


2079

NINA Rapport

Prediksjonsmodellering av naturtyper i ferskvann

Vegar Bakkestuen, Børre K. Dervo, Kim Magnus Bærum og Lars Erikstad



NINAs publikasjoner

NINA Rapport

Dette er NINAs ordinære rapportering til oppdragsgiver etter gjennomført forsknings-, overvåkings- eller utredningsarbeid. I tillegg vil serien favne mye av instituttets øvrige rapportering, for eksempel fra seminarer og konferanser, resultater av eget forsknings- og utredningsarbeid og litteraturstudier. NINA Rapport kan også utgis på engelsk, som NINA Report.

NINA Temahefte

Heftene utarbeides etter behov og serien favner svært vidt; fra systematiske bestemmelsesnøkler til informasjon om viktige problemstillinger i samfunnet. Heftene har vanligvis en populærvitenskapelig form med vekt på illustrasjoner. NINA Temahefte kan også utgis på engelsk, som NINA Special Report.

NINA Fakta

Faktaarkene har som mål å gjøre NINAs forskningsresultater raskt og enkelt tilgjengelig for et større publikum. Faktaarkene gir en kort framstilling av noen av våre viktigste forskningstema.

Annen publisering

I tillegg til rapporteringen i NINAs egne serier publiserer instituttets ansatte en stor del av sine forskningsresultater i internasjonale vitenskapelige journaler og i populærfaglige bøker og tidsskrifter.

Prediksjonsmodellering av naturtyper i ferskvann

Vegar Bakkestuen, Børre K. Dervo, Kim Magnus Bærum og Lars Erikstad

Bakkestuen, V., Dervo, B.K., Bærum, K.M. og Erikstad, L. 2022.
Prediksjonsmodellering av naturtyper i ferskvann. NINA Rapport
2079. Norsk institutt for naturforskning.

Lillehammer, februar 2022.

ISSN: 1504-3312

ISBN: 978-82-426-4864-8

RETTIGHETSHAVER

© Norsk institutt for naturforskning

Publikasjonen kan siteres fritt med kildeangivelse

TILGJENGELIGHET

Åpen

PUBLISERINGSTYPE

Digitalt dokument (pdf)

KVALITETSSIKRET AV

Jon Museth

ANSVARLIG SIGNATUR

Forskningsjef Kristin Evensen Mathiesen (sign.)

OPPDRAKSGIVER(E)/BIDRAGSYTER(E)

Miljødirektoratet

OPPDRAKSGIVERS REFERANSE

Prediksjonsmodellering av naturtyper i ferskvann
M-2132|2021

KONTAKTPERSON(ER) HOS OPPDRAGSGIVER/BIDRAGSYTER

Hege Sangolt

FORSIDEBILDE

© Vegar Bakkestuen

NØKKEWORD

- Norge
- Prediksjonsmodellering
- Naturtyper i ferskvann
- Infrastrukturindeks
- Vandringshinder for fisk
- Meandrerende elver
- Fisketomme lokaliteter
- Humussjøer

KEY WORDS

- Norway
- Distribution modelling
- Nature types in freshwater
- Infrastructure index
- Barriers for fish migration
- Meandering rivers
- Fish empty localities
- Humus lakes

KONTAKTOPPLYSNINGER

NINA hovedkontor
Postboks 5685 Torgarden
7485 Trondheim
Tlf: 73 80 14 00

NINA Oslo
Sognsveien 68
0855 Oslo
Tlf: 73 80 14 00

NINA Tromsø
Postboks 6606 Langnes
9296 Tromsø
Tlf: 77 75 04 00

NINA Lillehammer
Vormstuguvegen 40
2624 Lillehammer
Tlf: 73 80 14 00

NINA Bergen
Thormøhlens gate 55
5006 Bergen
Tlf: 73 80 14 00

www.nina.no

Sammendrag

Bakkestuen, V., Dervo, B.K., Bærum, K.M. og Erikstad, L. 2022. Prediksjonsmodellering av naturtyper i ferskvann. NINA Rapport 2079. Norsk institutt for naturforskning.

Hensikten med dette prosjektet har vært å teste ut metoder for prediksjon av fire lokalitetstyper i ferskvann i Norge, dvs. vandringshinder for fisk, kroksjøer og meandrerende elver, fisketomme innsjøer, tjern og dammer og humussjøer. I tillegg er en infrastrukturindeks brukt på de predikerte kalkrike innsjøene for å se på graden av påvirkning. Det er brukt en rekke ulike metoder og datakilder for prediksjonsmodellering av naturtyper, inkludert dyplæring og bruk av LiDAR-data, satellittdata, flybilder, kartdata, berggrunnsdata og biologiske databaser.

Infrastrukturindeksen er brukt for å predikere graden av påvirkning på kalkrike innsjøer og dammer. Denne indeksen bør utvikles videre for å tilpasse behovet for å måle graden av påvirkning for kalksjøene. Spesielt gjelder det komponentene vassdragsreguleringer i innsjøer og elver og jordbruksintensitet. Infrastrukturindeksen kan både være en forklaringsvariabel i en prediksjonsmodell og en tilstandsvariabel for økologisk kvalitet.

Prediksjonsmodelleringen av vandringshinder for fisk treffer i 9 av 10 tilfeller. Prediksjonen er dårligst for smale og små bekker. Feilklassifiseringene var ofte tilknyttet infrastruktur slik som kulverter og fisketrapper. Disse var da modellert som hinder, men i felt ble de avkrefte å være hinder. I denne modelleringen er hovedsakelig helningsgraden og høydeforskjellen brukt til å avgrense polygonene som angir vandringshinder. Egenskaper som vil kunne forbedre modellen er bl.a. data om vannføring i elvene, kraftverk og bortføring av vann fra elvene og en bedre hydrologisk modell. Prediksjonene av vandringshindre må sies å treffe godt. I noen landskap med smale og gjerne påvirkede bekkeløp med utretting, grøfting ol. vil modellen treffe noe dårligere. Dette medfører noen regionale forskjeller med at modellen treffer bedre på Vestlandet og nordover enn i flate jordbrukspregete vassdrag på Sør- og Østlandet.

For prediksjon av fisketomme lokaliteter så treffer prediksjonsmodellen relativt godt på stor geografisk skala. Modellen er ikke generisk nok til å kunne flyttes fra stor til liten skala uten å reparametrisere og trene modellen for riktig geografisk skala. Antagelig vil anvendbarheten av modellen først og fremst ligge på regionalt nivå med dagens datagrunnlag, når lokaliteter skal velges ut ift. utvalgt natur. Det vil med andre ord være vanskelig å plukke ut fisketomme lokaliteter på lokalt nivå, for eksempel på kommunenivå, uten at all eksisterende kunnskap om forekomst av fisk blir systematisert og inngår som en del av datagrunnlaget ved modellering. Det er tre tiltak som vil kunne forbedre presisjonen til modellen på tvers av geografisk skala:

- Kvalitetssikre og oppdaterte observasjoner av fisk i innsjøer. Denne innsamlingen bør gjøres på en slik måte at man får et så representativt utvalg som mulig av vann i Norge, samtidig som det bør være stort nok til å trene modellen på forskjeller i geografisk skala.
- Øke oppløsning på grunnkart som viser biologiske viktige variabler.
- Inkludere informasjon om gårdsdrift og andre historiske data hvis tilgjengelig.

Prediksjonsmodellering av meandrerende elver og kroksjøer har 97,2% treningsnøyaktighet og 96,8% uavhengig kryssvalideringsnøyaktighet. Selv om det er noen foreløpige feil i den, mener vi at denne modellen har potensial for fremtidig klassifisering av meandere. Modellen har potensiale til å være nyttig i utvelgelse av utvalgt natur. Forbedring av modellen krever bedre avgrensing av meandere og bedre kvalitet på trenings- og valideringsdata (bakkesannheter og bildechips materiale).

Våre prediksjoner av humussjøer viser at det er mellom 1,4 – 1,6 mill. humusrike innsjøer i Norge, inklusive dammer og tjern, litt avhengig av hvilken prediksjonsmodell man velger. Imidlertid er våre treningsdata basert på kriterier som også inkluderer mange innsjøer som bare har svakt humuspreg og hvor fargen på disse nesten ikke antyder humus. For å kunne lage en bedre modell for sterkt humuspregede innsjøer trengs et treningsdatasett hvor for eksempel farge > 60

mg Pt/I kunne ha vært et kriterium. Våre prediksjoner treffer noe dårligere i nord, noe som kan ha med at prediktoren høyde over havet ikke er like relevant her. Varmesum-verdier over året kunne antageligvis øke prediksjonsevnen i nord. Prediksjonsmodellen vil være til hjelp for å skille humøse og ikke-humøse innsjøer i forhold til utvalgt natur.

Vegar Bakkestuen, Norsk institutt for naturforskning (NINA), vegar.bakkestuen@nina.no

Børre K. Dervo, Norsk institutt for naturforskning (NINA), borre.dervo@nina.no

Kim Magnus Bærum, Norsk institutt for naturforskning (NINA), kim.barum@nina.no

Lars Erikstad, Norsk institutt for naturforskning (NINA), lars.erikstad@nina.no

Abstract

Bakkestuen, V., Dervo, B.K., Bærum, K.M. and Erikstad, L. 2022.
Prediction modeling of habitats in freshwater. NINA Report 2079. Norwegian Institute for Nature Research.

The purpose of this project has been to test methods for prediction of four locality types in freshwater in Norway, i.e. migration barriers for fish, ox bow lakes and meandering rivers, fish-empty lakes and ponds, and humic lakes and ponds. In addition, an infrastructure index is used on the predicted calcareous lakes to assess the degree of human impact. A number of different methods and data sources have been used for prediction modeling of habitat types, including deep learning and the use of LiDAR data, satellite data, aerial photographs, existing map data, bed-rock data and biological databases.

The infrastructure index is used to predict the degree of human impact on calcareous lakes and ponds. This index should be further developed in order to measure the degree of impact on the limestone lakes. This applies in particular to the components of hydrological regulations in the catchments of lakes and rivers, and agricultural intensity. The infrastructure index can be both an explanatory variable in a prediction model and a state variable for ecological quality.

The prediction modeling of migration barriers for fish hits in 9 out of 10 cases. The prediction is least accurate for narrow and small streams. The misclassifications were often associated with infrastructure such as culverts and fish ladders. These were then modeled as obstacles, but in the field they could often be confirmed not being obstacles. In this modeling, mainly the degree of inclination and the height difference are used to delimit the polygons which indicate migration obstacles. Properties that will be able to improve the model include data on water flow in the rivers, power plants and water abstractions from the rivers and a better hydrological model. Overall, the predictions of migration barriers are assessed to hit well. In some landscapes with narrow and often affected streams with straightening, ditching, etc. the model will be less accurate. This entails some regional differences, e.g. that the model hits better in Western Norway and northwards than in flat agricultural watercourses in Southern and Eastern Norway.

For prediction of fish-empty localities, the prediction model hit relatively well on a large geographical scale. The model is not generic enough to be able to move from large to small scale without re-parameterizing and training the model for the correct geographical scale. Presumably, the applicability of the model will first and foremost be at the regional level with the current data basis, when sites are to be selected in relation to "utvalgt natur" (selected nature types). In other words, it will be difficult to pick out fish-empty localities at the local level, for example at the municipal level, without all existing knowledge about the occurrence of fish being systematized and included as part of the data basis for modeling. There are three measures that will be able to improve the precision of the model across geographical scales:

- Ensure quality and update observations of fish in lakes. This collection should be done in such a way that you get as representative sample as possible of lakes and ponds in Norway, at the same time as it should be large enough to train the model on differences in geographic scale.
- Increase resolution on base maps that show biologically important variables.
- Include agricultural information and other historical data if available.

Prediction modeling of meandering rivers and ox-bow lakes has 97.2% training accuracy and 96.8% independent cross-validation accuracy. Although there are some preliminary errors in it, we believe that this model has potential for future classification of meanders in Norway. The model has the potential to be used to detect selected nature types ("utvalgt natur"). Improving the model requires better delimitation of meanders and better quality of training and validation data (ground truths and annotated image-chip material).

Our predictions of humic lakes show that there are between 1.4 - 1.6 million humus-rich lakes and ponds in Norway depending on which prediction model that is chosen. However, our training data are based on criteria that also include many lakes that have only a weak humic character and where the color of these hardly indicates humus. In order to be able to create a better model for strongly humus-laden lakes, a training data set is needed where, for example, color > 60 mg Pt / l could have been a criterion. Our predictions are least accurate in the north, which may partly because the predictor height above sea level is not as relevant here. Heat sum values over the year could probably increase the predictability in the north. The prediction model will be helpful in distinguishing humus and non-humus lakes in relation to selected nature ("utvalgt natur").

Vegar Bakkestuen, Norwegian Institute for Nature Research (NINA), vegar.bakkestuen@nina.no
Børre K. Dervo, Norwegian Institute for Nature Research (NINA), borre.dervo@nina.no
Kim Magnus Bærum, Norwegian Institute for Nature Research (NINA), kim.barum@nina.no
Lars Erikstad, Norwegian Institute for Nature Research (NINA), lars.erikstad@nina.no

Innhold

Sammendrag	3
Abstract	5
Innhold	7
Forord	8
1 Innledning	9
1.1 Oppdraget.....	10
1.2 Definisjon av typer	10
2 Ferskvann og biodiversitet i Norge	12
2.1 Metode og materiale	12
2.2 Innsjøer i Norge	12
2.3 Antall innsjøer fordelt på bioklimatiske soner.....	13
2.4 Antall innsjøer med forekomst av rødlistearter.....	14
2.5 Antall innsjøer med forekomst av arter.....	16
2.6 Arter i ferskvann.....	17
2.7 Oppsummering for biodiversitet i ferskvann.....	19
3 Påvirkning av kalklokaliteter	20
4 Modellering av vandringshinder	25
4.1 Metode	25
4.2 Resultat.....	31
4.3 Forbedringer	35
5 Prediksjonsmodellering av fisketomme lokaliteter	36
5.1 Introduksjon	36
5.2 Prediksjoner av fisketomme innsjøer basert på statistisk modellering	38
5.3 Resultat.....	40
5.4 Konklusjon på modelleringen av fisketomme lokaliteter	43
6 Prediksjonsmodellering av meanderende elver og kroksjøer med dyplæring	45
6.1 Metode	45
6.2 Dyplæringskartmodeller.....	47
7 Prediksjon av humusrike innsjøer	50
8 Oppsummering	52
9 Referanser	54
Vedlegg	56

Forord

Formålet med dette prosjektet har vært å teste ut en metode for prediksjon av tre lokalitetstyper i ferskvann i Norge, dvs. vandringshinder for fisk, kroksjøer og meanderende elver og fiske-tomme innsjøer, tjern og dammer. I tillegg skulle vi bruke infrastrukturindeksen på de predikerte kalkrike innsjøene fra forrige rapport for å se på graden av påvirkning.

Prosjektet er utført på oppdrag av Miljødirektoratet. Børre K. Dervo har vært prosjektleder, gjennomført deler av feltarbeidet og vært «redaktør» for rapporten. Vegar Bakkestuen, Kim Magnus Bærum og Stefan Blumentrath, med bistand fra Lars Erikstad, har hatt ansvaret for utvikling av prediksjonsmodellene. Annette Taugbøl, John Gunnar Dokk og Tobias Holter har hatt ansvaret for å teste vandringshindre i felt.

Kontaktperson hos oppdragsgiver har vært Hege Sangolt.

Alle takkes for konstruktive diskusjoner og flotte bidrag.

Lillehammer, februar 2022

Børre K. Dervo
Prosjektleder

1 Innledning

Formålet med dette prosjektet er å teste ut en forbedret metode for prediksjon av kalkrike innsjøer, og prediksjon av vandringshindre, fisketomme lokaliteter, meanderende elver og evjer, og humøse innsjøer. Prediksjonene er bygget på tilgjengelig informasjon om forekomster av elver og innsjøer, kalkrik berggrunn og annen relevant informasjon i offentlige og egne databaser.

NINA utviklet en prediksjonsmodell for potensielle kalkrike vannlokaliteter (> 20 mg Ca/l) i 2019 (Deruo m.fl. 2020). De kalkrike vannlokalitetene ble funnet gjennom en overlay-analyse, dvs. en sammenligning av kartlag mellom grunnlagskartet vann fra N50-kartserien i målestokk 1:50 000 og økologisk grunnlagskart for kalkinnhold klasse 5, dvs. svært kalkrikt, i målestokk 1:250 000. Alle vannpolygoner i N50 som inneholdt eller krysset kalkinnhold klasse 5 ble valgt ut og dannet grunnlaget for potensielt kalkrike innsjøer, dvs. innsjøer tjern og dammer. Antall potensielle kalkrike vannlokaliteter ble redusert ved å korrigere for myr, løsmassetypene tykk morene og deretter tynn morene.

Prediksjonsmodellen antyder at det finnes 4 094 kalkrike innsjøer, tjern og dammer i Norge (Deruo m.fl. 2020). Sammenhengen mellom prediksjonsmodellen og de reelle forekomstene ble testet med et uavhengig datasett på 464 vannforekomster med vannkjemiske målinger. Prediksjonsmodellen forklarte mer enn 95 % av utbredelsen til de kalkrike vannforekomstene. Dette tyder på at prediksjonsmodellen, logikken og oppbyggingen av denne hviler på gode antagelser om sammenhenger. Prediksjonsmodellen synes å sammenfalle godt overens med eksisterende kunnskap om kjente lokaliteter ellers i landet. Modellen synes å være et godt grunnlag for justering av mørketallet for svært kalkrike innsjøer i Norge, og den kan være et godt verktøy for videre feltundersøkelser av biologisk mangfold.

NINA utvikler for tiden en infrastrukturindeks som vi vil bruke for å få et mål på graden av menneskelig påvirkning. Infrastrukturindeksen er utregnet som frekvensen av nøkkelvariabler (i denne sammenheng ulike typer infrastruktur som medfører inngrep og fragmentering av arealer), målt i en sirkel med 500 m radius rundt hver piksel (fokuspunkt) og utregnet for hele landet. Infrastrukturindeksen består av to komponenter som summeres: En bygningskomponent og en konstruert fastmarkskomponent (som angir forekomst av konstruert fastmarksareal, resultatet av inngrep, og som gir landskapet et «menneskelandskapspreg»).

Datagrunnlaget som inngår i bygningskomponenten er bygninger (av ethvert slag), ett eller flere av linjeelementene fra datasettene N50 anlegg (inkludert framtreddende kraftlinjer) og N50 samferdsel (bane og veg senterlinje, traktorveg og sti ikke inkludert). Kartgrunnlag (N50), som inngår i konstruert fastmarkskomponenten er: Bebygd areal, tettbebygd areal, industriområde, lufthavn, steinbrudd, gravplass og sport/idrettsanlegg. Disse to komponentene kombineres til Infrastrukturindeks-verdier per piksel (for detaljer, se Erikstad m.fl. 2013 og Jakobsson m.fl. 2020). Selve utregningen av infrastrukturindeksen foregår ved hjelp av raster-kalkulasjoner med et flytende nabolagsvindu som beveger seg over kartgrunnlaget og regner indeksverdien fortløpende.

Infrastrukturindeksen kan kobles til ulike underlagskart som gjør at vi blant annet kan se hvilke typer natur som blir påvirket. Det vil være interessant å se hvilke innsjøer og vassdrag som er utbygget og påvirket av infrastrukturbygging. Jakobsson m.fl. (2020) gjennomgår et omfattende antall slike kartlag med ulikt opphav og formål. Infrastrukturindeksen kan også kobles på planlagte inngrep og regnes om etter ulike konkrete inngrepsplaner. Dette betyr at man kan legge inn nye veier, jernbane, osv. slik at verdiene av cellene endrer seg. Det er også mulig å regne indeksen tilbake i tid for å få en tidsutvikling på mengden av inngrep i ulike områder. Alt dette betyr at man kan bruke endringen i indeksen som en indikator på hvor mye man påvirker «uberørt» natur (pr. indeksen).

En annen del av det foreslåtte prosjektet handler om å utnytte stordata-analyser av blant annet LiDAR ved hjelp av Google Earth Engine. NINA har allerede utviklet et forslag til utregning av vandringshindre i alle elver og bekker i Norge avtegnet som polygoner på N5-kart, se

<https://vegar.users.earthengine.app/view/foss>. (kun CHROME nettleser). Denne modellen er utprøvd i sommer i forbindelse med «prosjektet tapte arealer i Orkla» (Solem m.fl. 2021), med gode erfaringer så langt. Vi ønsker å videreutvikle modellen til å omhandle vandringshindre på et regionalt skala-nivå.

I forbindelse med utvikling av ny teknologi gjennom maskinlæring og GIS/fjernanalyse er det nå muligheter til å bruke mønstergjenkjenning til prediksjon av objekter. Slike objekter i landskapet og terrenget kan for eksempel være åkerholmer eller kroksjøer. Vi ønsker å teste ut slik metodikk for å predikere mengde og utbredelse av meandrerende elver og kroksjøer. Disse prediksjonene vil også ses i sammenheng med den foreslåtte infrastrukturindeksen.

