

PROSJEKTRAPPORT

KONSULENTBISTAND TIL TESTING OG METODIKKUTVIKLING FOR KARTLEGGING AV NATURTYPER OG BESKRIVELSESVARIABLER VED BRUK AV FJERNMÅLING

For levering til
Miljødirektoratet



Tittel:

Konsulentbistand til testing og metodikkutvikling for kartlegging av naturtyper og beskrivelsesvariabler ved bruk av fjernmåling

Forfatter(e):

Floris Groesz / Blom Norway AS

Dato:

29.06.2018

Prosjektnummer:

2137

Oppdragsgiver:

Miljødirektoratet

Kontaktperson:

Ellen Arneberg

FORORD

Denne rapporten er resultatet av prosjektet «Konsulentbistand til testing og metodikkutvikling for kartlegging av naturtyper og beskrivelsesvariabler ved bruk av fjernmåling», i oppdrag av Miljødirektoratet, Miljødataseksjonen med Ellen Arneberg som kontaktperson.

Prosjektet ble gjort i samarbeid med Norges miljø- og biovitenskapelige universitet, Fakultet for miljøvitenskap og naturforvaltning. Hans Ole Ørka har bistått med metodevalg på klassifisering, råd om tolkning av resultatene og kommentarer på rapporten.

SAMMENDRAG

Romlige analyser av utbredelse, samt endringer av naturtyper og naturegenskaper ved hjelp av fjernmåling har blitt et stort og fortsatt voksende forskningsfelt, både i Norge og internasjonalt. Miljødirektoratet ønsket å videreutvikle metodikker til å gi informasjon om naturtyper som kystlynghei, gjengroing av semi-naturlige systemer og enkeltobjekter som store gamle eiker. I prosjektet var det viktig å teste metoder som egner seg for produksjon av nasjonale datasett basert på automatisert tolkning av fjernmålingsdata som dekker forvaltningens behov ut over enkeltområder/ forskningsbaserte enkeltstudier. Dette betyr også at ett av målene var å bruke fjernmålingsdata som er tilgjengelig landsdekkende, eller blir det i nær framtid: flyfoto, laserdata fra Nasjonal detaljert høydemodell og Sentinel-2 optiske satellittbilder.

Rapporten er delt opp i to deler: første del beskriver arbeidet med identifisering av kystlynghei, mens andre del handler om store gamle/hule eiker.

KYSTLYNGHEI

Som prosjektområde for kystlynghei ble det valgt et område langs kysten fra Sirivåg til Hellvik i Rogaland. Referansedata ble hentet fra eksisterende Natur i Norge (NiN) -kartlegging og fototolkning. Det ble ikke gjort noe datainnsamling i felt.

Som metode ble det brukt Objektbasert bildeanalyse (Objekt Based Image Analysis, OBIA), en metode som analyserer bilder på objektnivå i stedet for på pikselnivå. Ortofoto ble segmentert (delt opp i mange homogene områder) og segmentene ble analysert videre. Segmenteringen ble testet med ulike målestokk (detaljeringsgrad) og segmenteringen ble testet med og uten bruk av eksisterende vektordata, som arealressurskartet AR5.

I klassifiseringen ble det brukt informasjon fra ortofoto, aggregert på objektnivå, samt ekstrakter fra laserdata, som normalisert digital overflatemodell, terrengfuktighetsindeks og akkumulert solinnstråling. Ulike standard

maskinlæringsmetoder ble brukt til klassifisering, blant annet Neural Network, Support Vector Machine og Random Forest.

Høyest oppnådd klassifiseringsnøyaktighet på 9 ulike naturtyper med bruk av laserdata og flybilder ble 77% (kappaverdi på 0.72). Kappa-koeffisienten er et mål på hvor mye bedre klassifiseringen er enn det den hadde vært ved helt tilfeldig klassifisering. En kappaverdi på 0 betyr et helt tilfeldig resultat, mens en verdi på 1 betyr perfekt samsvar.

Nøyaktighet for kun kystlynghei (T34) ble opp til 94% ved bruk av ortofoto og laserdata. (kappaverdi på 0.76). Fuktindeks, basert på terrengmodell fra laserdata, var den viktigste inputvariabelen i klassifiseringen. Bildeoppløsningen, 10 cm eller 25 cm, hadde ikke stor påvirkning på klassifiseringsresultatet. Opptaksdato, mai eller juni, utgjorde heller ikke stor forskjell. Flere klassifiseringsmetoder som Neural Network, Support Vector Machine og Random Forest ga omtrent like gode resultater. Naive Bayes og kNN ga dårligere resultater.

Resultatene tilsier at Objektbasert bildeanalyse kan brukes til å lage kart over naturtyper som til en viss grad ligner på manuell naturkartlegging med NiN. Samtidig er Objektbasert bildeanalyse mer fleksibel og mindre tidskrevende enn manuell kartlegging. AR5 ser svært nyttig ut, og bør brukes som utgangspunkt i segmenteringen. En annen fordel med den brukte metoden er at den er i stand til å produsere et estimat på usikkerhet/nøyaktighet for alle kartfigurer.

Fundamentet til hele metoden og alle resultater er referansedata. I dette prosjektet ble all referansedata samlet inn ved å bruke eksisterende NiN-kart og fototolkning. For å få en uavhengig validering bør dette komplementeres med uavhengige feltregistreringer.

I tillegg til OBIA metoden med ortofoto ble det testet en metode basert på bruk av Sentinel-2 satellittdata fra 4 ulike opptaksdato i 2017. Sentinel-2 bilder fra 4 ulike opptaksdatoer ble brukt separat for å undersøke om opptaksdato og dermed sesong kan påvirke klassifiseringsnøyaktigheten. Det ble ikke funnet noen

tydelig effekt: opptakene fra mai og juni ga litt bedre resultater enn opptakene fra august og oktober. Fordelen med å bruke Sentinel-2 i klassifiseringen er at bildene har homogen belysning over store områder, i motsetning til flybilder. Ulempen med Sentinel-2 er at oppløsningen på 10 meter gjør dataene uegnet til å lage detaljerte kartfigurer.

HULE EIKER

Naturtypen Hule eiker er definert som eiketrær med en diameter på minst 63 cm eller en omkrets på minst to meter i brysthøyde (1.3 meter over bakken). Hule eiker er beskyttet etter naturmangfoldloven. For eiketrær som er synlig hule gjelder beskyttelsen for trær som er minst 30 cm i diameter eller 95 cm i omkrets.

Å identifisere hule eiker med fjernmålingsdata er ikke så realistisk, men målet var å finne ut hvor langt man kan komme med bruk av fjernmålingsdata. Prosjektet hadde delmål å svare på følgende spørsmål (i stigende vanskelighetsgrad): kan man:

- skille ut vegetasjon med bruk av NH laserdata?
- kartlegge enkelttrær med bruk av NH laserdata?
- skille løvtrær fra bartrær?
- skille ulike typer løvtrær og særlig eik fra andre løvtrær?
- estimere tre-størrelse (diameter ved brysthøyde)?

Det ble valgt et prosjektområde i Asker kommune. Her testet vi enkelttre-deteksjon og treslagsklassifisering med bruk av to ulike laserdatasett og 2 ulike flyfotodatasett. Totalt 517 referansetrær, fordelt over 17 ulike treslag ble brukt.

Både 2-punkts og 5-punkts data kunne brukes til å kartlegge vegetasjon og til å kartlegge enkelttrær, trekrone og posisjon, men det ble mange feil i form av over- og undersegmentering. Disse feilene er relevante for å estimere eksakt antall trær, men det var ikke et mål i prosjektet. De segmenterte trekronene kunne fortsatt brukes til treslagsklassifisering.

Det ble testet standard maskinlæringsmetoder, blant annet Neural Network, Support Vector Machine og Random Forest. I tillegg ble det brukt Neural Network med image embedding fra Google Tensorflow.

Å skille bartrær fra løvtrær ga gode resultater. Høyest oppnådd klassifiseringsnøyaktighet var 86% (kappverdi på 0.72), med bruk av RGB bilder og laserdata, sammen med Neural Network metoden.

Å skille eik fra andre løvtrær ble gjort med en nøyaktighet på 81.3% (kappaverdi på 0.63), med bruk av RGB og NIR flyfoto og laserdata.

Vi har ikke klart å skille mellom gran, furu og flere ulike løvtreslag med god nøyaktighet: 46% og en kappaverdi på 0.39, som er et dårlig resultat.

Klassifisering av eik fra andre løvtrær fungerte også ganske bra med Neural Network med image embedding. Med kun bruk av RGB ortofoto fikk resultatet en nøyaktighet på 80.1% (kappaverdi på 0.60).

Klassifiseringsnøyaktighet for bar- versus løvtrær varierer fra 70.5% (kappa 0.41) med bruk av 2012 ortofoto til 80.2% (kappa 0.60) med bruk av 2014 ortofoto (med Neural Network med image embedding). Vi har ikke testet flere flyfoto-datasett, så vi kan ikke si mer om hvor høy eller lav nøyaktigheten kan bli, basert på vanlige flybilder.

Neural Network og Neural Network med image embedding gir betydelig bedre resultater enn Support Vector Machine, k Nearest Neighbor og Random Forest metodene, særlig når flere inputvariabler brukes. Bruk av nær infrarød informasjon øker klassifiseringsnøyaktigheten litt, men ikke i alle tilfeller.

Vi har ikke klart å finne en sammenheng mellom estimert trehøyde og stammediameter på eiketrær i naturbasen.

Det er mulig å kartlegge eiketrær med bruk av flyfoto og laserdata, men resultatet på enkelttre-nivå vil inneholder en del feil. Det bør testes videre på større områder og det bør bygges opp et datasett med referansetrær.

INNHold

FORORD.....	3
SAMMENDRAG.....	4
INNHold	9
KYSTLYNGHEI	10
1 INTRODUKSJON.....	10
2 MATERIAL OG METODER.....	14
3 RESULTATER.....	38
4 DISKUSJON.....	62
5 KONKLUSJON OG ANBEFALINGER.....	72
HULE EIKER.....	75
1 INTRODUKSJON.....	75
2 MATERIALE OG METODE	77
3 RESULTATER.....	85
4 DISKUSJON.....	96
5 KONKLUSJON OG ANBEFALINGER.....	105
ORDLISTE	107
REFERANSER.....	109
APPENDIKS SAMPLES ENKELTTTRÆR ORTOFOTO 2014.....	112

KYSTLYNGHEI

1 INTRODUKSJON

Miljødirektoratet ønsker å videreutvikle fjernmålingsmetodikker til å gi informasjon om naturtyper, som identifisering av kystlynghei og vurdering av kystlyngheiens tilstand, samt gjengroing av semi-naturlige systemer i Norge. Det er videre viktig for Miljødirektoratet å teste metoder for produksjon av nasjonale datasett, basert på automatisert tolkning av fjernmålingsdata, som dekker forvaltningens behov ut over enkeltområder og forskningsbaserte enkeltstudier.

Formålet med prosjektet er:

- 1) Å vurdere mulighetene til å utvikle metodikk for å identifisere naturtypen kystlynghei (T34) ved hjelp av fjernmåling. Dersom naturtypen kan identifiseres, skal metodikk for å beskrive tilstand i kystlynghei ved hjelp av fjernmåling vurderes.
- 2) Å vurdere mulighetene for å identifisere gjengroing av semi-naturlige systemer (boreal hei T31), semi-naturlige engtyper (eng og strandeng T32 og T33).
- 3) Å undersøke mulighetene for å identifisere enkeltobjekter slik som store gamle eiker ved hjelp av fjernmåling (Beskrivelsesvariablene 4 TG Gammelt tre og 4 TS Trestørrelse).

Prosjektet skal ha hovedfokus på bruk og prosessering av data fra laserskanning, bildematching m.m. samt bruk/utvikling av relevante fjernmålingsteknikker til identifisering av naturtyper og tilstandsvariabler. Det er videre relevant å se på mulighetene for å overvåke naturtyper og tilstandsvariabler ved hjelp av fjernmåling. Prosjektet skal vurdere mulighetene for å produsere landsdekkende datasett basert på eksisterende datakilder, for eksempel NDH og omløpsbilder. Landsdekkende datasett basert på fjernmåling har som fordel at det kan redusere mengden nødvendig feltarbeid og at det kan effektivisere kartleggingen.

1.1 MÅL FOR Å IDENTIFISERE NATURTYPEN KYSTLYNGHEI (T34)

For å kunne identifisere naturtypen kystlynghei (T34) må den kunne skilles fra nærliggende (med tanke på geografi og slektskap) naturtyper, blant annet:

- T1 Nakent berg
- T21 Sanddynemark
- T32 Semi-naturlig eng
- T33 Semi-naturlig strandeng
- T35 Løs sterkt endret fastmark
- T39 Hard sterkt endret fastmark
- T4 Skogsmark
- T44 Åker – ingen forekomst i prosjektområde
- T45 Oppdyrket varig eng
- T6 Strandberg
- V1 Åpen jordvannsmyr
- V9 Semi-naturlig myr

Noen typer er vi nødt å gruppere fordi de sannsynligvis ikke kan skilles automatisk med bruk av flyfoto/laserdata.

1.2 MÅL FOR Å VURDERE MULIGHETEN TIL Å IDENTIFISERE GJENGROING AV SEMI-NATURLIGE SYSTEMER

Det finnes to strategier for å indentifisere eller måle gjengroing av semi-naturlige systemer.

Den første er å bruke fjernmålingsdata fra to tidspunkter, og analysere endringer mellom de to tidspunktene. Et resultat av en slik endringsanalyse kan være endring i snitthøyde, eller høyde og tetthet av vegetasjonen. Fjernmålingsdata må inneholde en høydekomponent: laserdata eller 3D punktsky fra bildematching for eksempel. Neste steg er å oversette disse observasjonene om fysiske endringer til en kvalitativ beskrivelse, som grad av gjengroing. Dette steget krever detaljerte feltregistreringer. Andre metoden er å kun analysere et fjernmålingsdatasett (med nyere opptaksdato) sammen med detaljerte feltobservasjoner.


Feltregistreringene bør inneholde en god beskrivelse av naturtypen og grad av gjengroing. Ideen er at en viss naturtype, som for eksempel kystlynghei, har

karakteristiske verdier for vegetasjonshøyde og tetthet. Alle fjernmålingsestimatene som ligger utenfor disse verdiene kan tolkes som gjengroing. Også her er det avgjørende å ha detaljerte feltregistreringer.

Det ble ingen mulighet til å samle inn spesifikke referansedata i felt til dette formålet på grunn av tidsplanen i prosjektet. Målet ble vurdert som lite nyttig å fokusere på, hvor fokuset heller har ligget på det første målet.

1.3 PROSJEKTOMRÅDE


Kystzone fra Sirivåg til Hellvik i Rogaland ble valgt som prosjektområde. Her finnes det store forekomster av kystlynghei.



Figur 1. Prosjektområde Kystlynghei Sirivåg-Hellvik

Videre dekkes området delvis av nyere NiN-kartlegging.

Området er interessant som pilotområde fordi det finnes flyfoto med ulike egenskaper og laserdatasett med 10 års mellomrom.



Figur 2. Prosjektområdet med flyfoto fra 2013 i bakgrunnen.

2 MATERIAL OG METODER

2.1 MATERIAL

2.1.1 LASERDATA

Prosjektnavn	NDH Jæren-Randaberg-Sola 5pkt 2017
År	2017
Selskap	Terratec
Sensor	Riegl LMS-Q1560
Opptaksdato	22.03.2017 til 26.05.2017
Punkttetthet (pkt/m2)	5

2.1.2 FLYFOTO

Prosjektområdet dekkes av to nyere datasett med flyfoto:

- Omløpsfotografering Rogaland 2013
- Hå 2014.

Prosjektnavn	Rogaland 2013	Hå 2014
År	2013	2014
Selskap	Terratec	COWI
Sensor	Vexcel UltraCamXP	Vexcel UltraCamXP
Opptaksdato	09-06-2013	02-04-2014
GSD (cm)	25	10

Rogaland 2013 bildene er fra Nasjonalt program for omløpsfotografering. Ground sampling Distance (GSD) eller oppløsning på bakken er 25 cm.

Omløpsfotografering dekker hele landet i løpet av 5 år, og er derfor interessant å bruke som grunnlag i analysene.

Bildene fra Hå 2014 er ikke en del av omløpsfotografering, og er tatt fra lavere flyhøyde med bedre oppløsning på 10 cm. Bedre oppløsning kan muligens gi bedre resultat, så derfor er dette datasettet interessant å sammenligne med omløpsbildene. En annen forskjell mellom Hå 2014 og Rogaland 2013 er bildenes opptaksdato: mai versus juni.


Ortofoto er et georeferert flybilde med samme geometriske egenskaper som et kart, og kan brukes til kartlegging og analyse.

Ortofotoene ble lastet ned fra Norge i Bilder (www.norgeibilder.no).

Ortofotoene som ble brukt har 3 fargebånd: rødt, grønt og blått. Hvert bånd består av 8 bits data, det vil si at fargeverdiene går fra 0 (mørkest) til 255 (lysest). Dette er standard for hele ortofotoarkivet til Norge i bilder.

2.1.3 SENTINEL-2

Sentinel-2 konstellasjonen består av 2 identiske satellitter: 2a og 2b. Disse eies av European Space Agency (ESA). Sentinel-2 sensoren er et optisk instrument som registrerer lys i den synlige delen av spektret, men også i den nær-infrarøde og kortbølge-infrarøde delen. Fire fargekanaler har en oppløsning på 10 meter. Disse kanalene anses å være mest interessante for kartlegging av kystlynghei, med tanke på spektral informasjon og oppløsning.



Figur 3. Spektrale kanaler Sentinel-2.

Sentinel-2 satellittene kan til sammen gjøre opptak over samme område om lag hver 2. til hver 3. dag i Norge, og opptaksstripene som går fra nord til sør er 285 kilometer brede. Fordelen med Sentinel-2 er at det blir mye data tilgjengelig, og at man kan regne med flere anvendbare opptak gjennom året, og dermed data innenfor spesifikke sesonger. En annen fordel er at fargeverdier i bildene er mer konstante, og enklere å kalibrere enn i for eksempel flyfoto. Et Sentinel-2 opptak

dekker et stort område på samme tidspunkt (samme solvinkel), og de ekstra spektrale kanalene gjør det enklere å utføre en atmosfærisk korrigering.

Sentinel-2 data ble lastet ned fra den Norske nasjonale nedlastingsportalen (<https://colhub.met.no/#/home>).


Sentinel-2 opptak av følgende datoer ble brukt:

06 mai 2017

05 juli 2017

27 august 2017

06 oktober 2017



Figur 4. Fire ulike opptak med Sentinel-2.

2.1.4 REFERANSEDATA

Styrt klassifisering krever referansedata, både til trening og til validering av resultatet. I dette prosjektet var det ikke mulighet til å samle prosjektspesifikke referansedata i felt på grund av kort gjennomføringstid. Referansepunkt ble valgt basert på eksisterende NiN kartlegging og flybildetolkning.

NiN-kartet som ble brukt var ikke 100% kvalitetssikret på tidspunktet det ble tilgjengeliggjort, og kan derfor inneholde noe inkonsistens samt manglende egenskaper. Se avsnitt 2.3.2 for en beskrivelse av hvordan referansedataene ble valgt ut.

