

Folkestad, Frida Polden
Svee, Marte

Kartgrunnlag til autonom dronesverm

Effektivisering av rekognosering ved hjelp av
GeoAI og geografiske analyser.

Bacheloroppgave i Geomatikk
Veileder: Ødegård, Rune Strand & Bjerke, Halvard
Medveileder: Jørgensen, Eina Bergem

Mai 2024



Dronesverm styrt fra stormpanservogn CV90. Foto: Krister Sørbø, Forsvarets forum.

Folkestad, Frida Polden
Svee, Marte

Kartgrunnlag til autonom dronesverm

Effektivisering av rekognosering ved hjelp av
GeoAI og geografiske analyser.

Bacheloroppgave i Geomatikk
Veileder: Ødegård, Rune Strand & Bjerke, Halvard
Medveileder: Jørgensen, Eina Bergem
Mai 2024

Norges teknisk-naturvitenskapelige universitet
Fakultet for ingeniørvitenskap
Institutt for vareproduksjon og byggingsteknikk



NTNU

Kunnskap for en bedre verden

Oppgavens tittel:	Dato: 20.05.2024		
Kartgrunnlag til autonom dronesverm: Effektivisering av rekognosering ved hjelp av GeoAI og geografiske analyser.	Antall sider: 87		
	Masteroppgave:	Bacheloroppgave	x
Navn: Frida Folkestad & Marte Svee			
Veileder: Ødegård, Rune Strand – Veileder NTNU Bjerke, Halvard – Veileder Krigsskolen			
Eksterne faglige kontakter/ veiledere: Jørgensen, Eina Bergem – Ekstern veileder FFI			

Den teknologiske utviklingen har gitt for Forsvaret nye muligheter innen blant annet etterretning, overvåking, rekognosering og autonome systemer. Geografiske analyser kan brukes til å identifisere sammenhenger, analysere satellittbilder eller predikere hendelser. GeoAI kombinerer geografiske informasjonssystemer med kunstig intelligens, og muliggjør effektiv innsamling og analyse av data. Ved å kombinere geografiske analyser og GeoAI med etterretning, overvåking, rekognosering og autonome systemer kan det bidra til å effektivisere prosesser, skape situasjonsforståelse og gi beslutningsstøtte.

For å gjøre Forsvaret i bedre stand til å utnytte kunstig intelligens, startet Forsvarets Forskningsinstitutt (FFI) en satsning på autonomi i 2014. En del av denne satsningen er det autonome dronesvermprosjektet *Valkyrie*, hvor målet var å utvikle en sverm av droner som kan handle selvstendig basert på gitte oppdrag. Dronesvermen skal kunne forstå omgivelsene sine, unngå hindringer og ta beslutninger på egenhånd. *Valkyries* kartgrunnlag skiller kun mellom åpne og ikke-åpne områder, og kan derfor ikke skille mellom for eksempel vann og vei. Det vil derfor være av interesse å bestemme hvilke områder dronene skal prioritere å søke i. Med denne utfordringen som utgangspunkt, har oppgaven undersøkt følgende problemstilling:

Hvordan kan GeoAI og geografiske analyser bidra til å effektivisere rekognosering med dronesverm?

Denne oppgaven har utviklet en arbeidsflyt for å automatisere generering av arealdekkkart og utviklet situasjonsbilder for å øke situasjonsforståelse i ulike militære operasjoner. Oppgaven utviklet to dyplæringsmodeller til å segmentere multispektrale Sentinel-2 satellittbilder for henholdsvis områdene Rena i Norge, og Tokmak i Ukraina. Dette resulterte i to oppdaterte arealdekkkart som gjorde det mulig å prioritere relevante arealtyper for rekognosering med drone. Arealdekkkartene ble deretter brukt i geografiske analyser sammen med etterretninger. Resultatene fra analysene viser hvordan en kan effektivisere rekognosering med dronesvermer i tre ulike egenutviklede scenarier. Analysene bidro til å betydelig innsnevre søksområdene. Denne arbeidsflyten er globalt anvendbar, og kan tilpasses etter behov.

Stikkord:

GeoAI
Arealdekkkart
Dronesverm
Geografiske analyser
Maskinlæring

Frida Folkestad

Marte Svee

Forord

Denne bacheloroppgaven er et resultat av åtte ukers arbeid høsten 2023, og har hatt et omfang på 20 studiepoeng. Oppgaven representerer avslutningen av et todelt studieløp: Bachelor i Ingeniørfag Geomatikk ved NTNU, og Militære studier med fordypning i ledelse og militær geomatikk ved Krigsskolen.

Motivasjonen bak tematikken for oppgaven var å utforske hvordan maskinlæring og geografiske analyser kunne kombineres for å skape bedre oppdrags- og beslutningsstøtte i militære operasjoner. Etter utbruddet av krigen i Ukraina har det vært et stort fokus på droner, og hvordan droner kan utnytte ny teknologi. Ideen om å undersøke hvordan militær geomatikk kunne kombineres med en autonom dronesverm kom med innspill fra Hærens Manøverskole, og dronesvermprosjektet *Valkyrie* ved Forsvarets Forskningsinstitutt (FFI).

Vi ønsker å rette en spesiell takk til forsker, Eina Bergem Jørgensen, ved FFI for teknisk og faglig veiledning innen maskinlæring. Maskinlæring blir kun kort introdusert under utdannelsen på Krigsskolen, og denne veiledningen har derfor vært avgjørende for resultatene i oppgaven. Vi vil også takke prosjektgruppen *Valkyrie* for faglig innsikt i prosjektet, og for gjennomføring av test i simulator.

Til slutt vil vi gi en stor takk til våre hovedveiledere: førsteamanuensis ved NTNU Rune Strand Ødegård og MilGeo-instruktør ved Krigsskolen Halvard Bjerke. Dere har begge gitt gode og konstruktive tilbakemeldinger som har vært veldig viktig for oppgaven.

Abstract

Advancements within technology has led to new possibilities within intelligence, surveillance, and autonomous systems. Geographical analyses can be used to identify relationships, analyze satellite images, or predict events. GeoAI combines the use of geographical information systems and artificial intelligence and enables rapid collection and analysis of large amounts of data. Geographical analyses and GeoAI can contribute to effective processes and enhance decision-makers situational awareness.

To enhance the Norwegian military's ability to utilize artificial intelligence, the Norwegian Defence Research Establishment (FFI) initiated a focus on autonomy in 2014. A key part of this initiative was the project *Valkyrie*, aimed at developing autonomous drone swarms. *Valkyrie's* objective is to develop drones that can understand their environment, avoid obstacles, and make decisions autonomously, based on a specific task. Currently, *Valkyrie's* navigation is based only on distinguishing between open and non-open areas. Therefore, the drones lack the ability to identify different types of land cover, such as water and roads. This has led to the following research question:

How can GeoAI and geographical analyses enhance the efficiency of reconnaissance with drone swarms?

This thesis presents a globally applicable workflow to automate the creation of land cover and situational maps for various military operations. The process entailed training two deep learning models to analyze multi-spectral Sentinel-2 satellite images from Rena in Norway, and Tokmak in Ukraine. This resulted in two land cover maps with updated topographic information, that facilitated the prioritization of relevant land covers for drone reconnaissance. Furthermore, these land cover maps were used in geographical analyses along with intelligence, to demonstrate how these analyses could enhance reconnaissance efficiency in three different self-developed scenarios. The results from these analyses indicate significantly narrowed and prioritized search areas. This workflow is globally applicable, and highly adaptable to various operations.

Sentrale begreper

Autonomi	Maskiner eller systemer som er i stand til å ta selvstendige beslutninger og operere selvstendig.
Beslutningsstøtte	Produkter, analyser og vurderingen som bidrar til å gi et bedre beslutningsgrunnlag (Grinderud et al., 2016, s.209).
Digital overflatemodell (DOM)	En modell av jordens overflate som inkluderer vegetasjon og menneskeskapte objekter som bygninger (Grinderud et al., 2016, s.155).
Digital terrengmodell (DTM)	En modell av jordens overflate som beskriver høyde- og terrenginformasjon (Grinderud et al., 2016, s.155).
Dronesverm	Flere droner som kommuniserer, koordinerer, og opererer sammen for å løse oppgaver.
Dyplæring	En type maskinlæring som lærer maskiner til å utføre komplekse oppgaver (Tidemann & Elster, 2023).
Esri LU/LC	Esri Land Use/ Land Cover er et globalt datasett over arealdekke produsert av Esri. Datasettet produseres årlig ved hjelp av dyplæring på Sentinel-2 satellittbilder (Esri, 2022).
Etterretning	Innhenting, analyse og vurdering av data og informasjon for å gi fortrinn i beslutningsprosesser (Forsvaret, 2021, s.100).
Felles kartdatabase (FKB)	Digital samling av detaljerte nasjonale data som kan brukes fra alt fra detaljplanlegging til å lage turkart (Håndbok for Geovekst-samarbeidet, 2023).
Fortifikasjon	En befestning, et militært anlegg bygget for å gjøre det enklere å forsvare et område eller gjøre det vanskeligere å angripe.
GeoAI	Bruken av kunstig intelligens kombinert med geografiske data, vitenskap og teknologi for å effektivisere virkelighetsforståelse (<i>What Is GeoAI?</i> , u.å.)
Oppdragsstøtte	Produkter, analyser og vurderingen som bidrar til gjennomføring av militære oppdrag (Grinderud et al., 2016)
Overvåking	Systematisk observasjon for å hente inn data og informasjon innenfor et bestemt område (Forsvaret, 2021, s.104).
Rasterdata	Geografiske data lagret som piksler i et rutenett, hvor hver piksel inneholder en verdi som representerer informasjon (Zeiler, 2010, s. 186-198).
Rekognosering	Å fremskaffe data eller informasjon om en aktør, aktiviteter eller fysiske karakteristikk i et definert område (Forsvaret, 2021, s.105).
Semantisk segmentering	Tilegne hver piksel i et bilde til en klasse.
Situasjonsbilde	Forenklet visuell fremstilling av en situasjonsforståelse.
Situasjonsforståelse	Etterretninger, informasjon om aktører, operasjonsområdet, egne styrker og annen relevant informasjon (Forsvaret, 2019, s.218)
Vektordata	Geografisk data lagret som punkter, linjer eller polygoner (Zeiler, 2010, s. 48-93).

Innholdsfortegnelse

1	Innledning.....	1
1.1	Problemstilling.....	2
1.2	Forutsetninger og avgrensninger	3
1.3	Oppgavens oppbygning	4
2	Teori	5
2.1	Innføring i <i>Valkyrie</i>	5
2.2	Geografiske analyser	6
2.3	Detaljerte kartdata i Norge	9
2.4	Dyplæring	10
2.5	Datagrunnlag dyplæring	19
3	Metode.....	22
3.1	Teknologivitenskapelig metode.....	22
3.2	Anvendt metode.....	23
4	Forsøksbeskrivelse	25
4.1	Arealdekkekart.....	26
4.2	Situasjonsbilder	27
5	Fremgangsmåte	33
5.1	Generering av arealdekke	33
5.2	Generering av situasjonsbilde.....	42
6	Resultater.....	51
6.1	Arealdekke.....	51
6.2	Situasjonsbilder	59
6.3	Simulatortest ved FFI	64
7	Diskusjon og drøfting.....	66
7.1	Resultater.....	66
7.2	Simulatortest ved FFI	74
7.3	Datakvalitet.....	75
7.4	Overførbarhet.....	81
8	Konklusjon	85
9	Videre arbeid.....	86
9.1	Anvendelse	86
9.2	Treningsdata	86
9.3	Modellarkitektur	86
9.4	Geografiske analyser	87
	Litteraturliste	88
	Vedlegg	91

Figurliste

Figur 1: Identifisering av åpne områder (gul) og ikke åpne områder (blå).....	5
Figur 2: Raster- og vektordata (Wegmann, 2010).....	6
Figur 3: Eksempel på Weighted Overlay.	7
Figur 4: Eksempel på en korridor fra verktøyet Corridor.	8
Figur 5: Kernel Density-analyse av punkter.	9
Figur 6: Kunstige nevrale nettverk (ANN).	10
Figur 7: Klassifisering i CNN.	11
Figur 8: Konvolusjon med 3x3 konvolusjonskjerne.	12
Figur 9: Arkitektur for U-nett (Ronneberger et al., 2015).	12
Figur 10: Max pooling.....	13
Figur 11: Veiledet læring.	14
Figur 12: Backpropagation i et kunstig nevral nettverk (ANN).	15
Figur 13: Over- og undertilpasning av en modell.	16
Figur 14: Eksempel på en forvirringsmatrise.....	17
Figur 15: Bilde av en Sentinel-2 satellitt (Rama, 2012).....	19
Figur 16: Romlig oppløsning for Sentinel-2 (European Space Agency - ESA, 2023).	20
Figur 17: Sentinel-2 L2A og L1C bilde.	20
Figur 18: Utsnitt fra Esri LULC 2022.	21
Figur 19: Fremgangsmåten for teknologivitskapelig metode (Stølen, 2019, s.20).	22
Figur 20: Anvendt fremgangsmåte basert på teknologivitskapelig metode.	23
Figur 21: Arbeidsflyt for fase 2: nyskaping.	24
Figur 22: Forsøksområde Rena.	25
Figur 23: Forsøksområde Tokmak.	26
Figur 24: Scenariobeskrivelse Scenario 1 - Rena.....	28
Figur 25: Scenariobeskrivelse Scenario 1 - Tokmak.	29
Figur 26: Scenariobeskrivelse Scenario 2 - Rena.....	30
Figur 27: Scenariobeskrivelse Scenario 2 - Tokmak.	30
Figur 28: Scenariobeskrivelse Scenario 3 - Rena.....	31
Figur 29: Scenariobeskrivelse Scenario 3 - Tokmak.	32
Figur 30: Arbeidsflyt for generering av arealdekkekart.....	33
Figur 31: Et treningseksempel med Sentinel-2 og labels fra Esri LULC.....	34
Figur 32: Datainnsamling Rena.....	35
Figur 33: Datainnsamling Tokmak.	36
Figur 34: Eksempel på ytelsen til to modeller under trening.	37
Figur 35: mAP før (mørkeblå) og etter (lyseblå) reklassifisering.	38
Figur 36: Fordel klasser for trenings- og valideringsdata Unet_Rena.	39
Figur 37: Fordeling klasser for trenings- og valideringsdata Unet_Tokmak.	40
Figur 38: Segmentering av et satellittbilde med og uten overlapp.....	41
Figur 39: Arbeidsflyt for generering av situasjonsbilde.....	42
Figur 40: Arbeidsflyt for Scenario 1: Krigssituasjon.	44
Figur 41: Bufferanalysen i Scenario 1 - Rena.	45
Figur 42: Kostnadsrasteret for stridsvogn i Scenario 1 - Rena.	46
Figur 43: Kostnadsraster Scenario 1 - Tokmak.....	48
Figur 44: Bufferanalyse i Scenario 1 - Tokmak.....	48
Figur 45: Arbeidsflyt i Scenario 3.....	49
Figur 46: Kostnadsrasterene i Scenario 3 - Rena (øverst) og Tokmak (nedert).	50

Figur 47: Labels (A), prediksjoner (B), Sentinel-2 bilde (C) og N50 (D) over Rena.....	52
Figur 48: Prediksjon (A) og Sentinel-2 bilde (B) over Rena.	53
Figur 49: Labels (A), prediksjon fra Unet_Tokmak (B) og Sentinel-2 bilde (C) over Tokmak.	54
Figur 50: Prediksjon over Tokmak (A) og Sentinel-2 bilde (B).	55
Figur 51: Forvirringsmatrise Unet_Rena.	56
Figur 52: Forvirringsmatrise Unet_Tokmak.	57
Figur 53: Arealdekkekart over Rena.	58
Figur 54: Arealdekkekart over Tokmak.	58
Figur 55: Situasjonsbildet Scenario 1 - Rena.	60
Figur 56: Situasjonsbilde Scenario 1 – Tokmak.	60
Figur 57: Situasjonsbilde Scenario 2 - Rena.	61
Figur 58: Situasjonsbilde Scenario 2 – Tokmak.	62
Figur 59: Situasjonsbilde Scenario 3 - Rena.	63
Figur 60: Situasjonsbilde Scenario 3 – Tokmak.	64
Figur 61: Skjermutklipp fra test i simulator hos FFI.....	65
Figur 62: labels (A), prediksjon fra Unet_Rena (B) og Norge i bilder (C).....	67
Figur 63: Labels (A), prediksjon fra Unet_Rena (B) og Norge i bilder (C).	68
Figur 64: Prediksjon fra Unet_Rena (A) og Sentinel-2 Scene Classification Map (B).	69
Figur 65: Labels (A), prediksjon fra Unet_Tokmak (B) og World Imagery (C).	71
Figur 66: Prediksjon fra Unet_Tokmak (A) og Sentinel-2 bilde fra 18.10.2023 (B).....	72
Figur 67: Prediksjon (A), Sentinel-2 True Colour (B) og Moisture Index fra 18.10.2023 (C). 73	
Figur 68: FKB AR5 med Norge i bilder fra 2022. (A) og labels fra Esri LULC med Norge i bilder fra 2022 (B).	76
Figur 69: FKB AR5 med Norge i bilder fra 2022. (A) og labels fra Esri LULC med Norge i bilder fra 2022 (B).	76
Figur 70: Esri LULC (2022) og World Imagery (2022) fra område Tokmak.....	77
Figur 71: Sentinel-2 bilde over Rena med oppgitt skydekke <5%.	79
Figur 72: Labels (A), prediksjon med Unet_Rena (B) og Norge i bilder (C) over Tana i Finnmark.	82

Tabelliste

Tabell 1: Hyperparametere.....	37
Tabell 2: Reklassifisering av Esri LULC klassene.....	38
Tabell 3: Vekting av klassene for Unet_Rena.....	39
Tabell 4: Vekting av klassene for Unet_Tokmak.....	40
Tabell 5: Vekting Arealdekke_Rena.	41
Tabell 6: Vekting Arealdekke_Tokmak.....	41
Tabell 7: Innsamlet data til generering av situasjonsbilde.	43
Tabell 8: Vekting av datasettene fiende_posisjon, sperringer og fortifikasjon.....	44
Tabell 9: Avstander på bufferanalysen i Scenario 1 - Rena.	45
Tabell 10: Vekting av arealdekke og helning i kostnadsrasteret i Senario 1 - Rena.	46
Tabell 11: Vekting av russiske posisjoner, sperringer og fortifikasjoner.	47
Tabell 12: Vekting av arealdekke og helning i kostnadsrasteret på Scenario 1 – Tokmak.....	47
Tabell 13: Vekting av arealdekke og helning i kostnadsrasteret i Scenario 3.....	49
Tabell 14: Ytelse for Unet_Rena og Unet_Tokmak.....	55
Tabell 15: Ytelse Unet_Rena i Finnmark.....	82

1 Innledning

Den teknologiske utviklingen har ført til at plattformer som droner og satellitter har blitt avgjørende innen etterretning, overvåkning og rekognosering, på engelsk *Intelligence, surveillance og reconnaissance* (ISR) (Hofoss et al., 2023). ISR handler om observasjon og monitorering av mål, informasjonshenting, analyser og vurderinger. Dette bidrar til å skape en oppdatert situasjonsforståelse (NATO, 2023), og kan fremstilles i form av et situasjonsbilde.

Droner har vist seg som svært viktige innenfor moderne krigføring for å identifisere fiendtlige styrker, gi måldata, utføre angrep, og til propaganda (Pettersen, 2022). Denne utviklingen har vist at droner er kostnadseffektive sammenlignet med tradisjonelle våpensystemer (Kramer & Addario, 2023). Bilder fra satellitter kan brukes for å oppdatere kartgrunnlag. Satellitter kan gi informasjon om store områder på kort tid, og spiller derfor også en viktig rolle innen datainnsamling. Satellitter som kan ta bilder i flere spektrale bånd gir også tilgang på informasjon en ikke kan se ved det blotte øyet (Phiri et al., 2020). Multispektrale bilder er godt egnet til ulike analyser, som eksempelvis endringsdeteksjon, overvåke klimaendringer eller til å kartlegge arealdekke. GeoAI kombinerer kunstig intelligens med geografiske analyser, og gjør det mulig å gjennomføre hurtig datainnsamling og analyser på store mengder data. Kombinert med ISR kan GeoAI og geografiske analyser bidra til mer effektive og bedre beslutninger i fredstid, krise, konflikter og krig.

Den teknologiske utviklingen har også relevans innen Forsvarets arbeid mot å nå FN's bærekraftsmål. FN's bærekraftsmål er en felles arbeidsplan for å utrydde fattigdom, bekjempe ulikheter og stoppe klimaendringene innen 2030 (FN, 2023). Bærekraftsmålene innen fred og sikkerhet: 16) *Fred, rettferdighet og velfungerende institusjoner*, og klima og miljø: 13) *Stoppe klimaendringene* og 15) *Livet på land*, er spesielt relevante for Forsvaret. Bruk av dyplæring i kombinasjon med droner og satellittbilder kan bidra til å effektivt identifisere og prioritere utsatte områder i militære operasjoner, eller overvåke ulovlig eller unormal aktivitet, og dermed bidra inn i bærekraftsmål 16). Videre kan droner benyttes til en rekke ulike formål, som for eksempel å frakte medisinsk utstyr (Hansbø, 2019, s.31). Ved å benytte droner fremfor personell og kjøretøy til rekognosering, vil menneskelig aktivitet i naturen reduseres. Dette vil hjelpe Forsvaret i arbeidet mot bærekraftsmål 13) og 15) gjennom om å bevare biologisk mangfold, og minske utslipp og forurensning.

For å gjøre Forsvaret i bedre stand til å utnytte teknologi forsker Forsvarets forskningsinstitutt (FFI) på blant annet autonomi og droner. Prosjektet *Valkyrie* går ut på å utvikle en autonom dronesverm som skal kunne forstå omgivelsene sine, unngå hindringer og ta beslutninger på egenhånd basert på et gitt oppdrag (O. R. Nummedal, personlig kommunikasjon, 9. november 2023). Målet med prosjektet er at en droneoperatør skal kunne styre en sverm, i motsetning til kun en drone slik det er i dag. Dette skal gjøres ved å gi et oppdrag til flere droner samtidig, hvor dronene skal koordinere og samarbeide om å løse oppdraget. En dronesverm kan derfor bidra til effektivisering av ulike oppdrag og frigjøre ressurser (Hansbø, 2019).

Effekten av dronesvermer vil avhenge av forutsetningene gitt for oppdragsløsningen. I *Valkyrie* navigerer dronene på et kartgrunnlag som kun skiller mellom åpne og ikke-åpne områder. Hvilke områder som er av interesse vil variere ut ifra terrenget og operasjonen. Dette fører til utfordringer som at dronesvermen søker i uønskede områder for et oppdrag, for eksempel kun langs en elv fremfor å søke i bebygde områder. Denne begrensningen i kartgrunnlaget hindrer dronene i å prioritere områder basert på hvordan terrenget ser ut (O. R. Nummedal, personlig kommunikasjon, 9. november 2023).

1.1 Problemstilling

Hensikten med oppgaven er å utarbeide et oppdatert kartgrunnlag til prosjektgruppen *Valkyrie* for å forbedre og prioritere søket til dronesvermen. Gjennom å definere prioriterte områder i kartgrunnlaget kan dette bidra til å gjøre dronene «smartere» og mer effektiv i sin oppdragsløsning. Denne oppgaven har som mål å gjøre kartgrunnlaget mer oppdatert og tilpasset et militært perspektiv. Med utgangspunkt i dette skal følgende problemstilling undersøkes:

Hvordan kan GeoAI og geografiske analyser bidra til å effektivisere rekognosering med dronesverm?

Problemstillingen vil løses ved å undersøke hvordan informasjon fra satellitter og etterretning kan benyttes sammen med geografiske analyser for å effektivisere navigasjon og prioritering av søk. En forutsetning for å prioritere områder er en god situasjonsforståelse. Oppgaven vil først benytte GeoAI i form av dyplæring til å segmentere Sentinel-2 bilder for å generere ett oppdatert kartgrunnlag over arealdekke. Deretter vil oppgaven benytte geografiske analyser basert på etterretninger for å generere et kartgrunnlag over situasjonsbilde som skal bidra til å prioritere områder og skape økt situasjonsforståelse.

Følgende forskningsspørsmål er utledet fra problemstillingen:

- *Hvordan kan en generere et kartgrunnlag over arealdekke som gjør det mulig å prioritere områder for rekognosering ved hjelp av dyplæring og Sentinel-2 bilder?*
- *Hvordan kan geografiske analyser og etterretninger bidra til å prioritere områder for søk med drone basert på*
 - *En fiendtlig handlemåte*
 - *En hendelseslogg*
 - *Støtte til søk etter en savnet person*

1.2 Forutsetninger og avgrensninger

Målgruppen for denne oppgaven er i hovedsak oppgavens oppdragsgiver: prosjektgruppen for *Valkyrie*, men også brukere innenfor geomatikk ved Krigsskolen eller tilsvarende. Oppgaven tar utgangspunkt i at det ikke er krav om forkunnskaper innen dyplæring, men dette vil være en fordel. Oppgaven forutsetter grunnleggende kunnskaper innenfor *Python* og geografiske analyser for å kunne benytte av fremgangsmåten og resultatene.

Målet med oppgaven er å utvikle en arbeidsflyt for å skape et oppdatert arealdekkekart ved hjelp av dyplæring og åpent tilgjengelig satellittdata. Arbeidsflyten er utviklet for å fungere globalt. I områder som eksempelvis er preget av klimaendringer, naturkatastrofer eller krig vil eksisterende kartgrunnlag raskt bli utdatert. Dette fører til usikkerhet rundt kvaliteten og aktualiteten på eksisterende kartgrunnlag. Det er derfor relevant med en metode for å generere oppdaterte arealdekkekart.

En begrensende faktor for oppgaven er tidsbegrensning og maskinvarens kapasitet, spesielt med tanke på prosesseringskraft og utvikling av dyplæringsmodellene. Fokuset for oppgaven er derfor å produsere et resultat som vurderes til å gi merverdi i militær sammenheng, fremfor å utvikle en nøyaktig og presis dyplæringsmodell. Tid er også en begrensende faktor for å kunne teste resultater i simulator ved FFI.

Oppgaven avgrenser seg til å gjennomføre dyplæring ved hjelp av programmeringsspråket *Python* med maskinlæringsbiblioteket *Pytorch*. Oppgaven tar utgangspunkt i å benytte og videreutvikle en kode for dyplæring levert av FFI. Dyplæringsmodellen i oppgaven trenes på en laptop med *NVIDIA GeForce RTX 3070 GPU* med 8192MiB minne. De geografiske analysene gjennomføres i programmet *ArcGIS Pro* ved hjelp av *Python* og det grafiske programmeringsspråket *Modelbuilder*.

Disse analysene baserer seg ikke på reelle kapasiteter og rekkevidder for å sørge for at oppgaven forblir ugradert. Oppgaven viser kun et utvalg av relevante analyser og scenarioer.

Dronesvermene i *Valkyrie* benytter et eksiterende antikollisjonssystem som baserer seg på en digital høydemodell, dette gjør at svermen selvstendig håndterte høydefaktoren (Z). Kartgrunnlaget som ble produsert avgrensner seg derfor til todimensjonale kart i (X, Y) -planet.

1.3 Oppgavens oppbygning


Oppgaven er delt inn i ni kapitler. *Kapittel 1* tar for seg bakgrunnen og problemstilling ved oppgaven. *Kapittel 2* beskriver det teoretiske rammeverket. Videre redegjør *Kapittel 3* for valgt metode, og hvordan denne er anvendt i oppgaven. *Kapittel 4* beskriver forsøket og rammeverket for forsøket. *Kapittel 5* beskriver selve fremgangsmåten for forsøket. Resultatene fra forsøket blir presentert i *Kapittel 6* og diskutert i *Kapittel 7*. Til slutt vil *Kapittel 8* presenterer en konklusjon for oppgaven, og *Kapittel 9* foreslår videre arbeid.

2 Teori

Dette kapitlet beskriver oppgavens teoretiske rammeverk. Innledningsvis vil kapitlet gi en innføring i det autonome dronesvermprosjektet *Valkyrie*, for deretter å redegjøre for relevant teori innen geografiske analyser. Avslutningsvis vil kapitlet beskrive grunnleggende teori innen dyplæring som er av relevans for oppgaven.

2.1 Innføring i *Valkyrie*

Det autonome dronesverm prosjektet *Valkyrie* benytter et kartgrunnlag i kombinasjon med ulike algoritmer for å navigere. Kartgrunnlaget er basert på en digital terrengmodell (DTM) og en digital overflatemodell (DOM). DTM er en modellering av terrengoverflaten som kun inkluderer jordoverflaten, mens DOM inkluderer både vegetasjon og menneskeskapte objekter som bygninger (Grinderud et al., 2016). For at dronene skal kunne identifisere vegetasjon og bygninger er det gjort enkle beregninger på datasettene ved å trekke DTM fra DOM. Figur 1 viser hvordan slike beregninger kan utføres for å skille mellom åpne områder og ikke-åpne områder.



Figur 1: Identifisering av åpne områder (gul) og ikke åpne områder (blå).

Kartgrunnlaget dronesvermen navigerer på inneholder ikke informasjon om arealtyper, og det er derfor ikke mulig for dronen å skille mellom ulike arealdekker som vann og vei. Satellittbilder kan brukes som et visuelt hjelpemiddel for svermoperatøren, men er ikke integrert i kartgrunnlaget for navigasjon (A. S. Simonsen, personlig kommunikasjon, 20. oktober 2023)

Dronene benytter en antikollisjonsalgoritme som baserer seg på planleggende algoritmer i forkant, og reaktive algoritmer under flyvning. De planleggende algoritmene tar inn et punkt A og et punkt B,


og finner en kollisjonsfri rute mellom punktene. De reaktive algoritmene benyttes for å manøvrere basert på nå-situasjonen, og gjør at dronene kan unngå både statiske og dynamiske objekter rundt seg som for eksempel andre droner eller bygninger (A. S. Simonsen, personlig kommunikasjon, 20. oktober 2023).

Søkealgoritmen til dronene er en reaktiv algoritme som avgjør hvor dronene skal fly. Dette bestemmes gjennom å samle inn relevant informasjon som for eksempel prioriterte områder, dronens posisjon, områder som allerede er søkt, og forventet dekningsgrad. Basert på denne informasjonen vil algoritmen produsere en rekke ulike handlemåter som rangeres og dronene vil velge den beste ruten (A. S. Simonsen, personlig kommunikasjon, 20. oktober 2023).

Dersom flere droner får tildelt samme oppdrag vil hver enkelt drone få informasjon fra de andre dronene. På denne måten vet de hvilke andre droner som gjør det samme, og kan koordinere oppdraget ved å for eksempel dele opp området som skal søkes. Deler av informasjonen deles med alle dronene innen radierekkevidde, som posisjon og hvilken oppgave de løser, mens annen informasjon deles kun med dronene som har samme oppdrag (A. S. Simonsen, personlig kommunikasjon, 20. oktober 2023).

