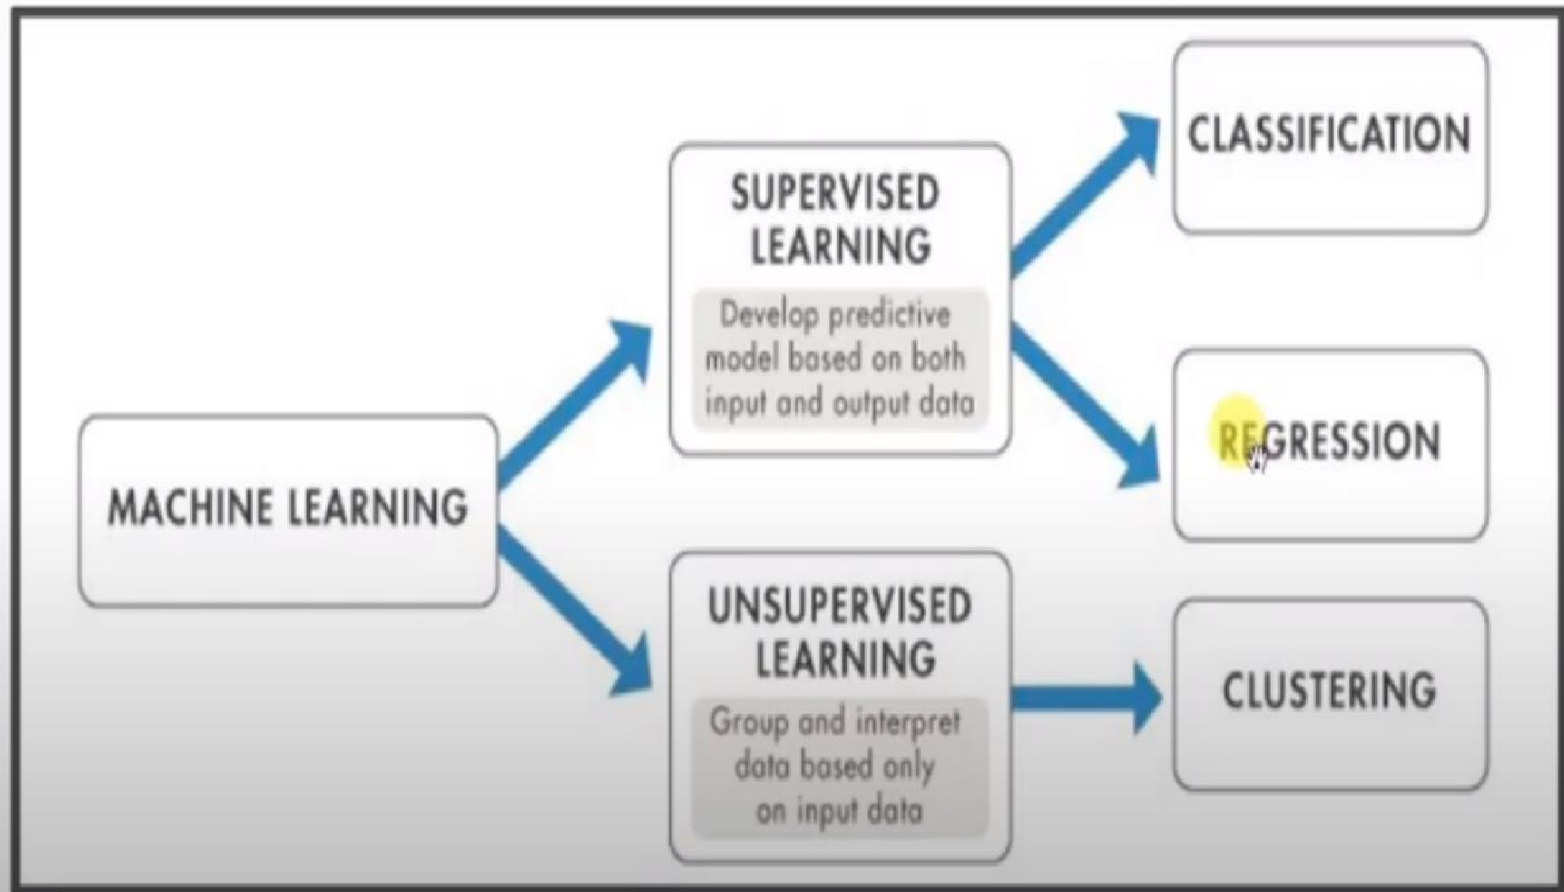




Lec. 9

Linear Regression

Assist. Prof. Dr. Saad Albawi



Linear regression equation


(without error)

$$\hat{Y} = bX + a$$

predicted values of Y

b = slope = rate of predicted \uparrow/\downarrow for Y scores for each unit increase in X

Y-intercept = level of Y when X is 0



- One Variable) و يسمى أيضا (Regression Univariate) او (Regression (Regression




Linear Regression التوقع الخطي

# of Favourites (X)	# of Posts (Y)
36	14
21	12
47	22
11	11
72	33
95	46
58	25
81	34
9	3
18	12
2	0
15	4
29	10
66	19
31	20

Linear Equations


- ▶ A **linear equation** is an equation whose graph is a line.
- ▶ The points on the line are **solutions** of the equation.

x	y	(x, y)
-1	0	(-1, 0)
0	1	(0, 1)
2	3	(2, 3)

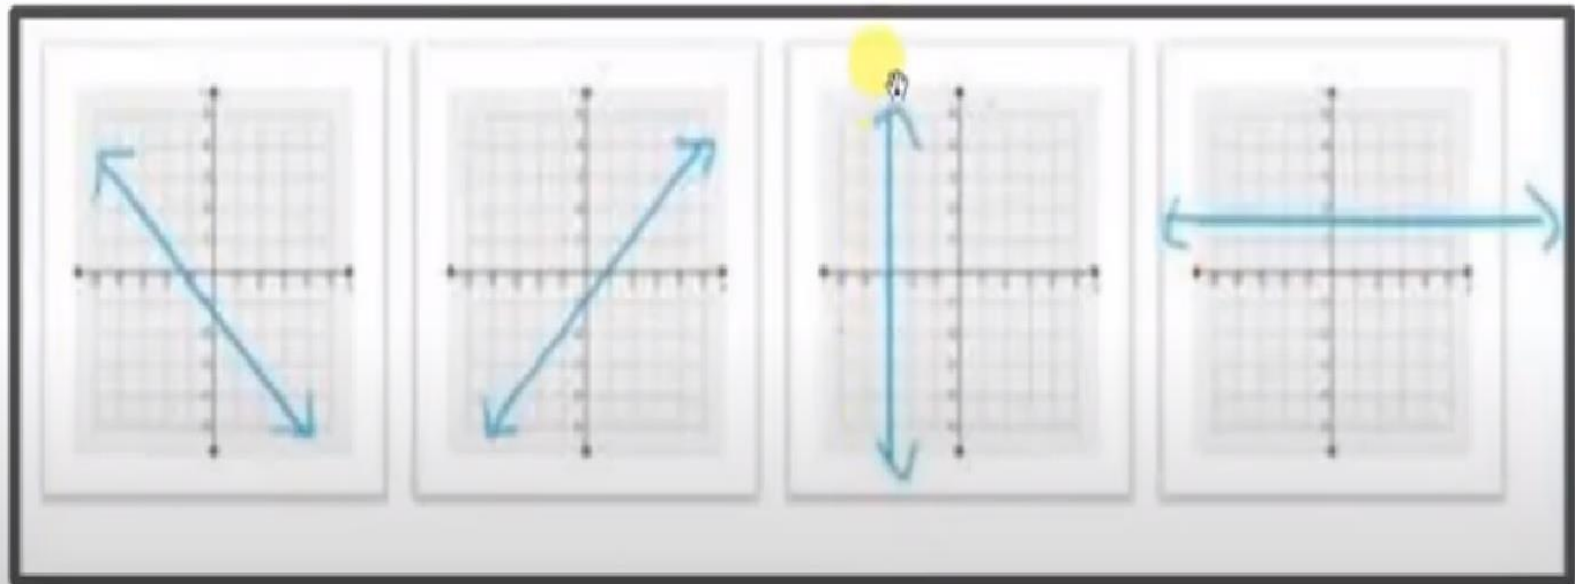



معناها:

- علاقة بين متغيرين , حين يكون كلا من X , Y لهما أس 1



$$\begin{array}{ccc}
 y_2 = 1 & & y_1 = -7 \\
 \swarrow & & \swarrow \\
 m = \frac{y_2 - y_1}{x_2 - x_1} = \frac{1 - (-7)}{12 - (-4)} \\
 \swarrow & & \swarrow \\
 x_2 = 12 & & x_1 = -4
 \end{array}$$





