



Norges miljø- og
biovitenskapelige
universitet

Masteroppgave 2020 30 stp

Fakultet for realfag og teknologi
Ivar Maalen-Johansen

Klassifisering av sjøbunnen ved bruk av batymetrisk, flybåren lidar

Seabed classification using bathymetric, airborne
lidar

Sigrid Løyning og Oda Mee Bjørklund Storsveen

Geomatikk
Fakultet for realfag og teknologi

Sammendrag

Flybåren batymetrisk laserskanning brukes i dag til å lage sømløse terrengmodeller mellom land og sjøbunn i kystnære områder. Ved å generere terrengmodeller fra punktskyen til laseren kan man få høyoppløslige og nøyaktige modeller av sjøbunnen. En laserskanner samler ikke bare inn høyde- og dybde data, men også intensitetsverdier til hvert enkelt punkt. Denne oppgaven undersøker om det er mulig å bruke disse intensitetsverdiene til å skille og klassifisere sedimentene på sjøbunnen. Informasjonen dette gir kan gjøre at sedimentklassifisering i kystsonen blir enklere å gjennomføre, da målebåter ikke slipper til i disse områdene.

For å klassifisere intensitetsverdiene er det her brukt to programvarer, PCI Geomatica og ArcGIS pro. Det er utført fem ulike klassifiseringsteknikker, der alle er en type styrt klassifisering. For å sammenligne resultatene fra de ulike programvarene er Python blitt tatt i bruk for å beregne nøyaktigheter og forvirringsmatriser. I tillegg ble det generert åtte ulike type intensitetskart. Bakgrunnen var å teste hvilke egenskaper som er viktig i denne typen klassifisering.

For å kunne teste de ulike teknikkene ble dataene delt inn i et test- og et verifiseringsområde. Resultatene fra testklassifiseringene viste at det ble for komplekst å skille mellom ti ulike sedimentklasser. I samråd med NGU ble det derfor dannet fire nye klasser, basert på kornstørrelse og egenskaper. Over testområdet ga dette klassifiseringsnøyaktigheter opp mot 70%. Verifiseringsområdene ga dårligere resultater for klassifisering, beste resultat her var på 47%. Ujevn klassefordeling kan være en av grunnene til lavere nøyaktigheter over verifiseringsområdet.

Resultatene fra denne oppgaven tyder på at bruk av intensitetsverdier alene til å klassifisere sedimentene på sjøbunnen ikke er en optimal metode. Intensitetsverdiene avhenger i stor grad av sjøbunnens refleksivitet, der farge på sedimentene har mye å si. Samme sedimenttype, som for eksempel «sand», kan ha ulik farge i ulike områder. Intensitetsverdiene kan likevel være nyttige, de kan gi en pekepinn på hvor det er et skifte mellom sedimenttyper. Dataene kan brukes til støtte i klassifisering, eller bidra til å kartlegge hvor det kan være nyttig å ta fysiske prøver av sjøbunnen.

Abstract

Today, airborne bathymetric lidar is used to establish terrain models between land covered areas and seabed in coastal zones. By generating point clouds from lidar, one is able to create digital terrain models and achieve accurate models over the seabed with a high resolution. Lidar can collect data such as height and depth, but is also able to collect intensity values for each point. This thesis examines the possibility of using intensity values in to separate and classify seabed sediments. The information provided could help simplify sediment classification in coastal zones, especially where marine vessels can not reach.

PCI Geomatica and ArcGIS pro were used to perform five different types of supervised classification techniques in order to classify intensity values. To compare the performance between two software programs, a Python script was used to calculate both accuracy and confusion matrices. In addition, eight different types of intensity maps were generated. The main reason for this was initially testing different properties to find the most important in this type of classification.

By testing different techniques, the data was separated into one test- and one verification area. The results show the complexity of separating ten different sediment classes. Therefore, in consultation with NGU, four new classes were established. Properties such as grain size were important factors of this class reduction. The test area gave classification accuracies up to 70 %. However, the verification area did not perform as well predicted, and the highest achieved accuracy was 47 %. One of the reasons why the accuracies decrease, is most likely the uneven class distribution.

The results of this thesis indicate that this is method not an optimal for classifying the seabed by solely incorporating intensity values. The intensity values affected by the reflectivity of the seabed, is heavily dependent of the color of the sediment. The same type of sediment, such as “sand”, may contain of different colors in different areas. Nevertheless, the intensity values can be useful, they can indicate change of location through different types of sediment. The intensity values can therefore be used as support to classify or help identify where it may be useful to take physical samples from the seabed.

Forord

Etter fire måneder med hardt arbeid er vi stolte av å presentere vår masteroppgave, som markerer slutten for oss som studenter ved NMBU – Norges Miljø- og Biovitenskaplige Universitet. Å skrive masteroppgave har vært en spennende, og svært lærerik prosess. Kartlegging av sjøbunnen med laserdata fra fly er ikke en utbredt metode, men en metode som næringslivet ønsker å benytte.

Oppgaven er skrevet for Terratec AS, her ønsker vi å rette en spesiell takk til biveileder Bernt Larsen og ikke minst Petter Solli for et godt samarbeid, og god veiledning rundt et nytt og relativt ukjent tema.

Vi vil også rette en stor takk til vår hovedveileder, Ivar Maalen-Johansen, for god veiledning og oppfølging. Vi setter stor pris på at det har vært en lav terskel for å spørre om støtte, både rundt små og større utfordringer.

Videre vil vi gjerne takke Dagrun Aarsten for hjelp med programvarer. Vi vil også takke Margaret Dolan og Sigrid Elvenes i NGU som har vært til stor hjelp med å øke vår forståelse av sjøbunnskartlegging. Tusen takk for gode diskusjoner rundt klasseinndelingen som er utført i oppgaven.

En takk må også rettes til Ross Downey i PCI Geomatics technical support og Vebjørn Nordhagen for hjelp med programvarene PCI Geomatica og ArcGIS pro. Ikke minst ønsker vi å rette en stor takk til Gro Melstveit og Morten Storsveen for korrekturlesing, og til Elise Gjessing for hjelp med oversetting.

Tilslutt vil vi gjerne takke hverandre for et godt samarbeid, og våre medstudenter ved NMBU som har gjort disse fem årene til en fantastisk opplevelse.

COVID-19s påvirkning på arbeidet med oppgaven

Koronaviruset gjorde at store deler av Norge, samt NMBU, stengte ned 13. mars. På dette tidspunktet var det to måneder igjen til innlevering av masteroppgaven. Viruset har ført til utfordringer, men har også gjort at vi har måttet omstille oss og tenke nytt.

Det meste av databehandlingen var ferdig før 13. mars, og ventetiden på å få tak i lisenser til programvarene til egne pc-er satte ikke for store kjepper i hjulene. Det som har vært mest utfordrende med denne perioden er at vi er to stykker som samarbeider om én oppgave. Det at vi ikke har hatt muligheten til å møtes så mye som ønsket, har gjort at det til tider har vært litt mindre fremgang enn tenkt. Fysiske møter med veileder og bi-veiledere i Terratec har heller ikke latt seg gjøre.

COVID-19 har imidlertid gjort at vi har måttet tenke nytt. På tross av at det ikke har vært mulig å få til fysiske møter med veiledere, opplever vi at både veileder på NMBU og bi-veiledere i Terratec har vært til god hjelp. Over Teams, en digital plattform for videomøter, har vi jevnlig hatt møter med veileder. Bi-veilederne har raskt gitt oss gode svar på spørsmål over mail.

Samarbeidet oss imellom har fungert veldig godt, og vi har hatt god kontakt med hverandre over Teams, telefon og gjennom korte skriv og kommentarer i google docs og word online.

Alt-i-alt har utfordringene COVID-19 førte med seg blitt løst på en god måte. Samarbeidet har fungert fint, og vi har fått god veiledning når behovet har vært der.

Så, COVID-19 – du har vært en pest og en plage, men med omstilling og nye løsninger kan alt løses – på en god måte.

Forkortelser

ALB - Airborne Lidar Bathymetri

cm – centimeter

CSV – Comma-Separated Values

CZMIL – Coastal Zone Mapping and Imaging Lidar

GIS – Geografisk Informasjonssystem

GLaSS – Green Laser Søre Sunnmøre

GNSS – Global Navigation Satellite System

Hz - Hertz

IR – Infrarød

km - kilometer

Lidar - Light Detection and Ranging

m - meter

MBES - Multibeam Echosound

NGU – Norges Geologiske Undersøkelse

nm – nanometer

NMBU – Norges miljø- og biovitenskapelige universitet

OGC - Open Geospatial Consortium

PIL – Python Imaging Library

RF – Random Forest

SVM – Support Vector Machine

QTM – Quick Terrain Modeler

Innholdsfortegnelse

SAMMENDRAG	I
ABSTRACT	II
FORORD	III
COVID-19S PÅVIRKNING PÅ ARBEIDET MED OPPGAVEN	IV
FORKORTELSER	V
FIGURLISTE	VIII
KAPITTEL 1: INNLEDNING	1
1.1 BAKGRUNN FOR OPPGAVEN	1
1.2 TEMA OG PROBLEMSTILLINGER	3
1.3 TIDLIGERE FORSKNING	4
1.4 OPPSETT OG STRUKTUR.....	5
1.5 FORDELING AV ARBEIDSOPPGAVER	6
KAPITTEL 2: TEORI	7
2.1 DET ELEKTROMAGNETISKE SPEKTERET	7
2.2 REFLEKSJON OG INTENSITET	8
2.2.1 Refleksjon.....	8
2.2.2 Intensitet.....	8
2.3 DEFINISJON AV FJERNMÅLING.....	8
2.4 LASER.....	9
2.5 EFFEKTER SOM PÅVIRKER MÅLINGENE I VANN	9
2.5.1 Refraksjon	9
2.5.2 Turbiditet.....	9
2.5.3 Secchidybde.....	10
2.6 RUHET OG HARDHET	10
2.7 KLASSIFISERING AV OBJEKTER	10
2.8 STYRT KLASSIFISERING.....	11
2.8.1 Support vector machine.....	11
2.8.2 Beslutningstre.....	12
2.8.3 Random forest	12
2.8.4 Minimum distance	13
2.8.5 Maximum likelihood.....	14
KAPITTEL 3: MATERIALER OG METODE	16
3.1 MATERIALER:	16
3.1.1 CZMIL (Coastal Zone Mapping and Imaging Lidar).....	16

3.1.2 Prosjektområder.....	18
3.1.3 Presentasjon av testområdet	19
3.1.4 Presentasjon av verifiseringsområdene	19
3.1.5 Datasett	21
3.1.6 Programvarer benyttet til preprosessering, klassifisering og fremstilling av resultater	23
3.1.7 Filformater som er brukt i oppgaven	26
3.1.8 Forvirringsmatrise	28
3.1.9 Nøyaktighet	29
3.1.10 Precision, recall og F1 score	29
3.2 METODE SOM ER BRUKT TIL PREPROSESSERING OG KLASIFISERING AV INTENSITETSVERDIER	30
3.2.1 Preprosessering og bearbeiding av data.....	30
3.2.2 Valg av datasett.....	34
3.2.3 Klassifisering av intensitetsverdier	35
3.2.4 Valg av datasett og klassifiseringsteknikker	46
3.2.5 Sammenslåing av klasser	48
KAPITTEL 4: RESULTATER OG DISKUSJON	55
4.1 RESULTATER FRA VERIFISERINGSOMRÅDER.....	55
4.2 DISKUSJON AV RESULTATER	60
4.3 DISKUSJON AV METODE	63
4.4 ARBEID FREMOVER	67
KAPITTEL 5: KONKLUSJON	69
REFERANSER.....	71
VEDLEGG	76

Figurliste

Bilde 1: Bildet til venstre viser intensitetsverdier fra batymetrisk lidar fremstilt av Terratec. Bildet til høyre viser sedimentdekket på sjøbunnen, kartet er fremstilt fra NGU sitt kornstørrelsekart.(Larsen & Solli, 2020)	1
Bilde 2: Bildet viser sedimentkartet fra NGU, med tilhørende klasser.	23
Bilde 3: Bildene over viser modellen etter at den har blitt kjørt gjennom en kontinuerlig analyse. Bildet til venstre viser modellen ovenfra, og bildet til høyre viser modellen i profil. Her kan man se returene nedover i vannsøylen.	30
Bilde 4: Bildene over viser modellen etter at man har fjernet alle klasser utenom sjøbunnen og vegetasjonen på sjøbunnen.	31
Bilde 5: Intensitetskart over Runde i rasterformat, fremstilt med QTM. Bildet til venstre viser maksimums intensitetsverdier, mens bildet til høyre viser gjennomsnittlige intensitetsverdier.	32
Bilde 6: Illustrerer området Runde før og etter rasteret ble klippet. Figuren til venstre viser intensitetsrasteret over Runde med landområder, figuren til høyre viser intensitetskartet etter en klippoperasjon.	33
Bilde 7: Bildet viser forskjellen på datasettet før og etter glatting	33
Bilde 8: Bildet viser treningsområder i PCI Geomatica.	36
Bilde 9: Bildet over viser en klassifisering i PCI Geomatica. Klassifiseringsmetoden er Maximum likelihood. Datasettet inneholder gjennomsnittlige intensitetsverdier, det er utført en glatting og vegetasjonen er fjernet.	37
Bilde 10: Klassifisering av testområdet i PCI Geomatica. Klassifiseringsmetoden er Minimum distance, og datasettet inneholder gjennomsnittlige intensitetsverdier, det er utført en glatting og vegetasjonen er fjernet.	38
Bilde 11: Resultat av maximum likelihood klassifisering i ArcGIS av Runde. Intensitetskartet som er klassifisert er datasettet mnfno.....	41
Bilde 12: Resultat av random trees klassifisering i ArcGIS av Runde. Intensitetskartet som er klassifisert er datasettet mnfno.....	41
Bilde 13: Resultat av SVM klassifisering i ArcGIS av Runde. Intensitetskartet som er klassifisert er datasettet mnfno.....	42
Bilde 14: Kart over testområdet Runde som viser hvordan sedimentene er basert på sammenslåingen av klasser.	49

Bilde 15: Resultatet av en maximum likelihood klassifisering utført i ArcGIS pro over Runde	50
Bilde 16: Resultatet av en maximum likelihood klassifisering utført i PCI Geomatica over Runde	50
Bilde 17: Resultatet av en SVM klassifisering utført i ArcGIS pro over Runde.....	51
Bilde 18: Kartet til venstre viser intensitetskart over Hatløya. Dette kartet er av typen mnfno. Til høyre er det et utsnitt av NGUs kornstørrelsekart med sammenslåtte klasser over samme område.....	55
Bilde 19: Kartet til venstre viser intensitetskart over Nautøya. Dette kartet er av typen mnfno. Til høyre er det et utsnitt av NGUs kornstørrelsekart med sammenslåtte klasser over samme område.....	56
Bilde 20: Kartet til venstre viser intensitetskart over Nerlandsøya. Dette kartet er av typen mnfno Til høyre er det et utsnitt av NGUs kornstørrelsekart med sammenslåtte klasser over samme område.	56
Bilde 21: Bildet viser dårligste klassifisering over Hatløya til venstre, og beste til høyre, ifølge nøyaktighetene. Dårligste klassifisering er utført i PCI Geomatica med maximum likelihood og beste er utført i ArcGIS pro med SVM.....	57
Bilde 22: Bildet viser dårligste klassifisering over Nautøya til venstre, og beste til høyre, ifølge nøyaktighetene. Dårligste klassifisering er utført i ArcGIS pro med maximum likelihood og beste er utført i ArcGIS pro med SVM.....	58
Bilde 23: Bildet viser dårligste klassifisering over Nerlandsøya til venstre, og beste til høyre, ifølge nøyaktighetene. Dårligste klassifisering er utført i PCI Geomatica med maximum likelihood og beste er utført i ArcGIS pro med maximum likelihood.....	58
Bilde 24: Intensitetskart over Runde med NGU sine grenser mellom de ulike kornstørrelsene lagt over i grønt.....	64
Figur 1: Det elektromagnetiske spekteret	7
Figur 2: Illustrasjon om hvordan SVM klassifiserer ved å finne et optimalisert sett med grenser som skiller klassene. De mest nærliggende objektene til den lineære grensen kalles support vectors.(Raschka & Mirjalili, 2017d)	11
Figur 3: Figuren illustrere hvordan et beslutningstre ser ut og hvordan det tilegner objekter en klasse.....	12

Figur 4: Figuren viser hvordan RF klassifiserer objekter ved å bruke flere beslutningstrær, der flertallet av beslutningstrærne bestemmer hvilken klasse det er (Koehrsen, 2017).	12
Figur 5: Minimum distance (SEOS, u.å.-b)	13
Figur 6: Maximum Likelihood (SEOS, u.å.-a)	14
Figur 7: Utsnitt A viser området som er skannet over Sande kommune. Utsnitt B viser området som er skannet over Ulstein og Herøy kommune. (Larsen & Solli, 2020).....	18
Figur 8: Illustrasjon av hvordan focal statistics beregner nye verdier til en output raster. Her er det vist i form av at den beregner ut en gjennomsnittlig verdi fra den 3x3 store masken. ...	24
Figur 9: Figuren illustrerer forskjellen mellom PCIDSK filer og andre konvensjonelle filtyper. (PCI Geomatics Enterprises Inc., 2018).....	27
Figur 10: Illustrasjonsfigur av en forvirringsmatrise med to klasser (Raschka & Mirjalili, 2017c).	28
Figur 11: Bildet viser forvirringsmatrisen til klassifiseringen utført i Bilde 9.	38
Figur 12: Bildet viser forvirringsmatrisen til klassifiseringen som vises i Bilde 11.	39
Figur 13: Figuren over viser treningsområdene som ble dannet i ArcGIS pro.....	40
Figur 14: Forvirringsmatrise til klassifisering utført i ArcGIS pro med maximum likelihood på datasettet mnfn. Matrisen viser antall piksler som er predikert og hva de er predikert som, i tillegg til en beregnet precision, recall og F1 score.	44
Figur 15: Stolpediagram som viser fordelingen av klassene over Runde oppgitt i antall piksler	45
Figur 16: Forvirringsmatrise til klassifisering utført i PCI Geomatica minimum distance på datasettet mnfn. Matrisen viser antall piksler som er predikert og hva de er predikert som, i tillegg til en beregnet precision, recall og F1 score.	45
Figur 17: Forvirringsmatrise til klassifisering utført i PCI Geomatica med maximum likelihood på datasettet mnfn. Matrisen viser antall piksler som er predikert og hva de er predikert som, i tillegg til en beregnet precision, recall og F1 score.	47
Figur 18: Forvirringsmatrise av klassifisering gjort i ArcGIS pro med SVM som klassifiseringsteknikk og mnfn som datasett. I tillegg viser figuren også beregnede precision, recall og F1 score.	52
Figur 19: Forvirringsmatrise av klassifisering gjort i PCI geomatica med maximum likelihood som klassifiseringsteknikk og mnfn som datasett. I tillegg viser figuren også beregnede precision, recall og F1 score.	52

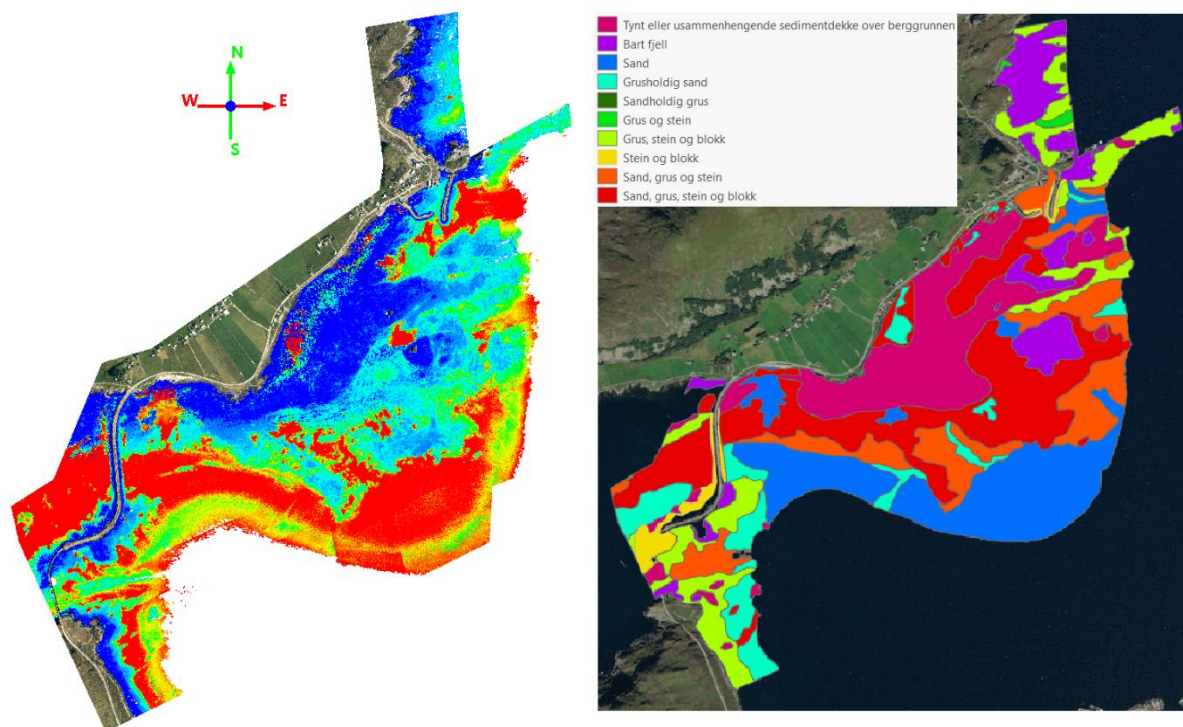
Figur 20: Forvirringsmatrise av klassifisering gjort i ArcGIS pro med maximum likelihood som klassifiseringsteknikk og mnfno som datasett. I tillegg viser figuren også beregnede precision, recall og F1 score.	52
Figur 21: Stolpediagram som viser fordelingen av klassene over Runde oppgitt i antall piksler. Dette er den nye fordelingen etter at klassene er slått sammen til nye klasser.	53
Figur 22: Forvirringsmatriser fra klassifiseringer over området Hatløya.....	59
Figur 23: Forvirringsmatriser fra klassifiseringer over området Nautøya.	59
Figur 24: Forvirringsmatriser fra klassifiseringer over området Nerlandsøya.	60
Figur 25: Stolpediagram som viser fordelingen av klasser over verifiseringsområdet. Fordelingen er vist i antall piksler.	61
Figur 26: Bildet viser i øvre venstre hjørnet, utsnitt av intensitetskartet over Runde. I øvre høyre hjørnet ser man et utsnitt av sedimentdekket over samme område. I nedre venstre hjørne er terrengmodellen over samme område.....	62
Tabell 1: Spesifikasjoner for CZMIL-sensoren	17
Tabell 2: spesifikasjoner for prosjektet (Larsen & Solli, 2020).....	19
Tabell 3: Viser testområdet, størrelsen til testområdet, flyhøyde og antall flystriper (Larsen & Solli, 2020).....	19
Tabell 4: Tabellen viser verifiseringsområdene og tilhørende størrelse, flyhøyde og antall flystriper (Larsen & Solli, 2020).....	20
Tabell 5: Tabellen over viser klassene Terratec delte returene inn i under første klassifisering (Larsen & Solli, 2020).	21
Tabell 6: Tabellen over viser klassene NGU har klassifisert dataene sine inn i (Norges Geologiske Undersøkelse, 2019a).	22
Tabell 7: Oversikt over testdatasettene som ble brukt til klassifisering av testområde Runde.	34
Tabell 8: Tabellen viser hvilke klasser det ble laget treningsområder for.	35
Tabell 9: Tabell som viser nøyaktigheten oppgitt i prosent til de ulike klassifiseringsteknikkene og datasettene. Tabellen er fargekodet slik at høyere nøyaktighet er vist i sterkere grønnfarge og lavere nøyaktighet i hvit.	43
Tabell 10: Tabellen over viser en oversikt over hvilke klasser som er slått sammen i samråd med NGU.....	49
Tabell 11: Tabellen over viser nøyaktigheten de ulike klassifiseringsteknikkene oppnår oppgitt i prosent.	51

Tabell 12: Tabellen viser nøyaktighetsresultater av klassifiseringer over
verifiseringsområdene. Datasettet som er brukt i klassifiseringen er mnfn.....57

Kapittel 1: Innledning

1.1 Bakgrunn for oppgaven

Bakgrunnen for denne oppgaven er et ønske fra Terratec om å utvide bruksområdene til flybåren batymetrisk laserskanning. I dag brukes dette hovedsakelig til å lage sømløse modeller i kystområder, som omfatter høydedata fra landområder, overgangen mellom land og sjø og dybdedata av sjøbunnen. Terratec har sett at det kan være en korrelasjon mellom intensitetsverdier og ulike sedimenter på sjøbunnen, se bilde 1. Som man kan se ved å sammenligne fremstillingene nedenfor, er det tydelig at store deler av konturene og skillene mellom sedimentene stemmer overens med intensitetsverdiene fremstilt fra batymetrisk lidar. På bakgrunn av dette kan det antas at det er mulig å gjennomføre klassifiseringer med relativt gode resultater. Dersom det er mulig å bruke laserdata til å klassifisere sjøbunnen, vil dette også være svært interessant for NGU (Norges Geologiske Undersøkelse), og andre aktører som forvalter data over den norske kysten.



