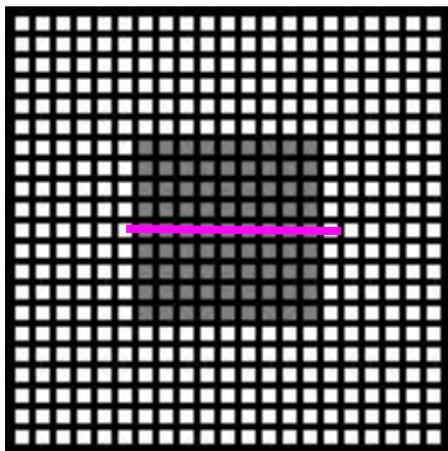
Gradient



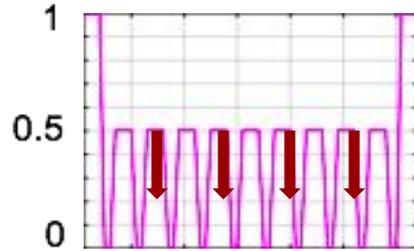
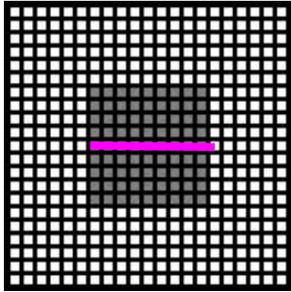
Chevreul



Ilusión de Dungeon



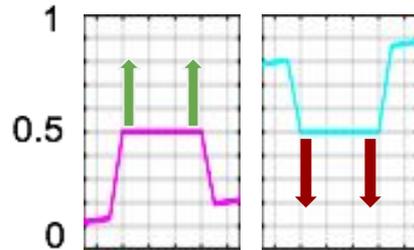
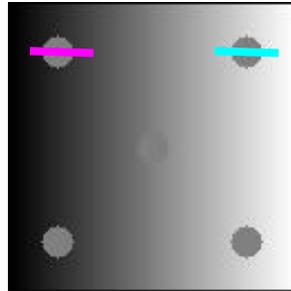
Efecto de asimilación y contraste



Efecto de asimilación:

Los valores de la imagen cambian en la dirección de sus vecinos.

→ Esperable cuando eliminamos ruido.

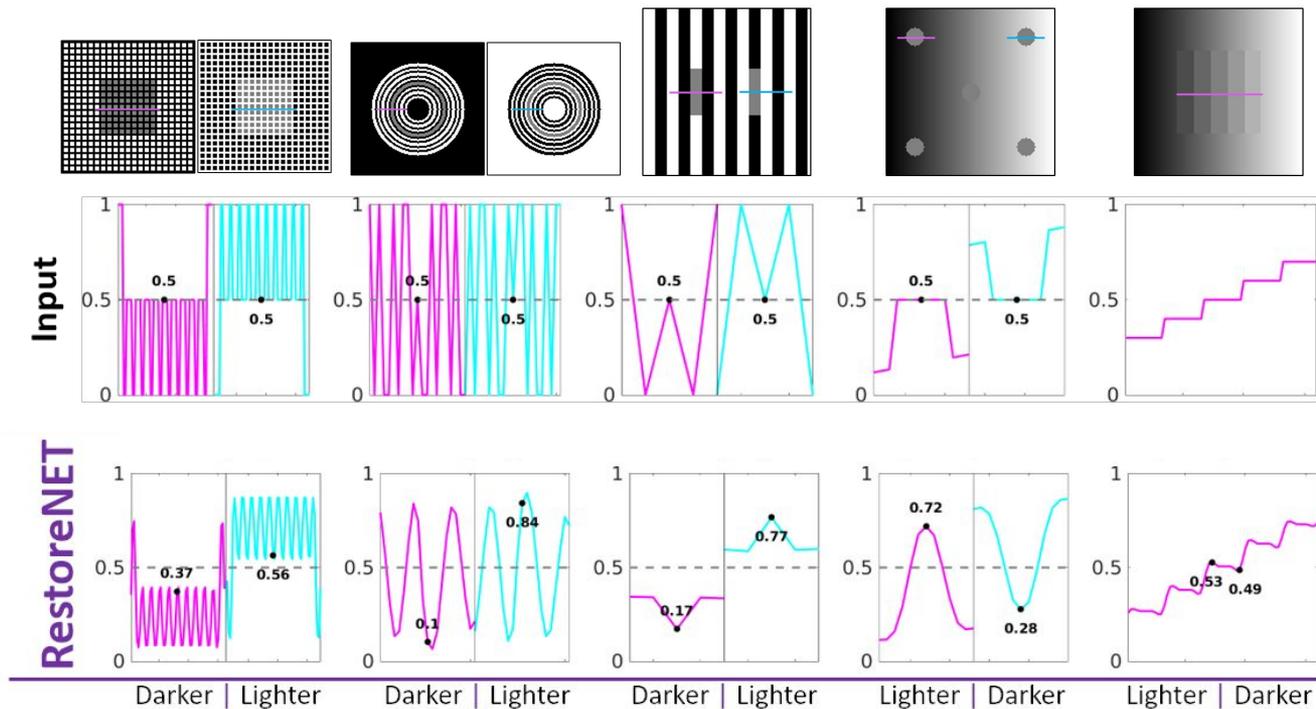


Efecto de contraste:

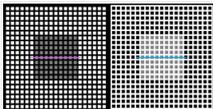
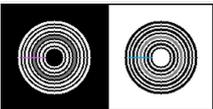
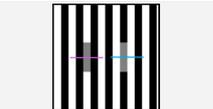
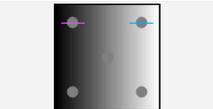
Los valores de la imagen cambian en dirección opuesta a sus vecinos.

