



# APRENDIZAJE PROFUNDO

## El poder del aprendizaje automático unido al poder de cálculo de las computadoras actuales.

*Dra. María del Pilar Gómez Gil*  
*Coordinación de computación*  
*Instituto Nacional de Astrofísica, Óptica*  
*y Electrónica.*  
*pgomez@inaoep.mx*  
*@pgomezgil*

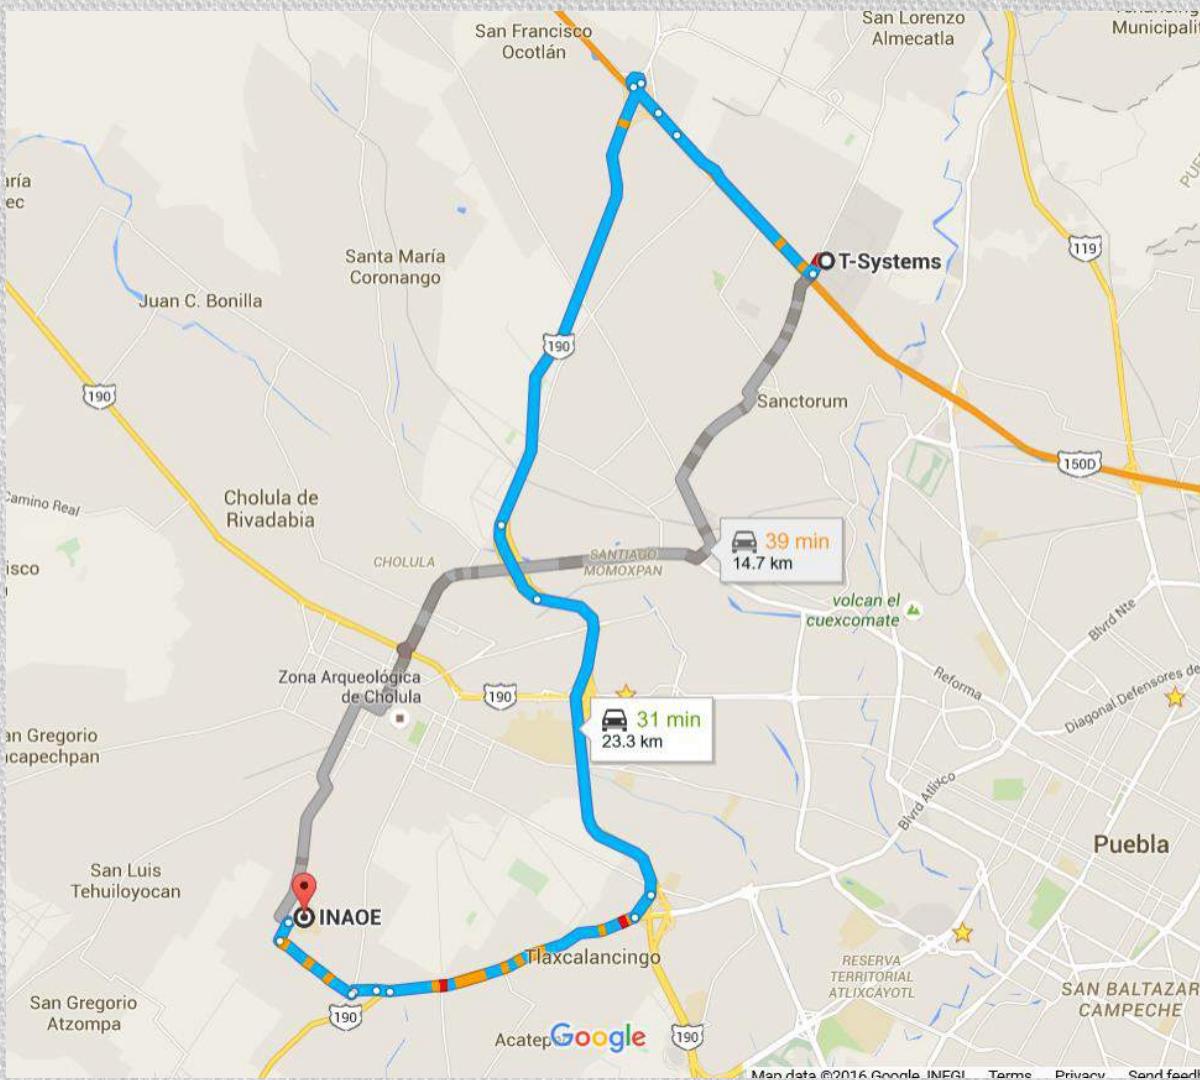
6 de Abril 2016

# Un poco sobre INAOE (1/2)



- Es un centro público de investigación localizado en Tonantzintla, Puebla México .
- Su **misión** es contribuir a la generación, avance y difusión del conocimiento, para el desarrollo del país y de la humanidad.
- Identifica y busca la solución de problemas científicos y tecnológicos
- Participa en la formación de especialistas en las áreas de Astrofísica, Óptica, Electrónica, **Ciencias Computacionales** y áreas afines.

# Un poco sobre INAOE (2/2)



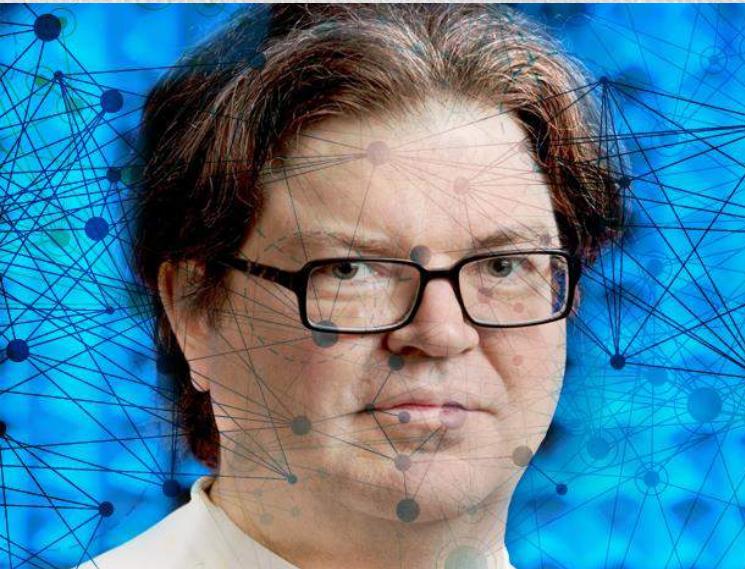
*Esta presentación está disponible en:*

[http://ccc.inaoep.mx/~pgomez/conferences  
/PggTSys16.pdf](http://ccc.inaoep.mx/~pgomez/conferences/PggTSys16.pdf)



“Most of the knowledge in the world in the future is going to be extracted by machines and will reside in machines”

Yann LeCun, Director of AI Research, Facebook<sup>1</sup>



Yan LeCun. Photo-illustration: Randi Klett

<sup>1</sup> “[The Five Tribes of Machine Learning \(And What You Can Learn from Each\)](#),” Pedro Domingos, Webminar produced by the Association of Computing Machinery (ACM). Dec. 29, 2015

# ¿Qué es aprendizaje profundo? (1/2)

- En el contexto de Inteligencia Artificial (IA), “aprendizaje profundo” (*Deep Learning* o **DL**) se refiere a la actividad **automática de adquisición de conocimiento**, a través del uso de máquinas que usan varios niveles para la extracción.
- El adjetivo “profundo” se aplica no en sí al conocimiento adquirido, sino a la forma en que el conocimiento se adquiere.

# ¿Qué es aprendizaje profundo? (2/2)

- La gran ventaja de DL es que no requiere de una definición “a mano” de las **características** que identifican a los patrones que se buscan, sino que automáticamente se generan dichas características, manipulando datos crudos
- Esto se lleva a cabo a través de construir automáticamente características de alto nivel, a través del uso de una gran cantidad de niveles jerárquicos de extractores, dentro de un sistema que **aprende automáticamente**.