2.2 Geografiske analyser

Rasterdata er geografisk data lagret som celler eller piksler i en matrise, vist i Figur 2. Cellene har en verdi som representerer informasjon, og cellens størrelse tilsvarer datasettenes oppløsning. Eksempler på rasterdata er høydedata eller satellittbilder (Zeiler, 2010, s. 186).



Figur 2: Raster- og vektordata (Wegmann, 2010).

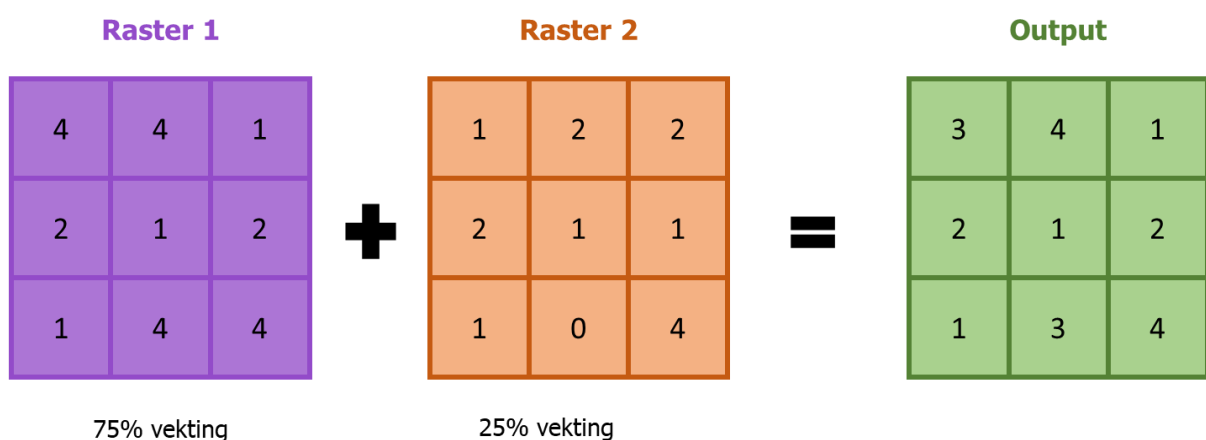
Satellittbilder brukes ofte som bakgrunnskart, og kan tilføre ny og oppdatert informasjon. Ved å benytte bilder fra multispektrale satellitter er det mulig å for eksempel generere temakart over klimaovervåking eller arealklassifisering. Rasterdata kan muliggjøre effektive og komplekse analyser på store mengder med data, og til å gjennomføre matematiske beregninger på dataene (Zeiler, 2010, s. 186-198).

En sentral del innen militær geomatikk er bruk av geografiske analyser til beslutnings- og oppdragsstøtte. Bufferanalyser, overlagsanalyser, rasteranalyser og romlige statistiske analyser er eksempler på slike analyser som ofte benyttes i forbindelse med militære operasjoner. Programvaren *ArcGIS Pro* inneholder en rekke verktøy innen geoprosesering for å gjennomføre ulike analyser, blant disse er analyseverktøyene *Weighted Overlay*, *Corridor* og *Kernel Density* benyttet i oppgaven.

2.2.1 Weighted Overlay

Weighted Overlay er et verktøy som kombinerer flere rasterlag til ett nytt rasterlag, eksemplifisert i Figur 3. Dette verktøyet kan blant annet brukes til å lage et kostnadsraster som representerer en kostnad for eksempel i form av energi, tid eller risiko, i forbindelse med å bevege seg gjennom et område (Esri, u.å.-a).

Et kostnadsraster kan genereres ved å for eksempel kombinere et raster over arealdekke med et raster som representerer helning for å bestemme den mest kostnadseffektive ruten fra A til B. Figur 3 viser hvordan ulike rasterlag kan tilegnes forskjellig vektning basert på hvilken betydning det bestemmes at de skal ha for resultatet. For eksempel kan arealdekke spille en større rolle enn helning i kostnadsrasteret.

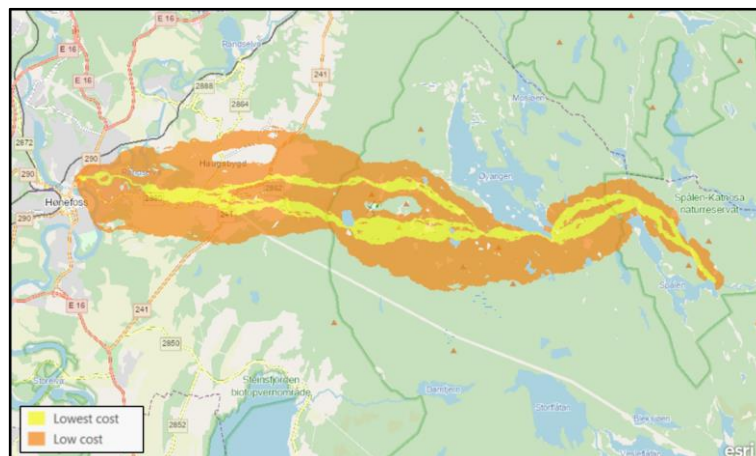


Figur 3: Eksempel på Weighted Overlay.

2.2.2 Corridor

Verktøyet *Corridor* kan brukes til å lage en korridor mellom ett startpunkt og ett sluttspunkt, og baserer seg på et kostnadsraster, et eksempel på en slik korridor er vist i Figur 4. Bredden på korridoren kan justeres ved å definere en terskelverdi for maksimal kostnad (Esri, u.å.-b).

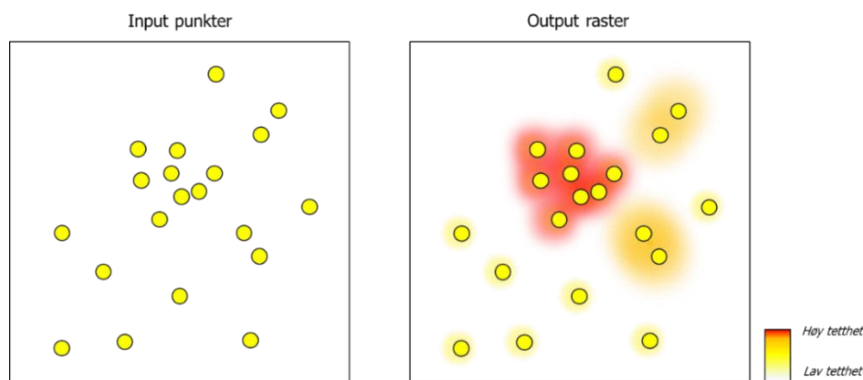
For å finne raskeste rute fra A til B, kan verktøyet *Distance Accumulation* brukes som kostandsraster for *Corrdior*. *Distance Accumulation* regner ut den samlede kostnaden fra hver celle i et raster til et eller flere definert områder (Esri, u.å.-c). Verktøyet baseres på ett eller flere kostnadsraster over overflaten som kan ta høyde for faktorer som vertikal og horisontal avstand eller arealdekke. Det er også mulig å inkludere hindringer som angir områder hvor det ikke er mulig å bevege seg over. Resultatet fra disse to verktøyene kan være et rasterkart med en korridor fra A til B, hvor verdiene representerer hvor det er mest kostnadseffektivt å bevege seg. I Figur 4 representerer det gule området hvor det er mest kostnadseffektivt å bevege seg.



Figur 4: Eksempel på en korridor fra verktøyet *Corridor*.

2.2.3 Kernel Density

Verktøyet *Kernel Density* brukes til romlig statistiske analyser, og kan identifisere og analysere tettheten av ulike egenskaper eller forekomster. Dette verktøyet kan brukes til å identifisere utsatte områder i en konflikt, eller endringer og trender i for eksempel en fiendes handlingsmønster. Verktøyet benytter inndata i form av vektordata som punkter eller linjer og søker innenfor en spesifisert radius for å produsere et rasterlag, se Figur 5. Hver celle i datasettet representerer en estimert tetthet basert nærheten av inndatapunktene. De høye verdiene i datasettet representerer en estimert høy tetthet (Esri, u.å.-d).



Figur 5: Kernel Density-analyse av punkter.

2.3 Detaljerte kartdata i Norge

Arealdekke- og arealressurskart er datasett med detaljert informasjon om arealtyper og arealressurser. Disse kan for eksempel brukes innen arealplanlegging eller til overvåking av klimapåvirkning. FKB-AR5 og N50 er blant de mest brukte kartdatasettene over arealressurser i Norge.

2.3.1 FKB

Felles kartdatabase (FKB) er en samling av detaljert grunnlagsdata i Norge og forvaltes av Geovekst-partnere i kommunene. Geovekst er et samarbeid om felles etablering, forvaltning, drift og vedlikehold av detaljerte kartdata og ortofoto. Dette samarbeidet bidrar til at data kun samles inn en gang etter en felles standard, og vedlikeholdes og oppdateres ett sted (*Håndbok for Geovekstsamarbeidet*, 2023).

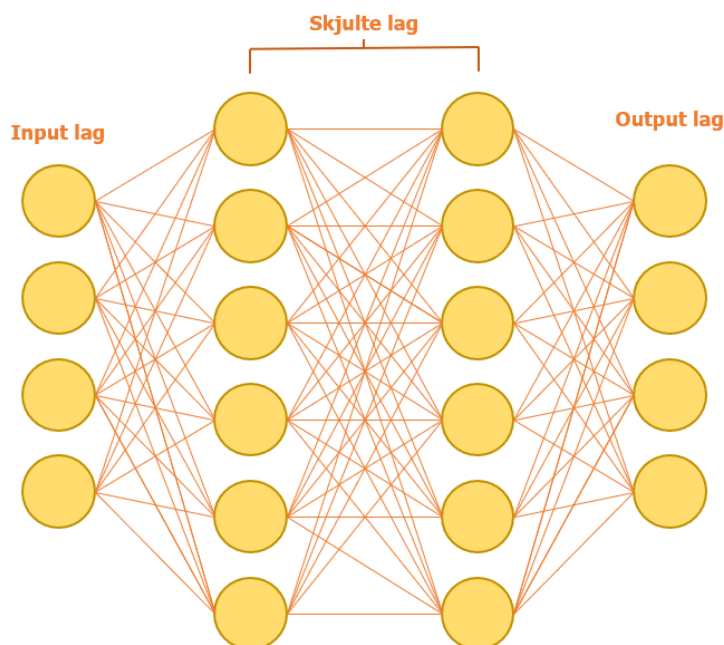
FKB-AR5 er et datasett som beskriver Norges arealressurser. Datasettet er delt inn i arealtypene fulldyrka jord, overflatedyrka jord, innmarksbeite, myr, åpen fastmark, bebyggd, samferdsel, snø/isbre, ferskvann og hav. FKB-AR5 dekker hovedsakelig behov innen arealplanlegging, landbruksforvaltning og lovforvaltning, datasettet er en del av det offentlige kartgrunnlaget og tilrettelagt for kommunenes plan- og byggesaksarbeid (*Arealressurskart - FKB-AR5 - Kartkatalogen*, u.å.). Ansvar for oppdatering av datasettet er delt mellom kommunene og Norsk institutt for bioøkonomi (NIBIO). Kommunene har ansvaret for det kontinuerlige ajourholdet, og NIBIO har ansvaret for det periodiske ajourholdet (*Ajourhold av AR5*, u.å.). FKB-AR5 har dekning over Norges hovedland og øyer med unntak av områder over tregrensen eller som har ukjent beskaffenhet (NIBIO, 2023).

2.3.2 N50

N50 er topografisk kartdata over Norge som er tilpasset målestokken 1:25 000 til 1:100 000. N50 ligger til grunn for den topografiske hovedkartserien i Norge, og den militære kartserien M711. Kartene inneholder detaljert topografisk informasjon som administrative områder, arealdekke, bygninger og anlegg, høyde, restriksjonsområde, samferdsel og stedsnavn (Kartverket, 2023).


2.4 Dyplæring

Dyplæring er en type maskinlæring som baserer seg på å trene maskiner til å utføre spesifikke komplekse oppgaver. Til forskjell fra en programmert applikasjon med bestemte regler for hvordan maskinen skal oppføre seg, skal dyplæring lære maskinen hva som er riktig oppførsel gjennom å trene på mange eksempler (Tidemann & Elster, 2023). For eksempel kan en maskin lære å identifisere og klassifisere objekter som hunder og katter i bilder den ikke har sett tidligere. Dyplæring benytter kunstige nevralt nettverk, på engelsk *artificial neural networks* (ANN), som er inspirert av den biologiske hjernen. ANN består av sammenkoblede noder som er organisert i flere lag, og trenes til å utføre forskjellige oppgaver (Goodfellow et al., 2016, s.5.). ANN består vanligvis av ett inndatalag, flere skjulte lag og ett utdatalag (Janiesch et al., 2021), vist i Figur 6.



Figur 6: Kunstige nevralt nettverk (ANN) Bearbeidet fra GeeksforGeeks.org (GeeksforGeeks.org, 2020).

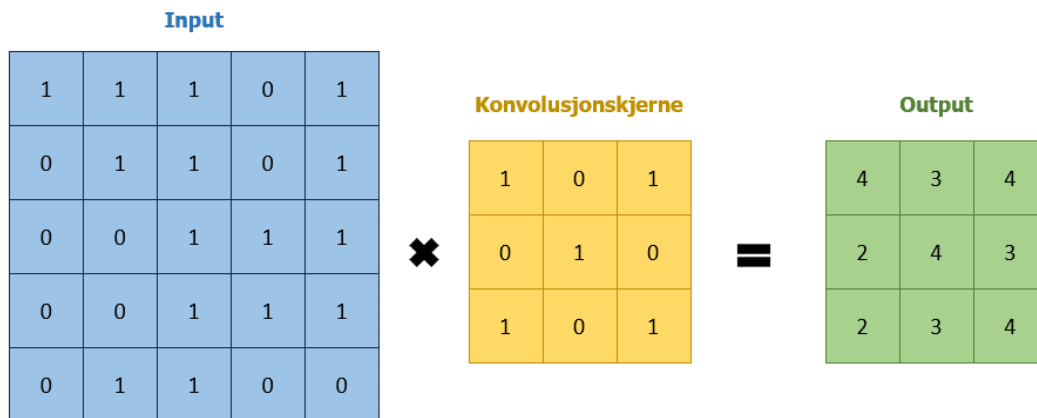
Nodene i lagene i ANN har tilknyttet vektore som bestemmer hvordan identifiserte egenskaper i bildene påvirker hva modellen predikerer (Goodfellow et al., 2016, s.105). For eksempel kan en node se etter katteører, og dersom denne noden identifiserer katteører vil dette sterkt påvirke modellen til å klassifisere objektet som en katt, se Figur 7. Dersom denne vekten derimot er lav, vil ikke identifiserte katteører påvirke at modellen klassifiserer objektet som en katt i like stor grad. Nodene har også en terskel-verdi som avgjør om noden blir aktivert og sender informasjon videre til neste lag (Goodfellow et al., 2016, s.108). Dersom verdien som sendes til noden er lavere enn terskelverdien vil ikke noden sende noe informasjon videre i nettverket. Disse vektene og terskelverdiene blir justert under trening av modellen. På denne måten blir de forskjellige lagene i ANN trent til å gjenkjenne ulike egenskaper ved informasjonen som sendes gjennom lagene (Goodfellow et al., 2016, s.6). Dette kan eksempelvis brukes til å gjenkjenne egenskaper i multispektrale satellittbilder, og segmentere disse til et kartgrunnlag.



Figur 7: Klassifisering i CNN. Bearbeidet fra Viso.ai (Boesch, 2021).

2.4.1 Konvolusjonelle nevrale nettverk

Konvolusjonelle nevrale nettverk, på engelsk *Convolutional neural network* (CNN), benytter konvolusjonslag for å identifisere og lære å gjenkjenne ulike egenskaper i blant annet bilder (Goodfellow et al., 2016, s.326). I konvolusjonslagene benyttes konvolusjonskjerne til å beregne *feature maps* fra pikselverdier. Dette gjøres ved matrisemultiplikasjon med matriser, også kjent som filtre, som beveger seg over bildene og beregner nye pikselverdier. Et eksempel på en slik matrisemultiplikasjon er vist i Figur 8. Dersom et bilde blir sendt inn som inndatalag, vil hver konvolusjonskjerne produsere et *feature map* av bildet. Etter en konvolusjonsoperasjon vil *feature map* bli sendt videre i nettverket til en aktiveringsfunksjon.

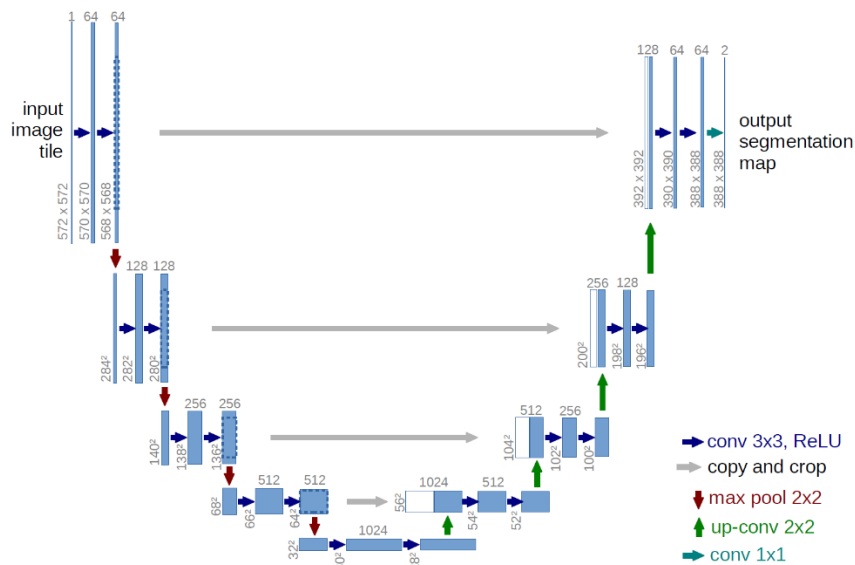


Figur 8: Konvolusjon med 3x3 konvolusjonskjerne.

2.4.2 U-nett

U-nett arkitekturen er en veletablert arkitektur for segmentering av ulike type bilder, som for eksempel biomedisinske bilder eller satellittbilder (Ronneberger et al., 2015; Solórzano et al., 2021). En av fordelene ved denne arkitekturen er at den utnytter treningsbildene på en effektiv måte, slik at en ikke har behov for veldig store mengder treningsdata (Ronneberger et al., 2015). Dette er spesielt relevant da tilgang til satellittbilder kan være en begrensende faktor for trening av en modell som skal bruke dette.

Arkitekturen for U-nettet i oppgaven består av en *encoder* og en *decoder*. *Encoder* omgjør og komprimerer inndataen, og utgjør den venstre delen av Figur 9. *Decoder* tolker informasjonen fra *Encoder* og rekonstruerer informasjonen til det originale formatet, og utgjør den høyre delen av Figur 9.

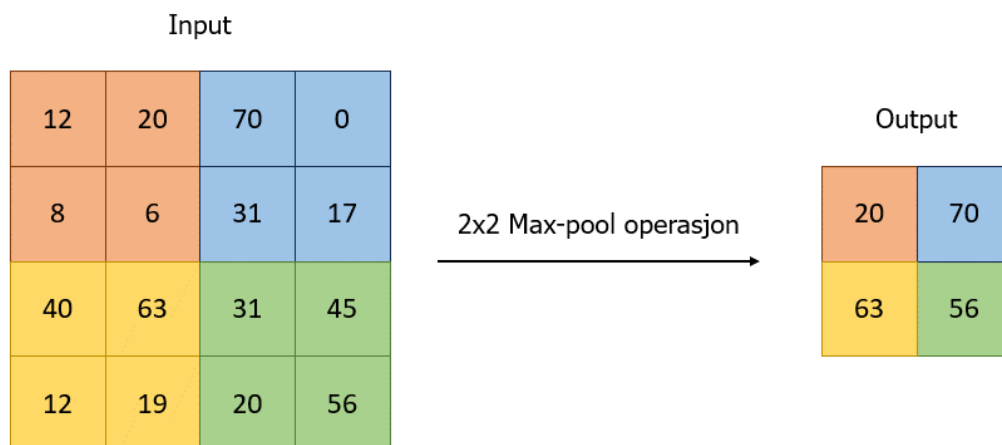


Figur 9: Arkitektur for U-nett (Ronneberger et al., 2015).

Encoder

I *encoder* vil bildet sendes inn som inndata og videre til flere konvolusjonsblokker bestående av konvolusjonslag, aktiveringsfunksjoner og max pool-operasjoner. Et eksempel på en aktiveringsfunksjon er *Rectified Activation Function* (ReLU) som erstatter negative verdier med null, og sender de positive verdiene videre i nettverket (Goodfellow et al., 2016, s.171). Slike ikke-lineære aktiveringsfunksjoner gjør det mulig for CNN å beskrive mer kompliserte funksjoner enn ved kun bruk av lineære funksjoner (Goodfellow et al., 2016, s.168). Etter første konvolusjonsblokk vil bildet ha 64 *feature maps*. Det gjennomføres også en *Batch normalization* i hver konvolusjonsblokk før verdiene sendes til aktiveringsfunksjonen. Dette fører blant annet til at modellen kan trenes hurtigere med en større læringsrate (Ioffe & Szegedy, 2015).

Deretter gjennomføres en *max-pooling* som *downsampler* størrelsen på bildet som innebærer at mengden informasjon som sendes videre i nettverket reduseres. Dette gjøres ved at bildet deles inn i områder på for eksempel 2x2 piksler, hvor kun den høyeste pikselverdien fra hver region beholdes, se Figur 10 (Goodfellow et al., 2016, s.335).



Figur 10: Max pooling. Bearbeidet fra Computersciencewiki.org (computersciencewiki.org, 2018)

Decoder

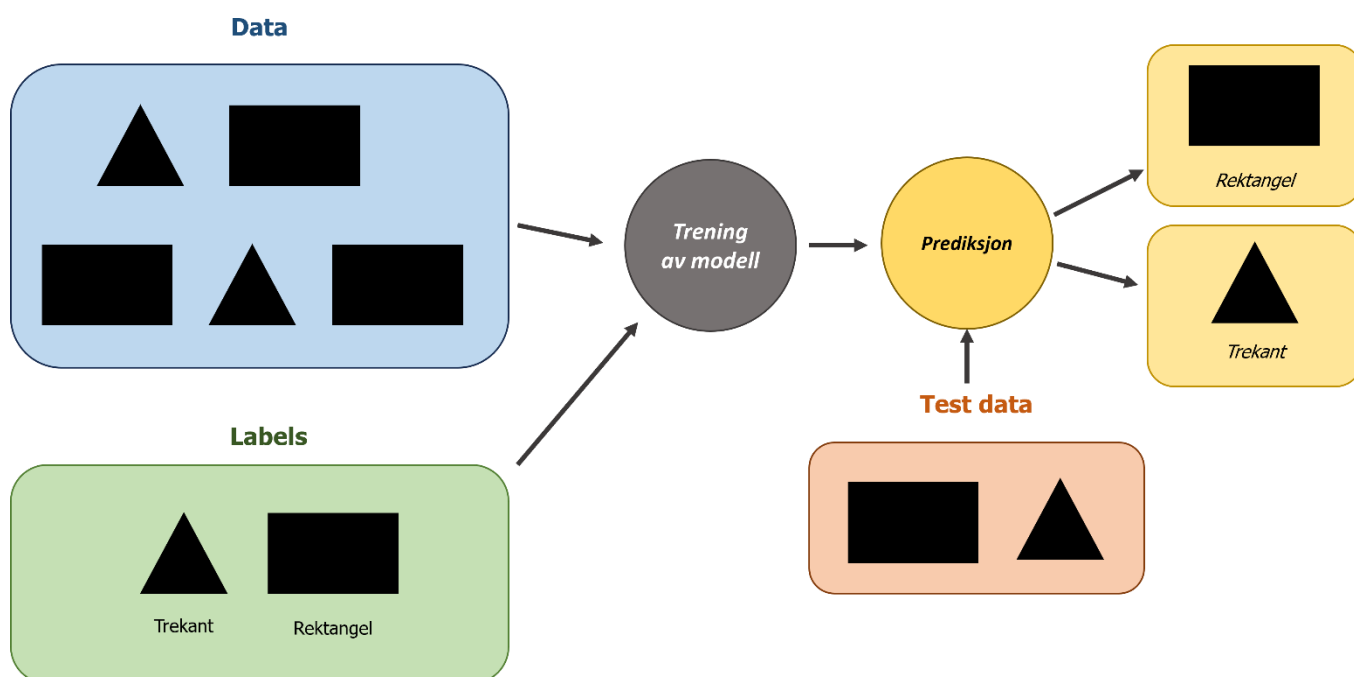
Etter at bildene har blitt sendt gjennom flere slike konvolusjonsblokker, gjennomføres opp-konvolusjoner for å øke oppløsningen til hvert *feature map* (Ronneberger et al., 2015, s.237). Det gjennomføres 2x2 opp-konvolusjoner som halverer antall *features* for hver operasjon. Deretter gjennomføres en 1x1 konvolusjon som omformer antall *feature map* likt antall klasser som skal segmenteres. Til slutt aktiveres en *softmax*-funksjon som angir en sannsynlighetsfordeling for hver

piksel for alle klassene. Underveis i prosessen sendes utdata fra lagene til *decoder* for å bedre lokalisering og kontekstualisering av de ulike egenskapene (Ronneberger et al., 2015). Dette er vist i Figur 9 som grå piler på tvers av modellen, og bidrar til å ivareta informasjon i bildene som ellers ville gått tapt.

2.4.3 Trening av dyplæringsmodell

Veiledet læring

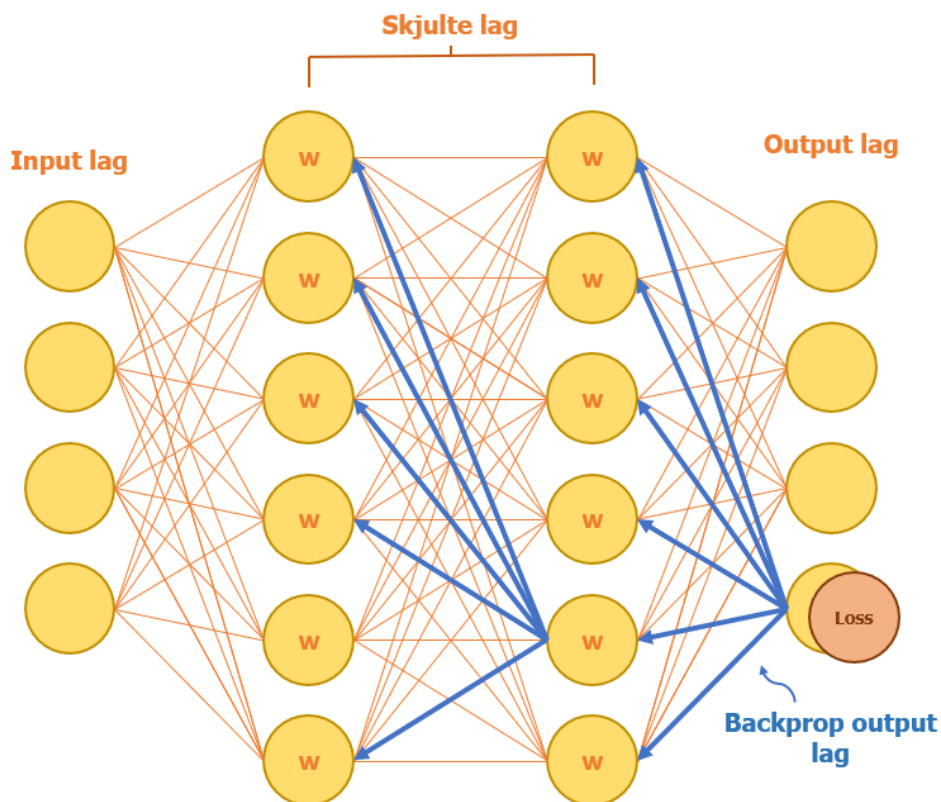
I veiledet læring inneholder treningsdatasettet et referansedatasett i form av korrekte klassifiseringer, også kalt *labels*, som modellen blir trent til å lære (Goodfellow et al., 2016, s.101). I et rasterdatasett med *labels* over arealdekke kan eksempelvis piksler over områder med klassen vann ha *label* «water». Et annet eksempel er vist i Figur 11, hvor treningsdata består av figurer merket med *labels* «Trekant», og «Rektangel». Modellen trener på data med *labels* og skal lære å gjenkjenne de ulike geometriske figurene. Deretter gjør modellen en prediksjon på et test-datasett, som resulterer i prediksjoner på hva modellen tror test-datasettet besto av.



Figur 11: Veiledet læring. Bearbeidet fra.(Javatpoint.com, u.å.).

Backpropagation og optimalisering

I treningsprosessen beregner modellen en tapsfunksjon som representerer avviket mellom den predikerte klassen og *label*, se Figur 12, (Goodfellow et al., 2016, s.80). En optimaliseringsalgoritme blir deretter benyttet for å sende informasjonen tilbake gjennom nettverket. Denne endrer vektene og terskelverdiene til nodene basert på gradienten til tapsfunksjonen. Gradienten er en vektor som angir retning og størrelse på den største økningen i tapsfunksjonen, og beregnes ved hjelp av en *Backpropagation*-algoritme (Goodfellow et al., 2016, s.200). Ved å benytte gradienten til å oppdatere vektene søker man å gjøre avviket mellom prediksjon og fasit så lite som mulig.

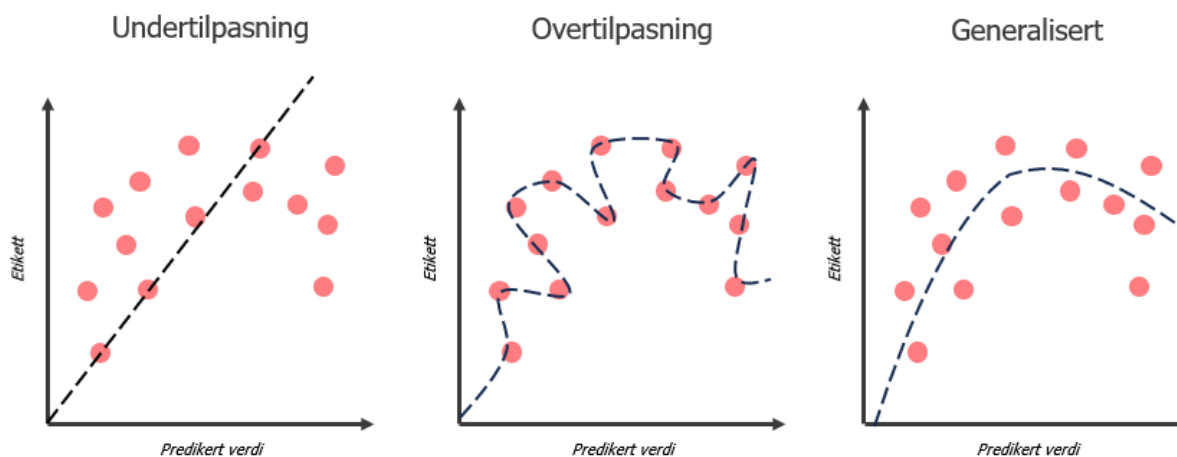


Figur 12: Backpropagation i et kunstig nevralt nettverk (ANN).

