

# Cursos Extraordinarios

**Verano 2024**

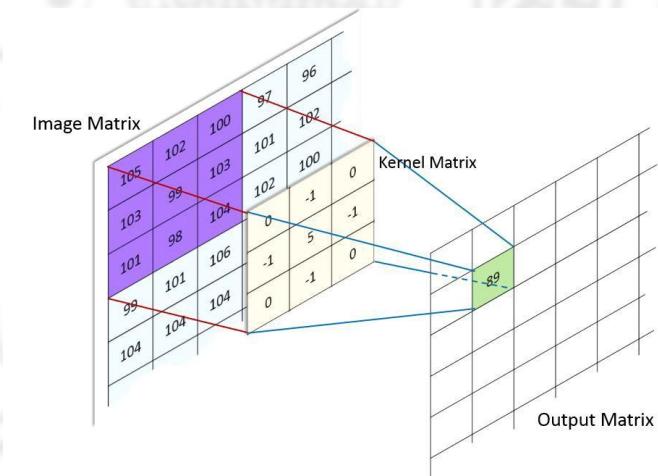
**“Inteligencia Artificial y Grandes  
Modelos de Lenguaje: Funcionamiento,  
Componentes Clave y Aplicaciones”**

**Zaragoza, del 3 al 5 de julio**

# Tipos de Redes: Arquitectura

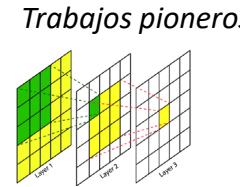
- **Redes Convolucionales (CNN)**

- Reducción del número de grados de libertad (parámetros).
- Reutilización de los pesos
  - Cada unidad procesa una región diferente de la entrada.
  - Todas comparten los pesos
  - Se usa conocimiento a priori para definir la topología
- Suelen incorporan capas de pooling
  - Reducen la dimensionalidad
  - Max-pooling, avg-pooling, ...



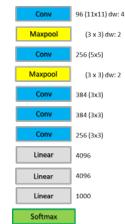
# Tipos de Redes: Arquitectura

## • Redes Convolucionales CNN



Trabajos pioneros

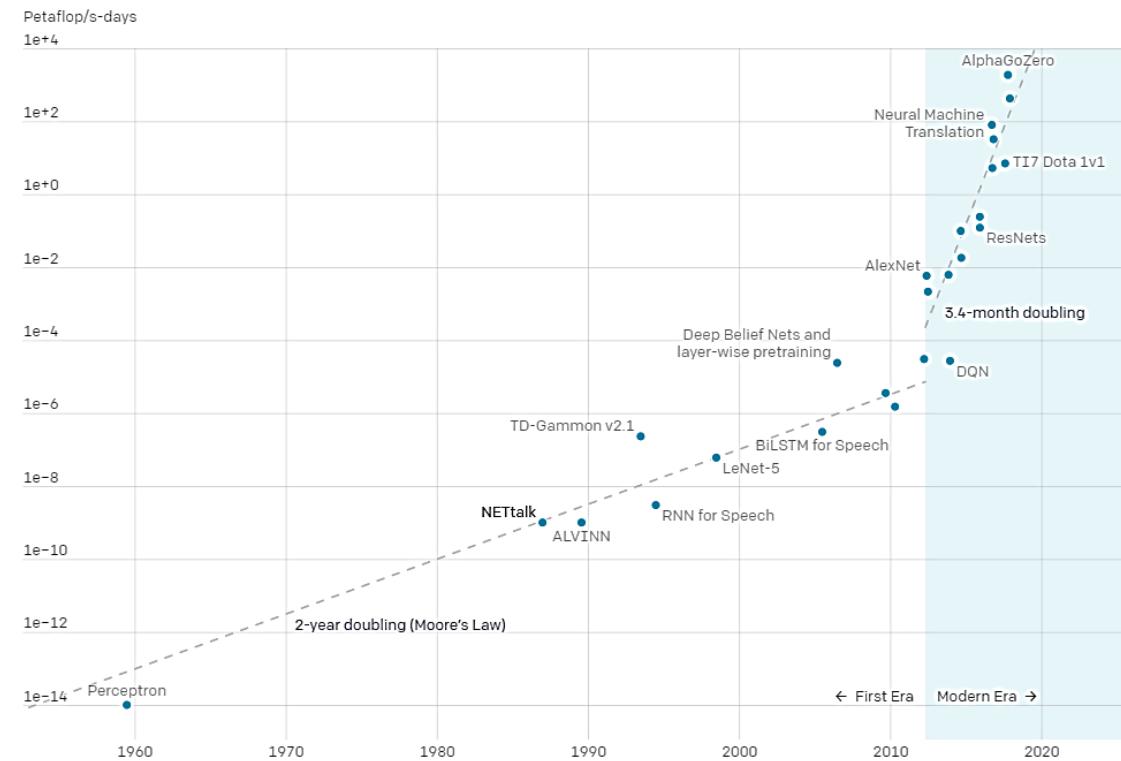
1998: 4 capas



2012: 7 capas  
84.6 % aciertos



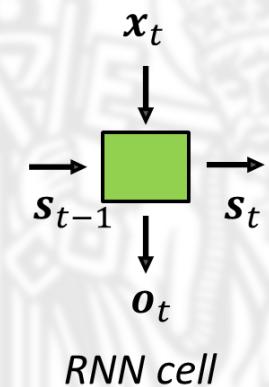
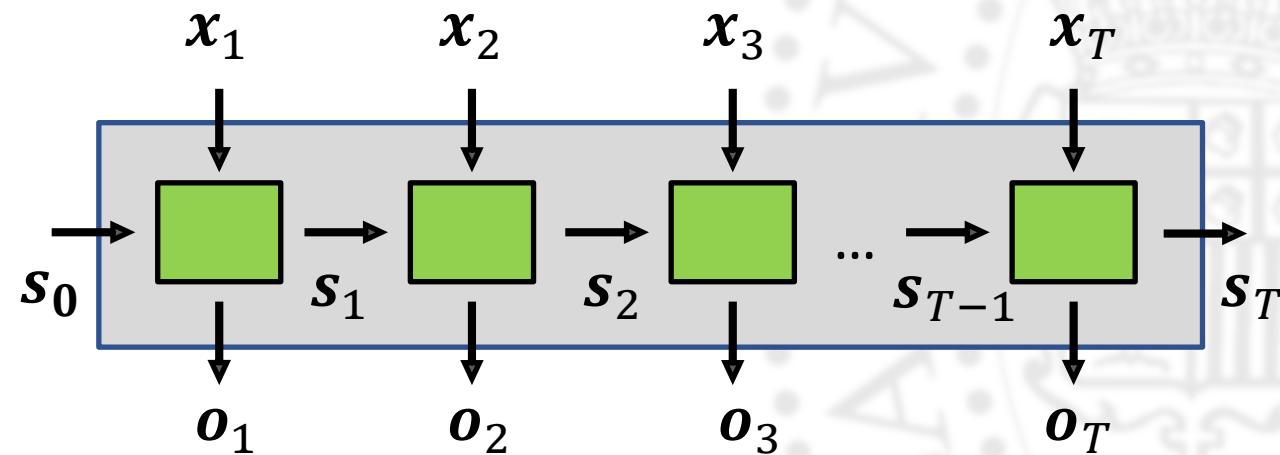
2015: Resnet >100 capas  
96.43% aciertos



# Tipos de Redes: Arquitectura

- **Redes Recurrentes:**

- 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
- Entrenamiento Backpropagation-Through-Time (BTT)

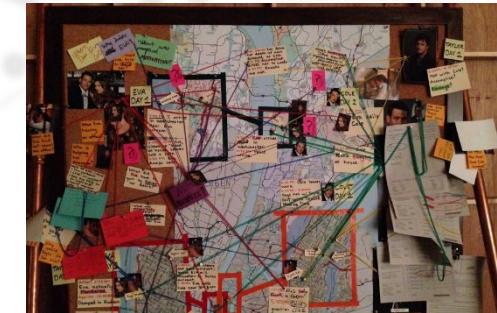
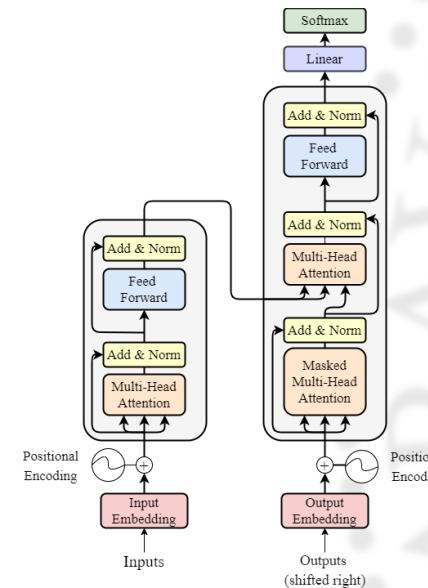


RNN cell

# Tipos de Redes: Arquitectura

- **Transformers:**

- Estructuras muy expresivas, eficientes y diferenciables
- Capaces de analizar las relaciones entre todas las entradas y entre las entradas y las salidas: Mecanismos de Atención.



# Tipos de Redes: Arquitectura

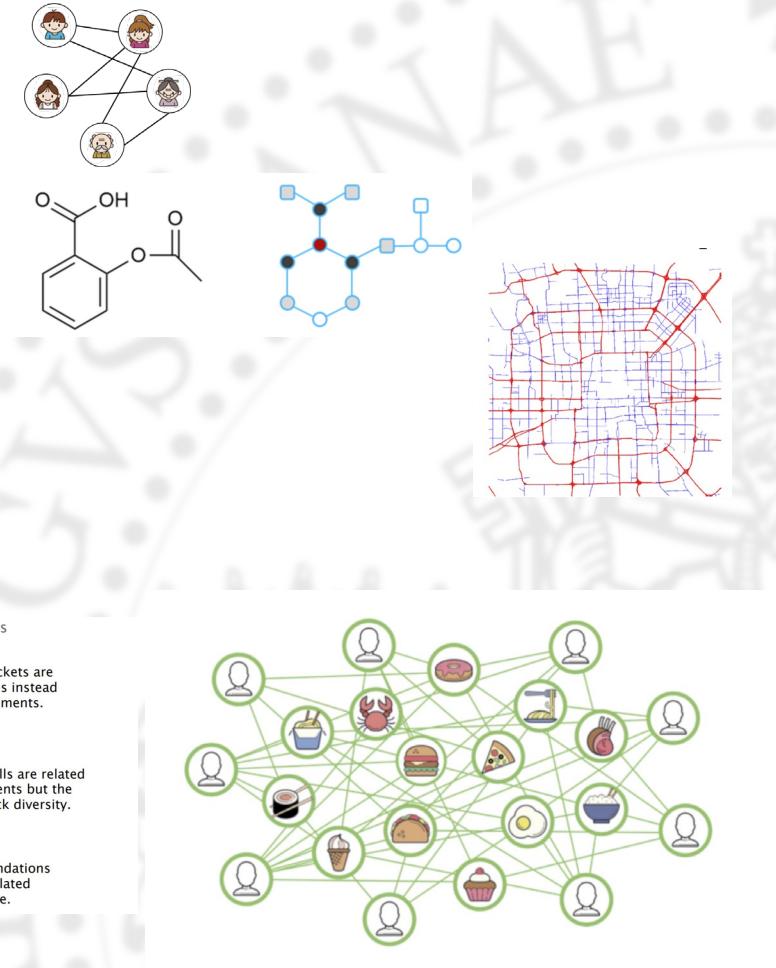
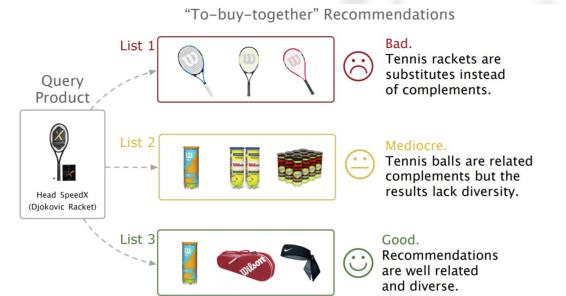
- **Redes aplicadas a grafos:**

- Redes sociales
- Química
- Conceptos y mapas de palabras
- Sistemas de recomendación
- Objetos 3d
- Mapas, redes de Comunicaciones, infraestructuras
- Tráfico, Transporte, Telemática



*In Pursuit of the Traveling Salesman:  
Mathematics at the Limits of Computation*  
William J. Cook  
Attention, learn to solve routing problems

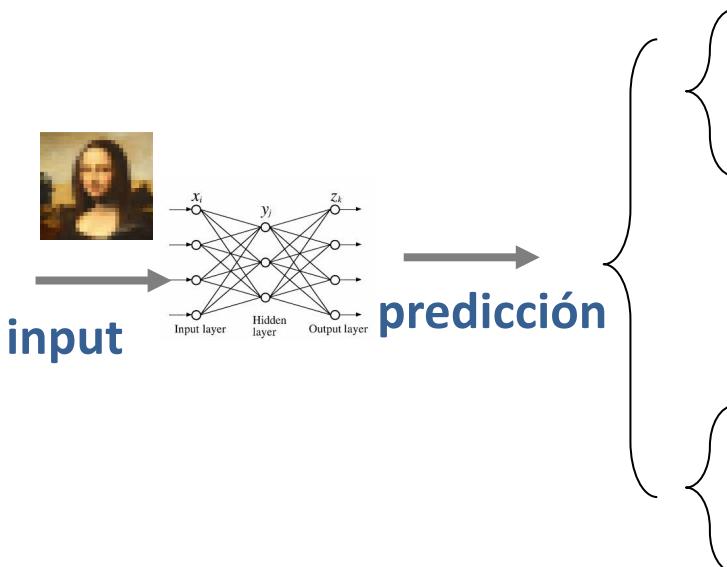
*A principled framework for diversified complementary product recommendation. Amazon 2020*



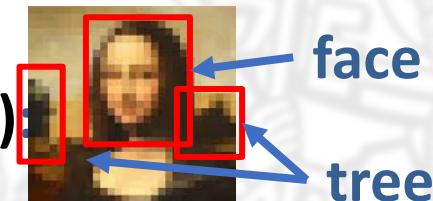
# Tipos de Redes: entrenamiento

- **Aprendizaje supervisado:**

- Ajuste de una función de coste mediante etiquetas



**Clasificación (global):** **Mona Lisa**



**Clasificación (múltiple):**

**Regresión (global):** **Age ? -> xx years**



**B&W to RGB  
super-resolution**

**Regresión (múltiple):**

# Tipos de Redes: entrenamiento

- **Aprendizaje no supervisado :**

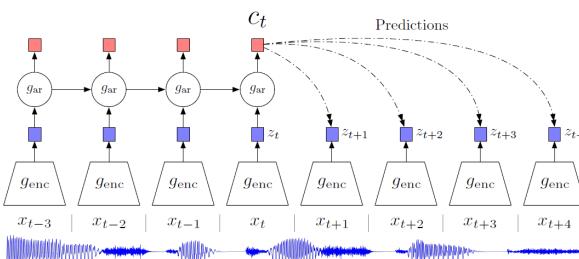
- Las redes aprenden la naturaleza de los datos
  - Podemos conseguir que los sistemas automáticos comprendan los datos forzando a que hagan predicciones sobre lo que no han visto



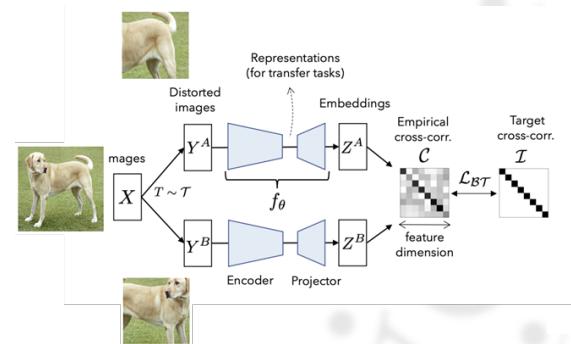
A Oord, N Kalchbrenner, O Vinyals, L Espeholt, A Graves, K Kavukcuoglu  
Conditional Image Generation with PixelCNN Decoders 2016

# Tipos de Redes

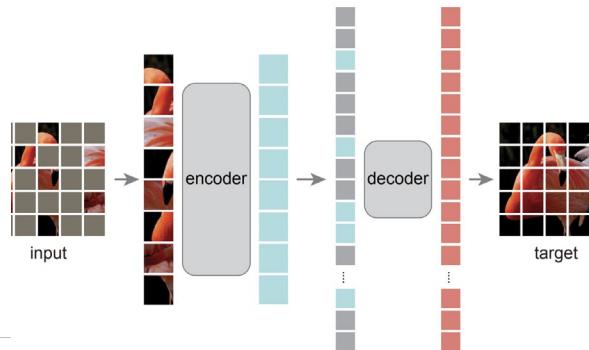
- **Self-supervised learning:**
  - Estrategias:



Una estrategia es dar varias opciones como si fuera un examen



Resolver la pregunta:  
¿son partes de la misma imagen ?

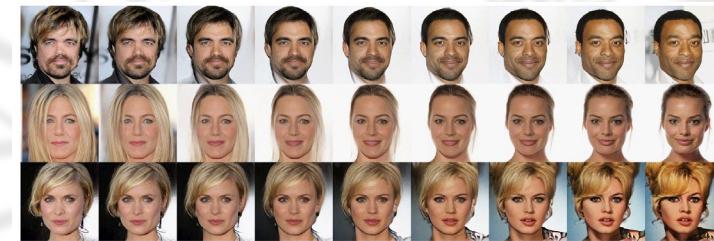
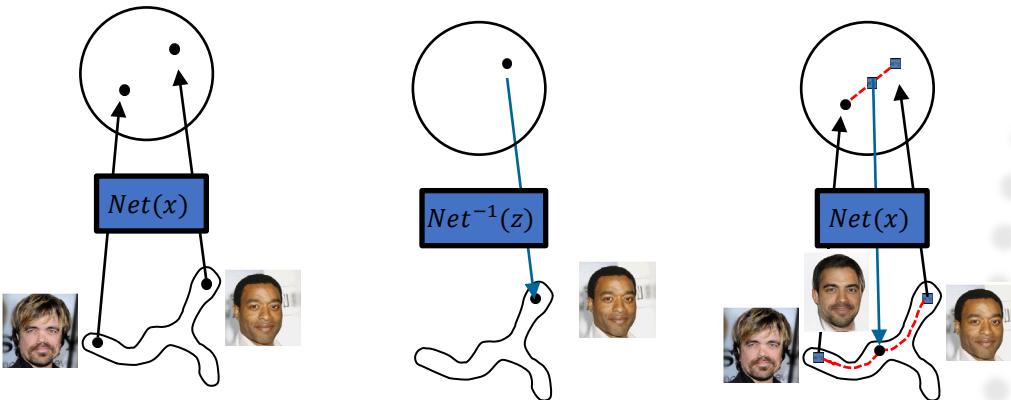


Reconstruir la imagen a partir de una con occlusiones



# Aplicaciones

- **Generación de Contenidos:**
  - Síntesis de voz, música, imágenes, ...
  - **Podemos aprender a manipular las imágenes**
    - ¿Qué pasa si cambio la representación para conseguir otra imagen distinta?