Bilde 1: Bildet til venstre viser intensitetsverdier fra batymetrisk lidar fremstilt av Terratec. Bildet til høyre viser sedimentdekket på sjøbunnen, kartet er fremstilt fra NGU sitt kornstørrelsekart. (Larsen & Solli, 2020)

Oppgaven tar utgangspunkt i arbeidet som ble gjort med Green Laser Søre Sunnmøre-prosjektet (GLaSS). GLaSS-prosjektet er en del av "*Pilotprosjekt - Kartlegging av marin natur i Møre og Romsdal*", som var et samarbeid mellom Kartverket, NGU og Terratec (Dolan et al., 2018).

Basert på data fra flybåren fjernmåling innsamlet i GLaSS-prosjektet, har NGU sitt marine grunnkart over Søre Sunnmøre blitt oppdatert. Dataene som var viktig i den geologiske tolkningen av sjøbunnen var data fra batymetrisk lidar og flyfoto. Det har også blitt tatt fysiske prøver av sjøbunnen. NGU klarte ikke å hente ut nyttig informasjon fra intensitetsverdiene i forhold til å klassifisere sjøbunnen.

I senere tid har det blitt gjort nye målinger med en kraftigere laser, CZMIL Nova. Dette gir bakgrunn for analyse av nye datasett, for å undersøke om intensitetsverdiene nå kan gi informasjon om sedimentene på sjøbunnen. I denne oppgaven skal de nye datasettene analyseres, og ønsket er å kunne definere sedimentene basert på innsamlet laserdata.

1.2 Tema og problemstillinger

Målet med denne oppgaven er å finne ut om det er mulig å trekke ut informasjon om sedimentene på sjøbunnen ved å se på intensitetsverdier fra laserdata. I innsamlingen av data er det brukt en CZMIL Nova sensor fra Optech. Denne laseren samler data fra to ulike bølgelengder, 532 nm og 1064 nm, som betyr at det samles inn data både med en laser i den grønne- og en i den nær-infrarøde delen av det elektromagnetiske spekteret. Disse bølgelengdene oppfører seg ulikt, og detekterer ulike deler av vannsøylen. Den nær-infrarøde laserstrålen reflekteres fra vannoverflaten, noe som gir en referanseflate for dybdene. Den grønne laseren holder høyere energi, og trenger derfor nedover i vannsøylen. Strålen vil treffe sjøbunnen ned til en viss dybde avhengig av flere faktorer som refraksjon og turbiditet. Ut ifra disse dataene er det ønskelig å svare på følgende problemstilling:

- Kan man ut ifra intensitetsverdier klassifisere sedimenter i kystsonen?

Videre er det interessant å se på følgende sekundærproblemstillinger:

- Kan man bruke intensitetsverdier som støtte i klassifisering?
- Er det mulig å si noe om ruhet og hardhet på bunnsedimentene ut fra intensitetsverdiene?

Det er ønskelig å svare på hvilke bruksområder laserdata av sjøbunnen kan ha. Som problemstillingene representerer er det et håp om å kunne detektere noe informasjon fra sjøbunnskartlegging, uavhengig hvilket svar primærproblemstillingen gir.

1.3 Tidligere forskning

NGU, ved Margaret F. J. Dolan, Valérie K. Bellec, Sigrid Elvenes og Aave Lepland, gjorde i 2018 et forsøk på å bruke intensitetsverdier fra en Optech Titan laserskanner til å tolke bunnsedimenter i grunne områder på Søre Sunnmøre. Data fra laseren var med på å bidra til å karakterisere sjøbunn, om den var ru eller glatt, og sammen med flyfoto ga dette en innsikt i type sjøbunn. I denne rapporten ble det konkludert med at intensitetsverdiene ikke kunne brukes grunnet at det ikke var påført korreksjoner som kan påvirke intensitetsverdiene (Dolan et al., 2018).

Det er blitt utført en del forskning på bruken av intensitetsverdier fra lidar-data til å klassifisere landområder og objekter på land, men relativt lite forskning på bruk av lidar til å klassifisere sjøbunnen.

Brennan og Webster gjorde i 2006 en undersøkelse om bruk av intensitetsverdier i klassifisering av objekter og landområder. De konkluderte med at intensitetsverdiene tydelig klarte å skille mellom mørke og lyse flater. Kombinert med høydene fra punktskyen klarte Brennan og Weber å skille mellom ti forskjellige klasser (Brennan & Webster, 2006).

Det har tidligere blitt utført forskning på klassifisering ved bruk av lidar-data sammen med hyperspektrale data som viser en økning i nøyaktighet ved å kombinere datasettene (Ghamisi et al., 2015).

Det er forsket på CZMIL Novas evne til å detektere objekter på havbunnen (Feygels et al., 2016), oljesøl og lekkasje fra kloakkrør (Feygels et al., 2017a). Ut fra det vi vet er det ikke utført annen forskning på bruk av intensitetsverdier fra CZMIL Nova i klassifisering.

1.4 Oppsett og struktur

Masteroppgaven har følgende struktur:

Kapittel 1: Innledning

Dette kapitlet inneholder bakgrunn for oppgaven, tema og problemstillinger og tidligere forskning på feltet.

Kapittel 2: Teori

Kapitlet tar for seg teorien som ligger bak selve laserskanningen og hvordan klassifiseringen av dataene foregår.

Kapittel 3: Metode

Dette kapitlet består av to ulike deler; materialer og metode. Materialdelen beskriver de ulike filtypene og programvarene som er brukt i oppgaveløsningen, samt informasjon om datasettene som er brukt. Metodedelen tar for seg metoden som er brukt til å klassifisere dataene, valg av datasett og klassifiseringsteknikker.

Kapittel 4: Resultater og diskusjon

I dette kapitlet presenteres resultatene databehandlingen vår har gitt. Disse diskuteres i sin helhet, og gir svar på hvor egnet metoden er sett ut fra våre data. Det blir sett nærmere på metoden og det diskuteres om denne er passende for å finne svar på problemstillingene.

Kapittel 5: Konklusjon

Konklusjonen presenterer svar på problemstillingene.

1.5 Fordeling av arbeidsoppgaver

Arbeidet denne oppgaven omfatter er utført av to personer. Det ble derfor bestemt at hver av oss skulle ha hovedansvaret for hver vår programvare.

Fordelingen er som følger:


- Sigrid Løyning har hatt hovedansvaret for preprosessering utført i QTM og klassifiseringer utført med programvaren PCI Geomatica.
- Oda Mee Bjørklund Storsveen har hatt hovedansvaret for preprosessering i ArcGIS pro og klassifiseringer utført i samme programvare. I tillegg har Oda Mee også hatt hovedansvaret for beregning av resultater utført i Python.

Metode knyttet til de enkelte programvarene er skrevet av personen med hovedansvaret for denne programvaren, men korrekturlest av den andre. Videre er innledning, teori, resultater, diskusjon og konklusjon skrevet i fellesskap og det har ellers vært et tett samarbeid.

Kapittel 2: Teori

2.1 Det elektromagnetiske spekteret

Elektromagnetisk stråling kan beskrives som en strøm av fotoner som beveger seg i et bølgelignende mønster. Bølgene bærer med seg energi og beveger seg i lysets hastighet. Ut ifra mengden energi hvert foton bærer, kan man skille mellom ulike typer elektromagnetisk stråling (NASA, 2013). Bølgene spenner seg over et nærmest ubegrenset frekvensområde som danner det elektromagnetiske spekteret, se figur 1. I det elektromagnetiske spekteret får strålingen navn etter hvilken frekvens eller bølgelengde den har, hvordan den brukes eller hvordan den oppstår (Sandstad, 2018).



Figur 1: Det elektromagnetiske spekteret

I denne oppgaven er det hovedsakelig den synlige og den infrarøde delen som trekkes frem. Synlig lys opptrer omtrent midt i det elektromagnetiske spekteret og har en bølgelengde på ca. 400-760 nm (Sandstad, 2018). Infrarødt (IR) er forlengelsen av det synlige lyset, og stråling med bølgelengder opp mot 1 mm betegnes som infrarød. I oppgaven vil hovedfokuset ligge på den den nærinfrarøde delen, som stråler med bølgelengder opp mot 1400 nm (Holtebekk, 2019).

2.2 Refleksjon og intensitet

2.2.1 Refleksjon

Refleksjon av lys er når lys treffer en flate og speiles tilbake (Grimenes et al., 2011). Speilende refleksjon, også kalt spekulær refleksjon, oppstår der lyset treffer en glatt flate slik at inn- og utfallsvinklene er like store. Diffus refleksjon eller spredning er refleksjon der overflaten lyset treffer er ru slik at lyset spres i flere retninger (Grimenes et al., 2011). Dette er tilfellet i de fleste situasjoner når man bruker en laserskanner. Likevel klarer mottakeren i sensoren å oppfatte informasjon fra den delen av pulsen som reflekteres tilbake.

2.2.2 Intensitet

Intensitet er et mål for energistrømmen i stråling eller i bølger (s.n., 2020). Intensitetsverdien er en verdi på hvor sterkt retursignalet fra laserpulsene er og er i denne oppgaven oppgitt som en verdi på mellom 0 – 65535. Dette avhenger av en rekke faktorer som refleksjonsevnen til overflaten laserpulsene treffer, styrken på laserstrålen, mottakeren og innfallsvinkelen til laserpulsene.

2.3 Definisjon av fjernmåling

Fjernmåling kan defineres på flere ulike måter. Mest vanlig er det å si at fjernmåling er å identifisere, observere og måle et objekt uten å være i direkte kontakt med objektet (Graham, 1999). En definisjon mer passende i dette tilfellet er at fjernmåling er en metode for å samle inn reflektert og emittert elektromagnetisk stråling fra både land- og vannområder på jorden. Vanligvis samles disse dataene inn ved bruk av fly eller satellitter (Horning, 2008).

En enkel form for fjernmåling er ved bruk av digitale kamera. Synlig lys som reflekteres fra overflaten til et objekt blir registrert som et bilde. Fjernmåling er ikke bare registrering av synlig lys, og mer moderne fjernmålingssensorer kan registrere energi som ligger utenfor spekteret til synlig lys (Horning, 2008). Dagens sensorer er vanligvis optiske, noe som betyr at sensorene kan registrere refleksjon innenfor et område som strekker seg fra 400 nm til 2500 nm i det elektromagnetiske spekteret.

2.4 Laser

En laser er en aktiv sensor. En aktiv sensor kjennetegnes ved at den genererer sitt eget lys/stråling. En laser er en lyskilde som forsterkes ved å bruke stimulert emisjon. Det som kjennetegner en laser er at laserstrålen er svært intens, har en spesifikk bølgelengde og er sterkt avgrenset i retning (Holtebekk & Ringvold, 2019). Informasjonen man får baserer seg på returene på de pulsene instrumentet selv sender ut. Fordelen med å bruke en aktiv sensor er at man har mindre begrensninger når det kommer til lysforhold og vær (Mai, 2017). I denne oppgaven er det snakk om en batymetrisk laser, med dette menes en laser som også har evnen til å måle dybden under vannoverflaten.

2.5 Effekter som påvirker målingene i vann

2.5.1 Refraksjon

Refraksjon er brytning av lys når den beveger seg fra ett medium til et annet, der de to mediene har ulik brytningsindeks. Brytningen skjer i grenseflata mellom de to mediene (Skaar, 2018). Årsaken til lysbrytningen kommer av at lys beveger seg med ulik hastighet i ulike medier.

Når mediet laserstrålen beveger seg gjennom endrer seg, som mellom luft og vann, vil dette påvirke lyshastigheten (Mæhlum, 2009). Når hastigheten endrer seg vil sensoren motta signalene til «feil tid». Dette gjør at det kan oppstå punkter som ligger utenfor modellen, såkalte støypunkter. Dette fenomenet må det korrigeres for når det utføres batymetrisk laserskanning.

2.5.2 Turbiditet

Turbiditet er et mål på mengden suspenderte partikler i en væske. Partiklene i væsken påvirker lys i form av spredning og absorbering av lys som forplanter seg gjennom væsken (Grobelaar, 2009). Turbiditet er enkelt forklart hvor klart vannet er.

Turbiditeten til vannet påvirker hvor dypt man kan få retursignaler fra laseren. En høy turbiditet i vannet vil gjøre at målingene ikke når så dypt som ved en lav turbiditet. Det som skjer er at ved høy tetthet av partikler i vannet vil større deler av signalene treffe partiklene og skape diffus refleksjon. Dette vil minke mengden energi som reflekteres fra sjøbunnen. (s.n., 2018)

2.5.3 Secchidybde

Secchidybde er et mål på hvor dypt øye kan se i vann. Denne dybden måles ved å senke en secchi disk nedover i vannsøylen. På det tidspunktet secchidiskene ikke lenger kan sees av det blotte øye har vi nådd secchidybden. Dette påvirkes av bl.a. turbiditeten i vannet. (Environmental Protection Agency, 2013)

Påvirkningen dette har på målinger er at størrelsen til secchidybden sier noe om hvor dypt det er mulig å innhente informasjon. Vanligvis er det mulig å skaffe informasjon på en dybde som er tre ganger så dypt som secchidybden. Dette vil si at dersom secchidybden er 15 meter, skal det være oppnåelig å skaffe informasjon om sjøbunn ned til 45 meters dybde. (Larsen & Solli, 2020)

2.6 Ruhet og hardhet

En ru overflate er en grov og ujevn overflate (Språkrådet, 2020b). Med ruhet menes hvor grov og ujevn overflaten av sedimentene på sjøbunnen er.

Hardhet sier noe om hvor hardt et material er, og motstandsevnen materialet har mot at andre materialer eller stoff trenger inn i det (Språkrådet, 2020a).

2.7 Klassifisering av objekter

Klassifisering handler om å tilordne objekter en klasse ut fra egenskaper objektet selv har eller egenskapene til andre nærliggende objekter. Det er to hovedkategorier når det kommer til klassifisering, styrt og ikke-styrt klassifisering. Hovedforskjellen mellom styrt og ikke-

styrkt klassifisering er at i styrkt klassifisering brukes treningsdata, mens i en ikke-styrkt klassifisering blir dataene tilordnet en klasse på bakgrunn av statistikk. (Dick, 2009)


2.8 Styrkt klassifisering

I denne oppgaven vil det kun bli brukt klassifiseringsalgoritmer som er av typen styrkt klassifisering. I styrkt klassifisering har man et sett treningsdata. Dette betyr at man forteller algoritmen hva slags klasse en mengde data faktisk tilhører, og ut ifra dette trener opp en modell som er i stand til å klassifisere liknende objekter eller piksler.

2.8.1 Support vector machine

Support vector machine (SVM) er en mye brukt læringsalgoritme som på mange måter er en utvidelse av den enkle perceptron-algoritmen. Målet med SVM er å optimalisere grensen mellom klassene. Grensen, eller margene, er avstanden mellom treningsobjektene og hyperplanet som skiller de ulike klassene, se figur 2. (Raschka & Mirjalili, 2017d)


Bakgrunnen for at man ønsker å optimalisere margene er at modeller med størst mulige marger generaliserer bedre enn modeller med mindre marger. Sagt på en annen måte, større marger gir mindre rom for overtilpasning. SVM er i utgangspunktet en klassifiseringsalgoritme som løser lineære problemer, men ved å tilføre en kernelfunksjon kan den også løse ikke-lineære klassifiseringsproblemer. (Raschka & Mirjalili, 2017d)



Figur 2: Illustrasjon om hvordan SVM klassifiserer ved å finne et optimalisert sett med grenser som skiller klassene. De mest nærliggende objektene til den lineære grensen kalles support vectors. (Raschka & Mirjalili, 2017d)

2.8.2 Beslutningstre

Klassifisering med beslutningstrær er en metode der man sorterer dataene inn i klasser ved å spørre en rekke spørsmål. Ut ifra treningsdataene genererer et beslutningstre en rekke spørsmål som skiller dataene inn i forskjellige klasser. Dataene blir splittet på en slik måte som resulterer i størst mulig informasjonsgevinst (Information gain) se figur 3. (Raschka & Mirjalili, 2017b)

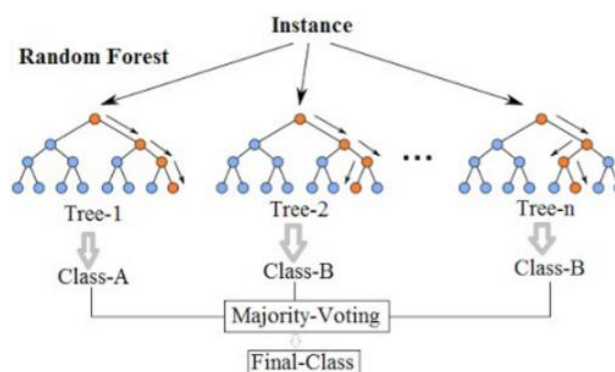


Figur 3: Figuren illustrere hvordan et beslutningstre ser ut og hvordan det tilegner objekter en klasse.

2.8.3 Random forest

Random forest (RF) har de siste årene opparbeidet seg høy popularitet innen maskinlæring, mye på bakgrunn av dens gode kvalitet i klassifisering og brukervennlighet. RF kan betraktes som en samling av beslutningstrær. Målet med metoden er å bruke flere beslutningstrær, som alene sliter med høy varians, til å bygge en mer robust modell som generaliserer bedre og er mindre utsatt for overtilpasning. (Raschka & Mirjalili, 2017a).

RF klassifiserer objektene ved å se på hva flertallet av beslutningstrærne har klassifisert objektet som, se figur 4.



Figur 4: Figuren viser hvordan RF klassifiserer objekter ved å bruke flere beslutningstrær, der flertallet av beslutningstrærne bestemmer hvilken klasse det er (Koehrsen, 2017).

Random forest er som flere andre klassifiseringsmetoder svært følsom for ubalanserte datasett. Dette kommer av at den fokuserer på å minimere den totale feilraten, og derfor har tendenser til å se mer på de store majoritetsklassenes nøyaktighet enn minoritetsklassene. (Chen et al., 2004).

2.8.4 Minimum distance

Minimum distance er en klassifiseringsalgoritme som ser på Euklidiske avstander mellom klassenes middelværdi og pikselverdien til pikselen som skal klassifiseres. En euklidisk avstand defineres slik:

Hvis p og q er punkter i R^3 er den euklidiske avstanden mellom q og p ,


$$d(p,q) = ||p-q||, \quad (1)$$

Siden

$$p-q = (p_1-q_1, p_2-q_2, p_3-q_3) \quad (2)$$

(O'Neill, 2006)

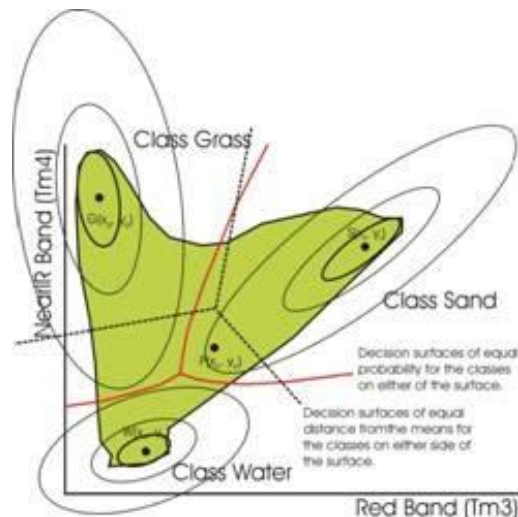
Ved å finne ut hvilken klasse pikslene har kortest Euklidisk avstand til, kan man plassere pikslene i en spesifikk klasse som vist i figur 5 (SEOS, u.å.-b).



Figur 5: Minimum distance (SEOS, u.å.-b)

2.8.5 Maximum likelihood

Maximum likelihood ser på varians og kovarians for å legge piksler til i spesifikke klasser. Dette blir gjort ved å beregne avstanden fra pikselen som skal klassifiseres til hver klasses middelværdi (SEOS, u.å.-a). Enheten dette blir beregnet ut ifra er standardavviket i retning pikselen, se figur 6. Pikselen tildeles klasse ut ifra det minste standardavviket.



Figur 6: Maximum Likelihood (SEOS, u.å.-a)

2.8.5.1 Maximum likelihood i ArcGIS

Algoritmen ArcGIS bruker i verktøyet «Maximum likelihood classification» baserer seg på to prinsipper:

1. Cellene i hver klasse i det flerdimensjonale rommet er normalfordelte.
2. Bayes teorem om beslutningstaking

Verktøyet ser på både variansen og kovariansen til typiske trekk ved de forskjellige klassene, før den tilordner hver celle til en av klassene. Ved å anta at fordelingen av alle klasseprøvene har en normalfordeling, kan en klasse bli karakterisert av en gjennomsnittsvektor og en kovariansmatrise (ESRI, u.å.-b). Gitt disse to karakteristikene for en celledverdi, beregnes en statistisk sannsynlighet for hver klasse for så å bestemme hvilken klasse hver enkelt celle tilhører. Cellen blir tilordnet den klassen som den har høyest sannsynlighet for at den er en del av.

2.8.5.2 Maximum Likelihood i PCI Geomatica

Algoritmen i PCI Geomatica gir brukeren valget mellom å kjøre en klassifisering der klasser kan tilføyes i en NULL-klasse eller en der en NULL-klasse ikke legges til. Metoden er noe ulik, og i denne oppgaven er det varianten der man utelukker en NULL-klasse som er brukt. Ifølge Ross Downey, ansatt i PCI Geomaticas tekniske support (Downey, 2020), bygger denne algoritmen på Mahalanobis avstander. Algoritmen ser på pikslene enkeltvis og legger de til den klassen pikslene har minst Mahalanobisk avstand til. Dette betyr også at dersom piksler avviker veldig fra de andre klassenes signaturer, vil den likevel legges til i klassen med minst Mahalanobisk avstand til. Dette kan skape et dårligere resultat. På tross av dette har vi likevel valgt å bruke algoritmen. Denne gir oss muligheter til å lagre TIF-filer som lett kan sammenlignes med TIF-filer skrevet ut fra andre programvarer, siden de blir lagret på samme måte.

Kapittel 3: Materialer og metode

Materialer og metode er et kapittel som legger frem hva slags data som er brukt, hvordan de er samlet inn og hvilke programvarer som er brukt for å bearbeide dataene. I tillegg tar kapittelet også for seg metoden som er brukt for å klassifisere lidar-dataene.

3.1 Materialer:

3.1.1 CZMIL (Coastal Zone Mapping and Imaging Lidar)

Coastal Zone Mapping and Imaging Lidar (CZMIL) er et luftbårent integrert lidar-bilde system som i hovedsak ble designet for topografisk og batymetrisk kartlegging. Systemet kan brukes til å detektere både fysisk og miljørelatert informasjon i kystområder ved å detektere inhomogeniteter i vannsøylen (Feygels et al., 2017b). Sensorene i CZMIL systemet registrerer pulser i to bølgelengder, en grønn puls (532 nm) og en nær-infrarød puls (1064 nm). Disse ulike bølgelengdene registrerer ulike dybder. Der den infrarøde vil registrere vannskorpen, vil den grønne trenge ned mot sjøbunnen og registrere pulser som blir reflektert fra sjøbunnen og i vannsøylen. I tillegg er et medium-format RGB-kamera inkludert i systemet. Spesifikasjonene til CZMIL systemet vises i tabell 1.


