

JORNADAS SARH

Inteligencia Artificial Aplicada a la Física Médica



SOCIEDAD ANDALUZA DE
RADIOFÍSICA HOSPITALARIA
www.sarh.es

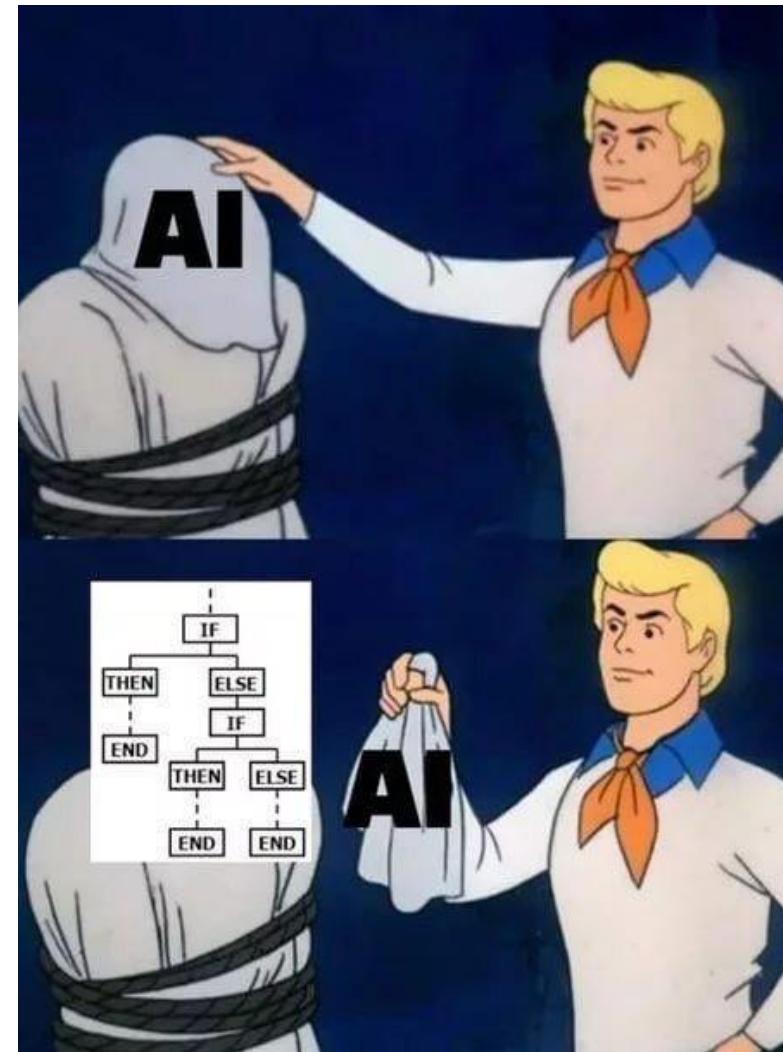
Parador de Antequera
14 de noviembre 2025

Desmitificando la inteligencia artificial: desde la teoría a la práctica clínica

A. Giuliano Mirabella

amirabella@us.es





<https://pbs.twimg.com/media/FIVeC2MWQAAAsnvz.jpg>



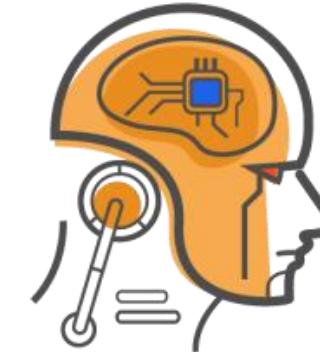
IA “narrow”

Diseñada para realizar
una tarea concreta.



IA “general”

Diseñada para realizar
tareas diferentes en
dominios diferentes.



IA “super”

Sistemas más
inteligentes que los
humanos.

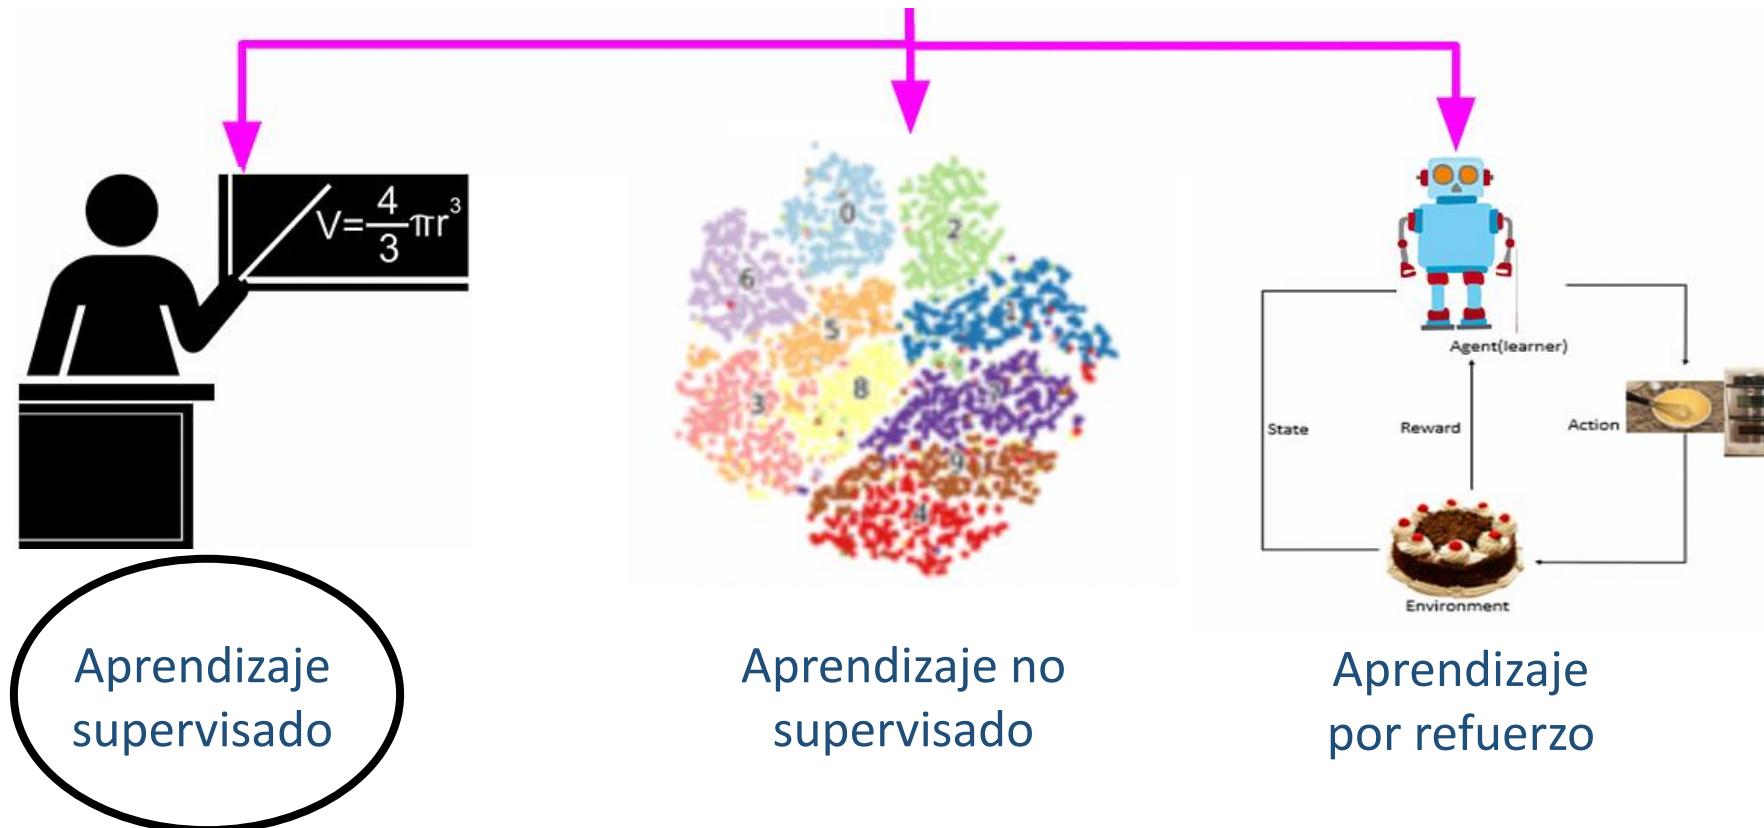
Contenido

- Bases del machine learning
- Perceptrón multicapa (MLP)
- Redes neuronales convolucionales (CNNs)
- Modelos de secuencia
- Riesgos
- Nuestra investigación
 - Aceleración de Monte Carlo
 - Personalización de dosis

Contenido

- **Bases del machine learning**
- Perceptrón multicapa (MLP)
- Redes neuronales convolucionales (CNNs)
- Modelos de secuencia
- Riesgos
- Nuestra investigación
 - Aceleración de Monte Carlo
 - Personalización de dosis

Bases del machine learning



<https://arshren.medium.com/supervised-unsupervised-and-reinforcement-learning-245b59709f68>

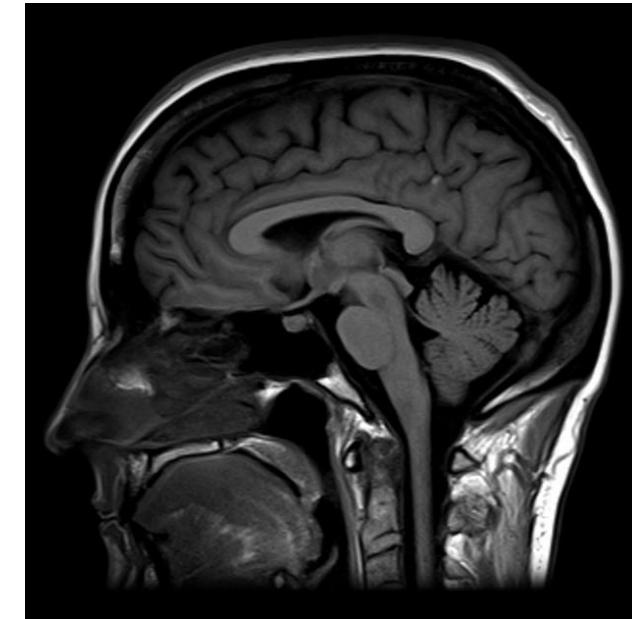
Bases del machine learning

Datos estructurados

vs.

Datos no estructurados

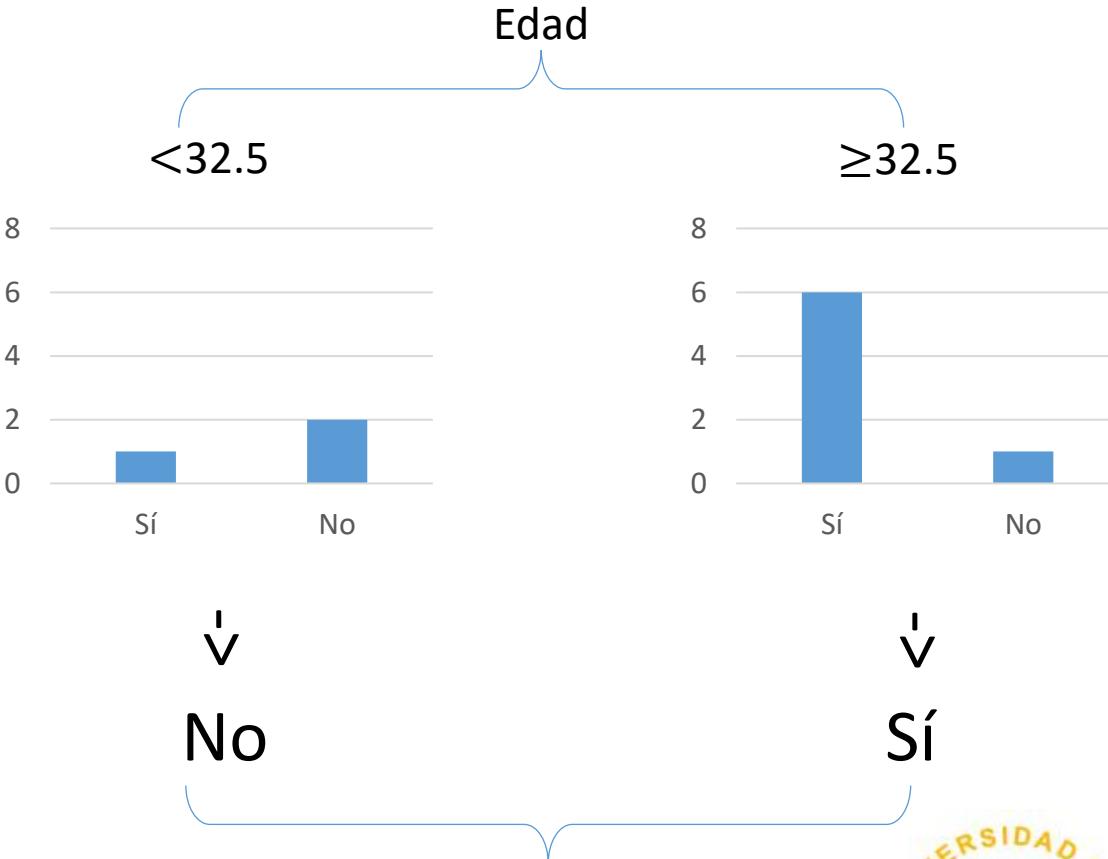
ID	Age	BMI	Blood pressure	Diabetes
1	45	28	130	Sí
2	50	35	140	No
3	25	22	110	Sí
...



<https://radiopaedia.org/articles/mri-brain-summary>

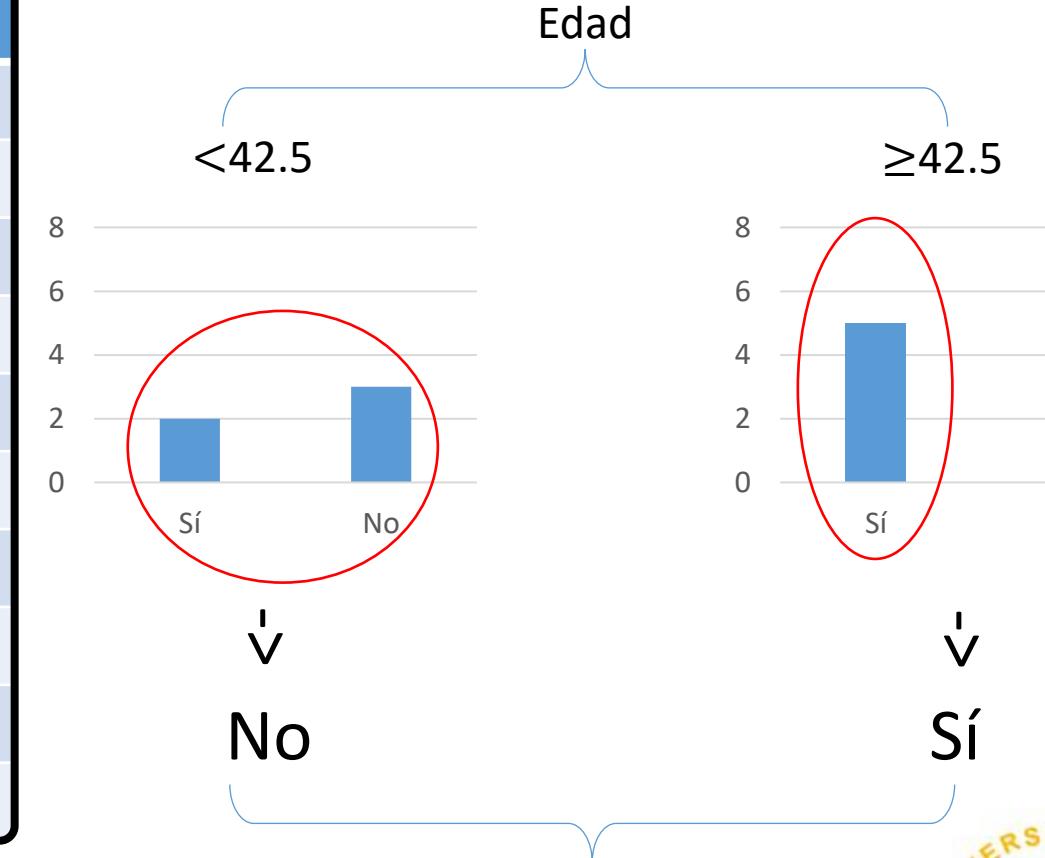
ID	Edad	BMI	Presión sanguínea	Insulina	Glucosa	Historia familiar	Diabetes
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí

ID	Edad	BMI	BP	Insulina	Glucosa	Historia	Target
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí



Accuracy: 80%

ID	Edad	BMI	BP	Insulina	Glucosa	Historia	Target
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí



Accuracy: 80%

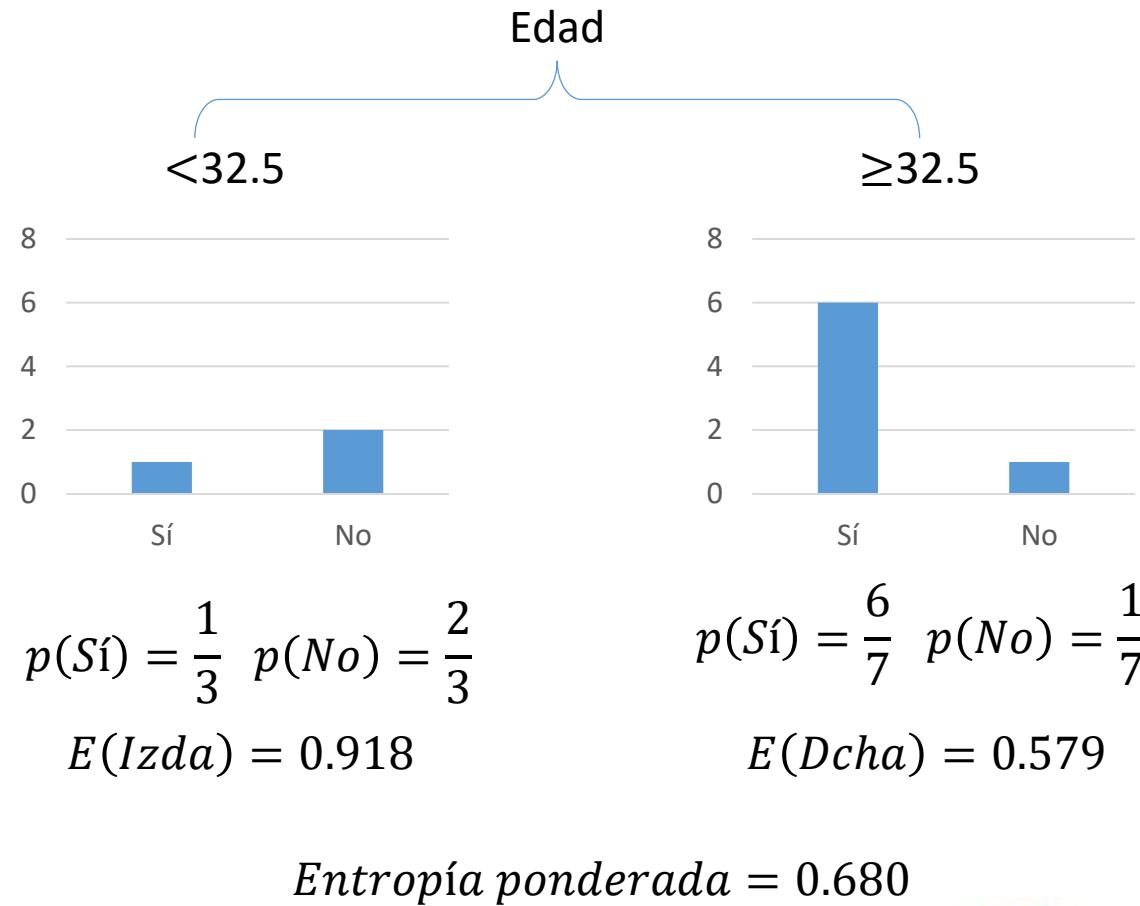
ID	Edad	BMI	BP	Insulina	Glucosa	Historia	Target
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí

$$Entropía(S) = - \sum_{i=1}^c p_i \log_2 p_i$$

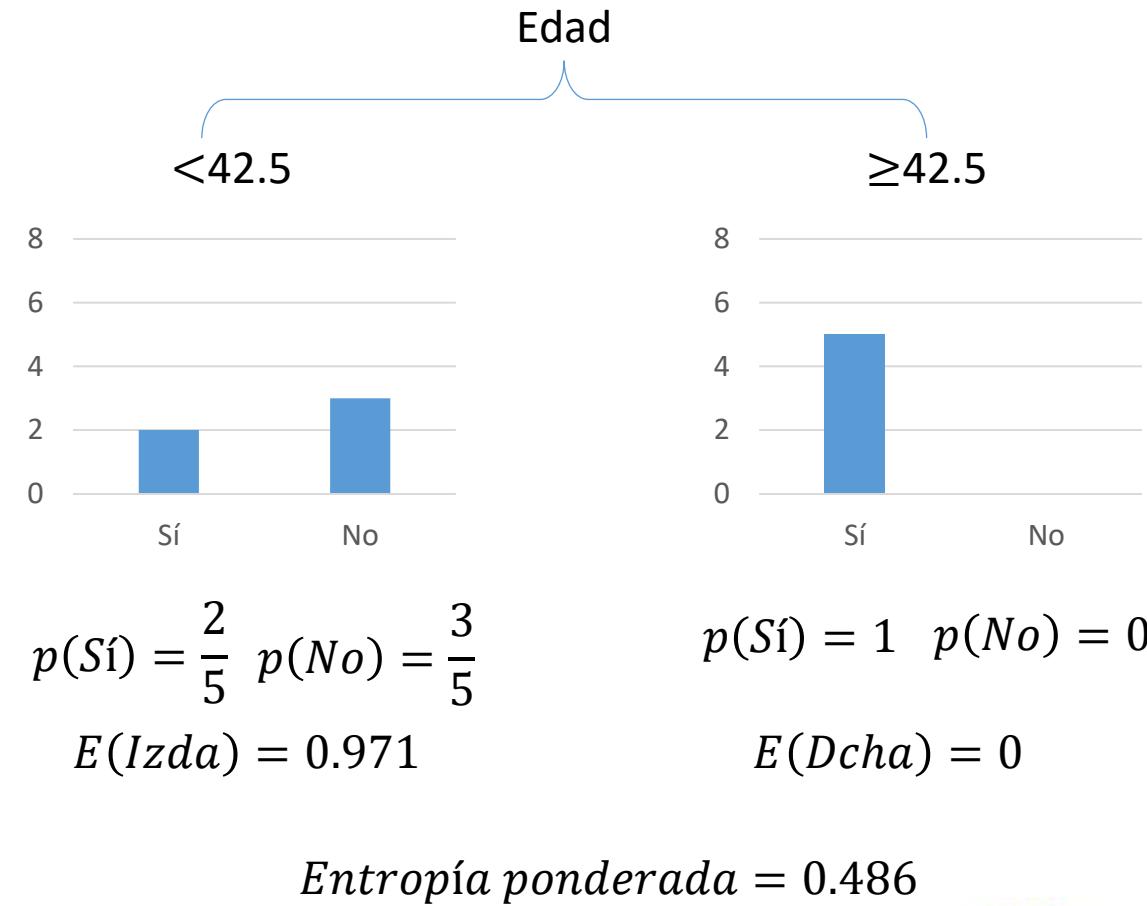
$$p(\text{Sí}) = \frac{7}{10} \quad p(\text{No}) = \frac{3}{10}$$

$$Entropía(S) = - \left(\frac{7}{10} \log_2 \frac{7}{10} + \frac{3}{10} \log_2 \frac{3}{10} \right) \\ = 0.881$$

ID	Edad	BMI	BP	Insulina	Glucosa	Historia	Target
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí



ID	Edad	BMI	BP	Insulina	Glucosa	Historia	Target
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí



ID	Edad	BMI	BP	Insulina	Glucosa	Historia	Target
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí

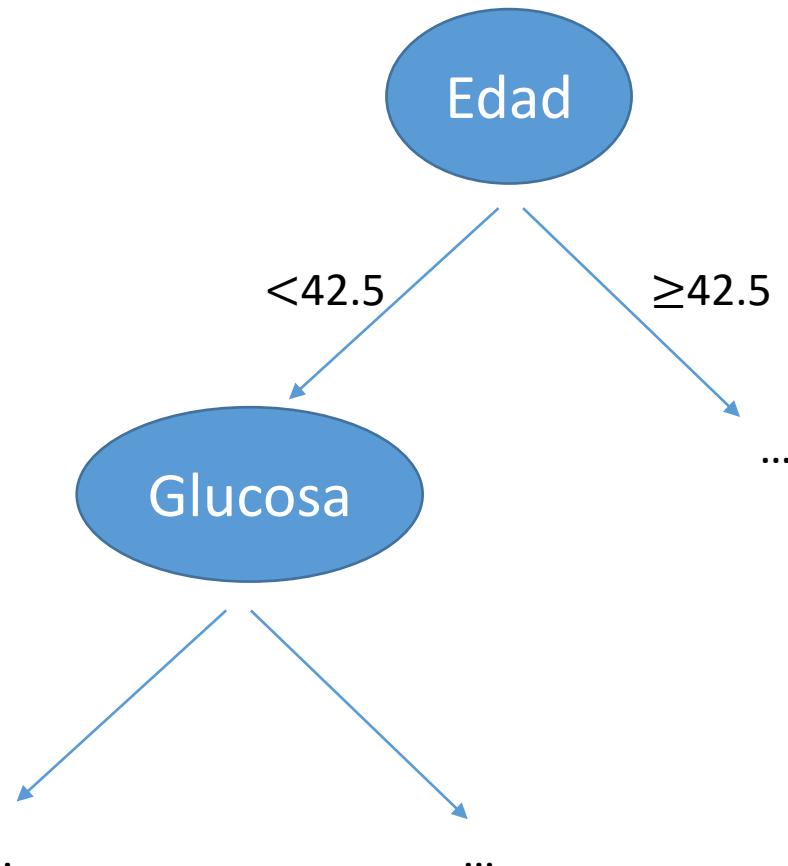
~~Edad < 32.5
0.680~~

vs.

Edad < 42.5
0.4855

ID	Edad	BMI	BP	Insulina	Glucosa	Historia	Target
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí

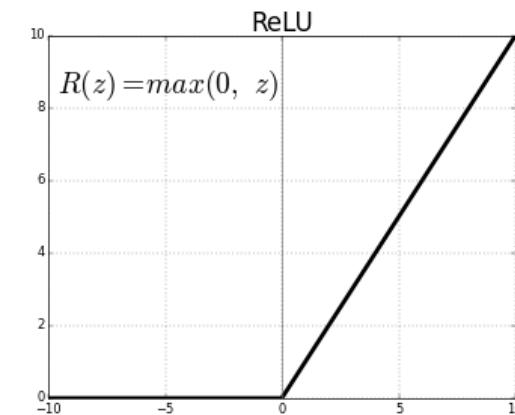
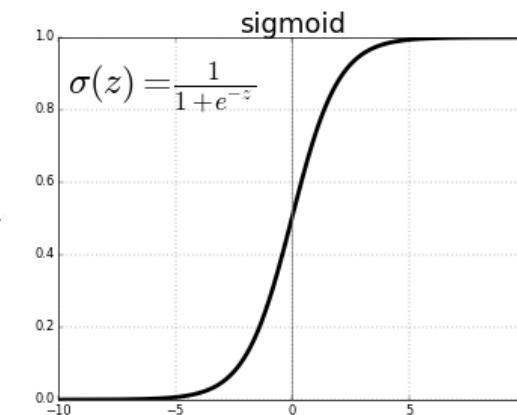
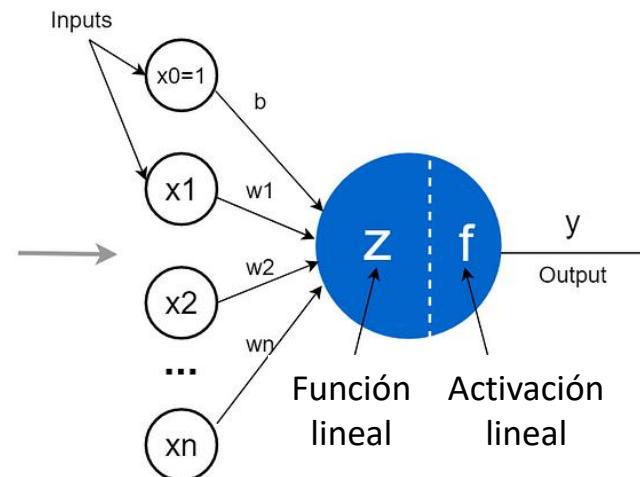
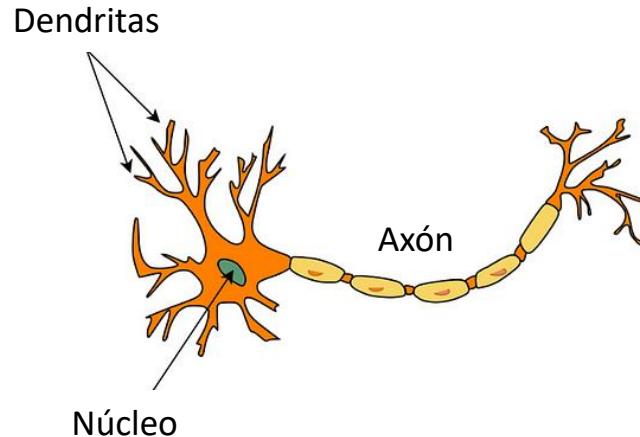
Árbol de decisión



Contenido

- Bases del machine learning
- **Perceptrón multicapa (MLP)**
- Redes neuronales convolucionales (CNNs)
- Modelos de secuencia
- Riesgos
- Nuestra investigación
 - Aceleración de Monte Carlo
 - Personalización de dosis

