


Khan, Zaki Ahmad
Sibbern, Linnea Sofia

Deteksjon i 100-metersbeltet ved bruk av kunstig intelligens

Bacheloroppgave i Bachelor i ingeniørfag - Geomatikk
Veileder: Ødegård, Rune Strand
Medveileder: Dugstad, Lars Roar og Bjørndal, Martin Gjesdal
Mai 2023

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



Khan, Zaki Ahmad
Sibbern, Linnea Sofia

Deteksjon i 100-metersbeltet ved bruk av kunstig intelligens

Bacheloroppgave i Bachelor i ingeniørfag - Geomatikk
Veileder: Ødegård, Rune Strand
Medveileder: Dugstad, Lars Roar og Bjørndal, Martin Gjesdal
Mai 2023

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



Kunnskap for en bedre verden

Forord

Oslo, 22.mai 2023

Denne bacheloroppgaven er opprinnelig en avsluttende oppgave ved Krigsskolen, skrevet høsten 2021. Grunnet endringer i utdanningsløpet resulterte oppgaven i å bli en avsluttende oppgave ved NTNU våren 2023 istedenfor. Grunnlaget for oppgaven er derfor opparbeidet gjennom totalt 4,5 år. Årene er fordelt på ingeniørlinjen ved Krigsskolen, med spesialisering innenfor militær geomatikk (MilGeo), Ingeniørfag ved NTNU, samt 1,5 år som MilGeo i Ingeniørbataljonen.

Oppgavens tematikk er valgt på bakgrunn av et ønske om å utforske nye muligheter innenfor MilGeo-fagfeltet. Tematikken er ny for gruppen, da maskinlæring ikke er et tema noen av de overnevnte utdanningene tar for seg. Hærens våpenskole gjennomførte høsten 2021 øvelse TERRA, der flere MilGeo fra ulike avdelinger i Forsvaret utforsket mulighetene innenfor maskinlæring. Gruppen ønsket å se mer på dette, med spesielt fokus på objekt-deteksjon i ArcGIS. Arbeidet med denne oppgaven har gitt mye læring, som vil kunne anvendes til å løse oppdrag ved senere anledninger.

I løpet av arbeidet med oppgaven har gruppen fått støtte og veiledning fra mange hold. Derfor ønsker vi å rette en stor takk til de som har hjulpet oss. Hærens våpenskole, og spesielt Jørgen Bråthen, har bidratt med kunnskap og erfaring opparbeidet under øvelse TERRA, samt utlån av datamaskin. Anders Martin Moe fra MH-Tech var en utrolig viktig sparrepartner i oppstartsfasen, og i arbeidet med å utarbeide en relevant og tidsaktuell problemstilling. Bibliotekar, Linn Carin Stenvig Andreassen, har hjulpet oss med kildehenvisning og bruk av sitater. Vi ønsker også å rette en takk til Halvard Bjerke, MilGeo-instruktør ved Krigsskolen, som til tross for en hektisk periode har satt av tid til å hjelpe oss med tekniske utfordringer underveis. Avslutningsvis vil vi spesielt takke våre veiledere; Lars Roar Uggerud Dugstad, Martin Gjesdal Bjørndal og Rune Strand Ødegård. Lars Roar, hovedlærer MilGeo på Krigsskolen, har hjulpet oss med alt fra metode til struktur og oppbygning. Martin, forsker på FFI, har vært ekstremt fleksibel og behjelpelig. Uten hans tekniske kompetanse hadde vi aldri klart å gjennomføre denne oppgaven. Rune, førsteamanuensis ved NTNU, har bidratt med gode tilbakemeldinger og en enorm kompetanse og engasjement innenfor geomatikk-fagfeltet som helhet. Tusen takk til dere alle tre. Deres tilbakemeldinger og vilje til diskusjon har vært en viktig drivkraft.

Sammendrag

Norges strandsone, eller det såkalte 100-metersbeltet, er ifølge Norges lover i utgangspunktet et område med byggeforbud. Dette fører til at mye uregistrert bebyggelse settes opp, som igjen vanskeliggjør kartleggingen av området. For flere avdelinger i Sjøforsvaret er 100-metersbeltet et spesielt interessant område ettersom det muliggjør åpning av nye landfronter. For å kunne planlegge landsettingsoperasjoner må en ha kontroll på blant annet bebyggelsen på land, men med manglende data blir dette vanskelig. Med denne motivasjonen for oppgaven har gruppen kommet frem til følgende problemstilling:

Kan en ved bruk av kunstige nevrale nettverk detektere uregistrert bebyggelse i ortofoto, i 100-metersbeltet?

For å svare på problemstillingen blir teknologivitenskapelig metode anvendt. Denne metoden går ut på at det først identifiseres et artefaktbehov, for deretter å lage en nyskaping som dekker dette behovet. I denne oppgaven er det forsøkt med hovedsakelig tre ulike nyskapinger for å løse artefaktbehovet, og dermed svare på problemstillingen.

Nyskapingene er ulike former for objekt-deteksjon i ArcGIS. Først anvendes en ferdigtrent modell fra ESRI. Deretter er det forsøkt å modifisere denne. Den siste nyskapingen går ut på å trene en helt ny modell. Alle tre modellene gjør deteksjoner i ortofoto, men i ulik grad.

Opgaven tar for seg hvordan disse modellene, anvendt i ulike dyplæringsverktøy i ArcGIS, best mulig kan svare på oppgavens artefaktbehov.

Av de tre nyskapingene så konkluderes det med at den egentrente modellen er den som gir best resultater. På deteksjonene som gjøres klarer modellen å detektere en andel hus, naust og brygger, inkludert uregistrert bebyggelse. Til tross for dette er det områder der modellen ikke gir tilfredsstillende resultat. Dette er trolig grunnet for lite treningsdata. Dermed kan det konkluderes med at en ved bruk av kunstige nevrale nettverk kan detektere uregistrert bebyggelse i ortofoto, i 100-metersbeltet. Det vil likevel kreve større mengder treningsdata for at resultatet skal bli tilfredsstillende langs hele Norges kystlinje.

Abstract

In Norway it is difficult to get a building permit in the 100-meter zone, which is a zone stretching 100 meters in from the seashore. This leads to many illegal buildings, which makes it difficult to map these structures. To the Navy it is critical to know the location of these structures, as the coast is used for landing operations. Planning and executing landing operations can be difficult if the data of structures on land, and in close proximity to land, is missing. This issue is used as motivation for this extended essay and our research question is:

Is it possible to use artificial neural networks to detect unregistered structures in an orthophoto, in the 100-meter zone?

Technological science method is used to answer this question. This method is based on firstly identifying the artifact need, then coming up with an innovation that answers the need identified. In this project, three different innovations have been used to answer the artifact need, and thus solve the problem.

The innovations are three different models of object detection in ArcGIS. The first model is a pre-trained deep learning model, made by ESRI. The second model is a modified version of the pre-trained model, and the last one is a self-trained model without any pre-training. All three models do detect objects, but in different degrees. This extended essay describes how one can use the models in the deep learning tools in ArcGIS to most accurately answer the artifact need.

The essay concludes that the self-trained model, which was not pre-trained, was the best one to solve the artifact need. In the evaluation-experiment the self-trained model manages to detect a proportion of structures, including unregistered buildings. On the other hand, the evaluation reveals that the amount of training data is too small to give a satisfactory result along Norway's entire coastline. Thus, it can be concluded that when using artificial neural networks, one can detect unregistered buildings in an orthophoto, in the 100-meter zone, but this will require relatively large amounts of training data.

Innholdsfortegnelse

Forord.....	I
Sammendrag	II
Abstract.....	III
Innholdsfortegnelse.....	IV
Ordforklaring	VII
Figurliste	VIII
Tabelliste.....	X
1 Innledning	1
1.1 Problemstilling	3
1.2 Målgruppe	3
1.3 Avgrensninger	4
1.4 Oppgavens oppbygning.....	4
2 Metode	6
2.1 Teknologivitenskapelig metode	6
2.2 Metode anvendt i denne oppgaven.....	7
3 Teori.....	9
3.1 Kunstig intelligens.....	9
3.1.1 Maskinlæring	10
3.1.2 Kunstige nevrale nettverk	11
3.2 Geografiske informasjonssystemer (GIS).....	13
3.3 Felles kartdatabase (FKB).....	14
3.4 Ortofoto	15
3.5 Mål for treffsikkerhet	16

4 Eksperiment	20
4.1 Forutsetninger.....	20
4.1.1 Maskinvare.....	20
4.1.2 Datasett	20
4.1.3 ArcGIS	21
4.1.4 Dyplæringsverktøy i ArcGIS	22
4.2 Lokalisere analyseområde	24
4.3 Modell-oppsett	26
4.3.1 ESRI-modell	26
4.3.2 Modifisert modell.....	26
4.3.3 Egentrent modell.....	29
5 Resultater og diskusjon	31
5.1 Presentasjon av resultatene.....	31
5.1.1 ESRI-modell	31
5.1.2 Modifisert modell.....	33
5.1.3 Egentrent modell.....	35
5.1.4 Evaluering av den egentrente modellen på nye lokasjoner	36
5.2 Diskusjon av resultatene.....	40
5.2.1 ESRI-modell	40
5.2.2 Modifisert modell.....	40
5.2.3 Egentrent modell.....	42
5.3 Svakheter ved oppgaven.....	46
5.3.1 Kildekritikk	46
6 Konklusjon.....	50
6.1 Videre arbeid.....	51

Litteraturliste..... 53

Ordforklaring

Artefakt	En ting, et objekt eller et fenomen skapt av mennesker (Stølen, 2019, p. 177).
Beslutningsstøtte	Støtte i en beslutningsprosess (Sjef Etterretningstjenesten, 2020, p. 9).
MilGeo	Brukes både om fagfeltet militær geomatikk og fagpersonen militær geomatiker (Sjef Etterretningstjenesten, 2020, p. 5).
Modell	Et generelt begrep om sluttresultatet av maskinlæringen (Datatilsynet, 2018, p. 6).
Polygon	En flate, representert som flere linjer som avgrenser et område (Grinderud <i>et al.</i> , 2016, p. 47).
Situasjonsforståelse	Oppfatning av en situasjon, begrenset i sted og tid (Endsley, 2000, pp. 2–3).
Vektordata	Geografisk data som viser geografien i form av punkter, linjer og flater (Kartverket, 2011).
100-metersbeltet	Området 100 meter fra strandlinjen målt i horisontalplanet ved alminnelig høyvann. Begrepet «strandsonen» brukes ofte som synonym (Gursli-Berg and Reusch, 2017).
IPOE	En etterretningsprosess som har til hensikt å støtte planprosesser i Forsvaret (Kristoffersen, 2021, p. 103).

Figurliste

Figur 1: Teknologivitenskapelig metode (Stølen, 2019, s. 20).....	6
Figur 2: Nyskapningen er en prosess som detekterer hus, naust og brygger.	7
Figur 3: Forenklet oversikt over hva som inngår i kunstig intelligens (European Commission, 2020).	9
Figur 4: Kunstig nevralt nettverk (Datatilsynet, 2018, p. 13).....	11
Figur 5: Et kunstig nevralt nettverk (Dvergsdal, 2019).	12
Figur 6: Flere lag i et kunstig nevralt nettverk (Dvergsdal, 2019).....	12
Figur 7: Det kan være vanskelig å skille brygge og båt, men ved hjelp av trening klarer det kunstige nevralt nettverket å finne særegne kjennetegn for brygger.	13
Figur 8: Større pikselstørrelse gir lavere oppløsning.	16
Figur 9: Eksempel på hva True Positive, False Positive og False Negative kan være.	17
Figur 10: Formler for Precision og Recall (Riggio, 2019).....	17
Figur 11: Visuell fremstilling av Precision og Recall. Figur etter Christoffer Riggio (Riggio, 2019).	18
Figur 12: Visuell fremstilling av IoU. Figur etter Christoffer Riggio (Riggio, 2019).....	19
Figur 13: Viser hvordan en kan laste ned ESRI-modellen i ArcGIS.	22
Figur 14: Hvert av de ulike stegene løses ved hjelp av et dyplæringsverktøy i ArcGIS.	23
Figur 15: Parametere som justeres underveis i prosessen.....	23
Figur 16: Analyseområdet; Malmøya, inneholder hus, naust og brygger.....	25
Figur 17: ESRI-modellen skal kun detektere objekter.....	26
Figur 18: Treningsdata lages.....	27
Figur 19: Det definerte analyse- og treningsområdet. Bakgrunnskart hentet fra ArcGIS basemaps (ESRI, no date g).....	28
Figur 20: Den modifiserte modellen lages.....	28
Figur 21: Objekter detekteres, som siste del av prosessen.....	29
Figur 22: Etersom treningsdata alt er etablert kan denne modellen starte direkte på treningen..	29
Figur 23: Den egentrente modellen skal i siste steg av prosessen detektere objekter.	30
Figur 24: Deteksjon ved bruk av ESRI-modellen.	32
Figur 25: ESRI-modellen detekterer i hovedsak større hus.	32

Figur 26: Deteksjonen ved bruk av den modifiserte modellen.	34
Figur 27: Den modifiserte modellen klarer å detektere hus, naust og brygger.	34
Figur 28: Deteksjonen ved bruk av egentrent modell.	35
Figur 29: Den egentrente modellen detekterer bygninger, naust og brygger.	36
Figur 30: Deteksjon ved bruk av den egentrente modellen over et område i Bodø.....	37
Figur 31: Deteksjon over Bygdøy.	38
Figur 32: Deteksjon ved bruk av egentrent modell for å detektere uregistrert bebyggelse på Malmøya.	39
Figur 33: En polygon dekker flere hus.	44
Figur 34: Deteksjon av brygger.	45
Figur 35: Flytebryggene vil ha varierende lokasjon, noe som kan fører til lite samsvar mellom FKB-datasettet og deteksjonen gjort av modellen.	48
Figur 36: Polygonene skiller ikke på bygninger og brygger.....	52

Tabelliste

Tabell 1: Parameterverdiene til ESRI-modellen.	31
Tabell 2: Resultatene til ESRI-modellen.	33
Tabell 3: Parameterverdiene til den modifiserte modellen.	33
Tabell 4: Resultatene til den modifiserte modellen.	35
Tabell 5: Resultatene til den egentrente modellen.	36
Tabell 6: Resultatene til den egentrente modellen i Bodø.	38
Tabell 7: Resultatene til den egentrente modellen på Bygdøy.	39

1 Innledning

I *Contemporary Military Theory* hevdes det at i fremtiden vil teknologi redusere krigens usikkerhet og kaos betraktelig, samt at krigens vinnere er de med informasjonsoverlegenhet og best situasjonsforståelse av operasjonsområdet (Widen and Angstrom, 2014, p. 107). Ifølge Forsvarets Forskningsinstitutt (FFI) går den militærteknologiske utviklingen ekstremt raskt, og dersom en ikke klarer å tilpasse seg denne utviklingen kan det få fatale konsekvenser. De trekker frem at en av de viktigste forskningsområdene i årene fremover er forbedret beslutningsstøtte ved hjelp av kunstig intelligens og prosessering av store datamengder. «Potensialet i kunstig intelligens anses som så stort at det stadig diskuteres om vi står ovenfor en revolusjonær utvikling» (Beadle *et al.*, 2019, pp. 49–51). Siden mennesket har en begrenset kognitiv prosesseringskapasitet vil for mye, ustrukturert informasjon gjøre det vanskelig for beslutningstaker å ta gode avgjørelser (Speier, Valacich and Vessey, 1999, p. 338). Ved bruk av kunstig intelligens kan enorme mengder data prosesseres, og dermed hjelpe beslutningstaker å etablere en god situasjonsforståelse og et robust grunnlag for raskere og bedre beslutningstaking (FFI, 2019).

Kunstig intelligens er dataprogrammer som anvender tilnærmet menneskelig intelligent oppførsel til å utføre gitte oppgaver. Dette er et område i enorm utvikling, og kan eksempelvis benyttes til oppgaver som oversettelse og objekt-deteksjon i bilder (FFI, 2019, pp. 12–13). I denne oppgaven skal mulighetene innenfor objekt-deteksjon utforskes. Dette er en form for kunstig intelligens som utnytter kunstige nevralt nettverk til å gjenkjenne spesifikke objekter i bilder (LeCun, Bengio and Hinton, 2015, p. 436). Kunstige nevralt nettverk er datastrukturer som er organisert på en måte som minner om oppbygningen til nervecellene i hjernen. Slike nettverk egner seg til å gjennomføre arbeidsoppgaver som er vanskelig å uttrykke ved bruk av matematiske formuleringer, slik som objekt-deteksjon i bilder (Dvergsdal, 2019).

Dersom en militær geomatiker (MilGeo) tar i bruk objekt-deteksjon i de allerede implementerte prosedyrene, slik som lende-vurderingen, kan det både effektivisere arbeidet og forbedre resultatet. Håndbok MilGeo (2020) definerer MilGeo sin generelle rolle til å gi beslutningstaker et bedre grunnlag å ta avgjørelser på. En MilGeo vil typisk støtte inn i *Intelligence Preparation of the Operational Environment* (IPOE-prosessen), der de blant annet støtter med en grundig

lendeanalyse. Lendeanalysen skal bidra til å lokalisere muligheter og begrensninger i lendet (Hærens våpenskole, 2015). Ved å la maskiner gjøre deler av denne jobben så kan en MilGeo bruke tiden sin mer effektivt på vurderinger, heller enn kartlegging av data. Dette vil kunne generere bedre situasjonsforståelse av operasjonsområdet.

