

# Statistika za jezikoslovno istraživanje

Damir Ćavar  
Sveučilište u Zadru  
14. travnja 2010.

# Domaći

- Jednadžba u R-u, za x niz vjerojatnosti (tj. vrijednosti između 0 i 1, i  $\text{sum}(x)=1$ ):

$$-\sum_{i=1}^n p(x_i) \log_b p(x_i)$$

# Domaći

- U R-u:
  - $-\text{sum}(x * \log2(x))$
- Primjer:
  - $x <- c(0.1, 0.3, 0.11, 0.3, 0.08, 0.02, 0.09)$
  - $-\text{sum}(x * \log2(x))$
  - 1.724659

# Promjene razmjera podataka

# Promjene razmjera

- Ako imamo rezultate:
  - 1, 3, 4, 5, 7
- Kolika je aritmetička sredina?
- Koja je srednja vrijednost?
- Koja je standardna devijacija?

# Promjene razmjera

- Za rezultate u R-u: `x <- c(1, 3, 4, 5, 7)`
  - Aritmetička sredina: 4
    - R: `mean(x)`
  - Srednja vrijednost: 4
    - R: `median(x)`
  - Standardna devijacija: 2
    - R: `sqrt(sum((x-mean(x))^2)/length(x))`

# R funkcije

- Definiramo funkciju za standardnu devijaciju u R-u:

```
sdd <- function (x) { sqrt( sum  
(( (x)-mean( (x) ))^2)/length(x) ) }
```

- Pozivamo funkciju:

```
sdd(x)
```

# Promjene razmjera

- Što ako menjamo rezultate, npr. dodajemo 4 ili oduzimamo 4 od svake vrijednosti u rezultatima?

- u R-u:

`mean(x-4)`

`median(x-4)`

`sdd(x-4)`

# Promjene razmjera

- Dodavanje ili oduzimanje jedne konstantne vrijednosti (npr. 4) svakoj vrijednosti
  - diže ili smanjuje aritmetičku sredinu i srednju vrijednost za vrijednost te konstante
  - standardna devijacija ostaje ista
- Histogram se samo miče desno ili lijevo.

# Promjene razmjera

- Što će se desiti ako umnožavamo ili dijelimo sve vrijednosti s pozitivnim konstantnim brojevima?

`mean( x*3 )`

`median( x*3 )`

`sdd( x*3 )`

# Promjene razmjera

- Množenje svih vrijednosti s pozitivnom konstantnom vrijednosti (npr. 3):
  - Umnožava aritmetičku sredinu i srednju vrijednost s tom konstantom
  - Standardna devijacija se isto umnožava s tom konstantom
- Histogram se rasteže.

# Promjene razmjera

- Množenje svih vrijednosti s negativnom konstantnom vrijednosti (npr. -1)
  - Umnožava aritmetičku sredinu i srednju vrijednost za vrijednost te konstante
  - Standardna devijacija se isto umnožava za vrijednost te konstante
- Histogram se rasteže (za vrijednosti veće od -1), ali se redoslijed vrijednosti odražava obratni redoslijed vrijednosti.

# Promjene razmjera

- Ako odbijemo od svakog rezultata aritmetičku sredinu i dijelimo kroz standardnu devijaciju, što to znači na kraju za rezultirajuće mjere?  
$$(x - \text{mean}(x)) / \text{sdd}(x)$$
- Koje vrijednosti dobijemo za:
  - aritmetičku sredinu
  - standardnu devijaciju

# Promjene razmjera

- Histogram distribucije se pomiče lijevo i centrira na 0
  - $\text{mean}(y) : 0$
- Standardna devijacija se ne mijenja ako dodajemo ili oduzimamo konstantnu vrijednost od svakog rezultata:
  - $\text{sdd}(x - \text{mean}(x)) : 2$

# Promjene razmjera

- Ako dijelimo svaku vrijednost kroz standardnu devijaciju distribucije, mijenjamo gustoću, smanjujemo raspršenost:

$$(x - \text{mean}(x)) / \text{sdd}(x)$$

-1.5 -0.5 0.0 0.5 1.5

- Tako da je  $\text{sdd}(x)$  na kraju uvijek 1
  - Zašto?

