

Seminario Deep Learning

COMENTARIOS DEL ARTÍCULO:

“Aprendizaje de representaciones en señales de EEG usando Redes Neuronales Recurrentes-Convolucionales profundas”

[Barshivan et. al, enviado a “International Conference on Learning Representation, ICLR 2016] “*

Presenta

Magdiel Jiménez Guarneros

magdiel.jg@ccc.inaoep.mx

16 de Junio de 2016

[* P.Barshivan, I. Rish, M. Yeasin, N. Coedella. Learning representations from EEG with Deep Recurrent-Convolutional Neural Networks. Submitted to ICLR 2016. <http://arxiv.org/abs/1511.06448>.

- **Introducción**
- **Redes Neuronales profundas**
 - Red Neuronal Convolutacional
 - Red Neuronal Recurrente
- **Metodología**
- **Resultados**
- **Conclusiones**

- El Electroencefalograma (EEG) es el registro de las señales que representan la actividad eléctrica en el cerebro [Varsavsky et al.,2011].
- Las señales de EEG pueden ser vistas como series de tiempo, las cuales pueden ser modeladas como un proceso estocástico que es altamente complejo, no lineal y no estacionario [Martínez Montes,2009].
- Dos tipos de actividades pueden ser identificadas en el estudio del funcionamiento cerebral [Martínez Montes, 2009].
 - Actividades espontáneas
 - Patologías, detección de epilepsia [Mirowski et al.,2009]
 - Actividades relacionada a eventos
 - Actividades cognitivas o sensoriales [Barshivan et al., 2016]





Figura obtenida de <http://www.infirmus.es/electroencefalograma/>

- El análisis de señales de EEG basado en aprendizaje automático puede ser dividido en tres fases:



- Ingeniería de características se refiere al proceso de usar el conocimiento del dominio de los datos para crear características de manera manual, que hacen a un clasificador trabajar [Bengio et al., 2013].
- La fase de ingeniería de características tiene una gran influencia en los resultados de reconocimiento de las señales de EEG.

- La automatización del proceso de ingeniería de características es conocida como aprendizaje de representaciones [Bengio et al.,2013; Lecun et al.,2015].
- Ésta se refiere a aprender representaciones de los datos que hacen más fácil extraer información útil cuando construyes clasificadores o predictores [Lecun et al.,2015].
- Un método de aprendizaje de representaciones no sólo usa las características para aprender, sino que aprende las características por sí mismo [Bengio et al.,2013].

El artículo fr de [Barshivan et al., 2016] busca modelar eventos cognitivos de datos de un electroencefalograma (EEG), a través de representaciones que son invariantes a las diferencias entre e intra-sujetos, así como al ruido inherente asociado con la recolección de las señales de EEG.

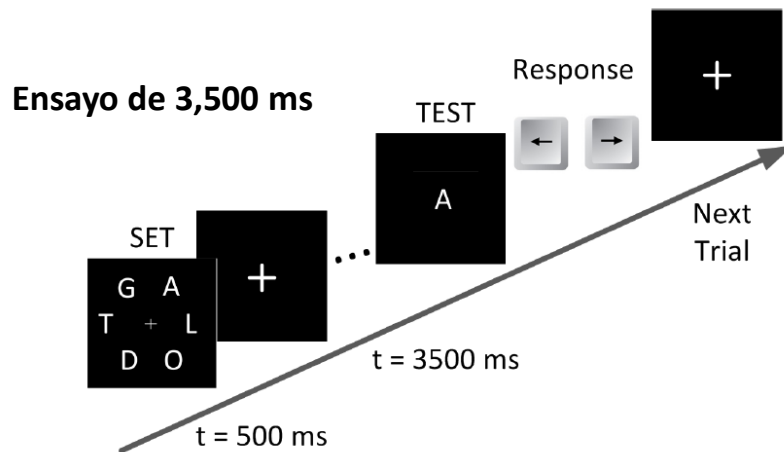


Figura obtenida de [Barshivan et al., 2016]



Figura obtenida de <http://www.saludymedicinas.com.mx/assets/img/Electroencefalograma-Actividad-Cerebral.jpg>

Experimento con 15 participantes de 240 repeticiones, 4 Niveles de carga con 2,4,6 y 8 caracteres. Frecuencia de muestreo 500 Hz.

Proponer un nuevo enfoque para el aprendizaje de representaciones de series de tiempo de EEG multicanal y mostrar sus ventajas en el contexto en tareas de clasificación de carga mental.

- La tarea de clasificación de carga mental consiste en reconocer la capacidad de memoria de los sujetos evaluados.

- **Introducción**
- **Redes neuronales profundas**
 - **Convolutacional**
 - **Recurrente**
- **Metodología**
- **Resultados**
- **Conclusiones**

- **Aprendizaje profundo:** es un conjunto de algoritmos de aprendizaje automático que intentan modelar abstracciones de alto nivel en datos usando arquitecturas compuestas de transformaciones no-lineales [Bengio et al.,2013].