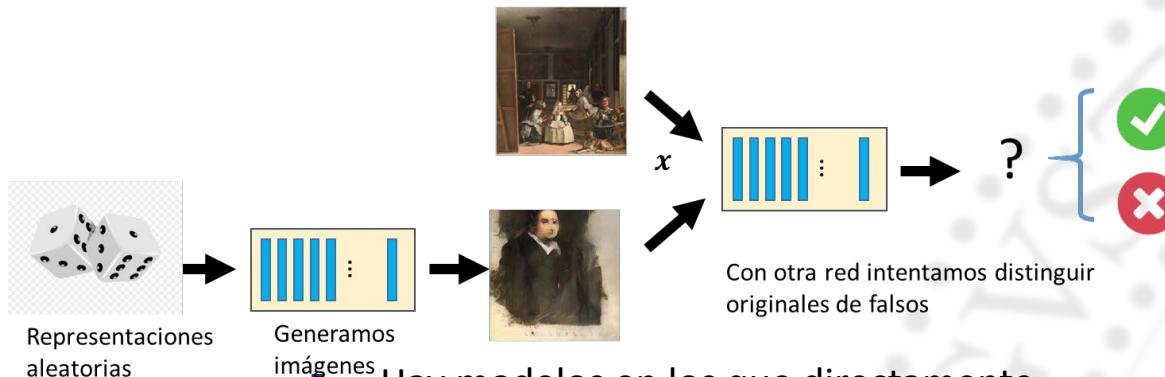


Generación de nuevas imágenes que nunca han existido

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

- **Generación de Contenidos:**
  - Síntesis de voz, música, imágenes, ...



Hay modelos en los que directamente se aprende a generar imágenes

- **Generative adversarial network**



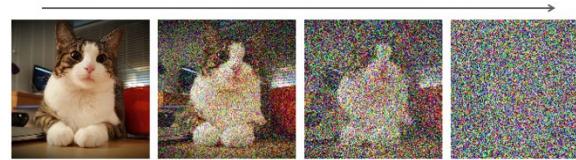
Este proceso se ha sofisticado mucho en menos de 10 años

# Aplicaciones

- **Generación de Contenidos:**

- Sintesis de voz, música, imágenes, ...

Podemos añadir ruido hasta que no se reconozca la imagen



Con una red aprendemos a “limpiar” ese ruido



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



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



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



Ho, J., Jain, A., & Abbeel, P. (2020). Denoising diffusion probabilistic models. arXiv preprint arXiv:2006.11239

Son capaces de generar imágenes tan realistas como los GANs

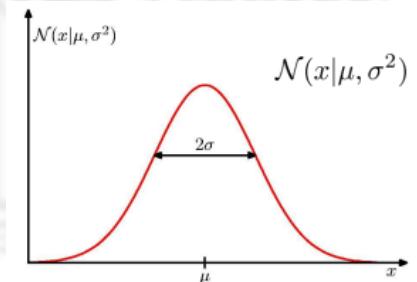
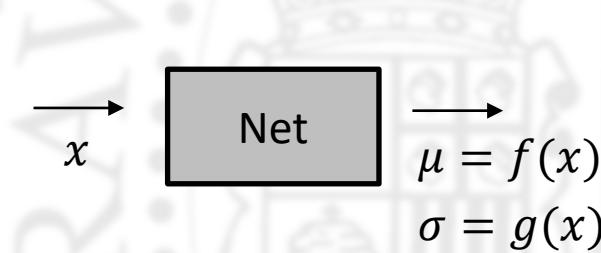
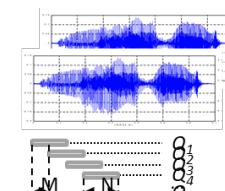


Medieval 1230 book page illustrating  
monks playing basketball

# Aplicaciones

- **Redes aplicadas al modelado estadístico**

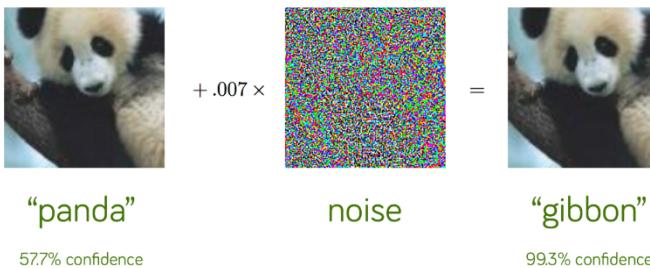
- Tratan de definir una probabilidad o una verosimilitud con respecto a la población que se ha usado para entrenarlas
- Aplicaciones:
  - Generar nuevos datos
  - Detección de ejemplos fuera de distribución
    - Fraude
    - Anomalías



# Robustez

- **Adversarial attacks**

- Un pequeño cambio en la imagen puede hacer que cambie la predicción



*Goodfellow, I. J., Shlens, J., & Szegedy, C. (2014). Explaining and harnessing adversarial examples. arXiv preprint arXiv:1412.6572.*



**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)*



→ Speed Limit 80  
(88% confidence)

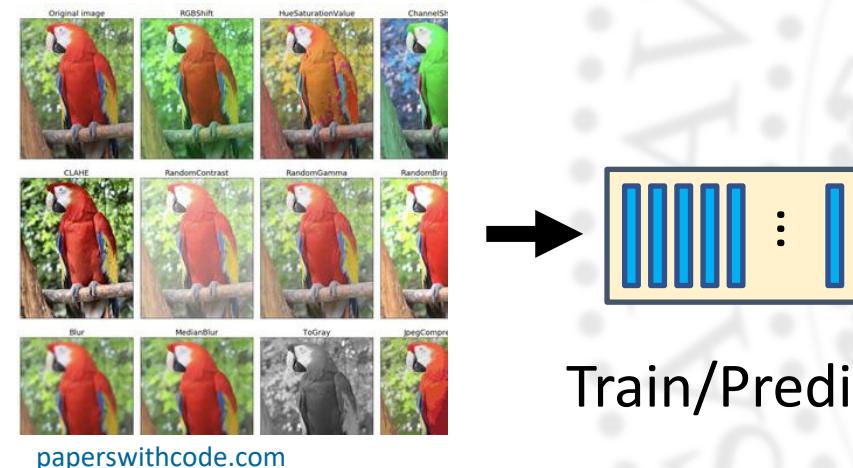
**Robust physical-world attacks on deep learning visual classification.**

*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).*

# Augmentation

- **Data augmentation**

- Incrementar artificialmente el dataset mediante datos transformados
  - Dependen de la tarea:
    - Imagen: rotaciones, occlusiones, escalado, recortes, transformaciones
    - Audio: ruido, reverberación
- El sistema se vuelve más robusto
  - Se expone a más variabilidad durante el entrenamiento
  - También se puede hacer al predecir (TTA test time augmentations)

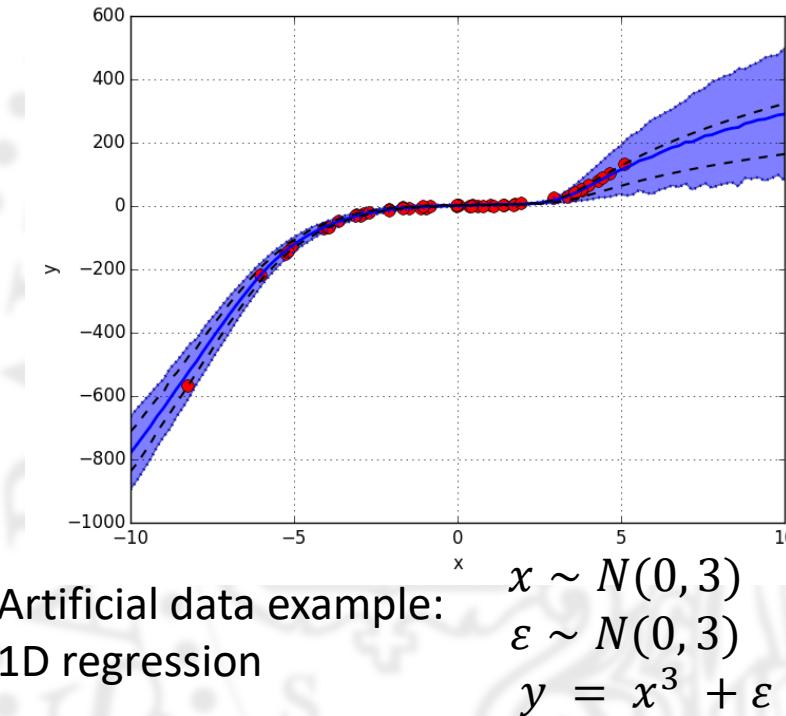
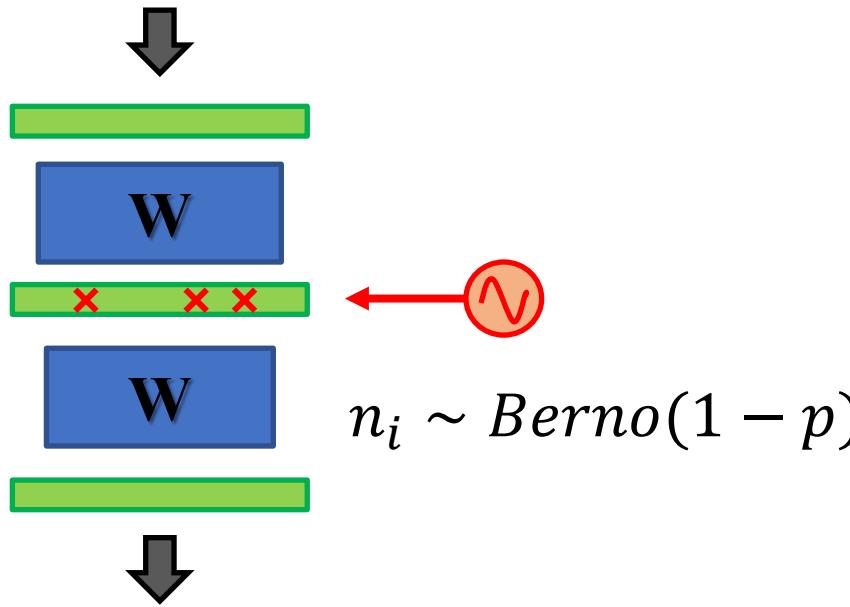


# Dropout

- **Dropout (Hinton 2012)**

Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R., 2014. Dropout: a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), pp.1929-1958.

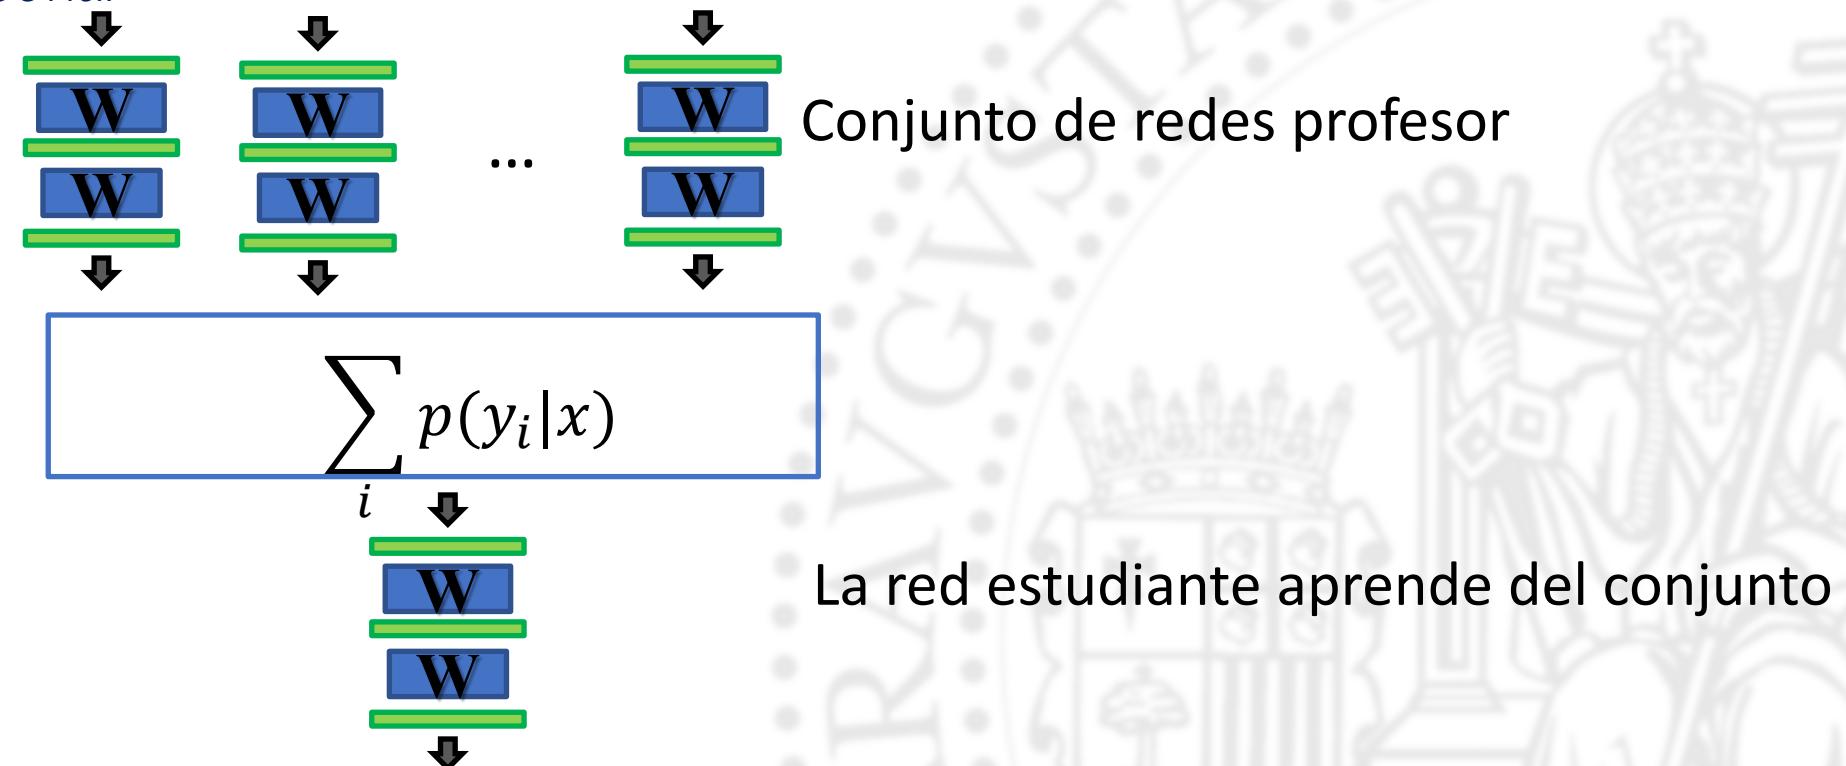
- Desactiva aleatoriamente algunas neuronas durante el entrenamiento
- Se puede aplicar también en predicción (TTA)



# Bayesian dark knowledge

- Bayesian dark knowledge(Korattikara 2015)

Korattikara Balan, A., Rathod, V., Murphy, K. P., & Welling, M. (2015). Bayesian dark knowledge. *Advances in Neural Information Processing Systems*, 28, 3438-3446..



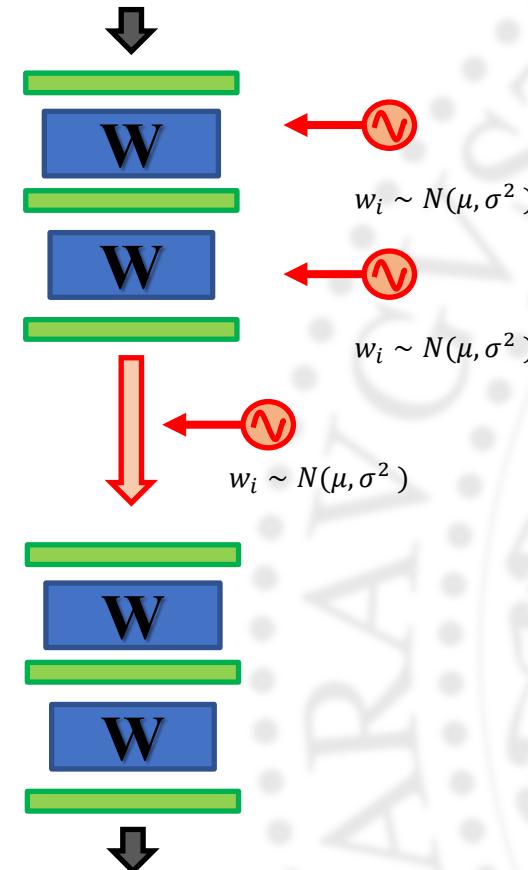
# Bayesian dark knowledge

- Bayesian dark knowledge(Korattikara 2015)

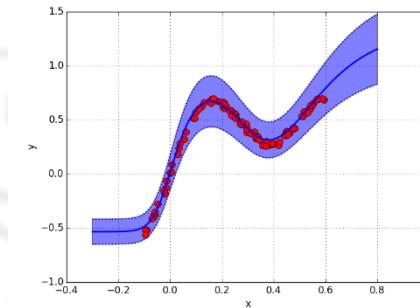
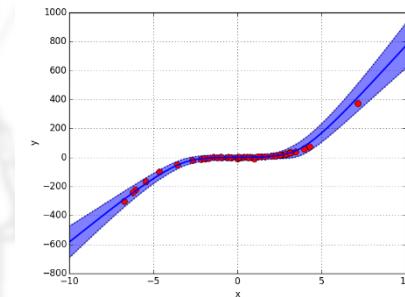
Korattikara Balan, A., Rathod, V., Murphy, K. P., & Welling, M. (2015). Bayesian dark knowledge. *Advances in Neural Information Processing Systems*, 28, 3438-3446..

