


## تحليل الانحدار الخطي البسيط

### Analyse de la régression Simple

كلمة انحدار: مصدرها دراسة أطوال الأبناء بالنظر إلى أطوال آبائهم  
يستخدم الانحدار الخطي البسيط لاختبار فرضية وجود علاقة بين متغير تابع  $Y$  ومتغير مفسر أو شارح أو مستقل  $X$  واحد وهذا قصد التحليل والتنبؤ.

- تحليل الانحدار الخطي البسيط: بافتراض وجود علاقة خطية بين  $X$  و  $Y$  ثم نرسم المستقيم الذي يمثل أو يقارب هذه العلاقة.

- عند دراستنا لشكل الانتشار أو سحابة النقط هل يمكن رصد حقيقة العلاقة أم لا.



- هذا التشويش أو الاضطراب نسميه بالحد العشوائي ونظر في توزيعها

- العلاقة الحقيقية والخطية تكتب:

$$Y_t = a + bX_t + U_t \dots\dots\dots(1)$$

(سلسلة زمنية لنفس الشخص).

$$Y_i = a + bX_i + U_i$$

(سلسلة مقطعية لأشخاص متعددة)

$$\hat{Y}_t = \hat{\alpha} + \hat{\beta}X_t \dots\dots\dots(2)$$

المتغيرات  $X$  و  $Y$  والمعالم  $a, b$  الحقيقية والمعالم المقدرة هي  $\hat{\alpha}, \hat{\beta}$  ووجود الحد العشوائي  $u$  في المعادلة (1) مرجعة إلى الخطأ.

● وجود متغيرات أخرى مفسرة مدرجة في المعادلة أو غير قابلة للقياس.

● الخطأ في قياس المتغيرات وعدم الدقة.

- المعلومات مصدرها العينة وسوف تعمم على المجتمع مما يعني هامش الخطأ. ويفترض فيها:

$$1. \text{ موزعة طبيعيا } U_t \sim N$$

$$2. \text{ وسطه معدوم } E(U_t) = 0$$

$$3. \text{ تباين ثابت } V(U) = E(U^2) = \sigma^2$$


$$4. \text{ عدم ارتباط الأخطاء مع بعضها } E(U_i U_j) = 0 \forall i \neq j$$

$$5. \text{ عدم ارتباط الأخطاء بالمتغير المفسر } E(U_i X_i) = 0. \text{ COV}(U_i X_i) = 0$$

في ظل هذه الفرضيات نحاول بناء خط مستقيم يمثل. التقريب للنموذج (1)

### 1. تطبيق طريقة المربعات الصغرى العادية MCØ. OLS.

وهي طريقة تقدير وأسلوب مفضل لرسم خط مستقيم لعين المشاهدات  $X$  و  $Y$  وهي تعمل على تصغير مجموع المربعات لإنحرافات النقاط الرأسية على الخط إلى أدنى حد ممكن باعتبار المعامل  $\hat{\alpha}$  هو مقدر ل  $a$  و  $\hat{\beta}$  هو مقدر ل  $b$ . فإننا نبحث في تصغير الفرق وبما أن الفرق يمكن ان يكون موجبا او سالبا نعمل على جعله و مربعا.



من (1) و (2) نجد أن:  $Y_t - \hat{Y}_t = U_t$

$$\sum U_t = \sum (Y_t - \hat{Y}_t) \rightarrow \text{Min } \sum U_t^2 = \text{Min } \sum (Y_t - \hat{Y}_t)^2$$

$$\sum U_t = 0 = \sum (Y_t - \hat{Y}_t) = 0 \quad (\text{حسب الفرضية 2 للاخطاء})$$

$$\sum (Y_t - \hat{a} - \hat{B}X_t) = 0 \Rightarrow \sum Y_t (n\hat{a} - \hat{B}\sum X_t) \Rightarrow \bar{Y} = \hat{a} + \hat{B}\bar{X} \dots (3)$$

وتفيدنا هذه الأخيرة أن الخط المقدر للنموذج يمر عبر النقطة  $(\bar{X}, \bar{Y})$  وتبقى إشكالية الخط، وباستعمال طريقة المربعات الصغرى أن تصغير مجموع مربعات الأخطاء فإننا نلجأ إلى الرياضيات وعندما نستعمل الاشتقاق الجزئي عند المعلمتين ونساوي المشتق إلى الصفر:

$$Q = \sum_{i=1}^n Ut^2 = \sum_{i=1}^n (Y_t - \hat{a} - \hat{B}X_t)^2 \text{ أي أنه}$$

