



Norges miljø- og
biovitenskapelige
universitet

Masteroppgave 2017 30 stp
Fakultet for realfag og teknologi

Multispektral laserskanning. En revolusjon innenfor klassifisering av arealtyper og objekter?

Multispectral Laserscanning.
A revolution within object- and landcover
classification?

Stian Rostad
Geomatikk

Sammendrag

Flybåren laserskanning har i løpet av de siste tiårene blitt en ideell datainnsamlingsmetode for kartlegging, modellering og romlig analyse. Høyoppløselige og nøyaktige laserskannere har gjenskapt terreng og overflater i form av punktskyer. Mangel på spektralinformasjon har vært en svakhet ved klassifisering av objekter og arealtyper i slike punktskyer. Tidligere laserskannere har ikke vært i stand til å samle inn spektralinformasjon, som derfor har kommet fra fly- og satellittbilder. I 2014 lanserte Teledyne Optech den flybårne laserskanneren Optech Titan. Ved å ta i bruk tre laserkanaler med forskjellig bølgelengde, kunne laserskanneren samle inn spektralinformasjon direkte i punktskyen.

Denne oppgaven fokuserer på tilleggsverdiene multispektrale laserdata gir i klassifiseringssammenheng. To datasett fra Optech Titan har blitt analysert. Disse er produsert av Terratec AS. Ulike kombinasjoner av laserkanalene har blitt brukt i klassifisering av objekter og arealtyper. Sammenligninger av klassifiseringsresultater basert på multi-, dual- og monospektrale egenskaper er gjort for å finne tilleggsverdier i multispektral klassifisering. Random Forest og Support Vector Machine er blant flere klassifiseringsmetoder brukt for et optimalt resultat.

Resultatene bekrefter at det finnes tilleggsverdi i multispektral laserskanning. Typiske overflater som gress, mark, grus, asfalt, jorder, skog og vann kunne med multispektrale egenskaper klassifiseres med 82,2% nøyaktighet ($\kappa = 0,80$), i motsetning til 75,4% ($\kappa = 0,69$) med monospektrale egenskaper. Mer nyanserte overflater kunne også klassifiseres bedre multispektralt. Det er i hovedsak overflater med lik geometri og monospektralt utseende som skiller seg fra hverandre når tre laserkanaler brukes i multispektral klassifisering. Optech Titan har stort potensiale til å forbedre tradisjonelle klassifiseringsmetoder.

Abstract

Over the past few decades, airborne laserscanning (ALS) has become an ideal data-acquisition method for modelling, mapping and spatial analysis. With high resolution and accuracy, laserscanners have been creating terrain- and surface models from point clouds. But the lack of spectral information in point clouds has weakened object- and landcover classification accuracy. Previous laserscanners has not been able to acquire spectral information. This has rather been acquired from aerial and satellite imagery. In 2014, Teledyne Optech introduced Optech Titan. Combining three laser channels with different wavelengths, the scanner could acquire spectral information directly from the point cloud.

This thesis is concerned with the additional value that multispectral laser data brings to classification performance. Two sets of point cloud data produced by Terratec AS have been analyzed. Combinations of features from three channels have been used for objects and landcover classification. Additional values are found by comparing results from different classifications based on multi-, dual-, and monospectral features. Random Forest and Support Vector Machine are among several classification methods used to optimize the results.

The results confirm that additional value exists in multispectral laserscanning. Common surfaces like grass, soil, gravel, asphalt, fields, forest and water were correctly classified with accuracy by 82,2% ($\kappa = 0,80$), compared to 75,4% ($\kappa = 0,69$) when using only monospectral features. More specific surfaces were also classified more accurate with multispectral features. It's mainly surfaces with equal geometry and monospectral appearance that improves in classification when three laser channels are used. Optech Titan has great potential to improve traditional classification methods.

Forord

Etter fire måneder med et arbeid som definerer min finaleopptreden som student, har lange dager (og netter) samt god hjelp fra veiledere, kjente og kjære, ført frem til et resultat jeg er stolt av å presentere som min masteroppgave. Først og fremst vil jeg takke min biveileder, Floris Groesz, prosjektleder i Blom. Floris har ledet meg i riktig retning gjennom hele prosessen. Fra oppgavens opprinnelse til siste dag før innlevering. Min hovedveileder Ivar Maalen-Johansen fortjener også en stor takk for stødig veiledning der det har vært behov for det. Jeg vil også takke resten av Blom, som har gitt meg en masterplass med tilgang på data, verktøy, kaffe og god hjelp fra hyggelige kollegaer med kompetanse i faget. Terratec skal også takkes for bidrag med datagrunnlag til oppgaven. For øvrig vil Luis Barreiro, Pål Nylund, Andreas Mathisen Tanner, Vegard Engen og Sigurd Hynne takkes for å ha hjulpet med relevant informasjon som gjorde oppgaven komplett.

En hjertelig takk går ut til mine foreldre, for støtte og korrekturlesing. Venner og kjære takkes også for å ha gjort mitt siste semester som student både innholdsrikt og spennende også utenom arbeidstiden. Spesielt takk til Anne Marte Henriksen, som har motivert meg til å gjøre mitt aller beste.

Innholdsfortegnelse

1	FIGURER	XI
2	TABELLER	XIII
3	INNLEDNING	1
3.1	BAKGRUNN.....	1
3.2	DETTE SKAL GJØRES	2
3.3	TEKNOLOGIENS POTENSIAL	3
3.4	LASERSKANNING OG KLASSIFISERING	4
3.5	TIDLIGERE FORSKNING	4
4	TEORI	7
4.1	LASER.....	7
4.2	LIDAR (LIGHT DETECTION AND RANGING)	8
4.3	FLYBÅREN LASERSKANNING.....	10
4.4	STRÅLING, ABSORBERING OG REFLEKSJON	12
4.5	MULTIDIMENSJONAL KLASSIFISERING	14
5	UTSTYR OG METODE	19
5.1	UTSTYR.....	19
5.1.1	<i>Optech Titan</i>	19
5.1.2	<i>Datagrunnlag</i>	20
5.1.3	<i>Programvare og filformater</i>	24
5.2	METODE	28
5.2.1	<i>Optech Titans laserkapasitet</i>	28
5.2.2	<i>Klassifisering av multispektrale laserdata fra Optech Titan</i>	29
5.2.3	<i>Konseptuelt produkt</i>	33
6	OPTECH TITANS KAPASITET	35
6.1	VURDERING AV DATASETT.....	35
6.1.1	<i>Punktfordeling</i>	35
6.1.2	<i>Intensitetsverdier</i>	37
6.1.3	<i>Kanalforskjeller</i>	38
6.1.4	<i>Punktsky-matching</i>	39
6.2	FREMGANGSMÅTE	40
6.2.1	<i>Datsett Rakkestad</i>	40
6.2.2	<i>Filtrering av punkter</i>	41
6.2.3	<i>Utvalg av arealoverflater</i>	41

6.2.4	<i>Teoretiske verdier</i>	43
6.3	RESULTATER OG ANALYSE	44
7	KLASSIFISERING AV MULTISPEKTRALE LASERDATA FRA OPTECH TITAN	49
7.1	FREMGANGSMÅTE	49
7.1.1	<i>Datsett Alvdal</i>	49
7.1.2	<i>Rasterkonvertering</i>	50
7.1.3	<i>Segmentering</i>	50
7.1.4	<i>Klasseinndeling</i>	51
7.1.5	<i>Kombinering av laser- og vektordata</i>	54
7.1.6	<i>Tabellsammenslåing og optimalisering</i>	55
7.1.7	<i>Klassifisering av data</i>	56
7.2	RESULTATER OG ANALYSE	64
7.2.1	<i>Hovedfunn</i>	64
7.2.2	<i>Primærklasser</i>	65
7.2.3	<i>Sekundærklasser</i>	73
7.2.4	<i>Enkeltrær</i>	87
7.2.5	<i>Polygonvisualisering</i>	90
7.3	HELHETLIG VURDERING	93
8	KONKLUSJON	97
9	REFERANSELISTE	99
10	VEDLEGG	103

1 Figurer

Figur 3.1: Oversikt over oppgavens oppbygning	3
Figur 4.1: Det elektromagnetiske spekter.	8
Figur 4.2: Irregulær punktavstand.....	11
Figur 4.3: Delaunay-triangulering.....	12
Figur 4.4: Det elektromagnetiske spekteret. (Shapley 2012).....	13
Figur 4.5: Reflektanskurver.....	13
Figur 4.6: Illustrasjon av Random Forest klassifiseringsmetoden.	16
Figur 4.7: Overfitting.	16
Figur 4.8: Prinsippet i forvirringsmatrisen.	17
Figur 5.1: Optech Titans laserkanaler.	20
Figur 5.2: Utsnitt fra FMS Planner.....	21
Figur 5.3: Arbeidsflyt for filformater og programvare.	25
Figur 5.4: Metode for innledende del av oppgaven.	29
Figur 5.5: Arbeidsflyt for klassifisering og analyse av data.	31
Figur 5.6: Arbeidsflyt for databehandling.....	32
Figur 5.7: Konseptuell utgave av metode for produktgrunnlag.	33
Figur 6.1: Teoretisk representasjon av Optech Titans skannemønster.....	35
Figur 6.2: Utsnitt av Optech Titans faktiske punktfordeling.	36
Figur 6.3: Utsnitt fra LAStools viser ujevnheten i punktfordeling.	36
Figur 6.4: Utsnitt fra LAStools over Alvdal viser ujevnheter i intensitet.	37
Figur 6.5: Punktfordelingen ved flygning på 1600 m	38
Figur 6.6: Utsnitt fra LAStools over skogsområde i Rakkestad.	39
Figur 6.7: Polygonutvalg for vurdering av punkttetthet.....	41
Figur 6.8: Oversikt over FMS Planners brukergrensesnitt.....	43
Figur 6.9: Reflektansverdier for asfalt og gress.	45
Figur 7.1: Utsnitt fra rasterrepresentasjoner av punktskyen.	50
Figur 7.2: Flerlags segmentering.....	51
Figur 7.3: Manuelle shape-polygoner basert på WMS og FKB.....	51
Figur 7.4: Oversikt over alle klasser.	53
Figur 7.5: Distribusjonsplott for antall utvalgte polygoner til primærklassifisering.....	57
Figur 7.6: Grafer for klassifisering.....	61
Figur 7.7: Klassifiseringsnøyaktighet for forskjellige egenskapsutvalg.	62

Figur 7.8: Antall verdier for gjennomsnittlig intensitetsverdier for MIR-kanalen	63
Figur 7.9: Histogram for fordeling av gjennomsnittlige intensitetsverdier, primærklasser.	65
Figur 7.10: Multiplott av polygoner	66
Figur 7.11: Faktiske reflektansverdier mot registrerte intensitetsverdier	79
Figur 7.12: Histogram for gjennomsnittlige intensitetsverdier (sekundærklasser).	81
Figur 7.13: Multiplott av alle sekundærklasser.	83
Figur 7.14: De klassifiserte enkeltrærnes utseende.	87
Figur 7.15: Histogram for fordeling av gjennomsnittlige intensitetsverdier, tresorter.	87
Figur 7.16 Multiplott av tresorter.	88
Figur 7.17: Polygonvisualisering for primær- og sekundærklassene.	91
Figur 7.18: Polygonvisualisering for enkeltrær.	92

2 Tabeller

Tabell 5.1: Spesifikasjoner for Optech Titan.	20
Tabell 5.2: Data hentet fra FMS Planner.....	21
Tabell 5.3: Spesifikasjoner for Rakkestad-flygningen.	22
Tabell 5.4: Spesifikasjoner for Alvdal-flygningen.....	23
Tabell 5.5: Spesifikasjoner for Alvdal-flyfotografering.	23
Tabell 6.1: Punkttetthet i hvert utvalg, pr. klasse, pr. flyhøyde.	42
Tabell 6.2: Samlet og separat punkttetthet for de tre laserkanalene.....	44
Tabell 6.3: Forholdet mellom teoretisk og faktisk punkttetthet i prosent.	44
Tabell 6.4: Interpolerte verdier for antall returnerte pulser for flygning ved 1900 m.....	46
Tabell 7.1: Oversikt over alle statistiske egenskaper kalkulert av lascanopy.	55
Tabell 7.2: Oversikt over alle egenskaper i komplett datasett.	56
Tabell 7.3: Oversikt over egenskaper som brukes	59
Tabell 7.4: Oversikt over parameterinnstillinger for de ulike klassifiseringsmetodene	63
Tabell 7.5: Kappa-verdi for de ulike klassifiseringene.	64
Tabell 7.6: Beskrivelse av de aktuelle klassene i primærklassifiseringen	65
Tabell 7.7: Forvirringsmatrise for klassifisering med 3 kanaler (primærklasser).....	67
Tabell 7.8: Klassifiseringsnøyaktighet med 3 kanaler (primærklasser).	67
Tabell 7.9: Klassifiseringsnøyaktighet pr. klasse med 3 kanaler (primærklasser).....	69
Tabell 7.10: Forvirringsmatrise for klassifisering med 2 kanaler (primærklasser).....	69
Tabell 7.11: Klassifiseringsnøyaktighet med 2 kanaler (primærklasser).	69
Tabell 7.12: Klassifiseringsnøyaktighet for dualspektral klassifisering. (Primærklasser).....	70
Tabell 7.13: Forvirringsmatrise for klassifisering med 1 kanal (primærklasser).	70
Tabell 7.14: Klassifiseringsnøyaktighet med 1 kanal (primærklasser).	71
Tabell 7.15: Klassifiseringsnøyaktighet for monospektral klassifisering med MIR-kanal.....	72
Tabell 7.16: Eksempelutsnitt av klassene finnes i kapittel 7.1.....	74
Tabell 7.17: Forvirringsmatrise for klassifisering med multispektrale egenskaper.	75
Tabell 7.18: Klassifiseringsnøyaktighet samlet med avvik. (sekundærklasser).....	75
Tabell 7.19: Klassifiseringsnøyaktighet pr. klasse (sekundærklasser).....	77
Tabell 7.20: Klassifiseringsnøyaktighet med 1 kanal. Avvik fra 3 kanaler til venstre.	78
Tabell 7.21: Klassifiseringsnøyaktighet samlet med avvik. (Enkeltrær)	89
Tabell 7.22: Klassifiseringsnøyaktighet sammenlignet (Enkeltrær).	89
Tabell 7.23: Forvirringsmatriser sammenlignet med ulike egenskapsutvalgene (Enkeltrær). 90	

Tabell 7.24 Eksempel på klassifisert polygon i tabellformat 90

3 Innledning

Med en stadig teknologisk utvikling innen flybåren laserskanning, har nøyaktige, høyoppløselige, tredimensjonale terreng- og overflatemodeller blitt et nyttig verktøy innenfor kartlegging, planlegging og analyse. I 2014 lanserte Teledyne Optech verdens første kommersielle laserskanner med multispektrale egenskaper. Med sine tre laserkanaler tok Optech Titan laserskanning til et nytt nivå. Koordinatmålinger var ikke lengre det eneste en laserskanner kunne brukes til. Med laser på tre ulike bølgelengder, vil forskjellige overflater, som løv, asfalt og jord, reflektere og absorbere forskjellige mengder lys. Dette er et godt utgangspunkt for å identifisere og klassifisere forskjellige typer overflater i terrenget. Med Optech Titan kan laserskanning og multispektral analyse kombineres for første gang. Dette kan gi laserskanneren nye arbeidsoppgaver, og potensielt gi bedre resultater enn hva andre, passive systemer har kapasitet til. Dette har ledet til problemstillingen:

«Hvilken tilleggsverdi har multispektrale laserdata fra Optech Titan, i forhold til tradisjonelle laserdata, ved klassifisering av objekter og areal typer i en punktsky.»

Andre, passive systemer for spektral datafangst, som f.eks. nærinfrarøde (NIR) kamera, påvirkes av bl.a. toveis refleksjon, solretning og skyer. Derfor kan aktiv, multispektral skanning være en attraktiv løsning for både geometrisk og radiometrisk nøyaktighet, fullstendighet og pålitelighet (Ahokas et al. 2016). Ved klassifisering er dette viktig. Data fra flybåren laserskanning klassifiseres i dag ved hjelp av høydeinformasjon. Å se på hvilken tilleggsverdi multispektral informasjon har for klassifisering, vil potensielt kunne forbedre og utvide bruksområde for flybåren laserskanning i fremtiden.

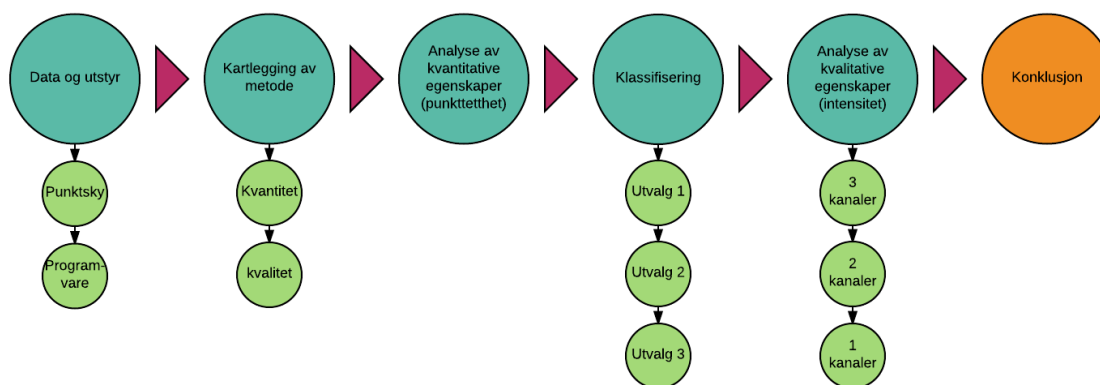
3.1 Bakgrunn

Tidligere har flybåren laserskanning blitt gjort med laserskannere bestående av én enkelt laserkanal. Dette har gjort det mulig å samle store mengder data på kort tid, til store kostnadsbesparelser. Selv om dette er en effektiv metode for datainnsamling, begrenser informasjonsmengden pr. skannede punkt seg til geometrisk posisjon i tre dimensjoner. I 2014 lanserte laserskannerprodusenten Teledyne Optech, en ny og unik laserskanner med tittelen Optech Titan. Istedenfor å skanne med én kanal, ble tre laserkanaler med forskjellige bølgelengdeegenskaper brukt, for å også kunne si noe om hva som ble skannet. I tillegg til nøyaktig stedfestelse og høy oppløsning, hevdet Teledyne Optech at Titan kunne identifisere overflatetyper, kartlegge vegetasjon, samt gjøre batymetriske målinger i vann, basert på kombinasjonen av tre ulike sensorer. Dermed ble Titan kalt den første kommersielle

multispektrale laserskanneren på markedet (Optech 2015). Med andre ord skulle Titan gjøre det aller meste av flybåren datafangst med kun ett enkelt sensordesign. Titan har i senere tid vist seg å ha forbedringspotensial (Ahokas et al. 2016; Bakula 2015; Wichmann et al. 2015), men et multispektralt lasersystem brukt til flybåren laserskanning er både interessant og høyt etterspurt i oppmålingsbransjen (Sitar et al. 2015). Det er derfor interessant å se på tilleggsverdiene Optech Titan har, med sitt enestående tre-kanals system. Skal den videre utviklingen av flybåren laserskanning ta med seg egenskapene Optech har introdusert? Det er flere aspekter ved flybåren laserskanning som kanskje kan forbedres med et tre-kanals system. Klassifisering basert på de spektrale egenskapene dette systemet tilbyr, blir drøftet i denne oppgaven. Det er tilleggsverdiene fra et multispektralt lasersystem som står i fokus. Kvaliteten på dataene vil bli drøftet, men det tas høyde for at disse vil forbedres i fremtiden. Optech Titan er foreløpig den eneste skanneren i sin klasse, og data fra dette systemet er derfor naturlig å ta i bruk.

3.2 Dette skal gjøres

Laserdata fra laserskanneren Optech Titan skal analyseres, for å finne ut hvilke tilleggsverdier knyttet til klassifisering, som ligger i datasett bestående av laserdata fra tre laserkanaler. Først skal en analyse av punktetthet fra skannede flystriper ved forskjellige høyder svare på laserkanalenes kvantitative ytelse. Altså hvor mye data systemet er i stand til å fange opp. Deretter vil diverse egenskaper fra laserdataene testes kvalitativt, ved å bruke dem i tre utvalg til klassifisering av forskjellige typer objekter og arealtyper fra en punktsky. Klassifiseringen, og veien frem til den, presenteres også som et konseptuelt produkt. Der forbedringspotensialet drøftes. Klassifiseringen gjort i oppgaven blir grunnlaget for analyse. Egenskaper basert på tre, to og én laserkanal vil sammenlignes for å kunne avgjøre hvilke tilleggsverdier som finnes i et system med multispektrale egenskaper, kontra et med dual- og monospektrale egenskaper. Data fra Optech Titan vil dermed bli behandlet i tre separate prosesser, med tre forskjellige egenskapsutvalg. Til slutt vil resultatet av hver prosess drøftes opp mot hverandre.



Figur 3.1: Oversikt over oppgavens oppbygning

Oppgaven vil utføres ved hjelp av en rekke programvare. Noe er åpent, men det meste lånes av Blom AS. Skriveprogrammer er tilgjengeliggjort av NMBU (Norges miljø- og Biovitenskapelige Universitet). Data er tilgjengeliggjort gjennom Blom AS og Terratec AS. Programvare og data er kombinert sammen med manuelle operasjoner og skript for å gjennomføre oppgaven.

3.3 Teknologiens potensial

Selv om ortofoto har et bedre spektralt grunnlag for klassifisering av forskjellige terrengoverflater, har ikke dette datagrunnlaget på langt nær like bra vertikal oppløsning som LiDAR-punktskyen fra en flybåren laserskanner. Flybåren laserskanning er effektivt og kostnadsbesparende, og gir informasjonsrike resultater. Aktive sensorer er i stand til å skanne både på dag- og nattetid. Samt at de ikke lar seg påvirke av sollys, solvinkel og toveis refleksjon på samme måte som passive sensorer (Ahokas et al. 2016). De viser også alltid overflater i nullgraders vinkel fra nadir. Tradisjonell flybåren laserskanning gir likevel ingen intuitive indikatorer på hva slags type overflater som skannes. Med multispektrale egenskaper i laserdataene skilles karakteristikken i overflater som skannes, og forbedrer de direkte klassifiseringsmulighetene. Dette være å klassifisere overflate-materiale, enkelttrær- og skogegenskaper m.m. Oppgaver som tidligere har blitt løst ved å ta i bruk kombinasjoner av laserdata og fotogrammetri. Disse metodene har svakheter, som at tid for datafangst ikke stemmer overens, og at sammenslåing av forskjellige dataformater blir en kompleks operasjon, noe som hindrer effektiviteten i produksjonen.

I en punktsky bestående av både høyde- og intensitetsdata, vil vi kunne få et spektralt grunnlag tilnærmet ortofoto, samt den vertikale oppløsningen fra LiDAR-punktskyen. Dette har potensiale til å øke kvaliteten på klassifiseringsmetodene som brukes i dag. Intensitetsverdiene kan korrigere feil i en geometrisk basert klassifisering, samt dele store klasser inn i mindre, mer

spesifikke klasser. For en byplanlegger kan oversikt over materialtyper i et urbant område være nyttig for alt fra innbyggertrivsel til håndtering av krisesituasjoner. I arkeologi kan multispektral laserskanning finne skjulte spor av bebyggelse under vegetasjon (Briese et al. 2013). Forandringsdeteksjon kan også gjøres i miljøstudier eller kartoppdatering (Matikainen et al. 2016). Spesielt innenfor skoganalyse vil en slik punktsky være et nyttig datagrunnlag, der både geometrien, samt de karakteristiske spektralegenskapene til hver enkel tresort har potensiale til å identifiseres i én og samme punktsky (Thomas 2015; Yu et al. 2017). Å basere all etterprosessering til forskjellige kartleggingsformål på kun ett enkelt datasett kan korrigere feil i nåværende metoder, og er mer effektivt og kostnadsbesparende enn ved å benytte data fra mange innsamlinger (Bakula 2015).

3.4 Laserskanning og klassifisering

Flybåren laserskanning kan ved hjelp av LiDAR-systemer, GPS og IMU, konstruere digitale 3D-representasjoner av terrenget, med relativt høy nøyaktighet (Vosselman & Maas 2010). Disse representasjonene består i utgangspunktet av store mengder punkter som sammen danner en punktsky. Dette er et nyttig verktøy for kartlegging, analyse og planlegging. Det kan i mange sammenhenger være aktuelt å ha mer informasjon om hva som befinner seg i punktskyen. Det er derfor utviklet metoder for klassifisering av punkter og objekter i punktskyer. Disse metodene består som regel av et sett med algoritmer som gir hvert punkt en klassesilhørighet, basert på punktets egenskaper, i sammenheng med nærliggende punkter. Morfologiske filtre og «region-growing»-algoritmer har tidligere blitt brukt for å klassifisere de største ulikhetene i punktskyen (Vosselman & Maas 2010). Statistiske analyser har i senere tid også blitt brukt til å skille mer spesifikke klasser fra hverandre. Som tresorter og forskjellige overflatematerialer. I motsetning til fotogrammetri, når laserskannere til under skogkledde områder. Selv om teksturen er klarere i bilder, har punktskyen den egenskapen at alle teksturer er geometrisk korrekte. Både i størrelse og posisjon. Dette gjelder ikke i bilder, der målestokk og fortegnings må korrigeres for. Fotogrammetri kan korrigere for dette, men vil fortsatt ikke nå til under vegetasjon. Derfor er klassifisering av objekter og overflater i en punktsky langt mer formålstjenlig, men også vanskeligere å oppnå (Vosselman & Maas 2010).

3.5 Tidligere forskning

Klassifisering av laserdata basert på intensitetsverdier ble allerede i 2002 forsøkt gjennomført. Forsøket konkluderte med at intensitetsverdier kan brukes til klassifisering, men at forbedringspotensialet var stort (Song 2002). Ved å interpolere intensitetsverdiene, samt utvikle filter for støyfjerning mente Song at klassifiseringen ville bli langt mer pålitelig. I 2006 ble en

lik type klassifisering foretatt, men denne gangen med et bedre datagrunnlag. Intensitetsverdiene var fri for signifikant støy, og trengte ingen videre behandling. Likevel forbedret ikke klassifiseringsresultatet seg i forhold til tidligere forsøk. Høydeegenskapene til laserdataene var fortsatt de mest avgjørende for klassifiseringen. Intensitetsverdier ble først avgjørende ved klassifisering av nyanseforskjeller i datagrunnlaget (Brennan & Webster 2006).

Først i 2014 ble det forsøkt å ta i bruk to separate laserskannere til å skanne med to forskjellige bølgelengder. En Optech-skanner med nærinfrarød laserkanal satt til 1064 nm, og en Riegl-skanner med kortbølge-infrarød laserkanal satt til 1550 nm, samlet begge inn laserdata. En Support Vector Machine klassifiseringsmetode kombinerte egenskaper fra begge skannerne, og greide å skille seks forskjellige overflateklasser fra hverandre. Med klassifiseringsnøyaktighet 97,4%. Overflatene var «vei og grus», «bar bakke», «lav vegetasjon», «høy vegetasjon», «tak» og «innsjøer». Forsøket viste at det å bruke to laserkanaler var avgjørende for å skille flere av disse klassene fra hverandre, og at dette ville kunne forbedre klassifiseringen av arealtyper betraktelig, sammenlignet med enkeltkanals laserskanning (Wang et al. 2014).

Etter at Optech Titan ble lansert som den første laserskanneren med tre laserkanaler, der en av kanalene var satt opp med grønn laser på 532 nm bølgelengde, mens de to andre kanalene besto av 1064 nm og 1550 nm bølgelengde slik som tidligere testet med separate skannere, ble mange forsøk gjort for å utnytte klassifiseringsegenskapene til et slikt system (Bakuła 2015; Thomas 2015; Wichmann et al. 2015). Disse forsøkene har gitt gode klassifiseringsresultater, som klare identifiseringer av gressområder, asfalt og bygningsmaterialer kun ved hjelp av direkte analyse i punktskyen (Thomas 2015). For klassifisering av tresorter til skogsformål, en total nøyaktighet på 93,5% (Ahokas et al. 2016), og spektralindekser basert på intensitetsverdiene fra de forskjellige kanalene har vært i stand til å skille vegetasjon fra bygninger med en total nøyaktighet på 92,5% (Morsy et al. 2016). Likevel har Optech Titan også vist svakheter i flere tilfeller. Både i sammenheng med punkttetthet (Ahokas et al. 2016) og intensitet (Thomas 2015).

Selv om de fleste forsøkene gjort med Optech Titan har gitt gode klassifiseringsresultater, og i en rekke forsøk har blitt behandlet som en laserskanner med egenskapene til et multispektralt flybildekamera (Ahokas et al. 2016; Morsy et al. 2016; Thomas 2015), er ikke dette en korrekt sammenligning. Optech Titan har tre laserkanaler med forskjellige spektralegenskaper, men disse er ikke like som de i multi- eller hyperspektrale flybilder. Intensitetsverdiene som registreres pr. kanal, er ikke en direkte avlesning av den skannede overflatens reflektans. Laserpulsens intensitetsverdi er kun en intensitetsverdi for den aktuelle kanalen. Dette er et mål

på returnert pulsstyrke. Mye kan påvirke denne pulsstyrken. Og dette på en annen måte enn den kontinuerlige strålingen fra returnert sollys, som passive sensorer baserer seg på. Laserpulser påvirkes av reisen gjennom omgivelsene, og spesielt hvis pulsen treffer flere overflater mellom utsendelse og retur. Les kapittel 4.2 for mer om dette. Værforhold, insidensvinkel og flyhøyde påvirker også disse verdiene i ulik grad. Kalibrering av intensitetsverdiene kan derfor være avgjørende for klassifiseringspotensialet (Briese et al. 2013). Fullstendigheten i kalibreringen, eller om den i det hele tatt er gjort, varierer mellom de forskjellige forsøkene. I flere sammenhenger er intensitetskalibrering utelatt pga. manglende metadata (Thomas 2015; Wichmann et al. 2015). En slik kalibrering er omfattende, og krever ekstra forberedelser. En forenklet kalibrering i etterprosessering har blitt brukt av flere. Her kan det være vanskelig å vite om klassifiseringene som er foretatt, vil yte like godt i andre datasett. Dette krever en absolutt kalibrering (Ahokas et al. 2016). Det at også klassifiseringsresultatet sammenlignes med klassifiseringer gjort med multi- eller hyperspektrale bilder (Bakula 2015) eller enkeltsensor-systemer, gjør at Optech Titans potensiale i tre laserkanaler ikke kommer så tydelig frem. Dette fordi multi- eller hyperspektrale flybilder kanskje gir mer pålitelige data til tross for lavere klassifiseringsnøyaktighet. Eller at høydeverdier påvirker klasses tilhørighet mer enn intensitetsverdier.

Optech Titan med multispektrale egenskaper til klassifisering, burde også vurderes mot sin egen ytelse. Med dette menes en vurdering av hvor mye de forskjellige laserkanalene faktisk gir, ved å utelukke kanalene som gjør den multispektral. Dette for å presisere tilleggsverdien tre kanaler har, kontra tidligere oppsett bestående av én og to kanaler. Ved å se på den relative klassifiseringsnøyaktigheten, blir heller ikke intensitetskalibreringen like viktig, ettersom fokuset ligger på hva Optech Titan gjør bedre enn tidligere laserskannere. Og ikke hvor godt den yter i forhold til andre, videreutviklede systemer.

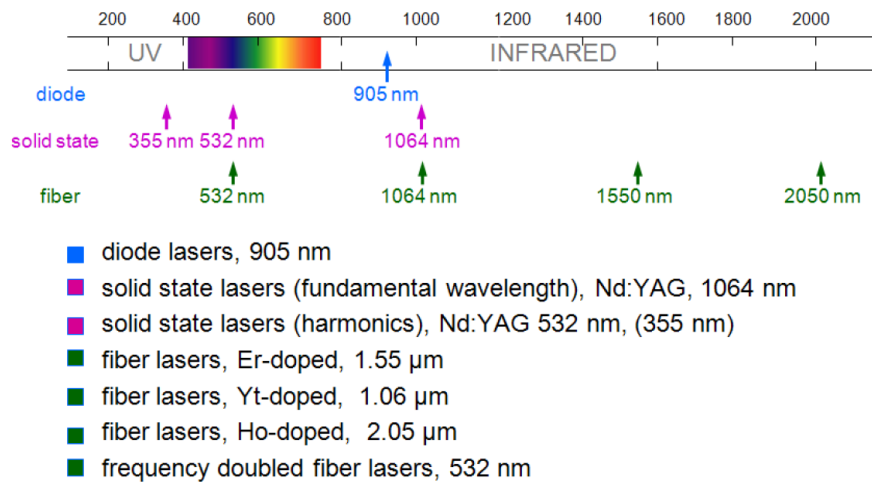
4 Teori

4.1 Laser

Laser (Light Amplification by Stimulated Emission of Radiation) er i utgangspunktet forsterket lys. Måten lyset forsterkes på i laser-prinsippet kalles stimulert emisjon. Dette går ut på at vanlige lysstråler sendes mot en materie, slik at fotonene i lyset reagerer med molekylene i materien (Abbaker 1995). Elektronene i materien vil hoppe til et høyere energi-nivå når materien treffes av lyset, før de deretter faller tilbake til sitt opprinnelige nivå ved å slippe ut fotoner. Disse nye fotonene vil ha akkurat de samme egenskapene som de fotonene som påvirket elektronene i utgangspunktet. Dette er med andre ord stråling med samme frekvens og fase som det lyset materien eksponeres for. De nye fotonene kan så brukes til å påvirke nye elektroner til å gjennomgå samme prosess (Wickersham 2016). Når denne prosessen repeteres konstant mellom to speil, vil all stråling ende opp med samme frekvens og fase. Dermed forsterkes lyset, samtidig som det gjennomgår en stimulert emisjon. Laseren, som først var lys, har blitt monokromatisk ved at det kun består av én bølgelengde, og koherent ved at alle bølger er i fase med hverandre. Ved å gjøre ett av speilene delvis reflekterende, kan en del av strålingen utvinnes ved at den slippes igjennom speilet, og dette er selve laserstrålen (Abbaker 1995). Lyset på innsiden av laser-kilden er altså mye sterkere, men har de samme egenskapene (PhotoMachining.com 2015).

Energivåket til de produserte fotonene fra materien, er invers proporsjonal med bølgelengden til de samme fotonene. Høyere energi gir dermed kortere bølgelengder. Andre faktorer som kan påvirke dette forholdet, er styrken på strømkilden til laseren, og om laserstrålen er konstant eller sendt ut i pulser. Det vil i utgangspunktet være bølgelengden som påvirker styrken på laserstrålen (Wickersham 2016).

Det finnes mange typer lasere, basert på hva slags materie lyset sendes igjennom. Disse gir oss forskjellige bølgelengder, med forskjellige styrker. For laserskanning fra fly, er det kun et fåtall bølgelengder hvor laseren er sterk nok. Disse vises i figuren som følger:



Figur 4.1: Det elektromagnetiske spekter. De tilgjengelige bølgelengdene for langdistanse flybåren laserskanning (Pfennigbauer & Ullrich 2011)

Materien som brukes til flybåren laserskanning er i dag som regel faststoff, diode eller fiber (Pfennigbauer & Ullrich 2011). De best egnede bølgelengdene som utstråles, er mellom 400 nm og 1600 nm (Vosselman & Maas 2010). Hvilke fordeler det finnes i å ta i bruk flere av disse bølgelengdene, og hvordan styrken på strålene kan skape utfordringer, blir sentralt for denne oppgaven.

4.2 LiDAR (Light Detection And Ranging)

LiDAR (Light Detection and Ranging) beskriver et system for avstandsmåling basert på lys. I prinsippet består dette systemet av en sender og en mottaker. Lyspulser sendes ut, reflekteres mot en overflate, og refleksjonspulsene registreres av mottakeren. Tiden det tar for lyset fra sender til mottaker måles, og med kjent lysfart kan avstanden regnes ut (Weitkamp 2006).

Laserlys brukes i LiDAR fordi det har en mye mer konsentrert energi og langt lavere divergens enn vanlig lys. Samtidig er det monokromatisk, som gjør det mulig å lese informasjon ut av returverdiene. Laserlys i et LiDAR system kan sendes ut kontinuerlig, eller deles opp i pulser. Ved målinger med kontinuerlige stråler, vil faseforskjellen mellom utsendt og returnert signal bli brukt for å avgjøre distanse, mens ved pulsmålinger vil pulsens reisetid brukes. Når en laserpuls returneres, vil mottakeren konvertere det optiske signalet til et elektrisk signal. Intensiteten til dette retursignalet, med sin avhengighet til tiden det tok fra utsendelse til registrering, lagres i et datasystem (Weitkamp 2006).