→ Esperable al desemborronar.

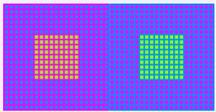
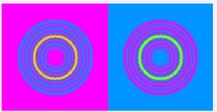
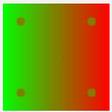
Resultados de las CNNs (cualitativos y cuantitativos)



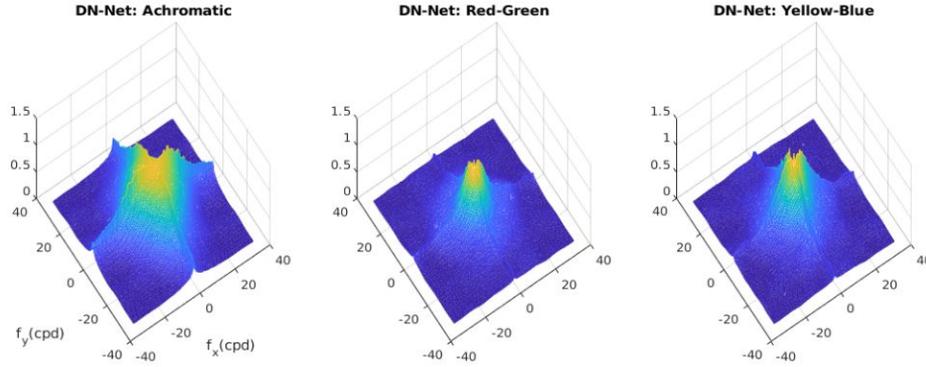
Ilusiones de brillo replicadas por las CNNs

Visual Illusion					
DN-NET	✓	✓	✓	✓	✗
DB-NET	✓	✓	✓	✓	✓
Restore-Net	✓	✓	✓	✓	✓
Deep DN-NET	✓	✓	✓	✗	✗
Deep DB-NET	✗	✓	✓	✓	✓
Deep RestoreNet	✓	✓	✓	✓	✓
Zhang et al.	✓	✗	✗	✓	✗

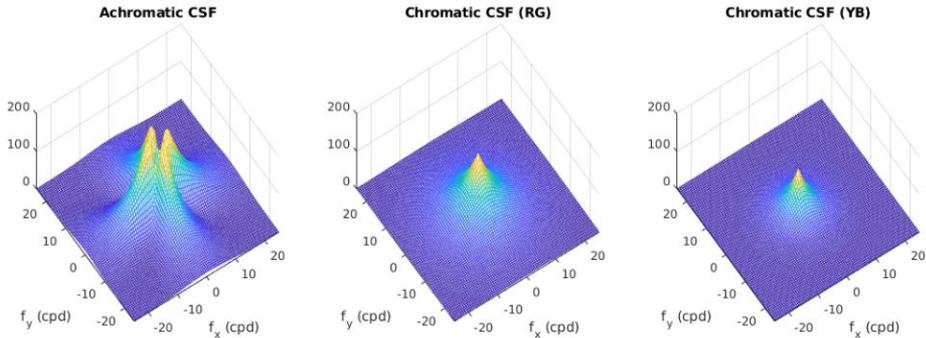
Ilusiones de color replicadas por las CNNs

Visual Illusion					
DN-NET	✓	✓	✓	✗	✓
DB-NET	✓	✓	✓	✗	✓
Restore-Net	✓	✓	✓	✗	✓
Deep DN-NET	✓	✓	✓	✗	✓
Deep DB-NET	✓	✓	✓	✓	✓
Deep RestoreNet	✓	✓	✓	✗	✓
Zhang et al.	✓	✗	✗	✓	✗

¿Percibimos de manera similar a las CNNs?



