



# Tópicos en Inteligencia Artificial Deep Learning

## Inicialización

Basado en el [ppt 07a – Initialization](#) de  
Prof. Simon Prince  
Adaptado por Prof. Fernando Crema García



# Inicialización


- Necesidad de inicialización
- Inicialización **He**
- Interludio: Valores esperados
- Demostrar que  $\mathbb{E}[f'_i] = 0$
- Escribir la varianza de las preactivaciones  $f'$  en términos de las activations  $h$  en la capa anterior

$$\sigma_{f'}^2 = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E} [h_j^2]$$

- Escribir la varianza de las preactivaciones  $f'$  en términos de las preactivaciones  $f$  de la capa anterior

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

# Inicialización



- Consideremos el bloque de construcción estándar de la red neuronal en términos de preactivaciones:

$$\begin{aligned} f_k &= \beta_k + \Omega_k h_k \\ &= \beta_k + \Omega_k a[f_{k-1}] \end{aligned}$$

¿a?

- RelU
- tanh
- $N(, )$

- ¿Cómo inicializamos los sesgos y los pesos?
- Equivalente a elegir el punto de partida en los modelos de regresión Gabor/Lineal

# Inicialización

- Considere el bloque de construcción estándar de red neuronal en términos de *preactivaciones*:

$$\begin{aligned} \mathbf{f}_k &= \beta_k + \Omega_k \mathbf{h}_k \\ &= \beta_k + \Omega_k a[\mathbf{f}_{k-1}] \end{aligned}$$

- Fijar todos los sesgos a 0

$$\beta_k = 0$$

- Pesos distribuidos normalmente
  - media 0
  - Varianza  $\sigma_{\Omega}^2$

$$\mathcal{L}_k \sim N(\mathbf{0}, \Omega)$$

- ¿Qué ocurrirá a medida que avancemos por la red si  $\sigma_{\Omega}^2$  es muy pequeña?
- ¿Qué ocurrirá a medida que avancemos por la red si  $\sigma_{\Omega}^2$  es muy grande?

# Resumen del backprop

**Backward pass:** We start with the derivative  $\partial \ell_i / \partial \mathbf{f}_K$  of the loss function  $\ell_i$  with respect to the network output  $\mathbf{f}_K$  and work backward through the network:

$$\begin{aligned}
 \frac{\partial \ell_i}{\partial \beta_k} &= \frac{\partial \ell_i}{\partial \mathbf{f}_k} & k \in \{K, K-1, \dots, 1\} \\
 \frac{\partial \ell_i}{\partial \Omega_k} &= \frac{\partial \ell_i}{\partial \mathbf{f}_k} \mathbf{n}_k^T & k \in \{K, K-1, \dots, 1\} \\
 \frac{\partial \ell_i}{\partial \mathbf{f}_{k-1}} &= \mathbb{I}[\mathbf{f}_{k-1} > 0] \odot \left( \Omega_k^T \frac{\partial \ell_i}{\partial \mathbf{f}_k} \right), & k \in \{K, K-1, \dots, 1\} \tag{7.13}
 \end{aligned}$$

*Relu*

where  $\odot$  denotes pointwise multiplication and  $\mathbb{I}[\mathbf{f}_{k-1} > 0]$  is a vector containing ones where  $\mathbf{f}_{k-1}$  is greater than zero and zeros elsewhere. Finally, we compute the derivatives with respect to the first set of biases and weights:

$$\begin{aligned}
 \frac{\partial \ell_i}{\partial \beta_0} &= \frac{\partial \ell_i}{\partial \mathbf{f}_0} \\
 \frac{\partial \ell_i}{\partial \Omega_0} &= \frac{\partial \ell_i}{\partial \mathbf{f}_0} \mathbf{x}_i^T
 \end{aligned}$$

# Inicialización

- Necesidad de inicialización
- Inicialización He  $\rightarrow R \subset L \cup$
- Interludio: Valores esperados
- Demostrar que  $\mathbb{E}[f'_i] = 0$
- Escribir la varianza de las preactivaciones  $f'$  en términos de las activations  $h$  en la capa anterior

$$\sigma_{f'}^2 = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E} [h_j^2]$$

- Escribir la varianza de las preactivaciones  $f'$  en términos de las preactivaciones  $f$  de la capa anterior

