

# Izlases, populācijas un centrālā robežteorēma

Māra Vēliņa, pētniece, LU FMF

Mazā Matemātikas Universitāte, 03.02.2018

# LU FMF Statistikas un datu analīzes laboratorija

Izveidota 2017.gadā LU Fizikas un matemātikas fakultātē

## Vadītājs

*Jānis Valeinīs, asoc. prof,  
PhD Stat*

## Doktorantūras grupa

*Māra Vēliņa, Artis Luguzis,  
Līga Bethere, Leonora Pahirko*

## Citi

*Dmitrijs Kašs, MBA*



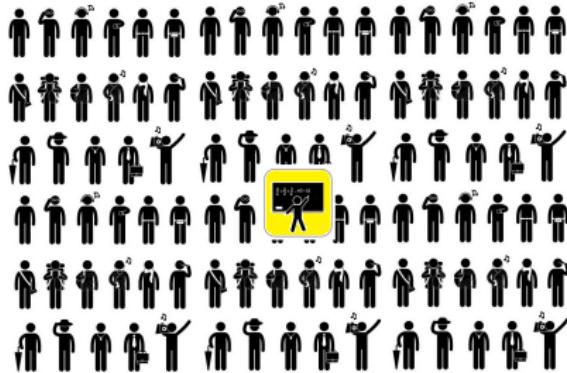
## Laboratorijas mērķi

- ▶ **Īstenot koppētījumus** dzīvības zinātņu, ekonomikas, socioloģijas u.c. jomās LU,
- ▶ **Konsultēt LU pētniekus un studentus**, kā arī **privātus uzņēmumus** ar statistisko analīzi saistītos jautājumos,
- ▶ **Iesaistīt LU FMF studentus** pētniecības darbā.
- ▶ **Līdzšinējā sadarbība:** LU Datorikas un medicīnas fakultātes, RTU, Latvijas Vides, ģeoloģijas un meteoroloģijas aģentūra, Eiropas Hitu radio, u.c.

# Ievada piemērs: Aptauja par matemātiku

- ▶ Vēlamies uzzināt:

*Cik lielā mērā Latvijas vidusskolēniem patīk matemātika?*



- ▶ Latvijā ir **36820 vidusskolēni**<sup>1</sup> -
  - ▶ Gandrīz neiespējami aptaujāt visus skolēnus!
- ▶ Nolejam aptaujāt **200 skolēnus** -
  - ▶ Vai tam ir jēga?..

---

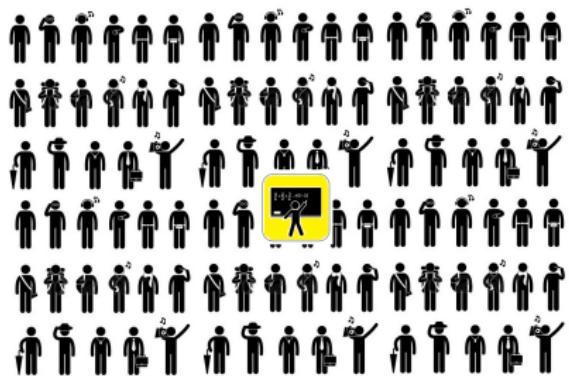
<sup>1</sup>2017. gada 1. septembrī

## Lekcijas saturs

- ▶ Izlase un populācija,
- ▶ Aprakstošā un secinošā statistika,
- ▶ Izlases veidošanas principi,
- ▶ Ilases sadalījumi,
- ▶ Normālais sadalījums,
- ▶ Centrālā robežteorēma un tās pielietojums.

Izlase un populācija

# Izlase un populācija



Visi 36820 skolēni - POPULĀCIJA



200 skolēni - IZLASE

- ▶ **Populācija** (jeb *ģenerālkopa*) ir visu pētāmo elementu kopums (visi vidusskolēni),
- ▶ **Izlase** ir populācijas apakškopa, kas atlasīta praktiskai novērošanai (200 aptaujātie vidusskolēni).

## Izlase



200 skolēni

- ▶ Var pētīt dažādas **pazīmes**, izdarot izlases elementu mērījumus:
  - ▶ **kvantitatīvas pazīmes**: skolēnu augums, vecums, atzīme matematikā,
  - ▶ **kvalitatīvas pazīmes**: dzimums, apmeklētā skola, utt.
- ▶ Izlases pazīmēm var aprēķināt dažādus skaitliskus lielumus:
  - ▶ *centrālās tendences* mēri: (aritmētiskais) vidējais, moda, mediāna,
  - ▶ *izkliedes* mēri: amplitūda, standartnovirze,
  - ▶ *pazīmju saistības analīze*: korelācijas koeficients.
- ▶ Šos lielumus sauc par **aprakstošās statistikas mēriem** jeb vienkārši **statistikām**.