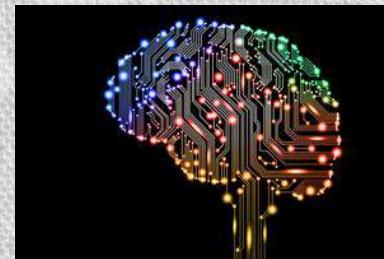


Foto tomada de:  
<http://www.kodemaker.no/deeplearning/>

# ¿Qué es aprendizaje automático?

- Los sistemas basados en IA se caracterizan porque contienen una **representación del conocimiento**, que les permite tomar decisiones de forma autónoma.
- Algunas técnicas de IA utilizan *representaciones simbólicas* del conocimiento, como los sistemas expertos basados en reglas. Sin embargo, estas técnicas aunque son exactas, no son fácilmente escalables.
- La **inteligencia computacional** (IC) permite trabajar con sistemas imprecisos y encontrar soluciones en tiempos razonables, aunque no exactas, a través de crear *representaciones numéricas* del conocimiento.
- En el aprendizaje automático, se adquiere el conocimiento a través de analizar datos y manipularlos, usando estrategias basadas en teorías matemáticas

# ¿Cómo descubren conocimiento las computadoras?

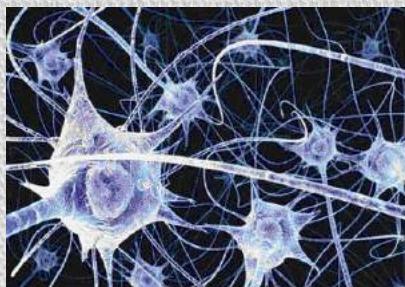
- Hay muchas estrategias, las mas populares lo hacen:
  - Llenando “huecos” en el conocimiento existente,
  - Construyendo máquinas que intentan emular al cerebro,
  - Simulando el proceso de evolución,
  - Reduciendo incertidumbre de forma sistemática,
  - Encontrando similitudes entre diferencias temporales.

“[The Five Tribes of Machine Learning \(And What You Can Learn from Each\)](#),”  
Pedro Domingos, Webminar produced by the Association of Computing  
Machinery (ACM). Dec. 29, 2015



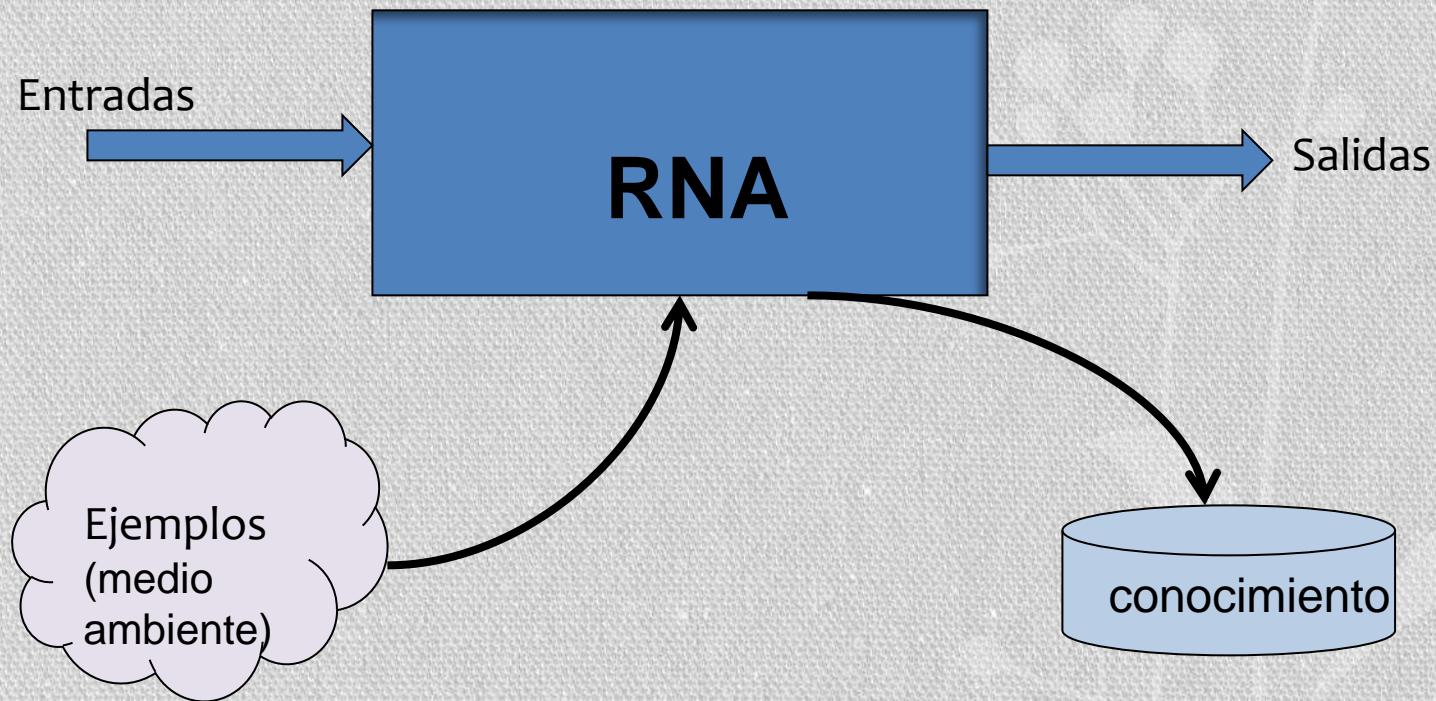
# Emulando al cerebro: Redes Neuronales Artificiales (RNA)

- Son **modelos matemáticos** capaces de adaptar su comportamiento en respuesta a ejemplos tomados del medio ambiente
- Están **inspiradas** en la construcción del cerebro y las neuronas biológicas.
- Sus componentes son procesadores simples que funcionan de forma **paralela y distribuida**
- Pueden **almacenar** y **utilizar** ese conocimiento adquirido de la experiencia

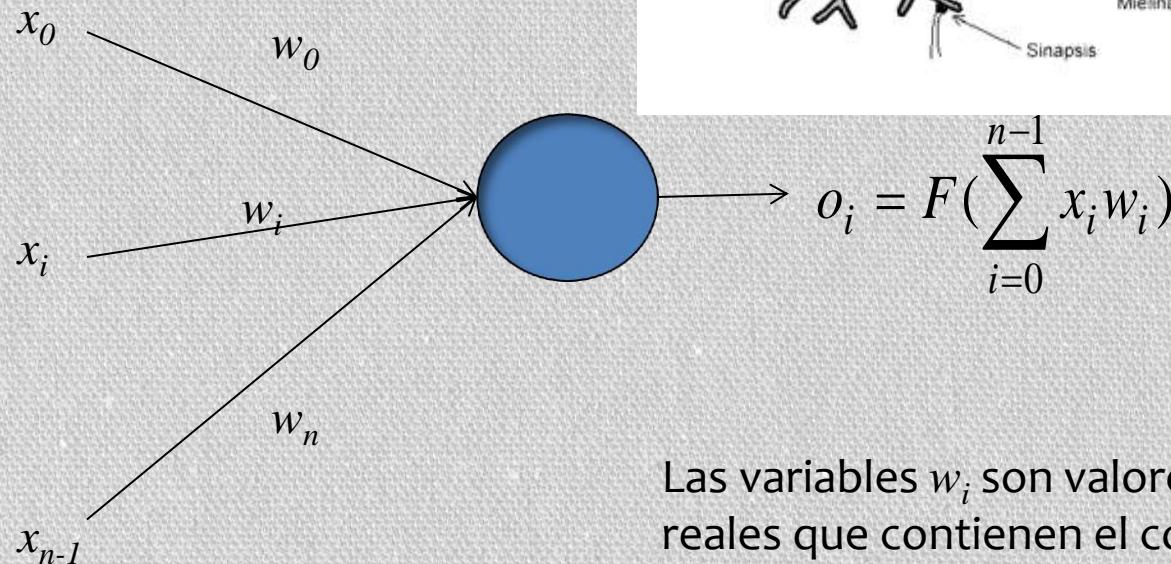


Haykin, S. (2009) Neural Networks and Learning Machines.  
Third Edition. Pearson Education: Upper Saddle River, New Jersey

