

**UNIVERSITETET I OSLO**  
**Institutt for informatikk**

**Overflateanalyse av  
trevirke for å skille  
mellom marg- og  
yteside**

Hovedoppgave

Werner Bjerke

2. april 2007



## Sammendrag

Denne hovedfagsoppgaven tar for seg metoder innen bildeanalyse for å skille marg- og yteside på limtrelameller slik at disse kan vendes korrekt i forkant av sammenliming til limtrebjelker. Limtrebjelkene vil dermed ikke bli så utsatt for sprekkdannelser grunnet kuing. En har i oppgaven lagt hovedvekt på analyse av årringsmønsteret siden trevirket alltid inneholder årringer til forskjell fra en del andre mulige egenskaper. En kan da også forutsi hvilken vei lamellen vil kuve og er således, til forskjell fra dagens systemer, ikke avhengig av at kuingen er igang.

Siden lamellene er uhøvlede er flatene i stor grad preget av støy, hovedsakelig i form av opprevete fibre, som kan ha vesentlig større kontrast enn årringsmønstrene og i tillegg svært varierende form/størrelse. En av hovedutfordringene har vært å skille årringsmønstrene fra denne.

En har funnet en algoritme som fjerner de mest støyfylte regionene fra den videre prosesseringen for å redusere datamengden på et tidlig stadium. I den videre analysen har en fokusert på to prinsipielle hovedretninger. Den ene har gått ut på å finne en egnet algoritme for å segmentere vårvedsområdene fra sommervedsområdene, og så måle antall årringer og årringsbredder direkte, mens den andre har sett på yte- og margsidene som ulike teksturregioner (texels), og har prøvd å finne teksturmål som kan diskriminere disse.

For førstnevnte hovedretning har en oppnådd lovende resultater ved å utnytte årringsmønstrenes form og orientering til å utvikle en adaptiv filtreringsalgoritme der valg av filterstørrelse er estimert utfra filtrenes respons i en projisert linjevektor. En har videre benyttet probabilistisk relaksasjon som ytterligere bildeforbedringssteg og linking av årringsregioner, samt projeksjon ned til én dimensjon før segmentering.

I sistnevnte hovedretning har en funnet at egenskapsuttrekning fra Gray Level Run Length Matrisen ga lovende resultater. Dette gjaldt både for egenskaper målt over manuelt avgrensede regioner og for adaptiv egenskapsuttrekning basert på klasseavstand- og klassesdifferanse-matrise anvendt på konkatenererte matriser.

En har gjort en Bayesiansk klassifikasjon for kombinasjoner av egenskaper. Siden én lamells yte kan være en annens marg har en først transformert dataene til nye klasser der en benytter differanser eller konkatenererte matriser. En oppnådde 100% korrekt klassifikasjon for flere av metodene basert på 1-2 egenskaper, dog med et datasett som kun besto av 25 prøver.

I tillegg til rettvending av limtrelameller kan flere av metodene ha potensiell anvendelse innenfor en rekke andre områder der en ønsker å detektere årringer på ubehandlet trevirke, slik som papirproduksjon, dendrokronologi, styrkeberegninger, møbelproduksjon, panelproduksjon etc.

# Kapittel 1

## Innledning

Dette er en hovedfagsoppgave utført av Werner Bjerke på studieretning for matematisk modellering ved Institutt for Informatikk, Universitetet i Oslo. Veileder for oppgaven er Professor Fritz Albrechtsen ved DSB-gruppen (Digital Signalbehandling og Bildeanalyse) på Institutt for Informatikk.

Oppgaven tar sikte på å utvikle metoder for automatisk å kunne diskriminere mellom marg- og yteside på limtrelameller ved hjelp av bildeanalyse. En har valgt å konsentrere seg om analyse av årringsmønsteret som diskriminant mellom de respektive sider. En nærmere begrunnelse for dette valget er gitt i kap 2.2 på side 7. Store deler av oppgaven vil således omfatte metoder for robust deteksjon av årringene i den støyfylte irregulære bakgrunnen som uhøvlet/ubehandlet trevirke representerer. Metodene som brukes vil kunne anvendes ved en rekke andre områder innen treforedling og analyse av tre, slik som papirproduksjon, panelproduksjon, kvalitetssortering, styrkeberegninger, dendrokronologi (årringsdateringer), dendroklimatologi, etc. Anvendelser innen noen av disse alternative områdene vil også til en viss grad bli nærmere skissert.

Ettersom en har som målsetning at algoritmene som er utviklet i denne oppgaven skal implementeres i et sanntids maskinsynssystem montert i løpende produksjon, er det lagt vekt på benytte metoder som ikke er for krevende prosesseringsmessig og/eller metoder som enkelt lar seg implementere i maskinvare.

Jeg vil gjerne få takke veileder Fritz Albrechtsen som har kommet med mange gode, kreative innspill gjennom hele oppgaven og hatt en stor faglig tyngde som har vært betryggende å støtte seg på. Jeg vil også takke for at han har vist stor tålmodighet og forståelse for at fremdriften i oppgaven periodevis har vært liten grunnet en krevende fulltidsjobb ved siden av studiet. Firmaet jeg jobber i heter ELOP AS og vi leverer maskinsynsystemer for kvalitetskontroll innen industrien. Denne hovedfagsoppgaven ble til etter kontakt med en kunde som la fram et behov

for et bedre system enn deres eksisterende mekaniske enhet for rettvending av limtre lameller.

# Innhold

<b>1</b>	<b>Innledning</b>	<b>1</b>
<b>2</b>	<b>Bakgrunn</b>	<b>6</b>
2.1	Limtre-produksjon . . . . .	6
2.2	Valg av diskriminant mellom marg- og yteside . . . . .	7
<b>3</b>	<b>Systembeskrivelse og bildefangst</b>	<b>14</b>
3.1	Bildefangst . . . . .	15
3.2	Belysning . . . . .	17
3.3	Bildemateriale og prøver . . . . .	20
<b>4</b>	<b>Problemanalyse</b>	<b>21</b>
4.1	Visuell vurdering av bildemateriale . . . . .	21
4.1.1	Årringenes distribusjon . . . . .	21
4.1.2	Årringenes karakteristiske egenskaper . . . . .	22
4.2	Kvantitativ analyse . . . . .	22
4.2.1	Histogram . . . . .	22
4.2.2	Histogram utjevning . . . . .	23
4.2.3	Linjeprofiler . . . . .	25
4.2.4	Korreksjon for ujevn belysning . . . . .	25
4.3	Diskusjon . . . . .	27

<i>INNHOLD</i>	4
<b>5 Preprosessering</b>	<b>29</b>
5.1 Lokalisering av beste region for videre prosessering . . . . .	29
5.1.1 Midlere kolonnevise standardavvik som støymål . . . . .	30
5.1.2 Maksimering av standardavvik i projeksjon . . . . .	30
5.1.3 Fjerning av mørke regioner . . . . .	31
5.2 Rotasjon av bildet . . . . .	34
5.2.1 Teori . . . . .	34
5.2.2 Diskusjon av resultater . . . . .	35
5.3 Støyreduksjon . . . . .	37
5.3.1 Midling og median-filtrering . . . . .	37
5.3.2 KNN- og KNCN støyfiltrering . . . . .	40
5.4 Kantfiltrering . . . . .	43
5.4.1 Canny's kantfiltreringsalgoritme . . . . .	47
5.5 Linjefiltrering . . . . .	48
5.5.1 Diverse Linjeoperatorer . . . . .	48
5.5.2 Annenderivert av Gaussisk operator . . . . .	51
5.5.3 Linjeprojsjon . . . . .	54
5.5.4 Vindusstørrelser og adaptivitet . . . . .	54
<b>6 Segmentering</b>	<b>57</b>
6.1 Global terskling av 2D bilde . . . . .	57
6.2 Global terskling av linjefiltrert 2D bilde . . . . .	57
6.3 Global terskling av 1D projeksjon . . . . .	61
6.4 Lokal adaptiv terskling av 1D projeksjon . . . . .	62
6.4.1 Metode basert på middelverdi og vektet standardavvik . .	62
6.4.2 Bernsens metode . . . . .	62
6.5 Relaksasjon . . . . .	73
6.5.1 Probabilistisk relaksasjon . . . . .	73
6.5.2 Diskusjon og resultater . . . . .	76
6.6 Dual watershed segmentering . . . . .	81
6.7 FFT-basert segmentering . . . . .	82
6.8 Diskusjon av tersklingsmetoder . . . . .	86

<i>INNHold</i>	5
<b>7 Egenskapsuttrekning</b>	<b>88</b>
7.1 Årringstelling og midlere årringsbredder . . . . .	88
7.2 Periodiske egenskaper . . . . .	94
7.2.1 Diskret Fourier transform . . . . .	94
7.2.2 DFT for simulerte årringsmønstre . . . . .	95
7.2.3 Initielle tester med 2D DFT . . . . .	97
7.2.4 Uttrekning av egenskaper fra DFT . . . . .	99
7.2.5 DFT på preprosessert 1D projeksjon . . . . .	106
7.3 Høyere ordens statistikk . . . . .	108
7.3.1 Gray Level Gap Length Matrix . . . . .	109
7.3.2 Gray Level Run Length Matrix . . . . .	111
7.4 GLRLM på preprosesserte bilder . . . . .	128
7.5 Kombinasjon av flere egenskaper . . . . .	131
7.5.1 Klassifikasjon basert på kombinasjon av flere egenskaper .	136
7.6 Overordnet logikk for beslutning om hva som er yte- og margside	142
7.7 Egenskapsutvelgelse . . . . .	143
7.8 Diskusjon og andre deskriptorer . . . . .	145
<b>8 Andre anvendelser</b>	<b>148</b>
<b>9 Konklusjon</b>	<b>151</b>
<b>Appendikser</b>	<b>160</b>
<b>A Bildemateriale</b>	<b>161</b>
<b>B Manuelt målt avstand til marg</b>	<b>172</b>

# Kapittel 2

## Bakgrunn

### 2.1 Limtre-produksjon

Norsk Limtrekontrolls definisjon av limtre er som følger:

*Med “limtre” forstås limte bærende trekonstruksjoner hvor ethvert tverrsnitt er oppbygd av et antall (minst fire) lameller med tilnærmet parallell fiberretning som ved hjelp av lim er brakt til fullt statisk samvirke [24].*

Normalt anvendes det til limtre granvirke sortert i henhold til regler fastlagt av Norsk Limtrekontroll, men for konstruksjoner som i lengre perioder kan bli utsatt for væte anvendes trykkimpregnert furuvirke ([24] s.13 og 15).

Ved sammenliming av limtre ønsker en at marg og yteside på hver enkelt lamell skal ha en bestemt orientering, for å oppnå maksimale styrkeegenskaper, og å forhindre sprekkdannelse i det ferdige produktet. Som figur 2.1 på side 8 viser har alle lamellene i limtrebjelken samme orientering, bortsett fra den øverste lamellen som er snudd slik at dennes yteside er vendt mot den underliggende lamellens yteside.

Årsaken til dette er at idet lamellene tørkes lenger ned enn til fibermetningspunktet [40], vil en få en krymping av trevirket. Denne krympingen er ulik i trevirkets tre hovedretninger (tangentielt og radielt med årringene i endevenden, samt i stokkens lengderetning), og vil således føre til en formendring av trevirket [40]. For lameller skåret ut av stokken slik figur 2.3 på side 10 illustrerer vil denne formendringen typisk gi en konkav yteside og en konveks margside, slik vist i figur 2.1 på side 8. En kan illustrativt si at årringene i trevirket “søker etter å rette



seg ut". Siden ytesidene er vendt mot hverandre, vil da flatene komme i press mot hverandre, og således motvirke videre kuving som kan føre til sprekkdannelse.

I dagens produksjonslinje benytter Moelven Limtre seg av en kontrollmekanisme basert på en mekanisk bryter, slik figur 2.2 på neste side illustrerer, for å sjekke hvilken vei kuven går på lamellen.

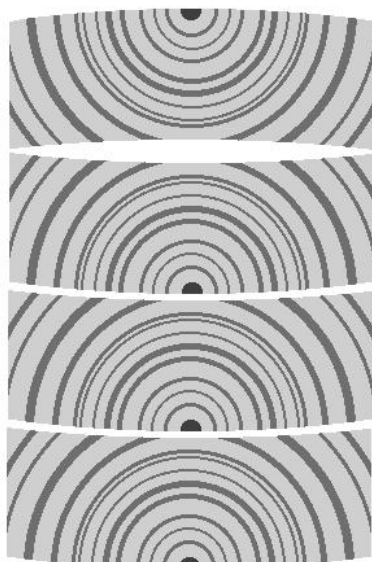
Hvis den bøyelige metallplaten kommer i kontakt med bryterne er krumningen konkav, hvilket vil si at ytesiden vender opp. Dette gir så et signal til en mekanisk bryter som vender om å snu lamellen. I denne stasjonen blir alle lamellene snudd samme vei. Vendingen yte mot yte for den øverste lamellen i limtrebjelken gjøres idag manuelt. Brytersystemet for kontroll av kuv har vist seg velegnet for større bordbredder, men for smalere lameller ( $< 110\text{mm}$ ), har systemet vært mindre pålitelig siden høydeforskjellen mellom midten og kantene da ikke er så betydelig. Siden systemet kun kontrollerer en av flatene vil det heller ikke detektere tilfellet der margen befinner seg inne i lamellen, og begge flater vil ha en konveks kuv. Ved Moelven Limtre er (på dette stadiet i produksjonen) de aktuelle bredder i området 90 - 230 mm. Figur 2.3 på side 10 viser hvordan limtre lamellene typisk skjæres ut av tømmerstokken ved sagbrukene.

## 2.2 Valg av diskriminant mellom marg- og yteside


Ved limtreproduksjon er det som nevnt ønskelig å finne ut om lamellene ligger med marg- eller yteside vendt opp når de kommer på produksjonsbåndet.

Det finnes en rekke egenskaper ved lamellene en kan tenke seg å måle for å kunne ta en slik avgjørelse. En vil her diskutere noen plausible egenskapsmål, og argumentere for det som er valgt.

En mulighet for å skille mellom marg- og yteside er å se på *kuven* til lamellene. Dette er det målet som brukes ved den nåværende mekaniske kontrollen ved Moelven Limtre. Etersom bord som er skåret fra en tømmerstokk gradvis vil få en krumning under tørking av trevirket (jmf. kap. 2.1 på forrige side), vil ytesiden ha en konkav krumning, mens margsiden vil være konveks. En mulig videreføring av dette i form av et maskinsynsystem, vil da være å avbilde endevenden på lamellene og måle kuven ved hjelp av bildeanalyse. En bør her kunne oppnå vesentlig mer nøyaktige målinger med et slik system enn dagens mekaniske brytere, og en vil kunne detektere tilfellet der margen befinner seg inne i lamellen, men en er her (som ved tidligere system) selvfølgelig avhengig av at det faktisk finnes en kuv av en viss betydning på endeflatene. Graden av kuv vil være avhengig av flere faktorer som trefuktighet, tid siden kapping, tørkevilkår, materialtykkelse og -bredde, avstand til marg m.m.[40]. Selv om dette er faktorer som er relativt godt



Figur 2.1: *Lamellenes orientering ved oppbygning av en limtre-bjelke*



Figur 2.2: *Prinsippskisse av eksisterende system for rettvending av bord ved Moelven Limtre.*


kontrollerte i dagens produksjon, kan det allikevel oppstå avvik som kan føre til at lameller uten kuv presenteres for systemet. I tillegg er det visse rent praktiske problemer med å avbilde endeflatene i langsgående produksjon, som er det mest brukte i limtreproduksjonen.

For å unngå å være avhengig av tverrgående produksjon ved bildefangstpunktet er det mulig å benytte seg av strukturert belysning [27], for eksempel ved hjelp av en linjelaser montert i en viss vinkel i forhold til kamera. Skjæringslinjen mellom laserplanet og lamelloverflaten vil da sees som en krum linje fra kameraets posisjon, dersom det finnes kuv i lamellen. Prinsippet er illustrert i figur 2.4 på neste side. En har med denne metoden mulighet til å få vesentlig flere målepunkter, og kan montere systemet i langsgående produksjon, men er som sagt fremdeles avhengig av at det er en viss kuv (noe det jo ikke vil være f.eks. umiddelbart etter skjæring).


Et annet tenkelig egenskapsmål kan være å se på kvistenes dimensjon på over- og undersiden av lamellene. Siden kvisten vokser samtidig med treet vil tverrsnittet av denne være mindre på margsidene enn ytesiden. Bruken av et slikt mål betinger imidlertid selvfølgelig at det finnes kvist på alle lamellene, noe som ikke nødvendigvis er tilfelle.

En tredje diskriminerende egenskap for marg- kontra yteside på lamellene er da årringene (jmf. figur 2.5 på side 11). Til forskjell fra forannevnte kvist finnes det alltid årringer i trevirket. En kan også her forestille seg muligheten for bildefangst av såvel endeflaten som over- og undersiden av lamellen. Når det gjelder den førstnevnte metoden kan en da tenke seg at en prøver å lokalisere årringene i endeveden, og analyserer hvilken vei disse kuver. Problemet med denne metoden, i tillegg til de rent praktiske nevnt tidligere, er at siden en kun har muligheten til å se et enkelt tverrsnitt av lamellen, er en avhengig av at det er mulig å oppnå tilstrekkelig pålitelig deteksjon av årringene basert på kun dette bildet. En kan for eksempel tenke seg at sagflaten er så flisete og/eller skitten at det er umulig å detektere årringene.


Ved bruk av den sistnevnte metoden kan en tenke seg at en detekterer og teller antall årringer på de respektive flatene. Den flaten med flest årringer vil da være margsidene, slik figur 2.3 på neste side illustrerer. I tillegg til antallet kan en her også se på årringsbreddene som tilsvarende vil være større for ytesiden enn margsidene. Fordelen med denne metoden kontra den forrige er at en her har muligheten til å gjøre målinger langs hele lamellens lengde, hvilket sterkt øker sannsynligheten for at en skal få et bildeutsnitt som ikke er ødelagt av skitt og ekstremt flisete sagflater. En står i tillegg mer fritt når det gjelder plassering i produksjonslinjen. En klar ulempe er imidlertid at en her er avhengig av to kameraer, hvilket øker systemkostnaden, vanskeliggjør montering i produksjonslinjen, samt tilnærmet



Figur 2.3: *Utnyttelse av stokken ved kapping av bord som skal benyttes til limtreproduksjon. Bordene med skraverte endeflater, ut mot yten av stokken, brukes ikke av Moelven Limtre.*



Figur 2.4: *Illustrasjon som viser prinsippet bak strukturert belysning fra [22] til venstre. Prinsippet anvendt på en limtrelamell til høyre. Margside er her øverst og yte nederst. Som en ser er den avbildede laserlinjen konkav for margside og konveks for ytesiden. Dette på grunn av kuv etter tørking.*



Figur 2.5: Mikroskopbilde av årringer i endeveden på trevirket. Figuren viser ulikheter i tykkelse på cellevegg mellom vårved (lyse områder) og sommerved (mørkere). En ser også at overgangene mellom vår- og sommerveden er relativt veldefinert for noen eksemplarer, mens for andre kan den være svært flytende. Fra [22].

dobler kravene til prosesseringskraft i forhold til å bare behandle et bilde.

For å få en oppfatning av hvor signifikant forskjell en kan forvente når det gjelder antall årringer på marg- versus yteside har en gjort en modellering av hvordan dette forholdet vil være gitt ulike dimensjoner av limtre lamellen som er skjært i ulik avstand fra stokkens marg. Det har her blitt benyttet en forenklet modell der årringene ses på som ekvidistante konsentriske sirkler. En bruker da avstanden mellom årringene som enhet, og lar avstanden fra margin i stokken til margsiden av lamellen være  $m$  enheter stor. Videre lar vi  $B$  og  $T$  være henholdsvis bredden og tykkelsen til lamellen. Antall årringer på margsiden er da gitt ved

$$A_M = 2 \left[ \sqrt{\left(\frac{B}{2}\right)^2 + m^2} - |m| \right] \quad (2.1)$$

mens antall årringer på ytesiden er gitt ved

$$A_Y = 2 \left[ \sqrt{\left(\frac{B}{2}\right)^2 + (m + T)^2} - |m + T| \right] \quad (2.2)$$

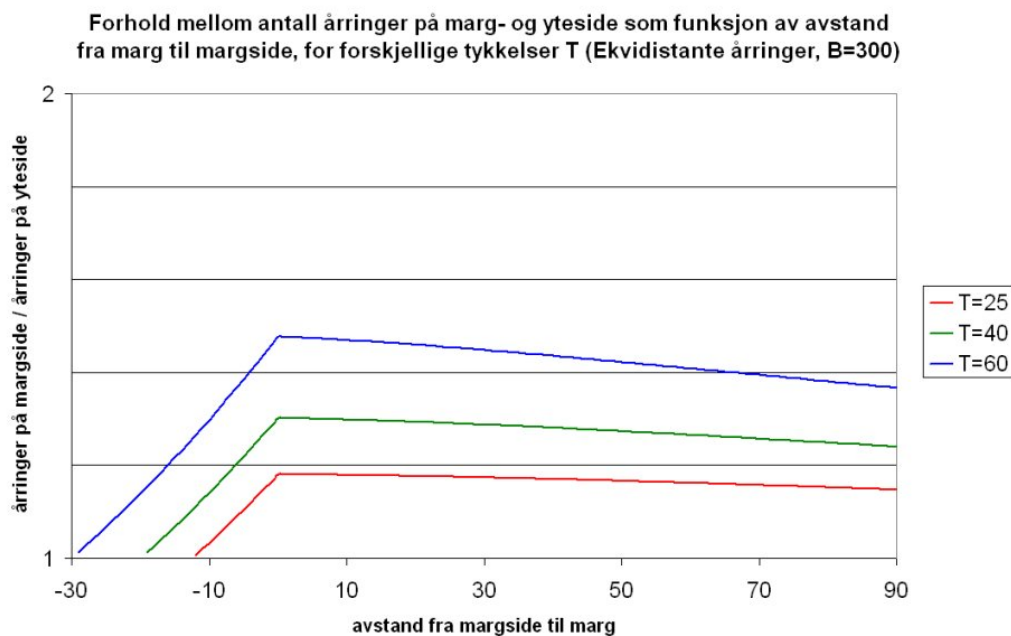
Forløpet av  $A_M/A_Y$  mot  $m$  er vist i figur 2.6 på neste side. Parametrene  $m$ ,  $B$  og  $T$  er her basert på middelvei av manuelt målt årringsavstand for en av prøvene (prøve 27) fra marg og ut til ene kanten. Denne middelavstanden var tilnærmet lik 0.8 mm. Verdien av  $B = 300$  tilsvarer en lamellbredde på ca. 240 mm hvilket er i overkant av den bredeste dimensjonen som Moelven Limtre benytter, og således vil være et "Worst Case" tilfelle for forholdet  $A_M/A_Y$ . Verdiene av  $T$  representerer tykkelser på ca. 20, 30 og 50 mm. Det blir ikke benyttet så smale lameller som førstnevnte av Moelven Limtre idag, men denne er tatt med siden dimensjonen kan være aktuell i forbindelse med andre anvendelser.

Som en ser av figur 2.6 på neste side er forskjellen på over 20% mellom marg- og yteside for begge lamelltykkelsene som blir benyttet av Moelven i hele det aktuelle intervallet med unntak av for  $m < 0$  (det vil si når margin er inne i lamellen) da forholdet synker raskt og for  $T = 40$  er nede i 10% med margin 13 enheter, eller ca 1/3, innenfor lamellens margside. I dette tilfellet vil en ved en feilmåling  $\geq 5\%$  nedover i antall årringer på margsiden og samtidig en feilmåling på  $\geq 5\%$  oppover på ytesiden kunne ta en feil beslutning om hvilken vei lamellen ligger vendt. Dette er imidlertid mindre kritisk når margin er nær senter av lamellen siden spennet fra årringene da til en viss grad motvirker hverandre.

En ser at for tynnere lameller/bord blir marginene ikke overraskende dårligere, men dersom en får til en pålitelig nok deteksjon av årringene vil også metoden kunne benyttes på disse.

Selv om forutsetningen om ekvidistante årringer er en relativt grov forenkling og selv om den målte midlere årringsavstanden brukt i parametrene ikke nødvendigvis er representativ anser en basert på de innledende analysene denne metoden som lovende for å diskriminere marg fra yte.

Etter en totalvurdering av de nevnte egenskaper og metoder endte en derfor opp med å konsentrere seg om deteksjon og sammenligning av årringsmønstre på over- og underside, da denne i tillegg til de nevnte fordeler også representerte en svært interessant utfordring rent faglig, og har mange potensielle anvendelser ut over den konkrete problemstillingen rettvending av limtrelameller.




Figur 2.6: Forventet forhold i antall årringer mellom marg og yteside som funksjon av avstand fra stokkens marg til lamellens margside.

## Kapittel 3

# Systembeskrivelse og bildefangst

Dette kapitlet beskriver den apparatur og det oppsett som er benyttet under bildefangsten av limtrelamellene. Den skisserer også prinsipielt hovedkomponenter og oppsett av et ferdig maskinsynsystem montert i produksjonslinjen på Moelven Limtre A/S.

Et maskinsynsystem består som oftest av hovedkomponentene belysning (mer generelt; bestråling), sensor, digitaliseringsenhet, prosesseringsenhet, lagringsenhet og et eller annet grensesnitt mot omverdenen der utgangsdataene overføres.



Figur 3.1: Typiske komponenter i et maskinsynsystem. Fra [9].

Her omtales de delene av et maskinsynsystem slik illustrert i figur 3.1 som benyttes for å fremskaffe et bilde på digital form. Denne delen av et maskinsynsystem er



svært viktig siden en her legger begrensninger på hvor gode data bildeprosesseringsalgoritmene skal ha å arbeide med. Selv ikke de mest avanserte metoder innen bildeanalyse klarer å ekstrahere informasjon som er tapt i bildefangsten (selv om det riktignok er mulig å rekonstruere noen typer informasjon hvis en er i stand til å modellere prosessene den er tapt under). På den annen side, hvis en har et godt tilpasset bildefangstsystem for oppgaven, kan en ofte slippe unna med langt enklere og mindre prosesseringsintensive algoritmer.

### 3.1 Bildefangst

En forsøkte gjennom prosjektet flere typer industrikameraer i laboppsettet, med ulik oppløsning og kvalitet. Kamera-typene som ble testet var følgende: *RVSI CM4000*, *Hitachi KP-M1/EK*, *Basler A113P*

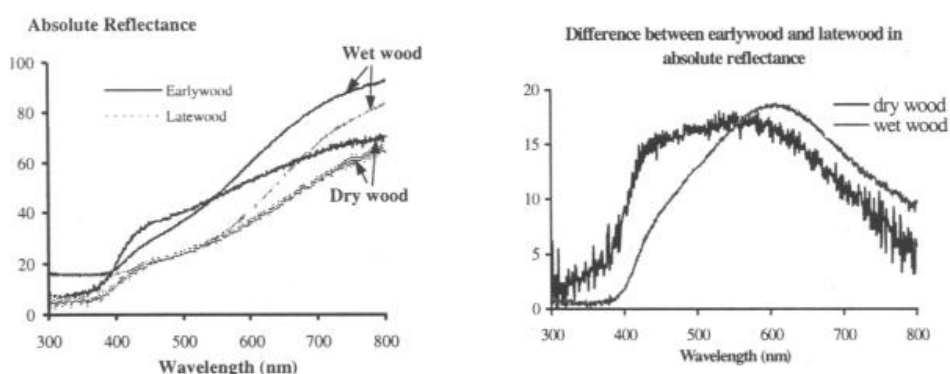
Alle kameraene hadde 8 bits gråtone oppløsning i kvantiseringen, og hadde en sensor-størrelse på henholdsvis 640x480, 768x576 og 1300x1030 piksler. De to førstnevnte er analoge kameraer (dvs. de har analog overføring av bilde-dataene i h.h.t RS170/CCIR standarden), mens det sistnevnte er et rent digitalt kamera. Tilstrekkelig oppløsning på kameraets sensor er viktig for å få gode kontrastrike bilder av de smaleste årringene. Det skanner-baserte målesystemet til Wang [3] hadde her en oppløsning på opptil 15.7 piksler/mm. Lab-bildene våre hadde en oppløsning på ca. 13 piksler/mm når vi hadde hele bredden av lamellene innenfor synsfeltet. Prøvene som ble benyttet var hovedsaklig av den smaleste lamell-dimensjonen som blir brukt av Moelven Limtre (90 cm), så en ville da altså ikke klare å avbilde hele bredden på de større dimensjonene med denne oppløsningen. En trenger imidlertid antagelig heller ikke å gjøre dette. Det skulle være tilstrekkelig å sammenligne antall årringer på over- og undersiden over ca. 1/3 av lamellens bredde for å bestemme hva som er marg- og yte-side.

Frame-grabberne som ble benyttet i labforsøkene var et RVSI Acuity 2300 vision prosessor kort for de analoge kameraene og et RVSI Acuity 2400 for det digitale kameraet. Disse PCI-kortene har i tillegg til å være frame-grabbere også en innebygd prosessor og en hardware-aksellerator for å øke hastigheten til bildebehandlingsrutinene.

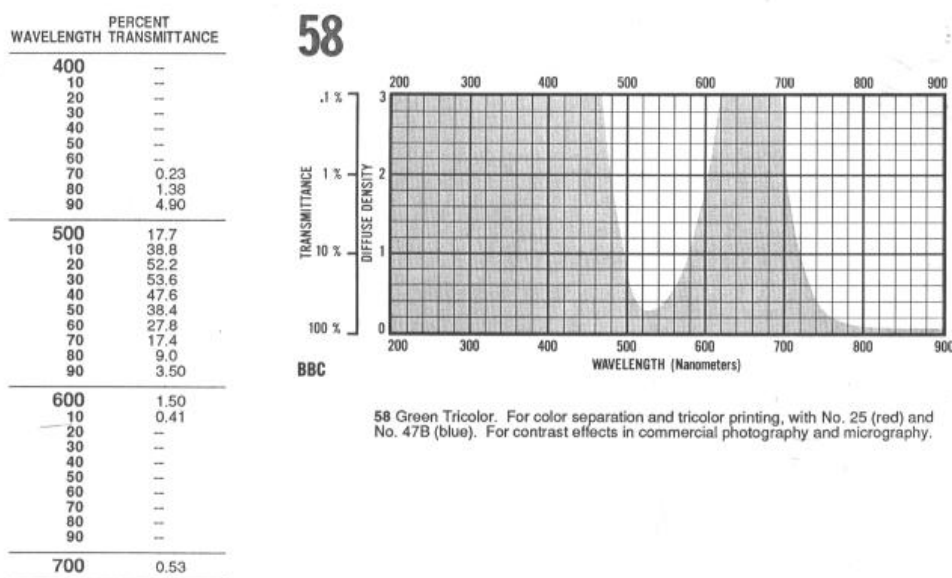
Ved de initielle avbildninger av lamell-prøvene, oppdaget en at kontrasten mellom vår- og sommerveden for visse prøver var svært dårlig. En ønsket da å se hva en kunne vinne i kontrast ved å benytte et filter foran kameralinsen. Figur 3.2 på neste side viser differansen i intensitet mellom vår- og sommerved for ulike bølgelengder.

Vi valgte da basert på disse målingene å benytte et Kodak Wratten gelatin båndpassfilter med høy transmisjon kun i den grønne delen av det synlige spekteret som vist i figur 3.3, for forsøke å bedre kontrasten mellom vår- og sommerved.

Figur 3.4 på neste side viser resultatene oppnådd med å bruke det nevnte filteret. Som en ser av bildene og målingene har en her oppnådd noe forbedring i kontrasten mellom vår- og sommerved regionene ved å benytte filteret. Langs den samme profilen før og etter filtrering kan man måle en økning i standardavvik

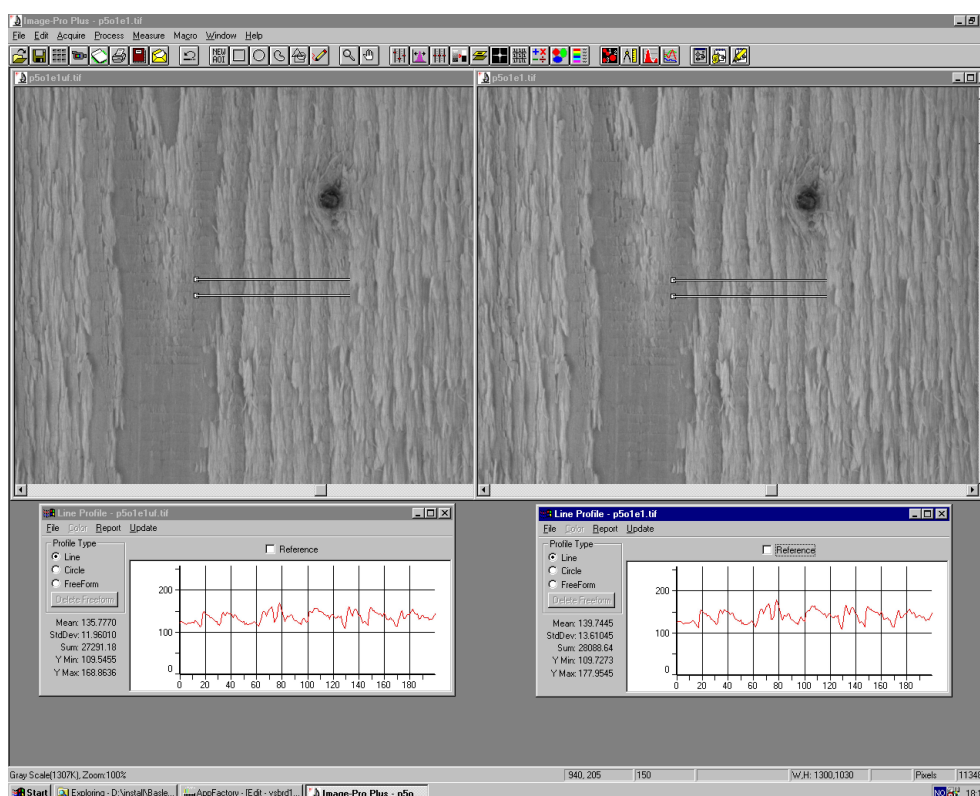


Figur 3.2: Differanse i spektral respons mellom vår- og sommerved (t.h.). Fra [4].



Figur 3.3: Transmisjonskurve for Kodak Wratten no. 58 båndpassfilter.

på ca 1.65 samt at forskjellen mellom minimum og maksimumsverdi er økt med ca. 9 gråtoner. En større forbedring ville muligens kunne oppnås ved å benytte et filter med en smalere båndbredde, og som har en senterfrekvens som er godt tilpasset grafen i figur 3.2 på forrige side. Av hensyn til at dette samtidig ville stilt strengere krav til belysningsintensitet, samt at det er uvisst hvor signifikant kontrastforbedring en ville oppnå, valgte en imidlertid å ikke gjøre videre forsøk med dette.



Figur 3.4: Kontrastforbedring ved bruk av et Kodak Wratten no. 58 båndpassfilter.

