


## Section 2

Uke 41-2

# Populasjon, utvalg og observator I

- Populasjon: består av alle enheter man er interessert i (vi ofte antar at vi vet fordeling)
  - normalpopulasjon
  - poissonpopulasjon
  - $f(x)$ -populasjon
- Utvalg: delmengde av en populasjon



- **Tilfeldig utvalg:**  $X_1, X_2, \dots, X_n$  er uavhengige og identisk fordelte
  - $E(X_i) = \mu$  og  $\text{Var}(X_i) = \sigma^2$  for  $i = 1, \dots, n$
- **Observator:** observerbar funksjon av SV (som er et tilfeldig utvalg)
  - Utvalgs Gjennomsnitt,  $\bar{X} = \frac{1}{n} \sum_i^n X_i$
  - Utvalgs Varians,  $S^2 = \frac{1}{n-1} \sum_i^n (X_i - \bar{X})^2$
- **Utvalgsfordeling:** sannsynlighetsfordelingen til en observator
  - fordeling for  $\bar{X}$ :
    - $E(\bar{X}) = \mu$  og  $\text{Var}(\bar{X}) = \sigma^2/n$  alltid
    - Hvis  $X_i \sim N(\mu, \sigma^2) \Rightarrow \bar{X} \sim N(\mu, \sigma^2/n)$

La  $X_1, X_2, \dots, X_n$  være uavhengige og normal fordelt SV. Anta at

$$\mathbf{E}(X_1) = \mu_1, \dots, \mathbf{E}(X_n) = \mu_n$$

$$\mathbf{Var}(X_1) = \sigma_1^2, \dots, \mathbf{Var}(X_n) = \sigma_n^2$$

La  $Y = a_1X_1 + a_2X_2 + \dots + a_nX_n + b$  da er  $Y \sim N(\mu_Y, \sigma_Y^2)$  med

$$\mu_Y = a_1\mu_1 + a_2\mu_2 + \dots + a_n\mu_n + b$$

$$\sigma_Y^2 = a_1^2\sigma_1^2 + a_2^2\sigma_2^2 + \dots + a_n^2\sigma_n^2$$


# Populasjon, utvalg og observator II

- **Tilfeldig utvalg:**  $X_1, X_2, \dots, X_n$  er uavhengige og identisk fordelte
  - $E(X_i) = \mu$  og  $\text{Var}(X_i) = \sigma^2$  for  $i = 1, \dots, n$
- **Observator:** observerbar funksjon av SV (som er et tilfeldig utvalg)
  - Utvalgs Gjennomsnitt,  $\bar{X} = \frac{1}{n} \sum_i^n X_i$
  - Utvalgs Varians,  $S^2 = \frac{1}{n-1} \sum_i^n (X_i - \bar{X})^2$
- **Utvalgsfordeling:** sannsynlighetsfordelingen til en observator
  - fordeling for  $\bar{X}$ :
    - $E(\bar{X}) = \mu$  og  $\text{Var}(\bar{X}) = \sigma^2/n$  alltid
    - Hvis  $X_i \sim N(\mu, \sigma^2) \Rightarrow \bar{X} \sim N(\mu, \sigma^2/n)$
    - Er datane normalfordelt?


# Er datane normal fordelt?

Plott for å vurdere om observerte verdier  $x_1, x_2, \dots, x_n$  synes å komme fra en normalpopulasjon


## Histogram



## Kumulativ Fordeling



## Normal QQ Plot



- **Tilfeldig utvalg:**  $X_1, X_2, \dots, X_n$  er uavhengige og identisk fordelte
  - $E(X_i) = \mu$  og  $\text{Var}(X_i) = \sigma^2$  for  $i = 1, \dots, n$
- **Observator:** observerbar funksjon av SV (som er et tilfeldig utvalg)
  - Utvalgs Gjennomsnitt,  $\bar{X} = \frac{1}{n} \sum_i^n X_i$
  - Utvalgs Varians,  $S^2 = \frac{1}{n-1} \sum_i^n (X_i - \bar{X})^2$
- **Utvalgsfordeling:** sannsynlighetsfordelingen til en observator
  - fordeling for  $\bar{X}$ :
    - $E(\bar{X}) = \mu$  og  $\text{Var}(\bar{X}) = \sigma^2/n$  alltid
    - Hvis  $X_i \sim N(\mu, \sigma^2) \Rightarrow \bar{X} \sim N(\mu, \sigma^2/n)$
    - Er datane normalfordelt?
    - Hva hvis de IKKE er normalfordelt?