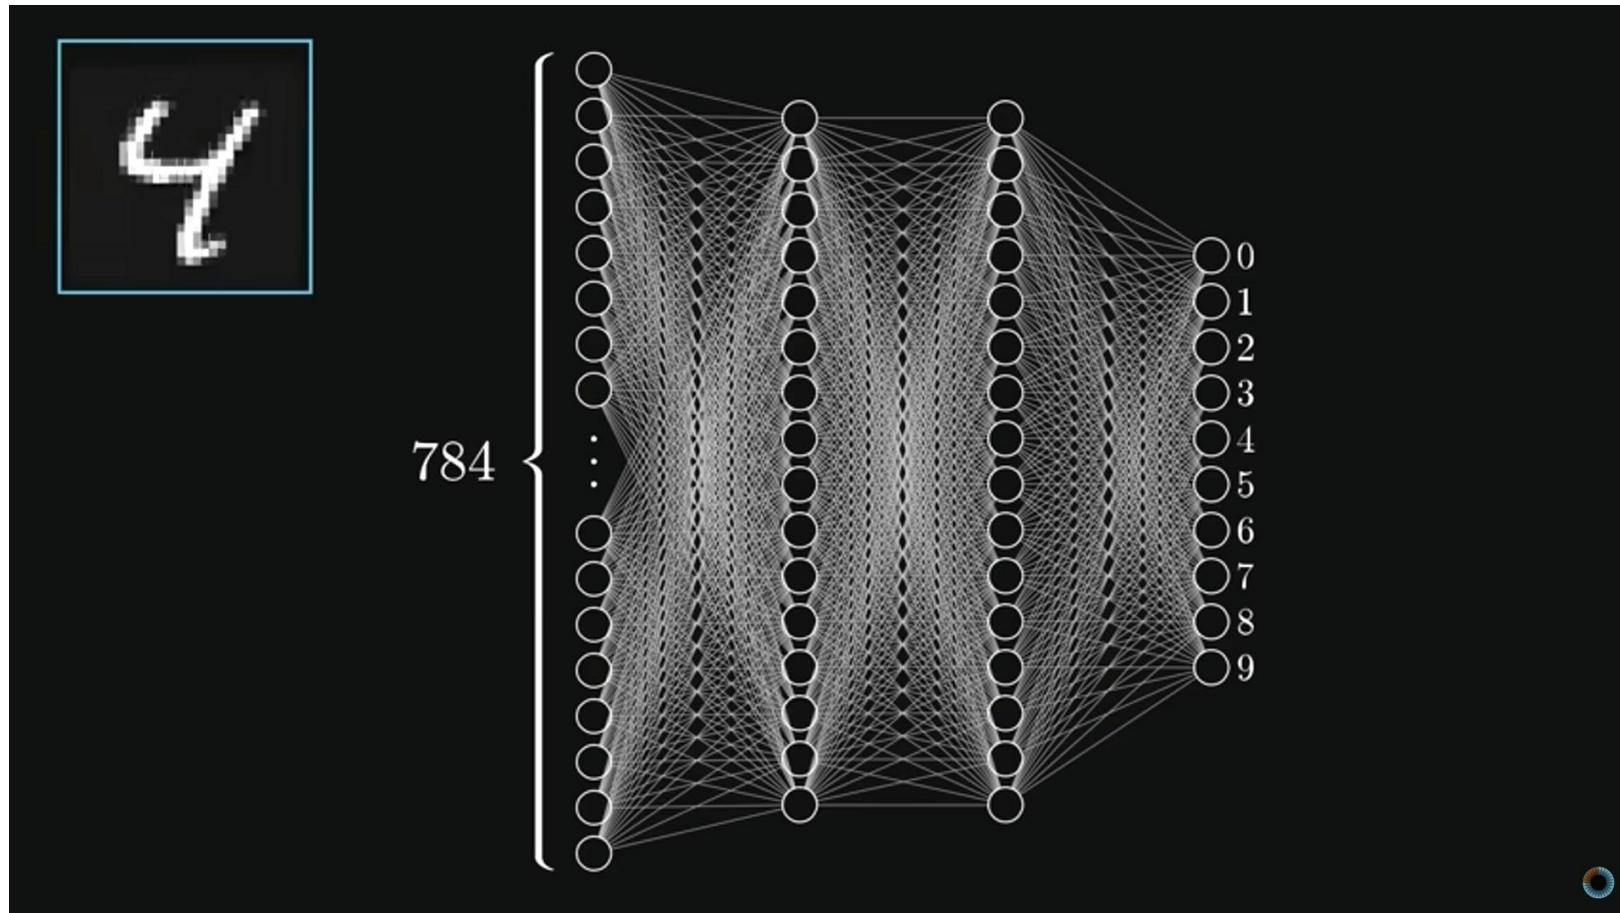
Perceptrón multicapa (MLP)



$$Z = \omega_1 x_1 + \omega_2 x_2 + \cdots + \omega_n x_n + b x_0$$

<https://towardsdatascience.com/the-concept-of-artificial-neurons-perceptrons-in-neural-networks-fab22249cbfc>

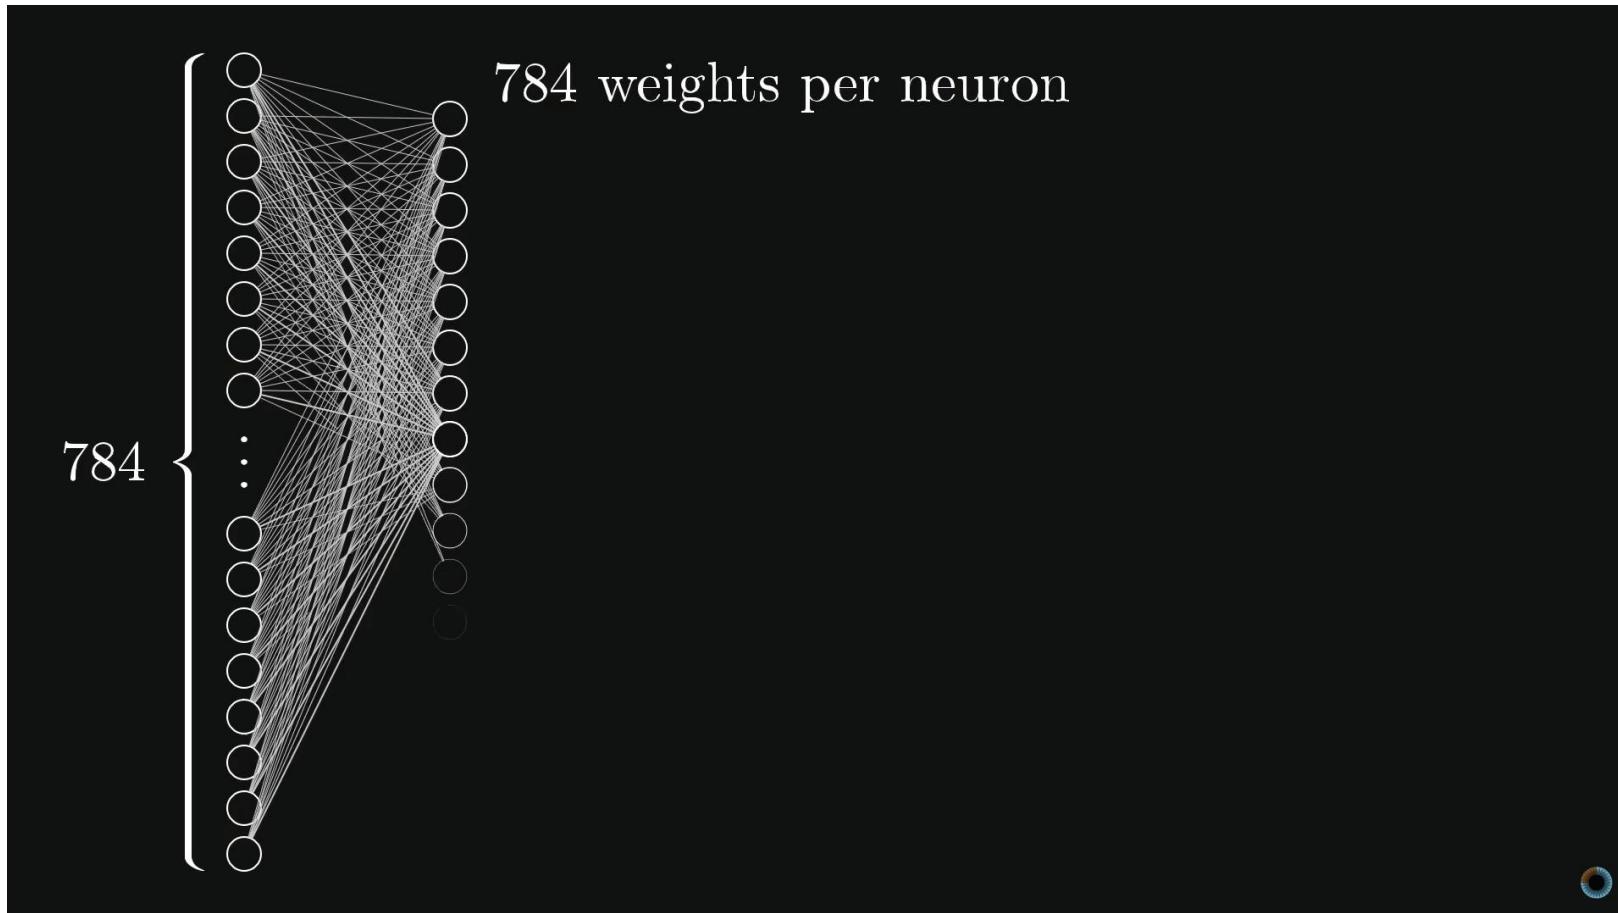
Perceptrón multicapa (MLP)



<https://www.youtube.com/c/3blue1brown>



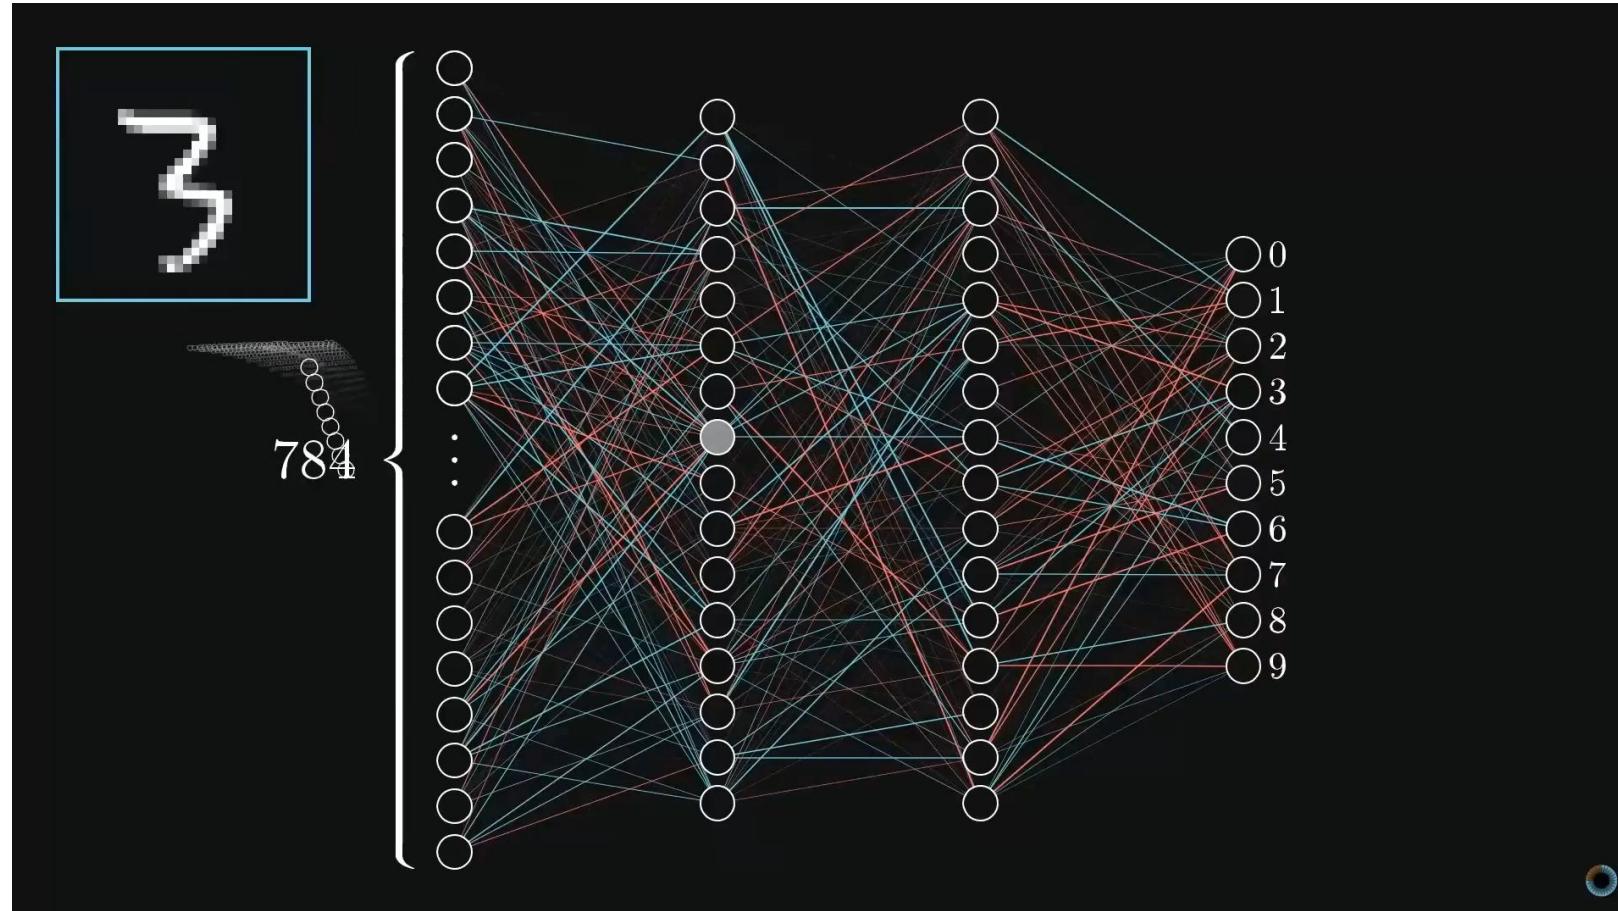
Perceptrón multicapa (MLP)



<https://www.youtube.com/c/3blue1brown>

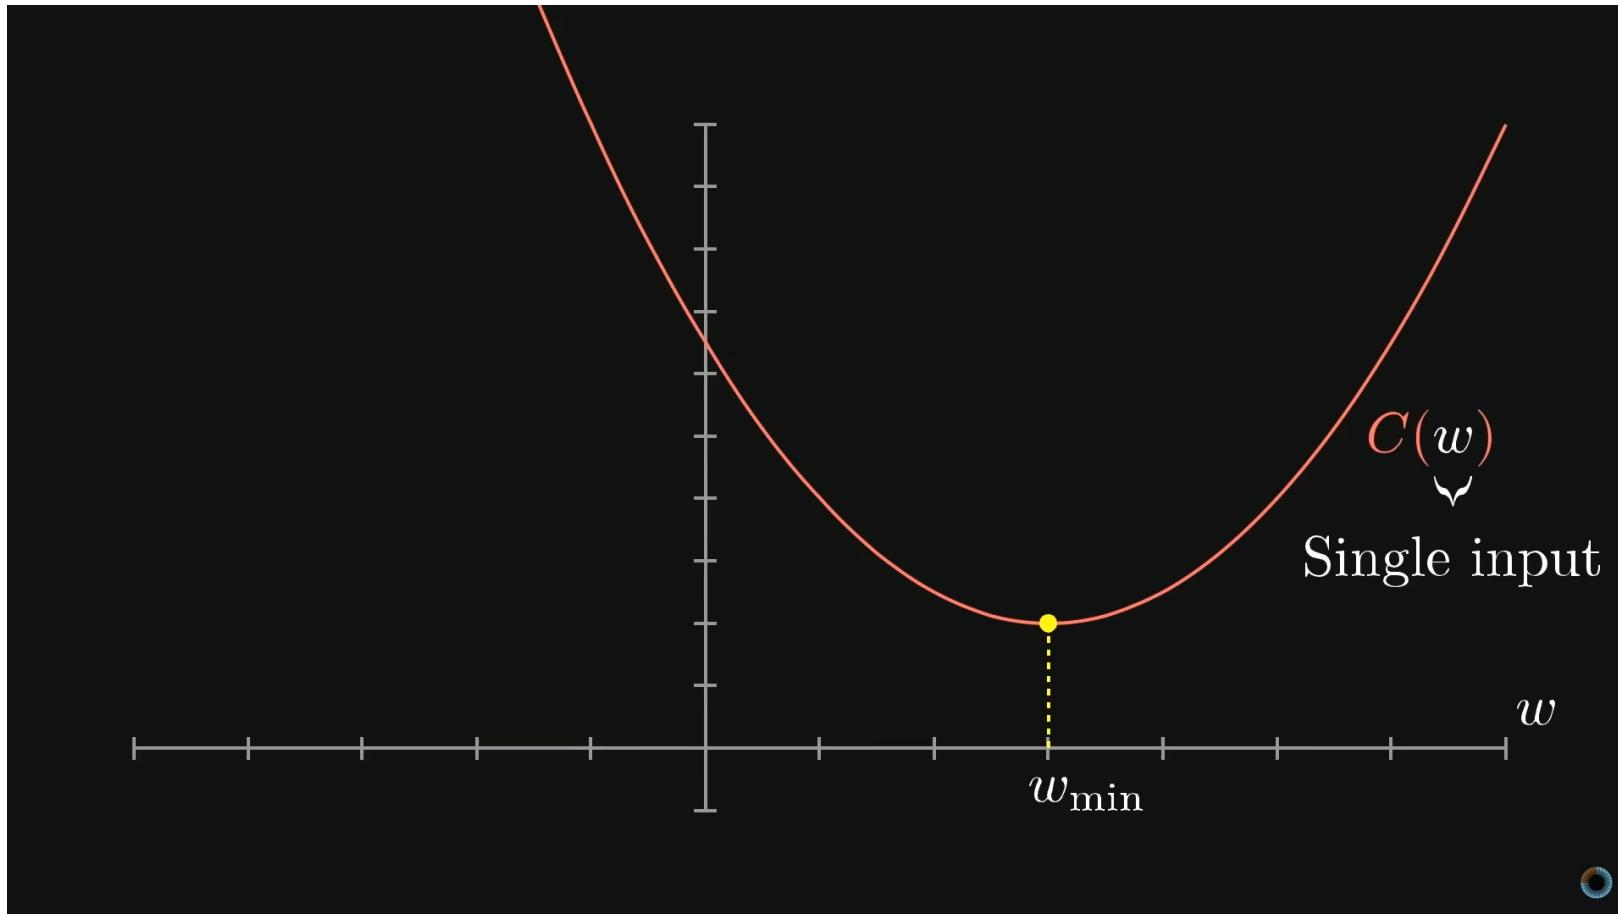


Perceptrón multicapa (MLP)



