

# آمار و احتمالات مهندسی توزیع‌های دوبعدی و ضریب همبستگی

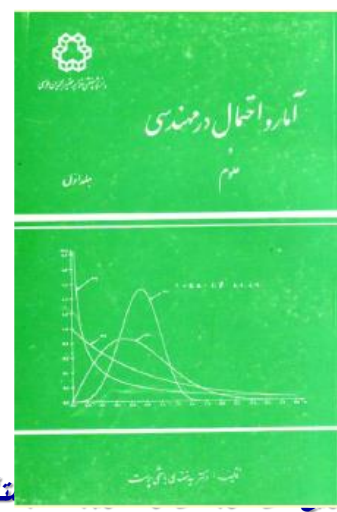
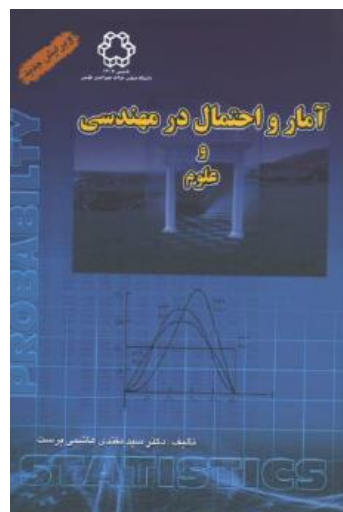
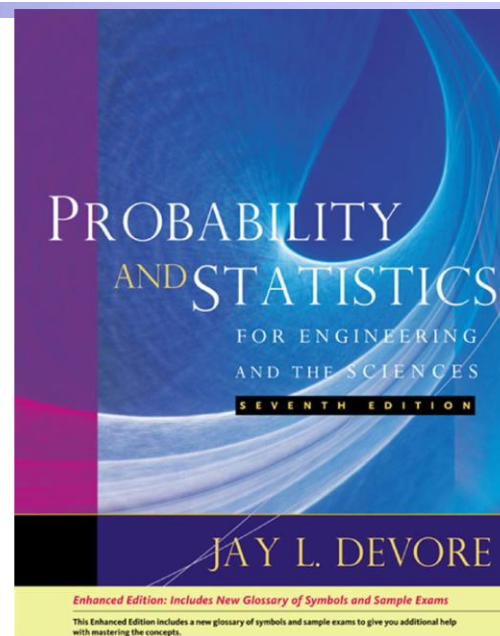
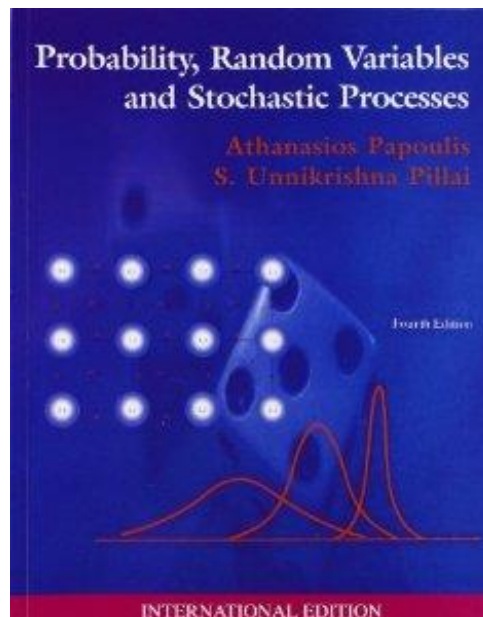
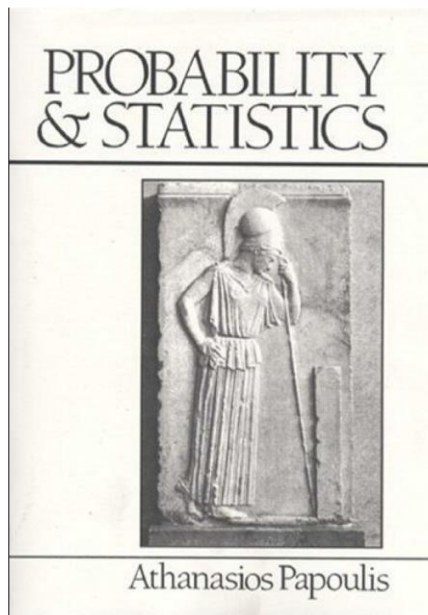
دکتر بهناز بیگدلی  
دانشکده مهندسی عمران  
دانشگاه صنعتی شاهرود

## نحوه ارزیابی

امتحان پایان ترم (۱۴)

امتحان میان ترم (۴)

تمرینات و کوئیزها (۲)



# فهرست و عناوین درس

## I. بخش اول: آمار مقدماتی (توصیفی)

1. آمار مقدماتی
2. اندازه‌گیری پراکندگی، گشاورها، چولگی و کشیدگی
3. برازش خط و منحنی بر داده‌ها
4. توزیع‌های دو بعدی و ضریب همبستگی

## II. احتمال

1. احتمال و فضای نمونه
2. فضای نمونه با عناصر متعدد
3. احتمالات شرطی و نایبستگی
4. تابع چگالی احتمال، تابع توزیع و امید ریاضی
5. توزیع‌های گسسته
6. توزیع‌های پیوسته مهم
7. نظریه برآورد
8. آزمون‌های فرض

# توزیع‌های دوبعدی و ضریب همبستگی

# فهرست مطالب این فصل:

- ۱- مقدمه-توزیع دوبعدی
- ۲- گشتاورهای دوبعدی
- ۳- کووریانس (وریانس مشترک)
- ۴- نمودارهای پراکندگی
- ۵- ضریب همبستگی
- ۶- ضریب همبستگی رتبه‌ای اسپیرمن
- ۷- ضریب تعیین
- ۸- معادله خط رگرسیون
- ۹- خطای استاندارد برآورد
- ۱۰- محاسبه زاویه بین دو خط رگرسیون
- ۱۱- ضرایب همبستگی داده‌های گروه‌بندی شده

## مقدمه-توزیع دوبعدی

✓ حوادث متعددی در طبیعت اتفاق می افتد که بین آنها همبستگی یا رابطه وجود دارد. منظور از رابطه بین متغیرها وجود رابطه علت معلولی نیست.

**نکته:** همبستگی رابطه بین دو متغیر در جامعه را توصیف می کند که در متغیرها، یکی را  $X$  و دیگری را  $Y$  می نامند.

## مقدمه-توزیع دوبعدی

✓ **نکته:** ضریب همبستگی با  $r_{xy}$  نشان داده می‌شود. ضریب همبستگی هم جهت رابطه و هم شدت رابطه را بیان می‌کند.

