

TECHNISCHE HOGESCHOOL EINDHOVEN

Afdeling Algemene Wetenschappen

Onderafdeling der Wiskunde

# **KANSREKENING**

**en**

# **STATISTIEK**

**Deel II: Statistiek**

**Bestemd voor WSK-IV**

**Voorjaarssemester 1979**



Technische Hogeschool  
Eindhoven

Dictaatnummer 2.242  
Prijs f. 3,50

# Onderafdeling der Wiskunde en Informatica

*JdS*

Deel II: Statistiek

## Kansrekening en Statistiek

Bestemd voor WSK-IV

TECHNISCHE HOGESCHOOL EINDHOVEN

Onderafdeling der Wiskunde

KANSREKENING EN STATISTIEK

bestemd voor WSK IV

deel 2: STATISTIEK

Voorjaarssemester 1979

Deel 2, Statistiek.

<u>Inhoudsopgave</u>	<u>blz.</u>
Inleiding	iv
Hoofdstuk 6. STEEKPROEF EN POPULATIE	83
Hoofdstuk 7. SCHATTEN van PARAMETERS	
7.1. Schatters en hun eigenschappen	85
7.2. Methoden voor het vinden van schatters	91
7.3. Voldoende schatters	96
Hoofdstuk 8. TOETSINGSTHEORIE	
8.1. Algemene principes	104
8.2. Constructie van toetsen	110
8.3. Betrouwbaarheidsintervallen	119
APPENDIX	
A3. Ongelijkheid van Cramér-Rao	128
A4. Onafhankelijkheid van $\underline{s}^2$ en $\bar{\underline{x}}$ (bij normale verdeling)	130

## Inleiding

De theoretische statistiek kan beschouwd worden als een toepassing van de kansrekening. Anderzijds gaat aan de toepassing van de kansrekening meestal een toepassing van de statistiek vooraf: in de statistiek houden we ons bezig met onderzoek naar het (gedetailleerde) kanstheoretische model dat het experiment of verschijnsel dat we bestuderen beschrijft. Dit model is meestal niet in alle details bekend en er zijn waarnemingen nodig om het model volledig te maken, zonder dat in het algemeen met zekerheid het precieze model kan worden vastgesteld. Als we (bijvoorbeeld) een uitspraak willen doen over het vrouwenoverschot in 1984, zullen we (o.a.) moeten weten hoe groot de kans, zeg  $p$ , is dat een (enkelvoudige) geboorte een meisje oplevert. Deze kans  $p$  kan wel uit waarnemingen (tellingen) geschat worden, maar niet exact worden vastgesteld. Deze waarnemingen kunnen ook worden gebruikt om te concluderen dat  $p$  "wel tussen  $p_1$  en  $p_2$  zal liggen" of speciaal dat  $p > \frac{1}{2}$  is. Methoden om te komen tot uitspraken van deze soort zijn het onderwerp van de volgende hoofdstukken.

## 6. Steekproef en populatie

Definitie 6.1:  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  heet een *aselecte steekproef* van de grootte  $n$  uit een *populatie* met verdelingsfunctie  $F$ , als  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  onderling onafhankelijke stochastische grootheden zijn met  $F_{\underline{x}_j} = F$  ( $j=1,2,\dots,n$ ). Als

$F = F_{\underline{x}}$ , dan spreken we wel van een *aselecte steekproef van  $\underline{x}$*  of een *aselecte steekproef uit een verdeling met verdelingsfunctie  $F$* . (Een vrijwel identieke definitie geldt voor een *aselecte steekproef uit een meer-dimensionale verdeling*).

In deze definitie speelt het woord "populatie" geen wezenlijke rol; het wordt gebruikt om aan te geven, dat de steekproef ontstaan is door het doen van metingen of waarnemingen bij een deelverzameling van een verzameling (de populatie) waarin we geïnteresseerd zijn. Voorbeeld: we kiezen, (met teruglegging en met gelijke kansen) 100 Eindhovenaren en bepalen hun lengte; de populatie bestaat nu uit alle Eindhovenaren (of: hun lengten), de steekproef bestaat uit de 100 (te kiezen) grootheden  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_{100}$ ,  $F(x)$  is gelijk aan de fractie van alle Eindhovenaren met een lengte niet groter dan  $x$  en  $\underline{x}$  is de lengte van zo'n willekeurig te kiezen Eindhovenaar. Het is niet altijd helemaal duidelijk wat de populatie is: als we aannemen dat de kansverdeling van de lengten van bijv. Enschedeërs, toekomstige Eindhovenaren of zelfs van alle huidige en toekomstige Nederlanders ook  $F$  is, dan kunnen we de populatie dienovereenkomstig uitbreiden. Een ander voorbeeld: we gaan  $n$  keer (onafhankelijk) met een dobbelsteen gooien en daarbij telkens noteren hoeveel zessen (0 of 1) er boven komen. De steekproef bestaat dan uit de  $n$  (nog te verschijnen) aantallen  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$ ; wat de populatie is, is in zekere mate een kwestie van smaak: alle mogelijke (gedane of nog te verrichten) worpen met die ene dobbelsteen of zelfs van alle soortgelijke dobbelstenen. We zullen ons verder niet met dit probleem bezighouden. Ook de manier waarop de steekproef tot stand komt, zullen we doorgaans in het midden laten. Problemen van deze soort komen aan de orde in de colleges Toegepaste Statistiek en Statistische Theorie van Proefopzetten.

We doen metingen alleen bij een deel van de populatie en niet bij de hele populatie omdat dat laatste meestal te kostbaar of te tijdrovend is. Sommige metingen zijn bovendien destructief: treksterktebepalingen, valproeven e.d.

Steekproeven worden gebruikt om iets over de populatie te weten te komen. In het eerste geval kunnen we bijvoorbeeld uit de steekproef een indruk krijgen van de gemiddelde lengte van de Eindhovenaren,  $E_{\underline{x}}$ ; in het tweede

geval kunnen we er achter komen of bij de gegeven dobbelsteen de kans op een zes (wel)  $1/6$  is. Het eerstgenoemde voorbeeld is een eenvoudig *schattingsprobleem*, het tweede een *toetsingsprobleem*.

In de meeste gevallen zullen we aannemen dat de populatie waar het over gaat een verdelingsfunctie  $F_{\underline{x}}$  heeft van de gedaante  $F_{\underline{x}}(x) = F(x; \theta)$ , waarbij alleen de waarde van  $\theta$  onbekend is. Hierbij zal de parameter  $\theta$  meestal één-dimensionaal zijn. De steekproef dient dan om een indruk te krijgen van de waarde van deze parameter. Dikwijls zullen we in verband hiermee een *functie* van de steekproef beschouwen, waarvan we verwachten dat die de waarde van  $\theta$  goed zal benaderen.

Definitie 6.2: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$ . Een *statistische grootheid*  $\underline{t}$  is een stochastische grootheid (of een stochastische vector) die een *functie van de steekproef* is:  $\underline{t} = t(\underline{x}_1, \dots, \underline{x}_n)$ . Als  $F_{\underline{x}}(x) = F(x; \theta)$ , dan hangt de functie  $t$  niet af van  $\theta$  (de kansverdeling van  $\underline{t}$  wel!).

Opmerking 6.3: Als de metingen of de waarnemingen gegeven zijn, dan is het resultaat een rijtje reële getallen (of vectoren):  $x_1, \dots, x_n$ . We noemen dit resultaat een *steekproefrealisatie* of een *waargenomen steekproef* of ook wel "*de waarnemingen*". De statistische grootheid gaat hierbij over in een functie van deze waarnemingen:  $t = t(x_1, \dots, x_n)$ . We noemen  $t$  dan een *realisatie* van  $\underline{t}$ .

We zullen in de volgende hoofdstukken drie basistechnieken uit de statistiek bespreken: (i) Het *schatten* van parameters, (ii) het *toetsen* van hypothesen en (iii) het bepalen van *betrouwbaarheidsintervallen*.

We illustreren dit aan een eenvoudig voorbeeldje.

Voorbeeld 6.4: We gooien 100 keer met een dobbelsteen en vinden 14 zessen. We kunnen nu (i) dit resultaat gebruiken om de kans  $p$  op een zes te schatten, bijv.  $p \approx 14/100$ . We kunnen ook (ii) er van uit gaan dat  $p = 1/6$  zou moeten zijn en nagaan ("toetsen") of dit wel in overeenstemming is met ons resultaat van 14 zessen. Tenslotte kunnen we (iii) onderzoeken welke interval van waarden van  $p$  redelijkerwijs mogelijk is gezien dit resultaat. Het zal duidelijk zijn dat de drie problemen met elkaar verwant zijn.

Opmerking 6.5: Soms zullen we steekproeven  $\underline{x}_1, \dots, \underline{x}_n$  beschouwen, waarbij de  $\underline{x}_j$  niet o.o. zijn of niet dezelfde verdeling hebben.

7. Schatten van parameters

7.1 Schatters en hun eigenschappen

We gaan er in dit hoofdstuk meestal van uit dat we beschikken over een aselechte steekproef  $\underline{x}_1, \dots, \underline{x}_n$  van  $\underline{x}$  met  $F_{\underline{x}}(x) = F(x; \theta)$ , waarbij  $\theta \in \Omega$  met  $\Omega \subset \mathbb{R}$  (of soms  $\Omega \subset \mathbb{R}^k$ ). We noemen de verzameling  $\Omega$  van parameterwaarden de *parameter ruimte*. Hierbij nemen we aan dat  $F$  een bekende functie is van  $x$  en  $\theta$ , waarbij  $\theta$  voor de beschouwde populatie een vaste, onbekende waarde heeft; deze waarde noemt men dan wel de *ware parameter waarde*. In een enkel geval hebben we te maken met niet gespecificeerde kansverdelingen:  $F_{\underline{x}} = F$  met  $F$  onbekend, terwijl we iets willen weten over bijv.  $E\underline{x}$  of  $\text{var } \underline{x}$ , waarvan we dan natuurlijk aannemen dat ze bestaan. In deze situatie spreekt men wel van parameter vrije statistiek. Wij zullen ook in dit geval  $E\underline{x}$  en  $\text{var } \underline{x}$  als parameters noteren:  $E\underline{x} = \mu$  en  $\text{var } \underline{x} = \sigma^2$ .

(Meta-)Definitie 7.1.1: Een *schatter*  $\hat{\theta}$  voor een parameter  $\theta$  is een statistische grootheid  $\hat{\theta}(\underline{x}_1, \dots, \underline{x}_n)$  die bedoeld is om  $\theta$  te schatten. Een realisatie  $\hat{\theta} = \hat{\theta}(\underline{x}_1, \dots, \underline{x}_n)$  van  $\hat{\theta}$  noemen we een *schatting* van  $\theta$ . Soms noteren we een schatter voor  $\mu, \sigma, \tau$ , etc. als  $\underline{m}, \underline{s}, \underline{t}$  etc. De functie  $\hat{\theta}$  hangt af van  $n$ ; als  $n$  niet constant is, schrijven we  $\hat{\theta}_n$  en evenzo  $\underline{m}_n, \underline{s}_n, \underline{t}_n$ , etc.

Volgens bovenstaande definitie is het aangeven van een schatter weinig meer dan een intentieverklaring. Wat we nodig hebben zijn kwaliteitseisen en criteria: welke eigenschappen zijn gewenst voor schatters en wanneer is de ene schatter beter dan de andere?

Definitie 7.1.2: Als  $\hat{\theta}_n$  een schatter is voor  $\theta$ , dan heet

$$\theta - E\hat{\theta}_n \quad (\theta \in \Omega)$$

de *onzuiverheid* van  $\hat{\theta}_n$  (met betrekking tot  $\theta$ ). Als

$$E\hat{\theta}_n = \theta \quad (\theta \in \Omega),$$

dan heet  $\hat{\theta}_n$  een *zuivere schatter* voor  $\theta$ . Als

$$\lim_{n \rightarrow \infty} E\hat{\theta}_n = \theta \quad (\theta \in \Omega),$$

dan heet (de rij schatters)  $\hat{\theta}_n$  *asymptotisch zuiver*.



Opmerking 7.1.3:  $E\hat{\theta}_{-n}$  is een functie van  $\theta$ , immers (als  $F_{\underline{x}}$  absoluut continu is, en analoog in het diskrete geval)

$$E\hat{\theta}_{-n} = \int_{-\infty}^{\infty} \dots \int_{-\infty}^{\infty} \hat{\theta}_{-n}(x_1, \dots, x_n) f_{\underline{x}_1}(x_1; \theta) \dots f_{\underline{x}_n}(x_n; \theta) dx_1 \dots dx_n;$$

dit wordt soms aangegeven door de notatie  $E_{\theta} \hat{\theta}_{-n}$ .

Definitie 7.1.4: Als  $\hat{\theta}_{-n}$  een schatter is voor  $\theta$ , dan heet

$$\{E(\hat{\theta}_{-n} - \theta)^2\}^{\frac{1}{2}} \quad (\theta \in \Omega)$$

de *onnauwkeurigheid* van  $\hat{\theta}_{-n}$ . Als  $E(\hat{\theta}_{-n,0} - \theta)^2 \leq E(\hat{\theta}_{-n} - \theta)^2$  voor alle  $\theta \in H$  en alle schatters  $\hat{\theta}_{-n}$  in een klasse  $S$ , terwijl ook  $\hat{\theta}_{-n,0} \in S$ , dan heet  $\hat{\theta}_{-n,0}$  een *nauwkeurigste* schatter in  $S$  (hierbij is impliciet verondersteld dat  $E\hat{\theta}_{-n}^2 < \infty$  voor  $\hat{\theta}_{-n} \in S$ ).

Definitie 7.1.5: Een rij schatters  $\hat{\theta}_{-n}$  voor  $\theta$  heet *asymptotisch nauwkeurig* als

$$\lim_{n \rightarrow \infty} E(\hat{\theta}_{-n} - \theta)^2 = 0 \quad (\theta \in \Omega) .$$

Definitie 7.1.6: Een rij schatters  $\hat{\theta}_{-n}$  voor  $\theta$  heet *asymptotisch raak* (of: *consistent*) als

$$\hat{\theta}_{-n} \xrightarrow{P} \theta \quad (\theta \in \Omega),$$

d.w.z. als  $\lim_{n \rightarrow \infty} P(|\hat{\theta}_{-n} - \theta| \geq \epsilon) = 0$  voor iedere  $\epsilon > 0$ .

Stelling 7.1.7: Als de rij schatters  $\hat{\theta}_{-n}$  voor  $\theta$  asymptotisch nauwkeurig is, dan is hij ook asymptotisch zuiver en consistent.

Bewijs:  $E(\hat{\theta}_{-n} - \theta)^2 = \text{var } \hat{\theta}_{-n} + (E\hat{\theta}_{-n} - \theta)^2$  (ga na). Omdat gegeven is dat  $E(\hat{\theta}_{-n} - \theta)^2 \rightarrow 0$  voor  $n \rightarrow \infty$ , geldt ook  $E\hat{\theta}_{-n} \rightarrow \theta$  als  $n \rightarrow \infty$ , d.w.z.  $\hat{\theta}_{-n}$  is asymptotisch zuiver.

Geheel analoog aan het bewijs van de ongelijkheid van Chebyshev (stelling 5.2.1) bewijst men

$$(7.1.1) \quad P(|\hat{\theta}_{-n} - \theta| \leq \epsilon) \geq \epsilon^{-2} E(\hat{\theta}_{-n} - \theta)^2.$$

Volgens het gegeven gaat het rechter lid van (7.1.1) voor  $n \rightarrow \infty$  naar nul.

Opmerking 7.1.8: Als  $\hat{\theta}_{-n}$  zuiver is, dan is  $E(\hat{\theta}_{-n} - \theta)^2 = \text{var } \hat{\theta}_{-n}$ .

Voorbeeld 7.1.9: Zij  $x_1, x_2, \dots, x_n$  een aselechte steekproef uit een Bernoulli-verdeling (binomiale verdeling met  $n=1$ ) met onbekende parameter  $p$ . Als schatter voor  $p$  ligt nu voor de hand: de fractie enen in de steekproef, dus  $\hat{p}_{-n} = k_{-n}/n$ , waarbij  $k_{-n} = x_1 + \dots + x_n$ . Nu is  $\hat{p}_{-n}$  zuiver en asymptotisch nauwkeurig, immers (zie voorbeeld 4.1.2 b en opgave 5.2.3)

$$E \hat{p}_{-n} = \frac{1}{n} E k_{-n} = p, \quad E(\hat{p}_{-n} - p)^2 = \text{var } \hat{p}_{-n} = p(1-p)/n.$$

Definitie 7.1.10: Als  $x_1, x_2, \dots, x_n$  een aselechte steekproef is van  $\underline{x}$  met (onbekende) verwachting  $\mu$ , dan heet

$$(7.1.2) \quad \underline{m}_{-n} := \bar{\underline{x}} = \frac{1}{n} \sum_1^n x_j$$

het *steekproefgemiddelde*;

$$(7.1.3) \quad \underline{s}_{-n}^2 := \frac{1}{n-1} \sum_1^n (x_j - \underline{m}_{-n})^2$$

heet de *steekproefvariantie*; hierbij nemen we aan dat  $\sigma^2 := \text{var } \underline{x} < \infty$  is en mogelijk onbekend.