Hyperparametere

Hyperparametere er parametere som modellen ikke kan lære selv gjennom trening, men som påvirker hvordan modellen trener og lærer (Goodfellow et al., 2016, s.96). For å evaluere hvor godt modellen presterer, benyttes valideringsdata som modellen ikke har vært eksponert for tidligere (Goodfellow et al., 2016, s.102). En modell som presterer godt på valideringsdata kalles for en generalisert modell. En overtilpasset modell lærer seg å gjenkjenne treningsdata som dermed fører til en god klassifikasjonsriktighetsscore, men vil prestere dårlig på usett data. En vanlig årsak til overtilpassing

er dersom modellen ikke har tilgjengelig nok treningsdata eller er at modellen er for kompleks i form av mange lag (Goodfellow et al., 2016, s.110). Som vist i midten i Figur 13 vil prediksjonene ved overtilpasning være lik inndatapunktene. På samme måte kan en modell undertilpasses dersom modellen ikke er kompleks nok til å lære av treningsdataen eller ikke har trent lenge nok (Goodfellow et al., 2016, s.111). Resultatet av under-tilpasning er derfor at modellen ikke klarer å lære seg sammenhengene i treningsdatasettet, og er eksemplifisert til venstre i Figur 13.



Figur 13: Over- og undertilpasning av en modell.

I motsetning til vektene i de skjulte lagene, kan ikke modellen lære hyperparameterne selv da dette vil føre til en stor risiko for overtilpasning (Goodfellow et al., 2016, s.119). Eksempler på hyperparametere er læringsrate, valg av optimaliseringsfunksjon, nettverksarkitektur, *chip-size*, *batch-size* og epoker.

Under trening blir bildene delt inn i mindre deler kalt *chips*. Dette gjør at nettverket kun får se en liten del av bildene om gangen og gjør det enklere for modellen å generalisere og lære ulike egenskaper. *Batch-size* angir hvor mange *chips* som modellen trener på før den oppdaterer vektene og trener på neste *batch*. Valg av *chip-size* vil avhenge av oppløsningen til bildet, og oppgaven modellen skal utføre. En stor *chip-size* vil dekke et større område, noe som vil gi mer kontekst til egenskapene i bildet. Mindre *chips* vil gi flere eksemplarer i treningsdatasettet. På samme måte fører en stor *batch-size* til at modellen får se mer data samtidig, og vil gjøre treningsprosessen raskere. I tillegg vil dette føre til at modellen oppdaterer vektene basert på flere eksempler, som vil gi en mer nøyaktig oppdatering av vektene. På samme tid krever en større *batch-size* mer maskinkraft i form av GPU eller CPU-minne, og kan også øke sannsynligheten for overtilpasning. En liten *batch-size* fører til en lengre treningsprosess, men har lavere krav til minne og kan føre til mer nøyaktig læring. I

tillegg kan en liten *batch-size* føre til at vektene oppdateres med utgangspunkt i noen dårlige eksempler som kan føre til mer unøyaktighet. En stor *batch-size* kan derfor ha høyere læringsrate, mens en liten *batch-size* vil med fordel ha en lav læringsrate.

Når maskinen har sett all treningsdata en gang vil det utgjøre en epoke. Dersom modellen trenes på for mange epoker kan dette føre til overtilpasning, mens for få epoker kan føre til undertilpasning. Optimal størrelse på *chip-size*, *batch-size* og antall epoker avhenger derfor av modellen, oppgaven modellen skal utføre, og kapasitet til maskinvaren.

Ytelse

Ytelsen og klassifikasjonsriktigheten til en modell kan blant annet evalueres ved hjelp av forvirringsmatriser, *precision*, *recall*, *F1 score*, *mAP*, og *loss*, og kan brukes til å justere hyperparametere. Klassifikasjonsriktighet angir hvor godt modellen presterer opp mot referansedata, og nøyaktighet brukes om hvor godt modellen presterer opp mot sann verdi fra virkeligheten.

Antall sanne positive angir tilfeller som klassifiseres som positiv verdi som er riktig klassifisert. Dersom en modell skal identifisere katt og ikke-katt vil antall sanne positive angi tilfeller som blir riktig klassifisert som katt. På samme måte vil tilfellene som blir riktig klassifisert som ikke-katt være antall sanne negative. Dersom modellen klassifiserer tilfeller som katt, men som i virkeligheten ikke var en katt, blir dette falske positive tilfeller. Falske negative omfatter tilfellene som feilaktig klassifiseres som ikke-katt. En forvirringsmatrise viser andel falske positive, sann positive, falske negative og sann negative i form av en tabell. Figur 14 vises en forvirringsmatrise for å identifisere katt og ikke-katt. En slik tabell kan vise hvor stor andel som blir riktig klassifisert, og hva de falske positive blir klassifisert som.

		Predikerte verdier	
		KATT	IKKE-KATT
Faktiske verdier	KATT	0.7 <i>(sann positiv)</i>	0.3 <i>(falsk negativ)</i>
	IKKE-KATT	0.6 <i>(falsk positiv)</i>	0.4 <i>(sann negativ)</i>

Figur 14: Eksempel på en forvirringsmatrise.

Precision angir andelen av de predikerte sanne positive tilfellene som faktisk var positive, og beregnes ved forholdet mellom sanne positive og summen av sanne og falske positive (Goodfellow et al., 2016, s.418).

$$Precision = \frac{Sann\ positiv}{Sann\ positiv + falsk\ positiv}$$

Recall beskriver forholdet mellom sanne positive og summen av falske negative og sanne positive (Goodfellow et al., 2016, s.418).

$$Recall = \frac{Sann\ positiv}{Sann\ positiv + falsk\ negativ}$$

F1 scoren er et uttrykk for *precision* og *recall* kombinert (Goodfellow et al., 2016, s.419). Denne scoren kan benyttes i tilfeller hvor en har et ubalansert treningsdatasett som inneholder overvekt av en klasse. Da vil modellen kunne få god *precision* ved å predikere den dominerende klassen. Ved å se på F1 scoren vil en få et mer balansert inntrykk av hvordan modellen presterer (Goodfellow et al., 2016, s.419).

$$F1 = \frac{2 * precision * recall}{precision + recall}$$

mAP (mean average precision) er den gjennomsnittlige presisjonen fordelt på alle klassene, og beregnes ut ifra *precision* og *recall*. *mAP* er derfor et uttrykk på hvor god modellen er til å predikere de ulike klassene. På formelen under er n = antall klasser, og *AP* er et uttrykk for den gjennomsnittlige presisjonen for klasse k med hensyn til både *precision* og *recall*.

$$mAP = \frac{1}{n} \sum_{k=1}^{k=n} APk$$

2.5 Datagrunnlag dyplæring

Datagrunnlaget for dyplæringen besto av Sentinel-2 bilder og arealdekkekart fra Esri Land Use/Land Cover.


2.5.1 Sentinel-2

Sentinel-2 er en del av det Europeiske union sitt romprogram kalt *Copernicus programmet* (European Space Agency - ESA, 2023). Copernicus programmet omfatter ulike typer satellitter og oppdrag som har til hensikt å gi informasjon om jordoverflaten og atmosfæren til blant annet miljømessige og samfunnssikkerhetsmessige formål (Tandberg, 2023). Sentinel-2 består av to jordobservasjons-satellitter, Sentinel-2A og Sentinel-2B, som tar multispektrale bilder av jordoverflaten. Siden Sentinel-2 tar bilder med elektrooptiske sensorer vil bildene være påvirket av lys- og atmosfæriske forhold. Satellittene opererer derfor i den samme solsynkrone bane, for å maksimere belysning og minimere skydekke (Phiri et al., 2020). Satellittene opererer 180 grader fra hverandre, og har en temporal oppløsning på 5 dager for begge satellittene ved ekvator (Copernicus, u.å.). Sentinel-2 dekker land og kyst mellom breddegrad 56° sør og 82.8° nord, og har en opptaksbredde på 290 km (The European Space Agency, u.å.). Dette gjør at informasjon fra Sentinel-2 kan generere store og oppdaterte datasett med høy dekningsgrad som er anvendelige til ulike analyseformål.



Figur 15: Bilde av en Sentinel-2 satellitt (Rama, 2012).

Satellittene tar multispektrale bilder med en MSI (Multispectral imager) som tar opp 13 spektrale bånd. Disse båndene har en med romlig oppløsning fra 10 til 60 m, og er vist i Figur 16. De ulike båndene kan ta opp bølgelengder innen synlig lys, nær-infrarød, og kortbølge infrarød. På denne måten kan Sentinel-2 benyttes til å innhente informasjon om jordoverflaten som det menneskelige øyet ikke kan se.





Figur 16: Romlig oppløsning for Sentinel-2 (European Space Agency - ESA, 2023).

Produkttype L1C og L2A

Ved nedlastning av Sentinel-2 bilder er det mulig å velge mellom produkttypene L1C og L2A, se Figur 17. Begge produkttypene er georefererte og orto-rektifiserte bilder, som innebærer at bildene er geometrisk- og radiometrisk korrigeret for å kunne gi en nøyaktig representasjon av jordoverflaten. L1C er bilder med *Top of Atmosphere Reflectance* som betyr at bildene kan være påvirket av lys og partikler i atmosfæren. L2A er bilder av *Bottom of Atmosphere Reflectance* som er atmosfærisk korrigeret (Phiri et al., 2020).

L2A

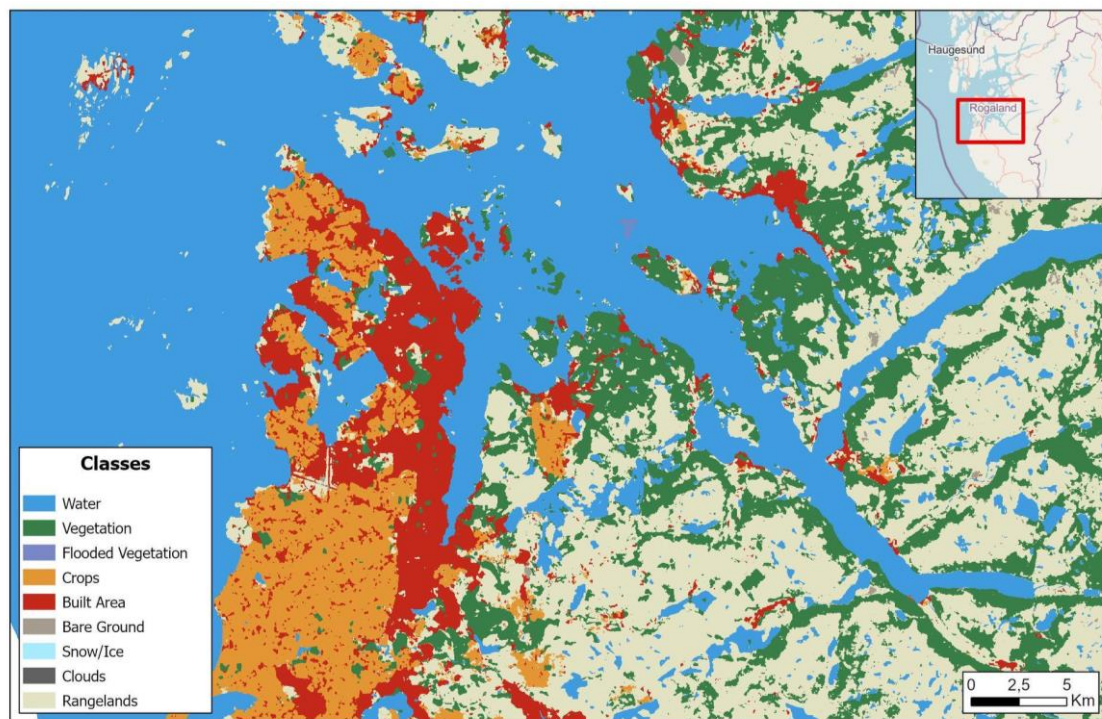
L1C



Figur 17: Sentinel-2 L2A og L1C bilde.

2.5.2 ESRI Land Use/Land Cover

ESRI Land Use/Land Cover (LULC) er et globalt rasterdatasett over arealdekke som er opprettet ved hjelp av *Impact Observatory's deep learning AI land classification model* basert på Sentinel-2 bilder med 10 meters romlig oppløsning (Esri, 2022). Datasettet lages for hele år basert på Sentinel-2 Level 2A bilder med manuelle *labels* som er laget ved å tegne polygoner rundt arealklassene. Datasettet har dekning fra 2017 til 2022, og inneholder ni forskjellige klasser arealklassifikasjon: vann, trær, oversvømt vegetasjon, dyrket jord, bebygd område, bar bakke, snø/is, skyer og beiteområder, se Figur 18. Datasettet over 2022 er oppgitt til å ha en gjennomsnittlig nøyaktighet på over 85% (Karra et al., 2021).



Figur 18: Utsnitt fra Esri LULC 2022.

3 Metode

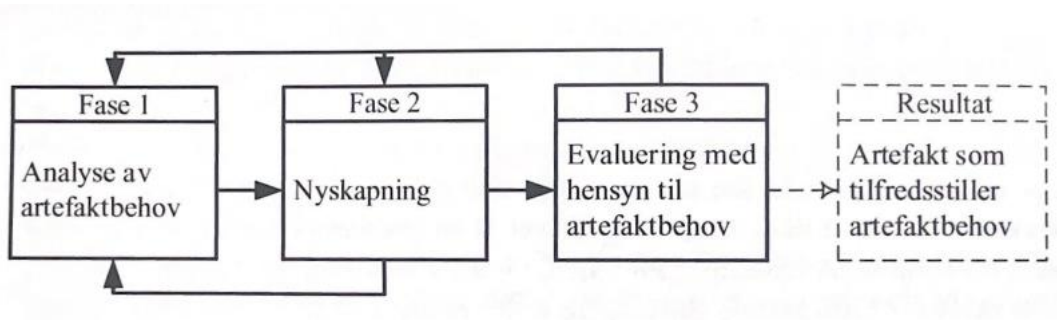
Metoden som ble benyttet i denne oppgaven tok utgangspunkt i teknologivitenskapelig metode beskrevet av Stølen (2019). Dette kapittelet vil gi en innføring i teknologivitenskapelig metode, og til slutt en beskrivelse av anvendt metode i oppgaven.

3.1 Teknologivitenskapelig metode

Teknologi kan forstås som menneskeskapte objekter og ferdigheter som brukes for å anvende og fremstille nye objekter og fenomener, kjent som artefakter. Teknologivitenenskap handler om å skape ny kunnskap eller utvikle og forbedre eksisterende artefakter. For å drive med teknologivitenskapelig forskning må det ligge et artefaktbehov til grunn som beskriver et behov for ny eller forbedret teknologi. Artefaktbehovet kan komme fra forskeren selv, eller en bestiller. Etter at artefaktbehovet er tilstrekkelig karakterisert er det opp til forskeren hvordan behovet skal oppfylles (Stølen, 2019, s.10-15).

3.1.1 Teknologivitenskapens fremgangsmåte

Den teknologivitenskapelige fremgangsmåten er delt inn i tre faser: *Fase 1*) Analyse av artefaktbehovet, *Fase 2*) Nyskapning, og *Fase 3*) Evaluering, se Figur 19. Resultatet av teknologivitenskapelig forskning skal være et nytt eller forbedret artefakt som tilfredsstillende artefaktbehovet (Stølen, 2019, s.20).



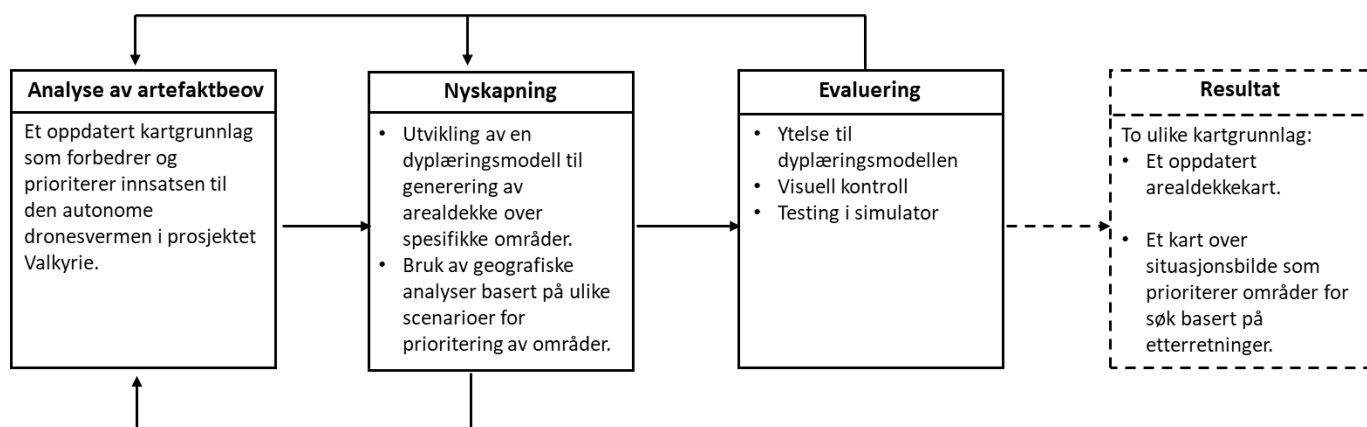
Figur 19: Fremgangsmåten for teknologivitenskapelig metode (Stølen, 2019, s.20).

Fase 1 handler om å identifisere og analysere artefaktbehovet, dette inkluderer å skaffe kunnskap om behovet, og eksisterende teknologi. *Fase 2* handler om nyskapning, her forsøkes det å skape eller forbedre et artefakt. *Fase 3* handler om evaluering opp mot artefaktbehovet. Denne fasen kan

innebære flere eksperimenter eller undersøkelser. Det er spesielt viktig å dokumentere oppsett for evaluering og resultater slik at forskningen er etterprøvbart. Dersom evalueringen tilfredsstillende, kan det konkluderes med et endelig resultat. Dersom forskningen ikke tilfredsstillende, må en gå tilbake for å revidere og justere analysen av behovet, utvikle nye eller forbedre artefakter. (Stølen, 2019, s.20-24).

3.2 Anvendt metode

I likhet med teknologivitenskapelig metode (Stølen, 2019) besto metoden i denne oppgaven av *fase 1) Analyse av artefaktbehov, fase 2) Nyskapning, fase 3) Evaluering* og til slutt et resultat som tilfredsstilte artefaktbehovet. De ulike fasene i denne oppgaven er illustrert i Figur 20.



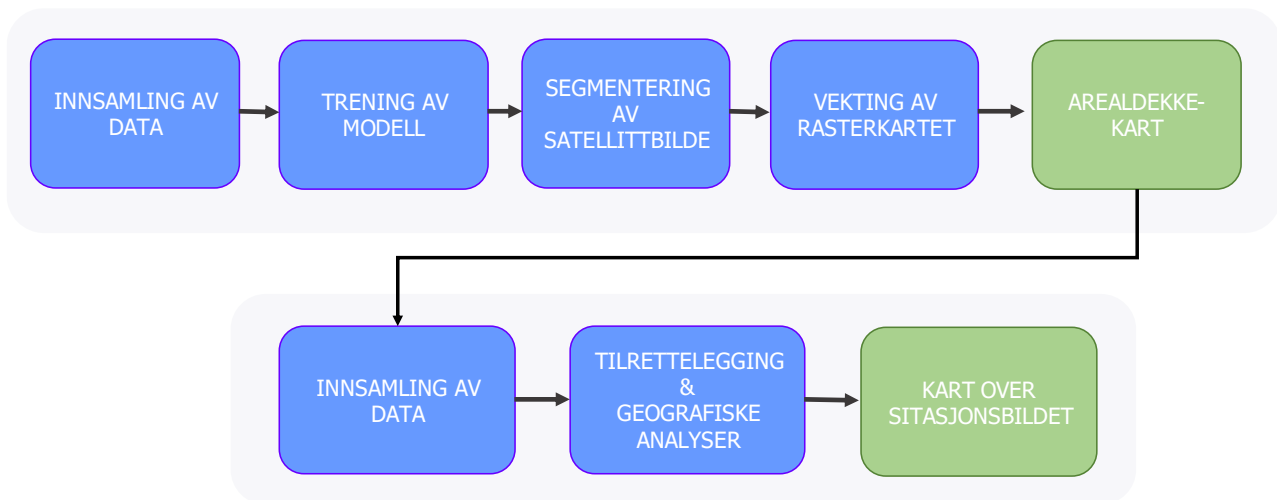
Figur 20: Anvendt fremgangsmåte basert på teknologivitenskapelig metode.

3.2.1 Fase 1: Analyse av artefaktbehov

Artefaktbehovet for denne oppgaven var et verktøy for å lage kartgrunnlag som FFI kan benytte i *Valkyrie*. I dialog med prosjektgruppen i *Valkyrie* ble det identifisert at deres behov var todelt. Det første behovet var et verktøy for å lage arealdekkekart som gjorde det mulig å angi hvilke områder som var av større interesse enn andre. Det andre behovet var et verktøy for å lage kart som beskrev situasjonsbilde basert på etterretninger for å effektivisere og prioritere områder dronene skulle søke. Disse kartgrunnlagene skulle benyttes i kombinasjon for å erstatte det nåværende kartgrunnlaget.

3.2.2 Fase 2: Nyskapning

Figur 21 illustrerer arbeidsflyten i Fase 2. Nyskapningen i oppgaven besto av å utvikle en metode for å generere de ulike kartgrunnlagene, og er beskrevet i større detalj i *Kapittel 4: forsøksbeskrivelse* og *Kapittel 5: Fremgangsmåte*. Prosessen for nyskapning har resultert i to steg: generering av segmentert satellittbilde til et arealdekkkart, og geografiske analyser for å beskrive situasjonsbilde.



Figur 21: Arbeidsflyt for fase 2: nyskapning.

Begge stegene i prosessen har inkludert: 1) Datainnsamling, 2) Tilrettelegging og geografiske analyser og 3) Evaluering. Resultatet av nyskapningen ble en arbeidsflyt for å generere et kart med arealdekke over et valgt område, i tillegg til en demonstrasjon av hvordan geografiske analyser kan bidra til å prioritere områder. Verken utvikling av arealdekkkart ved hjelp av dyplæring, eller de geografiske analysene er i seg selv nyskapende, men disse har ikke tidligere blitt brukt til å oppdatere et kartgrunnlag med prioriterte søkeområder for autonome dronesvermer.

3.2.3 Fase 3: Evaluering med hensyn til artefaktbehov


De segmenterte satellittbildene ble evaluert opp mot tilsvarende eksisterende data og referansedata brukt i dyplæringen. Arealdekkkartet ble evaluert ved å vurdere ytelsen og klassifikasjonsriktigheten til dyplæringsmodellen, og gjennom simulering av dronesverm ved FFI. I simuleringen ble det vurdert hvorvidt arealdekkkartet bidro til å effektivisere rekognosering, og ble sammenlignet opp mot tidligere kartgrunnlag.

Situasjonsbildene ble evaluert gjennom simulering av dronesverm ved FFI for å vurdere hvorvidt det bidro til å effektivisere rekognosering. Evaluering av hvorvidt forsøket oppfyller artefaktbehovet er beskrevet i *Kapittel 7 Diskusjon og drøfting*.

4 Forsøksbeskrivelse


Dette kapitlet vil gi en beskrivelse av forsøket og hvilke forutsetninger som lå til grunn. Først beskrives generering av arealdekkkartet, deretter situasjonsbildene med tilhørende scenariobeskrivelser. Fremgangsmåten og resultatene for forsøket er beskrevet i *Kapittel 5* og *6*.

Forsøket ble gjennomført på to ulike områder, Rena i Norge og Tokmak i Ukraina. Forsøksområdet Rena, se Figur 22, ble valgt fordi *Valkyrie* tidligere har benyttet dette område i sine simulatorer, og det var derfor interessant å lage arealdekkkart og situasjonsbilder over et område *Valkyrie* var kjent med fra før.



Figur 22: Forsøksområde Rena.

Forsøksområdet Tokmak, se Figur 23, ble valgt fordi den ukrainske frontlinjen befant seg ved Tokmak per november 2023. Dette gjorde det mulig å gjennomføre geografiske analyser på et reelt scenario, og generere et arealdekkkart over et område med annerledes topografi enn Norge.



Figur 23: Forsøksområde Tokmak.

4.1 Arealdekkekart

Generering av arealdekkekartene besto av en arbeidsflyt fra innsamling av satellittdata, trening av en dyplæringsmodell, segmentering av satellittbilder, og til slutt å generere oppdaterte kart med prioritert arealtyper. Det ble trent to dyplæringsmodeller tilpasset de to ulike forsøksområdene for å demonstrere hvordan en modell kan tilpasses et bestemt område. Deretter ble arealtypene i arealdekkekartene vektet basert på hvilke arealtyper som var av interesse.

Den utviklede arbeidsflyten gjør det mulig å generere kartgrunnlag over områder hvor det ikke eksisterer oppdatert kartgrunnlag, eller hvor kvaliteten til kartgrunnlaget er usikkert. Det gjør det også mulig å tilpasse dyplæringsmodellene og kartgrunnlaget basert på operasjonelle behov, eksempelvis hvilke arealtyper som er av interesse. Dyplæringsmodellen ble laget for å segmentere Sentinel-2 bilder som er åpent tilgjengelig for nedlastning. I tillegg har Sentinel-2 en hyppig og pålitelig temporal oppløsning. Dette gjør at arbeidsflyten for arealdekkekart enkelt kan gjenskapes, og benyttes over mange ulike områder.

4.2 Situasjonsbilder

Situasjonsbildene ble generert ved bruk av geografiske analyser med utgangspunkt i de utviklede arealdekkkartene, høydedata og etterretninger. Hensikten med situasjonsbildene var å bidra til å prioritere områder for rekognosering. Disse ble generert med utgangspunkt i tre egenproduserte scenarioer hvor det kan være relevant å benytte en autonom dronesverm. Scenarioene besto av en krigssituasjon, en hendelseslogg i en fredsbevarende operasjon og søk etter en savnet person. De geografiske analysene av hvert scenario ble gjennomført på begge forsøksområdene. Områdene i situasjonsbildene ble deretter vektet med verdier fra 1-5, hvor 5 var høyest prioritert.

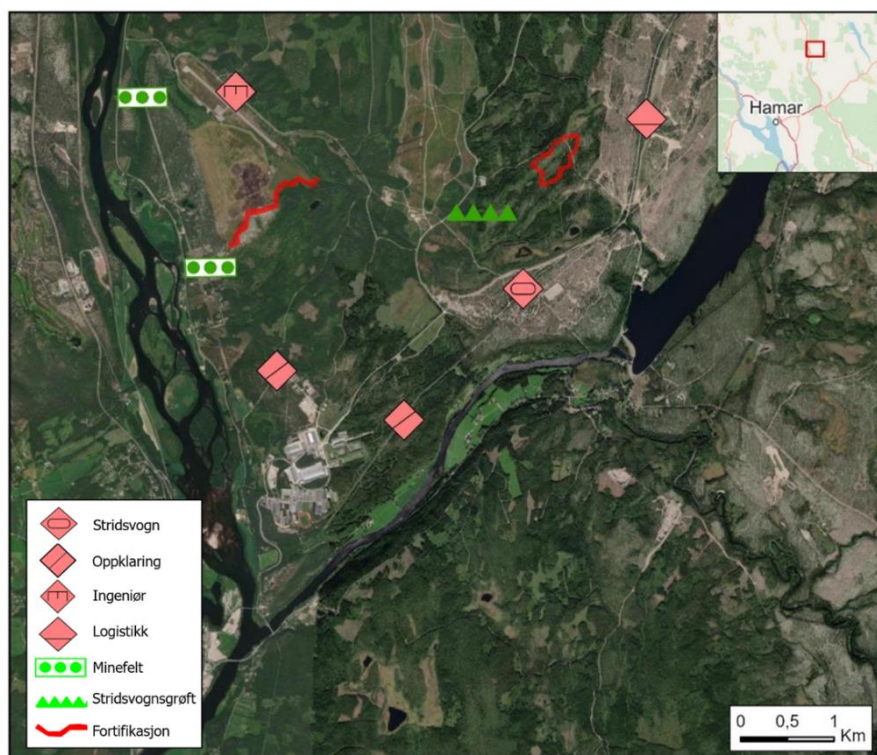
4.2.1 Scenario 1: Krigssituasjon

Scenario 1 benyttet raster- og overlagsanalyser på etterretninger om fiendens styrker, sperringer og fortifikasjoner i forsøksområdene. Hensikten med dette scenarioet var å vise hvordan geografiske analyser kombinert med rapporterte posisjoner kunne bidra til å prioritere områder for rekognosering.

Rena

Scenario 1 - Rena ble utviklet med utgangspunkt i en egenutviklet fiendtlig handlemåte. Handlemåten ble utformet basert på håndbøker benyttet i undervisning på Krigsskolen. Håndbøkene beskriver en fiendes styrkeoppbygging, materiell og handlemåte. Håndbøkene er merket *Unntatt offentligheten*, og derfor ikke vedlagt oppgaven.

Figur 24 beskriver *Scenario 1 - Rena*. Fienden består av en pansret infanteribataljon som har angrepet Rena. Den pansrede infanteribataljonen har til hensikt å ta Rena leir, for deretter å angripe videre mot Elverum. Lokalt består fienden av ett stridsvogns kompani støttet av en ingeniørtropp, en oppklaringstropp og en logistikkropp. Fienden har befestet seg på lokale høyder, og i tilknytning til flyplassen med flere sperringer i området. Fienden er kjent for å minelegge store områder, samt benytte andre typer sperringer. Lokalt ønsker fienden å nekte den forsvarende styrken tilgang til Rena flyplass. Fiendens sannsynlige handlemåte er å oppklare våre styrker med sin oppklaringstropp, for deretter å angripe oss med sitt stridsvogns kompani. Scenarioet er derfor basert på en forsvarende styrke som skal rekognosere en fiendtlig angripende styrke.



Figur 24: Scenariobeskrivelse Scenario 1 - Rena.

Tokmak

Utgangspunktet for *Scenario 1 - Tokmak* baserte seg på rapporterte russiske posisjoner, sperringer og fortifikasjoner fra krigen i Ukraina per 13.11.2023, data ble hentet fra *Ukraine control map*. Dette datasettet er utviklet av *Project Owl* som er et nettsamfunn med over 32 000 medlemmer. Datasettet er et av deres større prosjekter som handler om etterretninger basert på åpne kilder, og har mer enn 18.5 millioner visninger (*Home*, u.å.). Per november 2023 var Tokmak en tungt befestet by, omringet av sperringer og fortifikasjoner. De russiske styrkene hadde bygd komplekse sperringer langs hele frontlinjen, og dette medførte en stor taktisk utfordring for de Ukrainske styrkene (Watling & Reynolds, 2023).