Input X	المدخلات
Output Y	المخرجات
Rows m	الصفوف
Features n	العناصر
$h(x)$	القيمة المتوقعة
Cost J	قيمة الخطأ
Theta Θ	معاملات الـ X

معادلة التوقع الخطي Linear Regression Equation

Hypothesis: $h_{\theta}(x) = \theta_0 + \theta_1 x$

Parameters: θ_0, θ_1

Cost Function: $J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$

Goal: minimize $J(\theta_0, \theta_1)$
 θ_0, θ_1

- الهدف تقليل الفرق بين قيمة $h(x)$ و هي القيمة المتوقعة من المعادلة الخطية و قيمة y و هي القيمة الحقيقية
- يتم القسمة على $2m$ لربط قيمة الخطأ بعدد القيم بالعينة
- الهدف إيجاد قيم θ_0 و θ_1 والتي تجعل من J (نسبة الخطأ) اقل ما يمكن
- تسمى احيانا Cost error function

Linear Regression Equation معادلة التوقع الخطي

Theta0 = 5 , theta 1 = 2 Equation $h(x) = 5 + 2x$

X	Y	h(x)	h(x) - y	(h(x) - y) ²
1	7			
2	8			
2	7			
3	9			
4	11			
5	10			
5	12			

Linear Regression Equation معادلة التوقع الخطي

Theta0 = 5 , theta 1 = 2

Equation $h(x) = 5 + 2x$

X	Y	h(x)	h(x) - y	(h(x) - y) ²
1	7	7		
2	8	9		
2	7	9		
3	9	11		
4	11	13		
5	10	15		
5	12	15		

Linear Regression Equation معادلة التوقع الخطي

Theta0 = 5 , theta 1 = 2 Equation $h(x) = 5 + 2x$

X	Y	h(x)	h(x) - y	(h(x) - y) ²
1	7	7	0	
2	8	9	1	
2	7	9	2	
3	9	11	2	
4	11	13	2	
5	10	15	5	
5	12	15	3	

Linear Regression Equation معادلة التوقع الخطي

Theta0 = 5 , theta 1 = 2

Equation $h(x) = 5 + 2x$

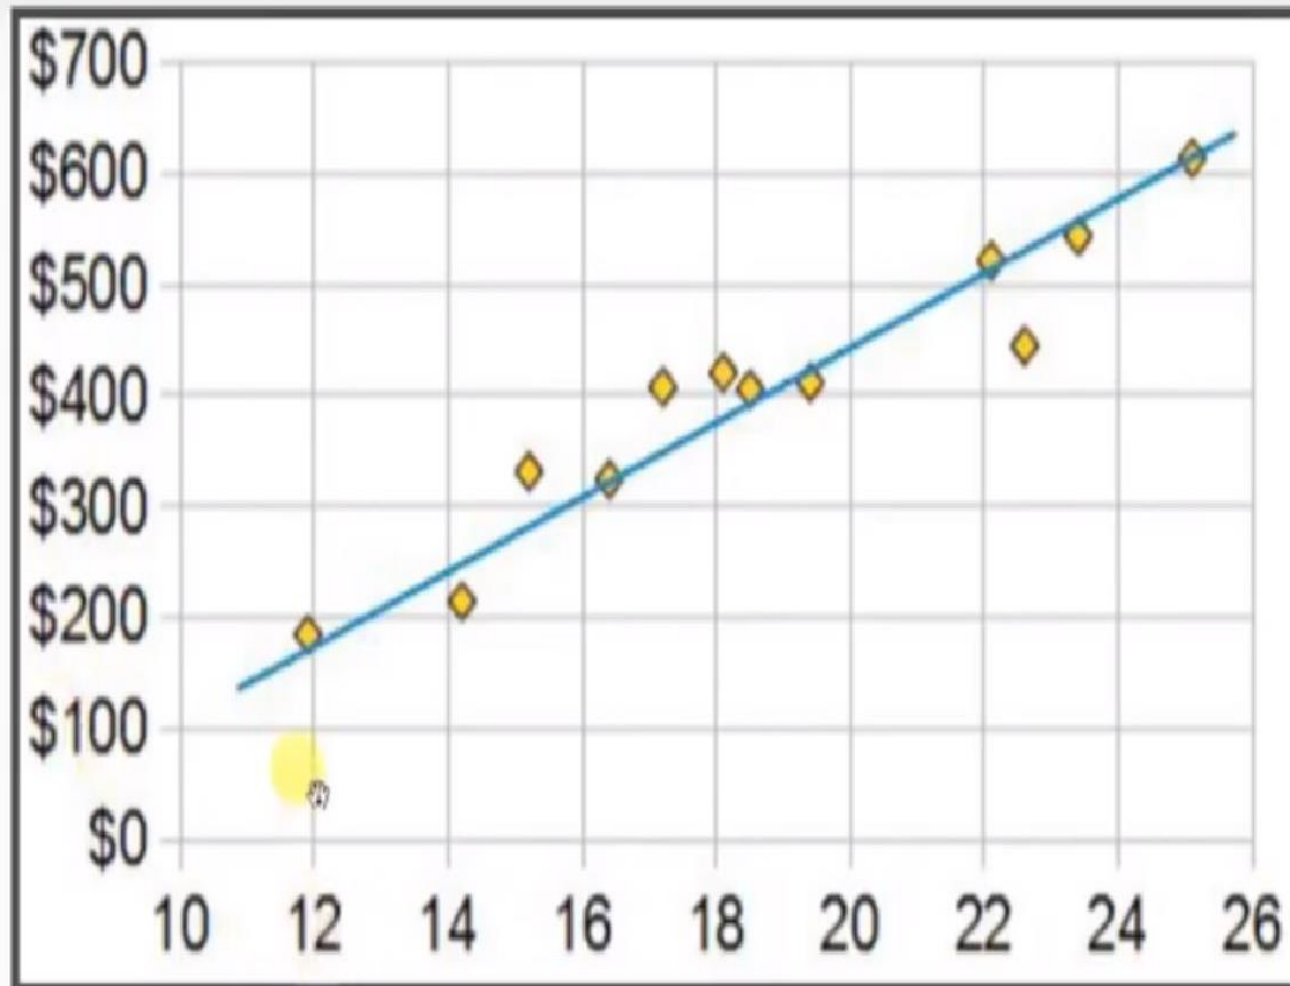
X	Y	h(x)	h(x) - y	(h(x) - y) ²
1	7	7	0	0
2	8	9	1	1
2	7	9	2	4
3	9	11	2	4
4	11	13	2	4
5	10	15	5	25
5	12	15	3	9

