

PSY117 2017

Statistická analýza dat v psychologii

**Přednáška 3**

---

# **Transformace skórů a kvantily normálního rozložení**

# Transformace skórů (dat)

---

Pro usnadnění porozumění a možnost dalších analýz často přepočítáváme hodnoty proměnných, aby měla lepší vlastnosti

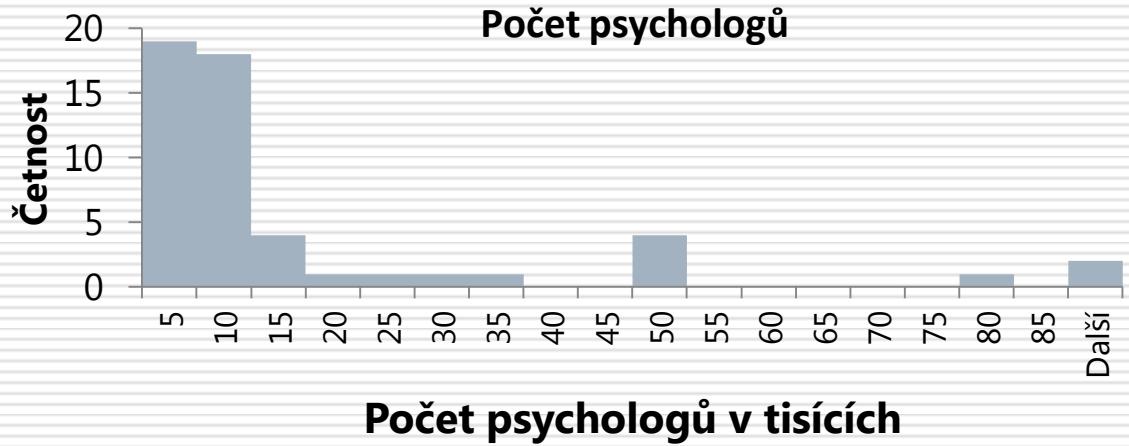
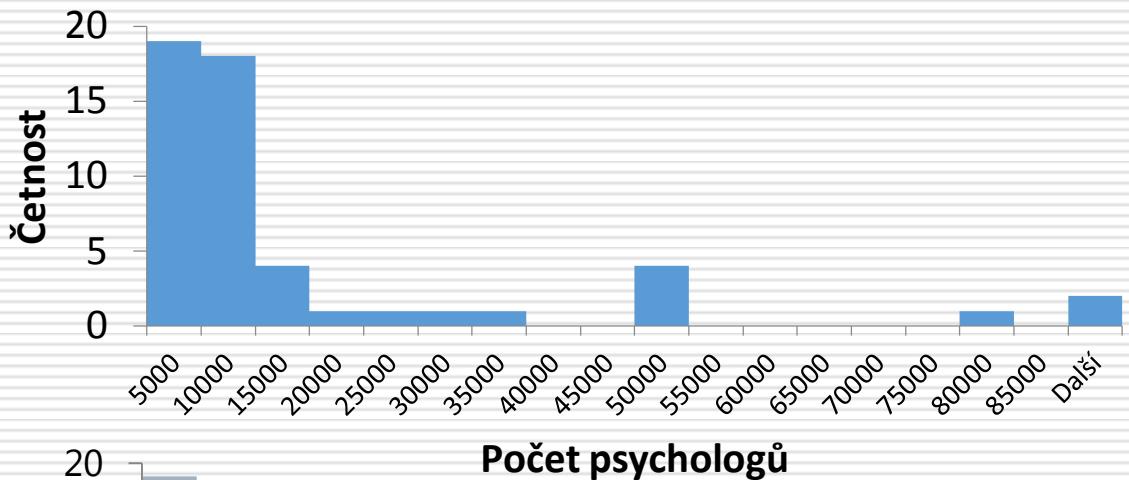
- Usnadnění interpretace – *lineární transformace*
    - např. vynásobení 10 nebo 100 pro odstranění desetinných míst
    - tvar rozložení zůstává zachován
    - možnost sjednocení různých proměnných na stejnou škálu, měřítko ... Standardizace
  - Změna tvaru rozložení – *nelineární transformace*
    - log/exp fce, (od)mocniny, Tukey: „ladder of powers“ Hendl kap. o EDA.
    - Též „normalizace“ rozložení – normalizované skóry
  - Změna úrovně měření – *pořadová transformace (ranking)*
-

# Lineární transformace 1

□ Např. počtu psychologů na tisíce

- Tvar rozložení zachován
- Popisné statistiky se předpověditelně změní
- $M$ ,  $SD$ ,  $Md$ ,  $IQR$ ,  $min$ ,  $max$  jsou tisíckrát menší
- $s^2$  (VAR)?

