

Introducción a las tecnologías de inteligencia artificial

Introducción

The screenshot shows the VIVOLAB website's 'TEAM' page. At the top, there is a chalkboard-style background featuring colorful stick figures and the word 'TEAM' in an orange box. Below this, there are three sections: 'Researchers' (with 10 profiles), 'Former Members' (with 10 profiles), and 'Students' (with 1 profile). Each profile includes a small photo and the name of the individual.

VIVOLAB

HOME RESEARCH ▾ PROJECTS ▾ TEAM PUBLICATIONS DEMOS NEWS INTRANET WIKI

TEAM

Researchers

Eduardo Briones Pablo Giménez Eduardo Llinares Enrique Magaña Antonio Miguel Victoria Mirógea Alfonso Ortega Dayana Ribas Javier Simón Luis Vicente

Former Members

Ignacio Vilches Jorge Ullíbarri Julia Okoza Jesús Villalba Leibny Pobla García Luis Buera Diego Castan David Martínez Adolfo Arguedas Enrique García William Ricardo Oscar Saz Carlos Vaquero David Recerrol Juan Diego Rivas

Students

Santiago Rodríguez

Speech and Audio Research
**Aragón Institute for Engineering
Research – I3A**

- More than 20 years developing Artificial Intelligence Technology and Systems applied to Language, Speech, and Audio
- Experience in training specialized professionals on Machine Learning and Signal Processing
- Knowledge transference from the academy to the industrial R&D sector

<https://vivolab.i3a.es/>

VIVOLAB




Universidad
Zaragoza
1542

antecedentes

Máquinas electrónicas

Mark I, 1944

1 operación cada 3 segundos



Máquinas mecánicas

Mecanismo de Anticitera 200 a. C



La teoría

**Frank Rosenblatt 1957
Alan Turing 1950**

antecedentes

Los microprocesadores

Intel 8086, 1978

50 mil operaciones por segundo

Intel i5, 2018

25 mil millones de operaciones por segundo



2010s La era de las GPUs

Playstation 4s, 2016

1.8 TFlops (~90 x intel i5)

Playstation 5s, 2020

10.2 TFlops (~411 x intel i5)

Nvidia RTX Titan, 2018


16 TFlops (~640 x intel i5)

Nvidia RTX 3090, 2020

35 TFlops (~1400 x intel i5)

Nvidia RTX 4090, 2022


82 TFlops (~3280 x intel i5)



antecedentes


Almacenamiento

Sistema mecánico 1937 (República Checa)



Capacidad de almacenamiento


Cinta perforada	1970	<1 KB
Disco 3 ½	1987	1.4 MB
DVD	1995	4.7 GB



Velocidad de almacenamiento
Disco duro 2000 18GB (48MB/s)
HD estado sólido 2021 1TB (7000 MB/s)



antecedentes



Proceedings papel 1995 /
Revistas papel



Buscadores internet 1998




2008 Redes sociales /
plataformas de desarrollo colaborativo





fundamentos

- Procesado en fases, capas




Imaginemos unos datos de entrada: altura, edad,..

*Por ejemplo podríamos decir:
Pregunta a los tres que tengas en la fila de delante y quédate con el máximo, mínimo, etc*



fundamentos


- Procesado en fases, capas





fundamentos

- Procesado en fases, capas




Algunos nodos
reciben
parte de la
información



fundamentos

- Procesado en fases, capas




Ahora al último
le podríamos
preguntar,
**¿quién es el
más joven ?**
Ha recibido
toda la
información




fundamentos

- Redes convolucionales

- *Cada capa suma varios valores de entrada con distinto peso, normalmente 9 entradas: 3x3*



Yann LeCun




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



fundamentos

- Redes convolucionales
- Con mayor **profundidad (*depth*)** se logra mayor **abstracción**
 - *Las primeras redes profundas tenían 7 capas*
 - *Hoy en día en cuestión de minutos se tiene acceso a redes de más de 100 capas ya entrenadas*






fundamentos

- Redes convolucionales

- Las primeras redes profundas tenían 7 capas
- Hoy en día en cuestión de minutos se tiene acceso a redes de más de 100 capas ya entrenadas