ولتصغير Q نعمل على اشتقاقها جزئياً بالنسبة إلى  $\hat{a}$  و  $\hat{B}$  ونجعل المشتق يساوي الصفر:  
الهدف هو:

$$\text{Min } Q = \frac{\partial Q}{\partial \hat{a}} = \frac{\partial Q}{\partial \hat{B}} = 0$$

عندما تشتق بالنسبة إلى  $\hat{a}$  و  $\hat{B}$ :

$$Q = \sum (Y_t - \hat{a} - \hat{B}X_t)^2 = \sum (Y_t - \hat{a} - \hat{B}X_t)(Y_t - \hat{a} - \hat{B}X_t)$$

$$\frac{\partial Q}{\partial \hat{a}} = 2 \sum (Y_t - \hat{a} - \hat{B}X_t)(-1) = 0$$

$$\Rightarrow \sum (Y_t - \hat{a} - \hat{B}X_t) = 0 \dots \dots \dots (3)$$

$$\Rightarrow \hat{a} = \bar{Y} - \hat{B}\bar{X} \dots \dots \dots (4)$$

$$\frac{\partial Q}{\partial \hat{B}} = 2 \sum (Y_t - \hat{a} - \hat{B}X_t)(X_t)(-1) = 0$$

$$\Rightarrow \sum X_t(Y_t - \hat{a} - \hat{B}X_t) = 0 = \Delta \quad \sum X_t Y_t = \hat{a} \sum X_t + \hat{B} \sum X_t^2$$

بالتعويض عن قيمة  $\hat{a}$  في المعادلة (4) نجد:

$$\sum X_t Y_t = (\bar{Y} - \hat{B}\bar{X}) \sum X_t + \hat{B} \sum X_t^2$$

$$\sum X_t Y_t = \bar{Y} \sum X_t - \hat{B}\bar{X} \sum X_t + \hat{B} \sum X_t^2$$

$$\bar{X} = \frac{\sum X_t}{n} \Rightarrow \sum X_t = n\bar{X} \text{ بما أن:}$$

$$\sum X_t Y_t = n\bar{X}\bar{Y} + \hat{B}(\sum X_t^2 - n\bar{X}^2)$$

$$\Rightarrow \hat{B} = \frac{\sum X_t Y_t - n\bar{X}\bar{Y}}{\sum X_t^2 - n\bar{X}^2} \Rightarrow \hat{B} = \frac{\sum_{t=i}^n (X_t - \bar{X})(Y_t - \bar{Y})}{\sum_{t=i}^n (X_t - \bar{X})^2} \dots \dots (5)$$

$$x_t = (X_t - \bar{X}), \quad y_t = (Y_t - \bar{Y}) \quad : \quad \hat{B} = \frac{\sum x_t y_t}{\sum x_t^2} \quad (5) \text{ يمكن التعبير عن}$$

ومنه وضعنا خط مستقيم يرمز ويلخص العلاقة بين المتغير التابع Y والمتغير المفسر أو الشارح X

$$\hat{Y}_t = \hat{a} + \hat{B}X_t$$


مثال/ لدينا جدول يلخص النتائج المتحصل عليها من محصول الخنطة القمح  $Y$  باستخدام كميات السماد  $X$

n	$Y_t$	$X_t$	$y_t$	$x_t$	$x_t y_t$	$x_t^2$
1	40	6	-17	-12	204	144
2	44	10	-13	-8	104	84
3	46	12	-11	-6	66	36
4	48	14	-9	-4	36	16
5	52	16	-5	-2	10	4
6	58	18	1	0	0	0
7	60	22	3	4	12	16
8	68	24	11	6	66	36
9	74	26	17	8	136	64
10	80	32	23	14	322	196
$\Sigma$	570	180	0	0	956	576

$$\hat{B} = \frac{\Sigma n_t y_i}{\Sigma n_t^2} = \frac{956}{576} = 1.66, \quad \hat{\alpha} = \bar{Y} - \hat{B}\bar{X} = 57 - 166(18) = 27.12$$

$$\hat{Y}_t = 27.12 + 1.66X_t$$

الرسم والشكل البياني :