Teacher network,  
muestrea

Student network,  
Aprende la variabilidad



Examples regression



# Ejemplos

<https://colab.research.google.com/drive/1Plplrls6XKIQYfafVkJpysV5dzmJim7?usp=sharing>

<https://colab.research.google.com/drive/1sgmP9FLzK3uUncigViUR74o3caTHB5k2?usp=sharing>

[https://colab.research.google.com/drive/1t\\_bpo-lPkP1YULkOScduscSQ\\_f7cLlhN?usp=sharing](https://colab.research.google.com/drive/1t_bpo-lPkP1YULkOScduscSQ_f7cLlhN?usp=sharing)

<https://colab.research.google.com/drive/1t9ZUHjUphMhwBSbTWOoPWpJWxDteWjT51?usp=sharing>

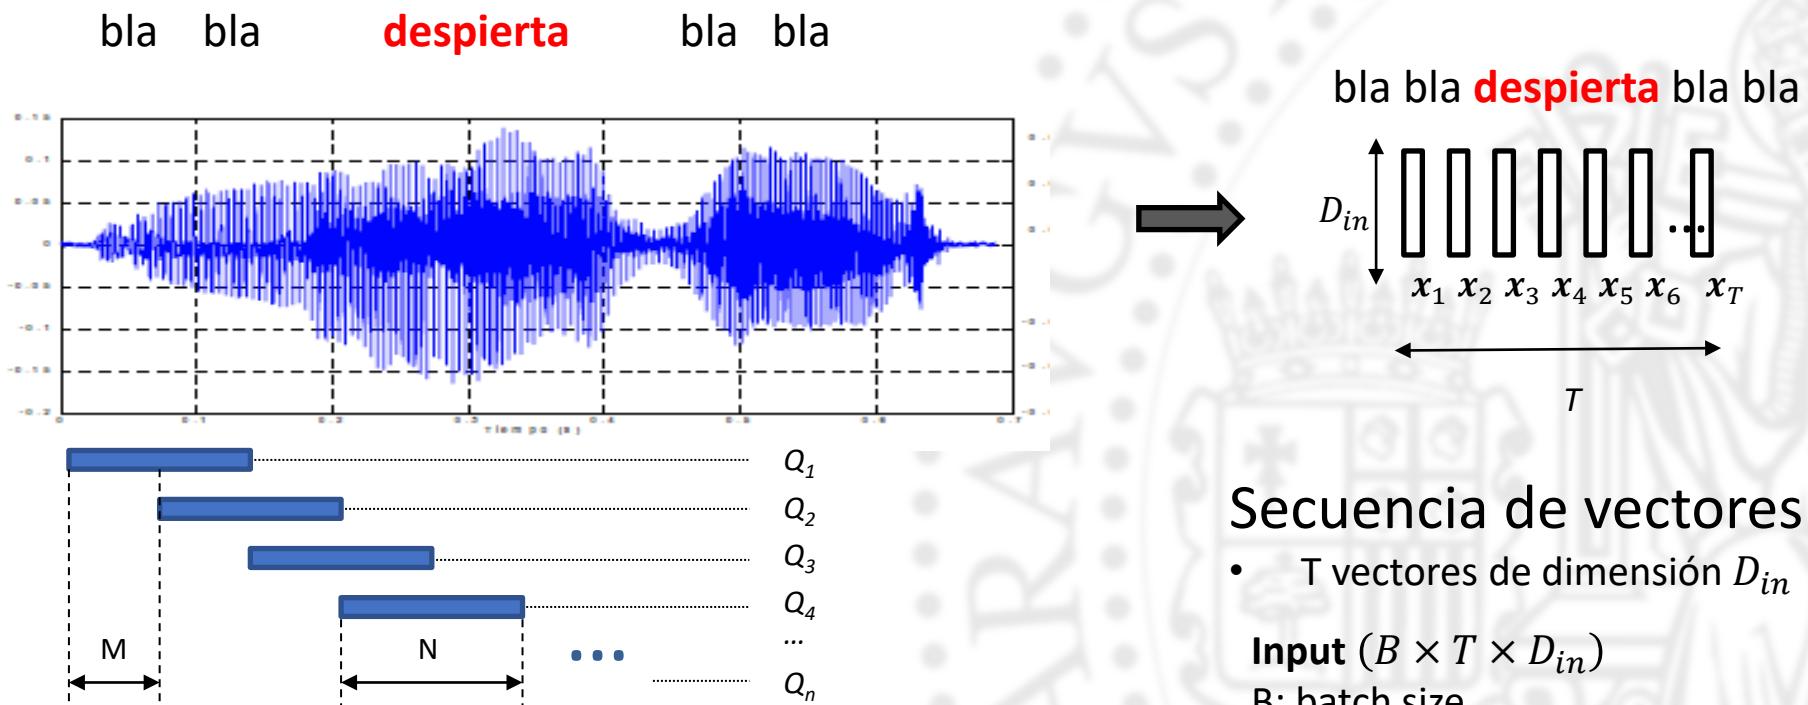
[https://colab.research.google.com/drive/15GtY0NaKFpanjXDQFKXz\\_AaTE0022oN-?usp=sharing](https://colab.research.google.com/drive/15GtY0NaKFpanjXDQFKXz_AaTE0022oN-?usp=sharing)

[https://colab.research.google.com/drive/1qsNusOm\\_mzagzytwadZOeFlk6eejg4\\_j?usp=sharing](https://colab.research.google.com/drive/1qsNusOm_mzagzytwadZOeFlk6eejg4_j?usp=sharing)

[https://colab.research.google.com/drive/1B4nsB5vCr5jBP7cHerc-G5V3DmpvE\\_B-?usp=sharing](https://colab.research.google.com/drive/1B4nsB5vCr5jBP7cHerc-G5V3DmpvE_B-?usp=sharing)

# Redes convolucionales

- Ejemplo: análisis de audio (o texto)
  - Queremos procesar una secuencia de vectores



Secuencia de vectores

- $T$  vectores de dimensión  $D_{in}$

**Input** ( $B \times T \times D_{in}$ )

$B$ : batch size

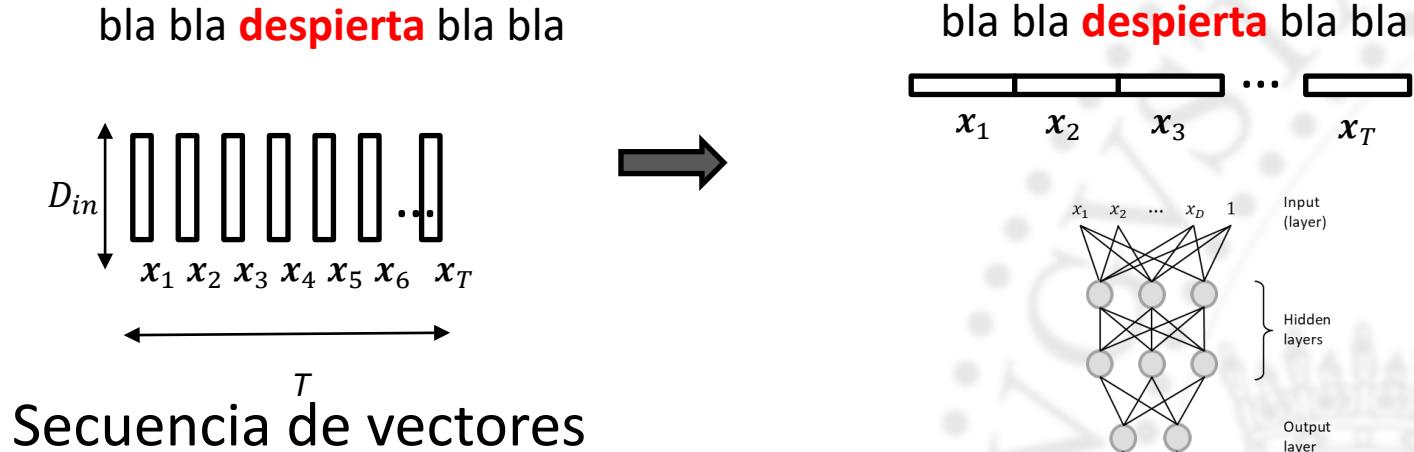
$T$ : seq. Length

$D_{in}$ : feature dim.

# Redes convolucionales

- **Ejemplo:**

- ¿Podemos aplicar un MLP?



Podríamos concatenar todos los vectores

- Esto podría funcionar si  $T$  es fijo

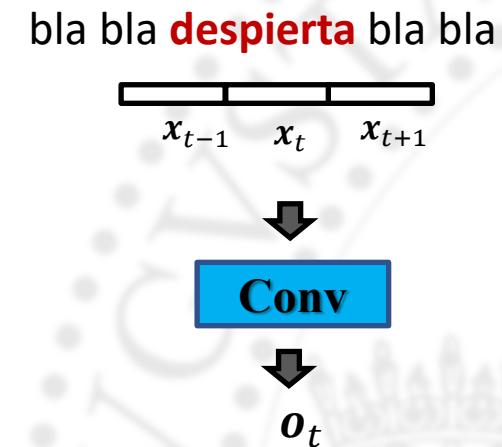
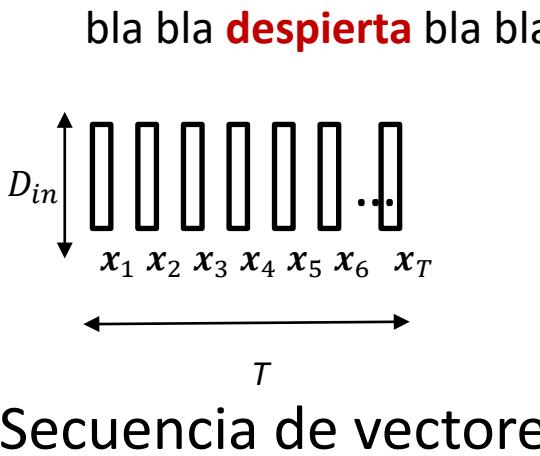
Problemas

- ¿Qué pasa si  $T$  es variable?
- ¿Qué pasa si desplazamos la secuencia?

# Redes convolucionales

- **Ejemplo:**

- ¿Podemos aplicar procesado deslizante?



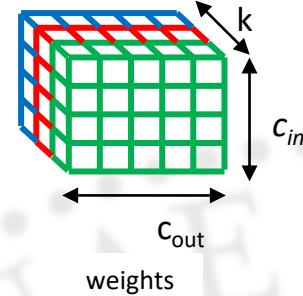
Definimos un contexto (**kernel\_size**) sobre el que vamos a calcular, por ejemplo  $k=3$  y una operación lineal:

$$o_t = W_0 x_{t-1} + W_1 x_t + W_2 x_{t+1}$$

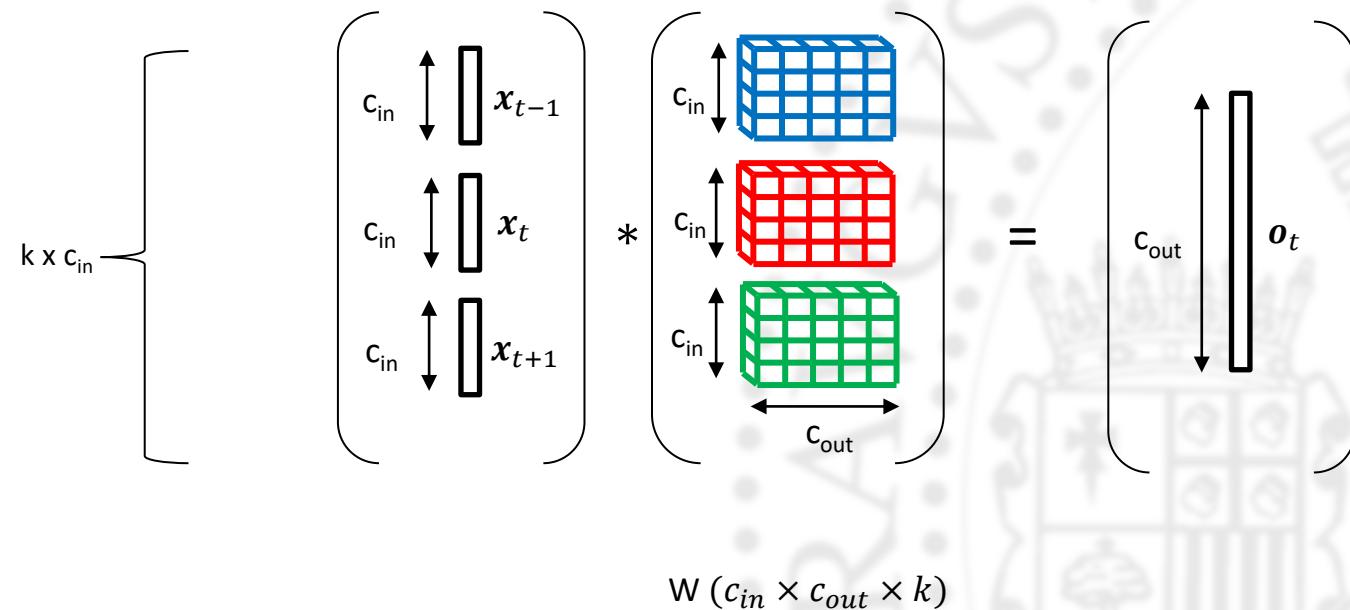
- las matrices  $W_i$  ( $c_{in} \times c_{out}$ ) se reutilizan en cada posición  $t$
- Las dimensiones de entrada y salida se denominan **canales**

# Redes convolucionales

- **Convolución 1D (DNNs)**
  - Interpretación matricial



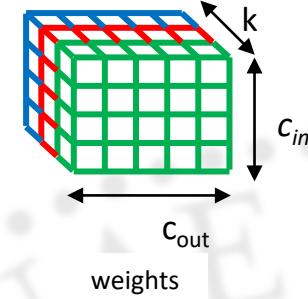
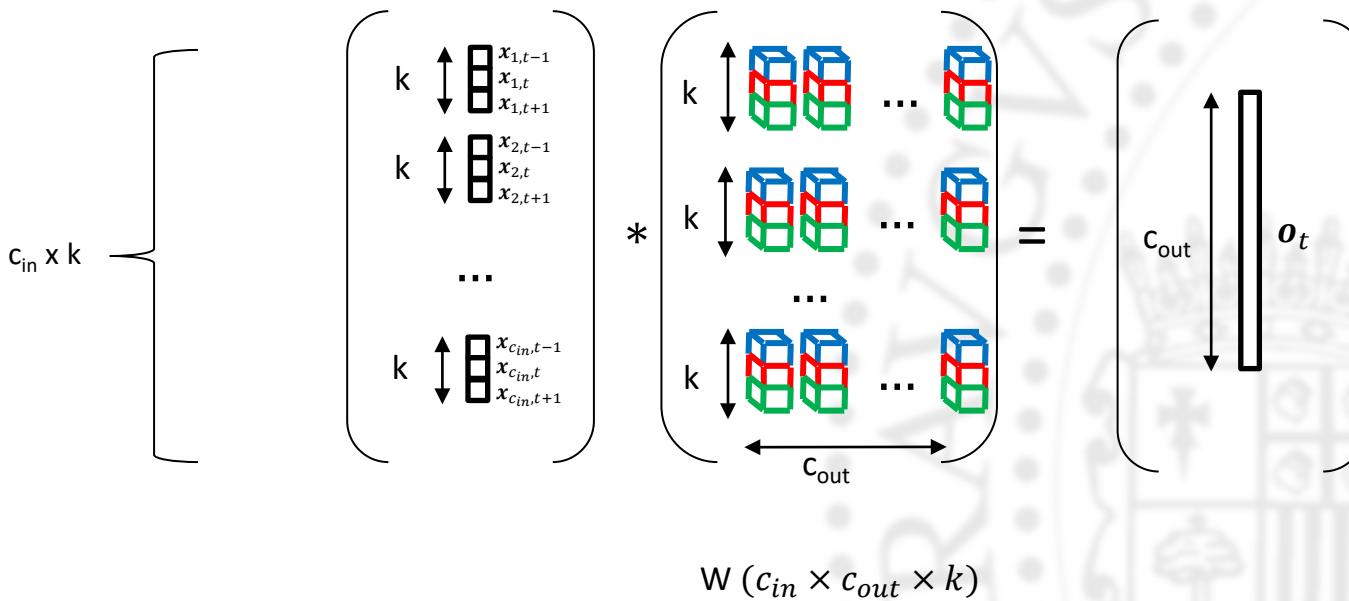
$W (c_{in} \times c_{out} \times k)$



# Redes convolucionales

- **Convolución 1D (DNNs)**

- Interpretación convoluciones:
  - Todos los canales de entrada x todos los canales de salida


 $W (c_{in} \times c_{out} \times k)$ 

 $W (c_{in} \times c_{out} \times k)$

# Redes convolucionales

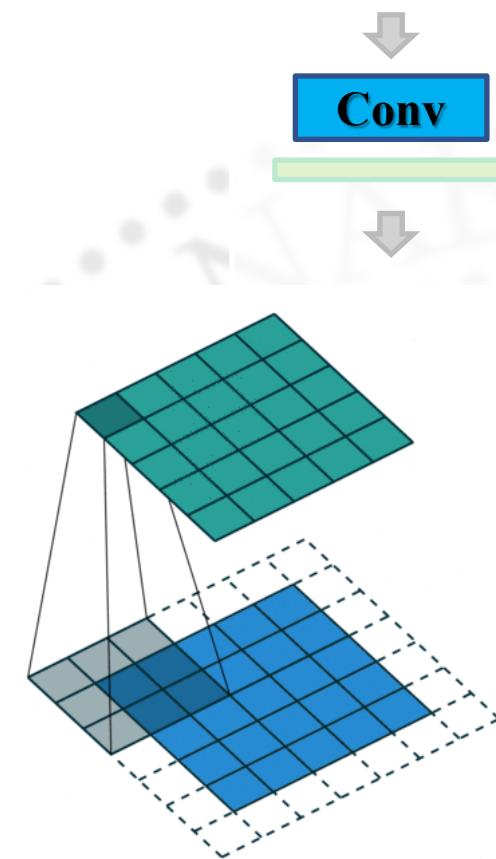
- **Convolución 1D/2D/3D (CNNs),**

- Ejemplo pytorch:

- Convolution2d ejemplo:
      - 4 input channels (dimensión entrada)
      - 5 output channels (dimensión salida)
      - 3 kernel size
      - 1 stride (sin muestreo)
      - 1 padding (mismo tamaño de salida)

```
pytorch
```

```
import torch
layer = torch.nn.Conv1d(4, 5, 3, padding=1)
x = torch.randn(32, 4, 100)
print(x.shape)
o = layer(x)
print(o.shape)
```



*A guide to convolution arithmetic for deep learning*  
[Vincent Dumoulin](https://arxiv.org/abs/1603.07285) 2016 <https://arxiv.org/abs/1603.07285>

TODO ejemplo conv2d filtros

# Redes convolucionales

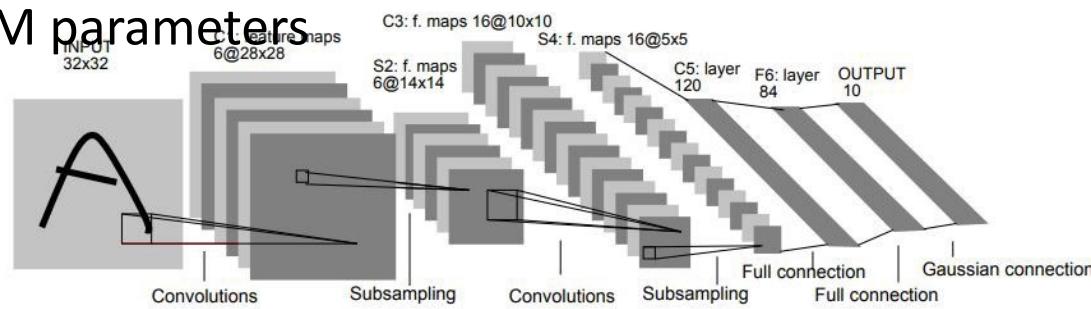
- **LeNet5 (Yann Lecun, 1998)**

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

- Modelo de referencia (redes convolucionales)

