



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY



IIMPI
INSTITUTO DE
INGENIERIA MECANICA
Y PRODUCCION INDUSTRIAL

Seminario en redes neuronales basadas en la Física

PINNs

[Physics-Informed Neural Networks]

MSc. Ing. Christian Díaz-Cuadro





Estaremos conversando sobre:



Estaremos conversando sobre:

- ¿Qué es una Red Neuronal?



Estaremos conversando sobre:

- ¿Qué es una Red Neuronal?
- ¿Qué es una PINN?



Estaremos conversando sobre:

- ¿Qué es una Red Neuronal?
- ¿Qué es una PINN?
- Aplicación a mecánica del sólido



Estaremos conversando sobre:

- ¿Qué es una Red Neuronal?
- ¿Qué es una PINN?
- Aplicación a mecánica del sólido
- Resultados



Estaremos conversando sobre:

- ¿Qué es una Red Neuronal?
- ¿Qué es una PINN?
- Aplicación a mecánica del sólido
- Resultados
- **Ejemplo**



¿Qué es una Red Neuronal?



¿Qué es una Red Neuronal?

Definición básica

Una red neuronal es un modelo computacional inspirado en la estructura y el funcionamiento del cerebro humano.



¿Qué es una Red Neuronal?

Definición básica

Una red neuronal es un modelo computacional inspirado en la estructura y el funcionamiento del cerebro humano.



¿Qué es una Red Neuronal?

Definición básica

Una red neuronal es un modelo computacional inspirado en la estructura y el funcionamiento del cerebro humano.



¿Qué es una Red Neuronal?

Definición básica


Una red neuronal es un modelo computacional inspirado en la estructura y el funcionamiento del cerebro humano.



¿Qué es una Red Neuronal?

Definición básica


Una red neuronal es un modelo computacional inspirado en la estructura y el funcionamiento del cerebro humano.




¿Qué es una Red Neuronal?

Definición básica

Una red neuronal es un modelo computacional inspirado en la estructura y el funcionamiento del cerebro humano.



¿Qué es una Red Neuronal?



¿Para qué sirve?

Es un sistema de procesamiento de información que aprende relaciones no lineales entre entradas y salidas.

Teorema de aproximación universal¹

Se han demostrado que una Red Neuronal de **1 capa** puede aproximar cualquier función continua en el espacio \mathbf{R}^n , siempre que:


- Utilice funciones de activación apropiadas
- Sea o suficientemente "ancha"

1. Hornik, Kurt; Stinchcombe, Maxwell; White, Halbert (January 1989). "Multilayer feedforward networks are universal approximators". *Neural Networks*. 2 (5): 359–366.




¿Qué es una Red Neuronal?

Características principales



¿Qué es una Red Neuronal?


Características principales



Nodos

¿Qué es una Red Neuronal?

Características principales




Nodos

Conexiones

¿Qué es una Red Neuronal?

Características principales




Nodos

Conexiones

Capas (o layers)

¿Qué es una Red Neuronal?

Características principales



Nodos

Conexiones


Capas (o layers)

Nodos por capa (3 en esta capa)

¿Qué es una Red Neuronal?


Características principales

Capa de entrada



¿Qué es una Red Neuronal?


Características principales




*Capas ocultas
"Profundidad"*

¿Qué es una Red Neuronal?

Características principales



¿Qué es una Red Neuronal?




Características principales

- Esta red es conocida como **Fully connected**.
- Existen gran cantidad de variantes de **NN** en función de la operación que se realizan en las neuronas:
 - Feedforward Neural Network
 - Redes Neuronales Recurrentes
 - Convolutional neural network
 - Generative Neural Networks
 - Autoencoders
 - Transformers Neural Networks
 - Spatial Neural Networks

Y muchas veces se combinan varias de estas buscando combinar sus fortalezas.

¿Qué es una Red Neuronal?




Características principales

- Esta red es conocida como **Fully connected**.
- Existen gran cantidad de variantes de **NN** en función de la operación que se realizan en las neuronas:
 - **Feedforward Neural Network**
 - **Redes Neuronales Recurrentes**
 - **Convolutional neural network**
 - **Generative Neural Networks**
 - Autoencoders
 - Transformers Neural Networks
 - Spatial Neural Networks

Y muchas veces se combinan varias de estas buscando combinar sus fortalezas.

¿Qué es una Red Neuronal?



Características principales


- Esta red es conocida como **Fully connected**.
- Existen gran cantidad de variantes de **NN** en función de la operación que se realizan en las neuronas:
 - **Feedforward Neural Network**
 - Redes Neuronales Recurrentes
 - Convolutional neural network
 - Generative Neural Networks
 - Autoencoders
 - Transformers Neural Networks
 - Spatial Neural Networks

Y muchas veces se combinan varias de estas buscando combinar sus fortalezas.




¿Qué es una Red Neuronal?

Funcionamiento




¿Qué es una Red Neuronal?

Funcionamiento



¿Qué es una Red Neuronal?

Funcionamiento



¿Qué es una Red Neuronal?

Funcionamiento

w_{ij}^L : peso de la capa L ,
para la entrada i ,
en la neurona j

b_j^L : bias de la capa L ,
en la neurona j

$$y_1^1 = \sigma(w_{11}^1 \cdot x + b_1^1)$$


$$y_2^1 = \sigma(w_{12}^1 \cdot x + b_2^1)$$

Datos de entrada

Función de activación

$\sigma: \mathbb{R} \rightarrow \mathbb{R}$ / no lineal

y_j^L : Salida de la capa L ,
de la neurona j .




¿Qué es una Red Neuronal?

Funcionamiento

w_{ij}^L : peso de la capa L ,
para la entrada i ,
en la neurona j

b_j^L : bias de la capa L ,
en la neurona j



X

y_1^1

y_1^1

y_1^1

y_2^1

y_2^1

y_2^1

$y_2^1 = \sigma(w_{12}^1 \cdot X + b_2^1)$

X

Datos de entrada

Función de activación

$\sigma: \mathbb{R} \rightarrow \mathbb{R}$ / no lineal

y_j^L : Salida de la capa L ,
de la neurona j .

¿Qué es una Red Neuronal?

Funcionamiento

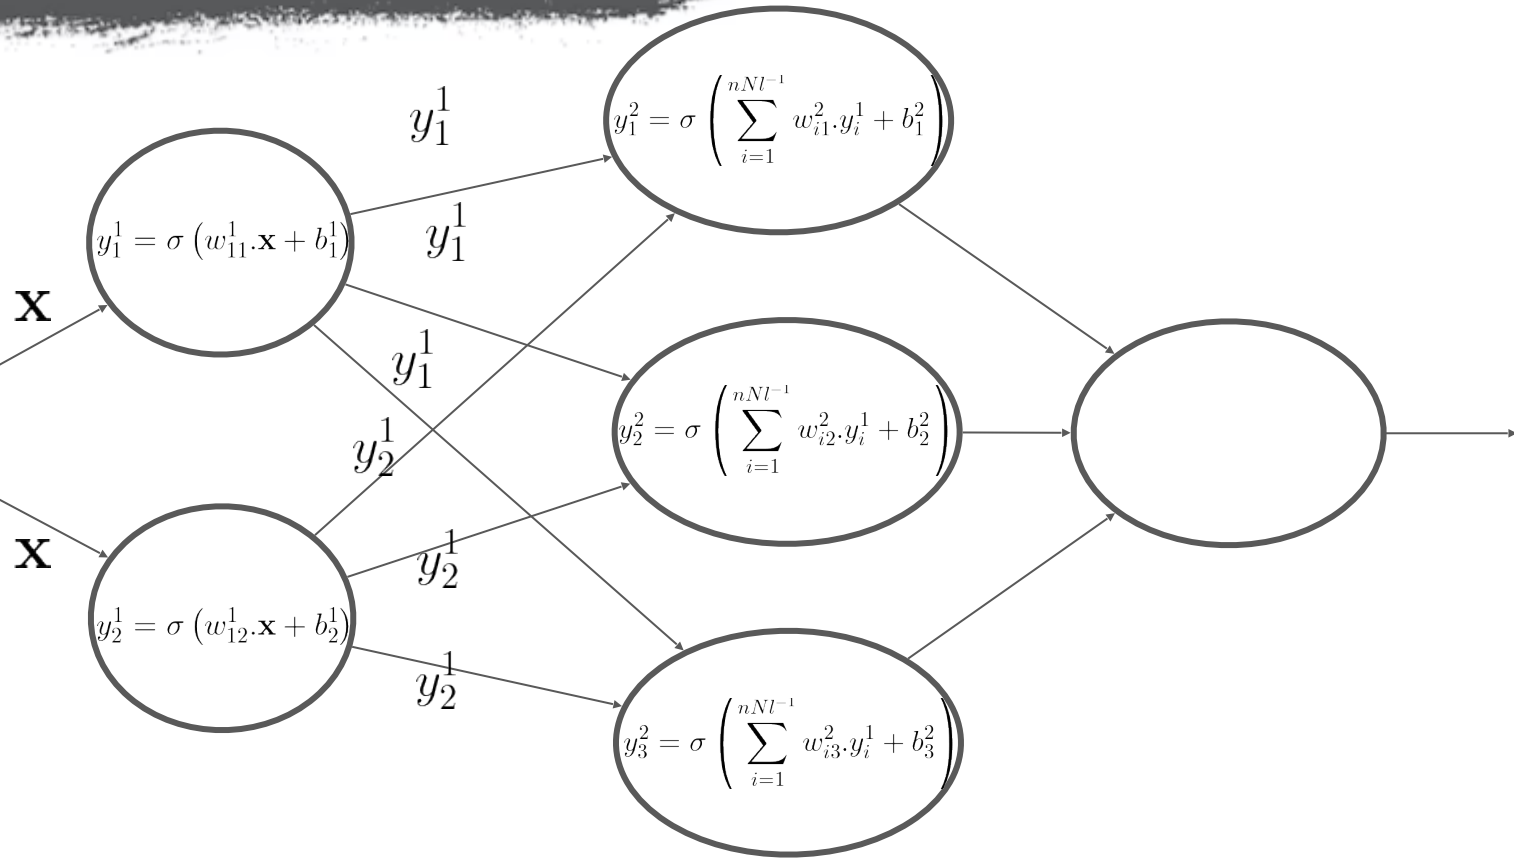
w_{ij}^L : peso de la capa L ,
para la entrada i ,
en la neurona j

b_j^L : bias de la capa L ,
en la neurona j

Datos de entrada

Función de activación
 $\sigma: \mathbb{R} \rightarrow \mathbb{R}$ / no lineal

y_j^L : Salida de la capa L ,
de la neurona j .



¿Qué es una Red Neuronal?

Funcionamiento

w_{ij}^L : peso de la capa L ,
para la entrada i ,
en la neurona j

b_j^L : bias de la capa L ,
en la neurona j

\mathbf{X}

$$y_1^1 = \sigma(w_{11}^1 \cdot \mathbf{x} + b_1^1)$$

y_1^1

y_1^1

y_1^1

y_2^1

y_2^1

y_2^1

$$y_2^1 = \sigma(w_{12}^1 \cdot \mathbf{x} + b_2^1)$$

$$y_1^2 = \sigma\left(\sum_{i=1}^{n_{Nl-1}} w_{i1}^2 \cdot y_i^1 + b_1^2\right)$$

y_1^2

$$y_2^2 = \sigma\left(\sum_{i=1}^{n_{Nl-1}} w_{i2}^2 \cdot y_i^1 + b_2^2\right)$$

y_2^2

$$y_3^2 = \sigma\left(\sum_{i=1}^{n_{Nl-1}} w_{i3}^2 \cdot y_i^1 + b_3^2\right)$$

