

---

# ***Tilastolliset menetelmät***

## **Osa 1: Johdanto**

- **Johdanto tilastotieteeseen**

# Mitä tilastotiede on?

---

- Tilastotiede kehittää ja soveltaa menetelmiä ja malleja, joiden avulla reaali maailman ilmiöistä voidaan tehdä johtopäätöksiä tilanteissa, joissa ilmiöitä koskeviin tietoihin liittyy epävarmuutta ja satunnaisuutta.
- Koska tietoihin liittyy epävarmuutta tai satunnaisuutta tilastolliset menetelmät ja mallit perustuvat todennäköisyyslaskentaan.
- Tilastotiede on todennäköisyyslaskennan tärkeimpiä sovellusalueita.

# Mitä tilastotiede on?

---

- Tilastotiedettä voidaan soveltaa kaikkialla missä tuotetaan reaailmailmaa ja sen ilmiöitä kuvaavaa numeerista tai kvantitatiivista tietoa. Jokainen empiirisen tutkimuksen havaintoaineisto on tilastotieteen tutkimuksen mahdollinen kohde.

# Tilastollinen aineisto

---

- Tilastollisen tutkimuksen *kaikki mahdolliset kohteet* muodostavat tutkimuksen (**kohde-**) **perusjoukon**.
- Tutkimuksen kohteiksi valittuja perusjoukon alkioita kutsutaan **havaintoyksiköiksi**.
- **Tilastollinen aineisto** koostuu havaintoyksiköitä kuvaavien muuttujien **havaituista arvoista**.

# Tilastollisen kuvailun ja päättelyn menetelmiä

---

- Kuvailun menetelmiä:
  - Tilastografiikka
  - Tilastolliset tunnusluvut
  - Tilastolliset mallit
- Päättelyn menetelmiä:
  - Tilastolliset mallit
  - Tilastollinen estimointi
  - Tilastollinen testaus

# Aineiston kerääminen

---

- Kohdistuuko tutkimus koko perusjoukkoon vai vain johonkin sen osaan?
  - Jos tutkimuksen kohteena on koko perusjoukko, tutkimusta kutsutaan **kokonaistutkimukseksi**, muuten kyseessä on **otantatutkimus**.
- Muutetaanko tutkimuksessa aktiivisesti tutkimuksen kohteiden olosuhteita?
  - Tutkimus on **koe**, jos tutkitaan olosuhteiden aktiivisen muuttamisen vaikutusta tutkimuksen kohteisiin.
  - Jos olosuhteita ei muuteta aktiivisesti, sanomme, että tutkimus perustuu **suoriin havaintoihin**.

# Kontrolloidut kokeet

---

- Kokeessa ei voida tehdä luotettavia johtopäätöksiä, ellei koe ole kontrolloitu:
  - Kokeessa on vertailtava vähintään kahden erilaisen käsittelyn vaikutuksia.
  - Käsittelyjen kohdistamisessa on käytettävä satunnaistusta.
  - Kokeessa on tehtävä riittävästi koetoistoja.
- Jos koe on kontrolloitu, koetuloksien analysointi tilastotieteen keinoin on mahdollista. Kutsumme kontrolloituja kokeita tavallisesti **tilastollisiksi kokeiksi**.

# Mittaaminen

---

- Tilastollisen tutkimuksen kohdetta kuvaavat numeeriset ja kvantitatiiviset tiedot saadaan mittaamalla.
- Mittari voidaan pitää funktiona, joka liittää mitattavan kohteen ominaisuuteen numeerisen arvon.



# Tilastolliset mitta-asteikot

---

- Mittaus on tehty **nominaali-** eli **laatueroasteikolla**, jos mittaus kertoo mihin luokkaan mittauksen kohde kuuluu. Esim. sukupuoli, asuinpaikka.
- **Ordinaali-** eli **järjestysasteikkoa** käytetään silloin, kun tilastoyksiköt voidaan jakaa luokkiin, joiden välillä on järjestys. Esim. oppiarvot: ylioppilas, kandidaatti, di/maisteri, lisensiaatti, tohtori.
- **Intervalli-** eli **välimatka-asteikko** kertoo kuinka paljon kahden mitattavan kohteen ominaisuudet eroavat toisistaan. Esim. lämpötila Celsius-asteina.
- Mittaus on tehty **suhdeasteikolla**, jos mittaus kertoo kuinka monta kertaa enemmän tai vähemmän mittauksen kohteella on mitattavaa ominaisuutta kuin jollakin toisella kohteella. Esim. pituus, nopeus, lämpötila Kelvin-asteikolla.

# Kvalitatiiviset ja kvantitatiiviset muuttujat

---

- Ominaisuutta ja sitä kuvaavaa muuttujaa kutsutaan
  - **Kvalitatiiviseksi**, jos mittauksen kohteet voidaan luokitella mittauksen perusteella toisistaan eroaviin luokkiin.
  - **Kvantitatiiviseksi**, jos mittaus tuottaa ominaisuuden määrällisen arvon.

# Havaintoarvot

---

- Olkoon tutkimuksen kohteiksi valittujen **havaintoyksiköiden lukumäärä**  $n$ .

- Olkoon

$$x_i, i = 1, 2, \dots, n$$

kohdeperusjoukon alkioden ominaisuutta kuvaavan muuttujan  $x$  **havaittu arvo** havaintoyksikössä  $i$ .

- Kutsumme muuttujan  $x$  havaittuja arvoja

$$x_1, x_2, \dots, x_n$$

tavallisesti **havaintoarvoiksi**.

- Havaintoarvo  $x_i$  saadaan *mittaamalla* muuttujan  $x$  arvo havaintoyksikölle  $i$ .

## Havaintoarvojen jakauma ja sen kuvaaminen

---

- Perusjoukon alkioiden ominaisuutta kuvaavan muuttujan  $x$  *havaittujen arvojen*


$$x_1, x_2, \dots, x_n$$

*vaihtelua havaintoyksiköiden joukossa* kuvaa parhaiten havaintoarvojen **jakauma**.

- Havaittujen arvojen jakaumaa voidaan kuvailla ja esitellä *tiivistämällä* havaintoarvoihin sisältyvä *informaatio* sopivaan muotoon:
  - Havaintoarvojen *jakaumaa kokonaisuutena* voidaan kuvata sopivasti valitulla **graafisella esityksellä**.
  - *Jakauman karakteristisia ominaisuuksia* voidaan kuvata sopivasti valituilla **tunnusluvuilla**.


# Havaintoarvojen jakauma ja sen kuvaaminen

Muistutus eri graafisista esityksistä ja tunnusluvuihin löytyvät Liitteessä **Tilastollisten aineistojen kuvaaminen.**



$$\bar{x} = \frac{f}{n}$$

$m_k$  **Mediaani**



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

---

# ***Tilastolliset menetelmät***

## **Osa 2: Otokset, otosjakaumat ja estimointi**

- **Otokset ja otosjakaumat**

# Otokset ja otosjakaumat

---

- >> **Satunnaisotanta ja satunnaisotokset**
  - Otostunnusluvut ja otosjakaumat**
  - Aritmeettisen keskiarvon ja otosvariانسsin otosjakaumat**
  - Suhteellisen frekvenssin otosjakauma**

## Satunnaisotanta ja satunnaisotokset

# Tilastollinen aineisto

---

- **Tilastollinen aineisto** koostuu tutkimuksen kohteita kuvaavien muuttujien *havaituista arvoista*.
- Tilastollisissa tutkimusasetelmissä havaintoarvoihin ajatellaan aina liittyvän *epävarmuutta ja satunnaisuutta*.
- Seurauksia:
  - (i) Tilastollisissa tutkimusasetelmissä ajatellaan, että *havaintoarvot on generoinut jokin satunnaisilmiö*.
  - (ii) Tilastollisen tutkimuksen kohteita kuvaavat muuttujat tulkitaan *satunnaismuuttujiksi* ja havaintoarvot tulkitaan näiden *satunnaismuuttujien realisoituneiksi arvoiksi*.



## Tilastollisen aineiston tilastollinen malli

---

- Tilastollisen havaintoaineiston **tilastollisella mallilla** tarkoitetaan tutkimuksen kohteita kuvaavien satunnaismuuttujien *todennäköisyysjakaumaa*.
- Tämän todennäköisyysjakauman ajatellaan *generoineen* ko. satunnaismuuttujien *havaitut arvot*.
- Havaintoarvojen ajatellaan syntyneen *arpomalla* käyttäen arvontatodennäköisyyksinä tilastollisena mallina käytetystä todennäköisyysjakaumasta saatavia todennäköisyyksiä.
- **Huomautus:**

Todennäköisyysjakaumat riippuvat tavallisesti **parametreista** eli vakioista, joiden arvoja ei yleensä tunneta.

## Tilastolliset mallit ja tilastollinen päättely

---

- Kun tilastollista mallia sovelletaan jotakin reaalimaailman ilmiötä kuvaavan havaintoaineiston analysointiin, kohdataan lähes aina seuraavat mallin **parametreja** koskevat ongelmat:
  - (i) Parametrien arvoja *ei tunneta* ja ne on **estimoitava** eli *arvioitava* havaintoaineistosta.
  - (ii) Parametrien arvoista on esitetty *oletuksia* tai *väitteitä*, joita halutaan **testata** eli asettaa koetteelle havaintoaineistosta saatua informaatiota vastaan.
- Tilastollisten mallien parametrien estimointi ja testaus muodostavat keskeisen osan **tilastollista päättelyä**.

## Satunnaisotanta ja satunnaisotokset

---

- **Satunnaisotos** poimitaan perusjoukosta *arpomalla* tutkittavat havaintoyksiköt perusjoukosta otokseen.
- Arvonnassa käytettävää menetelmää kutsutaan **satunnaisotannaksi**.
- Satunnaisotannassa *sattuma* määrää mitkä perusjoukon alkioista tulevat poimituiksi otokseen.

## Satunnaisotanta: Kommentteja

---

- Jos havaintoyksiköt poimitaan perusjoukosta satunnaisotannalla, pätee seuraava:
  - (i) **Havaintoyksiköitä kuvaavien muuttujien *havaitut arvot ovat satunnaisia* siinä mielessä, että ne vaihtelevat satunnaisesti otoksesta toiseen.**
  - (ii) ***Kaikki* havaintoyksiköitä kuvaavien muuttujien *havaituista arvoista lasketut tunnusluvut ovat satunnaisia* siinä mielessä, että ne vaihtelevat satunnaisesti otoksesta toiseen.**

## Yksinkertainen satunnaisotanta

---

- Olkoot

$$X_1, X_2, \dots, X_n$$

*riippumattomia, identtisesti jakautuneita* satunnaismuuttujia, joilla on *sama* pistetodennäköisyys- tai tiheysfunktio

$$f(x)$$

- Tällöin sanomme, että satunnaismuuttujat

$$X_1, X_2, \dots, X_n$$

muodostavat (**yksinkertaisen**) **satunnaisotoksen** jakaumasta  $f(x)$ .

# Satunnaisotanta ja satunnaisotokset

## Havainnot ja havaintoarvot

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

(yksinkertainen) satunnaisotos jakaumasta  $f(x)$ .

- Kutsumme satunnaismuuttujia  $X_1, X_2, \dots, X_n$  tavallisesti **havainnoiksi**.
- *Otoksen poimimisen jälkeen* satunnaismuuttujat  $X_1, X_2, \dots, X_n$  saavat havaituiksi arvoikseen **havaintoarvot**

$$x_1, x_2, \dots, x_n$$

- Merkitään:

$$X_1 = x_1, X_2 = x_2, \dots, X_n = x_n$$

# Yksinkertainen satunnaisotanta: Kommentteja 1/2

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*satunnaisotos* jakaumasta  $f(x)$ .

- Tällöin havaintoarvot

$$x_1, x_2, \dots, x_n$$

on saatu *toistamalla arvontaa toisistaan riippumattomin toistoin  $n$  kertaa samoin, jakaumasta  $f(x)$  saatavin todennäköisyyksin.*

## Yksinkertainen satunnaisotanta: Kommentteja 2/2

---

- Havaintoarvot  $x_1, x_2, \dots, x_n$  ovat *kiinteitä* eli *ei-satunnaisia*, mutta ne *vaihtelevat toisistaan riippumatta ja satunnaisesti otoksesta toiseen*.
- **Satunnaisuus *ei siis liity* otannan tuloksena saatuihin havaintoarvoihin, vaan poiminnassa sovellettuun arvontaan.**



# Tilastollinen malli yksinkertaiselle satunnaisotannalle 1/2

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*satunnaisotos* jakaumasta  $f(x)$ .