## 2 خواص المقدرات :

### 1 المتوسطات

$$\left. \begin{aligned} Y_t &= a + bX_t + \varepsilon_t \\ \bar{Y}_t &= a + b\bar{X}_t + \bar{\varepsilon}_t \end{aligned} \right\} \Rightarrow Y_t - \bar{Y} = b(X_t - \bar{X}) + \varepsilon_t - \bar{\varepsilon}$$

$$yt = Y_t - \bar{Y} = bxt + \varepsilon_t - \bar{\varepsilon}$$

بالتعويض في (5) عن قيم  $B$  و  $Y_t - Y$  نجد أن:

$$\hat{B} = \frac{\sum xtyt}{\sum xt^2} = \frac{\sum xt [bxt + (\varepsilon_t - \bar{\varepsilon})]}{\sum xt^2} = \frac{b \sum xt^2}{\sum xt^2} + \frac{\sum xt (\varepsilon_t - \bar{\varepsilon})}{\sum xt^2} \quad \text{on } a \setminus \sum x_t \bar{\varepsilon} = 0$$

$$\hat{B} = b + \frac{\sum xi (\varepsilon_t - \bar{\varepsilon})}{\sum xi^2} = b \frac{\sum xt \varepsilon_t}{\sum xt^2} \dots \dots (6)$$

$$E(\hat{B}) = E(b) + \frac{\sum xt E(\varepsilon_t)}{\sum xt^2} = b \quad \left| \begin{aligned} E(\hat{B}) &= b \\ E(\varepsilon_t) &= 0 \end{aligned} \right.$$

$\hat{B}$  هو مقدر غير متحيز ل  $b$

بنفس الطريقة نجد أن:  $E(\hat{a}) = a$

$$\left. \begin{aligned} \bar{Y} &= \hat{a} + \hat{B}\bar{X} \\ \bar{Y} &= a + b\bar{X} + \bar{\varepsilon} \end{aligned} \right\} \Rightarrow \hat{a} = a + \bar{\varepsilon} - (\hat{B} - b)\bar{X} ;$$

$$E(\hat{a}) = E(a) + E(\bar{\varepsilon}) - E((\hat{B} - b)\bar{X}) = a \quad \left| \begin{aligned} E(\bar{\varepsilon}) &= 0 \\ E(\hat{B} - b) &= 0 \end{aligned} \right.$$

$\hat{a}$  هو مقدر غير متحيز ل  $a$

تذكير: نقول عن مقدر أنه متحيز إذا كان  $q$  مقدار حجم التحيز ;  $E(\hat{\theta}) = \theta + q$

التباينات:

تعطى التباينات للمقدرات بالشكل التالي:

$$V(\hat{B}) = \frac{\sigma_v^2}{\sum xt^2}, \text{ et } V(\hat{a}) = \sigma_v^2 \cdot \frac{\sum Xt^2}{n \sum xt^2}:$$

والملاحظ أنه كلما  $\sum xt^2 \rightarrow \infty \rightarrow n \rightarrow \infty$  فيكون :

$$V(\hat{a}) \rightarrow 0 \text{ و } V(\hat{B}) \rightarrow 0$$

وحيث أن  $\sigma_v^2$  غير معروفة فإن تباين البواقي تقدره بـ  $S^2$

$$S^2 = \frac{\sum U_t^2}{n-k} \quad \left| \begin{aligned} n & \text{ عدد المشاهدات} \\ k & \text{ المعالم المقدره} \end{aligned} \right.$$

$$V(\hat{\alpha}) = \frac{\sum U_t^2}{n-k} \cdot \frac{\sum X_i^2}{n \sum x_i^2} = S_{\hat{\alpha}}^2 \text{ : ومن تصبح:}$$

$$V(\hat{B}) = \frac{\sum U_t^2}{n-k} \cdot \frac{1}{\sum x_i^2} = S_{\hat{B}}^2$$

$$\text{لدينا مقدرين إذا } k=2 \text{ فإن } S^2 = \frac{\sum U_t^2}{n-2} = \hat{\sigma}^2 \text{ كيف ذلك؟}$$