Ved hjelp av nye prediksjonsverktøy som «regression trees», CART eller maskinlæring er det mulig å lage modeller for arealer med rødlista arter. Et slikt eksempel er nylig utført for alle CR (kritisk truede) arter i Norge på skala 1x1 meter for hele landet i en stordata analyse i Google Earth Engine. Foreløpig resultat er mulig å se her (merk at denne mer er et eksempel på mulighet og at det kun er en enkel testmodell som ikke er verifisert: <https://vegar.users.earthengine.app/view/ecological-base-maps-ai> (kun CHROME nettleser).

1.1 Oppdraget

Oppdragstaker skal utvikle og teste prediksjonsmodell for forekomster av 1) fisketomme lokaliteter, 2) meandrerende elver og kroksjøer, 3) for vandringshindre for fisk og 4) utbredelse av humusrike sjøer. Prediksjonsmodellene skal testes i utvalgte områder.

Prosjektet skal i tillegg 5) etablere kart og liste over potensielle kalkrike lokaliteter sammenholdt med ny infrastrukturindeks. Oversikten vil vise hvilke lokaliteter som er mest påvirket av menneskelig aktivitet.

Prosjektet vil også framskaffe informasjon som er relevant for arbeidet til ekspertgruppa for kartlegging i ferskvann. I 2020 skal gruppa etablere en liste over ferskvannsnatur som fyller kriteriene for områder prioritert for kartlegging i St. Meld. 14 (2015-2016) Natur for livet. Prosjektet vil også kunne bidra med viktig bakgrunnsinformasjon om ulike tiltak som må gjøres for å ta vare på truet natur (Aalberg Haugen m. fl. 2019).

Prosjektet vil beskrive datakvaliteten som er tilgjengelig for prediksjonsmodellering i dag og hva som må til av forbedringer for å lage tilfredsstillende kart over potensielle lokaliteter for de tre hovedtypene beskrevet i over. Resultatene skal oppsummeres i rapport.

1.2 Definisjon av typer

Kalklokalitet

Kalksjøer er innsjøer, tjern og dammer som har et naturlig høyt kalsiuminnhold (større eller lik 20 mg Ca/l). Kalksjøer er karakterisert av en særpreget vannvegetasjon av kransalger og karplanter som benytter bikarbonat som karbonkilde. Ofte har kalksjøene klart vann med grønn- eller blåskjær. Mindre kalksjøer har ofte bunnsstrat dominert av løs kalkgrytje eller kalkmergel, mens større kalksjøer har flere typer substrat. Blant kalksjøene finnes både klare og humusrike innsjøer.

Meander

Meandere er regelmessige svinger i elver som går over meget slakt hellende underlag dekket med løsavsetninger, ofte finsubstrat som leire, silt, sand eller dy. En roligflytende elv som går gjennom løsmasser vil grave i yttersvingen og avsette materiale i innersvingen. Dette gir elveløpet en buktende form, der én «slynge» utgjør en meander. Når buen til svingene blir større enn en halvsirkel, kalles de serpentiner (slangebuktninger).

Kroksjø

Kroksjø er en avsnørt del av en meanderende elv. Kroksjøen har ulik grad av kontakt med hovedelva gjennom et flomløp eller en bekk. Elven har erodert seg et nytt og mer effektivt løp og dermed dannet en innsjø i den forlatte eller delvis forlatte slyngen.

Evje

Naturtypen evje er «innsjøer» (stillestående vann med innsjøbunn avsnørt kun i den ene enden) i direkte kontakt med moderelven og som er minst tre ganger så lang som åpningen mot elva. Bunnen består av silt eller leire og vannstanden bestemmes av vannføringen i hovedelva.

En evje kan være dannet gjennom en meander som bare er avsnørt fra hovedelva i den ene enden, et sideløp i elv som er avstengt i overkant, en bekk med utløp i ei elveslette, en vannfylt rasgrop i kontakt med elv eller en neddemt ravine i et regulerte vassdrag.

Fisketom lokalitet

Naturlig fisketomme innsjøer og dammer er stillestående vann som mest sannsynlig aldri har vært kolonisert av fisk. Lokalteter som er fisketomme på grunn av sur nedbør, vil derfor falle utenfor denne naturtypen. Fisketomme innsjøer, tjern og dammer begrenser seg til lokaliteter som ut fra fysiske forhold (størrelse og dyp) antas å kunne opprettholde fisk. Naturlige spredningsbarrierer har hindret kolonisering, og fisk har ikke blitt utsatt. Innsjøene kan mangle innløp og utløp eller utløpet kan danne stryk og fossefall som hindrer fiskevandring.

Humusrik innsjø

En humusrik innsjø er ofte næringsfattige og har ofte relativt lav pH. De ligger ofte i tilknytning til skog eller myr. De er ofte kalkfattige eller svært kalkfattige og har lavt innhold av nitrogen, fosfor og kalsium, men inneholder ofte mye jern. Fargen på vannet er ofte brungul eller såkalt 'humøs'. Som kriterier på en humusrik innsjø har vi har brukt; farge > 30 mg Pt/l eller TOC > 5 mg C/l og kalsium-innhold < 4 mg Ca/l.

2 Ferskvann og biodiversitet i Norge

2.1 Metode og materiale

Grunnlaget for analysene er grunnlagskartet vann fra N5 kartserien i målestokk 1:5 000, økologisk grunnlagskart for kalkinnhold produsert av NGU for Artsdatabanken i målestokk 1:250 000 og forekomst av arter fra Artskart og GBIF (www.artsdatabanken.no). Grunnkartet N5 for vann inneholder totalt 2 018 423 vannlokaliteter heretter kalt innsjøer, men som omfatter både dammer, tjern og innsjøer. Det økologiske grunnlagskartet for kalkinnhold er delt inn i 5 klasser fra svært kalkfattig (klasse 1) til svært kalkrikt (klasse 5) (Se vedlegg 1). Analysene er gjort i GIS (ArcGIS). Det er kun gjort en analyse av overlapp mellom sentrumspunktet i alle innsjøene med grunnlagskartet kalkinnhold og ikke korrigert for andre egenskaper som påvirker kalkinnhold som myr, skog og løsmasser nær lokalitetene eller i lokalitetenes nedbørfelt (se Dervo m.fl. 2019).

2.2 Innsjøer i Norge

Tabell 1 viser antall innsjøer fordelt på ulike størrelseskategorier (areal fra mindre enn 0,0010 km² (1 000 m²) til større enn 5 km²) og ulike kalkkategorier basert på berggrunnen i og rundt innsjøene. Antall innsjøer større enn 1 000 m² er 455 186 og antallet mindre enn 1 000 m² er 1 669 633. Av de som er større enn 1 000 m² ligger 3 936 i kalkkategori 5 (> 20 mg Ca/l) og 53 943 i kalkkategori 4 (4-20 mg Ca/l). Informasjon om kalk har tatt utgangspunkt i økologisk grunnkart for kalkrikt berggrunn. Se **vedlegg 1** for kategorisering av berggrunnen mht. innhold av kalk ift. klasser av kalkinnhold. For innsjøer større enn 1 km² er det viktig å være klar over at en viss andel svært kalkrikt grunn ikke gir svært kalkrike vannmasser. Det betyr at innsjøene som er større enn 1 km² i kalkkategori 5 egentlig tilhører kalkkategori 4. Et eksempel er Tyrifjorden (areal 123 km²), hvor store deler av berggrunnen består av kalkrikt leirskifer (kategori 5), men hvor kalkinnholdet i vannet er på rundt 5 mg Ca/l. Årsaken til det er at andelen kalkrikt grunn i nedbørfeltet blir lav og de kalkrike vannmasser blir tynnet ut. Det samlede antall innsjøer i de aller laveste kalkkategoriene 1 (< 1 mg Ca/l) og 2 (1.2 mg Ca/l) utgjør henholdsvis 1 403 009 og 210 095.

Tabell 2 viser andelen av antall innsjøer (%) fordelt på de samme kalk- og størrelseskategoriene som i **tabell 1**. **Tabell 3** viser samlet innsjøareal i km² for innsjøene i **tabell 1** fordelt på de samme størrelse- og kalkkategoriene. Selv om innsjøer under 1 000 m² i antall utgjør hele 1 669 633, dvs. 83 prosent av alle innsjøene i Norge på N5, utgjør ikke arealet mer enn 370 km² for denne størrelseskategorien.

Tabell 1. Antall innsjøer fordelt på kalk- og størrelseskategorier (areal i km²). 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrikt (> 20 mg Ca/l).

Innsjøareal (km ²)	1	2	3	4	5	Sum
	< 1 mg	1-2 mg	2-4 mg	4-20 mg	> 20 mg	
<0,0010	111 5437	166 354	218 546	157 865	11 431	1 669 633
0,0010-0,0025	125 300	19 585	29 925	25 590	1 644	202 044
0,0025 - 0,0100	95 129	14 119	21 375	17 729	1 232	149 584
0,0100-0,0500	44 546	6 506	9 777	7 135	652	68 616
0,0500 - 1,0000	21 021	3 225	4 567	3 185	369	32 367
1,0000-5,0000	1 365	261	299	258	32	2 215
> 5,0000	211	45	51	46	7	360
Sum	1 403 009	210 095	284 540	211 808	15 367	2 124 819

Tabell 2. Andel (%) innsjøer fordelt på kalk- og størrelseskategorier (areal i km²). 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (> 20 mg Ca/l). Samlet andel for størrelsesgruppen i kolonnene til høyre (alle størrelseskategorier og alle størrelseskategorien større enn 0,001 km²).

Innsjøareal (km ²)	1	2	3	4	5	Sum alle	Sum >0,001 km ²
	< 1 mg	1-2 mg	2-4 mg	4-20 mg	> 20 mg		
<0,0010	55,26 %	8,24 %	10,83 %	7,82 %	0,57 %	82,72 %	-
0,0010-0,0025	6,21 %	0,97 %	1,48 %	1,27 %	0,08 %	10,01 %	44,39 %
0,0025 - 0,0100	4,71 %	0,70 %	1,06 %	0,88 %	0,06 %	7,41 %	32,86 %
0,0100-0,0500	2,21 %	0,32 %	0,48 %	0,35 %	0,03 %	3,40 %	15,07 %
0,0500 - 1,0000	1,04 %	0,16 %	0,23 %	0,16 %	0,02 %	1,60 %	7,11 %
1,0000-5,0000	0,07 %	0,01 %	0,01 %	0,01 %	0,00 %	0,11 %	0,49 %
> 5,0000	0,01 %	0,00 %	0,00 %	0,00 %	0,00 %	0,02 %	0,08 %

Tabell 3. Innsjøareal fordelt på kalk- og størrelseskategorier (areal i km²). 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (> 20 mg Ca/l).

	1	2	3	4	5	Sum km ²
	< 1 mg	1-2 mg	2-4 mg	4-20 mg	> 20 mg	
<0,0010	247,42	36,57	48,60	35,11	2,51	370,20
0,0010-0,0025	196,53	30,83	46,88	40,19	2,56	316,99
0,0025 - 0,0100	462,83	69,00	104,54	86,17	6,08	728,62
0,0100-0,0500	978,18	143,93	215,79	158,35	14,05	1 510,30
0,0500 - 1,0000	3 961,87	627,17	884,10	623,31	69,17	6 165,61
1,0000-5,0000	2 692,89	516,17	566,93	503,92	66,65	4 346,56
> 5,0000	2 581,27	725,82	800,08	712,59	222,18	5 041,93
Sum alle størrelseskat.	11 120,98	2 149,49	2 666,91	2 159,64	383,18	18 480,20

2.3 Antall innsjøer fordelt på bioklimatiske soner

Tabell 4 viser antall innsjøer fordelt på størrelseskategorier og ulike bioklimatiske soner. Antall innsjøer i den nemorale og boreonemorale er 77 858, som utgjør fire prosent av det totale antallet sjøer og 11 % av totalt innsjøareal. Disse to sonene tilsvarer grovt kystsonen i Sør-Norge (se kart i vedlegg 2). Flest innsjøer er det i nordboreal og alpin sone, henholdsvis 674 589 og 633 728. I andel av totalt antall tilsvarer dette henholdsvis 33 og 31 prosent. Prosentandelen i andel av totalt innsjøareal er henholdsvis 29 og 31 prosent. Disse to siste sonene tilsvarer grovt fjellområdene i Norge.

Tabell 4. Antall innsjøer fordelt på bioklimatiske soner (se vedlegg 2 for kart) og størrelseskategorier (areal i km²).

Innsjøareal (km ²)	Nemoral	Boreone-moral	Sørboreal	Mellom-boreal	Nordbo-real	Alpin
	<0,0010	4 629	53 834	138 645	438 991	527 899
0,0010-0,0025	515	5 045	9 965	28 999	68 877	86 760
0,0025 - 0,0100	667	5 609	8 951	20 274	48 340	64 636
0,0100-0,0500	546	4 112	5 306	9 732	20 154	28 341
0,0500 - 1,0000	307	2 335	2 923	5 059	8 563	13 051
1,0000-5,0000	13	205	293	381	627	690
> 5,0000	2	39	57	69	129	64
Sum	6 679	71 179	166 140	503 505	674 589	633 728
Andel antall	0,3 %	3,5 %	8,1 %	24,5 %	32,8 %	30,8 %
Andel Areal	0,6 %	9,9 %	11,9 %	17,1 %	29,4 %	31,0 %

2.4 Antall innsjøer med forekomst av rødlistearter

Tabell 5 viser antall innsjøer hvor det er gjort en eller flere observasjon(er) av rødlistearter (data fra Artskart og GBIF), fordelt på ulike størrelseskategorier og ulike kalkkategorier basert på berggrunnen i og rundt innsjøene. Rødlisteartene omfatter alle kategorier fra nær truet (NT) og oppover for alle artsgrupper som er funnet i eller nærmere enn 10 m fra en innsjø. Det er innsjøer over 5 km² som har den største andelen funn av rødlistearter (80 %). Dette skyldes at de store innsjøene har mange habitattyper og utgjør et stort areal. I tillegg er fugl og pattedyr inkludert i gruppen av rødlistede arter. Disse to gruppene utgjør alene mer enn 3/4 av alle rødlistede observasjoner i Artskart som kan knyttes til innsjøer. Mange av de store innsjøene har fuglefredningsområder med regelmessig observasjon av fugl. **Tabell 9** ser nærmere på observasjoner uten fugl og pattedyr.

Andelen av innsjøene i kategorien kalkrik (4) og svært kalkrik (5) med rødlistearter er henholdsvis 0,9 og 2,2 % for alle størrelseskategorier. Hvis vi ser bare på størrelseskategorien mindre enn 1 000 m², er denne andelen henholdsvis 0,1 og 0,3 % (**tabell 6**). Dette er trolig både et uttrykk for at innsjøer mindre enn 1 000 m² har færre habitatstyper pr lokalitet og i mindre grad er kartlagt, sammenlignet med større lokaliteter.

Tabell 6 viser andelen av innsjøene i **tabell 1** som har observasjoner av rødlistede arter. Det er innsjøene over 5 km² som har den største andelen innsjøer med observerte rødlistearter. Det er størrelsen (stor habitatdiversitet) på innsjøene og sannsynligvis kartleggingsaktivitet som gjør at denne andelen er høy. Tilsvarende viser **tabell 7** arealet for innsjøene med rødlisteobservasjoner.

Tabell 5. Antall innsjøer hvor det er registrert rødlistearter fordelt på kalk- og størrelseskategorier. Andel av sjøene i de ulike kalkkategoriene med funn (observasjoner) nederst i tabellen og andelen med registrerte rødlistefunn fordelt på størrelseskategorier helt til høyre i tabellen. 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (>20 mg Ca/l).

	1 < 1 mg	2 1-2 mg	3 2-4 mg	4 4-20 mg	5 > 20 mg	Sum	Andel med funn
<0,0010	465	145	109	142	31	892	0,05 %
0,0010-0,0025	267	81	84	128	21	581	0,29 %
0,0025 - 0,0100	709	154	236	201	49	1 349	0,90 %
0,0100-0,0500	1 574	315	420	407	74	2 790	4,07 %
0,0500 - 1,0000	3 503	680	792	727	135	5 837	18,03 %
1,0000-5,0000	660	153	143	171	22	1 149	51,87 %
> 5,0000	160	38	38	44	7	287	79,72 %
Sum alle størrelseskat.	7 338	1 566	1 822	1 820	339	12 885	0,61 %
Andel med rødlistearter	0,52 %	0,75 %	0,64 %	0,86 %	2,21 %	0,61 %	-

Tabell 6. Andel (%) av lokalitetene med observasjon av rødlistearter i innsjøer fordelt på kalk- og størrelseskategorier (areal i km²). 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (> 20 mg Ca/l). Samlet andel for størrelsesgruppen i kolonnene til høyre (alle størrelseskategorier).

	1 < 1 mg	2 1-2 mg	3 2-4 mg	4 4-20 mg	5 > 20 mg	Sum
<0,0010	0,04 %	0,09 %	0,05 %	0,09 %	0,27 %	0,05 %
0,0010-0,0025	0,21 %	0,41 %	0,28 %	0,50 %	1,28 %	0,29 %
0,0025 - 0,0100	0,75 %	1,09 %	1,10 %	1,13 %	3,98 %	0,90 %
0,0100-0,0500	3,53 %	4,84 %	4,30 %	5,70 %	11,35 %	4,07 %
0,0500 - 1,0000	16,66 %	21,09 %	17,34 %	22,83 %	36,59 %	18,03 %
1,0000-5,0000	48,35 %	58,62 %	47,83 %	66,28 %	68,75 %	51,87 %
> 5,0000	75,83 %	84,44 %	74,51 %	95,65 %	100,00 %	79,72 %

Tabell 7. Innsjøareal for lokaliteter med rødlistearter fordelt på kalk- og størrelseskategorier (areal i km². 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (> 20 mg Ca/l)). Samlet areal for størrelsesgruppen i kolonnene til høyre (alle størrelseskategorier) og for kalkkategorien nederst..

	1	2	3	4	5	Sum
	< 1 mg	1-2 mg	2-4 mg	4-20 mg	> 20 mg	km ²
<0,0010	0,19	0,06	0,05	0,07	0,02	0,39
0,0010-0,0025	0,44	0,13	0,14	0,22	0,03	0,96
0,0025 - 0,0100	4,13	0,92	1,30	1,14	0,32	7,80
0,0100-0,0500	41,64	8,13	11,32	11,04	1,98	74,12
0,0500 - 1,0000	926,81	199,70	217,93	190,30	39,24	1 573,98
1,0000-5,0000	1 327,02	317,88	305,30	383,58	42,42	2 376,21
> 5,0000	2 172,50	673,69	682,87	696,73	222,18	4 447,96
Sum alle størrelseskat.	4 472,73	1 200,52	1 218,90	1 283,07	306,19	8 481,41

Tabell 8 viser totalt antall observasjoner av rødlistede arter som er gjort for alle innsjøer hvor det er registrert rødlistearter. Mønstrer er relativt likt som i **tabell 5** og **6**, med flest observasjoner i de større innsjøene. Litt overaskende er det at det er flest observasjoner i de laveste kalkkategoriene med henholdsvis 42 og 40 observasjoner per innsjø i gjennomsnitt.

Tabell 8. Antall funn (observasjoner) av rødlistede arter per innsjø med registrerte forekomster av en eller flere rødlistearter fordelt på kalk- og størrelseskategorier. 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (> 20 mg Ca/l). Samlet antall for størrelsesgruppen i kolonnene til høyre (alle størrelseskategorier) og for kalkkategorien nederst. Nederst er det også regnet ut gjennomsnittlig antall observasjon i hver kalkkategori.

	1	2	3	4	5	Sum
	< 1 mg	1-2 mg	2-4 mg	4-20 mg	> 20 mg	
<0,0010	556	316	262	317	31	1 482
0,0010-0,0025	780	619	174	825	43	2 441
0,0025 - 0,0100	6 903	6 401	2 919	4 861	193	21 277
0,0100-0,0500	24 967	3 058	13 130	8 924	1 712	51 791
0,0500 - 1,0000	154 105	21 423	52 092	35 580	4 912	268 112
1,0000-5,0000	74 046	12 085	12 926	7 728	1 742	108 527
> 5,0000	27 017	39 813	8 470	17 170	20 357	112 827
Sum alle størrelseskat.	288 374	83 715	89 973	75 405	28 990	566 457
Gjennomsnitt pr lok.	42,2	39,8	27,1	18,5	29,9	32,7

Mer enn $\frac{3}{4}$ av alle rødlisteregistreringene i Artskart som kan knyttes til innsjøer er fugler eller pattedyr. **Tabell 9** viser antall registrerte rødlistefunn i innsjøer for alle artsgrupper uten fugl og pattedyr. Totalt er det registret 840 innsjøer med rødlistefunn for disse artsgruppene. Naturlig nok blir andelen innsjøer med rødlistefunn vesentlig lavere for både alle størrelseskategoriene og for alle kalkkategoriene, når alle fugle- og pattedyrobservasjoner utelates. Antall observasjoner pr lokalitet med rødlistearter synker i gjennomsnitt til 1/10 av det den var når alle artsgruppene var inkludert (**tabell 10**).

Tabell 9. Antall innsjøer hvor det er registrert rødlistearter uten fugl og pattedyr fordelt på kalk- og størrelseskategorier. Andel av sjøene i de ulike kalkkategoriene med funn (observasjoner) nederst i tabellen og andelen med registrerte rødlistefunn fordelt på størrelseskategorier helt til høyre i tabellen. 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (>20 mg Ca/l).

