

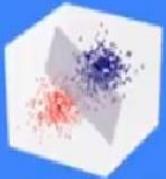


Lec. 10

Linear Classifiers

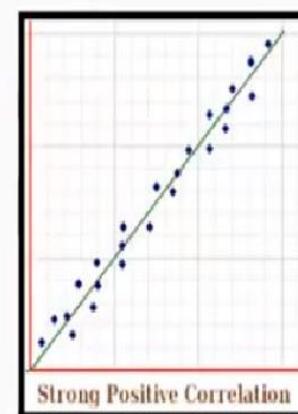
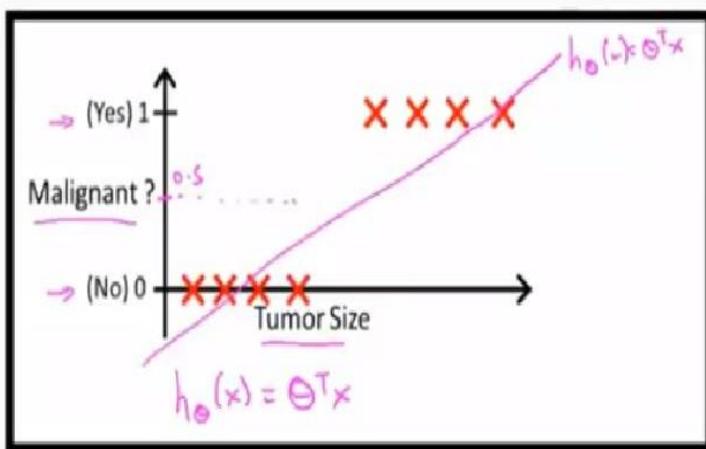
Assist. Prof. Dr. Saad Albawi

أساسيات التصنيف



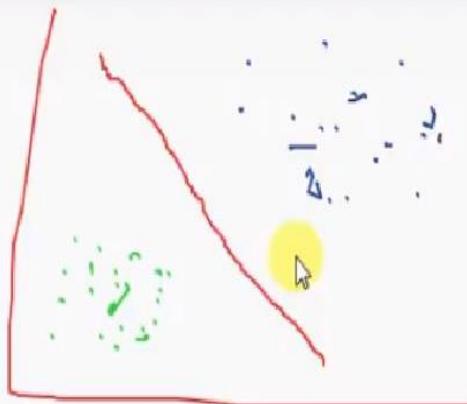
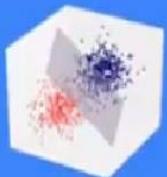
التصنيف و الخط الملائم :

- في التنبؤ قمنا بعمل الخط الملائم بسهولة
- يصعب في التصنيف عمل خط يلائم النقط العليا و الدنيا معا
- يقوم الخوارزم بعمل خط يفصل بينهم او curve يمشي عليهم



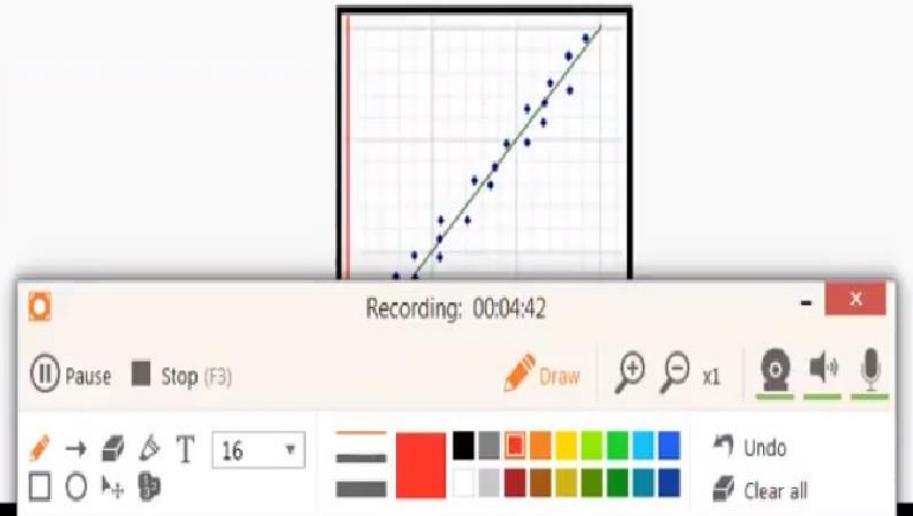
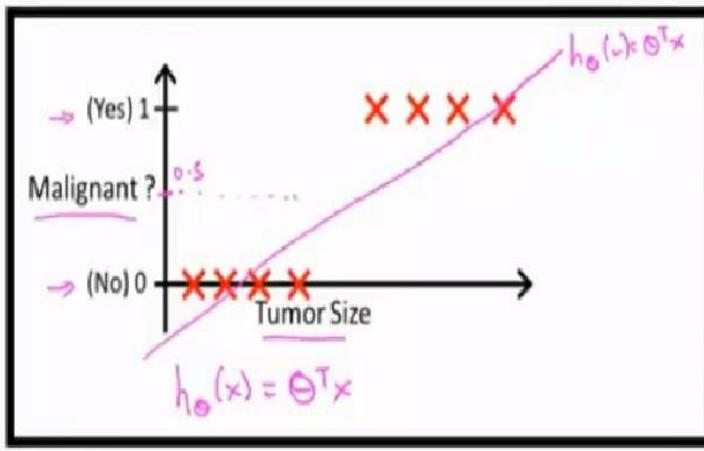
Strong Positive Correlation

أساسيات التصنيف

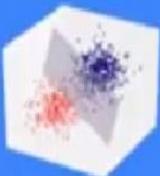


التصنيف و الخط الملائم :

- في التنبؤ قمنا بعمل الخط الملائم بسهولة
- يصعب في التصنيف عمل خط يلامن النقط العليا و الدنيا معا
- يقوم الخوارزم بعمل خط يفصل بينهم او curve يمشي عليهم

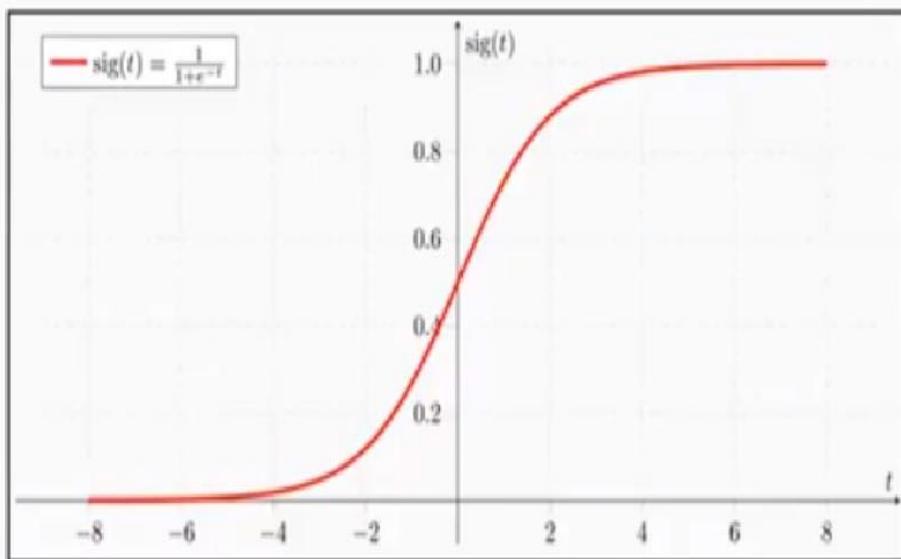


أساسيات التصنيف



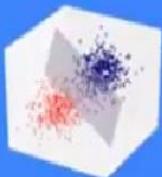
الفكرة :

- لازم قيمة اللاث في النهاية تكون بين الصفر والواحد ، مينفعش اكتر من 1 او اقل من صفر
- لا تنس أن αH هي القيمة المتوقعة ، وأن αZ هي القيمة الحقيقية .. وأن αX هو المدخلات
- يتم هذا عبر معادلة تسمى السigmoid



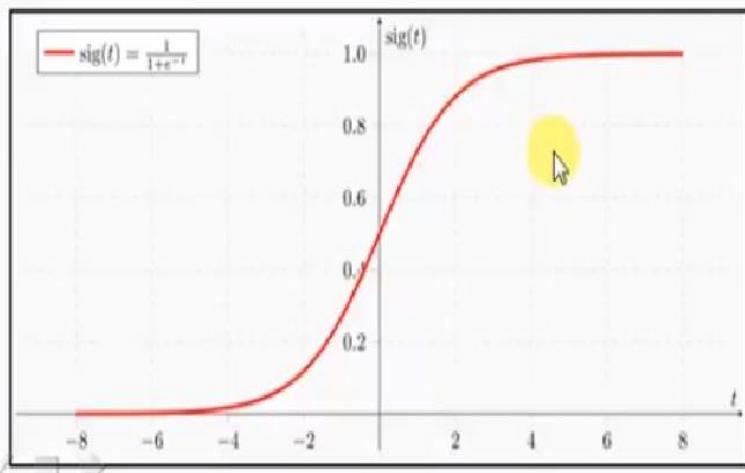
$$h_{\theta}(x) = \underline{\frac{1}{1+e^{-\theta^T x}}}$$

أساسيات التصنيف



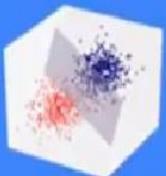
السيجمويد :

- حينما تكون قيمة X بالسالب , تصبح α لها أنس موجب , وبالتالي تزداد قيمتها , فتصبح قيمة h قليلة
- حينما تقل جدا قيمة X مثلًا سالب الف , يكون α أنس موجب ضخم , يعني رقم كبير , فتكون h تساوي 0
- حينما يكون X قيمة موجبة , يكون α أنس سالب , اي قيمة صغيرة , وبالقسمة عليها تزداد قيمة h
- حينما تزداد قيمة X جدا , يكون α أنس سالب كبير , أي تساوي صفر , فتكون h تساوي 1



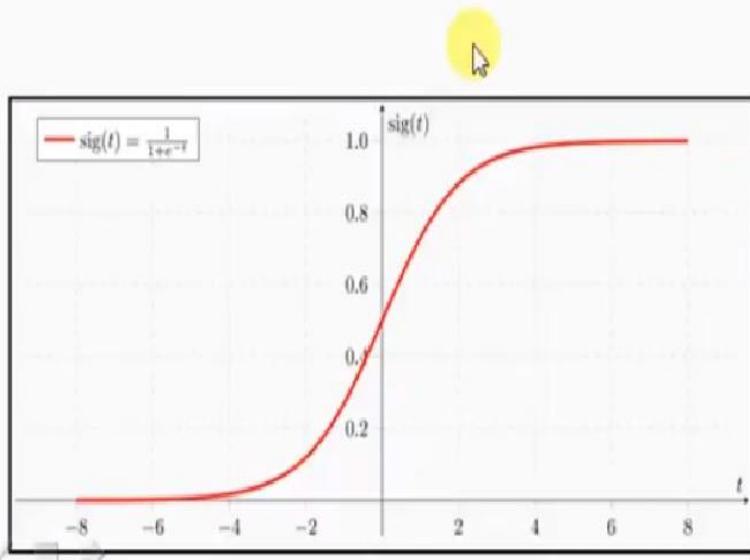
$$h_{\theta}(x) = \underline{\frac{1}{1+e^{-\theta^T x}}}$$

أساسيات التصنيف

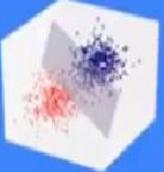


السيجمويد :

- أي أن قيم h وهى القيمة المتوقعة ، ستتراوی بين 0 و 1 ، وهو ما يجعل المخرج احد صنفين
- لو كان هناك قيم بين الصفر والواحد ، فاما يتم تقريرها 1 مثلا ، او أن يكون باسلوب الاحتمالا
- وبهذا يتم تصنيف البيانات لدينا لقسمين مثل المطلوب (ورم حميد او خبيث ، طالب مقبول او مرفوض ..)



$$h_{\theta}(x) = \underline{\frac{1}{1+e^{-\theta^T x}}}$$



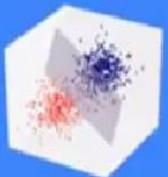
أساسيات التصنيف

المعادلة :

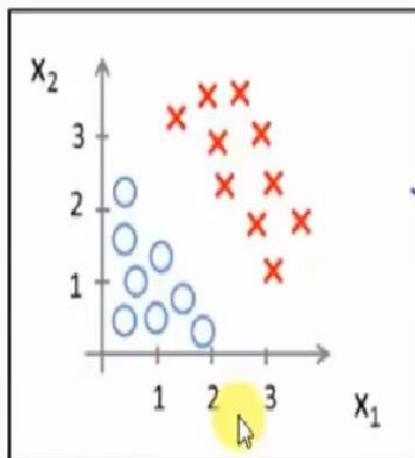
- المقصود بال $\theta^T x$ معادلة حاصل ضرب الثيتات في الاكسات مثلما فعلنا في التنبؤ
- قد تكون معادلة من الدرجة الاولى او الثانية او اكثـر ، حسب كمية التعقيد في المسألة

$$\underline{h_{\theta}(x)} = \frac{1}{1+e^{-\theta^T x}}$$

أساسيات التصنيف



مثال عملی :



- لدينا عدد من المنتجات ونريد تقسيمها لمنتجات مقبولة باللون الأزرق ومنتجات مرفوضة باللون الأحمر ، اعتمادا على معلوماتين x_1 ، x_2 .

