

۳۶ استادی یک امتحان ۵۰ نمره‌ای به کلاس ریاضی عمومی داده است. جدول زیر نمره‌های ۵۰ دانشجو می‌باشد

۲۶	۳۰	۳۷	۳۲	۴۵	۳۵	۴۱	۲۲	۳۴	۳۸
۳۶	۴۷	۳۱	۳۸	۳۳	۳۱	۱۶	۳۴	۲۸	۳۶
۳۱	۳۳	۳۹	۲۹	۳۶	۳۴	۴۲	۲۵	۲۷	۲۹
۳۴	۱۹	۴۱	۳۲	۴۴	۳۷	۳۱	۳۳	۳۵	۴۰
۳۵	۴۲	۳۰	۳۹	۲۶	۳۲	۳۸	۴۷	۴۹	۱۵

الف- یک جدول فراوانی برای داده‌های فوق تشکیل دهید.

- ب- آیا در سطح معنی‌دار $\alpha = 1/10$ می‌توان ادعا کرد که نمرات دارای توزیع یکنواخت است؟
- ج- آیا در سطح معنی‌دار $\alpha = 1/10$ می‌توان ادعا کرد که نمرات دارای توزیع نرمال است؟
- ۳۷ یک سکه را آنقدر پرتاب می‌کنیم تا اینکه یک شیر بیاید. اگر X برابر تعداد پرتاب این سکه باشد، بعد از تکرار این آزمایش در ۲۵۶ بار، نتایج زیر حاصل می‌شود

X	۱	۲	۳	۴	۵	۶	۷	۸
تعداد پرتاب	۱۳۶	۶۰	۳۴	۱۲	۹	۱	۳	۱

- آیا در سطح معنی‌دار $\alpha = 0.05$ می‌توان ادعا کرد که توزیع هندسی یا پارامتر λ بر داده‌ها برانزده است؟
- ۳۸ داده‌های زیر میزان محصول ذرت را در ۱۰۰ مزرعه نشان می‌دهد. اگر در این مزارع $\sum_{i=1}^{100} x_i = 91400$ و $s = 331/8$ باشد، آیا میزان محصول ذرت این مزارع از توزیع نرمال پیروی می‌کند؟

تعداد مزارع	محصول (برحسب کیلوگرم)
۳	$99/5 \leq x < 299/5$
۷	$299/5 \leq x < 499/5$
۱۵	$499/5 \leq x < 699/5$
۲۶	$699/5 \leq x < 899/5$
۲۲	$899/5 \leq x < 1099/5$
۱۳	$1099/5 \leq x < 1299/5$
۹	$1299/5 \leq x < 1499/5$
۵	$1499/5 \leq x < 1699/5$

فصل نهم


رگرسیون خطی و همبستگی

۱.۹ مقدمه

در اغلب بررسی‌های آماری نیاز به پیش‌بینی مقدار یک متغیر وابسته از روی مقدار یک متغیر مستقل می‌باشد. برای مثال پیش‌بینی طول قد فرزند از روی طول قد پدرش، یا پیش‌بینی معدل کل یک دانشجو در یک نیمسال از روی نمره درس ریاضیات او و یا پیش‌بینی مقدار مصرف بنزین از روی مسافت طی شده اتومبیل از این نوع مسائل می‌باشند. چنین مسائلی را مسائل برگشت یا رگرسیون گویند. متغیر مستقل را با X و متغیر وابسته را با Y یا برای راحتی با Y نمایش می‌دهند. برای مثال در پیش‌بینی طول قد فرزند از روی طول قد پدرش، طول قد پدر را که یک مقدار ثابت و بخصوص است با X نمایش می‌دهیم و چون برای یک طول قد پدر X فرزندان او می‌توانند طول قدهای متفاوت داشته باشند بنابراین طول قد فرزند او را با متغیر تصادفی Y یا $Y|X$ نشان می‌دهیم. به همین ترتیب در پیش‌بینی مقدار مصرف بنزین، برای مسافت معین طی شده X میزان مصرف بنزین را با Y نمایش می‌دهیم.

برای یافتن رابطه بین متغیر مستقل X و متغیر وابسته Y ابتدا یک نمونه تصادفی از جمعیت مورد نظر جمع‌آوری می‌کنیم. یعنی به ازاء مقادیر x_1, x_2, \dots, x_n از متغیر مستقل X مقادیر مربوط به متغیر وابسته Y را اندازه‌گیری می‌کنیم. فرض کنید این مقادیر اندازه‌گیری شده y_1, y_2, \dots, y_n باشند. بنابراین نمونه تصادفی ما به صورت زوج‌های $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ است که مقادیر مشاهده شده آن عبارت است از $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$. برای بی‌بردن به رابطه

بین X و Y ابتدا این مشاهدات که به صورت نقاطی در صفحه هستند را در یک دستگاه مختصات رسم می‌کنیم که به آن نمودار پراکنندگی گویند. در شکل ۱.۹ نمودار پراکنندگی نقاط برای حالتی مختلف رسم شده است. توجه کنید که برای یک مقدار X ممکن است چندین مقدار برای Y وجود داشته باشد.