y_3^2

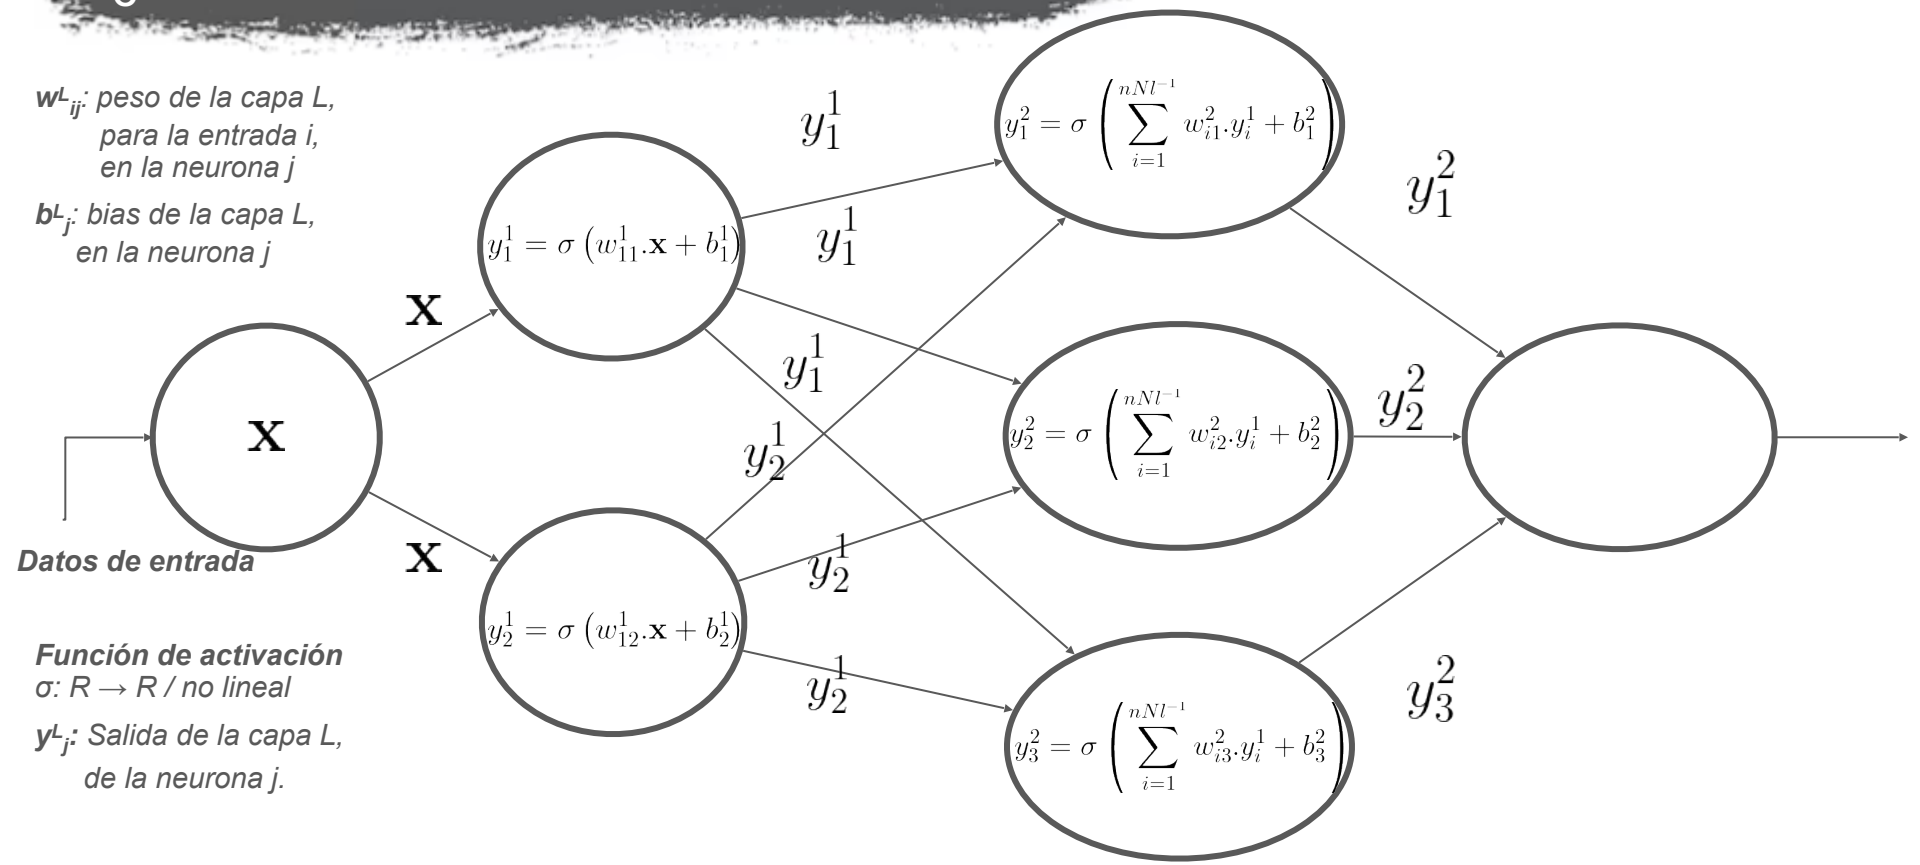
Datos de entrada

\mathbf{X}

Función de activación

$\sigma: \mathbb{R} \rightarrow \mathbb{R}$ / no lineal

y_j^L : Salida de la capa L ,
de la neurona j .



¿Qué es una Red Neuronal?

Funcionamiento

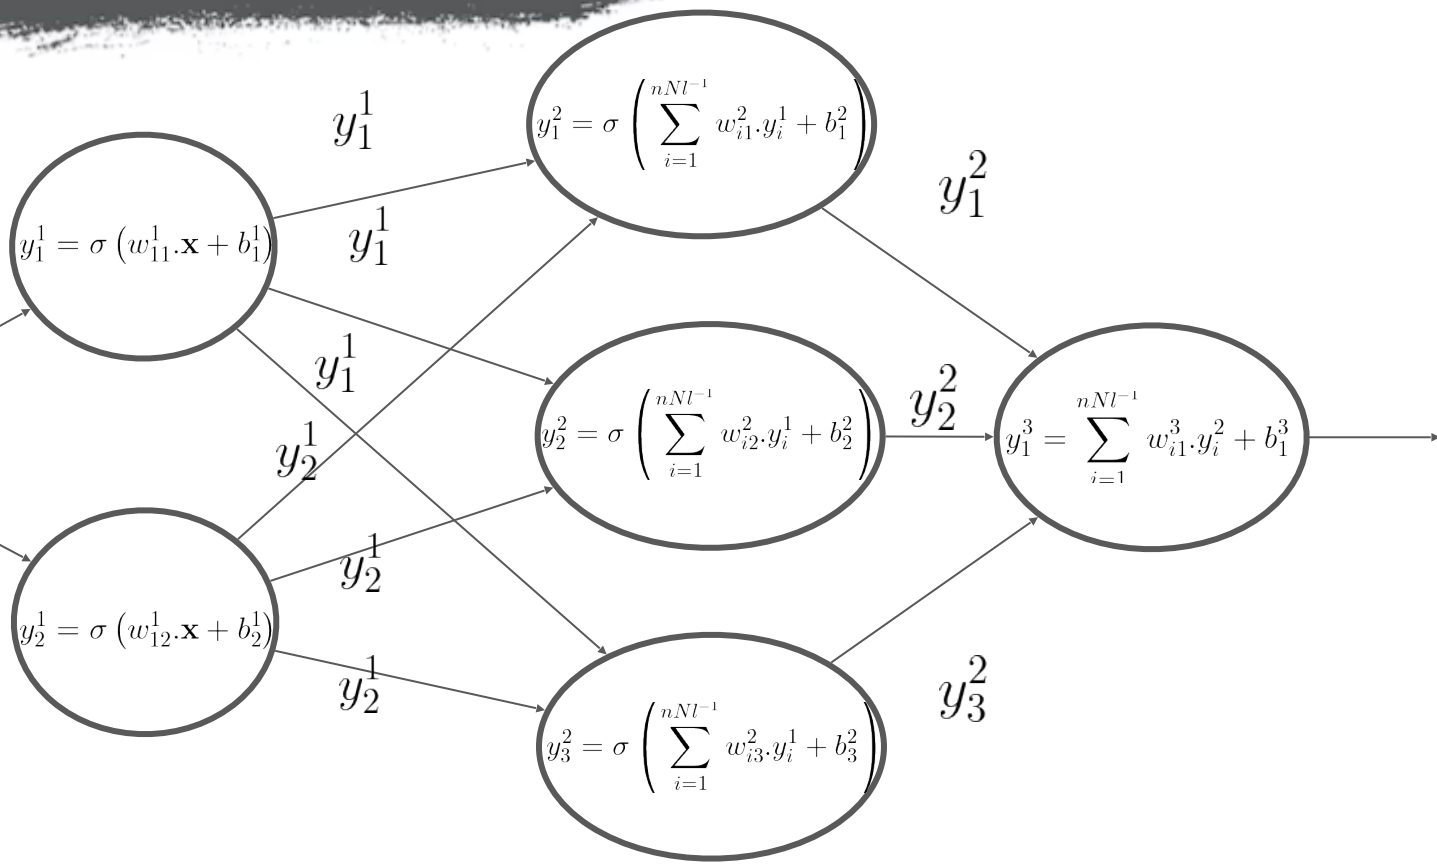
w_{ij}^L : peso de la capa L ,
para la entrada i ,
en la neurona j

b_j^L : bias de la capa L ,
en la neurona j

Datos de entrada

Función de activación
 $\sigma: \mathbb{R} \rightarrow \mathbb{R}$ / no lineal

y_j^L : Salida de la capa L ,
de la neurona j .



¿Qué es una Red Neuronal?

Funcionamiento

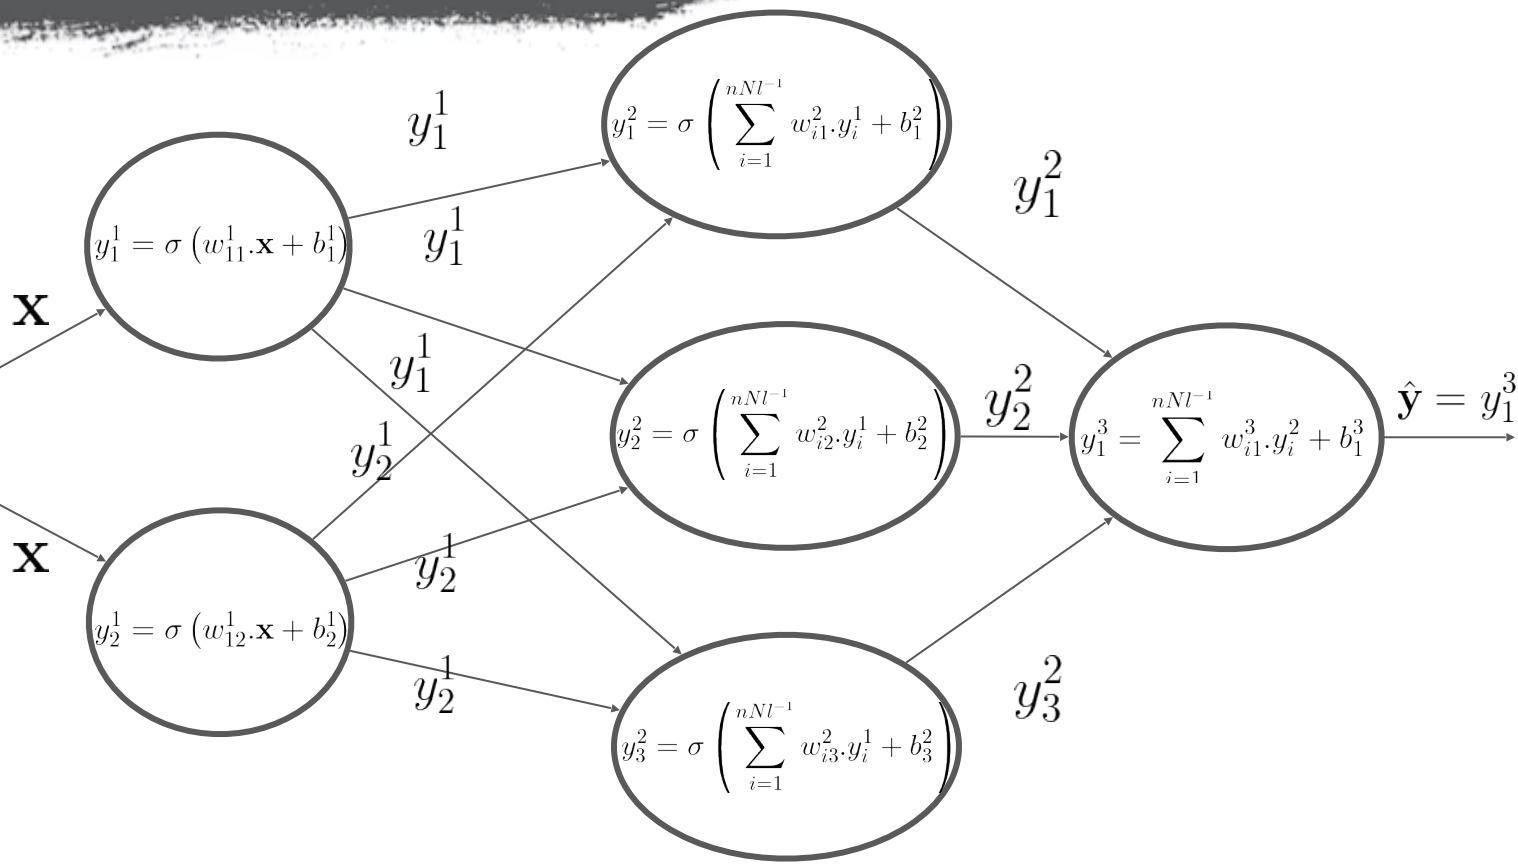
w_{ij}^L : peso de la capa L ,
para la entrada i ,
en la neurona j

b_j^L : bias de la capa L ,
en la neurona j

Datos de entrada

Función de activación
 $\sigma: \mathbb{R} \rightarrow \mathbb{R}$ / no lineal

y_j^L : Salida de la capa L ,
de la neurona j .



