



HELSINGIN YLIOPISTO  
HELSINGFORS UNIVERSITET  
UNIVERSITY OF HELSINKI

# Otantamenetelmät (78143) Syksy 2010

## TEEMAT 3 & 4

Risto Lehtonen  
[risto.lehtonen@helsinki.fi](mailto:risto.lehtonen@helsinki.fi)



Teema 3

## ERITYISKYSYMYKSIÄ



## Otannan erityiskysymyksiä

### ■ Ryvästanta

- Survey sampling reference guidelines (2008 edition)  
Introduction to sample design and estimation techniques  
Section 3.2.5 Cluster sampling

### ■ Otoskoon määrääminen

- Survey sampling reference guidelines (2008 edition)  
Introduction to sample design and estimation techniques  
Section 3.3 Sample size determination

### ■ Vastauskadon hallinnan perusteita

- Lehtonen-Pahkinen (2004) Chapter 3
- [VLISS](#) Training Key 114, 117, 123



## Sisäkorrelaatio ryvästannassa

- Samaan rypääseen kuulumisella on taipumus samankaltaistaa alkioita tutkittavien ilmiöiden suhteeseen
- Koulututkimukset
  - Rypäänä opetusryhmä
  - Oppimistulokset, esim. [PISA](#)
- Työolotutkimukset
  - Rypäänä työpaikka
  - Työolot, esim. Kelan työterveyshuoltotutkimus
  - OHC data, [VLISS](#)



## Sisäkorrelaatio

Sisäkorrelaatio  $\hat{\rho}_{\text{int}}$  *Intra - cluster correlation*

Likimääräinen kaava  $\hat{\rho}_{\text{int}} = (\text{deff} - 1)/(\bar{m} - 1)$

missä  $\bar{m}$  on keskimääräinen ryväskoko

Rypäät ovat usein positiivisesti sisäkorreloituneita  
eli  $\hat{\rho}_{\text{int}} > 0$  kun  $\text{deff} > 1$

Lisäksi on voimassa:  $\text{deff}(\hat{p}) = 1 + (\bar{m} - 1)\hat{\rho}_{\text{int}}$

missä  $\text{deff}(\hat{p})$  on asetelmakerroin  
(*design effect*)

Risto Lehtonen

5



## Esimerkkiaineisto: Työterveyshuoltotutkimus OHC

### ■ Otanta-asetelma

- Ositettu yksi- ja kaksiasteinen ryvästötanta
- Toimipaikat rypänä
- Ositus rypään koon ja toimialan mukaan
  - Pienet toimipaikat: Yksiasteinen otanta
  - Suuret toimipaikat: Kaksiasteinen otanta

### ■ Henkilötasolla likimain itsepainottuva (*self-weighting*) otos

### ■ Demonstraatioaineisto SAS-data OHC

#### ■ Rajaus:

- Toimipaikat, joissa vähintään 10 työntekijää
- $H = 5$  osittetta (*strata*)
- $m = 250$  toimipaikkaa (ryvästä, *clusters*)
- $n = 7841$  henkilöä

#### ■ Vaihteleva määrä otosrypäitä per osite



## **Deff-estimaatit OHC (Lehtonen&Pahkinen 2004)**

**Table 5.8**

Averages of design-effect estimates of proportion estimates of selected groups of binary response variables in the OHC Survey data set (number of variables in parentheses).

Study variable	Mean deff
Physical working conditions (12)	6.5
Psycho-social working conditions (11)	3.3
Psychosomatic symptoms (8)	2.0
Psychic symptoms (9)	1.8



Teema 4

## **OHJELMISTO**



## Ohjelmisto

- SAS-ohjelmisto
  - SAS-proseduurit
  - SAS-makrot
- SPSS module Complex Samples
- Stata:n svy-ohjelmat
- Erikoisalue: Pienalue-estimointi
  - SAS-makro EBLUPGREG
  - Ohjelma Domest
  - R-kieliset ohjelmat
- [Software](#)

Risto Lehtonen

9



## SAS-ohjelmisto, kuvailu

- Survey-proseduurit, joilla otanta-asetelma (ositus, ryvästyminen, painotus) voidaan ottaa huomioon estimoinnissa
- SURVEYMEANS
  - Keskiarvot ja kokonaismääärät
- SURVEYREG
  - Regressioestimointi
- SURVEYFREQ
  - Ristiintaulukointi ja perustestit

Risto Lehtonen

10



## SAS-ohjelmisto, analyysi

- SURVEYFREQ
  - Monipuolinen valikoima tilastollisia testejä
- SURVEYREG
  - Lineaariset mallit
- SURVEYLOGISTIC
  - Logistiset mallit