	1 < 1 mg	2 1-2 mg	3 2-4 mg	4 4-20 mg	5 > 20 mg	Sum	Andel med funn
<0,0010	116	28	23	27	14	208	0,01 %
0,0010-0,0025	45	15	7	13	4	84	0,04 %
0,0025 - 0,0100	57	18	16	12	3	106	0,07 %
0,0100-0,0500	38	15	9	10	6	78	0,11 %
0,0500 - 1,0000	108	40	17	24	14	203	0,63 %
1,0000-5,0000	55	19	10	16	4	104	4,70 %
> 5,0000	25	10	8	9	5	57	15,83 %
Sum alle størrelseskat.	444	145	90	111	50	840	0,04 %
Andel med rødlistearter	0,03 %	0,07 %	0,03 %	0,05 %	0,33 %	0,04 %	-

Tabell 10. Antall funn (observasjoner) av rødlistede arter uten fugl og pattedyr per innsjø med registrerte forekomster av en eller flere rødlistearter fordelt på kalk- og størrelseskategorier. 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (>20 mg Ca/l). Samlet antall for størrelsesgruppen i kolonnene til høyre (alle størrelseskategorier) og for kalkkategorien nederst. Nederst er det også regnet ut gjennomsnittlig antall observasjon i hver kalkkategori.

	1 < 1 mg	2 1-2 mg	3 2-4 mg	4 4-20 mg	5 > 20 mg	Sum
<0,0010	330	252	110	32	24	748
0,0010-0,0025	140	17	12	14	6	189
0,0025 - 0,0100	221	20	23	24	4	292
0,0100-0,0500	81	17	15	24	16	153
0,0500 - 1,0000	679	252	62	39	21	1 053
1,0000-5,0000	279	104	15	20	15	433
> 5,0000	102	32	64	45	94	337
Sum alle størrelseskat.	1 832	694	301	198	180	3 205
Gjennomsnitt pr lok.	4,1	4,8	3,3	1,8	3,6	3,8

2.5 Antall innsjøer med forekomst av arter

Vi har også sett nærmere på alle arter i artsgruppene krepsdyr og planter, også de som ikke er rødlistet. **Tabell 11** viser antall innsjøer med registrerte funn av planter i Artskart. Det er viktig her å presisere at det dreier seg om alle typer planter som er registrert i vann eller mindre enn 10 meter fra innsjøen. Oversikten viser at det er registrert planter i 3 av fire innsjøer over 5 km² og i nesten halvparten av innsjøene mellom 1 og 5 km². Dårligst er det for de minste innsjøene. For de under 1 000 m² er det registrert planter i mindre enn 0,1 % eller i omtrent 1 av 1 000 innsjøer. Andelen er omkring tre ganger så høy for innsjøene mellom 1 000 og 25 000 m². For denne størrelseskategorien er det registrert vannplanter i omtrent 3 av 1 000 lokaliteter.

For krepsdyrene er det noe av det samme bildet som for planter, men det er bare under halvparten så mange innsjøer med registrerte artsfunn (**tabell 12**). Også for krepsdyr er det best for de store innsjøene, med omtrent like mange innsjøer med registrerte funn av krepsdyr som med planter. For de minste innsjøene er imidlertid andelen med registrerte krepsdyrfunn lavere. For innsjøene under 1 000 m² er det registrert krepsdyr i omtrent 1 av 5 000 innsjøer og 1 av 1 000 for innsjøene mellom 1 000 og 25 000 m².

Tabell 11. Antall innsjøer hvor det er registrert plantearter fordelt på kalk- og størrelseskategorier. Andel av sjøene i de ulike kalkkategoriene med funn (observasjoner) nederst i tabellen og andelen med funn fordelt på størrelseskategorier helt til høyre i tabellen. 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (>20 mg Ca/l).

	1 < 1 mg	2 1-2 mg	3 2-4 mg	4 4-20 mg	5 > 20 mg	Sum	Andel med funn
<0,0010	624	226	161	146	68	1 225	0,07 %
0,0010-0,0025	307	96	96	76	19	594	0,29 %
0,0025 - 0,0100	548	178	175	130	52	1 083	0,72 %
0,0100-0,0500	831	260	253	198	92	1634	2,38 %
0,0500 - 1,0000	1734	462	443	452	129	3 220	9,95 %
1,0000-5,0000	485	139	113	134	15	886	40,00 %
> 5,0000	150	36	38	36	5	265	73,61 %
Sum alle størrelseskat.	4 679	1 397	1 279	1 172	380	8 907	0,42 %
Andel med planter	0,33 %	0,66 %	0,45 %	0,55 %	2,47 %	0,42 %	-

Tabell 12. Antall innsjøer hvor det er registrert krepsdyr fordelt på kalk- og størrelseskategorier. Andel av sjøene i de ulike kalkkategoriene med funn (observasjoner) nederst i tabellen og andelen med funn fordelt på størrelseskategorier helt til høyre i tabellen. 1= svært kalkfattig (< 1 mg Ca/l) til 5= svært kalkrik (> 20 mg Ca/l).

	1 < 1 mg	2 1-2 mg	3 2-4 mg	4 4-20 mg	5 > 20 mg	Sum	Andel med funn
<0,0010	146	39	54	52	19	333	0,02 %
0,0010-0,0025	73	25	37	37	10	182	0,09 %
0,0025 - 0,0100	109	39	63	62	15	288	0,19 %
0,0100-0,0500	237	90	64	80	21	492	0,72 %
0,0500 - 1,0000	953	305	202	235	45	1 745	5,39 %
1,0000-5,0000	403	95	90	115	9	715	32,28 %
> 5,0000	131	32	30	36	6	236	65,56 %
Sum alle størrelseskat.	2 052	625	540	617	125	3 959	0,19 %
Andel med krepsdyr	0,15 %	0,30 %	0,19 %	0,29 %	0,81 %	0,19 %	

2.6 Arter i ferskvann

Den første statusoversikten over limnisk arts mangfoldet i Norge ble publisert i 1996 (Aagaard og Dolmen 1996), mens den første statusoversikten i regi av Artsdatabanken (Artsprosjektet) ble publisert i 2011 (Aagaard 2011). Gjennom Artsprosjektet er statusoversikten over forekomst av arter i Norge er fulgt opp med nye publikasjoner i 2016 og 2021 (Elven og Søli 2016, Elven og Søli 2021). Artsprosjektet skal sikre langsiktig kunnskapsoppbygging om arter i norsk natur og har et spesielt fokus på arter og artsgrupper hvor kunnskapsnivået er dårlig. Artsprosjektet administreres av Artsdatabanken på vegne av Klima- og miljødepartementet. Som et ledd i Artsprosjektet er det utarbeidet oversikter over antall arter i Norge, og gjort vurderinger av hvor god kunnskap vi har om taksonomi, utbredelse og økologi for artsgruppene. Arbeidet er ledet av Naturhistorisk museum, Universitetet i Oslo i samarbeid med en rekke naturvitenskapelige institusjoner og frittstående fagpersoner.

Kunnskapsnivået om taksonomi, utbredelse og økologi varierer innenfor de vurderte artsgruppene over hele skalaen fra sikker kunnskap til total mangel på kunnskap. Kunnskapsnivået er overveiende vurdert å være relativt godt innen store deler av dyreriket (særlig innen gruppen virveldyr og enkelte insektordener) og innen karplantene. I Tabell 13 og 14 er det gitt en oversikt over antall arter for henholdsvis dyre- og planterikene med utgangspunkt i de publiserte katalogene.

Tabell 13. Oversikt over forekomst av ferskvannsdyr og antall rødlistearter for ulike artsgrupper i Norge.

Takson	Artsgruppe	1996 ¹⁾	2015 ²⁾	2020 ³⁾	Rødliste 2021 ⁴⁾
Klasse	Amfibier	6	7	8	3
Klasse	Strålfinnerfisker	41	45	45	2
Orden	Njøyer	4	4	4	2
Underrekke	Krepsdyr	219	240	224	20
Klasse	Edderkoppdyr	153	151	151	2
Orden	Vepser	1	1	1	2
Orden	Tovinger	1 016	1 073	1 212	58
Orden	Sommerfugler	5	5	5	3
Orden	Vårfluer	191	205	201	28
Orden	Biller	274	287	289	55
Orden	Mudderfluer	5	5	5	1
Orden	Nettvinger	2	2	3	2
Orden	Nebbmunnner	50	52	52	12
Orden	Steinfluer	35	35	35	2
Orden	Øyestikkere	45	50	52	8
Orden	Døgnfluer	44	48	49	6
Rekke	Bløtdyr	50	51	60	13
Rekke	Leddormer	65	64	94	3
Rekke	Hjuldyr	288	310	314	0
Rekke	Mosdyr	7	11	11	3
Rekke	Bjørnedyr	37	25	30	0
Rekke	Rundormer	57	-	11	0
Rekke	Flatormer	56	-	95	0
Rekke	Nesledyr	3	2	28	0
Klasse	Taglormer	1	1	1	0
Rekke	Krassere	7	5	5	0
Rekke	Svamper	5	5	5	1
	Sum	2 667	2 684	2 990	226

1) Aagaard og Dolmen 1996. 2) Elven og Sørli 2016. 3) Elven og Sørli i trykk. 4) Artsdatabanken 2021.

Tabell 14. Oversikt over forekomst av ferskvannsplanter og antall rødlistearter for ulike artsgrupper i Norge.

Takson	Artsgruppe	2015 ¹⁾	2020 ²⁾	Rødliste 2021 ³⁾
Rekke	Dekkfrøete planter	106	106	42
Rekke	Karsporeplanter	4	4	0
Rekke	Bladmoser	75	75	17
Rekke	Kransalger, inkl. andre algegrupper	230	291	37
Rekke	Grønnalger	306	293	-
Rekke	Levermoser	20	20	2
Rekke	Rødalger	24	24	-
	Sum	765	813	98

1) Elven og Sørli 2016. 2) Elven og Sørli 2021. 3) Artsdatabanken 2021.

2.7 Oppsummering for biodiversitet i ferskvann

Under er en oppsummering av viktige punkter for biodiversitet i ferskvann:

- Andel innsjøer under 1 000 m² utgjør hele 83 % av totalt antall innsjøer.
- Samlet innsjøareal utgjør 18 480 km²
- Det er få registreringer av rødlistede arter i ferskvann
- Andelen av innsjøene med registrerte rødlistearter er relativt lik for alle kalkkategoriene fra 1 til 4, men rundt fire ganger så høy i kalkkategori 5.
- Fugl og pattedyr utgjør mer enn 3 av 4 registreringer av rødlistede arter i ferskvann.
- Andelen rødlistearter er lavest for innsjøene under 25 000 m². Denne kategorien innsjøer er også svært dårlig kartlagt.
- Innsjøene over 1 km² har den høyeste andelen rødlistede arter og er de best kartlagte.
- Det kan virke som at hoveddelen av kartleggingene i ferskvann har sin bakgrunn i vassdragssvernundersøkelser, forsøringsundersøkelser og overvåking i store innsjøer.
- Med unntak for fisk, vannplanter, krepsdyr og amfibier er det for alle artsgrupper færre enn 1 000 innsjøer med artsregistreringer, dvs. at færre enn 1 av 2 000 innsjøer i Norge er kartlagt. For mange artsgrupper er antall innsjøer med kartlagt forekomst langt lavere.
- Hovedvekten av de kartlagte innsjøene er store. Rundt 12 prosent av innsjøene større enn 0,5 km² er kartlagt for en eller flere artsgrupper av ferskvannsdyr, mens kun 0,2 % av innsjøene under 0,5 km² har tilsvarende kartlegging.

3 Påvirkning av kalklokaliteter

Vi har brukt en infrastrukturindeks som mål for menneskelig påvirkning av kalklokalitetene. Infrastrukturindeksen er utregnet som frekvensen av nøkkelvariabler (i denne sammenheng ulike typer infrastruktur som medfører inngrep og fragmentering av arealer), målt i en sirkel med 500 m radius rundt hver piksel (fokuspunkt) og utregnet for hele landet. Infrastrukturindeksen består av to komponenter som summeres: En bygningskomponent og en konstruert fastmarkskomponent (som angir forekomst av konstruert fastmarksareal, resultatet av inngrep som gir landskapet et «menneskelandskapspreg»). Det skal understrekes at frekvens innebærer at det er fravær eller forekomst av ett eller flere av elementene i hver kategori (bygningkomponent eller fastmarkskomponent) som avgjør om en piksel får verdi 0 eller 1. Om flere bygningskomponenter forekommer i én piksel eller en hytte eller et stort industrianlegg forekommer i pikselen, spiller ingen rolle – skåren 1 er den samme.


Kartdatagrunnlag som inngår i bygningskomponenten er:

- bygninger (av ethvert slag) (GAB)
- linjeelementene fra N50 anlegg (inkludert framtreddende kraftlinjer)
- samferdsel fra N50 (traktorveg og sti ikke inkludert).

Kartdatagrunnlag som inngår i konstruert fastmarkskomponenten er:

- bebygd areal (N50)
- tettbebygd areal (N50)
- industriområde (N50)
- lufthavn (N50)
- steinbrudd (N50)
- gravplass (N50)
- sport/idrettsanlegg (N50)
- dyrket mark
- regulerte innsjøer

Disse to komponentene kombineres til Infrastrukturindeks-verdier per piksel (for detaljer, se Erikstad m.fl. 2013 og Jakobsson m.fl. 2020). Selve utregningen av infrastrukturindeksen foregår ved hjelp av raster-kalkulasjoner med et flytende nabolagsvindu som beveger seg over kartgrunnlaget og regner indeksverdien fortløpende (**figur 1**).




Figur 1. Prinsippet for frekvensberegning i flytende nabolagsvindu med 500 m radius (nabolagssirkel) og data med oppløsning 100x100m. Fokuspunktet er markert med en svart prikk plassert i midten av ruta. Denne midtruta skal nå gis en indeksverdi! Nabolagssirkelen inneholder 81 ruter á 100x100m (lys rosa farge) som ligger helt eller delvis innenfor nabolagssirkelen. I figureksemplet er en egenskap (f.eks. forekomst av bygninger) indikert med røde prikker. Det ligger 9 hus innenfor nabolagssirkelen, og 10 av rutene, som er markert med grønt, inneholder hus. I dette eksemplet har nøkkelvariabelen derfor verdien 10, eller alternativt 0,123, hvis den oppgis som frekvens. Hvert punkt i undersøkelsesområdet blir

etter tur benyttet som fokuspunkt ved beregning av nøkkelvariabler, slik at datasettet inneholder variabelverdier for alle nøkkelvariabler for alle 100x100 m-ruter. Dette rasteret (rutenettet) kan vurderes og endre størrelse etter behov. I denne omgang er kun infrastrukturindeksen utregnet med 500 m radius og 100 m oppløsning på nøkkelvariable.

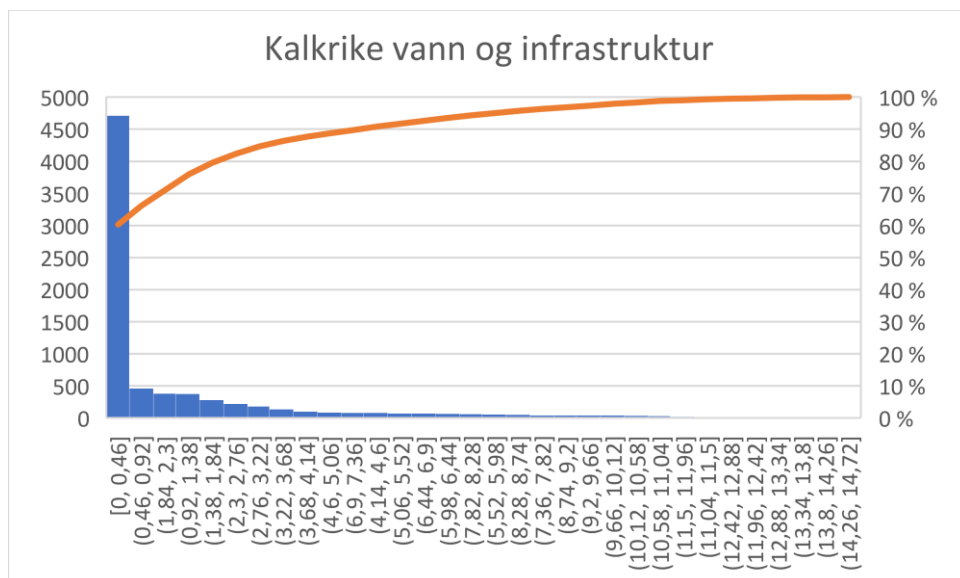
Infrastrukturindeksen kan kobles til ulike underlagskart som gjør at vi blant annet kan se hvilke typer natur som blir påvirket. Jakobsson m.fl. 2020 gjennomgår et omfattende antall slike kartlag med ulikt opphav og formål. Infrastrukturindeksen kan også kobles på planlagte inngrep og regnes om etter ulike konkrete inngrepsplaner. Dette betyr at du kan legge inn nye veier, jernbane, osv. slik at verdiene av cellene endrer seg. Det er også mulig å regne indeksen tilbake i tid for å få en tidsutvikling på mengde inngrep i ulike områder. Alt dette betyr at man kan bruke endringen i indeksen som en indikator på hvor mye man påvirker «uberørt» natur (pr. indeksen).

Figur 2 viser infrastrukturindeksen over Norge. En foreløpig tilgjengelig innsynsløsning til infrastrukturen er gjort tilgjengelig her <https://vegar.users.earthengine.app/view/infrastrukturindeks> - merk at denne er tilpasset Google Chrome nettleser.



Figur 2. Infrastrukturindeks over Norge.


Vi har sett på korrelasjon mellom predikerte kalksjøer i Norge og infrastruktur. I rapporten av Dervo m.fl. (2020) ble det modellert ca. 4 000 innsjøer i kalkklasse 5 (den rikeste klassen i det økologiske grunnkartet for kalkrikhet). Ved å bruke samme metodikk med vann i N5 som kartgrunnlag, får vi rundt 7 300 innsjøer i kalkklasse 5. Vi har her sjekket fordelingen av disse innsjøene med predikert høyest kalkinnhold mot verdier i infrastrukturindeksen (se **figur 3**).



Figur 3. Fordelingen av kalkrike innsjøer mot infrastrukturindeksen.


Fra **figur 3** ser vi at over 90% av alle predikerte kalkrike vann har infrastruktur-verdier nær 0. Dette indikerer at storparten av kalklokalitetene er lite påvirket av infrastruktur. Dette stemmer overens med at mange av disse innsjøene ligger i Nordland og Troms og eller i fjellområder, som er mindre utbygget enn for eksempel de lavereliggende områdene i Sør-Norge. Hele 74 % av innsjøene er under 1 000 m². Mange av disse ligger i lite utbygde områder.

Hvis man ser på tilsvarende sammenheng i Sør-Norge får vi en lignende fordeling, men en større andel av innsjøene er påvirket av infrastruktur (**figur 4**). I denne figuren er også vann i N5 brukt som kartgrunnlag, dvs. lokaliteter under er 1 000 m² inkludert.



Figur 4. Fordelingen av kalkrike innsjøer sør for Trondheim mot infrastrukturindeksen. X-aksen er gjort om til en kategorisk variable sortert etter antall innsjøer i hver kategori.

Infrastrukturindeksen kan utvikles videre og tilpasses ulike behov. Gjennom utviklingen av Natur i Norge (NiN) er det laget en egen indeks for å dekke opp jordbrukspreg. På bakgrunn av dette er det laget en utvidet infrastrukturindeks som inkluderer både fulldyrket mark og regulerte vann (figur 5). Det er denne indeksen som er brukt i analysene i denne rapporten.



Figur 5. Figuren viser infrastrukturindeksen til venstre og den utvidete versjonen som er brukt i denne rapporten der en har inkludert både dyrket mark og regulerte innsjøer til høyre.

I forbindelse med naturtyper i ferskvann vil det være naturlig å jobbe videre med komponentene vassdragsreguleringer og jordbruksintensitet, selv om disse inngår i den versjonen av infrastrukturindeksen som er brukt i denne rapporten. For eksempel vil det være aktuelt å ta med reguleringshøyde for magasinene. I eksemplet over i figur 5 vil Mjøsa kunne ha en større eller eventuelt en mindre infrastrukturindeksverdi avhengig av hvor mye reguleringsgrad skal ha av betydning på indeksen. Det vil således være mulig å bygge inn andre parametere i beregningen av indeksen slik som fraført eller overført vann og andre påvirkningsfaktorer. Spesielt en bedre indeksering av jordbruksvirksomhet vil ha betydning for forståelsene av påvirkede kalklokaliteter. Generelt for naturtyper i vann vil en bedre indeksering av vassdragsreguleringer og flomtiltak i elver være viktig for å få et mer helhetlig bilde av påvirkede vannlokaliteter.

Infrastrukturindeksen kan både være en forklaringsvariabel i en prediksjonsmodell (se kap. 7 prediksjon av humusrike innsjøer) og en tilstandsvariabel slik som beskrevet i dette kapittelet. Infrastrukturindeksen viser en gradient i menneskelig påvirkning på naturen og den viser regionale forskjeller i påvirkning. Den kan således være en nyttig forklaringsvariabel når lokaliteter skal velges ut i forhold til utvalgt natur og for vurdering av dens tilstand.

