

Fundamentos de Aprendizaje Automático y Reconocimiento de Patrones

Práctico 4

Instituto de Ingeniería Eléctrica
Facultad de Ingeniería

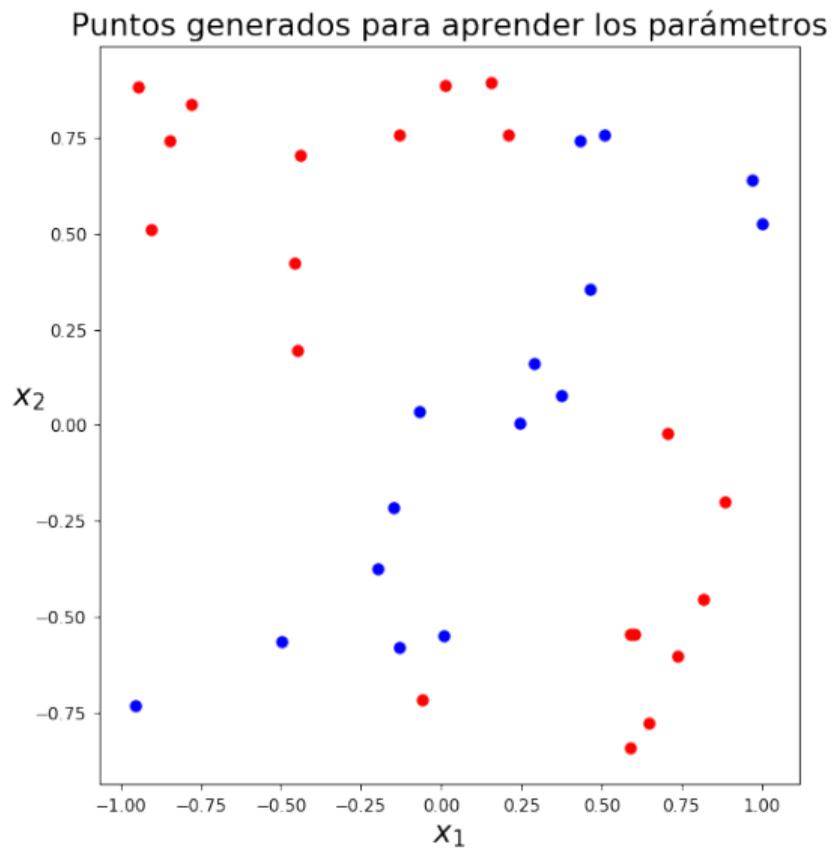


UNIVERSIDAD
DE LA REPÚBLICA
URUGUAY

- ① Ejercicio 1: regularización con *weight decay*
- ② Ejercicio 2: Curvas de aprendizaje
- ③ Ejercicio 3: Regresión polinómica regularizada
- ④ Ejercicio 4: Predicción del valor medio de las casas

- 1 Ejercicio 1: regularización con *weight decay*
- 2 Ejercicio 2: Curvas de aprendizaje
- 3 Ejercicio 3: Regresión polinómica regularizada
- 4 Ejercicio 4: Predicción del valor medio de las casas

Ejercicio 1: regularización con *weight decay*



Ejercicio 1: regularización con *weight decay*

La función de costo que se minimiza mediante el criterio de mínimos cuadrados es:

$$w^* = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{in}}(w) = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} \frac{1}{N} \|Xw - y\|^2$$

- Solución cerrada

$$w^* = X^\dagger y = (X^T X)^{-1} X^T y$$

La función de costo que se minimiza para implementar *weight decay*:

$$w^* = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{aug}}(w) = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{in}}(w) + \frac{\lambda}{N} w^T w$$

Consigna: Hallar la solución cerrada en este caso e implementarla (*regresion_Ridge()*)

Ejercicio 1: regularización con *weight decay*

La función de costo que se minimiza mediante el criterio de mínimos cuadrados es:

$$w^* = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{in}}(w) = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} \frac{1}{N} \|Xw - y\|^2$$

- Solución cerrada

$$w^* = X^\dagger y = (X^T X)^{-1} X^T y$$

La función de costo que se minimiza para implementar *weight decay*:

$$w^* = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{aug}}(w) = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{in}}(w) + \frac{\lambda}{N} w^T w$$

Consigna: Hallar la solución cerrada en este caso e implementarla (*regresion_Ridge()*)

Ejercicio 1: regularización con *weight decay*

La función de costo que se minimiza mediante el criterio de mínimos cuadrados es:

$$w^* = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{in}}(w) = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} \frac{1}{N} \|Xw - y\|^2$$

- Solución cerrada

$$w^* = X^\dagger y = (X^T X)^{-1} X^T y$$

La función de costo que se minimiza para implementar *weight decay*:

$$w^* = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{aug}}(w) = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{in}}(w) + \frac{\lambda}{N} w^T w$$

Consigna: Hallar la solución cerrada en este caso e implementarla (*regresion_Ridge()*)

Ejercicio 1: regularización con *weight decay*

La función de costo que se minimiza mediante el criterio de mínimos cuadrados es:

$$w^* = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{in}}(w) = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} \frac{1}{N} \|Xw - y\|^2$$

- Solución cerrada

$$w^* = X^\dagger y = (X^T X)^{-1} X^T y$$

La función de costo que se minimiza para implementar *weight decay*:

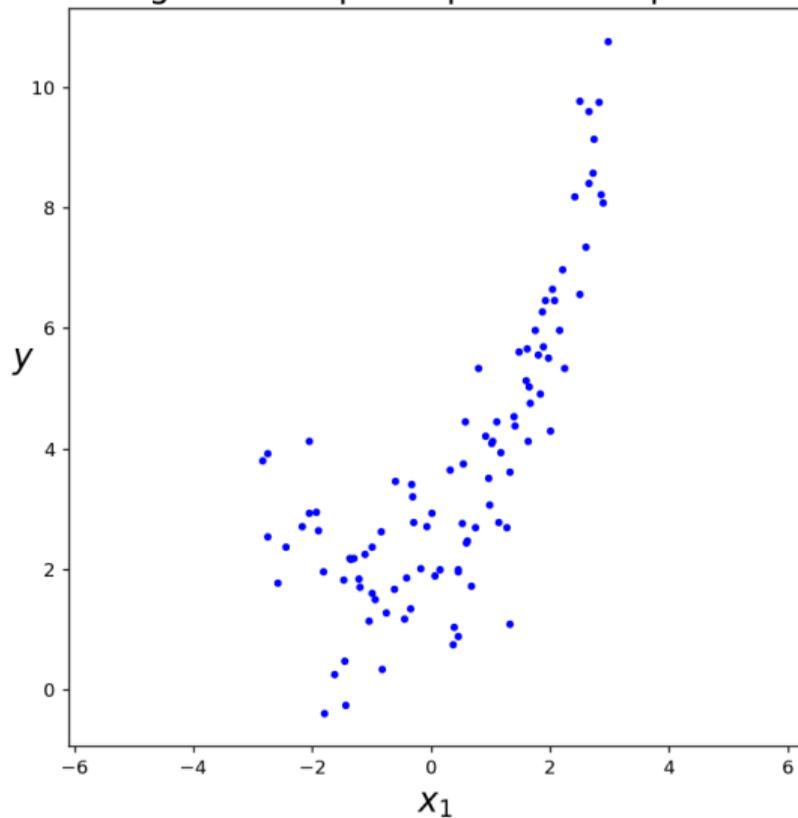
$$w^* = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{aug}}(w) = \operatorname{argmin}_{w \in \mathbb{R}^{d+1}} E_{\text{in}}(w) + \frac{\lambda}{N} w^T w$$

Consigna: Hallar la solución cerrada en este caso e implementarla (*regresion_Ridge()*)

- ① Ejercicio 1: regularización con *weight decay*
- ② Ejercicio 2: Curvas de aprendizaje
- ③ Ejercicio 3: Regresión polinómica regularizada
- ④ Ejercicio 4: Predicción del valor medio de las casas