Stelling 7.1.11: Zij  $x_1, \dots, x_n$  een aselechte steekproef van  $\underline{x}$  met  $E \underline{x} = \mu$  en  $\text{var } \underline{x} = \sigma^2$ , dan geldt

$$(7.1.4) \quad E \underline{m}_{-n} = \mu; \quad E \underline{s}_{-n}^2 = \sigma^2,$$

d.w.z.  $\underline{m}_{-n}$  en  $\underline{s}_{-n}^2$  zijn zuivere schatters voor resp.  $\mu$  en  $\sigma^2$ .

Bewijs: Dat  $E \underline{m}_{-n} = \mu$  zagen we al in opgave 5.2.3. Om te bewijzen dat  $\underline{s}_{-n}^2$  zuiver is beschouwen we  $(n-1)E \underline{s}_{-n}^2$ :

$$E \sum_1^n (x_j - \underline{m}_{-n})^2 = E \sum_1^n \{(x_j - \mu) - (\underline{m}_{-n} - \mu)\}^2 = E \sum_1^n (x_j - \mu)^2 - n E(\underline{m}_{-n} - \mu)^2 = (n-1)\sigma^2,$$

waarbij we gebruik hebben gemaakt van de identiteit

$$(7.1.5) \quad \sum_1^n (a_k - \bar{a})^2 = \sum_1^n a_k^2 - na^2,$$

waarbij  $\bar{a} = \frac{1}{n} \sum_1^n a_k$ .

Opgave 7.1.12: Bewijs (7.1.5) door var  $\underline{a}$  te beschouwen voor een stochastische grootheid  $\underline{a}$  met  $P(\underline{a} = a_k) = \frac{1}{n}$  ( $k=1,2,\dots,n$ ).

Opgave 7.1.13: Als  $E\underline{x} = \mu$  bekend is, dan is

$$(7.1.6) \quad \underline{s}_0^2 := n^{-1} \sum_1^n (\underline{x}_k - \mu)^2$$

een zuivere schatter voor  $\sigma^2 = \text{var } \underline{x}$ .

Stelling 7.1.14:  $\underline{m}_n$  is de nauwkeurigste schatter voor  $\mu$  onder alle zuivere lineaire schatters voor  $\mu$ , d.w.z. onder alle zuivere schatters  $\hat{\underline{\mu}}_n$  van de vorm

$$(7.1.7) \quad \hat{\underline{\mu}}_n = \sum_1^n \alpha_k \underline{x}_k.$$

Bewijs: Omdat  $E \hat{\underline{\mu}}_n = \mu$ , volgt uit (7.1.7) dat  $\sum_1^n \alpha_k = 1$ . De onnauw-

keurigheid van  $\hat{\underline{\mu}}_n$  wordt gegeven door (zie opmerking 7.1.8)  $\sigma(\hat{\underline{\mu}}_n)$ . Deze onnauwkeurigheid is minimaal, als  $\sum_1^n \alpha_k^2$  minimaal is onder de nevenvoorwaarde dat  $\sum_1^n \alpha_k = 1$ . Zij nu  $\delta_k = \alpha_k - 1/n$ , dan is  $\sum_1^n \delta_k = 0$  en (ga na)

$$\sum_1^n \alpha_k^2 = \sum_1^n \delta_k^2 + \frac{1}{n};$$

dit is minimaal als  $\delta_k = 0$ , d.w.z.  $\alpha_k = \frac{1}{n}$  voor  $k=1,2,\dots,n$ .

Opmerking 7.1.15: Het is soms mogelijk om de nauwkeurigheid te vergroten ten koste van de zuiverheid. Als we  $\mu$  schatten met

$$\hat{\underline{\mu}}_n = a \underline{m}_n = a/n \sum_1^n \underline{x}_k,$$

dan geldt

$$(7.1.8) \quad E \hat{\underline{\mu}}_n = a\mu, \quad E(\hat{\underline{\mu}}_n - \mu)^2 = a^2 \frac{\sigma^2}{n} + (1-a)^2 \mu^2.$$

De onnauwkeurigheid is minimaal en *kleiner* dan  $\sigma^2/n$  voor  $a = \mu^2/(\mu^2 + \sigma^2/n)$ .

Opmerking 7.1.16: Het kan voorkomen dat er voor een parameter geen zuivere schatter bestaat. Voorbeeld: zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met  $P(\underline{x}=1)=1/\theta$  en  $P(\underline{x}=0)=1-1/\theta$  met  $\theta \in (1, \infty)$ .

Stel nu dat  $\hat{\underline{\theta}} = \hat{\theta}(\underline{x}_1, \dots, \underline{x}_n)$  een zuivere schatter is voor  $\theta$ , dan geldt

$$(7.1.9) \quad E \hat{\underline{\theta}} = \sum \dots \sum \hat{\theta}(\underline{x}_1, \dots, \underline{x}_n) \left(\frac{1}{\theta}\right)^{\sum_{k=1}^n x_k} \left(1 - \frac{1}{\theta}\right)^{n - \sum_{k=1}^n x_k} = \theta,$$

waarbij gesommeerd wordt over alle  $(2^n)$  mogelijkheden voor  $(x_1, \dots, x_n)$ .

Nu staat in het linker lid van (7.1.9) een polynoom in  $1/\theta$ ; dit kan onmogelijk voor alle  $\theta \in (1, \infty)$  gelijk zijn aan  $\theta$ .

Opgave 7.1.17: Ga na dat voor  $n$  o.o. grootheden  $\underline{x}_1, \dots, \underline{x}_n$  met  $P(\underline{x}_k=0)=1-p$  en  $P(\underline{x}_k=1)=p$  ( $k=1, 2, \dots, n$ ) geldt

$$(7.1.10) \quad P((\underline{x}_1, \dots, \underline{x}_n) = (x_1, \dots, x_n)) = p^{x_1 + \dots + x_n} (1-p)^{n - (x_1 + \dots + x_n)}.$$

Soms is het mogelijk om van een schatter voor  $\theta$  te laten zien dat hij de nauwkeurigste is onder alle zuivere schatters. Dit kan op grond van de volgende stelling.

Stelling 7.1.18 (ongelijkheid van Cramér -Rao): Zij  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met  $F_{\underline{x}}(\underline{x}) = F(\underline{x}; \theta)$  en zij  $\underline{t} = t(\underline{x}_1, \dots, \underline{x}_n)$  een schatter voor  $\theta$  met  $E \underline{t} = \alpha(\theta)$ , dan geldt (onder weinig beperkende regulariteitsvoorwaarden)

$$(7.1.11) \quad \text{var } \underline{t} \geq \frac{\{\alpha'(\theta)\}^2}{n E \left\{ \frac{\partial \log p(\underline{x}; \theta)}{\partial \theta} \right\}^2} = \frac{-\{\alpha'(\theta)\}^2}{n E \frac{\partial^2 \log p(\underline{x}; \theta)}{\partial \theta^2}},$$

waarin

$$(7.1.12) \quad p(\underline{x}; \theta) = \begin{cases} f_{\underline{x}}(\underline{x}) & \text{als } F_{\underline{x}} \text{ absoluut continu is} \\ P(\underline{x}=\underline{x}) & \text{als } F_{\underline{x}} \text{ diskreet is.} \end{cases}$$

Gelijkheid geldt in (7.1.11) dan en slechts dan als er een constante  $c_n(\theta)$  bestaat zó dat met kans 1

$$(7.1.13) \quad \sum_{k=1}^n \frac{\partial \log p(\underline{x}_k; \theta)}{\partial \theta} = c_n(\theta) (\underline{t} - \alpha(\theta)).$$

Bewijs: voor het bewijs van een wat algemenere en preciezer geformuleerde stelling verwijzen we naar de Appendix (stelling A 3.1).

Relatie (7.1.13) kunnen we gebruiken om een nauwkeurigste *zuivere* schatter te vinden (vergelijk definitie 7.1.4). We komen hier in § 7.2 op terug.

Voorbeeld 7.1.19: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met  $P(\underline{x} = x) = e^{-\lambda} \lambda^x / x!$  ( $x=0, 1, 2, \dots$ ), d.w.z. in de notatie van stelling 7.1.18 dat

$$\log p(\underline{x}; \lambda) = -\lambda + \underline{x} \log \lambda - \log(\underline{x}!)$$

en dat

$$(7.1.14) \quad \frac{\partial \log p(\underline{x}; \lambda)}{\partial \lambda} = -1 + \frac{\underline{x}}{\lambda}; \quad \frac{\partial^2 \log p(\underline{x}; \lambda)}{\partial \lambda^2} = -\frac{\underline{x}}{\lambda^2},$$

en dus

$$-n E \frac{\partial^2 \log p(\underline{x}; \lambda)}{\partial \lambda^2} = n/\lambda.$$

Omdat  $\alpha(\lambda) = \lambda$  en dus  $\alpha'(\lambda) = 1$ , is de kleinst mogelijke variantie gelijk aan  $\lambda/n$ . Het is nu duidelijk dat  $\underline{t} := \underline{m}_n = n^{-1} \sum_1^n \underline{x}_k$  een zuivere schatter is met minimale variantie. Uit (7.1.13) volgt ook met (7.1.14) dat

$$\underline{t} = \lambda + c_n^{-1}(\lambda) \left\{ \sum_1^n \underline{x}_k / \lambda - n \right\};$$

omdat  $\underline{t}$  een statistische grootte moet zijn en dus niet van  $\lambda$  mag afhangen is de keuze  $c_n(\lambda) = n/\lambda$  de enig mogelijke.

Dit levert ook  $\underline{t}_n = n^{-1} \sum_1^n \underline{x}_k$ .

Opgave 7.1.20: Zij  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$ , waarbij  $\underline{x}$  normaal verdeeld is met  $E \underline{x} = \mu$  (onbekend) en  $\text{var } \underline{x} = I$ . Laat zien dat  $\underline{m}_n$  (zie (7.1.2)) een zuivere schatter is voor  $\mu$  met minimale variantie.

Opgave 7.1.21: Als  $\underline{t}$  aan (7.1.13) voldoet, dan geldt  $c_n^2(\theta) = (\alpha'(\theta))^2 / (\text{var } \underline{t})^2$ .

## 7.2 Methoden voor het vinden van schatters

In eenvoudige gevallen is het niet moeilijk om een schatter te bedenken voor een parameter. Zo ligt  $\underline{m}_n$  voor de hand als schatter voor  $E \underline{x}$  en  $\underline{s}_0^2$  als schatter voor  $\sigma^2$  als  $E \underline{x} = \mu$  bekend is (zie (7.1.6)). In ingewikkelder situaties is het van belang een formele methode te hebben om schatters voor een parameter te vinden. Eén zo'n methode berust op het zgn. principe van de *grootste aannemelijkheid* (*maximum likelihood principle*).

Definitie 7.2.1: Als  $(\underline{x}_1, \dots, \underline{x}_n)$  een stochastische vector is met verdelingsfunctie

$$F_{\underline{x}_1, \dots, \underline{x}_n}(\underline{x}_1, \dots, \underline{x}_n) = F(\underline{x}_1, \dots, \underline{x}_n; \theta),$$

waarin  $\theta$  een (mogelijk meer-dimensionale) parameter is, dan heet de functie  $L$  gedefinieerd door

$$(7.2.1) \quad L(\underline{x}_1, \dots, \underline{x}_n; \theta) = \begin{cases} f_{\underline{x}_1, \dots, \underline{x}_n}(\underline{x}_1, \dots, \underline{x}_n) & \text{als } F_{\underline{x}_1, \dots, \underline{x}_n} \text{ abs.kont. is} \\ P(\underline{x}_1 = \underline{x}_1, \dots, \underline{x}_n = \underline{x}_n) & \text{als } F_{\underline{x}_1, \dots, \underline{x}_n} \text{ diskreet is,} \end{cases}$$

de *aannemelijkheidsfunctie* van  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$ . Als  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef is van  $\underline{x}$  met  $F_{\underline{x}}(\underline{x}) = F(\underline{x}; \theta)$ , dan gaat (7.2.1) over in (zie (7.1.12))

$$(7.2.2) \quad L(\underline{x}_1, \dots, \underline{x}_n; \theta) = \prod_1^n p(\underline{x}_j; \theta).$$

Definitie 7.2.2: Zij  $(x_1, \dots, x_n)$  een realisatie van een stochastische vector met verdelingsfunctie  $F(x_1, \dots, x_n; \theta)$ . Een *meest aannemelijke schatting* van  $\theta$ , gebaseerd op de waarneming  $(x_1, \dots, x_n)$ , is een waarde  $\hat{\theta} = \hat{\theta}(x_1, \dots, x_n)$  met de eigenschap dat

$$(7.2.3) \quad \max_{\theta \in \Omega} L(x_1, \dots, x_n; \theta) = L(x_1, \dots, x_n; \hat{\theta}).$$

Als  $\hat{\theta}$  voor iedere  $(x_1, \dots, x_n)$  eenduidig bepaald is, en als  $\hat{\theta}(\underline{x}_1, \dots, \underline{x}_n)$  een stochastische grootheid (stochastische vector) is, dan heet

$$\underline{\hat{\theta}} := \hat{\theta}(\underline{x}_1, \dots, \underline{x}_n)$$

de *meest aannemelijke schatter* (*maximum likelihood estimator*) voor  $\theta$ . We zullen  $\underline{\hat{\theta}}$  bij wijze van afkorting wel de ML-schatter noemen.

Bovenstaande definitie is gebaseerd op de overweging dat een meest aannemelijke schatting voor  $\theta$  die waarde van  $\theta$  is, die aan de gevonden waarnemingen  $x_1, \dots, x_n$  in het diskrete geval de grootst mogelijke kans geeft en in het absoluut continue geval de grootst mogelijke kansdichtheid.

Voorbeeld 7.2.3: Zij  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met

$$f_{\underline{x}}(x) = \frac{1}{\sqrt{2\pi}} e^{-(x-\mu)^2/2} \quad (\mu \in \mathbb{R}).$$

Wat is de ML-schatter  $\underline{\hat{\mu}}$  voor  $\mu$ ?

Antwoord:  $L(x_1, \dots, x_n; \mu)$  is maximaal als  $\log L(x_1, \dots, x_n; \mu)$  maximaal is, en

$$\log L(x_1, \dots, x_n; \mu) = -\frac{n}{2} \log(2\pi) - \frac{1}{2} \sum_1^n (x_k - \mu)^2.$$

Men gaat eenvoudig na dat  $L$  maximaal is voor  $\mu = n^{-1} \sum_1^n x_k$ , d.w.z. dat

de meest aannemelijke schatter voor  $\mu$  gegeven wordt door  $\underline{\hat{\mu}} = \underline{m}_n$  (zie definitie 7.1.10).

Voorbeeld 7.2.4: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met

$$P(\underline{x} = 0) = 1 - p ; \quad P(\underline{x} = 1) = p \quad (0 \leq p \leq 1).$$

Bepaal de ML-schatter voor  $p$ .

Antwoord:  $L(\underline{x}_1, \dots, \underline{x}_n; p) = p^{\sum_{k=1}^n x_k} (1-p)^{n - \sum_{k=1}^n x_k}$  (zie opgave 7.1.17).

Als  $0 < \sum_{k=1}^n x_k < n$ , dan is  $L = 0$  voor  $p = 0$  en  $p = 1$ . Voor  $0 < p < 1$  geldt dat  $L$  maximaal is als  $\log L$  maximaal is, terwijl

$$\log L(\underline{x}_1, \dots, \underline{x}_n) = \sum_{k=1}^n x_k \log p + (n - \sum_{k=1}^n x_k) \log (1 - p).$$

Dit is maximaal voor  $p = n^{-1} \sum_{k=1}^n x_k$ . Als  $\sum_{k=1}^n x_k = 0$ , dan is  $L$  maximaal (gelijk aan 1)

voor  $p=0$ ; als  $\sum_{k=1}^n x_k = n$ , dan is  $L$  maximaal voor  $p=1$ .

Conclusie: de ML-schatter voor  $p$  is

$$\hat{p} = \underline{k}/n,$$

met  $\underline{k} = \underline{x}_1 + \dots + \underline{x}_n$ .

Opgave 7.2.5: Zij  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  een aselechte steekproef uit een homogene verdeling op  $[0, \theta]$ ,  $\theta > 0$ . Bepaal de ML-schatter voor  $\theta$ .