Figur 25 beskriver *Scenario 1 - Tokmak*. Dette scenarioet baserer seg på en fiendtlig styrke med et forberedt forsvar, de fiendtlige styrkene er ikke differensiert på avdelingstype. Fiendens sperringer består av dragetenner i form av trekant-formede betongelementer som har til hensikt å stanse pansrede kjøretøy. Fienden har også stillinger og skyttergraver i form av fortifikasjoner rundt byen Tokmak, og langs de nordre forsvarslinjene. Scenarioet baseres på en angripende styrke som skal identifisere gjennombrytningsmuligheter i et fiendtlig forsvar.




Figur 25: Scenariobeskrivelse Scenario 1 - Tokmak.

4.2.2 Scenario 2: Hendelseslogg

Scenario 2 er basert på statistiske analyser med bakgrunn i fiktive fredsbevarende operasjoner. Hensikten med scenarioet var å vise hvordan geografiske analyser kan bidra til å prioritere områder basert på tetthet av hendelser. Punktene som ble benyttet i analysene ble ansett som like viktige og hadde til hensikt å etterligne en hendelseslogg hvor fredsbevarende styrker hadde blitt angrepet av en opprørsgruppe.

Rena

Figur 26 beskriver *Scenario 2 - Rena*. Etterretningene som ble brukt i de geografiske analysene var tilfeldige punkter. Disse ble laget ved hjelp av en *Python*-kode som genererte en hendelseslogg med 500 tilfeldige punkter over hele området, og fire mindre klynger med punkter.



Figur 26: Scenariobeskrivelse Scenario 2 - Rena.

Tokmak

Figur 27 beskriver *Scenario 2 - Tokmak*. Etterretningene brukt i de geografiske analysene besto av en logg med russiske geolokasjoner fra krigen i Ukraina fra 2022 til 2023. Selv om punktene var fra krigen i Ukraina, representerte de i dette scenarioet fiendtlige hendelser i forbindelse med en fredsbevarende operasjon.



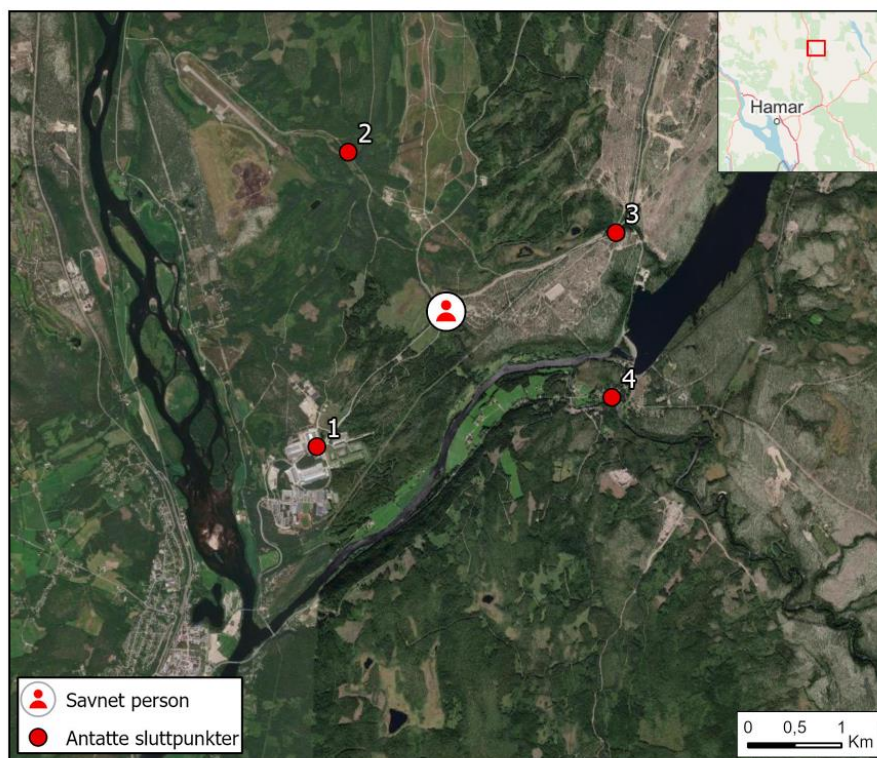
Figur 27: Scenariobeskrivelse Scenario 2 - Tokmak.

4.2.3 Scenario 3: Savnet person

Scenario 3 var basert på et scenario hvor en dronesverm skulle støtte med søk etter en savnet person. Scenarioet baserer seg på posisjoner med siste observasjon. Det var usikkert hvor personen ville bevege seg videre og det ble derfor vurdert fire mulige sluttpunkter. Hensikten med scenarioet var å vise hvordan geografiske analyser kan bidra til å prioritere hvilke områder en skal søke, basert på hvor det er kostnadseffektivt for en person å forflytte seg.

Rena

Figur 28 beskriver *Scenario 3 - Rena*. De fire mulige sluttpunktene er vurdert til å være: Rena leir (1), Rena flyplass (2), nord i øvingsområdet (3) og veiaksen sør for Løpssjøen (4).



Figur 28: Scenariobeskrivelse Scenario 3 - Rena.

Tokmak

Figur 29 beskriver *Scenario 3 - Tokmak*. De fire mulige slutt punktene er vurdert til å være: Tokmak i sør (1), Pokrovske i vest (2), Novoprokopvika i nord (3) og veiaksen i øst mot Ocheretuvate (4).



Figur 29: *Scenariobeskrivelse Scenario 3 - Tokmak.*

5 Fremgangsmåte

Kapittelet beskriver fremgangsmåten benyttet i forsøket. Først beskrives fremgangsmåten for dyplæring og generering av arealdekke, deretter fremgangsmåten for generering av situasjonsbilde. *Python*-kodene som er benyttet i oppgaven er vedlagt i *Vedlegg A* til *C*, og vil ikke beskrives i detalj i dette kapittelet.

5.1 Generering av arealdekke

For å generere arealdekkekart, trente oppgaven dyplæringsmodellene *Unet_Rena* og *Unet_Tokmak*. *Unet_Rena* ble trent til å generere et arealdekkekart over *Rena* i Norge, og *Unet_Tokmak* over *Tokmak* i Ukraina. Dette delkapittelet vil beskrive hovedlinjene for dyplæringen som besto av innsamling av data, trening av modell, segmentering av satellittbilde og vekting av rasterkart, illustrert i *Figur 30*. Koden for dyplæring (*Vedlegg B*) ble gitt av *FFI*, men har blitt endret og tilpasset til oppgaven. Koden ble endret fra å være tilpasset *Sentinel-2 L1C* bilder til å passe produkttypen *L2A*. I tillegg ble det eksperimentert med ulike hyperparametere for å tilpasse koden til datasettene.

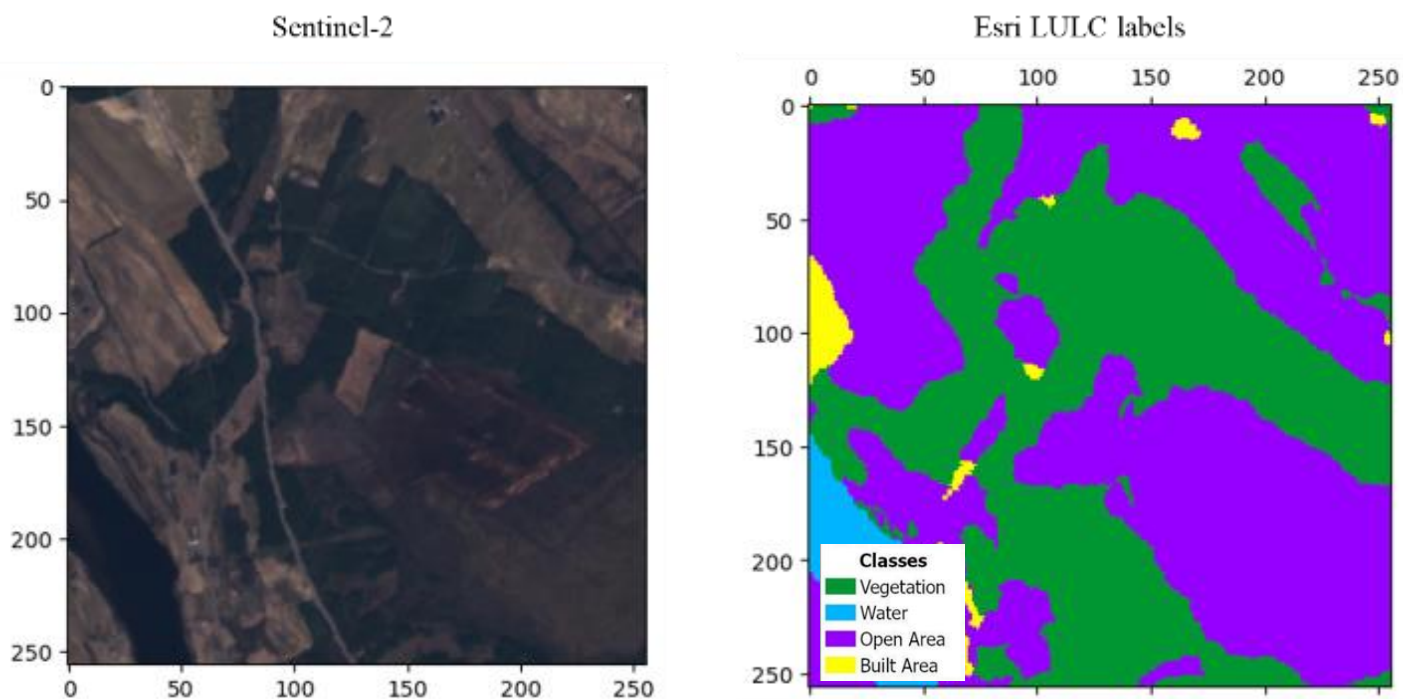


Figur 30: Arbeidsflyt for generering av arealdekkekart.

5.1.1 Innsamling av treningsdata

Treningsdatasettet til dyplæringsmodellene besto av *Sentinel-2* bilder satt sammen med *labels* fra *Esri LULC* innenfor samme år. Disse ble satt sammen ved hjelp av *GeoSampler* fra *Torchgeo* som hentet eksemplarer fra samme område fra begge datasettene. Disse ble deretter delt inn i *chips* på 256 x 256 piksler.

Bilde-fliser (*tiles*) med *Esri LULC* ble lastet ned fra *Esri* (*Esri, 2021*). *Sentinel-2* bildene ble lastet ned via *Python* og *Sentinel Hub API*. Koden for nedlastning av *Sentinel-2* bildene er lagt ved i *Vedlegg A*. *Figur 31* viser et eksempel på en flis fra et satellittbilde satt sammen med *labels* fra *Esri LULC* over samme område.



Figur 31: Et treningseksempel med Sentinel-2 og labels fra Esri LULC.

De nedlastede Sentinel-2 L2A bildene ble delt inn i treningsdata og valideringsdata.

Treningsdatasettet og valideringsdatasettet ble normalisert for å unngå for høye eller lave pikselverdier. Eksempelvis kan noen bånd i satellittbildene ha høyere verdier enn andre. Ved å normalisere bildene unngår en derfor at høye verdier overstyrer de mindre.

Unet_Rena

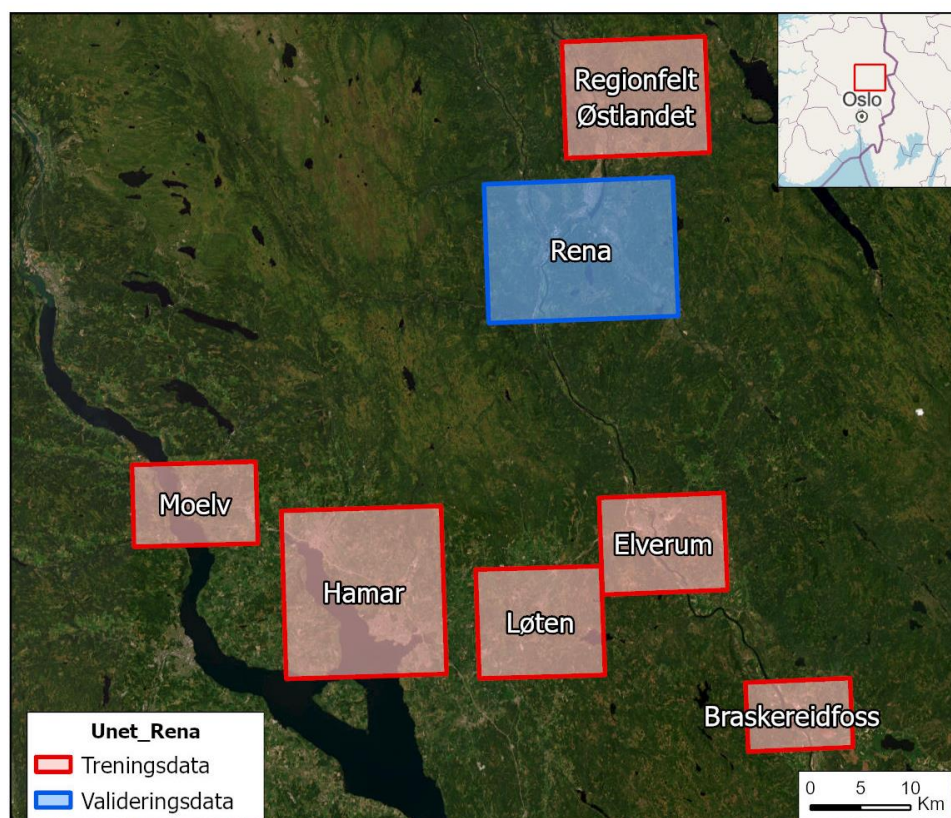
Følgende data ble lastet ned for å trene Unet_Rena:

- Esri LULC over UTM sonen 32V, for 2019, 2020, 2021, og 2022.
- Alle tilgjengelige Sentinel-2 L2A bilder fra tidsrommet 01.01.2019 til 31.12.2022, med skydekke under 10%.

Sentinel-2 bildene ble lastet ned over 7 områder, se Figur 32, i tilknytning Rena på Østlandet. Disse områdene ble lastet inn som treningsdata med unntak av Rena. Fordi modellen hadde som mål å lage et arealdekkkart over Rena ble dette området kun inkludert i valideringsdatasettet. Dette ble gjort for å unngå at modellen overtilpasset til Rena og for å vurdere ytelsen til modellen over et område den ikke har trent på. På denne måten ble det enklere å identifisere om modellen klarte å lære de ulike egenskapene i satellittbildene og gjorde det mulig å identifisere hvilke områder modellen

presterte godt på og ikke. Områdene for treningsdata ble valgt ut for å være representativt for Rena og Østlandet generelt, og inneholdt derfor større skogs- og landbruksområder. Resultatet ble:

- Treningsdatasett med 438 bilder.
- Treningssett med 4496 *chips*.
- Valideringsdatasett med 69 bilder.
- Valideringssett med 1184 *chips*.



Figur 32: Datainnsamling Rena.

Unet_Tokmak

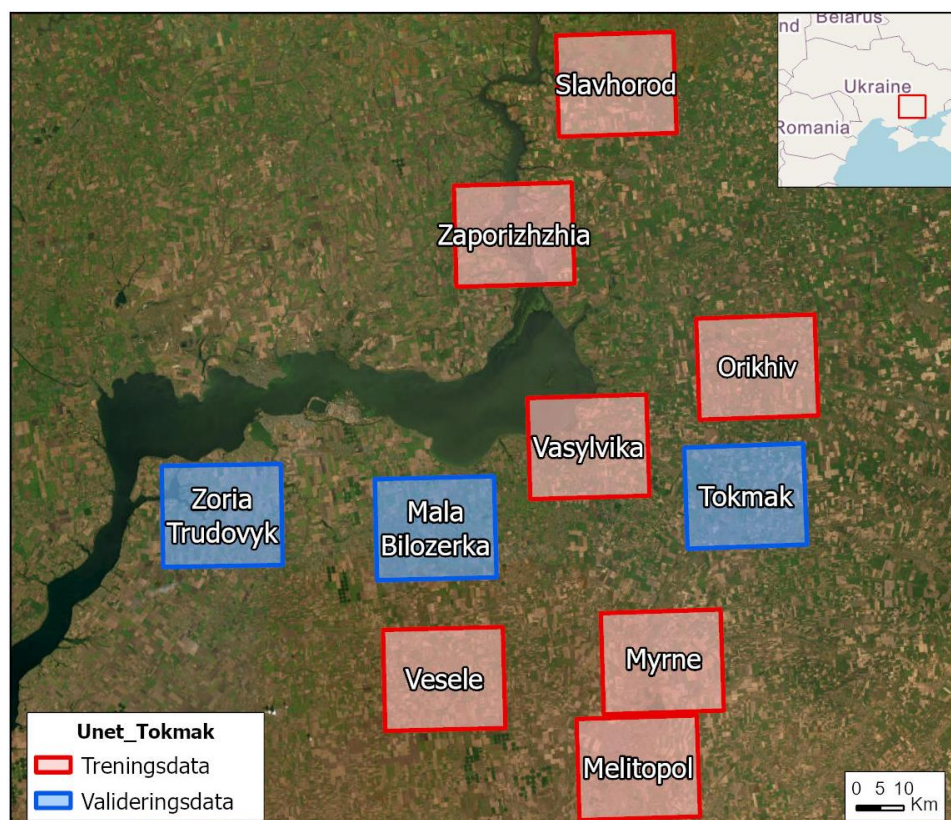
Følgende data ble lastet ned for å trene Unet_Tokmak:

- Esri LULC: UTM sonene 36T og 36U for 2019, 2020, 2021 og 2022.
- Sentinel-2 L2A bilder fra tidsrommet 01.01.2019 til 31.12.2022 med skydekke under 10%.

Sentinel-2 bildene ble lastet inn over 10 områder, hvor områdene Tokmak, Mala Bilozerka og Zoria Trodovoyk ble satt til valideringsdata, se Figur 33. Tokmak var området modellen hadde som mål å segmentere, men dette området inneholdt få forekomster av arealklassene *Water* og *Vegetation*. For å få med flere forekomster av *Water* og *Vegetation* i validerings-datasettet ble det derfor inkludert to

andre områder i tillegg til Tokmak. Områdene som inngikk i treningsdatasettet ble valgt ut for å være representativt for regionen, og var derfor dominert av åpne og urbane områder, men inneholdt også områder med elv og vann.

- Treningsdatasett med 487 bilder.
- Treningssett med 18656 *chips*.
- Valideringsdatasett med 228 bilder.
- Valideringssett med 11088 *chips*.



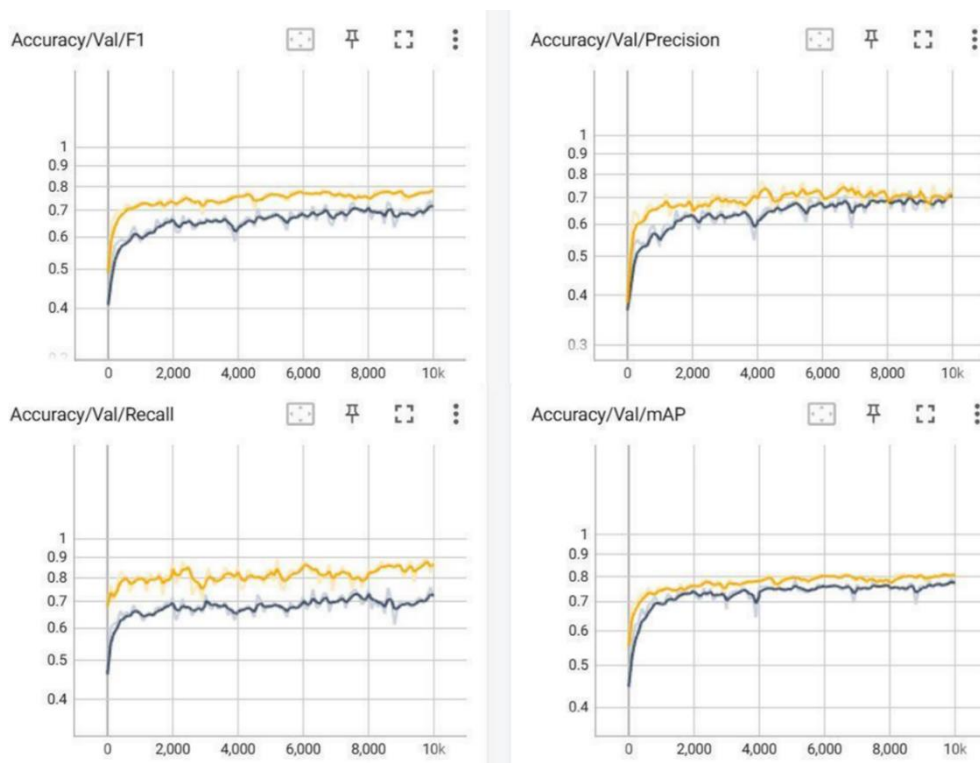
Figur 33: Datainnnsamling Tokmak.

5.1.2 Trening av modell

Modellene ble trent til å selv identifisere hvilken kombinasjon av de multispektrale båndene som ga best prediksjon på arealklassene. Før en ny runde med trening av modellene ble hyperparametere justert basert på hvordan modellen presterte på valideringsdata. Fordi formålet med modellene var å gi best mulig prediksjoner over områdene Rena og Tokmak, ble disse områdene også benyttet til test-data for å vurdere ytelsen til de endelige modellene. Hyperparameterne ble derfor justert basert på verdiene for *mAP*, *precision*, *recall*, *F1 score*, *loss* og forvirringsmatriser.

Hyperparametere

Underveis i treningen ble modellens *mAP*, *precision*, *recall*, *F1 score* og *loss* visualisert ved hjelp av TensorBoard. Dette gjorde det mulig å vurdere effekten av hyperparameterne, og sammenligne hvilke konfigurasjoner som ga best resultat, se Figur 34. Det ble blant annet eksperimentert med 4 og 5 nedsamplinger, *chip_size* på 128x128 og 256x256 piksler, ulikt antall *batch-size* og ulikt antall epoker. Dette resulterte i hyperparameterne oppgitt i Tabell 1.



Figur 34: Eksempel på ytelsen til to modeller under trening.

Hyperparameter	Verdi
Antall nedsamplinger	4
Størrelse på konvolusjonskjerne	3x3
Størrelse på max-pooling kjerner	2x2
Læringsrate	0.001
Batch-size	8
Epoker	20
Optimaliseringsalgoritme	AdamW

Tabell 1: Hyperparametere.

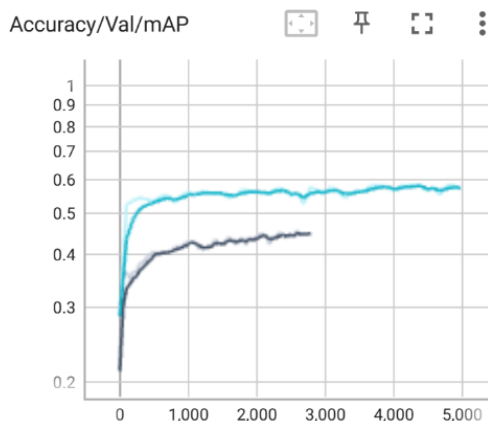
Reklassifisering

For å forenkle arealdekkekartene ble det gjennomført en reklassifisering av arealtypene. Dette førte også til at modellens ytelse økte gjennom å kombinere lignende arealklasser. De opprinnelige klassene fra Esri LULC ble slått sammen til fire klasser, som vist i Tabell 2. I tillegg ble klassene *No Data*, *Clouds* fjernet for å unngå at modellen klassifiserte disse i utdatasettet.

Esri LULC	Ny klasse
Water	Water
Flooded vegetation Trees	Vegetation
Rangeland Crops Bare ground	Open area
Built Area	Built Area

Tabell 2: Reklassifisering av Esri LULC klassene.

Flere av de nedlastede satellittbildene inneholdt områder som var dekket av snø om vinteren. Klassen *Snow/Ice* fra Esri LULC inneholdt kun områder som var dekket av snø hele året. Det var ingen forekomster av denne klassen i forsøksområdene, og *Snow/Ice* ble derfor fjernet. Siden referansedatasettet ikke tok høyde for sesongvariasjoner som snø, må modellen «gjette» på hvilke arealtyper som er under snøen i satellittbildene. Ved å slå sammen klasser hvor snø typisk vil se likt ut vil det være enklere for modellen klassifisere arealtypene under is og snø. Reklassifiseringen førte til en bedring i modellenes ytelse, og er vist i Figur 35. Den mørkeblå grafen i Figur 35 representerer *mAP* før og etter reklassifisering. Disse to modellene hadde like hyperparametere og inndata, men forskjellen var antall klasser.



Figur 35: *mAP* før (mørkeblå) og etter (lyseblå) reklassifisering.


Vekting av klasser

Fordi treningsdatasettene inneholdt ulikt antall forekomster av de forskjellige klassene ble disse tilegnet ulike vekt under trening vist i Tabell 3 og 4. Dette førte til at tapsfunksjonen skalerte tapet basert på denne vekten. For eksempel vil en høyere vekt på *Built up Area* føre til at en riktig eller feil prediksjon av denne klassen vil ha større betydning for hvordan modellen beregner tap og hvordan vektene justeres. På samme måte vil en lavere vektning av klassen *Vegetation* føre til at riktige eller feil prediksjoner vil ha mindre betydning for justering av vektene. Ved å vekte klassene ulikt hindres modellen i å kun fokusere på klassene med størst forekomst da dette ville ført til størst endring i tap.

Treningsdatasettet til Unet_Rena var ubalansert i form av at det inneholdt flere forekomster av *Vegetation* enn de andre klassene, og færrest forekomster av *Built Area*. Fordelingen av arealklassene er vist i Figur 36. Nettverket ble derfor vektet høyest på *Built Area* og lavest på *Vegetation*. Verdiene til vektene, se Tabell 3, ble satt ved å vurdere ytelsen til modellen ved hjelp av forvirringsmatriser.

Water	Vegetation	Open Area	Built Area
0.3	0.2	0.3	1.3

Tabell 3: Vekting av klassene for Unet_Rena.




Figur 36: Fordel klasser for trenings- og valideringsdata Unet_Rena.

Treningsdatasettet til Unet_Tokmak var også ubalansert fordi det inneholdt større mengder *Open area* enn de andre klassene. I tillegg inneholdt datasettet få forekomster av *Vegetation* og *Water*, se Figur 37. Det ble derfor inkludert flere områder som inneholdt mer *Vegetation* og *Water* i både treningsdatasettet og valideringsdatasettet. Denne modellen ble trent videre på de trente vektene fra

Unet_Rena, men klassene ble vektet annerledes fordi dette datasettet hadde en annen sammensetning, se Tabell 4.

Water	Vegetation	Open Area	Built Area
1	1.3	0.4	1

Tabell 4: Vekting av klassene for Unet_Tokmak.

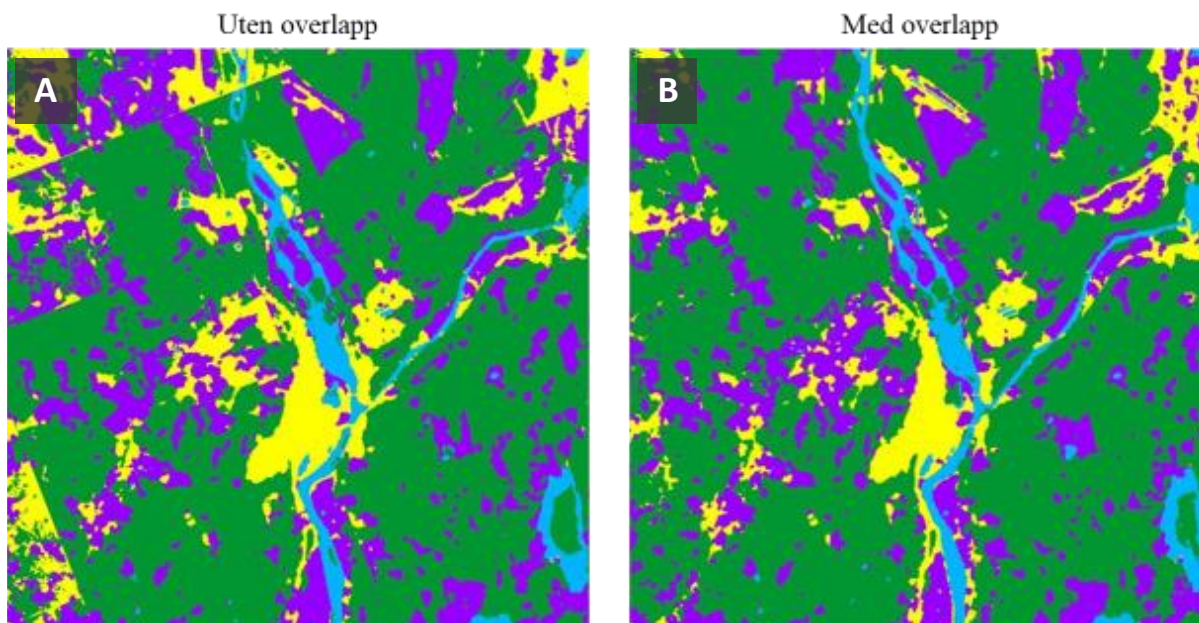


Figur 37: Fordeling klasser for trenings- og valideringsdata Unet_Tokmak.

5.1.3 Segmentering av satellittbilder

Det ble lastet ned Sentinel-2 L2A bilder for 2023 med skydekke under 5% for både Rena og Tokmak. Etter en visuell inspeksjon av bildene ble mest egnede valgt for segmentering.

Satellittbildene ble segmentert med en metode kalt *Sliding Window*, hvor bildet blir segmentert i mindre områder, kalt vinduer, på størrelse lik *chip-size*. Deretter ble vinduet forskjøvet med 32 piksler i totalt 8 steg. Dette gjorde at alle delene av bildene ble klassifisert flere ganger. Dette reduserer muligheten for feilklassifiseringer, og bidro til å unngå skarpe kanter i skillet mellom ulike *chips*, slik vist øverst i del A av Figur 38.



Figur 38: Segmentering av et satellittbilde med og uten overlapp.

5.1.4 Vekting av arealdekke

Det resulterende arealdekkekartet besto av klassene *Water*, *Vegetation*, *Open areas* og *Built area*. Arealdekkekartet ble importert i *ArcGIS Pro* hvor rasterverktøyet *Reclassify* ble brukt for å tilegne klassene en verdi fra null til fem, som kan justeres etter behov.

