

Logistic Regression

الانحدار اللوجستي

التنبؤ: Prediction: هو تقدير القيمة المستقبلية لمُتغير بناءً على معرفة قيم متغير آخر، وبفقدنا في:

- * تحديد العلاقة شكل العلاقة بين المتغيرين، بامنا وبيانياً (خط الانحدار)
- * توضيح اتجاه العلاقة بين المتغيرين.
- * التنبؤ بقيمة أحد المتغيرين بدلالة المتغير الآخر.

الانحدار: Regression: هو أسلوب يمكن بواسطته تقدير قيمة أحد المتغيرين بناءً على معلومة قيمة المتغير الآخر عن طريق معادلة الانحدار، وله أنواع:

الانحدار الخطي البسيط: فعلمة بسيطة تعني أن المتغير التابع Y يعتمد على متغير مستقل واحد وهو X وكلمة خطي تعني أن العلاقة بين المتغيرين X و Y علاقة خطية.

الانحدار الخطي المتعدد: إذا كان المتغير Y يعتمد على أكثر من متغير مستقل فنحن أمام الانحدار الخطي المتعدد.

الانحدار غير الخطي: إذا كانت العلاقة بين المتغير Y والمتغيران المستقلة غير خطية مثل أن تكون من الدرجة الثانية، أو أسية أو لوغاريتمية.

الانحدار الخطي البسيط: بعد تمثيل الأزواج المرتبة بالمستوى نضطلع على شكل انتسار، فإذا أظهر الشكل الانتشار للبيانات أن هناك علاقة خطية بين المتغيرين نقوم بتقدير خط الانحدار Y على X بواسطة العلاقة:

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

حيث a : ثابت الانحدار أو الجزء المقطوع من Y ، b : ميل خط الانحدار

وتحسب القمتان a و b من العلاقتان التاليتين:

$$b = \frac{n \sum XY - (\sum X)(\sum Y)}{n \sum X^2 - (\sum X)^2} \quad a = \frac{\sum Y - b \sum X}{n}$$

أيضا قيمة مقدرة $\hat{y}$ بغرض بقيمة معلومة للمتغير المستقل ولكن X_n في معادلة تقديري خط الانحدار، ملحوظات هامة:

* ميل الخط يمثل الكمية المتغيرة في Y المتغيرة للغير في X المقدار وحدة واحدة

* إشارة معامل الانحدار تدل على نوع الارتباط (موجب أو عكسي) مثال: لدراسة علاقة الاستهلاك للطاقة (Y) بالانتاج (X) لمادة الفوسفات (مليون قنطار) خلال سنوات 1950-1959 يوضحها الجدول التالي:

Y	6	8	9	8	7	6	5	6	5	5
X	10	13	15	14	9	7	6	6	5	5

أوجد معادلة الانحدار الخطي البسيط وتوقع قيمة الاستهلاك عندما يصل الانتاج إلى 16 مليون قنطار.

$$b = \frac{n \sum XY - (\sum X)(\sum Y)}{n \sum X^2 - (\sum X)^2} = \frac{6320 - 90 \cdot 65}{9420 - 90^2} = \frac{6320 - 5850}{9420 - 8100} = \frac{470}{1320} = 0,36$$

$$a = \frac{\sum Y - b \sum X}{n} = \frac{65 - (0,36)(90)}{10} = 3,26$$

X	Y	XY	X ²
10	6	60	100
13	8	104	169
15	9	135	225
14	8	112	196
9	7	63	81
7	6	42	49
6	5	30	36
6	6	36	36
5	5	25	25
5	5	25	25
Σ	90	632	9420

وتكون معادلة خط الانحدار $\hat{y} = 3.26 + 0.36x$

للتوقع قيمة الاستهلاك المعاني عند ما يصل الإنتاج إلى 16 مليون قنطار، يكون لدينا $x_h = 16$ بالتعويض في معادلة خط الانحدار يكون لدينا

$$\hat{y}_h = a + bx_h$$

$$= 3.26 + 0.36(16) = 9.02$$

الانحدار اللوجستي: الانحدار اللوجستي هو نموذج إحصائي للتنبؤ باحتمالية وقوع حدث ما وذلك بناءً على البيانات على معنى لوجستي، نستخدم الانحدار اللوجستي عدة متغيرات مستقلة (مستقلة **Predictors**)