For laserskanning er det mest vanlig å bruke pulser av laserlys fremfor kontinuerlige stråler. Dette kalles «Time-of-flight» måling. Når en laserpuls sendes ut, vil en terskelverdi for energimengde i laserpulsens avgjøre når tidtakeren skal starte og stoppe for en utsendt og mottatt

puls. Om energimengden er lavere enn terskelen, registreres ikke pulsene i datasystemet. Er energimengden stor nok, stopper tidtakeren. Dette gir oss lengden ρ på målingen ved hjelp av formelen:

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

Formel 4.1: Avstandsformel for laserpulser i et LiDAR-system. (Vosselman & Maas 2010)

Der c er lyshastigheten i vakuum, n er korreksjonen for lysets fart i luft basert på refraksjonsindeksen, τ er pulsens reisetid, og denne deles på 2 for å gi lengden én vei (Vosselman & Maas 2010). Selv om prinsippet er enkelt, er det flere faktorer som påvirker laserpulsen i løpet av reisen. Ved skanning av vegetasjon kan multiple returpulser registreres pr. utsendt puls. Dette kan geometrisk sett tas høyde for ved å signere hver utsendt puls med en kode. Om flere pulser returner med samme verdi, tilhører de samme puls, og kan dermed knyttes tilbake til utsendt tidspunkt. Intensitetsverdiene vil derimot fordeles utover disse returpulsene, og vil gi andre verdier enn pulser med kun én retur. Dette er ikke så viktig for den geometriske nøyaktigheten, så lenge energimengden som returneres er sterk nok til at den registreres av LiDAR-systemet, men intensitetsverdier kan brukes som tilleggsinformasjon for klassifisering av objekt- og overflatekarakteristikk. Da er det ugunstig å forholde seg til splittede pulser med lave intensitetsverdier. Det er flere faktorer som påvirker intensitetsverdiene til returpulsene, som distansen fra objektet og medførende energitap, insidensvinkel mellom pulsretning og objekt-overflate, atmosfæriske forhold, energimengde som overføres til omgivelser og LiDAR-systemets karakteristikk. Intensitetsverdiene kan kalibreres for å kompensere for utslaget til disse faktorene, men også ukalibrerte intensitetsverdier kan brukes til en viss grad (Ahokas et al. 2016; Bakuła 2015).

Det er to typer intensitetskalibrering. Relativ og absolutt. En relativ intensitetskalibrering er en kalibrering av forskjellige skanneavstander, insidensvinkler, pulsstyrker og atmosfæriske forhold. Siden de fleste av de naturlige overflatene er grove ved laserskannerens bølgelengder, kan insidensvinkel for det meste ses bort ifra. En absolutt intensitetskalibrering, er en kalibrering der de korrigerte overflatene som skannes, kan sammenlignes med overflater skannet av andre, kalibrerte systemer. Her brukes laboratoriumsmålte reflektanskoefisienter for forskjellige overflater, NIR-kamera, og kalibrerte reflektometer til å gi intensitetsverdiene riktige verdier (Ahokas et al. 2016). Relativ og absolutt kalibrering av intensitetsverdier kan gjøres med referanseflater under måleprosessen, eller med matematiske modeller i

etterprosessering. Modellene vil kompensere for noen av feilkildene til intensitetsverdiene og returnere mer pålitelige verdier. En enkel modell for intensitetskalibrering kan se slik ut:

$$I_c = I * \left(\frac{\rho}{\rho_s}\right)^{eksp}$$

Formel 4.2: Intensitetskalibrering.

Der I_c er den kalibrerte intensiteten, I er rå-intensiteten, ρ er lengden fra sensor til objektet, ρ_s er gjennomsnittlig lengde i prosjektet, $eksp$ er eksponeringsfaktor avhengig av materiale som skannes (Yu et al. 2017). Til tross for at dette er en enkel modell, er den både relativ og absolutt, da den tar for seg interne kalibreringer (ρ) og absolutte kalibreringer ($eksp$).

4.3 Flybåren Laserskanning


LiDAR utført fra fly, helikopter eller drone kalles flybåren laserskanning. Denne teknikken er basert på en kombinasjon av et LiDAR-system, GNSS og en IMU. GNSS (Global Navigation Satellite System) sørger for å måle den eksakte posisjonen til LiDAR-systemet til enhver tid, mens en IMU (Inertial Measurement Unit) måler LiDAR-systemets eksakte orientering til enhver tid (Vosselman & Maas 2010). Slik kan hver utsendte laserpuls orienteres til punkter i landskapet.

Laserskanneren i et fly monteres over et hull i flykroppen, og sender kontinuerlig ut laserpulser mot bakken under flygningen. En slik laserskanner kan sende ut pulser med høy nok puls-repetisjonsfrekvens (PRF) til å registrere opptil 50 pkt/m² på bakken. Dette avhenger av hastighet, skannevinkel og høyde over bakken, men også av laserskannerens evne til å håndtere flere utsendte laserpulser i luften samtidig. Nyere laserskannere kan ved hjelp av et kodesystem og en innebygget terrengmodell prosessere over 10 utsendte punkter samtidig, og dermed overgå den tidligere begrensningen i PRF, der hver puls måtte returnere før en ny kunne sendes ut (Vosselman & Maas 2010).

For å spre laserpulser ut i forskjellige retninger, kreves en skannermekanisme for å vinkle det utsendte laserlyset. Flere teknikker er utviklet for dette formålet. En av de mest brukte innenfor flybåren laserskanning er basert på oscillerende speil. Her sendes laserpulser fra en laserkilde, mot et speil med en oscillerende bevegelse. Laserlyset vinkles frem og tilbake, perpendikulært på flyveretningen og ned mot terrenget (nadir). Dette vil danne et slags sikksakk-mønster av punkter på bakken, ettersom laserlyset vil bevege seg i én retning, snu, og bevege seg i motsatt retning. Punktavstanden i sikksakk-mønsteret vil også variere, da en oscillerende bevegelse vil


føre til at laserlyset akselerer mot midtpunktet, og retarderer mot sidene. Punkttettheten vil dermed bli større på sidene, og minst på midten av flystripen (Vosselman & Maas 2010).

Som et resultat av flybåren laserskanning vil alle registrerte pulser lagres som posisjoner i et 3-dimensjonalt rom. Egenskapene til hvert punkt, som intensitet, klasse, første/siste-retur osv., lagres som attributter for punktene. En punktsky kan være et nyttig verktøy i mange sammenhenger, men det forutsetter at den gjenskaper geometrien med den fullstendigheten som kreves til formålet. Stor eller irregulær punktavstand vil føre til informasjonsmangel, og punkttetthet blir dermed avgjørende for bruksområdet. Med en oscillerende punktspredning vil punkttettheten, i kantene av flystripen, bli større i sveiperetning enn i flyveretning. Derfor er det viktig å se på punkttetthet i flere retninger, og ikke bare gjennomsnittlig over et areal, når den geometriske fullstendigheten skal vurderes. Punktfordelingen i en punktsky fra en flybåren laserskanner, ser ofte tilnærmet slik ut nær kantene. Der flyveretning er mot nord med stor punktavstand, og skanneretning mot øst med liten punktavstand.



Figur 4.2: Irregulær punktavstand nær kanten av en punktsky fra flybåren laserskanning. (Naus 2010)

Delaunay-triangulering og Voronoi-diagram er godt egnet for å studere irregulær punktavstand og punkttetthet. Ved å danne triangler mellom nærliggende punkter, kan Delaunay trianguleringen brukes til å måle avstand mellom alle punkter i punktskyen. Voronoi-diagrammet blir da polygoner, basert på perpendikulære sidekanter til Delaunay-trianglene. Disse sidekantene er alltid midt mellom to punkter, og danner da polygoner sammen med andre sidekanter.



Figur 4.3: Delaunay-triangulering. Illustrasjon av laserpunkter (svarte), Delaunay-triangulering (røde streker) og Voronoi-diagram (blå polygoner). (Naus 2010)

Arealet i hver polygon blir utgangspunktet for den nominale punktavstanden (NPA), som er det estimerte gjennomsnittet av arealet til hver polygon. Den nominale punkttettheten (NPT) blir dermed det inverse kvadratet av den nominale punktavstanden. Forholdet i mellom disse tallene uttrykkes slik (Naus 2010) :


$$NPA = \frac{1}{\sqrt{NPT}}$$

Formel 4.3: Forhold mellom nominell punktavstand og punkttetthet.

Tallene gir mer riktige verdier enn et tradisjonelt gjennomsnitt, da de tar hensyn til irregulariteten i en punktsky.

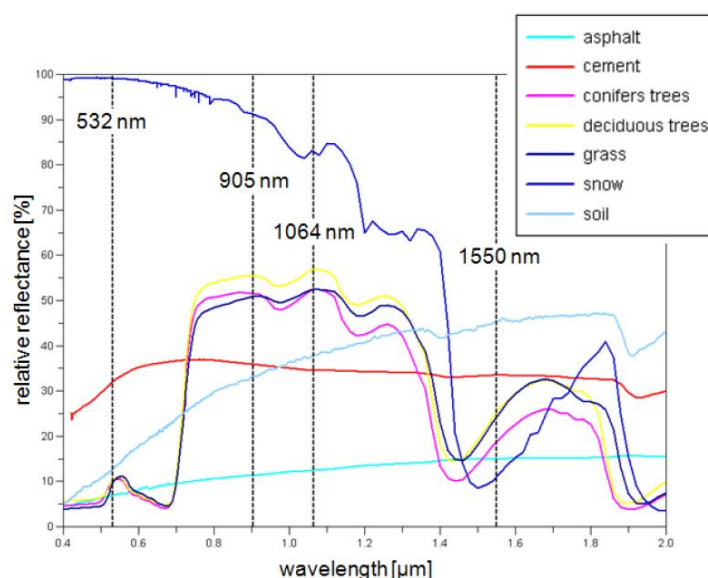
4.4 Stråling, absorbering og refleksjon

Laser kan både være synlig lys, ultrafiolett og infrarødt. Denne egenskapen defineres av bølgelengden på laserstrålen, og hvor på det elektromagnetiske spekteret denne bølgelengden ligger.



Figur 4.4: Det elektromagnetiske spekteret. (Shapley 2012)

Alt i dette spekteret kan defineres som stråling, og når stråling eksponerer en overflate, kan den bli reflektert eller absorbert (*Light Absorption, Reflection, and Transmission* 2016). Mest vanlig er en blanding av begge deler, der den reflekterte strålingen vil ha lavere energi, ettersom noe av energien absorberes av overflaten. Hvor godt en overflate reflekterer strålingen den blir eksponert for, avhenger av materialet overflaten består av, og sier noe om materialets reflektans. Reflektansen vil variere basert på hvilke bølgelengder den blir eksponert for. Noen materialer kan f.eks. ha høy reflektans ved kortere bølgelengder, og lavere reflektans ved lengre bølgelengder. Som vist i figuren under.



Figur 4.5: Reflektanskurver. Reflektans plottet mot bølgelengde for forskjellige materialer. (Pfennigbauer & Ullrich 2011)

Stråling fra laser har fordelene ved å bare bestå av én bølgelengde, og det er dermed enkelt å måle hvor mye energi som reflekteres fra et eksponert materiale ved å se på intensitetsverdiene

til de reflekterte laserpulsene. Hver bølgelengde har sine fordeler og ulemper ved praktisk bruk, basert på overflatens reflektans, bakgrunnsstråling, atmosfæriske overføringer og helserisiko (Pfennigbauer & Ullrich 2011). Bølgelengdene som står igjen som mest egnede basert på disse faktorene, er 532 nm, 905 nm, 1064 nm og 1550 nm. I denne oppgaven vil det vurderes om intensitetsverdier fra reflekterte laserpulser med bølgelengde 532 nm, 1064 nm og 1550 nm kan brukes til klassifisering av eksponert overflater.

4.5 Multidimensjonal klassifisering

Med LiDAR kan man registrere store mengder informasjon over et gitt område. Millioner av registrerte punkter kan inneholde mange attributter hver, som bl.a. koordinater, intensitet, avstand fra sender, returnnummer m.m. Grupperinger av punkter kan inneholde samsvarende attributtinformasjon. Matematiske beregninger som gjennomsnitt, standardavvik, punkttetthet osv. kan igjen danne flere statistiske egenskaper til de registrerte dataene. Percentiler og bincentiler er også statistiske mål på grupperinger av punkter. Her deles punktmengden inn i snitt, der kalkuleringer gjøres for hvert snitt. Percentiler er gjennomsnittlig verdi og bincentiler er antall punkter, for en prosentdel av grupperingen. LiDAR-data er multidimensjonale data, ettersom hvert attributt og hver egenskap til et punkt, kan tolkes som en egen dimensjon (Gnanadesikan 2011). Å sammenligne alle disse statistiske verdiene samtidig kalles multivariat analyse. Dette kan brukes til å finne sammenheng mellom attributter som kan være vanskelig eller umulig å oppdage ved en direkte studie av hvert enkelt attributt. Multivariat analyse er derfor nyttig for å finne ut av hvordan forskjellige overflater skannet med LiDAR, kan skilles fra hverandre basert på attributtene og de statistiske egenskapene til overflatene (Hair 2006).

For å kunne kategorisere de forskjellige overflatene basert på egenskapene som skiller dem fra hverandre, finnes det mange varianter av konsepter og teknikker under paraplybetegnelsen multidimensjonal klassifisering. I hovedsak går prinsippet klassifisering ut på å kategorisere data inn i forhåndsbestemte grupper. Dette gjøres basert på et egenskapsvalg, en effektiv dimensjonsutstrekning eller representasjon av egenskapene, samt en valgt måte å måle distansen mellom verdier i denne egenskapsrepresentasjonen (Gnanadesikan 2011). Målinger vil så bli klassifisert til den forhåndsbestemte gruppen den passer best inn i. Verdiene i de forhåndsbestemte gruppene dannes fra et utvalg av målinger der fasitverdi er gitt. Hentes disse verdiene fra datasettet som skal klassifiseres, kalles dette en styrt klassifisering. Verdiene danner treningsdatasett. Navnet kommer av at datasettet trener opp klassifiseringsmetoden til å gjenkjenne karaktertrekk i de forskjellige klassene. Hvordan disse verdiene velges ut er basert på hvilken teknikk som brukes. Kryssvalidering er en slik teknikk, som danner treningsdatasett

ved å iterativt ta flere utdrag av datasettet, for så å bruke gjennomsnittet som et endelig treningsdatasett. Når klassifiseringsmetoden har lært seg karaktertrekk for hver klasse, kan den også brukes til å klassifisere nye datasett uten å ta i bruk treningsdata. Dette kalles en ikke-styrt klassifisering. I denne oppgaven vil kryssvalidering være mest gunstig å bruke. Dette fordi datamengdene er for små til å utelate deler av datasettet til bruk som kun treningsdata. Oppgaven fokuserer på en styrt klassifisering, men det tas høyde for at metoden kan videreutvikles til også å gjøre ikke-styrte klassifiseringer.

Klassifiseringsmetodene som i hovedsak brukes i denne oppgaven kalles SVM (Support Vector Machine) og Random Forest. Andre metoder som tas i bruk er kNN (k-Nearest Neighbors), Logistisk Regresjon og Naive Bayes. SVM-metoden plotter verdiene inn i et multidimensjonalt rom, og konstruerer et hyperplan i dette rommet, som på best mulig måte separerer disse verdiene fra hverandre. Forskjellige algoritmer kan brukes for å minimere feillikningen. Formelen for en SVM kan settes opp slik, uten å gå får mye i dybden (Suykens & Vandewalle 1999). Gitt et treningsdatasett med N datapunkter $[y_k, x_k]_{k=1}^N$, der x_k er input-verdi, mens y_k er resultatverdi, så kan Support Vector-metoden konstruere en klassifisering på formen:

$$y(x) = \text{sign}\left[\sum_{k=1}^N \alpha_k y_k \Psi(x, x_k) + b\right]$$

Formel 4.4: Formel for SVM-metoden.

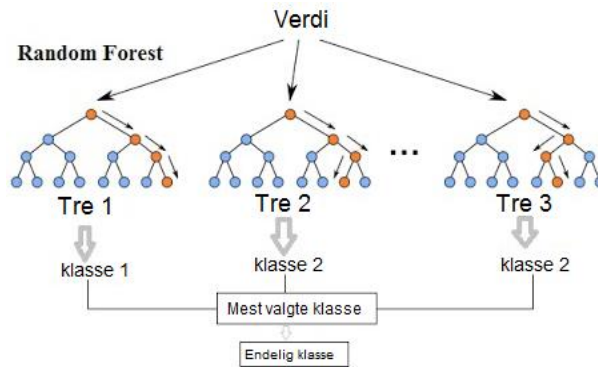
Der α_k er positive konstanter og b er konstanter. For $\Psi(x, x_k)$ kan man fylle inn forskjellige kernel-ligninger, som studerer forholdene i datasettet. I denne oppgaven brukes en RBF-kernel der σ er konstant:

$$\Psi(x, x_k) = \exp\left[-\frac{\|x - x_k\|_2^2}{\sigma^2}\right]$$

Formel 4.5: Kernel-funksjon i SVM-metoden.

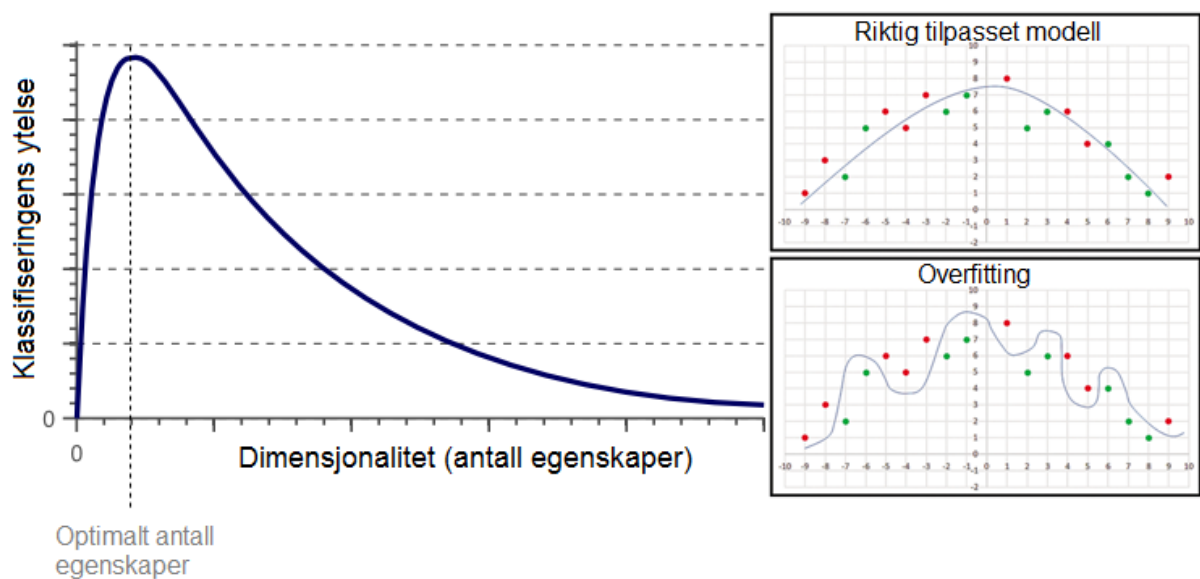
Random Forest klassifiseringsmetoden er bygget opp av beslutningstrær og har dermed en helt ulik representasjon av dataene i forhold til SVM-metoden. Beslutningstrær har ingen direkte tilknytning til vektor-rom, men fremstår heller som grafiske, tre-lignende fremstillinger av klasser. Dataene blir deterministisk testet for klassetilhørighet basert på egenskapsverdier, og for hver node i treet gjøres en slik test. En verdi i datasettet blir utsatt for en rekke mer og mer nyanserte tester før den ender opp i en resultatklasse. Random Forest fordeler treningsdataene opp i flere tilfeldige utvalg, der hvert utvalg brukes til å danne et beslutningstre. Når mange beslutningstrær er dannet, og hver verdi er klassifisert, blir de mest populære klassefordelingene

valgt. Denne klassefordelingen er resultatet av Random Forest klassifiseringsmetoden. (Breiman 2001) Algoritmen for Random Forest metoden kan visualiseres slik:



Figur 4.6: Illustrasjon av Random Forest klassifiseringsmetoden. (Random Forest based Classification 2016)

Disse klassifiseringsmetodene fungerer godt kun opp til et relativt antall dimensjoner. Derfor er det viktig å ta datasettets dimensjonale størrelse med i vurderingen av klassifiseringens ytelse. Det er lett å tro at flere dimensjoner gir en bedre klassifisering, fordi hver måling vil skille seg lettere fra andre målinger som tilhører andre klasser. For hver dimensjon minsker tettheten i datasettet eksponentielt, og det blir lettere å plassere et hyperplan som skiller klassetilhørighet. Problemet er at dette hyperplanet vil basere seg på små nyanser i datasettet, og ikke de generelle faktorene som går igjen når nye målinger legges til. Konseptet kalles «overfitting» (Spruyt 2014) og er avhengig av antall målinger i datasettet, kontra antall dimensjoner.



Figur 4.7: Overfitting. Når antall dimensjoner øker i klassifiseringer, øker også ytelsen til klassifiseringen til et visst punkt. Etter dette minsker den pga. "overfitting" (McCaffrey 2015; Spruyt 2014).

Et optimalt utvalg av dimensjoner kan oppnås ved å bruke algoritmer for å finne de dimensjonene som inneholder mest informasjon. Treningsdata vil også sterkt påvirkes av «overfitting», men effekten kan reduseres ved å bruke kryss-validering til å konstruere treningsdatasettene (Spruyt 2014).

Når et endelig klassifiseringsresultat skal studeres vil forvirringsmatrisen være den mest informative fremstillingen av resultatet. I en forvirringsmatrise blir predikerte verdier i en klassifisering plottet mot faktiske verdier. Riktige klassifiserte verdier vil da ligge i diagonalen gjennom matrisen. Feilklassifiserte verdier vil ligge et sted utenfor diagonalen. I kryssningen mellom faktisk verdi og predikert verdi. En typisk forvirringsmatrise er illustrert under:

	Predikert 1	Predikert 2
Faktisk 1	Sann 1	Falsk 2
Faktisk 2	Falsk 1	Sann 2

Figur 4.8: Prinsippet i forvirringsmatrisen.

Forvirringsmatrisen presenterer klassifiseringsresultatet. Der antall verdier i diagonalen fordelt på antall verdier totalt, er tallet på klassifiseringsnøyaktigheten. Dette tallet tar ikke hensyn til at noen predikeringer noen ganger vil avvike av ren tilfeldighet. Kappa-koeffisienten er den mest brukte statistikken for å ta høyde for slike tilfeller. En kappa på 1 indikerer perfekt riktighet, mens en kappa på 0 indikerer riktighet kun basert på ren tilfeldighet. Kappa-koeffisienten kan regnes ut slik:

$$K = \frac{N \sum_{i=1}^r x_{ii} - \sum_{i=1}^r (x_{i+} * x_{+i})}{N^2 - \sum_{i=1}^r (x_{i+} * x_{+i})}$$

Formel 4.6: Formel for utregning av kappa-koeffisient.

Der $\sum_{i=1}^r x_{ii}$ er summen av verdier i diagonalen av matrisen, $\sum_{i=1}^r (x_{i+} * x_{+i})$ er summen av faktiske verdier i en klasse, multiplisert med predikerte verdier i en klasse. N er det totale antall verdier i datasettet (Viera & Garrett 2005).

Kappa-koeffisienten kan tolkes ut fra en ofte brukt skala (Viera & Garrett 2005):

Grad av riktighet	Ingen	Minimal	Svak	Moderat	Sterk	Nesten perfekt
Kappa (K)	0,0	0,20	0,40	0,60	0,80	1,0

5 Utstyr og metode

I dette kapitlet beskrives og drøftes utstyr og metode. Kapitlet er delt inn i to delkapitler. Utstyrsdelen tar for seg alt av instrumenter, datasett, filformater og programvare som er brukt for å komme frem til en vellykket metode. Metodedelen beskriver selve metoden, og drøfter utformingen av denne. Metoden er et produkt av prøving og feiling, for å finne den best egnede besvarelsen på problemstillingen. De valgene som er tatt, drøftes i kapittel 5.2. Relevante feilgrep vurderes, og veivalg begrunnes. Først vil instrumenter, datagrunnlag, filformater og programvare beskrives og drøftes, for å gi bedre forståelse for metoden.

5.1 Utstyr

5.1.1 Optech Titan

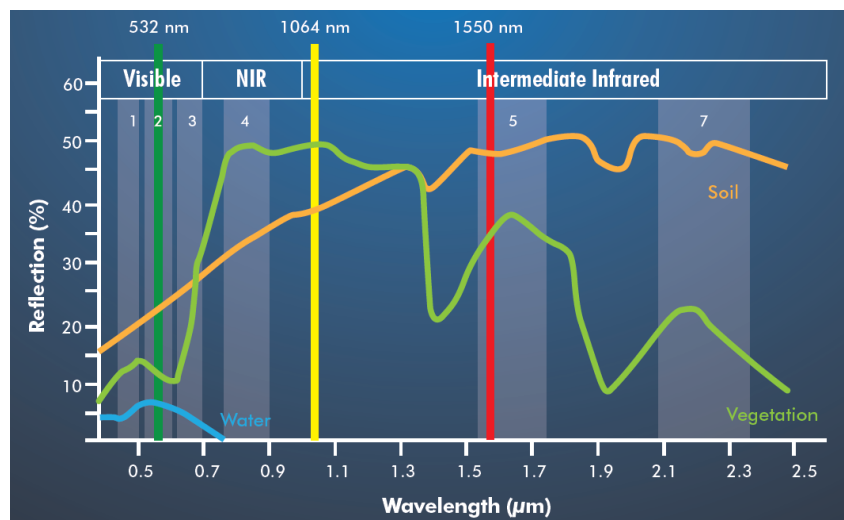
I 2014 lanserte Teledyne Optech verdens første kommersielle laserskanner med multispektrale egenskaper, kalt Optech Titan. Skanneren kan samle inn laserdata med tre forskjellige lasere samtidig, som operer på bølgelengdene 1550 nm, 1064 nm og 532 nm. Dette er henholdsvis kortbølge-infrarød laser (MIR), nær-infrarød laser (NIR) og grønn laser (G). Laserkanalene er vinklet forskjellig i forhold til pitch-retning. Der MIR-kanal er vinkel 3,5° fra nadir i flyveretning, NIR-kanal med vinkel 0° i nadir, og G-kanal er vinklet 7° fra nadir i flyveretning. Hver av kanalene kan skanne med en hastighet på 300 kHz, til sammen 900 kHz. (Morsy et al. 2016; Optech 2015) Skanneren skal kunne operere mellom 300 og 2000 meters høyde over terrenget. Den grønne kanalen er i utgangspunktet utviklet for batymetriske målinger, men kan bli nyttig i klassifisering sammen med de to andre kanalene (Ahokas et al. 2016). Optech Titan har også kamera. Spesifikasjonene for dette tas ikke med da det ikke fokuseres på i oppgaven. Noen batymetriske egenskaper er også utelatt i tabellen som følger:

Parametere	Spesifikasjoner
Kanal 1	532 nm grønn
Kanal 2	1064 nm NIR
Kanal 3	1550 nm MIR
Stråle-divergens	Kanal 2 & 3 $\approx 0,35$ mrad (1/e) Kanal 1 $\approx 0,7$ mrad (1/e)
Laser-klassifisering	Klasse IV (US FDA 21 CFR 1040,10 og 1040,11; IEC/EN 60825-1)
Funksjonelle altituder	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
Punktetthet	Batymetrisk: >15 pkt/m ² Topografisk: >45 pkt/m ²
Skannevinkel (FOV)	Programmerbar; 0 - 60° maksimum

Effektiv skannefrekvens	Programmerbar; 0 - 210 Hz
Sveipevidde	0 - 115% av AGL
Horisontal nøyaktighet	1/7,500 x altitude; 1 σ
Høyde-nøyaktighet	< 5 - 10 cm; 1 σ
Laserlengde presisjon	< 0,008 m; 1 σ

Tabell 5.1: Spesifikasjoner for Optech Titan. (Optech 2015)

Figuren under viser et plott mellom refleksjonsprosent, eller reflektans, horisontalt, mot bølgelengde vertikalt. Tre bølgelengder er markert med snitt. Dette er de bølgelengder Optech Titan operere på. En graf for jord, vegetasjon og vann er også tegnet inn i plottet. Det kommer frem av figuren at 532 nm (G) er en vel egnet bølgelengde for refleksjon på vann. 1064 nm (NIR) er en vel egnet bølgelengde for refleksjon av vegetasjon, mens 1550 nm (MIR) er en vel egnet bølgelengde for refleksjon av jord.



Figur 5.1: Optech Titans laserkanaler. Oversikt over Optech Titans ulike laserkanalers bølgelengder, og utvalgte reflektanskurver. (Optech 2015)

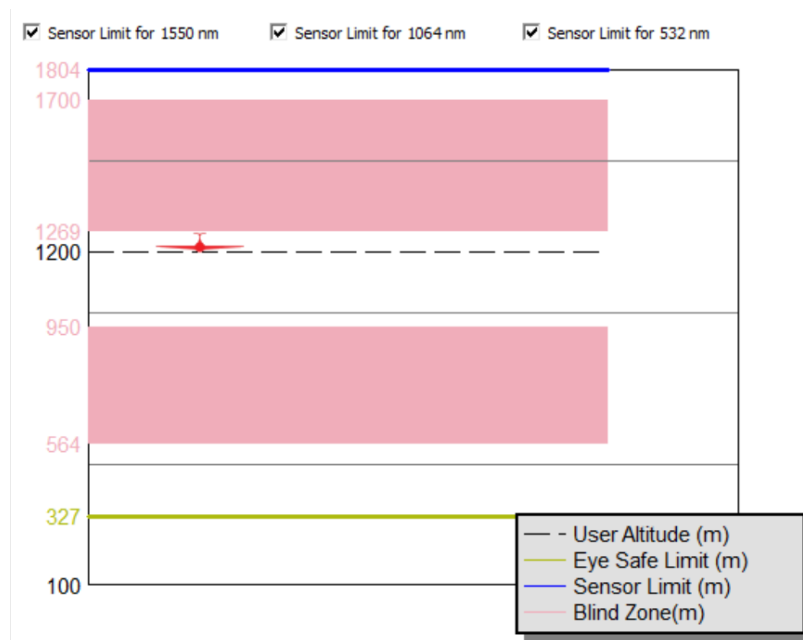
5.1.2 Datagrunnlag

Alle data brukt i denne oppgaven er enten hentet direkte fra Blom Geomatics AS og Terratec AS sine databaser, eller skaffet gjennom deres ressurser. Ingenting er rådata, alt er prosessert og tilrettelagt til en viss grad. Det vil si at det gjennom hele prosessen i denne oppgaven må tas høyde for at relevant data kan mangle, og at noen verdier kan være justerte.

Laserdata

Det er brukt 2 sett med laserdata i gjennomføringen av oppgaven. Det første datasettet som brukes i oppgaven er en skanning over Rakkestad Flyplass. Datasettet består av 5 flystriper med laserdata. Motivasjonen bak flygningen var å teste Optech Titan, og har blitt brukt av Terratec AS for å vurdere kapasiteten til skanneren. Flystripene er fløyet i forskjellige høyder. Dette er

gunstig for å analysere hvordan de forskjellige laserkanalene oppfører seg med forskjellig avstand til terrenget. En komplikasjon her er at flyplanleggeren ikke har beholdt de samme PRF-innstillingene for hver flystripe. Dette gjør at punkttettheten ikke har en direkte sammenheng med de forskjellige høydene. Grunnen til dette er at det finnes blindsoner for LiDAR-systemet. Ved visse høyder vil kodesystemet som håndterer multiple pulsutsendelser ikke greie å holde styr på utsendelse og returnnummer. Derfor er PRF satt til å fungere optimalt ved de forskjellige høydene.



Figur 5.2: Utsnitt fra FMS Planner. De røde områdene tilsvare blindsoner for 200 kHz. (Optech 2016)

En teoretisk fasit for punkttetthet for de forskjellige høydene, pr. kanal, kalkulert ut fra FMS Planner, er brukt for å analysere resultatene fra denne flygningen. En oversikt over innstillingene kommer frem i tabellen under:

Flyhøyde(m) over terrenget:	PRF:	Teoretisk punkttetthet(m ²) pr. kanal:
2000	125 kHz	1,08
1600	150 kHz	1,62
1200	200 kHz	2,89
800	125 kHz	2,71
400	250 kHz	10,83

Tabell 5.2: Data hentet fra FMS Planner.

Datasettet var allerede autoklassifisert da det ble analysert. Dvs. en automatisk klassifisering av laserdataene, der det kun kjøres batch-rutiner og ingen manuell kontroll eller editering. En grov klassifisering av bakke, vegetasjon og bygninger blir tilgjengelig, men brukes ikke i Rakkestad-datasettet. Dette ble ikke relevant for en analyse av punkttetthet. Om en støyfjerning er foretatt

er usikkert, men dataene besto av lite geometrisk støy da de ble analysert. Vurdering av skannet punktetthet for forskjellige overflater var målet for analysen. Om en støyfjerning er foretatt hadde dette i utgangspunktet vært ubrukelig data, og kunne blitt sammenlignet med mangel på returverdi. Derfor er ikke dette avgjørende for analysen, og antall registrerte returverdier pr. overflate vil fortsatt kunne gi gode indikasjoner på Optech Titans ytelse. En oversikt over spesifikasjoner for flyvningen følger:

Flyfirma	Terratec AS
Filformat	LAZ (Versjon 1.2)
Total filstørrelse	326 MB
Atributter pr. punkt	16 (x, y, z, intensitet, returnummer, antall returer, ende på flystripe, skanneretning-flag, klassifisering, skanneretning-rang, kanaldata, punkt-ID, GPS-tid, farge(r), farge(g), farge(b))
Prosjektet punktetthet	Flere
Lokasjon	Rakkestad flyplass, Åstorp, Østfold
Dato	28.10.2016
Tid (kl.)	13:00 - 13:30
Værforhold	9,7°C/0,0 mm nedbør
Høyde over havet	133.7 m
Projeksjon	EUREF89 UTM sone 32
Flyhøyde	536 m/936 m/1200 m/1600 m/2000 m
PRF	250 kHz/125 kHz/200 kHz/150 kHz/125 kHz
FOV	40°
Scan frequency	40 Hz
Max ground speed	250 km/t
Overflatetyper	Gress, Asfalt, Hustak, Landbruk, Skog

Tabell 5.3: Spesifikasjoner for Rakkestad-flyvningen. (Været som var: Rakkestad flyplass, Åstorp 2016)

Datasettet som brukes for klassifisering er skannet over Alvdal sentrum og omegn. Også dette datasettet var autoklassifisert da det ble analysert. Denne klassifiseringen kom til nytte, da en normalisert overflatemodell ble konstruert ut fra informasjonen om bakkeklasse. Ellers er klassifiseringen av overflatepunkter ikke tatt hensyn til i den klassifiseringen som gjøres her i denne oppgaven. For denne delen av oppgaven trengtes en variert sammensetning av overflater. Alt fra sub-urbane områder og industri, til forskjellige typer natur. Optech Titan har blitt brukt til et begrenset antall områder. Mange av områdene egner seg bedre enn Alvdal, men disse områdene er allerede ferdig prosessert av Terratec AS og informasjon om laserkanaler er fjernet. I utgangspunktet var et datasett over Hamar valgt som område for klassifisering, men her var informasjon om laserkanaler utilgjengelig. Alvdal var ikke et like optimalt område, der urbane områder var lavere representert. Likevel finnes det nok av overflater her som beskriver de forhåndsbestemte klassene. Noen underklasser justeres til å passe de forholdene Alvdal har

å by på. Den nominelle punktavstanden er også i dette datasettet ganske stor (se Figur 6.2). En oversikt over spesifikasjoner for flyvningen følger:

Flyfirma	Terratec AS
Filformat	LAZ (Versjon 1.2)
Total filstørrelse	20.3 GB
Atributter pr. punkt	13 (x, y, z, intensitet, returnummer, antall returer, ende på flystripe, skanneretning-flag, klassifisering, skanneretning-rang, kanaldata, punkt-ID, GPS-tid)
Prosjekttert punkttetthet	9,6 pts/m ²
Lokasjon	Alvdal, Hedmark
Dato	07.06.2016
Tid (kl.)	07:52 – 18:18
Værforhold	15,2°C/0,0 mm nedbør
Høyde over havet	505,8 m
Projeksjon	EUREF89 UTM sone 32
Flyhøyde	1900 m
PRF	175 kHz
FOV	30°
Scan frequency	40 Hz
Max ground speed	250 km/t
Overflatetyper	Gress, Mark, Grus, Asfalt, Hustak, Jorde, Skog, Vann

Tabell 5.4: Spesifikasjoner for Alvdal-flyvningen. (Yr.no - Været som var: Alvdal 2016)

Bildedata

For å konstruere treningsdata til klassifiseringen, er bl.a. flybilder fra Norgebilder.no brukt i WMS-formatet. Disse bildene har blitt tilgjengelige gjennom Blom sine ressurser. Flybildene er bruk som grunnlag for treningsdata til klassifiseringen. Det vil si at overflater i flybildene, som hustak, asfalt, grus og vegetasjon, gjenkjennes basert på en kombinasjon av FKB-grunnlag og kognitiv gjenkjennelse.

