

# Základy stochastiky

Testy dobré shody

Prof. RNDr. Gejza Dohnal, CSc.



# Pravděpodobnostní modely

# Pravděpodobnostní modely

1) Diskrétní:

# Pravděpodobnostní modely

## 1) Diskrétní:

- Rovnoměrný  $\Omega = \{1, 2, \dots, N\}$

# Pravděpodobnostní modely

## 1) Diskrétní:

- Rovnoměrný
- Alternativní

$$\begin{aligned}\Omega &= \{1, 2, \dots, N\} \\ \Omega &= \{0, 1\}\end{aligned}$$

# Pravděpodobnostní modely

## 1) Diskrétní:

- Rovnoměrný  $\Omega = \{1, 2, \dots, N\}$
- Alternativní  $\Omega = \{0, 1\}$
- Binomický  $\Omega = \{0, 1, \dots, n\}$

# Pravděpodobnostní modely

## 1) Diskrétní:

- Rovnoměrný  $\Omega = \{1, 2, \dots, N\}$
- Alternativní  $\Omega = \{0, 1\}$
- Binomický  $\Omega = \{0, 1, \dots, n\}$
- Hypergeometrický  $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$

# Pravděpodobnostní modely

## 1) Diskrétní:

- |                    |  |
|--------------------|--|
| • Rovnoměrný       | $\Omega = \{1, 2, \dots, N\}$                        |
| • Alternativní     | $\Omega = \{0, 1\}$                                  |
| • Binomický        | $\Omega = \{0, 1, \dots, n\}$                        |
| • Hypergeometrický | $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$ |
| • Geometrický      | $\Omega = \{0, 1, 2, \dots\}$                        |

# Pravděpodobnostní modely

## 1) Diskrétní:

- |                    |  |
|--------------------|--|
| • Rovnoměrný       | $\Omega = \{1, 2, \dots, N\}$                        |
| • Alternativní     | $\Omega = \{0, 1\}$                                  |
| • Binomický        | $\Omega = \{0, 1, \dots, n\}$                        |
| • Hypergeometrický | $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$ |
| • Geometrický      | $\Omega = \{0, 1, 2, \dots\}$                        |
| • Poissonův        | $\Omega = \{0, 1, 2, \dots\}$                        |

# Pravděpodobnostní modely

## 1) Diskrétní:

- |                    |  |
|--------------------|--|
| • Rovnoměrný       | $\Omega = \{1, 2, \dots, N\}$                        |
| • Alternativní     | $\Omega = \{0, 1\}$                                  |
| • Binomický        | $\Omega = \{0, 1, \dots, n\}$                        |
| • Hypergeometrický | $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$ |
| • Geometrický      | $\Omega = \{0, 1, 2, \dots\}$                        |
| • Poissonův        | $\Omega = \{0, 1, 2, \dots\}$                        |

## 2) Spojité:

# Pravděpodobnostní modely

## 1) Diskrétní:

- |                    |  |
|--------------------|--|
| • Rovnoměrný       | $\Omega = \{1, 2, \dots, N\}$                        |
| • Alternativní     | $\Omega = \{0, 1\}$                                  |
| • Binomický        | $\Omega = \{0, 1, \dots, n\}$                        |
| • Hypergeometrický | $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$ |
| • Geometrický      | $\Omega = \{0, 1, 2, \dots\}$                        |
| • Poissonův        | $\Omega = \{0, 1, 2, \dots\}$                        |

## 2) Spojité:

- |              |                                 |
|--------------|---------------------------------|
| • Rovnoměrný | $\Omega = \langle a, b \rangle$ |
|--------------|---------------------------------|

# Pravděpodobnostní modely

## 1) Diskrétní:

- |                    |  |
|--------------------|--|
| • Rovnoměrný       | $\Omega = \{1, 2, \dots, N\}$                        |
| • Alternativní     | $\Omega = \{0, 1\}$                                  |
| • Binomický        | $\Omega = \{0, 1, \dots, n\}$                        |
| • Hypergeometrický | $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$ |
| • Geometrický      | $\Omega = \{0, 1, 2, \dots\}$                        |
| • Poissonův        | $\Omega = \{0, 1, 2, \dots\}$                        |

## 2) Spojité:

- |              |                                 |
|--------------|---------------------------------|
| • Rovnoměrný | $\Omega = \langle a, b \rangle$ |
| • Normální   | $\Omega = (-\infty, \infty)$    |

# Pravděpodobnostní modely

## 1) Diskrétní:

- |                    |  |
|--------------------|--|
| • Rovnoměrný       | $\Omega = \{1, 2, \dots, N\}$                        |
| • Alternativní     | $\Omega = \{0, 1\}$                                  |
| • Binomický        | $\Omega = \{0, 1, \dots, n\}$                        |
| • Hypergeometrický | $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$ |
| • Geometrický      | $\Omega = \{0, 1, 2, \dots\}$                        |
| • Poissonův        | $\Omega = \{0, 1, 2, \dots\}$                        |

## 2) Spojité:

- |                 |                                      |
|-----------------|--------------------------------------|
| • Rovnoměrný    | $\Omega = \langle a, b \rangle$      |
| • Normální      | $\Omega = (-\infty, \infty)$         |
| • Exponenciální | $\Omega = \langle 0, \infty \rangle$ |

# Pravděpodobnostní modely

## 1) Diskrétní:

- |                    |  |
|--------------------|--|
| • Rovnoměrný       | $\Omega = \{1, 2, \dots, N\}$                        |
| • Alternativní     | $\Omega = \{0, 1\}$                                  |
| • Binomický        | $\Omega = \{0, 1, \dots, n\}$                        |
| • Hypergeometrický | $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$ |
| • Geometrický      | $\Omega = \{0, 1, 2, \dots\}$                        |
| • Poissonův        | $\Omega = \{0, 1, 2, \dots\}$                        |

## 2) Spojité:

- |                 |                                      |
|-----------------|--------------------------------------|
| • Rovnoměrný    | $\Omega = \langle a, b \rangle$      |
| • Normální      | $\Omega = (-\infty, \infty)$         |
| • Exponenciální | $\Omega = \langle 0, \infty \rangle$ |
| • Weibullův     | $\Omega = \langle 0, \infty \rangle$ |

# Pravděpodobnostní modely

## 1) Diskrétní:

- |                    |  |
|--------------------|--|
| • Rovnoměrný       | $\Omega = \{1, 2, \dots, N\}$                        |
| • Alternativní     | $\Omega = \{0, 1\}$                                  |
| • Binomický        | $\Omega = \{0, 1, \dots, n\}$                        |
| • Hypergeometrický | $\Omega = \{\max(0, n + M - N), \dots, \min(n, M)\}$ |
| • Geometrický      | $\Omega = \{0, 1, 2, \dots\}$                        |
| • Poissonův        | $\Omega = \{0, 1, 2, \dots\}$                        |

## 2) Spojité:

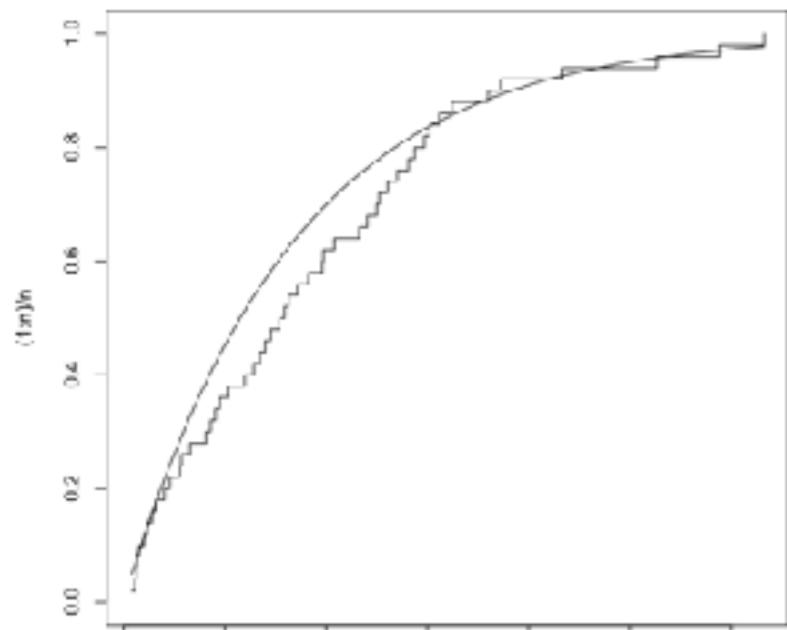
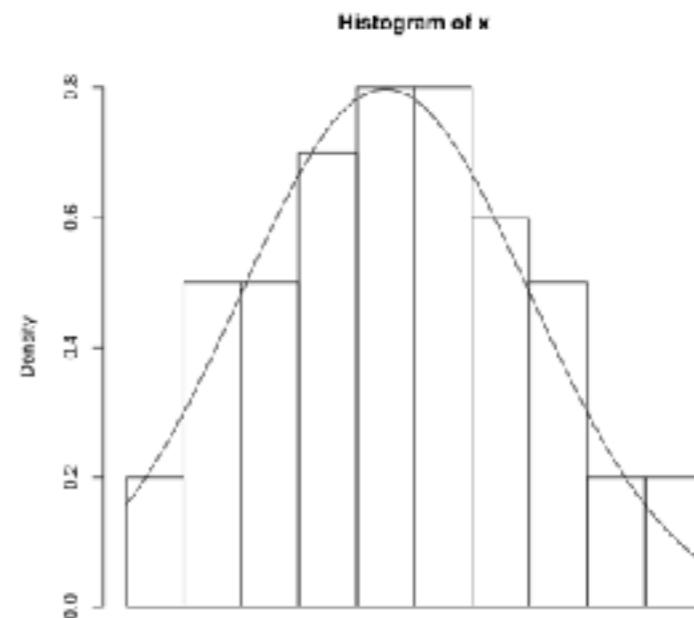
- |                         |                                      |
|-------------------------|--------------------------------------|
| • Rovnoměrný            | $\Omega = \langle a, b \rangle$      |
| • Normální              | $\Omega = (-\infty, \infty)$         |
| • Exponenciální         | $\Omega = \langle 0, \infty \rangle$ |
| • Weibullův             | $\Omega = \langle 0, \infty \rangle$ |
| • Logaritmicko-normální | $\Omega = \langle 0, \infty \rangle$ |

# **Testy dobré shody**

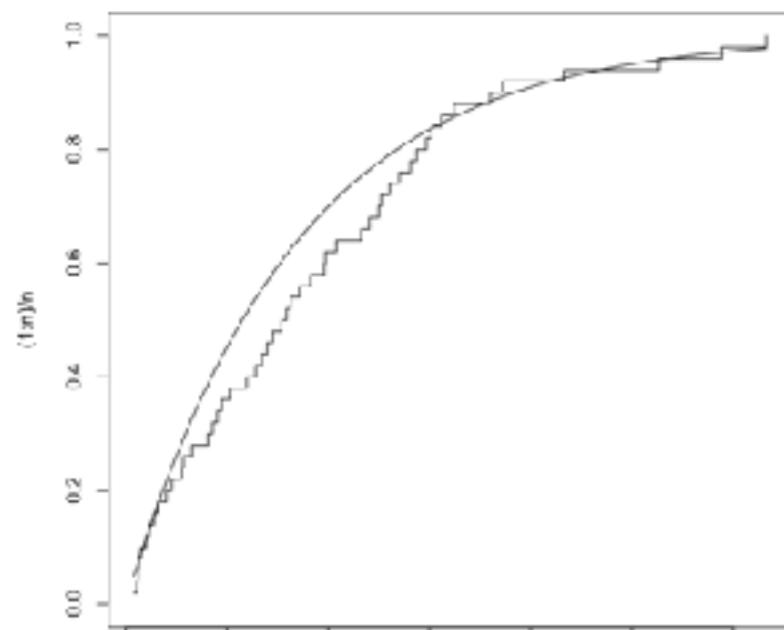
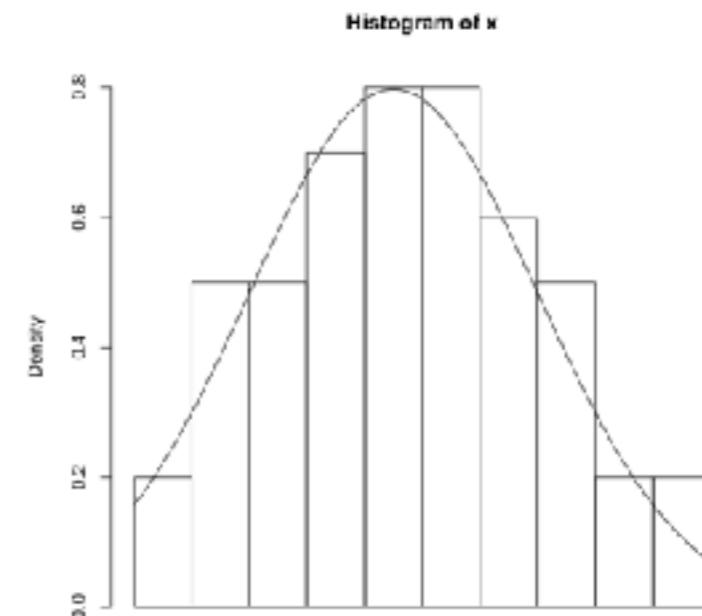
# Testy dobré shody



# Testy dobré shody



# Testy dobré shody



Jaká je shoda pozorovaného experimentu s teoretickým modelem?

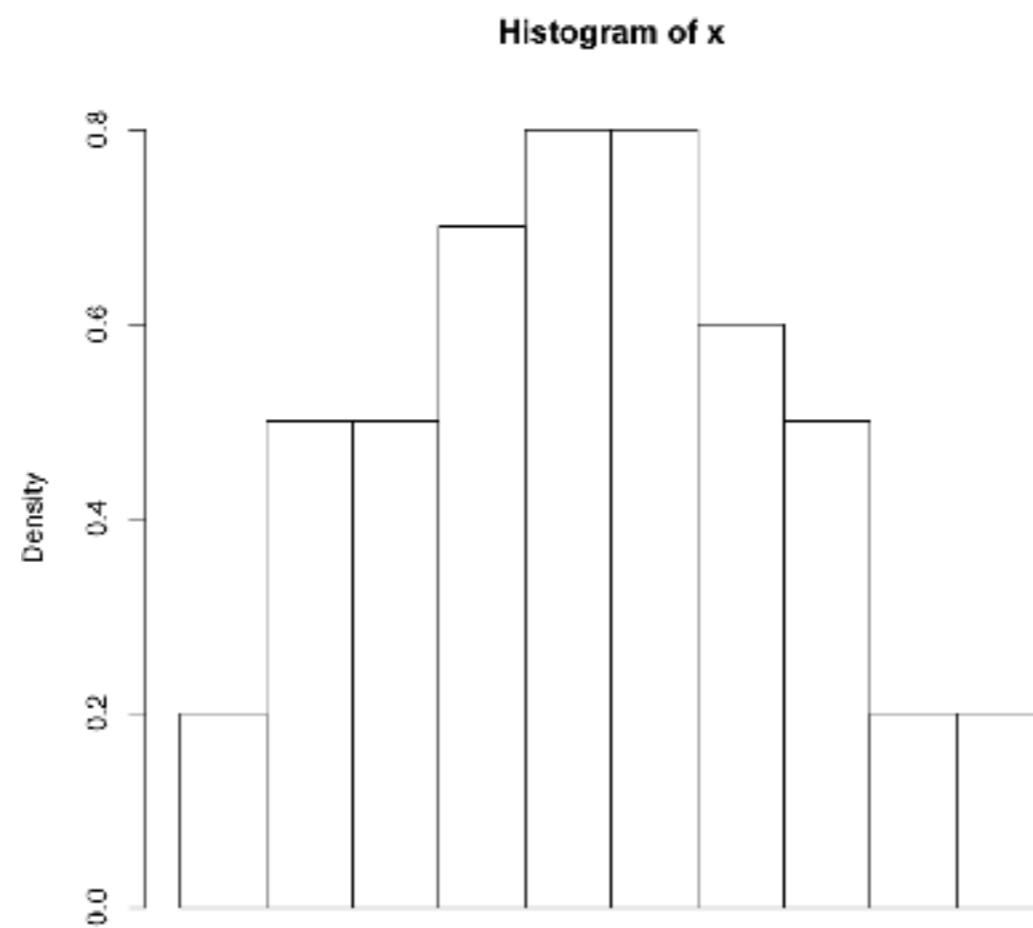
# Testy dobré shody

Co máme k dispozici?

# Testy dobré shody

Co máme k dispozici?

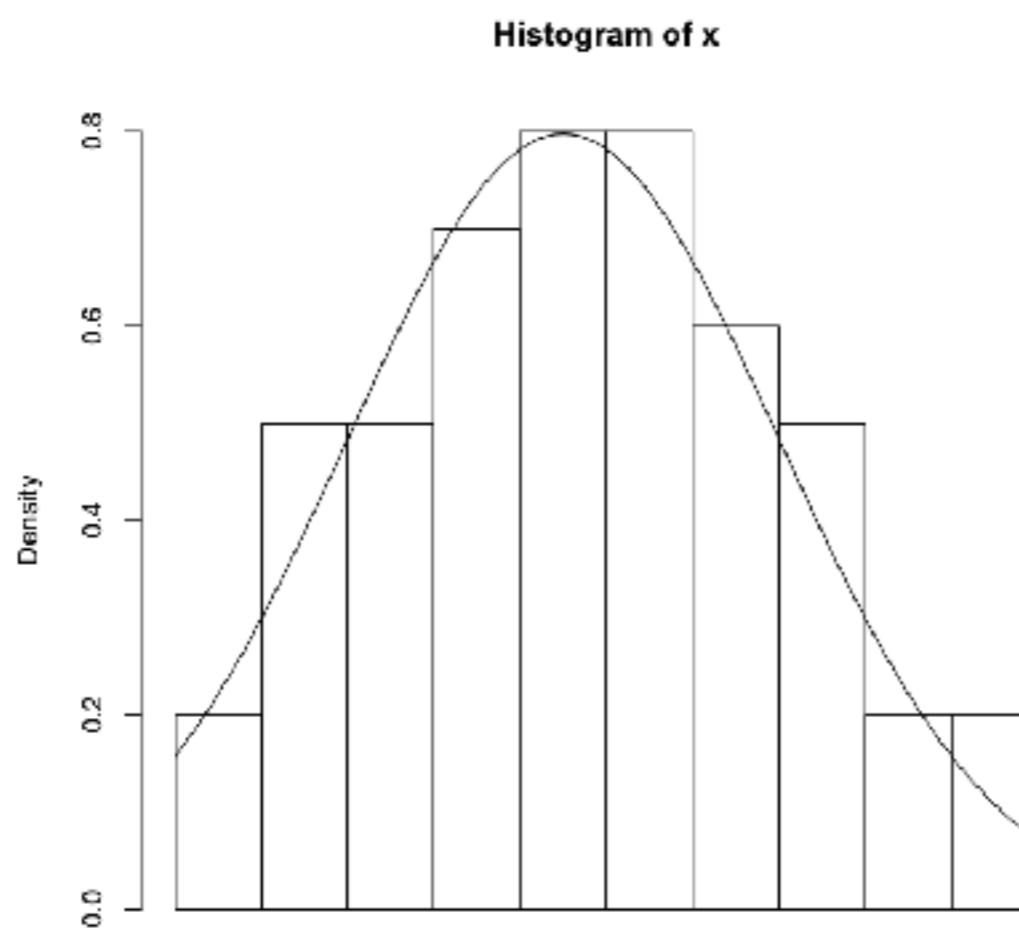
1) Pozorování výsledků experimentu (měření) = data



# Testy dobré shody

Co máme k dispozici?

