

Facultad de
Ciencias



Conocimiento y emulación de redes neuronales

Alberto Prieto

Profesor Emérito, pero sin sueldo por ahora porque la UGR
no se lo puede permitir a pesar de lo que hago.




20 enero 2017

CITIC-UGR
CENTRO DE INVESTIGACIÓN EN TECNOLOGÍAS
DE LA INFORMACIÓN Y LAS COMUNICACIONES

Contenido

- **Objetivos de la investigaciones en redes neuronales.**
- **Aprendizaje**
- **Modelos, estructuras y algoritmos**
- **Simuladores**
- **Plataformas y hardware especializado**
- **Dominios de uso y aplicaciones del mundo real.**
- **Neurobótica**
- **Retos y conclusiones**





OBJETIVOS DE LA INVESTIGACIONES EN REDES NEURONALES

UGR_ATC_CITIC

A. Prieto



En esta presentación:



- Consideramos el cerebro como un sistema de procesamiento de la información
- Nos centramos en las investigaciones cuyo **fundamento** reside en la obtención de modelos computacionales (matemáticos o físicos) de redes neuronales a distinta escala.

UGR_ATC_CITIC

A. Prieto



Los modelos computacionales de redes neuronales más próximos a la biología (“bio-inspirados” o “bio-miméticos”) tienen un doble objetivo:

- **A) Realizar ingeniería inversa del cerebro humano**
- **B) Realizar sistemas artificiales que emulen las redes naturales.**

UGR_ATC_CITIC

A. Prieto



A) Realizar ingeniería inversa del cerebro humano

- **Consiste en obtener modelos computacionales en los campos de la neurociencia, ciencia cognitiva y psicología para enmarcar hipótesis que puedan ser directamente comprobadas con experimentos biológicos o psicológicos.**
 - La simulación con computador de estos modelos permite la experimentación **in-virtual (in-silicio)** capaz de predecir el comportamiento de ciertas estructuras y funciones y obtener resultados empíricos muy próximos a los que se obtienen en experimentos **in-vitro** o **in-vivo** con muestras biológicas (se evitan métodos invasivos de experimentación para extracción de datos o realización de test de reacciones).

UGR_ATC_CITIC

A. Prieto



B) Realizar sistemas artificiales que emulen las redes naturales.

- **Lograr ciertas capacidades del cerebro.**
 - Aunque los computadores actuales son capaces de realizar muchas tareas más eficientemente que el cerebro humano, los computadores no son capaces de igualar a las capacidades cognitivas del cerebro, su flexibilidad, robustez y eficiencia energética.

UGR_ATC_CITIC

A. Prieto



En comparación con los computadores, el cerebro:

- Trabaja **lentamente** (con señales de pulsos con frecuencia de del orden de cientos de Hz) y con una **precisión baja** (procesos neurales individuales estocásticos).
- Sin embargo, todo el cerebro lleva a cabo cálculos bien **organizados en paralelo** (alrededor de 10^{16} operaciones sinápticas por segundo), trabaja en **tiempo real** (en interacción continua con el medio ambiente) con ciclos de percepción-acción cerrados y un consumo de energía muy bajo (aproximadamente **30W**).
- Supera a los ordenadores más potentes en ciertas "**tareas biológicamente relevantes**", como manipulación de objetos, reconocer una escena después de haberla visto una vez, etc.
- También proporciona una elegante degradación de capacidades, auto-reparación y modificación a través del aprendizaje (**plasticidad**).

UGR_ATC_CITIC

A. Prieto



La investigación en redes neuronales es un campo interdisciplinar:

- Se proporciona a los **neurocientíficos y psicólogos** nuevos métodos y técnicas cuantitativas que les permite, mediante simulaciones, conocer en mayor profundidad su campo.
- Los **informáticos e ingenieros** descubren nuevas ideas inspiradas en la biología (tales como los modelos de aprendizaje) que les permiten construir sistemas que satisfagan las necesidades y retos del mundo real.
- Los **físicos y los matemáticos** aplicados encuentran nuevos dominios y retos permitiendo el avance en sus campos.

UGR_ATC_CITIC

A. Prieto



El origen de las Redes Neuronales Artificiales es tratar de emular, con modelos matemáticos sencillos, el comportamiento del cerebro en la realización de determinadas tareas

- El concepto básico consiste en considerar al cerebro como un **computador paralelo, procesador de información, no lineal y altamente complejo.**
- **Las características más significativas que se tratan de emular son:**
 - El uso de redes de interconexión masiva de unidades de procesamiento simples (neuronas).
 - Procesamiento asincrónico paralelo y distribuido.
 - Dinámica no lineal.
 - Interconexión global de elementos de red.
 - Autoorganización.
 - Capacidad computacional de alta velocidad.
 - Modificación de los parámetros de la red para realizar una tarea específica o adaptación a su entorno a través de un proceso de aprendizaje.

UGR_ATC_CITIC

A. Prieto



El cerebro funciona (procesa información) de forma muy diferente a los computadores tradicionales

- No se hacen las tareas mediante programas
- No es un sistema síncrono, que funciona con un reloj,
- Etc.

UGR_ATC_CITIC

A. Prieto



Ejemplo: Problema del péndulo inverso


- **Computación tradicional:**

- Programamos el modelo físico

$$\frac{1}{2} \rho \pi \left(\frac{1}{2} h^4 + 2rh^3 + 2r^2 h^2 \right) \ddot{x} \cos \theta_2 + \frac{1}{2} \rho \pi \left(\frac{1}{2} h^4 + 2rh^3 + 2r^2 h^2 \right) (r + 2L) \cdot (\ddot{\theta}_1 - \ddot{\theta}_2) \cos(\theta_1 - \theta_2) - (\dot{\theta}_1^2 - \dot{\theta}_2^2) \sin(\theta_1 - \theta_2) = 0$$

$$\left\{ \frac{1}{2} \rho \pi \left(rh^2 - \frac{1}{3} h^3 \right) \right\} + Lm \ddot{x} \cos \theta_1 + \left\{ \frac{4}{3} mL^2 - 2 \left\{ \frac{1}{2} \rho \pi \left(rh^2 - \frac{1}{3} h^3 \right) \right\} (r + 2L) \right\} \ddot{\theta}_1 - Lm + 2 + 2 \left\{ \frac{1}{2} \rho \pi \left(rh^2 - \frac{1}{3} h^3 \right) \right\} (r + 2L) g \sin \theta_1 - \left[\frac{1}{2} \rho \pi \left(\frac{1}{2} h^4 + 2rh^3 + 2r^2 h^2 \right) \right] (r + 2L) \left\{ \ddot{\theta}_2 \cos(\theta_1 - \theta_2) + \dot{\theta}_2^2 \sin(\theta_1 - \theta_2) \right\} + D \dot{\theta}_1 = 0$$