الف- X و Y رابطه خطی دارند ب- X و Y رابطه غیر خطی دارند ج- X و Y رابطه‌ای ندارند

شکل ۱.۹ نمودارهای پراکنندگی نقاط

حال برای این نقاط می‌توان یک خط یا منحنی عبور داد و این خط یا منحنی رابطه بین X و Y را مشخص می‌کند. بنابراین در حالت کلی اگر بخواهیم مقدار متغیر Y را از روی مقدار متغیر X پیش‌بینی کنیم احتیاج به یک رابطه بین X و Y داریم که این رابطه یک معادله پیش‌بینی کننده است که به آن معادله رگرسیون Y روی X گویند.

۲.۹ رگرسیون ساده خطی

هر گاه بین متغیر مستقل X و متغیر وابسته $Y = Y|X$ یک رابطه خطی برقرار باشد گوئیم یک مدل رگرسیون ساده خطی بین X و Y برقرار است. برای تشکیل این رابطه خطی، فرض کنید یک نمونه تصادفی $(x_1, Y_1), (x_2, Y_2), \dots, (x_n, Y_n)$ با مقادیر مشاهده شده $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ داشته باشیم. توجه کنید که $Y_i = Y|X_i, i = 1, 2, \dots, n$ منظور از رگرسیون خطی این است که میانگین $Y|X$ به طور خطی با X در ارتباط باشد یعنی $\mu_{Y|X} = E(Y|X) = \alpha + \beta X$ که به آن خط رگرسیون گویند و در آن α و β پارامترهای نامعلوم هستند که بایستی برآورد شوند. به α و β ضرایب رگرسیون گویند اگر برآورد $\hat{\alpha}$ و $\hat{\beta}$ را با $\hat{\alpha}$ و $\hat{\beta}$ نمایش دهیم در این صورت

مقدار برآورد متغیر وابسته Y را با $\hat{Y} = \hat{\alpha} + \hat{\beta}X$ نمایش می‌دهند. در زیر روشی برای برآورد ضرایب رگرسیونی α و β از روی نمونه ارائه می‌دهیم و از روی آن بوسیله $\hat{Y} = \hat{\alpha} + \hat{\beta}X$ برای مقدار بخصوص X مقدار متغیر وابسته Y را پیش‌بینی می‌کنیم.

در نمونه تصادفی $(x_1, Y_1), (x_2, Y_2), \dots, (x_n, Y_n)$ چون همواره مقدار $Y_i = Y|X_i$ برابر $\mu_{Y|X_i} = E(Y|X_i)$ نیست، بنابراین اختلاف آنها برابر یک مقدار تصادفی E_i می‌باشد یعنی

$$Y_i = \mu_{Y|X_i} + E_i = \alpha + \beta X_i + E_i, \quad i = 1, 2, \dots, n \quad (1.9)$$

این مدل را مدل رگرسیون ساده خطی گویند و E_i را که یک متغیر تصادفی با میانگین صفر و واریانس σ^2 است را مقدار خطا گویند. اگر مقدار مشاهده شده E_i را با e_i نشان دهیم. در این صورت

$$y_i = \alpha + \beta x_i + e_i, \quad i = 1, 2, \dots, n$$

که e_i را مقدار باقیمانده گویند. حال برای یافتن برآوردهای $\hat{\alpha}$ و $\hat{\beta}$ بگونه‌ای عمل می‌کنیم که مجموع مربعات باقیمانده‌ها یعنی $\sum_{i=1}^n e_i^2$ می‌نیم گردد.

روش حداقل مربعات مجموع مربعات باقیمانده‌ها را معمولاً مجموع مربعات خطاها حول خط رگرسیون گویند و با SSE نمایش می‌دهند، یعنی

$$SSE = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \alpha - \beta x_i)^2 \quad (2.9)$$

مقادیری از $\hat{\alpha}$ و $\hat{\beta}$ که SSE را می‌نیم کنند، برآوردهای حداقل مربعات گویند و روش بنده دست آوردن آنها را روش حداقل مربعات^(۲) می‌نامند که در زیر به ذکر آن می‌پردازیم.