Fotodato	13.09.2016
Publiseringsdato	28.02.2017
Type	Ortofoto
Oppløsning	0,25 (m)
Fargedybde	24 bit/px
Opprinnelig bildeformat	TIFF
Flyfirma	Blom Geomatics AS
Produsent	Blom Geomatics AS

Tabell 5.5: Spesifikasjoner for Alvdal-flyfotografering. (KILDE)

Flyfotografiene er tatt 13.09.2016. Dette er tre måneder senere enn laserdataene er skannet. Overflater kan ha forandret seg på denne tiden. Spesielt jorder. Det er derfor en viss usikkerhet

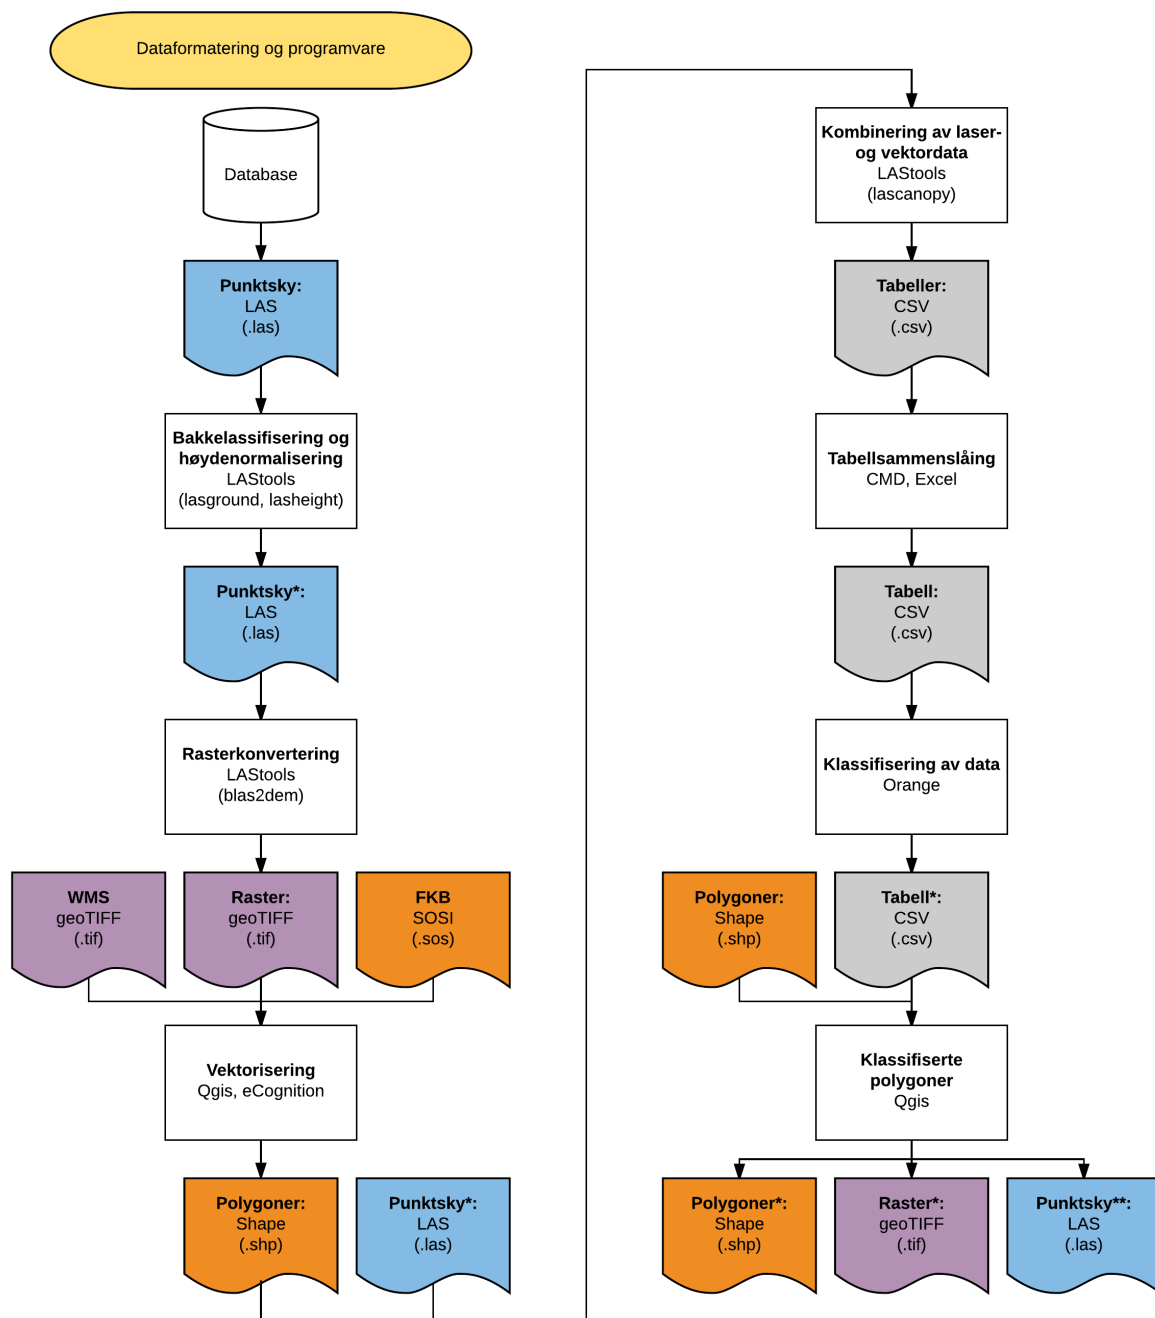
i fasitgrunnlaget for noen av klassene pga. dette. I drøftingen av klassifiseringsresultatet er dette tatt høyde for.

FKB-data

For å konstruere treningsdata til klassifiseringen er bl.a. FKB-data over Alvdal kommune tatt i bruk. Disse dataene har blitt tilgjengelige gjennom Blom AS sine ressurser. FKB-AR5 beskriver Norges arealressurser, og er velegnet for analyseformål. Inndelingen i arealtyper er basert på kriterier for vegetasjon, naturlig drenering og kulturpåvirkning. FKB-bygning inneholder detaljert bygningsinformasjon. Dataene omfatter beskrivelse av alle typer bygninger, takoverbygg, beskrivende bygningslinjer (for eksempel mønelinje) samt bygningsvedheng (for eksempel veranda). FKB-Veg inneholder vegelementer som beskriver vegens geometri. Kartgrunnlaget viser tydelig bygninger, veier og arealtyper, og importeres i QGIS sammen med WMS, for en sikrere vurdering av overflatene som tilegnes klasses tilhørighet (Kartverket 2017). FKB-dataene er hentet ut i SOSI-formatet, men konverteres til shape-formatet ved bruk.

5.1.3 Programvare og filformater

En rekke programvare og filformater er brukt i metoden. Her vil de viktigste og mest brukte introduseres. Det er forsøkt å gjøre det meste av prosessering i tilgjengelig programvare. Noen manuelle inngrep er gjort i overgang fra et program til et annet. En oversikt over dataflyten i metoden følger:



Figur 5.3: Arbeidsflyt for filformater og programvare.

LAS/LAZ

LAS (LASer) er et format for utveksling av tredimensjonal punktskydata mellom forskjellige brukere. Det er i utgangspunktet utviklet for LiDAR-data, men fungerer for all data med xyz-verdier. LAS kan komprimeres til LAZ. Dette er en reversibel komprimering av formatet, som også kan leses av direkte i visse programmer. Som f.eks. LAStools. I denne oppgaven er punktskyer lagret i LAS versjon 1.2. Små endringer er gjort i denne versjonen fra tidligere

versjoner (*LASer (LAS) File Format Exchange Activities* 2008). LAS-formatet håndterer store mengder laserdata veldig effektivt, og med LAStools kan LAS-filer både visualiseres og analyseres. I denne oppgaven brukes dette formatet på alle laserdata.

TIFF

TIFF (Tagged Image File Format) er et tag-basert filformat for lagring og utveksling av rasterbilder. Formatet kan brukes til å lagre svart-hvitt, gråskala og fargebilder. At formatet er tag-basert, betyr at det inneholder data definert med forskjellige koder. Disse kodene beskriver forskjellige data som er lagret i TIFF-filen. GeoTIFF er et sett med slike TIFF-tags, som brukes til å beskrive kartografisk informasjon assosiert med TIFF-bilder fra satellitter, fly eller konverteringer fra laser. TIFF tagger lagrer georeferert data i projeksjoner, som f.eks. UTM (Mahammad & Ramakrishnan 2003). I denne oppgaven bruke dette formatet både på laserdata konvertert til raster, og på WMS-data fra Norgebilder.no.

Shape

Shape-formatet er utviklet av ESRI, og lagrer ikke-topologisk geometri og attributtinformasjon for romlige egenskaper i et datasett. Geometrien er lagret som et sett med vektor-koordinater. Disse kan beskrive både punkt, linje og arealer. Arealer blir da representert som sluttede kretser av koordinater, som former polygoner (ESRI 1998). I denne oppgaven brukes shape-formatet i QGIS til å manuelt opprette polygoner som representerer overflater i terrenget. Disse behandles videre av LAStools.

CSV

CSV (Comma Sepaerated Value) brukes til å utveksle og konvertere data mellom forskjellige regneark-programmer. Data er lagret i rader og kolonner. Kolonner skilles med enten komma eller, semikolon, mellomrom eller tab. Dette må defineres ved import. Rader skilles ved linjeskifter (Shafranovich 2005). Programmet brukes i denne oppgaven til å eksportere og importere statistikk fra polygoner opprettet i shape-formatet.

LAStools

LAStools er et lisensiert analyse- og prosesseringsprogram for data i LAS-formatet som også kan brukes gratis med redusert kvalitet på eksportert data. Produktet er utviklet av Martin Isenburg, og består av effektive, batch-skriptede kommandolinjeverktøy. LAStools kan klassifisere, sortere, konvertere, filtrere, gridde, triangulere, konturere, klippe og polygonisere LAS-data. Dette i form av ulike verktøy. Verktøyene som brukes i denne oppgaven er blas2dem, som triangulerer punktskyen og lager raster-representasjoner av laserdata, basert på

ulike attributtverdier. Rasterdataene kan eksporteres som geoTIFF (kapittel 7.1.2). Lascanopy, som kombinerer shape-polygoner med laserdata, til å produsere statistikk innad i polygonene. Statistikken kan eksporteres som CSV (kapittel 7.1.5). Lasview, som kan brukes til å studere laserdata tredimensjonalt. Lasinfo, som rapporterer innholdet i header av LAS-filen og henter ut informasjon om laserdataene (Isenburg 2017).

Terrascan

Terrascan er et lisensiert analyse- og prosesseringsprogram for prosessering av punktskyer, utviklet av Terrasolid. Programmet kan enkelt behandle millioner av punkter samtidig. Mange av de samme mulighetene fra LAStools finnes også her, men med et mer sammensatt brukergrensesnitt. I denne oppgaven brukes Terrascan versjon 17.001 ved prosessering og analyse av punkttetthet (kapittel 6.2 og 6.3).

Optech FMS Planner

Optech FMS (Flight Management Suite Planner) Planner er et flyplanleggerprogram for Optech laserskannere. Programmet kan lage grafiske flyplaner med en rekke egenskaper. I denne oppgaven brukes Optech FMS Planner versjon 4.9.7.1 til å kalkulere teoretiske verdier for punkttetthet ved forskjellige høyder (kapittel 6.2.4).

QGIS

QGIS (Quantum GIS) er et åpent program for behandling av GIS (geografiske informasjonssystemer), utviklet av Gary Sherman med flere. Dette er et verktøy for arbeid knyttet til kart og romlige data. Analyse, prosessering og redigering av raster- og vektorbaserte data kan utføres i QGIS (Sherman 2017). I denne oppgaven brukes QGIS versjon 2.18.2 til oppretting av shape-polygoner for klassifisering. QGIS blir også brukt til å produsere visualiseringer av polygoner sammen med rasterrepresentasjoner av laserdata (kapittel 7.1 og 7.2.5).

Orange

Orange er et maskinlæring- og datavisualiseringsprogram med åpen kildekode. Programmet ligger tilgjengelig på GitHub, og kan brukes til dataanalyse på et intuitivt og visuelt nivå. Orange kan utføre klassifisering og regresjonsanalyse samt mye mer, på datasett i CSV- eller Excel-format (Orange 2017). I denne oppgaven brukes Orange versjon 3.3.11 til å klassifisere og visualisere statistiske data produsert i lascanopy (kapittel 7.1.7).

Diverse andre programmer

Andre programmer, som ikke er direkte avhengige av metoden, er Microsoft Excel og Trimble eCognition. Excel er brukt til å produsere alle tabeller presentert i oppgaven. Samt gjøre kalkuleringer og grafiske fremstillinger statistiske data fra de andre programmene. eCognition er brukt i en konseptuell utgave av metoden, der effektivisering av original metode beskrives. eCognition er et kraftig klassifiseringsverktøy med en rekke funksjoner for raster- og vektordata. Med mulighet til å effektivisere mange av de mer ressurskrevende stegene i oppgavens metode (les kapittel 7.1.3).

5.2 Metode

Helheten i denne oppgaven formidles gjennom flytskjemaer presentert i dette kapittelet. Både for hva som er gjort, og for en konseptuell utgave av et produkt. Målet med metoden er å svare på problemstillingen, som følger:

«Hvilken tilleggsverdi har multispektrale laserdata fra Optech Titan, i forhold til tradisjonelle laserdata, ved klassifisering av objekter og arealtyper i en punktsky.»

For dette er en arbeidsflyt utviklet i to deler. Hoveddelen består av en klassifisering av data hentet fra Optech Titan, mens en forberedende del ser på datagrunnlaget, og hva Optech Titan er i stand til å registrere av laserdata. Veivalg og utfordringer er også beskrevet i denne delen.

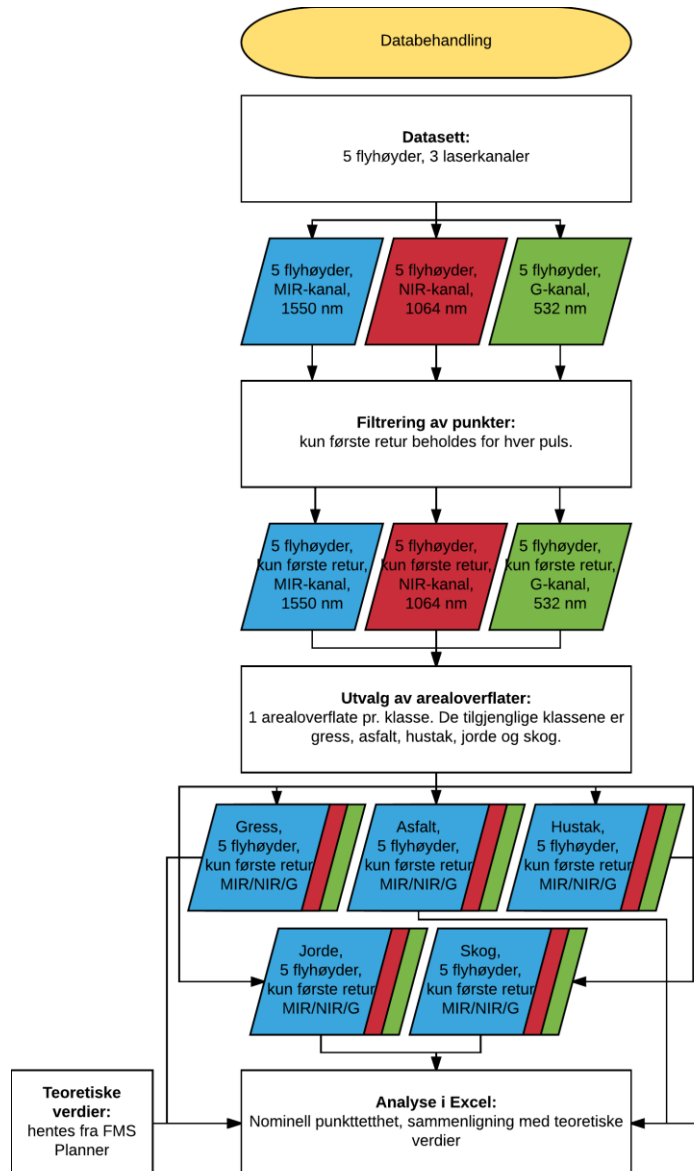
5.2.1 Optech Titans laserkapasitet

For å vurdere eventuelle tilleggsverdier til en multispektral laserskanner for klassifisering, er det først interessant å se på laserkanalenes kapasitet. Punkttetthet skal analyseres for å vurdere grunnlaget spektralverdiene stammer fra. I form av punkttetthet og returpulsstyrke. Det skal plukkes ut fem forskjellige overflatetyper, og for hver av disse skal en teoretisk forventet punkttetthet sammenlignes mot den faktiske punkttettheten i datasettet. Kun første retur pr. puls inkluderes. Resultatene blir tatt med i vurderingen av de multispektrale tilleggsverdiene til Optech Titan, og som egenskaper i klassifiseringen.

Veivalg og utfordringer

Denne delen av oppgaven er ment som en vurdering av Optech Titans klassifiseringsgrunnlag. Dette for å danne et mer helhetlig bilde av skanneren. Slik kan mangler og uregelmessigheter kartlegges for bedre forståelse av klassifiseringsresultater og forbedringspotensial. Hvordan informasjon om de forskjellige overflatenes registreringsevne skal brukes videre i klassifiseringen blir løst ved å implementere en kvalitativ egenskap for sterkeste og svakeste

kanal pr. overlate (les kapittel 7.1.6). Denne egenskapen viser seg å prestere dårlig i rangeringsalgoritmen, og ble dermed utelukket fra videre analyse.



Figur 5.4: Metode for innledende del av oppgaven.

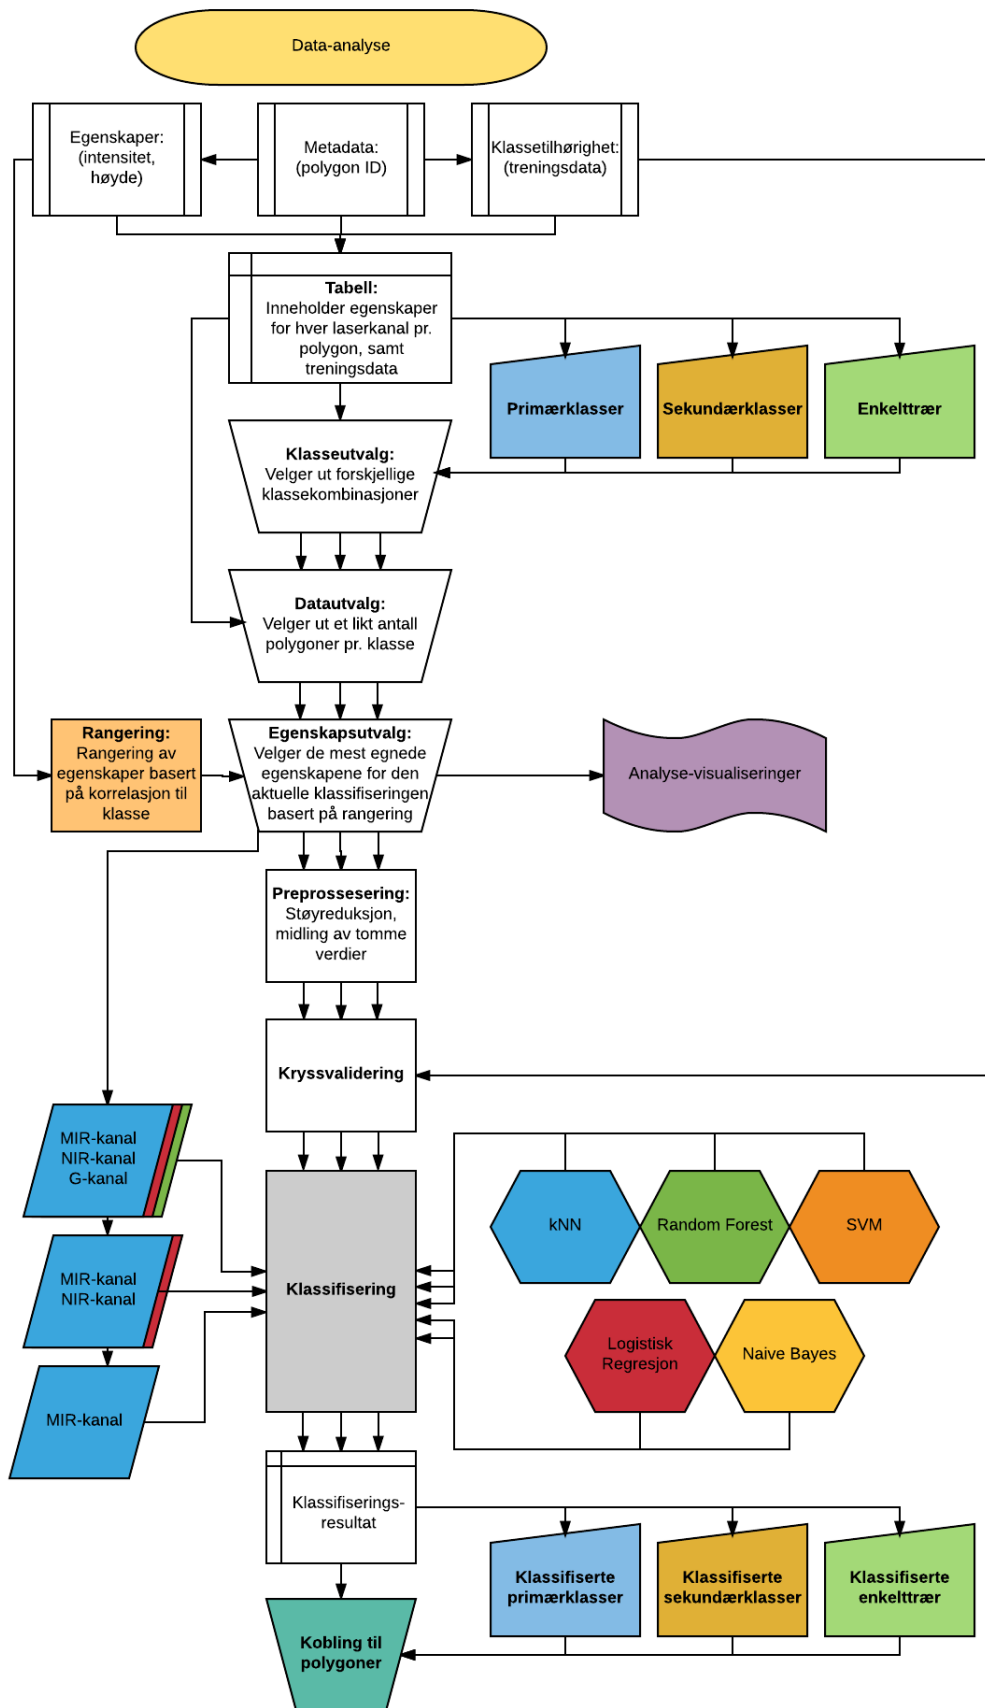
5.2.2 Klassifisering av multispektrale laserdata fra Optech Titan

For å svare på problemstillingen skal intensitetsverdier fra Optech Titans tre laserkanaler brukes til å klassifisere arealoverflater og objekter. I problemstillingen er arealtype nevnt, men da menes overflate-materiale/innhold, og ikke arealressurs, slik NIBIO (Norges Institutt for Bioøkonomi) definerer begrepet arealtype (Arealtype 2017). Klassifiseringen skal gjøres med alle tre laserkanaler, to laserkanaler, og én laserkanal hver for seg. Om resultatene viser at tre

laserkanaler er bedre enn to og én kanal, har de multispektrale laserdataene tilleggsverdi. Klassifiseringen gjøres på forskjellige utvalg, for å kartlegge hvor tilleggsverdiene ligger. Kappa-koeffisient og forvirringsmatriser fra klassifiseringene brukes til å vurdere resultatene. Dette er en gode indikatorer på klassifiseringens nøyaktighet (Viera & Garrett 2005). For de tre forskjellige klassifiseringsoppsettene, med tre kanaler, to kanaler og én kanal, er MIR, NIR og G valgt for multispektral klassifisering, MIR og NIR valgt for dual-spektral klassifisering og MIR valgt for monospektral klassifisering. Kanalene utelukkes etter antatt tilleggsverdi basert på returpulsstyrke, som studeres i forberedende del (kapittel 6.3), og norm innenfor bransjen. G utelukkes først, da denne kanalen har svakere pulser enn de to andre, og i hovedsak er en batymetrisk skanner. NIR utelukkes deretter da denne også har tendenser til å miste returer på visse overflater. MIR brukes som tradisjonelt grunnlag da denne har de sterkeste returpulsene, og bølgelengden er vanlig å bruke innenfor tradisjonell laserskanning. Det ble vurdert om NIR-kanalen skulle brukes som tradisjonelt grunnlag, men på grunn av dårligere punktgrunnlag, og ingen store forskjeller når bruk alene, ble den valgt bort.

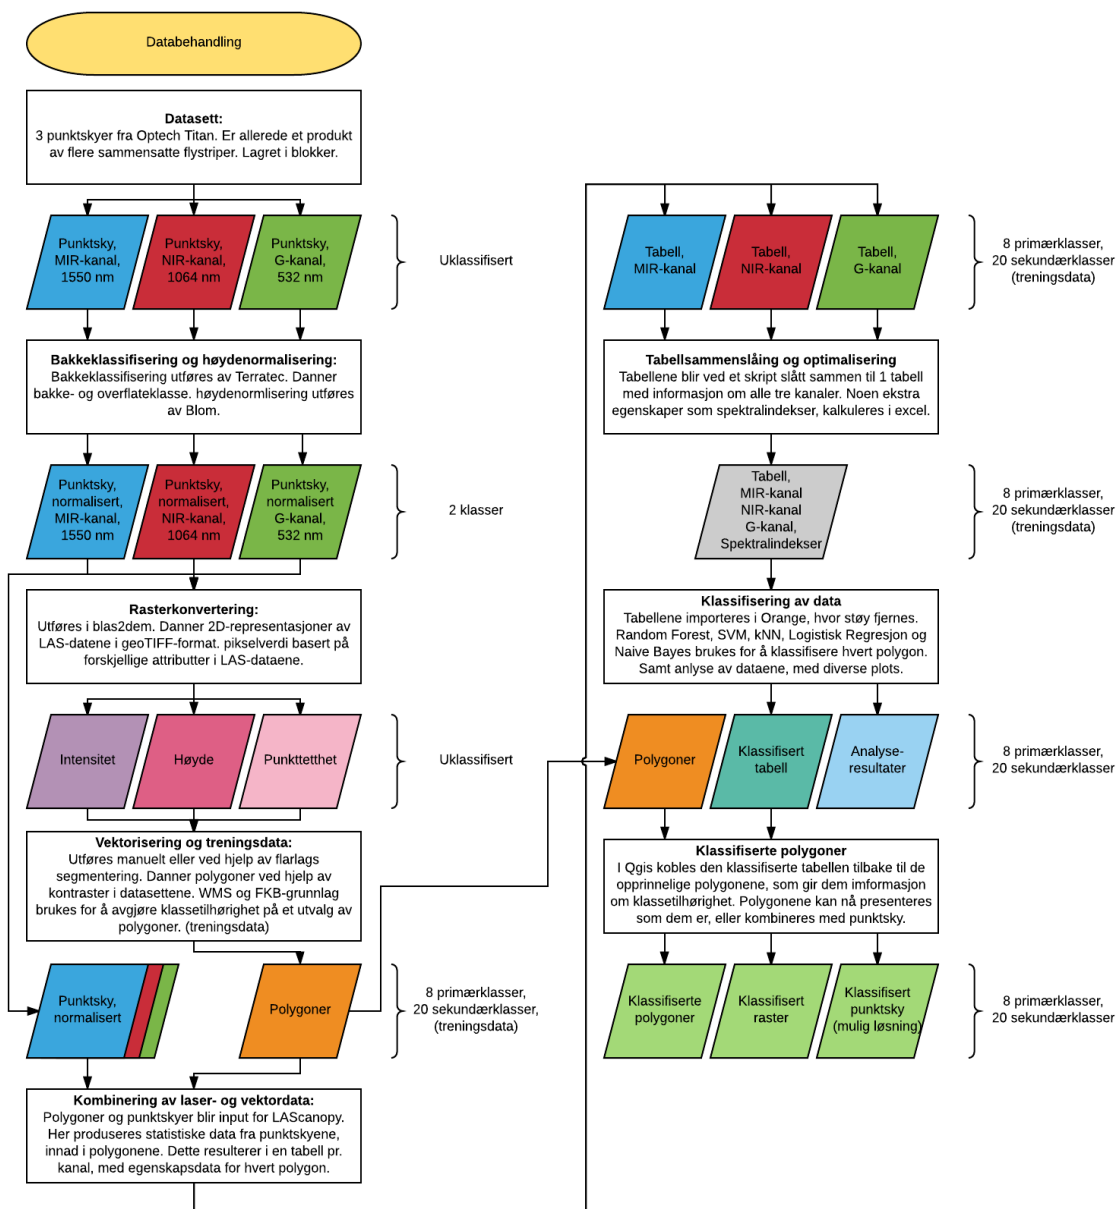
De forskjellige utvalgene deler data inn i primærklasser, sekundærklasser og enkeltrær. Disse skal klassifiseres hver for seg. Primærklassene inneholder flere sekundærklasser. I primærklassifiseringen blir den mest aktuelle sekundærklassen i hver primærklasse valgt ut. Dette fordi variasjonene mellom sekundærklasser har vist seg å være for store til å settes sammen til én klasse. Sekundærklassifiseringen inneholder alle sekundærklasser fra alle primærklasser bortsett fra «ung skog» (71), som viste seg å ikke la seg skille på noen måte fra «voksen skog» (72) sånn klassene er delt inn. Den siste klassifiseringen er enkeltreklassifisering, som innebærer å skille ulike tresorter fra hverandre. Tidligere forskning har vist at laserskanning med multispektrale egenskaper kan gi verdifulle data for skogkartlegging, med en klassifiseringsnøyaktighet på 85,6% (Yu et al. 2017), men i det omtalte forsøket er flyhøyden kun 400 m over terrenget. I kapittel 6.3 kommer det frem hvor avgjørende flyhøyde er for skog-klassene. Det kan gi stor nytteverdi om intensitetsverdiene kan brukes til klassifisering av enkeltrær ved denne oppgavens flyhøyde på 1900 meter.

En oversikt over hvordan dataene klassifiseres følger:



Figur 5.5: Arbeidsflyt for klassifisering og analyse av data.

Laserdataene slås sammen i segmenter, der høyde- og intensitetsstatistikk kalkuleres for hvert segment. Segmentene klassifiseres til overflatetype basert på denne statistikken. Percentiler og gjennomsnitt forhindrer at støy påvirker dataene i stor grad, andre statistiske mål som standardavvik, kurtose og skjevhet er med på å karakterisere dataene. Metoden er en kombinasjon av raster-tilnærming og punkt-tilnærming til datagrunnlaget (les kapittel 6.1.4). Der overflatene som klassifiseres er segmentert ut fra rasterrepresentasjoner, mens innholdet i hver overflate er data hentet direkte fra punktskyen. Metoden er tenkt å kunne brukes til faktisk produksjon av klassifiserte laserdata. En oversikt over metoden følger:



Figur 5.6: Arbeidsflyt for databehandling. Fra punktsky til klassifiserte produkter.

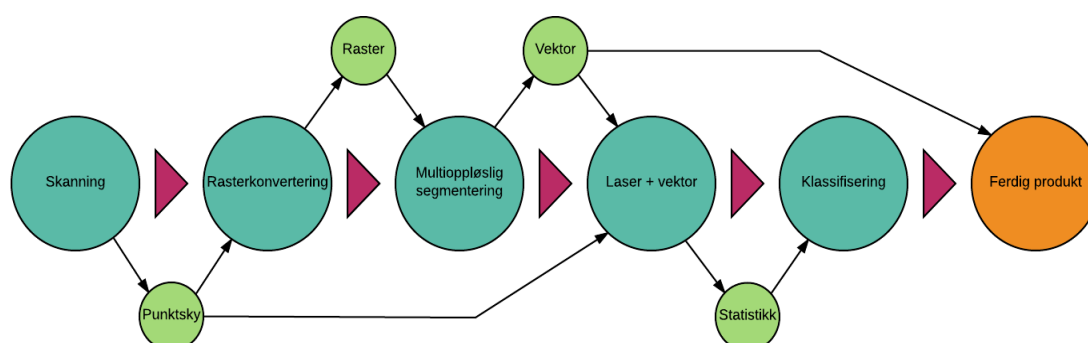
Les hvordan denne metoden utføres i fremgangsmåten (kapittel 7.1).

Veivalg og utfordringer

I kapittel 6.1.4 blir metoder fra tidligere forskning vurdert, for å utnytte potensialet i Optech Titans datainnsamling. Metoden i denne oppgaven er inspirert av disse, men kombinerer flere av de gode egenskapene fra hver av dem. Å dele inn overflater basert på rasterdata, er enklere enn å jobbe direkte i punktskyen, men punktskyen inneholder mye data som går tapt ved å bare jobbe på rasternivå. Derfor hentes statistikk direkte ut fra punktskyen. Om hele prosessen hadde foregått med direkte tilknytning til punktskyen, hadde dette vært optimalt, men også mer komplekst. I denne oppgaven har tid og kompetanse begrenset kompleksiteten til å finne en kombinasjonsløsning mellom det simple og det komplekse. Metoden er også valgt på grunn av at den beregner statistikk for store, men homogene overflater i datasettet. Ettersom den nominelle punktavstanden i datasettet er stor (les kapittel 0) vil punkt- og rasterbasert statistikk kunne gi feilinformasjon om overflaten. En god segmentering, vil dele overflater opp langs kontraster i overflaten, og vil ikke blande verdier i overflater med dårlig fullstendighet.

5.2.3 Konseptuelt produkt

Et tenkt produkt basert på denne oppgaven er beskrevet og illustrert her. Gjennom utvikling av metoden, har ressurskapasitet og tid satt begrensinger for et fullstendig og fungerende produkt. Dette drøftes i kapittel 7.3. Produktet er en effektivisert og automatisert utgave av metoden i denne oppgaven. Punktskyene normaliseres og slås sammen. Dette blir grunnlag for raster med intensitets-, høyde- og tetthetsverdier. Rasterene brukes i en flerlags-segmentering, til å produsere polygoner. Punktskyen gir statistikk til hver polygon, som brukes til å klassifisere polygonene med parametere generert fra treningsdata hentet fra denne oppgaven eller eventuelle andre datasett. De klassifiserte polygonene komplimenterer så punktene i punktskyen med klassetilhørighet.



Figur 5.7: Konseptuell utgave av metode for produktgrunnlag.

6 Optech Titans kapasitet

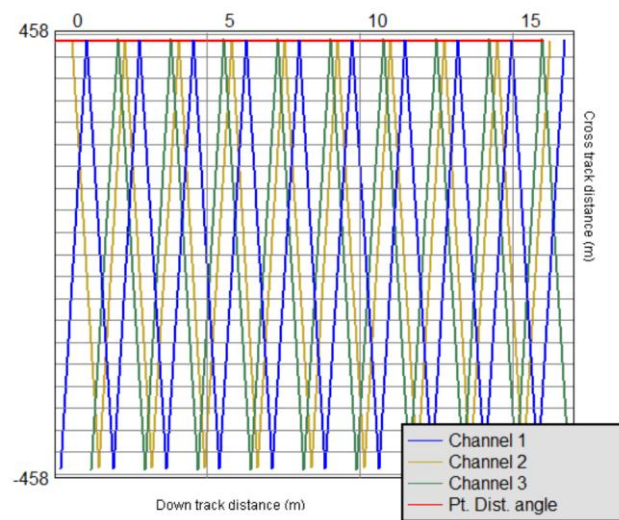
I følge Teledyne Optech selv, skal Titan være like mye i stand til å utføre høyoppløselig, topografisk kartlegging som vegetasjonskartlegging og 3D-overflateklassifisering opp til 2000 m (Optech 2015). I dette kapittelet blir Optech Titans faktiske kapasitet testet.

6.1 Vurdering av datasett

Til å begynne med inspiseres to av Optech Titans punkttskyer. Datasett over Rakkestad og Alvdal går igjennom for å danne et inntrykk av hvordan laserdataene fra Optech Titan ser ut. Disse datasettene er skannet på forskjellige tider av året, på forskjellige høyder, og med forskjellige parameterinnstillinger.

6.1.1 Punktfordeling

Terratec AS har hatt problemer med punkttettheten ved høye flygninger, der G-kanal ser ut til å ikke få sterke nok retursignaler for punktregistrering. Ettersom de forskjellige laserkanalene også er låst i ulike retninger mot bakken, byr dette på utfordringer for flyplanleggere. Pr. kanal blir avstanden mellom hver skannelinje ujevn, og kan fort danne ugunstig punktfordeling. Samles kanalene ser punktskyen mer konsistent ut. Optech Titan bruker et oscillerende speil for å fordele laserpulser i skannerretning. Dette gir skannemønsteret en slags sikksakk-formasjon. En visualisering av hvordan skannelinjene vil fordele seg med Optech Titan vises under:




Figur 6.1: Teoretisk representasjon av Optech Titans skannemønster. Det er også mulig å se for seg at punkttettheten kan bli høyere i skannerretning. (Optech 2016)

Dette innebærer også at punkttettheten blir høyere i kantene enn på midten av flystripen. Med tanke på at avstanden mellom hver skannelinje er større enn ønskelig, får vi dermed en ugunstig fordeling. Mange punkter ligger med centimeters avstand i skanneretning, mens avstanden i flyveretning er nærmere meteren.