$$J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$$

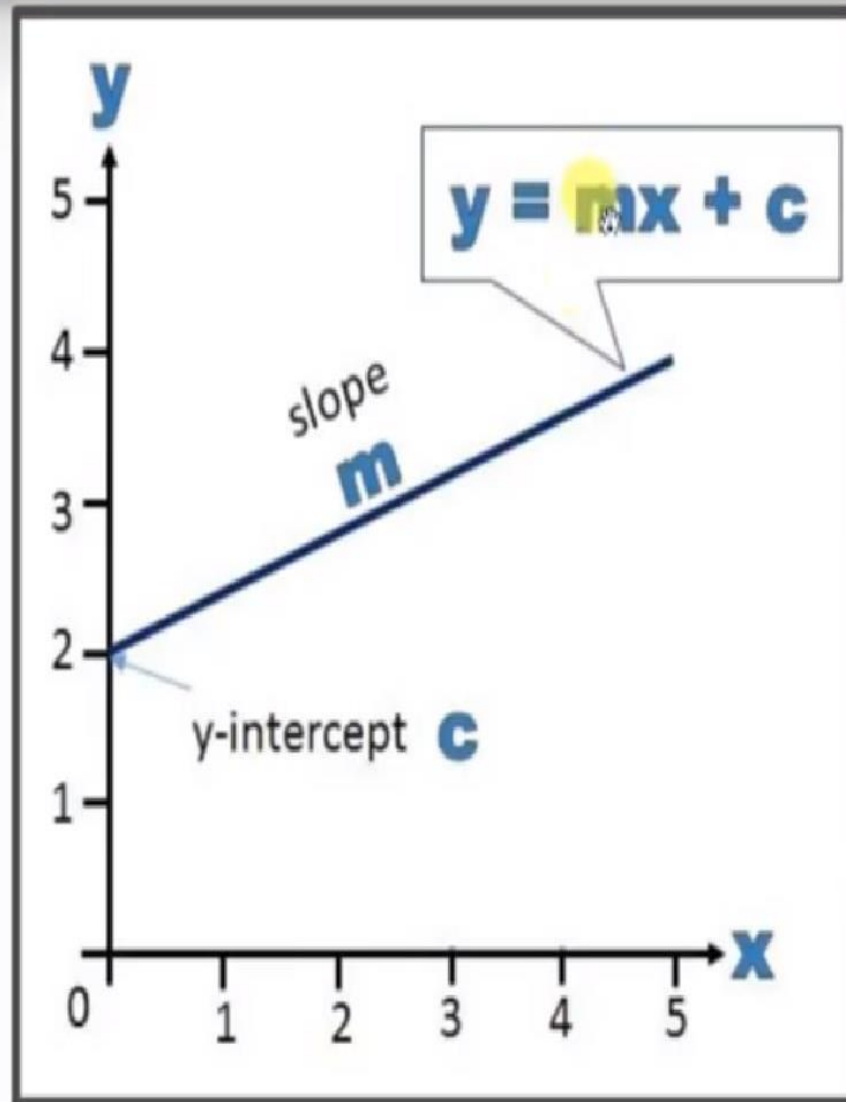
$$J = 1 / 14 (0+1+4+4+4+25+9)$$

$$J = 47/14 = 3.3$$

الخط الأكثر ملائمة Best fit line



معادلة الخط المستقيم



Linear Regression Equation معادلة التوقع الخطي

Hypothesis: $h_{\theta}(x) = \theta_0 + \theta_1 x$


Parameters: θ_0, θ_1


Cost Function: $J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$


Goal: minimize $J(\theta_0, \theta_1)$
 θ_0, θ_1

- الهدف تقليل الفرق بين قيمة $h(x)$ و هي القيمة المتوقعة من المعادلة الخطية و قيمة y و هي القيمة الحقيقية
- يتم القسمة على $2m$ لربط قيمة الخطأ بعدد القيم بالعينة
- الهدف إيجاد قيم θ_0 و θ_1 والتي تجعل من J (نسبة الخطأ) أقل ما يمكن
- تسمى أحيانا Cost error function