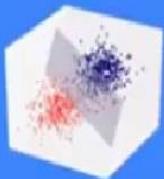
- معادلة h وهي القيمة المتوقعة ، ستكون من الدرجة الأولى ، وبالتالي ستعتمد على x_1 ، x_2 ، فتحتاج لثلاث ثيتات كالتالي :

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

- بفرض ثيتا صفر تساوي سالب 3 ، وكل من ثيتا 1 و 2 تساوي 1 تكون المعادلة :

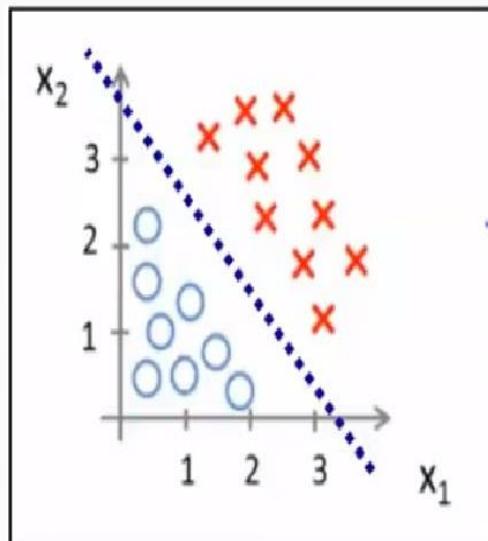
$$-3 + x_1 + x_2 \geq 0$$

أساسيات التصنيف



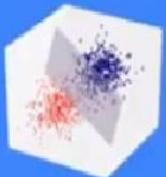
مثال عملی :

- هذه المtribانية ، تقوم بعمل خط مستقيم ، يقسم المساحة لقسمين ، أحد الجانبين يحتوي على المقبول و الآخر المرفوض

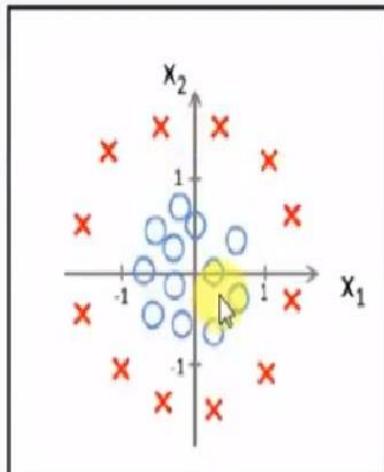


$$-3 + x_1 + x_2 \geq 0$$

أساسيات التصنيف



مثال آخر :



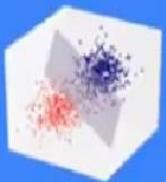
- المنتجات المقبولة في المنتصف والمرفوضة تحيط بها
- استخدام خط للفصل بينهم لن يكون ممكنا ، وبالتالي المعادلة بالدرجة الاولى غير متماش
- يتم استخدام معادلة بالدرجة الثانية كالتالي :

$$h_{\theta}(x) = g(\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_1^2 + \theta_4 x_2^2)$$

- بفرض ثيتا صفر تساوي سالب 1 ، وكلتا من ثيتا 1 و 2 تساوي صفر ، وكلتا من ثيتا 3 و 4 تساوي 1 ، تكون :

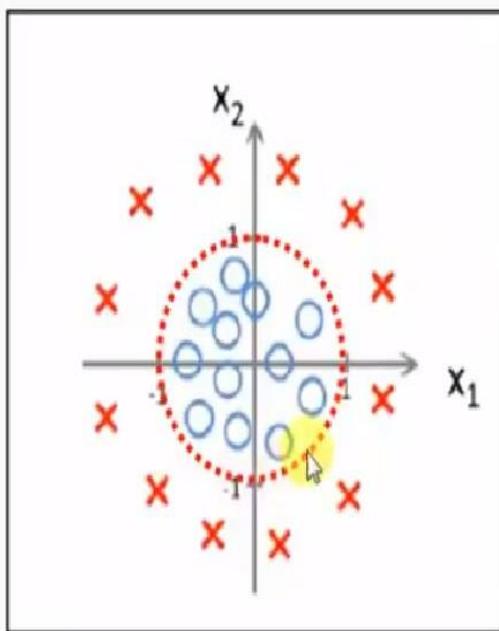
$$x_1^2 + x_2^2 \geq 1$$

أساسيات التصنيف

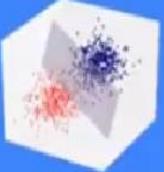


مثال آخر :

- وهي معادلة دائرة ، مركزها نقطة الأصل ، ونصف قطرها 1 ، أي أن كل ما داخل الدائرة مقبول ، وكل ما خارجها مرفوض



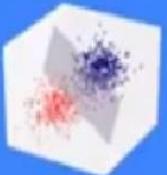
$$x_1^2 + x_2^2 \geq 1$$



أساسيات التصنيف

وبالتالي :

- نجحنا بعمل فاصل (خط مستقيم او دائرة او منحنى) يقوم بالفصل بين الصنفين المطلوبين لدينا ، المقبول و المرفوض ، السليم و التالف ، الخبيث والحميد
- يمكن للمعادلات ان تكون من الدرجات العليا حسب مدى تعقيدها
- يتم فرض قيمة ثيتا مؤقتا ، وسنتعلم لاحقا كيفية تحديدها
- عبر ادخال الاكسلات (البيانات) يقوم الخوارزم بتحديد هل اي القسمين ستكون هي
- قد تكون الاشكال الفاصلة اشكال أكثر تعقيد من مجرد دائرة او خط



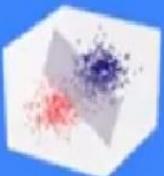
المعادلة المستخدمة للتصنيف

ما هي المعادلة المستخدمة :

- أي الصيغة الرياضية التي يجب استخدامها ، لتمكننا من عمل تصنيف سليم للمنتجات كما شرحنا
- في التبؤ استخدمنا المعادلة :

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

- لكنها لن تكون صالحة في تقسيم البيانات Classification ، وعليها البحث عن صيغة جديدة



المعادلة المستخدمة للتصنيف

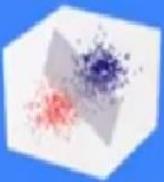
المعادلة المستخدمة :

- تسمى معادلة الخطأ Cost و التي نستخدم لها الرمز J ، والهدف تقليلها بقدر الإمكان
- المعادلة ليست واحدة ، بل اثنين ، واحدة في حالة y تساوي 0 وواحدة في حالة y تساوي 1
- المعادلة ببساطة هي مجموع سالب قيمة لوغاريتم h او 1 ناقص h ، ويتم قسمتها على m وهو عدد العناصر
- سيتم جمع المعادلتين معاً كما سنرى بعد قليل

$$J(\theta) = \frac{1}{m} \sum_{i=1}^m \text{Cost}(h_\theta(x^{(i)}), y^{(i)})$$

$$\text{Cost}(h_\theta(x), y) = -\log(h_\theta(x)) \quad \text{if } y = 1$$

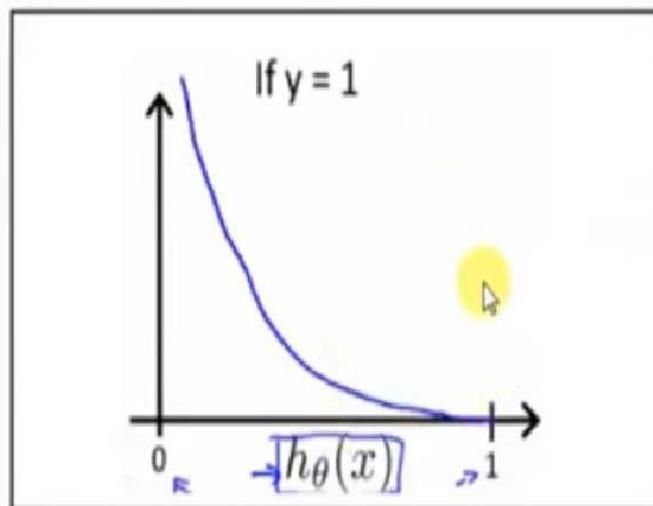
$$\text{Cost}(h_\theta(x), y) = -\log(1 - h_\theta(x)) \quad \text{if } y = 0$$

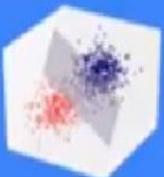


المعادلة المستخدمة للتنبیف

الحالة الأولى : $y = 1$

- المحور الافقى به قيمة لا h و الرأسى فيه قيمة لـ 1
- حينما تقل قيمة h لصفر ، تكون قيمة الخطأ كبيرة ، لأنها بعيدة عن القيمة الحقيقية 1
- حينما تقارب قيمة h من 1 ، يكون الخطأ قليل و يصل لصفر حينما تساوى 1 ، لأن القيمة الحقيقية تساوى 1

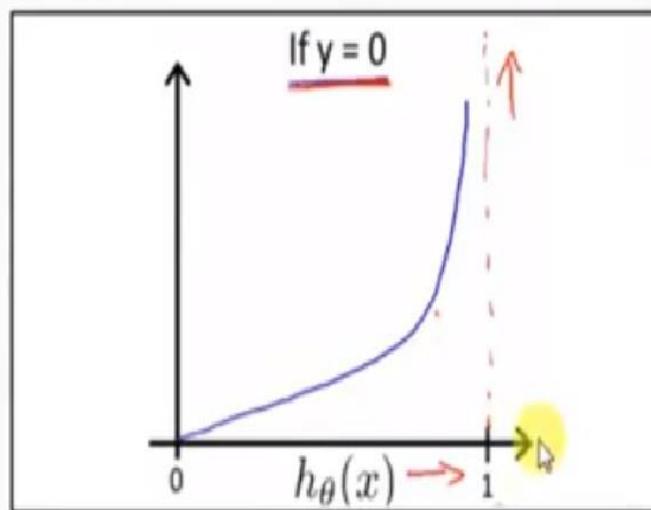




المعادلة المستخدمة للتصنيف

الحالة الثانية : $y = 0$

- المحور الافقى به قيمة لا h و الرأسى فيه قيمة لـ 1
- بينما تقل قيمة h لصفر ، تكون قيمة الخطأ صغيرة ، لأنها قريبة عن القيمة الحقيقية 1
- بينما تقترب قيمة h من 1 ، يكون الخطأ كبير ، لأن القيمة الحقيقية تساوى 1