CZMIL specifications (s.n., 2018)		
	Parameters	Specifications
General specifications	Operating altitude	400 m (nominal), up to 1000 m
	Aircraft speed	140 kts (nominal)
	Hyperspectral sensor	CASI-1500H
	Digital cameras	Phase One iXU-RS 1000
	Positioning & GPS/GNSS	Applanix POS AV™
	Positioning system	OmniSTAR capable (subscription required)

Lidar Hydrographic Mode	Shallow channels measurement rate	70 kHz
	Shallow channels maximum depth	$2/k_d$ (bottom reflectivity > 15%)
	Deep channel measurement rate	10 kHz
	Deep channel maximum depth	$4.2/k_d$ (bottom reflectivity > 15%)
	Depth measurement accuracy	$\sqrt{(0.3^2 + (0.013d)^2)} m, 2\sigma$ (3)
	Horizontal accuracy	$(3.5 + 0.05d) m, 2\sigma$ (4)
	Scan angle	20° circular
	Swath width	70% of operating altitude
	Laser classification	Class 4 laser product; IEC 60825-1 Ed. 3.0 2014LMaV1SD
Lidar Topographic Mode	Measurement rate	80 kHz
	Horizontal accuracy	$\pm 1 m, 2\sigma$
	Vertical accuracy	$\pm 15 cm, 2\sigma$
Physical	Power requirements	85 A for lidar/camera @ 28 VDC 95 A @ 28 VDC with CASI
	Operating temperature	0°C to 40°C
	Storage temperature	-10°C to 60°C
	Humidity	0-95% non-condensing
	Sensor head	89 W × 60 D × 90 H cm; 175 kg
	Control & operations rack	59 W × 56.5 D × 106 H cm; 112 kg
Software	Data processing software	CZMIL HydroFusion (Windows-based)

Tabell 1: Spesifikasjoner for CZMIL-sensoren

3.1.2 Prosjektområder

Datainnsamlingen er utført av Terratec AS i Sande, Herøy og Ulsteinvik kommune i Møre og Romsdal. Prosjektområdet har et samlet areal på ca. 25,57 km² fordelt på syv områder, se figur 7 (Larsen, 2019). Dette arealet er en del av det 850 km² store området på Søre Sunnmøre som det nå satses på for å fremstille detaljerte marine grunnkart (Kartverket, 2016).



Figur 7: Utsnitt A viser området som er skannet over Sande kommune. Utsnitt B viser området som er skannet over Ulstein og Herøy kommune. (Larsen & Solli, 2020)

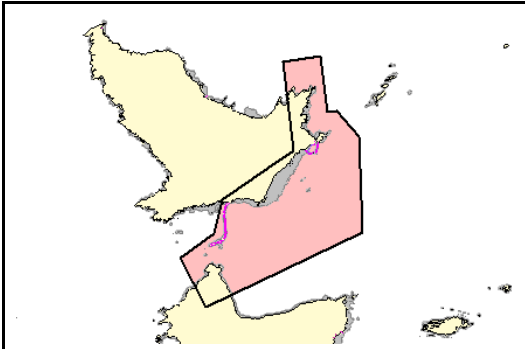
Tabell 2 viser generelle spesifikasjoner som gjelder for alle områdene i prosjektområdet. Tabellen beskriver elementer som utføringen av selve flyvningen, og hvilke forhold det var under flyvningen.

Spesifikasjoner – Prosjekt (Larsen, 2020)	
Kamera	Optech 4800i
Bunnforhold	Varierende pga. Vegetasjon og mørk sjøbunn
Turbiditet	Lav
Flyvning <ul style="list-style-type: none">• Field of view (FOV)• Skannefrekvens• Stripebredde	40° 27 Hz 291 meter

Vær og vannoverflate	Gode forhold
Secchi dybde	15 m
Tidevann	+5 cm over gjennomsnittlig havnivå

Tabell 2: spesifikasjoner for prosjektet (Larsen & Solli, 2020).

3.1.3 Presentasjon av testområdet

	Runde	
	Område	5,1 km ²
	Flyhøyde	400 m
	Flystriper	12

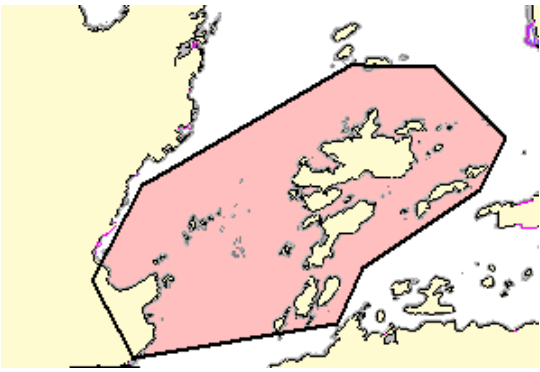
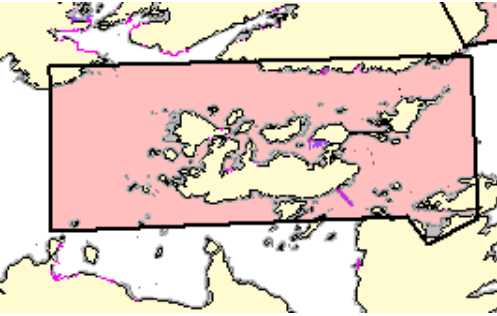
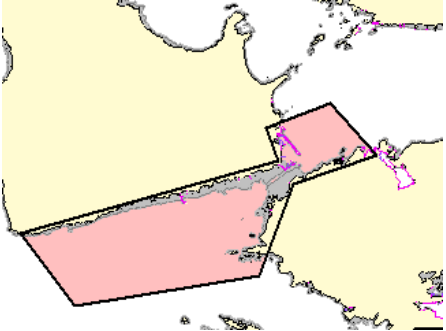
Tabell 3: Viser testområdet, størrelsen til testområdet, flyhøyde og antall flystriper (Larsen & Solli, 2020).

For å teste hypotesen om det er mulig å klassifisere sedimenter på sjøbunnen, var det nødvendig med et testområde, vist i tabell 3. På dette testområdet ble det testet ulike teknikker og metoder for å finne ut hvordan laserdata fra fly kan gi best mulig resultater.

Målingene gjort langs kysten av Runde ble valgt på bakgrunn av at dette var det første området som ble mottatt av Terratec. Området har sammenhengende god dekning og punkttetthet. Sedimentkartet til NGU dekker også et bredt spekter av sedimenttyper og er ifølge Terratec et godt område for å gjennomføre tester for klassifisering.

3.1.4 Presentasjon av verifiseringsområdene

Videre ble det vurdert hvilke kartlagte områder som ville gi best resultater basert på oppnådd resultat over testområdet. Det ble vurdert at tre av de syv områdene hadde relativt god dekning, med en punkttetthet som fører til at man ikke mister for mye informasjon når punktskyen konverteres til raster. Disse verifiseringsområdene vises i tabell 4.

	Hatløya (Torvikholmane)	
	Område	7,7 km ²
	Flyhøyde	400 m
	Flystriper	16
	Nautøya	
	Område	7,3 km ²
	Flyhøyde	400 m
	Flystriper	9
	Nærlandsøya	
	Område	6,3 km ²
	Flyhøyde	400 m
	Flystriper	9

Tabell 4: Tabellen viser verifiseringsområdene og tilhørende størrelse, flyhøyde og antall flystriper (Larsen & Solli, 2020).

Grunnen til at det kun ble valgt ut tre områder er at hypotesen lar seg teste selv om ikke alle syv brukes. Disse tre områdene inneholdt for det meste de samme sedimenttypene som i området ved Runde. I tillegg var flere av de andre områdene svært små og med lav punkttetthet som førte til at mye informasjon gikk tapt i konverteringen til raster. For å få best mulige raster, som egnet seg til klassifisering, ble det brukt områder med høy punkttetthet og god kartlegging av sedimenter.

3.1.5 Datasett

Det er flere datasett knyttet til oppgaven. Terratec var ansvarlige for innsamlingen av data over både testområdet og verifiseringsområdene. Innsamlingen ble utført med flybåren laserskanning og datasettet består av registrerte returer fra land, vannoverflate, sjøbunnen og andre uidentifiserte punkter. Siden dataene fra den batymetriske laseren inneholdt sensitiv informasjon om kystsonen fikk vi kun godkjenning til å få utdelt data ned til 30 m dyp. Innsamlingen av data ga resultater ned til 40-45 m dyp, så før vi fikk utdelt dataene fra Terratec ble alle punkter dypere enn 30 m fjernet.

Dataene ble preprosessert før de ble utlevert i forbindelse med denne oppgaven. Terratec har gjennomført en standard prosessering på dataene i programvaren som følger med skanneren. I tillegg har Terratec utført en første klassifisering av punktskyen. Denne klassifiseringen gikk ut på å skille de ulike returene fra hverandre, og bestemme hvilke punkter som er f.eks. land, vannoverflate, vegetasjon og sjøbunn. De ulike klassene returene ble tilegnet vises i tabell 5.

1	Unclassified
2	Ground
9	Water
17	Brigde Deck
26	Seafloor Bathy
29	Marine Vegetation

Tabell 5: Tabellen over viser klassene Terratec delte returene inn i under første klassifisering (Larsen & Solli, 2020).

Det neste datagrunnlaget som ble brukt er marine grunnkart fra NGU. Dataene som er brukt for å klassifisere sjøbunnen er basert på en innsamling av batymetriske data og diffus refleksjon fra MBES utført i 2014 og 2015, samlet inn av Kartverket gjennom flere år. Det har også blitt tatt fysiske prøver av sjøbunnen og ved hjelp av video har den diffuse refleksjonen blitt tolket manuelt (Elvenes, 2020). I 2018 ble det utført en oppdatering på dataene der ytterligere lidar-data og flyfoto ble tatt med i klassifiseringen gjennom GLaSS-prosjektet. Basert på dette har NGU valgt å benytte seg av følgende klasser for test- og

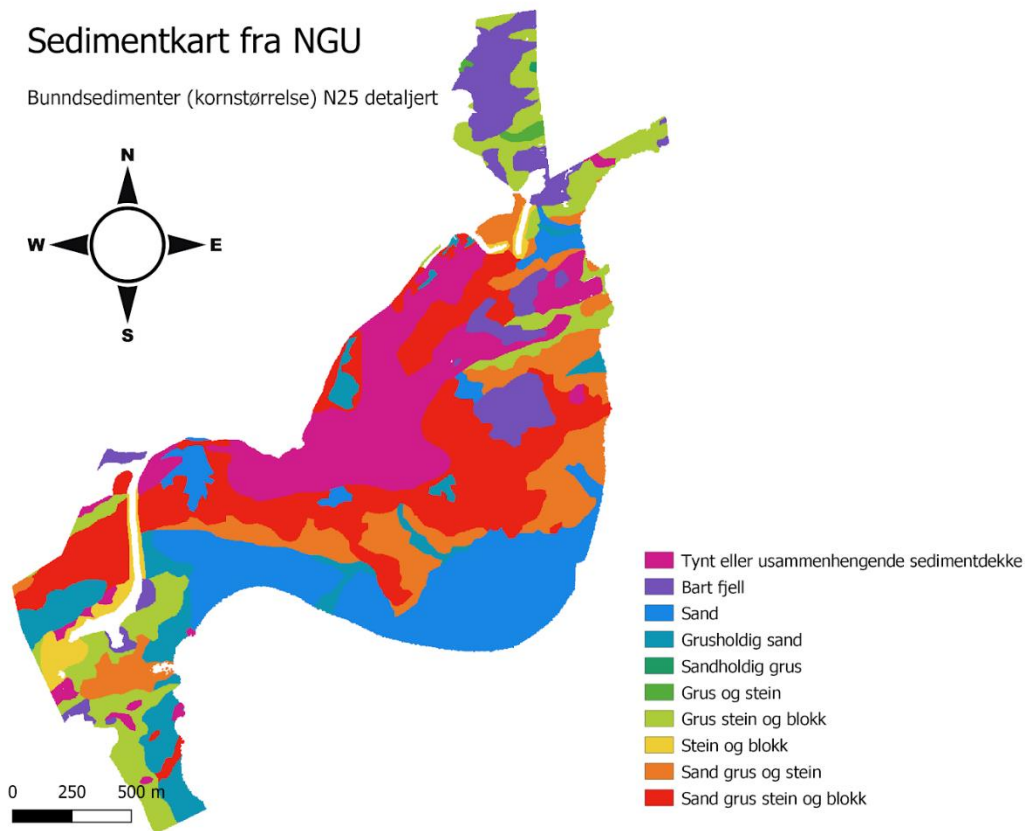
verifiseringsdataene (tabell 6). Det er kartlaget fra NGU som skal brukes som «fasitdata» for klassifiseringene og for å sjekke nøyaktigheten til klassifiseringene.

1	Tynt eller usammenhengende sedimentdekke over berggrunnen
5	Bart fjell
20	Slam
40	Sandholdig slam
80	Slamholdig sand
100	Sand
115	Grusholdig sandholdig slam
120	Grusholdig slamholdig sand
130	Grusholdig sand
150	Slamholdig sandholdig grus
160	Sandholdig grus
174	Grus og stein
175	Grus, stein og blokk
180	Stein og blokk
185	Sand, grus og stein
190	Sand og blokk
205	Slam/sand med stein/blokk
206	Slam og sand med grus, stein og blokk
210	Stein og blokk med sedimentdekke
215	Sand, grus, stein og blokk

Tabell 6: Tabellen over viser klassene NGU har klassifisert dataene sine inn i (Norges Geologiske Undersøkelse, 2019a).

NGUs marine kornstørrelseskart er tolket manuelt i en målestokk på 1:10 000, og er tilpasset bruk i en målestokk på 1:20 000 (Elvenes, 2020), og det er oppgitt en stedfestingsnøyaktighet på 10 m (Norges Geologiske Undersøkelse, 2019b). Det forventes at sedimenter med mer glidende overganger, som mellom «sand» og «slam», har dårligere nøyaktighet enn ved skarpere grenser, som trer tydeligere frem i bakgrunnsdataene, som «bart fjell» og «sand»

(Elvenes, 2020). Kartet over Runde er vist i bilde 2, og dette viser hvordan sedimentene er fordelt over testområdet Runde.



Bilde 2: Bildet viser sedimentkartet fra NGU, med tilhørende klasser.

3.1.6 Programvarer benyttet til preprosessering, klassifisering og fremstilling av resultater

3.1.6.1 Quick Terrain Modeler

Quick Terrain Modeler (QTM) er en programvare utviklet av Applied Imagery, utarbeidet for å kunne behandle lidar-data. QTM gir mulighet til å laste inn, bearbeide og analysere store lidar-datasett (O'Neil-Dunne, 2011).

I denne oppgaven ble programvaren brukt til å fjerne irrelevante klassifiserte punkter som f.eks. vannoverflaten samt uklassifiserte støypunkter fra modellen. Det ble også generert TIF-filer ut fra intensitetsverdiene i laz-filene.

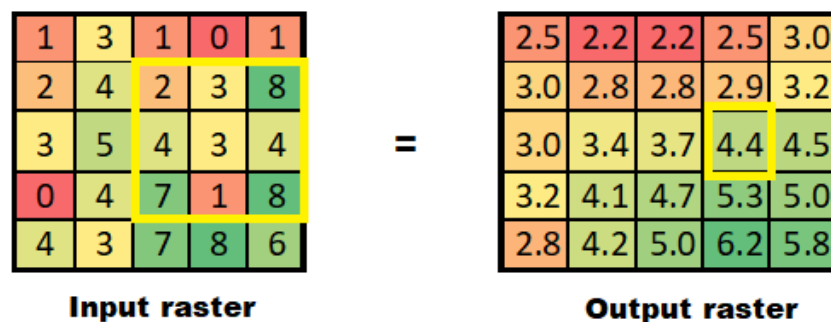
3.1.6.2 ArcGIS pro

ArcGIS pro er den nyeste GIS desktop applikasjonen fra ESRI. Med ArcGIS pro kan man visualisere både 2D og 3D data, redigere og analysere romlige data (ArcGIS pro, 2020).

I denne oppgaven har ArcGIS pro blitt brukt til å gjennomføre ulike rasteroperasjoner som en del av preprosesseringen. I tillegg brukes ArcGIS pro til å lage treningsområder, trene opp modeller for klassifisering og utføre klassifiseringer.

3.1.6.2.1 Focal Statistics

Focal statistics er et verktøy i ArcGIS pro som utfører nabooperasjoner på et raster. Et søkevindu, med en størrelse som bestemmes av brukeren, forflytter seg over det originale rasteret og beregner nye pikselverdier til et nytt raster. Nabooperasjonens funksjoner kan være å hente ut maksimumsverdien, minimumsverdien, gjennomsnittsverdien eller summen av alle pikselverdiene i søkevinduet. Disse beregnede verdiene flyttes så over til output-rasteret og danner det nye rasteret. Metoden focal statistics vises i figur 8. Som figuren viser vil hver pikselverdi i det nye rasteret være en funksjon av nabooperasjonen som ble utført på det opprinnelige rasteret. (ESRI, u.å-a)



Figur 8: Illustrasjon av hvordan focal statistics beregner nye verdier til en output raster. Her er det vist i form av at den beregner ut en gjennomsnittlig verdi fra den 3x3 store masken.

3.1.6.3 Geomatica Focus

Geomatica Focus er en del av programvaren PCI Geomatica, og er designet for å kunne håndtere store mengder ulike dataformater. Ved å konvertere de ulike filtypene til Geomaticas' egne filformat PCIDSK, finnes det også svært mange bearbeidelses-funksjoner i programvaren (PCI Geomatics Enterprises Inc., 2018). I denne oppgaven er programvaren brukt til å klassifisere intensitets-rasterfiler.

3.1.6.4 Python

Python er et objektorientert programmeringsspråk. Det inneholder moduler, klasser og dynamiske datatyper. I tillegg er Python åpen kildekode og er ofte brukt som et utvidelsesspråk for applikasjoner som trenger et programmerbart grensesnitt (Python, 2020). Python ble brukt til å lage forvirringsmatriser og beregne nøyaktigheten til klassifiseringene.

3.1.6.4.1 Moduler

Numpy

Numpy er en grunnleggende pakke for vitenskapelig databehandling i Python. Pakken er en multidimensjonalt vektor-objekt verktøy med høy ytelse (NumPy, 2020).

Pandas

Pandas er et datamanipuleringsverktøy utviklet av Wes McKinney. Det er en modul til Python som bygger på Numpy pakken. Pandas viktigste datastruktur kalles DataFrame, dette lar brukeren manipulere tabelldata på en enkel og brukervennlig måte (learnpython, u.å).

PIL Image

PIL står for Python imaging library som gir Python mulighet til å tolke og behandle billedata. Image er en underklasse av PIL som brukes til å presentere et PIL bilde og funksjoner for å åpne bilder fra filer og lage nye bilder. (Lundh & Clark, 2020)

Sklearn.metrics confusion_matrix

Scikit-learn er en modul for Python som inneholder en rekke læringsalgoritmer for både overvåket og uovervåket læring. I tillegg inneholder denne pakken en rekke funksjoner for å beregne nøyaktighet til disse læringsalgoritmene, som for eksempel «confusion_matrix» som beregner en forvirringsmatrise. (Browniee, 2014)

Sklearn.metrics accuracy_score

Accuracy_score er en funksjon fra Scikit learns modul sklearn som beregner nøyaktigheten til en klassifisering som består av flere klasser. (scikit-learn developers, 2007)

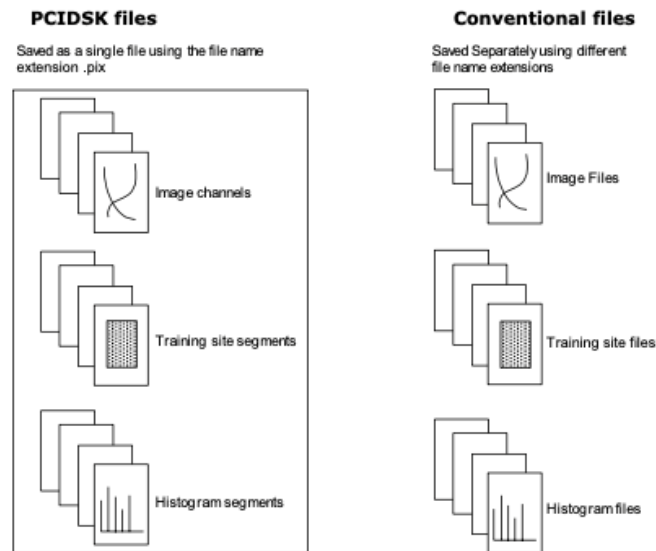
3.1.6.5 Microsoft Excel

Microsoft Excel er regneark som brukes til å fremstille tabeller, grafer eller analysere numeriske data. Det er et kraftig og brukervennlig verktøy. I denne oppgaven brukes Microsoft Excel til å fremstille resultater i tabellform og grafisk.

3.1.7 Filformater som er brukt i oppgaven

3.1.7.1 PCIDSK

PCIDSK er PCI Geomaticas sitt eget filformat. Det som skiller PCIDSK fra andre filformater er at man i PCIDSK lagrer all informasjon i en fil, mens man i andre ordinære filformater lagrer forskjellig informasjon i ulike filer (PCI Geomatics Enterprises Inc., 2018). Dette fremstilles i figur 9. Fordelen er at man kan lagre store mengder data i en og samme fil. Dette gjør at man enkelt kan endre, slette og legge til data uten å måtte lage nye filer.



Figur 9: Figuren illustrerer forskjellen mellom PCIDSK filer og andre konvensjonelle filtyper. (PCI Geomatics Enterprises Inc., 2018)

3.1.7.2 Shapefile

Shapefile er et utvekslingsformat for ikke-topologiske geometrier. En shapefile lagrer informasjon om romlige data i form av et sett med vektorkoordinater eller punkter, der hver flate, linje eller punkt har et sett med attributter (ESRI, 1998). Shapefiler er enkle å redigere, i tillegg til at de har en svært hurtig tegningstid, som betyr at flater og objekter vises hurtig på skjermen, også når man panorerer i kartutsnittet.

3.1.7.3 GeoTIFF

GeoTIFF er en OGC standard som brukes som utvekslingsformat for georefererte raster data, og er basert på TIFF formatet, også bare kalt TIF (NASA Earthdata, 2019). Filer av typen GEOTIFF blir i denne oppgaven referert til som TIF filer.

3.1.7.4 LAZ/LAS

LAS er et filformat for utveksling av 3-dimensjonale data i form av punktskyer. Formatet er i hovedsak brukt og utviklet for lidar-data, men støtter også andre typer 3-dimensjonale data som er gitt som x, y, z verdier (ASPRS, 2019).

LAZ er et identisk format som LAS, med det unntak av at LAZ er komprimert (Manifold, 2020).

3.1.7.5 CSV

Comma-separated values (CSV) er et filformat uten en formell spesifikasjon. Det er et mye brukt filformat for utveksling av tall og verdier. Enkelt forklart er CSV filer en mengde tall eller bokstaver som er separert med et tegn, dette kan være komma, mellomrom, semikolon eller andre tegn. (Shafranovich, 2005)

3.1.8 Forvirringsmatrise

		Predicted class	
		<i>P</i>	<i>N</i>
Actual class	<i>P</i>	True positives (TP)	False negatives (FN)
	<i>N</i>	False positives (FP)	True negatives (TN)

Figur 10: Illustrasjonsfigur av en forvirringsmatrise med to klasser (Raschka & Mirjalili, 2017c).

En forvirringsmatrise, se figur 10, er en matrise som beskriver antallet true positive (TP), true negative (TN), false positive (FP) og false negative (FN), som er prediksjoner av en klassifisering (Raschka & Mirjalili, 2017c). TP er antallet objekter som er predikert som positiv og som også er av klassen positiv og FN er objekter som er predikert til å være negative, men faktisk tilhører klassen positiv. Det samme gjelder for FP og TN, bare at her er FP predikert til å være positiv, men tilhører klassen negativ og TN er riktige predikerte negative objekter.