ابتدا کمیت‌های زیر را معرفی می‌کنیم

$$S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - \frac{(\sum_{i=1}^n x_i)^2}{n}$$

$$S_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n y_i^2 - \frac{(\sum_{i=1}^n y_i)^2}{n}$$

$$S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n x_i y_i - \frac{(\sum_{i=1}^n x_i)(\sum_{i=1}^n y_i)}{n}$$

قضیه ۱.۹ در یک مدل رگرسیون ساده خطی مقادیر $\hat{\alpha}$ و $\hat{\beta}$ که مجموع مربعات خطاها را می‌نیم می‌کنند عبارت اند از

$$\hat{\alpha} = \bar{y} - \hat{\beta} \bar{x}, \quad \hat{\beta} = \frac{S_{xy}}{S_{xx}} \quad (۳.۹)$$

اثبات با مشتق‌گیری از SSE نسبت به α و β و مساوی صفر قرار دادن آنها به معادلات زیر می‌رسیم

$$\begin{cases} \sum_{i=1}^n y_i - n\alpha - \beta \sum_{i=1}^n x_i = 0 \\ \sum_{i=1}^n x_i y_i - \alpha \sum_{i=1}^n x_i - \beta \sum_{i=1}^n x_i^2 = 0 \end{cases}$$

که از حل این دستگاه جوابهای $\hat{\alpha}$ و $\hat{\beta}$ داده شده در (۳.۹) حاصل می‌شوند و می‌توان نشان داد که این مقادیر SSE را می‌نیم می‌کنند.

بنابراین خط رگرسیون $\mu_{Y|X} = \alpha + \beta x$ بوسیله خط $\hat{y} = \hat{\alpha} + \hat{\beta} x$ برآورد می‌شود، که $\hat{\alpha}$ و $\hat{\beta}$ از رابطه (۳.۹) به دست می‌آیند.

مثال ۱.۲.۹ برای داده‌های جدول زیر برآورد خط رگرسیون را بیابید. سپس نقاط را در صفحه مشخص نموده و خط برآورد شده را رسم کنید.

x_i	۱	۳	۴	۶	۸	۹	۱۱	۱۴
y_i	۱	۲	۴	۴	۵	۷	۸	۹

حل از جدول فوق مقادیر زیر حاصل می‌شوند


$$\sum x_i = 56, \quad \sum y_i = 40, \quad \sum x_i^2 = 524, \quad \sum y_i^2 = 256, \quad \sum x_i y_i = 364$$

$$S_{xy} = 364 - \frac{(56)(40)}{8} = 84, \quad S_{xx} = 524 - \frac{(56)^2}{8} = 132$$

$$\hat{\beta} = \frac{S_{xy}}{S_{xx}} = \frac{84}{132} = 0.636, \quad \hat{\alpha} = \bar{y} - \hat{\beta} \bar{x} = \frac{40}{8} - (0.636) \frac{56}{8} = 0.525$$

و در نتیجه

$$\hat{y} = \hat{\alpha} + \hat{\beta} x = 0.525 + 0.636x$$



شکل ۲.۹ نمودار پراکنندگی نقاط و خط رگرسیون برآورد شده

مثال ۲.۲.۹ آزمایشی به منظور مطالعه اثر یک داروی معین در پایین آوردن ضربان قلب در افراد بالغ انجام شده است. مقدار داروی تجویز شده بر حسب میلی‌گرم و تفاوت ضربان قلب پس از استعمال دارو و قبل از آن برای یک نمونه ۱۳ تایی در جدول زیر آورده شده است

مقدار داروی تجویز شده	۰/۵	۰/۷۵	۱/۰	۱/۲۵	۱/۵	۱/۷۵	۲/۰
واکنش در ضربان قلب	۱۰	۸	۱۲	۱۲	۱۴	۱۲	۱۶
مقدار داروی تجویز شده	۲/۲۵	۲/۵	۲/۷۵	۳	۳/۲۵	۳/۵	
واکنش در ضربان قلب	۱۸	۱۷	۲۰	۱۸	۲۰	۲۱	

برآورد خط رگرسیون را به دست آورید. اگر مقدار داروی تجویز شده ۱/۶ باشد، واکنش در ضربان قلب در دقیقه را به چه میزان پیش بینی می‌کنید؟

حل از جدول فوق مقادیر زیر حاصل می‌شوند:

$$\sum x_i = 26, \quad \sum x_i^2 = 63/375, \quad \sum y_i = 198, \quad \sum y_i^2 = 3226, \quad \sum x_i y_i = 442/5$$

$$S_{xy} = 442/5 - \frac{(26)(198)}{13} = 46/5, \quad S_{xx} = 63/375 - \frac{(26)^2}{13} = 11/375$$

$$\hat{\beta} = \frac{46/5}{11/375} = 4/0.88, \quad \hat{\alpha} = \frac{198}{13} - (4/0.88) \frac{26}{13} = 7/0.55$$

در نتیجه

$$\hat{y} = \hat{\alpha} + \hat{\beta}x = 7/0.55 + 4/0.88x$$

حال اگر مقدار داروی تجویز شده $x=1/6$ باشد آنگاه پیش بینی می کنیم که میزان واکنش ضریبان قلم $13/6 \approx 2/0.55 + 4/0.88(1/6)$ یا در دقیقه باشد.