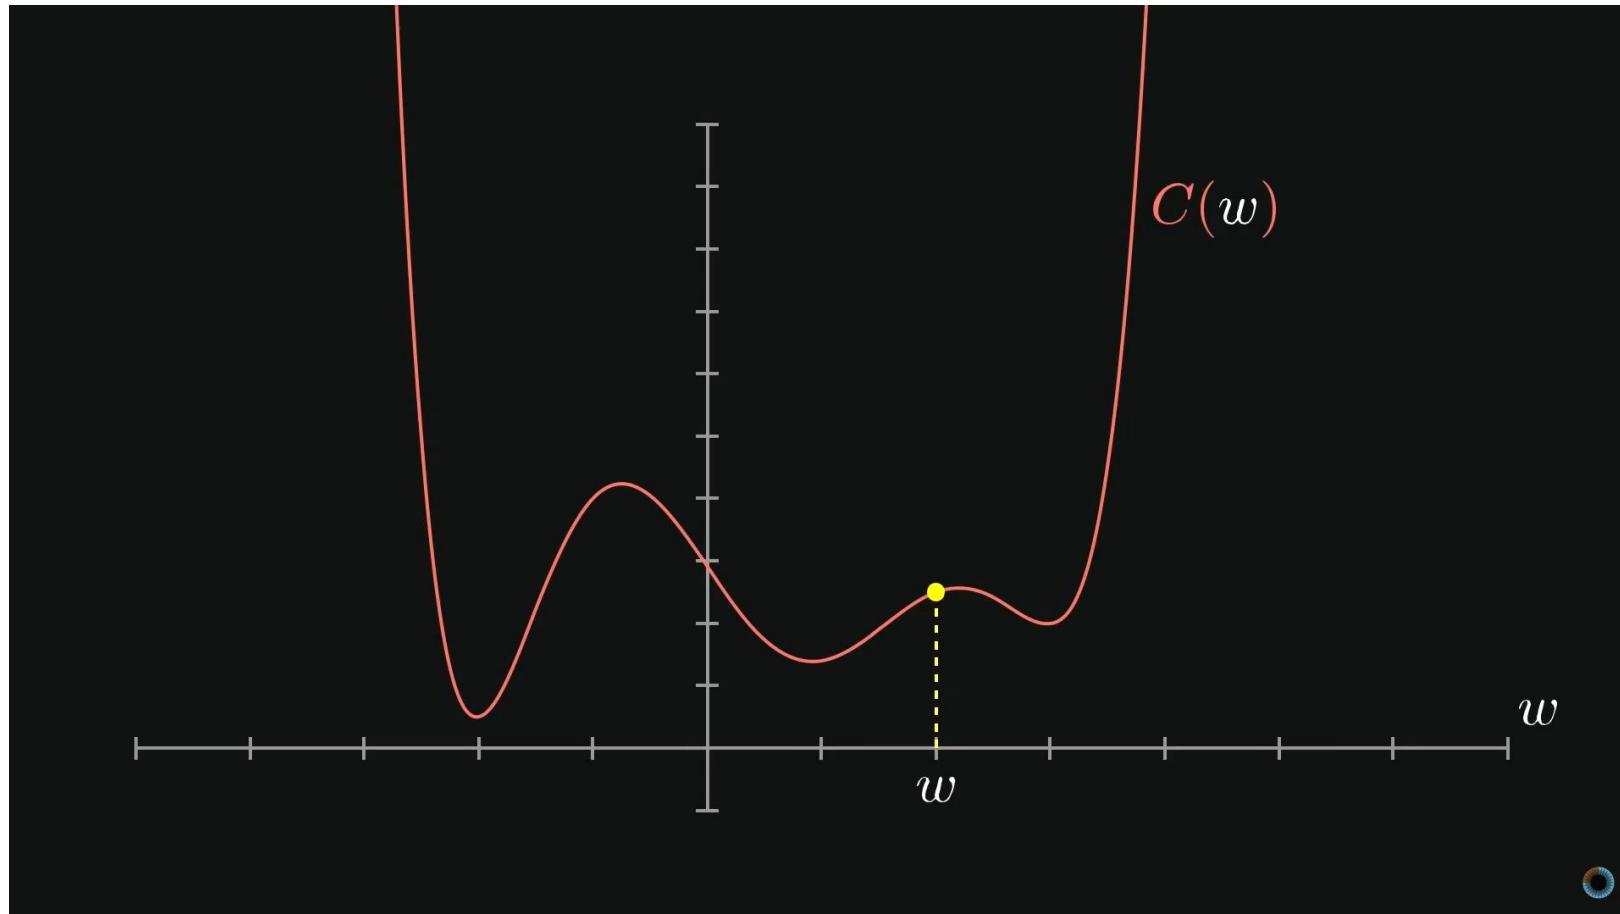
<https://www.youtube.com/c/3blue1brown>

Perceptrón multicapa (MLP)



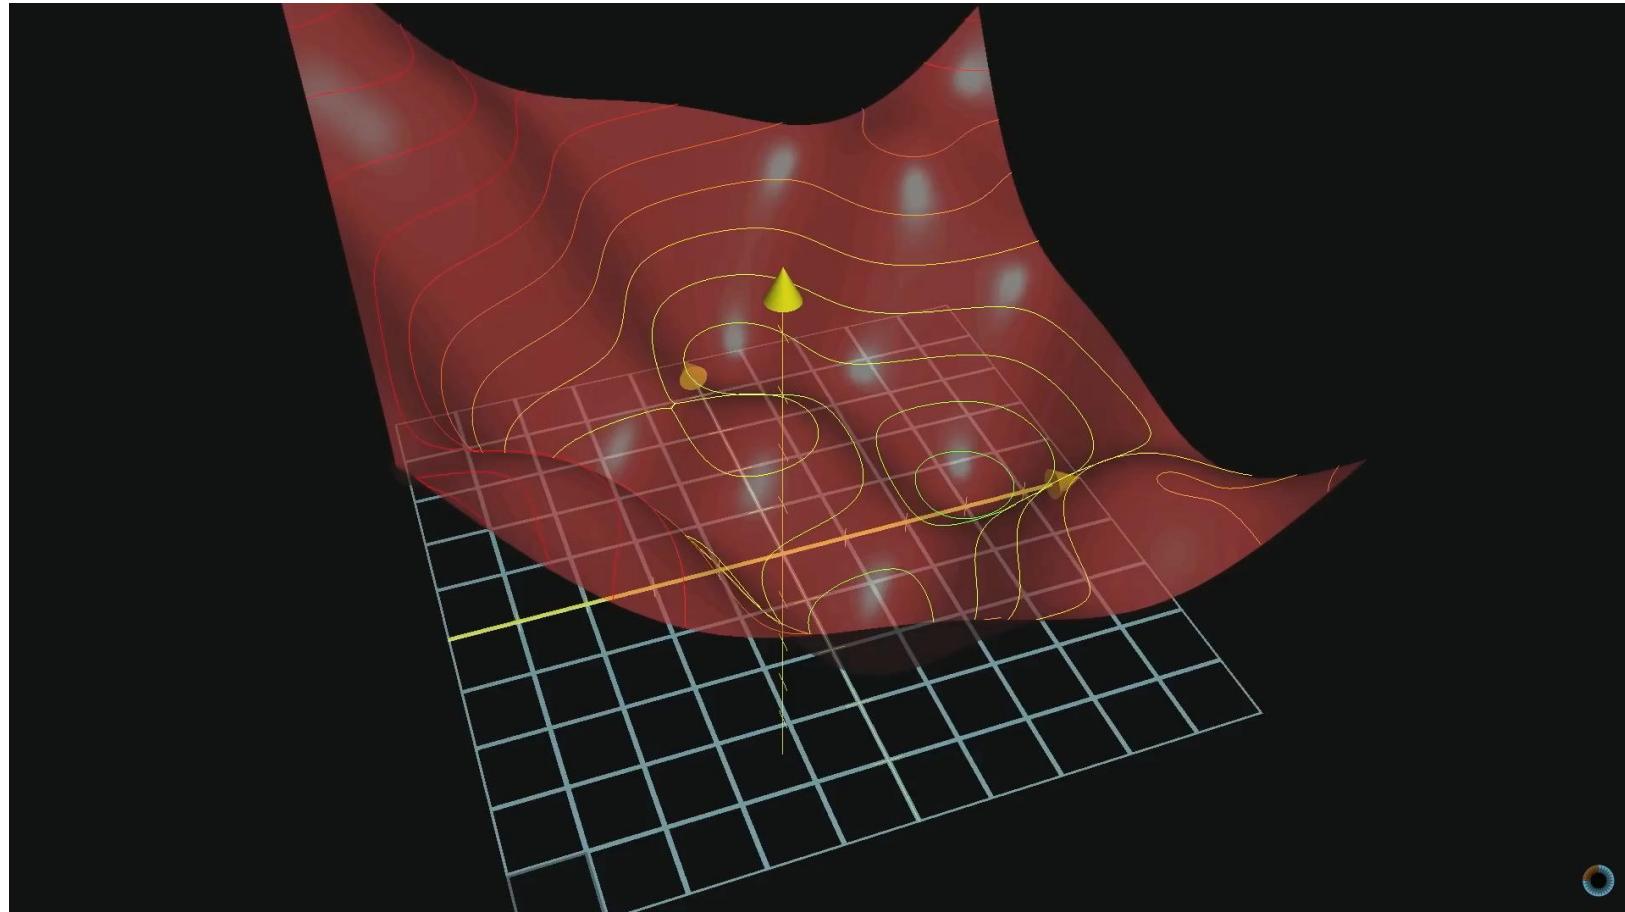
<https://www.youtube.com/c/3blue1brown>

Perceptrón multicapa (MLP)



<https://www.youtube.com/c/3blue1brown>

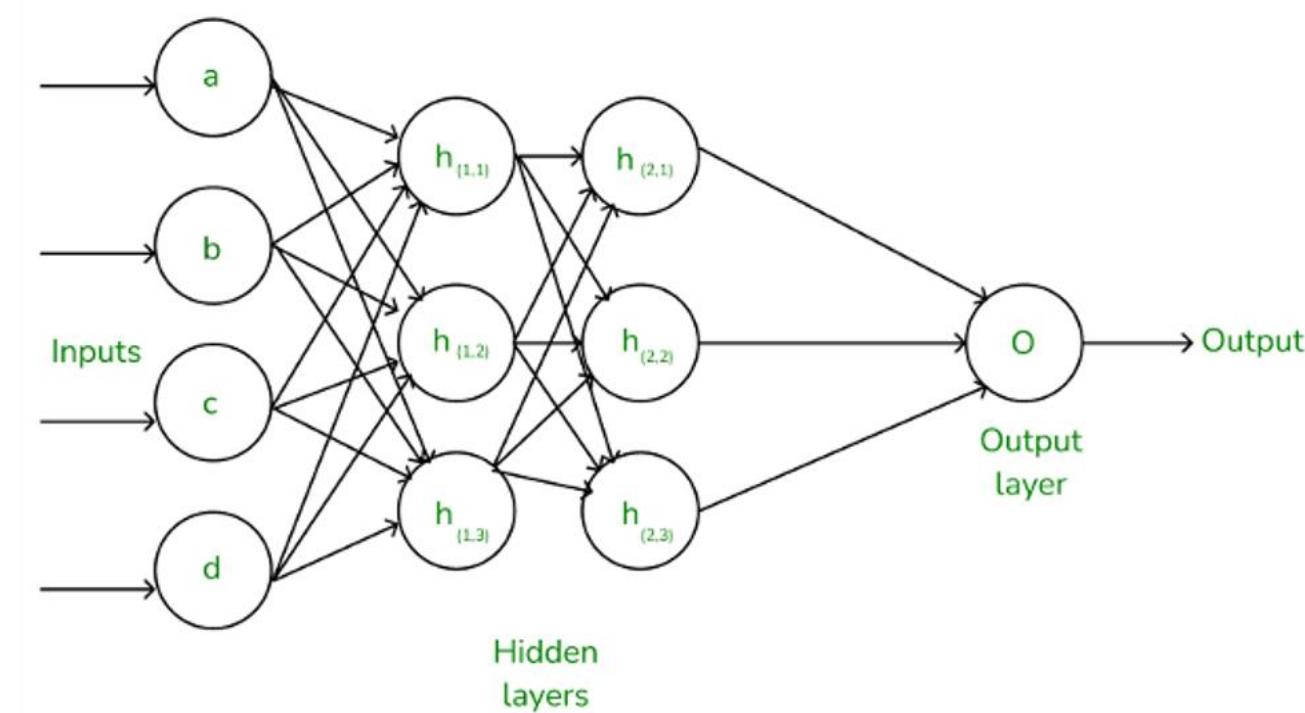
Perceptrón multicapa (MLP)



<https://www.youtube.com/c/3blue1brown>

Perceptrón multicapa (MLP)

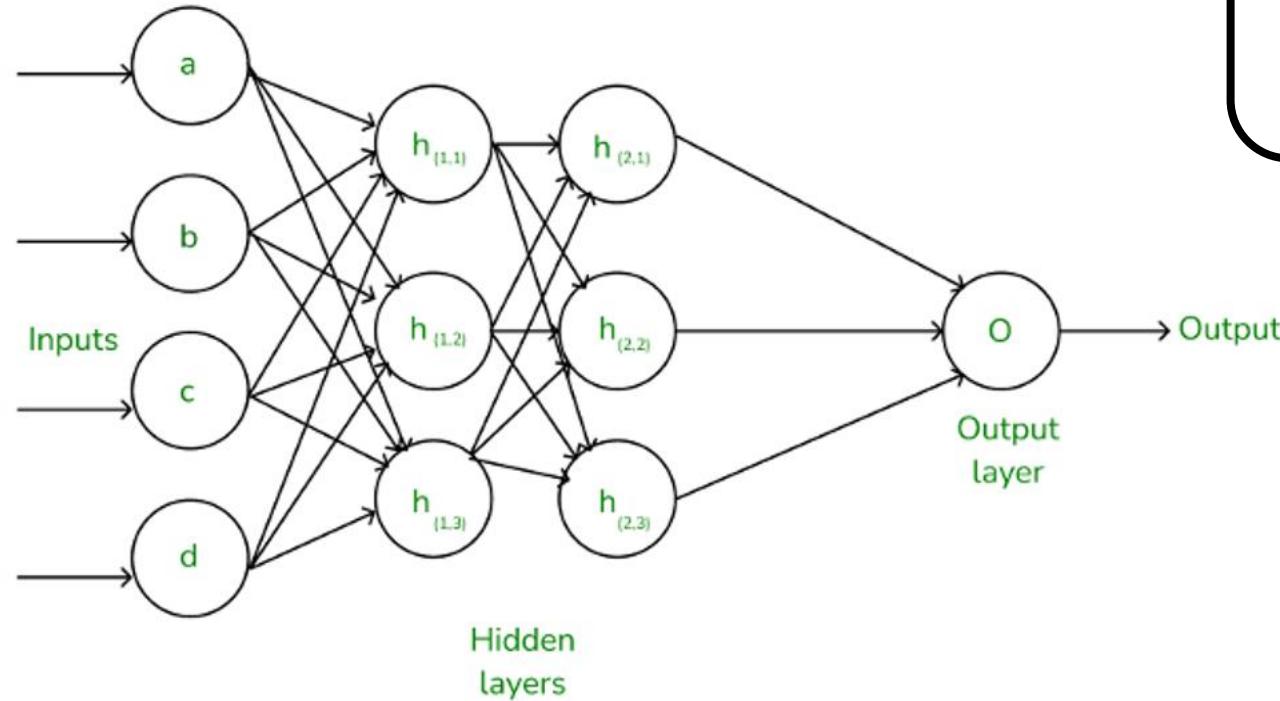
$$\omega_{ji}^{(l)} := \omega_{ji}^{(l)} - \eta \nabla_{\omega_{ji}} Loss$$