2.2 BEARBEIDING / PREPROSESSERING

2.2.1 BEARBEIDING LASERDATA

Laserpunktskyene i LAZ format ble lastet ned fra hoydedata.no.

Laserdata som samles inn via Nasjonal Detaljert Høydemodell prosjektet (NDH) inneholder følgende klasser:


Tabell 1 Klasser i standard NH LAZ laserdata (Kartverket, u.å.)

Klasse	Forklaring
1	Uklassifisert (Unclassified). Alle punkter som ikke er klassifisert som klasse 2, 7, 10 eller 13
2	Punkter på terrengoverflate (Ground). Denne klassen omfatter som standard også punkt på vannoverflater (innsjø, hav, elv). Punkter innenfor vannpolygon som ligger over vann-/terrengoverflate (vegetasjon, brygger og lignende) leveres i klasse 1 (uklassifisert).
7	Støy-punkter (Lowpoints) forårsaket av skyer, fugler, "multipath", system feil etc. Denne klassen omfatter unormalt høye og lave punkt (spikere) og punkt som under bakkeklassifiseringen blir definert til å ligge under terrengoverflaten.
10	Punkter som ligger på bru (Bridge) Minstemål for klassifisering er 10 m ² . Eksisterende FKB-data av best mulig kvalitet benyttes som støtte til klassifiseringen. Alle punkter som ligger på bru-avgrensingen skal klassifiseres som Bru (Klasse 10). Det presiseres at FKB-dataene kun benyttes som støtte i klassifiseringen. Kravet til klassifisering gjelder uavhengig av fullstendigheten i FKB-dataene.
13 (egendefinert)	Punkter som ligger på snø/is.

Digital Terrengmodell (DTM)

Punkt i klasse 2 representerer terrenghøyder. Disse ble brukt til å generere en Digital Terrengmodell (DTM) ved hjelp av LAsTools programvare.

Generering starter med å danne en triangelformet modell fra terrengpunktene ved å bruke Delaunay triangulering. Resultatet kan overføres til et regelmessig raster. Cellestørrelse i rasteret kan velges fritt, men bestemmes basert på punkttettheten i laserdataene og ønsket detaljeringsgrad på rasteret. I dette prosjektet ble en cellestørrelse på 1 meter valgt. Figur 5 viser et eksempel på en terrengmodell i raster formatet, fargelagt etter høyde.



Figur 5 Terrengmodell (DTM – Digital Terrain Model), fargelagt etter høyde. Figurer fra NiN-kartlegging i hvit.

Topographical Wetness Index (TWI)


Terrengmodellen ble brukt som grunnlag for å lage et raster med Topographical Wetness Index (TWI). TWI gir en indikasjon på potensiell fuktighet ut ifra informasjon i terrengmodellen. TWI beskriver forhold mellom størrelse på nedslagsfeltet som drenerer gjennom en rastercelle og bratthet i rastercellen. En høy TWI betyr at området er potensielt fuktig. Det er da et stort nedslagsfelt oppstrøms til cellen og cellen selv ligger i flatt terreng. En lav TWI betyr et lite nedslagsfelt oppstrøms, for eksempel toppen av en kolle eller rygg, eller at cellen ligger i bratt terreng (drenerer bra) (Friberg, 2014). TWI beskriver kun potensiell fuktighet og sier ingenting om aktuell fuktighet som er avhengig av nedbør og fordampning. Videre tar ikke TWI hensyn til jordsmonn (fjell, løsmasse også videre).

ArcGIS Spatial Analyst ble brukt til å lage et datasett med strømningsretning (flow direction) fra hver rastercelle i terrengmodellen. «Flow direction» raster ble brukt til å beregne «flow accumulation» per celle: det vil si at hver celle får en verdi som tilsvarer hvor mange celler oppstrøms det er som drenerer til denne cellen. I tillegg ble det generert en helningsraster fra terrengmodellen.

Topographical Wetness Index defineres som:

$$TWI = \ln(a/\tan b)$$


Hvor a er "flow accumulation" raster og b er helningsraster.



Figur 6. Nederst: Topographic Wetness Index (TWI) basert på Terrengmodellen. Øverst: ortofoto

Solinnstråling

Solinnstråling ble beregnet ut i fra terrengmodellen ved bruk av ArcGIS Spatial Analyst (Area Solar Radiation). Metoden tar utgangspunkt i breddegrad for å beregne solinnstråling for området. Videre brukes terrengmodellen til å beregne innstråling mer detaljert basert på geometrien: en nordvendt helning får mindre innstråling enn en sørvendt helning. Metoden estimerer potensiell innstråling og tar ikke hensyn til atmosfære eller skyer. Solinnstrålingskart kan blant annet brukes til å planlegge lokalisering av boliger og solcellepaneler. I dette prosjektet forventes det at kartet kan gi informasjon om ulike vegetasjonstyper (varmekjære typer versus typer som har forekomst i baklier). Absolutte innstrålingsverdier er ikke særlig relevante til dette formålet: det er relative forskjeller som kan være interessante. Det ble valgt å summere opp all innstråling over et helt år uten å gruppere per sesong.




Figur 7. Solinnstråling basert på Terrengmodellen.

Normalisert laserpunktsky / Delta-z

Laserdata består av punkter med koordinater: x, y og z hvor z-koordinaten representerer høyde over havet. I tillegg til høyde over havet kan det være


interessant å vite høyde over terrenget til hvert enkelt laserpunkt, for eksempel hvis man ønsker å måle høyder på trær eller hus. Hele punktskyen kan normaliseres ved å trekke fra terrenghøyde på hvert enkelt punkt. Resultatet er en normalisert høyde for hele datasettet. Normaliserte punktskyer brukes til å estimere høyde og andre variabler i skog, og for å måle høyder på tekniske objekter som hus, stolper og kabler.



Figur 8. profil (tverrsnitt) av en laserpunktsky øverst, og nederst er den samme profilen etter høydenormalisering. Røde punkt er bakketreff mens grønne punkt er ikke-bakketreff. Eksempelet er fra en 5 punkts /m2 datasett og ikke fra prosjektområdet.

Normalisert Digital OverflateModell (NDOM)

En digital terrengmodell (DTM) representerer terrenget. En digital overflatemodell (DOM) representerer terrenget pluss alt som er over terrenget: hus, vegetasjon, ledninger og stolper. Se Figur 9.




Figur 9. profil av en laserpunktsky. Den lyseblå linjen viser en digital overflatemodell (DOM). Eksempelet er fra en 5 punkts /m2 datasett og ikke fra prosjektområdet.


En normalisert digital overflatemodell (NDOM) representerer alle objekthøyder i forhold til terrenget.

LAStools ble brukt til å generere NDOM fra de normaliserte laserpunktene.

Resultatet ble en raster med cellestørrelse på 1 meter.



Figur 10. profil av en normalisert laserpunktsky. Den lyseblå linjen viser en normalisert digital overflatemodell (NDOM).




Figur 11. Normalisert digital overflatemodell (NDOM) viser høyder over bakkenivået. Det kan være vegetasjon men også andre objekter som bygninger, stolper store stein også videre. Rødt er 0 meter over bakken mens grønt er 25 meter over bakken.

Skyggemodell

Terrengmodellen ble brukt til å generere en skyggemodell. En skyggemodell viser modellert belysning fra en viss vinkel og retning på terrengmodellen. Resultatet fremhever terrengformen, og er nyttig for å tolke terreng visuelt. Resultatet er

ikke særlig anvendbart i klassifisering eller modellering videre, men kan brukes til å bedømme kvalitet på AR5 og NiN-kart med tanke på avgrensningen av kartfigurene. Terrengmodellen inkluderer ikke vegetasjon eller bygninger. Det er også mulig å generere en skyggemodell av en overflatemodell som inkluderer både terreng, vegetasjon og bygninger.



Figur 12 Skyggemodell basert på terrengmodell (DTM)

2.2.2 BEARBEIDING ORTOFOTO

Ortofoto ble brukt direkte til analyse. Det ble ikke gjort justering eller fargekorrigering. Ortofotoene fra Hå 2014 ble resamplet til 25 cm, for å matche oppløsningen til Rogaland 2013. På denne måten blir datasettene mer sammenlignbare, og det er da kun opptakstidspunkt som er annerledes. Hå 2014 datasettet på 10 cm ble også brukt videre. Det ble ikke gjort justeringer eller fargekorrigering ut over dette.

2.2.3 BEARBEIDING SENTINEL-2

Sentinel-2 bildene ble lastet som Level 1C data.

Level 1C betyr at bildene er:

- ortorektifisert (passer sammen med et kart).

- radiometrisk kalibrert til Top-Of-Atmosphere reflectance. Reflectance betyr at verdiene i pikslene gjenspeiler hvor mye sollys som er reflektert fra pikselen tilbake til sensoren, i forhold til total mengde sollys som har truffet pikselen. Verdiene går i teori fra 0 (ingen refleksjon) til 1 (alt lys har blitt reflektert). Top-Of-Atmosphere betyr at reflektans måles helt øverst i atmosfæren, det vil si at signalet som registreres av satellitt-sensoren har gått gjennom atmosfæren. Atmosfærer påvirker signalet i varierende grad på grunn av fukt og støv (ESA, u.a.).

Atmosfærisk korreksjon

For å gjøre effekten av atmosfæren på signalet mindre kan man utføre en atmosfærisk korreksjon på dataene. Med bruk av modeller og målingene i de andre spektrale kanaler i Sentinel-2 dataene kan man korrigere for atmosfærisk effekt til en viss grad. I prosjektet ble ESA sitt standard verktøy SNAP brukt til å gjøre atmosfærisk korreksjon. Resultatet blir pikselverdier som representerer Bottom-Of-Atmosphere reflectance. Det vil si at effekten mellom «top» og «bottom» av atmosfæren er fjernet fra dataene (ESA, u.a.).

Litt om ortorektifisering

ESA utfører en ortorektifisering av bildene, men bruker en terrengmodell over hele Norge som ikke er ideell. Konsekvensen er at de ortorektifiserte bildene ikke ligger helt riktig i forhold til kartet (Kääb et al. 2016). Effekten er størst i områder med store høydeforskjeller. Det var lite feil i prosjektområdet, maksimalt 1 piksel, men man må regne med større feil i fjellområder.

2.3 OBJEKTBASERT BILDEANALYSE AV FLYFOTO OG LASERDATA

Objektbasert bildeanalyse (OBIA) er en metode som analyserer bilder på objektnivå i stedet for pikselnivå. I pikselbaserte metoder klassifiserer man hver piksel for seg, ved å se på pikselverdiene i ulike spektrale kanaler.

OBIA metoder starter med å gruppere pikslene i et bilde til homogene objekter. Objektene brukes som enhet i klassifiseringen, og i tillegg til én spektralverdi per kanal finnes det ifølge Blaschke (2010) mange flere variabler som kan anvendes:

- **statistikk per objekt**, som snitt spektralverdi, persentilverdier, standardavvik og tekstur.
- **informasjon om form og størrelse på objektet**, som areal, lengde, rundhet, omriss/innhold, osv.
- **forhold til nabo-objekter**, som naboskap til objekter med en viss klasse.
- **Forhold til objekter på andre nivåer (målestokk).**

I dette prosjektet ble ikke OBIA metoden fullt utnyttet. Det ble for eksempel ikke brukt informasjon om form og størrelse, eller forhold til andre objekter. Grunnen er at det kreves svært mye kunnskap om type objekter man skal klassifisere for å kunne bruke slike typer variabler. Samtidig risikerer man å introdusere systematiske feil (bias) hvis man bruker variablene på feil måte.

Metoden som ble brukt i prosjektet besto av følgende steg:


1. Segmentering av bilde- og laserdata.
2. Valg av samples (trenings- og valideringsområder).
3. Testing og optimalisering av klassifiseringen.
4. Klassifisering.
5. Aggregering av resultatet.

Trimble eCognition programvare ble brukt til steg 1, 2, 4 og 5 i prosessen. Orange (Data Mining) ble brukt til steg 3.

2.3.1 SEGMENTERING MED ULIK MÅLESTOKK

Segmentering er en prosess som deler et bilde opp i meningsfulle regioner. Bilder består av piksler, og segmentering grupperer piksler inn i sammenhengende homogene objekter. Hva en meningsfull region er, kommer an på hva man ønsker å detektere i bildet og hvordan bildet ser ut. Hvis bildet viser et objekt på en ellers ensfarget bakgrunn, blir det forholdsvis enkelt. Men segmenterer man et flybilde blir det mer komplisert. Det er ikke lett å skille objektene man er interessert i fra «bakgrunnen», og objektene kan ha ulik størrelse og utseende.

Hvis objektene man skal kartlegge i tillegg er diffuse og mosaikker, blir det enda mer komplisert.



Figur 13. Eksempel segmentering

Figur 13 viser kompleksiteten: ulike elementer i landskapet har ulik størrelse og ulik kontrast. Det er umulig å utføre en segmentering som gir et perfekt resultat på alle elementer i bildet. Noen elementer er delt opp for mye, som vannet i dette bildet. Andre elementer er delt opp for lite: en del objekter består for eksempel av bart fjell og vegetasjon.

Vi har brukt eCognition programvare til å segmentere. eCognition har en egenutviklet algoritme som heter «multiresolution segmentation», som kan utføre segmentering på ulike rasterdata med ulik oppløsning. Det betyr at man kan velge å bruke både ortofoto og raster fra for eksempel laserdata samtidig. Dette betyr også at man kan velge ulike segmentstørrelser, og kan segmentere med ulike målestokk samtidig. I tillegg kan man bruke vektordata som faste grenser i segmenteringen.

Vi testet ulike strategier:

- Segmentering på ulike nivåer/målestokk.
- Segmentering med og uten bruk av AR5 som faste grenser.

- Segmentering med og uten bruk av NDOM og/eller fuktindeks.

Segmenteringen ble gjort på 3 nivåer: 1, 2 og 3, der 1 er grovest og 3 er finest.

Segmentering ble gjort på følgende datasett i rasterformat:


- Rød kanal
- Grønn kanal
- Blå kanal
- NDOM fra laserdata

Det fineste nivået ble valgt for å oppnå homogene segmenter, som ikke besto av mosaikk av naturtyper (i forhold til bildeoppløsning).


Nivå 1 og 2 ble valgt litt mer vilkårlig. Nivå 1 tilsvarer ca. kartleggingsmålestokk til NiN-kartleggingen. Det har ikke vært noe mål å få denne segmenteringen perfekt.

2.3.2 VALG AV SAMPLES / TRENINGS OG VALIDERINGS PUNKT


Styrt klassifisering krever referansedata, både til trening og validering av resultatet. I dette prosjektet var det ikke mulighet å ta prosjektspesifikke referansedata i felt, på grunn av kort gjennomføringstid. Referansepunkt ble valgt basert på eksisterende NiN-kartlegging og flybildetolkning. Figur 14 viser en oversikt over referansepunkt som har blitt plukket ut og fordelingen over prosjektområdet.



Figur 14. Oversikt over referansepunkt i prosjektområdet. Dekning av NiN-kartlegging i hvit/gjennomsiktig.



Figur 15 Eksempel på referansepunkt basert på NiN-kartlegging. Flater med gul avgrensning: NiN-kart. Punktene er fargelagt etter Hovedgruppe og hovedtype.



Figur 16. Eksempel på Kystlynghei (T34) referansepunkt basert på NiN-kartlegging. Flater med gul avgrensning: NiN-kart. Punkt er fargelagt etter Hovedgruppe og hovedtype. Selv om hele figuren er definert som kystlynghei ble referansepunktene valgt i «rene» områder.

Referansepunktene ble valgt innenfor NiN-figurer. Punktene ble valgt slikt at de skal fange opp variasjon av naturtypen i bildene. Samtidig ble punktene kun valgt i områder som ble tolket som «rene» overflater. Figur 16 viser et eksempel på kystlynghei (T34), hvor hele figuren er definert som kystlynghei (andel 100%). Allikevel ble punktene ikke plassert på områder med synlig bart fjell eller løvtrær, men kun i områder hvor hei-vegetasjon dominerer. Siden klassifiseringen derfor blir utført på et mye høyere detaljeringsnivå enn NiN-kartleggingen er det viktig å få «rene» referansepunkt. Figur 17 viser på hvilket detaljeringsnivå klassifiseringen har blitt gjort.



Figur 17. Detaljbilde referansepunkter.

Referansepunkt ble knyttet til segmentet de ligger i, og segmentet ble brukt i sin helhet til trening og validering videre.

Tabell 2 presenterer en oversikt over antall referansepunkt per naturtype, samt arealfordeling av naturtypene ifølge NiN i prosjektområdet.

Noen kommentarer til valgene som ble gjort:

- Noen naturtyper ble slått sammen fordi det var hensiktsmessig: F Limniske vannmasser, M Saltvannsbunnsystemer og L (uten nærmere spesifisering) ble aggregert til «L» vann. Prosjektet har ikke som formål å skille ut ulike typer innenfor vann-systemer.
- En klasse «Skygge» ble innført for å kunne identifisere skygger i bildene.
- Fastmarkstyper T35, T37 og T39 ble ikke med i utvalg av referansepunkt fordi overflatetyperne er altfor varierende. I tillegg er tanken å bruke andre type støttest data for å kartlegge infrastruktur og bebyggelse: AR5. Se avsnitt 4.1.1 for diskusjon rundt temaet.

Tabell 2. Arealfordeling ifølge NiN i prosjektområdet og antall referansepunkt som ble valgt ut per naturtype.

Type	Navn	Areal i NiN (ha)	Areal i NiN (%)	Referansepunkt (antall)	Referansepunkt (%)
L0	Ferskvannsbunnsystemer	7.84	1.7 %	24	6 %
L4	Helofytt-ferskvannssump	0.99	0.2 %	9	2 %
M0	Saltvannsbunnsystemer	26.93	5.8 %		
T1	Nakent berg	63.90	13.7 %	51	12 %
T2	Åpen grunnlendt mark	0.38	0.1 %		
T21	Sanddynemark	-	0.0 %	4	1 %
T29	Grus- og steindominert strand og strandlinje	0.34	0.1 %		
T32	Semi-naturlig eng	16.40	3.5 %	31	7 %
T33	Semi-naturlig strandeng	0.85	0.2 %	9	2 %
T34	Kystlynghei	107.94	23.2 %	86	20 %
T35	Løs sterkt endret fastmark	24.25	5.2 %		
T37	Ny løs fastmark	20.07	4.3 %		
T38	Treplantasje	0.99	0.2 %		
T39	Hard sterkt endret fastmark	27.11	5.8 %		
T4	Skogsmark	7.15	1.5 %	45	11 %
T41	Eng-liknende oppdyrket mark	8.26	1.8 %	27	6 %
T43	Plener, parker og liknende	14.19	3.1 %		
T45	Oppdyrket varig eng	86.44	18.6 %	30	7 %
T6	Strandberg	38.36	8.2 %	18	4 %
V1	Åpen jordvannsmyr	6.31	1.4 %	37	9 %
V2	Myr- og sumpskogsmark	0.80	0.2 %		
V9	Semi-naturlig myr	5.51	1.2 %	38	9 %
Skygge	Skygge i bildene	-	0.0 %	16	4 %
Totalt		465.04	100.0 %	425	100.0 %

2.3.3 KLASSIFISERING

I prosjektet har vi valgt å bruke styrt klassifisering. Det vil si at vi har forhåndsbestemte kategorier: naturtypene og referansedata for disse kategoriene. Klassifiseringsmetodene leter etter sammenheng mellom egenskaper fra både bilder og laserdata for de ulike kategoriene, og lager en modell ut av dette.