4 Modelling av vandringshinder

Tilgang på høyopløselig terrengdata fra LiDAR har gjort det mulig å modellere vandringshindre ved bruk av verktøy i GIS (Hegder m.fl. 2020). Metoden er tidligere prøvd ut på utvalgte vassdrag i mindre avgrensede områder. Ny tilgang på storregnemaskiner gjør at metoden kan la seg bruke på en regional skala. Dette gjør det mulig å modellere vandringshindre langs lange elvestrekninger og i flere vassdrag samtidig på nasjonal skala.

4.1 Metode

Vi har brukt Google Earth Engine (Gorelick m.fl. 2017) som prosesseringsverktøy for å gjennomføre en stordata analyse av vandringshindre for fisk i Innlandet, med hovedfokus på elvestrekningene som fører storørrestammer. I tillegg har vi brukt samme metode i et pågående prosjekt sammen med Vitenskapelig råd for lakseforvaltning, der vi har modellert vandringshindre i 1 273 elvestrekninger for å finne lengde på anadrom strekning for laks, sjørørret og sjørøye (Forseth m. fl. under utarbeidelse, Solem m. fl. 2021).

Modell

Vi har tatt utgangspunkt i offisielle N5 kartdata og elvepolygonene som er avtegnet her. I N5-kartdata er alle elver eller bekker som er bredere enn 2 meter, over en viss lengde, tegnet som en polygon. Men gjennomføringen av denne 2-meters regelen er noe avhengig av hvor du befinner deg i landet, og er mindre gjennomført i Nord-Norge der regelen ofte overskrider 5 meter i mer grusgrendte strøk. I hele N5 finnes det ca. 216 000 elvepolygoner. De største elvene består av mange polygoner, mens mindre elver har færre polygoner. Polygonene er manuelt avtegnet av en kartoperatør og oppdateres ved jevnlig, men ulike mellomrom.

I dag er over 2/3 av landarealet i Norge dekket av LiDAR. Ut fra disse LiDAR-opptakene er det laget både terrengmodeller (DTM) og overflatemodeller type trehøyder o.l. (DOM) i en meters oppløsning (se hoydedata.no). I løpet av 1-2 år skal hele Norge ha en terrengmodell i en meters oppløsning. Dette skal gjøres gjennom nye LiDAR opptak og såkalt bildematching av andre flyfoto der det ikke gjøres LiDAR målinger. I vårt studieområde i Innlandet er det 100 % dekning av LiDAR.


Vi har lastet opp alle tilgjengelige LiDAR 1 x 1 meter terrengmodeller fra hoydedata.no på en «egen» og passord-beskyttet del av Google Earth Engine. Dette er et datasett som dekker mer en 200 000 km² av Norge og da med en oppløsning på 1m². Dette tilsvarer et datasett bestående av mer enn 200 000 000 000 pixler. Vi har også lastet opp alle N5 elvepolygonene i Google Earth Engine på samme måte.

Vi har så fulgt følgende prosedyre for å modellere vandringshindre i Google Earth Engine:

- Vi regnet ut helning fra høydemodellen, som en geografisk variabel fra 0-90 grader, ved hjelp av funksjonen `ee.Terrain.slope`.
- Deretter ble elvepolygonene lagt over helningsmodellen, og terrengmodellen (helningsmodellen) ble klippet slik at kun pixler innenfor elvepolygonene ble beholdt for videre analyse.
- Ved analyse av kjente vandringshindre ble det funnet ut at laks, sjørørret og ørret meget sjeldent klarer å forsere stryk eller fosser med helningsvinkel på 24 grader over en distanse på tre meter. Vi har derfor dette som et kriterium i modellen.
- Alle elvepolygon-pixler ble så delt inn i klasse 1 for helning mindre enn 24 grader, og klasse 2 for pixler med verdi mer enn 24 grader.
- Pixlene i de to klassene ble så konvertert til polygoner der det var nok med et felles kontaktpunkt i et hjørne for å danne en sammenhengende polygon.

- For alle polygoner i klasse 2 (piksler >24 grader), ble forskjellen på maksimum og minimum høydeverdi innen polygonene utregnet ved hjelp av en reduce-funksjonen «reduceregion» i Google Earth Engine. Dette ga høydeforskjellen innen hver vannhindringspolygon, og dermed høyden for det potensielle vandringshinderet.
- Alle polygoner med enten klasse 1 eller 2 ble eksportert ut fra Google Earth Engine med en størrelsesbegrensning på ca. 80 MB per shapefil (GIS-fil). Et område som dekker store deler av innlandet (se **figur 8**) tilsvarer ca. seks 80 MB shapefiler og kan håndteres i en desktop GIS verktøy på egen PC.

For å definere et vandringshinder som absolutt umulig å passere, kreves det at det potensielle vandringshinderpolygonen dekker hele elvebredden, slik at de ikke finnes en vei rundt for fisken (se eksempel i **figur 7**). Dette er en litt tyngre og vanskeligere GIS-øvelse som krever en selektering av polygoner med felles grenser i en bestemt rekkefølge (**figur 6**).




Figur 6. En egen prosedyre brukes for å finne ut når et vandringshinder dekker hele elva og setter et punkt ved hvert av disse hindrene. De gule punktene i kartet representerer et slik vandringshinder.

Prosedyren for å lage et vandringshinder som dekker hele elvebredden er gitt her:

1. Man begynner å selektere en polygon som ikke fungerer som hinder (klasse 1 polygon). Denne polygonen vil strekke seg helt til den blir avsluttet i en klasse 2 polygon.
2. For at en klasse 2 polygon skal være et hinder trenges det en ny klasse 1 polygon på den «andre» siden, slik at fisken blir hindret i å komme seg videre til en ny klasse 1 polygon. Et vandringshinder er derfor, i denne rapporten, definert som en polygon med helning > 24 grader (klasse 2), og som har minst to felles grenser til polygoner med helningsvinkel < 24 grader (klasse 1).
3. Det oppstår mange ulike situasjoner der mange polygoner møter hverandre og det trenges etter hvert mer og mer kompliserte regler for å skille virkelige hindre fra de som ikke er det.
4. Et eksempel på et «hinder» som oppstår, og som ikke er et gyldig hinder, er små polygoner langs elvekanten som i utgangspunktet er tegnet litt unøyaktig av kartoperatør og har havnet delvis på land (se **figur 14**). Disse er svært vanskelige å fjerne uten at man må sette størrelseskriterier på klasse 1 polygonene som kun har en nabo. Men dette vil igjen føre til andre utfordringer slik som at små sideelver risikerer å falle ut fra modellen.
5. Vi har endt opp med å gjøre en manuell prosedyre med selektering av polygoner med og uten felles grenser mellom klasse 1 og 2 polygonene, ved hjelp av «select by location» verktøyet i ArcGIS Pro, etter prinsippene beskrevet over. Dette vil aldri bli 100 % riktig på grunn av det store mangfoldet innen polygongrenser og polygonmøter. Derfor vil det være nødvendig med en manuell vasking av dataene i etterkant av denne prosedyren.

Et kartutsnitt av en vandringshindermodell er vist i **figur 7**. I figuren er polygoner i klasse 1 (partier uten vandringshindre) vist med blå farge, mens partier som er i klasse 2 (potensielle vandringshindre) er vist med rød farge. Figuren inkluderer eksempler på mange av utfordringene i prosedyren vi har diskutert foran. I figuren vises mange røde polygoner som i utgangspunktet er utilgjengelig for fisken fordi helningsgraden her er for stor. Dette kan være fossestryk, men det kan også være steiner, blokker eller andre fysiske hindre. Det er først når en hel rød polygon dekker hele bredden av elva vi har definert dette som et vandringshinder. Et eksempel på vandringshinder er vist med en lilla farget prikk oppe i venstre hjørnet av figuren. Her dekker en rød polygon av klasse 2 hele elva. I sideelvene finnes mange andre eksempler der de røde områdene dekker hele elveløpet, og er da også eksempler på vandringshindre. Polygoner av klasse 2 som ligger midt i elven er lett å skille ut som ikke vandringshindre da de kun tilstøter en annen polygon av typen klasse 1. Det er de røde polygonene (klasse 2) langs elvekanten som er vanskelige å bli kvitt i en selekteringsprosess (se over), da noen av disse har en liten polygon på yttersiden igjen «mot land» som er av klasse 1.



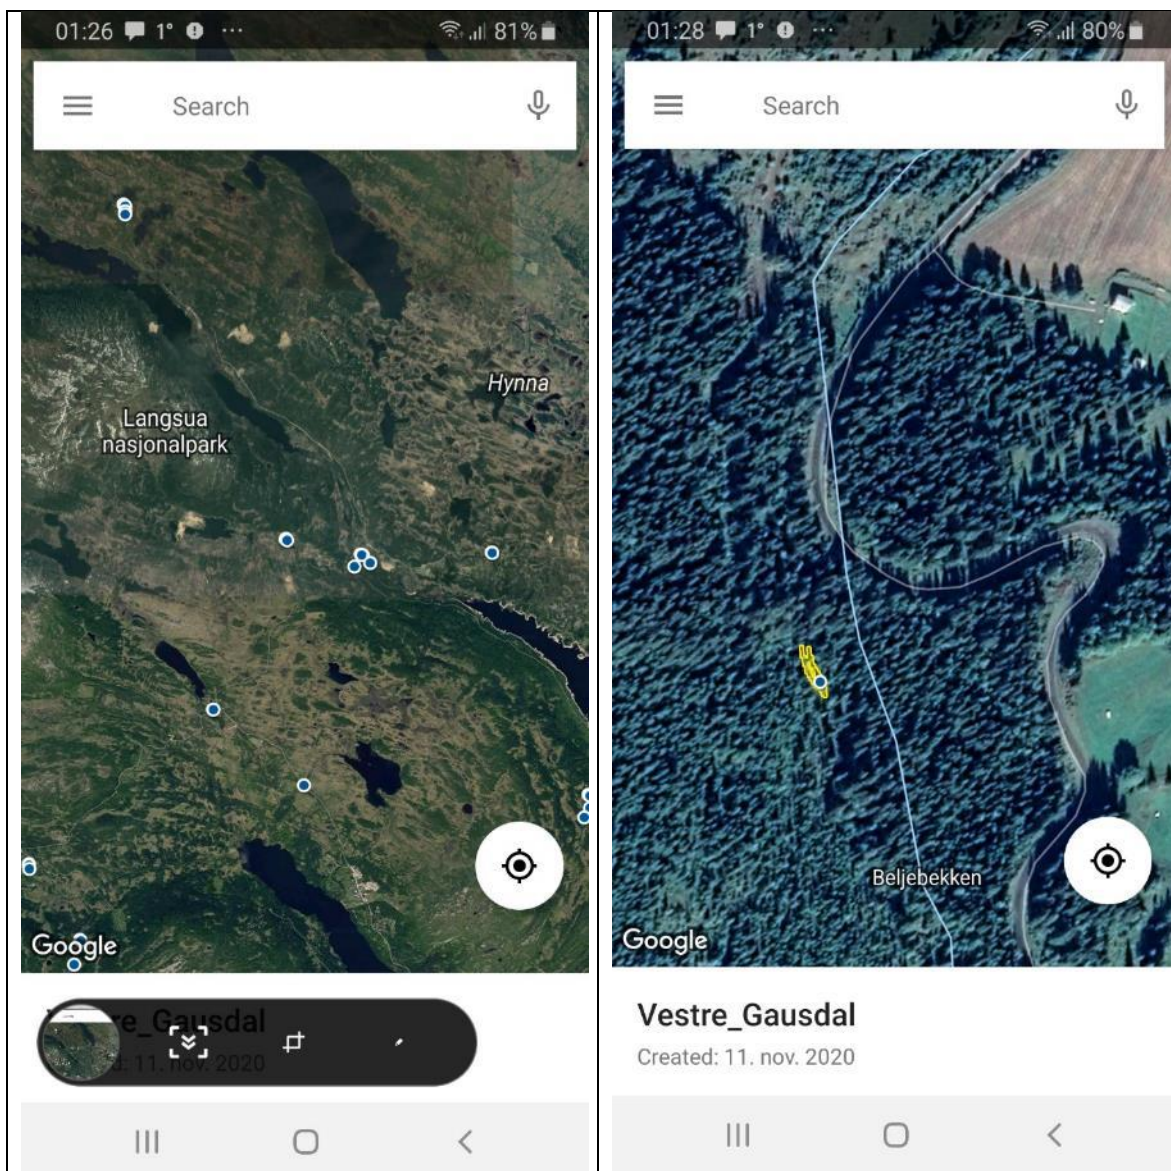
Figur 7. Vandringshindre og vandringsbarriere i en del av et utvalgt vassdrag. Her er polygoner i klasse 1 (partier uten vandringshindre) vist med blå farge, mens partier som er i klasse 2 (potensielle vandringshindre) er vist med rød farge.

I dette prosjektet har vi fokusert på et område i Innlandet som også inneholder flere vassdrag med storørretstammer. Området vi har modellert strekker seg fra Tyrifjorden i sør til Dokka-vassdraget i nord (se **figur 8**). Mjøsområdet og deler av Lågen-vassdraget er også inkludert i studieområdet. I alt fant vi 10 557 potensielle vandringshindre for fisk innenfor denne avgrensningen av studieområdet. Modellen er tilpasset til hva til som er kjente begrensninger eller vandringshindre for storørret i dag. Dette er vurdert til å være strekninger med helningsvinkel 24 grader, horisontal lengde på 3 meter og høydeforskjell på minst 1.5 meter. Vurderingen er gjort på bakgrunn av analyser av 1273 laks- og sjørret elver (Forseth m. fl. under utarbeidelse). Det er også brukt informasjon fra artene laks, sjørret og sjørøye, som vi antar har omtrent de samme fysiske egenskapene som storørreten.



Figur 8. Viser 10 557 vandringshindre som er modellert i Innlandet. Det vil være flere hindre i samme elv eller elv bekk. Skal man modellere elvestrekninger med storrett så skal man måle strekningen fra innsjø til først uoverkommelige vandringshindre. Modellen tar utgangspunkt i vannhindre som skal tilsvare, eller være større enn det som er fysisk umulig for en storrett å forsere.

For å gjøre en uavhengig evaluering av vandringshindrene la vi alle de modellerte vandringshindrene inn på en app som kunne tas med ut i felt (**figur 9**). Vi har i denne forbindelse brukt en gratis app utviklet av Google Maps som er kalt MyMaps. I denne appen kan man legge inn både punktlokasjonen av vandringshindrene og selve polygonene av de modellerte hindrene. Appen fungerer både som GPS og som en kartmodul.



Figur 9. Skjerm bilde av MyMaps som er en gratis app som kan tilpasses for innhenting av evalueringpunkter for testing av prediksjonsmodeller. Lokasjonene for innhenting av evalueringpunktene kan plottes på kart som synes på mobiltelefonen og som også viser din posisjon (figur til venstre). Piksler eller objekter/arealavgrønsinger kan visualiseres i høyoppløselig målestokk for hver lokasjon (figur til høyre).

Vi besøkte 250 vandringshinder i felt for å sjekke treffsikkerheten til modellen. I forbindelse med feltarbeidet ble det laget et skjema med ulike variabler som skulle scores. Dette var:

1. Dato
2. Analysert av
3. Vannføring (Liten/Normal/Stor/Flom)
4. Absolutt hinder for fiske (Ja/nei/Mulig)
5. Bredde (meter)
6. Lengde (meter)
7. Høyde (meter)
8. Helning (0-90)

9. Grad hinder (0-10)
10. Bru, kulvert? (Ja/Nei/Vet ikke)
11. Annen infrastruktur , forbygning, etc? (Ja/Nei/Vet ikke)
12. Er hinderet kommet ved menneskelig inngrep? (Ja/Nei/Vet ikke)
13. Er polygon helt eller delvis avtegnet der elva går? (Ja/Nei/Vet ikke)
14. Er elva overvokst eller tettbevokst av trær? (Ja/Nei/Vet ikke)
15. Går elva går i dyp kløft? (Ja/Nei/Vet ikke)
16. Er det blokkrikt og steinete? (Ja/Nei/Vet ikke)
17. Er hinderet oversiktlig fra der du står? (Ja/Nei/Vet ikke)
18. Hinder tegnet på skjema (Ja/nei)
19. Kommentar
20. Bilde ja (1)/nei(2)

I tillegg til dette uavhengige datasettet fra feltarbeid, ble også modellen utestet for 448 lakseelver hvor kjente vandringshindre er gitt i lakseregisteret (se [Miljødirektoratet - Kartkatalog \(miljodirektoratet.no\)](http://Miljødirektoratet - Kartkatalog (miljodirektoratet.no))) og for 825 sjørretelver der resultatene er manuelt gjennomgått med kjentfolk i de ulike elvene.

4.2 Resultat

Den uavhengige valideringen av modellen viste at for alle hindre høyere enn 1,5 meter så ble 12 av 159 hindre feilklassifisert. Feilklassifiseringene var ofte tilknyttet infrastruktur slik som kulverter og også fisketrapper. Disse var da modellert som hinder, men i felt ble de avkreftet å være hinder. Korrelasjon mellom hindre, og de som ble klassifisert som ikke hindre i felt, og andre parametere som ble målt i felt ved evaluering av modellen er gitt i **tabell 15**.

Tabell 15. Korrelasjonstabell med modellerte hindre og hva som ble bekreftet som hinder (**Hinder**) og de som ikke ble bekreftet som hinder (**Ikke hinder**). ** angir kendall tau signifikans på $p > 0.001$. X-korrelasjon med seg selv.


Variabel	Hinder	Ikke hinder
Hinder	X	-0,671**
Ikke hinder	-0,671**	X
Mulighinder	-0,402**	-0,403**
Bredde	0,228**	-0,025
Lengde	0,089	0,022
Høyde	0,540**	-0,434**
Grad av hinder	0,495**	-0,620**
Kulvert	-0,288**	0,254**
Annen infrastruktur	-0,165**	0,253**
Andre inngrep	-0,236**	0,213**
Trær	0,045	-0,210**
Kløft	0,361**	-0,184**
Blokkrikt	0,064	-0,264**

Fra **tabell 15** kan man se at bredde på elven der hinderet er modellert er positivt korrelert med riktige treffe på hinder i modellen. Altså blir modellen bedre hvis elva er større (bredere). Dette kan ha med usikkerhet i avgrensing elvepolygonene å gjøre. Når elvene blir smale og det er en større risiko for at polygonene ikke treffer riktig hydrologisk med LiDAR-modellen (dvs. at polygonen treffer elvekanten i stedet for midt i elven) blir usikkerheten større og modellene dårligere


(se **figur 14**). Det er verdt å merke seg at modellene blir klart bedre jo større høydeforskjellen i hinderet er. Ulike typer menneskelig aktivitet påvirker modellene, og det er nærmest umulig å se hvorvidt en kulvert er en barriere eller ikke fra en LiDAR modell. Trær kan påvirke modellen å klassifisere hindre der disse ikke eksisterer, og er dermed en kilde til usikkerhet i modellen. Det samme gjelder høyspentledninger ol. som kan «forstyrre» terrengmodellen (DTM).

Eksempler fra modelleringen

Vi har tatt en mer nøyaktig titt på vandringshinder i Etna og Dokka. I eksisterende kart for elvene Etna og Dokka er den storørretførende delen vist med rød farge i **figur 10**. I vår modell vist i **figur 11**, er de cyan fargede strekningene de som er de som er storørretførende ifølge modellen. Legg merke til at vår modell fanger flere småelver enn de som tidligere er markert. Ellers er de nokså like. Kartet i **figur 10** er tegnet etter manuell befaring mens kartet i **figur 11** er «vår» modell.




Figur 10. Eksisterende kart for storørretstrekninger i elvene Etna og Dokka. Figur bearbeidet fra Myrvold og Dervo (2019) av Bjørnar Dervo, 3D-smia.