Ved å bruke kunstig intelligens i form av objekt-deteksjon kan en finne uregistrert bebyggelse i lendet. Uregistrert bebyggelse kan være til hinder for infanteri og fartøy under landsettingsoperasjoner, og av den grunn er det ønskelig å inkludere dette i planleggingsfasen, som en del av lende-vurderingen. I Forsvarets doktrine for maritime operasjoner (FDMO) (2015, p. 63) er landsettingsoperasjoner beskrevet som en operasjon der styrker landsettes fra sjøen, i den hensikt å åpne en landfront og dermed oppnå overraskelse og manøvervirkning. Enkelte avdelinger i Sjøforsvaret har ytret et behov for oppdatert kartgrunnlag over Norges såkalte *100-metersbeltet*. Gjennom diskusjon og samtaler har det blitt beskrevet at det finnes betydelig uregistrert bebyggelse i strandsonen, særlig i Nord-Norge. Dette omhandler i hovedsak mangel på vektordata over bygninger, naust og brygger i 100-metersbeltet. Ifølge plan- og bygningsloven er det i utgangspunktet forbudt å bygge i 100-metersbeltet (Kommunal- og moderniseringsdepartementet, 2021, § 1-8). Dette kan føre til at bygg oppføres ulovlig og kan være en av årsakene til at statlige karttjenester ikke besitter vektordata over all bebyggelse i 100-metersbeltet.

Forsvaret er en storbruker av naturen og etterlater spor både på land, i sjøen og i luften. Samtidig har Forsvarssektoren et stort samfunnsansvar når det kommer til å bevare og behandle Norges natur på en bærekraftige måte (Prop. 14 S, 2020, p. 123). For å nå FN's bærekraftsmål, som har til hensikt å blant annet stoppe klimaendringene innen 2030, er det viktig å finne innovative løsninger som kan implementeres i daglig drift (FN-sambandet, 2023). Ved at Forsvaret i større grad tar i bruk kunstig intelligens kan miljøet spares gjennom minnetid- og ressursbruk i planleggingsfasen, samt et mindre behov for fysisk rekognosering av terrenget.

Med bakgrunn i det identifiserte behovet fra Sjøforsvaret skal denne oppgaven utforske metoder og teknikker for å detektere bebyggelse. Dette skal gjøres ved hjelp av objekt-deteksjon i ortofoto av menneskeskapte strukturer i 100-metersbeltet. Målet er automatisk generering av vektordata for bygninger, naust og brygger. På denne måten kan det kartlegges, og kontinuerlig oppdateres,

bebyggelse langs hele Norges kystlinje, og dermed bidra til at kartgrunnlaget stemmer overens med virkeligheten.

1.1 Problemstilling

Basert på overnevnte skal oppgaven svare på følgende problemstilling:

Kan en ved bruk av kunstige nevralt nettverk detektere uregistrert bebyggelse i ortofoto, i 100-metersbeltet?

For å konkretisere oppgavens slutttilstand er det utarbeidet resultat- og effektmål for oppgaven. Effektmålene beskriver prosjektets hensikt, mens resultatmålene skal beskrive hva prosjektet skal oppnå (Stølen, 2019, s.37). Denne oppgavens effektmål er todelt. For det første skal oppgaven bidra til å øke forståelsen og potensialet som ligger i kunstig intelligens, og belyse noen av dets bruksområder for leseren. For det andre skal oppgaven bidra til innovative og bærekraftige løsninger for hvordan Forsvaret kan bearbeide data for å sikre et oppdatert kartgrunnlag, som i sum vil effektivisere og aktualisere beslutningsstøtten som GIS. Oppgavens resultatmål er å skape vektordata på bakgrunn av detekterte hus, naust og brygger i ortofoto, uregistrert så vel som registrert.

For å svare på problemstillingen skal det gjennomføres et eksperiment i ArcGIS. Først vil et treningsområde og et analyseområde bli lokalisert. Deretter skal det utnyttes ressurser som allerede eksisterer innenfor tematikken, ved å anvende eller modifisere etablerte dyplæringsmodeller, eller ved å lage egentrente modeller. Hensikten er å detektere hus, naust og brygger i 100-metersbeltet ved bruk av disse modellene.

1.2 Målgruppe

Målgruppen som er tiltenkt for denne oppgaven er hovedsakelig brukere som har gjennomført fordypning i militær geomatikk (MilGeo) ved Krigsskolen, eller tilsvarende. Det kreves ingen forkunnskaper innenfor kunstig intelligens for å forstå oppgaven, men det vil være fordelaktig med en grunnleggende kompetanse og forståelse innenfor geografiske informasjonssystemer (GIS). Oppgaven har tidvis et teknisk språk og anvender en terminologi hentet fra GIS.

1.3 Avgrensninger

Oppgaven avgrenser seg til bruk av ArcGIS Pro. Denne avgrensingen gjøres da fordypningen i MilGeo på Krigsskolen hovedsakelig benytter seg av dette verktøyet. Grunnet tid tilgjengelig er det vurdert at det vil være lite hensiktsmessig å lære seg et nytt verktøy for å løse problemstillingen.

Heller enn å lage to verktøy, ett for brygger og ett for bygninger, er det i denne i oppgaven utarbeidet ett felles verktøy for både brygger og bygninger i 100-metersbeltet. Dette er et resultat av behovet identifisert i Sjøforsvaret, der utfordringen er knyttet til generell bebyggelse i strandsonen. I Forsvaret er det et mål om at prosesser skal være så effektive som mulig, dette oppnås i større grad ved at Sjøforsvaret kun har ett verktøy å forholde seg til. Til tross for dette ville et naturlig arbeid videre være å splitte dette verktøyet, og dermed tilby flere muligheter til en økt brukergruppe.

I evalueringsfasen av oppgaven benyttes det et verktøy som utgir ulike statistiske verdier for deteksjonen som er gjort. I denne oppgaven er det sett bort ifra verdien *FI Score*. Dette er gjort da andre verdier i nøyaktighetsanalysen er ansett som tilstrekkelig for å vurdere deteksjonene opp mot problemstillingen. Videre er det sett bort fra *IoU*-verdi lavere enn 0,5 da dette er verdien som generelt benyttes (Tan, 2019).

1.4 Oppgavens oppbygning

I første del av oppgaven gjennomgås metodevalg og en redegjørelse for oppgavens teoretiske rammeverk. Deretter følger en gjennomgang av fremgangsmåten, oppfulgt av en presentasjon og diskusjon av resultatene. Siste del er en konklusjon og en beskrivelse av videre arbeid.

Kapittel 2 redegjør for metodevalg, og beskriver hvordan valgt metode er anvendt i denne oppgaven.

Kapittel 3 er en teoretisk gjennomgang av de mest vesentlige delene av prosjektet. Dette skal gi grunnleggende kunnskap slik at forståelsen for eksperimentet øker.

Kapittel 4 tar for seg oppgavens eksperiment. Her beskrives hva som ligger til grunn for gjennomføringen, samt hvordan eksperimentet er løst. Hensikten er å øke etterprøvbareheten gjennom en strukturert gjennomgang av hva som er gjort.

Kapittel 5 består av en presentasjon, samt en diskusjon av resultatene. I denne delen drøftes og sammenliknes resultatene og relevante parametere fra eksperimentene. Videre belyses svakheter ved oppgaven.

Kapittel 6 konkluderer problemstillingen og beskriver videre arbeid innenfor tematikken.

2 Metode

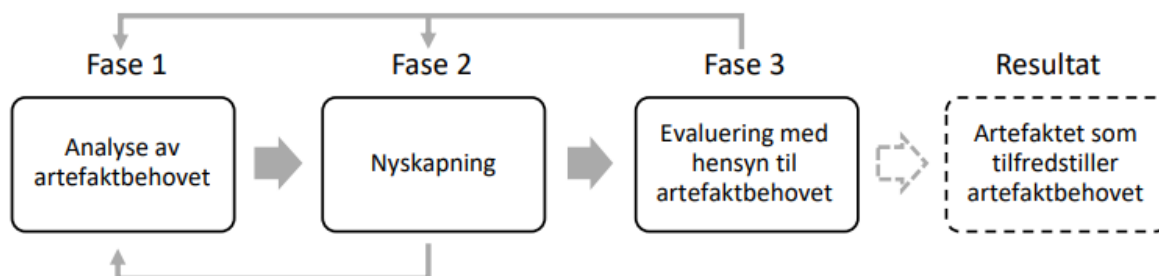
Dette kapittelet redegjør for metoden som er benyttet i oppgaven. Innledningsvis er det en teoretisk gjennomgang, for deretter en beskrivelse av hvordan denne metoden er anvendt for å løse problemstillingen.

Ettersom det i oppgaven fremstilles en ny metode for å detektere hus, naust og brygger i 100-metersbeltet, er teknologivitenskapelig metode valgt. Metoden har vokst frem som et resultat av at samfunnsvitenskap og naturvitenskap ikke egner seg for å forklare ny teknologiutvikling. Grunnleggeren, Ketil Stølen har definert en generell fremgangsmåte for å bidra til effektivitet og grundighet i arbeidet som gjøres (Stølen, 2019, pp. 1–2).

2.1 Teknologivitenskapelig metode

Stølen (2019, s.15) definerer teknologivitenskapelig metode som «vitenskap der man fokuserer på å utvide virkeligheten med nye eller vesentlig bedre artefakter», det dreier seg altså om å skape noe nytt basert på et behov. Stølen deler verden inn i to vitenskaper; forklaringsvitenskap og teknologivitenskap. Forklaringsvitenskap handler om å forklare, kartlegge og forstå dagens virkelighet, mens teknologivitenskap handler om å utvide dagens virkelighet (Stølen, 2019, p. 14).

For å skape nye artefakter har Stølen definert en fremgangsmåte for teknologivitenskap, som kan deles i 3 faser, vist i *Figur 1*. Utgangspunktet er et identifisert artefaktbehov. Dette behovet, eller ideen om en nyskaping, trenger ikke komme fra forskeren. Ofte er det enkeltpersoner eller organisasjoner som ytrer et behov, også blir det forskerens oppgave å skape eller forbedre et artefakt som svarer på dette behovet (Stølen, 2019, s.19).




Figur 1: Teknologivitenskapelig metode (Stølen, 2019, s. 20).

Første fase er en problemanalyse. I denne fasen skal artefaktbehovet identifiseres, og forskeren skal forstå problemet. Resultatet av denne fasen skal være en plan; en bestemt fremgangsmåte (Stølen, 2019, s. 35). I neste fase skal det skapes, lages eller oppfinnes et artefakt som svarer på artefaktbehovet. Denne fasen beskrives som den kreative delen av teknologiforskningen. Fase 3 innebærer å evaluere om artefaktet er tilfredsstillende nok, ofte i form av eksperimenter. Dersom evalueringen er positiv, kan forskeren konkludere med et sluttresultat der artefaktet tilfredsstiller artefaktbehovet. Dersom resultatene ikke er tilfredsstillende, må en gå tilbake i prosessen og enten justere problemanalysen eller utvikle nye artefakter (Stølen, 2019, s. 20).

2.2 Metode anvendt i denne oppgaven

Kapittel 1 er på mange måter et resultat av Stølenes første fase; analysen av artefaktbehovet. Ideen om nyskapningen presentert i denne oppgaven er basert på at noen avdelinger i Sjøforsvaret har identifisert et behov for å kartlegge bebyggelse i 100-metersbeltet, i forbindelse med landsettingsoperasjoner. Stølen (2019, s. 36) beskriver at forskerne i denne fasen kan bryte opp problemet, og dermed skape en dypere forståelse av hva det innebærer. Problemstillingen; *Kan en ved bruk av kunstige nevralt nettverk detektere uregistrert bebyggelse i ortofoto, i 100-metersbeltet?* og målene for oppgaven, som presentert i innledningen, kan konkretiseres til et artefaktbehov: *En modell som ved bruk av kunstige nevralt nettverk i ArcGIS detekterer uregistrerte hus, naust og brygger i 100-metersbeltet i Norge, og genererer vektordata av resultatene.*

I fase 2 skapes selve artefaktet som en løsning på artefaktbehovet. I grovt går det ut på å anvende, modifisere eller skape modeller i ArcGIS som detekterer hus, naust og brygger. Det betyr at artefaktet i denne oppgaven er et digitalt artefakt, altså noe menneskeskapt i den virtuelle verden (EMU, Danmarks læringsportal, 2022). Selve nyskapningen kan forstås som en digital prosess, vist i *Figur 2*. Resultatene fra det første steget anvendes inn i det neste, og målet er å lokalisere uregistrert bebyggelse i 100-metersbeltet.



Figur 2: Nyskapningen er en prosess som detekterer hus, naust og brygger.

For å evaluere nyskapningen gjennomføres det et eksperiment i ArcGIS. Eksperimentet går ut på å teste modeller som kan svare på artefaktbehovet. Dette eksperimentet kan deles i tre steg:

1. Teste en ferdigtrent ESRI-modell.
2. Hvis steg 1 ikke tilfredsstillende: Modifisere ESRI-modellen.
3. Hvis steg 2 ikke tilfredsstillende: Lage en egentrent modell.

Bebyggelsen som detekteres i modellene kan være registrert så vel som uregistrert, ettersom en ved å fastslå at modellen klarer å detektere bebyggelse generelt vil kunne lokalisere uregistrert bebyggelse spesifikt. Ettersom modellen ikke vet om bebyggelsen den detekterer er registrert eller uregistrert vil det ikke være et poeng i seg selv å kun teste modellene på uregistrert data. Dersom steg 1 eller steg 2 er tilfredsstillende så avsluttes eksperimentet. Dersom steg 3 ikke er tilfredsstillende så konkluderer oppgaven med at artefaktbehovet ikke blir tilfredsstilt.

For å svare på om nyskapningen er tilfredsstillende vil modellene vurderes i to steg. Første del er en nøyaktighetsanalyse i ArcGIS. Her klippes analyseresultatene til 100-metersbeltet, og det benyttes et verktøy til å generere en tabell som inneholder statistisk informasjon om nøyaktigheten til resultatene av analysen. Verktøyet beregner nøyaktigheten ved å sammenligne deteksjonen med et annet datasett definert som sannheten (ESRI, no date b). Dersom resultatet er tilfredsstillende, går evalueringen over i siste del.

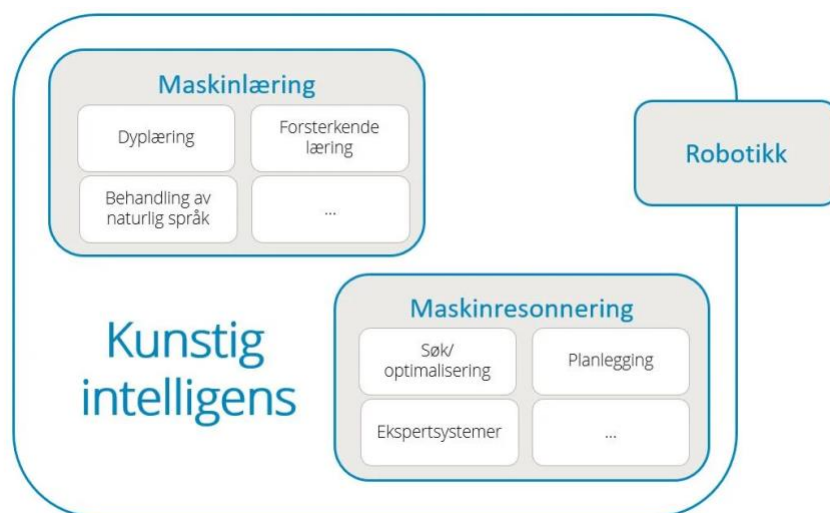
Siste del av evalueringen gjennomføres som en datasimulering, som vil si at artefaktet testes ved bruk av et dataprogram (Stølen, 2019, p. 54). For å belyse problemstillingen fra flere synsvinkler benyttes det Stølen (2019, p. 56) definerer som metodetriangulering type 2. Det vil si at undersøkelsen er gjennomført med samme oppsett, men med andre ekvivalente variasjoner. I denne oppgaven innebærer det at modellen som gir tilfredsstillende resultater i nøyaktighetsanalysen vil bli testet på nye kystlokasjoner, da også lokasjoner som inneholder uregistrert bebyggelse. Målet med denne delen er å teste modellen på ulike områder for å se om resultatet fremdeles blir tilfredsstillende. For å oppsummere vil det si at alle modellene vil evalueres ved hjelp av en nøyaktighetsanalyse, men kun den modellen som gir tilfredsstillende resultater i nøyaktighetsanalysen vil bli testet på nye lokasjoner.

3 Teori

I dette kapitlet beskrives oppgavens teoretiske rammeverk. Det vil inneholde en redegjørelse av kunstig intelligens, samt av maskinlæring og kunstige nevrale nettverk. Hvorav de to sistnevnte kan forstås som undergrupper av kunstig intelligens. Videre redegjøres det for hva GIS, felles kartdatabase (FKB) og ortofoto er. Avslutningsvis beskrives nøyaktighetsanalysen, og hvordan resultatene fra deteksjonen måles.

3.1 Kunstig intelligens

Det har lenge vært et naturlig skille på hva en datamaskin kontra et menneske kan gjøre. Nyere utvikling innenfor blant annet kunstig intelligens gjør dette skillet mindre åpenbart. FFI hevder at denne utviklingen har kommet så langt at maskiner snart vil kunne fatte beslutninger på vegne av mennesket (Beadle *et al.*, 2019, p. 51). Ifølge en gruppe, utpekt av EU-kommisjonen i 2018, så er kunstig intelligens systemer som utviser intelligent oppførsel ved å analysere og reagere på sine omgivelser for å oppnå en gitt målsetting (European Commission, 2020). Kunstig intelligens kan dermed forstås som en verktøykasse som kan anvendes til å løse komplekse problemer, som tidligere har vært knyttet til menneskelig intelligens. Dette kan for eksempel være evnen til resonnering, planlegging og læring. Kommunal- og moderniseringsdepartementet (2020) deler kunstig intelligens inn i undergruppene maskinlæring, maskinresonnering og robotikk, slik *Figur 3* viser:



Figur 3: Forenklet oversikt over hva som inngår i kunstig intelligens (European Commission, 2020).