Modellen kan brukes etterpå til å klassifisere resten av området hvor man ikke har referansedata. Vi har testet følgende klassifiseringsmetoder:

- **Random Forest (RF)**

Random Forest lager flere Beslutningstrær (decision trees). Et beslutningstre forsøker å finne de beste egenskapene og terskelverdier for å dele opp dataene i 2 grupper. Prosessen gjentas på hver gruppe (nodes) helt til man får rene klasser i hver node. Resultatet av beslutningstreet ser ut som forgreininger på et tre. Random forest kombinerer resultatene av mange ulike beslutningstrær i et optimalt resultat.

- **Support Vector Machine (SVM)**

SVM-metoden plotter egenskapene inn i et multidimensjonalt rom, og konstruerer et hyperplan i dette rommet, som på best mulig måte separerer disse egenskaper fra hverandre for de ulike klassene.

- **K-Nearest Neighbor (kNN)**

kNN danner et egenskapsrom i flere dimensjoner (1 egenskap = 1 dimensjon) og finner hvilket referansepunkt som ligger med kortest avstand i egenskapsrommet til et ukjent punkt. Det ukjente punktet får overført klassen fra nærmeste referansepunkt. Hvis $k = 1$ blir kun det nærmeste referansepunktet valgt. Hvis $k = 2$ blir snitt av de 2 nærmeste punkter brukt, og så videre.

- **Naïve Bayes (NB)**

Naïve Bayes går ut ifra at egenskapene er uavhengige (ikke korrelerte) og bruker sannsynlighet (fordelinger av egenskapene for ulike klasser) for å predikere hvilken klasse en ukjent kombinasjon av egenskaper tilhører.

- **Neural Network (NN)**

Neurale nettverk er en klassifiseringsmetode som bruker input (et lag) fra egenskapene til å predikere klasser (resultat lag). Mellom disse to lagene genererer NN et eller flere lag med ulike «nodes». Antall «nodes» og vekt som tilordnes hver node trenes opp med bruk av referansedata.

Vi sammenlignet resultatene:

- Mellom de ulike klassifiseringsmetodene.
- Ved bruk av ulikt antall variabler.
- Ved bruk av 2 ulike sett med ortofoto.

Klassifiseringsmetodene som ble brukt er ikke knyttet til spesielle programvarer, men er generelle. Det finnes flere ulike programvarer og programmeringsspråk som R, Orange, Python, Matlab og Weka, hvor disse metodene er implementert.

2.3.4 KRYSSVALIDERING

Klassifiseringen ble gjort med en 10 fold kryssvalidering. Det betyr at datasettet med samples ble splittet opp i 10 deler. Klassifiseringen ble gjort 10 ganger og hver gang ble det utelatt 1/10. del i opplæringsfasen. Resultatet ble testet mot den 1/10. del som var utelatt.

2.3.5 TESTE UTVELGELSE AV VARIABLER OG ANTALL VARIABLER

Tabell 3 viser oversikt over variabler som ble hentet på objektnivå fra ortofoto og laserdataene.

Det finnes mange egenskaper fra laser- og bildedataene som kan brukes i klassifiseringen. For å velge de mest relevante egenskapene ble alle egenskaper sortert i rekkefølge ved bruk av Gini-indeksen. Gini-indeksen forsøker å estimere en egenskap sin mulighet til å skille mellom klassene. (Breiman et al. 1984). Hver klassifiseringsmetode ble testet med 1,2, ...11 variabler for å finne optimalt antall variabler.

Tabell 3. Liste over variabler som ble brukt i klassifiseringen.

variable	beskrivelse
BLUE_avg	Blå kanal, gjennomsnitt
BLUE_std	Blå kanal, standard avvik
GLCM_H_all	Haralick Homogenitet, alle retninger, rød kanal
GREEN_avg	Grønn kanal, gjennomsnitt
GREEN_std	Grønn kanal, standard avvik
HSI_H	Hue (fargetransformert fra RGB)
HSI_I	Intensity (fargetransformert fra RGB)
HSI_S	Saturation (fargetransformert fra RGB)
FUKT_avg	Fuktighetsindeks (fra DTM)
SOL_avg	Solinnstråling (fra DTM)
NDSM_avg	NDOM, gjennomsnitt
NDSM_std	NDOM, standard avvik
RED_avg	Rød kanal, gjennomsnitt
RED_std	Rød kanal, standard avvik

2.3.6 SAMMENLIGNING ULIKE FLYFOTO DATASETT

Eksakt samme klassifikasjonsmetoder ble brukt på 2 + 1 flyfoto datasett.

- Omløpsfoto Rogaland 2013 med GSD 25 cm
- Hå 2014 med GSD 10 cm
- Hå 2014 resamplet opp til GSD 25 cm.

2.3.7 VARIABLENES SENSITIVITET.

Ulike valg av segmenteringsparameters påvirker danningen av bildesegmentene. I dette prosjekt har vi kun testet noen ulike valg og bedømt resultatet visuelt. Vi har ikke gjort en grundig analyse av alle de mulige valgene og resultatene.

2.4 KLASSIFISERING AV SENTINEL-2

2.4.1 VALG AV SAMPLES / TRENINGS OG VALIDERINGSPUNKT

Til analysene ble det samme settet med trenings- og valideringspunkt brukt som i analysene av flyfoto/laserdataene. Se avsnitt valg av samples / trenings og valideringspunkt. Punktene ble ikke koblet til segmenter (slik som i flyfotoanalysene) men til 1 piksel fra Sentinel-2.

2.4.2 KLASSIFISERING

Vi har testet følgende klassifiseringsmetoder:

- Random Forest
- Support Vector Machine
- kNN
- Naive Bayes
- Neural Network

Det er de samme metodene som ble beskrevet i avsnitt 2.3.3

Vi sammenlignet resultatene:

- Mellom de ulike klassifiseringsmetodene.
- Ved bruk av ulike opptaksdato separat.
- Mellom alle variabler fra ulike opptak blandet.

2.4.3 KRYSSVALIDERING

Klassifiseringen ble gjort med en 10 fold kryssvalidering. Det betyr at datasettet med samples ble splittet opp i 10 deler. Klassifiseringen ble gjort 10 ganger og hver gang ble det utelatt 1/10. del i opplæringsfasen. Resultatet ble testet mot den 1/10. del som var utelatt.

3 RESULTATER

3.1 RESULTATER OBIA OG FLYFOTO

3.1.1 SEGMENTERING MED ULIK MÅLESTOKK

Segmenteringen ble gjort på 3 nivåer: 1, 2 og 3, der 1 er grovest og 3 er finest.

Tabell 4 viser gjennomsnittlig arealstørrelse for segmentene på de ulike nivåene.

*Tabell 4. Oversikt over størrelse på segmentene i nivå 1, 2 og 3. * NiN-figurene ble valgt ut i et representativt område. Det finnes en del svært store figurer (>20 ha) som sannsynligvis ikke er helt ferdig tegnet og disse burde ikke være med i statistikken.*

Nivå	1	1 (T34% > 30%)	2	3	NiN*
Snitt areal (ha)	0,79	0,99	0,0469		1,27*
Snitt areal (m ²)	7900	9900	469	33	12784*
Standard avvik (m)	8000	9900	553	35	10956*
Antall segmenter	1 439	235	25 616	348 111	31*

Figur 18 viser et eksempel på segmenteringsresultatet for nivå 1, 2 og 3.


Her ser man at segmentene i nivå 1 har en størrelse som er sammenlignbar med figurer fra NiN-kartleggingen. Segmentet består av en mosaikk av kystlynghei (T34) og nakent fjell, og sannsynligvis noe myr langs vannet.

Ulempen med automatisk segmentering er at segmentene ikke blir perfekte. I en del tilfeller er segmentet litt «feil» eller uheldig tegnet og i noen tilfeller vil man se en del store feil. For eksempel at et segment dekker både bart fjell, noe vegetasjon og etterpå går over i vann.


Fordelen med automatisk segmentering versus manuell tegning er at segmentering ikke er like tidkrevende. Der hvor man ikke kan tegne for detaljert manuelt, fordi det blir for mye arbeid, kan segmenteringen enkelt gjøre det. Det samme gjelder å tegne/segmentere på ulike nivåer samtidig. Man kan også tenke seg å segmentere på ulike nivåer avhengig av «forventet» naturtype eller landskapstype.

Det hadde vært uaktuelt å tegne visse landskapstyper med 10 eller 20 ganger større detaljeringsgrad manuelt, mens dette ikke hadde vært noe problem ved bruk av segmentering. Segmentering gjør det mulig å velge nivået etter behov i

stedet for å la seg begrense av tilgjengelig tid og ressurser for å tegne kart manuelt.



Figur 18. Segmentering på 3 ulike nivåer. Øverst til venstre: mest detaljert (3), nederst til venstre, mellom detaljert (2) og til høyre, minst detaljert.



Figur 19. Segmenteringen i gult og NiN i hvit. Øverst vises det nivå1 og nederste halvdel viser nivå 2.

3.1.2 SEGMENTERING MED BRUK AV AR5


Det ser ut som AR5 er et bra startpunkt for naturtypekartlegging. I Figur 20 ser vi både AR5 og NiN-figurer i samme område. Det virker som NiN-kartleggeren ikke har brukt figurgrensene til AR5, selv om svært mange grenser nesten sammenfaller. AR5 er tilgjengelig til NiN-kartleggere og instruksene beskriver at AR5-grensene kan brukes direkte til å danne figurgrenser i NiN. Det kan hende at NiN-kartleggeren i dette eksempelet har vurdert grensene til AR5 og har valgt å tegne egne grenser.

Fordelen med å bruke AR5 som basis er at man får en bra avgrensning mot en del arealtyper som har blitt kartlagt fra før med bra kvalitet som vann, infrastruktur, bebyggelse og jordbruksarealer.



Figur 20: AR5 (i blått) og NiN-kartlegging (i hvit).

Med en automatisk segmentering er det enkelt å ta eksisterende kart som AR5 inn og å bruke grensene som faste figurgrenser. Innenfor figurene kan man ende opp med flere segmenter ved behov. Man trenger ikke å velge å bruke hele AR5 men man kan velge ulike figurer etter for eksempel arealtype.




Figur 21. segmentering på nivå 1 med bruk av AR5 som basis. Alle AR5 (blå) grenser er med i segmenteringsresultatet men segmenteringen har lagt ekstra figurer innenfor hvert AR5 figur.

3.1.3 SEGMENTERING MED OG UTEN BRUK AV NDOM ELLER FUKTINDEKS

Man kan bruke ulike rasterlag som input i segmenteringen. Man trenger ikke å begrense seg til ortofoto. Fordelen er at man har mange valg, men det er samtidig også ulempen: for hvert rasterlag man velger å bruke i tillegg, vil betydning av de andre lagene gå ned. Bruker man rasterlag som ikke bidrar vil kvaliteten på segmenteringen gå ned.

Siden analysene viser at fuktindeks er viktig for klassifiseringsresultatet (se neste avsnitt) har vi testet å ta dette laget med i segmenteringen. Figur 22 sammenligner resultatet. Vi har ingen mulighet å si noe kvantitativt om kvalitetsforskjellen mellom de to segmenteringene. For å kunne gjøre det trenger man et kart med fasit figurer, så kan man eventuelt måle hvilken segmentering som kommer nærmest. Nå er det slik at det ikke finnes en fasit for å tegne ut

avgrensninger. Det beste vi kunne gjøre var å bedømme visuelt om avgrensninger ser logiske ut.



Figur 22. Øverst: segmentering basert på fuktindeks. Nederst: segmentering basert på RGB flyfoto. I bakgrunn på venstre siden er fuktindeks og på høyre siden RGB flyfoto.

Man ser at ved å bruke fuktighetsindeks som lag i segmenteringen at en del landskapselementer, som myrer og rygger, blir godt definert. Samtidig bommer denne segmenteringen på en del viktige vegetasjonsoverganger. Skog og tregrupper ignoreres, og overganger mellom vegetasjon og bart fjell kommer heller ikke frem. Ved å kun bruke ortofoto som input i segmenteringen, kan man

få en mye bedre løsning på de to sistnevnte problemene, men ortofoto-segentering vil prestere dårligere på avgrensinger basert på potensiell fuktighet. Det er viktig å legge merke til at ortofoto-segentering også påvirkes av opptaksdato, belysning og sesong/fenologi. Det gjør at man kan forvente resultater som ikke blir like robuste i sammenligning med segentering basert på potensiell forekomst av fukt. Den beste metoden blir sannsynligvis å benytte begge deler.

3.1.4 KLASSIFISERINGSRESULTATER

Tabell 5 viser høyest oppnådd gjennomsnitt i klassifiseringsnøyaktighet for alle klasser. Tabell 6 viser en liste over naturtyper som er en del av klassifiseringen. Nøyaktigheten varierer fra 64% til 77%. Vi ser at Random Forest, SVM og Neural Network scorer litt bedre enn kNN og Naive Bayes metodene.

Vi ser også at Hå 2014 25 cm ortofoto som grunnlag gir best resultat, men det er liten forskjell mellom datasettene. Det er litt merkelig at Hå 2014 10 cm ortofoto gir et dårligere resultat enn 25 cm versjonen av samme datasett. En årsak kan være at segenteringen av 10 cm bilder har gitt et litt dårligere resultat, det vil si, segmenter som er litt mindre eller litt mindre representative.

Gjennomsnittlig nøyaktighet er interessant, men det gir ikke mye innsikt i hvor feilene ligger og hva det betyr for klasse T34. En krystabell (confusion matrix) med klassifiseringsresultater per klasse gjør nettopp det.

Tabell 5. Oppsummering av høyest oppnådd nøyaktighet for alle klasser.

Classification accuracy (CA %) alle klasser			
	flyfoto		
metode	Rogaland 2013 25 cm	Hå 2014 25 cm	Hå 2014 10 cm
Random Forest	73 %	77 % (kappa 0.72)	69 %
SVM	72 %	75 %	70 %
kNN	64 %	72 %	65 %
Naive Bayes	65 %	65 %	60 %
Neural Network	71 %	76 %	69 %

Tabell 6. Naturtyper i klassifiseringen (+ klasse Skygge)

Type	Navn
L0	Ferskvannsbunnsystemer
L4	Helofytt-ferskvannssump
T1	Nakent berg
T21	Sanddynemark
T32	Semi-naturlig eng
T33	Semi-naturlig strandeng
T34	Kystlynghei
T4	Skogsmark
T41	Eng-liknende oppdyrket mark
T45	Oppdyrket varig eng
T6	Strandberg
V1	Åpen jordvannsmyr
V9	Semi-naturlig myr
Skygge	Skygge i bildene

Tabell 7. Krysstabell (confusion matrix) for Random Forest klassifikator med bruk av Rogaland 2013 25 cm ortofoto og laser-ekstrakter.

Actual	Predicted															Σ	producer's accuracy (%)
	L	L4	SK	T1	T21	T32	T33	T34	T4	T41	T45	T6	V1	V9			
L	24	0	0	0	0	0	0	0	0	0	0	0	0	0	0	24	100
L4	0	2	0	0	0	0	0	1	0	0	0	0	3	3	0	9	22
SKYGGE	1	0	9	1	1	1	0	0	1	0	0	1	0	0	0	15	60
T1	1	0	0	44	0	0	0	0	2	0	0	4	0	0	0	51	86
T21	0	0	0	1	2	0	0	0	0	1	0	0	0	0	0	4	50
T32	0	0	0	0	0	16	0	6	0	4	1	0	2	2	0	31	52
T33	0	0	0	1	0	1	3	0	0	0	0	0	2	2	0	9	33
T34	0	0	0	0	0	1	0	70	2	1	0	0	4	8	0	86	81
T4	0	0	0	0	0	0	0	1	44	0	0	0	0	0	0	45	98
T41	0	0	0	0	0	6	0	2	0	13	0	0	1	3	0	25	52
T45	0	0	0	0	0	0	0	0	0	0	30	0	0	0	0	30	100
T6	0	0	1	7	0	0	0	0	0	0	0	10	0	0	0	18	56
V1	0	1	0	0	0	0	0	5	0	1	1	0	21	8	0	37	57
V9	0	1	1	0	0	4	0	3	0	4	0	0	5	20	0	38	53
Σ	26	4	11	54	3	29	3	88	49	24	32	15	38	46	0	422	
user's accuracy (%)	92	50	82	81	67	55	100	80	90	5	94	67	55	43	0		
Classification accuracy			73%														
Kappa Index			0.70														


Tabell 7 er en slik krysstabell og den viser antall referanse-segmenter som har blitt riktig og feil klassifisert. Radene viser klasse-inndeling fra referansedataene, mens kolonnene viser hvilken klasse segmentet fikk i klassifiseringen. Diagonalen med grønne celler viser antall riktig klassifiserte segmenter, mens alle andre celler i midten viser antall feilklassifiserte segmenter. Vi ser for eksempel at klasse T34 har 86 segmenter i referansedataene, og at 70 av disse 86 ble klassifisert riktig. Vi ser også at 8 av 86 T34 segmenter har fått feilaktig klasse V9. Når man følger T34-radene nedover ser man at en del segmenter fra andre klasser ble feilaktig klassifisert på samme måte som T34: for eksempel 5 segmenter fra klasse V1. Producer's accuracy per klasse viser antall riktige treff i forhold til referansedataene. User's accuracy forteller noe om hvor sikker man kan være på at klassifiseringsresultatet for en klasse er riktig: for T34 kan man være 80% sikker på at et klassifisert segment virkelig er klasse T34.

Krysstabellen viser også hvilke klasser som blir forvekslet med hverandre (ligner på hverandre). For T34 er det tydelig at den ligner mest på V1/V9 og T32. Ikke alle feil og forvekslinger er like relevant for dette prosjektet. Det er ikke overraskende at T1, nakent berg, og T6, strandberg, ikke kan skilles så bra fra hverandre i klassifiseringen.

Ser man kun på nøyaktighet for T34 isolert, så viser Tabell 8 at den varierer fra 87% til 94%.

Tabell 8. Oppsummering av høyest oppnådd nøyaktighet for klasse Kystlynghei (T34).

Classification accuracy (CA %) for klasse T34			
	flyfoto		
metode	Rogaland 2013 25 cm	Hå 2014 25 cm	Hå 2014 10 cm
Random Forest	93 %	92 %	91 %
SVM	93 %	94 % (kappa 0.76)	92 %
kNN	91 %	93 %	92 %
Naive Bayes	88 %	91 %	87 %
Neural Network	92 %	94 % (kappa 0.76)	93 %



Figur 23. Klassifiseringsnøyaktighet for de ulike klassifiseringsmetoder og med ulikt antall variabler. Basert på Hå 2014 25 cm ortofoto

Figur 23 viser hvordan nøyaktigheten endrer seg ved endret antall input variabler som brukes i klassifiseringen. Tabell 9 viser rekkefølge (viktighet) på variablene. Vi ser at nøyaktigheten øker stadig etterhvert som flere variabler brukes, men at økningen stopper rundt 5 til 6 variabler. Samtidig ser vi at linjene blir mere ustabile fra 6 til 11 variabler. Grunnen til dette er at flere variabler er korrelerte. Noen klassifikatorer som SVM, Neural Network og Random Forest håndterer dette bedre enn andre (Naive Bayes).

