

## INF 2310 – 15. mai 2019

### Segmentering ved terskling

#### Kap 10.3

- Global terskling
- Generelle histogramfordelinger og klassifikasjonsfeil
- To populære tersklingsalgoritmer
- Bruken av kanter, og effekten av "støy" og glatting
- Lokal terskling

Disse notatene er basert på F. Albrechtsens segmenteringsnotater fra 2016. Originalnotatene fra 2016 inneholder mange interessante detaljer, og de anses som kursorisk pensum!

2019.05.15

INF 2310

1

## Segmenterings-problemer

- Problemet blir banalt hvis vi bare har en objekt-region, og denne er homogen.
- Men vi har som regel flere objekter i bildet.
- Objektene er sjelden helt like, selv om de er av samme type.
- Ofte har vi flere typer/klasser av objekter samtidig.
- Belysningen kan variere over bildet.
- Refleksjon, farge etc. kan variere over objekter i bildet.



Hva og hvor er objektet i dette bildet?

2019.05.15

INF 2310


3

## Dagens verktøy: Terskling

- Hvis vi har grunn til å anta at objektene f.eks. er lysere enn bakgrunnen, kan vi sette en terskel  $T$  og lage oss et binært ut-bilde  $g(x,y)$  ved mappingen:

$$g(x,y) = \begin{cases} 0 & \text{hvis } f(x,y) \leq T \\ 1 & \text{hvis } f(x,y) > T \end{cases}$$

- Da har vi fått et ut-bilde  $g(x,y)$  med bare to mulige verdier.
- Vi tolker nå piksler med  $g(x,y)=1$  som objekt-piksler.
- Vi har gjort en global pikselvis *klassifikasjon* basert på pikselintensitet alene





2019.05.15

INF 2310

5

## Hva er segmentering?

- Segmentering er en prosess som deler opp bildet i meningsfulle regioner.
- Segmentering er et av de viktigste elementene i et komplett bildeanalyse-system.
- I segmentering får vi fram regioner og objekter som senere skal beskrives og gjenkjennes.
- I det enkleste tilfellet har vi bare to typer regioner:
  - Forgrunn
  - Bakgrunn



Eksempel:  
finne symboler for OCR

2019.05.15

INF 2310

2

## To segmenterings-kategorier

- Vi skiller mellom to kategorier av metoder, basert på hhv. likhet og diskontinuitet mellom pikslene i bildet.
1. Ved terskling og region-basert segmentering får vi fram de pikslene som ligner hverandre.  
Dette gir alle pikslene i objektet.
  2. Ved kant-basert segmentering finner vi basis-elementer i omrisset til objektene:
    - Kant-punkter, linje-punkter, hjørne-punkter..
    - I neste steg:
      - Tynner brede kanter
      - Lenker punktene sammen



2019.05.15

INF 2310

4

## Terskling, eksempel

- Anta at et bilde har to intensitets-områder: forgrunn og bakgrunn.
- Histogrammet vil da vise to topper, gjerne med et "dalsøkk" mellom.
- Avhengig av hvor mye forgrunn vi har i forhold til bakgrunn, kan det hende vi ikke ser to topper.
- **Nøkkelsspørsmål:** *Hvor skal vi legge terskelen?*




2019.05.15

INF 2310

6

## Tersking av egenskapsbilde


- Tersking er ofte noe som gjøres på et bilde hvor teksturegenskapene til objektene vi er interessert i har blitt fremhevet



Mer om dette i INF4300!


## Pikselklassifikasjon basert på gråtone

- Anta at vi har histogrammene til bakgrunn og forgrunn hver for seg, henholdsvis  $h_1$  og  $h_2$ 
  - Histogrammet for hele bildet er da  $h=h_1+h_2$
- La oss så klassifisere pikselene *kun basert på gråtone*
  - For hver gråtone må vi bestemme om en slik piksel skal klassifiseres til forgrunn eller bakgrunn
  - Minimerer totalt antall feilklassifiserte piksler om vi velger "forgrunn" for en intensitet "i" om  $h_2(i) > h_1(i)$  (**Hvorfor?!**)
  - Da vil antall feilklassifiserte piksler være  $\sum_{i=0}^{255} \min\{h_1(i), h_2(i)\}$



## Mulig fremgangsmåte: Finn $h_1$ og $h_2$

- Har vi  $h_1$  og  $h_2$  har vi altså alt vi trenger
- En mulig fremgangsmåte kan da være å anta enkle fordelinger for  $h_1$  og  $h_2$ , og å finne de parametrene som gir modellhistogrammer som til sammen tilnærmer h best mulig
- Eksempelvis, anta to Gauss-fordelinger og tilpass:



Summen av de to Gauss-kurvener passer rimelig godt til det observerte histogrammet (blå linje)

Piksler med intensitet hvor rødt > grønt blir klassifisert til bakgrunn

En populær algoritme for slik tilpassning kalles expectation-maximization (EM) (ikke pensem i dette kurset!)