Figur 6.2: Utsnitt av Optech Titans faktiske punktfordeling. Fra LAsTools.

Terratec AS har selv nevnt at den nominelle punktavstanden har blitt bedre etterhvert som programvare som støtter flyplanlegging med Optech Titan har blitt tilgjengelig. Likevel finnes det gjennomgående mønstre i datasettet over Alvdal. Som vist på disse utsnittene fra LAsTools.




Figur 6.3: Utsnitt fra LAsTools viser ujevnheten i punktfordeling. Til venstre ser vi en åpen slette med noen trær. Punkter farget med intensitetsverdi. Til høyre ser vi et nabolag. Punkter farget med bakke/ikke-bakke klassifisering.

Mønsteret i punktskyen kan minne om eksempelet i teorien, kapittel 4.3. Der punkttettheten er mye høyere i skanneretning enn i flyveretning. Grunnen til dette er flyplanlegging og det oscillerende speilets fysikk. Dette er en lite effektiv utnyttelse av pulsenergien, som gir store gap i geometrien langs flyveretningen. Det blir også hull i geometrien over noen hustak. Det drøftes senere i kapittelet hvilke kanaler som har størst problemer med å registrere punkter på forskjellige overflater. Ved en høyde på 1900 m over terrenget er det vist i kapittel 6.3 at Optech Titan ikke yter optimalt ved punktregistrering.

6.1.2 Intensitetsverdier

Det er også oppdaget en del ujevnheter i intensitetsdataene. Dette er noe som forårsakes både av atmosfæriske forhold, stripeoverlapp, returnnummer og bevegelse i flykroppen. Denne oppgaven går ikke inn i detaljene på hva som forårsaker hva, men ujevnheter i intensitetsdataene kan ha mye å si for en klassifisering basert på intensitet. To utsnitt fra LAStools over Alvdal er vist under, der forskjellige årsaker har påvirket intensitetsverdiene. En intensitetskalibrering kan antakelig utjevne verdiene, flere metoder finnes for å utføre slike kalibreringer. Se kapittel 4.2. Å gjøre dette over store områder vil pr. dags dato kreve mye ekstra tid og ressurser i en klassifiseringsprosess. Derfor vil dataene beholde sine opprinnelige intensitetsverdier i denne oppgaven, for å se om de har tilleggsverdi også uten å gjennomgå store kalibreringsbehandlinger.




Figur 6.4: Utsnitt fra LAStools over Alvdal viser ujevnheter i intensitet. Til venstre er ulike effekter synlige. Til høyre er ujevnheter antakelig forårsaket av bevegelse i flyet.

Når det gjelder intensitetsverdiene som lagres i hvert punkt, ser disse ut til å ha lavere verdier enn på mange andre skannere. Det er uvisst hvordan disse verdiene behandles av systemet, fra de registreres som returpulser, til en tallverdi for intensitetsrepresentasjon tilegnes hvert punkt. En form for relativ kalibrering er antatt. Det oppdages at intensitetsverdier fra G-kanalen er mye lavere enn fra de to andre kanalene. Dette skyldes antakelig de sikkerhetsmessige årsakene rundt å sende ut grønn laser med høy styrke, da dette kan være skadelig for øyet. Grønn laser har også lavere reflektans enn de to andre kanalene på mange overflater (les kapittel 4.4). Dessverre går dette også ut over LiDAR-ytelsen til laserkanalen. Spesielt ved høye flygninger, der denne kanalen til tider faller helt ut (Se Figur 6.6). Også det at hver av laserkanalene er vinklet forskjellig, gjør at ingen av laserpunktene fra de forskjellige kanalene kan kobles sammen på et attributt. Hadde kanalene vært stilt i samme retning kunne f.eks. GPS-tid blitt brukt til

sammenkobling. De forskjellige kanalene har spredning mellom seg, og disse må slås sammen for å kunne brukes i en klassifisering. Metode for sammenslåing kan finnes i kapittel 5.2.2, og hvordan dette er gjort kan leses i kapittel 7.1.


6.1.3 Kanalforskjeller

Optech Titan har som tidligere nevnt i kapittel 5.1.1 tre separate laserkanaler. Dette skaper tre separate punktskyer. De inspiseres både samlet, og hver for seg. Når punktskyene ligger samlet, kan dataene se fullstendige ut. Men studerer vi punktskyene hver for seg, blir punktfordelingen ujevn. Spesielt på visse områder. Her et utsnitt som illustrer denne effekten over Rakkestad.



Figur 6.5: Punktfordelingen ved flygning på 1600 m over terrenget for hver kanal. Viser hver for seg og samlet.

Punktskyene er ikke helt like. Dette kommer bl.a. av at laserkanalene er vinklet forskjellig. Andre årsaker er overflaterreflektansen i terrenget. De forskjellige kanalene oppfører seg ulikt i forhold til hverandre. Noen laserpulser absorberes fullstendig i én kanal, mens nærliggende laserpulser i andre kanaler reflekteres. NIR-kanalen ser ut til å få flest returverdier på vegetasjon, mens MIR-kanalen får gode returverdier på bakkepunkter. Dette stemmer godt overens med reflektanskurene i Figur 4.5. G-kanal derimot, har generelt lavere intensitet og har færre returverdier enn de to andre kanalene. Spesielt over skogkledde områder. Dette studeres nærmere i kapittel 6.3.



Figur 6.6: Utsnitt fra LAStools over skogsområde i Rakkestad. Fra venstre: MIR, NIR, G. Det lyse området er skog, og har generelt få returer pga. lave intensitetsverdier. Mørkt område er utmark. En vei buker seg gjennom skogen.

6.1.4 Punktsky-matching

Hvordan problemstillingen skulle besvares ble vurdert blant flere potensielle løsninger. Punktskyene Optech Titan produserer, har ingen direkte kobling til en viss klassifiseringsmetode. Råmaterialet fra Optech Titan etter punktskydannelse er tre separate punktskyer, der punktene er uten direkte referanse til hverandre. Det ville vært mulig å koble punktene sammen på GPS-tid, om de hadde blitt sendt ut i lik retning. Metoden for å gå fra tre separate punktskyer, til å klassifisere objekter og arealoverflater basert på spektralverdier, kan derfor utvikles på flere forskjellige måter. En del operasjoner må uansett gjøres på dataene. Tidligere forskning har funnet flere metoder for å utnytte dataene fra Optech Titan på. Noen av disse ble også vurdert i denne oppgaven. Det er i hovedsak blitt brukt to forskjellige metoder tidligere, som forklares her i korte trekk. Metoden som brukes i denne oppgaven, prøver å beholde enkelheten fra raster-tilnærming, men også ta med egenskapsmangfoldet fra punkt-tilnærmingen.

Raster-tilnærming

I denne metoden lages et grid på f.eks. 1x1 m basert på hver laserkanal. Den gjennomsnittlige intensitetsverdien innenfor hver 1x1 m lagres i den aktuelle grid-ruten pr. kanal. Gridet for tre kanaler legges over hverandre, og den gjennomsnittlige verdien i hver grid-rute pr. kanal brukes til å produsere en rasterrepresentasjon av de tre kanalene. Med tre verdier pr. grid-rute, kan de fremstilles som et RGB-bilde. Tradisjonell bildeanalyse kan da brukes til å skille overflater fra hverandre. Og klassifisering kan foretas på samme måte som i et ortofoto. (Bakuła 2015) Metoden kan også brukes til å danne spektralindekser. den gjennomsnittlige verdien i hver grid-rute brukes til å produsere en spektralindeks. Alle punkter i punktskyen blir da tilegnet en spektralindeks-verdi ved hjelp av bilinear interpolasjon. Dette gjøres for de tre mulige

kombinasjonene av spektralindekser. Metoden i praksis fungerte bra for å skille bebyggelse fra vegetasjon, men hadde problemer med å skille vann fra vegetasjon. (Morsy et al. 2016)

Metoden er enkel, og utnytter dermed ikke alle egenskapene i datasettet. Ved å legge alle punkter i datasettet innenfor et grid, simplifiseres også datasettet en del. Det er tydelig at intensitetsverdiene fra Optech Titan inneholder mye støy, selv om ikke geometrien gjør det. Et lavpassfilter i form av gjennomsnittsverdier kan være et nyttig verktøy for bedre resultater.

Punkt-tilnærming

I denne metoden blir alle punktskyene slått sammen til én. Et verktøy for å gi hvert punkt tre intensitetsverdier utvikles. Hvert punkt får intensitetsverdiene til de nærmeste punktene fra de andre kanalene, basert på en nærmeste-nabo operasjon. Andre punktegenskaper kalkuleres også (Wichmann et al. 2015).

Denne metoden unngår grid, og beholder tredimensjonalitet i datasettet. Problemer med intensitetskalibrering og mangel på returer fra G-kanalen gjør at denne metoden heller ikke fungerer optimalt. En feilkilde er også at metoden kan føre til feil sammenslåing av punkter. Om f.eks. avstanden fra ett punkt i G-kanal er lik til to punkter i NIR-kanal, blir hvert NIR-punkt tilegnet den samme G-verdien. Denne metoden er også mer kompleks enn den andre grid-baserte metoden.

6.2 Fremgangsmåte

For en oversikt over de ulike stegene i fremgangsmåten, se metode for laserkapasitet, kapittel 5.2.1 De ulike delene av metoden beskrives her i detalj.

Etter å ha inspisert punktskyene fra Optech Titan, kommer det tydelig frem at kanalene presterer ulikt på like overflater. For en klassifisering basert på tre kanaler, kan det være interessant å finne ut hvilke typer overflater de presterer dårligere/bedre på. Det skal også undersøkes om flyhøyde opp til 2000 m har innvirkning på kanalenes prestasjon. Dette skal gjøres ved å telle utsendte pulser, kontra mottatte pulser, for forskjellige høyder og forskjellige klasser. Utsendte pulser vil kalkuleres i Optech FMS Planner. Mottatte pulser vil hentes ut fra datasettet.

6.2.1 Datasett Rakkestad

Et godt egnet datasett for en slik undersøkelse, er testflygningen av Optech Titan over Rakkestad flyplass. Utført av Terratec AS. Flygningen er gjort den 28.10.2016, mellom kl. 13:00 og 13:30. Det er flydd fem flystriper over flyplassen, ved høyde 536 m, 936 m, 1200 m, 1600 m og 2000 m over terrenget. Flyets hastighet var 250 km/t på alle stripene. Se en oversikt

over flygningen i kapittel 5.1.2. Datasettet er allerede autoklassifisert når det hentes fra Terratec AS sin database. En så sen flyvning på året er ikke optimalt for å få spektralinformasjon ut av vegetasjon, da mange trær er bare. Likevel er dette et godt utgangspunkt for analyse av punktetthet, da datasettet består av fem forskjellige høyder over samme område.


Det er også blitt påpekt av Terratec AS, at det på flyvningens tidspunkt, ikke var lagt til rette for optimal flyplanlegging. Tendenser til dårlig punktfordeling, som diskutert i kapittel 5.1.1 kan være et resultat av manglende programvare for flyplanleggingen, men dette er ikke bekreftet.

6.2.2 Filtrering av punkter

Datasettet importeres til Terrascan. Denne prosessen kunne også blitt gjort med en kombinasjon av Lastools og QGIS, slik som resten av oppgaven, men Terrascan har for enkle analyser et mer lettvent brukergrensesnitt. I Terrascan filtreres alle punkter som ikke er første retur av en splittet laserpuls, vekk fra punktskyen. Dette fordi flere returverdier pr. laserpuls vil gi feilinformasjon når det studeres utsendte pulser kontra mottatte pulser. I denne sammenheng er puls-tetthet og puls-fordeling mest interessant å studere (Isenburg 2014).

6.2.3 Utvalg av arealoverflater

Med laserpunktene vist i intensitetsverdi, kommer tydelige konturer av forskjellige arealoverflater frem i punktskyen. En ortofoto-representasjon fra Google Earth® av samme område, brukes for å gjenkjenne hva slags type overflater punktskyen består av.



Figur 6.7: Polygonutvalg for vurdering av punktetthet. Til venstre: Google Maps®, brukt som fasitdata for klassebestemmelse. Til høyre: punktsky i Terrascan, med polygoner for avgrensning av punktsky.

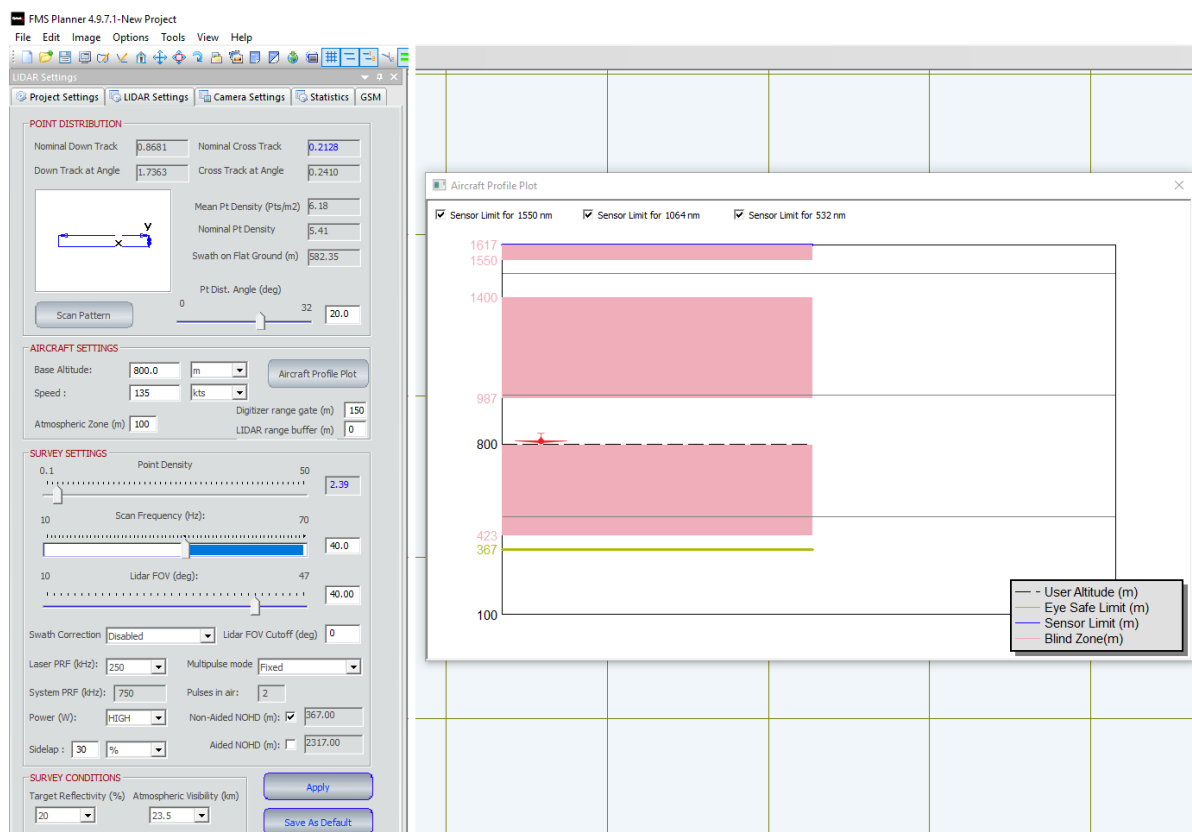
Det plukkes ut 5 forskjellige arealoverflater for denne analysen. Hver overflate med sin egne unike klasse. Disse klassene, er konsekvent et utvalg av de 8 klassene i klassifiseringsdelen av oppgaven. Begrunnelse av klassene finnes i kapittel 7.1.4. Ettersom ikke alle 8 klassene er representert i dette datasettet, blir de 5 tilgjengelige klassene analysert. Disse er asfalt, hustak, jord, skog og gress. Selv om kun 5 representeres her, kan styrker, svakheter og begrensninger ved Optech Titan oppdages ut fra de aktuelle klassene. I Terrascan tegnes 5 utvalg i punkttskyen over Rakkestad. Ett utvalg pr. arealklasse, for å holde analysen relativt enkel. Det kunne vært aktuelt å tegne flere utvalg pr. arealklasse, men punkttskyene ser ikke ut til å variere mye i punkttetthet innad i de forskjellige arealklassene. I Terrascan kan hvert utvalg inspiseres isolert fra de andre. Utvalgene filtreres basert på flyhøyde og hvilken laserkanal de hører til. Et av verktøyene i Terrascan, kalt Project Statistics, gjør det mulig å inspiserer antall punkter i hvert utvalg, pr. laserkanal og pr. flystripe. Disse verdiene lagres i tabeller, for videre analyse (se Vedlegg 1 i kapittel 10). For å gjøre tallene relative, beregnes den nominelle punkttettheten i Terrascan. Nominell punkttetthet defineres i kapittel 4.3. Tabellen under er en presentasjon av den nominelle punkttettheten for hvert utvalg, pr. laserkanal, pr. flystripe.

meter over terreng:		2000	1600	1200	800	400
Gress	1550 nm	1,20	1,92	3,15	2,81	11,31
	1064 nm	1,24	1,82	3,10	2,89	11,36
	532 nm	0,00	1,75	3,16	2,73	11,33
	Totalt	2,44	5,50	9,42	8,43	34,01
Asfalt	1550 nm	1,03	1,92	2,99	2,85	12,27
	1064 nm	0,00	0,61	3,13	2,86	11,65
	532 nm	0,02	1,91	3,17	2,83	11,67
	Totalt	1,05	4,44	9,29	8,55	35,59
Hustak	1550 nm	1,37	1,80	3,05	2,68	11,16
	1064 nm	1,20	1,86	3,31	2,84	10,71
	532 nm	1,20	1,86	2,93	2,77	11,18
	Totalt	3,77	5,51	9,29	8,28	33,05
Jord	1550 nm	0,99	1,85	3,02	2,82	10,53
	1064 nm	0,18	1,87	3,00	2,82	10,81
	532 nm	0,03	1,82	3,08	2,77	10,72
	Totalt	1,20	5,54	9,10	8,42	32,06
Skog	1550 nm	0,02	0,28	1,59	2,67	10,55
	1064 nm	0,00	0,09	1,64	2,86	10,93
	532 nm	0,00	0,00	0,00	0,65	10,81
	Totalt	0,02	0,37	3,24	6,17	32,29

Tabell 6.1: Punkttetthet i hvert utvalg, pr. klasse, pr. flyhøyde.

6.2.4 Teoretiske verdier

Punkttheteten sammenlignes videre med teoretiske tall for utsendte laserpulser. Dette kan oppdrives i flyplanlegger-programvaren FMS Planner. I dette programmet kan de programmerbare parameterne til Optech Titan justeres. Flygningen over Rakkestad flyplass gjenskapes her, for å finne den teoretiske punkttheteten. Fart settes til 135 knop (250 km/t), som er den faktiske farten i alle stripene. Skannefrekvens settes til 40 Hz, som er antall skannelinjer pr. sekund. Lidar FOV settes til 40 grader. Laser PRF settes ulikt ved forskjellige høyder. Konstant PRF på 250 kHz fører til at blindsoen for skannersystemet dekker over alle høyder bortsett fra 400 m. Dette forklarer hvorfor flygningene er gjort med forskjellig frekvens. I utklippet fra Optech FMS Planner under, er blindsonene illustrert ved aktuell PRF på 250 kHz. Av de aktuelle høydene er det kun 400 m som går utenfor.



Figur 6.8: Oversikt over FMS Planners brukergrensesnitt. Til venstre kan Optech Titans parametere justeres. Til høyre ser vi flyets plassering i forhold til blindsonene. I dette bildet er Laser PRF satt for høyt. Flyet vil ligge for nære blindsonen. (Optech 2016)

Ved å sette parameterne like som ved selve flygningen, oppgir FMS Planner teoretisk punktthet. Her brukes nominal punktthet. Da dette baserer seg på punktthet for kun første retur, og kalkuleres ut fra irregulær punktavstand i både flyve- og skanneretning. (Geocue 2016) Tallene for hver høyde lagres i en tabell, for videre sammenligning med faktisk punktthet.

m over terrenget	1550 nm	1064 nm	532 nm	Total
2000	1,08	1,08	1,08	3,24
1600	1,62	1,62	1,62	4,86
1200	2,89	2,89	2,89	8,67
800	2,71	2,71	2,71	8,13
400	10,83	10,83	10,83	32,49

Tabell 6.2: Samlet og separat punkttetthet for de tre laserkanalene. I utgangspunktet skal denne være lik pr. kanal.

6.3 Resultater og analyse


Optech Titan har tydelige begrensinger ved skanning av overflater. Punkttetthet for hver klasse ble studert ved forskjellige høyder. Forholdet mellom hver kanal ble analysert, og sammenlignet med en teoretisk fasitverdi for de aktuelle forholdene. Et prosenttall på antall faktiske returverdier, kontra teoretiske returverdier, er grunnlag for konklusjonen. Om tabellverdien viser 100% eller mer, har teoretisk sett alle utsendte laserpulser returnert. Om tabellverdien viser 0% har ingen laserpulser returnert. Verdiene inngår i tabellen som følger:

meter over terreng:		2000	1600	1200	800	400
Gress	1550 nm	111 %	119 %	109 %	104 %	104 %
	1064 nm	115 %	112 %	107 %	107 %	105 %
	532 nm	0 %	108 %	109 %	101 %	105 %
	Totalt	75 %	113 %	109 %	104 %	105 %
Asfalt	1550 nm	95 %	119 %	103 %	105 %	113 %
	1064 nm	0 %	38 %	108 %	106 %	108 %
	532 nm	2 %	118 %	110 %	104 %	108 %
	Totalt	32 %	91 %	107 %	105 %	110 %
Hustak	1550 nm	127 %	111 %	106 %	99 %	103 %
	1064 nm	111 %	115 %	114 %	105 %	99 %
	532 nm	111 %	115 %	101 %	102 %	103 %
	Totalt	116 %	113 %	107 %	102 %	102 %
Jord	1550 nm	92 %	114 %	105 %	104 %	97 %
	1064 nm	17 %	115 %	104 %	104 %	100 %
	532 nm	3 %	112 %	107 %	102 %	99 %
	Totalt	37 %	114 %	105 %	104 %	99 %
Skog	1550 nm	2 %	17 %	55 %	98 %	97 %
	1064 nm	0 %	6 %	57 %	105 %	101 %
	532 nm	0 %	0 %	0 %	24 %	100 %
	Totalt	1 %	8 %	37 %	76 %	99 %

Tabell 6.3: Forholdet mellom teoretisk og faktisk punkttetthet i prosent.

Det kommer frem av denne tabellen at Optech Titan ikke har problemer knyttet til punkttetthet ved flygninger på 400 m over terrenget. Alle overflater gir gode returverdier, som danner et godt grunnlag for spektralanalyse, da et fullstendig sett med intensitetsverdier kan tas i bruk. Også for flygninger ved 800 m gjelder dette, bortsett fra i skogkledde områder. Her faller noen av returene fra G-kanalen ut. Punkttettheten, som egentlig skulle vært 2,71 pkt/m, er kun 0,65

pkt/m. Dette samsvarer med Figur 6.6. I skog blir laserpulsene delt opp i flere, svakere pulser da små overflater ikke reflekterer hele fotavtrykket til laserstrålen. Det er kun de første returene pr. puls fra disse overflatene som er med i datasettet. G-kanalen har i utgangspunktet svakere pulser enn MIR- og NIR-kanalene (les kapittel 6.1.2), da sterke pulser med denne bølgelengden kan være skadelig for øyet. De fleste overflater har også lavere reflektans i den grønne delen av spekteret, enn i de infrarøde. Det er derfor trolig at G-kanalens splittede returpulser ikke er sterke nok til å registreres av LiDAR-systemet. De verdiene som faktisk returnerer vil i så fall også ha lavere intensitetsverdier, da pulsens intensitet er et direkte mål på pulsens styrke. Om Optech Titan gjør en automatisk intern intensitetskalibrering på disse verdiene er uvisst, men om det ikke gjøres, er intensitetsverdier fra trær utsatt for misvisende verdier. Lave intensitetsverdier kan på en annen side også være et kjennetegn for trær, og kan da klassifiseres på grunnlag av dette. Forskjellige tresorter kan da likevel bli vanskelig å skille. MIR- og NIR-kanalene kan ved 800 m fortsatt brukes til en dualspektral klassifisering, men ved 1200 m begynner også disse å returnere færre pulser i skogsområder. Antakelig av samme årsak som med G-kanalen. Her er punkttettheten for MIR- og NIR-kanalene halvert, mens G-kanalen har falt helt ut. De andre overflatene ser fortsatt ut til å returnere alle pulser. De andre overflatene er av natur flater og mer homogene, og pulser blir antakelig ikke splittet opp i like stor grad her. Ved 1600 m begynner likevel NIR-kanalen å miste returverdier på den asfalterte overflaten. De andre kanalene ser ut til å beholde punkttettheten. På denne høyden begynner antakelig returverdiene å bli svakere, men er for de fleste overflater fortsatt sterke nok til å registreres av LiDAR-systemet. Etersom G-kanalen har svakere pulser enn de to andre, er det noe annet som gjør at NIR-kanalen faller ut først. I følge spektralkurven for asfalt, reflekteres NIR i større grad enn G. NIR-kanalen skanner også vinkelrett på terrenget, noe som burde gi den bedre retursignaler på flater. Det er derfor uvisst hvorfor NIR-kanalen faller ut på asfalt. Asfalt har likevel generelt lav reflektans, og er antakelig grunnen til at denne faller ut før andre flater.



Figur 6.9: Reflektansverdier for asfalt og gress. (vegetasjon) (Kotthaus et al. 2014)

Ved 1600 m har også de fleste av skog-returene på alle kanaler falt ut. MIR-kanalen har flest retur (17%), men i spektralkurven for vegetasjon har NIR betydelig høyere reflektans enn

MIR. NIR har kun 6% av teoretisk tetthet. På 2000 m kommer det tydelig frem at både G- og NIR-kanalen sliter. Den eneste overflaten som returnerer alle pulser er hustak, som kan forklares av høy reflektans i materialet, samt flat og jevn geometri. På gress-overflater har G-kanalen falt helt ut, og totalt returneres 75% av utsendte pulser. For asfalt faller både NIR- og G-kanalen helt ut, mens MIR-kanalen returnerer nesten alle pulser. Totalt returneres 32% av pulsene. På jord ser vi tendenser av det samme, men her har NIR-kanalen 17%. Totalt blir 37% av alle pulser returnert. Skog har totalt 1% returnerte pulser. Der MIR-kanalen står for alle returere. NIR- og G-kanalen ser dermed ut til å prestere dårlig på 2000 m høyde. Dette vil kunne gi lave og misledende intensitetsverdier. Noe som er uheldig, da datasettet brukt til klassifisering senere i oppgaven, er fløyet på 1900 meter. Om pulsreturene faller av rett før 2000 meter, eller rett etter 1600 m er vanskelig å si. En lineær interpolasjon mellom de to høydene gir en tilnærmet oversikt over returere ved 1900 meter.

meter over terreng:		1900
Gress	1550 nm	113 %
	1064 nm	114 %
	532 nm	27 %
	Totalt	85 %
Asfalt	1550 nm	101 %
	1064 nm	9 %
	532 nm	31 %
	Totalt	47 %
Hustak	1550 nm	123 %
	1064 nm	112 %
	532 nm	112 %
	Totalt	116 %
Jord	1550 nm	97 %
	1064 nm	41 %
	532 nm	30 %
	Totalt	56 %
Skog	1550 nm	6 %
	1064 nm	1 %
	532 nm	0 %
	Totalt	2 %

Tabell 6.4: Interpolerte verdier for antall returnerte pulser for flygning ved 1900 m. Basert på tall fra 1600 m og 2000m.

Ved å interpolere blir ikke tallene presise, men danner et bilde på hvor godt kanalene kan prestere ved den aktuelle flyhøyden på 1900 m over terrenget. På alle overflater er det MIR-kanalen som gjør det best. Skog har også ved 1900 m veldig få returpulser. De andre overflatene har middelmådige tall, bortsett fra hustak. På jord gir det mening at G-kanalen har færrest returere, etterfulgt av NIR og MIR, slik spektralkurven er formet. Det samme gjelder gress, der

G-kanalen får forventet få returer, og NIR-kanalen returnerer alle pulser. Asfalt gir uforutsigbare resultater, der NIR-kanalen burde ha prestert bedre. Skog tolkes til at de splittede returene gjør første-returene for svake til å registreres av LiDAR-systemet. Alt i alt ser MIR-kanalen ut til å prestere best på alle overflatene, mens de andre kanalene ikke yter like godt ved aktuell høyde på 1900 m.

7 Klassifisering av multispektrale laserdata fra Optech Titan

I dette kapittelet blir laserdata fra Optech Titan konvertert, bearbeidet og klassifisert. Dette for å finne eventuelle tilleggsverdier i en multispektral laserskanner. Kapittelet består av hovedsakelig tre deler. Fremgangsmåte (7.1), resultater og analyse (7.2), samt en helhetlig vurdering (7.3).

7.1 Fremgangsmåte

For en oversikt over de ulike stegene i fremgangsmåten, se metode for klassifisering, kapittel 5.2.2. De ulike delene av metoden beskrives her i detalj.

Med informasjon om Optech Titans kapasitet ved 1900 m høyde, blir dataene testet videre i en klassifisering. Her skal egenskaper generert ut fra laserdataene vurderes for evne til å brukes i multispektral klassifisering.

7.1.1 Datasett Alvdal

For å kunne finne tilleggsverdien i Optech Titans multispektrale egenskaper til klassifiseringsformål, har det blitt foretatt flere klassifiseringer i et datasett produsert av Terratec AS. Datasettet består av laserdata fra Optech Titans tre laserkanaler. Laserdataene er samlet inn over Alvdal kommune. Flygningen er gjort den 07.06.2016. Det er flydd 140 flystriper for å dekke kommunen, ved høyde 1900 m over terrenget. Flyets hastighet var 250 km/t på alle stripene. Se utfyllende oversikt over flygningen i kapittel 5.1.2.

I utgangspunktet skulle et datasett over Hamar brukes i klassifiseringen, men da det tilgjengelige datasettet over Hamar ikke inneholdt informasjon om G-kanalen, ble et datasett over Alvdal valgt som nest beste tilgjengelige alternativ. Alvdal har et mindre utvalg av arealtyper til spektralklassifisering, men har nok til å danne et sett av forskjellige klasser. Basert på alt fra mer sub-urbane strøk, til jorder og industri, til skog og mark. Dette danner et godt grunnlag for klassifisering av forskjellige arealoverflater.


Ved å inspisere datasettet i LAStools, ser vi den samme irregulariteten i punktfordeling og intensitet, som diskutert i kapittel 6.1. Dette kan bli en utfordring for selve klassifiseringen, men metoden er utviklet til å ta høyde for dette. Overflater kan mangle punkter som følge av høy punktavstand på flere steder. De ukalibrerte intensitetsverdiene kan skape støy innad i overflater, og føre til at identiske materialer kan oppfattes forskjellig. Likevel blir ikke absoluttverdiene til intensiteten like viktige ved en multispektral klassifisering, da det er forholdet mellom hver kanal som mest sannsynlig vil avgjøre kassetilhørighet. Intensitet fra

kun én kanal har også vist seg i tidligere forskning å gi middelmådige resultater, selv etter kalibrering (Brennan & Webster 2006). I kapittel 6.3 kom det frem at noen overflater reflekteres dårlig av enkelte kanaler. Dette kan kanskje utnyttes i klassifiseringen, da svake/sterke returner på enkelte kanaler blir enestående for enkelte klasser.

Datasettet behandles først i LAStools. På forhånd har Terratec AS slått alle flystriper sammen, delt prosjektet opp i blokker, for mer effektiv lagring, samt gjort en autoklassifisering. Deretter gjør Blom AS en høydenormalisering, som utnytter bakkeklassen, ved å trekke fra høydekoordinaten i hvert bakke-laserpunkt. Dette gir en punktsky der terrenget er flatt, og sentrert rundt 0 m i høyde. Dette gjøres for å lettere skille objekter på overflaten fra hverandre. En enkel høydeverdi kan kanskje være avgjørende for å skille asfalt fra hustak.

7.1.2 Rasterkonvertering

Videre brukes blas2dem til å generere flere raster-representasjoner av attributtverdier fra punktskyen i geoTIFF-format. En rasterrepresentasjon av midlet intensitetsverdi for alle kanalene samlet, med pikselstørrelse GSD på 1 m skal brukes til å gjenkjenne forskjellige overflater i en segmentering. En rasterrepresentasjon av høyde og punkttetthet, begge med pikselstørrelse GSD på 1 m, skal hjelpe til å skille objekter fra hverandre i segmenteringen. Mørke piksler tilsvarer lave verdier. Lyse piksler tilsvarer høye. Helt hvite piksler tilsvarer manglende informasjon.




Figur 7.1: Utsnitt fra rasterrepresentasjoner av punktskyen. Fra venstre: intensitet, høyde, punkttetthet.

7.1.3 Segmentering


Rasterdataene importeres i QGIS, som grunnlag for segmentering. I denne oppgaven ble ikke selve segmenteringen utført, da det ikke lot seg gjøre med programvaren til rådighet. En gratisversjon av bildebehandlingsprogrammet eCognition er blitt brukt til å demonstrere en tenkt flerlags segmentering basert på rasterdataene produsert i blas2dem. Å eksportere disse segmentene som shape-filer, er en tenkt løsning på den produktrettede metoden, men er ikke

blitt gjort i oppgaven. Bildet under viser en slik segmentering. Der grensene for hver overflate kan brukes istedenfor manuelt opprettede polygoner for klassifiseringen. De synlige rasterlagene ser ut som et flybilde, men er falske fargebilder satt sammen av laserkanalene, fremstilt i rød, grønn og blå fargekanal.



Figur 7.2: Flerlags segmentering basert på intensitetsverdier, høyde og punktetthet i punktskyen, fremstilt som raster.

De automatisk opprettede polygonene skiller forskjellige overflatetyper fra hverandre. Disse kan eksporteres til shape-formatet, men dette er ikke gjort i oppgaven. Istedenfor brukes rasterdataene, sammen med WMS- og FKB-data til å manuelt opprette polygoner i QGIS. Disse polygonene er tenkte segmenter i en eventuell flerlags segmentering. På bilder under er disse polygonene tegnet over intensitetsrasterene.

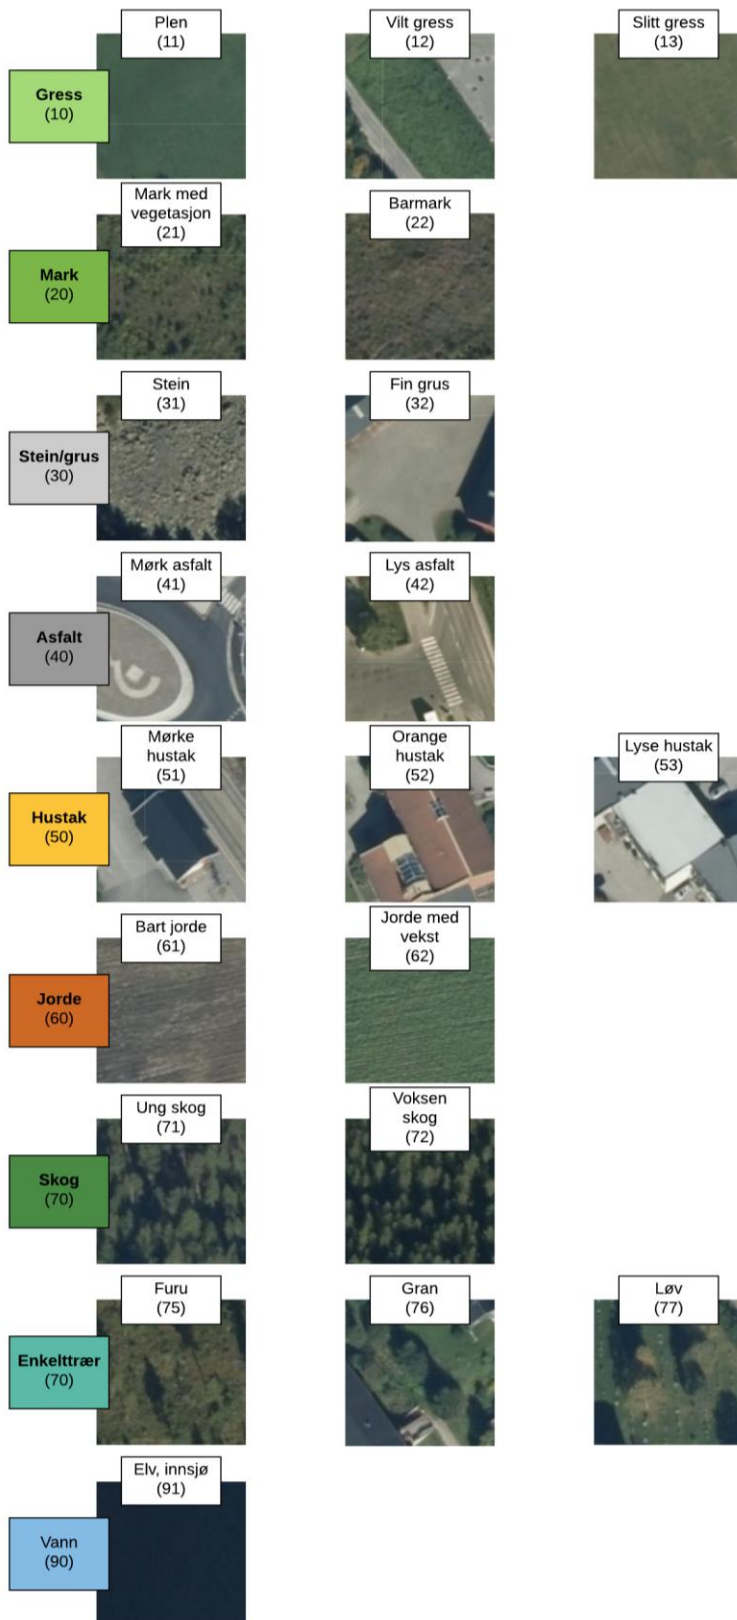


Figur 7.3: Manuelle shape-polygoner basert på WMS og FKB.

