

# Fundamentos de Aprendizaje Automático y Reconocimiento de Patrones

## Actividades en clase: Práctico 5

Graciana Castro, Martín Schmidt, Federico Lecumberry, Guillermo Carbajal

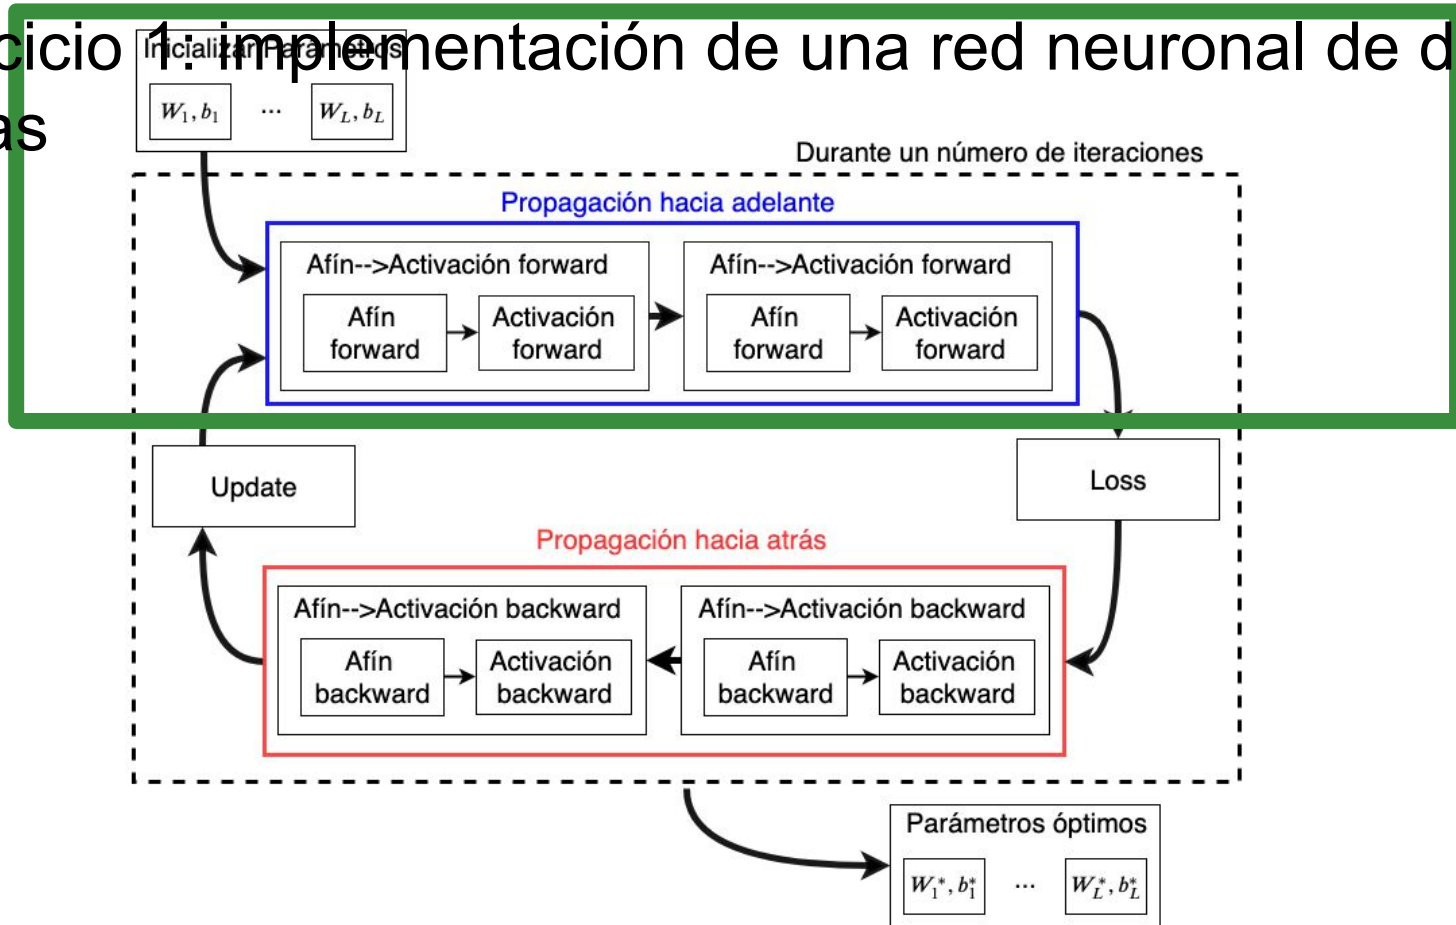
Instituto de Ingeniería Eléctrica

2024

# Tabla de contenido

- Ejercicio 1: implementación de una red neuronal de dos capas
  - Semana pasada: inicialización de pesos y feed forward
  - **Para hoy: funciones de costo y backpropagation**
  
- Ejercicio 2: Jugando con Tensorflow playground

# Ejercicio 1: implementación de una red neuronal de dos capas



# Funciones de costo

Entropía cruzada: **problemas de clasificación binaria**


$$H(\mathbf{x}^{(L)}, \mathbf{y}) = -\frac{1}{N} \sum_{n=1}^N \left( y_n \log x_n^{(L)} + (1 - y_n) \log (1 - x_n^{(L)}) \right)$$