Tabell 9 Variabler brukt i klassifiseringen i rekkefølge etter relevans.

nr.	variable	beskrivelse
1	FUKT_avg	Fuktighetsindeks
2	HSI_S	Saturation (fargetransformert fra RGB)
3	HSI_H	Hue (fargetransformert fra RGB)
4	NDSM_std	NDOM, standard avvik
5	NDSM_avg	NDOM, gjennomsnitt
6	HSI_I	Intensity (fargetransformert fra RGB)
7	RED_std	Rød kanal, standard avvik
8	BLUE_std	Blå kanal, standard avvik
9	GREEN_std	Grønn kanal, standard avvik
10	SOL_avg	Solinnstråling
11	GLCM_H_all	Haralick Homogenitet, alle retninger, rød kanal

Variabler som står øverst i tabellen bidrag mest til nøyaktigheten i klassifiseringen. Det kommer an på klassifiseringsmetode hvor mye hver variabel bidrar.

Rekkefølgen variablene ble tatt inn på påvirker også resultatet. Variabel nummer 2 (HSI_S) for eksempel, ville gitt et høyere bidrag hvis den hadde blitt brukt uten at variabel nummer 1 var med.

For å gjøre det litt mer komplisert er det også slik at variablene ble satt opp i rekkefølge etter Gini-indeksen. Ulike klassifikasjonsmetoder preferer ulik rangering av variabler. Derfor gir tabellen kun hovedtrekkene og her kan man ikke konkludere for mye om viktighet av variablene i detaljnivå (eksakt rekkefølge).

3.1.5 KLASSIFISERINGSRESULTATER – TEST AV KORRELASJON I REFERANSEDATAENE

Det er en risiko at referansepunktene som ble plukket ut innenfor NiN figurer er korrelerte. Figur 24 viser et eksempel: 6 rosa kystlynghei (T34) referansepunkt som ble valgt innenfor én NiN-figur. Det er mulig at punktene som ligger med kort avstand fra hverandre ligner på hverandre. Når vi tester klassifiseringen med kryssvalidering tar vi ikke hensyn til denne risikoen.

Vi kjører trening med 90% av referansedataene og validerer mot 10% av dem. I eksempelet betyr det at flere av de 6 punktene er med i treningen og kanskje 1 er med i valideringen. Dette kan gi et for gunstig estimat på nøyaktighet. Det kan

hender det er enklere å klassifisere det siste punktet innenfor samme figur riktig hvis man har brukt flere punkter innenfor samme figur til trening.



Figur 24. Eksempel referansepunkter innfor 1 NiN-figur.

Vi har testet om denne effekten kan ha forekommet i vår metode.

Vi har gitt alle referansepunkt som ligger i samme figur det samme cluster-id (klynge). Så har vi kjørt en kryssvalidering hvor alle referansepunkt fra samme klynge enten er med eller ikke i trening og validering.

Det finnes ikke nok referansepunkt i alle klasser til å kunne kjøre klassifisering på alle separate klasser på denne måten. Derfor har vi valgt å kjøre kystlynghei (T34) mot alle andre klasser, 1 gang med vanlig kryssvalidering og 1 gang med kryssvalidering per figur/klynge. Neural Network ble brukt som klassifikator fordi den ga stort sett best resultat i sammenligning med de andre metodene.

Figur 25 viser resultatene for kryssvalidering per figur/klynge og Figur 26 viser resultatet for «vanlig» kryssvalidering. Kryssvalidering per klynge har 1% lavere nøyaktighet og en kappa koeffisient som er 0.05 lavere. Dette betyr at det er litt korrelasjon mellom referansepunktene innenfor samme figur, men effekten er svært lavt. Innfor dette prosjektområdet er det ingen problem å velge ut flere referansepunkt innenfor samme NiN-figur, noe som effektiviserer generering av referansepunkt betydelig.

Figur 25. Test av korrelasjon: kryssvalidering per figur/klynge

	Kryssvalidering per figur/klynge		
	Predicted		
Actual	annet	T34	sum
annet	299	15	314
T34	22	64	86
sum	321	79	400
	overall accuracy	0.91%	
	Kappa	0.72	

Figur 26. Test av korrelasjon: kryssvalidering på «vanlig» måte.

	«Vanlig» kryssvalidering		
	Predicted		
Actual	Annet	T34	sum
Annet	320	18	338
T34	15	71	86
Sum	335	89	424
	overall accuracy	0.92%	
	Kappa	0.76	


3.1.6 KLASSIFISERINGSRESULTATER – USIKKERHETSKART

Vanligvis presenteres resultatet fra en klassifisering i et kart med «harde» klasser. Det vil si at hver figur får en klasse tildelt og ingenting imellom. Et eksempel vises i Figur 27.


Eventuelt kan man legge til generell informasjon om oppnådd gjennomsnittlig nøyaktighet i klassifiseringen til hver klasse i kartet. Ulempen er at gjennomsnittlig nøyaktighet ikke sier mye om en enkel kartfigur.

I klassifiseringen har vi brukt en 10 fold kryssvalidering for å kunne estimere nøyaktighet. Typiske resultater er en krysstabell som viser antall riktig og feil klassifiserte segmenter, samt uttrykk som klassifiseringsnøyaktighet, kappa koeffisient og så videre.

I tillegg har vi kjørt klassifiseringen 10 ganger på alle figurene, hver gang med bruk av kun 90% av treningsdataene. Resultatet ble 10 litt ulike klassifiseringsutfall for hver figur. Se Figur 28.



Figur 27. Resultat av en klassifisering av Kystlynghei (T34) (lilla) med kun «harde» klasser.



Figur 28. Resultat av en klassifisering av Kystlynghei (T34) med 10 kjøringer, hver gang med 90% av treningsdataene. Fargeskala får fra lys rosa (1 ut av 10 klassifiseringsrunder ble resultatet T34) til mørk rosa (10 ut av 10 ganger ble resultatet T34)

Figurer som får 10 ut av 10 ganger tildelt klasse T34 er de mest sikre T34 figurene, mens figurer med 0 ut av 10 ganger tildelt T34 er de mest sikre ikke-T34 figurene. Mellom de to ytterpunkter finnes det figurer som bytter klasser i de ulike klassifiseringsrundene.

Det finnes flere muligheter til å bruke dette kartet, for eksempel for:

- å finne forholdsvis sikre kystlynghei (T34) områder (10/10)
- å finne maksimalt areal som muligens er kystlynghei (T34), ifølge klassifiseringen*.
- å se lokalisering og mønster på områder som er ustabile i klassifiseringen.

* Legg merke til at det fortsatt kan finnes kystlynghei (T34) i områder som er 0/10 ganger klassifisert som kystlynghei. Dette er fordi

klassifiseringsalgoritmen, referansedatasettet og flyfoto-datasettet ikke er feilfrie.

Tabell 10 og Figur 29 viser fordelingen av klassifiseringsresultatet for de referansepunktene som ble brukt som grunnlag i klassifiseringen.


Totalt ble det brukt 86 referansepunkt for T34. 67 av disse ble klassifisert 10 ut av 10 ganger som T34, 4 fikk T34 9 av 10 ganger og så videre. 7 T34 referansepunkt ble aldri klassifisert som T34. Vi ser også at hovedtype V1 og V9 begge har 3 referansepunkt som ble klassifisert 10/10 ganger som kystlynghei (T34).

En annen mulighet for å estimere klassifiseringsnøyaktighet per figur er å bruke en metode som estimerer sannsynligheter etter klassifiseringen.

For eksempel for Support Vector Machine finnes det en metode basert på logistisk regresjon, foreslått av Platt (2000). Malley et al. (2012) beskriver lignende muligheter for Random Forest metoden.

Tabell 10. Antall ganger et referansepunkt ble klassifisert som T34 ut av 10 klassifiseringsrunder.

	antall ganger klassifisert som T34, forekomsten i antall.											
Hovedtype	0/10	1/10	2/10	3/10	4/10	5/10	6/10	7/10	8/10	9/10	10/10	sum
L	24											24
L4	9											9
T1	50	1										51
T21	4											4
T32	25		2	1							3	31
T33	8										1	9
T34	7	2	2	1	1		1		1	4	67	86
T4	44	1										45
T41	21	1	1		1		1			2		27
T45	30											30
T6	13	1			1	1					2	18
V1	30	2	1					1			3	37
V9	27	3		1	1		2	1			3	38
	antall ganger klassifisert som T34, forekomster i % av totalen											
Hovedtype	0/10	1/10	2/10	3/10	4/10	5/10	6/10	7/10	8/10	9/10	10/10	sum
L	100											100 %
L4	100											100 %
T1	98.04	1.96										100 %
T21	100											100 %
T32	80.65		6.45	3.23							9.68	100 %
T33	88.89										11.11	100 %
T34	8.14	2.33	2.33	1.16	1.16		1.16		1.16	4.65	77.91	100 %
T4	97.78	2.22										100 %
T41	77.78	3.70	3.70		3.70		3.70			7.41		100 %
T45	100											100 %
T6	72.22	5.56			5.56	5.56					11.11	100 %
V1	81.08	5.41	2.70					2.70			8.11	100 %
V9	71.05	7.89		2.63	2.63		5.26	2.63			7.89	100 %




Figur 29. Antall ganger et referansepunkt ble klassifisert som T34 ut av 10 klassifiseringsrunder.

3.1.7 KLASSIFISERINGSRESULTATER – AGGREGERING

Klassifiseringen ble utført og validert på det minste segmenteringsnivået (nivå 3). Det er imidlertid tydelig at dette segmenteringsnivået er for detaljert til å bli et sluttprodukt, hvis det skal være sammenlignbart med eksisterende NiN-kartlegging. Gjennomsnittsstørrelse på figurene i nivå 3 er på 33 m², mens gjennomsnittsstørrelse på NiN-figurer er på cirka 10 000 m². Se Tabell 4.

For å løse dette problemet kan man på en enkel måte ta i bruk de grovere segmenteringsnivåene som har blitt laget.

Figur 30 viser et eksempel på hvordan en figur på nivå 1 (rødt omriss) henger sammen med segmentene på nivå 3. Per figur finnes det eksakt informasjon om antall og areal på alle klassifiserte figurer fra nivå 3.



Figur 30. Eksempel på en figur på nivå 1 (rødt omriss) og klassifiseringsresultat på nivå 3 (til venstre). Figuren består av kystlynghei (T34) (rosa), myr V1 og V9 (gul-grønn) og nakent fjell (grått).

Det eneste man trenger er et sett med beslutningsregler for å bestemme i hvilken klasse figuren på nivå 1 hører hjemme.

For eksempel kan man bestemme at alle figurer

- med >40% kystlynghei (T34) på nivå 3 hører til kystlynghei klassen på nivå 1.
- med >40% nakent fjell på nivå 3 hører til nakent fjell klassen på nivå 1.
- med >40% skog hører til skog, men hvis resten består av kystlynghei (T34) hører til kystlynghei.


I tillegg til areal og antall figurer på nivå 3 har hver figur på nivå 1 også informasjon om fordeling av sub-arealene. Det finnes ulike indekser som sier noe om sub-arealene er spredt eller ligger i klynger.

Hvis figurene i nivå 3 ligger for mye i klynger, så kan man til og med bestemme (automatisk) at hele figuren på nivå 1 må deles opp.


Det er mulig å legge inn mange regler. Samtidig er det utfordrende å bestemme seg for ett optimalt resultat. Dette bør gjøres av sluttbrukere eller mer erfarne

naturkartleggere. Det kan hende at man bestemmer seg for flere versjoner avhengig av formål. Hvis formålet er vern av kystlynghei så kan man tenke seg å kun se på figurer med stor forekomst av kystlynghei. Hvis formålet er å se på endringer over tid så bør man se på alle områder, også figurer med lite forekomst av kystlynghei.

Største fordelen er at man har beslutningsregler som er transparente, objektive og homogene over større områder.



Figur 31. Figurer på nivå 1 fargelagt etter prosentandel av T34 på nivå 3.



Figur 32. Eksempel på aggregert figur med % forekomst av T34 som attributt. I tillegg har figuren % forekomst av alle klassifiserte naturtyper som attributter.

3.2 RESULTATER SENTINEL-2

Resultatene fra Sentinel-2 klassifiseringen presenteres på følgende måte:

- Vi har testet klassifiseringsnøyaktighet for alle klasser:
 - Med bruk av Sentinel-2 og laserekstrakter samtidig Tabell 12
 - Med bruk av kun Sentinel-2 Tabell 13
- Vi har testet klassifiseringsnøyaktighet for kun kystlynghei (T34):
 - Med bruk av Sentinel-2 og laserekstrakter samtidig: Tabell 14
 - Med kun bruk av Sentinel-2 data: Tabell 15

En liste over variabler fra Sentinel-2 og laserdata som ble brukt presenteres i Tabell 11.

Sentinel-2 dataene fra 4 ulike opptaksdatoer ble brukt:

- 06 mai 2017
- 05 juli 2017
- 27 august 2017
- 06 oktober 2017

Spektralinformasjon fra de ulike datoene ble ikke blandet: hver dato ble klassifisert for seg. For hver dato ble ulike klassifikasjonsmetoder testet.

Tabell 11 Variabler brukt i klassifiseringen. Alle variablene ble brukt samtidig.

Type	variable	beskrivelse
Sentinel-2	Bånd 2	Blått
Sentinel-2	Bånd 3	Grønt
Sentinel-2	Bånd 4	Rødt
Sentinel-2	Bånd 8	Nær-infrarødt
laserekstrakt	FUKT_avg	Fuktighetsindeks
laserekstrakt	NDSM_std	NDOM, standard avvik
laserekstrakt	NDSM_avg	NDOM, gjennomsnitt

Tabell 12. Oppsummering av høyest oppnådd nøyaktighet for alle klasser med Sentinel-2 og laserekstrakter

Classification accuracy (CA %) alle klasser				
Sentinel-2 data + laser-ekstrakter				
metode	mai	juli	august	oktober
Random Forest	67.6 %	66.6 %	66.1 %	65.4 %
SVM	70.8 %	68.1 %	63.4 %	64.1 %
kNN	70.0 %	70.0 %	68.3 %	63.1 %
Naive Bayes	53.8 %	58.5 %	54.1 %	48.4 %
Neural Network	72.5 %	70.8 %	65.4 %	67.8 %

Tabell 13. Oppsummering av høyest oppnådd nøyaktighet for alle klasser med kun Sentinel-2

Classification accuracy (CA %) alle klasser				
Kun Sentinel-2 data				
metode	mai	juli	august	oktober
Random Forest	58.5 %	56.5 %	57.0 %	54.3 %
SVM	59.2 %	56.8 %	56.0 %	56.3 %
kNN	59.0 %	59.0 %	57.2 %	52.8 %
Naive Bayes	38.8 %	40.0 %	40.5 %	32.4 %
Neural Network	61.2 %	58.7 %	60.7 %	60.7 %

Tabell 14. Oppsummering av høyest oppnådd nøyaktighet for kystlynghei (T34) med Sentinel-2 og laserekstrakter

	Classification accuracy (CA %) for klasse T34			
	Sentinel-2 data + laser-ekstrakter			
metode	mai	juli	august	oktober
Random Forest	88.9 %	86.2 %	86.2 %	88.2 %
SVM	91.2 %	88.7 %	86.7 %	88.5 %
kNN	90.2 %	89.2 %	88.9 %	89.0 %
Naive Bayes	85.5 %	88.2 %	88.5 %	81.8 %
Neural Network	91.9 %	89.9 %	88.5 %	88.0 %

Tabell 15. Oppsummering av høyest oppnådd nøyaktighet for kystlynghei (T34) med Sentinel-2 og laserekstrakter

	Classification accuracy (CA %) for klasse T34			
	Kun Sentinel-2 data			
metode	mai	juli	august	oktober
Random Forest	82.6 %	86.1 %	80.8 %	79.4 %
SVM	81.1 %	88.1 %	72.7 %	74.4 %
kNN	82.8 %	84.1 %	79.4 %	78.1 %
Naive Bayes	81.1 %	83.0 %	79.9 %	74.2 %
Neural Network	82.1 %	87.2 %	80.3 %	81.3 %

Nøyaktighet for alle klasser ligger rundt 66% og maksimalt på 72.5 % (Neural Network). Nøyaktighet for kystlynghei (T34) isolert når opp til 91.9 % (Neural Network).

Nøyaktigheten ligger litt lavere enn for ortofotoklassifiseringen: 77% for alle klassene og 94% for kystlynghei isolert.

Det er ikke mye forskjell mellom de ulike klassifiseringsmetodene, bortsett fra Naiv Bayes som presterer en del dårligere.

Vi ser at mai og juni gir litt bedre resultater enn august og oktober.

Vi hadde tenkt blomstringen av kystlynghei rundt august kunne bidra til litt bedre resultater, men det kan være mange grunner til at opptak fra vår og tidlig sommer gjør det enklere å skille mellom kystlynghei og de andre nærliggende klassene V1/V9 og T32.

4 DISKUSJON

4.1 KVALITET, UTFORMING OG GRUNNLAGSDATA

4.1.1 BRUK AV AR5 FKB DATA

AR5 brukes i NiN-kartleggingen som støttedata (bakgrunnskart) og i mange tilfeller også for å avgrense figurer direkte.

AR5 i vårt prosjektområde ser ut til å kunne bidra mye i avgrensningen av en del arealtyper og naturtyper.

Det er sannsynligvis mest effektivt å bruke AR5 som faste grenser i en segmentering, mens man segmenterer flere detaljer innenfor AR5-figurer med bruk av ortofoto og eventuelt fuktindeks.

Det er i hvert fall effektivt å bruke AR5 for å maskere ut en del arealtyper som man utelater i klassifiseringen.

En annen fordel med å bruke AR5 som grunnlag er at det knytter sammen kartet. Det betyr at man ved oppdateringer i framtiden kan forholde seg til oppdaterte versjoner av AR5, og ikke skape helt uavhengige datasett som må forvaltes og vedlikeholdes. Man må fortsatt vedlikeholde informasjon om naturtypene, men avgrensninger mot andre arealtyper slipper man å gjøre på nytt.

Legg merke til at vi kun har sett på ett prosjektområde, og at vi ikke har sett om AR5-kvalitet og aktualitet er representativt for alle potensielle kystlynghei-områder. Dette bør undersøkes nærmere før man tar beslutninger om å bruke AR5 som grunnlag.

4.1.2 SEGMENTERING

Det er mange muligheter til å segmentere dataene. Man kan bruke ulike kilder som ortofoto, derivater fra laserdata eller en kombinasjon av begge som forklart i avsnitt 3.1.3.

I tillegg kan man bruke ulike segmenteringsmetoder, samt nivåer (målestokk) og preferanser for segmentstørrelse og utforming (avsnitt 3.1.1).

Selv om det er krevende så er det teoretisk mulig å optimalisere segmenteringsprosessen, hvis det finnes en fasit for sluttresultatet. Det er nettopp

det som er utfordringen: Bryn & (2015) skriver at det ikke finnes noe fasit for å avgrense ulike kartelementer i naturkartlegging. Det samme område kan deles inn på mange ulike måter som kan være like riktige. Det finnes ofte myke overganger og mosaikker som gjør at eksakt avgrensning ikke er enkelt. Samtidig betyr det at eksakt avgrensning heller ikke er det viktigste, så lenge innhold til elementene er riktig.