## 3.2 Belysning

Belysningen er en svært viktig del av et maskinsynsystem. Bruk av eksisterende omgivelseslys (taklys) er generelt en dårlig løsning når systemet skal plasseres i et industrimiljø. En risikerer da store variasjoner i intensitet og distribusjon over objektet, eksempelvis som følge av at avstandene mellom lyskilden(e) og ulike deler av objektflaten ikke er lik, variasjoner i nettspenningen (variasjoner i lysintensiteten som følge av 50 Hz vekselstrømsfrekvens gjør seg også gjeldende ved

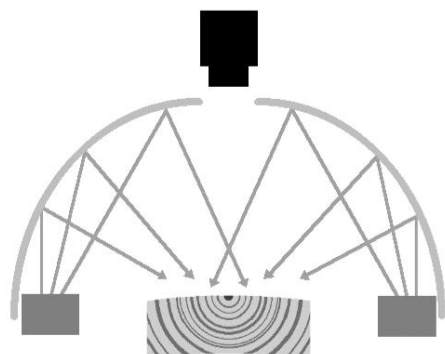
kortere eksponeringstider), at noe (f.eks. personer) helt eller delvis kommer mellom lyskilde og objekt, eller at lyset ved en feiltagelse rett og slett slås helt av! Dessuten er vanlig taklys sjelden den optimale belysning for en bestemt oppgave. Det er vanligvis en del å hente når det gjelder kontrast mellom objekt og bakgrunn, samt uniformitet i lysdistribusjon ved å benytte spesialtilpasset belysning. Avskjerming av området mellom belysning, bildefangstenhet og objekt er også fordelaktig. Dette for å motvirke innvirkning fra strølys samt beskytte mot støv og utilsiktet berøring av optiske flater, ømfintlig elektronikk etc.

Siden en som beskrevet i 3.1 på side 15 fant at et optisk filter i det grønne området av spekteret ga bedre kontrast mellom vårved og sommerved, var en tvunget til å benytte en lyskilde som hadde høy intensitet i den grønne delen av spekteret. Et naturlig valg var da å velge en hvit lyskilde, som har relativt høy intensitet i hele det synlige spekteret.

En gjorde innledningsvis forsøk med ulike typer belysning plassert i ulike vinkler og avstander i forhold til objekt og kamera, og gjorde en bedømming av hvor god kontrast det var mellom vårved og sommerved, samt belysningens uniformitet over flaten. Det ble gjort forsøk med relativt diffus belysning, samt mer retningsbestemt og fokusert (spot-light). En fant, ikke overraskende, at en diffus type belysning ga vesentlig mer uniform intensitet over flaten, mens den mer retningsorienterte i tillegg til å ha store variasjoner i intensitet over flaten ga en del speilende refleksjoner fra de blankere regionene. Begge belysningene ga skyggeeffekter i forbindelse med strukturen i form av de delvis løsrevne flisene som preget overflaten av lamellene i stor grad. Her var den retningsbestemte noe bedre enn den diffuse. Årsaken til dette er antagelig at det meste av lyset da falt i trefibrenes lengderetning. Ved å variere vinkelen på lyskilden i forhold til objektets overflate, observerte man at skyggeeffekten fra strukturen i lamellflatene ble mer fremtredende ved større innfallsvinkel på den retningsorienterte belysningen, samtidig som uniformiteten i lysdistribusjon over flaten ble noe bedre. En valgte imidlertid å benytte den diffuse belysningstypen, da denne ga en mye bedre uniformitet.


For å skape en diffus belysning som hadde god uniformitet over hele kamerafeltet, ble det benyttet en type belysning ofte kalt sylindrisk dom belysning, slik skissert i figur 3.5 på neste side. Prinsippet er at man lyser opp objektet indirekte via en matt (diffunderende) hvit skjerm formet tilnærmet som en halv sylinder. Det reflekterte lyset fra skjermen vil da bli spredt, og en får en veldig diffus belysningskarakteristikk over objektet. Lyskilden som ble brukt til å belyse skjermen var vanlige hvite lysrør. Skjermen var utstyrt med et hull på toppen og i senter slik at kameraet hadde fri vertikal sikt til objektet. Dette oppsettet viste seg å ha relativt gode belysningsmessige egenskaper for oppgaven, samt at det er en relativt enkel og billig løsning å konstruere i praksis. Belysningsmetoden har i tillegg god effek-

tivitet ettersom domene reflekterer mesteparten av lyset som kommer fra kilden ned mot objektet. I tillegg vil domene fungere som en avskjerming mot strølys, og andre eksterne faktorer for store deler av systemet, slik at eventuell ytterligere avskjerming som er nødvendig for belsnings- og kameradelen av systemet blir minimal.



Figur 3.5: Illustrasjon av indirekte diffus belsning v.h.a. sylindrisk dom prinsippet.

Figur 3.6 viser et bilde tatt med den sylindriske dom belsningen, og et tatt med direkte belsning vinklet med ca. 35 grader i forhold til innfallsvinkelen mellom kamera og objekt. Som en ser av bildet gir dom belsningen langt bedre uniformitet over flaten, i tillegg til at kontrasten mellom vår og sommervedregionene fremtrer noe bedre. Appendiks A på side 161 viser flere bilder tatt med denne belsningen.



Figur 3.6: Bilde av prøve-eksemplar 1, tatt med direkte belsning t.v. og sylindrisk dom belsning t.h.

### **3.3 Bildemateriale og prøver**

Som nevnt i forrige avsnitt endte en opp med å benytte sylindrisk dom for å belyse lamellene. I innledende forsøk ble det benyttet serie på 4 lamellprøver av dimensjon 90x38 mm, men etterhvert ble prøvematerialet utvidet med en serie på 25 nye lameller. Denne gang med dimensjon 100x38 mm. Førstnevnte serie ble avbildet med et 640x480 kamera som beskrevet i seksjon 3.1 på side 15 og en oppløsning på ca 6 piksler/mm, mens sistnevnte serie ble avbildet med et 1300x1030 kamera og en oppløsning på ca 13 piksler/mm. Bildene fra begge seriene er inkludert i appendiks A på side 161. Bilder fra den første serien er i denne rapporten referert til som prøve 1-4, mens bilder fra serie 2 er referert til som prøve 5-29.

# Kapittel 4

## Problemanalyse

En vil i dette kapittelet utføre en visuell og kvantitativ vurdering av bildematerialet, og utfra denne analysen forsøke å identifisere problemområder som krever spesiell fokus, og skissere mulige fremgangsmåter for å løse disse.

### 4.1 Visuell vurdering av bildemateriale

Som en ser av appendiks A på side 161, har de fleste bildene av lamellene (selv med filter) relativt dårlig kontrast mellom vår- og sommerved regionene.

En ser også at det er svært mye støy i form av delvis løsrevne fibre/fliser, sagemerker, skitt etc. Støyen kan ha en svært grovkornet karakter, og dens kontrast vil ofte overstige den mellom vår- og sommerveden slik figur 4.1 på side 24 viser.

Ved sammenligning av de ulike bildene, ser en i tillegg at det er en enorm variasjon i utseendet på de ulike lamelloverflatene. Variasjonene gjør seg først og fremst gjeldende i årringsbredder/frekvens, kontrast mellom vår- og sommerved, samt teksturegenskaper ved støyen slik som kontrast, størrelse, geometrisk form og frekvens. En stor utfordring ved denne oppgaven blir derfor å finne metoder som fungerer tilfredsstillende for hele dette spekteret av varianter.

#### 4.1.1 Årringenes distribusjon

En ser også at årringene har stor variasjon i bredde både mellom ulike lameller, og (som forutsatt) mellom marg- og yteside, men også innenfor hver enkelt overflate. I visse tilfeller kan årringer som ligger ved siden av hverandre ha store forskjeller i bredde og kontrast. Sommerveden kan i bildematerialet variere fra flere titalls

pikslers bredde og helt ned mot tilsynelatende ca. en piksel (Sensorens pikselopløsning på bildene er som nevnt 13 piksler/mm).

Det kan derfor fra et rent faglig synspunkt være fordelaktig med enda større oppløsning ettersom en for de smaleste objektene mister kontrast på grunn av samplingssystemet, men dette vil medføre en økning av datamengde som må prosesseres og en betydelig fordyring av kamera og deler av den øvrige maskinvaren.

### 4.1.2 Årringenes karakteristiske egenskaper

Karakteristisk for årringsmønstrene er at de i regelen, ihvertfall nær kanten av lamellene, følger en svært glatt kurve som har en nær vertikal orientering. Det er imidlertid visse unntak fra dette. I nærheten av sagspor vil en kunne få noe ulik høyde på de to sidene av sporet som kan etterlate seg en liten forskyvning av kurven. Opprevne trefibre fra vårved-områdene vil kunne dekke til større eller mindre deler av sommerved-områdene og etterlate seg en diskontinuitet i kurven. I nærheten av kvist vil årringskurvene i en viss grad følge kvistens ovale form, og dermed avvike mer fra vertikalen.

## 4.2 Kvantitativ analyse

Den kvantitative analysen består i å utføre ulike basis-målinger, for å få objektive verdier som beskriver ulike egenskaper ved bildet. Dette kan typisk være egenskaper ved gråtonedistribusjonen i bildet. En har også i denne seksjonen valgt å inkludere noen grunnleggende bildeforbedringsmetoder som gjør det enklere å gjøre en visuell analyse.

### 4.2.1 Histogram

Et histogram gir informasjon om sannsynligheten til de ulike gråtonene i bildet (Histogrammet kalles også første ordens sannsynlighetsfordeling). For et bilde med gråtone verdier i intervallet  $[0, G - 1]$ , er histogrammet gitt ved den diskrete funksjonen  $p(g_k) = n_k/n$  der  $g_k$  er den  $k$ 'te gråtoneverdi,  $n_k$  er antall piksler som har denne gråtoneverdien,  $n$  er totalt antall piksler i bildet, og  $k = 0, 1, \dots, G - 1$ .

Histogrammets form kan gi informasjon om en rekke viktige egenskaper ved bildet; blant annet dynamisk område, midlere intensitet, samt antyde om bildet har et eller flere forgrunnsobjekter som er distinkte i gråtone fra bakgrunnen, og forholdet i areal mellom disse. I sistnevnte tilfelle vil en kunne se et bi-modalt



(eller eventuelt multi-modalt) histogram, med flere distinkte topper. Den midlere gråtonen i bildet kan beregnes fra histogrammet ved hjelp av følgende formel

$$\mu = \sum_{k=0}^{G-1} g_k p(g_k) \quad (4.1)$$

og standardavviket ved

$$\sigma = \sqrt{\sum_{k=0}^{G-1} (g_k - \mu)^2 p(g_k)} \quad (4.2)$$

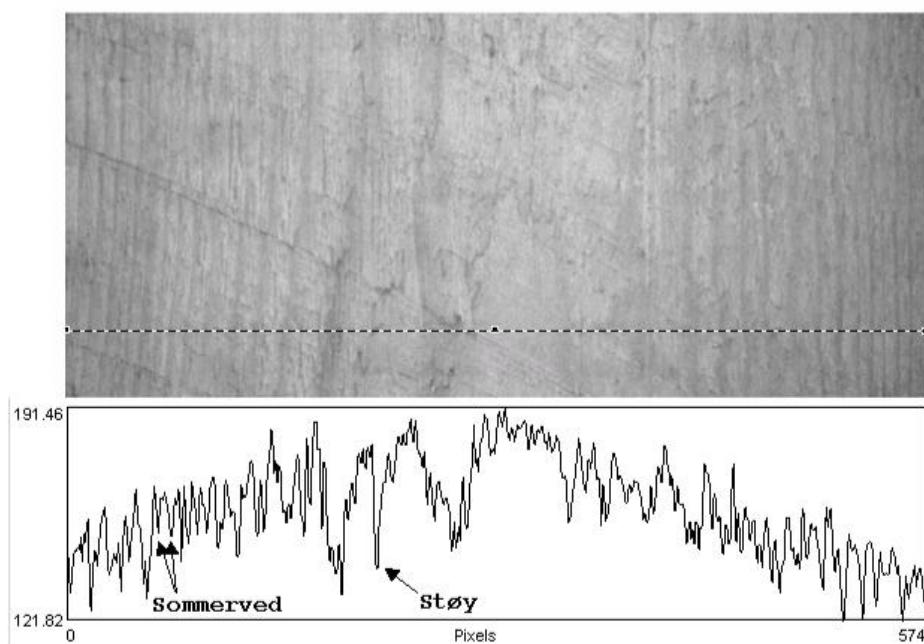
Figur 4.2 på neste side viser et typisk globalt histogram for lamelloverflaten på et av bildene. Som en ser har histogrammet et relativt lavt standardavvik som indikerer dårlig kontrast, samt at en ikke kan se noen antydning til separate topper for vår- og sommerved. Hadde en hatt en jevnere belysning av overflaten ville dessuten standardavviket vært betydelig lavere.

## 4.2.2 Histogram utjevning


Histogram utjevning er en metode som forbedrer den visuelle kontrasten i et lavkontrast bilde ved å mappe gråtoneverdiene under den forutsetning at det resulterende histogrammet skal være tilnærmet uniformt. Når en approksimerer den kumulative gråtonefordelingen til bildet med dets kumulative histogram kan denne mappingen utføres ved hjelp av følgende transferfunksjon

$$g_j = [g_{max} - g_{min}] \sum_{k=1}^j p(g_k) + g_{min} \quad (4.3)$$

Figur 4.3 på side 26 viser bildet og det tilhørende histogrammet etter at en har benyttet histogram utjevning. Som en ser har kontrasten mellom vår- og sommervedsregionene samt støyen økt i noen områder, mens en i andre områder ser en degradering av bildet. Denne degraderingen er mest fremtredende langs kantene av lamellene, og skyldes i stor grad ujevnheter i belysningen av overflaten, som kommer svært tydelig frem på det histogram-modifiserte bildet. Denne ujevnheten i belysningen over lamellflaten skyldes igjen i stor grad at denne flaten ikke er plan. Avhengig av om det er en yte- eller margside vil overflaten som nevnt i kapittel 2 på side 6 ha en konkav eller konveks form (kuv) over lamellens tverretning.



Figur 4.1: Linjeprofil av prøve 1 med noen av støy- og sommervedområdene markert.



Figur 4.2: Histogram fra prøve 1.

### 4.2.3 Linjeprofiler

Linjeprofiler viser et plott av gråtoneverdiene til pikslene langs en enkelt linje i bildet. Dette kan gi nyttig informasjon om størrelsen på objekter, samt disses kontrast til bakgrunnen og eventuell støy.

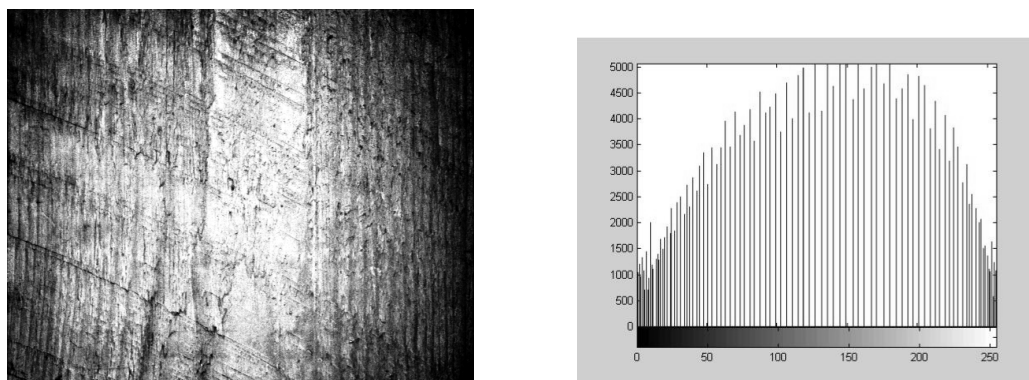
Figur 4.4 på neste side viser en profil på tvers av årringsmønstrene. En ser her at mye av støyen har en lavere gråtone, samt en bredere profil enn noen av årringene. En ren global terskling vil dermed etterlate flere støyobjekter, som må fjernes i den videre prosessering/analyse.

I figur 4.5 på neste side viser en profil på langs av et sommerved-område. Som en ser er her den relativt uniforme sommerved regionen avbrutt av topper som skyldes at opprevne vårved-fibre dekker over deler av sommerveden.


### 4.2.4 Korreksjon for ujevn belysning

Linjeprofilene i figur 4.4 på neste side og 4.5 på neste side indikerer (som en også så ved histogram utjevning) at belysningen ikke er uniform over hele bildeutsnittet. En ser en klar avtagende intensitet ut mot kantene, noe som vil vanskeliggjøre segmenteringen av bildet. En måte å kompensere for dette på er å subtrahere bakgrunnen i bildet. Det er ofte deretter ønskelig å gi gråtonene  $g_k$  en offset slik at de igjen ligger i området  $[0, G - 1]$ . Middelveidien  $\mu$  gir en egnet offset i vårt tilfelle, selv om den generelt sett ikke garanterer at alle  $g_k$  ligger innenfor  $[0, G - 1]$ . Bakgrunnen til bildet kan ofte finnes ved å avbilde en uniform flate under samme belysningsbetingelser som lamellene. Denne metoden vil imidlertid ikke kunne kompensere for ujevnheter i belysning som skyldes ulik kuv på lamellflatene, hvilket utgjør et vesentlig bidrag til non-uniformiteten en ser i vårt tilfelle. En mer egnet metode for å finne bakgrunnen er derfor å dynamisk, for hver ny lamell, gjøre en lavpassfiltrering av originalbildet der en kun lar de aller laveste frekvensene passere.

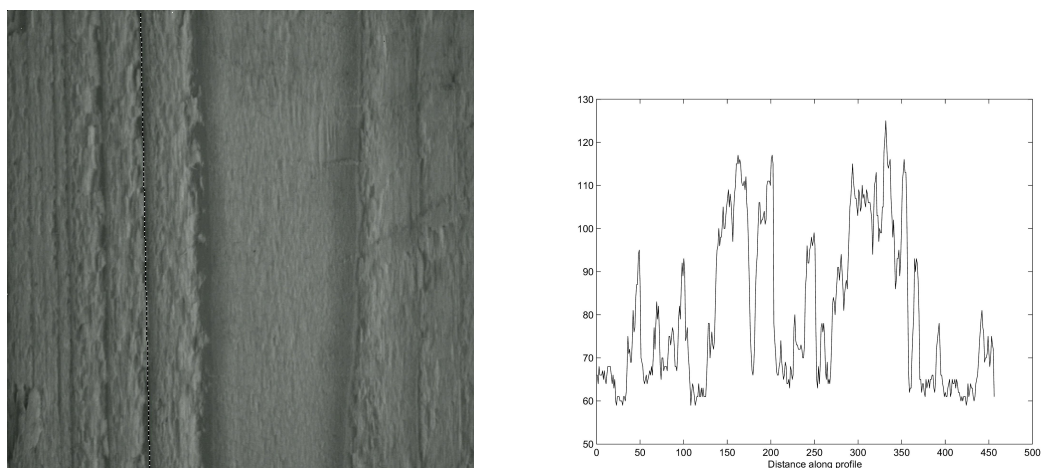
Siden en trenger en relativt stor operator (en fant fra forsøk at en trenger minimum  $50 \times 50$  for å få et tilfredsstillende resultat) for å utføre en midling som gir sterk nok glatteeffekt i  $xy$ -domenet, er dette en svært ressurskrevende operasjon. Et alternativ er da å utføre filtreringen i frekvens-domenet og transformere tilbake til  $xy$ -domenet. En Fast Fourier Transform (FFT, se kapittel 7.2.1 på side 94) etterfulgt av en invers FFT er imidlertid også relativt ressurskrevende operasjoner. En valgte derfor å benytte en enkel form for subsampling, der en delte opp bildet i  $64 \times 64$  piksels subregioner og benyttet middelveidien i hvert subbilde som et bildepunkt i resultatbildet. Det ble deretter kjørt en  $7 \times 7$  midling på det subsamplede bildet før det ble interpolert tilbake til full størrelse (v.h.a. bilinear interpolasjon). Denne



Figur 4.3: *Bilde og histogram etter histogram utjevning for prøve 1.*




Figur 4.4: *Linjeprofiler i tverrgående retning fra prøve 1 og 2.*



Figur 4.5: *Linjeprofil i langsgående retning fra prøve 2.*

prosedyren er vesentlig raskere enn de to forannevnte, og gir et bakgrunnsbilde av tilfredsstillende kvalitet.



Figur 4.6: Bakgrunnskorrigert bilde med tverrgående linjeprofil fra prøve 1.

Figur 4.6 viser et belyningskorrigert bilde, og en tverrprofil av dette. Som en ser har en her en jevn midlere intensitet langs hele profilen sammenlignet med den samme profilen i figur 4.4 på forrige side.

### 4.3 Diskusjon

Etter å ha utført de innledende visuelle og kvantitative analysene har en tilegnet seg en bedre innsikt i problemstillingen. En har identifisert noen punkter som en mener bør få mye fokus i oppgaven, enten fordi de er spesielt utfordrende eller fordi de på annen måte gir nøkkelinformasjon om problemet. I tillegg kan en også allerede på et så tidlig stadium si noe om hvilke fremgangsmåter som ikke vil føre fram. De nevnte punktene og innsikten tilegnet i denne analysen er listet opp nedenfor, sammen med noen innledende tanker rundt hvordan en skal gå fram for å løse noen av problemområdene.

- *Støy*. Som en ser av bildene og profil-plottene er det til dels svært mye og svært markant støy i bildene. Støyen har i tillegg svært variabel form og

størrelse. En må derfor finne metoder som kan eliminere eller undertrykke mye av denne støyen, eller som på annet vis klarer å skille mellom støy- og årringsobjekter.

- *Karakteristiske årringsegenskaper.* En har observert at årringene i regelen følger en tilnærmet vertikal og glatt kurve. Denne egenskapen kan og bør bygges inn i metodene for å bedre kunne diskriminere mellom årringer og støy.
- *Lav kontrast.* Mange av årringene har svært lav kontrast mellom vår- og sommervedsregionene. En bør derfor se om en finner metoder som kan fremheve disse uten at en samtidig fremhever støyen i for stor grad.
- *Ujevn bakgrunnsintensitet.* Belysningen samt lamellenes kuv gir en ujevn intensitet hovedsakelig i lamellenes tverretning. Denne effekten må kompenseres for enten som et forprosesserings-steg eller innbakt i metodene.
- *Variierende årringsbredder.* Bredden på vår- og sommerved regionene kan variere svært mye både mellom ulike lamelloverflater og i nærliggende regioner innen hvert enkelt bilde. En må derfor ha metoder som er generelle nok (eller tilpasningsdyktige nok) til å fungere tilfredsstillende på hele det aktuelle spekteret av årringsbredder.
- *Direkte global segmentering utilstrekkelig.* Implisitt fra de foregående punkter, og den innledende analysen for øvrig, kan en allerede nå fastslå at en fast eller adaptiv global terskling av et ikke-preprosessert bilde ikke vil føre fram.

# Kapittel 5

## Preprosessering

Bilder som ikke er kunstig fremstilt digitalt – det vil si bilder samlet og digitalisert fra den virkelige verden – inneholder som oftest støy. Med støy mener en her både stokastiske signaler som har oppstått i bildefangst-systemet (f.eks. støy fra sensor eller effekter introdusert ved digitalisering) og uønskede objekter og tekstur som ikke har sammenheng med den informasjonen en ønsker å ekstrahere fra bildet. Denne definisjonen av støy blir også brukt i de resterende deler av denne rapporten.

Formålet ved å preprosessere et bilde er å forbedre bildet på en slik måte at en øker muligheten for å lykkes i den senere prosesseringen og analysen av bildet. En ønsker altså å fremheve den informasjonen en er interessert i, samt å undertrykke den uinteressante informasjonen. Preprosesseringen kommer således ofte først i digitale bildeprosesseringssystemer. En god preprosesseringsalgoritme er spesielt viktig i vår applikasjon, siden bildene i så sterk grad var preget av støy som var svært dominerende i forhold til de objektene vi ønsket å detektere.

### 5.1 Lokalisering av beste region for videre prosessering

En del av prøvene som ble benyttet hadde regioner der det var spesielt mye støy. I noen regioner var til og med trefibrene så opprevet at det var umulig å bestemme hvor årringene gikk selv med grundig manuell analyse. Hvis man skulle benytte algoritmen som beskrevet tidligere på disse områdene, vil dette gi svært unøyaktige, og omtrent tilfeldige, resultater ved årringstelling, ettersom man da hovedsaklig detekterer skygger fra de opprevete fibrene. Selv om en benytter et større

antall regioner til å bestemme hva som er yte- og margside, vil disse svært støyfylte regionene kunne utgjøre en såpass signifikant del av lamelloverflaten at klassifikasjonen vil kunne bli upålitelig. I tillegg bruker en her unødvendig mye datakraft ved å kjøre en omfattende analyse på regioner som i utgangspunktet ikke inneholder den informasjonen en er ute etter (jmf. [2]). Det beste er derfor å finne en metode for å eliminere disse regionene fra den videre analysen. Det er lagt vekt på at dette datareduksjonssteget skal være så raskt som mulig og det bør dessuten utføres så tidlig i sekvensen som mulig, slik at flest mulig av de tynge prosedyrene utføres på en redusert datamengde.

### 5.1.1 Midlere kolonnevise standardavvik som støymål

Ideelt sett ønsker en å finne regioner der en for mindre vinduer har minst mulig struktur i vertikal retning. Ettersom årringene er tilnærmet vertikalt orientert for mindre  $\Delta y$ , vil intensiteten ideelt sett være tilnærmet lik innen kortere vertikale vinduer. Hvis denne varierer mye skyldes dette støy. Standardavviket beregnet for hver kolonne innen regionen burde derfor være et egnet mål på hvor mye støy som finnes i kolonnen. Hvis en så eksempelvis midler dette over alle kolonner vil en få et mål på hvor mye støy som finnes i hele området. Uttrykt matematisk blir dette

$$N_{region} = \frac{1}{N} \sum_{i=0}^{N-1} \sigma_i \quad (5.1)$$

der  $\sigma_i$  er standardavviket for kolonne  $i$  i bildet. En måtte da beregne  $N_{region}$  for både over- og undersiden av lamellen, og en valgte å benytte verdien fra den siden med høyest  $N_{region}$  siden man er avhengig av å finne region-par med lite støy på begge sider. I den videre prosesseringen brukte en da kun de  $n$  region-parene med lavest maksimumsverdi av  $N_{region}$ .

Figur 5.1 på side 32 viser et bilde-par av marg- og yteside der den ene siden har svært støyfylte, opprevete regioner. Som en ser velger algoritmen ut det region-paret der støyen på den mest problematiske siden er minst signifikant.

### 5.1.2 Maksimering av standardavvik i projeksjon

Den forannevnte metoden klarer som en ser å plukke ut regioner som har lite støy relativt til de andre regionene i bildet. En har imidlertid ingen garanti for at disse regionene samtidig har tydelige årringsmønstre med god kontrast mot bakgrunnen, hvilket også er av stor betydning for god og pålitelig deteksjon. Metoden vil



vert imot foretrekke regioner som er uniforme i vertikal retning, noe som generelt ikke er tilfelle i regioner med årringsmønstre som har god kontrast, ettersom disse ofte ligger i en viss vinkel i forhold til vertikalen, og/eller følger en svak bue.

For å sikre at en også velger regioner med brukbar kontrast mellom vår- og sommerved, altså kraftig signal, må en derfor benytte et annet kriterium. En har her valgt å benytte standardavviket i den vertikale projeksjonen som tilleggsmål

$$S_{region} = \sqrt{\frac{1}{N-1} \sum_{i=0}^{N-1} (\mu_i - \bar{\mu})^2} \quad (5.2)$$

der  $\mu_i$  er middelverdien til kolonne  $i$  og  $\bar{\mu} = \frac{1}{N} \sum_{i=0}^{N-1} \mu_i$ .

En kan så kombinere dette målet med det en fant i forrige seksjon, for å få et mål på hvor egnet regionen er for videre prosessering. En valgte da å benytte  $S_{region}/N_{region}$  som godhetsmål eller signal/støy-forhold for regionen.

Figur 5.2 på neste side viser et bilde-par av marg- og yteside der den “beste” regionen er valgt ut basert på signal/støy-forholdet slik beregnet ovenfor.


### 5.1.3 Fjerning av mørke regioner

I tillegg til metoden skissert i de to foregående seksjoner er det nødvendig med en ekstra sjekk på om regionen inneholder uønskede objekter som kan føre til feildeteksjon. Eksempler på dette er større kvist, margstriper, kvaelommer etc.


Kauppinen og Silven [2] har rapportert gode resultater ved å benytte enkle og raske prosentil mål til fargebasert klassifikasjon av trevirke. Vi har i vårt tilfelle riktignok kun et gråtonebilde (som tilnærmet vil tilsvare den grønne kanalen fra RGB-kameraet brukt i [2]), men siden de uønskede objektene i de fleste tilfeller fremstår som mørkere enn rent trevirke er det grunn til å anta at metoden vil kunne fungere for en stor del av de uønskede regionene. Utfra spektralmålingene vist i [2] kan en også se at de ovenfor nevnte objektene har en lavere reflektans enn vår- og sommerved i den grønne delen.

Ettersom prosentilen vil forskyve seg avhengig av størrelsen på regionen som analyseres, fant en det mer hensiktsmessig å benytte et fast antall piksler istedenfor en prosentverdi av totalt antall piksler i histogrammet. Metoden vil altså fjerne de regionene der den laveste gråtonen,  $g_N$ , som tilfredsstillers ulikheten

$$\sum_{i=0}^{g_N} H(i) > N \quad (5.3)$$



Figur 5.1: Lokalisering av beste region for videre prosessering basert på midlere kolonnevise standardavvik.



Figur 5.2: Lokalisering av beste region for videre prosessering basert på signal/støyforhold.

er mindre enn en terskel  $T_g$ , gitt at  $N$  er antall piksler som tolereres og  $H(i)$  er bildets histogram. Regionene som fjernes vil i dette tilfellet være relatert til de mørke objektenes faktiske (summerte) areal istedenfor deres relative areal til regionstørrelsen. Dette er ønskelig siden den aktuelle typen høykontrast objekter i stor grad vil påvirke den resterende analysen selv om de kun utgjør en mindre del av regionen. En fant at  $N = 1000$  og  $T_g = 70$  ga fornuftige resultater for de aktuelle objektene i vårt tilfelle.

## 5.2 Rotasjon av bildet

Siden årringene ikke er helt parallelle med lamellenes sidekanter, og dermed bildekanterne, vil en kunne få en redusert ytelse ved bruk av vertikalt orienterte linjefiltre eller linjeproeksjon (jmf. 5.5 på side 48 og 5.5.3 på side 54). En måte å kompensere for dette på er da å forsøke å rotere bildet slik at flest mulig av årringene ligger mest mulig vertikalt i bildet.

### 5.2.1 Teori

En rotasjon av bildet om kartesiske origo (nedre venstre hjørnet av bildet) med en vinkel  $\theta$  kan utføres ved en fremgangsmåte basert på revers utregning av korresponderende bildekoordinater i originalbildet,  $F(u_q, v_p)$ , for hvert piksel i en matrise som skal inneholde det roterte bildet,  $G(x_k, y_j)$ . Der de kartesiske koordinatene  $(x_k, y_j)$  i det roterte bildet er relatert til bildeindeksene  $(j, k)$  ved

$$x_k = k - \frac{1}{2} \quad (5.4)$$

$$y_j = J + \frac{1}{2} - j \quad (5.5)$$

og de kartesiske koordinatene  $(u_q, v_p)$  i  $F$  er relatert til bildeindeksene  $(q, p)$  helt tilsvarende

$$u_q = q - \frac{1}{2} \quad (5.6)$$

$$v_p = P + \frac{1}{2} - p \quad (5.7)$$

der  $1 \leq j \leq J$ ,  $1 \leq k \leq K$  og tilsvarende  $1 \leq p \leq P$ ,  $1 \leq q \leq Q$ .

En går altså suksessivt igjennom hvert piksel i  $G$ , og finner den korresponderende koordinat i  $F$  ved hjelp av følgende formel

$$\begin{bmatrix} u_q \\ v_p \\ 1 \end{bmatrix} = \begin{bmatrix} \cos\theta & \sin\theta & 0 \\ -\sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_k \\ y_j \\ 1 \end{bmatrix} \quad (5.8)$$

Generelt vil da den beregnede  $(u_q, v_p)$  ikke være en integer, og ligge eksakt på en piksel. En kan da benytte gråtoneverdien fra nærmeste piksel, men en vil få en

bedre tilnærming hvis en interpolerer mellom de nærmeste gråtonene i naboskapet til  $(u_q, v_p)$ . Det finnes flere ulike interpolasjonsmetoder av ulik nøyaktighet og kompleksitet (eksempelvis bilinear og bikubisk med ulike kjernefunksjoner). En valgte her å benytte en bilinear interpolasjonsmetode ettersom denne er mindre krevende prosesseringsmessig. Metoden benytter de fire nærmeste naboene for å estimere gråtonen etter følgende likning

$$\begin{aligned} \hat{F}(u_q, v_p) = & (1 - a)[(1 - b)F(p, q) + bF(p, q + 1)] \\ & + a[(1 - b)F(p + 1, q) + bF(p + 1, q + 1)] \end{aligned} \quad (5.9)$$

der  $a$  er den vertikale avstanden mellom  $(u_q, v_p)$  og  $(p, q)$ , og  $b$  er den horisontale. Rotasjonsvinkelen,  $\theta$ , ble her valgt dynamisk slik at den maksimaliserte et kontrastmål i den vertikale projeksjonen av  $G$ . Basert på forsøk ble det her valgt å bruke variansen som kontrastmål. Altså utfører en først en projeksjon, gitt ved

$$g(k, \theta_i) = \frac{1}{J} \sum_{j=0}^{J-1} G(j, k, \theta_i) \quad (5.10)$$

for et fastsatt antall  $\theta_i$  jevnt distribuert over et intervall som antas dekke de lokale avvikene i årringenes retning fra vertikalen.

Den valgte rotasjonsvinkelen er da gitt ved

$$\theta_{max} = \operatorname{argmax}_{\theta_i} \operatorname{Var}(g(k, \theta_i)) \quad (5.11)$$


og den korresponderende  $G(j, k, \theta_{max})$  blir brukt i den videre prosesseringen.

Andre mulige kontrastmål er å benytte differansen mellom maksimums og minimumsverdi, eller  $p$ -prosentilavstanden til den projiserte vektoren. Et argument for å velge variansen fremfor det enklere og raskere førstnevnte alternativet,  $max - min$ , er at denne er mer robust mot støy og enkeltavvik i årringenes vinkel ettersom den utnytter hele datasettet istedenfor kun de to ekstremverdiene.

## 5.2.2 Diskusjon av resultater

Figur 5.3 på neste side viser et bilde rotert etter maksimalt standardavvik i projeksjon kriteriet. Prosedyren benyttet her en oppløsning på 0.5 grader og tillot maksimalt rotasjoner på +/- 2.5 grader, da årringene er tilnærmet vertikale langs

kanten av lamellene. Som en ser av bildet er de fleste av årringene tilnærmet vertikale etter rotasjon, mens den lengst til høyre i bildet fremdeles er skjev, da denne hadde en vinkel som avvek en del fra de andre. Dette avviket skyldes imidlertid at denne årringen ligger nær senter av lamellen, og hvis en plasserer sin “region of interest” slik at en kun ser på årringene som ligger lenger ut mot kanten, vil disse avvikene i de fleste tilfeller være mindre signifikante. En vil i tillegg kunne oppleve større lokale avvik i årringenes vinkel i nærheten av kvist, men dette kan omgås eksempelvis ved at man først detekterer kvist, og plasserer ROI i god avstand til disse.



Figur 5.3: *Bildet før og etter rotasjon etter den beskrevne metoden.*

Prosedyren kan gi unøyaktigheter i den estimerte optimale vinkelen hvis det er mye støy i bildet. En mer robust metode ville være å kjøre filtreringen beskrevet i 5.5.2 på side 51 før en projiserer og finner maksimalt standardavvik, men denne metoden vil bli såpass mye tyngre prosessermessig at den ikke vil være realistisk å benytte i et sanntidssystem. En annen mulighet vil være å kjøre filtreringen på et ikke-rotert bilde, og så estimere vinkelen basert på dette bildet. Hvis en da kun roterer det filtrerte bildet, taper en ikke noe prosesseringstid på denne fremgangsmåten. Siden filteret fungerer optimalt for helt vertikale årringer, vil det imidlertid gi et teoretisk bedre resultat å kjøre en ekstra filtrering på et rotert originalbilde, hvilket vil medføre en del ekstra prosesseringstid.