- **Resumen:**

- 2 capas conv2d
- 2 capas Pooling (diezmado)
- Flatten/Reshape para convertir a vector
- 2 Dense layers
- 1.6M parameters



<https://engmrk.com/lenet-5-a-classic-cnn-architecture/>

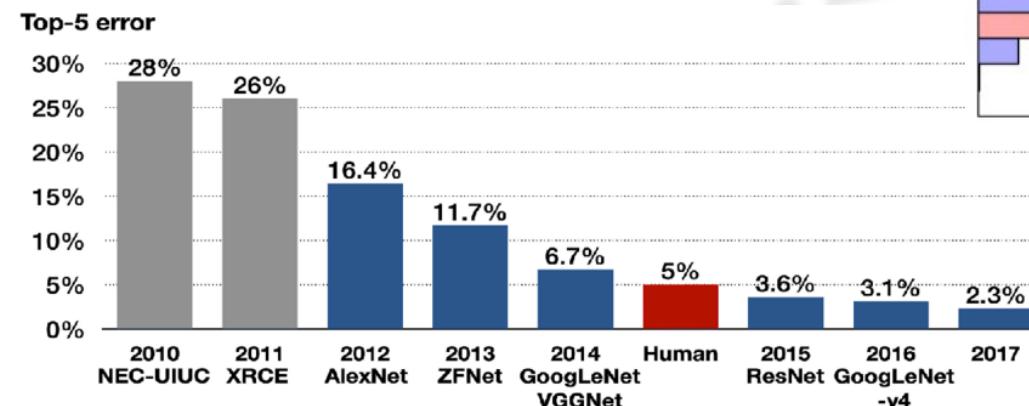
Model: "sequential"

Layer (type)	Output Shape	Param #
<hr/>		
conv2d (Conv2D)	(None, 32, 32, 20)	1520
activation (Activation)	(None, 32, 32, 20)	0
max_pooling2d (MaxPooling2D)	(None, 16, 16, 20)	0
conv2d_1 (Conv2D)	(None, 16, 16, 50)	25050
activation_1 (Activation)	(None, 16, 16, 50)	0
max_pooling2d_1 (MaxPooling2 (None, 8, 8, 50)	0	
flatten (Flatten)	(None, 3200)	0
dense (Dense)	(None, 500)	1600500
activation_2 (Activation)	(None, 500)	0
dense_1 (Dense)	(None, 100)	50100
activation_3 (Activation)	(None, 100)	0
<hr/>		
Total params:	1,677,170	
Trainable params:	1,677,170	
Non-trainable params:	0	

<https://medium.com/ai-in-plain-english/lenet-5-the-22-year-old-neural-network-ce4af257ecd3>

# Redes convolucionales

- Imagenet challenge
- 1000 clases, imágenes RGB
  - Hay ambigüedad en las etiquetas
  - por eso a veces se da la tasa top5
  - (error si no está entre las 5 primeras opciones)

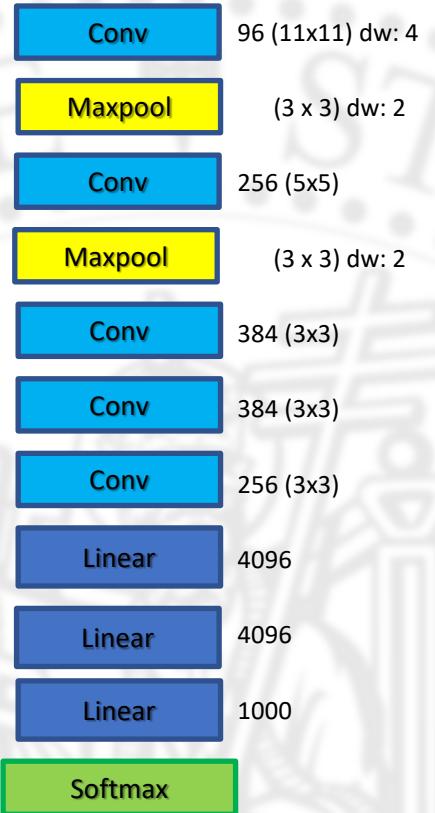


# Redes convolucionales

## • Alexnet (Krizhevsky, 2012)

Krizhevsky, A., Hinton, G. E., Sutskever, I. (2012). *Imagenet classification with deep convolutional neural networks*. *Advances in neural information processing systems*, 25, 1106-1114.

- Imagenet: 84.6 % top5 accuracy
- Aumento de profundidad con respecto a LeNet5:
  - GPUs
  - Uso de momento y weight\_decay
  - Nueva técnica: dropout
  - Usa relus
  - Flatten -> modelo muy grande 62M parámetros



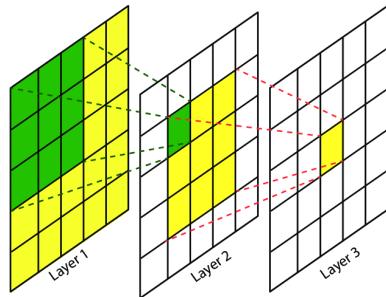
<https://engmrk.com/alexnet-implementation-using-keras/>

# Redes convolucionales

- **VGG16 (Simonyan, 2014)**

*Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.*

- Imagenet 92.7% top-5
- Más profundidad 16 capas 138M:



- El número de coeficientes para un tamaño 5x5 es de 25
- La composición de dos de 3x3  
 $3 \times 3 + 3 \times 3 = 18$

Mientras que el campo receptivo es equivalente

Conv	64 (3x3)
Conv	64 (3x3)
Maxpool	(2 x 2) dw: 2
Conv	128 (3x3)
Conv	128 (3x3)
Maxpool	(2 x 2) dw: 2
Conv	256 (3x3)
Conv	256 (3x3)
Conv	256 (3x3)
Maxpool	(2 x 2) dw: 2
Conv	512 (3x3)
Conv	512 (3x3)
Conv	512 (3x3)
Maxpool	(2 x 2) dw: 2
Conv	512 (3x3)
Conv	512 (3x3)
Conv	512 (3x3)
Maxpool	(3 x 3) dw: 2
Linear	4096
Linear	4096
Linear	1000
Softmax	

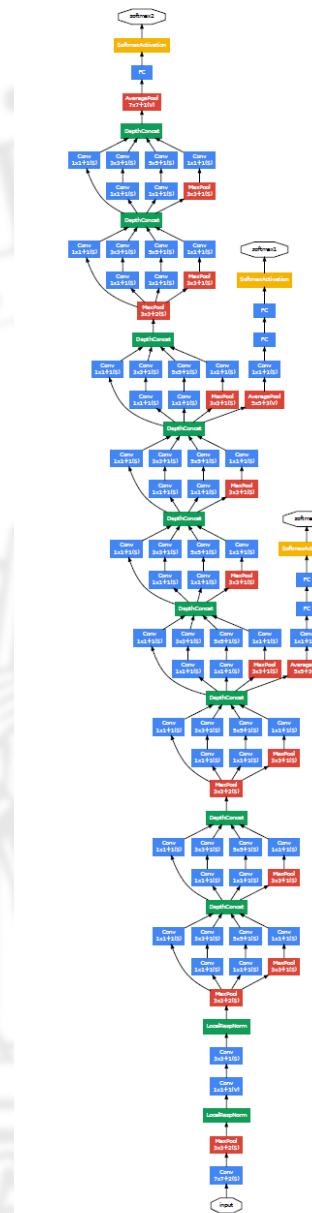
<https://engmrk.com/alexnet-implementation-using-keras/>

# Redes convolucionales

- **GoogleLeNet Inception (Szegedy, 2014)**

Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A., 2015. Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).

- Imagenet 93.3% top-5 accuracy (winner 2014)
- Aumento de profundidad, 22 capas, 4M
- Mean average pooling



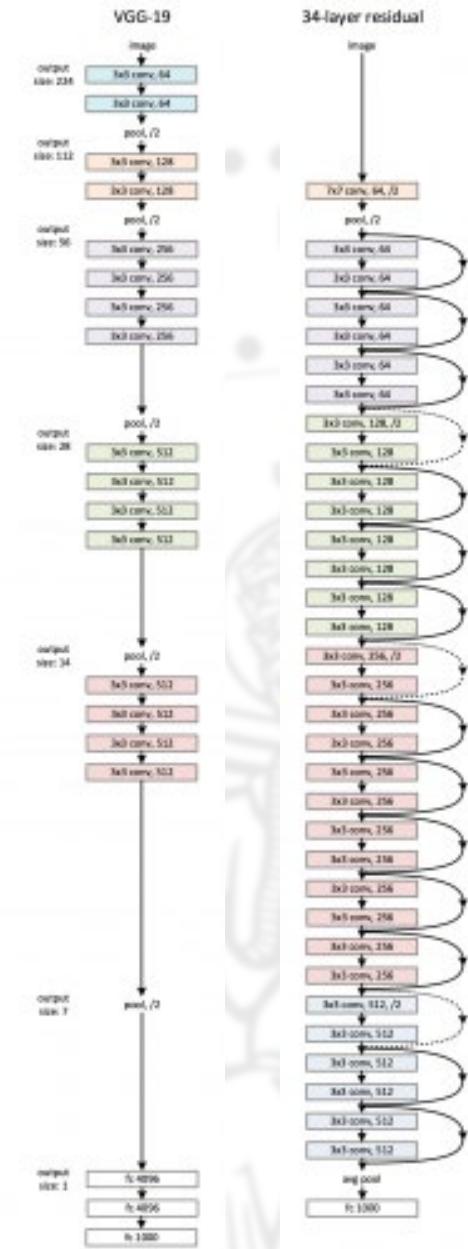
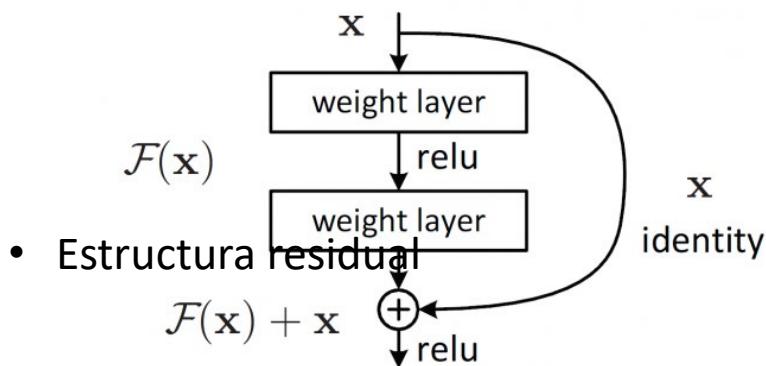
# Redes convolucionales

- **Resnet (Kaiming, 2015)**

*He, K., Zhang, X., Ren, S. and Sun, J., 2016. Deep residual learning for image recognition.*

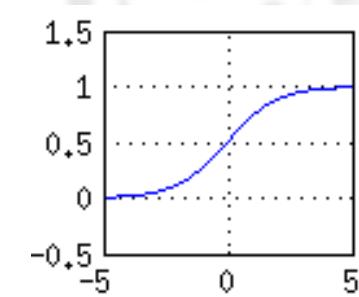
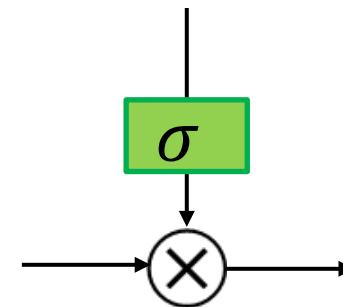
*In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).*

- Imagenet 2015: 96.43% top-5
- Aumento enorme de la profundidad:
  - 152 capas, 60M



# Redes convolucionales

- **Modelos de atención**
  - Puerta sigmoide:
    - juega el papel de una puerta lógica que deja pasar o no la información en función de su entrada



$$f(x) = \frac{1}{1 + \exp(-x)}$$

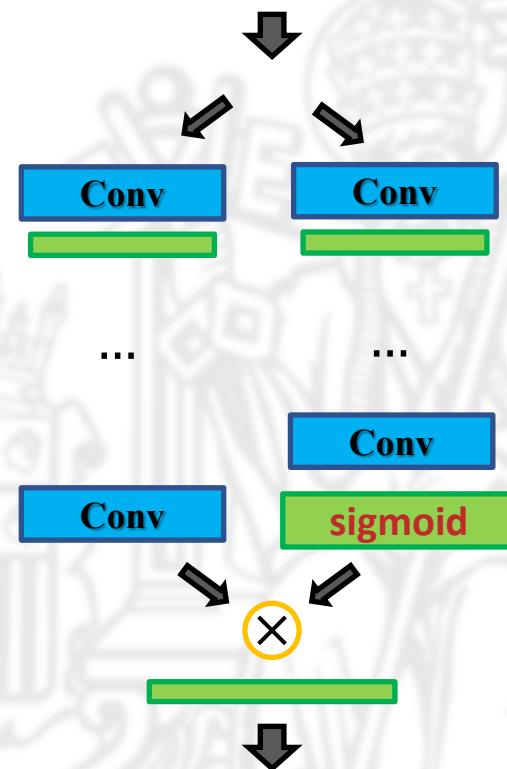
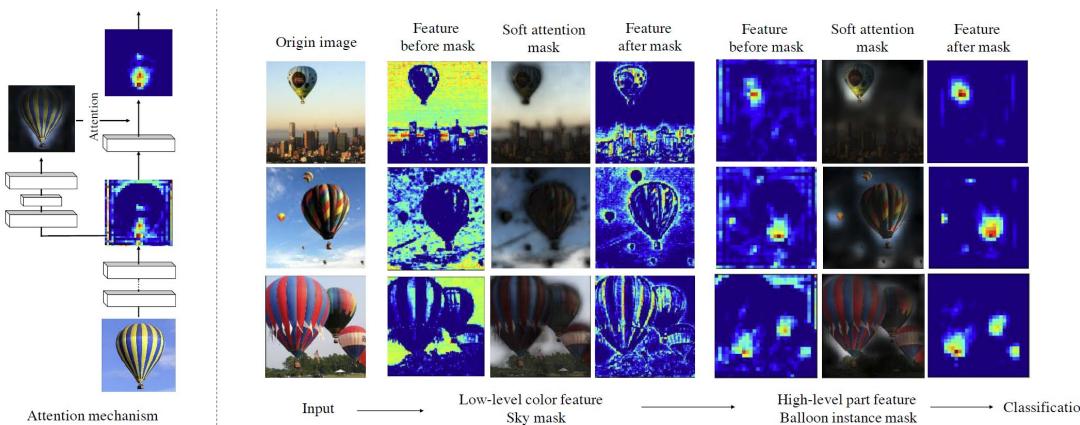
# Redes convolucionales

## • Modelos de atención

Srivastava, Rupesh Kumar, Klaus Greff, and Jürgen Schmidhuber. "Highway networks." arXiv preprint arXiv:1505.00387 (2015).

Wang, F., Jiang, M., Qian, C., Yang, S., Li, C., Zhang, H., ... & Tang, X. (2017). Residual attention network for image classification. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 3156-3164).

- En estos modelos la red decide en la rama de atención
  - Qué información debe anular/dejar pasar

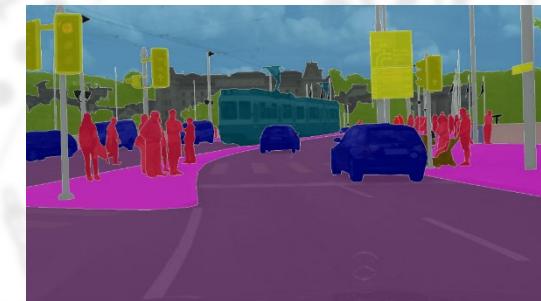
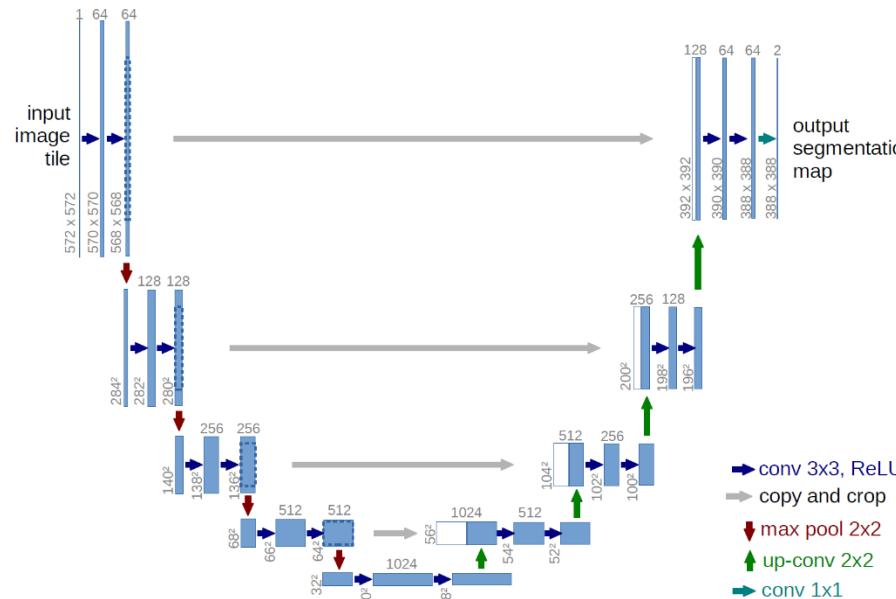


# Redes convolucionales

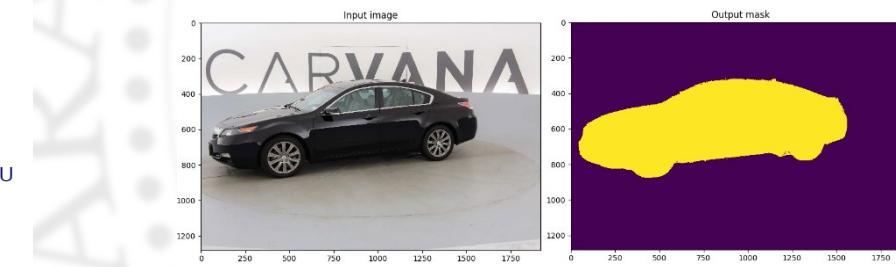
## • Unet (Ronneberger, 2015)

Ronneberger, O., Fischer, P., & Brox, T. (2015, October). U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.