# Promjene razmjera

- Ako dijelimo vrijednosti rezultata kroz neki konstantni broj, npr.  $\text{sdd}(x)$ , posljedice za rezultirajuću standardnu devijaciju su da se i ona dijeli kroz tu konstantu.
- |:  
$$\text{sdd}((x - \text{mean}(x)) / \text{sdd}(x))$$
  - je isto kao:  
$$\text{sdd}(x - \text{mean}(x)) / \text{sdd}(x)$$
  - Za svaki broj  $n (\neq 0)$ ,  $n/n = 1$

# Promjene razmjera

- Pretvaranje distribucije u standardne mjere (tkzv. z-vrijednosti u literaturi)
  - dimenzije imaju standardne mjere:
    - aritmetička sredina 0
    - standardna devijacija 1
  - Ne znači da sve distribucije izgledaju iste, da su uopće normalne distribucije!

# Standardne mjera

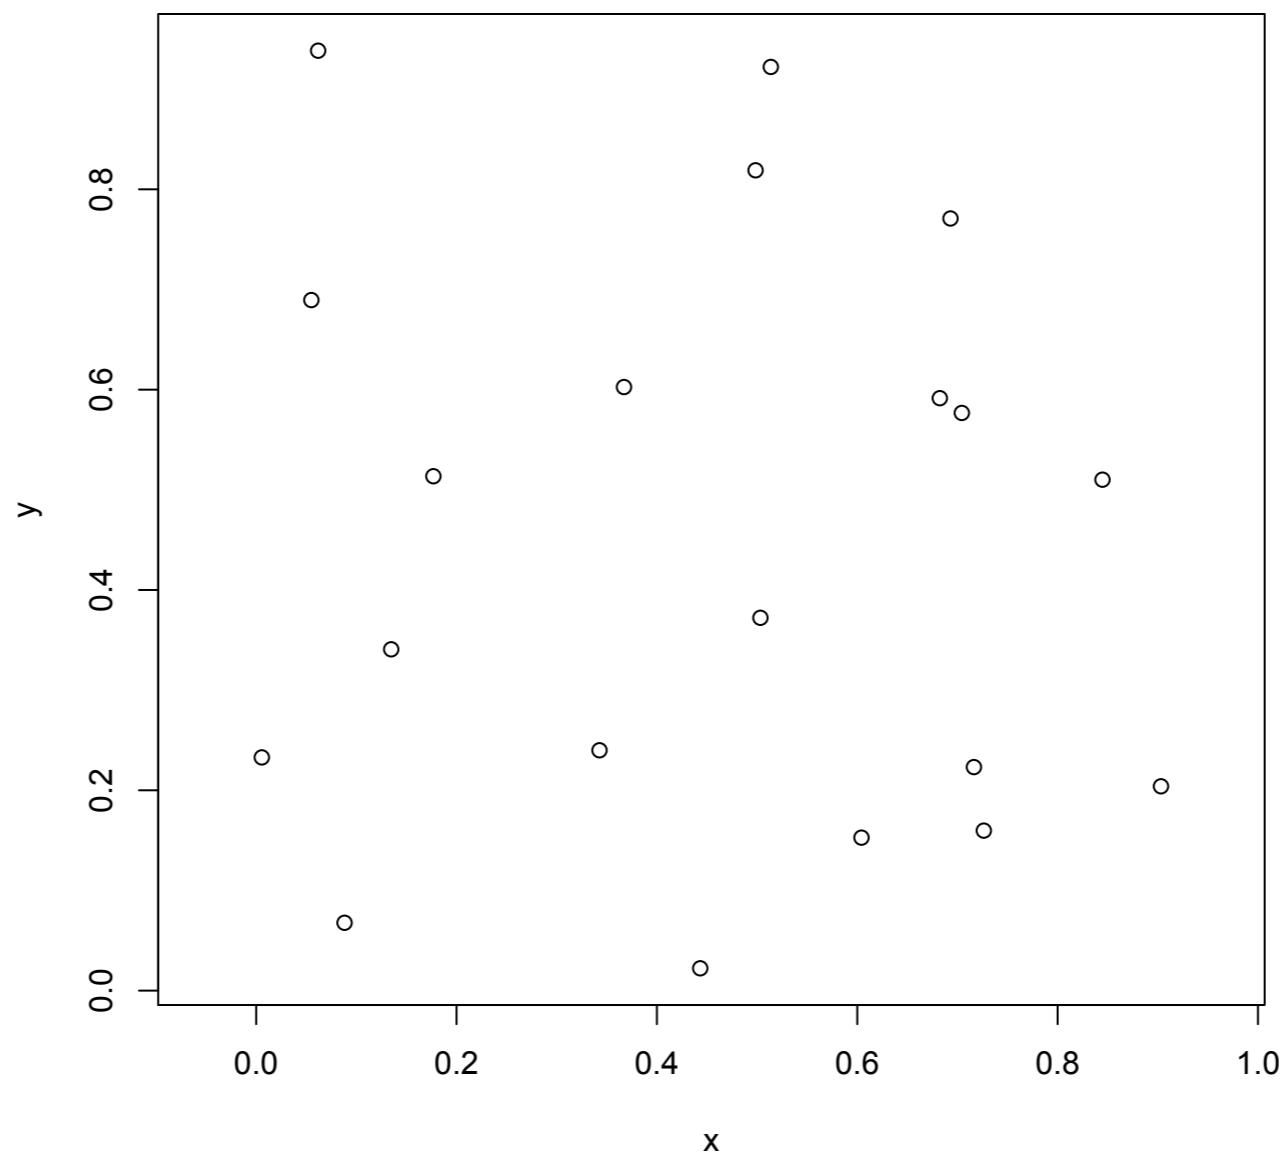
- Standardna mjerama nam daje odgovor na pitanje:
  - Koliko standardnih devijacija je svaka mjerama odmaknuta od aritmetičke sredine?