Spørsmålet videre blir om en automatisert segmentering og klassifisering skal ligne mest på manuell NiN-kartlegging eller om resultatet skal se annerledes ut. Hvis manuell-kartlegging er fasiten så kan man forsøke å finne optimale rutiner ved å teste ut metoden på ulike områder og på resultater fra ulike kartleggere. Hvis resultatet kan se annerledes ut så bør sluttbrukeren komme med flere innspill om ønsket utforming av kartfigurene. Se avsnitt 5.2 for anbefalinger.

4.1.3 FASTE GRENSER ELLER FLYTENDE OVERGANGER?

Automatisk segmentering og klassifisering gjør det mulig å velge ulike sluttprodukter (kart). Tradisjonell kartlegging trenger avgrensninger, og man bestemmer klassene med tilhørende variabler. Automatiske metoder kan utføre prosessen på samme måte: segmentere bildene og bestemme klasse etterpå. Det blir imidlertid også mulig å produsere kart med flytende overganger: sannsynlighet på naturtype kystlynghei – T34- for eksempel. Se avsnitt 3.1.6 I tillegg kan man framstille et resultat med sannsynlighet for alle naturtyper som har vært med i klassifiseringen. Det blir kartografisk utfordrende å visualisere all informasjon samtidig, men ut ifra en komplett kart-base kan man visualisere den informasjonen man ønsker.

På samme måte kan man generere kart med ulik detaljeringsgrad ut ifra resultatene. Se avsnitt 3.1.7.

Alle mulighetene gjør at det blir utfordrende å beholde oversikten. For å bestemme retningen i grove trekk, bør brukerne og bestillerne komme med innspill.

4.1.4 SENTINEL-2 VERSUS FLYFOTO

Klassifiseringsnøyaktigheten var litt bedre for ortofoto klassifiseringen enn for den med Sentinel-2 i prosjektområdet: 77% versus 72.5% for alle klasser og 94% versus 91.9% for kystlynghei (T43) isolert. Det er ingen stor forskjell, og det kan skyldes tilfeldigheter: for eksempel at ortofotoene som ble brukt hadde høy kvalitet.

Over større områder kan man forvente større variasjon i resultatet med ortofoto enn med Sentinel-2 på grunn av variasjon i opptakskvaliteten på flybildene.

Den største forskjellen mellom å bruke ortofoto og Sentinel-2 i metodene er at ortofoto har en mye bedre detaljeringsgrad. Det er ikke mulig å generere kartfigurer som ligner på NiN-kartleggingen kun med Sentinel-2. Man kan heller ikke fange opp fine mosaikker av ulike naturtyper slik man kan med segmentering av ortofoto.

Til gjengjeld er Sentinel-2 mye enklere å håndtere i klassifiseringen enn ortofoto: Sentinel-2 består av mye mindre datamengder enn ortofoto over samme område: 10 meter oppløsning versus 25 cm oppløsning gir en faktor 40 flere piksler ved bruk av ortofoto. På den andre siden har Sentinel-2 standard 4 kanaler (mot 3 for ortofoto) og dobbelt så mye data per kanal (16 bits versus 8 bits) så til slutt gir Sentinel-2 «kun» 15 ganger mer data enn ortofoto.

Den største fordel med Sentinel-2 er at man står friere til å velge opptaksdato og år. Noe som er helt umulig ved bruk av ortofoto. Dette kan sørge for et mye mindre behov for referansedata til trening og validering av klassifiseringen.

En oppsummering av sammenligning mellom Sentinel-2 og flyfoto finnes i Tabell 16.

Tabell 16. Sammenligning mellom Sentinel-2 og flyfoto ved bruk i klassifisering.

	Flyfoto	Sentinel-2
Detaljeringsgrad	++	-- I forhold til mosaikk struktur
Valg av opptaksdato	-- Ingen valg	++ Flere valg gjennom sesongen
Valg av opptaksår	-- Ingen valg. Nye bilder i snitt hvert 5. år	++ Valgfritt, tilbake til 2016
Homogenitet av datasettet	- Noen gang homogent, men mange ganger svært varierende (sesong, belysning)	++ Homogent over store områder. Kan være litt utfordrende med skyer.
Kvalitet spektralt	- Kun 3 kanaler. Sjelden med IR som 4. kanal. Kun 8 bits per kanal. I praksis ikke mulig å korrigere for atmosfæren / radiometrien.	+ 4 kanaler på 10 meter Mulig støtte med flere kanaler på 20 meter. 12 bits per kanal Mulighet til atmosfærisk korreksjon.

4.1.5 KOMBINERT BRUK AV SENTINEL-2 OG FLYFOTO?

Både Sentinel-2 og ortofoto har sine svake og sterke sider. Man kan tenke seg å kombinere begge datakilder i en ny metode. Det er mulig å segmentere ortofoto for å utnytte den høye detaljeringsgraden og for å bruke Sentinel-2 data til å klassifisere, eventuelt som støtte i en kombinert klassifisering.

Dette har ikke blitt utviklet og testet i dette prosjektet.

4.2 OVERFØRBARHET TIL STØRRE OMRÅDER

4.2.1 BETYDNING AV FLYFOTOEGENSKAPER FOR RESULTATENE.

Det er viktig for automatisk klassifisering å ha konstant belysning i (fly-) bildene. Flybilder preges av belysningsvariasjon

1. innenfor et bilde, på grunn av sol-sensor og objekt geometri.
2. mellom bilder tatt på ulike tidspunkter på grunn av endring i solvinkel.
3. mellom bilder innenfor samme prosjekt på grunn av opptak på ulik dato og ulikt kamerasystem.
4. Mellom bilder tatt i ulike prosjekt på grunn av ulik opptakssesong og år.

Konsekvenser og resultatene er at større variasjon i belysning gir dårligere nøyaktighet i klassifiseringen.


Ulike tiltak kan gjøres for å håndtere utfordringene:

1. variasjon innenfor et bilde minskes på en bedre måte enn før med bruk av forbedrede programvarer av kameraleverandører. Dette er noe som gjøres standard av flyfoto-leverandører per i dag, men fokuset ligger ofte på et visuelt produkt, ikke på et produkt som er optimalt for automatisk klassifisering.
2. forrige punkt gjelder også for variasjon mellom bilder.
3. dette kan løses ved å ta inn flere referansepunkter.
4. dette kan også løses ved å ta inn flere referansepunkter.

I dette prosjektet har vi klassifisert et begrenset område. Bildene som dekker området ble tatt på samme dato og ser homogene ut.

Vi har ikke testet å blande bilder fra ulike dato, prosjekt, kamerasystem, sesong eller år. Selv om vi hadde testet noen kombinasjoner, ville det ha vært umulig å konkludere for alle mulige kombinasjoner i et større (nasjonalt) prosjekt.

Figur 33 viser planen for omløpsfotografering og dermed forventet antall blokker (prosjekter). Vi har ikke undersøkt hvor stor variasjonen i bildene er for de ulike omløps-blokkene. Dette kan gjøres ved å se på metadataene, da først og fremst på opptaksdatoene. Vi har sett nærmere på omløpsprosjekt Rogaland, og der ser vi at hele prosjektet er av 4 ulike opptaksdato (ikke 4 oppfølgende dager). I et eventuelt større prosjekt bør det gjøres en systematisk gjennomgang av metadataene samt en visuell vurdering av variasjonen i ortofotoene.



Figur 33. Program for omløpsfotografering: framover med årstall og bakover visualisert med farger.



Figur 34. Oversikt over datasett Rogaland 2013. Området er dekket i 4 opptaksdager og største delen av kysten er tatt i løpet av 2 dager.

Honkavaara (2014) gir en god oversikt over muligheter for radiometriske korreksjoner av flybilder for å gjøre dem mer egnet til automatisk klassifisering. Dette har ikke blitt testet i Norge enda, men det skal testes (Kastdalen 2017, Høgskolen i Sørøst-Norge. Personlig kommunikasjon).

Hvis man ønsker å utføre radiometrisk korreksjon på omløpsfoto må bildene prosesseres på nytt av leverandørene. I tillegg må det genereres ortofoto på nytt fra de reproseserte bildene. Begge oppgavene er svært arbeidskrevende. Dessuten mangler de fleste leverandørene (utenom Terratec og Blom) en produksjonsløype for denne typen radiometrisk korreksjon av flybilder.

4.2.2 KRAV TIL REFERANSEDATA

Referansedata er fundamentet til automatisk klassifisering. Referansedata er nødvendig for å trene klassifiseringsalgoritmer og for å validere resultatene. Validering er minst like viktig som trening fordi et klassifiseringsresultat ikke er mye verdt uten dokumentasjon om nøyaktighet.

I dette prosjektet har vi basert referansedataene på fototolkning og NiN-kartet. Det gir en effektiv måte å generere referansedata på:

- Man trenger ikke tidskrevende feltbesøk.
- Eksisterende arbeid (NiN) kan gjenbrukes.
- Man kan ta referansedata der det trenges.

Ulempen med denne metoden er at eventuelle feil i NiN-kartleggingen eller i fototolkningen forplanter seg videre i resultatet, uten at dette kommer fram i nøyaktighetsestimatene. For å validere resultatet uavhengig må et utvalg av referansepunktene oppsøkes og registreres i felt.

Det beste er å legge ut et tilfeldig grid med punkt som man besøker i felt, uavhengig av referansepunktene som tas med fototolkning. For å øke effektiviteten kan man eventuelt bruke NiN-kart ved utlegging av gridet. Slik kan man få felt-punkt mer riktig fordelt over klassene man ønsker å validere. Ved et helt tilfeldig grid er det større risiko for å få en del punkt som er overflødige, og noen klasser som får for få punkt for å kunne valideres uavhengig.

Feltregistreringen skal:

- Være homogen innenfor en sirkel med 10 meter radius, helst 20 meter radius hvis Sentinel-2 data brukes.
- Bestå av et nøyaktig oppmålt GPS punkt (innenfor 1 meter).
- Inneholde registrering av
 - naturtype.
 - Uttørkingsfate (UF)
 - Kalkinnhold (KA)
 - Hevdintensitet (HI)
 - Semi-naturlig hevdregime (HR)
 - Vannmetning (VM-A)
 - Tresjiktsdekning (1AG-A)
 - Busksjiktddekning (1AG-B)

Antall uavhengige referanseflater som trengs bestemmes av:

- Variasjon og utseende av naturtype
- Antall klasser/naturtyper som er med i klassifiseringen
- Ønsket feilmargin (ved et gitt konfidensintervall)


4.2.3 KOSTNADER OG TIDSBRUK

Prosjektet har testet ulike metoder og teknikker. Det er utfordrende å estimere tidsbruk og kostnader for alle muligheter som ble testet. Det er heller ikke realistisk å forvente at alle muligheter skal brukes i et eventuelt større prosjekt.

For å komme til et grovt estimat gjør vi følgende antakelser:

- Et fylke skal kartlegges, i dette eksempelet er det Rogaland.
- Produktet blir basert på OBIA.
- Som bilde data brukes ortofoto fra Norge i Bilder.
- Laserdata fra NDH brukes.
- Bestilleren har valgt at AR5 grenser gjelder i bestemte arealklasser.

Rogaland dekkes av 2 omløpsfotograferingsprosjekt, fra to ulike år.



Figur 35. Omløpsfotodekning over Rogaland Fylke. To datasett dekker hele fylke, Rogaland 2013 og Rogaland 2012 prosjektet.

Tabell 17. Estimert på tidsbruk for klassifisering av 1 fylke.

Aktivitet	Tidsbruk i dagsverk*
Tilrettelegging av NiN, AR5	5
Tilrettelegging av ortofoto og laserdata	5
Prosessering av laserdataene	10
Fototolkning utvalgt av referanseflater (2-3 runder)	10
Test av segmentering	5
Test av klassifiseringsoppsett (2-3 runder)	10
Oppsett av segmentering hele området. Kjøring og etterprosessering	10
Klassifisering av hele området	10
Aggregering av klasser til naturtyper (faste regler)	5
Etterprosessering	5
Rapportskriving.	5
Feltregistrering*	15*
Totalt	95

* 1 dagsverk tilsvarer 7.5 timer.

** 3x100 flater, 30 flater per dag, + reising

I tillegg til arbeidstimer kommer det reiseutlegg for cirka 15 dager feltarbeid.

Eksakt antall dager og referanseflater kan diskuteres.

Det kommer ingen materialkostnader i tillegg.

Estimatet tar ikke hensyn til at bestilleren bør bidra med valg av beslutningsregler for å aggregere kartfigurene. Dette prosjektet har ikke kommet i mål med det. En usikkerhet er hvordan områder uten potensiell forekomst av kystlynghei skal håndteres. Vi regner med å kunne maskere noen områder som for eksempel fjellområder.

95 dagsverk kan komme opp til om lag 800 000 Kroner + reise/diett-kostnader.

5 KONKLUSJON OG ANBEFALINGER

5.1 KONKLUSJONER

- Flyfoto (ortofoto) kan brukes for automatisk klassifisering av Kystlynghei (T34) og for å skille den fra nærliggende naturtyper.
- Avledede produkter fra laserdata som fuktindeks og normalisert overflatemodell øker nøyaktigheten betydelig.
- Gjennomsnitt nøyaktighet for alle klasser ble opp til 77% ved bruk av ortofoto og laserdata. Kappaverdien var på 0.72.
- Nøyaktighet for kun kystlynghei (T34) ble opp til 94% ved bruk av ortofoto og laserdata. Kappaverdien var på 0.76.
- Fuktindeks, basert på terrengmodell fra laserdata er den viktigste inputvariabelen i klassifiseringen.
- Ortofoto fra to ulike opptaksdato, mai og juni, ga omtrent samme nøyaktighet i klassifiseringen.
- Ortofoto med ulik oppløsning, 10 cm og 25 cm ga omtrent samme nøyaktighet i klassifiseringen.
- Flere klassifiseringsmetoder som Neural Network, Support Vector Machine og Random Forest gir omtrent like gode resultater.
- Sentinel-2 bilder fra 4 ulike opptaksdatoer ga (brukt separat) omtrent samme, men litt lavere klassifiseringsnøyaktighet enn ved bruk av ortofoto.
- Objektbasert bildeanalyse kan brukes for å lage kart over naturtyper som til en viss grad ligner på manuell naturkartlegging med NiN.
- Objektbasert bildeanalyse er mer fleksibelt enn manuell kartlegging i den forstand at et resultat kan bestå av ulike kart i ulike målestokk.
- AR5 ser svært nyttig ut og bør brukes som utgangspunkt i segmenteringen (delvis faste grenser), i hvert fall for å skille ut noen arealtyper.
- Objektbasert bildeanalyse og automatisk klassifisering kan levere et estimat på usikkerhet/nøyaktighet som et heldekkende kart.
- Referansedata kan genereres ved bruk av eksisterende NiN-kart og fototolkning, men bør komplementeres med uavhengig feltregistreringer.

5.2 ANBEFALINGER

Utforming av kartfigurer

Sluttbrukeren bør bestemme i større grad hvordan kartfigurene skal se ut: Hvis en automatisert metode skal etterligne manuell kartlegging kan segmenteringsmetoden optimaliseres. Hvis manuell kartlegging ikke er målet, bør sluttbrukeren komme med flere innspill om ønsket utforming av kartet: minste kartleggingsenhet, avgrensninger osv. Siden prosessen er automatisert er det mulig å kombinere flere valg i samme kart uten at det skaper betydelig ekstra arbeid. Se også avsnitt 4.1.2 for diskusjon.

Kombinasjon av Sentinel-2 og ortofoto

Ortofoto har som fordel at man kan kartlegge detaljerte figurer, og som ulempe at spektralverdiene ikke er så konstante (belysningen varierer).

Sentinel-2 har som fordel at belysningen er konstant og mulig å kalibrere på store områder. Ulempen med Sentinel-2 er at man ikke får kartlagt detaljerte figurer fordi oppløsningen kun er 10x10 meter.

Alt tilsier at Sentinel-2 og ortofoto er komplementære datakilder. Det er interessant å se om man kan utvikle en metode som kombinerer begge datasettene.

Fuktighetsindeks

Fuktighetsindeks er den viktigste variabelen i klassifiseringen. Derfor er det interessant å undersøke ulike fuktighetsindekser videre. Vi har brukt Topographic Wetness Index, men det finnes flere lignende metoder. Depth to Water index er det mest aktuelle alternativet. Bergkvist et al. (2014) konkluderer med at denne indeksen er den beste for å beskrive markfuktighet i forbindelse med kjøreskader ved hogstaktivitet i skogen.

Identifisering av gjengroing

Som forklart i innledningen, avsnitt 1.2 har vi ikke besvart spørsmålet om identifisering av gjengroing i semi-naturlige systemer.

Vi skisserte to mulige metoder, som begge trenger detaljerte feltregistreringer. Hvis man skal undersøke problemstillingen nærmere, bør det legges opp til en del feltregistreringer. Registreringene bør legges ut slik at de dekker variasjonen som er målt i fjernmålingsdatasettet eller -settene. Derfor er det viktig at man tenker på analysemetoden før man planlegger feltarbeidet.

- Den første metoden vi beskrev, utnytter to fjernmålingsdatasett (med ulikt opptakstidspunkt) og måler endringer.
- Den andre metoden krever kun et fjernmålingsdatasett og måler tilstand.

Fordelen med å bruke to fjernmålingsdatasett er at man kan få et mer nøyaktig estimat på gjengroing og endring. Den mest nøyaktige måten å måle (endringer i) vegetasjonshøyder og tetthet på er å bruke laserdata. Dessverre finnes det få områder i Norge med laserdata fra to ulike tidspunkt.

Et alternativ kan være 3D punktskyer fra bildematching. Disse kan lages på alle flyfoto som finnes, også på historiske flyfoto. Høydenøyaktighet er dessverre dårligere enn på laserdata.

Fordelen med å bruke kun ett fjernmålingsdatasett er at metoden kan brukes på nasjonalt nivå: hele landet kommer til å bli dekket med laserdata. Den største ulempen med metoden er at den kun gir et estimat på tilstand, ikke på endringer over tid. Dette trenger ikke å være et problem hvis det finnes entydige indikatorer på gjengroing, for eksempel faste terskelverdier. I praksis vil det være naturlig variasjon i høyde og tetthet av vegetasjonen uten at det er snakk om gjengroing. Dette betyr at man kun kan kartlegge gjengroing på en grovere måte. Man kan for eksempel kartlegge arealandel høyere busk-sjikt eller tre-sjikt, ikke små endringer i gjengroing.

HULE EIKER

1 INTRODUKSJON

1.1 MÅL

Målet var å undersøke muligheten for å identifisere enkeltobjekter slik som store gamle eiker ved hjelp av fjernmåling (Beskrivelsesvariablene 4 TG Gammelt tre og 4 TS Trestørrelse).

Prosjektet hadde som delmål å svare på følgende spørsmål: Kan man med tilfredsstillende nøyaktighet

- skille ut vegetasjon ved bruk av Nasjonal Detaljert Høydemodell (NDH) laserdata?
- kartlegge enkelttrær ved bruk av NDH laserdata?
- Skille mellom løvtrær og bartrær?
- Skille ulike typer løvtrær og særlig eik fra andre løvtrær?
- Estimere diameter i brysthøyde?