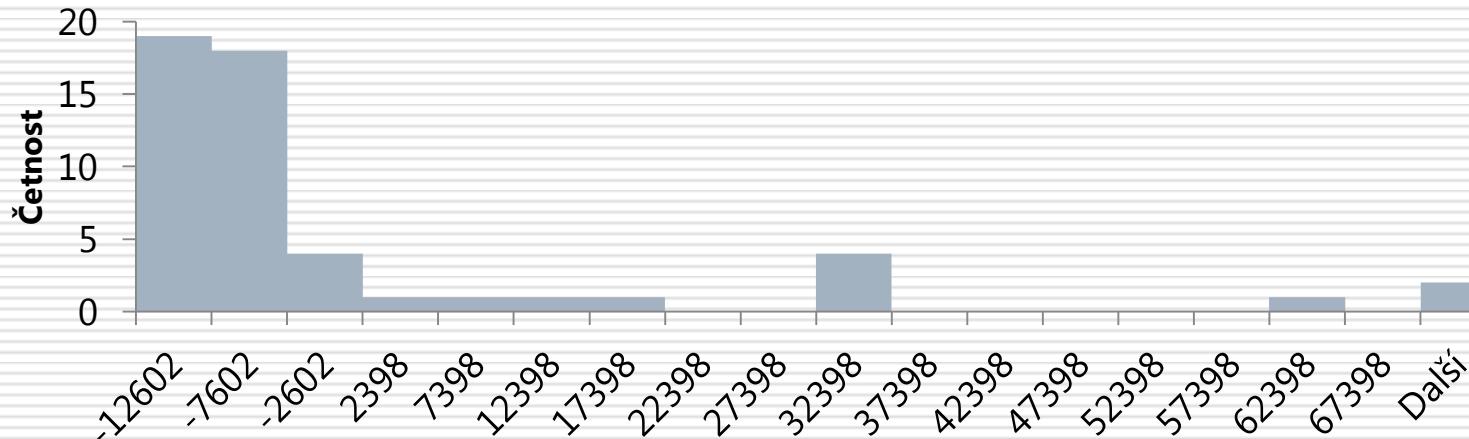
poc_psy	v tisících
5000	5
1200	1,2
1000	1
10000	10
12000	12
4000	4
1500	1,5
10000	10
100000	100
10000	10
12000	12
10000	10
150000	150
35000	35
80000	80
50000	50
17000	17
1385	1,385
2000	2
10000	10
5000	5
10000	10
9999	9,999
50000	50
10000	10
10000	10
12500	12,5
3000	3
15000	15
3 000	3
6000	6
2000	2
5000	5
10000	10
10000	10
10000	10
5000	5
5000	5
5743	5,743
8000	8
3500	3,5
1500	1,5
25000	25
10000	10
10000	10
50000	50
30000	30
50000	50
5000	5
7000	7
5000	5
1000	1



# Lineární transformace 2

## □ Deviační skóry $x_i$ - odečtení průměru

- Tvar rozložení zůstává zachován
- Popisné statistiky – CT jsou o průměr menší, variabilita beze změn
- Snadnější interpretace jednotlivých skóru



poc_psy	v tisících	dev
5000	5	-12602
12000	12	-16402
10000	10	-16602
10000	10	-7602
12000	12	-5602
4000	4	-13602
1500	1,5	-16102
10000	10	-7602
100000	100	82398
10000	10	-7602
12000	12	-5602
10000	10	-7602
150000	150	132398
3500	35	17398
80000	80	62398
50000	50	32398
17000	17	-602
1385	1,385	-16217
2000	2	-15602
10000	10	-7602
5000	5	-12602
10000	10	-7602
9999	9,999	-7602
50000	50	32398
10000	10	-7602
10000	10	-7602
10000	10	-7602
12600	12,6	-5102
3000	3	-14602
15000	15	-2602
3000	3	-14602
6000	6	-11602
2000	2	-15602
5000	5	-12602
10000	10	-7602
10000	10	-7602
5000	5	-12602
5743	5,743	-11859
8000	8	-9602
3500	3,5	-14102
1500	1,5	-16102
25000	25	7398
10000	10	-7602
10000	10	-7602
50000	50	32398
30000	30	12398
50000	50	32398
5000	5	-12602
7000	7	-10602
5000	5	-12602
1000	1	-16602
M	17602	17,60
SD	27410	27,41
VAR	751320188	751,3202
Md	10000	10,000
IQR	7125	7,125
min	1000	1 -16602,4423
max	150000	150 132397,558

**Rozdíl mezi odhadem a průměrem odhadu počtu psychologů**

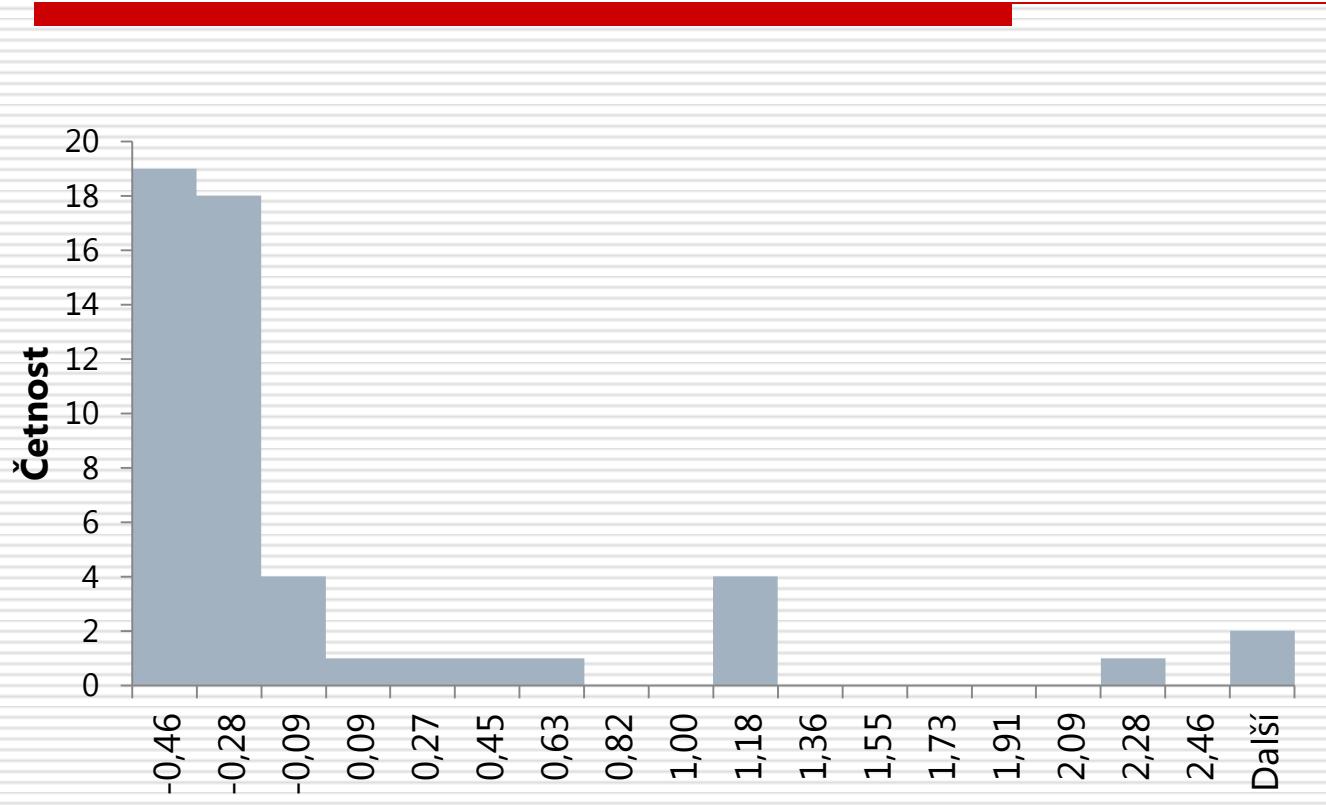
# Lineární transformace - standardizace z-skóry, standardizované skóry