**نکته:** جهت همبستگی با علامت  $+/-$  نشان داده می‌شود و شدت همبستگی با قدر مطلق.

**نکته:** بالاترین ضریب همبستگی  $\pm 1$  می‌باشد.

## مقدمه-توزیع دوبعدی

✓ اگر یک جامعه آماری  $N$  تایی، دو صفت  $X, Y$  را اندازه‌گیری کنیم و آنها را بر حسب  $X, Y$  دسته‌بندی کنیم، جدول زیر بدست می‌آید.

	$a'_1 - b'_1$	$a'_2 - b'_2$	.....	$a'_m - b'_m$	
$a_1 - b_1$	$f_{11}$	$f_{12}$	.....	$f_{1m}$	$f_{1o}$
$a_2 - b_2$	$f_{21}$	$f_{22}$	.....	$f_{2m}$	$f_{2o}$
⋮	⋮	⋮	⋮	⋮	⋮
$a_n - b_n$	$f_{n1}$	$f_{n2}$	.....	$f_{nm}$	$f_{no}$
	$f_{o1}$	$f_{o2}$	.....	$f_{om}$	

## مقدمه-توزیع دوبعدی

	$a'_1 - b'_1$	$a'_2 - b'_2$	.....	$a'_m - b'_m$	
$a_1 - b_1$	$f_{11}$	$f_{12}$	.....	$f_{1m}$	$f_{1o}$
$a_2 - b_2$	$f_{21}$	$f_{22}$	.....	$f_{2m}$	$f_{2o}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$a_n - b_n$	$f_{n1}$	$f_{n2}$	.....	$f_{nm}$	$f_{no}$
	$f_{o1}$	$f_{o2}$	.....	$f_{om}$	

$$f_{io} = \sum_{j=1}^m f_{ij}$$

$$f_{oj} = \sum_{i=1}^n f_{ij}$$

$$N = \sum_{j=1}^m \sum_{i=1}^n f_{ij}$$

## مقدمه-توزیع دوبعدی

	$a'_1 - b'_1$	$a'_2 - b'_2$	.....	$a'_m - b'_m$	
$a_1 - b_1$	$f_{11}$	$f_{12}$	.....	$f_{1m}$	$f_{1o}$
$a_2 - b_2$	$f_{21}$	$f_{22}$	.....	$f_{2m}$	$f_{2o}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$a_n - b_n$	$f_{n1}$	$f_{n2}$	.....	$f_{nm}$	$f_{no}$
	$f_{o1}$	$f_{o2}$	.....	$f_{om}$	

$$\bar{X} = \frac{1}{N} \sum_{i=1}^n f_{io} x_i \quad \sigma_X^2 = \frac{1}{N} \sum_{i=1}^n f_{io} (x_i - \bar{X})^2$$

$$\bar{Y} = \frac{1}{N} \sum_{j=1}^m f_{oj} y_j \quad \sigma_Y^2 = \frac{1}{N} \sum_{j=1}^m f_{oj} (y_j - \bar{Y})^2$$

## گشتاورهای دوبعدی

✓ اگر بخواهیم  $X, Y$  را همزمان و در کنار هم مورد مطالعه قرار دهیم، لازم است پارامترهای مناسبی تعریف کنیم. گشتاور  $\mu'_{r_1 r_2}$  گشتاور مرتبه  $r_1$  ام بر حسب  $X$  و گشتاور مرتبه  $r_2$  ام بر حسب  $Y$  بصورت زیر تعریف می‌شود.

$$\mu'_{r_1 r_2} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m x_i^{r_1} y_j^{r_2} f_{ij}$$

## گشتاورهای دوبعدی

✓ اگر  $r_2 = 0, r_1 = r$  خواهیم داشت.

$$\mu'_{r,0} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m x_i^r f_{ij} = \frac{1}{N} \sum_{i=1}^n x_i^r \sum_{j=1}^m f_{ij} = \frac{1}{N} \sum_{i=1}^n x_i^r f_{i0} = \mu'_{r(x)}$$

✓ که  $\mu'_{r(x)}$  گشتارو مرتبه  $r$  ام حول مبدا  $X$  است و اگر  $r=1$  باشد.

$$\mu'_{1,0} = \mu'_{1(x)} = \mu_x = \bar{X}$$

## گشتاورهای دوبعدی

✓ اگر  $r_1 = 0, r_2 = r$  خواهیم داشت.

$$\mu'_{0,r} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m y_j^r f_{ij} = \frac{1}{N} \sum_{j=1}^m y_j^r f_{0j} = \mu'_{r(y)}$$

✓ که  $\mu'_{r(y)}$  گشتارو مرتبه  $r$  ام حول مبدا  $y$  است و اگر  $r=1$  باشد.

$$\mu'_{0,1} = \mu'_{1(y)} = \mu_y = \bar{Y}$$

## گشتاورهای دوبعدی

✓ گشتاور  $\mu'_{r_1 r_2}$  مرتبه  $r_1$  ام بر حسب  $X$  و گشتاور مرتبه  $r_2$  ام بر حسب  $Y$  حول دو مقدار  $a, b$  بصورت زیر تعریف می‌شود.

$$\mu'_{r_1 r_2} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m (x_i - a)^{r_1} (y_j - b)^{r_2} f_{ij}$$

✓ اگر  $a = \bar{X}, b = \bar{Y}$  باشد، گشتاور حول میانگین بدست خواهد آمد.

$$\mu_{r_1 r_2} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m (x_i - \bar{X})^{r_1} (y_j - \bar{Y})^{r_2} f_{ij}$$

## گشتاورهای دوبعدی

✓ اگر  $r_2 = 0, r_1 = r$  در گشتاور حول میانگین خواهیم داشت.

$$\mu_{r,0} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m (x_i - \bar{X})^r f_{ij} = \frac{1}{N} \sum_{i=1}^n (x_i - \bar{X})^r \sum_{j=1}^m f_{ij} = \frac{1}{N} \sum_{i=1}^n (x_i - \bar{X})^r f_{i0} = \mu_{r(x)}$$

✓ در حالتی که  $r=2$  وریانس  $X$  بدست خواهد آمد.

$$\mu_{2,0} = \frac{1}{N} \sum_{i=1}^n (x_i - \bar{X})^2 f_{i0} = \mu_{2(x)} = \sigma_x^2$$