<https://www.geeksforgeeks.org/backpropagation-in-neural-network/>

Perceptrón multicapa (MLP)

$$\omega_{ji}^{(l)} := \omega_{ji}^{(l)} - \eta \nabla_{\omega_{ji}} Loss$$

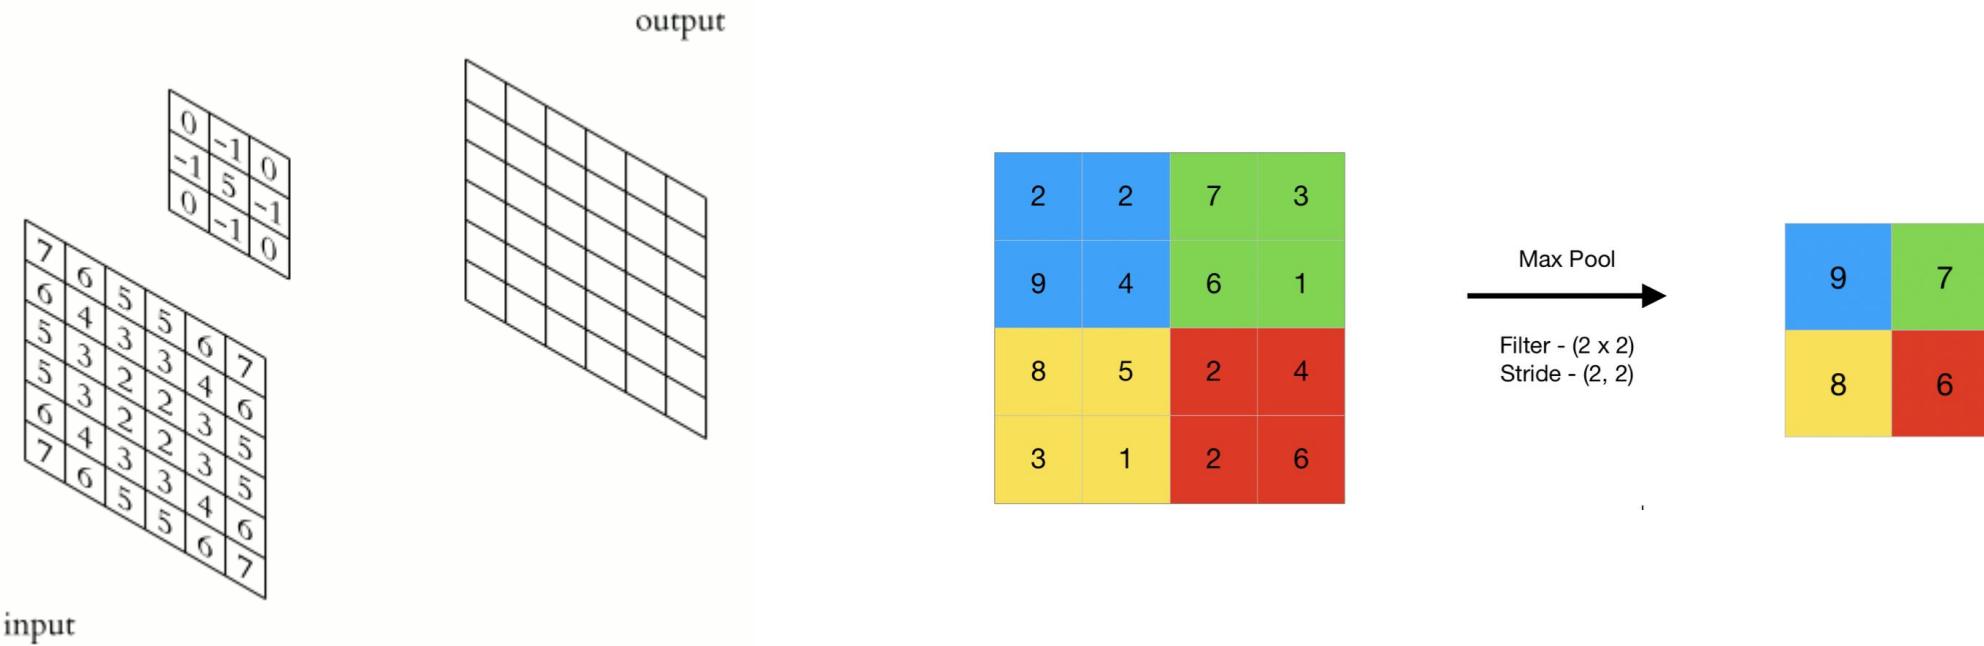


“Aprender” es buscar:
 $\operatorname{argmin}_{\omega_{ji}^{(l)}} Loss$

Contenido

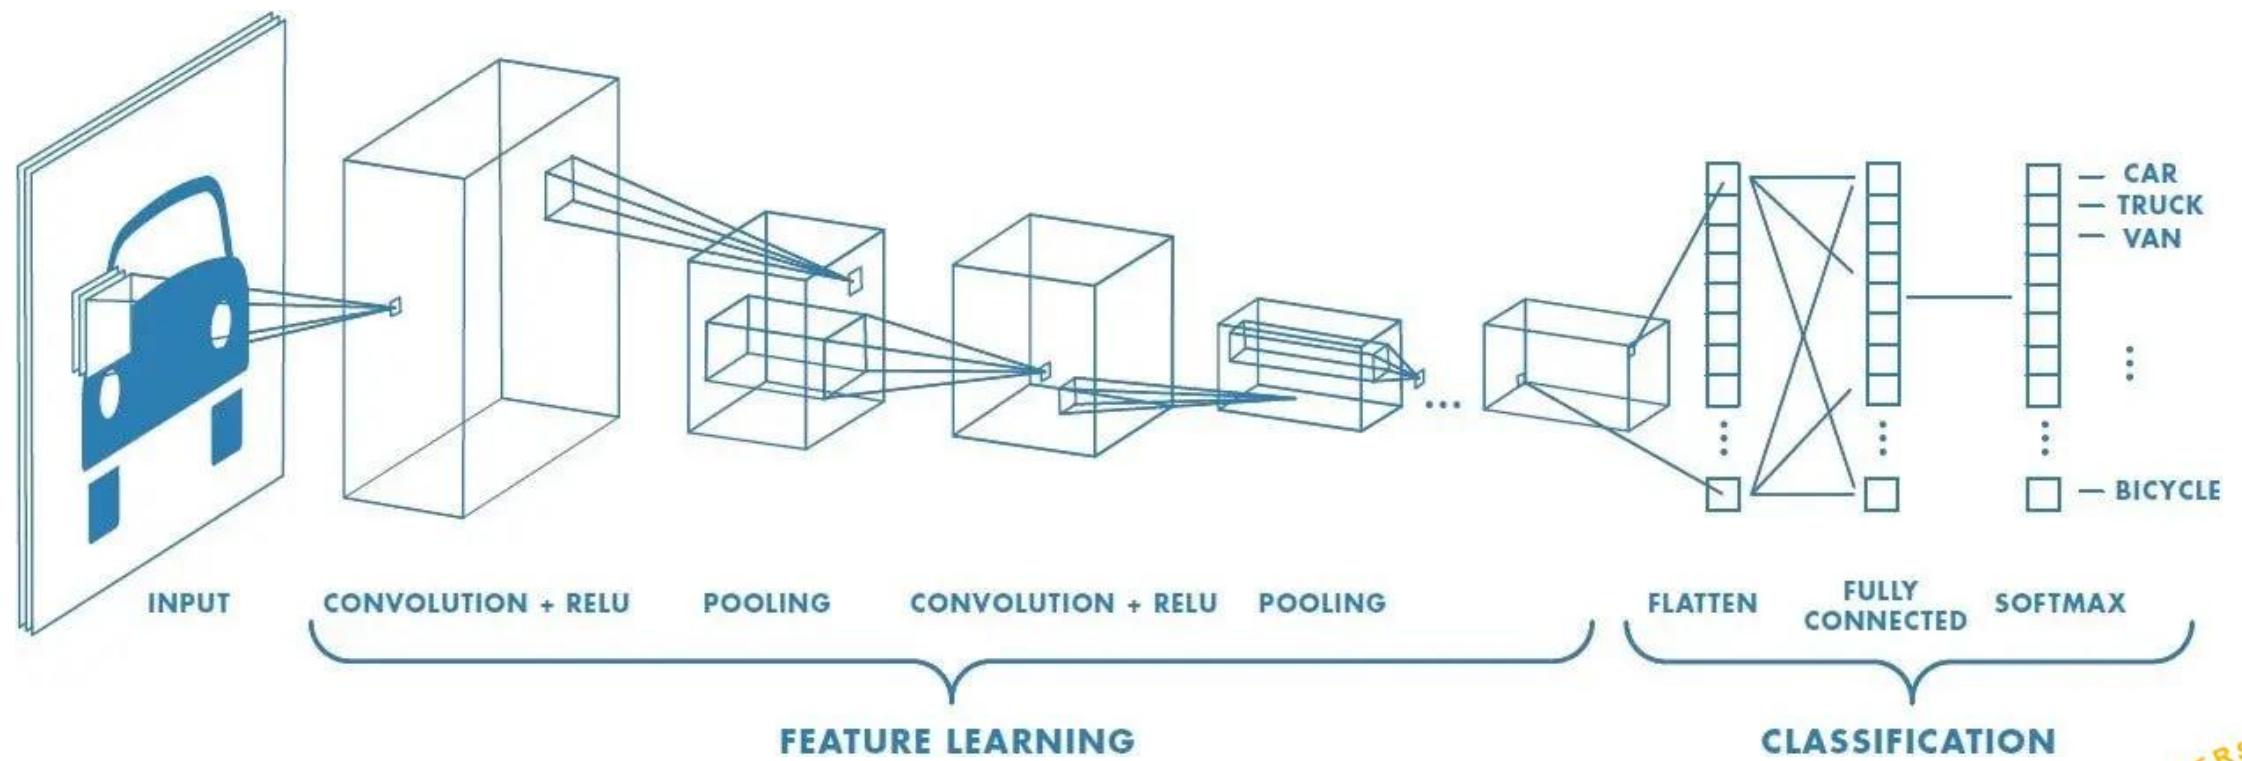
- Bases del machine learning
- Perceptrón multicapa (MLP)
- **Redes neuronales convolucionales (CNNs)**
- Modelos de secuencia
- Riesgos
- Nuestra investigación
 - Aceleración de Monte Carlo
 - Personalización de dosis

Redes neuronales convolucionales (CNNs)



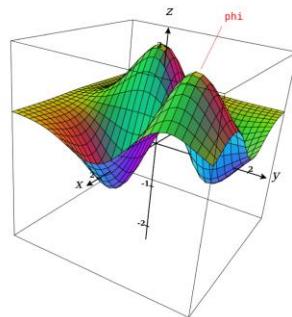
<https://www.geeksforgeeks.org/cnn-introduction-to-pooling-layer/>

Redes neuronales convolucionales (CNNs)

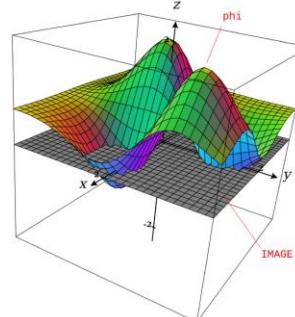


<https://saturncloud.io/blog/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way/>

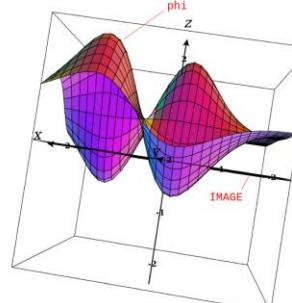
“AI and Digital Images Processing in Melanoma Detection”, 2020



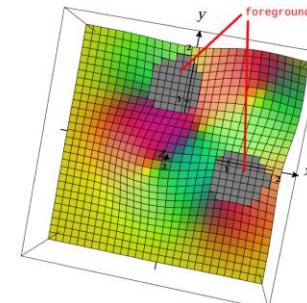
(a) The ϕ function



(b) ϕ function and the plane $z = 0$



(c) ϕ and $z = 0$ intersection



(d) foreground regions, $\phi < 0$

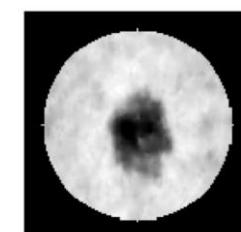
Figure 3.21: The Chan-Vese ϕ function visualized.



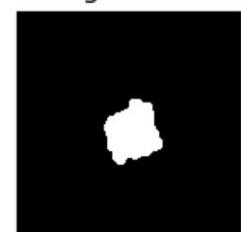
original



hairs removed



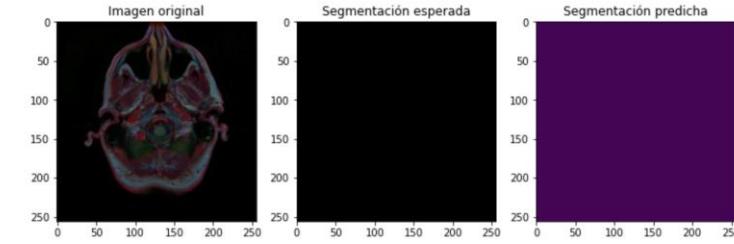
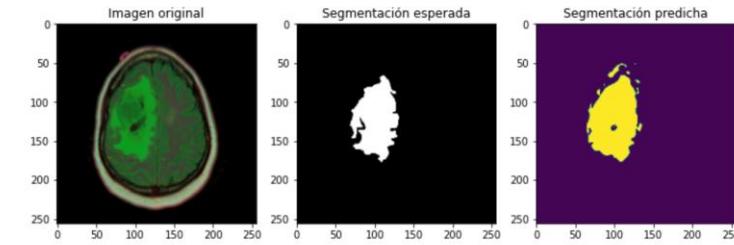
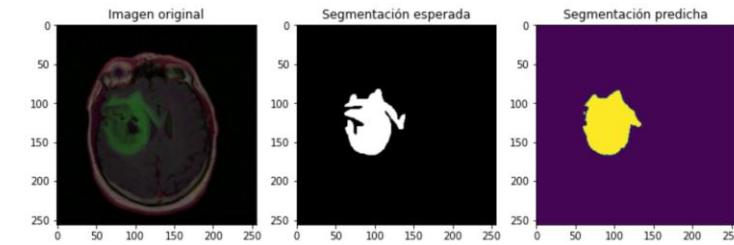
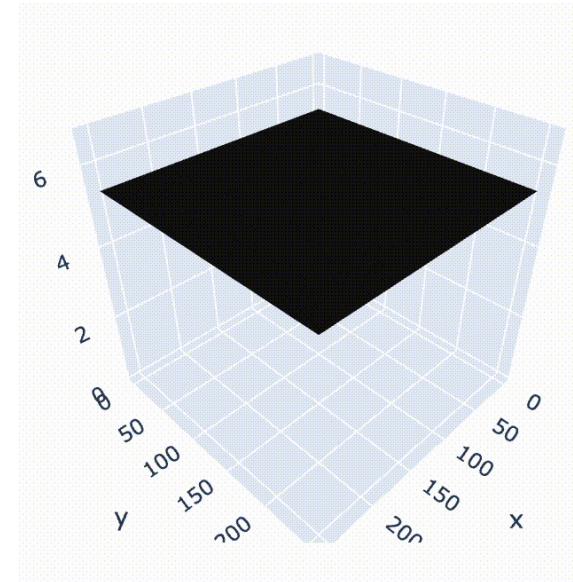
circle mask



segmented

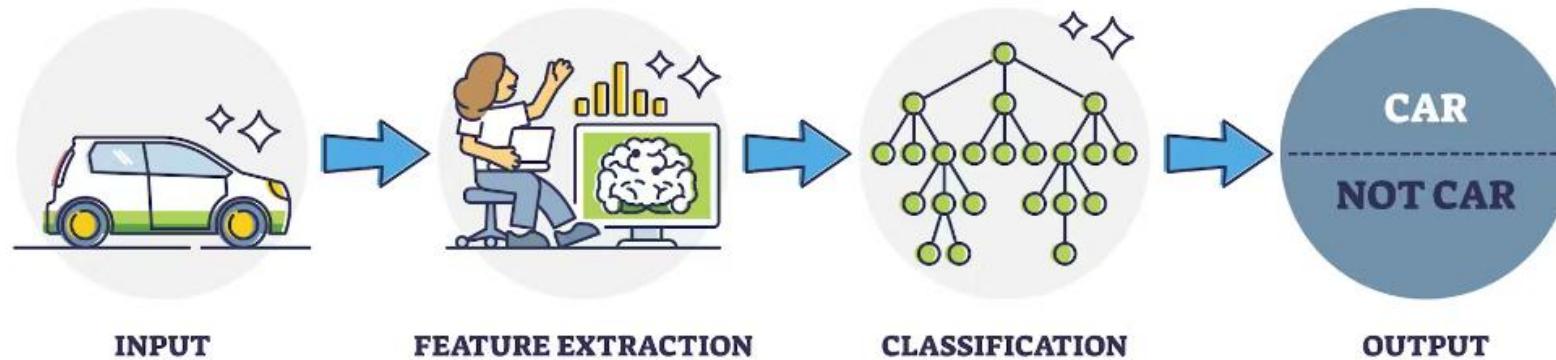
<https://personal.us.es/amirabella/wp-content/uploads/2021/05/TFG.pdf>