---

- Nejobvyklejší lineární transformace - **standardizace**
  - transformace sady skórů, aby  $m = 0$ ,  $s = 1$
  - **jednotkou měření se stává  $s$** , možnost srovnávání různých škal (ale pozor rozdíly v rozložení zůstávají!)

$$z_i = (X_i - m) / s$$

- s. je zajímavá zvláště u normálně rozložených dat, protože známe řadu jeho percentilů z paměti
  - u přibližně normálně rozložených dat o lidech je většina (přes 90%) lidí mezi -3 a 3



poc_psy	v tisících	dev	z	
5000	5	-12602	-0,46	
1200	1,2	-16402	-0,60	
1000	1	-16602	-0,61	
10000	10	-7602	-0,28	
12000	12	-5602	-0,20	
4000	4	-13602	-0,50	
1500	1,5	-16102	-0,59	
10000	10	-7602	-0,28	
100000	100	82398	3,01	
10000	10	-7602	-0,28	
12000	12	-5602	-0,20	
10000	10	-7602	-0,28	
150000	150	132398	4,83	
35000	35	17398	0,63	
80000	80	62398	2,28	
50000	50	32398	1,18	
17000	17	-602	-0,02	
1385	1,385	-16217	-0,59	
2000	2	-15602	-0,57	
10000	10	-7602	-0,28	
5000	5	-12602	-0,46	
10000	10	-7602	-0,28	
9999	9,999	-7603	-0,28	
50000	50	32398	1,18	
10000	10	-7602	-0,28	
10000	10	-7602	-0,28	
12500	12,5	-5102	-0,19	
3000	3	-14602	-0,53	
15000	15	-2602	-0,09	
3 000	3	-14602	-0,53	
6 000	6	-11602	-0,42	
2 000	2	-15602	-0,57	
5 000	5	-12602	-0,46	
5 000	5	-12602	-0,46	
5743	5,743	-11859	-0,43	
8 000	8	-9602	-0,35	
3 500	3,5	-14102	-0,51	
1 500	1,5	-16102	-0,59	
25 000	25	7398	0,27	
10 000	10	-7602	-0,28	
10 000	10	-7602	-0,28	
10 000	10	-7602	-0,28	
5 000	5	-12602	-0,46	
5 000	5	-12602	-0,46	
Md	10000	10,000	-7602	0
IQR	7125	7,125	7125	0,25994
min	1000	1	-16602,4423	-0,6057
max	150000	150	132397,558	4,83026
VAR	751320188	751,3202	751320188	1

# Skóry odvozené ze z-skórů

---

Používané primárně v psychodiagnostických metodách

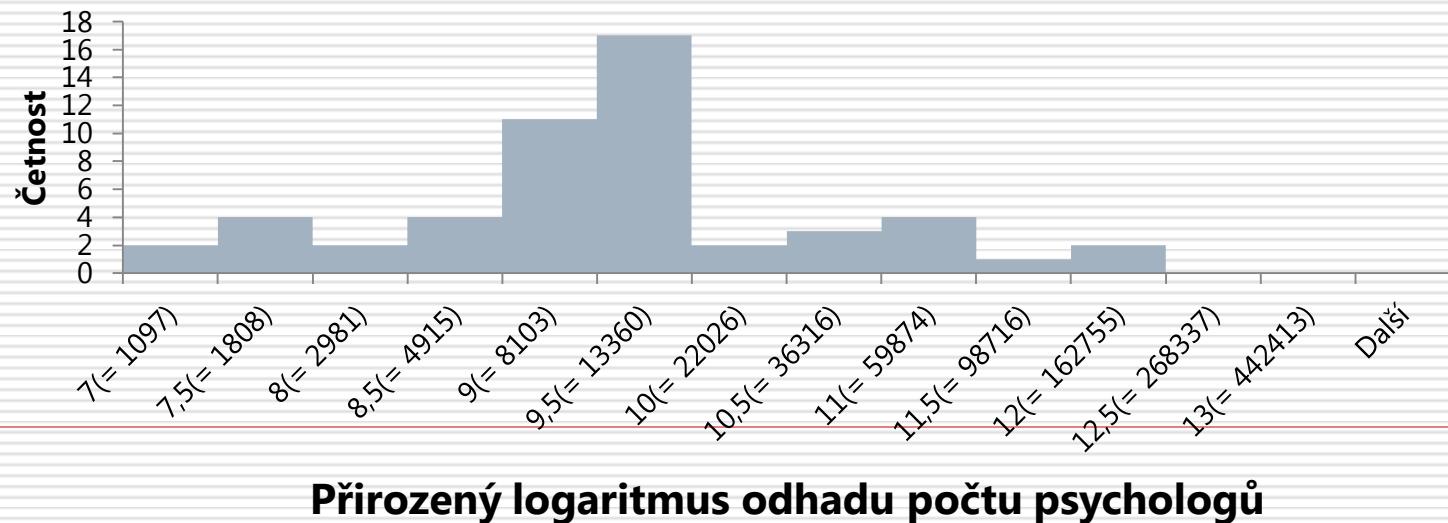
- IQ* skóry** ( $m=100, s=15$ )
- T* skóry** ( $m=50, s= 10$ )
  