$$U_t = Y_t - \hat{Y}_t = Y_t - \hat{B}X_t - \hat{\alpha} \quad \text{لدينا}$$

$$= Y_t - \hat{B}X_t - \hat{\alpha} - \hat{B}X_t + \hat{B}\bar{X}$$

$$= Y_t - \hat{B}\bar{X}_t - \hat{\alpha} - \hat{B}X_t + \hat{B}\bar{X}$$

$$= Y_t - \bar{Y} - \hat{B}(X_t - \bar{X})$$

$$U_t = b(X_t + \bar{X}) + \varepsilon_t - \bar{\varepsilon} - \hat{B}(X_t - \bar{X}): \bar{Y} \text{ و } Y_t \text{ عن قيم}$$

$$U_t = (b - \hat{B})(X_t - \bar{X}) + (\varepsilon_t - \bar{\varepsilon})$$

$$\sum U_t^2 = (b - \hat{B})^2 \sum x_i^2 + \sum (\varepsilon_t - \bar{\varepsilon})^2 + 2(b - \hat{B}) \sum x_i (\varepsilon_t - \bar{\varepsilon})^2$$

$$\sum x_i^2 (\hat{B} - b) = \sum x_i (\varepsilon_t - \bar{\varepsilon}) = -(b - \hat{B}) \sum x_i^2 \text{ من (6) نجد أن}$$

ونعوض في المعادلة نجد:

$$\sum U_t^2 = (b - \hat{B})^2 \sum x_i^2 + \sum (\varepsilon_t - \bar{\varepsilon})^2 + 2(b - \hat{B})(-b - \hat{B}) \sum x_i^2$$

$$= \sum (\varepsilon_t - \bar{\varepsilon})^2 - (b - \hat{B})^2 \sum x_i^2$$

$$V(U_t) = E(\sum U_t^2) = E[\sum (\varepsilon_t - \bar{\varepsilon}_t)^2] - (b - \hat{B})^2 \sum x_i^2$$

$$E[\sum \varepsilon_t^2 - n(\bar{\varepsilon}_t)^2] - E(\hat{B} - b)^2 \sum x_i^2 \quad \left| \quad E(\bar{\varepsilon}) = 0 \right.$$

$$E(\sum U_t^2) = \sum E(\varepsilon_t)^2 - \frac{1}{n} E(\sum \varepsilon_t)^2 \sigma^2 \quad \left| \quad E(\hat{B} - b) = \frac{\sigma^2}{\sum x_i^2} \right.$$

$$= n\sigma_v^2 - \frac{1}{n} n\sigma_v^2 - \sigma_v^2 = \quad \left| \quad E(\bar{\varepsilon}) = 0 \right.$$

$$E(\sum U_t^2) = (n - 2)\sigma^2, \hat{\sigma}^2 = S^2 = \frac{\sum U_t^2}{n-2} \quad \left| \quad E(\hat{B} - b) = \frac{\sigma^2}{\sum x_i^2} \right.$$

عندما يكون مقدر التباين

### 3 اختبار معنوية المعالم

لأجل اختبار معنوية المعالم ينبغي علينا معرفة اختبار ستودنت T لان:

$$\frac{\hat{B}-b}{\sigma_{\hat{B}}} \sim N(0,1) \text{ et } (n-2) \frac{S_{\hat{B}}^2}{\sigma_{\hat{B}}^2} \sim X_{n-2}^2 \Rightarrow \frac{\hat{B}-b}{S_{\hat{B}}} \sim T_{n-2}$$

$$T = \frac{\hat{B} - b}{\frac{\sigma_{\hat{B}}}{\sqrt{\frac{X_t^2}{n}}}} = \frac{\hat{B} - b}{\sqrt{\frac{(n-2)S_{\hat{B}}^2}{\sigma_{\hat{B}}^2}}} = \frac{\hat{B} - b}{S_{\hat{B}}} \sim T_{n-2}^{1-\frac{\alpha}{2}}$$

حيث صيغة الاختبار تكون بالشكل التالي

$$\begin{cases} H_0: b = 0 & T_C \sim T_T \\ H_1: b \neq 0 & |T_C| < T_T \text{ نقبل } H_0 \text{ عندما} \end{cases}$$

وبنفس الطريقة نختبر  $\hat{\alpha}$

$$\begin{cases} H_0: a = 0 & T_{C_a} = \frac{\hat{a} - a}{S_{\hat{a}}} \\ H_1: a \neq 0 & |T_C| < T_T \text{ نقبل } H_0 \text{ عندما} \end{cases}$$