7.1.4 Klasseinndeling

For å kunne klassifisere disse segmentene til forskjellige typer overflater, er en klassifiseringsmetode avhengig av et sett med treningsdata. Dette tilsvarer en rekke fasit-overflater, med oppgitt klassetilhørighet, som klassifiseringsmetoden bruker til å lære seg de

ulike karaktertrekkene i egenskapene til hver klasse. I denne oppgaven blir alle manuelt konstruerte polygoner tilegnet en fasit-klasse, basert på flybilder fra WMS-tjenesten til Norgebilder.no. For enkeltrær er også Google StreetView® tatt i bruk. Dette er en styrt klassifisering. I et konseptuelt produkt kan klassifiseringsregler fra den styrte klassifiseringen brukes videre til ikke-styrt klassifiseringer av andre datasett. De forskjellige klassene som tilegnes hver polygon, er plukket ut for å teste Optech Titans klassifiseringsevne. Hva som er mulig å skille med multispektral laser, og hva som ikke lar seg skille er interessant å kartlegge. Det regnes med at ikke alle klasser lar seg skille. Noen av dem er konstruert for å teste grensene til skanneren. Klassene er også konstruert ut ifra hvilke typer overflater som er tilgjengelig i Alvdal. Klassene deles inn hierarkisk som primærklasser med underliggende sekundærklasser. Det forventes at primærklassene er mulig å skille fra hverandre i en klassifisering, mens sekundærklassene er ment som testing av klassifiseringskapasitet. Hver primærklasse er basert på ulike typer arealoverflater, mens sekundærklassene er varianter av disse. Det er altså ikke arealbruk som betraktes her, selv om sekundærklassene kan virke spesifikke nok til å defineres som det. En oversikt over klassene, med utsnitt fra Norgebilder.no, vises her:



Figur 7.4: Oversikt over alle klasser. Primærklasser (loddrett) og sekundærklasser (vannrett), med eksempelbilder hentet fra Alvdal. Norgebilder.no

Alle utsnittene over har samme målestokk. Primærklassene ligger under hverandre, mens sekundærklassene ligger ved siden av hverandre. Til sammen dekker disse klassene de fleste

overflatetypene i Alvdal. Klassene er ikke definert basert på en standard, men fritt valgt ut etter hva som lot seg definere. Disse er definert etter farge og mønster. Underklasser som hustak-farge, antas at lett kan skilles, mens forskjellige gress-overflater kan bli en større utfordring for Optech Titan. Tradisjonell punktsky-klassifisering innebærer ofte klassene «bakke», «lav vegetasjon», «medium vegetasjon», «høy vegetasjon», «bygninger» og «vann». Disse klassene defineres på grunnlag av høydeverdier. Og er relativt lett å skille fra hverandre. Tidligere studier på Optech Titan har sett på muligheter for å klassifisere overflater som tørt gress, sand, våtmark og lys/mørk asfalt. Sekundærklassene som defineres i denne oppgaven er langt flere enn hva som tidligere er gjort. En utfordring med dette er at det ved noen av disse klassene er vanskelig å tilegne konsekvent klassetilhørighet i alle polygoner, og fasitverdiene blir noe subjektive. Om ikke overflatene gis riktig fasitklasse, kan de bli ødeleggende for datasettet. I et konseptuelt produkt, ville en mer konsekvent klasseinndeling blitt brukt. Der fokuset ville ligge på overflatens materielle oppbygning. Dette drøftes videre i kapittel 7.3. Klassene defineres også ut i fra flyfoto. Hvilke tidspunkt disse fotografiene er tatt på er viktig, slik at f.eks. jorder i både punktsky og flybilder består av enten jord eller strå. Bildene er tatt tre måneder etter skanningen. Fra juni til september. I denne tidsperioden er det hovedsakelig jordene som har størst potensial for å forandre utseende. Dette kan ha påvirket resultatet.

7.1.5 Kombinering av laser- og vektordata

Det opprettes 30-40 polygoner pr. sekundærklasse. Etter at hver polygon har blitt tildelt primær- og sekundærklasse, importeres de inn i lascanopy sammen med den normaliserte punktskyen. I lascanopy isoleres de aktuelle laserpunktene innenfor hver polygon. En rekke statistikk kan nå produseres ut ifra de punktene som befinner seg innenfor polygonen. For hver kanal trekkes en rekke egenskaper ut fra hver polygon. Dette gir et stort sett med variabler som vist i tabellen under:

MIR-kanal	NIR-kanal	G-kanal	Beskrivelse
index_ch1	index_ch2	index_ch3	ID
min_x_ch1	min_x_ch2	min_x_ch3	minimum x-koordinatverdi
min_y_ch1	min_y_ch2	min_y_ch3	minimum y-koordinatverdi
max_x_ch1	max_x_ch2	max_x_ch3	maksimum x-koordinatverdi
max_y_ch1	max_y_ch2	max_y_ch3	maksimum y-koordinatverdi
all_ch1	all_ch2	all_ch3	Antall punkter i polygonen
min_ch1	min_ch2	min_ch3	laveste punkt i polygonen
max_ch1	max_ch2	max_ch3	høyeste punkt i polygonen
avg_ch1	avg_ch2	avg_ch3	Gjennomsnittlig høyde
qav_ch1	qav_ch2	qav_ch3	Gjennomsnittlig kvadrat høyde
std_ch1	std_ch2	std_ch3	Standardavvik i høydeverdier
ske_ch1	ske_ch2	ske_ch3	Skjevhet i histogram for høydefordeling
kur_ch1	kur_ch2	kur_ch3	kurtose i histogram for høydefordeling
p01_ch1	p01_ch2	p01_ch3	1% høydeprecentil for høyder i polygonen
p05_ch1	p05_ch2	p05_ch3	5% høydeprecentil

p10_ch1	p10_ch2	p10_ch3	10% høydeprecentil
p25_ch1	p25_ch2	p25_ch3	25% høydeprecentil
p50_ch1	p50_ch2	p50_ch3	50% høydeprecentil
p75_ch1	p75_ch2	p75_ch3	75% høydeprecentil
p90_ch1	p90_ch2	p90_ch3	90% høydeprecentil
p95_ch1	p95_ch2	p95_ch3	95% høydeprecentil
p99_ch1	p99_ch2	p99_ch3	99% høydeprecentil
b10_ch1	b10_ch2	b10_ch3	10% høydebincentil
b20_ch1	b20_ch2	b20_ch3	20% høydebincentil
b30_ch1	b30_ch2	b30_ch3	30% høydebincentil
b40_ch1	b40_ch2	b40_ch3	40% høydebincentil
b50_ch1	b50_ch2	b50_ch3	50% høydebincentil
b60_ch1	b60_ch2	b60_ch3	60% høydebincentil
b70_ch1	b70_ch2	b70_ch3	70% høydebincentil
b80_ch1	b80_ch2	b80_ch3	80% høydebincentil
b90_ch1	b90_ch2	b90_ch3	90% høydebincentil
int_min_ch1	int_min_ch2	int_min_ch3	laveste intensitetsverdi i polygonen
int_max_ch1	int_max_ch2	int_max_ch3	høyeste intensitetsverdi i polygonen
int_avg_ch1	int_avg_ch2	int_avg_ch3	Gjennomsnittlig intensitetsverdi
int_qav_ch1	int_qav_ch2	int_qav_ch3	Gjennomsnittlig kvadrat intensitet
int_std_ch1	int_std_ch2	int_std_ch3	Standardavvik i intensitetsverdier
int_ske_ch1	int_ske_ch2	int_ske_ch3	Skjevhet i histogram for intensitetsfordeling
int_kur_ch1	int_kur_ch2	int_kur_ch3	kurtose i histogram for intensitetsfordeling
int_p01_ch1	int_p01_ch2	int_p01_ch3	1% intensitetsprecentil
int_p05_ch1	int_p05_ch2	int_p05_ch3	5% intensitetsprecentil
int_p10_ch1	int_p10_ch2	int_p10_ch3	10% intensitetsprecentil
int_p25_ch1	int_p25_ch2	int_p25_ch3	25% intensitetsprecentil
int_p50_ch1	int_p50_ch2	int_p50_ch3	50% intensitetsprecentil
int_p75_ch1	int_p75_ch2	int_p75_ch3	75% intensitetsprecentil
int_p90_ch1	int_p90_ch2	int_p90_ch3	90% intensitetsprecentil
int_p95_ch1	int_p95_ch2	int_p95_ch3	95% intensitetsprecentil
int_p99_ch1	int_p99_ch2	int_p99_ch3	99% intensitetsprecentil

Tabell 7.1: Oversikt over alle statistiske egenskaper kalkulert av lascanopy.

7.1.6 Tabellsammenslåing og optimalisering

Ikke alle egenskapene blir tatt i bruk, ettersom dette kan føre til en dårligere klassifisering, som diskutert i kapittel 4.5. Lascanopy produserer én tabell pr. kanal, der alle egenskaper for hver polygon lagres. Et skript for å kjøre hele prosessen i lascanopy, samt navngi hver egenskap med kanaltilhørighet, utvikles. Dette skriptet ligger som vedlegg 2 i kapittel 10.

I Excel blir tabellene for hver kanal slått sammen til én. Klasseinformasjonen fra polygonene ligger ikke i tabellen fra lascanopy, og må kombineres manuelt. Redundante kolonner fjernes. Spektralindekser kalkuleres for utvalgt intensitets-statistikk. Tanken er at forholdstall mellom kanalene kan hjelpe klassifiseringen. Intensitetsgjennomsnittet for MIR, NIR og G blir brukt til å forme NDFI(G-NIR), NDFI(G-MIR) og NDFI(NIR-MIR) som følger:

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

Formel 7.1 Spektralindekser.

For å ta hensyn til at noen overflater har færre returverdier enn andre på visse laserkanaler, som studert i kapittel 6.3, utvikles et mål på sterkeste og svakeste laserkanal pr. polygon. Tanken er at overflaters evne til å returnere laserpulser sier noe om karakteristikken i overflaten. Dette kan kanskje brukes som en egenskap i klassifiseringen. Sterkeste og svakeste kanal baseres på antall returverdier i polygonen (*all_ch*) pr. kanal, og egenskapene defineres i Excel som følger:

SterkesteKanal

$$= INDEX(all_{ch1}:all_{ch3}; 0; MATCH(MAX(all_{ch1}(ID), all_{ch2}(ID), all_{ch3}(ID))))$$

SvakesteKanal

$$= INDEX(all_{ch1}:all_{ch3}; 0; MATCH(MIN(all_{ch1}(ID), all_{ch2}(ID), all_{ch3}(ID))))$$

Disse operasjonene kan effektiviseres ved integrering av SQL i et konseptuelt produkt. Tabellen består, etter manuelle inngrep, av en rekke egenskaper. Denne blir importert i Orange for videre analyse.

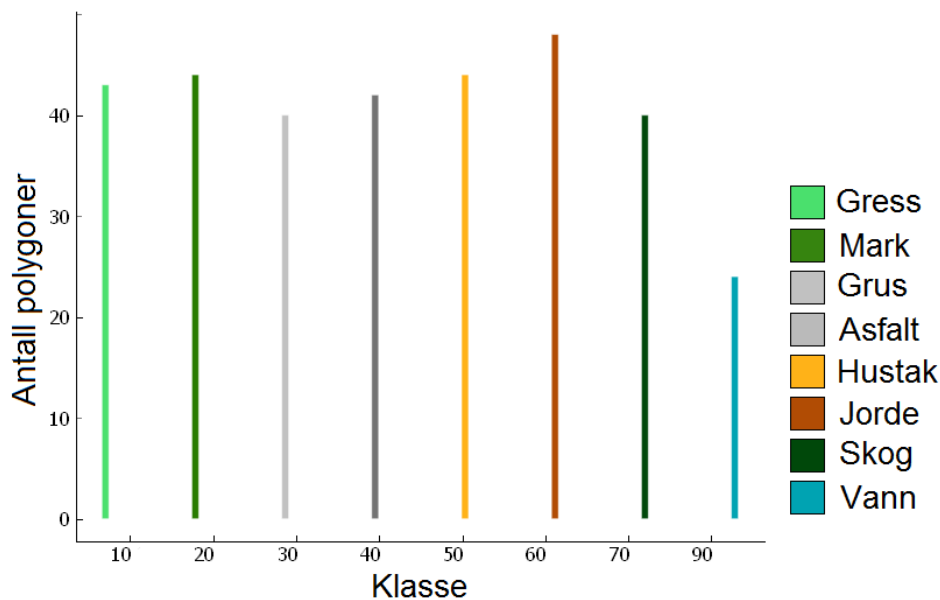
Type	Data	Attributter	kanal
Klasse	Mål	klasse1, klasse2	
Identifikasjon	Meta	ID	
Høydestatistikk	Egenskaper	all, min, max, avg, qav, std, ske, kur	MIR, NIR, G
Høydepercentiler	Egenskaper	p01, p05, p10, p25, p50, p75, p90, p95, p99	MIR, NIR, G
Høydebincentiler	Egenskaper	b10, b20, b30, b40, b50, b60, b70, b80, b90	MIR, NIR, G
Intensitetsstatistikk	Egenskaper	all, min, max, avg, qav, std, ske, kur	MIR, NIR, G
Intensitetspercentiler	Egenskaper	p01, p05, p10, p25, p50, p75, p90, p95, p99	MIR, NIR, G
NDFI(G-NIR)	Egenskaper	avg, p05, p50, p95	
NDFI(G-MIR)	Egenskaper	avg, p05, p50, p95	
NDFI(NIR-MIR)	Egenskaper	avg, p05, p50, p95	
SterkesteKanal	Egenskaper		
SvakesteKanal	Egenskaper		

Tabell 7.2: Oversikt over alle egenskaper i komplett datasett.

7.1.7 Klassifisering av data

I Orange blir de forskjellige kolonnene i tabellen tilegnet en hensikt. Hver polygon har sin unike identitet, som blir metadata for datasettet. Hver polygon har også to kolonner som definerer klassetilhørighet. Primærklasse og sekundærklasse. Disse kolonnene blir satt til mål for klassifiseringen, og vil også da brukes som treningsdata i kryssvalideringen. Resten av kolonnene er egenskapene til polygonene. Det skal foretas tre forskjellige klassifiseringer pr. datautvalg. Én basert på alle primærklasser samlet, én basert på alle sekundærklasser samlet, og én hvor enkelttrær klassifiseres alene. Det blir også sett på de spektrale forholdene mellom sekundærklasser innad i primærklassene. Disse vurderes, og brukes for å tolke resultater fra

klassifiseringen. Polygoner selekteres for hvert datautvalg. For primærklassifiseringen blir 780 polygoner redusert til 302, der klassene 11, 22, 32, 42, 51, 61, 71 og 91 velges ut til å representere sin primærklasse, med ca. 40 polygoner i hver klasse. Sekundærklassene slås altså ikke sammen til én hel primærklasse, da dette skapte for mye variasjon innad i klassen. For sekundærklassifiseringen blir 780 polygoner redusert til 467, der alle sekundærklassene velges ut. Inkludert tresortene, for å kunne gjøre enkelttre-klassifisering blant andre klasser. Her ca. 25 polygoner i hver klasse. Grunnen til at antall polygoner reduseres, er for å holde et ca. likt antall polygoner i hver klasse. I en del av klassene var det enten ikke mulig å oppdrive 40 polygoner, eller så har flere polygoner blitt fjernet pga. støy i eller manglende data. Mesteparten av det geometriske støyet lå i de «vann»-klassen. Spektral støy lå for det meste i lyse overflater. I enkelttreklassifiseringen er alle polygoner for tresortene furu, gran og løv beholdt.



Figur 7.5: Distribusjonsplott for antall utvalgte polygoner til primærklassifisering

Egenskaper som skal tas i bruk blir selektert basert på en rangeringsalgoritme, der hver egenskap vurderes basert på korrelasjonen til klassene, og rangeres etter den antatte mengden informasjon hver egenskap kan bidra med. Dette innebærer også at egenskapene er knyttet til intensitet. En høyde-egenskap pr. kanal blir også tatt med i klassifiseringen, for å kunne skille like overflater på forskjellige høyder. Denne blir konsekvent tatt med i alle klassifiseringer, slik at de multispektrale tilleggsverdiene kan vurderes isolert. I denne oppgaven brukes høyde som en tilleggs-egenskap, men vil ikke være den avgjørende faktor ved klassifiseringen. Høydeegenskapene alene gir ikke mer enn 0,5 i klassifiseringsnøyaktighet. Alle resultater over dette er forårsaket av intensitetsverdier. Tidligere forskning har vist at kun intensitetsverdier


alene har gitt en klassifiseringsnøyaktighet på 69% (Sitar et al. 2015). For klassifisering av sekundærklasser og enkelttrær vil også bincentiler inkluderes til en viss grad, da dette er vanlig å bruke ved enkelttreklassifisering. Bincentiler vil også si noe om hvor i terrenget punktene fra de forskjellige kanalene legger seg. Om de fleste punktene legger seg på bakken eller over vegetasjonen. Dette er også en egenskap ved å operere med 3 kanaler, men er ikke fokuset mye på i denne oppgaven. Det er viktig å påpeke at det er intensitetsverdiene som skal vurderes. 45x3 egenskaper (45 pr. kanal) blir redusert til 7x3 egenskaper for primær- og sekundærklassifiseringen, og 5x3 for enkelttreklassifiseringen. Dette basert på rangeringsalgoritmen, og for å unngå «overfitting» (les kapittel 4.5). Hvilke egenskaper som brukes for hver klassifisering er listet opp i tabellen under.

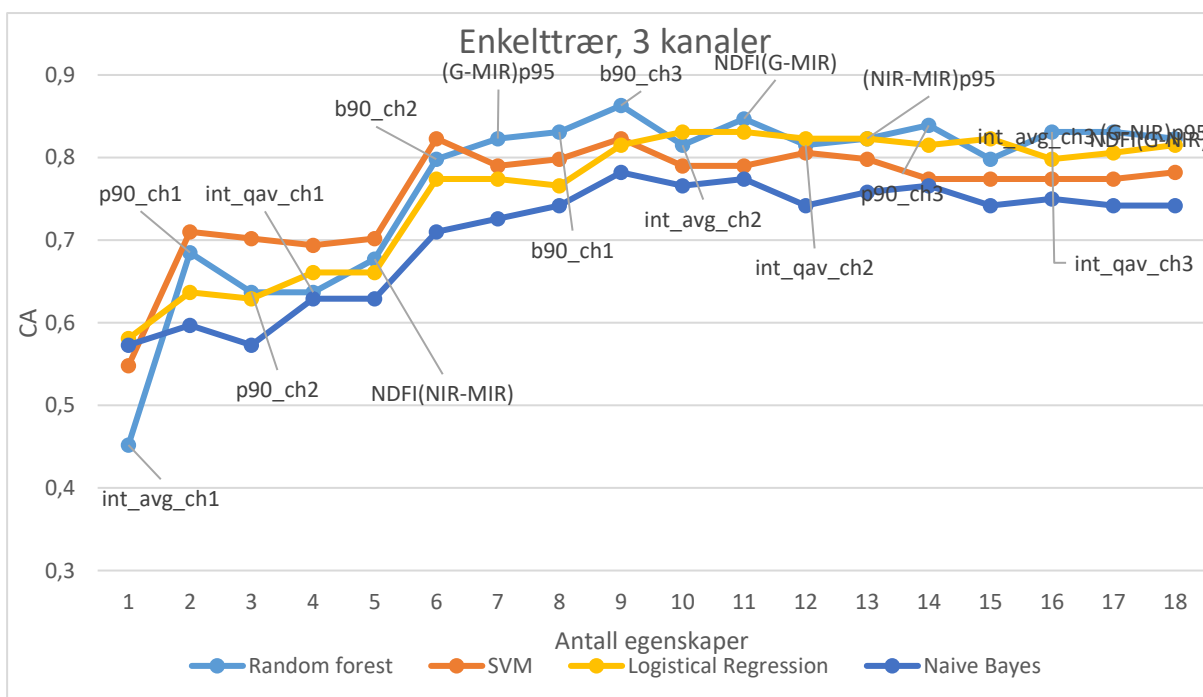

Primærklasser			Sekundærklasser		
3 kanaler	2 kanaler	1 kanal	3 kanaler	2 kanaler	1 kanal
p90_ch1	p90_ch1	p90_ch1	p90_ch1	p90_ch1	p90_ch1
p90_ch2	p90_ch2	p90_ch2	p90_ch2	p90_ch2	p90_ch2
p90_ch3	p90_ch3	p90_ch3	p90_ch3	p90_ch3	p90_ch3
int_p05_ch1	int_p05_ch1	int_p05_ch1	b90_ch1	b90_ch1	b90_ch1
int_p10_ch1	int_p10_ch1	int_p10_ch1	b90_ch2	b90_ch2	
int_p25_ch1	int_p25_ch1	int_p25_ch1	b90_ch3		
int_p50_ch1	int_p50_ch1	int_p50_ch1	int_p01_ch1	int_p01_ch1	int_p01_ch1
int_p75_ch1	int_p75_ch1	int_p75_ch1	int_p90_ch1	int_p90_ch1	int_p90_ch1
int_avg_ch1	int_avg_ch1	int_avg_ch1	int_avg_ch1	int_avg_ch1	int_avg_ch1
int_p05_ch2	int_p05_ch2		int_kur_hc1	int_kur_hc1	int_kur_hc1
int_p10_ch2	int_p10_ch2		int_p01_ch2	int_p01_ch2	
int_p25_ch2	int_p25_ch2		int_p90_ch2	int_p90_ch2	
int_p50_ch2	int_p50_ch2		int_avg_ch2	int_avg_ch2	
int_p75_ch2	int_p75_ch2		int_kur_hc2	int_kur_hc2	
int_avg_ch2	int_avg_ch2		int_p01_ch3	(NIR-MIR)p05	
int_p05_ch3			int_p90_ch3		
int_p10_ch3			int_avg_ch3		
int_p25_ch3			int_kur_hc3		
int_p50_ch3			(G-NIR)p05		
int_p75_ch3			(G-MIR)p05		
int_avg_ch3			(NIR-MIR)p05		

Enkelttrær		
3 kanaler	2 kanaler	1 kanal
p90_ch1	p90_ch1	p90_ch1
p90_ch2	p90_ch2	p90_ch2
p90_ch3	p90_ch3	p90_ch3
b90_ch1	b90_ch1	b90_ch1
b90_ch2	b90_ch2	
b90_ch3		
int_avg_ch1	int_avg_ch1	int_avg_ch1
int_qav_ch1	int_qav_ch1	int_qav_ch1
int_avg_ch2	int_avg_ch2	
int_qav_ch2	int_qav_ch2	
int_avg_ch3	NDFI(NIR-MIR)	
int_qav_ch3	(NIR-MIR)p95	
NDFI(G-NIR)		
NDFI(G-MIR)		
NDFI(NIR-MIR)		
(G-NIR)p95		
(G-MIR)p95		
(NIR-MIR)p95		

Tabell 7.3: Oversikt over egenskaper som brukes i de ulike datautvalgene og egenskapsutvalgene.

Rangeringsalgoritmen har valgt ut de mest informasjonsrike egenskapene. Informasjon om sterkeste og svakeste kanal så ikke ut til hjelpe til på informasjonsmengden, og brukes dermed ikke videre. Rangeringen av informasjonsmengde pr. egenskap vurderes i et plott mellom klassifiseringsnøyaktighet og antall egenskaper. Rangert etter rangeringsalgoritmens resultat. For å holde dimensjonsantallet lavest mulig, legges én og én egenskap til i klassifiseringen, til økningen i nøyaktighet går mot null. Ved å sammenligne kurven til hver klassifiseringsmetode kommer det frem hvilken metode som egner seg best.

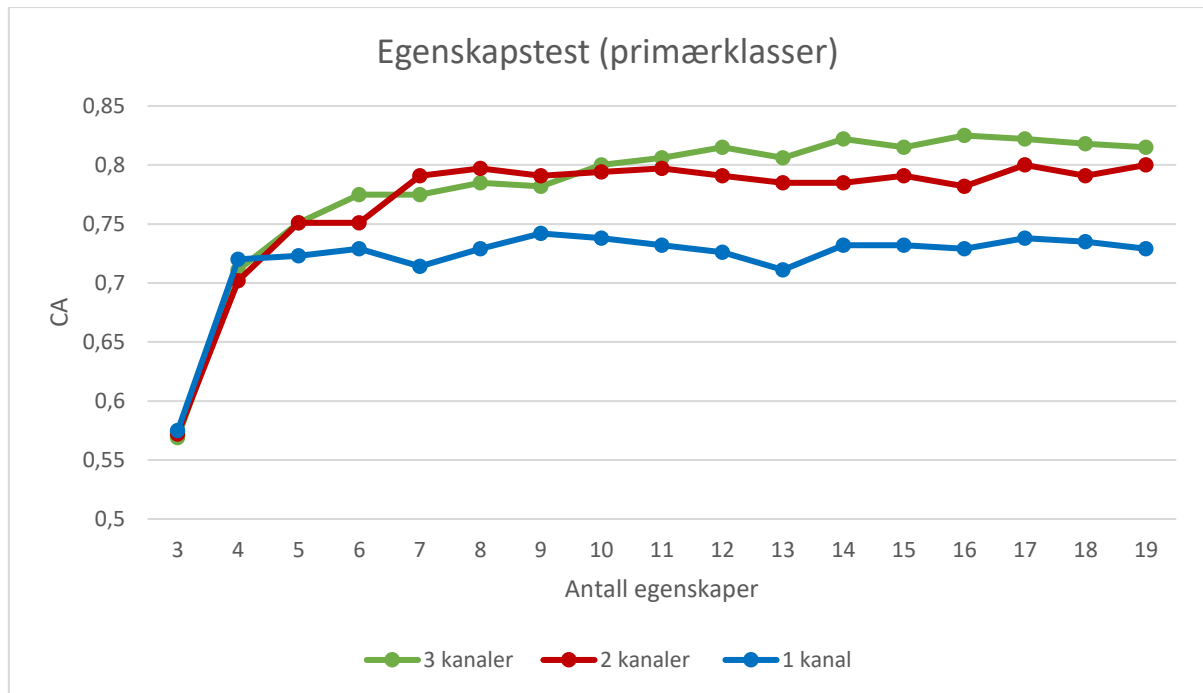




Figur 7.6: Grafer for klassifisering.

Allerede etter 10 egenskaper er det meste av klassifiseringsnøyaktigheten oppnådd. Etter dette har grafene en tendens til å flate ut. I de forskjellige egenskapsutvalgene for hvert spektralnivå, blir ikke antallet egenskaper det samme, ettersom et tre-kanals system har tre egenskaper knyttet til hvert statistiske mål, sånn metoden er satt opp (Se Tabell 7.3). For at ikke egenskapsmengde skal være den avgjørende faktor for klassifiseringsnøyaktigheten er en egenskapstest gjort ut ifra rangeringsalgoritmens 19 mest informasjonsgivende egenskaper. De tre første attributtene

er høydeinformasjon, og gir hver klassifisering et utgangspunkt med klassifiseringsnøyaktighet 0,57. Deretter legges én og én egenskap til, basert på rangeringsalgoritmens utvalg. Grønn graf har egenskaper fra alle tre kanaler. Blå graf har kun egenskaper fra MIR-kanal.

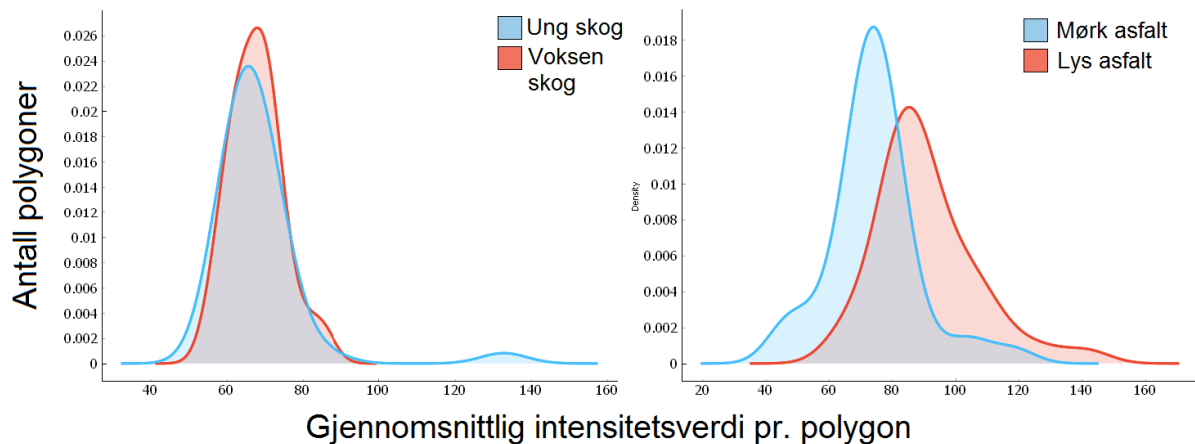


Figur 7.7: Klassifiseringsnøyaktighet for forskjellige egenskapsutvalg.

3 kanaler får tidlig en høyere klassifiseringsnøyaktighet enn 1 kanal. Dette selv om hver klassifisering har like mange egenskaper. Med monospektrale egenskaper flater grafen ut allerede ved 4 egenskaper. De dualspektrale resultatene er nesten like gode som de multispektrale, men etter 10 egenskaper viser multispektrale egenskaper bedre resultater. De ulike grafene flater ut på forskjellige nøyaktighet, og testen viser at det er egenskapenes kvalitet, og ikke antall egenskaper, som avgjør nøyaktigheten. Dermed kan metodens egenskapsutvalg med ulik mengde egenskaper godkjennes.

Med de egenskapsutvalgene som nå er gjort kan en rekke plott og visualiseringer av dataene produseres. Dette for å fremstille spektrale karaktertrekk i de ulike arealoverflatene. For tolkning av klassifiseringsresultater. Det er mulig å antyde hvilke klasser som har potensiale for å lett kunne feilklassifiseres, og hvilke som har gode forutsetninger for å lykkes. Her et eksempel på dette. Med klassene «ung skog» (72) mot «voksen skog» (71), som ikke ser ut til

å kunne skilles, og klassene «mørk asfalt» (41) mot «lys asfalt» (42), som skilles til en viss grad.



Figur 7.8: Antall verdier for gjennomsnittlig intensitetsverdier for MIR-kanalen, mot antall tettheten av polygoner med denne verdien. Til venstre: ung skog mot skog. Til høyre: mørk asfalt mot lys asfalt.

Videre blir eventuelle tomme verdier i datasettene fylt med mest sannsynlige verdi, før kryssvalidering og klassifisering utføres. Kryssvalideringen deler datasettet opp i 10 deler. En del holdes ut og klassifiseres om gangen, basert på klassifiseringsmønstre fra de andre delene. Det tas i bruk 5 forskjellige klassifiseringsmetoder. Resultatet fra metoden med best klassifiseringsnøyaktighet og kappa-koeffisient blir brukt videre. For de forskjellige utvalgene er parameterinnstillingene i klassifiseringsmetodene de samme. Parameterne som brukes for hver metode er listet opp under. Orange styrer resten av klassifiseringsprosessen.

Klassifiseringsmetode	Parametere
kNN-nærmeste nabo klassifisering	Euklidsk, uniform distanse til de 3 nærmeste naboene.
Random Forest klassifisering	100 trær, ikke dypere enn 5 nivå
Support Vector Machine	Kost-basert feillikning = 1,0. Radial basis funksjon (RBF)-kernel. Iterasjonsgrense = 100
Logistisk Regresjon	L2-regularisering med styrke = 1,0
Naive Bayes	Ingen parameterinnstillinger i Orange

Tabell 7.4: Oversikt over parameterinnstillinger for de ulike klassifiseringsmetodene som brukes i oppgaven.

Klassifiseringene gjøres henholdsvis med multispektralt egenskapsutvalg (MIR, NIR, G), dualspektralt egenskapsutvalg (MIR, NIR) og monospektralt egenskapsutvalg (MIR). Resultatet fra hver av disse klassifiseringene sammenlignes mot hverandre, for å vurdere tilleggsverdien i det multispektrale egenskapsutvalget.

Resultatene av klassifiseringene er predikeringer på hvilken klasse hver polygon tilhører. Dette lagres som egenskaper i polygondataene. Slik at hver polygon inneholder informasjon om opprinnelig kassetilhørighet, og predikert kassetilhørighet. Statistikk i form av

forvirringsmatriser, samt visualiseringer av feilklassifisering brukes til analyse av resultatet. Se kapittel 7.2.1.

7.2 Resultater og analyse

I dette kapittelet er metoden (kapittel 5.2) utført, med dokumentasjon av prosessen i fremgangsmåten (kapittel 7.1). Alle relevante resultater med rot i fremgangsmåten, presenteres her. Problemstillingen skal besvares på grunnlag av disse resultatene. De viktigste resultatene, hovedfunnene, vil bli presentert først (kapittel 7.2.1). Disse har størst betydning for problemstillingen. Deretter vil andre funn, som bygger opp under hovedfunnet presenteres i kapittel 7.2.2, 7.2.3, 7.2.4 og 7.2.5.

7.2.1 Hovedfunn

Basert på data i form av resultater fra klassifiseringer gjort av Optech Titan, kommer det frem at et 3-kanalssystem, der kortbølge-infrarød (MIR), nærinfrarød (NIR) og grønn (G) laser sammen har en bedre evne til å klassifisere objekter og arealtyper, enn tradisjonelle laserskannere. Det ble utført klassifiseringer av tre forskjellige datautvalg: Primærklasser, sekundærklasser og enkeltrær. Alle utvalgene har bedre klassifiseringsresultater med multispektrale egenskaper, enn med monospektrale egenskaper.

Kappa-koeffisienten er regnet ut for hver forvirringsmatrise, og resultatet viser at multispektrale egenskaper gir sterk grad av riktighet for primærklasser. Moderat for sekundærklasser og enkeltrær. Dette basert på en ofte brukt skala for tolkning av kappa-verdi. Alle kappakoeffisientene er som følger:

Kappa (K)	3 kanaler	2 kanaler	1 kanal
Primærklasser	0,8	0,78	0,69
Sekundærklasser	0,71	0,7	0,59
Enkeltrær	0,74	0,7	0,7

Grad av riktighet	Ingen	Minimal	Svak	Moderat	Sterk	Nesten perfekt
Kappa (K)	0,0	0,20	0,40	0,60	0,80	1,0

Tabell 7.5: Kappa-verdi for de ulike klassifiseringene. (Viera & Garrett 2005)

Av primærklassene ble 269 polygoner riktig klassifisert med multispektrale egenskaper, 263 med dualspektrale, og 236 med monospektrale, av totalt 325 polygoner. Av sekundærklassene ble 339 polygoner riktig klassifisert med multispektrale egenskaper, 334 med dualspektrale og 295 med monospektrale egenskaper av totalt 467 polygoner. Av tresortene ble 103 polygoner riktig klassifisert med multispektrale egenskaper, 99 med dualspektrale og 99 med monospektrale egenskaper av totalt 124 polygoner.

Det skal nevnes at 2 kanaler (MIR, NIR) gir nesten like gode resultater som 3 kanaler (MIR, NIR, G). Forskjellene mellom multispektrale tilleggsv verdier og dualspektrale tilleggsv verdier er ikke så store. Hva som skiller de forskjellige egenskapsutvalgene studeres videre i kapittelet. Klassifiseringsmetoden som har gjort det best på de fleste klassifiseringene er Random Forest metoden. Med enkeltrær overgår denne metoden av Support Vector Machine og Logistisk Regresjon ved 2 kanaler og 1 kanal. Kappa-koeffisienten og hypotesen gir tydelige svar på at det finnes tilleggsv verdi i multispektral laserskanning til klassifisering av objekter og arealtyper, men ikke spesifikt hvor tilleggsv verdiene ligger. Dette studeres videre i kapittel 7.2.2 for primærklasser, 7.2.3 for sekundærklasser og 7.2.4 for enkeltrær.


7.2.2 Primærklasser

Primærklassene er et utvalg av én sekundærklasse pr. primærklasse, som klassifiseres mot hverandre. Dette er de mest vanlige overflatene i Alvdal. Her med indeksering og beskrivelse:

Klasse	Info
Gress (10)	Plen
Mark (20)	Barmark
Grus (30)	Fin grus
Asfalt (40)	Lys asfalt
Hustak (50)	Mørke hustak
Jorde (60)	Bart jorde
Skog (70)	Voksen skog
Vann (90)	Elv, innsjø


Tabell 7.6: Beskrivelse av de aktuelle klassene i primærklassifiseringen

Før klassifiseringsresultatene drøftes klassevis, analyseres plott av intensitetsverdifordelingen pr. klasse. Disse gir et inntrykk av hvordan intensitetsverdier har potensialet til å skille klassene fra hverandre:



Figur 7.9: Histogram for fordeling av gjennomsnittlige intensitetsverdier, primærklasser.