- Satunnaismuuttujien  $X_1, X_2, \dots, X_n$  yhteisjakauma muodostaa **tilastollisen mallin** *havaintoarvojen satunnaiselle vaihtelulle otoksesta toiseen.*

## Tilastollinen malli yksinkertaiselle satunnaisotannalle 2/2

---

- Koska satunnaismuuttujat

$$X_1, X_2, \dots, X_n$$

on oletettu riippumattomiksi, niin satunnaismuuttujien  $X_1, X_2, \dots, X_n$  yhteisjakauma on muotoa

$$f(x_1, x_2, \dots, x_n) = f(x_1)f(x_2)\cdots f(x_n)$$

jossa

$$X_i \sim f(x_i), i = 1, 2, \dots, n$$

# Otokset ja otosjakaumat

---

**Satunnaisotanta ja satunnaisotokset**

**>> Otostunnusluvut ja otosjakaumat**

**Aritmeettisen keskiarvon ja otosvariانسsin otosjakaumat**

**Suhteellisen frekvenssin otosjakauma**

# Otostunnusluvut ja otosjakaumat

## Otostunnusluvut 1/3

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

(**yksinkertainen**) **satunnaisotos** jakaumasta, jonka pistetodennäköisyys- tai tiheysfunktio on  $f(x)$ .

- Tällöin havainnot  $X_1, X_2, \dots, X_n$  ovat *riippumattomia, identtisesti jakautuneita satunnaismuuttujia*, joilla on *sama pistetodennäköisyys- tai tiheysfunktio*  $f(x)$ :

$$X_1, X_2, \dots, X_n \perp$$

$$X_i \sim f(x), i = 1, 2, \dots, n$$

## Otostunnusluvut ja otosjakaumat

# Otostunnusluvut 2/3

---

- Olkoon

$$T = g(X_1, X_2, \dots, X_n)$$

jokin *satunnaismuuttujien*  $X_1, X_2, \dots, X_n$  (mitallinen)  
*funktio*.

- Kutsumme satunnaismuuttujaa  $T$  seuraavassa (**otos-**)  
**tunnusluvuksi.**

## Otostunnusluvut 3/3

---

- Oletetaan, että otoksen poimimisen jälkeen satunnaismuuttujat  $X_1, X_2, \dots, X_n$  saavat havaituiksi arvoikseen *havaintoarvot*  $x_1, x_2, \dots, x_n$ :

$$X_1 = x_1, X_2 = x_2, \dots, X_n = x_n$$

- Tällöin tunnusluku

$$T = g(X_1, X_2, \dots, X_n)$$

*saa havaituksi arvokseen*  $t$  funktion  $g$  arvon pisteessä

$(x_1, x_2, \dots, x_n)$ :

$$t = g(x_1, x_2, \dots, x_n)$$

## Otostunnusluvut ja otosjakaumat

# Otosjakauma

---

- Oletetaan, että satunnaismuuttujat

$$X_1, X_2, \dots, X_n$$

muodostavat *satunnaisotoksen* jakaumasta  $f(x)$  ja olkoon funktio

$$T = g(X_1, X_2, \dots, X_n)$$

jokin *otostunnusluku*.

- Tunnusluvun  $T$  jakaumaa kutsutaan *tunnusluvun  $T$  otosjakaumaksi*.
- Tunnusluvun  $T$  otosjakauma muodostaa **tilastollisen mallin** *tunnusluvun  $T$  arvojen satunnaiselle vaihtelulle otoksesta toiseen*.

## Eräiden tavallisten tunnuslukujen otosjakaumat

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*satunnaisotos* jakaumasta  $f(x)$ .

- Jatkossa tarkastellaan seuraavien tunnuslukujen (ks. lukua **Tilastollisten aineistojen kuvaaminen**) otosjakaumia:
  - **Aritmeettinen keskiarvo**
  - **Otosvarianssi**
  - **Suhteellinen frekvenssi**



# Otokset ja otosjakaumat

---

**Satunnaisotanta ja satunnaisotokset**

**Otostunnusluvut ja otosjakaumat**

**>> Aritmeettisen keskiarvon ja otosvariانسsin otosjakaumat**

**Suhteellisen frekvenssin otosjakauma**

## Aritmeettinen keskiarvo:

### Määritelmä 1/2

---

- Oletetaan, että havainnot

$$X_1, X_2, \dots, X_n$$

muodostavat *satunnaisotoksen* satunnaismuuttujan  $X$  jakaumasta, jonka *odotusarvo* ja *varianssi* ovat

$$E(X) = \mu$$

$$\text{Var}(X) = \sigma^2$$

- Tällöin kaikilla satunnaismuuttujilla  $X_i, i = 1, 2, \dots, n$  on *sama* odotusarvo  $\mu$  ja *sama* varianssi  $\sigma^2$ .

## Aritmeettinen keskiarvo:

### Määritelmä 2/2

---

- Olkoon

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{X_1 + X_2 + \dots + X_n}{n}$$

havaintojen  $X_1, X_2, \dots, X_n$  **aritmeettinen keskiarvo**.

- Aritmeettinen keskiarvo  $\bar{X}$  kuvaa havaintojen *keskimääräistä arvoa*.
- Aritmeettinen keskiarvo  $\bar{X}$  on satunnaismuuttuja, jonka saamat *arvot vaihtelevat satunnaisesti otoksesta toiseen*.

## Aritmeettisen keskiarvon odotusarvo ja varianssi

---

- **Aritmeettisen keskiarvon  $\bar{X}$  odotusarvo ja varianssi:**

$$E(\bar{X}) = \mu$$

$$\text{Var}(\bar{X}) = D^2(\bar{X}) = \frac{\sigma^2}{n}$$

- Aritmeettisen keskiarvon  $\bar{X}$  *standardipoikkeamaa*

$$D(\bar{X}) = \sigma / \sqrt{n}$$

kutsutaan tavallisesti **keskiarvon keskivirheeksi** ja se kuvaa aritmeettisen keskiarvon otosvaihtelua oman odotusarvonsa  $\mu$  ympärillä.

## Aritmeettisen keskiarvon ja otosvarianssin otosjakaumat

# Aritmeettisen keskiarvon otosjakauman käyttäytyminen otoskoon kasvaessa

---

- Koska aritmeettisen keskiarvon  $\bar{X}$  odotusarvo on

$$E(\bar{X}) = \mu$$

ja varianssi on

$$\text{Var}(\bar{X}) = \sigma^2/n$$

niin aritmeettisen keskiarvon otosjakauma *keskittyy yhä voimakkaammin havaintojen yhteisen odotusarvon  $\mu$  ympärille, jos otoskoon  $n$  annetaan kasvaa.*

## Aritmeettisen keskiarvon otosjakauma normaalisen otoksen tapauksessa

---

- Oletetaan, että havainnot

$$X_1, X_2, \dots, X_n$$

muodostavat *satunnaisotoksen normaalijakaumasta*

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

Tällöin havaintojen *aritmeettinen keskiarvo*  $\bar{X}$  *noudattaa eksaktisti* (eli myös äärellisissä otoksissa) **normaalijakaumaa**:

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

## Aritmeettisen keskiarvon asymptoottinen jakauma

---

- Oletetaan, että havainnot

$$X_1, X_2, \dots, X_n$$

muodostavat *satunnaisotoksen* satunnaismuuttujan  $X$  jakaumasta, jonka *odotusarvo* on  $\mu$  ja *varianssi* on  $\sigma^2$ .

- Tällöin havaintojen *aritmeettinen keskiarvo*  $\bar{X}$  *noudattaa keskeisen raja-arvolauseen mukaan suurissa otoksissa approksimatiivisesti normaalijakaumaa*, jonka odotusarvo on  $\mu$  ja varianssi on  $\sigma^2 / n$ :

$$\bar{X} \sim_a N\left(\mu, \frac{\sigma^2}{n}\right)$$

## Aritmeettisen keskiarvon jakauma: Kommentteja

---

- Aritmeettisen keskiarvon otosjakaumaa koskeva asymptoottinen tulos *pätee tietyin lisäehdoin* myös monissa sellaisissa tilanteissa, joissa *havaintojen riippumattomuutta ja samaa jakaumaa koskevat oletukset eivät päde*.



## Otosvariانسsi:

### Määritelmä 1/2

---

- Oletetaan, että havainnot

$$X_1, X_2, \dots, X_n$$

muodostavat *satunnaisotoksen* satunnaismuuttujan  $X$  jakaumasta, jonka *odotusarvo* ja *variانسsi* ovat

$$E(X) = \mu$$

$$\text{Var}(X) = \sigma^2$$

- Tällöin kaikilla satunnaismuuttujilla  $X_i, i = 1, 2, \dots, n$  on *sama* odotusarvo  $\mu$  ja *sama* variانسsi  $\sigma^2$ .

## Otosvarianssi: Määritelmä 2/2

---

- Olkoon

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

havaintojen  $X_1, X_2, \dots, X_n$  **otosvarianssi**, jossa

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

on havaintojen  $X_1, X_2, \dots, X_n$  *aritmeettinen keskiarvo*.

- Otosvarianssi  $S^2$  kuvaa havaintoarvojen *vaihtelua niiden aritmeettisen keskiarvon ympärillä*.
- Otosvarianssi  $S^2$  on satunnaismuuttuja, jonka saamat *arvot vaihtelevat satunnaisesti otoksesta toiseen*.

# Aritmeettisen keskiarvon ja otosvariانسsin otosjakaumat

## Otosvariانسsin odotusarvo ja variانسsi

---

- **Otosvariانسsin  $S^2$  odotusarvo:**

$$E(S^2) = \sigma^2$$

- Jos lisäksi voidaan olettaa, että havainnot  $X_1, X_2, \dots, X_n$  noudattavat normaalijakaumaa  $N(\mu, \sigma^2)$ , niin **otosvariانسsin  $S^2$  variانسsi** on

$$\text{Var}(S^2) = D^2(S^2) = \frac{2\sigma^4}{n-1}$$

- Siten otosvariانسsin  $S^2$  *standardipoikkeama* on normaalisen otoksen tapauksessa

$$D(S^2) = \sigma^2 \sqrt{\frac{2}{n-1}}$$

## Otosvariانسsin otosjakauma normaalisen otoksen tapauksessa 1/2

---

- Oletetaan, että havainnot

$$X_1, X_2, \dots, X_n$$

muodostavat *satunnaisotoksen normaalijakaumasta*

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

- Tällöin *satunnaismuuttuja*

$$Y = \sum_{i=1}^n \left( \frac{X_i - \mu}{\sigma} \right)^2$$

*noudattaa  $\chi^2$ -jakaumaa vapausastein  $n$ :*

$$Y \sim \chi^2(n)$$

## Otosvariانسsin otosjakauma normaalisen otoksen tapauksessa 2/2

---

- Oletetaan, että havainnot

$$X_1, X_2, \dots, X_n$$

muodostavat *satunnaisotoksen normaalijakaumasta*

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

- Tällöin *satunnaismuuttuja*

$$V = \frac{(n-1)S^2}{\sigma^2} = \sum_{i=1}^n \left( \frac{X_i - \bar{X}}{\sigma} \right)^2$$

*noudattaa  $\chi^2$ -jakaumaa vapausastein  $(n-1)$ :*

$$V \sim \chi^2(n-1)$$

# Aritmeettisen keskiarvon ja otosvarianssin otosjakaumat

## Aritmeettisen keskiarvon ja otosvarianssin otosjakaumat: Seuraus

---

- Oletetaan, että havainnot

$$X_1, X_2, \dots, X_n$$

muodostavat *satunnaisotoksen normaalijakaumasta*

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

- Tällöin

$$t = \frac{\bar{X} - \mu}{S / \sqrt{n}} \sim t(n-1)$$

- Ks. monisteen **Todennäköisyyyslaskenta** lukua **Normaalijakaumasta johdettuja jakaumia**.