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

$$(x_1, x_2, \dots, x_{100})$$

# Inicialización de los pesos

Paso hacia adelante  
*Forward pass*




Figura 7.7

Setup

1) Número de capas  $k = 50$

2) Número de neuronas por capa  $D_h = 100$

3) El vector de entrada

$$X \sim N(0, 1)^{100} = \begin{bmatrix} N(0, 1) \\ \vdots \\ N(0, 1) \end{bmatrix}$$


4) El vector de salida es fijo con  $Y = [0]^{100} = \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}$

5) El vector de sesgo  $\beta_k = [0]^{100} = \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}$

6) La matriz de pesos

$$\Omega_k \sim N(0, 1)^{100 \times 100} = \begin{bmatrix} N_{1,1}(0, \sigma_\Omega^2) & \cdots & N_{1,100}(0, \sigma_\Omega^2) \\ \vdots & \ddots & \vdots \\ N_{100,0}(0, \sigma_\Omega^2) & \cdots & N_{100,100}(0, \sigma_\Omega^2) \end{bmatrix}$$


7) Las varianzas  $\sigma_\Omega^2 \in \{0.001, 0.01, 0.02, 0.1, 1\}$





$$101 \approx 101$$

# Inicialización de los pesos

Paso hacia adelante  
*Forward pass*



Paso hacia atrás  
*(backward pass)*



- Gradientes explotados
- Gradientes desvanecen

# Inicialización He (asume ReLU como activación)

- Paso hacia adelante: desea que la varianza de las activaciones de la unidad oculta en la capa  $k+1$  sea la misma que la varianza de las activaciones en la capa  $k$ :

$$\frac{2}{100} = 0 \cdot D_2$$

$$\sigma_{\Omega}^2 = \frac{2}{D_h}$$



Número de unidades en la capa  $k$

- Paso hacia atrás: se desea que la varianza de los gradientes en la capa  $k$  sea la misma que la varianza del gradiente en la capa  $k+1$ :

$$\sigma_{\Omega}^2 = \frac{2}{D_{h'}}$$

Número de unidades en la capa  $k+1$

# Inicialización de los pesos



Fíjense cómo para  $\sigma_{\Omega}^2 = 0.02$  en la línea gris para ambos pasos los valores son estables

# Inicialización

- Necesidad de inicialización
- Inicialización **He**
- Interludio: Valores esperados
- Demostrar que  $\mathbb{E}[f'_i] = 0$
- Escribir la varianza de las preactivaciones  $f'$  en términos de las activations  $h$  en la capa anterior



$$\sigma_{f'}^2 = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E} [h_j^2]$$

- Escribir la varianza de las preactivaciones  $f'$  en términos de las preactivaciones  $f$  de la capa anterior

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

$$f(x) = 1$$

## Valores esperados



$$\mathbb{E}[g[x]] = \int g[x] Pr(x) dx,$$



Interpretación: ¿Cuál es el valor medio de  $g[x]$  teniendo en cuenta la probabilidad de  $x$ ?

Podría aproximarse, muestreando muchos valores  $\text{de } x$  de la distribución, calculando  $g[x]$ , y tomando la media:

$$\left\{ \begin{array}{l} f(x) = F(b) - F(a) \\ \int_a^b F.D.A \end{array} \right. \Rightarrow \int_a^b f(x) dx = 0$$

$$\mathbb{E}[g[x]] \approx \frac{1}{N} \sum_{n=1}^N g[x_n^*]$$

where  $x_n^* \sim Pr(x)$

$$\begin{aligned} P(a < x < b) &= F(b) - F(a) \\ E(x) &= \left\{ \begin{array}{l} \sum x \cdot P(x=x) \\ \forall x \in \mathbb{R}_x \\ \int_{-\infty}^{\infty} x \cdot f(x). dx \end{array} \right. \end{aligned}$$



# Valores esperados

$$\underline{\mathbb{E}}[\underline{g}[\underline{x}]] = \int g[x] Pr(x) dx,$$

Interpretación: ¿Cuál es el valor medio de  $g[x]$  teniendo en cuenta la probabilidad de  $x$ ?