- 1) Pozorování výsledků experimentu (měření) = data
- 2) Představu o hypotetickém (teoretickém) rozdělení pozorované veličiny



# **Testy dobré shody**

**Co s tím?**

# Testy dobré shody

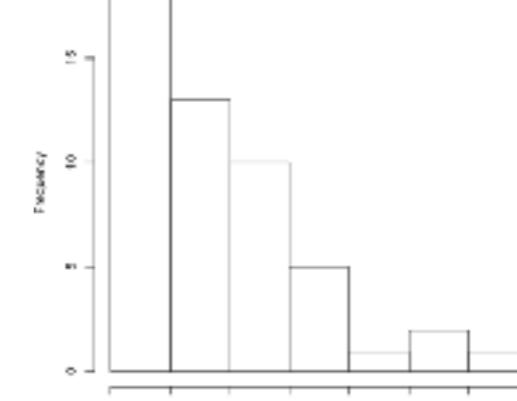
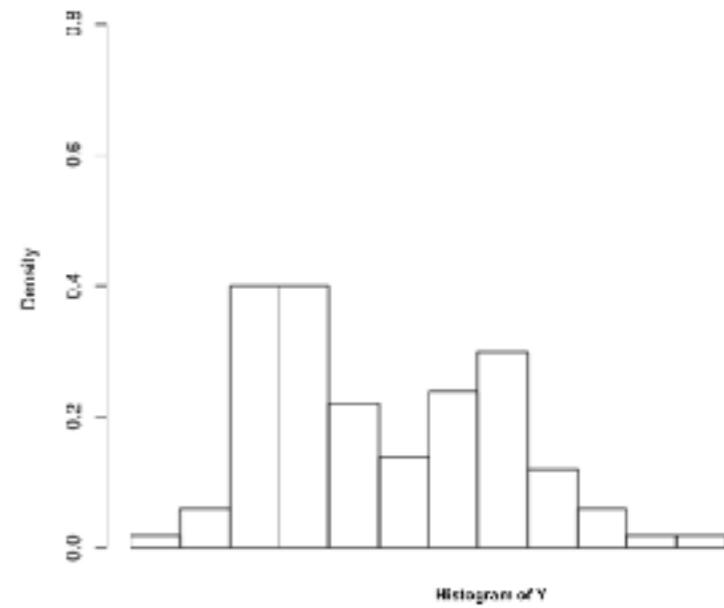
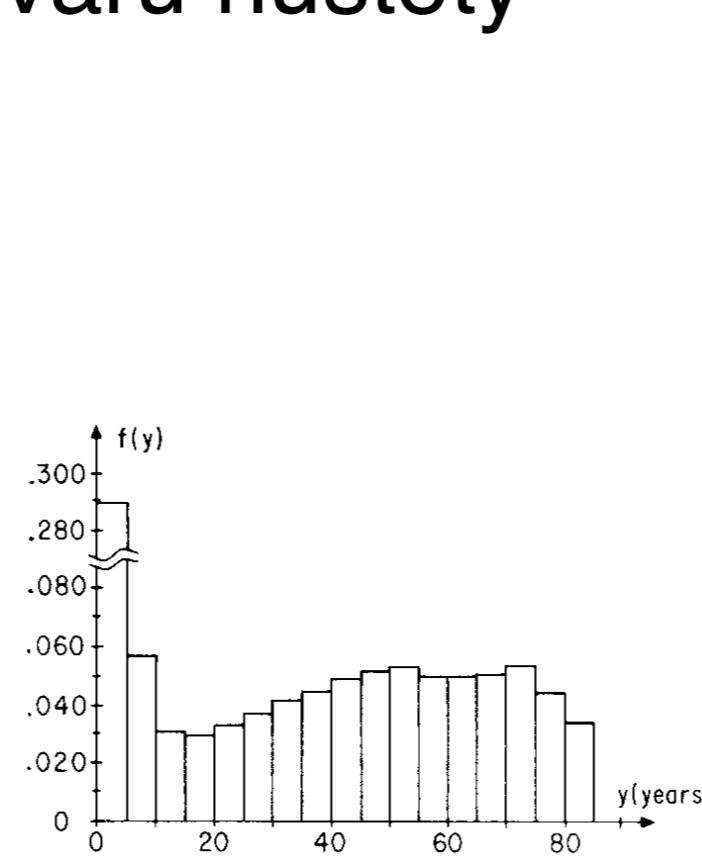
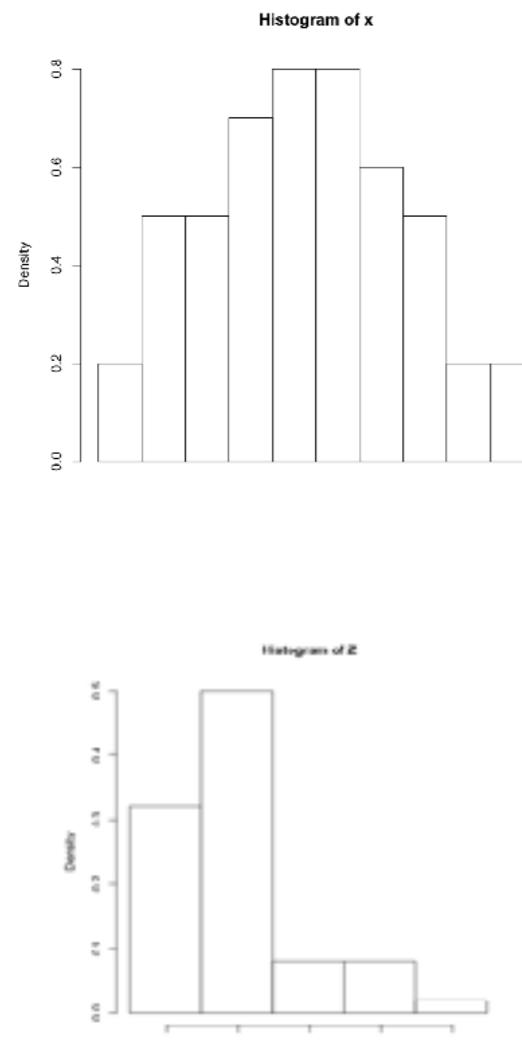
Co s tím?

- 1) Histogram - poskytuje předběžnou představu o tvaru hustoty

# Testy dobré shody

Co s tím?

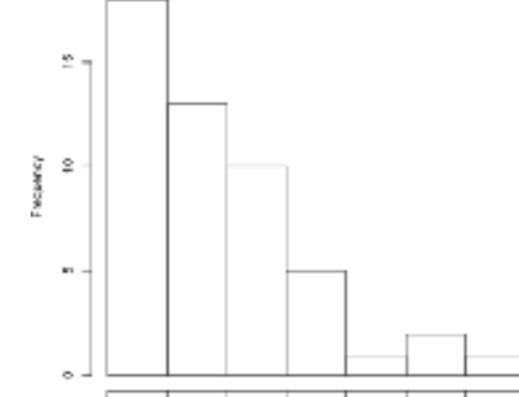
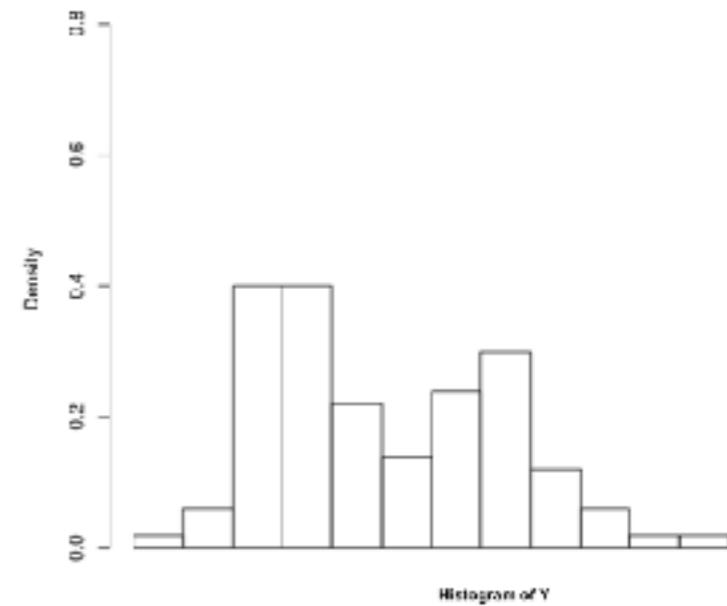
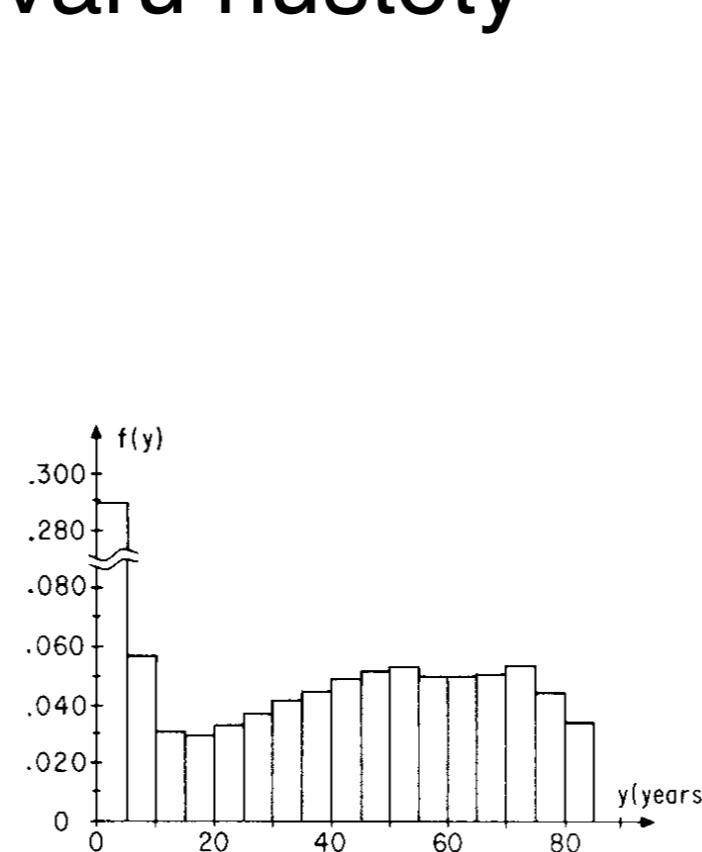
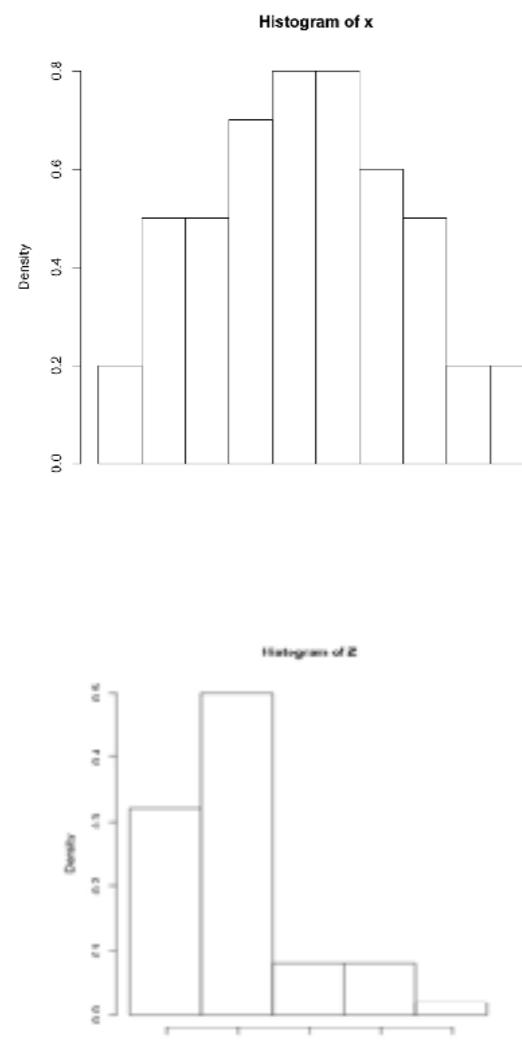
1) Histogram - poskytuje předběžnou představu o tvaru hustoty



# Testy dobré shody

Co s tím?

1) Histogram - poskytuje předběžnou představu o tvaru hustoty



Lze použít například Sturgessovo pravidlo pro volbu počtu tříd:  $k = 1 + \frac{10}{3} \log_{10} N$

# Testy dobré shody

Co s tím?

2) Empirická distribuční funkce

# Testy dobré shody

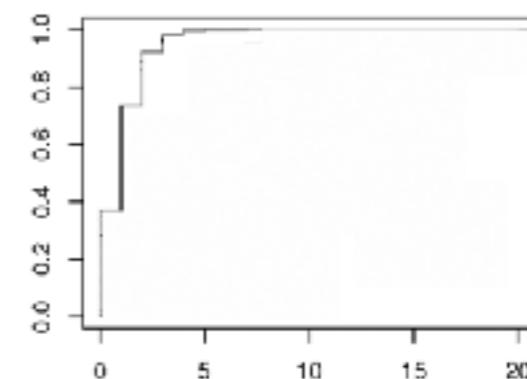
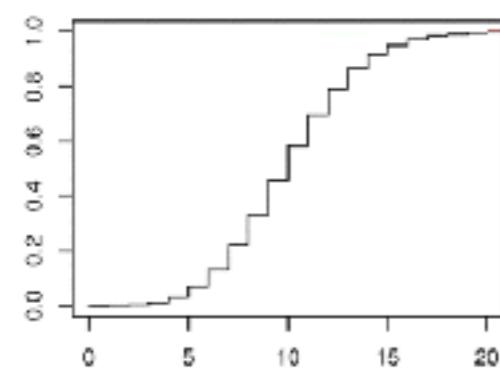
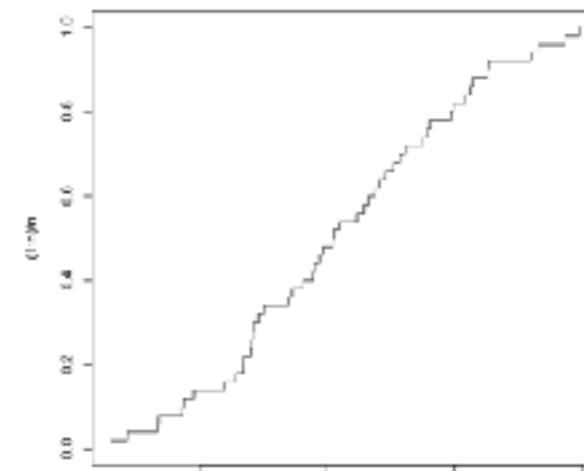
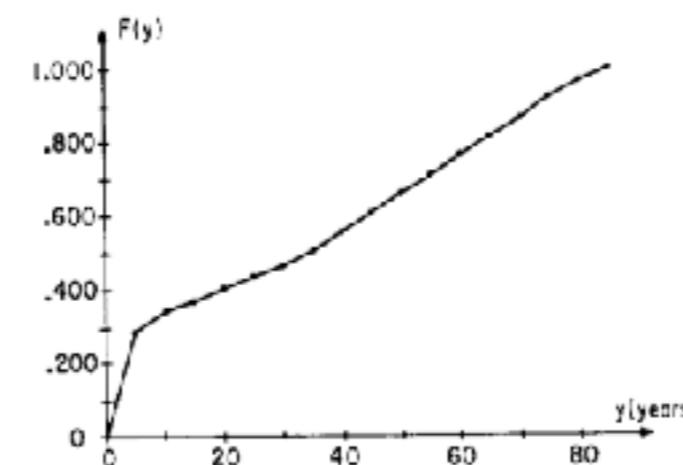
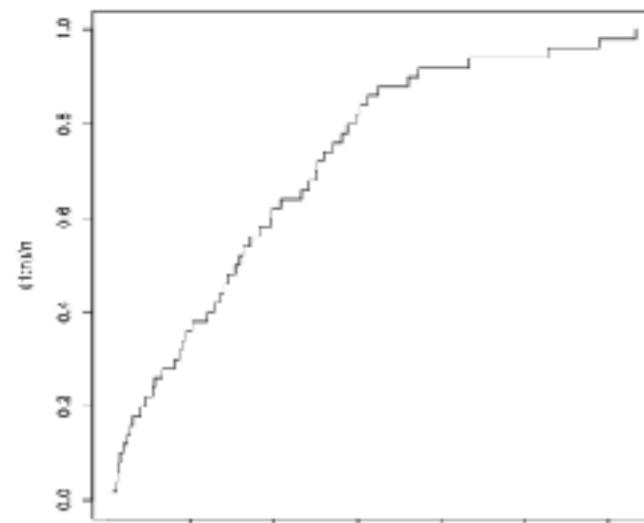
Co s tím?

2) Empirická distribuční funkce - poskytuje předběžnou  
představu o tvaru distribuční funkce

# Testy dobré shody

Co s tím?

2) Empirická distribuční funkce - poskytuje předběžnou představu o tvaru distribuční funkce



# Testy dobré shody

Co s tím?

3) Informaci o rozdělení nám poskytují i výběrové momenty:

# Testy dobré shody

Co s tím?

3) Informaci o rozdělení nám poskytují i výběrové momenty:

1. výběrový moment = aritmetický průměr: .....  
(bodový odhad střední hodnoty)

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

# Testy dobré shody

## Co s tím?

3) Informaci o rozdělení nám poskytují i výběrové momenty:

1. výběrový moment = aritmetický průměr: .....  
(bodový odhad střední hodnoty)

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

2. výběrový centrální moment = výběrový rozptyl .....

$$m_2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

# Testy dobré shody

## Co s tím?

3) Informaci o rozdělení nám poskytují i výběrové momenty:

1. výběrový moment = aritmetický průměr: .....  
(bodový odhad střední hodnoty)

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

2. výběrový centrální moment = výběrový rozptyl .....

$$m_2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

3. výběrový centrální moment .....  
(bodový odhad

$$m_3 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^3$$

koeficientu šikmosti:  $S_{kew} = \frac{m_3}{\sqrt{m_2^3}}$

# Testy dobré shody

## Co s tím?

3) Informaci o rozdělení nám poskytují i výběrové momenty:

1. výběrový moment = aritmetický průměr: .....  
(bodový odhad střední hodnoty)

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$$

2. výběrový centrální moment = výběrový rozptyl .....

$$m_2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2$$

3. výběrový centrální moment .....  
(bodový odhad  
koeficientu šikmosti:  $S_{kew} = \frac{m_3}{\sqrt{m_2^3}}$ )

$$m_3 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^3$$

4. výběrový centrální moment .....  
(bodový odhad  
koeficientu špičatosti:  $K_{urt} = \frac{m_4}{m_2^2} - 3$ )

$$m_4 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^4$$

# Testy dobré shody

Co dál?