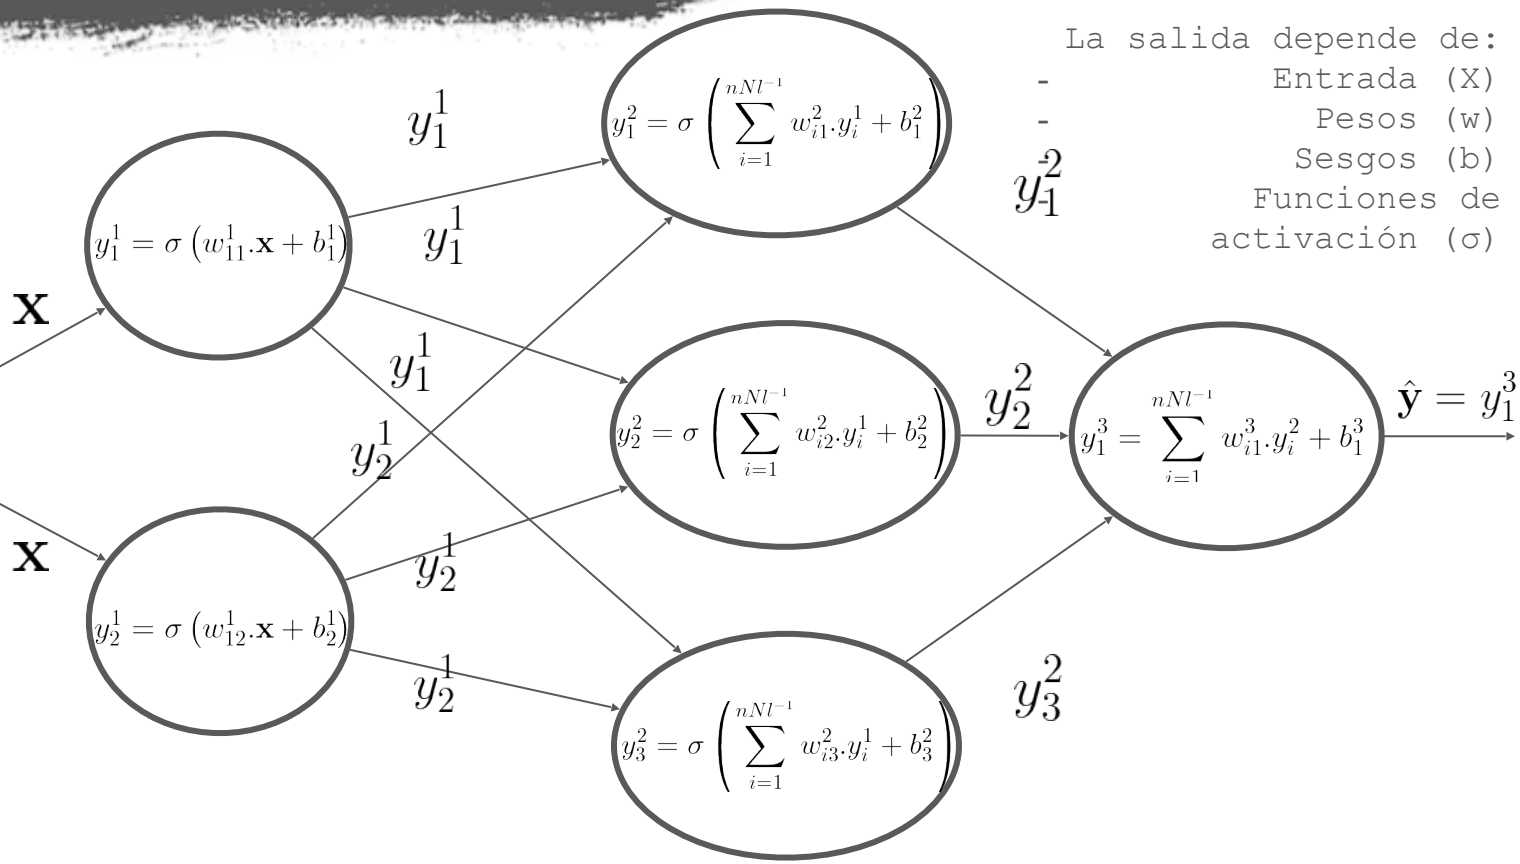
¿Qué es una Red Neuronal?

w_{ij}^L : peso de la capa L ,
para la entrada i ,
en la neurona j

b_j^L : bias de la capa L ,
en la neurona j

Función de activación
 $\sigma: \mathbb{R} \rightarrow \mathbb{R}$ / no lineal

y_j^L : Salida de la capa L ,
de la neurona j .



Funcionamiento

La salida depende de:

- Entrada (X)
- Pesos (w)
- Sesgos (b)
- Funciones de activación (σ)

¿Qué es una Red Neuronal?

Funcionamiento

¿Cómo hacemos que la red aprenda la relación entre x e y ?
es decir: $f(x): y=f(x)$

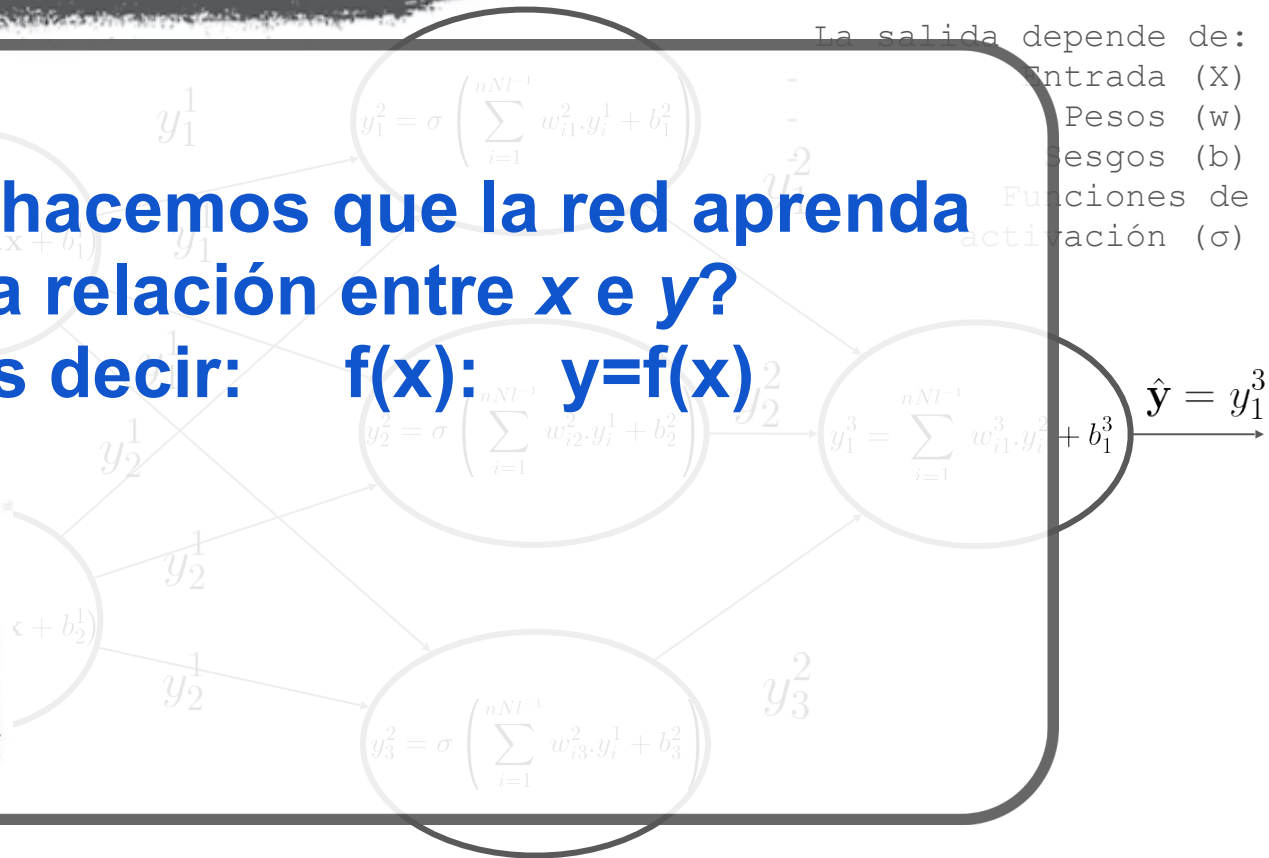
w_{ij}^L : peso de la capa L , para la entrada i , en la neurona j
 b_j^L : bias de la capa L , en la neurona j

La salida depende de:
- Entrada (X)
- Pesos (w)
- Sesgos (b)
- Funciones de activación (σ)

X
Datos de entrada

Función de activación
 $\sigma: R \rightarrow R$ / no lineal

y_j^L : Salida de la capa L , de la neurona j .



¿Qué es una Red Neuronal?

Funcionamiento

w_{ij}^L : peso de la capa L ,
para la entrada i ,
en la neurona j

b_j^L : bias de la capa L ,
en la neurona j

La salida depende de:

- Entrada (X)
- Pesos (w)
- Sesgos (b)
- Funciones de activación (σ)

Hay que entrenarla!!




¿Qué es una Red Neuronal?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$




¿Qué es una Red Neuronal?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$




¿Qué es una Red Neuronal?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$




¿Qué es una Red Neuronal?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n : i = 1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m : \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}^m$



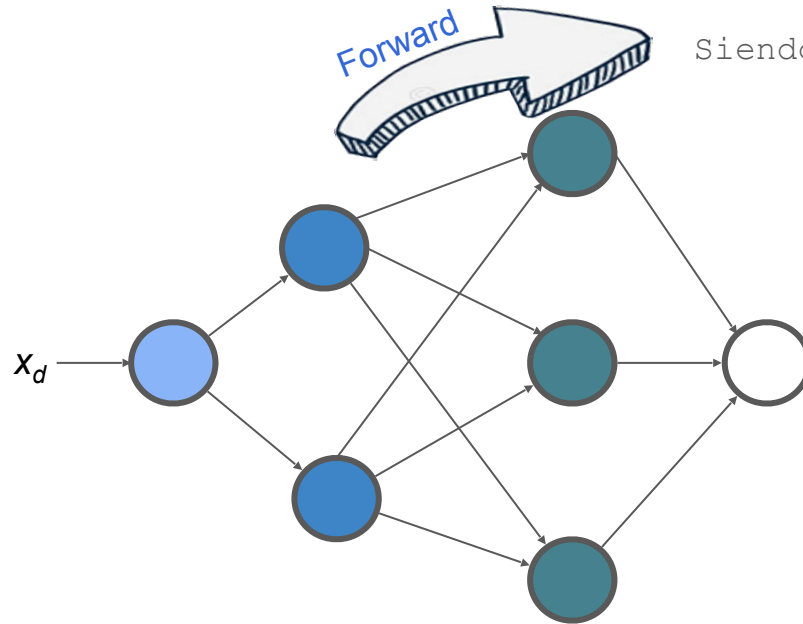
¿Qué es una Red Neuronal?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$




¿Qué es una Red Neuronal?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$

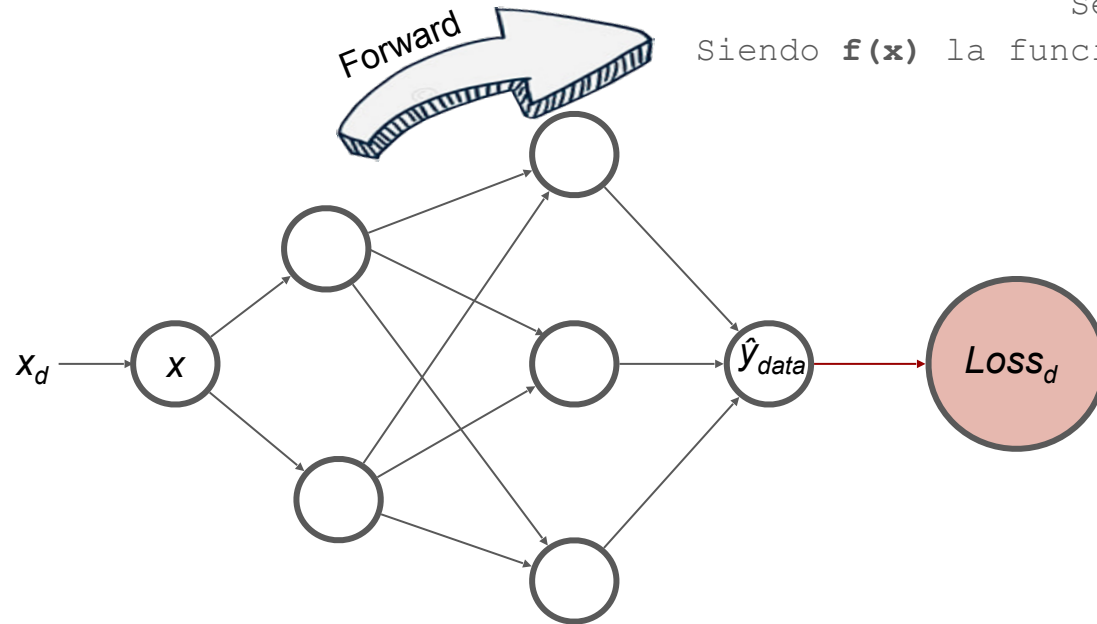


¿Qué es una Red Neuronal?