Podría aproximarse, muestreando muchos valores de  $x$  de la distribución, calculando  $g[x]$ , y tomando la media:

$$\mathbb{E}[g[x]] \approx \frac{1}{N} \sum_{n=1}^N g[x_n^*] \quad \text{where} \quad x_n^* \sim Pr(x)$$

E.CDF

# Valores esperados

$$\mu = E[x]$$

$$x^k = E[x^k] = E[x^k - \bar{x}]$$

$$V(x) = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx$$

Function $g[\bullet]$	Valor esperado
$x$	media, $\mu$
$x^k$	$k$ - ésmo momento alrededor de cero
$(x - \mu)^k$	$k$ - ésmo momento alrededor de la media
$(x - \mu)^2$	varianza
$(x - \mu)^3$	Asimetría (skew)
$(x - \mu)^4$	Curtosis (kurtosis)

# Propiedades para manipular Valores esperados

$$\mathbb{E}[k] = k$$

$$\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$$

$$\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$$

$$\mathbb{E}[f[x]g[y]] = \mathbb{E}[f[x]]\mathbb{E}[g[y]] \quad \text{if } x, y \text{ independent}$$

# Regla 1

$$\sum_{i=1}^N a_i f(i) = a \sum f(i)$$

$$\mathbb{E}[g[x]] = \int g[x] Pr(x) dx,$$

---

$$\begin{aligned}\mathbb{E}[\underline{\kappa}] &= \int \kappa Pr(x) dx \\ &= \kappa \int_0^\infty Pr(x) dx \\ &= \kappa.\end{aligned}$$

## Regla 2

$$\mathbb{E}[g[x]] = \int g[x]Pr(x)dx,$$

---

$$\begin{aligned}\mathbb{E}[\kappa \cdot g[x]] &= \int \kappa \cdot \textcircled{g[x]} Pr(x)dx \\ &= \kappa \cdot \int g[x] Pr(x)dx \\ &= \kappa \cdot \underline{\mathbb{E}[g[x]]}\end{aligned}$$


## Regla 3

$$g(x) = f(x) + \epsilon(x)$$

$$\mathbb{E}[g[x]] = \int g[x] Pr(x) dx,$$

$$\begin{aligned}\mathbb{E}[f[x] + g[x]] &= \int (f[x] + g[x]) \cancel{Pr(x) dx} \quad f(x) \\ &= \int (f[x] Pr(x) + g[x] Pr(x)) dx \\ &= \int f[x] Pr(x) dx + \int g[x] Pr(x) dx \\ &= \mathbb{E}[f[x]] + \mathbb{E}[g[x]]\end{aligned}$$


# Independencia



( $x, y$ )

↓  $x|y = \frac{f(x|y)}{f_y(y)}$

$$Pr(x|y = y_1)$$



$$f(x|y = y_1)$$

$$Pr(x|y = y_2)$$



$$P(A|B)$$


Probabilidad de x e y

$$\begin{aligned} Pr(x|y) &= Pr(x) \\ Pr(y|x) &= Pr(y) \end{aligned}$$

# Independencia

$$N(0, 1)^{100} = \prod_{i=1}^{100} N(0, 1)$$

$$Pr(x, y)$$




$$Pr(x|y = y_1)$$

$$Pr(x|y = y_2)$$

$$Pr(x, y) = \underbrace{Pr(x)}_{\text{Probabilidad de } x} \underbrace{Pr(y)}_{\text{Probabilidad de } y}$$

Probabilidad de x e y

## Regla 4



$$\mathbb{E}[g[x]] = \int g[x] Pr(x) dx,$$

---

$$\begin{aligned}\mathbb{E}[f[x] \cdot g[y]] &= \int \int f[x] \cdot g[y] Pr(x, y) dx dy \\ &= \int \int f[x] \cdot g[y] Pr(x) Pr(y) dx dy \\ &= \int f[x] Pr(x) dx \int g[y] Pr(y) dy \\ &= \mathbb{E}_x[f[x]] \mathbb{E}_y[g[y]]\end{aligned}$$

if  $x, y$  independent

Porque  
independientes

Ahora probemos:

$$\mathbb{E}[(x - \mu)^2] = \mathbb{E}[x^2] - \mathbb{E}[x]^2$$

Teniendo en cuenta:

$$\mathbb{E}[x] = \mu$$

Ahora probemos:

$$\mathbb{E}[(x - \mu)^2] = \mathbb{E}[x^2] - \mathbb{E}[x]^2$$

Teniendo en cuenta:

$$\mathbb{E}[x] = \mu$$

$$\text{Regla 1: } \mathbb{E}[k] = k$$

$$\text{Regla 2: } \mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$$

$$\text{Regla 3: } \mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$$

$$\text{Definición } \mathbb{E}[x] = \mu$$

$$\boxed{\mathbb{E}[(x - \mu)^2]} = \mathbb{E}[x^2 - 2x\mu + \mu^2]$$

$$g(x) = (x - \mu)^2$$

Regla 1:  $\mathbb{E}[k] = k$

Regla 2:  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$

Regla 3:  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$

Definición  $\mathbb{E}[x] = \mu$

$g(x) = -h(x)$

$$\begin{aligned}\mathbb{E}[(x - \mu)^2] &= \mathbb{E}[x^2 - 2x\mu + \mu^2] \\ &= \mathbb{E}[x^2] - \mathbb{E}[2x\mu] + \mathbb{E}[\mu^2]\end{aligned}$$

Regla 1:	$\mathbb{E}[k] = k$	
Regla 2:	$\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$	
Regla 3:	$\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$	
Definición	$\mathbb{E}[x] = \mu$	

$$\begin{aligned}
 \mathbb{E}[(x - \mu)^2] &= \mathbb{E}[x^2 - 2x\mu + \mu^2] \\
 &= \mathbb{E}[x^2] - \mathbb{E}[2x\mu] + \mathbb{E}[\mu^2] \\
 &= \mathbb{E}[x^2] - \textcircled{2}\mu\mathbb{E}[x] + \mu^2
 \end{aligned}$$

Regla 1:  $\mathbb{E}[k] = k$

Regla 2:  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$

Regla 3:  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$

Definición  $\mathbb{E}[x] = \mu$



$$\begin{aligned}\mathbb{E}[(x - \mu^2)] &= \mathbb{E}[x^2 - 2x\mu + \mu^2] \\&= \mathbb{E}[x^2] - \mathbb{E}[2x\mu] + \mathbb{E}[\mu^2] \\&= \mathbb{E}[x^2] - 2\mu\mathbb{E}[x] + \mu^2 \\&= \mathbb{E}[x^2] - 2\mu^2 + \mu^2\end{aligned}$$

Regla 1:  $\mathbb{E}[k] = k$

Regla 2:  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$

Regla 3:  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$

Definición  $\mathbb{E}[x] = \mu$

$$\begin{aligned}\mathbb{E}[(x - \mu^2)] &= \mathbb{E}[x^2 - 2x\mu + \mu^2] \\&= \mathbb{E}[x^2] - \mathbb{E}[2x\mu] + \mathbb{E}[\mu^2] \\&= \mathbb{E}[x^2] - 2\mu\mathbb{E}[x] + \mu^2 \\&= \mathbb{E}[x^2] - 2\mu^2 + \mu^2 \\&= \mathbb{E}[x^2] - \mu^2\end{aligned}$$

Regla 1:  $\mathbb{E}[k] = k$

Regla 2:  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$

Regla 3:  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$

Definición  $\mathbb{E}[x] = \mu$



$$\begin{aligned}\mathbb{E}[(x - \mu^2)] &= \mathbb{E}[x^2 - 2x\mu + \mu^2] \\&= \mathbb{E}[x^2] - \mathbb{E}[2x\mu] + \mathbb{E}[\mu^2] \\&= \mathbb{E}[x^2] - 2\mu\mathbb{E}[x] + \mu^2 \\&= \mathbb{E}[x^2] - 2\mu^2 + \mu^2 \\&= \mathbb{E}[x^2] - \mu^2 \\&= \boxed{\mathbb{E}[x^2] - E[x]^2}\end{aligned}$$

- 1) V.A  
2)  $\frac{x}{\int f(x)} = \mathbb{R}$   
 $\int x f(x) = E(x)$   
 $\int g(x) f(x) = E(g(x))$   
3) Propri.

