



Norges miljø- og  
biovitenskapelige  
universitet

Masteroppgave 2018 30 stp  
Fakultet for realfag og teknologi

# **Klassifisering av treslag i urbane områder med multispektral laserskanning**

Classifying tree species in urban areas using  
multispectral laser scanning

Håkon Berg Lofthus  
Geomatikk



## Forord

Denne oppgaven markerer avslutningen på mitt liv som student ved Norges miljø- og biovitenskapelige universitet i Ås. Jeg ønsker først og fremst å takke Floris Groesz, min veileder hos Blom, for all hjelp og støtte underveis i prosessen. Det har blitt noen timer med samtaler på hans kontor. Jeg vil også rette en takk til alle i Blom for at jeg fikk skrive oppgaven hos dere og for all hjelpen jeg har fått. En spesiell takk går til Stian Rostad og Luis Barreiro som har holdt ut med mine stadige spørsmål, dere har vært til uvurderlig hjelp.

En takk rettes til min veileder ved NMBU Ivar Maalen-Johansen for stødig veiledning der det har vært behov for det. Videre vil jeg takke Oslo kommune for å få bruke dataene deres. Jeg vil også takke Hans Ole Ørka ved fakultet for miljøvitenskap og naturforvaltning på NMBU for viktige innspill til oppgaven.

Til slutt vil jeg takke min kjære samboer Annie Samuelsen for å ha hjulpet meg til å holde motivasjonen oppe gjennom et langt semester og for å inspirere meg til å yte mitt aller beste.



## Sammendrag

I denne oppgaven blir muligheten til å bruke multispektral laserdata for å klassifisere treslag i urbane områder undersøkt. Det ble også undersøkt om multispektral laserskanning gir et bedre resultat enn tradisjonell en-kanals laserskanning. Et datasett over Oslo fra en Optech Titan laserskanner ble benyttet. Fra dette datasettet ble det valgt ut et mindre testområde som strakte seg over Tøyen, Grønland og Kampen. Innenfor testområdet var det 1308 registrerte trær, i hovedsak løvtrær.

Punktskyen ble brukt til å generere en kronehøydmodell. Denne ble så brukt til segmentering for deteksjon av enkelttrær. For de enkelte segmentene ble det beregnet en rekke statistiske mål i punktskyen. Statistikken ble kombinert med fasisdatasettet som ble brukt til å trene og validere en klassifiseringsmodell. Utvelgelsen av trenings- og valideringsdata ble gjort ved å bruke kryssvalidering. Nevralnettverk var den klassifiseringsmodellen som gjennomgående ga det beste resultatet.

65% av fasistrærne ble korrekt detektert i segmenteringsprosessen. Den beste klassifiseringen oppnådde en total nøyaktighet på 77.11% med kappa på 0.68 for de fire treslagene Eik, Kirsebær, Lind og Lønn. Både klassifisering med tre og to kanaler var signifikant bedre enn klassifisering med kun en kanal. Tre kanaler var imidlertid ikke signifikant bedre enn to kanaler. Klassifiseringer med bruk av ulike egenskaper viste at relative intensitetsmål ikke ga signifikant forskjell fra å bruke rå intensitet. Resultatene indikerer også at klassifiseringsnøyaktigheten påvirkes av antall sampler. Når det blir færre sampler per klasse går klassifiseringsnøyaktigheten ned samtidig som variasjonen øker.

Resultatene viser at multispektral laserskanning gir et godt resultat ved klassifisering av trær i urbane områder og at resultatet er signifikant bedre enn tradisjonell en-kanals laserskanning.



## Abstract

This thesis investigated the possibility of using multispectral laser scanning to classify tree species in urban areas. It was also investigated if multispectral laser scanning performed better than traditional laser scanning that use only one channel. A dataset over Oslo, acquired by an Optech Titan scanner, was used. From this dataset a smaller one was chosen, which spanned the areas of Tøyen, Grønland and Kampen. The test area contained 1308 registered trees, mainly deciduous.

The point cloud was used to generate a canopy height model. The canopy height model was then used to detect individual trees using segmentation techniques. For each segment several statistical features were calculated from the point cloud. These statistics were then combined with the data for the registered trees and used to train and validate a classification model. The selection of training and validation data was done using cross validation. Neural network was the classification model that consistently gave the best results.

65% of the registered trees were correctly detected during the segmentation process. The best classification achieved an overall accuracy of 77.11% with a kappa of 0.68 for the four tree species Oak, Cherry, Linden and Maple. Classification with both three and two channels was significantly better than using only one channel. However, using three channels was not significantly better than using two. Classification with different features showed that relative intensity did not significantly improve the result compared to raw intensity. The results also indicate that the number of samples affects the accuracy of the classification. When there is fewer samples for each tree species the accuracy of the classification drops, and the variation rises.

Overall the results from this thesis suggest that using multispectral laser scanning for classification of tree species in urban areas produces good results, and that it is significantly better than using traditional laser scanning with one channel.





# Innholdsfortegnelse

1	Figurer.....	ix
2	Tabeller .....	xi
3	Formler.....	xii
4	Innledning .....	1
4.1	Bakgrunn .....	1
4.2	Problemstilling.....	1
4.3	Tidligere forskning .....	2
5	Teori.....	4
5.1	LiDAR (Light Detection and Ranging).....	4
5.2	Flybåren laserskanning .....	5
5.3	Multispektral LiDAR.....	8
6	Data .....	10
6.1	Optech Titan .....	10
6.2	Testområdet .....	12
6.3	Datainnsamling.....	17
6.4	Fasitdata.....	18
7	Programvare .....	19
8	Metode .....	21
8.1	Kontroll av dataene.....	22
8.2	Fjerning av stripeoverlapp .....	23
8.3	Høydenormalisering og kronehøydemodell .....	24
8.4	Segmentering .....	27
8.5	Statistikk .....	32
8.6	Klassifisering .....	34
8.7	Evaluering av nøyaktighet .....	38
9	Resultater .....	42

9.1	Segmentering .....	42
9.2	Klassifisering av treslag.....	42
9.3	Forskjellig antall kanaler og egenskaper .....	44
9.4	Påvirkning av antall sampler .....	46
10	Diskusjon.....	47
11	Konklusjon .....	50
12	Referanseliste .....	51
13	Vedlegg .....	53

# 1 Figurer

Figur 5.1. Stråledivergens .....	5
Figur 5.2. Flybåren laserskanning(Vosselman & Maas 2010).....	5
Figur 5.3. Oscillerende speil (Vosselman & Maas 2010) .....	6
Figur 6.1. Bølgelengder Optech Titan (Optech 2015) .....	10
Figur 6.2. Oversiktsbilde over testområdet .....	12
Figur 6.3. Intensitet MIR-kanal.....	13
Figur 6.4. Intensitet NIR-kanal .....	13
Figur 6.5. Intensitet G-kanal .....	14
Figur 6.6. Gatetrær .....	14
Figur 6.7. Allétrær.....	15
Figur 6.8. Liten park.....	15
Figur 6.9. Større park .....	16
Figur 6.10. Trær i bygård .....	16
Figur 6.11. Treklynger .....	17
Figur 6.12. Kartutsnitt skanneblokk.....	18
Figur 8.1. Oversikt databehandling .....	21
Figur 8.2. Mønster i dataene.....	22
Figur 8.3. G-kanalen går ikke like langt ut til sidene som MIR- og NIR-kanalen.....	23
Figur 8.4. Laserpulser og returer fra fire flylinjer (Isenburg 2016) .....	25
Figur 8.5. Interpolering av alle første returer (Isenburg 2016) .....	25
Figur 8.6. Interpolering av alle relevante returer (Isenburg 2016).....	26
Figur 8.7. Utsnitt av generert CHM .....	26
Figur 8.8. Bygninger som er helt eller delvis dekket av trær .....	27
Figur 8.9. Hull i trær forårsaket av bygninger.....	28
Figur 8.10. Segmenter før og etter manuell redigering .....	29
Figur 8.11. Google Street View bilde av trærne i figur 8.10.....	29
Figur 8.12. Flybilde fra 1881.no av trærne i figur 8.10.....	30
Figur 8.13. Feilsegmentering .....	30
Figur 8.14. Visuell kontroll av trær fra figur 8.13.....	31
Figur 8.15. Systematisk forskyvning av bytrær .....	31
Figur 8.16. Bincentiler (Herries 2014) .....	33
Figur 8.17. Høydepercentiler (Herries 2014).....	33

Figur 8.18. Klassifiseringsprosessen.....	36
Figur 8.19. To ganger to forvirringsmatrise (Foody 2004).....	40
Figur 9.1. Nøyaktighet ved forskjellige antall sampler per klasse.....	46

## 2 Tabeller

Tabell 6.1. Spesifikasjoner Optech Titan (Optech 2015).....	11
Tabell 8.1. Statistiske mål fra lascanopy.....	32
Tabell 8.2. Originale og aggregerte artsnavn.....	34
Tabell 8.3. Antall trær i hver klasse.....	35
Tabell 8.4. Grad av enighet (Viera & Garrett 2005).....	39
Tabell 9.1. Forvirringsmatrise og nøyaktighetsevaluering for 8 treslag.....	43
Tabell 9.2. Forvirringsmatrise og nøyaktighetsevaluering for 6 treslag.....	43
Tabell 9.3. Forvirringsmatrise og nøyaktighetsevaluering for 4 treslag.....	44
Tabell 9.4. Forskjell i nøyaktighet med forskjellige antall kanaler.....	44
Tabell 9.5. McNemar test på forskjellige antall kanaler. Tall markert med * indikerer signifikant forskjell på 5% nivå.....	45
Tabell 9.6. Nøyaktighet med forskjellige egenskaper.....	45
Tabell 9.7. McNemar test på forskjellige kombinasjoner av egenskaper. Tall markert med * indikerer signifikant forskjell på 5% nivå.....	45

### 3 Formler

Formel 5.1. Avstandsmåling (Vosselman & Maas 2010) .....	4
Formel 5.2. Tidsforsinkelse fra faseforskjell (Vosselman & Maas 2010) .....	4
Formel 5.3. Diameter til fotavtrykket til laserpulsen (Vosselman & Maas 2010) .....	6
Formel 5.4. Intensitetskalibrering (Yu et al. 2017) .....	8
Formel 8.1. Spektralindekser (Teo & Wu 2017).....	34
Formel 8.2. Ratioer.....	34
Formel 8.3. Utregning av kappa koeffisient (Viera & Garrett 2005).....	39
Formel 8.4. Forventet nøyaktighet .....	39
Formel 8.5. McNemar (Foody 2004) .....	40

## 4 Innledning

### 4.1 Bakgrunn

De siste årene har vi sett et stadig større fokus på klimaendringer og bærekraftig utvikling. En viktig del av arbeidet mot et mer miljøvennlig og bærekraftig samfunn er grønne byer. Stadig flere byer legger frem handlingsplaner for grønn utvikling. Oslo ble i fjor kåret til europeisk miljøhovedstad for 2019. Denne prisen deles ut til en europeisk by som har forpliktet seg til å forbedre miljøpolitikken sin. Et av satsningsområdene til Oslo kommune er å sørge for gode grøntarealer. Trær og vegetasjon gjør ikke bare byen grønnere og triveligere, det hjelper også til å gjøre Oslo mer robust overfor klimaendringer. Ved å bruke data samlet inn av Oslo kommune ønsker firmaet Blom å se på metoder for å kartlegge trærne i byen.

En-kanals flybåren laserskanning har lenge spilt en viktig rolle i tradisjonell skogforvaltning. Laserdata har blitt brukt til å estimere skogparametere som høyde, volum og treslag. På grunn av mangelen på spektral informasjon har imidlertid ikke en-kanals laserskanning vært mye brukt til klassifisering av treslag på et individuelt nivå. En kombinasjon av laserdata og multispektral informasjon fra flybilder har vist seg å øke nøyaktigheten til klassifiseringen av enkelttrær. Å kombinere laserdata med flybilder er imidlertid utfordrende, i tillegg er det kostbart å gjøre målinger med to sensorer. Det er her flybåren multispektral laserskanning kommer inn som en ny og spennende mulighet. Multispektral laserskanning skanner på flere forskjellige kanaler, noe som gjør at man får informasjon om refleksjonen til objekter på forskjellige bølgelengder i tillegg til punktsky data. Dette gjør at flybåren multispektral laserskanning i teorien vil ha potensial til å kunne klassifisere treslag med bedre nøyaktighet enn tradisjonell en-kanals laserskanning.

### 4.2 Problemstilling

Problemstillingen i denne oppgaven er å se om multispektral laserskanning kan benyttes til klassifisering av treslag i urbane områder. Nøyaktigheten til klassifiseringen vil bli vurdert, samt om bruken av multispektrale laserdata gir et bedre resultat i forhold til tradisjonelle laserdata.

### 4.3 Tidligere forskning

Multispektral flybåren laserskanning er en relativt ny teknologi og det finnes foreløpig lite forskning på å bruke dataene til klassifisering av treslag. Men man kan forvente at det vil komme stadig nye studier på dette området i nærmeste framtid.

Tidligere studier har vist at man kan bruke tradisjonell en-kanals laserskanning til å klassifisere ulike typer trær (Holmgren & Persson 2004; Ørka et al. 2009). Holmgren & Persson viste at det var mulig å klassifisere furu og gran med en klassifiseringsnøyaktighet på 95%, kun ved å bruke strukturegenskaper utledet fra punktskyen. Ved å også ta i bruk intensitet klassifiserte Ørka et al. gran og bjørk med en klassifiseringsnøyaktighet på 88.6% for store trær og 63.6% for små trær. Andre har forsøkt å kombinere laserdata med multispektrale flybilder for å kompensere for manglende spektral informasjon (Dalponte et al. 2012; Holmgren et al. 2008). Holmgren et al. oppnådde en klassifiseringsnøyaktighet på 96% ved klassifisering av furu, gran og bjørk. Mens Dalponte et al. fikk en kappa nøyaktighet på 0.86 med sju ulike treslag. De testet også ut en kombinasjon av hyperspektrale bilder og laserdata. Det ga en kappa nøyaktighet på 0.93.

Etter at Optech lanserte verdens første multispektrale laserskanner, Optech Titan i 2014, har det kommet flere studier som skulle teste ut denne nye teknologien. I 2016 ble Optech Titan brukt til å klassifisere gran, furu og bjørk med klassifiseringsnøyaktighet på 93.5%. Ved å bare ta i bruk intensitet oppnådde de en klassifiseringsnøyaktighet på 91%. De viste også at det er potensial til å ytterligere klassifisere løvtrær til flere tresorter (Ahokas et al. 2016). Senere viste en annen studie med samme testområde som Ahokas et al. at 61.3% av feltrær ble korrekt detektert. Også her ble gran, furu og bjørk klassifisert. Den beste klassifiseringsnøyaktigheten ble på 85.9% med kappa verdi på 0.75 ved bruk av data utledet fra punktskyen og intensitet fra en kanal. Dette ga ikke signifikant forskjell fra klassifiseringene ved bruk av alle egenskaper (klassifiseringsnøyaktighet 85.6%, kappa 0.75) og intensitet fra kun en kanal (klassifiseringsnøyaktighet 85.4%, kappa 0.75) (Yu et al. 2017). For klassifisering av gran, furu og løv ble det oppnådd en klassifiseringsnøyaktighet på 82.3% (Rostad 2017). Felles for alle disse studiene er imidlertid at de ble utført i skogsområder og med et begrenset antall klasser.

En studie fra 2017 ble utført med et datasett fra en forstad til Toronto, Canada. En av få studier om dette temaet som er blitt utført i et urbant område. Der fikk de klassifiseringsnøyaktigheter som varierte fra 78.9% - 91.6% for treslagene lønn, gran, ask og korstorn (Budei et al. 2017). Dette var en av de første studiene som klassifiserte flere ulike typer løvtrær. En nylig utgitt studie fra 2018 har gjort klassifisering med så mange som ni treslag, sju sorter av løvtrær og to



sorter av bartrær. En total klassifiseringsnøyaktighet på 76.5% ble oppnådd, og med nøyaktigheter som varierte fra 47 – 100% for de individuelle treslagene. De har imidlertid relativt få feltmålte trær per klasse, fra 5 – 38 trær per klasse og har kun brukt trær som står for seg selv (Axelsson et al. 2018).