۳.۹ استنباط آماری روی ضرایب رگرسیونی

در بخش قبل بر اساس نمونه تصادفی $(x_1, Y_1), (x_2, Y_2), \dots, (x_n, Y_n)$ در مدل رگرسیونی

$$Y_i = \alpha + \beta x_i + E_i \quad i = 1, 2, \dots, n$$

ضرایب رگرسیونی α و β را به وسیله برآوردگرهای $\hat{\alpha} = \bar{Y} - \hat{\beta}\bar{x}$ و $\hat{\beta} = \frac{S_{xy}}{S_{xx}}$ برآورد کردیم که در آن $\bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$ و $S_{xy} = \sum_{i=1}^n (x_i - \bar{x})(Y_i - \bar{Y})$ متغیر تصادفی می باشند. حال اگر در مدل رگرسیونی فوق فرض کنیم $E_i \sim N(0, \sigma^2)$, $i = 1, 2, \dots, n$ و E_1, E_2, \dots, E_n از یکدیگر مستقل باشند، در این صورت چون Y_i یک ترکیب خطی از متغیرهای تصادفی نرمال E_i می باشد، پس $Y_i \sim N(\alpha + \beta x_i, \sigma^2)$, $i = 1, 2, \dots, n$ بر اساس توزیع متغیرهای تصادفی Y_i می توان توزیع $\hat{\alpha}$ و $\hat{\beta}$ و SSE را به دست آورد. توزیع این برآوردگرها را در قضیه زیر بدون اثبات می آوریم.

قضیه ۲.۹ در مدل رگرسیونی ساده خطی با فرض $E_i \sim N(0, \sigma^2)$, $i = 1, 2, \dots, n$ داریم که

الف- $\hat{\alpha} \sim N\left(\alpha, \frac{\sigma^2 \sum x_i^2}{n S_{xx}}\right)$

ب- $\hat{\beta} \sim N\left(\beta, \frac{\sigma^2}{S_{xx}}\right)$

ج- اگر $S^2 = \frac{SSE}{n-2}$ آنگاه $S^2 \sim \chi^2_{(n-2)}$

د- $\hat{\alpha}$ و S^2 و همچنین $\hat{\beta}$ و S^2 از یکدیگر مستقل هستند.

با استفاده از قضیه ۲.۹ می توان نتایج زیر را به دست آورد

$$\frac{\hat{\beta} - \beta}{\frac{S}{\sqrt{S_{xx}}}} \sim t_{(n-2)} \quad (۴.۹)$$

$$\frac{\hat{\alpha} - \alpha}{S \sqrt{\frac{\sum x_i^2}{n S_{xx}}}} \sim t_{(n-2)} \quad (۵.۹)$$

که در آن

$$S^2 = \frac{SSE}{n-2} = \frac{1}{n-2} \sum_{i=1}^n (Y_i - \hat{\alpha} - \hat{\beta}x_i)^2 = \frac{1}{n-2} [S_{yy} - \hat{\beta}S_{xy}] \quad (۶.۹)$$

با استفاده از تابع محورهای (۴.۹) و (۵.۹) می توان فواصل اطمینان $(1-\alpha) \cdot 100\%$ برای α و

β به دست آورد که این فواصل اطمینان عبارتند از

$$\alpha \in \left(\hat{\alpha} - t_{1-\frac{\alpha}{2}, (n-2)} S \sqrt{\frac{\sum x_i^2}{n S_{xx}}}, \hat{\alpha} + t_{1-\frac{\alpha}{2}, (n-2)} S \sqrt{\frac{\sum x_i^2}{n S_{xx}}} \right) \quad (۷.۹)$$

$$\beta \in \left(\hat{\beta} - t_{1-\frac{\alpha}{2}, (n-2)} \frac{S}{\sqrt{S_{xx}}}, \hat{\beta} + t_{1-\frac{\alpha}{2}, (n-2)} \frac{S}{\sqrt{S_{xx}}} \right)$$

با استفاده از روابط (۴.۹) و (۵.۹) می توان آزمونهای آماری را روی α و β انجام داد که

این آزمونها در جدول ۱.۹ آورده شده اند.

H.	آماره آزمون	H ₁	ناحیه بحرانی
$\alpha = \alpha_0$	$T = \frac{\hat{\alpha} - \alpha_0}{S \sqrt{\frac{\sum x_i^2}{n S_{xx}}}}$	$\alpha > \alpha_0$	$T > t_{1-\alpha_0, (n-2)}$
		$\alpha < \alpha_0$	$T < -t_{1-\alpha_0, (n-2)}$
		$\alpha \neq \alpha_0$	$ T > t_{1-\frac{\alpha_0}{2}, (n-2)}$
$\beta = \beta_0$	$T = \frac{\hat{\beta} - \beta_0}{\frac{S}{\sqrt{S_{xx}}}}$	$\beta > \beta_0$	$T > t_{1-\alpha_0, (n-2)}$
		$\beta < \beta_0$	$T < -t_{1-\alpha_0, (n-2)}$
		$\beta \neq \beta_0$	$ T > t_{1-\frac{\alpha_0}{2}, (n-2)}$