- Vi skal se på en enklere variant hvor vi tilpasser to likefremmede Gauss-fordelinger ved å kun endre middelverdiene (Riddler & Calvards metode og Otsus metode)

## Noen begreper relatert til histogrammer

- La  $p_1(i)$  og  $p_2(i)$  være **normaliserte** bakgrunns- og forgrunns-histogrammer
- La  $F$  og  $B$  være **a priori sannsynlighet** for bakgrunn og forgrunn ( $B+F=1$ )
- Det normaliserte histogrammet til bildet kan da skrives

$$p(i) = B \cdot p_1(i) + F \cdot p_2(i)$$


- Vi har selvfølgelig  $h = (NM)p$ ,  $h_1 = (NM)Bp_1$  og  $h_2 = (NM)Fp_2$  der NM er antall piksler i bildet

Merk: På noen av notatene er  $f(i)$  normalisert forgrunns-histogram, og  $b(i)$  normalisert bakgrunns-histogram

## Klassifikasjonsfeil ved tersking

- Andelen feilklassifiserte piksler:
  - Andelen forgrunns-piksler klassifisert som bakgrunns-piksler pluss andelen bakgrunns-piksler klassifisert som forgrunn
- For en gitt terskel  $t$ :

$$E(t) = F \int_{-\infty}^t p_2(z) dz + B \int_t^{\infty} p_1(z) dz$$



(Benytter ofte kontinuerlige variable, da våre histogrammodeller ofte er definert for slike, jfr. normalfordelingen)

## Finn den T som minimerer feilen

$$E(t) = F \int_{-\infty}^t p_2(z) dz + B \int_t^{\infty} p_1(z) dz$$

- $E(t)$  vil alltid ha et minimum der kurvene for forgrunns- og bakgrunns-histogrammer krysser hverandre (hvorfor?)
- Kan også sette den deriverte lik 0 og vi får:


$$\frac{dE(t)}{dt} = 0 \Rightarrow F \cdot p_2(t) = B \cdot p_1(t)$$

VIKTIG!


- Merk at dette er en generell løsning som gir minst feil.
- Det er ingen restriksjoner mht. fordelingene  $p_1$  og  $p_2$

## Studie av to Gauss-fordelinger


- To Gauss-fordelinger med samme standardavvik,  $\sigma$ .
- $D = \mu_2 - \mu_1$
- Like a priori sannsynligheter.
- D avgjør om vi ser to toppler.



- Ulike a priori sannsynlighet.
- D avgjør om vi ser to toppler.



- Veldig ulike sannsynligheter.
- Selv ved stor verdi for D ser vi ikke to toppler.




2019.05.15

INF 2310


13

## To Gauss-fordelinger II

- Et eksempel:
- To Gauss-fordelinger
  - bakgrunn:  $\mu_1 = 16$ ,  $\sigma_1 = 3$
  - forgrunn:  $\mu_2 = 36$ ,  $\sigma_2 = 8$



- Normaliserte histogrammer:



- Skalerer med **a priori** sannsynligheter, f.eks.  $P_1 = 0.2$ ,  $P_2 = 1 - P_1 = 0.8$

- Dette kan forskyve både
  - minimum i bildets histogram
  - skjæringspunktet mellom fordelingene

2019.05.15

INF 2310

14

## Tersking av to Gauss-fordelinger

- Anta at bakgrunns- og forgrunns-intensitetene følger hver sin Gauss-fordeling,  $b(z)$  og  $f(z)$ , slik at det normaliserte histogrammet kan skrives som

$$p(z) = \frac{B}{\sigma_B \sqrt{2\pi}} e^{-\frac{(z-\mu_B)^2}{2\sigma_B^2}} + \frac{F}{\sigma_F \sqrt{2\pi}} e^{-\frac{(z-\mu_F)^2}{2\sigma_F^2}}$$

- $F$  og  $B$  er a priori sannsynligheter for for- og bakgrunn
- $\mu_B$  og  $\mu_F$  er middelveidene for bakgrunn og forgrunn.
- $\sigma_B^2$  og  $\sigma_F^2$  er variansen for bakgrunn og forgrunn.