En annen tilnæringsmåte for å finne den dominerende orientasjonen kan være å transformere bildet til polare koordinater for så å finne symmetrivinkelen. I et  $\rho$ - $\theta$  plott vil lineære parallelle årringsmønstre fremstå som buede kurver symmetrisk om en verdi av  $\theta$  som vil være lik orientasjonen til årringene. Dersom denne symmetrien kunne detekteres pålitelig vil en kunne få et godt estimat på rotasjonsvinkelen direkte, uten at en behøver å rotere bildet i inkremerter på 0.5 grader og estimere standardavviket i projeksjonen hver gang som i metoden ovenfor.

Orientasjonen vil antagelig også kunne finnes ved å benytte Hough transform [19][20][7]. Siden dette er en relativt prosesserskrevende algoritme ville det isåfall være mer hensiktsmessig å benytte Random Hough Transform (RHT) in-

trodusert av Kultanen et al. [12] som er betydelig raskere. Denne varianten baserer seg på at hvert punkt i parameter-rommet kan uttrykkes som en funksjon av to punkter i  $xy$ -domenet (for lineære kurver). Dette til forskjell fra standard Hough transform (HT) som mapper hvert enkelt punkt separat. I RHT plukkes i tillegg punktparene som akkumuleres i parametercellene random, slik at når prosessen har pågått lenge nok vil det være maksima i akkumulatorrommet på samme steder som etter at HT er ferdig. RHT benytter en søkestrategi der den suksessivt detekterer maksima i parameterrommet, fjerner alle punktene i  $xy$ -domenet som ligger under kurven som korresponderer med maksimumet, og nuller ut akkumulatoren. Algoritmen stoppes når det ikke er flere “på”-punkter igjen i bildet. Både RHT og vanlig HT krever imidlertid en preprosessering av bildene for å lokalisere aktuelle punkter.

De nevnte alternative metodene har ikke blitt nærmere utforsket ettersom den førstnevnte rotasjonsprosedyre i de langt fleste tilfeller fungerer tilfredsstillende, og siden den prosesseringsmessig er håndterbar. En kan få en betydelig hastighetsøkning ettersom en ikke trenger å gjøre utregningen i ligning 5.8 på side 34 og 5.9 på side 35 under kjøring, men at projeksjonene isteden kan produseres direkte fra prekalkulerte oppslagstabeller for hver rotasjonsvinkel. Algoritmen er dessuten egnet for implementasjon i maskinvare.

## 5.3 Støyreduksjon

Ettersom en i denne oppgaven ønsket å analysere trevirket uhøvlet inneholdt bildene en god del støy som måtte filtreres vekk før en kunne detektere årringsmønstrene. Denne støyen besto hovedsaklig i at fibrene var mer eller mindre løsrevet på overflaten slik at denne fikk en veldig grov karakteristikk. I tillegg var det noe støv og skitt på flatene.

### 5.3.1 Midling og median-filtrering

#### Teori

I de innledende forsøkene ble det forsøkt med enkle basisfiltre som midling og median filtrering.

*Midling* gir senterpikselen i et  $M \times N$  naboskap middelverdien av alle pikselverdiene i naboskapet.

*Median filtrering* gir senterpikselen den midterste verdien i en sortert tabell over pikselverdiene i naboskapet.

Det ble her eksperimentert med ulike vindusstørrelser for å forsøke å finne et optimalt fast vindu som kunne filtrere bort det meste av støyen, men samtidig bevare årringsinformasjonen.


### **Diskusjon av resultater**

Midling og median-filtrering viste seg å fungere lite tilfredsstillende. På grunn av den tildels svært grove støyen i bildene kreves det store vinduer for å filtrere den vekk, noe som fører til at små detaljer som smale årringsmønstre også fjernes. For bredere og tilnærmet ensrettede årringsmønstre fungerte derimot metodene brukbart. Median filteret viste seg imidlertid å fungere best, både ved at det gir bedre kontrast mellom vår- og sommerveden og ved at det sparer smalere årringer. Denne egenskapen ved medianfilteret er illustrert i figur 5.4 på neste side. Som en ser av figuren er median-filteret overlegent middelvei-filteret når det gjelder å bevare step-funksjoner og er mer robust mot å la ekstremverdier påvirke den generelle gråtonen i området rundt støyimpulser. En ser imidlertid at medianfilteret i likhet med midling flater ut triangel-funksjonen. Medianfilteret fjerner impulsfunksjoner med en periode som er under halvparten av vindusbredden.


Selv om medianfilteret i større grad enn midling ser ut til å bevare linjene for våre bilder, vil det for tynne linjer kunne fjerne disse totalt, slik illustrert i figur 5.5 på neste side. Siden en i våre bilder kan finne linjer ned mot en piksels bredde, er dette ikke noen ønskelig egenskap for vår applikasjon. Et medianbasert filter som kan bevare linjer er imidlertid beskrevet i [10]. Dette filteret kan i tillegg til en viss grad gjøres selektivt for hvilken form den støyen som skal undertrykkes har. Metoden er imidlertid noe ad hoc og må i betydelig grad tilpasses vår applikasjon og støyproblematikk. En vurderte det derfor som usikkert hvor mye det er å vinne med denne metoden, og valgte å ikke gå videre med å implementere den.

Bildene i figur 5.6 på side 40 viser noen resultater med disse filtrere.





Figur 5.4: Sammenligning av median filtrering og midling med vindusstørrelse 5 på diverse en-dimensjonale test signaler. Fra [19].



Figur 5.5:  
 (a) Et linje-objekt som blir helt fjernet av medianfilteret.  
 (b) Et objekt med hjørner som blir erodert vekk av median filteret. Fra [7].

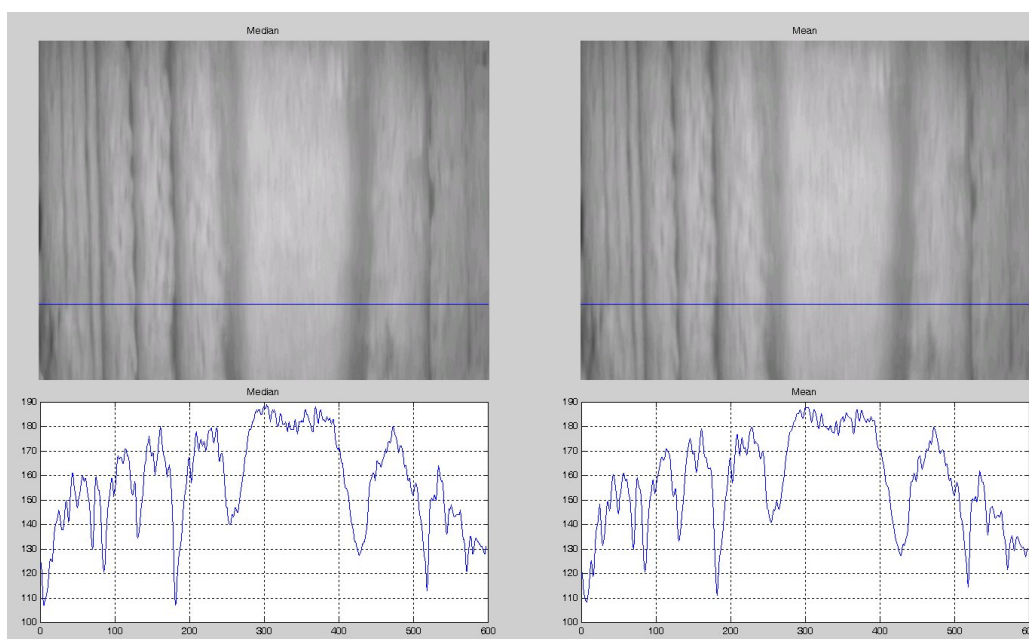
### 5.3.2 KNN- og KNCN støyfiltrering

#### Teori

*K-nearest neighbour* støyfiltreringsalgoritme midler over de  $k$  pikslene i naboskapet (definert av vindusstørrelsen) som ligger nærmest senterpikselet i gråtone.

Dette er en støyfiltreringsmetode som i langt større grad bevarer kanter, og i tillegg er mer retningsuavhengig enn de forannevnte filtrene. I våre forsøk ble det kun brukt kvadratiske vinduer med denne metoden.


*K-nearest connected neighbour* midler over de  $k$  pikslene som ligger nærmest senterpikselet i gråtoneverdi, og samtidig enten direkte eller via andre av de  $k$  pikslene er sammenkoblet med senterpikselet. Algoritmen har altså ikke noen definert vindusstørrelse, men søker suksessivt utover fra senterpikselet, etter et slags “region growing” prinsipp, helt til den har funnet  $k$  piksler å midle over



Figur 5.6: Resultatbilder oppnådd med median (t.v.) og midling støyfiltrering på prøveeksemplar nr. 2, samt profilplott langs samme linje i bildene. Det er her benyttet en vindusstørrelse på  $30 \times 3$  for begge filtrene.

### Diskusjon av resultater

Figur 5.7 viser resultatene av de to støyfiltreringsalgoritmene med de parameterinnstillingene en vurderte som den beste avveining mellom å fjerne støy, samt bevare informasjon (henholdsvis  $k=30$  og  $200 \times 200$  vindu for KNN (implementasjonen tillot kun kvadratiske vinduer) og  $k=200$  for KNCN). Hvis en sammenligner med originalen i appendiks A på side 161, kan en for begge algoritmene se at noe av støyen i vårvedregionene har fått en lysere gråtone, og går mer i ett med forgrunnen. En ser imidlertid også at en i visse regioner har fått dårligere kontrast mellom vår- og sommerved. Ved sammenligning av de to algoritmene kan en se at KNCN opprettholder kontrasten i de finere årringsmønstrene i større grad enn KNN. Den har imidlertid også noe dårligere støyfjerningsegenskaper enn KNN har ved denne parametersettingen. En videre økning av  $k$ 'en i KNCN viste seg imidlertid å gi liten effekt. Det sistnevnte skyldes antagelig begrensninger i implementasjonen av KNCN algoritmen som ble brukt ved testing. Siden resultatene ikke virket mer lovende for lavere  $k$ , valgte en imidlertid å ikke bruke tid på å finne alternativer for å unngå disse begrensningene.



Figur 5.7: Beste resultater oppnådd med KNN- (t.v.) og KNCN støyfiltrering på prøveeksemplar nr. 1. KNN har her en vindusstørrelse på  $200 \times 200$  og  $k=30$ , mens KNCN har  $k=200$ .

Som en ser av bildene gir begge metodene relativt liten støyreduksjon ved bruk av

parametere som i stor nok grad bevarer kontrasten i de smalere årringsmønstrene. Noe av årsaken til dette er at gråtonen til støyen i bildene ofte har en betydelig høyere kontrast enn objektene en ønsker å fremheve. Det vil si gråtonen til støyen i vårvedregionene kan ha en langt lavere verdi enn gråtonen i sommervedregionene og vice versa. Siden KNN og KNCN kun midler over de pikslene som ligger nærmest i gråtoneverdi, vil ikke denne typen støy glattes ut i det hele tatt for lavere  $k$ -verdier.

## 5.4 Kantfiltrering

Den største utfordringen i forbindelse med denne oppgaven viste seg, ikke overraskende, å være deteksjon av de smaleste åringene. Vi bestemte oss av denne grunn for å konsentrere oss mest om å finne en algoritme for å fremheve disse.

En kant i et bilde er et sted i bildet der gråtonen endres brått. I vårt tilfelle vil en overgang mellom sommer- og vårved i et bilde kunne sees på som en kant. En valgte derfor å undersøke hvilke resultater en preprosessering ved hjelp av kantfiltre kunne gi oss.

### Diverse kantoperatører

En kan konstruere et filter som gir utslag hvis det er en kant på et gitt sted i bildet  $F(x, y)$  ved å finne gradienten  $G(x, y)$  i dette punktet. Gradienten i punktet kan i det kontinuerlige domene beregnes ved å finne den deriverte langs ortogonale akser, slik den følgende likningen viser.

$$G(x, y) = \frac{\delta F(x, y)}{\delta x} \cos\theta + \frac{\delta F(x, y)}{\delta y} \sin\theta$$

I det diskrete tilfellet kan den totale gradientamplituden  $G(i, j)$  defineres ved hjelp av de to ortogonale gradientene  $G_1(i, j)$  og  $G_2(i, j)$  der

$$G(i, j) = \sqrt{[G_1(i, j)]^2 + [G_2(i, j)]^2}$$

Orienteringen i forhold til første-aksen blir da

$$\theta(i, j) = \tan^{-1} \left\{ \frac{G_2(i, j)}{G_1(i, j)} \right\}$$

Den enkleste gradientoperatoren blir da en løpende differanse mellom piksler langs 1. og 2. akse i bildet

$$G_1(i, j) = F(i, j) - F(i, j - 1) \quad G_2(i, j) = F(i, j) - F(i - 1, j)$$

Hvilket gir følgende filtermasker

$$\begin{bmatrix} 1 & -1 \end{bmatrix} \quad \begin{bmatrix} -1 \\ 1 \end{bmatrix}$$

For å gjøre gradientfilteret mer robust mot støy, er det ofte hensiktsmessig å benytte større operator-masker. En kan se på disse som sammensatte operatører, der en glatteoperasjon utføres på bildet før gradientoperasjonen [19]. Den sammensatte gradient impulsrespons kan da skrives som konvolusjonen

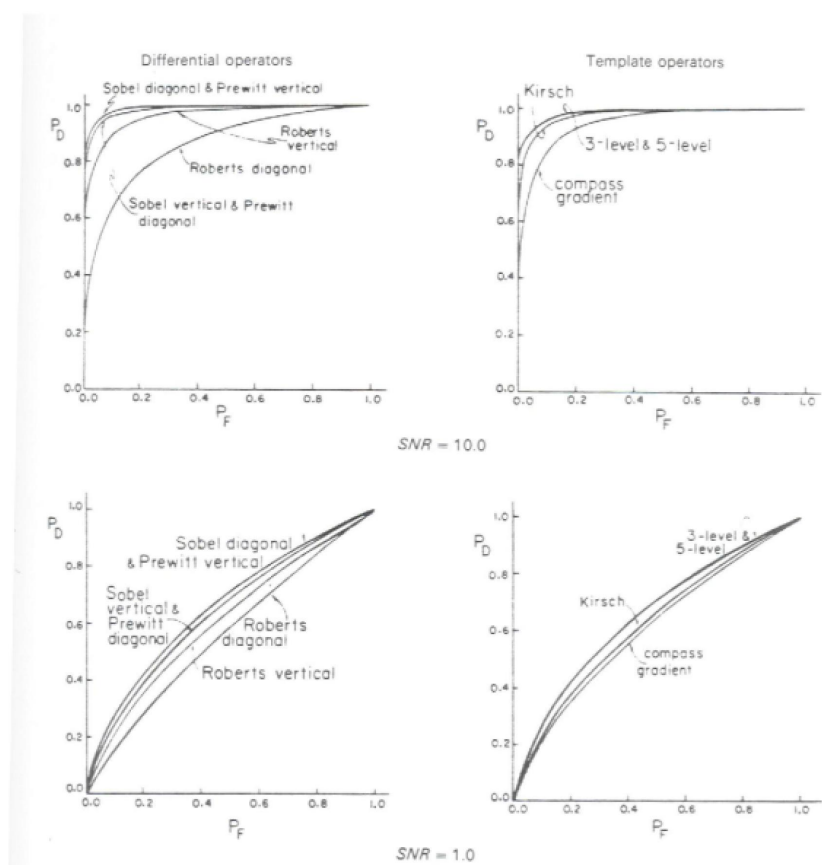
$$H(i, j) = H_G(i, j) \otimes H_S(i, j) \quad (5.12)$$

der  $H_G(i, j)$  er en gradient-operator (eksempelvis piksel-differanse operatoren nevnt ovenfor), og  $H_S(i, j)$  er en lavpass-filter impulsrespons operator. Under ser en filtermaskene for henholdsvis den vertikale 3x3 prewitt og sobel operatoren som på grunn av en glattekomponent i tillegg til en gradient operator er noe mindre følsomme for støy:


$$\begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix} \quad (5.13)$$

Figur 5.9 på side 46 viser noen enkle vertikale kantfilteroperatører testet på ytesiden av prøve nr 1.

Som en ser fremhever ingen av dem årringsmønstrene i særlig grad, og i tillegg fanger de, ikke overraskende, opp svært mye støy. Sobel og prewitt fungerer noe bedre enn piksel-differanse operatoren, men en trenger en vesentlig kraftigere glattingskomponent, og dermed større operatormasker, for å kunne håndtere så kraftig støy.



Figur 5.8: Sannsynligheten for deteksjon versus sannsynligheten for feildeteksjon for noen 2x2 og 3x3 operatorer. Fra [19]



Figur 5.9: Noen basis kantfiltermasker testet på prøve nr. 1. Ovenfra og ned: piksel-differanse, 3x3 prewitt og 3x3 sobel.



### 5.4.1 Canny's kantfiltreringsalgoritme

#### Teori

En valgte i første omgang å konsentrere seg om Canny's kantfiltreringsalgoritme, da denne i litteraturen har vist seg å gi gode resultater i forbindelse med kantdeteksjon i støyfylte, teksturerede bilder [29] [30].

John Canny valgte en analytisk fremgangsmåte for å detektere kanter i bilder [16]. Han utledet tre kriterier som var karakteristiske for en god kantdeteksjon, beskrev disse matematisk, og optimaliserte disse likningene numerisk. De tre kriteriene var som følger:

*God deteksjon:* Signal-støy forholdet til gradienten maksimaliseres slik at sannsynligheten for å ikke merke virkelige kant punkter, og sannsynligheten for å feilaktig merke punkter som ikke tilhører kanter blir lav. Matematisk kan dette kriteriet formuleres på følgende måte

$$SNR = \frac{A}{n_0} \Sigma(f) \quad , \quad \Sigma(f) = \frac{|\int_{-W}^0 f(x)dx|}{\sqrt{\int_{-W}^{+W} f^2(x)dx}} \quad (5.14)$$

der  $A/n_0$  er signal-støyforholdet til bildet, mens  $f(x)$  betegner den optimale (en dimensjonale) filteroperatoren, og  $W$  er halve vindusstørrelsen.

*God lokalisering:* Punktene som markeres som kantpunkter skal være så nær sentret til den virkelige kanten som mulig. Kriteriet uttrykkes i følgende formel

$$Location = \frac{A}{n_0} \Lambda(f') \quad , \quad \Lambda(f') = \frac{|f'(0)|}{\sqrt{\int_{-W}^{+W} f'^2(x)dx}} \quad (5.15)$$

der parametrene representerer tilsvarende størrelser som i forrige punkt.

*Single respons:* Det skal være kun en enkelt respons for hver virkelige kant. Dette uttrykkes i følgende likning

$$x_m(f) = kW \quad (5.16)$$

der  $x_m$  er avstanden mellom maksima i støyresponsen til  $f$ ,  $W$  som før er halve vindusstørrelsen, og  $k$  er en parameter som fikserer antall støymaksima som kan føre til falsk respons.

I Canny's algoritme blir produktet av likning 5.14 og 5.15 optimalisert numerisk med likning 5.16 som et begrensende kriterium. Formen på operatoren for noen

ulike verdier av  $x_m$  er vist i figur 5.10 på neste side. En ser at for større verdier av  $x_m$  vil funksjonen approksimere en derivert av en gaussfunksjon, mens for lav  $x_m$  vil den nærme seg en trunkert “boxcar” funksjon. Ifølge Canny’s artikkel er det her filteret med  $x_m = 1.20$  som gir den beste ytelsen når det gjelder multipl respons kriteriet. Hvis en velger å optimalisere med hensyn på dette kriteriet ser en at den resulterende impulsresponsen ligger relativt tett opptil den deriverte av en Gauss-funksjon. Av effektivitetshensyn valgte også Canny å benytte denne approksimasjonen i sin implementasjon. Ved å tolerere en liten reduksjon i multipl respons kriteriet er det imidlertid mulig å oppnå signifikante forbedringer i de andre to. Den en-dimensjonale optimale operatoren konvolveres så med en ortogonal projeksjonsfunksjon orientert parallelt med kanten, for å danne en to-dimensjonal maske. (Retningen til kanten defineres her som den retningen tangenten til kantens kontur har i det aktuelle punkt.)

### Diskusjon av resultater

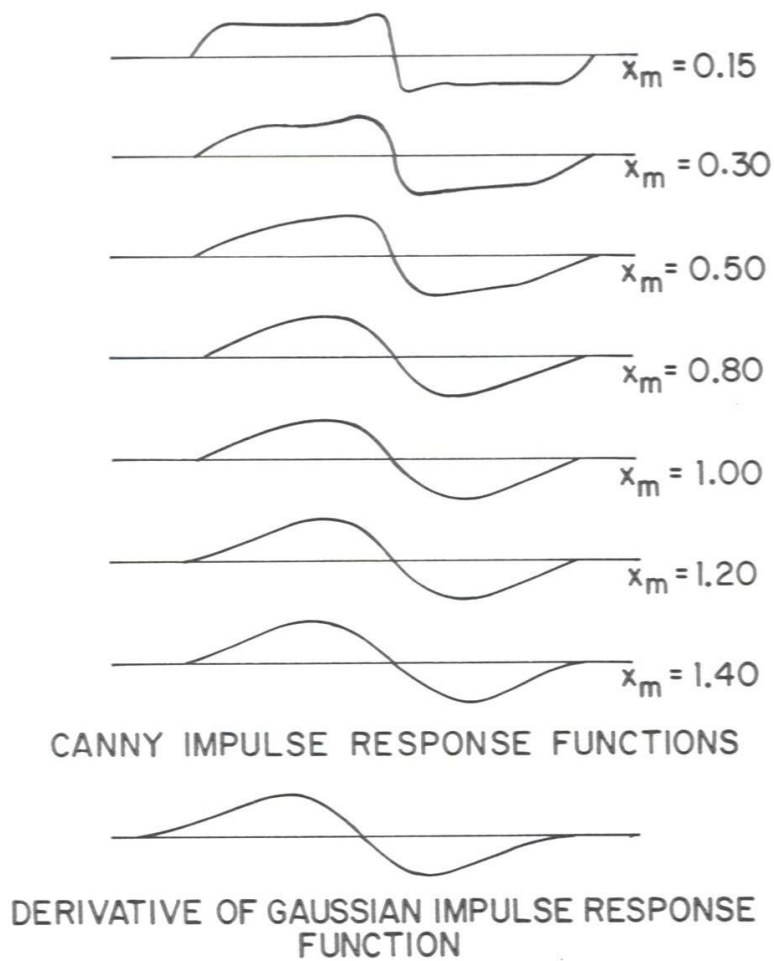
Figur 5.11 på side 50 viser henholdsvis absolutt magnitude- og vinkelbilde ved bruk av Canny’s kantfiltrering med et standardavvik på  $\sigma = 1.25$ . En ser at denne metoden fungerer bedre enn kantoperatorene prøvd tidligere, men at den i tillegg til å ringene også fremhever en del støy. En ser her at vinkelbildet gir den beste separasjonen mellom årringer og støy, noe som ikke er overraskende siden årringene - ihvertfall mot kanten av lamellene - er orientert i tilnærmet samme retning, mens støyen er mer tilfeldig orientert.

Et problem med denne metoden er imidlertid - i likhet med de fleste andre kantoperatører - at den er optimalisert for å gi best respons på kanter med form som likner step-funksjoner [25] [16], det vil si kanter som vist i figur 5.12 på side 50 (b). Selv om metodene da som oftest også vil gi en respons på linjeformede objekter i bildet, vil responsen, i tillegg til å ikke gi et optimalt signal støyforhold, kunne gi en systematisk feil i posisjonen [26], samt at den vil gi dobbel deteksjon av bredere linjer. For svært smale (høyfrekvente) årringer, det vil si nær en piksels bredde, vil dessuten noen kantoperatører gi respons lik null slik figur 5.13 på side 51 illustrerer.


## 5.5 Linjefiltrering

### 5.5.1 Diverse Linjeoperatører


Figur 5.14 på side 52 viser noen vanlige operatormasker for å detektere linjeformede objekter (slik vist i 5.12 på side 50) i bilder.



Figur 5.10: Sammenlikning av Canny og den deriverte av gauss-funksjonen sine impulsresponser. Fra [19]



Figur 5.11: Resultater ved bruk av Canny's kantfiltrering med et standardavvik på  $\sigma = 1.25$  på prøve 1. Bildet t.v. viser absoluttverdien av amplituderresponsen, mens bildet t.h. viser vinkelresponsen.



Figur 5.12: Ulike endimensjonale kant- og linjemodeller. Fra [19].

### 5.5.2 Annenderivert av Gaussisk operator

En metode for å danne en linje operator er å konvolvare to en-dimensjonale ortogonale funksjoner, der den ene er en ren gaussisk funksjon, mens den andre er den annen-deriverte av en gaussisk funksjon (Laplacian of Gaussian – eller LoG). Utrykt matematisk har en altså:

$$H(i, j) = (H_G \otimes H_L)(i, j) \quad (5.17)$$

der  $H_G$  er en  $M \times 1$  matrise samlet fra en en-dimensjonal Gauss-funksjon gitt ved

$$g(y, \sigma_1) = \frac{1}{\sqrt{2\pi}\sigma_1} e^{-\frac{y^2}{2\sigma_1^2}} \quad (5.18)$$

og  $H_L$  er en  $1 \times N$  matrise samlet fra den annen-deriverte av en en-dimensjonal Gauss-funksjon gitt ved <sup>1</sup>

$$l(x, \sigma_2) = -\frac{1}{\sqrt{2\pi}\sigma_2^3} e^{-\frac{x^2}{2\sigma_2^2}} \left(1 - \frac{x^2}{\sigma_2^2}\right) \quad (5.19)$$

En får da en operatormaske som vist i figur 5.15 på side 53. En ser at masken har en gaussisk glatte-komponent i y-retningen, mens komponenten i x-retning har null bias, og en form som gir høy respons på linjer (“ridges”) i bildet.

<sup>1</sup>En filter-funksjon av denne formen betegnes også ofte som et sombrero- eller "mexican hat-filter og er i sin 2-dimensjonale form foreslått av Marr og Hildrith [38] som en operator for kant-deteksjon.

		<b>-1</b>	<b>0</b>	<b>1</b>	
		<b>-1</b>	<b>0</b>	<b>1</b>	
		<b>-1</b>	<b>0</b>	<b>1</b>	

Figur 5.13: Illustrasjon av et kantfilter benyttet på et høyfrekvent bilde. Konvolusjonen vil her gi 0 respons når bildet inneholder linjemønstre med en periode på to piksler.


	Unweighted line	Weighted line
$H_1$	$\begin{bmatrix} -1 & 2 & -1 \\ -1 & 2 & -1 \\ -1 & 2 & -1 \end{bmatrix}$	$\begin{bmatrix} -1 & 2 & -1 \\ -2 & 4 & -2 \\ -1 & 2 & -1 \end{bmatrix}$
$H_2$	$\begin{bmatrix} -1 & -1 & -1 \\ 2 & 2 & 2 \\ -1 & -1 & -1 \end{bmatrix}$	$\begin{bmatrix} -1 & -2 & -1 \\ 2 & 4 & 2 \\ -1 & -2 & -1 \end{bmatrix}$
$H_3$	$\begin{bmatrix} -1 & -1 & 2 \\ -1 & 2 & -1 \\ 2 & -1 & -1 \end{bmatrix}$	$\begin{bmatrix} -2 & -1 & 2 \\ -1 & 4 & -1 \\ 2 & -1 & -2 \end{bmatrix}$
$H_4$	$\begin{bmatrix} 2 & -1 & -1 \\ -1 & 2 & -1 \\ -1 & -1 & 2 \end{bmatrix}$	$\begin{bmatrix} 2 & -1 & -2 \\ -1 & 4 & -1 \\ -2 & -1 & 2 \end{bmatrix}$
Scale factor	$\frac{1}{6}$	$\frac{1}{8}$

Figur 5.14: Noen 3x3 impuls respons masker for deteksjon av linjer.

Canny [16] og Petrou [25] foreslår en optimal operator for linjedeteksjon basert på Canny's tre kriterier nevnt i 5.4.1 på side 47.

Petrou foreslår en funksjon som kan tunes til å modellere de ulike intensitetsprofilene en ønsker å detektere, og benytter så funksjonslikningen sammen med Canny's kriterier til å finne en optimal operator for denne typen profil. Noen eksempler på modellering av ulike lineære intensitetsprofiler fra bilder er vist i venstre halvdel av figur 5.16 på neste side, mens høyre side av figuren viser en sammenlikning mellom responsen til det optimale filteret og et sombrero-filter på en syntetisk intensitetsprofil. Parametrene til sombrero-filteret er her satt slik at støykarakteristikkene er det samme som det optimale filteret. Petrou definerer her støykarakteristikkene ved hjelp av to faktorer. (i) Diskontinuiteten til filteret når det er trunkert til en endelig bredde. (ii) Kvadratsummen av koeffisientene når det er diskretisert.

Som en ser av figuren gir det optimale filteret en betydelig høyere respons på intensitetsprofilen enn sombrero-filteret. En må imidlertid her ta i betraktning at det optimale filteret er spesialtilpasset den aktuelle profilen, som her har en svært enkel form, og sannsynligvis kan approksimeres perfekt med Petrou's modelleringsfunksjon. Selv om denne funksjonen er demonstrert som relativt fleksibel til å approksimere ulike intensitetsprofiler i Petrou's artikkel, vil en nok svært sjelden oppnå et så godt resultat på virkelige bilder. For de fleste bilder - inkludert våre -



Figur 5.15: Filtermaske. Annenderivert av en 1-D Gauss-funksjon konvolvert med en ortogonalt orientert 1-D Gauss-funksjon

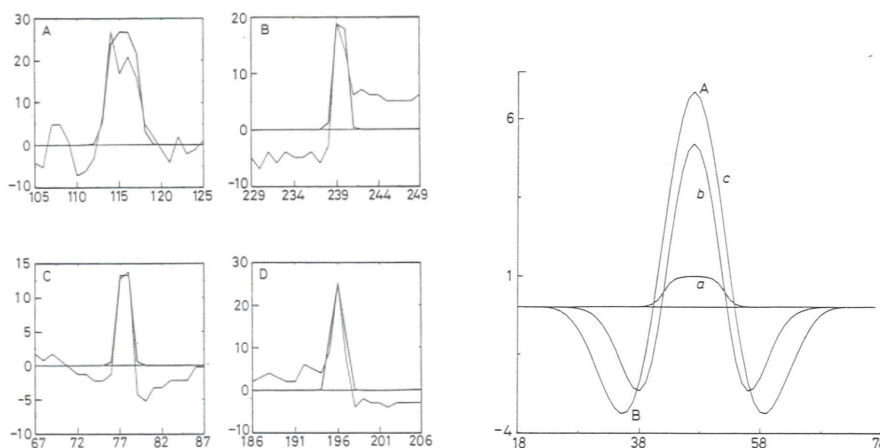
vil det dessuten være et stort spenn i hvilken størrelse og form de ulike profilene har, slik at det vil være en betydelig utfordring å finne et representativt utvalg av intensitetsprofiler.

### 5.5.3 Linjeproeksjon

Selv om årringene i utgangspunktet har en buet form, vil denne buen lokalt - ihvertfall nær ytterkanten av lamellene - ha en så svak krumning at en kan se på de som lineære. Støyen i bildet har imidlertid en mer tilfeldig orientering, og generelt en mindre vertikal utstrekning enn årringene. En enkel metode for å øke signal/støy-forholdet er da å projisere hver kolonne av bildet ned til en linjeprofil, slik uttrykt i likning 5.10 på side 35. Hver verdi i den projiserte linjen vil altså være summen av alle  $J$  gråtoneverdiene i den respektive kolonnen på 2D-bildet (eller eventuelt middelverdien hvis en vokter summen med  $1/J$ ).

### 5.5.4 Vindusstørrelser og adaptivitet

Vindusbredden og høyden for lavpassfiltre er proporsjonal med hvor mye bildet skal gattes ut i de forskjellige retningene. Siden en i vårt tilfelle er ute etter å



Figur 5.16:

Figuren t.v.: Intensitetsprofiler fra noen bilder og den approksimerte modell av profilen.


Figuren t.h.: Syntetisk linjeprofil (a), og de respektive filterresponser til sombrero-filteret (b) og Petrou's optimale filter (c).

Fra [25].



bevare årringer med liten horisontal utstrekning, men samtidig glatte ut til dels grov støy, er det generelt ønskelig med sterk glatte effekt i vertikal retning, mens en i horisontal retning ønsker å bevare så mye av informasjonen som mulig. Siden årringene ikke er helt rette og vertikale er en imidlertid begrenset oppad når det gjelder høyden på filtermasken, før en glatter ut sommerveden mot bakgrunnen og mister vesentlig informasjon.

Dersom en benytter filtermasker som er større enn minste periode i årringsfrekvensen vil en oppleve en aliasing effekt, i den forstand at responsen til filteret er basert på flere årringsperioder istedenfor bare et enkelt sommerved signal mot en vårved bakgrunn. Resultatet av dette er som en ser av figur 5.17 at responsene til de høyfrekvente årringene glattes ut, og i noen tilfeller er helt fraværende.



Figur 5.17: *LOG-filter med fast  $\sigma$  benyttet på bilde som inneholder sommervedregioner med ulik bredde. Som en ser er her filteret rimelig bra tilpasset de bredere sommervedregionene, mens en for de smalere regionene får dårlig respons som følge av utglating og aliasing.*


Det er altså ønskelig å tilpasse vindusbredden til filteret (og dermed  $\sigma$ ) utfra frekvensen til de lokale årringene i bildet slik at en får et best mulig signal/støy forhold. Som beskrevet i seksjon 5.5.3 på forrige side vil en vertikal projeksjon av det filtrerte bildet ned til en vektor,  $x$ , generelt gi en økning av signal/støy-forholdet. Det er da naturlig å trekke ut et egenskapsmål som sier noe om signal/støy-forholdet fra denne projeksjonen for et sett med ulike filterstørrelser og benytte det filteret som scorer best innenfor hver horisontale subregion.

En fant i dette bildematerialet at en filterbank med tre forskjellige vindusstørrelser var et hensiktsmessig kompromiss mellom adaptivitet og prosesseringsmengde, samt at  $\sigma_1 = 1.5$ ,  $\sigma_2 = 3.75$  og  $\sigma_3 = 6$  ga en fornuftig tilpasning for det typiske spennet av sommervedbredder (verdiene halveres for prøve 1-4 som ble avbildet med lavere oppløsning). Estimeringen av beste filterstørrelse ble gjort for vindusstørrelser på  $w_x \approx 7\sigma$  for hvert  $k = 10$  piksel langs bildets x-akse som en avveining mellom trunkeringsfaktor, adaptivitet og prosesseringshastighet. For

den gaussiske glattingskomponenten i vertikal retning ble det benyttet  $\sigma = 7$  og en konstant vindusstørrelse på  $w_y = 43$  (tilsvarende  $6\sigma$ ).

Som egenskapsmål for å velge hvilken filterstørrelse en skal benytte innenfor en gitt subregion valgte en da å benytte det filteret som ga høyest maksimalrespons,  $\max(\mathbf{x})$ , innefor de sentrale  $k$  pikslene i den vertikale projeksjonen.

Som en ser av det kunstig genererte testbildet i figur 5.18 gir algoritmen en fornuftig tilpasning til de ulike linjebreddene og fremhever de vertikale linjene effektivt mens støyen undertrykkes. Noen eksempler på resultater fra denne algoritmen for reelle bilder er blant annet vist i figur 6.4 på side 63 til 6.7 på side 66. Også på disse bildene ser en at algoritmen tilpasser seg vekslingene i årringsbredder på en fornuftig måte, selv om en fortsatt har en del støy på grunn av opprevete fibre med høy kontrast og større vertikal utstrekning – spesielt når flere av disse ligger nær hverandre i x-posisjon og vel innenfor vindusstørrelsen i y-posisjon slik at de adderes i glattekomponentens respons.