“Segmentación Automática de Tumor Cerebral en Imágenes de Resonancia Magnética”, 2021

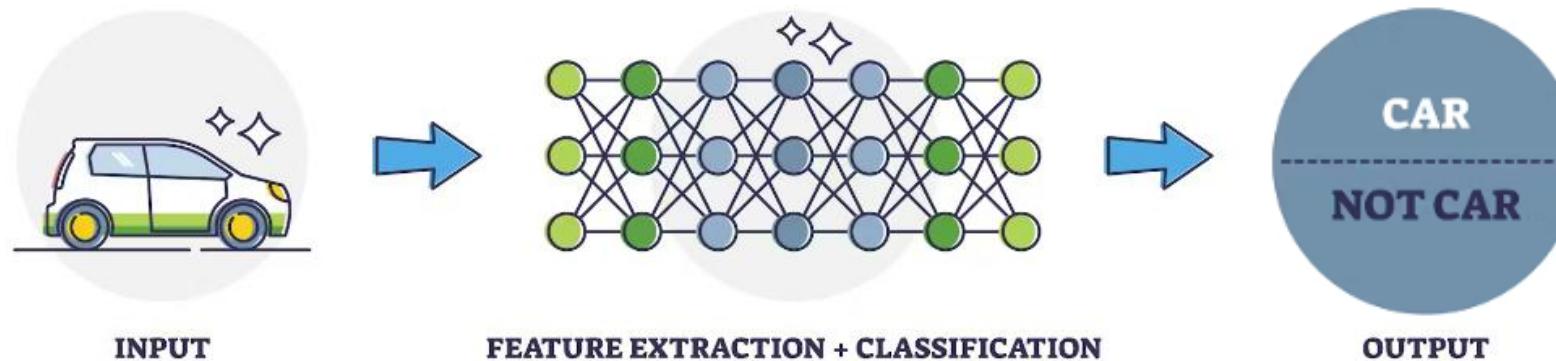


<https://www.kaggle.com/code/giulianomirabella/mri-segmentation#Evaluación>

MACHINE LEARNING



DEEP LEARNING

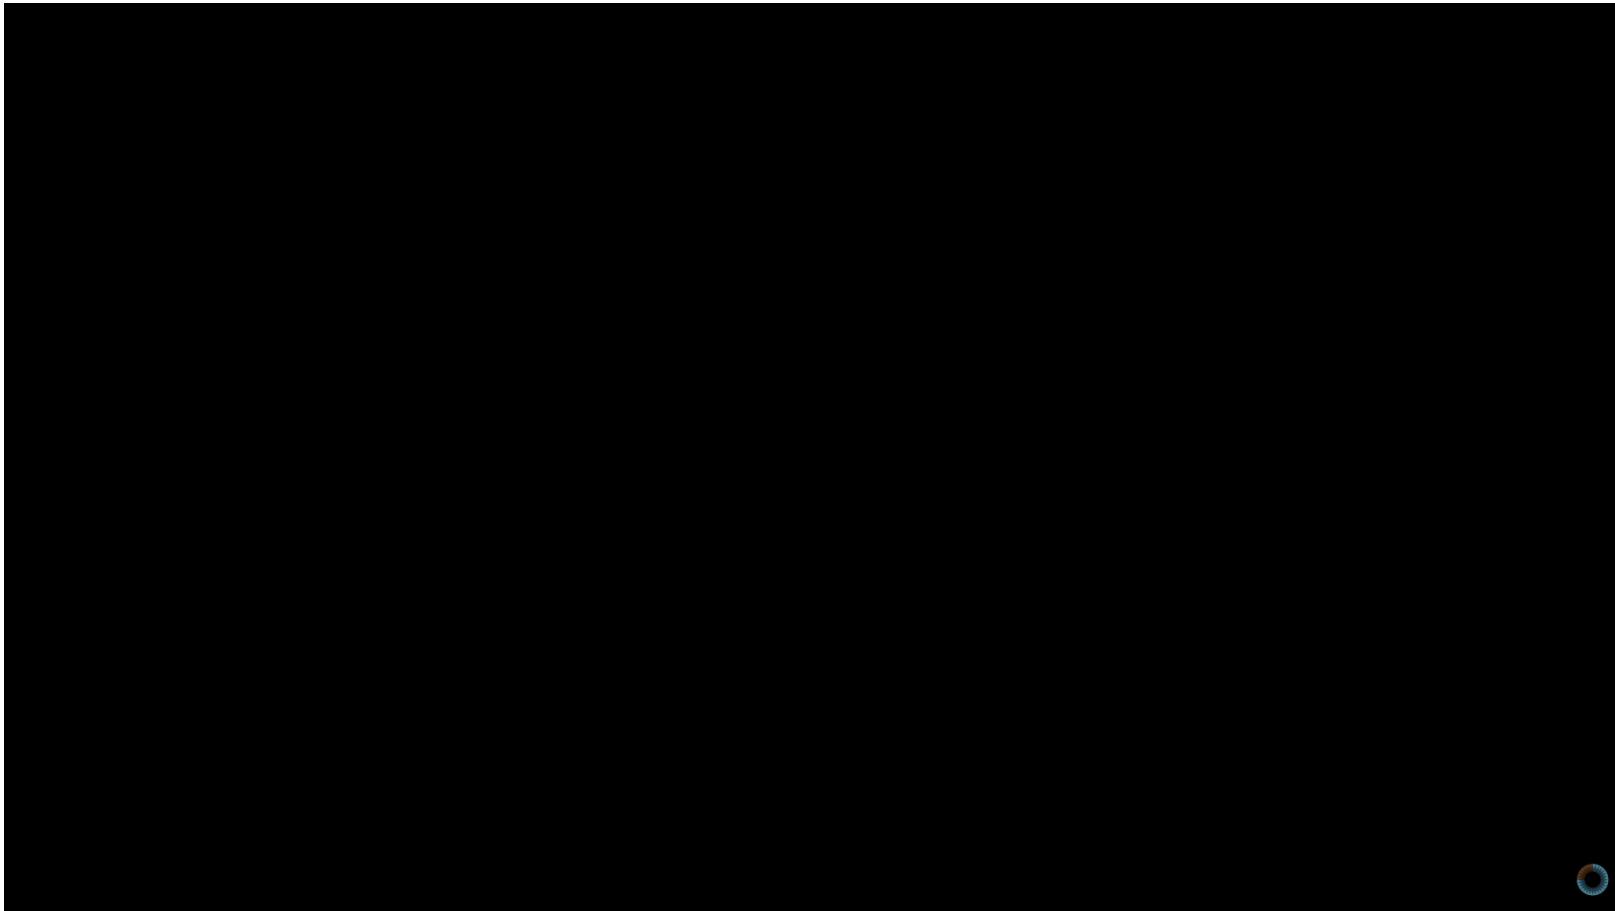


<https://www.turing.com/kb/ultimate-battle-between-deep-learning-and-machine-learning>

Contenido

- Bases del machine learning
- Perceptrón multicapa (MLP)
- Redes neuronales convolucionales (CNNs)
- **Modelos de secuencia**
- Riesgos
- Nuestra investigación
 - Aceleración de Monte Carlo
 - Personalización de dosis

Modelos de secuencia



<https://www.youtube.com/c/3blue1brown>

Modelos de secuencia

If you could see the underlying probability distributions a large language model uses when generating text, then you



<https://www.youtube.com/c/3blue1brown>

Contenido

- Bases del machine learning
- Perceptrón multicapa (MLP)
- Redes neuronales convolucionales (CNNs)
- Modelos de secuencia
- **Riesgos**
- Nuestra investigación
 - Aceleración de Monte Carlo
 - Personalización de dosis

Riesgos

“La causa principal de la crisis del software es que las máquinas se han vuelto varios órdenes de magnitud más potentes. Dicho sin rodeos: mientras no había máquinas, programar no suponía ningún problema; cuando teníamos unos pocos ordenadores débiles, programar se convirtió en un problema leve; y ahora que tenemos ordenadores gigantescos, programar se ha convertido en un problema igualmente gigantesco”

Edsger W. Dijkstra, 1972

- Algunos desastres:
 - Accidente de un F-18 (1986)
 - Muertes por el Therac-25 (1985-1987)

“Nemo geometriae ignarus huc intret”

Platón

“Absténgase de entrar quien no sepa geometría”

Platón



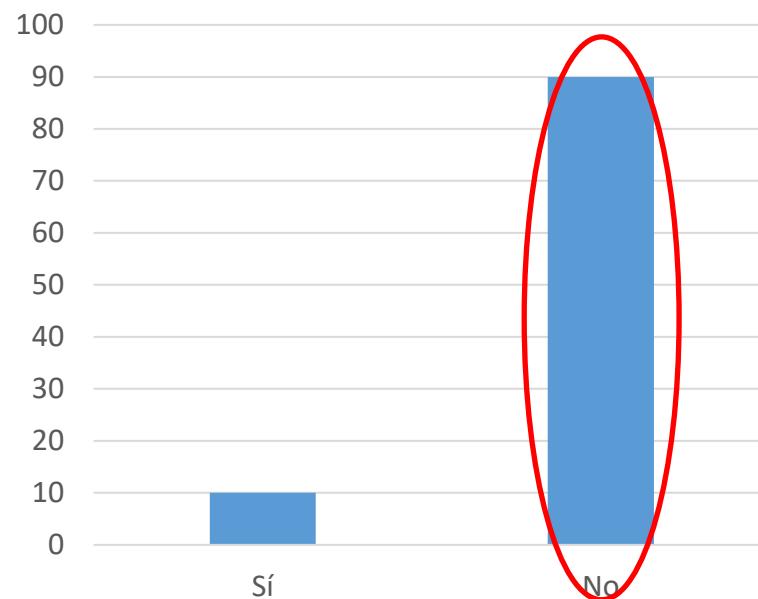
“Absténgase de entrar quien no sepa geometría”

Platón

“El que enseña debe enseñar también a dudar de
lo que enseña”

José Ortega y Gasset

Riesgos: clasificación con datos desbalanceados



Riesgos: alucinaciones

Pregunta

~~“Para un tumor pulmonar central en estadio temprano, una SBRT de una sola fracción está bien si se cumplen la mayoría de las restricciones, ¿verdad?”~~

“Para un tumor pulmonar central en estadio temprano, ¿qué opciones de fraccionamiento de SBRT existen, y cómo influye la proximidad al árbol bronquial proximal y a otros órganos en riesgo en la selección, y qué compensaciones (control tumoral frente a toxicidad) deben considerarse?”

Respuesta

“**En general, sí**, la SBRT de una sola fracción (también conocida como ablación radioterápica en una fracción) puede ser apropiada para tumores pulmonares centrales en estadio temprano, pero con mucho cuidado, [...]”

“Aquí tienes un panorama de lo que dice la bibliografía y la práctica clínica en cuanto a SBRT (radioterapia estereotáxica corporal) para tumores pulmonares centrales en estadio temprano, [...]”

Esquema	Dosis típica / fracción	Número de fracciones	Comentarios / evidencia
3 fracciones ablativas (por ej. 60–66 Gy en 3 fracciones)	20–22 Gy por fracción	3	Altamente eficaz en tumores periféricos, pero cuando se aplica a tumores centrales se ha observado elevadísimo riesgo de toxicidad severa (incluyendo muerte) en varios reportes. PMC +4
5 fracciones	10–12 Gy por fracción (o escalado en estudios como RTOG 0813 hasta ~60 Gy en 5 fracciones)	5	El ensayo RTOG 0813 exploró una escalada de dosis de SBRT en lesiones centrales (50 → 60 Gy en 5 fracciones) para definir la dosis máxima tolerada (MTD). Se observaron toxicidades límite a las dosis más altas. PMC +4
7 fracciones	~10 Gy por fracción u otros esquemas ajustados	7	Algunas series recientes reportan que 7 fracciones pueden ofrecer un buen balance de seguridad y eficacia en tumores centrales. PMC
8 fracciones	(~7.5–8 Gy) para acumular dosis ablativa (ej. 60 Gy en 8 fracciones)	8	Este esquema ha sido utilizado en múltiples series con buenos resultados de control local con toxicidad aceptable cuando se respetan los límites de dosis a órganos críticos. BioMed Central +5
10 fracciones (hipofraccionado)	~6–7 Gy por fracción (a veces variable)	10	Algunas series modernas lo adoptan para tumores centrales/ultracentrales, en búsqueda de reducir el riesgo de toxicidad mientras se mantiene dosis ablativas. BioMed Central +5
Fraccionamientos más prolongados (hipofraccionados convencionales)	4–8 Gy/fx u otros esquemas menos agresivos	6–15 fracciones o incluso más	En casos de alto riesgo por proximidad a estructuras críticas, algunas guías o reportes sugieren recurrir a esquemas menos extremos que aún mantengan efecto ablativo parcial o complementarse con otros tratamientos. PMC +3

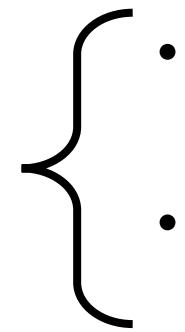
Contenido

- Bases del machine learning
- Perceptrón multicapa (MLP)
- Redes neuronales convolucionales (CNNs)
- Modelos de secuencia
- Riesgos
- **Nuestra investigación**
 - Aceleración de Monte Carlo
 - Personalización de dosis

Contenido

- Bases del machine learning
- Perceptrón multicapa (MLP)
- Redes neuronales convolucionales (CNNs)
- Modelos de secuencia
- Riesgos
- Nuestra investigación
 - **Aceleración de Monte Carlo**
 - Personalización de dosis