جدول ۱.۹ آزمونهای آماری روی ضرایب رگرسیونی α و β

ج- در این مثال با آزمون $\begin{cases} H_0: \alpha = -1 \\ H_1: \alpha \neq -1 \end{cases}$ مواجه هستیم و با استفاده از جدول ۱.۹ فرض

H_0 رد می شود اگر و فقط اگر $t_{1-\frac{\alpha}{2}}(n-2) > |T|$ که در آن

$$t_{1-\frac{\alpha}{2}}(n-2) = t_{.995}(10) = 3/17$$

$$T = \frac{\hat{\alpha} - \alpha_0}{s \sqrt{\frac{\sum x_i^2}{n \sum y_i^2}}} = \frac{-0/948 + 1}{\sqrt{\frac{(1/213)(24529)}{(12)(852/917)}}} = 0/305$$

چون $t_{1-\frac{\alpha}{2}}(n-2) = 3/17 < |T| = 0/305$ پس فرض H_0 رد نمی شود یعنی $\alpha = -1$ می باشد.

مثال ۲.۳.۹. نمره های امتحان میان ترم و پایان ترم یک کلاس ۹ نفره از دانشجویان به صورت زیر

میان ترم	۶	۵	۷	۷	۴	۶	۴	۵	۳
پایان ترم	۱۰	۸	۱۱	۱۲	۱۱	۹	۱۰	۹	۶

الف- برآورد خط رگرسیونی را برای پیش بینی نمره پایان ترم از روی نمره میان ترم به دست آورید.

ب- یک فاصله اطمینان ۹۰ درصدی برای α پیدا کنید.

ج- آیا در سطح معنی دار ۰/۰۵ می توان ادعا کرد که $\beta < 2$ است؟

حل الف- اگر x نمره میان ترم و y نمره پایان ترم باشد آنگاه از جدول فوق مقادیر زیر حاصل می شوند

$$\sum x_i = 47, \quad \sum x_i^2 = 261, \quad \sum y_i = 86, \quad \sum y_i^2 = 848, \quad \sum x_i y_i = 462$$

بنابراین

$$S_{xy} = 462 - \frac{(47)(86)}{9} = 12/89, \quad S_{xx} = 261 - \frac{(47)^2}{9} = 15/56$$

$$S_{yy} = 848 - \frac{(86)^2}{9} = 26/22, \quad \hat{\beta} = \frac{12/89}{15/56} = 0/828$$

$$\hat{\alpha} = \frac{86}{9} - (0/828) \frac{47}{9} = 5/23, \quad s^2 = \frac{1}{8} [26/22 - (0/828)(12/89)] = 2/22$$

مثال ۱.۳.۹. مواد اولیه ای که برای ساختن الیاف مصنوعی به کار می رود در انبار مسرطوبی نگهداری می شود. نتایج حاصل از اندازه گیریهای رطوبت نسبی در انبار و میزان رطوبت در یک

نمونه مواد اولیه (هر دو بر حسب درصد) در ۱۲ روز در جدول زیر ثبت شده است

رطوبت انبار x	۴۲	۳۵	۵۰	۴۳	۴۸	۶۲
رطوبت مواد اولیه y	۱۲	۸	۱۴	۹	۱۱	۱۶
رطوبت انبار x	۳۱	۳۶	۴۴	۳۹	۵۵	۴۸
رطوبت مواد اولیه y	۷	۹	۱۲	۱۰	۱۳	۱۱

الف- برآورد خط رگرسیون را به دست آورید.

ب- یک فاصله اطمینان ۹۵ درصدی برای β بسازید.

ج- آیا در سطح معنی دار ۰/۰۱ می توان ادعا کرد که $\alpha = -1$ است؟

حل الف- از جدول فوق مقادیر زیر حاصل می شوند:

$$\sum x_i = 533, \quad \sum x_i^2 = 24529, \quad \sum y_i = 132, \quad \sum y_i^2 = 1526, \quad \sum x_i y_i = 6093$$

بنابراین

$$S_{xy} = 6093 - \frac{(533)(132)}{12} = 230, \quad S_{xx} = 24529 - \frac{(533)^2}{12} = 854/917$$

$$S_{yy} = 1526 - \frac{(132)^2}{12} = 74, \quad \hat{\beta} = \frac{230}{854/917} = 0/269$$

$$\hat{\alpha} = \frac{132}{12} - (0/269) \frac{533}{12} = -0/948, \quad s^2 = \frac{1}{10} [74 - (0/269)(230)] = 1/213$$

در نتیجه

$$\hat{y} = \hat{\alpha} + \hat{\beta}x = -0/948 + 0/269x$$

ب- با استفاده از فواصل اطمینان (۷.۹) داریم که

$$t_{1-\frac{\alpha}{2}}(n-2) = t_{.975}(10) = 2/23$$

$$\beta \in (0/269 - 2/23 \sqrt{\frac{1/213}{854/917}}, 0/269 + 2/23 \sqrt{\frac{1/213}{854/917}}) = (0/185, 0/353)$$

بنابراین ۹۵ درصد اطمینان داریم که β در فاصله فوق قرار دارد.