Denne oppgaven tar for seg maskinl ring, med spesielt fokus p  kunstige nevr le nettverk. Den avgrens r seg dermed bort fra maskinresonnering og robotikk. Maskinl ring er en form for datadrevet kunstig intelligens, som vil si at modellene ikke har forh ndsprogrammerte regler, men at modellene l rer seg disse reglene p  egenh nd (Tidemann and Elster, 2021).

3.1.1 Maskinl ring

Maskinl ring utnytter en l ringsalgoritme ved hjelp av statistikk. Denne algoritmen utf rer en oppgave og m ler resultatet. Dersom et sett av treningsdataen kan forbedre resultatet, kan en si at algoritmen har l rt av erfaringen (Goodfellow, Bengio and Courville, 2016, p. 95). If lge Tidemann & Elster (2021, para. 1) s  er maskinl ring definert som «en spesialisering innen kunstig intelligens hvor man bruker statistiske metoder for   la datamaskiner finne m nstre i store datamengder».

Det finnes flere m ter   trene opp en modell, og en m te   kategorisere denne treningen p  er ved hjelp av begrepene *veiledet l ring* og *ikke-veiledet l ring* (Goodfellow, Bengio and Courville, 2016, p. 95). Veiledet l ring g r ut p  at en trener maskinen til   gjenkjenne riktig data ved   gi den riktig svar, og er mye brukt innenfor bildeklassifisering (Hastie, Tibshirani and Friedman, 2017, p. 29). Ikke-veiledet l ring g r ut p  at maskinen selv l rer seg   gjenkjenne riktig data i store datamengder ved   strukturere eller oppdage m nstre (Bayr, 2020, p. 3). Dette er mye brukt innenfor eksempelvis kundegrupperinger og reklametilpasninger.

Volum og kvalitet p  treningsdataen som anvendes til   trene modellen vil ha betydning for resultatet. En statistisk modell kan ikke gi bedre vurderinger enn treningsdataene har gitt den grunnlag for. Anta for eksempel en modell med hensikt   gjenkjenne hunder i bilder. Modellen blir god til   gjenkjenne *hunder* dersom den blir presentert for tilstrekkelig mange bilder av ulike raser, st rrelser, farger etc. Da kan modellen l re at en hund kan v re liten eller stor, den kan h re som st r opp eller henger ned, og den kan v re i ulike farger. P  denne m ten kan modellen bli generell. Dette betyr at ved   kun trene modellen p  store, svarte labradorer vil ikke modellen forst  at en liten terrier ogs  er en *hund*. Dersom treningsdataene for hund generelt ikke inneholder et merket bilde av en dalmatiner, kan heller ikke den ferdigtrente modellen predikere «dalmatiner» i et testbilde. Ved   s rge for at modellen blir generell, unng s det som kalles for *overtilpasning*. Dette vil si at en modell er trent for spesifikt, og dermed ikke klarer   gjenkjenne


objekter med mindre de er bortimot identiske med de dataene den er trent på (Makhlysheva *et al.*, 2018, p. 2).

Å oppdage bygningsobjekter i flyfoto er spesielt utfordrende selv med svært presis og nøyaktig data. Tak, som primært er det som synes fra luften, har mange ulike former, materialer, størrelser, farger etc. I tillegg til slike byggestil-relaterte faktorer kan maskinlæringen møte optiske utfordringer som ulik belysning, refleksjon og vinkler. Ortofotoet kan også inneholde støy som eksempelvis kraftledninger og vegetasjon. I sum gjør dette det særlig vanskelig for modeller å gjenkjenne bygningsobjekter (Schlosser *et al.*, 2020, p. 2). Dette understreker viktigheten av volum og kvalitet på treningsdataen som benyttes.

3.1.2 Kunstige nevralt nettverk

Slik mennesket tar beslutninger basert på kunnskap og opparbeidet erfaring kan også en maskin gjøre noe av det samme, blant annet ved hjelp kunstige nevralt nettverk. Dette er et kunstig nettverk som minner mye om nettverket i den menneskelige hjernen.

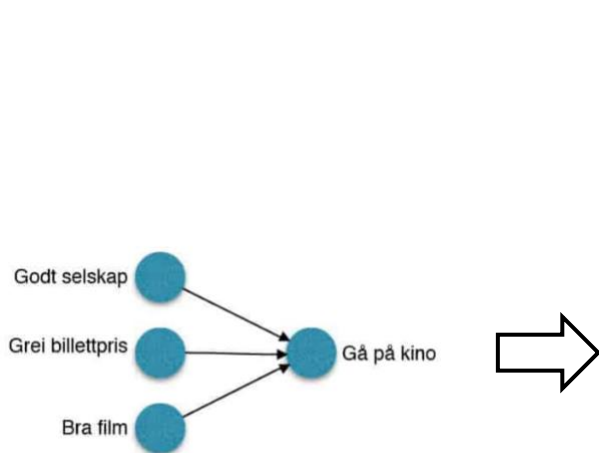
Kunstige nevralt nettverk er bygget opp lagvis av grupper av nevroner. Nettverket er satt sammen av et input- og outputlag, og kan også inneholde ett eller flere skjulte lag, slik *Figur 4* viser. Dersom det nevralt nettverket inneholder flere slike skjulte lag, regnes det som dyplæring (Datatilsynet, 2018, p. 13).



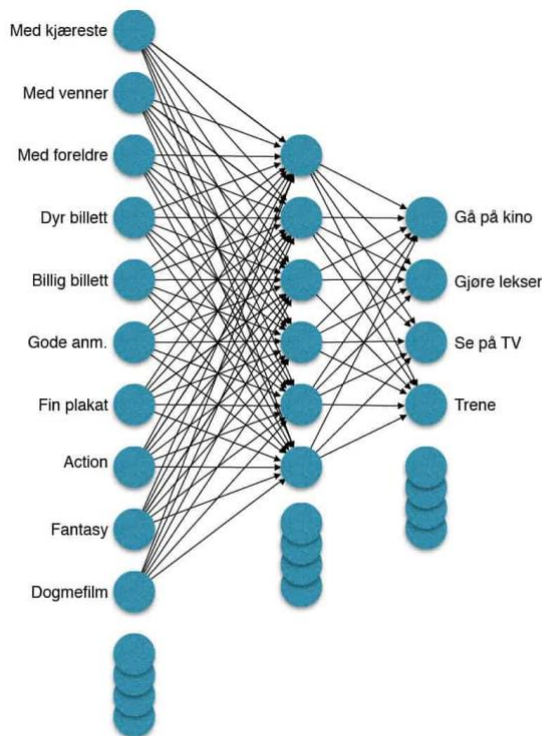
Figur 4: Kunstig nevralt nettverk (Datatilsynet, 2018, p. 13).

Et trent kunstig nevralt nettverk har evnen til å generalisere og trekke ut karakteristiske egenskaper ved objekter (Nilsen, 2021, pp. 14–16). I dyplæring blir slike kunstige nevralt nettverk brukt til å finne skjulte relasjoner og foreta prediksjoner (Microsoft Azure, no date).

Figur 5 viser et kunstig nevralt nettverk bestående av et input- og outputlag. Outputlaget «Gå på kino» påvirkes av tre ulike argumenter. Alle argumentene er såkalte ja/nei-argumenter, som vil si at de enten gir full uttelling eller ingen uttelling. Argumentene kan ha ulik verdi, og dermed påvirke resultatet ulikt. Eksempelvis kan et individ veie godt selskap lik 12 poeng, grei billettpris lik 7 poeng og bra film lik 6 poeng. Det vil si at dersom individet svarer ja på alle de tre argumentene så vil individet ha en uttelling på totalt 25 poeng. For at resultatet skal bli «Gå på kino» så har dette individet definert et minstekrav lik 10 poeng. I teorien vil det si at så lenge individet har godt selskap trenger ikke billettprisen å være grei eller filmen å være bra. Hvis det derimot er dårlig selskap er individet avhengig av at både billettprisen er grei og at filmen er bra for å gå på kino (Dvergsdal, 2019).



Figur 5: Et kunstig nevralt nettverk (Dvergsdal, 2019).



Figur 6: Flere lag i et kunstig nevralt nettverk (Dvergsdal, 2019).

Figur 6 viser hvordan flere lag i et kunstig nevralt nettverk kan kombineres for å bestemme hva et individ skal gjøre. Ved å bruke maskiner og trene opp slike kombinerte kunstige nevralt nettverk kan maskinlæring benyttes til å ta intelligente beslutninger (Dvergdsdal, 2019).

Et bruksområde innenfor kunstige nevralt nettverk er objektdeteksjon i bilder. En modell kan trenes opp til å selvstendig gjenkjenne bestemte objekter. For å trene modellene kan det lages ett omriss rundt relevante objekter, eller det kan anvendes ferdig vektordata. En trent modell vil da være i stand til å selvstendig detektere et objekt, men resultatet vil avhenge av modellens treningsmengde. Eksempelvis kan det være vanskelig å skille brygge fra båt da disse, som vist i Figur 7, ser relativt like ut ovenfra. Når det kunstige nevralt nettverket, i en ferdigtraint modell, har lært seg å gjenkjenne brygger klarer det likevel å skille ut de helt spesielle kjennetegnene til en brygge.



Figur 7: Det kan være vanskelig å skille brygge og båt, men ved hjelp av trening klarer det kunstige nevralt nettverket å finne særegne kjennetegn for brygger.

3.2 Geografiske informasjonssystemer (GIS)

Det er flere ulike definisjoner på GIS. I boken *GIS – Geografiens språk i vår tidsalder* står det:

«Et geografisk informasjonssystem (GIS) er sammensetningen av geografiske data, kartsystemer, metoder og menneskelig kunnskap og erfaring som gjør det mulig å samle inn, bearbeide, analysere og presentere geografien rundt oss» (Grinderud *et al.*, 2016, p. 17).

Basert på dette kan et GIS forstås som et sammensatt system for å samle inn og bearbeide geografisk informasjon, og den menneskelige kunnskapen muliggjør en visualisering av denne

informasjonen. Ut fra denne definisjonen anses GIS å være til stor hjelp for å gi beslutningsstøtte.

I Forsvaret brukes GIS som et verktøy for blant annet kommunikasjon, beslutningsstøtte og planlegging. Det finnes flere ulike typer GIS, og ArcGIS er primærverktøyet til MilGeo i Forsvaret. Ifølge Geodata (u.å.) er ArcGIS «markedets kraftigste BildeGIS-verktøy med unike funksjoner for effektiv dataforvaltning, avanserte geografiske analyser og kraftfull visualisering». Environmental Systems Research Institute (ESRI) er en internasjonal leverandør av geografiske informasjonssystemer, herunder ArcGIS, og de hevder at ArcGIS er første steg i retningen mot klokere beslutningstaking (ESRI, u.å.-a).

3.3 Felles kartdatabase (FKB)

FKB er en samling av detaljert basis geodata over hele Norge. Det vil si grunnleggende data, som mange brukere har behov for til en rekke ulike formål (Miljøverndepartementet, 2003, p. 8). Til militært bruk er FKB-data derfor mye benyttet som kartgrunnlag under lendeanalysen. Det er en omfangsrik database som kan være til stor nytte når en MilGeo skal lokalisere muligheter og begrensninger i lendet, og benyttes i alle steg av lendeanalysen.

Nøyaktighet varierer på tvers av datasettene i databasen, avhengig av område. Eksempelvis stilles det strengere nøyaktighetskrav til byområdene enn fjellandskapene. Sonene deles i fire, fra sone A til og med sone D. Sone A dekker sentrale byområder, og her er kravene til stedfestningsnøyaktighet og detaljgrad svært høy, da det brukes til svært presis planlegging. Resterende soner får gradvis lavere krav til nøyaktighet. Sone D, som er områder med manglende infrastruktur, har de laveste kvalitetskravene (Geovekst, 2020, pp. 13–15). For å vurdere kvaliteten på FKB-datasettene, som er benyttet i denne oppgaven, vil faktorene *troverdighet*, *ajourføring*, *nøyaktighet* og *fullstendighet* bli brukt. Disse faktorene for datakvalitet er hentet ut ifra *GIS – Geografiens språk i vår tidsalder* (Grinderud *et al.*, 2016, p. 61).

Geovekst er et samarbeid som sørger for felles etablering, forvaltning, drift, vedlikehold og bruk av geografisk informasjon, herunder FKB-data (Geovekst-forum, 2022). FKB oppdateres jevnlig ved hjelp av flyfotografering, oppmåling, samt daglige, administrative rutiner (Granum, 2020). Et eksempel på slike administrative rutiner er byggesaksbehandlinger. På bakgrunn av de gode rutinene og den jevnlige oppdateringen regnes ofte FKB som primærdata. Det vil si det datasettet

som består av den mest detaljerte og nøyaktige dataen innenfor et definert område, har en viss utbredelse og jevnlig blir ajourholdt (Geovekst, 2020, p. 19). FKB-databasen inneholder totalt 17 ulike datasett, men i denne oppgaven benyttes kun FKB-Bygning og FKB-BygnAnlegg.

FKB-BygnAnlegg er et datasett over menneskeskapt objekter som ikke kategoriseres som bygning eller vei. FKB-Bygning er et datasett over bygninger i Norge som lages basert på Matrikkelen (Geovekst, 2016b, p. 12, 2016a, p. 12).

3.4 Ortofoto

Ifølge O'Sullivan og Miller (2015, p. 22) brukte amerikanske styrker flyfoto heller enn kart under Vietnamkrigen grunnet de konstante, store endringene i terrenget. I dag er flyfotografering en av de vanligste formene for datafangst, og er mye benyttet innenfor GIS (Grinderud *et al.*, 2016, p. 54).

Flyfoto som har gjennomgått en prosess slik at bildet stemmer overens med kartet kalles for ortofoto (Kartverket, 2021). Denne prosessen sørger for at ortofotoet har samme geometriske egenskaper som et kart, og er knyttet til et koordinatsystem. Foto som benyttes til ortofoto er tatt med et kamera i sentralprojeksjon, altså at kameraet peker rett ned mot bakken. Når flyfoto korrigeres slik at det er lik målestokk i hele bildet og objektene kommer på samme sted som i kartet, endres projeksjonen til å være ortogonalprojeksjon. Dette er samme projeksjon som benyttes i kart, og derfor kan ortofoto erstatte eller supplere bruken av kart (Grinderud *et al.*, 2016, s. 55). Det er likevel slik at et ortofoto kan ha et visst standardavvik. Dette avviket avhenger av bildets oppløsning. For eksempel kan et ortofoto i Norge med oppløsning på 10 centimeter ha et avvik på opptil 1,5 meter (Trollvik, 2020, p. 22). Dette er derfor et viktig avvik å ha kjennskap til når stedfestingsnøyaktighet i et ortofoto skal vurderes.

Flyfoto er et raster. Det vil si at bildet består av rader og kolonner, som deler bildet inn i et rutenett. Hver rute innehar unik informasjon og kalles for en piksel. Pikselstørrelsen for rastermodellen sier noe om hvor god oppløsning bildet har. Jo større pikselstørrelse- desto lavere oppløsning, og motsatt (Grinderud *et al.*, 2016, s. 48). Dette er vist i *Figur 8*:



Pikselstørrelse= 1m.



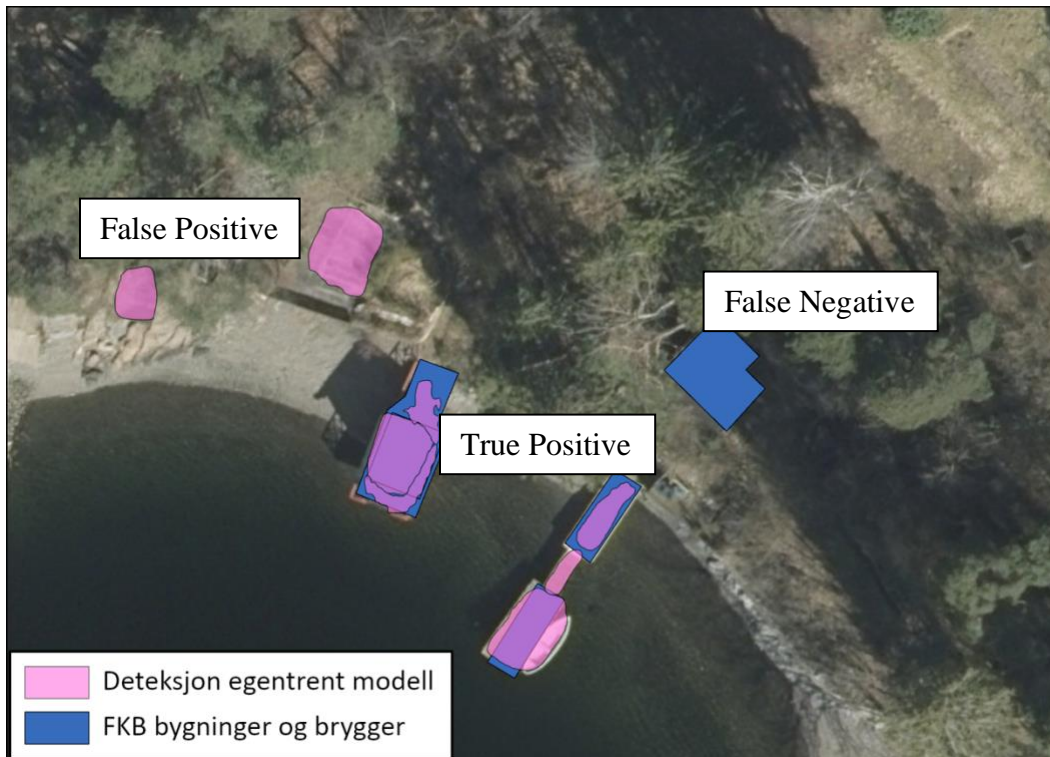
Pikselstørrelse= 0,1m.