Risto Lehtonen

11



## SAS-proseduuri SURVEYMEANS

- Asetelmaperusteinen estimointi
- Kokonaismäärien, keskiarvojen ja osuuksien estimointi koko aineistossa ja osajoukoissa
- Osajoukkoestimointi (domains)
  - BY statement
  - Ositekohtainen estimointi (*planned domains*)
  - DOMAIN statement
  - Estimointi muuntyyppisille osajoukoille (*unplanned domains*)

Risto Lehtonen

12



## SAS-makrot, pienalue-estimointi

- EURAREA Project

<http://www.statistics.gov.uk/eurarea/>

- Asetelmaperusteinen estimointi

- GREG with linear fixed-effects models

- Malliperusteinen estimointi

- Standard estimators (EBLUP)
  - Estimators with spatial or temporal effects
  - Estimators for cross-classifications

- Proper MSE estimation

Risto Lehtonen

13



## EURAREA Project

- [The EURAREA "Standard" Estimators and performance criteria\\*](#)  
[Office for National Statistics, UK](#)

- [Area-level Composite Estimator with Time-Varying Area Effect\\*](#)  
[Office for National Statistics, UK](#)

- [\*\*EBLUPGREG: Unit-level Composite Estimator with Spatial or Temporal Effects\\*\*\*](#)  
[Statistics Finland](#)

- [Unit-level Composite Estimator with Spatial Effects\\*](#)  
[ISTAT, Italy](#)

- [Small Area Estimation with Sampling Weights\\*](#)  
[INE, Spain / UMH, Spain](#)

- [Cross Classifications with Two-way and Three-way tables\\*](#)  
[ISTAT, Italy](#)

Risto Lehtonen

14



## Estimation for domains and SAE

### ■ *Domain estimation*

- The estimation of population quantities for the desired population subgroups called domains (large or small)
  - Totals , Means, Proportions
  - Medians, Quantiles, Percentiles
  - More complex indicators...

### ■ *Small area estimation, SAE*

- Estimation for domains whose **sample size** is small or very small (even zero)


Risto Lehtonen

15



## Domain estimation design

- Types of domains of interest
  - Planned domains / Unplanned domains
- Type of domain estimator
  - Direct / Indirect
  - Design-based / Model-based
- Availability of auxiliary (population) data
  - Unit-level / Aggregated (area-level)
- Type of model
  - Linear / Non-linear
  - Fixed-effects model / Mixed model
  - Generalized linear mixed models (GLMM)
- Accuracy measures
  - Variance estimators / MSE estimators



## Domain type and estimator type

Domain type	Estimator type	
	Direct	Indirect
Planned	Typical set-up	More rarely
Unplanned	More rarely	Typical set-up

Risto Lehtonen 18

## Ohjelma DOMEST

- Stand-alone Java program for estimation of totals and means for domains and small areas developed by Dr. Ari Veijanen and Prof. Risto Lehtonen
- Design-based estimators
  - HT and Hájek estimator
  - GREG with linear model
  - GREG with linear mixed model
- Model-based estimators
  - EBLUP (Empirical best linear unbiased predictor) with linear mixed model

Risto Lehtonen

19

The screenshot shows the 'Domain Estimation' window of the DOMEST software. On the left, there's a sidebar with 'Select Model' (Linear Mixed Model selected), 'Select Estimator' (EBLUP(p)), and 'Select Statistics' (Domain totals, Variance and MSE selected). The main area displays 'Estimated Domain Totals of y in p'. A table provides details for 10 domains:

domain	Population Size	Sample Size	EBLUP(p)	MSE of EBLUP(p)	$\sqrt{g_1}$	$\sqrt{g_2}$
1	69	1	1299.648	23.627	22.487	10.481
2	125	1	2620.545	31.247	56.206	17.709
3	94	14	1884.812	40.133	27.157	9.909
4	95	5	1896.048	41.756	30.181	13.521
5	95	1	2119.218	21.178	17.280	7.848
6	204	19	4691.358	77.450	54.277	20.226
7	46	11	840.922	23.327	14.998	7.403
8	47	6	1047.055	24.152	16.076	7.169
9	49	1	2121.238	23.223	17.273	7.775
10	174	14	3631.264	71.784	50.286	17.764

Risto Lehtonen

20



## R-kieliset ohjelmat

- R-kielisiä ohjelmia on tekeillä eri EU-projekteissa (FP7)
  - SAMPLE project (EU FP7)
  - [AMELI](#) project (EU FP7)
- Demoissa käytetään SAS-ohjelmiston proseduureja
  - SURVEYSELECT
  - SURVEYMEANS
  - SURVEYREG

Risto Lehtonen

21



## Kuinka jatkaa eteenpäin?

- [Yhteiskuntatilastotiede](#), kevät 2011
  - [Pienalue-estimointi](#)
  - [Tilastolliset tietosuojamenetelmät](#)
  - [Imputointimenetelmät](#)
- Pro gradu yhteiskuntatilastotieteen alalta
  - Tilastokeskus
  - Kelan tutkimusosasto
  - Muu valtionhallinnon tutkimuslaitos tai virasto