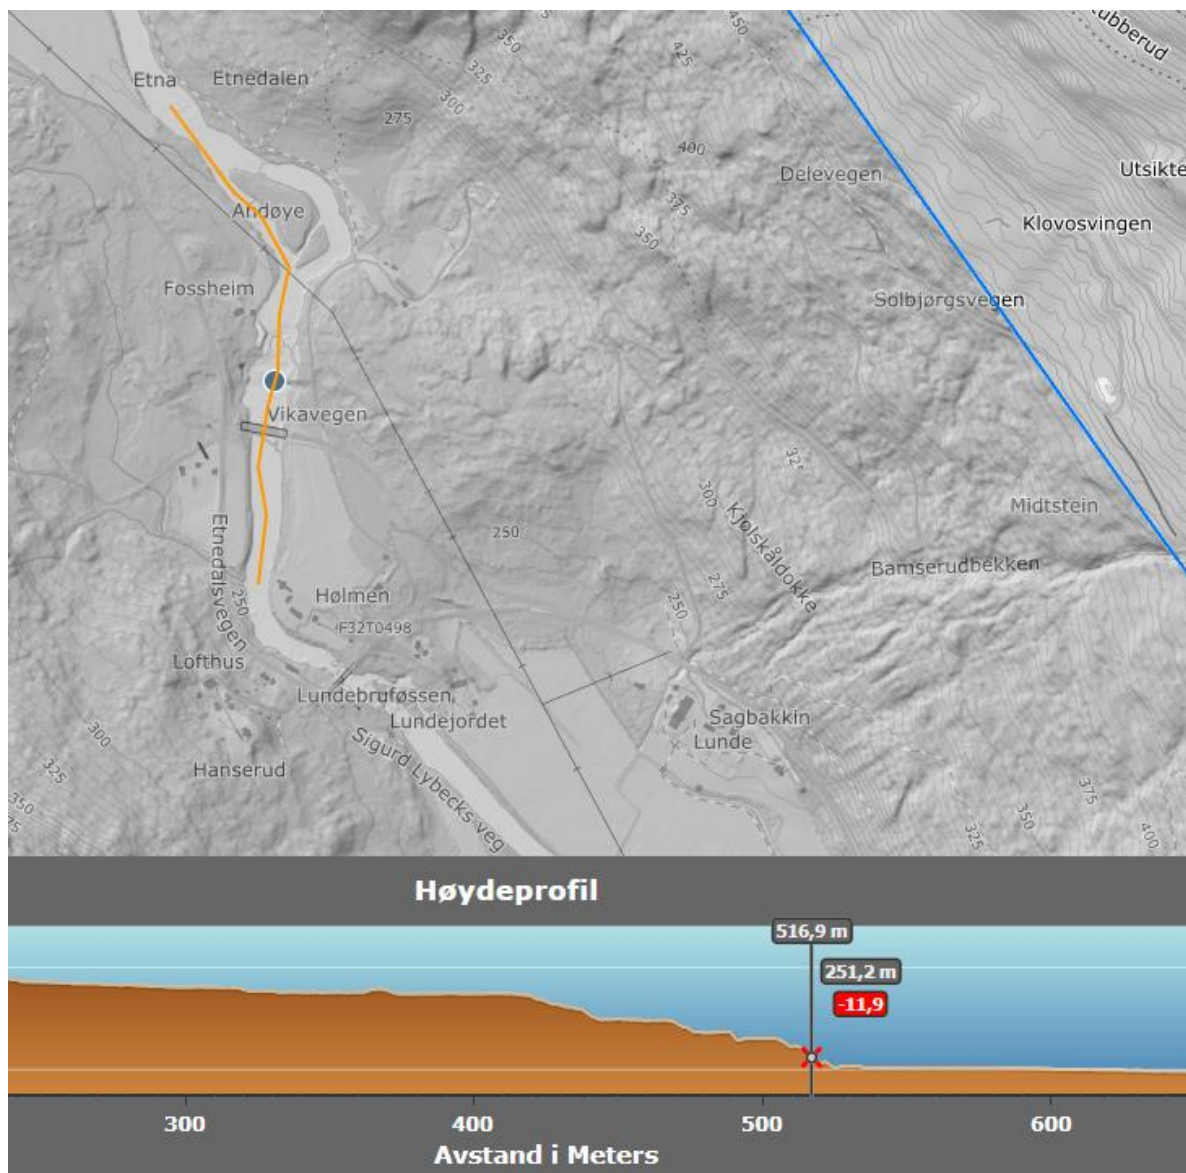
Figur 11. Vår modell for storørretførende deler av elvene Etna og Dokka. Modellen her fanger opp flere detaljer enn det som er angitt i **figur 10** (som er det nåværende kartet som gjelder for disse elvene). Dette er blant annet synlig ved at tilløpselvene også er markert på kartet.

Dersom vi ser litt nærmere på noen av vandringshindrene, så kommer usikkerheten tilknyttet menneskelig aktivitet fram. For eksempel ville lokasjon Høljerast være en naturlig hinder (**figur 12**), men her er det sprengt ut en fisketrapp i fjellet som gjør at storørreten kanskje kan gå videre oppover. Men der er likevel usikkert om dette skjer og eventuelt i hvilket omfang (Høitomt pers. med.).



Figur 12. Potensiell vandringsstopp ved Høljerast. De røde områdene er umulig å forsere ifølge modellen. Det er sprengt ut en fisketrapp i fjellet som gjør at storørreten kanskje kan gå videre oppover. Men der er usikkert om dette skjer. Fisketrappa er ikke synlig fra LiDAR eller på N5 kart.

Det er flere potensielle vandringshindre oppover Etna fra Høljerast. Det mest sannsynlige vandringsstoppen er på Lundefossen hvis fisk kommer opp ved Høljerast. Men ved Lundefossen er det også en teoretisk mulighet for at fisk kan komme forbi i sideløpet i øst ved høy vannføring. Neste stopp da er Hellefosnbrua like ovenfor Lundefossen som i dag er helt umulig å forsere (figur 13).




Figur 13. Lundefossen vil være umulig å forsere for fisk. Kartet er hentet fra hoydedata.no.

Modellen vår er også utprøvd for 825 sjørettelver og 448 lakseelver i Norge i samarbeid med Miljødirektoratet og Vitenskapelig råd for lakseforvaltning. I forbindelse med gjennomgang er det funnet ca. 20 steder med feil vandringshindrer for alle de 1 273 elvene som er modellert. Feilene ligger noen ganger i at modellen har for strenge kriterier, men også for snille kriterier andre steder. Det vil uansett være små detaljer som ikke fanges opp på 1 x 1 meter LiDAR som gjør at modellen angir feil hinder.

4.3 Forbedringer

Det er flere måter å forbedre modellen på. Hittil er kun helningsgraden og høydeforskjellen brukt til å avgrense polygonene som angir vandringshinder. En viktig faktor som hittil er utelatt er vannføring i elvene. Vannføringen er avhengig av nedbørsfelt og avrenning. Begge disse faktorene er mulig å oppdrive og kan inkluderes i framtidige modeller. En annen type effekt som vil påvirke vannføring er kraftverk og bortføring av vann fra elvene. I forbindelse med modellering av de anadrome strekningene i Norge er dette informasjon som er inkludert. Det er også mulig å tilpasse modellen til de ulike fiskeartenes svømmekapasitet.

Elver og bekker er også dynamiske systemer som gjør at de endrer elveløp over tid mange steder. Dette kan føre til at det ikke er overenstemmelse mellom den elvepolygonen som er tegnet i N5 og den hydrologien som avledes fra LiDAR modellene. Det at polygonen ligger på feil sted enn der elven går vil gjøre modellene upålitelige der dette skjer (**figur 14**).



Figur 14. Eksempel på feilkilde der kotene går i elva langs kanten (se blå pil). Dette er en kanteffekt vi ser nokså mye av i modellene. I og med at et vandringshinder skal dekke hele elva skaper dette i de fleste tilfellene kun kosmetiske problemer i kartene.

En mulighet til forbedring vil være å lage egne hydrologiske modeller fra LiDAR. Her kan elvepolygonene utledes fra den hydrologiske modellen og vil derfor være hydrologisk korrigert, noe som vil føre til mindre kanteffekter. Dette er blant annet gjort av Hegder m. fl. 2020, men i mindre områder. Vi har ikke i dag mulighet til å lage hydrologiske modeller i Google Earth Engine eller i andre stordata systemer. En fullstendig hydrologisk modell fra LiDAR, hvor alle elvepolygoner er korrigert mot terrenget, vil nok komme i fremtiden. Men foreløpig er det ikke praktisk mulig å gjennomføre en hydrologisk modellering på landbasis basert på LiDAR.

Prediksjonene av vandringshindre må sies å treffe godt. I noen landskap med smale og gjerne påvirkede bekkeløp med utretting, grøfting ol. vil modellen treffe noe dårligere. Dette medfører noen regionale forskjeller med at modellen treffer bedre på Vestlandet og nordover enn i flate jordbrukspregete vassdrag på Sør- og Østlandet.

5 Prediksjonsmodellering av fisketomme lokaliteter

I en tilnærming for prediksjon av fisketomme lokaliteter har vi fulgt en trinnvis prosedyre. Vi har tatt utgangspunkt i fiskedatabasen som er en PostgreSQL/PostGIS database som heter «nofa» og ligger hos NTNU. Fiskedatabasen er en samling av data fra ulike kilder slik som vann-info, PIKE, m.fl. Fiskedatabasen inneholder i underkant av 31 000 lokaliteter med registreringer av hvilke arter fisk som finnes for hver lokalitet eller ikke. Det er imidlertid verdt å merke seg at informasjonen i denne databasen ikke er utfyllende for mange lokaliteter, og det antas å være ubalanse i data når det gjelder registrering av spesifikke fiskearter og undersøkte lokaliteter. For eksempel, siden mye av informasjonen i fiskedatabasen er basert på informasjon fra lokale fiskere og ofte mer eller mindre artsspesifikt fiske, så vil flere fiskearter kunne være utelatt fra fiskedatabasen, selv om de kan befinne seg i de spesifikke innsjøene. Datasettet vil allikevel antas å kunne gi indikasjoner på tilstedeværelse av fisk for mange lokaliteter.

5.1 Introduksjon

Vi har tatt utgangspunkt i alle innsjøer fra N5 Kartdata. I N5 er det 2 018 423 innsjøer i Norge (se **kapittel 2**).

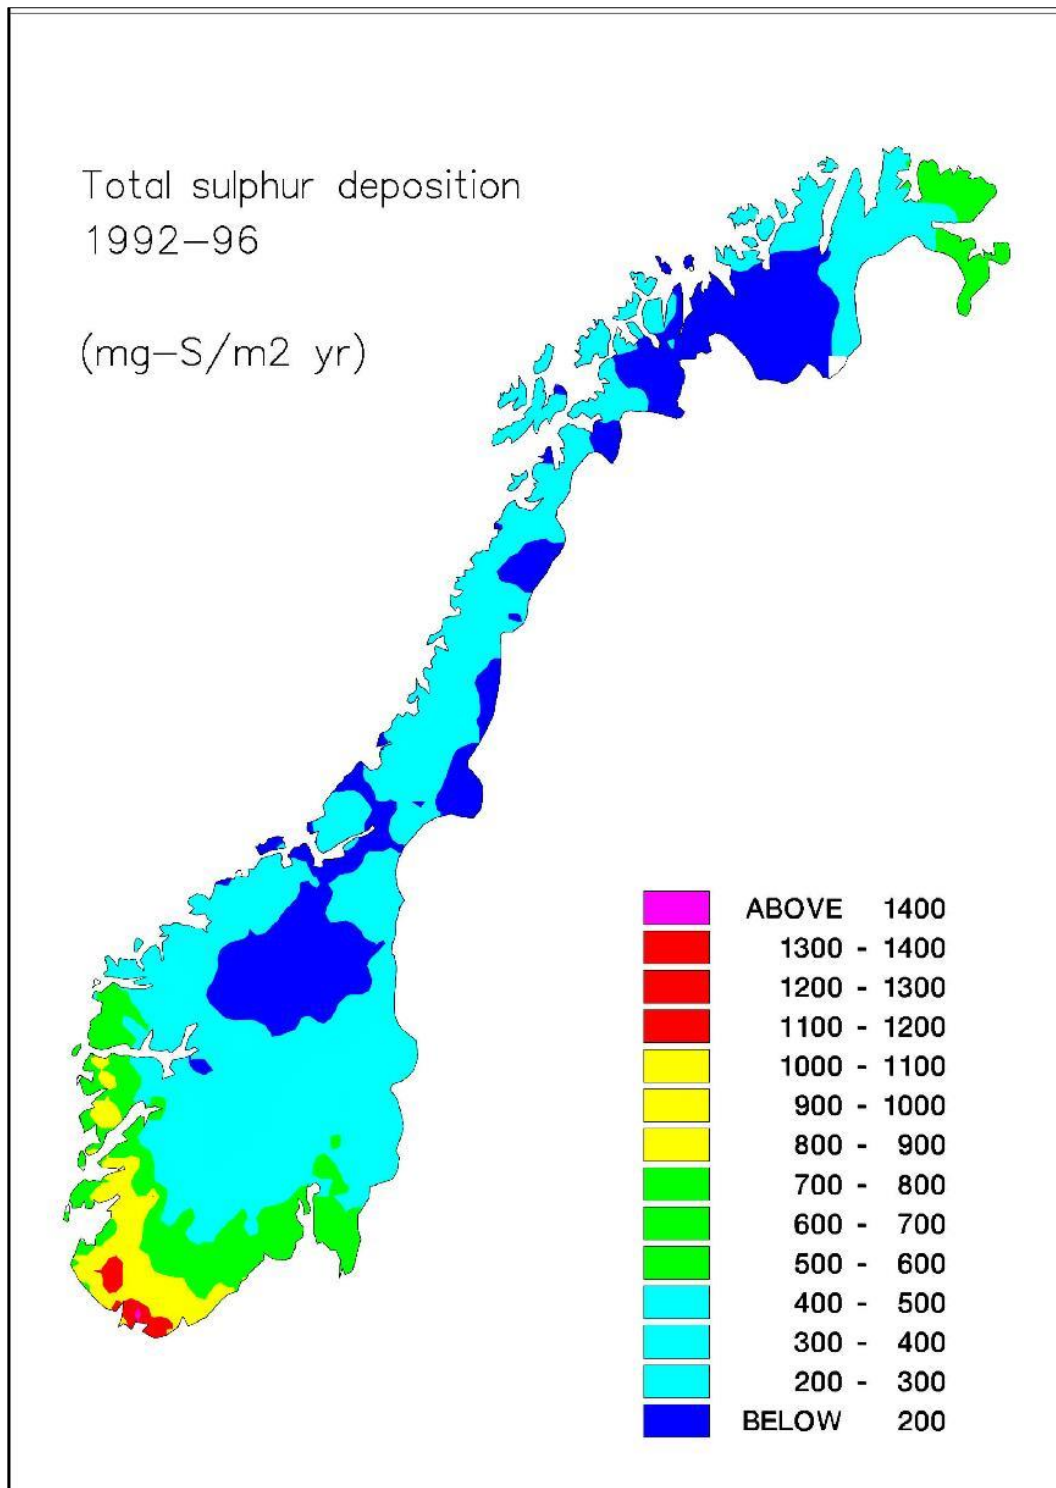
Regelbasert prediksjonsmodell (overlay analyse)

I utgangspunktet har vi tenkt at innsjøer som er mindre 1 000 m² har liten sannsynlighet for å ha fisk og innsjøer større enn 50 000 m² nesten alltid vil ha fisk. Vi antar at nærhet til «befolkning» og infrastruktur gjør at sannsynligheten for fisk i innsjøer øker. Sannsynligheten for fisk vil derimot avta i forsurrede områder, eller i områder med naturlig sure bergarter (slik som i områder med mye gneis og granitt). Det er også en bioklimatisk grense for hvor høyt over havet det finnes fisk i innsjøer. Dette gjelder også i en viss grad en gradient langs en regional gradient fra sør til nord hvor høydegrensen for fisk vil avta mot nord. Det er også sannsynlig at vandringshindre og landheving siden siste istid påvirker den naturlige utbredelsen av fisk også i dag. Til slutt antar vi at innsjøer som ligger i myrdominerte områder og som ikke har tilgang på elv har mindre sannsynlighet for fisk.

Fiskedatabasen, som er gjort tilgjengelig gjennom INVAFiSH (se Hedger m.fl. 2020), inneholder fiskedata for 30 614 innsjøer i Norge. Dette betyr at vi har informasjon om funn eller fravær av en eller flere fiskearter i disse innsjøene. Av disse 30 614 innsjøene med fiskeregistreringer er det kun to som har areal mindre enn 500 m², fire som har areal mindre enn 1 000 m² og 15 innsjøer med areal mindre enn 2 000 m². For areal på 3 000 m² eller mindre er det 63 innsjøer med fisk i fiskedatabasen.

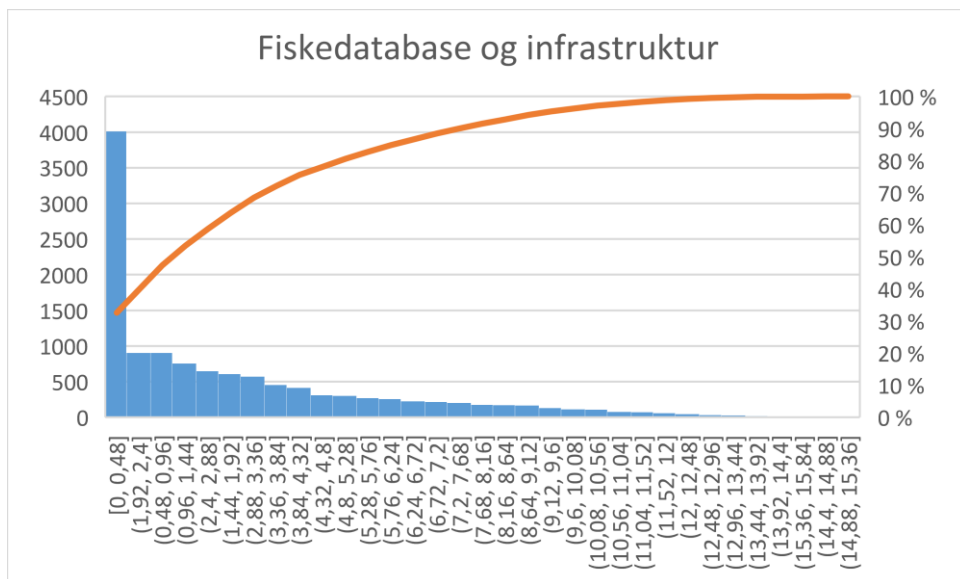
Vi har også brukt fiskebasen for å se på hvor høydegrensa for fisk går i ulike deler av landet. Den høyestliggende innsjøen i Norge, hvor det er registrert i fisk i fiskedatabasen, er på 1 835 moh. Det er 25 registreringer av fisk i innsjøer som ligger over 1 600 moh. Ettersom høydegrensa faller mot nord har vi også brukt gjennomsnittstemperatur i luft. Den innsjøen med fisk i fiskedatabasen som har kaldest gjennomsnittstemperatur i luft, har et årlig gjennomsnitt på -6.25 grader celsius. Det er 35 av de 30 614 innsjøene som har et årlig gjennomsnitt kaldere en -5.0 grader for lufttemperatur.

Vi har brukt en sammenstilling av grunnlagskartet for kalkrik berggrunn (se Dervo m.fl. 2020) og et kart over langtransportert svoveldeposisjon over Norge i perioden 1992-1996 (**figur 15**) (se Hesthagen m.fl. 1999 og Økland m.fl. 2001) som utgangspunkt for å lokalisere områder med innsjøer som antagelig er fisketomme på grunn av forsuring.



Figur 15. Svoveldeposisjon over Norge i perioden 1992-1996. Kilde: se Austnes m. fl. 2018.

I fiskedatabasen er det 3 508 innsjøer som har en majoritet av myr i en buffersone på 200 meter rundt innsjøene. Dette er litt over 10% av alle innsjøene i fiskebasen. Ved å inkludere myr utregnet på denne måten som et kriterium på fisketomme lokaliteter i den regelbaserte prediksjonsmodellen vil det føre til man «mister» en del innsjøer i områder med myr som egentlig inneholder fisk. Når det gjelder infrastrukturindeksen er fordelingen av innsjøer med fisk og graden av infrastruktur vist i **figur 16**.