Ejercicio 2: curvas de aprendizaje

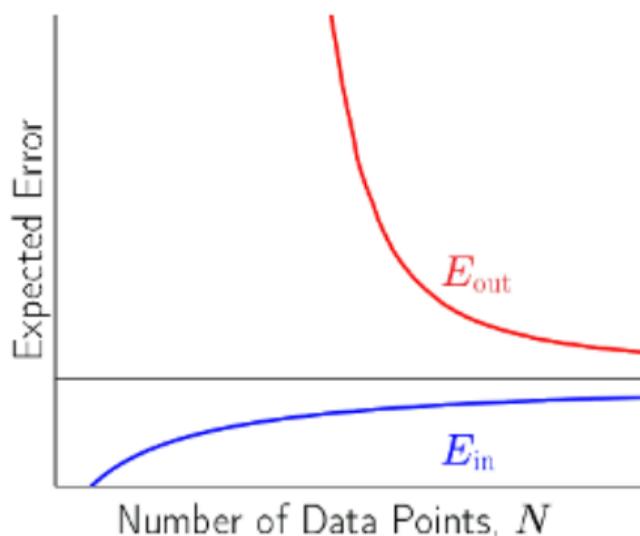
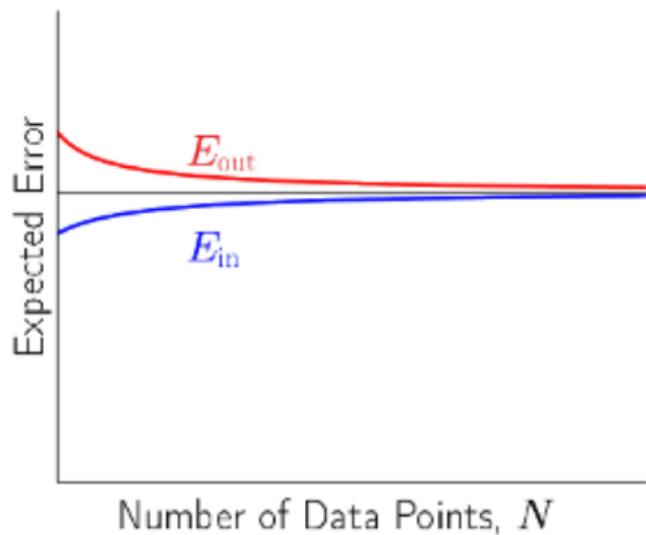
Puntos generados para aprender los parámetros



Ejercicio 2: curvas de aprendizaje

- Implementar *transformacion_polinomial()*
- Utilizar *regresion_lineal()* del **Ejercicio 1**
- Mostrar el resultado de aplicar el modelo a un conjunto de datos de validación