Voorbeeld 7.2.6: Zij  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met

$$f_{\underline{x}}(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-(x-\mu)^2/(2\sigma^2)} \quad (\mu \in \mathbb{R}; \sigma^2 > 0).$$

$L(\underline{x}_1, \dots, \underline{x}_n; \mu, \sigma^2)$  is maximaal, als  $\log L$  maximaal is. We schrijven  $\lambda = 1/(2\sigma^2)$  en  $\ell = \log L$ . We krijgen dan

$$\ell(\underline{x}_1, \dots, \underline{x}_n; \mu, \lambda) = \text{const.} + \frac{n}{2} \log \lambda - \lambda \sum_{j=1}^n (x_j - \mu)^2$$

met  $\lambda > 0$  en  $\mu \in \mathbb{R}$ . We vinden de stationaire punten uit

$$\frac{\partial \ell}{\partial \lambda} = \frac{n}{2\lambda} - \sum_{j=1}^n (x_j - \mu)^2 = 0$$



$$\frac{\partial \ell}{\partial \mu} = 2\lambda \sum_1^n (x_j - \mu) = 0.$$

De enige oplossing hiervan is  $\mu = \hat{\mu} = \frac{1}{n} \sum_1^n x_j$  en  $\lambda = \hat{\lambda} = (2 \sum_1^n (x_j - \hat{\mu})^2 / n)^{-1}$ ,  
 d.w.z.  $\hat{\sigma}^2 = \frac{1}{n} \sum_1^n (x_j - \hat{\mu})^2$ . Verder vinden we voor  $\lambda = \hat{\lambda}$  en  $\mu = \hat{\mu}$

$$\frac{\partial^2 \ell}{\partial \lambda^2} = -n / (2\lambda^2); \quad \frac{\partial^2 \ell}{\partial \lambda \partial \mu} = \frac{\partial^2 \ell}{\partial \mu \partial \lambda} = 0; \quad \frac{\partial^2 \ell}{\partial \mu^2} = -2n\lambda.$$

Dit betekent dat L een uniek maximum heeft in  $(\hat{\lambda}, \hat{\mu})$ , zodat de ML-schatteer voor  $(\mu, \sigma^2)$  gegeven wordt door  $(\hat{\mu}, \hat{\sigma}^2)$  met

$$\hat{\mu} = \frac{1}{n} \sum_1^n x_j = \bar{x}_n$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_1^n (x_j - \bar{x}_n)^2,$$

waarbij dus  $\hat{\sigma}^2$  blijkens stelling 7.1.11 niet zuiver is (wel asymptotisch zuiver;  $\hat{\mu}$  en  $\hat{\sigma}^2$  zijn natuurlijk functies van n).

Opgave 7.2.7: Laat het volgende zien. Als  $\hat{\theta}$  de meest aannemelijke schatteer is voor  $\theta$  en als  $u: \Omega \rightarrow \Omega'$  een een-eenduidige functie is, z6 dat  $u(\hat{\theta})$  een stochastische grootheid is, dan is  $u(\hat{\theta})$  de ML-schatteer voor  $u(\theta)$  ( deze eigenschap wordt wel *invariantie* genoemd).

Opmerking 7.2.8: Onder vrij algemene voorwaarden geldt voor ML-schatteers

- $E(\hat{\theta}_n - \theta)^2 \rightarrow 0$  (en zelfs  $\hat{\theta}_n \xrightarrow{a.s.} \theta$ ) ( $n \rightarrow \infty; \theta \in \Omega$ )
- $\hat{\theta}_n$  is asymptotisch normaal (vergelijk definitie 5.4.4).

Opgave 7.2.9: De schatteer  $\underline{s}_n^2$  (zie 7.1.3) is zuiver voor  $\sigma^2$ . Laat zien dat  $\underline{s}_n$  niet zuiver is voor  $\sigma$ .

Een iets primitievere methode om schatteers te krijgen is de *momentenmethode*. We geven eerst een definitie.

Definitie 7.2.10: Als  $\underline{x}_1, \dots, \underline{x}_n$  een aselecte steekproef is van  $\underline{x}$ , dan heet

$$(7.2.4) \quad \underline{m}^{(k)} = \underline{m}_n^{(k)} := \frac{1}{n} \sum_{j=1}^n \underline{x}_j^k$$

het  $k$ -de *steekproefmoment*. Een realisatie van  $\underline{m}^{(k)}$  geven we aan met  $m^{(k)}$ .

Definitie 7.2.11: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met  $\mu_k = E \underline{x}^k$  ( $k=1, 2, \dots, r$ ) en  $F_{\underline{x}}(\mathbf{x}) = F(\mathbf{x}; \theta_1, \dots, \theta_r)$ . Als de vergelijkingen

$$(7.2.5) \quad \mu_k = \mu_k(\theta_1, \dots, \theta_r) = m^{(k)} \quad (k=1, \dots, r)$$

één oplossing  $(\hat{\theta}_1, \dots, \hat{\theta}_r)$  hebben zó dat  $\hat{\theta}_k := \hat{\theta}_k(\underline{m}^{(1)}, \dots, \underline{m}^{(r)})$  een stochastische grootheid is ( $k=1, \dots, r$ ), dan heet  $(\hat{\theta}_1, \dots, \hat{\theta}_r)$  de *momentenschatter* voor  $(\theta_1, \dots, \theta_r)$ .

Voorbeeld 7.2.12: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met  $E \underline{x} = \mu$  en  $\text{var } \underline{x} = \sigma^2$ . Voor  $r=2$  vinden we uit (7.2.5)

$$m^{(1)} = \mu_1 \text{ en } m^{(2)} = \mu_2 = \sigma^2 + \mu_1^2,$$

omdat  $\sigma^2 = \mu_2 - \mu_1^2$ . De momenten schatters voor  $\mu_1$  en  $\sigma^2$  zijn dus

$$\hat{\mu}_1 = \underline{m}^{(1)} \quad ; \quad \hat{\sigma}^2 = \underline{m}^{(2)} - (\underline{m}^{(1)})^2.$$

Opgave 7.2.13: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef uit een homogene verdeling op  $(\theta_1, \theta_2)$ . Bereken de momentenschatter en de ML-schatter voor  $(\theta_1, \theta_2)$ .

Opmerking 7.2.14: Ook voor momentenschatters geldt onder vrij algemene voorwaarden dat zij asymptotisch nauwkeurig zijn en asymptotisch normaal.

Opmerking 7.2.15: Beide hierboven behandelde schattingsmethoden kunnen ook gebruikt worden als de steekproef niet bestaat uit onafhankelijke grootheden (vergelijk definities 7.2.1 en 7.2.2). Afhankelijkheid van de waarnemingen heeft natuurlijk wel invloed op de eigenschappen van de schatters. Bovendien moet (in ieder geval in het geval van de ML-schatters) de simultane kansverdeling bekend zijn.

### 7.3 Voldoende schatters

Als  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  diskrete stochastische grootheden zijn, die een kansverdeling hebben die *niet* van  $\theta$  afhangt, d.w.z. als

$$P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n)$$

niet van  $\theta$  afhangt, dan kan men uit de steekproef  $\underline{x}_1, \dots, \underline{x}_n$  geen informatie krijgen over deze parameter. Immers eigenschappen als  $\underline{t} = t(\underline{x}_1, \dots, \underline{x}_n) \stackrel{P}{\sim} \theta$  voor  $\theta \in \Omega$  kunnen alleen gelden als de verdeling van  $\underline{t}$  afhangt van  $\theta$ . Op een soortgelijke overweging berust de volgende definitie.

Definitie 7.3.1: Zij  $(\underline{x}_1, \dots, \underline{x}_n)$  een diskrete stochastische vector, waarvan de kansverdeling afhangt van een parameter  $\theta$  ( $\theta \in \Omega$ ). Een statistische grootheid  $\underline{t} = t(\underline{x}_1, \dots, \underline{x}_n)$  heet *voldoende* voor  $\theta$ , als

$$(7.3.1) \quad P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n \mid \underline{t} = t) \text{ niet afhangt van } \theta,$$

d.w.z. als de voorwaardelijke kansverdeling van  $\underline{x}_1, \dots, \underline{x}_n$  gegeven  $\underline{t} = t$  niet van  $\theta$  afhangt.

In analogie met de in de eerste alinea beschreven situatie zegt men nu dat  $\underline{t}$  alle in de steekproef  $\underline{x}_1, \dots, \underline{x}_n$  aanwezige informatie over  $\theta$  bevat: als  $t(\underline{x}_1, \dots, \underline{x}_n)$  gegeven is, dan geeft verdere precisering van  $(\underline{x}_1, \dots, \underline{x}_n)$  geen nadere informatie over  $\theta$ :  $\underline{t}$  is voldoende voor  $\theta$ .

Voorbeeld 7.3.2: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met  $P(\underline{x}=1) = \theta$  en  $P(\underline{x}=0) = 1-\theta$ , waarbij  $\theta$  onbekend is. Nu is  $\underline{k}_n = \underline{x}_1 + \dots + \underline{x}_n$  voldoende voor  $\theta$ , immers (ga na)

$$(7.3.2) \quad P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n \mid \underline{k}_n = k) = \begin{cases} \binom{n}{k}^{-1} & \text{als } x_1 + \dots + x_n = k \\ 0 & \text{anders} \end{cases},$$

d.w.z. de voorwaardelijke kansverdeling is een diskrete homogene verdeling over de  $\binom{n}{k}$  mogelijke punten. We kunnen nu het idee dat  $\underline{k}_n$  alle informatie over  $\theta$  bevat ook als volgt duidelijk maken: als we de kansverdeling van  $\underline{k}_n$  kennen, dan kunnen we de kansverdeling van de hele steekproef  $\underline{x}_1, \dots, \underline{x}_n$  terugvinden zonder dat we  $\theta$  kennen, immers

$$P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n) = \sum_{k=0}^n P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n \mid \underline{k}_n = k) P(\underline{k}_n = k),$$

waarbij blijkens het voorgaande alleen  $P(\underline{k} = k)$  van  $\theta$  afhangt.

Stelling 7.3.3 (Factorisatiestelling): Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef uit een diskrete verdeling met verdelingsfunctie  $F(x; \theta)$ . Een statistische grootte  $\underline{t}$  is dan en slechts dan voldoende voor  $\theta$  als

$$(7.3.3) \quad P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n) = h(t(x_1, \dots, x_n); \theta) k(x_1, \dots, x_n),$$

waarbij  $k$  niet afhangt van  $\theta$ .

Bewijs: Als  $\underline{t}$  voldoende is voor  $\theta$ , dan geldt

$$P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n) = P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n \mid \underline{t} = t(x_1, \dots, x_n)) P(\underline{t} = t(x_1, \dots, x_n))$$

waarbij o.g.v. definitie 7.3.1 de eerste factor niet van  $\theta$  afhangt.

Als (7.3.3) geldt, dan is

$$P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n \mid \underline{t} = t) = \begin{cases} 0 & \text{als } t \neq t(x_1, \dots, x_n) \\ \frac{P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n)}{P(\underline{t} = t)} & \text{als } t = t(x_1, \dots, x_n) \end{cases}$$

onafhankelijk van  $\theta$ , omdat  $P(\underline{t} = t) = \sum_{t(x_1, \dots, x_n) = t} P(\underline{x}_1 = x_1, \dots, \underline{x}_n = x_n)$

alleen via de factor  $h(t; \theta)$  van  $\theta$  afhangt.

Definitie 7.3.4: Zij  $(\underline{x}_1, \dots, \underline{x}_n)$  een stochastische vector met kansdichtheid  $f(x_1, \dots, x_n; \theta)$ . Een statistische grootte  $\underline{t} = t(\underline{x}_1, \dots, \underline{x}_n)$  heet *voldoende* voor  $\theta$ , als  $f$  in de volgende vorm gebracht kan worden:

$$(7.3.4) \quad f(x_1, \dots, x_n; \theta) = h(t(x_1, \dots, x_n); \theta) k(x_1, \dots, x_n),$$

waarbij  $k$  niet van  $\theta$  afhangt.

Opmerking 7.3.5: Men definieert ook wel:  $\underline{t}$  is voldoende voor  $\theta$  als

$F_{\underline{x}_1, \dots, \underline{x}_n}(x_1, \dots, x_n \mid \underline{t} = t)$  niet van  $\theta$  afhangt, analoog aan definitie 7.3.1.

Een eigenschap als (7.3.4) kan dan uit deze definitie worden afgeleid.

Dit leidt tot voor ons te grote wiskundige moeilijkheden.

Voorbeeld 7.3.6: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met  $f_{\underline{x}}(x) = \theta e^{-\theta x}$  ( $x > 0$ ). Nu is  $\underline{x}_1 + \dots + \underline{x}_n$  voldoende voor  $\theta$ , immers

$$f_{\underline{x}_1, \dots, \underline{x}_n}(x_1, \dots, x_n) = \theta^n e^{-\theta(x_1 + \dots + x_n)} \quad (x_1 > 0, \dots, x_n > 0)$$

voldoet aan (7.3.4) met  $k(x_1, \dots, x_n) = 1$ .

Stelling 7.3.7: Als  $\underline{t} = t(\underline{x}_1, \dots, \underline{x}_n)$  voldoende is voor  $\theta$  en als  $\hat{\theta}$  de ML-schatter is voor  $\theta$ , dan is  $\hat{\theta}$  een functie van  $\underline{t}$ .

Bewijs: We hebben (zie definitie 7.2.1) omdat  $\underline{t}$  voldoende is

$$(7.3.5) \quad L(x_1, \dots, x_n; \theta) = h(t(x_1, \dots, x_n); \theta) k(x_1, \dots, x_n),$$

waarbij  $k$  niet van  $\theta$  afhangt. Uit (7.3.5) volgt dat  $L$  maximaal is voor die waarde van  $\theta$ , waarvoor  $h(t; \theta)$  maximaal is. Dit betekent dat  $\hat{\theta}$  een functie is van  $t$ , d.w.z.  $\hat{\theta}(x_1, \dots, x_n)$  hangt alleen via  $t = t(x_1, \dots, x_n)$  van  $x_1, \dots, x_n$  af.

Stelling 7.3.8: Zij  $\underline{t}$  voldoende voor  $\theta$ .

- a. Als  $u: \mathbb{R} \rightarrow \mathbb{R}$  een omkeerbare functie is zo dat  $\underline{u} = u(\underline{t})$  een stochastische grootheid is, dan is ook  $\underline{u}$  voldoende voor  $\theta$ .
- b. Als  $v: \mathbb{R} \rightarrow \mathbb{R}$  een omkeerbare functie is, dan is  $\underline{t}$  voldoende voor  $v(\theta)$ .

Bewijs: a. zij  $\tau$  de inverse functie van  $u$ , dan geldt

$$L(x_1, \dots, x_n; \theta) = h(t; \theta) k(x_1, \dots, x_n) = h(\tau(u); \theta) k(x_1, \dots, x_n).$$

Het bewijs van b is analoog.

Opgave 7.3.9: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met

$$f_{\underline{x}}(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-\mu)^2}.$$

Laat zien dat de ML-schatter voor  $\mu$  voldoende is voor  $\mu$ .

Opgave 7.3.10: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselechte steekproef van  $\underline{x}$  met

$$f_{\underline{x}}(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-x^2/(2\sigma^2)}.$$

Laat zien dat de ML-schatter voor  $\sigma$  voldoende is voor  $\sigma$ .

Voorbeeld 7.3.11: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een aselecte steekproef van  $\underline{x}$  met

$$f_{\underline{x}}(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp \left\{ -\frac{1}{2\sigma^2} (x-\mu)^2 \right\} .$$

We zagen in voorbeeld 7.2.6 dat de ML-schatter voor  $(\mu, \sigma^2)$  gelijk is aan  $(\hat{\mu}, \hat{\sigma}^2)$  met

$$\hat{\mu} = \frac{1}{n} \sum_1^n \underline{x}_j \quad ; \quad \hat{\sigma}^2 = \frac{1}{n} \sum_1^n (\underline{x}_j - \hat{\mu})^2 .$$

We laten zien dat het paar  $(\hat{\mu}, \hat{\sigma}^2)$  voldoende is voor  $(\mu, \sigma^2)$ . We hebben

$$\begin{aligned} L(\underline{x}_1, \dots, \underline{x}_n; \mu, \sigma^2) &= \left(\frac{1}{2\pi}\right)^{n/2} \frac{1}{\sigma^n} \exp \left[ -\frac{1}{2\sigma^2} \sum_1^n (\underline{x}_j - \mu)^2 \right] = \\ &= \left(\frac{1}{2\pi}\right)^{n/2} \frac{1}{\sigma^n} \exp \left[ -\frac{n}{2\sigma^2} \{ \hat{\sigma}^2 + (\hat{\mu} - \mu)^2 \} \right] = \\ &= \left(\frac{1}{2\pi}\right)^{n/2} h(\hat{\mu}, \hat{\sigma}^2; \mu, \sigma^2) . \end{aligned}$$

Opmerking 7.3.12: Het begrip "voldoende" komt duidelijk tot uitdrukking in het volgende voorbeeld. Laat  $\underline{k}_1, \underline{k}_2, \dots, \underline{k}_n$  waarnemingen zijn van aantallen gebeurtenissen die optreden bij een Poisson-proces (zie § A1) gedurende disjuncte tijdsintervallen van (bekende) lengte  $t_1, t_2, \dots, t_n$ . We willen de onbekende parameter  $\lambda$  van het Poisson-proces schatten. We beschouwen

$$\begin{aligned} P(\underline{k}_1 = k_1, \dots, \underline{k}_n = k_n) &= e^{-\lambda(t_1 + \dots + t_n)} \prod_1^n \{ (\lambda t_j)^{k_j} / k_j! \} = \\ &= e^{-\lambda(t_1 + \dots + t_n)} \lambda^{k_1 + \dots + k_n} \prod_1^n \frac{t_j^{k_j}}{k_j!} , \end{aligned}$$

waaruit blijkt dat  $\underline{k}_1 + \dots + \underline{k}_n$  voldoende is voor  $\lambda$ . Om  $\lambda$  te schatten is het dus "voldoende" om alleen dit totaal aantal gebeurtenissen dat in de tijd  $t_1 + \dots + t_n$  optreedt te tellen. De ML-schatter voor  $\lambda$  is (ga na)

$$\hat{\lambda} = \sum_1^n \frac{k_j}{\sum_1^n t_j}$$

Stelling 7.3.13: Als  $\underline{t}$  een schatter is voor  $\theta$  met minimale variantie, d.w.z. als in (7.1.11) het gelijkheidsteken geldt, dan is  $\underline{t}$  voldoende voor  $\theta$ .