- Procesado multiescala
- Los caminos bypass mejoran la resolución
- Muy utilizada en segmentación



Multiclass segmentation

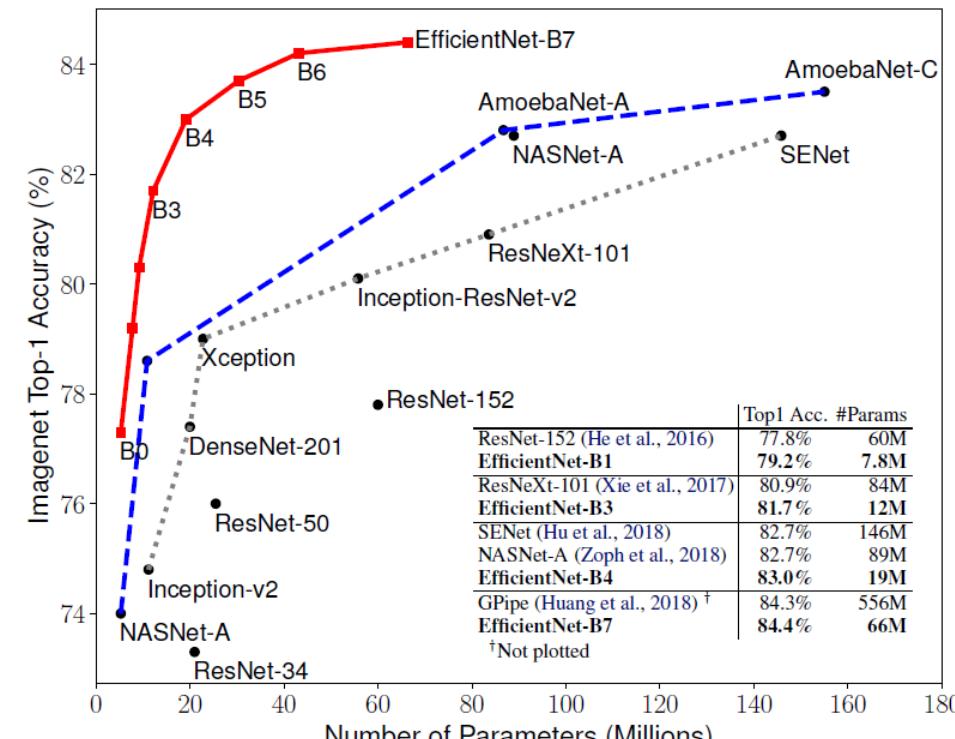


# Redes convolucionales

## • Efficientnet (Tan, Quoc Le, 2019)

Tan, M., & Le, Q. V. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. arXiv preprint arXiv:1905.11946.

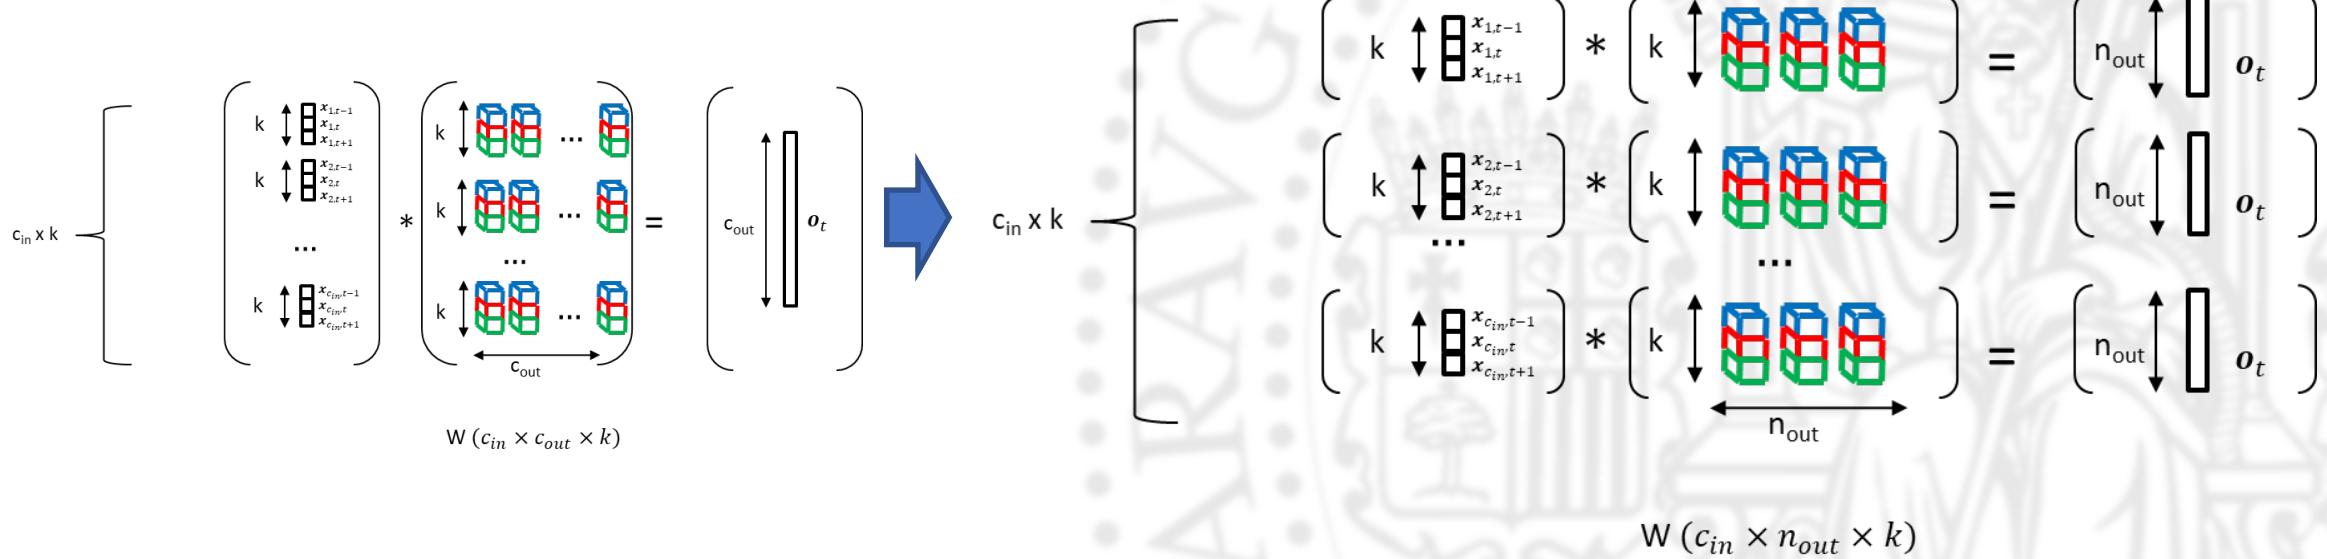
- En los últimos años se están buscando arquitecturas que reduzcan el coste computacional/energético



# Redes convolucionales

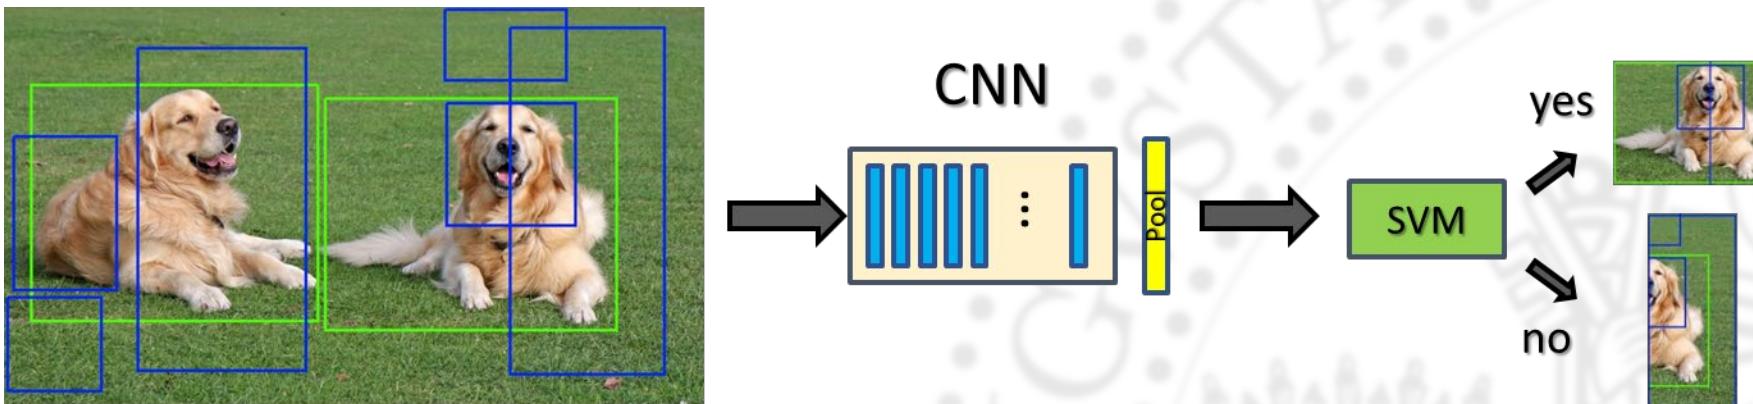
- Efficientnet (Tan, Quoc Le, 2019)

- Depthwise convolutions: convoluciones ligeras
  - no multiplican todos los canales



# Redes convolucionales

- **Detección de objetos**



- **Region CNN**

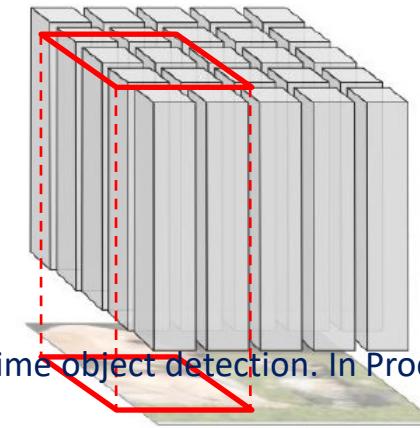
- Se entrena una red para procesar las regiones y extraer un embedding
- Poco eficiente porque se procesa varias veces la imagen

# Redes convolucionales

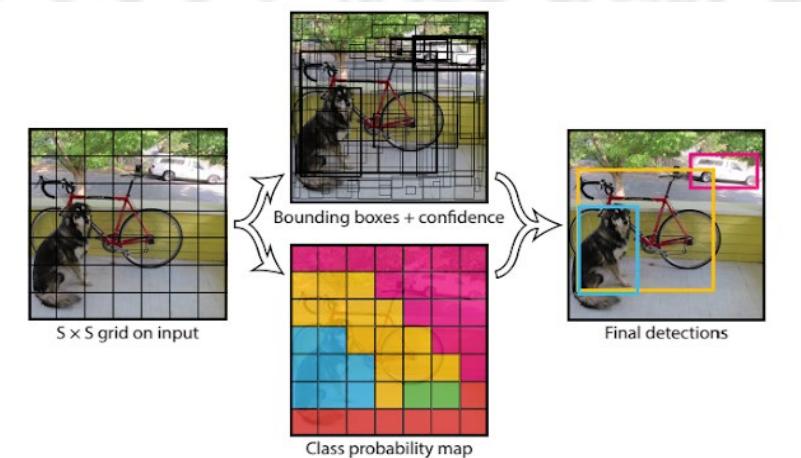
- Object detection
- YOLO, You Only Look Once:

Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 779-788).

- La red procesa la imagen una vez
- Por cada zona final predice los objetos que hay en esa zona
- Muy rápido puede perder objetos



<https://distill.pub/2018/building-blocks/>



# Redes convolucionales

- **Reconocimiento facial**
  - responder la pregunta
    - ¿Es la misma persona?
  - La mayoría de los enfoques usan datos de entrenamiento etiquetados (imágenes + identidad)
  - Entrenar una tarea de clasificación, función de pérdida CrossEntropy

Labeled Faces in the Wild

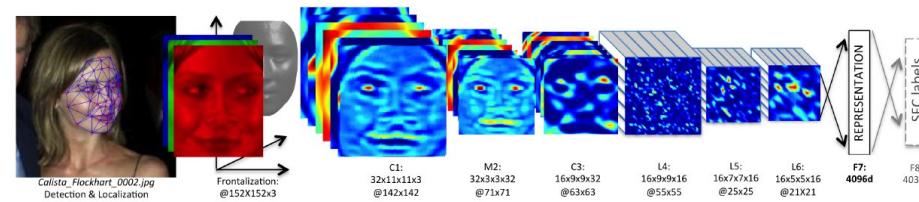


<http://vis-www.cs.umass.edu/lfw/>

- **Deep face 2014**

Taigman, Y., Yang, M., Ranzato, M. A., & Wolf, L. (2014). Deepface: Closing the gap to human-level performance in face verification. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1701-1708).

**Input:**  
Imagen cara

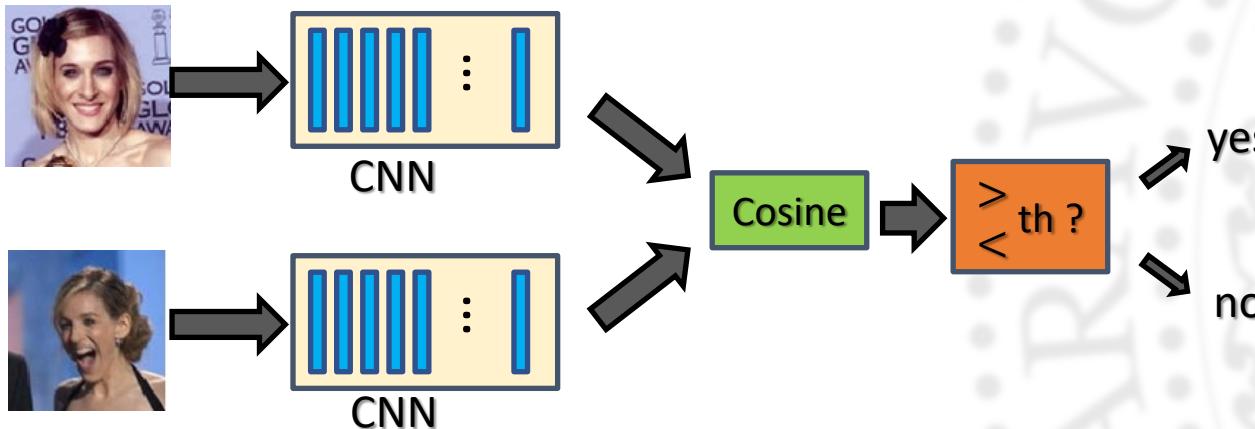


**Label:**  
Identidad, se intenta clasificar

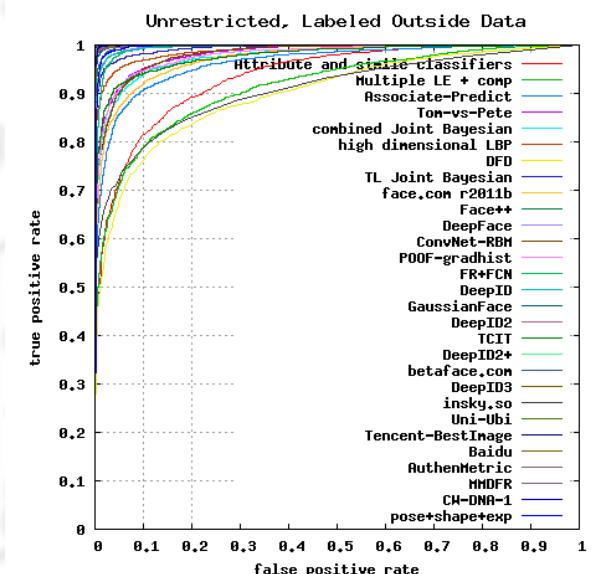
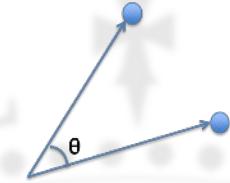
# Redes convolucionales

- **Similitud coseno**

- Mide el ángulo de separación entre dos vectores
- Muchos sistemas usan una red p. ej (CNN) para generar **representaciones**
  - La última capa lineal y softmax se descartan
  - Se decide mediante un umbral de parecido



$$\text{sim}(A, B) = \cos(\theta) = \frac{A \cdot B}{\|A\| \|B\|}$$

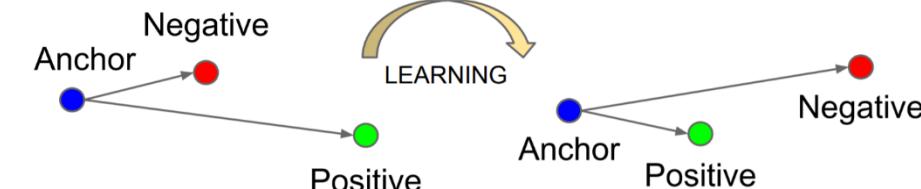
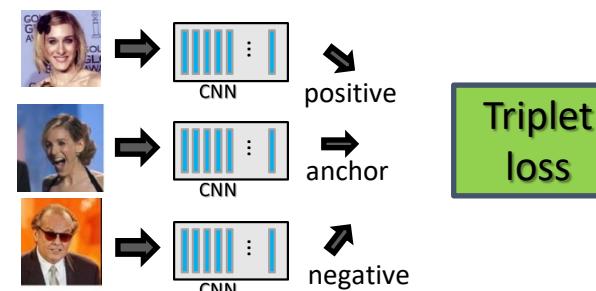


<http://vis-www.cs.umass.edu/lfw/>

# Redes convolucionales

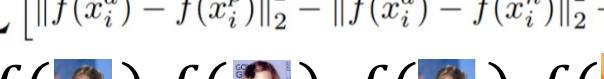
- **Facenet(Schroff 2015)**

Schroff, F., Kalenichenko, D., & Philbin, J. (2015). Facenet: A unified embedding for face recognition and clustering. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 815-823).