2019.05.15

INF 2310

15

## Optimal løsning – to Gauss-fordelinger

- Vi vet at optimal løsning ligger der hvor  $F \cdot f(T) = B \cdot b(T)$

- Vi setter inn for  $b(z)$  og  $f(z)$ :  $\frac{F}{\sigma_F \sqrt{2\pi}} e^{-\frac{(T-\mu_F)^2}{2\sigma_F^2}} = \frac{B}{\sigma_B \sqrt{2\pi}} e^{-\frac{(T-\mu_B)^2}{2\sigma_B^2}}$

- Vi kan stryke  $\sqrt{2\pi}$  og ta logaritmen:  $\frac{(T-\mu_F)^2}{2\sigma_F^2} - \ln\left(\frac{F}{\sigma_F}\right) = \frac{(T-\mu_B)^2}{2\sigma_B^2} - \ln\left(\frac{B}{\sigma_B}\right)$

- Dette gir en annengrads-ligning i  $T$ :  $(\sigma_B^2 - \sigma_F^2)T^2 + 2(\mu_B\sigma_F^2 - \mu_F\sigma_B^2)T + \sigma_B^2\mu_F^2 - \sigma_F^2\mu_B^2 + 2\sigma_B^2\sigma_F^2 \ln\left(\frac{B\sigma_F}{F\sigma_B}\right) = 0$

- Vi kan altså få to løsninger for  $T$ .**

2019.05.15


INF 2310

16

## To terskler – når kan det skje?

- Hvis standardavvikene i de to Gauss-fordelingene er forskjellige
  - og skjæringspunktene mellom fordelingene (skalert med a priori sannsynlighet) ligger innenfor gråtoneskalaen i bildet

- En terskelverdi for hvert skjæringspunkt.



- Det er bare mellom de to tersklene at flertallet av pikslene er bakgrunns piksler!

2019.05.15

INF 2310

17

## Hvor ligger optimal terskel?

- Vi har en annengrads-ligning i  $T$ :

$$(\sigma_B^2 - \sigma_F^2)T^2 + 2(\mu_B\sigma_F^2 - \mu_F\sigma_B^2)T + \sigma_B^2\mu_F^2 - \sigma_F^2\mu_B^2 + 2\sigma_B^2\sigma_F^2 \ln\left(\frac{B\sigma_F}{F\sigma_B}\right) = 0$$

- Hvis standard-avvikene i de to fordelingene er like ( $\sigma_B = \sigma_F = \sigma > 0$ ) får vi en enklere ligning:

$$2(\mu_B - \mu_F)T - (\mu_B + \mu_F)(\mu_B - \mu_F) + 2\sigma^2 \ln\left(\frac{B}{F}\right) = 0$$

$$\Downarrow$$

$$T = \frac{(\mu_B + \mu_F)}{2} + \frac{\sigma^2}{(\mu_B - \mu_F)} \ln\left(\frac{F}{B}\right)$$

- Hvis a priori sannsynlighetene  $F$  og  $B$  er omtrent like har vi en veldig enkel løsning:

$$T = \frac{(\mu_B + \mu_F)}{2}$$

(Jfr Riddler & Calvards metode)



2019.05.15

INF 2310

18

## Hvis vi nå bare antar at $P_1 = P_2 \dots$

- Et lite eksempel:
- For  $\mu_1 = 20$  og  $\mu_2 = 44$ , med  $\sigma_1 = \sigma_2 = 8$ , så vil  $T = (\mu_1 + \mu_2)/2 = 32$  være en OK terskel, selv om  $P_1 = 0.6 \neq P_2$ .
- For  $P_1 = 0.9 \neq P_2$  vil feilen bli ganske stor.