Bewijs: Blijkens (7.1.13) is met kans 1 (zie (7.2.1) en (7.2.2))

$$\frac{\partial \log L(\underline{x}_1, \dots, \underline{x}_n; \theta)}{\partial \theta} = c_n(\theta) \{ t(\underline{x}_1, \dots, \underline{x}_n) - \alpha(\theta) \},$$

d.w.z. (bijna) overal waar  $L(x_1, \dots, x_n; \theta)$  positief is geldt

$$\frac{\partial \log L(x_1, \dots, x_n; \theta)}{\partial \theta} = c_n(\theta) \{ t(x_1, \dots, x_n) - \alpha(\theta) \}.$$

Dit betekent dat  $\log L(x_1, \dots, x_n; \theta)$  de volgende vorm heeft:

$$\log L(x_1, \dots, x_n; \theta) = q(t(x_1, \dots, x_n); \theta) + c(x_1, \dots, x_n)$$

en dus  $L$  de vorm

$$L(x_1, \dots, x_n; \theta) = h(t(x_1, \dots, x_n); \theta) k(x_1, \dots, x_n),$$

d.w.z.  $\underline{t}$  is voldoende voor  $\theta$  (zie (7.3.3) en (7.3.4)).

Stelling 7.3.14 (Rao-Blackwell): Zij  $\underline{t}$  voldoende voor  $\theta$  en zij  $\underline{u}$  een zuivere schatter voor  $h(\theta)$ . Zij verder  $\underline{v}$  gedefinieerd door (zie p.57)

$$\underline{v} := E(\underline{u} | \underline{t}).$$

Dan geldt

(i)  $\underline{v}$  is een statistische grootheid;  $\underline{v} = v(\underline{t})$ ,

(ii)  $E\underline{v} = h(\theta)$ ,

(iii)  $\text{var } \underline{v} \leq \text{var } \underline{u}$  met  $\text{var } \underline{v} = \text{var } \underline{u}$  d.e.s.d. als  $P(\underline{u}=\underline{v})=1$ .

Bewijs: We beperken het bewijs tot het geval dat  $(\underline{x}_1, \dots, \underline{x}_n)$  en dus ook  $\underline{u}$  en  $\underline{t}$  een diskrete verdeling hebben.

(i)  $v(t) := E(\underline{u} | \underline{t}=t) = \sum \dots \sum u(x_1, \dots, x_n) P(\underline{x}_1=x_1, \dots, \underline{x}_n=x_n | \underline{t}=t)$ .

Omdat  $\underline{t}$  voldoende is voor  $\theta$  hangt deze uitdrukking niet van  $\theta$  af, maar alleen van  $t$ . Uit de definities van  $\underline{v}$  en van  $E(\underline{u} | \underline{t})$  (zie blz. 57) volgt nu dat  $\underline{v} = v(\underline{t})$ .

(ii)  $E \underline{v} = E E(\underline{u} | \underline{t}) = E \underline{u} = h(\theta)$  (zie(4.3.4))

(iii)  $\text{var } \underline{u} = E(\underline{u} - h(\theta))^2 = E(\underline{u} - \underline{v} + (\underline{v} - h(\theta)))^2 = E(\underline{u} - \underline{v})^2 + \text{var } \underline{v}$ ,

omdat  $E(\underline{u} - \underline{v})(\underline{v} - h(\theta)) = E(\underline{u} - \underline{v})\underline{v} = E E((\underline{u} - \underline{v})\underline{v} | \underline{t})$ , met

(7.3.6)  $E((\underline{u} - \underline{v})\underline{v} | \underline{t} = t) = v(t) E(\underline{u} - \underline{v} | \underline{t} = t) = v(t) \{E(\underline{u} | \underline{t} = t) - v(t)\} = 0$ .

Nu is dus  $\text{var } \underline{u} \geq \text{var } \underline{v}$ . Er geldt zelfs (zie stelling 4.2.6) dat  $\text{var } \underline{u} > \text{var } \underline{v}$ , tenzij  $P(\underline{u} = \underline{v}) = 1$ . Dit laatste betekent dat  $\underline{u}$  zelf al een functie van  $\underline{t}$  is.

Dan geldt natuurlijk (zie p. 57a of stelling 4.3.3)

$$\underline{v} = E(\underline{u} | \underline{t}) = E(g(\underline{t}) | \underline{t}) = g(\underline{t}) = \underline{u}.$$

Voorbeeld 7.3.15: Laat  $\underline{x}_1$  en  $\underline{x}_2$  onafhankelijk zijn en exponentieel verdeeld met  $E \underline{x} = \theta$ . Nu is  $\underline{t} = \underline{x}_1 + \underline{x}_2$  voldoende voor  $\theta$  en  $\underline{u} = \underline{x}_1$  is een zuivere schatter voor  $\theta$ , zodat  $\underline{v} = E(\underline{u} | \underline{t}) = \underline{t}/2$ . We hebben dus  $\text{var } \underline{v} = \theta^2/2$ , terwijl  $\text{var } \underline{u} = \theta^2$ .

Opgave 7.3.16: Bewijs dat  $E(\underline{x}_1 | \underline{x}_1 + \underline{x}_2 = t) = t/2$ , als  $\underline{x}_1$  en  $\underline{x}_2$  o.o. zijn en exponentieel verdeeld met dezelfde verwachting.

Opmerking 7.3.17: Als  $\underline{u} = u(\underline{x}_1, \dots, \underline{x}_n)$  een functie is van alle grootheden  $\underline{x}_1, \dots, \underline{x}_n$ , dan is de voorwaardelijke kansverdeling van  $\underline{u}$  gegeven  $\underline{t} = t$  geconcentreerd op het oppervlak  $t(\underline{x}_1, \dots, \underline{x}_n) = t$ . Dit soort kansverdelingen geeft aanleiding tot wiskundige moeilijkheden (zie opmerking 3.8.7). Voorwaardelijke verwachtingen van de vorm  $E(\underline{x}_1^2 + \underline{x}_2^2 | \underline{x}_1 + \underline{x}_2 = t)$  kunnen we met de door ons ingevoerde begrippen niet direkt berekenen (de uitkomst is  $2t^2/3$  - ga na).

Definitie 7.3.18: Een verzameling verdelingsfuncties  $\{F_{\underline{t}}(t; \theta); \theta \in \Omega\}$  heet *volledig*, als voor iedere (continue) functie  $v$  de volgende implicatie geldt

$$\{\forall_{\theta \in \Omega} [E_{\theta} v(\underline{t}) = 0]\} \Rightarrow \{\forall_{\theta \in \Omega} [P_{\theta}(v(\underline{t}) = 0) = 1]\}.$$

Hierbij geeft  $E_{\theta}$  en  $P_{\theta}$  aan dat de verwachting resp. de kans wordt uitgerekend met behulp van  $F(t; \theta)$ . Verder wordt aangenomen dat  $E_{\theta} v(\underline{t})$  inderdaad bestaat voor  $\theta \in \Omega$ .



Voorbeeld 7.3.19: De verzameling kansdichtheden  $f(t; \theta) = \theta e^{-\theta t}$  ( $t > 0$ ) met  $\theta \in (0, \infty)$  is volledig: als  $v: (0, \infty) \rightarrow \mathbb{R}$  continu is en als

$$E v(\underline{t}) = \theta \int_0^{\infty} v(t) e^{-\theta t} dt = 0$$

voor alle  $\theta \in (0, \infty)$ , dan is  $v(t) = 0$  voor alle  $t > 0$  o.g.v. de eenduidigheid van de Laplace-transformatie. Dus is  $P(v(\underline{t})=0)=1$ .

Voorbeeld 7.3.20: De verzameling verdelingen met

$$P(\underline{k}=k; \mu) = e^{-\mu} \frac{\mu^k}{k!} \quad (k=0, 1, \dots)$$

voor  $\mu \in (0, \infty)$  is volledig, immers als

$$E v(\underline{k}) = e^{-\mu} \sum_{k=0}^{\infty} v(k) \frac{\mu^k}{k!} = 0$$

voor alle  $\mu$  in een rechter-omgeving van  $\mu = 0$  dan is  $v(k) = 0$  voor  $k \in \{0, 1, \dots\}$  o.g.v. de eenduidigheidsstelling voor machtreeksen.

Stelling 7.3.21: Als  $\underline{t}$  voldoende is voor  $\theta$  ( $\theta \in \Omega$ ) en als de verzameling verdelingsfuncties  $F_{\underline{t}}(t; \theta)$  volledig is en als bovendien  $v(\underline{t})$  een zuivere schatter is voor  $h(\theta)$ , dan is  $v(\underline{t})$  de (unieke) nauwkeurigste zuivere schatter voor  $h(\theta)$ .

Bewijs: Omdat  $F_{\underline{t}}(t; \theta)$  ( $\theta \in \Omega$ ) volledig is geldt

$$E_{\theta} \{v_1(\underline{t}) - v_2(\underline{t})\} \equiv 0 \Rightarrow P_{\theta} (v_1(\underline{t})=v_2(\underline{t})) \equiv 1.$$

Er bestaat dus hoogstens één zuivere schatter voor  $h(\theta)$ , die een functie is van  $\underline{t}$ . Stel nu dat  $\underline{u}$  een zuivere schatter is voor  $h(\theta)$ , die geen functie is van  $\underline{t}$  (en dus ongelijk aan  $v(\underline{t})$ ), dan geldt wegens stelling 7.3.14 dat  $\text{var } \underline{u} > \text{var } v(\underline{t})$ , omdat nu  $E(\underline{u} | \underline{t}) = v(\underline{t})$ .

Voorbeeld 7.3.22: Zij  $\underline{k}_1, \underline{k}_2, \dots, \underline{k}_n$  een aselechte steekproef van  $\underline{k}$  met  $P(\underline{k}=k) = e^{-\mu} \frac{\mu^k}{k!}$  ( $k=0, 1, \dots; \mu > 0$ ). De grootte  $\underline{t} = \sum_{j=1}^n \underline{k}_j$  is voldoende voor  $\mu$  (vergelijk opmerking 7.3.12). Verder is  $\underline{t}/n$  een zuivere schatter voor  $\mu$ . Tenslotte is de verzameling verdelingsfuncties  $F_{\underline{t}}(t; \mu)$  volledig, immers als

$$E v(\underline{t}) = e^{-n\mu} \sum_{k=0}^{\infty} v(k) \frac{(n\mu)^k}{k!} = 0$$

voor alle  $\mu > 0$ , dan is  $v(k) = 0$  voor alle  $k \in \{0, 1, \dots\}$ . Op grond van stelling 7.3.21 is  $\underline{t}/n$  de nauwkeurigste zuivere schatter voor  $\mu$ . Dit is in overeenstemming met voorbeeld 7.1.19 (zie ook voorbeeld 7.3.20).

Opmerking 7.3.23: Het begrip voldoende is altijd gerelateerd aan het beschikbare waarnemingsmateriaal. Zo is in het bovenstaande voorbeeld  $\underline{k}_1 + \dots + \underline{k}_n$  voldoende t.a.v.  $(\underline{k}_1, \dots, \underline{k}_n)$ , maar niet t.a.v.  $(\underline{k}_1, \dots, \underline{k}_{n+1})$ .

## 8. Toetingstheorie

### 8.1 Algemene principes

We beginnen met een eenvoudig voorbeeld.

Voorbeeld 8.1.1: We hebben een geldstuk dat bij iedere worp  $K$  ("kruis") of  $M$  ("munt") oplevert. We vermoeden dat  $p := P(M) = \frac{1}{2}$  is en we willen dit vermoeden toetsen aan de hand van de uitkomsten van 100 worpen. Het ligt (ook gezien de resultaten bij de schattingstheorie; zie voorbeeld 7.3.2) voor de hand om het aantal keren munt als criterium te gebruiken. We noemen dit aantal  $k$ . Stel nu dat we als realisatie vinden  $k = 40$ . We kunnen dan als volgt redeneren. Onder de hypothese  $p = \frac{1}{2}$  lijkt de uitkomst  $k = 40$  tamelijk klein. We berekenen nu de kans op een zo kleine waarde of een nog kleinere:  $P(k \leq 40; p = \frac{1}{2}) \approx \Phi(-2) = 0,0228$ . We kunnen nu deze kans (te) klein vinden en de hypothese  $p = \frac{1}{2}$  verwerpen. Hierbij is het principe dat we niet geloven in het optreden van gebeurtenissen met heel kleine kansen. Wat in dit verband "klein" genoemd wordt is een kwestie van smaak - en van traditie. Het is natuurlijk altijd mogelijk dat een dergelijke gebeurtenis toch optreedt (opgetreden is); dit is een onvermijdbaar risico.

We geven nu een algemenere beschrijving van het toetsen van een hypothese.

Definitie 8.1.2: Zij  $F_n(x_1, \dots, x_n; \theta)$  de verdelingsfunctie van een stochastische vector  $\underline{x}_1, \dots, \underline{x}_n$ , waarbij  $\theta \in \Omega \subset \mathbb{R}^k$  een onbekende parameter is. Onder een *hypothese*  $H$  betreffende  $\theta$  verstaan we een uitspraak van de vorm  $\theta \in \Omega_0$  met  $\Omega_0 \subset \Omega$ . Als  $\Omega_0$  uit één punt bestaat, dan heet  $H$  *enkelvoudig*, anders *meervoudig*.

Definitie 8.1.3: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een steekproef met verdelingsfunctie  $F(x_1, \dots, x_n; \theta)$  ( $\theta \in \Omega$ ). Een *toets* voor de hypothese  $H_0: \theta \in \Omega_0$ , is een voorschrift dat voor iedere realisatie  $x_1, \dots, x_n$  aangeeft of  $H_0$  al of niet verworpen wordt. Met andere woorden: een toets is een splitsing van  $\mathbb{R}^n$  in twee delen:  $\mathbb{R}^n = R \cup A$ , met  $R \cap A = \emptyset$ , waarbij  $H_0$  verworpen wordt als  $(x_1, \dots, x_n) \in R$  en  $H_0$  niet verworpen wordt als  $(x_1, \dots, x_n) \in A = R^*$ . De hypothese  $H_0$  heet ook wel *nulhypothese* en de hypothese  $H_1$ , gedefinieerd door  $H_1: \theta \in \Omega_1 := \Omega_0^*$  (t.o.v.  $\Omega$ ) heet de *alternatieve hypothese*. Het gebied  $R$  heet het *kritieke gebied*,  $A$  heet wel het *aanvaardingsgebied* ( $R$  van "reject",  $A$  van "accept").

Opmerking 8.1.4: Bij een enkelvoudige hypothese van de vorm  $\theta = \theta_0$  worden kansen dikwijls als volgt genoteerd:  $P((\underline{x}_1, \dots, \underline{x}_n) \in R; \theta_0)$ , om aan te geven dat de betreffende kans wordt uitgerekend onder de aanname dat  $\theta = \theta_0$  is, dus met de verdelingsfunctie  $F(x_1, \dots, x_n; \theta_0)$ .

Bij het toetsen van een hypothese kunnen twee fouten optreden: we kunnen  $H_0$  verwerpen terwijl deze hypothese juist is en we kunnen  $H_0$  niet verwerpen, terwijl de hypothese onjuist is. Deze fouten worden resp. *fout van de eerste soort* en *fout van de tweede soort* genoemd. Toetsen worden i.h.a. zó geconstrueerd, dat de kans op een fout van de eerste soort niet boven een gegeven grens  $\alpha$ , de *onbetrouwbaarheidsdrempel*, komt. Veel gebruikte waarden van  $\alpha$  zijn 0,05 en 0,01. Men probeert dan onder deze restrictie de kans op een fout van de tweede soort zo klein mogelijk te maken, d.w.z. de kans op verwerpen van  $H_0$  voor waarden van  $\theta$  in  $\Omega_1$  zo groot mogelijk te maken.

Definitie 8.1.5: Zij  $R$  het kritieke gebied voor een toets van de nulhypothese  $H_0: \theta \in \Omega_0$  tegen het alternatief  $H_1: \theta \in \Omega_1$ . Dan heet

$$\alpha_0 := \sup_{\theta \in \Omega_0} P((\underline{x}_1, \dots, \underline{x}_n) \in R; \theta) \quad \text{de onbetrouwbaarheid}$$

van de toets. Voor  $\theta \in \Omega_1$  heet de functie  $\beta$ , gedefinieerd door

$$\beta(\theta) := P((\underline{x}_1, \dots, \underline{x}_n) \in R; \theta), \quad \text{het onderscheidingsvermogen}$$

van de toets. (We eisen dat  $\alpha_0 \leq \alpha$ , de onbetrouwbaarheidsdrempel, terwijl we zo mogelijk  $\alpha_0 = \alpha$  kiezen; dit kan i.h.a. als  $(\underline{x}_1, \dots, \underline{x}_n)$  een absoluut continue verdeling heeft; bij diskrete verdelingen kiezen we  $\alpha_0$  zo groot mogelijk, maar  $\leq \alpha$ ).