المعادلة المستخدمة للتصنيف

المعادلة المجمعة :

- يتم تجميع المعاجلتين معا ، في كلتا حالتي y ، حينما تكون بصفر وبواحد ، بالصيغة التالية :

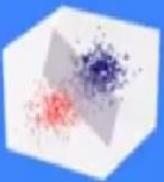
$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m y^{(i)} \log h_\theta(x^{(i)}) + (1 - y^{(i)}) \log (1 - h_\theta(x^{(i)})) \right]$$

- حينما تكون y تساوي صفر ، يختفي الجزء الاول من المعادلة و تصير هكذا :

$$J(\theta) = -\frac{1}{m} [(1 - y^{(i)}) \log (1 - h_\theta(x^{(i)}))]$$

- حينما تكون y تساوي 1 ، يختفي الجزء الثاني من المعادلة و تكون هكذا

$$J(\theta) = -\frac{1}{m} \left[\sum_{i=1}^m y^{(i)} \log h_\theta(x^{(i)}) \right]$$



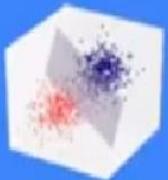
المعادلة المستخدمة للتصنيف

ایجاد الثیتا :

- کي لا ننسى ، الثیتا هي معاملات الإکسات ، التي يتم ايجاجها ، وذلك للحصول على معادلة الكيرف الاكثر ملائمة *best fit curve*
- يتم ايجاد الثیتا بهذه بالمعادلة ، حيث :
- الرمز \hat{z} يشير لرقم الثیتا المطلوبة $(0, 1, 2, \dots)$ ، أي انه سيتم تكرارها لكل الثیيات المطلوبة
- الفا هي معامل يشير لمقدار خطوة الحساب (مثلاً فعلنا في التنبؤ)
- المعادلة بعد الفا هي تفاضل المعادلة الكبيرة السابقة (مش لازم تعرف اثباتها)
- يتم وضع اکس 0 لثیتا صفر و اکس 1 لثیتا 1 و هكذا

$$\theta_j := \theta_j - \alpha \sum_{i=1}^m (h_\theta(x^{(i)}) - y^{(i)}) x_j^{(i)}$$

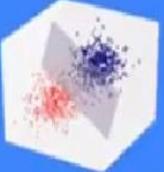
مثال عملي للتصنيف



ایجاد الثیتا :

- کي لاننسى ، الثیتا هي معاملات الإكسات ، التي يتم ايجاجها ، وذلك للحصول على معادلة الكيرف الاكثر ملائمة best fit curve
- يتم ايجاد الثیتا بهذه بالمعادلة ، حيث :
- الرمز ز يشير لرقم الثیتا المطلوبة (0 , 1 , 2 , ...) ، أي انه سيتم تكرارها لكل الثیيات المطلوبة
- الفا هي معامل يشير لمقدار خطوة الحساب (مثلما فعلنا في التنبؤ)
- المعادلة بعد الفا هي تفاضل المعادلة الكبيرة السابقة (مش لازم تعرف اثباتها)
- يتم وضع اكس 0 لثیتا صفر و اكس 1 لثیتا 1 و هكذا

$$\theta_j := \theta_j - \alpha \sum_{i=1}^m (h_\theta(x^{(i)}) - y^{(i)}) x_j^{(i)}$$



مثال عملي للتنبیف



المعادلة كمصفوفات :

- يجب ان نقوم بتحويلها لمصفوفة للتعامل معها باي لغة برمجة ، فستكون المعادلة كالتالي ، حيث :

- ثيتا هنا هي مصفوفة عمود واحد ، وفيها صفوف بعدد الثيتات $(n \times 1)$

- الفا و m هي نفس الرموز السابق ذكرها

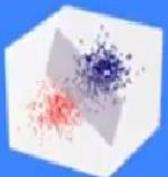
- اكس ترانسيوز ، هي تدوير مصفوفة اكس الكبيرة ، كانت $(m \times n)$ ، وستصير $(n \times m)$

- اكس في ثيتا ، المقصود بها ضرب مصفوفة اكسات في مصفوفة ثيتات

- الواي هنا هي مصفوفة قيم واي (اصفار ووحدات) يتم طرحها منها $(m \times 1)$

$$\theta := \theta - \frac{\alpha}{m} X^T (g(X\theta) - \vec{y})$$

مثال عملي للتصنيف



مثال عملي :

مريض	فقر الدم	السن	الوزن	الاسم
1	1	18	70	أحمد
1	0	22	88	حامد
1	0	38	91	منى
0	1	21	65	سيد
0	1	25	79	لبني

- لدينا بيانات افراد ، و هل مصابين بالانفلونزا او لا

- عدد العينة m هو 5

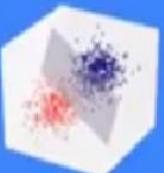
- عدد العناصر **features** و رمزها n هو 3

- الارقام الخضراء هي x

- الارقام الحمراء هي y

- عدد الثيارات سيكون 4 ، لانه يكون عدد الـ **features** زائد 1

- الاسماء لن تستخدم لأنها غير مؤثرة في الحساب



مثال عملي للتصنيف

المعادلة كمصفوفات :

- يجب ان نقوم بتحويلها لمصفوفة للتعامل معها باي لغة برمجة ، فستكون المعادلة كالتالي ، حيث :
 - ثيتا هنا هي مصفوفة عمود واحد ، وفيها صفوف بعدد الثيتات ($n \times 1$)
 - الفا و m هي نفس الرموز السابق ذكرها
 - اكس ترانسبوز ، هي تدوير مصفوفة اكس الكبيرة ، كانت ($m \times n$) ، وستصير ($n \times m$)
 - اكس في ثيتا ، المقصود بها ضرب مصفوفة اكسات في مصفوفة ثيتات
 - الواي هنا هي مصفوفة قيم واي (اصفار ووحدات) يتم طرحها منها ($m \times 1$)

$$\theta := \theta - \frac{\alpha}{m} X^T (g(X\theta) - \vec{y})$$



مثال عملي للتصنيف

المصفوفات :

٤X٥ تدوير مصفوفة X

1	1	1	1	1
1	0	0	1	1
18	22	38	21	25
70	88	91	65	79

٥X٤ مصفوفة X

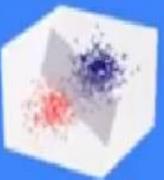
1	1	18	70
1	0	22	88
1	0	38	91
1	1	21	65
1	1	25	79

٥X١ مصفوفة y

1
1
1
0
0

٤X١ مصفوفة ثيتا

1
1
1
1



مثال عملي للتصنيف

عملية ضرب \times في ثيتا :

- حاصل ضرب مصفوفة 5×4 في مصفوفة 4×1 ستكون مصفوفة 5×1

- ستكون كالتالي :

90

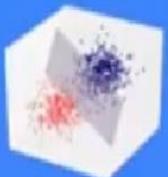
111

130

88

106

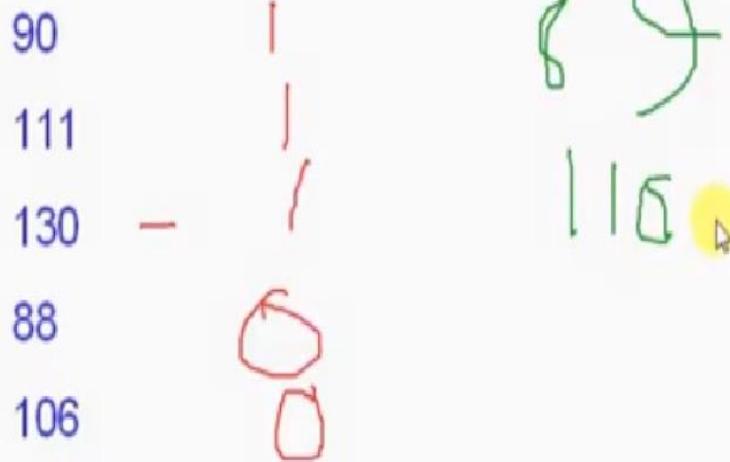
مثال عملي للتنصيف

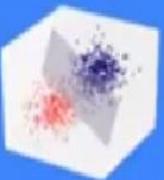


عملية ضرب X في ثيتا :

- حاصل ضرب مصفوفة 5×4 في مصفوفة 4×1 ستكون مصفوفة 5×1

- ستكون كالتالى :





مثال عملي للتصنيف

الطرح من ٦ :

- كل المصفوفتين هي 5×1 ، وبالتالي الطرح يمكن أن يتم و ستكون أيضا

- ستكون كالتالي :

89

110

129

88

106

مثال عملي للتصنيف



الطرح من y :

- كل المصفوفتين هي 5×1 ، وبالتالي الطرح يمكن أن يتم و ستكون أيضا 5×1

- ستكون كالتالي :

89

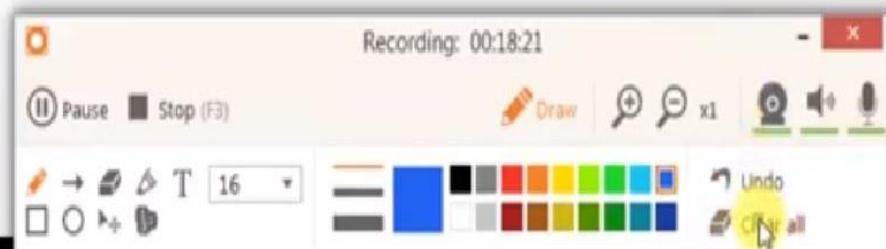
110

129

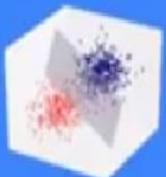
88

106

$$4 \times 5 - 5 \times 1$$



مثال عملي للتنزيف



الضرب في تدوير إكس :

- تدوير إكس هو 4×5 و المصفوفة الموجودة هي 5×1 فالضرب ممكن ، وستكون 4×1

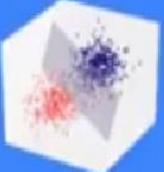
1	1	1	1	1
1	0	0	1	1
18	22	38	21	25
70	88	91	65	79

X

=

89
110
129
88
106

522
283
13422
41743



مثال عملي للتصنيف

الضرب في الفا على m :

- بفرض الفا تساوي 0.5 نقسمها على m التي تساوي 5 تكون 0.1

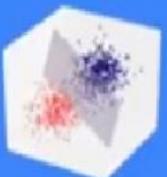
- نضرب 0.1 في القيم الاربعة تكون

52.2

28.3

1342.2

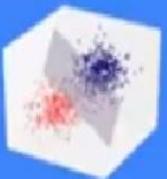
4174.3



مثال عملي للتصنيف

اخيرا نطرح قيم ثيتا الاصلية منها تكون :

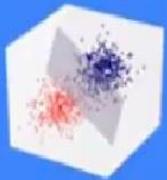
$$\begin{array}{r} 1 \\ 1 \\ 1 \\ 1 \end{array} - \begin{array}{r} 52.2 \\ 28.3 \\ 1342.2 \\ 4174.3 \end{array} = \begin{array}{r} -51.2 \\ -27.3 \\ -1341.2 \\ -4173.3 \end{array}$$



مثال عملي للتصنيف

القرار :