## گشتاورهای دوبعدی

✓ اگر  $r_1 = 0, r_2 = r$  در گشتاور حول میانگین خواهیم داشت.

$$\mu_{0,r} = \frac{1}{N} \sum_{j=1}^m (y_j - \bar{Y})^r f_{oj} = \mu_{r(y)}$$

✓ در حالتی که  $r=2$  وریانس  $\gamma$  بدست خواهد آمد.

$$\mu_{0,2} = \frac{1}{N} \sum_{j=1}^m (y_j - \bar{Y})^2 f_{oj} = \mu_{2(y)} = \sigma_y^2$$

## کوریانس (وریانس مشترک)

✓ اگر  $\mu'_{r_1 r_2}$  حول میانگین  $\bar{X}$  و  $\bar{Y}$  و  $r_1 = r_2 = 1$  خواهیم داشت.

$$\mu_{1,1} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m (x_i - \bar{X})(y_j - \bar{Y}) f_{ij}$$

✓ پراکندگی  $X$ ها را حول میانگین در کنار پراکندگی  $Y$ ها حول میانگین خود را نشان می‌دهد. بنابراین نشان دهنده پراکندگی متقابل  $X, Y$  است.

$$\mu_{1,1} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m (x_i - \bar{X})(y_j - \bar{Y}) f_{ij} = \sigma_{XY} = \text{Cov}(X, Y)$$

$$\sigma_{XY} = \frac{1}{N} \sum_{i=1}^n \sum_{j=1}^m x_i y_j f_{ij} - \bar{X} \bar{Y} = \overline{XY} - \bar{X} \bar{Y}$$

# کووریانس (وریانس مشترک)

✓ کووریانس بیان کننده نحوه وابستگی  $X, Y$  است.

■ اگر کووریانس مثبت باشد، یعنی تغییرات  $X, Y$  در یک جهت است.

■ اگر کووریانس منفی باشد، یعنی تغییرات  $X, Y$  در خلاف جهت است.

# خواص کووریانس

✓ خواص کووریانس

$$\text{Cov}(X, X) = \sigma_X^2$$

$$\text{Cov}(X, Y) = \text{Cov}(Y, X)$$

$$\text{Cov}(X, C) = 0$$

$$\text{Cov}(X, Y + Z) = \text{Cov}(X, Y) + \text{Cov}(X, Z)$$

$$\text{Cov}(X, \alpha Y) = \alpha \text{Cov}(X, Y)$$

$$\text{Cov}(X, \alpha Y + \beta Z + \gamma) = \alpha \text{Cov}(X, Y) + \beta \text{Cov}(X, Z)$$

$$[\text{Cov}(X, Y)]^2 \leq \sigma_X^2 \sigma_Y^2$$

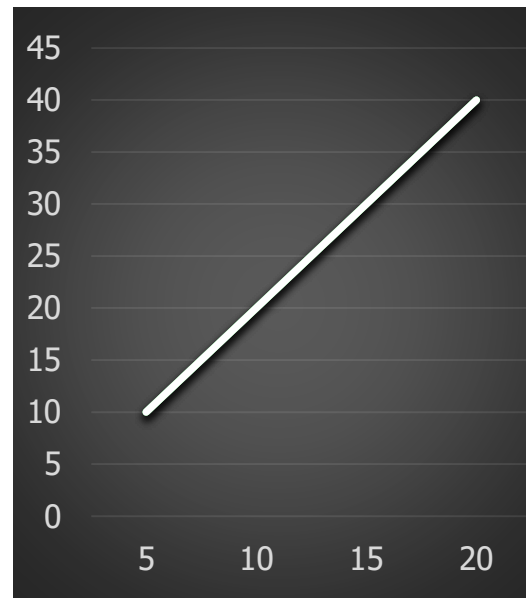
# نمودارهای پراکندگی

✓ یکی از روش‌هایی که می‌توان به وسیله آن همبستگی بین دو متغیر را نشان داد، نمودار پراکندگی است.

اشکال مختلف نمودار پراکندگی:

✓ الف: زمانی که با افزایش متغیر  $X$  متغیر  $Y$  هم افزایش پیدا می‌کند.