Figur 5.18: Adaptiv LOG-filter algoritme benyttet på et syntetisk generert bilde der en har generert vertikale linjer av ulik bredde med kontrast= 0.1 (øverste bilde) og lagt til gaussisk støy med  $\sigma = 0.15$  (midten). Resultatbildet fra filtreringen er vist nederst. Den adaptive algoritmen velger her filteret med  $\sigma$  lik henholdsvis 1.5, 3.75 og 6 for linjen til venstre, midten og til høyre. I regionene utenom linjene velges typisk  $\sigma = 1.5$  siden støyen her er såpass finkornet.

# Kapittel 6


## Segmentering

### 6.1 Global terskling av 2D bilde


Det ble initielt gjort forsøk med en fast global terskel på originalbildene. Noen eksempler på dette er vist i figur 6.1 på neste side. En ser her at en sitter igjen med mye støy når en setter terskelen slik at en får med flest mulig av årringene. Mange av de svakere årringene lar seg dessuten ikke detektere i det hele tatt ved bruk av denne metoden. En global tersklingsmetode er altså uegnet for å skille mellom vårved og sommerved for disse bildene. En liknende konklusjon ble også trukket i [3].

### 6.2 Global terskling av linjefiltrert 2D bilde


En gjorde så noen forsøk med global terskling av responsen til linjefilteret beskrevet i seksjon 5.5.2 på side 51. En søkte her å finne en fast terskel som ville fungere for alle årringstyper. Figur 6.2 på side 59 og 6.3 på side 60 viser resultater for årringsmønstre av ulik størrelse og kontrast. Som en ser av bildene får man en god del støysegmenter samt at sommervedsegmentene i stor grad inneholder brudd. En ser at det ville kreve en meget omfattende postprosessering og analyse for å plukke ut sommervedområdene i de tersklede bildene. I visse tilfeller er det antagelig heller ikke mulig. En fant det derfor nødvendig med ytterligere pre-prosessering før en eventuell global terskling kan finne sted.



Figur 6.1: Resultater ved global fast terskel lik 142 på et utsnitt av henholdsvis prøve 2 overflate 1 og prøve 4 overflate 2.



Figur 6.2: Resultater: prøve 2, overflate 1 og 2. Filtrert v.h.a. annenderivert av gaussisk operator med maskestørrelse  $31 \times 31$  og  $\sigma = 3$ , og så tersklet med fast global terskel. Originalbilder øverst, filtrerte bilder i midten og tersklede bilder nederst.



Figur 6.3: Resultater: prøve 1, overflate 1 og 2. Filtrert v.h.a. annenderivert av gaussisk operator med maskestørrelse  $31 \times 31$  og  $\sigma = 3$ , og så tersklet med fast global terskel.

### 6.3 Global terskling av 1D projeksjon

Etter projeksjon av preprosessert bilde ned til en dimensjon har en et økt signal/støyforhold, som gjør det enklere å sette terskelen slik at sommerveden detekteres, mens det meste av støyen gir en respons som er lavere enn terskelen. Etter å initielt ha prøvd med en global fast terskel også her, oppdaget en at på grunn av de store variasjoner i årringenes kontrast og støyens grovhet for de ulike flatene, og dermed den projiserte respons fra gauss-filteret, vil det være vanskelig å finne en terskel som fungerer for alle variantene. En valgte derfor å benytte en dynamisk - eller globalt adaptiv - tersklingsmetode, der terskelen bestemmes ut fra egenskaper i hvert enkelt bilde.

I en globalt adaptiv tersklingsrutine som er mye benyttet settes terskelen,  $T$ , basert på middelverdien og et vektet standardavvik i linjevektoren,  $f$ . Vi har altså

$$T = \mu_f + k\sigma_f \quad (6.1)$$

der  $\mu$  er middelverdien, og  $\sigma$  er standardavviket for hele vektoren. Den binære resultatvektoren ved å terskle  $f$  er da gitt ved

$$o(i) = \begin{cases} 1, & \text{hvis } f(i) > T \\ 0, & \text{ellers} \end{cases}$$

Parameteren  $k$  gir en her mulighet til å justere ømfintligheten til tersklingsmetoden. Hvis en velger en høy positiv  $k$  vil metoden være robust mot falske deteksjoner, men vil ikke registrere sommervedområder som har en svakere respons i linjeprofilen. Ved lavere og negativ  $k$  vil effekten være motsatt. En fant her at en  $k = 0.6$  var et godt kompromiss mellom disse faktorene.

Figur 6.4 på side 63 og 6.5 på side 64 viser oppnådde resultater ved bruk av den globale dynamiske tersklingsmetoden basert på middelverdi og vektet standardavvik. Terskelen er indikert ved en rød heltrukken linje i projeksjonsplottet, mens de grønne, stiplede linjene indikerer middelverdi og standardavvik. En ser her at terskelen settes lavere for rene, lavkontrast bilder, mens bilder med mye støy mellom årringene og/eller høy kontrast får en høy middelverdi og høyt standardavvik, og dermed en høyere satt terskel. Terskelen tilpasser seg her, slik bildene viser, de ulike overflateegenskapene til trevirket på en brukbar måte, men det forekommer fremdeles falske deteksjoner hvis en har grov støy i bildet. Som en ser - spesielt i figur 6.5 på side 64 - skjer det også at årringene har en så svak respons i 1D-projeksjonen at de ikke blir detektert med denne metoden.

Et annet problem med metoden er at den ikke tar noe hensyn til mer lokale variasjoner i trevirkets overflateegenskaper. Som en spesielt ser i figur 6.6 på side 65,

kan det være svært store variasjoner i kontrasten mellom vår- og sommerved på korte horisontale intervaller innen bildet. I slike tilfeller vil regionene med høy kontrast kunne trekke opp den globale terskelen til et nivå som ligger over de langt lavere responsene i regioner der årringene har lav kontrast og/eller er svært smale.

## 6.4 Lokal adaptiv terskling av 1D projeksjon

### 6.4.1 Metode basert på middelvei og vektet standardavvik

For å kunne kompensere for de store lokale variasjonene i trevirkets kontrast, og dermed i responsen til filtreringsmetoden, kan en benytte lokal adaptiv terskling. En benyttet også her i prinsippet samme metode beskrevet i avsnitt 6.3 på forrige side og likning 6.1 på forrige side for å beregne terskelen, men gjorde nå dette for lokale vinduer langs den projiserte vektoren.

Figur 6.6 på side 65 og 6.7 på side 66 viser noen resultater med metoden basert på middelvei og vektet standardavvik for et lokalt vindu innen regionen. Standardavviket ble her vektet med en faktor  $k = 0.6$  for å få et kompromiss mellom en terskel som detekterer de fleste av årringene, og samtidig i størst mulig grad unngår feildeteksjoner. En fant at en vindusbredde på  $w = 17$ , var hensiktsmessig for å få en adaptivitet som kan tilpasse seg de brå lokale variasjonene i årringenes respons, og samtidig kunne beregne parametrene over et såpass stort intervall at en ikke plukker opp alle små lokale støyfluktuasjoner.


Som en ser tilpasser metoden seg de lokale variasjonene i trevirket godt, og gjør det mulig å detektere de svært svake årringene samtidig som en får en mer robust deteksjon av de mer tydelige årringene. Hovedproblemet med denne metoden er at hvis man skal sette parametrene slik at de svake og små årringene slik vist i figur 6.6 på side 65 detekteres, detekterer man også noe grov støy slik vist i figur 6.7 på side 66. Responsen fra støyen er her i noen tilfeller høyere enn den en får fra de smale og svake årringene.

### 6.4.2 Bernsens metode


Bernsen [17] har foreslått en lokal adaptiv tersklingmetode som er relativt enkel og rask, i tillegg til at den har en justeringsparameter som gjør det mulig å til en viss grad eliminere feildeteksjoner på grunn av støy.

Hvis en lar  $F(k, l)$  være intensitetsfunksjonen til bildet, vil terskelen for et piksel  $(k, l)$  i bildet være gitt ved







Figur 6.4: Resultater: prøve 2, overflate 1 og 2. Global adaptiv terskling av linjeproeksjon basert på middelerdi og standardavvik, med parameter  $k=0.6$ . En har her originalbildene i øverste rad mens de påfølgende radene representerer gradvis senere steg i preprosesseringssekvensen. Her henholdsvis adaptiv annen-derivert av gauss linjefiltrering, vertikal projeksjon til linje, terskling av linjeproeksjon. Dette prinsippet for å vise resultatene fra forskjellige steg i preprosesseringssekvensen er også benyttet senere i dette kapitlet.



Figur 6.5: Resultater: prøve 1, overflate 1 og 2. Global adaptiv terskling basert på middelvei og standardavvik, med parameter  $k=0.6$



Figur 6.6: Resultater: prøve 4, overflate 1 og 2. Lokal adaptiv terskling basert på middelerdi og standardavvik, med parametrene  $w=17$  og  $k=0.6$

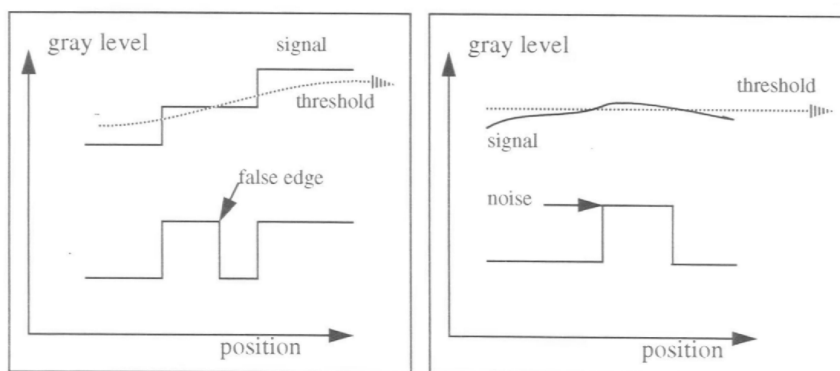


Figur 6.7: Resultater: prøve 2, overflate 1 og 2. Lokal adaptiv terskling basert på middelvei og standardavvik, med parametrene  $w=17$  og  $k=0.6$

$$T(k, l) = \frac{1}{2} [MAX_{window}(F(k + i, l + j)) + MIN_{window}(F(k + i, l + j))] \quad (6.2)$$

for en vindusstørrelse på  $2m + 1$  og  $i, j = -m, \dots, m$ , og der  $MAX$  og  $MIN$  står for maksimum- og minimumverdien innen vinduet.

Terskelen for senter-pikselet i et vindu er altså gitt ved middelverdien av maksimum- og minimumverdien innenfor vinduet.



Figur 6.8:

- (a) Et trappetrinnsformet gråtoneprofil og den resulterende feildetekterte kant.  
 (b) Et tilnærmet homogent signal der tersklingen introduserer støy.

En fordel med denne metoden er at den detektere svært svake signaler. Dette gjør den imidlertid også svært følsom for støy – spesielt når hele vinduet er plassert i et tilnærmet homogent område, eller i intensitets-profiler med trappetrinnsform slik figur 6.8. For å unngå dette problemet innførte Bernsen en kontrastfunksjon, der kontrasten i hvert vindu er definert ved

$$C(k, l) = MAX_{window}(F(k + i, l + j)) - MIN_{window}(F(k + i, l + j)) \quad (6.3)$$


Kriteriet for å benytte terskelen på en gitt piksel bestemmes da ved

$$o(k, l) = \begin{cases} 1, & \text{hvis } F(k, l) > T(k, l) \text{ og } C(k, l) > C_{min} \\ 0, & \text{ellers} \end{cases}$$

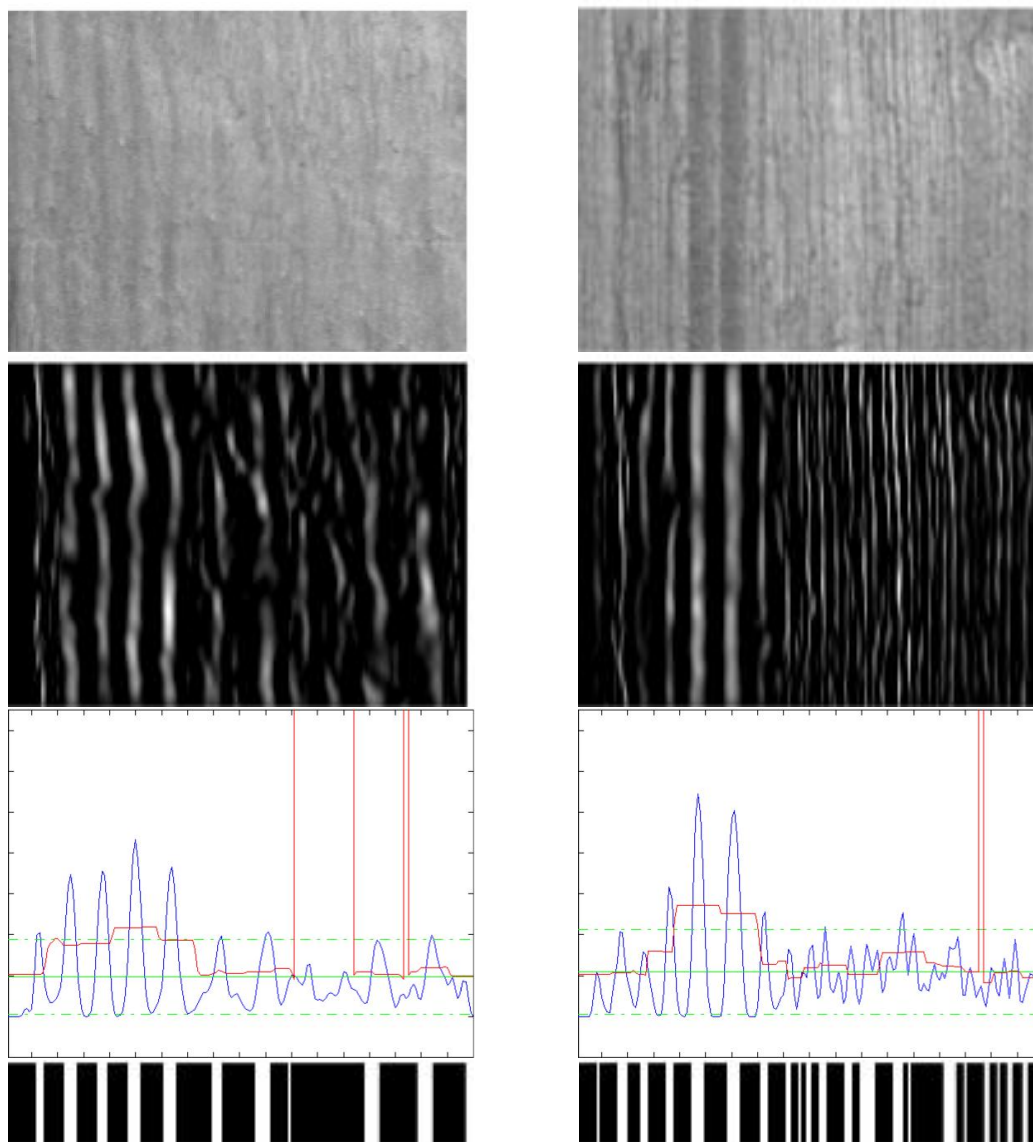
I vårt tilfelle hadde vi imidlertid kun behov for å benytte Bernsens metode i en-dimensjon, det vil si på den projiserte vektoren. Den en-dimensjonale varianten som ble benyttet er her helt analog til likningene over.

Figur 6.9 på neste side og 6.10 på side 70 viser noen resultater fra Bernsens adaptive tersklingsmetode benyttet på bilde som er filtrert og projisert til en linje. En fant også her at en lokal vindusstørrelse på 17 piksler var mest egnet utfra samme begrunnelse som avsnitt 6.4.1 på side 62. Minimum kontrast for deteksjon av et sommerved segment ble satt til 30 gråtoner, og lokale regioner med lavere kontrast ble satt til svart. Denne parameterverdien ble funnet å fungere best utfra forsøk, og er et kompromiss mellom god deteksjon av årringer med svak kontrast, og minimalisering av antall feildeteksjoner på grunn av støy.

Hvis en sammenligner med figur 6.7 på side 66, ser en at en her unngår noen av de feildeteksjonene en hadde med tersklingsmetoden i forrige avsnitt, på grunn av at disse ikke overstiger minimum kontrast parameteren. En kan imidlertid også se at noen plasser der det faktisk er årringer, detekteres ikke disse på grunn av at kontrasten blir for svak. De lokale regionene der kontrasten er lavere enn minimumsverdien er på figuren indikert ved at terskelen er satt til maksimum (gråtone 255).




Figur 6.9: Resultater: prøve 2, overflate 1 og 2. Bernsens tersklingsmetode  $m/c_{min}=30$  og  $dx=17$ . En av de beste subregioner for dette bildet




Figur 6.10: Resultater: prøve 4, overflate 1 og 2. Bernsens tersklingsmetode  $m/c_{min}=30$  og  $dx=17$ . En av de beste subregioner for dette bildet





Figur 6.11: Resultater: prøve 2, overflate 1 og 2. Bernsens tersklingsmetode  $m/c_{min}=30$  og  $dx=17$ . En av de dårligste subregioner for dette bildet.



Figur 6.12: Resultater: prøve 4, overflate 1 og 2. Bernsens tersklingsmetode  $m/c_{min}=30$  og  $dx=17$ . En av de dårligste subregioner for dette bildet.

## 6.5 Relaksasjon

En har både parallelle og sekvensielle metoder for segmentering.

- *Parallelle metoder* bestemmer klassetilhørigheten til et piksel uavhengig av at andre piksler er klassifisert (selv om de godt kan benytte egenskaper i naboskapet til pikselet).
- *Sekvensielle metoder* benytter tidligere beslutninger til å klassifisere nye piksler (f.eks. allerede klassifiserte nabopiksler), samt at de kan redefinere klassifikasjonskriteriene underveis.

Sekvensielle metoder er således fundamentalt kraftigere ettersom de kan lære underveis, og dermed definere svært presise klassifikasjonskriterier. Et hovedproblem med disse metodene er imidlertid at de er ofte er prosesseringskrevende og lite egnet for parallellprosessering ettersom de ofte benytter tidligere beslutninger til å både bestemme hvilke punkter som skal klassifiseres i neste omgang, samt hvilke klassifikasjonskriterier som skal brukes.

Relaksasjonsmetoder kan sees på som et slags hybrid mellom parallelle- og sekvensielle metoder, ettersom de iterativt oppdaterer et sett av sannsynligheter for hvert piksel ved hjelp av forrige generasjons sannsynlighet i nabopikslene. De bruker imidlertid bare informasjon fra originalbildet i det initielle steget. Etter dette forbedres resultatet – til forskjell fra sekvensielle metoder – uten støtte fra originalbildet. Relaksasjon dessuten også egnet for parallellprosessering siden hver iterasjon foregår i parallell. Vanligvis er det dessuten nok med noen få iterasjoner (typisk  $< 10$ , iflg. [33]).

### 6.5.1 Probabilistisk relaksasjon

Probabilistisk relaksasjon er en metode introdusert av bl.a. Rosenfeld [33] [32].

#### Teori

Anta at vi har et bilde med  $N$  klasser. For hvert piksel angir vi en sannsynlighet  $p(k, s)$  for at pikselet  $k$  tilhører en gitt klasse  $s$ .

Vi trenger da et samsvarsmål  $c(k, s; l, t)$  som er et mål på sannsynligheten for at pikselet  $k$  tilhører klasse  $s$  samtidig som at nabopikselet  $l$  tilhører klasse  $t$ . Vi antar så at  $c$ 'ene ligger innenfor området  $[-1, +1]$ , der  $-1$  representerer at naboen er inkompatibel,  $+1$  kompatibel, og  $0$  "don't care".

Vi lar  $p^0(k, s)$  være startestimatet av sannsynligheten for at piksel  $k$  tilhører klasse  $s$  for alle piksler og alle klasser  $s \in [1, \dots, N]$ . Metoden går så ut på å iterativt oppdatere et sett av initielle sannsynligheter for hvert piksel ved hjelp av forrige generasjons sannsynlighet i nabopikslene.

Vi lar så  $p(l, t)$  være sannsynligheten for at nabopikselet tilhører klassen  $t$ . Vi ønsker da å inkrementere  $p(k, s)$  hvis  $p(l, t)$  er høy og  $c(k, s; l, t) > 0$  siden  $k \in s$  er kompatibel med en event,  $l \in t$ , som har høy sannsynlighet. Hvis  $c(k, s; l, t) < 0$  (og  $p(l, t)$  fremdeles er høy), ønsker vi derimot å senke  $p(k, s)$  siden naboer med en slik klassetilhørighet er inkompatible. Hvis  $p(l, t)$  er lav eller  $c(k, s; l, t)$  nær 0, ønsker vi å beholde  $p(k, s)$  uforandret siden enten sannsynligheten for  $l \in t$  er liten eller dette er irrelevant for om  $k \in s$ . Disse egenskapene ivaretas med produktet  $c(k, s; l, t)p(l, t)$  som dermed gir oss det ønskede inkrementet i  $p(k, s)$ . Disse inkrementene blir så for hvert piksel lineært kombinert over alle klasser

$$\acute{c}_l(k, s) = \sum_{t=1}^N c(k, s; l, t)p^{(j)}(l, t) \quad (6.4)$$

der  $\acute{c}_l(k, s) \in [-1, 1]$ . For hver klasse  $s$  summerer vi så over alle  $n$  naboene og finneret midlere inkrement  $q$

$$q(k, s) = \frac{1}{n} \sum_{l=1}^n \acute{c}_l(k, s) \quad (6.5)$$

der  $q(k, s) \in [-1, 1]$ . Dette midlere inkrementet benyttes så til å oppdatere  $p^{(j)}(k, s)$  ved hjelp av formelen

$$p^{(j+1)}(k, s) = \frac{p^{(j)}(k, s)(1 + q(k, s))}{\sum_{t=1}^N p^{(j)}(k, t)(1 + q(k, t))} \quad (6.6)$$

der  $0 \leq p^{(j+1)}(k, s) \leq 1$  og  $\sum_{s=1}^N p^{(j+1)}(k, s) = 1$ . Dette utføres så for alle piksler i bildet, og itereres. Verdien av  $p^{(j)}(k, s)$  vil så etter et antall iterasjoner konvergere til enten 0 eller 1, og pikselet  $k$  tilordnes klassen  $s$  der  $p^{(j)}(k, s) = 1$ . Ofte ønsker en å avbryte iterasjonen før alle piksler har nådd metningstilstanden 1 eller 0. I dette tilfellet tilordnes pikselet den klassen,  $s$ , der  $p^{(j)}(k, s)$  har størst verdi.

### Initielle sannsynlighetsestimater

For å oppnå et godt resultat med relaksasjonsmetoden er det viktig at majoriteten av de initielle sannsynlighetsestimaterne for sommed (lyse regioner det filtrerte

bildet) ikke havner for langt under 0.5, og vice versa for vårved. Dette kan fort skje hvis en benytter helt enkle estimater som for eksempel  $g_i/g_{max}$  (som bl.a. ble foreslått i [33]). Hvis en eksempelvis har en sprekk i bilderegionen, vil denne gi en vesentlig sterkere respons fra linjefilteret enn svake sommervedregioner, og vil føre til så lave initielle estimater av disse at relaksasjonsprosessen glatter de ut mot bakgrunnen istedenfor å fremheve de.

For å estimere de initielle sannsynlighetene gjorde man isteden en apriori antagelse om at en (med grov tilnærming) har en fast prosentvis mengde  $P$  av pikslene som representerer vårved i bildet innen hver bilderegion for alle lameller. En kan så benytte den estimerte  $\hat{P}$ -prosentilen,  $\hat{P}_p$ , for å skalere gråtonene slik at en for det skalerte bildet får  $\hat{P} = P$ . Dette kan for det  $k$ 'te piksel i bildet gjøres med formelen

$$p^{(0)}(k, \text{vaarved}) = \frac{0.5 \cdot f_r(k)}{P_p} \quad (6.7)$$

Initielt estimat for sommerved blir da  $1 - p^{(0)}(k, \text{vaarved})$ .

Hancock og Kittler [39] benyttet en mer omfattende fremgangsmåte for å estimere de initielle sannsynlighetene. Denne går ut på å utføre en probabilistisk modellering av støyprosessen, der responsen fra linjefilterets vertikale og horisontale komponent inngår som elementer i egenskapsvektoren.

### Valg av samsvarsmål

Samsvarsmålet  $c(k, s; l, t)$  er som nevnt et mål på sannsynligheten for at pikselet  $k$  tilhører klasse  $s$  samtidig som at nabopikselet  $l$  tilhører klasse  $t$ , og bestemmes utfra apriori kunnskaper om den aktuelle oppgaven. I mange applikasjoner er det vanlig å begrense piksel  $l$  til å tilhøre et 4'er eller 8'er naboskap rundt  $k$ , ettersom de lokale klassifikasjonsresultatene i løpet av et antall iterasjoner allikevel vil forplante seg til større deler av bildet.

I vårt tilfelle har vi imidlertid sterkt retningsorienterte objekter, som har en stor utstrekning i vertikal retning, mens de generelt kun er noen få piksler brede i horisontal retning. Det er derfor grunn til å anta at en har en høy kompatibilitet mellom piksler som ligger langt mer enn én piksel unna hverandre i vertikal retning. Denne ekstra apriori kunnskapen ble også utnyttet i valg av størrelse på naboskapet som ble benyttet. En har dessuten en del støy i form av opprevde fibre og lignende som kan gi relativt lange vertikale objekter med høy initieell sannsynlighet. For å unngå at relaksasjonsprosessen forsterker disse, er det fordelaktig å benytte større vertikale "vinduer" i beregningene. Vi velger i det påfølgende å gi

piksel  $l$  en todimensjonal indeksering,  $(i, j)$  i et naboskap rundt  $k$  som får indeks  $(0, 0)$ . I det tilfellet at klasse  $s$  representerer sommerved, og  $t$  vårved, ble graden av samsvar innen vinduet valgt til å avta med offsetvinkel fra vertikalen i henhold til formelen

$$c(i, j) = \begin{cases} 1 - \left| \tan^{-1} \left( \frac{j}{i} \right) \right| & \text{for } -m \leq i \leq -1 \text{ eller } 1 \leq i \leq m, -n \leq j \leq n \\ 0 & \text{ellers} \end{cases} \quad (6.8)$$


En ser av likningen at graden av samsvar mellom naboer er uavhengig av avstand innenfor vinduet. Dette er en forenkling, men ble gjort for å effektivt kunne linke sammen objekter med stor vertikal avstand. En bedre metode ville sannsynligvis vært å øke vindusstørrelsen ytterligere, og multiplisert den vinkelavhengige samsvarsmatrisen med en Gaussisk funksjon for å oppnå større grad av samsvar for nære nabopikslar. Dette ville imidlertid også økt prosesseringstiden. Merk at likningen kan gi negativ kompatibilitet for større verdier av  $n$ , hvilket i de fleste tilfeller antagelig er uønsket. For de verdier av  $n$  som er aktuelle i vår applikasjon er imidlertid ikke dette noe problem. I horisontal retning valgte en som en ser av likningen å benytte en  $c(k, s; l, t) = 0$ , ettersom en her kan ha årringsmønstre med perioder helt ned mot to pikslar.

I det tilfellet at klasse  $s$  representerer vårved og  $t$  sommerved, ble graden av samsvar innen vinduet valgt slik at  $c(i, j) = 0.7$  for  $j = 0$  og  $i \neq 0$  og  $c(i, j) = 0$  ellers. Dette for å gi et bias mot å sommerved i klassifikasjonen, slik at smale relativt svake responser fra linjefilteret ble bevart, mens en allikevel fikk fjernet relativt store støyobjekter.

## 6.5.2 Diskusjon og resultater

En fant at en  $m$  på minimum 40 og en  $n = 1$  (tilsvarer en vindusstørrelse på 81x3) ga et godt visuelt resultat med de øvrige innstillingene som skissert ovenfor. Ved ytterligere økning av  $m$  får en bedre støyfjerningsegenskaper, men en gjør samtidig metoden noe mindre tilpasningsdyktig for lokale endringer i årringsmønstrenes vinkel, samt øker risikoen for aliasing når smale ikke helt vertikale årringer står tett inntil hverandre. I tillegg øker prosesseringstiden.


Selv om en ifølge [33] [32] i de fleste tilfeller klarer seg med maksimalt 10 iterasjoner, opplevde en for våre bilder at det ga en forbedring å la metoden kjøre enda flere iterasjoner slik figur 6.13 på neste side viser. Konvergens eller tilnærmet



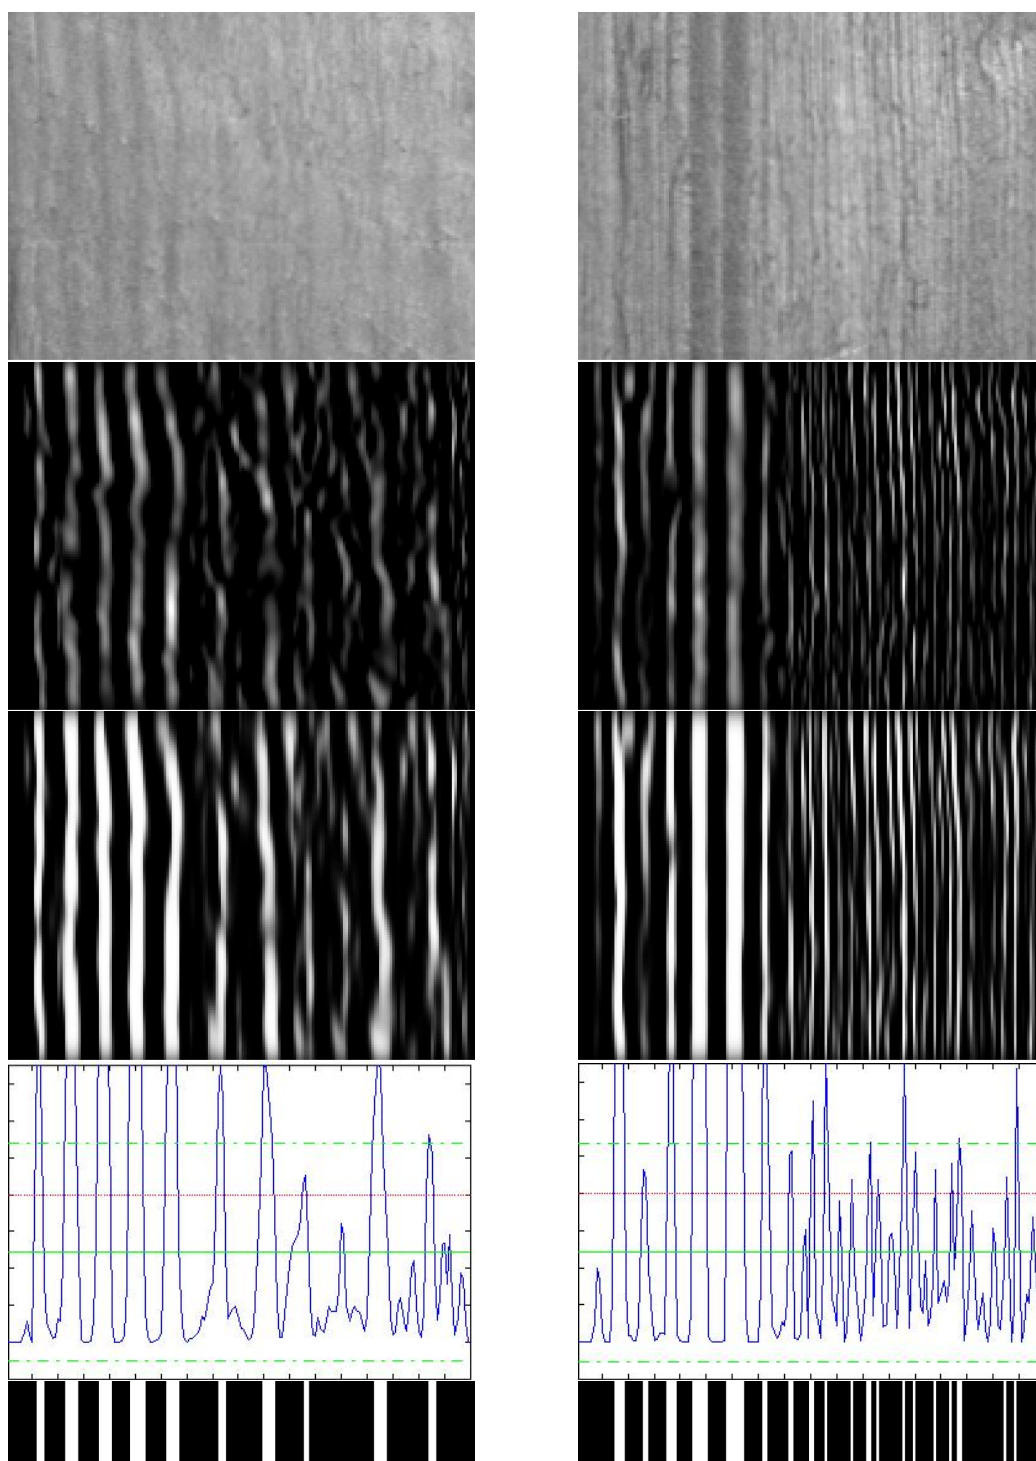
Figur 6.13: Relaksasjon på et utsnitt av prøve 2 med samsvarsfunksjon,  $c(k, s; l, t)$ , definert i et naboskap på  $81 \times 3$ . Originalbilde øverst t.v., linjefiltrert bilde øverst t.h., så relaksasjonsforbedret bilde etter henholdsvis 3, 5, 10 og 15 iterasjoner.

dette ble ikke alltid oppnådd selv etter 20 iterasjoner. Dette skyldes nok hovedsakelig at vi har såpass store og intense støyobjekter som vi ønsker å fjerne. Et stort objekt med relativt høy initiell sannsynlighet vil kreve et stort antall iterasjoner for å konvergere til sannsynlighet 0. En annen årsak er at vi har et bias mot lyse objekter i bildene for å bevare og bedre fremheve smale sommerved-objekter med relativt lav initiell sannsynlighet. En oppnår imidlertid en signifikant forbedring av bildet selv etter 4-5 iterasjoner. En valgte derfor å stoppe metoden etter 5 iterasjoner, og således bruke den kun som et bildeforbedringssteg istedenfor en ferdig klassifikasjon av pikslene. Figur 6.14 på neste side, 6.15 på side 80 og 7.2 på side 90 viser noen resultater oppnådd ved bruk relaksasjon som bildeforbedringssteg etter filtrering.





Figur 6.14: Resultater med 5 iterasjoner relaksasjon som bildeforbedringssteg og Bernsens tersklingsmetode med  $c_{min} = 80/255$ . Prøve 4.



Figur 6.15: Resultater med 5 iterasjoner relaksasjon som bildeforbedringssteg og fast tersklingsmetode med  $T = 0.4$ . Prøve 4.

## 6.6 Dual watershed segmentering

Wählby med fler [42] foreslår en segmenteringsmetode, inspirert av watershed algoritmen [43], der en benytter to terskler. Det ble her benyttet en en-dimensjonal versjon av denne algoritmen på den projiserte vektoren.

Algoritmen starter med maksimaene i bildet, og plasserer en øvre terskel der. Ulike merker blir så gitt til alle piksler som er sammenkoblet til et maksimum og samtidig har en intensitet som er høyere enn en lavere terskel. Både den øvre og den nedre terskelen blir så senket med én. Hvis så et umerket piksel med en intensitet lik den øvre terskelen blir funnet, blir denne gitt et nytt merke. Det samme merket gis så til alle sammenkoblede piksler som er umerkede og har en intensitet høyere enn den lavere terskelen. Når den nedre terskelen når en predefinert terskel for bakgrunnen vil avstanden mellom den øvre og nedre terskel avta helt til også den øvre terskelen også når terskelen for bakgrunnen.