در نتیجه

$$\hat{y} = 5/23 + 0/828x$$

ب- چون $t_{1-\alpha/2}(n-2) = t_{0.05}(7) = 1/9$ بنابراین از (۷.۹) داریم که

$$\alpha \in (5/23 - 1/9, 5/23 + 1/9) = (1/365, 9/95)$$

بنابراین ۹۰ درصد اطمینان داریم که α در فاصله فوق قرار دارد.

ج- در این مثال با آزمون $\begin{cases} H_0: \beta = 2 \\ H_1: \beta < 2 \end{cases}$ مواجه هستیم و با استفاده از جدول ۱۰.۹ فرض H_0 رد می‌شود اگر و فقط اگر $T < -t_{1-\alpha}(n-2)$ که در آن

$$t_{1-\alpha}(n-2) = t_{0.05}(7) = 1/9$$

$$T = \frac{\hat{\beta} - \beta_0}{\frac{s}{\sqrt{S_{xx}}}} = \frac{-/828 - 2}{\sqrt{15/56}} = -3/1.3$$

چون $-1/9 = T < -t_{1-\alpha}(n-2) = -3/1.3$ پس فرض H_0 رد می‌شود یعنی $\beta < 2$ است.


۴.۹ ضریب همبستگی خطی

تاکنون فرض کردیم که متغیر مستقل X یک متغیر کنترل شده است و یک متغیر تصادفی نیست. حال فرض کنید که هم متغیر X و هم Y هر دو متغیر تصادفی باشند. روشهای رگرسیونی موقعی مناسب هستند که متغیر تصادفی Y به متغیر تصادفی X که اغلب به وسیله پژوهشگر کنترل می‌شود بستگی داشته باشد. برای سنجش میزان وابستگی دو متغیر تصادفی X و Y از معیاری بنام ضریب همبستگی خطی استفاده می‌شود که در بخش ۴.۴ آن را در جمعیت به صورت زیر تعریف کردیم


$$\rho = \rho(X, Y) = \frac{\text{COV}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}} = \frac{\sigma_{XY}}{\sigma_X \sigma_Y}$$

و در بخش ۴.۴ مشاهده کردیم که ضریب همبستگی خطی به مبدا و واحد اندازه‌گیری داده‌ها بستگی ندارد و همواره $-1 \leq \rho \leq 1$ می‌باشد. در شکل ۳.۹ حالتی مختلف از همبستگی خطی X و



Y نشان داده شده است.




ج- $\rho = 0$ عدم همبستگی



ب- $0 < \rho < 1$ همبستگی مثبت



د- $\rho = -1$ همبستگی کامل منفی



د- $-1 < \rho < 0$ همبستگی منفی

شکل ۳.۹ حالتی مختلف همبستگی خطی بین متغیرهای X و Y

برای برآورد ضریب همبستگی یک نمونه تصادفی $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ از (X, Y) را انتخاب می‌کنیم و از روی این نمونه تصادفی کواریانس X و Y و واریانس X و واریانس Y را به صورت زیر برآورد می‌کنیم

$$\hat{\sigma}_X^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{1}{n-1} S_{XX}$$

$$\hat{\sigma}_Y^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \bar{Y})^2 = \frac{1}{n-1} S_{YY}$$

$$\hat{\sigma}_{XY} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) = \frac{1}{n-1} S_{XY}$$

حال با قرار دادن این برآوردگرها به جای پارامترهای $\sigma_{XY}, \sigma_Y^2, \sigma_X^2$ در فرمول ضریب همبستگی خطی، برآوردگر ضریب همبستگی خطی به صورت زیر به دست می‌آید:

$$\hat{\rho} = R = \frac{S_{XY}}{\sqrt{S_{XX}S_{YY}}} \quad (۸.۹)$$

اگر مقدار مشاهده شده این نمونه تصادفی $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ باشد آنگاه برآورد

تصادفی داریم. فیشر^(۱) آماردان انگلیسی ثابت کرده است که آماره $W = \frac{1}{Y} Ln \frac{1+R}{1-R}$ برای اندازه

نمونه بزرگ تقریباً دارای توزیع نرمال با میانگین تقریبی $\frac{1+\rho}{1-\rho} Ln \frac{1+\rho}{1-\rho}$ و واریانس تقریبی

$\frac{1}{n-3}$ می باشد. یعنی به طور تقریبی داریم که:

$$Z = \frac{W - \mu_w}{\sigma_w} \sim N(0, 1) \quad (9.9)$$

با استفاده از تابع محور (۹.۹) می توان برای ρ فاصله اطمینان پیدا کرد و با استفاده از توزیع

(۹.۹) می توان آزمونهای آماری را روی ρ انجام داد که این آزمونها در جدول ۲.۹ آورده شده اند.

