

8. april, 2013

# MAT-INF 2360: Obligatorisk oppgave 3

Innleveringsfrist: 2/5-2013, kl. 14:30

## Informasjon

Den skriftlige besvarelsen skal leveres i obligkassa som står i gangen utenfor ekspedisjonen i 7. et. i Niels Henrik Abels hus senest *kl. 14.30 torsdag 2/5*. Du kan også levere via devilry. Besvarelsen *skal* være skrevet av deg selv, for hånd eller på datamaskin.

Studenter som blir syke eller av andre grunner trenger å søke om utsettelse for denne obligatoriske oppgaven, må ta kontakt med studieadministrasjonen ved Matematisk institutt (7. et. Niels Henrik Abels hus, telefon 22 8558 88, e-post: [studieinfo@math.uio.no](mailto:studieinfo@math.uio.no)) i god tid før innleveringsfristen.

Det oppfordres til samarbeid underveis i arbeidet med oppgavene, og gruppelærer og forelesere har anledning til å svare på generelle spørsmål, men kan ikke servere ferdige løsninger. *Den endelige besvarelsen som du leverer skal utarbeides av deg selv, og du må kunne redegjøre for innholdet ved en eventuell muntlig høring (aktuelt ved mistanke om avskrift).*

Husk at de tre obligatoriske oppgavene i MAT-INF 2360 alle må bestås for å kunne gå opp til endelig eksamen i kurset. *For å få bestått på denne tredje obligatoriske oppgaven må du gjøre seriøse løsningsforsøk på alle oppgavene, og minst 6 av de 8 deloppgavene bør være riktig besvart.*

I kapittel 1 i kompendiet om ikkelineær optimering forklarte vi at maximum-likelihood er en av de viktige anvendelsene av ikkelineær optimering. Vi skal se litt mer på hva dette innebærer i praksis. Utgangspunktet er at man har en sannsynlighetstetthetsfunksjon  $p(x; \alpha, \beta, \dots)$  for et eller annet fenomen, der  $\alpha, \beta, \dots$  er ukjente parametre (det kan være mange flere parametre enn det vi har listet opp her).

Vi skal se på en modell fra fysikk for desintegrasjon av myoner (se Eksempel 1.3 i kompendiet). Vinkelen  $\theta$  i elektronstråling ved desintegrasjon av myoner har en fordeling med sannsynlighetstetthet

$$p(x; \alpha) = \frac{1 + \alpha x}{2} \quad (1)$$

for  $x \in [-1, 1]$ , der  $x = \cos\theta$ , og der  $\alpha$  er en ukjent parameter i  $[-1, 1]$ . Målet vårt er å estimere  $\alpha$  ved hjelp av  $n$  målinger  $\mathbf{x} = (x_1, \dots, x_n)$ . I metoden for maximum likelihood gjøres dette ved at vi maksimerer likelihoodfunksjonen  $g(\alpha) = \prod_{i=1}^n p(x_i; \alpha)$ .

**1 (Oppgave 1.4 i kompendiet).** Forklar hvorfor det å maksimere  $g$  er det samme som å maksimere  $\ln g$ .

**Løsningsforslag:** Vi har at  $(\ln g)' = \frac{g'}{g}$ , slik at  $g'(x) = 0$  hvis og bare hvis  $(\ln g)'(x) = 0$ . Dette viser at funksjonene har de samme stasjonære punktene.

Det viser seg at det ofte er enklere å maksimere  $\ln g$  enn  $g$  selv, siden logaritmen til et produkt er summen av logaritmene. Vi skal derfor jobbe med  $\ln g$ , som kalles for log-likelihoodfunksjonen. Mer presist skal vi jobbe med funksjonen  $f(\alpha) = -\ln g(\alpha)$ , siden å finne maksimum til  $g$  er det samme som å finne minimum til  $f$ , og siden kompendiet er formulert for å finne minimum til funksjoner. Vi skal med andre ord minimere funksjonen

$$f(\alpha) = -\ln g(\alpha) = -\ln \left( \prod_{i=1}^n p(x_i; \alpha) \right) = -\sum_{i=1}^n \ln((1 + \alpha x_i)/2). \quad (2)$$

**2.** Når vi minimerer  $f$  har vi også tilleggsbetingelsene  $-1 \leq \alpha \leq 1$ . Omformuler problemet slik at det er et betinget minimeringsproblem med to ulikhetsbetingelser  $g_1$  og  $g_2$ .