# Otokset ja otosjakaumat

---

**Satunnaisotanta ja satunnaisotokset**

**Otostunnusluvut ja otosjakaumat**

**Aritmeettisen keskiarvon ja otosvariانسsin otosjakaumat**

**>> Suhteellisen frekvenssin otosjakauma**

## Frekvenssi ja suhteellinen frekvenssi: Määritelmät 1/3

---

- Olkoon  $P$  jokin otosavaruuden  $S$  alkioiden *ominaisuus*.
- Jos otosavaruuden  $S$  alkiolla  $x$  on ominaisuus  $P$ , merkitään

$$P(x)$$

- Olkoon

$$A = \{x \in S \mid P(x)\}$$

niiden otosavaruuden  $S$  alkioiden *osajoukko*, joilla on ominaisuus  $P$ .

- Oletetaan, että **tapahtuman  $A$  todennäköisyys** on

$$\Pr(A) = p$$



## Frekvenssi ja suhteellinen frekvenssi: Määritelmät 2/3

---

- Poimitaan otosavaruudesta  $S$  *satunnaisotos*, jonka *koko* on  $n$ .
- Olkoon

$f$

niiden havaintoyksiköiden **frekvenssi**, joilla on ominaisuus  $P$  ja olkoon

$$\hat{p} = f/n$$

vastaava **suhteellinen frekvenssi**.

## Frekvenssi ja suhteellinen frekvenssi: Määritelmät 3/3

---

- Frekvenssi

$f$

kuvaa *A*-tyyppisten alkioiden **lukumäärää** otoksessa ja vastaava suhteellinen frekvenssi

$$\hat{p} = f/n$$

kuvaa *A*-tyyppisten alkioiden **suhteellista osuutta** otoksessa.

- Frekvenssi  $f$  ja vastaava suhteellinen frekvenssi  $\hat{p}$  ovat *satunnaismuuttujia*, joiden saamat arvot vaihtelevat *satunnaisesti otoksesta toiseen*.

Suhteellisen frekvenssin otosjakauma

**Frekvenssi:**

**Odotusarvo, varianssi ja jakauma 1/2**

---

- Olkoon  $A$  jokin otosavaruuden  $S$  tapahtuma:

$$A \subset S$$

- Poimitaan otosavaruudesta  $S$  satunnaisotos, jonka koko on  $n$ .
- Olkoon

$f$

$A$ -tyyppisten alkioiden *lukumäärä* eli *frekvenssi* otoksessa.

## Frekvenssi:

## Odotusarvo, varianssi ja jakauma 2/2

---

- **Frekvenssin  $f$  odotusarvo ja varianssi:**

$$E(f) = np$$

$$\text{Var}(f) = npq$$

jossa  $q = 1 - p$ .

- *Frekvenssi  $f$  noudattaa eksaktisti **binomijakaumaa** parametrein  $n$  ja  $\text{Pr}(A) = p$ :*

$$f \sim \text{Bin}(n, p)$$

Ks. monisteen **Todennäköisyyslaskenta** lukua **Diskreettejä jakaumia** tai lukua **Satunnaismuuttujien muunnosten jakaumat**.

## Suhteellisen frekvenssin otosjakauma

# Suhteellinen frekvenssi: Odotusarvo ja varianssi

---

- **Suhteellisen frekvenssin  $\hat{p}$  odotusarvo ja varianssi:**

$$E(\hat{p}) = p$$

$$\text{Var}(\hat{p}) = D^2(\hat{p}) = \frac{pq}{n}$$

jossa  $q = 1 - p$ .

- Suhteellisen frekvenssin  $\hat{p}$  *standardipoikkeamaa*

$$D(\hat{p}) = \sqrt{\frac{pq}{n}}$$

kutsutaan tavallisesti **suhteellisen frekvenssin keski-  
virheeksi** ja se kuvaa suhteellisen frekvenssin  $f/n$  otos-  
vaihtelua oman odotusarvonsa  $p$  ympärillä.

Suhteellisen frekvenssin otosjakauma

## Suhteellisen frekvenssin otosjakauma: Jakauman käyttäytyminen otoskoon kasvaessa

---

- Koska suhteellisen frekvenssin  $\hat{p}$  odotusarvo

$$E(\hat{p}) = p$$

ja varianssi on

$$\text{Var}(\hat{p}) = pq/n, \quad q = 1 - p$$

niin suhteellisen frekvenssin otosjakauma *keskittyy yhä voimakkaammin tapahtuman A todennäköisyyden  $p$  ympärille, jos otoskoon  $n$  annetaan kasvaa.*

## Suhteellisen frekvenssin otosjakauma: Asymptoottinen jakauma

---

- *Suhteellinen frekvenssi  $\hat{p}$  noudattaa keskeisen raja-arvolauseen mukaan suurissa otoksissa approksimatiivisesti normaalijakaumaa:*

$$\hat{p} \sim_a N\left(p, \frac{pq}{n}\right)$$

- *Siten standardoitu satunnaismuuttuja*

$$Z = \frac{\hat{p} - p}{\sqrt{pq/n}}$$

*noudattaa suurissa otoksissa approksimatiivisesti standardoitua normaalijakaumaa:*

$$Z \sim_a N(0,1)$$

---

## ***Tilastolliset menetelmät***

### **Osa 2: Otokset, otosjakaumat ja estimointi**

- **Estimointi**



# Estimointi

---

- >> Todennäköisyysjakaumien parametrit ja niiden estimointi**
  - Hyvän estimaattorin ominaisuudet**
  - Estimointimenetelmät**

## Todennäköisyysjakaumat tilastollisten aineistojen kuvaajina

---

- **Tilastollinen aineisto** koostuu tutkimuksen kohteita kuvaavien muuttujien *havaituista arvoista*.
- Tilastollisissa tutkimusasetelmissä havaintoarvoihin liittyy *epävarmuutta* ja *satunnaisuutta*.
- Tilastollisissa tutkimusasetelmissä tutkimuksen kohteita kuvaavat muuttujat tulkitaan *satunnaismuuttujiksi*, jotka *generoivat* muuttujien havaitut arvot.
- *Havaintoarvot generoineiden satunnaismuuttujien todennäköisyysjakauma* muodostaa **tilastollisen mallin** sille satunnaisilmiölle, jota havainnot koskevat.

## Todennäköisyysjakaumien parametrit 1/2

---

- Tarkastellaan jotakin tutkimuksen kaikkien mahdollisten kohteiden muodostaman perusjoukon alkioiden ominaisuutta kuvaavaa *satunnaismuuttujaa*  $X$ .
- Oletetaan, että satunnaismuuttuja  $X$  noudattaa *todennäköisyysjakaumaa*, jonka *pistetodennäköisyys-* tai *tiheysfunktio*

$$f(x ; \theta)$$

riippuu **parametrilla**  $\theta$ .

- Merkintä:

$$X \sim f(x ; \theta)$$

## Todennäköisyysjakaumien parametrit 2/2

---

- Satunnaismuuttujan  $X$  pistetodennäköisyys- tai tiheysfunktio

$$f(x ; \theta)$$

kuvaa satunnaismuuttujan  $X$  *todennäköisyysjakaumaa* ja parametri  $\theta$  kuvaa jotakin jakauman *karakteristista ominaisuutta*.

- Koska parametrin  $\theta$  arvoa *ei yleensä tunneta*, tilastollisen tutkimuksen tärkeimpiä osatehtäviä on **estimoida** eli *arvioida* parametrille  $\theta$  sopiva arvo *jakaumasta*  $f(x ; \theta)$  *poimitun otoksen perusteella*.

# Todennäköisyysjakaumien parametrit ja niiden estimointi

## Yksinkertainen satunnaisotos

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

(**yksinkertainen**) **satunnaisotos** jakaumasta, jonka pistetodennäköisyys- tai tiheysfunktio  $f(x; \theta)$  riippuu parametrasta  $\theta$ .

- Tällöin havainnot  $X_1, X_2, \dots, X_n$  ovat *riippumattomia, identtisesti jakautuneita satunnaismuuttujia*, joilla on *sama pistetodennäköisyys- tai tiheysfunktio*  $f(x; \theta)$ :

$$X_1, X_2, \dots, X_n \perp$$

$$X_i \sim f(x; \theta), i = 1, 2, \dots, n$$

# Todennäköisyysjakaumien parametrit ja niiden estimointi

## Havainnot ja havaintoarvot

---

- Oletetaan, että satunnaismuuttujat (havainnot)

$$X_1, X_2, \dots, X_n$$

saavat *poimitussa otoksessa* **havaituiksi arvoikseen** luvut

$$x_1, x_2, \dots, x_n$$

- **Havaintoarvot**

$$x_1, x_2, \dots, x_n$$

*vaihtelevat satunnaisesti otoksesta toiseen.*

## Todennäköisyysjakaumien parametrit ja niiden estimointi

### Estimaattorit ja estimaatit

---

- Oletetaan, että *parametrin  $\theta$  estimointiin* käytetään satunnaismuuttujien  $X_1, X_2, \dots, X_n$  funktiota eli *tunnuslukua*

$$T = g(X_1, X_2, \dots, X_n)$$

- Tällöin funktiota  $T = g(X_1, X_2, \dots, X_n)$  kutsutaan parametrin  $\theta$  **estimaattoriksi**

ja *havaintoarvoista*  $x_1, x_2, \dots, x_n$  laskettua arvoa  $t = g(x_1, x_2, \dots, x_n)$  kutsutaan parametrin  $\theta$  **estimaatiksi**.

## Estimaattorit ja estimaatit:

### Kommentti

---

- Todennäköisyysjakauman  $f(x ; \theta)$  parametrin  $\theta$  *estimaattorilla*

$$T = g(X_1, X_2, \dots, X_n)$$

tarkoitetaan siis sellaista jakaumaa  $f(x ; \theta)$  noudattavien *satunnaismuuttujien*

$$X_1, X_2, \dots, X_n$$

*funktiota, joka generoi* muuttujien  $X_1, X_2, \dots, X_n$  havaittuihin arvoihin  $x_1, x_2, \dots, x_n$  sovellettuna *estimaatteja eli arvioita*

$$t = g(x_1, x_2, \dots, x_n)$$

parametrille  $\theta$ .



# Todennäköisyysjakaumien parametrit ja niiden estimointi

## Estimaattorin otosjakauma

---

- Estimaattorin

$$T = g(X_1, X_2, \dots, X_n)$$

havaintoarvoista

$$x_1, x_2, \dots, x_n$$

lasketut arvot eli estimaatit

$$t = g(x_1, x_2, \dots, x_n)$$

*vaihtelevat satunnaisesti otoksesta toiseen.*

- Estimaattorin  $T$  arvojen satunnaista vaihtelua otoksesta toiseen voidaan kuvata *estimaattorin  $T$  otosjakaumalla*; ks. lukua **Otokset ja otosjakaumat**.

# Estimointi

---

**Todennäköisyysjakaumien parametrit ja niiden estimointi**

- >> Hyvän estimaattorin ominaisuudet**
- Estimointimenetelmät**

## Hyvä estimaattori

---

- Todennäköisyysjakauman parametreille on tavallisesti tarjolla useita *vaihtoehtoisia estimaattoreita*.
- Estimaattorin valintaa ohjaavat **hyvyyskriteerit**, joilla pyritään takamaan se, että valittu estimaattori tuottaa järkeviä arvoja estimoitavalle parametrille.
- Estimaattoreiden hyvyyskriteereitä:
  - **Harhattomuus**
  - **Tehokkuus**
  - **Tarkentuvuus**

## Hyvän estimaattorin ominaisuudet

# Harhattomuus ja harha

---

- Olkoon  $\hat{\theta}$  parametrin  $\theta$  estimaattori.
- Estimaattori  $\hat{\theta}$  on **harhaton** parametrille  $\theta$ , jos sen odotusarvo yhtyy parametrin  $\theta$  arvoon:  
$$E(\hat{\theta}) = \theta$$
- Harhaton estimaattori tuottaa *keskimäärin* oikean kokoisia arvoja parametrille.