Figur 8: Større pikselstørrelse gir lavere oppløsning.

Bildene i *Figur 8* er over akkurat samme område og med lik målestokk, men med ulik pikselstørrelse. Som bildet til høyre viser, vil liten pikselstørrelse og derav høy oppløsning vise flere detaljer. Den høye oppløsningen vil samtidig gjøre at bildet inneholder mer data, noe som kan føre til at prosesseringstiden øker (Grinderud *et al.*, 2016, pp. 48–49).

3.5 Mål for treffsikkerhet

«Et nevralt nettverk vil alltid kunne klassifisere et objekt. Det fins imidlertid ingen garanti for at klassifiseringen er riktig» (Nilsen, 2021, p. 14). For å kontrollere dette evalueres deteksjonene i etterkant. Dette gjøres ved å måle antall *True Positive*-, *False Positive*- og *False Negative*-verdier. True Positive vil si at deteksjonen har detektert et objekt som stemmer overens med datasettet definert som sannheten. False Positive betyr at deteksjonen registrerer et objekt som ikke er registrert i datasettet definert som sannheten. False Negative vil si at deteksjonen ikke klarer å detektere objekter. Dette er visualisert i *Figur 9*:



Figur 9: Eksempel på hva True Positive, False Positive og False Negative kan være.

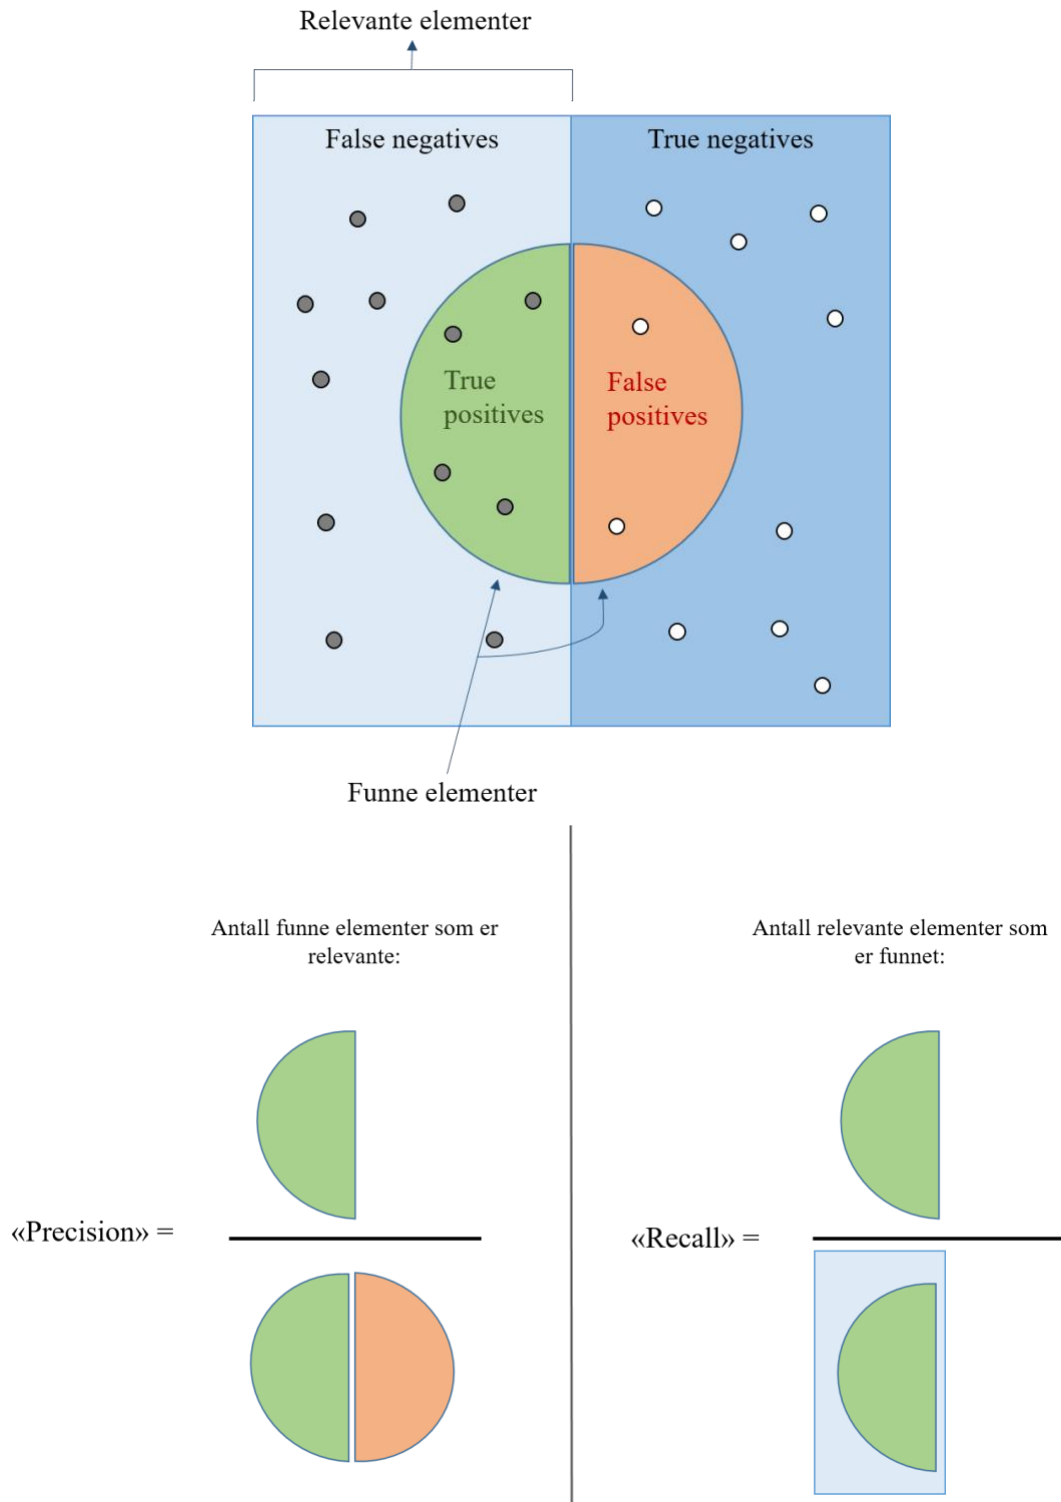
Disse verdiene anvendes til å beregne modellenes *Precision*- og *Recall*-verdier, som vist i Figur 10:

$$\mathbf{Precision} = \frac{\mathbf{True\ Positive}}{\mathbf{True\ Positive} + \mathbf{False\ Positive}}$$

$$\mathbf{Recall} = \frac{\mathbf{True\ Positive}}{\mathbf{True\ Positive} + \mathbf{False\ Negative}}$$

Figur 10: Formler for Precision og Recall (Riggio, 2019).

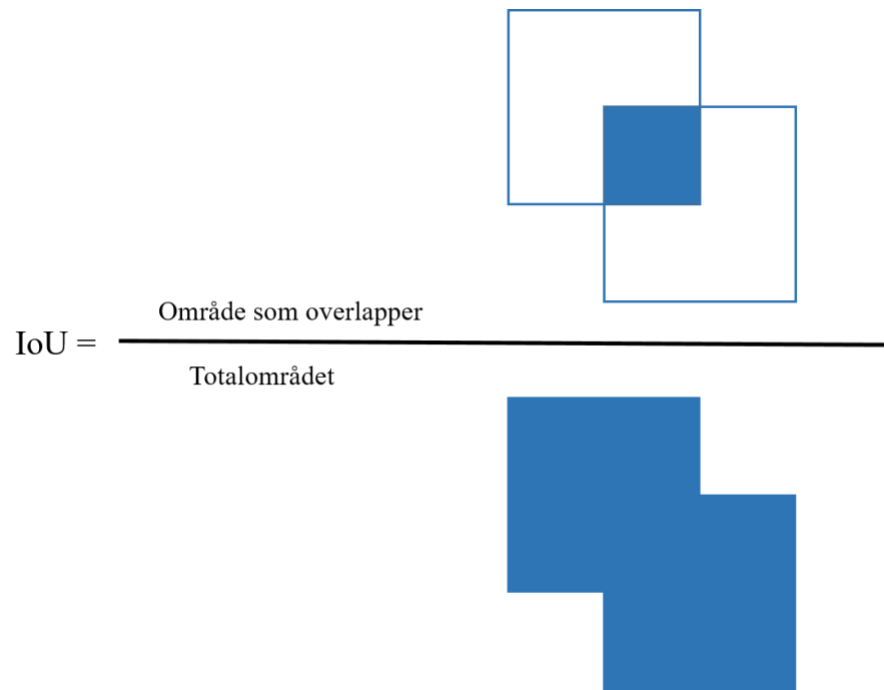
Precision forteller hvor stor andel av de detekterte objektene som er True Positive, altså korrekte. Recall beskriver hvor mange korrekte deteksjoner som er gjort i forhold til datasettet definert som sannheten, og forteller på så måte hvor mange objekter som ble detektert av antall mulige. Disse to verdiene brukes også til å beregne modellens gjennomsnittlige presisjon, kalt *Average Precision* (AP) (Riggio, 2019). Precision og Recall er visuelt fremstilt i Figur 11:



Figur 11: Visuell fremstilling av Precision og Recall. Figur etter Christoffer Riggio (Riggio, 2019).

Disse verdiene produseres i verktøyet *Compute Accuracy For Object Detection* i ArcGIS. I verktøyet sammenlignes deteksjonen med et annet, antatt virkelighetsnært datasett.

For å bestemme hvor mye av deteksjonen som må overlape med datasettet definert som sannheten, settes det en *Intersect over Union* (IoU)-verdi. IoU-verdien avgjør om nøyaktighetstesten skal klassifisere deteksjonen som True Positive. Det vil si at hvis IoU-verdien er satt til 0,5 må størrelsen på overlappen delt på begge polygonene samlet, overstige 0,5 (Riggio, 2019). Dette er visualisert i *Figur 12*:



Figur 12: Visuell fremstilling av IoU. Figur etter Christoffer Riggio (Riggio, 2019).

4 Eksperiment

I dette kapittelet forklares innledningsvis hvilke forutsetninger som ligger til grunn for gjennomføringen av eksperimentet, dette inkluderer en beskrivelse av de mest sentrale verktøyene i oppgaven. Deretter følger en introduksjon av analyseområdet, og avslutningsvis et delkapittel som gjennomgår fremgangsmåten til eksperimentet. Resultatene fra fremgangsmåten er beskrevet i *kapittel 5 Resultater og diskusjon*.

4.1 Forutsetninger

Hensikten med dette delkapitlet er å presentere forberedelsene til eksperimentet som skal evaluere nyskapingen. Det vil si en beskrivelse av hva som må gjøres før modellene kan anvendes i ArcGIS. Innledningsvis beskrives datamaskinen, samt datasettene som er benyttet under eksperimentet. Deretter følger en gjennomgang av sentrale forberedelser knyttet til dyplæring i ArcGIS, inkludert en beskrivelse av dyplæringsverktøyene benyttet i oppgaven.

4.1.1 Maskinvare

Ifølge ESRI (no date a) er det anbefalt å ha en datamaskin med minst 8 gigabyte (GB) Random Access Memory (RAM) dersom dyplæringsverktøyene i ArcGIS skal brukes. I dette eksperimentet er det benyttet en datamaskin med 16 GB RAM. Prosessoren på datamaskinen har seks kjerner med klokkehastighet 2,60 gigahertz (GHz).

4.1.2 Datasett

I denne delen blir datasettene som er benyttet i oppgaven beskrevet. Det er FKB-data, data over kystkontur, samt ulike ortofoto.

FKB-data anvendes hovedsakelig til to oppgaver. For det første benyttes *FKB-Bygning* og *FKB-BygnAnlegg* til å trene dyplæringsmodellene. Oppgaven benytter dermed veiledet læring i form av at datasettet *FKB-Bygning* anvendes til å trene modellene på bygninger, og tilsvarende brukes *FKB-BygnAnlegg* til å trene modellene på brygger. For det andre anvendes FKB-data til å evaluere resultatene, ettersom avdelingene som ønsker svar på problemstillingen primært bruker

FKB-data i sine analyser. FKB defineres dermed til sannheten, og dersom modellene samsvarer med FKB-dataen anses modellene som virkelighetsnære.

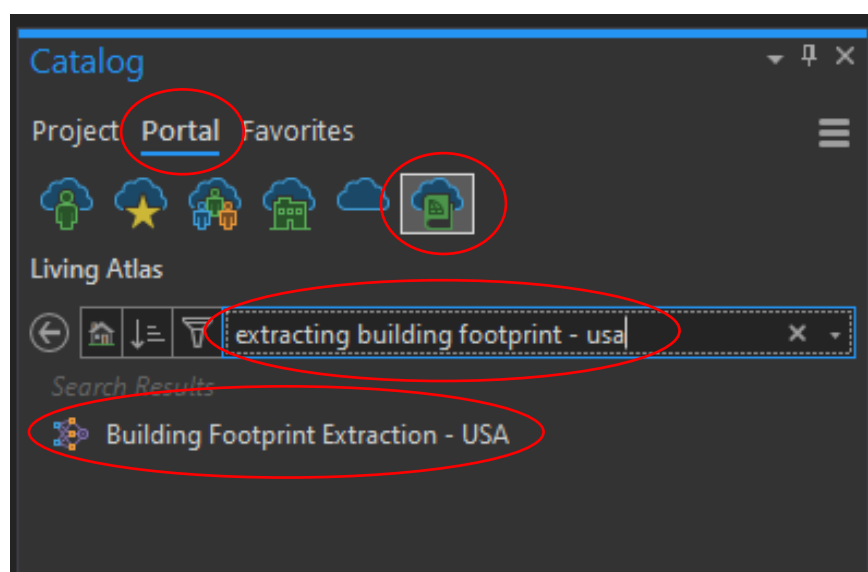
For å begrense funnene til 100-metersbeltet er datasettet *Sjøkart-Dybde* lastet ned. Dette er et datasett levert av Geonorge som inneholder data over Norges kystlinje, kalt kystkontur. Kystkontur er definert som middel-høyvann (Kartverket, 2020, p. 7). Videre er det gjort en buffer på 100 meter, slik at resultatene kan tilpasses det relevante området. En fordel med denne begrensningen er også kortere prosesseringstid.

I denne oppgaven er det benyttet ortofoto over Oslo-området, samt over et område i Bodø. Bildene er en del av Kartverket sitt prosjekt; *Norge i bilder*, og er eid av henholdsvis Oslo kommune og Geovekst. Begge bildene har en pikselstørrelse lik 0,1 meter. Bildene over Oslo er tatt 31.03.2020, og bildet over Bodø er tatt 25.05.2014. Ettersom dyplæringsmodellene i ArcGIS er laget med bakgrunn i å kunne detektere bygninger en kan se med det blotte øyet, bør bildene være av så god kvalitet at en lett kan gjenkjenne hus. For å oppnå dette bør bildene ha en oppløsning, det vil si en pikselstørrelse mellom 0,1 og 0,4 meter (Alouta and Hess, 2021). Dersom pikselstørrelsen overskrider dette vil nøyaktigheten og detaljnivået bli såpass lavt at det blir vanskelig for maskinen å dra kjensel på objektene, samt plassere dem riktig. I denne oppgaven er det derfor benyttet ortofoto med en pikselstørrelse i dette intervallet.

4.1.3 ArcGIS

Før en kan benytte seg av ArcGIS sine dyplæringsverktøy må en ha *Image Analyst License*, og såkalte bibliotek må lastes ned (ESRI, no date f). ArcGIS trenger et nytt bibliotek for å «vite» hvordan det skal reagere på kommandoene i dyplæringsverktøyene. Dyplæringsverktøyene i ArcGIS er implementert i Python og benytter forskjellige kjente biblioteker for maskinlæring, som for eksempel Tensorflow, PyTorch og Keras. ESRI har samlet alle de nødvendige pythonpakkene til et rammeverk som kan lastes ned og installeres av brukeren (ESRI, 2021b). Bibliotekene kan en finne på ArcGIS sine nettsider ved å søke på *Deep Learning Frameworks For ArcGIS*. Det er viktig at en laster ned biblioteket som er kompatibel med ArcGIS-versjonen som benyttes. Siden det i denne oppgaven er benyttet ArcGIS Pro 2.8.2 er biblioteket *Deep Learning Libraries Installer For ArcGIS Pro 2.8* lastet ned, og benyttet.