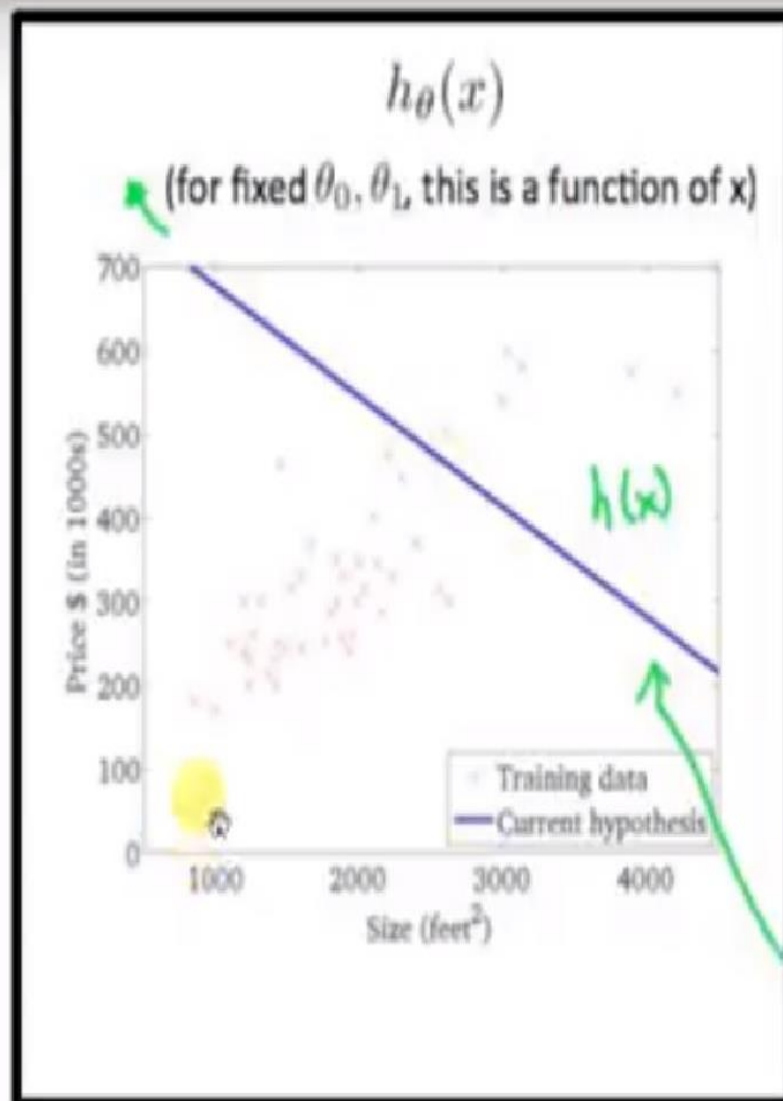
معادلة الخط المستقيم



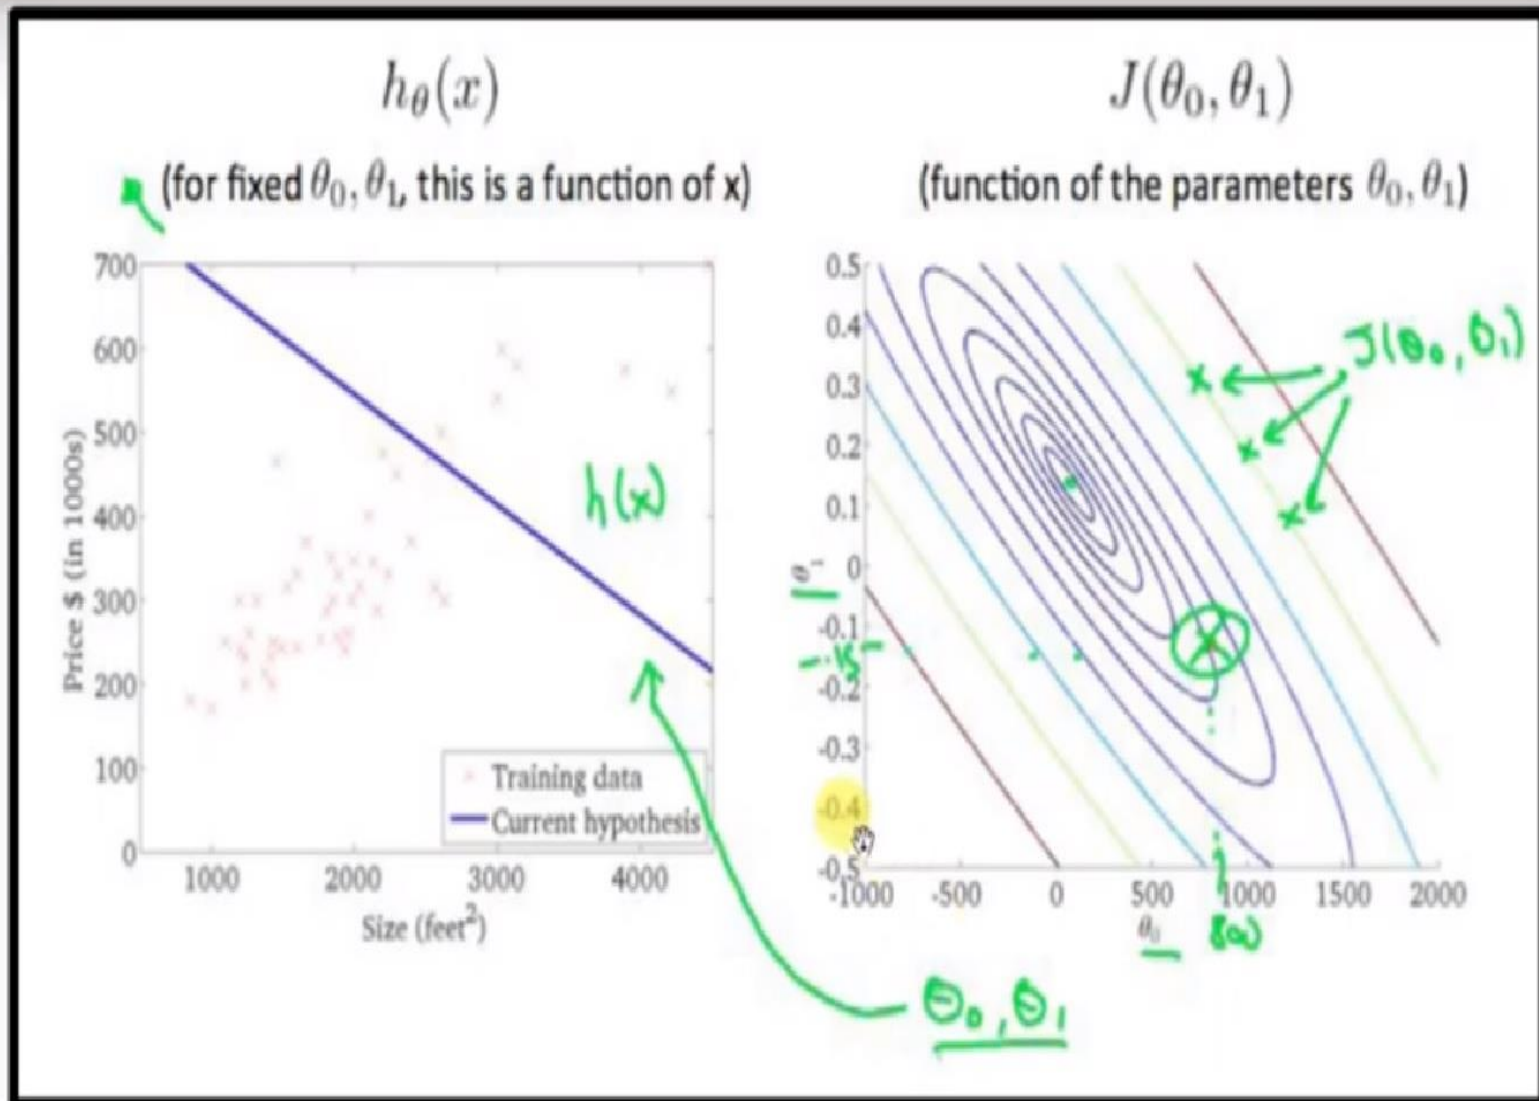




تحديد قيمة ثيتا

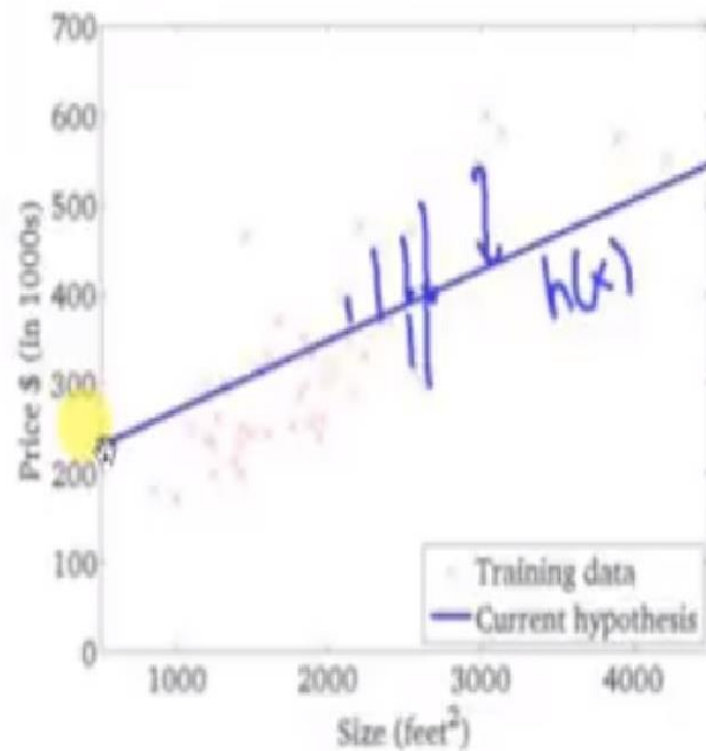


تحديد قيمة ثيتا




$$h_{\theta}(x)$$

(for fixed θ_0, θ_1 , this is a function of x)




$$h_{\theta}(x)$$

(for fixed θ_0, θ_1 , this is a function of x)



$$J(\theta_0, \theta_1)$$

(function of the parameters θ_0, θ_1)



Linear Regression Equation معادلة التوقع الخطي

Hypothesis: $h_{\theta}(x) = \theta_0 + \theta_1 x$

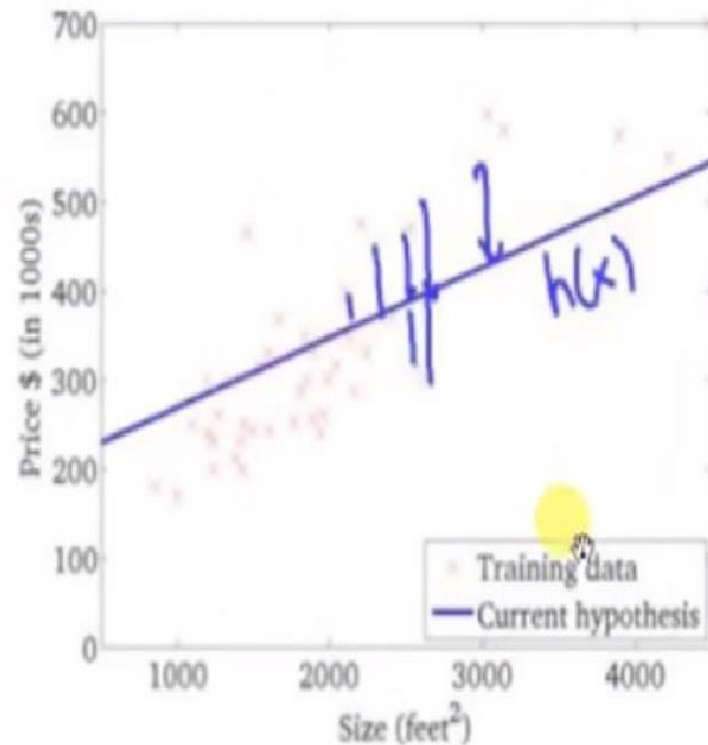
Parameters: θ_0, θ_1

Cost Function: $J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$

Goal: minimize $J(\theta_0, \theta_1)$
 θ_0, θ_1

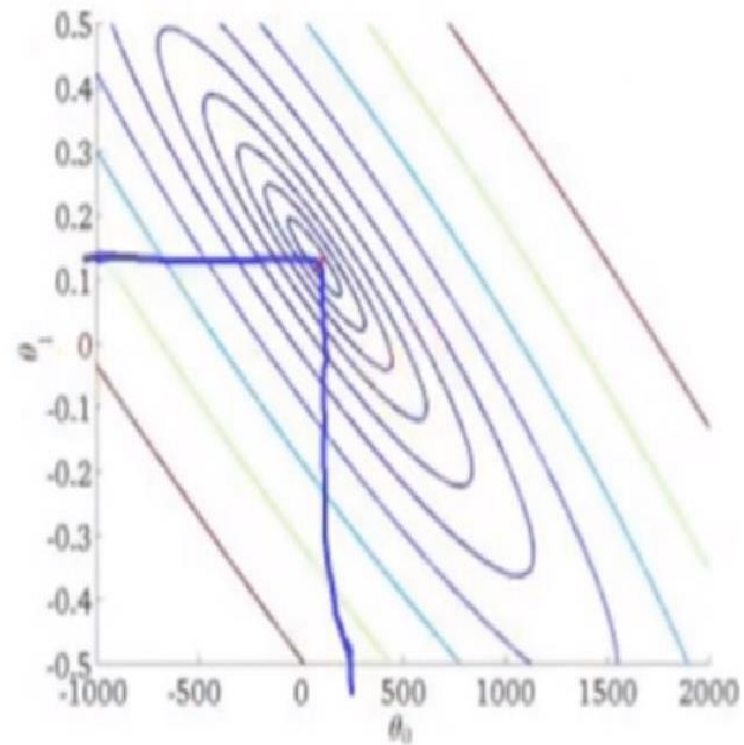
$$h_{\theta}(x)$$

(for fixed θ_0, θ_1 , this is a function of x)




$$J(\theta_0, \theta_1)$$

(function of the parameters θ_0, θ_1)



الإنحدار التدريجي Gradient Descent

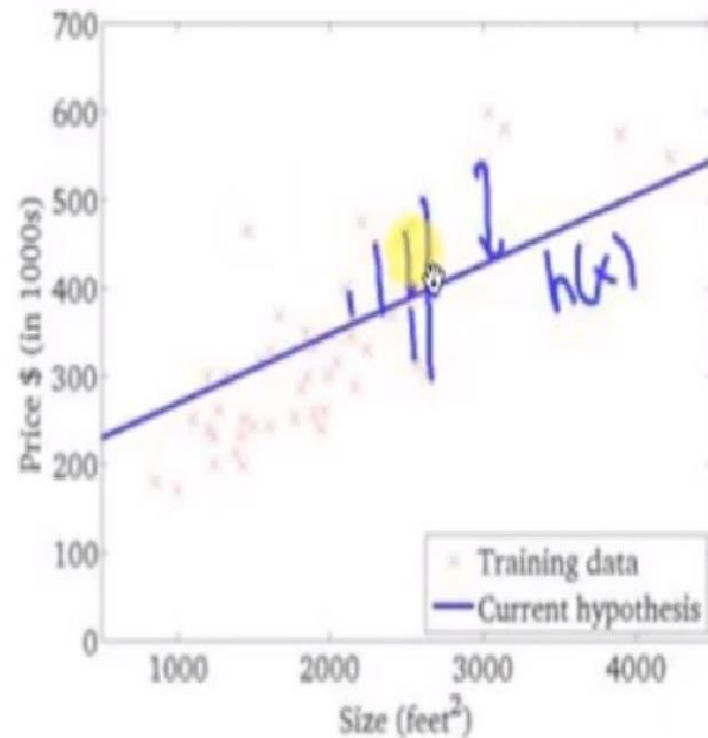


الإنحدار التدريجي :