- Estimaattorin  $\hat{\theta}$  **harha** on

$$\text{Bias}(\hat{\theta}) = \theta - E(\hat{\theta})$$

- Jos estimaattori  $\hat{\theta}$  on harhaton parametrille  $\theta$ , niin

$$\text{Bias}(\hat{\theta}) = 0$$

## Estimaattorin keskineliövirhe ja tarkkuus

---

- Parametrin  $\theta$  estimaattorin  $\hat{\theta}$  **keskineliövirhe** on

$$\begin{aligned}\text{MSE}(\hat{\theta}) &= \text{E}\left[(\hat{\theta} - \theta)^2\right] \\ &= \text{Var}(\hat{\theta}) + \left[\text{Bias}(\hat{\theta})\right]^2\end{aligned}$$

- Jos  $\hat{\theta}$  on *harhaton* parametrille  $\theta$  eli

$$\text{Bias}(\hat{\theta}) = \theta - \text{E}(\hat{\theta}) = 0$$

niin

$$\text{MSE}(\hat{\theta}) = \text{Var}(\hat{\theta})$$

- Estimaattoria sanotaan **tarkaksi**, jos se on *harhaton* ja sen *varianssi* on *pieni*.

## Tehokkuus

---

- Olkoot  $\hat{\theta}_1$  ja  $\hat{\theta}_2$  kaksi parametrin  $\theta$  estimaattoria.
- Estimaattori  $\hat{\theta}_1$  on **tehokkaampi** kuin estimaattori  $\hat{\theta}_2$ , jos
$$\text{Var}(\hat{\theta}_1) < \text{Var}(\hat{\theta}_2)$$
- Parametrin  $\theta$  estimaattori  $\hat{\theta}$  on **täystehokas**, jos sen varianssi on *pienempi kuin minkä tahansa muun parametrin  $\theta$  estimaattorin*.

# Hyvän estimaattorin ominaisuudet

## Harhattomuus ja tehokkuus:

### Esimerkki 1/2

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

satunnaisotos normaalijakaumasta  $N(\mu, \sigma^2)$ .

- Voidaan osoittaa, että sekä havaintojen *aritmeettinen keskiarvo*

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

että niiden *mediaani*  $Me$  ovat molemmat *harhattomia* normaalijakauman odotusarvolle  $\mu$ :

$$E(\bar{X}) = E(Me) = \mu$$

## Hyvän estimaattorin ominaisuudet

# Harhattomuus ja tehokkuus:

### Esimerkki 2/2

---

- Sen sijaan

$$\text{Var}(\bar{X}) = \frac{\sigma^2}{n} < \frac{\pi}{2} \cdot \frac{\sigma^2}{n} = \text{Var}(Me)$$

joten normaalijakautuneiden havaintojen aritmeettisen keskiarvon  $\bar{X}$  varianssi on *pienempi* kuin niiden mediaanin  $Me$  varianssi.

- Siten aritmeettinen keskiarvo  $\bar{X}$  on normaalijakauman odotusarvon  $\mu$  estimaattorina *tehokkaampi* kuin mediaani  $Me$ .
- Voidaan osoittaa, että havaintoarvojen aritmeettinen keskiarvo  $\bar{X}$  on normaalijakauman odotusarvoparametrin  $\mu$  estimaattorina *täystehokas*.



## Tarkentuvuus

---

- Olkoon  $\hat{\theta}$  parametrin  $\theta$  estimaattori.
- Estimaattori  $\hat{\theta}$  on **tarkentuva** parametrille  $\theta$ , jos se *konvergoi* melkein varmasti *kohti parametrin oikeata arvoa*, kun otoskoon  $n$  annetaan kasvaa rajatta:

$$\Pr(\hat{\theta}_n \rightarrow \theta) = 1, \text{ kun } n \rightarrow +\infty$$

Ks. monisteen **Todennäköisyyslaskenta** lukua **Stokastiikan konvergenssikäsitteet ja raja-arvolauseet**.

# Estimointi

---

**Todennäköisyysjakaumien parametrit ja niiden estimointi**

**Hyvän estimaattorin ominaisuudet**

**>> Estimointimenetelmät**

## Todennäköisyysjakaumien parametrien estimointi

# Estimaattoreiden johtaminen

---

- *Hyvien estimaattoreiden johtaminen todennäköisyysjakaumien tuntemattomille parametreille on teoreettisen tilastotieteen keskeisiä ongelmia.*
- **Suurimman uskottavuuden menetelmä** *on ehkä tärkein kaikista estimointimenetelmistä.* **Momenttimenetelmä** on toinen hyvin yleinen estimaattoreiden johtamiseen käytettävä menetelmä.

# Estimointimenetelmät

---

- >> **Suurimman uskottavuuden menetelmä**
  - Normaalijakauman parametrien estimointi**
  - Bernoulli-jakauman parametrien estimointi**

## Suurimman uskottavuuden menetelmä

# Uskottavuusfunktio 1/2

---

- Olkoon  $X_1, X_2, \dots, X_n$  yksinkertainen satunnaisotos jakaumasta  $f(x; \theta)$ , jonka parametrina on  $\theta$ .
- Koska havainnot  $X_1, X_2, \dots, X_n$  on tässä oletettu riippumattomiksi, niiden yhteisjakauman pistetodennäköisyys- tai tiheysfunktio on

$$f(x_1, x_2, \dots, x_n; \theta) = f(x_1; \theta) f(x_2; \theta) \cdots f(x_n; \theta)$$

jossa

$$f(x_i; \theta), i = 1, 2, \dots, n$$

on havaintoon  $X_i$  liittyvä pistetodennäköisyys- tai tiheysfunktio.

## Suurimman uskottavuuden menetelmä

# Uskottavuusfunktio 2/2

---

- Otoksen  $X_1, X_2, \dots, X_n$  **uskottavuusfunktio**

$$L(\theta; x_1, x_2, \dots, x_n) = f(x_1, x_2, \dots, x_n; \theta)$$

on havaintojen

$$X_1, X_2, \dots, X_n$$

*yhteisjakauman pistetodennäköisyys- tai tiheysfunktion  $f$  arvo pisteessä  $x_1, x_2, \dots, x_n$  tulkittuna parametrin  $\theta$  arvojen funktioksi.*

## Suurimman uskottavuuden estimaattori 1/2

---

- Olkoon

$$t = g(x_1, x_2, \dots, x_n)$$

parametrin  $\theta$  arvo, joka *maksimoi uskottavuusfunktion*

$$L(\theta; x_1, x_2, \dots, x_n)$$

parametrin  $\theta$  suhteen.

- **Huomautus:**

Uskottavuusfunktion  $L$  maksimin antava parametrin  $\theta$  arvo  $t$  on muuttujien  $X_1, X_2, \dots, X_n$  havaittujen arvojen  $x_1, x_2, \dots, x_n$  funktio.

## Suurimman uskottavuuden estimaattori 2/2

---

- Sijoittamalla uskottavuusfunktion  $L$  maksimin parametrin  $\theta$  suhteen antavassa lausekkeessa

$$t = g(x_1, x_2, \dots, x_n)$$

muuttujien

$$x_1, x_2, \dots, x_n$$

paikalle havainnot (satunnaismuuttujat)

$$X_1, X_2, \dots, X_n$$

saadaan parametrin  $\theta$  suurimman uskottavuuden **estimaattori** eli **SU-estimaattori**

$$\hat{\theta} = g(X_1, X_2, \dots, X_n)$$



## Suurimman uskottavuuden menetelmä

# Kommentteja

---

- Suurimman uskottavuuden menetelmän idea on antaa mallin parametreille sellaiset arvot, jotka tekevät saadun havaintoaineiston mahdollisimman todennäköiseksi.

## SU-estimaattorin määrittäminen 1/2

---

- Parametrin  $\theta$  suurimman uskottavuuden estimaattori määrätään *maksimoimalla uskottavuusfunktio*

$$L(\theta) = L(\theta ; x_1, x_2, \dots, x_n)$$

parametrin  $\theta$  suhteen.

- Ns. säännöllisissä tapauksissa maksimi löydetään merkitsemällä uskottavuusfunktion  $L(\theta)$  *derivaatta*

$$L'(\theta)$$

*nollaksi* ja ratkaisemalla  $\theta$  saadusta *yhtälöstä*

$$L'(\theta) = 0$$

## Suurimman uskottavuuden menetelmä

# SU-estimaattorin määrittäminen 2/2

---

- Jos parametrin  $\theta$  arvo

$$t = g(x_1, x_2, \dots, x_n)$$

tuottaa uskottavuusfunktion  $L(\theta)$  maksimin, parametrin  $\theta$  suurimman uskottavuuden estimaattori on

$$\hat{\theta} = g(X_1, X_2, \dots, X_n)$$

jossa  $X_1, X_2, \dots, X_n$  on yksinkertainen satunnaisotos siitä jakaumasta, johon uskottavuusfunktio  $L(\theta)$  liittyy.

## Logaritminen uskottavuusfunktio 1/3

---

- Uskottavuusfunktion maksimi kannattaa tavallisesti etsiä maksimoimalla uskottavuusfunktion sijasta *logaritminen uskottavuusfunktio* (uskottavuusfunktion logaritmi)

$$l(\theta) = \log L(\theta)$$

- Tämä johtuu seuraavista seikoista:
  - (i) Logaritminen uskottavuusfunktio ja uskottavuusfunktio saavuttavat ääriarvonsa *samassa pisteessä*, koska logaritmi on *aidosti monotoninen funktio*.
  - (ii) Logaritminen uskottavuusfunktio on monien todennäköisyysjakaumien tapauksessa uskottavuusfunktioita *yksinkertaisempi* muodoltaan.

## Logaritminen uskottavuusfunktio 2/3

---

- Koska havainnot  $X_1, X_2, \dots, X_n$  on tässä oletettu *riippumattomiksi*, *logaritminen uskottavuusfunktio* voidaan kirjoittaa seuraavaan muotoon:

$$\begin{aligned}l(\theta) &= \log L(\theta) \\ &= \log (f(x_1; \theta) f(x_2; \theta) \cdots f(x_n; \theta)) \\ &= \log f(x_1; \theta) + \log f(x_2; \theta) + \cdots + \log f(x_n; \theta) \\ &= l(\theta; x_1) + l(\theta; x_2) + \cdots + l(\theta; x_n)\end{aligned}$$

jossa

$$l(\theta; x_i) = \log f(x_i; \theta), \quad i = 1, 2, \dots, n$$

on havaintoarvoon  $x_i$  liittyvä logaritminen uskottavuusfunktio.

## Logaritminen uskottavuusfunktio 3/3

---

- Logaritmisen uskottavuusfunktion summaesityksen

$$l(\theta) = l(\theta ; x_1) + l(\theta ; x_2) + \cdots + l(\theta ; x_n)$$

maksimointi on usein *ratkaisevasti helpompaa* kuin uskottavuusfunktion itsensä maksimointi.

## Suurimman uskottavuuden menetelmä

# SU-estimaattorin ominaisuudet

---

- Olkoon  $X_1, X_2, \dots, X_n$  yksinkertainen satunnaisotos jakaumasta  $f(x; \theta)$ , jonka parametrina on  $\theta$ .
- Olkoon  $\hat{\theta}$  parametrin  $\theta$  suurimman uskottavuuden eli **SU-estimaattori**.
- Hyvä estimaattori on *harhaton, tehokas ja tarkentuva*.
- **SU-estimaattori ei välttämättä täytä yhtäkään hyvän estimaattorin kriteereistä, joten suurimman uskottavuuden menetelmää käytettäessä on aina erikseen varmistettava tuloksena saadun estimaattorin hyvyys.**

## SU-estimaattorin asymptoottiset ominaisuudet

---

- Jos SU-estimaattori ei täytä hyvän estimaattorin kriteereitä *äärellisillä havaintojen lukumäärillä*, sen käyttöä estimaattorina voidaan perustella SU-estimaattorin *yleisillä asymptoottisilla ominaisuuksilla*.
- Hyvin yleisin ehdoin pätee:
  - (i) SU-estimaattori  $\hat{\theta}$  on **tarkentuva** eli
$$\Pr(\hat{\theta} \rightarrow \theta) = 1, \text{ kun } n \rightarrow +\infty$$
  - (ii) SU-estimaattori  $\hat{\theta}$  on **asymptoottisesti normaalin**.