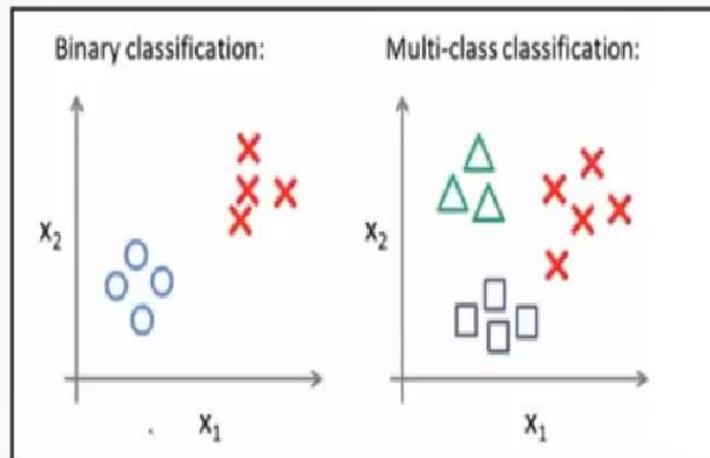
- يتم تكرار العملية مرات عديدة ، وكل مرة يتم ادخال قيم ثيتا التم تم اخراجها ، حتى نصل لقيم ثيتا المثالية
- قيم ثيتا هذه ، هي التي ستقوم برسم الخط او الدائرة او الكيرف الذي سيقوم بالفصل بين الصنفين ، المريض و غير المريض
- اذا جاءت اليانا بيانات فرد جديد ، ونزير ان نعلم هل هو مريض ام غير مريض ، فنقوم بضرب قيم اكسسات (features) في الثيتات المثلية ، وسيكون الرقم اما صفر او واحد ، وبهذا نقوم قد قمنا بعمل تصنيف سليم



التصنيف المتعدد MultiClassification

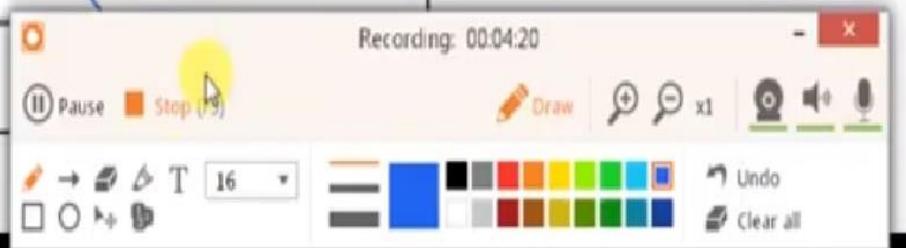
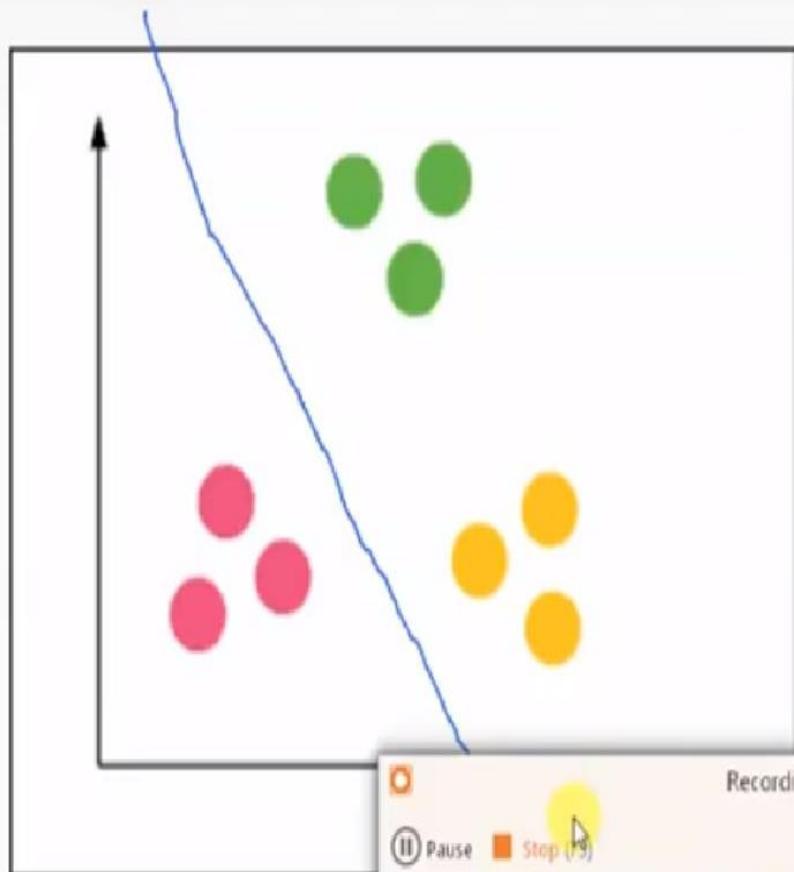
: معناه

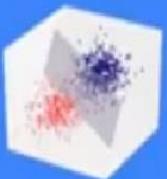
- أن التصنيف ليس فقط لعنصرین او إجابتين ، ولكن لأكثر من إجابة
- بدلاً من أن يكون الشخص مريض أو غير مريض ، يكون مريض عادي ، مريض جدا ، متماثل للشفاء ، غير مريض
- بدلاً من المنتج مقبول أو مرفوض : منتج متميز ، منتج مقبول ، مرفوض لكن يمكن اصلاحه ، مرفوض تماما
- بدلاً من استخدام 1 و 0 للتصنيف ، سيكون هناك ارقام عديدة (. . . , 3 , 2 , 1 , 0)



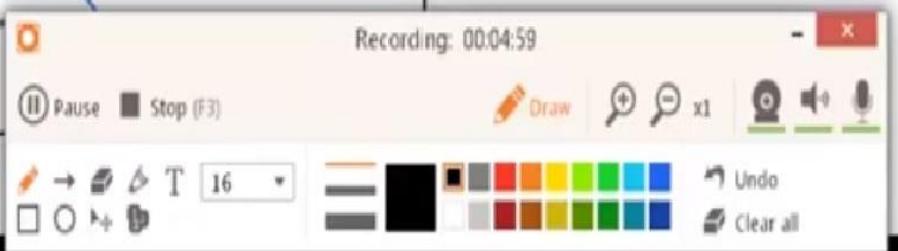
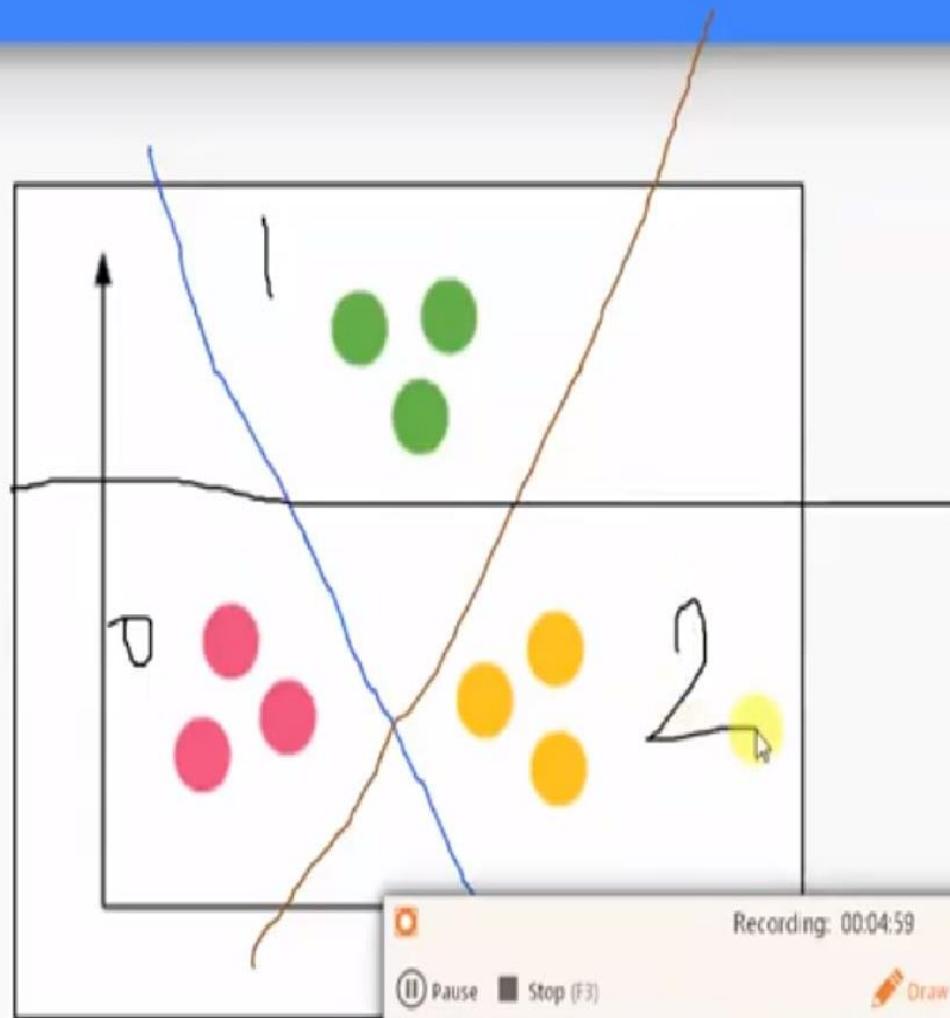


