
Johdatus tilastotieteeseen
Estimointi

Estimointi

Todennäköisyysjakaumien parametrit ja niiden estimointi
Hyvän estimaattorin ominaisuudet

Estimointi:

Mitä opimme? – 1/4

- **Tilastollisen tutkimuksen** tavoitteena on tehdä *johtopäätöksiä prosesseista, jotka generoivat reaalimaailman ilmiöitä koskevia havaintoja.*
- Tavoitteeseen pyritään rakentamalla **tilastollinen malli** sille prosessille, joka on generoinut tutkimuksen kohteena olevaa ilmiötä koskevat havainnot.
- Koska tilastollisissa tutkimusasetelmissä havaintoihin liittyy aina **satunnaisuutta** tai **epävarmuutta**, tilastolliset mallit ovat luonteeltaan **todennäköisyysmalleja**.
- Tilastollinen malli on täysin määrätty, *jos havaintojen todennäköisyysjakauma tunnetaan.*

Estimointi:

Mitä opimme? – 2/4

- *Havaintojen todennäköisyysjakauman määräävät jakauman karakteristisia ominaisuuksia kuvaavat **parametrit**, joiden arvoja ei sovellustilanteessa yleensä tunneta.*
- Jos jakauman tuntemattomille parametreille ei löydetä hyviä **estimaatteja** eli *arvioita*, jakaumaa ei voida käyttää mallina sille prosessille, joka on generoinut tutkimuksen kohteena olevaa ilmiötä koskevat havainnot.
- Tilastollisen tutkimuksen tärkeimpiä osatehtäviä on **estimoida** eli *arvioida havainnot generoineen prosessin mallina käytettävän todennäköisyysjakauman tuntemattomat parametrit ilmiötä koskevien havaintojen perusteella.*

Estimointi:

Mitä opimme? – 3/4

- *Havaintojen funktiota*, joka tuottaa **estimaatteja** eli *arvioita* todennäköisyysjakauman tuntemattoman parametrin todelliselle arvolle, kutsutaan parametrin **estimaattoriksi**.
- Tilastotieteen tärkeimpiä osatehtäviä on hyvien estimaattoreiden *johtaminen* todennäköisyysjakauman parametreille.
Ks. lukua **Estimointimenetelmät**.
- Koska todennäköisyysjakauman parametreille voidaan muodostaa erilaisia estimaattoreita, estimaattoreille on esitetty erilaisia **hyvyyskriteereitä**, joita käytetään apuna estimaattorin valinnassa.
- *Vaatimukset hyvälle estimaattorille:*
Hyvän estimaattorin on oltava **harhaton, tehokas, tyhjentävä ja tarkentuva**.

Estimointi:

Mitä opimme? – 4/4

- Todennäköisyysjakauman tuntemattomien parametrien *arvojen määräämistä* kutsutaan tavallisesti **piste-estimoinniksi**.
- Todennäköisyysjakauman parametrin estimaattiin on aina syytä liittää **luottamusväliksi** kutsuttu väli, *joka sisältää parametrin todellisen arvon, tietyllä, soveltajan valittavissa olevalla todennäköisyydellä*.
Ks. lukua **Väliestimointi**.

Estimointi: Esitiedot

- Esitiedot: ks. seuraavia lukuja:
 - Tilastollisten aineistojen kerääminen ja mittaaminen**
 - Tilastollisten aineistojen kuvaaminen**
 - Otos ja otosjakaumat**
- Tarvitset esitietoja myös seuraavista kalvokokoelman **Johdatus todennäköisyyslaskentaan** luvuista:
 - Satunnaismuuttujat ja todennäköisyysjakaumat**
 - Jakaumien tunnusluvut**

Estimointi: Lisätiedot

- Todennäköisyysjakaumien *parametrien estimaattoreiden johtamis-*
periaatteita käsitellään luvussa

Estimointimenetelmät

- *Luottamusvälien määrittämisestä* todennäköisyysjakaumien
parametreille käsitellään luvussa

Väliestimointi

- Todennäköisyysjakaumien *parametreja koskevien tilastollisten*
hypoteesien testaamista käsitellään luvussa

Tilastolliset testit

Testit suhdeasteikollisille muuttujille

- *Jakaumaoletuksien testaamista* käsitellään luvussa

Yhteensopivuuden, homogeenisuuden ja riippumattomuuden testaaminen

Estimointi

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

Todennäköisyysjakaumien parametrit ja niiden estimointi

Avainsanat

Estimaatti

Estimaattori

Estimointi

Havainto

Havaintoarvo

Otosjakauma

Parametri

Piste-estimointi

Tilastollinen aineisto

Tilastollinen malli

Todennäköisyysjakauma

Yksinkertainen satunnaisotos

Luottamusväli

Todennäköisyysjakaumat tilastollisten aineistojen kuvaajina

- **Tilastollinen aineisto** koostuu tutkimuksen kohteita kuvaavien muuttujien *havaituista arvoista*.
- Tilastollisissa tutkimusasetelmissä havaintoarvoihin liittyy aina *epävarmuutta* ja *satunnaisuutta*.
- Tilastollisissa tutkimusasetelmissä tutkimuksen kohteita kuvaavat muuttujat tulkitaan *satunnaismuuttujiksi*, jotka *generoivat* muuttujien havaitut arvot.
- **Tilastollisella mallilla** tarkoitetaan *havaintoarvot generoineiden satunnaismuuttujien todennäköisyysjakaumaa*.