- staniny**, stanicové skóry (standard *nine*) ( $m=5, s= 2$ ) + kategorizace zaokrouhlením na celá čísla ... od 1 do 9
- steny**, stenové skóry (standard *ten*) ( $m=5,5, s= 2$ ) + kategorizace zaokrouhlením na celá čísla ... od 1 do 10

**Pořad je podmínkou správné interpretace normální rozložení měřené proměnné v dané populaci!**

---

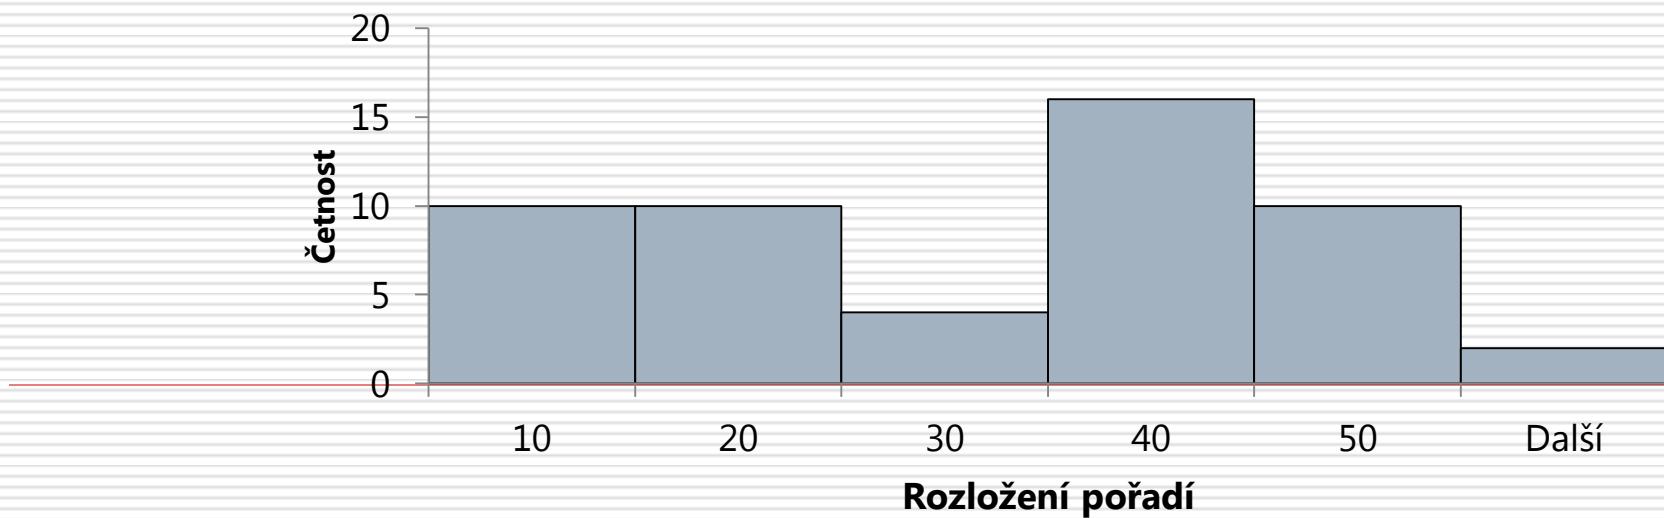
# Nelineární transformace 1

- Změna rozložení (obv. směrem k normálnímu)
  - Pro smysluplnější využití momentových statistik
  - Pro možnost využití analytických technik, které nějakou podobu rozložení vyžadují
- Popisné statistiky se mění složitěji
- Př. logaritmus počtu psychologů



# Nelineární transformace 2

- Transformace na pořadí – ranking
  - Eliminace odlehlých hodnot, odhlédnutí od velikosti rozdílů mezi lidmi
  - Obvykle vzestupně (nejnižší hodnota má pořadí 1)
  - Stejné hodnoty dostávají průměrné pořadí (=RANK.AVG)
  - Výsledné rozložení je (přibližně) uniformní