- **Triplet loss**
    - Ancla y positive misma identidad: los acerca
    - Separa negativo del ancla

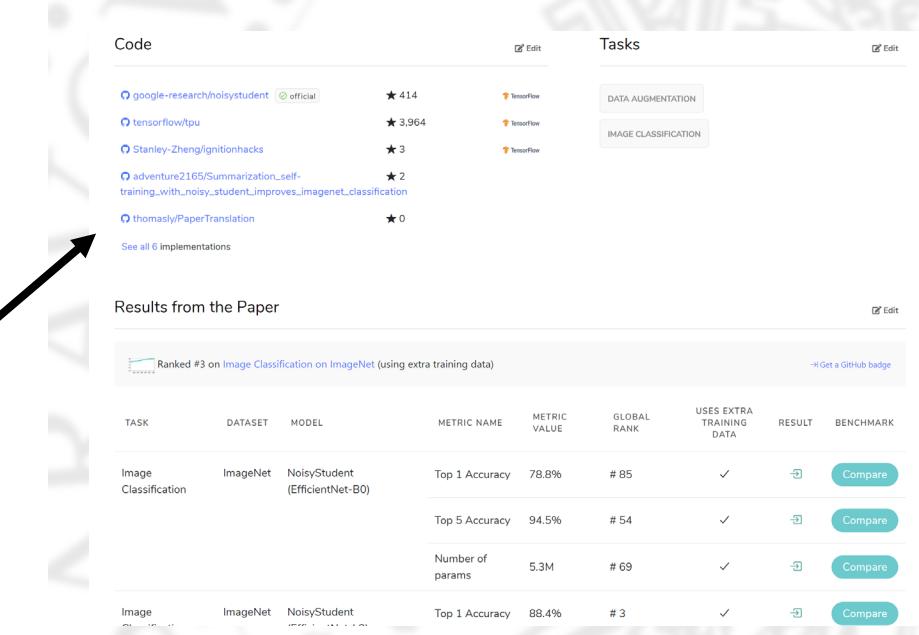
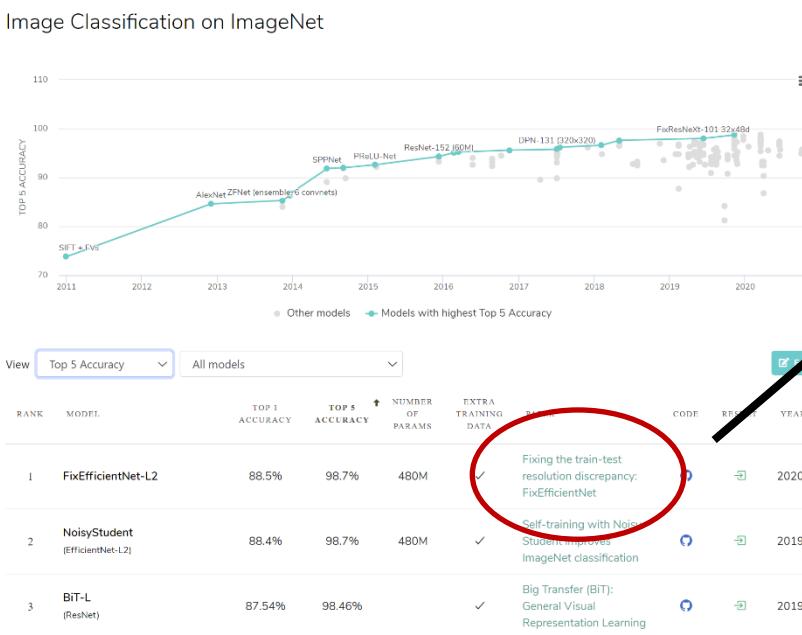
$$Triplet_{loss} = \sum_i^N \left[ \|f(x_i^a) - f(x_i^p)\|_2^2 - \|f(x_i^a) - f(x_i^n)\|_2^2 + \alpha \right]$$


  
 Minimize separation      Maximize separation

# Redes convolucionales

- **Papers with code:**

- <https://paperswithcode.com/sota/image-classification-on-imagenet>
- Muy útil para comprobar el estado del arte de muchas tareas
- Además indica implementaciones en código abierto disponibles



Code

See all 6 implementations

OWNER	NAME	STARS	LICENSE
google-research/noisystudent	noisystudent	414	TensorFlow
tensorflow/tf-pu	tf-pu	3,964	TensorFlow
Stanley-Zheng/ignition-hacks	ignition-hacks	3	TensorFlow
adventure2165/Summarization_self-training_with_noisy_student_improves_imagenet_classification	Summarization	2	TensorFlow
thomasyli/PaperTranslation	PaperTranslation	0	

Tasks

DATA AUGMENTATION | IMAGE CLASSIFICATION

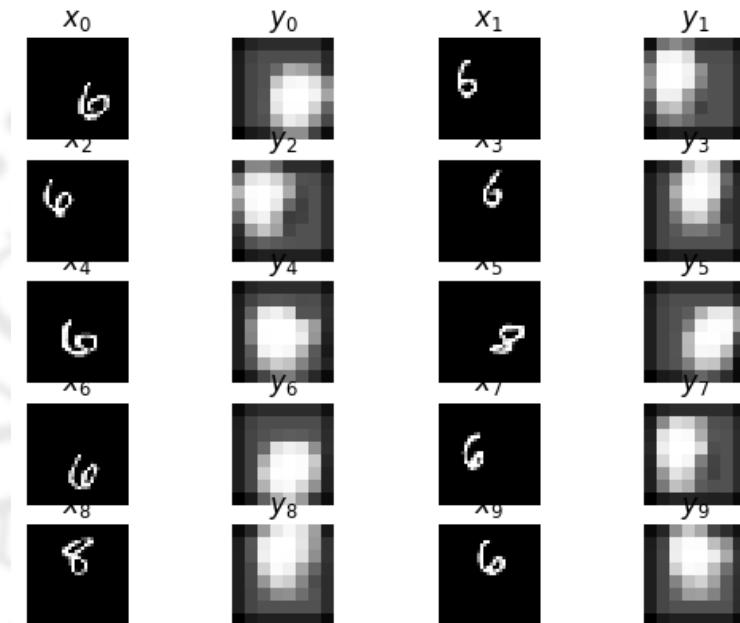
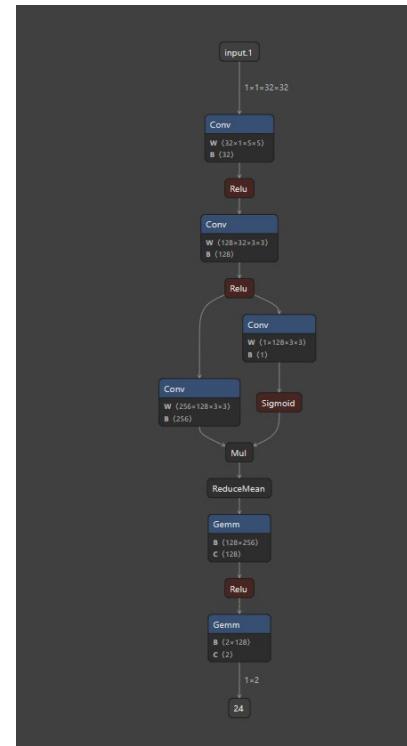
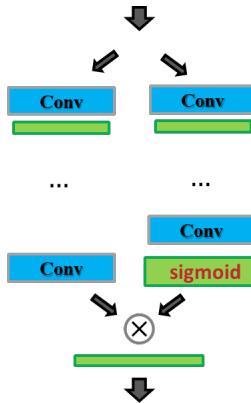
Results from the Paper

Ranked #3 on Image Classification on ImageNet (using extra training data) | Get a GitHub badge

TASK	DATASET	MODEL	METRIC NAME	METRIC VALUE	GLOBAL RANK	USES EXTRA TRAINING DATA	RESULT	BENCHMARK
Image Classification	ImageNet	NoisyStudent (EfficientNet-B0)	Top 1 Accuracy	78.8%	# 85	✓	<a href="#">View</a>	<a href="#">Compare</a>
			Top 5 Accuracy	94.5%	# 54	✓	<a href="#">View</a>	<a href="#">Compare</a>
			Number of params	5.3M	# 69	✓	<a href="#">View</a>	<a href="#">Compare</a>
Image	ImageNet	NoisyStudent	Top 1 Accuracy	88.4%	# 3	✓	<a href="#">View</a>	<a href="#">Compare</a>

# Redes convolucionales

- Ejemplo 1: <https://colab.research.google.com/drive/1Vu3HwaFlxAgDgS4KnD8gfaVwWhSaevsu?usp=sharing>



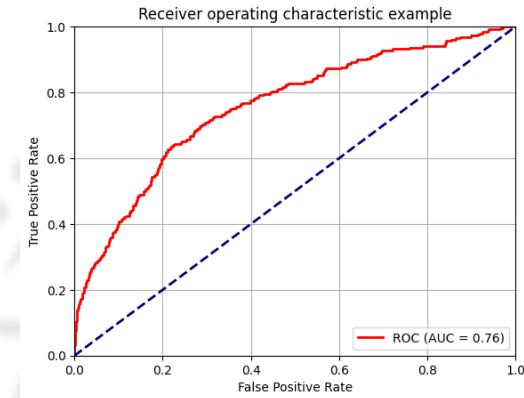
<https://netron.app/>

# Redes convolucionales

- Ejemplo 2: <https://colab.research.google.com/drive/1Zi1icw0J1eSQIGAoejjw27TYI3pVAT4q?usp=sharing>

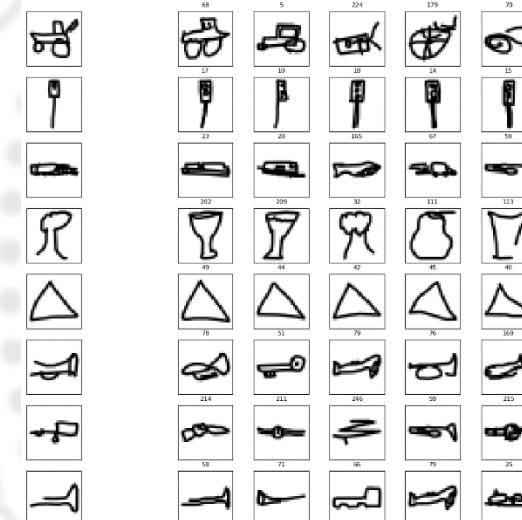


detección



embeddings

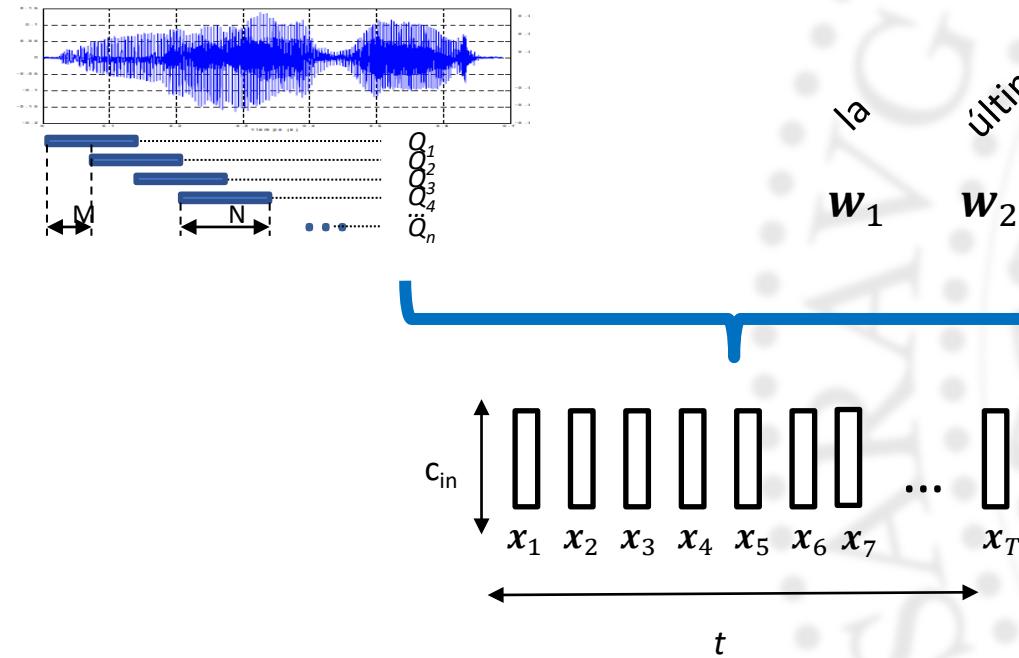
búsqueda



# Redes recurrentes

- **Modelos de secuencia**

- Muchas aplicaciones implican secuencias (orden temporal)
- Ejemplos
  - Audio, voz, texto, señales biológicas (ECG, EEG), señales muestreadas de sensores...



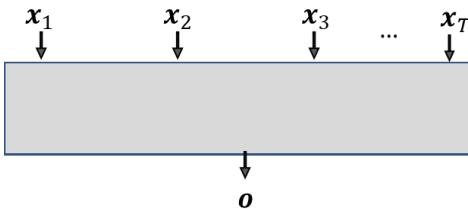
la  
última  
resolución  
de  
naciones

$w_1$     $w_2$     $w_3$     $w_4$     $w_5$

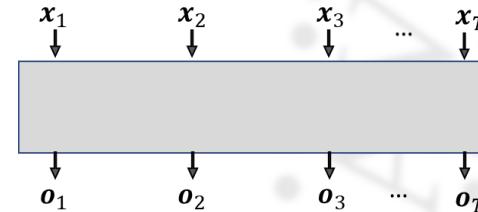
**Input** ( $B \times T \times D_{in}$ )  
 $B$ : batch size  
 $T$ : seq. Length  
 $D_{in}$ : feature dim.

# Redes recurrentes

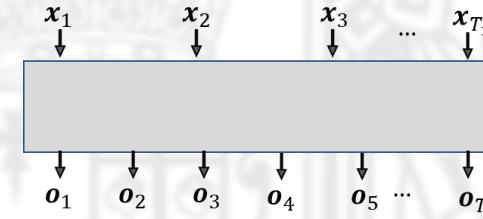
- **Modelos de secuencia**
  - Salida simple (global)
  - Salida múltiple:
  - Seq2seq
    - Diferente tamaño entrada/salida



**Input** ( $B \times T \times D_{in}$ )  
**Output** ( $B \times D_{out}$ )



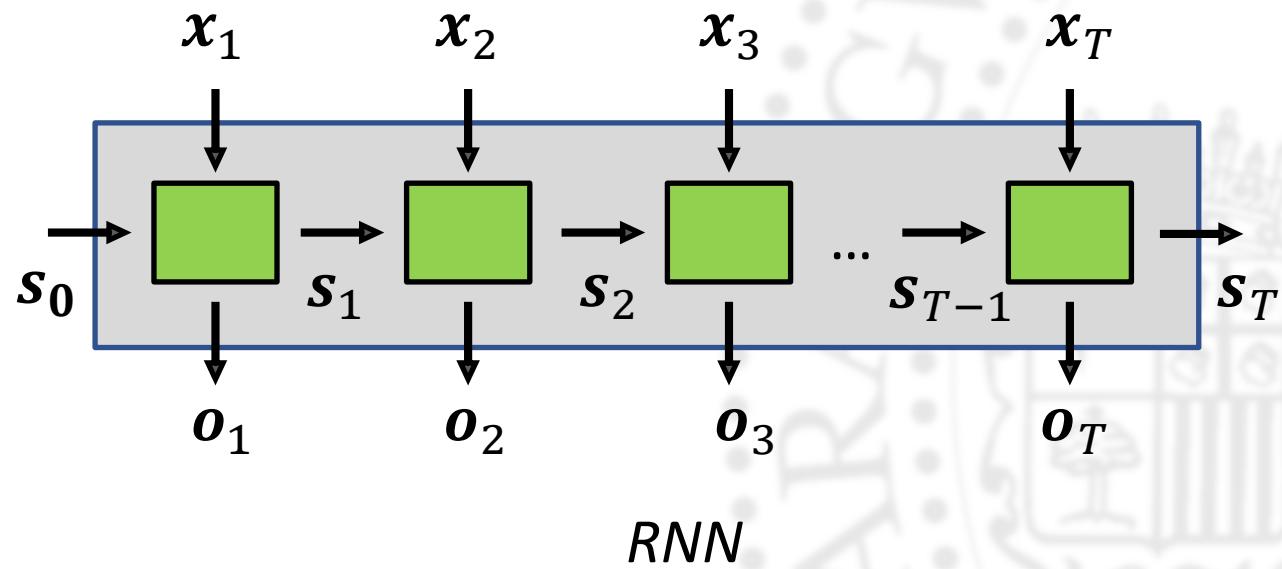
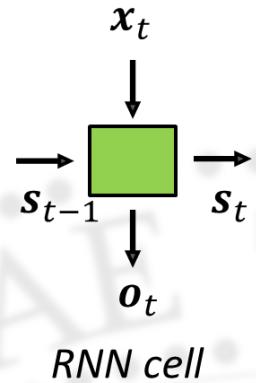
**Input** ( $B \times T \times D_{in}$ )  
**Output** ( $B \times T \times D_{out}$ )



**Input** ( $B \times T_1 \times D_{in}$ )  
**Output** ( $B \times T_2 \times D_{out}$ )  
 $T_1 \neq T_2$

# Redes recurrentes

- Procesado secuencial mediante una celda básica
  - Guarda la información contexto en un estado
  - Puede ser un cuello de botella para la información del pasado: olvida
  - Es difícil de entrenar de forma robusta para secuencias largas

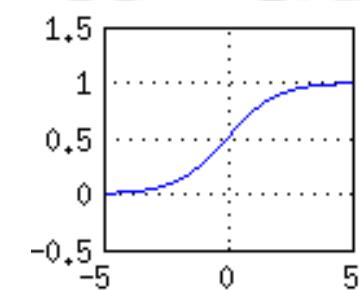
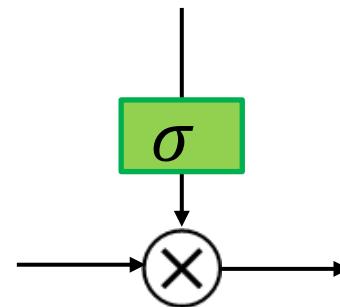


# Redes recurrentes

- **LSTM**

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

- Supuso un gran avance sobre modelos anteriores:
  - problemas de estabilidad
- Usa puertas sigmoide como mecanismo de atención de tipo puerta

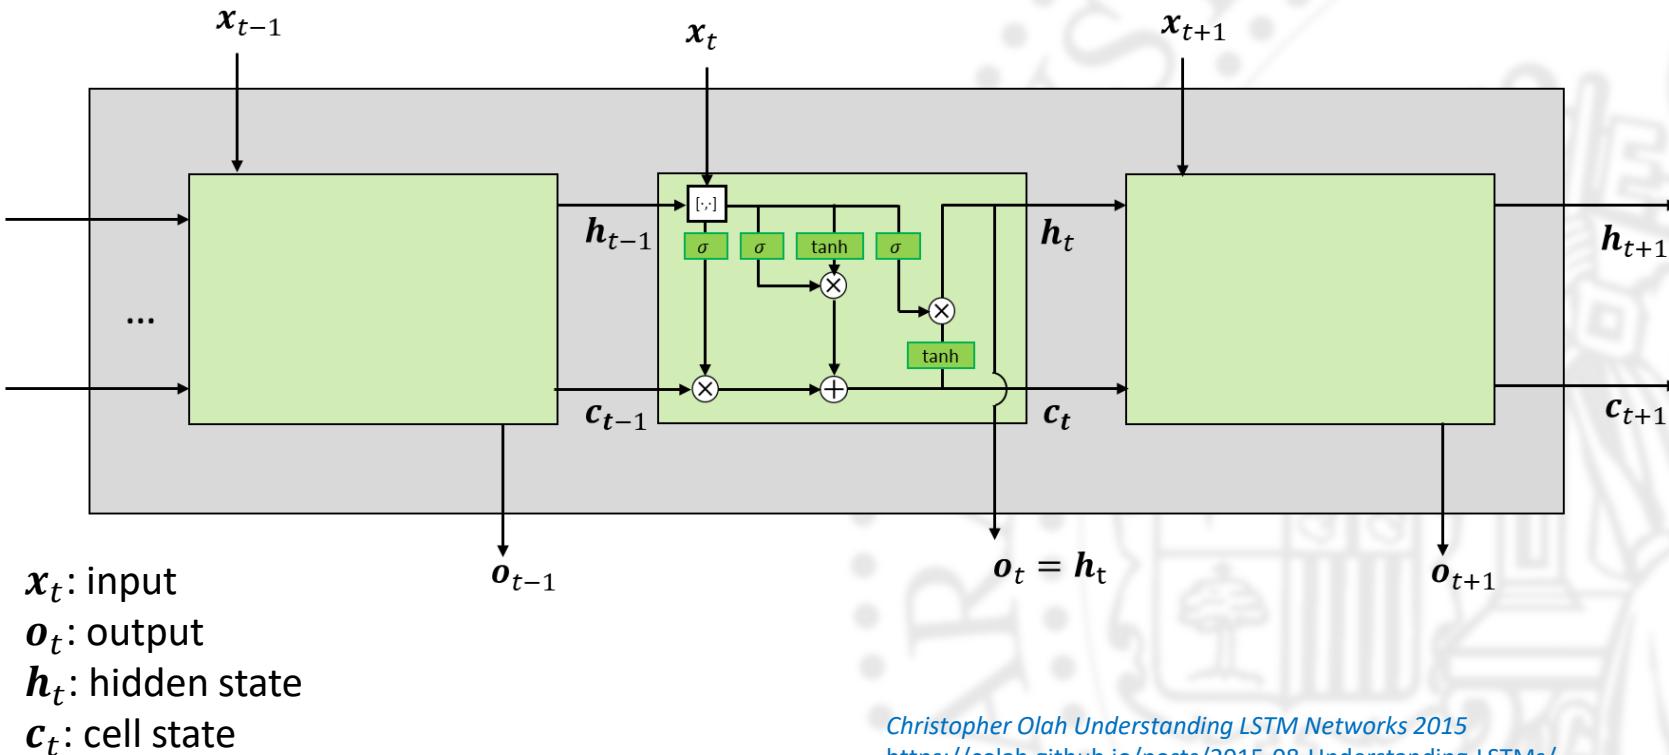


$$f(x) = \frac{1}{1 + \exp(-x)}$$

# Redes recurrentes

- **LSTM**

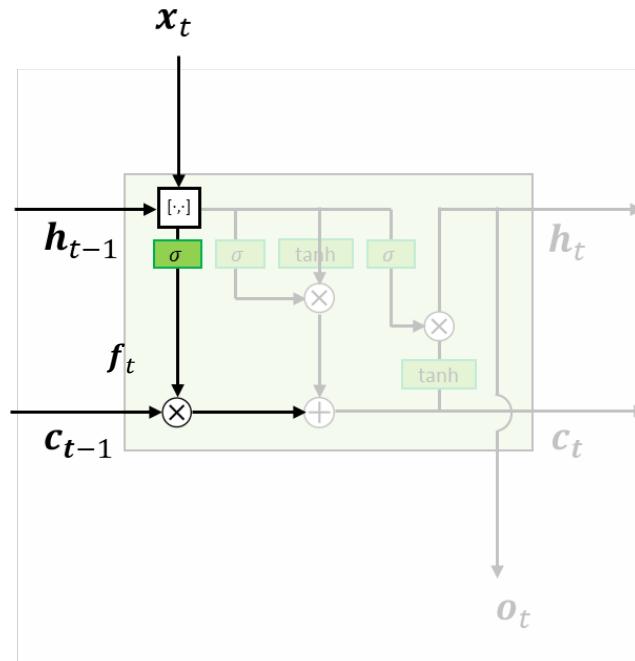
- La estructura interna de las celdas implica varios modelos de atención
- La información de estado se transmite a la siguiente celda