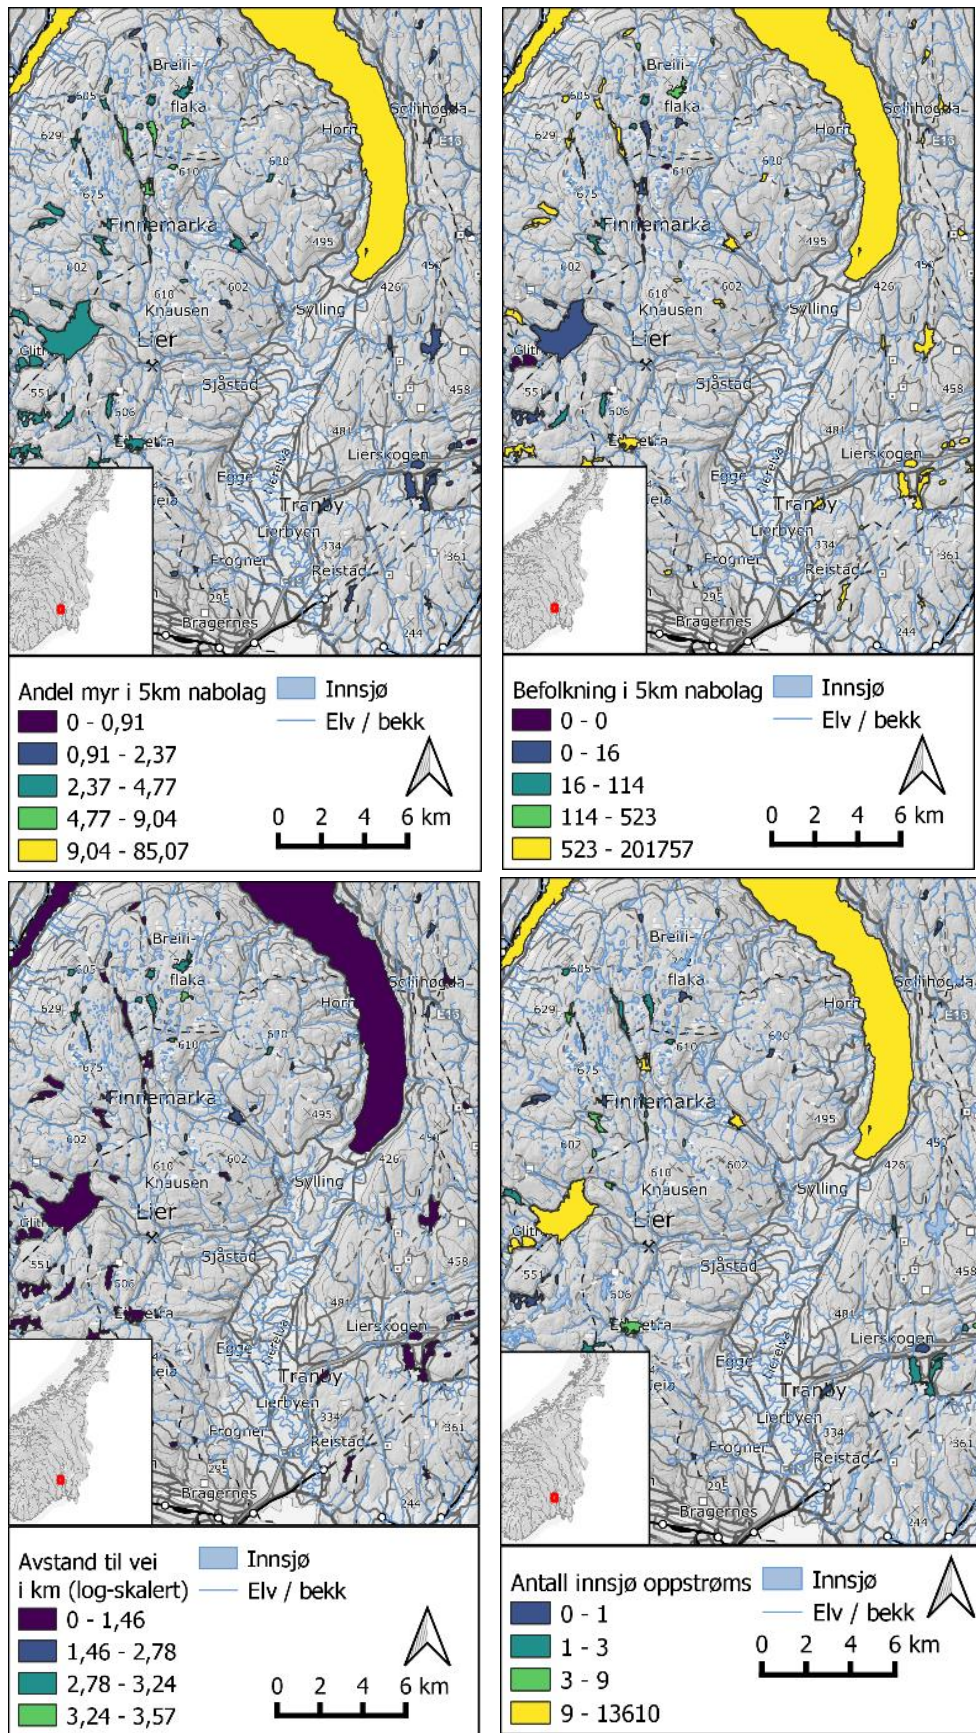


Figur 16. Fiskedatabasen og dens fordeling i forhold til infrastrukturindeksen. X-aksen er gjort om til en kategorisk variable sortert etter antall innsjøer i hver kategori.

Figur 16 viser at det er mange innsjøer som har infrastrukturindeksverdi på 0 eller verdier nær null. I så måte kan ikke denne indeksen brukes til å sette en «cut off-verdi» direkte for bruk i en regelbasert prediksjonsmodell. Det kan være aktuelt å kjøre en distansefunksjon fra infrastruktur i stedet.

5.2 Prediksjoner av fisketomme innsjøer basert på statistisk modellering

Datasettene fra NOFA databasen som ligger til grunn for sannsynlighetsvurderingene består av en sammenslåing av garnfiskedata fra lokale fiskere, standardisert prøvafiske og overvåkingsdata i Norge, med nordligste avgrensing i tidligere Nord-Trøndelag. I alt inkluderer dette 25 490 vannforekomster, hvorav 1 895 vannforekomster er antatt fisketomme. For hver av disse vannforekomstene ble det trukket ut ti forskjellige variabler, ved hjelp av GIS-analyser, som generelt beskriver menneskelige påvirkningsfaktorer og andre miljøforhold som kan tenkes å påvirke sannsynlighet for fisketomme innsjøer. Konkret så innebar dette mål på: 1) Høyde over havet, 2) antall innsjøer oppstrøms i samme vassdrag, 3) distanse til nærmeste vei, 4) areal til vannforekomstene, 5) form på innsjø, 6) befolkningstetthet innenfor en radius på 5 km, 7) antall innsjøer i nærheten uavhengig av konnektivet mellom dem, innenfor en radius på 5 km, 8) andel myr i et bufferområde på 5 km, 9) kalkrik berggrunn i området og 10) svovelkonsentrasjon i berggrunnen. **Figur 7** viser en oversikt over utvalgte miljøvariable i kart for Lier området der modellen er testet på lokal skala. Data på vannforekomster er hentet fra N50 kartdata, og befolkningstetthet fra SSB sin befolkningsstatistikk i rutenett. Konnektivet, dvs. stigning i grader mellom innsjøene i de berørte nedbørsfeltene er beregnet med et Python skript utviklet i INVA-FISH prosjektet (https://gitlab.com/invafish/lake_connectivity). Beregningene er utført basert på en digital terrengmodell med 10 m oppløsning (DTM 10). Pga. mismatch mellom terrengmodell og elvenett ble et terrengavledet elvenett lagt i bunn i analysene. GIS analyse er gjennomført med GRASS GIS 7.8 (GRASS GIS Development Team 2020) og PostGIS 3.0 (<http://postgis.net/>).



Figur 17. Oversikt over utvalgt miljøvariabler brukt i modelleringen ved vannforekomster i Lier kommune i Viken fylke.

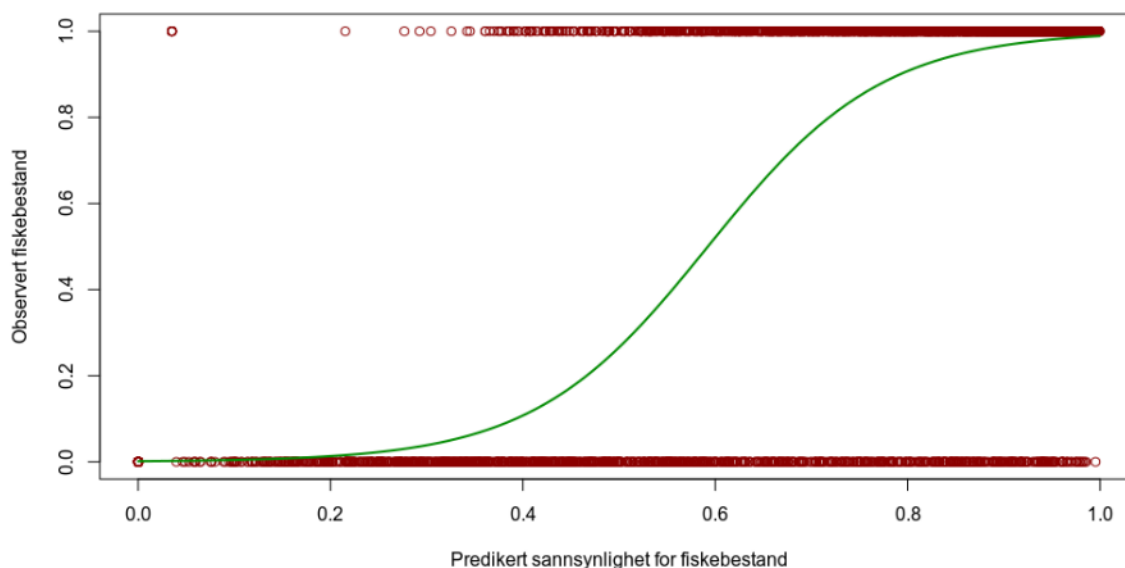
For å beregne den overordnede sannsynlighet for fisketomme innsjøer, så brukte vi en «boosted regression trees» (BRT)-modell (Elith m.fl. 2008). Dette er en type maskinlæringsmodell som forsøker å finne trender i data, og i tillegg lære av disse trendene. Vi valgte denne typen modell siden den har noen fordeler når det gjelder presisjon for prediksjoner, samt at den er ganske fleksibel hva gjelder ikke-lineære responser og uteliggere, som kan forventes i et slikt datasett. Sammenlignet med andre maskinlæringsalgoritmer, slik som «random forests» er «boosted regression trees» spesielt egnet for ubalanserte data – dvs. data med en svært skjev fordeling i antall data-rader per klasse slik vi har med fordelingen av fisketomme innsjøer. Modellen ble satt opp ved hjelp av dismo-biblioteket (Hijmans m.fl. 2017) i den statistiske programvaren R (R Core Team 2021). I prosessen for å optimalisere modellene, altså prøve å få den til å beskrive data så riktig som mulig, brukte vi en kryssvalideringsprosess, der hvor separate modeller med økende kompleksitet tilknyttet til 10 forskjellige deler av det fulle tilgjengelige datasettet. Hver del bestod av 80% av det fulle datasettet. Med bakgrunn i denne prosessen fikk vi optimalisert innstillingene for modellen. Dette er en prosess som i prinsippet øker presisjonen på prediksjonene som kommer ut av modellen, ved å tilpasse modellen til informasjonen som finnes i datasettet på best mulig måte. Vi brukte et mål på forskjellen mellom prediktert introduksjon og faktiske observerte introduksjoner (predictive deviance) i treningsdatasettet, samt «area under curve» (AUC)-statistikk (Hanley & McNeil 1982) for å finne de mest optimale modell-spesifikasjonene.

Parameterestimatene fra modellen ble brukt for å predikere sannsynlighet for en innsjø er fisketom på et småskala datasett fra Lier kommune, der vi har relativt god kontroll på forekomst av fisk, og spesielt salamander (som fungerer som en indikator på fravær av fisk). Dette ble gjort for å teste praktisk bruk og presisjon av modellen på tvers av geografisk skala.


5.3 Resultat

BRT-modellen som predikerer om en innsjø har fiskepopulasjoner eller er fiskeløs, har relativt gode prediksjonsegenskaper innenfor treningsdatasettet, ifølge AUC-statistikken (AUC=0,995) og «predictive deviance» (mean deviance = 0,17). Disse tallene kan imidlertid være misvisende for hvor gode prediktive egenskaper modellen har i praksis (se nærmere beskrivelse rundt dette lenger ned). En sammenligning av observerte fiskebestander og predikert sannsynlighet for fiskebestander i en innsjø, viser at modellen bommer i en del tilfeller, selv om hovedtyngden av prediksjoner ser ut til å gi fornuftige sannsynligheter (**figur 18**). De mest utslagsgivende variablene for modellprediksjonene er en som indikerer andel kalk i berggrunnen og en som indikerer andel svovel (**figur 19**). Dette betyr ikke at dette var de eneste variabelene som ga et reelt utslag i prediksjonene, men at disse variablene i interaksjon med andre variable hadde størst innflytelse på modell-prediksjonene. Spesielt var det kombinasjon av areal og kalkrikhet, kalkrikhet og distanse til vei, og areal og svovel som ga mest utslag i predikasjonsverdiene. Interaksjonen mellom areal og kalkrik berggrunn viste at sannsynligheten for fisketomme innsjøer generelt øker dess høyere kalkinnhold for små vann (opp til ca. 60% sannsynlighet for høyeste nivå for kalkrikhet og minst vann (0,04 km²). Effekten av kalkrik berggrunn avtar imidlertid med økende størrelse på vannet, og har minimal effekt på større innsjøer hvor sannsynligheten for fisketomme innsjøer nærmer seg null. For distanse til vei så økte sannsynligheten for fisketomme innsjøer med økende distanse ved de to høyeste klassifiseringene av kalkrikhet, men sannsynligheten for en fisketom innsjø oversteg aldri 40% basert på disse to variablene alene. For svovel så var det liten forskjell mellom målte verdier (<10%), men en «NULL»-kategori, dvs. områder hvor det ikke finnes svovelverdier i kartgrunnlaget, hadde vesentlig økt sannsynlighet (> 60%) for fisketomme innsjøer. Denne sannsynligheten ble imidlertid nedjustert noe med økende størrelse på vannet (ned til ca. 40%). Disse NULL-kategoriene for svovel, representerte naturlig nok da ikke svovelverdier, men er et uttrykk for andre ukjente variabler. I hovedsak så ligger vann med NULL-verdier for svovel langs kysten av Norge.


I vår test av BRT-modellen på et mindre datasett i Lier, så vi at modellen i stor grad skiller på predikert sannsynlighet mellom innsjøer som hvor fisk er observert og de som er antatt fiske-tomme, men predikert sannsynlighet for fiskebestander er likevel veldig høy for alle vann (**figur 20**). I hovedsak så har alle observerte fiske-tomme vann en predikert sannsynlighet under 95%, mens de fleste vann med fisk har en predikert sannsynlighet over 95% for å inneholde fisk. Med andre ord så klarer modellen å skille mellom de to gruppene med relativt høy treffsikkerhet, men skalaen for sannsynlighetsprediksjonene er helt feil i og med at fiske-tomme vann fremdeles får tildelt over 80% sannsynlighet for å inneholde fisk.



Figur 18: Sammenheng mellom observerte fiskebestander i datasettet (y akse, 0=antatt fiske-tomt og 1 = observert fiskebestand) og predikert sannsynlighet for en fiskebestand i de samme lokalitetene (x akse). Grønn linje er en logistisk regresjonslinje som illustrerer sammenhengen mellom variablene.

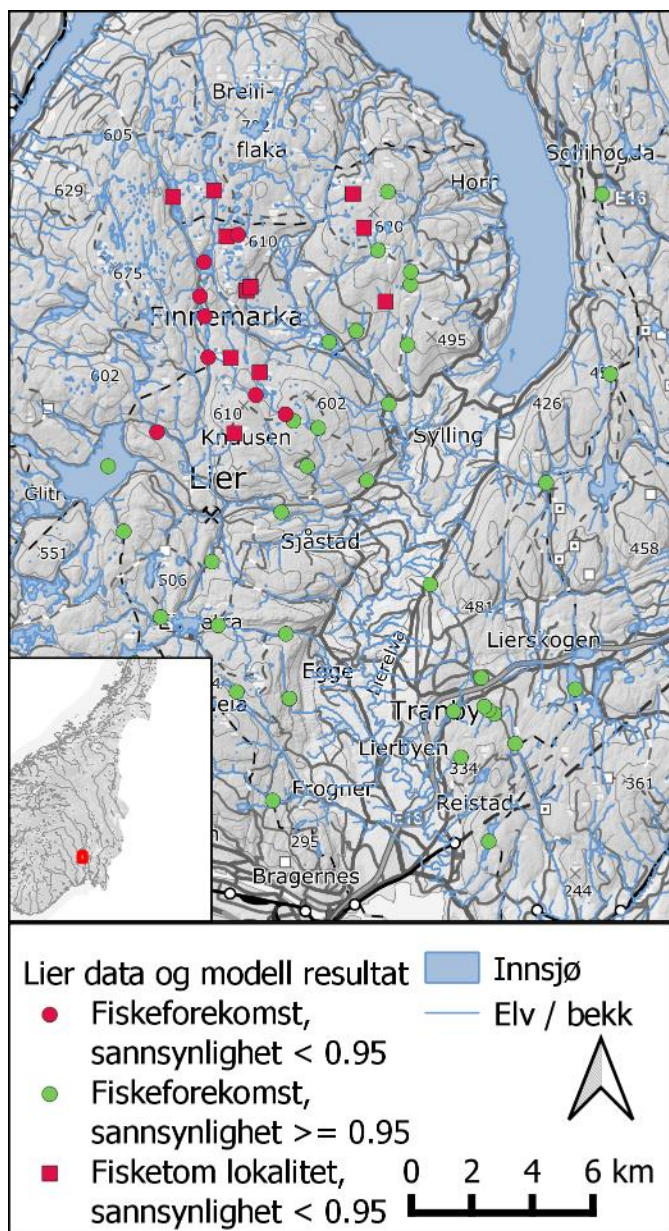


Figur 19: Søylediagram som angir parameterinnflytelse (i prosent) for de forskjellige variablene som er inkludert i BRT-modellen som predikerer sannsynlighet for fisk i en innsjø.



Figur 20. Boksplot over fordelingen av predikert sannsynlighet for at et vann i Lier har en fiskebestand (y-akse), mot observerte fiskebestander i Lier (x-akse, 0 = ingen bestand og 1 = har fiskebestand). Selv om sannsynligheten for fiskebestand i begge gruppene er veldig høy generelt, er det likevel vesentlig forskjell i predikert sannsynlighet mellom vann med fisk/uten fisk.

En visualisering av hvor godt modellen treffer i forhold til Lierdataene er vist i **figur 21**.



Figur 21. Modell resultat mot felldata for vannforekomster i Lier.

5.4 Konklusjon på modelleringen av fisketomme lokaliteter

BRT-modellen har i teorien gode forutsetninger for å kunne gi indikasjoner for fisketomme innsjøer basert på et antall forklaringsvariabler, som brukt i denne modell-øvelsen. På stor geografisk skala så har modellen relativt god treffsikkerhet på sannsynligheten for fisk i mange vann, men den bommer også i en del situasjoner. Dette medvirker til at det på et storskala datasett kan være vanskelig å sette en bastant sannsynlighets-grense der hvor de fleste vann vil ha fisk om den er over denne sannsynligheten, og de fleste vann vil være fisketomme om den er under. Dette ble tydelig når vi predikerte sannsynlighet for fisk i vann i et datasett i Lier der status for fisk var kjent. Modellen viser tydelige forskjeller i prediksjoner mellom fisketomme vann og vann med fisk (**figur 20**), men sannsynligheten er såpass høy for alle vann her at ingen av disse vannene ville blitt vurdert som sannsynlig fisketomme hvis man hadde inkludert Lierdatasettet i en større geografisk setting. Dette indikerer at modellen ikke er generisk nok til å kunne flyttes fra stor til liten skala uten å re-parametrisere og trene modellen for riktig geografisk skala. Det er

flere grunner til dette: 1) Siden graden av kalkrik berggrunn er en viktig parameter i modellen, og denne variabelen har relativt lav geografisk oppløsning i kartlagene den er basert på, vil småskala prediksjoner med liten variasjon i berggrunn også gi små forskjeller i sannsynlighet for fisk/ikke fisk; 2) Treningsdatasettet som er brukt er ikke utfyllende når det gjelder observert fisk/ikke fisk, slik at man feilaktig kan anta dette i modelleringen også. Med det begrensede antall av fisketomme lokaliteter kan falske negative (dvs. innsjøer som er klassifisert som fisketom, men som har fisk), få spesielt stor innflytelse på modellen; 3) Det finnes kjente og ukjente variable utover de vi har informasjon om, og som derfor ikke kan tas med i en beregningsmodell, som er styrende for sannsynlighet for fisketomme innsjøer. Det er derfor også tre relativt åpenbare tiltak som vi antar vil kunne forbedre presisjonen til modellen på tvers av geografisk skala.

- Kvalitetssikre og oppdatere observasjoner av fisk i innsjøer ved for eksempel representative e-DNA prøver, slik at alle fiskearter blir inkludert i fiskedatabasen. e-DNA metoden vil vel og merke fungere best for de øverste innsjøene i nedbørfeltet. Denne innsamlingen bør gjøres på en slik måte at man får et så representativt utvalg som mulig av vann i Norge, samtidig som det bør være stort nok til å trene modellen på forskjeller i geografisk skala.
- Øke oppløsning på grunnkart som viser biologiske viktige variabler.
- Inkludere informasjon om gårdsdrift og andre historiske data hvis tilgjengelig.

Antagelig vil anvendbarheten av modellen først og fremst ligge på regionalt nivå med dagens datagrunnlag, når lokaliteter skal velges ut ift. utvalgt natur. Det vil med andre ord være vanskelig å plukke ut fisketomme lokaliteter på lokalt nivå, for eksempel på kommunenivå, uten at eksisterende kunnskap om forekomst av fisk blir systematisert og inngår som en del av datagrunnlaget ved modellering.

6 Prediksjonsmodellering av meandrerende elver og kroksjøer med dyplæring

Det har hittil vært en utfordring å få avgrenset og klassifisert mønstre i GIS og fjernanalyse ved hjelp av rent matematiske metoder og algoritmer. I Erikstad m. fl. (2004) ble det utprøvd en algoritme for å definere og klassifisere meandrerende elvestrekninger ved å legge ut punkter langs en midtlinje og regne på retningsforandringer langs midtlinjen. Metoden krevde mye regnekapasitet og er skalaavhengig. Nye metoder innen maskinlæring kan imidlertid være den framtidige løsningen for å komme videre med avgrensning av meandrerende elver og kroksjøer. Vi har derfor gjort en test på om vi kan klassifisere og identifisere meandrerende elver i Norge ved hjelp av metoden dyplæring.

6.1 Metode

Bakgrunn og forsøk på enkel forklaring av dyplæring

Maskinlæring kommer til å bli stadig mer utviklet som metode innen data science og naturfaglige analyser (Webb 2018). Dette gjelder for eksempel mønstergjenkjenning, objekt-identifikasjon og objekt-klassifisering. I GIS og fjernanalyse har disse metodene eksistert i flere tiår, men prosesseringskapasitet på lokale arbeidsstasjoner (pc'er) og dertil tilgjengelig programvare og infrastruktur har vært flaskehals. Imidlertid går utviklingen nå raskt, særlig etter utviklingen av en ny prosesseringsenhet kalt TPU (Tensor Processing Units) som brukes av TensorFlow, og det brede anvendelsesområdet til teknologien.