# Suurimman uskottavuuden menetelmä

## Esimerkkejä

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*yksinkertainen satunnaisotos* jakaumasta  $f(x; \theta)$ .

- Tarkastellaan seuraavien jakaumien parametrien SU-estimointia eli estimointia suurimman uskottavuuden menetelmällä
  - **Normaalijakauma**
  - **Bernoulli-jakauma**

# Normaalijakauman parametrien estimointi SU-menetelmällä

## Normaalijakauma ja sen parametrointi

---

- Satunnaismuuttuja  $X$  noudattaa **normaalijakaumaa**  $N(\mu, \sigma^2)$ , jos sen *tiheysfunktio* on

$$f(x; \mu, \sigma^2) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2\right\}$$

$$-\infty < \mu < +\infty, \sigma > 0$$

- Normaalijakauman *parametreina* ovat jakauman *odotusarvo*

$$E(X) = \mu$$

ja *varianssi*

$$\text{Var}(X) = \sigma^2$$

# Normaalijakauman parametrien estimointi SU-menetelmällä

## Otos normaalijakaumasta

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*yksinkertainen satunnaisotos* normaalijakaumasta

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

- Tällöin havainnot  $X_1, X_2, \dots, X_n$  ovat *riippumattomia, samaa normaalijakaumaa*

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

noudattavia satunnaismuuttujia.

# Normaalijakauman parametrien estimointi SU-menetelmällä

## Normaalijakautuneen otoksen uskottavuusfunktio ja log-uskottavuusfunktio

---

- Otoksen  $X_1, X_2, \dots, X_n$  uskottavuusfunktio on

$$\begin{aligned} L(\mu, \sigma^2; x_1, x_2, \dots, x_n) &= f(x_1; \mu, \sigma^2) f(x_2; \mu, \sigma^2) \cdots f(x_n; \mu, \sigma^2) \\ &= \sigma^{-n} (2\pi)^{-\frac{1}{2}n} \exp\left\{-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right\} \end{aligned}$$

- Otoksen  $X_1, X_2, \dots, X_n$  logaritminen uskottavuusfunktio on

$$\begin{aligned} l(\mu, \sigma^2; x_1, x_2, \dots, x_n) &= \log L(\mu, \sigma^2; x_1, x_2, \dots, x_n) \\ &= -\frac{n}{2} \log \sigma^2 - \frac{1}{2} n \log(2\pi) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \end{aligned}$$

## Normaalijakauman parametrien SU-estimaattorit

---

- Normaalijakauman  $N(\mu, \sigma^2)$  odotusarvon  $\mu$  ja varianssin  $\sigma^2$  **suurimman uskottavuuden estimaattorit** ovat havaintojen  $X_1, X_2, \dots, X_n$  *aritmeettinen keskiarvo*

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

ja *otosvarianssi*

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

# Normaalijakauman parametrien estimointi SU-menetelmällä

## SU-estimaattoreiden johto 1/2

---

- *Derivoidaan* logaritminen uskottavuusfunktio

$$l(\mu, \sigma^2) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2} n \log(2\pi) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

*ensin* parametrin  $\mu$  suhteen ja merkitään derivaatta nolllaksi:

$$\frac{\partial l(\mu, \sigma^2)}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu) = 0$$

- Derivaatan ainoa *nollakohta*

$$\hat{\mu} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

antaa log-uskottavuusfunktion *maksimin* parametrin  $\mu$  suhteen.

# Normaalijakauman parametrien estimointi SU-menetelmällä

## SU-estimaattoreiden johto 2/2

---

- *Sijoitetaan* ratkaisu  $\mu = \bar{x}$  logaritmiseen uskottavuusfunktioon:

$$l(\bar{x}, \sigma^2) = -\frac{n}{2} \log \sigma^2 - \frac{1}{2} n \log(2\pi) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \bar{x})^2$$

- *Derivoidaan* funktio  $l(\bar{x}, \sigma^2)$  parametrin  $\sigma^2$  suhteen ja merkitään derivaatta nolllaksi:

$$\frac{\partial l(\mu, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i - \bar{x}) = 0$$

- Derivaatan ainoa *nollakohta*

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

antaa log-uskottavuusfunktion *maksimin* parametrin  $\sigma^2$  suhteen.

# Normaalijakauman parametrien estimointi SU-menetelmällä

## SU-estimaattoreiden ominaisuudet 1/2

---

- Normaalijakauman  $N(\mu, \sigma^2)$  odotusarvon  $\mu$  SU-estimaattorilla  $\hat{\mu}$  on seuraavat ominaisuudet:
  - (i)  $\hat{\mu}$  on *harhaton*.
  - (ii)  $\hat{\mu}$  on *tehokas* eli minimivarianssinen estimaattori.
  - (iii)  $\hat{\mu}$  on *tarkentuva*.
  - (iv)  $\hat{\mu}$  noudattaa *normaalijakaumaa*:

$$\hat{\mu} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$



## Normaalijakauman parametrien estimointi SU-menetelmällä

# SU-estimaattoreiden ominaisuudet 2/2

---

- Normaalijakauman  $N(\mu, \sigma^2)$  varianssin  $\sigma^2$  SU-estimaattorilla  $\hat{\sigma}^2$  on seuraavat ominaisuudet:

(i)  $\hat{\sigma}^2$  on *harhainen*, mutta estimaattori

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

on *harhaton*.

(ii)  $\hat{\sigma}^2$  ei ole *tehokas* eli minimivarianssinen estimaattori.

(iii)  $\hat{\sigma}^2$  on *tarkentuva*.

(iv)  $(n-1) S^2 / \sigma^2$  noudattaa  $\chi^2$ -jakaumaa:

$$\frac{(n-1)S^2}{\sigma^2} \sim \chi^2(n-1)$$

# Bernoulli-jakauman parametrien estimointi SU-menetelmällä

## Bernoulli-jakauma ja sen parametrintointi

---

- Olkoon  $A$  *tapahtuma*, jonka todennäköisyys on  $p$ :

$$\Pr(A) = p$$

- Määritellään satunnaismuuttuja  $X$  seuraavasti:

$$X = \begin{cases} 1, & \text{jos } A \text{ tapahtuu} \\ 0, & \text{jos } A \text{ ei tapahdu} \end{cases}$$

- Satunnaismuuttuja  $X$  noudattaa **Bernoulli-jakaumaa**  $B(p)$  ja sen *pistetodennäköisyysfunktio* on

$$f(x; p) = p^x (1-p)^{1-x}, \quad x = 0, 1; \quad 0 < p < 1$$

- Bernoulli-jakauman ainoa *parametri*  $p$  yhtyy jakauman *odotusarvoon*:

$$p = E(X)$$

# Bernoulli-jakauman parametrien estimointi SU-menetelmällä

## Otos Bernoulli-jakaumasta

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*yksinkertainen satunnaisotos Bernoulli-jakaumasta*

$$B(p)$$

- Tällöin havainnot  $X_1, X_2, \dots, X_n$  ovat *riippumattomia, samaa Bernoulli-jakaumaa*

$$B(p)$$

noudattavia satunnaismuuttujia.

# Bernoulli-jakauman parametrien estimointi SU-menetelmällä

## Bernoulli-jakautuneen otoksen uskottavuusfunktio ja log-uskottavuusfunktio

---

- Otoksen  $X_1, X_2, \dots, X_n$  uskottavuusfunktio on

$$\begin{aligned}L(p; x_1, x_2, \dots, x_n) \\ &= f(x_1; p) f(x_2; p) \cdots f(x_n; p) \\ &= p^{\sum x_i} (1-p)^{n-\sum x_i}\end{aligned}$$

- Otoksen  $X_1, X_2, \dots, X_n$  logaritminen uskottavuusfunktio on

$$\begin{aligned}l(p; x_1, x_2, \dots, x_n) \\ &= \log L(p; x_1, x_2, \dots, x_n) \\ &= \sum_{i=1}^n x_i \log(p) + (n - \sum_{i=1}^n x_i) \log(1-p)\end{aligned}$$

# Bernoulli-jakauman parametrien estimointi SU-menetelmällä

## Bernoulli-jakauman odotusarvoparametrin SU-estimaattori 1/2

---

- Bernoulli-jakauman  $B(p)$  odotusarvoparametrin  $p$  **suurimman uskottavuuden estimaattori** on havaintojen  $X_1, X_2, \dots, X_n$  *aritmeettinen keskiarvo*

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

# Bernoulli-jakauman parametrien estimointi SU-menetelmällä

## Bernoulli-jakauman odotusarvoparametrin SU-estimaattori 2/2

---

- Koska

$$X_i = \begin{cases} 1, & \text{jos } A \text{ tapahtuu} \\ 0, & \text{jos } A \text{ ei tapahdu} \end{cases}$$

niin

$$\sum_{i=1}^n X_i = f$$

jossa  $f$  on tapahtuman  $A$  *frekvenssi* otoksessa.

- Siten Bernoulli-jakauman odotusarvoparametrin  $p$  *suurimman uskottavuuden estimaattori*

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{f}{n}$$

on tapahtuman  $A$  *suhteellinen frekvenssi* otoksessa.

# Bernoulli-jakauman parametrien estimointi SU-menetelmällä

## SU-estimaattorin johto

---

- *Derivoidaan* logaritminen uskottavuusfunktio

$$l(p) = \sum_{i=1}^n x_i \log(p) + (n - \sum_{i=1}^n x_i) \log(1-p)$$

parametrin  $p$  suhteen ja merkitään derivaatta nolllaksi:

$$\frac{\partial l(p)}{\partial p} = \frac{\sum x_i}{p} - \frac{n - \sum x_i}{1-p} = 0$$

- Derivaatan ainoa *nollakohta*

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}$$

antaa uskottavuusfunktion *maksimin*.

# Bernoulli-jakauman parametrien estimointi SU-menetelmällä

## SU-estimaattorin ominaisuudet

---

- Bernoulli-jakauman  $B(p)$  odotusarvoparametrin  $p$  SU-estimaattorilla  $\hat{p}$  on seuraavat ominaisuudet:
  - (i)  $\hat{p}$  on *harhaton*.
  - (ii)  $\hat{p}$  on (asymptoottisesti) *tehokas* eli minimivarianssinen estimaattori.
  - (iii)  $\hat{p}$  on *tarkentuva*.
  - (iv)  $\hat{p}$  noudattaa *asymptoottisesti normaalijakaumaa*:

$$\hat{p} \sim_a N\left(p, \frac{p(1-p)}{n}\right)$$



---

## ***Tilastolliset menetelmät***

### **Osa 2: Otokset, otosjakaumat ja estimointi**

- **Väliestimointi**

# Todennäköisyysjakaumien parametrien estimointi

## Piste-estimointi ja väliestimointi

---

- Todennäköisyysjakauman *parametrin arvon estimointia* kutsutaan tavallisesti **piste-estimoinniksi**.
- Estimaatin arvo vaihtelee otoksesta toiseen, joten siihen liittyy tietty epätarkkuus. Herää kysymys, missä *rajoissa* parametrin todellinen arvo  $\theta$  on.
- Ei ole järkevää yrittää antaa rajoja, joiden sisällä  $\theta$ :n arvo on 'täysin varmasti'. Sen sijaan voidaan yrittää antaa väli, jonka uskotaan peittävän alleen parametrin tarkan arvon tietyllä suurella todennäköisyydellä. Tällöistä väliä kutsutaan **luottamusväliksi**.
- Luottamusvälin määräämistä kutsutaan **väliestimoinniksi**.

# Väliestimointi

---

## >> Luottamusväli

**Normaalijakauman odotusarvon luottamusväli**

**Normaalijakauman varianssin luottamusväli**

**Bernoulli-jakauman odotusarvon luottamusväli**

## Luottamusväli ja luottamustaso

---

- *Väliestimoinnissa todennäköisyysjakauman  $f(x ; \theta)$  tuntemattomalle parametrille  $\theta$  pyritään määräämään havainnoista riippuva väli, joka tietyllä, soveltajan valitsemalla todennäköisyydellä, peittää parametrin todellisen arvon.*
- Konstruoitua väliä kutsutaan **luottamusväliksi** ja valittua todennäköisyyttä kutsutaan **luottamustasoksi**.