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$



Entrenamiento

Loss:

Función de pérdida que evalúa la diferencia entre el valor esperado \mathbf{y}_d y el valor obtenido de la red $\hat{\mathbf{y}}_d$

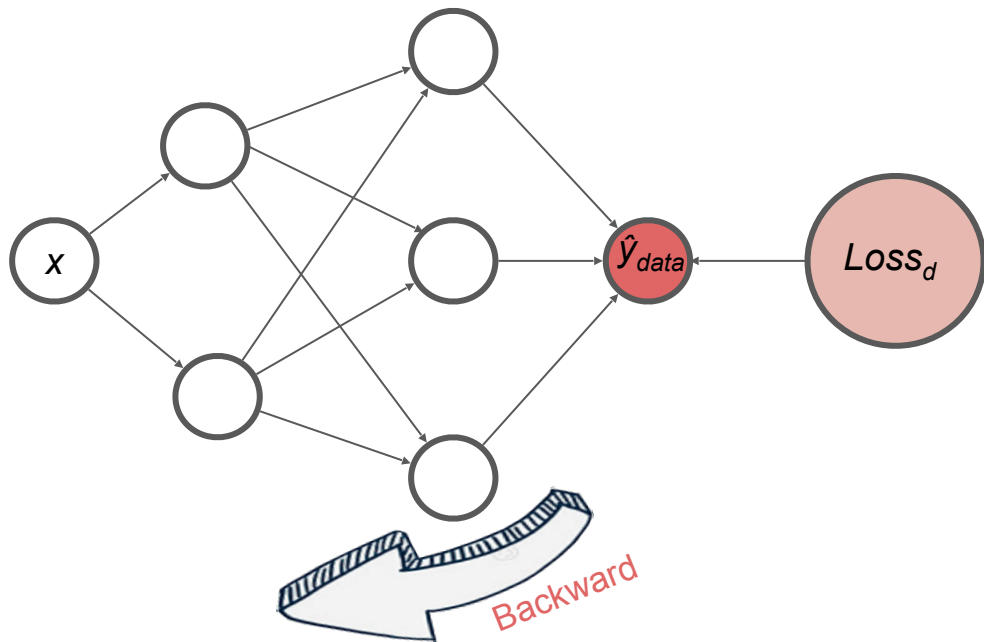
$$L_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \|\mathbf{y}_d - \hat{\mathbf{y}}_d\|^2 = MSE(\mathbf{y}_d, \hat{\mathbf{y}}_d)$$

¿Qué es una Red Neuronal?

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$



Entrenamiento

Loss:

Función de pérdida que evalúa la diferencia entre el valor esperado \mathbf{y}_d y el valor obtenido de la red $\hat{\mathbf{y}}_d$

$$L_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \|\mathbf{y}_d - \hat{\mathbf{y}}_d\|^2 = MSE(\mathbf{y}_d, \hat{\mathbf{y}}_d)$$

Actualiza parámetros

$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss}{\partial \omega_{li}}$$


$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss}{\partial b_l}$$

¿Qué es una Red Neuronal?

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n : i = 1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m : \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}^m$



Entrenamiento

Loss:

Función de pérdida que evalúa la diferencia entre el valor esperado \mathbf{y}_d y el valor obtenido de la red $\hat{\mathbf{y}}_d$

$$L_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \|\mathbf{y}_d - \hat{\mathbf{y}}_d\|^2 = MSE(\mathbf{y}_d, \hat{\mathbf{y}}_d)$$

Actualiza parámetros

$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss}{\partial \omega_{li}}$$


$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss}{\partial b_l}$$

¿Qué es una Red Neuronal?

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n : i = 1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m : \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}^m$



Entrenamiento

Loss:

Función de pérdida que evalúa la diferencia entre el valor esperado \mathbf{y}_d y el valor obtenido de la red $\hat{\mathbf{y}}_d$

$$L_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \|\mathbf{y}_d - \hat{\mathbf{y}}_d\|^2 = MSE(\mathbf{y}_d, \hat{\mathbf{y}}_d)$$

Actualiza parámetros

$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss}{\partial \omega_{li}}$$

$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss}{\partial b_l}$$


¿Qué es una Red Neuronal?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n : i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m : \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}^m$



Se completó una iteración

Loss:

Función de pérdida que evalúa la diferencia entre el valor esperado \mathbf{y}_d y el valor obtenido de la red $\hat{\mathbf{y}}_d$

$$L_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \|\mathbf{y}_d - \hat{\mathbf{y}}_d\|^2 = MSE(\mathbf{y}_d, \hat{\mathbf{y}}_d)$$

Actualiza parámetros

$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss}{\partial \omega_{li}}$$

$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss}{\partial b_l}$$

¿Qué es una Red Neuronal?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n : i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m : \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}^m$

Loss:


Función de pérdida que evalúa la diferencia entre el valor esperado \mathbf{y}_d y el valor obtenido de la red $\hat{\mathbf{y}}_d$

$$L_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \|\mathbf{y}_d - \hat{\mathbf{y}}_d\|^2 = MSE(\mathbf{y}_d, \hat{\mathbf{y}}_d)$$

Actualiza parámetros

$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss}{\partial \omega_{li}}$$

$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss}{\partial b_l}$$



Proceso iterativo

El entrenamiento se repite hasta que se cumple alguna condición de parada

¿Qué es una Red Neuronal?

¿Nada les sorprende hasta ahora?



Proceso iterativo

El entrenamiento se repite hasta que se cumple alguna condición de parada



Entrenamiento

Para un conjunto de N_d datos $\{ \mathbf{x}_d = (\mathbf{x}_i \in \mathbb{R}^m, y_i \in \mathbb{R}^m) \}_{i=1, \dots, N_d}$
 Se conoce $\mathbf{y}_d = \{ y_i \in \mathbb{R}^m \}_{i=1, \dots, N_d}$ con $f(\mathbf{x}) : \mathbb{R}^m \rightarrow \mathbb{R}^m$

Loss:

Función de pérdida que evalúa la diferencia entre el valor esperado \mathbf{y}_d y el valor obtenido de la red $\hat{\mathbf{y}}_d$

$$L_d = \frac{1}{N_d} \sum_{i=1}^{N_d} \|\mathbf{y}_d - \hat{\mathbf{y}}_d\|^2 = MSE(\mathbf{y}_d, \hat{\mathbf{y}}_d)$$

Actualiza parámetros

$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss}{\partial \omega_{li}}$$

$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss}{\partial b_l}$$

¿Qué es una Red Neuronal?

¿Nada les sorprende hasta ahora?



Entrenamiento

Para un conjunto de N_d datos $\{ \mathbf{x}_d = (\mathbf{x}_i \in \mathbb{R}^m, y_i \in \mathbb{R}^m) \}_{i=1, \dots, N_d}$
 Se conoce $\mathbf{y}_d = (y_i \in \mathbb{R}^m)_{i=1, \dots, N_d}$
 Se define la función de pérdida con $f(\mathbf{x}) : \mathbb{R}^m \rightarrow \mathbb{R}^m$

Loss:

es la pérdida que
 representa la diferencia entre
 el verdadero \mathbf{y}_d y el
 predicho por la red $\hat{\mathbf{y}}_d$

$$Loss = MSE(\mathbf{y}_d, \hat{\mathbf{y}}_d)$$

Proceso iterativo

El entrenamiento se repite hasta que se cumple alguna condición de parada



Actualiza parámetros

$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss}{\partial \omega_{li}}$$

$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss}{\partial b_l}$$


¿Qué es una Red Neuronal?

¿Cómo calculo

$$\frac{\partial Loss}{\partial \omega_{li}} ?$$

Automatic differentiation

Es una técnica computacional que existe desde el siglo pasado pero que explotó con el aumento de la capacidad de cómputo de las últimas décadas



¿Qué es una Red Neuronal?


¿Cómo calculo

$$\frac{\partial Loss}{\partial \omega_{li}} ?$$

Automatic differentiation


Es una técnica computacional que existe desde el siglo pasado pero que explotó con el aumento de la capacidad de cómputo de las últimas décadas

Crea un grafo computacional



¿Qué es una Red Neuronal?

¿Cómo calculo $\frac{\partial Loss}{\partial \omega_{li}}$?



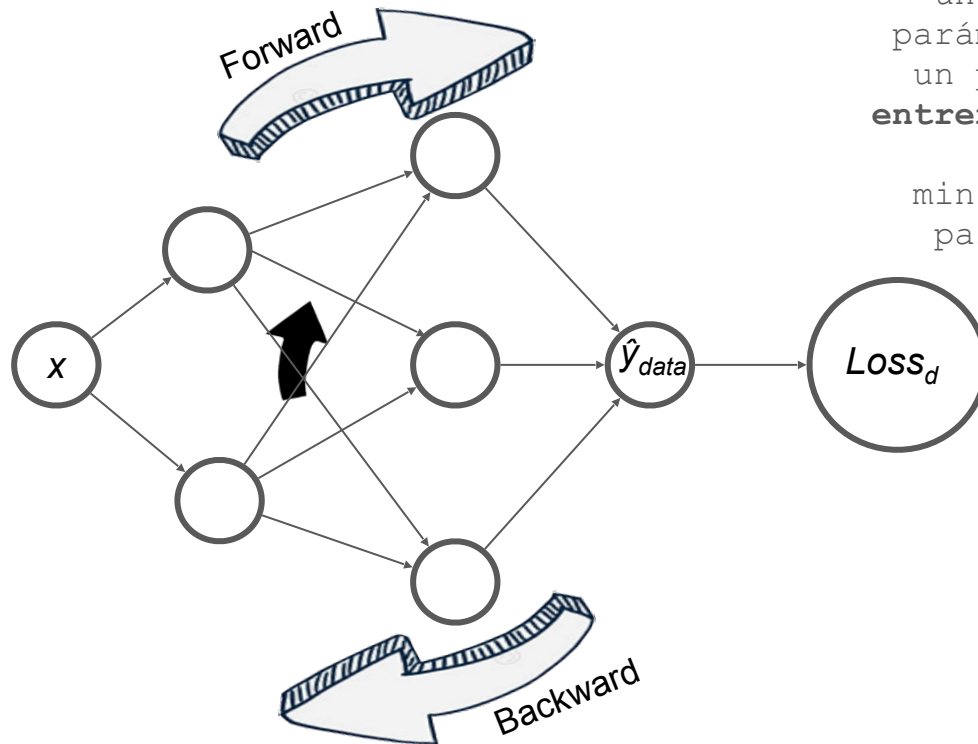
Automatic differentiation

Es una técnica computacional que existe desde el siglo pasado pero que explotó con el aumento de la capacidad de cómputo de las últimas décadas

Crea un grafo computacional

Aplica la regla de la cadena

¿Qué es una Red Neuronal?



Resumen de Red Neuronal

Se puede decir que una red neuronal es un **aproximador de funciones**, cuyos parámetros son ajustados a partir de un proceso iterativo (conocido como **entrenamiento**) que optimiza los **pesos** y los **sesgos** de cada neurona, minimizando una **función objetivo**, a partir de técnicas de **descenso por gradiente** para lo que utiliza **Automatic differentiation**.

$$\arg \min_{w,b} Loss_d(\mathbf{x}, w, b)$$



¿Qué es una PINN?



¿Qué es una PINN?

Características principales

Una PINN se obtiene cuando se dota a la **NN** de información proveniente de la **física del**

problema, con el objetivo de:


- Ayudar al proceso de optimización
- Aprender con menos datos
- Mejorar la generalización
- Aprender de datos ruidosos.

¿Qué es una PINN?

Características principales

Una PINN se obtiene cuando se dota a la **NN** de información proveniente de la **física del problema**, con el objetivo de:

- Ayudar al proceso de optimización
- Aprender con menos datos
- Mejorar la generalización
- Aprender de datos ruidosos.




¿Qué es una PINN?

Características principales

Una PINN se obtiene cuando se dota a la **NN** de información proveniente de la **física del problema**, con el objetivo de:

- Ayudar al proceso de optimización
- Aprender con menos datos
- Mejorar la generalización
- Aprender de datos ruidosos.

Loss_{PDE}: Ecuación diferencial en derivadas parciales que gobierna la física del problema



¿Qué es una PINN?


Características principales

Una PINN se obtiene cuando se dota a la **NN** de información proveniente de la **física del problema**, con el objetivo de:


- Ayudar al proceso de optimización
- Aprender con menos datos
- Mejorar la generalización
- Aprender de datos ruidosos.

Loss_{PDE}: Ecuación diferencial en derivadas parciales que gobierna la física del problema

Loss_{BC}: Ecuación que fuerza a cumplir condiciones de borde.



¿Qué es una PINN?



Características principales

Una PINN se obtiene cuando se dota a la **NN** de información proveniente de la **física del problema**, con el objetivo de:

- Ayudar al proceso de optimización
- Aprender con menos datos
- Mejorar la generalización
- Aprender de datos ruidosos.

Loss_{PDE}: Ecuación diferencial en derivadas parciales que gobierna la física del problema

Loss_{BC}: Ecuación que fuerza a cumplir condiciones de borde.

Loss_{IC}: Ecuación que fuerza a cumplir con condiciones iniciales.

¿Qué es una PINN?