Disse tre plottene viser distribusjonen av polygoner med gjennomsnittlig intensitetsverdi på vannrett akse. Loddrett akse er tetthet av polygoner med lik verdi.



Figur 7.10: Multiplott av polygoner (punkter) på gjennomsnittlig intensitetsverdi for hver kanal.

Multiplottet viser alle polygonenes gjennomsnittlige intensitetsverdier plottet som punkter. Hver akse trekker i punktet med vekt lik punktets verdi. Dette skaper en 3-dimensjonal fremstilling i 2 dimensjoner.

Både MIR- og NIR-kanal ser ut til å sentrere de fleste intensitetsverdier rundt 80. G-kanalen har langt lavere verdier, men i kapittel 6.1.2 oppdages det at denne er noe svakere enn de andre kanalene. Så de lave verdiene betyr ikke utelukkende at overflatene har lav reflektans. Fordelingene må studeres relativt til kanalstyrke, og ikke som absolutte verdier. Flere grupperinger kan skimtes i multiplottet mellom de tre kanalene. Også i intensitetsverdifordelingen kommer det frem at hver klasse har ulike karakteristikk. Dette er en god indikator på at en klassifisering basert på multispektrale egenskaper har funksjonalitet. Klassene «vann» (90), «mark» (20) og «skog» (70) ser også ut til å ha bimodal fordeling i noen av plottene. Dette kan være et tegn på at noen av polygonene har helt andre verdier, og burde tilhørt en annen klasse. Da kan det både være snakk om en uoppgadet sekundærklasse, eller feil fasitverdi i treningsdataene. Dette kan føre til støy i klassifiseringen. «jorde» (60) har en veldig bred fordeling i MIR-kanalen. Dette kan også føre til at klassen ikke klassifiseres riktig.

Ved å studere forvirringsmatrisen (se Figur 4.8), kommer det tydelig frem hvilke primærklasser som ikke lar seg skille like godt som andre. Matrisen under visualiserer antall feilklassifiseringer til venstre, og hvilke feilklassifiseringer til høyre.

Predikert Faktisk	10	20	30	40	50	60	70	90	Σ	Predikert Faktisk	10	20	30	40	50	60	70	90	Σ
10	38	0	0	0	0	4	1	0	43	10	38	0	0	0	0	4	1	0	43
20	2	33	0	0	0	9	0	0	44	20	2	33	0	0	0	9	0	0	44
30	0	0	31	5	0	3	0	1	40	30	0	0	31	5	0	3	0	1	40
40	0	0	4	37	1	0	0	0	42	40	0	0	4	37	1	0	0	0	42
50	0	0	0	1	39	0	1	3	44	50	0	0	0	1	39	0	1	3	44
60	7	8	3	0	1	29	0	0	48	60	7	8	3	0	1	29	0	0	48
70	0	1	0	0	0	0	39	0	40	70	0	1	0	0	0	0	39	0	40
90	1	0	0	0	0	0	0	23	24	90	1	0	0	0	0	0	0	0	23
Σ	48	42	38	43	41	45	41	27	325	Σ	48	42	38	43	41	45	41	27	325

Tabell 7.7: Forvirringsmatrise for klassifisering med 3 kanaler (primærklasser). Fremstilt på to måter. Til venstre antall feil, til høyre hvilke feil.

Kolonnene viser klassifiseringens predikerte klassetilhørighet, mens radene viser faktisk klassetilhørighet for hver klassifisert polygon.

Tall inne i matrisene er antall polygoner. I matrisen til venstre er det antall feilklassifiseringer som utheves. Tall utenfor den lille diagonalen er antallet predikerte polygoner som egentlig tilhører en annen klasse. Tall i den lille diagonalen er antall riktig predikerte polygoner. Jo mørkere rosafargede ruter, jo flere feilklassifiseringer av samme predikerte klassetilhørighet er gjort. De største tallene er uthevet med rammer. I matrisen til høyre er radene farget etter faktisk klassetilhørighet. Om en annen farge ligger over radens opprinnelige farge, tilhører denne fargen feilklassifiserte polygoner med predikert klasse lik den raden den ligger på. Om f.eks. et brunt felt ligger over den lysegrønne raden, er dette en eller flere polygoner fra «jorde» (60)-klassen, feilklassifisert som «gress» (10).

Denne forvirringsmatrisen kommer av Random Forest metoden, som viste seg å gi best resultater for de fleste klassifiseringer gjort i oppgaven. Videre vil klassifiseringsnøyaktighet (CA) innad matrisen brukes til å bedømme resultatene. Formelen for klassifiseringsnøyaktighet er definert som:

$$CA = \frac{t}{n} * 100$$

Formel 7.2: Formel for klassifiseringsnøyaktighet (CA).

Der t er antall korrekte klassifiserte polygoner, og n er totalt antall polygoner. Klassifiseringsnøyaktighet til primærklassene for de forskjellige metodene ble som følger:

	Random Forest Klassifisering	Support Vector Machine	k-Nærmeste Nabo	Logistisk Regresjon	Naive Bayes
CA [%]:	82,2%	79,7%	75,7%	72,6%	70,5%

Tabell 7.8: Klassifiseringsnøyaktighet med 3 kanaler (primærklasser).

Random Forest klassifiseringen kunne med 82% nøyaktighet predikere klassetilhørigheten riktig. Videre analyse tar utgangspunkt i forvirringsmatrisen for multispektral klassifisering av primærklasser (Tabell 7.7). I forvirringsmatrisen er det tre klasser som forveksles mer enn andre. «jorde» (60) forveksles som «mark» (20), mens «gress» (10) og «mark» forveksles med «jorde». De spektrale egenskapene mellom «jorde» og «mark» kan virke like. «jorde» er i hovedsak jord, noe mer regelmessig fordelt enn «mark», der også vegetasjon kan dukke opp innad i polygonen. At disse klassene forveksles er derfor forståelig. De spektrale forskjellene mellom disse klassene er visualisert i Figur 7.9. Der kommer det tydelig frem at «mark» og «jorde» deler like intensitetsverdier. «gress» forveksles også med «jorde». Dette kan tyde på feil i fasitgrunlaget for «jorde»-klassen. Etersom bildegrunlaget for fasitdataene er tatt 3 måneder senere enn laserskanningen, kan visse overflater, spesielt innenfor «jorde»-klassen, ha forandret seg noe. Dette grunlaget er derfor ikke helt pålitelig. Til et konseptuelt produkt ville mer konsekvente klasseinndelinger blitt gjort. Dette drøftes i kapittel 7.3. «gress» forveksles også i ett tilfelle med «skog» (70). «jorde» forveksles i 3 tilfeller med «grus» (30), og i ett tilfelle med «hustak» (50). Dette gir en klassifiseringsnøyaktighet for «gress», «mark» og «jorde» på henholdsvis 88%, 75% og 60% (se Tabell 7.9).

Utenom forvekslingene av «gress», «mark» og «jorde», er det gjort få feilklassifiseringer. Mellom «grus» og «asfalt» (40), er 5 «grus»-overflater predikert til «asfalt», og 4 «asfalt»-overflater predikert til «grus». 3 «grus»-overflater er predikert til «jorde» og 1 til «vann» (90), mens 1 «asfalt»-overflate er predikert til «hustak». Av 40 og 42 overflater tilsvarer dette en klassifiseringsnøyaktighet på henholdsvis 77% og 88% for «grus» og «asfalt». (se Tabell 7.9).

Av de resterende klassene «hustak», «skog» og «vann» blir de aller fleste overflater riktig klassifisert. Med nøyaktighet på henholdsvis 89% og 97%. Ett hustak er klassifisert som «asfalt», ett som «skog» og 3 som «vann». Av «skog»-overflatene er kun én polygon klassifisert feil, til «mark». Én «vann»-overflate er klassifisert til «gress».

Noen av feilklassifiseringene gjort av Random Forest metoden er intuitivt forståelige. Som at «gress» forveksles med «mark» og «asfalt» med «grus» og «hustak». Det er også relativt få polygoner som klassifiseres feil av disse. Ved multispektral klassifisering er primærklassene rangert etter klassifiseringsnøyaktighet i tabellen under.

Klasse	CA
Skog (70)	97 %
Vann (90)	96 %
Hustak (50)	89 %
Gress (10)	88 %
Asfalt (40)	88 %
Mark (20)	77 %
Grus (30)	77 %
Jorde (70)	60 %

Tabell 7.9: Klassifiseringsnøyaktighet pr. klasse med 3 kanaler (primærklasser).

Nå vil G-kanalens egenskaper fjernes fra klassifiseringsgrunnet. Den samme klassifiseringen er gjort med 2 kanaler (MIR, NIR). Den dualspektrale forvirringsmatrisen er presentert på samme måte som den multispektrale:

Predikert Faktisk	10	20	30	40	50	60	70	90	Σ	Predikert Faktisk	10	20	30	40	50	60	70	90	Σ
10	38	2	0	0	0	2	1	0	43	10	38	2	0	0	0	2	1	0	43
20	2	34	3	0	1	4	0	0	44	20	2	34	3	0	1	4	0	0	44
30	0	3	28	5	0	3	0	1	40	30	0	3	28	5	0	3	0	1	40
40	0	0	4	37	1	0	0	0	42	40	0	0	4	37	1	0	0	0	42
50	0	0	0	1	41	0	0	2	44	50	0	0	0	1	41	0	0	2	44
60	7	4	10	3	1	23	0	0	48	60	7	4	10	3	1	23	0	0	48
70	0	1	0	0	0	0	39	0	40	70	0	1	0	0	0	0	39	0	40
90	1	0	0	0	0	0	0	23	24	90	1	0	0	0	0	0	0	23	24
Σ	48	44	45	46	44	32	40	26	325	Σ	48	44	45	46	44	32	40	26	325

Tabell 7.10: Forvirringsmatrise for klassifisering med 2 kanaler (primærklasser). Fremstilt på to måter. Til venstre antall feil, til høyre hvilke feil.

Klassifiseringsnøyaktighet til primærklassene for de forskjellige metodene ble som følger. Reduksjon fra multispektral klassifisering står i rød parentes:

	Random Forest Klassifisering	Support Vector Machine	k-Nærmeste Nabo	Logistisk Regresjon	Naive Bayes
CA [%]:	79,7%(-2,5%)	76,9%(-2,8%)	67,7%(-8%)	66,8%(-5,8%)	69,5 %(-1%)

Tabell 7.11: Klassifiseringsnøyaktighet med 2 kanaler (primærklasser).

Random Forest klassifiseringen kunne med 79,7% nøyaktighet predikere klassetilhørigheten riktig. Dette er en nedgang på 2,5% fra multispektral klassifisering. Dette tyder på at to laserkanaler er i stand til å gjøre opp imot like gode klassifiseringer som tre laserkanaler. Det kan likevel være noen klasser som blir vanskeligere å skille med to kanaler. Ved å studere forvirringsmatrisen (Tabell 7.10) kommer det nå frem at «jorde» (60) også forveksles i høy grad med «grus» (30). «grus» forveksles også mer med «mark» (20), og «mark» med «gress» (10). De spektrale egenskapene som forårsaker denne feilklassiferingen kan studeres i Figur 7.9. Her kommer det tydelig frem at G-kanalen har relativt større avstand mellom «grus» og

«mark» enn i MIR- og NIR-kanalene. Det samme gjelder «grus» og «jorde». Dermed er det naturlig at disse klassene blandes i større grad ved å utelate G-kanalen. «mark» feilklassifiseres nå til «gress», «grus», «hustak» (50) og «jorde», i motsetning til kun «gress» og «jorde» fra tidligere. «jorde» klassifiseres nå også til «asfalt» (40). Klassifiseringsnøyaktigheten til mark, grus og jorde er henholdsvis 77%, 70% og 48% (se Tabell 7.12).

Av de resterende klassene er det ikke store forskjeller fra tidligere. «hustak» har fått en bedre nøyaktighet enn tidligere. «hustak» korrelerer sterkt med høyde, da de i en normalisert punktsky vil ligge høyere enn de fleste andre overflater. En forklaring på den økende nøyaktigheten kan være at høydeegenskapene spiller en større rolle når 1/3 av intensitetsverdiene er fjernet fra klassifiseringsgrunnlaget. Ved dualspektral klassifisering er primærklassene rangert etter klassifiseringsnøyaktighet i tabellen under.

Klasse	CA	Avvik fra multispektral klassifisering
Skog (70)	97 %	0 %
Vann (90)	96 %	0 %
Hustak (50)	93 %	4 %
Gress (10)	88 %	0 %
Asfalt (50)	88 %	0 %
Mark (20)	77 %	0 %
Grus (30)	70 %	-7 %
Jorde (60)	48 %	-12 %

Tabell 7.12: Klassifiseringsnøyaktighet for dualspektral klassifisering. (Primærklasser). Avviket fra Multispektral klassifisering står i kolonnen til høyre.

Nå vil NIR-kanalens egenskaper også fjernes fra klassifiseringsgrunnlaget. Den samme klassifiseringen er gjort med 1 kanal (MIR). Den monospektrale forvirringsmatrisen er presentert på samme måte som den multispektrale:

Predikert Faktisk	10	20	30	40	50	60	70	90	Σ	Predikert Faktisk	10	20	30	40	50	60	70	90	Σ
10	28	0	2	5	0	7	1	0	43	10	28	0	2	5	0	7	1	0	43
20	1	31	5	0	1	6	0	0	44	20	1	31	5	0	1	6	0	0	44
30	4	5	26	2	0	2	0	1	40	30	4	5	26	2	0	2	0	1	40
40	6	0	4	30	1	1	0	0	42	40	6	0	4	30	1	1	0	0	42
50	0	0	0	1	39	0	1	3	44	50	0	0	0	1	39	0	1	3	44
60	10	7	10	0	1	20	0	0	48	60	10	7	10	0	1	20	0	0	48
70	0	1	0	0	0	0	39	0	40	70	0	1	0	0	0	0	39	0	40
90	0	0	0	1	0	0	0	23	24	90	0	0	0	1	0	0	0	23	24
Σ	49	44	47	39	42	36	41	27	325	Σ	49	44	47	39	42	36	41	27	325

Tabell 7.13: Forvirringsmatrise for klassifisering med 1 kanal (primærklasser). Fremstilt på to måter. Til venstre antall feil, til høyre hvilke feil.

Klassifiseringsnøyaktighet til primærklassene for de forskjellige metodene ble som følger. Reduksjon fra multispektral klassifisering står i rød parentes:

	Random Forest Klassifisering	Support Vector Machine	k-Nærmeste Nabo	Logistisk Regresjon	Naive Bayes
CA [%]:	75,4%(-6,8%)	68,9%(-10,8%)	66,8%(-8,9%)	56,3%(-16,3%)	64,3%(-6,2%)

Tabell 7.14: Klassifiseringsnøyaktighet med 1 kanal (primærklasser).

Random Forest klassifiseringen kunne med 75,4% nøyaktighet predikere klassetilhørigheten riktig. Dette er en nedgang på 6,8% fra multispektral klassifisering. Ved å basere seg kun på intensitetsverdier fra MIR-kanalen, kommer det tydelig frem hvilke tilleggsverdier som ligger i multispektral klassifisering av primærklassene. «skog» (70), «vann» (90) og «hustak» (50) beholder den samme nøyaktigheten med og uten multispektrale egenskaper. Dette kan skyldes at disse overflatene enklest skilles ved hjelp av høydeegenskaper. I kapittel 7.2.3 blir forskjellige typer «hustak» forsøkt klassifisert. «asfalt» (40), «mark» (20), «grus» (30), «gress» (10) og «jorde» (60) derimot, får betydelig lavere nøyaktighet ved kun å bruke én laserkanal. Disse overflatene forveksles nå i stor grad med hverandre. «gress» har nå en klassifiseringsnøyaktighet på 65% og blir oppfattet som både «grus», «asfalt», «jorde» og «skog». «mark» har nå en klassifiseringsnøyaktighet på 70% og blir oppfattet som både «gress», «grus», «hustak» og «jorde». «grus» har nå en klassifiseringsnøyaktighet på 65% og blir oppfattet som både «gress», «mark», «asfalt», «jorde» og «vann». «asfalt» har nå en klassifiseringsnøyaktighet på 71% og blir oppfattet som både «gress», «grus», «hustak» og «jorde». «jorde» har nå en klassifiseringsnøyaktighet på 42% og blir oppfattet som både «gress», «mark», «grus» og «hustak».

De fleste av feilklassifiseringene er knyttet til «jorde». Dette er forståelig da den intuitivt kan minne om både «gress» og «mark». Ut ifra intensitetsplottet i Figur 7.9 kan den lave nøyaktigheten forklares med den store spredningen av intensitetsverdier i MIR-kanalen. Det er denne kanalen som dårligst skiller «jorde» fra andre klasser. De to andre kanalene er med på å forbedre klassifiseringen av «jorde»-overflater, til tross for at disse har lav klassifiseringsnøyaktighet i utgangspunktet. Ved monospektral klassifisering er primærklassene rangert etter klassifiseringsnøyaktighet i tabellen under.

Klasse	CA	Avvik fra multispektral klassifisering
Skog (70)	97 %	0 %
Vann (90)	96 %	0 %
Hustak (50)	89 %	0 %
Asfalt (40)	71 %	-17 %
Mark (20)	70 %	-7 %
Grus (30)	65 %	-12 %
Gress (10)	65 %	-23 %
Jorde (60)	42 %	-18 %

Tabell 7.15: Klassifiseringsnøyaktighet for monospektral klassifisering med MIR-kanal. Avviket fra multispektral klassifisering står i kolonnen til høyre.

Det skal nevnes at mange polygoner har blitt riktig klassifisert også kun med én kanal. Høydeegenskapene gir alene en klassifiseringsnøyaktighet på 0,5 (se Figur 7.7). Sammen med monospektrale egenskaper kan da mange polygoner klassifiseres, men langt færre enn ved dual- og multispektral klassifisering. For hver klasse kan klassifiseringene gjort i dette kapitlet sammenlignes slik:

	Predikert	10	20	30	40	50	60	70	90	Σ
Faktisk		10	20	30	40	50	60	70	90	
10 (MIR, NIR, G)		38	0	0	0	0	4	1	0	43
10 (MIR, NIR)		38	2	0	0	0	2	1	0	43
10 (MIR)		28	0	2	5	0	7	1	0	43

Multispektrale egenskaper skiller «gress» (10) fra hovedsakelig «grus» (30) og «asfalt» (40). Også noe fra «jorde» (60).

	Predikert	10	20	30	40	50	60	70	90	Σ
Faktisk		10	20	30	40	50	60	70	90	
20 (MIR, NIR, G)		2	33	0	0	0	9	0	0	44
20 (MIR, NIR)		2	34	3	0	1	4	0	0	44
20 (MIR)		1	31	5	0	1	6	0	0	44

Multispektrale egenskaper skiller «mark» (20) fra hovedsakelig «grus» (30) og «hustak» (50).

	Predikert	10	20	30	40	50	60	70	90	Σ
Faktisk		10	20	30	40	50	60	70	90	
30 (MIR, NIR, G)		0	0	31	5	0	3	0	1	40
30 (MIR, NIR)		0	3	28	5	0	3	0	1	40
30 (MIR)		4	5	26	2	0	2	0	1	40

Multispektrale egenskaper skiller «grus» (30) fra hovedsakelig «gress» (10) og «mark» (20).

	Predikert	10	20	30	40	50	60	70	90	Σ
Faktisk		10	20	30	40	50	60	70	90	
40 (MIR, NIR, G)		0	0	4	37	1	0	0	0	42
40 (MIR, NIR)		0	0	4	37	1	0	0	0	42
40 (MIR)		6	0	4	30	1	1	0	0	42

Multispektrale egenskaper skiller «asfalt» (40) fra hovedsakelig «gress» (10) og «jorde» (60).

Predikert Faktisk	10	20	30	40	50	60	70	90	Σ
50 (MIR, NIR, G)	0	0	0	1	39	0	1	3	44
50 (MIR, NIR)	0	0	0	1	41	0	0	2	44
50 (MIR)	0	0	0	1	39	0	1	3	44

Multispektrale egenskaper ser ikke ut til å skille «hustak» (50) fra andre primærklasser.

Predikert Faktisk	10	20	30	40	50	60	70	90	Σ
60 (MIR, NIR, G)	7	8	3	0	1	29	0	0	48
60 (MIR, NIR)	7	4	10	3	1	23	0	0	48
60 (MIR)	10	7	10	0	1	20	0	0	48

Multispektrale egenskaper skiller «jorde» (60) fra hovedsakelig «grus» (30) og «gress» (10), selv om disse klassene fortsatt forveksles til en viss grad.

Predikert Faktisk	10	20	30	40	50	60	70	90	Σ
70 (MIR, NIR, G)	0	1	0	0	0	0	39	0	40
70 (MIR, NIR)	0	1	0	0	0	0	39	0	40
70 (MIR)	0	1	0	0	0	0	39	0	40

Multispektrale egenskaper ser ikke ut til å være betydelig i klassifisering av «skog» (70).

Predikert Faktisk	10	20	30	40	50	60	70	90	Σ
90.0	1	0	0	0	0	0	0	23	24
90.0	1	0	0	0	0	0	0	23	24
90.0	0	0	0	1	0	0	0	23	24

Multispektrale egenskaper ser ikke ut til å være betydelig i klassifisering av «vann» (90).

Noen primærklasser får med andre ord nytte av Optech Titans multispektrale egenskaper. Det er oppdaget tilleggsverdi i klassifisering av overflater som «grus» (30), «asfalt» (40), «mark» (20) og «gress» (10). Videre vil mer nyanserte klasser inspiseres. Der sekundærklassene for hver primærklasse skal vurderes for eventuelle tilleggsverdier til klassifisering.

7.2.3 Sekundærklasser

I sekundærklasse-datasettet inngår det 467 polygoner. Det er kun brukt 25 polygoner pr. klasse. Dette er i minste laget, og er en av svakhetene til den manuelle metoden som brukes i denne oppgaven. En flerlags segmentering ville kunne danne et bedre datagrunnlag i et konseptuelt produkt. 25 polygoner pr. klasse er likevel nok til å se tendenser av hva multispektrale egenskaper gjør bedre enn monospektrale. 19 klasser inngår i matrisen. Klassen «ung skog» (72), som er en skogklasse med yngre trær, utgår da den er for lik «voksen skog» (71). Dette drøftes senere i kapittelet. Enkeltrær er også med her, da dette datautvalget er regnet for en situasjon der både objekter og arealtyper skal kunne klassifiseres samtidig, og enkeltrær skal

kunne skilles fra andre overflater. Drøfting av enkeltrær er gjort i kapittel 7.2.4. En oversikt over de 19 sekundærklassene følger:

Gress		Hustak	
(10)	Plen	(51)	Mørke hustak
(12)	Vilt gress	(52)	Orange hustak
(13)	Slitt gress	(53)	Lyse hustak
Mark		Jorde	
(21)	Mark med vegetasjon	(61)	Bart jorde
(22)	Barmark	(62)	Jorde med vekst
Grus		Skog	
(31)	Stein	(71)	Voksen skog
(32)	Fin grus	Enkeltrær	
Asfalt		(75)	Furu
(41)	Mørt asfalt	(76)	Gran
(42)	Lys asfalt	(77)	Løv
		Vann	
		(91)	Elv, innsjø

Tabell 7.16: Eksempelutsnitt av klassene finnes i kapittel 7.1

Forvirringsmatrisen til sekundærklassene er langt større enn for primærklassene, og inneholder naturlig nok flere feilklassifiseringer. Denne matrisen vil ikke bli presentert i like stor grad, men de samme beregningene vil gjøres for å finne eventuelle tilleggsverdier. Forvirringsmatrise for multi-, dual- og monospektral sekundærklassifisering ligger vedlagt som henholdsvis Vedlegg 3, Vedlegg 4 og Vedlegg 5 i kapittel 10. Dette er forvirringsmatrisen for multispektral klassifisering. Matrisen sammenlignes med dualspektral og monospektral klassifisering senere i kapittelet.

Predikert Faktisk	11	12	13	21	22	31	32	41	42	51	52	53	61	62	71	75	76	77	91	Σ
11	22	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	25
12	6	4	1	1	5	0	0	0	0	0	0	0	2	6	0	0	0	0	0	25
13	1	1	13	1	2	0	1	0	0	0	0	0	4	0	0	0	0	0	0	23
21	0	1	2	15	5	0	0	0	0	0	0	0	0	0	2	0	0	0	0	25
22	0	1	1	3	17	2	0	0	0	0	0	0	1	0	0	0	0	0	0	25
31	0	0	0	0	1	20	3	0	0	0	0	0	0	0	0	0	0	0	1	25
32	0	0	1	0	0	2	18	0	3	0	0	0	1	0	0	0	0	0	0	25
41	0	0	0	0	0	0	0	21	3	0	0	0	0	0	0	0	0	0	1	25
42	0	0	0	1	0	0	2	6	15	0	0	0	0	0	0	0	0	0	0	24
51	0	0	0	1	0	0	0	0	0	12	1	5	0	0	0	0	1	0	1	21
52	0	0	0	0	0	0	0	0	0	3	20	1	0	0	0	0	0	1	0	25
53	0	0	0	0	0	0	0	0	0	2	1	21	0	0	0	0	0	1	0	25
61	1	3	1	0	0	1	0	0	0	0	0	0	13	6	0	0	0	0	0	25
62	0	4	2	0	0	0	1	0	0	0	0	0	5	13	0	0	0	0	0	25
71	0	0	0	1	0	0	0	0	0	0	0	0	0	0	23	0	1	0	0	25
75	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24	1	0	0	25
76	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	25
77	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	3	19	0	25
91	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24	24
Σ	30	15	22	23	30	25	25	27	21	17	22	27	25	27	26	26	31	21	27	467

Tabell 7.17: Forvirringsmatrise for klassifisering med multispektrale egenskaper.

Som med primærklassene er denne forvirringsmatrisen farget etter kassetilhørighet. Faktiske klasser ligger vannrett, mens predikerte klasser ligger loddrett. Sekundærklassene har like farger innad i primærklassen. Matrisen er et resultat av en Random Forest klassifisering. Allerede ved multispektral klassifisering ligger det flere feilklassifiserte polygoner innad i hver primærklasse. Denne klassifiseringen er gjort for å teste Optech Titans klassifiseringskapasitet. Hva som lar seg klassifisere av spektralverdier, og hva som blir for vanskelig å skille.

For sekundærklassene vil ikke resultatene presenteres separat for hver kanalkombinasjon, men samlet, der multispektrale, dualspektrale og monospektrale resultater settes opp mot hverandre. Klassifiseringsnøyaktigheten presenteres, med henholdsvis 3 kanaler (MIR, NIR, G), 2 kanaler (MIR, NIR) og 1 kanal (MIR), samt differansen imellom. Dette for alle klassifiseringsmetoder i tabellen som følger:

CA [%]	Random Forest Klassifisering	Support Vector Machine	k-Nærmeste Nabo	Logistisk Regresjon	Naive Bayes
MIR, NIR, G	73,0%	61,7%	53,3%	59,1%	59,3%
MIR, NIR	69,2%(-3,8%)	55,0%(-6,7%)	50,7%(-2,6%)	52,9%(-6,2%)	57,6%(-1,7%)
MIR	62,7%(-10,3%)	47,3%(-14,4%)	46,0%(-7,3%)	50,3%(-8,8%)	49,7%(-9,6%)

Tabell 7.18: Klassifiseringsnøyaktighet samlet med avvik. (sekundærklasser)

Den totale klassifiseringsnøyaktigheten reduseres fra 73,0% til 62,7% med Random Forest metoden. Som med primærklassene kan det tyde på at noen klasser påvirkes mer enn andre ved utelukkning av multispektrale egenskaper. Ved å sammenligne klassifiseringsnøyaktigheten for hver klasse separat, med og uten multispektrale egenskaper, kommer de mest påvirkede klassene til syne. Dette er gjort i følgende tabell:

Klasse, CA	MIR, NIR, G	MIR, NIR	MIR
Gress (11)	88 %	88 %	72 %
Gress (12)	16 %	32 %	28 %
Gress (13)	57 %	57 %	48 %
Mark (21)	60 %	64 %	52 %
Mark (22)	68 %	60 %	64 %
Grus (31)	80 %	84 %	80 %
Grus (32)	72 %	76 %	48 %
Asfalt (41)	84 %	84 %	80 %
Asfalt (42)	63 %	67 %	46 %
Hustak (51)	57 %	67 %	57 %
Hustak (52)	80 %	68 %	68 %
Hustak (53)	84 %	52 %	36 %
Jorde (61)	52 %	52 %	44 %
Jorde (62)	52 %	36 %	32 %
Skog (71)	92 %	96 %	84 %
Enkelttrær (Furu)	96 %	100 %	100 %
Enkelttrær (Gran)	100 %	100 %	84 %
Enkelttrær (Løv)	76 %	76 %	76 %
Vann (91)	100 %	100 %	100 %

Tabell 7.19: Klassifiseringsnøyaktighet pr. klasse (sekundærklasser)

Separat klassifiseringsnøyaktighet for hver sekundærklasse mellom multispektral og dualspektral klassifisering gir ganske like tall. I flere tilfeller er de dualspektrale resultatene mer nøyaktige. Det diskuteres i kapittel 7.3 om G-kanalen mangler betydelig tilleggsverdi. Ved monospektral klassifisering derimot, blir avvikene større. Slik ser klassifiseringsnøyaktigheten ut med kun NIR-kanal, samt avviket fra multispektral klassifisering, rangert etter klassifiseringsnøyaktighet i tabellen under:

Klasse	CA	Avvik fra multispektral klassifisering
Furu (75)	100 %	4 %
Vann (91)	100 %	0 %
Skog (71)	84 %	-8 %
Gran (76)	84 %	-16 %
Grus (31)	80 %	0 %
Asfalt (41)	80 %	-4 %
Løv (77)	76 %	0 %
Gress (11)	72 %	-16 %
Hustak (52)	68 %	-12 %
Mark (22)	64 %	-4 %
Hustak (51)	57 %	0 %
Mark (21)	52 %	-8 %
Grus (32)	48 %	-24 %
Gress (13)	48 %	-9 %
Asfalt (42)	46 %	-17 %
Jorde (61)	44 %	-8 %
Hustak (53)	36 %	-48 %
Jorde (62)	32 %	-20 %
Gress (12)	28 %	12 %


Tabell 7.20: Klassifiseringsnøyaktighet med 1 kanal. Avvik fra 3 kanaler til venstre.

Klassene som påvirkes mest av multispektrale egenskaper er «gran» (76), «plen» (11), «orange hustak» (52), «fin grus» (32), «lys asfalt» (42), «lyse hustak» (53) og «jorde med vekst» (62). «plen», «fin grus» og «lys asfalt» viste også i primærklassifiseringen at de ble forbedret med multispektrale egenskaper. Andre klasser som påvirkes er «voksen skog» (71), «mørk asfalt» (41), begge «mark»-klassene (21 og 22), «slitt gress» (13) og «bart jorde» (61). Disse klassene forbedres noe med multispektral klassifisering. «vilt gress» (12) ser ut til å forverre nøyaktigheten med 12% ved multispektral klassifisering, men denne klassen har allerede lavest nøyaktighet, og inneholder antakelig for mye støy til å kunne klassifiseres bra. Enkeltrærne ser ikke ut til å påvirkes stort av de multispektrale egenskapene, bortsett fra «gran», som forbedrer nøyaktigheten med 16%. Resultater for enkelttreklassifiseringen i kapittel 7.2.4 går nærmere inn på hva som skiller tresortene fra hverandre.

Akkurat som med primærklassene, er det flere av sekundærklassene som forveksles med hverandre. Hovedsakelig innenfor primærklassen. Noen sekundærklasser forveksles også med sekundærklasser i andre primærklasser. Dette er da de samme tendensene som ved primærklassifiseringen.

Intensitetsverdifordeling

Som forklart i kapittel 4.4 er ikke intensitetsverdiene som brukes til å klassifisere i denne oppgaven korrekte avlesninger av overflatenes reflektans. Hadde disse verdiene blitt absolutt-kalibrert (les kapittel 4.2) kunne antakelig flere sekundærklasser skilles fra hverandre. Verdiene som kommer direkte fra Optech Titan er her drøftet for sin evne til å klassifisere sekundærklasser uten videre kalibrering. Først ved å sammenligne intensitetsverdier fra Optech Titan, med reflektansen til et utvalg overflater. Intensitetsverdiene som brukes er gjennomsnittlige for de ulike overflatene, og normalisert til prosentandel av maksimalverdi for hver kanal. Maksimalverdien er kalibrert etter klassen «fin grus» (32), fra reflektanstill. Slik at grus har like verdier i sammenligningen. Andre prosentall fra Optech Titan er dermed relative til «fin grus»-verdiene. Reflektanstill er hentet fra spektralkurver for de ulike overflatene. Diagrammet under viser hvor godt disse stemmer overens.

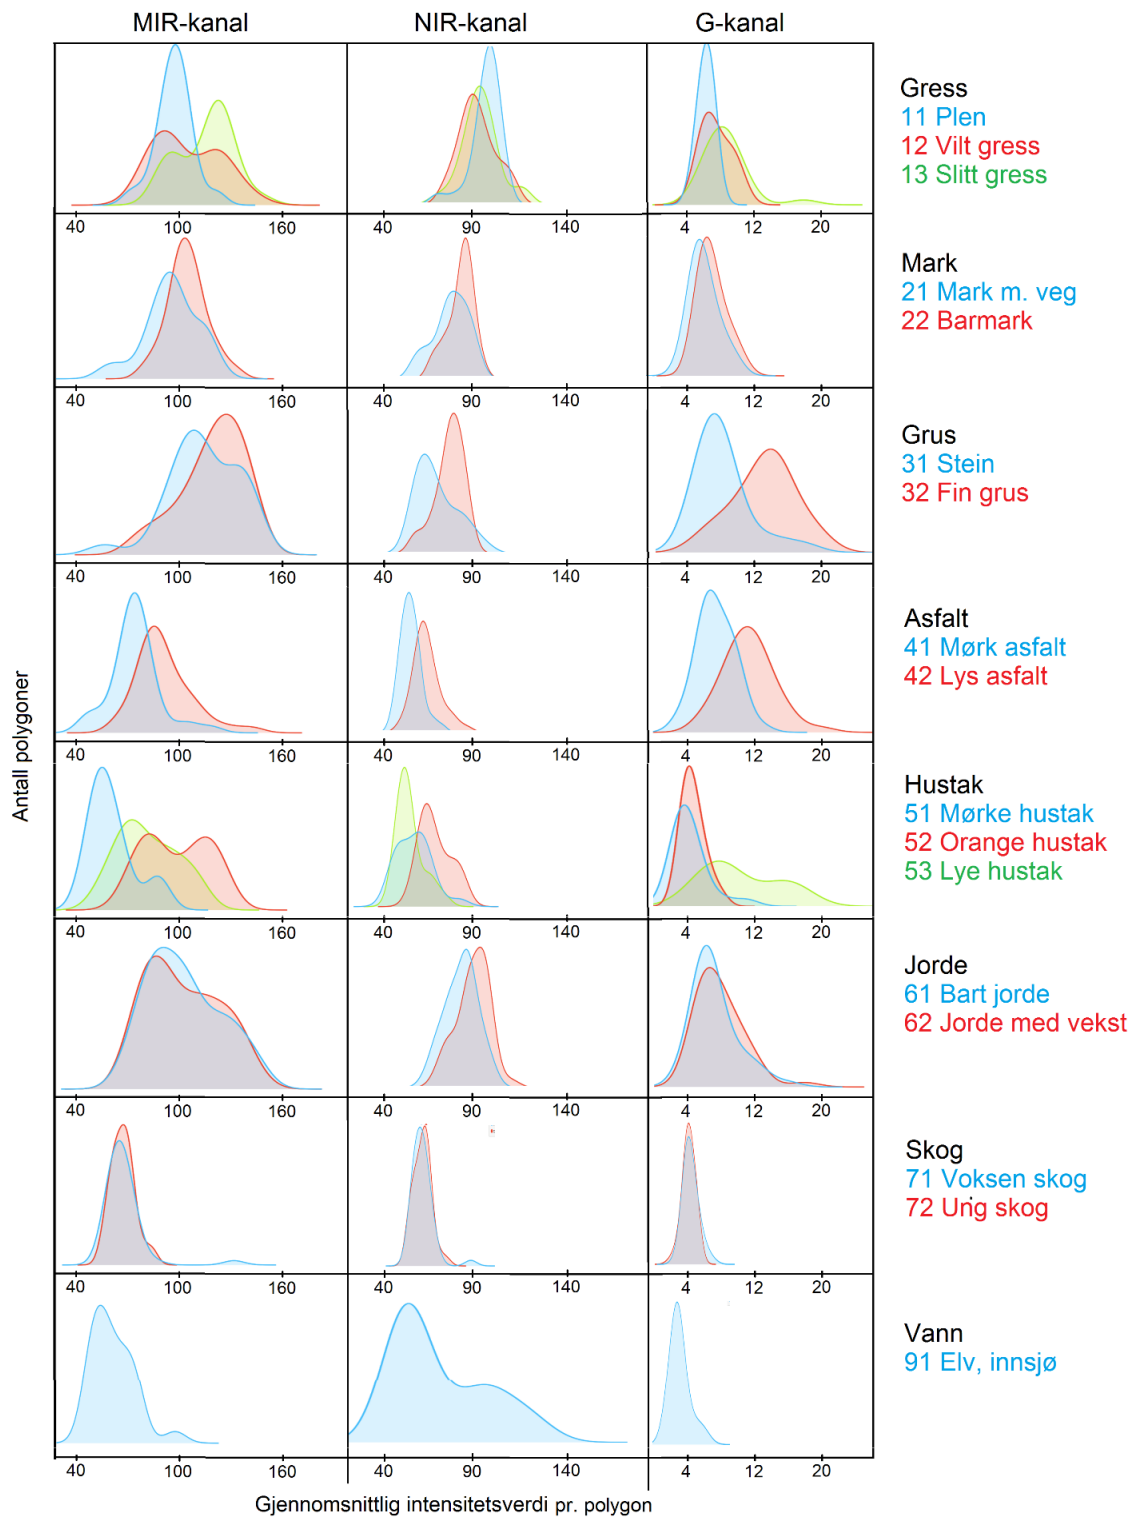


Figur 7.11: Faktiske reflektansverdier mot registrerte intensitetsverdier for noen av klassene i oppgaven.