$$\left[2 \left\{ \frac{1}{2} \rho \pi \left(-\frac{1}{5} h^5 + rh^4 - \frac{5}{3} r^2 h^3 + r^3 h^2 \right) \right\} + M + m \right] \ddot{x} + \left\{ \frac{1}{2} \rho \pi \left(rh^2 - \frac{1}{3} h^3 \right) \right\} + Lm \cdot (\ddot{\theta}_1 \cos \theta_1 - \dot{\theta}_1^2 \sin \theta_1) - \left[\frac{1}{2} \rho \pi \left(\frac{1}{2} h^4 + 2rh^3 + 2r^2 h^2 \right) \right] (\ddot{\theta}_2 \cos \theta_2 - \dot{\theta}_2^2 \sin \theta_2) = u$$




UGR_ATC_CITIC

A. Prieto



Implementación del sistema en nuestro departamento (con Simulink y Arduino):




UGR_ATC_CITIC

A. Prieto



Mi cerebro lo hace de otra forma:



- No utiliza ecuaciones diferenciales, ni lineales, ni cosenos, etc...
- Ni programas...
- ¡¡¡Que yo sepa!!!!
- Y lo hace razonablemente bien: mantiene el péndulo erguido; sobre todo con un pequeño entrenamiento (**APRENDIZAJE**)

UGR_ATC_CITIC

A. Prieto



APRENDIZAJE

UGR_ATC_CITIC

A. Prieto



El concepto de aprendizaje es la contribución más notable de las RN al campo de los sistemas de procesamiento de la información.

- El aprendizaje consiste en estimar los parámetros de un modelo de datos dado con objeto de realizar una determinada tarea.
- No hace falta conocer los mecanismos (**modelos internos**) que subyacen en un proceso específico para implementar el sistema. Las RN son “cajas negras”
- Mediante el aprendizaje el sistema se puede ir **adaptando** a cambios del entorno.

UGR_ATC_CITIC

A. Prieto



Hay tres tipos básicos de aprendizaje

- **Aprendizaje predictivo o supervisado**
 - El objetivo es aprender la correspondencia entre entradas y salidas, a partir de un conjunto de entrenamiento etiquetado de pares de entrada-salida. Se necesita conocer las correspondencias de entrada-salida, y los parámetros se establecen, minimizando una función de coste.
- **Aprendizaje descriptivo o no supervisado.**
 - Se lleva a cabo con patrones de entrada para los que no hay que especificar las salidas es decir, se realiza de "forma autoorganizada". El objetivo es extraer conocimiento ("estructuras latentes").
- **Aprendizaje por reforzamiento**
 - También se hace sin un maestro para proporcionar la respuesta deseada en cada paso del proceso de aprendizaje, y se basa en el uso de señales de premio o castigo para estimar los parámetros. Las correspondencias entrada-salida se llevan a cabo a través de la **interacción continua del sistema de aprendizaje con su entorno.**
- **Existen variaciones de los tipos básicos mencionados anteriormente, como el aprendizaje semi-supervisado, en el que el aprendizaje tradicional se combina con datos no etiquetados y datos etiquetados.**


UGR_ATC_CITIC

A. Prieto



Para el diseño de un sistema neuronal artificial


- **Hay que establecer:**
 - **Modelo** de neurona (elemento de computo)
 - **Topología** de la red
 - Reglas de **aprendizaje**
- Pre-procesamiento de datos



UGR_ATC_CITIC

A. Prieto





MODELOS, ESTRUCTURAS Y ALGORITMOS

UGR_ATC_CITIC

A. Prieto



Desde el punto de vista del objetivo de mejorar nuestro conocimiento del sistema neuronal humano



- Los modelos pretenden ser capaces de llevar a cabo experimentos y predicciones **sin tener que recurrir a tejidos biológicos**, lo que frecuentemente requiere utilizar **técnicas invasivas**.
- En este caso la tarea más importante y difícil es **conocer lo más detalladamente posible la circuiteria neuronal y los responsables de la realización de funciones cognitivas específicas**.
 - Obviamente no podemos simular algo, por ejemplo el cerebro humano, sin tener suficiente conocimiento de él.

UGR_ATC_CITIC

A. Prieto



El sistema neuronal puede ser analizado en distintos niveles de detalle o complejidad


UGR_ATC_CITIC

A. Prieto

Desde el punto de vista del objetivo de la ingeniería y la construcción de sistemas


- No ha sido posible desarrollar un modelo "universal" que pudiese aplicarse a cualquier dominio de procesamiento de la información.
- La eficiencia de un modelo se establece en términos de su **precisión** en la resolución de un problema particular y su **complejidad** que determina los recursos necesarios para su implementación con el fin de mejorar en velocidad de procesamiento, miniaturización y reducción de la energía consumo.
- Como resultado, se ha desarrollado una **gran cantidad de modelos** con el objetivo de cubrir todo tipo de problemas en el mundo real.
 - El ingeniero siempre tiene que tratar de encontrar la mejor **combinación de modelos, algoritmos y datos** con el fin de obtener la mayor eficiencia posible en cuanto a complejidad y precisión.

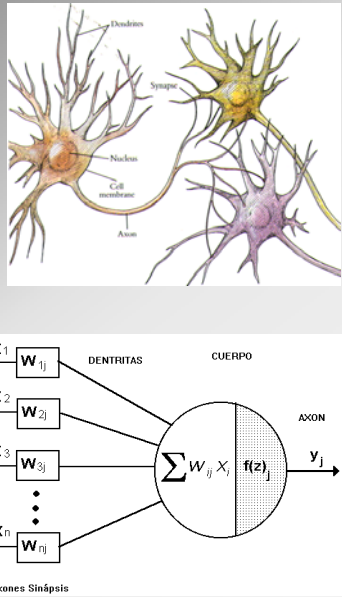
Periodos de desarrollo de los modelos de redes neuronales		
Period	Facts	Concepts applied to artificial neural networks domain.
1 st period: 1940s and 1950s.	Models and learning rules of individual neurons.	Formal neuron model, perceptrons, associative memories.
2 nd period: 1960s and 1970s.	Development of learning rules for single-layer networks, and the widespread application of techniques of statistical mechanics for recurrent networks.	Least mean-square algorithm (delta rule), Adaline, associative memories implementations, correlation matrix memory, Self-Organizing Maps (SOM), Adaptive Resonance Theory (ART), etc.
3 rd period 1980s and 1990s.	Renewal of interest in the field of neural networks and a deepening study of self-organizing maps. Application and development of learning rules for multi-layer networks. Application of Bayesian methods and Gaussian processes.	Vector quantization (VQ), Discrete-Time Hopfield Neural Network, Principal Components Analysis (PCA), Boltzmann Machine (BM), Independent Component Analysis (ICA), Back-propagation learning (BP) (generalized delta rule), Radial Basis Functions (RBF), Cellular Neural Network (CNN), Natural gradient descent learning, Support Vector Machines (SVM), etc.
4 th : 2000 until the present day.	Exhaustive theoretical studies to optimize and improve previous models: convergence analysis, statistical equilibrium, stability, estimation of states and control of synchronization.	Incremental Extreme Learning Machine (I-ELM). Deep Neural Networks (DNN).