# Inicialización

- Necesidad de inicialización
- Inicialización **He**
- Interludio: Valores esperados
- Demostrar que  $\mathbb{E}[f'_i] = 0$
- Escribir la varianza de las preactivaciones  $f'$  en términos de las activations  $h$  en la capa anterior

$$\sigma_{f'}^2 = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E} [h_j^2]$$

- Escribir la varianza de las preactivaciones  $f'$  en términos de las preactivaciones  $f$  de la capa anterior

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

# Inicialización

- Considere el bloque de construcción estándar de red neuronal en términos de *preactivaciones*:

$$\begin{aligned} \mathbf{f}_k &= \beta_k + \Omega_k \mathbf{h}_k \\ &= \beta_k + \Omega_k a[\mathbf{f}_{k-1}] \end{aligned}$$

- Fijar todos los sesgos a 0

$$\rightarrow \beta_k = 0$$

- Pesos distribuidos normalmente

- media 0
- varianza  $\sigma_\Omega^2$

$$N(0, \sigma_\Omega^2)$$

- ¿Qué ocurrirá a medida que avancemos por la red si es muy pequeño?
- ¿Qué ocurrirá a medida que avancemos por la red si es muy grande?

Objetivo: mantener la misma varianza entre dos capas

$$\boxed{f'} = \beta + \underline{\Omega} \underline{h}$$

DD

Considerar la media de las preactivaciones:

$$\mathbb{E}[f'_i] = \mathbb{E} \left[ \beta_i + \sum_{j=1}^{D_h} \Omega_{ij} h_j \right]$$

$$\text{Regla 1: } \mathbb{E}[k] = k$$

$$\text{Regla 2: } \mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$$

$$\text{Regla 3: } \mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$$

$$\text{Regla 4: } \mathbb{E}[f[x]g[y]] = \mathbb{E}[f[x]]\mathbb{E}[g[y]] \quad \text{if } x, y \text{ independent}$$



$$\begin{aligned} \mathbb{E}[f'_i] &= \mathbb{E}\left[\beta_i + \sum_{j=1}^{D_h} \Omega_{ij} h_j\right] = \mathbb{E}[\beta_i] + \mathbb{E}\left[\sum_{j=1}^{D_h} \Omega_{ij} h_j\right] \\ &= \mathbb{E}[\beta_i] + \sum_{j=1}^{D_h} \mathbb{E}[\Omega_{ij} h_j] \end{aligned}$$

$$\text{Regla 1: } \mathbb{E}[k] = k$$

$$\text{Regla 2: } \mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$$

$$\text{Regla 3: } \mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$$

$$\text{Regla 4: } \mathbb{E}[f[x]g[y]] = \mathbb{E}[f[x]]\mathbb{E}[g[y]] \quad \text{if } x, y \text{ independent}$$



$$\mathbb{E}[f'_i] = \mathbb{E} \left[ \beta_i + \sum_{j=1}^{D_h} \Omega_{ij} h_j \right]$$

$$= \mathbb{E}[\beta_i] + \sum_{j=1}^{D_h} \mathbb{E}[\Omega_{ij} h_j]$$

$$= \mathbb{E}[\beta_i] + \sum_{j=1}^{D_h} \mathbb{E}[\Omega_{ij}] \mathbb{E}[h_j]$$

- Regla 1:  $\mathbb{E}[k] = k$
- Regla 2:  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$
- Regla 3:  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$
- Regla 4:  $\mathbb{E}[f[x]g[y]] = \mathbb{E}[f[x]]\mathbb{E}[g[y]]$  if  $x, y$  independent

$$\mathbb{E}[f'_i] = \mathbb{E} \left[ \beta_i + \sum_{j=1}^{D_h} \Omega_{ij} h_j \right]$$

$$= \mathbb{E}[\beta_i] + \sum_{j=1}^{D_h} \mathbb{E}[\Omega_{ij} h_j]$$

Poner todos los sesgos a 0

$$= \mathbb{E}[\beta_i] + \sum_{j=1}^{D_h} \mathbb{E}[\Omega_{ij}] \mathbb{E}[h_j]$$

Ponderaciones distribuidas normalmente

media 0  
varianza  $\sigma_\Omega^2$

$$= 0 + \sum_{j=1}^{D_h} 0 \cdot \mathbb{E}[h_j] = 0$$

# Inicialización

- Necesidad de inicialización
- Inicialización **He**
- Interludio: Valores esperados
- Demostrar que  $\mathbb{E}[f'_i] = 0$
- Escribir la varianza de las preactivaciones  $f'$  en términos de las activations  $h$  en la capa anterior

$$\sigma_{f'}^2 = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E} [h_j^2]$$

- Escribir la varianza de las preactivaciones  $f'$  en términos de las preactivaciones  $f$  de la capa anterior