Ejercicio 2: curvas de aprendizaje



- Implementar `generar_curva_aprendizaje()`
- Implementar `mse()`

$$mse = \frac{1}{N} \sum_{n=1}^N (y_n - w^T x)^2$$

Ejercicio 2: curvas de aprendizaje

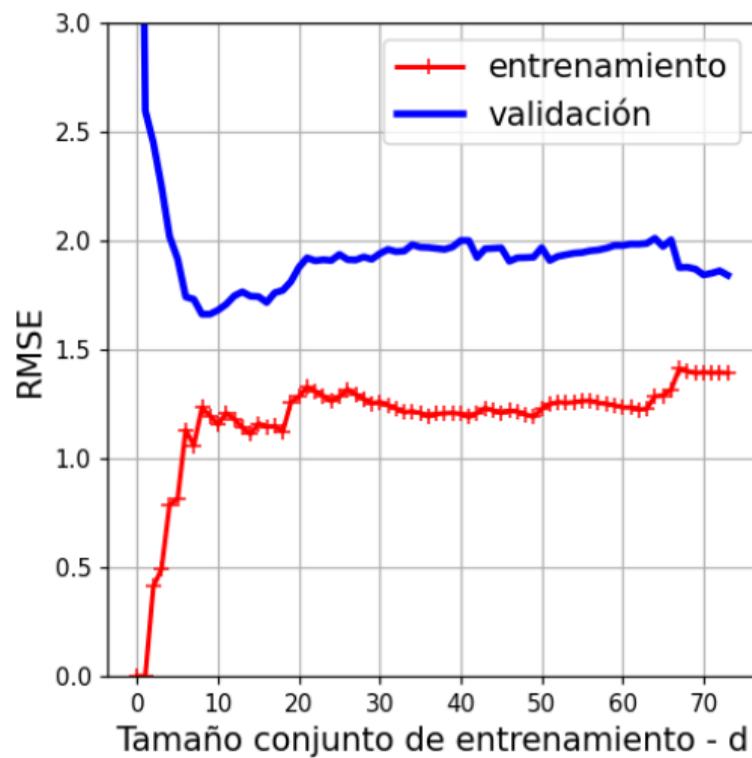


Figure: Curva de aprendizaje modelo lineal

Ejercicio 2: curvas de aprendizaje



Figure: Curva de aprendizaje modelo lineal

Ejercicio 2: curvas de aprendizaje



Figure: Curva de aprendizaje modelo lineal

Ejercicio 2: curvas de aprendizaje

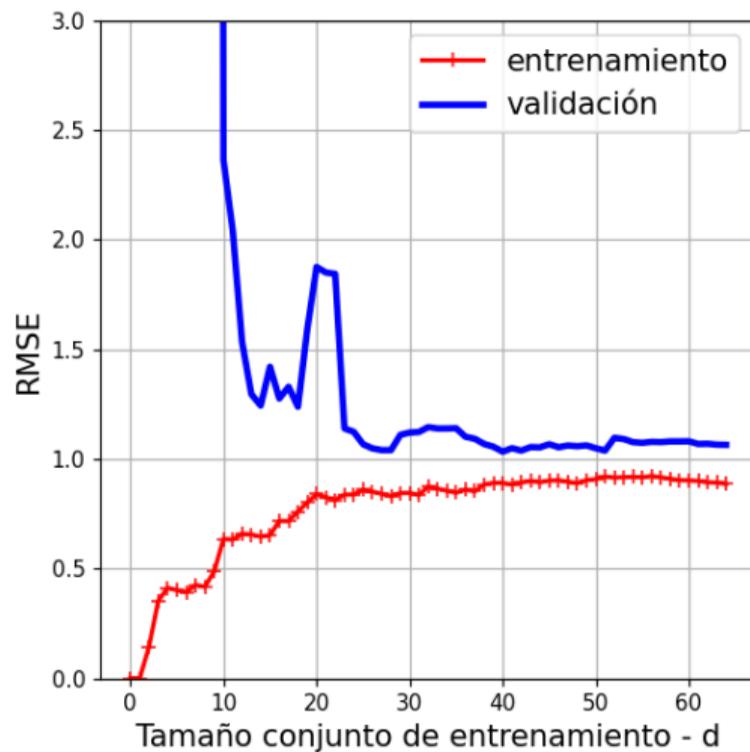


Figure: Curva de aprendizaje modelo orden 10

Ejercicio 2: curvas de aprendizaje



Figure: Curva de aprendizaje modelo orden 10

Ejercicio 2: curvas de aprendizaje

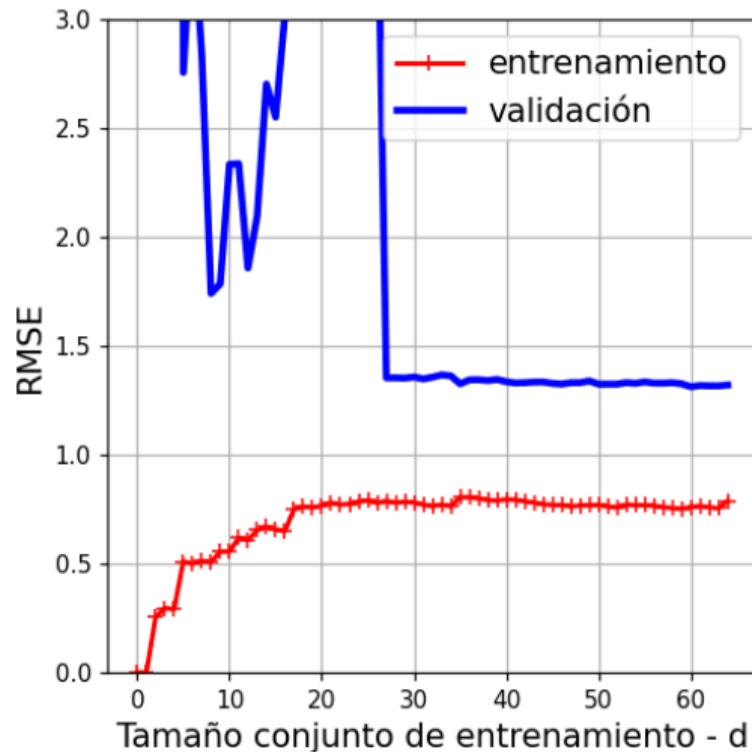
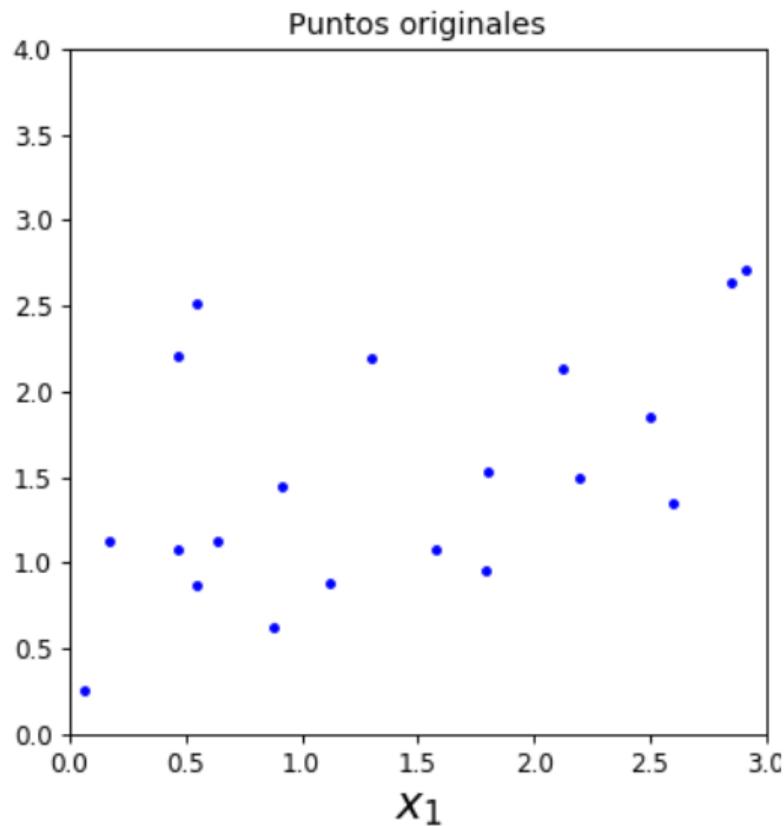


Figure: Curva de aprendizaje modelo orden 10

- ① Ejercicio 1: regularización con *weight decay*
- ② Ejercicio 2: Curvas de aprendizaje
- ③ Ejercicio 3: Regresión polinómica regularizada
- ④ Ejercicio 4: Predicción del valor medio de las casas

Ejercicio 3: regresión polinómica regularizada



Ejercicio 3: regresión polinómica regularizada

- Utilizar *regresion_Ridge()* del **Ejercicio 1**
- Implementar *comparar_regularizaciones()*
 - *transformacion_polinomial()* (ya implementado)
 - *regresion_Ridge()* (ya implementado)

Ejercicio 3: regresión polinómica regularizada

- En la regresión de Ridge se minimiza el error aumentado

$$\begin{aligned}E_{\text{aug}}(\mathbf{w}) &= E_{\text{in}}(\mathbf{w}) + \frac{\lambda}{N} \mathbf{w}^T \mathbf{w} \\ &= \frac{1}{N} \sum_{n=1}^N (\mathbf{w}^T \mathbf{z}_n - y_n)^2 + \frac{\lambda}{N} \mathbf{w}^T \mathbf{w} \\ &= \frac{1}{N} (\mathbf{Z}\mathbf{w} - \mathbf{y})^T (\mathbf{Z}\mathbf{w} - \mathbf{y}) + \frac{\lambda}{N} \mathbf{w}^T \mathbf{w} \\ &= \frac{1}{N} (\mathbf{w}^T \mathbf{Z}^T \mathbf{Z} \mathbf{w} - 2\mathbf{w}^T \mathbf{Z}^T \mathbf{y} + \mathbf{y}^T \mathbf{y}) + \frac{\lambda}{N} \mathbf{w}^T \mathbf{w}\end{aligned}$$

- Usando que

$$\nabla_{\mathbf{w}}(\mathbf{w}^T \mathbf{A} \mathbf{w}) = (\mathbf{A} + \mathbf{A}^T) \mathbf{w}, \quad \nabla_{\mathbf{w}}(\mathbf{w}^T \mathbf{b}) = \mathbf{b}, \quad \nabla_{\mathbf{w}}(\mathbf{w}^T \mathbf{w}) = 2\mathbf{w}$$

- Se obtiene

$$\mathbf{w}^* = (\mathbf{Z}^T \mathbf{Z} + \lambda \mathbf{I})^{-1} \mathbf{Z}^T \mathbf{y}$$

Ejercicio 3: regresión polinómica regularizada

```
def regresion_Ridge(X, y, reg, regularizar_bias=False):
    """
    Implementa la solución cerrada de la regresión de Ridge. En esta variante se
    permite elegir si se desea regularizar el bias (coeficiente  $w_0$ ) o no.
    Entrada:
        X: matriz de tamaño  $N \times (d+1)$ 
        y: valores objetivo
        reg: coeficiente que multiplica al término de regularización
        regularizar_bias: variable booleana que indica si se regulariza el término
            de bias o no.
    Salida:
        w_reg: parámetros encontrados mediante la regularización de Ridge
    """

    # Si no se regulariza el coeficiente  $w_0$  se pone el elemento  $[0,0]$ 
    # de la matriz identidad a cero
    reg_matrix = np.identity(X.shape[1])
    if not regularizar_bias:
        reg_matrix[0,0]=0

    #####
    ##### EMPIEZA ESPACIO PARA COMPLETAR CÓDIGO #####
    #####

    # w_reg =

    #####
    ##### TERMINA ESPACIO PARA COMPLETAR CÓDIGO #####
    #####

    return w_reg
```

Ejercicio 3: regresión polinómica regularizada

```
def regresion_Ridge(X, y, reg, regularizar_bias=False):
    ...
    Implementa la solución cerrada de la regresión de Ridge. En esta variante se
    permite elegir si se desea regularizar el bias (coeficiente  $w_0$ ) o no.
    Entrada:
        X: matriz de tamaño  $N \times (d+1)$ 
        y: valores objetivo
        reg: coeficiente que multiplica al término de regularización
        regularizar_bias: variable booleana que indica si se regulariza el término
            de bias o no.
    Salida:
        ... w_reg: parámetros encontrados mediante la regularización de Ridge
    ...

    # Si no se regulariza el coeficiente  $w_0$  se pone el elemento  $[0,0]$ 
    # de la matriz identidad a cero
    reg_matrix = np.identity(X.shape[1])
    if not regularizar_bias:
        reg_matrix[0,0]=0

    #####
    ##### EMPIEZA ESPACIO PARA COMPLETAR CÓDIGO #####
    #####

    # w_reg =
    w_reg = np.linalg.inv(X.T @ X + reg * reg_matrix) @ X.T @ y

    #####
    ##### TERMINA ESPACIO PARA COMPLETAR CÓDIGO #####
    #####

    return w_reg
```