# Luottamusvälin määrittäminen

---

- Olkoon  $f(x; \theta)$  todennäköisyysjakauma, jonka määrää tuntematon parametri  $\theta$ , ja  $X_1, X_2, \dots, X_n$  satunnaisotos jakaumasta  $f(x; \theta)$ .

- Valitaan **luottamustaso**  $(1 - \alpha)$  siten, että

$$0 < 1 - \alpha < 1$$

- Määrätään satunnaismuuttujat

$$L = L(X_1, X_2, \dots, X_n)$$

$$U = U(X_1, X_2, \dots, X_n)$$

siten, että

$$\Pr(\theta \in (L, U)) = 1 - \alpha$$

- Tällöin sanomme, että väli  $(L, U)$  on **parametrin  $\theta$  luottamusväli luottamustasolla  $(1 - \alpha)$** .

## Luottamusvälin määrittäminen: Kommentit

---

- Luottamusvälin  $(L, U)$  päätepisteet  $L$  ja  $U$  riippuvat yleensä sekä havainnoista  $X_1, X_2, \dots, X_n$  että valitusta luottamustasosta  $(1 - \alpha)$ .
- Käytännössä  $\theta$ :n arvo on tuntematon eikä ole tietoa, onko sen arvo saadun luottamusvälin sisällä. Näin kuitenkin uskotaan. Käytettäessä esim. 95%:n luottamusväliä keskimäärin 5 kertaa sadasta käy niin, että tarkka arvo jää saadun välin ulkopuolelle.

## Johtopäätökset luottamusväleistä

---

- Tehdään *johtopäätös*, että konstruoitu luottamusväli peittää parametrin  $\theta$  tuntemattoman todellisen arvon.
  - (i) Luottamusvälin konstruktiosta seuraa, että tehty johtopäätös *on oikea*  $100 \times (1 - \alpha)$  %:ssa tapauksia.
  - (ii) Luottamusvälin konstruktiosta seuraa, että tehty johtopäätös *on väärä*  $100 \times \alpha$  %:ssa tapauksia.
- **Huomautus:**

Virheellisen johtopäätöksen mahdollisuutta *ei saada häviämään*, ellei luottamusväliä tehdä *niin leveäksi*, että väli *ei enää sisällä informaatiota* parametrin  $\theta$  todellisesta arvosta.

## Esimerkki: Normaalijakauman odotusarvon luottamusväli, (kun $\sigma$ :n arvo tiedossa) 1/2

---

- Jos estimaattori  $\hat{\theta}$  on jatkuva ja sen jakauma on tiedossa, luottamusväli voidaan ilmoittaa havaintojen avulla.
- Olkoon  $X \sim N(\mu, \sigma^2)$  ja  $X_1, X_2, \dots, X_n$  (yksinkertainen) satunnaisotos normaalijakaumasta  $N(\mu, \sigma^2)$ . Silloin  $\mu$ :n harhaton estimaattori on

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

ja tiedetään että

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



## Esimerkki: Normaalijakauman odotusarvon luottamusväli, (kun $\sigma$ :n arvo tiedossa) 2/2

---

- Oletetaan että  $\sigma$ :n arvo on tiedossa.
- Lasketaan  $\mu$ :n 95%:n luottamusväli: Tiedetään taulukoista että

$$P\left(\left|\frac{\bar{X} - \mu}{\sigma/\sqrt{n}}\right| \leq 1.96\right) = 0.95$$

- Tämä voi muokata muotoon

$$P(\bar{X} - 1.96\sigma/\sqrt{n} \leq \mu \leq \bar{X} + 1.96\sigma/\sqrt{n}) = 0.95$$

- Joten väli  $\left[\bar{X} - 1.96\sigma/\sqrt{n}, \bar{X} + 1.96\sigma/\sqrt{n}\right]$  on  $\mu$ :n 95%:n luottamusväli.
- Otoksesta  $(x_1, \dots, x_n)$  lasketaan  $\mu$ :n 95%:n luottamusvälin arvoksi

$$\left[\bar{x} - 1.96\sigma/\sqrt{n}, \bar{x} + 1.96\sigma/\sqrt{n}\right]$$

# Väliestimointi

---

## Luottamusväli

- >> **Normaalijakauman odotusarvon luottamusväli**
- Normaalijakauman varianssin luottamusväli**
- Bernoulli-jakauman odotusarvon luottamusväli**

## Normaalijakauman parametrien estimointi

---

- Olkoon  $X_1, X_2, \dots, X_n$  (yksinkertainen) satunnaisotos normaalijakaumasta  $N(\mu, \sigma^2)$
- *Estimoidaan* normaalijakauman  $N(\mu, \sigma^2)$  parametrit  $\mu$  ja  $\sigma^2$  niiden *harhattomilla estimaattoreilla*:
  - (i) *Odotusarvoparametrin*  $\mu$  harhaton estimaattori:

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

- (ii) *Varianssiparametrin*  $\sigma^2$  harhaton estimaattori:

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

## Normaalijakauman odotusarvon luottamusväli

# Luottamuskertoimet

---

- Olkoon valittu luottamustaso  $(1 - \alpha)$ .
- Määrätään **luottamuskertoimet**  $-t_{\alpha/2}$  ja  $+t_{\alpha/2}$  siten, että

$$\Pr(t \leq -t_{\alpha/2}) = \frac{\alpha}{2}$$

$$\Pr(t \geq +t_{\alpha/2}) = \frac{\alpha}{2}$$

jossa satunnaismuuttuja  $t$  noudattaa *Studentin  $t$ -jakaumaa* vapausastein  $(n - 1)$ :

$$t \sim t(n - 1)$$


- Luottamuskertoimet  $-t_{\alpha/2}$  ja  $+t_{\alpha/2}$  toteuttavat ehdon

$$\Pr(-t_{\alpha/2} \leq t \leq +t_{\alpha/2}) = 1 - \alpha$$

# Normaalijakauman odotusarvon luottamusväli

## Luottamuskertoimien määrittäminen: Havainnollistus

- Luottamuskertoimet  $-t_{\alpha/2}$  ja  $+t_{\alpha/2}$  jakavat  $t$ -jakauman tiheysfunktion kuvaajan alle jäävän todennäköisyysmassan (= 1) kolmeen osaan:
  - (1) Pisteeseen  $-t_{\alpha/2}$  vasemmalle puolelle jää  $\alpha/2$  % massasta.
  - (2) Pisteeseen  $+t_{\alpha/2}$  oikealle puolelle jää  $\alpha/2$  % massasta.
  - (3) Pisteiden  $-t_{\alpha/2}$  ja  $+t_{\alpha/2}$  väliin jää  $(1 - \alpha)$  % massasta.
- Huomaa, että
$$\alpha/2 + \alpha/2 + (1 - \alpha) = 1$$



## Luottamusväli normaalijakauman odotusarvolle

---

- Normaalijakauman **odotusarvoparametrin  $\mu$  luottamusväli luottamustasolla  $(1 - \alpha)$**  on muotoa

$$\left( \bar{X} - t_{\alpha/2} \frac{S}{\sqrt{n}}, \bar{X} + t_{\alpha/2} \frac{S}{\sqrt{n}} \right)$$

jossa

$\bar{X}$  = havaintojen *aritmeettinen keskiarvo*

$S^2$  = havaintojen harhaton *otosvarianssi*

$n$  = havaintojen *lukumäärä*

$-t_{\alpha/2}, +t_{\alpha/2}$


= luottamustasoon  $(1 - \alpha)$  liittyvät *luottamuskertoimet  $t$ -jakaumasta vapausastein  $(n - 1)$*

# Normaalijakauman odotusarvon luottamusväli

## Luottamusväli ja sen pituus

---

- Normaalijakauman odotusarvon  $\mu$  luottamusväli luottamustasolla  $(1 - \alpha)$ :



# Normaalijakauman odotusarvon luottamusväli

## Luottamusvälin johto 1/5

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*yksinkertainen satunnaisotos normaalijakaumasta*

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

- Olkoon

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

*havaintojen  $X_1, X_2, \dots, X_n$  aritmeettinen keskiarvo ja*

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

*havaintojen  $X_1, X_2, \dots, X_n$  (harhaton) otosvarianssi.*



# Normaalijakauman odotusarvon luottamusväli

## Luottamusvälin johto 2/5

---

- Määritellään satunnaismuuttuja

$$t = \frac{\bar{X} - \mu}{S/\sqrt{n}}$$

- Voidaan osoittaa että  $t$  noudattaa *Studentin t-jakaumaa* vapausastein  $(n - 1)$  :

$$t \sim t(n-1)$$

ks. lukua **Otokset ja otosjakaumat**.

# Normaalijakauman odotusarvon luottamusväli

## Luottamusvälin johto 3/5

---

- Määrätään  $t$ -jakaumasta vapausastein  $(n - 1)$  piste  $+t_{\alpha/2}$  siten, että

$$\Pr(t \geq +t_{\alpha/2}) = \frac{\alpha}{2}$$

jolloin ( $t$ -jakauman symmetrian perusteella)

$$\Pr(t \leq -t_{\alpha/2}) = \frac{\alpha}{2}$$

ja edelleen

$$\Pr(-t_{\alpha/2} \leq t \leq +t_{\alpha/2}) = 1 - \alpha$$

# Normaalijakauman odotusarvon luottamusväli

## Luottamusvälin johto 4/5

---

- Tarkastellaan epäyhtälöketjua

$$-t_{\alpha/2} \leq t \leq +t_{\alpha/2}$$

- Sijoittamalla tähän epäyhtälöketjuun satunnaismuuttujan  $t$  lauseke, saadaan epäyhtälöketju

$$-t_{\alpha/2} \leq \frac{\bar{X} - \mu}{S/\sqrt{n}} \leq +t_{\alpha/2}$$

- Tästä epäyhtälöketjusta saadaan sen kanssa *yhtäpitävä* epäyhtälöketju

$$\bar{X} - t_{\alpha/2} \frac{S}{\sqrt{n}} \leq \mu \leq \bar{X} + t_{\alpha/2} \frac{S}{\sqrt{n}}$$

# Normaalijakauman odotusarvon luottamusväli

## Luottamusvälin johto 5/5

---

- Yhdistämällä saatu epäyhtälö siihen, että

$$\Pr(-t_{\alpha/2} \leq t \leq +t_{\alpha/2}) = 1 - \alpha$$

saadaan vihdoin

$$\Pr\left(\bar{X} - t_{\alpha/2} \frac{S}{\sqrt{n}} \leq \mu \leq \bar{X} + t_{\alpha/2} \frac{S}{\sqrt{n}}\right) = 1 - \alpha$$

Siten konstruoitu luottamusväli *peittää* parametrin  $\mu$  todellisen arvon todennäköisyydellä  $(1 - \alpha)$  ja se *ei peitä* parametrin  $\mu$  todellista arvoa todennäköisyydellä  $\alpha$ .

## Normaalijakauman odotusarvon luottamusväli

# Luottamusvälin ominaisuudet

---

- Normaalijakauman odotusarvon  $\mu$  luottamusvälin *keskipiste*  $\bar{X}$  vaihtelee otoksesta toiseen.
- Luottamusvälin *pituus*

$$2 \times t_{\alpha/2} \frac{S}{\sqrt{n}}$$

vaihtelee otoksesta toiseen.

- Luottamusvälin *pituus* riippuu valitusta luottamustasosta  $(1 - \alpha)$ , havaintojen lukumäärästä  $n$  ja otosvarianssista  $S^2$  .

