

آزمون نرمال بودن داده‌ها

الف - آزمون شاپیرو-ویلک

یکی از آزمون‌هایی که برای قضاوت نرمال بودن داده‌ها وجود دارد، آزمون شاپیرو-ویلک است که به صورت زیر می‌توان انجام داد.

> shapiro.test(x)

مثال: در مجموعی داده آماده Women در R که مربوط به قد و وزن ۱۵۰ نفر از زنان آمریکایی است، می‌خواهیم بررسی کنیم که آیا قد و وزن این افراد دارای توزیع نرمال هستند یا خیر.

> Women

	height	weight
1	58	115
2	59	117
3	60	120
⋮	⋮	⋮

> Shapiro.test(Women[,1])

Shapiro-Wilk normality test

W = 0.96 , P-Value = 0.75

> Shapiro.test(Women[,2])

تمرین ۱: در مجموعی داده آماده CO2 در R که مربوط به جذب دی‌اکسید کربن در گیاهان علوفه‌ای است، بررسی کنید آیا میزان جذب (uptake) دارای توزیع نرمال هست یا خیر؟

تمرین ۲: در مجموعی داده 1 - info که در تکالیف دوم از آن استفاده کرده‌اید، بررسی کنید آیا فشارخون افراد براساس جنسیت دارای توزیع نرمال هست؟! (به تفکیک جنسیت بررسی کنید آیا توزیع فشارخون (BP) نرمال است؟)

ب- آزمون کلوگروف-اسمیرنوف

آزمون کلوگروف-اسمیرنوف نیز برای فرض نرمال بودن داده‌ها مورد استفاده قرار می‌گیرد. این آزمون در مقایسه با آزمون شاپیرو-ویلک از توان آزمون کمتری برای بررسی نرمال بودن داده‌ها برخوردار است. این آزمون با تابع $(ks.test)$ در R قابل انجام است.

> $ks.test(x, "pnorm", mean(x), sd(x))$

> $ks.test(Women[1,], "pnorm", mean(Women[1,]), sd(Women[1,]))$

ج- آزمون نرمال بودن با استفاده از آزمون نیکویی-برازش

در این روش ابتدا باید داده‌های پیوسته را به صورت دسته‌ای بنویسیم و طبقه بندی کنیم و سپس جایی که مراحل را هاتند آنجایی که در آزمون نیکویی برازش گفته شد انجام می‌دهیم.

دقیقاً همان‌طور که قبلاً بررسی کنیم آیا میزان جذب (uptake) در هر دسته داده

CO₂ دارای توزیع نرمال است یا خیر.

> $x = CO2[1,5]$ → برای باقی کار داده‌های این متغیر را داخل بردار x

> $range(x)$ → بردار کردن دامنه تغییرات متغیر x قرار دادیم.

[1] 7.7 45.5

> $max(x) - min(x)$

[1] 37.8

حال باید داده‌ها را به صورت دسته‌ای بنویسیم. برای این کار فرض کنید می‌خواهیم داده‌ها را به ۶ دسته تقسیم بندی کنیم. بنابراین طول هر دسته را به دست می‌آوریم.

> $(max(x) - min(x)) / 6$

[1] 6.3

حال دسته‌های صاف قدرت زیری شوند.

$$7.7 < x < 14 \quad \equiv \quad x < 14$$

$$14 < x < 20.3$$

$$20.3 < x < 26.6$$

$$26.6 < x < 32.9$$

$$32.9 < x < 39.2$$

$$x \geq 39.2$$

$$\rightarrow Z = 1$$

$$\rightarrow Z = 2$$

$$\rightarrow Z = 3$$

$$\rightarrow Z = 4$$

$$\rightarrow Z = 5$$

$$\rightarrow Z = 6$$

و مرحله بعد بدست آوردن فراوانی‌های هر دسته است که می‌توان این‌ها را به صورت زیر

یا هم ادغام کنیم:

$$W = C ()$$

$$W[1] = \text{Length (which } (x < 14))$$

$$W[2] = \text{Length (which } (x < 20.3 \text{ \& } x \geq 14))$$

⋮

$$W[6] = \text{Length (which } (x \geq 39.2))$$

> W

[1] 13 17 7 18 15 14

بنابراین ضرایب دسته‌های صافها به صورت زیری شود:

دسته‌ها	Z=1	Z=2	Z=3	Z=4	Z=5	Z=6
فراوانی‌ها	13	17	7	18	15	14

$$H_0: X \sim N(\mu, \sigma^2)$$

$$H_1: O.W$$

آزمون مساله:

حال باید احتمال های مورد نظر با هر دسته را حاصل کنیم. (تحت فرض H_0)

$$P_1 = P_{0.1} = P(Z=1) = P(X < 14)$$

$$X \sim N(\mu, \sigma^2)$$

یعنی μ و σ^2 را معلوم پس باید برآورد کنیم.

$$\hat{\mu} = \bar{X} \quad \hat{\sigma}^2 = S_x^2$$

> mean(x) → mu

> mu = mean(x)

> Sd(x) → sd

> sd = Sd(x)

$$\Rightarrow P_{0.1} = P_{H_0}(X < 14) = P\left(\frac{X - \mu}{Sd} \leq \frac{14 - \mu}{Sd}\right) = \Phi\left(\frac{14 - \mu}{Sd}\right)$$

به همین ترتیب باید احتمال های هر دسته را حاصل کنیم.

> P = c ()

> P[1] = pnorm(14, mean = mu, sd = sd)

> P[2] = pnorm(20.3, mu, sd) - pnorm(14, mu, sd)

⋮

> P[6] = pnorm(39.2, mu, sd, lower.tail = F)

پس به این ترتیب برآورد احتمالات مربوط به هر دسته مشخص شود.

★ چون برای انجام این آزمون، دو پارامتر را حاصل کردیم بنابراین باید این آزمون را

بدون استفاده از تابع () chisq.test انجام دهیم.

> n = length(x)

> n

[1] 84

> e = c ()

> e = n * p →

برآورد مربوط به مقادیر مورد انتظار

حال باید چک کنیم ببینیم آیا مقادیر مورد انتظار از 5 بالاتر هستند یا نه که در این مثال خاصی

مقادیر e بالای 5 هستند.

حال باید مقدار آماره آزمون (χ^2) و P-value را بصورت بیاوریم

$$\chi^2 = \sum_{i=1}^k \frac{(o_i - e_i)^2}{e_i}$$

$$P\text{-value} = P(\chi^2 > \chi^2_0)$$

$$\chi^2 \stackrel{H_0}{\sim} \chi^2_{(k-1-2)}$$

\leftarrow 6
 \leftarrow ۲ پارامتر بیاورد
 کردیم

$$> \chi^2 = \text{sum}(((w - e)^2) / e)$$

$$> P\text{-value} = \text{pchisq}(\chi^2, 3, \text{lower.tail} = F)$$

نردین ۳: بررسی کنید آیا مسافرون افراد حاضر در خابله info_1 به تفکیک جنسیت دارای

توزیع زمانی هستند یا خیر.

مسافرون افراد با جنسیت ۰

$H_0: BP_0 \sim \exp(\lambda)$
 $H_1: 0, W$

ازون اول

$H_0: BP_1 \sim \exp(\lambda)$
 $H_1: 0, W$

ازون دوم