Opmerking 8.1.6: In de meeste gevallen wordt het kritieke gebied  $R$  bepaald door de waarden van een statistische grootte  $t = t(x_1, \dots, x_n)$ , waarbij  $t(\underline{x}_1, \dots, \underline{x}_n)$  bijvoorbeeld een schatter is voor  $\theta$  (vergelijk voorbeeld 8.1.1). De functie  $t$  heet in dit verband een *toetsingsgrootte*. Het kritieke gebied  $R$  heeft dan de gedaante

$$(8.1.1) \quad R = R(\alpha, n) = \{ (x_1, \dots, x_n) \mid t(x_1, \dots, x_n) \in K \}$$

met  $K \subset \mathbb{R}$ . De verzameling  $K$  (dikwijls het complement van een interval) wordt nu ook wel *kritiek gebied* (voor  $t$ ) genoemd.

We illustreren nu de boven ingevoerde begrippen aan de hand van een voorbeeld.

Voorbeeld 8.1.7: Zij  $x_1, x_2, \dots, x_n$  de realisatie van een aselechte steekproef van  $\underline{x}$  met

$$f_{\underline{x}}(x) = \frac{1}{\sqrt{2\pi}} \exp\{-\frac{1}{2}(x-\theta)^2\} \quad (\theta \in \mathbb{R}).$$

We toetsen de enkelvoudige hypothese  $H_0: \theta = \theta_0$  tegen het alternatief  $H_1: \theta \neq \theta_0$  (d.w.z.  $\Omega_0 = \{\theta_0\}$  en  $\Omega_1 = \mathbb{R} \setminus \{\theta_0\}$ ). Het ligt voor de hand om  $\frac{1}{n}(x_1 + \dots + x_n)$  (of een functie daarvan) als toetsingsgrootte te gebruiken, d.w.z. om een kritiek gebied te gebruiken van de vorm

$$R = \{(x_1, \dots, x_n) \mid (x_1 + \dots + x_n)/n \in K\}$$

met  $P((\underline{x}_1, \dots, \underline{x}_n) \in R; \theta_0) = \alpha = 0,05$ . Door deze eisen ligt de toets nog allerm minst vast. We schrijven  $t = t(x_1, \dots, x_n) = (x_1 + \dots + x_n)/n$  en beschouwen drie mogelijkheden voor  $K$  (en dus voor  $R$ ):

(i)  $K_1 = \{t \mid |t - \theta_0| \geq t_1\}$  met  $t_1$  zó dat

$$P((\underline{x}_1, \dots, \underline{x}_n) \in R_1; \theta_0) = P(|\underline{t} - \theta_0| \geq t_1; \theta_0) = \alpha = 0,05.$$

Hieruit volgt (ga na), dat  $t_1 = 1,96/\sqrt{n}$ , zodat

$$R_1 = \{(x_1, \dots, x_n) \mid \left| \frac{x_1 + \dots + x_n}{n} - \theta_0 \right| \geq 1,96/\sqrt{n}\}.$$

(ii)  $K_2 = \{t \mid t \geq \theta_0 + t_2\}$  met  $t_2$  zó dat

$$P((\underline{x}_1, \dots, \underline{x}_n) \in R_2; \theta_0) = P(\underline{t} \geq \theta_0 + t_2; \theta_0) = 0,05.$$

We vinden dan  $t_2 = 1,645/\sqrt{n}$ , d.w.z.

$$R_2 = \{(x_1, \dots, x_n) \mid \frac{x_1 + \dots + x_n}{n} \geq \theta_0 + 1,645/\sqrt{n}\}.$$


(iii)  $K_3 = \{t \mid |t - \theta_0| \leq t_3\}$  met  $t_3$  zó dat

$$P((\underline{x}_1, \dots, \underline{x}_n) \in R_3; \theta_0) = P(|\underline{t} - \theta_0| \leq t_3; \theta_0) = 0,05.$$

We vinden  $t_3 = 0,063/\sqrt{n}$ , d.w.z.

$$R_3 = \{(x_1, \dots, x_n) \mid \left| \frac{x_1 + \dots + x_n}{n} - \theta_0 \right| \leq 0,063/\sqrt{n}\}.$$

De kans op een fout van de eerste soort is voor elk van de drie toetsen 0,05. Het verschil zit in het onderscheidingsvermogen (zie definitie 8.1.5). In het onderstaande plaatje is het onderscheidingsvermogen voor elk van de toetsen geschetst (en aangegeven met  $\beta_1$ ,  $\beta_2$  en  $\beta_3$ ) als functie van  $\theta$ .



Het is duidelijk dat de derde toets slecht is: de kans op verwerpen van  $H_0$  is hoogstens  $\alpha$  (voor  $\theta = \theta_0$ ) en neemt bovendien af naar mate  $\theta$  verder van  $\theta_0$  verwijderd is. De eerste toets lijkt het meest redelijk: de kans op verwerpen van  $H_0$  neemt (snel) toe als  $\theta$  verder van  $\theta_0$  ligt, zowel links als rechts. Bij de tweede toets is de kans op verwerpen van  $H_0$  klein bij waarden van  $\theta$  kleiner dan  $\theta_0$ , maar  $\beta_2(\theta) > \beta_1(\theta)$  als  $\theta > \theta_0$ . In sommige gevallen verdient de toets met  $R_2$  daarom de voorkeur boven die met  $R_1$ . We komen hier later op terug, als we zgn. eenzijdige toetsen bespreken.

Uit dit voorbeeld blijkt dat we pas over de "beste" toets kunnen praten, in de zin van de toets met het grootste onderscheidingsvermogen, als we van te voren hebben afgesproken, voor welke  $\theta$  het onderscheidingsvermogen groot moet zijn. Gezien definitie 8.1.5 komt dit neer op het kiezen van de nulhypothese en de alternatieve hypothese. Ook hierdoor ligt een toets echter niet vast.

Opgave: Geef een formule voor het onderscheidingsvermogen van de toets in voorbeeld 8.1.7 (i).

Definitie 8.1.8: Een toets  $T^*$  voor de hypothese  $H_0: \theta \in \Omega_0$  tegen het alternatief  $H_1: \theta \in \Omega_1$  met onbetrouwbaarheid  $\alpha_0$  heet *uniform meest onderscheidend*, als

$$\beta^*(\theta) \geq \beta(\theta) \quad (\theta \in \Omega_1)$$

voor iedere toets  $T$  met onbetrouwbaarheid hoogstens  $\alpha_0$  (hierbij hebben we het onderscheidingsvermogen van  $T^*$  en  $T$  aangegeven met resp.  $\beta^*$  en  $\beta$ ).

Definitie 8.1.9: Een toets voor de hypothese  $H_0: \theta \in \Omega_0$  tegen  $H_1: \theta \in \Omega_1$  heet *zuiver* (met onbetrouwbaarheid  $\alpha_0$ ) als

$$\alpha_0 = \sup_{\theta \in \Omega_0} P((\underline{x}_1, \dots, \underline{x}_n) \in R; \theta) \leq \inf_{\theta \in \Omega_1} P((\underline{x}_1, \dots, \underline{x}_n) \in R; \theta).$$

Definitie 8.1.10: Een toets heet (uniform) meest onderscheidend zuiver, als hij onder de zuivere toetsen (uniform) meest onderscheidend is, d.w.z. (uniform) het grootste onderscheidingsvermogen heeft.

Opmerking 8.1.11: De toets onder (i) in voorbeeld 8.1.7 is uniform meest onderscheidend zuiver voor de nulhypothese  $\theta = \theta_0$  tegen het alternatief  $\theta \neq \theta_0$  (geen bewijs).

Voor enkelvoudige hypothesen hebben we

Stelling 8.1.12 (Lemma van Neyman en Pearson): Zij  $(x_1, \dots, x_n)$  de realisatie van een steekproef  $(\underline{x}_1, \dots, \underline{x}_n)$  met aannemelijkheidsfunctie  $L(x_1, \dots, x_n; \theta)$  (zie definitie 7.2.1) met  $\theta \in \{\theta_0, \theta_1\}$ . De meest onderscheidende toets voor de hypothese  $H_0: \theta = \theta_0$  tegen het alternatief  $H_1: \theta = \theta_1$  wordt verkregen door een kritiek gebied  $R$  te nemen van de vorm

$$(8.1.2) \quad R = \{(x_1, \dots, x_n) \mid \frac{L(x_1, \dots, x_n; \theta_0)}{L(x_1, \dots, x_n; \theta_1)} \leq k\}.$$

(Voor een toets met onbetrouwbaarheidsdrempel  $\alpha$  wordt  $k$  zó gekozen dat  $\alpha_0 \leq \alpha$  en zo groot mogelijk)

Bewijs: We beschouwen het geval, waar  $(\underline{x}_1, \dots, \underline{x}_n)$  een absoluut continue verdeling heeft met dichtheid (in vectornotatie)  $L(x; \theta)$ . Zij  $R'$  het kritieke gebied van een willekeurige andere toets (met dezelfde onbetrouw-

baarheid). We schrijven

$$R = U + D; R' = V + D$$

met  $D = RR'$ ,  $U = R(R')^*$  en  $V = R^*R'$ . Dan geldt  $\alpha = \int_R L(x; \theta_0) dx$  en  $\alpha = \int_{R'} L(x; \theta_0) dx$ , dus

$$(8.1.3) \quad \int_U L(x; \theta_0) dx = \int_V L(x; \theta_0) dx.$$

Omdat op  $R$  en dus op  $U$  geldt dat  $L(x; \theta_0) \leq kL(x; \theta_1)$  en op  $V$  dat  $L(x; \theta_0) > kL(x; \theta_1)$ , hebben we

$$(8.1.4) \quad \int_U L(x; \theta_0) dx \leq k \int_U L(x; \theta_1) dx,$$

$$(8.1.5) \quad \int_V L(x; \theta_0) dx \geq k \int_V L(x; \theta_1) dx.$$

Uit (8.1.3) t.m. (8.1.5) volgt dat  $\int_U L(x; \theta_0) dx \geq \int_V L(x; \theta_1) dx$  en dus dat

$$\int_R L(x; \theta_1) dx \geq \int_{R'} L(x; \theta_1) dx,$$

d.w.z.  $\beta(\theta_1) \geq \beta'(\theta_1)$ , dus de toets met  $R$  is minstens even onderscheidend als die met  $R'$ .

Opgave 8.1.13: Bewijs stelling 8.1.12 voor diskrete  $(\underline{x}_1, \dots, \underline{x}_n)$ .

Opmerking 8.1.14: Het quotient  $L(x_1, \dots, x_n; \theta_0) / L(x_1, \dots, x_n; \theta_1)$  wordt *aannemelijkheidsquotient* genoemd (engels: likelihood ratio); de bijbehorende toets en toetsen van een verwant type heten *likelihood-ratio-toetsen*.

Opmerking 8.1.15: Punten met  $L(x_1, \dots, x_n; \theta_0) = 0$  komen in  $R$  terecht; punten met  $L(x_1, \dots, x_n; \theta_1) = 0$  (en  $L(x_1, \dots, x_n; \theta_0) \neq 0$ ) in  $R^*$ .



Opgave 8.1.16: De toets onder (ii) in voorbeeld 8.1.7 is uniform meest onderscheidend (en zuiver) voor  $H_0: \theta = \theta_0$  tegen  $H_1: \theta > \theta_0$ . Bewijs dit door toepassing van stelling 8.1.12 met (telkens) één vaste  $\theta_1 > \theta_0$ .

## 8.2 Constructie van toetsen

In veel gevallen worden toetsen "bedacht" door uit te gaan van een redelijke toetsingsgrootte, zoals in de voorbeelden 8.1.1 en 8.1.7.

We geven nu een aantal voorbeelden van toetsen die veel worden gebruikt en die op zo'n "redelijke" toetsingsgrootte berusten.

Voorbeeld 8.2.1: Zij  $x_1, \dots, x_n$  een realisatie van een aselechte steekproef uit een normale verdeling met verwachting  $\mu$  en variantie  $\sigma^2$ .

We willen toetsen  $H_0: \mu = \mu_0$  tegen  $H_1: \mu \neq \mu_0$ . We onderscheiden twee gevallen:

A:  $\sigma^2$  bekend. Dan zijn we terug bij voorbeeld 8.1.7: we gebruiken als toetsingsgrootte  $\underline{x}_1 + \dots + \underline{x}_n$  of liever de grootte

$$(8.2.1) \quad \underline{u} = \frac{\underline{x}_1 + \dots + \underline{x}_n - n\mu_0}{\sigma\sqrt{n}} = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n},$$

die onder de hypothese  $H_0$  normaal verdeeld is met  $E\underline{u} = 0$  en  $\text{var } \underline{u} = 1$ . Bij voorgeschreven  $\alpha$  verwerpen we nu  $H_0$ , als  $u = \frac{\bar{x} - \mu_0}{\sigma} \sqrt{n}$  zó is dat

$$(8.2.2) \quad P(\underline{u} \geq u; \mu_0) \leq \alpha/2$$

of zó dat

$$(8.2.3) \quad P(\underline{u} \leq -u; \mu_0) \leq \alpha/2,$$

d.w.z. als  $u \geq u_{\alpha/2}$  of  $u \leq -u_{\alpha/2}$ , waar  $u_{\gamma}$  gedefinieerd is door

$$(8.2.4) \quad 1 - \Phi(u_{\gamma}) = \gamma.$$

B:  $\sigma^2$  onbekend. Dan vervangen we  $\sigma^2$  in (8.2.1) door een goede schatter:

$\underline{s}^2 = (n-1)^{-1} \sum_1^n (x_j - \bar{x})^2$ . De toetsingsgrootte wordt dan

$$(8.2.5) \quad \underline{t} = \frac{\bar{x} - \mu_0}{\underline{s}} \sqrt{n}.$$

Nu zijn (zie Appendix 4)  $\bar{x}$  en  $s^2$  (en dus ook  $\underline{x}$  en  $\underline{s}$ ) onafhankelijk, zodat  $\underline{t}$  in (8.2.5) onder  $H_0$  een student-verdeling heeft met  $n-1$  vrijheidsgraden (vergelijk Appendix 2, blz. 80 en opgave 8.2.3). We verwerpen nu  $H_0$  als  $\underline{t}$  zó is dat

$$P(\underline{t} \geq t; \mu_0) \leq \alpha/2$$

of zó dat

$$P(\underline{t} \leq t; \mu_0) \leq \alpha/2,$$

d.w.z. als  $\underline{t} \geq t_{\alpha/2}$  of  $\underline{t} \leq -t_{\alpha/2}$  met

$$(8.2.6) \quad \int_{t_\gamma}^{\infty} f_{t_{n-1}}(x) dx = \gamma.$$

Opmerking 8.2.2: De bovengenoemde toetsen zijn *tweezijdig*: we verwerpen  $H_0$  zowel bij grote waarden van  $u$  en  $t$  als bij kleine. We kunnen ook *eenzijdig* toetsen. We toetsen dan  $H_0: \mu = \mu_0$  tegen  $H_1: \mu > \mu_0$  of ook wel  $H_0: \mu \leq \mu_0$  tegen  $\mu > \mu_0$ . Bij deze *rechts-eenzijdige* toets verwerpen we  $H_0$  alleen bij grote waarden van  $u$  of  $t$ . In plaats van beide *overschrijdingskansen* (8.2.2) en (8.2.3) beschouwen we alleen de *rechter overschrijdingskans*  $P(\underline{u} \geq u; \mu_0)$  en we verwerpen als  $u \geq u_\alpha$ , d.w.z. als

$$P(\underline{u} \geq u; \mu_0) \leq \alpha.$$

Analoog kunnen we *links-eenzijdig* toetsen. Eenzijdig toetsen doen we in die gevallen waar we alleen willen verwerpen (en dus ingrijpen of protesteren) bij een steekproefresultaat dat naar één bepaalde kant t.o.v. de nulhypothese afwijkt, bijvoorbeeld als we een partij goederen niet willen kopen als een steekproef te veel (vergeleken met een opgegeven percentage) defecten bevat.

Opgave 8.2.3: Ga na dat  $\sum_1^n (\underline{x}_j - \bar{x})^2 / \sigma^2$  een  $\chi_{n-1}^2$ -verdeling heeft, als  $\underline{x}_1, \dots, \underline{x}_n$  o.o. zijn en  $N(\mu, \sigma^2)$ -verdeeld.

Voorbeeld 8.2.4: Zij  $x_1, \dots, x_n$  een realisatie van een aselechte steekproef van  $\underline{x}$  met een  $N(\mu, \sigma^2)$ -verdeling. We willen toetsen  $H_0: \sigma^2 = \sigma_0^2$  tegen  $H_1: \sigma^2 \neq \sigma_0^2$ .

A. Als  $\mu$  bekend is, kunnen we als toetingsgrootheid nemen

$$(8.2.7) \quad \chi_n^2 = \sum_1^n (\underline{x}_j - \mu)^2 / \sigma_0^2.$$

Het is duidelijk dat  $\chi_n^2$  onder  $H_0$  een  $\chi_n^2$ -verdeling heeft. We verwerpen  $H_0$  dan als  $\chi^2$  zo is dat

$$P(\chi_n^2 \geq \chi^2; \sigma_0^2) \leq \alpha/2$$

of zó dat

$$P(\chi_n^2 \leq \chi^2; \sigma_0^2) \leq \alpha/2,$$

d.w.z. als  $\chi^2 \geq \chi_{\alpha/2}^2$  of  $\chi^2 \leq \chi_{1-\alpha/2}^2$ , waarbij  $\chi_\gamma^2$  gedefinieerd is in analogie met (8.2.4) en (8.2.6).