1.2 HULE EIKER

Naturtypen Hule eiker er definert som eiketrær med en diameter på minst 63 cm eller en omkrets på minst to meter i brysthøyde (1.3 meter over bakken). Hule eiker er beskyttet etter naturmangfoldloven. For eiketrær som er synlig hule gjelder beskyttelsen trær med minst 30 cm i diameter eller 95 cm i omkrets. Synlig hule trær er definert som trær med et indre hulrom større enn åpningen, og der åpningen er større enn 5 cm. Også døde hule eiker har store naturverdier og er fortsatt en utvalgt naturtype med lovfestet beskyttelse. Unntak er hule eiker i produktiv skog. Da eiker som ligger minst 20 meter inn i produktiv skog (Lovdata, 2011, MiljøDirektoratet/Landbruksdirektoratet, 2017).

1.3 PROSJEKTOMRÅDE

Prosjektområdet ble lagt til i Asker kommune. Asker er en kommune med forholdsvis store forekomster av (hule) eiker og mange verdifulle eiker er

registrert (Biofokus, 2013). Prosjektområdet består av urbane områder, gammelt kulturlandskap og overgang til skogsområder.



Figur 36. Prosjektområdet hule eiker i Asker kommune

2 MATERIALE OG METODE

2.1 MATERIALE

2.1.1 LASERDATA

To ulike laserdatasett ble brukt i prosjektet. Et fra 2010 med 2 punkt per m² og et fra 2012 med 10 punkt per m². Datasettet med 2 punkt per m² har nesten de samme egenskaper som 2-punkts laserdata fra Nasjonal Detaljert Høydemodell (NDH).

Tabell 18. Laserdatasett i prosjektområdet hule eiker.

Prosjektnavn	Ukjent	LACHOA27
År	2010	2012
Selskap	Blom Geomatics	Terratec AS
Sensor	Optech ALTM Gemini	Leica ALS70
opptaksdato	28.05.2010 til 02.06.2010	22.06.2012 til 21.08.2012
Punkttetthet (pkt/m2)	2	10

2.1.2 FLYFOTO

Prosjektområdet dekkes av flere flyfoto opptak, men ikke alle datasettene dekker hele prosjektområdet. Følgende datasettene ble valgt ut:

Tabell 19. Ortofotodatasett i prosjektområdet hule eiker.

Prosjektnavn	Asker og Bærum 2012	Asker 2014
År	2012	2014
Selskap	Terratec	Blom Geomatics
Sensor	Vexcel UltraCamXP	Vexcel UltraCamXP
Opptaksdato	20-06-2012	01-09-2014
GSD (cm)	20	10
Spektrale kanaler	4: Rød, Grønn, Blå, Nær-Infrarød	3: Rød, Grønn, Blå

2012 datasettet ble valgt ut fordi den består av 4 spektrale kanaler og dermed har nær-infrarød informasjon i tillegg til «standard» registrering rødt, grønt og blått lys.

De fleste kamera som brukes til flyfotografering i (Geovekst) Norge tar opp nær-infrarød informasjon, men det er sjeldent at disse dataene bestilles, prosesseres og leveres.

De fleste bebygde strøk og sentrale områder i landet dekkes av flyfoto med 10 cm oppløsning. Øvrige områder i Norge dekkes av flybilder med 20 eller 25 cm oppløsning.

Ortofoto er et georeferert flybilde slik at bildet har samme geometriske egenskaper som et kart og kan brukes til kartlegging og analyser.

Ortofotoene ble lastet ned fra Norge i Bilder (www.norgeibilder.no).

Ortofotoene som ble brukt har 3 fargebånd: rødt, grønt, blått og et 4. fargebånd for 2012 dataene: nær-infrarødt. Hvert bånd inneholder 8 bits data, det vil si at fargeverdiene går fra 0 (mørkest) til 255 (lysest). Dette er standarden for hele ortofotoarkivet i Norge i bilder.

2.1.3 STØTTEDATA

I prosjektet ble det brukt FKB data som støttedata: FKB bygninger som inneholder polygoner som representerer omrisset til bygningene.

2.1.4 REFERANSEDATA

Som referansedata ble det samlet inn posisjon og treslag for enkelttrær i prosjektområdet med bruk av fire kilder:

- Naturbase
- Feltbefaring
- Ortofoto
- Streetview

Vi har brukt 127 kartlagte eiketrær som ligger i naturbasen. Hvis nødvendig ble posisjonen kontrollert og eventuelt justert med bruk av ortofoto eller etter feltbefaring. I felt har vi kartlagt 183 trær med posisjon og treslag. Posisjonene ble registrert med bruk av laserdata. Det ble ikke målt inn eksakt stammeposisjon

med GPS i felt. Fra ortofoto har vi hentet 125 grantrær med bruk av bildetolkning. Med bruk av Streetview (gatebilder) har vi registrert 82 trær til.

Fototolkning ble kun brukt for å kartlegge treslag som er relativt enkle å kjenne igjen.

Tabell 20. Liste over referansetrær som ble samlet inn: treslag og hvilken kilden ble brukt.

	Kilde				
Treslag	felt	naturbase	ortofoto	StreetView	Totalt
Alm	8				8
Ask	30			3	33
Dunbjørk	11			30	41
Eik	20	127			147
Furu	3			18	21
Gran			125	30	155
Gråor	2				2
Hassel	1				1
Hengebjørk	6				6
Hestekastanje	2			1	3
Kirsebær	7				7
Lind	25				25
Osp	1				1
Platanlønn	4				4
Rogn	27				27
Selje	2				2
Spisslønn	34				34
Totalt	183	127	125	82	517

2.2 OVERSIKT METODE

2.3 BEARBEDING / PREPROSESSERING

2.3.1 BEARBEIDING LASERDATA


Se avsnitt 2.2.1 i Kystlynghei-delen av rapporten for en nærmere beskrivesels av bearbeiding av laserdataene.

2.3.2 BEARBEIDING ORTOFOTO

Ortofotoene ble brukt direkte i analysene uten noen justering eller fargekorrigering.

2.3.3 ENKELTTRE-SEGMENTERING

Normalisert Digital overflatemodell (NDOM) ble brukt for å segmentere enkeltrær. Inverse watershed segmentation ble brukt som segmenteringsmetode. Inverse watershed segmentation tar en overflatemodell som utgangspunkt og starter med å finne lokale toppe (maksima) i modellen. Figur 37 viser toppene med gule kryss. Så inverteres modellen (man kan forestille seg dette ved å snu modellen opp ned). Modellen «fylles opp» fra hvert kryss, helt til den møter en kant eller et annet segment som har blitt «fylt opp».



Figur 37: Visuell forklaring av en inverse watershed segmentation for å detektere enkeltrær i laserdata. Identifisering av lokale maksima (topper) vises til venstre. Invertering av modellen og «oppfylling» vises til høyre.

Resultater er en samling av flater som representerer trekrone-omriss. Figur 38 viser et eksempelområde. Resultatet blir aldri perfekt og antall feil avhenger av algoritmen med de eventuelle innstillinger som brukes, størrelse, fasong og plassering av trekronene, samt detaljeringsgraden av laserdataene (punktettheten). Vi skiller mellom 3 type feil:

- Over-segmentering: en trekrone blir delt opp i flere segmenter.
- Under-segmentering: flere trekroner blir slått sammen til ett segment.

- Andre feil: segmentet kan inkludere andre objekt enn trekronen, for eksempel en del av en bygning eller en kabel.



Figur 38. Eksempel på trekroner dannet med bruk av inverse watershed segmentation.

Bygninger ble maskert ut med bruk av FKB data.

2.3.4 BEREGNING AV EGENSKAPER FRA LASER OG BILDER

Hver enkelt-trekrone ble brukt til å beregne statistiske mål fra laserdataene og ortofotoene.

Laserdata

Fra laserdataene ble det ekstrahert informasjon om høyde og høydefordeling av punktene innenfor trekronen. For eksempel høydefordelingens 90 percentil, dvs. høyden på laserdata der 90 % av observasjonen har en lavere høyde.

Tabell 21. Liste over laservariabler som ble brukt i klassifiseringen.

variabel	beskrivelse (alle variabler er høydevariabler)		variabel	beskrivelse (alle variabler er høydevariabler)
min	minimum		p90	90. persentil
max	maksimum		p95	95. persentil
avg	gjennomsnitt		p99	99. persentil
qav	gjennomsnitt kvadratisk		b10	% andel punkt som er mellom cutoff-height* og 10 persentil-høyde
std	standard avvik		b20	% andel punkt som er mellom cutoff-height* og 20 persentil-høyde
ske	skewness		b30	% andel punkt som er mellom cutoff-height* og 30 persentil-høyde
kur	kurtosis		b40	% andel punkt som er mellom cutoff-height* og 40 persentil-høyde
p10	10. persentil		b50	% andel punkt som er mellom cutoff-height* og 50 persentil-høyde
p20	20. persentil		b60	% andel punkt som er mellom cutoff-height* og 60 persentil-høyde
p30	30. persentil		b70	% andel punkt som er mellom cutoff-height* og 70 persentil-høyde
p40	40. persentil		b80	% andel punkt som er mellom cutoff-height* og 80 persentil-høyde
p50	50. persentil		b90	% andel punkt som er mellom cutoff-height* og 90 persentil-høyde
p60	60. persentil		dns	antall treff over cutoff-height* delt på totalt antall treff
p70	70. persentil		Int_avg	Gjennomsnitt intensitet
p80	80. persentil		Int_std	Standardavvik intensitet

*cutoff height er satt til 1 meter over bakken.

Ortofoto – spektrale verdier

Fra ortofoto ble det ekstrahert informasjon om fargeverdiene innenfor hver trekrone, for eksempel gjennomsnittsverdi per fargekanal. Informasjon om nær-infrarødt var kun tilgjengelig i bildene fra 2012.

Tabell 22. Liste over ortofotovariablene som ble brukt i klassifiseringen.

variabel	beskrivelse
BLUE_avg	gjennomsnitt blå
GREENavg	gjennomsnitt blå
RED_avg	gjennomsnitt blå
RED_q50	median rød
GREEN_q50	median grønn
BLUE_q50	median blå
GREEN_q90	90 persentil grønn
BLUE_q90	90 persentil blå
RED_q90	90 persentil rød
GREEN_std	standardavvik grønn
RED_std	standardavvik rød
BLUE_std	standardavvik blå
HSI_H	fargetransformert IHS, Hue
HSI_I	fargetransformert IHS, Intensity
HSI_S	fargetransformert IHS, Saturation
NIR_avg	gjennomsnitt nær-infrarød (kun 2012 bilder)
NIR_q50	median nær-infrarød (kun 2012 bilder)
NIR_q90	90 persentil nær-infrarød (kun 2012 bilder)
NIR_std	standardavvik nær-infrarød (kun 2012 bilder)

Ortofoto – Image embedding og Neural Network

I tillegg til statistikk på spektrale verdier ble det ekstrahert informasjon med Inception v3 modellen fra Google Tensorflow (Szegedy et al. 2015).

Et bilde på 5 x 5 meter ble klipt ut for hver tretopp. Fra hvert bilde ble det laget 2048 avlede bilder som inneholdt karakteristiske egenskaper. Inception v3 modellen er lært opp til å gjenkjenne andre typer objekter i bilder enn treslag fra flyfoto, men modellen er muligens anvendbar allikevel. Det er arbeidsintensivt å trene egne modeller, fordi det krever mange eksempler (i størrelsesorden av 10 000 – 100 000; jo flere desto bedre).

Appendiks Samples enkelttrær ortofoto 2014' viser alle bildene som ble generert.

2.3.5 KLASSIFISERING

Følgende klassifiseringsmetoder ble brukt med «vanlige spektrale verdier fra trekrone-segmenter»:

- Random Forest (RF)
- Support Vector Machine (SVM)
- kNN
- Neural Network (NN)

Se avsnitt 332.3.3 fra kystlynghei-delen i rapporten for en beskrivelse av metodene.

Det finnes mange egenskaper fra laser- og bildedataene som kan brukes i klassifiseringen. For å velge de mest relevante egenskapene ble alle egenskaper sortert i rekkefølge ved bruk av Gini-indeksen. Gini-indeksen prøver å estimere en egenskap sin mulighet til å skille mellom klassene. (Breiman et al. 1984).

Image embedding og Neural Network

I tillegg ble det brukt image embedding og Neural Network fra Google Tensorflow. Tensorflow er en åpen kildekode som kan brukes til bildegjenkjenning. Tanken er at det ligger mer informasjon i bildene rundt tretoppene enn kun enkel statistikk om spektrale verdier. I noen flyfoto-datasett virker det å være tydelig forskjell i mønster mellom ulike trær.

2.4 ESTIMERING AV STAMMEDIAMETER

Vi har undersøkt om det er noe sammenheng mellom trehøyde estimert fra laserdata og stammediameter som registrert i naturbasen.


3 RESULTATER

3.1 KVALITET ENKELTTRE-SEGMENTERING


Figur 39, Figur 40 og Figur 41 viser eksempler på segmentering basert på både 2 punkt/m² og 10 punkt/m² laserdata. Bokstav «A» viser et tilfelle av under-segmentering, bokstav «B» et tilfelle av over-segmentering. Bokstav «C» viser en riktig segmentering, men treet finnes ikke lengre i 2014 (ortofoto).

Vi har ikke gjort en kvantitativ kontroll av over- og under-segmenteringen. Vi har heller ikke brukt mye tid på å justere parameterne på segmenteringsalgoritmen. Mulige innstillinger i algoritmen er å sette terskelverdier på tillat størrelse av en trekrone, både i areal eller kronevolum, og tillat høydeforskjell mellom nabo-segmenter.


En generell vurdering er at resultatet ser bra ut, men at store løvtrær viser en del over-segmentering. Det er mulig å minske denne andelen, men det vil ha som bi-effekt at en del mindre trær som står nær hverandre blir undersegmentert. Videre finnes det en del treklynger som ikke lar seg segmentere riktig med denne metoden. Vi ser at resultatet fra 2 punkts laserdata blir akseptabelt og at det ikke kreves 10 punkts laserdata, i hvert fall ikke for å segmentere litt større trær (om lag >15 meter høyde).



Figur 39. Eksempel på enkelttre-segmentering. I rødt vises resultatene som er basert på 2 punkt/m² laserdata og i blått vises resultatene basert på 10 punkt/m². Ortofoto fra 2014 i bakgrunnen.



Figur 40. Eksempel på enkelttre-segmentering. I blått vises resultatene basert på 10 punkt/m². NDOM fra de samme laserdataene i bakgrunnen.



Figur 41. Eksempel på enkelttre-segmentering. I rødt vises resultatene basert på 2 punkt/m². NDOM fra de samme laserdataene i bakgrunnen.

3.2 TRESLAGSKLASSIFISERING

3.2.1 RESULTATER FOR ALLE TRESLAG

Som en start er det interessant å se hva resultatet blir når man forsøker å klassifisere alle treslag hver for seg. Det var forventet at det ikke skulle bli enkelt å skille mellom ulike løv-treslag med vanlige flybilder, og vi ser i Tabell 23 at resultatene ikke er så gode. Det er flere feilklassifiseringer enn riktige og de fleste treslag får en lav nøyaktighet. En gjennomsnittlig nøyaktighet på 46% og en kappa indeks på 0.39 er ikke bra. Det var Neural Network med image embedding basert på ortofoto fra 2014 som ga best resultat og som presenteres i denne tabellen.

Eik-klassifiseringen gjør det forholdsvis bra, med 26 ut av 44 trær riktig, men samtidig blir flere trær klassifisert som Eik enn det de burde: 58 i stedet for 44. Noen klasser scorer svært dårlig med 0% nøyaktighet. En av grunnene er at det finnes få eksempler i disse klassene: Kirsebær-klassen består av 7 trær og det er ikke nok til å lære opp klassifiseringsrutinen. Klasser med enda færre trær, for eksempel hassel, kan ikke få en nøyaktighetsprosent fordi den ikke kan beregnes med kun 1 sample (Hvis sampelet er med som treningsdata kan den ikke være med i valideringen).

Tabell 23. Nøyaktighet på klassifisering av alle treslag, med Neural Network - image embedding metode, basert på ortofoto fra 2014.

	Predicted																
Actual	alm	ask	bjørk	eik	furu	gran	hassel	kastanje	kirsebær	lind	lønn	or	Poppel	rogn	vier	Σ	producer's accuracy (%)
alm	0	1	1	5	0	0	0	0	0	1	0	0	0	0	0	8	0
ask	0	27	0	0	1	1	0	0	0	0	4	0	0	0	0	33	82
bjork	0	1	16	9	2	1	0	0	0	6	3	0	0	1	0	39	41
eik	1	1	3	26	3	0	0	0	1	3	3	0	0	3	0	44	59
furu	0	2	3	1	7	1	0	0	0	2	2	0	0	3	0	21	33
gran	0	1	3	0	1	13	0	0	0	0	1	0	0	3	0	22	59
hassel	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0
kastanje	0	0	0	1	0	0	0	0	1	0	0	0	0	1	0	3	0
kirsebær	1	0	1	2	0	0	0	0	0	1	0	0	0	2	0	7	0
lind	2	2	5	5	1	0	0	0	0	5	5	0	0	0	0	25	20
lønn	0	2	6	4	2	1	0	0	0	3	19	0	0	1	0	38	50
or	0	0	2	0	0	0	0	0	0	0	0	0	0	0	0	2	0
poppel	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0
rogn	0	1	1	3	3	1	0	0	1	2	1	0	0	13	0	26	50
vier	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	2	0
Σ	4	38	42	58	20	18			3	24	38			27		272	
user's accuracy (%)	0	71	38	45	35	72	-	-	0	0	0	-	-	48	-		
Classification accuracy			46%														
Kappa Index			0.39														

3.2.2 RESULTATER FOR BAR-LØV OG EIK-LØV

For å kunne finne ut mer om hvilke klassifiseringsalgoritmer og hvilke flybilder som presterer bedre, bør klassene slås sammen. Ellers kan klasser med svært få samples forstyrre resultatene. Tabell 24 viser oppnådde resultater når man skiller mellom bar-trær (gran og furu) og løvtrær (alle løv treslag), og når man skiller mellom eik og andre løvtrær.

Tabell 24. Nøyaktighet på klassifisering av bar- versus løvtrær og av eik versus andre løvtrær, basert på ortofoto fra 2014 og fra 2012

Klassifiseringsnøyaktighet (%) og Kappa-koeffisient i parentes					
Ortofoto 2014			Ortofoto 2012		
metode	bar – løv	eik - løv		bar - løv	eik - løv
NN-IE	80.2% (0.60)	72.1% (0.44)		70.5% (0.41)	80.1% (0.60)
NN	71.5% (0.43)	64.2% (0.28)		74.5% (0.49)	77.8% (0.56)
SVM	67.5% (0.35)	50.3% (0.01)		72.0% (0.44)	65.3% (0.31)
kNN	60.0 % (0.2)	55.9% (0.12)		71.5% (0.43)	70.5% (0.41)
RF	63.5% (0.27)	59.7% (0.19)		71.4% (0.43)	70.5% (0.41)

Tabellen viser et ganske bra resultat for eik versus andre løvtrær, på 80.1 % med en kappa-verdi på 0.60, basert på ortofoto fra 2012. Samtidig ser vi at samme klassifiseringsmetode gir et betydelig dårligere resultat når man bruker ortofoto fra 2014, på 72.1% med en kappa-verdi på 0.44.