En forvirringsmatrise er et godt verktøy for å se hvor godt klassifiseringen predikerer de ulike klassene, hvilke klasser den klarer å predikere og hvilke klasser som blir predikert feil.

3.1.9 Nøyaktighet

Den observerte nøyaktigheten til en klassifisering sier noe om hvor godt klassifiseringsalgoritmen predikerer de ulike klassene.

Den observerte nøyaktigheten er gitt slik:

$$\text{Nøyaktighet} = \frac{\text{Summen av diagonalen i en forvirringsmatrise}}{\text{Summen av alle objekter}} * 100 \quad (5)$$

(Raschka & Mirjalili, 2017e).

Det er dette oppgaven tar utgangspunkt i når det er snakk om nøyaktighet. I denne oppgaven er også nøyaktigheten oppgitt som prosent.

3.1.10 Precision, recall og F1 score

Precision, også kalt positiv prediktiv verdi, er forholdet mellom korrekt klassifiserte objekter, true positive, og totalt antall objekter som er klassifisert som positive.

$$P = \frac{TP}{(TP + FP)} \quad (6)$$

Recall er sannsynligheten for deteksjon eller den sanne positive rate. Det er forholdet mellom korrekt klassifiserte objekter og totalt antall objekter som er positive ifølge «fasitdata».

$$R = \frac{TP}{(TP + FN)} \quad (7)$$

F1 score, eller F1 verdi, er et mål på hvor godt noe er klassifisert som tar hensyn til både precision og recall og er derfor en funksjon av begge. F1 verdien er beskrevet som:

$$F1 = 2 * \frac{P * R}{P + R} \quad (8)$$


(Shung, 2018) (Raschka & Mirjalili, 2017c)

3.2 Metode som er brukt til preprosessering og klassifisering av intensitetsverdier

3.2.1 Preprosessering og bearbeiding av data


I en oppgave der man er ute etter å se på sjøbunnen i et 2D aspekt, som i et raster, er det viktig å gjøre et utvalg av returene som er reflektert fra sjøbunnen. For å optimalisere muligheten for en tilstrekkelig klassifisering av sjøbunnen er man avhengig av å fjerne irrelevante returer fra modellen. Programvaren QTM gir brukeren denne muligheten. Ved å kjøre en diskret analyse vil brukeren kunne velge hvilke returer som skal brukes i videre analyser av datasett. Videre vil man også ha muligheten til å fremstille digitale terreng- eller overflatemodeller basert på de utvalgte returene som defineres.

I denne oppgaven ble laz-filene fra Runde lastet inn i programvaren. Disse filene inneholder flere returer, som alle er klassifisert etter tabell 5. Modellen kjøres gjennom en kontinuerlig analyse der punktene fremstilles på en kontinuerlig skala, og der fargene viser grad av styrke på retursignalene. Dette kan sees i bilde 3. Lave intensitetsverdier vises i blått og høyere intensitetsverdier vises i rødt.



Bilde 3: Bildene over viser modellen etter at den har blitt kjørt gjennom en kontinuerlig analyse. Bildet til venstre viser modellen ovenfra, og bildet til høyre viser modellen i profil. Her kan man se returene nedover i vannsøylen.

Det ble i oppgaven laget to ulike modeller som inneholdt noe ulikt valg av klasser. For å lage modeller der man fjerner visse klasser, og for å bestemme hvilke klasser som ønskes i modellene bruker man en diskret analyse. Klassene 1, 2, 9 og 17 fra tabell 5 ble fjernet fra begge datasettene. Det ble derimot bestemt å teste data som inneholder vegetasjon på sjøbunnen og data uten vegetasjon på sjøbunnen. Bilde 4 viser hvordan modellen ser ut etter at man kun har tatt med punktene fra sjøbunnen og vegetasjon.



Bilde 4: Bildene over viser modellen etter at man har fjernet alle klasser utenom sjøbunnen og vegetasjonen på sjøbunnen.

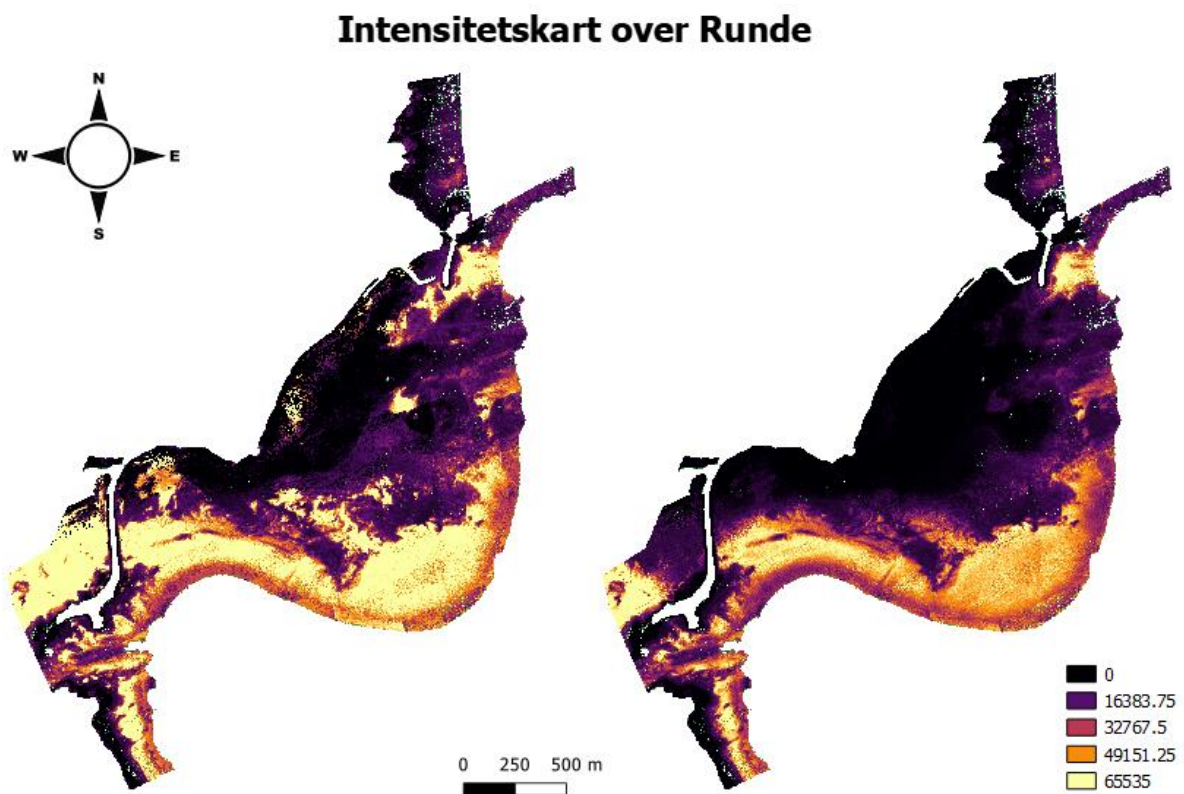
Som nevnt over ble det laget modeller både med og uten vegetasjon. Hensikten med å lage begge disse modellene er at man senere kan sammenligne om dette utgjør noen forskjell i klassifiseringen av sjøbunnen.

For å kunne utføre videre analyser av sjøbunnen må modellen konverteres til en TIF-fil. Selve klassifiseringen av sjøbunnen må gjøres i andre programvarer, og ved å konvertere til en rasterfil der hver piksel inneholder en intensitetsverdi gir dette muligheten til å åpne filene i andre programvarer. Det er også lettere for programvarene som skal brukes til klassifisering å håndtere rasterdata enn punktskyer. Denne konverteringen er en algoritme som er innebygd i QTM.

Når man laster laz-filene inn i QTM gjør programvaren en skalering der intensitetsverdiene legges mellom 0 og 255. I den originale filen ligger intensitetsverdiene mellom 0 og 65535. I konvertering mellom laz-fil og tif-fil gir QTM brukeren mulighet til å velge om man skal gå videre med originale eller skalerte intensitetsverdier. Ved å velge de originale intensitetsverdiene oppnår man et optimalisert TIF-bilde og gå videre med i analyser over området.


I denne prosessen er man ute etter å finne ut hvilke TIF-bilder som gir best mulig resultat. Men dette menes at man ønsker å se på TIF-bilder med forskjellige egenskaper. QTM gir muligheten til å danne disse TIF-filene, der man velger hvilke egenskaper filene skal ha. Det ble lagret filer for følgende egenskaper; maksimum intensitet uten vegetasjon, maksimum intensitet med vegetasjon, gjennomsnittlig intensitet uten vegetasjon og gjennomsnittlig intensitet med vegetasjon. Maksimums og gjennomsnittlige intensitetsverdier blir beregnet

ved at alle punkter innenfor et gitt kvadratisk område får verdien til den høyeste intensitetsverdien eller den gjennomsnittlige verdien til alle punktene. Dette blir da pikselverdien, som får samme pikselstørrelse som det gitte kvadratiske området. Bilde 5 viser de to ulike metodene, der man tydelig ser en forskjell mellom å fremstille med maksimums- og gjennomsnittlige intensitetsverdier. Det er også mulig å lagre bilder der minimumsintensiteten vises, men etter en vurdering ble dette valgt bort. Bakgrunnen for at TIF-filer med minimumsverdier ble valgt bort er at mye informasjon vil gå tapt. Det ble dermed ikke sett som hensiktsmessig å prøve å klassifisere bildene med denne egenskapen.




Bilde 5: Intensitetskart over Runde i rasterformat, fremstilt med QTM. Bildet til venstre viser maksimums intensitetsverdier, mens bildet til høyre viser gjennomsnittlige intensitetsverdier.

Laserdataene fra Terratec inneholder også endel landområder, se bilde 6. For at disse landområdene ikke skal bli tatt med som en del av klassifiseringen av sjøbunnen må disse områdene klippes bort. Dette ble gjort i ArcGIS pro ved å klippe intensitetskartene fra laserdataene mot sedimentkartene fra NGU. Ved å gjøre dette sikres det for at det kun er områder kartlagt fra NGU som blir tatt med i klassifiseringene.



Bilde 6: Illustrerer området Runde før og etter rasteret ble klippet. Figuren til venstre viser intensitetsrasteret over Runde med landområder, figuren til høyre viser intensitetskartet etter en klippoperasjon.

Siden punkttettheten i laserdataene var svært forskjellig i ulike områder, oppstod det “hull” i rasterfilene som ble generert i QTM. For å ha mer sammenhengende områder i rasterfilene og for å glatte ut bildet ble det også utført en type glatting ved å bruke verktøyet focal statistics i ArcGIS pro. I denne operasjonen ble det valgt å bruke en gjennomsnittsfunksjon, og et søkevindu på 3x3 piksler. Bakgrunnen for dette var å få et mindre kornete raster, siden det er naturlig å tenke at en piksel tilhører samme sedimentklasse som sine nærliggende piksler. Bilde 7 illustrerer dette.



Bilde 7: Bildet viser forskjellen på datasettet før og etter glatting

Det ble også bestilt opp sedimentkart fra NGU, bunnsedimenter (kornstørrelse) N25 detaljert. Disse kartlagene besto av et flatedatasett og et linjedatasett på shapefile format. For å senere kunne sammenligne klassifiseringene piksel for piksel måtte flatedatasettet fra NGU konverteres til rasterformat. Dette ble utført i ArcGIS pro.

3.2.2 Valg av datasett

Etter preprosessering av punktskyen i både QTM og ArcGIS pro ble det valgt ut åtte ulike rasterdatasett over testområdet Runde som skulle brukes til klassifisering. Disse åtte rasterdataene står beskrevet i tabell 7.

Kode	Intensitetsverdi	Glattet datasett	Vegetasjon
mfnno	Mean	x	Nei
mnrno	Mean		Nei
mxfno	Max	x	Nei
mxrno	Max		Nei
mfnw	Mean	x	Ja
mrxw	Mean		Ja
mxfw	Max	x	Ja
mrxw	Max		Ja

Tabell 7: Oversikt over testdatasettene som ble brukt til klassifisering av testområde Runde.

Tabellen beskriver navnet på datasettet, om det er gjennomsnittlige eller maksimums intensitetsverdier, om det er blitt utført en glatting på datasettet og om datasettet inneholder vegetasjon eller ikke. Kodene som beskriver datasettet vil brukes videre i oppgaven til å forklare hvilket datasett som blir brukt og hva det inneholder.

Datasettene som ble valgt ut består av intensitetsverdier som har piksler som enten har maksimumsverdi eller gjennomsnittlig verdi fra punktskyen. I tillegg har halvparten av datasettene intensitetsverdier med vegetasjon og halvparten uten. Det ble også utført en glatting av rasterdataene, for å se om dette ga bedre klassifiseringsresultater.

Datasettene som gir best resultater vil igjen brukes på verifiseringsområdene, for å se om man kan oppnå et like godt resultat der som på testområdet. I tillegg gir dette muligheten til å se om datasett uten vegetasjon gir bedre eller dårligere resultater enn datasett med vegetasjon. Det kan også være interessant å se om det er gjennomsnittlig intensitetsverdier eller maksimumsintensitetsverdier som gir best resultat, eller om enkelte sedimenter klassifiseres bedre med maksimums- eller gjennomsnittlige intensitetsverdier.

3.2.3 Klassifisering av intensitetsverdier

Klassifisering er beskrevet i delkapittel 2.7 og 2.8. I denne oppgaven er det piksler som skal klassifiseres ut ifra dens egenskap, som i dette tilfellet er en intensitetsverdi. Klassene som skal predikeres er ulike typer kornstørrelser og sedimenttyper på havbunnen. Det er brukt ulike programvarer til klassifisering av dataene.

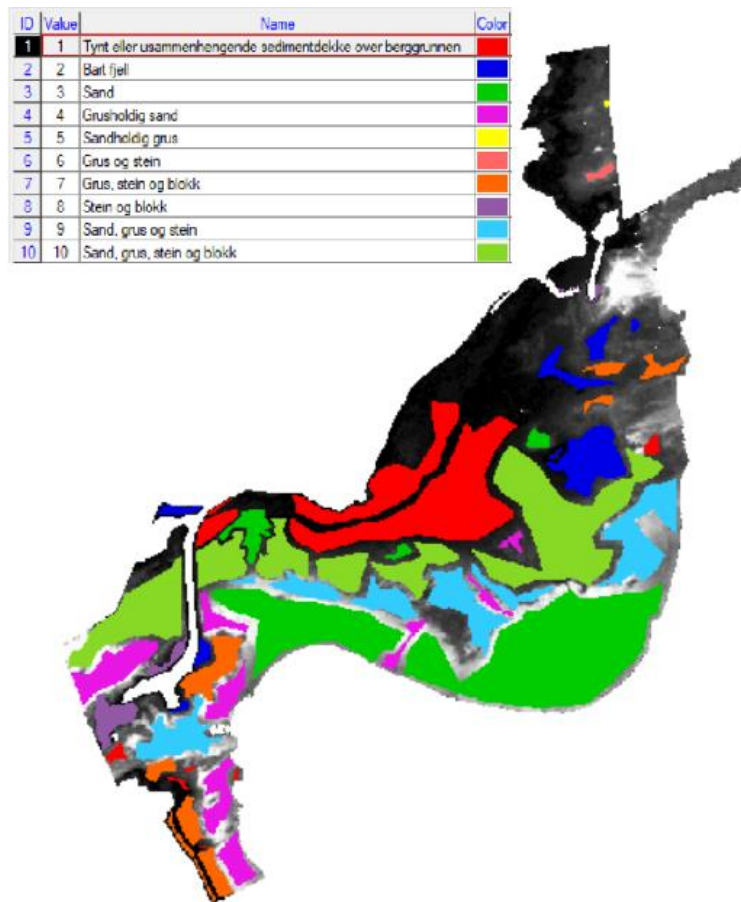
3.2.3.1 Gjennomføring av klassifisering i PCI Geomatica

Ved å gjennomføre en styrt klassifisering i PCI Geomatica oppretter man to nye lag. Et lag der man legger inn treningsområder og et resultatlag. I datalaget for treningsområder danner man polygoner som representerer de ulike klassene man er ute etter. Disse polygonene baserer seg på «fasitdataene» fra NGU. I oppgaven ble det laget treningsområder for 10 av klassene fra tabell 6 og disse klassene er vist i tabell 8.

1	Tynt eller usammenhengende sedimentdekke over berggrunnen
5	Bart fjell
100	Sand
130	Grusholdig sand
160	Sandholdig grus
174	Grus og stein
175	Grus, stein og blokk
180	Stein og blokk
185	Sand, grus og stein
215	Sand, grus, stein og blokk

Tabell 8: Tabellen viser hvilke klasser det ble laget treningsområder for.

Bilde 8 viser treningsområdene som ble tegnet opp i PCI Geomatica.

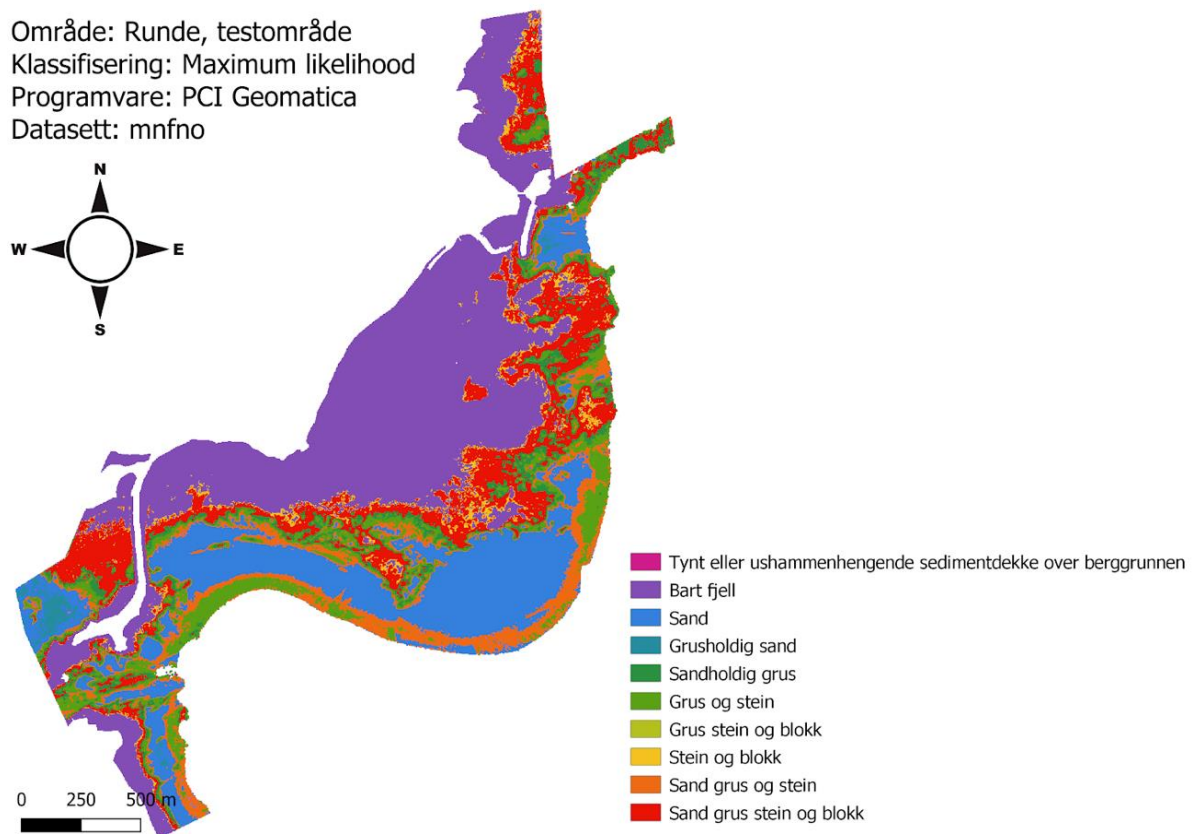


Bilde 8: Bildet viser treningsområder i PCI Geomatica.

PCI Geomatica gir brukeren muligheten til å utføre klassifiseringer ved bruk av ulike metoder. Minimum distance, maximum likelihood og parallelepiped er alle metoder som støttes av PCI Geomatica og som gir resultater av varierende grad. Hvor godt klassifiseringene gjennomføres kartlegges i en klassifiseringsrapport som skrives ut automatisk. Denne baserer seg på hvordan pikslene klassifiseres ut fra treningsområdene som opprettes. I rapporten får man ut en forvirringsmatrise, gjennomsnittlig nøyaktighet og en total nøyaktighet. Gjennomsnittlig nøyaktighet er hvor godt diagonalen i forvirringsmatrisa stemmer overens med treningsområdene. Dette betyr gjennomsnittet av hvor godt de ulike sedimentene klassifiseres som det de faktisk er. Ross Downey skriver at den totale nøyaktigheten sier noe om nøyaktigheten til klassene basert på en vektet verdi (Downey, 2020). Nøyaktigheten til hver klasse vektet med antallet treningsområder for den gjeldende klassen.

Alle de åtte ulike datasettene nevnt tidligere ble klassifisert i PCI. Klassifiseringen ble kjørt basert på to forskjellige metoder; Maximum Likelihood og Minimum Distance.

Parallelepiped brukes ikke på bakgrunn av at PCI Geomaticas algoritme bygger på den samme som maximum likelihood, og ved en test gav disse metodene eksakt samme resultat. Det vurderes derfor til at det ikke er hensiktsmessig å bruke begge to. Som nevnt over skrives det ut en klassifiseringsrapport som viser til hvor nøyaktig klassifiseringen blir utført. Figur 11 og 12 viser forvirringsmatrisene til klassifiseringene som er vist i bilde 9 og 10. Forvirringsmatrisene mangler det enkelte kolonner, disse kolonnene er klasser klassifiseringen ikke klarte å predikere. I figur 11 mangler både kolonnen for «Tynt eller usammenhengende sedimentdekke over berggrunnen» og «grus, stein og blokk», dette er fordi klassifiseringen maximum likelihood ikke klarte å predikere disse klassene på datasettet mnfno.



Bilde 9: Bildet over viser en klassifisering i PCI Geomatica. Klassifiseringsmetoden er Maximum likelihood. Datasettet inneholder gjennomsnittlige intensitetsverdier, det er utført en glatting og vegetasjonen er fjernet.