H_0	آماره آزمون	H_1	ناحیه بحرانی آزمون
$\rho = \rho_0$	$Z = \frac{W - \mu_w}{\sigma_w}$	$\rho > \rho_0$	$Z > z_{1-\alpha}$
		$\rho < \rho_0$	$Z < -z_{1-\alpha}$
		$\rho \neq \rho_0$	$ Z > z_{\frac{1-\alpha}{2}}$

جدول ۲.۹ آزمونهای آماری روی ρ که $\mu_w = \frac{1}{Y} Ln \frac{1+\rho}{1-\rho}$ می باشد.

مثال ۲.۴.۹ در مثال ۱.۴.۹ آیا در سطح معنی دار $\alpha = 0.05$ می توان ادعا کرد که $\rho > 0.5$ است.

حل در این مثال با آزمون $\begin{cases} H_0: \rho = 0.5 \\ H_1: \rho > 0.5 \end{cases}$ مواجه هستیم و با استفاده از جدول ۲.۹ فرض H_0 رد می شود اگر و فقط اگر $Z > z_{1-\alpha}$ که در آن

$$r = 0.822 \quad w = \frac{1}{Y} Ln \frac{1+r}{1-r} = \frac{1}{Y} Ln \frac{1.822}{0.168} = 1/195$$

$$\mu_w = \frac{1}{Y} Ln \frac{1+\rho_0}{1-\rho_0} = \frac{1}{Y} Ln \frac{1.5}{0.5} = 0.529$$

$$\sigma_w = \sqrt{\frac{1}{n-3}} = \sqrt{\frac{1}{9}} = 0.333, \quad Z = \frac{w - \mu_w}{\sigma_w} = \frac{1/195 - 0.529}{0.333} = 1/94$$

$$z_{1-\alpha} = z_{.95} = 1/645$$

چون $1/94 = Z > z_{1-\alpha} = 1/645$ پس فرض H_0 رد می شود یعنی $\rho > 0.5$ است.

ضریب همبستگی خطی یعنی مقدار مشاهده شده R عبارت از $r = \frac{S_{xy}}{\sqrt{S_{xx}S_{yy}}}$ خواهد بود که به آن

ضریب همبستگی نمونه گویند. می توان نشان داد که R با تغییر مبدأ و واحد اندازه گیری تغییر

نمی کند و همواره $-1 \leq R \leq 1$ است. تعبیر مقادیر R همانند تعبیر مقادیر ρ در شکل ۲.۹ می باشد. به

مقدار R^2 ضریب تعیین گویند و $100 \cdot R^2$ ٪ از تغییرات مقادیر Y جهت رابطه خطی آن با متغیر X

به حساب می آید.

مثال ۱.۴.۹ داده های زیر مربوط به مقاومت (بر حسب اهم) و زمان شکست (بر حسب دقیقه)

ترازیستورها با بار اضافی می باشد

مقاومت (x)	۴۳	۲۹	۴۴	۳۳	۳۳	۴۷
زمان شکست (y)	۳۲	۲۰	۴۵	۳۵	۲۲	۴۶
مقاومت (x)	۳۴	۳۱	۴۸	۳۴	۴۶	۳۷
زمان شکست (y)	۲۸	۲۶	۳۷	۳۳	۴۷	۳۰

ضریب همبستگی نمونه را به دست آورید و آن را تعبیر کنید.

حل از جدول فوق مقادیر زیر حاصل می شوند

$$\sum x_i = 459, \quad \sum x_i^2 = 18075, \quad \sum y_i = 401, \quad \sum y_i^2 = 14301, \quad \sum x_i y_i = 15907$$

بنابراین

$$S_{xy} = 15907 - \frac{(459)(401)}{12} = 56875, \quad S_{xx} = 18075 - \frac{(459)^2}{12} = 51825$$

$$S_{yy} = 14301 - \frac{(401)^2}{12} = 900917$$

$$r = \frac{56875}{\sqrt{(51825)(900917)}} = 0.822$$

در نتیجه

چون مقدار r به یک نزدیک است پس یک رابطه خطی نسبتاً خوبی در جهت مثبت بین X و Y

برقرار است. همچنین چون $r^2 = 0.693$ پس 69.3 ٪ از تغییرات Y جهت رابطه خطی آن با X به

حساب می آید.