## Centrālā tendēncija: izlases (aritmētiskais) vidējais

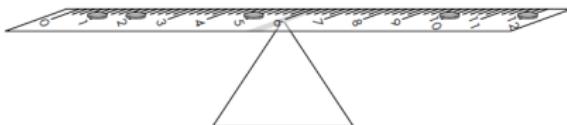
- ▶ **Izlases (aritmētiskais) vidējais**  $\bar{x}$  ir novērojumu summa, dalīta ar to novērojumu skaitu izlasē,  $n$ :

$$\bar{x} = \frac{\sum x_i}{n}$$

- ▶ Piemērs. Pieci cilvēki atrisināja mīklu 5, 2, 12, 1 un 10 sekundēs. Tad, *izlases vidējais* risināšanas laiks ir

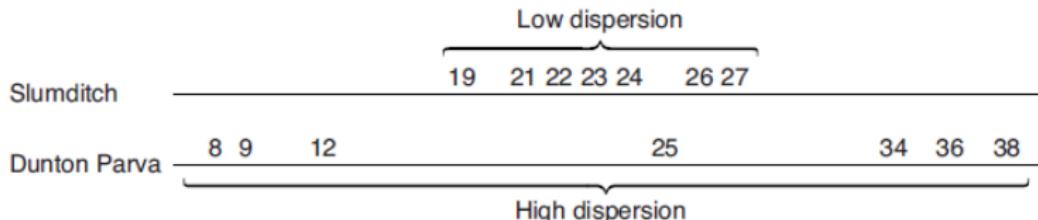
$$\bar{x} = \frac{5 + 2 + 12 + 1 + 10}{5} = 6 \text{ sekundes.}$$

- ▶ Izlases vidējais ir *tipisks novērojums* jeb *balansa punkts* starp izlases novērojumiem!



## Dispersijas mēri: Izlases standartnovirze

- ▶ Izlases **dispersijas mēri** raksturo, cik tuvu novērojumu vērtības izkliedētas ap izlases centru.
- ▶ **Piemērs.** Viedokļa aptaujas rezultāti par lapsu medībām divos Anglijas ciematos:



- ▶ Slumditch ciematā viedokli ir ar *zemu dispersiju (izkliedi)*, taču Dunton Parva ciematā - ar *augstu dispersiju!*
- ▶ Bieži izmantots izkliedes mērs ir **izlases standartnovirze**:

$$s = \sqrt{s^2} = \sqrt{\frac{\sum(x_i - \bar{x})^2}{n - 1}}$$

# Aprakstošā un secinošā statistika

- ▶ **Aprakstošā statistika** sniedz izlases elementu vienkāršus raksturlielumus (skaitliskus vai vizuālus), pētot izlasi pēc vienas vai vairākām pazīmēm.
  - ▶ aprakstošā statistika raksturo izlasi!
- ▶ **Secinošā statistika** palīdz izdarīt secinājumus par visu pētāmo elementu kopumu jeb populāciju.
  - ▶ veic prognozes, veido dažādus modeļus!
  - ▶ galvenais pētnieku mērķis!
- ▶ Secinošās statistikas metodes ir **novērtēšana** un **hipotēžu pārbaude**.
  - ▶ Šodien aplūkosim **novērtēšanu**!

# No izlases uz populāciju

Izlase	→	Populācija
Statistikas latīņu burti	SECINOŠĀ STATISTIKA →	Parametri grieķu burti
$\bar{x}$ =izlases vidējais		$\mu$ =populācijas vidējais
$s$ = izlases standartnovirze		$\sigma$ =populācijas standartnovirze

## Piemērs: Aptauja par matemātiku (turpinājums)

Pieņemsim, ka tika sastādīta *reprezentatīva izlase* no 200 vidusskolēniem, un tika uzdots jautājums:

- ▶ **Kā Tev patīk matemātikas priekšmets? Atbildi skalā no 0 līdz 10, kur**
  - ▶ **0** nozīmē *nemaz nepatīk*,
  - ▶ **10** nozīmē *mīļākais priekšmets*.

0 1 2 3 4 5 6 7 8 9 **10**

- ▶ Tā kā šis ir **kvantitatīvs** mainīgais,
  - ▶ aprēķinām *izlases vidējo*, pieņemsim, ka iegūstam punktu skaitu
  - ▶  $\bar{x} = 6,12$
- ▶ BET: kāds ir *visu vidusskolēnu (populācijas)* videjais punktu skaits?
  - ▶  $\mu = ?$
  - ▶ Atbildi var sniegt *secinošā statistika*.

Atlasses principi

## Gadījumizlase

Izlase ir *populācijas apakškopa*, bet svarīgi, lai tā *labi reprezentētu populāciju*.

- ▶ **Vienkārša gadījumizlase** ir izlase, kur ikvienam populācijas elementam pastāv vienāda iespēja tikt iekļautam izlasē.
  - ▶ sastādīt visu 36820 Latvijas vidusskolēnu sarakstu (**atlases ietvars**),
  - ▶ likt datoram **nejauši izlozēt** 200 skaitlus no 36820,
  - ▶ izvēlēties **aptaujas metodi** - klātienes vai telefona intervija, aptauja internetā utml.,
  - ▶ aptaujāt izlozētos vidusskolēnus un **aprēķināt izlases statistikas**.