UGR_ATC_CITIC A. Prieto 

Algunos prominentes modelos matemáticos próximos a la biología	
1943	Formal neuron model proposed by McCulloch & Pitts
1949	Synapsis behaviour proposed by Hebb
1952	Firing process and spike propagation model proposed by Hodgkin & Huxley
1961	Neuron model proposed by FitzHugh & Nagumo (FHN)
1972	Mathematical neural model proposed by Nagumo and Sato
1984	Neural model proposed by Hindmarsh-Rose.
1990	Chaotic neural networks proposed by Aihara, Takabe & Toyoda.
1994	Active membrane model of the cerebellar Purkinje cell proposed by Schutter & Bower
2002	Liquid state machine (LSM) proposed by Maass
2003	Simple model of spiking neurons proposed by Izhikevich
2005	Adaptive exponential integrate-and-fire model (AdEx or aEIF), proposed by Brette & Gerstner

Prieto, A., Prieto, B., Ortigosa, E. M., Ros, E., Pelayo, F., Ortega, J., & Rojas, I. (2016). Neural networks: An overview of early research, current frameworks and new challenges. *Neurocomputing*, 214, 242-268.

UGR_ATC_CITIC A. Prieto 

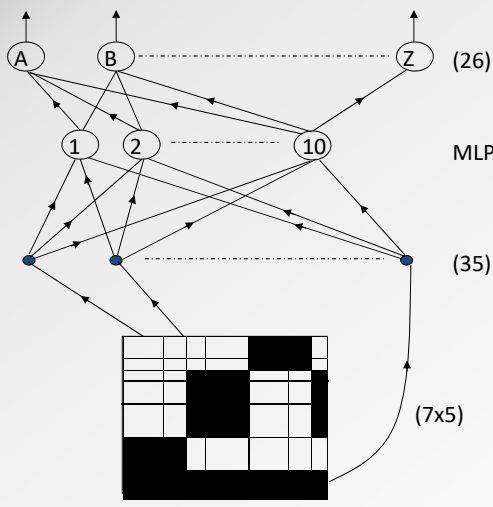


Modelo de McKulloch-Pitts (1943)

- ↳ Potencial de membrana: $z_j = \sum_i w_{ij} \cdot x_i$
- ↳ Condición de disparo: $x_i > t$
- ↳ Salida o potencial de acción: $y_j = f(z_j)$
- ↳ Función de activación: f
- ↳ La salida "y_j" representa un nivel de tensión o la frecuencia de "spike" de la neurona j.

UGR_ATC_CITIC A. Prieto

Reconocimiento de caracteres



(7x5)




(35)

MLP

(26)

UGR_ATC_CITIC A. Prieto



Señales que biológicamente se transmiten ("spikes")



UGR_ATC_CITIC

A. Prieto

Modelo estándar de Hodgkin-Huxley



The capacitive current across the cell membrane can be described as the sum of changes in the membrane voltage V_m and ion currents caused primarily by sodium (Na) and potassium (K) and other leakages (L), mainly chloride ions. The ion currents are defined by their conductances (g , with the Na and K conductances being voltage dependent), their equilibrium potentials (E) and how the channel gates open and close (m, n, h):

$$I_{ext} = C_m \frac{dV_m}{dt} + I_{ion}$$

$$= C_m \frac{dV_m}{dt} + g_{Na} m^3 h (V - E_{Na}) + g_K n^4 (V - E_K) + g_L (V - E_L)$$

UGR_ATC_CITIC

A. Prieto

The standard Hodgkin-Huxley model expands into a set of four differential equations:

$$C \frac{dV}{dt} = I - g_{Na} m^3 h (V - E_{Na}) - g_K n^4 (V - E_K) - g_L (V - E_L)$$

$$\frac{dm}{dt} = a_m(V)(1 - m) - b_m(V)m$$

$$\frac{dh}{dt} = a_h(V)(1 - h) - b_h(V)h$$

$$\frac{dn}{dt} = a_n(V)(1 - n) - b_n(V)n$$

$$a_m(V) = 0.1(V + 40)/(1 - \exp(-(V + 40)/10))$$

$$b_m(V) = 4 \exp(-(V + 65)/18)$$

$$a_h(V) = 0.07 \exp(-(V + 65)/20)$$

$$b_h(V) = 1/(1 + \exp(-(V + 35)/10))$$

$$a_n(V) = 0.01(V + 55)/(1 - \exp(-(V + 55)/10))$$

$$b_n(V) = 0.125 \exp(-(V + 65)/80)$$

UGR_ATC_CITIC

A. Prieto




Algunas contribuciones de nuestro grupo en el modelado y diseño de RNA

- Castillo, P. A., Merelo, J. J., Prieto, A., Rivas, V., & Romero, G. (2000). G-Prop: Global optimization of multilayer perceptrons using GAs. *Neurocomputing*, 35(1), 149-163. (169 citas).
- Rojas, I., Pomares, H., Ortega, J., & Prieto, A. (2000). Self-organized fuzzy system generation from training examples. *IEEE Transactions on Fuzzy Systems*, 8(1), 23-36. (169 citas).
- Castillo, P. A., Carpio, J., Merelo, J. J., Prieto, A., Rivas, V., & Romero, G. (2000). Evolving multilayer perceptrons. *Neural Processing Letters*, 12(2), 115-128. (80 citas)
- J.L. Bernier, J. Ortega, E. Ros, I. Rojas, A. Prieto, A Quantitative Study of Fault Tolerance, Noise Immunity and Generalization Ability of MLPs, *Neural Computation*, 12 (2000) 2941-2964.
- J.L. Bernier, J. Ortega, I. Rojas, A. Prieto, Improving the tolerance of multilayer perceptrons by minimizing the statistical sensitivity to weight deviations, *Neurocomputing*, 31(1-4) (2000) 87-103.