# El Contexto de Redes Neuronales

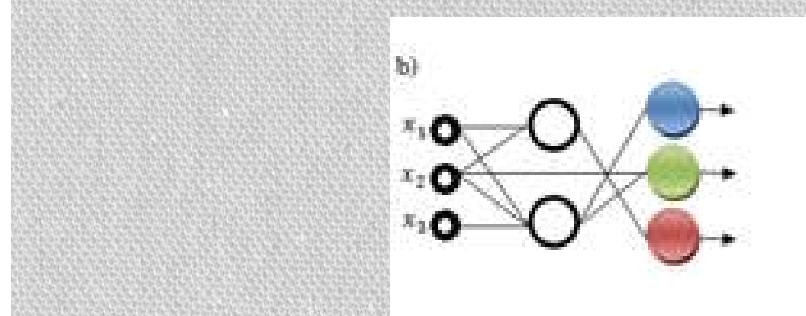
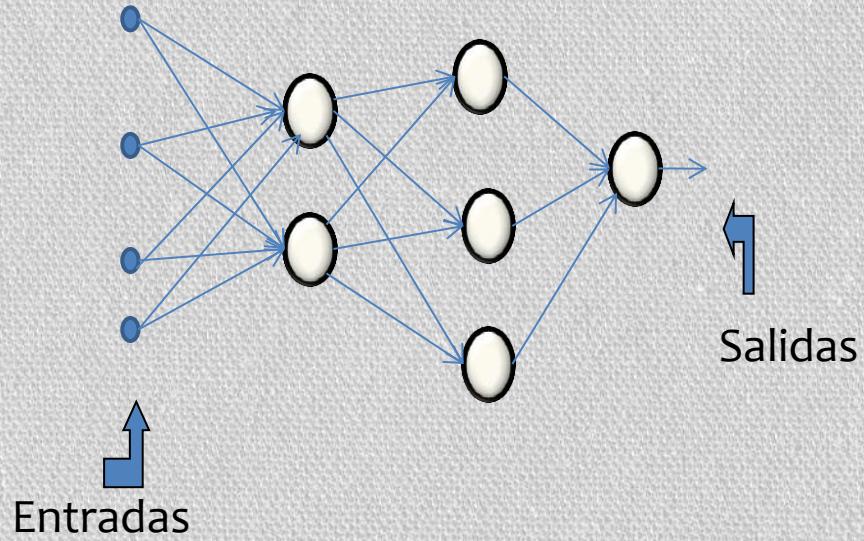
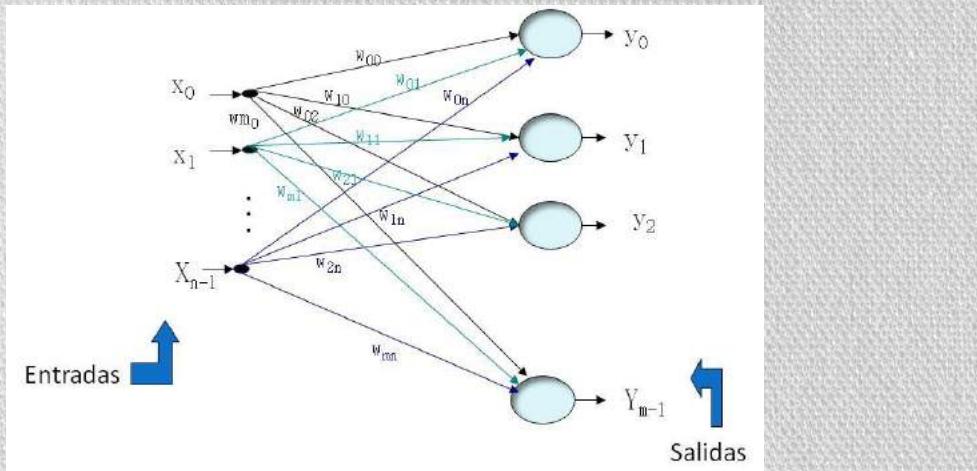


# El componente fundamental: neurona



Las variables  $w_i$  son valores reales que contienen el conocimiento de la red neuronal

# La conexión entre neuronas forma las RNA



# Su topología puede ser bastante sofisticada

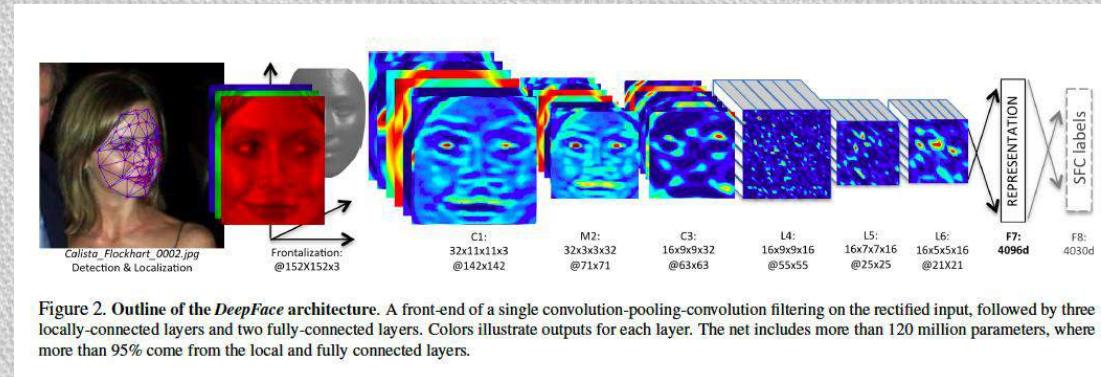
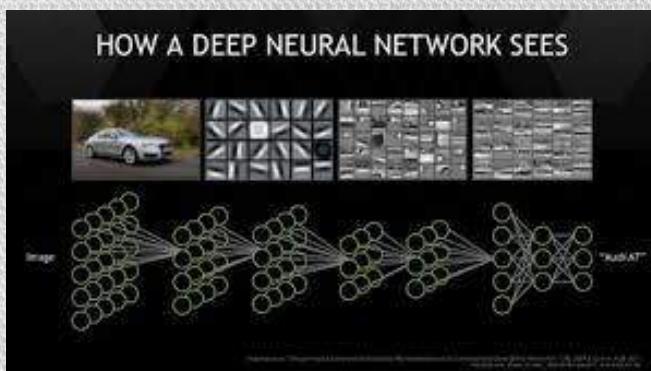
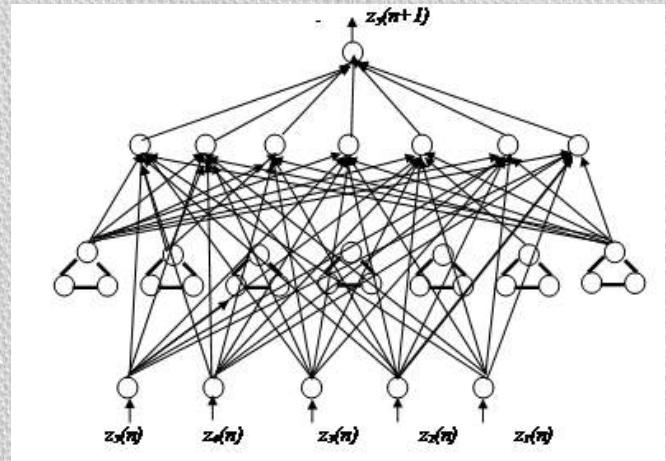
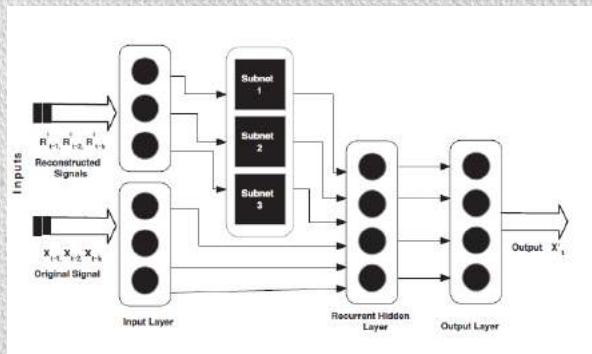


Figure 2. Outline of the *DeepFace* architecture. A front-end of a single convolution-pooling-convolution filtering on the rectified input, followed by three locally-connected layers and two fully-connected layers. Colors illustrate outputs for each layer. The net includes more than 120 million parameters, where more than 95% come from the local and fully connected layers.

# Matemáticas rigurosas solventan a las RNA

*Neural Networks*, Vol. 2, pp. 359–366, 1989  
Printed in the USA. All rights reserved.