Efecto de regularizar el bias

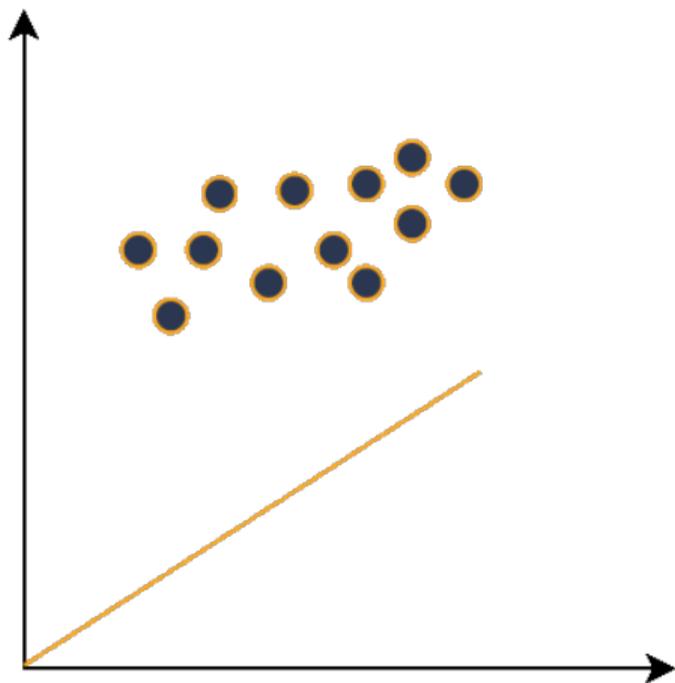


Figure: Regularizando fuertemente el bias

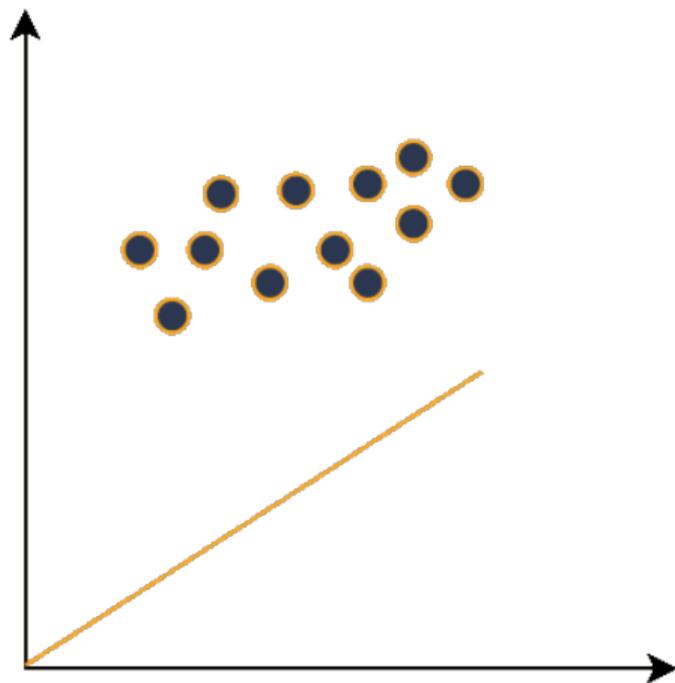


Figure: Sin regularizar el bias

Efecto de regularizar el bias

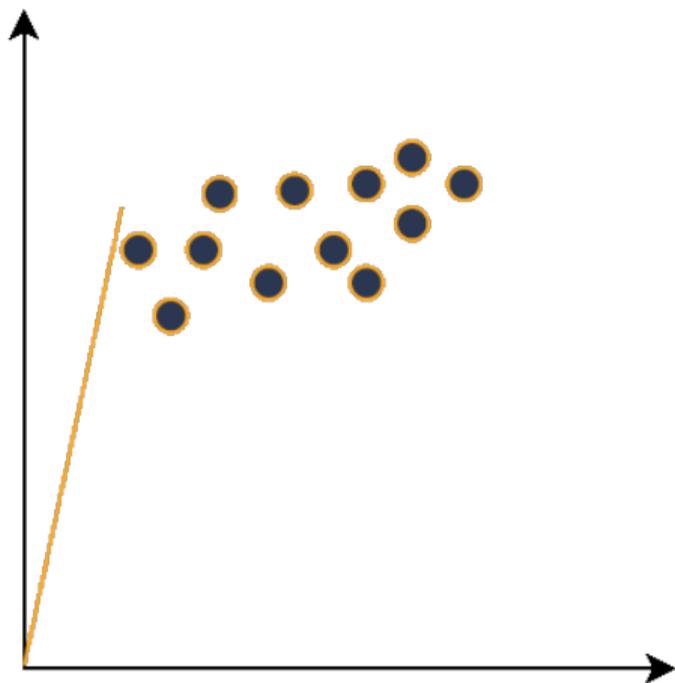


Figure: Regularizando fuertemente el bias

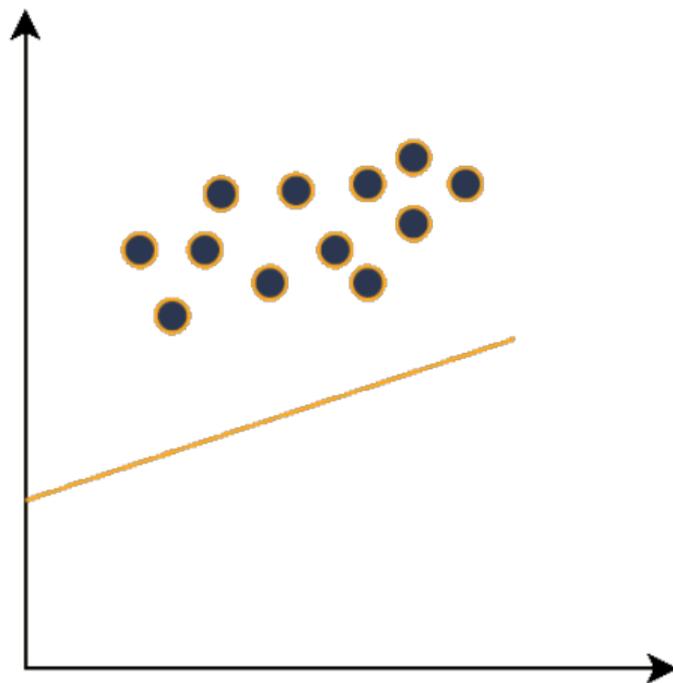


Figure: Sin regularizar el bias

Efecto de regularizar el bias

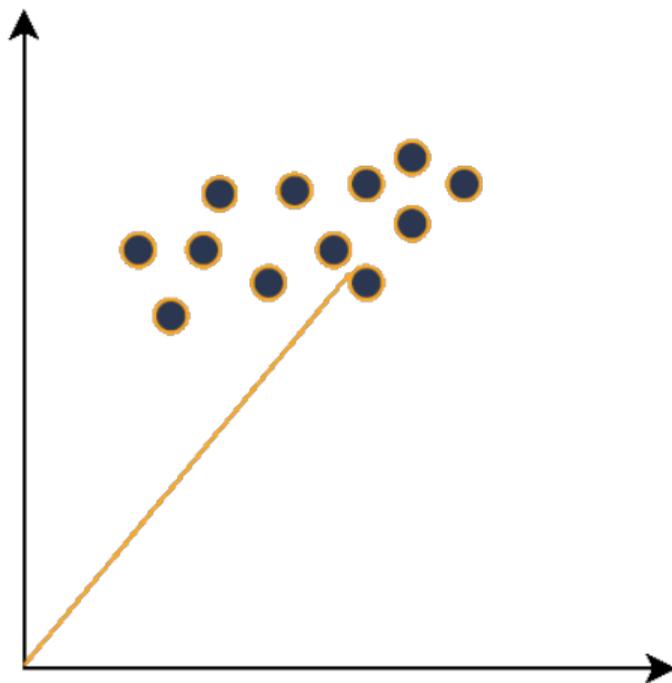


Figure: Regularizando fuertemente el bias

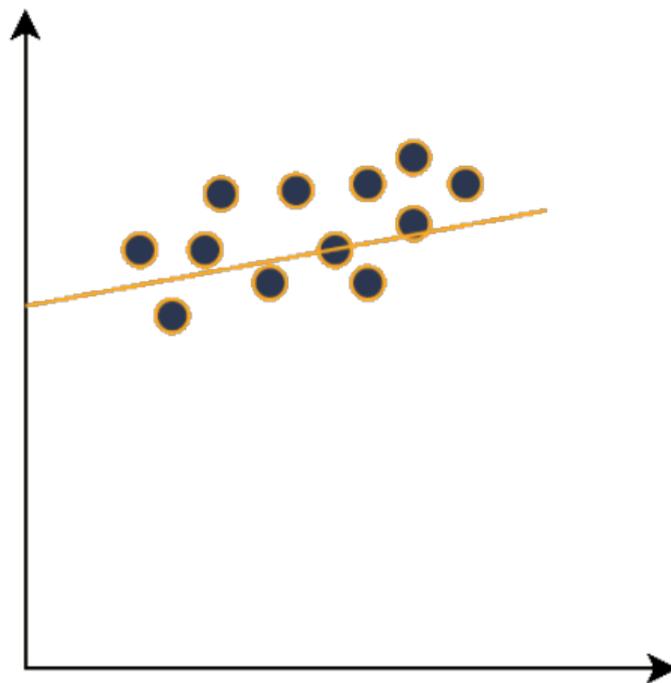


Figure: Sin regularizar el bias

Efecto de regularizar el bias

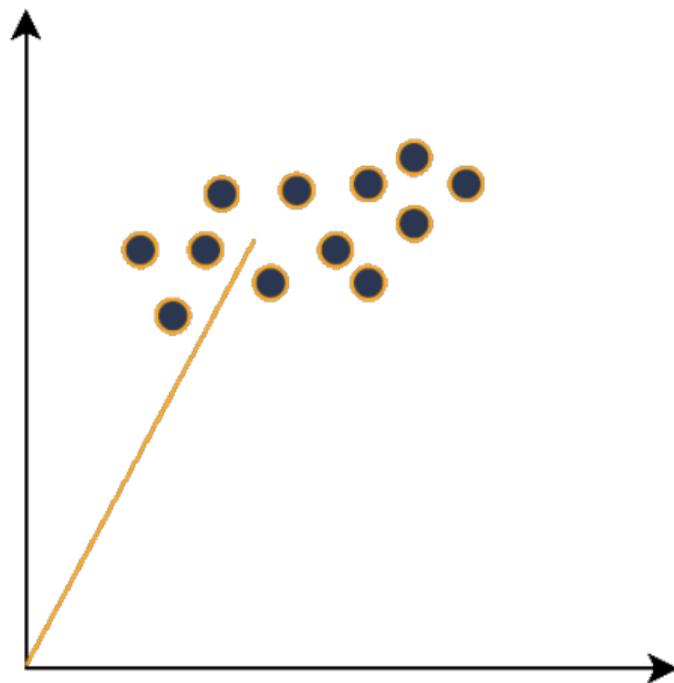


Figure: Regularizando fuertemente el bias

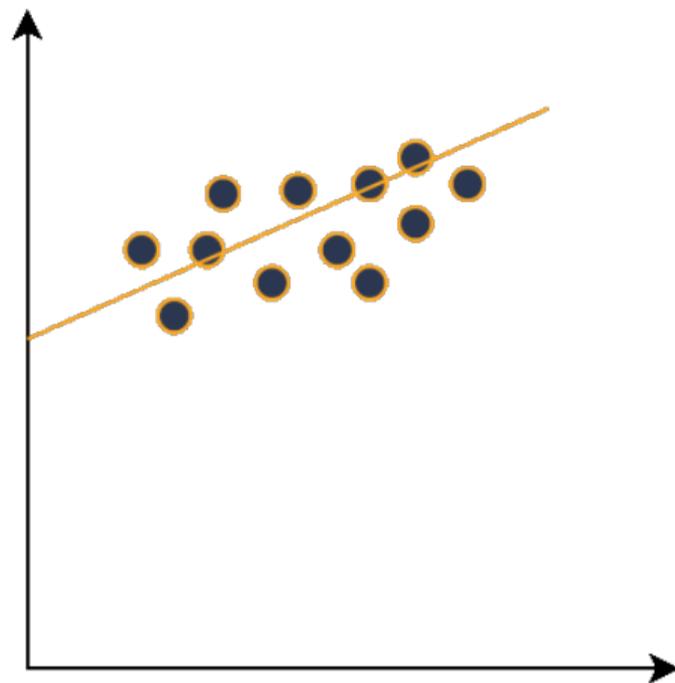


Figure: Sin regularizar el bias

Efecto de regularizar el bias

