

**Prosjekt:** Korrelasjon mellom genotyper i to lokus

**Veileder:** Øyvind Bakke

**Bakgrunn:** I GWA-studier (genomwide association studies) er det av interesse å undersøke om det er sammenheng mellom en bestemt sykdom og genotype. Genotypen i  $m$  (mange hundre tusen) lokus, som hvert består av ett basepar på et kromosom, kartlegges, både hos friske individer og hos individer med den aktuelle sykdommen. Genotypen kodes som 0, 1 eller 2, som svarer til genotyper hhv.  $aa$ ,  $aA$  og  $AA$  (to homozygoter og én heterozygot).

For å undersøke en slik sammenheng, er én mulighet å gjøre en hypotesetest for hvert lokus. Da må imidlertid signifikansnivået for hver enkelt test,  $\alpha_{\text{local}}$  settes kraftig ned for å holde sannsynligheten for minst én type I-feil begrenset til et valgt nivå (f.eks.  $\alpha = 0,05$ ). Det er mange måter å gjøre dette på. Den mest kjente er Bonferroni-korreksjon, der signifikansnivået for den enkelte testen reduseres til  $\alpha/m$ .

En annen metode er å estimere og utnytte korrelasjonsstrukturen mellom testobservatorene for hvert lokus. Ideelt burde man ha brukt hele simultanfordelingen, men man kan få en konservativ skranke for  $\alpha_{\text{local}}$  ved bare å bruke simultanfordelingene til to og to nabolokus.

**Problem:** Anta at to nabolokus, f.eks. nr.  $i$  og  $i + 1$  har simultan sannsynlighetsfordeling  $p_{jk}$  for genotype  $j$  på lokus  $i$  og genotype  $k$  på lokus  $i + 1$ , der  $j = 0, 1, 2$  og  $k = 0, 1, 2$ , og  $\sum_{jk} p_{jk} = 1$ . Definer marginalsannsynlighetene  $p_{j \cdot} = \sum_k p_{jk}$  og  $p_{\cdot k} = \sum_j p_{jk}$ .

For en av flere mulige testobservatorer,  $\text{CATT}_{1/2}$ , er den asymptotiske korrelasjonen under nullhypotesen mellom denne testobservatoren i lokus  $i$  og i lokus  $i + 1$

$$\rho_{i,i+1} = \frac{\frac{1}{4}(p_{11} - p_{1 \cdot} \cdot p_{\cdot 1}) + \frac{1}{2}(p_{12} - p_{1 \cdot} \cdot p_{\cdot 2}) + \frac{1}{2}(p_{21} - p_{2 \cdot} \cdot p_{\cdot 1}) + p_{22} - p_{2 \cdot} \cdot p_{\cdot 2}}{\sqrt{(\frac{1}{4}p_{1 \cdot} + p_{2 \cdot} - (\frac{1}{2}p_{1 \cdot} + p_{2 \cdot})^2)(\frac{1}{4}p_{\cdot 1} + p_{\cdot 2} - (\frac{1}{2}p_{\cdot 1} + p_{\cdot 2})^2)}}.$$

For å undersøke hvor godt korreksjonsmetoden for multippel testing fungerer, er det av interesse å kunne simulere genotyper slik at korrelasjonen  $\rho_{i,i+1}$  mellom to nabolokus får en ønsket verdi.

1. Hvordan kan  $p_{jk}$ -ene velges for å få en gitt  $\rho_{i,i+1}$ ,  $-1 \leq \rho_{i,i+1} \leq 1$ ?

La oss døpe om  $p_{jk}$  til  $p_{jk}(i, i + 1)$ , og vi definerer tilsvarende simultanfordelingen  $p_{jk}(i + 1, i + 2)$  for genotypene i lokus  $i + 1$  og  $i + 2$  osv. Merk at marginalfordelingen for lokus  $i + 1$  må være den samme om vi betrakter simultanfordelingen til  $i$  og  $i + 1$  eller simultanfordelingen til  $i + 1$  og  $i + 2$ , osv.

2. Hvis vi har flere nabolokus,  $i$ ,  $i + 1$ ,  $i + 2$  osv. – er det da mulig å velge simultanfordelingene for to og to nabolokus slik at  $\rho_{i,i+1}$ ,  $\rho_{i+1,i+2}$  får ønskede verdier? Hvilke begrensninger fins det eventuelt?

**Forkunnskaper:** Grunnkurs i statistikk (ST1101/TMA4240/TMA4245). I tillegg er det en fordel med noe programmeringserfaring i MATLAB, R eller annet.

**Opplæring:** Veileder vil gi mer utfyllende informasjon.