En fordel med denne algoritmen er at en ved hjelp av avstanden mellom den øvre og nedre terskelen setter en grense for hvor små minima (daler) en kan ha mellom to maksima for at de skal tolkes som to separate objekter. En unngår altså at mindre støymaksima i nærheten av et sammervedobjekt vil tolkes som et separat objekt.

Algoritmen gir i sin basisform anledning til at to forgrunnsobjekter kan ligge helt inntil hverandre. Ved celle-avbildning i flouriserende mikroskopi, som algoritmen er spesielt utviklet for, kan dette scenarioet inntreffe. I vårt anvendelsesområde vil imidlertid forgrunnsobjektene alltid være adskilt av bakgrunnsobjekter. En må derfor gjøre visse modifikasjoner for å ta hensyn til denne forutsetningen. Disse modifikasjonene kan enten gjøres direkte i algoritmen, som et postprosesseringssteg, eller i egenskapsuttrekningen. Siden en på dette punktet i rutinen har relativt små datamengder har en av hensyn til oversiktighet og modularitet valgt å benytte et eget postprosesseringssteg for dette. En har her valgt å benytte seg av en filtreringsmetode som har store likhetstrekk med binær morfologi. I dette tilfellet er imidlertid inndata objekter med unike merker istedenfor et binært bilde. Hvis en antar at inndata er gitt som en en-dimensjonal array tilsvarende den projiserte årringsprofilen der bakgrunns pikslene er lik 0, og alle forgrunns pikslene som tilhører forgrunnsobjekt nummer  $k$ , der  $k = 1, 2, \dots, K$ , er merket med det objektnummeret de tilhører. En ønsker da i de tilfellene der to forgrunns piksler med ulikt merke ligger inntil hverandre å erstatte den ene pikselverdien med en 0. Dette bør videre være det pikselet som har lavest intensitet i gråtoneprofilen.


Figur 6.16 på neste side illustrerer noen egenskaper ved algoritmen, mens figur 6.17 på side 83 viser noen resultater av å benytte algoritmen på den projiserte årringsprofilen.

Som en ser av figur 6.17 på neste side gir metoden fornuftige resultater. Den klarer imidlertid ikke å registrere de laveste årringsprofilene i dette tilfellet ettersom disse ligger under den satte terskelen for bakgrunnsstøy.


## 6.7 FFT-basert segmentering

Etter relaksasjon vil de bredere sommerved-objektene bli kraftig forsterket og i de fleste tilfeller tilnærmet nå metningsverdi for  $p^{(j)}(k, s)$ , altså en sannsynlighet lik 1. De smalere objektene vil imidlertid i mange tilfeller ha en relativt lav sannsynlighetsovervekt etter det satte maksimale antall iterasjoner. Hvis disse i tillegg har en viss vinkel i forhold til vertikalen vil responsen bli ytterligere dempet under projeksjon til én dimensjon, ettersom de da midles med bakgrunnen. Det kan derfor være ønskelig med en lavere terskel i regioner med smale årringer enn i regioner der årringene er bredere. En ønsker derfor å se på om en kan benytte et lokalt frekvensestimat for å regulere terskelen i det projiserte bildet. En benytter da diskret fourier transform (DFT) for å finne dette estimatet. DFT er nærmere beskrevet i kapittel 7.2.1 på side 94.

En har valgt å bruke middelverdien av magnituden til den lokale DFT transformen



Figur 6.16: *Dual watershed tersklingsmetode med  $\Delta T = 23$  og  $T_{BG} = 50$  (stiplet). Figuren viser et midlertidig resultat til venstre og resultatet etter ferdig tersklings og adskillelse av sammenkoblede forgrunnsobjekter til høyre. Merk på figuren til venstre at helt til venstre i denne er det to profiler adskilt av en dal som marginalt overstiger  $\Delta T$ , og de blir derfor tolket som separate objekter, mens forgrunnsobjekt nummer 5 fra høyre består av to profiler som er marginalt lavere enn  $\Delta T$ , og blir slått sammen til ett objekt. Merk også at de to forgrunnsobjektene helt til venstre ikke er adskilt av en bakgrunnsregion i figuren til venstre, men at dette er korrigert i figuren til høyre.*




Figur 6.17: Resultater med 5 iterasjoner relaksasjon som bildeforbedringssteg og dual watershed tersklingsmetode med  $\Delta T = 20$  og  $T_{BG} = 60$ . Prøve 4.

som basismål for terskelen (DC-komponenten er ignorert i beregningen). Dette basismålet betegnes  $m_{ft}$ . Terskelen er da gitt ved

$$T(i) = o + k \cdot \frac{1}{m_{ft}} \quad (6.9)$$

der  $o$  og  $k$  er justeringsparametre.

Noen resultater oppnådd med metoden er vist i figure 6.18 på neste side.



Figur 6.18: Resultater med 5 iterasjoner relaksasjon som bildeforbedringssteg og FFT-basert tersklingsmetode. En har her benyttet en vindusbredde på 25 samt justeringsparametre  $\alpha = -0.4$  og  $k = 0.25$ . Prøve 4.

## 6.8 Diskusjon av tersklingsmetoder

Når en sammenligner disse ulike metodene ser en at en global terskling ikke er tilpascningsdyktig nok til å håndtere variasjonene amplituden til responsene i projeksjonen. De adaptive variantene fungerer bedre, men et generelt problem ved vindusbaserte adaptive tersklingsmetoder er at de kan skape feil der hvor vinduet ikke inneholder piksler fra begge fordelingene. Bernsens metode prøver å kompensere for dette ved hjelp av et fast og globalt kriterium for hvilke vinduer man skal og ikke skal benytte standard adaptiv terskling. Problemet med denne fremgangsmåten er å finne et egnet kriterium. Kontrastfunksjonen som Bernsen benyttet vil som vi har sett føre til at visse svakere årringsprofiler ikke blir detektert.

En ser at probabilistisk relaksasjon som bildeforbedringssteg på de todimensjonale bildene gir en markant forbedring av resultatene for alle de endimensjonale segmenteringsmetodene ved å øke signal/støy-responsen i projeksjonene, slik at de globale kriteriene slik som  $C_{min}$  i Bernsens metode og  $T_{BG}$  i Wählbys dual watershed segmentering kan settes høyere. Den fourierbaserte tersklingsmetoden er i stor grad tilpasset spesielle anvendelser siden den forutsetter at høyfrekvente mønstre har lavere respons enn lavfrekvente. Selv om dette hovedsakelig er regelen i vår applikasjon finnes det også her som en ser av figur 6.18 på forrige side regioner med relativt lavfrekvente årringsmønstre som også har svært lav kontrast der denne metoden ikke vil fungere spesielt bra.

Basert på en totalvurdering av segmenteringsmetodene på den endimensjonale projeksjonen for et større bildemateriale fant en at Wählby og Bernsen fungerte best. Når bildene var preprosessert med probabilistisk relaksasjon så imidlertid Wählbys metode ut til å være noe bedre.

Et alternativ til å benytte segmentering i vår- og sommerved regioner, er i vårt tilfelle å kun beskrive overflaten med et eller flere globale egenskapsmål. Det er nevnt mer om dette i kapittel 7 på side 88.

Ved justering av parametere og valg av ulike metoder i preprosesseringsstegene, har en i stor grad gjort en visuell vurdering av resultatbildet fra de ulike prosesseringsstegene. Denne vurderingen ble gjort utfra hvilke metoder/parametere som ga en tilsynelatende økning i kontrasten mellom vår- og sommervedregionene og samtidig undertrykte støyobjekter slik som opprevete fibre, skitt etc. – altså økte signal/støyforholdet i bildet. Det er imidlertid ikke sikkert at de samme parametere er optimale med hensyn på den videre prosesseringen og senere egenskapsuttrekningen/klassifikasjonen i oppgaven. I en artikkel av Due Trier [63] beskrives det et formelt rammeverk for en målstyrt (“goal directed”) evalueringsmetode, der resultatet fra analyseringsmodulen gir et kvantitativt mål på



hvor gode parametrene/algoritmekandidatene er. Problemet med å benytte denne metoden er at en får et svært stort utfallsrom ettersom antall forprosesseringssteg øker, spesielt dersom flere av disse stegene også har et antall parametere som kan justeres – hvilket i stor grad er tilfelle i denne oppgaven.

# Kapittel 7

## Egenskapsuttrekning

I forrige kapittel så vi på hvordan vi ved hjelp av ulike metoder for preprosessering av bildene kunne fremheve årringsmønstrene og deretter segmentere disse slik at vi endte opp med et binært bilde (eventuelt en vektor) der elementverdiene 0 og 1 representerte vår- og sommervedregioner. I dette kapitlet ønsker vi å se på hvordan vi kan ekstrahere en eller flere skalare egenskaper fra bildene/vektorene som enten alene eller i kombinasjon er egnet til å diskriminere mellom marg- og yteside.

### 7.1 Årringstelling og midlere årringsbredder

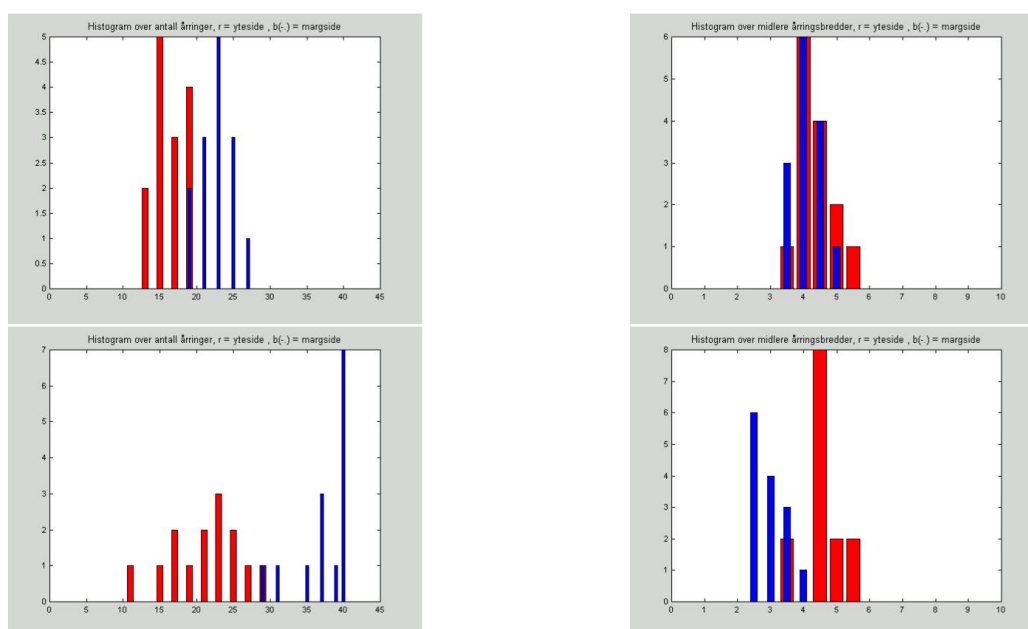
Som en diskuterte innledningsvis i kapittel 2 på side 6 vil *antall årringer* være en egnet diskriminant for å skille marg- og yteside, dersom en på en robust måte kan detektere disse. Dersom en runlength-enkoder den binære vektoren en fant i kapittel 5 på side 29 vil antallet årringer være gitt av antall elementer i den runlength-enkodede vektoren dividert med 2.

Et annet mulig egnet egenskapsmål en nevnte i kapittel 2 på side 6 var *bredden* til årringene.

Figur 7.1 på neste side og 7.2 på side 90 inneholder histogrammer som viser spredninger og overlapp for antall årringer og midlere sommervedbredder målt på samme lamell, men der regionene målingene ble gjort i er forskjøvet vertikalt nedover den ene kanten av lamellbildene (med overlapp) for å produsere flere målepunkter. Dersom en har en perfekt deteksjon av årringene forventer en da at histogrammene for marg- og ytesiden skal være smale, ettersom reelt antall årringer og reell gjennomsnittlig sommervedbredde bør variere lite over de ca. 8 cm som bildet dekker av lamellen i lengderetning. Spredningen på histogrammene


vil således være en indikasjon på hvor pålitelig algoritmen er, og hvor robust den er mot støy. Videre vil avstanden mellom histogrammene for yte- og margside og graden av overlapp fortelle noe om marginene for metoden, og risikoen for feilklassifikasjon.

Figur 7.1 ble generert basert på 200x150 pikslers regioner og følgende algoritmer fra kapittel 5 på side 29: rotasjon, adaptiv LoG-filtrering, linjeproeksjon og en-dimensjonal lokal adaptiv terskling basert på middelverdi og vektet standardavvik. Figur 7.2 på neste side ble generert på samme måte med unntak av at en her etter den adaptive LoG-filtreringen isteden benytter 5 iterasjoner probabilistisk relaksasjon, linjeproeksjon og en-dimensjonal fast terskel med  $T = 102$  og runlength.



Figur 7.1: Resultathistogrammer for prøve 2 (øverst) og prøve 4. Skalaen langs første-aksen på plottene er her til lengden på den runlength-enkodede vektoren, altså antall vårved + antall sommerved regioner, og midlere bredde av sommervedregionene.

Utfra figurene ser en at sommervedbredde er et lite egnet egenskapsmål for metoden som ikke benytter probabilistisk relaksasjon. For prøve nr 2 er her histogrammene 100% overlappende og nesten identiske. Ved bruk av relaksasjon som bildeforbedringssteg ser det imidlertid vesentlig bedre ut. Selv om en fortsatt har litt overlapp er tyngepunktene godt separerte, og spredningen er også forbedret begge prøvene sett under ett. Når det gjelder antall åringer har en her bedre separasjon for begge



Figur 7.2: Resultathistogrammer etter å ha benyttet 5 iterasjoner relaksasjon som bildeforbedringssteg og fast terskel  $T = 102$  på prøve 2 og 4. Skalaen langs første-aksen på plottene er her til lengden på den runlength-enkodede vektoren, altså antall vårved + antall sommerved regioner, og midlere bredde av sommervedregionene.

metodene. For metoden med probabilistisk relaksasjon har en her ingen overlapp i histogrammene, selv om en fortsatt har noe spredning.


Disse plottene gir også en indikasjon på hva man kan forvente ved å ta et større antall bilder langs hele lamellens lengde, og deretter kombinere resultatene fra disse. Som en ser av histogrammene kan en ved å analysere kun innen et enkelt regionpar få svært små marginer i egenskapsmålene, og kunne risikere å bli feilklassifisert, men dersom en isteden bruker eksempelvis middelverdien av flere målinger vil en øke marginene betraktelig og få en sikrere klassifikasjon.

Figur 7.3 på neste side viser resultat av årringstelling og måling av midlere sommervedbredde på et bilde preprocessert med noen av metodene beskrevet i kapittel 5 på side 29. En har her initielt benyttet metoden for automatisk lokalisering av “beste” region fra kapittel 5.1 på side 29. Bildet ble først delt opp i 10 subregioner av størrelse 500x300 piksler lokalisert på venstre og høyre side av lamelloverflaten og med 50% overlapp i vertikal retning. I tillegg til den regionen som metoden estimerte som “best” inkluderte en også alle regioner, med samme horisontal offset, som hadde et signal/støy-forhold,  $S/N > S/N_{opt} - 0.3$ . Dette for å få et større beslutningsgrunnlag. Målingene fra de ulike regionene ble kombinert ved hjelp av median til slutt. En benyttet videre i denne testen følgende algoritmer fra kapittel 5 på side 29: rotasjon, adaptiv LoG-filtrering, 5 iterasjoner probabilistisk relaksasjon, linjeproeksjon og en-dimensjonal dual watershed segmentering med  $\Delta T = 20$  og  $T_{BG} = 125$ .

I et differanse-søyleplott av typen vist i figur 7.3 på neste side ønsker en først og fremst at flest mulig av de fremre, blå søylene skal ha likt fortegn, siden dette betyr at det gitte egenskapsmålet har mest mulig konsekvent høyest verdi for en av sidene (om dette flertallet av søylene peker i positiv eller negativ retning er i prinsippet likegyldig, selv om en gjerne for et gitt egenskapsmål forventer en overvekt av enten positive eller negative verdier i forkant).

Som en ser av figur 7.3 på neste side gir antall årringer korrekt klassifikasjon for alle prøvene med unntak av to, hvorav det for den ene (prøve nr 11) rapporteres “lik avstand”. For denne prøven ser en også av de røde søylene at den faktiske differansen i avstand til marg er relativt liten. En observerer videre at for de 4 prøvene hvor en har lavest faktisk differanse i avstand til marg får en også liten differanse i antall årringer. Utover dette finner en imidlertid liten sammenheng mellom faktisk avstand og antall årringer. Når det gjelder den andre feilklassifiserte prøven (nr. 15) ser en her at den faktiske avstanden til marg er stor. Ser man på originalbildet for denne prøven (jmf. A på side 161), ser en imidlertid at flatene er svært støyfylte, og det er vanskelig å vurdere hvilken side som er yte og marg også visuelt basert på dette bildeutsnittet.

Når det gjelder midlere sommervedbredde ser en at denne gir betydelig dårligere



Figur 7.3: Søypleplott som viser resultat for målt antall årringer (antall vår- og sommervedregioner summert), samt midlere årringsbredde for sommervedregioner. De blå søylene i front viser normalisert differanse mellom egenskaper for yte og marg, mens de røde bakenforliggende søylene viser normalisert differanse for manuelt målt avstand i endeveden på lamellene (I noen av tilfellene ligger ikke margen innenfor den delen av stokken lamellen er skåret ut fra, slik at man ikke kan måle avstanden manuelt. Disse tilfellene er satt til en maksimumsverdi på 5 mm høyere enn maksimalt målte avstand, og vil få verdien 1 i det normaliserte plottet, mens de høyeste reelt målte avstandene vil ha en verdi i underkant av 0.9).

klassifikasjonsresultater. Noe overraskende ser en også at en har en overvekt av søyler med negativt fortegn i et *yte – marg* plott! Ved en vurdering av bildematerialet i etterkant ser en imidlertid at sommervedbredden kan være svært smal både på yte og margside for et større antall av prøvene med den oppløsningen og graden av opprevde fibre som helt eller delvis maskerer sommervedregionene en har. Den forskjellen som måtte finnes er antagelig svært vanskelig å måle konsekvent under disse forutsetningene. En annen faktor er at en i denne testen unnlot å analysere de midtre ca. 10% av lamellen. Det er ofte i dette området en enklest kan se forskjell i sommervedbredde visuelt. Her får imidlertid årringsmønstrene typisk en så stor og varierende vinkeldifferanse fra vertikalen, og ulineær form at mange av de forutsetningene en tok i kapittel 5 på side 29 ikke er gyldige. I tillegg er det oftest også i dette området en finner margen, hvilket vil føre til en falsk – og bred – årringsdeteksjon når denne ikke tas hensyn til spesielt. Metodene vil derfor ikke være egnet i dette området. Midlere sommervedbredde er altså ikke et spesielt godt egnet egenskapsmål i vårt tilfelle.

## 7.2 Periodiske egenskaper

### 7.2.1 Diskret Fourier transform

En mye benyttet metode for å ekstrahere periodiske egenskaper innen bildeanalyse er den Diskrete Fourier Transformen (DFT). Likningen for den to-dimensjonale fremlengse transformen, det vil si den som transformerer bildedataene fra det romlige  $xy$ -domenet til frekvensdomenet, er gitt ved

$$F(u, v) = \frac{1}{N} \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) e^{-\frac{2\pi i}{N}(xu-yv)} \quad (7.1)$$

der  $i = \sqrt{-1}$ .

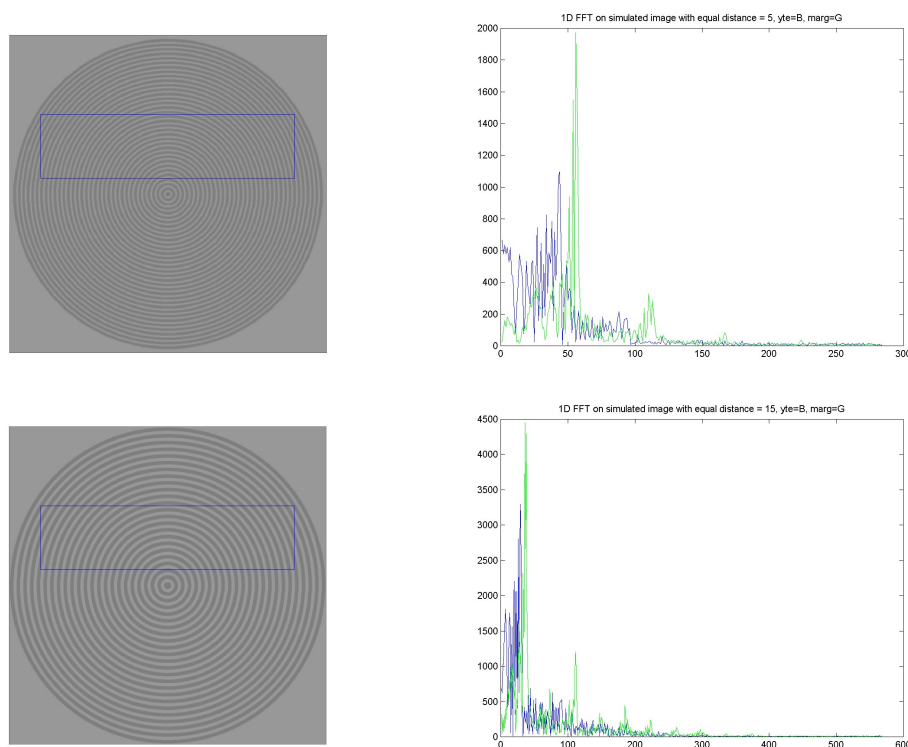
DFT kan ha mange anvendelser innen bildeanalyse. Filtreringer som utføres ved hjelp av konvolusjon i  $xy$ -domenet kan blant annet for store filtermasker utføres mer effektivt (d.v.s. med mindre prosesseringskraft) ved å transformere bildet til Fourier-domenet, utføre filtreringen der, og transformere tilbake (dette forutsetter bruk av Fast Fourier Transform, FFT, algoritmen). I vår applikasjon kan det imidlertid være interessant å se om det finnes signifikante forskjeller i fourierspektrene til ytesiden og margsiden av limtre-lamellene. Utfra apriori-antagelsen om at margsiden av limtre-lamellene har flere årringer enn yteside, kan en enkelt resonnerer seg fram til at den midlere perioden til årringene på margsiden også må være kortere, hvilket vil kunne observeres som større energinivåer ved høyere frekvenser i fourier-domenet.



## 7.2.2 DFT for simulerte årringsmønstre

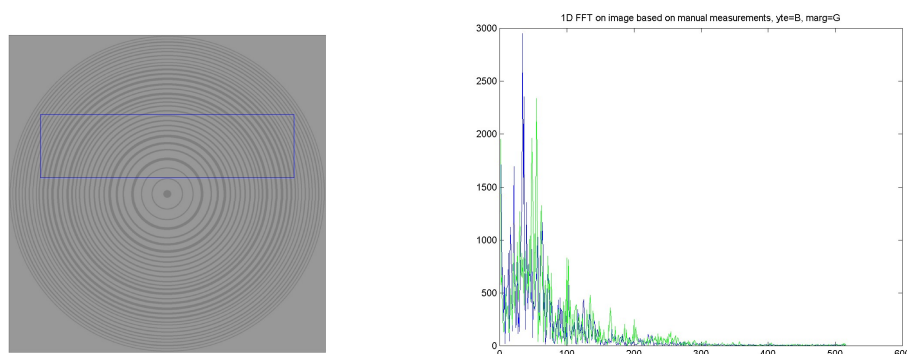
For å bedre kunne vurdere i hvilke deler av fourierspekteret en vil kunne finne størst differanse mellom marg- og yteside, samt hva slags metoder en kan benytte for å ekstrahere de mest karakteristiske egenskapene, ønsket en å se hvordan fouriertransformen ser ut for yte- og margsiden på en “ideell” limtre lamell – det vil si en med flater som kun inneholder årringsmønstre, og er fri for støy.

Dette ble gjort ved å generere kunstige tverrsnittbilder av stokker med ulike årringsmønstre, og simulere utskjæringer av lameller i ulike posisjoner på disse. Figur 7.4 viser eksempler på dette med uniform årringsavstand over hele stokksnittet. Bildene av stokktverrsnittet er glattet (gauss med  $\sigma = 1.0$ ) og gitt en relativt lav kontrast for å få mest mulig realistiske resultater.



Figur 7.4: Endimensjonal fouriertransform for simulerte årringsmønstre. Simulerte utskjæringer fra stokk er vist til venstre, og den korresponderende DFT for yte- (blå linje) og margside (grønn linje) er vist til høyre. I det øverste figurparet har en simulert en konstant årringsavstand på 5 piksler (vårvedbredde=sommervedbredde), mens den nederste har en konstant årringsavstand på 15 piksler.

Lik årringsavstand over hele stokksnittet, og lik bredde for vår- og sommervedregioner, er en grov forenkling av virkeligheten, men forenklingen er hensiktsmessig for å få en bedre forståelse av hvordan endringer i årringsavstander påvirker fourierresponsen. Som en ser av figur 7.4 på forrige side blir DFT relativt kompleks selv for disse enkle bildene. For å få en mer realistisk, men støyfri, respons genererte man imidlertid et årringsbilde basert på manuelle målinger av årringsavstander i endeveden på prøve nr 27. DFT for en simulert lamellutskjæring av denne er vist i figur 7.5.



Figur 7.5: Endimensjonal fouriertransform for simulerte årringsmønstre basert på manuell måling av prøve nr. 27. Simulerte utskjæringer fra stokk er vist til venstre, og den korresponderende DFT for yte (blå linje) og marg (grønn linje) er vist til høyre.


Selv om DFT for figur 7.4 på forrige side og 7.5 blir relativt kompleks selv for disse enkle bildene, ser en – som en også hadde forventet – at yten har mer energi (og topper) for lavere frekvenser enn margside. Det meste av informasjonen for støyfrie bilder ligger dessuten i de lavere frekvensene og frekvensen til maksimum for samme side kan variere ganske mye med variasjoner i årringsavstand.

### 7.2.3 Initielle tester med 2D DFT

For å få en oversikt over hvordan den todimensjonale Fourier-transformen vil se ut for virkelige bilder som også inneholder støy, ble det gjort noen initielle forsøk på et utvalg av lamellbildene. Den påfølgende delen av undersøkelsen er gjort på ubehandlede originalbilder. Dette for å finne ut om det er mulig å se noen forskjell på marg- og yteside via DFT *uten* noen form for preprosessering.

Figur 7.6 på neste side viser Fourier-spektrene for et bildeutsnitt av marg- og ytesiden for to ulike limtre-lameller.

De initielle testene på to av prøvene vist i figur 7.6 på neste side virker oppløftende med hensyn på egenskapsuttrekning fra Fourier-rommet. En ser her at for disse har margsidene et betydelig bredere frekvensspekter enn de korresponderende ytene, slik vi antok i forrige avsnitt over. En har imidlertid også i bildene en del støy, som vil kunne ha et stort spenn av frekvenser innen hvert enkelt bilde, og i tillegg være variabel fra lamell til lamell. Spørsmålet er da om forskjellene i spektrene mellom marg og yte er signifikant nok til å kunne detekteres pålitelig, eller om de “drukker” i all støyen.




Figur 7.6: Amplituden til 2D DFT for yte (t.v.) og marg for prøve 2 (øverst) og prøve 4. Bildene er rotert 45 grader før transformasjon for å unngå at kunstige frekvenser introdusert på grunn av diskontinuitet i kantene skal sammenfalle med tverretningen av årringene (Denne metoden ble valgt for enkelhets skyld. Andre måter å unngå problemet med diskontinuitet i kantene på ville vært å benytte en vindusfunksjon, eller å midle over de motstående ytre kantene av bildet).

## 7.2.4 Uttrekning av egenskaper fra DFT

### Geometriske vinduer i fourierplanet

For å unngå en sammenblanding av ulike frekvenser og retninger i fourierplanet er det ofte hensiktsmessig å betrakte spekteret i polare koordinater,  $S(r, \theta)$ .



Figur 7.7: Radiale projeksjonsplot av amplituden til DFT for yte (t.v.) og marg for prøve 6. Vinkelprojeksjonen ( $\theta$ -aksen) er gjort over et intervall på henholdsvis 30, 10 og 3 grader (ovenfra og ned).

En kan da finne polare egenskapsmål for DFT ved å ekstrahere skalare verdier som

sum, middelværdi, maksimumsverdi, maksimumsposisjon, varians etc. over en avgrenset sektor (i både vinkel og frekvens) i fourierplanet. Den skalare summen vil eksempelvis være gitt ved

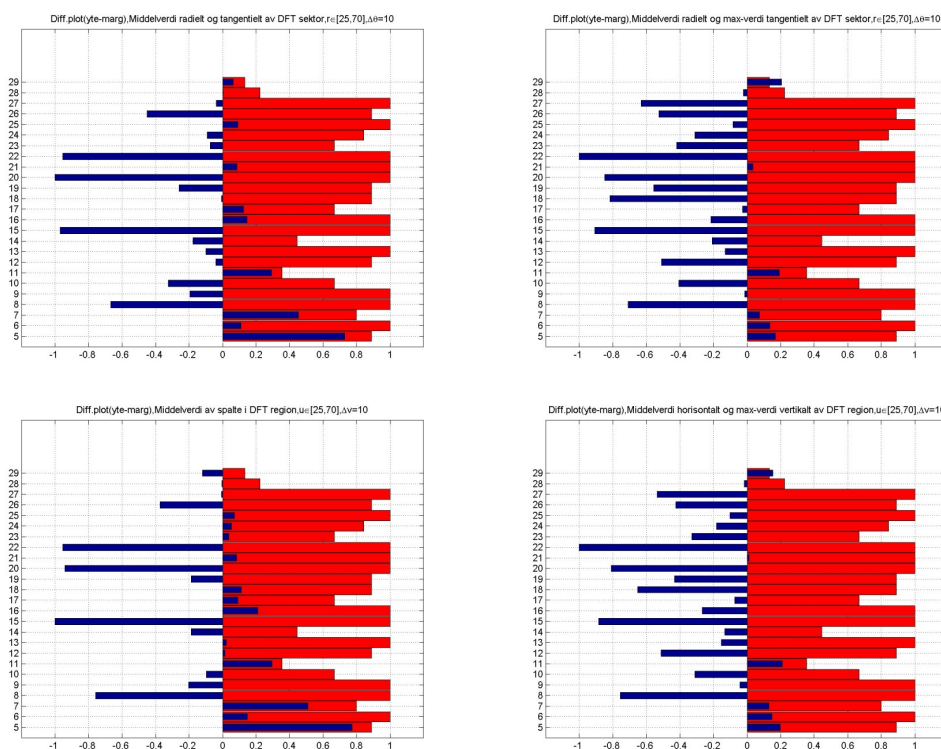
$$S_{\Sigma} = \sum_{r=r_1}^{r_2} \sum_{\theta=\theta_1}^{\theta_2} F(r, \theta) \quad (7.2)$$

der  $\theta = \arctan(u/v)$  og  $r = \sqrt{u^2 + v^2}$ .

Figur 7.7 på forrige side viser en polar sektor transformert til kartesiske koordinater for ulike  $\theta_1$  og  $\theta_2$  sentrert om  $\theta = 15$  grader som er lik vinkelen i det roterte (jmf. figur 7.6 på side 98 der  $\theta = 45$  grader) og deretter DFT transformerte bildet, samt projeksjoner ned på  $r$ - og  $\theta$ -aksen. På projeksjonen ned på  $\theta$ -aksen ser vi en distinkt topp innenfor ihvertfall de to bredeste vinkelintervallene, som tilsvarer tverretningen på årringsmønsteret. En ser også en mindre differanse i maksimumsvinkel,  $\theta_{max}$  for denne prøven, men differansen er svært liten i tillegg til at maksimaene er støyfylte med flere topper, noe som vil gjøre det vanskeligere å finne disse eksakt. Når en betrakter projeksjonen ned på  $r$ -aksen ser en at margsidene har et mindre maksimum rundt  $r = 25$ , noe som kan skyldes den høyere årringsfrekvensen på margsidene. For yten er dette maksimumet mindre tydelig, men en kan se en antydning rundt  $r = 10$ . Denne forskjellen indikerer altså at det kan være hensiktsmessig å se på om en differanse i middelværdi innenfor dette området kan være et egnet egenskapsmål. Når en sammenligner med de simulerte DFT-plottene i seksjon 7.2.2 på side 95 for en annen prøve ser en imidlertid at denne har sin "topp" for margsidene ved vesentlig høyere frekvenser, samt at hovedtyngden i koeffisientene for yten også forskyves en del mot høyere frekvenser (dette kan en også til en viss grad også se i fourierresponsen til den virkelige prøven). Man ønsker altså å se om det finnes et område,  $[r_1, r_2]$ , med en signifikant differanse i midlere respons som er gyldig for hele datasettet.

Figur 7.8 på neste side viser resultater for noen egenskapsmål fra faste DFT regioner.

Som en ser av differanseplottet gir bruk av middelværdi langs begge akser svært dårlige resultater i både det polare og kartesiske tilfellet. Når en imidlertid benytter maksimumsverdien over vinkelaksen (og den vertikale aksene ved bruk av spalter) før en finner middelværdien radielt blir imidlertid resultatene vesentlig bedre, selv om feilklassifiseringsraten fremdeles er for høy. Vi får da i begge tilfeller seks feilklassifiserte prøver, hvilket gir en feilklassifiseringsrate på ca. 24%. En ser at prøve 29, hvilket er den prøven som har minst avstand mellom yte og marg vil bli feilklassifisert i begge tilfellene, men ellers ser det ut til å være lite sammenheng mellom avstand til marg og risiko for feilklassifisering. En ser også at i



Figur 7.8: Søypleplott som viser resultat for noen egenskapsmål fra faste DFT regioner. De blå i front viser normalisert differanse mellom egenskaper for yte og marg, mens de røde bakenforliggende søylene viser normalisert differanse for manuelt målt avstand i endeveden på lamellene. Figurene øverst er basert på sektorer i polare koordinater, mens de nederste er basert på spalter i kartesiske koordinater. For resultatene i figurene t.v. har en benyttet middelverdi langs begge akser, mens for resultatene t.h. har en benyttet middelverdi langs  $r$ - henholdsvis  $u$ -aksen, mens en har benyttet maksimumsverdi for  $\theta$ - henholdsvis  $v$ -aksen.

vår anvendelse er dette egenskapsmålet relativt uavhengig av om en partisjonerer fourierdomenet i sektorer eller spalter.

### Maksimumsfrekvens som egenskapsmål


Med utgangspunkt i analysen gjort i 7.2.2 på side 95 ønsket man å se på om lokalisering av maksimumspunktet i en glattet DFT-respons kan være et egnet egenskapsmål. Denne egenskapen ble testet på de simulerte bildene, og det virket robust selv om en flyttet på “lamellen” i det simulerte stokktverrsnittet, samt endret størrelse på denne (med unntak av når marg og yte har svært kort avstand eller det er svært liten forskjell i avstand til marg).

Absolutt maksimum i den glattede projeksjonen er gitt av

$$r_{max} = \underset{r}{\operatorname{argmax}} \left[ \left( \frac{1}{N} \sum_{\theta=\theta_1}^{\theta_2} F(r, \theta) \right) \otimes h(r) \right] \quad (7.3)$$

der  $h(r)$  er en endimensjonal glattefunksjon og  $F(r, \theta)$  er en polar sektor i fourierdomenet transformert til kartesiske koordinater i en  $M \times N$  stor rektangulær region som vist i figur 7.7 på side 99.

Figur viser resultatet ved bruk av denne metoden. En benyttet her en gaussisk glattefunksjon med vindusstørrelse 17 i  $h(r)$ , samt  $\theta_1 = 10$  og  $\theta_2 = 20$ .



Figur 7.9: Søypleplott som viser resultat ved bruk av absolutt maksimumsfrekvens i glattet projisert DFT respons.