B. Als  $\mu$  onbekend is, kunnen we dezelfde toets gebruiken, nu met

$$(8.2.7') \quad \chi_{n-1}^2 = \sum_1^n (\underline{x}_j - \bar{\underline{x}})^2 / \sigma_0^2.$$

Deze grootheid is onder  $H_0$   $\chi_{n-1}^2$ -verdeeld (zie opgave 8.2.3).

De volgende voorbeelden hebben betrekking op twee steekproeven.

Voorbeeld 8.2.5:  $x_1, \dots, x_m$  en  $y_1, \dots, y_n$  zijn realisaties van twee onafhankelijke aselechte steekproeven van  $\underline{x}$  en  $\underline{y}$  die resp.  $N(\mu, \sigma_1^2)$ - en  $N(\lambda, \sigma_2^2)$ -verdeeld zijn. We toetsen  $H_0: \lambda = \mu$  tegen  $H_1: \lambda \neq \mu$ .

A:  $\sigma_1^2$  en  $\sigma_2^2$  bekend. Nu is  $(\bar{\underline{x}} - \bar{\underline{y}}) \left( \frac{mn}{2n\sigma_1^2 + m\sigma_2^2} \right)^{\frac{1}{2}}$   $N(0, 1)$ -verdeeld (onder  $H_0$ ).

Als  $\sigma_1 = \sigma_2 = \sigma$  wordt dit

$$\frac{\bar{\underline{x}} - \bar{\underline{y}}}{\sigma} \left( \frac{mn}{m+n} \right)^{\frac{1}{2}}.$$

B:  $\sigma_1^2 = \sigma_2^2 = \sigma^2$  onbekend. We kunnen nu de, (onder  $H_0$ )  $t_{m+n-2}$ -verdeelde, toetsingsgrootheid

$$(8.2.8) \quad \underline{t} = \frac{\bar{x} - \bar{y}}{\underline{s}} \left( \frac{mn}{m+n} \right)^{\frac{1}{2}}$$

gebruiken, waarbij  $\underline{s}^2 = \frac{1}{m+n-2} \left\{ \sum_1^m (\underline{x}_j - \bar{x})^2 + \sum_1^n (\underline{y}_k - \bar{y})^2 \right\}$ .

Opmerking: Als  $m = n$  en als de paren  $(\underline{x}_j, \underline{y}_j)$  o.o. zijn en simultaan normaal verdeeld, dan passen we de toets uit voorbeeld 8.2.1 toe op de *verschillen*

$$\underline{x}_1 - \underline{y}_1, \dots, \underline{x}_n - \underline{y}_n.$$

Voorbeeld 8.2.6:  $x_1, \dots, x_m$  en  $y_1, \dots, y_n$  zijn aselechte steekproeven van  $\underline{x}$  en  $\underline{y}$ , waarbij  $\underline{x}$  en  $\underline{y}$  o.o. zijn en resp.  $N(\mu_1, \sigma_1^2)$ -en  $N(\mu_2, \sigma_2^2)$ -verdeeld. We toetsen  $H_0: \sigma_1^2 = \sigma_2^2$  tegen  $H_1: \sigma_1^2 \neq \sigma_2^2$ .

A.  $\mu_1$  en  $\mu_2$  bekend. Als toetsingsgrootheid ligt voor de hand

$$(8.2.9) \quad \underline{F} = \frac{\frac{s^2}{2} 0,1}{\frac{s^2}{2} 0,2},$$

met  $\frac{s^2}{2} 0,1 = \frac{1}{m} \sum_1^m (\underline{x}_j - \mu_1)^2$  en  $\frac{s^2}{2} 0,2 = \frac{1}{n} \sum_1^n (\underline{y}_k - \mu_2)^2$ . Onder  $H_0$  heeft  $\underline{F}$  een  $F_{m,n}$ -verdeling (zie appendix 2, blz. 80).

B.  $\mu_1$  en  $\mu_2$  onbekend. We vervangen nu  $\mu_1$  en  $\mu_2$  door hun schatters en vinden

$$(8.2.10) \quad \underline{F} = \frac{\frac{s_1^2}{2}}{\frac{s_2^2}{2}},$$

met  $\frac{s_1^2}{2} = \frac{1}{m-1} \sum_1^m (\underline{x}_j - \bar{x})^2$  en  $\frac{s_2^2}{2} = \frac{1}{n-1} \sum_1^n (\underline{y}_j - \bar{y})^2$ . De grootheid  $\underline{F}$  in (8.2.10) heeft een  $F_{m-1, n-1}$ -verdeling (onder  $H_0$ ).

Opmerking 8.2.7: De toetsingsgrootheden in de bovenstaande voorbeelden kunnen natuurlijk zowel voor éénzijdige als voor tweezijdige toetsen gebruikt worden.

In de volgende definitie wordt een procedure gegeven om toetsen te construeren. Alle hierboven behandelde toetsingsgrootheden kunnen met deze procedure gevonden worden.

Definitie 8.2.8: Zij  $x_1, x_2, \dots, x_n$  een steekproef uit een verdeling met  
 likelihood functie  $L(x_1, \dots, x_n; \theta)$ . De (gegeneraliseerde) *likelihood-*  
*ratio-toets* met onbetrouwbaarheidsdrempel  $\alpha$  voor de hypothese  $H_0: \theta \in \Omega_0$   
 tegen  $H_1: \theta \in \Omega_1 = \Omega_0^*$  is de toets gebaseerd op het volgende kritieke  
 gebied  $R$ . We definiëren eerst het *aannemelijkheidsquotient (likelihoodratio)*  
 $\lambda$  door

$$(8.2.11) \quad \lambda(x_1, \dots, x_n) = \frac{\sup_{\theta \in \Omega_0} L(x_1, \dots, x_n; \theta)}{\sup_{\theta \in \Omega} L(x_1, \dots, x_n; \theta)}.$$

Vervolgens definiëren we het kritieke gebied  $R$  door

$$(8.2.12) \quad R = \{(x_1, \dots, x_n) \mid \lambda(x_1, \dots, x_n) \leq k(\alpha)\},$$

waarbij  $k(\alpha)$  vast ligt door de eis dat  $\sup_{\theta \in \Omega_0} P((x_1, \dots, x_n) \in R; \theta)$  zo groot mogelijk  
 is, maar  $\leq \alpha$ .

Het is duidelijk dat  $0 \leq \lambda \leq 1$ . Het idee achter deze procedure, die  
 verwant is aan het maximum likelihood principe, is dat  $\lambda$  i.h.a. groot  
 zal zijn (dicht bij 1 of gelijk aan 1) als de werkelijke waarde van  $\theta$   
 in  $\Omega_0$  ligt, d.w.z. als  $H_0$  waar is.

Opmerking 8.2.9: Een iets algemenere toets ontstaat als we  $\lambda$  vervangen  
 door  $\lambda_1$  gedefinieerd door

$$\lambda_1(x_1, \dots, x_n) = \frac{\sup_{\theta \in \Omega_0} L(x_1, \dots, x_n; \theta)}{\sup_{\theta \in \Omega_1} L(x_1, \dots, x_n; \theta)}.$$

Deze toets is een echte generalisatie van de toets in stelling 8.1.12. Hij  
 gaat hier in over als  $H_0$  en  $H_1$  enkelvoudig zijn, d.w.z. als  $\Omega_0 = \{\theta_0\}$   
 en  $\Omega_1 = \{\theta_1\}$ .

Voorbeeld 8.2.10: Zij  $x_1, \dots, x_n$  de realisatie van een aselechte steekproef  
 van  $\underline{x}$  met

$$f_{\underline{x}}(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left\{-\frac{1}{2\sigma^2}(x-\mu)^2\right\}.$$

We bepalen de likelihood-ratio-toets voor de hypothese  $H_0: \mu = \mu_0$  tegen het alternatief  $H_1: \mu \neq \mu_0$  met onbetrouwbaarheid  $\alpha$ . We bepalen eerst  $\lambda(x_1, \dots, x_n)$ ; we hebben  $\Omega = \{(\mu, \sigma^2) \mid \mu \in \mathbb{R}, \sigma^2 > 0\}$ ,  $\Omega_0 = \{(\mu, \sigma^2) \mid \mu = \mu_0, \sigma^2 > 0\}$  en dus (zie opgave 7.3.10 en voorbeeld 7.3.11), met  $\theta = (\mu, \sigma^2)$ ,

$$\begin{aligned} \sup_{\theta \in \Omega_0} L(x_1, \dots, x_n; \theta) &= \max_{\sigma^2} \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_1^n (x_j - \mu_0)^2\right\} = \\ &= \left(\frac{1}{2\pi\hat{\sigma}_0^2}\right)^{n/2} \exp\left\{-\frac{1}{2\hat{\sigma}_0^2} \sum_1^n (x_j - \mu_0)^2\right\}, \end{aligned}$$

met  $\hat{\sigma}_0^2 = \frac{1}{n} \sum_1^n (x_j - \mu_0)^2$ , terwijl

$$\begin{aligned} \sup_{\theta \in \Omega} L(x_1, \dots, x_n; \theta) &= \max_{\mu, \sigma^2} \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left\{-\frac{1}{2\sigma^2} \sum_1^n (x_j - \mu)^2\right\} = \\ &= \left(\frac{1}{2\pi\hat{\sigma}^2}\right)^{n/2} \exp\left\{-\frac{1}{2\hat{\sigma}^2} \sum_1^n (x_j - \bar{x})^2\right\} \end{aligned}$$

met  $\hat{\sigma}^2 = \frac{1}{n} \sum_1^n (x_j - \bar{x})^2$ . Voor  $\lambda$  vinden we dus

$$\lambda(x_1, \dots, x_n) = \frac{\hat{\sigma}_0^2}{\hat{\sigma}^2} \frac{n/2}{1 + (\hat{\sigma}_0^2 - \hat{\sigma}^2)/\hat{\sigma}^2} = \frac{1}{\left\{1 + \frac{(\bar{x} - \mu_0)^2}{\hat{\sigma}^2}\right\}^{n/2}}.$$

Nu is  $\lambda$  dus gelijk aan (zie (8.2.5))

$$\lambda(x_1, \dots, x_n) = \left\{ \frac{1}{1+t^2/(n-1)} \right\}^{n/2},$$

zodat (ga na) het kritieke gebied (8.2.11) de volgende vorm krijgt:

$$R = \{(x_1, \dots, x_n) \mid t^2 \geq c(\alpha)\},$$

met  $t = \frac{(\bar{x} - \mu_0)\sqrt{n}}{s}$ , zodat  $\underline{t} = \frac{(\bar{x} - \mu_0)\sqrt{n}}{s}$ , een  $t_{n-1}$ -verdeling heeft (zie App. 4).

Het kritieke gebied  $K$  voor  $t$  wordt dus

$$K = \{t \mid |t| \geq t_{\alpha/2}\},$$

d.w.z. we vinden de toets van voorbeeld 8.2.1 B terug.

Voorbeeld 8.2.11: In de situatie van voorbeeld 8.2.10 toetsen we nu de nulhypothese  $H_0: \sigma^2 = \sigma_0^2$  tegen  $H_1: \sigma^2 \neq \sigma_0^2$ . We vinden nu met

$$\Omega_0 = \{(\mu, \sigma^2) \mid \mu \in \mathbb{R}, \sigma^2 = \sigma_0^2\}$$

$$\sup_{\theta \in \Omega_0} L(x_1, \dots, x_n; \theta) = \left(\frac{1}{2\pi\sigma_0^2}\right)^{n/2} \exp\left\{-\frac{1}{2\sigma_0^2} \sum_{j=1}^n (x_j - \bar{x})^2\right\}$$

$$\sup_{\theta \in \Omega} L(x_1, \dots, x_n; \theta) = \left(\frac{1}{2\pi\hat{\sigma}^2}\right)^{n/2} \exp\left\{-\frac{1}{2\hat{\sigma}^2} \sum_{j=1}^n (x_j - \bar{x})^2\right\},$$

met weer  $\hat{\sigma}^2 = \frac{1}{n} \sum_{j=1}^n (x_j - \bar{x})^2$ . We vinden dus voor  $\lambda$  de uitdrukking (ga na)

$$\lambda(x_1, \dots, x_n) = e^{n/2 \left\{ \frac{\hat{\sigma}^2}{\sigma_0^2} e^{-\hat{\sigma}^2/\sigma_0^2} - 1 \right\}}$$

Het kritieke gebied wordt nu van de vorm

$$(8.2.13) \quad R = \{(x_1, \dots, x_n) \mid \frac{\hat{\sigma}^2}{\sigma_0^2} e^{-\hat{\sigma}^2/\sigma_0^2} \leq c(\alpha)\},$$

met  $c(\alpha)$  zó dat  $P((x_1, \dots, x_n) \in R; \sigma_0^2) = \alpha$ . Als toetsingsgrootheid kunnen we dus gebruiken  $\frac{\hat{\sigma}^2}{\sigma_0^2}$  of

$$\chi^2 = \frac{n\hat{\sigma}^2}{\sigma_0^2} = \frac{1}{\sigma_0^2} \sum_{j=1}^n (x_j - \bar{x})^2.$$

Het kritieke gebied  $K$  voor  $\chi^2$  behorende bij deze likelihood-ratio-toets wordt nu gegeven door

$$(8.2.14) \quad K = \{\chi^2 \mid \chi^2 \leq \chi_1^2 \text{ of } \chi^2 \geq \chi_2^2\},$$

waarbij  $\chi_1^2$  en  $\chi_2^2$  voldoen aan  $\chi^2 e^{-\chi^2/n} = nc(\alpha)$ , terwijl  $c(\alpha)$  zó is dat

$$P(\chi_1^2 < \chi^2 < \chi_2^2) = 1 - \alpha.$$

De grootheid  $\chi^2$  is dezelfde als die in voorbeeld 8.2.4 B en heeft dus een  $\chi_{n-1}^2$ -verdeling. Omdat de grenzen  $\chi_1^2$  en  $\chi_2^2$  zoals boven gedefinieerd niet zo makkelijk te berekenen zijn, gebruikt men in de praktijk toch vaak

de toets uit voorbeeld 8.2.4 B, d.w.z. men gebruikt een kritiek gebied van de vorm (8.2.14), maar met  $\chi_1^2$  en  $\chi_2^2$  z6 dat

$$P(\underline{\chi}^2 \leq \chi_1^2) = P(\underline{\chi}^2 \geq \chi_2^2) = \alpha/2.$$

Dit is dan geen echte likelihood-ratio-toets.

Opmerking 8.2.12: In voorbeeld 8.2.10 hangt de kansverdeling van  $\underline{t}$  niet van  $\sigma^2$  af; in voorbeeld 8.2.11 hangt de kansverdeling van  $\underline{\chi}^2$  niet van  $\mu$  af (vergelijk definitie 8.2.8).

Opgave 8.2.13:  $x_1, \dots, x_{100}$  is de realisatie van een aselechte steekproef uit een normale verdeling. Men vindt  $\bar{x} = 4,27$  en  $s^2 = 0,975$ .

- a. Toets  $H_0: \mu = 4,00$  tegen  $H_1: \mu \neq 4,00$  ( $\alpha = 0,01$ )
- b. Toets  $H_0: \sigma^2 = 0,810$  tegen  $H_1: \sigma^2 \neq 0,810$  ( $\alpha = 0,01$ ) en bereken het onderscheidingsvermogen van deze toets voor  $\sigma = 1,00$ .

Opgave 8.2.14: Laat zien dat de toetsen in voorbeeld 8.2.1 A en in voorbeeld 8.2.5 A en B likelihood-ratio-toetsen zijn.

Voorbeeld 8.2.15: Zij  $x_1, \dots, x_n$  de realisatie van een aselechte steekproef van  $\underline{x}$  met

$$P(\underline{x}=0) = 1-p, \quad P(\underline{x}=1) = p.$$

We construeren de likelihood-ratio-toets voor de nulhypothese  $H_0: p=p_0$  tegen  $H_1: p \neq p_0$ . We vinden gemakkelijk (ga na) dat

$$(8.2.15) \quad \lambda(x_1, \dots, x_n) = \frac{p_0^k (1-p_0)^{n-k}}{\binom{k}{n}^k (1-\frac{k}{n})^{n-k}},$$

met  $k = x_1 + \dots + x_n$ . Het kritieke gebied is dus

$$R = \{(x_1, \dots, x_n) \mid (\frac{np_0}{k})^k \{\frac{n(1-p_0)}{n-k}\}^{n-k} \leq c(\alpha)\}.$$

Nu is het rechterlid van (8.2.15) stijgend voor  $k < np_0$  en dalend voor  $k > np_0$ , zodat het kritieke gebied voor  $k$  de volgende vorm heeft:

$$(8.2.16) \quad K = \{k \mid k \leq k_1 \text{ of } k \geq k_2\}.$$



Ook hier is het weer lastig om  $k_1$  en  $k_2$  te vinden. In de praktijk kiest men  $k_1$  en  $k_2$  zo groot, resp. zo klein, mogelijk terwijl

$$(8.2.17) \quad P(\underline{k} \leq k_1; p_0) \leq \alpha/2, \quad P(\underline{k} \geq k_2; p_0) \leq \alpha/2.$$

Opgave 8.2.16: Men gooit 200 keer met een dobbelsteen en vindt 40 "zessen". Toets de hypothese  $P(\text{"zes"}) = 1/6$  tegen het alternatief  $P(\text{"zes"}) \neq 1/6$  (zie opmerking 5.4.7). Kies  $\alpha = 0,05$ .