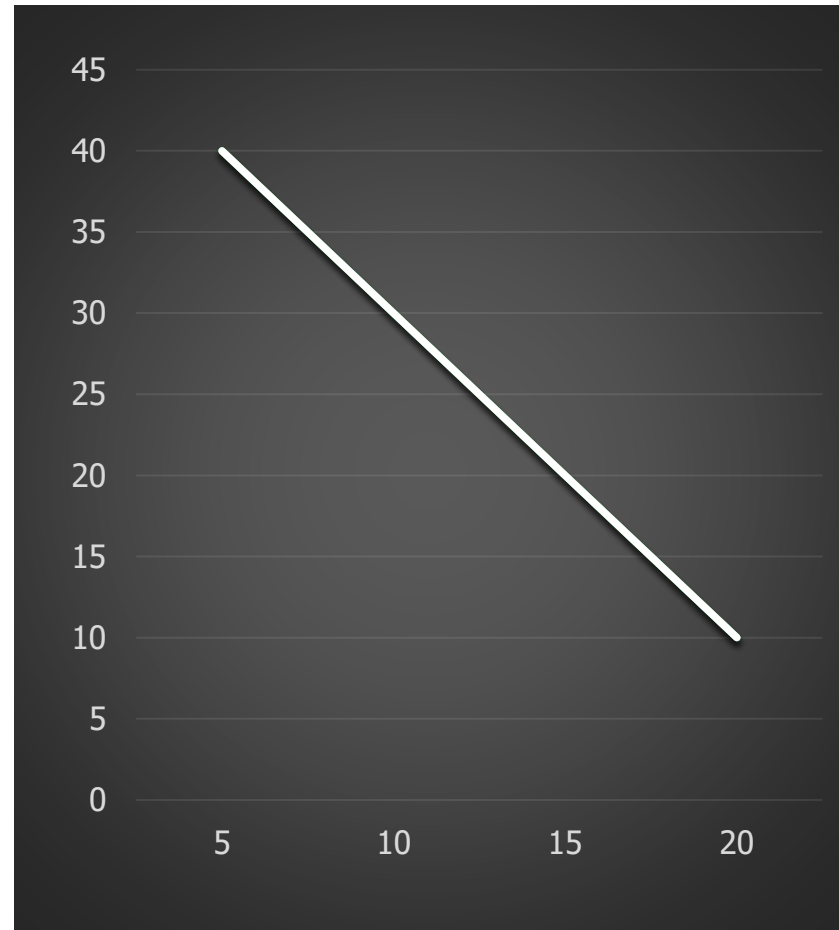
$$r_{xy} = +1$$



# نمودارهای پراکندگی

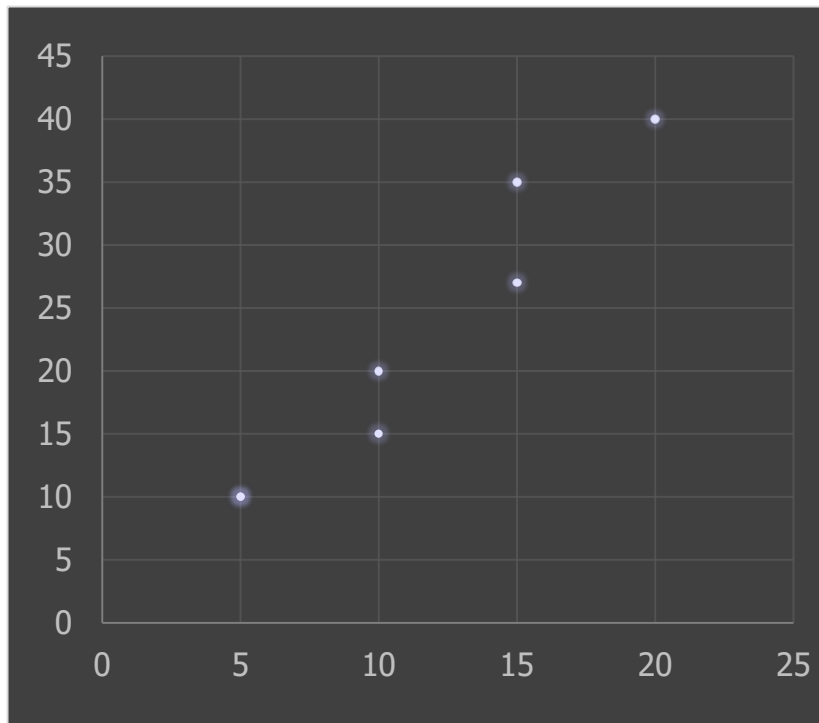
✓ ب: اگر با افزایش یک متغیر  $X$  متغیر دیگر  $Y$  کاهش پیدا کند

$$r_{xy} = -1$$



# نمودارهای پراکندگی

✓ ج: زمانی که با افزایش یک متغیر، متغیر دیگر افزایش پیدا کند ولی مقادیر افزایش یکسان نباشد رابطه مستقیم خواهد بود ولی کامل نیست.

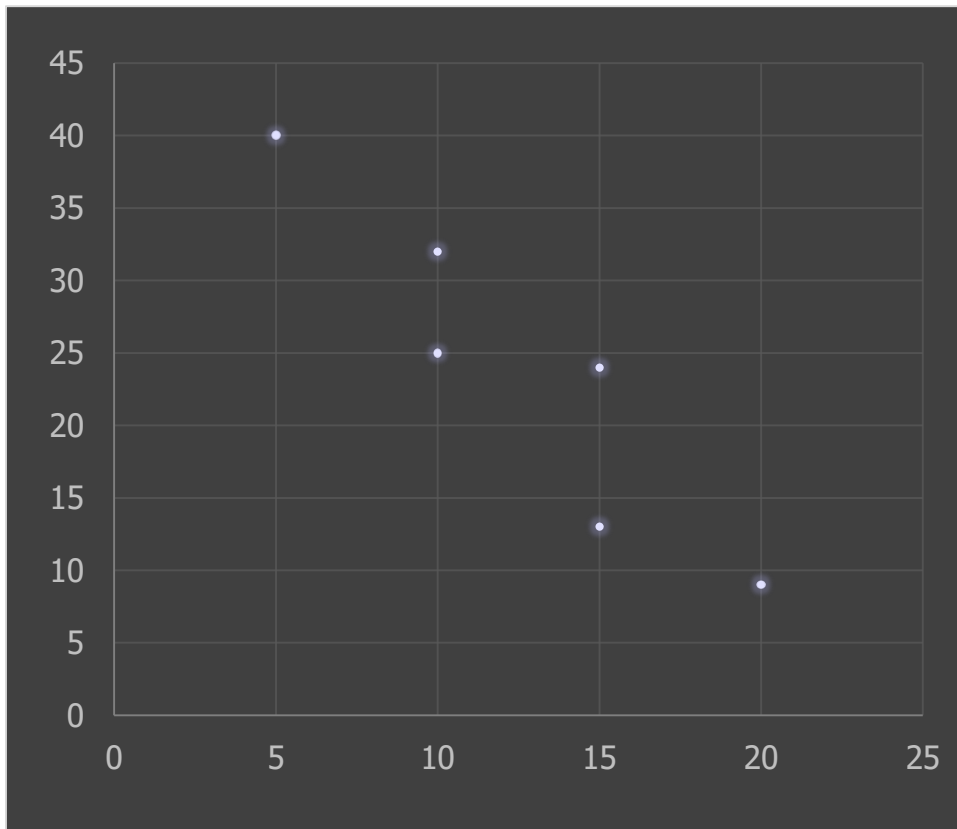


مثلاً

$$r_{xy} = +0.655$$

# نمودارهای پراکندگی

✓: زمانی که با افزایش یک متغیر مقدار متغیر دیگر کاهش پیدا می‌کند، اما مقادیر یکسان نیست.