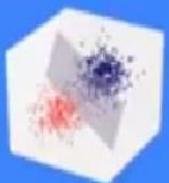
التصنيف المتعدد MultiClassification



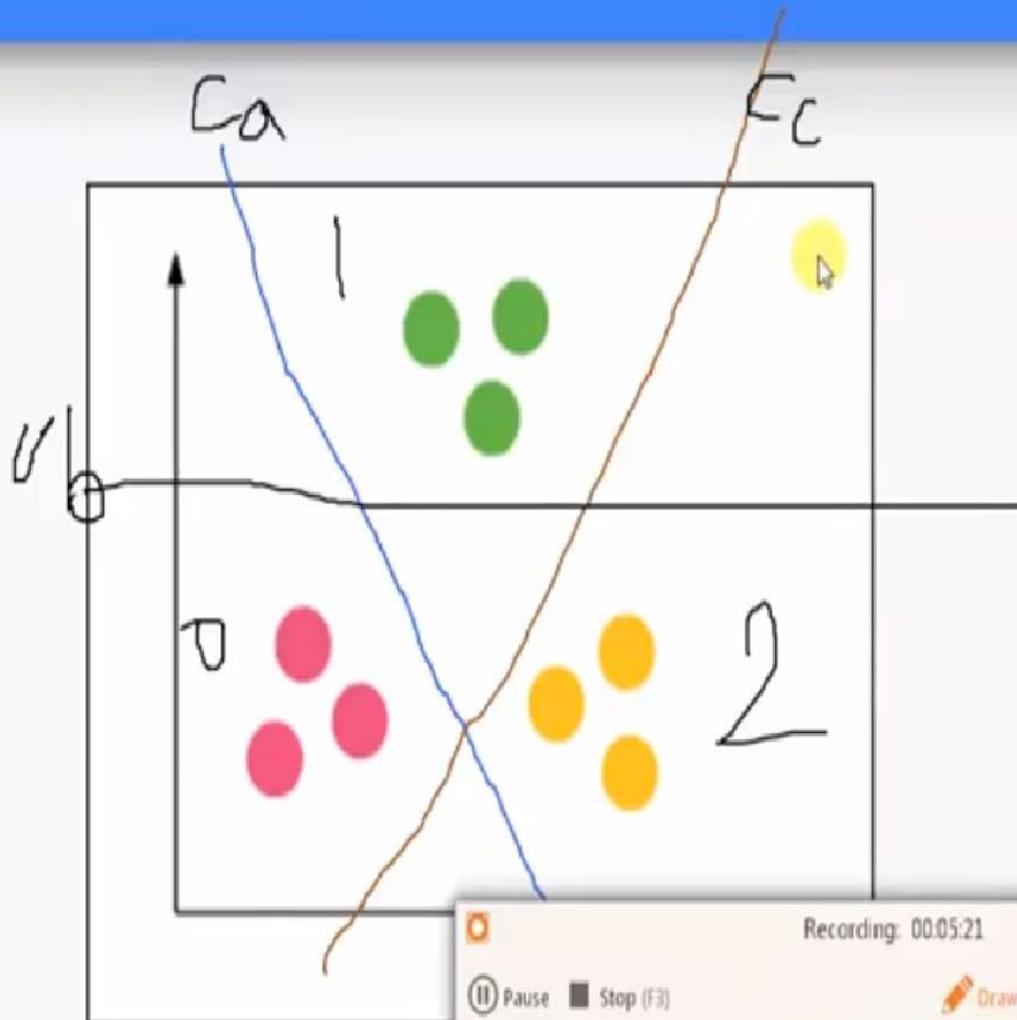


التصنيف المتعدد MultiClassification





التصنيف المتعدد MultiClassification

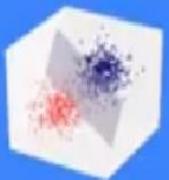


Recording: 00:05:21

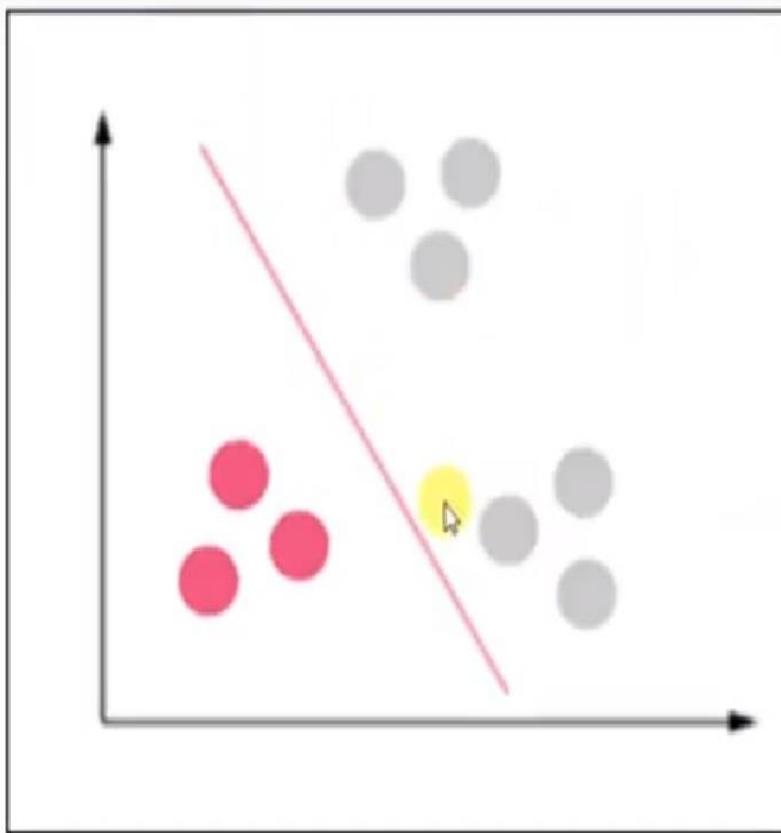
Pause Stop (F5) Draw

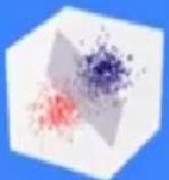
Clear all

Undo

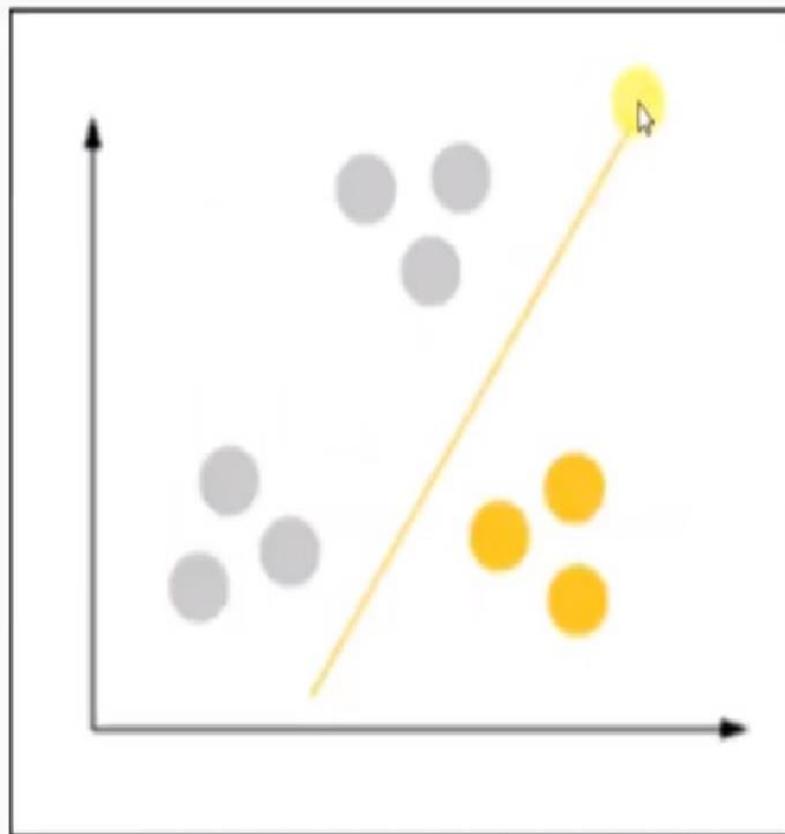


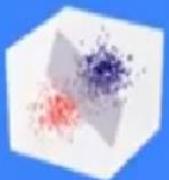
التصنيف المتعدد MultiClassification



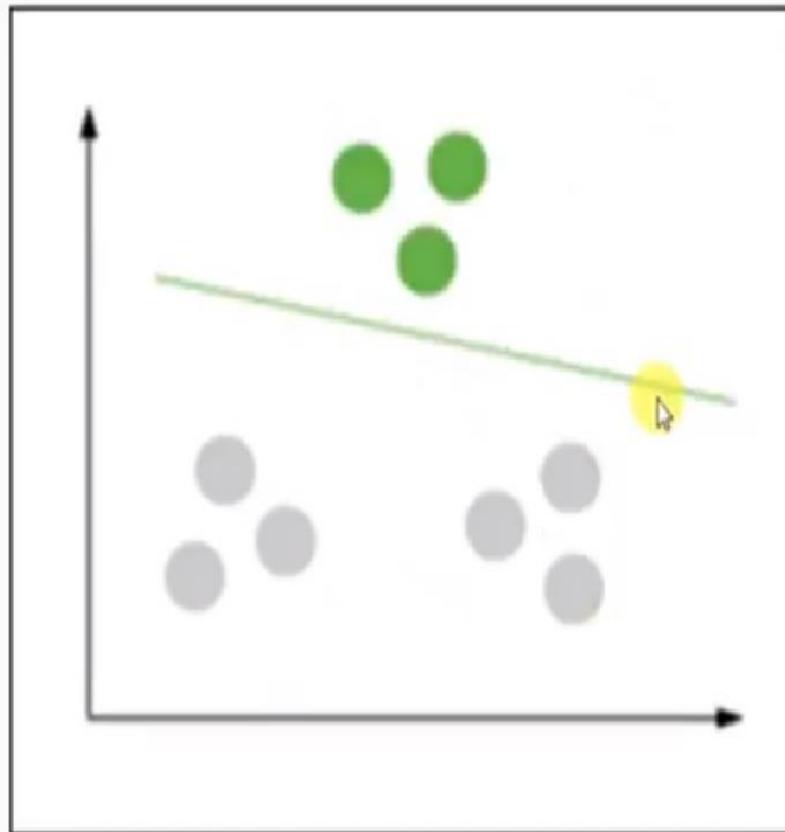


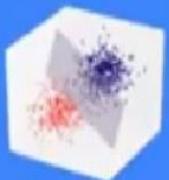
التصنيف المتعدد MultiClassification





التصنيف المتعدد MultiClassification

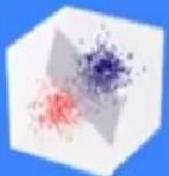




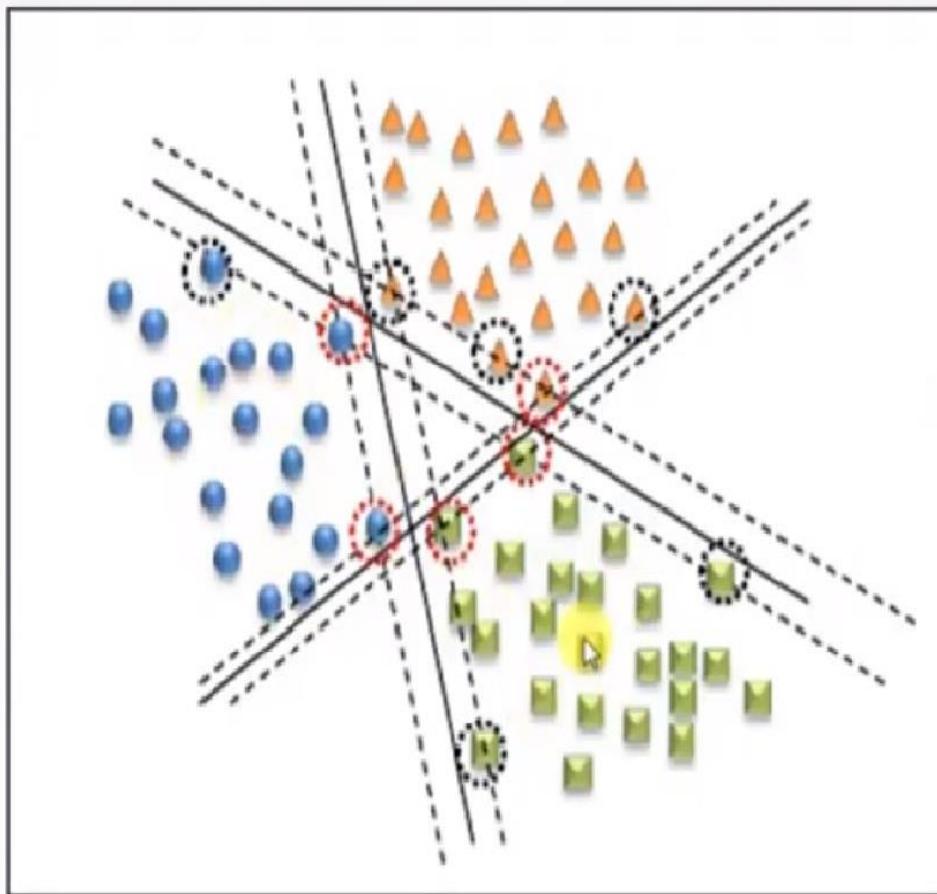
التصنيف المتعدد MultiClassification

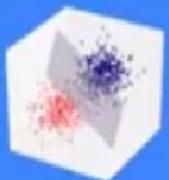
الواحد للجميع ، والجميع للجميع :