- طالما نحن نبحث عن قيم θ_0 و θ_1 التي سنقل قيمة J بأقصى قدر , فسنفرض قيم ل θ_0 و θ_1 و 2 , ثم نقوم بتقليلها تدريجيا حتي نصل لاقبل قيمة ل J


$$h_{\theta}(x)$$

(for fixed θ_0, θ_1 , this is a function of x)




$$J(\theta_0, \theta_1)$$

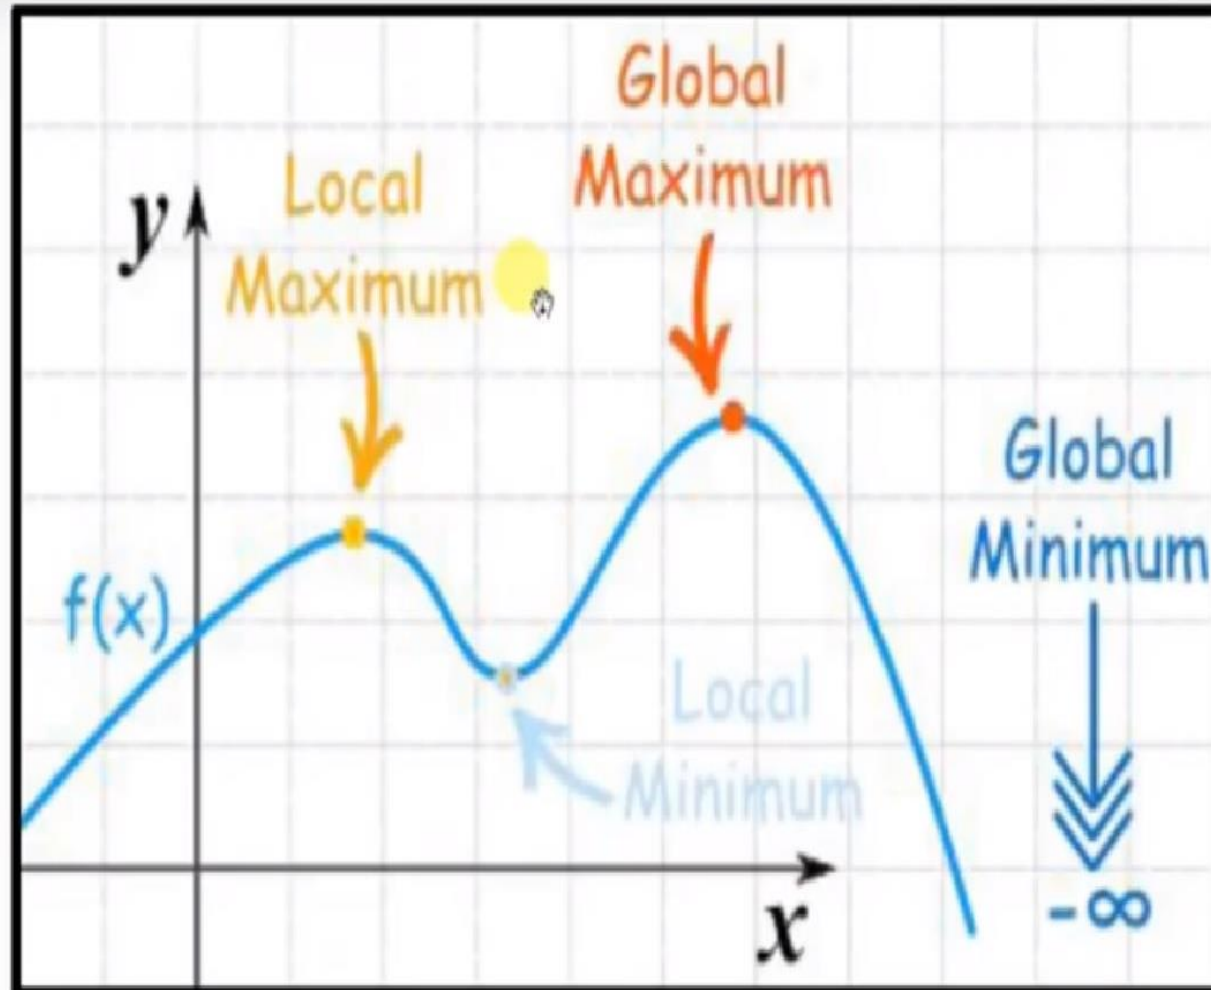
(function of the parameters θ_0, θ_1)



Gradient Descent الإنحدار التدريجي




Local Max & Min القيم المحلية



الإنداد التدرجي Gradient Descent

القيم المحلية :



- فهناك ما يسمى local minimum يعني قيمة دنيا , لكن محلية (علي اليمين) و لا نري جوارها اي قيم دنيا اخري , لكن في الحقيقة هناك قيم اقل منها لكن ابعد
- والقيمة الأقل جميعا اسمها



معادلة الإنحدار التدريجي

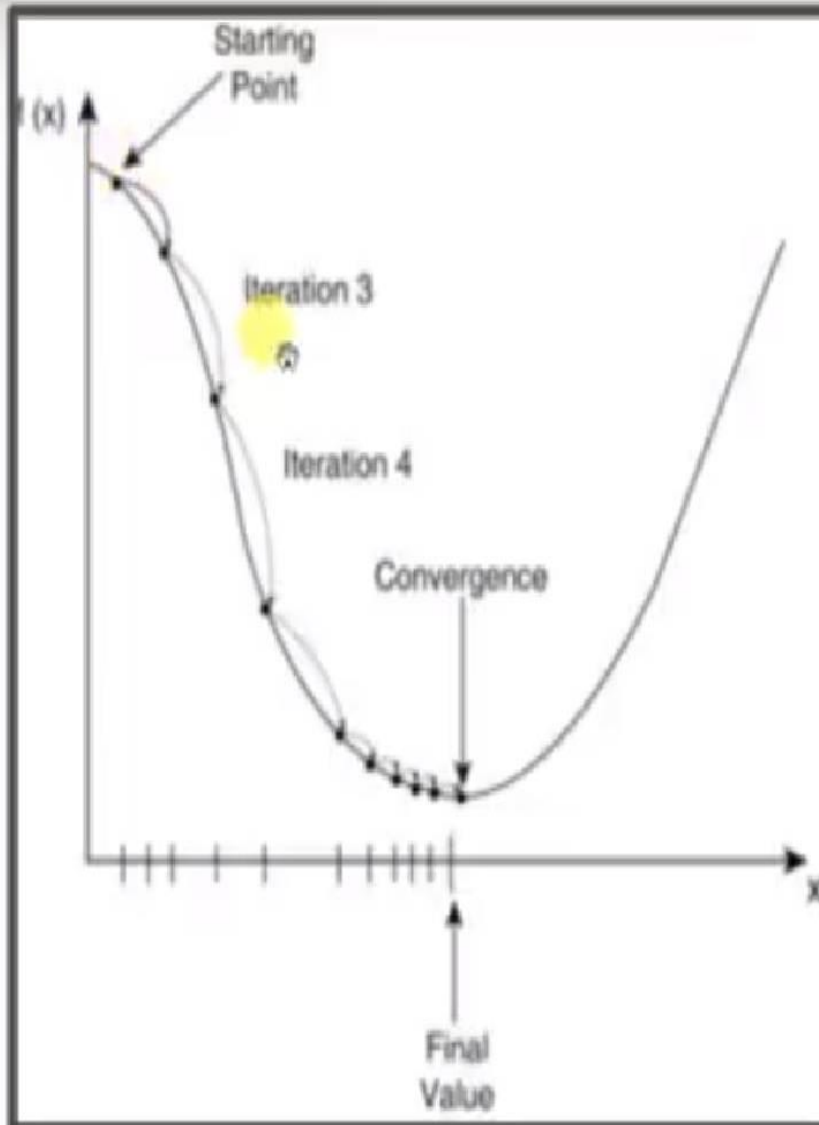
الفكرة :

repeat until convergence:

$$\theta_j := \theta_j - \alpha \frac{\partial}{\partial \theta_j} J(\theta_0, \theta_1)$$