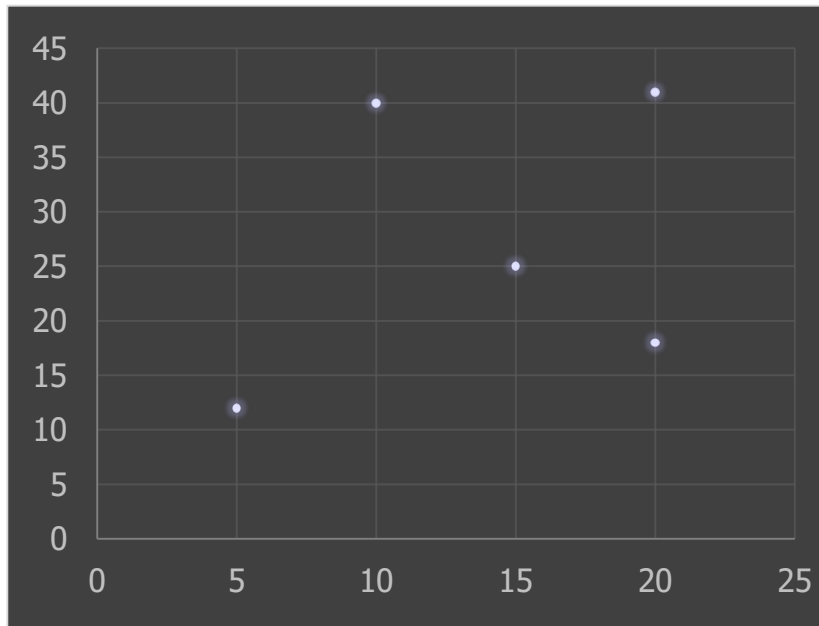
مثلاً

$$r_{xy} = -0.655$$

# نمودارهای پراکندگی

✓ ه: زمانی که رابطه ای بین متغیرها وجود نداشته باشد.

مثلاً



$$r_{xy} = 0.0$$

# محاسبه ضریب همبستگی

- ✓ برای محاسبه ضریب همبستگی شاخص‌های متعددی تدوین شده است. معروف‌ترین و در عین حال پر مصرف‌ترین آنها زمانی به کار برده می‌شود که متغیرهای مورد مطالعه با استفاده از مقیاس فاصله‌ای یا نسبی اندازه‌گیری شده باشند.
- ✓ این روش توسط **کارل پیرسون** تهیه و تنظیم گردیده است و **ضریب همبستگی گشتاوری پیرسون** نامیده می‌شود.

# محاسبه ضریب همبستگی پیرسون با سه روش

۱- استفاده از اعداد خام

$$r_{xy} = \frac{N(\sum XY) - (\sum X)(\sum Y)}{\sqrt{\left(N\sum X^2 - (\sum X)^2\right) \left(N\sum Y^2 - (\sum Y)^2\right)}}$$

<b>X</b>	<b>Y</b>	<b>X<sup>2</sup></b>	<b>Y<sup>2</sup></b>	<b>XY</b>
<b>10</b>	<b>15</b>	<b>100</b>	<b>225</b>	<b>150</b>
<b>15</b>	<b>14</b>	<b>225</b>	<b>196</b>	<b>210</b>
<b>5</b>	<b>11</b>	<b>25</b>	<b>121</b>	<b>55</b>
<b>8</b>	<b>13</b>	<b>64</b>	<b>169</b>	<b>104</b>
<b>12</b>	<b>12</b>	<b>144</b>	<b>144</b>	<b>144</b>
<b>50</b>	<b>65</b>	<b>558</b>	<b>855</b>	<b>663</b>

$$r_{xy} = \frac{5(663) - (50)(65)}{\sqrt{[5(558) - (50)^2][5(855) - (65)^2]}} = 0 / 54$$

# محاسبه ضریب همبستگی پیرسون با سه روش

۲- محاسبه ضریب همبستگی از راه انحراف از میانگین:

$$r_{xy} = \frac{\Sigma(X - \bar{X})(Y - \bar{Y})}{\sqrt{\Sigma(X - \bar{X})^2 \Sigma(Y - \bar{Y})^2}} = \frac{\text{cov}(X, Y)}{\sigma_x \sigma_y}$$

$$r_{XY} = \frac{\Sigma xy}{\sqrt{\Sigma x^2 \Sigma y^2}}$$

## مثال:

<b>X</b>	<b>Y</b>	<b>X'</b>	<b>Y'</b>	<b>X'<sup>2</sup></b>	<b>Y'<sup>2</sup></b>	<b>X'Y'</b>
<b>10</b>	<b>15</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>4</b>	<b>0</b>
<b>15</b>	<b>14</b>	<b>5</b>	<b>1</b>	<b>25</b>	<b>1</b>	<b>5</b>
<b>5</b>	<b>11</b>	<b>-5</b>	<b>-2</b>	<b>25</b>	<b>4</b>	<b>10</b>
<b>8</b>	<b>13</b>	<b>-2</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>0</b>
<b>12</b>	<b>12</b>	<b>2</b>	<b>-1</b>	<b>4</b>	<b>1</b>	<b>-2</b>
<b>50</b>	<b>65</b>			<b>58</b>	<b>10</b>	<b>13</b>

$$r_{xy} = \frac{13}{\sqrt{58 \times 10}} = 0.54$$

# محاسبه ضریب همبستگی پیرسون با سه روش

۳- محاسبه ضریب همبستگی با استفاده از داده‌های استاندارد شده

$$r_{xy} = \frac{\sum Z_x Z_y}{N}$$

$$Z_x = \frac{x - \mu_x}{\sigma_x}$$

$$Z_y = \frac{y - \mu_y}{\sigma_y}$$

## مثال:

<b>X</b>	<b>Y</b>	<b>Z<sub>x</sub></b>	<b>Z<sub>y</sub></b>	<b>Z<sub>x</sub>Z<sub>y</sub></b>
<b>10</b>	<b>15</b>	<b>0</b>	<b>1/41</b>	<b>0</b>
<b>15</b>	<b>14</b>	<b>1/47</b>	<b>0/71</b>	<b>1/04</b>
<b>5</b>	<b>11</b>	<b>-1/47</b>	<b>-1/41</b>	<b>2/1</b>
<b>8</b>	<b>13</b>	<b>-0/59</b>	<b>0</b>	<b>0</b>
<b>12</b>	<b>12</b>	<b>+0/59</b>	<b>-0/71</b>	<b>-0/42</b>
<b>50</b>	<b>65</b>			<b>2/72</b>

$$r_{xy} = \frac{2/72}{5} = 0/54$$

# ضریب همبستگی اسپیرمن

ضریب همبستگی اسپیرمن صورتی از ضریب همبستگی پیرسون است و زمانی به کار برده می‌شود که داده‌ها رتبه‌بندی شده باشند یا به جای اعداد رتبه‌های آنها در دست باشد.

$$P = 1 - \frac{6\sum D^2}{N(N^2 - 1)}$$

**P** = ضریب همبستگی رتبه‌ای اسپیرمن

**D<sup>2</sup>** = مجذور تفاوت رتبه‌ها

**N** = تعداد داده‌ها

## مراحل محاسبه ضریب همبستگی رتبه‌ای اسپیرمن

- ۱- اعداد متغیر  $X$  به ترتیب از بزرگ به کوچک مرتب می‌کنیم  $(R_x)$  و بعد از آن اعداد  $Y$  مربوط به هر عدد  $X$  را در ستون  $Y$  ها قرار می‌دهیم و به آنها رتبه می‌دهیم  $(R_y)$
- ۲-  $R_y$  را از  $R_x$  کم می‌کنیم و اختلاف آنها را  $D$  می‌نامیم.
- ۳-  $D$  ها را به توان دو می‌رسانیم و مجموع آنها را محاسبه می‌کنیم.
- ۴- مقادیر به دست آمده را در فرمول جایگزین می‌کنیم.