Vektingene for arealdekke Rena og Tokmak eksemplifiserer hvordan arealklassene kan prioriteres, og denne vektingen vil variere ut ifra operasjonen kartet skal brukes i. Eksempelvis kan vann vurderes til å være av lite interesse sommerstid fordi det da vil være utfordrende å krysse, men av stor interesse vintertid når det er dekket av is og kan benyttes av militære styrker.

Arealdekke_Rena ble vektet med utgangspunkt i at åpne og bebygde områder var av størst interesse, se Tabell 5, og *Arealdekke_Tokmak* med utgangspunkt i at vegetasjon og bebygde områder var av størst interesse, se Tabell 6 og Tabell 4.

Vann	Vegetasjon	Åpne områder	Bebygde områder
1	2	5	5

Tabell 5: Vekting *Arealdekke_Rena*.

Vann	Vegetasjon	Åpne områder	Bebygde områder
1	5	2	5

Tabell 6: Vekting *Arealdekke_Tokmak*.

5.2 Generering av situasjonsbilde

Oppgaven genererte situasjonsbilder over forsøksområdene Rena og Tokmak basert på de 3 utviklede scenarioene. Denne prosessen inkluderte innsamling av data, tilrettelegging og geografiske analyser, illustrert i Figur 39. Dette delkapittelet beskriver først datasettene som ble brukt i analysene, og deretter fremgangsmåten i hvert scenario for begge forsøksområdene.



Figur 39: Arbeidsflyt for generering av situasjonsbilde.

5.2.1 Innsamling av data

Datasettene som ble brukt besto av de utviklede arealdekkekartene, høydedata og etterretninger om fienden. Datasettene ble lastet ned fra åpne kilder, levert av Forsvaret eller egenprodusert.

Datasettene som ble benyttet i analysene er vist i Tabell 7:

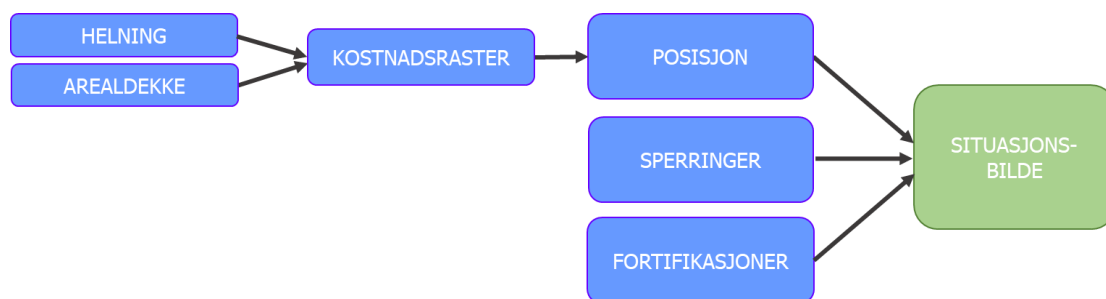
Datasett	Beskrivelse	Kilde	Dato for nedlastning
<i>Arealdekke_Rena</i>	Arealdekke over Rena med en oppløsning på 10m. Datasettet skiller mellom vann, vegetasjon, åpne områder og bebygde områder.	Dyplæring (Kap. 5.1)	
<i>Arealdekke_Tokmak</i>	Arealdekke over Tokmak med en oppløsning på 10m. Datasettet skiller mellom vann, vegetasjon, åpne områder og bebygde områder.	Dyplæring (Kap. 5.1)	
<i>DTM1</i>	Landsdekkende digital terrengmodell med en oppløsning på 1m (<i>Høydedata og dybdedata</i> , 2023).	Hoydedata.no	03.11.2023
<i>World TREx 12m elevation</i>	Digital terrengmodell over Ukraina med en oppløsning på 12m. Datasettet er levert av Forsvaret og merket «Unntatt offentligheten».	Forsvaret	13.11.2023
<i>Fienden_posisjon</i>	Punkter for fiendens posisjon, og inneholder attributter som beskriver gren, avdeling, størrelse og angir en kategori for fremkommelighet.	Egenprodusert	
<i>Sperringer</i>	Polygoner for fiendens sperringer, og inneholder attributter som beskriver type sperring, avdeling og størrelse.	Egenprodusert	
<i>Fortifikasjoner</i>	Polygoner for fiendens fortifikasjoner, og inneholder attributter beskriver type fortifikasjon, avdeling og størrelse.	Egenprodusert	
<i>Hendelseslogg_Rena</i>	Punkter for tidligere hendelser av angrep på militære styrker.	Egenprodusert	
<i>Ukraine Control Map</i>	Punkter for russiske og ukrainske styrker, polygoner for viktige områder, og linjer for frontlinje, dragetennger og fortifikasjoner. Sist oppdatert 13.11.2023.	Project Owl OSINT	13.11.2023

Tabell 7: Innsamlet data til generering av situasjonsbilde.

5.2.2 Tilrettelegging og geografiske analyser

Scenario 1: Krigssituasjon

Situasjonsbildene i *Scenario 1* ble generert ved å bruke geografiske analyser på etterretninger om fienden. Figur 40 illustrerer arbeidsflyten benyttet i de geografiske analysene i *Scenario 1*. Det ble først laget kostnadsrasterer som representerte hvilke områder som var fordelaktig for militære enheter å bevege seg i. Kostnadsrasterne ble laget med verktøyet *Weighted Overlay* basert på en helningsanalyse fra verktøyet *Slope*, og et vektet arealdekkkart. Deretter ble kostnadsrasterne klippet til en buffer rundt fiendens posisjon, og slått sammen med rasterdata som inneholdt fortifikasjoner og sperringer.



Figur 40: Arbeidsflyt for Scenario 1: Krigssituasjon.

Rena

Datsettene *arealdekke_Rena*, *DTM1* (høydedata), *fienden_posisjon*, *sperringer* og *fortifikasjon* ble benyttet i analysene på forsøksområde Rena. Disse inneholdt egenskaper som beskrev avdeling, type sperring, og type fortifikasjon. Videre ble egenskapene vektet basert på hvor en vurdering på hvor viktige disse var, se Tabell 8. Disse vektingene kan endres ut ifra behov.

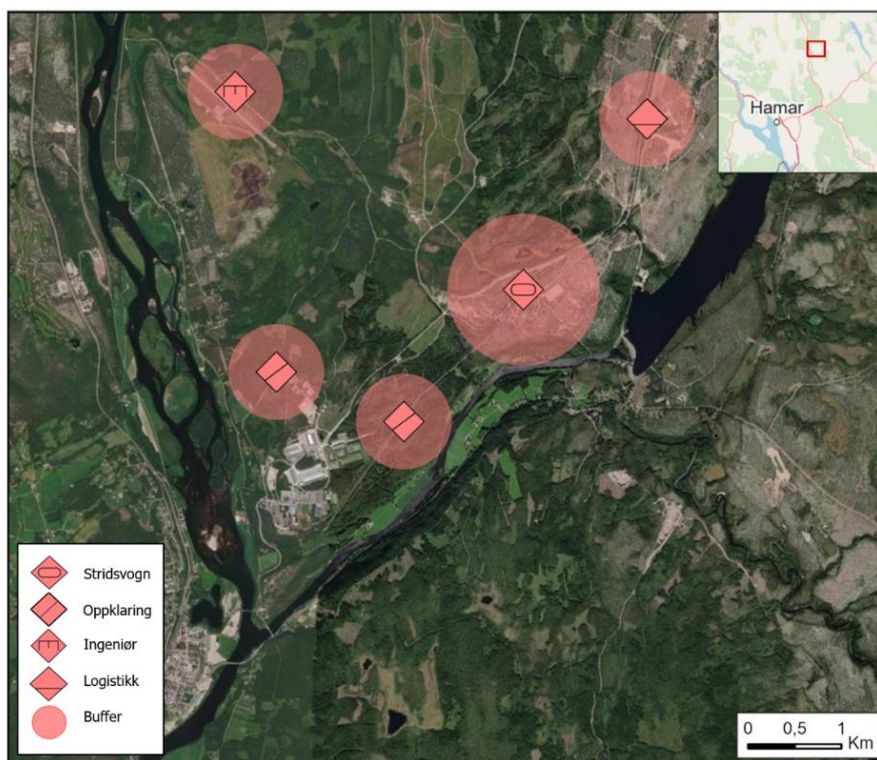
Vekting <i>fienden_posisjon</i>		Vekting <i>Sperringer</i>	
Avdeling	Vekting (1-5)	Type sperring	Vekting (1-5)
Stridsvogn	4	Stridsvogngroft	3
Pansret infanteri	3	Voll	1
Oppklaring	2	Minefelt	5
Artilleri	5	Narreminefelt	5
Ingeniør	5	Piggtråd	1
Samband	5	Forhugning	2
Bombekaster	5		
Ildstøtte	3	Vekting <i>fortifikasjoner</i>	
Panservern	3	Type sperring	Vekting (1-5)
Logistikk	5	Stillingssystem	5
Luftvern	5	Enkelstilling	2
		Bivuakk område	4

Tabell 8: Vekting av datsettene *fiende_posisjon*, *sperringer* og *fortifikasjon*.

Størrelsen på bufferne varierte basert på egenskapen *Avdeling* med utgangspunkt i hvordan de ulike avdelingene normalt opererer, se Tabell 9. En stridsvogn vil for eksempel forflytte seg hurtigere og lengere enn avdelinger til fots, og fikk derfor en større buffer, se Figur 41.

Avdeling	Avstand (m)
Stridsvogn	800
Pansret infanteri	800
Oppklaring	500
Artilleri	1500
Ingeniør	500
Samband	100
Bombekaster	800
Ildstøtte	500
Panservern	500
Logistikk	500
Luftvern	1500

Tabell 9: Avstander på bufferanalysen i Scenario 1 - Rena.




Figur 41: Bufferanalysen i Scenario 1 - Rena.

Kostnadsrasterer ble laget med utgangspunkt i egenskapen *Fremkommelighet* i datasettet *fienden_posisjon*. *Fremkommelighet* ble definert ut ifra hva slags fremkomstmiddel avdelingen benyttet, og er delt inn i *beltegående*, *hjulgåendene* og *fot*, se Tabell 10.

Fremkommelighet	Arealdekke (vektning)	Helning° (vektning)
Beltegående	Vann (1)	0-17 (5)
	Vegetasjon (4)	17-26 (3)
	Åpne områder (5)	<26 (1)
	Bebygde områder (5)	
Hjulgående	Vann (1)	0-17 (5)
	Vegetasjon (2)	17-26 (3)
	Åpne områder (5)	<26 (1)
	Bebygde områder (5)	
Fot	Vann (1)	0-30 (5)
	Vegetasjon (5)	30-45 (3)
	Åpne områder (3)	>45 (1)
	Bebygde områder (2)	

Tabell 10: Vekting av arealdekke og helning i kostnadsrasterer i Senario 1 - Rena.

Figur 42 viser kostnadsrasteret som ble laget for *Avdeling* stridsvogn. Her er de grønne områdene med verdi 5 mest gunstig for en stridsvogn og bevege seg i, og de røde områdene med verdi 1 minst gunstig.



Figur 42: Kostnadsrasteret for stridsvogn i Senario 1 - Rena.

Tokmak

Analysene på forsøksområde Tokmak benyttet arealdekke_Tokmak, høydedata *World TREx 12m Elevation*, og etterretninger fra *Ukraine Control Map*. *Ukraine Control Map* inneholdt russiske posisjoner, sperringer og fortifikasjoner, og ble vektet i henhold til Tabell 11.

Etterretning	Vekting (1-5)
Russiske posisjoner	2
Russiske sperringer	2
Russisk fortifikasjoner	5

Tabell 11: Vekting av russiske posisjoner, sperringer og fortifikasjoner.

Kostnadsrasteret som ble utviklet er vist i Figur 43, og er basert på verdiene fra Tabell 12 som beskriver en antagelse på hvor det ville være fordelaktig for russiske styrker å bevege seg. I kostnadsrasteret vises bebygde områder i grønn farge og representerer den høyeste verdien. På samme måte er områder med vann vist i rødt og representerer de laveste verdiene og minst fordelaktige områdene å bevege seg i. Deretter ble bufferanalysen gjennomført med en buffer på 500m i tilknytning til punktene for russiske posisjoner, se Figur 44.

Arealdekke (vekting)	Helning° (vekting)
Vann (1)	0-17 (5)
Vegetasjon (5)	17-26 (3)
Åpne områder (3)	<26 (1)
Bebygde områder (5)	

Tabell 12: Vekting av arealdekke og helning i kostnadsrasteret på Scenario 1 – Tokmak.



Figur 43: Kostnadsraster Scenario 1 - Tokmak.




Figur 44: Bufferanalyse i Scenario 1 - Tokmak.

Scenario 2: Hendelseslogg

Situasjonsbildene i *Scenario 2* ble utviklet ved å benytte verktøyet *Kernel Density* på datasett som representerer en hendelseslogg. På forsøksområde Rena ble datasettet *Hendelseslogg* benyttet, og på forsøksområde Tokmak ble på russiske geolokasjoner fra 23.10.2022 til 12.11.2023 fra datasettet *Ukraine Control Map* benyttet.

Scenario 3: Søk etter savnet person

Situasjonsbildene i *Scenario 3* ble generert ved å lage en optimal korridor basert på et kostnadsraster. Kostnadsrasterne ble laget med verktøyet *Weighted Overlay* basert på en helningsanalyse fra verktøyet *Slope*, og et vektet arealdekkekart. Deretter ble dette kostnadsrasteret benyttet i verktøyene *Distance Accumulation* og *Corridor* for å lage en optimal korridor. Figur 45 illustrerer arbeidsflyten benyttet i de geografiske analysene i *Scenario 3*.





Figur 45: Arbeidsflyt i Scenario 3.

Kostnadsrasterene, se Figur 46, ble laget i henhold til Tabell 13, og beskriver hva som er mest kostnadseffektivt for en person å bevege seg i til fots på sommerstid. I kostnadsrasterene representerer rød de laveste verdiene, og mørk grønn de høyeste.

Arealdekke (vekting)	Helning ^o (vekting)
Vann (0)	0-10 (5)
Vegetasjon (3)	10-20 (4)
Åpne områder (5)	20-30 (3)
Bebygde områder (5)	30-40 (2)
	>40 (1)

Tabell 13: Vekting av arealdekke og helning i kostnadsrasteret i Scenario 3.

For å identifisere den mest sannsynlige ruten til fots for den savnede personen ble det laget en korridor fra sist posisjon til antatte slutt punkter basert på kostnadsrasteret. I forsøksområdet Rena ble DTM1 og *arealdekke_Rena* benyttet i analysene, og på forsøksområdet Tokmak ble *World TREx 12m elevation* og *arealdekke_Tokmak* benyttet i analysene.



Figur 46: Kostnadsraster i Scenario 3 - Rena (øverst) og Tokmak (nedert).

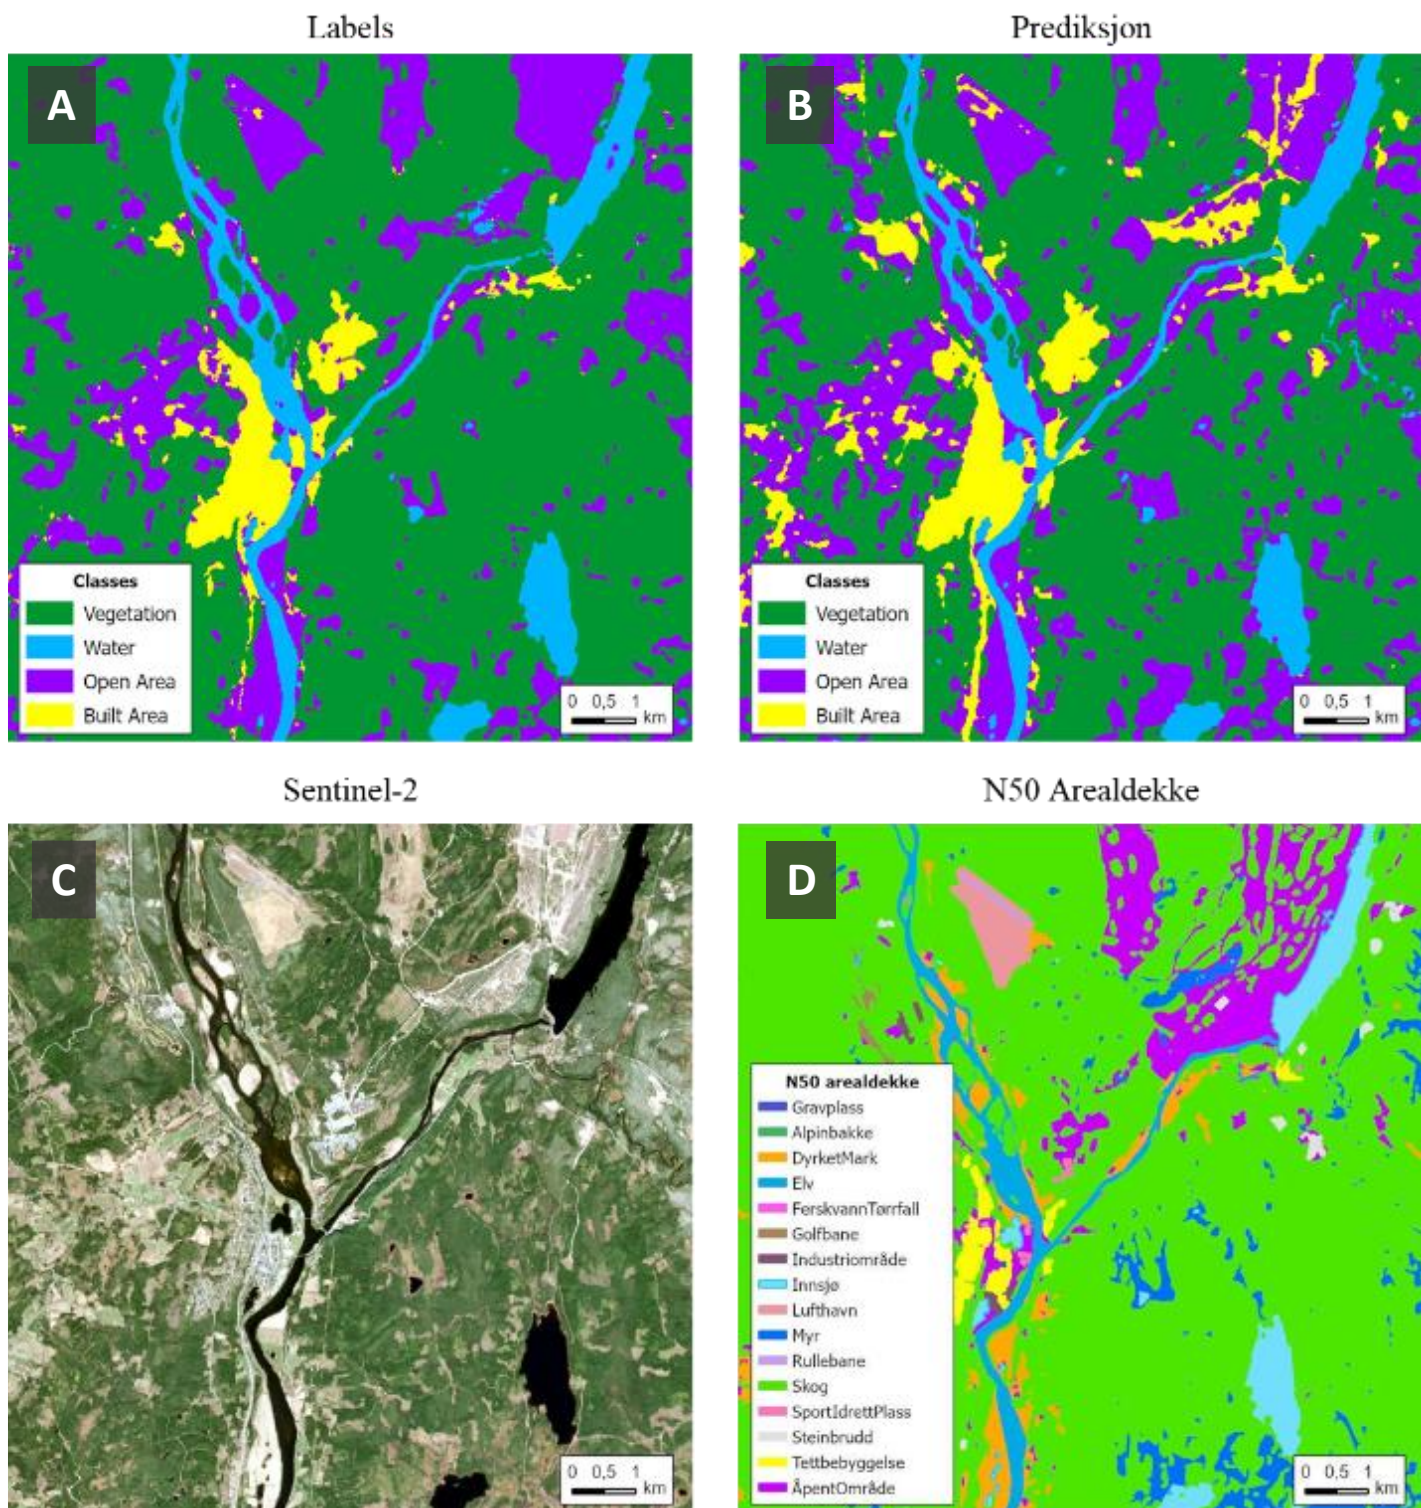
6 Resultater

Dette kapitlet beskriver resultatene fra forsøket. Først vil kapitlet vise eksempler på resultater og verdier for ytelsen til dyplæringsmodellene. Deretter vil det resulterende arealdekkekartet presenteres, og til slutt situasjonsbilder til de ulike scenarioene. Resultatene vil videre bli diskutert i *Kapittel 7*.

6.1 Arealdekke

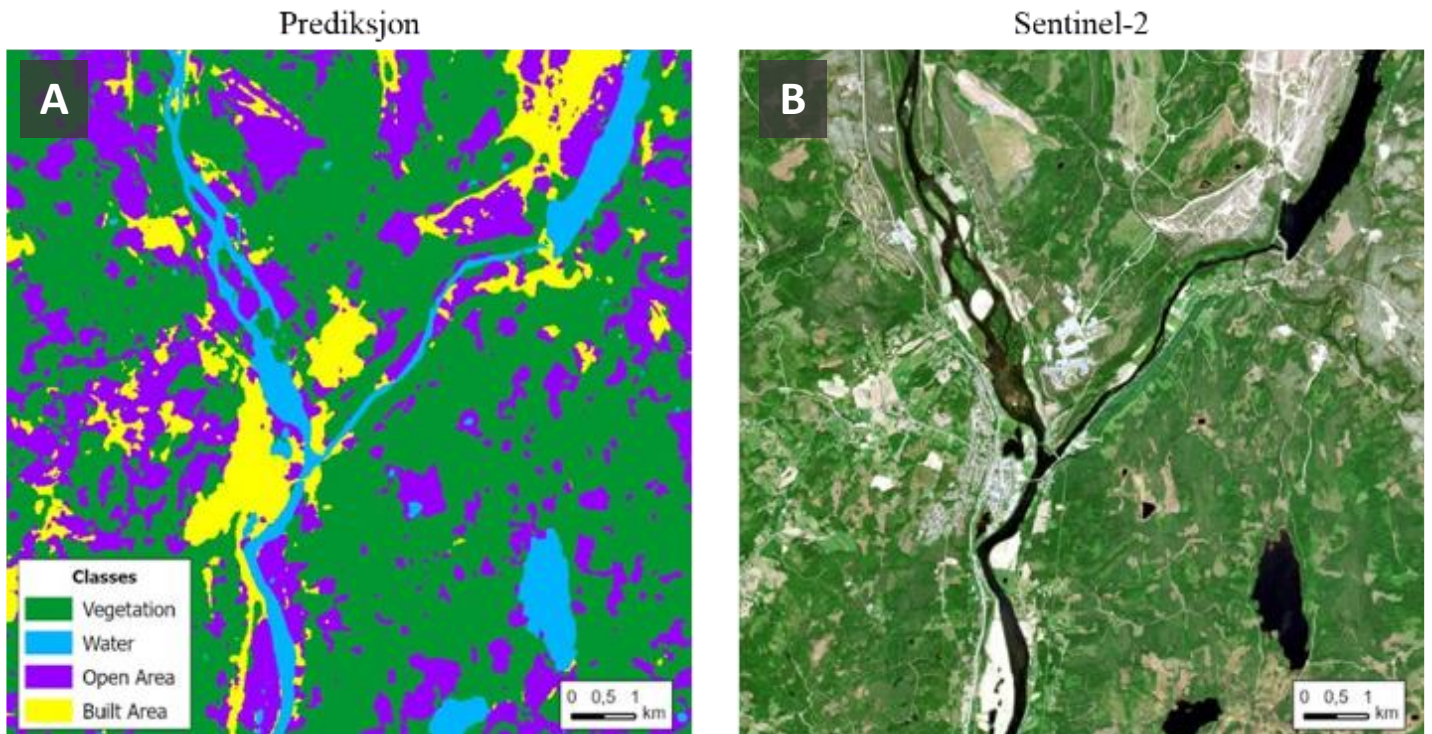
6.1.1 Prediksjoner Unet_Rena

Figur 47 viser referansedata fra Esri LULC (A), et segmentert bilde over Rena fra dyplæringsmodellen Unet_Rena (B), et Sentinel-2 *True colour*-bilde (C), og N50 Arealdekke (D). Esri LULC var fra 2022, og prediksjonen og satellittbildet var fra 17.05.2022. Resultatene viser at modellen klarte i stor grad å klassifisere de ulike klassene riktig. Det segmenterte bilde (B) inneholder fremdeles bebygde områder, som i referansedataen fra Esri LULC (A) er klassifisert som *Open Area* eller *Vegetation*. I tillegg er flere av områdene klassifisert som *Vegetation* i Esri LULC klassifisert som *Open Area* fra Unet_Rena. På samme tid ser det ut til at resultatet fra Unet_Rena har klart å klassifisere *Open Areas* innenfor områdene med *Vegetation* mer nøyaktig enn N50 og Esri LULC.



Figur 47: Labels (A), prediksjoner (B), Sentinel-2 bilde (C) og N50 (D) over Rena.

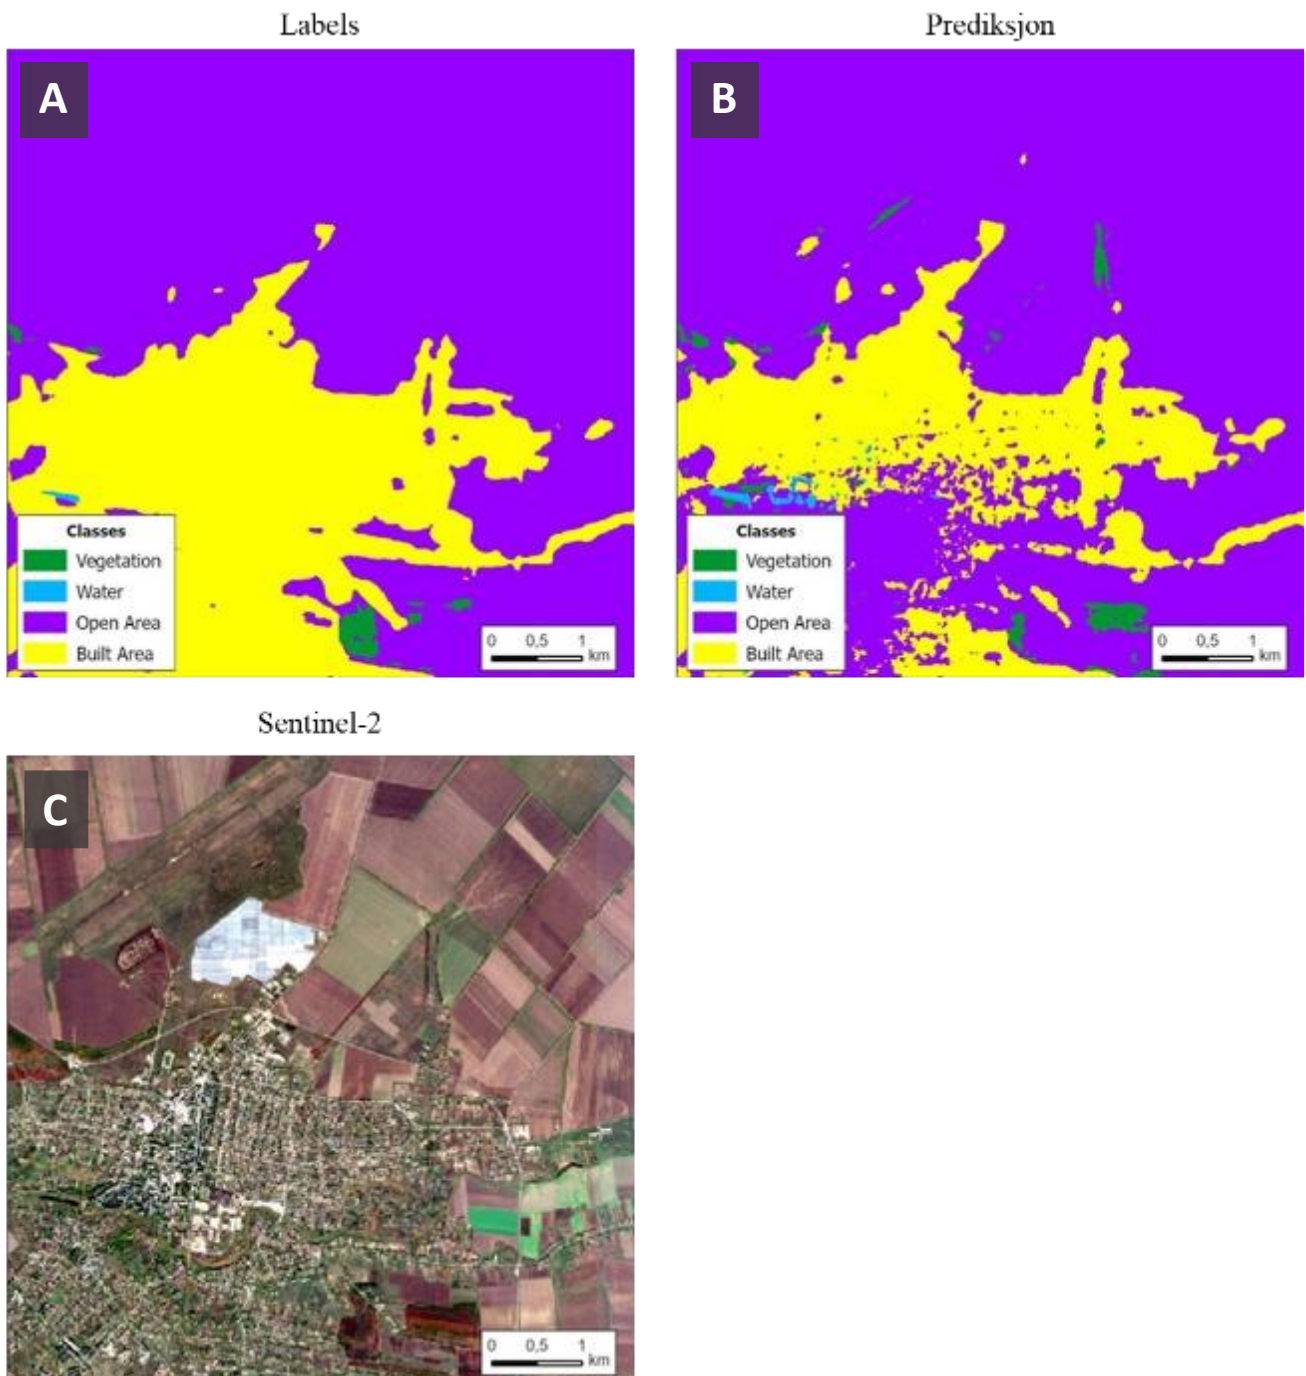
Figur 48 viser et eksempel på et resultat over Rena fra 06.11.2023 (A) sammen med et Sentinel-2 *True colour* bilde fra samme dag (B). Fra denne datoen er det ikke tilgjengelig referansedata fra Esri LULC. I likhet med resultatene vist i Figur 47 ser det ut til at modellen i stor grad klarer å klassifisere arealtypene riktig. I Figur 48 er også flere områder klassifisert som bebygde områder enn i Figur 47.