## ORIGINAL CONTRIBUTION

*Lemma 2.1.* All of the following are equivalent.

- (a)  $\rho_\mu(f_n, f) \rightarrow 0$ .
- (b) For every  $\varepsilon > 0$   $\mu\{x: |f_n(x) - f(x)| > \varepsilon\} \rightarrow 0$ .
- (c)  $\int \min\{|f_n(x) - f(x)|, 1\} \mu(dx) \rightarrow 0$ .  $\square$

## Multilayer Feedforward Networks are Universal Approximators

KUR' HORNIK

Technische Universität Wien

MAXWELL STINCHCOMBE AND HALBER WHITE

University of California, San Diego

(Received 16 September 1988; revised and accepted 9 March 1989)

### Definition 2.4

For any measurable function  $G(\cdot)$  mapping  $R$  to  $R$  and  $r \in N$ , let  $\Sigma\Pi'(G)$  be the class of functions

$$\{f: R' \rightarrow R: f(x) =$$

$$\sum_{j=1}^q \beta_j \cdot \prod_{k=1}^{l_j} G(A_{jk}(x)), x \in R', \beta_j \in R, A_{jk} \in A', l_j \in N,$$

$$q =$$

**Abstract**—This paper rigorously establishes that standard multilayer feedforward networks with one hidden layer using arbitrary squashing functions are capable of approximating any Borel measurable function from one finite dimensional space to another to any desired degree of accuracy, provided sufficiently many hidden units are available. In this sense, multilayer feedforward networks are a class of universal approximators.

**Keywords**—Feedforward networks, Universal approximation, Mapping networks, Network representation capability, Stone-Weierstrass Theorem, Squashing functions, Sigma-Pi networks, Back-propagation networks.



# El famoso algoritmo de Retropropagación

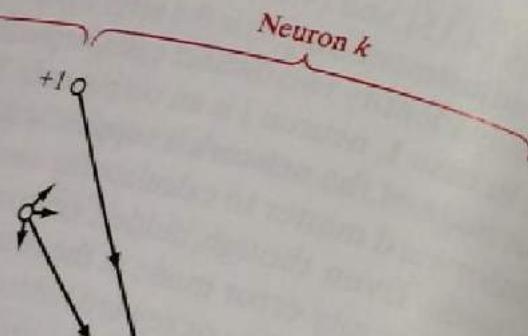
Section 4.4 The Back-Propagation A  
where in the second line we have used Eq. (4.11). To calculate the partial derivative  $\frac{\partial \mathcal{E}(n)}{\partial y_j(n)}$ , we may proceed as follows: From Fig. 4.4, we see that

$$\mathcal{E}(n) = \sum_{k \in C} e_k^2(n), \quad \text{neuron } k \text{ is an output node}$$

is Eq. (4.4) with index  $k$  used in place of index  $j$ . We have made this substitution to avoid confusion with the use of index  $j$  that refers to a hidden neuron. Differentiating Eq. (4.18) with respect to the function signal  $y_j(n)$ , we get

$$\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)}$$

Neuron  $k$



Next we use the chain rule for the partial derivative  $\frac{\partial e_k(n)}{\partial y_j(n)}$  and re-express it in the equivalent form

$$\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)}$$

However, from Fig. 4.4, we note that

$$\begin{aligned} e_k(n) &= d_k(n) - y_k(n) \\ &= d_k(n) - \varphi_k(v_k(n)), \end{aligned}$$

Hence,

neuron  $k$  is an output node

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n))$$

$$v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n)$$

where  $m$  is the total number of inputs (excluding the bias). Again, the synaptic weight  $w_{k0}(n)$  is equal to the bias  $+1$ . Correspondingly, the corresponding input is fixed at the value  $+1$ . This yields

We also note from Fig. 4.4 that for neuron  $k$ , the induced local field is

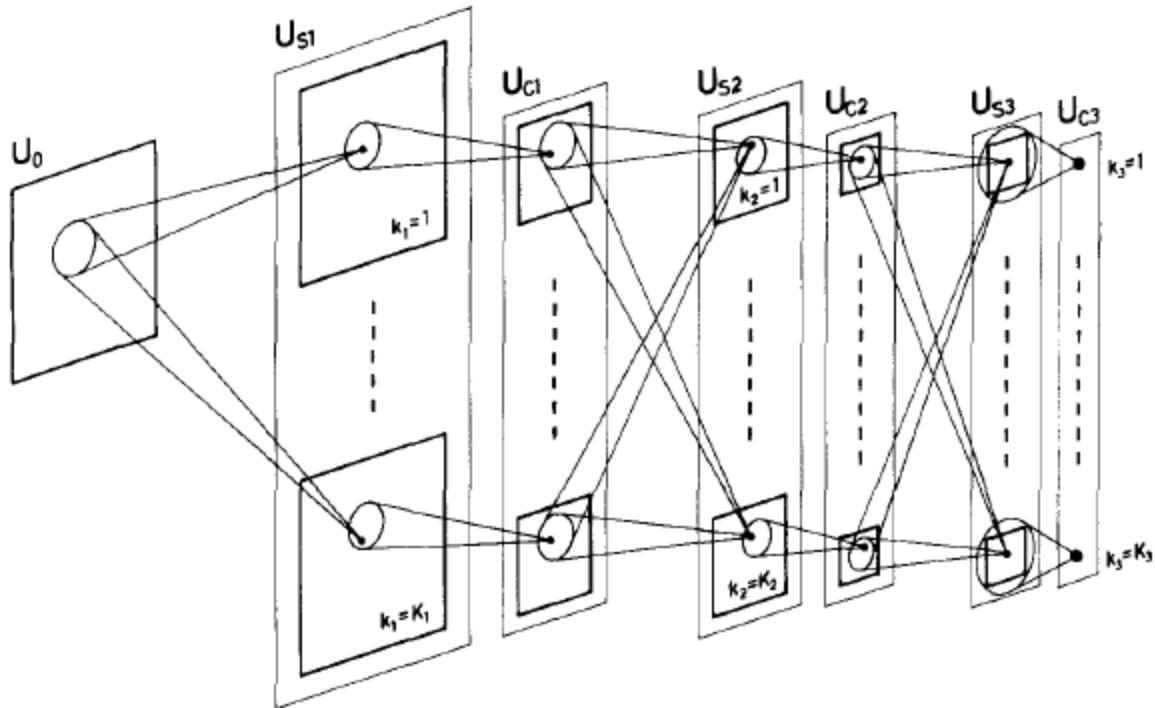
Haykin, S. S. (2009). Neural networks and learning machines (Vol. 3). Upper Saddle River: Pearson Education.

# El problema de clasificar



(Tao & Gonzalez ,1974)