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2} \quad \leftarrow$$

Objetivo: mantener la misma varianza entre dos capas

$$\mathbf{f}' = \boldsymbol{\beta} + \boldsymbol{\Omega} \mathbf{h}$$

$$\mathbf{h} = \mathbf{a}[\mathbf{f}],$$

$$\sigma_{f'}^2 = \mathbb{E}[f_i'^2] - \mathbb{E}[f_i']^2$$

$$\longrightarrow \mathbb{E}[(x - \mu)^2] = \mathbb{E}[x^2] - \mathbb{E}[x]^2$$

- Regla 1:**  $\mathbb{E}[k] = k$
- Regla 2:**  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$
- Regla 3:**  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$
- Regla 4:**  $\mathbb{E}[f[x]g[y]] = \mathbb{E}[f[x]]\mathbb{E}[g[y]]$  if  $x, y$  independent

$$\begin{aligned}\sigma_{f'}^2 &= \mathbb{E}[f_i'^2] - \mathbb{E}[f_i']^2 \\ &= \mathbb{E} \left[ \left( \beta_i + \sum_{j=1}^{D_h} \Omega_{ij} h_j \right)^2 \right] - 0\end{aligned}$$


Poner todos los sesgos a 0

Ponderaciones distribuidas normalmente

media 0

varianza  $\sigma_\Omega^2$

- Regla 1:**  $\mathbb{E}[k] = k$
- Regla 2:**  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$
- Regla 3:**  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$
- Regla 4:**  $\mathbb{E}[f[x]g[y]] = \mathbb{E}[f[x]]\mathbb{E}[g[y]]$  if  $x, y$  independent

$$\sigma_{f'}^2 = \mathbb{E}[f_i'^2] - \mathbb{E}[f_i']^2$$

$$= \mathbb{E} \left[ \left( \beta_i + \sum_{j=1}^{D_h} \Omega_{ij} h_j \right)^2 \right] - 0$$

$$= \mathbb{E} \left[ \left( \sum_{j=1}^{D_h} \Omega_{ij} h_j \right)^2 \right]$$

Poner todos los sesgos a 0



Ponderaciones distribuidas normalmente

media 0

varianza  $\sigma_\Omega^2$

Regla 1:  $\mathbb{E}[k] = k$

Regla 2:  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$

Regla 3:  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$

Regla 4:  $\mathbb{E}[f[x]g[y]] = \mathbb{E}[f[x]]\mathbb{E}[g[y]]$  if  $x, y$  independent

$$\sigma_{f'}^2 = \mathbb{E}[f_i'^2] - \mathbb{E}[f_i']^2$$

$$= \mathbb{E} \left[ \left( \beta_i + \sum_{j=1}^{D_h} \Omega_{ij} h_j \right)^2 \right] - 0$$

$$= \mathbb{E} \left[ \left( \sum_{j=1}^{D_h} \Omega_{ij} h_j \right)^2 \right]$$

$$\Rightarrow = \sum_{j=1}^{D_h} \mathbb{E} [\Omega_{ij}^2] \mathbb{E} [h_j^2]$$

Poner todos los sesgos a 0

Ponderaciones distribuidas normalmente  
media 0  
varianza  $\sigma_\Omega^2$

- Regla 1:  $\mathbb{E}[k] = k$
- Regla 2:  $\mathbb{E}[k \cdot g[x]] = k \cdot \mathbb{E}[g[x]]$
- Regla 3:  $\mathbb{E}[f[x] + g[x]] = \mathbb{E}[f[x]] + \mathbb{E}[g[x]]$
- Regla 4:  $\mathbb{E}[f[x]g[y]] = \mathbb{E}[f[x]]\mathbb{E}[g[y]]$  if  $x, y$  independent

$$V(x) = \underline{\mathbb{E}(x^2)} - \mathbb{E}(x)^2$$

$$\sigma_{f'}^2 = \mathbb{E}[f_i'^2] - \mathbb{E}[f_i']^2$$

$$= \mathbb{E} \left[ \left( \beta_i + \sum_{j=1}^{D_h} \Omega_{ij} h_j \right)^2 \right] - 0$$

$$= \mathbb{E} \left[ \left( \sum_{j=1}^{D_h} \Omega_{ij} h_j \right)^2 \right]$$

$$= \sum_{j=1}^{D_h} \mathbb{E} [\Omega_{ij}^2] \mathbb{E} [h_j^2]$$

$$= \sum_{j=1}^{D_h} \sigma_\Omega^2 \mathbb{E} [h_j^2] = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E} [h_j^2]$$