OVA vs AVA

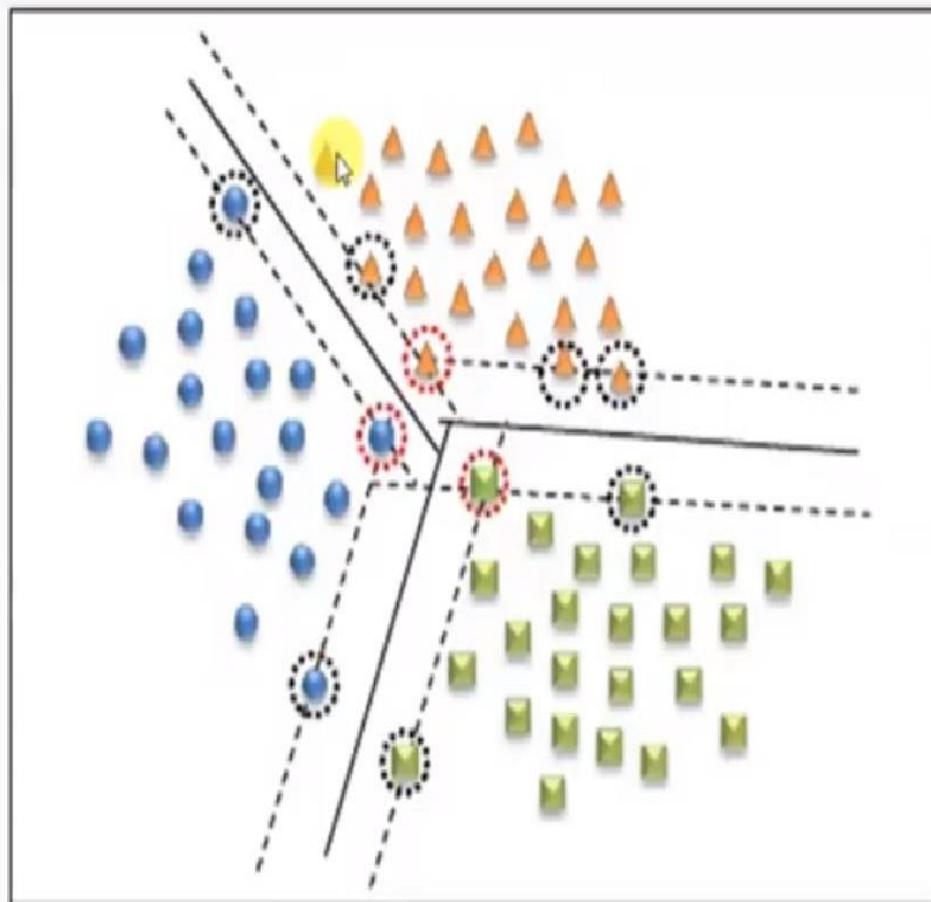


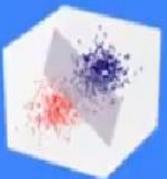
التصنيف المتعدد MultiClassification





التنبیف المتعدد MultiClassification

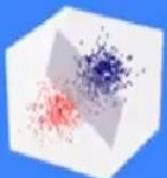




الضبط الزائد و الناقص UF , OF

المعنى :

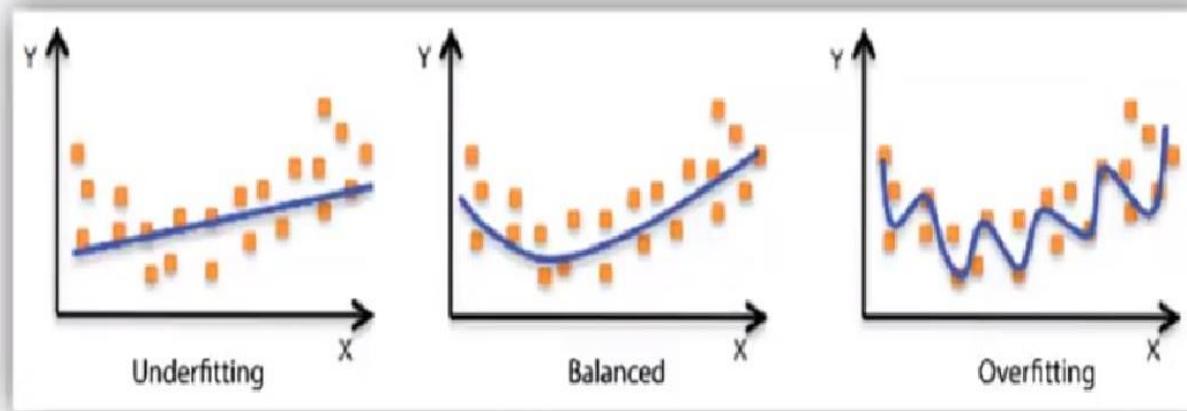
- يقصد بالضبط الناقص Underfitting حينما تكون المعادلة الرياضية المستخدمة أضعف وأقل من تغطية جميع النقاط الموجودة
- يقصد بالضبط الزائد Overfitting حينما تقوم المعادلة الرياضية المستخدمة بضبط جميع النقاط بوجه كامل ، مما يسبب أخطاء في التوقع

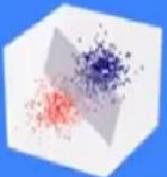


الضيـط الزائـد و الناقـص UF , OF

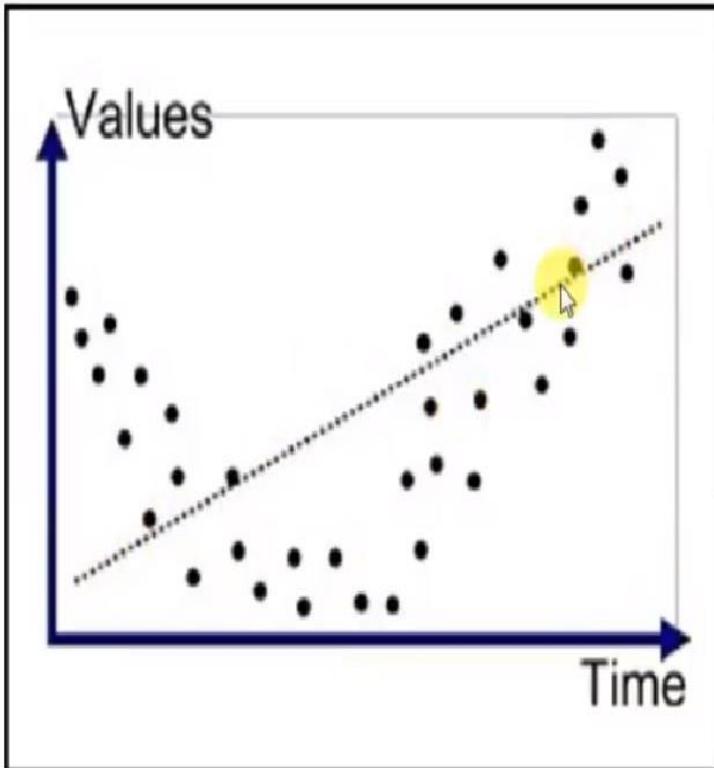
المعنى :

- يقصد بالضيـط الناقـص Underfitting حينما تكون المعادلة الرياضية المستخدمة أضعف وأقل من تغطية جميع النقاط الموجودة
- يقصد بالضيـط الزائـد Overfitting حينما تقوم المعادلة الرياضية المستخدمة بضبط جميع النقاط بوجه كامل ، مما يسبب أخطاء في التوقع



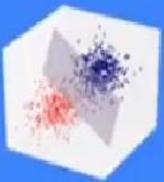


الضبط الزائد و الناقص UF , OF

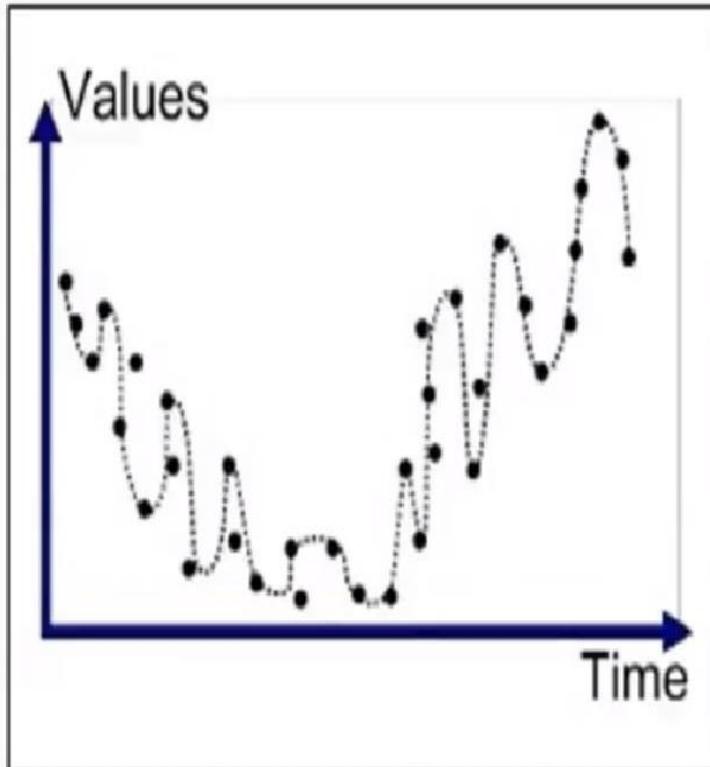


الضبط الناقص :

- تكون المعادلة بسيطة ، وصغريرة ، وغير قادرة على الالامام و المرور بأغلب النقاط الموجودة
- يكون لها مشكلة كبيرة في توقع القيم القادمة ، وتكون نسبة الخطأ كبيرة
- غالباً تأتي بسبب نقط البيانات (اما عدد العينات m او عدد العناصر n)، أو اختيار المعادلة غير المناسبة



الضبط الزائد و الناقص UF , OF



الضبط الزائد :

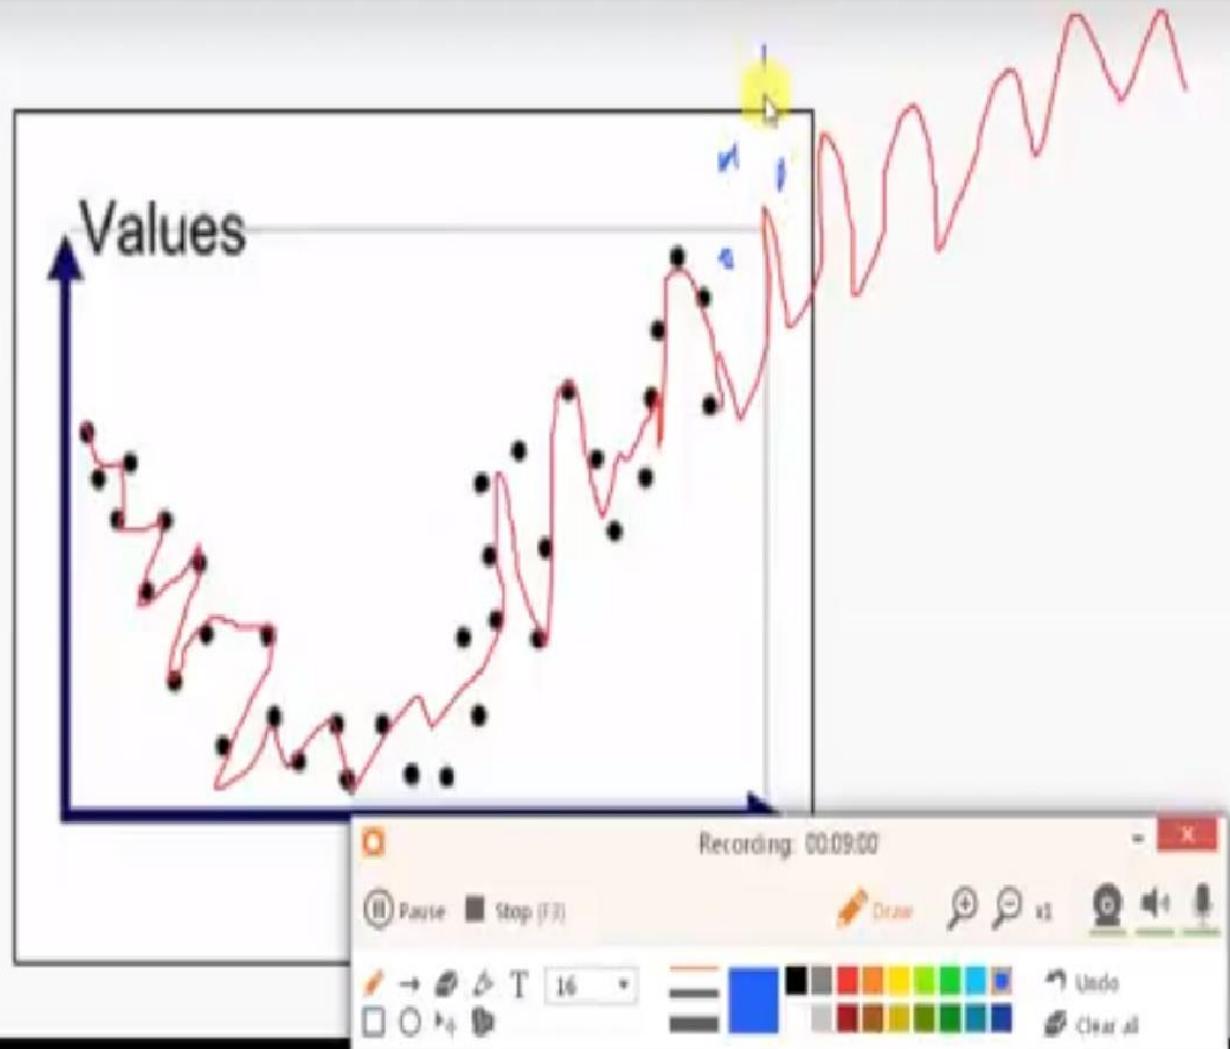
- حينما تقوم المعادلة بالمرور على كل النقاط بالضبط ، وبشكل مبالغ فيه