## ضریب همبستگی رتبه‌ای اسپیرمن

✓ نکته:

بعضی مواقع یک عدد چند بار تکرار شده است در این مواقع رتبه‌های اعداد را با هم جمع کرده و بر تعداد آنها تقسیم می‌کنیم. نتیجه به دست آمده رتبه اعداد تکرار شده می‌باشد.

## ضریب همبستگی اسپیرمن داده‌های زیر را محاسبه کنید.

X	46	45	47	45	43	41	45
Y	51	32	38	39	50	48	41

<b>X</b>	<b>Y</b>	<b>R<sub>x</sub></b>	<b>R<sub>y</sub></b>	<b>D</b>	<b>D<sup>2</sup></b>
<b>47</b>	<b>38</b>	<b>1</b>	<b>6</b>	<b>-5</b>	<b>25</b>
<b>46</b>	<b>51</b>	<b>2</b>	<b>1</b>	<b>1</b>	<b>1</b>
<b>45</b>	<b>32</b>	<b>4</b>	<b>7</b>	<b>-3</b>	<b>9</b>
<b>45</b>	<b>39</b>	<b>4</b>	<b>5</b>	<b>-1</b>	<b>1</b>
<b>45</b>	<b>41</b>	<b>4</b>	<b>4</b>	<b>0</b>	<b>0</b>
<b>43</b>	<b>50</b>	<b>6</b>	<b>2</b>	<b>4</b>	<b>16</b>
<b>41</b>	<b>48</b>	<b>7</b>	<b>3</b>	<b>4</b>	<b>16</b>
					<b>68</b>

$$P = 1 - \frac{6(68)}{7(7^2 - 1)} = -0.21$$

# عواملی که بر ضریب همبستگی تأثیر می گذارند:

۱- اساس رابطه از جامعه‌ای به جامعه دیگر فرق می‌کند.

مثلاً در افراد بشر در سنین ۱۶-۱۰ سالگی بین سن تقویمی و توانایی فیزیولوژیکی همبستگی بالایی وجود دارد. ولی بین این دو متغیر در سنین ۲۶-۲۰ سالگی همبستگی وجود ندارد.

## عواملی که بر ضریب همبستگی تأثیر می گذارند:

۲- پراکندگی متغیرها در جوامع مختلف متفاوت است بدین معنی که هر چه تجانس بیشتر باشد همبستگی کمتر است. به عنوان مثال، در یک دانشکده (جامعه) بین قد و موفقیت در بازی بسکتبال همبستگی مثبت و بالایی وجود دارد. اما در تیم بسکتبال یک کشور چنین رابطه ای وجود ندارد.

## عواملی که بر ضریب همبستگی تأثیر می گذارند:

۳- همبستگی بین دو متغیر تحت تأثیر همبستگی آنها با متغیر ثالثی قرار دارد به عنوان مثال، همبستگی بین فیزیک و ریاضی ممکن است به دلیل همبستگی این متغیرها با هوش باشد.

**نکته:** تفسیر ضریب همبستگی نباید بر حسب درصد و نسبت باشد. مثلاً  $r_{xy} = 0/70$  هفتاد درصد رابطه بین متغیرها را تبیین نمی کند و  $r_{xy} = 0/90$  دقیقاً دو برابر  $r_{xy} = 0/45$  نیست.

## ضریب تعیین

ضریب تعیین نشان دهنده میزان تأثیری است که متغیر  $X$  (مستقل) در متغیر  $Y$  (وابسته) ایجاد می‌کند یا به عبارتی با محاسبه این ضریب می‌توان تعیین کرد چند درصد از کل واریانس  $X$  ناشی از واریانس  $Y$  است.

$$V = (r_{xy})^2 (100)$$

**نکته:** ضریب تعیین هیچ وقت منفی نخواهد شد زیرا برای محاسبه آن ضریب همبستگی مجذور می‌شود.

## پیش بینی

✓ زمانی که بین دو متغیر همبستگی وجود داشته باشد می توان از طریق رگرسیون مقدار یک متغیر  $Y$  را از روی یک متغیر دیگر  $X$  پیش بینی یا برآورد کرد، و هر چه همبستگی بین متغیرها بالاتر باشد، به همان اندازه پیش بینی دقیق تر است.

**نکته:** رابطه بین متغیر پیش بینی شونده  $Y$  و متغیر پیش بینی کننده  $X$  تابع علامت و شدت ضریب همبستگی است.

# پیش بینی داده‌های استاندارد (Z)

مقدماتی ترین روشی که در استفاده از ضریب همبستگی پیرسون برای پیش بینی به کار برده می شود داده‌های استاندارد است.

$$Z_x = \frac{x - \mu_x}{\sigma_x}$$

$$Z_y = (Z_x)(r_{XY})$$

# رگرسیون

زمانی که همبستگی بین دو متغیر پایین باشد، داده‌های پیش بینی شده نزدیک به میانگین داده پیش‌بینی شونده هستند تا داده واقعی، به این پدیده رگرسیون می‌گویند.

**نکته:** میزان همبستگی بین دو متغیر حدود یا مقدار اتفاق رگرسیون را تعیین می‌کند.

**نکته:** پدیده رگرسیون اولین بار بوسیله گالتن مورد استفاده قرار گرفت. بر اساس مطالعات گالتن، فرزندان والدین بلند قد، بلند قد هستند. اما نه به اندازه والدین خود. به همین ترتیب فرزندان والدین کوتاه قد، کوتاه قد هستند اما نه به کوتاهی والدین خود.

# خط رگرسیون

خطی که در رابطه با داده‌های پیش بینی شده است **خط رگرسیون** نامیده می‌شود. به عبارتی خطی است که خطاهای پیش بینی را به حداقل می‌رساند (خط حداقل مجذورها).