- **Definición formal** [Storcheus,2015]: Sea $S = ((x_1, c_1), \dots, (x_m, c_m))$ un conjunto de datos etiquetados, un método de aprendizaje profundo es una familia de funciones no lineales \mathcal{F} , tal que:

$$\mathcal{F}(S) = (f_n(\dots f_0(S)) \dots) = ((y_1, c_1), \dots, (y_m, c_m))$$

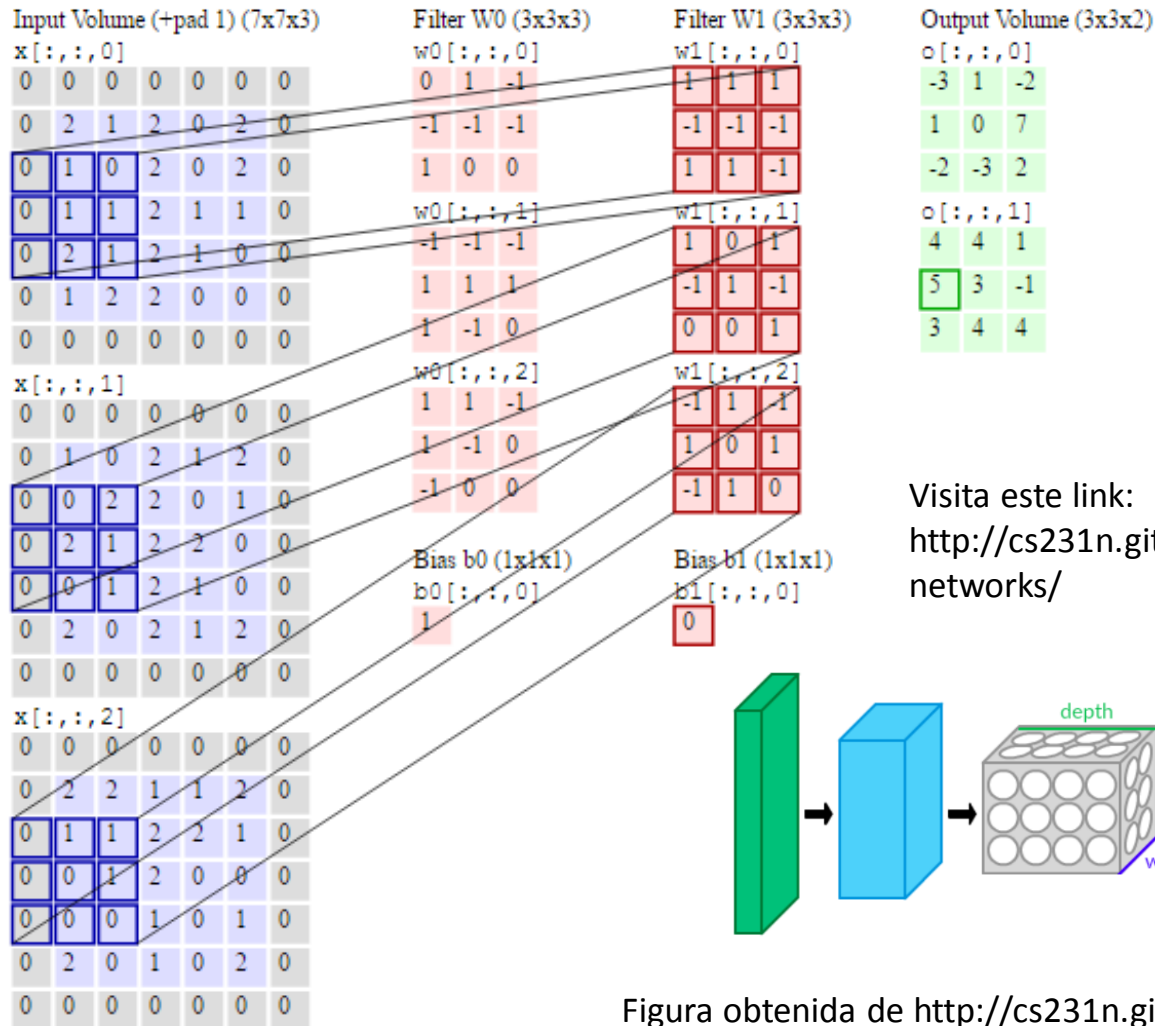
- donde $f_i: H_i \rightarrow H_{i+1}$ y H_i es la representación de la capa i -ésima.

- *Convolutional Neural Network* (CNN) [GoodFellow,2016] es una variante de una red neural perceptrón multicapa y está biológicamente inspirado en la corteza visual de los animales.
- Dos tipos de capas [GoodFellow,2016]:

1. Capa de convolución: un mapa de características h_k es obtenido en esta capa. Este mapa es el resultado de la convolución de una entrada y un filtro lineal, seguido de una transformación no lineal. La entrada en esta capa es puede ser una imagen sin procesamiento o un mapa de características de una capa previa. Un mapa de características es definido como:

$$h^k = \tanh((W^k * x)_{ij} + b_k)$$

2. Max-pooling: esta capa puede ser vista como una disminución de resolución no lineal. Una función de *pooling* reemplaza la salida de la red en cierta locación o región con un resumen estadístico de salidas cercanas, es decir, el elemento máximo o promedio.