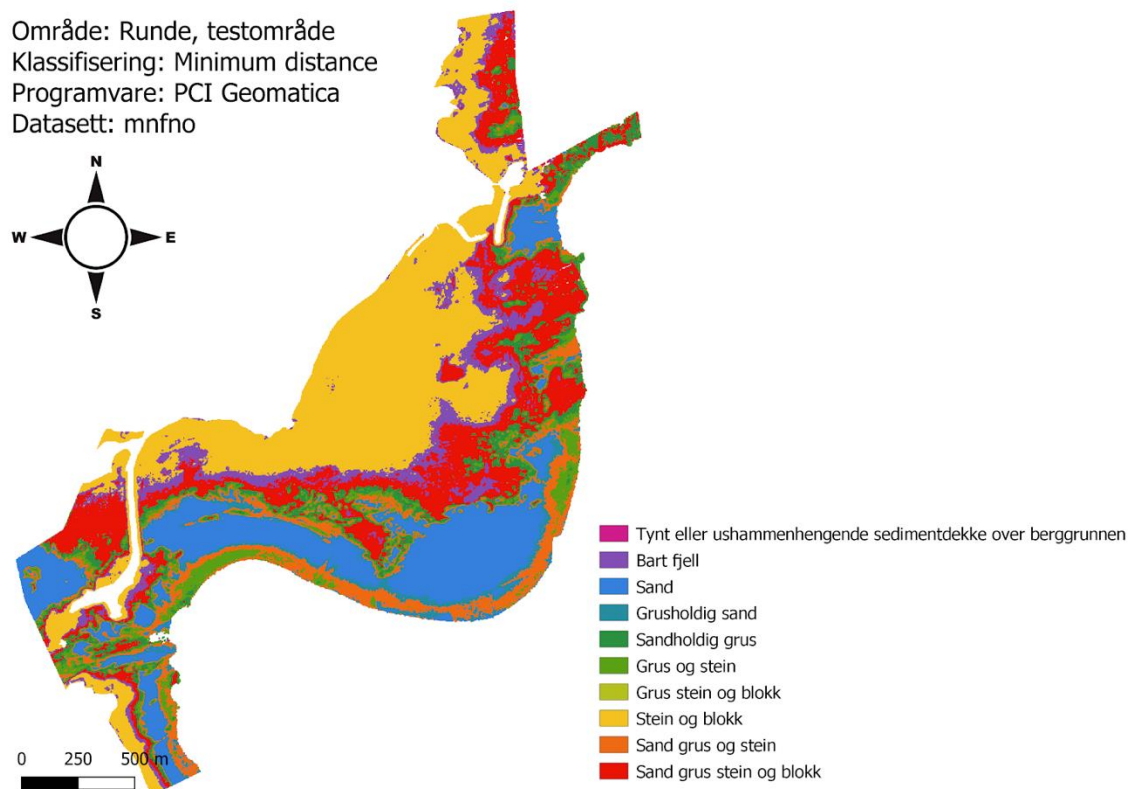
CONFUSION MATRIX

Areas		Percent Pixels Classified by Code									
Name	Code	Pixels	0	2	3	4	5	6	8	9	10
Tynt eller us	1	37143	0.00	96.66	0.01	0.00	0.50	0.86	0.33	0.18	1.46
Bart fjell	2	12801	0.00	89.67	0.00	0.00	0.28	0.11	3.83	0.00	6.11
Sand	3	63455	0.00	3.45	68.07	0.04	0.09	7.57	0.64	17.87	2.27
Grusholdig sa	4	17243	0.00	1.11	44.25	12.71	2.81	15.65	0.30	20.53	2.64
Sandholdig gr	5	61	0.00	0.00	0.00	0.00	96.72	3.28	0.00	0.00	0.00
Grus og stein	6	531	0.00	0.00	0.00	0.00	6.40	86.25	0.00	7.34	0.00
Grus, stein o	7	11710	0.01	31.98	2.95	0.00	12.11	11.32	5.94	4.12	31.58
Stein og blok	8	4204	0.00	90.44	0.14	0.00	1.97	1.09	1.83	0.14	4.38
Sand, grus og	9	28423	0.00	0.07	26.71	0.05	11.35	28.53	0.17	25.48	7.64
Sand, grus, s	10	53771	0.00	29.18	2.49	0.36	9.22	5.75	7.39	1.78	43.85

Average accuracy = 53.07 %

Overall accuracy = 48.91 %

Figur 11: Bildet viser forvirringsmatrisen til klassifiseringen utført i Bilde 9.



Bilde 10: Klassifisering av testområdet i PCI Geomatica. Klassifiseringsmetoden er Minimum distance, og datasettet inneholder gjennomsnittlige intensitetsverdier, det er utført en glatting og vegetasjonen er fjernet.

CONFUSION MATRIX

Areas		Percent Pixels Classified by Code									
Name	Code	Pixels	1	2	3	4	5	6	8	9	10
Tynt eller us	1	37143	0.00	0.37	0.00	0.02	0.62	0.64	96.23	0.27	1.84
Bart fjell	2	12801	0.00	28.36	0.00	0.00	0.36	0.04	59.81	0.00	11.43
Sand	3	63455	0.00	2.17	61.16	10.05	0.14	5.13	1.12	17.16	3.07
Grusholdig sa	4	17243	0.00	1.05	50.49	10.02	3.49	10.56	0.00	21.42	2.98
Sandholdig gr	5	61	0.00	0.00	0.00	0.00	100.00	0.00	0.00	0.00	0.00
Grus og stein	6	531	0.00	0.00	0.00	0.00	18.83	65.16	0.00	16.01	0.00
Grus, stein o	7	11710	0.01	12.19	1.76	1.74	14.50	7.86	18.17	4.71	39.07
Stein og blok	8	4204	0.00	14.11	0.07	0.07	2.26	0.74	75.81	0.26	6.68
Sand, grus og	9	28423	0.00	0.02	16.43	14.73	14.72	19.85	0.00	26.45	7.79
Sand, grus, s	10	53771	0.00	15.21	2.28	0.82	10.65	3.86	12.40	2.08	52.70

Average accuracy = 46.63 %
 Overall accuracy = 38.42 %

Figur 12: Bildet viser forvirringsmatrisen til klassifiseringen som vises i Bilde 11.

Rapporten som skrives ut fra PCI Geomatica baserer seg kun på nøyaktigheten til treningsdataene brukeren lager. Rapporten gir derfor ikke annen informasjon enn hvor godt pikslene klassifiseres i forhold til treningsdataene, og sier ikke hvor godt klassifiseringen stemmer med faktiske forhold. For å finne ut nøyaktigheten til de klassifiserte dataene i forhold til «fasitdataene» fra NGU, og dermed de faktiske forholdene, må de kjøres gjennom en algoritme i Python, se delkapittel 3.2.3.3.

3.2.3.2 Gjennomføring av klassifisering i ArcGIS pro

Det er mulig å utføre både styrt og ikke-styrt klassifisering av piksler i ArcGIS pro. I denne oppgaven er det kun sett på styrt klassifisering. Det finnes flere metoder for klassifisering i ArcGIS pro. Metodene som er valgt her er SVM, random trees og maximum likelihood. Random trees er samme teknikk som er beskrevet i delkapittel 2.8.3 Random forest.

For å utføre en klassifisering i ArcGIS pro må man først definere hvilke klasser man ønsker å predikere, deretter opprettes det treningsområder der man definerer hvilke områder som tilhører hvilken klasse. Dette gjøres ved å ta utgangspunkt i «fasitdataene» fra NGU. Treningsområdene lagres som en shapefile og kan brukes i de ulike klassifiseringene, slik at alle klassifiseringene har samme treningsområder. Figur 13 viser treningsområdene over testområdet og inneholder de ti sedimenttypene som dekker dette området.





Figur 13: Figuren over viser treningsområdene som ble dannet i ArcGIS pro

I ArcGIS pro kan man trene opp en modell for så å kunne bruke denne modellen på flere forskjellige datasett senere. Dette er en nyttig funksjon når det senere skal sees på verifiseringsområdene.

Det ble trent opp totalt 24 modeller for åtte forskjellige datasett, se tabell 7, og tre ulike klassifiseringer; SVM, random trees og maximum likelihood. Etter at modellene er trent opp, kan disse brukes til å klassifisere intensitetsverdiene som er lagret som en raster i TIF format. Bilde 11-13 viser tre forskjellige klassifiseringsteknikker av datasettet mnfn.



Område: Runde, testområde
 Klassifisering: Maximum likelihood
 Programvare: ArcGIS pro
 Datasett: mnfno



- Runde_maxlike_mean_focal_noveg
- Tynt eller usammenhengende sedimentdekke over berggrunnen
 - Bart fjell
 - Sand
 - Grusholdig sand
 - Sandholdig grus
 - Grus og stein
 - Grus stein og blokk
 - Stein og blokk
 - Sand grus og stein
 - Sand grus stein og blokk

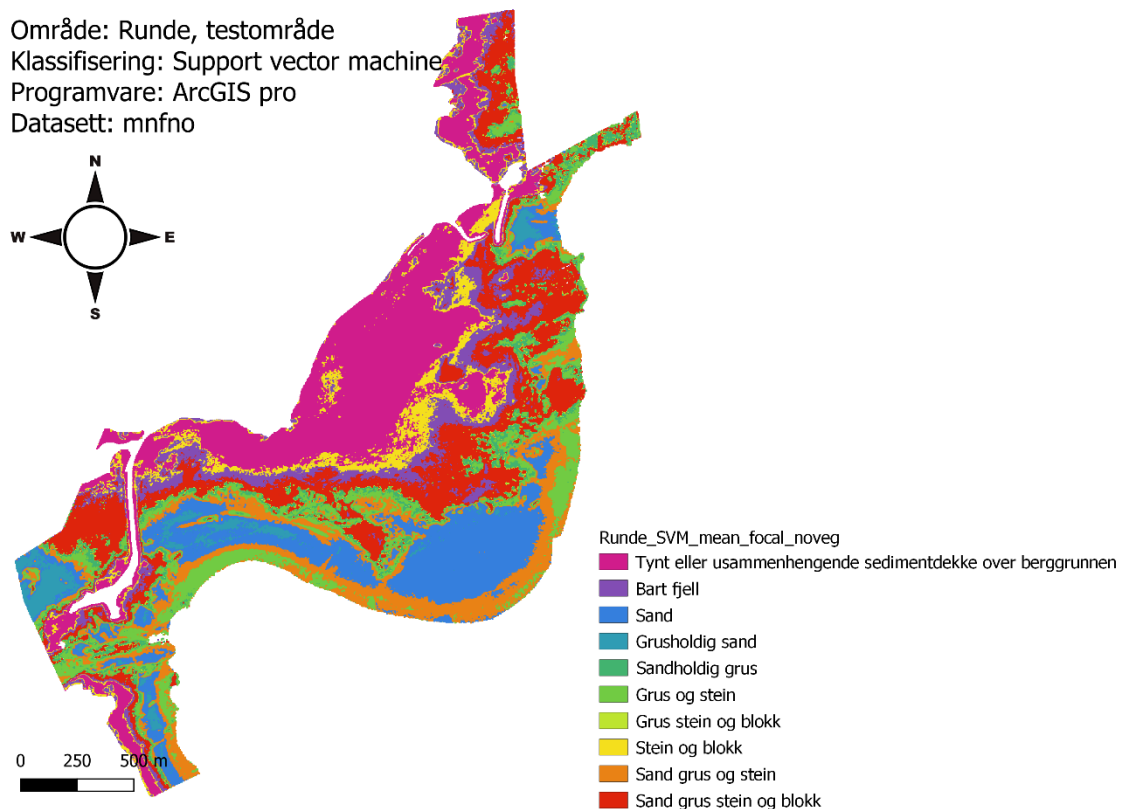
Bilde 11: Resultat av maximum likelihood klassifisering i ArcGIS av Runde. Intensitetskartet som er klassifisert er datasettet mnfno.

Område: Runde, testområde
 Klassifisering: Random trees
 Programvare: ArcGIS pro
 Datasett: mnfno



- Runde_randomtrees_mean_focal_noveg
- Tynt eller usammenhengende sedimentdekke over berggrunnen
 - Bart fjell
 - Sand
 - Grusholdig sand
 - Sandholdig grus
 - Grus og stein
 - Grus stein og blokk
 - Stein og blokk
 - Sand grus og stein
 - Sand grus stein og blokk

Bilde 12: Resultat av random trees klassifisering i ArcGIS av Runde. Intensitetskartet som er klassifisert er datasettet mnfno.



Bilde 13: Resultat av SVM klassifisering i ArcGIS av Runde. Intensitetskartet som er klassifisert er datasettet mnfno.

Det finnes egne funksjoner i ArcGIS pro for å verifisere klassifiserte data. Programvaren har blant annet en funksjon for å beregne en forvirringsmatrise ved å generere evalueringspunkter og bruke disse til å lage en forvirringsmatrise. Siden det i denne oppgaven ble brukt to ulike programvarer, ble denne nøyaktighetsvurderingen utført i Python for å kunne få resultater som kan sammenlignes med hverandre (se delkapittel 3.2.3.3).

3.2.3.3 Beregning av nøyaktighet og forvirringsmatriser i Python

Siden PCI Geomatica og ArcGIS pro har ulike måter å vurdere nøyaktigheten til klassifiseringene, ble det valgt å vurdere alle klassifiseringene ved hjelp av Python slik at man har samme vurderingsgrunnlag for de ulike klassifiseringsteknikkene.

Python scriptet er et svært enkelt script som laster inn TIF-filene til numpy-vektorer, fjerner piksler som ikke inneholder verdier med intensitet og gir mulighet til å endre verdiene i

vektoren slik at samme type sedimentdekke har lik verdi. Dette var nødvendig fordi ArcGIS pro og PCI Geomatica ga samme klasse ulike klasseverdier, der ArcGIS pro begynner sine klasseverdier fra null, starter PCI Geomatica sine verdier fra en. Videre lages en forvirringsmatrise ved hjelp av modulen til scikit learn og det beregnes en nøyaktighet for klassifiseringen. Både nøyaktigheten og forvirringsmatrisen blir lagret i to separate csv filer.

For å kunne få en oversikt over hvilke datasett og hvilke klassifiseringsteknikker som er best, ble det i første omgang kun sett på nøyaktigheten til de ulike datasettene og klassifiseringsteknikkene som vist i tabell 9.

Datasett	SMV	Random trees	Maximum likelihood		Minimum distance	Total
			i ArcGIS pro	PCI Geomatica		
mnfno	38.03	33.33	39.23	29.17	26.00	33.15
mnfw	37.64	31.62	38.56	25.08	20.80	30.74
mxfno	32.16	29.25	30.91	23.06	22.86	27.65
mnrno	37.03	35.31	35.88	15.19	0.17	24.72
mnrw	38.58	30.47	35.73	15.94	0.33	24.21
mxfw	23.65	24.69	25.80	25.31	19.20	23.73
mxrno	31.17	26.92	30.70	10.89	0.16	19.97
mxrw	21.23	20.71	23.96	2.51	0.16	13.71
Total	32.44	29.04	32.60	18.39	11.21	

Tabell 9: Tabell som viser nøyaktigheten oppgitt i prosent til de ulike klassifiseringsteknikkene og datasettene. Tabellen er fargekodet slik at høyere nøyaktighet er vist i sterkere grønnfarge og lavere nøyaktighet i hvit.

Ut fra tabell 9 ser det ut til at datasettene som inneholder gjennomsnittlige intensitetsverdier klassifiserer bedre enn datasett som inneholder maksimums intensitetsverdier. Basert på tabellen kan man også se at glatting fører til noe bedre resultater. I tillegg kan det virke som at datasett der vegetasjonen er fjernet også egner seg bedre til klassifisering enn datasett med vegetasjon.

Man kan se et tydelig skille mellom klassifiseringsteknikkene, der ArcGIS pro jevnt over har mye høyere nøyaktighet på sine klassifiseringsteknikker enn PCI Geomatica.

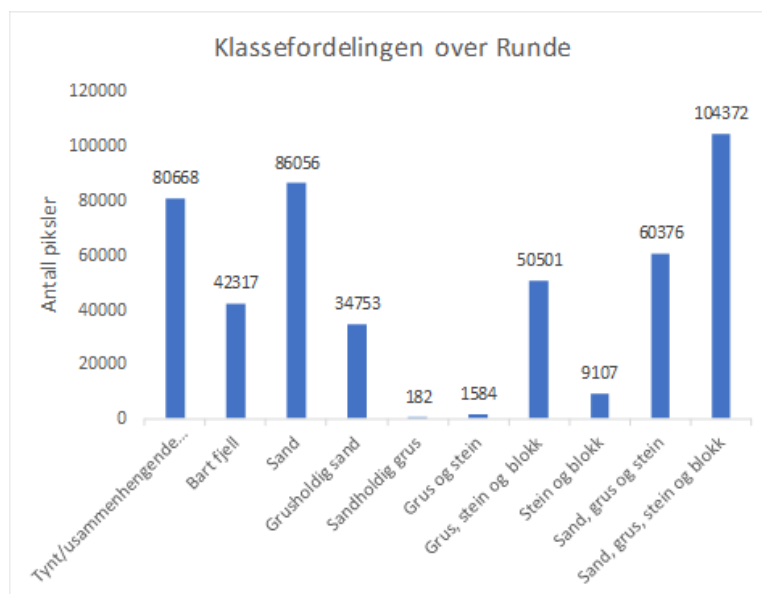
Ved å se på forvirringsmatrisen til den klassifiseringen med best nøyaktighet (figur 14), som i dette tilfellet er datasettet mnfno klassifisert ved å bruke maximum likelihood i ArcGIS, ser man at enkelte klasser blir bedre predikert enn andre.

		Predikerte data												
Datasett: mnfn Område: Runde Klassifisering: Maximum Likelihood Programvare: ArcGIS pro		Tynt/usammenhengende sedimentdekke over berggrunnen	Bart fjell	Sand	Grusholdig sand	Sandholdig grus	Grus og stein	Grus, stein og blokk	Stein og blokk	Sand, grus og stein	Sand, grus, stein og blokk	Precision	Recall	F1 score
Faktiske data	Tynt/usammenhengende sedimentdekke over berggrunnen	67021	4450	309	0	1647	1267	0	0	386	5588	46.79	83.08	59.87
	Bart fjell	23436	12625	18	0	575	149	0	0	21	5493	25.00	29.83	27.21
	Sand	2173	2896	58635	0	483	6415	0	0	13262	2192	57.49	68.14	62.36
	Grusholdig sand	3065	497	18871	0	950	3954	0	0	6226	1190		0.00	
	Sandholdig grus	0	0	0	0	157	13	0	0	0	12	0.53	86.26	1.05
	Grus og stein	255	4	0	0	292	731	0	0	84	218	2.03	46.15	3.89
	Grus, stein og blokk	10426	6048	3193	0	8009	5646	0	0	2348	14831		0.00	
	Stein og blokk	6084	1466	71	0	395	211	0	0	66	814		0.00	
	Sand, grus og stein	3450	1919	16835	0	8126	12172	0	0	9632	8242	28.04	15.95	20.34
	Sand, grus, stein og blokk	27314	20591	4063	0	9051	5479	0	0	2323	35551	47.96	34.06	39.83

Figur 14: Forvirringsmatrise til klassifisering utført i ArcGIS pro med maximum likelihood på datasettet mnfn. Matrisen viser antall piksler som er predikert og hva de er predikert som, i tillegg til en beregnet precision, recall og F1 score.

Ut ifra forvirringsmatrisen til maximum likelihood klassifiseringen, ser man at det ikke er noen tydelig diagonal, og precision for hver klasse er heller ikke i nærheten av 100% i noen av tilfellene. For klassen «tynt eller usammenhengende sedimentdekke over berggrunnen» er precision 46,79%, altså blir svært mange piksler som ikke tilhører klassen «tynt eller usammenhengende sedimentdekke over berggrunnen» likevel klassifisert som dette. Selv om man kan se en del feilklassifisering, er recall relativt høy for denne klassen. Det vil si at av pikslene som faktisk tilhører klassen «tynt eller usammenhengende sedimentdekke over berggrunnen» blir klassifisert riktig. Hvis man ser på F1 verdiene, er det klassen «sand» som blir predikert best, mens av de predikerte klassene er det «sandholdig grus» som har den laveste F1 verdien.

Man kan også se at enkelte klasser ikke blir predikert i det hele tatt. For Maximum likelihood i ArcGIS gjelder dette klassene «grus, stein og blokk» og «stein og blokk». Dette kan tyde på at klassene er for komplekse til at klassifiseringen klarer å skille mellom dem. Bakgrunnen for dette kan være for lite treningsdata eller at intensitetsverdiene til denne klassen er veldig lik andre klasser.



Figur 15: Stolpediagram som viser fordelingen av klassene over Runde oppgitt i antall piksler

Ser man på fordelingen av klassene over Runde (figur 15) ser man at datasettet er svært ubalansert, der noen klasser nesten ikke er representert, som «sandholdig grus» og «grus og stein». At datasettet er såpass ubalansert gjør det vanskeligere for modellene å klassifisere riktig, da den mangler mye treningsdata på enkelte klasser. Dette gjenspeiles veldig når man ser på forvirringsmatrisene i figur 14 og figur 16.

		Predikerte data												
Datasett: mnfn0 Område: Runde Klassifisering: Minimum distance Programvare: PCI Geomatica		Tynt/usammenhengende sedimentdekke over berggrunnen	Bart fjell	Sand	Grusholdig sand	Sandholdig grus	Grus og stein	Grus, stein og blokk	Stein og blokk	Sand, grus og stein	Sand, grus, stein og blokk	Precision	Recall	F1 score
Faktiske data	Tynt/usammenhengende sedimentdekke over berggrunnen	0	3529	137	136	1719	1004	0	66953	460	6730			0.00
	Bart fjell	0	10357	2	13	524	101	0	23298	27	7995	26.41	24.47	25.41
	Sand	0	2336	48394	8573	642	5702	0	2150	15472	2787	62.64	56.24	59.27
	Grusholdig sand	0	411	14714	3493	1136	3421	0	3056	7186	1336	16.75	10.05	12.56
	Sandholdig grus	0	0	0	0	161	5	0	0	0	16	0.50	88.46	0.99
	Grus og stein	0	0	0	0	406	593	0	255	96	234	2.02	37.44	3.83
	Grus, stein og blokk	0	4318	1939	1077	8480	4395	0	10382	2662	17248			0.00
	Stein og blokk	0	1308	31	27	418	161	0	6064	86	1012	4.25	66.59	7.99
	Sand, grus og stein	0	1510	9197	6515	9379	9825	0	3433	11309	9208	28.30	18.73	22.54
	Sand, grus, stein og blokk	0	15443	2842	1023	9325	4167	0	27119	2666	41787	47.30	40.04	43.36

Figur 16: Forvirringsmatrise til klassifisering utført i PCI Geomatica minimum distance på datasettet mnfn0. Matrisen viser antall piksler som er predikert og hva de er predikert som, i tillegg til en beregnet precision, recall og F1 score.

En av de svakere klassifiseringsteknikkene var minimum distance i PCI Geomatica. Forvirringsmatrisen til denne klassifiseringen for datasettet mnfn0 kan sees i figur 16. Her kan man jevnt over se en lavere precision og recall, med noen få unntak. Minimum distance ser ut til å predikere mange piksler som «sandholdig grus», selv om det er relativt få piksler som faktisk tilhører denne klassen. Denne klassen har dermed en svært lav precision, men en høy recall. I tillegg har klassifiseringen bedre precision på «sand» enn maximum likelihood i ArcGIS pro, men F1 verdien for «sand» er lavere. Det vil si at recall for minimum distance er dårligere for denne klassen enn for maximum likelihood i ArcGIS pro. Jevnt over presterer minimum distance dårligere enn maximum likelihood.

3.2.4 Valg av datasett og klassifiseringsteknikker

Basert på resultatene fra Python ble det valgt å gå videre med datasettet mnfn0. Grunnen for at dette vurderes til å være det beste datasettet, baserer seg på ulike vurderinger gjort i testforsøket. Datasettene med gjennomsnittlige intensitetsverdier presterer jevnt over best i de forskjellige klassifiseringsteknikkene. Funksjonen som glatter ut rasterene ser ut til å ha en betydelig positiv effekt, og gir bedre resultater enn de originale rasterene. Tabellen viser også at datasett der vegetasjonen er fjernet gir bedre resultater enn datasett med vegetasjon under klassifiseringene. Dette gjelder jevnt over alle teknikker og datasett, og resultatene denne vurderingen baseres på kan man se i tabell 9.

Det er tydelig at klassifiseringsteknikkene som er tilgjengelige i ArcGIS pro predikerer mye bedre enn teknikkene som er tilgjengelige i PCI Geomatica. Av klassifiseringsteknikkene i ArcGIS pro ble det valgt å gå videre med SVM og Maximum likelihood. Grunnen til dette er at disse så ut til å jevnt over presterer bedre enn random trees, som er en klassifiseringsteknikk som ofte fungerer bedre på balanserte datasett.

		Predikerte data												
Datasett: mnfn Område: Runde Klassifisering: Maximum Likelihood Programvare: PCI Geomatica		Tynt/usammenhengende sedimentdekke over berggrunnen	Bart fjell	Sand	Grusholdig sand	Sandholdig grus	Grus og stein	Grus, stein og blokk	Stein og blokk	Sand, grus og stein	Sand, grus, stein og blokk	Precision	Recall	F1 score
Faktiske data	Tynt/usammenhengende sedimentdekke over berggrunnen	0	70768	215	5	1457	1389	0	1120	376	5338			
	Bart fjell	0	34365	9	0	464	162	0	2449	23	4845	18.57	81.21	30.22
	Sand	0	4658	53903	486	454	8493	0	617	15446	1999	61.27	62.64	61.94
	Grusholdig sand	0	3491	14553	2542	873	5062	0	112	6915	1205	66.77	7.31	13.18
	Sandholdig grus	0	0	0	0	150	16	0	0	0	16	0.57	82.42	1.12
	Grus og stein	0	255	0	0	268	782	0	11	41	227	1.83	49.37	3.53
	Grus, stein og blokk	0	15181	2618	64	7183	6260	0	2005	2357	14833			
	Stein og blokk	0	7417	52	0	366	234	0	187	66	785	1.41	2.05	1.68
	Sand, grus og stein	0	5075	13510	292	7370	14153	0	447	10838	8691	28.25	17.95	21.95
	Sand, grus, stein og blokk	0	43871	3122	418	7932	6168	0	6271	2299	34291	47.47	32.85	38.83

Figur 17: Forvirringsmatrise til klassifisering utført i PCI Geomatica med maximum likelihood på datasettet mnfn. Matrisen viser antall piksler som er predikert og hva de er predikert som, i tillegg til en beregnet precision, recall og F1 score.