وحسب المثال السابق نجد:

Y				
40	37.08	2.92	8.5264	36
44	43.72	0.28	0.0784	100
46	47.04	-1.04	1.0816	144
48	50.36	-2.36	5.5696	196
52	53.68	-1.68	2.8224	256
58	57	1.00	1.0000	324
60	63.64	-3.64	13.2496	484
68	66.96	1.04	1.0816	576
74	70.28	3.72	13.8384	676
80	80.24	-0.24	0.0576	1024
$\Sigma$	$\Sigma_{U_t=0}$	$\Sigma U_t^2 = 47.3056$	$\Sigma X_t^2 = 3816$	

$$S_{\hat{\alpha}}^2 = V(\hat{\alpha}) = \frac{\Sigma U_t^2}{n-R} \cdot \frac{\Sigma X_t^2}{n \Sigma x_i^2} = 5.9132 \cdot \frac{3816}{10 \cdot (576)} \cong 3.92 = 0 \quad S_{\hat{a}} = 1.98$$

$$S_{\hat{B}}^2 = V(\hat{B}) = \frac{\Sigma U_i^2}{n-R} \cdot \frac{1}{\Sigma x_i^2} = \frac{5.9132}{576} \cong 0.01 \Rightarrow S_{\hat{B}} = 0.1$$

في ظل فرضية العدم  $H_0$

$$\text{pour } \hat{a}: T_{C_{\hat{a}}} = \frac{\hat{a} - a}{S_{\hat{a}}} = \frac{27.12 - 0}{1.98} \cong 13.7, T_{C_{\hat{B}}} = \frac{\hat{B} - b}{S_{\hat{B}}} = \frac{1.66 - 0}{0.1} \cong 16.6$$

نقارن النتيجةين السالفتين بـ  $T_t$  عند  $\alpha=5\%$

$$T_{n-R}^{1-\frac{\alpha}{2}} = T_8^{0.975} = 2.306$$

نجد أن كل من  $\hat{\alpha}$  و  $\hat{B}$  مختلفتين عن الصفر أي معنوية احصائية عن 5%

#### 4 اختبار جودة التوفيق والارتباط:

نلاحظ أنه كلما كانت المشاهدات أقرب إلى خط الانحدار كلما صغرت البواقي وكلما زاد التغير في  $Y_t$  الذي يفسره معادلته يرجع تلك الزيادة إلى الزيادة في الأخطاء.

$$\sum(Y_t - \bar{Y})^2 = \sum(\hat{Y}_t - \bar{Y})^2 + \sum(Y_t - \hat{Y}_t)^2$$

التغير في البواقي + التغير المفسر في  $Y$  = التغير الاجمالي في  $Y$

مجموع مربعات الخطأ + مجموع مربعات الانحدار = إجمالي مجموع المربعات

$$TSS=ESS+RSS$$

$$SCT=ECE+SCR$$

معامل التحديد  $R^2$ : coefficient de détermination

$$TSS = ESS + RSS \Rightarrow \frac{TSS}{TSS} = \frac{ESS}{TSS} + \frac{RSS}{TSS}$$

$$1 = \frac{ESS}{TSS} + \frac{RSS}{TSS}$$

$$R^2 = \frac{ESS}{TSS} = 1 - \frac{RSS}{TSS} \Rightarrow R^2 = 1 - \frac{\sum U_i^2}{\sum y_i^2} = \frac{\sum(\hat{Y}-\bar{Y})^2}{\sum y_i^2}$$

نجد قيمة  $R^2$ : 0 : عندما لا يفسر معادلة الانحدار أي من التغير في  $Y_t$

1 : عندما تقع كل النقاط على خط الانحدار

ويمكن القول أن النموذج يفسر التغير في  $Y_t$  بنسبة % وكلما زادت قيمة  $R^2$  (أقرب من 1) كان أحسن و زاد تفسير النموذج.