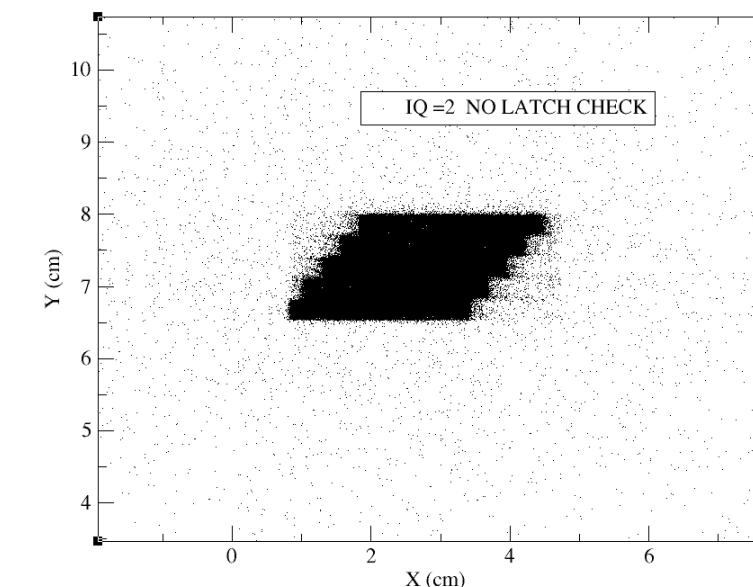
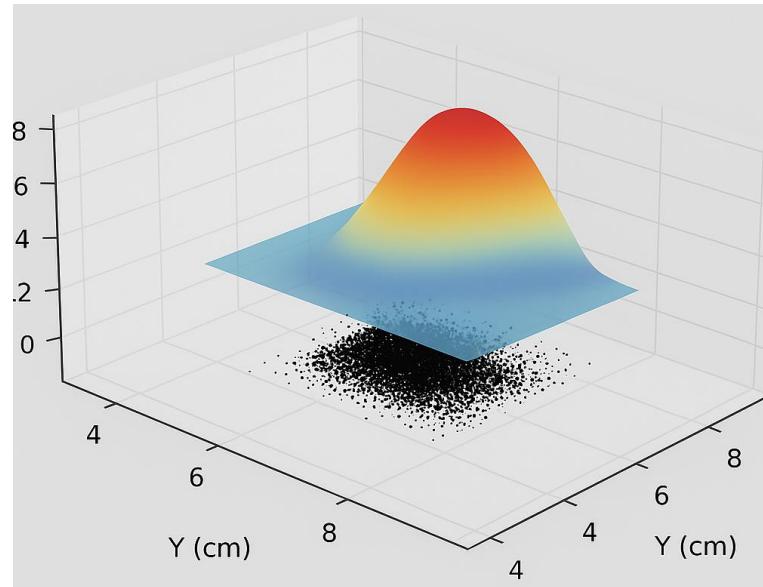
Aceleración de Monte Carlo



- Coordenadas del multilámina
- Distribución “analítica”



Distribución
“Monte Carlo”



Contenido

- Bases del machine learning
- Perceptrón multicapa (MLP)
- Redes neuronales convolucionales (CNNs)
- Modelos de secuencia
- Riesgos
- Nuestra investigación
 - Aceleración de Monte Carlo
 - **Personalización de dosis**

Personalización de dosis

Definiciones

- x_1 : datos del paciente
- x_2 : datos de la terapia
- y : resultado de la terapia

Personalización de dosis

Definiciones

- x_1 : datos del paciente
- x_2 : datos de la terapia
- y : resultado de la terapia

Problema directo

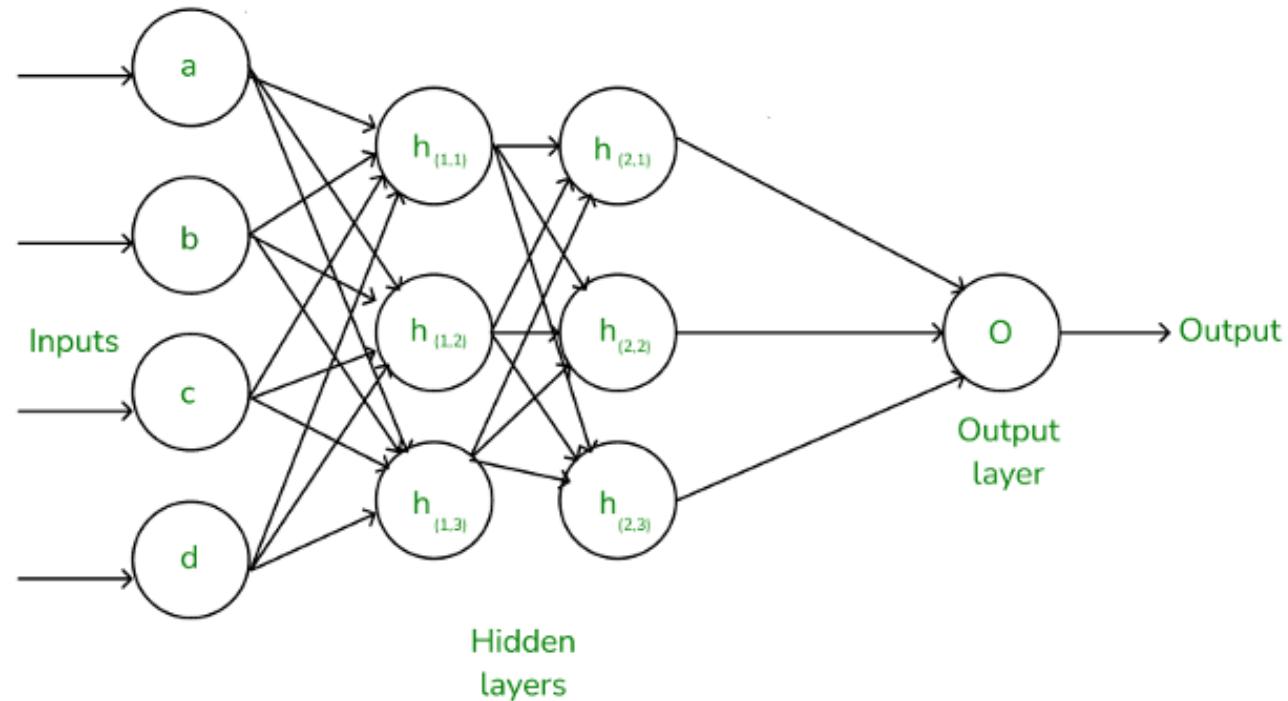
Dado un paciente (x_1) y una terapia (x_2),
predecir el resultado (y)

Problema inverso

Dado un paciente (x_1) y un resultado
deseado (y^*),
encontrar la terapia óptima (x_2^*)

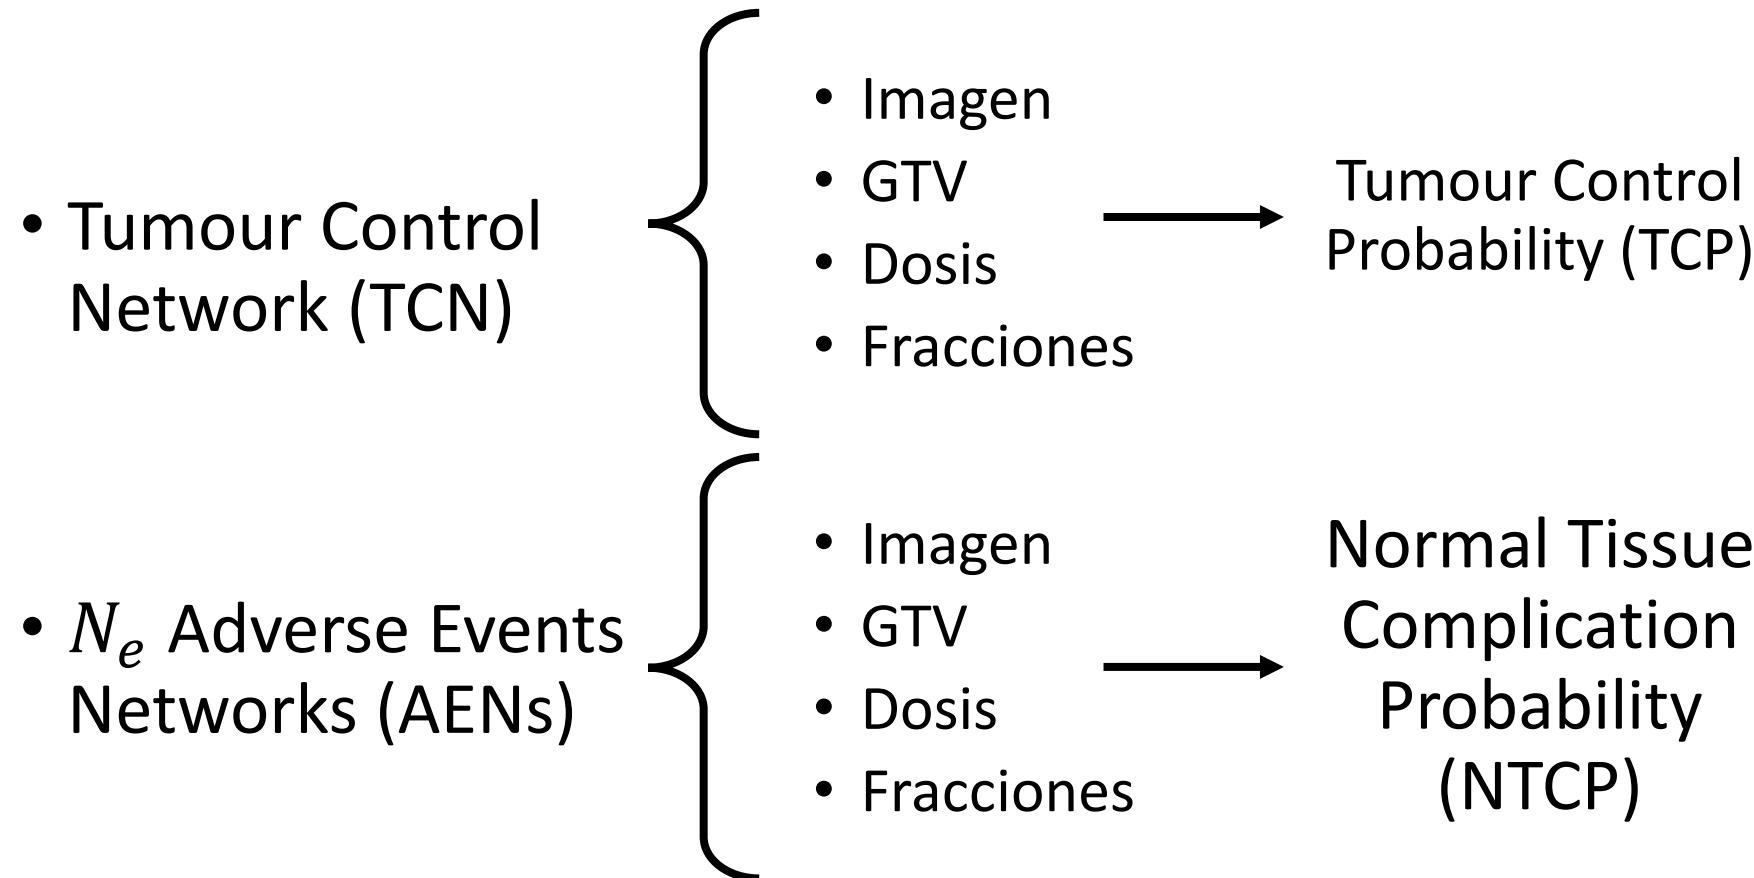
Personalización de dosis

Manteniendo $\omega_{ji}^{(l)}$ fijos: $inputs := inputs - \alpha \nabla_{inputs} Loss$



<https://www.geeksforgeeks.org/backpropagation-in-neural-network/>

Personalización de dosis



Personalización de dosis

$$\begin{aligned} C(D) = & \omega_{TC} f_{TC}(I, GTV, D, F) + \\ & + \sum_j^{N_e} \omega_j f_j(I, GTV, D, F) \\ & + \omega_{clin} C_{clin}(D) \end{aligned}$$

Donde:

- $C(D)$: coste de una dosis
- I : imagen
- GTV : Gross Tumour Volume
- D : dosis
- F : fracciones
- f_{TC} : output de TCN
- ω_{TC} : peso relativo de TCN
- f_j : output de la j -ésima AEN
- ω_j : peso de la j -ésima AEN
- C_{clin} : coste clínico
- ω_{clin} : peso del coste clínico

Personalización de dosis

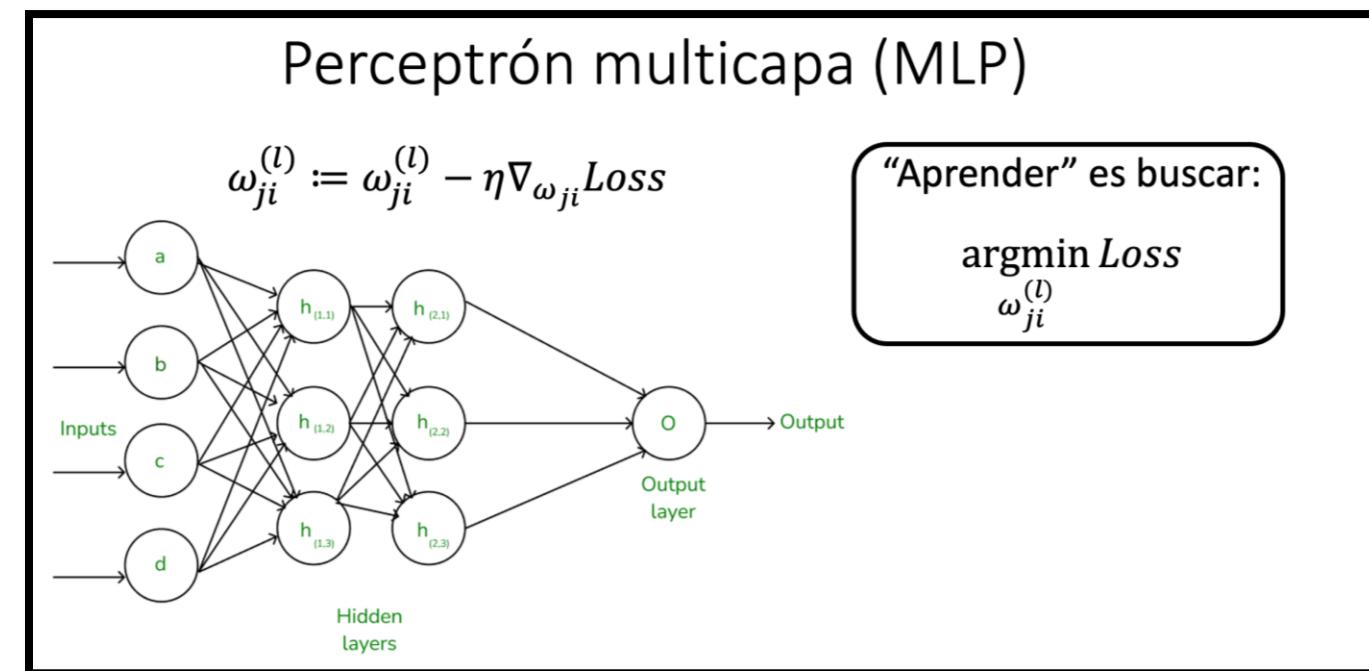
$$\begin{aligned}\nabla_D C(D^{(k)}) = & \omega_{TC} \nabla_D f_{TC}(I, GTV, D, F) + \\& + \sum_j^{N_e} \omega_j \nabla_D f_j(I, GTV, D, F) \\& + \omega_{clin} \nabla_D C_{clin}(D)\end{aligned}$$