# El neocognitron de Fukushima (1980)



**Fig. 2.** Schematic diagram illustrating the interconnections between layers in the neocognitron

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

# Extrayendo características en 1989

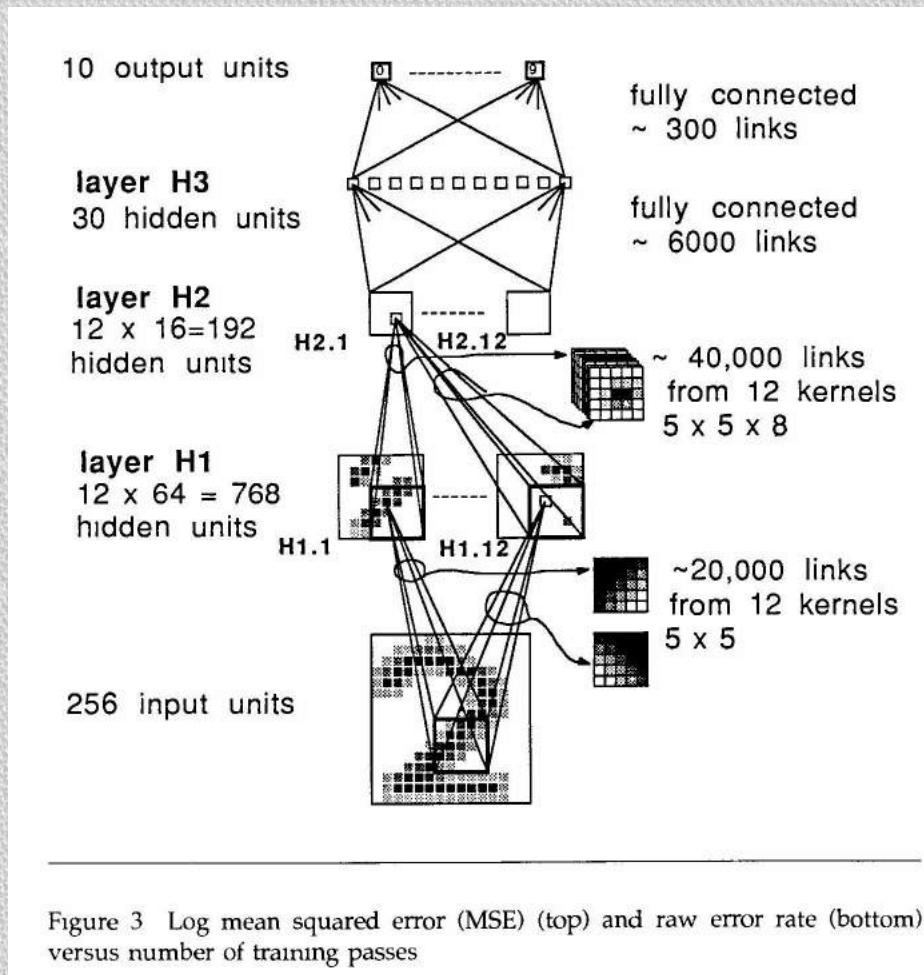


Figure 3 Log mean squared error (MSE) (top) and raw error rate (bottom) versus number of training passes

LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W., & Jackel, L. D. (1989). [propagation applied to handwritten zip code recognition](#). *Neural Computation*, 1(4), 541-551.

# Extrayendo características actualmente

Samoyed (16); Papillon (5.7); Pomeranian (2.7); Arctic fox (1.0); Eskimo dog (0.6); white wolf (0.4); Siberian husky (0.4)

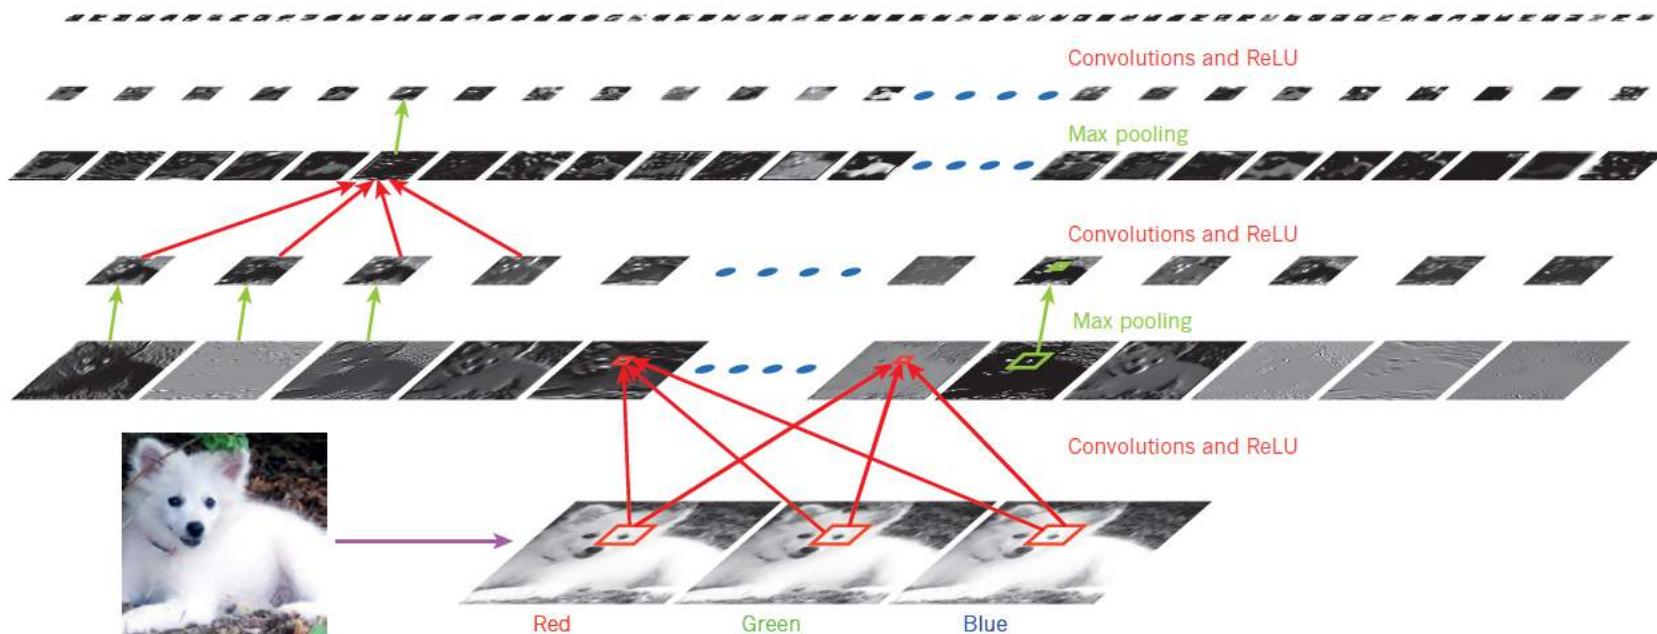


Figure 2 | Inside a convolutional network. The outputs (not the filters) of each layer (horizontally) of a typical convolutional network architecture applied to the image of a Samoyed dog (bottom left; and RGB (red, green, blue) inputs, bottom right). Each rectangular image is a feature map

corresponding to the output for one of the learned features, detected at each of the image positions. Information flows bottom up, with lower-level features acting as oriented edge detectors, and a score is computed for each image class in output. ReLU, rectified linear unit.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). [Deep learning](#). *Nature*, 521(7553), 436-444.

# RNA y DL

- DL permite que redes neuronales con varios niveles de neuronas aprendan a representar características, sin decirle cuales son.
- A este campo se le conoce como “**aprendizaje de representaciones**” (*representational learning*)
- Utilizan combinaciones de aprendizaje supervisado y no supervisado, en los diferentes niveles.
- Las arquitecturas mas comunes son:
  - Red profunda de convolución (convolutional Net)
  - Red de creencias profundas (deep-belief network)
  - Redes recurrentes de memoria corta y larga (*long-short term memory*, LSTM)

# Principales aplicaciones de DL

- Reconocimiento de voz
- Reconocimiento de imágenes
- Detección de fraudes
- Reconocimiento de caracteres manuscritos
- Descubrimiento de componentes farmacéuticos
- Procesamiento de lenguaje Natural

LeCun, Y., Bengio, Y., & Hinton, G. (2015). [Deep learning](#). *Nature*, 521(7553), 436-444.