# Sentralgrense teorem

La  $X_1, X_2, \dots, X_n$  være tilfeldig utvalg fra fordeling med  $E(X_i) = \mu$  og  $Var[X_i] = \sigma^2$ . Da vil fordelingen til

$$Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}}$$

konvergere mot en standard normal fordeling når  $n \rightarrow \infty$ .

- Når  $n$  er stor har vi dermed at

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{(n)}} \approx N(0, 1)$$



# Sentralgrense teorem

La  $X_1, X_2, \dots, X_n$  være tilfeldig utvalg fra fordeling med  $E(X_i) = \mu$  og  $Var[X_i] = \sigma^2$ . Da vil fordelingen til

$$Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}}$$

konvergere mot en standard normal fordeling når  $n \rightarrow \infty$ .

- Når  $n$  er stor har vi dermed at

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{(n)}} \approx N(0, 1)$$

- Det betyr at (når  $n$  er stor)

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

- unntatt for svært skjeve fordelinger har man en god approksimasjon når  $n \geq 30$

$X_1, X_2, \dots, X_n$  u.i.f. fra  $f(x)$  med  $E(X_i) = \mu$  og  $\text{Var}(X_i) = \sigma^2$ .

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

- Hvis  $f(x) = N(\mu, \sigma^2) \Rightarrow \bar{X} \sim N(\mu, \sigma^2/n)$
- Hvis  $f(x)$  ikke er  $N(\mu, \sigma^2) \Rightarrow \bar{X} \xrightarrow[n \rightarrow \infty]{} N(\mu, \sigma^2/n)$

- Hva er gjennomsnitt antall blogemer i australske idrettsutøvere? (estimering)
- Har jeg lavere antall blogemer enn gjennomsnittlig australske idrettsutøvere? (hypothsetest)
- Hva er forskjell i høyde mellom menn og kvinner australske idrettsutøvere? (estimering)
- Er menn australske idrettsutøvere høyere enn kvinnelig australske idrettsutøvere? (hypothsetest)

- **Situasjon**

- $X_1, X_2, \dots, X_9$  er et tilfeldig utvalg fra  $N(\mu, \sigma^2)$ -populasjon -verdien til  $\mu$  er ukjent -skal estimere (anslå) verdien til  $\mu$  -vil sammenligne
  - Gjennomsnitt  $\bar{x} = \frac{1}{n} \sum X_i$
  - Median  $\tilde{X}$
- Generere 9 observasjoner  $X_i \sim N(2.4, 0.1)$
- Regne  $\bar{x}$  og  $\tilde{x}$

- Hva er en estimator?
- Hva mener vi med “god” estimator?
- Hvordan finner vi en estimator?

- Hva er en estimator?
  - Anta at vi har et tilfeldig utvalg  $X_1, X_2, \dots, X_n$  fra  $f(x; \theta)$ -populasjonen, der verdien til parameteren  $\theta$  er ukjent. En estimator for  $\theta$  er da en observator som benyttes til å anslå verdien til  $\theta$ .
  - En estimator er en stokastisk variabel med sin egen fordeling
- Hva mener vi med “god” estimator?
- Hvordan finner vi en estimator?

- Hva er en estimator?
- Vi har to estimatorer  $\hat{\theta}_1$  og  $\hat{\theta}_2$  hvilken er best?
  - Ide: tenker oss at vi kan gjenta forsøket (uendelig) mange ganger. Vi foretrekker den estimator som vanligvis treffer nærmest den sanne verdi  $\theta$ 
    - Vi vet ikke verdi til  $\theta$
    - Vi vanligvis gjør forsøket bare en gang!
- Hvordan finner vi en estimator?

- Hva er en estimator?
- Vi har to estimatorer  $\hat{\theta}_1$  og  $\hat{\theta}_2$  hvilken er best?
  - Ide: tenker oss at vi kan gjenta forsøket (uendelig) mange ganger. Vi foretrekker den estimator som vanligvis treffer nærmest den sanne verdi  $\theta$ 
    - Vi vet ikke verdi til  $\theta$
    - Vi vanligvis gjør forsøket bare en gang!
  - Def: En observator  $\hat{\theta}$  er en forventingsrett (unbiased) estimator for  $\theta$  hvis  $E[\hat{\theta}] = \theta$ . Hvis ikke sier vi at  $\hat{\theta}$  er forventingsskjev (biased)
  - Def: Av flere forventingsrette estimatorene sier vi at den med minst varians er mest effisient
- Hvordan finner vi en estimator?



- Hva er en estimator?
- Vi har to estimatorer  $\hat{\theta}_1$  og  $\hat{\theta}_2$  hvilken er best?
- Hvordan finner vi en estimator?
  - Bruke vår intuisjon (some vi har gjort til nå)
  - Bruke matematiske metoder (neste gang)