## Normaalijakauman odotusarvon luottamusväli

# Vaatimukset luottamusvälille

---

- Olisi toivottavaa pystyä konstruoimaan odotusarvolle  $\mu$  mahdollisimman *lyhyt* luottamusväli, johon liittyvä luottamustaso olisi mahdollisimman *korkea*.
- Vaatimusten samanaikainen täyttäminen *ei ole* kuitenkaan *mahdollista, jos otoskoko pidetään kiinteänä*:
  - (i) *Luottamustason kasvattaminen pidentää luottamusväliä, jolloin tieto parametrin  $\mu$  todellisen arvon sijainnista tulee epätarkemmaksi.*
  - (ii) *Luottamusvälin lyhentäminen pienentää luottamustasoa, jolloin tieto parametrin  $\mu$  todellisen arvon sijainnista tulee epävarmemmaksi.*

## Normaalijakauman odotusarvon luottamusväli

### Esimerkki – 1/6

---


- Kone tekee *ruuveja*, joiden *pituudet vaihtelevat satunnaisesti noudattaen normaalijakaumaa*;
- Ruuvien joukosta poimitaan *yksinkertainen satunnaisotos*, jonka *koko  $n = 30$*  ja otokseen poimittujen ruuvien pituudet mitataan.
- Taulukko oikealla esittää pituuksien *luokiteltua frekvenssi-jakaumaa*.

Luokkavälit	Luokkafrekvenssit
(9.85,9.90]	1
(9.90,9.95]	2
(9.95,10.00]	6
(10.00,10.05]	3
(10.05,10.10]	5
(10.10,10.15]	4
(10.15,10.20]	5
(10.20,10.25]	3
(10.25,10.30]	1

## Normaalijakauman odotusarvon luottamusväli

### Esimerkki – 2/6

- Kuva oikealla esittää otokseen poimittujen ruuvien pituuksien luokiteltua frekvenssijakaumaa vastaavaa *histogrammia*.
- *Luokkavälit* määräävät histogrammin suorakaiteiden *kannat*.
- Suorakaiteiden *korkeudet* on valittu niin, että suorakaiteiden *pinta-alat* suhtautuvat toisiinsa kuten vastaavat *luokka-frekvenssit*.





## Normaalijakauman odotusarvon luottamusväli

### Esimerkki – 3/6

---

Otoskoko:	$n = 30$
Pituuksien aritmeettinen keskiarvo:	$\bar{x} = 10.09 \text{ cm}$
Pituuksien otoskeskihajonta:	$s = 0.1038 \text{ cm}$

- Konstruoidaan ruuvien *todelliselle keskipituudelle*  $\mu$  *luottamusväli luottamustasolla* 0.95.
- Valitaan *luottamuskertoimet*  $-t_{0.025}$  ja  $+t_{0.025}$  siten, että
$$\Pr(t \leq -t_{0.025}) = \Pr(t \geq +t_{0.025}) = 0.025$$
jossa satunnaismuuttuja  $t$  noudattaa *Studentin t-jakaumaa* vapausastein  $n - 1 = 29$ .

# Normaalijakauman odotusarvon luottamusväli

## Esimerkki – 4/6

- $t$ -jakauman *taulukoista* nähdään, että

$$\Pr(t \geq +2.045) = 0.025$$

$$\Pr(t \leq -2.045) = 0.025$$

kun vapausasteiden lukumäärä


$$n - 1 = 29$$

- Siten *luottamuskertoimet* ovat:

$$+t_{0.025} = +2.045$$

$$-t_{0.025} = -2.045$$

- Kuvio oikealla havainnollistaa luottamuskertoimien valintaa.



## Normaalijakauman odotusarvon luottamusväli

### Esimerkki – 5/6

---

- *Luottamusväliksi* saadaan:

$$\begin{aligned}\bar{x} \pm t_{\alpha/2} \frac{s}{\sqrt{n}} &= 10.09 \pm 2.045 \times \frac{0.1038}{\sqrt{30}} \\ &= 10.09 \pm 0.04 \\ &= (10.05, 10.13)\end{aligned}$$

- Siten tiedämme, että *ruuvien todellinen keskipituus on todennäköisyydellä 0.95 välillä*  
(10.05, 10.13)

# Normaalijakauman odotusarvon luottamusväli

## Esimerkki – 6/6

---

- *Luottamustason 0.95 tulkinta:*

Oletetaan, että poimimme koneen tekemien ruuvien joukosta *toistuvasti* yksinkertaisia satunnaisotoksia, joiden koko on 30 ja konstruimme *jokaisesta* otoksesta 95 %:n luottamusvälin edellä esitetyllä menetelmällä.

Tällöin:

- (i) *Konstruoidusta väleistä keskimäärin 95 % peittää ruuvien todellisen, mutta tuntemattoman keskipituuden.*
- (ii) *Konstruoidusta väleistä keskimäärin 5 % ei peitä ruuvien todellista, mutta tuntematonta keskipituutta.*

# Väliestimointi

---

**Luottamusväli**

**Normaalijakauman odotusarvon luottamusväli**

**>> Normaalijakauman varianssin luottamusväli**

**Bernoulli-jakauman odotusarvon luottamusväli**

# Normaalijakauman varianssin luottamusväli

## Otos normaalijakaumasta

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*(yksinkertainen) satunnaisotos* normaalijakaumasta

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

- Tällöin satunnaismuuttujat  $X_1, X_2, \dots, X_n$  ovat *riippumattomia* ja noudattavat *samaa normaalijakaumaa*

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

## Normaalijakauman parametrien estimointi

---

- *Estimoidaan* normaalijakauman  $N(\mu, \sigma^2)$  parametrit  $\mu$  ja  $\sigma^2$  niiden *harhattomilla estimaattoreilla*:

- (i) *Odotusarvoparametrin*  $\mu$  harhaton estimaattori:

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

- (ii) *Varianssiparametrin*  $\sigma^2$  harhaton estimaattori:

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

## Normaalijakauman varianssin luottamusväli

# Luottamustaso

---

- Määrätään **luottamusväli normaalijakauman varianssiparametrille  $\sigma^2$** .
- Valitaan **luottamustasoksi**  
 $1 - \alpha$
- Luottamustaso kiinnittää todennäköisyyden, jolla konstruoitava luottamusväli peittää normaalijakauman varianssin  $\sigma^2$  todellisen arvon.



## Normaalijakauman varianssin luottamusväli

# Luottamuskertoimet

---

- Olkoon valittu luottamustaso  $(1 - \alpha)$ .
- Määrätään **luottamuskertoimet**  $\chi^2_{1-\alpha/2}$  ja  $\chi^2_{\alpha/2}$  siten, että

$$\Pr(\chi^2 \leq \chi^2_{1-\alpha/2}) = \frac{\alpha}{2}$$

$$\Pr(\chi^2 \geq \chi^2_{\alpha/2}) = \frac{\alpha}{2}$$

jossa satunnaismuuttuja  $\chi^2$  noudattaa  $\chi^2$ -jakaumaa vapausastein  $(n - 1)$ :


$$\chi^2 \sim \chi^2(n - 1)$$

- Luottamuskertoimet  $\chi^2_{1-\alpha/2}$  ja  $\chi^2_{\alpha/2}$  toteuttavat ehdon

$$\Pr(\chi^2_{1-\alpha/2} \leq \chi^2 \leq \chi^2_{\alpha/2}) = 1 - \alpha$$

# Luottamuskertoimien määrittäminen: Havainnollistus

- Luottamuskertoimet  $\chi^2_{1-\alpha/2}$  ja  $\chi^2_{\alpha/2}$  jakavat  $\chi^2$ -jakauman tiheysfunktion kuvaajan alle jäävän todennäköisyysmassan (= 1) kolmeen osaan:
  - (1) Pisteiden  $\chi^2_{1-\alpha/2}$  vasemmalle puolelle jää  $\alpha/2$  % massasta.
  - (2) Pisteiden  $\chi^2_{\alpha/2}$  oikealle puolelle jää  $\alpha/2$  % massasta.
  - (3) Pisteiden  $\chi^2_{1-\alpha/2}$  ja  $\chi^2_{\alpha/2}$  väliin jää  $(1 - \alpha)$  % massasta.
- Huomaa, että
$$\alpha/2 + \alpha/2 + (1 - \alpha) = 1$$



## Luottamusväli normaalijakauman varianssille

---

- Normaalijakauman **varianssiparametrin  $\sigma^2$  luottamusväli luottamustasolla  $(1 - \alpha)$**  on muotoa

$$\left( \frac{(n-1)S^2}{\chi_{\alpha/2}^2}, \frac{(n-1)S^2}{\chi_{1-\alpha/2}^2} \right)$$

jossa

$S^2$  = havaintojen harhaton *otosvarianssi*

$n$  = havaintojen *lukumäärä*

$\chi_{1-\alpha/2}^2, \chi_{\alpha/2}^2$

= luottamustasoon  $(1 - \alpha)$  liittyvät *luottamuskertoimet  $\chi^2$ -jakaumasta vapausastein  $(n - 1)$*

## Normaalijakauman varianssin luottamusväli

# Luottamusvälin ominaisuudet 1/2

---

- Normaalijakauman varianssin  $\sigma^2$  luottamusvälin *pituus*

$$(n-1)S^2 \left( \frac{1}{\chi_{1-\alpha/2}^2} - \frac{1}{\chi_{\alpha/2}^2} \right)$$

vaihtelee otoksesta toiseen.

- Luottamusvälin *pituus* riippuu valitusta luottamustasosta  $(1 - \alpha)$  ja otosvarianssista  $s^2$  sekä havaintojen lukumäärästä  $n$ .

## Normaalijakauman varianssin luottamusväli

# Luottamusvälin ominaisuudet 2/2

---

- Luottamusväli *lyhenee (pitenee)*, jos *luottamustasoa*  $(1 - \alpha)$  *pienennetään (kasvatetaan)*.
- Luottamusväli *lyhenee (pitenee)*, jos *otosvarianssi*  $s^2$  *pienenee (kasvaa)*.
- Luottamusväli *lyhenee*, jos *otoskokoa*  $n$  *kasvatetaan*.

## Normaalijakauman varianssin luottamusväli

### Vaatimukset luottamusvälille

---

- Olisi toivottavaa pystyä konstruoimaan varianssi-parametrille  $\sigma^2$  mahdollisimman *lyhyt* luottamusväli, johon liittyvä luottamustaso olisi samanaikaisesti mahdollisimman *korkea*.
- Vaatimusten samanaikainen täyttäminen *ei ole* kuitenkaan mahdollista:
  - (i) *Luottamustason kasvattaminen pidentää luottamusväliä*, jolloin tieto parametrin  $\sigma^2$  todellisen arvon sijainnista tulee *epätarkemmaksi*.
  - (ii) *Luottamusvälin lyhentäminen pienentää luottamustasoa*, jolloin tieto parametrin  $\sigma^2$  todellisen arvon sijainnista tulee *epävarmemmaksi*.

# Väliestimointi

---

**Luottamusväli**

**Normaalijakauman odotusarvon luottamusväli**

**Normaalijakauman varianssin luottamusväli**

**>> Bernoulli-jakauman odotusarvon luottamusväli**

## Bernoulli-jakauma ja sen parametointi 1/2

---

- Olkoon  $A$  kiinnostuksen kohteena oleva *tapahtuma* ja

$$\Pr(A) = p$$

$$\Pr(A^c) = 1 - p = q$$

- Määritellään satunnaismuuttuja

$$X = \begin{cases} 1, & \text{jos } A \text{ tapahtuu} \\ 0, & \text{jos } A \text{ ei tapahdu} \end{cases}$$

- Tällöin  $X$  noudattaa **Bernoulli-jakaumaa** parametrinaan

$$p = \Pr(A) = E(X)$$

- Merkitään:

$$X \sim B(p)$$



## Bernoulli-jakauma ja sen parametointi 2/2

---

- *Bernoulli-jakauman  $B(p)$  pistetodennäköisyysfunktio on*

$$f(x; p) = p^x q^{1-x}, \quad x = 0, 1$$

$$0 < p < 1$$

$$q = 1 - p$$

## Bernoulli-jakauman odotusarvoparametrin estimointi 1/2

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

(yksinkertainen) satunnaisotos Bernoulli-jakaumasta

$$B(p)$$

- *Estimoidaan Bernoulli-jakauman  $B(p)$  odotusarvoparametri  $p$  sen harhattomalla estimaattorilla:*

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i$$

## Bernoulli-jakauman odotusarvoparametrin estimointi 2/2

---

- Koska

$$X_i = \begin{cases} 1, & \text{jos } A \text{ tapahtuu} \\ 0, & \text{jos } A \text{ ei tapahdu} \end{cases}$$

niin

$$\sum_{i=1}^n X_i = f$$

jossa  $f$  on tapahtuman  $A$  *frekvenssi* otoksessa.