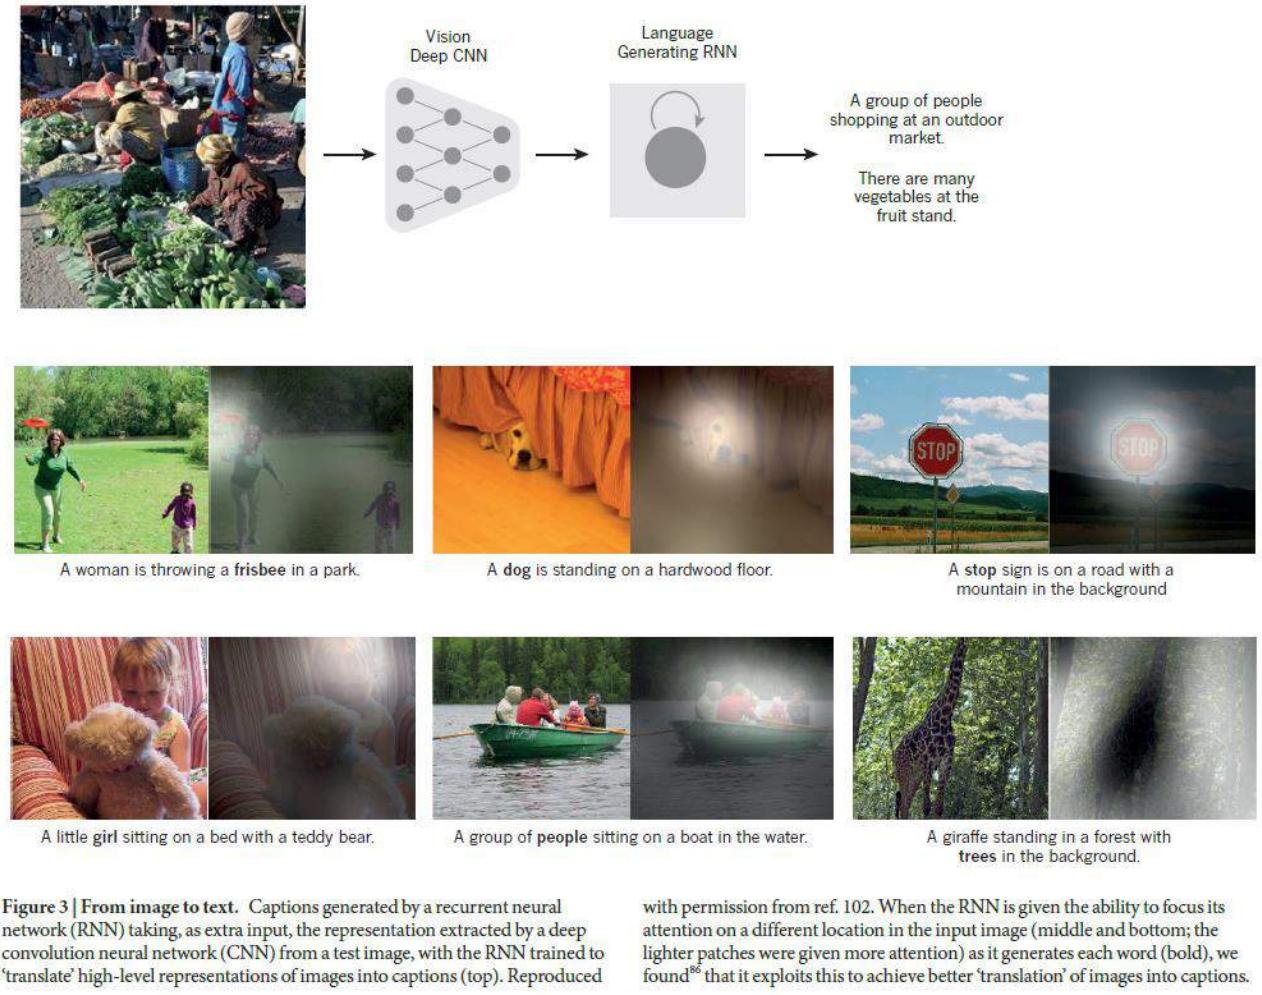
# Procesando datos con el neocognitron (1980)



**FIGURE 12. Experiment of handwritten numeral recognition on a minicomputer.**

Fukushima, K. (1988). [Neocognitron: A hierarchical neural network capable of visual pattern recognition](#). *Neural networks*, 1(2), 119-130.

# Procesando datos con la red de convolución (2015)



LeCun, Y., Bengio, Y., & Hinton, G. (2015). [Deep learning](#). *Nature*, 521(7553), 436-444.

# El poder del cómputo actual es la diferencia



IBM'S Watson

<http://www.wired.com/2012/03/ibm-watson/>



IBM Ble Gene / Q systems powering the Fermi supercomputer at Cineca in Italy.



K SUPERCOMPUTER, RIKEN Advanced Institute for Computational Science (AICS), Japan

[http://www.datacenterknowledge.com/  
top-10-supercomputers-illustrated-june-2012-continued/](http://www.datacenterknowledge.com/top-10-supercomputers-illustrated-june-2012-continued/)

# Laboratorio Nacional de Supercómputo del sureste de México



<http://www.lns.buap.mx/>

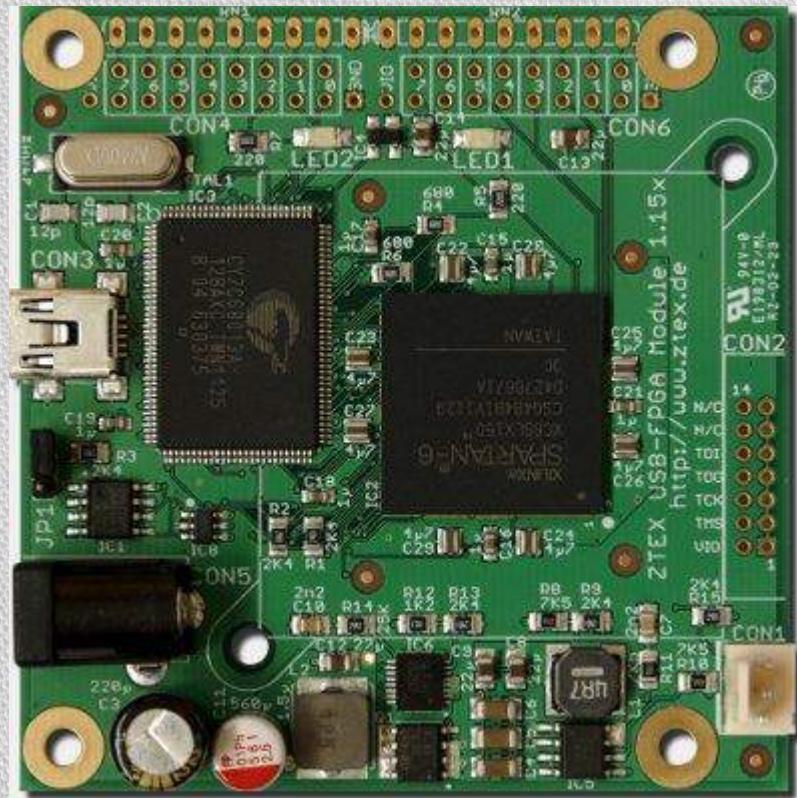


<http://www.conacytprensa.mx/index.php/tecnologia/tic/2723-lns-del-sureste-de-mexico-un-centro-de-datos-de-clase-mundial>

# Se pueden usar aplicaciones de DL con equipo de alto desempeño mas pequeño



<http://www.geforce.com/whats-new/articles/introducing-the-geforce-gtx-680m-mobile-gpu>