## 5 Teori

### 5.1 LiDAR (Light Detection and Ranging)

LiDAR står for Light Detection and Ranging og er en metode for å måle avstander ved hjelp av laserlys. Metoden baserer seg på at man estimerer den såkalte lystiden. Dette er også kjent som time-of-flight. En egenskap ved lys er at den beveger seg med konstant hastighet i et gitt medium. Ved å måle tidsforskjellen fra en laserpuls blir sendt ut til den reflekteres tilbake kan man regne ut avstanden til det reflekterende objektet.

$$\rho = \frac{c}{n} * \frac{\tau}{2}$$

*Formel 5.1. Avstandsmåling (Vosselman & Maas 2010)*

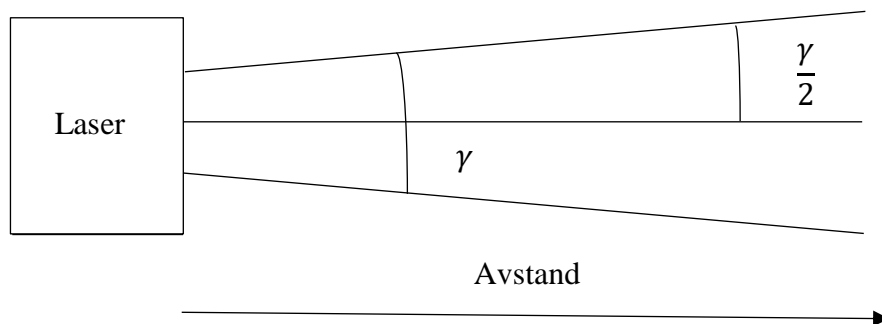
$\rho$  er avstanden fra lyskilden til overflaten.  $c$  står for lyshastigheten i vakuum. Siden laserpulsene ikke går i vakuum må det legges på en korreksjonsfaktor  $n$ . For luft er denne faktoren lik refraksjonsindeksen som er avhengig av luftfuktigheten, trykk og temperatur.  $\tau$  er tidsforskjellen mellom utsendt og mottatt signal. Ved å dele på to får man avstanden fra kilden til overflaten. Time-of-flight kan også realiseres ved målinger på laserpulsens fase. Det sendes ut et kontinuerlig signal hvor man måler faseforskjellen mellom den utsendte og den mottatte laserpulsene. Faseforskjellen  $\Delta\varphi$  mellom bølgeformene gir tidsforskjellen:

$$\tau = \frac{\Delta\varphi}{2\pi} * \frac{\lambda}{c}$$

*Formel 5.2. Tidsforsinkelse fra faseforskjell (Vosselman & Maas 2010)*

$\lambda$  er bølgelengden til signalet. Avstanden kan deretter finnes ved å benytte formelen for avstandsmåling.


På grunn av diffraksjonen som oppstår når lyset beveger seg gjennom lufta klarer ikke laserpulsene å opprettholde lik spredning over en distanse. Desto lengre det er fra lyskilden til objektet desto større vil spredningen til laserpulsene bli. Denne spredningen kalles stråledivergensen  $\gamma$ .



Figur 5.1. Stråledivergens

## 5.2 Flybåren laserskanning


Flybåren laserskanning består av to hovedkomponenter. Et LIDAR-system og en kombinasjon av Global Navigation Satellite System (GNSS) og Inertial Measurement Unit (IMU) for å måle nøyaktig posisjon og orientering til systemet. Ved å kjenne posisjonen og orienteringen til systemet kan man bestemme den absolute posisjonen til de lasermålte punktene på bakken.



Figur 5.2. Flybåren laserskanning(Vosselman & Maas 2010)

Hver sensor har sitt eget koordinatsystem og for å korrekt kunne integrere dataene fra de forskjellige sensorene kreves det at man kjenner offseten mellom sensorene. Et koordinatsystem for plattformen blir bestemt hvor vektorene, også kjent som lever-arm, fra sensorene til origo blir målt ved landmåling. Man må også utføre tidssynkronisering mellom sensorene. Dette oppnås med PPS (puls per sekund) signalet til GNSS som korrigerer de interne klokken til laserskanner og IMU. Tidsstempler blir brukt for å knytte avstandsmålingene til flyets posisjon.

For å oppnå en tett samplet tredimensjonal overflate med en enkelt laserstråle kreves det en skannermekanisme til å bevege laserstrålen over overflaten. Det finnes flere metoder for dette, Optech Titan benytter seg av et såkalt oscillerende speil. Et oscillerende speil beveger seg fram og tilbake og generer et sikk-sakk mønster på bakken. Avstanden mellom punktene på bakken langs skannelinjen varierer siden speilet konstant akselererer og bremser ned. Dette fører til at det blir kort avstand mellom punktene i ytterkant av skannerlinjene og større avstand i midten av linja. Bruk av oscillerende speil fører også til at punkttettheten blir større i sveiperetningen enn i flyretningen. Forhold under flyvningen eller feil i flyplanleggingen kan føre til at avstanden  $dy$  mellom skannelinjene blir så stor at objekter enten blir mangelfullt representert eller ikke kommer med i det hele tatt.



Figur 5.3. Oscillerende speil (Vosselman & Maas 2010)


En fordel med oscillerende speil er at skannevinkelen og skanneraten er variabel. Dette gjør det enklere å konfigurere skanneren for å møte oppdragsspesifikke krav (Vosselman & Maas 2010).

Størrelsen til laserpulsene utvider seg med avstanden fra laserskanneren. Formel 5.3 beskriver størrelsen til fotavtrykket til laserpulsene på bakken.

$$D = 2h \times \tan\left(\frac{\gamma}{2}\right)$$


Formel 5.3. Diameter til fotavtrykket til laserpulsene (Vosselman & Maas 2010)

Hvor  $\gamma$  er stråledivergensen og  $h$  er høyden over bakken.



Figur 5.4. Fotavtrykket til en laserpuls (Vosselman & Maas 2010)

Egenskaper og orienteringen til overflaten kan føre til at laserpulsene splittes opp i flere returpulser. Dette er spesielt når den reflekterende overflaten er vegetasjon. For et tre vil den første returen som regel være fra toppen av treet, mens de neste vil være fra steder lenger ned i treet. Den siste returen kan være fra bakken under treet, gitt at laserpulsene faktisk klarer å penetrere helt ned til bakken.



Figur 5.5. Multiple returer (Vosselman & Maas 2010)

For å kunne skille to returnerte pulser fra hverandre er man avhengig av at avstanden mellom dem er større enn halve pulslengden. Det vil si at for en laserpuls med pulsbredde på 5 ns må objekter være mer enn 0.75 m fra hverandre for at det skal være mulig å skille dem fra hverandre (Vosselman & Maas 2010).

### 5.3 Multispektral LiDAR


Tradisjonelt har LiDAR systemer sendt ut laserpulser på en bølgelengde. De siste årene har det kommet nye systemer som skanner på flere bølgelengder samtidig, såkalt multispektral laserskanning. Dette gir mulighet til å få spektralinformasjon om skannede objekter i uavhengige kanaler (Bakuła 2015). I en slik sensor spiller intensiteten en viktig rolle. Intensiteten er mengden av energi som blir reflektert tilbake til laserskanneren. Mengden energi som returneres til laserskanneren er en funksjon av flere variabler, blant annet atmosfærisk transmisjon, vanndamp, egenskaper ved den reflekterende overflaten (reflektans, tekstur, osv.) og oppdrags- og instrumentparametere (Yu et al. 2017). For å kompensere for de nevnte faktorene kan det være nødvendig å utføre en kalibrering av intensitetsverdiene slik at man oppnår et bedre resultat ved klassifisering. Yu et al. 2017 bruker en simplifisert modell for intensitetskalibrering.

$$I_C = I * \left(\frac{R}{R_S}\right)^{eksp}$$

Formel 5.4. Intensitetskalibrering (Yu et al. 2017)

$I_C$  er den normaliserte intensiteten,  $I$  er den rå intensiteten,  $R$  er avstanden fra laserskanneren til overflaten og  $R_S$  er gjennomsnittlig flyhøyde. Eksponential faktoren velges ut ifra hvilken type overflate som skal skannes. I denne oppgaven ble det ikke utført kalibrering av intensitetsverdiene. Delvis på grunn av mangel på tid og delvis på grunn av at dataene manglet informasjon som var nødvendig for å utføre kalibreringen.

Materialer reflekterer ulike intensiteter for forskjellige utsendte bølgelengder.



Figur 5.6. Spektralsignaturer til forskjellige materialer (Pfennigbauer & Ullrich 2011)

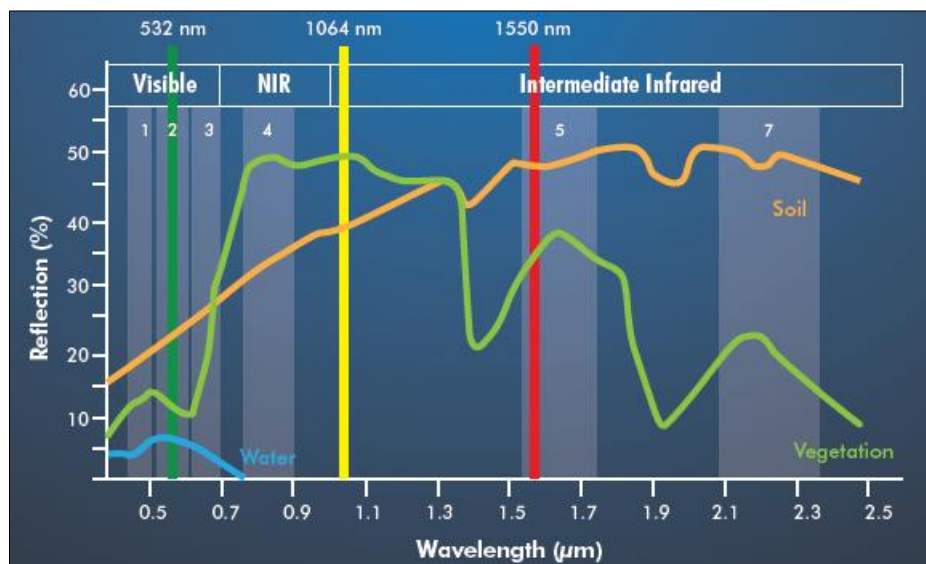
Ut i fra figur 5.6 ser man at det er store forskjeller i reflektans mellom forskjellige typer materialer for ulike bølgelengder. Returnert intensitet for en kanal gir ikke nok informasjon til å klassifisere objekter, men ved å se på forskjellen i returnert intensitet mellom flere kanaler kan objekter klassifiseres. Andre fordeler med å bruke flere kanaler er at det er mulig å få data i områder som ikke kan måles med bare en bølgelengde. Materialer som har lav reflektans i en bølgelengde kan være reflekterende i en annen (Pfennigbauer & Ullrich 2011).

## 6 Data

### 6.1 Optech Titan

Optech Titan ble lansert av firmaet Teledyne Optech i 2014 og var verdens første multispektrale flybårne laserskanner. Skanneren består av tre separate kanaler som skanner samtidig på hver sine bølgelengder, henholdsvis kortbølge infrarød (MIR, 1550 nm), nær infrarød (NIR, 1064 nm) og grønn (G, 532 nm). Titan kan lagre både diskrete signal og full bølgeform for alle tre kanalene. De tre kanalene står i forskjellige vinkler i forhold til nadir. MIR er vinklet 3,5° framover, NIR er vinklet rett ned og grønn (G) er vinklet 7° framover. Dette fører til at laserpunktene i de ulike kanalene ikke treffer det samme punktet på bakken, og man kan dermed ikke direkte relatere intensitetsverdiene fra kanalene til hverandre.

Ved å ta i bruk flere kanaler muliggjør Titan at man i tillegg til å utføre topografisk kartlegging også kan utføre batymetrisk kartlegging (dette er hovedgrunnen til at de har valgt å bruke den grønne kanalen), vegetasjonskartlegging og klassifisering av overflater og materialer. Ulike materialer reflekterer og absorberer ulike bølgelengder av lys forskjellig. Ved å sammenligne forskjeller i returnert intensitet for de tre kanalene er det mulig å skille mellom ulike typer materialer.



Figur 6.1. Bølgelengder Optech Titan (Optech 2015)



Figur 6.1 viser spektralsignaturen til vann, vegetasjon og jord. Titan kanalene er også tegnet inn slik at man ser hvor mye refleksjon man forventer å få fra disse når de treffer de aktuelle materialene. Ut i fra figur 6.1 kan man se at det er stor forskjell i hvor mye refleksjon man får fra vegetasjon i NIR- og G-kanalen. Ved å se på forskjellen mellom disse kanalene kan man da i teorien klassifisere hva som er vegetasjon.

Her er en tabell med utvalgte spesifikasjoner for Optech Titan:

Tabell 6.1. Spesifikasjoner Optech Titan (Optech 2015)

Parametere	Spesifikasjon
Kanal 1	1550 nm MIR
Kanal 2	1064 nm NIR
Kanal 3	532 nm grønn
Stråle divergens	Kanal 1 og 2: $\approx 0,35$ mrad (1/e) Kanal 3: $\approx 0,7$ mrad (1/e)
Operasjonelle flyhøyder	Topografisk: 300 – 2000 m AGL, alle kanaler Batymetrisk: 300 – 600 m AGL, 532 nm
Effektiv PRF	Programmerbar; 50 – 300 kHz (per kanal); 900 kHz totalt
Punkttetthet	Topografisk: $> 15$ pkt/m <sup>2</sup> Batymetrisk: $> 45$ pkt/m <sup>2</sup>
Skannevinkel (FOV)	Programmerbar; 0 – 60° maksimum
Effektiv skannefrekvens	Programmerbar; 0 – 210 Hz
Sveipebredde	0 – 115% av AGL
Horisontal nøyaktighet	1/7,500 x høyde; 1 $\sigma$
Høyde nøyaktighet	$< 5 - 10$ cm; 1 $\sigma$
Presisjon laseravstand	$< 0,008$ m; 1 $\sigma$
Minimal målseparasjonsavstand	$< 1,0$ m (diskre)
Avstandsmåling	Opptil 4 avstandsmålinger for hver puls, inkludert siste
Intensitetsmåling	Opptil 4 avstandsmålinger for hver puls, inkludert siste 12 bit dynamisk måling og rekkevidde
Måling av bølgeform	12 bit, 1 Gs/sek (valgfri)

## 6.2 Testområdet

Testområdet er ca. 1.6 km x 1.2 km og ligger i Oslo. Området strekker seg over Tøyen, Grønland og Kampen. Dette er et typisk bymiljø med bygårder, gater og parker. Treslagene innenfor området er nesten utelukkende løvtrær med overvekt av Lind, Lønn, Kirsebær og Eik.

Figur 6.2 viser et oversiktsbilde over testområdet.



*Figur 6.2. Oversiktsbilde over testområdet*

Figur 6.3, 6.4 og 6.5 viser intensiteten for henholdsvis MIR-, NIR- og G-kanalen over testområdet.



*Figur 6.3. Intensitet MIR-kanal*



*Figur 6.4. Intensitet NIR-kanal*




*Figur 6.5. Intensitet G-kanal*

Figur 6.6 – 6.11 viser bilder av de ulike kategoriene av trær som man finner innenfor testområdet.