1) Grafická analýza

# Testy dobré shody

Co dál?

1) Grafická analýza

- histogram, boxplot, empirická distribuční funkce

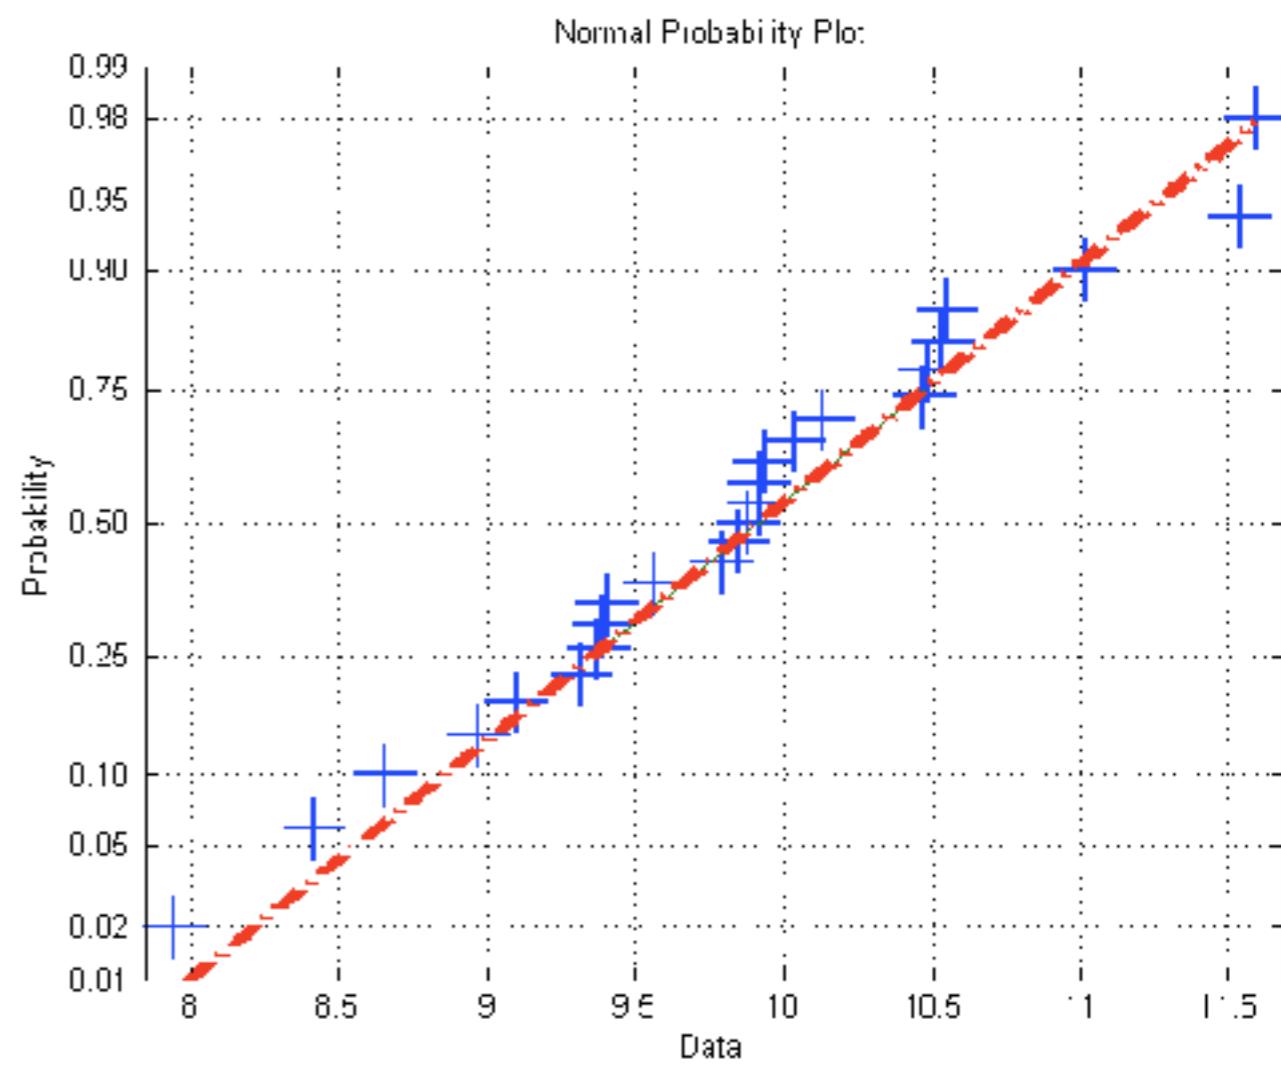
# Testy dobré shody

Co dál?

## 1) Grafická analýza

- histogram, boxplot, empirická distribuční funkce
- pravděpodobnostní papír
  - osa x: lineární
  - osa Y: transformované “pravděpodobnostní” měřítko

Zakresujeme dvojice  
 $(x_{(i)}, i/n)$



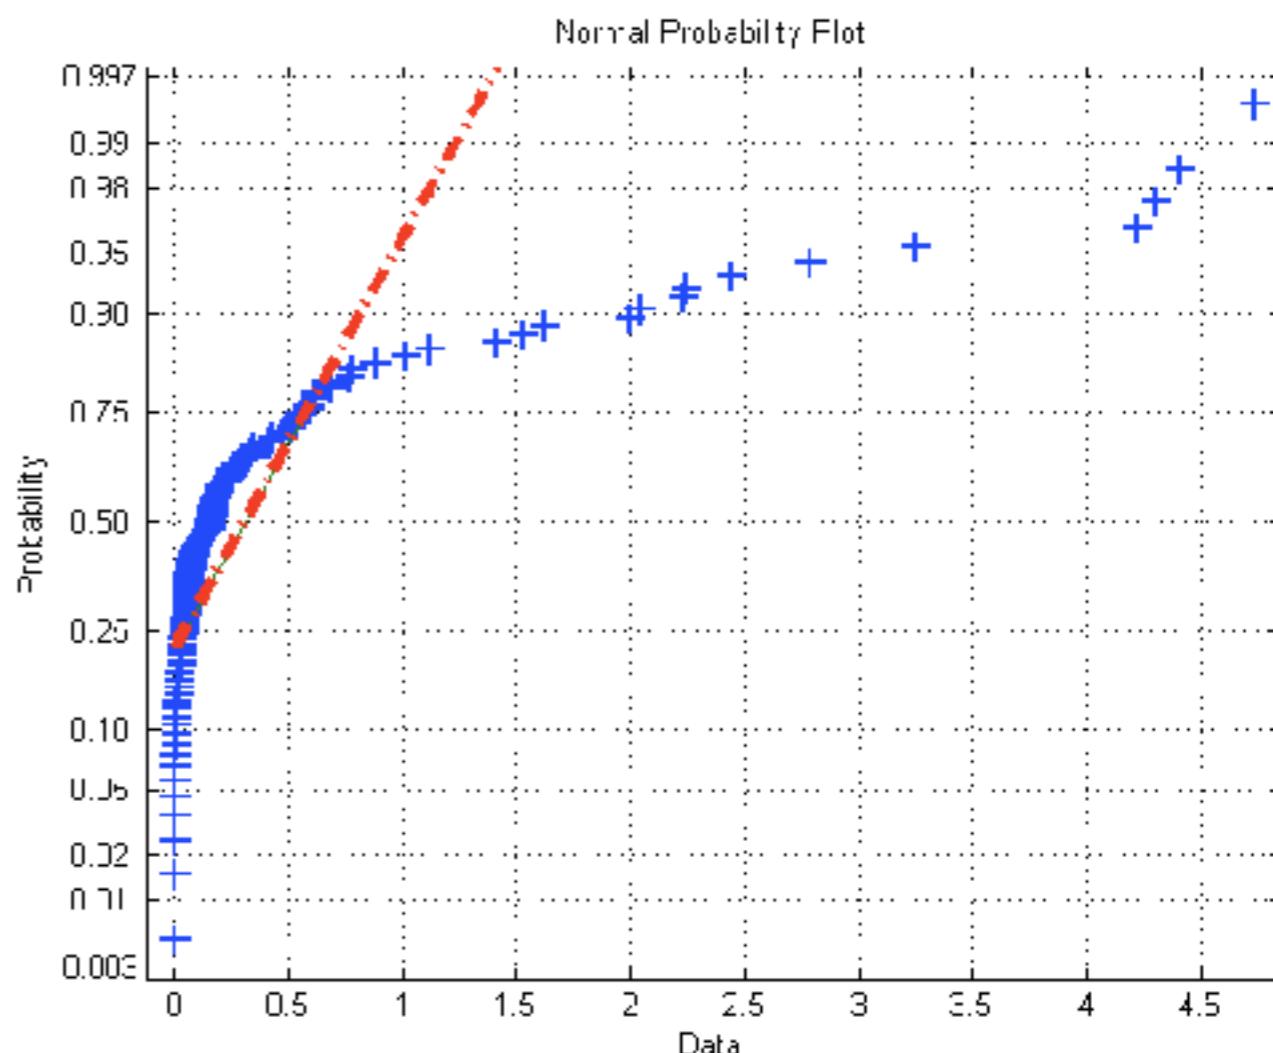
# Testy dobré shody

Co dál?

## 1) Grafická analýza

- histogram, boxplot, empirická distribuční funkce
- pravděpodobnostní papír
  - osa x: lineární
  - osa Y: transformované “pravděpodobnostní” měřítko

Zakresujeme dvojice  
 $(x_{(i)}, i/n)$



# Testy dobré shody

Co dál?

## 1) Grafická analýza

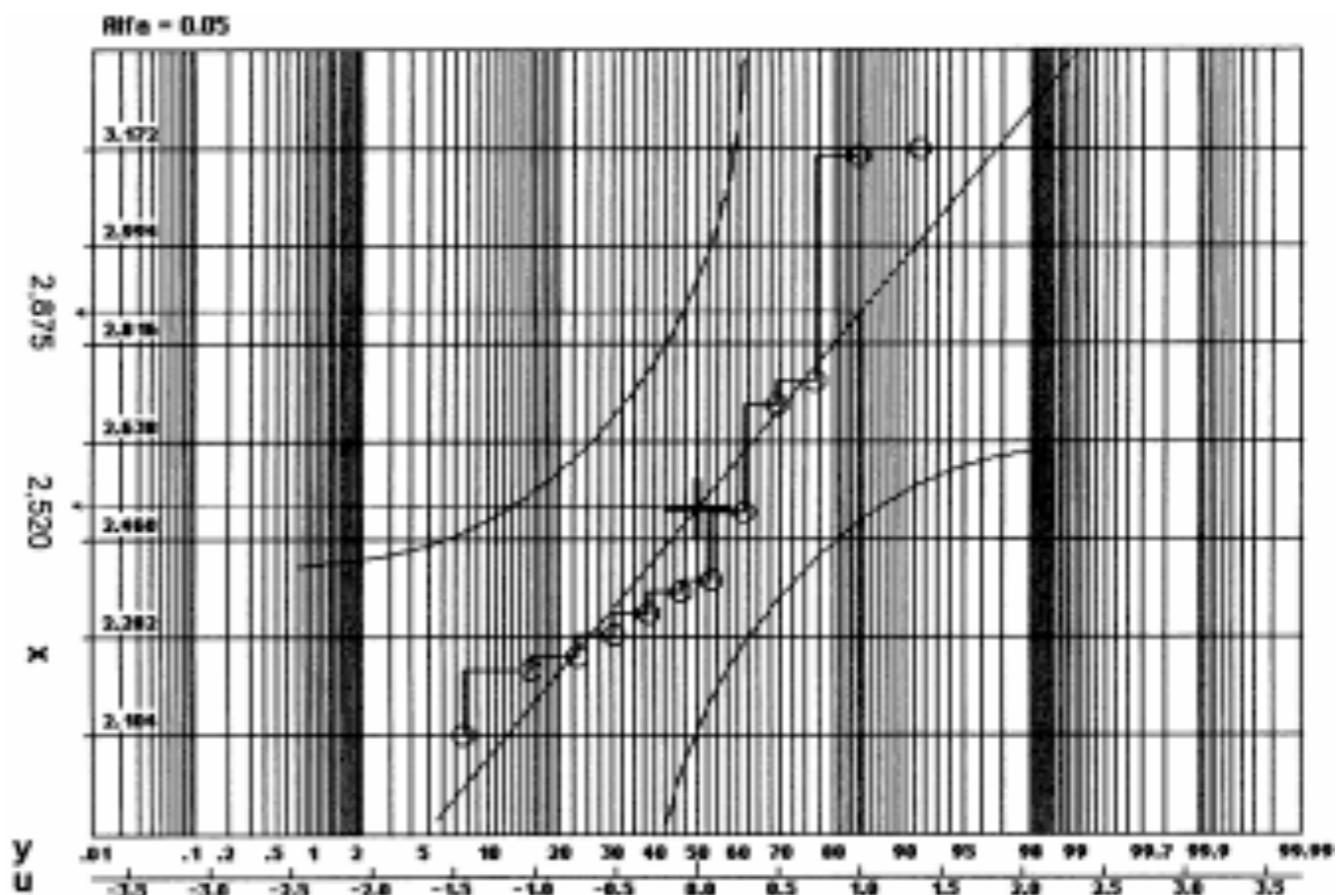
- histogram, boxplot, empirická distribuční funkce

- pravděpodobnostní papír

osa x: lineární

osa Y: transformované  
“pravděpodobnostní”  
měřítko

Zakreslujeme dvojice  
 $(x_{(i)}, i/n)$



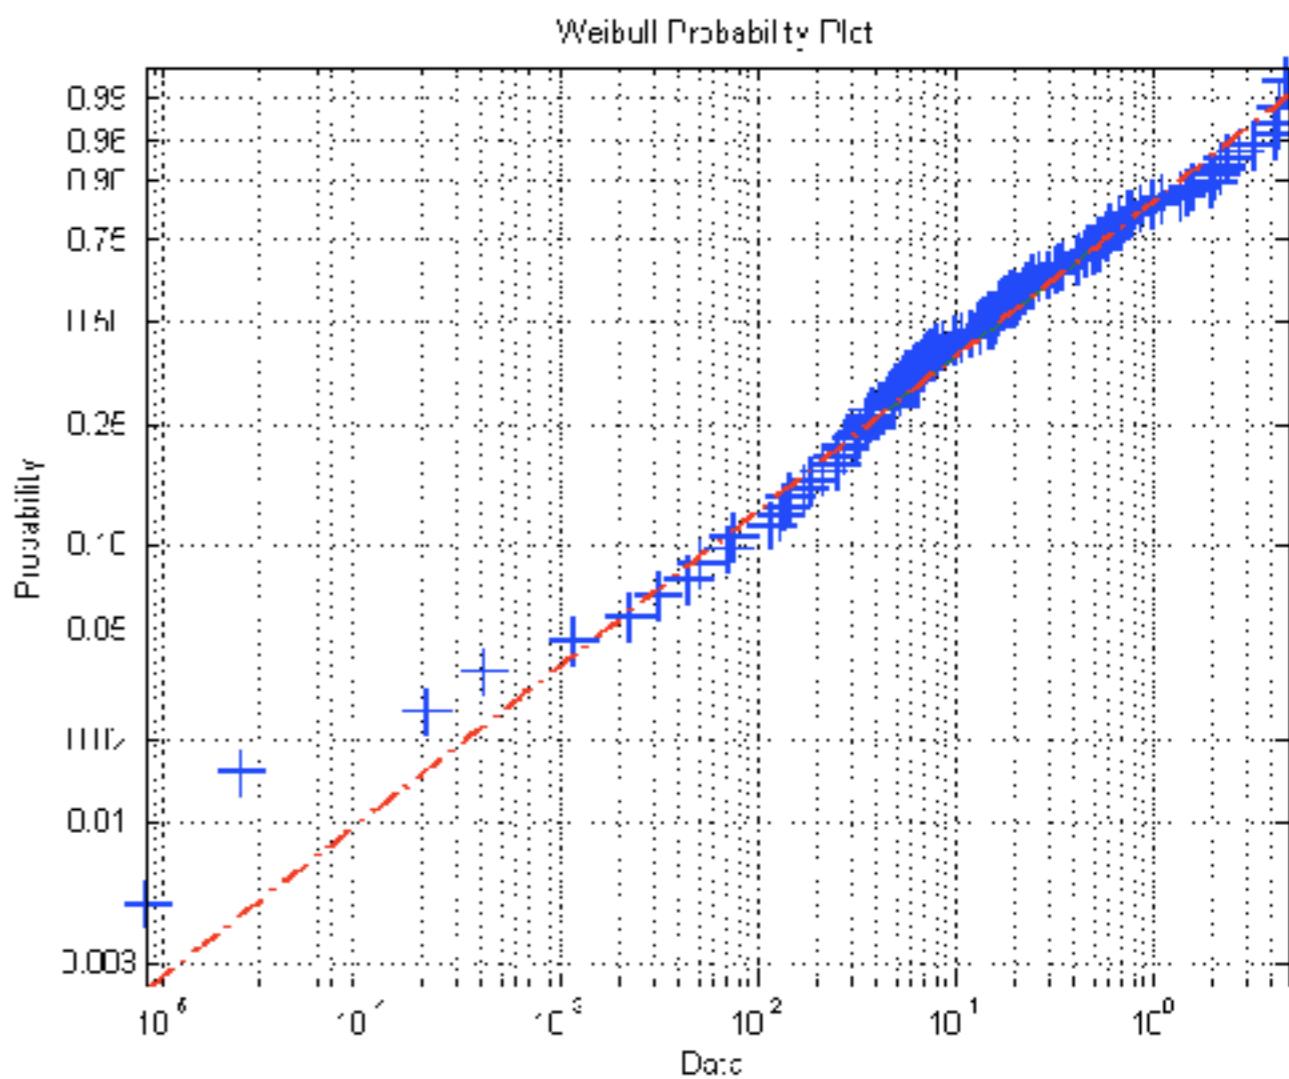
# Testy dobré shody

Co dál?