Poner todos los sesgos a 0

Ponderaciones distribuidas normalmente  
media 0

varianza  $\sigma_\Omega^2$

# Inicialización

- Necesidad de inicialización
- Inicialización **He**
- Interludio: Valores esperados
- Demostrar que  $\mathbb{E}[f'_i] = 0$
- Escribir la varianza de las preactivaciones  $f'$  en términos de las activations  $h$  en la capa anterior

$$\sigma_{f'}^2 = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E} [h_j^2]$$

- Escribir la varianza de las preactivaciones  $f'$  en términos de las preactivaciones  $f$  de la capa anterior

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

$$h_J = \alpha(f_J)$$

$$\sigma_{f'}^2 = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E}[h_j^2]$$

$$= \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E}[\text{ReLU}[f_j]^2]$$

$$g(f_J) = \text{ReLU}$$

$$\int_{-\infty}^{\theta} \mathbb{I}(f_T > 0) f_J^3$$

$$= \sigma_\Omega^2 \sum_{j=1}^{D_h} \int_{-\infty}^{\infty} \text{ReLU}[f_j]^2 Pr(f_j) df_j$$

$$= \sigma_\Omega^2 \sum_{j=1}^{D_h} \int_{-\infty}^{\infty} (\mathbb{I}[f_j > 0] f_j)^2 Pr(f_j) df_j$$

$$V(f_J) = \sigma_f^2$$

$$\hookrightarrow = \sigma_\Omega^2 \sum_{j=1}^{D_h} \int_0^{\infty} f_j^2 Pr(f_j) df_j = \sigma_\Omega^2 \sum_{j=1}^{D_h} \mathbb{E}(f_j^2)$$

$$= \sigma_\Omega^2 \sum_{j=1}^{D_h} \frac{\sigma_f^2}{2} = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

Problema 7.14

Objetivo:  
mantener la misma varianza entre dos capas

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

Debería elegir:

$$\sigma_\Omega^2 = \frac{2}{D_h}$$

Esto se llama **inicialización He**.

# Objetivo:

mantener la misma varianza entre dos capas

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

Buscamos  $\sigma_f^2 = \sigma_{f'}^2$  si asumimos que  $\sigma_f^2 = \sigma_{f'}^2 > 0$

Basta con hacer  $\sigma_f^2 = \sigma_{f'}^2 = a$  y tenemos

$$\sigma_f^2 = \frac{\sigma_f^2 D_h \sigma_\Omega^2}{2} \equiv \cancel{x} = \cancel{\frac{\alpha D_h \sigma_\Omega^2}{2}}$$

que implica entonces que

$$N(0, \theta_\Omega^2 = \frac{2}{D_h})$$

$$\sigma_\Omega^2 = \frac{2}{D_h}$$

A esto lo llamamos **inicialización He**.

# Leer más

Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. Kaiming He et al. Microsoft

## Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification

Kaiming He

Xiangyu Zhang

Shaoqing Ren

Jian Sun

Microsoft Research

{kahe, v-xiangz, v-shren, jiansun}@microsoft.com

This product is the key to the initialization design. A proper initialization method should avoid reducing or magnifying the magnitudes of input signals exponentially. So we expect the above product to take a proper scalar (e.g., 1). A sufficient condition is:

$$\frac{1}{2}n_l Var[w_l] = 1, \quad \forall l. \quad (10)$$

This leads to a zero-mean Gaussian distribution whose standard deviation (std) is  $\sqrt{2/n_l}$ . This is our way of initialization. We also initialize  $\mathbf{b} = 0$ .

For the first layer ( $l = 1$ ), we should have  $n_1 Var[w_1] = 1$  because there is no ReLU applied on the input signal. But the factor 1/2 does not matter if it just exists on one layer. So we also adopt Eqn.(10) in the first layer for simplicity.

**Objetivo:**  
mantener la misma varianza entre dos capas

$$\sigma_{f'}^2 = \frac{D_h \sigma_\Omega^2 \sigma_f^2}{2}$$

Cuando las dimensiones de las capas lineales no son cuadradas. Es decir

$$D_h \neq D_{h'}$$

Podemos hacer el compromiso con usando el promedio  $\frac{D_h + D_{h'}}{2}$  por lo que

$$\sigma_\Omega^2 = \frac{4}{D_h + D_{h'}}$$

A esto lo llamamos **inicialización He**.