TensorFlow er et programvarebibliotek basert på åpen kildekode for maskinlæring, som utvikles av Google. Pytorch og keras er eksempler på andre rammeverk/biblioteker. Der CPU-enheter har prøvd å knuse algoritmer for å gjenkjenne mønstre og objekter piksel mot piksel, kan TPU sammen med kraftige GPU-enheter (graphics processing units), brukes til å gjenkjenne mønstre uten at disse må gjenskapes gjennom programmering av forhåndsdefinerte algoritmer. Dyplæring er en læreprosess som går ut på å «trene opp» såkalte «dype kunstige nevralt nettverk». Dette er en sentral metode innen maskinlæring – hvor prinsippet er at datamaskiner skal tilegne seg kunnskap (lære) noe de ikke vet eller kan fra før.

Et eksempel på dyplæring kan sammenlignes med den klassiske leken stein, saks og papir. Et nevralt nettverk blir presentert i et bilde av en hånd som er formet som en saks samtidig som du sier til nettverket «dette er en saks». Hvis nettverket responderer at «dette er en stein» eller «papir», så justerer man vektene ørlite grann, slik at nettverket etterhvert sier «saks». Gjennom å vise nettverket tusenvis av bilder av hender formet som stein, saks eller papir, klarer det etterhvert å skille mellom disse, selv om hendene er store eller små, ulike farger osv. Til slutt tester man at nettverket har lært å generalisere hva en stein, saks eller papir er med et uavhengig testdatasett. Dette gjøres ved å presentere nye bilder av nye hender som nettverket ikke har sett før. Dette er som en «eksamen» for nettverket.

Vi har sett at dyplæringsnettverkene har blitt stadig bedre med tiden, og at treffsikkerheten ofte er på godt over 95% i ulike problemstillinger. Det er disse metodene som er brukt i blant annet appene INaturalist og Artsorakelet, hvor man kan ta bilder av ulike arter med for eksempel mobiltelefonen og få forslag til artsbestemmelse av disse «objektene». En annen tilnærming er brukt i søkemotoren Google i nettleseren Google Chrome. Her kan man gripe tak i et bilde med pc-musen og trekke dette inn i søkevinduet der man vanligvis skriver søkeordene. Da vil Google søke etter helt like bilder eller lignende bilder på nettet akkurat som den gjør med ord. Metoden er nylig brukt i avsløringer av falske brukerkontoer på sosiale medier hvor profilbilder er stjålet fra andre kontoer.

I dag tilbyr flere fjernanalyseprogrammer, slik som for eksempel Google Earth Engine, ArcGIS Pro og ulike biblioteker gjennom Python, maskinlæring som verktøy i mønstergjenkjenning og

mønsteranalyser. Disse læringsmodellene kan brukes for både objekt-identifikasjon og objekt-klassifisering og mer tradisjonell bildeklassifisering (styrt klassifisering). Objekt-identifikasjon er prosessen med å finne bestemte objekter i et bilde, fra satellitt, flyfoto, drone eller LiDAR. For eksempel kan nevrale nettverk finne lokaliseringen av et ny hogstfelt, en kroksjø, en åkerholme eller et treslag hvis den er opplært til dette (Puttermans m.fl. 2018).

I prinsippet kan bruk av objekt-identifikasjon være i stand til å oppdage sjeldne naturtyper over et stort areal ved bruk av satellittbilder. Objekt-identifikasjon tegner vanligvis en avgrensingsboks rundt objektene den har funnet, mens objekt-klassifisering «fargelegger» hele arealet av objektet og kan eksportere dette som en polygon. Denne polygonen vil kunne være nedbørsmyr eller et elvedelta alt etter hva det nevrale nettverket er trent opp til å gjøre. Nevrale nettverk kan også brukes som metode i tradisjonelt styrt klassifisering av satellittbilder (eller andre bilder). Her trenes modellene til å gjenkjenne forhåndsbestemte arealtyper. Forskjellen er at dyplæring bruker et pikselnabolag som BFF, mens tradisjonelt styrt klassifisering er piksel mot piksel-basert (se neste avsnitt).

Piksel versus pikselnabolag

Tenk deg at du får i oppdrag å skille en hund fra katt i et bilde med en tradisjonell piksel mot piksel-klassifisering. Det har lenge vært tenkt som et umulig oppdrag for en datamaskin å skille hund og katt bare ved å regne på pikselverdier. Et sett med prøvepunkter (treningsdata) på en hvit hundepels vil høyst sannsynlig gi pikselverdier som ikke kan skilles fra en hvit kattepels. Så spørsmålet er hvordan Artsoraklet og andre apper klarer å skille hund og katt? Svaret ligger i at treningsdataene består av pikselnabolag og ikke enkeltpikslar.

Ved å bruke pikselnabolag som treningsdata tilfører man en hel ekstra dimensjon i klassifiseringer. Man er ikke lenger så avhengig av at selve verdiene i enkeltpikselet gir unike signaler lenger. Det er sammensetningen av pikselverdier i et større nabolag som teller. Nabolagene kan ha forskjellig størrelse og kan være så store som 512 x 512 pikslar (se **kap. 5.3** under). Ved bruk av disse nabolagene blir det mulig å finne strukturer eller mønstre som lar datamaskinen skille hund og katt gjennom dyplæringsprosessen. De samme prinsippene fra hund og katt er overførbare til fjernmåling. Myr eller fjell er kanskje vanskelig å klassifisere basert på tradisjonell piksel mot piksel klassifisering, men antagelig mye enklere i klassifiseringer basert på pikselnabolag. Det betyr jo i praksis at homogenitetskravet i BFF vil kunne endres med tanke på dyplæring.


Innsamling av data for dyplæring

Dyplæring krever som nevnt i avsnittet over, en noe annen innsamling for trening og validering av modellene. Mens tradisjonell klassifisering av bilder er gjort på piksel-nivå, bruker dyplæring en gruppe av pikslar i et nabolag for det samme formålet. Dette betyr at det ikke er kun verdiene i den undersøkte pikselen som ligger til grunn for analysen eller klassifiseringen, men også pikselverdiene i nabolaget rundt og mønstrene de danner internt seg imellom (se **kap 5.2**). Dette betyr også at det trengs en ny type trenings- og evalueringsdata der bilder eller bilde chips må «annoteres» eller merkes med riktig klasse, for eksempel (1) meandrerende elv og (2) ikke-meandrerende elv. Bilde chips kan brukes i alle typer modeller slik som klassifisering med kategoriske klasser og i modeller kontinuerlige variabler.

«Bakkesannheter» for trening av dyplæringsmodeller bør dermed bestå av nabolag-pikslar som er merket («tagget») med riktig klasse eller arealtype. Valideringsbakkesannheter kan derimot fortsatt være pikselbasert som tidligere. Nabolaget med pikslar for trening av dyplæringsmodeller kan ha forskjellig størrelse og utforming. Vanligvis er et nabolag på 128 x 128 pikslar eller 256 x 256 pikslar. Nabolag kan også være mindre. Det finnes også større nabolag, men disse blir progressivt tyngre og tyngre å prosessere. Nabolagene med piksel kalles i dyplæringssammenheng ofte «bildechips». Selv om nabolag kan være store så vil for eksempel en klassifisering av en klasse være nøyaktig. Det vil for eksempel si for klassen myr at avgrensningen av disse vil gå i overgangen mellom myr og andre klasser. Dette er direkte sammenlignbart med

objektklassifisering i vanlige bilder/fotografier. Nøyaktighet eller presisjon gis ved validering av uavhengige BFF slik som i andre metoder. Erfaring hittil er at dyplæringsmodeller gir bedre resultat enn tradisjonelle metoder, men det må understrekes at metoden fortsatt er ny i fjernmålingsammenhenger.

Det er allerede laget en del bildechips som er tagget med ulike arealklasser med tanke på klassifisering av Sentinel satellittbilder. Et slikt datasett kalt «eurosat» finnes på TensorFlow sine nettsider <https://www.tensorflow.org/datasets/catalog/eurosat>. Søker man ellers på nettsiden, finner man også de klassiske hund mot katt treningsdataene, møbler, sko, forskjellige dyre- og plantegrupper osv., som brukes til trening og validering av dyplæringsmodeller i ulike sammenhenger. **Figur 22** viser bilde-chips for myr som er samlet inn i forbindelse med et annet prosjekt (Venter & Sydenham 2021).



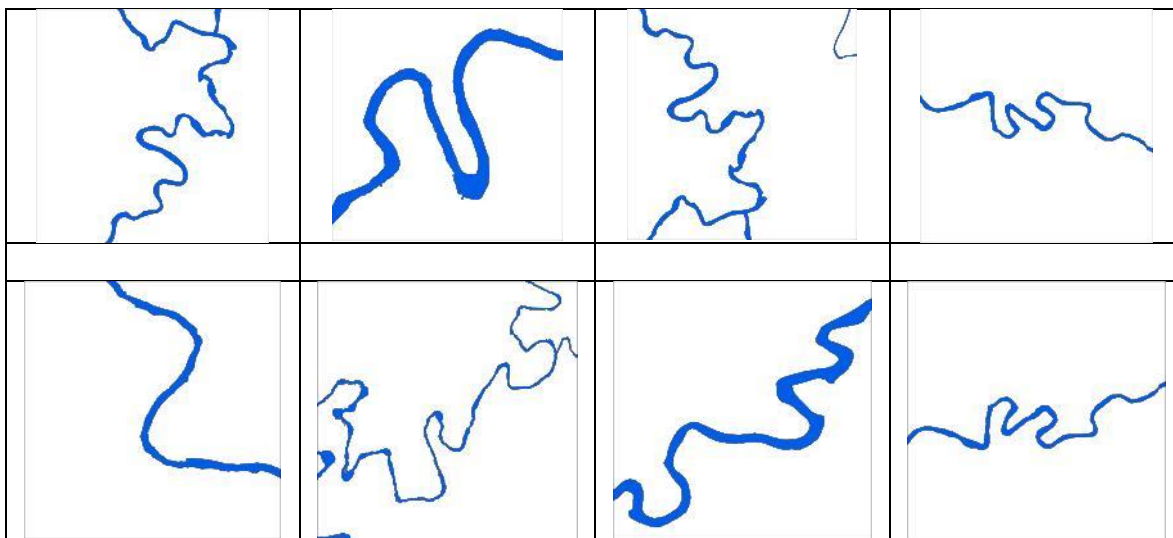
Figur 22. Eksempel på chips for trening av dyplæringsmodeller for objektidentifikasjon, objektklassifisering og bildeklassifisering. Her vises 8 bildechips samlet fra orthofoto for myr og myrer med bekker i Norge. En samling av bildechips kan og bør består av flere tusen bilder.

Det har så vidt begynt å komme noen eksempler norske nevrale nettverk fra fjernmålingsdata med norske bildechips, se blant annet Seim Brekke (2020) for klassifisering av arealtyper i satellittbilder ved bruk av konvensjonelle nevrale nettverk. Det er viktig at trente modeller gjøres tilgjengelig, slik at de kan gjenbrukes og videreutvikles. Objektklassifisering er ny teknikk som krever både kompetanse innen dyplæring og en helt egen type datamaskiner med GPU og TPU prosesseringskapasitet enn det som vanligvis brukes for vanlig desktop GIS og fjernanalyse.

6.2 Dyplæringskartmodeller

Vi har fått trent en dyplæringsmodell i Colab med TensorFlow (Abadi et al. 2015). Modellen er trent med 100 bildechips av meandrerende elver (se **figur 23**) og 100 bildechips med elver i flatt åpent landskap uten meandere. Modellen har klart å lære seg å skille disse to typene med 97.4 % sannsynlighet. Ved å «mate» modellen med nye chips den ikke har sett fra før er forklaringsprosenten på 94.3 %.

Det neste steget er nå å bruke modellen på et storformat bildemateriale, som for eksempel flyfotomosaikker eller satellittbilder, å finne lokasjoner som tilsvarer de bildechipsen modellen er trent opp til å kjenne igjen.




Figur 23. Eksempel på bildechips for trening av dyplæringsmodeller for objektidentifikasjon, objektklassifisering og bildeklassifisering. Her vises 8 bildechips av meandrerende elver samlet fra N5 – kartdatabasen. Innsamlingen av bildechips som er gjort i forbindelse med dette prosjektet består av 300 bilder i størrelse 512x512 piksler.

Vi utviklet en mønsterbasert dyplæring meandermodell med TensorFlow og Google Collaboratory (Colab) basert på bilde-chipsene (se et utvalg i **figur 23**) i Google Earth Engine. Vi benyttet en U-Net-modell med bruk av Keras-implementering. 18 000 bilde chips ble brukt til trening og 8 000 for validering. Ca. 200 våtmarkspolygoner ble brukt som grunnlag til å kategorisere bilde chipsene (se **figur 22**). For modellinnstillinger brukte vi «Adam» som optimizer, «binær cross-entropi» som loss og «binær accuracy» for nøyaktighetsvurdering. Vi trente modellen i 35 epoker for å nå stabil ytelse.

Vi har brukt sinusitet som viktig parameter for å skille meandrerende fra ikke-meandrene elvestreknig. Sinusitet er forholdet mellom elvens lengde (lengde tilbakelagt hvis du fløt nedover elven) delt på rett lengdelinje (euklidsk eller fuglens flyavstand, dvs. fra punkt A til B). Vi har brukt sinusitet-verdi på 1.7 som kriterium på meandring, dvs. at elvens lengde må være mer enn 1.7 ganger lengre enn den euklidske distansen mellom 2 punkter langs elven. For små elver har vi brukt 300 meter mellom punktene det måles sinusitet mellom. For de største elvene har vi brukt 600 meter. I tillegg skal ikke elvens fall eller helning være mer enn 2 grader over samme distanse. Vår meandermodell har 97,2% treningsnøyaktighet og 96,8% uavhengig kryssvalideringsnøyaktighet. Selv om det er noen foreløpige feil i den, mener vi at denne modellen har potensial for fremtidig klassifisering av meandere i Norge (**figur 24**).

Vi har også gjort en test på kroksjøer. Metodikken er stort sett den samme som for meandrerende elver, men her måles sinusitet på midtlinjen i potensielle innsjøpolygoner. Potensielle polygoner er hentet fra N5 og det er satt et avstandskriterium på 200 meter fra elv. Et foreløpig resultat kan ses i denne innsynsløsningen: <https://nina.maps.arcgis.com/apps/instant/basic/index.html?appid=5e0f1e1784db4d0eaf4ce2f6d9844fe1>



0 1 2 4 Kilometers

Figur 24. Et utsnitt av vår meandermodell. Utsnittet er fra Rendalen kommune i Innlandet med Fonnåsfjellet i midten og Tysla og Unsetåa på hhv. venstre og høyre side. De blå partiene representerer elvestrekninger som meandrerer og de røde strekningene er uten meandrering. Modellen er veldig skalaavhengig og bør antageligvis kjøres på ulike skalanivåer.

Det er ikke gjort en regional modellering av meandre over hele fastlandet i Norge da dette foreløpig krever tilgang på stor prosesseringskapasitet. Dette vil imidlertid være tilgjengelig innen kort tid. Modellen har potensiale til å være nyttig i utvelgelse av utvalgt natur. Forbedring av modellen krever bedre avgrensning av meandere og bedre kvalitet på trenings- og valideringsdata (bakkessannheter og bilde-chips materiale).

7 Prediksjon av humusrike innsjøer

Som et innspill til 'Forslag til naturtyper prioritert for kartlegging i ferskvann' (Velle m.fl. 2021) har vi gjort en prediksjon av kalkfattige og humøse innsjøer. Vi har brukt data fra Vann-nett som trening og validering av prediksjonsmodellen.

Som prediktorer har vi brukt høyde over havet (1), myrarealer (totalareal fra myrpolygoner) som enten deler felles linje med innsjøene eller har areal (i myrpolygonene) innenfor en buffersone på 100 meter rundt innsjøene (2), kalkinnhold (3) (se **kap. 3**) og infrastrukturindeksen inkludert med jordbruksarealer (4) (se **kap. 3**). Infrastrukturindeksen med jordbruksarealer er her brukt som aktuell prediktor under antagelsen at humus-rike innsjøer er lite utbredt nært jordbruk og andre steder med høyt menneskelig inngrep.

I tillegg har vi en modell hvor vi har inkludert spektrale bånd og indekser fra satellitten Sentinel 2 som har en pikselopløsning på 10 meter. Vi har brukt medianverdien av sommermånedene juni, juli og august 2020 for båndene «blue», «green», «red», «near infrared», «infrared1», «infrared2», «infrared3», «swir1», «swir2» og indeksene «ndvi» (normalized difference vegetation index), «ndwi» (Normalized difference water index) og «ndsi» (normalized difference snow index) (se Venter & Sydenham 2021 for mer informasjon).

Som klassifikator brukte vi random forest (RF) i Google Earth engine. Vi brukte midtpunktet av 1 401 innsjøer fra Vann-nett med kriterier på en humusrik innsjø: brukt farge > 30 mg Pt/l eller TOC > 5 mg C/l og kalsium-innhold < 4 mg Ca/l som ground truth (bakkesannheter). I tillegg digitaliserte vi midtpunkter på 200 humusfattige innsjøer fra høyoppløselige flyfoto. Vi delte dette datasettet i to deler, 75% for trening og 25% for validering.

De to modellene oppnådde en AUC-verdi på 0,884 (uten satellitt) og 0,912 (med satellitt) (**tabell 16**). Dette må sies å være nokså gode AUC-verdier (se diskusjon om AUC-verdier i **kap. 5.3**). Modellen angir en sannsynlighet fra 0 til 100 prosent hvorvidt en innsjø er humusrik eller ikke. Vi har brukt et kriterium på 80 % sannsynlighet i modellen for humusrikhet som grunnlag for å regne antall sjøer. Dette er et pragmatisk kriterium som er gjort ved en inspeksjon av modellen på kjente lokaliteter.

Tabell 16 Antall innsjøer (av et utvalg på ca 25 % av det totale antallet) som er predikert humusrike og humusfattige fordelt størrelseskategorier (areal i km²). Analysen er gjort på ¼ av alle 1:5000 innsjøer. Prediktorer er kalkrikhet, myrarealer tilknyttet innsjøene, høyde over havet og infrastrukturindeks. I tillegg har spektrale bånd satellitten Sentinel 2 blitt brukt som prediktorer for farge på overflatevannet til innsjøene (resultater i de to høyre kolonnene). PredHumus = antall innsjøer predikert som humusrike, Predhumusfattig = antall innsjøer predikert som humusfattige, PredSatHumus = antall innsjøer predikert som humusrike, modellen inneholder prediktorer fra satellitt. PredSathumusfattig = antall innsjøer predikert som humusfattige, modellen inneholder prediktorer fra satellitt. Vi har brukt et kriterium på 80 % sannsynlighet i modellen for humusrikhet som grunnlag for å regne antall sjøer.

Innsjøareal (km ²)	PredHumus	Predhumusfattig	PredSatHumus	PredSathumusfattig
<0,0010	373 437	178 199	343 985	207 655
0,0010-0,0025	7 585	3 720	6 708	4 597
0,0025 - 0,0100	6 265	2 600	5 565	3 300
0,0100-0,0500	2 648	1 173	2 293	1 528
0,0500 - 1,0000	393	192	343	242
1,0000-5,0000	290	132	231	191
> 5,0000	42	16	13	23
Sum	390 660	186 032	359 138	217 536

Resultatene vår viser en nokså stor andel av innsjøer i Norge som humusrike. Vi brukte farge > 30 mg Pt/l eller TOC > 5 mg, noe som kan anses som lite konservativt. Vi har laget en visualisering av modellene våre i Google Earth Engine.

Modell 1 med fire prediktorer (høyde over havet, tilknyttet myrareal, kalkrikhet og infrastruktur): (denne omfatter mye regning og kan ta opptil 2-3 minutter å laste):

<https://vegar.users.earthengine.app/view/humus>

Modell 2 med de fire prediktorene i modell 1 pluss 12 prediktorer fra satellitten Sentinel 2 kan ses her (denne omfatter mye regning og kan ta opptil 5 minutter å laste):

<https://vegar.users.earthengine.app/view/humussentinel2>

Blå farge viser predikerte humusfattige innsjøer mens rød farge predikerer humusrike innsjøer. Farger mellom blå og rød (lilla) viser prediksjon av innsjøer midt mellom humusfattig og humusrik. Man kan navigere å se alle innsjøer i hele Norge.

Våre prediksjoner viser at det er mellom 1,4 – 1,6 mill. humusrike innsjøer i Norge litt avhengig av hvilken prediksjonsmodell man velger. Imidlertid er våre treningsdata basert på kriterier som også inkluderer mange innsjøer som bare har svakt humuspreg og hvor fargen på disse nesten ikke antyder humus. For å kunne lage en bedre modell for sterkt humuspregede innsjøer trengs et treningsdatasett hvor for eksempel farge > 60 mg Pt/l kunne ha vært et kriterium.

Våre prediksjoner treffer noe dårligere i nord, noe som kan ha med at prediktoren høyde over havet ikke er like relevant her. Verdier fra trinnløse bioklimatiske soner (se Bakkestuen m.fl. 2008) eller varmesum over året, kunne antageligvis øke prediksjonsevnen i nord. Prediksjonsmodellen vil være til hjelp for å skille humøse og ikke-humøse innsjøer i forhold til utvalgt natur.