Conv	96 (11x11) dw: 4
Maxpool	(3 x 3) dw: 2
Conv	256 (5x5)
Maxpool	(3 x 3) dw: 2
Conv	384 (3x3)
Conv	384 (3x3)
Conv	256 (3x3)
Linear	4096
Linear	4096
Linear	1000
Softmax	



Geoffrey Hinton



2012: 7 capas
84.6 % aciertos

2014: Inception 25 capas
93.3% aciertos

2015: Resnet >100 capas
96.43% aciertos







fundamentos

- Redes recurrentes

- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural computation, 9(8), 1735-1780

- Analizan la entrada en orden (*sentido temporal, orden del texto*)
- Cada celda tiene una memoria finita para recibir información de los instantes previos y escribir nueva información para el futuro



RNN

VIVOLAB



Universidad
Zaragoza





fundamentos

- ## Transformers

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N. Kaiser L., Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30, 5998-6008

- *Son capaces de analizar la relación de todas las entradas*



*Grado de influencia de la
entrada i sobre la j*

<https://nlp.seas.harvard.edu/2018/04/03/attention.html>

RNN

VIVOLAB




Universidad
Zaragoza

fundamentos



• Transformers

- Son capaces de analizar la relación de todas las entradas



palabra anterior


Final de frase

RNN


VIVOLAB



Universidad
Zaragoza



Desambigución ellos -> vecinos




Determinantes y modificadores de un nombre



fundamentos

- Transformers



RNN

VIVOLAB



Universidad
Zaragoza




fundamentos

- **Para aprender a realizar la tarea**

Un modelo de Deep learning


Actual puede tener desde unos pocos millones de parámetros a **miles de millones!!**



Se podría probar prueba y error hasta que se encontrara alguna buena combinación de todas las palancas ... pero tardaríamos demasiado



fundamentos



- **Repetir el proceso de corrección**

- **miles de veces**

- Depende de lo complicada que sea la tarea pueden ser **millones** de correcciones



- **Hay que disponer de datos y respuestas, coste**

- Corpus, bases de datos
 - Miles o millones de ejemplos con su etiqueta

- **Problema sesgos en los datos**

- Si mostramos más veces un ejemplo y la respuesta que otros ejemplos aparecerá un sesgo en el sistema



fundamentos

- **Etiquetado de datos**

- ¿Quién etiqueta?
- Freelance,
 - Mechanical turk amazon
- Empresas de etiquetado de datos
- **Todos nosotros**





<https://time.com/5518339/china-ai-farm-artificial-intelligence-cybersecurity/>



fundamentos

Tipos de problemas (1 / 4)

- Aunque cada día hay más variantes las dos formas principales de usar DNNs hoy en día:
 - Clasificación:
 - Decir **qué concepto** hay en una imagen/texto/audio





Una sola salida/concepto para toda la entrada



fundamentos

Tipos de problemas (2 / 4)

- Aunque cada día hay más variantes las dos formas principales de usar DNNs hoy en día:
 - **Clasificación múltiple:**
 - Decir **qué concepto** hay en cada zona/pixel: imagen/texto/audio
 - Decir **varias propiedades/conceptos** de una imagen/texto/audio



Una salida/concepto para cada pixel de entrada


sol	sol	gato	gato
sol	sol	gato	gato
pájaro			
pájaro		hoja	hoja



fundamentos

Tipos de problemas (3 / 4)

- Aunque cada día hay más variantes las dos formas principales de usar DNNs hoy en día:
 - **Regresión:**
 - Utilizar los datos para obtener algún tipo de **predicción numérica**







fundamentos

Tipos de problemas (4/4)