Figur 48: Prediksjon (A) og Sentinel-2 bilde (B) over Rena.

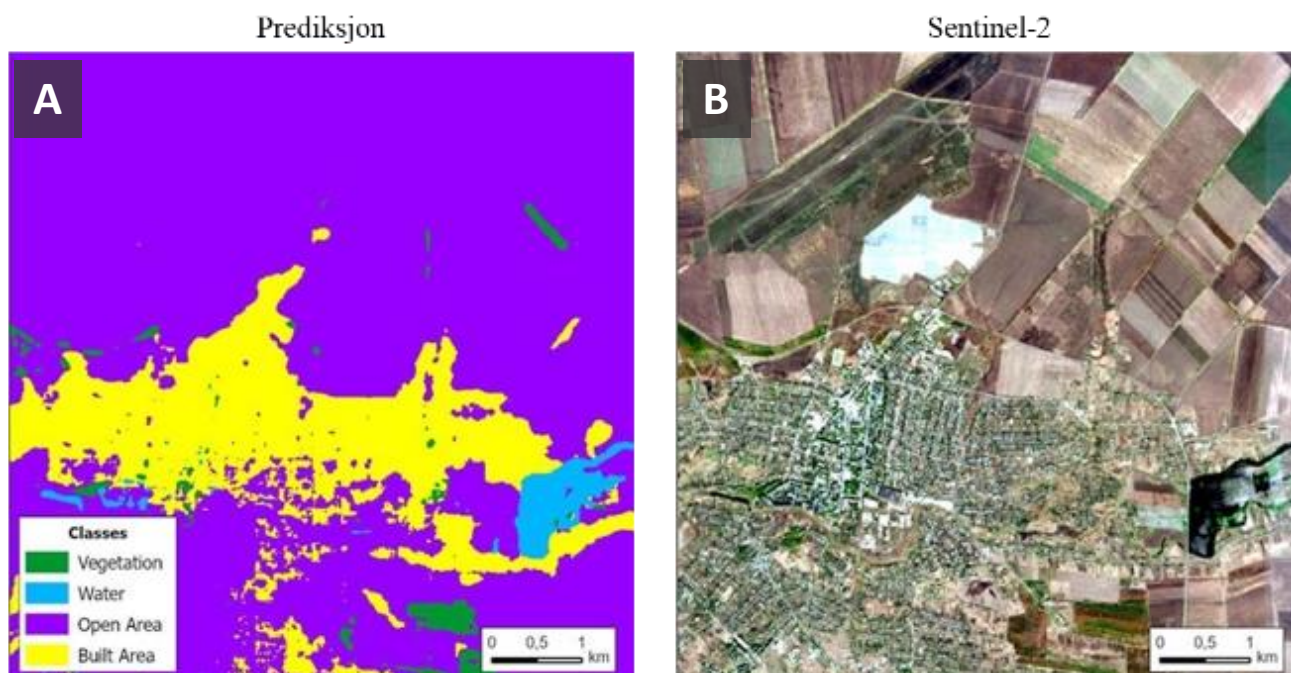
6.1.2 Prediksjoner Unet_Tokmak

Figur 49 viser *labels* over Tokmak fra 2022 (A), sammen med prediksjon (B) og satellittbilde fra 18.10.2022 (C). Ved å sammenligne prediksjonene med referansedatasettet er det tydelig at modellen har klart å identifisere deler av *Built Area*, men har klassifisert flere områder som *Open Area*, *Vegetation* og *Water* som ikke stemmer med referansedataen.



Figur 49: Labels (A), prediksjon fra Unet_Tokmak (B) og Sentinel-2 bilde (C) over Tokmak.

Figur 50 viser et utsnitt med prediksjon over Tokmak fra 18.10.2023 (A) og Sentinel-2 bilde fra samme dag (B). Figur 50 viser i likhet med Figur 49 områder i det som ser ut til å være bykjernen i Tokmak klassifisert som åpent område. I tillegg er det klassifisert en større mengde *Water* øst av bebyggelsen. Det ser også ut til at modellen har klart å identifisere og klassifisere området med *Vegetation* nede til høyre i bildet.



Figur 50: Prediksjon over Tokmak (A) og Sentinel-2 bilde (B).


6.1.3 Klassifikasjonsriktighet

Tabell 14 viser gjennomsnittlig *mAP F1 score*, *Recall* og *Precision* for hele testsettet for både Unet_Rena og Unet_Tokmak. *mAP* angir den gjennomsnittlige presisjonen for alle klassene, og resultater på 0.87 og 0.82 angir at modellene har høy gjennomsnittlig klassifikasjonsriktighet. *F1* kombinerer *precision* og *recall*, og resultatene viser at Unet_Rena har en høy *F1* score på 0.81. *Recall* representerer andelen sanne positive resultater, og viser at Unet_Tokmak identifiserte flest sanne positive tilfeller. På samme tid har Unet_Tokmak en lavere *F1* og *precisionscore*, noe som indikerer at modellen gjør enkelte feil-klassifiseringer. *Precision* angir andelens klassifiseringer som faktisk er korrekte. Resultatene viser at Unet_Rena har en høyere *precision* enn Unet_Tokmak.

	<i>mAP</i>	<i>F1</i>	<i>Recall</i>	<i>Precision</i>
Unet_Rena	0.87554	0.81204	0.86708	0.76357
Unet_Tokmak	0.82642	0.78986	0.90884	0.69843


Tabell 14: Ytelse for Unet_Rena og Unet_Tokmak.

Figur 51 viser forvirringsmatrisen for Unet_Rena. Ut ifra denne matrisen kan en se at modellen har oppnådd størst klassifikasjonsriktighet ved prediksjon av *Vegetation* med 90% riktige klassifiseringer, deretter *Built Area* med 88% og til slutt *Water* og *Open Area* med 85% og 84%. Av feilklassifiseringer ble 6% av *Built Area* klassifisert som *Open Area*, og 8.6% av *Open Areas* klassifisert som *Built Area* og *Water*. Disse verdiene representerte kun modellens klassifikasjonsriktighet sett opp mot referansedatasettet, og vil ikke kunne si noe om hvor nøyaktig modellen er sett i forhold til virkeligheten.



Figur 51: Forvirringsmatrise Unet_Rena.

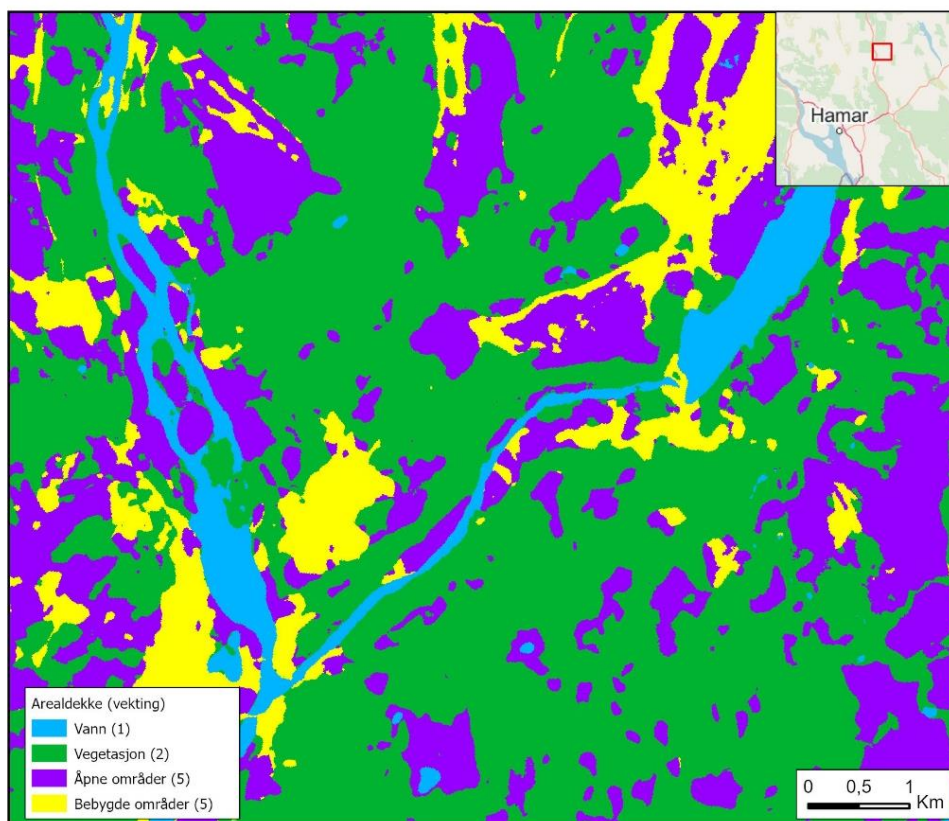
Forvirringsmatrisen for Unet_Tokmak, se Figur 52, viser at modellen har en klassifikasjonsriktighet på 77% på *Water*, 67% på *Vegetation*, 98% på *Open Areas* og 88% på *Built Area*. 30% av *Vegetation* og 10% av *Built Area* ble feilklassifisert som *Open Area*.



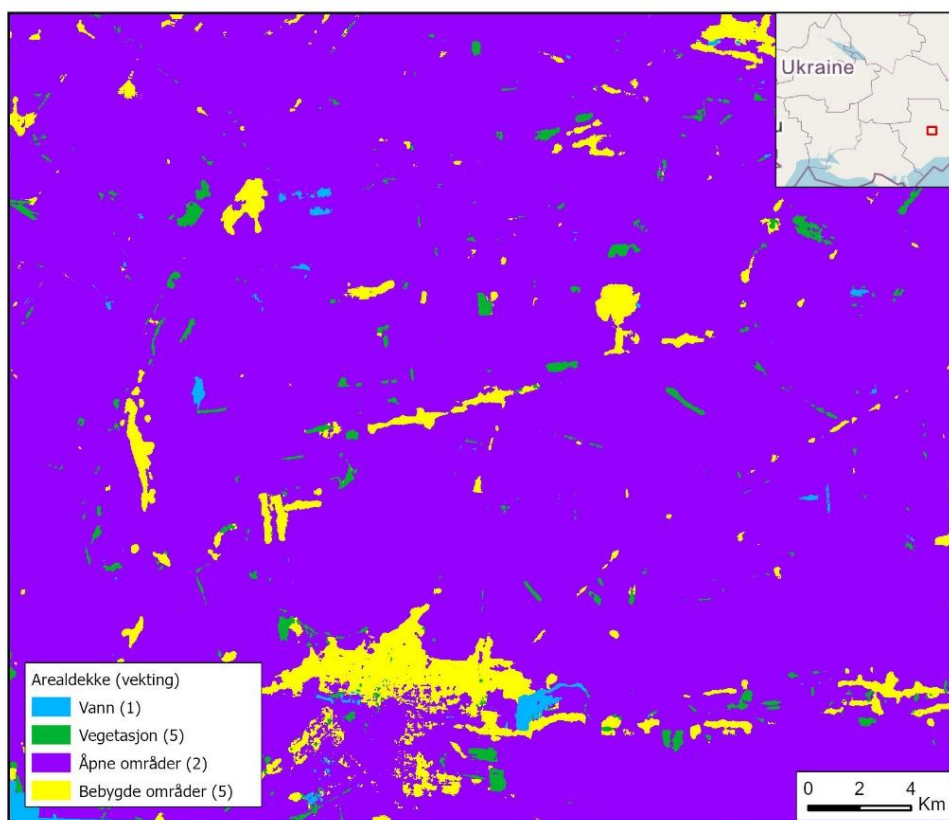
Figur 52: Forvirringsmatrise Unet_Tokmak.

6.1.4 Segmentert arealdekkekart

Resultatet fra dyplæringsmodellene ble to arealdekkekart. Et over Rena, se Figur 53, og et over Tokmak, se Figur 54. Verdiene i rasterkartene er vektet med verdier fra 1 til 5, basert på hvilke områder som ble ansett som av interesse. Dette gjør det mulig å skille på hvilke arealtyper en dronesverm skal søke i, og hvilke arealtyper den skal søke i først, for å effektivisere søk med dronesverm.



Figur 53: Arealdekkkart over Rena.




Figur 54: Arealdekkkart over Tokmak.

6.2 Situasjonbilder

Resultatet av analysene ble ulike rasterlag som representerte situasjonbilder basert på de ulike scenarioene. Områdene i rasterlagene inneholder verdier mellom 1 og 5. I resultatene representerer verdien 5 områdene med høyest prioritet, og er symbolisert med mørkest farge. På samme måte er områdene med lavest prioritet symbolisert med lys farge. Disse situasjonbildene inneholder kun informasjon i områder som er av interesse å søke i.

6.2.1 Scenario 1

Situasjonbildene som ble generert i *Scenario 1* viser områder av interesse basert på etterretninger om fienden. Figur 55 viser situasjonbildet for *Scenario 1 - Rena*. Resultatet viser at områdene med høyest prioritert er de rapporterte ingeniør- og logistikkstyrkene i nord, samt fiendens fortifikasjoner og stridsvognsgrøfter (5). Deretter områder vurdert som mest fordelaktig for stridsvognen å operere i (5), og områder som ble vurdert som mindre fordelaktig for stridsvognen å operere i (4). Videre ble fiendens minefelt og områder vurdert som mest fordelaktig for oppklaringsstyrkene å bevege seg i (3). Til slutt ble områdene vurdert som mindre fordelaktig for oppklaringsstyrkene å bevege seg i vektet lavest (2).



Figur 55: Situasjonbildet Scenario 1 - Rena.


Figur 56 viser situasjonsbilde for Scenario 1 - Tokmak. Resultatet viser at de fiendtlige fortifikasjonene er høyest prioritert (5), deretter de fiendtlige posisjonene og dragetennene (2).




Figur 56: Situasjonsbilde Scenario 1 – Tokmak.

6.2.2 Scenario 2

Resultatene fra *Scenario 2* viser prioriterte områder basert på hvor det er høy tetthet av punkter. Figur 57 viser *Scenario 2 – Rena* hvor tre områder er identifisert som interessante, og området i øst peker seg ut som viktigst. Figur 58 viser situasjonsbilde i Tokmak hvor det også ble identifisert tre områder av interesse. I situasjonsbildet over Tokmak er det et stort område i nordøst som fremstår som det viktigste. Disse resultatene viser at store områder anses som mindre viktige, og dermed reduserer søkeområdene.



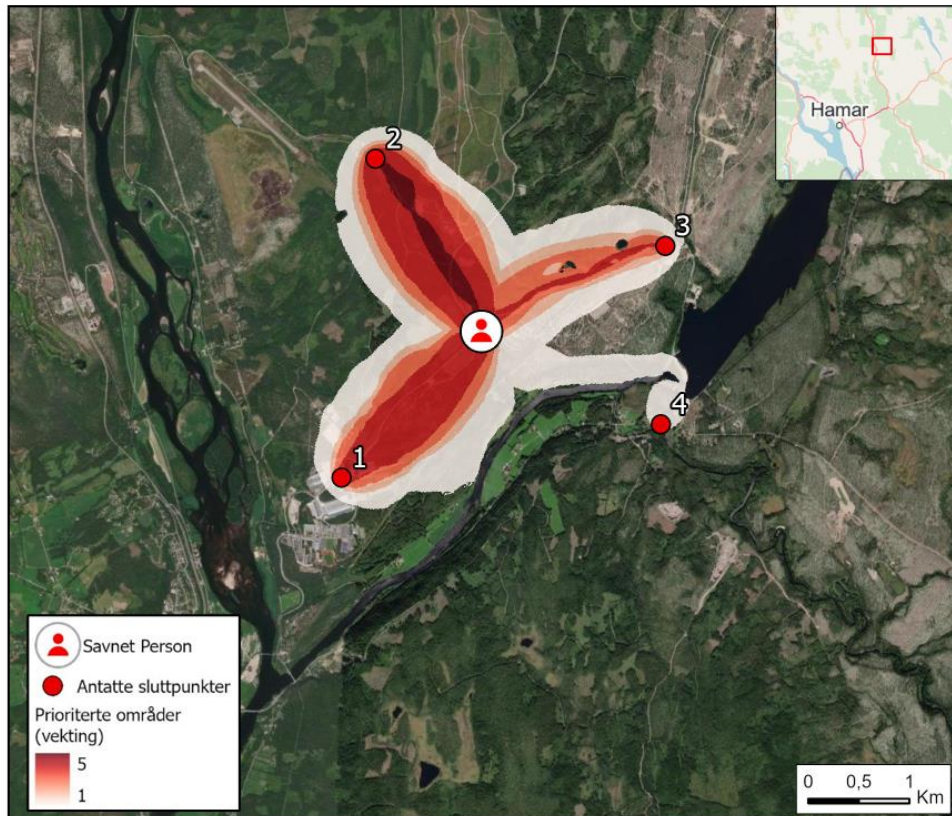
Figur 57: Situasjonsbilde Scenario 2 - Rena.



Figur 58: Situasjonsbilde Scenario 2 – Tokmak.


6.2.3 Scenario 3

Situasjonsbildene fra *Scenario 3* viser de mest kostnadseffektive korridorene fra punktet hvor den savnede personen sist ble observert til fire ulike antatte sluttpunkter. Figur 59 viser situasjonsbildet på Rena og viser at korridoren til punkt 2 er mest kostnadseffektiv å gå i, og dermed av høyest prioritet. Deretter korridorene til punkt 1 og 3. Korridoren til punkt 3 snevrer inn området i større grad enn til punkt 1. Til slutt ble det identifisert at korridoren til punkt 4 var den minst kostnadseffektive, og dermed minst sannsynlig.



Figur 59: Situasjonsbilde Scenario 3 - Rena.

Figur 60 viser situasjonsbildet over Tokmak og viser at de mest interessante områdene ble identifisert som korridorene til punkt 2 og punkt 4. Deretter korridorene til 3, og til slutt punkt 1. I likhet med Figur 59 klarer analysen i Figur 60 å identifisere områder av høyere prioritet, og på den måten snevrer inn og effektiviserer søket.



Figur 60: Situasjonsbilde Scenario 3 – Tokmak.

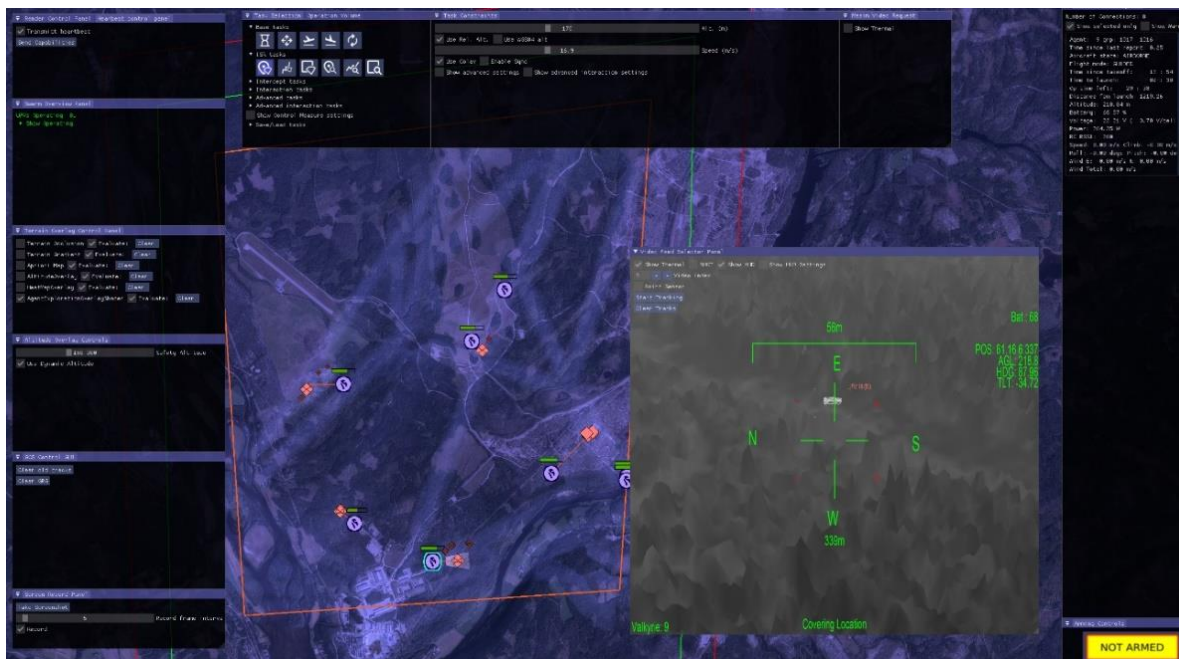
6.3 Simulatortest ved FFI

Situasjonsbildet for *Scenario 1 - Rena* og arealdekkekartet over Rena ble testet i en simulator ved FFI. Situasjonsbildet ble kun testet i kombinasjon med det eksisterende kartgrunnlaget. Arealdekkekartet ble testet uten kombinasjon med andre kartgrunnlag.

Testene av situasjonsbildet viste at det utviklede kartgrunnlaget bidro til å effektivisere søket med dronesvermen. Uten situasjonsbildet søkte dronesvermen først i nærområdene ved Rena leir, og deretter tilfeldig rundt i området. Dronesvermen fant fiendens oppklaringstropper fordi det var i nærhet av Rena leir, men ikke resten av fiendens styrker. Ved å benytte situasjonsbildet fant dronesvermen alle enhetene raskere fordi søket ble mer rettet mot prioriterte områder.

Testene av arealdekkekartet viste at muligheten til å skille ut vann var veldig nyttig. På det eksisterende kartgrunnlaget ble elven Glomma tolket som et åpent område, men med arealdekkekartet ble elven sett på som mindre interessant. Dette reduserte derfor områdene dronene måtte avspøke. Siden åpne og bebygde områder var vektet høyere enn vegetasjon i arealdekkekartet

var det vanskeligere for dronene å identifisere militære enheter i skogen, fordi dronene prioriterte åpne og bebygde områder. Figur 61 viser et utklipp fra simulatoren hos FFI, hvor dronesvermen hadde funnet alle de fiendtlige posisjonene og overvåket disse.



Figur 61: Skjermtklipp fra test i simulator hos FFI.

7 Diskusjon og drøfting

Dette kapitlet vil først diskutere resultatene fra dyplæringsmodellene og de utviklede situasjonsbildene. Deretter diskuteres testen som ble gjennomført i simulator ved FFI. Videre vil datagrunnlaget og analysene for oppgaven diskuteres, og avslutningsvis hvordan arbeidsflyten kan gjennomføres på andre geografiske områder.

7.1 Resultater

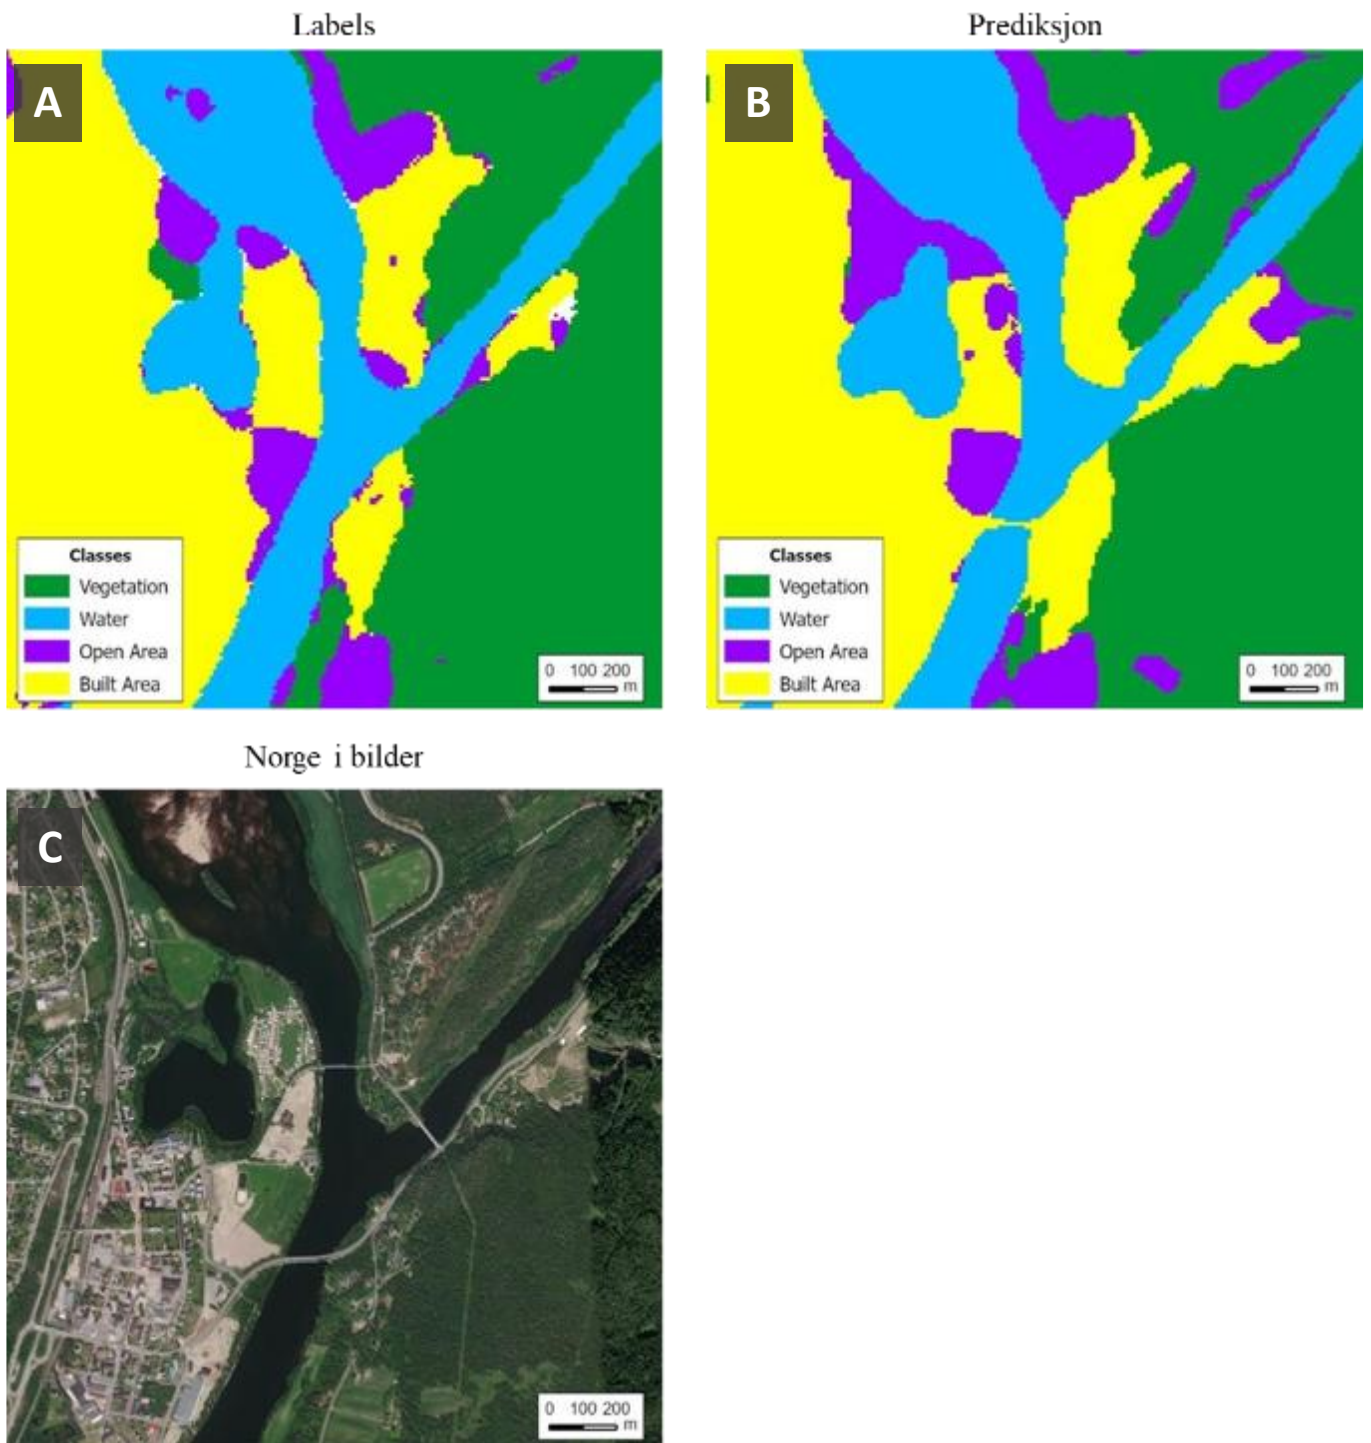
7.1.1 Unet_Rena

Figur 62 viser et utsnitt fra Figur 47 hvor det sammenlignes resultater fra 17.05.2022 fra Unet_Rena (B) med Esri LULC (A) og flyfoto fra *Norge i bilder* fra 19.06.2022 (C). Flyfotoet fra Norge i bilder har en romlig oppløsning på 10 cm, noe som gjør det enklere å visuelt sammenligne prediksjonene enn ved Sentinel-2 bilder som har en romlig oppløsning på 10m.

Resultatene fra Figur 62 viser at modellens prediksjoner stemmer godt med referansedata fra Esri LULC, spesielt for klassene *Vegetation* og *Water*. Dette kommer også frem av modellens *mAP* og *F1 score*, som var på 87% og 81%, som vurderes til et godt resultat sett i forhold til at Esri LULC hadde en gjennomsnittlig nøyaktighet på 85% for 2022 (Karra et al., 2021). Dersom klassifikasjonsriktigheten hadde vært nærmere 100% ville dette sannsynligvis ført til at modellen hadde lært seg unøyaktighetene fra Esri LULC og dette kunne ha svekket nøyaktigheten til klassifiseringen.