UGR_ATC_CITIC

A. Prieto





SIMULADORES

UGR_ATC_CITIC

A. Prieto



Un modelo por si sólo no es muy útil...

- **Realmente es un paso intermedio para facilitar la emulación o replica del comportamiento de una función neuronal o un sistema mediante:**
 - Un programa de ordenador
 - Hardware específico (hardware neuronal)

UGR_ATC_CITIC

A. Prieto



- Hay simuladores generales de RN, en forma de programas software que emulan el comportamiento de la red neuronal artificial o biológica.
- Con el término “general” se desea indicar:
 - Que puede ejecutarse en computadores de uso general.
 - Son usados para simular distintos tipos de neuronas o redes, siendo capaz de modificar en cada simulación los parametros o la topología de red.
- Con estos simuladores **en-virtual (in-silicio)** puede hacerse la experimentación, predecir el comportamiento de ciertas estructuras y funciones, y obtener resultados empíricos, coincidiendo con medidas tomadas de estructuras biológicas (con experimentación **in vitro** o **in vivo**).

UGR_ATC_CITIC

A. Prieto



Los simuladores enfocados a emulaciones biológicas utilizan modelos de neuronas que representan detalladamente la biofísica:

- **Modelos de**
 - Hodgkin-Huxley,
 - FitzHugh-Nagumo,
 - Hindmarsh-Rose,
 - Schutter-Bower,
 - Izhikevich, etc.

UGR_ATC_CITIC

A. Prieto



En general, la biofísica neural se representa a través de modelos matemáticos híbridos

- Por un lado, se define la dinámica del estado neural a través de **ecuaciones diferenciales** (ordinarias o parciales y determinísticas o estocásticas), y
- Por otra parte, una **ecuación no lineal** define el disparo sináptico dependiendo del estado neuronal y de los pulsos (*spikes*) recibidos.
- Desde un punto de vista computacional, los simuladores neuronales pueden ser vistos como programas que resuelven **ecuaciones diferenciales acopladas a gran escala con métodos numéricos**. Las variables de entrada y salida están relacionadas (interconectadas) según la topología de la red y los estímulos externos.
 - Decenas de miles de millones (10^{10}) de neuronas y centenares de billones (10^{14}) de sinapsis.

UGR_ATC_CITIC

A. Prieto



Algunos ejemplos de simuladores		
Acronym	Description	Original proposers
BRIAN	Brian spiking neural network simulator	Romain Brette Dan Goodman Marcel Stimberg
DigiCortex	Biological Neural Network Simulator	Ivan Dimkovic Ana Balevic
ECANSE Siemens	Environment for Computer Aided Neural Software Engineering	Roman Blaško (Siemens)
EDLUT	Event Driven Look-Up-Table simulator	Eduardo Ros & col.
emergent	Emergent Neural Network Simulation System	Randall C. O'Reilly
GENESIS	General NEural Simulation System	James Bower Dave Beeman
Mvaspike	Modelling and simulating large, complex networks of biological neural networks, event-based.	Inria Sophia Antipolis (France)
NCS	NeoCortical simulator	Wilson C.E., Goodman P.H., Harris F.C.
NENGO	Graphical and scripting based software for simulating large-scale neural systems.	Chris Eliasmith Terry Stewart Bryan Tripp
NEST Neuron	Neural Simulation Tool Neuron for empirically-based simulations of neurons and networks of neurons	NEST Initiative Michael Hines
Neuroph	Java neural network framework	Zoran Sevarac Ivan GoloskokovicJon
NN Toolbox	MATLAB Neural Network Toolbox	Mathworks
OpenNN	Open Neural Networks Library	Roberto López
PCSIM and CSIM	Parallel neural Circuit SIMulator	Thomas Natschläger Pecevski Dejan
SimBrain	Computer simulations of brain circuitry	Jeff Yoshimi
SNNAP	Simulator for Neural Networks and Action Potentials	John Byrne Douglas Baxter
SNNS	Stuttgart Neural Network Simulator	University of Stuttgart, Maintained at University of Tübingen
SpikeNET,	Neural simulator for modelling large networks of integrate and fire neurons	Arnaud Delorme Simon Thorpe
PSICS	Parallel Stochastic Ion Channel Simulator	Matthew Nolan
XNBC	X- NeuroBioClusters	Jean-François VIBERT
XPP /XPPAUT	General numerical tool for simulating, animating, and analyzing dynamical systems.	G. Bard Ermentrout John Rinzel
VERTEX	Virtual Electrode Recording Tool for EXtracellular potentials	Richard John Tomsett, and Marcus Kaiser

UGR_ATC_CITIC

A. Prieto




Simuladores

- **J.Ortega, I.Rojas, A.F.Díaz, A.Prieto, Parallel Coarse Grain Computing of Boltzmann Machines, Neural Processing Letters (NPL), Vol. 7, No. 3, pp. 169-184, June 1998.**
- **EDLUT**
 - E. Ros, R. Carrillo, E.M. Ortigosa, B. Barbour, R. Agís, *Event-Driven Simulation Scheme for Spiking Neural Networks Using Lookup Tables to Characterize Neuronal Dynamics*. Neural Computation, 18 (2006) 2959-2993.
 - F. Naveros, N.R. Luque, J.A. Garrido, R.R. Carrillo, M. Anguita, E. Ros, A spiking neural simulator integrating event-driven and time-driven computation schemes using parallel CPU-GPU co-processing. IEEE Transactions on Neural Networks, 26 (7) (2014) 1567-1574.

UGR_ATC_CITIC

A. Prieto



PLATAFORMAS Y HARDWARE ESPECIALIZADO

UGR_ATC_CITIC

A. Prieto



La simulación o implementación física puede realizarse utilizando:

- Computadores convencionales (donde se pueden ejecutar los simuladores) o
 - Hardware neuronal, cuando se requiere una mayor velocidad, o cuando se utiliza un modelo para una aplicación específica que, por ejemplo, requiere insertarse en sistemas más complejos con un tamaño reducido y trabajando en tiempo real.
- **Hay que considerar dos dimensiones:**
 - **flexibilidad**, que se refiere a las facultades que ofrece el sistema para parametrizar o escalar el modelo de red, la topología y los algoritmos de aprendizaje;
 - **eficiencia**, que se considera como el grado de adaptación (*tuning*) de la red con la aplicación, en lo que respecta a la autonomía, velocidad computacional, miniaturización y consumo de energía.