Visita este link:
<http://cs231n.github.io/convolutional-networks/>

Figura obtenida de <http://cs231n.github.io/convolutional-networks/>




Figura obtenida de <http://cs231n.github.io/convolutional-networks/>



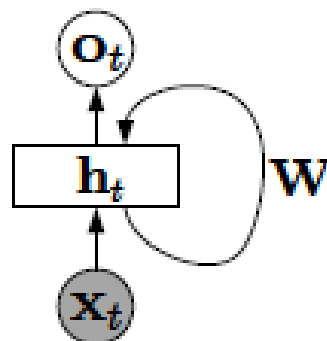


Figura obtenida de <http://www.rsipvision.com/wp-content/uploads/2015/04/Slide7.png>

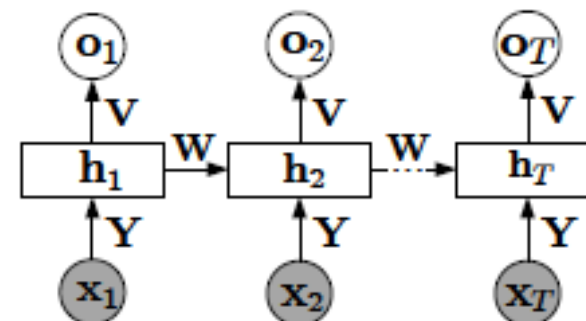


Red *Feedforward*

$$h_t = V\phi(Wx)$$



Red Neuronal Recurrente



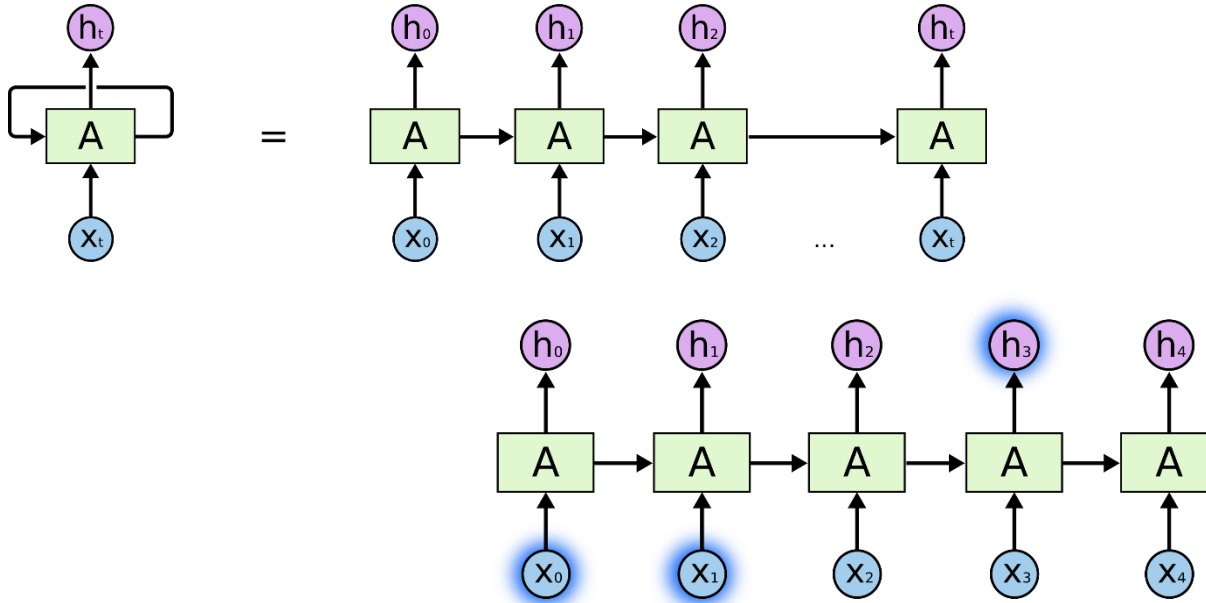
Red Neuronal Recurrente
desenrollada

$$a_t = Wh_{t-1} + Yx_t + b$$


$$h_t = \tanh(a_t)$$

$$o_t = Vh_t + c$$

Dependencias a largo plazo



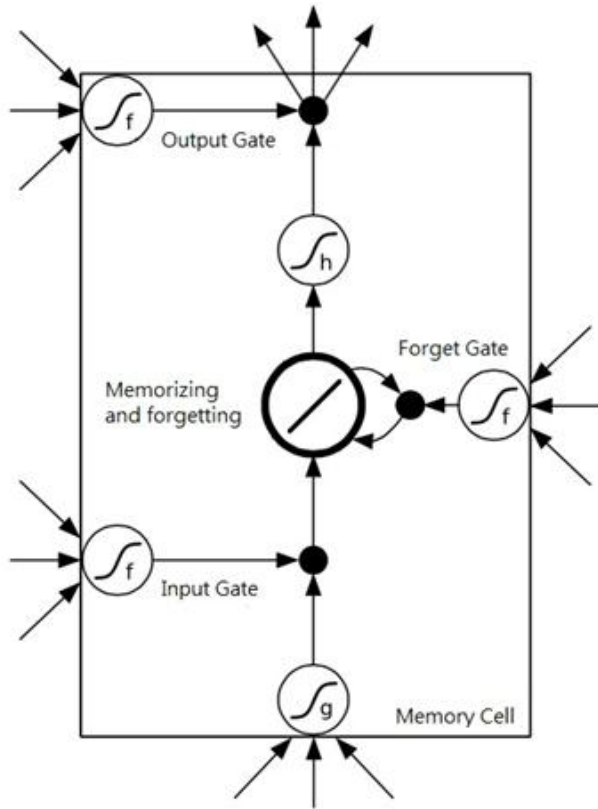
- Usualmente fue usado Retro-propagación a través del tiempo para el entrenamiento de estas redes.