- اولاً فكرة ان $=$ معناها ان يا برنامج , اعمل `overwrite` للقيمة اليسرى بقيمة اليمنى
- الفا هو معامل , ان زاد , ستكون الخطوات اسرع (و غالباً اقل دقة) و ان قل ستكون الخطوات ابطى و ادق
- ما هو على يمين الفا , هو اشتقاق جزئي للدالة , بالنسبة لثابتنا
- لاحظ ان هذه المعادلة تكون مرة لثابتنا صفر , ومرة لثابتنا 1
- كلا المعادلتين يمشيان بالتوازي معا , ويتم تكرارهما معا
- ولاحظ ان الابدث لازم يتم زي اللي على الشمال , مثل اليمين

معادلة الإنحدار التدريجي



الفكرة :

- لاحظ ان في حالة القيمة الدنيا قيمة التفاضل بصفر (لأن وقتها هيكون الخط شبه مستقيم فالميل هيكون تقريبا 0)
- لاحظ ان قيمة التفاضل نقل كلما قل الميل (التفاضل هو ميل الخط المستقيم , فتدريجيا هيقل قيمة التفاضل لتغير الميل) , وكلما اقترب من القيمة الدنيا , فلا داعي لتقليل الالفا , فالقيمة نفسها سنقل تدريجيا

معادلة الإنحدار التدريجي

Correct: Simultaneous update

- $\text{temp0} := \theta_0 - \alpha \frac{\partial}{\partial \theta_0} J(\theta_0, \theta_1)$
- $\text{temp1} := \theta_1 - \alpha \frac{\partial}{\partial \theta_1} J(\theta_0, \theta_1)$
- $\theta_0 := \text{temp0}$
- $\theta_1 := \text{temp1}$

Incorrect:

- $\text{temp0} := \theta_0 - \alpha \frac{\partial}{\partial \theta_0} J(\theta_0, \theta_1)$
- $\theta_0 := \text{temp0}$
- $\text{temp1} := \theta_1 - \alpha \frac{\partial}{\partial \theta_1} J(\theta_0, \theta_1)$
- $\theta_1 := \text{temp1}$


الفكرة:

- كلا المعادلتين يمشيان بالتوازي معا , ويتم تكرارهما معا
- ولاحظ ان الابدیت لازم يتم زي اللي علي الشمال , مش اليمين

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x_i) - y_i)$$

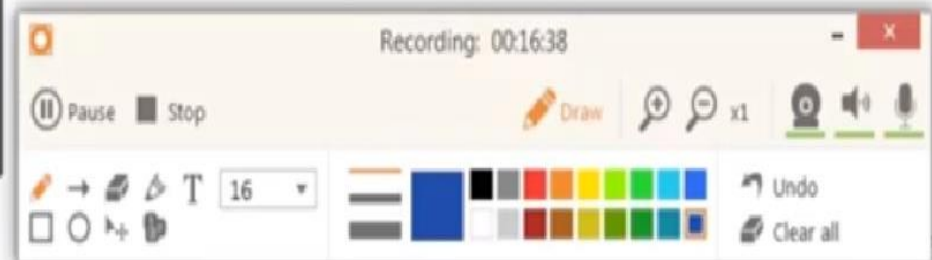
$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m ((h_{\theta}(x_i) - y_i)x_i)$$


الإنحدار التدريجي Gradient Descent



الإنحدار التدريجي :

- طالما نحن نبحث عن قيم ثباتا 0 و 1 التي سنقل قيمة J بأقصى قدر ، فسنفرض قيم لثباتا 1 و 2 ، ثم نقوم بتقليلها تدريجيا حتي نصل لأقل قيمة لـ J





مثال عملي

مساحة البيت (X_1 م ²)	السعر (الف \$) Y
100	135
95	130
90	110
80	95
80	90
70	85
70	80
60	80


- لاحظ ان المساحة اكس , بينما السعر هو واي
- عشان اعمل best fit line
هنفرض الثبتات قيم معينة , وليكن
ثبتا $1 = 0$ و $ثبتا 3 = 1$
- المعادلة هتكون :

$$h(x) = 1 + 3 X$$

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x_i) - y_i)$$

$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m ((h_{\theta}(x_i) - y_i)x_i)$$

مثال عملي



مثال عملي

X_1	Y	$h(x)$	$h(x) - y$
100	300		
95	285		
90	270		
80	240		
80	235		
70	200		
70	205		
60	180		

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x_i) - y_i)$$

ثبثًا 0 = 1

ثبثًا 1 = 3

المعادلة

$$h(x) = 1 + 3X$$

مثال عملي

X_1	Y	$h(x)$	$h(x) - y$
100	300	301	
95	285	286	
90	270	271	
80	240	241	
80	235	241	
70	200	211	
70	205	211	
60	180	181	

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x_i) - y_i)$$

ثبنا 0 = 1

ثبنا 1 = 3

المعادلة

$$h(x) = 1 + 3X$$

مثال عملي

X_1	Y	$h(x)$	$h(x) - y$
100	300	301	1
95	285	286	1
90	270	271	1
80	240	241	1
80	235	241	6
70	200	211	11
70	205	211	6
60	180	181	1

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x_i) - y_i)$$

ثبنا 0 = 1

ثبنا 1 = 3

المعادلة

$$h(x) = 1 + 3X$$

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x_i) - y_i)$$

$$\text{Theta } 0 = 1 - ((0.002 / 8) * (28))$$

$$\text{Theta } 0 = 1 - 0.007 = 0.993$$

ثابتاً $1 = 0$

مجموع الفروق $28 =$

الفا $0.002 =$

قيمة $m = 8$

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x_i) - y_i)$$

$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m ((h_{\theta}(x_i) - y_i)x_i)$$

مثال عملي

X_1	Y	$h(x)$	$h(x) - y$	$(h(x) - y)x$
100	300	301	1	100
95	285	286	1	95
90	270	271	1	90
80	240	241	1	80
80	235	241	6	480
70	200	211	11	770
70	205	211	6	420
60	180	181	1	60

$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m ((h_{\theta}(x_i) - y_i)x_i)$$

ثَبَاتًا 0 = 1

ثَبَاتًا 1 = 3

مثال عملي

$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m ((h_{\theta}(x_i) - y_i)x_i)$$

$$\text{Theta } 1 = 3 - ((0.002 / 8) * (2095))$$

$$\text{Theta } 1 = 3 - 0.52 = 2.48$$


ثابتا 1 = 0

مجموع الفروق = 2095

الفأ = 0.002

قيمة m = 8

الإنحدار التدريجي Gradient Descent



الإنحدار التدريجي :

- طالما نحن نبحث عن قيم θ_0 و θ_1 التي ستقلل قيمة J بأقصى قدر ، فسنفرض قيم θ_0 و θ_1 ثم نقوم بتقليلها تدريجياً حتى نصل لأقل قيمة لـ J

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x_i) - y_i)$$

$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m ((h_{\theta}(x_i) - y_i)x_i)$$

Theta 0 = 1

Theta 1 = 3

Theta 0 = 0.993

Theta 1 = 2.48

Theta 0 = 0.991

Theta 1 = 2.46

..

..

Theta 0 = 0.825

Theta 1 = 1.772

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

التعامل مع أكثر من بعد :

- تحدثنا سابقا , عن التعامل مع متغير واحد (قيمة لـ X و نجيب منها قيمة Y) الان نتعامل مع أكثر من متغير
- أكثر من متغير معناها ان البيانات الداخلة لها أكثر معلومة لكل صف , فبدلا من ادخال مساحة البيت لمعرفة سعره (X واحدة) , نقوم بادخال مساحة البيت و عدد غرفه , وعمره, و موقعه , وحالته , ولونه , لتحديد سعره , وهذه الأشياء تسمى features

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

Multiple features (variables).

Size (feet ²)	Number of bedrooms	Number of floors	Age of home (years)	Price (\$1000)
x_1	x_2	x_3	x_4	y
2104	5	1	45	460
1416	3	2	40	232
1534	3	2	30	315
852	2	1	36	178
...

$m = 47$

Notation:

$\rightarrow n$ = number of features

$n = 4$

$x^{(i)}$ = input (features) of i^{th} training example.

$x_j^{(i)}$ = value of feature j in i^{th} training example.