8 Oppsummering

Vi har gjort en oppsummering av egnetheten og potensiale i de ulike prediksjonsmodellene som er gjort i denne rapporten i **tabell 17**. De fleste modellene predikerer meget eller svært godt og de antyder at det generelt finnes flere lokaliteter enn det som er kjent, registrert eller beskrevet.

Tabell 17. Oppsummering og konklusjoner for hver av kapitlene

Prediksjoner	Infrastruktur /påvirkning	Vandringshindre	Fisketomme lokaliteter	Meandering	Humusrikhet
Hvor mange lokaliteter av totalt antall kjente lokaliteter	Like mange som kjente	Mange flere enn kjente	Usikker modell, antagelig flere enn kjente	Mange flere enn kjente	Mange flere enn kjente
Hvor godt treffer prediksjonen?	Svært godt - er egentlig ingen prediksjonsmodell, men en indeks	Svært godt	Varierende	Godt	Meget godt
Er det noen regionale forskjeller?	Ja, treffprosent avtar generelt mot nord	Noe, avhengig av terrengvariasjon	Ja, blant annet forsuring	Ikke undersøkt	Noe, avhengig av myr og skogdekning
Nyttighet ift. utvalgt natur?	Stor	Kan inngå som forklaringsvariabel	Kan gi en god regional indikasjon	Ja, som et kriterium	Ja, som et kriterium
Hvilke muligheter er det til å forbedre modellen?	Ja, bedre inkludering av jordbruksintensitet og vannstandsreguleringer	Noe, inkludering av flere terrengvariable?	Ja, inkludering av historiske data og høyere oppløsning på regionale variable slik som kalkrikhet, forsuring osv.	Ja, bedre tilgang på "bakkesannheter"	Ja, bedre tilgang på "bakkesannheter"

I **tabell 18** vises foreslåtte naturtyper som tilfredsstillende kravene til naturtyper prioritert for kartlegging i ferskvann. Av de foreslåtte naturtypene anslår vi elveslette (1), delta (2), meanderende elver og bekker (3), kroksjø (4), evje (5), grytehullsjø (6), humøse sjøer (8 og 9), kalksjøer (11 og 12), kalkrik helofytsump (13), delvis fisketomme lokaliteter (14), gårdsdam (15), brakkvannsjø- og dam (16), uregulert elv (17) og kalkrik bekk og liten elv (18) egner seg godt til prediksjonsmodellering. Vi begrunner dette med at vi har gode basisdata (prediktorer) i terrengmodeller og LiDAR, i eksisterende kartverk slik som N5 og økologiske grunnkart slik som kalkrikhet og infrastrukturindeksen, som gjør disse naturtypene egnede som modelleringsobjekter. I tillegg har vi en god del informasjon om utbredelsen av disse naturtypene gjennom naturbase og egne databaser fra for eksempel overvåkningsprosjekter.

Tabell 18. Foreslåtte naturtyper som tilfredsstillter kravene til naturtyper prioritert for kartlegging i ferskvann. 1 = Truet naturtype, 2 = Nær truet naturtype, 3 = Spesielt dårlig kartlagte naturtyper, 4.1 = Leveområder for truede og nær truede arter, 4.2 Naturtyper med høyt arts mangfold, 4.3 Naturtyper inneholder sentrale områder knyttet til reproduksjon for vandrende arter, 5 = Naturtyper med internasjonale forpliktelser. 1 og 2 følger Artsdatabanken (2018), der VU tilsier sårbar, EN tilsier sterkt truet og CR tilsier kritisk truet. For 4.1 er * = rødlistearter forekommer, ** = flere rødlistearter (hotspot), *** = svært mange rødlistearter (hotspot). Kilde Velle m.fl. 2021.

NR	NATURTYPE	KRITERIER						
		1	2	3	4.1	4.2	4.3	5 ¹
1	ELVESLETTE ²		*				*	*
2	DELTA ²	*(VU)					*	*
3	MEANDRERENDE ELV OG BEKK ^{2,3}	*(VU)					*	*
4	KROKSJØ		*				*	*
5	EVJE						*	*
6	GRYTEHULLSJØ (DØDISGRØP) ²		*	*				
7	VANNMASSER I STOR OG DYP INNSJØ			*	*	*		
8	HUMØS STOR OG DYP INNSJØ ⁴	*(EN)						
9	HUMØS GRUNN INNSJØ	*(VU)						
10	TURBID INNSJØ ⁵		*					
11	KALKSJØ ⁶	*(VU)			***	*		
12	MODERAT KALKRIK INNSJØ				**	*		
13	KALKRIK HELOFYTTSUMP	*(VU)			*			
14	NATURLIG FISKETOM INNSJØ OG DAM			*	*			*
15	GÅRSDAM				*	*	*	
16	BRAKKVANNSJØ- OG DAM			*	**			
17	UREGULERT ELV ⁷		*					*
18	KALKRIK BEKK OG LITEN ELV			*	**	*	*	*
19	UNDERJORDISK ELVELØP ^{2,8}		*					
20	VARM KILDE	*(CR)		*	*			

¹ Utgår fra oppdraget, se kapitlet om fremgangsmåte; ² Landform tilknyttet ferskvann; ³ I rødlisten angitt som Meander; ⁴ I rødlisten angitt som Humøs dyp innsjø; ⁵ I rødlisten navngitt som Turbide innsjøvannmasser i små og/eller grunne innsjøer; ⁶ I rødlisten navngitt som Sterkt kalkrike pytter, dammer og små innsjøer; ⁷ I rødlisten angitt som Elvevannmasser; ⁸ I Rødlisten angitt som Kalkgrotter.

9 Referanser

- Abadi, M., Agarwal, A., Barham, P., et al. 2015. TensorFlow: Large-scale machine learning on heterogeneous systems. Software available from tensorflow.org.
- Artsdatabanken 2021. Norsk rødliste for arter 2021. Hentet 20.12.2021 fra <https://www.artsdatabanken.no/rodlisterforarter/2021>.
- Artsdatabanken (2018). Norsk rødliste for naturtyper 2018. Hentet 20.10.21 fra <https://www.artsdatabanken.no/rodlisterfornaturtyper>.
- Austnes, K; Lund, E; Sample, JE; Aarrestad, PA; Bakkestuen, V Aas, W. 2018. Overskridelser av tålegrenser for forsuring og nitrogen for Norge. Oppdatering med perioden 2012–2016. NIVA-rapport, 7239. ISBN 978-82-577-6974-1
- Dervo, B., Mjelde, M., Schartau, A. K. og Uglem, I. (alfabetisk). 2018. Humøse kalkfattige innsjøvannmasser i dype innsjøer med sjikting, Ferskvann. Norsk rødliste for naturtyper 2018. Artsdatabanken, Trondheim. Hentet (dato) fra: <https://artsdatabanken.no/RLN2018/38>.
- Dervo, B.K., Bakkestuen, V., Mjelde, M., Walseng, B., Jensen, T. og Gregersen, F. 2020. Prediksjonsmodellering av forekomst av kalkdammer i Norge. NINA Rapport 1814. Norsk institutt for naturforskning.
- Elith, J., Leathwick, J.R. and Hastie, T. 2008. A working guide to boosted regression trees. *Journal of Animal Ecology*, 77: 802-813. <https://doi.org/10.1111/j.1365-2656.2008.01390.x>
- Elven H. og Søli G. (red.) 2021. Kunnskapsstatus for artsmangfoldet i Norge 2020. Utredning for Artsdatabanken 1/2021. Artsdatabanken, Norge.
- Elven H. og Søli G. (red.) 2016. Kunnskapsstatus for artsmangfoldet i Norge 2015. Utredning for Artsdatabanken 1/2016. Artsdatabanken, Norge.
- Erikstad, L., Sloreid, S.-E. & Bakkestuen, V. 2004. Bruk av eksisterende kartdata (N50 og N250) for å karakterisere nedbørfelt og elvestrekninger. - NINA Oppdragsmelding 818. 27 s.
- Erikstad, L., Blumentrath, S., Bakkestuen, V., Halvorsen, R. 2013. Landskapstypekartlegging som verktøy til overvåking av arealbruksendringer. NINA Rapport 1006: 41 s.
- Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. 2017. Google Earth Engine: Planetary-scale geospatial analysis for everyone.
- Hanley, J.A. & Mcneil, Barbara. (1982). The Meaning and Use of the Area Under a Receiver Operating Characteristic (ROC) Curve. *Radiology*. 143. 29-36. 10.1148/radiology.143.1.7063747.
- Hedger, R.D., Blumentrath, S., Bergan, M.A. & Eloranta, A.P. 2020. Mapping natural and artificial migration hindrances for fish using LiDAR remote sensing. NINA Report 1833. Norwegian Institute for Nature Research
- Hesthagen, T., Sevaldrud, I.H., Berger, H.M., 1999. Assessment of damage to fish populations in Norwegian lakes due to acidification. *Ambio* 28, 112-117.
- Hijmans, R.L., Phillips, S., Leathwick, J. & Elith, J. 2017. dismo – Species Distribution Modeling. [WWW document]. URL <https://cran.r-project.org/web/packages/dismo/index.html>
- Jakobsson, S., Bakkestuen, V., Barton, D.N., Lindhjem, H. & Magnussen K. 2020. Utredning av tilgjengelige og relevante datagrunnlag for kategorisering av naturareal. – NINA Rapport 1767.
- Myrvold, K.M. & Dervo, B.K. 2019. NiN-kartlegging av funksjonsområder for storørret med fokus på gytesubstrat. NINA Rapport 1682. Norsk institutt for naturforskning.
- Puttemans, S., Van Beeck, K. & Goedemé, T. 2018. Comparing Boosted Cascades to Deep Learning Architectures for Fast and Robust Coconut Tree detection in Aerial Images. Doi: 10.5220/0006571902300241.

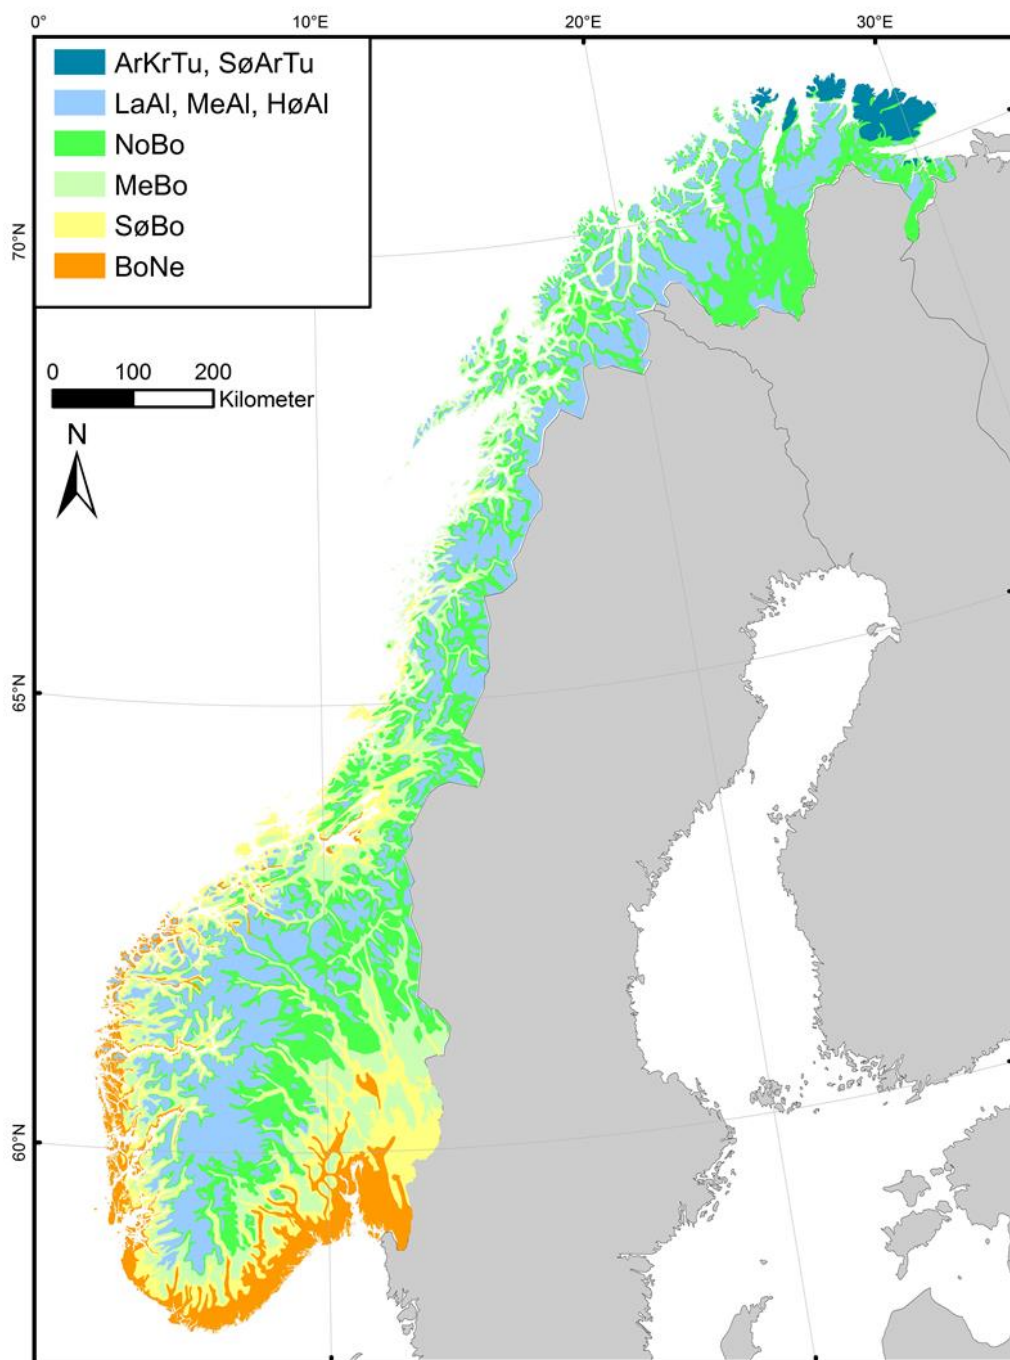
- Seim Brekke, R. 2020. Klassifisering av arealtyper i satellittbilder ved bruk av konvolusjonelle nevrale nettverk Prediction of Land Cover Classes from Satellite Images using Convolutional Neural Networks. Masteroppgave. Geomatikk. Fakultet for realfag og teknologi. NMBU.
- Solem, Ø., Holthe, E., Bakkestuen, V., Bergan, M.A., Ulvan, E.M., Berg, M., T.B., Havn, Jensås, J.G., Krogdahl, R. & Lykkja, O. 2021. Tapt areal og redusert produksjonspotensial i sidevassdragtil Orkla. Sluttrapport for undersøkelser i perioden 2017-2019. NINA Rapport 1797. Norsk institutt for naturforskning.
- Velle, G., Dervo, B., Erikstad, L., Mjelde, M., Schartau, A.K., Skarbøvik, E. 2021. Forslag til naturtyper prioritert for kartlegging i ferskvann. NORCE LFI-rapport 418, Miljødirektoratet rapport M-2050|2021. Norwegian Research Center LFI, Bergen.
- Venter, Z.S. & Sydenham, M.A.K. 2021. Continental-Scale Land Cover Mapping at 10 m Resolution over Europe (ELC10). Remote Sensing 13: 2301. <https://www.mdpi.com/2072-4292/13/12/2301>
- Webb S. 2018. Deep learning for biology. Nature 554(7693): 555–557. doi:10.1038/d41586-018-02174-z.
- Økland, T., Bakkestuen, V., Økland, R., & Eilertsen, O. 2001. Det norske konseptet for vegetasjons-økologisk intensivovervåking. NIJOS-rapport 08/01: 1- 46.
- Aagaard K, Dolmen D. 1996. Limnofauna norvegica: katalog over norsk ferskvannsfauna: Tapir.
- Aagaard, K. 2011. Artsmangfoldet i Norge - en kunnskapsoversikt anno 2011. Utredning for Artsdatabanken 1/2011. Artsdatabanken, Norge.
- Aalberg Haugen, I.M., Kyrkjeeide, M.O., Bjerke, J.W, Brandrud, T.E., Hegre, H., Jokerud, M., Vange, V., Westergaard, K.B., Øien, D.-I., Myklebost, H., Hanssen, O., Hassel, K., Järnegren, J., Endrestøl, A., Lyngstad, A., Nordén, J., Dervo, B.K., Evju, M., Mjelde, M., Nordén, B., Christie, H., Gjershaug, J.O., Pedersen, B., Austrheim, G., Mattison, J., Ødegaard, F., Handberg, Ø.N, Magnussen, K, Bombu, S.V., Ruano, M., Daverdin, M., Jackson, C.R., Hanssen, F., Dervo, B., & Singaas, F.T. 2019. Tiltak for å ta vare på truet natur: Kunnskapsgrunnlag for 90 truede arter og 33 truede naturtyper. NINA Rapport 1646. Norsk institutt for naturforskning.

Vedlegg

Vedlegg 1. Gjennomsnittsanalyser og rangering av bergartsgrupper etter kalkinnhold, samt en mulig grensdragning av trinn i gradienten. Bergartsgrupper merket med rødt viser veldig store variasjoner, og må behandles uavhengig av analyseverdiene. Sammenlignbare kalkgradient i vannforskriften
Kilde: NGU 2019.

Bergartgruppe	Gj.sn ICP-AES*	Gradient	Kalkgradienten vannforskriften (mg Ca/l)
Kvartsitt	3234	Svært kalkfattig	< 1
Granitt	3292		
Tonalitt/trondhemitt	4813		
Granodioritt	5594		
Syenitt	5788		
Gneis	5835		
Biotittskifer/gneis	5925		
Kvartsskifer/metasandstein	6654		
Migmatitt	6731		
Ryolitt	7473		
Monzonitt	7481		
Larvikitt	7746		
Kvartsdioritt	8196		
Mangeritt	9256		
Dioritt	9588		
Anortositt	11715	Intermediær	2–4
Eklogitt	12093		
Glimmerskifer/gneis	12547		
Sandstein	12758		
Amfibolitt	13384		
Latitt	13771		
Gabbro	14518		
Gråvakke	19998	Kalkrik	4–20
Fyllitt	21417		
Grønnstein/skifer	27760		
Konglomerat	28711		
Kalkskifer	40200		
Dolomitt	202500	Svært kalkrik	> 20
Kalkstein/marmor	261834		

* Analyseres på pulver fra knust stein. Dette pulveret limes sammen til tablett, smeltes til å forme glasstabletter eller løses i syre, og det oppløste materialet analyseres i en ICP-AES ("Inductively coupled plasma atomic emission spectroscopy").



Vedlegg 2. Kart som viser utstrekningen til de ulike bioklimatiske sonene. Sonene beskrevet i tabell 2.4 tilsvarer følgende fargekoder: BoNE = Nemoral og Boreonemoral, SøBo = Sørboreal, MeBo = Mellomboreal, NoBo = Nordboreal og LaAL/MeAl/HøAl/ArKrTu og MeArTu = Alpin. Kilde: NTNU Vitenskapsmuseet/Artsdatabanken.

BoNE = Nemoral og Boreonemoral, SØBo = Sørboreal, MeBo = Mellomboreal, NoBo = Nordboreal og LaAL/MeAl/HøAl/ArKrTu og MeArTu = Alpin.

ArPoØr - arktisk polarørkensone
NoArTu - nordarktisk tundrasone
MeArTu - mellomarktisk tundrasone
SøArTu - sørarktisk tundrasone
ArKrTu - arktisk kratt-tundrasone
HøAl - høyalpin sone (HA)
MeAl - mellomalpin sone (MA)
LaAl - lavalpin sone (LA)
NoBo - nordboreal sone (NB)
MeBo - mellomboreal sone (MB)
SøBo - sørboreal sone (SB)
BoNe - boreonemoral sone (BN)

Norsk institutt for naturforskning, NINA, er en uavhengig stiftelse som forsker på natur og samspillet natur–samfunn.

NINA ble etablert i 1988. Hovedkontoret er i Trondheim, med avdelingskontorer i Tromsø, Lillehammer, Bergen og Oslo. I tillegg driver NINA Sæterfjellet avlsstasjon for fjellrev på Oppdal, og forskningsstasjonen for vill laksefisk på Ims i Rogaland.

NINAs virksomhet omfatter både forskning og utredning, miljøovervåking, rådgivning og evaluering. NINA har stor bredde i kompetanse og erfaring med både naturvitere og samfunnsvitere i staben. Vi har kunnskap om artene, naturtypene, samfunnets bruk av naturen og sammenhenger med de store drivkreftene i naturen.

ISSN:1504-3312
ISBN: 978-82-426-4864-8

Norsk institutt for naturforskning

NINA Hovedkontor

Postadresse: Postboks 5685 Torgarden, 7485 Trondheim

Besøks-/leveringsadresse: Høgskoleringen 9, 7034 Trondheim

Telefon: 73 80 14 00, Telefaks: 73 80 14 01

E-post: firmapost@nina.no

Organisasjonsnummer 9500 37 687

<http://www.nina.no>



Samarbeid og kunnskap for framtidens miljøløsninger