Características principales

Una PINN se obtiene cuando se dota a la **NN** de información proveniente de la **física del problema**, con el objetivo de:

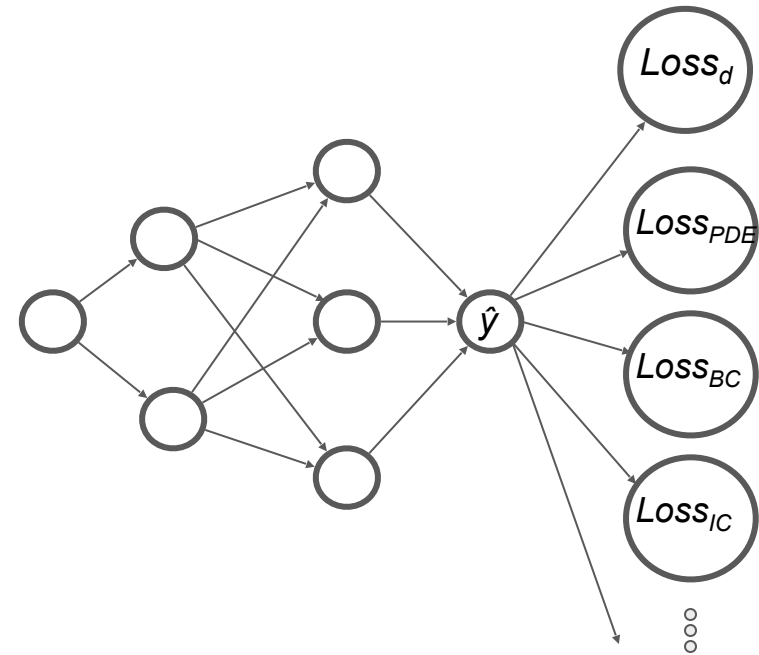
- Ayudar al proceso de optimización
- Aprender con menos datos
- Mejorar la generalización
- Aprender de datos ruidosos.

Loss_{PDE}: Ecuación diferencial en derivadas parciales que gobierna la física del problema

Loss_{BC}: Ecuación que fuerza a cumplir condiciones de borde.

Loss_{IC}: Ecuación que fuerza a cumplir con condiciones iniciales.

Otras Losses: Cualquier información que se conozca en alguna parte del problema puede colaborar con el proceso de optimización.




¿Qué es una PINN?

Características principales

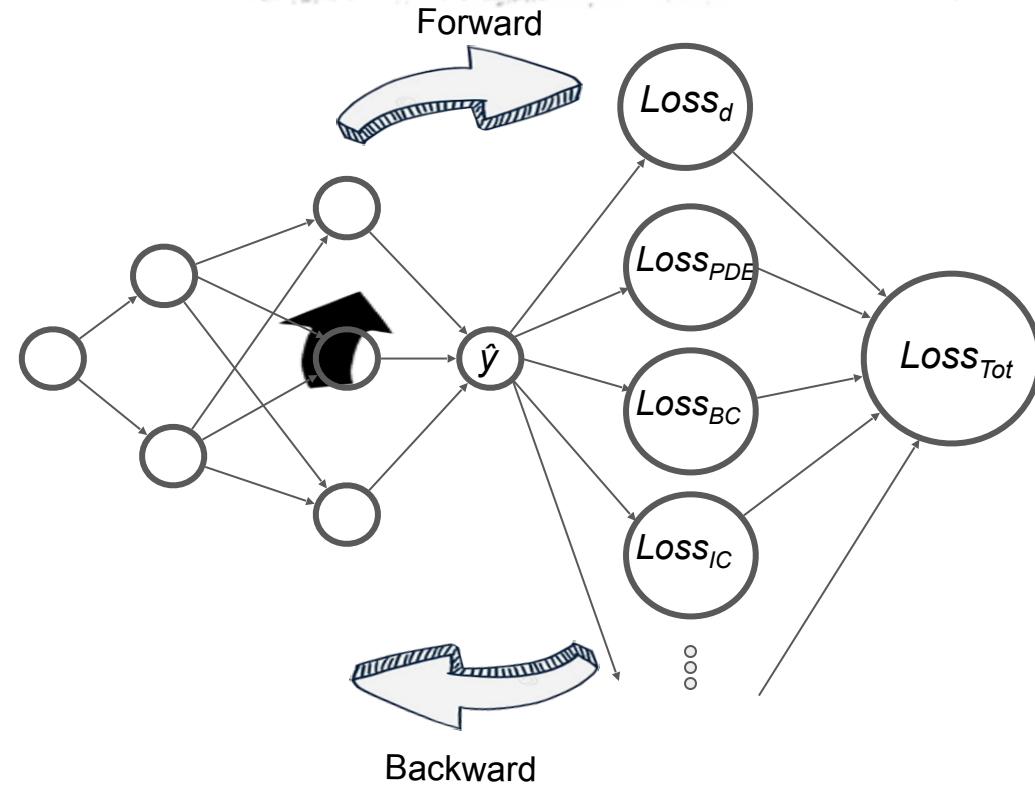
La Loss total se suele calcular como la suma **ponderada** de cada término, para **escalar las magnitudes** y **controlar la "importancia"** que el proceso de optimización le da a cada componente.

$$Loss_{Tot} = \alpha_d Loss_d + \alpha_{BC} Loss_{PDE} + \alpha_{BC} Loss_{BC} + \alpha_{IC} Loss_{IC} + \dots$$



¿Qué es una PINN?

Entrenamiento



¿Qué es una PINN?

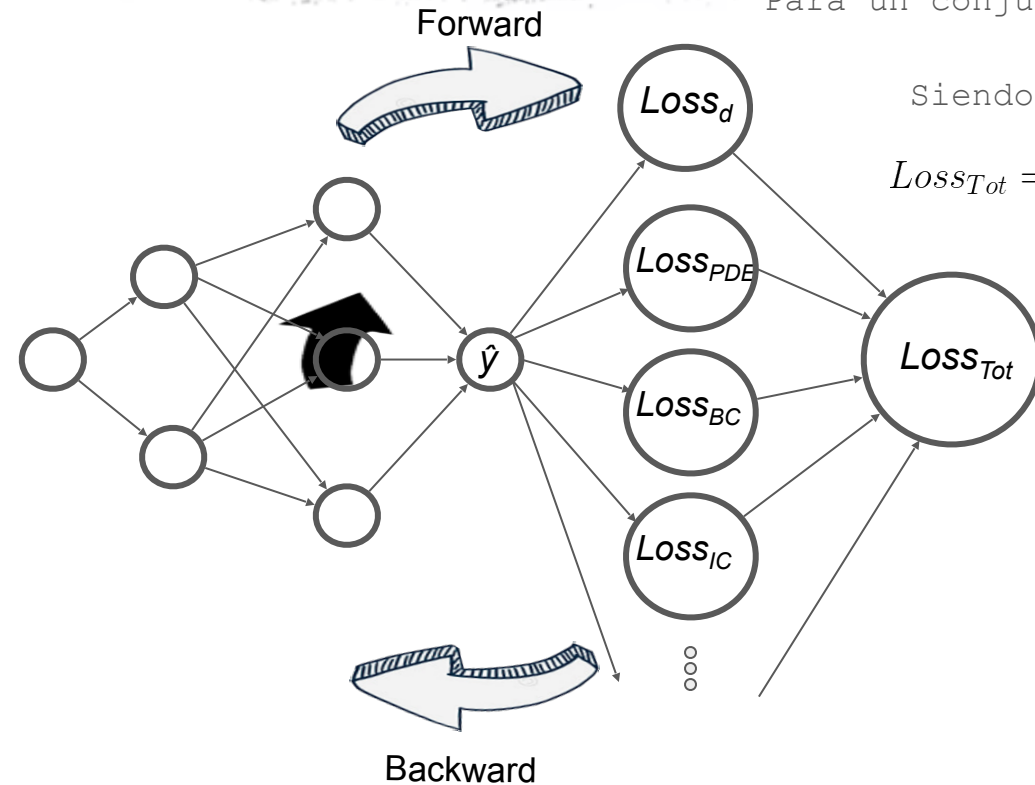
Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$

$$Loss_{Tot} = \alpha_d Loss_d + \alpha_{BC} Loss_{PDE} + \alpha_{BC} Loss_{BC} + \alpha_{IC} Loss_{IC} + \dots$$



¿Qué es una PINN?

Forward



$Loss_d$

$Loss_{PDE}$

$Loss_{BC}$

$Loss_{IC}$

⋮

$Loss_{Tot}$

\hat{y}



Backward

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n : i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m : \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}) : \mathbb{R}^n \rightarrow \mathbb{R}^m$

$$Loss_{Tot} = \alpha_d Loss_d + \alpha_{BC} Loss_{PDE} + \alpha_{BC} Loss_{BC} + \alpha_{IC} Loss_{IC} + \dots$$

Resuelve iterativamente

$$\arg \min_{w_{li}, b_l} Loss_{Tot}(\mathbf{x}, w_{li}, b_l)$$

Actualizando parámetros

$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss_{Tot}}{\partial \omega_{li}}$$

$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss_{Tot}}{\partial b_l}$$

¿Qué es una PINN?

Entrenamiento

Para un conjunto de N_d datos $\rightarrow \mathbf{x}_d = \{\mathbf{x}_i \in \mathbb{R}^n: i=1, \dots, N_d\}$

Se conoce $\mathbf{y}_d = \{\mathbf{y}_i \in \mathbb{R}^m: \mathbf{y}_i = \mathbf{f}(\mathbf{x}_i)\}$

Siendo $\mathbf{f}(\mathbf{x})$ la función a estimar con $\mathbf{f}(\mathbf{x}): \mathbb{R}^n \rightarrow \mathbb{R}^m$

$$Loss_{Tot} = \alpha_d Loss_d + \alpha_{BC} Loss_{PDE} + \alpha_{BC} Loss_{BC} + \alpha_{IC} Loss_{IC} + \dots$$

Resuelve iterativamente

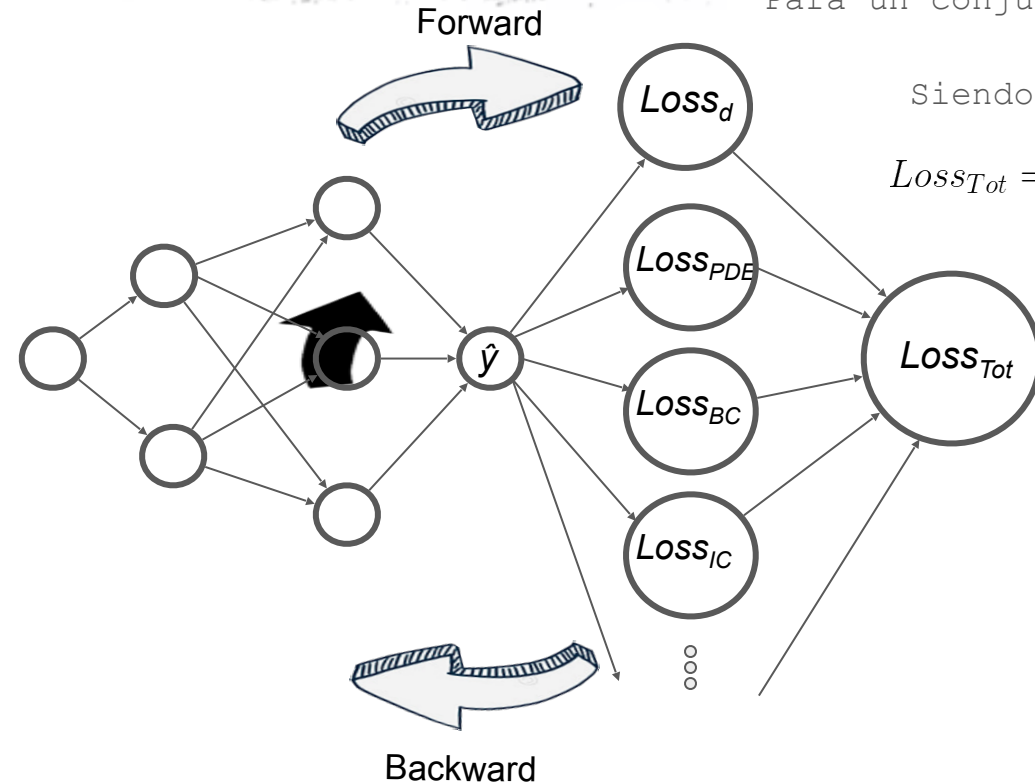
$$\arg \min_{\omega_{li}, b_l, \theta} Loss_{Tot}(\mathbf{x}, \omega_{li}, b_l)$$

Actualizando parámetros


$$\omega_{li}^{t+1} = \omega_{li}^t - \eta \frac{\partial Loss_{Tot}}{\partial \omega_{li}}$$

$$b_l^{t+1} = b_l^t - \eta \frac{\partial Loss_{Tot}}{\partial b_l}$$

Otros parámetros




¿Qué es una PINN?



Ventajas

- Incorporación de información física
- Aprendizaje de datos ruidosos y escasos
- Alta generalización
- Flexibilidad en la formulación de problemas
- Menos (o nula) dependencia de mallas o discretización
- Capacidad para lidiar con EDPs no lineales
- Escalabilidad
- Potencial para resolver problemas inversos
- Integrabilidad con otros métodos

¿Qué es una PINN?