Opgave 8.2.17: Laat zien dat de eenzijdige toets met kritiek gebied van de vorm

$$K = \{k \mid k \geq k_1\}$$

uniform meest onderscheidend is voor de hypothese  $H_0: p=p_0$  tegen  $H_1: p > p_0$  (vergelijk opgave 8.1.16).

Voorbeeld 8.2.18: Twee analisten bepalen telkensbeiden de concentratie van stof Z in n monsters. Het resultaat bestaat uit een realisatie

$(x_1, y_1), \dots, (x_n, y_n)$  van een aselechte steekproef van  $(\underline{x}, \underline{y})$ , waarbij  $\underline{x}$  en  $\underline{y}$  niet noodzakelijk onafhankelijk zijn. We willen toetsen of beide analisten even grote concentraties vinden. We toetsen de hypothese

$H_0: P(\underline{x} > \underline{y}) = P(\underline{x} < \underline{y}) = \frac{1}{2}$  tegen het alternatief  $H_1: P(\underline{x} > \underline{y}) \neq P(\underline{x} < \underline{y})$  (we nemen gemakshalve aan dat  $(\underline{x}, \underline{y})$  een absoluut continue verdeling heeft, zodat  $P(\underline{x}=\underline{y})=0$ ).

Als toetsingsgrootte gebruiken we  $\underline{k}$ , het aantal positieve verschillen onder  $\underline{x}_1 - \underline{y}_1, \underline{x}_2 - \underline{y}_2, \dots, \underline{x}_n - \underline{y}_n$ . Onder  $H_0$  heeft  $\underline{k}$  dus een binomiale verdeling met parameters  $n$  en  $\frac{1}{2}$ . Men noemt deze toets, waarbij alleen op het teken van  $\underline{x} - \underline{y}$  wordt gelet, *tekentoets*.

Men gebruikt hierbij voor de tweezijdige toets een kritiek gebied bepaald door (8.2.16) en (8.2.17), weer met de conditie dat  $k_1$  zo groot mogelijk is en  $k_2$  zo klein mogelijk; we kunnen natuurlijk ook eenzijdig toetsen.

Opgave 8.2.19: Hoe vaak moeten we met een munt gooien om met een betrouwbaarheid van 0,01 te kunnen beslissen dat hij onzuiver is (d.w.z. niet met kansen  $\frac{1}{2}$  kruis en munt geeft)?

### 8.3. Betrouwbaarheidsintervallen

Betrouwbaarheidsintervallen en, iets algemener, betrouwbaarheidsgebieden kunnen worden opgevat als een generalisatie van schatters, in dit verband ook wel puntschatters genoemd. Een schatter (of een schatting) geeft één enkele aannemelijke waarde voor een onbekende parameter, een betrouwbaarheidsgebied is een *verzameling* van parameterwaarden, die met een zekere aannemelijkheid, betrouwbaarheid de werkelijke (onbekende) waarde bevat. Het begrip aannemelijkheid kwamen we tegen bij de schattingstheorie, het begrip onbetrouwbaarheid bij de toetsingstheorie (zie definities 7.2.1 en 3.2.5). We geven eerst een formele definitie.

Definitie 8.3.1: Zij  $\underline{x}_1, \dots, \underline{x}_n$  een steekproef met aannemelijkheidsfunctie  $L(\underline{x}_1, \dots, \underline{x}_n; \theta)$  ( $\theta \in \Omega$ ). Een *betrouwbaarheidsgebied* voor de (mogelijk meer-dimensionale) parameter  $\theta$  met betrouwbaarheid  $1-\alpha$  is een gebied  $C = C(\underline{x}_1, \dots, \underline{x}_n)$  met de eigenschap dat

$$(8.3.1) \quad P_{\theta}(C(\underline{x}_1, \dots, \underline{x}_n) \ni \theta) = 1-\alpha \quad (\theta \in \Omega).$$

Speciaal, als  $\theta$  een-dimensionaal is, dan is een betrouwbaarheidsinterval voor  $\theta$  een interval  $(\theta_1, \theta_2)$  met  $\theta_1 = \theta_1(\underline{x}_1, \dots, \underline{x}_n)$  en  $\theta_2 = \theta_2(\underline{x}_1, \dots, \underline{x}_n)$  zó, dat

$$P_{\theta}(\theta_1 < \theta < \theta_2) = 1-\alpha.$$

Opmerking 8.3.2: Bij gegeven waarnemingen, d.w.z. bij een realisatie van de steekproef is een betrouwbaarheidsgebied en vaste verzameling, waarover geen kansuitspraken kunnen worden gedaan. Op grond van de wet van de grote aantallen, zal wel bij dikwijls herhalen van het waarnemen in een fractie  $1-\alpha$  van de gevallen dit gebied de gezochte parameterwaarde bevatten.

In veel gevallen vindt men betrouwbaarheidsintervallen op de volgende manier:  $\underline{x}_1, \dots, \underline{x}_n$  is de realisatie van  $\underline{x}_1, \dots, \underline{x}_n$  met aannemelijkheidsfunctie  $L(\underline{x}_1, \dots, \underline{x}_n; \theta)$  ( $\theta$  een-dimensionaal). De grootheid  $\underline{T}$  is een schatter voor  $\theta$  met de eigenschap dat  $P(\underline{T} \leq T; \theta)$  monotoon, bijvoorbeeld dalend, is in  $\theta$  (en stijgend in  $T$ ) terwijl dan  $P(\underline{T} \geq T; \theta)$  stijgend is in  $\theta$  (en dalend in  $T$ ). Men bepaalt  $\theta_1$  en  $\theta_2$  uit definitie 8.3.1 door van de overschrijdingskansen voor de waargenomen waarde  $T$  te eisen dat

$$(8.3.2) \quad P(\underline{T} \leq T; \theta_2) = P(\underline{T} \geq T; \theta_1) = \alpha/2,$$

d.w.z. die waarden van  $\theta$ , waarvoor de kans op overschrijding van de gevonden waarde  $T$  gelijk is aan  $\alpha/2$ , vormen de grenzen van het betrouwbaarheidsinterval. We hebben dan  $\theta_2 = \theta_2(T)$  en  $\theta_1 = \theta_1(T)$ , waarbij  $\theta_1$  en  $\theta_2$  stijgend zijn in  $T$  (ga na), zodat de volgende identiteit in  $T$  geldt:

$$P(\underline{T} \leq T; \theta_2) = P(\underline{T} \leq T; \theta_2(T)) = P(\theta_2(\underline{T}) \leq \theta_2(T); \theta_2(T)) = \alpha/2,$$


en dus voor willekeurige  $\theta \in \Omega$  met  $\theta = \theta_2(T)$  geldt  $P_\theta(\theta_2 \leq \theta) = P_\theta(\theta_2(\underline{T}) \leq \theta) = \alpha/2$  en evenzo  $P_\theta(\theta_1 \geq \theta) = \alpha/2$ , d.w.z.

$$(8.3.3) \quad P_\theta(\theta_1 < \theta < \theta_2) = 1 - \alpha.$$

Dus  $(\theta_1, \theta_2)$  is een betrouwbaarheidsinterval voor  $\theta$  met betrouwbaarheid  $1 - \alpha$ . De samenhang met een toets voor  $\theta$  is als volgt: voor vaste  $\theta = \theta_0$  hebben we  $\theta_0 = \theta_1(T_2) = \theta_2(T_1)$  met  $T_1 < T_2$ . Voor  $\theta = \theta_0$  gaat (8.3.3) dan over in

$$\begin{aligned} 1 - P_{\theta_0}(\theta_1 < \theta_0 < \theta_2) &= P_{\theta_0}(\theta_1(\underline{T}) \geq \theta_1(T_2) \text{ of } \theta_2(\underline{T}) \leq \theta_2(T_1)) = \\ &= P_{\theta_0}(\underline{T} \leq T_1 \text{ of } \underline{T} \geq T_2) = \alpha. \end{aligned}$$

Het betrouwbaarheidsinterval met betrouwbaarheid  $1 - \alpha$  correspondeert dus met een toets voor  $\theta$  met kritiek gebied  $(T_1, T_2)^*$ , waarbij  $T_1$  en  $T_2$  functies zijn van  $\theta$  bepaald door  $\theta = \theta_1(T_2) = \theta_2(T_1)$ ; bij vaste  $T$  bestaat het betrouwbaarheidsinterval uit al die waarden van  $\theta$  die bij toetsing niet worden verworpen:  $\theta \in (\theta_1(T), \theta_2(T)) \Leftrightarrow T \in (T_1(\theta), T_2(\theta))$ . De correspondentie tussen betrouwbaarheidsinterval en aanvaardingsinterval is geschetst in de onderstaande figuur.



Voorbeeld 8.3.3: Zij  $x_1, \dots, x_n$  de realisatie van een aselechte steekproef van  $\underline{x}$  met  $\underline{x} \sim N(\mu, \sigma^2)$ -verdeeld. We zoeken een betrouwbaarheidsinterval met betrouwbaarheid  $1-\alpha$  voor  $\mu$ .

A.  $\sigma^2$  bekend. Als toetsingsgrootte gebruiken we  $\bar{\underline{x}} = (x_1 + \dots + x_n)/n$ . We weten dat *bij gegeven*  $\mu$  de grootte  $\underline{u} = (\bar{\underline{x}} - \mu) \sqrt{n}/\sigma$  een  $N(0,1)$ -verdeling heeft. We vinden dus de grenzen van het betrouwbaarheidsinterval uit de voorwaarden

$$P(\bar{\underline{x}} \leq \bar{x}; \mu_2) = \alpha/2 \quad ; \quad P(\bar{\underline{x}} \geq \bar{x}; \mu_1) = \alpha/2$$

en dus (vergelijk voorbeeld 8.2.1 A)

$$\frac{\bar{x} - \mu_1}{\sigma} \sqrt{n} = u_{\alpha/2} \quad ; \quad \frac{\bar{x} - \mu_2}{\sigma} \sqrt{n} = -u_{\alpha/2},$$

zodat

$$(\mu_1, \mu_2) = \left( \bar{x} - \frac{\sigma}{\sqrt{n}} u_{\alpha/2}, \bar{x} + \frac{\sigma}{\sqrt{n}} u_{\alpha/2} \right).$$

B.  $\sigma^2$  onbekend. Bij gegeven  $\mu$  gebruiken we de toetsingsgrootte (zie voorbeeld 8.2.1 B)  $\underline{t} = (\bar{\underline{x}} - \mu) \sqrt{n}/\underline{s}$ , die (bij gegeven  $\mu$ ) een  $t_{n-1}$ -verdeling heeft. Geheel analoog vinden we nu het interval

$$(\mu_1, \mu_2) = (\bar{x} - \frac{s}{\sqrt{n}} t_{\alpha/2}, \bar{x} + \frac{s}{\sqrt{n}} t_{\alpha/2}).$$

Opgave 8.3.4: Zij  $x_1, \dots, x_{100}$  de realisatie van een aselechte steekproef van  $\underline{x}$  met  $\underline{x} \sim N(\mu, \sigma^2)$  verdeeld. Zij  $\bar{x} = 1,24$  en  $s^2 = 0,0081$ .

Bereken een betrouwbaarheidsinterval met betrouwbaarheid 0,96 voor  $\sigma^2$ ,

A. als  $\mu$  bekend is:  $\mu = 1,20$ ,

B. als  $\mu$  onbekend is (vergelijk voorbeeld 8.2.4).

Zoals al door het bovenstaande wordt gesuggereerd, geldt de volgende stelling.

Stelling 8.3.5: Zij  $x_1, \dots, x_n$  de realisatie van een steekproef  $\underline{x}_1, \dots, \underline{x}_n$  met aannemelijkheidsfunctie  $L(x_1, \dots, x_n; \theta)$  ( $\theta \in \Omega$ ). Zij  $A = A(\theta) \subset \mathbb{R}^n$  het aanvaardingsgebied van een toets voor de hypothese  $\theta$  met onbetrouwbaarheidsdrempel  $\alpha$ , d.w.z.

$$P_{\theta}((\underline{x}_1, \dots, \underline{x}_n) \in A(\theta)) \geq 1-\alpha,$$

dan is de verzameling parameterwaarden  $C = C(x_1, \dots, x_n) \subset \Omega$  gedefinieerd door

$$C(x_1, \dots, x_n) = \{\theta \in \Omega \mid (x_1, \dots, x_n) \in A(\theta)\}$$

een betrouwbaarheidsgebied voor  $\theta$  met betrouwbaarheid  $\geq 1-\alpha$ , d.w.z. de verzameling van alle parameterwaarden die bij toetsing niet verworpen worden vormen een betrouwbaarheidsgebied voor  $\theta$  (vergelijk definitie van  $A$  en  $R$ , definitie 8.1.3).

Bewijs:  $P_{\theta}(C(\underline{x}_1, \dots, \underline{x}_n) \ni \theta) = P_{\theta}((\underline{x}_1, \dots, \underline{x}_n) \in A(\theta)) \geq 1-\alpha$ .

Opmerking 8.3.6: Stelling 8.3.5 geeft ook bij een eenzijdige toets een (eenzijdig) betrouwbaarheidsgebied. Ook analoog aan (8.3.2) vinden we een eenzijdig betrouwbaarheidsinterval  $(-\infty, \theta'_2)$  of  $(\theta'_1, \infty)$  door te eisen

$$P(\underline{T} \leq T; \theta'_2) = \alpha$$

of

$$P(\underline{T} \geq T; \theta'_1) = \alpha.$$

In voorbeeld 8.3.3 A krijgen we dan

$$\text{linkseenzijdig: } \mu'_2 = \bar{x} + \frac{\sigma}{\sqrt{n}} u_\alpha$$

$$\text{rechtseenzijdig: } \mu'_1 = \bar{x} - \frac{\sigma}{\sqrt{n}} u_\alpha.$$

Opmerking 8.3.7: Stelling 8.3.5 houdt in, dat een betrouwbaarheidsinterval ook een toets levert: alle  $\theta \notin C(x_1, \dots, x_n)$  worden verworpen.


Voorbeeld 8.3.8: Zij  $x_1, \dots, x_n$  de realisatie van een aselechte steekproef van  $\underline{x}$  met  $\underline{x} \sim N(\mu, \sigma^2)$ -verdeeld. We construeren een betrouwbaarheidsgebied voor de parameter  $(\mu, \sigma^2)$ . We gebruiken de toetsingsgrootheden  $\bar{x}$  en  $s^2$ , waarvan we weten dat ze onafhankelijk zijn, terwijl  $\bar{x}$  een  $N(\mu, \sigma^2/n)$ -verdeling heeft en  $(n-1)s^2/\sigma^2 = \sigma^{-2} \sum_{j=1}^n (x_j - \bar{x})^2$  een  $\chi_{n-1}^2$ -verdeling. Omdat  $\bar{x}$  en  $s^2$  onafhankelijk zijn, geldt (zie voorbeeld 8.2.4)

$$P\left(\left|\frac{\bar{x}-\mu}{\sigma}\sqrt{n}\right| < u_{\beta/2}, \chi_{1-\gamma/2}^2 < ns^2/\sigma^2 < \chi_{\gamma/2}^2; \mu, \sigma^2\right) = (1-\beta)(1-\gamma).$$

Voor  $(1-\beta)(1-\gamma) = 1-\alpha$  vinden we o.g.v. stelling 8.3.5 als betrouwbaarheidsgebied met betrouwbaarheid  $1-\alpha$  de volgende verzameling van  $(\mu, \sigma^2)$ -waarden:

$$\{(\mu, \sigma^2) \mid \left|\frac{\bar{x}-\mu}{\sigma}\sqrt{n}\right| < u_{\beta/2}, \chi_{1-\gamma/2}^2 < ns^2/\sigma^2 < \chi_{\gamma/2}^2\}.$$

Dit gebied en het corresponderende gebied in het  $(\mu, \sigma)$ -vlak is geschetst in onderstaande figuur.




Als we te maken hebben met diskrete verdelingen, dan hebben toetsen met onbetrouwbaarheidsdrempel  $\alpha$  dikwijls een onbetrouwbaarheid die kleiner is dan  $\alpha$ ; als gevolg hiervan hebben de corresponderende betrouwbaarheidsgebieden dan een betrouwbaarheid die groter is dan  $1-\alpha$ . Als voorbeeld beschouwen we betrouwbaarheidsintervallen voor de kans  $p$  op succes.

Voorbeeld 8.3.9: Zij  $x_1, \dots, x_n$  een realisatie van een aselecte steekproef van  $\underline{x}$  met  $P(\underline{x}=1)=1-P(\underline{x}=0)=p$ . We bepalen een tweezijdig betrouwbaarheidsinterval voor  $p$  uitgaande van (8.3.2): we bepalen  $p_1$  en  $p_2$  zó dat bij de realisatie  $k$  van de toetsingsgrootte  $\underline{k} = \underline{x}_1 + \dots + \underline{x}_n$  geldt

$$(8.3.4) \quad P(\underline{k} \leq k; p_2) = P(\underline{k} \geq k; p_1) = \alpha/2 \quad (1 \leq k \leq n-1);$$

dit is mogelijk, omdat beide kansen *continu* afhangen van  $p$ . Omdat (zie lemma 8.3.10)  $P(\underline{k} \geq k; p)$  stijgend is in  $p$  voor alle  $k$  met  $1 \leq k \leq n-1$ , en dus  $P(\underline{k} \leq k; p)$  dalend, zijn  $p_1$  en  $p_2$  in (8.3.4) eenduidig bepaald:  $p_1 = p_1(k)$  en  $p_2 = p_2(k)$  (zie onderstaande figuur). We definiëren  $p_1(0) = 0$  en  $p_2(n) = 1$ .