Som en ser av figuren gir denne metoden dårlige resultater for virkelige bilder med hele 9 feilklassifiserte prøver. Årsaken til dette er antagelig at maksimumet som representerer de dominerende årringsfrekvensene her “drukner” i frekvensresponsene fra støyobjektene.



**Spredningsmål på 2D Fourier transform**

Faugeras og Pratt [45] har foreslått følgende spredningsmål anvendt på autokorrelasjonsfunksjonen

$$S(u, v) = \sum_{m=0}^T \sum_{n=-T}^T (m - \eta_m)^u (n - \eta_n)^v A_F(m, n) \quad (7.4)$$

der

$$\eta_m = \sum_{m=0}^T \sum_{n=-T}^T m A_F(m, n) \quad (7.5)$$

$$\eta_n = \sum_{m=0}^T \sum_{n=-T}^T n A_F(m, n) \quad (7.6)$$

og autokorrelasjonsfunksjonen er gitt ved

$$A_F(m, n) = \sum_j \sum_k f(j, k) f(j - m, k - n) \quad (7.7)$$

Vi ønsket å utforske om disse spredningsmålene kunne anvendes for å trekke ut egenskaper fra Fourier transformen – istedenfor autokorrelasjonsfunksjonen – som er egnet til å diskriminere mellom yte og marg. Ved å substituere  $F(m, n)$  for  $A_F(m, n)$  i likning 7.4, 7.5 og 7.6 får vi da:

$$S(u, v) = \sum_{m=0}^T \sum_{n=-T}^T (m - \eta_m)^u (n - \eta_n)^v F(m, n) \quad (7.8)$$

der

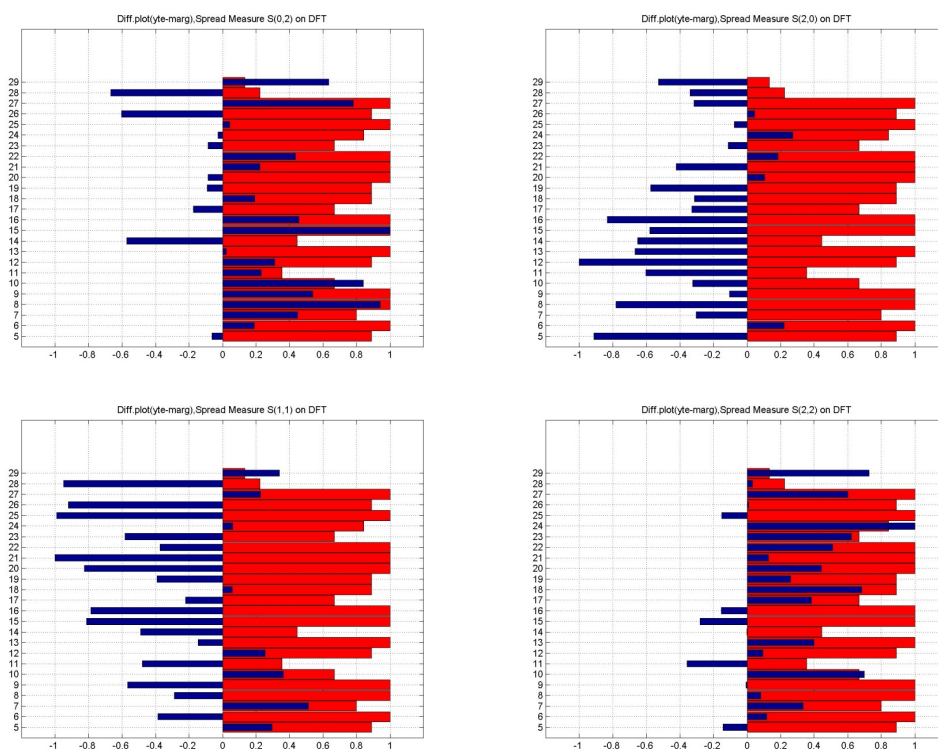
$$\eta_m = \sum_{m=0}^T \sum_{n=-T}^T m F(m, n) \quad (7.9)$$

$$\eta_n = \sum_{m=0}^T \sum_{n=-T}^T n F(m, n) \quad (7.10)$$

Siden Fouriertransformen, i likhet med autokorrelasjonsfunksjonen, er symmetrisk er det også i 7.8 på forrige side tilstrekkelig å kun beregne spredningen over halve Fourierdomenet.

Spredningsmålene  $S(u, v)$  representerer her sentralmomenter i Fourierspekteret av høyere orden for økende  $u$  og  $v$ .  $S(0, 0)$  er her summen av fourierkoeffisientene i bildet, mens  $S(1, 0)$  og  $S(0, 1)$  er henholdsvis første ordens horisontalt og vertikalt moment.

Egenskapene som ble testet med denne metoden var de projiserte profil spredningene  $S(0, 2)$  og  $S(2, 0)$ , samt kryssrelasjonen  $S(1, 1)$  og andre grads spredningen  $S(2, 2)$ . Resultatene er vist i figur 7.10.



Figur 7.10: Søyplelott som viser resultat ved bruk av noen utvalgte spredningsmål på DFT. De blå søylene i front viser normalisert differanse mellom egenskaper for yte og marg, mens de røde bakenforliggende søylene viser normalisert differanse for manuelt målt avstand i endeveden på lamellene.

Som en ser av søyleplottet er det  $S(2, 0)$  som gir det beste resultatet av disse med 5 feilklassifiserte lameller, hvilket gir en feilklassifiseringsrate på ca. 17%. I tillegg til en lav feilklassifiseringsrate er det ønskelig med en større grad av samsvar i

amplitude mellom de målte verdiene og den faktiske avstanden til marg. Selv om hovedformålet med oppgaven strengt tatt kun er å diskriminere mellom marg- og yteside på lamellene, vil et samsvar med faktisk avstand indikere at algoritmen har en bedre robusthet. En kan imidlertid ikke se noen signifikant sammenheng av denne typen i figur 7.10 på forrige side.

En kan også trekke ut en rekke andre egenskaper fra  $S(u, v)$  for å beskrive formen til  $F(m, n)$ . Det kunne for eksempel vært interessant å se på objekt ellipsen til fourierspekteret. Dette er definert som ellipsen med største og minste inertialmoment som er like de til objektet. Ellipsens senterpunkt er gitt av likning 7.9 på side 103 og 7.10 på side 103, mens dens orientasjon er gitt av

$$\hat{\Theta} = \frac{1}{2} \tan^{-1} \left[ \frac{2S(1, 1)}{S(2, 0) - S(0, 2)} \right] \quad (7.11)$$

De antagelig mest interessante parametrene til objekt ellipsen å benytte som egenskap er imidlertid lengdene til halvaksene. Disse er gitt ved

$$(\alpha, \beta) = \left( \frac{2[S(2, 0) + S(0, 2) \pm \sqrt{(S(2, 0) - S(0, 2))^2 + 4S(1, 1)^2}]}{S(0, 0)} \right)^{1/2} \quad (7.12)$$

Disse kan videre benyttes til å beregne eksentrisiteten som også bør kunne være en egnet egenskap. For en ellipse er denne gitt ved

$$\epsilon = \sqrt{1 - \frac{\alpha^2}{\beta^2}} \quad (7.13)$$


Likning 7.11 og 7.12 er hentet fra [46] som også lanserte en rask og eksakt metode for å beregne disse geometriske momentene basert på Greens teorem.

Disse egenskapene bør da relativt enkelt kunne fange opp forskjellene i frekvensspekteret mellom yte- og margside dersom de er så åpenbare som vist i figur 7.6 på side 98. Ved eksaminasjon av 2D DFT for en større del av bildematerialet ser en imidlertid at det er flere eksempler der regelen om kraftigere respons for høyere frekvenser på margsiden ikke er gjeldende. Årsaken til dette er antagelig at støyobjektens respons i for stor grad dominerer responsen fra årringene. Dette kombinert med de nedslående initielle resultatene førte til at en ikke prioriterte å gå videre med denne tilnæringsmetoden.

## 7.2.5 DFT på preprosessert 1D projeksjon

Som en nevnte tidligere kan støyen i bildene inneholde et relativt stort spenn av frekvenskomponenter. Det kan derfor være hensiktsmessig å preprosessere bildene for å undertrykke mest mulig av denne støyen, og samtidig fremheve de ønskede årringssignalene. Ulike metoder for preprosessering av bildene ble diskutert i kapittel 5 på side 29. En ønsker altså her å utføre en DFT på den preprosesserte projeksjonen istedenfor en terskling som ble skissert i kapittel 6 på side 57. Årringstillingen og målingen av årringsbredder erstattes da med å trekke ut egenskaper fra fourier-domenet.


Bildene er her altså preprosessert med følgende algoritmer fra 5 på side 29: rotasjon, adaptiv LoG-filtrering, linjeproeksjon og probabilistisk relaksasjon, før en har benyttet endimensjonal DFT og endimensjonale versjoner av spredningsmålene diskutert i seksjon 7.2.4 på side 103. Uttrykkene for de endimensjonale spredningsmålene blir helt analoge likningene for den todimensjonale versjonen gitt i likning 7.8 på side 103, 7.9 på side 103 og 7.10 på side 103. Figur 7.11 viser et eksempel på en profil fra en projeksjon på et originalbilde sammenlignet med en preprosessert projeksjon hvilket brukes som input til denne metoden.



Figur 7.11: *Projeksjoner av originalbilde t.v. og samme region i preprosessert bilde t.h. Utsnitt fra prøve nr. 4.*

Figur 7.12 på neste side viser et differanseplott av  $S(1)$  mot  $S(2)$  i dette tilfellet.


Som en ser av figuren gir hverken  $S(1)$  eller  $S(2)$  egenskapene et godt klassifikasjonsresultat separat siden disse er spredd på begge sider av origo i yte-marg plottet, selv om  $S(2)$  er noe bedre. Videre ser en at egenskapene i stor grad er korrelerte, slik at en eventuell klassifikasjon basert på begge egenskapene heller ikke vil gi noen betydelig forbedring. Prøve nummer 5, 9 og 25 er de som avviker mest for disse egenskapene, men totalt har en 10 prøver som har minst en region lavere enn 0 for begge egenskapene, og således ville blitt feilklassifisert.



Figur 7.12: DFT på preprosessert 1D projeksjon. Plott av 1. moment vs. 2. moment for 25 forskjellige lamellprøver. Tallene indikerer prøvenummer, mens bokstavene, der de er tilstede indikerer at algoritmen for lokalisering av "beste region" har funnet mer enn en region som passerer kriteriene.

### 7.3 Høyere ordens statistikk

Et problem med 1. ordens statistikk (jmf. bl.a. 4.2.1 på side 22) er at denne ikke sier noe om geometrien eller konteksten i bildet. To bilder med svært forskjellig tekstur kan derfor ha helt identiske histogrammer slik det er illustrert i figur 7.13. En måte å løse dette på er å benytte seg av høyere ordens statistikk.



Figur 7.13: *Illustrasjon som viser et eksempel på at 1. ordens histogrammer kan være helt identiske for to bilder som er svært forskjellige geometrisk.*

I vår applikasjon ser en at selv om forholdet mellom det totale arealet av vårved og det totale arealet av sommerved kan være relativt likt fordelt mellom yte- og margside, vil ytesiden generelt ha bredere årringer og en lavere frekvens i årringsmønsteret. En ønsker derfor å se på om dette vil kunne fanges opp ved hjelp av noen metoder som baserer seg på høyere ordens statistikk.

### 7.3.1 Gray Level Gap Length Matrix

Gray Level Gap Length Matrix er en metode som ble introdusert av Wang et al.[1][3][4] Til forskjell fra GLRLM (seksjon 7.3.2 på side 111) som ser på sammenhengende “runs” av like gråtonenivåer, ser en her på avstander mellom like gråtonenivåer i en gitt retning, altså “gaps” mellom gråtoner.

I en Gray Level Gap Length Matrix (GLGLM) angir altså hvert element  $p(i, j|\theta)$  antall ganger et “gap” for gråtone  $i$  og av lengde  $j$  i en gitt retning  $\theta$  er representert. Et “gap” er her en topp eller dal mellom to kolineære piksler som har samme gråtoneverdi.

Vi lar  $f(i, j)$  være gråtonen for piksel  $(i, j)$ . Et “gap” av lengde  $l = \sqrt{x^2 + y^2} - 1$  for gråtone  $g$  er da et sett med sammenhengende, kolineære piksler mellom punktene  $(i, j)$  og  $(i + x, j + y)$  slik at

$$\begin{aligned}
 & f(i, j) = g, \\
 & \text{samtidig som} \\
 & f(i + u, j + u) > g \quad \text{og} \quad f(i + x, j + y) \leq g \\
 & \text{eller} \\
 & f(i + u, j + u) < g \quad \text{og} \quad f(i + x, j + y) \geq g \quad (7.14) \\
 & \text{der} \quad 0 < u < x, \quad 0 < v < y
 \end{aligned}$$

Et element i GLGLM er da definert ved

$$A(g, l|\theta) = \#\{(i, j)|\text{Likn. (7.14)}\} \quad (7.15)$$

hvor “#” står for “antall” og  $g$  er gråtonen,  $l$  er “gap-length” og  $\theta$  er søkeretningen, samt at en har

$$\begin{aligned}
 x &= (l + 1) \cos \theta, & y &= (l + 1) \sin \theta, \\
 0 \leq g &\leq G - 1, & 0 \leq l &\leq L \quad 0^\circ \leq \theta \leq 360^\circ
 \end{aligned}$$

der  $G$  er antall gråtoner i bildet og  $L$  er det lengste “gap” i bildet.

Figur 7.14 på neste side viser et eksempel på GLGLM for et lite bilde.

Som for GLRLM er det også her i de langt fleste tilfeller mest hensiktsmessig å redusere antall gråtoner i bildet før man genererer en GLGLM, da man generelt er

mest interessert i å representere “gaps” mellom *tilnærmet* og ikke *eksakt* samme gråtonenivåer, samt at man ved bruk av et større antall gråtoner (med unntak av svært store bilder) vil få en svært spredt matrise, med et lavt antall “gaps” i hver celle, og dermed lavere statistisk gyldighet. I vår applikasjon fant vi etter noe testing at en reduksjon fra 256 til 16 gråtoner så ut til å være hensiktsmessig for denne applikasjonen. Etersom en ønsker å fange opp forskjeller i avstander mellom langsgående årringsmønstre fant en det også fornuftig å benytte en  $\theta = 0$ .

For å få en initiell oversikt over om denne metoden kunne gi gode resultater valgte en å se på differansen av midlere GLGLM for yte- og margsidene over et antall prøver. Figur 7.15 på neste side viser resultatene fra denne initielle testen.

Som en ser av differansematrisen er det en tydelig forskjell mellom midlere GLGLM for yte og marg. Denne differansen er imidlertid kun signifikant for svært korte “gaps”, der en ser at yten generelt har en større mengde av sine korte “gaps” for et høyere gråtonenivå enn margsidene. Dette skyldes sannsynligvis intensitetsforskjeller på de to flatene på grunn av ulik kuv, og dermed ulikt belysning over flatene, og har antagelig mindre sammenheng med årringsmønstrene som en først og fremst er ute etter i denne oppgaven. Selv om de initielle analysene tyder på at denne metoden kan gi en brukbar diskriminant mellom yte- og margside etter at kuvingen er igang, valgte en å ikke gå videre med denne metoden. Dette delvis på grunn av at forutsetningen om kuv vil føre til at et av argumentene for en kamerabasert løsning som skissert i denne oppgaven vil falle bort, og delvis på grunn av mangel på tid.

Image:	0° and 90°				45°				135°				
	GapLength				GapLength				GapLength				
	0	1	2	3	0	1	2	3	0	1	2	3	
2 0 2 1	0	0	0	0	2	0	0	0	0	0	2	0	
0 2 3 2	gray 1	0	1	0	0	0	0	1	gray 1	0	0	0	0
2 3 2 0	level 2	0	4	0	0	0	0	0	level 2	5	0	0	0
1 2 0 2	3	0	0	0	0	1	0	0	3	0	0	0	0

Figur 7.14: Et lite bilde-eksempel og tilhørende Gray Level Gap Length Matrix (hentet fra [4]).



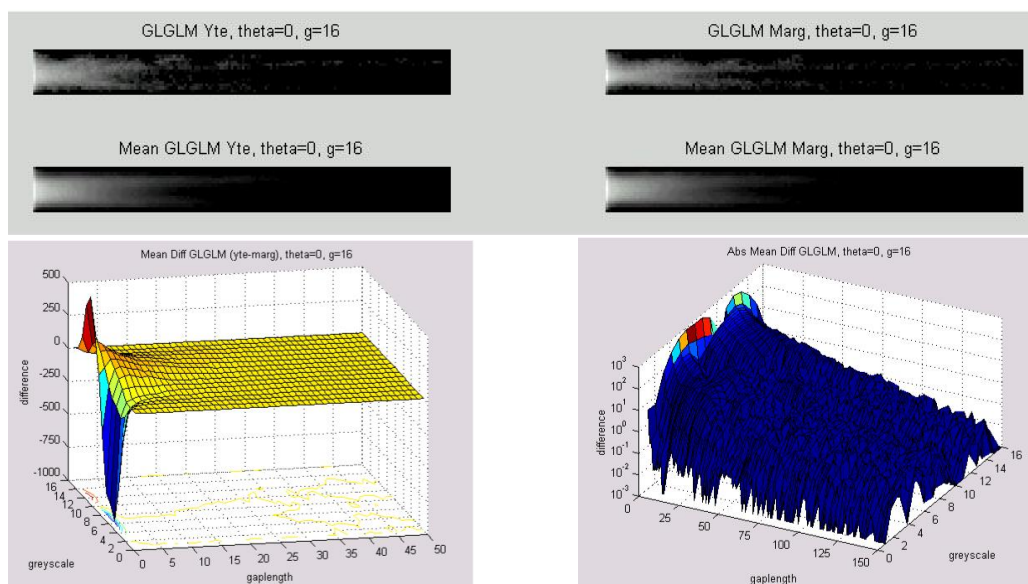
### 7.3.2 Gray Level Run Length Matrix

Gray Level Run Length Matrix er en metode introdusert av Galloway [44] for å trekke ut høyere ordens statistiske egenskaper fra bilder. Metoden gir altså informasjon om pikslenes innbyrdes posisjon i tillegg til deres gråtonefordeling. I en Gray Level Run Length Matrix (GLRLM) angir hvert element  $p(i, j|\theta)$  antall ganger et “run” med gråtone  $i$  og av lengde  $j$  i en gitt retning  $\theta$  er representert. Et “run” er her en mengde 8-naboskap sammenhengende ko-lineære piksler som har samme gråtoneverdi. Den normaliserte GLRLM,  $P(i, j|\theta)$ , er da gitt ved

$$P(i, j|\theta) = \frac{p(i, j|\theta)}{\sum_{i=1}^G \sum_{j=1}^R p(i, j|\theta)} \quad (7.16)$$

der  $G$  er antall gråtoner i bildet og  $R$  er det lengste “run” i bildet. Figur 7.16 på neste side viser et eksempel på GLRLM for et lite bilde.

I de langt fleste tilfeller er det mest hensiktsmessig å redusere antall gråtoner i bildet før man genererer en GLRLM, da man generelt er mest interessert i å representere “runs” over *tilnærmet* og ikke *fullstendig* uniforme regioner, samt at man ved bruk av et større antall gråtoner (med unntak av svært store bilder) vil få en svært spredt matrise, med et lavt antall “runs” i hver celle, og dermed lavere



Figur 7.15: Midlere GLGLM basert på 4 adskilte 300x200 subregioner på 24 forskjellige lamellprøver.

statistisk gyldighet. I vår applikasjon fant vi at en reduksjon fra 256 til 8 gråtoner ga et godt resultat. Det ble i tillegg gjort en histogram-normalisering i forkant av gråtone-reduksjonen for å bedre utnytte den reduserte oppløsningen slik at man i større grad unngår at celler som inneholder “runs” med lav og høy gråtone blir tomme.


Figur 7.17 på neste side viser et eksempel på en differanse GLRLM mellom yte og margside for en av prøvene vist som et gråtonebilde. For å unngå negative verdier har en her flyttet nullpunktet til gråtoneverdi 127. Dersom elementverdiene i GLRLM er større for ytesiden vil en altså få en lys verdi (høyere enn gråtone 127) i gråtonebildet, mens en for de elementverdiene der GLRLM for margsiden er størst vil få mørke gråtoner. En har her funnet GLRLM til kun den midtre subregionen av lamellen (midtre 550 piksler av bildet). Det er innenfor dette området forskjellen mellom yte og marg vil være størst når lamellene er skåret tilnærmet sentrert på margin i stokken slik vist i figur 2.3 på side 10. Bredden på den sentrale subregionen må velges så stor at den skal ta høyde for de naturlige variasjonene i hvor godt sentrert margin vil være på lamellene, men samtidig bør den ikke inneholde for mye av sidekanten på lamellene der forskjellene mellom yte og marg er mindre signifikante, og støyen derfor vil kunne påvirke resultatet til GLRLM-metoden i større grad.

IMAGE

```
1 2 3 4
1 3 4 4
3 2 2 2
4 1 4 1
```

gray level $i$	run length ( $j$ )			
	1	2	3	4
1	4	0	0	0
2	1	0	1	0
3	3	0	0	0
4	3	1	0	0

Figur 7.16: Et lite bilde-eksempel og tilhørende Gray Level Run Length Matrix (hentet fra [6]).



Figur 7.17: Midregion av yte(t.v.), marg(midten), samt Differanse Gray Level Run Length matrise(t.h.) til disse regionene for av prøve 27. GLRLM til marg er subtrahert fra GLRLM til yte.

### Midlere GLRLM


Ut fra figur 7.17 på forrige side kan det se ut til at yten har en overvekt av lengre “runs” for midlere gråtoner, noe som antagelig kan representere de større sammenhengende sommedregionene sentralt på lamellene. For kortere “runs” og høyere gråtoner ser det imidlertid ut til at margsideen har høyest hyppighet. For å få en bedre oversikt om disse funnene lar seg overføre til et større antall av lamellprøvene har en valgt å generere midlere GLRLM for marg og yte. En ønsker altså å finne

$$\overline{p(i, j|\theta)} = \frac{1}{N} \sum_{n=1}^N p_n(i, j|\theta) \quad (7.17)$$



Figur 7.18: Midlere GLRLM for yte på prøve 5-29 (øverst) og tilsvarende for marg(midten). Nederst vises en differansematrix der midlere GLRLM for marg er subtrahert fra midlere GLRLM til yte. Plottene er gjort logaritmiske etter formelen  $p_{\log}(i, j|\theta) = \log(1 + p(i, j|\theta))$  for å lettere oppdage forskjeller i lengre “runs” som er sterkt underrepresentert i antall. En viser her utsnitt av matrisene fram til “runlength”  $R = 100$ .

Som en ser av figur 7.18 og figur 7.19 på neste side viser også GLRLM midlet over 25 prøver at yten har en klar overvekt av lengre “runs” for midlere gråtoner, mens margsideen har en overvekt av kortere til middels lange “runs” for både lavere og høyere gråtoner. En får altså en styrket og mer presis indikasjon på hvor i GLRLM en har den mest signifikante differansen mellom yte- og margside.



Figur 7.19: Tredimensjonalt plott og konturplott av samme differansematrise for midlere GLRLM som vist i figur 7.18 på forrige side for å lettere se forskjellene.

### Uttrekning av skalare egenskaper fra GLRLM

I forrige seksjon så vi utfra den midlere GLRLM indikasjoner på at en har signifikante forskjeller mellom yte og marg for lengre “runs”. Galloway [44] foreslo et egenskapsmål (blant flere) der en multipliserer hver “run length value”,  $P(i, j|\theta)$ , med kvadratet av lengden til det aktuelle “run” for å gi mest vekt til lengre “runs”. Dette egenskapsmålet blir betegnet “Long Runs Emphasis” (LRE) og er gitt ved formelen

$$LRE = \sum_{i=1}^G \sum_{j=1}^R j^2 P(i, j|\theta) \quad (7.18)$$

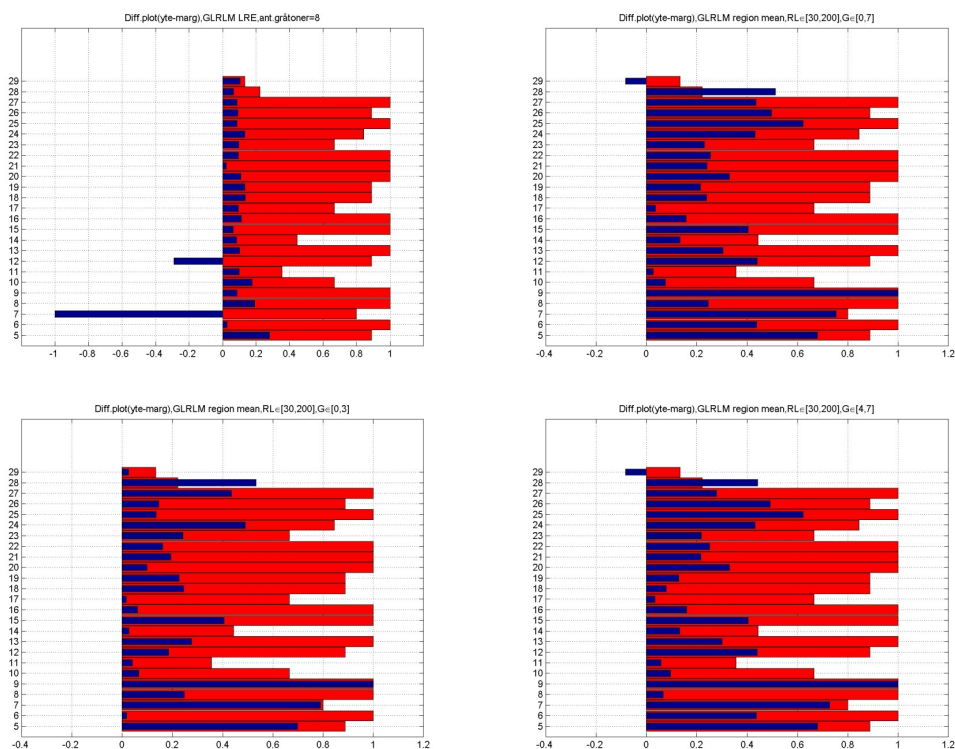
I tillegg til LRE har man sett på midlere antall “runs” som egenskapsmål over ulike rektangulære regioner i GLRLM. Disse egenskapene er da uttrykt ved

$$MGR = \frac{1}{(G_2 - G_1)(R_2 - R_1)} \sum_{i=G_1}^{G_2} \sum_{j=R_1}^{R_2} p(i, j|\theta) \quad (7.19)$$

for ulike verdier av  $G_1$ ,  $G_2$ ,  $R_1$  og  $R_2$ .

Søyleplottene i figur 7.20 på neste side viser resultatene for noen av de testede egenskapsmålene fra GLRLM. En har i tillegg inkludert normaliserte verdier for manuelt målt avstand til marg (jmf. tabell i appendiks B på side 172) for å bedre kunne se om det er en sammenheng mellom verdien av de skalare egenskapene og faktisk avstand til marg.

Som en ser av resultatene gir MGR for gråtoner fra 0-3 og “runs” fra 30-200 ( $G_1 = 0$ ,  $G_2 = 3$ ,  $R_1 = 30$ ,  $R_2 = 200$ ), som den eneste, 100% korrekt klassifikasjon av prøvene. Dette betyr imidlertid ikke nødvendigvis at dette er det generelt beste av disse egenskapsmålene for å diskriminere mellom yte og marg. Det kan for eksempel se ut til at MGR over alle gråtoner ( $G \in [0, 7]$  og  $R \in [30, 200]$ ) gir en større differanse for de fleste av prøvene og i tillegg har bedre samsvar mellom målt verdi og faktisk avstand, selv om denne feilklassifiserer prøve 29. Denne prøven har dessuten kun ca. 6 mm forskjell mellom avstanden fra ytesiden til margen og avstanden fra margensiden til margen, og er dermed den prøven med minst faktisk avstandsdifferanse. Ved en visuell inspeksjon av flatene er det dessuten svært vanskelig å vurdere hvilken som er marg og yte (Over den regionen av lamellprøven som bildet dekker ville en også visuelt – under tvil – anslått at den flaten som faktisk ligger nærmest margen er yten – jmf. appendix). Når differansen er så liten vil det dessuten ha mindre betydning hvilken vei lamellen er vendt med hensyn på risiko for sprekkdannelse. Når det gjelder sammenheng mellom målt



Figur 7.20: Søypleplott som viser resultat ved bruk av LRE og middelerdi over noen ulike faste rektangulære regioner i GLRLM som egenskapsmål. De blå søylene i front viser normalisert differanse mellom egenskaper for yte og marg, mens de røde bakenforliggende søylene viser normalisert differanse for manuelt målt avstand i endeveden på lamellene.

egenskap og faktisk avstand forøvrig, observerer man at prøve 10, 11, 14, 17 og 29 er de fem prøvene med minst verdi av MGR (for sistnevnte region i GLRLM). Alle disse prøvene har margen innenfor den delen av stokken lamellen er skåret ut fra, og er blant de 8 prøvene med minst faktisk avstandsdifferanse. For visse av prøvene ser en imidlertid også lite sammenheng mellom responsstyrke på disse egenskapsmålene og faktisk avstand til marg. Dette skyldes i stor grad at støy påvirker målingene og utjevner/forsterker differansen. Blant annet vil flisete flater stykke opp run's og gi egenskapsmålet en bias mot margside, samtidig som de også vil kunne maskere vekk årringer og således gi en bias mot yteside. I tillegg har også flatene andre objekter som vil påvirke målingene i ulike retninger, slik som kvist, skitt, sprekker, kvaelommer, synlige deler av marg etc.

Som en ser av diskusjonen i forrige avsnitt er klassifikasjonsraten et relativt dårlig "godhetsmål" på algoritmen uten å samtidig vurdere magnituden til responsene på egenskapsmålene sett i forhold til faktisk avstand til marg. Dersom en ønsker et kvantitativt mål på hvor godt algoritmen fungerer er det antagelig mer hensiktsmessig å se på en vektet sum av egenskapsmålene, der vektene er en funksjon av faktisk avstand til marg.



**Adaptiv egenskapsuttrekning fra klasseavstand og klasse differanse GLRLM**

Nielsen et al. [47] har foreslått en adaptiv fremgangsmåte for egenskapsuttrekning fra GLRLM. Metoden beregner et fåtall adaptive egenskaper ved å benytte kvadratet av Mahalanobis klasseavstandsmatriser som vektorer i en summasjon over matrise-elementene. Hvilke elementer det summeres over for de ulike egenskapene, avgjøres av fortegnet til klasse differanse matrisen. En får altså en egenskap der summasjonen utføres over de elementene der klasse differanse matrisen er  $\leq 0$  og en annen der den er  $> 0$ .

I denne metoden beregner man initielt GLRLM,  $P_n(i, j|\omega_c)$ ,  $n = 1, 2, \dots, N(\omega_c)$ , fra et treningssett av størrelse  $N(\omega_c)$  for klasse  $\omega_c$ . Deretter beregner man for hvert element  $(i, j)$  i matrisen den klasseavhengige sannsynlighetsdistribusjonen av den normaliserte matriseverdien. Utfra disse klasseavhengige sannsynlighetsfordelingene kan vi så finne den midlere matrisen,  $\bar{P}(i, j|\omega_c)$  for alle klasser  $\omega_c$ , korresponderende variansmatrise  $\sigma_P^2(i, j|\omega_c)$ , klassedifferansematrisen  $\Delta_P(i, j|\omega_1, \omega_2)$ , og til slutt Mahalanobis distansematrisen  $J_P(i, j|\omega_1, \omega_2)$  mellom klassene  $\omega_1$  og  $\omega_2$ . De nevnte matrisene kan beregnes utfra følgende uttrykk:

$$\bar{P}(i, j|\omega_c) = \frac{1}{N(\omega_c)} \sum_{n=1}^{N(\omega_c)} P_n(i, j|\omega_c) \quad (7.20)$$

$$\sigma_P^2(i, j|\omega_c) = \frac{1}{N(\omega_c)} \sum_{n=1}^{N(\omega_c)} (P_n(i, j|\omega_c) - \bar{P}(i, j|\omega_c))^2 \quad (7.21)$$

$$\Delta_P(i, j|\omega_1, \omega_2) = \bar{P}_n(i, j|\omega_1) - \bar{P}_n(i, j|\omega_2) \quad (7.22)$$

$$J_P(i, j|\omega_1, \omega_2) = 2 \frac{(\bar{P}_n(i, j|\omega_1) - \bar{P}_n(i, j|\omega_2))^2}{\sigma_P^2(i, j|\omega_1) + \sigma_P^2(i, j|\omega_2)} \quad (7.23)$$


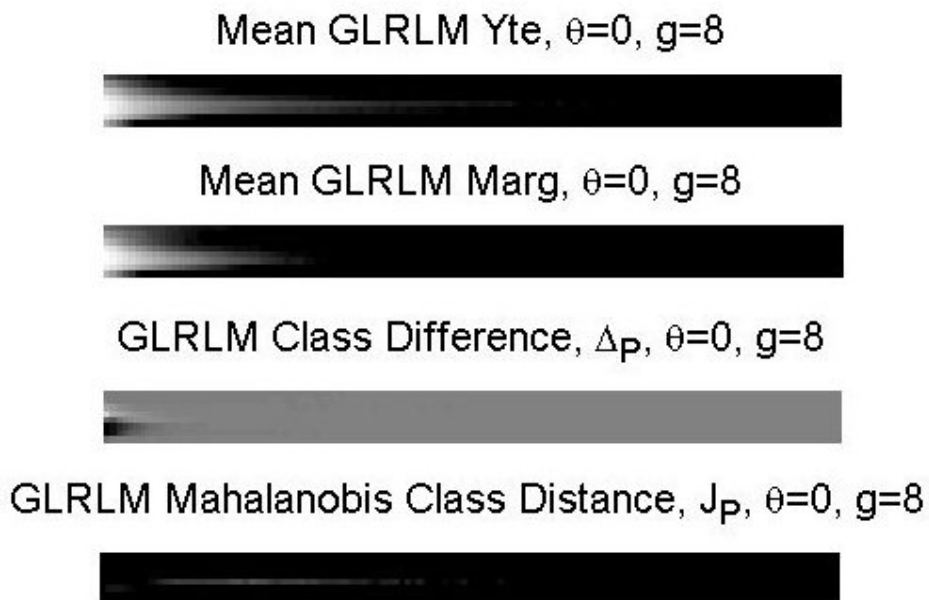
I vår applikasjon setter vi her  $\omega_1$  til å representere *yte* og  $\omega_2$  *marg*-klassen.

Mahalanobis klasse distanse matrisen og klasse differanse matrisen kan så brukes som en basis for å trekke ut to adaptive egenskaper fra sannsynlighetsmatrisen for GLRLM,  $P_k(i, j)$ . Disse egenskapene er gitt ved

$$F_+ = \sum_{\Delta_P(i, j|\omega_1, \omega_2) \leq 0} P_k(i, j|\omega_c) [J_P(i, j|\omega_1, \omega_2)]^2 \quad (7.24)$$

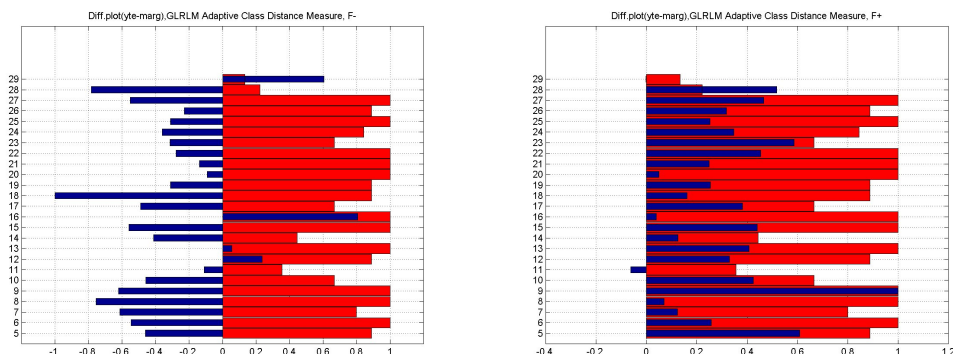
$$F_- = \sum_{\Delta_P(i, j|\omega_1, \omega_2) < 0} P_k(i, j|\omega_c) [J_P(i, j|\omega_1, \omega_2)]^2 \quad (7.25)$$

En summerer altså her sannsynlighetsmatrisen vektet med mahalanobis distanse matrisen over henholdsvis de positive og de negative elementene i differansematrisen mellom klassene. Disse adaptive egenskapene vil dermed kombinere de elementene i sannsynlighetsmatrisen som bidrar mest til separasjonen mellom klassene.