Algunas desventajas

- Su rendimiento depende de la elección adecuada de la **arquitectura de red**, la **configuración de hiperparámetros** y la cantidad de datos de entrenamiento disponibles. También pueden requerir **esfuerzo** y **experiencia** en su implementación y sintonización para obtener resultados óptimos en problemas específicos.


Aplicación a mecánica del sólido

Objetivo

Resolver el **problema inverso** de identificación de propiedades mecánicas (K , G) a partir de conocer:

- Algunos datos de desplazamiento.

- La fuerza ejercida.




Aplicación a mecánica del sólido

Objetivo

Resolver el **problema inverso** de identificación de propiedades mecánicas (K , G) a partir de conocer:

- Algunos datos de desplazamiento.

- La fuerza ejercida.



Física del problema

$$\nabla \cdot \mathbf{P} + \mathbf{b} = 0 \quad \text{Ecuación de equilibrio}$$

$$\mathbf{P} = \frac{\partial \Psi(\mathbf{F})}{\partial \mathbf{F}} \quad \text{Ecuación constitutiva}$$

$$\Psi(\mathbf{C}) = \frac{G}{2}(\text{tr}(\mathbf{C}) - 3) - G \ln(J) + \left(\frac{K}{2} - \frac{G}{3} \right) \ln(J)^2 \quad \text{Densidad de energía de deformación}$$


$$\mathbf{F} = \nabla_m \chi : \quad \mathbf{C} = \mathbf{F}^T \mathbf{F} \quad J = \sqrt{|\mathbf{C}|} \quad \text{Relaciones cinemáticas}$$

Aplicación a mecánica del sólido

Objetivo

Resolver el **problema inverso** de identificación de propiedades mecánicas (K, G) a partir de conocer:

- Algunos datos de desplazamiento.
- La fuerza ejercida.



Física del problema

$$\nabla \cdot \mathbf{P} + \mathbf{b} = 0 \quad \text{Ecuación de equilibrio}$$

$$\mathbf{P} = \frac{\partial \Psi(\mathbf{F})}{\partial \mathbf{F}} \quad \text{Ecuación constitutiva}$$

$$\Psi(\mathbf{C}) = \frac{G}{2} (\text{tr}(\mathbf{C}) - 3) - G \ln(J) + \left(\frac{K}{2} - \frac{G}{3} \right) \ln(J)^2 \quad \text{Densidad de energía de deformación}$$

$$\mathbf{F} = \nabla_m \chi : \quad \mathbf{C} = \mathbf{F}^T \mathbf{F} \quad J = \sqrt{|\mathbf{C}|} \quad \text{Relaciones cinemáticas}$$

Parámetros a identificar

$$\Psi(\mathbf{C}) = \frac{G}{2} (\text{tr}(\mathbf{C}) - 3) - G \ln(J) + \left(\frac{K}{2} - \frac{G}{3} \right) \ln(J)^2$$

Aplicación a mecánica del sólido

Creación de datos digitales

Utilizando un software de Elementos

Finitos se resuelve el caso con:


Geometría (axhxl): 1x1x3mm

3000 elementos Hexaedros

$E = 4 \text{ MPa}$

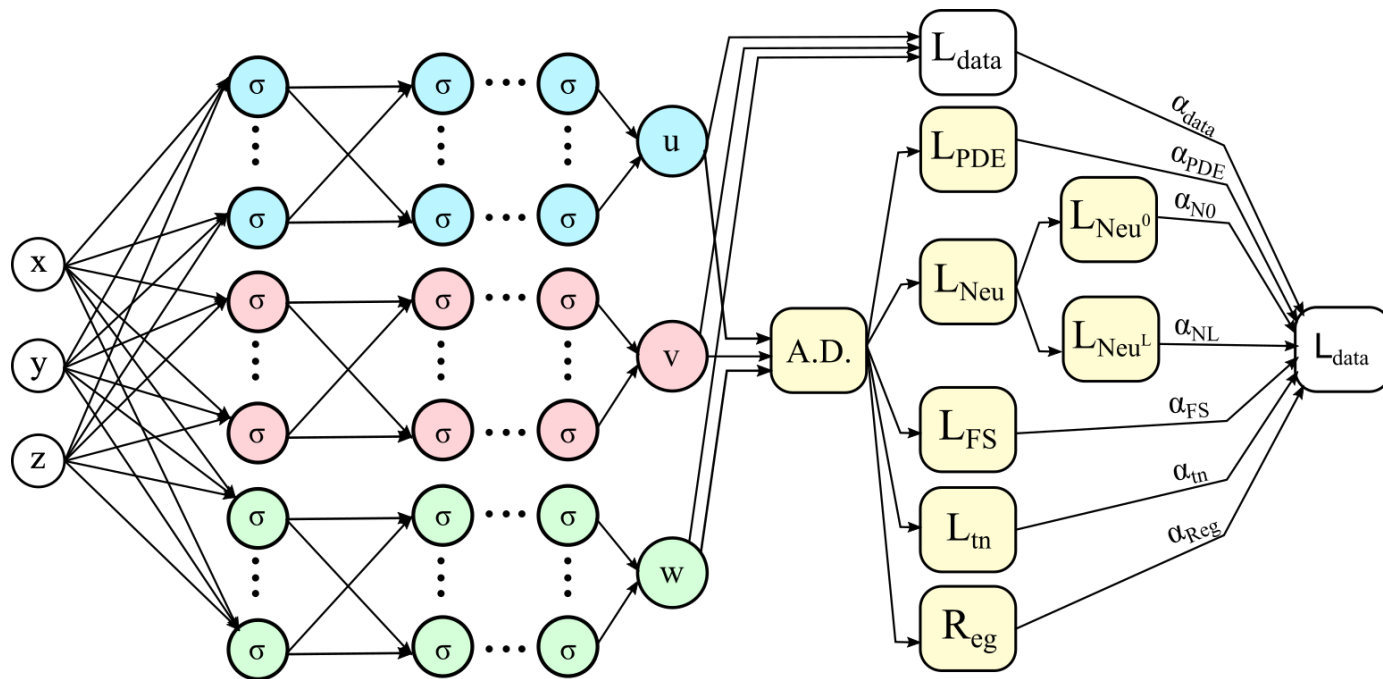
$\nu = 0.3$

$P = -5 \text{ N}$



Aplicación a mecánica del sólido

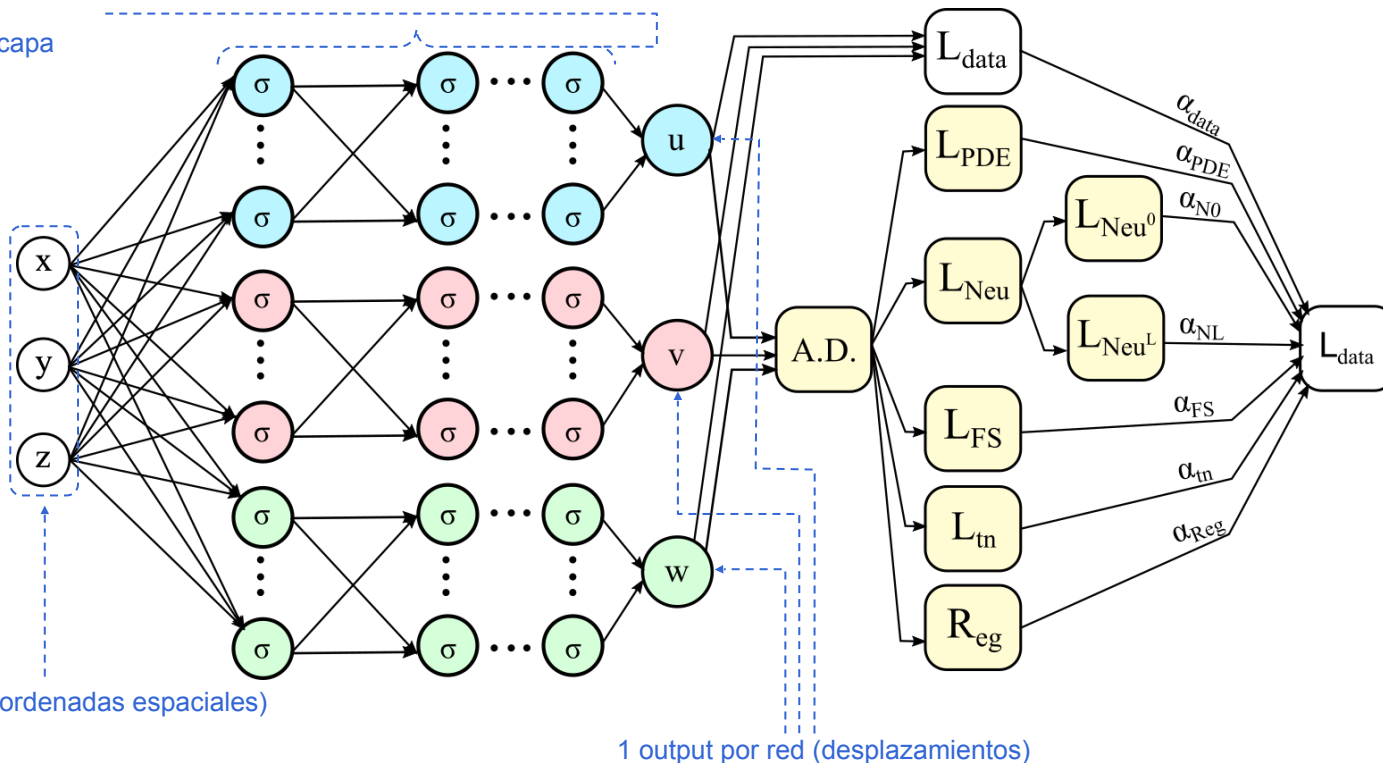
PINN propuesta



Aplicación a mecánica del sólido

PINN propuesta

3 Redes independientes
4 capas ocultas
50 neuronas por capa

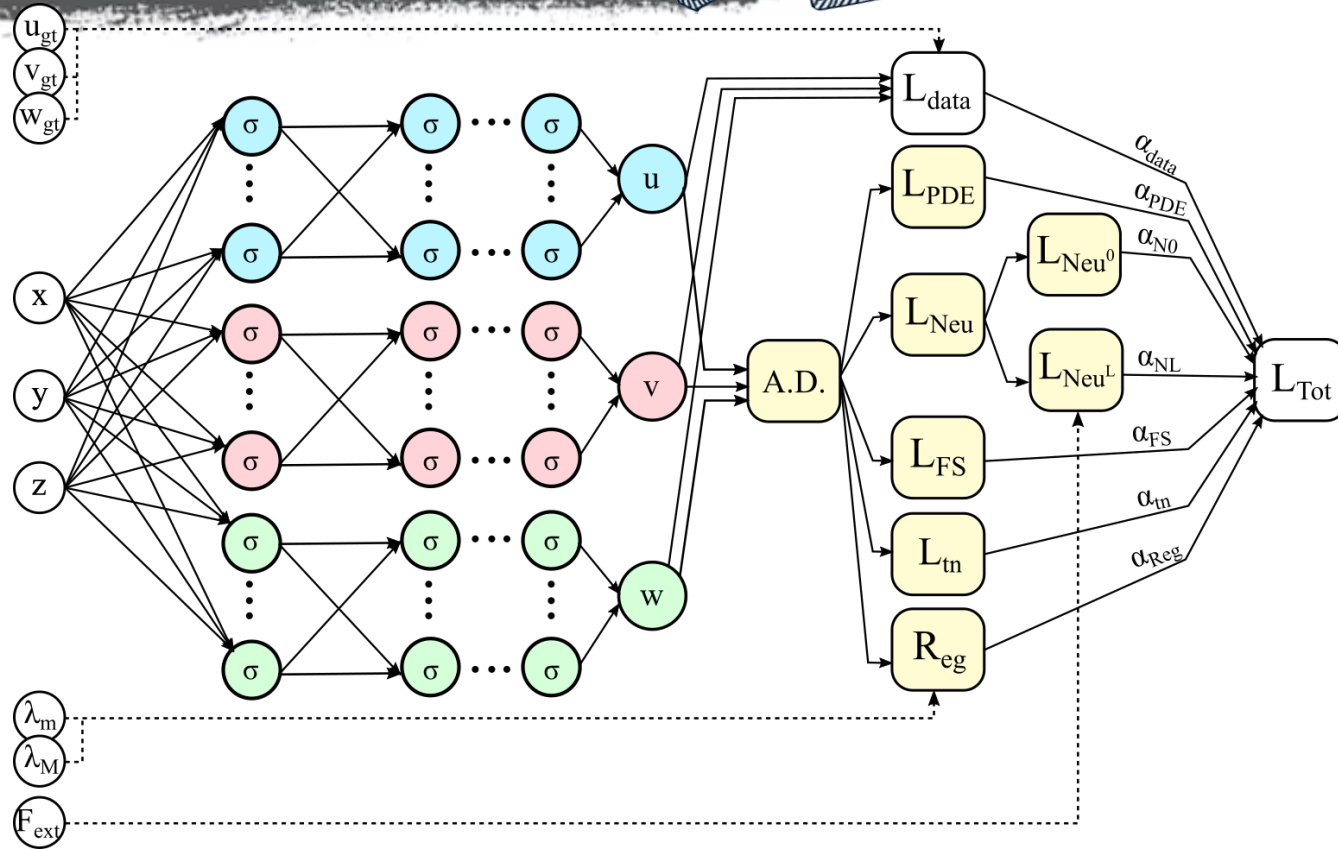


Aplicación a mecánica del sólido

Forward



PINN propuesta

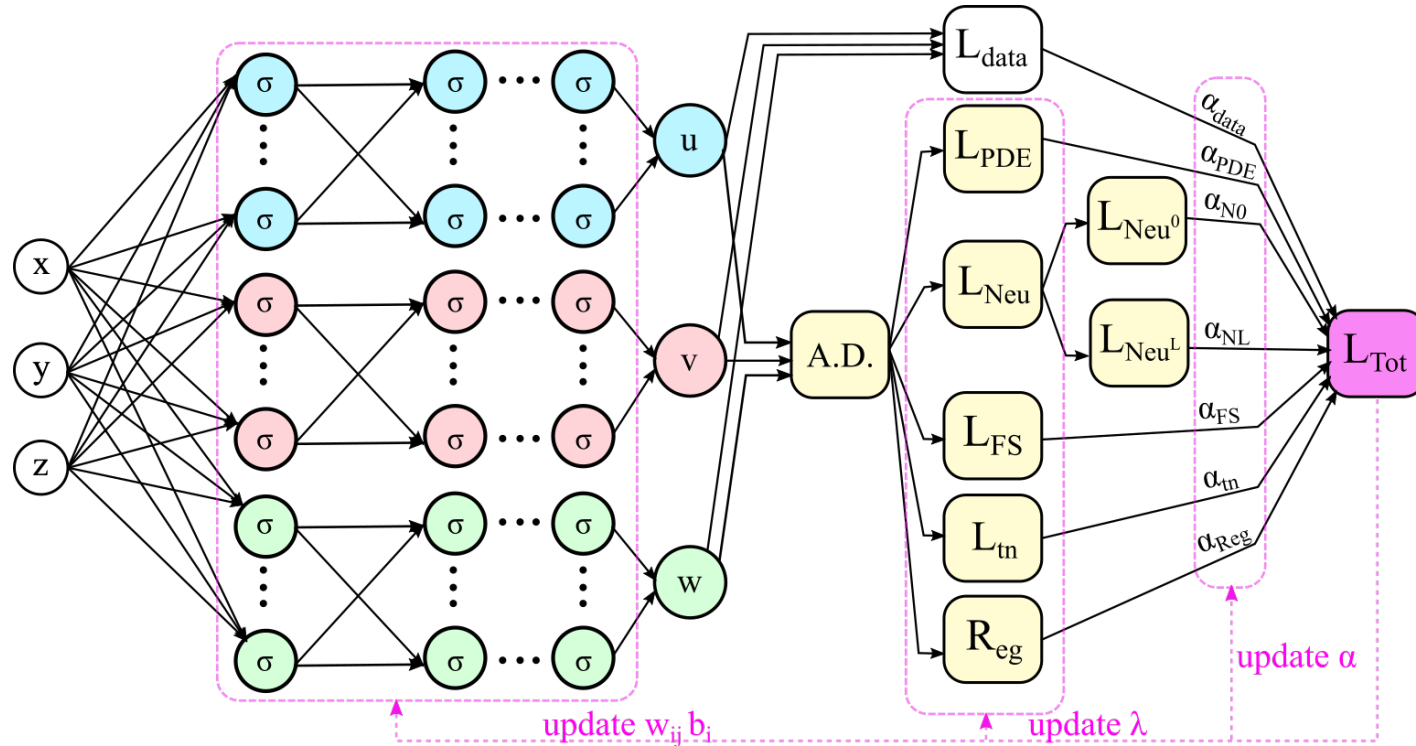


Aplicación a mecánica del sólido

Backward



PINN propuesta



Aplicación a mecánica del sólido

PINN propuesta

$$L_{Tot} = \left\{ \begin{array}{ll} \alpha_{data} L_{data} + & \longrightarrow \alpha_{dx} L_{dx} + \alpha_{dy} L_{dy} + \alpha_{dz} L_{dz} \\ \alpha_{PDE} L_{PDE} + & \longrightarrow \text{Minimiza el residuo de la PDE} \\ \alpha_{N0} L_{Neu^0} + & \longrightarrow \text{Aplica la condición de borde libre} \\ \alpha_{NL} L_{Neu^L} + & \longrightarrow \text{Aplica la condición de borde cargada} \\ \alpha_{FS} L_{FS} + & \longrightarrow \text{Aplica deslizamiento sin fricción en el contacto} \\ \alpha_{t_n} L_{t_n} + & \longrightarrow \text{Aplica condición de presión de contacto negativa} \\ \alpha_{Reg} R_{eg} & \longrightarrow \text{Restringe el rango posible de valores del parámetro material} \end{array} \right.$$

Aplicación a mecánica del sólido

PINN propuesta

$$L_{Tot} = \left\{ \begin{array}{ll} \alpha_{data} L_{data} + & \longrightarrow \alpha_{dx} L_{dx} + \alpha_{dy} L_{dy} + \alpha_{dz} L_{dz} \\ \alpha_{PDE} L_{PDE} + & \longrightarrow \text{Minimiza el residuo de la PDE} \\ \alpha_{N0} L_{Neu^0} + & \longrightarrow \text{Aplica la condición de borde libre} \\ \alpha_{NL} L_{Neu^L} + & \longrightarrow \text{Aplica la condición de borde cargada} \\ \alpha_{FS} L_{FS} + & \longrightarrow \text{Aplica deslizamiento sin fricción en el contacto} \\ \alpha_{t_n} L_{t_n} + & \longrightarrow \text{Aplica condición de presión de contacto negativa} \\ \alpha_{Reg} R_{Reg} & \longrightarrow \text{Restringe el rango posible de valores del parámetro material} \end{array} \right.$$



Aplicación a mecánica del sólido

PINN propuesta

$$\alpha_{data} L_{data} = \alpha_{dx} L_{dx} + \alpha_{dy} L_{dy} + \alpha_{dz} L_{dz}$$

$$L_{dx} = \frac{1}{N_d} \sum_{i=1}^{N_d} \|u_{NN_i} - u_{gt_i}\|^2$$

Cada loss es calculada como el MSE de las correspondientes componentes del desplazamiento.

$$L_{dy} = \frac{1}{N_d} \sum_{i=1}^{N_d} \|v_{NN_i} - v_{gt_i}\|^2$$

Como los nodos con desplazamiento nulo corresponden al grupo de N_d puntos en los que se conocen los datos, la condición de borde de Dirichlet queda impuesta a través de esta los. Esta forma de aplicar las condiciones de borde se conoce como "soft constrain"

$$L_{dz} = \frac{1}{N_d} \sum_{i=1}^{N_d} \|w_{NN_i} - w_{gt_i}\|^2$$

Aplicación a mecánica del sólido

PINN propuesta

$$\alpha_{PDE} L_{PDE}$$

Minimiza el residuo de la ley que gobierna el sistema (PDE)

$$L_{PDE} = \frac{1}{N_c} \sum_{i=1}^{N_c} \|Res(\mathbf{x}_i)\|^2$$

Mean square error del residuo

$$Res(\mathbf{x}_i) = \nabla \cdot \mathbf{P}(\mathbf{x}_i) + \mathbf{b}(\mathbf{x}_i)$$

Equilibrio mecánico (forma fuerte)

$$\mathbf{P} = \mathbf{F}\mathbf{S}$$

Primer tensor de tensiones de Piola-Kirchhoff

$$\mathbf{F} = \nabla_m \chi = \mathbf{I} + \nabla_m \mathbf{u}$$

Tensor del gradiente de la deformación

$$\mathbf{S} = 2 \frac{\partial \psi}{\partial \mathbf{C}}$$

Tensor de tensiones de Cosserat

$$\mathbf{C} = \mathbf{F}^T \mathbf{F}$$

Tensor de deformaciones de Cauchy-Green derecho

$$\psi(\mathbf{C}) = \frac{G}{2} (\text{tr}(\mathbf{C}) - 3) - G \ln(J) + \left(\frac{K}{2} - \frac{G}{3} \right) \text{Función de densidad de energía de deformación (Neo-Hookean)}$$

Aplicación a mecánica del sólido

PINN propuesta

$$\alpha_{N_0} L_{Neu}^0$$



Aplica la condición de borde sin carga

$$L_{Neu}^0 = \frac{1}{N_{N_0}} \sum_{i=1}^{N_{N_0}} \|\mathbf{t}\|^2$$

Mean square error de la norma de la tensión superficial

$$\mathbf{t} = \sigma \cdot \hat{\mathbf{n}}$$


\mathbf{t} : tensión sobre la superficie en el punto con normal \mathbf{n}

$$\sigma = J^{-1} F S F^T$$

Tensor de tensiones de Cauchy

$$J = \sqrt{|C|}$$

Módulo de compresibilidad



Aplicación a mecánica del sólido

PINN propuesta

 $\alpha_{NL} L_{NeuL}$

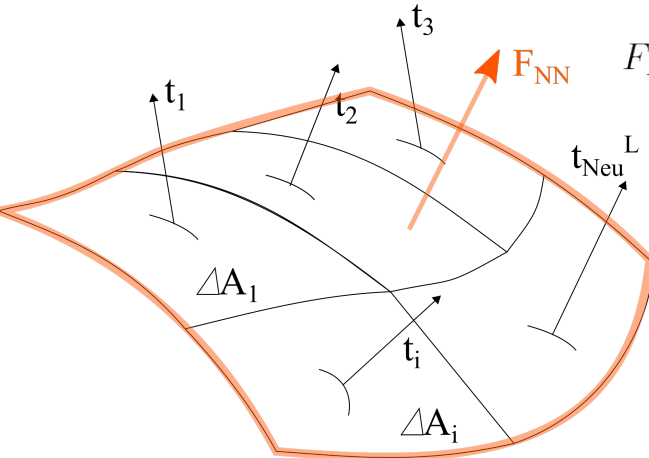
Aplica la condición de borde de carga

$$L_{NeuL} = \left\| \frac{\mathbf{F}_{ext} - \mathbf{F}_{NN}}{\|\mathbf{F}_{ext}\|} \right\|^2$$

Equilibrio de fuerzas en la superficie

$$F_{NN} = \int_{\partial\Omega} \mathbf{t} dA \approx \sum_{i=1}^{N_{NL}} \mathbf{t}_i \cdot \Delta A_i = \sum_{i=1}^{N_{NL}} \sigma_i \cdot \hat{\mathbf{n}}_i \cdot \Delta A_i$$

Aproximación de las fuerzas internas sobre la superficie cargada



Aplicación a mecánica del sólido

PINN propuesta

$\alpha_{FS} L_{FS}$ \longrightarrow Aplica el deslizamiento sin fricción en el contacto

$$L_{FS} = \frac{1}{N_{FS}} \sum_{i=1}^{N_{FS}} \|\mathbf{s}_i\|^2$$

MSE de la tensión cortante \mathbf{s} en cada nodo de N_{FS}

$$\sigma = (1/J) F S F^T \quad \rightarrow \quad \mathbf{t} = \sigma \cdot \mathbf{n}$$

Tensor de tensiones de Cauchy
 \rightarrow Tensión superficial

$$\mathbf{t}_a = \frac{\mathbf{t} \times \mathbf{n}}{\|\mathbf{t} \times \mathbf{n}\|} \quad \mathbf{t}_b = \frac{\mathbf{n} \times \mathbf{t}_a}{\|\mathbf{n} \times \mathbf{t}_a\|}$$


Vectores tangenciales a la superficie

$$\mathbf{s}_a = \mathbf{t} \cdot \mathbf{t}_a \quad \mathbf{s}_b = \mathbf{t} \cdot \mathbf{t}_b$$

Vectores de tensión cortante

$$\|\mathbf{s}\| = \sqrt{\|\mathbf{s}_a\|^2 + \|\mathbf{s}_b\|^2}$$

Norma de la tensión cortante equivalente



Aplicación a mecánica del sólido

PINN propuesta

$\alpha_{t_n} L_{t_n}$ \longrightarrow Aplica la condición de negatividad de las tensiones en el contacto

$$L_{t_n} = \frac{1}{N_{t_n}} \sum_{i=1}^{N_{t_n}} \|Penalty(i)\|^2$$


MSE de la función de penalización de la componente de tensión normal a la superficie en cada nodo N_{FS}

$$\mathbf{t}_n = \mathbf{t} \cdot \mathbf{n}$$

Componente normal de la tensión superficial

$$Penalty = \frac{1}{2} [1 + sg(\mathbf{t}_n)] \mathbf{t}_n$$

Función de penalización de la componente normal de la tensión superficial



Aplicación a mecánica del sólido


PINN propuesta

$\alpha_{Reg} L_{Reg}$

a)



Restringe el rango en el que puede variar el parámetro a ser identificado




Considerando que λ es el parámetro a ser identificado
 Se setean los valores mínimo y máximo que puede valer λ por el conocimiento del material aproximado $\rightarrow [\lambda_m, \lambda_M]$
 Luego α parametriza el rango de λ entre $[-1, 1]$

$$\alpha = 2 \frac{\lambda_{NN} - \lambda_m}{\lambda_M - \lambda_m} - 1$$

La regularización penaliza si la red predice valores de α mayores a 1 o menores a -1, según:

$$Reg = \begin{cases} Ampl(\min - \alpha)^2 & \text{si: } \alpha < \min \\ 0.0 & \text{si: } \alpha \in [-1;1] \\ Ampl(\alpha - \max)^2 & \text{si: } \alpha > \max \end{cases}$$