Contrast sensitivity function of DN-NET

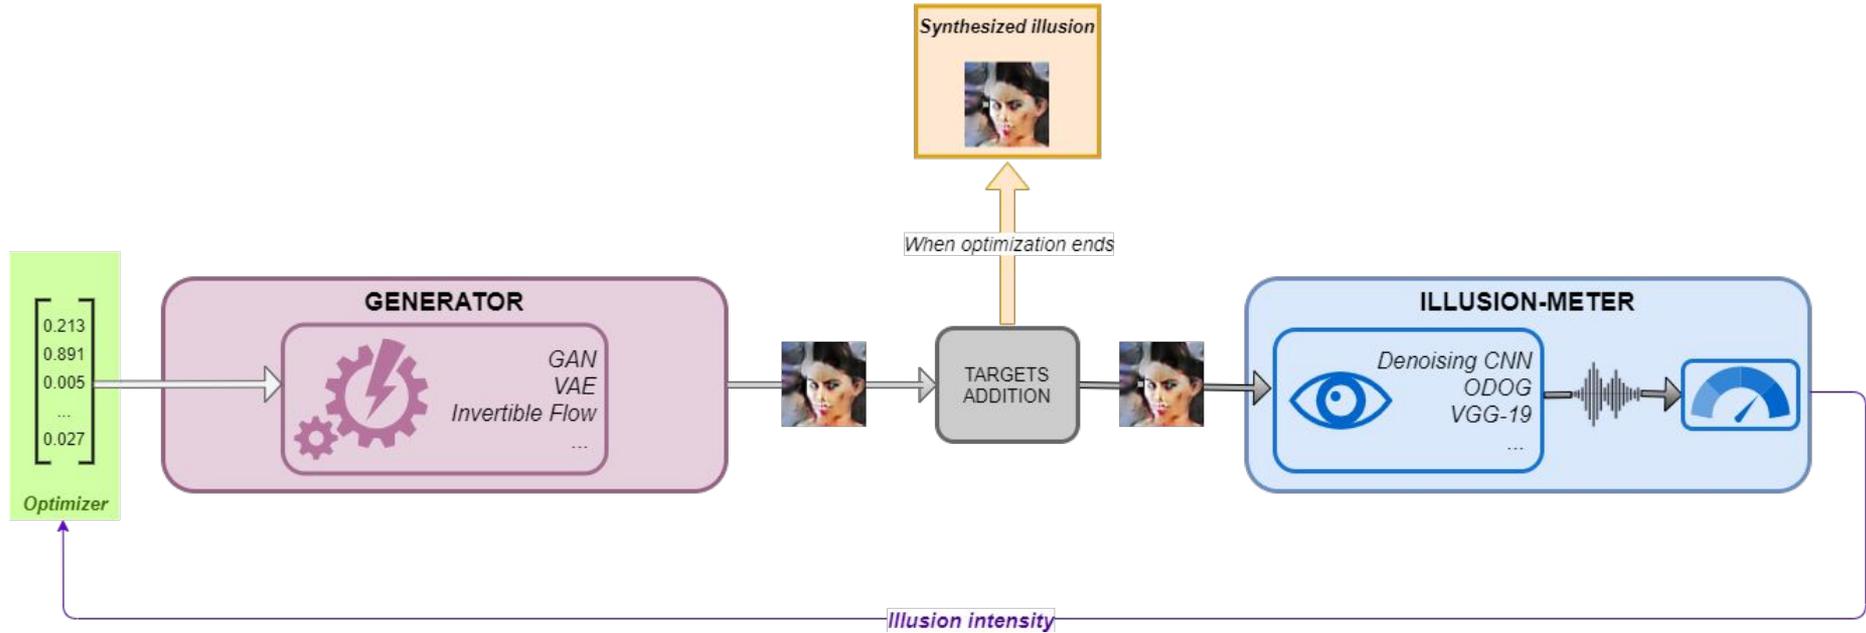


Human contrast sensitivity functions

Mullen, K. T. (1985). The contrast sensitivity of human colour vision to red-green and blue-yellow chromatic gratings. *The Journal of physiology*, 359(1), 381-400.

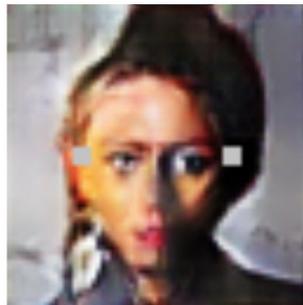
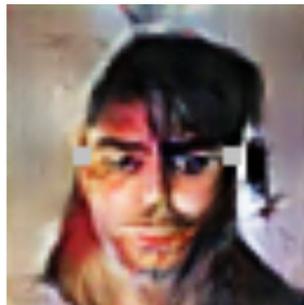
Watson, A. B., & Malo, J. (2002, September). Video quality measures based on the standard spatial observer. In *Proceedings. International Conference on Image Processing (Vol. 3, pp. III-III)*. IEEE.

¿Y si utilizamos las CNNs para generar nuevas ilusiones?



Resultados usando VGG-16

Celeb
faces



Cats
faces 64x64



¿Pero entonces son racistas o no?

- Las redes neuronales que aprenden directamente de nuestros datos “sin pulir” reproducen y exacerban **nuestros sesgos**.
- No todo es sesgo, problemas como los **ataques adversarios** muestran que procesamos los datos de formas muy distintas.
- *Una Nueva Esperanza*
 - Las redes neuronales entrenadas para realizar tareas básicas de la visión también reproducen algunas ilusiones visuales como nosotros.
- *El Imperio Contraataca*
 - Los efectos de las ilusiones parecen ser más reducidos en las redes más complejas.

PONENTES

* Mariua Martinez-Garcia (UJI) ————— Inteligencia artificial? aprendiendo de la biología

* Alex Gomez-Villa (UAB) ————— Las neuronas artificiales hacen cosas increíbles!

* Gonzalo Mateo (UV) ————— Las neuronas artificiales simulan procesos físicos

* Adriau Martiu (UPF) ————— Errores de percepción en neuronas artificiales

* Emiliano Diaz (UV) ————— Inferencia Causal a partir de datos

* Valero Laparra (UV) ————— IA a debate!

¿Que tienen que ver la **Estadística** y la **Neurociencia** con la modelización en **Física**?

¿Puede ayudar a la inferencia causal a responder?

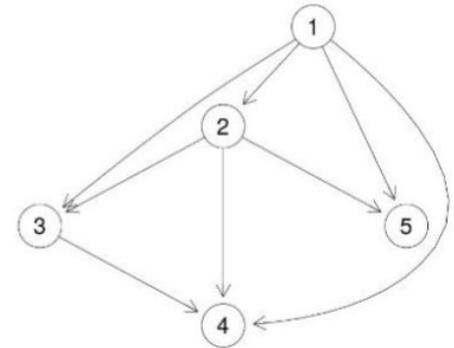
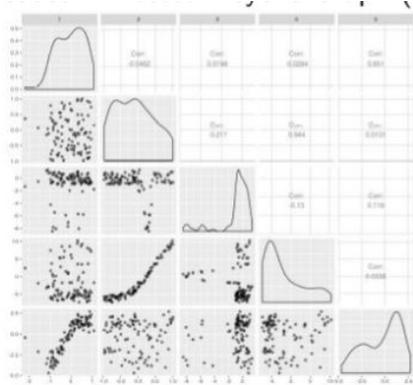
(Spoiler sí)

¿Que es la inferencia causal?

Algunas preguntas causales, para un sistema de variables:

1. cuales son causas y cuales efectos (directos e indirectos)
2. Cual es el tamaño del efecto?
3. Que pasaría si parte del sistema cambiara?
4. Que hubiera pasado si “aquello” hubiera sucedido?