## 1) Grafická analýza

- histogram, boxplot, empirická distribuční funkce
- pravděpodobnostní papír
  - osa x: lineární
  - osa Y: transformované “pravděpodobnostní” měřítko

Zakresujeme dvojice  
 $(x_{(i)}, i/n)$



# Testy dobré shody

Co dál?

## 1) Grafická analýza

- histogram, boxplot, empirická distribuční funkce
- pravděpodobnostní papír
- Q-Q graf
  - osa x: měření
  - osa y: kvantily hypotetické d.f.

Zakreslujeme dvojice  
 $(x_{(i)}, F^{-1}(i/n))$

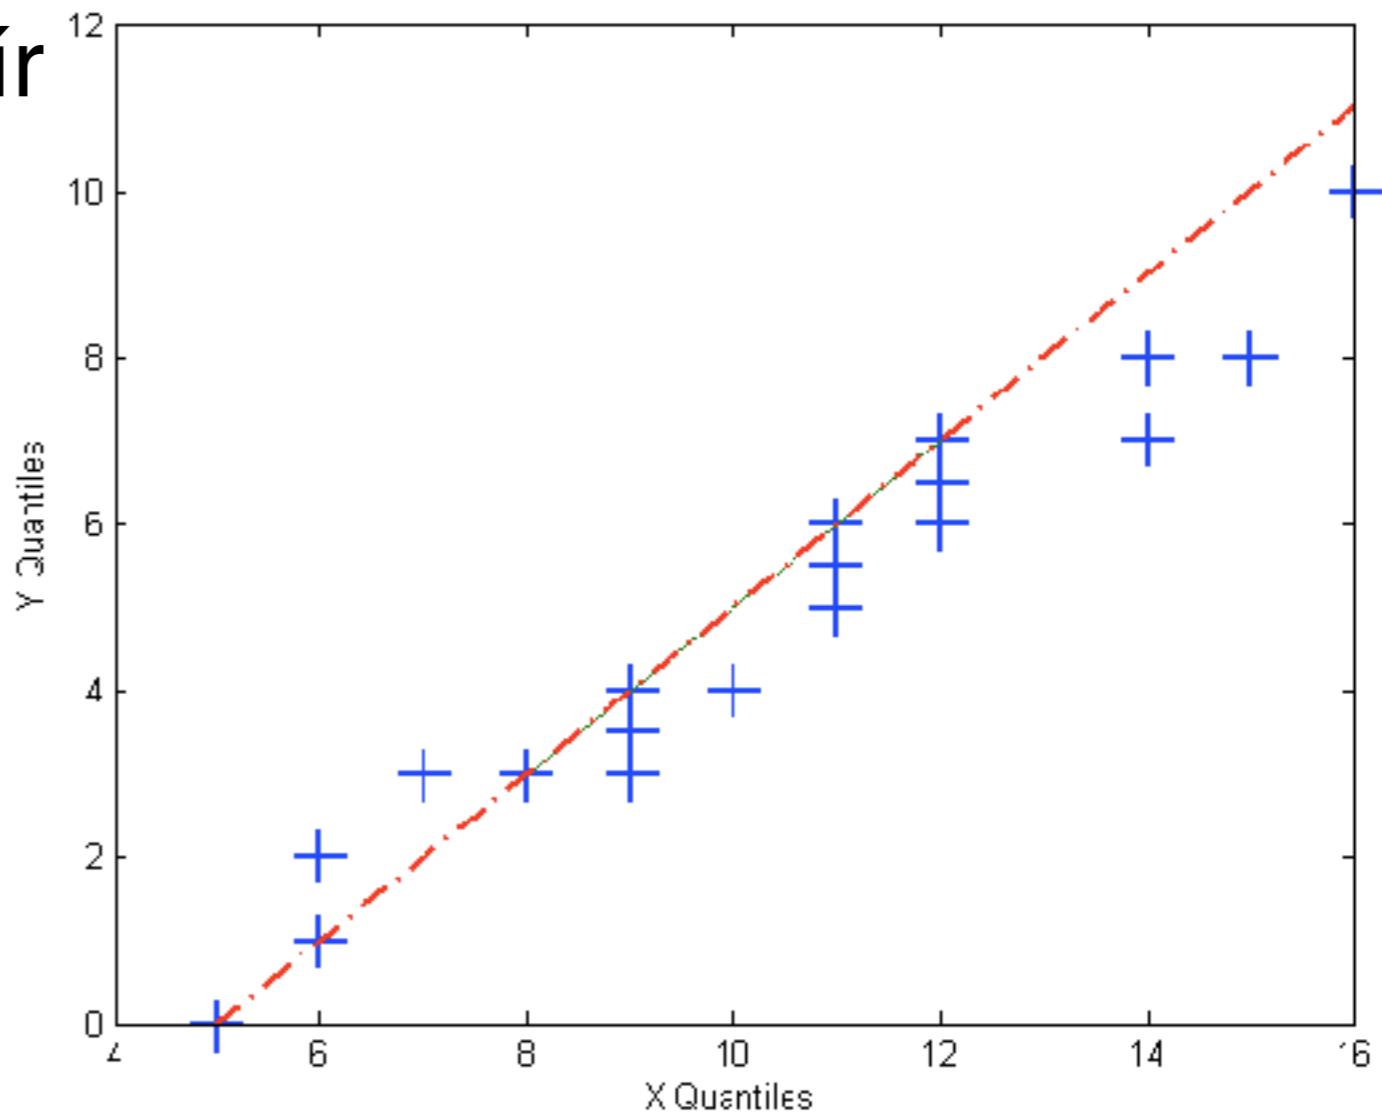
# Testy dobré shody

Co dál?

## 1) Grafická analýza

- histogram, boxplot, empirická distribuční funkce
- pravděpodobnostní papír
- Q-Q graf
  - osa x: měření
  - osa y: kvantily hypotetické d.f.

Zakreslujeme dvojice  
 $(x_{(i)}, F^{-1}(i/n))$



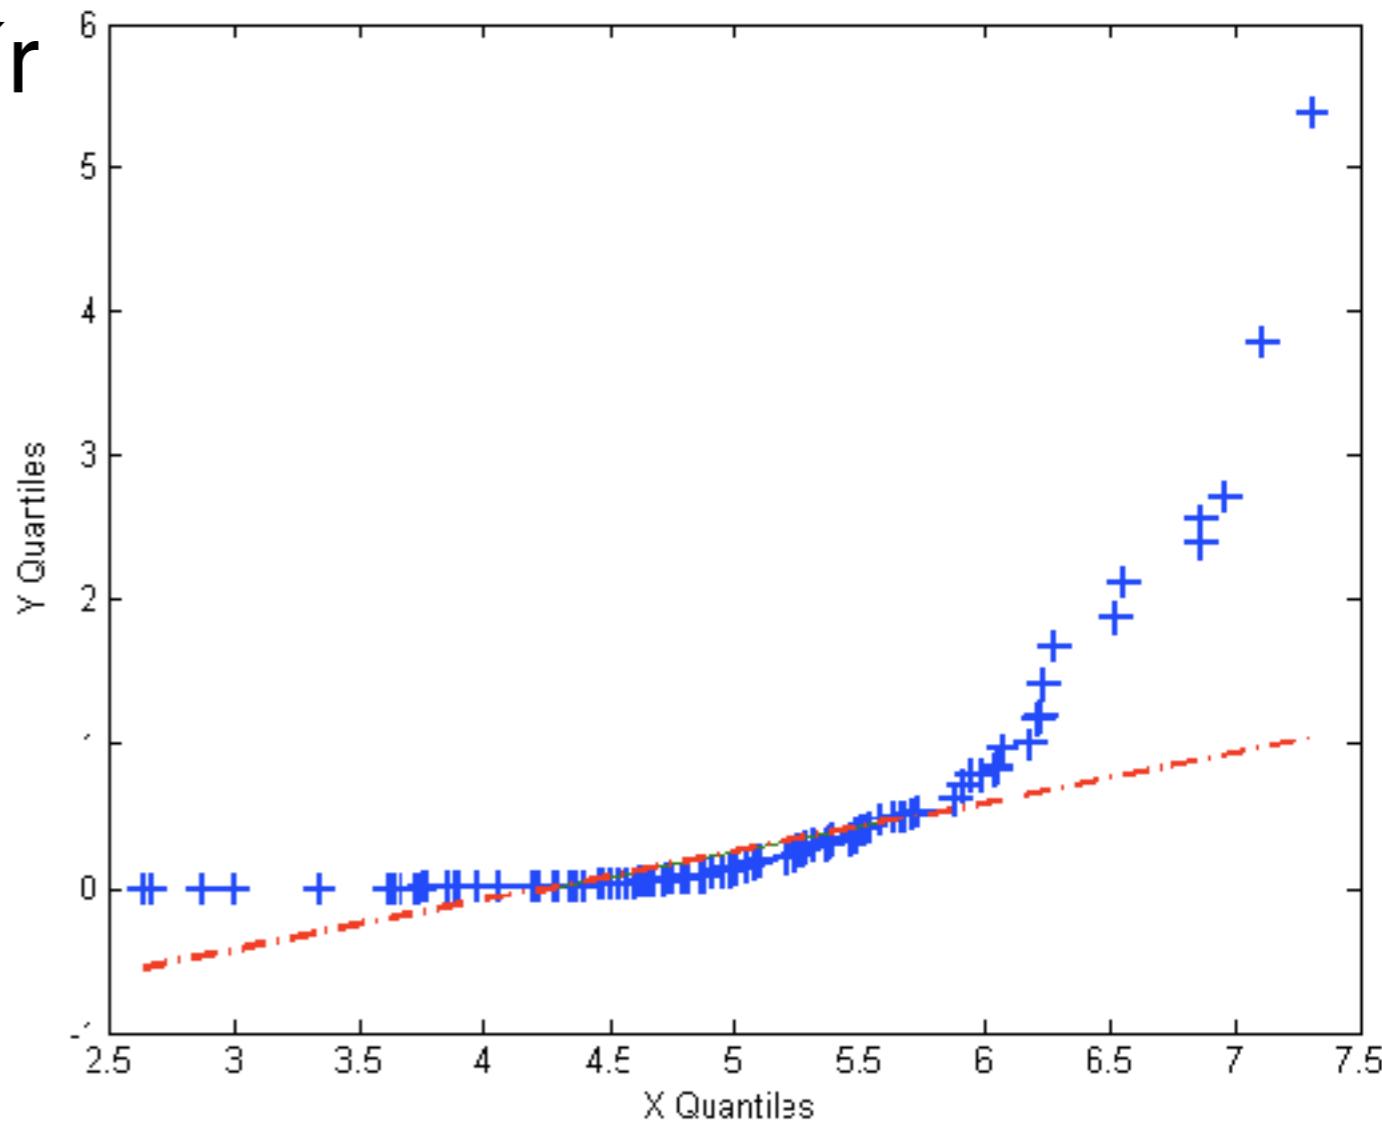
# Testy dobré shody

Co dál?

## 1) Grafická analýza

- histogram, boxplot, empirická distribuční funkce
- pravděpodobnostní papír
- Q-Q graf
  - osa x: měření
  - osa y: kvantily hypotetické d.f.

Zakreslujeme dvojice  
 $(x_{(i)}, F^{-1}(i/n))$



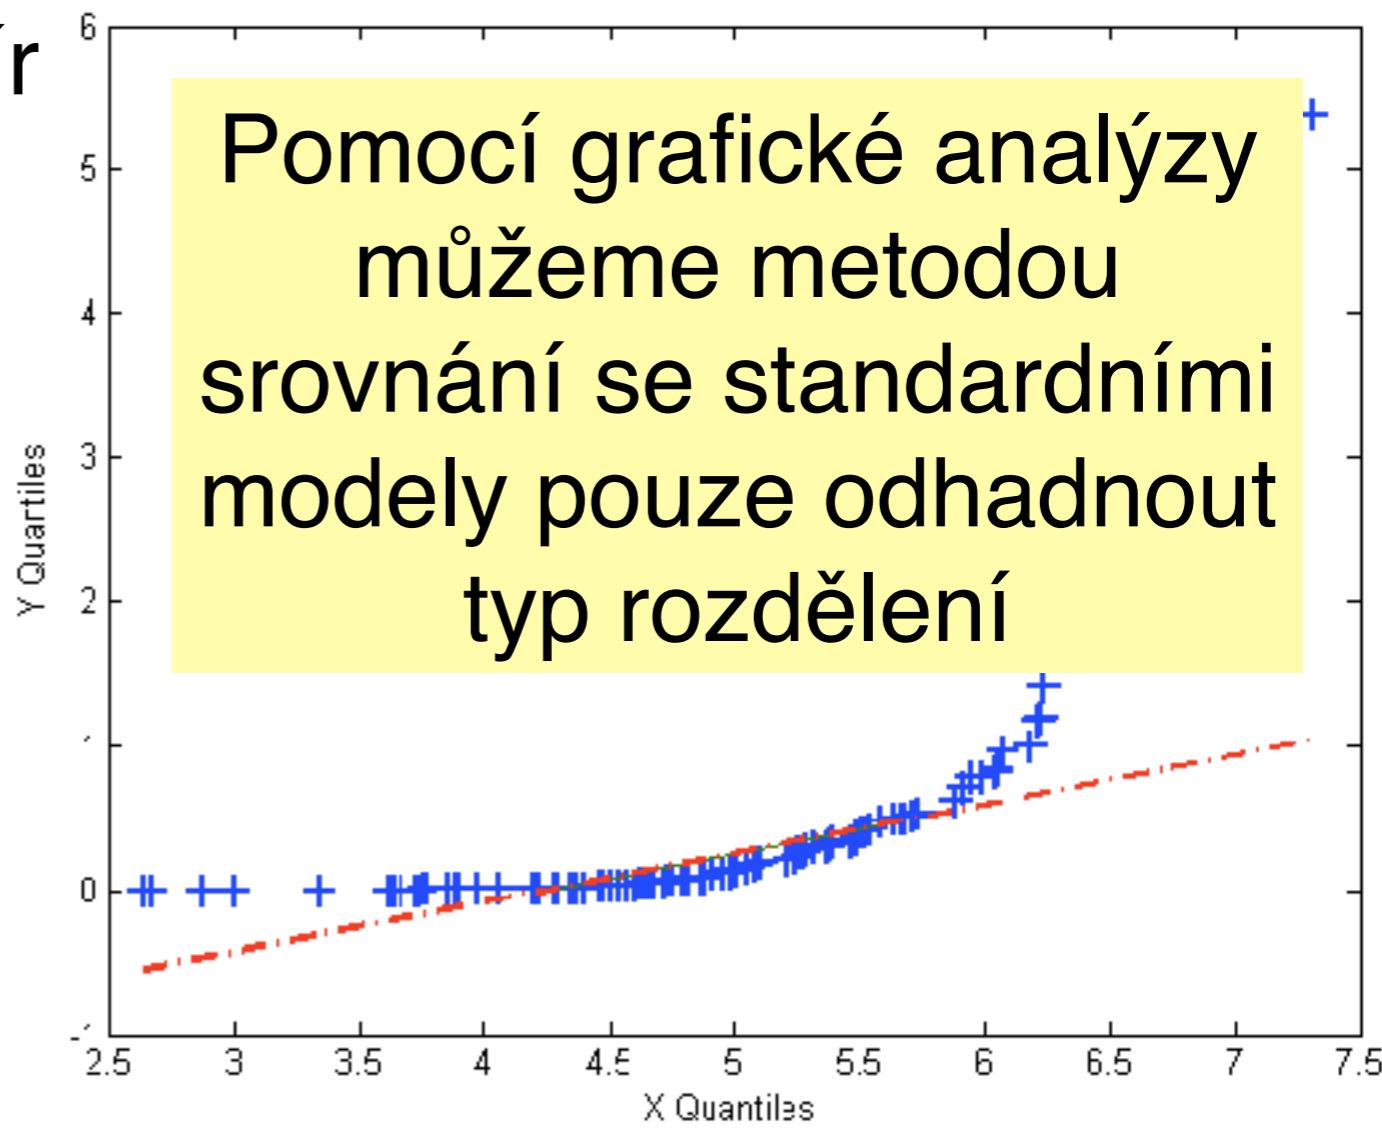
# Testy dobré shody

Co dál?

## 1) Grafická analýza

- histogram, boxplot, empirická distribuční funkce
- pravděpodobnostní papír
- Q-Q graf
  - osa x: měření
  - osa y: kvantily hypotetické d.f.

Zakreslujeme dvojice  
 $(x_{(i)}, F^{-1}(i/n))$



# Testy dobré shody

Co dál?

2) Kvantitativní testy hypotézy o daném typu rozdělení

# Testy dobré shody

Co dál?

## 2) Kvantitativní testy hypotézy o daném typu rozdělení

nulová hypotéza :  $H_0 : F(x) = F_0(x)$

alternativní hypotéza:  $H_A : F(x) \neq F_0(x)$

testová statistika :  $T(X_1, X_2, \dots, X_n)$

hladina významnosti:  $\alpha$

# Testy dobré shody

## Co dál?

### 2) Kvantitativní testy hypotézy o daném typu rozdělení

nulová hypotéza :  $H_0 : F(x) = F_0(x)$

alternativní hypotéza:  $H_A : F(x) \neq F_0(x)$

testová statistika :  $T(X_1, X_2, \dots, X_n)$

hladina významnosti:  $\alpha$

chyba 1. druhu: zamítneme hypotézu, která platí

chyba 2. druhu: nezamítneme hypotézu, která neplatí

hladina významnosti testu: pravděpodobnost chyby 1. druhu

síla testu: pravděpodobnost zamítnutí hypotézy, když neplatí

p-hodnota: nejménší hladina významnosti, při které bychom ještě zamítli nulovou hypotézu.

# Testy dobré shody

Co dál?

2) Kvantitativní testy hypotézy o daném typu rozdělení

# Testy dobré shody

Co dál?

2) Kvantitativní testy hypotézy o daném typu rozdělení

Chí-kvadrát test dobré shody

# Testy dobré shody

Co dál?

2) Kvantitativní testy hypotézy o daném typu rozdělení

Chí-kvadrát test dobré shody

Kolmogorov-Smirnovův test

# Testy dobré shody

Co dál?

2) Kvantitativní testy hypotézy o daném typu rozdělení

Chí-kvadrát test dobré shody

Kolmogorov-Smirnovův test

Testy normality (Shapiro-Wilkův test, testy na základě šiknosti a špičatosti, Lilieforsův, Anderson-Darlingův test)

# Testy dobré shody

Co dál?