# Transformace na percentily

---

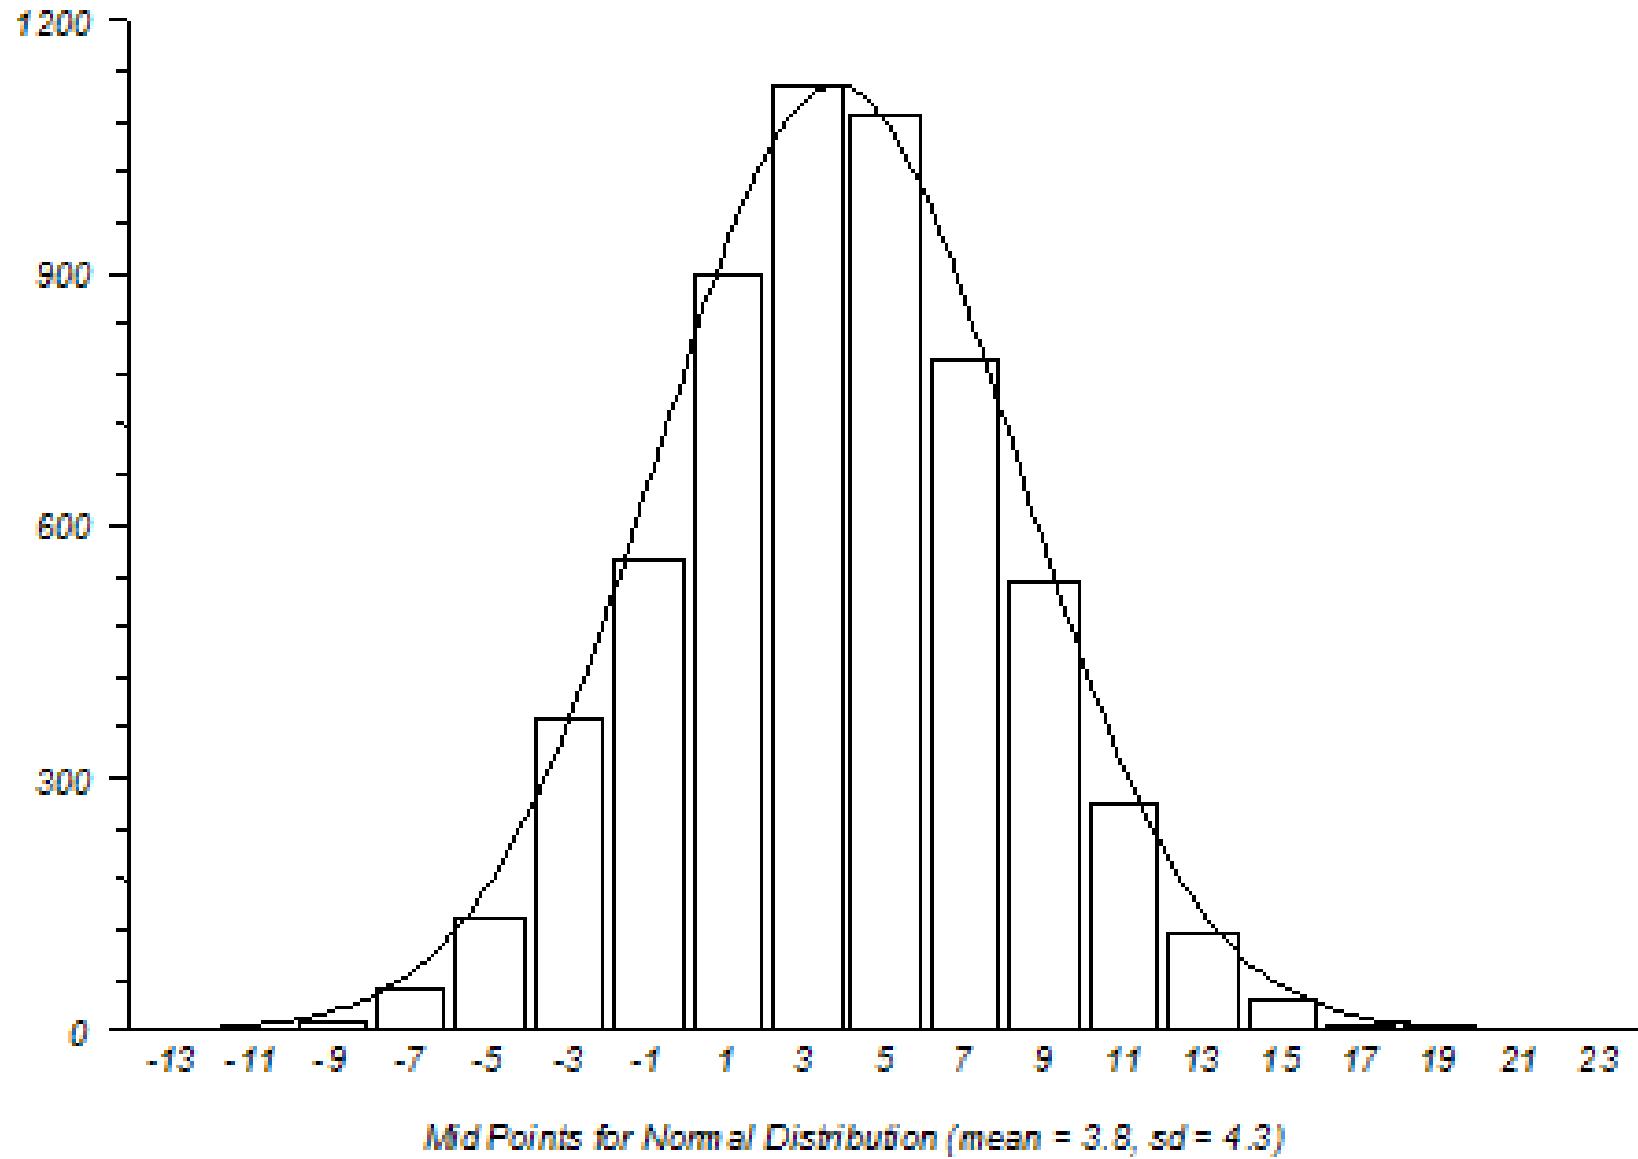
- Zvláštní (standardizovaná) podoba transformace na pořadí
  - Používá se při tvorbě norem psychodiagnostických metod a ve výběrových testech
-