Når bilder skal analyseres i ArcGIS kan det benyttes ferdigtrente dyplæringsmodeller som ESRI har publisert, eller en kan skape nye modeller (ESRI, no date e). Ved bruk av ESRI sine ferdigtrente modeller kan en detektere objekter som modellen er trent til å gjenkjenne. I denne oppgaven anvendes modellen *Building Footprint Extraction – USA*. Dette er en modell som er trent til å detektere bygninger i et bilde. Modellen er trent på bygninger fra USA. Ifølge ESRI (2021a) viser denne modellen til en AP-verdi på 71,8%, noe som vurderes til å være et godt resultat. Etersom byggestilen i USA og Norge er relativ lik anses det som mulig å implementere modellen til et norsk landskap. Denne modellen kan en finne ved å søke i ArcGIS sin portal *Living Atlas* og laste ned .dlpk filen, som vist i *Figur 13*:




Figur 13: Viser hvordan en kan laste ned ESRI-modellen i ArcGIS.

Disse ferdigtrente modellene kan også retrenes og modifiseres, og da skapes en ny modell basert på den ferdigtrente. Eventuelt kan modellen trenes opp, for å i større grad påvirke hva som skal detekteres i bildet.

4.1.4 Dyplæringsverktøy i ArcGIS

Dette delkapittelet har til hensikt å redegjøre kort for de tre dyplæringsverktøyene som anvendes i eksperimentet, samt de parametrene som anses å påvirke denne oppgavens artefaktbehov i størst grad. Hensikten er å danne en grunnleggende forståelse for de mest sentrale verktøyene i eksperimentet, og på den måten øke etterprøvnbarheten. For en mer detaljert gjennomgang se *Vedlegg A- Dyplæringsverktøy i ArcGIS*.

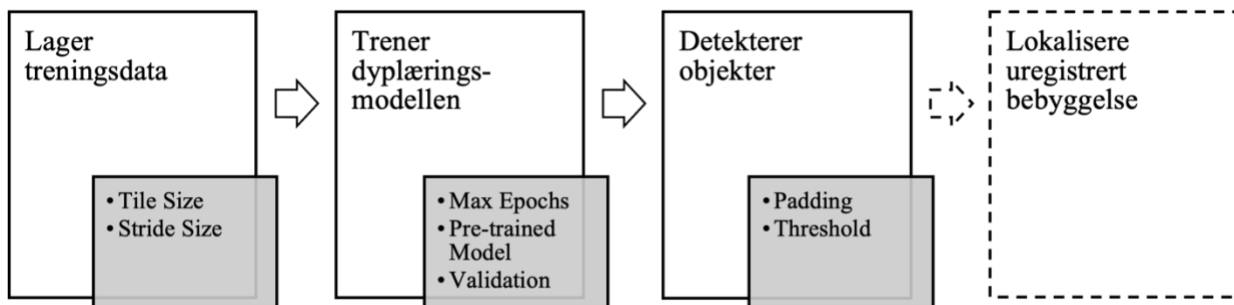
De tre første stegene i nyskapingen, som vist i *Figur 14*, løses ved å benytte ulike dyplæringsverktøy i ArcGIS. Som beskrevet tidligere anvendes resultatene fra det ene verktøyet inn i det neste.



Figur 14: Hvert av de ulike stegene løses ved hjelp av et dyplæringsverktøy i ArcGIS.

For å lage treningsdata anvendes *Export Training Data For Deep Learning*. Dette er et verktøy som bruker ortofoto og eksisterende vektordata til å lage treningsdata (ESRI, no date c). I denne oppgaven er det valgt ut et område som et definert treningsområde. Fra dette området er vektordata over brygger og bygninger konvertert til treningsdata. Verktøyet lager såkalte *chips*, som vil si mindre bilder av ortofotoet med tilhørende informasjon. Når chipsene lages klippes bildet opp på en symmetrisk måte, og det tas ikke hensyn til hvor vektordataen er plassert (ESRI, no date c). For å trene dyplæringsmodellen er *Train Deep Learning Model* brukt. Dette verktøyet anvender chipsene med treningsdataen til å trene en modell (ESRI, no date h). Resultatet er en ny modell. Deretter benyttes *Detect Objects Using Deep Learning*. Dette verktøyet benytter dyplæringsmodellen til å detektere objekter i et raster (ESRI, no date b). Etter at deteksjonen er gjennomført produseres det vektordata over de detekterte objektene.

For hvert av de ulike stegene i prosessen har ulike parametere i dyplæringsverktøyene blitt justert, for å påvirke resultatet. Disse parameterne er vist i *Figur 15*:



Figur 15: Parametere som justeres underveis i prosessen.

De ulike parameterne vil nå bli gjennomgått slik at leseren har forutsetninger til å forstå de tilpasningene som senere blir presentert. Innledningsvis bestemmes *Tile-* og *Stride Size*,

henholdsvis rutestørrelse og overlapp. *Tile Size* angir hvilken størrelse hver treningschip skal ha, mens *Stride Size* angir hvor stort overlapp det skal være mellom chipsene (ESRI, no date c).

Max Epochs angir hvor mange ganger treningsdatasettet gjennomgås, altså antall treningsepoker. Dette påvirker hvor godt trent modellen blir. *Pre-trained Model* åpner opp for å bruke allerede ferdigtrente modeller, slik som *Building Footprint Extraction – USA* benyttes i denne oppgaven. Dersom *Pre-trained Model* ikke anvendes må *Model Type* og *Backbone Model* velges. *Model Type* bestemmer hva slags type kunstige nevralt nettverk som skal benyttes. *Backbone Model* er det forhånds konfigurerte kunstige nevralt nettverket som benyttes for å trene en ny modell. I parameteren *Validation* bestemmes andelen treningsdata som skal brukes til å validere resterende treningsdata. Denne andelen benyttes da ikke til å trene modellen (ESRI, no date h).


Padding bestemmer antall piksler som skal ignoreres fra kantene i en chip under deteksjonen. Ved å stille inn maskinen til å ignorere ytterkantene, altså høyere *Padding*, vil de objektene som havner i ytterkantene av chipsene ikke bli valgt. Dette hindrer modellen i å detektere halve objekter. *Threshold* bestemmer konfidensnivå på resultatet. Default-verdien er 0,9 som tilsvarer 90%. Det vil si at modellen må, med minst 90% sikkerhet, kunne fastslå at deteksjonen er korrekt (Alouta and Hess, 2021).

4.2 Lokalisere analyseområde

Ettersom artefaktbehovet er å skape en modell som finner uregistrerte hus, naust og brygger i ortofoto over 100-metersbeltet må analyseområdet være i kystsonen, og inneholde de tre overnevnte kategoriene. På den ene siden er det hensiktsmessig å gjøre analysene i Nord-Norge da mangelen, og dermed behovet er størst i dette området. På den andre siden er det god dekning på FKB-data i Oslo-området, og dermed mulig å evaluere deteksjonene opp mot FKB-dataen. Ettersom denne oppgaven kun skal teste mulighetene til å detektere hus, naust og brygger ved hjelp av kunstig intelligens, så anses det som mest hensiktsmessig å evaluere resultatene opp mot FKB-data. Derfor gjennomføres analysene i Oslo-området. Resultatene vil likevel ha stor overføringsverdi ettersom byggestilen langs Norges kystlinje er såpass lik.

Figur 16 viser Malmøya; analyseområdet som er valgt. Dette området benyttes for å teste modellenes evne til å detektere objekter. Ifølge Aftenposten (2020) har det blitt oppdaget opptil 15 ulovlige bygg på Malmøya. Mange av dem skal være ulovlige brygger, båthus og naust i 100-

metersbeltet. Dette eksempelet er kun ett av mange i området rundt Oslofjorden. Malmøya er et relativt lite område med mye, ulik bebyggelse langs kystlinjen, noe som betyr at området egner seg godt med tanke på oppgavens problemstilling. Videre er det fordelaktig at området ikke er så stort da dette begrenser verktøyets prosesseringstid.



Figur 16: Analyseområdet; Malmøya, inneholder hus, naust og brygger.

Hovedårsaken til at det er definert et analyseområde er at det skal være mulig å sammenlikne deteksjonene fra de ulike modellene i eksperimentet, med så like forutsetninger som mulig. Den modellen som gjør det best på dette området vil, som beskrevet tidligere, testes på nye kystlokasjoner. Dette vil være et område i Bodø, et område på Bygdøy, samt et nytt område på Malmøya. Hensikten med de to første; Bodø og Bygdøy, er å teste modellen på nye områder med god FKB-dekning. På den måten kan det gjennomføres nye nøyaktighetsanalyser, og modellens resultater fra ulike lokasjoner kan sammenliknes. Ettersom det er et lite område på Malmøya med manglende FKB-data er dette området valgt for å teste modellens evne til å detektere uregistrert data. Hovedårsaken til at modellene testes på uregistrert data er for å vise at modellene detekterer uregistrert så vel som registret bebyggelse, og at verktøyet derfor kan brukes til gitt problemstilling.


4.3 Modell-oppsett

I dette delkapitlet forklares utførelsen stegvis. Det gjennomgås hvilke parameterjusteringer og valg som er gjort i de ulike modellene. Hensikten med dette delkapitlet er å øke etterprøvbareheten, gjennom å oversiktlig dokumentere fremgangsmåten anvendt for å lage modellene.

4.3.1 ESRI-modell

I dette steget testes ESRI sin ferdigtrente modell opp mot artefaktbehovet. Som tidligere nevnt er det modellen *Building Footprint Extraction – USA* som benyttes.

Etter å ha lastet ned ESRI sin ferdigtrente modell og anskaffet ortofoto over analyseområdet iverksettes bruk av dyplæringsverktøyene i ArcGIS. I dette steget er det ikke nødvendig å lage treningsdata ettersom det testes en ferdigtrent modell. Derfor benyttes kun verktøyet *Detect Objects Using Deep Learning* til å detektere objekter, slik *Figur 17* viser:




Figur 17: ESRI-modellen skal kun detektere objekter.

I dette steget benyttes de forhåndsinnstilte parameterverdiene. Dette gjøres da hensikten er å teste om ESRI-modellen er tilstrekkelig slik den er for å løse artefaktbehovet på en tilfredsstillende måte.

4.3.2 Modifisert modell

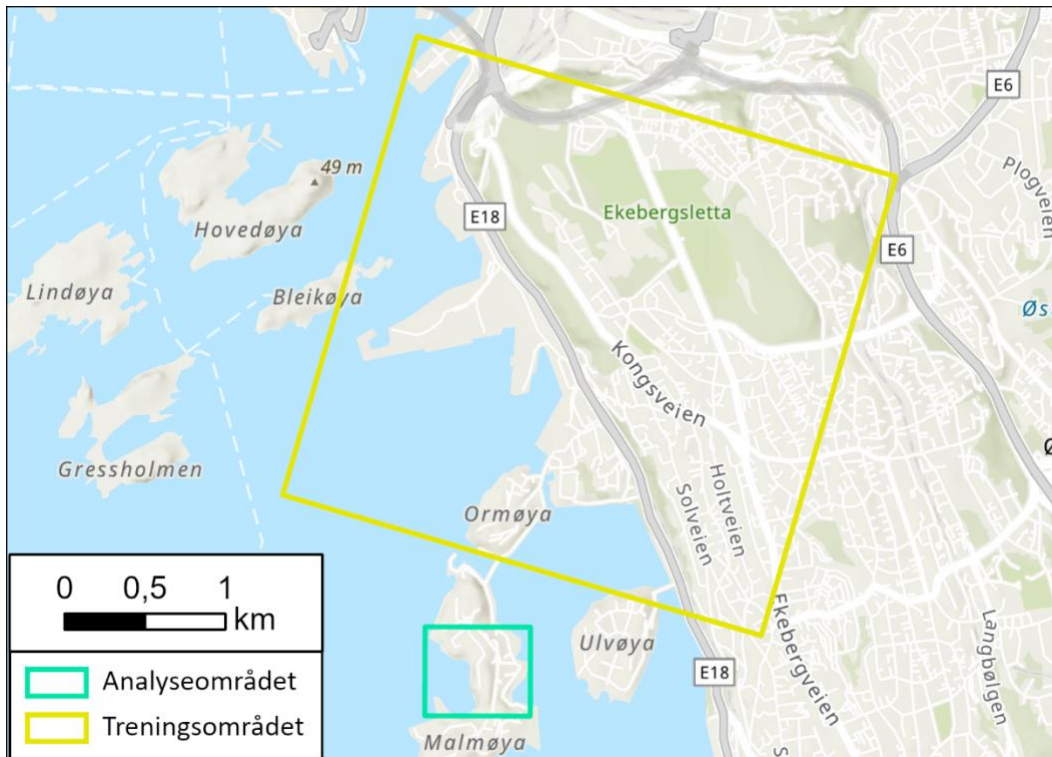
Dette steget tar for seg hvordan en kan modifisere ESRI-modellen til å bedre svare på oppgavens artefaktbehov. Det er i hovedsak to tiltak som gjøres for å modifisere ESRI-modellen. Modellen trenes med ytterligere data, og det testes ulike justeringer av parameterne. Når modellen modifiseres lages det en ny modell, som i denne oppgaven omtales som *modifisert modell*. Det er de justeringene som i sum har gitt best resultater som vektlegges i oppgaven. Den største utfordringen ved bruk av ESRI-modellen var deteksjon av brygger. Siden FKB-data inneholder brygger brukes dette til å trene ESRI-modellen. Før modellen kan trenes, må treningsdataen lages, slik *Figur 18* viser:



Figur 18: Treningsdata lages.

I FKB-BygnAnlegg gjøres det spørring på `KaiBrygge`, `Molo` og `Flytebrygge`. Deretter er brygge-datasettet og bygning-datasettet slått sammen ved bruk av verktøyet *Union* slik at det kun er ett datasett for videre arbeid.


På samme måte som analyseområdet, må treningsområdet inneholde hus, naust og brygger. Som tidligere nevnt tilegner maskinlæringsmodellene seg kunnskap ved å identifisere distinkte trekk for det gitte objektet. Disse objektene blir lettere for modellen å gjenkjenne dersom analyseområdet inneholder så lik data som treningsdatasettet som mulig. Dette inkluderer bygningstype, størrelse, den omkringliggende naturen og lys- og kontrastforhold (Nguyen and Wangen-Eriksen, 2022, p. 8). Det anses derfor som hensiktsmessig å hente treningsdata fra et tilsvarende område som analyseområdet. Det ble først testet med et treningsområde over store deler av Oslo, men da disse treningsdataene skulle trene modellen tok det 24 timer å fullføre 15%. Grunnet tid tilgjengelig ble det derfor ansett som nødvendig å redusere mengden treningsdata, og et mindre område blir derfor brukt, slik *Figur 19 viser*. Ettersom treningsområdet i denne oppgaven inneholder flere ortofoto blir de aktuelle bildene slått sammen ved hjelp av verktøyet *Create Mosaic Dataset*. Dataen fra treningsområdet brukes til å lage de nevnte chipsene, som brukes videre i prosessen.



Figur 19: Det definerte analyse- og treningsområdet. Bakgrunnskart hentet fra ArcGIS basemaps (ESRI, no date g).

For å utvikle modellen ytterligere er enkelte parametere justert. Det ble forsøkt med ulik rutestørrelse og overlapp. Rutestørrelsen økes til 640x640 piksler, slik at alle bygninger kan få plass i en chip. For å forsikre at minst en chip dekker hele objektet, settes overlappet til halvparten av rutestørrelsen.


Etter å ha laget treningsdataen benyttes denne, samt ESRI-modellen, til å lage en ny modell. Dette er neste steg i prosessen, som vist i Figur 20.



Figur 20: Den modifiserte modellen lages.

I denne delen av prosessen er det variert på parameteren Epochs, som økes til 30. Som nevnt i 4.1.4 Dyplæringsverktøy i ArcGIS angir dette antall treningsepoker. *Stop when model stops improving*- parameteren blir huket av for å forhindre overtilpasning, og Validation settes til 10%.

Etter å ha trent modellen ferdig gjøres siste steg i prosessen for å detektere objekter, slik Figur 21 viser:




Figur 21: Objekter detekteres, som siste del av prosessen.

I dette steget benyttes dyplæringsverktøyet på samme måte som beskrevet tidligere, men med litt variasjon i Padding- og Threshold-parameterne. Det ble testet ulike Padding-verdier, fra 0 til 160. I denne oppgaven er det valgt en Padding lik halvparten av overlappet, altså 160. Dette er en måte å hjelpe maskinen å velge den chipsen som best viser hele bygget. Threshold verdien settes til 0,7, i den hensikt å senke kravet til hva modellen skal akseptere som en True Positive-deteksjon.

4.3.3 Egentrent modell

For å gjøre en modell i stand til å detektere ønskede objekter kan en også trene opp en egen dyplæringsmodell. I dette steget testes det om det vil være en bedre løsning å lage en egen modell ved bruk av tilgjengelig data, heller enn å modifisere ESRI-modellen.


Den egentrente modellen bruker det allerede etablerte treningsdatasettet, derfor blir første steg å trene modellen, slik *Figur 22* viser. Denne modellen bruker parameterverdiene som i den modifiserte modellen ga best resultater.



Figur 22: Ettersom treningsdata alt er etablert kan denne modellen starte direkte på treningen.

Når det ikke anvendes en ferdigtraint modell, slik som tidligere beskrevet i oppgaven, er det enkelte nye parametere som blir tilgjengelige. Modelltypen som anvendes til å trene dyplæringsmodellen er Mask R-CNN (He *et al.*, 2018). På ESRI (no date d) sine nettsider står det at Mask R-CNN er den modelltypen som er mest brukt til å finne bygninger, og denne benyttes derfor i oppgaven. Som Backbone model anvendes Resnet-50. Dette beskriver at det kunstige nevralt nettverket består av 50 lag.

Etter å ha laget, og trent opp, en ny modell iverksettes deteksjonen, vist i *Figur 23*. På samme måte som med treningen av modellen anvendes de parameterne som fra forrige steg ga best resultater.



Figur 23: Den egentrente modellen skal i siste steg av prosessen detektere objekter.