UGR_ATC_CITIC

A. Prieto



Alternativas de plataformas de simulación y hardware neuronal



UGR_ATC_CITIC

A. Prieto




- **Custom neural circuit o silicon neuron**

- Circuito integrado de aplicación específica (ASIC) que replica una función neuronal, una estructura o un comportamiento de neuronas reales.



- **Circuito o sistema "neuromórfico" (Carver Mead)**

- sistemas y circuitos cuya arquitectura y principios de diseño se basan en los sistemas nerviosos biológicos.
- Entre los ejemplos de circuitos neuromórficos se encuentran las **retinas de silicio**, un modelo de silicio de la **corteza cerebral**, órganos **auditivos** y sistemas **vestibulares**.



UGR_ATC_CITIC

A. Prieto



Acelerador neuronal

- **Sistema no autónomo que funciona conectándose a través de un bus de banda ancha a una computadora de propósito general que actúa como un host, con el fin de aumentar el rendimiento en la ejecución de algunas tareas inherentes a la computación neuronal.**
- **Estos aceleradores están embebidos en el host como placas co-procesadoras que contienen procesadores especializados, como GPU, DSP, FPGA o neuronas de silicio, así como una memoria de estado sólido adicional.**


UGR_ATC_CITIC

A. Prieto



Computador neuromórfico (o neurocomputador)

- Plataforma autónoma, personalizada, de alto rendimiento, construida con el objetivo de **emular tejido nervioso biológico** a diferentes niveles, compuesto principalmente de sinapsis y neuronas individuales, y con una programabilidad similar a un sistema de uso general.
- Se basan en arquitecturas de ordenadores muy diferentes a las de von Neumann, con una estructura y una función inspiradas en la estructura y función del cerebro y generalmente contienen circuitos neuromórficos



UGR_ATC_CITIC

A. Prieto



Algunos ejemplos de proyectos sobre neurocomputadores

- **SyNAPSE**,
 - trata de desarrollar una máquina neuromórfica electrónica que escale a niveles biológicos e intenta construir un nuevo tipo de computadora con forma y función similares al cerebro de los mamíferos.
- **SpiNNaker (Spiking Neural Network Architecture)**,
 - es un sistema de computación multi-core masivamente paralelo, basado en un modelo de seis capas de talamocortical, diseñado en la Universidad de Manchester para mejorar el rendimiento de simulaciones de cerebro humano
- **El sistema de computación neuromórfico de la Universidad de Heidelberg.**
 - Han desarrollado diversos sistemas y circuitos neuromórficos, uno de los cuales está actualmente en funcionamiento y cuenta con 200.000 neuronas y 50.000.000 de sinapsis en una oblea de silicio completa fabricada en una tecnología CMOS de 180nm.
 - Tratan de desarrollar circuitos neuronales universales y configurables que sirvan como prototipos para un nuevo tipo de arquitectura informática.

UGR_ATC_CITIC

A. Prieto



Algunos ejemplos de proyectos sobre neurocomputadores

- **Neurogrid**

- sistema neuromórfico para simular modelos neuronales a gran escala en tiempo real que es suficiente para incluir múltiples áreas corticales, suficientemente detalladas como para tener en cuenta propiedades celulares distintas.
- El componente fundamental no es una puerta lógica, como en una arquitectura secuencial síncrona (Von Neumann) sino una neurona de silicio, cuyo comportamiento y conectividad son programables.
- Estas opciones facilitan la simulación de millones de neuronas, con miles de millones de sinápticas en tiempo real, utilizando 16 neurocores integrados en una placa, consumiendo 3 vatios, aproximadamente 100.000 veces menos energía que si la simulación se realizara con un supercomputador.

UGR_ATC_CITIC

A. Prieto



Sistemas neuromórficos empotrados

- **Se usan en computación de alto rendimiento, servicios avanzados y productos de electrónica de consumo, sensores inteligentes, robótica, etc.**

- A diferencia de los neurocomputadores están orientados hacia aplicaciones muy específicas en tiempo real y no funcionan de forma autónoma, sino que llevan a cabo sus funciones dentro de un sistema electrónico o mecánico más grande donde están incrustados.
- Estos sistemas pueden contener circuitos neuronales personalizados, FPGAs o hardware off-the-shelf

UGR_ATC_CITIC

A. Prieto



El desarrollo del hardware neuronal ha influido significativamente en el progreso:

- Del desarrollo de hardware especializado para implementar físicamente modelos neurobiológicos de computación y aplicarlo para obtener soluciones para servicios avanzados, industria y electrónica de consumo.
- De la exploración de nuevas arquitecturas informáticas inspiradas en el cerebro y basadas en nuevos conceptos de codificación, aprendizaje, paralelismo masivo y procesamiento con variables estocásticas, lejos de los conceptos tradicionales basados en la lógica discreta
 - Robert Noyce ya afirmó en 1984: “Until now we have been going the other way; that is, in order to understand the brain we have used the computer as a model for it. Perhaps it is time to reverse this reasoning: to understand where we should go with the computer, we should look to the brain for some clues”.
 - (“Hasta ahora hemos ido por al revés; es decir, para entender el cerebro hemos utilizado como modelo los computadores. Tal vez es hora de invertir este razonamiento: para entender cómo deber ser los computadores, debemos buscar algunas pistas en el funcionamiento del cerebro”).

UGR_ATC_CITIC

A. Prieto



Trazado de máscaras de un neurocircuito desarrollado en CASIP-UGR (1991).



Matriz de 128 sinapsis con 16 entradas y 8 salidas diferenciales post-sinápticas (densidad 50 sinapsis por mm²)

PELAYO,F.J.; PINO,B.; PRIETO,A.; ORTEGA,J.; FERNANDEZ,F.J.: "CMOS Implementation of Synapse Matrices with programmable analog weights". Lecture Notes in Computer Science 540. pp. 307-314, ISSN: 0302-9743, Springer-Verlag. 1991.

UGR_ATC_CITIC

A. Prieto



Mascaras de una celda de una retina artificial (CNN) desarrollada en CASIP-UGR (1996)



Dispone de 64 celdas con 11 parámetros programables y un sensor integrado. Densidad 10,7 celdas/mm²

M. Anguita, F. Pelayo, F.J. Fernandez, A. Prieto, A low-power CMOS implementation of programmable CNN's with embedded photosensors, *Circuits and Systems I: Fundamental Theory and Applications*, IEEE Transactions on 44.2 (1997) 149-153.
M. Anguita, F.J. Pelayo, A. Prieto, J. Ortega, Analog CMOS implementation of a cellular neural networks with programmable cloning templates, *IEEE Trans. on Circuits and Systems*, 40(3) (1993).