# Sistemātiskās klūdas

- ▶ Pārkļajuma klūda
  - ▶ sastādītais vidusskolēnu saraksts nav pilnīgs,
- ▶ Atlases klūda
  - ▶ visiem elementiem nav vienāda varbūtība ieklūt izlasē,
  - ▶ piemēram, t.s. ērtības izlase - "nejauša" aptauja uz ielas,
- ▶ Nerespondences (neatbildētības) klūda
  - ▶ atteikšanās atbildēt uz jautājumu
- ▶ Respondences klūda
  - ▶ sociāli vēlamu atbilžu sniegšana

**Mērķis:** Sastādīt vienkāršu gadījumizlasi un pēc iespējas samazināt sistemātisko klūdu iespējamību!

- ▶ Izveidot nejaušu gadījumizlasi ir teju neiespējami...

# Nejaušas gadījumizlases alternatīvas

## 1. Ligzdveida izlase

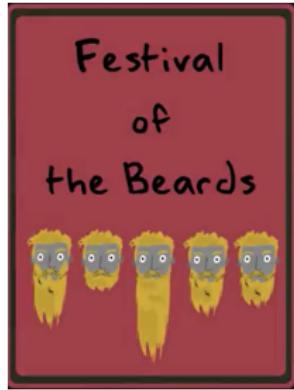
- ▶ Sadala populāciju *līdzīgu elementu apakškopās* (**ligzdas**), piemēram skolas, nami, preču kastes,
- ▶ Nejauši atlasa noteiktu ligzdu skaitu un apseko visus tās elementus.

## 2. Stratificētā izlase

- ▶ Sadala populāciju *atšķirīgu elementu apakškopās* (**stratas**), piemēram, vidusskolas klase, preču partija,
- ▶ nejauši atlasa noteiktu elementu skaitu no katras stratas, kas ir proporcionāls stratas lielumam populācijā.

Izlases sadalījumi

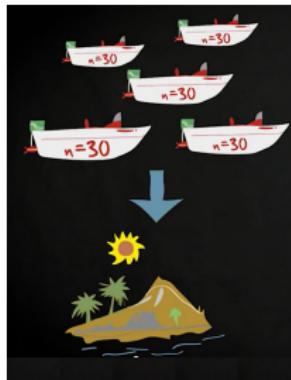
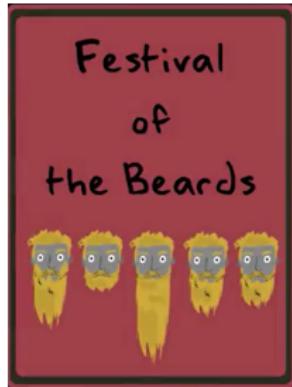
## Piemērs: bārdaiņu festivāls<sup>2</sup>



- ▶ Pieņemsim, ka Oslo pilsētā uz kādas salas tiek rīkots bārdaiņu festivāls

<sup>2</sup>W.W. Norton. Naked Statistics: Stripping the Dread from the Data. 2013

## Piemērs: bārdaiņu festivāls



- ▶ Tieki pārdotas ~ 5000 biletēs
- ▶ Sadala dalībniekus laivās pa 30 dalībniekiem
- ▶ Pieņemsim, ka mēs zinām, ka vidējais festivāla dalībnieku bārdas garums  $\mu = 10.3\text{mm}$ .