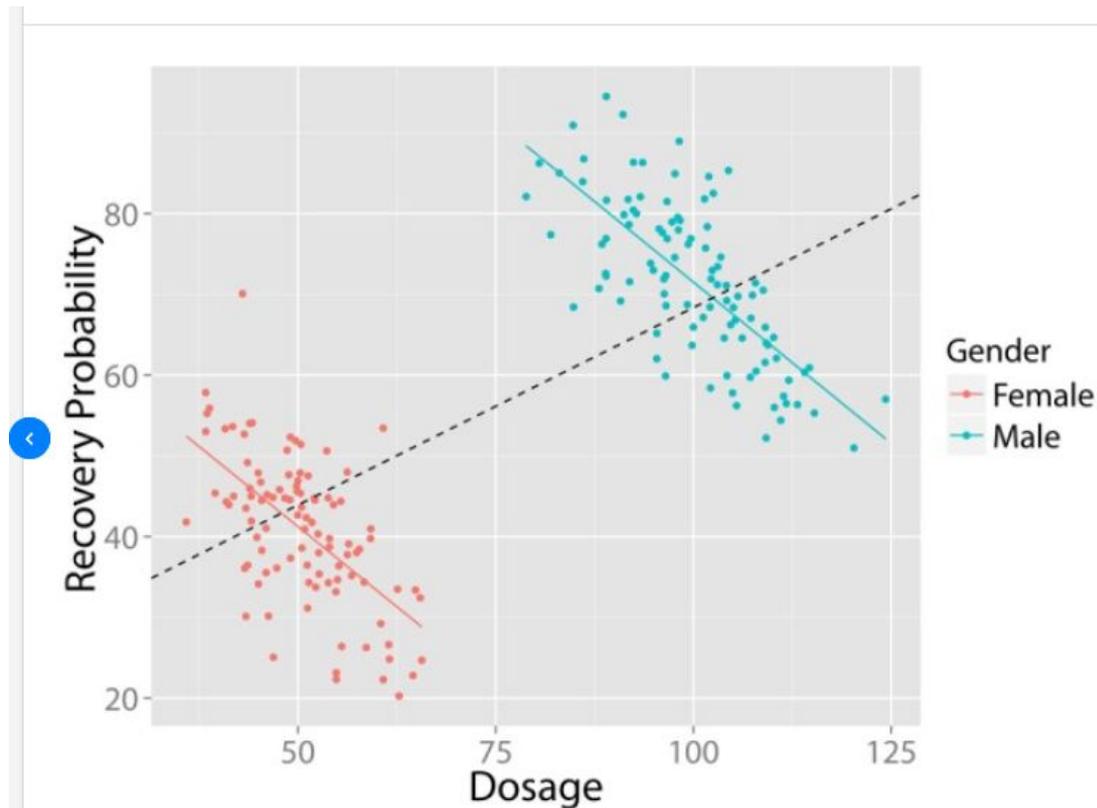
la inferencia causal intenta usar datos para responder estas (entre otras) preguntas



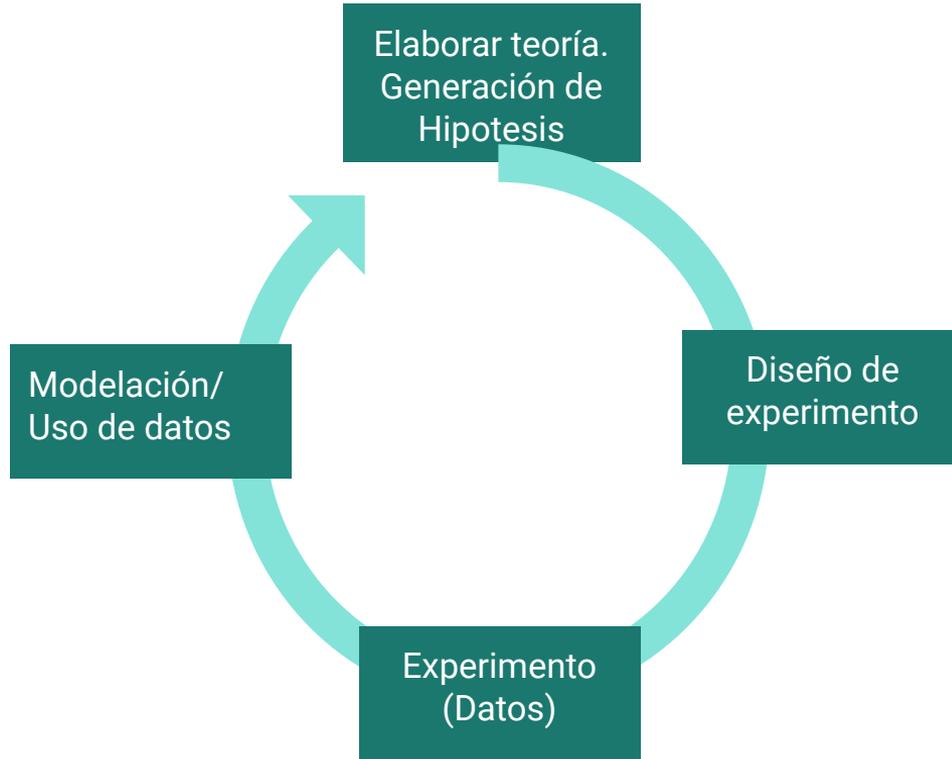
¿Que es la inferencia causal?

pregunta 1 y 2:

1. Incrementar la “dosis de un medicamento” es una causa del “grado de recuperación”?
2. Cual es el tamaño del efecto?



La Ciencia es inferencia causal



Preguntas anteriores muy propias de la ciencia. La búsqueda de conocimiento científico se puede plantear como un un proceso sucesivo/online de inferencia causal.