2) Kvantitativní testy hypotézy o daném typu rozdělení

Chí-kvadrát test dobré shody

Kolmogorov-Smirnovův test

Testy normality (Shapiro-Wilkův test, testy na základě šiknosti a špičatosti, Lilieforsův, Anderson-Darlingův test)

Kvantitativní statistické testy nám poskytnou objektivní míru shody dat s teoretickým modelem

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění:

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění:

- i) provedeme roztrídění naměřených hodnot do  $k$  tříd

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění:

- i) provedeme roztrídění naměřených hodnot do  $k$  tříd
- ii) napočítáme empirické četnosti  $n_1, n_2, \dots, n_k$

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění:

- i) provedeme roztrídění naměřených hodnot do  $k$  tříd
- ii) napočítáme empirické četnosti  $n_1, n_2, \dots, n_k$
- iii) napočítáme pravděpodobnosti tříd  $p_1, p_2, \dots, p_k$  při hypotetickém rozdělení (kde  $p_j = F(x_{j+1}) - F(x_j)$  )

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění:

- i) provedeme roztrídění naměřených hodnot do  $k$  tříd
- ii) napočítáme empirické četnosti  $n_1, n_2, \dots, n_k$
- iii) napočítáme pravděpodobnosti tříd  $p_1, p_2, \dots, p_k$  při hypotetickém rozdělení (kde  $p_j = F(x_{j+1}) - F(x_j)$ )
- iv) napočítáme teoretické četnosti  $np_1, np_2, \dots, np_k$

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění:

- i) provedeme roztrídění naměřených hodnot do  $k$  tříd
- ii) napočítáme empirické četnosti  $n_1, n_2, \dots, n_k$
- iii) napočítáme pravděpodobnosti tříd  $p_1, p_2, \dots, p_k$  při hypotetickém rozdělení (kde  $p_j = F(x_{j+1}) - F(x_j)$ )
- iv) napočítáme teoretické četnosti  $np_1, np_2, \dots, np_k$
- v) pokud pro všechna  $j = 1, 2, \dots, k$  platí  $np_j > 5$ , spočítáme hodnotu testové statistiky

$$\chi^2 = \sum_{j=1}^k \frac{(n_j - np_j)^2}{np_j}$$

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění:

- i) provedeme roztrídění naměřených hodnot do  $k$  tříd
- ii) napočítáme empirické četnosti  $n_1, n_2, \dots, n_k$
- iii) napočítáme pravděpodobnosti tříd  $p_1, p_2, \dots, p_k$  při hypotetickém rozdělení (kde  $p_j = F(x_{j+1}) - F(x_j)$ )
- iv) napočítáme teoretické četnosti  $np_1, np_2, \dots, np_k$
- v) pokud pro všechna  $j = 1, 2, \dots, k$  platí  $np_j > 5$ , spočítáme hodnotu testové statistiky

$$\chi^2 = \sum_{j=1}^k \frac{(n_j - np_j)^2}{np_j}$$

- vi) neplatí-li podmínka v bodě (v), provedeme úpravu třídních intervalů (nemusejí být stejně velké)

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění pomocí testové statistiky

$$\chi^2 = \sum_{j=1}^k \frac{(n_j - np_j)^2}{np_j}$$

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění pomocí testové statistiky

$$\chi^2 = \sum_{j=1}^k \frac{(n_j - np_j)^2}{np_j}$$

vii) známe-li parametry hypotetického rozdělení předem, bude mít testová statistika rozdělení  $\chi^2(k - 1)$  a nulovou hypotézu zamítneme, pokud bude  $\chi^2 \geq \chi^2_{1-\alpha}(k - 1)$ , kde  $\chi^2_{1-\alpha}(k - 1)$  je  $(1 - \alpha)$ -kvantil chí-kvadrát rozdělení o  $(k-1)$  stupních volnosti.

# Chí-kvadrát test dobré shody

Test srovnává empirické a teoretické četnosti při zadaném třídění pomocí testové statistiky

$$\chi^2 = \sum_{j=1}^k \frac{(n_j - np_j)^2}{np_j}$$

- vii) známe-li parametry hypotetického rozdělení předem, bude mít testová statistika rozdělení  $\chi^2(k - 1)$  a nulovou hypotézu zamítneme, pokud bude  $\chi^2 \geq \chi^2_{1-\alpha}(k - 1)$ , kde  $\chi^2_{1-\alpha}(k - 1)$  je  $(1 - \alpha)$ -kvantil chí-kvadrát rozdělení o  $(k-1)$  stupních volnosti.
- viii) pokud neznámé parametry hypotetického rozdělení odhadujeme z naměřených dat, bude mít testová statistika chí-kvadrát rozdělení o  $(k-r-1)$  stupních volnosti, kde  $r$  je počet odhadovaných parametrů. Nulovou hypotézu v tomto případě zamítneme, pokud bude  $\chi^2 \geq \chi^2_{1-\alpha}(k - r - 1)$

# Kolmogorov-Smirnovův test dobré shody

Test srovnává empirickou a teoretickou distribuční funkci pomocí maximálního rozdílu hodnot.

# Kolmogorov-Smirnovův test dobré shody

Test srovnává empirickou a teoretickou distribuční funkci pomocí maximálního rozdílu hodnot.

- i) seřadíme  $n$  naměřených hodnot podle velikosti od nejmenší do největší

# Kolmogorov-Smirnovův test dobré shody

Test srovnává empirickou a teoretickou distribuční funkci pomocí maximálního rozdílu hodnot.

- i) seřadíme  $n$  naměřených hodnot podle velikosti od nejmenší do největší
- ii) pro každou hodnotu  $x_{(i)}$  spočteme rozdíly

$$\left| F_0(x_{(i)}) - \frac{i}{n} \right|, \quad \left| F_0(x_{(i)}) - \frac{i-1}{n} \right|$$

# Kolmogorov-Smirnovův test dobré shody

Test srovnává empirickou a teoretickou distribuční funkci pomocí maximálního rozdílu hodnot.

- i) seřadíme  $n$  naměřených hodnot podle velikosti od nejmenší do největší
- ii) pro každou hodnotu  $x_{(i)}$  spočteme rozdíly

$$\left| F_0(x_{(i)}) - \frac{i}{n} \right|, \quad \left| F_0(x_{(i)}) - \frac{i-1}{n} \right|$$

- iii) největší z těchto rozdílů je hodnota testové statistiky  $D(n)$

# Kolmogorov-Smirnovův test dobré shody

Test srovnává empirickou a teoretickou distribuční funkci pomocí maximálního rozdílu hodnot.

- i) seřadíme  $n$  naměřených hodnot podle velikosti od nejmenší do největší
- ii) pro každou hodnotu  $x_{(i)}$  spočteme rozdíly

$$\left| F_0(x_{(i)}) - \frac{i}{n} \right|, \quad \left| F_0(x_{(i)}) - \frac{i-1}{n} \right|$$

- iii) největší z těchto rozdílů je hodnota testové statistiky  $D(n)$
- iv) pokud je hypotetické rozdělení známé včetně parametrů, použijeme krok (v). Jinak musí použít některou z modifikací K-S testu (Liliefors, Anderson-Darling)

# Kolmogorov-Smirnovův test dobré shody

Test srovnává empirickou a teoretickou distribuční funkci pomocí maximálního rozdílu hodnot.

- i) seřadíme  $n$  naměřených hodnot podle velikosti od nejmenší do největší
- ii) pro každou hodnotu  $x_{(i)}$  spočteme rozdíly

$$\left| F_0(x_{(i)}) - \frac{i}{n} \right|, \quad \left| F_0(x_{(i)}) - \frac{i-1}{n} \right|$$

- iii) největší z těchto rozdílů je hodnota testové statistiky  $D(n)$
- iv) pokud je hypotetické rozdělení známé včetně parametrů, použijeme krok (v). Jinak musíme použít některou z modifikací K-S testu (Liliefors, Anderson-Darling)
- v) pro malá  $n$  tuto hodnotu porovnáme s tabulkovou kritickou hodnotou  $d_{1-\alpha}(n)$  pro K-S-test. Pro velká  $n$  můžeme použít approximaci  $d_{1-\alpha}(n) = \sqrt{(1/2n) \ln(2/\alpha)}$

# Kolmogorov-Smirnovův test dobré shody

Test srovnává empirickou a teoretickou distribuční funkci pomocí maximálního rozdílu hodnot.

- i) seřadíme  $n$  naměřených hodnot podle velikosti od nejmenší do největší
- ii) pro každou hodnotu  $x_{(i)}$  spočteme rozdíly

$$\left| F_0(x_{(i)}) - \frac{i}{n} \right|, \quad \left| F_0(x_{(i)}) - \frac{i-1}{n} \right|$$

- iii) největší z těchto rozdílů je hodnota testové statistiky  $D(n)$
- iv) pokud je hypotetické rozdělení známé včetně parametrů, použijeme krok (v). Jinak musíme použít některou z modifikací K-S testu (Liliefors, Anderson-Darling)
- v) pro malá  $n$  tuto hodnotu porovnáme s tabulkovou kritickou hodnotou  $d_{1-\alpha}(n)$  pro K-S-test. Pro velká  $n$  můžeme použít approximaci  $d_{1-\alpha}(n) = \sqrt{(1/2n) \ln(2/\alpha)}$

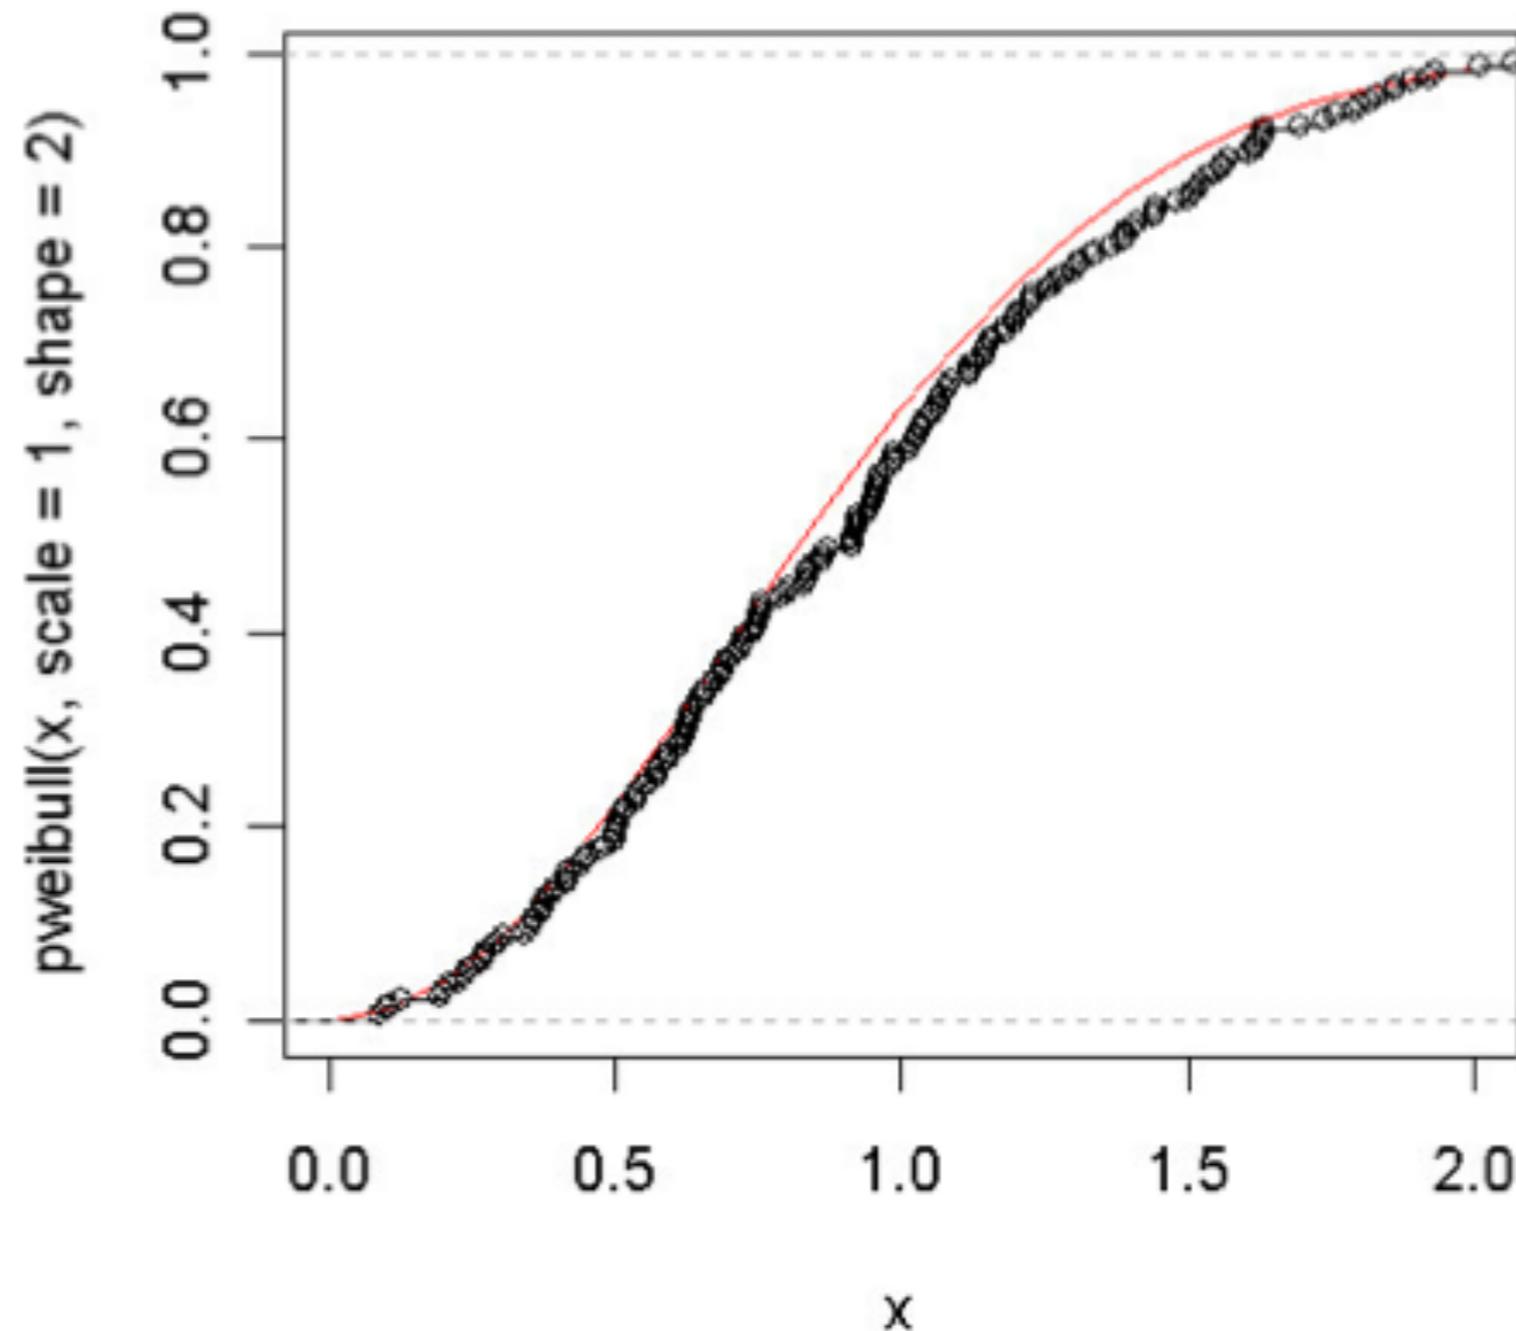
Pokud je  $D(n) \geq d_{1-\alpha}(n)$ , nulovou hypotézu zamítáme.

# Kolmogorov-Smirnovův test dobré shody

```
> x<-seq(0,2,0.1)
> plot(x,pweibull(x,scale=1,shape=2),type="l",col="red")
> plot(ecdf(x.wei),add=TRUE)
```

# Kolmogorov-Smirnovův test dobré shody

```
> x<-seq(0,2,0.1)
> plot(x,pweibull(x,scale=1,shape=2),type="l",col="red")
> plot(ecdf(x.wei),add=TRUE)
```



# Kolmogorov-Smirnovův test dobré shody

```
> ks.test(x.wei, "pweibull", shape=2, scale=1)

One-sample Kolmogorov-Smirnov test

data: x.wei D = 0.0623, p-value = 0.4198
alternative hypothesis: two.sided
```

# Testy normality

**Testy na základě šikmosti a špičatosti**

# Testy normality

## Testy na základě šikmosti a špičatosti

Za předpokladu, že výběr pochází z normálního rozdělení,  
platí pro index šikmosti:

$$E(S_{kew}^{norm}) = 0$$

$$Var(S_{kew}^{norm}) = \frac{6(n - 2)}{(n + 1)(n + 3)}$$

# Testy normality

## Testy na základě šikmosti a špičatosti

Za předpokladu, že výběr pochází z normálního rozdělení, platí pro index šikmosti:

$$E(S_{kew}^{norm}) = 0$$

$$Var(S_{kew}^{norm}) = \frac{6(n-2)}{(n+1)(n+3)}$$

a pro index špičatosti:

$$E(K_{urt}^{norm}) = -\frac{6}{n+1}$$

$$Var(K_{urt}^{norm}) = \frac{24n(n-2)(n-3)}{(n+1)^2(n+3)(n+5)}$$

# Testy normality

## Testy na základě šiknosti a špičatosti

Za předpokladu, že výběr pochází z normálního rozdělení, platí pro index šiknosti:

$$E(S_{kew}^{norm}) = 0$$

$$Var(S_{kew}^{norm}) = \frac{6(n-2)}{(n+1)(n+3)}$$

a pro index špičatosti:

$$E(K_{urt}^{norm}) = -\frac{6}{n+1}$$

$$Var(K_{urt}^{norm}) = \frac{24n(n-2)(n-3)}{(n+1)^2(n+3)(n+5)}$$

Máme-li dostatečný počet pozorování (řádově stovky), mají statistiky

$$T_3 = \frac{S_{kew}^{norm}}{\sqrt{Var(S_{kew}^{norm})}} \quad T_4 = \frac{K_{urt}^{norm} - E(K_{urt}^{norm})}{\sqrt{Var(K_{urt}^{norm})}}$$

přibližně standardní normální rozdělení pravděpodobnosti.