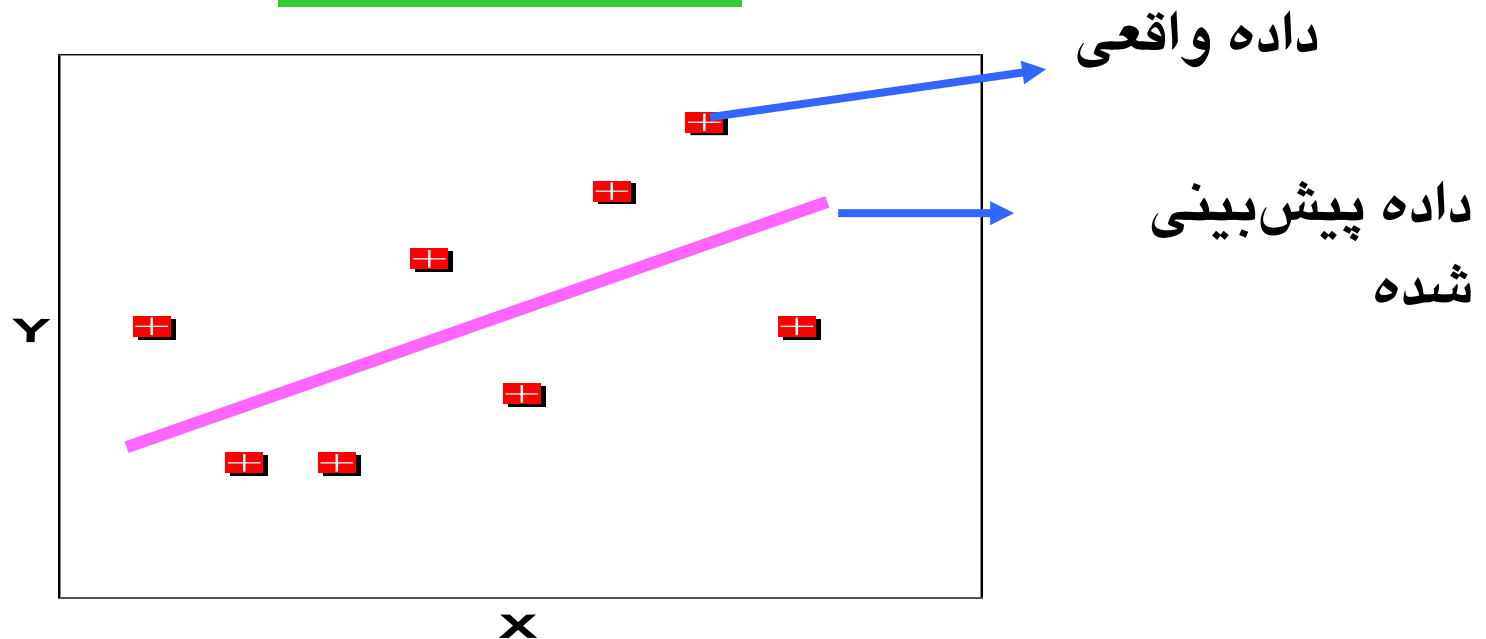
✓ یعنی اینکه مجموع مجذور فاصله  $Y$  ها از خط رگرسیون کوچکتر از فاصله هر خط دیگری تا محور  $Y$  ها می‌باشد.

# خط رگرسیون

**نکته:** خط رگرسیون را خط برازشده نیز می‌نامند.

**نکته:** اختلاف بین داده واقعی  $Y$  و داده پیش‌بینی شده  $y'$  را خطای پیش‌بینی  $e$  می‌گویند.

$$e = y - y'$$



# معادله خط رگرسیون

برای پیش بینی یک متغیر از روی متغیر دیگر از معادله خط رگرسیون استفاده می شود.

فرمول معادله خط :

$$y' = a + bx$$

$b$  = شیب خط

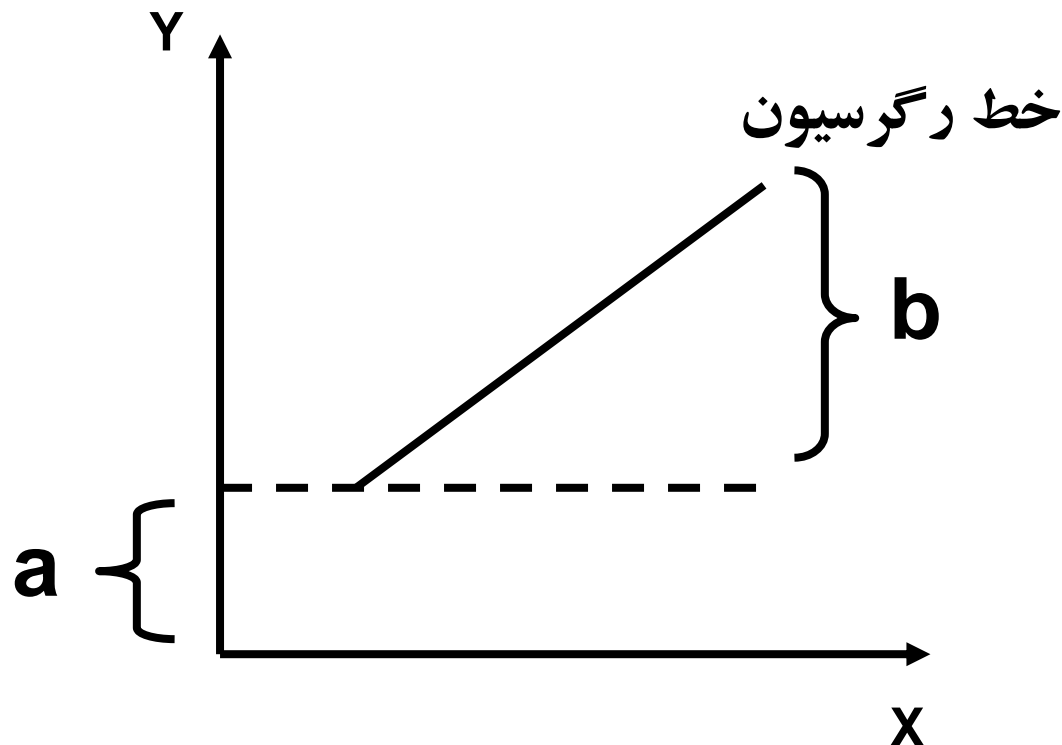
متغیری که می خواهیم پیش بینی کنیم  $y'$

عرض از مبدأ یا محل تلاقی خط رگرسیون با محورایگرگ  $a$

متغیری که مقدار آن را در اختیار داریم  $x$

## معادله خط رگرسیون

✓ نکته: بعضی مواقع مقدار  $a$  و  $b$  در اختیار است در این صورت با جایگزینی مقادیر محاسبه خیلی ساده می باشد.