*Figur 6.6. Gatetrær*



Figur 6.7. Allétrær



Figur 6.8. Liten park



Figur 6.9. Større park



Figur 6.10. Trær i bygård

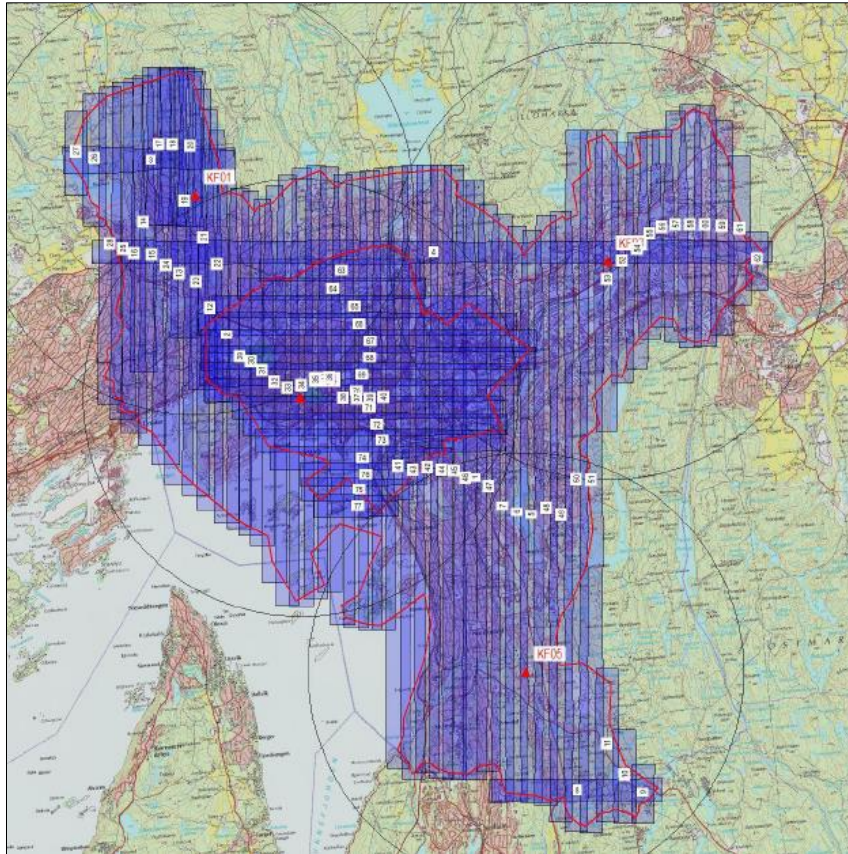


Figur 6.11. Treklynger

Valget av akkurat dette området som testområde ble gjort på grunn av at området er et typisk bymiljø og dette var det området i byen med mest fasitdata. Samtidig var det viktig at området ikke skulle være for stort for å holde prosesseringstiden nede.

### 6.3 Datainnsamling

Den 22. og 23. august 2017 utførte Terratec AS datainnsamlingen med den multispektrale laserskanneren Optech Titan. Hele byggesonen i Oslo kommune ble skannet med 5 pkt/m<sup>2</sup> og med 10 pkt/m<sup>2</sup> i sentrum innenfor Ring 3. Punktettheten i sentrum er imidlertid ikke «ekte» 10 pkt/m<sup>2</sup>. Dette er fordi området ble flydd to ganger (nord-sør og øst-vest) med 5 pkt/m<sup>2</sup> på hver flyvning, istedenfor å fly en gang med 10 pkt/m<sup>2</sup>. På grunn av at det er flydd i to retninger er det varierende punktthet i dataene, med høy punktthet i de mange stripeoverlappene.



Figur 6.12. Kartutsnitt skanneblokk

Terratec utførte georeferering, kontroll og enkel klassifisering av punktskyen før leveranse. De hadde klassifisert punktene i følgende klasser: uklassifisert, terreng, støy, bru og snø. For å gjøre dataene mer håndterlige er datasettet delt opp i blokker.

#### 6.4 Fasitdata

Som fasitdata ble det brukt en database med bytrær i Oslo, laget av Oslo kommune. Totalt for hele kommunen er det samlet inn informasjon om 30 000 trær. På grunn av at ikke alle trærne i databasen har blitt registrert med artsnavn er det totalt 16340 trær som kan brukes. Innenfor testområdet er det 1318 trær. Dataene har blitt samlet inn av ansatte i kommunen og sommerstudenter gjennom flere år. Databasen inneholder en stor mengde data, både beskrivende og administrative. Fordi denne oppgaven ser på klassifisering er det bare informasjon om posisjon og treslag som er brukt. Hvordan posisjonene til hvert tre er bestemt kommer ikke fram av databasen. Det er grunn til å tro at posisjonene har blitt bestemt ved en kombinasjon av håndholdt GPS, flyfotografier og ved å plukke ut tretopper i lasermålte punktskyer. På grunn av usikkerheten rundt posisjoneringsen til trærne er man nødt til å være ekstra kritisk når dataene brukes.



## 7 Programvare

### LAStools

LAStools er utviklet av Martin Isenburg og er en samling av effektive kommandolinjeverktøy for prosessering av LiDAR data. LAStools kan kjøres både som batch-script, gjennom et grafisk brukergrensesnitt eller som verktøy i ArcGIS og QGIS. LAStools består av en rekke verktøy som kan utføre ulike redigerings- og analyseoperasjoner på punktskyer i .las og .laz format.

I denne oppgaven er LAStools benyttet til all prosessering av laserdataene. Det ble skrevet batch filer for å utføre alle operasjonene. Først ble laserpunktene som havnet innenfor test området klippet ut. Deretter ble det brukt til å fjerne overlapp mellom flystripene, normalisering av punktskyen, lage kronehøydemodell og trekke ut statistikk fra punktskyen innenfor de segmenterte trekronene.

### TerraScan

TerraScan er utviklet av Terrasolid og er hovedapplikasjonen i programfamilien til Terrasolid for håndtering, visualisering og prosessering av LiDAR punktskyer. TerraScan er et komplett program hvor man kan utføre alle ønskede operasjoner for prosessering av laserdata. Det er et lisensiert program.

TerraScan er et mer avansert alternativ til LAStools med en høyere terskel for bruk. Dette er noe av grunnen til at TerraScan ikke ble brukt til selve prosesseringen av laserdataene. Derimot ble TerraScan brukt til visualisering, noe den er mye bedre på enn LAStools. I begynnelsen av arbeidet var TerraScan et nyttig verktøy for å bli kjent med laserdataene. Visuell kontroll av punktskyen både før og etter de forskjellige prosesseringsstegene ble også gjort i TerraScan.

### eCognition Developer

eCognition Developer er et lisensiert objektorientert bildeanalyseprogram som er utviklet av Trimble. eCognition kan brukes til å analysere både fly-, satellitt- og hyperspektrale bilder, LiDAR og radar. Programmet kan utføre alle vanlige fjernanalyseoppgaver slik som vegetasjonskartlegging, endringsdeteksjon, objekt gjenkjenning og uthenting av egenskaper. Analysen implementeres basert på betingelser gitt gjennom såkalte regler. Betingelsene baserer

seg på spektrale, tekstuelle og kontekstuelle attributter for å ekstrahere de ønskede egenskapene. De ekstraherte egenskapene kan eksporteres i raster- eller vektorformat slik at de kan tas videre inn i GIS-programmer.

I denne oppgaven ble eCognition kun brukt til segmentering av trekroner. En trekronemodell ble importert og analysert. Resultatet av analysen var polygoner som representerte enkeltrær.

## ArcGIS Pro

ArcGIS Pro er utviklet av Esri og er deres mest avanserte GIS applikasjon. Geografiske data kan visualiseres, editeres og analyseres i både 2D og 3D.

I denne oppgaven ble ArcGIS Pro brukt til visualisering og kontroll av fasitdata og trekronemodeller. Det ble også brukt til manuell redigering av polygoner fra eCognition og romlig sammenføring av trekronesegmenter og fasitdata.

## Orange

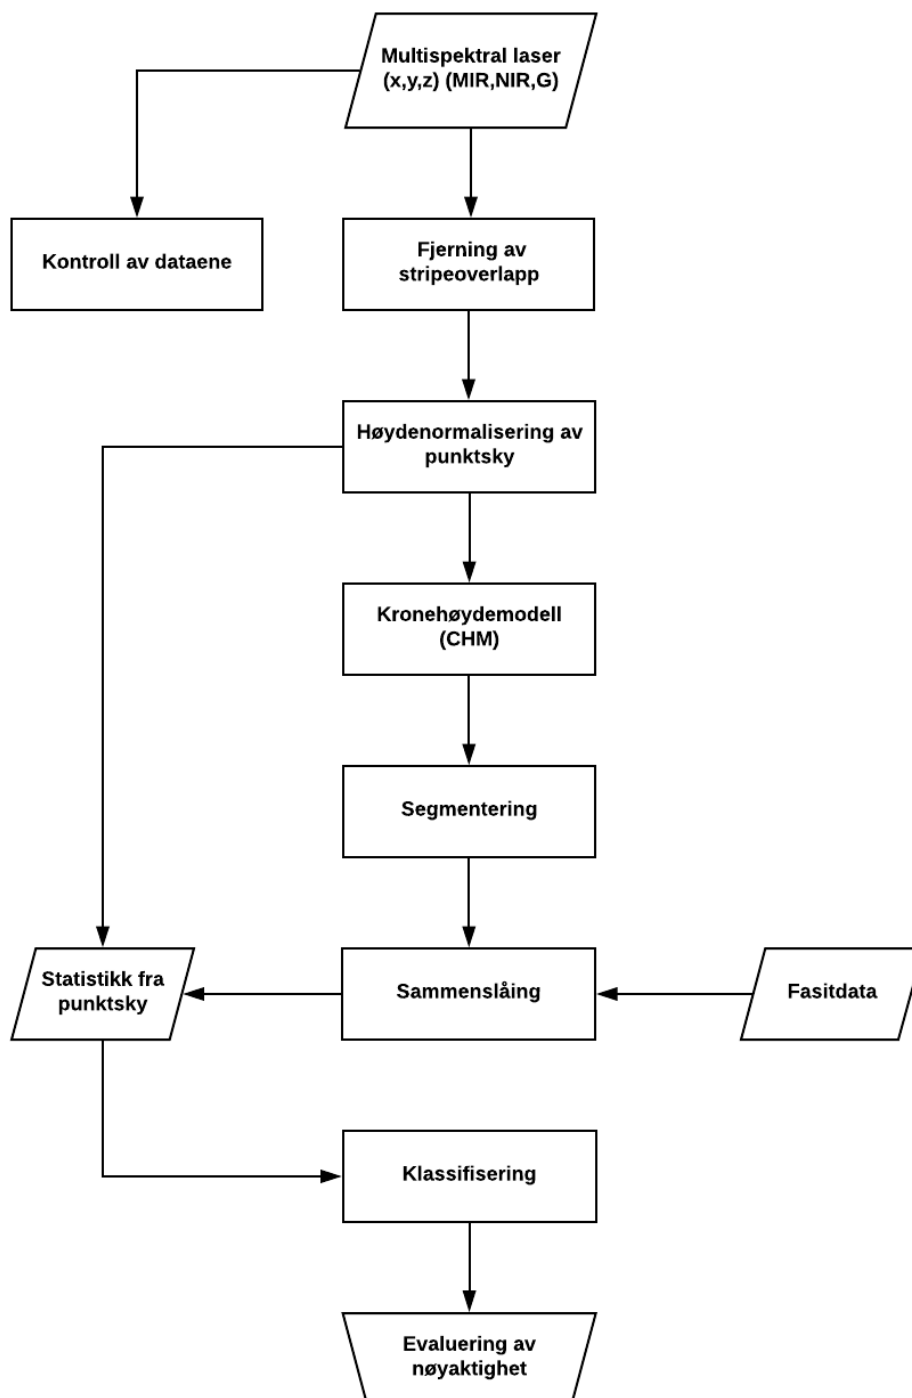
Orange er en komponent basert visuell programpakke for maskinlæring, analyse og visualisering av data. Programmet bruker visuell programmering til å utføre alt fra enkel datavisualisering til evaluering av læringsalgoritmer og predikativ modellering. For mer avansert bruk kan Orange også brukes som et bibliotek i Python. Orange har åpen kildekode og ligger tilgjengelig på GitHub. I denne oppgaven har Orange blitt brukt til å utføre klassifiseringen og produsere forvirringsmatriser og tabeller med klassifiseringsresultatene.

## Microsoft Office Excel

Excel er et program som er produsert av Microsoft og er en del Microsoft Office-pakken. Programmet er et digitalt regneark hvor man blant annet kan lage og redigere tabeller, utføre beregninger og analysere informasjon. Excel ble i denne oppgaven brukt til å redigere og produsere tabeller, beregne spektralindekser og ratioer, og gjøre statistiske beregninger.

## 8 Metode


I dette kapittelet beskrives metodene som er benyttet i oppgaven. Først presenteres et flytdiagram som viser hovedstegene i databehandlingen (se figur 8.1). Deretter følger delkapitler som vil beskrive de enkelte stegene. Alle batch filene som ble skrevet for prosessering i LAStools er lagt ved under Vedlegg.



Figur 8.1. Oversikt databehandling

## 8.1 Kontroll av dataene


Det ble utført en visuell kontroll av dataene i TerraScan. Det ble sett etter ulike effekter og det ble gjort kontroll av punktetthet. Under kontrollen dukket det opp et mønster som gjentar seg flere ganger over hele datasettet.



*Figur 8.2. Mønster i dataene*

Mønsteret gjenkjennes med en stripe med lav punktetthet etterfulgt at en tynn stripe med veldig høy punktetthet. En teori for hva som kan ha forårsaket mønsteret er at flyet har steilet. Når flyet steiler beveger nesene på flyet seg oppover, noe som fører til at skanneren går raskere framover. Dette fører til stripene med lav punktetthet. Når flyet så beveger nesene ned igjen vil skanneren beveges bakover og føre til at skanneren «står stille» i forhold til bakken. Dermed får vi de tynne stripene med veldig høy punktetthet. Siden de tre kanalene til skanneren er vinklet forskjellig får vi de tre parallelle stripene. En for hver kanal. Det er usikkert om dette vil ha en effekt på klassifiseringen. Jeg kjenner ikke til en metode for å fjerne eller korrigere for slike effekter. På grunn av det valgte jeg å ikke gjøre noe med det.

En annen effekt som ble oppdaget var at G-kanalen ikke går like langt ut til sidene som MIR- og NIR-kanalen.



*Figur 8.3. G-kanalen går ikke like langt ut til sidene som MIR- og NIR-kanalen*

Dermed får vi ikke returer fra G-kanalen der vi egentlig skulle fått det. Under klassifiseringen vil forskjellen mellom kanalene være en egenskap og da vil det at det mangler returer for G-kanalen kunne føre til feil i klassifiseringen for trær i slike områder. Ved å fjerne overlappen mellom flystripene vil denne potensielle feilkilden elimineres.

## 8.2 Fjerning av stripeoverlapp

Det er flere grunner til å fjerne overlappen mellom flystripene utover manglende returer fra G-kanalen (kapittel 5.1). For klassifiseringsformål er det klart ønskelig med en mest mulig homogen punktsky med hensyn på punkttetthet. Hvis punkttettheten varierer kan man få uheldige effekter hvor man får bedre klassifiseringsnøyaktighet for trær i områder med høy punkttetthet og dårligere der punkttettheten er lav. Som tidligere nevnt er det i dette datasettet varierende punkttetthet på grunn av mange kryssende flystriper (kapittel 6.3). Fjerning av overlappen mellom flystripene vil gjøre at vi får et datasett med en mye mer homogen punkttetthet.