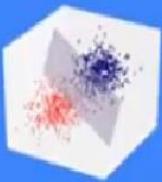
- الشكل يبدو جميل ، لكن المشكلة في توقع اي قيمة جديدة

- غالباً تأتي بسبب الزيادة الغير مفيدة للبيانات (إما عدد العينات m او عدد العناصر n)، أو اختيار المعادلة غير المناسبة

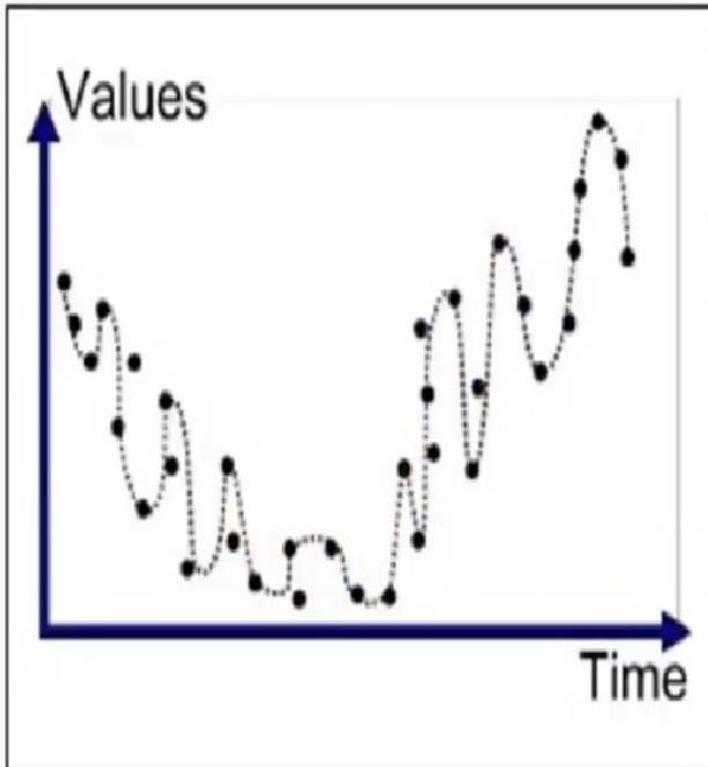


الضيـط الزائـد و الناقـص UF , OF





الضبط الزائد و الناقص UF , OF



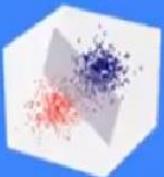
الضبط الزائد :

- حينما تقوم المعادلة بالمرور على كل النقاط بالضبط ، وبشكل مبالغ فيه

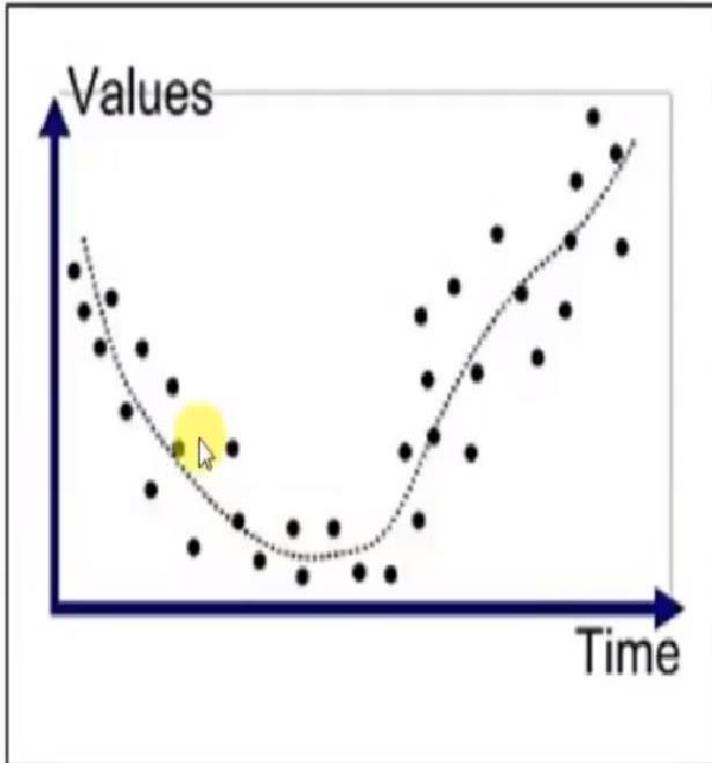


- الشكل يبدو جميل ، لكن المشكلة في توقع اي قيمة جديدة

- غالبا تأتي بسبب الزيادة الغير مفيدة للبيانات (إما عدد العينات m او عدد العناصر n)، أو اختيار المعادلة غير المناسبة



الضبط الزائد و الناقص UF , OF

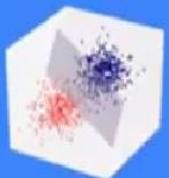


الضبط المناسب :

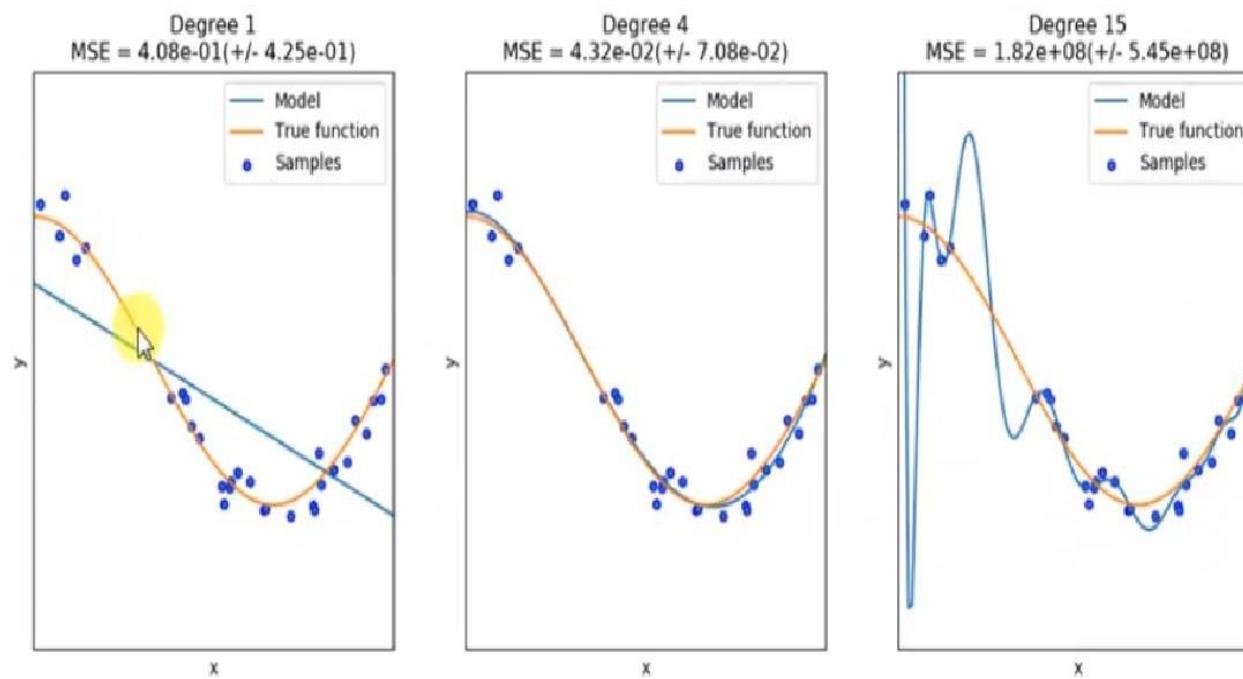
- حينما تقوم المعادلة بالمرور على أغلب النقاط بالضبط ، وبشكل مناسب

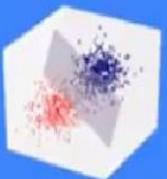
- الشكل قد لا يبدو تاما ، لكن التوقع يكون قريب جدا من الصحيح

- يتم ظبطها باختيار عدد مناسب من البيانات ، والمعادلة السليمة و استخدام اسلوب التعريم (Regularization)

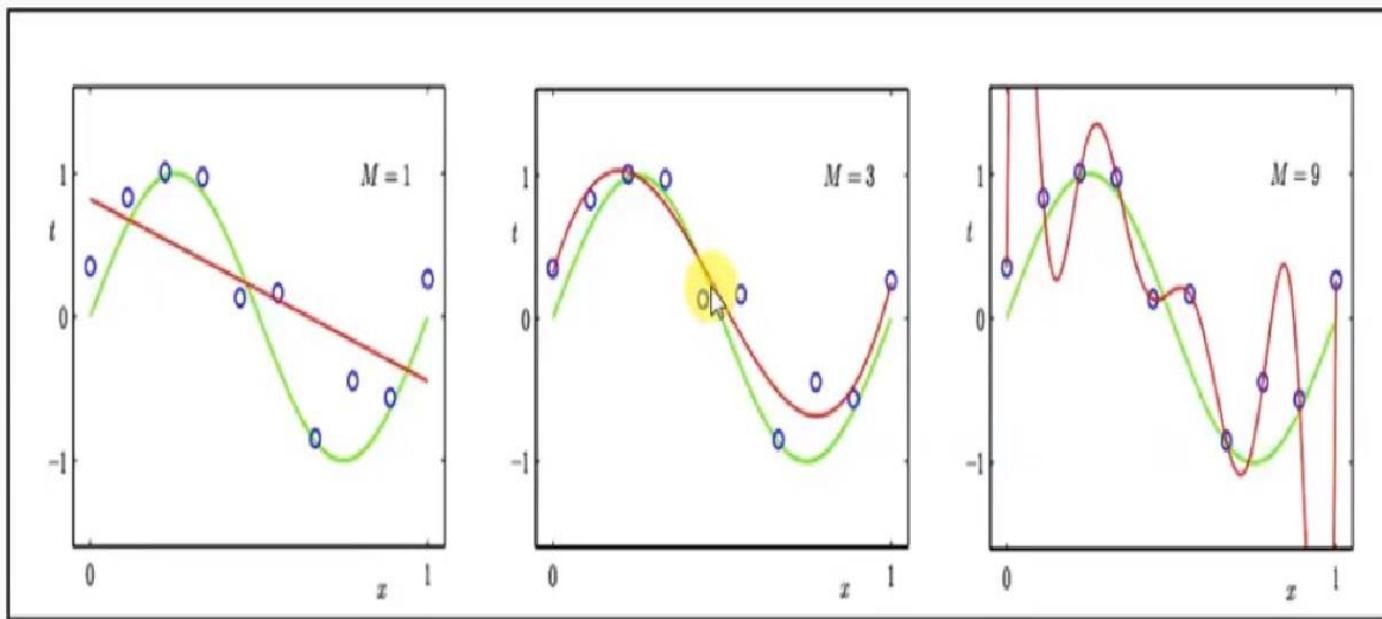


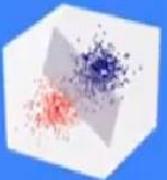
الضبط الزائد و الناقص UF , OF





الضبط الزائد و الناقص UF, OF



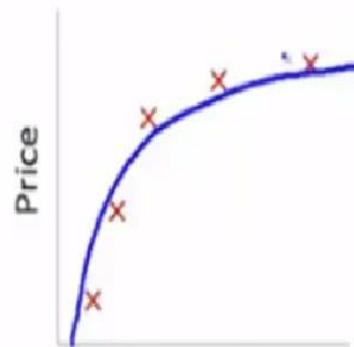


الخطأ الزائد والتناقض UF, OF



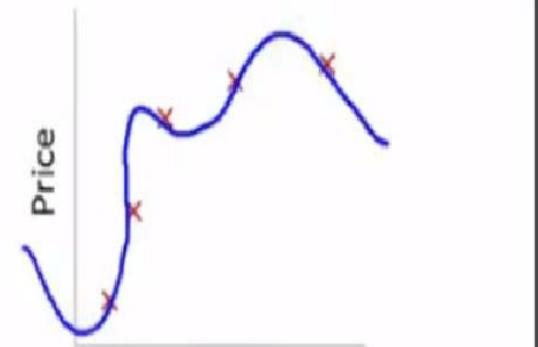
$$\theta_0 + \theta_1 x$$

High bias
(underfit)