استنباط آماری روی ρ

برای استنباط آماری روی ρ نیاز به داشتن توزیع احتمال R ضریب همبستگی نمونه

۵.۹ تمرینات

۱ برای تعیین رابطه بین هزینه حمل یک نوع کالا و فاصله فروشگاه از محل توزیع کالا، یک نمونه تصادفی شامل ۸ فروشگاه که این کالا را عرضه می‌کنند انتخاب و فاصله فروشگاه تا محل توزیع کالا و هزینه حمل ۱۰۰ واحد از این کالا در جدول زیر ثبت شده است

x	۶	۱۳	۲۷	۱۵	۹	۱۱	۲۱	۱۴
y	۲۹	۹۳	۱۵۹	۱۱۵	۶۶	۹۰	۱۳۹	۹۸

برآورد خط رگرسیون هزینه حمل کالا بر حسب فاصله را به دست آورید. اگر فاصله یک فروشگاه تا محل توزیع ۱۰ کیلومتر باشد، هزینه حمل ۱۰۰ واحد کالا تا این فروشگاه را به چه میزان پیش بینی می‌کنید؟

۲ می‌خواهیم به داده‌های حاصل از قدرت کشش y ده قطعه پلاستیک که هر یک x دقیقه پخته شده‌اند، یک خط راست برازش کنیم. داده‌ها در جدول زیر ثبت شده‌اند. برآورد خط رگرسیون مورد نظر را به دست آورید.

x	۲۳	۳۵	۴۵	۶۵	۷۵	۹۵	۱۰۵	۱۲۵	۱۵۵	۱۸۵
y	۲	۹/۸	۹/۲	۲۶/۲	۱۷/۱	۲۴/۸	۲۳	۵۵/۳	۳۸/۲	۶۳/۳

۳ از یک نمونه تصادفی از ۱۰ مرد ۳۰ ساله اطلاعات زیر در مورد حقوق سالیانه کنونی (بر حسب صد هزار تومان) و تعداد سالهای تحصیلی رسمی که داشته‌اند به دست آمده است.

x	۱۰	۱۲	۱۳	۱۴	۱۶	۱۶	۱۶	۱۶	۱۸	۲۰
y	۷/۰	۶/۲	۸/۱	۷/۵	۶/۵	۱۰/۵	۸/۰	۱۳/۲	۱۲/۸	۱۶/۵

برآورد خط رگرسیون حقوق سالیانه بر حسب تعداد سالهای تحصیلی را به دست آورید. اگر مردی ۱۵ سال تحصیل کرده باشد، حقوق سالیانه او را به چه میزان پیش بینی می‌کنید؟
۴ یک نوع ماده شیمیایی داریم که در x درجه حرارت y گرم آن تجزیه می‌شود. در پنج آزمایش داده‌های زیر به دست آمده‌اند:

x	-۲	-۱	۰	۱	۲
y	۵	۴	۳	۲	۱

الف- برآورد خط رگرسیون مقدار ماده تجزیه شده بر حسب درجه حرارت را به دست

آورید.

ب- نقاط داده شده و خط برآورد شده را در یک دستگاه مختصات رسم کنید.

ج- اگر درجه حرارت ۳ باشد، مقدار ماده‌ای را که تجزیه می‌شود پیش بینی کنید.

۵ در جدول زیر نیروی کشش به کار رفته برای یک نمونه فولاد، بر حسب هزار پوند و طول حاصل از کشش بر حسب یک هزارم اینچ می‌باشد

x	۱	۲	۳	۴	۵	۶
y	۱۴	۳۳	۴۰	۶۳	۷۶	۸۵

الف- با رسم نمودار پراکنندگی داده‌ها، تأیید کنید که فرض خطی بودن رگرسیون y روی x معقول است.

ب- برآورد خط رگرسیون را به دست آورده و با استفاده از آن وقتی نیروی کشش $۳/۵$ هزار پوند باشد، طول حاصل را پیش بینی کنید.

ج- برای ضرایب رگرسیونی α و β فواصل اطمینان ۹۵ درصدی را تشکیل دهید.

۶ یک مطالعه توسط یک خرده فروش در ارتباط با رابطه بین مخارج تبلیغ و میزان فروش (هر دو بر حسب هزار تومان) به طور هفتگی صورت پذیرفته است و داده‌های زیر به دست آمده است

x	۴۰	۲۰	۲۵	۲۰	۳۰	۵۰	۴۰	۵۰	۴۰	۲۵	۵۰
y	۳۸۵	۴۰۰	۳۹۵	۳۶۵	۴۷۵	۴۴۰	۴۹۰	۴۲۰	۵۶۰	۵۲۵	۴۸۰

الف- معادله خط رگرسیون را جهت پیش بینی فروش هفتگی از روی هزینه تبلیغات پیدا کنید.

ب- فاصله اطمینان ۹۰ درصدی را برای β به دست آورید.

۷ در تمرین ۳، آیا می‌توان در سطح معنی‌دار $\alpha = ۰/۰۱$ ادعا کرد که $\rho > ۰$ است؟

۸ داده‌های زیر مربوط به تعداد کارها بر حسب روز و زمان لازم برای پردازش مرکزی (CPU) می‌باشد.

x	۱	۲	۳	۴	۵
y	۲	۵	۴	۹	۱۰

الف- معادله خط رگرسیون را جهت پیش بینی زمان (CPU) بر حسب تعداد کارها پیدا