# Piemērs: bārdaiņu festivāls



Piemērs: Vidējais bārdas garums laivā

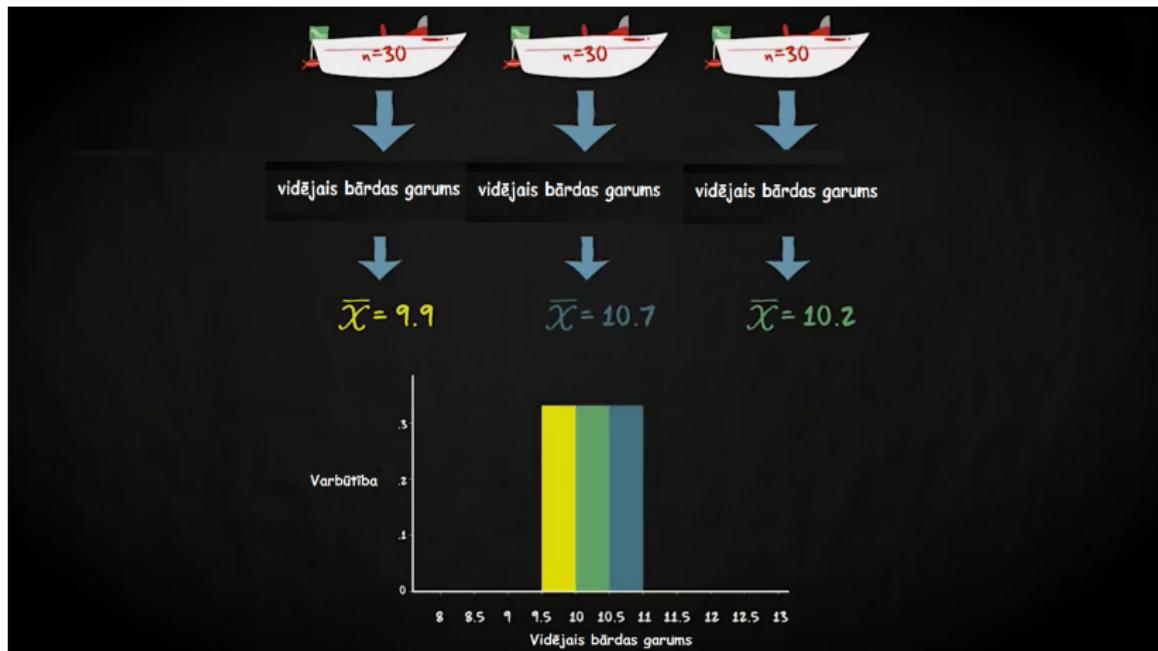


# Piemērs: Vidējais bārdas garums laivā



## Piemērs: Vidējais bārdas garums laivā

- Aplūkosim vidējo vērtību sadalījumu **3 laivām**:



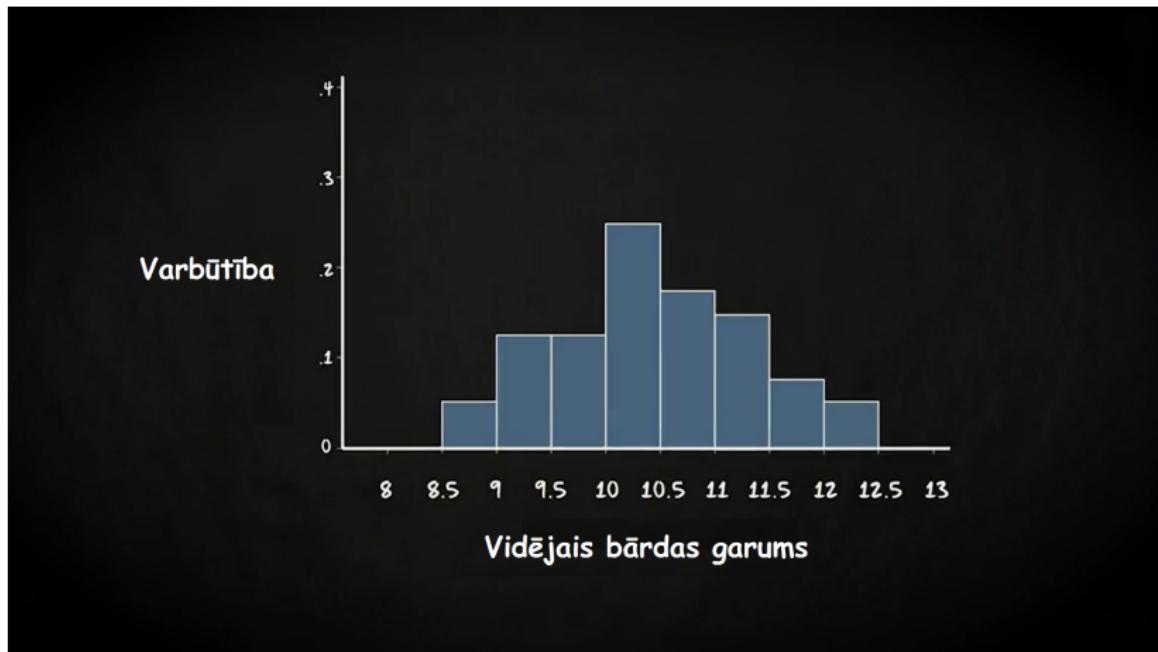
## Piemērs: Vidējais bārdas garums laivā

- ▶ Aplūkosim vidējo vērtību sadalījumu **15 laivām**:



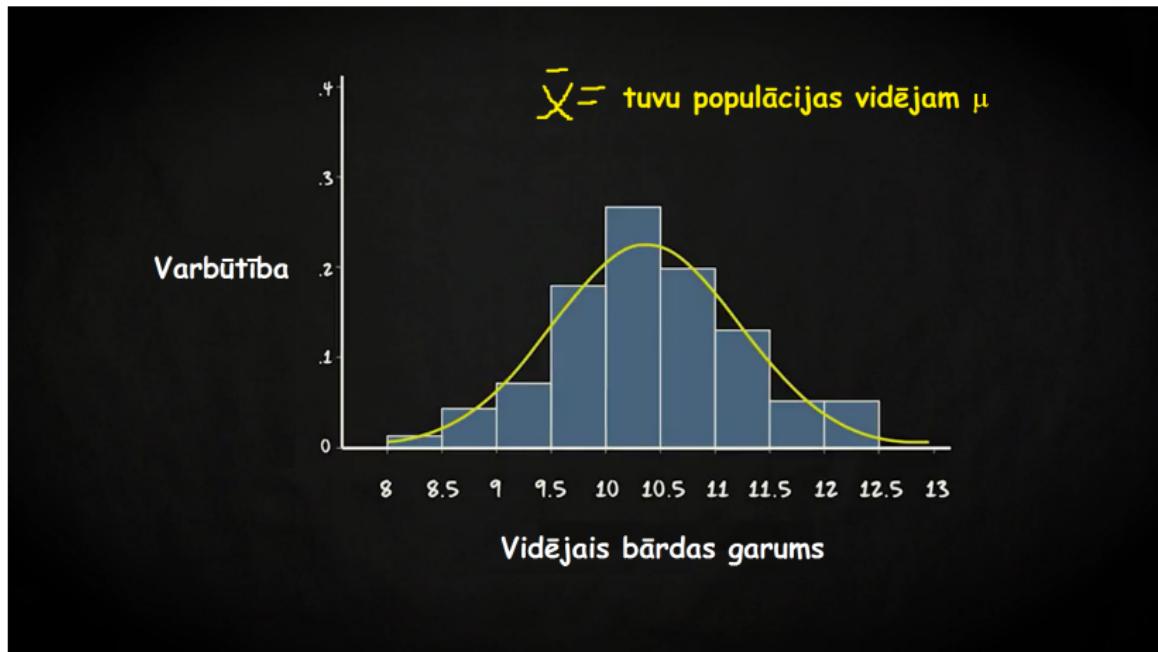
## Piemērs: Vidējais bārdas garums laivā