# Testy normality

**Testy na základě šikmosti a špičatosti**

# Testy normality

## Testy na základě šiknosti a špičatosti

Tedy hypotézu o normalitě na základě šiknosti zamítáme, pokud bude platit  $|T_3| \geq u_\alpha$ , nebo pokud bude  $p \leq \alpha$ , kde  $p = 2 \min\{\Phi(T_3), 1 - \Phi(T_3)\}$

# Testy normality

## Testy na základě šiknosti a špičatosti

Tedy hypotézu o normalitě na základě šiknosti zamítáme, pokud bude platit  $|T_3| \geq u_\alpha$ , nebo pokud bude  $p \leq \alpha$ , kde  $p = 2 \min\{\Phi(T_3), 1 - \Phi(T_3)\}$

Hypotézu o normalitě na základě špičatosti zamítáme, pokud bude platit  $|T_4| \geq u_\alpha$ , nebo pokud bude  $p \leq \alpha$ , kde  $p = 2 \min\{\Phi(T_4), 1 - \Phi(T_4)\}$

# Testy normality

## Testy na základě šiknosti a špičatosti

Tedy hypotézu o normalitě na základě šiknosti zamítáme, pokud bude platit  $|T_3| \geq u_\alpha$ , nebo pokud bude  $p \leq \alpha$ , kde

$$p = 2 \min\{\Phi(T_3), 1 - \Phi(T_3)\}$$

Hypotézu o normalitě na základě špičatosti zamítáme, pokud bude platit  $|T_4| \geq u_\alpha$ , nebo pokud bude  $p \leq \alpha$ , kde

$$p = 2 \min\{\Phi(T_4), 1 - \Phi(T_4)\}$$

Oba testy by se měly používat současně, proto se často používá kombinovaný test s testovou statistikou  $T_{34} = T_3^2 + T_4^2$ , která má  $\chi^2$ -rozdělení o 2 stupních volnosti. Hypotézu o normalitě potom zamítáme, když  $T_{34} \geq \chi_\alpha^2(2)$

# Testy normality

## Shapirův-Wilkův test

Jeden z nejsilnějších testů normality

$$SW = \frac{\left[ \sum_{i=1}^n a_{(i)} x_{(i)} \right]^2}{\sum_{i=1}^n a_{(i)}^2 \sum_{i=1}^n (x_{(i)} - \bar{x})^2}$$

kde  $a_{(i)} = \Phi^{-1} \left( \frac{8i-3}{8n+2} \right)$  a kritické hodnoty jsou tabelovány.

# Testy normality

## Shapirův-Wilkův test

Jeden z nejsilnějších testů normality

$$SW = \frac{\left[ \sum_{i=1}^n a_{(i)} x_{(i)} \right]^2}{\sum_{i=1}^n a_{(i)}^2 \sum_{i=1}^n (x_{(i)} - \bar{x})^2}$$

kde  $a_{(i)} = \Phi^{-1} \left( \frac{8i - 3}{8n + 2} \right)$  a kritické hodnoty jsou tabelovány.

=> pro aplikaci tohoto testu potřebujete tabulky a počítač,  
případně specializovaný statistický software.

# Testy normality

## Shapirův-Wilkův test

Jeden z nejsilnějších testů normality

$$SW = \frac{\left[ \sum_{i=1}^n a_{(i)} x_{(i)} \right]^2}{\sum_{i=1}^n a_{(i)}^2 \sum_{i=1}^n (x_{(i)} - \bar{x})^2}$$

kde  $a_{(i)} = \Phi^{-1} \left( \frac{8i - 3}{8n + 2} \right)$  a kritické hodnoty jsou tabelovány.

=> pro aplikaci tohoto testu potřebujete tabulky a počítač,  
případně specializovaný statistický software.

```
> shapiro.test(x.norm)
```

Shapiro-Wilk normality test

```
data: x.norm W = 0.9938, p-value = 0.5659
```

# Testy normality

## Shapirův-Wilkův test

Jeden z nejsilnějších testů normality

$$SW = \frac{\left[ \sum_{i=1}^n a_{(i)} x_{(i)} \right]^2}{\sum_{i=1}^n a_{(i)}^2 \sum_{i=1}^n (x_{(i)} - \bar{x})^2}$$

kde  $a_{(i)} = \Phi^{-1} \left( \frac{8i - 3}{8n + 2} \right)$  a kritické hodnoty jsou tabelovány.

=> pro aplikaci tohoto testu potřebujete tabulky a počítač,  
případně specializovaný statistický software.

## Lilieforsův test

Testová statistika je totožná s Kolmogorov-Smirnovovým testem,  
parametry hypotetického rozdělení odhadujeme z dat a kritické  
hodnoty hledáme v tabulkách

# Testy normality

## Lilieforsův test

Testová statistika je totožná s Kolmogorov-Smirnovovým testem, parametry hypotetického rozdělení odhadujeme z dat a kritické hodnoty hledáme v tabulkách

# Testy normality

## Lilieforsův test

Testová statistika je totožná s Kolmogorov-Smirnovovým testem, parametry hypotetického rozdělení odhadujeme z dat a kritické hodnoty hledáme v tabulkách

## Anderson-Darlingův test

Test, který je modifikací Kolmogorovova-Smirnovova testu (používá empirickou distribuční funkce a uspořádaný výběr) s testovou statistikou

$$AD = -\frac{\sum_{i=1}^n (2i-1) \left( \ln F_0(x_{(i)}) + \ln(1 - F_0(x_{(n-i+1)})) \right)}{n} - n$$

Kritické hodnoty jsou pro malá  $n$  tabelovány, pro velká  $n$  lze použít approximaci  $ad_{0,95} = 1,0348(1 - 1,013/n - 0,93/n^2)$

# Testy normality

## Lilieforsův test

Testová statistika je totožná s Kolmogorov-Smirnovovým testem, parametry hypotetického rozdělení odhadujeme z dat a kritické hodnoty hledáme v tabulkách

## Anderson-Darlingův test

Test, který je modifikací Kolmogorovova-Smirnovova testu (používá empirickou distribuční funkce a uspořádaný výběr) s testovou statistikou

$$AD = - \frac{\sum_{i=1}^n (2i - 1) (\ln F_0(x_{(i)}) + \ln(1 - F_0(x_{(n-i+1)})))}{n} - n$$

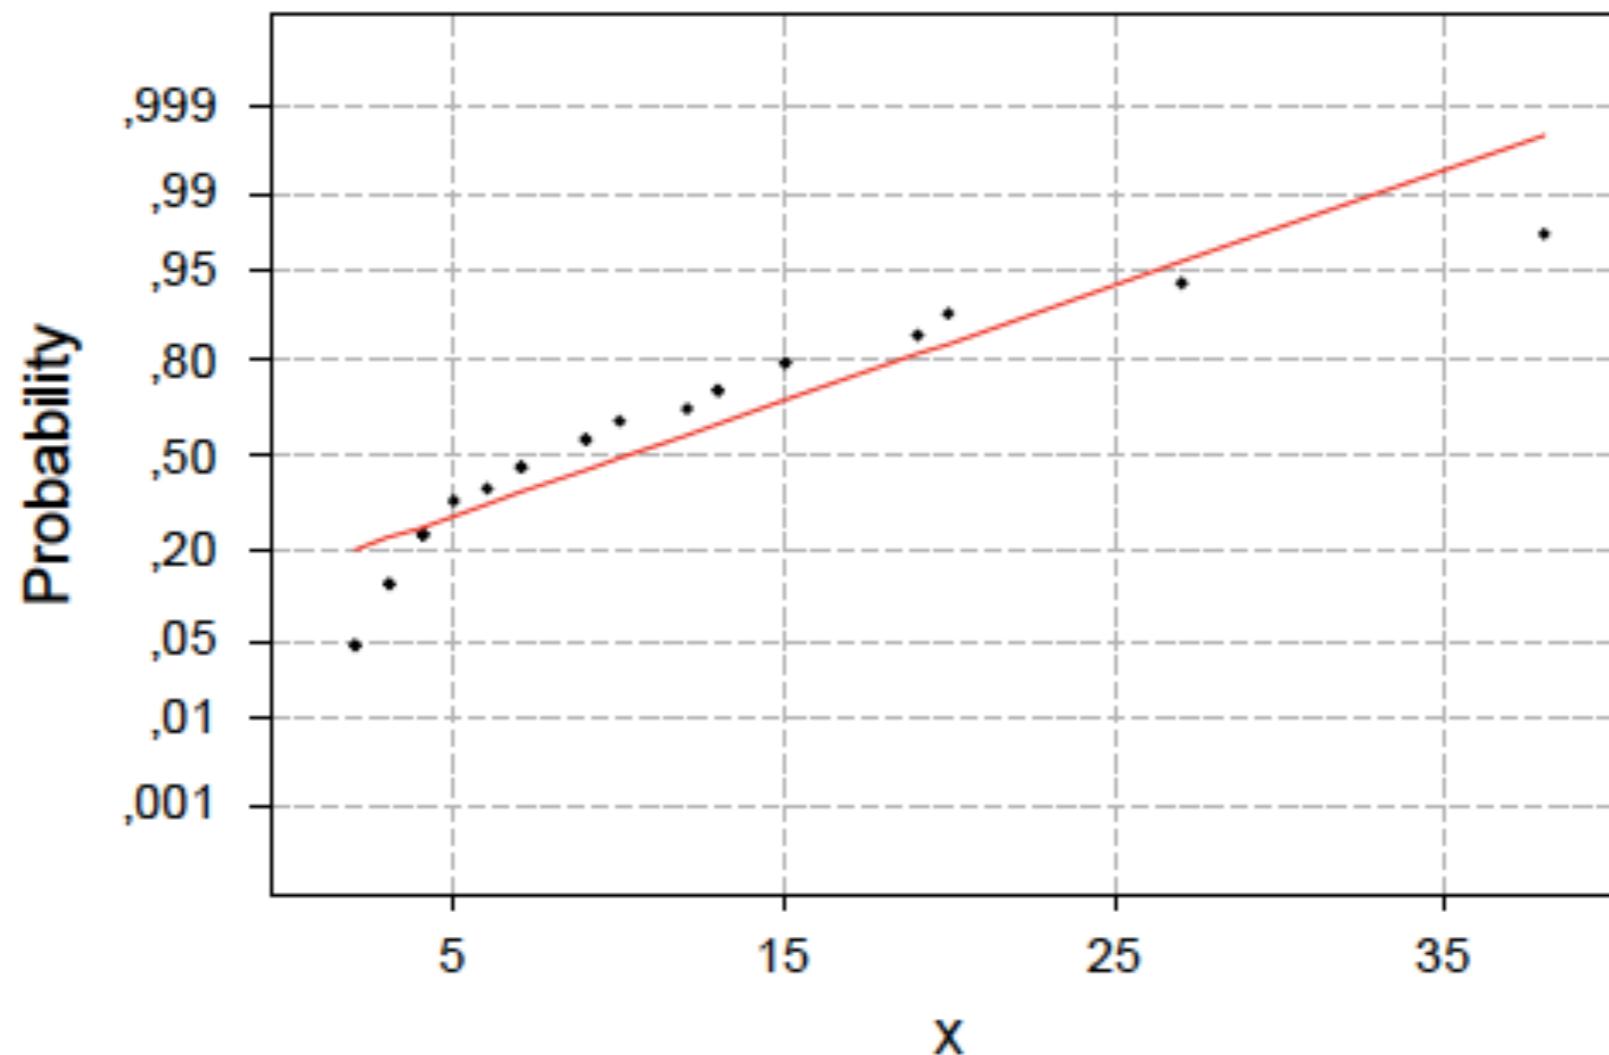
Kritické hodnoty jsou pro malá  $n$  tabelovány, pro velká  $n$  lze použít approximaci  $ad_{0,95} = 1,0348(1 - 1,013/n - 0,93/n^2)$

=> pro aplikaci tohoto testu potřebujete tabulky a počítač, případně specializovaný statistický software.

# Testy normality

## Anderson-Darlingův test

Normal Probability Plot



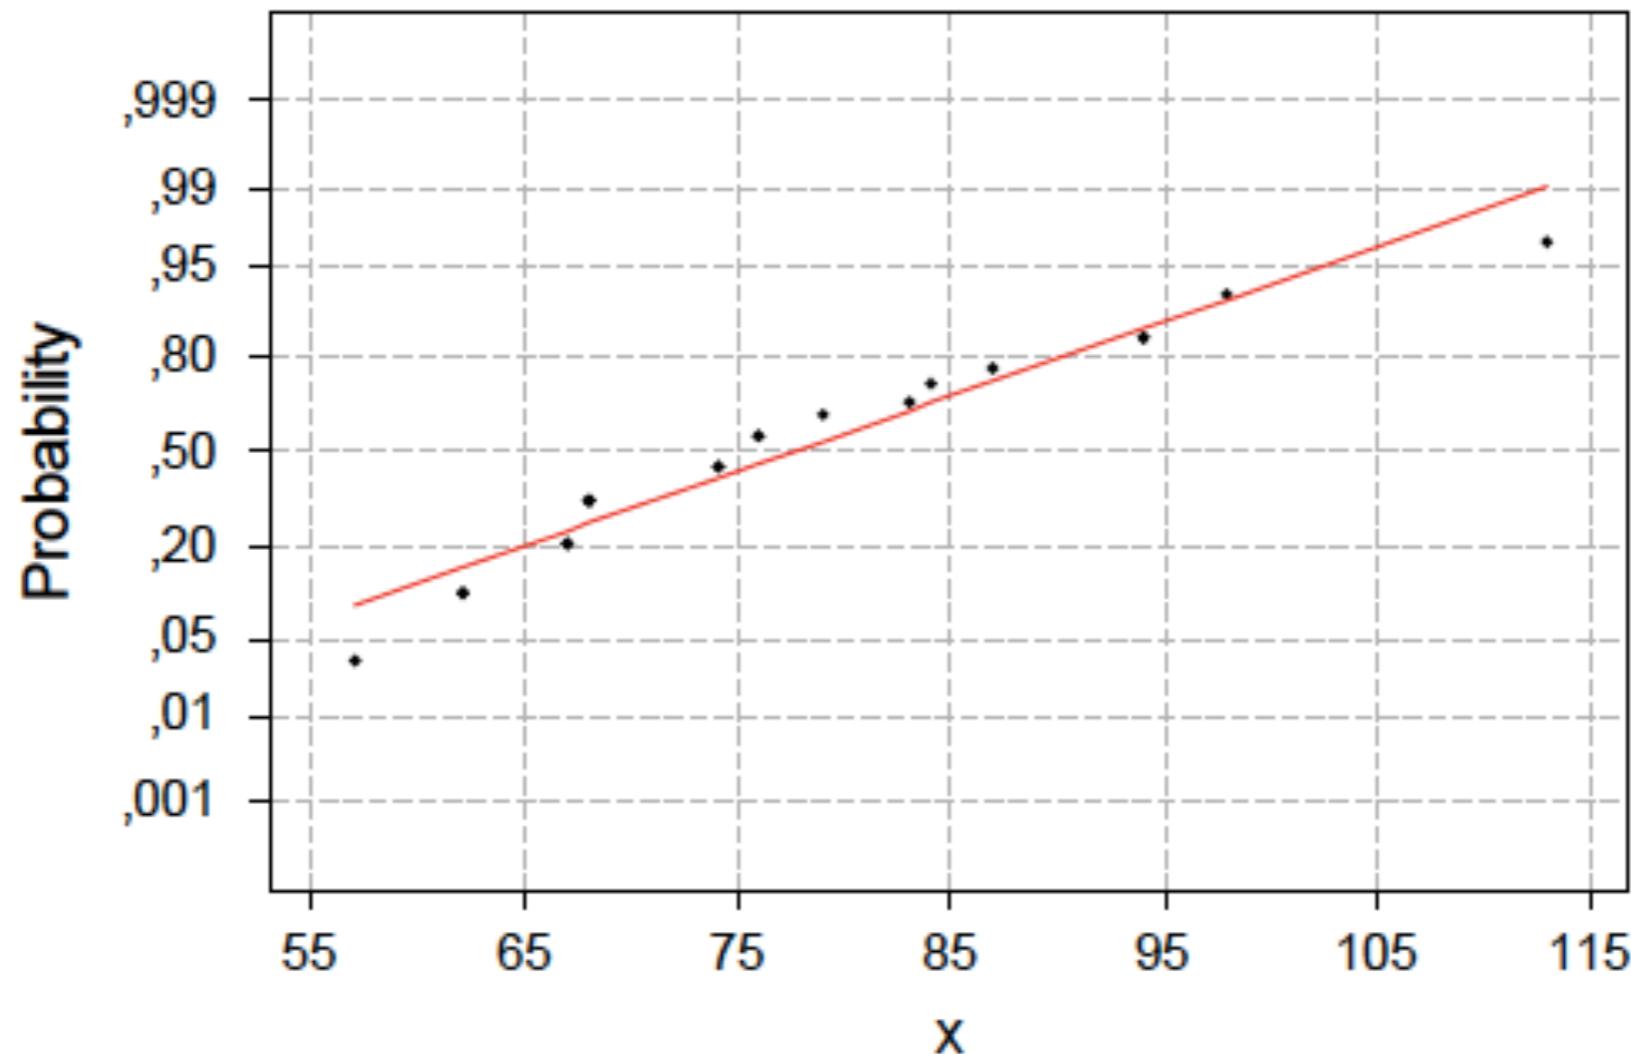
Average: 10,32  
StDev: 8,57185  
N: 25

Anderson-Darling Normality Test  
A-Squared: 1,276  
P-Value: 0,002

# Testy normality

## Anderson-Darlingův test

Normal Probability Plot



Average: 77,55  
StDev: 14,1625  
N: 20

Anderson-Darling Normality Test  
A-Squared: 0,455  
P-Value: 0,240

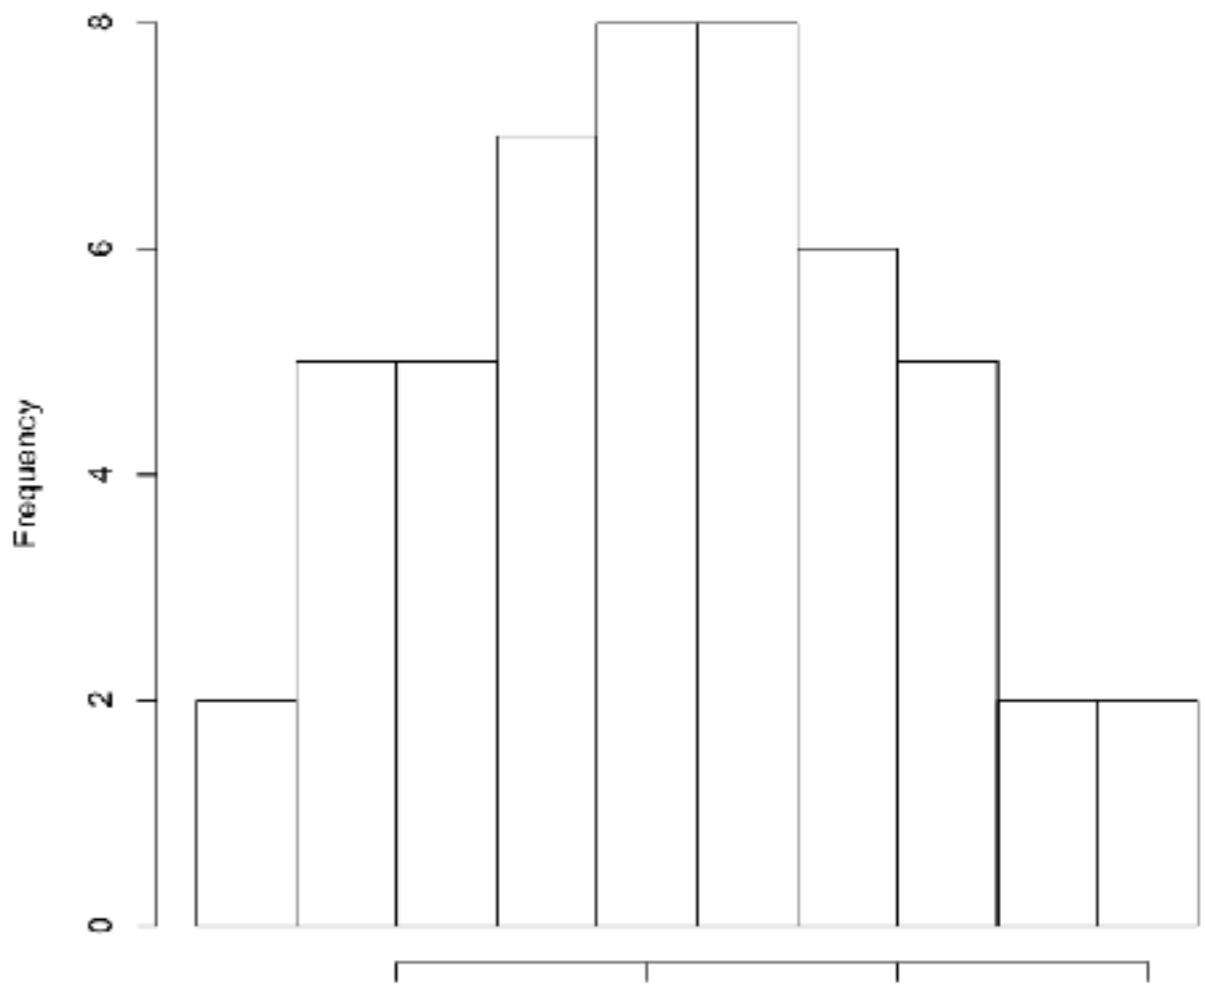
# Testy dobré shody

24.52586	24.17119	24.54486	24.44240	23.93455	24.20389	24.19974	24.34851	23.94024	24.21022
24.87474	25.06155	25.48924	25.32572	23.71721	24.61622	25.06676	24.90055	24.36213	24.98580
24.80591	24.20853	24.72623	24.64437	24.70405	23.97645	25.29837	24.46910	24.99453	25.42994
24.66147	24.75773	25.03970	24.44901	25.13285	24.40205	24.78721	23.83656	24.17186	23.65390
24.48244	24.68550	24.22988	23.83956	24.09777	24.52098	24.89240	24.25332	24.14259	25.12906