# Korelacijski koeficijent

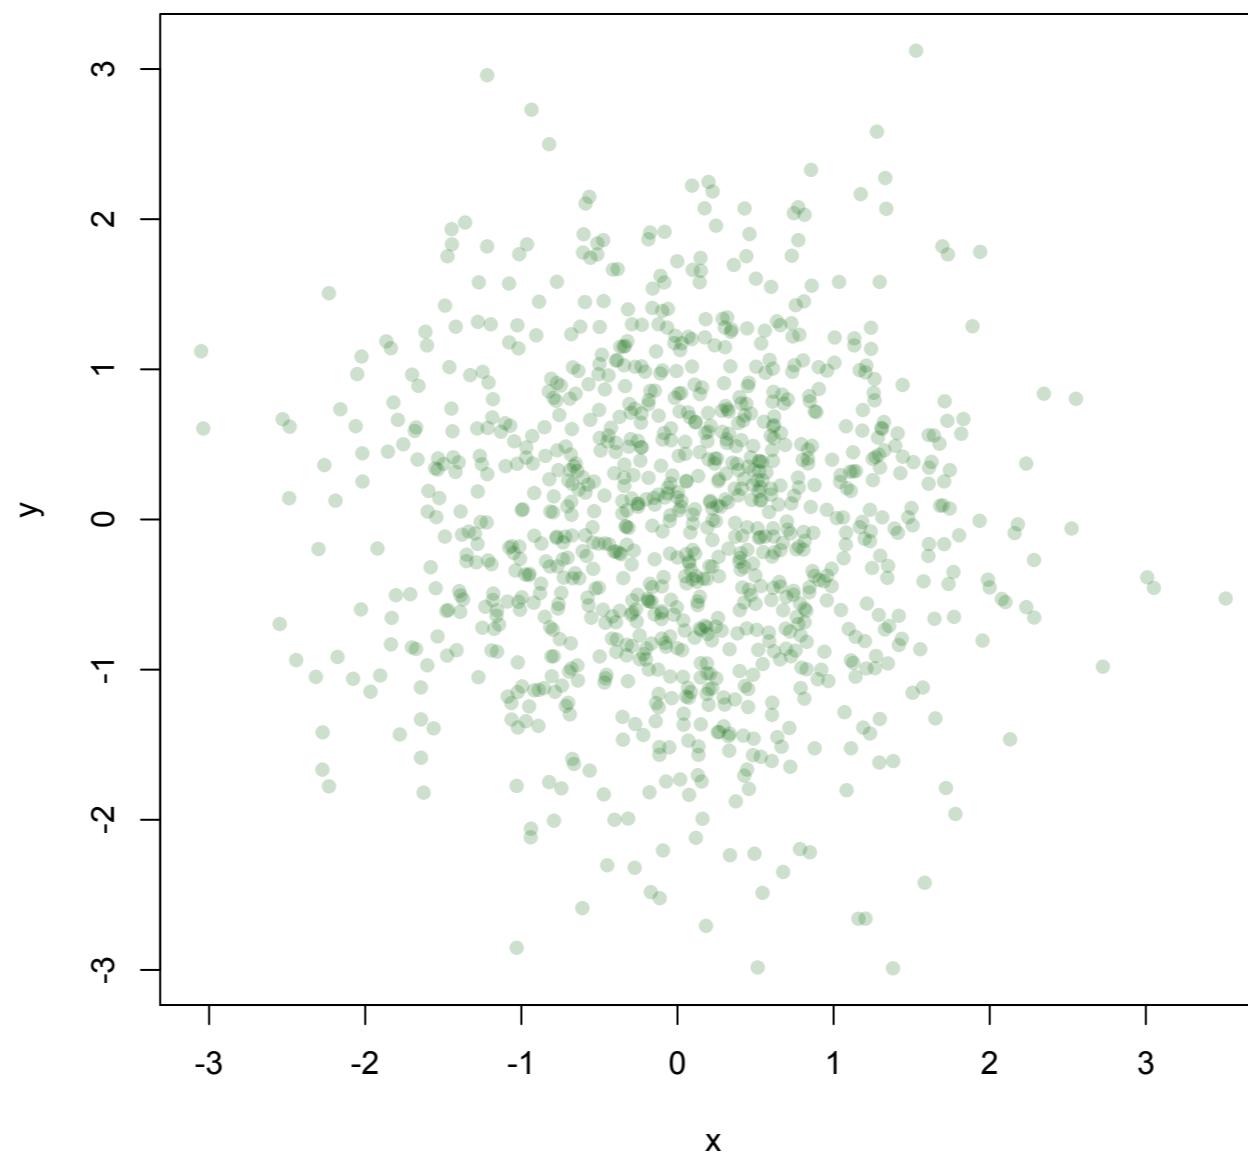
# Korelacijski koeficijent

- Do sada:
  - Centar distribucije:  $\text{mean}(x)$
  - Simetrija:  $\text{median}(x)$ ,  $\text{mode}(x)$  u relaciji s  $\text{mean}(x)$
  - Raspršenost:  $\text{sdd}(x)$
- Ako imamo dvije varijable, kao u primjerima kada smo računali Chi2 vrijednosti, što želimo znati ili pronaći?