2019.05.15

INF 2310

19

## Otsus metode:

### Likeformet Gausstilpasning direkte søk

- **Bakgrunnstankegang:** Anta at bildet inneholder to populasjoner av piksler, slik at pikslene innenfor hver populasjon er noenlunde like, mens populasjonene er forskjellige.
- **Målsetting:**
  - Let igjennom alle gråtonene, og finn en terskel  $T$  slik at hver av de to klassene som oppstår ved tersklingen blir mest mulig homogene, mens de to klassene blir mest mulig forskjellige.
  - Klassene er homogene: **variansen i hver av de to klassene er minst mulig.**
  - Separasjonen mellom klassene er stor: **avstanden mellom middelveidene er størst mulig.**

2019.05.15

INF 2310

21

## Otsus metode – II/II

- $\sigma_w^2(t) + \sigma_b^2(t) = \sigma_{tot}^2$  og er uavhengig av  $t$  (altså konstant)
- Å minimere  $\sigma_w^2(t)$  er altså det samme som å maksimere  $\sigma_b^2(t)$
- Vi kan altså likeså godt maksimere  $\sigma_b^2(t)$  (Ved å prøve alle terskler  $t$ )
- Divideres  $\sigma_b^2(t)$  med totale variansen får vi et kvantitativt mål på separabilitet:

$$\eta(t) = \frac{\sigma_b^2(t)}{\sigma_{tot}^2}, \quad 0 \leq \eta(t) \leq 1$$

2019.05.15

INF 2310

23

## Ridler og Calvards metode: Iterativ tilpasning av likeformede Gausser

- Anta to Gauss-fordelinger med forventninger  $\mu_1$  og  $\mu_2$ , og med  $\sigma_1 \approx \sigma_2$ , og anta  $F \approx B$
  - 1) Vi kjenner ikke den sanne  $\mu_1$  og  $\mu_2$  så vi starter med å gjette på en løsning
  - 2) Beregner så en terskel ved  $T = (\mu_1 + \mu_2)/2$
  - 3) Basert på denne terskelen, finner vi ny  $\mu_1$  og  $\mu_2$  som henholdsvis middelveidene til pikslene under og over terskelen
- Dess mindre modellen passer med dataene, dess mer vil  $\mu_1$  og  $\mu_2$  endre seg
- Gjenta derfor 2) og 3) til den nye terskelen ikke endrer verdi ( $T$  konvergerer)
  - Dette er en enkel og rask måte å finne parametrene  $\mu_1$  og  $\mu_2$  som gir fordelinger som best "passer" histogrammet vårt, jfr. lysark 9
    - Husk at vi antar  $\sigma_1 \approx \sigma_2$  og  $F \approx B$
  - Algoritmen beskrives i DIP s. (746) (også kjente under navnet *k-means*)

2019.05.15

INF 2310

20

## Otsus metode – I/II

- For en gitt terskel  $t$ , la  $\sigma_1^2(t)$  og  $\sigma_2^2(t)$  være variansen til pikslene i henholdsvis bakgrunn og forgrunn, og  $\sigma_b^2(t)$  være (den vektete) variansen til middelveidene:

$$\sigma_1^2(t) = \sum_{i=0}^{t-1} [i - \mu_1(t)]^2 p(i) / P_1(t)$$

$$\sigma_2^2(t) = \sum_{i=t}^{G-1} [i - \mu_2(t)]^2 p(i) / P_2(t)$$

$$\sigma_b^2(t) = P_1(\mu_1 - \mu)^2 + P_2(\mu_2 - \mu)^2$$

- der  $P_1$  og  $P_2$  er sannsynligheten for bakgrunn og forgrunn ( $P_1 =$  antall bakgrunnpiksler/totalt antall piksler i bildet,  $P_2 = 1 - P_1$ ), og  $\mu$  er (den totale) middelveidene i bildet
- Otsu foreslår at vi velger  $t$  som minimerer  $\sigma_w^2(t) = P_1\sigma_1^2(t) + P_2\sigma_2^2(t)$

2019.05.15

INF 2310

22

## Otsus metode; i praksis

- Gitt et  $N \times M$  piksels bilde med  $G$  gråtoner.
- Finn bildets histogram,  $h(k)$ ,  $k = 0, 1, 2, \dots, G-1$ .
- Finn bildets normaliserte histogram:  $p(k) = \frac{h(k)}{MN}$ ,  $k = 0, 1, 2, \dots, G-1$
- Beregn kumulativt normalisert histogram:  $P_i(k) = \sum_{i=0}^k p(i)$ ,  $k = 0, 1, 2, \dots, G-1$
- Beregn kumulativ middelveid,  $\mu(k)$ :  $\mu(k) = \sum_{i=0}^k ip(i)$ ,  $k = 0, 1, 2, \dots, G-1$
- Beregn global middelveid,  $\mu$ :  $\mu = \sum_{i=0}^{G-1} ip(i)$
- Beregn variansen mellom klassene,  $\sigma_b^2(k)$ :  $\sigma_b^2(t) = \frac{[\mu(t) - \mu P_1(t)]^2}{P_1(t)(1 - P_1(t))}$
- Finn terskelen der  $\sigma_b^2(k)$  har sitt maksimum.
- Beregn separabilitetsmålet,  $\eta(t)$ :  $\eta(t) = \frac{\sigma_b^2(t)}{\sigma_{tot}^2}$ ,  $0 \leq \eta(t) \leq 1$