Tabellen viser at Neural Network med image embedding stort sett gir bedre resultater enn de andre metodene. Vi ser også litt bedre resultater når vi skiller mellom bar- og løvtrær. Ut av erfaring vet vi at særlig grantrær skiller seg mer ut, så dette resultatet er som forventet. Det er allikevel litt rart at bar-løv klassifisering på 2012 ortofoto ikke gir så gode resultater for Neural Network med image embedding: 70.5 % klassifiseringsnøyaktighet.

Tabellen viser også at resultatene basert på ortofoto fra 2012 er stort sett bedre for de ulike klassifiseringsmetodene enn resultatene fra 2014.

Neural Network med image embedding gir forholdsvis bedre resultater enn de andre metoder med ortofoto fra 2014, mens 2012 ortofoto gir et annet bilde: neural Network med image embedding gjør det ikke mye bedre, og av og til dårligere. En grunn kan være forskjell i GSD: 2014 bildene har 10 cm og 2012 bildene har 20 cm GSD. Neural Network med image embedding bruker i større grad tekstur i ortofoto, mens de andre metoder stort sett har brukt spektrale gjennomsnittsverdier per trekrone. Det kan hende at bedre GSD gir mer informasjon om tekstur i 2014-bildene. Det finnes imidlertid flere mulige forklaringer: 2014-bildene ble tatt i september mens 2012-bildene ble tatt i juni.

Det kan også hende at tidspunktet på dagen gjør belysningen bedre for ett av datasettene. Til slutt er det mulig at ulik bildeprosessering er årsaken.

3.2.3 RESULTATER MED OG UTEN IR. 2012

Flybildene fra 2012 ble levert med informasjon i den nær-infrarøde kanalen. Tabell 25 viser resultatene med og uten bruk av denne kanalen. Det beste resultatet for bar- versus løvtrær går betydelig opp fra 74.5 % til 82.0 % og for eik versus løv litt opp fra 77.8 til 79.2 %. Vi har ikke testet om økningen er signifikant. I begge tilfeller er det Neural Network som er den beste metoden.

Tabell 25. Nøyaktighet på klassifisering med og uten bruk av den nær-infrarøde kanalen, basert på ortofoto og fra 2012.

Klassifiseringsnøyaktighet (%) og Kappa-koeffisient i parentes					
Ortofoto 2012					
	bar – løv			eik - løv	
metode	Uten NIR	Med NIR		Uten NIR	Med NIR
NN	74.5% (0.49)	82.0% (0.64)		77.8% (0.56)	79.2% (0.58)
SVM	72.0% (0.44)	69.0% (0.38)		65.3% (0.31)	58.0% (0.16)
kNN	71.5% (0.43)	79.5% (0.59)		70.5% (0.41)	66.3% (0.33)
RF	71.4% (0.43)	73.0% (0.46)		70.5% (0.41)	76.0% (0.52)

Klassifiseringsmetoden Neural Network med image embedding ble ikke testet her fordi den ikke fungerer på 4 kanals bilder, men kun på 3 kanals bilder. Vi kunne ha testet med følgende 3 kanaler: NIR, rød, grønn, men dette er ikke testet.

3.2.4 RESULTATER MED BRUK AV LASEREKSTRAKTER

I stedet for å bruke billedata til klassifisering av treslag er det også mulig å bruke laserdata. Avsnitt 2.3.4 beskriver hvilke variabler som ble beregnet per trekrone.


Tabell 26. Nøyaktighet på klassifisering av bar- versus løvtrær og av eik versus andre løvtrær, basert på laserdata med 2 punkt / m².

Klassifiseringsnøyaktighet (%) og Kappa-koeffisient i parentes					
Laserdata (2 pkt/m ²)					
metode	bar – løv	eik - løv		bar – løv	eik - løv
NN	85.0% (0.70)	77.4% (0.55)		69.5% (0.39)	75.7% (0.51)
Antall variabler brukt	5	7		1	1
Variabler	dns std p95 p80 b30	std p70 p80 p90 p95 qav p60		p95	p95

Tabell 26 viser resultatene for Neural Network Metoden med den best oppnådde nøyaktigheten fra venstre side. Her ser vi at nøyaktigheten er høyere enn ved bruk av ortofoto. Gini-indeks ble brukt for å putte variablene i rekkefølge av høyest forklaringsgrad og tabellen viser hvilke variabler som ble valgt ut.

For å skille mellom bar og løv var det optimalt å bruke 5 laservariabler. Bruk av flere variabler ga ikke et betydelig bedre eller dårligere resultat.

Det er litt uforventet at klassifisering med laserdata gir bedre resultater enn ved bruk av ortofoto, men det finnes en viktig forklaring på dette. På høyre side i tabellen vises resultatet med bruk av kun 1 laservariabel: 95 persentilhøyde. Den tilsvarer cirka trehøyde. Det er litt mistenkelig at vi klarer å oppnå et ganske bra resultat ved å kun bruke trehøyde som input-variabel. En mulig forklaring er at de ulike treslagene i felt-datasettet ikke har en lik fordeling av trehøyder. Gran-klassen for eksempel, inneholder flere trær med høyde over 26 meter, mens noen løv-klasser består av mange forholdsvis nyplantede allé-trær. Eiketrærne i felt-datasettet holder seg stort sett mellom 13 og 26 meter. Se Figur 42.



Figur 42. fordeling av trenings- og valideringstrær i høydeklasser, basert på laserhøyde p95.

3.2.5 RESULTATER MED EN KOMBINASJON AV BILDER OG LASER

Vi har testet klassifisering med bruk av ortofoto (med og uten nær-infrarødt) og med bruk av laserdata separat, men det er også mulig å teste bruk av laser og billededata samlet. Tabell 27 viser en oversikt over høyest oppnådd nøyaktighet med alle kombinasjoner av bruk med ortofoto 2012, 3 RGB kanaler, 4 kanaler (RGB og nær-infrarødt), og laserdata. Tabellen viser kun resultater for Neural Network metode, som stort sett ga best resultat. Neural Network med image embedding ga bedre resultat på kun bruk av RGB ortofoto (se avsnitt 3.2.2) men den metoden har ikke blitt testet på nær-infrarøde bilder, og heller ikke på en kombinasjon av laser- og billededata.

Tabell 27. Nøyaktighet på klassifisering av bar- versus løvtrær og av eik versus andre løvtrær, basert på laserdata med 2 punkt / m² og ortofoto.

Klassifiseringsnøyaktighet (%) og Kappa-koeffisient i parentes			
Ortofoto 2012			
	bar – løv		
Metode (NN)	RGB	RGB + NIR	Ingen ortofoto
Uten laser	74.5% (0.49)	82.0% (0.64)	-
Med laser	86.0% (0.72)	84.5% (0.69)	85.0% (0.70)
	Eik – løv		
Metode (NN)	RGB	RGB + NIR	Ingen ortofoto
Uten laser	77.8% (0.56)	79.2% (0.58)	-
Med laser	80.2% (0.60)	81.3% (0.63)	77.4% (0.55)

I tabellen ser vi at for bar-løv klassifisering med bruk av kun 3 kanals RGB ortofoto gir dårligst resultat. Bruk av NIR eller laser i tillegg, eventuelt kun laser, gir bedre resultater.


For eik-løv klassifisering er det ikke så store forskjeller. En kombinasjon av RGB og laser eller RGB + NIR og laser gir litt bedre resultater, men vi har ikke testet om forskjellen er signifikant.

3.3 ESTIMERING AV TRE-EGENSKAPER


Ved enkelttre-taksering i skog brukes det sammenhenger mellom trehøyde og stammediameter, målt i felt på noen prøvetrær, for å estimere stammediameteren ut ifra laserhøyder på trærne. Stammediameter måles i brysthøyde (1.3 meter) og variabelen kalles diameter i brysthøyde (dbh).

I dette prosjektet har vi ikke målt stammediameter i felt selv, men har sett på dataene i naturbasen. Figur 43 viser relasjonen mellom trehøyde (representert av laserpersentil 95) og stammediameter målt i felt (fra naturbase), eller bedre sagt: figuren viser at det ikke finnes noen sammenheng. Vi ser at en eik på cirka 15 meter kan ha alt fra en diameter på 15-20 cm til en diameter på 160 til 200 cm. Vi har forsøkt noen modeller med bruk av laserdata, men har ikke klart å finne sammenheng (r^2 tilsvarende 0). Det er svært stor spredning i stammediameter og

dette er ikke uforventet. Det er stor variasjon i alder og skjøtsel av eiketrær i urbane strøk og i kulturlandskapet.



Figur 43. Sammenheng mellom trehøyde (laserpersentil 95) i meter på x-aksen og stammediameter DBH i centimeter på y-aksen.



Figur 44. Sammenheng mellom trekroneareal i kvadratmeter på x-aksen og stammediameter DBH i centimeter på y-aksen.

Figur 44 viser relasjonen mellom trekroneareal og stammediameter. Her ser vi en liten trend, men også i denne ser vi dårlig sammenheng (r^2 på 0.1-0.2). I tillegg vet vi at eksakt trekrone-areal på større, mer kompliserte løvtrær, ikke er feilfritt på grunn av over-segmentering (1 trekrone blir feilaktig delt opp i flere del-kroner).

4 DISKUSJON

4.1 ER NDH LASERDATA EGNEDE FOR ENKELTTRE KARTLEGGING?

NDH laserdata kommer med to ulike punkttettheter: 2 punkt/m² og 5 punkt. 5 punkts data anvendes over urbane strøk, områder med mye infrastruktur og utvalgte områder i forbindelse med arkeologisk kartlegging. Resten av landet tas med 2 punkts data bortsett fra fjellområdene (uten vegetasjon).

Det er viktig å vite om metoden for å kartlegge enkeltrær er bra nok med 2 punkts og 5 punkts laserdata. Vi testet enkelttre-segentering med 2 og 10 punkts data. Vi har ikke gjort noen kvantitativ kontroll. En typisk måte å teste enkelttre-segenteringens nøyaktighet på er å måle opp alle tre-posisjoner i et område og telle hvor mange trekroner som har blitt riktig segmentert, hvor mange trekroner som har blitt delt opp for mye (over-segentering) og hvor mange trekroner som ikke har blitt delt opp nok (under-segentering). Det var for tidskrevende for prosjektet å gjøre innmåling av tre-posisjoner i felt. Det ble derfor en kvalitativ kontroll av segenteringen.

Vi ser at 2 punkts data ikke gir en god segentering på mindre trær og på trær som står tett. Dette gjelder også 10 punkts data. Enkelttre-segentering fungerer bra i produksjonsskog hvor alle trær har lik utforming og størrelse, og står med god avstand til hverandre. Utfordringen med bytrær er at det finnes både trær med stor og flat krone og gjerne med flere stammer i tette treklynger sammen med små kroner. Konsekvensen av feil i segenteringen er at man ikke kan bestemme eksakt antall trær, og at man ikke kan få ut en riktig stamme-posisjon. Det er imidlertid fortsatt mulig å bruke trekrone-segmenter for å klassifisere treslag. I tillegg er målet å finne gamle (større) trær slik at segenteringsfeil for små trær ikke blir så viktige.

En annen faktor som må tas hensyn til er opptakssesong. En del 5 punkts laserdata tas opp om våren før løvsprett. Dette gjøres for å få flere treff på bakken og dermed bedre terrengmodeller. Ulempen for enkelttre-kartlegging er

at trekrone uten løv er mindre synlig i laserdataene. Dette har ikke blitt testet i prosjektet.

4.2 KVALITET PÅ TRESLAGSKLASSIFISERINGEN

Nøyaktigheten på treslagsklassifiseringen for alle treslag var svært lav med 46% og en kappa indeks på 0.39. Klassifiseringen for bar- versus løvtrær ga et ganske bra resultat: 86.0% (Kappa 0.72). Klassifiseringen for Eik versus andre løvtrær ga også et ganske bra resultat: 81.3% (0.63). Det er usikkert om resultatene er robuste. Det ble brukt litt få referansetrær (517 totalt) og det er mulig at det finnes noen årsaker for at resultatene har blitt litt kunstig høye. Et eksempel på en mulig årsak er at utvalget av referansetrær ikke har blitt gjort tilfeldig.

Vi har ikke funnet mange studier om klassifisering av enkelttrær i urbane strøk med bruk av vanlige flybilder. Det finnes mange studier av treslagsklassifisering i skogsområder med bruk av vanlige flybilder. Det finnes også mange studier av enkelttre-klassifisering i urbane strøk med bruk av mer avanserte data som hyperspektrale bilder. Vi har ikke funnet en eneste studie som fokuserer på eiketrær.

Immitzer et al. (2012) presenterer en oversikt over artikler om treslagsklassifisering. Resultatene på få treslag (3 eller 4) varierer fra 67% (ingen kappaverdi presentert) til 96 % (kappaverdi på 0.93). De fleste resultater er basert på skogsområder. Resultatene på flere treslag varierer fra 45% (ingen kappaverdi presentert) til 93% (ingen kappaverdi presentert). En del av studiene som ble oppsummert i artikkelen ble gjort med hyperspektrale data.

Korpela et al. (2010) testet treslagsklassifisering med kun bruk av laserdata i skogsområder i Finland. De skilte kun mellom gran, furu og bjørk og klarte dette med en klassifiseringsnøyaktighet rundt 88-90 % og en kappa rundt 0.80. De har brukt intensitetsinformasjon på en mer avansert måte (inkludert normalisering/kalibrering av intensitet). Samtidig er det mer variasjon i urbane trær enn i trær i produktive skogsområder. Vi tror det er mulig å forbedre våre resultater ved å følge metodene fra artikkelen i større grad. Det er imidlertid

usikkert om dette også øker resultatene for klassifiseringen av eiketrær. Korpela et al. (2010) har ikke testet klassifisering av ulike løvtreslag.

Puttonen et al. (2009) har rapportert en nøyaktighet på 67.8 % (ingen kappa verdi nevnt) i en treslagsklassifisering av gran, furu og bjørk med bruk av DMC flybilder. Nøyaktigheten gikk opp til 76.9 % i klassifiseringen mellom bartrær og løvtrær. Alle fire fargekanaler fra DMC kameraet ble brukt (RGB og NIR).

Kvalitet på treslagsklassifiseringen er avhengig av bildedataene og metodene, men også av kompleksiteten i området. Det er noe helt annet å klassifisere enkelttrær i homogene produksjonsskoger enn i naturskog eller byområder.

Derfor er det litt vanskelig å sammenligne resultater mellom studier.

Våre resultater faller ikke utenfor resultatene vi finner i litteraturen.

Det finnes sikkert muligheter til å forbedre resultatene med mer avanserte metoder, men samtidig er det begrensninger på nøyaktigheten som kan oppnås ved bruk av vanlige flyfoto i urbane strøk.

4.3 BETYDNING AV FLYFOTOEGENSKAPER FOR RESULTATENE.

Egenskapene til flyfotoene påvirker resultatene på treslagsklassifiseringen. GSD, opptakssesong, opptakstidspunkt (på dagen), sensor kvalitet og bildebehandling. Vi har kun brukt 2 datasett med flyfoto og har derfor ikke klart å undersøke disse faktorene. Så vidt vi vet finnes det ingen studier som har undersøkt alle faktorene innenfor et prosjektområde.

Immitzer et al. (2012) har gjort en litteraturstudie som gir oversikt over en del faktorer, men siden alle studier ble gjort i ulike test-områder er det vanskelig å konkludere mer om for eksempel beste opptaks-sesong, beste sensor eller beste GSD. Målet med dette prosjektet er å finne ut hva mulighetene er ved bruk av eksisterende flybilder og laserdata, så å finne ut hva slags flybilder som er optimale for treslagsklassifisering er kanskje ikke så relevant. Det viktigste er at man er bevisst over at man får ulike resultater for ulike flyfotodatasett. Det betyr at man må ha rutiner for å kontrollere resultatene per flyfotodatasett hvis man

skal klassifisere større områder som dekkes av flere datasett. Det påvirker igjen behovet for referansedata.

Utfordringer med variasjon i belysning i flyfotoene beskrives i avsnitt 4.2.1 (kystlynghei-delen) og gjelder på samme måten for klassifisering av enkelttrær.

4.4 GEOMETRI AV TREKRONER OG ORTOFOTO

I dette prosjektet har vi brukt vanlige ortofoto sammen med laserdata for å klassifisere trekroner. Vanlig ortorektifisering korrigerer geometrien i flybilder på bakkenivå. Trekroner blir ikke korrigert riktige og det vil forekomme forskyvninger avhengig av trehøyden og plassering av treet i forhold til kamerapunktet. Mer høyde gir større forskyvning og større avstand fra kamerapunktet gir større vinkel og dermed større forskyvning.

Det finnes tre muligheter for å forbedre dette:

1. Ortorektifisere på nytt med en overflatemodell (trekronemodell). Resultatet kalles for «true-ortophoto» eller «sant-ortofoto». Større byer som Oslo pleier bestiller denne type ortofoto.
2. Bruke bildematching for å generere en 3D-punktsky fra flyfotoene.
3. Prosjektare trekroneomrissene fra enkelttre-segmenteringen på (ukorrigerende) flyfoto før man trekker ut spektrale verdier fra flybildene.

Ulempen med metode 1 er at den skaper noen artefakter og interpolering i bildene der hvor det er store høydeforskjeller, nemlig ved kanten av trekroner. Dette kan skape problemer med treslagsklassifiseringen. Teksturen i bildene forandres også, noe som ikke er bra for klassifisering med Neural Network med image embedding.

Metode 2 har som ulempe at teksturen i bildene fjernes i stor grad, noe som ikke er bra for klassifisering med Neural Network med image embedding.

Metode 3 endrer ikke noe i bildene, men er en tidskrevende prosess, særlig på enkelttrær.

Metode 1 og 2 er i stor grad automatiske prosesser, men det er knyttet kostnader til disse.

4.5 BEHOV FOR MER AVANSERTE SENSORER?

Bruk av vanlige flyfoto gir begrensinger på hvor høy nøyaktighet man kan oppnå i treslagsklassifisering, særlig mellom ulike løvtreslag. Mer avanserte sensorer gir sannsynligvis bedre resultater.

Hyperspektrale sensorer og eventuelt multispektral laserskanning er eksempler på kommersielt tilgjengelige muligheter i Norge. Terratec AS for eksempel, utfører datainnsamling med en Hypsux sensor (hyperspektral kamera) og med Optech Titan, en multispektral laserskanner. En hyperspektral sensor har flere titalls spektrale kanaler som registrerer reflektert sollys. Standard digitale kameraer har 3 eller 4 spektrale kanaler. Ulike materialer reflekterer en ulik mengde med lys i ulike deler av spektrumet og i teorien bør man kunne skille ulike treslag fra hverandre på en bedre måte med flere spektrale kanaler.

Dalpoite et al. (2013) oppnådde en total nøyaktighet på 92.8 % ved bruk av Hypsux i skogsområder på treslag som gran, furu og bjørk.

Sommer et al. (2016) har brukt Hypsux for å klassifisere 13 ulike treslag i skogsområder og rapporterer en total nøyaktighet på 91% og en kappaverdi på 0.89. Eik var ikke med i klassifiseringen. Ballanti et al. (2016) har brukt en AISA hyperspektral skanner for å klassifisere 8 ulike treslag i skogsområder i California og oppnådde en nøyaktighet på 95% (ingen kappaverdi rapportert). Eik var med i klassifiseringen og fikk lavest resultat. Trier et al. (2018) har testet Hypsux hyperspektrale data i skogsområder i Norge. Tre treslag ble forsøkt skilt: gran, furu og bjørk. Med bruk av kun 3 kanaler og laserdata ble nøyaktigheten 74%, og ved bruk av alle 160 kanaler gikk nøyaktigheten opp til 87%.