- Aunque cada día hay más variantes las dos formas principales de usar DNNs hoy en día:
 - Regresión múltiple:
 - Predecimos varios valores numéricos: por cada zona, pixel...






aplicaciones: análisis


– Clasificación:

- Decir **qué concepto** hay en una imagen/texto/audio



En este ejemplo la red neuronal se prepara para resolver el problema de clasificación:
¿Qué hay en esta imagen? -> 1 respuesta

*Entre las posibles respuestas hay 120 razas de perro
 En 2012 el error top5 era del 25%,
 Hinton y Krizhevsky red de 7 capas 15%
 Hoy en día decenas, cientos de capas, alrededor del 2%,*




aplicaciones: análisis


– Clasificación: ¿ nos podemos fiar ?




¿cómo es ese pequeño porcentaje de fallos... ?





Hay modelos que pueden mostrar **qué zonas** han considerado más





aplicaciones: análisis

– Clasificación: ¿ nos podemos fiar ?




Ataques adversarios



→ Speed Limit 80
(88% confidence)



Accessorize to a crime: Real and stealthy attacks on state-of-the-art face recognition
Mahmood Sharif, Sruti Bhagavatula, Lujo Bauer, Michael K. Reiter
ACM Conference on Computer and Communications Security (CCS 2016)

Robust physical-world attacks on deep learning visual classification.
Eykholt, K., Evtimov, I., Fernandes, E., Li, B., Rahmati, A., Xiao, C., ... & Song, D. (2018). In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1625-1634).




aplicaciones: análisis

- Clasificación: ¿ nos podemos fiar ?



Hoy en día se entrenan facilitando múltiples versiones de las imágenes/sonidos


Se conoce como:
Aumento de datos



aplicaciones: análisis


– Clasificación múltiple:

- **varias propiedades/conceptos** de una imagen/texto/audio




En este ejemplo la red neuronal se prepara para resolver muchas respuestas sí o no:

¿Hay un perro?	No
¿Hay un gato?	Sí
¿Hay árboles?	No
¿Hay un pájaro?	Sí
¿Hay cielo?	No
¿Hay hierba?	Sí



aplicaciones: análisis



– Regresión:

- Utilizar los datos para obtener algún tipo de **predicción numérica**


En este ejemplo la red neuronal se prepara para resolver el problema:


¿Qué edad tienen estas personas?

La respuesta sería un número con la edad en años


Entrenaríamos el sistema con muchas imágenes

Aplicaríamos las correcciones necesarias cuando la red se equivoca






aplicaciones: síntesis



– Regresión múltiple:


- **Transformar los datos** con alguna finalidad, que se parezcan a algo, que mejoren de calidad...



En este ejemplo la red neuronal se prepara para resolver el problema:
Convertir una imagen de BN en color





En este ejemplo la red neuronal se prepara para resolver el problema:
Mejorar la calidad de la imagen



aciones


■ Resumen: Aprendizaje supervisado






acciones

- Aprendizaje no supervisado
 - Los métodos clásicos de aprendizaje no supervisado
 - Self supervised labeling
 - El modelo me da las etiquetas para el siguiente modelo



- Clustering
 - Agrupamos los datos por parecido,: por ejemplo similar color







aplicaciones: análisis

■ Representation learning

- Podemos utilizar representaciones internas de la red
 - Objetivo comparar imágenes/sonidos/textos







aplicaciones: análisis

■ Representation learning

- Podemos utilizar representaciones internas de la red
 - imágenes/sonidos/textos similares están más próximos en ese espacio







aplicaciones: análisis

■ Representation learning

- Podemos utilizar representaciones internas de la red




Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.





aplicaciones: análisis

- **Representation learning**
 - Podemos utilizar representaciones internas de la red



Comparar si dos imágenes corresponden a la misma identidad






aplicaciones: análisis

- Generación

- Podemos aprender a manipular las imágenes




- ¿Qué pasa si cambio la representación para conseguir otra imagen distinta?