Spartan 6 LX150 FPGA Board

<http://www.ztex.de/usb-fpga-1/usb-fpga-1.15x.e.html>

# Aplicación exitosa a la fecha: Verificación de Caras (1/2)

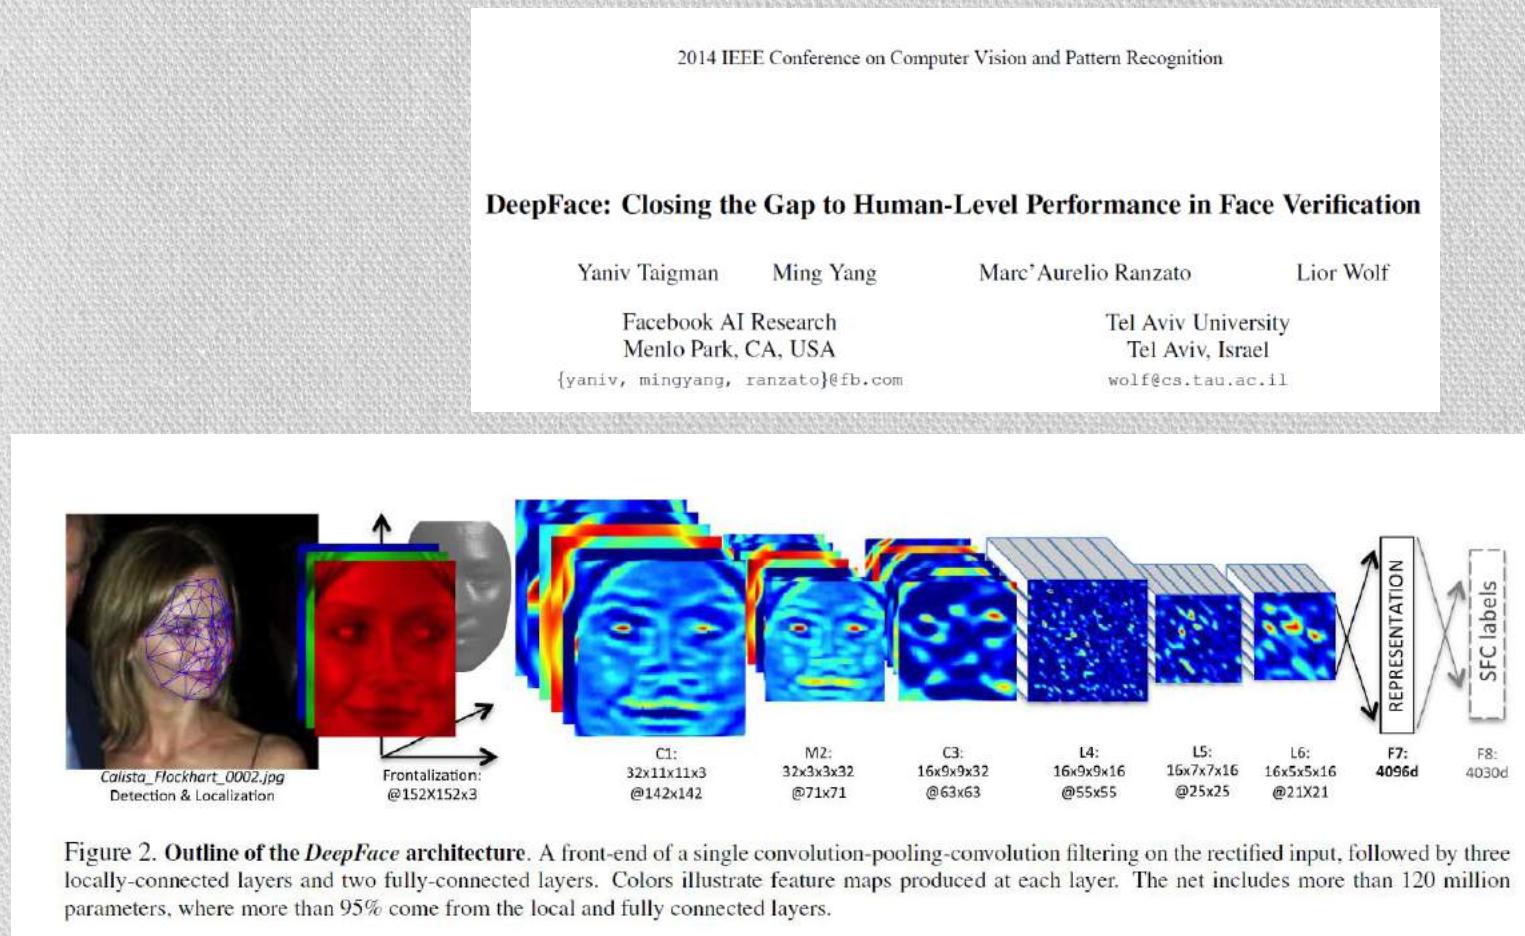


Figure 2. Outline of the DeepFace architecture. A front-end of a single convolution-pooling-convolution filtering on the rectified input, followed by three locally-connected layers and two fully-connected layers. Colors illustrate feature maps produced at each layer. The net includes more than 120 million parameters, where more than 95% come from the local and fully connected layers.

Y. Taigman, M. Yang, M. Ranzato and L. Wolf, “[DeepFace: Closing the Gap to Human-Level Performance in Face Verification](#),” Computer Vision and Pattern Recognition (CVPR), 2014 IEEE Conference on, Columbus, OH, 2014, pp. 1701-1708.

# Aplicación exitosa a la fecha: Verificación de Caras (2/2)

Method	Accuracy (%)	AUC	EER
MBGS+SVM- [31]	$78.9 \pm 1.9$	86.9	21.2
APEM+FUSION [22]	$79.1 \pm 1.5$	86.6	21.4
STFRD+PMML [9]	$79.5 \pm 2.5$	88.6	19.9
VSOF+OSS [23]	$79.7 \pm 1.8$	89.4	20.0
DeepFace-single	<b>91.4 ±1.1</b>	96.3	8.6

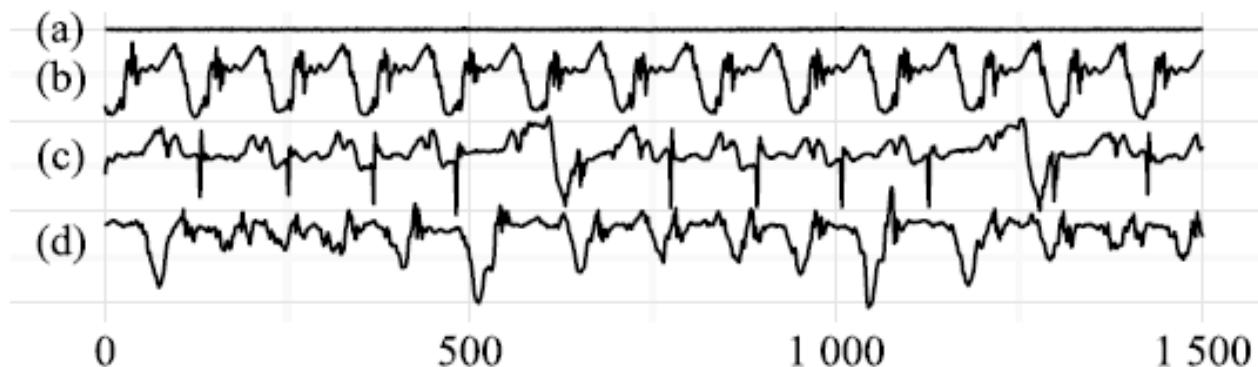


Table 4. Comparison with the state-of-the-art on the *YTF* dataset.

<http://dx.doi.org/10.1109/CVPR.2014.220>

Y. Taigman, M. Yang, M. Ranzato and L. Wolf, “[DeepFace: Closing the Gap to Human-Level Performance in Face Verification](#),” Computer Vision and Pattern Recognition (CVPR), 2014 IEEE Conference on, Columbus, OH, 2014, pp. 1701-1708.

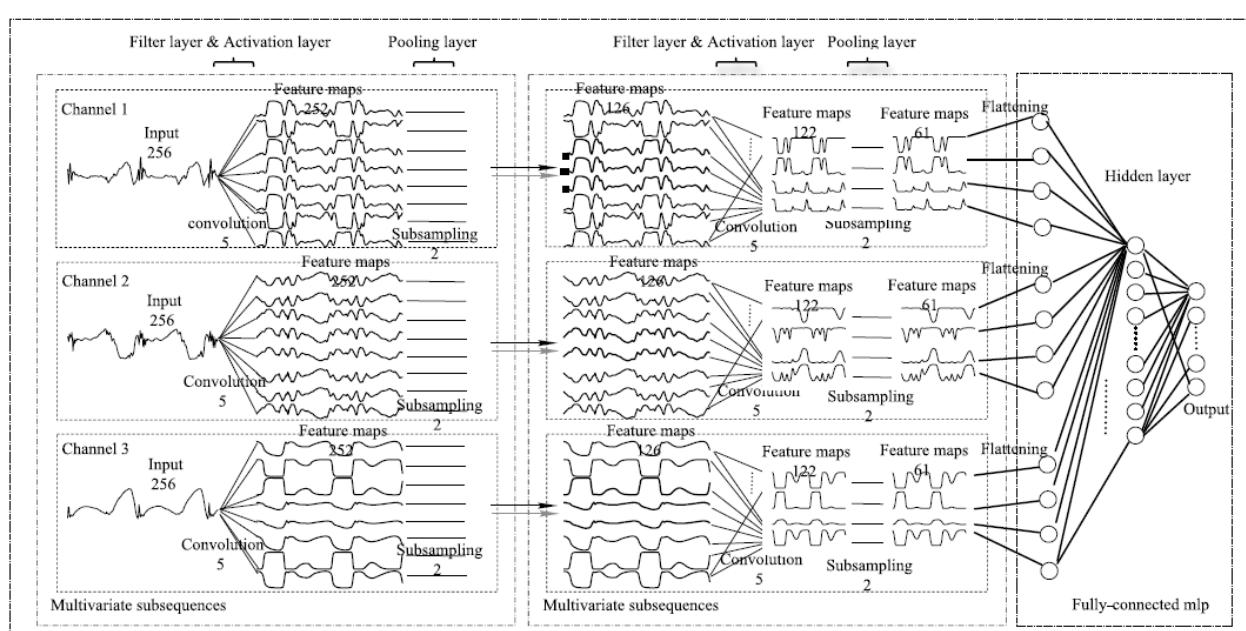
# Otras aplicaciones del aprendizaje de representaciones: claseficación de series de tiempo (1/2)



**Fig. 2** Four 1D samples of 3D weakly labeled physical activities: (a) “standing”; (b) “walking”; (c) “ascending stairs”; (d) “descending stairs”

Zheng, Y., Liu, Q., Chen, E., Ge, Y., & Zhao, J. L. (2016). Exploiting multi-channels deep convolutional neural networks for multivariate time series classification. *Frontiers of Computer Science*, 10(1), 96-112.