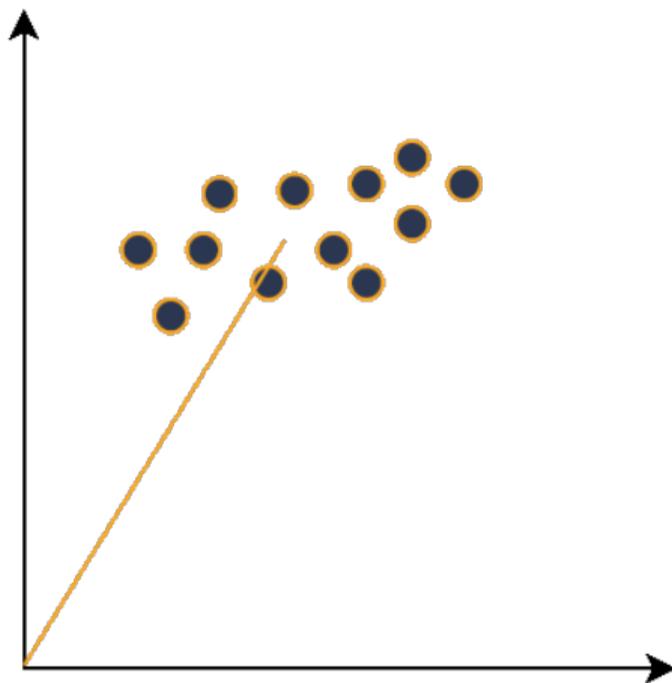


Figure: Regularizando fuertemente el bias

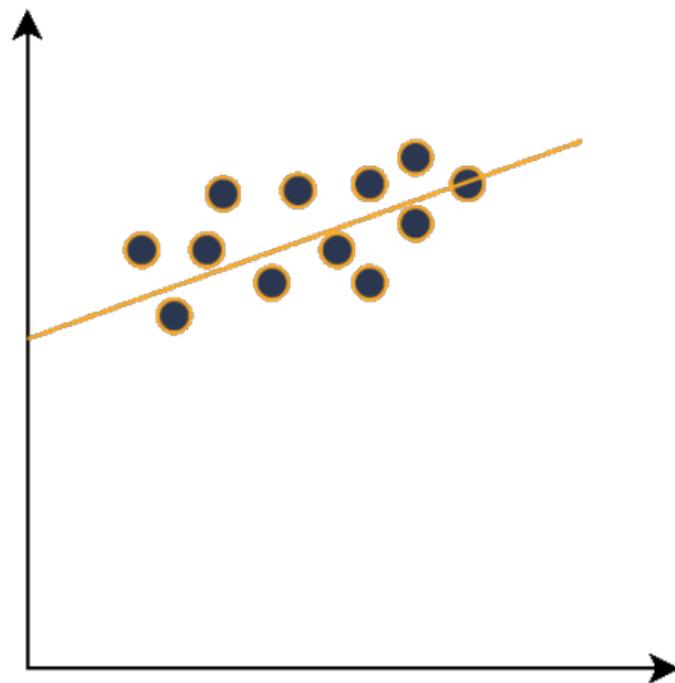
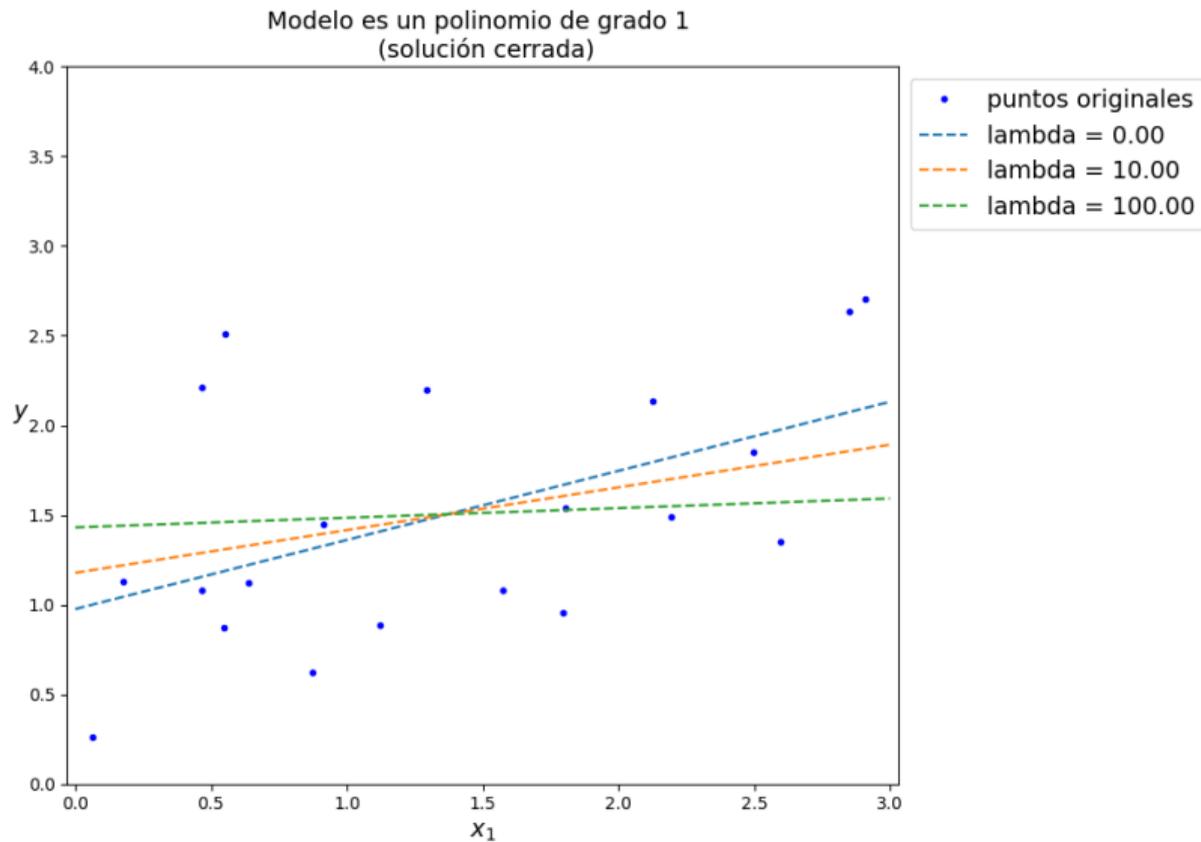
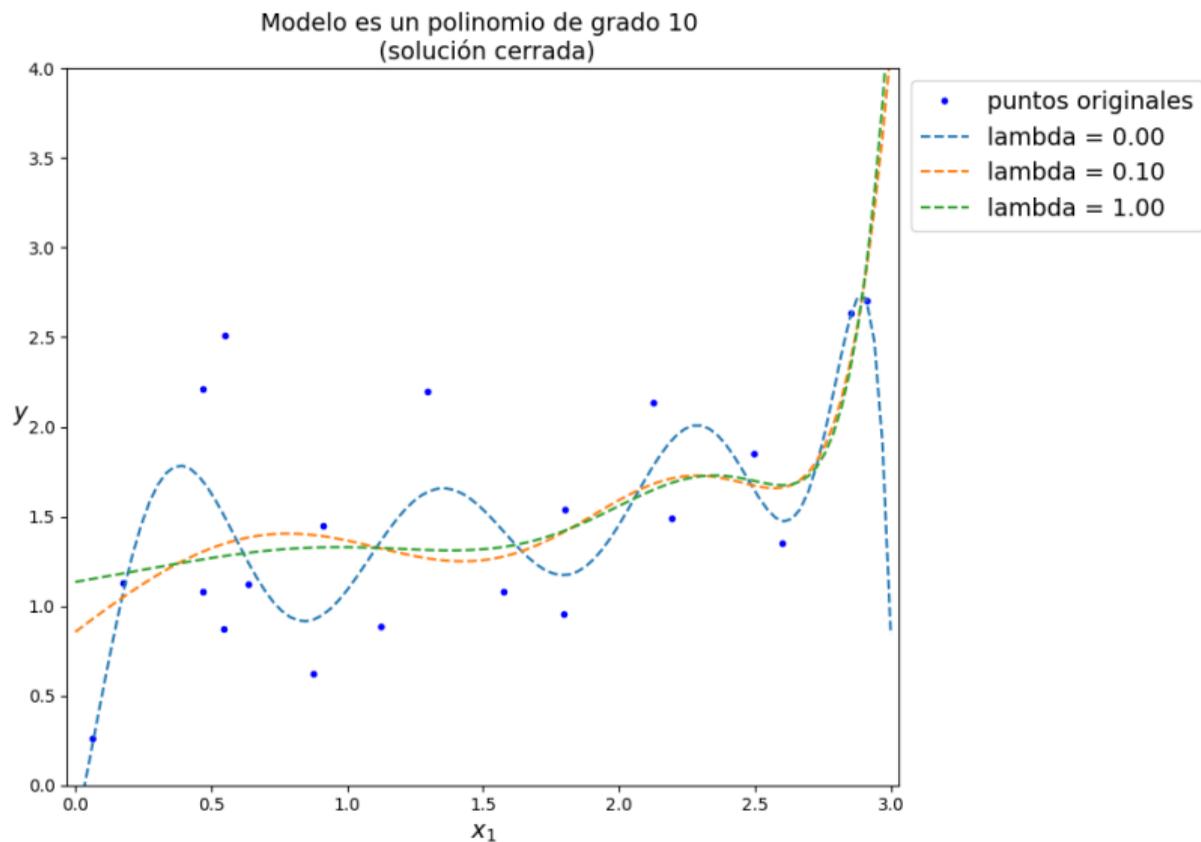


Figure: Sin regularizar el bias

Ejercicio 3: regresión polinómica regularizada



Ejercicio 3: regresión polinómica regularizada



Ejercicio 3: regularización mediante descenso por gradiente estocástico

- Implementar *regresion_lineal_SGD()*
- Se deberán contemplar los siguientes casos:
 - Sin regularización

$$E_{in} = \frac{1}{2N} \sum_{n=1}^N (y_n - \mathbf{w}^T \mathbf{x}_n)^2$$

- Regularización de Ridge

$$\begin{aligned} E_{aug} &= E_{in} + E_{Ridge} \\ &= E_{in} + \frac{\lambda}{2} \sum_{i=1}^d w_i^2 \end{aligned}$$

- Regularización de Lasso

$$\begin{aligned} E_{aug} &= E_{in} + E_{Lasso} \\ &= E_{in} + \lambda \sum_{i=1}^d |w_i| \end{aligned}$$

Ejercicio 3: regularización mediante descenso por gradiente estocástico

- Implementar *regresion_lineal_SGD()*
- Se deberán contemplar los siguientes casos:
 - Sin regularización

$$E_{in} = \frac{1}{2N} \sum_{n=1}^N (y_n - \mathbf{w}^T \mathbf{x}_n)^2$$

- Regularización de Ridge

$$\begin{aligned} E_{aug} &= E_{in} + E_{Ridge} \\ &= E_{in} + \frac{\lambda}{2} \sum_{i=1}^d w_i^2 \end{aligned}$$

- Regularización de Lasso

$$\begin{aligned} E_{aug} &= E_{in} + E_{Lasso} \\ &= E_{in} + \lambda \sum_{i=1}^d |w_i| \end{aligned}$$

Ejercicio 3: regularización mediante descenso por gradiente estocástico

- Implementar *regresion_lineal_SGD()*
- Se deberán contemplar los siguientes casos:
 - Sin regularización