2019.05.15

INF 2310

24

## Effekten av *a priori* sannsynlighet

- Total tersklingsfeil mot  $\log_{10}(P_1/P_2)$  for fire verdier av  $\mu_2 - \mu_1 = D\sigma$ :



- Feilen øker raskt ved  $\log_{10}(P_1/P_2) \approx 1$
- => Otsus metode bør bare brukes når  $0.1 < P_1/P_2 < 10$ .
- Det samme gjelder for Ridler & Calvard.


2019.05.15

INF 2310

25

## Eksempel I

- Gitt et bilde  $f(x,y)$  der objekt-arealet er relativt lite.
- Beregn et kantbilde
  - Enten gradient-magnitude eller absoluttverdi av Laplace.
- Terskle kantbildet med en høy terskel.
  - > "maske-bilde"  $G_T(x,y)$
- Finn histogram av  $f(x,y) \cdot G_T(x,y)$
- Finn optimal terskel med f.eks. Otsu.
- Anvend på  $f(x,y)$ .
- Nær perfekt resultat.



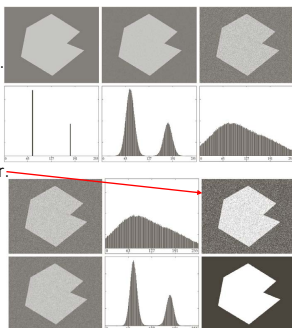
2019.05.15

INF 2310

27

## Effekten av støy i bildet

- Gitt to-nivå gråtonebilde
  - $G=256$ .
  - A priori sannsynligheter  $\approx 0.5$ .
- Støy
  - => Mister bimodalitet.
- Global terskling
  - => Mange feilklassifiserte piksler.
- Støyfjerning + terskling:
  - + Bimodalt histogram => bedre terskling
  - Blurring av bildet => feil langs objekt-kanten.



2019.05.15

INF 2310

29

## Bruk av kant-informasjon

- Hvordan kan vi unngå problemene som følger av at objekt og bakgrunn har ulik *a priori* sannsynlighet?
  - Bruk bare piksler som ligger på eller nær overgangen mellom objekt og bakgrunn.
  - Forholdet mellom a priori sannsynligheter blir da  $\approx 1$ .
- Hvordan gjør vi det?
  - Bruk en gradient-estimator, og terskle resultatet.
  - Bruk en Laplace-operator (nullgjennomgang), og utvid resultatet.
- Dette er egentlig en sirkelslutning:
  - For å forbedre tersklingen av objektet trenger vi objektets omriss.
  - For å avgrense omrisset trenger vi en terskling.


2019.05.15

INF 2310

26

## Eksempel II

- Vi ønsker å finne de lyse strukturene i  $f(x,y)$ .
- Vanskelig histogram:
  - Otsu -> "feil" terskelverdi
- Beregn abs(Laplace)
- Terskle (høy percentil)
  - > "maske-bilde"  $G_T(x,y)$
- Finn histogram av  $f(x,y) \cdot G_T(x,y)$ .
- Finn optimal terskel med f.eks. Otsu.
- Anvend på  $f(x,y)$ .



2019.05.15


INF 2310

28

## Flernivå-terskling

- Har vi flere klasser av objekter med forskjellig intensitet, så kan vi utvide dette til  $M$  gråtone-intervaller ved hjelp av  $M-1$  terskler.

$$g(x,y) = \begin{cases} 0 & \text{hvis } 0 \leq f(x,y) \leq t_1 \\ 1 & \text{hvis } t_1 \leq f(x,y) \leq t_2 \\ \dots & \dots \\ M-1 & \text{hvis } t_{M-1} \leq f(x,y) \leq G-1 \end{cases}$$



2019.05.15

INF 2310

30

## Flernivå Ridler & Calvards metode

- Ridler & Calvards metode kan generaliseres til M terskler:

$$t_{1,k+1} = \frac{\mu(0, t_{1,k}) + \mu(t_{1,k} + 1, t_{2,k})}{2}$$

$$\vdots$$

$$t_{M,k+1} = \frac{\mu(t_{M-1,k}, t_{M,k}) + \mu(t_{M,k} + 1, G-1)}{2}$$

- Nytt sett terskelverdier beregnes til alle terskler er stabile
  - dvs til alle differansene  $|t_{n,k} - t_{n,k-1}|$ ,  $1 \leq n \leq M$ , er mindre enn  $\Delta T$ .
- Prosedyren konvergerer vanligvis raskt.