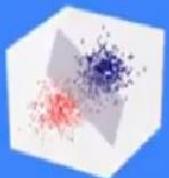
$$\theta_0 + \theta_1 x + \theta_2 x^2$$

"Just right"

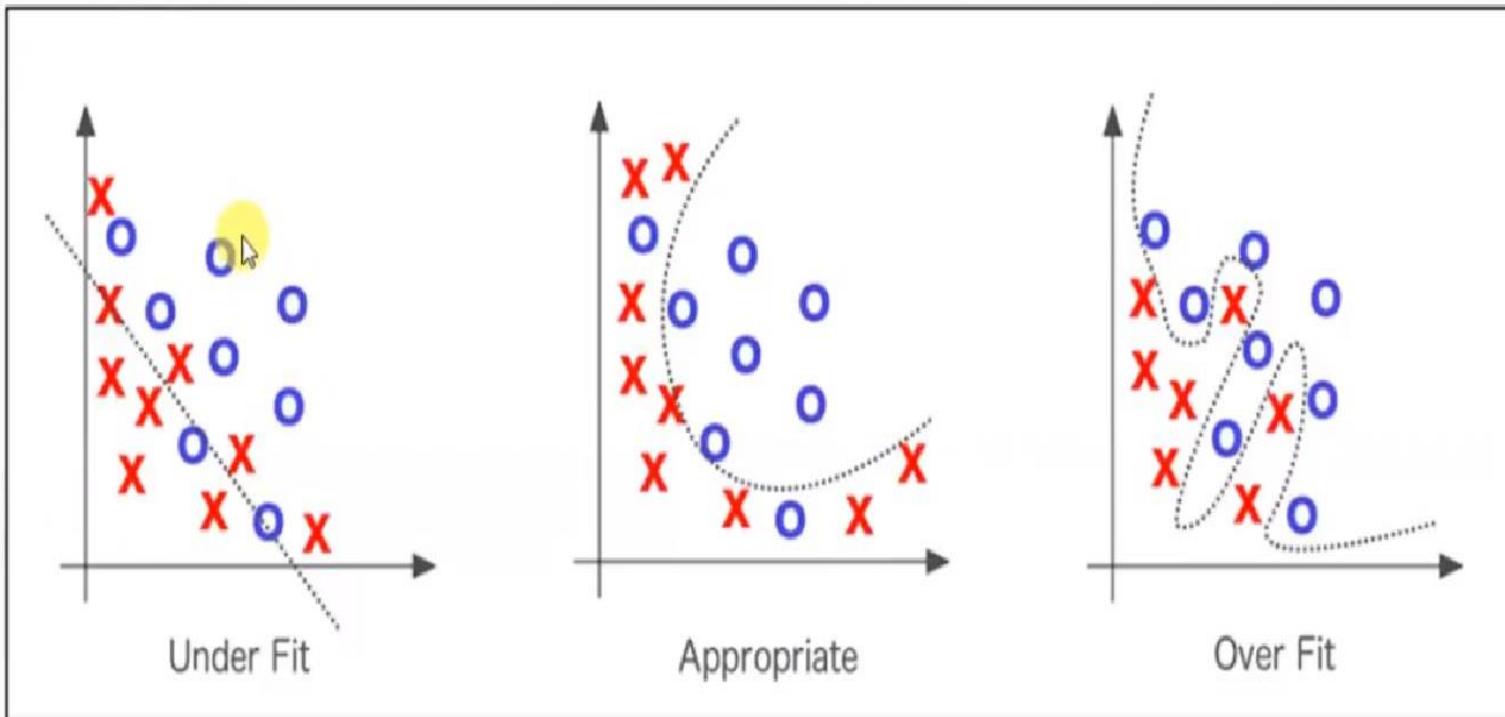


$$\theta_0 + \theta_1 x + \theta_2 x^2 + \theta_3 x^3 + \theta_4 x^4$$

High variance
(overfit)



الضبط الزائد و الناقص UF , OF





تنعيم البيانات Regularization

المفهوم :

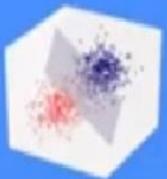
- عملية تنقية البيانات بهدف التخلص من الضياع الزائد λF
- يتم عبر 3 طرق هامة، قد نقوم بإحداها فقط أو باثنتين فقط أو بالثلاثة معاً:
 - * إتقاء البيانات
 - * تغيير المعاملات
 - * إضافة (المدا)



تنعيم البيانات Regularization

انتقاء البيانات :

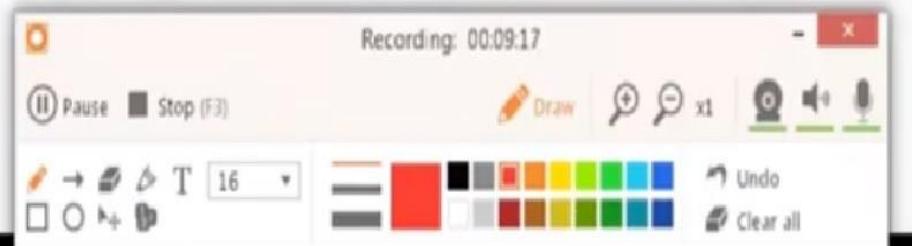
- يقصد بها انتقاء العناصر features التي يتم استخدامها في اي خوارزم
- وجود عناصر غير مؤثرة في الناتج المطلوب سيقوم بعمل تضليل mislead للخوارزم
- في هذه الخطوة لابد من الاستعانة بمتخصصين في المجال ، ولن يعتمد هذا على معلوماتك الخاصة
- ما الذي يؤثر في جودة ثمرة البطاطس (الطول ، الوزن ، اللون ، نوع التربة ، كمية الماء ، السماد ، الشمس ، درجة الحرارة ، الرياح ، الشهر الذي تم زراعتها فيه ...)
- نزع العناصر غير المؤثرة يؤدي لتطوير الخوارزم الخاص بك بشكل كبير ، و دقة البيانات الخارجة منه
- كما أن اختيار العينات اساسا (المفهوم m) له دور مهم في صحة البيانات ، فيجب ان تكون متجانسة و ممثلة لكل اجزاء المجموعة

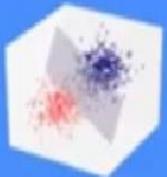


تنعيم البيانات Regularization

انتقاء البيانات :

- يقصد بها انتقاء العناصر features التي يتم استخدامها في اي خوارزم
- وجود عناصر غير مؤثرة في الناتج المطلوب سيقوم بعمل تضليل mislead للخوارزم
- في هذه الخطوة لابد من الاستعانة بمتخصصين في المجال ، ولن يعتمد هذا على معلوماتك الخاصة
- ما الذي يؤثر في جودة ثمرة البطاطس ~~(الطول ، الوزن ، اللون ، نوع التربة ، كمية الماء ، السهماد ، السففس ، درجة الحرارة ، الرياح ، الشهر الذي تم زراعتها فيه ...)~~
- نزع العناصر غير المؤثرة يؤدي لتطوير الخوارزم الخاص بك بشكل كبير ، و دقة البيانات الخارجة منه
- كما أن اختيار العينات اساسا (الصفوف m) له دور مهم في صحة البيانات ، فيجب ان تكون متجانسة و ممثلة لكل اجزاء المجموعة





تنعيم البيانات Regularization

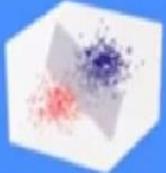
تغغير المعاملات :

- يقصد بها تغيير معاملات العناصر التي تؤثر في المخرج لكن ليس بشكل كبير
- فمثلاً درجة حرارة المدينة التي يعيش فيها الطالب ، تؤثر بشكل ما في تفوقه و درجاته ، ولكن بمقدار بسيط
- فلو كانت لدى معادلة بها اربع عوامل مؤثرة هي إكس 1 و 2 و 3 و 4 كالتالي :

$$\theta_0 + \theta_1 x + \theta_2 x_2 + \theta_3 x_3 + \theta_4 x_4$$



- فنرغب في تقليل معاملات (ثيتا) للعناصر غير المهمة (إكس 3 و 4) و بقاء معاملات العناصر الهامة (إكس 1 و 2) كما هي



تنعيم البيانات Regularization

تغير المعاملات :

- ويتم هذا عبر اضافة ارقام ضخمة للمعاملات المطلوب **لتقليلها** لمعادلة التكلفة Cost Function

↓

$$\min_{\theta} \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 + 1000 \cdot \theta_3^2 + 1000 \cdot \theta_4^2$$

- إضافة أرقام كبيرة جانب الثنيات المطلوب **لتقليل قيمها** ، سيجبر المعادلة لتقليل قيمها جدا ليكون حاصل ضربهم رقم معقول



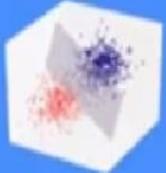
تنعيم البيانات Regularization

إضافة لمدا λ :

- واجبنا يسمى معامل التنعيم regularization factor
- ونقوم بضميه في مجموعة مربيعات جميع الثيتات (باستثناء ثيتا صفر) ، ثم إضافته لمعادلة الكوست

$$\min_{\theta} \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 + \lambda \sum_{j=1}^n \theta_j^2$$

- باختيار قيمة معينة للمدا ، و بدأ ادخال المعادلة المحددة في الخوارزم ، نري أن الا OF سيختفي
- اذا ظل الا OF موجود ، نغير قليلا من قيمة لمدا و نجرب مرة اخري



تنعيم البيانات Regularization

إضافة لمدا λ :

- الصيغة المعدلة لمعادلة الكوست ستكون

Repeat {

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

$$\theta_j := \theta_j - \alpha \left[\left(\frac{1}{m} \sum_{i=1}^m (h_\theta(x^{(i)}) - y^{(i)}) x_j^{(i)} \right) + \frac{\lambda}{m} \theta_j \right] \quad j \in \{1, 2, \dots, n\}$$

}

- وهى جزئين لأن الثيتا صفر لا يتم ضربها في اللمندا ، والثانية لباقي الثيتات

- يتم تكرار العملية للوصول لأفضل قيمة للثيتات ، ويتم تغيير قيمة اللمندا اذا ما ظل الـ OF موجود