التعامل مع أكثر من بعد :

- فنري ان سعر البيت (Y) يتأثر
- بعدد من العوامل (Features) (Xs)
- عدد الاكسات نسميه n , بينما
- عدد الصفوف لازال m

$x_j^{(i)}$ = value of feature j in the i^{th} training example

- الرقم اللي فوق يكون رقم الصف (انهي ريكورد فيهم m) و الرقم اللي تحت هيكون رقم العمود (انهي معلومة فيهم n)

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

$$h_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n$$

For convenience of notation, define $x_0 = 1$. ($x_0^{(i)} = 1$)

$$x = \begin{bmatrix} x_0 \\ x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \in \mathbb{R}^{n+1}$$

$$\theta = \begin{bmatrix} \theta_0 \\ \theta_1 \\ \theta_2 \\ \vdots \\ \theta_n \end{bmatrix} \in \mathbb{R}^{n+1}$$

$$\underbrace{[\theta_0 \ \theta_1 \ \dots \ \theta_n]}_{\theta^T} \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix}$$

(n+1) x 1 matrix

$\theta^T x$

$$h_{\theta}(x) = \theta_0 x_0 + \theta_1 x_1 + \dots + \theta_n x_n$$

$\downarrow = 1$

$$= \theta^T x$$

Multivariate linear regression. ←

- وقتها الفكشن ،
هتكون متعددة
الحدود زي كدة ،
وهنعمل ماتركس
للاكسات ،
وواحدة للثينات ،
ونضربهم في
بعض بعد ما
نعمل ترانزبوس
للثينا

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

$$\underbrace{[\theta_0 \ \theta_1 \ \theta_2 \ \dots \ \theta_n]}_{\theta^T} \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix}$$

$(n+1) \times 1$
matrix

● ليه بنعمل ترانزبوس؟

لان الثيتا و الاكس اصلا هما فيكتور (عمود واحد في كذا صف) , فلازم اعمل ترانزبوس لو احد فيهم و اضربه في الثاني , عشان تكون المصفوفة الاولى صف واحد في 5 عواميد مثلا , والثانية زي ما هي 5 صفوف في عمود واحد , يتضربو ببقو رقم واحد

بس

$$h_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n$$

$$\text{Cost Function: } J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$$

- وخذ بالك الصيغة القديمة التي كانت لل J هيكون فيها شوية تعديل , عشان مبقاش عامل واحد , نفس المعادلة , لكن دلوقتي H بقت فيها ثينات كثيرة
- لما عملت تفاضل , هنظلل انش زى هي , وهتخنفى كل الثينات التانية عدا الثينا اللي باعمل تفاضل علي اساسها اللي هتتبقى في الاخر

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

القانون الجديد ●

repeat until convergence: {

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_0^{(i)}$$

$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_1^{(i)}$$

$$\theta_2 := \theta_2 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_2^{(i)}$$

...

}

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

● الصيغة المجمعة

repeat until convergence: {

$$\theta_j := \theta_j - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_j^{(i)} \quad \text{for } j := 0 \dots n$$

}



Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

سعر السيارات :

X_1	X_2	X_3	Y
العمر	القدرة	الاسطوانات	السعر
5	20	6	12
5	35	6	14
6	38	8	16
7	40	8	15
7	46	10	20

- عدد السيارات 5 (m)
- المعلومات عن كل سيارة (features n) 3

Linear Regression with Multivariable التوقع الخطي لأكثر من متغير

X_1	X_2	X_3	Y
العمر	القدرة	الاسطوانات	السعر
5	20	6	114
5	35	6	120
6	38	8	123
7	40	8	121
7	46	10	135

X_1	X_2	X_3
1	1	1
5	5	6
20	35	38
6	6	8

X_4	X_5
1	1
7	7
40	46
8	10

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

X_1	X_2	X_3	Y
العمر	القدرة	الاسطوانات	السعر
5	20	6	114
5	35	6	120
6	38	8	123
7	40	8	121
7	46	10	135

X_1	X_2	X_3
1	1	1
5	5	6
20	35	38
6	6	8
X_4	X_5	
1	1	
7	7	
40	46	
8	10	

Theta

Theta0

Theta1

Theta2

Theta3

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

X_1	X_2	X_3	Y
العمر	القدرة	الاسطوانات	السعر
5	20	6	114
5	35	6	120
6	38	8	123
7	40	8	121
7	46	10	135

X_1 X_2 X_3

1 1 1
5 5 6
20 35 38
6 6 8

Theta

Theta0 5
Theta1 2
Theta2 3
Theta3 6

X_4 X_5

1 1
7 7
40 46
8 10

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

$$\underbrace{[\theta_0 \ \theta_1 \ \dots \ \theta_n]}_{\theta^T} \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix}$$

$(n+1) \times 1$
matrix

- ليه بنعمل ترانزبوس ؟
لان الثبتا و الاكس اصلا هما فيكتور (عمود واحد في كذا صف) , فلازم اعمل ترانزبوس لو احد فيهم و اضربه في الثاني , عشان تكون المصفوفة الاولى صف واحد في 5 عواميد مثلا , والثانية زي ما هي 5 صفوف في عمود واحد , يتضربو بيقتو رقم واحد بس

$$h_{\theta}(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \dots + \theta_n x_n$$

$$h(x) = (\text{Theta})^T X$$

$$(\text{Theta})^T = \begin{matrix} 5 \\ 2 \\ 3 \\ 6 \end{matrix}^T = (5 \ 2 \ 3 \ 6)$$

$$X_1 = \begin{matrix} 1 \\ 5 \\ 20 \\ 6 \end{matrix}$$

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

$$h(x) = (\text{Theta})^T X$$

$$(\text{Theta})^T = 5^T = (5 \ 2 \ 3 \ 6)$$

$$X_1 = \begin{matrix} 1 \\ 5 \\ 20 \\ 6 \end{matrix}$$

$$h(x)_1 = (5 \ 2 \ 3 \ 6) \begin{matrix} 1 \\ 5 \\ 20 \\ 6 \end{matrix} = 5*1 + 2*5 + 3*20 + 6*6 = 111$$

$$\underbrace{[\theta_0 \ \theta_1 \ \dots \ \theta_n]}_{\theta^T}$$

$$\begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix}$$

$$(n+1) \times 1$$

matrix

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

$$h(x) = (\text{Theta})^T X$$

$$(\text{Theta})^T = \begin{matrix} 5 \\ 2 \\ 3 \\ 6 \end{matrix}^T = (5 \ 2 \ 3 \ 6)$$

$$X_1 = \begin{matrix} 1 \\ 5 \\ 20 \\ 6 \end{matrix}$$

$$h(x)_1 = (5 \ 2 \ 3 \ 6) \begin{matrix} 1 \\ 5 \\ 20 \\ 6 \end{matrix} = 5*1 + 2*5 + 3*20 + 6*6 = 111$$

$$h(x)_1 = 111 \quad h(x)_2 = 119 \quad h(x)_3 = 127 \quad h(x)_4 = 122 \quad h(x)_5 = 140$$

$[\theta_0 \ \theta_1 \ \dots \ \theta_n]$
 θ^T
 $(n+1) \times 1$
matrix

$\begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix}$

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

● القانون الجديد

repeat until convergence: {

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_0^{(i)}$$

$$\theta_1 := \theta_1 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_1^{(i)}$$

$$\theta_2 := \theta_2 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_2^{(i)}$$

...

}

Linear Regression with Multivariable التوقع الخطي لأكثر من متغير

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_0^{(i)}$$

Suppose Alpha = 0.01 m = 5



Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_0^{(i)}$$

Suppose Alpha = 0.01 m = 5

Theta 0 = 5 - (0.01 / 5) [(111-114) + (119-120) + (127-123) + (122-121) + (140-135) (1)] = 4.9

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_0^{(i)}$$

Suppose Alpha = 0.01 m = 5

$$\text{Theta } 0 = 5 - (0.01 / 5) [(111-114) + (119-120) + (127-123) + (122-121) + (140-135) (1)] = 4.9$$

$$\text{Theta } 1 = 2 - (0.01 / 5) [(111-114) + (119-120) + (127-123) + (122-121) + (140-135) (5)] = 2.6$$

$$\text{Theta } 2 = 3 - (0.01 / 5) [(111-114) + (119-120) + (127-123) + (122-121) + (140-135) (20)] = 3.9$$

$$\text{Theta } 3 = 6 - (0.01 / 5) [(111-114) + (119-120) + (127-123) + (122-121) + (140-135) (6)] = 6.4$$

Linear Regression with Multivariables التوقع الخطي لأكثر من متغير

$$\theta_0 := \theta_0 - \alpha \frac{1}{m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)}) \cdot x_0^{(i)}$$