# Psychodiagnostická kalkulačka

---

- Převody různých skórů online.
  - Nástroj vyuvíjí Hynek Cígler a Martin Šmíra
  - <http://kalkulacka.testforum.cz/transformace-skoru>
-

Histogram for Normal Distribution (mean = 3.8, sd = 4.3)



# Normální rozložení

## Gaussovo, bell-curve

---

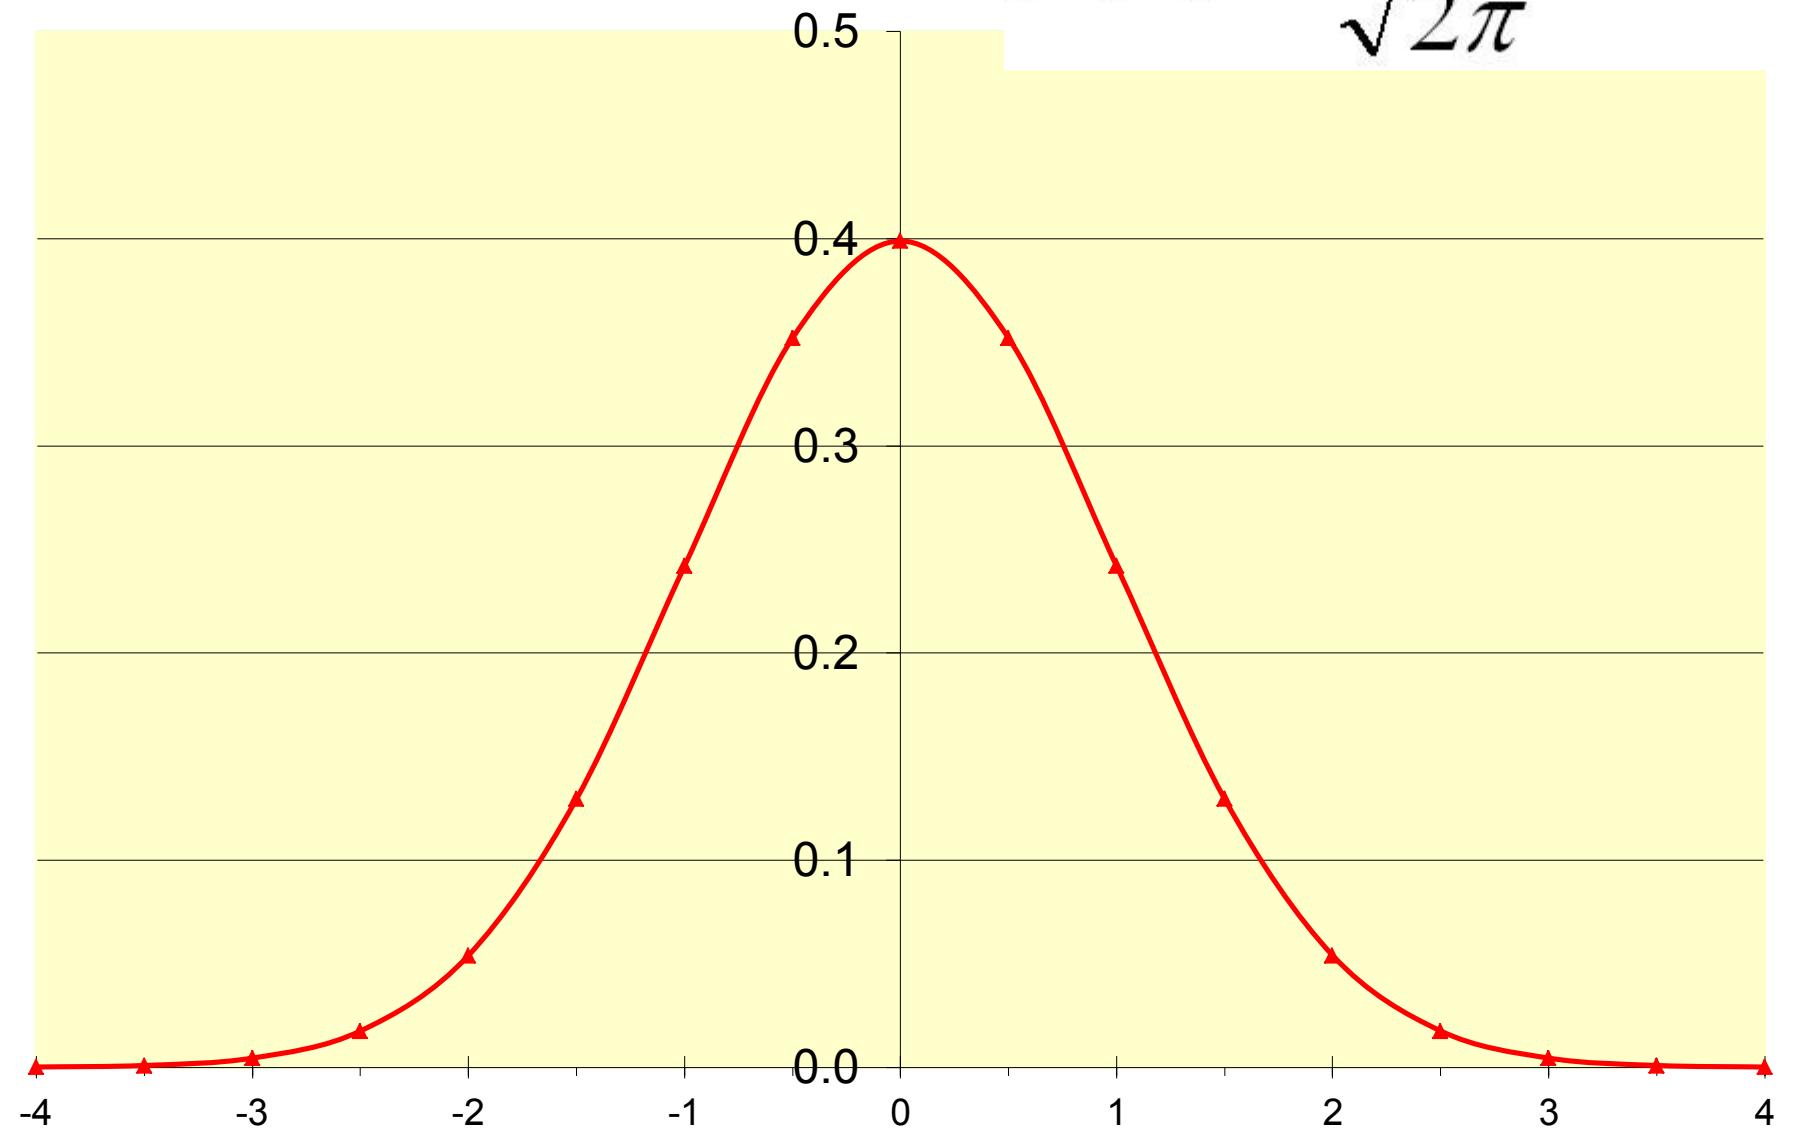
### □ Rozložení...