Todennäköisyysjakaumien parametrit 1/2

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

$$f(x ; \theta)$$

riippuu **parametrasta** θ .

- Merkintä:

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

Todennäköisyysjakaumien parametrit 2/2

- Satunnaismuuttujan X pistetodennäköisyys- tai tiheysfunktio

$$f(x ; \theta)$$

kuvaa satunnaismuuttujan X *todennäköisyysjakaumaa* ja parametri θ kuvaa jotakin jakauman *karakteristista ominaisuutta*.

- Koska parametrin θ arvoa *ei yleensä tunneta*, tilastollisen tutkimuksen tärkeimpiä osatehtäviä on **estimoida** eli *arvioida* parametrin θ tuntematon 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 θ .

- 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 jakaumasta

$$f(x; \theta)$$

saatavin todennäköisyyksin.

Todennäköisyysjakaumien parametrit ja niiden estimointi

Estimaattorit ja estimaatit 1/2

- Oletetaan, että todennäköisyysjakauman $f(x; \theta)$ **parametrin θ 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 **θ estimaattoriksi** ja funktion g *havaintoarvoista*

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

laskettua arvoa

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

kutsutaan parametrin **θ estimaatiksi**.

Todennäköisyysjakaumien parametrit ja niiden estimointi

Estimaattorit ja estimaatit 2/2

- Olkoon

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

jakauman $f(x; \theta)$ parametrin θ *estimaattori*.

- Tällöin estimaattorin T havaintoarvoista

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

laskettu arvo eli *estimaatti*

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

on satunnaismuuttujan T arvon realisaatio otoksessa.

Estimaattorit ja estimaatit:

Kommentti

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

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.*

Todennäköisyysjakaumien parametrit ja niiden estimointi

Estimaattoreiden johtaminen

- *Hyvien estimaattoreiden johtaminen todennäköisyysjakaumien tuntemattomille parametreille on teoreettisen tilastotieteen keskeisiä ongelmia.*
 - Tärkeimmät estimaattoreiden johtamiseen käytettävät menetelmät:
 - **Suurimman uskottavuuden menetelmä**
 - **Momenttimenetelmä**
- Ks. lukua **Estimointimenetelmät**.

Todennäköisyysjakaumien parametrit ja niiden estimointi

Piste-estimointi ja väliestimointi

- Todennäköisyysjakauman *parametrin arvon estimointia* kutsutaan usein **piste-estimoinniksi**.
- Parametrin estimaattiin on aina syytä liittää **luottamusväliksi** kutsuttu *väli, joka sisältää estimoidun parametrin todellisen, mutta tuntemattoman arvon tietyllä, soveltajan valittavissa olevalla todennäköisyydellä*.
- Luottamusvälin määräämistä kutsutaan **väliestimoinniksi**.
Ks. lukua Väliestimointi.

Estimointi

Todennäköisyysjakaumien parametrit ja niiden estimointi

>> Hyvän estimaattorin ominaisuudet

Hyvän estimaattorin ominaisuudet

Avainsanat

Estimaattori
Harha
Harhattomuus
Hyvyyskriteeri
Keskineliövirhe
Parametri
Tarkentuvuus
Tehokkuus
Tyhjentävyys

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**
 - **Tyhjentävyys**
 - **Tehokkuus**
 - **Tarkentuvuus**

Harhattomuus ja tyhjentyvyys

- **Harhattomuus:**

Estimaattori T on parametrin θ *harhaton estimaattori*, jos sen odotusarvo yhtyy parametrin θ arvoon:

$$E(T) = \theta$$

- **Tyhjentyvyys:**

Estimaattori T on *tyhjentävä* parametrille θ , jos se *käyttää* parametrin arvon estimoimiseen *kaiken otoksessa olevan informaation*.

Tehokkuus ja tarkentuvuus

- **Tehokkuus:**

Estimaattori T on parametrin θ *tehokas estimaattori*, jos sen *varianssi on pienempi kuin minkä tahansa muun estimaattorin*.

- **Tarkentuvuus:**

Estimaattori T on parametrin θ *tarkentuva estimaattori*, jos se *konvergoi melkein varmasti kohti parametrin oikeata arvoa*, kun otoskoon n annetaan kasvaa rajatta:

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

Ks. lukua **Konvergenssikäsitteet ja raja-arvolauseet**.

Hyvän estimaattorin ominaisuudet

Estimaattorin harha

- Parametrin θ estimaattorin $\hat{\theta}$ **harha** on

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

- Jos $\hat{\theta}$ on parametrin θ *harhaton* estimaattori eli

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

niin

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

Hyvän estimaattorin ominaisuudet

Estimaattorin keskineliövirhe

- Parametrin θ 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 parametrin θ *harhaton* estimaattori 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*.