Elaboración de datos generación de hipótesis causales (aparentemente) no se realiza únicamente a partir de datos

La Ciencia es inferencia causal

Dificultades para inferir causas SOLO a partir de datos: confounders, Simpson paradox

principio de Reichenbach : si dos variables estan asociadas es porque una causa a la otra o una tercera (confounder) causa a las dos

Herramienta fundamental para resolver disyuntiva: diseño de experimento y estadística. Diseño de experimentos elimina problema de confounding. (Aún así necesitamos información adicional/ supuestos para escoger variables relevantes.)

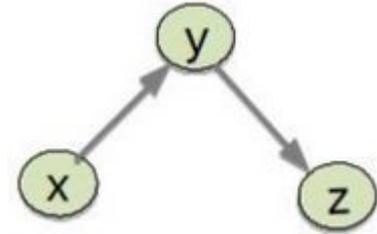
Datos experimentales solo. Podemos usar datos donde no hay control? Como integrar datos de distintos experimentos?

Marco matemático: Proba y modelos gráficos

Dado un sistema de variables como encontrar causas y efectos (directos e indirectos)

$$\mathbb{P}^{\mathcal{X}} = p(x, y, z) = p(z|x, y)p(y|x)p(x) = p(z|y)p(y|x)p(x)$$

$$x \perp\!\!\!\perp z | y$$

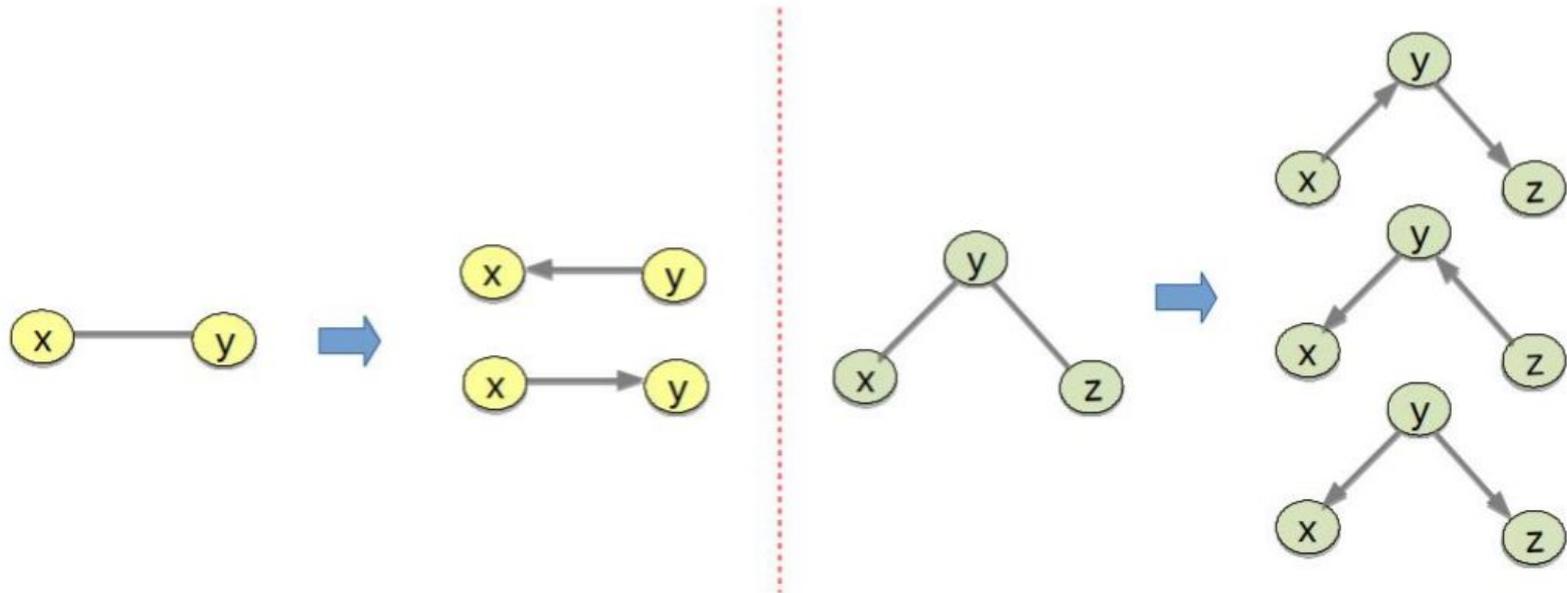


- Factorización de la conjunta ya sugiere causa y efecto pero en general existen mas de una factorización
- Las relaciones de independencia restringen las factorizaciones posibles: ie. eliminan algunas hipotesis causales
- Estas relaciones se resumen con modelos graficos (DAGs) que recogen la intuición de $P(X) = \text{mult } p(\text{efecto}|\text{causa})$.

Problemas:

- no hay definicion causa-efecto es solo intuición
- No hay forma de distinguir hipotesis causales (DAGs) que representan mismas independencias condicionales

Marco matemático: Proba y modelos gráficos



- Given that we know x and y dependent ($x \not\perp\!\!\!\perp y$): choose between $x \rightarrow y$ or $y \rightarrow x$
- Given that we know x and z conditionally independent given y ($x \perp\!\!\!\perp z | y$): choose between $x \rightarrow y \rightarrow z$, $x \leftarrow y \leftarrow z$ or $x \leftarrow y \rightarrow z$.