Christopher Olah Understanding LSTM Networks 2015  
<https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

# Redes recurrentes

- LSTM



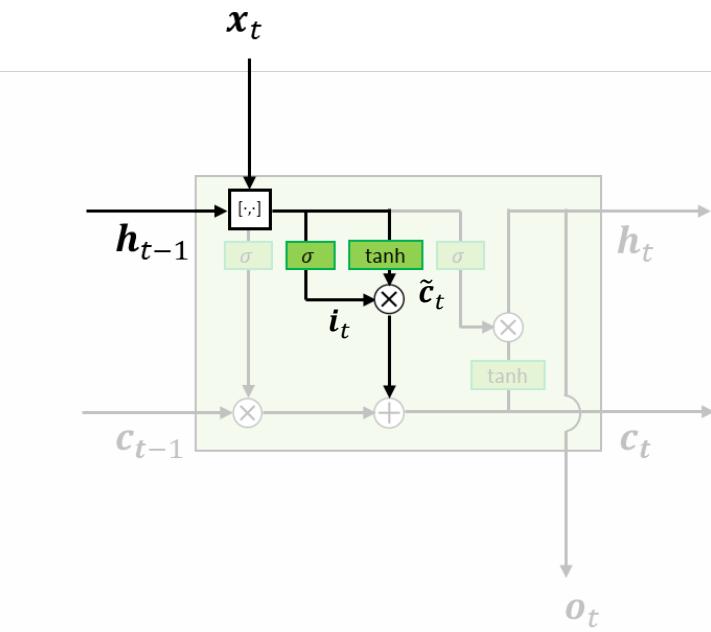
## Puerta olvido

*Elige mediante una capa qué información del pasado se borra*

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

# Redes recurrentes

- LSTM



## Puerta entrada

Elige mediante una capa qué información de la entrada se introduce al modelo

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

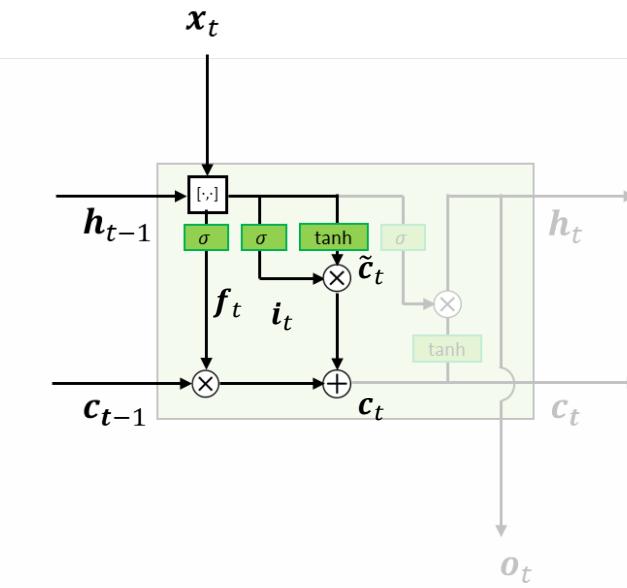
## Nuevo estado

Calcula la información que se introduce al modelo

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

# Redes recurrentes

- LSTM



## Estado

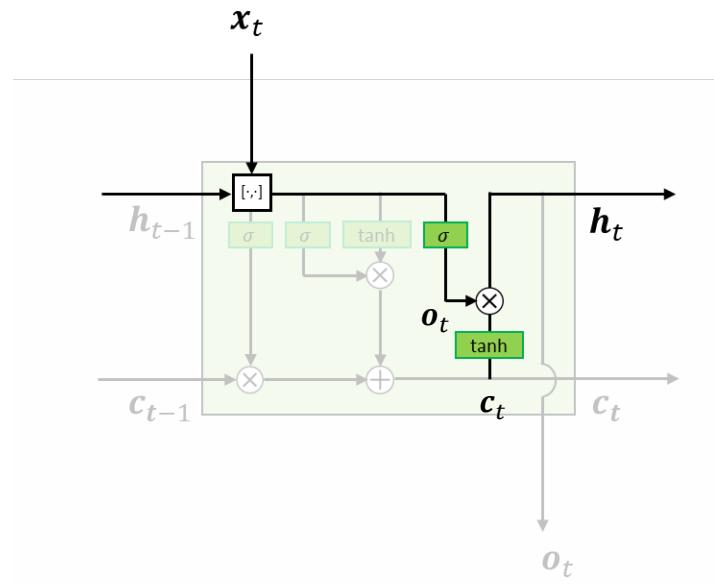
*El nuevo estado se calcula con la parte que se conserva del estado anterior y la información nueva*

$$c_t = f_t \circ c_{t-1} + i_t \circ \tilde{c}_t$$

◦, Hadamard product, elementwise

# Redes recurrentes

- LSTM



## Puerta de salida

*Elige qué información va a salir del modelo*

$$\mathbf{o}_t = \sigma(\mathbf{W}_o \cdot [\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o)$$

## Valores de salida

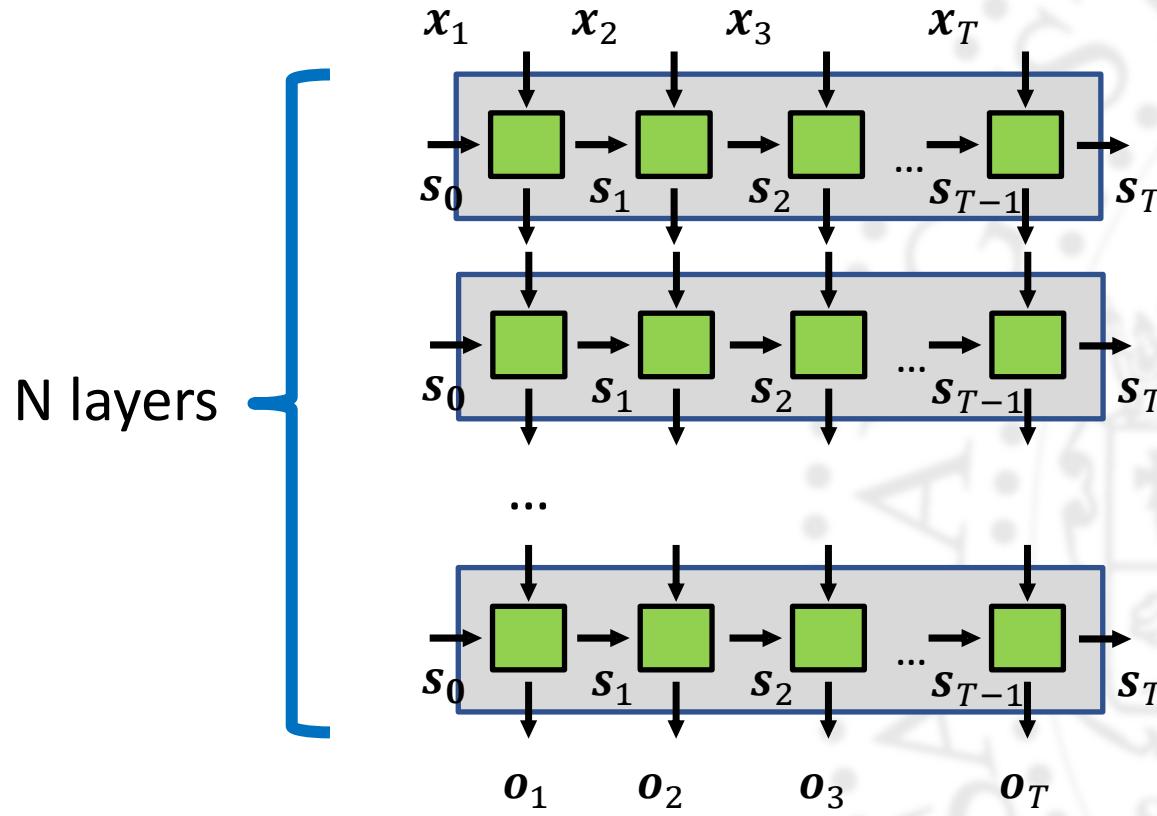
*Calcula las nuevas salidas*

$$\mathbf{h}_t = \mathbf{o}_t \circ \tanh(\mathbf{c}_t)$$

# Redes recurrentes

- **Redes multicapa**

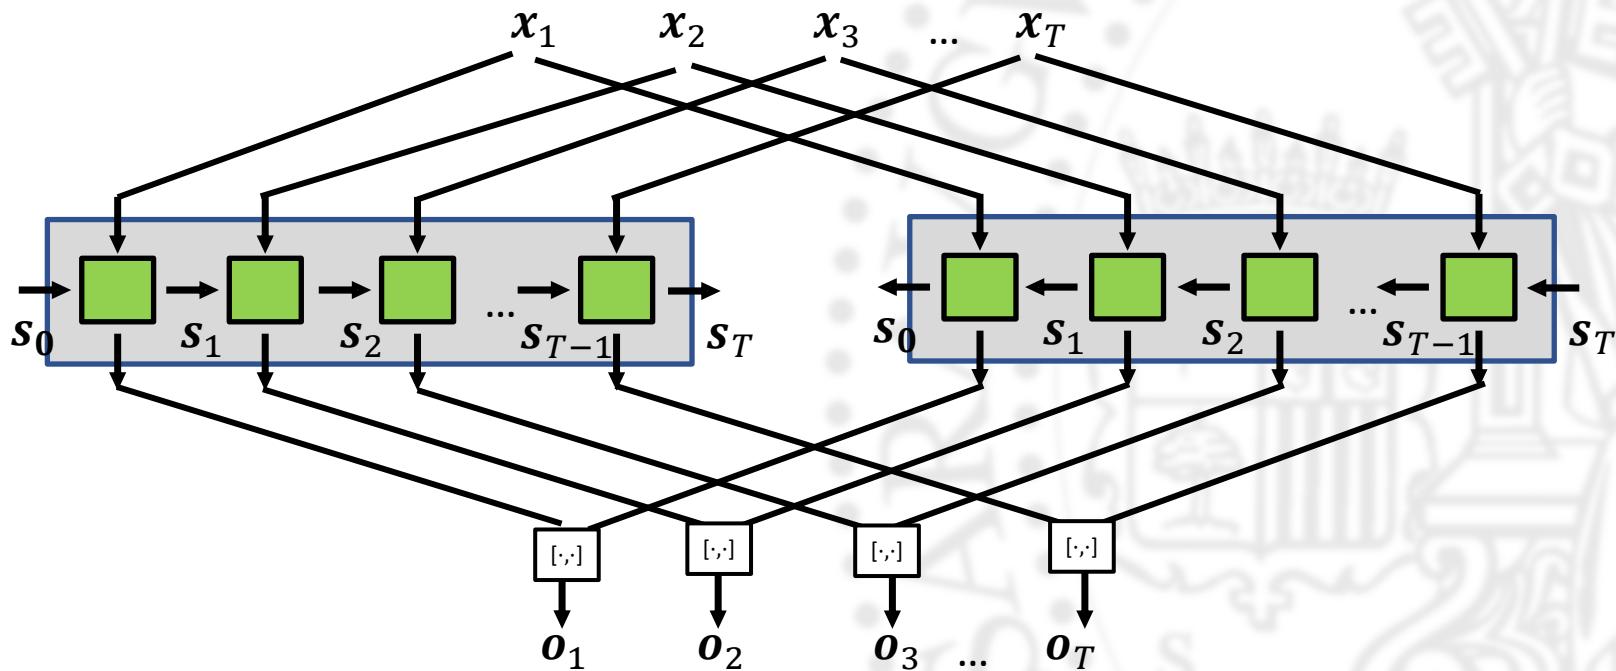
- pueden apilarse en múltiples capas, proporcionando una mayor abstracción



# Redes recurrentes

- **Redes bidireccionales**

- Cuando la secuencia se puede analizar sin la restricción del modelado causal
  - Dos redes operando una en orden directo y la otra en inverso
  - Después de la concatenación la dimensión es  $2D_h$  (hidden dimension)

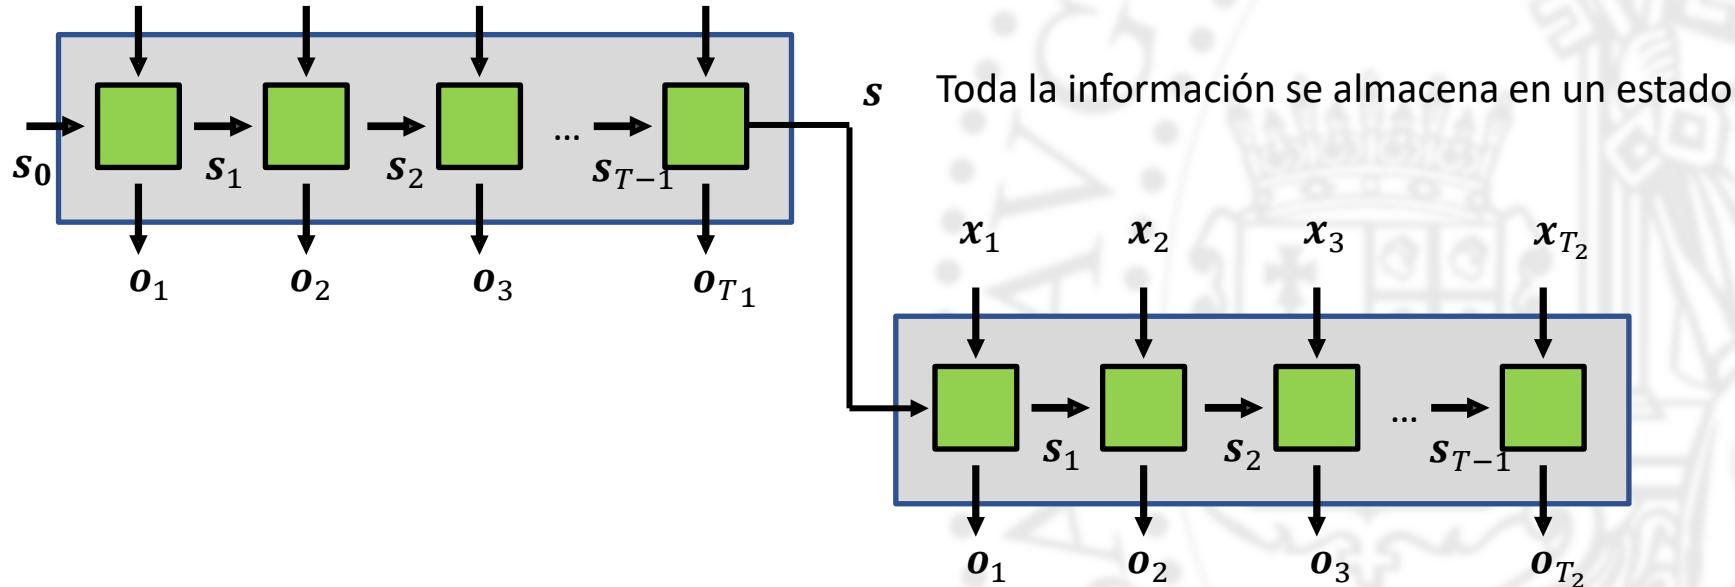


# Redes recurrentes

- **Redes seq2seq (Sutskever 2014)**

Sutskever, I., Vinyals, O. and Le, Q.V., 2014. Sequence to sequence learning with neural networks. *Advances in neural information processing systems*, 27.