For å fjerne overlappen mellom flystripene brukes ulike verktøy i LAStools. Først brukes lassplit for å dele opp blokkene med laserdata i flere filer hvor hver fil tilsvarende en flystripe. Deretter brukes lasmerge for å slå sammen flystripene fra de forskjellige blokkene til hele flystriper. For å fjerne de overlappende punktene mellom flystripene brukes lasoverage. Her er det viktig å gjøre det i to omganger, en gang for hver flyretning, ellers risikerer man å fjerne for mange punkter. I lasoverage kan det velges om man vil fjerne punktene helt eller klassifisere dem til klassen reserved. Det er valgt å klassifisere punktene til reserved. Til slutt lages nye

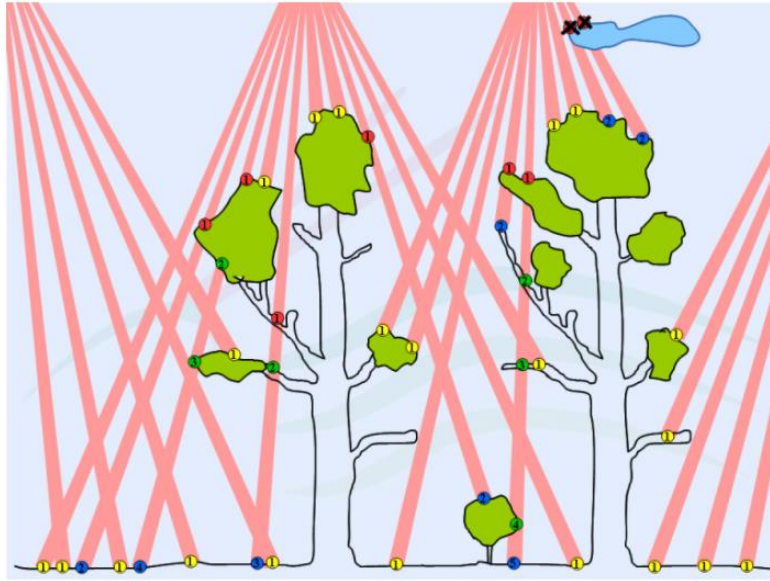
blokker med lastile. Det gjøres for å holde antall punkter per fil lav for effektiv bruk av minnet til datamaskinen, og for å gjøre prosesseringen raskere (Isenburg 2015).

### 8.3 Høydenormalisering og kronehøydemodell

For å kunne detektere enkelttrær i punktskyen trengs en kronehøydemodell (CHM). En CHM representerer høyden til vegetasjonen over terrenget. Vanligvis lages en CHM ved å først lage en digital terrengmodell (DTM) og en digital overflatemodell (DSM). Deretter trekkes DTM fra DSM og vi får CHM (Vosselman & Maas 2010). Metoden som benyttes i denne oppgaven beregner CHM direkte fra en høydenormalisert punktsky (Isenburg 2014).


Ved en høydenormalisering settes høyden til punktene lik punktets høyde over terrenget. Til dette trenger man å vite hvilke av punktene som representerer terrenget. Siden punktskyen allerede var bakkeklassifisert (kapittel 6.3) kunne vi gå rett på høydenormaliseringen. Høydenormaliseringen ble utført med lasheight. Alle punkter over 50 m ble filtrert ut da det ikke er noen trær i testområdet som er høyere enn det. Disse punktene er støy.

Tradisjonelt har bare første retur blitt brukt til å generere DSM / CHM. Tanken er at første retur vil komme fra tretoppene og ved å kun bruke disse får man en modell av overflaten. Det er imidlertid noen ulemper med denne framgangsmåten. For det første bruker man ikke all informasjon man har tilgjengelig. Dette gjelder spesielt for høye skannevinkler hvor første retur ikke nødvendigvis kommer fra toppen av treet. Ved forekomst av skyer og høy støy fjernes første retur og dermed vil ikke de laserpulsene bidra til å generere CHM.



Figur 8.4. Laserpulser og returer fra fire flylinjer (Isenburg 2016)

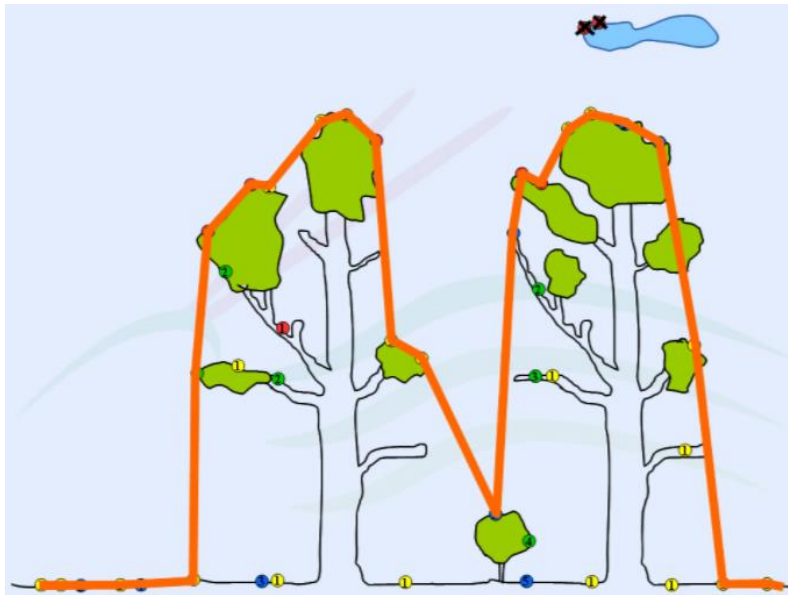
Ved å bruke alle første returer betyr det i praksis at det under trianguleringen av modellen oppstår nåleformede triangler som fremstår som hull i CHM. Disse nåleformede trianglerne kalles for «spikes».



Figur 8.5. Interpolering av alle første returer (Isenburg 2016)


Spikes vanskeliggjør videre analyse, spesielt ved deteksjon av enkeltrær (Isenburg 2016).

En helt ny metode for generering av CHM tar i bruk alle relevante returer istedenfor bare første returer. Algoritmen som brukes forhindrer genereringen av spikes ved å ignorere de returene som ville generert en spike dersom de hadde blitt tatt med i modellen (Khosravipour et al. 2016).



Figur 8.6. Interpolering av alle relevante returer (Isenburg 2016)

Algoritmen for såkalt «spike-free» generering av CHM er implementert i LAStools. las2dem med spike-free ble brukt for generering av CHM. Rutestørrelsen til CHM bør settes til en verdi som er omtrent lik gjennomsnittlig punktavstand for å unngå tomme ruter. Gjennomsnittlig punktavstand i punkttskyen er 0.22 m og ble funnet ved å bruke lasinfo. Rutestørrelsen settes derfor til 0.25 m. For spike-free må det settes en verdi for frys begrensning. Denne verdien er relatert til den forventede kantlengden (Isenburg 2016). Isenburg anbefaler en verdi som er omtrent tre ganger så stor som gjennomsnittlig punktavstand. Etter å ha prøvd flere forskjellige verdier var det verdien 1.1 som gav best resultat, altså fem ganger gjennomsnittlig punktavstand. Punkter som mangler data settes til verdien 0 slik at det vil vises hvor det mangler data. Støyklassen (kapittel 6.3) blir sett bort i fra slik at støypunktene ikke bidrar til modellen.




Figur 8.7. Utsnitt av generert CHM



## 8.4 Segmentering

Etter å ha generert CHM tas denne inn i eCognition for segmentering. Segmenteringen forsøker å skille ut hvert enkelt tre ved å lage omsluttende polygoner som kan brukes videre.

Det første som gjøres er å bruke «multi-threshold» segmentering for å filtrere ut piksler som har en verdi som er mindre enn 3 m. De pikslene som har en verdi som er høyere enn 3 m blir slått sammen til objekter. Neste steg er å filtrere ut bygninger. Bygningene er nødt til å fjernes, ellers vil de gi feil i statistikken som skal beregnes senere. En utfordring med fjerningen av bygninger er at jeg ikke har klart å finne en metode for å fjerne bygninger i 3D. Bygningene må istedenfor fjernes i grunnriss. Dette medfører at fjerning av bygninger som er helt eller delvis dekket av trær også vil fjerne den delen av treet som står over bygningen.



*Figur 8.8. Bygninger som er helt eller delvis dekket av trær*

I mangel av en bedre metode ble bygningene fjernet og trær som fikk deler av kronen fjernet ble ikke tatt med videre i segmenteringen. Trær som bare fikk minimale deler av kronen fjernet ble tatt med videre. Det ble lagt på en buffer på 1 m på bygningene for å forhindre kant effekter.




*Figur 8.9. Hull i trær forårsaket av bygninger*


For å eliminere falske lokale maksima forårsaket av grener blir CHM glattet to ganger med et Gauss filter med et søkevindu på 5 ganger 5 piksler.

Til slutt gjøres en watershed segmentering for å avgrense trekronene. Watershed algoritmen finner først lokale maksima som blir ansett for å være tretopper. Tretoppene blir brukt som utgangspunkt for neste steg som er å finne skillene mellom trærne. For å unngå oversegmentering ble det bestemt to kriterier som bestemte om et segment skulle slås sammen med et nabosegment. Det første kriteriet sier at arealet til segmentet må være mindre enn 150 piksler. Det andre kriteriet sier at forskjellen mellom maksimal og minimal intensitet (pikselverdi) må være mindre enn 100. Etter å ha prøvd flere forskjellige verdier var det disse som tilsynelatende ga det beste resultatet. Kriteriene ble kun brukt når to segmenter rørte ved hverandre. Begge kriteriene måtte være oppfylt for at et segment skulle slås sammen med et annet.


Segmentene fra eCognition ble så tatt inn i ArcGIS Pro for manuell redigering. Fasittrærne blir tatt inn slik at de eneste segmentene som blir vurdert for redigering er de som inneholder fasittrær. Segmenteringen fra eCognition har undersegmentert trærne, så redigeringen besto for det meste i å splitte opp segmentene i flere segmenter der det var nødvendig. Der CHM ikke gir et tydelig svar på hvor skillene mellom trærne går blir flybilder fra 1881.no og Google Street View brukt som visuell kontroll.



Figur 8.10. Segmenter før og etter manuell redigering




Figur 8.11. Google Street View bilde av trærne i figur 8.10




Figur 8.12. Flybilde fra 1881.no av trærne i figur 8.10

Enkelte steder viser den visuelle kontrollen at eCognition har feilsegmentert.




Figur 8.13. Feilsegmentering



Figur 8.14. Visuell kontroll av trær fra figur 8.13

Noen av fasittrærne ble flyttet. Hvorfor det ble gjort er listet opp nedenfor:

- Treet ligger ikke innenfor et segment, men ved kontroll med flybilder og Google Street View viste det seg at treet tilhører et nærliggende segment.
- Treet ligger innenfor et segment hvor det er et eller flere andre trær og det aktuelle treet ved visuell kontroll viser seg å ikke eksistere.
- Grupper av trær som virker systematisk forskjøvet.



Figur 8.15. Systematisk forskyvning av bytrær

## 8.5 Statistikk

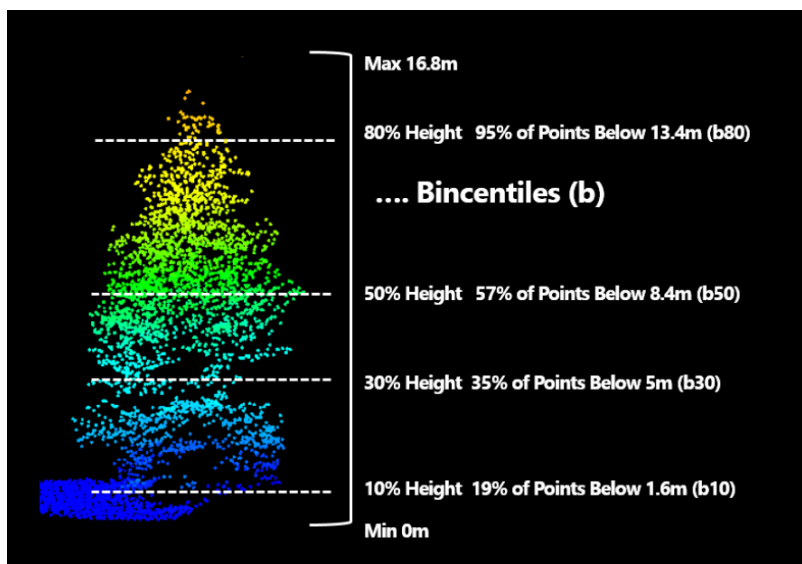
For å kunne klassifisere trærne må det beregnes statistiske mål for hvert segmenterte tre. Først må segmentene kobles sammen med fasittrærne slik at man senere kan knytte statistikken til rett tre. Deretter gjøres en romlig sammenkobling av segmentene og fasittrærne i ArcGIS Pro. Før det kan beregnes statistikk må alle eventuelle hull (spikes) i segmentene tettes. Hvis de ikke tettes vil hvert hull framstå som et eget segment og det vil bli nærmest umulig å knytte statistikken som beregnes til rett segment. Til å fylle ut hullene i segmentene brukes verktøyet «Fill Polygon Holes» fra ET GeoWizards som er en plugin til ArcMap.

Deretter kan statistikk for hvert segment beregnes. Ved å bruke lascanopy kan en rekke statistiske mål beregnes. Statistikken beregnes separat for hver av de tre laserkanalene.

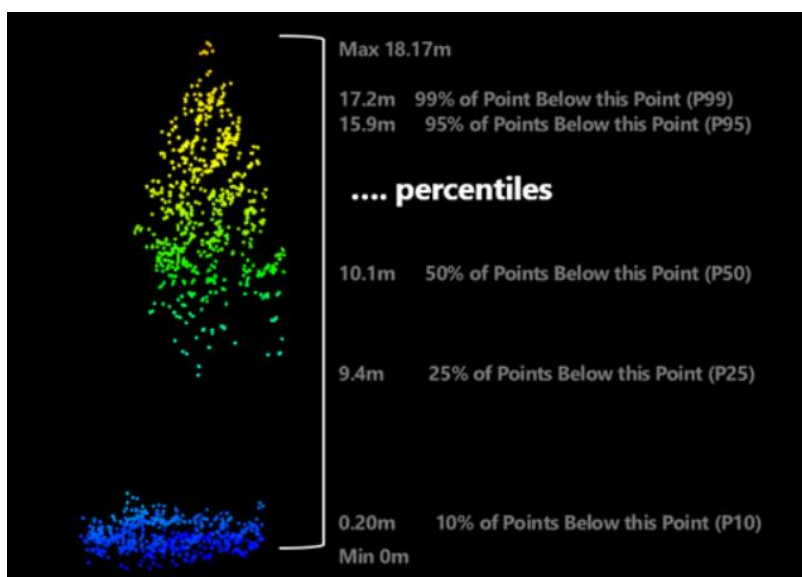
Tabell 8.1. Statistiske mål fra lascanopy

Statistiske mål	Egenskaper
Høydepercentiler	p10, p20, p30, p40, p50, p60, p70, p80, p90, p95, p99
Bincentiler	b10, b20, b30, b40, b50, b60, b70, b80, b90, b95
Intensitetsstatistikk	int_avg, int_std
Intensitetspercentiler	int_p10, int_p25, int_p50, int_p75, int_p90, int_p95
Kronetetthet	dns

For å beskrive strukturen til treet beregnes høydepercentiler og bincentiler. Høydepercentiler viser hvilken høyde en gitt prosent av laserpunktene befinner seg under. Det vil si at p90 gir høyden som 90% av punktene i treet befinner seg under. Bincentiler gir andelen av punkter som er under en gitt prosent av treet høyde. b90 vil da gi hvor stor andel av punktene som ligger under 90% av høyden til treet.



Figur 8.16. Bincentiler (Herries 2014)



Figur 8.17. Høydepercentiler (Herries 2014)

Høydepercentilene og bincentilene beregnes over en terskelhøyde på 2.0 m. Dette gjøres fordi det er stor sannsynlighet at mange av punktene som er lavere enn 2.0 m ikke tilhører treet. Disse punktene kan for eksempel være parkerte biler, benker eller fotgjengere. Kronetettheten beregnes også. For intensitet beregnes gjennomsnittlig intensitet og standardavvik innenfor segmentet og intensitetspercentiler.