**Løsningsforslag:**  $\alpha \geq -1$  kan skrives som  $g_1(\alpha) = -1 - \alpha \leq 0$ .  $\alpha \leq 1$  kan skrives som  $g_2(\alpha) = \alpha - 1 \leq 0$ . Når vi definerer  $g_1$  og  $g_2$  slik kan dermed vårt minimeringsproblem formuleres som

minimer under betingelsene	$f(\alpha)$ $g_1(\alpha) \leq 0$ $g_2(\alpha) \leq 0$
-------------------------------	---

3. Skriv opp KKT-betingelsene for problemet du fant i forrige oppgave, og drøft løsningene du får for følgende muligheter:

1. Kun  $g_1$  er aktiv
2. Kun  $g_2$  er aktiv
3. Hverken  $g_1$  eller  $g_2$  er aktive
4. Både  $g_1$  og  $g_2$  er aktive

**Løsningsforslag:** Vi har at  $g'_1(\alpha) = -1$ , og  $g'_2(\alpha) = 1$ .

1. Hvis kun  $g_1$  er aktiv så er  $\alpha = -1$ . KKT-betingelsene kan da skrives  $f'(\alpha) - \mu_1 = 0$ , som er det samme som at  $f'(\alpha) \geq 0$ . Denne muligheten svarer derfor til at  $f'(-1) \geq 0$  og  $\alpha = -1$ .
2. Hvis kun  $g_2$  er aktiv så er  $\alpha = 1$ . KKT-betingelsene kan da skrives  $f'(\alpha) + \mu_2 = 0$ , som er det samme som at  $f'(\alpha) \leq 0$ . Denne muligheten svarer derfor til at  $f'(1) \leq 0$  og  $\alpha = 1$ .
3. Dette betyr at  $-1 < \alpha < 1$ , og at  $f'(\alpha) = 0$ .
4.  $g_1$  og  $g_2$  kan ikke begge være aktive samtidig, siden dette svarer til at både  $\alpha = -1$  og  $\alpha = 1$ .

I Eksempel 1.3 i kompendiet regnet vi ut  $f'(\alpha)$  og  $f''(\alpha)$  til å være

$$f'(\alpha) = - \sum_{i=1}^n \frac{x_i/2}{(1 + \alpha x_i)/2} = - \sum_{i=1}^n \frac{x_i}{1 + \alpha x_i}$$
$$f''(\alpha) = \sum_{i=1}^n \frac{x_i^2}{(1 + \alpha x_i)^2}$$

Fra dette fulgte det at  $f$  er konveks. Tegner vi et fortegnsskjema for  $f'(\alpha)$  over hele  $\mathbb{R}$  ser vi da at

- $f$  har nøyaktig ett minimum i hvert intervall av formen  $[-1/x_i, -1/x_{i+1}]$  når vi lister opp  $x_i$  i voksende rekkefølge.
- $f'(\alpha) \rightarrow 0$  når  $\alpha \rightarrow \pm\infty$ .
- $f'(\alpha) \rightarrow \infty$  når  $\alpha \rightarrow -1/x_i$  nedenfra.

- $f'(\alpha) \rightarrow -\infty$  når  $\alpha \rightarrow -1/x_i$  ovenfra.

4. Forklar ut fra fortegnskjemaet at det vil alltid kun være en kandidat fra mulighet 1 til 3 over som vil være kandidat til minimum for  $f$ , uavhengig av måleverdiene  $x_i$ .