Det ble også valgt å ta med klassifiseringsteknikken maximum likelihood fra PCI Geomatica. Grunnen til dette var at selv om teknikken ikke så ut til å klassifisere like godt som ArcGIS pro sine teknikker, var det et potensiale der som kanskje kunne komme frem ved å simplifisere klassene. Man kan se ut fra forvirringsmatrisen, figur 17, til maximum likelihood klassifiseringen fra PCI at store mengder av klassen «tynt usammenhengende sedimentdekke over berggrunnen» blir klassifisert som «bart fjell». Dette er to klasser som kan ha mye av de samme egenskapene. I tillegg har denne teknikken høyere precision på «sand» enn maximum likelihood klassifiseringen i ArcGIS. Det som ser ut til å trekke ned nøyaktigheten til denne klassifiseringsteknikken er rett og slett at den ikke klarer å predikere klassen «tynt usammenhengende dekke over berggrunnen». Dette er en relativt stor klasse i datasettet over Runde og er nok grunnen til at nøyaktigheten er såpass mye dårligere enn ved for eksempel SVM eller maximum likelihood i ArcGIS pro. Ved å forenkle klassene og slå sammen flere liknende klasser kan denne klassifiseringsteknikken prestere bedre enn det den tilsynelatende gjør i denne testen.

3.2.5 Sammenslåing av klasser

Etter analysen i Python ser man at nøyaktigheten til klassifiseringene er relativt lav. En av grunnene til dette kan være at klasseinndelingen er for kompleks og at flere klasser er relativt like, og derfor vanskelig å skille fra hverandre under klassifisering. Med like klasser menes klasser som inneholder samme type sedimenter, som klassene «sandholdig slam» og «slamholdig sand». I tillegg har man klasser som «grus og stein» som igjen kan sies å være ganske lik klassen «grus, stein og blokk». En annen faktor som gjør det vanskelig for klassifiseringene å skille mellom klassene er at noen av klassene ekstremt små, noe som gjør at man får lite treningsdata fra disse klassene. Ved å redusere antallet klasser vil klassene bli mindre komplekse og lettere å skille. I tillegg er det viktig å tenke på at den eneste verdien som brukes for å klassifisere er intensitetsverdien, altså er det kun et attributt som brukes for å skille mellom flere forskjellige klasser.


I samråd med NGU (Elvenes, 2020) har det i denne undersøkelsen blitt redusert til fire ulike klasser som kan sees i tabell 10. NGUs kategorier og klasseinndelinger beskriver sedimenter av ulike kornstørrelser og et naturlig skille vil være å se på partikler som er sand eller grovere og bunntyper som inneholder slam. NGU kommer derfor med forslaget om å skille mellom fjell, sand, slamholdig dekke og grove, blandede bunntyper uten slam. De originale klassene slås sammen basert på flere årsaker. Ruhet og hardhet er en faktor som påvirker dette. Som skrevet i delkapittel 2.7 sier ruheten noe om hvor grovt og ujevnt sedimentet er. Sandbaserte klasser vil derfor ha en annen ruhet enn fjellbaserte klasser. Dette gjelder også hardheten til sedimentene. Grunnen til å skille mellom dekker med og uten slam er fordi slam kan gi nyttig informasjon om for eksempel strøm og avsetningsforhold. I tillegg kan det også gi informasjon om økologiske forhold da sedimenter med slam ofte inneholder en helt annen bunnfauna enn i dekke med grovere sedimenter.

Klasseverdi	Forklaring	Forslag fra NGU	Ny klasseverdi NGU
1	Tynt eller usammenhengende sedimentdekke over berggrunnen	Fjell	1
5	Bart fjell	Fjell	1
20	Slam	Sand	2
40	Sandholdig slam	Sand	2
80	Slamholdig sand	Sand	2
100	Sand	Sand	2
115	Grusholdig sandholdig slam	Sand	2
120	Grusholdig slamholdig sand	Sand	2

130	Grusholdig sand	Sand	2
150	Slamholdig sandholdig grus	Slamholdig dekke	4
160	Sandholdig grus	Grove, blandede bunntyper uten slam	3
174	Grus og stein	Grove, blandede bunntyper uten slam	3
175	Grus, stein og blokk	Grove, blandede bunntyper uten slam	3
180	Stein og blokk	Fjell	1
185	Sand, grus og stein	Grove, blandede bunntyper uten slam	3
190	Sand og blokk	Grove, blandede bunntyper uten slam	3
205	Slam/sand med stein/blokk	Slamholdig dekke	4
206	Slam og sand med grus, stein og blokk	Slamholdig dekke	4
210	Stein og blokk med sedimentdekke	Slamholdig dekke	4
215	Sand, grus, stein og blokk	Grove, blandede bunntyper uten slam	3

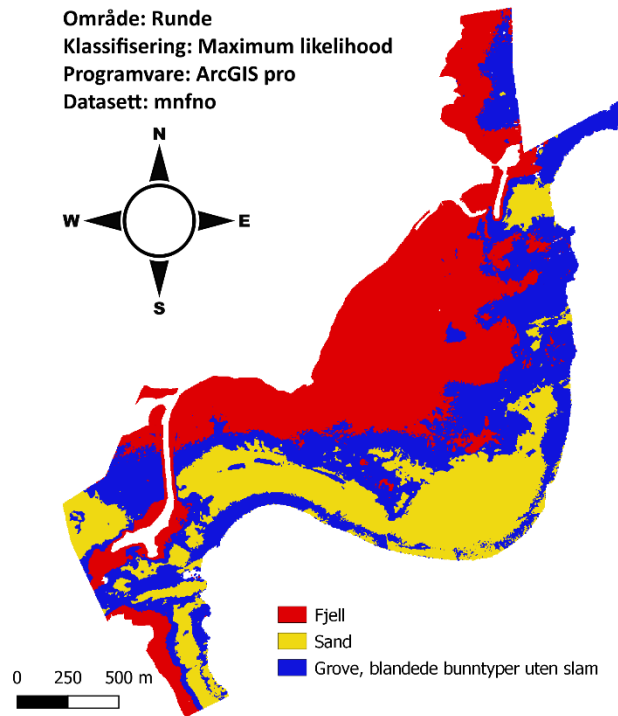
Tabell 10: Tabellen over viser en oversikt over hvilke klasser som er slått sammen i samråd med NGU.

Bilde 14 viser hvordan området ved Runde blir seende ut etter sammenslåingen av klasser.

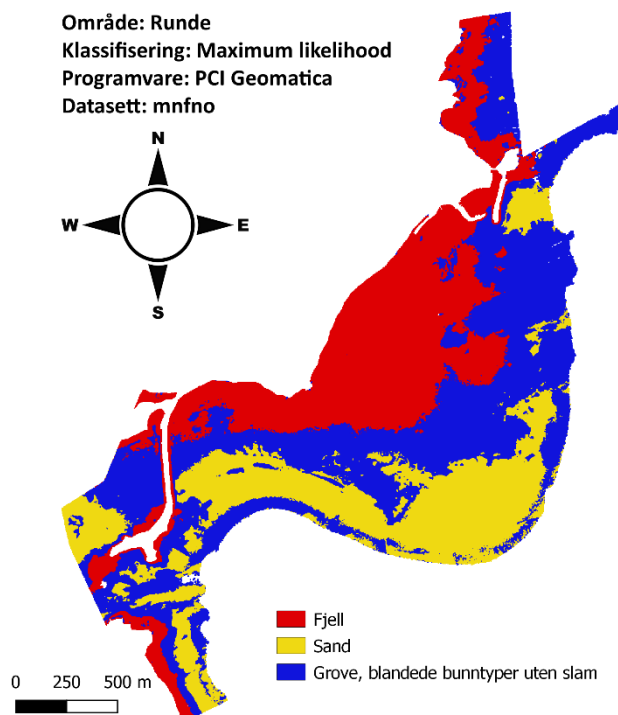


Bilde 14: Kart over testområdet Runde som viser hvordan sedimentene er basert på sammenslåingen av klasser.

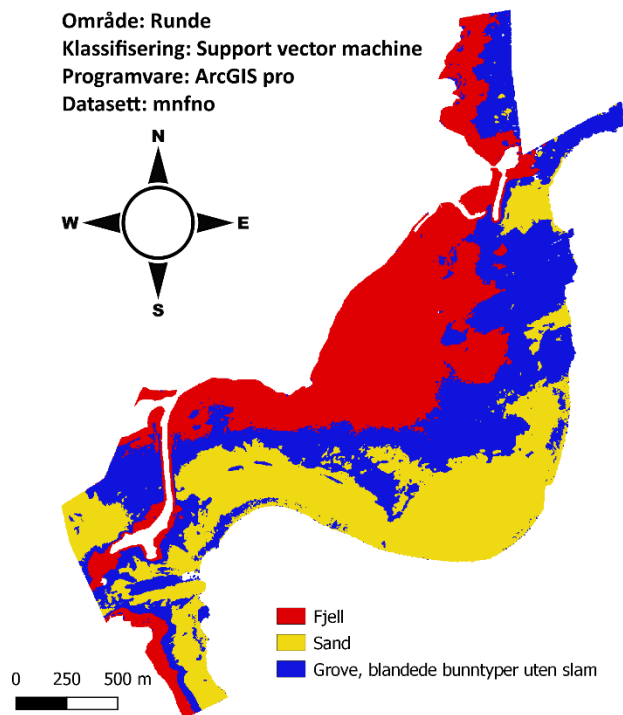
Ved å følge metode beskrevet i delkapittel 3.2.1 og 3.2.3, og bruke de sammenslåtte klassene utarbeidet i samråd med NGU i klassifiseringene, ble klassifiseringene seende ut som vist i bilde 15-17.



Bilde 15: Resultatet av en maximum likelihood klassifisering utført i ArcGIS pro over Runde



Bilde 16: Resultatet av en maximum likelihood klassifisering utført i PCI Geomatica over Runde



Bilde 17: Resultatet av en SVM klassifisering utført i ArcGIS pro over Runde

Som man kan se på bildene av resultatene, bilde 15-17, er det svært små visuelle forskjeller mellom klassifiseringene. Store deler som er klassifisert som «fjell», «sand» eller «grove, blandede bunntyper uten slam», er blitt klassifisert likt i de ulike teknikkene.

Klassifisering	Nøyaktighet
Maximum likelihood i ArcGIS pro	68.08
Maximum likelihood i PCI Geomatica	69.74
Support vector machine	69.7

Tabell 11: Tabellen over viser nøyaktigheten de ulike klassifiseringsteknikkene oppnår oppgitt i prosent.

Resultatene vist i tabell 11 viser at det å slå sammen klasser gjør at man oppnår høyere nøyaktighet på klassifiseringene. Av de tre forskjellige klassifiseringsmetodene er det maximum likelihood i PCI Geomatica som har den høyeste nøyaktigheten, men det er med så liten margin at man kan si at i dette tilfellet predikerer de ulike metodene like godt. Både tabell 11 og bildene 15-17 viser små forskjeller i nøyaktighet og klassifisering mellom de ulike klassifiseringsteknikkene.

Resultatene fra klassifiseringene er vist i figur 18-20 som forvirringsmatriser.

		Predikerte data					
Datasett: mnfno Område: Runde Klassifisering: Support vector machine Programvare: ArcGIS pro		Fjell	Sand	Grove, blandede bunntyper uten slam	Precision	Recall	F1 score
Faktiske data	Fjell	101707	1192	29193	65.01	77.00	70.50
	Sand	6099	102309	12401	68.96	84.69	76.02
	Grove, blandede bunntyper uten slam	48639	44849	123527	74.81	56.92	64.65

Figur 18: Forvirringsmatrise av klassifisering gjort i ArcGIS pro med SVM som klassifiseringsteknikk og mnfno som datasett. I tillegg viser figuren også beregnede precision, recall og F1 score.

		Predikerte data					
Datasett: mnfno Område: Runde Klassifisering: Maximum likelihood Programvare: PCI Geomatica		Fjell	Sand	Grove, blandede bunntyper uten slam	Precision	Recall	F1 score
Faktiske data	Fjell	99299	555	32238	66.14	75.17	70.37
	Sand	5682	86704	28423	73.84	71.77	72.79
	Grove, blandede bunntyper uten slam	45148	30161	141706	70.02	65.30	67.58


Figur 19: Forvirringsmatrise av klassifisering gjort i PCI geomatica med maximum likelihood som klassifiseringsteknikk og mnfno som datasett. I tillegg viser figuren også beregnede precision, recall og F1 score.

		Predikerte data					
Datasett: mnfno Område: Runde Klassifisering: Maximum likelihood Programvare: ArcGIS pro		Fjell	Sand	Grove, blandede bunntyper uten slam	Precision	Recall	F1 score
Faktiske data	Fjell	113844	523	17725	60.13	86.19	70.84
	Sand	8404	85210	27195	74.22	70.53	72.33
	Grove, blandede bunntyper uten slam	67078	29076	120861	72.90	55.69	63.15

Figur 20: Forvirringsmatrise av klassifisering gjort i ArcGIS pro med maximum likelihood som klassifiseringsteknikk og mnfno som datasett. I tillegg viser figuren også beregnede precision, recall og F1 score.

Som figurene 18-20 viser finnes ikke klassen «slamholdig dekke» i datasettet over Runde. Dette er fordi klassene som ble slått sammen til «slamholdig dekke» ikke eksisterer i området.

Sammenslåingen viser bedre nøyaktighet i klassifiseringen enn tidligere. Grunnen til dette kan være fordi klassene er mindre komplekse og særtrekk i intensitetsverdiene er lettere å skille. I tillegg er fordelingen av klassene noe jevnere, selv om størsteparten av områdene er dekket av klassen «grove, blandede bunntyper uten slam» se figur 21.



Figur 21: Stolpediagram som viser fordelingen av klassene over Runde oppgitt i antall piksler. Dette er den nye fordelingen etter at klassene er slått sammen til nye klasser.

Det er uansett forventet at klassifiseringen vil få høyere nøyaktighet siden det er færre klasser å skille mellom, og sannsynligheten for feilklassifisering er betraktelig mindre. Man ser en forbedring i klassifisering, der både precision og recall for de forskjellige teknikkene er adskillig høyere enn tidligere. Det er ingen klasser med lavere precision enn 60%.

Det er ikke bare fordeler som kan komme av å slå sammen klassene. Klassene blir som sagt mindre komplekse og mer generelle, men dette betyr også at mye informasjon kan gå tapt i prosessen. Man får ikke skilt mellom et like stort utvalg kornstørrelser, og ulike bunntyper kan avsløre ulike forhold om strømminger i vannet og biologisk fauna. Denne sammenslåingen er gjort i samråd med NGU for å beholde den viktigste informasjonen om kornstørrelse og bunntype for å minske informasjonstapet.

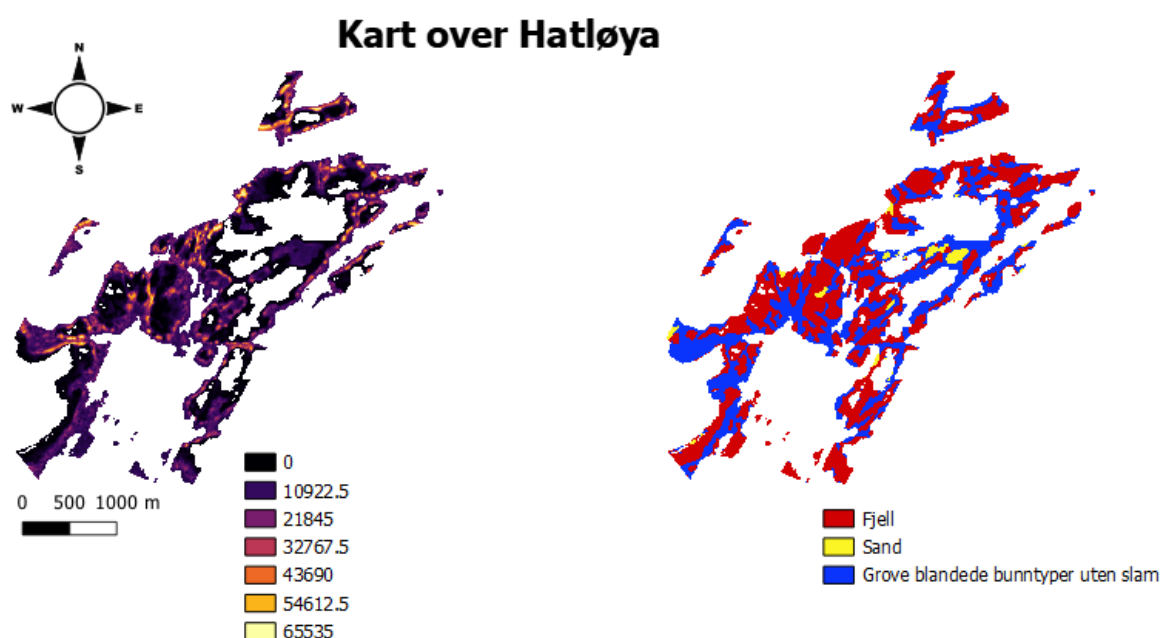
Basert på forbedringen kan man se at antagelsen om at maximum likelihood i PCI Geomatica presterer bedre ved færre klasser stemmer. PCI Geomatica har den største forbedringen etter sammenslåingen. Klassifiseringsmetodene i ArcGIS pro blir også betraktelig bedre etter en sammenslåing av klasser, men i mindre grad enn for PCI Geomatica.

Kapittel 4: Resultater og Diskusjon

I dette kapittelet vil resultatene legges frem. Målet er å oppnå gode klassifiseringsresultater over verifiseringsområdene med de samme klassene som er utarbeidet i samråd med NGU. Resultatene ligger til grunn når problemstillingene blir besvart. Videre vil resultater og metode diskuteres, før blikket rettes fremover for å se hva som kan gjøres videre og for å forbedre resultatene.



4.1 Resultater fra verifiseringsområder

Ved å teste flere ulike datasett og klassifiseringsmetoder ble det vurdert at datasettet mnfn0, altså gjennomsnittlige intensitetsverdier uten vegetasjon og der det er gjennomført en glatting, var det datasettet som egnet seg best. I tillegg ble klassifiseringsteknikkene SVM og maximum likelihood i både ArcGIS pro og PCI Geomatica tatt i bruk da det var disse som viste best resultater fra testene. Intensitetskartene som ble brukt over de ulike verifiseringsområdene og «fasitdata» fra NGU vises i bilde 18-20.






Bilde 18: Kartet til venstre viser intensitetskart over Hatløya. Dette kartet er av typen mnfn0. Til høyre er det et utsnitt av NGUs kornstørrelsekart med sammenslåtte klasser over samme område.

Kart over Nautøya




0 500 1000 m






Bilde 19: Kartet til venstre viser intensitetskart over Nautøya. Dette kartet er av typen mnfno. Til høyre er det et utsnitt av NGUs kornstørrelsekart med sammenslåtte klasser over samme område.

Kart over Nerlandsøya



0 500 1000 m



Bilde 20: Kartet til venstre viser intensitetskart over Nerlandsøya. Dette kartet er av typen mnfno. Til høyre er det et utsnitt av NGUs kornstørrelsekart med sammenslåtte klasser over samme område.

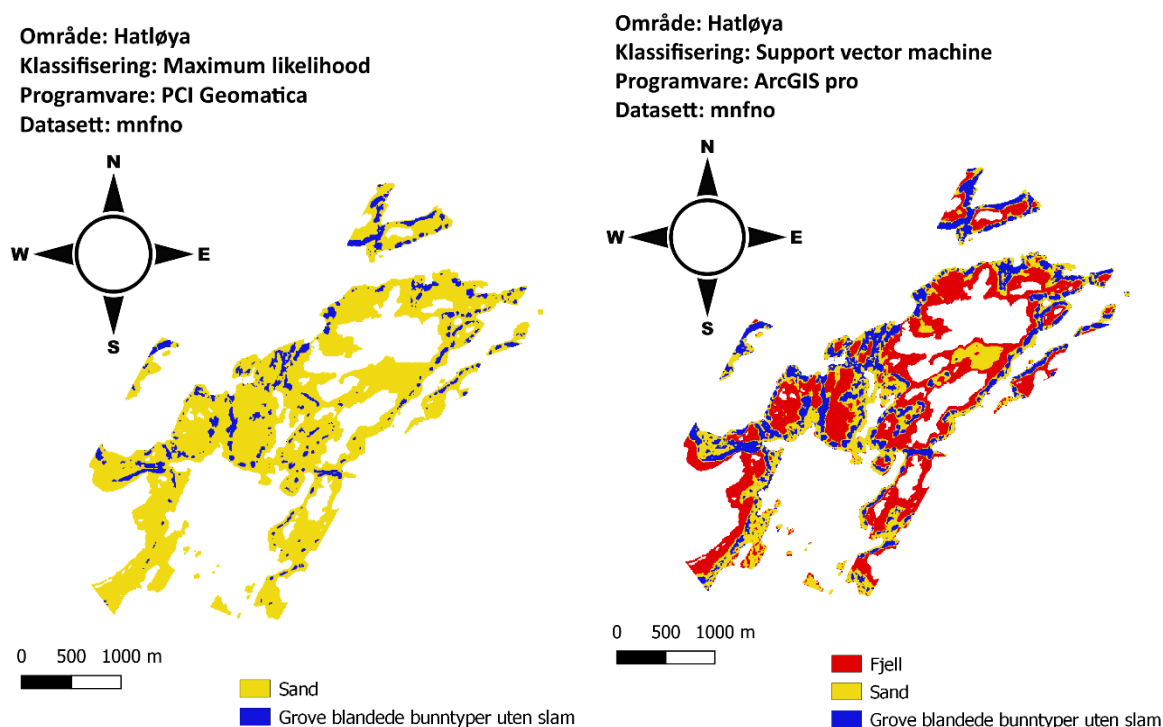
Verifiseringsområdene ble klassifisert ut ifra de fire klassene som står beskrevet i avsnitt 3.2.5. Siden testområdet ikke inneholder klassen «slamholdig dekke», kunne man dessverre ikke bruke ferdig trente modeller fra testområdet. Det ble derfor opprettet nye

treningsområder på verifiseringsområdene for å kunne gjennomføre klassifiseringene. Nøyaktighetene til klassifiseringene over verifiseringsområdene vises i tabell 12.