$$E_{in} = \frac{1}{2N} \sum_{n=1}^N (y_n - w^T x_n)^2$$

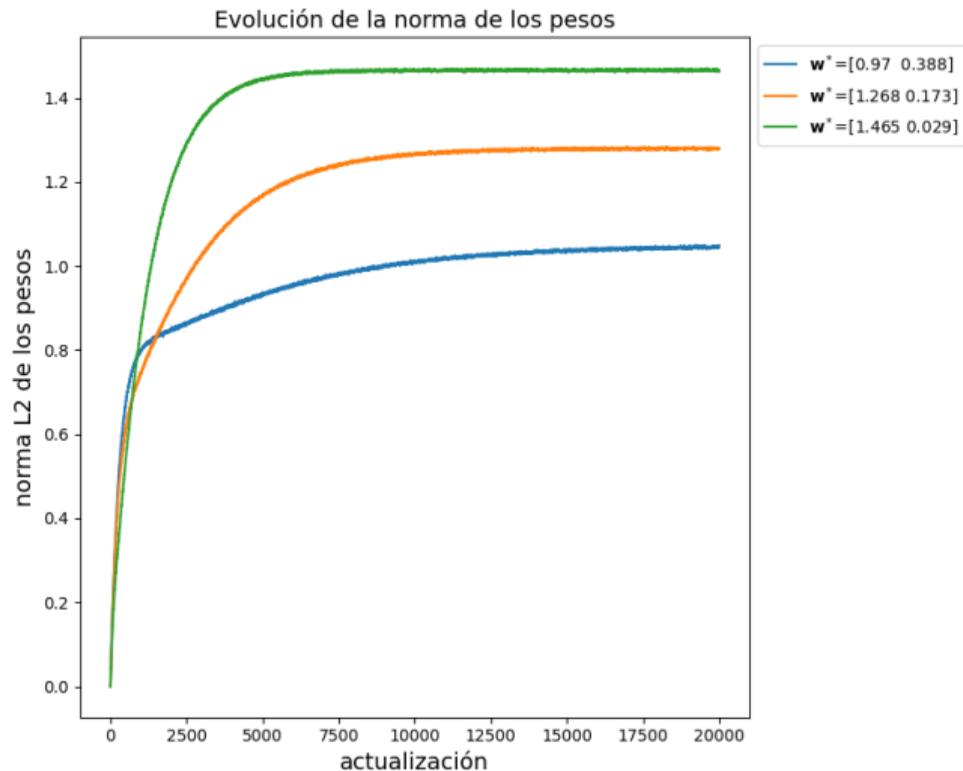
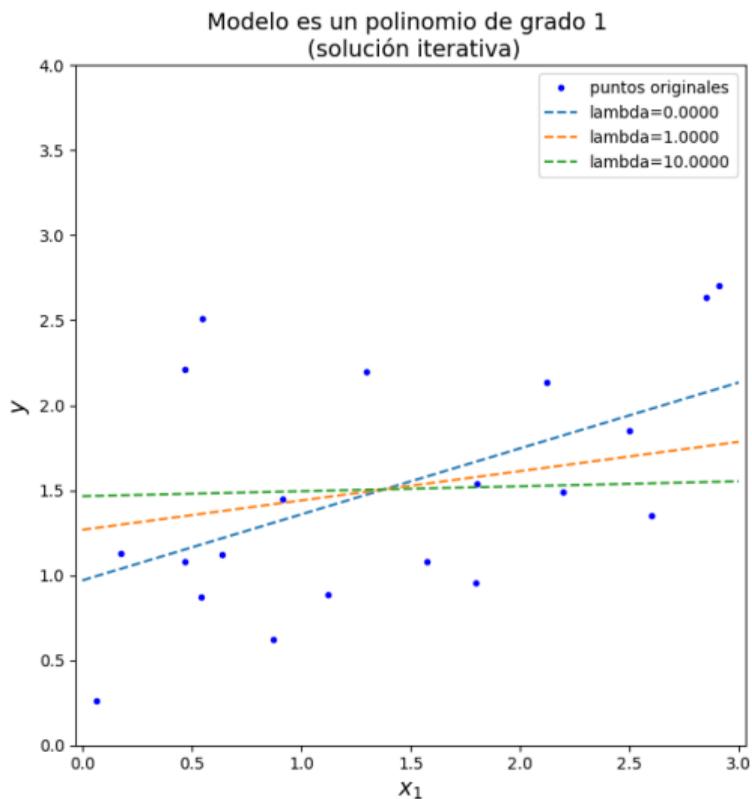
- Regularización de Ridge

$$\begin{aligned} E_{aug} &= E_{in} + E_{Ridge} \\ &= E_{in} + \frac{\lambda}{2} \sum_{i=1}^d w_i^2 \end{aligned}$$

- Regularización de Lasso

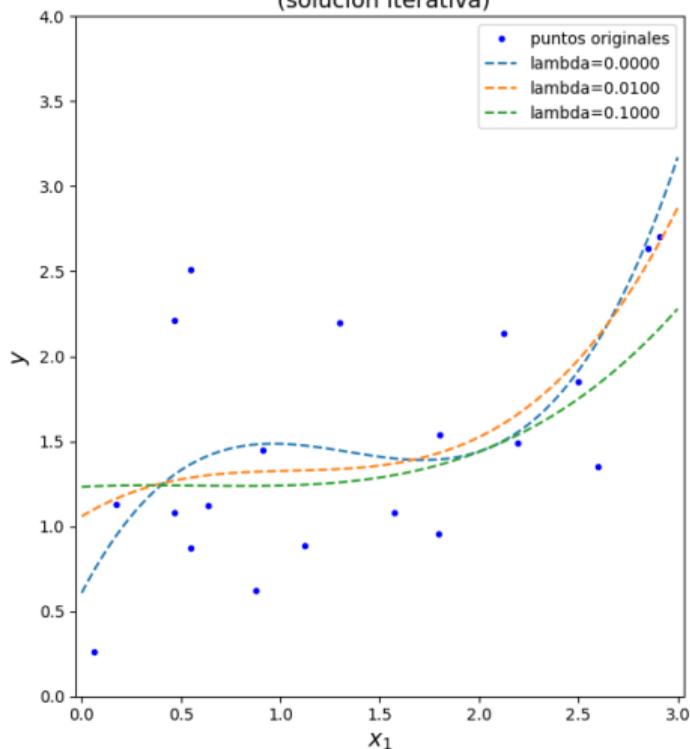
$$\begin{aligned} E_{aug} &= E_{in} + E_{Lasso} \\ &= E_{in} + \lambda \sum_{i=1}^d |w_i| \end{aligned}$$