Statistikken for alle kanalene slås så sammen med fasittrærne. I tillegg til statistikken fra lascanopy beregnes spektralindekser og ratioer mellom kanalene i Excel. Ideen er at det er bedre å bruke forholdstall enn de absolute intensitetsverdiene. Dette kan også kompensere for manglende intensitetskalibrering. Spektralindeksen som beregnes er Normalized Difference

Feature Indices (NDFI). Gjennomsnittlig intensitet for hver kanal blir brukt for å lage indeksene.

$$NDFI_{MIR-NIR} = \frac{MIR - NIR}{MIR + NIR} \quad NDFI_{MIR-G} = \frac{MIR - G}{MIR + G} \quad NDFI_{NIR-G} = \frac{NIR - G}{NIR + G}$$

Formel 8.1. Spektralindekser (Teo & Wu 2017)

I likhet med NDFI beregnes også ratioene med gjennomsnittlig intensitet for hver kanal.

$$Ratio_{MIR} = \frac{MIR}{MIR + NIR + G} \quad Ratio_{NIR} = \frac{NIR}{MIR + NIR + G} \quad Ratio_G = \frac{G}{MIR + NIR + G}$$

Formel 8.2. Ratioer

## 8.6 Klassifisering

Før selve klassifiseringen starter er det valgt å aggregere treslagene. Multispektral laserskanning har ikke fått like gode resultater ved klassifisering av ulike typer løvtrær i tidligere studier og det er liten grunn til å tro at den vil klare å skille mellom treslag som for eksempel Rogn og Rogneasal. En annen grunn til å gjøre aggregeringen er for å få større klasser. Det er generelt en fordel med færre større klasser enn flere mindre. Aggregeringen er gjort ved å bruke de latinske navnene til treslagene. For eksempel heter Rogn, Rogneasal og Svenskeasal henholdsvis *Sorbus aucuparia*, *Sorbus hybrida* og *Sorbus intermedia* på latin. Siden de alle har felles familienavn, *Sorbus*, har de blitt aggregert til en klasse.

Tabell 8.2. Originale og aggregerte artsnavn

Originale artsnavn	Aggregerte artsnavn
Alm	Alm
Ask, Mannaask	Ask
Bjørk, Dunbjørk, Hengebjørk, Papirbjørk	Bjørk
Bøk	Bøk
Eik, Rødeik, Sommereik, Skarlageneik, Sumpeik, Søyleeik, Vintereik	Eik
Eple, Prydeple	Eple
Furu, Weymouthfuru	Furu
Blågran, Sitkagran	Gran
Parkhagtorn	Hagtorn



Hestekastanje, Kastanje, Rød hestekastanje	Hestekastanje
Kirsebær, Kulekirsebær, Søtkirsebær, Morell	Kirsebær
Lerk	Lerk
Lind	Lind
Kulelønn, Naverlønn, Platanlønn, Spisslønn	Lønn
Hvitpil, Pil	Pil
Poppel, Pyramidepoppel	Poppel
Pære	Pære
Rogn, Rogneasal, Svenskeasal	Rogn
Storrobina	Storrobina
Søyleagnbøk	Søyleagnbøk
Valnøtt	Valnøtt

Dette gir en tabell med følgende klassestørrelser:

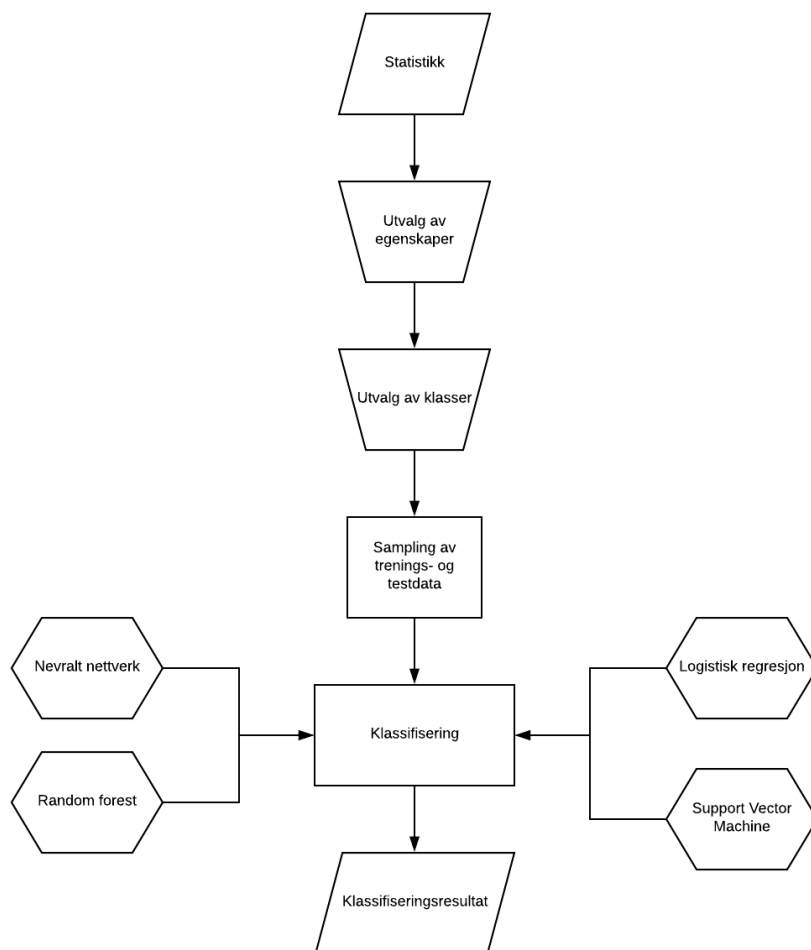
Tabell 8.3. Antall trær i hver klasse

Artsnavn	Antall
Lind	262
Kirsebær	130
Lønn	123
Eik	101
Rogn	53
Bjørk	44
Alm	31
Hestekastanje	30
Hagtorn	14
Ask	13
Valnøtt	13
Poppel	10
Storrobina	7
Bøk	5
Furu	5
Lerk	4

Pil	4
Gran	3
Eple	3
Pære	1
Søyleagnbøk	1

Det første man legger merke til er at det er veldig stor forskjell i størrelsen på klassene. Klassene varierer fra 1-262 trær per klasse. Over halvparten av klassene er veldig små i forhold til de største klassene. Når det blir veldig stor forskjell i klassestørrelsen kan det bli utfordrende i klassifiseringen. Det er derfor satt en grenseverdi på 30 trær. De klassene som har færre enn 30 trær blir ikke tatt med videre i klassifiseringen.

Selve klassifiseringen blir gjort i Orange. Figur 8.18 viser et flytdiagram med klassifiseringsprosessen.



Figur 8.18. Klassifiseringsprosessen

Først velges det hvilke av egenskapene som skal brukes. Mange egenskaper utledet fra laser blir påvirket av høyden til treet (Ørka et al. 2009). I Oslo blir en stor del av trærne beskåret. Dette fører til at de får en uniform høyde og form. Hvor i byen treet står har også betydning for om det blir beskåret eller ikke. Allétrær blir oftere beskåret enn trær i parker. For eksempel er flesteparten av kirsebærtrærne i testområdet allétrær. Hvis modellen klassifiserer kirsebærtrær rett fordi de har omtrent lik høyde er det ikke en god modell. Det er derfor valgt å ikke bruke høyde i hoveddelen av klassifiseringen. Det vil imidlertid gjøres klassifiseringer med hver enkelt type egenskap hver for seg, også høyde, for å se hvilken påvirkning de forskjellige egenskapene har på klassifiseringen.

Når man lager klassifiseringsmodeller er det viktig å unngå såkalt overtilpasning. For å lage en modell trenger man data for å trene modellen, såkalte treningsdata. Etterpå tester man modellen på valideringsdata. Overtilpasning skjer når en modell lærer seg treningsdataene så bra at det negativt påvirker ytelsen til modellen på valideringsdataene. Med andre ord så tror modellen at det som bare er støy og tilfeldige variasjoner i treningsdataene er egenskaper ved det som skal klassifiseres (Brownlee 2016). Grunnen til at overtilpasning oppstår er at det brukes for mange egenskaper (Spruyt 2014).

For å unngå overtilpasning av modellen brukes en Random Forest algoritme til å velge ut de 15 egenskapene som gir størst bidrag. Random Forest er en styrt læringsalgoritme som består av flere beslutningstrær. Egenskapene blir delt opp i tilfeldige utvalg der hvert utvalg danner et beslutningstre. Hver gang en node i treet splittes søker algoritmen etter den beste egenskapen i det tilfeldige utvalget. Med mange beslutningstrær skaper dette et stort mangfold, og som regel fører dette til en bedre modell (Donges 2018).

Utvelgelsen av trenings- og valideringsdata gjøres ved å bruke en teknikk som kalles kryssvalidering. Kryssvalidering splitter dataene opp i  $k$  like store deler (i dette tilfellet er  $k = 10$ ). En av delene blir holdt ute som valideringsdata for å teste modellen, mens de andre delene blir brukt til å trene modellen. Dette gjentas  $k$  antall ganger slik at hver del blir brukt som valideringsdata en gang. Til slutt regnes gjennomsnittet for alle kjøringene for å lage det endelige resultatet. Fordelen med denne metoden er at alle samplene blir brukt både til trening og validering.

Klassifiseringsmodellene som benyttes er Nevral Nettverk, Random Forest, Logistisk regresjon og Support Vector Machine. Det benyttes flere modeller for å se hvilke(n) som gir det beste klassifiseringsresultatet. Nevral nettverk er en samling av algoritmer og

datastrukturer som er inspirert av måten nervecellene i hjernen prosesserer informasjon. Slike nettverk egner seg til å identifisere mønstre i dataene som er vanskelig å finne matematisk. Nettverket består av nevroner som mottar en verdi og beregner en ny verdi som sendes videre. Verdiene nevronet mottar blir tillagt en vekt som beskriver dens relative viktighet i forhold til andre verdier. Nevronet bruker en funksjon på den vektete summen til verdiene den mottar. Hvis sluttsummen overstiger en terskelverdi blir verdien sendt videre i nettverket for å påvirke det endelige resultatet. Desto flere nevroner man har desto mer detaljert blir nettverket. (Dvergsdal 2017; Fumo 2017).

I Orange er det forhåndsbestemt et antall nevroner i det nevrale nettverket. Har man et stort nettverk med mange nevroner krever det mange samples siden nettverket blir såpass detaljert. Når man ikke har mange samples er det viktig å sette ned antall noder for å unngå overtilpasning. Orange har forhåndsbestemt 100 nevroner. Med så mange nevroner ble det veldig stor forskjell på klassifiseringsnøyaktigheten når modellen ble testet på henholdsvis trenings- og valideringsdata. Det ble gjort ved å trekke ut 30% av dataene til validering, trene modellen på de resterende 70%, og teste på henholdsvis trenings- og valideringsdataene. Hvis modellen prestere mye bedre på treningsdataene enn på valideringsdataene tyder det på at modellen er overtilpasset. Etter å ha prøvd flere forskjellige verdier kom jeg fram til at 50 nevroner ga mye mindre forskjell mellom testing på trenings- og valideringsdataene og det tyder dermed på at modellen ikke er overtilpasset.

## 8.7 Evaluering av nøyaktighet

Nøyaktigheten til klassifiseringen evalueres ved å sammenligne de klassifiserte trærne med referansen. Resultatet representeres som en forvirringsmatrise som viser antall korrekt klassifiserte trær og antall trær som er feilklassifisert. Total nøyaktighet, bruker- og produsentnøyaktighet og kappa koeffisient beregnes for å evaluere nøyaktigheten til klassifiseringen. Total nøyaktighet er gitt som den totale andelen korrekt klassifiserte trær, dvs. antall korrekt klassifiserte trær delt på totalt antall trær. Brukernøyaktighet regnes ut som antall korrekt predikerte trær i en klasse delt på totalt antall trær som er predikert for den klassen. Produsentnøyaktighet er antall faktiske trær som er rett klassifisert delt på totalt antall trær i den klassen.

Kappa koeffisient er et mål på hvor mye bedre klassifiseringen er enn den hadde vært hvis klassifiseringen hadde vært helt tilfeldig. Beregningen baserer seg på hvor mye enighet som

observeres (hvor mange trær som har blitt korrekt klassifisert) i forhold til hvor mye enighet man ville forventet hvis utfallet var helt tilfeldig (Viera & Garrett 2005). Kappa koeffisienten regnes ut på denne måten:

$$K = \frac{p_0 - p_e}{1 - p_e}$$

Formel 8.3. Utregning av kappa koeffisient (Viera & Garrett 2005)

$p_0$  er observert nøyaktighet (den totale nøyaktigheten) og  $p_e$  er den forventede nøyaktigheten. Den forventede nøyaktigheten regnes ut slik:

$$p_e = \left(\frac{p_1}{t} * \frac{a_1}{t}\right) + \dots + \left(\frac{p_n}{t} * \frac{a_n}{t}\right)$$

Formel 8.4. Forventet nøyaktighet

Antall trær som er predikert å tilhøre en klasse ( $p$ ) deles på totalt antall trær som er klassifisert ( $t$ ). Dette ganges med faktisk antall trær i klassen ( $a$ ) som deles på  $t$ . Dette gjøres for  $n$  antall klasser og legges sammen for å lage  $p_e$ .

Kappa varierer mellom -1 til 1 hvor en verdi på 0 indikerer at utfallet er helt tilfeldig mens en verdi på 1 indikerer nesten perfekt enighet.

Tabell 8.4. Grad av enighet (Viera & Garrett 2005)

Grad av enighet	Ingen	Minimal	Svak	Moderat	Sterk	Nesten perfekt
Kappa	0.0	0.20	0.40	0.60	0.80	1.0

Det ble utført klassifiseringer med henholdsvis 3, 2 og 1 kanal for å se på om flere kanaler gir bedre klassifiseringsnøyaktighet. For to-kanals kombinasjonen ble MIR og NIR brukt. Denne kombinasjonen ble valgt fordi det er interessant å se hvilket resultat man oppnår ved å ikke bruke den grønne kanalen. Den grønne kanalen er veldig krevende å fly med. På grunn av at grønt lys er synlig lys kan det skade øynene til personene på bakken. Derfor er den utsendte intensiteten satt lavere enn for de andre kanalene. Grønt lys har også lavere reflektans enn de andre kanalene på mange overflater (kapittel 5.3). Det er derfor nødvendig å fly lavt hvis en skal få nok returer fra denne kanalen. Hvis det flys for høyt kan kanalen falle helt ut (Rostad 2017). Uten den grønne kanalen kan det dermed flys høyere, noe som gjør at datainnsamlingen blir mer effektiv og dermed billigere. Som den enslige kanalen velges NIR. Grunnen til at NIR ble valgt er fordi det er den kanalen som er mest brukt ved tradisjonell en-kanals laserskanning.

Noe som er verdt å merke seg er at punkttettheten går ned når antall kanaler reduseres. Dette kan påvirke nøyaktigheten til klassifiseringen.

For å undersøke hvilke egenskaper som gir mest informasjon til klassifiseringen blir også klassifiseringer med ulike egenskaper utført. Egenskapene som blir testet er høyden til trærne (p95), struktur (bincentiler og dns), intensitet, ratio og NDFI. Ved å bare bruke høyden får man innsikt i hvor bra klassifiseringen blir med bare en egenskap og om det er underliggende korrelasjon i dataene. Et eksempel på en slik underliggende korrelasjon kan være at alle Kirsebærtrærne er lave mens alle Eiketrærne er høye. En klassifisering med bare bruk av høyde vil i et slikt tilfelle gi en høy klassifiseringsnøyaktighet på Kirsebær og Eik. De andre egenskapene blir testet kumulativt hvor det første bare brukes struktur før det legges til intensitet og til slutt ratio og NDFI. Dette vil gi et inntrykk av hvilke egenskaper som bidrar mest til klassifiseringsnøyaktigheten.

Selv om resultatene fra klassifiseringene er forskjellige betyr det imidlertid ikke at de er statistisk signifikant forskjellig. Den observerte forskjellen kan være et resultat av tilfeldigheter. For å evaluere om det signifikant forskjell mellom de ulike klassifiseringene gjøres det en McNemar test. McNemar sin test ser på forskjellen mellom to klassifiseringer og baserer seg på forvirringsmatriser med dimensjon to ganger to. Større matriser kan reduseres til denne størrelsen fordi man kun ser på korrekt eller feil klasseallokering (Foody 2004).

Allocation	Classification 2		$\Sigma$
	Correct	Incorrect	
Classification 1			
Correct	$f_{11}$	$f_{12}$	
Incorrect	$f_{21}$	$f_{22}$	
$\Sigma$			

Figur 8.19. To ganger to forvirringsmatrise (Foody 2004)

McNemar verdien (kji-kvadrat) kan regnes ut på denne måten:

$$\chi^2 = \frac{(f_{12} - f_{21})^2}{f_{12} + f_{21}}$$

Formel 8.5. McNemar (Foody 2004)

Ved å evaluere McNemar verdien med kji-kvadrat distribusjonen med en frihetsgrad får man p-verdien. P-verdien forteller hvor stor sannsynligheten er for at den observerte forskjellen er tilfeldig. Om forskjellen er signifikant avhenger av hvilket signifikansnivå som velges. Det

mest vanlige signifikansnivået er 5%. Det betyr at hvis det er mindre enn 5% sannsynlighet for at den observerte forskjellen er tilfeldig er forskjellen signifikant.