Disse diagrammene sammenligner reflektans fra materialer på ulike bølgelengde. Det kommer tydelig frem at disse spektralkurvene ikke er like. På grunn av den lokale kalibreringen gjort i Optech Titan-diagrammet, er «fin grus» (32)-grafene lik i begge plot. «lys asfalt» (42)-grafene ligger relativt likt i forhold. Utenom dette er det få klasser fra Optech Titan som gir like forholdstall som i reflektansplottet. Alle verdier ligger en del lavere, og har mindre spredning. «furu» (76), «løv» (77) og «plen» (11) har tendenser til likehetstrekk i form, bortsett fra dette finnes ikke mye korrelasjon mellom grafene. Dette tyder på at det kan bli vanskelig å skille nyanser i klassene fra hverandre. De multispektrale verdiene til Optech Titan kan ha nytte av å

bli både relativt kalibrert, for å øke spredningen, og absolutt kalibrert, for å gi de riktige forholdstallene.

Ved å også studere intensitetsverdifordelingen til sekundærklassene hver for seg, pr. kanal, er det lettere å forstå hvorfor noen klasser forveksles. Det blir også enklere å forstå hvilken tilleggsverdi disse multispektrale egenskaper har. I figuren under er gjennomsnittlig intensitetsverdi pr. polygon plottet mot antall polygoner. På denne måten kommer den typiske intensitetsverdien for hver overflate frem.



Figur 7.12: Histogram for gjennomsnittlige intensitetsverdier (sekundærklasser).

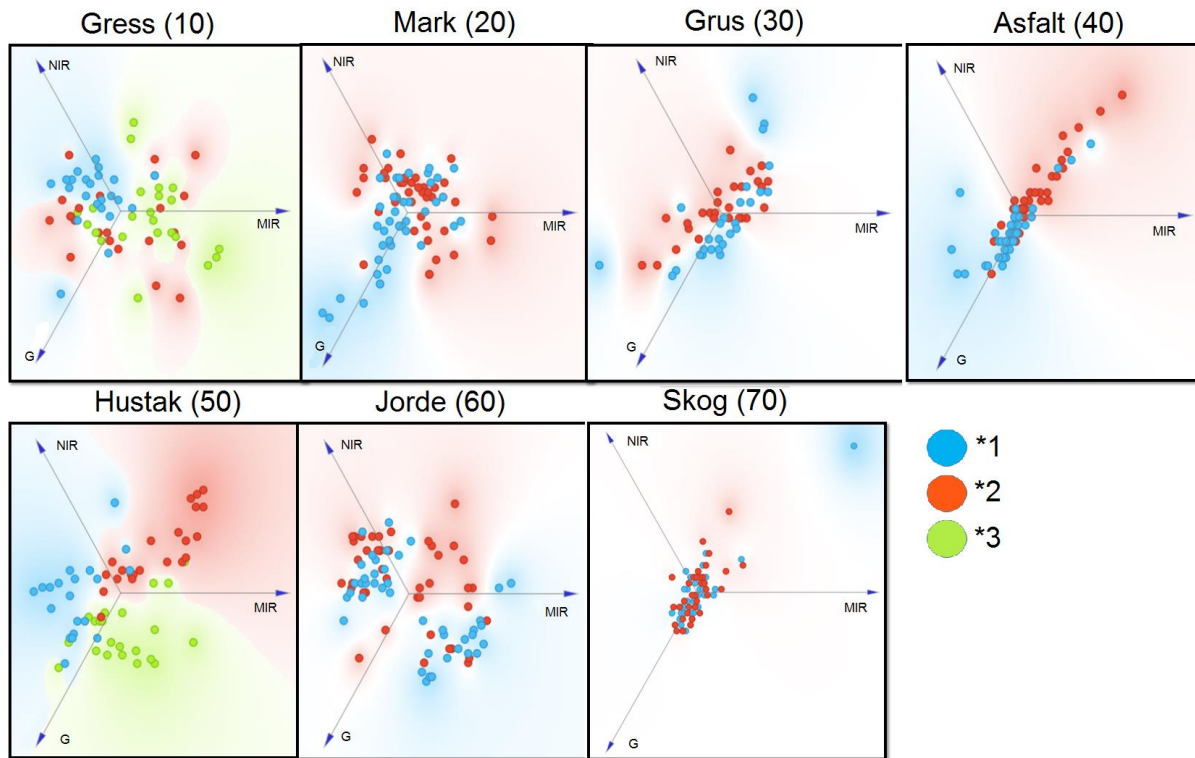
Histogrammene til de ulike klassene og kanalene har forskjellige former. Normalfordeling av histogrammene er gunstig for klassifiseringsformål. Dette fordi gjennomsnittlig intensitetsverdi med standardavvik er enkle tall å skille fra hverandre. Har histogrammene skjevhet, eller bimodal fordeling, blir også karakteristikken for klassen mer kompleks. Normalfordeling

innebærer at alle verdier er sentrert rundt én topp, med et ca. likt antall verdier på hver side av senter. I figuren over har blant andre «barmark» (22) i MIR, «plen» (11) i MIR og G, tilnærmet normalfordeling. Grunnen til at ikke alle histogrammene er normalfordelt, kommer av at det ikke er entydig hvilken intensitetsverdi disse klassene er sentrert rundt. Dette kan være i form av skjevhet eller bimodalitet. Ved skjevhet har en betydelig del av overflatene innad i klassen høyere verdier enn gjennomsnittet. Dette forekommer i bl.a. «fin grus» (32) i MIR og G, samt «jorde med vekst» (62) i NIR. Noen av overflatene her kunne kanskje skilles til flere sekundærklasser innad i primærklassen. Ved bimodal fordeling kan flere topper skimtes i histogrammet. Dette tyder også på at flere sekundærklasser kan skilles i primærklassen. Eventuelt feil fasitverdi i treningsdataene. Skjevhet og bimodal fordeling kan være med på å skape støy i klassifiseringen.

Mange av histogrammene ligger i samme områder, og alle overlapper hverandre til en viss grad. Dette kan klassifiseringsmetoder skille ved å bruke karaktertrekk ved histogrammene. Om histogrammene skulle bli for like hverandre, kan det likevel bli vanskelig for klassifiseringsmetoden. Det er her de multispektrale egenskapene blir viktige. Selv om klassehistogrammene er lik i én kanal, kan de opptre veldig forskjellig i andre kanaler. Stor spredning av intensitetsverdier er også en utfordring. Dette forekommer bl.a. i grus- og jordeklassene for MIR og G. «vilt gress» (12) og «slitt gress» (13) har f.eks. ganske nære topper i NIR-kanalen, men i MIR-kanalen er distansen større. Fra figuren ser det ut til at «gress»-klassene, «grus»-klassene, «asfalt»-klassene og «hustak»-klassene skal kunne skilles i en multispektral klassifisering. «mark»-klassene, «jorde»-klassene og «skog»-klassene ser ut til å være en større utfordring for klassifiseringsmetoden, da de har ganske like verdier i hver kanal.

Spektralverdi multiplott

Gjennomsnittlig intensitetsverdi plottes også i et multiplott, der tre dimensjoner fremstilles som én dimensjon. Hvert punkt i plottet er en polygon. Høyere verdier i én kanal trekker den aktuelle polygonen i retningen til kanalens akse. Multiplott for hver primærklasse, med sekundærklassene plottet mot hverandre, følger:



Figur 7.13: Multiplott av alle sekundærklasser.

Som i intensitetsverdifordelingen er det flere av klassene som blandes. Klassene som ser ut til å skille seg best, er «grus» (30), «asfalt» (40) og «hustak» (50). Dette samsvarer bra med intensitetsverdifordelingen. «plen» (11) og «slitt gress» (13) ser ut til skilles, men «vilt gress» (12) ligger spredt over de andre klassene. «mark»-klassene ser også ut til å blande seg en del. Der antakelig en del av «barmark» (22) vil oppfattes som «mark med vegetasjon» (21). «jorde»-klassene har mye spredning og lite konsistens innad i klassene. «skog»-klassene derimot, har liten spredning, men ingen tendenser til å skille seg. Klassen «ung skog» (72) blir utelatt av klassifiseringen på grunn av dette. Klassen er for udefinert til å kunne vurderes, og vil skape støy i resultatet som kan reduser kvaliteten i analysen.

Forvirringsmatriser

Av primærklassene var det visse klasser som ved hjelp av multispektrale egenskaper bedre lot seg skille fra andre klasser. Her blir klassifiseringsnyansene i hver primærklasse studert nærmere, både i forhold til andre sekundærklasser, og innad i primærklassen. Forvirringsmatrisen for multispektral, dualspektral og monospektral klassifisering sammenlignes. Utklipp av separate klasser vises hver for seg. Dette for å lettere se sammenheng mellom forvirringsmatrisene. Her kommer den multispektrale tilleggsverdien til syne.

		11	12	13	21	22	31	32	41	42	51	52	53	61	62	71	75	76	77	91	Σ
MIR,NIR, G	11	22	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	25
	12	6	4	1	1	5	0	0	0	0	0	0	0	2	6	0	0	0	0	0	25
	13	1	1	13	1	2	0	1	0	0	0	0	0	4	0	0	0	0	0	0	23
MIR,NIR	11	22	0	2	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	25
	12	4	8	2	0	7	0	0	0	0	0	0	0	1	3	0	0	0	0	0	25
	13	1	0	13	1	4	0	3	0	1	0	0	0	0	0	0	0	0	0	0	23
MIR	11	18	2	0	0	0	0	0	0	3	0	0	0	2	0	0	0	0	0	0	25
	12	4	7	1	2	4	0	1	1	1	0	0	0	2	2	0	0	0	0	0	25
	13	0	2	11	0	2	0	7	0	1	0	0	0	0	0	0	0	0	0	0	23

Innad i primærklassen gress, skiller ikke sekundærklassene seg noe bedre fra hverandre ved multispektral klassifisering. I plottet for intensitetsverdier (Figur 7.12) kan dette forklares med at det er MIR-kanalen som best skiller «gress»-sekundærklassene best fra hverandre. Det er heller andre klasser som forveksles med «gress» (10). Spesielt «vilt gress», som i utgangspunktet har veldig lav nøyaktighet. Bimodal fordeling observeres i intensitetsverdiene (Figur 7.12) og stor spredning av verdier observeres i multiplottet (Figur 7.13) for «vilt gress». Alle klassene ser ut til å forveksles med «asfalt» (40) ved monospektral klassifisering. «vilt gress» og «slitt gress» (13) ser også ut til å forveksles med «mark» (20), uten at dette forbedres ved multispektral klassifisering. Det eneste som forbedres i stor grad ved multispektral klassifisering er forvekslingen med «grus» og «asfalt» (40).

		11	12	13	21	22	31	32	41	42	51	52	53	61	62	71	75	76	77	91	Σ
MIR,NIR, G	21	0	1	2	15	5	0	0	0	0	0	0	0	0	0	2	0	0	0	0	25
	22	0	1	1	3	17	2	0	0	0	0	0	0	0	1	0	0	0	0	0	25
MIR,NIR	21	0	0	2	16	6	0	0	0	0	0	0	0	0	0	1	0	0	0	0	25
	22	0	4	0	4	15	2	0	0	0	0	0	0	0	0	0	0	0	0	0	25
MIR	21	0	0	2	13	8	0	0	0	0	0	0	0	0	0	1	0	1	0	0	25
	22	0	4	0	3	16	2	0	0	0	0	0	0	0	0	0	0	0	0	0	25

Innad i primærklassen «mark», skiller sekundærklassene seg noe bedre med multispektrale egenskaper. Ved monospektral klassifisering er 8 polygoner fra «mark med vegetasjon» (21) klassifisert som «barmark» (22), mens ved multispektral er antallet redusert til 5. Dette er altså fortsatt ikke perfekt. «gress»-klassene (12 og 13) ser ut til å bli forvekslet med «mark»-klassene (21 og 22). Situasjonen forbedrer seg ikke ved multispektral klassifisering. 2 «barmark»-overflater ser ikke ut til å kunne skilles fra «stein» (31). Det samme gjelder «mark med vegetasjon» og «voksen skog» (71). Det eneste som ser ut til å forbedre seg med multispektral klassifisering er sekundærklassene innad i primærklassen «mark». I multiplottet (Figur 7.13) ser det også ut til at disse sekundærklassene kan skilles til en viss grad.

		11	12	13	21	22	31	32	41	42	51	52	53	61	62	71	75	76	77	91	Σ	
MIR,NIR,G	31	0	0	0	0	1	20	3	0	0	0	0	0	0	0	0	0	0	0	0	1	25
	32	0	0	1	0	0	2	18	0	3	0	0	0	1	0	0	0	0	0	0	0	25
MIR,NIR	31	0	0	0	0	1	21	2	0	0	0	0	0	0	0	0	0	0	0	0	1	25
	32	0	0	0	0	0	3	19	0	3	0	0	0	0	0	0	0	0	0	0	0	25
MIR	31	0	0	0	0	2	20	2	0	0	0	0	0	0	0	0	0	0	0	0	1	25
	32	1	1	5	1	0	2	12	0	1	0	0	0	0	2	0	0	0	0	0	0	25

Innad i primærklassen grus ser det ikke ut til at sekundærklassene skiller seg bedre fra hverandre ved multispektral klassifisering. Det eneste som forbedres fra monospektral til multispektral klassifisering er «fin grus» (32), som skiller fra hovedsakelig «slitt gress» (13), men også resten av gressklassen samt «mark med vegetasjon» (21).

		11	12	13	21	22	31	32	41	42	51	52	53	61	62	71	75	76	77	91	Σ	
MIR,NIR,G	41	0	0	0	0	0	0	0	21	3	0	0	0	0	0	0	0	0	0	0	1	25
	42	0	0	0	1	0	0	2	6	15	0	0	0	0	0	0	0	0	0	0	0	24
MIR,NIR	41	0	0	0	0	0	1	0	21	2	0	0	0	0	0	0	0	0	0	0	1	25
	42	0	0	0	1	0	0	1	6	16	0	0	0	0	0	0	0	0	0	0	0	24
MIR	41	0	0	0	0	1	0	0	20	3	0	0	0	0	0	0	0	0	0	0	1	25
	42	2	0	0	1	0	0	1	7	11	0	0	0	0	2	0	0	0	0	0	0	24

Innad i primærklassen asfalt ser det ikke ut til at sekundærklassene skiller seg bedre fra hverandre med multispektral klassifisering. Her er det heller «lys asfalt» (42) som skiller fra «plen» (11), «mark med vegetasjon» (21) og «jorde med vekst» (62) som skiller seg i overgangen fra monospektral til multispektral klassifisering. I intensitetsverdifordelingen ser «asfalt»-klassene ut til å skille seg lett i alle kanaler.

		11	12	13	21	22	31	32	41	42	51	52	53	61	62	71	75	76	77	91	Σ
MIR,NIR,G	51	0	0	0	1	0	0	0	0	0	12	1	5	0	0	0	0	1	0	1	21
	52	0	0	0	0	0	0	0	0	0	3	20	1	0	0	0	0	0	1	0	25
	53	0	0	0	0	0	0	0	0	0	2	1	21	0	0	0	0	0	1	0	25
MIR,NIR	51	0	0	0	1	0	0	0	0	0	14	1	2	0	0	0	0	2	0	1	21
	52	0	0	0	0	0	0	0	0	0	3	17	5	0	0	0	0	0	0	0	25
	53	0	0	0	0	0	0	0	0	0	3	8	13	0	0	0	0	0	1	0	25
MIR	51	0	0	0	0	0	0	0	1	0	12	0	4	0	0	0	0	1	1	2	21
	52	0	0	0	1	0	0	0	0	0	1	17	6	0	0	0	0	0	0	0	25
	53	0	0	0	0	0	0	0	0	0	6	8	9	0	0	0	0	0	2	0	25

Innad i primærklassen «hustak» (50) skiller sekundærklassene seg noe bedre i overgangen fra monospektral til multispektral klassifisering. «lyse hustak» (53) skiller fra «mørke hustak» (51) i overgangen fra monospektral til dualspektral klassifisering. Fra dualspektral til multispektral klassifisering skiller «orange hustak» (52) fra «lyse hustak». Én «mørk asfalt» (41)-overflate ser også ut til å ikke lenger forveksles med «mørke hustak» ved overgangen fra mono til multispektrale egenskaper. Disse overflatene er allerede enkle å skille med høydeegenskaper. En del enkeltrær ser også ut til å forveksles med de tre «hustak»-klassene. Dette forbedres heller

ikke med flere kanaler. Trærne kan ha høyder som tilsvarer hus, samtidig som det i kapittel 7.2.4 kommer frem at trær har lave intensitetsverdier, som antatt i kapittel 6.3. Disse lave verdiene kan ligne på lave verdier fra «mørke hustak». Det samme gjelder «mark med vegetasjon» (21) som kan forklares av det samme som med enkeltrær. Da det kan finnes punkter med høy høydeverdi og lav intensitetsverdi i denne klassen. Hvorfor «elv, innsjø» (91), som kun består av lave høydeverdier, er forvekslet med «mørke hustak» (51) er vanskelig å forstå. Ut i fra intensitetsverdifordelingen, ser «mørke hustak og «elv, innsjø» ut til å ha de samme lave intensitetsverdiene i MIR-kanalen. «vann» (90) kan naturlig få mye støy i høydeverdiene, samt lave intensitetsverdier. Alt i alt er det eneste som ser ut til å forbedre seg i betydelig grad med multispektral klassifisering, sekundærklassene innad i primærklassen «hustak».


		11	12	13	21	22	31	32	41	42	51	52	53	61	62	71	75	76	77	91	Σ
MIR,NIR, G	61	1	3	1	0	0	1	0	0	0	0	0	0	13	6	0	0	0	0	0	25
	62	0	4	2	0	0	0	1	0	0	0	0	0	5	13	0	0	0	0	0	25
MIR,NIR	61	0	2	0	0	2	0	2	0	1	0	0	0	13	5	0	0	0	0	0	25
	62	0	3	5	0	0	0	3	0	1	0	0	0	4	9	0	0	0	0	0	25
MIR	61	4	1	1	0	1	1	0	0	0	0	0	0	11	6	0	0	0	0	0	25
	62	0	3	3	0	1	0	3	3	0	0	0	0	4	8	0	0	0	0	0	25

Innad i primærklassen «jorde» (60) ser det ikke ut til at sekundærklassene skilles bedre fra hverandre med multispektral klassifisering. Det er generelt mye støy i denne primærklassen, uansett egenskapsutvalg. Det ser likevel ut til at både «barmark» (22), «fin grus» (32), og begge «asfalt»-klassene kan skilles fra «jorde»-klassene med multispektral klassifisering. Ved dualspektral klassifisering skiller «stein» (31) seg fra «jorde med vekst» (62). Ved multispektral klassifisering skiller «barmark» fra «bart jorde». «fin grus» og «lys asfalt» (42) skiller seg fra begge «jorde»-klassene. Alle «gress»-klassene ser ut til å forveksles med begge «jorde»-klassene uansett egenskapsutvalg. Dette kan skyldes at «jorde»-klassene kan bestå av mye som ligner på «plen» (11), «vilt gress» (12) og «slitt gress» (13). Alt i alt er det «grus»- og «asfalt»-klassene som lar seg skille fra «jorde»-klassene ved multispektral klassifisering.

Videre er tilleggsverdier for klassifisering av enkelttrær analysert. Sekundærklassene innenfor «Skog»-klassen ble ikke vurdert opp mot hverandre på samme måte som klassene ovenfor, da disse ikke lot seg skille på noe vis. Primærklassen «skog» (70) derimot, lot seg skille fra de andre klassene i kapittel 7.2.2. Dette tyder på at intensitetsverdiene kan skille «skog» fra andre overflater, men at sekundærklassene som er valgt ikke er optimale. «Vann»-klassen er heller ikke drøftet videre da den ikke består av flere sekundærklasser.


7.2.4 Enkeltrær

I enkeltrær-analysen inngår det 123 polygoner. Disse er fordelt på 3 enkelttre-klasser med 41 polygoner i hver klasse. Enkeltrærne som klassifiseres er «furu» (75), «gran» (76) og «løv» (77). I motsetning til de tidligere klassifiseringene, har ikke bare disse klassene ulike spektraloverflater, men også forskjellig form. De forskjellige trærne ser ganske forskjellig ut, både geometrisk og spektralt. Laserskanning har lenge blitt brukt til enkelttre-deteksjon (Vosselman & Maas 2010), men da basert på geometrisk fordeling av punkter. Dette har holdt til bl.a. å estimere høyder, identifisere tresorter, volum, biomasse og vekst. Spektrale egenskaper kan kanskje forbedre enkelttreklassifiseringen ytterligere, ved å også skille tresorter fra hverandre ved hjelp av intensitetsverdier (Yu et al. 2017). Eksempler på de ulike enkelttre-klassene er vist under.



Figur 7.14: De klassifiserte enkeltrærnes utseende.


Trærne har tydelige spektrale forskjeller i den visuelle delen av spekteret. I hvert fall løv, som skiller seg mer fra furu og gran. Løvtrær kan ha forskjellige fargetoner, så det forventes en større spredning av spektralverdier. De spektrale forskjellene i de aktuelle kanalene MIR, NIR og G vises i plottet av gjennomsnittlig intensitetsverdi mot antall polygoner analysert.



Figur 7.15: Histogram for fordeling av gjennomsnittlige intensitetsverdier, tresorter.

I MIR-kanalen har «furu» (75) og «løv» (77) begge skjevheter i histogrammet, mens «gran» (76) har en tilnærmet normalfordeling, men med tendenser til bimodalitet. Furu har størst spredning av verdier. De samme tendensene dukker opp i NIR-kanalen. Her ser «løv» ut til å

ha den største spredningen. I G-kanalen er alle tresorter tilnærmet normalfordelt. Et mulig problem er at spektralverdiene overlapper i stor grad. En antakelse var også at «løv» skulle ha høyere intensitetsverdier enn de to andre tresortene, men verdiene ser ut til å ligge på nivå med «gran». «furu» derimot, ser ut til å ha de høyeste intensitetsverdiene. En forklaring på dette kan være pulsfordeling (les kapittel 4.2), der pulsene som treffer løvtrær splittes i større grad, og returnerer lavere intensitetsverdier. «furu» har naturlig tynnere vegetasjon, og kan dermed ha splittet pulser i mindre grad. Maksverdi for intensitet viser at «løv» har de høyeste verdiene i NIR-kanal, men holder seg på nivå med «gran» i MIR- og G-kanal. Maksverdiene er likevel ikke valgt ut blant egenskaper til klassifisering, da de ikke viste seg å gjøre signifikante utslag på klassifiseringsnøyaktigheten. Multiplottet som følger bekrefter at intensitetsverdiene overlapper hverandre i stor grad:



Figur 7.16 Multiplott av tresorter. For gjennomsnittlig intensitetsverdi i de forskjellige kanalene.

I multiplottet ser «gran» (76) og «løv» (77) ut til å blandes. Dette kan føre til forvekslinger i klassifiseringen. Høydeverdier vil likevel kunne skille disse, men i så fall gir ikke multispektrale egenskaper noen ekstra tilleggsverdi. «furu» (75) har et tydeligere skille fra de to andre tresortene, men blandes også til en viss grad.

I klassifiseringen ble tresortene klassifisert med kappaverdi 0,74 med multispektrale egenskaper, 0,70 med dualspektrale egenskaper, og 0,70 med monospektrale egenskaper. Dette tyder på at det finnes en tilleggsverdi i de multispektrale egenskapene. Disse tilleggsverdiene blir funnet ved å se på den tilsvarende klassifiseringsnøyaktigheten:

Klassifiseringsnøyaktighet [%]	Random Forest Klassifisering	Support Vector Machine	k-Nærmeste Nabo	Logistisk Regresjon	Naive Bayes
MIR, NIR, G	82,3%	78,2%	50,8%	80,6%	74,2%
MIR, NIR	79,0%(-3,3%)	79,8%(+1,6%)	50,8%(-0%)	75,8%(-4,8%)	73,4%(-0,8%)
MIR	75,8%(-6,5%)	79,0%(+0,8%)	50,0%(-0,8%)	77,4%(-3,2%)	71,8%(-2,4%)

Tabell 7.21: Klassifiseringsnøyaktighet samlet med avvik. (Enkeltrær)

Denne klassifiseringen skiller seg fra de andre, ettersom Random Forest metoden går fra å yte best ved multispektrale egenskaper til å yte dårligere enn Support Vector Machine og Logistisk Regresjon ved monospektrale egenskaper. Support Vector Machine er den mest nøyaktige klassifiseringsmetoden ved dual- og monospektral klassifisering av tresorter, men får dårligere nøyaktighet ved multispektral klassifisering. Det er mulig at fallet i nøyaktighet har noe med antall attributter å gjøre. På grunn av dette brukes forvirringsmatrisen fra Random Forest for å finne tilleggsverdier ved multispektrale egenskaper, og sammenlignes med forvirringsmatrisene fra Support Vector Machine ved dual- og monospektrale egenskaper. Dette betyr at klassifiseringsmetode kan være avgjørende for å utnytte de tilleggsverdiene multispektrale egenskaper har.

Ved å sammenligne klassifiseringsnøyaktigheten for hver klasse separat, med og uten multispektrale egenskaper, kommer de mest påvirkede klassene til syne. Dette er gjort i følgende tabell:

Klasse, CA	MIR, NIR, G	MIR, NIR	MIR	Avvik (3 til 2) kanaler	Avvik (3 til 1) kanal
Furu (75)	88 %	85 %	85 %	-3 %	-3 %
Gran (76)	86 %	88 %	86 %	2 %	0 %
Løv (77)	76 %	66 %	68 %	-10 %	-8 %

Tabell 7.22: Klassifiseringsnøyaktighet sammenlignet (Enkeltrær). Avvik fra 3 kanaler til venstre.

Det er interessant å se at i denne klassifiseringen har «gran» (76) ikke blitt forbedret fra monospektral klassifisering, mens den i datautvalget til sekundærklassene var en av de mest påvirkede. Dette var tilfelle både for Random Forest og Support Vector Machine. Resultatet kan tyde på at gran har en tendens til å feilklassifiseres som andre ting enn trær. Det kommer tydelig frem i forvirringsmatrisen til «hustak» (50) i kapittel 7.2.3, at både «gran» (76) og «løv» (77) forveksles mye med både «mørke hustak» (51) og «lyse hustak» (53). Ellers er det «løv» som drar mest nytte av multispektrale egenskaper, med en forbedring på 8%. «furu» (75) har en forbedring på 3%.

Forvirringsmatrisene sammenlignes for hvert egenskapsutvalg pr. tresort.

	Furu 75	Gran 76	Løv 77	Σ
75 (MIR, NIR, G)	36	3	2	41
75 (MIR, NIR)	35	1	5	41
75 (MIR)	35	2	4	41
76 (MIR, NIR, G)	2	36	4	42
76 (MIR, NIR)	2	37	3	42
76 (MIR)	2	36	4	42
77 (MIR, NIR, G)	1	9	31	41
77 (MIR, NIR)	5	9	27	41
77 (MIR)	0	13	28	41

Tabell 7.23: Forvirringsmatriser sammenlignet med ulike egenskapsutvalgene (Enkeltrær)

I matrisen over er de tre egenskapsutvalgene sammenlignet for hver tresort. For «furu» (75) skiller multispektrale egenskaper ut noe «løv» (77). For «gran» (76) ser ikke multispektrale egenskaper ut til å hjelpe til med å skille tresorter fra hverandre. «gran» ser ut til å forveksles noe mer med «løv» enn med «furu» ved alle egenskapsutvalgene. Dette stemmer godt overens med intensitetsplottet, der disse klassene blandet seg mer enn «furu». For «løv» skiller multispektrale egenskaper ut noe «furu» og «gran».

Tresortene skiller seg generelt noe bedre med multispektrale egenskaper, men godt også uten. I hovedsak er det «furu» (75) og «løv» (77) som forbedres. «løv» blir mest påvirket. Dette går imot antakelsen om at «furu» ville best la seg skille av tresortene, som lest ut fra intensitetsplottet i Figur 7.16. «gran» (76) skiller seg også fra de to andre tresortene, men ikke på grunn av multispektrale egenskaper. Dette er antakelig mer knyttet til geometri og monospektrale intensitetsverdier.

7.2.5 Polygonvisualisering

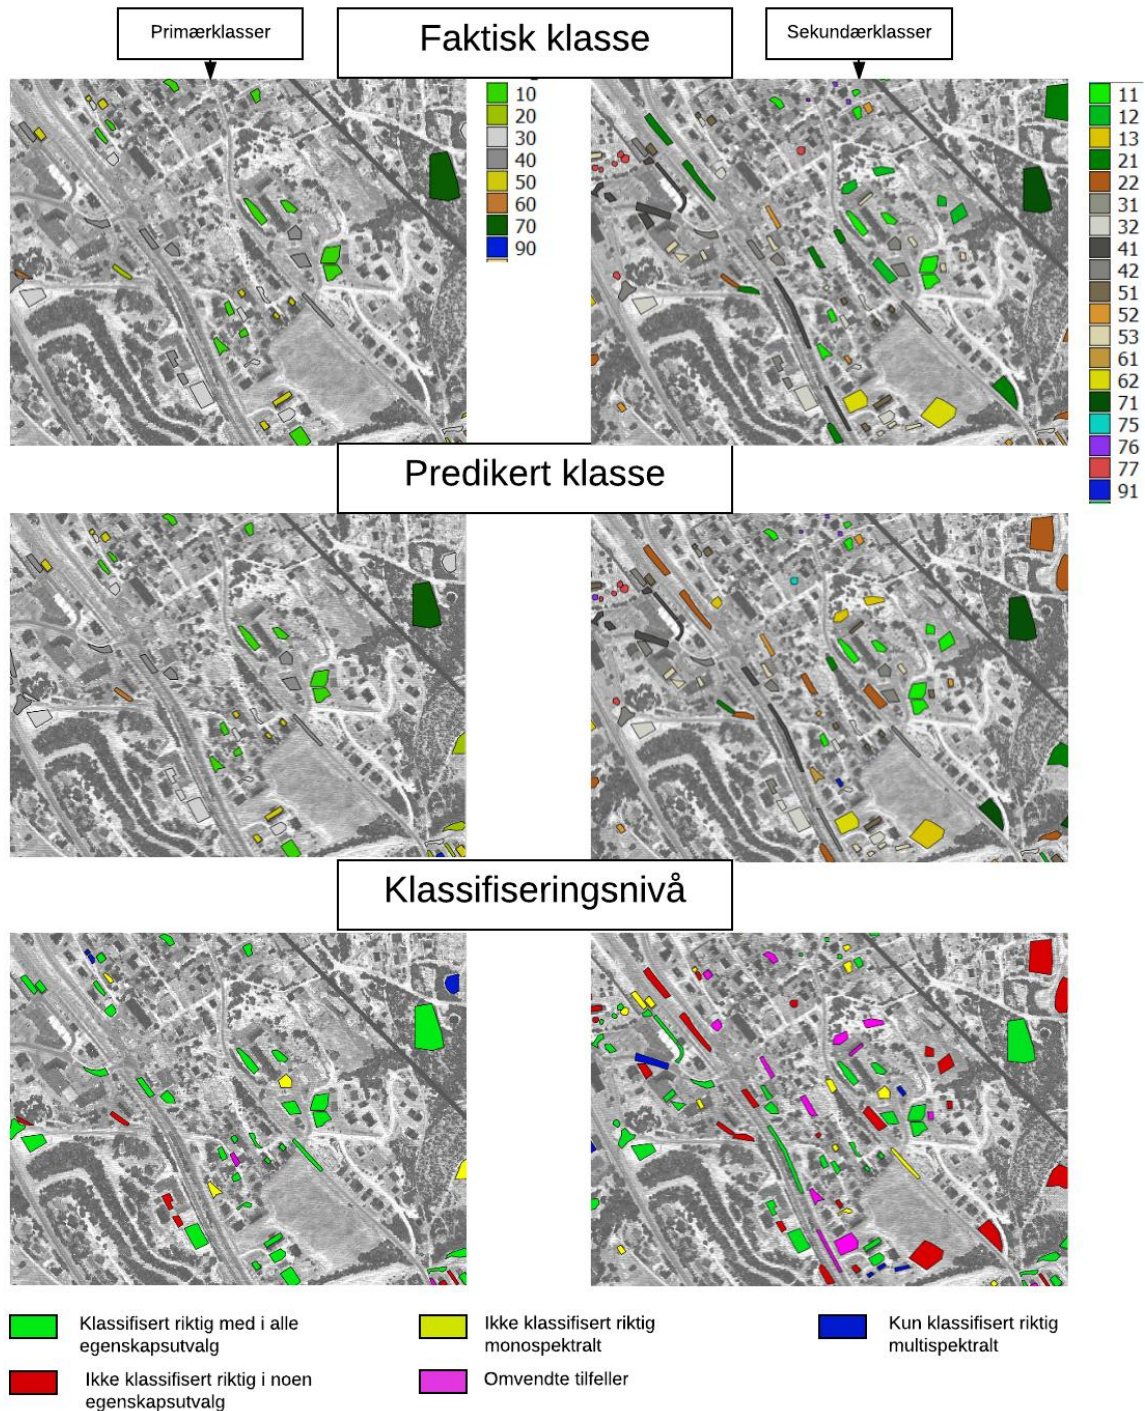
Etter fullført klassifisering kombineres resultatet med de opprinnelige polygonene. Hver polygon får tilegnet informasjon om predikert klasse for hver klassifisering. Som vist i følgende tabell:

ID	Primærklasse	Sekundærklasse	Predikert (3 kanaler)	Predikert (2 kanaler)	Predikert (1 kanal)
162	50	52	52	53	71

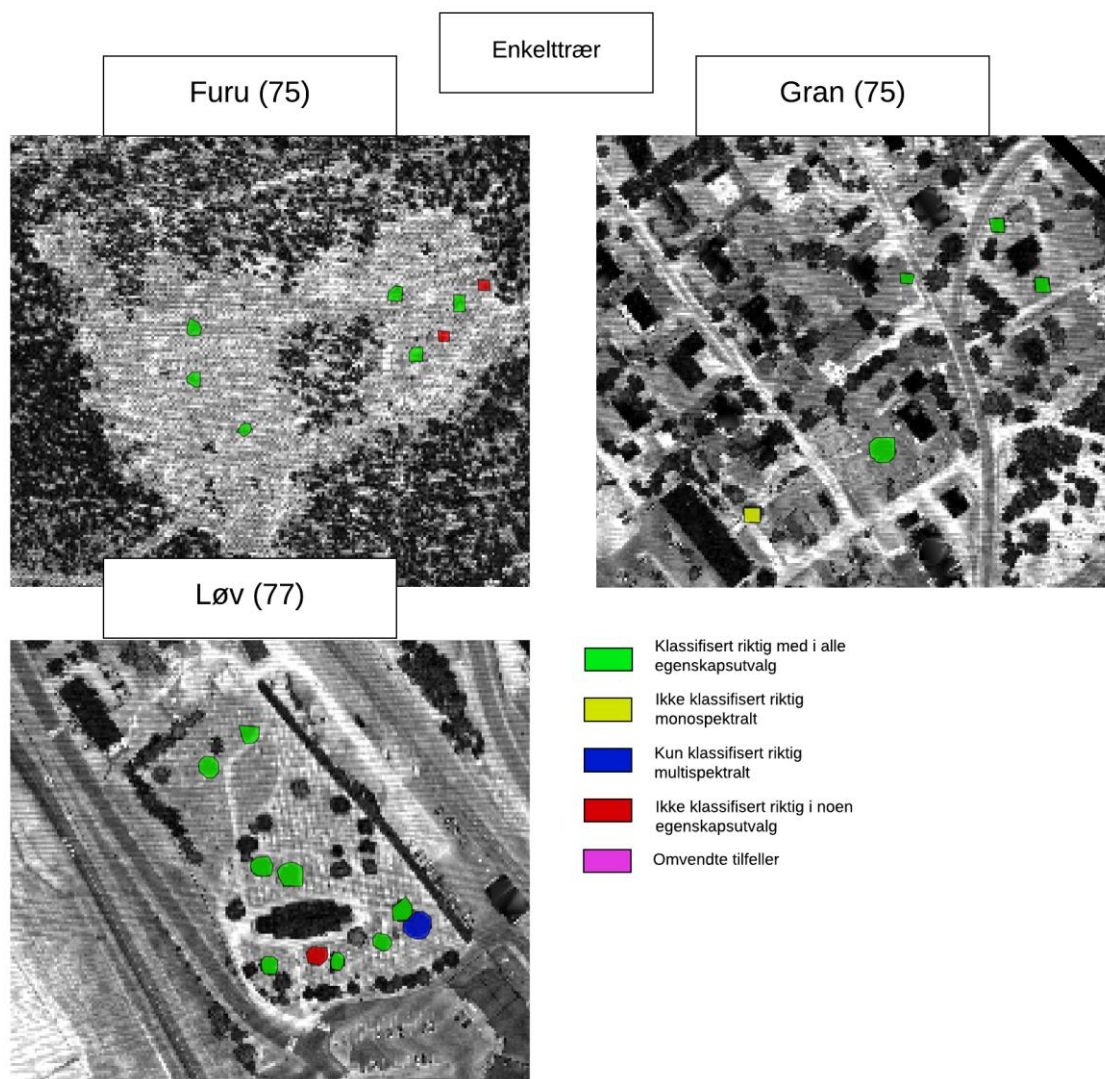
Tabell 7.24 Eksempel på klassifisert polygon i tabellformat.