Figur 7.21: Figurene øverst viser midlere GLRLM for de to klassene samt klassenes differansematrix og Mahalanobis distansen mellom klassene, mens figuren under viser et tredimensjonalt plott av Mahalanobis distansen.

På grunn av en svært begrenset størrelse på datasettet valgte en her å benytte leave-one-out kryssvalidering. En benyttet altså 24 av prøvene til å estimere differanse og mahalanobis distanse matrisen, og klassifiserte prøven som ikke var med i treningssettet. Denne prosedyren ble så gjentatt for de resterende 24 prøvene. Klassifikasjonsresultatene ved bruk av denne metoden er vist i figur 7.22.



Figur 7.22: Søyplelott som viser resultat ved bruk av adaptiv klassesdistanse GLRLM som egenskapsmål. De blå søylene i front viser normalisert differanse mellom egenskaper for yte og marg, mens de røde bakenforliggende søylene viser normalisert differanse for manuelt målt avstand i endeveden på lamellene.

Som en ser av figuren gir egenskapen  $F_+$  feilklassifisering for prøve 11 og marginelt for prøve 29, mens egenskapen  $F_-$  gir feilklassifisering for prøve 12, 13, 16 og 29. I tillegg til at en har flere feilklassifiseringer for  $F_-$  gjøres feilklassifiseringene også med betydelig større margin.

### Tilpasning av datasett for adaptiv egenskapsuttrekning fra klasseavstand og klasse differanse GLRLM

Hovedproblemet med å benytte denne metoden direkte som beskrevet i forrige seksjon er at denne baserer seg på at man har et sett med prøvedata innenfor to prinsipielt adskilte klasser som en beregner sannsynlighetsdistribusjonene innenfor. I vår applikasjon vil en imidlertid *per definisjon* ha betydelig overlapp mellom disse klassene ettersom én lamells margside kan være lenger unna margin enn en annen lamells yteside. Hvis en tenker seg at to lameller har ligget ovenfor hverandre i samme stakk før de har blitt skåret ut, vil en for eksempel ha det tilfelle at den indre lamellens yteside er tilnærmet identisk med den ytre lamellens margside. Det vil altså ikke være prinsipielt korrekt å benytte denne metoden direkte på GLRLM for yte og margsiden slik vist ovenfor. For å få en korrekt algoritme må en derfor enten tilpasse selve klassifikasjonsmetoden slik at denne håndterer parvise adskilte klassesdata som ikke nødvendigvis er separerbare på tvers av flere prøvesampler, eller en kan transformere dataene i forkant slik at de får et standard klassifikasjonsformat med separate klasser som kan benyttes i en algoritme som den ovenfor. En valgte her det siste alternativet.

Basert på GLRLM for yte og margside ønsker en altså å lage seg to klasser som – ihvertfall prinsipielt – er separerbare slik at en kan benytte datasettene fra prøvene til å trene en klassifikator for eksempel av typen nevnt over. En måte å gjøre dette på er at en istedenfor å benytte GLRLM for yte,  $P_n(i, j|\omega_1)$ , og marg,  $P_n(i, j|\omega_2)$ , heller klassifiserer differanse GLRLM,  $P_n(i, j|\omega_{1-2})$  og  $P_n(i, j|\omega_{2-1})$ , der disse er gitt ved

$$P_n(i, j|\omega_{1-2}) = P_n(i, j|\omega_1) - P_n(i, j|\omega_2) \quad (7.26)$$

$$P_n(i, j|\omega_{2-1}) = P_n(i, j|\omega_2) - P_n(i, j|\omega_1) \quad (7.27)$$

for  $n = 1, 2, \dots, N$ .

Figur 7.23 på neste side viser differansematrise og Mahalanobis distanse matrise ved bruk av denne metoden.

Når en sammenligner det skalerte plottet av differansematrisen her med det en hadde for de ikke transformerte dataene ser en at disse er helt like. Dette er ikke overraskende siden

$$\begin{aligned} \Delta_P(i, j|\omega_{1-2}, \omega_{2-1}) &= (\bar{P}_n(i, j|\omega_1) - \bar{P}_n(i, j|\omega_2)) - (\bar{P}_n(i, j|\omega_2) - \bar{P}_n(i, j|\omega_1)) \\ &= 2\Delta_P(i, j|\omega_1, \omega_2) \end{aligned} \quad (7.28)$$

Mahalanobis distanse matrisen vil imidlertid være forskjellig. Figur 7.24 viser klassifikasjonsresultatene ved bruk av denne metoden.

En ser av figur 7.24 at denne metoden ga et noe dårligere klassifikasjonsresultat enn den som brukte GLRLM for yte- og margside direkte.

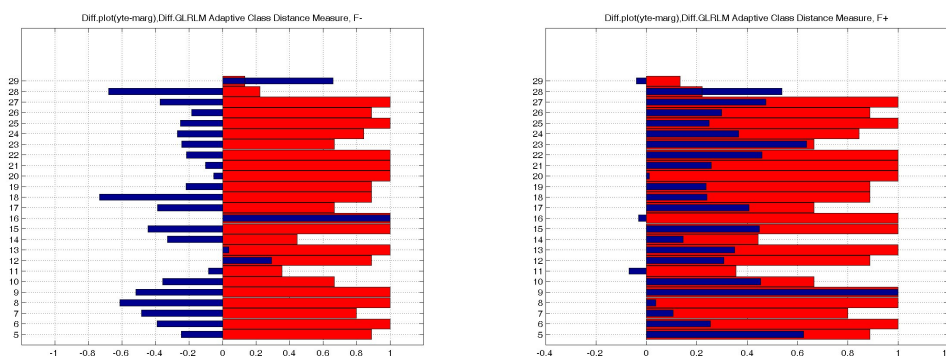
GLRLM Class Difference,  $\Delta_P$ ,  $\theta=0$ ,  $g=8$



GLRLM Mahalanobis Class Distance,  $J_P$ ,  $\theta=0$ ,  $g=8$



Figur 7.23: Figurene viser de transformerte differanseklassene,  $\omega_{1-2}$  og  $\omega_{2-1}$ , sin differansematrise og Mahalanobis distansen mellom klassene.



Figur 7.24: Søypleplott som viser resultat ved bruk av adaptiv klassesdistanse for differanse GLRLM som egenskapsmål. De blå søylene i front viser normalisert differanse mellom egenskaper for yte og marg, mens de røde bakenforliggende søylene viser normalisert differanse for manuelt målt avstand i endeveden på lamellene.

**Konkatenering av GLRLM**

En annen måte å angripe problemet med at rådataene fra GLRLM for yte og marg ikke gir separerbare klasser på er å si at en komplett statistisk beskrivelse av GLRLM til en prøve består i at den inneholder en GLRLM for yten *samtidig* med at den inneholder en GLRLM for margin. Dette kan eksempelvis representeres ved en konkatenering av de to matrisene.

En lagde da kombinerte yte- og margside GLRL-matriser ved å legge matrisen for ytesiden ved siden av den for margside. En får altså

$$P_n(k, j|\omega_{1;2}) = \begin{pmatrix} P_n(i, j|\omega_1) \\ P_n(i, j|\omega_2) \end{pmatrix}$$

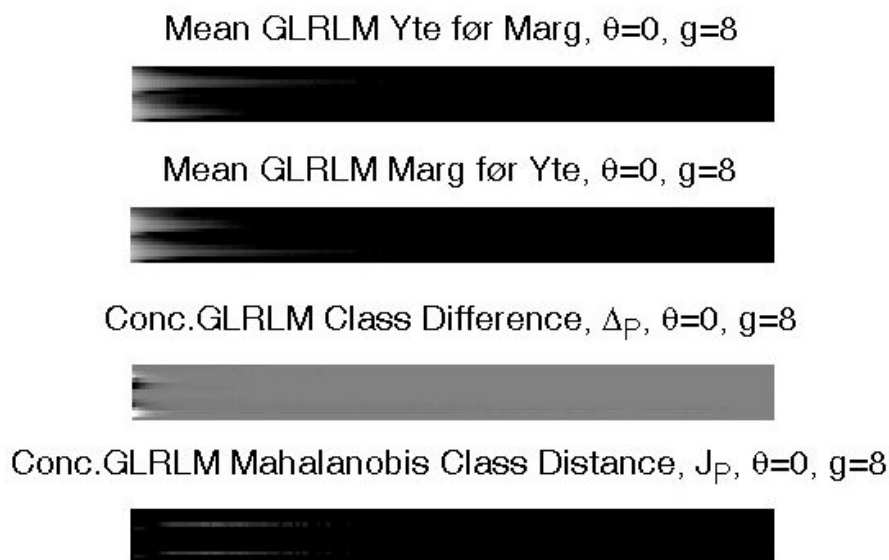
$$P_n(k, j|\omega_{2;1}) = \begin{pmatrix} P_n(i, j|\omega_2) \\ P_n(i, j|\omega_1) \end{pmatrix}$$

for  $n = 1, 2, \dots, N$  og  $k = 1, 2, \dots, 2G$ .


Beregningen av differanse- og avstandsmatriser, samt de adaptive egenskapene ble da gjort på disse konkatenererte matrisene på tilsvarende måte som tidligere.

Figur 7.25 på neste side viser differansematrise og Mahalanobis distanse matrise ved bruk av denne metoden.

Figur 7.26 på neste side viser klassifikasjonsresultatene ved bruk av denne metoden.



Figur 7.25: Figurene viser midlere GLRLM for de konkatenerte klassene ( $\omega_{1;2}$ ) og ( $\omega_{2;1}$ ), samt disse klassenes differansematrix og Mahalanobis distansen mellom klassene.



Figur 7.26: Søypleplott som viser resultat ved bruk av adaptiv klassesdistanse for konkatenerte GLRLM som egenskapsmål. De blå søylene i front viser normalisert differanse mellom egenskaper for yte og marg, mens de røde bakenforliggende søylene viser normalisert differanse for manuelt målt avstand i endeveden på lamellene.



En ser av figur 7.24 på side 124 at denne metoden ga et noe dårligere klassifikasjonsresultat enn den som brukte GLRLM for yte- og margside direkte, mens den sammenliknet med  $F_+$  for den metoden som baserer seg på to differanser fra forrige avsnitt har én prøve mindre feilklassifisert, men til gjengjeld har større margin på de den feilklassifiserer.

En ser også at en får en eksakt speilet respons for  $F_+$  og  $F_-$  egenskapene siden de konkatenerte GLRLM for de to klassene her inneholder de samme dataene, bare med ytedelen i nedre halvdel av “gråtoneskalaen” og margdelen i den øvre for den ene klassen, og vice versa for den andre. Som en ser av figur 7.25 på forrige side gir dette to like konsentrasjoner av høy differanse i øvre og nedre halvdel av  $\Delta_P$  der disse har identisk verdi og form bortsett fra motsatt fortegn, samt at en får lik avstandsmatrise for de to halvdelene.


Alle resultatene med GLRLM ble gjort på originalbilder uten histogramnormalisering og uten logaritmisk “binning” av runlengths i GLRLM. En gjorde også noen forsøk med disse modifikasjonene, men resultatene ble da betydelig dårligere ved histogramnormalisering og marginalt dårligere ved logaritmisk “binning” av runlengths.

## 7.4 GLRLM på preprosesserte bilder

En har hittil i oppgaven benyttet to prinsipielt forskjellige fremgangsmåter for å skille mellom marg- og yteside på limtrelemeller. Den første har vært å benytte ulike preprosesseringsalgoritmer for å fremheve årringsmønstrene for deretter å segmentere og å gjøre ulike målinger, slik som antall og bredder. Den andre tilnæringsmetoden har vært å se på ulike teksturmål som en har antatt har sammenheng med årringsmønstrene og som således kan være egnede diskriminatorer mellom marg- og yteside. I det sistnevnte tilfellet har en til nå gjort disse analysene på bilder som ikke har blitt filtrert og preprosessert for å fremheve årringsmønstrene og undertrykke opprevete fibre og annen støy. En ønsker derfor å se hva en kan oppnå ved å kombinere disse fremgangsmåtene gjennom å benytte seg av de mest suksessfulle metodene for preprosessering av todimensjonalt bilde i kapittel 5 på side 29 med de mest suksessfulle teksturbaserte egenskapsmålene i dette kapitlet.

En har her preprosessert bildet med metoden for lokalisering av beste region beskrevet i kapittel 5.1 på side 29 med størrelse 500x500 piksler, automatisk rotasjon av bildet som beskrevet i kapittel 5.2 på side 34, adaptivt LoG-filter fra kapittel 5.5.2 på side 51 og 5.5.4 på side 54, og til slutt 5 iterasjoner med probabilistisk relaksasjon slik kapittel 6.5 på side 73 beskriver.

Figur 7.27 viser et eksempelbilde etter å ha brukt den skisserte preprosesseringsmetoden.




Figur 7.27: Region fra prøve 5 preprosessert for å fremheve årringer og undertrykke støy med hensyn på teksturbasert egenskapsuttrekning. Yteside til venstre og marg til høyre.

Som teksturmål har en brukt adaptiv egenskapsuttrekning fra klasseavstand og klasse differanse GLRLM på concatenerte matriser beskrevet i seksjon 7.3.2 på

side 119 og 7.3.2 på side 125. Figur 7.28 på neste side viser resultater ved bruk av denne metoden.

En ser av figur 7.28 på neste side at denne metoden ga korrekt klassifikasjon for alle prøvene, dog med relativt liten margin for noen av de. Når det gjelder samsvaret mellom magnituden på de målte egenskapene og faktisk avstand til marg kan en imidlertid ikke se noen signifikant sammenheng.

En ser at en også her får en eksakt speilet respons for  $F_+$  og  $F_-$  egenskapene på grunn av konkatenering av GLRLM. Dette er nærmere forklart i seksjon 7.3.2 på side 125.



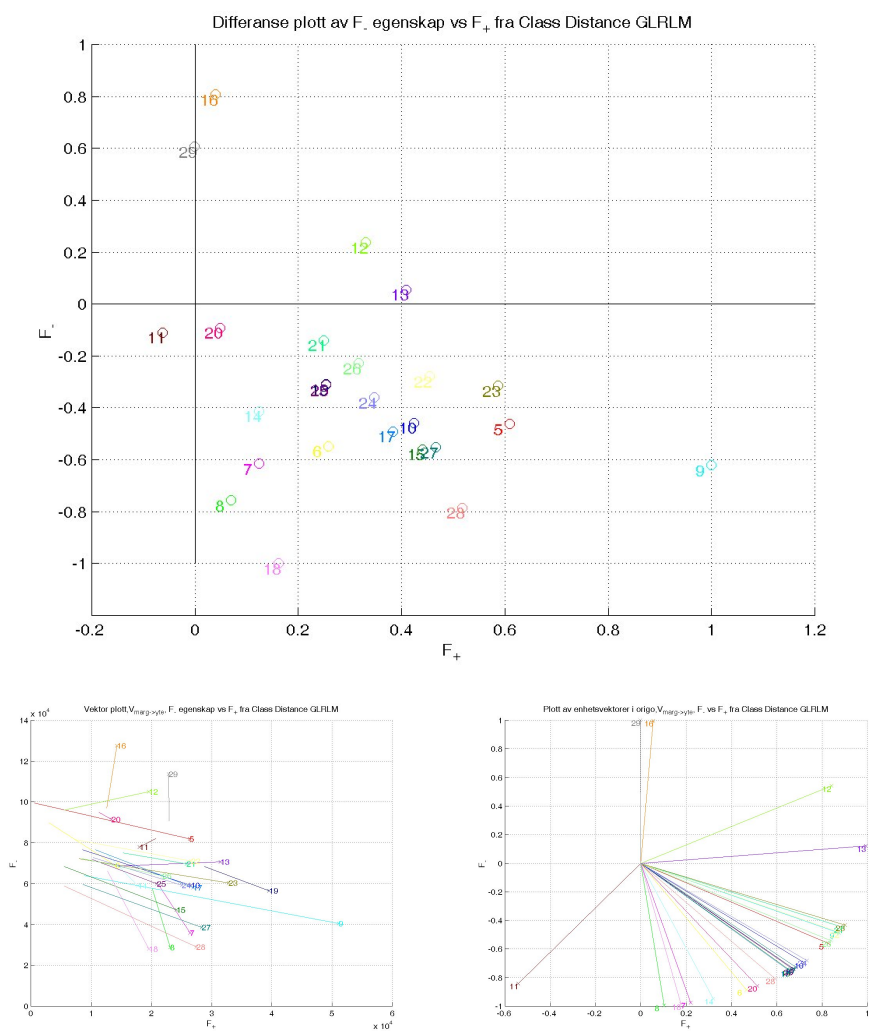
Figur 7.28: Resultater ved bruk av adaptiv egenskapsuttrekning fra klasseavstand og klasse differanse GLRLM på preprosseserte bilder og concatenerte matriser. Fra toppen: Midlere concatenerte GLRLM, differanse- og Mahalanobis avstandsmatrise, og nederst søyleplott som viser klassifikasjonsresultat med metoden for egenskapene  $F_+$  og  $F_-$ . De blå søylene i front viser normalisert differanse mellom egenskaper for yte og marg, mens de røde bakenforliggende søylene viser normalisert differanse for manuelt målt avstand i endeveden på lamellene.

## 7.5 Kombinasjon av flere egenskaper

En har tidligere i dette kapitlet sett på ulike metoder for å trekke ut egenskaper fra bildene som er egnet for å skille yte- og margside på limtrelamellene. Ved klassifisering har en imidlertid hittil kun sett på egenskapene hver for seg. I denne seksjonen skal en se på hva en kan oppnå ved å kombinere noen av disse egenskapene for å få en bedre klassifikasjonsrate.


Figur 7.29 på neste side viser et differanseplott for egenskaper fra adaptiv klasse distanse metoden på GLRLM slik beskrevet i seksjon 7.3.2 på side 119. En har videre forsøkt å få fram ekstra informasjon ved å lage vektorer som går fra egenskapenes verdi for margin til egenskapenes verdi for yten. En ønsker her at disse vektorene skal ha en mest mulig uniform retning for å med best mulig margin kunne skille marg- og ytesiden under disse egenskapene. Vektorplottet nederst til venstre inneholder informasjon om hvilken faktisk score en prøve har fått for de to egenskapene, og vektorlengden gir informasjon om graden av forskjell mellom marg- og yteside for egenskapskombinasjonen. Det kan imidlertid være vanskelig utfra denne grafen å få oversikt over spredningen i vinkel. En har derfor translateret vektorene til origo og gitt disse enhets lengde for å tydeliggjøre denne forskjellen.

En ser av differanseplottet og det translaterte vektorplottet at  $F+$  egenskapen diskriminerer best, men denne har en reversert fortegn for prøve nummer 11 i forhold til de andre prøvene, og er marginalt positiv for prøve nummer 16 og 29. De sistnevnte er dessuten feilklassifisert med stor margin av  $F-$  egenskapen. Dersom en tenker seg at en trekker en rett “beslutningslinje” gjennom origo i differanse- eller det translaterte vektorplottet og forsøker å rotere denne så en får alle punktene/vektorene på samme side av denne, ser en her raskt at det ikke vil være mulig å klassifisere alle prøvene korrekt med en lineær kombinasjon disse av  $F+$  og  $F-$  egenskapene. En observerer forøvrig av vektorplottet til venstre at de mest problematiske prøvene har en relativt høy score for  $F-$  egenskapen sett i forhold til de andre prøvene.



Figur 7.29: Scatterplott av differansen mellom yte og marg for egenskapene  $F_+$  vs.  $F_-$  (øverst) samt plott av marg til yte vektorer basert på de samme egenskapsmålene (under). I figuren nederst t.h. er vektorene translaterert til origo og gitt enhets lengde for å tydeliggjøre forskjeller i retning.

Figur 7.30 viser et scatterplott for egenskaper fra adaptiv klasse distanse metoden på differanse GLRLM slik beskrevet i seksjon 7.3.2 på side 123.



Figur 7.30: Scatterplott som viser egenskapene  $F_+$  vs.  $F_-$  for klassene  $\omega_{1-2}$  og  $\omega_{2-1}$ . Dataene for den ene klassen vil her være lik dataene for den andre klassen med invertert fortegn siden en her gjør egenskapsuttrekningen basert på differansen mellom de to klassene.

En ser av figuren at de fleste av dataene har en brukbar samling og separasjon fra den andre klassen. Det er imidlertid noen prøver som vil kunne bli svært problematiske å klassifisere korrekt. Dette gjelder spesielt prøve nummer 16 og 29 som en ser at ligger såpass tett opp til de andre klassetthetene at de antagelig vil være vanskelige å klassifisere riktig også med en kvadratisk klassifikasjonsregel. Som en ser av figur 7.24 på side 124 ser en at de samme prøvene også ble feilklassifisert når en så på  $F_+$  og  $F_-$  separat ved bruk av samme metode. Sammenligner en med og 7.26 på side 126 ser en at de samme prøvene også ble feilklassifisert ved bruk av konkatenererte GLRLM matriser. Om en imidlertid ser på manuelt målt avstand i de samme figurene ser en at prøve nummer 29 også har svært liten





som ligger i grenseland for den ene av egenskapene også har en tendens til å ligge i grenseland for den andre (jmf. prøve nr 11, 16 og 29), slik at å tilføre en ekstra egenskap kan således ikke forventes å gi en stor forbedring av klassifikasjonsraten. Det sistnevnte er også til en viss grad tilfellet for plottet som viser  $F_+$  versus  $F_-$ .

Det kan altså være noe å hente på å kombinere flere egenskaper når det gjelder klassifikasjonsrater, selv om de scatterplottene og kombinasjonene en har sett på her indikerer at en ikke kan forvente svært store forbedringer siden de prøvene som er problematiske har en tendens til å være de samme på tvers av de ulike egenskapsmålene.

### 7.5.1 Klassifikasjon basert på kombinasjon av flere egenskaper

Selv om de problematiske prøvene – som nevnt i den initiale analysen i forrige seksjon – hadde en tendens til å ha liten differanse mellom marg- og yteside for de fleste egenskapsmålene, kan det være et signifikant forbedringspotensiale ved å kombinere flere egenskaper. En valgte derfor å undersøke litt nærmere hvilke resultater en kan oppnå ved å benytte en klassifikator i et flerdimensjonalt egenskapsrom.

En bør imidlertid være forsiktig med å benytte for mange egenskaper i en klassifikator dersom man ikke har svært store datasett, da risikoen for at en ved en tilfeldighet finner en tilpasning øker betraktelig med dimensjonen til egenskapsrommet (“The curse of dimensionality” [51],[7]). Siden en i denne oppgaven har et såpass lite datasett ønsker vi å minimere dette problemet ved å unngå klassifikatorer med mange frihetsgrader, samt å begrense antall egenskaper. En valgte derfor å benytte en Bayesiansk klassifikator ([51], [20]) med beste lineære og kvadratiske regel, samt å begrense antall egenskaper til 2.

En antar at dataene er normalfordelte, og siden de to klassene alltid blir presentert parvis har de lik apriorisannsynlighet. En forutsetter videre at “tap”(“loss” jmf. [51], [20]) for en korrekt beslutning er 0, og at “tap” for en ukorrekt beslutning er 1 (ingen “doubt”).

I Bayes regel for Lineær diskriminant analyse (LDA) forutsetter en at klassene har lik kovariansmatrise,  $\Sigma$ . Klassifikasjonsregelen velger da klasse  $j$  dersom denne maksimerer

$$LDA_j = \mathbf{x}\Sigma^{-1}\mu_j^T - \frac{1}{2}\mu_j^T\Sigma^{-1}\mu_j \quad (7.29)$$

for  $j = 1, 2$ , der  $\Sigma$  er felles kovariansmatrise og  $\mu_j$  er middelverdivektoren for klasse  $j$ , og  $\mathbf{x}$  er egenskapsvektoren for gjeldende prøve.


Bayes regel for kvadratisk diskriminant analyse (QDA) er på tilsvarende måte gitt ved

$$QDA_j = -\frac{1}{2}\ln|\Sigma_j| - \frac{1}{2}[(\mathbf{x} - \mu_j)\Sigma_j^{-1}(\mathbf{x} - \mu_j)^T] \quad (7.30)$$

for  $j = 1, 2$ , der  $\Sigma_j$  er kovariansmatrisen for klasse  $j$  og  $\mu_j$  er middelverdivektoren for klasse  $j$ , og  $\mathbf{x}$  er egenskapsvektoren for gjeldende prøve.

Figur 7.32 på side 138 viser resultater ved bruk av Lineær Diskriminant Analyse (LDA) og Kvadratisk Diskriminant Analyse (QDA) som klassifikatorer for  $F_+$  og  $F_-$  egenskapene hentet fra adaptiv klasse distanse metoden på konkatenerert

GLRLM. En har i begge tilfeller antatt at egenskapsmålene er normalfordelte og at klassene har like apriorisannsynligheter. Resultatene er basert på klassifikasjon med leave-one-out kryssvalidering.



Figur 7.32: Klassifikasjonsresultater ved bruk av LDA og QDA samt leave-one-out kryssvalidering for egenskapene  $F_+$  vs.  $F_-$  ved konkatenering av GLRLM. Den virkelige klasses tilhørigheten er markert med punkt for  $\omega_{1,2}$  og kryss for  $\omega_{2,1}$ , mens den estimerte klasses tilhørigheten er markert med henholdsvis en sirkel og en firkant.

Tabell 7.1 viser forvirringsmatrisene for de samme klassifikasjonsmetodene og egenskapene:

LDA		QDA	
23	2	25	0
2	23	0	25

Tabell 7.1: *Forvirringsmatriser med ulike klassifikasjonsmetoder for egenskapene  $F_+$  og  $F_-$  ved konkatenering av GLRLM.*

Som en ser av figur 7.32 på forrige side og tabell 7.1 oppnår en 100% korrekt klassifikasjon ved bruk av den kvadratiske klassifikasjonsregelen (QDA), mens den lineære regelen (LDA) feilklassifiserer to prøver. Utfra scatterplottene kan en også observere en at en lineær beslutningslinje ikke vil kunne klare å separere klassene effektivt. Dessuten har en at siden dataene for klasse  $\omega_{1;2}$  er speilede versjoner av dataene for klassen  $\omega_{2;1}$ , vil kovariansmatrisen for den ene klassen være lik den transponerte av kovariansmatrisen for den andre klassen, altså  $\Sigma_{1;2} = \Sigma_{2;1}^T$ . Så lenge  $\Sigma \neq \Sigma^T$  vil altså forutsetningen om felles  $\Sigma$  for alle klassene i LDA [51] [20] ikke være oppfylt i vår applikasjon, og en optimal regel i henhold til Bayes formel vil ikke være lineær.

Figur 7.33 på neste side viser klassifikasjonsresultater for  $F_+$  egenskapen hentet fra adaptiv klasse distanse metoden på differanse GLRLM kombinert med antall åringer.


Tabell 7.2 viser forvirringsmatrisene for de samme klassifikasjonsmetodene og egenskapene:

LDA		QDA	
23	2	23	2
2	23	2	23

Tabell 7.2: *Forvirringsmatriser med ulike klassifikasjonsmetoder for egenskapene  $F_+$  for differanse GLRLM og antall åringer.*

Som en ser av figur 7.33 på neste side og tabell 7.2 oppnår en noe dårligere klassifikasjonsrater for disse egenskapene enn det en gjorde med  $F_+$  og  $F_-$  fra konkatenerert GLRLM.

Egenskapsutvelgelsen har i det foregående vært gjort manuelt og i stor grad basert på de egenskapene som fungerer bra individuelt. Disse egenskapene kan imidlertid være korrelerte, og vil således ikke nødvendigvis være de som gir en best mulig diskriminering når de kombineres [53] [54].



Figur 7.33: Klassifikasjonsresultater ved bruk av LDA og QDA samt leave-one-out kryssvalidering for egenskapene  $F_+$  for differanse GLRLM vs. antall årringer. Den virkelige klassetilhørigheten er markert med punkt for  $\omega_{1;2}$  og kryss for  $\omega_{2;1}$ , mens den estimerte klassetilhørigheten er markert med henholdsvis en sirkel og en firkant.

Selv om resultatene i figur 7.32 på side 138 og tabell 7.1 på side 139, gir 100% prosent korrekt klassifikasjonsrate for prøvene er det høyst tvilsomt at dette resultatet kan videreføres på et fremtidig datasett. Ved trening av klassifikatoren på et så begrenset antall prøver er det stor risiko for overtilpasning, og siden uhøvlede limtre lameller har store variasjoner i overflatestruktur og årringsmønstre, og i tillegg kan inneholde en rekke forskjellige detaljer (som f.eks. kvist, marg, kvaelommer, skitt etc.) kreves det et stort datasett for å få et representativt utvalg.

Problemet med et lite datasett er forsøkt kompensert for ved å benytte leave-one-out kryssvalidering for å kunne ha et størst mulig treningssett samtidig som at en reduserer muligheten for overtilpasning ved å teste på en prøve som ikke er med i treningssettet. En leave-one-out kryssvalidering vil imidlertid også gi et optimistisk bias når en gjør egenskapsutvelgelsen basert på alle dataene [53]. En alternativ metode beskrevet i [53] ville vært å gjøre egenskapsutvelgelsen innenfor hver syklus av leave-one-out. For  $F_+$  og  $F_-$  fra konkatenerert GLRLM innebærer dette eksempelvis at en lager alle matrisene og finner de adaptive egenskapene for alle prøvene minus én, og så klassifiserer den utelatte prøven. Hele denne prosedyren gjentas så for de resterende prøvene. Denne varianten av leave-one-out gir praktisk talt ingen bias i den estimerte klassifikasjonsraten [53], men den har en betydelig høyere varians. Man vil altså heller ikke med denne metoden kunne sitte igjen med et entydig sett av egenskaper som kan anbefales brukt på et fremtidig stort datasett.

## 7.6 Overordnet logikk for beslutning om hva som er yte- og margside

Som nevnt i seksjon 5.1 på side 29 blir det tidlig i bildeprosesseringssekvensen gjort en bedømming av hvilke regioner av bildet som er best egnet for videre analyse, og hvilke som er så preget av støy at videre prosessering av disse er unødvendig og bare vil bidra til å gjøre beslutningen mer usikker. En skal i denne seksjonen se på metoder for å kombinere resultater fra flere subregioner på limtre-lamellene for å øke påliteligheten av egenskapsmålene, samt gi en sikrere beslutning når det gjelder hva som er yte- og margside.

Som nevnt i kapittel 5.1 på side 29 kombinerte en årringsmålinger fra flere subregioner som passerte godhetskriteriet ved å ta medianen av resultatene (antall årringer/midlere årringsavstand) når regionene lå i nærheten av hverandre langs lamellens lengderetning (innenfor samme bilde) og hadde tilnærmet samme posisjon i tverretning. Dette for å gjøre systemet mer robust mot falske og manglende deteksjoner på grunn av støy/dårlig kontrast. For regioner som ligger lengre unna hverandre i lamellens lengderetning vil imidlertid disse årringsmålene kunne være svært forskjellig. Siden stokken kan være skåret skjevt i forhold til margin vil en dessuten kunne ha det tilfellet at for den ene enden av stokken er oversiden nærmest marginen, mens for den andre enden er undersiden nærmest. For å håndtere disse tilfellene ønsker en i det ferdige systemet å analysere lamellen på flere steder mens denne føres forbi kameraet og til slutt kombinere disse resultatene med en *majority vote*. For å få en mest mulig robust analyse er det prinsipielt ønskelig å gjøre flest mulig analyser langs lamellen, gjerne også med overlapp, men dette vil begrense seg i forhold til prosesseringshastighet og maskinvarekostnader forbundet med å øke denne.

Selv om det prinsipielt er nok med tre sampler jevnt fordelt langs lamellen for å kunne detektere om en side *hovedsakelig* er en yte- eller margside, bør en imidlertid dimensjonere systemet for å få minimum 5 sampler langs de korteste lamellene som kjøres. Dette vil da medføre at en kan håndtere at to av disse bildesamplene kan være regioner med så mye støy at en ikke kan oppnå pålitelige målinger (dersom ingen tilleggseffekter av typen nevnt over eksisterer samtidig), og allikevel gjøre en korrekt beslutning.

Når det gjelder bildematerialet benyttet i denne oppgaven besto disse av kun 25 forskjellige lamellprøver (pluss 4 av en annen type og tatt med annen oppløsning) der en kun har avbildet et område på ca 90x70 mm av lamellen. Det er derfor liten grunn til å tro at en har noe worst case tilfelle blant noen av disse. Det en imidlertid ser er at selv innenfor de begrensede områdene en har avbildet varierer bakgrunnsstøyen svært mye og ytelsen til algoritmene med denne. Slik at om en



øker antallet samples av samme lamell, og samtidig er istand til å gjøre en vurdering av hvilke regioner som kan gi mest pålitelig deteksjon, bør en kunne øke robustheten for lameller av den typen en har sett betydelig og samtidig få større marginer for å takle de variasjonene som vil oppstå for et produkt av denne typen når en ser på langt større volum enn det som lar seg gjennomføre å benytte i en studie som denne.

## 7.7 Egenskapsutvelgelse

De ulike metodene en har gjort forsøk med i dette kapitlet måler en rekke forskjellige egenskaper som er relatert til årringsmønstrene i trevirket. En har f.eks. beregnet antall årringer, midlere årringsbredder, en rekke ulike fourierbaserte egenskaper, GLRLM-baserte egenskaper og GLGLM-baserte egenskaper. Det kunne vært interessant å benytte en egenskapsutvelgelsesalgoritme for å finne et subset av egenskapene som gir en god diskriminering mellom marg og yteside, og samtidig er ukorrelerte.

Det finnes en rekke algoritmer i litteraturen for egenskapsutvelgelse [53], [55]:

- En har optimale metoder som tester alle kombinasjonene av  $d$  ut av  $D$  kandidater. Her blir imidlertid utfallsrommet uhåndterlig selv for et moderat antall egenskaper [53]. Det finnes også varianter av denne som er garantert å finne det optimale subsettet raskere [59], gitt at visse kriterier oppfylles.
- En har sequential-forward [56] og sequential-backward [57] samt en kombinasjon av disse; stepwise forward-backward selection [58]. For disse metodene legges et gitt antall egenskaper til og et gitt antall trekkes fra i hvert step.
- En har også “Floating Search” metoder, der antall egenskaper lagt til og fjernet kan variere i hvert steg. Pudil et al. sin “Sequential Forward Floating Selection” (SFFS) algoritme [60] har her fått gode resultater i litteraturen.