والتي يمكن أن تكون نسبية أو فئوية أو ترتيبية أو اسمية مقابل متغير متنبأ به (تابع) واحد. مثال احتمال إصابة فرد ما

من عدم الإصابة بالربو يمكن التنبؤ بها من خلال معرفة معلومات حول الجانب الوراثي والمناعي للفرد وتقد يوحده الخصي لدية ... إن

الانحدار اللوجستي يقوم بتحليل العلاقة بين مجموعة من المتغيرات المستقلة ومتغير تابع يكون تصنيفياً **Categorical** أو ترتيبياً **Ordinal** من خلال تقدير احتمال وقوع حدث ما عدة عن طريق تركيب منصف لوجستي

نحال استخدم اسم الانحدار اللوجستي:

يوظف الانحدار اللوجستي في حافتي الدراسات التي:

* تهدف إلى التنبؤ وشرح قيم متغيرات كيفية، حيث يعتبر الأنسب أسلوب احصائي في الدراسات التي تهدف إلى بناء نماذج تنبؤية ويكون المتغير التابع فيها متغيراً كميًا.

* كذلك نستخدم الانحدار اللوجستي بهدف استنباط احتمالات

هذه ما يكون في وصفه خطر، حيث يساع الاستعداد للوصف في المجال الصحي والبي قصه التنبؤ بإمكانية الإصابة مرضا ما من عدة ...

* كما تستخدم في التسويق لحساب ميل المستهلك إلى شراء منتج ما أو امتناعه عن الشراء.

شروط تطبيق الانحدار اللوجستي:

* أن يكون المتغير التابع متغيرا اسميا ثنائيا يصنف الانحدار اللوجستي ثنائي الحد، أو تصنيفيا متعدد الحدود. بالسنة للأعداد اللوغستي

* أن يصنف النموذج على أكثر من متغير مستقل يكون في المستوى التصنيفي أو الترتيبي أو الفئوي أو النسبي.

* أن يحصل المتغير التابع احتمالا واحد لكل فرد بمعنى لا يكون الفرد في فئتين في نفس الوقت.

* عدم وجود التعددية الخطية *multicollinearity* بمعنى عدم وجود ارتباطات قوة بين المتغيرات المستقلة

أنواع الانحدار اللوجستي:

1- الانحدار اللوجستي الترتيبي: يتميز بتفسير أثر المتغيرات المستقلة (المستقلة) باختلاف مستويات قياسها على الاستجابات الترتيبية بمعنى أن تكون المتغير التابع متغيرا ترتيبيا.

2- الانحدار اللوجستي ثنائي الحد: أيضا بالانحدار اللوجستي الثنائي ويستخدم في تفسير أثر المتغيرات المستقلة على الاستجابات الثنائية بمعنى تفسير قد يكون على المتغير المستقل ذات المستويات المختلفة على التنبؤ بمتغير واحد تابع يكون ثنائي التفرع (ذكر، أنثى) / مريض / غير مريض

لذلك فالقيمة إما أن تكون موجبة (إيجابية) وتأخذ القيمة 1 أو غير
موجبة (سلبية) وتأخذ القيمة (0) وتأخذ معادلة الانحدار الليني
تأخذ الشكل التالي :

$$Y = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_n X_n$$

Y = المتغير التابع (التأثير)

b_0 = تمثل الحد الثابت في معادلة الانحدار الليني
 $b_n X_n$ قيمة التوجيبي للمتغيرات المستقلة

3- الانحدار اللوستي المقعد الكعوي : يتم استخدامه في حالة كون
المتغير التابع يتكون من أكثر من فئتين تصنيفيتين أو اسميتين.

$$B_0 + B_1 X \longrightarrow \text{Age}(X)$$

$$\text{Logit}(X) = g(X) = B_0 + B_1 X$$

يستخدم الانحدار اللوجستي للتنبؤ بتغير ثنائي (أي ذو القيم 0، 1) يعني الفشل، 1 يعني النجاح. المتغير التابع يأخذ قيمتين فقط

متعلقات استخدم الانحدار الخطي البسيط للبيانات الشائعة

* ليس هناك شيء يعني أن قيم المتغير التابع لن تزيد عن 1 ولن تقل عن 0

* إن غالبية النتائج لن تقع خارج الانحدار، نظرًا لطبيعة درجات المتغير التابع.