Marco matemático: Structural Equation Models (SEMs)

Dado un sistema de variables como encontrar causas y efectos (directos e indirectos)

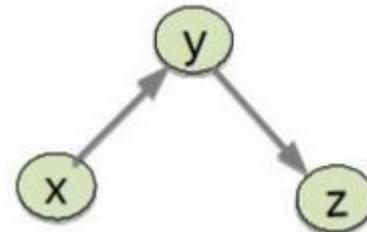
Punto de vista “generativo”. Que ecuaciones describen la relación entre los elementos estocásticos (ruido/variables exógenas) y determinísticos (variables de interés) del sistema:

- Los datos observados en un sistema son generados por ecuaciones, una por variable

$$x = f_x(PA_x, n_x) = n_x$$

$$y = f_y(PA_y, n_y) = x^2 + e^{n_y x}$$

$$z = f_z(PA_z, n_z) = 5y + n_z$$



Marco matemático: Structural Equation Models

nuevo problema de optimización discreto!

Si solo disponemos de datos observacionales imposible/muy difícil (espacio de grafos muy grande)

conjunto de causas posibles: $\{\}, \{y\}, \{z\}, \{y,z\}$

variables exógenas/ruido

$$\mathbb{P}^{\mathcal{N}} = p(n_x)p(n_y)p(n_z)$$

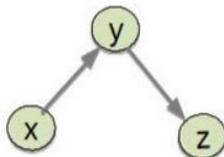
$$\begin{aligned} x &= f_x(PA_x, n_x) = n_x \\ y &= f_y(PA_y, n_y) = x^2 + e^{n_y x} \\ z &= f_z(PA_z, n_z) = 5y + n_z \end{aligned}$$

realizar supuestos

ejemplo concreto

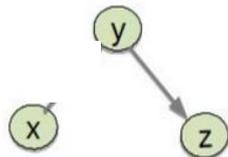
Marco matemático: Structural Equation Models

$$\begin{aligned}
 x &= f_x(PA_x, n_x) = n_x \\
 y &= f_y(PA_y, n_y) = x^2 + e^{n_y x} \\
 z &= f_z(PA_z, n_z) = 5y + n_z
 \end{aligned}$$



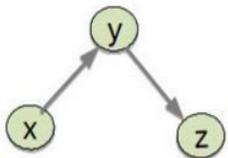
Densidad observacional

$$\mathbb{P}^{\mathcal{X}}$$



Densidad intervencional:

$$\mathbb{P}^{\mathcal{X} | do(y = f'_y(PA'_y, n'_y))}$$



Densidad “counterfactual”

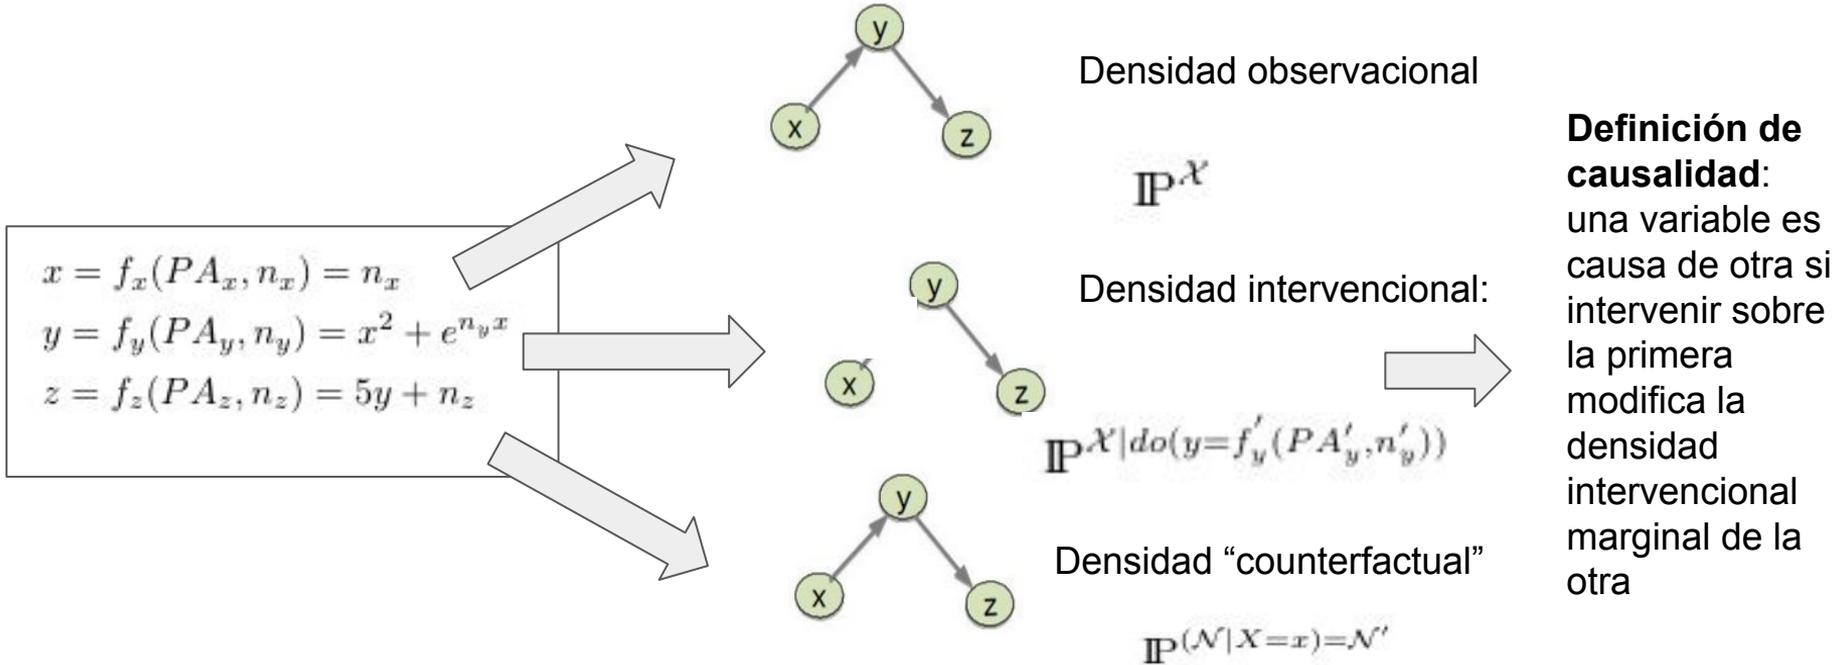
$$\mathbb{P}^{\mathcal{N} | X=x} = \mathcal{N}'$$