UGR_ATC_CITIC

A. Prieto



Otras contribuciones:

- **A. Prieto, P. Martin-Smith, J.J. Merelo, F.J. Pelayo, J. Ortega, F.J. Fernandez, B. Pino, Simulation and hardware implementation of competitive learning neural networks, in: Statistical Mechanics of Neural Networks. Lectures Notes in Physics. Springer-Verlag, 368 (1990) 189-204.**
- **F.J. Pelayo, E. Ros, X. Arreguit, A. Prieto, VLSI neural model using spikes, Analog Integrated Circuits and Signal Processing, 13(1-2) (1997) 111-121.**

UGR_ATC_CITIC

A. Prieto



DOMINIOS DE USO Y APLICACIONES DEL MUNDO REAL.

UGR_ATC_CITIC

A. Prieto



- Las redes neuronales son especialmente útiles para inferir el conocimiento subyacente en las observaciones o cuando los datos o las tareas son tan complejas que son irrealizables en tiempos razonables con los métodos tradicionales.
- Los sistemas de procesamiento de información basados en redes neuronales se han convertido en herramientas estándar, especialmente útiles para resolver problemas del mundo real, desde fines de los años ochenta.

UGR_ATC_CITIC

A. Prieto



Algunos problemas del mundo real resolubles con técnicas de aprendizaje

- Reconocimiento complejo de patrones,
- Estimación de funciones,
- Problemas de clasificación y
- Descubrimiento de factores latentes

UGR_ATC_CITIC

A. Prieto



Classification and clustering

Face detection and recognition	Biometric identification
Traffic sign recognition	Image processing
Texture classifier.	
Handwriting recognition	Internet
Document classification and e-mail spam filtering.	
Detecting intrusions and attacks through the Internet	Medical diagnosis.
Biomedical images classification.	
Classification and diagnostic prediction of cancers ^{327,328} .	Medicine & health
Microarray gene expression cancer diagnosis ³²⁹ .	
Pattern recognition on medical images ³³⁰ .	Meteorology
Supervised pattern recognition in food analysis ³³¹ .	
Cloud classification and detection via satellite remote sensing	Pharmacology
Virtual screening of compounds	Scientific taxonomies
Classifying flowers ⁷⁴ .	Signal processing
Classification of EGG signals (in BCI, etc.) ^{355,356} .	Space
Satellite selection for GPS navigation ³⁶¹ .	

UGR_ATC_CITIC

A. Prieto



Modelling, functional approximation and forecasting	
Brand choice decisions ²⁸⁸ .	Business management
Modelling processes in Analytical Chemistry ²⁹⁷	Chemistry
Modelling the Escherichia coli fermentation process ²⁹⁶ .	Chemistry
PID controllers design ²⁹⁵ .	Control
Prediction pollutant levels ³⁰⁰ .	Ecology
Forecasting financial and economic time series ³⁰⁹ .	Ecology
Corporate credit ratings ³¹² . Credit scoring and prediction ^{310, 311} .	Economy and finances
Financial distress prediction ³¹³ .	Economy and finances
Modelling in induction motors ³⁰¹ .	Electro-mechanics.
Adaptive position tracking control of permanent magnet synchronous motor ³⁰² .	Electro-mechanics.
Modelling of energy systems ^{303,304,305} .	Energy resources.
Electrical load forecasting ³⁰⁶ .	Energy resources.
Model for analysis of the Drosophila Melanogaster genome ³¹⁴ .	Genetics
Prediction of geological risks ³¹⁵ .	Geology

UGR_ATC_CITIC A. Prieto

Modelling, functional approximation and forecasting	
Predicting the age of a viewer watching a given video on YouTube ⁷⁴ .	Internet
Decision making ^{347,348} . Multiple criteria decision-making ^{349,350} .	Management.
Machinery diagnosis ³²³ .	Mechanics
Modelling for knee rehabilitation ³³³ .	Medicine & health.
Predicting the amount of prostate specific antigen (PSA) in the body ⁷⁴ .	Medicine & health.
Predicting climate variables (temperature, wind speed, etc.) ^{339,340,341}	Meteorology
Protein function prediction ³⁴² .	Molecular biology
Modelling, predicting and forecasting water resources ^{344,345,346} .	Natural resources
Tracking control of a biped robot ³⁵² .	Robotics
Enhancing robot accuracy ³⁵³ .	Robotics

UGR_ATC_CITIC A. Prieto


Discovering clusters		
	<ul style="list-style-type: none"> Autoclass system³⁶², discovered a new type of star, based on clustering astrophysical measurements⁷⁴. 	Astronomy & space
	<ul style="list-style-type: none"> Cluster users into groups, according to their web purchasing or browsing profile in order to customize the advertisements to be displayed to each group^{74, 289}. 	Business management . e-commerce
	<ul style="list-style-type: none"> Cluster flow-cytometry data into groups, to discover different sub-populations of cells^{74, 366}. 	Scientific taxonomies

UGR_ATC_CITIC A. Prieto

Discovering latent factors		
	<ul style="list-style-type: none"> Motions capture data to a low dimensional space, and using it to create animations⁷⁴. 	Computer graphics
	<ul style="list-style-type: none"> Using PCA to interpret gene microarray data⁷⁴. 	Genetics
	<ul style="list-style-type: none"> Detection of changes on the Earth's surface³¹⁶. 	Geology
	<ul style="list-style-type: none"> Filtering for network intrusion detection³¹⁹. 	Internet
	<ul style="list-style-type: none"> Feature extraction in gearbox fault detection³²⁴. 	Mechanics
	<ul style="list-style-type: none"> Using latent semantic analysis (a PCA variant) for document retrieval⁷⁴. 	Natural language.
	<ul style="list-style-type: none"> Speech processing and language modelling^{363,364,365}. 	Medicine & health
	<ul style="list-style-type: none"> Signal processing in Brain Computer Interfaces (BCI)³³⁴. 	Signal processing
	<ul style="list-style-type: none"> Signals separation into their different sources^{49,50,357,358,359,360}. 	