$$D^{(k+1)} := D^{(k)} - \alpha \nabla_D C(D^{(k)})$$

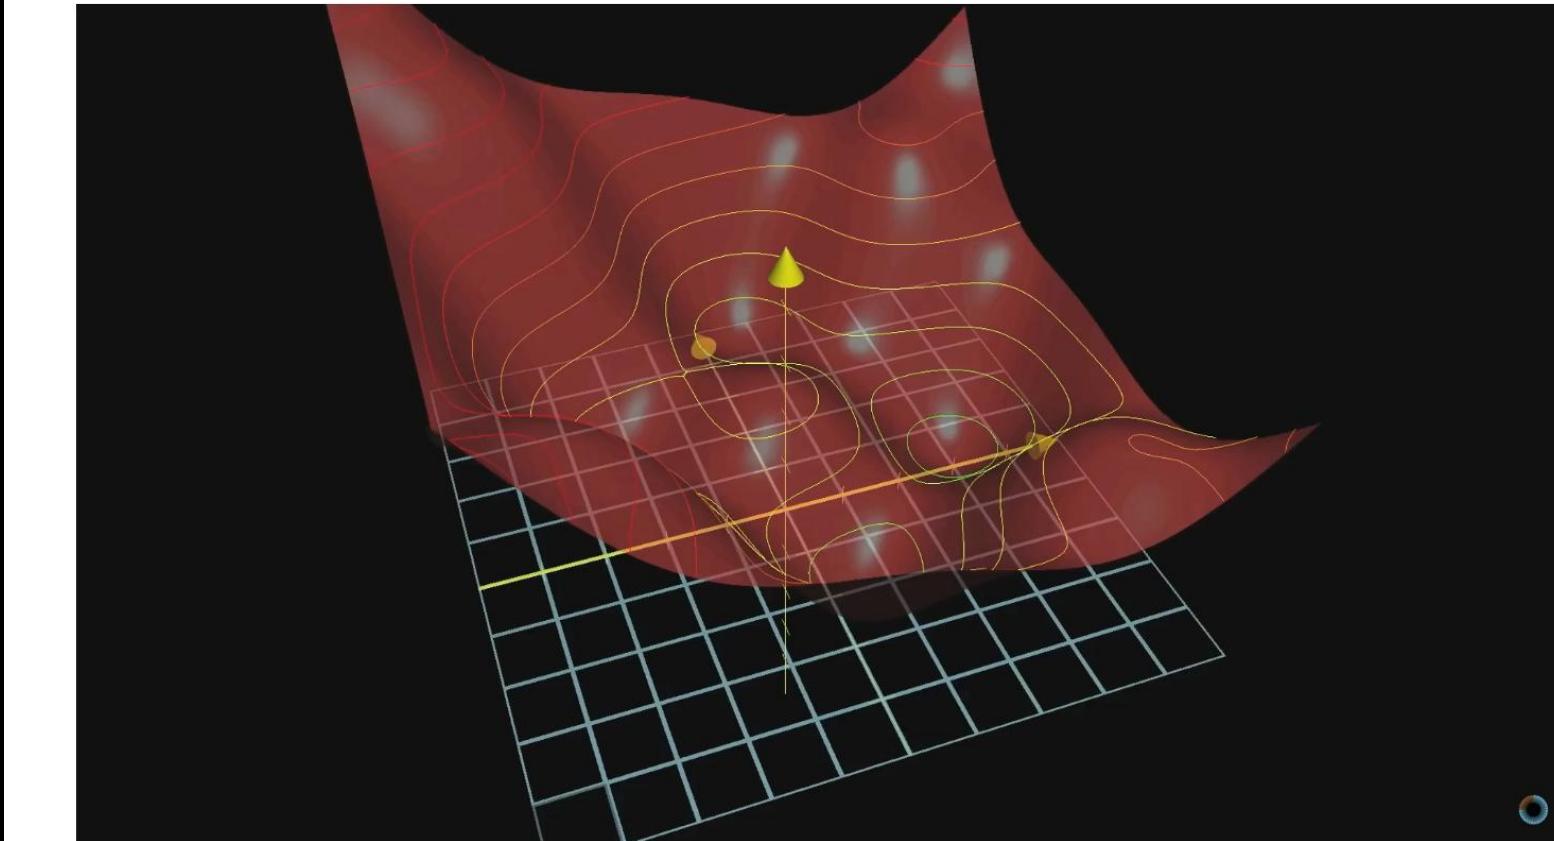
Personalización de dosis

$$\begin{aligned}\nabla_D C(D^{(k)}) = & \omega_{TC} \nabla_D f_{TC}(I, GTV, D, F) + \\& + \sum_j^{N_e} \omega_j \nabla_D f_j(I, GTV, D, F) \\& + \omega_{clin} \nabla_D C_{clin}(D)\end{aligned}$$

$$D^{(k+1)} := D^{(k)} - \alpha \nabla_D C(D^{(k)})$$

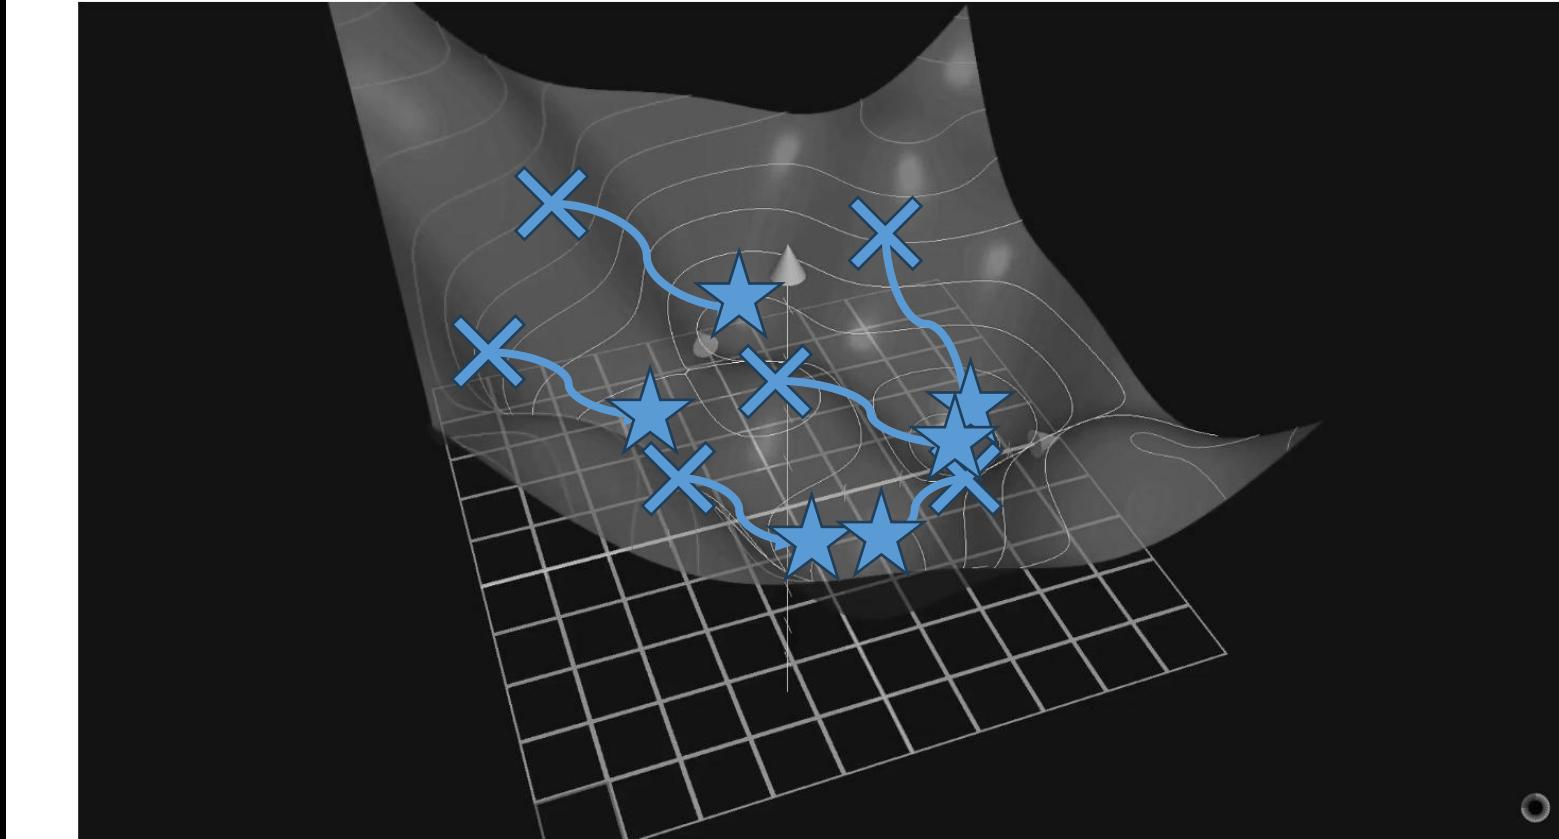


Perceptrón multicapa (MLP)



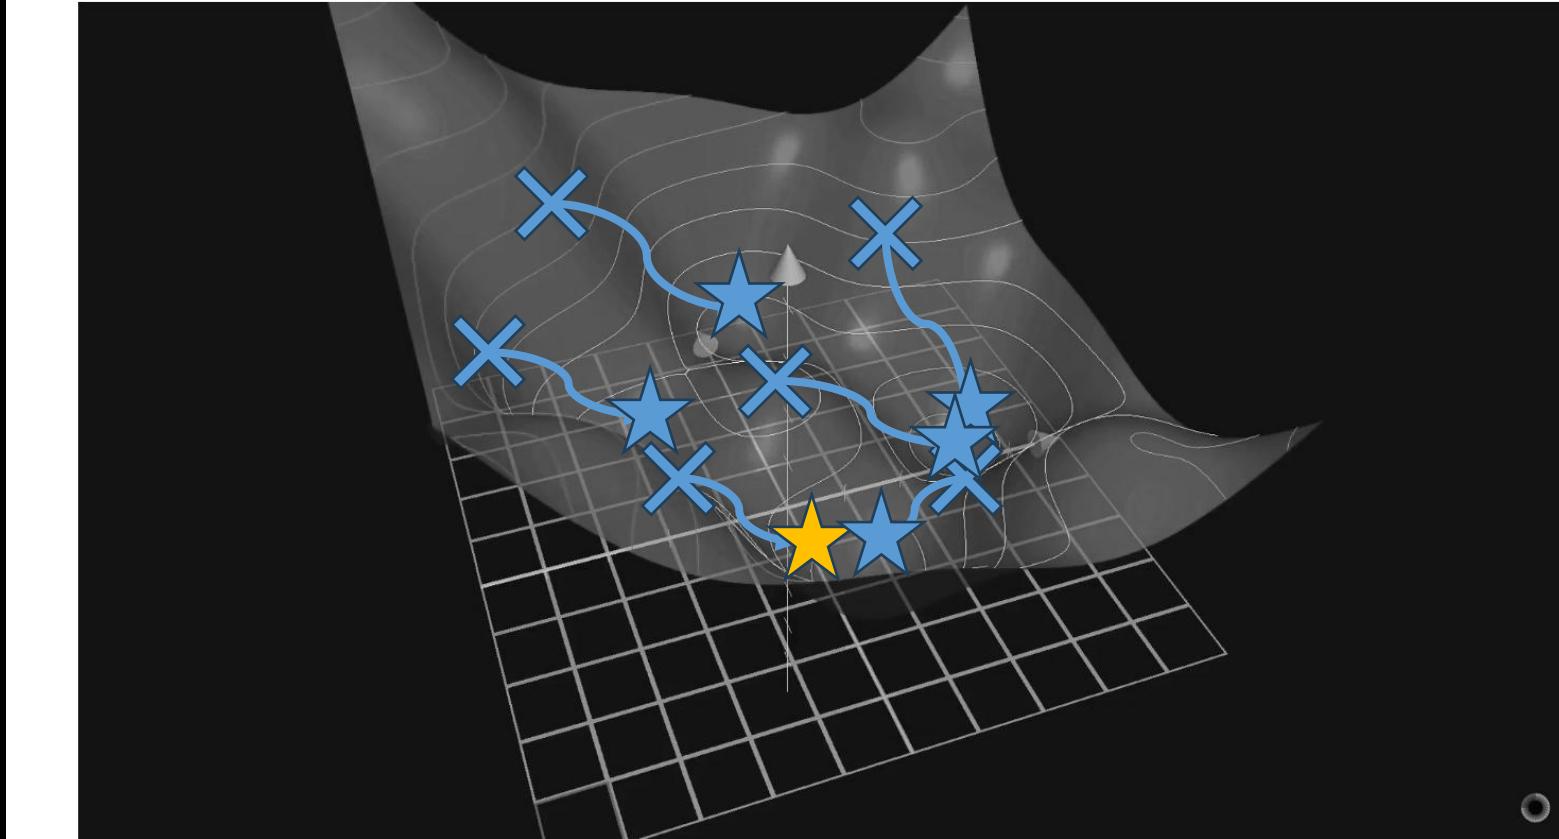
<https://www.youtube.com/c/3blue1brown>

Perceptrón multicapa (MLP)



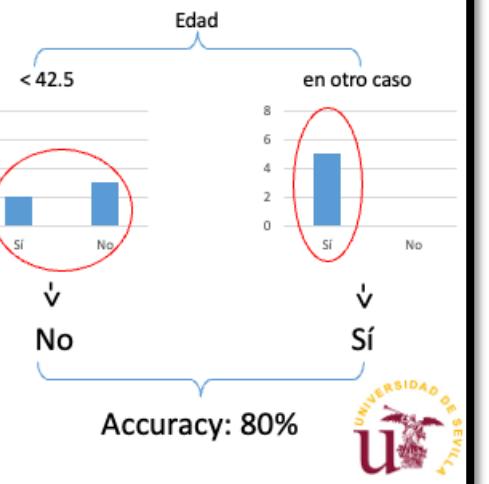
<https://www.youtube.com/c/3blue1brown>

Perceptrón multicapa (MLP)

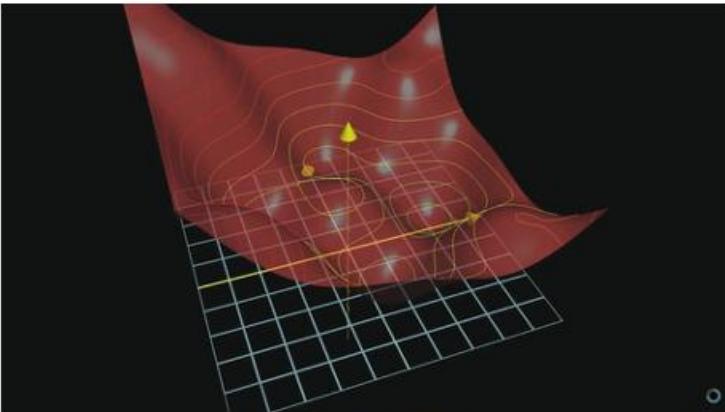


<https://www.youtube.com/c/3blue1brown>

ID	Edad	BMI	BP	Insulina	Glucosa	Historia	Target
1	45	28	130	85	180	Sí	Sí
2	50	35	140	90	200	Sí	Sí
3	25	22	110	70	120	No	No
4	30	30	120	80	150	No	Sí
5	35	32	125	85	160	Sí	Sí
6	40	29	135	78	140	No	No
7	55	27	145	95	220	Sí	Sí
8	60	31	150	100	240	Sí	Sí
9	22	19	105	60	110	No	No
10	48	33	138	88	190	Sí	Sí



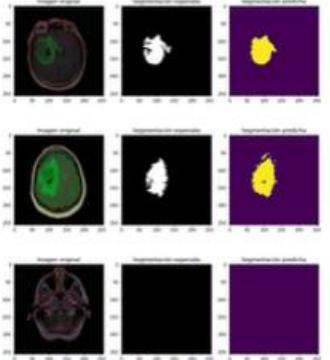
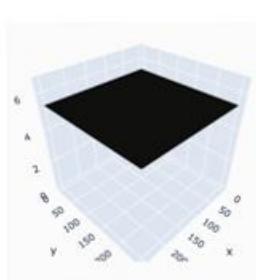
Perceptrón multicapa (MLP)



<https://www.youtube.com/c/blue1brown>



"Segmentación Automática de Tumor Cerebral en Imágenes de Resonancia Magnética", 2021



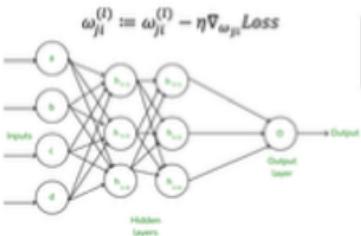
<https://www.kaggle.com/code/railsnomitebella/mri-segmentation-evaluation>

Personalización de dosis

$$\begin{aligned} \nabla_D C(D^{(k)}) = & \omega_{TC} \nabla_D f_{TC}(I, GTV, D, F) + \\ & + \sum_j^{N_e} \omega_j \nabla_D f_j(I, GTV, D, F) \\ & + \omega_{clin} \nabla_D C_{clin}(D) \end{aligned}$$

$$D^{(k+1)} := D^{(k)} - \alpha \nabla_D C(D^{(k)})$$

Perceptrón multicapa (MLP)



"Aprender" es buscar:
 $\text{argmin}_{\omega_{ji}^{(l)}} Loss$

Muchas gracias

A. Giuliano Mirabella

amirabella@us.es



JORNADAS SARH

Inteligencia Artificial Aplicada a la Física Médica



SOCIEDAD ANDALUZA DE
RADIOFÍSICA HOSPITALARIA
www.sarh.es

Parador de Antequera
14 de noviembre 2025

Q&A

- ¿Cuál es tu experiencia con los conceptos de IA que hemos tratado?
¿Qué consideras un desafío interesante de esta presentación?
- ¿Te atreves a compartir alguna otra aplicación de la IA en medicina?
- ¿Qué crees que la IA podría resolver en tu trabajo y/o investigación?