- **Problema:** El error retro-propagado en la etapa aprendizaje para largos periodos de tiempo se vuelve cero (*Vanish gradient*).



Figuras tomada de <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

Red neuronal propuesta por S. Hochreiter and J. Schmidhuber en 1997.

Celda de Memoria LSTM



[Hochreiter & Schmidhuber, 1997]

Compuerta de olvido:

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

Compuerta de entrada:

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

Estado de la celda:

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

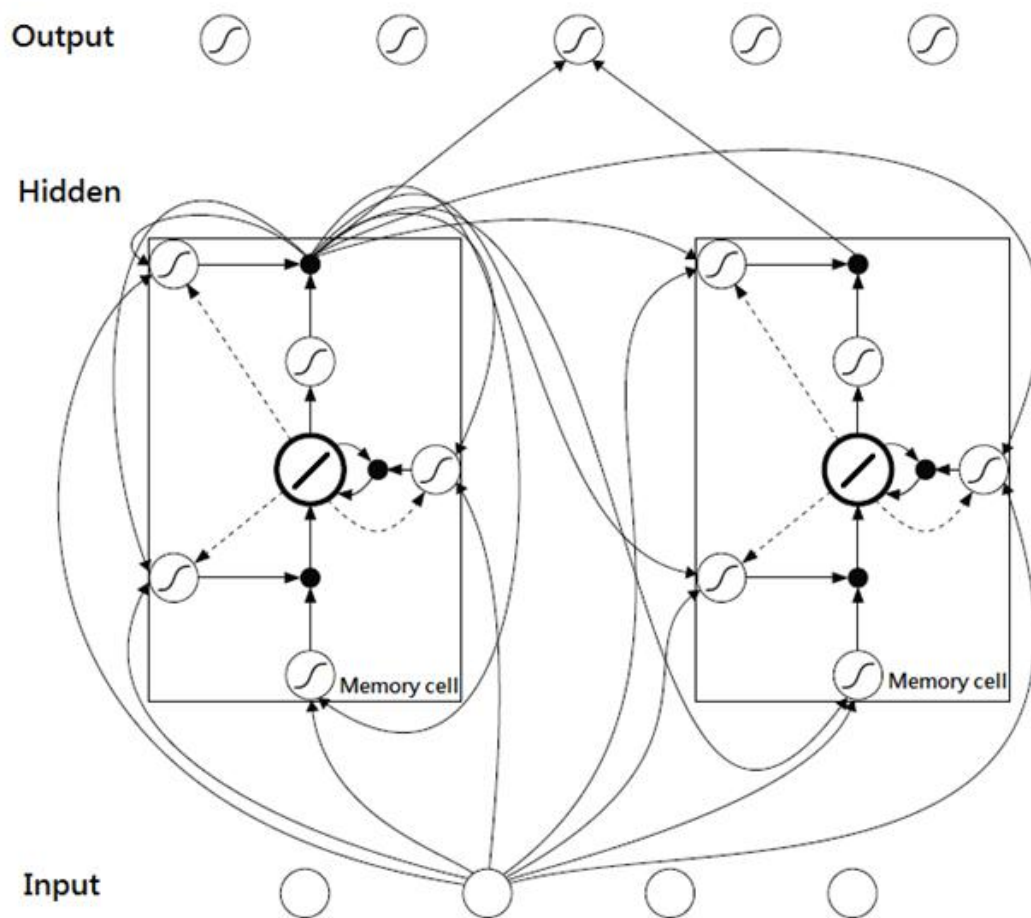
$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Compuerta de salida:

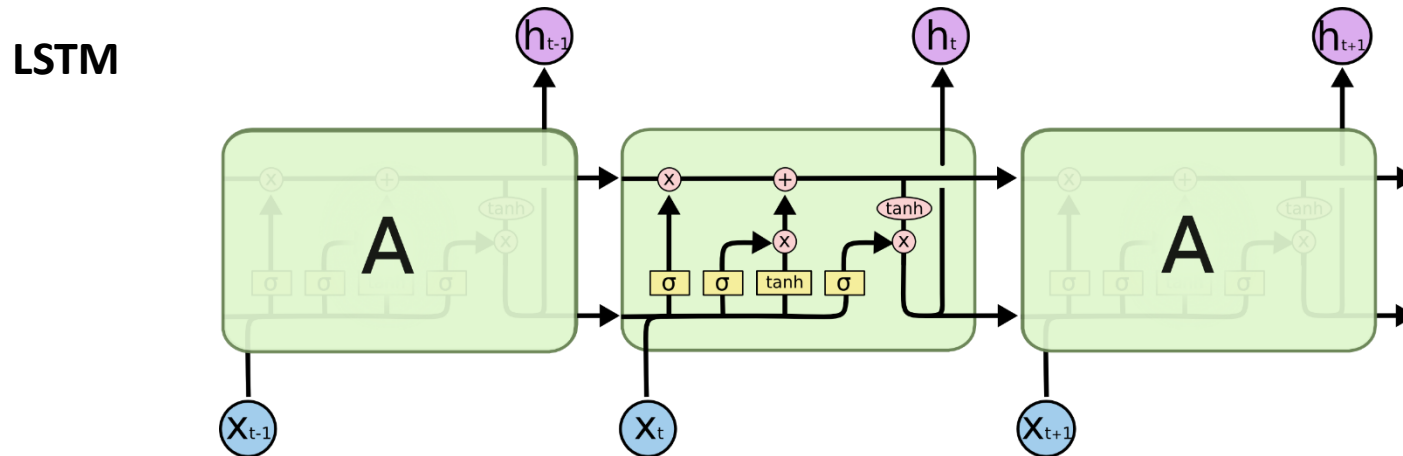

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o)$$

Estado actual de la capa oculta:

$$h_t = o_t * \tanh(C_t)$$





[Hochreiter & Schmidhuber, 1997]