# Inicialización Xavier

$\mathcal{N}_K$

- Glorot & Bengio, "Understanding the difficulty of training deep feedforward neural networks", AISTATS 2010.

- **Xavier Uniform**


$$W \sim \mathcal{U}(-a, a), \quad a = \sqrt{\frac{6}{\text{fan\_in} + \text{fan\_out}}}$$

- **Xavier Normal**

$$W \sim \mathcal{N}\left(0, \sqrt{\frac{2}{\text{fan\_in} + \text{fan\_out}}}\right)$$

# Inicialización Xavier

$$[-a, a]$$



- Xavier Uniform  $W \sim \mathcal{U}(-a, a)$ ,  $a = \sqrt{\frac{6}{\text{fan\_in} + \text{fan\_out}}}$

Si hacemos  $W \sim \text{Unif}(-a, a)$  entonces la varianza de los pesos es

$$\text{Var}(W) = \frac{(b-a)^2}{12} = \frac{(2a)^2}{12} = \frac{4a^2}{12} = \frac{a^2}{3}$$

$$[-\sqrt{3} \cdot \frac{1}{\sqrt{\text{fan\_in}}}, \sqrt{3} \cdot \frac{1}{\sqrt{\text{fan\_in}}}]$$

Si entonces queremos igualar la varianza a  $\frac{1}{\text{fan\_in}}$

$$\frac{a^2}{3} = \frac{1}{\text{fan\_in}} \Rightarrow a = \sqrt{3} \cdot \frac{1}{\sqrt{\text{fan\_in}}}$$

# Inicialización Xavier

- Xavier Uniform  $W \sim \mathcal{U}(-a, a), \quad a = \sqrt{\frac{6}{\text{fan\_in} + \text{fan\_out}}}$

Si hacemos  $W \sim \text{Unif}(-a, a)$  entonces la varianza de los pesos es

$$\text{Var}(W) = \frac{(b - a)^2}{12} = \frac{(2a)^2}{12} = \frac{4a^2}{12} = \frac{a^2}{3}$$

)

Si entonces queremos igualar la varianza a  $\frac{2}{\text{fan\_in} + \text{fan\_out}}$

$$\frac{a^2}{3} = \frac{2}{\text{fan\_in} + \text{fan\_out}} = \sqrt{\left( \frac{6}{\text{fan\_in} + \text{fan\_out}} \right)}$$

# Leer más

- “Understanding the difficulty of training deep feedforward neural networks.” Xavier Glorot and Yoshua Bengio. DIRO.

---

## Understanding the difficulty of training deep feedforward neural networks

---

Xavier Glorot  
DIRO, Université de Montréal, Montréal, Québec, Canada

Yoshua Bengio  
DIRO, Université de Montréal, Montréal, Québec, Canada

We initialized the biases to be 0 and the weights  $W_{ij}$  at each layer with the following commonly used heuristic:

$$\rightarrow W_{ij} \sim U\left[-\frac{1}{\sqrt{n}}, \frac{1}{\sqrt{n}}\right], \quad (1)$$



where  $U[-a, a]$  is the uniform distribution in the interval  $(-a, a)$  and  $n$  is the size of the previous layer (the number of columns of  $W$ ).

# Resumen

Inicialización	Activación	Salida esperada
Xavier + tanh	Ideal	Estable. Valores balanceados
Kaiming + ReLU	Ideal	Buena varianza, pocas neuronas muertas
Xavier + ReLU	Riesgoso	Riesgo de neuronas muertas (varianza baja)
Kaiming + tanh	Riesgoso	Puede ocasionar explosión de los gradientes



# Experimentos

ReLU  
he



# Experimentos

$$\text{ReLU} = \max(0, x)$$



# En PyTorch

- Inicialización He

[https://docs.pytorch.org/docs/stable/nn.init.html#torch.nn.init.kaiming\\_uniform\\_](https://docs.pytorch.org/docs/stable/nn.init.html#torch.nn.init.kaiming_uniform_)

- Inicialización Xavier

[https://docs.pytorch.org/docs/stable/nn.init.html#torch.nn.init.xavier\\_uniform\\_](https://docs.pytorch.org/docs/stable/nn.init.html#torch.nn.init.xavier_uniform_)