- ▶ Aplūkosim vidējo vērtību sadalījumu **40 laivām**:



## Piemērs: Vidējais bārdas garums laivā

- ▶ Aplūkosim vidējo vērtību sadalījumu **100 laivām**:



- ▶ Vidējo vērtību **sadalījuma forma** tiecas uz īpašu **zvanveida** jeb **Gausa funkciju!**

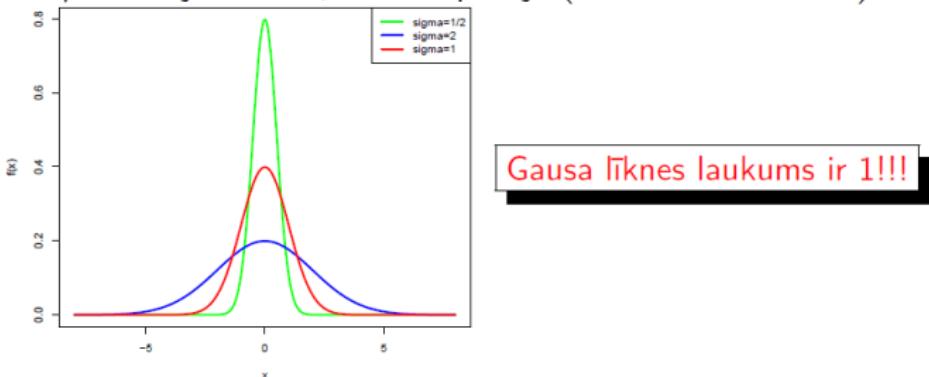
Normālais jeb Gausa sadalījums

## Normālais sadalījums

Daudzi procesi dabā pakļaujas normālajam (**Gausa**) sadalījumam.  
Normālā sadalījuma *blīvuma funkcija*:

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

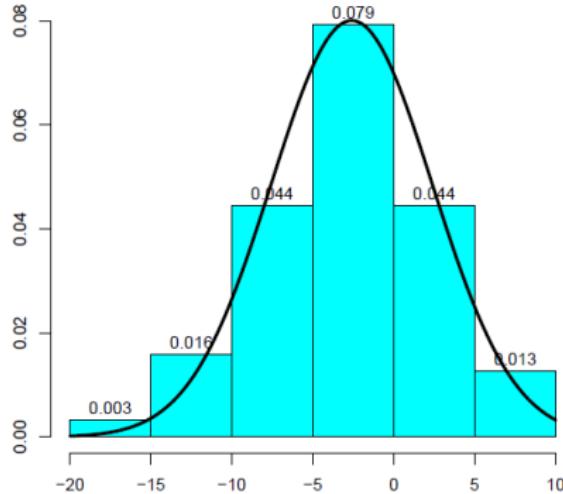
kur  $\mu$  – vidējā vērtība,  $\sigma^2$  – dispersija ( $\sigma$  – standartnovirze).



Piemēram:  $\mu$  – vidējā temperatūra,  $\sigma^2$  – izkliede ap vidējo temperatūru.

## Normālais sadalījums

Gaisa temp. 3. marts



Vidējā temperatūra:

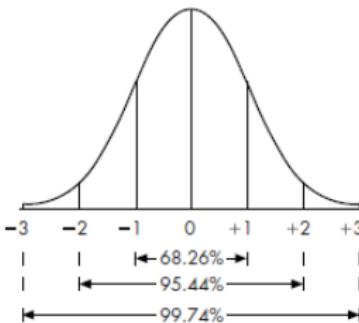
$$\mu = -2,6^{\circ}\text{C}$$

Standartnovirze:  $\sigma \approx 4,98^{\circ}\text{C}$

Ja gadījuma lielums  $X$  ir normāli sadalīts, to pieraksta

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

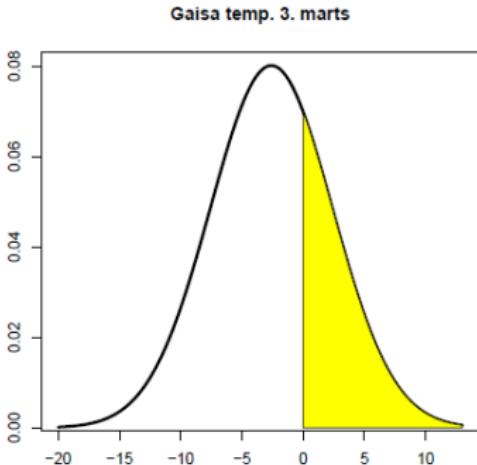
## Trīs sigma likums



- ▶ Normālajam sadalījumam ir spēkā:
  - ▶ **68.2%** no novērojumiem atrodas intervalā  $+/-$  **vienu standartnovirzi** no vidējā,
  - ▶ **95.4%** no novērojumiem atrodas intervalā  $+/-$  **divas standartnovirzes** no vidējā,
  - ▶ **99.7%** no novērojumiem atrodas intervalā  $+/-$  **trīs standartnovirzes** no vidējā.
- ▶ **Sekas.** Ja dati ir *aptuveni normāli sadalīti*, gandrīz visas datu vērtības atrodas  $\pm 3$  standartnoviržu attālumā no vidējā!
- ▶ **Piezīme.** Šie procenti raksturo *laukumu zem Gausa līknēs* jeb *varbūtību* novērojumam piederēt konkrētajam intervālam.

## Laukums zem līknes: Piemērs

- ▶ Izmantojot blīvuma funkciju, laukumu zem līknes jeb varbūtību iespējams aprēķināt *jebkuram* brīvi izvēlētam intervālam!
- ▶ Kāda ir varbūtība, ka gaisa temperatūra 3. martā pārsniedz  $0^{\circ}\text{C}$ ?
  - ▶ Ja  $\mu = -2.6$  un  $\sigma = 4.9$ , tad
  - ▶  $P(X > 0) = 0.3$ .

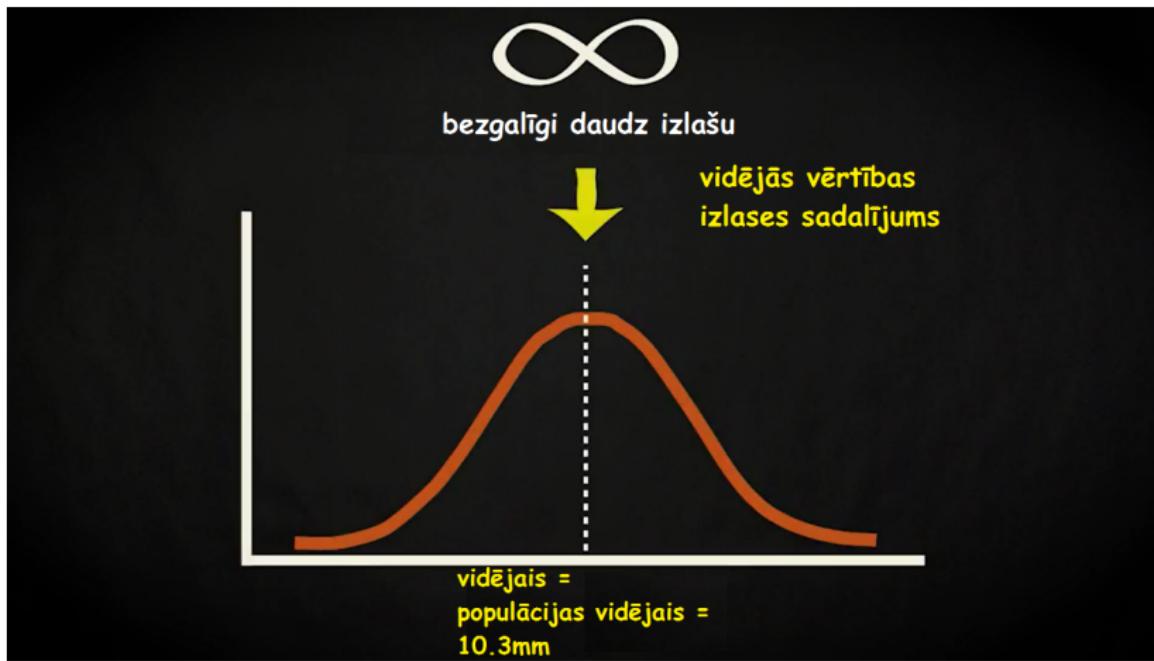


$$P(X > 0) = 0.3$$

Saliekot visu kopā... Centrālā robežteorēma

## Vidējās vērtības izlases sadalījums

- ▶ Sadalījumu, kas raksturo visas vērtības, kādas var pieņemt izlases vidējais, sauc par **vidējās vērtības izlases sadalījumu** izlasēm ar apjomu  $n$ .



## Centrālā robežteorēma

**Centrālā robežteorēma.** Pie nosacījuma, ka  $n$  ir pietiekoši liels, vidējās vērtības izlases sadalījums ir normālais, t.i.,

$$\bar{X} \sim N(\mu, \sigma^2/n),$$

kur  $\mu$ -populācijas vidējā vērtība,  $\sigma$  - populācijas standartnovirze.