Figuras tomada de <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

LSTM paso a paso




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




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

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$



$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

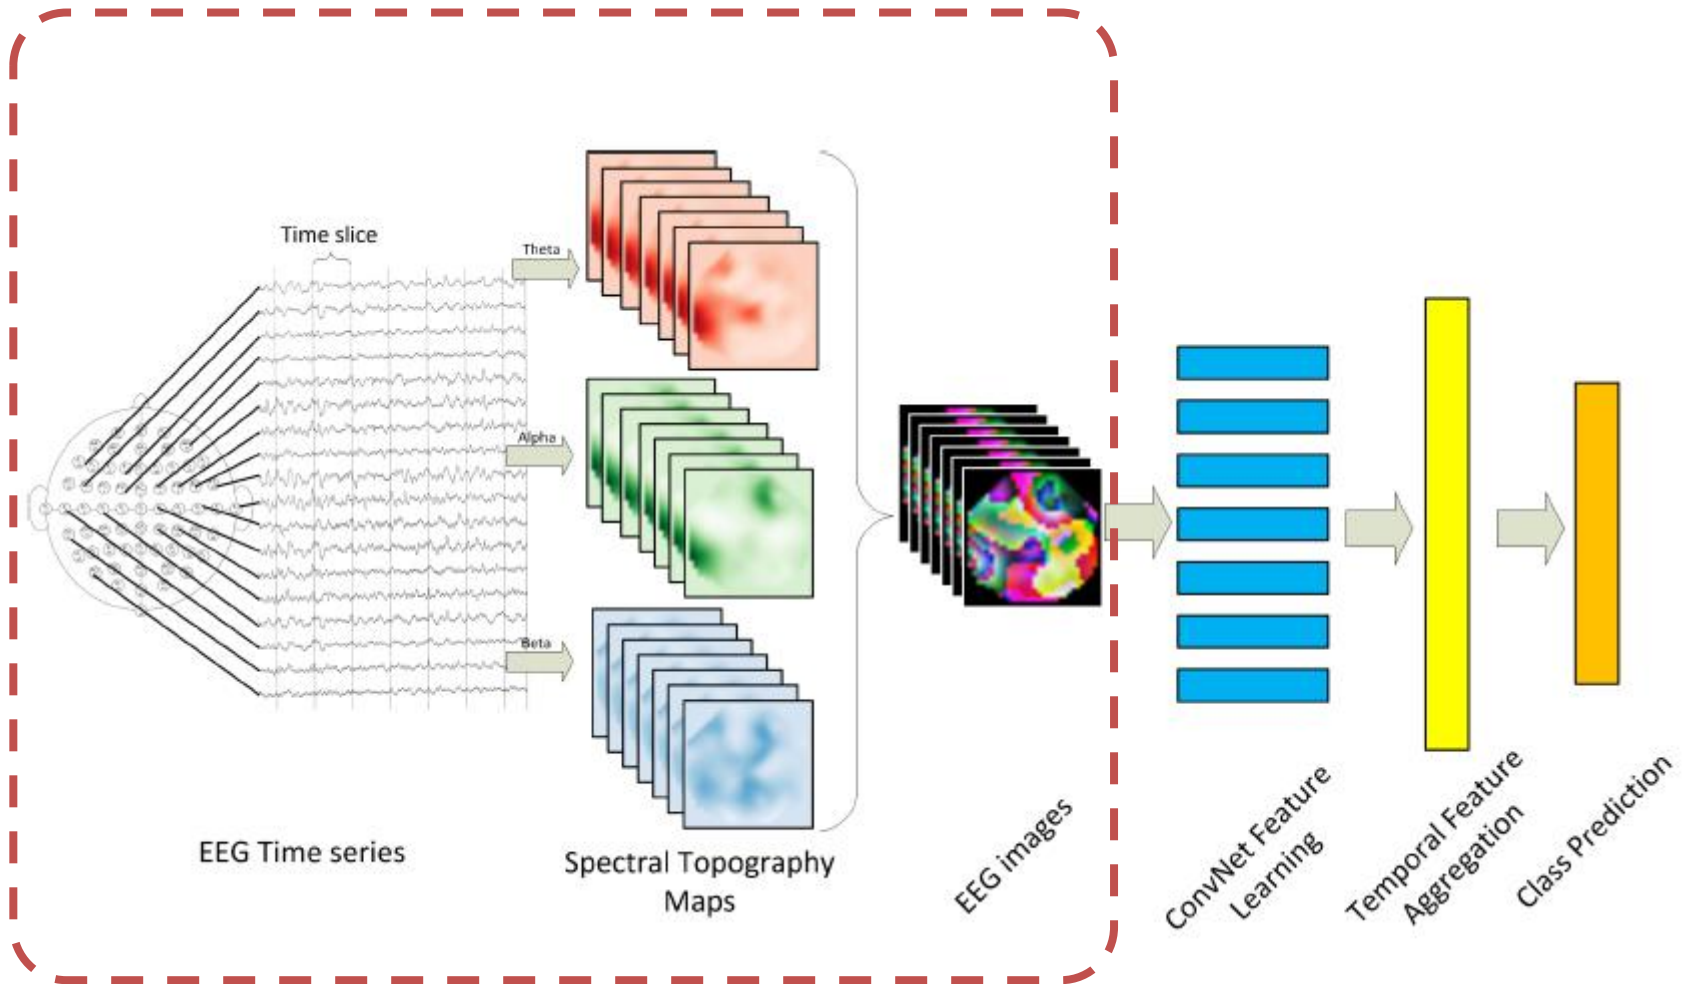


$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$


Figuras tomada de <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>

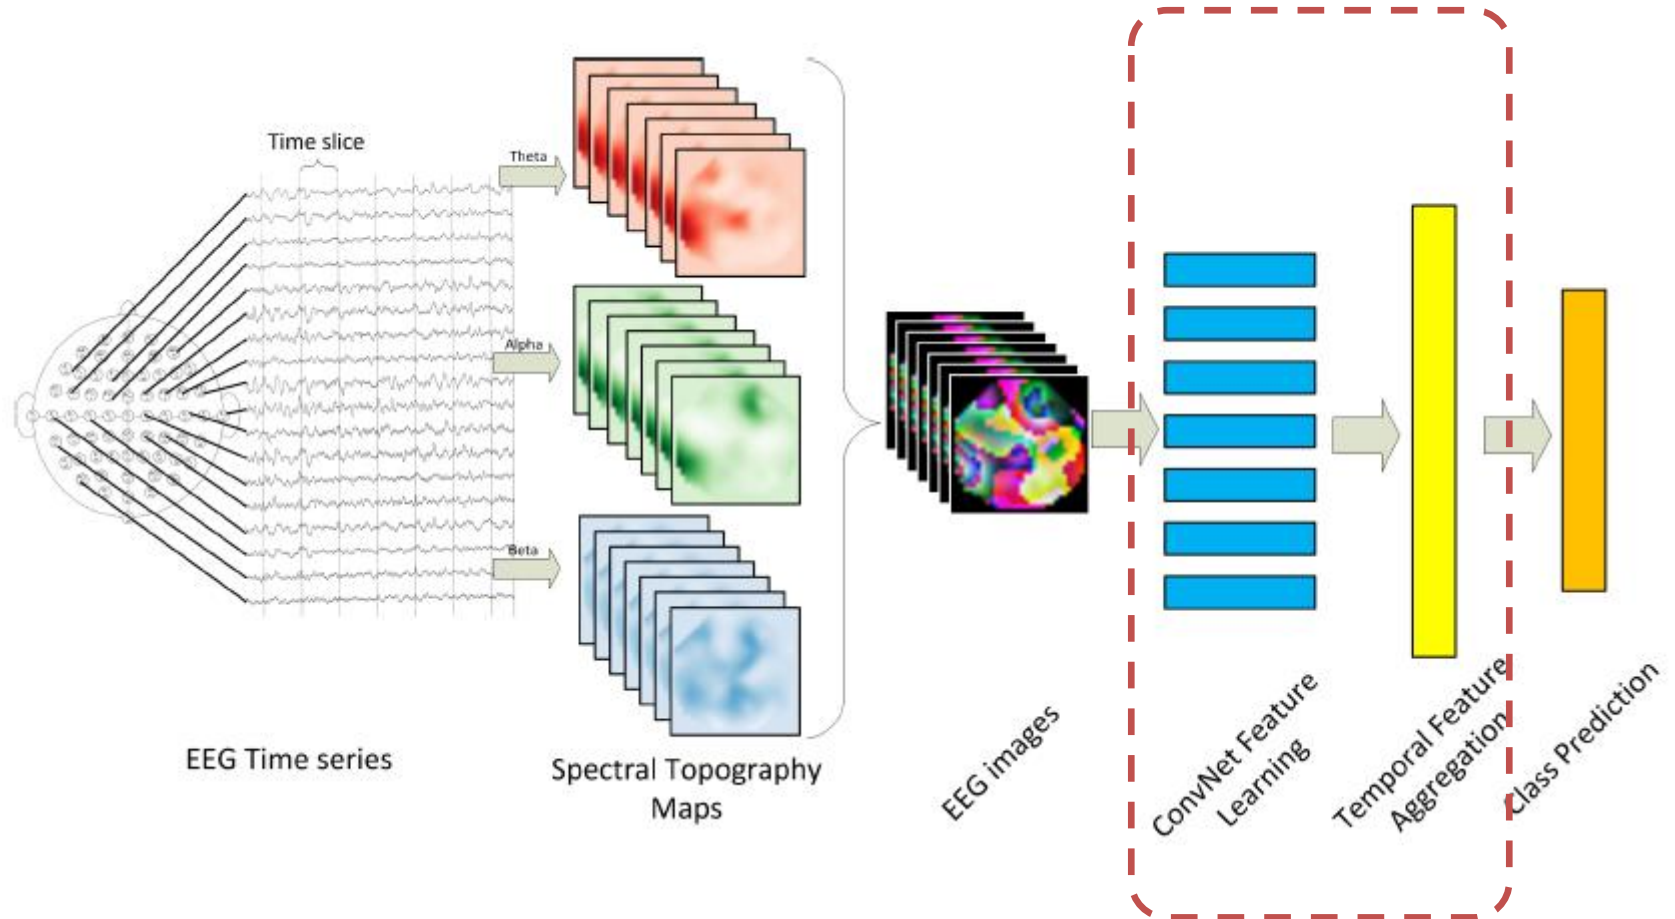
- **Introducción**
- **Redes neuronales profundas**
 - Red Neuronal Convolutacional
 - Red Neuronal Recurrente
- **Metodología**
- **Resultados**
- **Conclusiones**



[Barshivan,2016]

- Las señales de EEG son transformadas en imágenes.
 - Proyectan 64 canales de EEG de 3D a 2D usando *Azimuthal Equidistant Projection* (AEP) [Snyder et al.,1987].
 - Construyen una imagen de 32x32 pixeles con las canales proyectados.
 - Los pixeles faltantes son interpolados.