Å velge ut de egenskapene som best separerer klassene kan imidlertid være problematisk også for en automatisert algoritme når en disponerer et såpass lite datasett som i vårt tilfelle. Schulerud og Albregtsen [53] har gjort en Monte Carlo studie som viser at sannsynligheten for å velge de korrekte egenskapene er avhengig av størrelsen på treningssettet, antall egenskaper samt Mahalanobis-distansen mellom klassene. Deres simuleringer viser at for å finne flesteparten av de korrekte egenskapene når antallet treningsdata er få (<100) varierer forholdet mellom antall

i treningsettet og antall egenskapskandidater,  $n^{Tr}/D$  mellom 1 og 10 (Simuleringene ble her gjort med en stepwise-forward-backward egenskapsutvelgelsesmetode og en bayesiansk klassifikator). Siden vi har 24 prøver når vi benytter leave-one-out, vil da antall egenskaper som vi kan mate inn i en eventuell automatisk algoritme ligge en plass mellom 2 og 24. Siden vi basert på analysene som ble gjort med egenskapene hver for seg og parvis kan anta at Mahalanobis-distansen mellom klassene ikke er stor er det grunn til å begrense antall kandidater til helt i det nedre sjiktet av dette intervallet. På grunn av tidsmangel, og delvis på grunn av at det var noe usikkert hvor mye som var å hente, valgte en å ikke gå videre med å implementere en automatisert egenskapsutvelgelse i denne oppgaven. En vil uansett få vesentlig mer utbytte av å gjøre dette steget etter at en eventuelt får montert en prototyp inn i produksjonslinjen og dermed har vesentlig større tilgang på data.

## 7.8 Diskusjon og andre deskriptorer

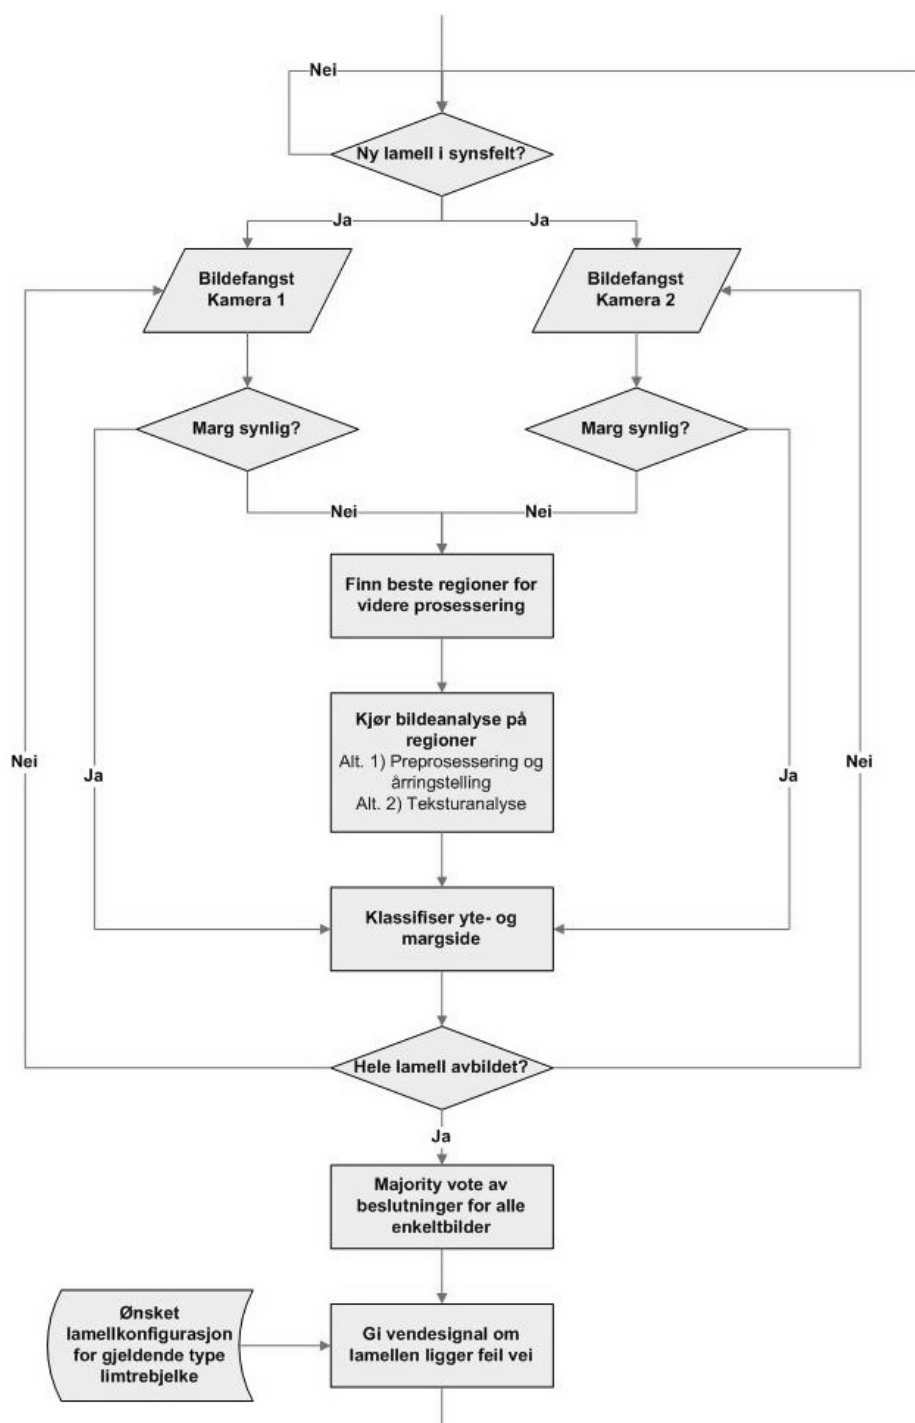
Denne oppgaven har valgt å konsentrere seg om årringsegenskaper for å klassifisere hva som er marg og yteside på limtrelameller. I tillegg til disse er det som en også var inne på i kapittel 2 på side 6 flere andre deskriptorer som kan benyttes for å øke klassifikasjonsraten.

Et opplagt egenskapsmål som en antagelig bør inkludere for å øke klassifikasjonsraten er *margen* på lamellen når denne er synlig. Denne har god kontrast mot både vår- og sommerveden, samt karakteristisk form, i tillegg til at den i vår applikasjon også har en begrenset variabilitet i posisjon. Den bør derfor være relativt enkel å detektere på en sikker måte.

Andre egenskaper en kan vinne på å inkludere, er arealet på kvist når disse er tilstede, og kan detekteres pålitelig. Som nevnt i 2 på side 6 vil kvist ha et økende areal mot yten av lamellen.

En bør imidlertid være forsiktig med å benytte for mange egenskaper i en klassifikator (og egenskapsutvelgelse) da risikoen for at en ved en tilfeldighet finner en tilpasning øker betraktelig med dimensjonen til egenskapsrommet (“The curse of dimensionality”) [51], [7]. Det faktum at noen av de nevnte tilleggsegenskapene heller ikke alltid er tilstede på limtrelamellene, øker kompleksiteten ved design av visse klassifikatorer betraktelig (eksempelvis bayesianske klassifikatorer [51][20] og nevrale nett [52][51]). En måte å omgå dette problemet på er selvfølgelig å kjøre separate klassifikasjoner for disse egenskapene, og finne en egnet metode for å kombinere resultatene. Hvis en eksempelvis anser kvistareal som en mer pålitelig egenskap enn årringer, kan en gi resultatet fra denne klassifikasjonen høyere prioritet.

En har i stor grad benyttet uprosesserte “råbilder” som input til algoritmene beskrevet i dette kapitlet. Hovedårsaken til dette var at en ønsket å se om det var mulig å finne pålitelige diskriminatorer uten å benytte den relativt prosesseringskrevende algoritmen beskrevet i kapittel 5 på side 29 i tillegg til de teksturbaserte algoritmene beskrevet her. En så imidlertid i seksjon 7.4 på side 128 at en kunne oppnå bedre resultater ved bruk av preprosesserte bilder som input til metoden for adaptiv egenskapsuttrekning fra klasseavstand og klasse differanse på konkatenerede GLRLM enn det en kunne på “råbilder”. Metodene i kapittel 5 på side 29 var her dessuten utviklet med hensyn på segmentering og årringstelling/måling, så det er også mulig en kunne oppnå enda bedre resultater dersom disse algoritmene ble utviklet spesielt som et preprosesseringssteg for eksempelvis egenskapsuttrekning via GLRLM. En så blant annet at selv om Adaptivt LoG-filter og probabilistisk relaksasjon som preprosesseringssteg er relativt effektive når det gjelder undertrykking av støy og fremheving av årringsmønstrene, gir de en relativt dårlig



Figur 7.34: Flytskjema som illustrerer hvordan en kan tenke seg en inspeksjonsskvens der en kombinerer deteksjon av marg når denne er synlig med årringsdeteksjon/teksturanalyse og kombinerer resultatene fra bilder på flere steder langs lamellen med en majority vote til slutt.

utnyttelse av elementene i GLRLM siden en svært stor andel av pikselverdiene ligger i ekstremområdene av gråtoneskalaen. Det er mulig en bedre tilpasning her ville gitt forbedringer.

En har videre i dette kapitlet i stor grad benyttet hele bilder, eller en større fast region, istedenfor algoritmen for lokalisering av “beste region” for videre prosessering beskrevet i kapittel 5.1 på side 29. Hovedårsaken til dette har vært at en har bilder fra et svært begrenset område av lamellen, og for en del av de algoritmene en har prøvd er avhengig av en viss mengde data for å få en pålitelig analyse. En ønsker for eksempel å unngå at Gray Level Run Length og Gray Level Gap Length matrisene blir for spredte, det vil si at deres “average occupancy level” blir for liten. I tillegg vil en ved bruk av større regioner bli mindre følsom for avvik som eksempelvis lyse kvister, svært opprevete delregioner etc. som i visse tilfeller ikke kan elimineres vekk av datareduksjonsalgoritmen. Noen ganger vil disse støyobjektene være tilstede i alle de begrensede regionalalternativene en kan plukke fra. Dersom en hadde hatt et større antall bilder fra en flere meter lang lamell ville en kunne vunnet en del på å eliminere vekk de dårligere regionene også for de teksturbaserte metodene i dette kapitlet, men med en så begrenset datamengde har en vurdert det som mest hensiktsmessig å kun dele inn råbildet i en eller maksimalt to subregioner slik det ble gjort i 7.4 på side 128.

# Kapittel 8

## Andre anvendelser

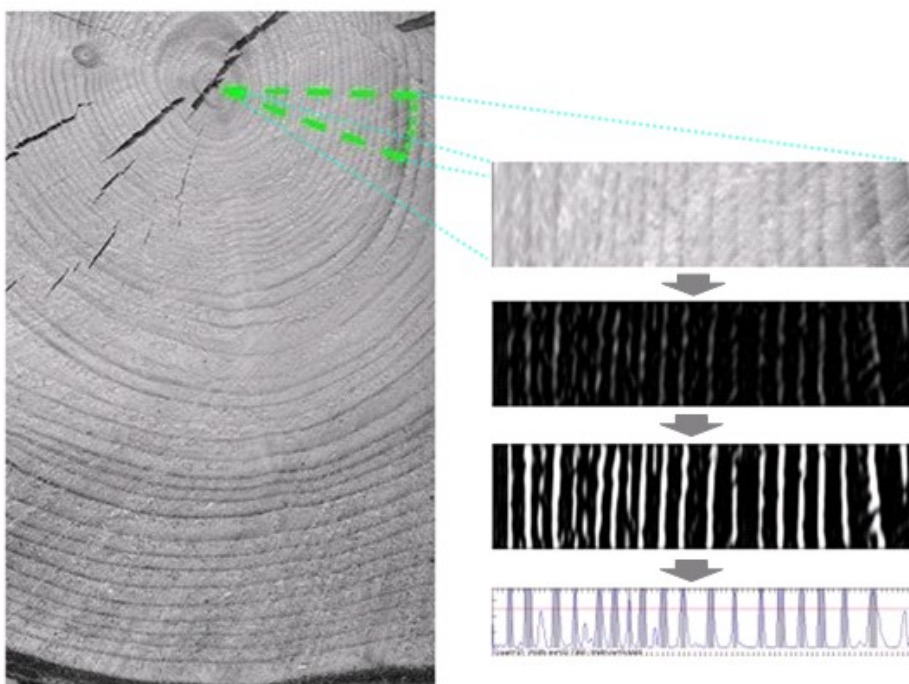
En har i denne oppgaven hatt fokus på å løse en konkret oppgave, nemlig å bestemme yte- og margside av limtre lameller basert på årringsmønstre. En del av metodene kan imidlertid brukes i en rekke andre anvendelser der en ønsker å segmentere eller estimere årringsmønstre, samt også andre lineære mønstre, i støyfylte omgivelser. Eksempler på konkrete anvendelser er dendrokronologi, dendroklimatologi, sortering av trevirke med hensyn på papirproduksjon, kvalitetssortering, styrkeberegninger, kontroll av kuvretning og rettvending i forbindelse med panelproduksjon m.m.

I mange av de alternative anvendelsene ønsker en å analysere årringsmønstrene i endeveden på stokken, der årringene har en tilnærmet sirkulær form istedenfor lineær, slik metodene i denne oppgaven forutsetter. En måte å håndtere dette på er å gjøre en kartesisk til polar transform av bildet og benytte algoritmen på et rektangulært bilde med polare koordinater. For et koordinatsystem med origo i margin kan denne transformen uttrykkes ved

$$\begin{aligned} f_p(r, \theta) &= f_k(x, y) && \text{der} \\ x &= r \cos(\theta) && \text{og} \\ y &= r \sin(\theta) \end{aligned} \tag{8.1}$$

for  $r \in [0, R]$  og  $\theta \in [\Theta_1, \Theta_2]$ . Siden de korresponderende punktene til  $(r, \theta)$  i det kartesiske systemet da generelt ikke havner på hele pikselverdier har en samplet  $f_k(x, y)$  ved hjelp av bilinear interpolering.

I figur 8.1 på neste side har en benyttet denne transformen i forkant av segmentering algoritmen beskrevet i denne oppgaven.



Figur 8.1: Eksempel på bruk av metodene beskrevet i denne oppgaven for segmentering av endeveden på en uhøvlet stokk. Bildet er her transformert fra et sektorsegment sentrert om margen i stokken til en rektangulær region slik at årringsmønstrene blir tilnærmet lineære. Det rektangulære bildet har her en lavere oppløsning for lavere pikselverdier,  $x$ . Sektorsegmentet ble her sentrert på margen manuelt.

Som en ser av figuren får man en god deteksjon av årringene for telling. Segmenteringen av vår- og sommersvedsområdene ser også fornuftig ut, med unntak av de brede sommersvedområdene helt til høyre i regionen som fremtrer noe smale etter segmentering. For så brede årringer kunne en antagelig fått et bedre resultat dersom en hadde benyttet flere og større matriser i banken av linjefiltre. Dersom en har en applikasjon som krever nøyaktig segmentering av vår- og sommersvedområder kan det antagelig også være en del å hente ved å benytte en mer avansert (og mer prosesseringskrevende) metode enn rotasjon av hele bilderegionen samlet og en ren projeksjon i overgangen fra 2D til 1D, samt å optimalisere tersklingsalgoritmen. Sistnevnte ble i stor grad optimalisert for deteksjon av korrekt antall, siden dette viste seg å være et mer robust egenskapsmål enn årringsbredder for å skille mellom marg- og ytesiden til limrelamellene. I denne illustrasjonen ble sektorsegmentet sentrert på margin manuelt. I visse applikasjoner er det antagelig ønskelig å også lokalisere dette punktet automatisk. Å finne en robust metode for dette ville imidlertid føre for langt i denne oppgaven siden denne type anvendelse ligger på siden av hovedfokuset.



# Kapittel 9

## Konklusjon

En har i denne oppgaven sett på ulike metoder for å skille marg- og yteside på uhøvlede limtre lameller for at disse skal kunne vendes korrekt i forkant av sammenliming til limtre bjelker. Limtre bjelkene vil dermed ikke bli så utsatt for sprekke dannelser grunnet kuring. Det har i oppgaven blitt lagt hovedvekt på å skille marg- og ytesiden ved hjelp av en automatisk analyse av årringsmønsteret på de to flatene. Dette på grunn av at trevirket alltid inneholder årringer til forskjell fra en del andre egenskaper en kunne tenke seg, slik som kviststørrelse og marg. Ved å analysere årringene kan en dessuten forutsi hvilken vei lamellen vil kure og er således ikke avhengig av at kuringen allerede har satt igang. Dette til forskjell fra dagens mekaniske systemer som baserer seg på måling av kurevinkel. Metoden gir en større fleksibilitet når det gjelder hvor i limtreproduksjonen deteksjonen skal foregå, ettersom det er mulig å plassere systemet umiddelbart etter skjæring. Dagens mekaniske innretninger er i tillegg avhengige av at lamellen ligger i ro en kort tid mens kuremålingen utføres. Det kamerabaserte systemet en har skissert i denne oppgaven vil kunne utføre målingen i full produksjonshastighet, og vil således åpne mulighetene for å øke produksjonskapasiteten. Dersom margen på en stokk ikke er helt rett, eller utskjæringen ikke gjøres helt parallell med margen, vil hva som er marg- og yteside kunne variere langs lamellens lengderetning (som typisk kan være opptil 6 meter). Siden en med et kamerabasert system vil gjøre samplere langs hele lamellen vil det være lettere å ta hensyn til dette enn med et mekanisk system (der en isåfall må stoppe lamellen flere ganger, ha flere mekaniske kuremålere eller lignende).

I tillegg til de nevnte punktene har det vært en medvirkende motivasjon for å fokusere på årringsanalyse at en robust deteksjon av årringsegenskaper på ubehandlede flater representerer en faglig utfordring [3][4] som kan ha potensiell anvendelse innenfor en rekke andre områder slik som papirproduksjon [3], dendrokronologi, styrkeberegninger, møbelproduksjon, panelproduksjon etc.

Det ble initielt gjort en del labforsøk med å optimalisere bildefangsten og belysningen for å få uniform intensitet over lamellflatene samtidig med at en fikk god kontrast mellom vår- og sommerveden. En fant her at en sylindrisk dombelysning kombinert med et båndpassfilter i det grønne området av lysspekteret ga best resultat av de oppsettene som ble prøvd. Kontrasten mellom vår- og sommervedregionene var imidlertid lav i forhold til den omfattende støyen i bildene, representert ved blant annet opprevete trefibre og skitt. En hadde derfor en betydelig utfordring i forbindelse med bildeanalysen.

Det har blitt fokusert på to prinsipielle hovedretninger for å oppnå en robust diskriminering av marg og yteside. Den ene tilnærmingen har gått ut på å finne en egnet algoritme for å segmentere vårvedsområdene fra sommervedsområdene, og så måle antall årringer og årringsbredder direkte, mens den andre har sett på yte- og margsiden som ulike teksturregioner (texels), og har prøvd å finne teksturmål som kan diskriminere disse mest mulig robust.

Når det gjelder førstnevnte tilnærming har en utviklet en adaptiv filtreringsalgoritme som benytter en filterbank med linjefiltre av typen Laplacian of Gaussian (LoG) der valg av filterstørrelse for en gitt region er estimert utfra hvilket av filterene som gir høyest maksimumsrespons i den vertikalt projiserte linjevektoren. En har videre benyttet et fast antall iterasjoner med probabilistisk relaksasjon [33] [32] som ytterligere bildeforbedringssteg og linking av årringsregioner.

De viktigste bidragene med denne oppgaven har altså vært:

- Den åpner til forskjell fra tidligere systemer muligheten for å detektere hvilken vei en limtrelamell vil kuve tidligere i prosessen – før selve kuvingen har begynt.
- Den gir mulighet for å detektere kuv i fart.
- En vil i motsetning til en enkelt punktmåling kunne detektere endringer i kuvretning langs lamellen og håndtere dette.
- Tester utført i denne oppgaven indikerer at det vil være mulig å oppnå et mer pålitelig estimat på om lamellen skal vendes enn dagens mekaniske systemer, selv om det er vanskelig å trekke noen bastante konklusjoner basert på et så lite antall prøve-eksemplarer – spesielt i en applikasjon der en har så store variasjoner i objektenes utseende som for uhøvlet trevirke.
- Det har i oppgaven blitt fokusert på å redusere datamengden på et tidlig stadium. En har derfor funnet en rask algoritme for å estimere et signal/støy forhold i ulike regioner av limtrelamellene, og kun inkludere de regionene der dette er høyest i videre prosessering.

- En har funnet en robust adaptiv algoritme for å segmentere vår- og som-  
mervedregioner i bilder der disse har lav kontrast og der en har svært mye  
og vesentlig mer kontrastrik støy – først og fremst i form av opprevete trefi-  
bre på grunn av uhøvlede treflater. Algoritmen utnytter apriori kunnskap om  
at årringene er tilnærmet lineære og uniformt orientert i den subregionen en  
ønsker å segmentere for å mer effektivt skille ut årringsmønstrene fra støy.  
Ved eventuelle andre anvendelser av algoritmen må en påse at dette kriteriet  
er oppfylt, eller alternativt transformere dataene slik at det blir oppfylt.
- En har funnet en algoritme som skiller marg- og yteside ved å sammenligne  
teksturen på de to flatene. En har her oppnådd gode resultater med adaptive  
algoritmer som baserer seg på Gray Level Run Length Matrisen.

Studiene gjort i denne oppgaven har avdekket flere lovende metoder for å kunne  
detektere hva som er marg- og yteside på limtrelameller, selv for ubehandlede  
flater. Siden hovedutfordringen i oppgaven besto i å skille årringsmønstrene fra  
opprevete trefibre, som kunne ha vesentlig høyere kontrast, vil en utvilsomt opp-  
nådd en enda mer robust analyse dersom en hadde kunnet endre produksjonspros-  
essen slik at lamellene ble høvlet før de ble analysert. Arbeidet som har blitt gjen-  
nomført i denne oppgaven vil kunne danne grunnlaget for et kostnadsestimat på  
en prototyp utvikling som kan presenteres for Moelven Limtre og eventuelt an-  
dre aktører i bransjen for å bringe dette arbeidet videre til et ferdig kommersielt  
maskinsynsystem.

# Bibliografi

- [1] Wang, Foyn, Albrechtsen: *An automatic tree ring measurement system*, Proc. of IAPR Workshop on Machine Vision Applications, Dec. 13-15, 1994, Kawasaki, Japan, pp. 387-390.
- [2] Kauppinen and Silven: *A color vision approach for grading lumber*, In *Selected Papers from 9th Scandinavian Conference on Image Analysis*"World Scientific Publishing Co Pte Ltd, Singapore, pp. 367-379, 1995.
- [3] X. Wang: *A tree ring measurement system using image analysis*, Thesis, Department of Informatics, University of Oslo, 1994.
- [4] X. Wang: *Computer Vision Algorithms for Measuring Log Quality in the Pulp and Paper Industry*, Dr. Scient Thesis, Department of Informatics, University of Oslo, 1998.
- [5] S. Baheeratan, F. Albrechtsen and H. E. Danielsen: *New Texture Features Based on the Complexity Curve*, *Pattern Recognition* 32, pp. 605-618, 1999.
- [6] F. Albrechtsen: *Statistical Texture Measures Computed from Gray Level Run Length Matrices*, Image Processing Laboratory, Dept. of Informatics, University of Oslo, 1995.
- [7] F. Albrechtsen: *Lecture Notes for the Course of 'Selected Items in Image Processing'*, Dept. of Informatics, University of Oslo, 1992.
- [8] R. H. Falk, K. H. Solli og E. Aasheim: *Styrkeegenskaper til Limtrebjelker fremstilt av Norsk Maskinsortert Gran*, Norsk Treteknisk Institutt, 1992.
- [9] A. Erhardt-Ferron: *Theory and Applications of Digital Image Processing*, University of Applied Sciences Offenburg, 2000.
- [10] J. S. Jimmy Li: *Median Based Feature Selective Filtering*, *SPIE Vol. 1247, Nonlinear Image Processing*, pp. 58-69, 1990.

- [11] R. W. Connors, D. E. Kline, P. A. Araman and R. L. Brisbin: *Reflections on the Development of a Machine Vision Technology for the Forest Products Industry*, Proc. Knowledge Based Expert Systems for the Furniture Industry.
- [12] Kultanen, P., Xu, L., Oja, E.: *Randomized Hough Transform (RHT)* Proceedings 10th International Conference on Pattern Recognition, vol. 1, pp. 631-635, 1990.
- [13] White, Rohrer: *Image thresholding for optical character recognition and other applications requiring character image extraction*, IBM Journal of Research and Development, Vpl. 27, pp. 400-411, 1983.
- [14] T. Ridler and S. Calvard: *Picture Thresholding using an Iterative Selection Method*, IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-8, pp. 630-632, 1978.
- [15] N. Otsu: *A Threshold Selection Method from Gray-Level Histograms*, IEEE Trans. on Systems, Man and Cybernetics, Vol. SMC-9, No.1, pp. 62-66, 1979.
- [16] J. F. Canny: *A computational approach to edge detection*, IEEE Trans. Pattern Analysis and Machine Intelligence, pp. 679-698, 1986.
- [17] J. Bernsen: *Dynamic Thresholding of Grey-level Images* Proc. of the 8th ICPR, Paris, pp 1251-1255, 1986.
- [18] Hancock, Kittler: *Relaxational Refinement of Intensity Ridges*, Proc. 11th IAPR International Conference of Pattern Recognition, Los Alamitos, Calif., Vol 3 pp. 459-463, 1992.
- [19] William K. Pratt: *Digital Image Processing*, Wiley Interscience 1991.
- [20] R. C. Gonzales, R. E. Woods: *Digital Image Processing*, Addison-Wesley Publishing Company Inc., 1992.
- [21] Svein Bøe, Tor Lønnestad and Otto Milvang: *Xite User's Manual*, Report no. 56, Image Processing Laboratory, Department of Informatics, University of Oslo, 1998.
- [22] F. F. P. Kollman and W. A. Cote: *Principles of Wood Science and Technology*, Springer-Verlag, Germany, 1968.
- [23] T. Lønnestad: *Connected Filters for Noise Removal*, Proc. of 9. ICPR, Rome, pp. 848-850, 1988.

- [24] N. I. Bovim og H. Sund: *Limtreboka*, Moelven Limtre A/S, 1984.
- [25] M. Petrou: *Optimal convolution filters and an algorithm for the detection of wide linear features*, IEE PROCEEDINGS-I, Vol. 140, No. 5, pp. 331-339, 1993.
- [26] I.J. Cox, R.A. Boie, D.A. Wallach: *Line Recognition*, IEEE, pp. 639-645, 1990.
- [27] A. Erhardt-Ferron: *Theory and Applications of Digital Image Processing*, University of Applied Sciences Offenburg, 2000.
- [28] M. Frellumstad: *Segmentering av store arterier i sekvenser MR-bilder og beregning av blodflyt*, Hovedfagsoppgave, Institutt for Informatikk, Universitetet i Oslo, 2000.
- [29] M. Heath, S. Sarkar, T. Sanocki, K. Bowyer: *Comparison of edge detectors*, Computer Vision and Image Understanding, Vol. 69, No. 1, January, pp. 38-54, 1998.
- [30] M. Heath, S. Sarkar, T. Sanocki, K. Bowyer: *A Robust Visual Method for Assessing the Relative Performance of Edge-Detection Algorithms*, IEEE Transactions on Pattern Recognition and Machine Intelligence, Vol. 19, No. 12, pp. 1338-1359, 1997.
- [31] I.T. Young, L.J. van Vliet: *Recursive Gaussian Filtering*, Proceedings of The 9th Scandinavian Conference on Image Analysis, Vol. 1, pp. 333-340, 1995.
- [32] A. Rosenfeld, A. Hummel, S.W. Zucker: *Scene labeling by relaxation operations*, ZEEE trans. Syst., Man Cybern., V SMC-6, pp. 420-433, 1976
- [33] A. Rosenfeld, *Digital Picture Processing*, New York: Academic Press, 1976.
- [34] O. Monga, S. Benayoun: *Modelling surfaces from 3D images using hypersurfaces in  $R^4$* , Proceedings of The 8th Scandinavian Conference on Image Analysis, pp. 41-48, 1993.
- [35] N. Armande, P. Montesinos, O. Monga: *Thin Nets Extraction Using A Multi-Scale Approach*, Proceedings of The 10th Scandinavian Conference on Image Analysis, Vol. II, pp. 893-900, 1997.
- [36] O. Monga, R. Lengagne, R. Deriche: *Crest lines extraction in volume 3D medical images: a multiscale approach*, Proceedings of The 12th IAPR Conference on Pattern Recognition, Vol. I, Conference A: Computer Vision & Image Processing, pp. 553-555, 1994.

- [37] R. Lengagne, P. Fua, O. Monga: *Using Crest lines to guide Surface Reconstruction from Stereo*, Proceedings of The 13th International Conference on Pattern Recognition, Vol. I, Track A: Computer Vision, pp. 9-13, 1996.
- [38] D. Marr, E. Hildreth: *Theory of edge detection*, Proc. Royal Society of London, Vol. B207, Pt. B, pp. 187-217, 1980.
- [39] E. R. Hancock, J. Kittler: *Edge-Labeling Using Dictionary-Based Relaxation*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 12, No. 2, pp. 165-181, 1990.
- [40] S. Tronstad: *Tre og fuktighet - fra produsent til forbruker*, Norsk Treteknisk Institutt, Teknisk småskrift nr. 35, 2001.
- [41] D. Waaler, Ø. Dahle: *Object Illumination and Optics for Machine Vision*, Impro Industrial Image Processing Course Module 3.3, COMETT, 1995.
- [42] C. Wählby, J. Lindblad, M. Vondrus, E. Bengtsson, L. Björkesten: *Algorithms for Cytoplasm Segmentation of Fluorescence Labeled Cells*, Analytical Cellular Pathology, 24, pp. 101-111, 2002.
- [43] L. Vincent, P. Soille: *Watersheds in digital spaces: An efficient algorithm based on immersion simulations*, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 13, No. 3, pp. 583-597, 1991.
- [44] M.M. Galloway: *Texture analysis using gray level run lengths*, Computer Graphics and Image Processing 4(1975) 172-179.
- [45] O.D. Faugeras, W.K. Pratt: *Decorrelation Methods of Texture Feature Extraction*, IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-2, 4, pp. 323-332, 1980.
- [46] L. Yang, F. Albrechtsen: *Fast and Exact Computation of Cartesian Geometric Moments using Discrete Green's Theorem* Pattern Recognition, Vol. 29, No. 7, pp. 1061-1073, 1996.
- [47] B. Nielsen, F. Albrechtsen, H.E. Danielsen: *Low Dimensional Adaptive Texture Feature Vectors From Class Distance and Class Difference Matrices*, IEEE Transactions on Medical Imaging, Vol. 23, No. 1, pp. 73-84, 2004.
- [48] F. Albrechtsen, B. Nielsen: *Texture Classification based on Cooccurrence of Gray Level Run Length Matrices*, Australian Journal og Intelligent Information Processing Systems, 6 (1), pp. 38-45, 2000.

- [49] M. Unser: *Sum and difference histograms for texture classification*, IEEE PAMI, 8, pp. 118-125, 1986.
- [50] R. M. Haralick, K. Shanmugam, I. Dinstein: *Textural features for image classification*, IEEE SMC, 3, pp. 610-621, 1973.
- [51] B.D. Ripley: *Pattern Recognition and Neural Networks*, Cambridge University Press, 1996.
- [52] T.M. Mitchell: *Machine Learning*, McGraw-Hill International Editions, 1997, ISBN 0-07-115467-1.
- [53] H. Schulerud, F. Albrechtsen: *Many are called but few are chosen. Feature selection and error estimation in high dimensional spaces*, Computer Methods and Programs in Biomedicine, 73, pp. 1061-1073, 2004.
- [54] T.M. Cover: *The best two independent measurements are not the two best*, IEEE Trans. Syst. Man Cybern. 4, pp. 116-117, 1974.
- [55] A. Jain, D. Zongker: *Feature selection: evaluation, application, and small sample performance*, IEEE Trans. Pattern Anal. Mach. Intell. 19 (2), pp. 153-158, 1997.
- [56] A. Whitney: *A direct method of nonparametric measurement selection*, IEEE Trans. Comput. 20, pp. 1100-1103, 1971.
- [57] T. Marill, D.M. Green: *On the effectiveness of receptors in recognition systems*, IEEE Trans. Inf. Theory 9, pp. 11-17, 1963.
- [58] S.D. Stearns: *On selecting features or pattern classifiers*. Proceedings of Third International Conference on Pattern Recognition, pp. 71-75, 1976.
- [59] P.M. Narendra and K. Fukunaga: *A Branch and Bound Algorithm for Feature Subset Selection*, IEEE Trans. Computers, vol. 26, no. 9, pp. 917-922, 1977.
- [60] P. Pudil, J. Novovicova, and J. Kittler: *Floating Search Methods in Feature Selection*, Pattern Recognition Letters, vol. 15, pp. 1,119-1,125, 1994.
- [61] M. Kass and A. Witkin and D. Terzopoulos: *Snakes: Active Contour Models*, Proc. of Intern. Conf. on Comp. Vision, pp. 259-268, 1987.
- [62] P. Radeva, J. Serrat, E. Marti: *A snake for model-based segmentation* Computer Vision, 1995. Proceedings., Fifth International Conference on 20-23 June, pp. 816 - 821, 1995.




- [63] Ø.D. Trier, A.K. Jain, *Goal-directed evaluation of binarization methods* Pattern Analysis and Machine Intelligence, IEEE Transactions on Volume 17, Issue 12, pp. 1191 - 1201, 1995.


# **Appendikser**

# Appendiks A


## Bildemateriale



Figur A.1: Prøve 1. Yteside t.v. og margside t.h.




Figur A.2: Prøve 2. Yteside t.v. og margside t.h.




Figur A.3: Prøve 3. Yteside t.v. og margside t.h.




Figur A.4: Prøve 4. Yteside t.v. og margside t.h.




Figur A.5: Prøve 5. Yteside t.v. og margside t.h.




Figur A.6: Prøve 6. Yteside t.v. og margside t.h.




Figur A.7: Prøve 7. Yteside t.v. og margside t.h.




Figur A.8: Prøve 8. Yteside t.v. og margside t.h.




Figur A.9: Prøve 9. Yteside t.v. og margside t.h.




Figur A.10: Prøve 10. Yteside t.v. og margside t.h.




Figur A.11: Prøve 11. Yteside t.v. og margside t.h.




Figur A.12: Prøve 12. Yteside t.v. og margside t.h.




Figur A.13: Prøve 13. Yteside t.v. og margside t.h.



Figur A.14: Prøve 14. Yteside t.v. og margside t.h.




Figur A.15: Prøve 15. Yteside t.v. og margside t.h.




Figur A.16: Prøve 16. Yteside t.v. og margside t.h.







Figur A.17: Prøve 17. Yteside t.v. og margside t.h.




Figur A.18: Prøve 18. Yteside t.v. og margside t.h.




Figur A.19: Prøve 19. Yteside t.v. og margside t.h.




Figur A.20: Prøve 20. Yteside t.v. og margside t.h.




Figur A.21: Prøve 21. Yteside t.v. og margside t.h.




Figur A.22: Prøve 22. Yteside t.v. og margside t.h.




Figur A.23: Prøve 23. Yteside t.v. og margside t.h.




Figur A.24: Prøve 24. Yteside t.v. og margside t.h.




Figur A.25: Prøve 25. Yteside t.v. og margside t.h.




Figur A.26: Prøve 26. Yteside t.v. og margside t.h.



Figur A.27: Prøve 27. Yteside t.v. og margside t.h.



Figur A.28: Prøve 28. Yteside t.v. og margside t.h.



Figur A.29: Prøve 29. Yteside t.v. og margside t.h.

# Appendiks B

## Manuelt målt avstand til marg

Manuelt målt avstand til marg fra yte- og margside(overfl. 1 og 2)

Prøve	Avstand til marg [mm]	
	O1	O2
1	>45	?
2	43	2
3	42	3
4	>45	?
5	40	0
6	>40	?
7	38	-2
8	>40	?
9	>40	?
10	35	-5
11	28	-12
12	40	0
13	>40	?
14	30	-10
15	>40	?
16	>40	?
17	35	-5
18	40	0
19	40	0
20	>40	?
21	>40	?
22	>40	?
23	35	-5
24	39	-1
25	>40	?
26	40	0
27	>40	?
28	25	-15
29	23	-17

\* For disse prøvene befant margin seg utenfor lamellen og kunne derfor ikke måles