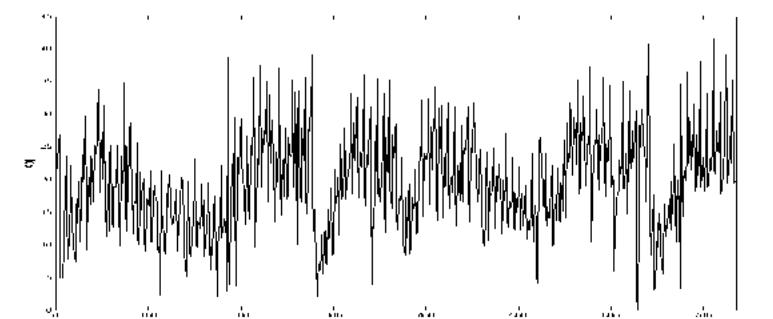
# Otras aplicaciones del aprendizaje de representaciones: clasificación de series de tiempo (1/2)



**Fig. 3** A two-stage MC-DCNN architecture for activity classification. This architecture consists of three channels input, two filter layers, two pooling layers and two fully-connected layers. Pretraining is performed for two stages gradually and then supervised learning is applied. This architecture is denoted as  $\mathcal{S}(5)-2-4(5)-2-732-4$  based on the template  $C1(\text{Size})-S1-C2(\text{Size})-S2-H-O$ , where  $C1$  and  $C2$  are numbers of filters in the first and second stage,  $\text{Size}$  denotes the kernel size,  $S1$  and  $S2$  are subsampling factors,  $H$  and  $O$  denote the numbers of units in hidden and output layers of MLP

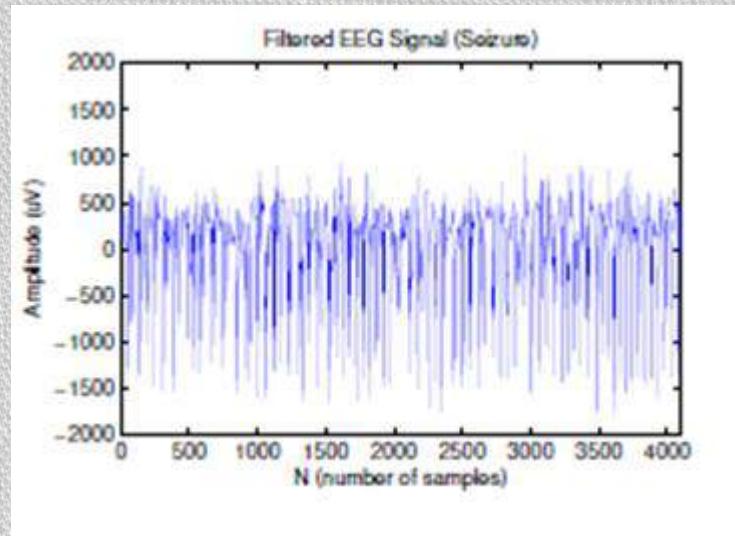
Zheng, Y., Liu, Q., Chen, E., Ge, Y., & Zhao, J. L. (2016). Exploiting multi-channels deep convolutional neural networks for multivariate time series classification. *Frontiers of Computer Science*, 10(1), 96-112.

# Ejemplos de señales complejas



Retiros de Cajeros automáticos. Fragmento  
De la Serie 1 de Competencia Internacional  
NN5-001

S. F. Crone, “NN5 forecasting competition for artificial neural networks & computational intelligence,” 2008, available in <http://www.neural-forecasting-competition.com/NN5/index.htm>



Estado Ictal en un paciente con epilepsia

Juarez-Guerra E, Alarcon-Aquino V and Gomez-Gil P. “[Epilepsy Seizure Detection in EEG Signals Using Wavelet Transforms and Neural Networks](#).” New Trends in Networking, Computing, E-learning, Systems Sciences, and Engineering. Lecture Notes in Electrical Engineering. Eds: K. Elleithy, T. Sobh. Vol 312, 2015, pp 261-269.

# Algunas Desventajas de DL

- En la mayoría de los casos se requieren grandes cantidades de datos
- Los algoritmos de aprendizaje aún necesitan mejorarse
- La migración/adecuación para programar aplicaciones en paralelo puede ser tediosa
- El porcentaje de éxito obtenido aún es bajo para poder usarse en muchas aplicaciones prácticas, pero va mejorando
- Puede ser que se identifiquen patrones que no son útiles

# Los sistemas encuentran lo que aprendieron antes - Google Deep Dream

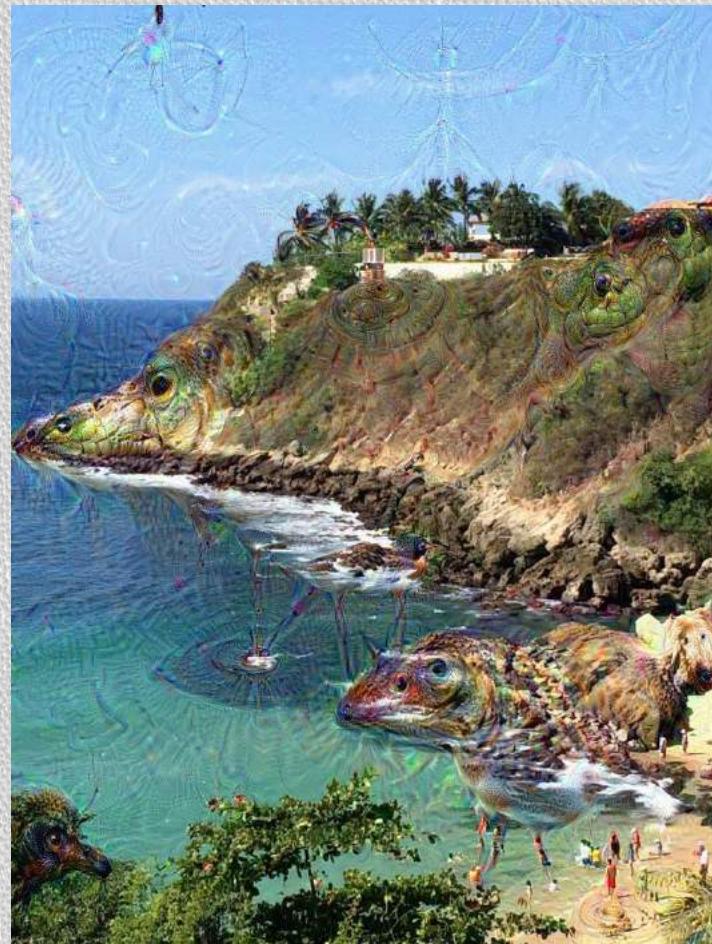


Imagen generada usando  
<http://deepdreamgenerator.com/>

# Una playa de puerto escondido procesada con Deep Dream



Imagen generada usando  
<http://deepdreamgenerator.com/>

# Consideraciones finales

- DL y *big-data* van de la mano
- Esta tecnología aún no está madura, pero está teniendo avances muy rápidos, y pronto se verá reflejada en otras aplicaciones
- El futuro de DL, según Yan LeCun<sup>1</sup> gira alrededor de:
  - Aprendizaje no supervisado
  - Redes Neuronales Recurrentes
  - Entendimiento de Lenguaje Natural
  - Combinación de aprendizaje de representaciones con razonamiento complejo

1. LeCun, Y., Bengio, Y., & Hinton, G. (2015). [Deep learning](#). *Nature*, 521(7553), 436-444.

# Muchas gracias por su atención!



Imagen tomada de: <https://www.tumblr.com/search/deep dream art>

Esta presentación está disponible en:

<http://ccc.inaoep.mx/~pgomez/conferences/PggTSys16.pdf>