 - La Transformada rápida de Fourier es aplicada sobre cada canal para estimar su espectro de poder.
 - Tres bandas de frecuencia son exploradas: tetha (4-7 Hz), alpha (8-13Hz) y beta (13-30 Hz).





[Barshivan,2016]

- Se siguieron dos enfoques para el análisis de un ensayo (3.5 s)
 - **Simple:** se construyó una sola imagen para todo el ensayo.
 - **Múltiple:** cada ensayo fue dividido en ventanas de 0.5 s, y se extrajo una imagen por ventana.


- Configuración de red Convolucional
 - Los autores adoptan el trabajo de [Simonyan & Zisserman, 2015].
 - El tamaño de los filtros son de 3x3 pixeles con un paso de 1.
 - Las capas de *Max-pooling* son de tamaño de 2x2 pixeles con un paso de 2.

4 arquitecturas

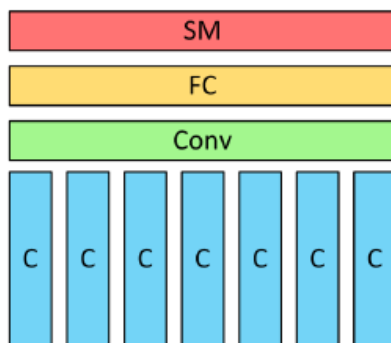
		ConvNet Configurations			
		A	B	C	D
		input (32×32 3-channel image)			
Capas ocultas	1	Conv3-32	Conv3-32	Conv3-32	Conv3-32 Conv3-32 Conv3-32
	2	maxpool			
	3		Conv3-64	Conv3-64	Conv3-64
	4		Conv3-64	Conv3-64	Conv3-64
	5			Conv3-128	Conv3-128
	6			maxpool	
	7		FC-512		
		softmax			

[Barshivan,2016]