Por lo tanto penaliza valores de λ mayores que λ_M o menores que λ_m



Aplicación a mecánica del sólido

PINN propuesta

$$L_{Tot} = \left\{ \begin{array}{l} \alpha_{data} L_{data} + \\ \alpha_{PDE} L_{PDE} + \\ \alpha_{N0} L_{Neu^0} + \\ \alpha_{NL} L_{Neu^L} + \\ \alpha_{FS} L_{FS} + \\ \alpha_{KKT} L_{KKT} + \\ \alpha_{Reg} L_{Reg} \end{array} \right.$$

Existen numerosas técnicas para seleccionar o calcular los pesos de las losses, aquí tenemos implementado 4:

1. **Coefficient of Variance** (Ajusta los pesos según la varianza acumulada de las losses) **No buenos resultados**
2. **Adaptive Weights** (The network aprende los pesos de la misma manera que con los parámetros de la red) **Buenos resultados en algunos casos**
3. **Residual-Based attention** (Ajusta los éspns de acuerdo al error correspondiente en cada loss relativo al maximo) **Buenos resultados en algunos casos**
4. **Self-Adaptative Residual Minimization** (Maximiza los pesos de acuerdo al gradiente de la loss con momentum activado) **Los Mejores resultados hasta ahora**



Resultados de caso

Datos digitales

Resultados de caso

$Lr = 1e-1$

L-BGFS optimizer

120 data points only on surfaces(25x4 + 10x2)




2000 collocation points

100 points on no-loaded surfaces


190 points on contact surfaces

198 points on loaded surface

Datos digitales





Resultados de caso



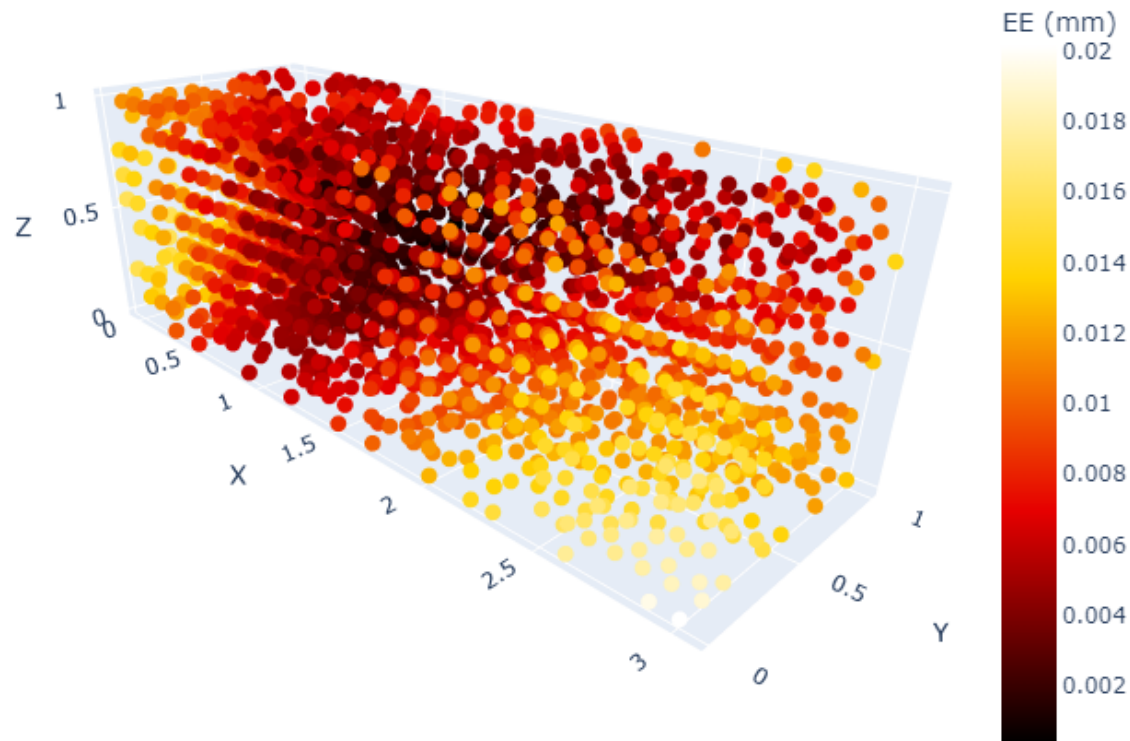
Identificación de K y G

$$G_{\text{real}} = 1.538 \mid G_{\text{NN}} = 1.570 \text{ (2.1\% de error)}$$

$$K_{\text{real}} = 3.333 \mid K_{\text{NN}} = 3.107 \text{ (6.8 \% de error)}$$



Resultados de caso



Otras métricas de error

Usando 2000 puntos de prueba:


MEE: 0.00765mm

MREE: 1.5 %

99.95 % de los pts tienen $EE < 0.02$ mm

MAE: [0.00577 0.00187 0.00351] mm

MRAE: [0.337 0.726 1.364] %





Ejemplo


ANTES DEL EJEMPLO

¿¿ ALGUNA PREGUNTA ??



Ejemplo


Placa 2D de $L_x = 30\text{mm}$, $L_y = 10\text{mm}$.
Elástico isotrópico con: $E = 10\text{ MPa}$, $\nu = 0.3$



Características del ejemplo

Ejemplo

Placa 2D de $L_x = 30\text{mm}$, $L_y = 10\text{mm}$.
Elástico isotrópico con: $E = 10\text{ MPa}$, $\nu = 0.3$
Extremo izquierdo fijo deslizante



Características del ejemplo


Ejemplo

Placa 2D de $L_x = 30\text{mm}$, $L_y = 10\text{mm}$.

Elástico isotrópico con: $E = 10\text{ MPa}$, $\nu = 0.3$

Extremo izquierdo fijo deslizante

Fuerza en el extremo: $T = 1\text{N}$



Características del ejemplo

Ejemplo

Placa 2D de $L_x = 30\text{mm}$, $L_y = 10\text{mm}$.

Elástico isotrópico com: $E = 10\text{ MPa}$, $\nu = 0.3$


Extremo izquierdo fijo deslizante

Fuerza en el extremo: $T = 1\text{ N}$

Aplicando equilibrio puntual


Características del ejemplo

$$Res(\mathbf{x}_i) = \nabla \cdot P(\mathbf{x}_i) + b(\mathbf{x}_i)$$



Ejemplo

Placa 2D de $L_x = 30\text{mm}$, $L_y = 10\text{mm}$.
Elástico isotrópico com: $E = 10\text{ MPa}$, $\nu = 0.3$
Extremo izquierdo fijo deslizante
Fuerza en el extremo: $T = 1\text{ N}$
Estado plano de tensiones




Características del ejemplo

$$Res(\mathbf{x}_i) = \nabla \cdot \mathbf{P}(\mathbf{x}_i) + b(\mathbf{x}_i)$$

$$\mathbf{P} = G \begin{pmatrix} \frac{2}{1-\nu}(u_x + \nu v_y) & u_x + v_y \\ u_x + v_y & \frac{2}{1-\nu}(v_y + \nu u_x) \end{pmatrix}$$

Ejemplo

Placa 2D de $L_x = 30\text{mm}$, $L_y = 10\text{mm}$.
Elástico isotrópico com: $E = 10\text{ MPa}$, $\nu = 0.3$
Extremo izquierdo fijo deslizante
Fuerza en el extremo: $T = 1\text{N}$
Aplicando gradiente y despreciando b



Características del ejemplo


$$Res(\mathbf{x}_i) = \nabla \cdot \mathbf{P}(\mathbf{x}_i) + b(\mathbf{x}_i)$$

$$\mathbf{P} = G \begin{pmatrix} \frac{2}{1-\nu}(u_x + \nu v_y) & u_x + v_y \\ u_x + v_y & \frac{2}{1-\nu}(v_y + \nu u_x) \end{pmatrix}$$

$$\nabla \cdot \mathbf{P} = G \begin{pmatrix} \frac{2}{1-\nu} \nu (u_{xx} + \nu v_{yx}) + u_{xy} + v_{yy} \\ \frac{2}{1-\nu} (v_{yy} + \nu u_{xy}) + u_{xx} + v_{yx} \end{pmatrix} = 0$$

Ejemplo

Placa 2D de $L_x = 30\text{mm}$, $L_y = 10\text{mm}$.
Elástico isotrópico com: $E = 10\text{ MPa}$, $\nu = 0.3$
Extremo izquierdo fijo deslizante
Fuerza en el extremo: $T = 1\text{ N}$
Condición de borde de desplazamiento nulo



Características del ejemplo

$$Res(\mathbf{x}_i) = \nabla \cdot \mathbf{P}(\mathbf{x}_i) + b(\mathbf{x}_i)$$

$$\mathbf{P} = G \begin{pmatrix} \frac{2}{1-\nu}(u_x + \nu v_y) & u_x + v_y \\ u_x + v_y & \frac{2}{1-\nu}(v_y + \nu u_x) \end{pmatrix}$$


$$\nabla \cdot \mathbf{P} = G \begin{pmatrix} \frac{2}{1-\nu}(u_{xx} + \nu v_{yx}) + u_{xy} + v_{yy} \\ \frac{2}{1-\nu}(v_{yy} + \nu u_{xy}) + u_{xx} + v_{yx} \end{pmatrix} = 0$$

$$\text{— } \mathbf{u}(\mathbf{x}) \cdot (\mathbf{e}_1) = 0 \quad \forall \mathbf{x} \in \partial\Omega_X$$

$$\text{— } \mathbf{u}(\mathbf{x}) \cdot (\mathbf{e}_2) = 0 \quad \forall \mathbf{x} \in \partial\Omega_Y$$

Ejemplo

Placa 2D de $L_x = 30\text{mm}$, $L_y = 10\text{mm}$.
 Elástico isotrópico com: $E = 10\text{ MPa}$, $\nu = 0.3$
 Extremo izquierdo fijo deslizante
 Fuerza en el extremo: $T = 1\text{N}$
Condición de borde de carga



Características del ejemplo

$$Res(\mathbf{x}_i) = \nabla \cdot \mathbf{P}(\mathbf{x}_i) + b(\mathbf{x}_i)$$

$$\mathbf{P} = G \begin{pmatrix} \frac{2}{1-\nu}(u_x + \nu v_y) & u_x + v_y \\ u_x + v_y & \frac{2}{1-\nu}(v_y + \nu u_x) \end{pmatrix}$$

$$\nabla \cdot \mathbf{P} = G \begin{pmatrix} \frac{2}{1-\nu}(u_{xx} + \nu v_{yx}) + u_{xy} + v_{yy} \\ \frac{2}{1-\nu}(v_{yy} + \nu u_{xy}) + u_{xx} + v_{yx} \end{pmatrix} = 0$$

$$\mathbf{u}(\mathbf{x}) \cdot (\mathbf{e}_1) = 0 \quad \forall \mathbf{x} \in \partial\Omega_X$$

$$\mathbf{u}(\mathbf{x}) \cdot (\mathbf{e}_2) = 0 \quad \forall \mathbf{x} \in \partial\Omega_Y$$


$$\mathbf{P}(\mathbf{x})[\mathbf{e}_1] = t \quad \forall \mathbf{x} \in \partial\Omega_{L_x}$$

$$\mathbf{P}(\mathbf{x})[\mathbf{e}_2] = 0 \quad \forall \mathbf{x} \in \partial\Omega_{L_y}$$

Ejemplo

Placa 2D con $L_x = 30\text{mm}$, $L_y = 20\text{mm}$
 Elástico isotrópico con: $E = 100\text{MPa}$, $\nu = 0.3$
 Extremo izquierdo fijo deslizante
 Fuerza en el extremo: $t = 1\text{MPa}$
 Condición de borde de carga

VEAMOS UN POCO DE CÓDIGO



Características del ejemplo

$$Res(x_i) = \nabla \cdot P(x_i) + b(x_i)$$

$$P = G \begin{pmatrix} 2(u_x + \nu v_y) & u_x + v_y \\ u_x + v_y & 2(\nu u_x + v_y) \end{pmatrix}$$

$$\begin{pmatrix} u_x + \nu u_y & v_{yy} \\ \nu u_x + v_y & u_{xx} + v_{yy} \end{pmatrix} = 0$$

$$u(x) \cdot (e_1) = 0 \quad \forall x \in \partial \Omega_X$$

$$u(x) \cdot (e_2) = 0 \quad \forall x \in \partial \Omega_Y$$

$$P(x)[e_1] = t \quad \forall x \in \partial \Omega_{L_x}$$

$$P(x)[e_2] = 0 \quad \forall x \in \partial \Omega_{L_y}$$



UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY



Seminario en redes neuronales basadas en la Física

PINNs

[Physics-Informed Neural Networks]

GRACIAS

MSc. Ing. Christian Díaz-Cuadro

¿Preguntas?