Det er interessant å se på om antall sampler er med på å påvirke nøyaktigheten til klassifiseringen. Klassifiseringen ble utført med henholdsvis 100, 60 og 30 sampler i hver klasse. For hvert samplingsnivå blir klassifiseringen kjørt 15 ganger og kappa koeffisient beregnes for hver kjøring. Resultatet blir presentert i et boksplokk. Dette gjøres både for kryssvalidering og en annen mye brukt metode, tilfeldig sampling. Tilfeldig sampling fungerer på den måten av datasettet deles tilfeldig opp i to deler, en treningsdel og en valideringsdel. En typisk fordeling er at 70% av dataene blir brukt til treningsdata mens 30% blir brukt som valideringsdata. Først trenes modellen på treningsdataene før den testes på valideringsdataene.

## 9 Resultater

### 9.1 Segmentering

Av totalt 1318 fasittrær klarte segmenteringen å detektere 857 trær, dvs. 65%. Flesteparten av trærne som ikke ble detektert var trær som sto sammen i tette klynger. Flere steder viste det seg at trær var fjernet uten at databasen var oppdatert. I noen tilfeller var det også vanskelig å avgjøre om trærne var fjernet eller om det var feil i koordinatene. Områdene som var vanskeligst å segmentere, og hvor de fleste av de udetekterte trærne befant seg, var parker og bygårder. Det var også vanskelig å få bilder til visuell kontroll da Google Street View som oftest ikke har bilder i disse områdene.

### 9.2 Klassifisering av treslag

Utvelgelsen av de 15 egenskapene som ga størst bidrag til modellen varierte fra klassifisering til klassifisering. Det var noen egenskaper som skilte seg ut og som ga mest bidrag i hver klassifisering. Mange av verdiene ga imidlertid omtrent likt bidrag noe som førte til at det varierte hvilke som til enhver tid ble en del av de 15 beste. På grunn av dette vil jeg ikke gå i detalj på hvilke egenskaper som til enhver tid gjorde det best, men vil fortelle om de generelle trendene. De egenskapene som ble rangert høyeste var ratio, NDFI og dns etterfulgt av intensitet og bincentiler. Det var nesten utelukkende egenskaper fra kanal 1 og 2 som ble ansett av Random forest algoritmen til å gi de største bidragene.

For alle klassifiseringene var det Nevral nettverk som ga den høyeste klassifiseringsnøyaktigheten. Derfor blir kun forvirringsmatrisene fra klassifiseringene med Nevral nettverk og resultatene fra nøyaktighetsevalueringene presentert.

Tabell 9.1 viser resultatet fra klassifiseringen av de 8 treslagene som hadde mer enn 30 sampler.



Tabell 9.1. Forvirringsmatrise og nøyaktighetsevaluering for 8 treslag

		Predikert								Σ	Produsent (%)
		Alm	Bjørk	Eik	Hestekastanje	Kirsebær	Lind	Lønn	Rogn		
Faktisk	<b>Alm</b>	11	7	1	0	3	1	8	0	<b>31</b>	35.48
	<b>Bjørk</b>	5	16	5	0	3	14	1	0	<b>44</b>	36.36
	<b>Eik</b>	2	3	67	0	7	16	4	2	<b>101</b>	66.34
	<b>Hestekastanje</b>	0	1	1	16	1	1	10	0	<b>30</b>	53.33
	<b>Kirsebær</b>	4	5	13	3	80	9	14	2	<b>130</b>	61.54
	<b>Lind</b>	2	1	13	0	14	210	17	5	<b>262</b>	80.15
	<b>Lønn</b>	3	1	4	3	12	9	83	8	<b>123</b>	67.48
	<b>Rogn</b>	0	0	5	0	4	14	17	13	<b>53</b>	24.53
	<b>Σ</b>	<b>27</b>	<b>34</b>	<b>109</b>	<b>22</b>	<b>124</b>	<b>274</b>	<b>154</b>	<b>30</b>	<b>774</b>	
Bruker (%)		40.74	47.06	61.47	72.73	64.52	76.64	53.90	43.33		
Total nøyaktighet = 64.08%											
Kappa = 0.55											

Den totale nøyaktigheten ble på 64.08% med en kappa på 0.55. Det er stor forskjell i klassifiseringsnøyaktighetene for hver enkelt klasse. De klassene med relativt mange sampler har gjennomgående høyere produsentnøyaktighet enn de klassene med relativt få sampler. Det er produsentnøyaktigheten som er mest interessant å se på i dette tilfellet fordi den forteller hvor stor andel av de faktiske trærne som har blitt korrekt klassifisert.

Det ble gjort en ny klassifisering der de to treslagene med færrest sampler er tatt vekk. Resultatet fra denne vises i tabell 9.2.

Tabell 9.2. Forvirringsmatrise og nøyaktighetsevaluering for 6 treslag

		Predikert						Σ	Produsent (%)
		Bjørk	Eik	Kirsebær	Lind	Lønn	Rogn		
Faktisk	<b>Bjørk</b>	21	4	4	11	2	2	<b>44</b>	47.73
	<b>Eik</b>	2	69	9	16	5	0	<b>101</b>	68.32
	<b>Kirsebær</b>	9	15	78	6	18	4	<b>130</b>	60.00
	<b>Lind</b>	2	11	17	215	14	3	<b>262</b>	82.06
	<b>Lønn</b>	1	7	14	9	87	5	<b>123</b>	70.73
	<b>Rogn</b>	0	4	4	10	20	15	<b>53</b>	28.30
	<b>Σ</b>	<b>35</b>	<b>110</b>	<b>126</b>	<b>267</b>	<b>146</b>	<b>29</b>	<b>713</b>	
Bruker (%)		60.00	62.73	61.90	80.52	59.59	51.72		
Total nøyaktighet = 68.02%									
Kappa = 0.58									

Denne gangen ble den totale nøyaktigheten 68.02% med kappa på 0.58. Dette er høyere enn forrige klassifisering, men fremdeles er produsentnøyaktigheten markant lavere for de klassene med få sampler. I tabell 9.3 presenteres en klassifisering hvor de fire treslagene med flest sampler er tatt med. Disse klassene hadde markant flere sampler enn resten.

Tabell 9.3. Forvirringsmatrise og nøyaktighetsevaluering for 4 treslag

		Predikert				Σ	Produsent (%)
		Eik	Kirsebær	Lind	Lønn		
Faktisk	Eik	71	15	11	4	<b>101</b>	70.30
	Kirsebær	12	91	10	17	<b>130</b>	70.00
	Lind	11	11	225	15	<b>262</b>	85.88
	Lønn	7	14	14	88	<b>123</b>	71.54
	Σ	<b>101</b>	<b>131</b>	<b>260</b>	<b>124</b>	<b>616</b>	
Bruker (%)		70.30	69.47	86.54	70.97		
Total nøyaktighet = 77.11%							
Kappa = 0.68							

Den totale nøyaktigheten ble 77.11% med kappa på 0.68. Denne klassifiseringen fikk klart høyere nøyaktighet enn de foregående. Nøyaktigheten var høyest for Lind med 85.88% produsent nøyaktighet, mens Lønn, Eik og Kirsebær fikk en produsentnøyaktighet på henholdsvis 71.54 %, 70.30% og 70.00%.

### 9.3 Forskjellig antall kanaler og egenskaper

Klassifiseringer med forskjellig antall kanaler ga høyest total nøyaktighet og kappa for tre kanaler, henholdsvis 77.11% og 0.68. Dette var bare så vidt bedre enn to kanaler som fikk total nøyaktighet på 75.49% og kappa på 0.65. Klassifisering med en kanal ga total nøyaktighet på 71.75% og kappa på 0.60 (Tabell 9.4).

Tabell 9.4. Forskjell i nøyaktighet med forskjellige antall kanaler

	Total nøyaktighet	Kappa
Tre kanaler	77.11 %	0.68
To kanaler	75.49 %	0.65
En kanal	71.75 %	0.60

En McNemar test indikerte at det er signifikant forskjell mellom klassifisering med tre og en kanal på et 5% signifikansnivå ( $p = 0.0017$ ) (Tabell 9.5). Forskjellen mellom to og en kanal var også signifikant ( $p = 0.0276$ ). Forskjellen mellom tre og to kanaler var imidlertid ikke signifikant ( $p = 0.1655$ ).

Tabell 9.5. McNemar test på forskjellige antall kanaler. Tall markert med \* indikerer signifikant forskjell på 5% nivå

	Tre kanaler	To kanaler
To kanaler	0.1655	
En kanal	0.0017 *	0.0276 *

Klassifisering basert på forskjellige egenskaper viste at klassifisering ved bruk av struktur, intensitet, ratio og NDFI ga det beste resultatet med en total nøyaktighet på 77.11% og kappa på 0.60 (Tabell 9.6). Dette var bare marginalt bedre enn struktur og intensitet som ga en total nøyaktighet på 74.84% med kappa på 0.56. Kun bruk av høyde ga den dårligste totale nøyaktigheten på 56.01% med kappa på 0.28.

Tabell 9.6. Nøyaktighet med forskjellige egenskaper

	Total nøyaktighet	Kappa
Høyde	56.01 %	0.28
Struktur	62.34 %	0.36
Struktur + intensitet	74.84 %	0.56
Struktur + intensitet + ratio + NDFI	77.11 %	0.60

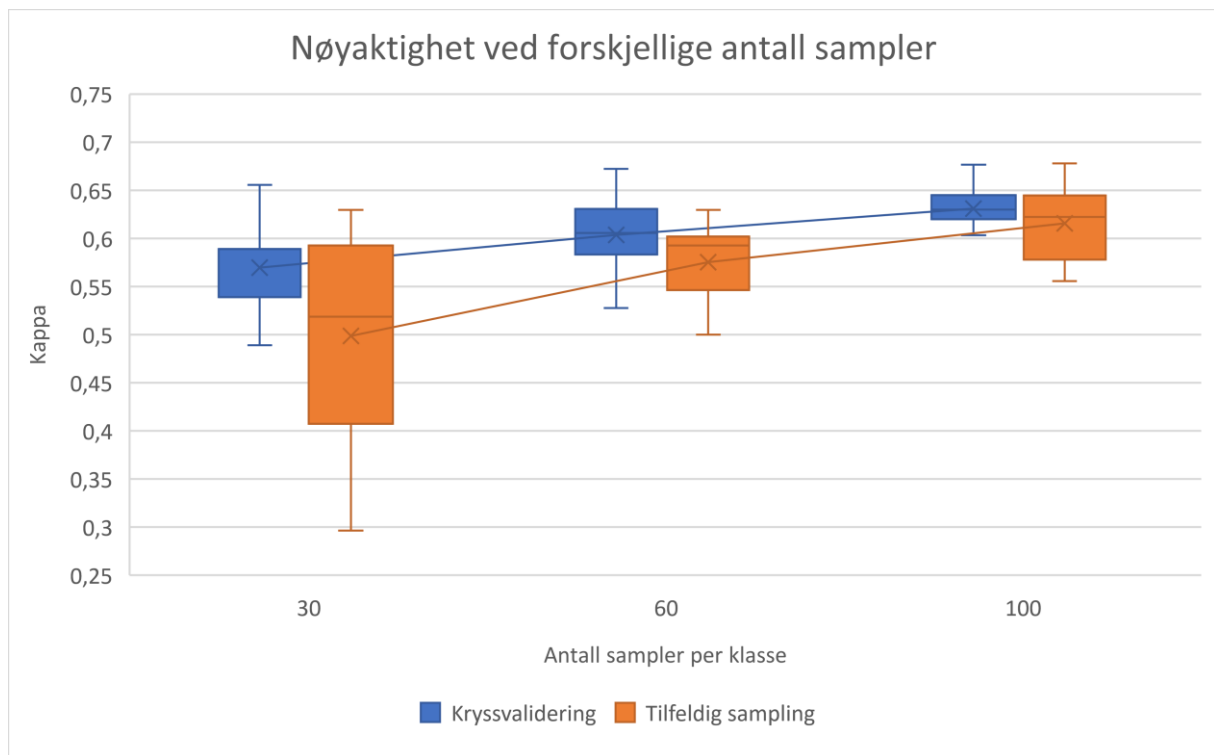
McNemar tester viste at klassifisering basert på høyde var signifikant dårligere enn klassifisering med alle de andre kombinasjonene på et 5% signifikansnivå (Tabell 9.7). Struktur og intensitet og struktur, intensitet, ratio og NDFI var begge signifikant bedre enn klassifisering kun basert på struktur. Forskjellen mellom bruk av struktur og intensitet kontra struktur, intensitet, ratio og NDFI var imidlertid ikke signifikant ( $p = 0.11$ ).

Tabell 9.7. McNemar test på forskjellige kombinasjoner av egenskaper. Tall markert med \* indikerer signifikant forskjell på 5% nivå

	Høyde	Struktur	Struktur + intensitet
Struktur	$5.5 \times 10^{-3}$ *		
Struktur + intensitet	$3.4 \times 10^{-14}$ *	$3.0 \times 10^{-8}$ *	
Struktur + intensitet + ratio + NDFI	$2.6 \times 10^{-17}$ *	$3.6 \times 10^{-11}$ *	0.11

## 9.4 Påvirkning av antall sampler

Figur 9.1 viser resultatet av testen som ble gjennomført for å se om antall sampler påvirker nøyaktigheten til klassifiseringen.



Figur 9.1. Nøyaktighet ved forskjellige antall sampler per klasse

Boksene viser hvor hoveddelene av dataene strekker seg over. Boksene lages ved først å ta medianen til alle dataene. Denne medianen er representert ved den horisontale streken inne i boksene. Deretter finner man medianene til de delene av dataene som er over og under medianen til hele datasettet. Dette gir den maksimale og den minimale utstrekningen til boksene. De ytterste strekene markerer de maksimale og de minimale verdiene for hele datasettet. Kryssene representerer gjennomsnittet.

Ved 100 sampler per klasse gir kryssvalidering og tilfeldig sampling omtrent samme resultat. Når antall sampler per klasse blir mindre synker kappaverdiene for både kryssvalidering og tilfeldig sampling. Nøyaktigheten synker raskere for tilfeldig sampling, og variasjonen i nøyaktigheten blir større, enn det gjør for kryssvalidering. Dette indikerer to ting. For det første indikerer det at hvis det er få sampler i klassene vil det påvirke nøyaktigheten til klassifiseringen negativt i forhold til om man har flere sampler per klasse. Det indikerer også at kryssvalidering gir et bedre resultat enn tilfeldig sampling. Viktig å presisere at dette gjelder for testområdet og at det ikke nødvendigvis ville blitt samme resultat med et annet område.

## 10 Diskusjon

Resultatene fra denne oppgaven er ikke direkte sammenlignbare med tidligere studier på området. Det er få studier som har blitt utført i urbane områder og da er det med et lite antall treslag (Budei et al. 2017). Studier som har klassifisert mange treslag har så vidt meg bekjent kun vært utført i skogsområder (Axelsson et al. 2018; Budei et al. 2017). Det er heller ingen tidligere studier som kun har klassifisert løvtrær. Flere av de tidligere studiene har hatt hovedvekt av gran og furu, noe som sannsynligvis er enklere enn å klassifisere ulike typer av løvtrær. Det er dermed grunn til å tro at hvis det hadde vært mer gran og furu i testområdet ville klassifiseringsnøyaktigheten i denne oppgaven blitt bedre.