A) Maxpool



B) Temporal convolution



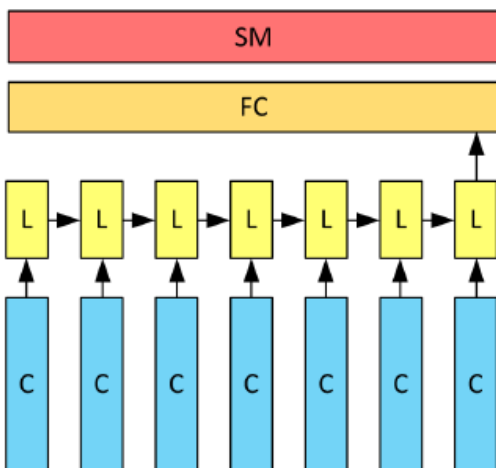
C: 7 capas *ConvNet*

Max: *max-pool*


FC: *Fully conected*

Conv: Convolución temporal 1-D con 16 y 32 filtros de tamaño 3x3.

C) LSTM



D) Mixed LSTM/1DConv



Entrenamiento:

- La función de costo usada en CNN fue Cross-entropy con *Stochastic Gradient Descent*.
- El algoritmo Adam fue usado para LSTM [Kigima & Ba, 2015].

[Barshivan,2016]

- **Introducción**
- **Redes profundas**
 - Red Neuronal Convolutacional
 - Red Neuronal Recurrente
- **Metodología**
- **Resultados**
- **Conclusiones**

Model	Number of parameters	Test Error (%)
RBF SVM	-	14.68
L1- Logistic Regression	-	14.55
Random Forest	-	14.44
DBN	428k	13.59
ConvNet Arch. A	10k	13.05
ConvNet Arch. B	65.5k	13.17
ConvNet Arch. C	139.4k	13.91
ConvNet Arch. D	158k	12.39

[Barshivan,2016]

Architecture	Test Error (%)	Validation Error (%)	Number of parameters
RBF SVM	15.34	-	-
L1-Logistic Regression	15.32	-	-
Random Forest	12.59	-	-
DBN	14.96	8.37	1.02 mil
ConvNet+Maxpool	14.80	8.48	1.21 mil
ConvNet+1D-Conv	11.32	9.28	441 k
ConvNet+LSTM	10.54	6.10	1.34 mil
ConvNet+LSTM/1D-Conv	8.89	8.39	1.62 mil

[Barshivan,2016]

- **Introducción**

- **Definiciones**
 - Red Neuronal Convolutacional

 - Red Neuronal Recurrente

- **Metodología**

- **Resultados**

- **Conclusiones**

- Proponen una nueva metodología para el aprendizaje de representaciones de señales de EEG y muestran sus ventajas en el contexto de tareas de clasificación de cargas mentales (4 niveles de memoria).
- Los autores transforman los datos en una secuencia de imágenes multi-espectrales para preservar la información espacial de los canales de EEG. Posteriormente, adicionan características temporales a la representación final.
- El enfoque propuesto muestra una mejora en la exactitud de la clasificación con respecto a clasificadores del estado del arte.

¡Gracias!, ¿preguntas?

[Barshivan et al.,2016] P.Barshivan, I. Rish, M. Yeasin, N. Coedella. Learning representations from EEG with Deep Recurrent-Convolutional Neural Networks. ICLR 2016.

[Bengio et al., 2013] Bengio, Y., Courville, A., and Vincent, P. (2013). Representation learning: A review and new perspectives. IEEE Trans. Pattern Anal. Mach. Intell., 35(8):1798–1828.

[Goodfellow et al.,2016] Ian Goodfellow Yoshua Bengio and Aaron Courville. Deep learning. Book in preparation for MIT Press, 2016.

[LeCun et al., 2015] LeCun, Y., Bengio, Y., and Hinton, G. (2015a). Deep learning. Nature, 521:436 –444.

[Hochreiter & Schmidhuber, 1997] Hochreiter, Sepp, and Jürgen Schmidhuber. "Long short-term memory." Neural computation 9.8 (1997): 1735-1780.

[Kingma & Ba, 2015] Kingma, Diederik P. and Ba, Jimmy Lei. Adam: a Method for Stochastic Optimization. International Conference on Learning Representations, pp. 1–13, 2015.

[Martínez Montes, 2009] Martínez Montes, E. (2009). Caracterización Espacio- Tiempo- Frecuencia de la actividad eléctrica de redes neuronales. PhD thesis.

[Mirowski et al., 2009] Mirowski, P., Madhavan, D., LeCun, Y., and Kuzniecky, R. (2009). Classification of patterns of fEEG synchronization for seizure prediction. *Clinical Neurophysiology*, 120(11):1927 –1940.

[Varsavsky et al. 2011] ANDREA Varsavsky, IVEN Mareels, and MARK Cook. *Epileptic seizures and the eeg*, 2011.

[Storcheus et al., 2015] Storcheus, D., Rostamizadeh, A., and Kumar, S. (2015). A survey of modern questions and challenges in feature extraction. In *Proceedings of The 1st International Workshop on ?Feature Extraction: Modern Questions and Challenges?*, NIPS, pages 1–18.