# Raspršeni grafikon

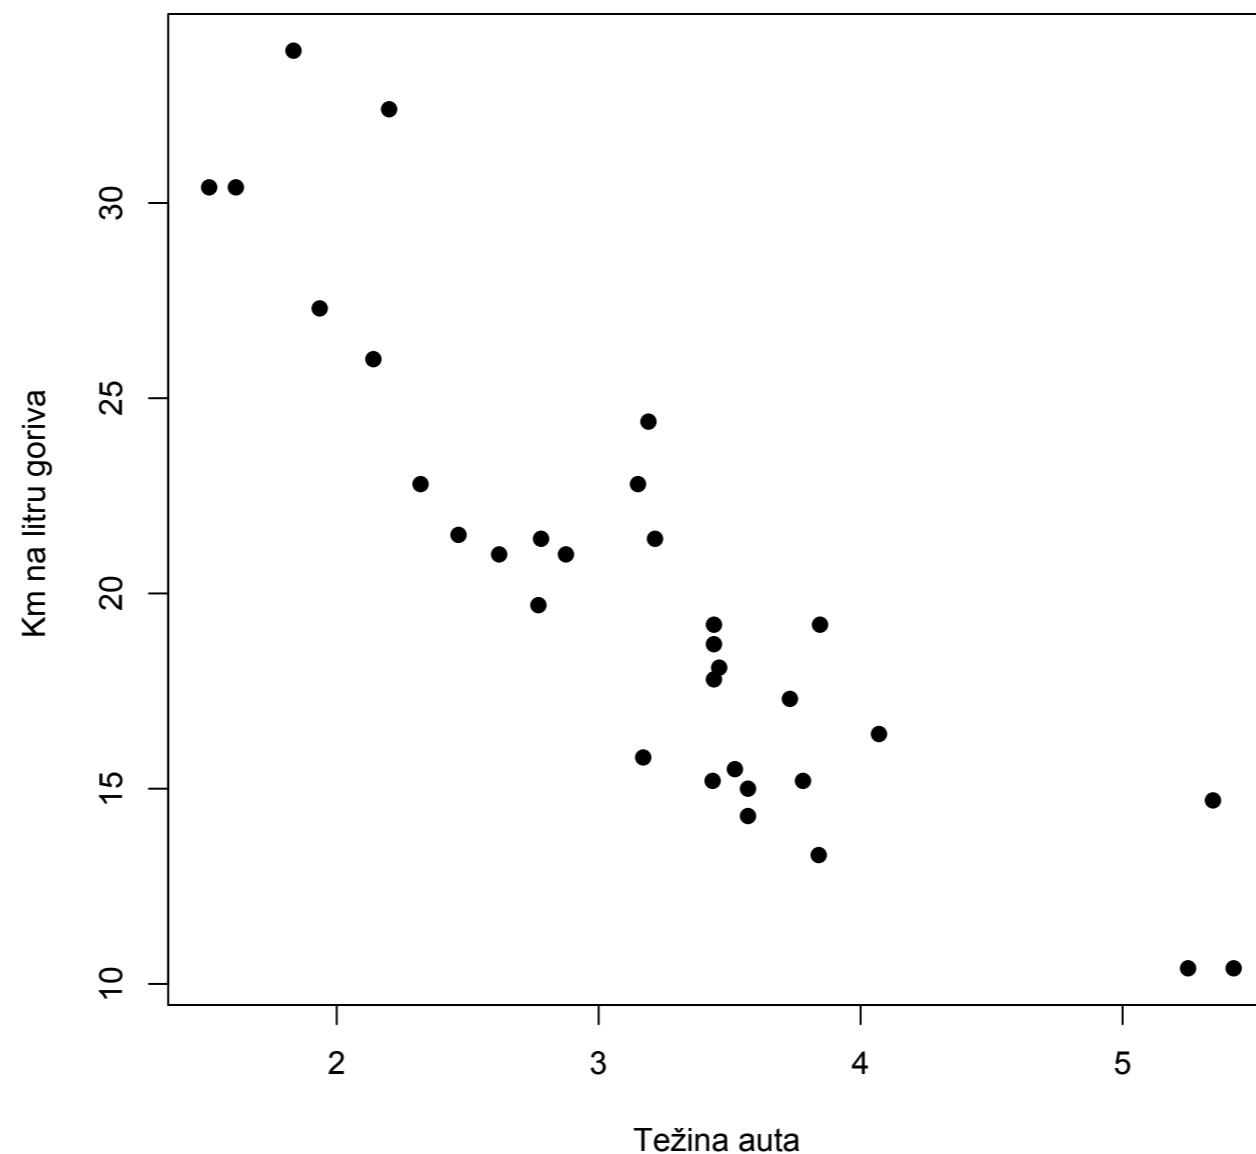