Definición de causalidad:
una variable es causa de otra si intervenir sobre la primera modifica la densidad intervencional marginal de la otra

Inferencia Causal: aprender el SEM con datos + supuestos

- experimentos controlados aportan datos de distribución intervencional
- ojo: modularidad implica que no todo cambia con intervencionales y “counterfactual”
- podemos usar datos de distintas densidades para hacer inferencia sobre el mismo SEM y su grafo! (y sobre densidades que nunca veremos!)

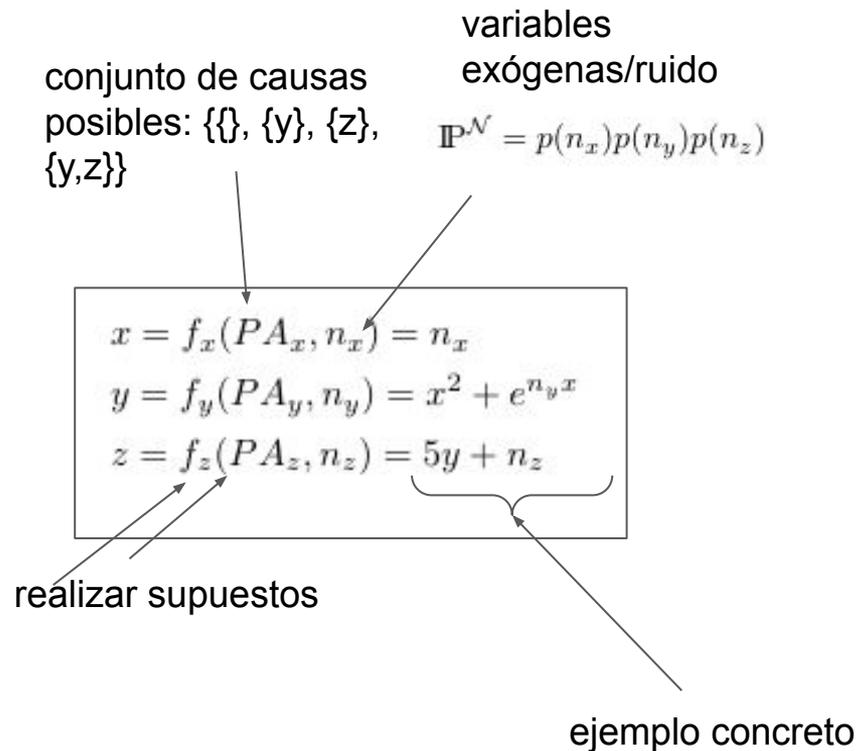
Marco matemático: Structural Equation Models



Difficultad: sin supuestos adicionales sobre clase de f y conjuntos $G=\{PA_x, PA_y, PA_z\}$ muy difícil o imposible identificar f y G (aún con muchos datos).

Pero ahí entra elaboración de **teoría**: usar conocimiento acumulado para acotar problema.

Marco matemático: Structural Equation Models



Aprendizaje de SEM

- Normalmente primero el grafo y después funciones
- Usar
 - datos de distintos experimentos y observacionales de forma coherente
 - propiedades de independencia que acotan posibles grafos
 - supuestos científicos sobre clase de funciones relaciones causales permitidas
 - otros supuestos más abstractos de parsimonia (~ model selection)
- Existen algunos desarrollos que cambian el problema de optimización discreto por uno continuo! Descenso por gradiente!

Marco matemático: Structural Equation Models

Inferencia Causal y SEMS dan un lenguaje matemático más rico para hablar de causalidad! Nuevas preguntas interesantes!:

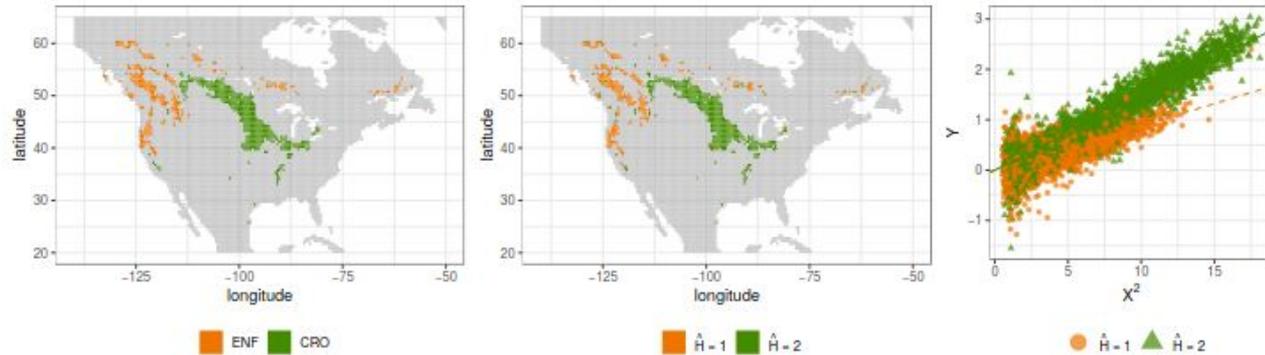
- Puedo aprender el grafo con puros datos observacionales?
Ej ciencia climática
- Cuantos experimentos (intervenciones) necesito para aprenderlo? **Ej genética**
- Como puedo combinar datos de diferentes experimentos y/o observacionales de forma coherente para aprender grafo, tamaño de efectos, ecuaciones