MSE: **problemas de**

$$\text{MSE}(\mathbf{x}^{(L)}, \mathbf{y}) = \frac{1}{2N} \sum_{n=1}^N \left( y_n - x_n^{(L)} \right)^2$$

# Backpropagation

Objetivo: minimizar el error respecto a los parámetros.



$$\frac{\partial e(\mathbf{w})}{\partial w_{ij}^{(l)}} = \frac{\partial e(\mathbf{w})}{\partial s_j^{(l)}} \frac{\partial s_j^{(l)}}{\partial w_{ij}^{(l)}}$$

The diagram shows the chain rule for the derivative of the error with respect to the weight  $w_{ij}^{(l)}$ . The derivative is expressed as the product of the derivative of the error with respect to the input  $s_j^{(l)}$  and the derivative of  $s_j^{(l)}$  with respect to the weight  $w_{ij}^{(l)}$ . The derivative  $\frac{\partial s_j^{(l)}}{\partial w_{ij}^{(l)}}$  is shown to be equal to  $x_i^{(l-1)}$ . The derivative  $\frac{\partial e(\mathbf{w})}{\partial s_j^{(l)}}$  is shown to be equal to  $\delta_j^{(l)}$ .

En el ejercicio: **cache** del forward

# Cálculo del delta

Uno de ellos es fácilmente calculable:

$$\delta_1^{(L)} = \frac{\partial e_n(\mathbf{w})}{\partial s_1^{(L)}}$$

$$= \frac{\partial}{\partial s_1^{(L)}} \left( x_1^{(L)} - y_n \right)^2$$


$$= 2 \left( x_1^{(L)} - y_n \right) \frac{\partial x_1^{(L)}}{\partial s_1^{(L)}}$$

$$= 2 \left( x_1^{(L)} - y_n \right) \theta' \left( s_1^{(L)} \right)$$

Donde:

$$x_1^{(L)} = \theta \left( s_1^{(L)} \right)$$

y suponiendo MSE.

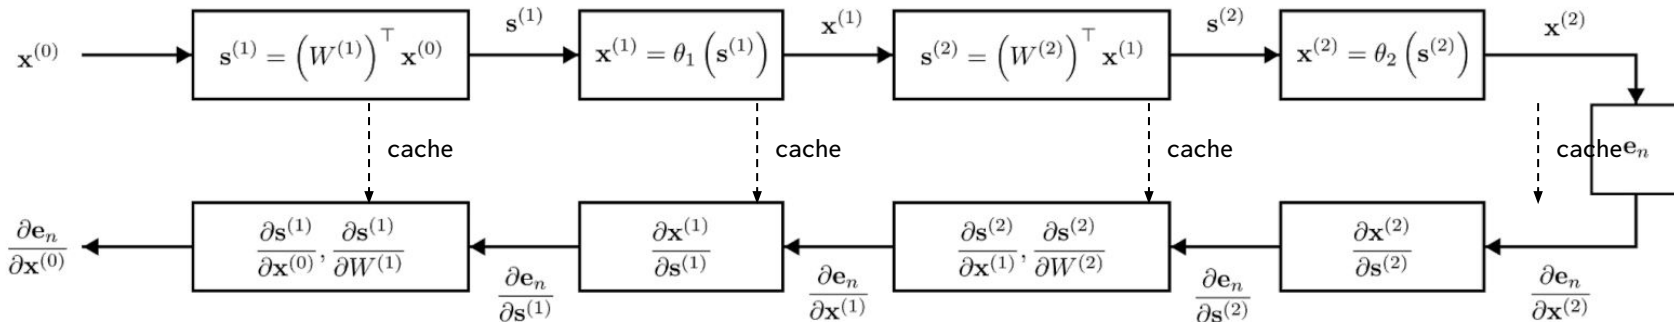


**Derivada de la función de activación**

# Ejercicio 1: implementación de una red neuronal de dos

Forward  $\longrightarrow$

$$\mathbf{x} = \mathbf{x}^{(0)} \xrightarrow{W^{(1)}} \mathbf{s}^{(1)} \xrightarrow{\theta} \mathbf{x}^{(1)} \xrightarrow{W^{(2)}} \mathbf{s}^{(2)} \xrightarrow{\theta} \mathbf{x}^{(2)} \dots \longrightarrow \mathbf{s}^{(L)} \xrightarrow{\theta} \mathbf{x}^{(L)} = h(\mathbf{x})$$



$$\delta^{(1)} \longleftarrow \delta^{(2)} \dots \longleftarrow \delta^{(L-1)} \longleftarrow \delta^{(L)} \longleftarrow \text{Backward}$$

# Implementación:

Forward: Afín → Activación

Backward: ~~Activación~~ → Afín

$$dS^{(l)} = dX^{(l)} \theta'(S^{(l)})$$

$$\frac{\partial E}{\partial W^{(l)}} = dW^{(l)} = \left(X^{(l-1)}\right)^T dS^{(l)}$$

$$\frac{\partial E}{\partial \mathbf{b}^{(l)}} = d\mathbf{b}^{(l)} = \mathbf{1}^T dS^{(l)}$$

$$\frac{\partial E}{\partial X^{(l-1)}} = dX^{(l-1)} = dS^{(l)} \left(W^{(l)}\right)^T$$



# Actualización de los parámetros

Utilizando **Descenso por gradiente**:

$$W^{(l)} = W^{(l)} - \eta dW^{(l)}$$

$$\mathbf{b}^{(l)} = \mathbf{b}^{(l)} - \eta d\mathbf{b}^{(l)}$$

# Ejercicio 1: repaso final completo