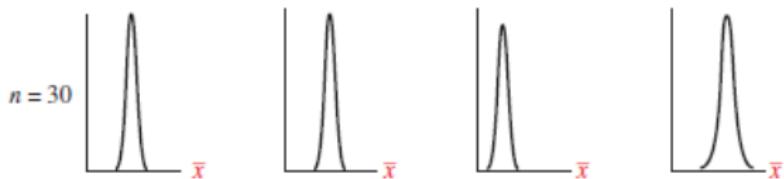
- ▶ 1. Piezīme. Izlases sadalījuma standartnovirze ir vienāda ar  $\sigma/\sqrt{n}$ . Šo lielumu sauc par **vidējās vērtības standartklūdu** ( $se$ ).
- ▶ 2. Piezīme. CRT ir ļoti spēcīgs rezultāts, jo tā ir **spēkā jebkurai populācijai ar galīgu standartnovirzi** ( $\sigma < \infty$ ), neatkarīgi no populācijas sadalījuma veida!

CRT ir spēkā neatkarīgi no populācijas sadalījuma veida!

Populācijas sadalījuma forma



Vidējās vērtības izlases sadalījuma forma



Centrālās robežteorēmas pielietojums:  
Ticamības intervāli

## Vidējās vērtības variācija

- ▶ Centrālā robežteorēma ļauj kvantificēt *vidējās vērtības variāciju*, ko izsaka ar *standartklūdu*:

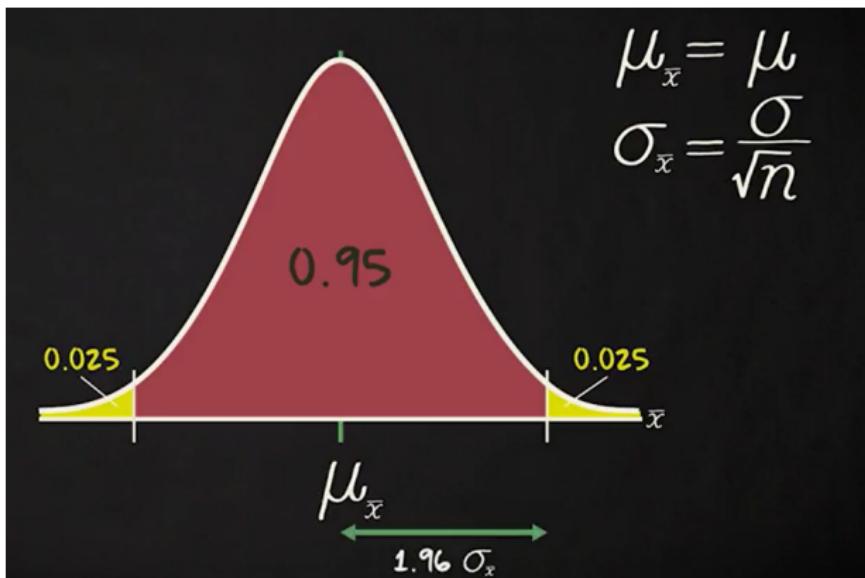
$$se = \frac{\sigma}{\sqrt{n}}$$

- ▶ *Vidējās vērtības standartklūda* ir atkarīga no:
  - ▶ Populācijas standartnovirzes:  $\sigma \uparrow se \uparrow$ ,
  - ▶ Izlases apjoma:  $n \uparrow se \downarrow$ .

## Ticamības intervāli

- ▶ Ideja: uzdot vērtību intervālu, kurā ar kādu noteiktu *ticamības līmeni* atrodas populācijas vidējais
- ▶ Vēl viens veids kā novērtēt populācijas parametru  $\mu$ !
- ▶ Izvēlas ticamības līmeni tuvu 1, visbiežāk, 0.95.
- ▶ Izmantosim **centrālo robežteorēmu!**

## Ticamības intervāli



- ▶ Saskaņā ar **normālā sadalījuma īpašībām**, 95.4% novērojumu atrodas  $\pm 2$  **standartnovirzes** attēlumā no vidējā.
- ▶ Saskaņā ar **CRT** un normālā sadalījuma īpašībām\*, **tieši 95%** **vērtību** atrodas  $\pm 1.96$  standartnoviržu  $\sigma/\sqrt{n}$  attēlumā no  $\mu$ .

## Ticamības intervāla konstruēšana, kad $\sigma$ zināms

- ▶ Pieņemsim, ka populācijas standartnovirze  $\sigma$  **ir zināma**.
- ▶ Tad, **95% ticamības intervāls populācijas vidējai vērtībai ir formā**

$$\left( \bar{x} - 1.96 \frac{\sigma}{\sqrt{n}}; \bar{x} + 1.96 \frac{\sigma}{\sqrt{n}} \right).$$

- ▶ Iespējams konstruēt arī  $\alpha\%$  **ticamības intervālus**:

$$\left( \bar{x} - z_\alpha \frac{\sigma}{\sqrt{n}}; \bar{x} + z_\alpha \frac{\sigma}{\sqrt{n}} \right),$$

+ $z_\alpha$  ir **normālā sadalījuma kvantile**, piem.:

Tic. līmenis $\alpha$	$z_\alpha$
0,9	1,65
0,95	1,96
0,99	2,58

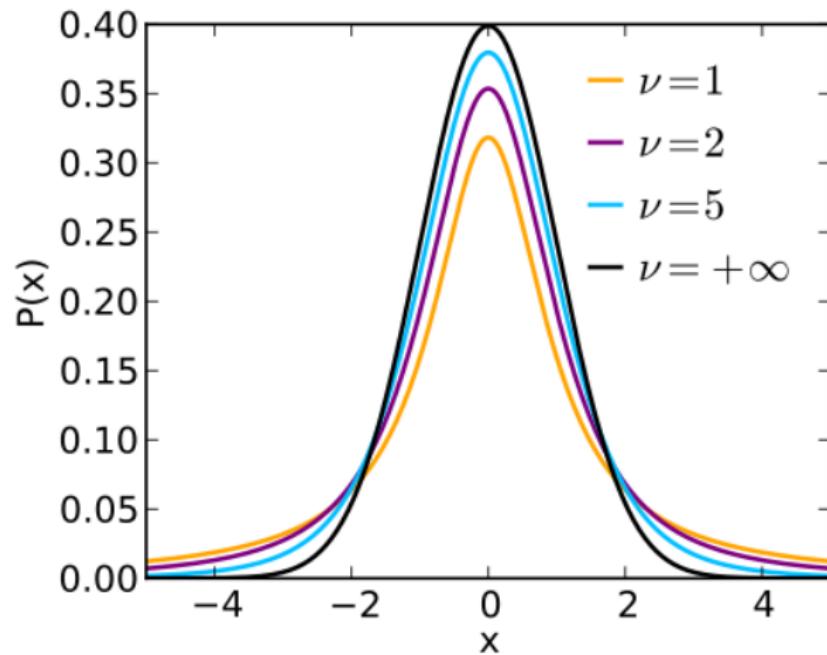
## Piemērs. Aptauja par matemātiku

- ▶ Aptaujājot 200 skolēnu *reprezentatīvu izlasi*, tika iegūts vidējais punktu skaits  $\bar{x} = 6,12$ .
- ▶ Pieņemsim, ka pirms gada *jau bija veikts plāss pētījums* par skolēnu attieksmi pret matemātiku, kur tika noskaidrots, ka
  - ▶  $\sigma = 1,12$
- ▶ Aprēķināt **95% ticamības intervālu** populācijas vidējai vērtībai  $\mu$ !
  - ▶  $n = 200$
  - ▶  $\sigma/\sqrt{n} = 1,12/\sqrt{200} = 0,079$
  - ▶  $z_{0.95} = 1,96$
  - ▶ Ticamības intervāls ir
$$(6,12 - 1,96 \cdot 0,079; 6,12 + 1,96 \cdot 0,079) = (5,97; 6,27)$$
- ▶ **Interpretācija.** Ar 95% pārliecību varam teikt, ka visu Latvijas vidusskolēnu vidējā attieksme pret matemātiku 10 punktu skalā pieder intervālam (5,97; 6,27).

## Ticamības intervāla konstruēšana, kad $\sigma$ nav zināma

- ▶ Visbiežāk, populācijas standartnovirze  $\sigma$  **nav zināma!**
- ▶ Novērtē  $\sigma$  ar **izlases standartnovirzi**  $s$ .
  - ▶ Rodas *papildus nenoteiktība*!
- ▶ Tādēļ,  $\bar{x}$  sadalījumu raksturo nevis normālais sadalījums, bet **Stjūdenta t-sadalījums!**

## Stjūdenta t-sadalījums



- ▶ Parametrs  $\nu$  raksturo **brīvības pakāpes**,  $\nu = n - 1$ .
- ▶ Tātad, katram izlases apjomam ir *cits Stjūdenta t-sadalījums!*
- ▶ \*Kas bija Stjūdents?
  - ▶ Viljams Gosets, kas strādāja Ginesa alusdarītavā, tāpēc

## Ticamības intervāls balstīts uz Stjūdenta sadalījumu

- ▶ Ticamības intervāls ir formā:

$$\left( \bar{x} - t_{\alpha, n-1} \frac{s}{\sqrt{n}}; \bar{x} + t_{\alpha, n-1} \frac{s}{\sqrt{n}} \right),$$

kur  $t_{\alpha, n-1}$  ir Stjūdenta sadalījuma  $\alpha$  kvantile!

## Piemērs. Holesterīna līmenis asinīs

- ▶ Pētnieki vēlējās noteikt vidējo holesterīna līmeni smēķējošiem vīriešiem ar paaugstinātu asinsspiedienu.
- ▶ Tika izveidota 12 vīriešu izlase un iegūts
  - ▶ izlases vidējais  $\bar{x} = 217\text{mg}/100\text{ml}$ ,
  - ▶ izlases standartnovirze  $s = 46\text{mg}/100\text{ml}$ .
- ▶ Aprēķināt 95% ticamības intervālu **populācijas vidējam holesterīna līmenim** smēķējošiem vīriešiem ar paaugstinātu asinsspiedienu!
- ▶ Tabulā atrod  $t_{0,95,11} = 2,20$ ,
- ▶ Ticamības intervāls:

$$(217 - 2,2 \cdot 46/\sqrt{12}; 217 + 2,2 \cdot 46/\sqrt{12}) = (187,8; 246,2).$$