هذه المعادلة لا تصح للتنبؤ $\Rightarrow -aX + b = \hat{y}$ (واحد) بالمتغير التابع، فنتجنا نحتاج إلى معادلة تعني شيئًا للقيم التي تخرجها المعادلة قيم موجبة ومطلوبة

المعز والواحد
لذلك سنستخدم الدالة الأسية التي تعني مخرجات موجبة

$$e = 2,718282$$

الشرط 1 ← هذه العلاقة تعني
الشرط 2 ←

$$\hat{y} = e^{ax+b}$$

$$\hat{y} = \frac{e^{ax+b}}{1 + e^{ax+b}}$$

$$\hat{y} = \frac{1}{1 + e^{-(ax+b)}}$$

$\hat{y}$

$$0 \leq \hat{y} \leq 1$$

الدالة محصورة بين 0 و +∞

$$\frac{\hat{y}}{1 - \hat{y}}$$

لأنه تتركها بين -∞ و +∞

$$\log\left(\frac{\hat{y}}{1 - \hat{y}}\right) = \ln\left(\frac{\hat{y}}{1 - \hat{y}}\right)$$

$$\ln\left(\frac{\hat{y}}{1 - \hat{y}}\right) = ax + b$$

$\hat{y}$ احتمال وقوع الحدث ، $1 - \hat{y}$ احتمال عدم وقوع الحدث
(الحدث المتكامل)

تسمى نسبة الترتيب Odds Ratio $\left(\frac{\hat{y}}{1 - \hat{y}}\right)$ ^{ديفني} a تمثل الكفاءة الذي يزيد في لو غا، يتم نسبة الترتيب عند a

يزيد المتغير المستقل مرة واحدة .
(ينقص)

* إذا كانت النسبة $\left(\frac{\hat{y}}{1 - \hat{y}}\right)$ أضعف من الواحد أي أن احتمالية وقوع الحدث أقل من احتمالية عدم وقوعه ولو غا، يتم نسبة الترتيب يكون سالبا

* والعكس بالعكس للملاحظة السابقة

* إذا كانت نسبة الترتيب = 1 أي أن احتمالية وقوع الحدث تساوي احتمالية عدم وقوعه ولو غا، يتم نسبة الترتيب يكون مساويا للصفر

وفقاً للمعادلة إذا زاد المتغير X درجة واحدة فإن نسبة الترتيب تزداد بمقدار $\exp(9)$ وليس للمتغير التابع الذي يزيد بهذه النسبة.

- إذا كانت α سالبة بمعنى علاقة عكسية بين المتغيرين فإن قيمة $\exp(9)$ تكون أقل من (1)

- إذا كانت قيمة α موجبة بمعنى علاقة طردئية بين المتغيرين فإن $\exp(9)$ تكون أكبر من (1)




تظهر مجموعة البيانات للنجاح/الفشل في امتحان لـ 5 طلبة في الجدول أدناه. إذا كانت المعادلة التالية:

$$\text{Loge}(\text{Odds}) = -64 + 2 \times \text{hours}$$

Hours studied	Results (1 = Pass, 0 = Fail)
29	0
15	0
33	1
28	1
39	1

- 1- ما هو احتمال النجاح لطالب درس لمدة 33 ساعة
- 2- كم على الأقل يجب أن يدرس الطالب ليعتبر احتمال نجاحه 95%؟



$$S(x) = \frac{1}{1 + e^{-x}}$$

الدالة

$$\log(\text{Odds}) = z = -64 + 2 \times \text{hours}$$

$$p = \frac{1}{1 + e^{-z}} \quad z = -64 + 2 \times 33 = -64 + 66 = 2$$

$$p = \frac{1}{1 + e^{-2}} = 0,88$$

هذا يعني أن الطالب الذي يدرس لمدة 33 ساعة فإن
هناك احتمال مقدار 88% أن هذا الطالب سيجب في
الامتحان

-2

$$p = \frac{1}{1 + e^{-z}} = 0,95$$

$$\Rightarrow 0,95 \times (1 + e^{-z}) = 1$$

$$0,95 e^{-z} = 1 - 0,95$$

$$e^{-z} = \frac{0,05}{0,95} = 0,0526$$

$$\ln(e^x) = x$$

$$\ln(e^{-z}) = \ln(0,0526)$$

$$-z = -2,94 \Rightarrow z = 2,94$$