Ejercicio 3: regularización mediante descenso por gradiente estocástico

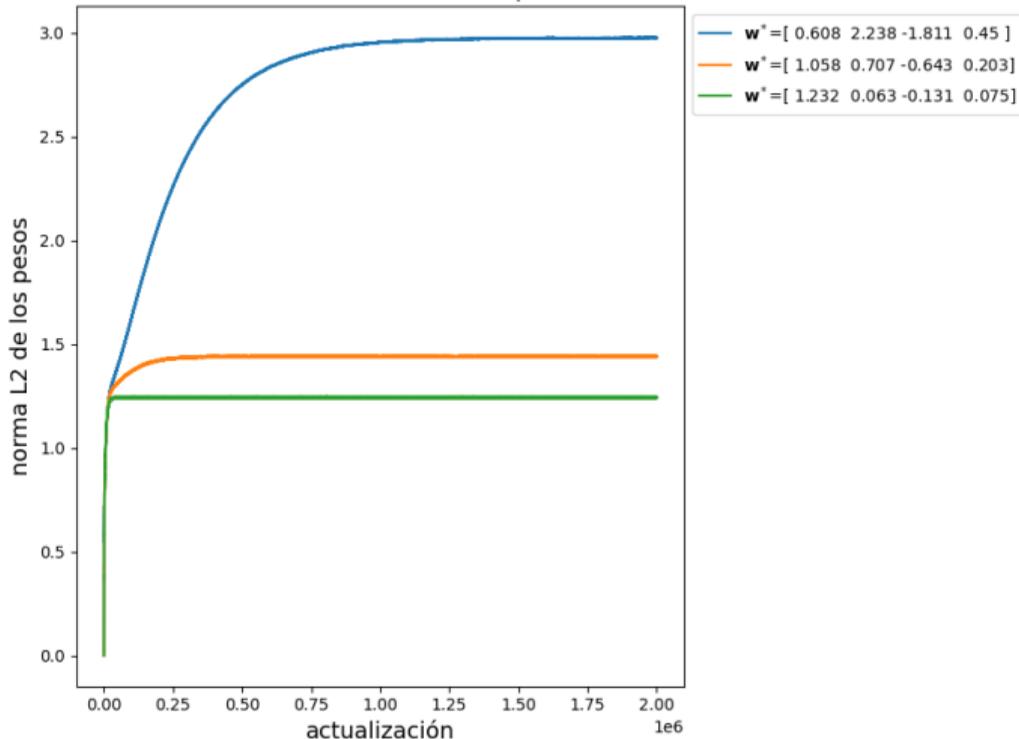


Ejercicio 3: regularización mediante descenso por gradiente estocástico

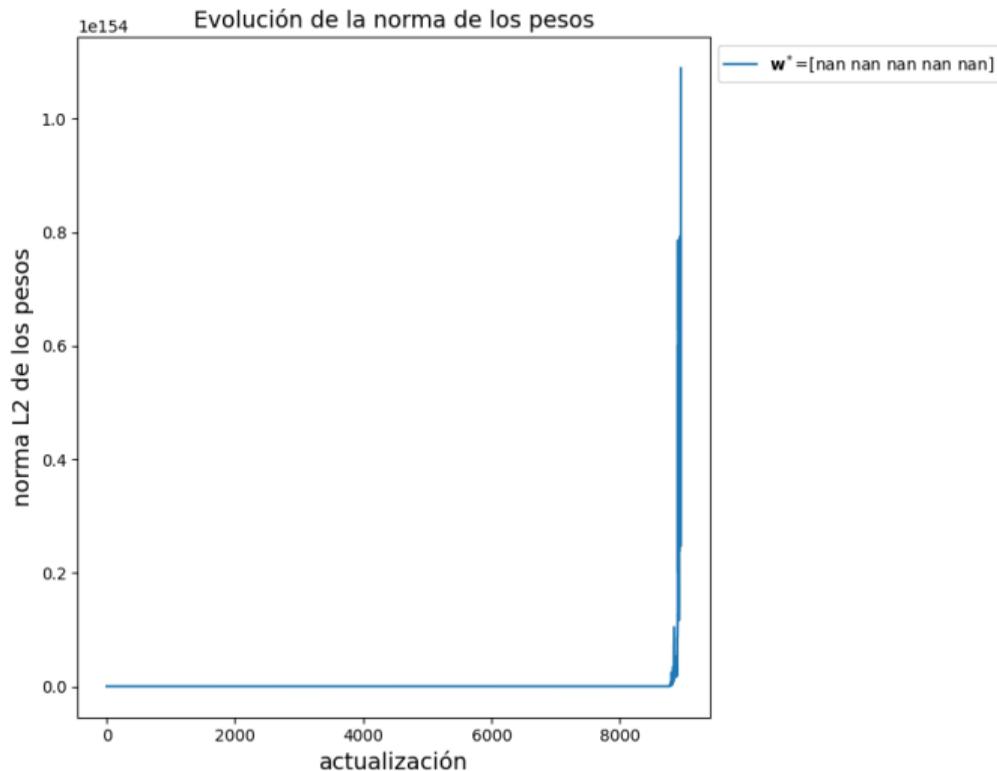
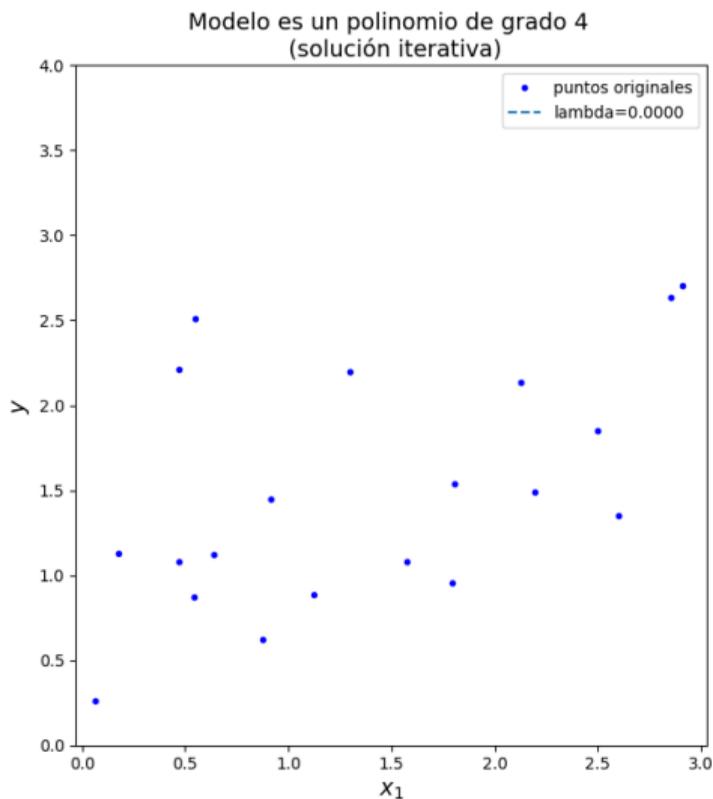
Modelo es un polinomio de grado 3
(solución iterativa)



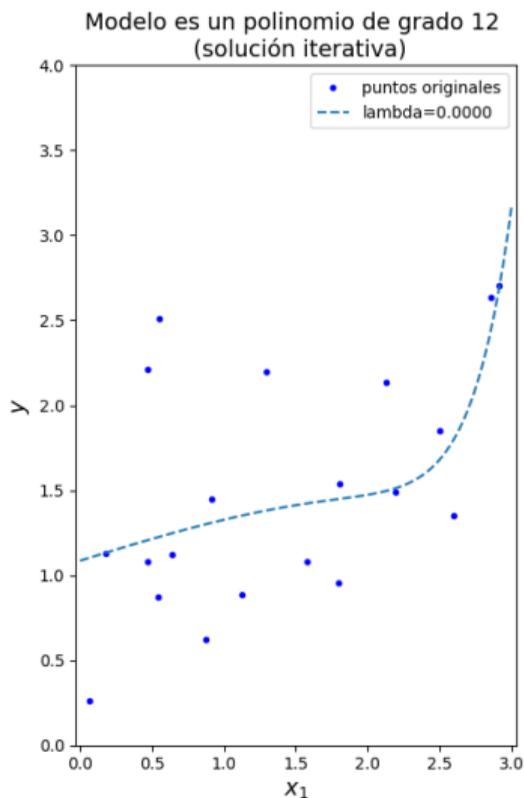
Evolución de la norma de los pesos



Ejercicio 3: regularización mediante descenso por gradiente estocástico



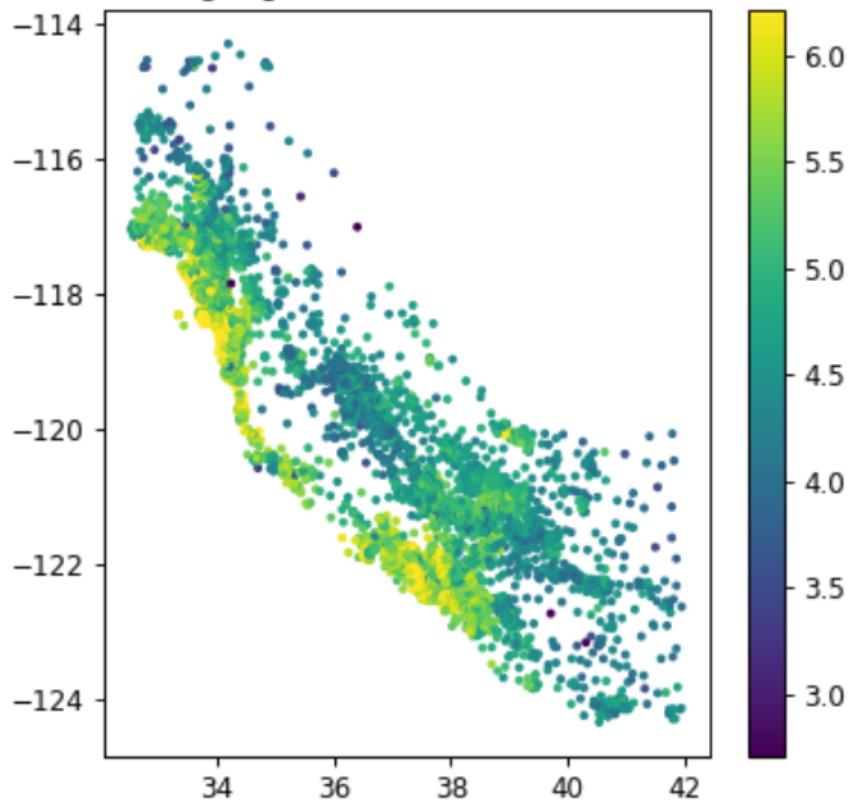
Ejercicio 3: regularización mediante descenso por gradiente estocástico



- ① Ejercicio 1: regularización con *weight decay*
- ② Ejercicio 2: Curvas de aprendizaje
- ③ Ejercicio 3: Regresión polinómica regularizada
- ④ Ejercicio 4: Predicción del valor medio de las casas

Ejercicio 4: predicción del valor medio de las casas

Distribución geográfica de los valores de las casas



Ejercicio 4: predicción del valor medio de las casas