العلاقة بين معامل الارتباط  $r$  ومعامل التحديد  $R^2$

$$r = \sqrt{R^2} = \frac{\sum x_i y_i}{\sqrt{\sum x_i^2} \sqrt{\sum y_i^2}} = \sqrt{\hat{B} \frac{\sum x_i y_i}{\sum y_i^2}}$$

$$R^2 = 1 - \frac{\sum U_i^2}{\sum y_i^2} = 1 - \frac{47.31}{1634} = 1 - 0.029 \cong 0.971$$

حسب المثال السابق:



أي معادلة الانحدار تفسر 97% من التغير الاجمالي في  $Y_t$  (انتاج القمح) أما النسبة الباقية 3% فهي لعوامل أخرى.

خلاصة:

مقدرات طريقة  $OLS$  هي الأفضل لأنها

- غير متحيزة *sans biais*

- مقدر كفؤ *efficace* له أصغر تباين (نظرية قوس ماركون).

- مقدر متسق (يقترّب من القيمة الحقيقية)  $\lim_{n \rightarrow \infty} (\hat{\alpha}\hat{\beta})$

### 5 معادلة وجدول تحليل التباين ANOVA

$$\sum(Y_t - \bar{Y})^2 = \sum(\hat{Y}_t - \bar{Y})^2 + \sum U_t^2$$

$$TSS = ESS + RSS$$

$$R^2 = \frac{\sum(\hat{Y}_t - \bar{Y})^2}{\sum(Y_t - \bar{Y})^2} = 1 - \frac{\sum U_t^2}{\sum(Y_t - \bar{Y})^2}$$

لدينا

جدول تحليل التباين

Source de variation	Somme des carrés	Degré de liberté	Carrés moyens
$X$	$ESS = \sum(\hat{Y}_t - \bar{Y})^2$	1	ESS/1
Résidu	$RSS = \sum U_t^2$	n-2	RSS/(n - 2)
Total	$TSS = \sum(Y_t - \bar{Y})^2$	n-1	

درجة الحرية توافق عدد المتغيرات المستقلة

$$\begin{cases} H_0: b = 0 & : H_0: ESS = 0 \\ H_1: b \neq 0 & : H_1: ESS \neq 0 \end{cases} \quad X \text{ لا يفسر النموذج (ليس جزء من التفسير)}$$

الاختبار هو اختبار فيشر

$$F_c = \frac{\frac{ESS}{k-1}}{\frac{RSS}{n-k}} = \frac{\frac{\sum(\hat{Y}_t - \bar{Y})^2}{1}}{\frac{\sum U_t^2}{n-2}} = \frac{\frac{R^2}{1}}{\frac{1-R^2}{n-2}} \sim F_r = F_{R-1, n-k}$$

نرفض  $H_0$  عندما  $F_c > F_t$  برهان التوزيع (P35.RB)

$$F_c = (tc_{\hat{\beta}})^2 = \left(\frac{\hat{B}}{S_{\hat{\beta}}}\right)^2 = \frac{\hat{B}^2}{\sigma_u^2 / \sum(X_t - \bar{X})^2} = \frac{\hat{B}^2 \sum(X_t - \bar{X})^2}{\sum U_t^2 / (n-2)}$$

نلاحظ أن

**6** التنبؤ في نموذج الانحدار الخطي البسيط:

$$\hat{Y}_t = \hat{\alpha} + \hat{\beta}X_t$$

$$\hat{Y}_{t+1} = \hat{\alpha} + \hat{\beta}X_{t+1} \quad \text{لأجل الفترة } t+1$$

$$U_{t+1} = Y_{t+1} - \hat{Y}_{t+1} \sim \left(0, \sigma_u^2 \left[\frac{1}{n} + \frac{(X_{t+1} - \bar{X})^2}{\sum(X_t - \bar{X})^2} + 1\right]\right)$$

فيكون:

$$\frac{\hat{\alpha} + \hat{\beta}X_{t+1} - Y_{t+1}}{S_{\epsilon} \sqrt{\frac{1}{n} + \frac{(X_{t+1} - \bar{X})^2}{\sum(X_t - \bar{X})^2} + 1}} \sim T_{n-2}$$

ولدينا:

( $S^2$  مقدر تباين البواقي)

ومنه مجال الثقة للقيم المتنبأ بها.:

$$Y_{t+1} = \hat{Y}_{t+1} \pm t_{n-2}^{1-\alpha/2} S \sqrt{\frac{1}{n} + \frac{(X_{t+1} - \bar{X})^2}{\sum(X_t - \bar{X})^2} + 1}$$