Resultatene viser at multispektral laserskanning kan brukes til å klassifisere åtte treslag med en total nøyaktighet på 64.08% og kappa på 0.55. Ved å redusere antall tresorter blir nøyaktigheten høyere hvor beste scenario med fire treslag gir en total nøyaktighet på 77.11% og kappa på 0.68. Totalt sett indikere resultatene at ved å ta med mange tresorter gjør dette klassifiseringen vanskeligere. Det er imidlertid grunn til å tro at de ujevne klassestørrelsene har påvirket resultatet. Testen som ble gjort på antall sampler indikerer at nøyaktigheten går opp når antall sampler per klasse går opp. Ved å bruke kryssvalidering som samplingsmetode synes antall sampler ikke å ha like stor effekt på klassifiseringen enn om tilfeldig sampling hadde blitt benyttet. Men selv kryssvalidering viser en negativ trend når antall sampler per klasse går ned. Det indikerer at hvis det hadde vært flere klasser med et høyt antall sampler ville det gitt et bedre resultat på klassifiseringen.

Andelen detekterte trær på 65% ligger på nivå med tidligere studier (Yu et al. 2017). I denne oppgaven ble det ikke brukt like mye tid på segmenteringsprosessen som en normalt ville gjort. Dette var et valg som ble tatt på grunn av at hensikten med oppgaven var å se på om det er mulig å bruke multispektral laserdata til å klassifisere treslag, ikke å få til en «perfekt» segmentering. Ved å legge mer tid og arbeid i segmenteringen er det rimelig å tro at andelen detekterte trær ville vært større. Det ville også forbedret nøyaktigheten til segmenteringen, spesielt i områdene hvor trærne sto sammen i tette klynger. Strukturinformasjonen påvirkes når trærne står sammen i tette klynger. Trær som står tett sammen får en annen form og fasong enn trær som står mer for seg selv. Innenfor testområdet er det mange tilfeller av treklynger hvor alle trærne er av samme treslag. I disse klyngene hadde antageligvis ikke en bedre segmentering forbedret resultatet markant. Det er heller treklyngene med forskjellige tresorter hvor dette hadde utgjort en forskjell. Grunnen til dette er at trær av samme art i teorien gir lik returnert intensitet og da vil klynger av trær av samme treslag gi lik returnert intensitet for alle trærne.

Om segmenteringen da er feil blir ikke klassifiseringen påvirket i like stor grad siden intensitetsinformasjonen er lik for alle segmentene. For klynger av trær med ulike treslag blir det mer problematisk da de ulike trærne vil gi ulike intensitetsverdier og en dårlig segmentering kan gi feil i klassifiseringen.

Klassifisering med alle tre kanalene viste seg å ikke være signifikant bedre enn å bruke en to-kanals kombinasjon av MIR og NIR. Både klassifisering med tre og to kanaler var signifikant bedre enn å bare bruke en kanal. Resultatene tyder på at bruk av den grønne kanalen ikke gir et bedre resultat på nøyaktigheten til klassifiseringen. Da kan det være aktuelt å se på å kutte ut den grønne kanalen for oppdrag med klassifiseringsformål. Å kutte ut den grønne kanalen vil gi den fordelen at man kan fly høyere. Dette fører til at datainnsamlingen blir mer effektiv og gir dermed et billigere produkt (kapittel 8.7). Men vi vet ikke om resultatet blir like bra med høyere flyhøyde. For å oppnå like stor punkttetthet ved større flyhøyde må enten flyet kjøre saktere eller så må skannespeilet bevege seg raskere. Stråledivergensen vil også øke når flyhøyden øker. Økt stråledivergens fører til et større fotavtrykk på bakken som gir mindre nøyaktige målinger. Resultatet indikerer også at multispektral laserskanning gir et bedre resultat enn tradisjonell en-kanals laserskanning og at multispektral laserskanning vil være nyttig for klassifiseringsformål. Lavere punkttetthet kan være med på å forklare hvorfor resultatet blir dårligere med færre kanaler. Det er vanskelig å si hvor stor påvirkning det har på klassifiseringsnøyaktigheten.

For de ulike egenskapene var det struktur, intensitet, ratio og NDFI som ga den høyeste klassifiseringsnøyaktigheten med total nøyaktighet på 77.11% og kappa på 0.60. Det var ikke signifikant bedre enn ved å kun bruke struktur og intensitet som ga en total nøyaktighet på 74.84% og kappa på 0.56. En mulig forklaring på at bruk av ratio og NDFI ikke signifikant forbedret klassifiseringen kan være at testområdet er relativt lite. Innenfor et lite område vil det generelt være mindre variasjon i datasettet enn i et større område. Relative verdier vil antageligvis hjelpe mer i områder med mer variasjon i datasettet. En måte å teste det på hadde vært å bruke et større område, for eksempel hele Oslo innenfor byggesonen. Bruk av kun høyde ga et dårlig resultat og var signifikant dårligere enn alle de andre kombinasjonene av egenskaper. Dette tyder på at det ikke er store underliggende høydekorrelasjoner i datasettet. Struktur alene ga en total nøyaktighet på 63.34% og kappa på 0.36. Det var signifikant dårligere enn ved å legge til intensitet og intensitet, ratio og NDFI.

Bruk av Titan data fører med seg noen ulemper. For det første har Titan dataene ikke homogen punktfordeling. Punktavstanden er mye lavere i skannerretningen enn i flyretningen. For det andre fører ulik vinkling av kanalene til at punktene i de tre kanalene ikke registreres for samme posisjon på bakken. Det betyr at returene fra de forskjellige kanalene kan komme fra ulike steder i treet og de er dermed ikke direkte sammenlignbare, noe som kan påvirke klassifiseringsnøyaktigheten. Man er dermed nødt til å benytte objekt basert klassifisering, slik det er gjort i denne oppgaven, piksel- eller punktbasert klassifisering kan ikke utføres.

## 11 Konklusjon

I denne oppgaven har muligheten til å bruke multispektral laserdata fra Optech Titan til å klassifisere treslag i urbane områder blitt undersøkt. Resultatene viser at multispektral laserskanning kan brukes til å klassifisere treslag, hvor den beste modellen klassifiserte Eik, Kirsebær, Lind og Lønn med en total nøyaktighet på 77.11% med kappa på 0.68.

Oppgaven viser at tre og to kanaler gir et signifikant bedre resultat enn tradisjonell en-kanals laserskanning. Den stiller også spørsmålsteget ved nytteverdien til den grønne kanalen. Spesielt siden resultatet blir nesten like bra uten den grønne kanalen. Videre undersøkelser bør foretas for å undersøke om resultatet med to kanaler blir like bra når flyhøyden blir større.

Hvor mange sampler det er per klasse i klassifiseringen synes å også ha en effekt på det endelige resultatet. Et høyere antall sampler per klasse fører til at klassifiseringsnøyaktigheten stiger. Hvis det hadde vært flere klasser med et høyere antall sampler er det grunn til å tro at klassifiseringsresultatet ville blitt bedre, og flere enn fire treslag kunne bli brukt for å gi en god klassifiseringsnøyaktighet. Dette kunne vært gjort ved enten å utvide testområdet eller å registrere flere trær innenfor det nåværende testområdet.



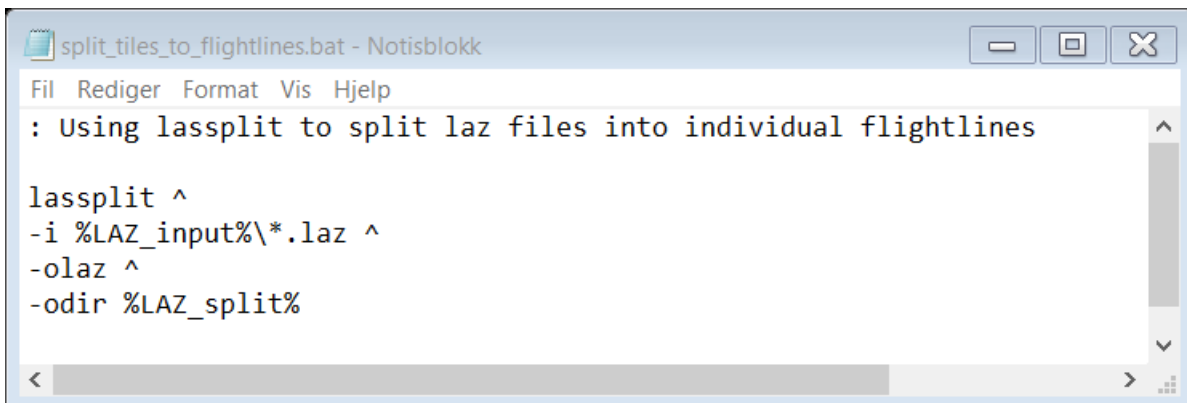
## 12 Referanseliste

- Ahokas, E., Hyyppä, J., Yu, X., Liang, X., Matikainen, L., Karila, K., Litkey, P., Kukko, A., Jaakkola, A. & Kaartinen, H. (2016). TOWARDS AUTOMATIC SINGLE-SENSOR MAPPING BY MULTISPECTRAL AIRBORNE LASER SCANNING. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences*, 41.
- Axelsson, A., Lindberg, E. & Olsson, H. (2018). Exploring Multispectral ALS Data for Tree Species Classification. *Remote Sensing*, 10 (2): 183.
- Bakuła, K. (2015). Multispectral airborne laser scanning—a new trend in the development of LiDAR technology. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, 27.
- Brownlee, J. (2016). *Overfitting and Underfitting With Machine Learning Algorithms*. Tilgjengelig fra: <https://machinelearningmastery.com/overfitting-and-underfitting-with-machine-learning-algorithms/>.
- Budei, B. C., St-Onge, B., Hopkinson, C. & Audet, F.-A. (2017). Identifying the genus or species of individual trees using a three-wavelength airborne lidar system. *Remote Sensing of Environment*.
- Dalpono, M., Bruzzone, L. & Gianelle, D. (2012). Tree species classification in the Southern Alps based on the fusion of very high geometrical resolution multispectral/hyperspectral images and LiDAR data. *Remote sensing of environment*, 123: 258-270.
- Donges, N. (2018). *The Random Forest Algorithm*. Tilgjengelig fra: <https://towardsdatascience.com/the-random-forest-algorithm-d457d499ffcd>.
- Dvergsdal, H. (2017). *Nevralt Nettverk*. Store norske leksikon. Tilgjengelig fra: [https://snl.no/nevralt\\_netverk](https://snl.no/nevralt_netverk).
- Foody, G. M. (2004). Thematic map comparison. *Photogrammetric Engineering & Remote Sensing*, 70 (5): 627-633.
- Fumo, D. (2017). *A Gentle Introduction To Neural Networks Series — Part 1*. Tilgjengelig fra: <https://towardsdatascience.com/a-gentle-introduction-to-neural-networks-series-part-1-2b90b87795bc>.
- Herries, D. (2014). *What is Plot Imputation and How Do You Generate Forest Yield Tables?* Tilgjengelig fra: <http://www.interpine.co.nz/news/Lists/Posts/Post.aspx?ID=213>.
- Holmgren, J. & Persson, Å. (2004). Identifying species of individual trees using airborne laser scanner. *Remote Sensing of Environment*, 90 (4): 415-423.
- Holmgren, J., Persson, Å. & Söderman, U. (2008). Species identification of individual trees by combining high resolution LiDAR data with multi-spectral images. *International Journal of Remote Sensing*, 29 (5): 1537-1552.
- Isenburg, M. (2014). *Rasterizing Perfect Canopy Height Models from LiDAR*. Tilgjengelig fra: <https://rapidlasso.com/2014/11/04/rasterizing-perfect-canopy-height-models-from-lidar/>.
- Isenburg, M. (2015). *Use Buffers when Processing LiDAR in Tiles*. Tilgjengelig fra: <https://rapidlasso.com/2015/08/07/use-buffers-when-processing-lidar-in-tiles/>.
- Isenburg, M. (2016). *Generating Spike-Free Digital Surface Models from LiDAR*. Tilgjengelig fra: <https://rapidlasso.com/2016/02/03/generating-spike-free-digital-surface-models-from-lidar/>.
- Khosravipour, A., Skidmore, A. K. & Isenburg, M. (2016). Generating spike-free digital surface models using LiDAR raw point clouds: A new approach for forestry applications. *International journal of applied earth observation and geoinformation*, 52: 104-114.
- Optech, T. (2015). *Optech Titan Multispectral Lidar System: High Precision Environmental Mapping*. <https://www.teledyneoptech.com/wp-content/uploads/Titan-Specsheet-150515-WEB.pdf>: Teledyne Optech (lest 23.01.18).
- Pfennigbauer, M. & Ullrich, A. (2011). *Multi-wavelength airborne laser scanning*. Proceedings of the International Lidar Mapping Forum, ILMF, New Orleans.
- Rostad, S. (2017). *Multispektral laserskanning: en revolusjon innenfor klassifisering av arealtyper og objekter?*: Norwegian University of Life Sciences, Ås.

- Spruyt, V. (2014). *The Curse of Dimensionality in classification*. Tilgjengelig fra: <http://www.visiondummy.com/2014/04/curse-dimensionality-affect-classification/>.
- Teo, T.-A. & Wu, H.-M. (2017). Analysis of Land Cover Classification Using Multi-Wavelength LiDAR System. *Applied Sciences*, 7 (7): 663.
- Viera, A. J. & Garrett, J. M. (2005). Understanding interobserver agreement: the kappa statistic. *Fam Med*, 37 (5): 360-363.
- Vosselman, G. & Maas, H.-G. (2010). *Airborne and terrestrial laser scanning*: Whittles Publishing.
- Yu, X., Hyyppä, J., Litkey, P., Kaartinen, H., Vastaranta, M. & Holopainen, M. (2017). Single-Sensor Solution to Tree Species Classification Using Multispectral Airborne Laser Scanning. *Remote Sensing*, 9 (2): 108.
- Ørka, H. O., Næsset, E. & Bollandsås, O. M. (2009). Classifying species of individual trees by intensity and structure features derived from airborne laser scanner data. *Remote Sensing of Environment*, 113 (6): 1163-1174.

## 13 Vedlegg

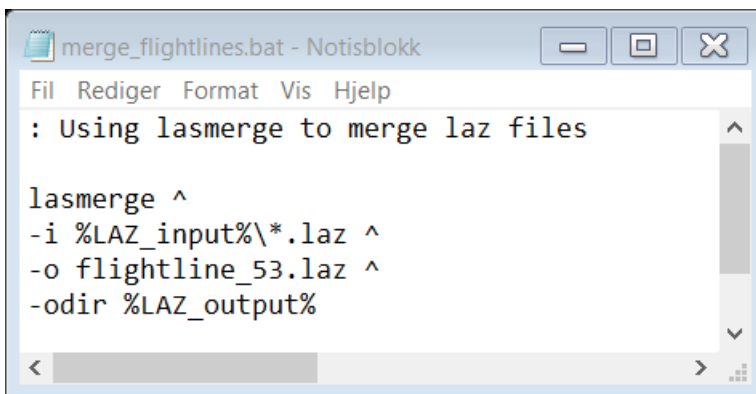
Batch skript for lassplit:



```
split_tiles_to_flightlines.bat - Notisblokk
Fil Rediger Format Vis Hjelp
: Using lassplit to split laz files into individual flightlines

lassplit ^
-i %LAZ_input%\*.laz ^
-olaz ^
-odir %LAZ_split%
```

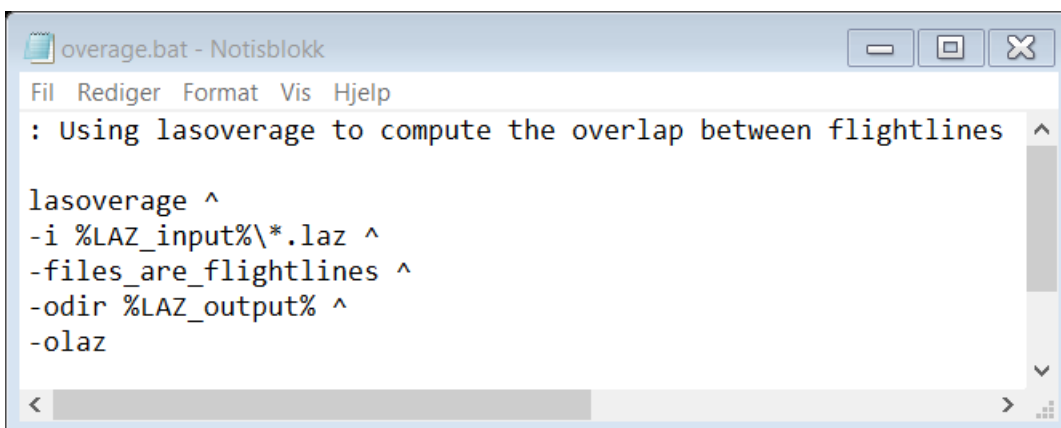
Batch skript for lasmerge:



```
merge_flightlines.bat - Notisblokk
Fil Rediger Format Vis Hjelp
: Using lasmerge to merge laz files

lasmerge ^
-i %LAZ_input%\*.laz ^
-o flightline_53.laz ^
-odir %LAZ_output%
```