UGR_ATC_CITIC A. Prieto

Discovering graph structure		
	• Determination of the phosphorylation status of some proteins in a cell.	Molecular biology.
	• Improving financial portfolio management by learning a sparse graph ⁷⁴ .	Economy and finances
	• Predicting traffic jams on freeways ⁷⁴ .	Engineering
	• Recovering, from time-series EEG data, the neural “wiring diagram” of a certain kind of bird ⁷⁴ .	Neuroscience

UGR_ATC_CITIC A. Prieto 

Matrix completion		
	• Inpainting images to obtain realistic textures ⁷⁴ .	Computer graphics
	• Market basket analysis and predicting in commercial mining data ⁷⁴ .	Economy and finances
	• Collaborative filtering for, say, predicting the desired movies by a person on the basis of what they have previously seen ⁷⁴ .	Internet

Prieto, A., Prieto, B., Ortigosa, E. M., Ros, E., Pelayo, F., Ortega, J., & Rojas, I. (2016). Neural networks: An overview of early research, current frameworks and new challenges. *Neurocomputing*, 214, 242-268.

UGR_ATC_CITIC A. Prieto 

Algunas aplicaciones de nuestro grupo de investigación

- Andrade, M. A., Chacon, P., Merelo, J. J., & Moran, F. (1993). Evaluation of secondary structure of proteins from UV circular dichroism spectra using an unsupervised learning neural network. *Protein Engineering*, 6(4), 383-390. (1.033 citas).
- González, J., Rojas, H., Ortega, J., & Prieto, A. (2002). A new clustering technique for function approximation. *IEEE Transactions on Neural Networks*, 13(1), 132-142. (152 citas)
- J.J. Merelo, M.A. Andrade, A. Prieto, Moran F. Proteinotopic feature maps. *Neurocomputing* 6(4) (1994) 443-454. (144 citas).
- Rojas, I., Pomares, H., Bernier, J. L., Ortega, J., Pino, B., Pelayo, F. J., & Prieto, A. (2002). Time series analysis using normalized PG-RBF network with regression weights. *Neurocomputing*, 42(1), 267-285. (148 citas).
- C.G. Puntonet; A. Prieto. Neural net approach for blind separation of sources based on geometric properties. *Neurocomputing* 18, (1-3), (1998), 141-164.

UGR_ATC_CITIC

A. Prieto



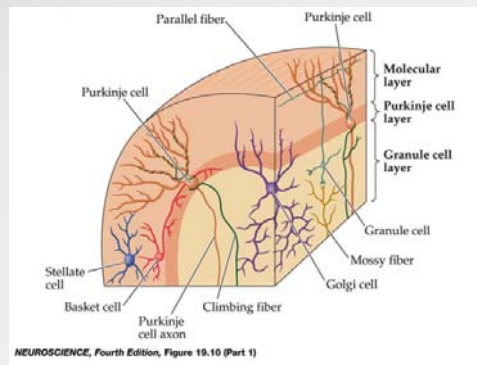
Algunas aplicaciones de nuestro grupo de investigación

- L.J. Herrera, H. Pomares, I. Rojas, A. Guillén, A. Prieto, O. Valenzuela, Recursive prediction for long term time series forecasting using advanced models, *Neurocomputing*, 70(16-18) (2007) 2870-2880.
- M. A. Lopez-Gordo, F. Pelayo, A. Prieto, and E. Fernandez, An Auditory Brain-Computer Interface with Accuracy Prediction. *International Journal of Neural Systems* 22(3) (2012).
- M.A. Lopez, A. Prieto, F. Pelayo, C. Morillas, Use of Phase in Brain-Computer Interfaces based on Steady-State Visual Evoked Potentials, *Neural Processing Letters*, 32 (1) (2010) 1-9.
- M.A. Lopez, H. Pomares, F. Pelayo, J. Urquiza, J. Perez, Evidences of cognitive effects over auditory steady-state responses by means of artificial neural networks and its use in brain-computer interfaces, *Neurocomputing*, 72 (16-18) (2009) 3617-3623.
- M.A. Lopez-Gordo, F. Pelayo, A. Prieto, E. Fernandez, An Auditory Brain-Computer Interface with accuracy prediction. *International Journal of Neural Systems*, 22 (3) (2012).

UGR_ATC_CITIC

A. Prieto





NEUROBÓTICA

UGR_ATC_CITIC

A. Prieto



**Un cerebro sin un "cuerpo" no sirve para nada ...
es una pieza de carne gelatinosa**

- **La magia está en la integración Cuerpo-Cerebro-Cuerpo**


UGR_ATC_CITIC

A. Prieto



En otras palabras el objetivo del cerebro es interactuar con el entorno

- Acción ... a través del movimiento (interacción con el entorno)



UGR_ATC_CITIC

A. Prieto



El Ajedrecista (1914)



- Leonardo Torres Quevedo

UGR_ATC_CITIC

A. Prieto



Neurobotica: interfaz de robots virtuales o físicos con modelos cerebrales

- El uso de robots simulados o reales como “cuerpos” para la neurociencia computacional representa una nueva herramienta de investigación que acaba de nacer.
- Sin duda ofrecerá nuevas herramientas, modelos, simuladores, interfaces, ..., que en la actualidad son necesarias.



UGR_ATC_CITIC

A. Prieto



Demostración

- vídeos

UGR_ATC_CITIC

A. Prieto





Neurobotics. Manipulación de objetos. Prueba de trayectorias

$$q_1 = A_1 \cdot \sin(\pi \cdot t) + C_1$$

$$q_2 = A_2 \cdot \sin(\pi \cdot t + \theta) + C_2$$

$$q_3 = A_3 \cdot \sin(\pi \cdot t + 2 \cdot \theta) + C_3$$



Main Contributor: Niceto Luque-Sola (UGR)

UGR_ATC_CITIC


A. Prieto



Durante la manipulación hay que considerar diferentes contextos



Objetos con **diferentes dinámicas**
(distintos pesos 1 Kg, 5 Kg, etc)



Objetos con **diferentes cinemáticas**
(apuntar a un objeto con distintos ángulos, etc)