- Siten Bernoulli-jakauman parametrin  $p$  *estimaattori*

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i = \frac{f}{n}$$

on tapahtuman  $A$  *suhteellinen frekvenssi* otoksessa.

## Bernoulli-jakauman odotusarvon luottamusväli

# Luottamustaso

---

- Määrätään **luottamusväli Bernoulli-jakauman odotusarvoparametrille  $p$** .
- Valitaan **luottamustasoksi**  
 $1 - \alpha$
- Luottamustaso kiinnittää todennäköisyyden, jolla konstruoitava luottamusväli peittää Bernoulli-jakauman parametrin  $p$  todellisen arvon.

## Bernoulli-jakauman odotusarvon luottamusväli

# Luottamuskertoimet

---

- Olkoon valittu luottamustaso  $(1 - \alpha)$ .
- Määrätään **luottamuskertoimet**  $-z_{\alpha/2}$  ja  $+z_{\alpha/2}$  siten, että

$$\Pr(z \leq -z_{\alpha/2}) = \frac{\alpha}{2}$$

$$\Pr(z \geq +z_{\alpha/2}) = \frac{\alpha}{2}$$

jossa satunnaismuuttuja  $z$  noudattaa *standardoitua normaalijakaumaa*:

$$z \sim N(0,1)$$


- Luottamuskertoimet  $-z_{\alpha/2}$  ja  $+z_{\alpha/2}$  toteuttavat ehdon

$$\Pr(-z_{\alpha/2} \leq z \leq +z_{\alpha/2}) = 1 - \alpha$$

# Bernoulli-jakauman odotusarvon luottamusväli

## Luottamuskertoimien määrääminen: Havainnollistus

- Luottamuskertoimet  $-z_{\alpha/2}$  ja  $+z_{\alpha/2}$  jakavat normaalijakauman tiheysfunktion kuvaajan alle jäävän todennäköisyysmassan (= 1) kolmeen osaan:
  - (1) Pisteeseen  $-z_{\alpha/2}$  vasemmalle puolelle jää  $\alpha/2$  % massasta.
  - (2) Pisteeseen  $+z_{\alpha/2}$  oikealle puolelle jää  $\alpha/2$  % massasta.
  - (3) Pisteiden  $-z_{\alpha/2}$  ja  $+z_{\alpha/2}$  väliin jää  $(1 - \alpha)$  % massasta.
- Huomaa, että
$$\alpha/2 + \alpha/2 + (1 - \alpha) = 1$$



## Luottamusväli Bernoulli-jakauman odotusarvolle

---

- Bernoulli-jakauman **odotusarvoparametrin  $p$  approksimatiivinen luottamusväli luottamustasolla  $(1 - \alpha)$**  on muotoa

$$\left( \hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}, \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \right)$$

jossa

$\hat{p}$  = parametrin  $p$  *harhaton estimaattori*

$n$  = havaintojen *lukumäärä*

$-z_{\alpha/2}, +z_{\alpha/2}$

= luottamustasoon  $(1 - \alpha)$  liittyvät *luottamuskertoimet normaalijakaumasta  $N(0,1)$*

## Bernoulli-jakauman odotusarvon luottamusväli

# Luottamusväli ja sen pituus 1/2

---

- Bernoulli-jakauman odotusarvoparametrin  $p$  approksimatiivinen luottamusväli luottamustasolla  $(1 - \alpha)$  esitetään usein muodossa

$$\hat{p} \pm z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$

koska väli on symmetrinen keskipisteensä  $\hat{p}$  suhteen.

- Bernoulli-jakauman parametrin  $p$  approksimatiivisen **luottamusvälin pituus** on

$$2 \times z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$



## Bernoulli-jakauman odotusarvon luottamusväli

### Luottamusväli ja sen pituus 2/2

---

- Bernoulli-jakauman odotusarvoparametrin  $p$  approksimatiivinen luottamusväli luottamustasolla  $(1 - \alpha)$ :

$$\hat{p}$$
$$z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$$
$$z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$$

# Bernoulli-jakauman odotusarvon luottamusväli

## Luottamusvälin johto 1/5

---

- Olkoon

$$X_1, X_2, \dots, X_n$$

*yksinkertainen satunnaisotos Bernoulli-jakaumasta*

$$B(p)$$

- Olkoon

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i$$

*harhaton estimaattori parametrille  $p$ .*

- Huomaa, että  $\hat{p}$  on havaintojen  $X_1, X_2, \dots, X_n$  *aritmeettinen keskiarvo.*

# Bernoulli-jakauman odotusarvon luottamusväli

## Luottamusvälin johto 2/5

---

- Määritellään satunnaismuuttuja

$$z = \frac{\hat{p} - p}{\sqrt{\hat{p}(1 - \hat{p})/n}}$$

- Satunnaismuuttuja  $z$  noudattaa Bernoulli-jakautuneen otoksen *suhteellisen osuuden otosjakaumaa koskevan tuloksen perusteella suurissa otoksissa approksimatiivisesti standardoitua normaalijakaumaa*  $N(0,1)$  :

$$z \sim_a N(0,1)$$

## Bernoulli-jakauman odotusarvon luottamusväli

# Luottamusvälin johto 3/5

---

- Määrätään normaalijakaumasta  $N(0,1)$  piste  $+z_{\alpha/2}$  siten, että

$$\Pr(z \geq +z_{\alpha/2}) = \frac{\alpha}{2}$$

jolloin (normaalijakauman symmetrian perusteella)

$$\Pr(z \leq -z_{\alpha/2}) = \frac{\alpha}{2}$$

ja edelleen

$$\Pr(-z_{\alpha/2} \leq z \leq +z_{\alpha/2}) = 1 - \alpha$$

# Bernoulli-jakauman odotusarvon luottamusväli

## Luottamusvälin johto 4/5

---

- Tarkastellaan epäyhtälöketjua

$$-z_{\alpha/2} \leq z \leq +z_{\alpha/2}$$

- Sijoittamalla tähän epäyhtälöketjuun satunnaismuuttujan  $z$  lauseke, saadaan epäyhtälöketju

$$-z_{\alpha/2} \leq \frac{\hat{p} - p}{\sqrt{\hat{p}(1 - \hat{p})/n}} \leq +z_{\alpha/2}$$

- Tästä epäyhtälöketjusta saadaan sen kanssa *yhtäpitävä* epäyhtälöketju

$$\hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}} \leq p \leq \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$

# Bernoulli-jakauman odotusarvon luottamusväli

## Luottamusvälin johto 5/5

---

- Yhdistämällä saatu epäyhtälö siihen, että

$$\Pr(-z_{\alpha/2} \leq z \leq +z_{\alpha/2}) =_{a} 1 - \alpha$$

saadaan vihdoin

$$\Pr\left(\hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \leq p \leq \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}\right) =_{a} 1 - \alpha$$

Siten konstruoitu luottamusväli *peittää* parametrin  $p$  todellisen arvon approksimatiivisesti todennäköisyydellä  $(1 - \alpha)$  ja se *ei peitä* parametrin  $p$  todellista arvoa approksimatiivisesti todennäköisyydellä  $\alpha$ .

## Bernoulli-jakauman odotusarvon luottamusväli

# Luottamusvälin ominaisuudet 1/2

---

- Bernoulli-jakauman parametrin  $p$  luottamusvälin *keskipiste*  $\hat{p}$  vaihtelee otoksesta toiseen.
- Luottamusvälin *pituus*

$$2 \times z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$

vaihtelee otoksesta toiseen.

- Luottamusvälin *pituus* riippuu valitusta luottamustasosta  $(1 - \alpha)$ , havaintojen lukumäärästä  $n$  ja estimaattorista  $\hat{p}$ .

## Bernoulli-jakauman odotusarvon luottamusväli

# Luottamusvälin ominaisuudet 2/2

---

- Luottamusväli *lyhenee* (*pitenee*), jos *luottamustasoa*  $(1 - \alpha)$  *pienennetään* (*kasvatetaan*).
- Luottamusväli *lyhenee*, jos *otoskokoa*  $n$  *kasvatetaan*.
- Luottamusväli on *lyhyimmillään*, kun
$$\hat{p} \approx 0 \text{ tai } \hat{p} \approx 1$$
- Luottamusväli on *pisimmillään*, kun

$$\hat{p} = \frac{1}{2}$$



## Bernoulli-jakauman odotusarvon luottamusväli

# Vaatimukset luottamusvälille

---

- Olisi toivottavaa pystyä konstruoimaan parametrille  $p$  mahdollisimman *lyhyt* luottamusväli, johon liittyvä luottamustaso olisi samanaikaisesti mahdollisimman *korkea*.
- Vaatimusten samanaikainen täyttäminen *ei ole* kuitenkaan mahdollista, *jos otoskoko pidetään kiinteänä*:
  - (i) *Luottamustason kasvattaminen pidentää luottamusväliä*, jolloin tieto parametrin  $p$  todellisen arvon sijainnista tulee *epätarkemmaksi*.
  - (ii) *Luottamusvälin lyhentäminen pienentää luottamustasoa*, jolloin tieto parametrin  $p$  todellisen arvon sijainnista tulee *epävarmemmaksi*.

## Bernoulli-jakauman odotusarvon luottamusväli

# Otoskoon määrääminen $1/4$

---

- Monissa tutkimustilanteissa toivotaan, että parametrille voitaisiin muodostaa *mahdollisimman lyhyt* luottamusväli.
- Bernoulli-jakauman odotusarvoparametrin  $p$  luottamusvälin pituus riippuu otoskoosta siten, että *väli lyhenee, jos havaintojen lukumäärää  $n$  kasvatetaan*.
- Tämä odotusarvoparametrin  $p$  luottamusvälin ominaisuus mahdollistaa tietyin ehdoin otoskoon valinnan niin, että *luottamusvälistä tulee* (suurin piirtein) *toivotun mittainen*.
- Oletetaan siis, että Bernoulli-jakauman odotusarvoparametrille  $p$  halutaan konstruoida luottamusväli, jonka *toivottu pituus* on

2A

## Bernoulli-jakauman odotusarvon luottamusväli

### Otoskoon määrääminen 2/4

---

- *Bernoulli-jakauma odotusarvoparametrin  $p$  luottamusväli luottamustasolla  $(1 - \alpha)$  on muotoa*

$$\hat{p} \pm z_{\alpha/2} \sqrt{\frac{\hat{p}(1 - \hat{p})}{n}}$$

jossa

$\hat{p}$  = parametrin  $p$  *harhaton estimaattori*

$n$  = havaintojen *lukumäärä*

$-z_{\alpha/2}$  ,  $+z_{\alpha/2}$

= luottamustasoon  $(1 - \alpha)$  liittyvät *luottamuskertoimet normaalijakaumasta  $N(0,1)$*

## Bernoulli-jakauman odotusarvon luottamusväli

# Otoskoon määrääminen 3/4

---

- Voidaan otoskoko  $n$  ratkaista yhtälöstä:

$$z_{\alpha/2} \sqrt{\frac{p(1-p)}{n}} = A$$

jossa

$z_{\alpha/2}$  = luottamustasoon  $(1 - \alpha)$  liittyvä *luottamuskerroin normaalijakaumasta*  $N(0,1)$

$p$  = odotusarvon *oletettu arvo*

$n$  = *otoskoko*

$2A$  = *toivottu pituus* luottamusvälille

## Bernoulli-jakauman odotusarvon luottamusväli

# Otoskoon määrääminen 4/4

---

- Siten *tarvittava otoskoko* on

$$n = \left( \frac{z_{\alpha/2} \sqrt{p(1-p)}}{A} \right)^2$$

- Huomaa, että tarvittava otoskoko *saavuttaa maksiminsa*

$$n = \left( \frac{z_{\alpha/2}}{2A} \right)^2$$

kun  $p = 1/2$

- **Huomautus:**

Tarvittavan otoskoon kaavasta nähdään, että mitä lyhyempää luottamusväliä toivotaan, sitä suurempi otos on poimittava:

Jos esimerkiksi luottamusvälin pituus halutaan puolittaa, pitää havaintoja kerätä 4 kertaa enemmän.