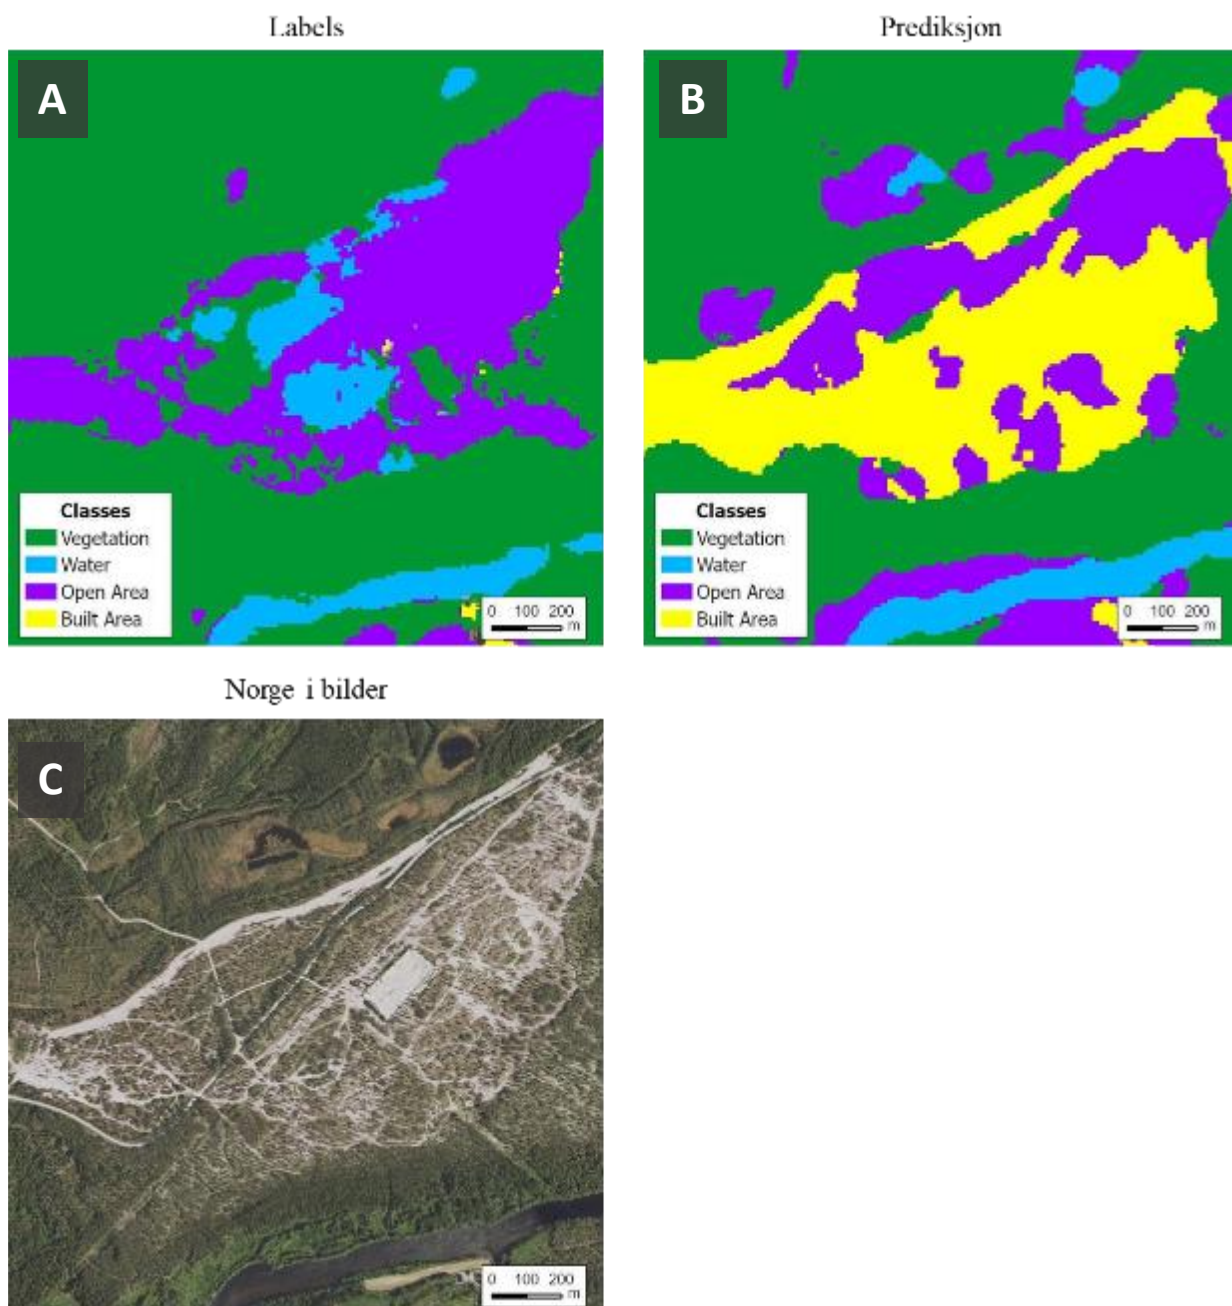
I tillegg har modellen klart å klassifisere områder som er feil-klassifisert i Esri LULC. Et eksempel på dette er den største av de tre broene i området. I Esri LULC er denne klassifisert som *Water*, mens modellen har klassifisert denne som *Built Area*. En slik «feil-klassifisering» vil svekke klassifiseringsriktigheten til modellen fordi modellen måler opp mot referansedataen fra Esri LULC. Denne feil-klassifiseringen vil imidlertid gi et mer representativt bilde av virkeligheten, og vil i denne sammenhengen gi mer nøyaktig informasjon til arealdekkkartet. En bro kan eksempelvis være omringet av områder med vann som kan vurderes til å være av lite interesse. Dette gjør at en slik klassifisering kan være viktig for å identifisere et område av interesse blant områder som ellers er av liten interesse. Dette eksempelet viser også potensialet til en tilpasset modell har til å

identifisere områder som ikke finnes i det eksisterende kartgrunnlaget. Dette indikerer også at modellen har blitt vellykket trent og tilpasset for det spesifikke området.



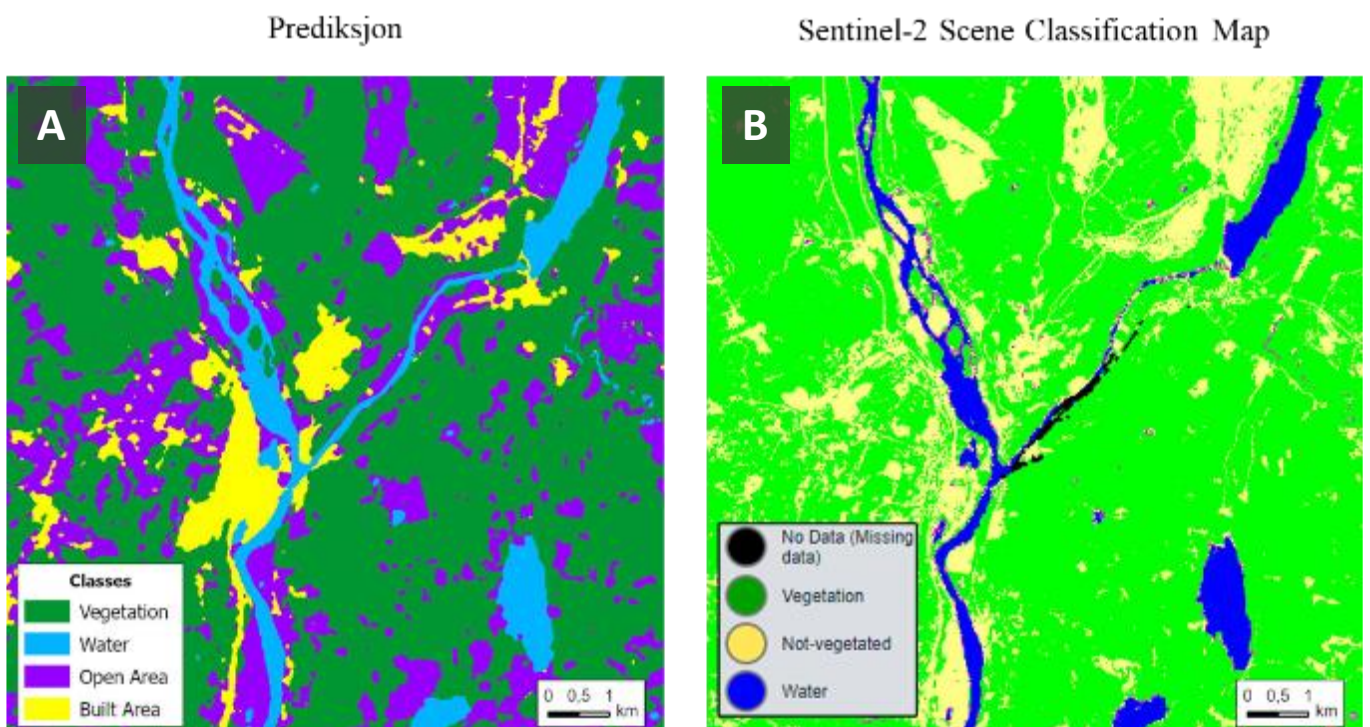
Figur 62: labels (A), prediksjon fra Unet_Rena (B) og Norge i bilder (C).

Figur 63 viser utsnitt av Figur 47 (A-B) sammen med flyfoto fra 19.06.2022 (C). I dette område har modellen feil-klassifisert områder med *Open Area* og *Water* som *Open Area* og *Built Area*. Slike feil-klassifiseringer kan også ses gjennom modellens *precision*- og *recall*-verdier på 86% og 76%. En høy *recall* verdi indikerer at modellen klassifisert en stor en høy andel sanne positive, men den litt lavere *precision* verdien indikerer at modellen samtidig feil-klassifiserte en del piksler. Samtidig kan det se ut fra flyfotoet at disse feil-klassifiserte områdene hadde lignende egenskaper som bebygde områder. En slik feil-klassifisering kan derfor skyldes unøyaktigheter i Esri LULC, og kan gi mer representativ informasjon om terrenget.



Figur 63: Labels (A), prediksjon fra Unet_Rena (B) og Norge i bilder (C).

For å vurdere resultatene fra Unet_Rena kan disse sammenlignes med resultater fra eksisterende lignende verktøy som The European Space Agency sin *Sentinel-2 Scene Classification*. *Sentinel-2 Scene Classification* er en algoritme som klassifiserer piksler inn i ulike klasser for skyer, skygger, vegetasjon, områder uten vegetasjon, vann og snø (European Space Agency - ESA, u.å.). Figur 64 viser resultatet fra Unet_Rena fra 17.05.2022 (A) sammen med *Sentinel-2 Scene Classification Map* fra samme dato (B). En slik algoritme som *Sentinel-2 Scene Classification* vil kunne gi oversikt over områder med vann, vegetasjon og ikke-vegetasjon. Den vil derimot ikke inkludere bebygde områder, slik Unet_Rena kan. Dette gjør at Unet_Rena i større grad kan prioritere ulike områder og hvor klassene kan tilpasses til operasjonelle behov.

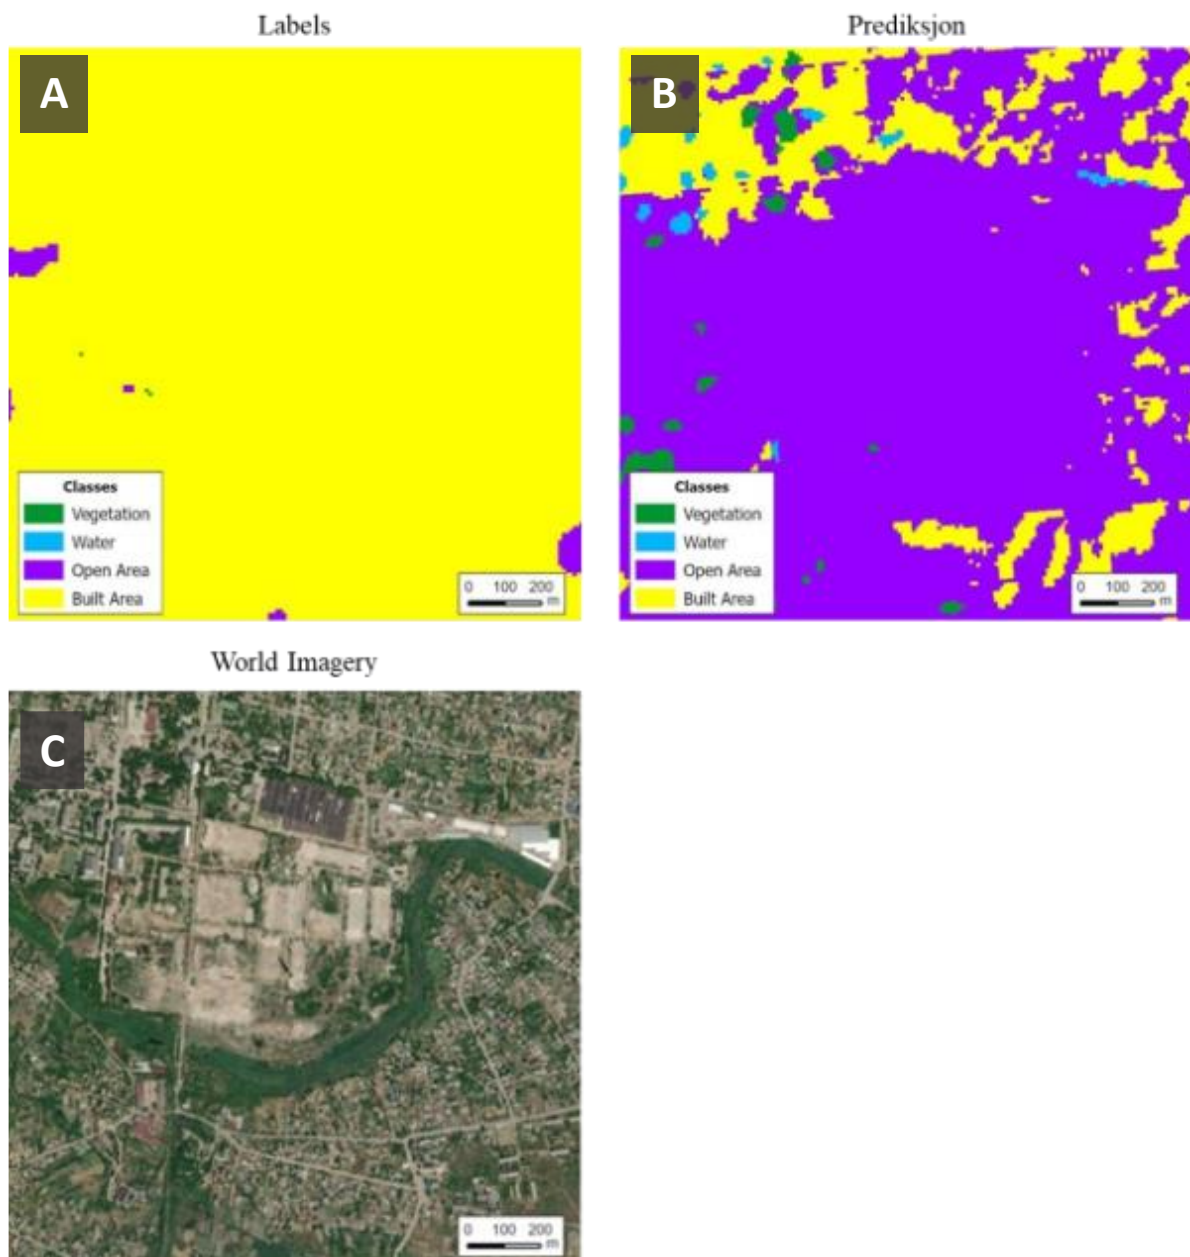


Figur 64: Prediksjon fra Unet_Rena (A) og Sentinel-2 Scene Classification Map (B).

7.1.2 Unet_Tokmak

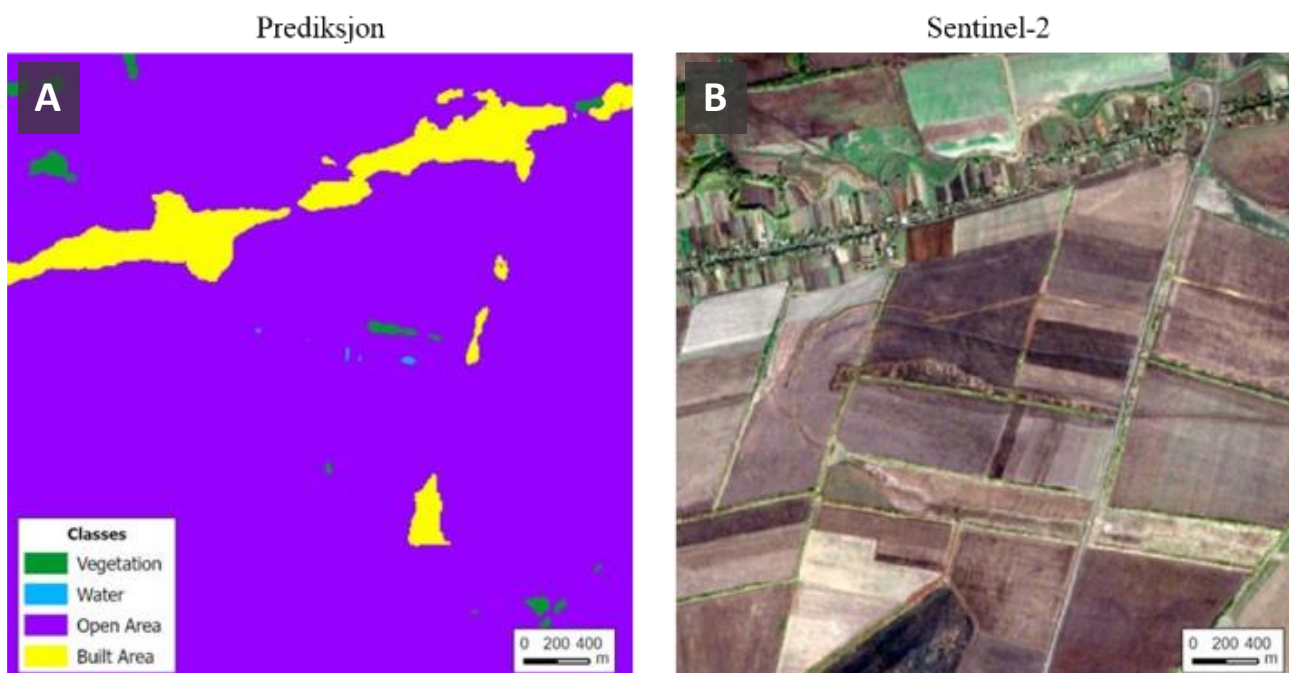
Som presentert i Figur 49 ble en stor del av det urbane området i Tokmak klassifisert som åpent område. I Figur 65 er *labels* (A) og prediksjon (B) fra Figur 49 satt sammen med et World Imagery bilde fra Esri fra 20.06.2022 (C). Ut ifra referansedatasettet skal enkelte områder som skal være *Built Area* klassifisert som *Open Area*. Satellittbildet viser samme område som ser ut til å være tidligere bebyggelse, eller åpne områder med grus og jord. Selv om disse områdene er feil-klassifiseringer sett opp mot referansedatasettet vil klassen *Open Area* stemme bedre overens med virkeligheten. Dette kan forklare den noe lavere *F1* og *precision* score som Unet_Tokmak hadde, og feilklassifiseringene vist i forvirringsmatrisen i Figur 52.

I tillegg ser en fra satellittbildet (C) det som ser ut til å være en elv med vegetasjon rundt, som også har blitt klassifisert som *Open Area*. Dette kan forklares av at modellen har lavest klassifiseringsriktighet på klassene *Vegetation* og *Water*. I disse resultatene ser det ut til at modellens klassifiseringer er mer nøyaktig enn referansedataen fra Esri LULC, selv om disse også har noen begrensninger. Dette belyser også viktigheten av å ha et aktuelt referansedatasett.



Figur 65: Labels (A), prediksjon fra Unet_Tokmak (B) og World Imagery (C).


Figur 65 viser at modellen har klart å identifisere og klassifisere bebygde områder, og deler av veiaksen som *Built Area* (A). Området rundt Tokmak er dominert av åpne områder, og derfor vil de bebygde områdene kunne gi viktig informasjon til kartgrunnlaget. På samme tid ville det vært fordelaktig om hele veien hadde vært klassifisert som *Built Area* eller som en egen klasse. Esri LULC inneholder ikke mindre veiakser fordi disse er klassifisert som arealtypene rundt. Modellen lærer derfor ikke å klassifisere veiakser. For å øke nytteverdien av modellen bør modellene videreutvikles slik at de i større grad klarer å klassifisere veiakser. En måte å løse dette på kunne vært å inkludere et datasett med veier i treningsdatasettet slik at modellen blir i stand til å lære å gjenkjenne denne arealtypen.




Figur 66: Prediksjon fra Unet_Tokmak (A) og Sentinel-2 bilde fra 18.10.2023 (B).

Figur 66 viser et utsnitt med prediksjon (A), sentinel-2 *true colour*-bilde (B) og Sentinel-2 *Moisture index* (C). På figuren vises store områder som ble klassifisert som *Water*. De mørke områdene på True Colour utsnittet, og de blå områdene på *Moisture Index*-utsnittet representerer vann eller fuktighet. Ved å sammenligne utsnittene kommer det tydelig frem at området i virkeligheten inneholdt store mengder vann i oktober 2023. I juni 2023 omtale Bellingcat det som så ut på satellittbilder til å være en russisk-forårsaket flom i Tokmak i forbindelse med en russisk motoffensiv (Sheldon, 2023). Dette kan forklare de store forekomstene av vann i satellittbildene. Slik informasjon kan være verdifull innen planlegging og gjennomføring av militære operasjoner. I dette eksempelet har dyplæringsmodellen klart å lage et arealdekkekart med høy aktualitet, hvor den har klart å identifisere en topografisk endring.


Prediksjon



Sentinel-2 True Colour



Sentinel-2 Moisture Index



Figur 67: Prediksjon (A), Sentinel-2 True Colour (B) og Moisture Index fra 18.10.2023 (C).

Et alternativ for å øke kvaliteten på arealdekkekartet ville vært å benytte mer detaljerte vektordata som FKB i kombinasjon med de segmenterte satellittbildene for å bidra til et større detaljnivå på analysene. Dette gjelder også i utlandet i områder det er mulig å få tak i data av høyere oppløsning. På denne måten kunne det for eksempel vært mulig å inkludere veier uten å trene modellen til å klassifisere det. På samme tid vil en være avhengig av at datasettet en skal bruke er av høy aktualitet og troverdighet. For eksempel ved en flom, eller områder preget av krig kan store endringer ha skjedd slik at tilgjengelig vektordata ikke er oppdatert.

7.1.3 Situasjonbilder

De utviklede situasjonbildene, vist i Figur 55 til 60, inneholder kun informasjon over de prioriterte områdene slik at områder som anses som mindre viktige inneholder ingen data. Dette gjør at situasjonbildene må benyttes i kombinasjon med andre kartgrunnlag. Dersom situasjonbildet kombineres med arealdekkekartet kan en velge hvilke arealtyper som er av interesse på ruten til de prioriterte områdene. For eksempel ved å vekte skog høyere enn åpne områder dersom en anser disse områdene som interessante. Selv om det ville vært mulig å kombinere arealdekkekartet og situasjonskartet til ett rasterlag, ble det besluttet å lage to forskjellige rasterlag. Dette ble gjort fordi *Valkyrie* hadde mulighet til å benytte to kartgrunnlag sammen og for å enklere kunne skille mellom informasjonen i lagene.

Siden situasjonbildene ikke inneholder informasjon om arealtype, kan ikke dronene justere søket til arealtype. For eksempel hvis en drone skal søke i områder med vegetasjon kan det være fordelaktig å fly lavere enn dersom dronen skal søke over åpne områder. Arealdekkekartet og situasjonbildene bør derfor kombineres for å optimalisere søket.

7.2 Simulatortest ved FFI

Dronesvermen hadde større vanskeligheter med å finne de fiendtlige enhetene i skogen med det utviklede kartgrunnlaget, enn med det opprinnelige kartgrunnlaget. Dette var fordi åpne og bebygde områder var vektet høyere enn vegetasjon i det genererte kartgrunnlaget som vist i Figur 55. Dette viser viktigheten av at vektingen på både arealdekkekartet og situasjonskartet er tilpasset den spesifikke operasjonen disse skal benyttes i. Å kunne vekte ulike arealtyper er i mange tilfeller svært nyttig som for eksempel å utelukke å søke i områder med vann. På samme tid kan dette også bidra til at andre relevante områder ikke søkes i. Å kombinere arealdekkekartet, vist i Figur 53, og

situasjonsbildet, vist i Figur 55, vil derfor sannsynligvis gi de beste forutsetningene for dronene til å søke i relevante områder. Å kombinere arealdekkkart og situasjonsbilder ble ikke testet i simulator på grunn av begrenset tid til gjennomføring av oppgaven.

7.3 Datakvalitet

Datakvalitet på inndata har hatt stor betydning for resultatene i oppgaven. Dette del-kapittelet vil diskutere datakvalitet for både treningsdatasettet til dyplæringsmodellen og inndata benyttet til analysene for situasjonskartene.

7.3.1 Esri LULC som treningsdata

Kvaliteten til treningsdatasettet vil være med å påvirke hvordan modellens ytelse vurderes. Esri LULC er generert basert på en dyplæringsmodell, hvor referansedatasettet til treningsdataen besto av manuelt tegnede polygoner og Sentinel-2 bilder. Siden Esri LULC er generert fra Sentinel-2 bilder har datasettet en romlig oppløsning på 10 meter. Esri LULC er oppgitt til å ha en gjennomsnittlig nøyaktighet på 85% for 2022, med høyest klassifikasjonsriktighet på *Water*, *Trees*, *Crops* og *Built Area* (Karra et al., 2021). Referansedataen fra Esri LULC vil derfor inneholde avvik, og har lavest klassifikasjonsriktighet på blant annet *Bare Ground*, *Grass* og *Flooded Vegetation*. Basert på resultatene fra oppgaven ser det ut til at den egentrente modellen har oppnådd en bedre generalisering av arealtypene ved å benytte sammenslåtte klasser.

Ved å sammenligne Esri LULC fra 2022 med ortofoto fra Norge i bilder fra 2022, kan en se at Esri LULC inneholder det som ser ut til å være feilklassifiserte piksler. For eksempel inneholder del B av Figur 68 piksler klassifisert som bebyggelse, som ut ifra ortofotoet og AR5 fra del A ser ut til å være skog. På samme måte inneholder

Figur 69 det som ser ut som en veiakse i del A klassifisert som både *Built area Vegetation* og *Open areas*.



Figur 68: FKB AR5 med Norge i bilder fra 2022. (A) og labels fra Esri LULC med Norge i bilder fra 2022 (B).



Figur 69: FKB AR5 med Norge i bilder fra 2022. (A) og labels fra Esri LULC med Norge i bilder fra 2022 (B).

Slike feilklassifiserte piksler vil føre til at modellen feillæres opp mot hva som finnes i virkeligheten. Ved å sammenligne FKB AR5 med Esri LULC i Figur 68 og Figur 69 er det tydelig at FKB AR5 har en mye høyere romlig oppløsning og nøyaktighet. En annen svakhet ved å bruke datasettet Esri LULC er at det ikke inneholder mindre veier. Veier er ofte viktig i militære operasjoner, og det ville derfor vært fordelaktig å benytte et referansedatsett som også inkluderte mindre veier slik AR5 gjør.

For å øke dyplæringsmodellens nøyaktighet kan en bruke treningsdatasett av høyere oppløsning eller nøyaktighet som for eksempel FKB AR5. Ved å bruke FKB AR5 ville det vært mulig å eksempelvis klassifisere veier, men da ville ikke arbeidsflyten fungert globalt. FKB AR5 har heller ikke dekning i enkelte områder som for eksempel over tregrensen. Dette er en stor begrensning da militære operasjoner også kan foregå i slike områder, og dette gjør FKB AR5 til mindre egnet som treningsdata i en militær sammenheng. Siden oppgaven ønsket å lage en global arbeidsflyt ble det derfor ikke aktuelt å bruke FKB AR5 eller lignende datasett i treningsdataen. Å benytte Esri LULC fører til at analysene kan gjennomføres andre steder i verden med lite behov for tilrettelegging og endring på koden for dyplæringen.

I likhet med områdene over Rena, vist i Figur 68 og 69, er det unøyaktigheter i Esri LULC over området Tokmak i Ukraina vist i Figur 70. Oppgaven hadde imidlertid ikke tilgjengelig datasett av høyere oppløsning og nøyaktighet enn tilsvarende Esri LULC. Det ble derfor vurdert at Esri LULC var av tilstrekkelig kvalitet til å benyttes som treningsdata for dyplæringsmodellene.



Figur 70: Esri LULC (2022) og World Imagery (2022) fra område Tokmak.

7.3.2 Sentinel-2 L2A som treningsdata


Sentinel-2-bilder har i flere studier vist seg som egnet til klassifisering av arealdekke (Karra et al., 2021). Noen av de største fordelene ved bruk av denne plattformen var at den tar multispektrale bilder, og kan samle inn informasjon i flere spektrale bånd. På samme tid er multispektrale bilder sårbare for atmosfæriske forhold som mangel på lys eller tett skydekke. Lysforhold kan spesielt være en utfordring i Nord-Norge om vinteren. I slike tilfeller kan bruk av vær-uavhengige satellitter være fordelaktig, men bruk av slike satellitter vil ikke gi samme detaljerte informasjon om jordoverflaten som multispektrale satellitter.

Produkttype L2A

Oppgaven har benyttet Sentinel-2-bilder av produkttypen L2A. Siden disse er atmosfærisk korrigert, vil dette styrke kvaliteten til datagrunnlaget. Ulempen ved å benytte L2A-bilder er at det er færre nedlastbare eksemplarer av denne typen. Det finnes flere bilder av typen L1C for nedlastning, noe som ville gitt tilgang til større mengder treningsdata. Det er imidlertid mulig å gjennomføre en atmosfærisk korreksjon på L1C-bilder i programvare som *ArcGIS Pro*, men dette ville vært en tidkrevende prosess. Det ble derfor besluttet å benytte L2A bilder for å ha best mulig kvalitet på datagrunnlaget, og heller inkludere flere områder for å samle inn mer treningsdata.

Nedlastede bilder

Alle bildene som ble benyttet som inndata var lastet ned med skydekke på under 10%. Figur 71 viser et Sentinel-2 bilde over Rena som er oppgitt til å ha skydekke under 5 %. Prosenten med skydekke som benyttes i *Copernicus Browser*, som oppgaven har brukt, beregnes basert på et estimat over skydekke for hele bildeflisser. Graden av skyer gjelder derfor for en hel flis, og vil ikke være representativt for alle områdene i bildet (Sentinelhub, 2023). Lokalt høyere grad av skydekke enn 10% er derfor en potensiell feilkilde for oppgaven.



