

**Tentamen Regressie en Variantie-Analyse (191530440)**  
**Woensdag 2 juli 2014 van 13:45 tot 16:45 uur**

*Dit tentamen bestaat uit 6 vragen. Een rekenmachine is NIET toegestaan.*

Als er gevraagd wordt naar een toets, geef dan aan (voor zover nog niet gegeven) :

- (1) De modelveronderstellingen (het "statistisch model"),
- (2) De formulering van de nulhypothese en alternatieve hypothese,
- (3) De formule voor de toetsingsgrootte, indien er meerdere formules mogelijk zijn kies dan voor de formule die rekentechnisch het eenvoudigst is.
- (4) De verdeling van de toetsingsgrootte onder de nulhypothese,
- (5) Geef aan voor welke waarden van de toetsingsgrootte de nulhypothese verworpen moet worden. (Als  $T$  de toetsingsgrootte is, verwerp je dan de nulhypothese voor  $T \geq c$  ? Of voor  $T \leq -c$  ? Of voor zowel  $T \geq c$  als  $T \leq -c$  ?)

**Vraag 1**

Beschouw het model van multiple regressie met  $k$  verklarende variabelen en een constante  $\beta_0$ , waarbij we uitgaan van onafhankelijke en normaal verdeelde storingen met verwachting 0 en gelijke variantie  $\sigma^2$ . We bestuderen de residuen  $Y_i - \hat{Y}_i$ .

- a. Toon aan:  $E(Y_i - \hat{Y}_i) = 0$
- b. De residuen zijn voor grote waarden van de steekproefgrootte  $n$  bij benadering normaal verdeeld met verwachting 0 en variantie  $\sigma^2$ . De variantie  $var(Y_i - \hat{Y}_i)$  is niet exact gelijk aan  $\sigma^2$ . Motiveer met formules welke van de volgende twee beweringen waar is:
  - (1) de varianties  $var(Y_i - \hat{Y}_i)$  zijn alle (iets) groter dan  $\sigma^2$ ,
  - (2) de varianties  $var(Y_i - \hat{Y}_i)$  zijn alle (iets) kleiner dan  $\sigma^2$ .
- c. Toon aan dat de som van de residuen  $Y_i - \hat{Y}_i$  altijd exact gelijk is aan 0.

**Vraag 2**

Beschouw het model van multiple regressie met  $k$  verklarende variabelen en een constante  $\beta_0$ . We beschouwen nu het geval dat de storingen  $\varepsilon_i$  verdeeld zijn volgens een AR(1)-model.

- a. Geef aan wat het AR(1)-model inhoudt (geef alle modelveronderstellingen).
- b. Laat zien dat  $var(\varepsilon) = \sigma^2 \Omega$  geldt met  $\Omega$  een matrix die alleen van een correlatiecoëfficiënt  $\rho$  afhangt.
- c. Geef de formule voor de 'estimated generalized least squares estimator' van de vector  $\beta$ .

**Vraag 3**

We beschouwen variantie-analyse met 2 factoren zonder interactie.

- a. Geef aan hoe we het model van de variantie-analyse met 2 factoren zonder interactie in de vorm " $Y = X\beta + \varepsilon$ " kunnen schrijven.
- b. Pas algemene toetsingstheorie van regressiemodellen toe om te toetsen of de tweede factor eigenlijk wel in het model thuishoort. Volg het schema van 5 punten vermeld aan het begin van dit tentamen.

(Bij het beantwoorden van deze vraag worden voor kansverdelingen en formules van toetsingsgrootheden **geen** bewijzen verwacht.)

**Z.O.Z.**

#### Vraag 4

Beschouw het algemene regressiemodel met normale verdelingen:  $Y \sim N(X\beta, \sigma^2 I_n)$ , met  $X$  een  $n \times (k+1)$  matrix van rang  $k+1$  ( $k+1 < n$ ). Toon aan dat de gebruikelijke schatter  $S^2$  van  $\sigma^2$  als volgt verdeeld is:

$\frac{(n-k-1)S^2}{\sigma^2}$  heeft de  $\chi_{n-k-1}^2$ -verdeling.

#### Vraag 5

De concentratie van een stof  $A$  wordt op tijdstippen  $t_1 = -3, t_2 = -2, t_3 = -1, t_4 = 0, t_5 = 1, t_6 = 2$  en  $t_7 = 3$  gemeten. Men wil bestuderen hoe de verwachting van de meting verandert als functie van de tijd. Voor de metingen  $Y_1, Y_2, \dots, Y_7$  geldt de volgende modelvergelijking:

$$Y_i = \beta_0 + \beta_1 t_i + \beta_2 (t_i^2 - 4) + \varepsilon_i$$

met onafhankelijke storingen  $\varepsilon_i$  die verdeeld zijn volgens  $N(0, \sigma^2)$ .

- Leid formules af voor de (kleinste kwadraten) schatters  $\hat{\beta}_0, \hat{\beta}_1$  en  $\hat{\beta}_2$ , vereenvoudig de formules als functie van de waarnemingen  $Y_i$  zo veel mogelijk.
- Bepaal  $se(\hat{\beta}_1)$ , de geschatte standaardafwijking van  $\hat{\beta}_1$ , als functie van  $S$ . (De gebruikelijke schatter  $S$  van  $\sigma$  hoef je niet te herschrijven in termen van deze opgave.)
- Geef aan hoe we een 95%-betrouwbaarheidsinterval voor  $\beta_1$  kunnen construeren.

#### Vraag 6

In een fabriek wordt geëxperimenteerd om de (verwachte) productie zo veel als mogelijk te verhogen. In een deelexperiment worden twee factoren  $A$  en  $B$  onderscheiden, met elk twee niveaus. Metingen van de productie  $Y_{ijk}$  worden gepland volgens volgend schema

Factor A	Factor B	
	1	2
1	$Y_{111}$ en $Y_{112}$	$Y_{121}$ en $Y_{122}$
2	$Y_{211}$ en $Y_{212}$	$Y_{221}$ en $Y_{222}$

We gaan uit van variantie-analyse met 2 factoren met interactie, waarbij we uitgaan van de volgende restricties op de parameters:  $\alpha_1 = \beta_1 = \gamma_{11} = \gamma_{12} = \gamma_{21} = 0$ .

- Geef aan hoe we in dit geval het model in de vorm " $Y = X\beta + \varepsilon$ " kunnen schrijven.
- Geef een algemene formule voor de schatter van  $\sigma^2$  (variantie van de storingen) en geef aan wat de verdeling is in de context van deze opgave.
- Geef (in algemene termen) aan hoe we  $H_0: \beta_2 = \gamma_{22} = 0$  tegen  $H_1: \beta_2 \neq 0 \vee \gamma_{22} \neq 0$  kunnen toetsen. Volg het schema van 5 punten vermeld aan het begin van dit tentamen.

#### Normering:

De vragen 1 t/m 6 worden beoordeeld met een "rapportcijfer" (cijfer tussen 1 en 10). Tentamencijfer is hiervan het gemiddelde.