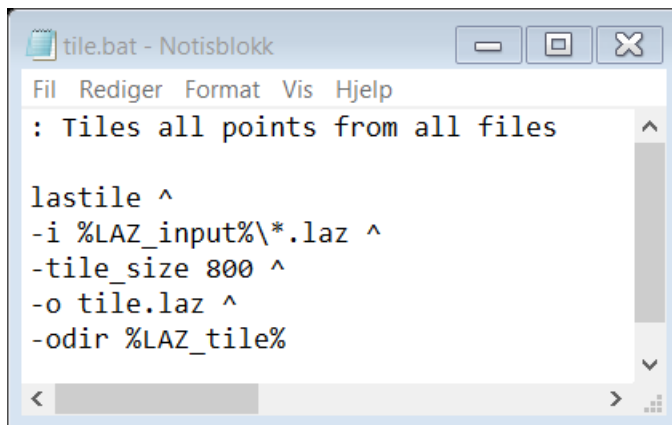
Batch skript for lasoverage:



```
overage.bat - Notisblokk
Fil Rediger Format Vis Hjelp
: Using lasoverage to compute the overlap between flightlines

lasoverage ^
-i %LAZ_input%\*.laz ^
-files_are_flightlines ^
-odir %LAZ_output% ^
-olaz
```

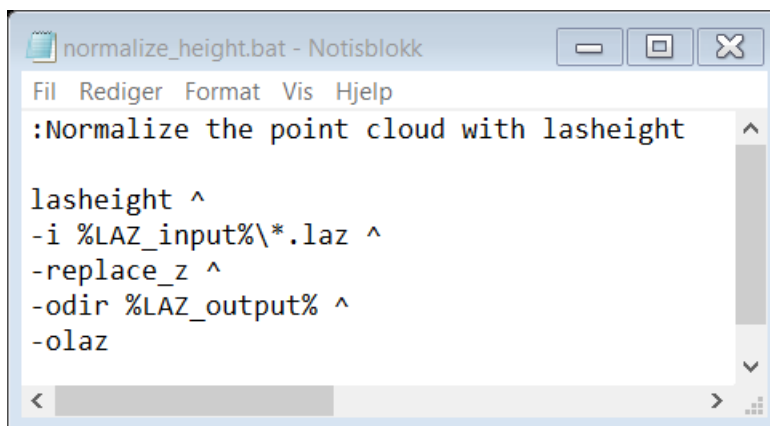
Batch skript for lastile:



```
tile.bat - Notisblokk
Fil Rediger Format Vis Hjelp
: Tiles all points from all files

lastile ^
-i %LAZ_input%\*.laz ^
-tile_size 800 ^
-o tile.laz ^
-odir %LAZ_tile%
```

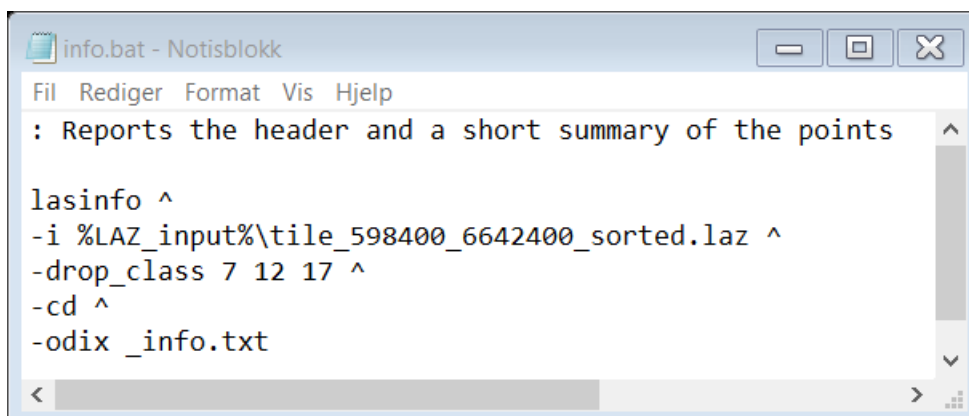
Batch skript for lasheight:



```
normalize_height.bat - Notisblokk
Fil Rediger Format Vis Hjelp
:Normalize the point cloud with lasheight

lasheight ^
-i %LAZ_input%\*.laz ^
-replace_z ^
-odir %LAZ_output% ^
-olaz
```

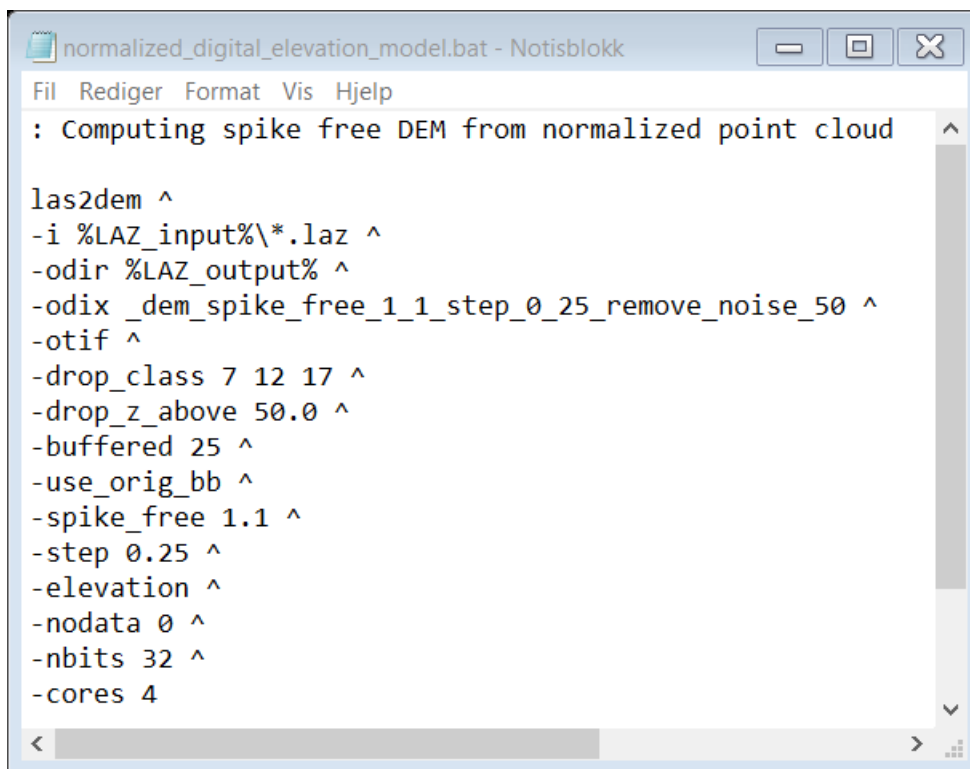
Batch skript for lasinfo:



```
info.bat - Notisblokk
Fil Rediger Format Vis Hjelp
: Reports the header and a short summary of the points

lasinfo ^
-i %LAZ_input%\tile_598400_6642400_sorted.laz ^
-drop_class 7 12 17 ^
-cd ^
-odix _info.txt
```

Batch skript for las2dem:

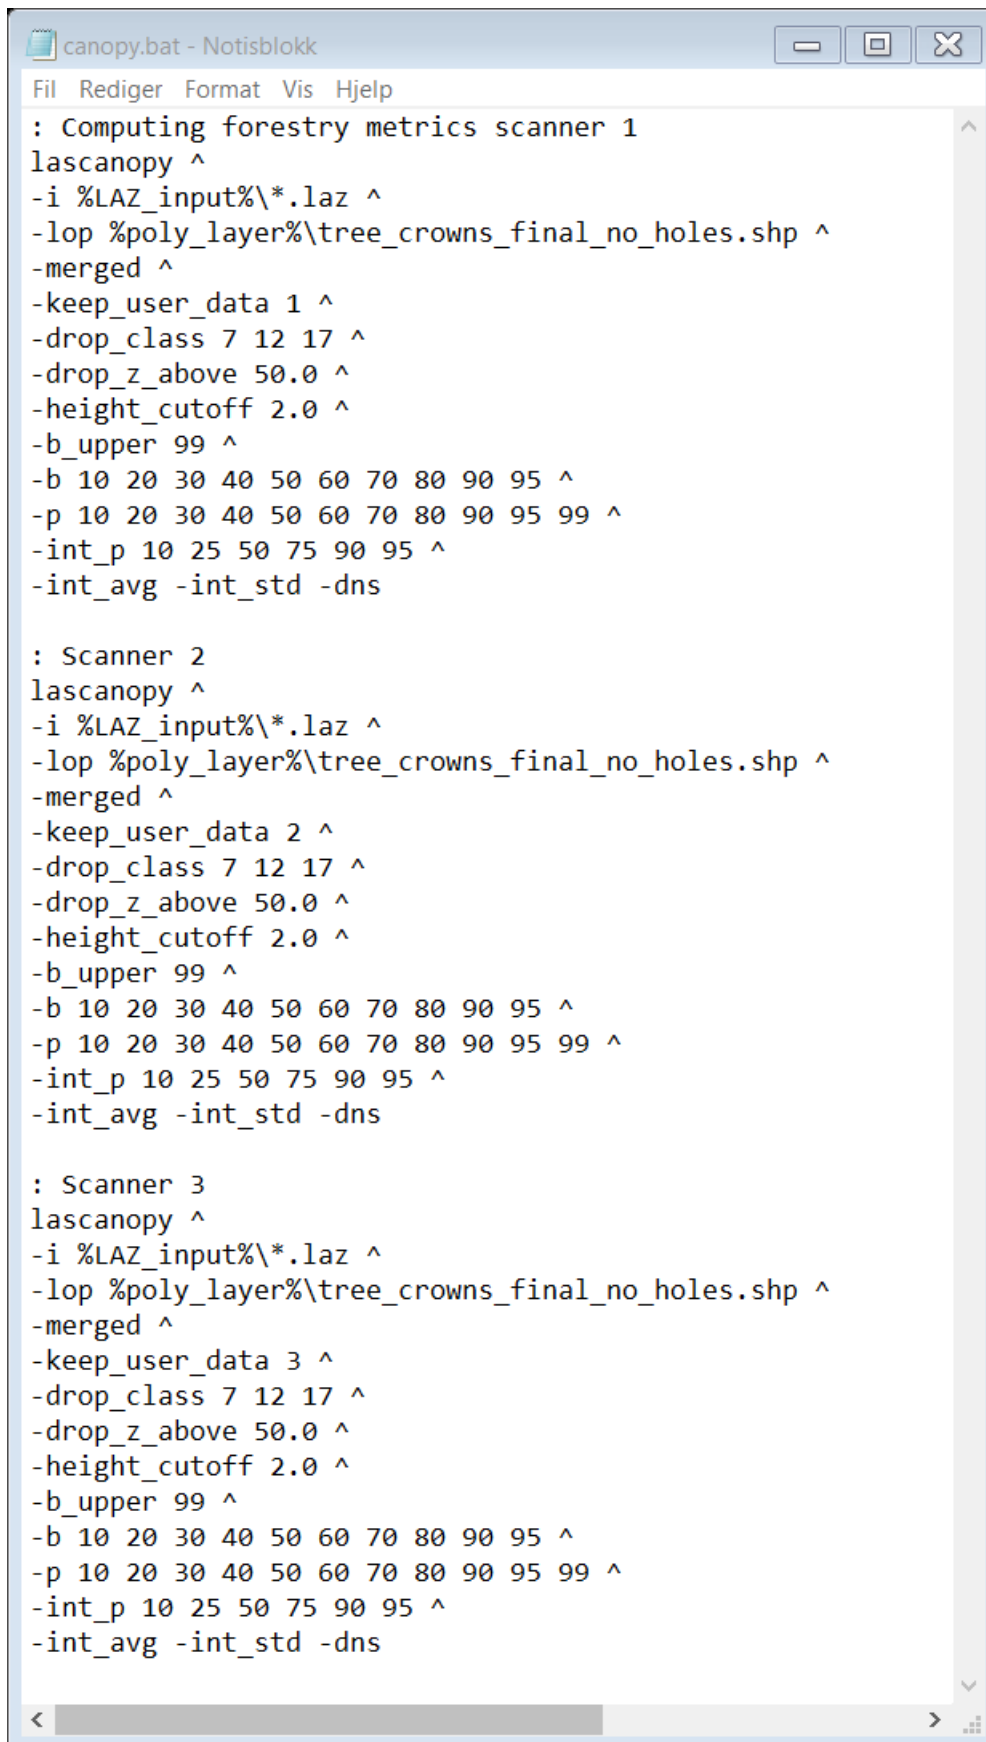


The image shows a screenshot of a Notisblokk window titled "normalized\_digital\_elevation\_model.bat - Notisblokk". The window contains a batch script for processing LAZ files into a DEM. The script uses the las2dem command with various options for input/output paths, noise removal, and processing parameters. The menu bar includes "Fil", "Rediger", "Format", "Vis", and "Hjelp".

```
normalized_digital_elevation_model.bat - Notisblokk
Fil Rediger Format Vis Hjelp
: Computing spike free DEM from normalized point cloud

las2dem ^
-i %LAZ_input%\*.laz ^
-odir %LAZ_output% ^
-odix _dem_spike_free_1_1_step_0_25_remove_noise_50 ^
-otif ^
-drop_class 7 12 17 ^
-drop_z_above 50.0 ^
-buffered 25 ^
-use_orig_bb ^
-spike_free 1.1 ^
-step 0.25 ^
-elevation ^
-nodata 0 ^
-nbits 32 ^
-cores 4
```

Batch skript for lascanopy:



```
canopy.bat - Notisblokk
Fil Rediger Format Vis Hjelp
: Computing forestry metrics scanner 1
lascanopy ^
-i %LAZ_input%\*.laz ^
-lop %poly_layer%\tree_crowns_final_no_holes.shp ^
-merged ^
-keep_user_data 1 ^
-drop_class 7 12 17 ^
-drop_z_above 50.0 ^
-height_cutoff 2.0 ^
-b_upper 99 ^
-b 10 20 30 40 50 60 70 80 90 95 ^
-p 10 20 30 40 50 60 70 80 90 95 99 ^
-int_p 10 25 50 75 90 95 ^
-int_avg -int_std -dns

: Scanner 2
lascanopy ^
-i %LAZ_input%\*.laz ^
-lop %poly_layer%\tree_crowns_final_no_holes.shp ^
-merged ^
-keep_user_data 2 ^
-drop_class 7 12 17 ^
-drop_z_above 50.0 ^
-height_cutoff 2.0 ^
-b_upper 99 ^
-b 10 20 30 40 50 60 70 80 90 95 ^
-p 10 20 30 40 50 60 70 80 90 95 99 ^
-int_p 10 25 50 75 90 95 ^
-int_avg -int_std -dns

: Scanner 3
lascanopy ^
-i %LAZ_input%\*.laz ^
-lop %poly_layer%\tree_crowns_final_no_holes.shp ^
-merged ^
-keep_user_data 3 ^
-drop_class 7 12 17 ^
-drop_z_above 50.0 ^
-height_cutoff 2.0 ^
-b_upper 99 ^
-b 10 20 30 40 50 60 70 80 90 95 ^
-p 10 20 30 40 50 60 70 80 90 95 99 ^
-int_p 10 25 50 75 90 95 ^
-int_avg -int_std -dns
```





**Norges miljø- og biovitenskapelige universitet**  
Noregs miljø- og biovitenskapelige universitet  
Norwegian University of Life Sciences

Postboks 5003  
NO-1432 Ås  
Norway