5 Resultater og diskusjon

I dette kapitlet vil først resultatene fra de ulike modellene bli presentert. Deretter vil de, samt innvirkningen fra ulike parametere, bli diskutert. Avslutningsvis drøftes svakheter ved oppgaven.

5.1 Presentasjon av resultatene

Resultatene fra ESRI-modellen, den modifiserte modellen og den egentrente modellen presenteres separat. Først følger en tabell med oppsummering av parameterverdiene beskrevet i 4.1.4 *Dyplæringsverktøy i ArcGIS*, slik at disse kan sees i sammenheng med resultatene. Deretter vil resultatene i form av vektordata fremstilles visuelt. Avslutningsvis blir resultatene fra nøyaktighetsanalysen presentert. Det henvises til *Vedlegg B – Resultater fra Compute Accuracy For Object Detection* for å se de fullstendige nøyaktighetsanalysene.

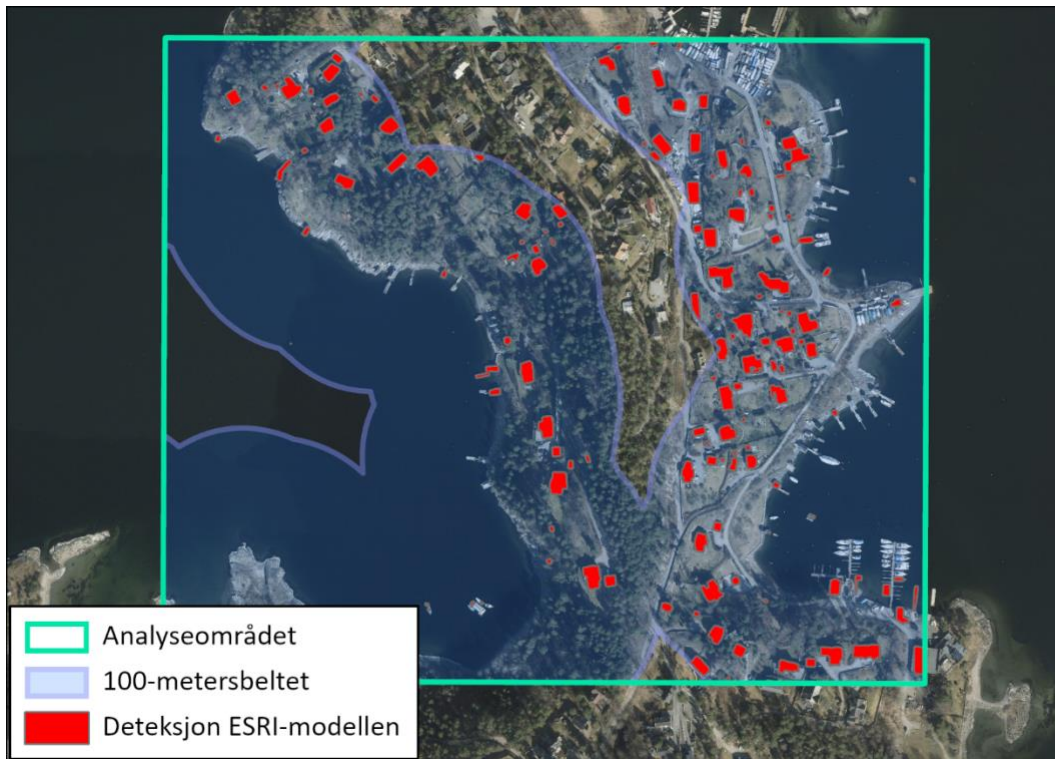
5.1.1 ESRI-modell

Under deteksjonen med ESRI-modellen er alle forhåndsinnstilte parameterverdier benyttet, slik *Tabell 1* viser. Etersom modellen er ferdigtrent så velges ikke Tile- og Stride Size og Epochs, da disse parameterne justeres i verktøyet *Export Training Data For Deep Learning* og *Train Deep Learning Model*.

Tabell 1: Parameterverdiene til ESRI-modellen.

Tile Size	Stride Size	Padding	Threshold	Epochs	IoU
-	-	56	0,9	-	0,5

Som vist i *Figur 24* og *Figur 25* kan en se at ESRI-modellen generelt gjør det veldig bra på større hus, men samtidig svært dårlig på mindre naust og brygger.



Figur 24: Deteksjon ved bruk av ESRI-modellen.



Figur 25: ESRI-modellen detekterer i hovedsak større hus.

I henhold til nøyaktighetsanalysen er ESRI-modellen en modell med høy Precision, men med relativt mange udetekterte objekter, altså en høy False Negative-verdi. Dette påvirker resultatene, i form av en lav Recall- og AP-verdi slik *Tabell 2* viser:

Tabell 2: Resultatene til ESRI-modellen.

Precision	Recall	AP	True Positive	False Positive	False Negative
0,79	0,35	0,28	122,00	32,00	230,00

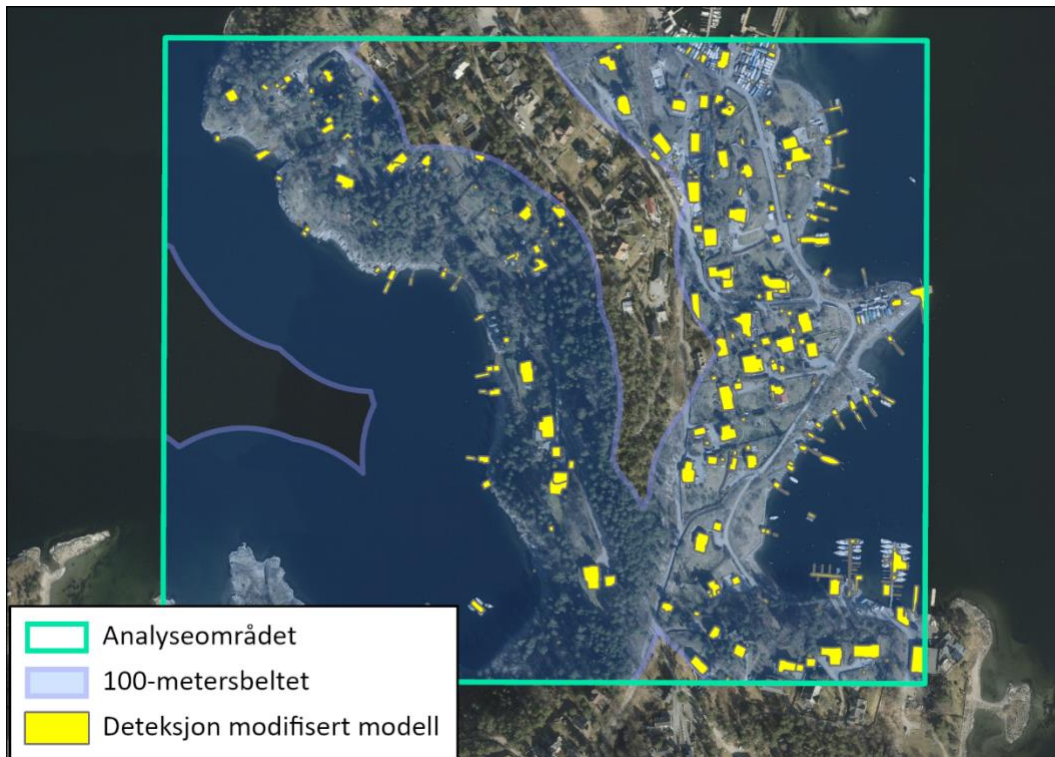
5.1.2 Modifisert modell

Under deteksjonen ved bruk av den modifiserte modellen er parameterverdiene vist i *Tabell 3* benyttet:

Tabell 3: Parameterverdiene til den modifiserte modellen.

Tile Size	Stride Size	Padding	Threshold	Epochs	IoU
640	320	160	0,7	30	0,5

Resultatet, presentert i *Figur 26* og *Figur 27* viser at den modifiserte modellen klarer å detektere hus, naust og brygger i 100-metersbeltet.



Figur 26: Deteksjonen ved bruk av den modifiserte modellen.



Figur 27: Den modifiserte modellen klarer å detektere hus, naust og brygger.

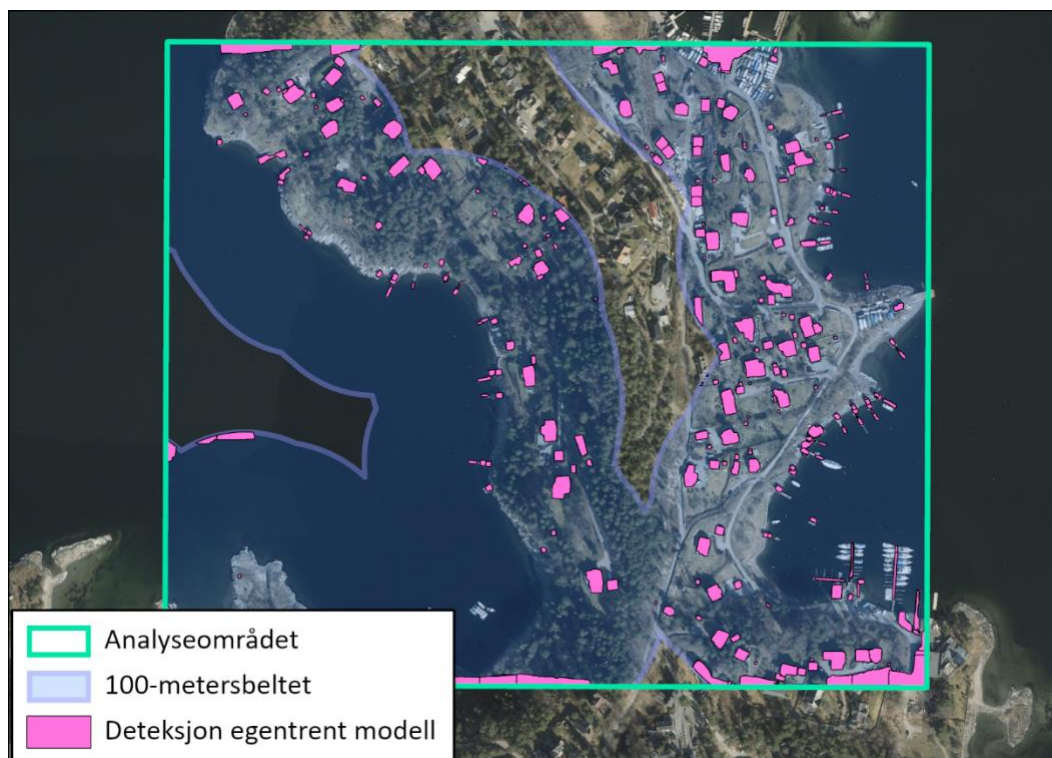
Tabell 4 viser resultatet fra nøyaktighetsanalysen basert på deteksjonene fra den modifiserte modellen. Her er Precision-verdien betydelig lavere, men Recall-verdien er nesten doblet. Tabellen viser også at både False Positive- og True Positive-verdiene er betydelig større enn i ESRI-modellen.

Tabell 4: Resultatene til den modifiserte modellen.

Precision	Recall	AP	True Positive	False Positive	False Negative
0,41	0,48	0,31	170,00	246,00	182,00

5.1.3 Egentrent modell

Under deteksjonen ved bruk av den egentrente modellen er det benyttet identiske parameterverdier som i den modifiserte modellen, vist i Tabell 3. Resultatene fra den egentrente modellen viser at også denne modellen klarer å detektere hus, naust og brygger. Dette er vist i Figur 28 og Figur 29.



Figur 28: Deteksjonen ved bruk av egentrent modell.



Figur 29: Den egentrente modellen detekterer bygninger, naust og brygger.

Tabell 5 viser resultatet fra nøyaktighetsanalysen til den egentrente modellen. Den har lavere False Positive- og False Negative-verdi enn begge de foregående modellene, samt en høyere True Positive-verdi. Dette fører til at denne modellen gjennomgående får høyere verdier enn de andre modellene.

Tabell 5: Resultatene til den egentrente modellen.

Precision	Recall	AP	True Positive	False Positive	False Negative
0,75	0,66	0,60	232,00	79,00	120,00

5.1.4 Evaluering av den egentrente modellen på nye lokasjoner

Ettersom den egentrente modellen er den som gir best resultater på deteksjonene gjennomført i analyseområdet, er denne forsøkt på nye lokasjoner. Som beskrevet testes modellen på et område i Bodø, et område på Bygdøy, samt et nytt område på Malmøya. Hensikten med disse eksperimentene er å evaluere den egentrente modellen. Som tidligere beskrevet testes modellen

på nye kystlokasjoner der det er god FKB-dekning, for å kunne gjennomføre nye nøyaktighetsanalyser. Deretter testes modellen på et område med dårligere FKB-dekning, i den hensikt å kontrollere modellens evne til å detektere uregistrert bebyggelse. Det gjennomføres ikke en nøyaktighetsanalyse på dette området da FKB-dataen er mangelfull.

På *Figur 30* vises resultatet fra deteksjonen over området på Bodø ved bruk av den egentrente modellen. Bodø er et område med god FKB-dekning, og er dermed et egnet sted for å teste modellens nøyaktighet. Resultatet viser at modellen klarer å detektere en del hus, naust og brygger, men en kan tydelig se at den ikke har detektert bygninger på enkelte områder. Dette gjenspeiles i form av en høy False Negative-verdi som en kan se i *Tabell 6*.



Figur 30: Deteksjon ved bruk av den egentrente modellen over et område i Bodø.

I *Tabell 6* vises resultatene fra nøyaktighetsanalysen. Denne deteksjonen har betydelig lavere resultater enn deteksjonene fra det definerte analyseområdet.

Tabell 6: Resultatene til den egentrente modellen i Bodø.

Precision	Recall	AP	True Positive	False Positive	False Negative
0,31	0,19	0,08	30	66	128

Videre er modellen testet på et område i Bygdøy. Dette er, på samme måte som området over Bodø, et område med god FKB-dekning. Resultatene viser at modellen gjør det bedre enn i Bodø. *Figur 31* viser at modellen klarer å detektere en stor andel av hus, naust og brygger i området.




Figur 31: Deteksjon over Bygdøy.

Nøyaktighetsanalysen fra deteksjonen over Bygdøy viser til bedre resultater enn deteksjonen gjort over Bodø. Det er likevel en relativ høy andel False Negative-verdier. Resultatene er vist i *Tabell 7* nedenfor:

Tabell 7: Resultatene til den egentrente modellen på Bygdøy.

Precision	Recall	AP	True Positive	False Positive	False Negative
0,67	0,42	0,33	56	27	76

Ettersom deteksjonene i analyseområdet ikke kontrollerer modellens evne til å detektere uregistrert bebyggelse, er dette en sentral del av evalueringen. For å teste den egentrente modellens evne til å detektere uregistrert bebyggelse er det gjort en deteksjon på et lite, nytt område på Malmøya. Dette området ligger utenfor analyseområdet og inneholder flere uregistrerte brygger. Resultatet fra deteksjonen er vist i *Figur 32*:



Figur 32: Deteksjon ved bruk av egentrent modell for å detektere uregistrert bebyggelse på Malmøya.

I *Figur 32* kan en se at modellen klarer å detektere uregistrerte brygger, dette er visualisert med de røde sirklene. Det er verdt å merke seg at tre av sirklene markerer uregistrerte flytebrygger. Til tross for at FKB-BygnAnlegg har en egen attributt med *'Flytebrygge'* er det ganske naturlig at disse ikke er registrert, da de sjeldent er permanente, men heller sesong-baserte.

5.2 Diskusjon av resultatene

I dette delkapitlet vil resultatene til de tre ulike modellene diskuteres separat. Først vil parameterjusteringene drøftes, deretter diskuteres det hvordan modellene presterer med tanke på oppgavens problemstilling og artefaktbehov.

Felles for alle de tre modellene er potensialet for å redusere fysisk rekognosering av terrenget. Ved å utvikle et verktøy som automatisk genererer vektordata kan Forsvaret i mange situasjoner unngå manuell innhenting. Som direkte konsekvens av dette vil Forsvaret redusere sine utslipp knyttet til innhenting av geografisk data. Med tanke på Forsvarets overordnede samfunnsansvar om å bidra til å nå FNs bærekraftsmål er det viktig å implementere slike miljøbesparende tiltak i daglige gjøremål. I sum vil dette være med på å minke det totale fotavtrykket. Det er derfor en fordel at modellen som implementeres i Forsvarets drift er troverdig nok til å kunne erstatte fysisk innhenting.

5.2.1 ESRI-modell

Som nevnt gir resultatet fra ESRI-modellen en høy Precision-verdi (0,79), mens Recall-verdien (0,35) er nokså lav. Dette kan tolkes som at modellen ikke har lært seg en generell regel, og dermed er overtilpasset på en type bebyggelse (Makhlysheva *et al.*, 2018, p. 2). Samtidig er det viktig å skille på overtilpasning og det faktum at treningsdataen ikke har gitt grunnlag for å klare deteksjonen. Denne modellen er ikke trent på brygger, og har derfor ingen forutsetninger for å klare å detektere dette. Resultatet tyder derfor ikke på at modellen er overtilpasset, heller på at modellen ikke er gitt grunnlag for å klare arbeidsoppgaven. Det er derfor naturlig at False Negative-resultatet blir høyt og gir en lav Recall-verdi.

På bakgrunn av dette anses ikke resultatet fra denne analysen som tilfredsstillende, og eksperimentet har derfor testet å modifisere modellen for å bedre utnytte nyskapningen til å svare på artefaktbehovet.