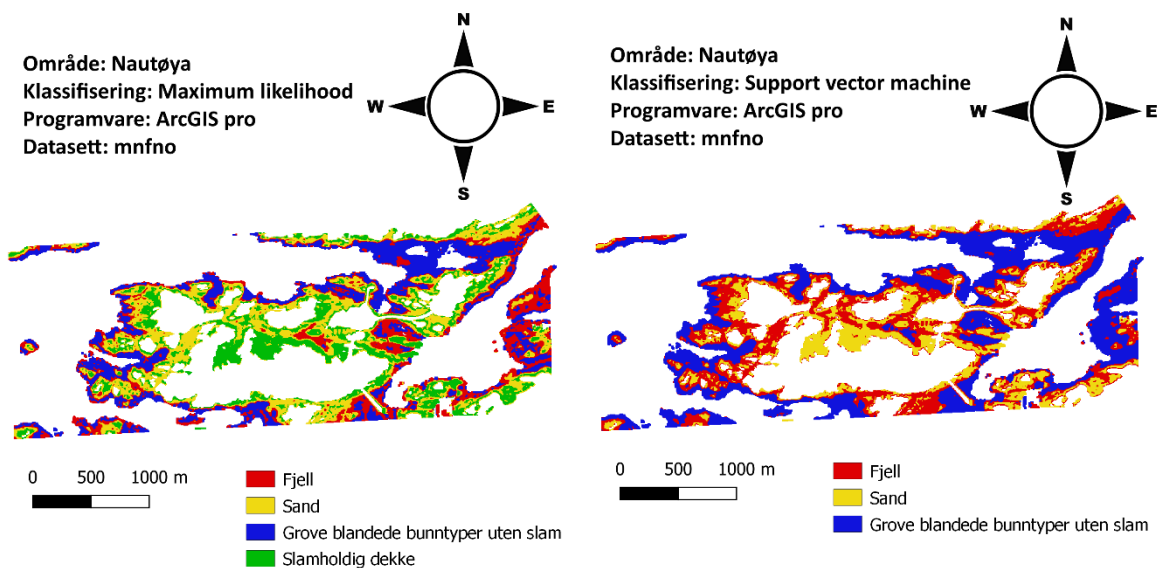
Område	SVM	Maximum likelhood i ArcGIS pro	Maximum likelhood i PCI Geomatica
Hatløya	47.12	41.31	9.68
Nautøya	47.09	27.87	40.96
Nerlandsøya	31.55	37.1	16.75

Tabell 12: Tabellen viser nøyaktighetsresultater av klassifiseringer over verifiseringsområdene. Datasettet som er brukt i klassifiseringen er mnfno.

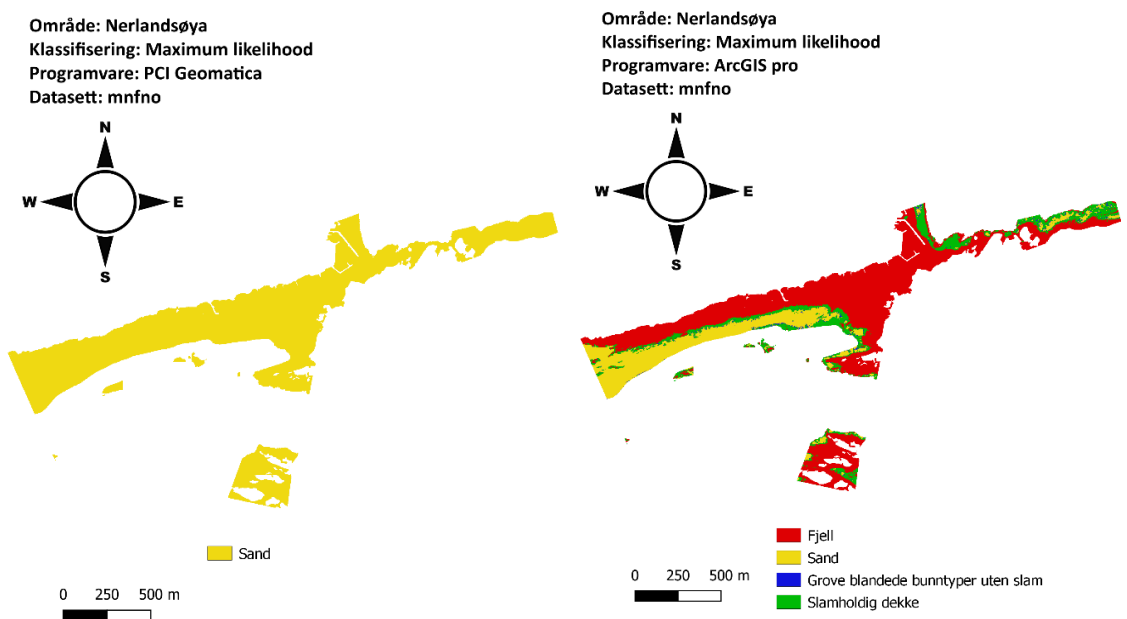
Bilde 21-23 viser noen av resultatene etter klassifiseringene. Bildene viser beste og dårligste klassifisering ifølge nøyaktighetene. I klassifiseringene av testområdet med sammenslåtte klasser var det lite variasjon mellom de ulike klassifiseringsteknikkene. Her kan man se en mye større forskjell, der noen av klassifiseringsteknikkene ikke engang klarer å predikere alle klassene som datasettene inneholder.



Bilde 21: Bildet viser dårligste klassifisering over Hatløya til venstre, og beste til høyre, ifølge nøyaktighetene. Dårligste klassifisering er utført i PCI Geomatica med maximum likelhood og beste er utført i ArcGIS pro med SVM.



Bilde 22: Bildet viser dårligste klassifisering over Nautøya til venstre, og beste til høyre, ifølge nøyaktighetene. Dårligste klassifisering er utført i ArcGIS pro med maximum likelihood og beste er utført i ArcGIS pro med SVM.



Bilde 23: Bildet viser dårligste klassifisering over Nerlandsøya til venstre, og beste til høyre, ifølge nøyaktighetene. Dårligste klassifisering er utført i PCI Geomatica med maximum likelihood og beste er utført i ArcGIS pro med maximum likelihood.

De ulike forvirringsmatrisene til verifiseringsområdene vises i figur 22-24. Siden Hatløya, i likhet med Runde ikke har sedimenter med slam i seg, inneholder heller ikke dette datasettet klassen «slamholdig dekke».

		Predikerte data					
		Fjell	Sand	Grove, blandede bunntyper uten slam	Precision	Recall	F1 score
Faktiske data	Fjell	54036	29654	13764	71.91	55.45	62.62
	Sand	774	1984	985	3.41	53.01	6.41
	Grove, blandede bunntyper uten slam	20333	26523	25994	63.80	35.68	45.77
	Datasett: mnfn Område: Hatløya Klassifisering: Support vector machine Programvare: ArcGIS pro						
	Datasett: mnfn Område: Hatløya Klassifisering: Maximum likelihood Programvare: ArcGIS pro						

		Predikerte data					
		Fjell	Sand	Grove, blandede bunntyper uten slam	Precision	Recall	F1 score
Faktiske data	Fjell	0	92159	5295		0.00	
	Sand	0	3084	659	2.00	82.39	3.90
	Grove, blandede bunntyper uten slam	0	59088	13762	69.80	18.89	29.73
	Datasett: mnfn Område: Hatløya Klassifisering: Maximum likelihood Programvare: PCI Geomatica						
	Datasett: mnfn Område: Hatløya Klassifisering: Support vector machine Programvare: ArcGIS pro						

Figur 22: Forvirringsmatriser fra klassifiseringer over området Hatløya.

Nautøya og Nærlandsøya har områder med «slamholdig dekke», og vil derfor klassifiseres med alle de fire ulike klassene.

		Predikerte data						
		Fjell	Sand	Grove, blandede bunntyper uten slam	Slamholdig dekke	Precision	Recall	F1 score
Faktiske data	Fjell	35835	24008	31807	0	80.07	39.10	52.54
	Sand	1060	2491	1344	0	8.34	50.89	14.32
	Grove, blandede bunntyper uten slam	7797	2983	23571	0	41.49	68.62	51.71
	Slamholdig dekke	61	403	91	0		0.00	
	Datasett: mnfn Område: Nautøya Klassifisering: Support vector machine Programvare: ArcGIS pro							

		Predikerte data						
		Fjell	Sand	Grove, blandede bunntyper uten slam	Slamholdig dekke	Precision	Recall	F1 score
Faktiske data	Fjell	19033	31151	17945	23521	66.66	20.77	31.67
	Sand	589	947	881	2478	2.46	19.35	4.37
	Grove, blandede bunntyper uten slam	8890	6326	16250	2885	46.26	47.31	46.78
	Slamholdig dekke	41	59	52	403	1.38	72.61	2.70
	Datasett: mnfn Område: Nautøya Klassifisering: Maximum likelihood Programvare: ArcGIS pro							

		Predikerte data						
		Fjell	Sand	Grove, blandede bunntyper uten slam	Slamholdig dekke	Precision	Recall	F1 score
Faktiske data	Fjell	35404	21121	28671	6454	70.50	38.63	49.91
	Sand	1162	952	1148	1633	3.83	19.45	6.40
	Grove, blandede bunntyper uten slam	13600	2729	17142	880	36.43	49.90	42.12
	Slamholdig dekke	51	66	89	349	3.75	62.88	7.07
	Datasett: mnfn Område: Nautøya Klassifisering: Maximum likelihood Programvare: PCI Geomatica							

Figur 23: Forvirringsmatriser fra klassifiseringer over området Nautøya.

		Predikerte data						
Datasett: mnfno Område: Nerlandsøya Klassifisering: Maximum likelihood Programvare: ArcGIS pro		Fjell	Sand	Grove, blandede bunntyper uten slam	Slamholdig dekke	Precision	Recall	F1 score
Faktiske data	Fjell	178598	13877	1977	40816	43.05	75.91	54.94
	Sand	37682	63274	494	10833	43.66	56.35	49.20
	Grove, blandede bunntyper uten slam	198018	67694	5313	49494	67.86	1.66	3.24
	Slamholdig dekke	576	63	45	1420	1.38	67.49	2.71

		Predikerte data						
Datasett: mnfno Område: Nerlandsøya Klassifisering: Support vector machine Programvare: ArcGIS pro		Fjell	Sand	Grove, blandede bunntyper uten slam	Slamholdig dekke	Precision	Recall	F1 score
Faktiske data	Fjell	14217	47391	104774	68886	41.46	6.04	10.55
	Sand	4810	76339	11150	19984	34.21	67.99	45.51
	Grove, blandede bunntyper uten slam	15228	99427	118850	87014	50.62	37.08	42.81
	Slamholdig dekke	39	9	0	2056	1.16	97.72	2.28

		Predikerte data						
Datasett: mnfno Område: Nerlandsøya Klassifisering: Maximum likelihood Programvare: PCI Geomatica		Fjell	Sand	Grove, blandede bunntyper uten slam	Slamholdig dekke	Precision	Recall	F1 score
Faktiske data	Fjell	0	235268	0	0		0.00	
	Sand	0	112283	0	0	16.75	100.00	28.70
	Grove, blandede bunntyper uten slam	0	320519	0	0		0.00	
	Slamholdig dekke	0	2104	0	0		0.00	

Figur 24: Forvirringsmatriser fra klassifiseringer over området Nerlandsøya.


4.2 Diskusjon av resultater

Som man kan se i tabell 12 gir klassifiseringene over verifiseringsområdene dårligere nøyaktigheter enn over testområdet. Dette på tross av at verifiseringsområdene ikke ble brukt som totalt usette data, men hadde egne treningsområder. Det kommer også tydelig frem av tabellen at PCI Geomaticas maximum likelihood er den klassifiseringsteknikken som er svakest. Den klassifiseringsteknikken som predikerer best er SVM, men også her er nøyaktigheten til klassifiseringene betydelig lavere enn over testområdet. Av verifiseringsområdene er det Nautøya som gir de beste resultatene, dette selv om Nautøya inneholder en klasse mer enn Hatløya.

Ved å se på forvirringsmatrisene, først over området Hatløya i figur 22, ser man tydelig hvorfor PCI Geomatica har så lav nøyaktighet. Klassifiseringsteknikken klarer kun å predikere to klasser, «sand» og «grove, blandede bunntyper uten slam». Denne teknikken har altså ikke predikert et eneste piksel som «fjell». I tillegg kan man se at klassen «sand» har svært lav precision, men høy recall. Dette betyr at veldig mange piksler blir klassifisert som «sand», selv om de ikke er av klassen sand ifølge «fasitdataene» fra NGU. Til gjengjeld klarer klassifiseringen i stor grad å klassifisere det som faktisk er «sand» som «sand», men med en så lav precision kan dette også være ren tilfeldighet. Store mengder av pikslene er predikert som «sand», og da er det bare naturlig at en god del av disse pikslene faktisk tilhører klassen «sand». For klassen «grove, blandede bunntyper uten slam» er det nesten

motsatt. Størsteparten av det som er predikert til å være av denne klassen, er faktisk «grove blandede bunntyper uten slam». På tross av dette er recall veldig lav. Dette betyr at av andelen «grove, blandede bunntyper uten slam» NGU har kartlagt, er det bare en liten del som blir riktig i klassifiseringen. En stor del av det som hører til i klassen predikeres som «sand».

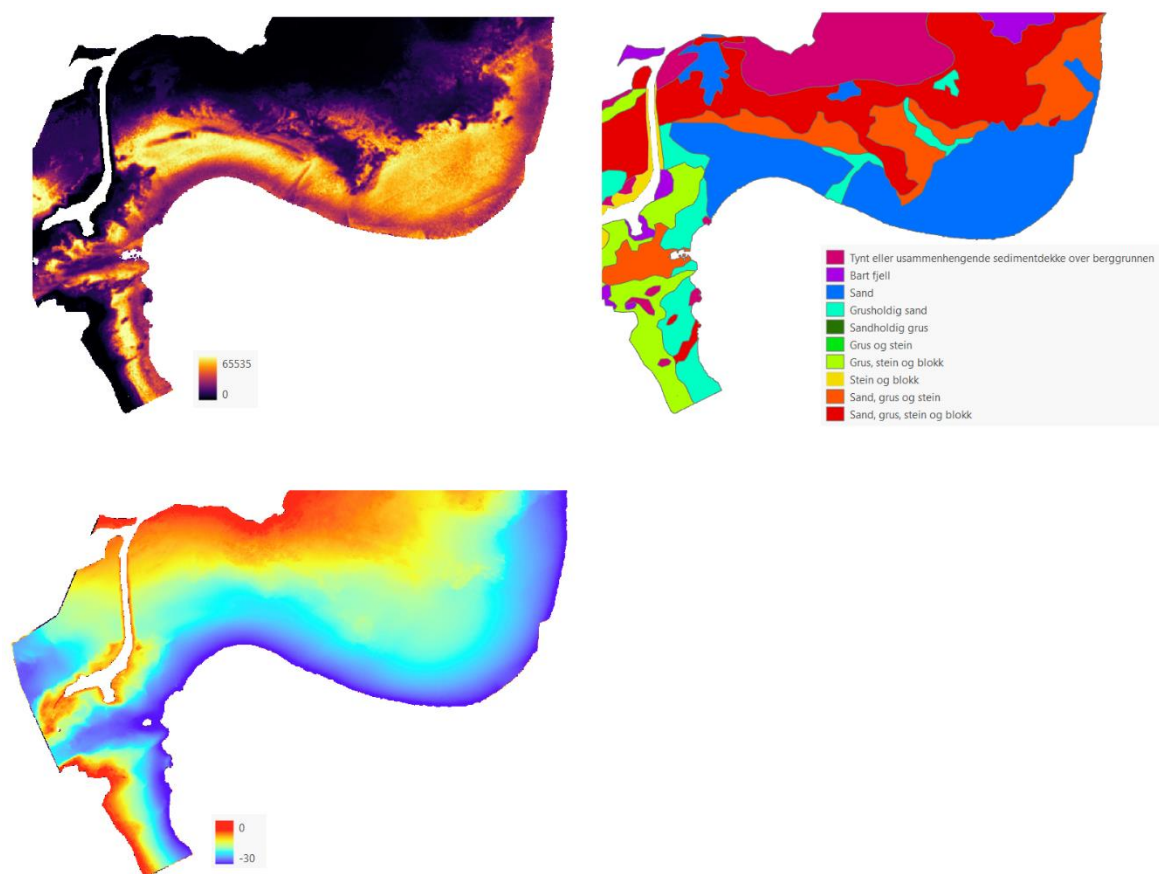
Generelt kan man se på alle forvirringsmatrisene at ingen av dem har en fremtredende diagonal, som er typisk for en klassifisering som predikerer med høy nøyaktighet. Det er tydelig at klassene «fjell» og «grove, blandede bunntyper uten slam» er de klassene med høyest F1 verdi. «Sand» og «slamholdig dekke» er de klassene som har de svakeste resultatene og laveste F1 verdiene. For Nerlandsøya blir alle piksler klassifisert som «sand» i maximum likelihood klassifiseringen fra PCI Geomatica. En mulig forklaring på hvorfor dette området klassifiseres så dårlig er at det er tvetydighet innad i klassene. Som forklart tidligere kan samme sediment ha ulik farge, og dermed gi ulike intensitetsverdier. Dersom dette er tilfellet i flere av klassene kan dette gi problemer under klassifisering.



Figur 25: Stolpediagram som viser fordelingen av klasser over verifiseringsområdet. Fordelingen er vist i antall piksler.

Årsaker for at det er så store forskjeller mellom nøyaktigheten på verifiseringsområdene og testområdet kan være at selv om bunntypene er kategorisert som samme kornstørrelse på de ulike områdene, kan de ha ulik farge og dermed refleksivitet. Datasettene er også svært ubalanserte, altså er det ikke like mye «fjell», «sand», «slamholdig dekke» og «grove, blandede bunntyper uten slam» i datasettene. Som man ser av figur 25 er det en svært skjev

fordeling, der «slamholdig dekke» nesten ikke er representert i forhold til de andre klassene. I tillegg er det også betraktelig mindre andel «sand» enn «fjell» og «grove blandede bunntyper uten slam». Dette kan være med på å forklare hvorfor akkurat disse to klassene er de som blir klassifisert best og med høyest F1 verdi. I tillegg kan fordelingen av klasser være med på å forklare hvorfor verifiseringsområdene predikerer dårligere enn testområdet. For selv om også testområdet hadde noe ubalanse i datasettet, er verifiseringsområdene betydelig mer ubalanserte.



Figur 26: Bildet viser i øvre venstre hjørnet, utsnitt av intensitetskartet over runde. I øvre høyre hjørnet ser man et utsnitt av sedimentdekket over samme område. I nedre venstre hjørne er terrenngmodellen over samme område.

Som man kan se på intensitetskartet i figur 26, ser man et skifte i intensitetsverdi når dybden når et visst punkt. Dette området er mørkere på intensitetskartet og mindre lys er blitt reflektert tilbake til sensoren. Ser man på «fasitdataene» over samme område som også er vist i figur 26, ser man at hoveddelen av sedimenttypen over dette området er «sand» eller «grusholdig sand». Likevel observeres dette fenomenet som at intensitetsverdiene blir svakere i takt med dybden. Ved å gjennomføre en korreksjon av intensitetsverdiene som en


funksjon av dybden, kan man kanskje oppnå bedre resultater. Dette fenomenet kan man også se over andre områder, som for eksempel verifiseringsområdet Nerlandsøya, se bilde 20. Her kan det se ut til at ved dypere vann (den sørlige delen er inne ved land og den nordlige delen heller nedover mot dypere vann) oppstår samme fenomen som blir observert over Runde.

En annen faktor som kan påvirke nøyaktigheten til klassifiseringsteknikkene er at nøyaktigheten til «fasitdataene» er på 10 m. Pikkstørrelsen på dataene i denne oppgaven er på 2.6 m, både for «fasitdata» fra NGU og intensitetskartene. I grensen mellom to sedimenter kan det derfor være tilfeller hvor NGU sine sedimentkart ikke viser riktig sedimentklasse. Det predikerte intensitetskartet kan i disse tilfellene ha predikert riktig klasse ifølge faktiske, fysiske forhold, men feil i forholdt til «fasitdata».

4.3 Diskusjon av metode

Metoden som er beskrevet i kapittel 3.2 har blitt vurdert til å ha sine styrker og svakheter. Et aspekt ved oppgaven som er svært positivt, er at det har blitt testet ut ulike typer programvarer. Klassifiseringene gjøres på ulike måter, og programvarene støtter ulike klassifiseringsmetoder. Det er også generert en mengde ulike intensitetskart med forskjellige egenskaper. Dette for å teste om sjøbunnsvegetasjon, glatting eller intensitetsverdi har en effekt på klassifiseringsnøyaktigheten. Det har med andre ord blitt kjørt svært mange klassifiseringer på en mengde ulike datasett.

Det at datasettene kun inneholder ett attributt å klassifisere etter, er en av svakhetene ved metoden. Dette gjør at man har færre egenskaper å støtte seg på når det skal klassifiseres. For å bygge en god modell, i dette tilfellet en klassifisering, er man avhengig av mye og god data. I denne oppgaven er det kun tatt utgangspunkt i intensitetsverdier fra lidar.



Bilde 24: Intensitetskart over Runde med NGU sine grenser mellom de ulike kornstørrelsene lagt over i grønt.

Som nevnt i 1.1 så Terratec potensiale i klassifisering av sjøbunnen, på bakgrunn av at man lett kan se en korrelasjon mellom «fasitdataene» fra NGU og intensitetsbildene innsamlet av Terratec. I bilde 24 er grensene mellom kornstørrelsene lagt over intensitetskartet, og her trer denne likheten enda tydeligere frem.

Selv om store deler av resultatene denne oppgaven har gitt ikke er spesielt gode, ser man likevel at de klassifiserte bildene inneholder mange av de samme konturene og skillene mellom ulike sedimenter som «fasitdataene». På bakgrunn av dette anses ikke intensitetsverdiene som ubrukelige, selv om man ikke har fått et entydig klassifiseringsresultat. Man kan trolig bruke noe av informasjonen til å forenkle prosessen med å lage marine grunnkart. NGU skrev i sin GLaSS rapport (Dolan et al., 2018) at det var i hovedsak flybilder som ble brukt til å oppdatere de marine grunnkartene, men at det tidvis var problematisk med svake lysforhold eller skygger i bildene. Siden laser er en aktiv sensor, kan man få klare intensitetsbilder selv under dårlige lysforhold, og det kan dermed brukes som en støtte til å se skillene mellom ulike sedimenttyper.

Ruhet og hardhet er i denne oppgaven og i delkapittel 3.2.5 definert ut fra kornstørrelsene de ulike sedimentene har. Ved sammenslåingen av klasser i samråd med NGU ble de klassene

med tilsvarende ruhet og hardhet slått sammen. På bakgrunn av dette er det mulig å si noe om ruhet og hardhet, ut fra resultatene klassifiseringen gir.

Som nevnt tidligere i oppgaven fungerer ikke PCI Geomatica så godt som ønsket når det kommer til å skille mellom de ulike intensitetsverdiene. Grunnen til dette kan være at algoritmene ikke fungerer optimalt på denne typen data, men det kan også være basert på menneskelige feil av brukeren. En utfordring var at man ikke kunne lagre treningsområdene, og bruke de samme på flere datasett. Man var altså nødt til å definere nye treningsområder for hvert datasett. En forståelig menneskelig feil er at det er vanskelig å danne nøyaktig de samme treningsområdene for alle datasettene. Ulike størrelser på treningsområdene fører til forskjellig antall piksler i de ulike datasettene. Dette bidrar til at klassifiseringen blir gjort på nye premisser hver gang et nytt datasett klassifiseres. Det at treningsområdene ikke er entydige for alle klassifiseringer er en mulig årsak til den store forskjellen i nøyaktighet. Dette gjelder også når det kommer til å sammenligne ArcGIS pro og PCI Geomatica, da klassifiseringer gjort i ArcGIS pro ikke har like treningsområder som i PCI Geomatica.

En annen svakhet med PCI Geomatica er at det er få muligheter til å optimalisere klassifiseringene ved å fininnstille parameterne som maximum likelihood klassifiseringen bygger på. ArcGIS pro har derimot flere muligheter til å gjøre endringer i klassifiseringsalgoritmene som ikke er testet ut i denne oppgaven. Gjennom ArcPy som er en Python-pakke kan man endre parameterne i klassifiseringsalgoritmen, og dermed optimalisere algoritmen. I denne oppgaven er klassifiseringene kun trent opp ved å bruke ArcGIS pro sine standardverdier og parametere.

I prosessen der klassifiseringene skal utføres på verifiseringsområdene, oppstår det også noe som vurderes som en svakhet med metoden. Både i PCI Geomatica og i ArcGIS pro må det dannes nye treningsområder for verifiseringsområdene. Som nevnt over kan dette skape utfordringer, og gi varierende resultater for klassifiseringene. I tillegg vil klassifiseringsteknikkene ikke kunne testes på helt usette data. Dette er en stor svakhet i denne metoden da det ikke kan utvikles en modell som kan kjøres automatisk på flere områder i ettertid. Mye av årsaken til at dette ikke er mulig er forskjell i lysheten til sedimentene innenfor en klasse. «Sand» kan være både lys og mørk, og vil dermed gi ulike intensitetsverdier selv om det er samme klasse. Det at man må lage nye treningsområder for

hvert datasett/område gjør at det er vanskelig å skaffe entydige intensitetsverdier til å definere de ulike klassene.