- ...náhodných chyb
- ...jevů v přírodě ovlivněných mnoha nezávislými faktory

### □ Dlouhá historie – od 17. stol.

- DeMoivre – sázení
  - Laplace a Gauss – chyby v astronomických pozorováních
  - Quetelet – lidi, *l'homme moyen*, BMI
-

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(\mu-x)^2}{2\sigma^2}}$$



# K čemu/proč normální rozložení?

---

- Mnoho proměnných je takto rozloženo
    - Můžeme pak hádat, kolik jakých hodnot v populaci je
  - Mnoho statistických postupů s normálním rozložením pracuje
    - v různých modifikacích a rolích
-

# Vlastnosti normálního rozložení

[https://en.wikipedia.org/wiki/Normal\\_distribution](https://en.wikipedia.org/wiki/Normal_distribution)

---

- Symetrické, unimodální
  - Průměr=medián=modus
  - V hodnotách  $M \pm SD$  se mění prohnutí
  - Je-li  $SD = 1$ , pak plocha pod křivkou je 1
  - Zešikmení (skewness) je 0
  - Strmost (kurtosis) je 3
    - často se prezentuje hodnota K-3
  - *Forma, od níž odrážíme popis pozorovaných rozložení*
- 

$$\text{Skewness} = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{SD(x)} \right)^3$$

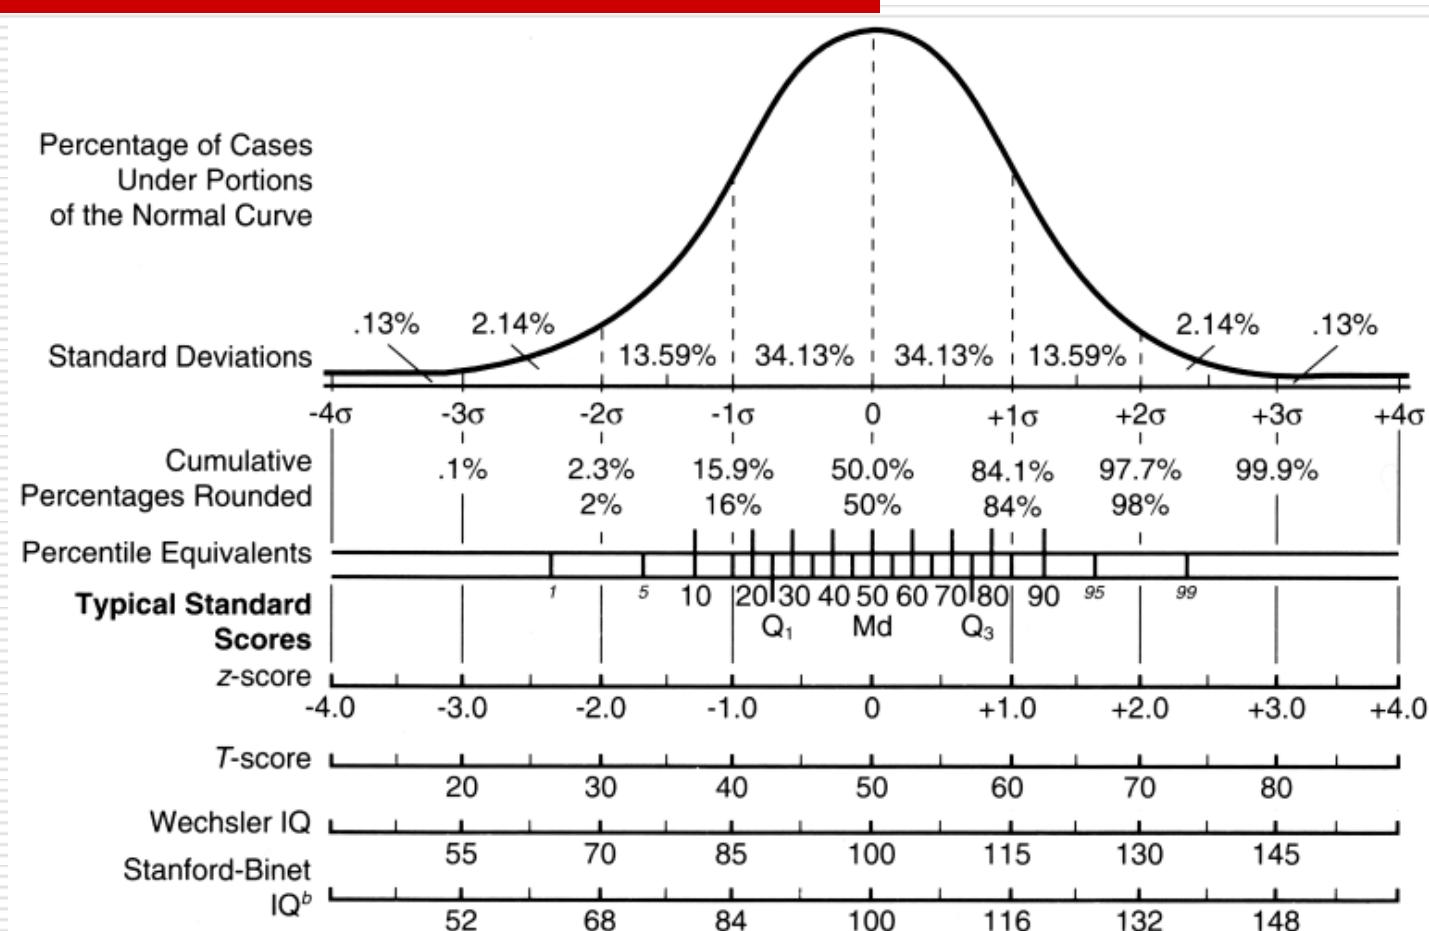
$$\text{Kurtosis} = \frac{1}{n} \sum_{i=1}^n \left( \frac{x_i - \bar{x}}{SD(x)} \right)^4$$