## معادله خط رگرسیون

✓ نکته: بعضی مواقع مقدار  $a$  و  $b$  در اختیار است در این صورت با جایگزینی مقادیر محاسبه خیلی ساده می باشد.

مثال:

$$X = 0$$

$$Y = 4 + 2(0) = 4$$

$$X = 1$$

$$Y = 4 + 2(1) = 6$$

$$X = 4$$

$$Y = 4 + 2(4) = 12$$

$$X = 8$$

$$Y = 4 + 2(8) = 20$$

# روش محاسبه ضرایب $a$ و $b$

✓  $a$  و  $b$  را به دو روش می توان محاسبه کرد:

**الف:** زمانی که داده های خام در اختیار نداشته باشیم و یک سری اطلاعات به ما داده باشند.

**ب:** زمانی که اطلاعات و داده های خام در اختیار داشته باشیم.

# محاسبه $a$ و $b$ از روی اطلاعات ثانوی

$$b_{yx} = r_{xy} \frac{\sigma_Y}{\sigma_X}$$

$$b_{xy} = r_{xy} \frac{\sigma_X}{\sigma_Y}$$

شیب خط رگرسیون  $b_{yx}$  و  $b_{xy}$

$r_{xy}$  = ضریب همبستگی

$\sigma_Y$  =  $Y$  انحراف استاندارد

$\sigma_X$  =  $X$  انحراف استاندارد

## محاسبه $a$ و $b$ از روی اطلاعات ثانوی

$$a_{xy} = \bar{x} - b_{xy}(\bar{y})$$

$$a_{yx} = \bar{y} - b_{yx}(\bar{x})$$

$$a_{yx}, a_{xy} =$$

عرض از مبدأ

$$\bar{x}, \bar{y} =$$

میانگین

$$b_{xy}, b_{yx} =$$

شیب خط

## محاسبه $a$ و $b$ از روی داده‌های خام

$$b_{yx} = \frac{N \sum XY - (\sum X)(\sum Y)}{N \sum X^2 - (\sum X)^2} = \frac{\sum XY - N \bar{X} \bar{Y}}{\sum X^2 - N \bar{X}^2}$$

$$a_{yx} = \frac{\sum Y - b_{yx} \sum X}{N} = \bar{Y} - b_{yx} \bar{X}$$

مثال: برای داده‌های زیر معادله خط رگرسیون را به دست آورید؟

X	Y	X <sup>2</sup>	Y <sup>2</sup>	XY
6	8	36	64	48
9	9	81	81	81
5	7	25	49	35
20	24	142	194	164

$$b_{yx} = \frac{3(164) - (20)(24)}{3(142) - (20)^2} = 0 / 46$$

$$a_{yx} = \frac{24 - (0 / 46)(20)}{3} = 4.93$$

$$y = 4.93 + 0 / 46(X)$$

# خطای استاندارد برآورد

اکثر مواقع بین داده‌های پیش‌بینی شده و داده‌های مشاهده تفاوت وجود دارد، به این اختلاف **خطای استاندارد برآورد** می‌گویند.

**نکته:** هر چه همبستگی بین متغیرها بیشتر باشد، خطای پیش‌بینی کمتر خواهد بود. این خطا به دو روش محاسبه می‌شود.

# خطای استاندارد برآورد

$$\sigma_{yx} = \sigma_y \sqrt{1 - r_{xy}^2}$$

$$\sigma_{yx} = \sqrt{\frac{\sum e^2}{N}}$$

$\sigma_{yx}$  = خطای استاندارد پیش بینی

$\sigma_y$  =  $y$  انحراف استاندارد

$\sigma_x$  =  $x$  انحراف استاندارد

$r_{xy}$  = ضریب همبستگی

$e$  = خطای پیش بینی

## محاسبه زاویه بین دو خط رگرسیون

✓ شیب‌های خطوط رگرسیون  $Y$  روی  $X$  و  $X$  روی  $Y$  به ترتیب عبارتند از:

$$\frac{1}{r} \times \frac{\sigma_x}{\sigma_y} \quad r \frac{\sigma_y}{\sigma_x}$$

✓ در نتیجه زاویه بین دو خط رگرسیون یعنی  $\theta$  برابر است با:

$$\tan(\theta) = \frac{\frac{1}{r} \times \frac{\sigma_x}{\sigma_y} - r \frac{\sigma_y}{\sigma_x}}{1 + \frac{1}{r} \times \frac{\sigma_x}{\sigma_y} \times r \frac{\sigma_y}{\sigma_x}} = \frac{1-r^2}{r} \times \frac{\sigma_x \sigma_y}{\sigma_x^2 + \sigma_y^2}$$

# محاسبه زاویه بین دو خط رگرسیون

✓ دو حالت ممکن است اتفاق بیافتد:

✓ همبستگی کامل  $r = \pm 1$  در این حالت زاویه بین دو خط صفر است، همچنین چون دو خط از میانگین‌ها رد می‌شوند، پس بر هم منطبق‌اند.

✓ همبستگی وجود ندارد  $r = 0$  در این حالت زاویه بین دو خط ۹۰ است و در نتیجه دور خط بر هم عمودند.

$$\tan(\theta) = \frac{\frac{1}{r} \times \frac{\sigma_x}{\sigma_y} - r \frac{\sigma_y}{\sigma_x}}{1 + \frac{1}{r} \times \frac{\sigma_x}{\sigma_y} \times r \frac{\sigma_y}{\sigma_x}} = \frac{1-r^2}{r} \times \frac{\sigma_x \sigma_y}{\sigma_x^2 + \sigma_y^2}$$

## ضریب همبستگی داده‌های گروه‌بندی شده

✓ یک جدول فراوانی دو طرفه متشکل از ستون‌ها ( $X$ ) و سطرها ( $Y$ ) دانست که هرکدام فراوانی دارند، در اینگونه از جداول از رابطه زیر به محاسبه ضریب همبستگی می‌پردازیم.

$$r = \frac{\sum fxy - \frac{\sum fx \times \sum fy}{N}}{\left[ \sum fx^2 - \frac{(\sum fx)^2}{N} \right]^{1/2} \times \left[ \sum fy^2 - \frac{(\sum fy)^2}{N} \right]^{1/2}}$$

تشکر از توجه شما