5.2.2 Modifisert modell

Dersom en sammenlikner resultatene fra den modifiserte modellen med ESRI-modellen kan en se at Recall-verdien har steget (0,48). Dette stemmer godt overens med at dette datasettet nå er trent på brygger, og derav også finner langt flere brygger enn ESRI-modellen. Et annet tiltak som gjøres for å øke True Positive-verdien, og dermed påvirke Recall- og Precision-verdien i en

positiv retning, er å øke størrelsen på chipsene og overlappet. I oppgaven gjøres analyser på et område med bygninger som er på størrelse med «vanlige» boliger, noe som betyr at bygningene stort sett er lengre eller bredere enn de forhåndsinnstilte rutene på 256x256 piksler, altså 25,6 meter. Derfor velges det en ny rutestørrelse på 640x640 piksler. Pikslene på benyttet ortofoto er på 10 centimeter og dekker dermed 64x64 meter. Et stort hus på Malmøya vil nå kunne få plass i en enkel chip. Som tidligere beskrevet klippes bildet opp på en symmetrisk måte, den tilpasser altså ikke grensene sine ut ifra hvor objektene ligger. Dette betyr at til tross for at mange av objektene *kan* få plass i en chip, kan de havne på grensen mellom flere chips. For å motvirke dette, samt sørge for at noen av chipsene fanger hele objektet settes overlappet til 320x320 piksler, altså halvparten av rutestørrelsen. Ulempen ved å ha så høy rutestørrelse og så mye overlapp er at chipsene blir større og flere, noe som kan gjøre at prosesseringstiden øker. Dette var imidlertid ikke et stort problem under arbeidet med denne oppgaven.

Til tross for økningen i rutestørrelsen og overlappet har Precision-verdien nesten blitt halvert i den modifiserte modellen (0,41). Dette betyr at deteksjonen har funnet en del objekter som ikke er bygninger og brygger i henhold til FKB-datasettet. Det er i hovedsak antatt to mulige årsaker til at Precision-verdien synker. For det første er det sannsynlig at modellen ikke er godt nok trent på brygger til å klare å detektere dette med ønskelig nøyaktighet. Modellen får derfor en del False Positive-resultater, som påvirker Precision-verdien i en negativ retning. Dette vil med høy sannsynlighet motvirkes ved å trene modellen ytterligere.

For det andre er Threshold-verdien satt til 0,7. Threshold indikerer hvor sikker modellen skal være før den velger å markere et objekt som detektert. Fordelen med å la denne være høy er at de resultatene som produseres sannsynligvis er riktig, men samtidig risikerer en at modellen forkaster deteksjoner som kunne vært riktig. Ved å senke Threshold-verdien gjør modellen flere deteksjoner, men samtidig øker andelen feil-deteksjoner, altså øker False Positive-verdien. For å bidra til økt True Positive-verdi, og samtidig redusere False Positive-verdien, er Padding-verdien og antall treningsepoker økt, samt Validation satt til 10%.

Det er beskrevet at høyere Padding-verdi fører til at mer av kantene under deteksjonen ignoreres, noe som er fordelaktig for å forhindre deteksjon av halve objekter. I denne oppgaven er det bygninger og brygger som skal gjenkjennes, og en halv brygge eller bygning kan enkelt beskrives som en mindre bygning, eller en mindre brygge, dermed fortsatt relevant data. Det kan

derfor argumenteres for at det ikke er nødvendig å stille inn verktøyene til å detektere *kun* fullstendige objekter, men på den andre siden kunne det like gjerne vært trafikkskilt som skulle detekteres. Dersom nettverket kun gjenkjenner halve trafikkskilt, kan det gi direkte feil informasjon. Hvis en modell utelukkende ser tallet 0 på et fartsskilt, kan dette bety en rekke ulike fartsgrenser. Høyere Padding-verdi vil sørge for at objekter som likner på deler av et hus eller en brygge ikke blir detektert. Dette bidrar til å minke False Positive-verdien, og dermed øke Precision-verdien.

Som nevnt er også antall treningsepoker økt. Denne parameteren bestemmer hvor mange ganger modellen skal trene på treningsdataen, og ved å øke denne vil modellen bli bedre til å detektere objekter. Denne økningen er gjort siden mengden treningsdata som er benyttet er ganske liten, og det er dermed et større behov for å trene på samme data flere ganger. Ulempen ved å øke antall treningsepoker er todelt. For det første tar det lengre tid å trene modellen. I oppgaven er parameteren justert opp fra 20 til 30. Dette tilsvarer en tredjedel økning, og tidsbruken økte dermed tilsvarende. For det andre kan økningen av antall treningsepoker føre til at modellen blir overtilpasset (Brownlee, 2018). For å forhindre nettopp dette er verktøyet som trener modellen innstilt på å stoppe treningen når maskinen skjønner at modellen ikke lenger forbedres.

Av samme grunn som at antall treningsepoker økes så settes Validation til 10%. Hensikten er at mesteparten av dataen brukes til å trene modellen. På den andre siden innebærer dette en risiko for at valideringen blir unøyaktig, da 10% av treningsområdet utgjør en relativt liten mengde data. Ved å øke mengden treningsdata vil en minimere risikoen for dette problemet.

Den modifiserte modellen gir en bedre AP-score enn ESRI-modellen, men har likevel et forbedringspotensial. Modellen gjør en del feil, vist i form av både False Positive- og False Negative-resultater. Både Precision- og Recall-verdien er under 0,5, som vil si at modellen har flere feil-deteksjoner enn riktige, og at den detekterer mindre enn 50% av antall mulige riktige deteksjoner. Derfor vurderes denne modellen til ikke tilfredsstillende.

5.2.3 Egentrent modell

Den egentrente modellen er den modellen som jevnt over scorer best. Den har lavere False Positive- og False Negative-verdi enn begge de foregående modellene, samt en høyere True Positive-verdi. Dette fører til at denne modellen får Precision- og Recall-verdier på henholdsvis

0,75 og 0,66, samt at AP-verdien nesten dobles sammenliknet med den modifiserte modellen. Det vil si at alle verdiene ligger over 50%, noe som anses som godt nok til å i mange situasjoner erstatte fysisk innhentning. På bakgrunn av dette vil denne modellen evalueres videre.

Parameterne er innstilt på akkurat samme måte i den egentrente modellen som i den modifiserte modellen, men likevel er det en markant forskjell i resultatene. En logisk årsak til dette er andelen og typen treningsdata. Den modifiserte modellen er i hovedsak trent på treningsdata over bygninger fra USA, samt litt data over Oslo. Den egentrente modellen derimot er kun trent ved bruk av treningsdata over Oslo. Dette betyr at den egentrente modellen har bedre forutsetninger enn den modifiserte modellen til å detektere bebyggelse i akkurat Oslo-området (Nguyen and Wangen-Eriksen, 2022, p. 7).

Den egentrente modellen blir først testet på et område i Bodø, i den hensikt å teste modellens generalitet. Her viser resultatene at modellen klarer å detektere både bygninger og brygger, men verdiene fra nøyaktighetsanalysen er lavere enn tidligere deteksjoner. Det er flere faktorer som kan forklare dette, blant annet byggestilen og ortofotoet.

For det første ligger husene i Bodø svært tett. Dette er en stor forskjell fra treningsområdet, der husene ligger spredt i tilknytning til åpne områder. I *Figur 33* kan en se at modellen har detektert mange av husene som en større bygning. Dette vil slå ut negativt i nøyaktighetsanalysen i form av en høyere False Negative-verdi.



Figur 33: En polygon dekker flere hus.

For det andre kan en mulig årsak til at modellen presterer dårligere over Bodø, være at ortofotoet er annerledes. En bygning kan vises ulikt på forskjellige bilder grunnet faktorer som kameravinkel, skygge, sol, avstand, farger etc. Dette kan føre til at det er vanskelig å detektere samme objekter i andre bilder (Bayr, 2020, p. 3). Modellen er trent på én type ortofoto over treningsområdet, og ortofotoet benyttet over analyseområdet er i samme serie. Ortofotoet over Bodø derimot skiller seg mer ut. Alle bildene, både de over analyse- og treningsområdet og over Bodø, er med en pikselstørrelse lik 0,1, men det er andre detaljer, som eksempelvis farger, lys og skygger som skiller seg ut. Som *Figur 33* viser er det ganske mye skygger i ortofotoet over Bodø. Dette er en potensiell feilkilde for modellen. De nevrale nettverkene bruker ofte hjørner, kanter og linjer til å gjenkjenne objekter generelt, og spesielt når det er snakk om bygninger. Skygger kan vanskeliggjøre klassifiseringen ettersom det blir vanskelig å identifisere nettopp dette (Buyukdemircioglu, Can and Kocaman, 2021, pp. 1–2). Det eksisterer metoder som gjør det mulig å fjerne skygger i ortofoto, og ofte gjøres dette som en del av etterarbeidet. Dersom en vet at ortofotoet skal benyttes til objekt-deteksjon kan dette derfor være fornuftig.

Videre kan en i *Figur 34* se at det i FKB-datasettet er ytterste del av bryggen som er registrert som en brygge, mens deteksjonen kun markerer den innerste delen. Det er ønskelig at modellen

skal detekttere hele bryggen, så dette er en svakhet i seg selv. Samtidig vil ikke deteksjonen få positiv uttelling i nøyaktighetsanalysen i form av True Positive-resultater, til tross for at den har detektert relativt riktig. Dette er derfor et resultat av at FKB-datasettet er noe ufullstendig, og at modellen er noe upresis.



Figur 34: Deteksjon av brygger.

For å utforske modellens generalitet videre er det forsøkt med en deteksjon over Bygdøy. Dette området har ortofoto i samme serie som det benyttet over analyseområdet. Denne deteksjonen viser bedre resultater, da modellen detekterer større andel bygninger og brygger i 100-metersbeltet. Dette kan tyde på at modellen har behov for mer variasjon i ortofotoene som benyttes i treningsdataen.

Som tidligere beskrevet ble det til slutt gjennomført en deteksjon på et område over Malmøya, som inneholder uregistrerte brygger. Fra denne deteksjonen blir det synlig at den egentrente modellen detekterer alle de uregistrerte bryggene i området. Dette viser at modellen klarer å detektere uregistrert bebyggelse. Likevel er det nærliggende å tro at modellen vil trenge mer treningsdata for å klare dette langs hele Norges kystlinje, ettersom resultatene fra de ulike lokasjonene er varierende.

5.3 Svakheter ved oppgaven

Som tidligere beskrevet er analyseområdet som er valgt svært likt treningsområdet. Til tross for viktigheten av å gi modellene gode forutsetninger gjennom relevant treningsdata, står det beskrevet i boken *Deep Learning* (2016, p. 107) at det viktigste innenfor maskinlæring er at verktøyet klarer å prestere på nye steder eller områder. I denne oppgaven er området modellen skal prestere på nesten identisk med området den er trent på. Det kan på bakgrunn av dette argumenteres for primært to svakheter ved oppgaven. For det første at analyseområdet ikke tester generaliteten til de tre modellene i stor nok grad. For det andre at treningsdataen er av for lite volum og bredde. For å kompensere for den første svakheten blir resultatene fra Teknologivitenskapens 3. fase; evalueringen, som gjøres i Bodø og på Bygdøy, svært viktig. Selv om Bygdøy geografisk ikke er langt unna Malmøya, er byggestilen der annerledes. Det kunne derfor vært interessant å teste alle tre modellene på flere steder, men grunnet tid tilgjengelig er dette kun gjort på den egentrente modellen.


Når det kommer til mengden og bredden i treningsdataen kan en raskt trene opp modellen på nye steder i forkant av deteksjoner som skal gjøres, forutsatt tilgjengelig treningsdata. Det vil si at dersom det er nødvendig å gjennomføre en deteksjon i eksempelvis Lofoten, kan en først trene modellen på et tilsvarende, lite område fra Lofoten. Dette vil gå relativt raskt, og samtidig gjøre modellen bedre egnet til den gitte arbeidsoppgaven.

5.3.1 Kildekritikk

Det teoretiske grunnlaget er basert på åpne kilder, relevante fagbøker og MilGeo-fagpersonell. Det er enkelte svakheter med dette. For det første kan dialogen med fagpersonellet bli farget av ulik begrepsforståelse, noe som kan medføre misforståelser. For det andre er de fleste åpne kilder skrevet av fagpersonell med et sterkt ønske om å fremme sitt fagfelt. Mange fagartikler peker utelukkende på mulighetene, og dette kan føre til at oppgaven får en unaturlig vektlegging av enkelte sider. For å motvirke dette er det ved innhenting av åpne kilder tilstrebet å bruke kilder med et troverdig rykte i samfunnet. Videre er kildene vurdert i samråd med veiledere underveis i oppgaven.

FKB er vurdert ut fra faktorene beskrevet i teoridelen 3.3 *Felles kartdatabase (FKB)*. Datasettet anses å være svært troverdig da det er regulert hvem som kan endre på datasettet. Videre er det et

anerkjent og mye brukt datasett innenfor geomatikk-fagmiljøet. Som tidligere beskrevet blir det jevnlig oppdatert, og er derfor relevant med tanke på ajourføring. Når det kommer til nøyaktighet er datasettene underlagt strenge, regulerte krav, og områdene denne oppgaven tar for seg er definert som sone A (Kartverket, 2019). Dersom en studerer noen av resultatbildene kan det virke som at FKB-dataen er unøyaktig, eksemplifisert gjennom *Figur 35*. Dette er et resultat av at flytebryggene flytter på seg, heller enn et resultat av unøyaktig kartlegging. Dette vil likevel påvirke den statistiske nøyaktighetsanalysen i en falsk negativ retning, ettersom FKB-dataen er definert som virkeligheten. Når deteksjonen plasserer bryggen korrekt i forhold til nåværende plassering, mens FKB-datasettets plassering er forskjøvet vil deteksjonen telle negativt i de statistiske resultatene. Eksempelvis vil deteksjonen i *Figur 35* telles som en False Positive-deteksjon, og siden den ikke dekker FKB-polygonen vil dette også gi utslag som et False Negative-resultat. Det er derfor viktig å poengtere at disse statistiske feilkildene ikke bør brukes som eksempler på unøyaktig FKB-data. Når det gjelder den siste kvalitets-faktoren; fullstendighet, er oppgavens problemstilling et resultat av at brukere har oppdaget mangler, og i *Figur 34* pekes det på noe ufullstendighet i datasettet. Sammenliknet med andre datasett anses likevel FKB som et fullstendig datasett. På bakgrunn av dette er FKB-datasettene vurdert til å være et svært godt alternativ for treningsdata, samtidig som det gir et godt sammenlikningsgrunnlag for evalueringen av resultatene.



Figur 35: Flytebryggene vil ha varierende lokasjon, noe som kan fører til lite samsvar mellom FKB-datasettet og deteksjonen gjort av modellen.

Ettersom bildene anvendt i oppgaven er flyfoto med høy oppløsning, har de også en høy visuell kvalitet. Den lave pikselstørrelsen kombinert med skyfri himmel skaper skarpe bilder med jevn fargekontrast. Bildene over Malmøya er tatt samme dag og det er dermed ingen skjøter mellom bildene. Ortofotoene er også fri for støy fra digitale instrumenter, som kan oppstå i prosessen. Dette er alle kvalitetskrav kartverket (2020) setter til sine ortofoto, og ettersom de oppfylles i disse ortofotoproduktene anses de som egnede til å gjennomføre eksperimentet på. Dette gjelder også bildene over resterende evalueringsområder, derav Bodø og Bygdøy, til tross for skygger i bildene over Bodø. Det at bildene over Malmøya er tatt i mars 2020, og at bildene over Bodø i 2014, betyr at bildene kan mangle nye endringer i terrenget. Det er såpass lang tid at relativt store endringer, som eksempelvis ny bebyggelse eller nye hogstfelt kan forekomme. Bildene og analysene er derfor ikke så aktuelle som ønskelig, men siden dette kun er gjennomført som et eksperiment for å identifisere mulighetene til å bruke ortofoto, vil ikke dette ha innvirkning på oppgavens konklusjon. Bruk av satellittbilder ville muliggjort en enklere oppdatering av nye bilder, men samtidig blir oppløsningen lavere og kvalitetskravene fires på. Det gir derfor et mer

detaljert, og dermed virkelighetsnært bilde, dersom analysene gjøres på ortofoto basert på flyfoto.

6 Konklusjon

Boken *The Geography of Warfare* hevder at fundamentet til alle strategiske og taktiske problemer er geografiske, og trekker frem kartet som det mest effektive hjelpemiddelet for å dekke informasjonsbehovet (O'Sullivan and Miller, 2015, pp. 9–18). Denne oppgaven har undersøkt en ny metode for å oppdatere geografisk informasjon. Dette har blitt gjort ved å se på hvordan kunstig intelligens kan bidra til å oppdatere kartgrunnlaget. Oppgaven er en forsøkt løsning på et identifisert behov fra Sjøforsvaret om å oppdatere kartdataen over 100-metersbeltet i Norge.

I eksperimentet ble ulike modeller testet for å søke svar på problemstillingen om hvorvidt en ved bruk av kunstige nevrale nettverk kan detektere uregistrert bebyggelse i ortofoto, i 100-metersbeltet. Evalueringen fra alle de tre modellene konkluderer med at modellen detekterer objekter i ortofoto ved hjelp av kunstige nevrale nettverk. Det er likevel i svært varierende grad. Etersom ESRI-modellen og den modifiserte modellen ikke leverte et tilfredsstillende nok resultat, er disse modellene aldri evaluert med hensyn til modellens evne til å detektere *uregistrert* bebyggelse.

Den egentrente modellen er den som leverer best resultat. Den klarer å detektere hus, naust og brygger, inkludert uregistrert bebyggelse. Den får likevel en andel feil-deteksjoner på alle de utprøvde lokasjonene. For å konkludere resultatet vurderes derfor den egentrente modellen opp mot oppgavens problemstilling, mål og artefaktbehov.