2019.05.15

INF 2310

31

## Flernivå Otsu-terskling

- Maksimeringskriteriet til Otsu,  $\sigma_B^2$ , kan generaliseres til M klasser (altså M-1 terskler):

$$\sigma_B^2(t_1, t_2, \dots, t_{M-1}) = \sum_{k=1}^M P_k (\mu_k - \mu)^2$$

- Finn de M-1 tersklene  $t_1 > t_2 > \dots > t_{M-1}$  som maksimerer uttrykket over

2019.05.15

INF 2310


32

## Global, variabel eller adaptiv?

- Global terskling :
  - Samme verdi for T over hele bildet.
- Variabel terskling:
  - Verdien av T varierer over bildet.
- Lokalt adaptiv terskling:
  - T beregnes fra bildets lokale egenskaper ( $\mu$ ,  $\sigma$ , ...)



Ved Otsus metode:




2019.05.15

INF 2310

33

## Eksempel – bimodalitet i lokale vinduer



Bimodal, ca 1:1

Bimodal, skjevt forhold

Unimodal

2019.05.15

INF 2310

34

## Adaptiv terskling ved interpolasjon

- Globale terskler gir ofte dårlig resultat.
- Globale metoder kan benyttes lokalt.
- Dette virker ikke der vinduet bare inneholder en klasse!
- Mulig oppskrift:
  - NIVÅ I:** Del opp bildet i del-bilder
    - For del-bilder med bi-modalt histogram, eller som for eksempel har godt Otsu-separasjonsmål:
      - Finn lokal terskelverdi  $T_{\text{lokal}}(i,j)$
  - NIVÅ II:** Piksel-for-piksel interpolasjon:
    - Gå gjennom alle piksel-posisjoner
      - bestem adaptiv terskelverdi  $T(x,y)$  ved interpolasjon mellom de lokale terskelverdiene  $T_{\text{lokal}}(i,j)$ .
    - Terskle så hvert piksel  $(x,y)$  i bildet i terskelverdiene  $T(x,y)$ .

2019.05.15

INF 2310

35

## En enklere adaptiv metode

- En metode som benytter det dere lærte i forelesningen om gråtonetransformer
- Beregn middelerverdi og standardavvik innenfor et glidende  $(n \times n)$  vindu over hele bildet.

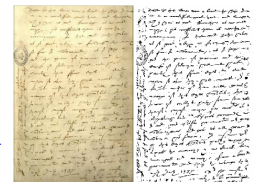
- Nieblacks metode:** Sett den lokale terskelverdien til

$$t(i, j) = \mu(i, j) + k \sigma(i, j)$$

- La ut-bildet være gitt ved

$$g(i, j) = \begin{cases} 0 & \text{hvis } f(i, j) \leq t(i, j) \\ 1 & \text{hvis } f(i, j) > t(i, j) \end{cases}$$

- Ex.: for  $w = 31$ ,  $k = -0.8$  :



2019.05.15

INF 2310

36

# Oppsummering terskling

---

- Generelle histogramfordelinger og klassifikasjonsfeil
  - Har vi  $h_1$  og  $h_2$  har vi alt: forgrunn der  $h_2(i) > (h_1)$   
altså der  $F * p_2(i) > B * p_1(i)$
  - Terskling og (lokale) klassifikasjonsfeilminima der  $h_1(i) = h_2(i)$
- To vanlige globale tersklingsalgoritmer:
  - Ridler og Calvards metode (anta likeformede Gausser og tilpass iterativt)
  - Otsus metode (anta og søk etter homogenitet innad i klassene)
  - Hvilke betingelser må være oppfylt? Når feiler de?
- Ulik apriori sannsynlighet og bruken av kantinformasjon
- Effektene av "støy" og bruken av lavpassfilter
- Flernivå-terskling
- Lokale adaptive metoder
  - Håndtere mangel på lokal bimodalitet