# Testy dobré shody

24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

Histogram of X



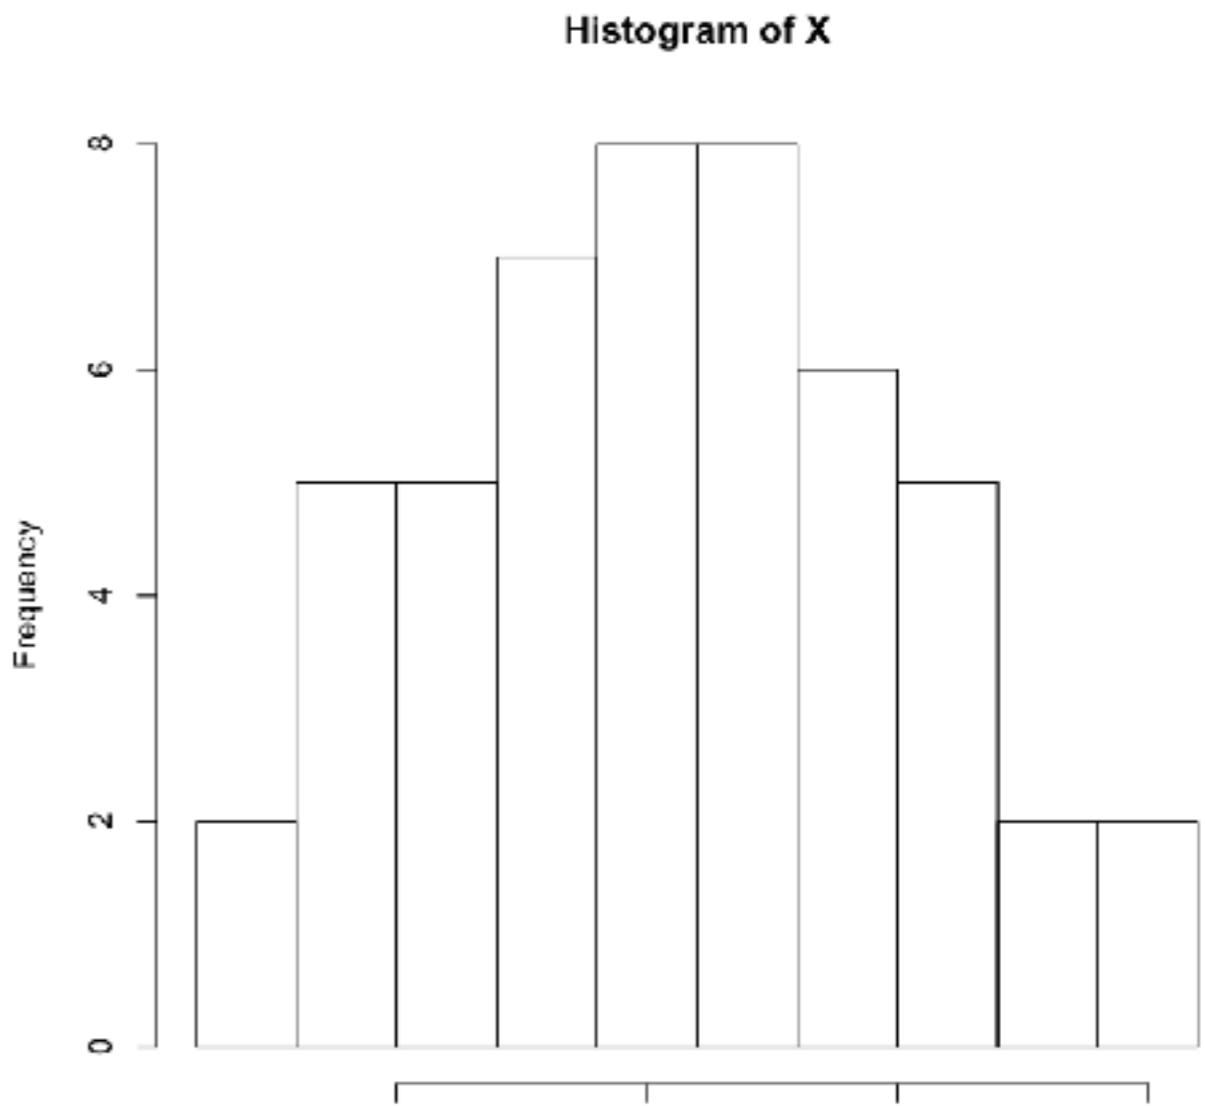
# Testy dobré shody

24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i = 24.54689$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^2 (X_i - \bar{X})^2 = 0,2102477$$

$$s = \sqrt{0,2102477} = 0,4585$$



# Testy dobré shody

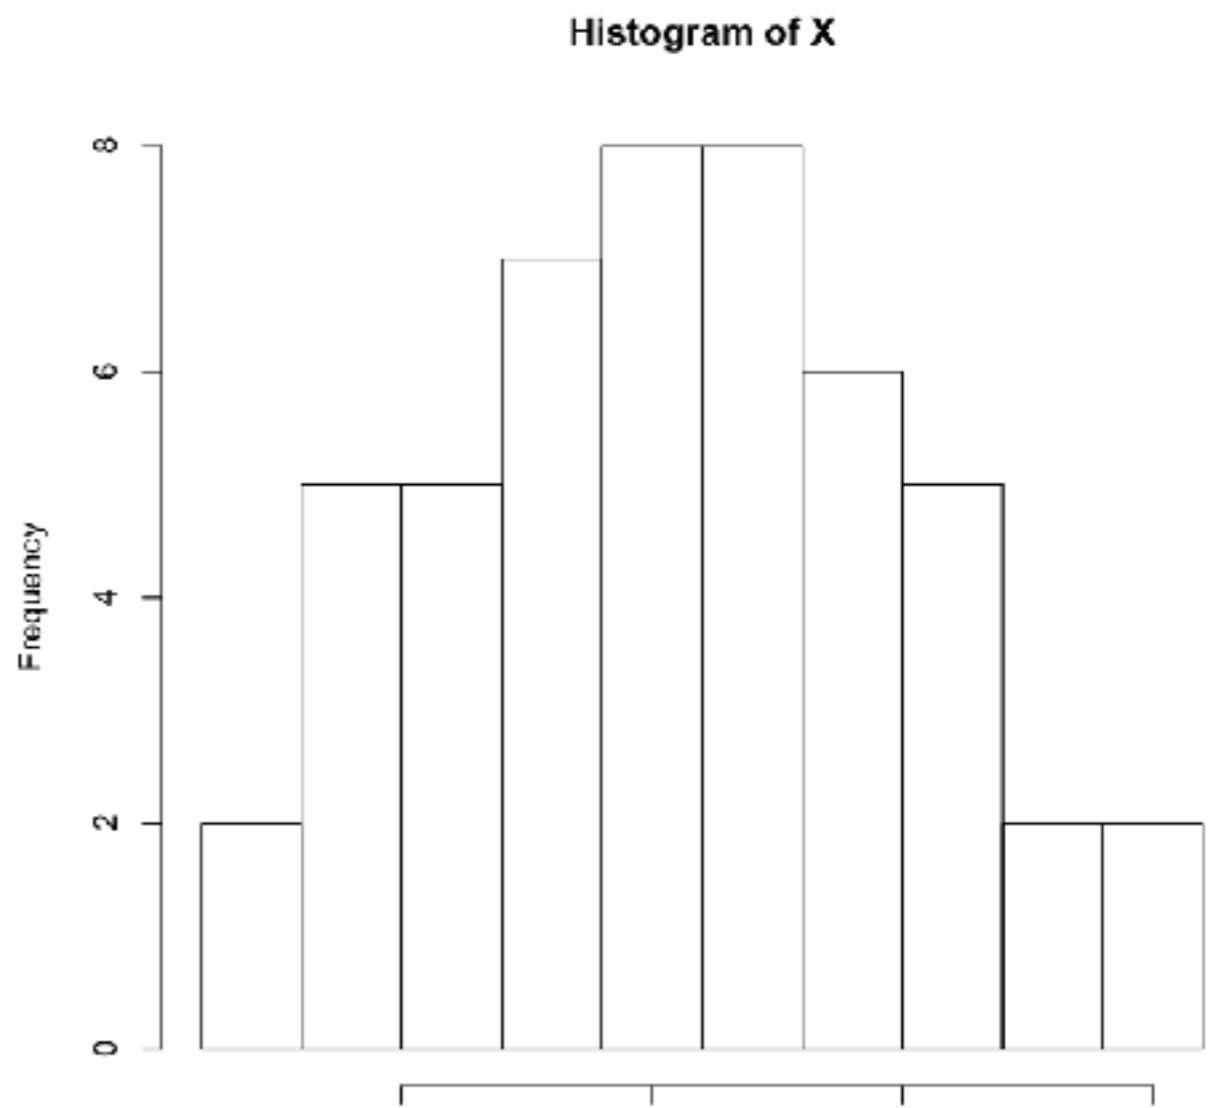
24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i = 24.54689$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = 0,2102477$$

$$s = \sqrt{0,2102477} = 0,4585$$

$$N(24,55; 0,2102)$$



# Testy dobré shody

24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

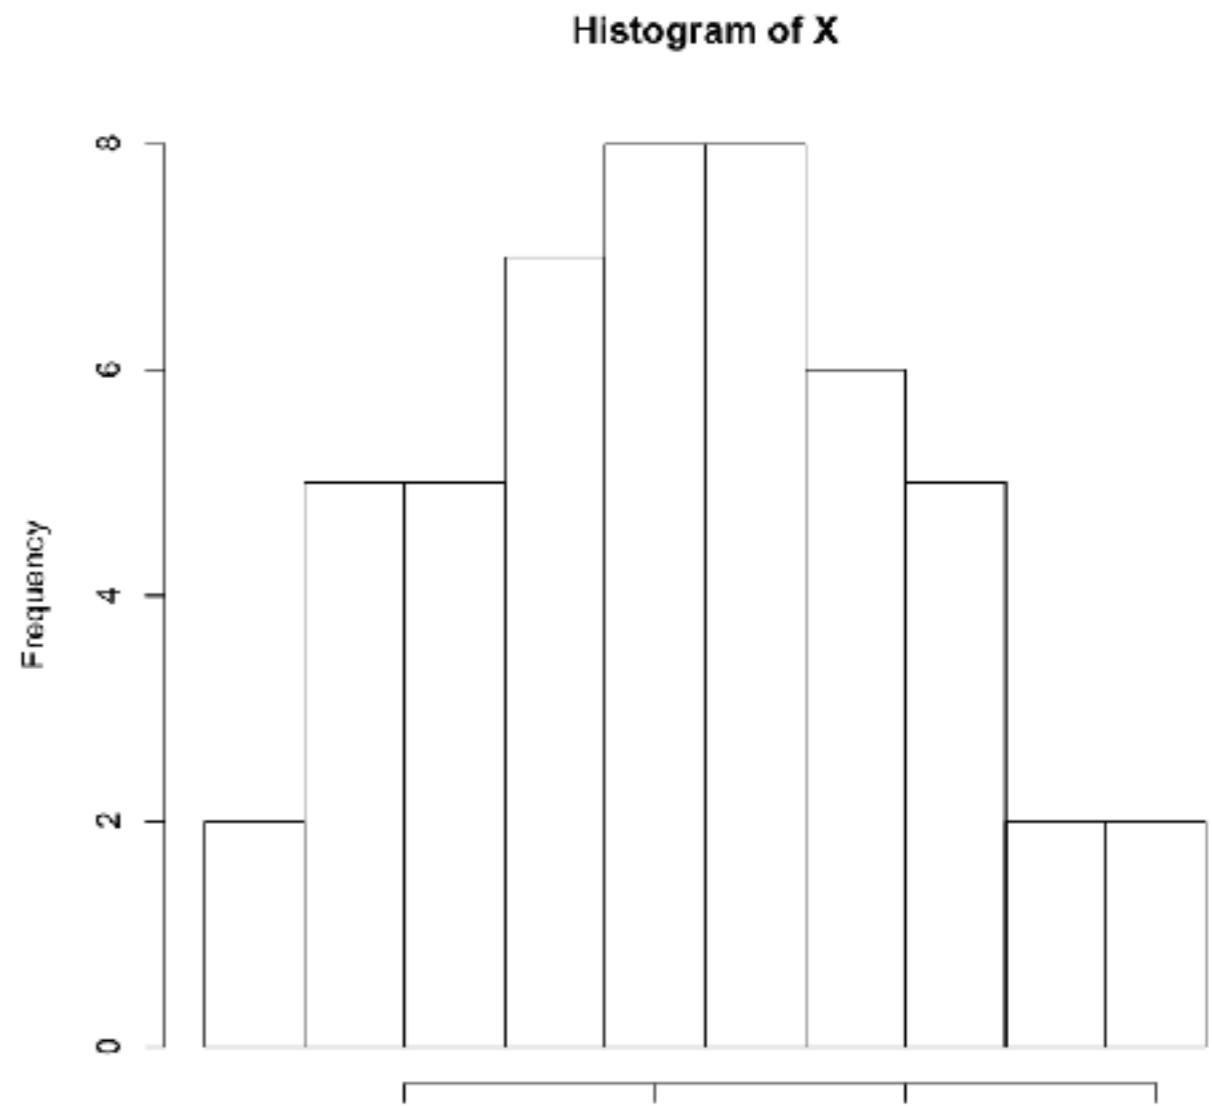
$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i = 24.54689$$

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 = 0,2102477$$

$$s = \sqrt{0,2102477} = 0,4585$$

$$N(24,55; 0,2102)$$

$$H_0 : F(x) = F_{N(24,55; 0,2102)}(x)$$

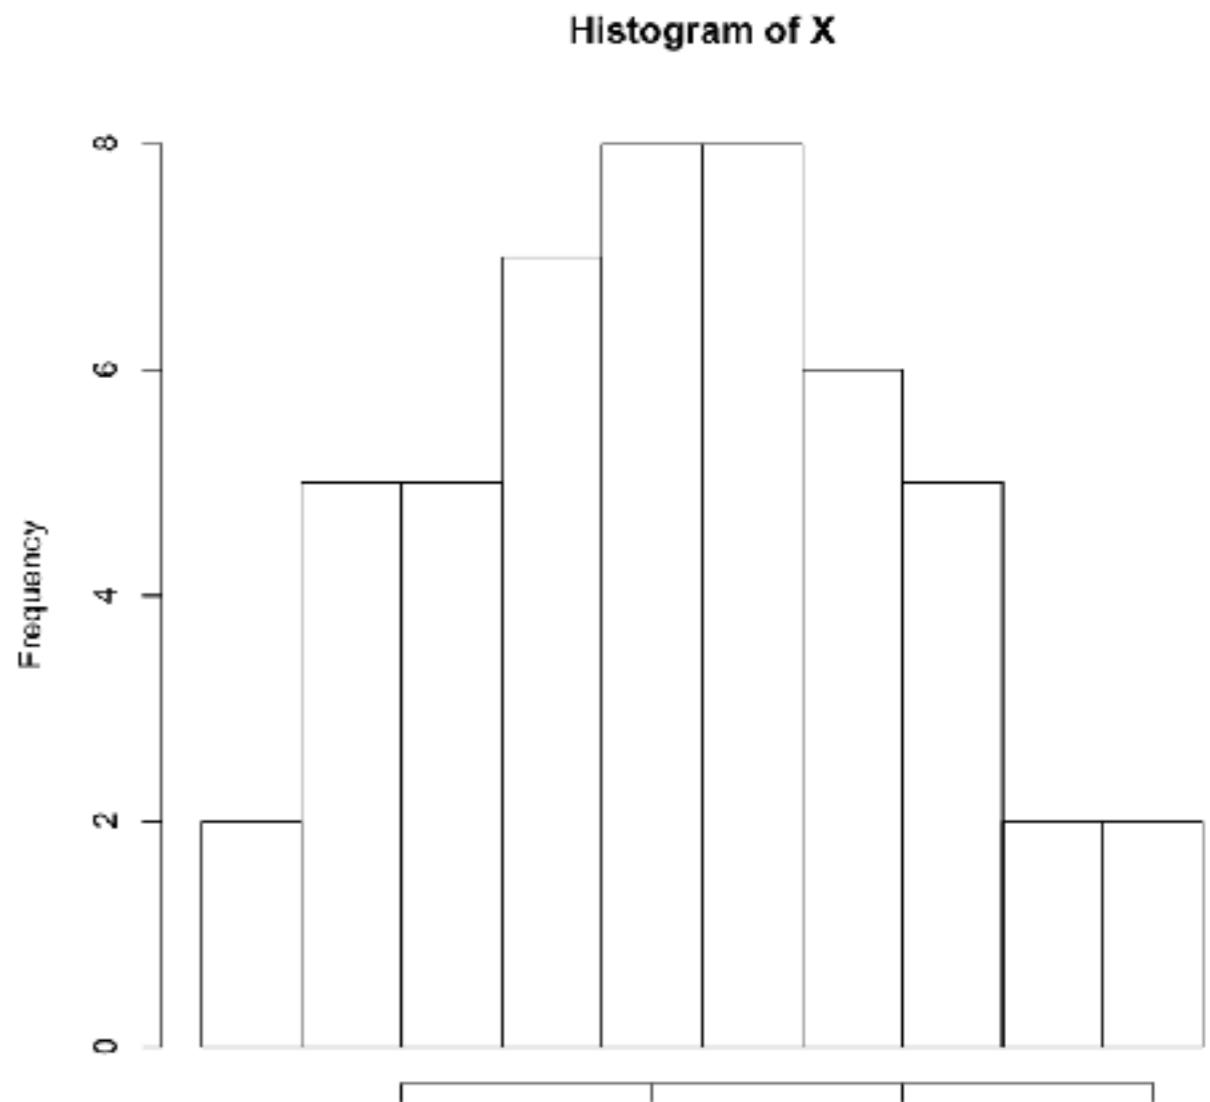


# Testy dobré shody

24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
 24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
 24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
 24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
 24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

	i	ni	pi	npi	(ni-npi)2/npi
23,6	23,8	2	0,0634	3,17	0,4323
23,8	24	5	0,0743	3,72	0,4433
24	24,2	4	0,1187	5,94	0,6312
24,2	24,4	8	0,1572	7,86	0,0025
24,4	24,6	8	0,1727	8,63	0,0463
24,6	24,8	8	0,1572	7,86	0,0025
24,8	25	6	0,1187	5,94	0,0007
25	25,2	5	0,0743	3,72	0,4433
25,2	25,4	2	0,0386	1,93	0,0026
25,4	26	2	0,0248	1,24	0,4636
	suma	50	1,0000	50,00	2,4684