Marco matemático: Structural Equation Models

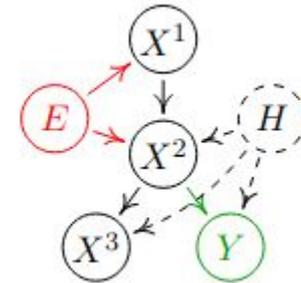
Inferencia Causal y SEMS dan un lenguaje matemático más rico para hablar de causalidad! Nuevas preguntas interesantes!:

- Puedo aprender el grafo con puros datos observacionales?
Ej ciencia climática
- Cuantos experimentos (intervenciones) necesito para aprenderlo? **Ej genética**
- Como puedo combinar datos de diferentes experimentos y/o observacionales de forma coherente para aprender grafo, tamaño de efectos, ecuaciones

Ejemplo de aplicación: clasificación de tipo de suelo



variable	description
Y	sun-induced fluorescence (SIF)
X^1	incident shortwave radiation (SW)
X^2	absorbed photosynthetically active radiation (APAR _{chl})
X^3	gross primary productivity (GPP)
H	vegetation type



De “Switching Regression Models and Causal Inference in the Presence of Discrete Latent Variables” (R. Christensen y J. Peters)

Inferencia causal y Estadística

Diferencia entre inferencia causal y ciencia : Inferencia causal da únicamente da un marco y lenguaje para hacer preguntas e integrar datos observacionales y experimentales

Machine learning y estadística: tradicionalmente son una herramienta de la estadística:

- Cuando se puede hacer experimentos: diseño de experimento + ANOVA (normalmente 1 solo experimento a la vez)
- cuando no: usar experimentos idealizados, datos observacionales

Con **Inferencia causal**

- Son herramientas para navegar el espacio de SEMs (Grafo + funciones)
- Primero hay que hacer supuestos para acotar el problema.
 - sobre clase de funciones
 - variables relevantes
 - relaciones causales permitidas

Limitaciones: la definición del sistema en “variables” con ciertas unidades de medición ya recoge sesgo

Automatic scientist? AI? Se tiene un marco mas rico para integrar la cadena de datos obtenidos por intervenciones del agente. Aún así es difícil resumir toda la intuición del científico en este marco: todos los datos recibidos y filtrados por el subconsciente.

Inferencia Causal y Redes Neuronales

Relaciones con otros campos:

- ML:
 - Estadística robusta y generalización: si aprendemos el grafo podemos generalizar para densidades intervencionales!
- AI:
 - one-shot learning, Reinforcement learning (Exploration)
- NNs
 - Otro tipo de modelo con el cual estimar modelos pero posible aprender espacio latente y, representaciones causales
 - estructura espacio temporal -> supuestos mas abstractos
 - autoencoders, disentanglement -> búsqueda de representaciones causales! -> Usar penalizaciones “causales” (independencia, parsimonia, numero de intervenciones)
 - modelos generativos potentes (eg Normalizing flows, GANs)
- Estacionariedad: no-estacionariedad generada por diferentes densidades intervencionales
- XAI: si los modelos son causales no hay necesidad de explicarlos

Conclusión: ¿Que tienen que ver la **Estadística** y ~~la Neurociencia~~ con la modelización en ~~Física~~ **Ciencia**?:

La inferencia causal da un marco y lenguaje útil para la ciencia para:

- utilizar datos de distintos experimentos y observacionales de forma coherente (usar estadística y ML!)
- preguntarse sobre que tipos de datos son necesarios (cuantos experimentos, es suficiente observaciones?)
- incorporar supuestos o conocimiento científico anterior

PONENTES

* Mariua Martinez-Garcia (UJI) ——— Inteligencia artificial? aprendiendo de la biología

* Alex Gomez-Villa (UAB) ——— Las neuronas artificiales hacen cosas increíbles!

* Gonzalo Mateo (UV) ——— Las neuronas artificiales simulan procesos físicos

* Adriau Martiu (UPF) ——— Errores de percepción en neuronas artificiales

* Emiliano Diaz (UV) ——— Inferencia Causal a partir de datos

* Valero Laparra (UV) ——— IA a debate!

LA INTELIGENCIA ARTIFICIAL A DEBATE:

	A parrot	Machine learning algorithm
Learns random phrases	✓	✓
Doesn't understand shit about what it learns	✓	✓
Occasionally speaks nonsense	✓	✓
Is a cute birdie parrot	✓	✗

- **CIENCIA AUTOMÁTICA?** La inferencia científica y la elaboración de teorías ¿es un mera cuestión de escalado de las técnicas de aprendizaje estadístico?. ¿Necesitamos data scientists o simplemente scientists?
- **PODEMOS REPRODUCIR EL CEREBRO?** ¿la solución al problema del funcionamiento cerebral es un mero escalado de las redes neuronales actuales?. ¿Crees en el Human Brain Project? -from extreme low-level to high level- .
- **DINERO:** al menos, ¿podemos forrarnos con el big-data? (en ciencia -haciendo papers- y en economía -haciendo billetes-)
- **SOCIEDAD:**
 - ¿Dejarías que te contratase un robot?
 - ¿Dejarías que la política económica la dictase un algoritmo?
 - ¿Crees en los anuncios personalizados?
 - ¿Te liarías con Siri o con Alexa?
 - ¿Arte o humor sintéticos?
-