Ørka et al. (2013)

Zhang et al. (2016) utførte en treslagsklassifisering ved bruk av Hymap hyperspektrale data og laserdata i Seattle. De skilte mellom de 7 mest forekommende treslag og klarte å oppnå en klassifiseringsnøyaktighet på 88.9% og en kappaverdi på 0.870.

Yu et al. (2017) rapporterer interessante muligheter med en Optech Titan multispektral laserskanner. Denne laserskanner måler ikke med 1 bølgelengde, men med 3 ulike bølgelengder samtidig. I skogsområder i Finland ble det gjort en treslagsklassifisering av gran, furu og bjørk med en nøyaktighet på 85% og en kappaverdi på 0.75. Resultatet på dominerende trær (trær som ikke er delvis under andre trær) var 90.5%. Til sammenligning ga bruk av kun laserpunktskyen uten intensitetsinformasjon en nøyaktighet på 76% (kappaverdi på 0.57).

Det er klart at mer avanserte sensorer gir bedre resultater på treslagsklassifisering, men det er usikkert hvor store forbedringene kan bli, særlig i urbane strøk. For å kunne svare på dette bør det gjøres mer forskning hvor man sammenligner bruk av vanlige laserdata og flyfoto, med bruk av hyperspektrale data og/eller multispektrale laserdata. Oslo kommune har kjøpt inn Hypex data og Optech Titan data over et betydelig testområde i byen. Noen studenter fra NMBU jobber med hovedoppgaver basert på disse dataene.

Selv om mer avanserte sensorer gir et bedre resultat, er det et spørsmål om det er realistisk å kartlegge store områder med disse sensorene på kort sikt (de nærmeste årene). Det finnes nesten ikke noen områder som er dekket med hyperspektrale data i Norge og det kan ta flere år før hele landet blir dekket, selv om man hadde startet med datainnsamlingen for fullt i år. Samtidig er opptak av hyperspektrale data dyrere enn opptak av vanlig flyfoto. Det er viktig å påpeke at de utfordringer nevnt ovenfor kun handler om kostnader, nytte og praktisk gjennomføring. Det er ikke noe tekniske aspekter som hindrer en storskala kartlegging med bruk av hyperspektrale data.

4.6 PROGRAMVARER OG AUTOMATISERING

I dette prosjektet har vi brukt følgende programvare:

- eCognition (enkelttre-segentering og uttrekning av bildestatistikk)
- Orange (analyse og klassifisering)
- LAStools (prosessering av laserdata og uttrekning av laserstatistikk)
- ArcGIS (diverse tilrettelegging av data)

Alt som ble gjort i eCognition kan også gjøres med åpen kildekode programvare, som for eksempel OpenCV biblioteket. Analysene som ble gjort i Orange kan også gjøres i R, eller Python med bruk av OpenCV biblioteket. Alt som ble utført med ArcGIS kan også gjøres med den åpne kildekode-programvaren QGIS. LAStools er lisensiert programvare, men deler av biblioteket (LASlib) er åpen kildekode. Det finnes også en versjon av dette biblioteket kalt liblas (liblas.org). Ett annet bibliotek for laserdata-prosessering som utvikles er pdal (www.pdal.io). Videre kan man for uttrekning av laserstatistikk per trekrone bruke en gratis programvare kalt FUSION.

Alle prosesser som ble kjørt kan kjøres automatisk og det kan brukes parallell prosessering. Forutsetningen er da at man deler opp dataene i kartblad/blokker. eCognition og LAStools er svært egnede for denne typen prosessering og det finnes mange muligheter med åpen kildekode programvare for å lage lignende rutiner, men det krever litt mer programmering.

4.7 KRAV TIL REFERANSEDATA

Referansedata er fundamentet til automatisk klassifisering. Referansedata er nødvendig for å «Trene» eller lære opp klassifiseringsalgoritmer og for å validere resultatene. Validering er minst like viktig som «trening» fordi et klassifiseringsresultat ikke er mye verdt uten dokumentasjon om nøyaktighet.

I dette prosjektet har vi brukt referansedata om enkelttrær:

- Posisjon, basert på trekrone og ikke stammeposisjon.
- Treslag.
- Eventuelt stammediameter.

Referansedataene kom fra følgende kilder:

- Naturbase – kun eiketrær.
- Feltbefaring – alle treslag.
- Ortofoto /skråfoto – kun treslag som er enkle å tolke, som gran, furu, bjørk.
- Streetview – kun treslag som er enkle å tolke, som gran, furu, bjørk.

Posisjon ble ikke målt med GPS men ble basert på trekroneinformasjon fra laserdataene.

Naturbasen inneholder en god del eiketrær som kan brukes som referansedata, men posisjonen må kontrolleres og eventuelt rettes. Det kan gjøres ved bruk av ortofoto og laserdata, selv om dette også kan introdusere nye feil. Alle andre treslag må inventeres i felt, mens noen «enklere» treslag kan tolkes fra ortofoto, skråfoto og gatebilder/Streetview.

Stammediameter kan i de fleste tilfeller hentes fra naturbasen (kun på eiketrær), eller måles i felt.

Det kreves et sett med referansetrær per flyfoto-datasett. Hvis flyfoto-datasettet ikke er homogent, det vil si at bildene ble tatt i for eksempel ulike sesonger, så må flyfotodatasettet deles opp. Et sett referansetrær bør bestå av minst 30-40 trær i hver treslagsklasse og antall klasser er avhengig av antall typer treslag som forekommer i analyseområdet. Vi har analysert et område som er litt mindre enn Asker kommune. Hvis man analyser en blokk med omløpsfoto som dekker cirka et helt fylke, bør man øke antall referansetrær betydelig. Det vil være mye mer variasjon i et større område og dette må representeres i referansedataene. 30-40 er et minimum antall og man ønsker helst 100-200 trær i hver klasse, men dette vil øke kostnadene til feltarbeidet. Anslaget er et estimat. Vi har ikke gjort noe test som kan svare på hva minimum antall referansetrær må være. Det er også umulig å bruke funn fra andre studier som fasit, siden nødvendig antall fasittrær er avhengig av fjernmålingsdataene (homogenitet) og prosjektområdet.

4.8 KOSTNADER OG TIDSBRUK

Prosjektet har testet ulike metoder og teknikker. Det er utfordrende å estimere tidsbruk og kostnader for alle muligheter som ble testet. Det er heller ikke realistisk å forvente at alle muligheter skal brukes i et eventuelt større prosjekt.

For å komme til et grovt estimat gjør vi følgende antakelser:

- Et lite fylke skal kartlegges, for eksempel Akershus eller Vestfold.

- Kun områder utenfor produktiv skog skal analyseres.
- Som bilde data brukes ortofoto fra Norge i Bilder eller det skal lages sant ortofoto på nytt med automatisk metode.
- Laserdata fra NDH brukes.

Tabell 28. Estimert på tidsbruk for klassifisering av 1 fylke.

Aktivitet	Tidsbruk i dagsverk*
Tilrettelegging av ortofoto og laserdata	5
Reprosessering av flybilder til sant ortofoto	10
Preprosessering av laserdataene	5
Enkelttre segmentering	10
Kontroll og tilrettelegging av referansetrær fra naturbase	10
Planlegging av feltinnsamling av referansetrær	3
Fototolkning referansetrær	5
Feltregistrering referansetrær	15
Klassifisering av hele området	17
Etterprosessering	5
Rapportskriving	5
Totalt	90

* 1 dagsverk tilsvarer 7.5 timer.

I tillegg til arbeidstimer kommer det reiseutlegg for cirka 15 dager feltarbeid.

Eksakt antall dager og antall referansetrær er usikkert.

Det kommer ingen materialkostnader i tillegg.

90 dagsverk kan komme opp til litt i underkant av 800 000 Kroner + reise/diett-kostnader.

5 KONKLUSJON OG ANBEFALINGER

5.1 KONKLUSJONER

- NDH laserdata, både 2 punkts og 5 punkts data kan brukes for å kartlegge trær og (høy) vegetasjon.
- NDH laserdata, både 2 punkts og 5 punkts data kan brukes for å kartlegge enkeltrær, trekrone og posisjon, men det blir mange feil i form av over- og undersegmentering. Det gjør at man ikke kan bruke det for å finne eksakt antall trær og eksakt posisjon. Det blir flest feil på trær som er små og trær som står tett nær hverandre.
- Selv om enkelttre-segmenteringen inneholder feil kan trekrone-segmentene brukes til å klassifisere treslag.
- Vi har ikke klart å finne en sammenheng mellom estimert trehøyde og stammediameter på eiketrær i naturbasen.
- Vi har ikke klart å skille mellom gran, furu og flere ulike løvtreslag med god nøyaktighet: 46% og en kappaverdi på 0.39 er et dårlig resultat.
- Å skille bartrær fra løvtrær ga bedre resultater. Høyest oppnådd klassifiseringsnøyaktighet var 86% (kappverdi på 0.72), med bruk av RGB bilder og laserdata og med bruk av Neural Network metoden.
- Å skille eik fra andre løvtrær ble gjort med en nøyaktighet på 81.3% (kappaverdi på 0.63), med bruk av RGB og NIR flyfoto og laserdata.
- Neural Network med image embedding ga nesten like gode resultater ved kun bruk av RGB flyfoto: 80.1% (kappaverdi på 0.60).
- Klassifiseringsnøyaktighet for bar- versus løvtrær varierer fra 70.5% (kappa 0.41) ved bruk av 2012 ortofoto til 80.2% (kappa 0.60) ved bruk av 2014 ortofoto (med Neural Network med image embedding metoden). Vi har ikke testet flere flyfoto-datasett så vi kan ikke si noe mer om hvor høyt eller lavt nøyaktigheten basert på vanlige flybilder kan bli.
- Neural Network og Neural Network med image embedding gir betydelig bedre resultater enn Support Vector Machine, k Nearest Neighbor og Random Forest metodene, særlig når flere inputvariabler brukes.
- Bruk av nærinfrarød informasjon øker klassifiseringsnøyaktigheten litt, men ikke i alle tilfeller.

- Det er mulig å kartlegge eiketrær ved bruk av flyfoto og laserdata, men resultatet på enkelttre-nivå vil inneholde en del feil.

5.2 ANBEFALINGER

- Det anbefales å teste metodene på litt større områder enn en kommune, med bruk av flere flyfoto-datasett.
- Det anbefales å teste ut mer avanserte sensorer som hyperspektrale kameraer eller multispektral laserskanning for å se hvor mye bedre klassifiseringsresultatene kan bli. Det er viktig at testene gjøres i Norge, og da i byområder og kulturlandskap.
- Det anbefales å samle inn referansedata om enkelttre-posisjoner og treslag på en systematisk måte, slik at det blir enklere/mindre kostbart å teste kartlegging av enkelttrær. Et slikt referansedatasett kan gjenbrukes i flere prosjekter.

ORDLISTE

BOA	Bottom-Of-Atmosphere
DBH	Diameter i brysthøyde
DTM	Digital TerrengModell
ESA	European Space Agency
Gini-indeks	Indeks som beskriver estimert mulighet for en variabel å skille mellom ulike klasser.
GSD	Ground Sampling Distance («oppløsning» i for eksempel flybilder)
Kappa-koeffisient	Et mål på hvor mye bedre klassifiseringen er enn den hadde vært hvis klassifiseringen hadde vært helt tilfeldig. En kappaverdi på 0 betyr et helt tilfeldig resultat, mens en verdi på 1 betyr perfekt samsvar.
kNN	K-Nearest Neighbor. Styrt klassifiseringsalgoritme
LAS	Industristandard format for laserdata
LAZ	Industristandard format for komprimerte laserdata
NB	Naive Bayes. Styrt klassifiseringsalgoritme
NDH	Nasjonal detaljert høydemodell. Et prosjekt i regi av Kartverket som har som mål å samle inn detaljerte laser- og bildematchingsdata for hele Norge (https://www.kartverket.no/Prosjekter/Nasjonal-detaljert-hoydemodell/)
NiN	Natur i Norge
NIR	Nær-Infrarød. En del av lysets spektrum (cirka fra 700 nm til 1000 nm hos de vanligste storformat kameraer)
NN	Neural Network. (Styrt klassifiseringsalgoritme)
OBIA	Object-Based Image Analysis (Objektbasert bildeanalyse). I motsetning til «piksel for piksel»-analyser.
Ortofoto	Et georeferert (fly)bilde slik at bildet har samme geometriske egenskaper som et kart og kan brukes til kartlegging og analyser.
RF	Random Forest. Styrt klassifiseringsalgoritme.
RGB-bilder	Bilder med i hvert bildeelement tre tall med en verdi for henholdsvis rød-, grønn- og blå komponent. «vanlige fargebilder»

SVM Support Vector Machine. Styrkt klassifiseringsalgoritme.
TOA Top-Of-Atmosphere

REFERANSER

- Ballanti, L.; Blesius, L.; Hines, E.; Kruse, B. 2016. Tree Species Classification Using Hyperspectral Imagery: A Comparison of Two Classifiers. *Remote Sens.* **2016**, *8*, 445.
- Bergkvist, I., Friberg, G., Mohtashami, S. & Sonesson, J. 2014. STIG-projektet 2010-2014. Arbetsrapport 818-2014. Skogforsk. Uppsala
- Biofokus / Oldberg, S. 2013. Kartlegging av hule eiker i Asker. Biofokus-rapport 2013-21, ISBN 978-82-8209-280-7
- Blaschke, T., 2010. Object-based image analysis for remote sensing. *ISPRS International Journal of Photogrammetry and Remote Sensing* 65 (1), 2–16
- Breiman, L., Friedman, J., Olshen, R., & Stone, C. (1984). *Classification and Regression Trees*. Belmont, CA, USA: Wadsworth International Group
- Bryn, A & Halvorsen, R., 2015. Veileder for kartlegging av terrestrisk naturvariasjon etter NiN (2.0.2) Veileder versjon 2.0.2a
- Dalponete, M; Ørka, H; Gobakken, T; Gianelle, D; Næsset, E. Tree Species Classification in Boreal Forests With Hyperspectral Data. *IEEE Transactions on Geoscience and Remote Sensing*. 2013 ;Volum 51.(5) s. 2632-2645
- ESA. Uten år. Sentinel-2 MSI, products and algorithms. Hentet fra: <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/products-algorithms>
- Friberg, G. (2014). En analysemetode for å optimere skotning mot optimalisert körsträcka och minimerad påverkan på mark och vatten. Institutionen för skogens produkter, 1-62.
- Halvorsen, R. & Bratli, H. 2017. Dokumentasjon av NiN versjon 2.1 tilrettelagt for praktisk naturkartlegging: utvalgte variabler fra beskrivelsessystemet. – Natur i Norge, Artikkel 11 (versjon 2.1.1): 1–163 (Artsdatabanken, Trondheim; <http://www.artsdatabanken.no>.)
- Honkavaara, E. 2014. State-of-the-art within radiometric correction of large - format aerial photogrammetric images. Fagdag Omløpsfotografering 8.mai 2014, Kartverket. Uten år. Hentet fra <http://sehavnivaa.no/globalassets/kart/flyfoto/state-of-the-art-within-radiometric-correction-of-large-format-aerial-photogrammetric-images.pdf>

Kartverket. Uten år. NDH Kravspesifikasjon. Hentet fra https://www.kartverket.no/globalassets/arkiv/kart/nasjonal-hoydemodell/ndh_kravspesifikasjon.pdf

Malley JD, Kruppa J, Dasgupta A, Malley KG, Ziegler A. Probability Machines: Consistent Probability Estimation Using Nonparametric Learning Machines. *Methods of Information in Medicine*. 2012;51(1):74-81. doi:10.3414/ME00-01-0052.

Immitzer, M.; Atzberger, C.; Koukal, T. Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. *Remote Sens*. 2012, 4, 2661-2693.

Kääb, A.; Winsvold, S.H.; Altena, B.; Nuth, C.; Nagler, T.; Wuite, J. Glacier Remote Sensing using Sentinel-2. Part I: Radiometric and geometric performance, application to ice velocity. *Remote Sens*. 2016, doi:10.3390/rs8070598.

Korpela, I., Ørka, H.O., Maltamo, M., Tokola, T. & Hyyppä, J. 2010. Tree species classification using airborne LiDAR – effects of stand and tree parameters, downsizing of training set, intensity normalization, and sensor type. *Silva Fennica* 44(2): 319–339

Lovdata, Forskrift om utvalgte naturtyper etter naturmangfoldloven. 2011. Hentet fra <https://lovdata.no/dokument/SF/forskrift/2011-05-13-512>

MiljøDirektoratet/Landbruksdirektoratet, 2017. Presisering om avgrensning av den utvalgte naturtypen "hule eiker" mot eiker som står i produktiv skog. Brev. 2-11-2017. Hentet fra <https://www.hule-eiker.no/Documents/Hule-eiker/Dokumenter/Presisering-av-produktiv-skog-fellesbrev%20KLD-LMD%2002-11-17.pdf>

Platt, J. 2000. Probabilistic outputs for support vector machines and comparison to regularized likelihood methods. In A.J. Smola, P.L. Bartlett, B. Schölkopf, and D. Schuurmans, editors. *Advances in Large Margin Classifiers*, Cambridge, MA, 2000. MIT Press.

Puttonen, E.; Litkey, P.; Hyyppä, J. Individual tree species classification by illuminated-shaded area separation. *Remote Sens*. 2009, 2, 19–35.

Szegedy, c. Vanhoucke, V. Ioffe, S. Shlens, J. Rethinking the Inception Architecture for Computer Vision. arXiv:1512.00567v3 [cs.CV] 11 Dec 2015.

- Sommer, Carolin & Holzwarth, Stefanie & Heiden, Uta & Heurich, Marco & Müller, Jörg & Mauser, Wolfram. (2016). Feature-based tree species classification using hyperspectral and lidar data in the Bavarian forest national park. *EARSeL eProceedings*. 14. 49-70. 10.12760/02-2015-2-05.
- Trier, Øivind & Salberg, Arnt-Børre & Kermit, Martin & Rudjord, Øystein & Gobakken, Terje & Næsset, Erik & Aarsten, Dagrun. (2018). Tree species classification in Norway from airborne hyperspectral and airborne laser scanning data. *European Journal of Remote Sensing*. 51. 336-351. 10.1080/22797254.2018.1434424.
- Yu, Xiaowei & Hyypä, Juha & Litkey, Paula & Kaartinen, Harri & Vastaranta, Mikko & Holopainen, Markus. (2017). Single-Sensor Solution to Tree Species Classification Using Multispectral Airborne Laser Scanning. *Remote Sensing*. 9. 108. 10.3390/rs9020108.
- Zhang, Z.; Kazakova, A.; Moskal, L.M.; Styers, D.M. Object-Based Tree Species Classification in Urban Ecosystems Using LiDAR and Hyperspectral Data. *Forests* 2016, 7, 122.
- Ørka, H; Dalponte, M; Gobakken, T; Næsset, E; Ene, L. Characterizing forest species composition using multiple remote sensing data sources and inventory approaches. *Scandinavian Journal of Forest Research*. 2013 ;Volum 28.(7) s. 677-688.

APPENDIKS SAMPLES ENKELTTREÆR ORTOFOTO 2014

Treningsbilder for enkelttre-klassifisering fra ortofoto 2014 for Neural Network med image embedding.