Figur 71: Sentinel-2 bilde over Rena med oppgitt skydekke <5%.

7.3.3 Valg av områder for datainnsamling

Fordeling av arealklassene i trenings- og valideringsdatasettene påvirket modellens evne til å klassifisere arealklassene riktig. Trenings- og valideringsdatasettene var ubalanserte for både Unet_Rena og Unet_Tokmak. For at modellen skulle være i stand til å validere prediksjonen for de ulike klassene var det viktig at valideringsdatasettet inneholdt tilstrekkelig forekomster av disse.

For Unet_Tokmak ble det prioritert å inkludere store områder for å få mye treningsdata, fremfor en jevnere fordeling av arealklassene. Området Tokmak inneholdt svært få forekomster av *Water* og *Vegetation*, og det ble derfor inkludert flere områder i valideringsdatasettet. Til tross for dette var datasettene fortsatt ubalanserte og modellen fikk fortsatt få områder å trene på og validere prediksjonene for *Water* og *Vegetation*. Dette kan forklare hvorfor modellen fikk lavest klassifikasjonsriktighet på disse klassene, i tillegg til feilklassifiseringen mellom *Vegetation* og *Open Areas*. På samme tid hadde modellen som mål å klassifisere arealdekke i denne regionen, og trenings- og valideringsdata burde være representativt for dette. Det ble inkludert ulik vektning for klassene for å sørge for at modellen også hadde insentiver for å predikere de mindre representerte klassene korrekt. For å øke klassifiseringskorrektheten til Unet_Tokmak kunne treningsdataen blitt lastet ned over områder med større andel av arealtypene *Water* og *Vegetation*, og mindre områder med *Open Areas*.

Treningsdatasettet for Unet_Rena inneholdt en større variasjon av arealklassene i både treningsdatasettet og valideringsdatasettet enn Unet_Tokmak. Dette ble gjort gjennom å velge ut områder av mindre størrelse som eksempelvis inneholdt en stor andel av *Built Area*, uten å inkludere store områder rundt med andre arealklasser. Dette resulterte i mindre bilder og færre treningseksemplarer, men en bedre fordeling av arealklassene. Dette kan forklare at Unet_Rena har fått en jevnere klassifikasjonsriktighet på klassene enn Unet_Tokmak. Ut ifra resultatene fra oppgaven ser det ut til at fordeling av arealklassene i datasettene har hatt større betydning for klassifikasjonsriktigheten enn mengde treningsdata.

7.3.4 Høydedata

Oppløsningen på høydedatasettet som er benyttet i oppgaven har påvirket kvaliteten på de geografiske analysene som ble gjennomført i utarbeidelsen av situasjonsbildene. I analysene over Rena er det benyttet høydedata med romlig oppløsning på 1 meter. Formålet med bruk av høydedata i denne oppgaven har vært for å gjennomføre helningsanalyser. Ved å bruke en høydemodell med 1 meter romlig oppløsning var det mulig å gjennomføre en helningsanalyse av høy oppløsning som klarte å identifisere små variasjoner i terrenget. På samme tid kan en så høy oppløsning føre til støy i datasettet. Høydedata med lavere romlig oppløsning på for eksempel 10 meter vil kunne gi en mer helhetlig representasjon av terrenget. I tillegg ble resultatene fra helningsanalysene brukt sammen med rasteret arealdekke som har 10 meters oppløsning. Dette gjør at den lavere oppløsningen til arealdekke begrenser muligheten til å utnytte oppløsningen til høydedataen. Siden formålet med høydedata i analysen var å representere helheten i terrenget ville det vært mer hensiktsmessig å benytte høydedata med 10 meters romlig oppløsning.

Siden helning stort sett er konstant vurderes det at både *DTM1* og *World TREx 12m elevation* er tilstrekkelig oppdatert til å brukes i oppgaven. Det trengs derfor ikke å generes nye høydedata for å ha oppdaterte datagrunnlag, slik som med arealdekke. Høydemodellen over Rena vurderes til å ha god kvalitet og oppløsning siden den er levert av Kartverket og er godt dokumentert. Høydemodellen benyttet over Ukraina var datasettet med høyest romlig oppløsning som var tilgjengelig. Ideelt sett ville oppgaven benyttet en høydemodell som var av samme oppløsning som arealdekkekartet. Fordi *World TREx 12m Elevation* er merket «Unntatt Offentligheten» fører dette til at analysene må gjennomføres på Forsvarets systemer. Det finnes imidlertid en global høydemodell med 30 meters romlig oppløsning (European Commission, 2022), men dette vil føre til lavere oppløsning på helningsanalysene.

7.3.5 Etterretninger

Testene av situasjonsbildet i simulator ved FFI viste hvordan etterretninger i kombinasjon med geografiske analyser bidro til å effektivisere rekognosering, på samme tid forutsetter dette at etterretningene er gode. Etterretninger brukes for å predikere hva som vil skje, men det er ingen garanti for at det stemmer. Feil i informasjonsgrunnlag, antagelser eller analyser kan føre til et situasjonsbilde som prioriterer feil områder. Et eksempel på dette er at analysene i *Scenario 3* som baserte seg på start og slutt punkter for så å beregne den optimale korridoren mellom punktene. Dersom de antatte slutt punktene ikke stemmer, kan dette føre til at dronesvermen søker i feil områder. På samme tid vil en slik analyse gi en indikasjon på hvor det er best å begynne søket etter den savnede personen.

Under utvikling av *Scenario 1 - Tokmak* ble *Ukraine Control Map* benyttet som etterretninger. Selv om *Ukraine Control Map* er et anerkjent og mye brukt datasett er det knyttet en viss usikkerhet til datasettet fordi dette baserer seg på åpne kilder og man ikke har kontroll på hvem som oppdaterer det. Datasettet kan lastes ned, men det er ikke mulig å gjennomføre analyser direkte på datasettene. For å kunne benytte datasettet i analyser må dette eksporteres fra KML til shape filer. I denne prosessen forsvant strukturen til datasettet og enkelte egenskaper. Det originale datasettet inneholdt ulike klasser for frontlinje, viktige områder, ukrainske geolokasjoner, russiske geolokasjoner, arkiv for geolokasjoner, ukrainske posisjoner og russiske posisjoner. Resultatet av eksporten ble tre ulike datasett, ett som inneholdt linjer, ett med polygoner og ett med punkter. Dette svekker integriteten til datasettet, og begrenser muligheten for mer detaljerte geografiske analyser basert på egenskaper som avdelingstype eller størrelse. Det ville derfor vært fordelaktig for arbeidsflyten å benytte et standardisert format for etterretninger hvor alle attributtene beholdes.

7.4 Overførbarhet

Arbeidsflyten brukt i oppgaven ble utviklet for at denne også skulle kunne benyttes andre steder i verden enn forsøksområdene.

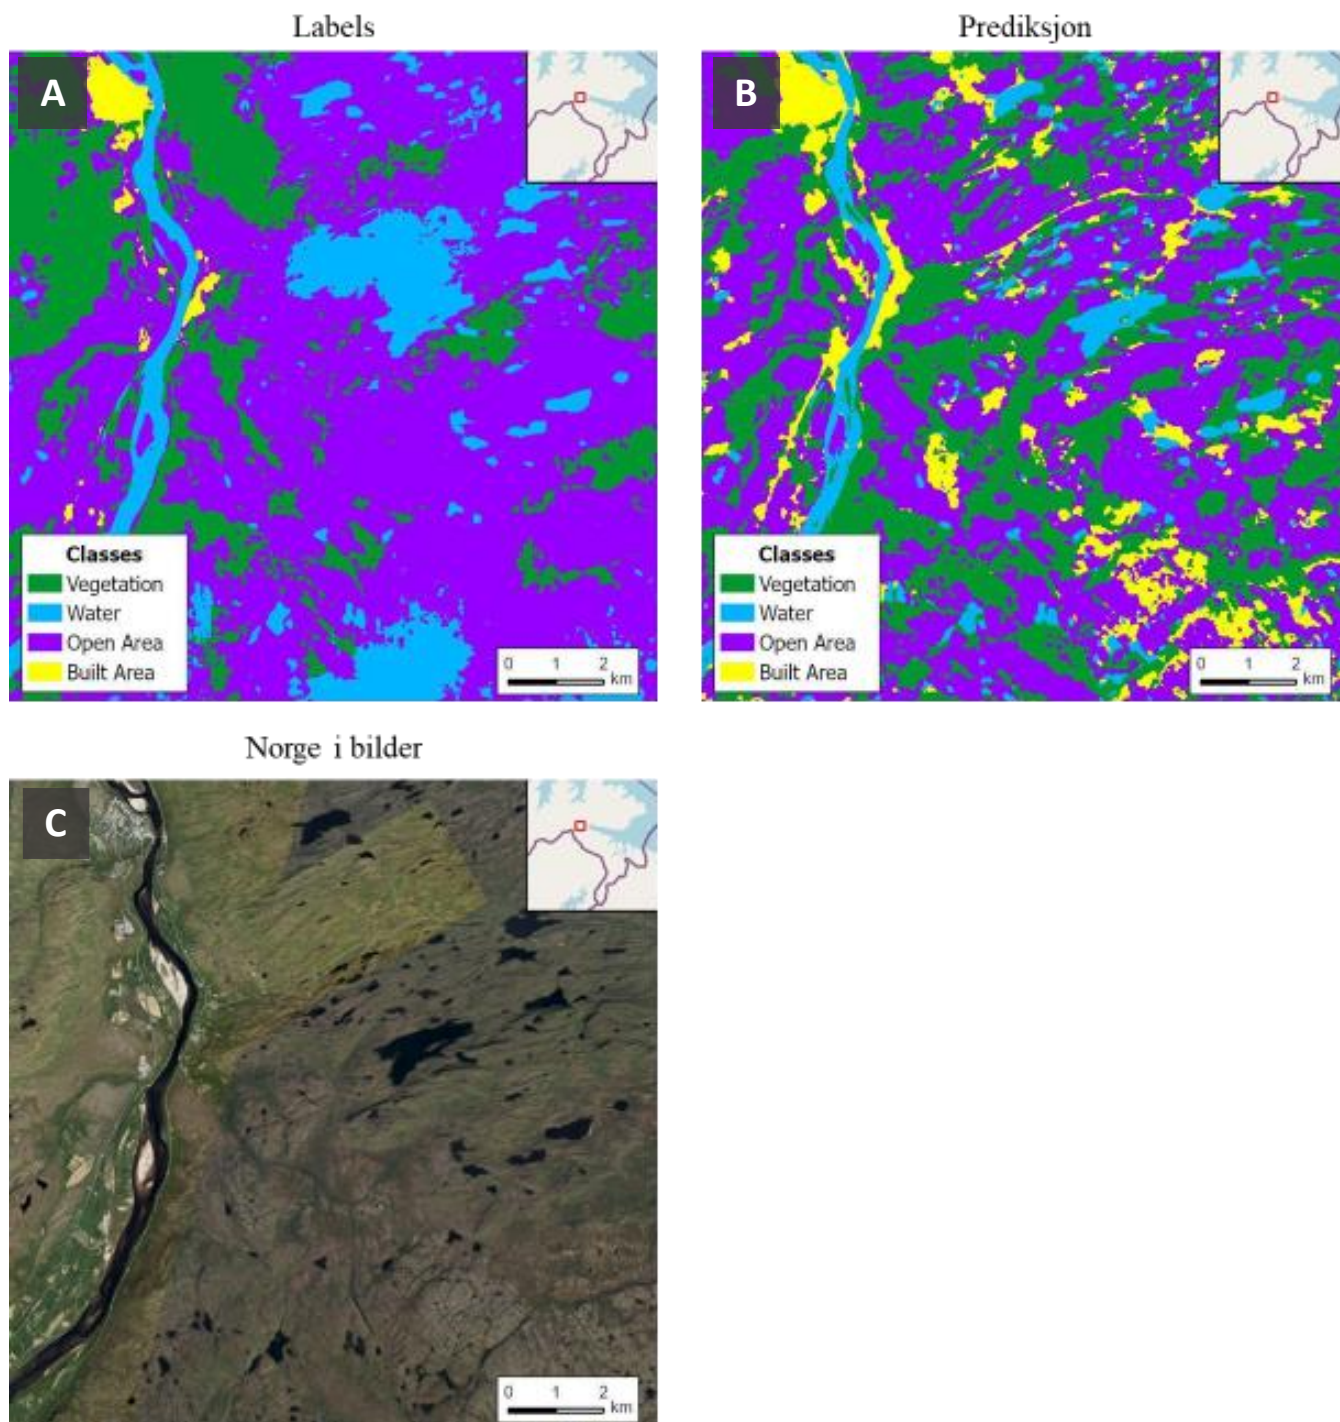
7.4.1 Dyplæringsmodeller

Ytelsen til dyplæringsmodellene ved bruk i områder de ikke spesifikt er trent for, er avhengig av områdets topografi. Figur 72 viser et resultat fra *Unet_Rena* testet i Tana i Finnmark med tilhørende ytelsesscore i Tabell 15. Resultatene viser at modellen klarer å klassifisere elven, og enkelte områder

med vann riktig. Derimot har modellen feil-klassifisert flere områder som *Built Area*, og *Vegetation*. Dette kan skyldes at Finnmark har en annerledes topografi enn Østlandet som modellen ble trent på. Disse resultatene viser derfor at Unet_Rena ikke fungerer optimalt på områder med annerledes topografi enn det modellen er trent på, uten å tilpasse modellen.

	<i>mAP</i>	<i>F1</i>	<i>Recall</i>	<i>Precision</i>
Unet_Rena	0.50307	0.51500	0.54903	0.48495

Tabell 15: Ytelse Unet_Rena i Finnmark.



Figur 72: Labels (A), prediksjon med Unet_Rena (B) og Norge i bilder (C) over Tana i Finnmark.

Det kan derfor forventes at dyplæringsmodellene vil prestere godt på områder av lignende topografi som de områdene de er trent på. Ved å trene modellene på data fra flere områder med mer varierende topografi, kan en forvente at modellen vil ha god ytelse på et større geografisk område. Det vil også være mulig å trene videre på vektene fra en trent modell, for eksempel ved å trene en modell over Finnmark med utgangspunkt i vektene fra Unet_Rena, slik at treningsprosessen blir hurtigere. Denne oppgaven har kun sett på to områder i Europa, og det er usikkert hvordan dette arbeidsflyten vil fungere i eksempelvis Afrika som har en ganske annerledes topografi. Det forventes imidlertid at dette vil fungere globalt dersom en klarer å få en god fordeling av arealklassene.

7.4.2 Geografiske analyser

De geografiske analysene som ble gjennomført innebar forenklinger og generaliseringer. Eksempelvis hadde alle beltegående kjøretøy samme kostnadsraster. For å gjøre analysene mer avansert kan kostnadsrasterne basere seg på flere data, og variere i større grad med bakgrunn i type kjøretøy, avdeling og oppdrag. Analysene er også i stor grad basert på antagelser og vurderinger om hvordan fienden vil operere, for eksempel at infanteriavdelingene vil hovedsakelig operere i skog. For å lage situasjonsbilder av høy kvalitet kreves det i likhet med andre etterretningsanalyser en god kjennskap til kapasitet, og fiendens teknikk, taktikk og prosedyrer. Kostnadsrasteret brukt Scenario 1 Tokmak ble ikke like detaljert som på Rena (se Figur 42 og Figur 43) fordi det ikke var mulig å skille mellom de ulike typene russiske avdelinger. Mer detaljert informasjon vil dermed kunne øke kvaliteten på situasjonsbildene.

De geografiske analysene er gjennomført i *Modelbuilder* og *Python*. Dette gjør det mulig å kombinere flere verktøy og utarbeide *Python*-koder som kan brukes av andre. Fordelen med slike koder er at analysene kan gjennomføres flere ganger med modifiserte parametere eller ulik inndata. Kodene som er utviklet demonstrerer en metode og er tilpasset det enkelte scenarioet og området, og må derfor justeres dersom den skal benyttes andre steder.

For eksempel ble koden fra *Scenario 1 – Rena* (se Vedlegg C) benyttet som utgangspunkt for analysene på Tokmak, men måtte i stor grad endres. Dette var fordi datasettene var strukturert annerledes som for eksempel at etterretningene i Rena hadde egenskapen *Avdeling* som bufferavstanden ble bestemt fra. Datasettet for de registrerte posisjonene i Tokmak inneholdt ikke denne egenskapen noe som førte til at koden måtte endres slik at bufferavstanden ble lik for alle posisjonene. Dette eksempelet viser hvordan arbeidsflyten kan tilpasses formatet på etterretningene.

Koden fra *Scenario 3* kunne derimot benyttes på begge forsøksområdene ved å endre inndata som høydedata, arealdekkekart og start- og sluttunkt. Det ville vært mulig å lage en kode som for eksempel var tilpasset NATO-standarder for hvordan data skal struktureres, men det ville fortsatt vært behov for enkelte tilpasninger og justeringer. Kodene som er utarbeidet viser derfor en arbeidsflyt, og demonstrerer hvordan geografiske analyser kan benyttes i og tilpasses ulike militære operasjoner og på ulike typer etterretninger.

8 Konklusjon

Denne oppgaven har undersøkt hvordan GeoAI og et utvalg geografiske analyser kan benyttes for å effektivisere rekognosering med dronesvermer. Dette har resultert i en arbeidsflyt for automatisk generering av arealdekkekart og situasjonskart som bidrar inn i oppdragsløsning og til økt situasjonsforståelse.

For å effektivisere rekognosering med dronesverm er en avhengig av å kunne identifisere hvilke områder som skal prioriteres å søke i. Oppgaven har beskrevet en arbeidsflyt for å generere arealdekkekart og situasjonskart med prioriterte områder. Dette ble gjort gjennom å segmentere satellittbilder til arealdekkekart hvor det var mulig å vekte hvilke arealtyper som var av interesse. Dette arealdekkekartet ble deretter brukt inn i analyser i kombinasjon med etterretninger for å identifisere prioriterte områder.

Gjennom å trene dyplæringsmodeller for å segmentere satellittbilder, har oppgaven vist at det er mulig å generere arealdekkekart for å identifisere områder av interesse, og prioritere disse. Dyplæringsmodellene var i stand til å fange opp endringer som flom og å identifisere større broer. Et prioritert arealdekkekart er spesielt relevant i tilfeller en ikke har tilgang til, eller begrenset etterretninger. Oppgaven har vist at dyplæringsmodellene vil være svært relevant å bruke i områder hvor det ikke er tilgjengelig tilstrekkelig oppdatert eller fullstendig arealdekkekart fordi de gjør det mulig å generere arealdekkekart av høyere kvalitet enn eksisterende kart. Arbeidsflyten ble utviklet for å fungere globalt, men er kun demonstrert på to områder i Europa. For å forbedre artefaktet bør dyplæringsmodellene videreutvikles for å bedre identifisere og klassifisere veiakser.

Resultatene fra situasjonsbildene demonstrerer at analysene prioriterer hvilke områder som først bør søkes i og hvilke områder som bør utelukkes. Disse kartene innsnevrer og avgrenser søkeområder, og dermed effektiviserer rekognosering gjennom å utelukke mindre relevante områder og prioritere de viktigste. Oppgaven har vist hvordan rekognosering i en krigssituasjon, basert på en hendelseslogg, og innenfor søk etter en savnet person, kan effektiviseres. Kvaliteten av situasjonskartet vil i stor grad avhenge av aktualiteten til etterretningene, og vurderinger som gjøres i analysene.

Arealdekkekartene og situasjonskartene generert i oppgaven har bidratt til å effektivisere rekognosering med dronesverm og er et viktig bidrag inn i *Valkyrie*. Det er allikevel rom for forbedringer innen dyplæringsmodellene og de geografiske analysene for å gi et enda bedre resultat.

9 Videre arbeid

Tema for oppgaven har et stort potensial i både sivil og militær sammenheng, og det finnes mange muligheter for videre forskning og utvikling.

9.1 Anvendelse

Det ville vært verdifullt å gjennomføre fysiske flyvninger med dronesvermen under militære øvelser for å vurdere arbeidsflyten under realistiske forhold. For å evaluere hvor overførbar arbeidsflyten er vil videre testing av dyplæringsmodellene og de geografiske analysene over flere områder med variert topografi vil være viktig. Det er også mulig å utforske og eksperimentere med mer avanserte og tilpassede analyser for ulike scenarioer.

9.2 Treningsdata

Som beskrevet i konklusjonen kan dyplæringsmodellen med fordel videreutvikles til å klassifisere veier for å øke nytteverdien av verktøyet. Det ville derfor vært interessant å utforske andre treningsdatasett av høyere oppløsning som også inkluderte veier. For eksempel gjennom å trene en modell på FKB AR5 over Norge, og deretter teste denne på steder som for eksempel i Ukraina. Et annet alternativ er å kombinere Esri LULC med et globalt veidatasett som for eksempel *GRIP global roads database* for å inkludere veier i referansedatasettet.

En annen mulighet for å utvikle en mer nøyaktig modell kan være å eksperimentere med hyperspektrale bilder for fange opp mer detaljert informasjon av jordoverflaten. Det er også mulig å kombinere multispektrale bilder med bilder fra syntetisk apertur radar for å forbedre klassifisering av arealdekke.

9.3 Modellarkitektur

Denne oppgaven har trent et u-nettverk fra bunnen, men det ville vært mulig å trene videre på andre forhåndstreinte modeller for å gjøre treningsprosessen raskere eller for å gi mer nøyaktige klassifiseringer. Oppgaven kan også kun sett på nettverksarkitekturen U-net, og det vil være mulig å eksperimentere med andre nettverksarkitekturer for å løse sammen oppgave.

9.4 Geografiske analyser

Denne oppgaven har kun vist et utvalg av relevante analyser med forenklinger og generaliseringer. Det ville vært relevant å utarbeide en kode som i større grad analyserer terrenget kombinert med fiendens handlemåte for å predikere hvordan fiende vil handle. For eksempel for å identifisere spesielt kanaliserende områder, og inkludere dette i situasjonsbildene for krigsscenarioene. I tillegg til måter å benytte sanntidsinformasjon for å oppdatere situasjonsbildene som for eksempel observasjoner fra dronene selv.

Opgaven var avgrenset til å bruke fiktive eller åpent tilgjengelig etterretninger som datagrunnlag for å generere situasjonsbilde. Det ville vært relevant å utforske mer realistiske metoder for innsamling av data som for eksempel å importere en fiende-situasjon fra kommando og kontroll-programvaren NORCCIS som benyttes i Forsvaret.

Litteraturliste

- Ajourhold av AR5. (u.å.). Nibio. Hentet 22. november 2023, fra
<https://nibio.no/tema/jord/arealressurser/arealressurskart-ar5/ajourhold-av-ar5>
- Alparone, L., Garzelli, A., & Zoppetti, C. (2023). Fusion of VNIR Optical and C-Band Polarimetric SAR Satellite Data for Accurate Detection of Temporal Changes in Vegetated Areas. *Radar Techniques an Imaging Applications*. <https://doi.org/10.3390/rs15030638>
- Arealressurskart—FKB-AR5—Kartkatalogen. (u.å.). Hentet 27. oktober 2023, fra
<https://kartkatalog.geonorge.no/metadata/arealressurskart-fkb-ar5/243751e8-5803-4627-898c-d0ddabe82056>
- Boesch, G. (2021). *Deep Neural Network: The 3 Popular Types (MLP, CNN and RNN)*.
<https://viso.ai/deep-learning/deep-neural-network-three-popular-types/>
- computersciencewiki.org. (2018). *File:MaxpoolSample2.png—Computer Science Wiki*.
<https://computersciencewiki.org/index.php/File:MaxpoolSample2.png#filelinks>
- Copernicus. (u.å.). *Copernicus in detail | Copernicus*. Hentet 18. oktober 2023, fra
<https://www.copernicus.eu/en/about-copernicus/copernicus-detail>
- Esri. (2021). *Esri | Sentinel-2 Land Cover Explorer*. <https://livingatlas.arcgis.com/landcoverexplorer/>
- Esri. (2022). *Sentinel-2 10m Land Use/Land Cover Time Series—Oversikt*.
<https://www.arcgis.com/home/item.html?id=cfc7609de5f478eb7666240902d4d3d>
- Esri. (u.å.-b). *Creating a corridor—ArcGIS Pro | Documentation*. <https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/creating-a-corridor.htm>
- Esri. (u.å.-c). *Distance Accumulation (Raster Analysis)—ArcGIS Pro | Documentation*.
<https://pro.arcgis.com/en/pro-app/latest/tool-reference/raster-analysis/distance-accumulation.htm>
- Esri. (u.å.-d). *How Kernel Density works—ArcGIS Pro | Documentation*.
<https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/how-kernel-density-works.htm>
- Esri. (u.å.-a). *Weighted Overlay (Spatial Analyst)—ArcGIS Pro | Documentation*.
<https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-analyst/weighted-overlay.htm>
- European Commission. (2022). *TanDEM-X - Digital Elevation Model (DEM)—Global, 30m—Data Europa EU*. <https://data.europa.eu/data/datasets/8545a026-2e0c-466f-b6de-99faa639e3c0?locale=en>

- European Space Agency - ESA. (u.å.). *Level-2A Algorithm—Sentinel-2 MSI Technical Guide—Sentinel Online*. Sentinel Online. Hentet 29. november 2023, fra <https://copernicus.eu/technical-guides/sentinel-2-msi/level-2a/algorithm-overview>
- European Space Agency - ESA. (2023). *Sentinel-2—Missions—Sentinel Online*. Sentinel Online. <https://sentinels.copernicus.eu/web/sentinel/missions/sentinel-2>
- FN. (2023, september 18). *FNs bærekraftsmål*. <https://www.fn.no/om-fn/fns-baerekraftsmaal>
- Forsvaret. (2019). *Forsvarets felleoperative doktrine*. Forsvarsstaben.
- Forsvaret. (2021). *Forsvarets etterretningsdoktrine*.
- GeeksforGeeks.org. (2020). *Artificial Neural Networks and its Applications*. <https://www.geeksforgeeks.org/artificial-neural-networks-and-its-applications/>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
- Grinderud, K., Bjerke, H., Sanderud, Ø., Ulveseth, P. G., Mauseth, Ø., Nilsen, S., Fjetland, M., Steffensen, A., & Richardsen, I. (2016). *GIS: geografiens språk i vår tidsalder* (A. C. Haavik-Nilsen, Red.; 2. utg.). Fagbokforlaget.
- Hansbø, M. (2019). *Dronestrategien – hva nå? - Innspill til en mulig nasjonal sivil-militær satsing på ubemannede luftfarkoster*.
- Hofoss, E., Aarønæs, L., & Tollfesen, D. (2023). Forsvaret i verdensrommet. *Viten, 1. Home*. (u.å.). Project Owl. Hentet 14. november 2023, fra <https://www.projectowl.one>
- Håndbok for Geovekst-samarbeidet*. (2023, september 21). Kartverket.no. <https://kartverket.no/geodataarbeid/geovekst/veiledningsmaterieill-geovekst>
- Ioffe, S., & Szegedy, C. (2015). *Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift* (arXiv:1502.03167). arXiv. <https://doi.org/10.48550/arXiv.1502.03167>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets, 31* (3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Javatpoint.com. (u.å.). *Supervised Machine learning—Javatpoint*. Hentet 19. mai 2024, fra <https://www.javatpoint.com/supervised-machine-learning>
- Karra, K., Kontgis, C., Statman-Weil, Z., Mazzariello, J. C., Mathis, M., & Brumby, S. P. (2021). Global land use / land cover with Sentinel 2 and deep learning. *2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS*. <https://doi.org/10.1109/IGARSS47720.2021.9553499>
- Kartverket. (2023, november 17). *Kartgrunnlag Fastlands-Norge*. Kartverket.no. <https://kartverket.no/api-og-data/kartgrunnlag-fastlands-norge>

- NIBIO. (2023). *Produktark: Arealressurskart—FKB-AR5*.
- Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., & Ranagalage, M. (2020). Sentinel-2 Data for Land Cover/Use Mapping: A Review. *Remote Sensing*, 12(14), Artikkel 14. <https://doi.org/10.3390/rs12142291>
- Rama. (2012). *Model of Sentinel 2*. Own work. https://commons.wikimedia.org/wiki/File:Sentinel_2-IMG_5873-gradient.jpg
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. I N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Red.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (s. 234–241). Springer International Publishing. https://doi.org/10.1007/978-3-319-24574-4_28
- Sentinelhub. (2023). *Sentinel-2 L2A*. <https://docs.sentinel-hub.com/api/latest/data/sentinel-2-l2a/>
- Sheldon, M. (2023, juni 29). *Satellite Imagery Reveals Russia Caused Flooding in Occupied Ukrainian Town Before Counteroffensive*. Bellingcat. <https://www.bellingcat.com/news/2023/06/29/satellite-imagery-reveals-russia-caused-flooding-in-occupied-ukrainian-town-before-counter-offensive/>
- Simonsen, A. S. (2023, oktober 20). *Kartgrunnlag dronesverm* [Personlig kommunikasjon].
- Solórzano, J. V., Mas, J. F., Gao, Y., & Gallardo-Cruz, J. A. (2021). Land Use Land Cover Classification with U-Net: Advantages of Combining Sentinel-1 and Sentinel-2 Imagery. *Remote Sensing*, 13(18), 3600. <https://doi.org/10.3390/rs13183600>
- Stølen, K. (2019). *Teknologivitenskap; forskningsmetoder for teknologer*. Universitetsforlaget.
- Tandberg, E. (2023). Copernicus – romprogram. I *Store norske leksikon*. https://snl.no/Copernicus_-_romprogram
- The European Space Agency. (u.å.). *User Guides—Sentinel-2 MSI - Revisit and Coverage—Sentinel Online*. Sentinel Online. Hentet 18. oktober 2023, fra <https://copernicus.eu/user-guides/sentinel-2-msi/revisit-coverage>
- Tidemann, A., & Elster, A. C. (2023). Maskinlæring. I *Store norske leksikon*. <https://snl.no/maskinl%C3%A6ring>
- Watling, J., & Reynolds, N. (2023). Meatgrinder: Russian Tactics in the Second Year of Its Invasion of Ukraine. *Royal United Services Institute for Defence and Security Studie*. <https://rusi.orghttps://rusi.org>
- Wegmann. (2010). *English: A graph showing differences in vector and raster files using tikz*: Own work. https://commons.wikimedia.org/wiki/File:Raster_vector_tikz.png
- What Is GeoAI? | Accelerated Data Generation & Spatial Problem-Solving*. (u.å.). Hentet 20. oktober 2023, fra <https://www.esri.com/en-us/capabilities/geoai/overview>

Vedlegg

	Antall sider
Vedlegg A Sentinel-2 nedlastning	2
Vedlegg B Segmentering	10
Vedlegg C Geografiske analyser	12