# Mnohost normálních rozložení

---

- Jeden tvar, ale různé umístění na různých škálách ( $M$ ) a různé roztažení ( $SD$ )
  - <http://www.intmath.com/counting-probability/normal-distribution-graph-interactive.php>
- Standardizované rozložení  $N(0,1)$ 
  - tj. převedení normálně rozložené proměnné na z-skóry

# Kvantily standardního normálního rozložení $N(0;1)$ alias oblasti pod křivkou normálního rozložení



# Kvantily přesněji v MS Excel

---

- NORM.S.DIST( $z;1$ ) – udává percentil odpovídající zadanému  $z$ -skóru, tj. kolik lidí má  $z$ -skór roven  $z$  nebo menší
  - Procento lidí v rozmezí  $z$ -skórů =  $\text{NORM.S.DIST}(\text{vyšší } z;1) - \text{NORM.S.DIST}(\text{nižší } z;1)$
- NORM.S.INV( $p$ ) – udává  $z$ -skór odpovídající zadanému percentilu

Bez toho S. poskytují funkce tutéž informaci pro normální rozložení s jiným M a SD

---

# Kvantily přesněji postaru

Table A-1

The Standard Normal Distribution

<i>z</i>	<b>0.00</b>	<b>0.01</b>	<b>0.02</b>	<b>0.03</b>	<b>0.04</b>	<b>0.05</b>	<b>0.06</b>	<b>0.07</b>	<b>0.08</b>	<b>0.09</b>
<b>0.0</b>	0.5000	0.4980	0.4960	0.4940	0.4920	0.4901	0.4881	0.4871	0.4861	0.4851
<b>0.1</b>	0.4802	0.4552	0.4522	0.4483	0.4443	0.4404	0.4364	0.4325	0.4286	0.4247
<b>0.2</b>	0.4207	0.4169	0.4129	0.4089	0.4052	0.4013	0.3974	0.3936	0.3897	0.3859
<b>0.3</b>	0.3821	0.3783	0.3745	0.3707	0.3669	0.3632	0.3594	0.3557	0.3520	0.3483
<b>0.4</b>	0.3446	0.3409	0.3372	0.3336	0.3300	0.3264	0.3228	0.3192	0.3156	0.3121
<b>0.5</b>	0.3065	0.3050	0.3015	0.2981	0.2946	0.2912	0.2877	0.2843	0.2810	0.2776
<b>0.6</b>	0.2743	0.2709	0.2676	0.2643	0.2611	0.2578	0.2546	0.2514	0.2483	0.2451
<b>0.7</b>	0.2429	0.2399	0.2369	0.2337	0.2296	0.2266	0.2236	0.2206	0.2177	0.2148
<b>0.8</b>	0.2119	0.2080	0.2041	0.2003	0.1965	0.1927	0.1889	0.1852	0.1814	0.1777
<b>0.9</b>	0.1841	0.1814	0.1788	0.1762	0.1736	0.1711	0.1685	0.1660	0.1635	0.1611
<b>1.0</b>	0.1587	0.1562	0.1539	0.1515	0.1492	0.1469	0.1446	0.1423	0.1401	0.1379
<b>1.1</b>	0.1357	0.1335	0.1314	0.1292	0.1271	0.1251	0.1230	0.1210	0.1190	0.1170
<b>1.2</b>	0.1151	0.1131	0.1112	0.1093	0.1075	0.1056	0.1038	0.1020	0.1003	0.0985

# Statistické zkratky a značky

---

- různé systémy, je třeba dobře popisovat
- $N, n$  = velikost vzorku, podvzorku(skupiny)
- $X_i$  = skór i-té osoby u proměnné  $X$
- $x_i$  = deviační skór, odchylka od průměru
- $M, m, \bar{x}$  = průměr
- $SD, s$  = směrodatná odchylka
- $VAR, s^2$  = rozptyl



**Yo Momma  
is so Mean,  
she has no  
Standard Deviation**