# Raspršeni grafikon



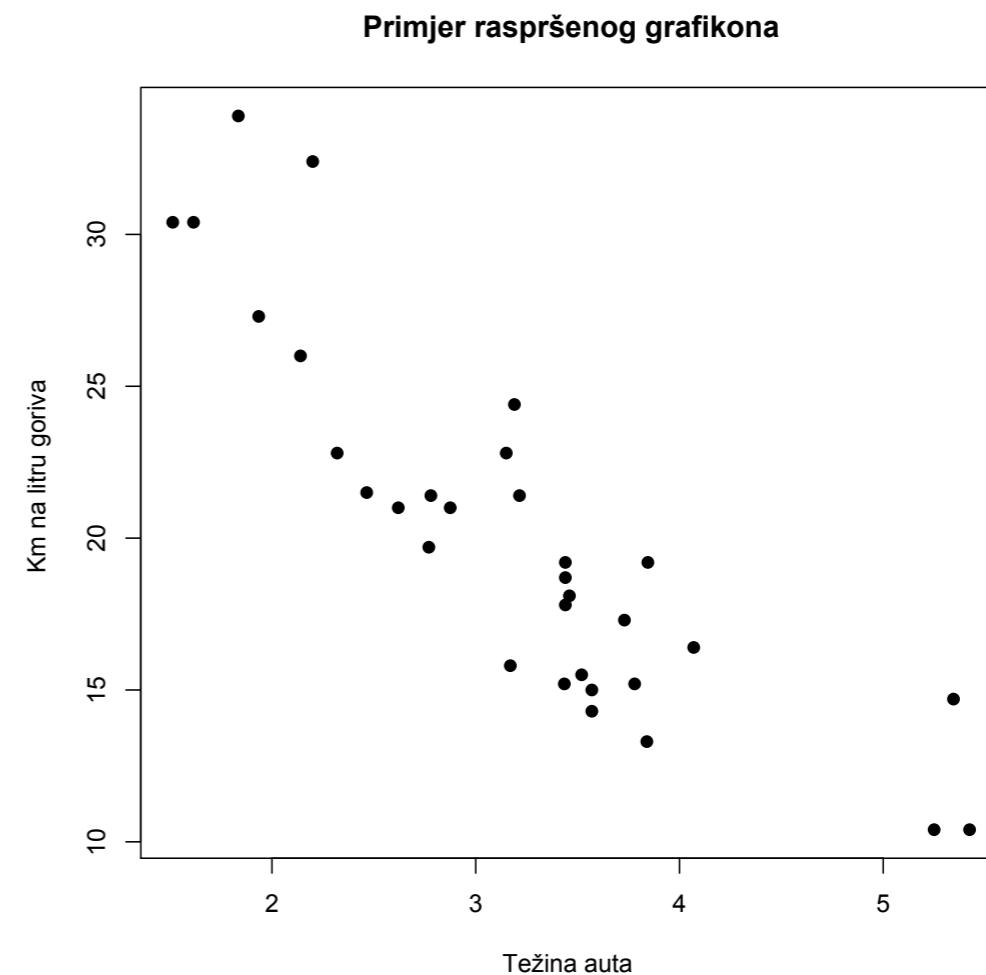