We berekenen nu de betrouwbaarheid van het interval  $(p_1, p_2)$  met  $p_1 = p_1(k)$  en  $p_2 = p_2(k)$ . We hebben

$$P_p(p_1 < p < p_2) = 1 - P_p(p_1 \geq p) - P_p(p_2 \leq p).$$

Bij een gegeven waarde van  $p$  is er een kleinste waarde van  $k$ ,  $k_1(p)$ , waar-  
 bij  $p$  niet wordt verworpen, d.w.z. waarvoor  $p$  in het bijbehorende betrouw-  
 baarheidsinterval ligt; evenzo is er een grootste waarde van  $k$ ,  $k_2(p)$ , waar-  
 voor  $p$  in het daarbij behorende betrouwbaarheidsinterval ligt. Op grond van  
 de monotonie geldt dan dat voor  $k_1(p) \leq k \leq k_2(p)$  de waarde  $p$  in het betrouw-  
 baarheidsinterval van  $k$  ligt (en niet in het betrouwbaarheidsinterval  
 behorende bij andere waarden van  $k$ ), d.w.z.

$$P_p(\underline{p}_1 < p < \underline{p}_2) = P_p(k_1(p) \leq \underline{k} \leq k_2(p)).$$

Zij nu  $p_1^* = p_1(k_2(p)+1)$  en  $p_2^* = p_2(k_1(p)-1)$ , dan is i.h.a. (zie figuur)  
 $p_1^* > p$  en  $p_2^* < p$ , zodat o.g.v. de monotonie (zie lemma 8.3.10)

$$P_p(\underline{k} \leq k_1(p)-1) < P_{p^*}(\underline{k} \leq k_1(p)-1) = \alpha/2$$

$$P_p(\underline{k} \geq k_2(p)+1) < P_{p^*}(\underline{k} \geq k_2(p)+1) = \alpha/2.$$

Dan is ook  $P_p(\underline{p}_1 < p < \underline{p}_2) > 1-\alpha$ .

Lemma 8.3.10:

$$P(\underline{k} \geq k; p) := \sum_{j=k}^n \binom{n}{j} p^j (1-p)^{n-j}$$

is stijgend in  $p$  voor  $k=1, 2, \dots$ .

Bewijs: door differentiatie verifieert men gemakkelijk dat

$$\sum_{j=k}^n \binom{n}{j} p^j (1-p)^{n-j} = \frac{1}{B(k, n-k+1)} \int_0^p t^{k-1} (1-t)^{n-k} dt$$

(vergelijk voorbeeld 3.5.13).

Opgave 8.3.11:  $x_1 + \dots + x_{10}$  is een realisatie van een steekproef van  $\underline{x}$  met  
 $P(\underline{x}=1) = 1 - P(\underline{x}=0) = p$ . Bereken de betrouwbaarheidsintervallen voor  $p$  als  
 $x_1 + \dots + x_n = k$  voor  $k=0, 1, \dots, 10$ .

Schets het verloop van de werkelijke betrouwbaarheid als functie van  $p$   
 door  $P_p(\underline{k} \leq k_1(p)-1)$  en  $P_p(\underline{k} \geq k_2(p)+1)$  uit te rekenen.



Voor grote waarden van  $n$  benaderen we de (binomiale) verdeling van  $\underline{k}$  weer door een normale verdeling. We bepalen de benaderende grenzen van het betrouwbaarheidsinterval dan als volgt (zie opmerking 5.4.7):

$$P(\underline{k} \geq k; p_1) \approx 1 - \Phi\left(\frac{k - np_1 - \frac{1}{2}}{\sqrt{np_1(1-p_1)}}\right) = \alpha/2$$

$$P(\underline{k} \leq k; p_2) \approx \Phi\left(\frac{k - np_2 + \frac{1}{2}}{\sqrt{np_2(1-p_2)}}\right) = \alpha/2.$$

We vinden nu  $p_1$  als de kleinste oplossing van

$$(k - np - \frac{1}{2})^2 = (u_{\alpha/2})^2 np(1-p)$$

en  $p_2$  als de grootste oplossing van

$$(k - np + \frac{1}{2})^2 = (u_{\alpha/2})^2 np(1-p).$$

Voor grotere  $n$  (bijv.  $n > 100$ ) kunnen we de continuïteitscorrectie weglaten; we vinden dan  $p_1$  en  $p_2$  als de oplossingen van

$$(k - np)^2 = (u_{\alpha/2})^2 np(1-p).$$

Een benaderende oplossing hiervan is (ga na)

$$p_{1,2} \approx \bar{p} \mp u \sqrt{\bar{p}(1-\bar{p})/n},$$

met  $u = u_{\alpha/2}$  en  $\bar{p} = (k + \frac{u^2}{2}) / (n + u^2)$ . Voor zeer grote  $n$  gebruikt men de (verdere) benadering

$$\bar{p}_{1,2} \approx \frac{k}{n} \mp u \sqrt{\frac{k}{n} \left(1 - \frac{k}{n}\right) \frac{1}{n}}.$$

Opgave 8.3.12: Bij 10000 enkelvoudige geboorten zijn 5150 van de babies jongens. Geef een betrouwbaarheidsinterval met een betrouwbaarheid van 0,99 voor  $p := P(\text{jongen})$ .

Opgave 8.3.13: Hoe bepaalt men een betrouwbaarheidsinterval voor de parameter  $\mu$  van een Poisson-verdeling; hoe ziet de benadering voor grote steekproeven er uit?

Opmerking 8.3.14: Eenzijdige betrouwbaarheidsintervallen voor  $p$   
vinden we door oplossing van

$$P(\underline{k} \geq k; p'_1) = \alpha ;$$

dit levert de linkergrens voor een rechts-eenzijdig betrouwbaarheidsinterval  
 $(p'_1, 1]$ . De normale benadering is analoog aan die in het tweezijdige geval.

APPENDIX

A3 Ongelijkheid van Cramér-Rao

We geven hier een iets algemenere versie van stelling 7.1.18.

Stelling A3.1 (Ongelijkheid van Cramér-Rao): Zij  $\underline{x}_1, \dots, \underline{x}_n$  een steekproef met likelihood-functie  $L(x_1, \dots, x_n; \theta)$  met  $(x_1, \dots, x_n) \in X \subset \mathbb{R}^n$  en  $\theta \in \Omega$  (zie definitie 7.2.1) en zij  $\underline{t} = t(\underline{x}_1, \dots, \underline{x}_n)$  een schatter voor  $\theta$  met  $E \underline{t} = \alpha(\theta)$  en  $E \underline{t}^2 < \infty$  voor alle  $\theta \in \Omega$ . Als voldaan is aan de volgende voorwaarden (hierbij korten we  $L(x_1, \dots, x_n; \theta)$  af tot  $L(x; \theta)$ ):

(i)  $\frac{\partial}{\partial \theta} \log L(x; \theta)$  bestaat voor alle  $x \in X$  en  $\theta \in \Omega$ ,

(ii)  $\frac{\partial}{\partial \theta} \int_X L(x; \theta) dx = \int_X \frac{\partial}{\partial \theta} L(x; \theta) dx \quad (\theta \in \Omega)$ ,

(iii)  $\frac{\partial}{\partial \theta} \int_X t(x) L(x; \theta) dx = \int_X t(x) \frac{\partial}{\partial \theta} L(x; \theta) dx \quad (\theta \in \Omega)$ ,

(iv)  $0 < E_{\theta} \left\{ \frac{\partial}{\partial \theta} \log L(\underline{x}; \theta) \right\}^2 < \infty \quad (\theta \in \Omega)$ ,

dan geldt

$$(A3.1) \quad \text{var } \underline{t} \geq \frac{\{\alpha'(\theta)\}^2}{E \left\{ \frac{\partial}{\partial \theta} \log L(\underline{x}; \theta) \right\}^2} \quad (\theta \in \Omega).$$

**Bewijs:** de voorwaarden betekenen dat onder het integraalteken gedifferentieerd mag worden. We hebben (o.g.v. (i) is  $L(x; \theta) > 0$  voor  $x \in X$  en  $\theta \in \Omega$ )

$$(A 3.2) \quad 1 \equiv \int_X L(x; \theta) dx \Rightarrow 0 \equiv \int_X \frac{\partial}{\partial \theta} L(x; \theta) dx = E \frac{\partial}{\partial \theta} \log L(\underline{x}; \theta),$$

omdat  $\int \frac{\partial}{\partial \theta} L(x; \theta) dx = \int \frac{\partial}{\partial \theta} \{\log L(x; \theta)\} L(x; \theta) dx = E \frac{\partial}{\partial \theta} \log L(\underline{x}; \theta)$ . Verder is op dezelfde manier

$$(A 3.3) \quad \alpha'(\theta) = \int_X t(x) \frac{\partial}{\partial \theta} L(x; \theta) dx = E \underline{t} \frac{\partial}{\partial \theta} \log L(\underline{x}; \theta).$$

Als we afkorten  $\underline{u} := \frac{\partial}{\partial \theta} \log L(\underline{x}; \theta)$  (dit is o.g.v. (i) en (ii) een stochastische grootheid) dan geldt

$$\alpha'(\theta) = E \underline{t} \underline{u} = E (\underline{t} - E\underline{t}) \underline{u},$$

omdat  $E \underline{u} = 0$  (zie (A.3.2)). De ongelijkheid van Schwarz (stelling 4.2.8) levert nu

$$\{\alpha'(\theta)\}^2 = \{E(\underline{t} - E\underline{t}) \underline{u}\}^2 \leq \text{var } \underline{t} \cdot E \underline{u}^2,$$

equivalent met (A 3.1).

Opmerking A 3.2: als nogmaals onder het integraalteken gedifferentieerd mag worden, dan blijkt (ga na) dat

$$- E \frac{\partial^2 \log L(\underline{x}; \theta)}{\partial \theta^2} = E \left\{ \frac{\partial \log L(\underline{x}; \theta)}{\partial \theta} \right\}^2.$$

Ongelijkheid (A 3.1) gaat dan over in

$$(A.3.4) \quad \text{var } \underline{t} \geq \frac{-\{\alpha'(\theta)\}^2}{E \frac{\partial^2 \log L(\underline{x}; \theta)}{\partial \theta^2}}.$$

Opmerking A 3.3: Gelijkheid geldt in (A 3.1) d.e.s.d. als met kans 1

$$(A 3.5) \quad \frac{\partial}{\partial \theta} \log L(\underline{x}_1, \dots, \underline{x}_n; \theta) = c_n(\theta)(\underline{t} - E\underline{t}) \equiv c_n(\theta)(\underline{t} - \alpha(\theta));$$

dit volgt ook uit stelling 4.2.8. Door de uiterste leden van (A 3.5) te kwadrateren en vervolgens de verwachting ( $E = E_\theta$ ) te nemen blijkt dat

$$E \left\{ \frac{\partial}{\partial \theta} \log L(\underline{x}_1, \dots, \underline{x}_n; \theta) \right\}^2 = (c_n(\theta))^2 \text{var } \underline{t},$$

zodat (zie (A 3.1) en vergelijk opgave 7.1.21)

$$|c_n(\theta)| = \frac{|\alpha'(\theta)|}{\text{var } \underline{t}}.$$

A 4 Onafhankelijkheid van  $\underline{s}^2$  en  $\underline{\bar{x}}$

Stelling A 4.1: Als  $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_n$  onderling onafhankelijk zijn en  $N(0,1)$ -verdeeld, dan zijn de grootheden  $\underline{\bar{x}} = (\underline{x}_1 + \dots + \underline{x}_n)/n$  en  $\underline{s}^2 = (n-1)^{-1} \sum_{j=1}^n (\underline{x}_j - \underline{\bar{x}})^2$  onderling onafhankelijk. Bovendien heeft de grootheid  $(n-1)\underline{s}^2$  een  $\chi_{n-1}^2$ -verdeling.

Bewijs: we maken gebruik van het feit dat er een orthonormale matrix A bestaat, met elementen  $a_{ij}$  ( $i=1,2,\dots,n; j=1,2,\dots,n$ ), die behalve de eigenschappen  $\sum_j a_{ij}^2 = 1$  en  $\sum_j a_{ij} a_{kj} = 0$  ( $i \neq k$ ) nog de eigenschap heeft dat

$$(A 4.1) \quad a_{nj} = \frac{1}{\sqrt{n}} \quad (j=1,2,\dots,n).$$

Dat zo'n A bestaat is een gevolg van het feit dat we  $n-1$  orthonormale vectoren kunnen vinden in de ruimte  $\{x \in \mathbb{R}^n \mid x_1 + \dots + x_n = 0\}$ , die isomorf is met  $\mathbb{R}^{n-1}$ .

We definiëren nu  $\underline{u}_1, \underline{u}_2, \dots, \underline{u}_n$  door (in (kolom)vectornotatie)

$$(A 4.2) \quad \underline{u} = A \underline{x}.$$

Dan is  $\sum_{j=1}^n \underline{u}_j^2 = \underline{u}^T \underline{u} = \underline{x}^T A^T A \underline{x} = \underline{x}^T \underline{x} = \sum_{j=1}^n \underline{x}_j^2$ , omdat wegens de orthonormaliteit van A geldt dat  $A^T A = I$ . Voor de kansdichtheid van  $\underline{u}_1, \dots, \underline{u}_n$  hebben we dan (vergelijk opgave 3.7.4)

$$\begin{aligned} f_{\underline{u}_1, \dots, \underline{u}_n}(u_1, \dots, u_n) &= f_{\underline{x}_1, \dots, \underline{x}_n}(x_1(u_1, \dots, u_n), \dots, x_n(u_1, \dots, u_n)) \left| \frac{\partial(x_1, \dots, x_n)}{\partial(u_1, \dots, u_n)} \right| \\ &= \left(\frac{1}{\sqrt{2\pi}}\right)^n \exp\left\{-\frac{1}{2} \sum_{j=1}^n x_j^2(u_1, \dots, u_n)\right\} \cdot \det A \\ &= \left(\frac{1}{\sqrt{2\pi}}\right)^n \exp\left\{-\frac{1}{2} \sum_{j=1}^n u_j^2\right\}, \end{aligned}$$

d.w.z.  $\underline{u}_1, \dots, \underline{u}_n$  zijn o.o. en  $N(0,1)$  verdeeld. Nu is wegens (A 4.1)

$$(A 4.3) \quad \underline{u}_n = \sum_{j=1}^n \underline{x}_j / \sqrt{n} = \sqrt{n} \underline{\bar{x}},$$

zodat

$$(A\ 4.4) \quad (n-1)\underline{s}^2 = \sum_1^n (\underline{x}_j - \underline{\bar{x}})^2 = \sum_1^n \underline{x}_j^2 - n\underline{\bar{x}}^2 = \sum_1^{n-1} \underline{u}_j^2.$$

Uit (A 4.3) en (A 4.4) volgt nu direct dat  $\underline{\bar{x}}$  en  $\underline{s}^2$  onafhankelijk zijn en dat  $(n-1)\underline{s}^2 = \sum_1^{n-1} \underline{u}_j^2$  een  $\chi_{n-1}^2$  verdeling heeft (vergelijk definitie A 2.1.1).

Gevolg A 4.2: Als  $\underline{x}_1, \dots, \underline{x}_n$  o.o. zijn en  $N(\mu, \sigma^2)$ -verdeeld, dan zijn  $\underline{\bar{x}}$  en  $\underline{s}^2$  o.o., terwijl

$$\frac{1}{\sigma^2} \sum_1^n (\underline{x}_j - \underline{\bar{x}})^2$$

een  $\chi_{n-1}^2$  verdeling heeft.

Opmerking A 4.3: Voor de matrix A in het bewijs van stelling A 4.1 kunnen we nemen

$$A = \begin{pmatrix} \frac{1}{\sqrt{1.2}} & -\frac{1}{\sqrt{1.2}} & 0 & \dots & \dots & 0 \\ \frac{1}{\sqrt{2.3}} & \frac{1}{\sqrt{2.3}} & -\frac{2}{\sqrt{2.3}} & 0 & \dots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{1}{\sqrt{(n-1)n}} & \frac{1}{\sqrt{(n-1)n}} & \dots & \frac{1}{\sqrt{(n-1)n}} & \frac{1}{\sqrt{(n-1)n}} & \frac{-(n-1)}{\sqrt{(n-1)n}} \\ \frac{1}{\sqrt{n}} & \frac{1}{\sqrt{n}} & \dots & \frac{1}{\sqrt{n}} & \frac{1}{\sqrt{n}} & \frac{1}{\sqrt{n}} \end{pmatrix}.$$

Opgave A 4.4: Bewijs dat

$$\frac{(\underline{\bar{x}} - \mu)\sqrt{n(n-1)}}{\sqrt{\sum_1^n (\underline{x}_j - \underline{\bar{x}})^2}}$$

een  $t_{n-1}$ -verdeling heeft.