Av dette produseres en visualisering av de klassifiserte polygonene. Først med faktisk klasse, deretter predikert klasse. Til slutt blir polygonene fremstilt basert på hvilke egenskapsutvalg som har vært i stand til å klassifisere den. Om overflaten kunne klassifiseres riktig med både mono-, dual- og multispektrale egenskaper, blir overflaten farget grønn, om den kunne klassifiseres riktig dual- og multispektralt blir overflaten farget gul. Om overflaten bare kunne

klassifiseres riktig multispektralt blir den farget blå. Overflater som ikke lot seg klassifisere riktig ble farget rødt. Om noen overflater skulle klassifiseres riktig monospektralt, men ikke multispektralt, blir overflaten farget lilla. Forskjellige utsnitt av visualiseringen vises under:



Figur 7.17: Polygonvisualisering for primær- og sekundærklassene.



Figur 7.18: Polygonvisualisering for enkeltrær.

Det er de blå polygonene som er mest interessante her. Disse overflatene og objektene har klassifiseringsmetoden greid å klassifisere kun i tilfeller med multispektrale egenskaper. I de aktuelle utsnittene er det få av disse blå polygonene. Mange forbedringer skjer i overgangen fra monospektral til dualspektral klassifisering (gule polygoner). For primærklassene og tresortene blir de fleste polygoner klassifiseres riktig med monospektral klassifisering. For sekundærklasser er det større uregelmessighet. Her er også mange av polygonene feilklassifisert i alle tilfeller.

7.3 Helhetlig vurdering

I denne oppgaven har spektralverdier og klassifiseringsresultater blitt brukt til å finne hvilke tilleggsverdier Optech Titan har med sine tre laserkanaler. Dette er en helhetlig vurdering av arbeidet gjort i kapittel 6 og 7 for å finne de multispektrale tilleggsverdiene Optech Titan tilbyr.

Primærklasser kan skilles med god nøyaktighet ved multispektral klassifisering, kontra monospektral klassifisering. Nyansene innad i hver primærklasse (sekundærklassene), har noe mer støy og får lavere nøyaktighet enn primærklassene. Dette er naturlig, da det ikke forventes at multispektrale egenskaper skal kunne gi en perfekt gjengivelse av omgivelsene. Disse forbedres også fra monospektral klassifisering. Tresortene klassifiseres også med lavere nøyaktighet enn primærklassene, og forbedres ikke så mye fra monospektral klassifisering. Det skal sies at andre måter å klassifisere dataene på kan kanskje utnytte det multispektrale potensialet ytterligere. En relativ intensitetskalibrering vil kunne danne klarere skiller mellom verdiene fra hver kanal, der verdiene i nåværende datasett blandes i stor grad. En absolutt intensitetskalibrering vil også kunne gjøre multispektrale laserdata verdige til å brukes på linje med multispektrale bilder. Eller kanskje enda bedre (les kapittel 3.3). I motsetning til de avvikende spektralkurvene hentet direkte fra intensitetsverdiene (les kapittel 7.2.3). Utfordringen er å automatisere en slik kalibrering. Dette kan raskt bli en tidkrevende prosess. Derfor skal det argumenteres for at metoden tenkt i denne oppgaven, er relativt rask, og automatiserbar. I forhold til tidligere tilsvarende studier (Morsy et al. 2016; Wichmann et al. 2015; Yu et al. 2017), har også datasettet brukt i denne oppgaven en mye høyere flyhøyde. I kapittel 6 ble kapasitet i forhold til flyhøyde vurdert, og resultatet (les kapittel 6.3) viste at det er først ved høyere flyvninger at pulser ikke returneres. Noe som både fører til lavere og mindre pålitelige intensitetsverdier, samt overflater med manglende informasjon. Klassifiseringer på denne høyden, til tross for et svakere datagrunnlag, gir fortsatt bedre resultater ved multispektral klassifisering. Altså er ikke kvalitetsbetingelser som intensitetskalibrering og fullstendige data nødvendig for at multispektrale egenskaper skal forbedre resultatet. Selv om det antakelig hadde blitt enda bedre med et bedre datagrunnlag. De tilleggsverdier som da er funnet i denne oppgaven, vil også være aktuelle ved datasett med bedre datagrunnlag.

For enkelttre-klassifisering er lavere flyhøyder en større nødvendighet. En flyhøyde på 1900 m gir ugunstig få verdier for trær (les kapittel 6.3). Dette gjelder da også skog. De verdier som returneres har lave intensitetsverdier med mye variasjon. Tilleggsverdien i multispektrale egenskaper er lav, da forskjellen på resultatene fra enkelttreklassifiseringene er små (kappa differanse = 0,04). Det ser ut til at høyderelaterte egenskaper har langt større innvirkning enn

intensitetsverdier på så høye flygninger. Med lavere flygninger, og intensitetskalibrering, kan Optech Titan ha tilleggsverdi også til klassifisering av tresorter. Som studert av Yu (Yu et al. 2017).

Etter å ha klassifisert med forskjellige egenskapsutvalg, har den noe manglende tilleggsverdien i G-kanalen blitt oppdaget. I alle klassifiseringene bortsett fra enkelttrær, øker nøyaktigheten betraktelig mye mer fra mono- til dualspektral klassifisering. Det ser ut til at MIR- og NIR-kanalene sammen kan predikere de fleste overflater. Kanskje holder dette til de fleste klassifiseringsformål. Tidligere forskning har resultert i nøyaktige klassifiseringer, på hele 97,4% (kappa = 0,966) (Wang et al. 2014), med NIR- og MIR-kanalene. De er har også nytteverdi innen arkeologi (Briese et al. 2013). Les mer om dette i kapittel 3.5. Lave intensitetsverdier, og få returverdier fra G-kanalen, gjør den antakelig mindre synlig i klassifiseringsgrunnlaget. Dette er noe en intensitetskalibrering kunne forbedret, men de manglende returverdiene er vanskelig å få gjort noe med. Kanskje kunne en annen laserkanal blitt brukt, på rundt 700 nm, i overgangen fra gul til rød. Dette hadde gitt mulighet for større energimengde pr. puls, og dermed også sterkere returer. Nærmere 2000 nm er det også en del forskjellige spektrale karaktertrekk i ulike overflater (se Figur 4.5). Resultatene i oppgaven viser helt klart forbedringer fra mono- til multispektral klassifisering, men datasettet kan være i minste laget til å verifisere sikkerhet i statistikken. I et konseptuelt produkt, som beskrevet i metodekapittel 5.2.3, ville langt flere polygoner blitt brukt til å vurdere tilleggsverdi. Dette kunne gitt mer håndfaste tall på hvilke overflater som faktisk er mulig å skille fra hverandre med multispektrale egenskaper. Når kun én verdi er det som skiller en klassifisering fra en annen, er det ikke sikkert om dette er tilfeldig, eller knyttet til nøyaktigheten på klassifiseringen. Likevel holder det i de fleste sammenhenger til å avgjøre forbedring i klassifiseringene, selv om prosent-tallene kan virke overdrevet. Det skal presiseres at målet i oppgaven er å finne tilleggsverdi, og ikke absolutte tall. Videre arbeid med denne oppgaven vil innebære å korrigere slike feilgrep for å kunne realisere det konseptuelle produktet. Der klassifisering av multispektrale data fra Optech Titan kunne blitt gjort effektivt og med høy nøyaktighet. For å få til dette er det flere ting som kunne blitt gjort annerledes. En mer konsekvent og materialrettet klasseinndeling ville gjort oppgaven mer ryddig, samtidig som fasitklassene for polygoner ved oppretting av treningsdatasett ville vært mer objektivt valgt. Også egenskapsutvalgene som definerer multi-, dual-, og monospektrale klassifiseringsgrunnlag, ble satt opp slik at utvalget tredoblet seg for hvert nivå av spektralinformasjon. Langt flere attributter ble dermed brukt for å klassifisere i multispektral klassifisering. Dette kunne vært løst med mer jevne utvalg, kun

basert på mest egnede egenskaper for hver klassifisering. På en annen side ble det gjort flere tester som tyder på at resultatet i oppgaven ikke påvirkes av dette (beskrives i kapittel 7.1.7). Når det gjelder klassifiseringen, ville en optimal klassifisering blitt gjort direkte i punktskyen. Der nabo-forholdet mellom punkter i tre dimensjoner kunne blitt analysert uten konvertering og generalisering av data. I Terrascan har det nylig blitt utviklet en funksjon kalt «classify by groups» som skal kunne se på slike forhold direkte i punktskyen, og klassifisere ut ifra dette. Det kan være gunstig å bruke multispektrale data fra Optech titan i en slik sammenheng. Dette er ikke en del av det konseptuelle produktet, men ville om realiserbart, kunne forbedre klassifiseringen ytterligere.

I en helhetlig vurdering av Optech Titan, er det funnet både begrensninger og tilleggsverdier i systemet. Begrensninger i form av at skanneren ikke registrerer alle punkter i skogområder ved flygninger over 800 m for G-kanal og 1200 m for MIR- og NIR-kanal. Samt at NIR- og G-kanal faller ut på ulike hustak- og vegetasjonsoverflater. Noe som fører til reduksjon av kvalitet på dataene som skal brukes til klassifisering. Multispektrale egenskaper ser ikke ut til å ha stor innvirkning på vann og skog, og for flere klasser gjør dualspektral klassifisering en nesten like god jobb. Det som Optech Titan, med sitt multispektrale lasersystem gjør bra, og som påfører tilleggsverdi til tradisjonell laserskanning, er å forstå forskjeller i overflater med ulik spektral karakter. Med sine tre kanaler, blir tallverdier og statistikk for noe som kan minne om falske farger, et utgangspunkt for å skille en rekke overflatetyper fra hverandre. Disse er overflater som ikke kan skilles geometrisk, da det er de spektrale forskjellene som er annerledes, og geometrien lik. Monospektralt kan noe i disse overflatene skilles, dualspektralt kan mere skilles, og multispektralt kan de fleste overflater skilles. Dette til tross for ukalibrerte og varierende verdier innad i klassene, ettersom den relative forskjellen mellom hver kanal blir tilnærmet lik for målinger av samme arealtype. De arealtype som Optech Titan var i stand til å skille fra hverandre i denne oppgaven, som monospektralt ikke lot seg skille i like stor grad, og som definerer tilleggsverdien i skanneren, er gress, mark, grus, asfalt, hustak og jorder. Mark og hustak kunne også skilles ytterligere, inn i flere sekundærklasser, ved hjelp av multispektrale egenskaper. Dette tyder på at det finnes et stort potensiale for multispektrale laserskannere i fremtiden. Å kunne klassifisere de samme overflatene i en punktsky som i et bilde, gir mange fordeler for bl.a. kvalitet og effektivitet i produksjonssammenheng. Optech Titan kan sies å være et steg i denne retningen.

8 Konklusjon

I oppgavens innledning ble Optech Titan presentert som en flybåren laserskanner med evnen til å klassifisere objekter og overflater basert på spektrale data (kapittel 3.1). Som den første laserskanneren til å kombinere de geometriske fordelene ved LiDAR, med de spektrale egenskapene fra billedata, åpnet Optech Titan opp for helt nye klassifiseringsmuligheter i et integrert system. Tre laserkanaler med ulike bølgelengder produserte hver sin punktsky. Herifra ble det opp til brukeren å utnytte potensialet. Flere studier ble gjort på å utnytte denne kombinasjonen til ulike klassifiseringer (kapittel 3.5). I denne oppgaven ble tilleggsverdiene av disse multispektrale egenskapene forsøkt belyst. Overflater og objekter ble forsøkt klassifisert, med forskjellige spektrale forutsetninger. Deretter ble klassifiseringsresultatene sammenlignet. En metode ble utviklet, med fokus på selve klassifiseringen (kapittel 5.2.2). Denne ble knyttet opp mot et konseptuelt produkt for effektivisering og forbedring (kapittel 5.2.3). Ulike klassifiseringsmetoder, inkludert Random Forest og SVM ble brukt. Tilleggsverdiene som er funnet, ligger i Optech Titans evne til å skille overflater fra hverandre, som i utgangspunktet ser like ut ved geometrisk og monospektral analyse. Typiske overflater som gress, mark, grus, asfalt, jorder, skog og vann kunne med multispektrale egenskaper klassifiseres med 82,2% nøyaktighet ($\kappa = 0,80$), i motsetning til 75,4% ($\kappa = 0,69$) med monospektrale egenskaper. Mer nyanserte overflater innad i hver klasse, som bl.a. plen, slitt gress, lys/mørk asfalt, lyse/mørke/orange hustak, og ulike markoverflater kunne samlet klassifiseres multispektralt med 73,0% ($\kappa = 0,71$), mot 62,7% ($\kappa = 0,59$) monospektralt. Enkeltrær av de forskjellige tresortene furu, gran og løv, kunne klassifiseres multispektralt med 82,3% nøyaktighet ($\kappa = 0,74$), mot 79,0% ($\kappa = 0,7$) monospektralt.

Dette tyder på at Optech Titan er i stand til å forbedre den tradisjonelle klassifiseringsmetoden, der geometri står sentral. Flere av de tradisjonelle klasseinndelingene vil kunne spesifiseres ytterligere, med informasjon om materiell opprinnelse. Arbeidsoppgaver som før har vært knyttet til flybilder, kan nå også gjøres med laserskanning. Selv på en flyhøyde der flere av laserpulsene fra LiDAR-systemet ikke returneres, og intensitetsverdiene forblir ukalibrerte, er forbedringer oppdaget. Dualspektral klassifisering med kortbølge- og nærinfrarød kanal ser ut til å nesten være like nøyaktig som multispektral klassifisering i flere sammenhenger ($\kappa = 0,78$ for primærklasser). Et dualspektralt system ville også kunne gi gode tilleggsverdier til tradisjonell laserskanning. Grønn laser kan enten optimaliseres eller byttes mot en annen bølgelengde. Formål knyttet til skog- og enkeltrær vil også være avhengig av lavere flygninger og intensitetskalibrering for å utnytte de multispektrale dataene. Dette fordi energimengden i

de splittede laserpulsene ser ut til å være for svake til å gi et godt nok datagrunnlag for klassifisering. Oppdagelsene gjort i denne oppgaven kan dermed brukes til å konkludere med at Optech Titan har åpnet dører og beveger seg mot en symbiose mellom laserdata og spektralinformasjon. Tidligere kun tilgjengelig som separate systemer. Mye må forbedres før pålitelige og konsistente data effektivt kan oppdrives fra en multispektral laserskanner. Optech Titan har bevist at en slik kombinasjon fungerer, og viser vei for videre utvikling.

I en fremtidig multispektral laserskanner burde de spektrale verdiene være tilnærmet like pålitelige som de geometriske. Videre utvikling burde innebære å inkludere en relativ intensitetskalibrering (les kapittel 4.2), i selve lasersystemet. Flere studier gjort på Optech Titan har konkludert med at det finnes et forbedringspotensial i intensitetsverdiene (Thomas 2015; Wichmann et al. 2015). Dette involverer bl.a. en returnnummer-normalisering for splittede pulser. Intensitetsverdiene vil da på sikt kunne sammenlignes mer med multispektrale bilder. Samtidige målinger mellom sensorene vil effektivisere og automatisere klassifiseringsprosessen i stor grad, da intensitetsverdiene i punktskyene ikke ville være avhengig av å kobles sammen av brukeren (Wichmann et al. 2015). Dette kan f.eks. løses ved å vinkle alle kanaler i den multispektrale laserskanneren i samme retning. Videre kan bedre algoritmer for klassifisering i tre dimensjoner utvikles. Enten ved å ta klassifiseringen fra piksel- til voxel-nivå, eller ved å utnytte funksjoner som «classify by group» i Terrascan. Slik kan multispektral laserskanning nå sitt fulle potensial, der både geometri og eksakte intensitetsverdier utnyttes.

9 Referanseliste

- Abbaker, A. A. (1995). *The Semiclassical Laser Theory And Some Applications Of Laser*. Master Thesis. Sudan: University Of Khartoum, Physics Department Faculty of Science. 83 s.
- Ahokas, E., Hyyppä, J., Yu, X., Liang, X., Matikainen, L., Karila, K., Litkey, P., Kukko, A., Jaakkola, A., Kaartinen, H., et al. (2016). Towards Automatic Single-Sensor Mapping by Multispectral Airborne Laser Scanning. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B3 (XXIII): 155-162.
- Arealtype. (2017). NIBIO. Tilgjengelig fra: http://www.skogoglandskap.no/kart/temakart_arealressursklasser/map_view (lest 09.05.2017).
- Bakuła, K. (2015). Multispectral airborne laser scanning - a new trend in the development of LiDAR technology. *Archiwum Fotogrametrii, Kartografii i Teledetekcji*, 27: 25-44.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45 (1): 5-32.
- Brennan, R. & Webster, T. L. (2006). Object-oriented land cover classification of lidar-derived surfaces. *Canadian Journal of Remote Sensing*, 32 (2): 162-172.
- Briese, C., Pfennigbauer, M., Ullrich, A. & Doneus, M. (2013). Multi-Wavelength Airbourne Laser Scanning For Archaeological Prospection. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XL-5/W2 (XXIV): 119-124.
- ESRI. (1998). ESRI Shapefile Technical Description: Environmental Systems Research Institute. 34 s.
- Geocue, G. S. (2016). *Nominal Pulse Spacing (NPS)*: GeoCue Group. Tilgjengelig fra: <http://support.geocue.com/nominal-pulse-spacing/> (lest 20.04.2017).
- Gnanadesikan, R. (2011). *Methods for Statistical Data Analysis of Multivariate Observations*. Google Books: Wiley. 384 s.
- Hair, J. F. (2006). *Multivariate data analysis*. 6 utg. Upper Saddle River, NJ [etc.]: Pearson Prentice Hall. 899 s.
- Isenburg, M. (2014). *Density and Spacing of LiDAR*: Rapidlasso. Tilgjengelig fra: <https://rapidlasso.com/2014/03/20/density-and-spacing-of-lidar/> (lest 22.03.2017).
- Isenburg, M. (2017). *LAStools*: Rapidlasso.
- Kartverket. (2017). *Kartkatalogen*. Geonorge.no: Kartverket. Tilgjengelig fra: <https://kartkatalog.geonorge.no/search> (lest 05.05.2017).
- Kotthaus, S., Smith, T. E. L., Wooster, M. J. & Grimmond, C. S. B. (2014). Derivation of an urban materials spectral library through emittance and reflectance spectroscopy. *ISPRS Journal of Photogrammetry and Remote Sensing*, 94: 194-212.
- LASer (LAS) File Format Exchange Activities*. (2008). ASPRS Organization: ASPRS The Imaging & Geospatial Information Society Tilgjengelig fra: <https://www.asprs.org/committee-general/laser-las-file-format-exchange-activities.html> (lest 04.05.2017).
- Light Absorption, Reflection, and Transmission*. (2016). The Physics Classroom. Tilgjengelig fra: <http://www.physicsclassroom.com/class/light/Lesson-2/Light-Absorption,-Reflection,-and-Transmission> (lest 12.03.2017).
- Mahammad, S. S. & Ramakrishnan, R. (2003). GeoTIFF-A standard image file format for GIS applications. *Map India*: 28-31.
- Matikainen, L., Hyyppä, J. & Litkey, P. (2016). Multispectral Airborne Laser Scanning for Automated Map Updating. *ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XLI-B3 (XXIII): 323-330.
- McCaffrey, J. (2015). *Model Overfitting [JPEG]*. Microsoft Developer Network: Microsoft. Tilgjengelig fra: <https://msdn.microsoft.com/en-us/magazine/dn904675.aspx> (lest 05.05.2017).
- Morsy, S., Shaker, A., El-Rabbany, A. & LaRocque, P. E. (2016). Airborne Multispectral LIDAR Data for Land-Cover Classification and Land/water Mapping Using Different Spectral Indexes. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, III-3 (XXIII): 217-224.

- Naus, T. (2010). Unbiased LiDAR Data Measurement (Draft) 25.
- Optech, T. (2015). *Optech Titan Multispectral LiDAR System: High Precision Environmental Mapping* [Brosjyre]. Tilgjengelig fra: <https://www.teledyneoptech.com/wp-content/uploads/Titan-Specsheet-150515-WEB.pdf> (lest 05.05.2017).
- Optech, T. (2016). *Optech Flight Management Suite*: Teledyne Optech.
- Orange. (2017). *Orange 3.3.11* utg. <https://orange.biolab.si/download/>: Orange Team.
- Pfennigbauer, M. & Ullrich, A. (2011). Multi-Wavelength Airborne Laser Scanning. *Proceedings of the International Lidar Mapping Forum*: 10.
- PhotoMachining.com. (2015). *How Laser Works | Laser Micromachining | Lasers in Industry | Picosecond Lasers | Ultrafast Lasers*: PhotoMachining.com. Tilgjengelig fra: <https://www.youtube.com/watch?v=cJgViCkzg8o> (lest 11.03.2017).
- Random Forest based Classification*. (2016). [Video]. Youtube.com: Be Expert in Minutes. Tilgjengelig fra: <https://www.youtube.com/watch?v=ajTc5y3OqSQ>.
- Shafranovich, Y. (2005). *Common format and MIME type for comma-separated values (CSV) files*. <https://tools.ietf.org/html/rfc4180>: SolidMatrix Technologies, Inc. Tilgjengelig fra: <https://tools.ietf.org/html/rfc4180> (lest 07.05.2017).
- Shapley, P. (2012). *Light and the Electromagnetic Spectrum* [JPEG]: Patrica Shapley Tilgjengelig fra: <http://butane.chem.uiuc.edu/pshapley/GenChem2/A3/3.html> (lest 05.05.2017).
- Sherman, G. (2017). *QGIS. 2.18.2* utg.: QGIS.
- Sitar, M., M.E.S & B.SC. (2015). Beyond 3D: Multispectral Optech Titan Opens New Applications for Lidar. *Lidar news* 5(1): 6.
- Song, J. H. (2002). Assessing the possibility of land-cover classification using lidar intensity data. *International archives of the photogrammetry, remote sensing and spatial information sciences.*, 34 (3/b): 259-262.
- Spruyt, V. (2014). *The Curse of Dimensionality in classification: Computer vision for dummies*. Tilgjengelig fra: <http://www.visiondummy.com/2014/04/curse-dimensionality-affect-classification/> (lest 05.04.2017).
- Suykens, J. A. K. & Vandewalle, J. (1999). Least Squares Support Vector Machine Classifiers. *Neural Processing Letters*, 9 (3): 293-300.
- Thomas, J. J. C. (2015). *Terrain classification using multi-wavelength LiDAR data*. Master Thesis. Monterey: Naval Postgraduate School, United States Naval Academy. 85 s.
- Viera, A. J. & Garrett, J. M. (2005). Understanding interobserver agreement: the kappa statistic. *Family medicine*, 37 (5): 360-363.
- Vosselman, G. & Maas, H.-G. (2010). *Airborne and Terrestrial Laser Scanning*. NMBU: Whittles Publishing. 313 s.
- Været som var: Rakkestad flyplass, Åstorp*. (2016). Yr.no. Tilgjengelig fra: https://www.yr.no/sted/Norge/%C3%98stfold/Rakkestad/Rakkestad_flyplass,%C3%85storp/almanakk.html?dato=2016-10-28 (lest 05.05.2017).
- Wang, C.-K., Tseng, Y.-H. & Chu, H.-J. (2014). Airborne Dual-Wavelength LiDAR Data for Classifying Land Cover. *Remote Sensing*, 6 (1): 700-715.
- Weitkamp, C. (2006). *Lidar: Range-Resolved Optical Remote Sensing of the Atmosphere*. Springer Series in Optical Sciences, b. 102: Springer-Verlag New York. 456 s.
- Wichmann, V., Bremer, M., Lindenberger, J., Rutzinger, M., Georges, C. & Petrini-Monteferrri, F. (2015). Evaluating the Potential of Multispectral Airborne LIDAR for Topographic Mapping and Land Cover Classification. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3/W5: 113-119.
- Wickersham, J. (2016). *What Determines the Wavelength of a Laser?* [Blog]: escooptics.com. Tilgjengelig fra: <https://escooptics.com/blogs/news/84277891-what-determines-the-wavelength-of-a-laser> (lest 12.03.2017).
- 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.

10 Vedlegg

Vedlegg 1:

meter over terreng:		2000	1600	1200	800	400
Gress	1550 nm	1742	2799	4596	4092	16486
	1064 nm	1811	2655	4524	4216	16560
	532 nm	5	2557	4601	3975	16508
	Totalt	3558	8011	13721	12283	49554
Asfalt	1550 nm	313	585	910	868	3732
	1064 nm	0	186	953	871	3544
	532 nm	5	581	964	861	3551
	Totalt	318	1352	2827	2600	10827
Hustak	1550 nm	255	336	569	499	2081
	1064 nm	224	346	617	530	1998
	532 nm	224	346	547	516	2086
	Totalt	703	1028	1733	1545	6165
Jord	1550 nm	3631	6782	11088	10 338	38589
	1064 nm	662	6845	10990	10348	39609
	532 nm	121	6679	11285	10165	39303
	Totalt	4414	20306	33363	30851	117501
Skog	1550 nm	13	159	918	1537	6073
	1064 nm	0	54	947	1644	6291
	532 nm	0	0	0	373	6227
	Totalt	13	213	1865	3554	18591

Vedlegg 2:

```

: create ch_1
lascanopy -i %LAZ_INPUT%*.laz ^
-merged ^
-keep_user_data 1 ^
-lop "%SHP_INPUT%\polygoner.shp" ^
-height_cutoff 0 ^
-all -min -max -avg -std -ske -kur -qav ^
-p 1 5 10 25 50 75 90 95 99 ^
-b 10 20 30 40 50 60 70 80 90 ^
-int_min -int_max -int_avg -int_std -int_ske -int_kur -int_qav ^
-int_p 1 5 10 25 50 75 90 95 99 ^
-o "%CSV_OUTPUT%\ch_1i.csv"

: create ch_2
lascanopy -i %LAZ_INPUT%*.laz ^
-merged ^

```

```

-keep_user_data 2 ^
-lop "%SHP_INPUT%\polygoner.shp" ^
-height_cutoff 0 ^
-all -min -max -avg -std -ske -kur -qav ^
-p 1 5 10 25 50 75 90 95 99 ^
-b 10 20 30 40 50 60 70 80 90 ^
-int_min -int_max -int_avg -int_std -int_ske -int_kur -int_qav ^
-int_p 1 5 10 25 50 75 90 95 99 ^
-o "%CSV_OUTPUT%\ch_2i.csv"

: create ch_3
lascanopy -i %LAZ_INPUT%\*.laz ^
-merged ^
-keep_user_data 3 ^
-lop "%SHP_INPUT%\polygoner.shp" ^
-height_cutoff 0 ^
-all -min -max -avg -std -ske -kur -qav ^
-p 1 5 10 25 50 75 90 95 99 ^
-b 10 20 30 40 50 60 70 80 90 ^
-int_min -int_max -int_avg -int_std -int_ske -int_kur -int_qav ^
-int_p 1 5 10 25 50 75 90 95 99 ^
-o "%CSV_OUTPUT%\ch_3i.csv"

@echo off
cls
setlocal
echo
index_ch1,min_x_ch1,min_y_ch1,max_x_ch1,max_y_ch1,all_ch1,min_ch1,max_ch1,avg_ch1
,qav_ch1,std_ch1,ske_ch1,kur_ch1,p01_ch1,p05_ch1,p10_ch1,p25_ch1,p50_ch1,p75_ch1,
p90_ch1,p95_ch1,p99_ch1,b10_ch1,b20_ch1,b30_ch1,b40_ch1,b50_ch1,b60_ch1,b70_ch1,b
80_ch1,b90_ch1,int_min_ch1,int_max_ch1,int_avg_ch1,int_qav_ch1,int_std_ch1,int_sk
e_ch1,int_kur_ch1,int_p01_ch1,int_p05_ch1,int_p10_ch1,int_p25_ch1,int_p50_ch1,int
_p75_ch1,int_p90_ch1,int_p95_ch1,int_p99_ch1>ch_1.csv
more ch_1i.csv>>ch_1.csv
type ch_1.csv
@echo off
cls
setlocal
echo
index_ch2,min_x_ch2,min_y_ch2,max_x_ch2,max_y_ch2,all_ch2,min_ch2,max_ch2,avg_ch2
,qav_ch2,std_ch2,ske_ch2,kur_ch2,p01_ch2,p05_ch2,p10_ch2,p25_ch2,p50_ch2,p75_ch2,
p90_ch2,p95_ch2,p99_ch2,b10_ch2,b20_ch2,b30_ch2,b40_ch2,b50_ch2,b60_ch2,b70_ch2,b
80_ch2,b90_ch2,int_min_ch2,int_max_ch2,int_avg_ch2,int_qav_ch2,int_std_ch2,int_sk
e_ch2,int_kur_ch2,int_p01_ch2,int_p05_ch2,int_p10_ch2,int_p25_ch2,int_p50_ch2,int
_p75_ch2,int_p90_ch2,int_p95_ch2,int_p99_ch2>ch_2.csv

```

```

more ch_2i.csv>>ch_2.csv
type ch_2.csv
@echo off
cls
setlocal
echo
index_ch3,min_x_ch3,min_y_ch3,max_x_ch3,max_y_ch3,all_ch3,min_ch3,max_ch3,avg_ch3
,qav_ch3,std_ch3,ske_ch3,kur_ch3,p01_ch3,p05_ch3,p10_ch3,p25_ch3,p50_ch3,p75_ch3,
p90_ch3,p95_ch3,p99_ch3,b10_ch3,b20_ch3,b30_ch3,b40_ch3,b50_ch3,b60_ch3,b70_ch3,b
80_ch3,b90_ch3,int_min_ch3,int_max_ch3,int_avg_ch3,int_qav_ch3,int_std_ch3,int_sk
e_ch3,int_kur_ch3,int_p01_ch3,int_p05_ch3,int_p10_ch3,int_p25_ch3,int_p50_ch3,int
_p75_ch3,int_p90_ch3,int_p95_ch3,int_p99_ch3>ch_3.csv
more ch_3i.csv>>ch_3.csv
type ch_3.csv
del "ch_1i.csv"
del "ch_2i.csv"
del "ch_3i.csv"

```

Vedlegg 3:

Faktisk/Predikert	11	12.0	13.0	21.0	22.0	31.0	32.0	41.0	42.0	51.0	52.0	53.0	61.0	62.0	71.0	75.0	76.0	77.0	91.0	Σ
11.0	22	1	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	25
12.0	6	4	1	1	5	0	0	0	0	0	0	0	2	6	0	0	0	0	0	25
13.0	1	1	13	1	2	0	1	0	0	0	0	0	4	0	0	0	0	0	0	23
21.0	0	1	2	15	5	0	0	0	0	0	0	0	0	0	2	0	0	0	0	25
22.0	0	1	1	3	17	2	0	0	0	0	0	0	0	1	0	0	0	0	0	25
31.0	0	0	0	0	1	20	3	0	0	0	0	0	0	0	0	0	0	0	0	25
32.0	0	0	1	0	0	2	18	0	3	0	0	0	1	0	0	0	0	0	0	25
41.0	0	0	0	0	0	0	0	21	3	0	0	0	0	0	0	0	0	0	0	25
42.0	0	0	0	1	0	0	2	6	15	0	0	0	0	0	0	0	0	0	0	24
51.0	0	0	0	1	0	0	0	0	0	12	1	5	0	0	0	0	1	0	1	21
52.0	0	0	0	0	0	0	0	0	0	3	20	1	0	0	0	0	0	0	1	25
53.0	0	0	0	0	0	0	0	0	0	2	1	21	0	0	0	0	0	0	1	25
61.0	1	3	1	0	0	1	0	0	0	0	0	0	13	6	0	0	0	0	0	25
62.0	0	4	2	0	0	0	1	0	0	0	0	0	5	13	0	0	0	0	0	25
71.0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	23	0	1	0	0	25
75.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24	1	0	0	25
76.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	25
77.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	3	19	0	25
91.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24	24
Σ	30	15	22	23	30	25	25	27	21	17	22	27	25	27	26	26	31	21	27	467

Vedlegg 4:

Faktisk/Predikert	11.0	12.0	13.0	21.0	22.0	31.0	32.0	41.0	42.0	51.0	52.0	53.0	61.0	62.0	71.0	75.0	76.0	77.0	91.0	Σ
-------------------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	------	---

11.0	22	0	2	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	25
12.0	4	8	2	0	7	0	0	0	0	0	0	0	0	1	3	0	0	0	0	25
13.0	1	0	13	1	4	0	3	0	1	0	0	0	0	0	0	0	0	0	0	23
21.0	0	0	2	16	6	0	0	0	0	0	0	0	0	0	1	0	0	0	0	25
22.0	0	4	0	4	15	2	0	0	0	0	0	0	0	0	0	0	0	0	0	25
31.0	0	0	0	0	1	21	2	0	0	0	0	0	0	0	0	0	0	0	0	25
32.0	0	0	0	0	0	3	19	0	3	0	0	0	0	0	0	0	0	0	0	25
41.0	0	0	0	0	0	1	0	21	2	0	0	0	0	0	0	0	0	0	0	25
42.0	0	0	0	1	0	0	1	6	16	0	0	0	0	0	0	0	0	0	0	24
51.0	0	0	0	1	0	0	0	0	0	14	1	2	0	0	0	0	2	0	1	21
52.0	0	0	0	0	0	0	0	0	0	3	17	5	0	0	0	0	0	0	0	25
53.0	0	0	0	0	0	0	0	0	0	3	8	13	0	0	0	0	0	1	0	25
61.0	0	2	0	0	2	0	2	0	1	0	0	0	13	5	0	0	0	0	0	25
62.0	0	3	5	0	0	0	3	0	1	0	0	0	4	9	0	0	0	0	0	25
71.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24	0	1	0	0	25
72.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	0	25
76.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	25
77.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	2	3	19	0	25
91.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24	24
Σ	27	17	24	23	35	27	30	27	24	20	26	20	18	18	26	27	31	20	27	46 7

Vedlegg 5:

Faktisk/predikert	11.0	12.0	13.0	21.0	22.0	31.0	32.0	41.0	42.0	51.0	52.0	53.0	61.0	62.0	71.0	75.0	76.0	77.0	91.0	Σ
11.0	18	2	0	0	0	0	0	0	3	0	0	0	2	0	0	0	0	0	0	25
12.0	4	7	1	2	4	0	1	1	1	0	0	0	2	2	0	0	0	0	0	25
13.0	0	2	11	0	2	0	7	0	1	0	0	0	0	0	0	0	0	0	0	23
21.0	0	0	2	13	8	0	0	0	0	0	0	0	0	0	1	0	1	0	0	25
22.0	0	4	0	3	16	2	0	0	0	0	0	0	0	0	0	0	0	0	0	25
31.0	0	0	0	0	2	20	2	0	0	0	0	0	0	0	0	0	0	0	1	25
32.0	1	1	5	1	0	2	12	0	1	0	0	0	0	2	0	0	0	0	0	25
41.0	0	0	0	0	1	0	0	20	3	0	0	0	0	0	0	0	0	0	1	25
42.0	2	0	0	1	0	0	1	7	11	0	0	0	0	2	0	0	0	0	0	24
51.0	0	0	0	0	0	0	0	1	0	12	0	4	0	0	0	0	1	1	2	21
52.0	0	0	0	1	0	0	0	0	0	1	17	6	0	0	0	0	0	0	0	25
53.0	0	0	0	0	0	0	0	0	0	6	8	9	0	0	0	0	0	2	0	25
61.0	4	1	1	0	1	1	0	0	0	0	0	0	11	6	0	0	0	0	0	25
62.0	0	3	3	0	1	0	3	3	0	0	0	0	4	8	0	0	0	0	0	25
71.0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	21	1	1	1	0	25
75.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	25	0	0	0	25
76.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	21	2	0	25
77.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	4	19	0	25
91.0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24	24
Σ	29	20	23	22	35	25	26	32	20	19	25	19	19	20	23	29	28	25	28	46 7



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

Postboks 5003
NO-1432 Ås
Norway