Som nevnt klarer modellen å detektere uregistrert bebyggelse i ortofoto, i 100-metersbeltet, ved bruk av kunstige nevrale nettverk. Den oppnår dermed også resultatmålet om å skape vektordata på bakgrunn av deteksjonene gjort i ortofoto. Modellen får en AP-verdi lik 60%, noe gruppen definerer som relativt bra, men på deteksjonene som er gjennomført på de nye lokasjonene synker verdien. Dette er trolig en konsekvens av at modellen ikke er godt nok trent til å klare å levere stabile, uavhengige resultater. Effektmålene; om å øke forståelsen for kunstig intelligens sitt potensiale, og å bidra med innovative løsninger, kan også anses som oppnådd.

Modellen som har blitt utviklet tilfredsstillende delvis artefaktbehovet. Modellen evner å bruke kunstige nevrale nettverk til å lage vektordata ved å finne uregistrerte hus, naust og brygger i

ortofoto. Graden av tilfredsstillende resultater er likevel såpass varierende at en ikke kan konkludere med at den er anvendbar over hele Norges kystlinje. Ettersom ESRI-modellen har høyere Precision-verdi enn den egentrente modellen, og er trent på betydelig mer data, kan det konkluderes med at modellen vil bli mer nøyaktig ved å øke treningsmengden. Før modellen tilfredsstillende artefaktbehovet må derfor modellen trenes ytterligere, på mer variert data.

Oppgaven kan dermed konkluderes med at en ved bruk av kunstige nevralt nettverk kan detektere uregistrert bebyggelse i ortofoto, i 100-metersbeltet. Det vil likevel være nødvendig med relativt store mengder treningsdata for å oppnå tilfredsstillende resultater langs hele Norges kystlinje.

6.1 Videre arbeid

Basert på konklusjonen presentert over kunne det først og fremst vært interessant å trene modellen ytterligere, da dette er vurdert som nødvendig for å oppnå ønsket resultat. Første steg ville derfor vært å trene modellen på et langt større område. Videre kunne det vært nyttig å skille på bygninger og brygger i resultatet, samt å skille ut den uregistrerte bebyggelsen.

Denne oppgaven har ikke klassifisert resultatene i henholdsvis bygninger og brygger, men dersom en avdeling skal kartlegge infrastruktur i helt nye områder kan det å skille på deteksjonene øke situasjonsforståelsen, så vel som planleggingsgrunnlaget. Eksempelvis vil et båthus på en brygge bety at det finnes mulighet for dekning og skjul, men slik *Figur 36* viser kommer ikke denne informasjonen frem i modellene i denne oppgaven. Et naturlig arbeid videre ville derfor vært å skille på polygonene til bygninger og brygger. For å gjøre dette kan det anvendes et klassifiseringsverktøy i ArcGIS som også benytter seg av dyplæring.



Figur 36: Polygonene skiller ikke på bygninger og brygger.

For å kun sitte igjen med uregistrert bebyggelse vil det være naturlig å lage en ModelBuilder i ArcGis der eksempelvis verktøyet *Erase* benyttes til å fjerne polygoner som overlapper med eksisterende FKB-datasett. På denne måten kan den nye vektordataen brukes som et supplement ved behov.

Videre vil det å lage relevant treningsdata for flere steder i verden øke metodens bruksområder. Ettersom byggestilen i Norge ikke er identisk med byggestilen i eksempelvis Midtøsten, må modeller trenes opp med relevant data for det området som skal analyseres. På internasjonale operasjoner finnes det ikke alltid tilgjengelig vektordata, men dersom det eksisterer ortofoto over området, samt et treningsdatasett, kan det effektivt skapes relevant vektordata. På denne måten kan metoden anvendes til å lage datasett over moskeer, skoler, veier, telemaster etc. på utallige lokasjoner.

Litteraturliste

Alouta, R. and Hess, K. (2021) 'Deep Learning with ArcGIS Pro Tips & Tricks: Part 2', *ArcGIS Blog*, 2 March. Available at: <https://www.esri.com/arcgis-blog/products/arcgis-pro/imagery/deep-learning-with-arcgis-pro-tips-tricks-part-2/> (Accessed: 26 October 2021).

Bayr, U. (2020) 'Maskinl ring til bildeanalyse', *NIBIO-pop* [Preprint]. Available at: https://nibio.brage.unit.no/nibio-xmlui/bitstream/handle/11250/2678349/NIBIO_POP_2020_6_35.pdf?sequence=1&isAllowed=y (Accessed: 18 October 2021).

Beadle, A.W. *et al.* (2019) *Globale trender mot 2040 - et oppdatert fremtidsbilde*. 19/00045, p. 281. Available at: <https://publications.ffi.no/nb/item/asset/dspace:5906/19-00045.pdf> (Accessed: 3 November 2021).

Brownlee, J. (2018) 'Use Early Stopping to Halt the Training of Neural Networks At the Right Time', *Machine Learning Mastery*, 25 August. Available at: <https://machinelearningmastery.com/how-to-stop-training-deep-neural-networks-at-the-right-time-using-early-stopping/> (Accessed: 30 November 2021).

Buyukdemircioglu, M., Can, R. and Kocaman, S. (2021) *Deep learning based roof type classification using very high resolution aerial imagery*. Ankara, Turkey, p. 5.

Datatilsynet (2018) *Kunstig intelligens og personvern*. Tollbugaten 3, Oslo. Available at: <https://www.datatilsynet.no/globalassets/global/dokumenter-pdfer-skjema-ol/rettigheter-og-plikter/rapporter/rapport-om-ki-og-personvern.pdf> (Accessed: 9 November 2021).

Dvergsdal, H. (2019) 'nevralt nettverk', *Store norske leksikon*. Available at: http://snl.no/nevralt_netverk (Accessed: 20 October 2021).

EMU, Danmarks læringsportal (2022) *Digitale artefakter*. Available at: <https://emu.dk/grundskole/teknologiforstaaelse/begrebsguide-til-teknologiforstaaelse/digitale-artefakter> (Accessed: 21 March 2023).

Endsley, M.R. (2000) 'Theoretical underpinnings of situation awareness', in *Situation awareness analysis and measurement*.

ESRI (2021a) *Building Footprint Extraction - USA - Oversikt*. Available at: <https://www.arcgis.com/home/item.html?id=a6857359a1cd44839781a4f113cd5934> (Accessed: 25 November 2021).

ESRI (2021b) 'Deep Learning Libraries Installers for ArcGIS'. Esri. Available at: <https://github.com/Esri/deep-learning-frameworks> (Accessed: 30 November 2021).

Esri (no date) *ArcGIS, Esri.com*. Available at: <https://www.esri.com/en-us/arcgis/about-arcgis/overview> (Accessed: 18 October 2021).

ESRI (no date a) *Deep learning frequently asked questions—ArcGIS Pro | Documentation*. Available at: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/deep-learning/deep-learning-faq.htm> (Accessed: 5 November 2021).

ESRI (no date b) *Detect Objects Using Deep Learning (Image Analyst), ArcGis Pro*. Available at: <https://pro.arcgis.com/en/pro-app/2.7/tool-reference/image-analyst/detect-objects-using-deep-learning.htm> (Accessed: 18 October 2021).

ESRI (no date c) *Export Training Data For Deep Learning (Image Analyst), ArcGis Pro*. Available at: <https://pro.arcgis.com/en/pro-app/2.7/tool-reference/image-analyst/export-training-data-for-deep-learning.htm> (Accessed: 11 November 2021).

ESRI (no date d) *How _MaskRCNN_ works | ArcGIS Developer*. Available at: <https://developers.arcgis.com/python/guide/how-maskrcnn-works/> (Accessed: 15 November 2021).

ESRI (no date e) *Image Analysis, Esri.com*. Available at: <https://www.esri.com/en-us/arcgis/products/imagery-remote-sensing/capabilities/analysis> (Accessed: 22 October 2021).

ESRI (no date f) *Install deep learning frameworks for ArcGIS—ArcGIS Pro | Documentation*. Available at: <https://pro.arcgis.com/en/pro-app/latest/help/analysis/deep-learning/install-deep-learning-frameworks.htm> (Accessed: 4 November 2021).

ESRI (no date g) 'Topographic'.

ESRI (no date h) *Train Deep Learning Model (Image Analyst), ArcGis Pro*. Available at: <https://pro.arcgis.com/en/pro-app/2.7/tool-reference/image-analyst/train-deep-learning->

model.htm (Accessed: 11 November 2021).

European Commission (2020) *HIGH-LEVEL EXPERT GROUP ON ARTIFICIAL INTELLIGENCE*. Available at: <https://www.aepd.es/sites/default/files/2019-12/ai-definition.pdf> (Accessed: 19 October 2021).

FFI (2019) *Forsvarsteknologiske trender – en overordnet analyse av teknologiens betydning for et effektivt og relevant forsvar*. 19/02072. Kjeller, p. 20. Available at: <https://publications.ffi.no/nb/item/asset/dspace:6451/19-02072.pdf> (Accessed: 3 November 2021).

FN-sambandet (2023) *FNs bærekraftsmål*. Available at: <https://www.fn.no/om-fn/fns-baerekraftsmaal> (Accessed: 29 March 2023).

Forsvarsstaben (2015) *Forsvarets doktrine for maritime operasjoner*, 224. Bergen: Forsvaret. Available at: <https://fhs.brage.unit.no/fhs-xmlui/handle/11250/2407101> (Accessed: 20 October 2021).

Geodata (no date) *ArcGIS fra Esri, Geodata*. Available at: <https://geodata.no/produkter-og-tjenester/arcgis-fra-esri> (Accessed: 27 October 2021).

Geovekst (2016a) ‘Produktspesifikasjon FKB-BygnAnlegg 4.6’, p. 193.

Geovekst (2016b) ‘Produktspesifikasjon FKB-Bygning 4.6’, p. 115.

Geovekst (2020) ‘SOSI Del 3 Produktspesifikasjon for Felles KartdataBase (FKB)’, 4.6, p. 50.

Geovekst-forum (2022) *Fellesdokument for overordnet arbeid i Geovekst-samarbeidet 2023-2026*. 3, p. 16. Available at: https://www.kartverket.no/globalassets/geodataarbeid/geovekst/fellesdokument-for-overordnet-arbeid-i-geovekst-samarbeidet-2023_2026-.pdf.

Goodfellow, I., Bengio, Y. and Courville, A. (2016) *Deep Learning*. London, England: The MIT Press. Available at: https://books.google.no/books?hl=en&lr=&id=omivDQAAQBAJ&oi=fnd&pg=PR5&dq=machine+learning+goodfellow&ots=MNP3dmtCRS&sig=wHpArUUU2hKEQgheUebhyfvPZgM&redir_esc=y#v=onepage&q=machine%20learning%20goodfellow&f=false.

Granum, N. (2020) 'FKB', *Store norske leksikon*. Available at: <http://snl.no/FKB> (Accessed: 24 November 2021).

Grinderud, K. *et al.* (2016) *GIS - Geografiens språk i vår tidsalder*. 2nd edn. Bergen: Fagbokforlaget.

Gursli-Berg, G. and Reusch, M. (2017) 'strandsonen', *Store norske leksikon*. Available at: <http://snl.no/strandsonen> (Accessed: 2 November 2021).

Hærens våpenskole (2015) *Stabshåndbok for Hæren- plan og beslutningsprosessen*. Rena: Brigader Aril Brandvik.

Hastie, T., Tibshirani, R. and Friedman, J. (2017) 'The Elements Of Statistical Learning', p. 764.

He, K. *et al.* (2018) 'Mask R-CNN', *arXiv:1703.06870 [cs]* [Preprint]. Available at: <http://arxiv.org/abs/1703.06870> (Accessed: 30 November 2021).

Kartverket (2011) *Satellitdata*, *Kartverket.no*. Available at: <https://kartverket.no/api-og-data/satellitdata> (Accessed: 29 November 2021).

Kartverket (2019) *Georef 3 WMS - Kartkatalogen*. Available at: <https://kartkatalog.geonorge.no/metadata/georef-3-wms/e85b8d94-64f2-45c3-b84a-c785c9c3c802> (Accessed: 26 April 2023).

Kartverket (2020) 'Produktspesifikasjon Sjøkart - Dybdata'. Kartverket. Available at: https://register.geonorge.no/data/documents/Produktspesifikasjoner_sjokart-dybdata_v2_produktspesifikasjon-kartverket-dybdata-20201001_.pdf (Accessed: 15 November 2020).

Kartverket (2021) *Flyfoto*, *Kartverket.no*. Available at: <https://kartverket.no/til-lands/flyfoto> (Accessed: 22 October 2021).

Kommunal- og moderniseringsdepartementet (2020) *Nasjonal strategi for kunstig intelligens*, *Regjeringen.no*. regjeringen.no. Available at: <https://www.regjeringen.no/no/dokumenter/nasjonal-strategi-for-kunstig-intelligens/id2685594/> (Accessed: 18 October 2021).

Kommunal- og moderniseringsdepartementet (2021) *Lov om planlegging og*

- byggesaksbehandling (plan- og bygningsloven)*, Lovdata. Available at: https://lovdata.no/dokument/NL/lov/2008-06-27-71/KAPITTEL_1-1#KAPITTEL_1-1 (Accessed: 27 October 2021).
- Kristoffersen, E. (2021) 'Forsvarets etterretningsdoktrine (2021)'.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015) 'Deep learning', *Nature*, 521(7553), pp. 436–444. Available at: <https://doi.org/10.1038/nature14539>.
- Makhlysheva, A. *et al.* (2018) 'Kunstig intelligens og maskinl ring i helsesektoren', p. 2.
- Microsoft Azure (no date) *Hva er dypl ring?* / *Microsoft Azure*. Available at: <https://azure.microsoft.com/nb-no/overview/what-is-deep-learning/> (Accessed: 25 October 2021).
- Milj verndepartementet (2003) *St. Meld. nr. 30, «Norge digitalt» – et felles fundament for verdiskaping*. Oslo, p. 43. Available at: <https://www.regjeringen.no/contentassets/91795c899d1b41e5959b0b81eb1cce48/no/pdfs/stm200220030030000dddpdfs.pdf>.
- Nguyen, K. and Wangen-Eriksen, M. (2022) *A Deep Learning Based Approach for Detecting Change of Buildings from Aerial Images*. Trondheim: NTNU, p. 85.
- Nilsen, A.E. (2021) *Maskinl ringsteknikker for klassifisering*. 2001/01501. Kjeller: FFI, p. 108. Available at: <https://publications.ffi.no/nb/item/asset/dspace:3483/01-01501.pdf> (Accessed: 5 November 2021).
- Olsen, T. (2020) 'Uro i  yparadiset: Krever riving av ulovlige badehus og brygger', *Aftenposten*, 3 June. Available at: <https://www.aftenposten.no/oslo/i/opOLga/uro-i-oeyparadiset-krever-riving-av-ulovlige-badehus-og-brygger> (Accessed: 8 November 2021).
- O'Sullivan, P. and Miller, J.W. (2015) *The Geograpghy of Warfare*. New York: Routledge Library Editions: Ploitical Geography. Available at: <http://opac.lib.idu.ac.id/unhan-ebook/assets/uploads/files/5252d-172.the-geography-of-warfare-routledge-library-editions-political-geography.pdf>.
- Prop. 14 S (2020) *Evne til forsvar – vilje til beredskap Langtidsplan for forsvarssektoren*.

Forsvarsdepartementet. Available at:

<https://www.regjeringen.no/contentassets/81506a8900cc4f16bf805b936e3bb041/no/pdfs/prp202020210014000dddpdfs.pdf>.

Riggio, C. (2019) *What's the deal with Accuracy, Precision, Recall and F1?*, Medium. Available at: <https://towardsdatascience.com/whats-the-deal-with-accuracy-precision-recall-and-f1-f5d8b4db1021> (Accessed: 16 November 2021).

Schlosser, A.D. *et al.* (2020) 'Building Extraction Using Orthophotos and Dense Point Cloud Derived from Visual Band Aerial Imagery Based on Machine Learning and Segmentation', *MDPI*, p. 28.

Sjef Etterretningstjenesten (2020) *Håndbok Militær Geomatikk (MilGeo) innen landmilitær virksomhet*. Bardufoss: Sjef Hæren.

Speier, C., Valacich, J.S. and Vessey, I. (1999) 'The Influence of Task Interruption on Individual Decision Making: An Information Overload Perspective', *Decision Sciences*, 30(2). Available at: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.77.481&rep=rep1&type=pdf>.

Stølen, K. (2019) *Teknologivitenskap*. Oslo: Universitetsforlaget.

Tan, R.J. (2019) *Breaking down Mean Average Precision (mAP)*, Medium. Available at: <https://towardsdatascience.com/breaking-down-mean-average-precision-map-ae462f623a52> (Accessed: 16 November 2021).

Tidemann, A. and Elster, A.C. (2021) 'maskinlæring', *Store norske leksikon*. Available at: <http://snl.no/maskinl%C3%A6ring> (Accessed: 18 October 2021).

Trollvik, J.A. (2020) 'Produktspesifikasjon for Ortofoto versjon 5.0'. Geovekst. Available at: https://register.geonorge.no/data/documents/Produktspesifikasjoner_digitale-ortofoto_v8_produktspesifikasjon-for-ortofoto-v5-0-geodata_.pdf (Accessed: 29 November 2021).

Widen, J.J. and Angstrom, J. (2014) *Contemporary Military Theory- The dynamics of war*. 1.utgave. Sweden: Taylor and Francis.