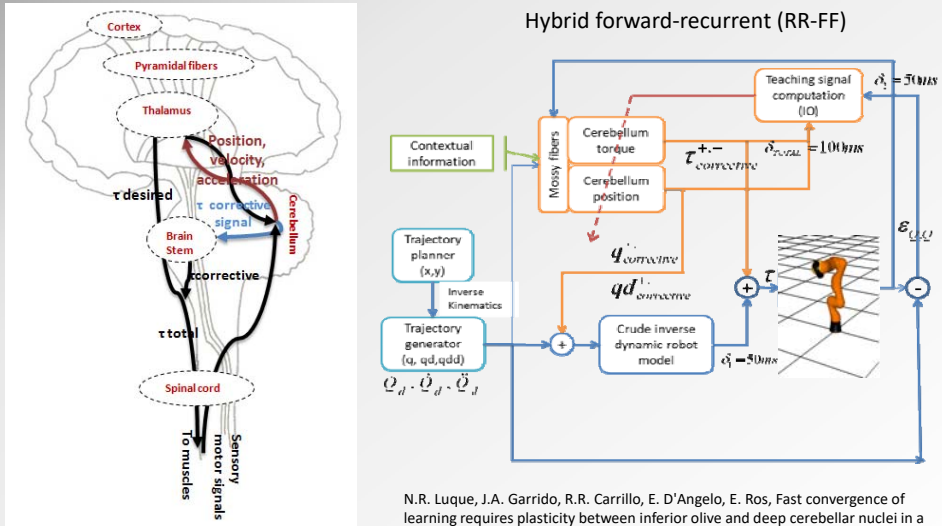
Los contextos también podrían ser diferentes en términos de fricción, tipos de nieve durante el esquí, etc

UGR_ATC_CITIC

A. Prieto



Lazos de control biomimeticos



N.R. Luque, J.A. Garrido, R.R. Carrillo, E. D'Angelo, E. Ros, Fast convergence of learning requires plasticity between inferior olive and deep cerebellar nuclei in a manipulation task: a closed-loop robotic simulation. *Front. Comput. Neurosci.* (2014) 1-16.

UGR_ATC_CITIC

A. Prieto

RETOS Y CONCLUSIONES



UGR_ATC_CITIC

A. Prieto

- Es evidente que a lo largo de los últimos años, los modelos y simulaciones neuronales **están haciendo posible revelar los principios fundamentales de la computación neural a los neurocientíficos.**
- Por otra parte, el interés en las redes neuronales artificiales está creciendo tanto que sus modelos y algoritmos se han convertido en **herramientas estándar en informática e ingeniería de la información.**
 - Se están obteniendo sistemas con capacidades cognitivas similares, flexibilidad, potencia y eficiencia energética a las del cerebro humano.

UGR_ATC_CITIC

A. Prieto



- Hay que hacer notar que poco a poco el campo de las redes neuronales artificiales ha contribuido en gran medida al **nacimiento y desarrollo de otras disciplinas, donde se ha integrado, aportando de forma natural conceptos relevantes. Entre estas disciplinas se encuentran la:**
 - Inteligencia Computacional,
 - Aprendizaje en Máquinas (Aprendizaje Automático),
 - Neurociencia Computacional,
 - Neuroingeniería,
 - Computación Natural y
 - Neuroinformática.

UGR_ATC_CITIC

A. Prieto



- Las comunidades científicas de varios países, y la sociedad en general, consideran que el **conocimiento profundo del cerebro humano** constituye uno de los **retos más importantes del Siglo XXI**.
- La mejor comprensión del cerebro humano requiere la colaboración internacional masiva de muchos laboratorios en diferentes campos interdisciplinarios.
- Esto ha llevado a la CE y a EE UU a establecer dos grandes proyectos para estudiar el cerebro humano a fondo, e incluso a tratar de simularlo, parcial o totalmente, con la ayuda de supercomputación de alto rendimiento.
 - Human Brain (1.000 millones de € a distribuir en 10 años) y
 - Brain Initiative (5.000 millones de \$)

UGR_ATC_CITIC

A. Prieto



- El objetivo es conocer los "algoritmos" que gobiernan el procesamiento de la información dentro de un circuito neuronal y las interacciones entre circuitos en el cerebro como un todo, lo que sin duda conducirá a **nuevos tratamientos médicos** y a **nuevas tecnologías informáticas**.
- El proyecto HB, entre otros objetivos, trata de desarrollar una plataforma de cómputo de altas prestaciones orientada a la agregación de múltiples datos de neurociencia para construir un **atlas de cerebro** en varios niveles y **navegar** a través de él, y de desarrollar otra plataforma que sirva para **escalar** y **optimizar** las simulaciones cerebrales.
- En nuestro departamento, dentro CITIC-UGR, y bajo la dirección del **Eduardo Ros Vidal**, estamos participando dentro de HBP en el desarrollo de una **plataforma neuro-robótica** para poder realizar experimentos cognitivos en circuito cerrado, con el fin de evaluar interacciones de modelos detallados del cerebro con un entorno simulado.

UGR_ATC_CITIC

A. Prieto



Pregunta osada: ¿Seremos capaces, hoy en día, de construir un cerebro humano?

- El cerebro humano tiene alrededor de **90 mil millones de neuronas** que configuran una red **extremadamente compleja**, pero cada vez tenemos modelos y datos recopilados del cerebro humano más precisos.
- Los supercomputadores Teraescala (billones de ope/s) nos permitieron dar el salto de simulaciones de neuronas individuales a **nivel celular** a simulaciones a nivel de **microcircuitos neuronales**.
- Ahora disponemos de computadores Petaescala (mil billones op/s) con potencia suficiente para realizar simulaciones a **nivel celular de todo un cerebro de roedor**, o para simulaciones a **nivel molecular de neuronas individuales**.
- Está previsto al final de la presente década el desarrollo de computadores Exascale (trillones de operaciones por segundo) que nos podría permitir **simulaciones a nivel celular de un cerebro humano completo y a nivel molecular de partes del mismo**.



UGR_ATC_CITIC

A. Prieto



- Sin duda, el logro de los retos tanto del HBP como de la Brain Initiative, proporcionará una mejor comprensión de las redes neuronales y de la neurociencia computacional, en general; y tal vez nos permitirá conocer de qué manera se llevan a cabo algunas de las **propiedades únicas de la mente humana**, tales como el **conocimiento de alto nivel**, el **razonamiento**, la **toma de decisiones**, la **conciencia**, la **emoción**, el **libre albedrío** y la **creatividad**.



UGR_ATC_CITIC

A. Prieto



Un resumen de todo en....

- Prieto, A., Prieto, B., Ortigosa, E. M., Ros, E., Pelayo, F., Ortega, J., & Rojas, I. (2016). Neural networks: An overview of early research, current frameworks and new challenges. *Neurocomputing*, 214, 242-268.
- Esta presentación se encuentra en:
 - http://atc.ugr.es/APrieto_conferencias

UGR_ATC_CITIC

A. Prieto



Muchas gracias por vuestra atención

UGR_ATC_CITIC

A. Prieto