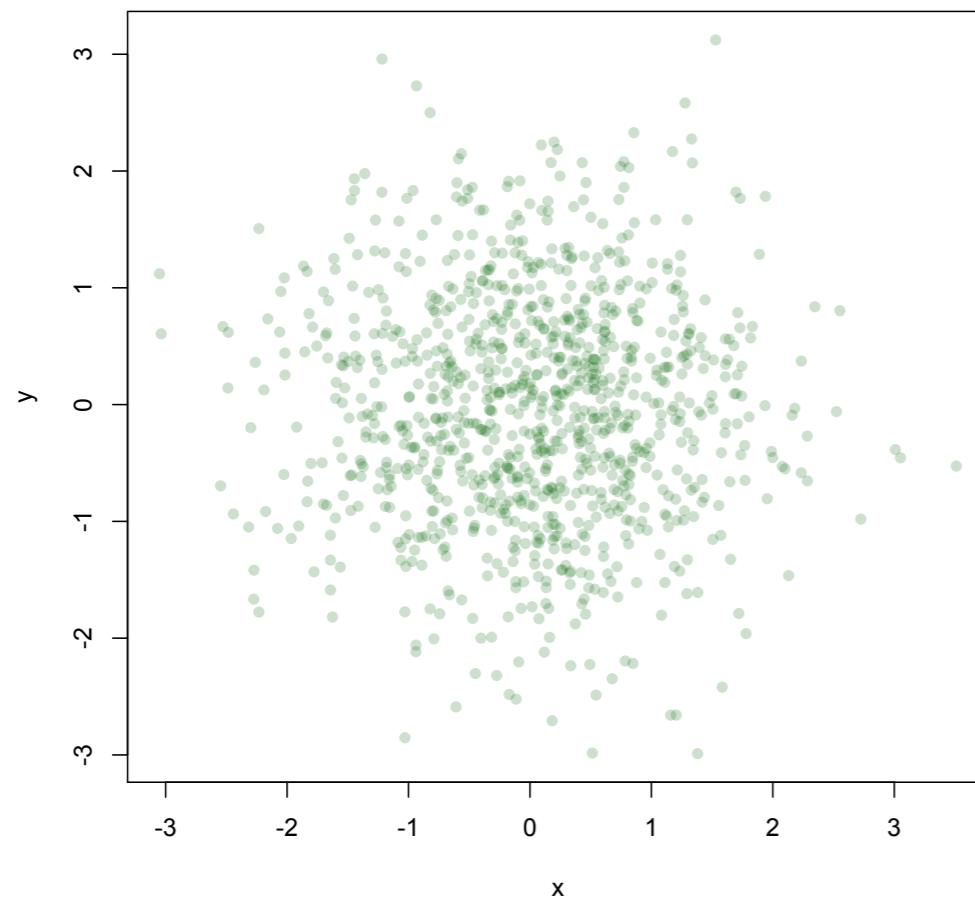
# Raspršeni grafikon