Suppose Alpha = 0.01 m = 5

Theta 0 = 4.9

Theta 0 = 4.7

Theta 0 = 4.68

Theta 0 = 4.6236

Theta 1 = 2.6

Theta 1 = 2.55

Theta 1 = 2.542

Theta 1 = 2.5398

Theta 2 = 3.9

Theta 2 = 3.87

Theta 2 = 3.863

Theta 2 = 3.8605

Theta 3 = 6.4


Theta 3 = 6.36

Theta 3 = 6.357

Theta 3 = 6.35721


المعادلة العمودية Normal Equation

مفهوم القيم العظمى و الصغرى




- اي منحنى تصاعدي , تكون قيمة التفاضل موجبة

- اي منحنى هابط , تكون قيمة التفاضل سالبة



- اي قيمة صغرى او كبرى تكون قيمة التفاضل صفر

المعادلة العمودية Normal Equation



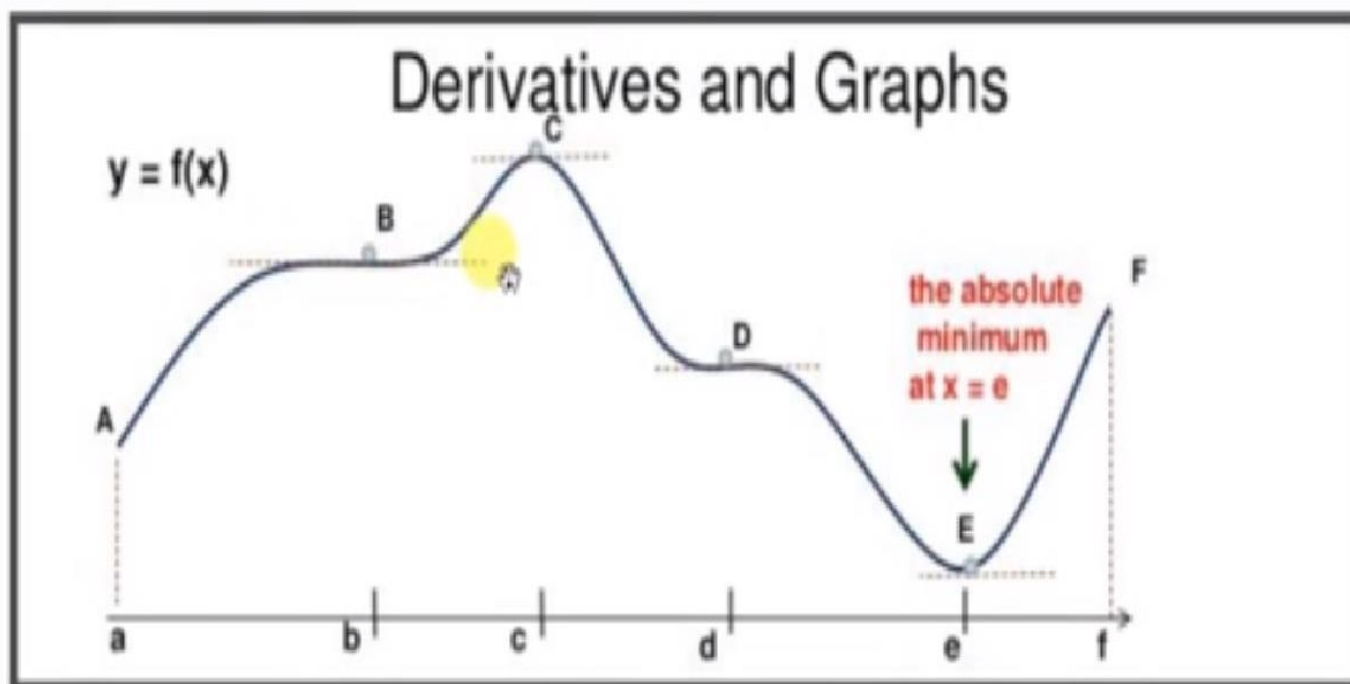
مفهوم القيم العظمى و الصغرى

- اي منحنى تصاعدي , تكون قيمة التفاضل موجبة
- اي منحنى هابط , تكون قيمة التفاضل سالبة
- اي قيمة صغرى او كبرى تكون قيمة التفاضل صفر

المعادلة العمودية Normal Equation

مفهوم القيم العظمى و الصغرى

- تتواجد عندما يكون التفاضل يساوي صفر



Linear Regression Equation معادلة التوقع الخطي

Theta0 = 5 , theta 1 = 2

Equation $h(x) = 5 + 2x$

X	Y	h(x)	h(x) - y	(h(x) - y) ²
1	7	7	0	0
2	8	9	1	1
2	7	9	2	4
3	9	11	2	4
4	11	13	2	4
5	10	15	5	25
5	12	15	3	9

$$J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2$$

$$J = 1 / 14 (0+1+4+4+4+25+9)$$

$$J = 47/14 = 3.3$$

المعادلة العمودية Normal Equation

طريقة الـ Normal Equation

- وهي عن طريق الاعتماد علي تفاضل J و مساوتها بالصفر لإيجاد قيمة الثابت المطلوبة
- و اذا كان لدينا جدول مثل هذا لاكثر من متغير , فبعد مفاضلتها و مساوتها بالصفر ستكون الثابت كالتالي

$$\theta = (X^T X)^{-1} X^T y$$

المعادلة العمودية Normal Equation

X_1	X_2	X_3	Y
العمر	القدرة	الاسطوانات	السعر
5	20	6	114
5	35	6	120
6	38	8	123
7	40	8	121
7	46	10	135

X_1	X_2	X_3	
1	1	1	
5	5	6	
20	35	38	Y
6	6	8	114
			120
			123
X_4	X_5		121
1	1		135
7	7		
40	46		
8	10		

Normal Equation المعادلة العمودية

$$\theta = (X^T X)^{-1} X^T y$$

X

1	5	20	6
1	5	35	6
1	6	38	8
1	7	40	8
1	7	46	10

X^T


1	1	1	1	1
5	5	6	7	7
20	35	38	40	46
6	6	8	8	10

Normal Equation المعادلة العمودية

$X^T X$	5	30	179	38
	30	184	1105	234
	179	1105	6785	1414
	38	234	1414	300

$(X^T X)^{-1}$	10.4	-2.6	0.05	0.4
	-2.6	1.3	-0.02	-0.5
	0.05	-0.02	0.008	-0.02
	0.46	-0.5	-0.02	0.54

Normal



$$(X^T X)^{-1} X^T$$

10.4	-2.6	0.05	0.4
-2.6	1.3	-0.02	-0.5
0.05	-0.02	0.008	-0.02
0.46	-0.5	-0.02	0.54

1	1	1	1	1
5	5	6	7	7
20	35	38	40	46
6	6	8	8	10




المعادلة العمودية Normal Equation

X_1	X_2	X_3	Y
العمر	القدرة	الاسطوانات	السعر
5	20	6	114
5	35	6	120
6	38	8	123
7	40	8	121
7	46	10	135

X_1	X_2	X_3	
1	1	1	
5	5	6	
20	35	38	
6	6	8	Y
			114
			120
			123
			121
			135
X_4	X_5		
1	1		
7	7		
40	46		
8	10		

Normal



$$(X^T X)^{-1} X^T Y$$

0.8	1.55	-0.1	-2.6	-1.5	114
0.5	0.2	0.4	1.7	0.58	120
-0.01	0.11	0.074	0.07	0.078	123
0.8	0.5	1.02	0.48	1.44	121
					135

4x1

4x5

5x1

5x1

Normal Equation المعادلة العمودية

$$(X^T X)^{-1} X^T Y$$

0.8	1.55	-0.1	-2.6	-1.5	114	-252.2
0.5	0.2	0.4	1.7	0.58	120	414.2
-0.01	0.11	0.074	0.07	0.078	123	40.162
0.8	0.5	1.02	0.48	1.44	121	529.14
					135	

المعادلة العمودية Normal Equation

أيهما أفضل : الـ Gradient Descent ولا الـ Normal Equation :

- الـ Normal Equation ميزتها ان مش محتاج تحسب قيمة **الف** , و مش هتعمل خطوات كثير , هي خطوة واحدة
- بس عيبها انها بتكون صعبة و بطيئة جدا مع عدد كبير لـ features اللي هي n لان الماتريكس هتكون مخيفة خاصة لعمل الـ inverse , فلو عدد الـ n يقل عن 10 الاف خليك في الـ Normal Equation , لو زادت يبقى لازم الـ Gradient Descent
- كمان فيه خوارزميات (زي linear regression) مش هينفع تشتغل الا بالـ Gradient Descent , و خوارزميات ثانية ممكن الـ Normal Equation , فلازم تكون عارف الاتنين و تشوف مين مناسب لايه

المعادلة العمودية Normal Equation

أحيانا نتحصل مشكلة في نوع النورمال , ان مصفوفة $X^T X$ في اكن تكون singular و معناها ان مش هينفع يتعمل لها inverse , وده هيعمل مشكلة

غالبا بيكون سبب انها singular حاجة من اتنين

- ان عدد ال- m (عدد الصفوف) اقل من عدد ال- n (العوامل او المعلومات عن كل بيت) خاصة لو الفرق كبير , فا اما تمسح شوية عوامل مش مهمة , او تزود بيانات و صفوف , او تشوف نوع ثاني
- اما يكون فيه عمودين معتمدين علي بعض , يعني فيه مثلا مساحة البيت بالمتر المربع , ومساحة البيت بالقدم المربع , وده معناه ان فيه عمود كامل يساوي عمود ثاني مضروب في فاكتور , وده هيودي ان قيمة الماتريكس كلها تساوي صفر , فال- inverse مش ه يظهر