0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2	2
3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3	3
4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4	4
5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5
C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C	C
7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7	7
8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8
9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9	9

Azimuth	Stroke thickness	Width
0 0	0 0	0 0
1 1	1 1	1 1
2 2	2 2	2 2
3 3	3 3	3 3
4 4	4 4	4 4
5 5	5 5	5 5
C C	C C	C C
7 7	7 7	7 7
8 8	8 8	8 8
9 9	9 9	9 9




Antoran, J., & Miguel, A. (2019, December). Disentangling and Learning Robust Representations with Natural Clustering. In 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA) (pp. 694-699). IEEE.



aplicaciones: síntesis


■ Generación

- Podemos aprender a manipular las imágenes
 - ¿Qué pasa si cambio la representación para conseguir otra imagen distinta?



Generación de nuevas imágenes que nunca han existido


Kingma, D. P., & Dhariwal, P. (2018). Glow: Generative flow with invertible 1x1 convolutions. In Advances in neural information processing systems (pp. 10215-10224). Kingma, D. P., & Dhariwal, P. (2018). Glow: Generative flow with invertible 1x1 convolutions. In Advances in neural information processing systems (pp. 10215-10224).




aplicaciones: síntesis

■ Generación


- Hay modelos en los que directamente se aprende a generar imágenes
- **Generative adversarial network**




representación



imagen





aplicaciones: síntesis

■ Generación

- Hay modelos en los que directamente se aprende a generar imágenes
- **Generative adversarial network**




¿Qué imagen es artificial?

One hour of imaginary celebrities


<https://www.youtube.com/watch?v=36IE9tV9vm0>

representación



Dos redes compiten:

- **Red 1 genera imágenes realistas de manera que la Red 2 falle**
- **Red 2 intenta distinguir las imágenes reales de las falsas**
- Es una combinación de generación y clasificación
- Genera datos de forma que sean indistinguibles de los originales
- Generador ilimitado de datos: imágenes, audio, texto...



aplicaciones: síntesis


■ Generación

- Este proceso se ha sofisticado mucho en menos de 10 años


Goodfellow et al., 2014; Radford et al., 2016; Liu & Tuzel, 2016; Karras et al., 2018; Karras et al., 2019; Goodfellow, 2019; Karras et al., 2020, Karras 2021




StyleGAN3 (Karras 2021)



aplicaciones: síntesis



StyleGAN2 (Karras 2020)



aplicaciones: síntesis

Monet \leftrightarrow Photos



Monet \rightarrow photo

Zebras \leftrightarrow Horses



zebra \rightarrow horse

Summer \leftrightarrow Winter



summer \rightarrow winter




photo \rightarrow Monet



horse \rightarrow zebra



winter \rightarrow summer



Photograph



Monet



Van Gogh



Cezanne



Ukiyo-e


<https://junyanz.github.io/CycleGAN/>



aplicaciones: síntesis

- Generación de vídeos realistas: Deep fakes





aplicaciones: síntesis

■ Generación:

Podemos añadir ruido hasta que no se reconozca la imagen




Con una red aprendemos a “limpiar” ese ruido



■ CLIP (2021)

- representación texto + imagen
- Sesión del miércoles (multimedia)

Radford, A., Kim, J. W., Hallacy, C., Ramesh, A., Goh, G., Agarwal, S., ... & Sutskever, I. (2021, July). Learning transferable visual models from natural language supervision. In *International conference on machine learning* (pp. 8748-8763). PMLR.



aplicaciones: síntesis

■ Generación:

Imágenes 2021, CLIP + GAN



unreal engine gaudi
house in a field of poppy




unreal engine building by gaudi



the angel of air. unreal engine
[@arankomatsuzaki](#)



treehouse in the style of studio ghibli
animation [@danielrussruss](#)



aplicaciones: síntesis

■ Generación:

Imágenes 2021, CLIP + diffusion



A wooden Spanish laptop of 1650 found in the library of El Escorial




Medieval 1230 book page illustrating monks playing basketball


Imágenes 2022, CLIP + diffusion



documentary travel photography of a woman, 30 years old, medium length red hair, colourful maxi dress, casual spring look, smiling, carefree, natural light --ar 4:5 --v 5.2 --style raw --s 25
[@matthew_paul0](#)



A rainy urban street at night, the neon lights reflecting off the wet pavement. A cat walks cautiously, its glowing eyes focused on its path ahead --v 5 --q 2
[@AI_creative_gal](#)




aplicaciones: síntesis

■ Aprendiendo sin etiquetas: no supervisado

- Podemos conseguir que los sistemas automáticos comprendan los datos **forzando a que hagan predicciones** sobre lo que no han visto




A Oord, N Kalchbrenner, O Vinyals, L Espeholt, A Graves, K Kavukcuoglu
Conditional Image Generation with PixelCNN Decoders 2016




aplicaciones: análisis

■ Aprendiendo sin etiquetas: no supervisado


- Podemos conseguir que los sistemas automáticos comprendan los datos **forzando a que hagan predicciones** sobre lo que no han visto



Oord, A. V. D., Li, Y., & Vinyals, O. (2018). Representation learning with contrastive predictive coding. arXiv preprint arXiv:1807.03748
 Oord, A. V. D., Li, Y., & Vinyals, O. (2018). Representation learning with contrastive predictive coding. arXiv preprint arXiv:1807.03748




Una estrategia es dar varias opciones como si fuera un examen




aplicaciones: análisis

■ Aprendiendo sin etiquetas: no supervisado




Resolver la pregunta son partes de la misma imagen

- Chen, T., Kornblith, S., Norouzi, M., & Hinton, G. (2020, November). A simple framework for contrastive learning of visual representations. In *International conference on machine learning* (pp. 1597-1607). PMLR.
- Zbontar, J., Jing, L., Misra, I., LeCun, Y., & Deny, S. (2021, July). Barlow twins: Self-supervised learning via redundancy reduction. In *International Conference on Machine Learning* (pp. 12310-12320). PMLR.



Reconstruir la imagen a partir de una con occlusiones

- He, K., et al (2022). Masked autoencoders are scalable vision learners. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*




aplicaciones: análisis

■ Aprendiendo sin etiquetas: no supervisado

- Motivación: hay muchos datos no etiquetados
- Las representaciones obtenidas se pueden usar en otras tareas




Caron, M., Touvron, H., Misra, I., Jégou, H., Mairal, J., Bojanowski, P., & Joulin, A. (2021). Emerging properties in self-supervised vision transformers. arXiv preprint arXiv:2104.14294..



aplicaciones

- La inteligencia artificial halla rastros del descubrimiento español de Australia




Un grupo de investigación en la UPV lleva años desarrollando sistemas de reconocimiento de texto manuscrito antiguo.

¿Se puede usar ya la tecnología?

- En un texto concreto un experto es más fiable
- La tecnología actual puede permitir **buscar**
- “escalar” un sistema básico permite hacer frente a documentos que no podrían ser tratados.
- **El Archivo General de Indias**, tiene 80 millones de páginas que no se han procesado en su totalidad.
- **Objetivo: asistir al profesional**

divulgación

- **Comunicar, comparar y aprender**
 - Congresos y conferencias científico-técnicas como Iberspeech / Interspeech / ICCASP
 - Los **retos Albayzín-RTVE 2018 y 2020** organizados por la **Cátedra RTVE de la Universidad de Zaragoza**
 - Páginas web como papers with code




contexto global

- Muchas grandes empresas y países han apostado fuerte por lograr posiciones dominantes en esta nueva industria

PRIVATE INVESTMENT in AI by GEOGRAPHIC AREA, 2015-20

Source: CAPIQ, Crunchbase, and NetBase Quid, 2020 | Chart: 2021 AI Index Report



Artificial Intelligence Index Report 2021, Stanford's Institute for Human-Centered Artificial Intelligence (HAI).