Primjer raspršenog grafikona



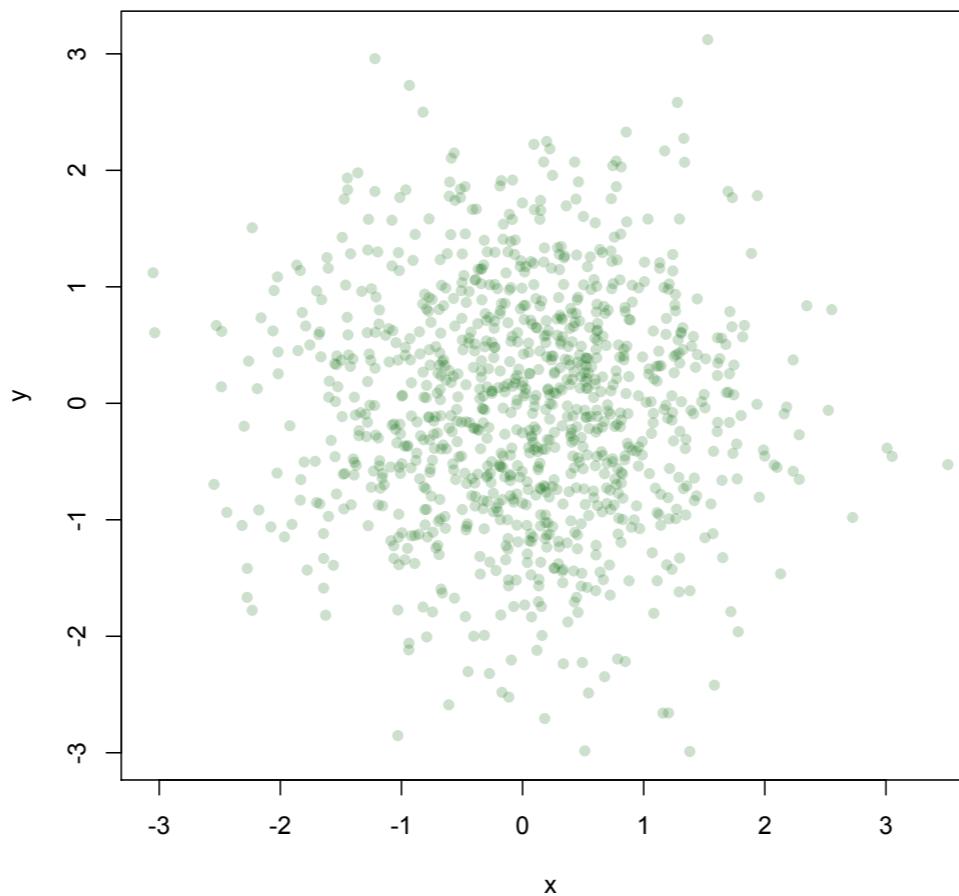
# Raspršeni grafikon

- Što nam pokazuje raspršeni grafikon, ako uspoređujemo prvi i drugi primjer?