**Løsningsforslag:** Mulighet 1 svarer til at  $f'(-1) \geq 0$ , og mulighet 2 svarer til at  $f'(1) \leq 0$ . Hvis ingen av disse gjelder har vi at  $f'(-1) < 0$ , og  $f'(1) > 0$ . Men da er det klart at det finnes nøyaktig et punkt  $c$  i  $[-1, 1]$  der  $f'(c) = 0$ , som da er fra mulighet 3. Det er dermed klart at vi alltid har nøyaktig et punkt som faller innenfor en av de tre mulighetene.

Siden  $f$  er konveks kan vi bruke resultater fra kompendiet til å begrunne at Newtons metode for å finne eventuelle punkter der  $f'(\alpha) = 0$  konvergerer, så lenge vi starter nær nok. Siden vi allerede har regnet ut den deriverte og andrederiverte for  $f$  kan vi sette disse direkte inn i Newton's metode for å finne minimum til  $f$  (=nullpunkt til  $f'$ ).

5. I Kapittel 4 i kompendiet om ikkelineær optimering forklares det hvordan man kan lage en litt mer avansert variant av Newtons metode som fungerer for funksjoner i flere variable, og som bruker det vi kaller *backtracking line search*. I Oppgave 4.12 på s. 49 blir du bedt om å programmere denne. Koden fra denne oppgaven kan du finne i funksjonen `newtonbacktrack`, som ligger på det vanlige området for matlabkode for kurset (<http://folk.uio.no/oyvindry/matinf2360/matlab/>). Kommenter denne koden, ut fra teorien i Kapittel 4. Kommenter også hvordan du kan endre koden slik at den tar høyde for muligheten at det ikke finnes noe punkt der den deriverte er 0.

**6 (Oppgave 4.10 i kompendiet).** Funksjonen `newtonbacktrack` kaller en annen funksjon, `armijo_rule`, som implementerer Likning (4.7) i kompendiet (Oppgave 4.11 i kompendiet), og som du også kan finne på det vanlige området for matlabkode for kurset. Hva vil kunne gå galt i denne funksjonen hvis  $\nabla^2 f$  er negativ definit (det vil si at alle egenverdiene til  $\nabla^2 f$  er negative)? Merk at dette ikke vil skape problemer for funksjonen  $f(\alpha)$  vi bruker her, siden den er konveks (slik at  $\nabla^2 f$  er positiv definit)?

**Hint:** Sett inn Taylorapprosimasjonen

$$f(\mathbf{x}_k + \beta^m \mathbf{s} \mathbf{d}_k) \approx f(\mathbf{x}_k) + \nabla f(\mathbf{x}_k)^T (\beta^m \mathbf{s} \mathbf{d}_k)$$

i (4.7), og husk at  $\sigma$  der er valgt slik at  $\sigma < 1$ .

**Løsningsforslag:** Vi vet fra før at  $f(\mathbf{x}_k) - f(\mathbf{x}_k + \beta^m \mathbf{s} \mathbf{d}_k) \approx -\beta^m \mathbf{s} \nabla f(\mathbf{x}_k)^T \mathbf{d}_k$ . Skal (4.7) holde for store  $m$  må derfor

$$-\beta^m \mathbf{s} \nabla f(\mathbf{x}_k)^T \mathbf{d}_k \geq -\sigma \beta^m \mathbf{s} \nabla f(\mathbf{x}_k)^T \mathbf{d}_k.$$