Det ble også dannet svært store treningsområder over testområdet Runde. Bakgrunnen for dette var at det i begynnelsen var tenkt å bruke Runde som et testområde der modellene som ble trent opp over Runde kunne videreføres til verifiseringsområdene og dermed klassifisere verifiseringsområdene usett. Som nevnt ble dette ikke utført på grunn av ulike klasser over de ulike områdene. Ideelt sett skal ikke treningsområdene være på mer enn 10-40% av det totale datasettet, avhengig av størrelsen på datasettet. Over testområdet ble treningsområdene ganske store, men det var ingen effektiv og enkel metode for å sjekke hvor stor andel av det totale datasettet som var dekket av treningsområder.

En styrke ved metoden som har blitt brukt, er at det er benyttet en måte å sammenligne resultater på uavhengig av programvare. PCI Geomatica og ArcGIS pro har ulike metoder på å rapportere resultatene av klassifiseringen. Ved å danne et felles Python-script kan man nå bruke TIF-filer fra begge programvarer og sammenligne disse med «fasitdata» på en entydig måte.

I denne oppgaven ser vi på observert nøyaktighet når modellene skal evalueres. En styrke ved dette er at nøyaktighet er en enkel parameter å beregne og lett å forstå seg på.

Det observert nøyaktighet ikke tar hensyn til, er forholdet mellom observert og tilfeldig nøyaktighet, der tilfeldig nøyaktighet er nøyaktigheten man forventer ved tilfeldig gjetting basert på at man allerede vet klassefordelingen. Bakgrunnen for å bruke observert nøyaktighet som et mål på klassifiseringsnøyaktighet, er at modellene evalueres ut fra de samme datasettene med samme fordeling. Dermed vil den tilfeldige nøyaktigheten være den samme for alle datasett som er over samme område. I tillegg til å evaluere forvirringsmatriser, precision, recall og F1 verdi ble det sett slik at observert nøyaktighet var et godt nok mål for å evaluere de ulike klassifiseringsteknikkene og datasettene.

Som resultatene viser blir ikke klassifiseringen av verifiseringsområdene like gode som på testområdet. Som skrevet og vist i 3.1.5 er testområdet et godt område å teste hypotesen på. Dataene inneholder større entydige områder dekket med samme sediment. Dette gjør det antakeligvis enklere å klassifisere riktig. Verifiseringsområdene derimot inneholder stort sett mindre områder med samme sediment, noe som gjør at treningsområdene også dekker færre

pikslar. I delkapittel 4.1 står det skrevet at klassifiseringsteknikkene ikke kan testes på usette data, og at man derfor må lage nye treningsområder for hvert område. Som nevnt tidligere i oppgaven er dette en svakhet ved metoden. Dette betyr at dersom man ønsker å utnytte informasjonen fra lidar-dataene på en best mulig måte, krever det at man har mer informasjon. Denne tilleggsinformasjonen kan være gode multispektrale bilder, RGB-bilder, god kjennskap til området eller fysiske prøver av sedimenter på sjøbunnen.

Siden datasettene som ble utdelt fra Terratec ikke inneholdt informasjon til dypere enn 30 m, ble det vurdert slik at det ikke skulle påføres noen dybdekorreksjoner. I datasettene som er utdelt er det kun et lite område fra 25 m dyp og utover det ser ut til at dybden utgjør en større effekt på intensitetsverdiene. I tillegg har vi ikke et konkret tall på turbiditeten og det kan være variasjoner i turbiditet både innad i et område, og mellom de ulike test- og verifiseringsområdene.

4.4 Videre arbeid

Metoden som er brukt i denne oppgaven antas å ha forbedringspotensial. Dette er aspekt som kan tas tak i og testes ut for å få et bedre resultat. Det er mulig at man også kan få mer informasjon ut fra intensitetsverdiene.

Som nevnt i avsnitt 4.2 Diskusjon av resultater, ser det ut til at intensitetsverdiene avhenger av dybden, og at ved dypere vann blir intensiteten svakere. I denne oppgaven er det ikke gjennomført noen korreksjon av intensitetsverdier med hensyn til dybden. Dette kan være interessant å se på videre, for å se om en dybdekorrigering av intensitetsverdiene vil gi et bedre resultat.

Som skrevet tidligere i oppgaven anser vi klassifisering med kun intensitetsverdier som en svak metode. Mer informasjon kan gjøre at man klarer å klassifisere bedre uten å måtte ta fysiske prøver av sjøbunnen. I innsamlingen av dataene ble det også tatt multispektrale bilder. Disse ble dessverre tatt under for svake lysforhold og ansett for å være av for dårlige til å kunne brukes i denne oppgaven som støtte. Hadde derimot disse bildene vært gode ville det muligens gitt mye god informasjon man kunne brukt som tilleggsinformasjon om området. I sensorsystemet til CZMIL kan man også velge å inkludere et medium format RGB kamera.

Ved å analysere bildene fra kamera kan man trekke ut informasjon man ikke får ut fra intensitetsverdiene. Vanlige RGB-kamera er derimot veldig avhengig av gode lysforhold. Dette betyr at dersom det skal være mulig å trekke ut informasjon må forholdene ligge til rette for det.

Det ble nevnt i 4.3 at det er mulig å endre algoritmen i ArcGIS pro for å optimalisere klassifiseringen. I denne oppgaven ble det brukt standard verdier og parametre for å klassifisere. En mulighet er å optimalisere denne algoritmen og kjøre nye klassifiseringer. En annen metode er å bruke andre klassifiseringsteknikker, som klyngeanalyse eller segmentering.

I denne oppgaven er det i hovedsak brukt algoritmer som ikke legger like stor vekt på pikslens plassering. En mulighet er å bruke algoritmer som legger større vekt på dette, da det er naturlig å anta at en piksel som ligger i nærheten av et annet piksel tilhører samme sedimentklasse. En klyngeanalyse, segmentering eller kantdeteksjon kan være operasjoner som kan forbedre klassifiseringene. Ved å bruke slike algoritmer kan man også klassifisere selve punktskyen generert fra lidar dataene.

Kapittel 5: Konklusjon

I dette kapitlet skal problemstillingene besvares. Problemstillingene er presentert i delkapittel 1.2, der det ble stilt følgende hovedproblemstilling:

- Kan man ut ifra intensitetsverdier klassifisere sedimenter i kystsonen?

I tillegg ble det også stilt to sekundærproblemstillinger:

- Kan man bruke intensitetsverdier som støtte i klassifisering?
- Er det mulig å si noe om ruhet og hardhet på bunnsedimentene ut fra intensitetsverdiene?

Resultatene denne oppgaven gir viser at bruk av intensitetsverdier alene ikke er en god metode for å klassifisere sjøbunnen. En av grunnene er at samme sediment har ulike intensitetsverdi på ulike områder. Med dette menes at «sand» kan være lys i fargen eller mørkere i fargen, og dermed ikke gi entydig intensitetsverdi på grunn av sjøbunnens refleksivitet. I tillegg har de forskjellige områdene ulikt antall klasser og sedimenttyper. Dette fører til at man ikke kan utføre klassifiseringer på usette data. På datasettnivå ser man en ujevn klassefordeling, som kan være en av grunnene til svake klassifiseringsresultater. Disse utfordringene gjør at det kreves annen og mer informasjon om områdene for å klassifisere. Denne informasjonen kan for eksempel være hyperspektrale bilder.

Selv om intensitetsverdier alene ikke kan brukes til en fullverdig klassifisering, er det tydelig at de kan være til god støtte. Som bilde 26 viser ser man at tydelige skifter i intensitetsverdi korrelerer med avgrensningene til kornstørrelsene. Dette kan bidra til å lettere vite hvor det må tas fysiske prøver av sjøbunnen, eller hvor det er et skifte mellom sedimenttyper.

Ruhet og hardhet sier noe om overflatestrukturen til bunnsedimentene, og er sterkt knyttet opp mot kornstørrelsen. Under sammenslåingen av klasser var dette en av nøkkelfaktorene for å bestemme den nye klasseinndelingen. Resultatene etter sammenslåingen viser at man til dels kan si noe om ruhet og hardhet. På testområdet predikeres det med en nøyaktighet på nærmere 70%. Basert på at det kun er predikert tre ulike klasser, kan man ikke med sikkerhet

si at dette er et godt resultat. I tillegg har verifiseringsområdene en mye lavere nøyaktighet, og det er derfor ikke mulig å bekrefte at man kan skille de ulike kornstørrelsene fra hverandre. Det er en utfordring å si noe sikkert om ruhet og hardhet ut fra intensitetsverdier alene.

Gjennom arbeidet med analyser av de innsamlede dataene i de valgte programvarene, ser vi at vi har funnet ut en del som kan være interessant for Terratec, NGU og Kartverket. Vi har ikke kommet frem til et verktøy som kan gi sikker informasjon, men vi ser at intensitetsverdiene kan være et godt supplement i detekteringen av sjøbunnen. Kanskje kan man, ved å gå videre inn i arbeidet vi har påbegynt, ende opp med å finne gode, nye metoder og verktøy til å bestemme hva som finnes på havbunnen i kystnære områder. Vi tror at det å bruke allerede eksisterende kunnskap og data på nye måter kan være spennende for å få ny informasjon, og for å utvikle gode løsninger for databehandling. Vi synes dette er et spennende fagfelt, der mer forskning trengs for å finne gode løsninger.

Referanser

- ArcGIS pro. (2020). *About ArcGIS pro*. pro.arcgis.com. Tilgjengelig fra:
<https://pro.arcgis.com/en/pro-app/get-started/get-started.htm> (lest 19.02).
- ASPRS. (2019). *Laser (LAS) file format exchange activities*. Tilgjengelig fra:
<https://www.asprs.org/divisions-committees/lidar-division/laser-las-file-format-exchange-activities> (lest 22.01).
- Brennan, R. & Webster, T. L. (2006). *Object-oriented land cover classification of lidar-derived surfaces* 02.06.14 utg. Taylor & Francis Online. Tilgjengelig fra:
<https://www.tandfonline.com/doi/abs/10.5589/m06-015> (lest 15.01).
- Browniee, J. (2014). *A Gentle Introduction to Scikit-learn: A Python Machine Learning Library* Machine Learning Mastery. Tilgjengelig fra:
<https://machinelearningmastery.com/a-gentle-introduction-to-scikit-learn-a-python-machine-learning-library/> (lest 25.02).
- Chen, C., Liaw, A. & Breiman, L. (2004). *Using Random Forest to Learn Imbalanced Data*. Tilgjengelig fra: <https://statistics.berkeley.edu/sites/default/files/tech-reports/666.pdf> (lest 24.04.20).
- Dick, Ø. B. (2009). *spektral klassifisering*. Store norske leksikon. Tilgjengelig fra:
https://snl.no/spektral_klassifisering (lest 21.04).
- Dolan, M. F. J., Bellec, V. K., Elvenes, S. & Lepland, A. (2018). Interpretation of green laser and aerial photograph data for seabed sediment mapping in shallow areas, Søre Sunnmøre.
- Downey, R. (2020). (27.03).
- Elvenes, S. (2020). (01.04).
- Environmental Protection Agency. (2013). *Standard Operating Procedure for Zooplanktion Sample Collection and Preservation and Secchi Depth Measurement Field Procedures*. Tilgjengelig fra: <https://www.epa.gov/sites/production/files/2017-01/documents/sop-for-zooplankton-sample-collection-preservation-and-secchi-depth-measurement-field-procedures-201303-7pp.pdf> (lest 25.02).
- ESRI. (1998). ESRI Shapefile technical description.
- ESRI. (u.å-a). *How Focal Statistics works*. Tilgjengelig fra: <https://pro.arcgis.com/en/pro-app/tool-reference/spatial-analyst/how-focal-statistics-works.htm> (lest 23.03).

- ESRI. (u.å-b). *How Maximum Likelihood Classification works*. Tilgjengelig fra:
<https://pro.arcgis.com/en/pro-app/tool-reference/spatial-analyst/how-maximum-likelihood-classification-works.htm> (lest 06.04).
- Feygels, V., Ramnath, V., Smith, B. & Kopilevich, Y. (2016). Meeting the International Hydrographic Organization Requirements for Bottom Feature Detection Using the Coastal Zone Mapping and Imaging Lidar (CZMIL). 6. doi:
10.1109/OCEANS.2016.7761295.
- Feygels, V., Ramnath, V., Marthouse, R., Aikten, J., Smith, B., Clark, N., Renz, E., Duong, H., Kopilevich, Y., Wozencraft, J., et al. (2017a). CZMIL as a Rapid Environmental Disaster Response Tool.
- Feygels, V., Ramnath, V., Marthouse, R., Aitken, J., Smith, B., Clark, N., Renz, E., Duong, H., Wozencraft, J., Reisser, J., et al. (2017b). CZMIL as a rapid environmental disaster response tool. doi: 10.1109/OCEANSE.2017.8084942.
- Ghamisi, P., Benediktsson, J. A. & Phinn, S. (2015). Land-cover classification using both hyperspectral and LiDAR data.
- Graham, S. (1999). *Remote sensing*. Earth observatory. Tilgjengelig fra:
<https://earthobservatory.nasa.gov/features/RemoteSensing> (lest 09.01).
- Grimenes, A. A., Jerstad, P. & Sletbak, B. (2011). Grunnleggende fysikk for universitet og høyskole. I, s. 726-737: Cappelen Damm AS.
- Grobbelaar, J. U. (2009). *Turbidity*. Encyclopedia of Inland Waters: Elsevier Inc.
Tilgjengelig fra:
<https://www.sciencedirect.com/science/article/pii/B9780123706263000752> (lest 08.01).
- Holtebekk, T. (2019). *Infrarød stråling*. Store norske leksikon. Tilgjengelig fra:
https://snl.no/infrar%C3%B8d_str%C3%A5ling (lest 26.03).
- Holtebekk, T. & Ringvold, A. (2019). *Laser*. Store norske leksikon. Tilgjengelig fra:
<https://snl.no/laser> (lest 14.01).
- Horning, N. (2008). *What is remote sensing?* Encyclopedia of Ecology. Tilgjengelig fra:
<https://www.sciencedirect.com/science/article/pii/B9780080454054002378> (lest 14.08).
- Kartverket. (2016). *Satsningar på Søre Sunnmøre*. Kartverket.no. Tilgjengelig fra:
<https://www.kartverket.no/Prosjekter/sore-sunnmore/> (lest 27.01).

- Koehrsen, W. (2017). *Random Forest Simple Explanation*. Tilgjengelig fra: <https://medium.com/@williamkoehrsen/random-forest-simple-explanation-377895a60d2d> (lest 26.04).
- Larsen, B. (2019). *Kartutsnitt områder Terratec AS* (03.12).
- Larsen, B. (2020). *Informasjon om datasettene fra CZMIL* (18.03.20).
- Larsen, B. & Solli, P. (2020). (13.01).
- learnpython. (u.å). *Pandas Basics*. Tilgjengelig fra: https://www.learnpython.org/en/Pandas_Basics (lest 26.03).
- Lundh, F. & Clark, A. (2020). *Image Module: Pillow*. Tilgjengelig fra: <https://pillow.readthedocs.io/en/stable/reference/Image.html> (lest 25.02).
- Mai, T. (2017). *What are passive and active sensors?* Tilgjengelig fra: https://www.nasa.gov/directorates/heo/scan/communications/outreach/funfacts/txt_passive_active.html (lest 14.01).
- Manifold. (2020). *LAS, LAZ lidar*. Tilgjengelig fra: http://www.manifold.net/doc/mfd9/las_laz_lidar.htm (lest 22.01).
- Mæhlum, L. (2009). *Avstandsmåling*. 8 utg. Store Norske Leksikon: Knut Hofstad. Tilgjengelig fra: <https://snl.no/avstandsmåling> (lest 28.04).
- NASA. (2013). *The electromagnetic spectrum*. Tilgjengelig fra: <https://imagine.gsfc.nasa.gov/science/toolbox/emspectrum1.html> (lest 08.01).
- NASA Earthdata. (2019). *GeoTIFF*. NASA Earthdata: EOSDIS. Tilgjengelig fra: <https://earthdata.nasa.gov/esdis/eso/standards-and-references/geotiff>.
- Norges Geologiske Undersøkelse. (2019a). *Presentasjonsregler: Bunnsedimenter (kornstørrelse), detaljert*. Norges geologiske undersøkelse.
- Norges Geologiske Undersøkelse. (2019b). *PRODUKTARK: BUNNSEDIMENTER (KORNSTØRRELSE), DETALJERT - M 1 : 25 000*. Norges geologiske undersøkelse.
- NumPy. (2020). *NumPy*. Tilgjengelig fra: <https://numpy.org/> (lest 25.02).
- O'Neill, B. (2006). *Elementary Differential Geometry*: Elsevier Inc. Tilgjengelig fra: https://www.sciencedirect.com/book/9780120887354/elementary-differential-geometry?fbclid=IwAR3_Uzt9Mf7ec1TYvOX454OuNEVPd42YukRDDwotUDwZMsCYiWODfCfjxk#book-description (lest 24.02).
- O'Neil-Dunne, J. (2011). Quick Terrain (QT) Modeler - A Software Review. *LiDAR Magazine*, 1.
- PCI Geomatics Enterprises Inc. (2018). *Geomatica Training Guide 1*.

- Python. (2020). *General Python FAQ*. Tilgjengelig fra:
<https://docs.python.org/3/faq/general.html#what-is-python> (lest 25.02).
- Raschka, S. & Mirjalili, V. (2017a). Combining multiple decision trees via random forests. I: *Python machine learning*, s. 98-100. Livery Place
 35 Livery Street
 Birmingham B3 2PB, UK: Packt Publishing.
- Raschka, S. & Mirjalili, V. (2017b). Decision tree learning. I: *Python machine learning*, s. 88-91. Livery Place
 35 Livery Street
 Birmingham B3 2PB, UK.: Packt Publishing.
- Raschka, S. & Mirjalili, V. (2017c). Looking at different performance evaluation metrics. I: *Python machine learning*, s. 205-209. Livery Place
 35 Livery Street
 Birmingham B3 2PB, UK: Packt Publishing.
- Raschka, S. & Mirjalili, V. (2017d). Maximum margin classification with support vector machines. I: *Python machine learning*, s. 76-78. Livery Place
 35 Livery Street
 Birmingham B3 2PB, UK: Packt Publishing Ltd.
- Raschka, S. & Mirjalili, V. (2017e). Optimizing the precision and recall of a classification model. I: *Python Machine Learning*, s. 207-208. Livery Place 35 Livery Street
 Birmingham B3 2PB, UK: Packt Publishing.
- s.n. (2018). Optech CZMIL Nova. (lest 27.01.20).
- s.n. (2020). *intensitet - fysikk*. Store norske leksikon. Tilgjengelig fra:
https://snl.no/intensitet_-_fysikk (lest 23.04).
- Sandstad, J. (2018). *Elektromagnetisk stråling*. Store norske leksikon. Tilgjengelig fra:
https://snl.no/elektromagnetisk_str%C3%A5ling (lest 08.01.20).
- scikit-learn developers. (2007). *sklearn.metrics.accuracy_score*. Tilgjengelig fra:
https://scikit-learn.org/stable/modules/generated/sklearn.metrics.accuracy_score.html
 (lest 26.03).
- SEOS. (u.å.-a). *The Maximum Likelihood Classifier*. Tilgjengelig fra: https://seos-project.eu/classification/classification-c05-p01.html?fbclid=IwAR3f6hdHRS_rPCJderyuc1CG9_1JbIxS4HDDkJ7_nY3VLdoic52Dhl-Z8fs (lest 24.02).

- SEOS. (u.å.-b). *The Minimum Distance Classifier*. Tilgjengelig fra: <https://seos-project.eu/classification/classification-c04-p01.html?fbclid=IwAR1fwgWlf1Wakh8H0IpkUi0TccXraFyMnLUUI4EeE9LqZ8SbZZojeUt473w> (lest 24.02).
- Shafranovich, Y. (2005). *Common Format and MIME Type for Comma-Separated Values (CSV) Files*. Tilgjengelig fra: <https://www.hjp.at/doc/rfc/rfc4180.html> (lest 28.04).
- Shung, K. P. (2018). *Accuracy, precision, recall or F1? Towards data science*. Tilgjengelig fra: <https://towardsdatascience.com/accuracy-precision-recall-or-f1-331fb37c5cb9> (lest 19.04).
- Skaar, J. (2018). *Refraksjon - fysikk*. Store norske leksikon. Tilgjengelig fra: https://snl.no/refraksjon_-_fysikk (lest 08.01).
- Språkrådet. (2020a). *Bokmålsordboka / Nynorskordboka*. Hardhet: Språkrådet Universitetet i Bergen. Tilgjengelig fra: https://ordbok.uib.no/perl/ordbok.cgi?OPP=hardhet&ant_bokmaal=5&ant_nynorsk=5&begge=+&ordbok=begge (lest 23.04).
- Språkrådet. (2020b). *Bokmålsordboka / Nynorskordboka*. Ru: Språkrådet Universitetet i Bergen. Tilgjengelig fra: https://ordbok.uib.no/perl/ordbok.cgi?OPP=+ru&ant_bokmaal=5&ant_nynorsk=5&begge=+&ordbok=begge (lest 23.04).

Vedlegg

```
# -*- coding: utf-8 -*-
"""
Created on Sat Mar 14 13:37:56 2020
@author: Oda_Mee
"""
#-----
# Importing modules
#-----

from PIL import
Image import
numpy as np
import pandas as
pd
from sklearn.metrics import
confusion_matrix from sklearn.metrics
import accuracy_score

#-----
# Functions
#-----
def open_image_to_array(filename):
    """Function that opens a picture file and stores it as an array"""
    image = Image.open(filename)
    imarray = np.array(image).reshape(-1)
    return imarray

def clean_array(array1, NoDataValue):
    """Function that removes noe data values from an image array"""
    cln_array = array1[array1!=NoDataValue]
    return cln_array

def replace_values(array1, replacedict):
    """Function that replaces values in an image array with another value"""
    rep_array = np.asarray([replacedict[num] for num in array1])
    return rep_array

def confusionmatrix_dataframe(array1, fasitdata_array):
    """Function that computes a confusion matrix as an pandas dataframe"""
    df_cm = pd.DataFrame(confusion_matrix(fasitdata_array, array1))
    return df_cm

def save_dataframe(df, filename):
    """Function that saves a pandas dataframe as an csv file"""
    df.to_csv(filename)

#-----
# Opening images to array
#-----

path_1 = 'path_to_folder_with_tif_files'
classified_raster = open_image_to_array(path_1+'filename.tif')
kornstr_raster = open_image_to_array(path_1+'filename.tif')
```

```

#-----
# Removing NoDataValue
#-----

classified_raster = clean_array(classified_raster,no_data_value)
kornstr_raster = clean_array(kornstr_raster,no_data_value)

#-----
# Print unique values
#-----

print('Unique values in classified_raster:', np.unique(classified_raster))
print('Unique values in kornstr_raster:', np.unique(kornstr_raster))

#-----
# Replacing values
#-----

replace_dict = {} # Dictionary with values to replace as key, and new values as values
classified_raster = replace_values(classified_raster,replace_dict)
kornstr_raster = replace_values(kornstr_raster,replace_dict)

#-----
# Making a dataframe confusion matrix
#-----

df_confusion_matrix = confusionmatrix_dataframe(classified_raster,kornstr_raster)

#-----
# Saving confusion matrix to a csv file
#-----

path_2 = "Path to folder you want to save the results"
save_dataframe(df_confusion_matrix,path_2+'filename.csv')

#-----
# Computing accuracy
#-----

accuracy = accuracy_score(kornstr_raster, classified_raster)

#-----
# Createing an accuracy dataframe
#-----

Datasett = ['list of dataset, or datasets']
Accuracy = [accuracy]
df_accuracy = pd.DataFrame(list(zip(Datasett, Accuracy)),
                           columns=['Datasett', 'Noyaktighet'])

#-----
# Saving an accuracy dataframe to a csv file
#-----

save_dataframe(df_accuracy,path:2+'filename.csv')

```




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

Postboks 5003
NO-1432 Ås
Norway