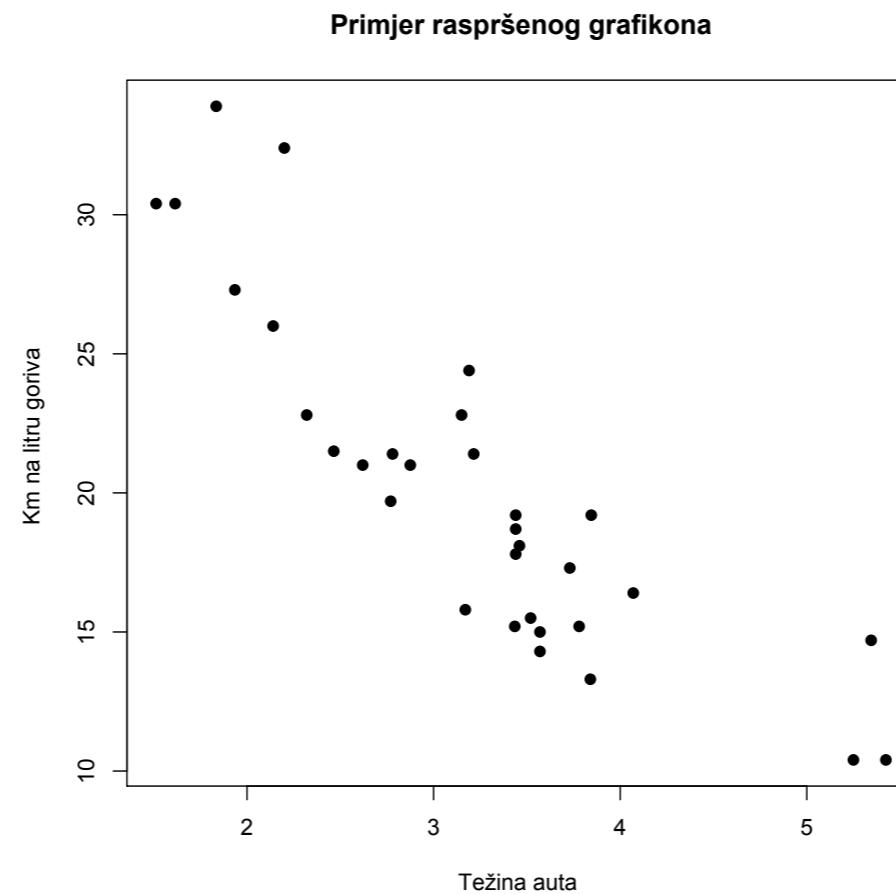
# Raspršeni grafikon

- U prvom primjeru dvije varijable ne izgledaju ovisne, ne koreliraju, ili koreliraju minimalno:



# Raspršeni grafikon

- U drugom primjeru dvije varijable izgledaju ovisne, koreliraju, ili koreliraju značajno:



# Raspršeni grafikon

- Oblik:
  - krug: nema korelacije
  - oval: moguća umjerena korelacija
  - linija: jaka korelacija

# Korelacijski koeficijent

- Korelacijski koeficijent  $r$ 
  - mjeri jakost jačine linearne relacije između dvaju varijabli.
  - Koliko blizu su svi rezultati jednoj liniji?

# Korelacijski koeficijent

- Korelacijski koeficijent  $r$ 
  - $r$  nema mjere
  - $r$  je uvijek između -1 i 1, tj. ako  $r = -1$  ili  $r = 1$ : rezultati se nalaze na jednoj liniji, s negativnim ili pozitivnim nagibom
  - ako  $r = -1$ :
    - što veće X vrijednosti, to manje Y vrijednosti
  - ako  $r = 1$ :
    - što veće X vrijednosti, to veće Y vrijednosti

# Korelacijski koeficijent

- Ako  $r=0$ :
  - Nema korelacije između varijabli.
  - Ne može se naći nijedna idealna linija kroz rezultate.
    - rezultati se slažu u krug
    - rezultati se slažu u neki simetrički oblik (npr. četverokut, trokut), bez idealne linije

# Korelacijski koeficijent

- Vrijednosti od  $r$  između 0 i 1 ili -1:
  - Što god bliže 1 ili -1, to veća korelacija između varijabli
- Kako izračunati  $r$ ?
  - Konvertiranje svih vrijednosti u standardnu mjeru
  - Izračunati umnožak tih standardnih mjera za obe varijable
  - Izračunati srednju vrijednost umnoška

# Korelacijski koeficijent

- Primjer u R-u:

```
x = c(2, 4, 5, 6, 8)
```

```
y = c(5, 2, 4, 8, 6)
```

```
mean(x) = mean(y) = 5
```

```
sdd(x) = sdd(y) = 2
```

- standardizirana mjera u R-u:

```
(x-mean(x))/sdd(x)
```

```
(y-mean(y))/sdd(y)
```

# Korelacijski koeficijent

- Definiramo funkciju za standardizirane mjere u R-u:

```
stm <- function(x) { (x-mean(x))/sd(x) }
```

- Pozivamo funkciju:

```
stm(x)
```

-1.5 -0.5 0.0 0.5 1.5

# Korelacijski koeficijent

- Primjer u R-u:
  - Umnožak standardnih mjera za x i y:
    - `psm <- stm(x) * stm(y)`
  - Srednja vrijednost tog umnoška:
    - `mean(psm)`
  - Korelacija u našem primjeru: 0.45
  - Zaključak: niska pozitivna korelacija

# Korelacijski koeficijent

- Definiramo funkciju za korelacijski koeficijent:

```
mojkk <- function(x, y)
{ mean(stm(x) * stm(y)) }
```

- ili koristimo jednostavno postojeću funkciju u R-u:

```
cor(x, y)
```

# Domaći

- Varijabla X

```
x <- c(3, 4, 8, 4, 2, 1, 0, 6)
```

- Varijabla Y

```
y <- c(1, 2, 4, 2, 2, 0, 1, 4)
```

- Izračunajte:

- Standardnu mjeru za sve rezultate varijabli
- Korelacijski koeficijent za X i Y

# Dodatni domaći

- Prevedite sljedeću jednadžbu u R:

$$-\sum_{i=1}^n p(x_i) \frac{\log_b p(x_i)}{\log_b(n)}$$