Hvis  $\nabla^2 f$  er negativ definit så er også  $(\nabla^2 f)^{-1}$  negativ definit, og da vil

$$\nabla f(\mathbf{x}_k)^T \mathbf{d}_k = -\nabla f(\mathbf{x}_k)^T (\nabla^2 f(\mathbf{x}_k))^{-1} \nabla f(\mathbf{x}_k) > 0,$$

der vi har satt inn søkeretningen for Newtons metode. Deler vi med  $\beta^m s \nabla f(\mathbf{x}_k)^T \mathbf{d}_k > 0$  i ulikheten får vi derfor at  $-1 \geq -\sigma$ , som gir at  $\sigma \geq 1$ . Men dette er ikke kompatibelt med  $\sigma = 10^{-3}$ , som det står i kompendiet. Med andre ord, når  $\nabla^2 f$  er negativ definit kommer vi fort i situasjoner der armijorule går i en uendelig løkke. Dette lager ikke problemer for funksjonen vår siden  $f$  er konveks (positiv definit).

**7 (Oppgave 4.13 a. i kompendiet).** Kjør funksjonen `newtonbacktrack` med  $f$ ,  $f'$ , og  $f''$  som parametre når  $n = 10$  og

$\mathbf{x} = (0.4992, -0.8661, 0.7916, 0.9107, 0.5357, 0.6574, 0.6353, 0.0342, 0.4988, -0.4607)$

Bruk startverdi  $\alpha_0 = 0$  for Newtons metode. Husk at du kan sende inn en funksjon som  $f(x) = x^2$  som parameter ved å sende med  $@(x) x.^2$  som parameter. Hvilket estimat for minimumspunktet til  $f$ , og dermed til  $\alpha$ , fikk du?

**Løsningsforslag:** Med  $\mathbf{x}$  og  $f$  definert som over så kan denne oppgaven løses slik:

```
x=[0.4992; -0.8661; 0.7916; 0.9107; 0.5357; 0.6574; 0.6353; 0.0342; 0.4988; -0.4607];
[xopt,numit]=newtonbacktrack(...
    @(alpha) (-sum(log(1+alpha*x)/2) ),...
    @(alpha) (-sum(x./(1+alpha*x)) ),...
    @(alpha) ( sum( x.^2./(1+alpha*x).^2 ) ),...
    0)
```

Svaret vi får da blir 0.7230.

De ti punktene over ble generert fra en sannsynlighetsfordeling der  $\alpha = 0.5$ . Svaret du fikk i Oppgave 5 viste seg å være gansk langt fra dette. La oss også se på hvor mange måleverdier vi bør bruke for å få ganske presise estimater på  $\alpha$ . Du kan bruke funksjonen

```
function ret=randmuon(alpha,m,n)
```

til å generere en  $m \times n$ -matrise med måleverdier generert etter en sannsynlighetsfordeling med gitt verdi for  $\alpha$ . Denne funksjonen kan du finne på det vanlige området for matlabkode for kurset.

**8 (Oppgave 4.13 b. i kompendiet).** Med  $\alpha = 0.5$ , generer  $n = 10$  måleverdier ved hjelp av funksjonen `randmuon`, og finn maximum-likelihood-estimatet som over. Gjenta dette ti ganger, og plott de ti estimatene du har fått. Gjenta for  $n = 1000$ ,

og for  $n = 100000$  (i alle tilfellene skal du altså plote 10 maximum-likelihood estimator). Hvor mange måleverdier trenger vi for å få en pålitelig maximum-likelihood estimator for  $\alpha$ ?

**Løsningsforslag:** De ti estimatene vi får for  $n = 10$ ,  $n = 1000$ , og  $n = 100000$  kan plottes slik:

```
for ant=[10 1000 100000]
    pts=zeros(1,10);
    for z=1:10
        x=randmuon(0.5,ant,1);
        [xopt,numit]=newtonbacktrack(...
            @(alpha) (-sum(log(1+alpha*x)/2) ),...
            @(alpha) (-sum(x./(1+alpha*x)) ),...
            @(alpha) ( sum( x.^2./(1+alpha*x).^2 ) ),...
            0);
        pts(z)=xopt;
    end
    plot(pts);
end
```

Vi ser fra figurene vi da får at det er først for  $n = 100000$  at maximum-likelihood estimatene begynner å bli ganske pålitelige.