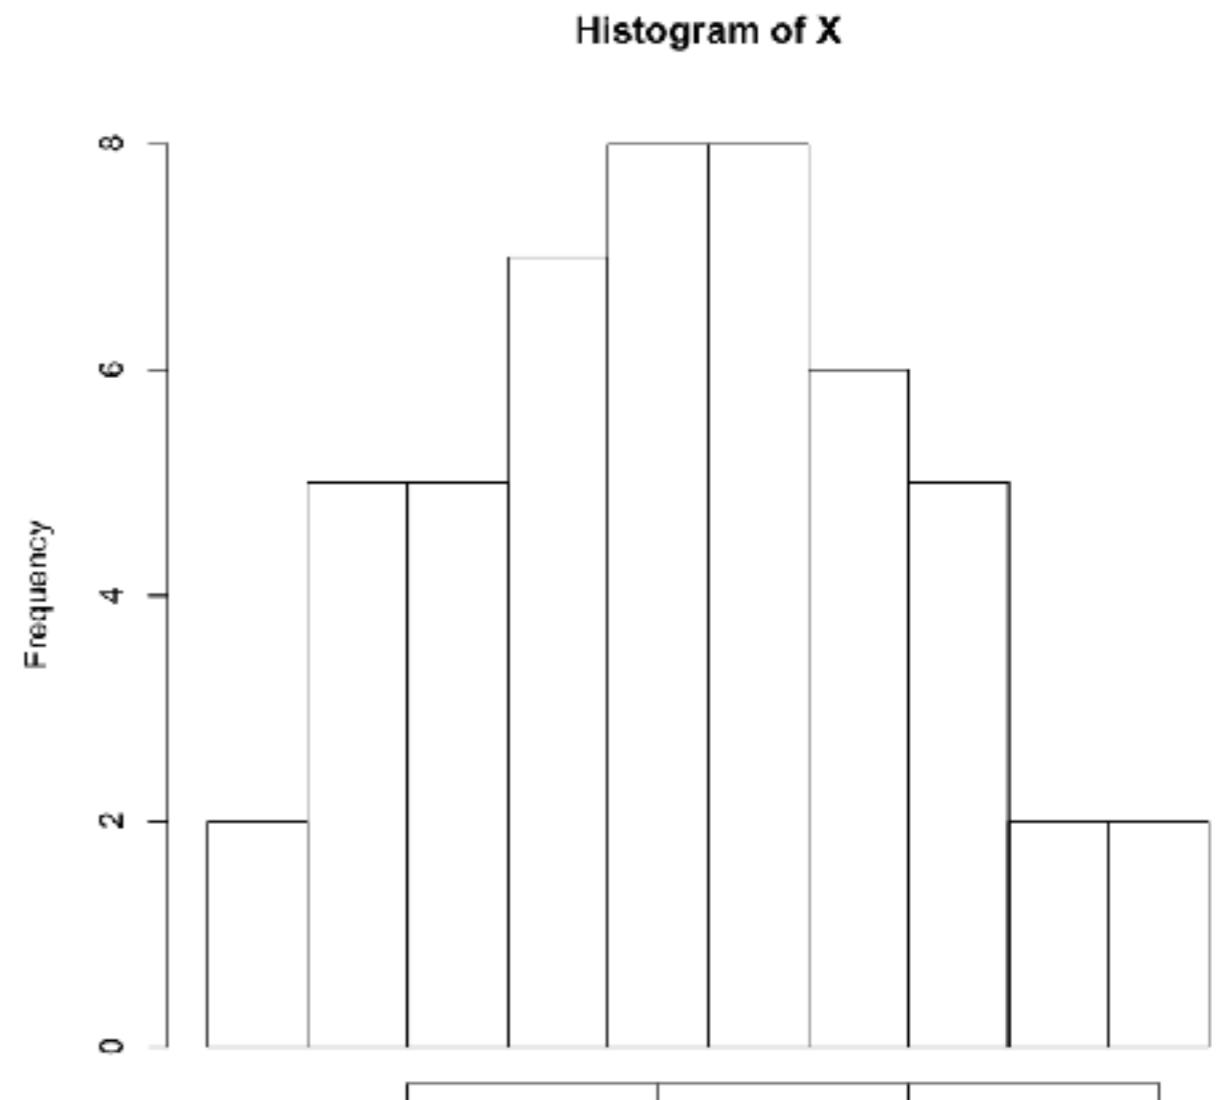
$$H_0 : F(x) = F_{N(24,55;0,21024)}(x)$$



# Testy dobré shody

24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
 24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
 24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
 24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
 24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

	i	ni	pi	npi	(ni-npi)2/npi
23,6	23,8	2	0,0634	3,17	0,4323
23,8	24	5	0,0743	3,72	0,4433
24	24,2	4	0,1187	5,94	0,6312
24,2	24,4	8	0,1572	7,86	0,0025
24,4	24,6	8	0,1727	8,63	0,0463
24,6	24,8	8	0,1572	7,86	0,0025
24,8	25	6	0,1187	5,94	0,0007
25	25,2	5	0,0743	3,72	0,4433
25,2	25,4	2	0,0386	1,93	0,0026
25,4	26	2	0,0248	1,24	0,4636
	suma	50	1,0000	50,00	2,4684

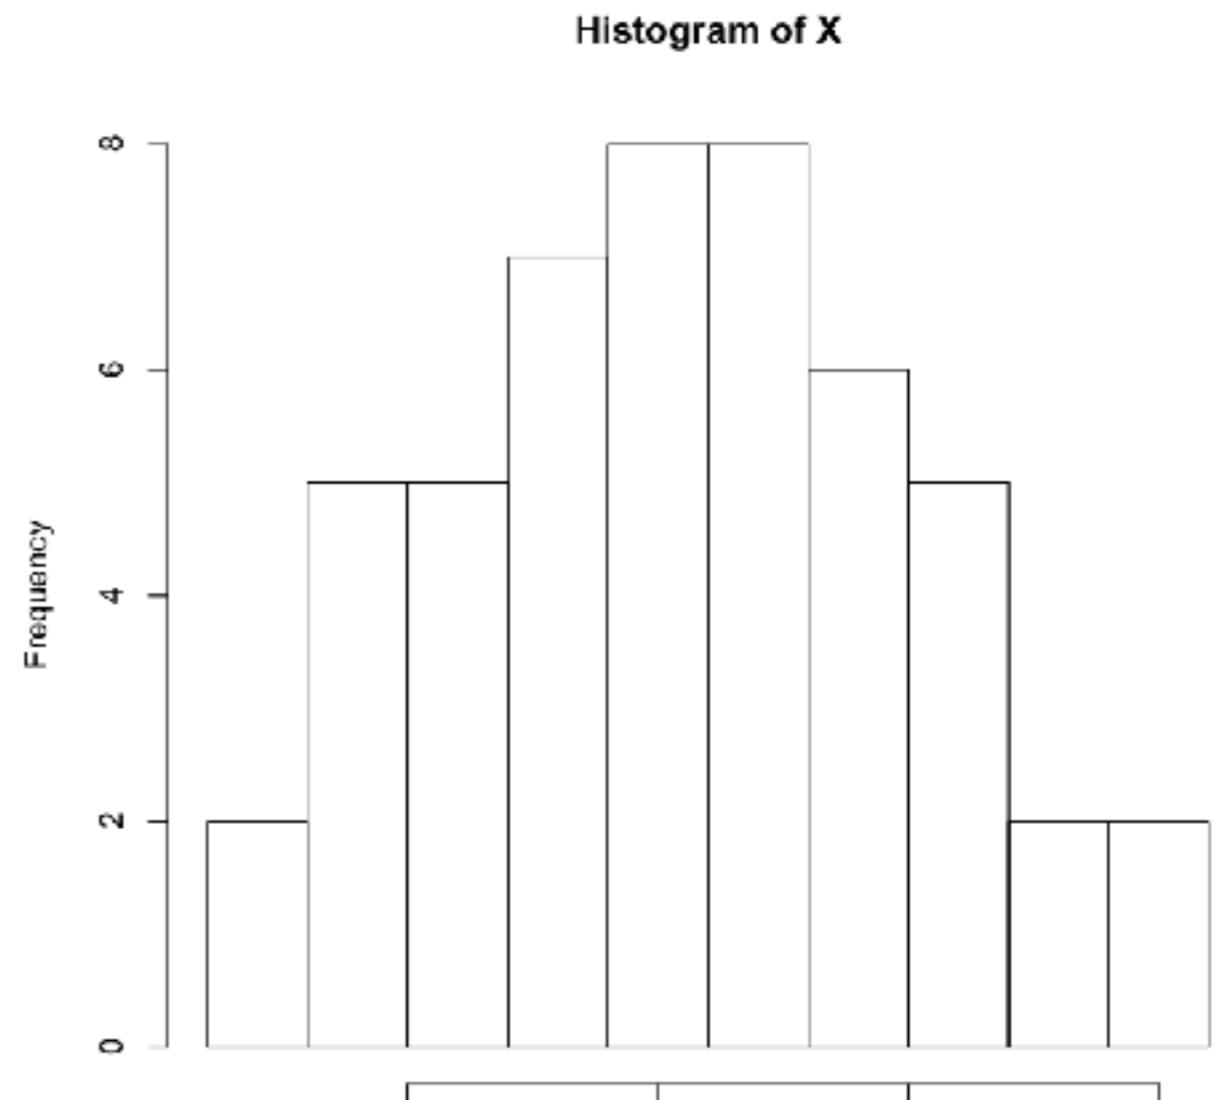


$$H_0 : F(x) = F_{N(24,55;0,21024)}(x)$$

# Testy dobré shody

24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
 24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
 24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
 24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
 24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

	i	ni	pi	npi	(ni-npi)2/npi
23,6	23,8	2	0,0634	3,17	0,4323
23,8	24	5	0,0743	3,72	0,4433
24	24,2	4	0,1187	5,94	0,6312
24,2	24,4	8	0,1572	7,86	0,0025
24,4	24,6	8	0,1727	8,63	0,0463
24,6	24,8	8	0,1572	7,86	0,0025
24,8	25	6	0,1187	5,94	0,0007
25	25,2	5	0,0743	3,72	0,4433
25,2	25,4	2	0,0386	1,93	0,0026
25,4	26	2	0,0248	1,24	0,4636
	suma	50	1,0000	50,00	2,4684



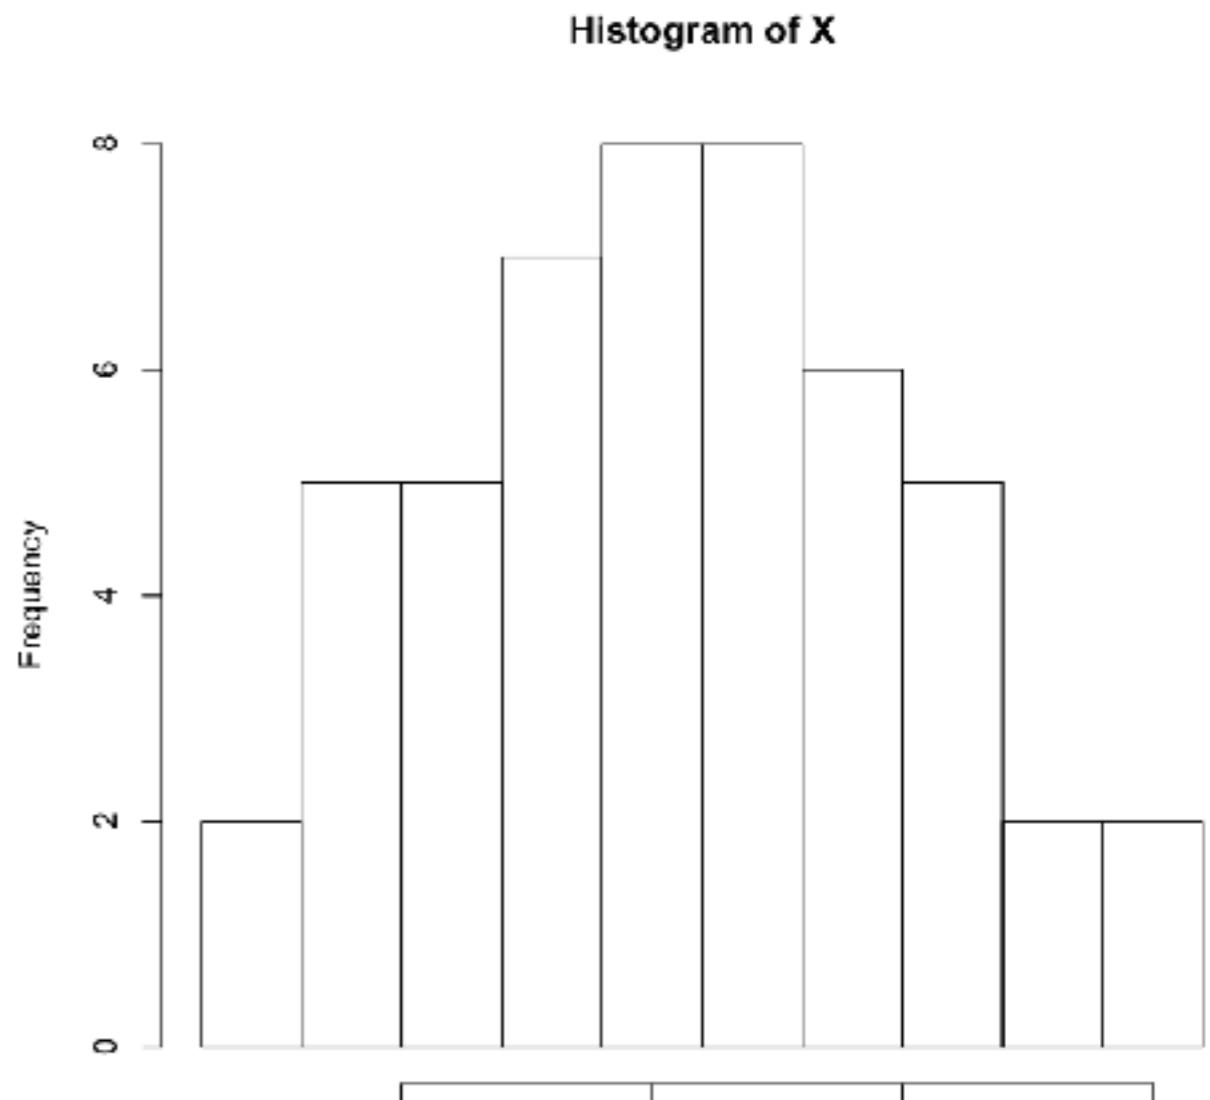
$$H_0 : F(x) = F_{N(24,55;0,21024)}(x)$$

# Testy dobré shody

24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

	i	ni	pi	npi	(ni-npi)2/npi
23,6	24	7	0,1377	6,89	0,0018
24	24,2	4	0,1187	5,94	0,6312
24,2	24,4	8	0,1572	7,86	0,0025
24,4	24,6	8	0,1727	8,63	0,0463
24,6	24,8	8	0,1572	7,86	0,0025
24,8	25	6	0,1187	5,94	0,0007
25	26	9	0,1377	6,89	0,6482
<b>suma</b>		50	1,0000	50,00	1,3332

$$H_0 : F(x) = F_{N(24,55;0,21024)}(x)$$



# Testy dobré shody

24.52586 24.17119 24.54486 24.44240 23.93455 24.20389 24.19974 24.34851 23.94024 24.21022  
24.87474 25.06155 25.48924 25.32572 23.71721 24.61622 25.06676 24.90055 24.36213 24.98580  
24.80591 24.20853 24.72623 24.64437 24.70405 23.97645 25.29837 24.46910 24.99453 25.42994  
24.66147 24.75773 25.03970 24.44901 25.13285 24.40205 24.78721 23.83656 24.17186 23.65390  
24.48244 24.68550 24.22988 23.83956 24.09777 24.52098 24.89240 24.25332 24.14259 25.12906

	i	ni	pi	npi	(ni-npi)2/npi
23,6	24	7	0,1377	6,89	0,0018
24	24,2	4	0,1187	5,94	0,6312
24,2	24,4	8	0,1572	7,86	0,0025
24,4	24,6	8	0,1727	8,63	0,0463
24,6	24,8	8	0,1572	7,86	0,0025
24,8	25	6	0,1187	5,94	0,0007
25	26	9	0,1377	6,89	0,6482
suma		50	1,0000	50,00	1,3332

$$\chi^2 = 1,3332 \leq \chi_{0,95}(47) = 32,3$$

$$H_0 : F(x) = F_{N(24,55;0,21024)}(x)$$