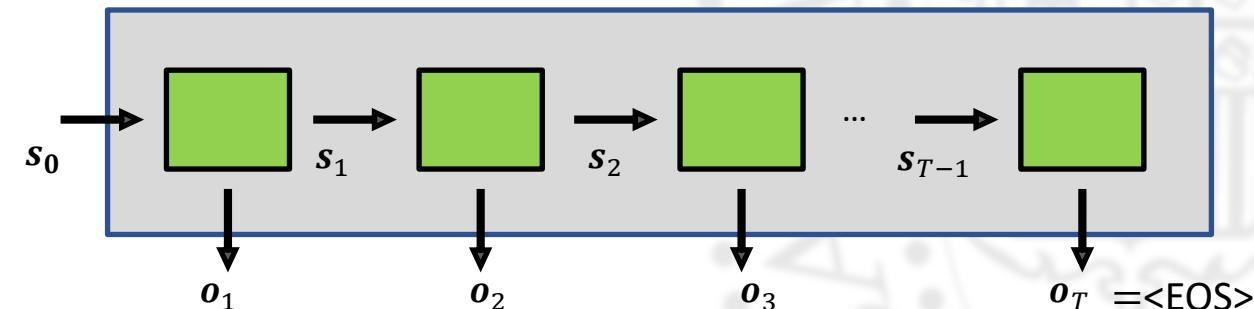
- Traduce una secuencia de entrada en una de salida
  - Primeros modelos competitivos en traducción automática de idiomas



# Redes recurrentes

- **Salida autorregresiva**

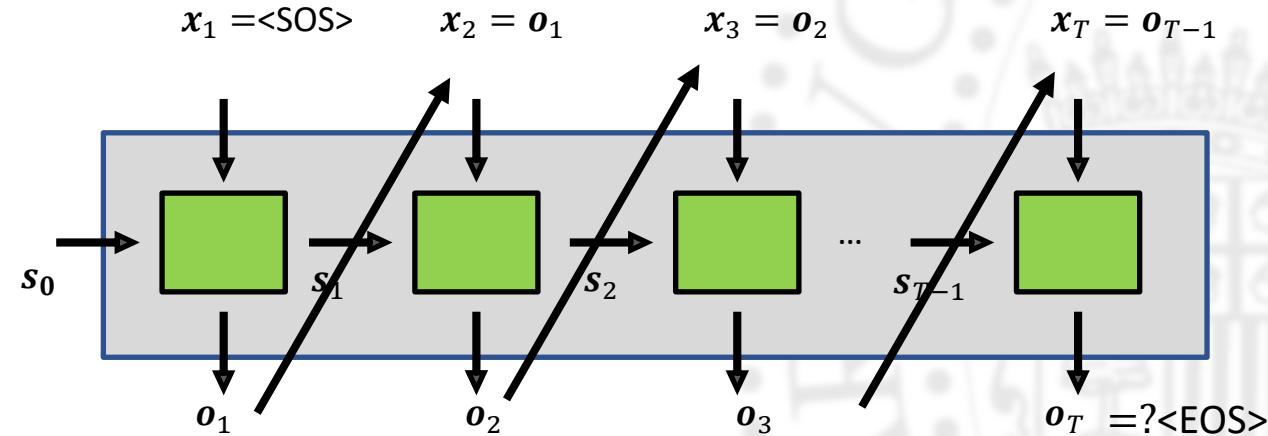
- Generación texto a partir de un estado, problemas:
  - Se puede degradar la calidad para secuencias largas
  - El estado que se va pasando de unas celdas a otras puede acumular errores
- Si intentamos generar solo a partir de el estado
  - el sistema apenas funciona en ejemplos triviales
  - ¿Qué podemos hacer?



# Redes recurrentes

- **Salida autorregresiva**

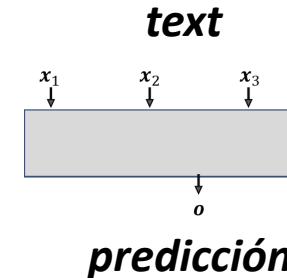
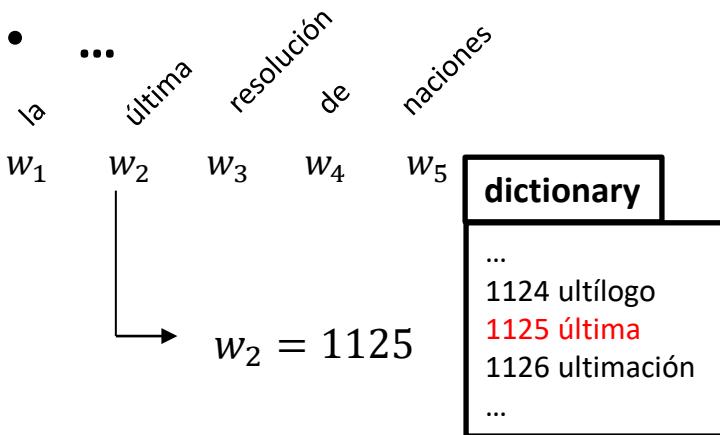
- Solución: cada celda recibe la salida de la celda previa como entrada
  - Para la primera entrada se usa el símbolo especial: <SOS> start of sequence
  - La red finaliza cuando se predice el símbolo <EOS> end of sequence



# Redes recurrentes

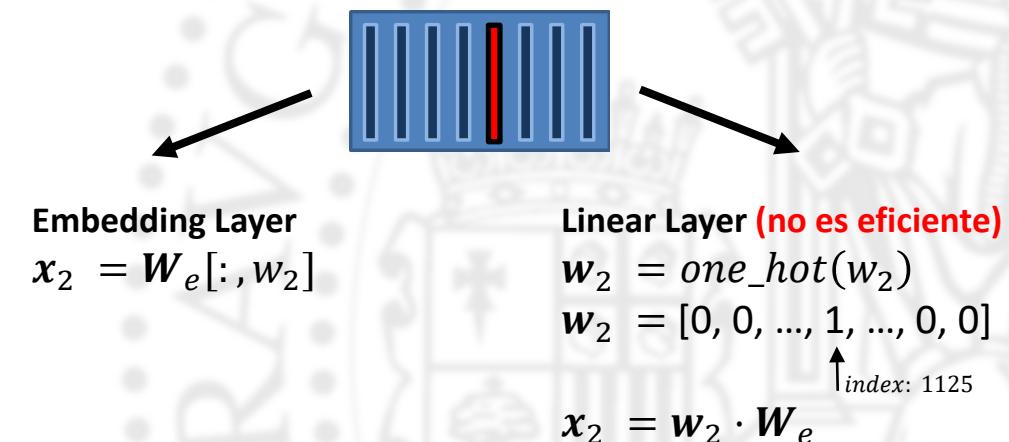
- Ejemplos:

- Clasificación de texto
- Clasificación de tema
- Reconocimiento de autor/fraude
- Clasificación de idioma



```
pytorch
import torch
layer = torch.nn.Embedding(nwords, dim)

keras
from tensorflow import keras
layer = keras.layers.Embedding(nwords, dim)
```



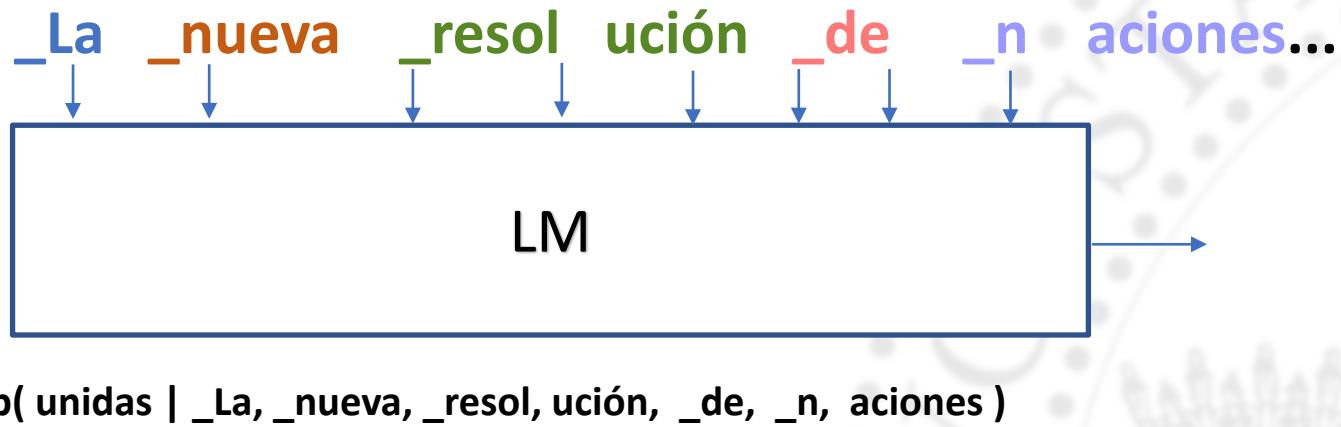
# Redes recurrentes

- **Modelo de lenguaje: objetivo**
  - predecir la siguiente palabra en una secuencia de palabras (un texto)



# Redes recurrentes

- **Modelo de lenguaje: partes de palabra (tokens)**

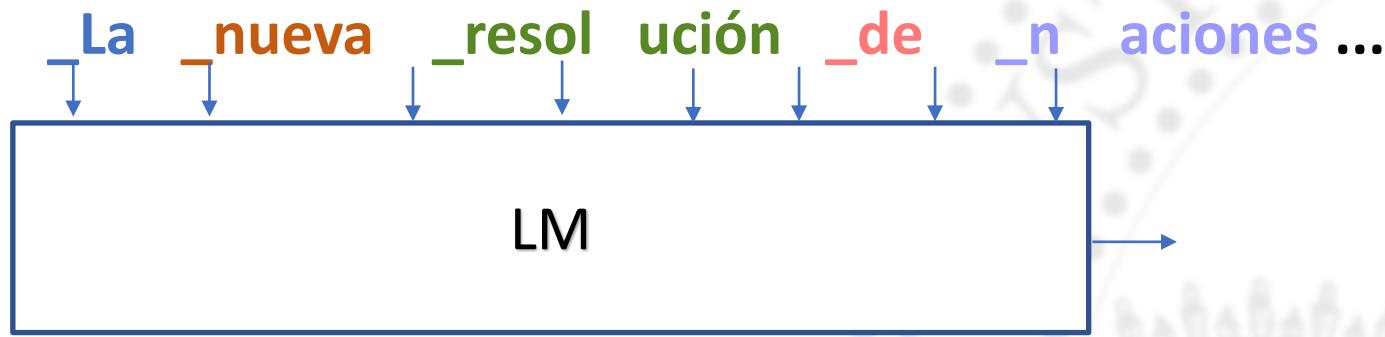


token	prob
<code>_un</code>	0.48
<code>_y</code>	0.04
<code>_en</code>	0.03
<code>_Un</code>	0.03
<code>_que</code>	0.02
,	0.02
...	

- Lo que obtendremos es una estimación de la probabilidad
- ¿Para qué queremos esas estimaciones?
- ¿No es suficiente con la más probable?

# Redes recurrentes

- **Modelo de lenguaje: generación**



- Generar secuencias (la salida de los LMs generativos)
- Controlar otros procesos: Reconocedor de automático del habla, traductores, etc.

<u>_un</u> (0.48) ->	<u>idas</u> (0.99)
<u>ific</u>	(0.00)
<u>ip</u>	(0.00)
<u>as</u>	(0.00)
<u>id</u>	(0.00)

<u>-y</u> (0.04) ->	<u>pue</u> (0.21)
<u>-g</u>	(0.07)
<u>-raz</u>	(0.04)
<u>nacional</u>	(0.04)
<u>-de</u>	(0.04)

<u>-en</u> (0.03) ->	<u>la</u> (0.13)
<u>-el</u>	(0.13)
<u>-conflic</u>	(0.05)
<u>-las</u>	(0.04)
<u>-Europa</u>	(0.03)

# Redes recurrentes

## • Representación de palabras

- Cada palabra del vocabulario se representa mediante un vector (32k por ejemplo en LLAMA)
- Pensemos en una versión simplificada donde cada palabra fuera descrita mediante una ficha de miles de preguntas (sparse vector)

palabra	rey	reina	gato	árbol	ráiz	gustará	odiaba
<hr/>							
propiedades							
persona	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>					
monarquía	<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>					
vegetal				<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		
animal			<input checked="" type="checkbox"/>				
masculino	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>			
femenino		<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>		<input checked="" type="checkbox"/>		
positivo					<input checked="" type="checkbox"/>		
negativo						<input checked="" type="checkbox"/>	
verbo					<input checked="" type="checkbox"/>	<input checked="" type="checkbox"/>	
presente							
pasado							
futuro					<input checked="" type="checkbox"/>		

Un cambio de significado puede ir asociado a cambiar uno de esos aspectos, **recuerdan más a un ideograma chino** que a una representación mediante un alfabeto fonético

木 → 本  
Árbol Raíz

# Redes recurrentes

- **Representación de palabras**

- Aún siendo una simplificación podemos intuir
- dos operaciones importantes en los modelos de lenguaje
- El mecanismo de comparación de palabras (semántico)
- dos palabras son parecidas si tienen muchas coincidencias (productor escalar)

**rey - hombre + mujer -> (está cerca de) reina**

- Podemos transformar una palabra para llegar a otra mediante manipulaciones algebraicas (aproximadamente claro):

tenis - raqueta + bate	-> béisbol
motocicleta - motor + pedales	-> bicicleta
amar - positivo + negativo	-> odiar
parís - francia + españa	-> madrid

- Otras analogías obtenidas (word2vec):

palabra	rey	reina	gato	árbol	ráiz	gustará	odiaba
<hr/>							
persona							
monarquía							
vegetal							
animal							
masculino	✓						
femenino		✓					
positivo						✓	
negativo							✓
verbo							✓
presente				✓			
pasado							✓
futuro							

# Redes recurrentes

- **LSTM**

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

- Limitación: cada celda tiene una dimensión finita para recibir información de los instantes previos y escribir nueva información para el futuro

2015 <http://karpathy.github.io/2015/05/21/rnn-effectiveness/>

- Red recurrente (LSTM) 3 capas dimensión 512, **5.8M**
- **4.4MB** texto Shakespeare

DUKE VINCENTIO: Well, your wit is in the care of side and that.

Second Lord: They would be ruled after this chamber, and my fair nues begun out of the fact, to be conveyed, Whose noble souls I'll have the heart of the wars.

Clown: Come, sir, I will make did behold your worship.

VIOLA: I'll drink it.

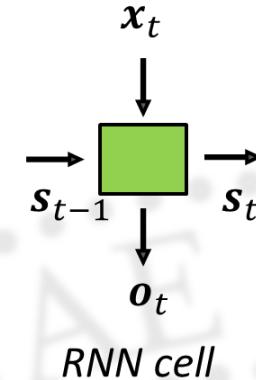
2016 <https://medium.com/deep-writing/harry-potter-written-by-artificial-intelligence-8a9431803da6>

- Primeros 4 libros

Ron didn't even upset her little ingredients on the toilet, and a group of third-year girls last year. Highly bushy and then burst away from them quickly.

"Thought you're all right?" he said.

Harry grinned at Harry. "Why should she be cheerful so while you gave detentions, Moody!"

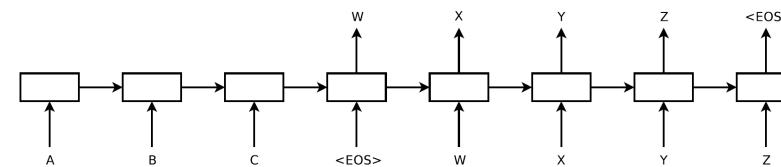


# Redes recurrentes

- **Translation (Sutskever, 2014)**

Sutskever, I., Vinyals, O., & Le, Q. V. (2014). Sequence to sequence learning with neural networks. In *Advances in neural information processing systems* (pp. 3104-3112).

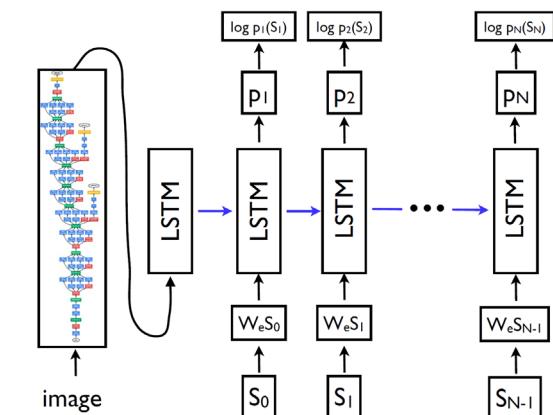
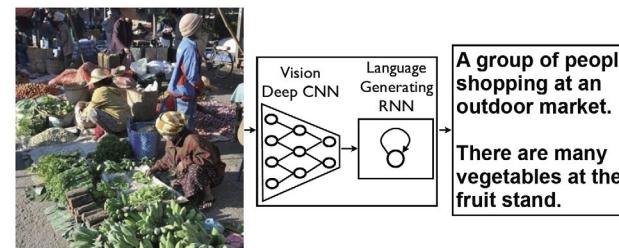
- Se utilizó en tarea de traducción: inglés a francés



- **Image captioning (Vinyals 2014)**

Vinyals, O., Toshev, A., Bengio, S., & Erhan, D. (2015). Show and tell: A neural image caption generator. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3156-3164).

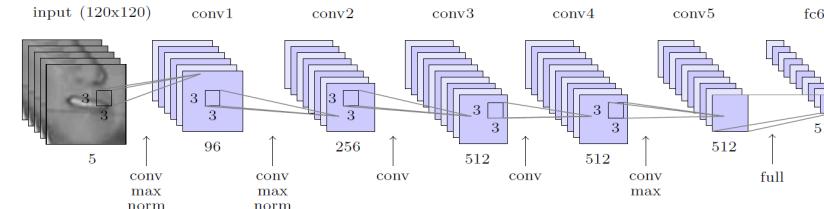
- Embedding de imagen
- Generación de texto



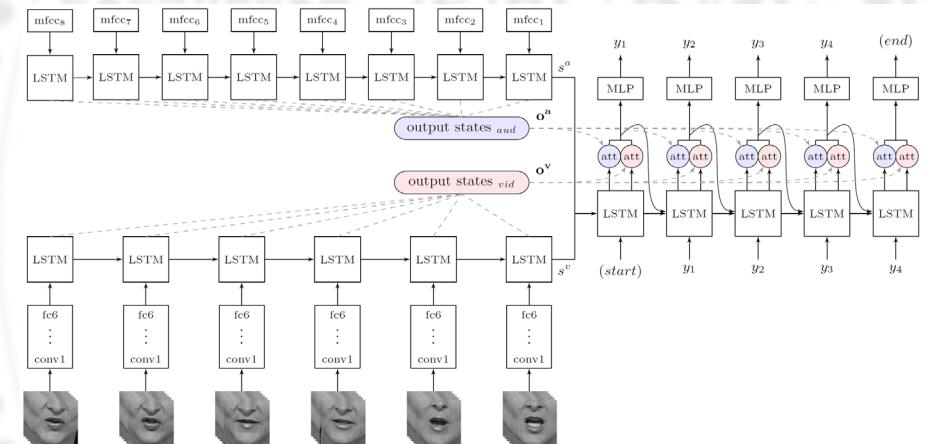
# Redes recurrentes

- Lip reading (Chung 2016) or Watch, Listen, Spell

Chung, J. S., Senior, A., Vinyals, O., & Zisserman, A. (2017, July). Lip reading sentences in the wild. In 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 3444-3453). IEEE.



- Parte visual procesado con CNN -> características
- La secuencia de embeddings de audio/video
  - se procesan mediante una LSTM cada una
- La salida se genera mediante una LSTM



# Redes recurrentes

- **Ejemplos**

<https://colab.research.google.com/drive/1BTRR4llqVmxA-kSGPbTfjVnTRBkl5cXn?usp=sharing>

[https://colab.research.google.com/drive/1S8N4jeMR49Q1e-SOtYa6mjsPe\\_yEOHIm?usp=sharing](https://colab.research.google.com/drive/1S8N4jeMR49Q1e-SOtYa6mjsPe_yEOHIm?usp=sharing)