

Kunstig intelligens i miljøovervågningen?

I miljøovervågningen anvendes viden om planter og dyrs egenskaber til at vurdere deres levesteders økologiske tilstand. Der er mange slags, der kan være svære at bestemme uden ekspertviden. Men måske kan kunstig intelligens hjælpe. En computer kan nemlig "trænes" til at identificere organismerne ud fra fotos. Her vurderer vi mulighederne for at identificere vandløbenes smådyr via kunstig intelligens.

KENNETH THORØ MARTINSEN, SØREN THROMSHOLDT CHRISTENSEN & KAJ SAND-JENSEN

Organismer i miljøovervågningen

Tilstedeværelse og hyppighed af bestemte arter, slægter eller grupperinger på mere overordnet taksonomisk niveau, i det følgende omtalt som "taxa", kan karakterisere levesteders kvalitet både på land og i vand. På land er de såkaldte Ellenberg-værdier for forskellige plantearter anvendt til at beskrive forskellige miljøfaktorer. I vandløb og søer anvendes planktoniske og bundlevende alger, højere planter, smådyr (makroinvertebrater) og fisk til at vurdere den økologiske tilstand. Både i og uden for Danmark er der lang tradition for at anvende tilstedeværelse og hyppighed af smådyr til at bedømme vandløbs miljøtilstand, fordi forskellige taxa bl.a. varierer i tolerance over for forurening med vandets

indhold af organisk stof og påvirkningen af iltindholdet (Figur 1). Konkret benytter man Dansk vandløbsfaunaindeks (DVFI) til netop det formål.

På grund af smådyrenes vidtspændende tolerance, ikke bare over for let-omsætteligt organisk stof, men også fysiske forhold, er organismegruppen en rigtig god indikator ^{1,2}. Smådyrene har den fordel frem for kemiske og fysiske øjeblikmålinger, at de lever relativt længe og dermed giver et mere retvisende billede af varierende miljøfaktorer. Det kræver imidlertid en korrekt identifikation af de anvendte taxa, noget som først opnås med lang træning og erfaring.

Kunstig intelligens

Identifikation af smådyr kræver øje for detaljer og hukommelse for at have set samme eller lignende taxa, og derefter kan informationen vurderes for at nå til korrekt taxa. For mennesker kræver det tid at opbygge en sådan erfaring.

Med passende data, fx i form af billeder, kan man lære en computer at genkende mønstre og karaktertræk hos de enkelte taxa. Kunstig intelligens betegner kunsten at få computere til at efterligne menneskelig intelligens, herunder maskinlæring, hvor forskellige algoritmer trænes til at udføre specifikke opgaver ved hjælp af data, for eksempel til at genkende objekter på billeder ³. Var denne artikel skrevet for blot ét år siden, ville brugen af udtryk som kunstig intelligens og maskinlæring have løftet en del øjenbryn. Men nu har brugen for alvor gjort sit indtog og skabt respekt i den brede befolkning på grund af anvendelser som ChatGPT.

Den seneste nyudvikling indenfor maskinlæring har taget udgangspunkt i bl.a. billedklassifikation (Boks 1). I 2012 benyttede forskere fra Torontos universitet store neurale netværk i ImageNet konkurrencen og vandt overbevisende. ImageNet er en konkurrence om at træne modeller til klassifikation af indholdet i over 1 million billeder i 1000 forskellige kategorier. Resultatet var, at det blev muligt at træne store neurale netværk med mange parametre. Desuden forøgedes hastigheden af træningsprocessen dramatisk ved at bruge specielt hardware i form af grafikkort, som ellers er designet til computerspil. I dag er tilgængeligheden af værktøjer til at træne neurale netværk mangedoblet, og det samme gælder anvendelser af teknologien.

En intelligent computer assistent

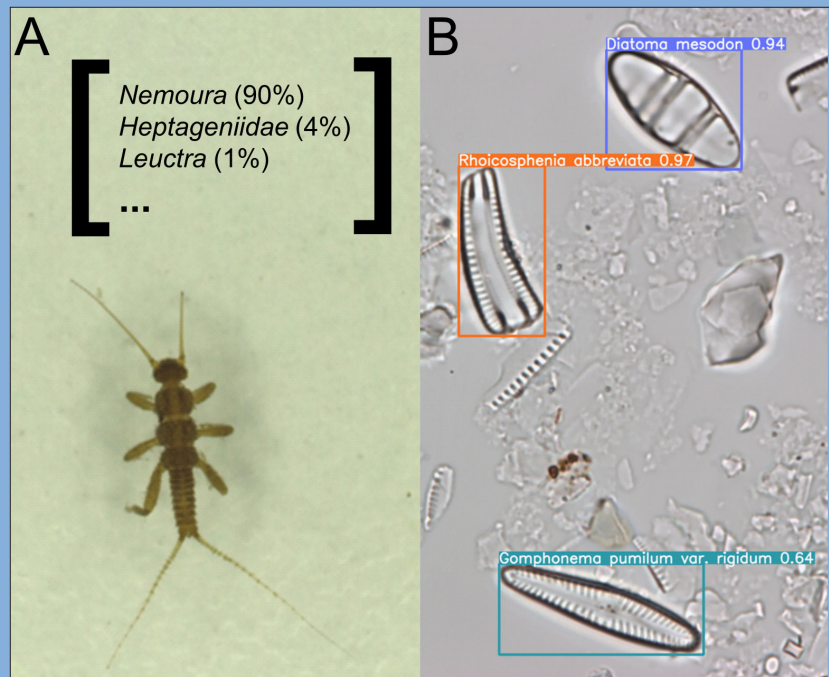
Der findes mange anvendelser af generel identifikation af arter, især landplanter, hvor der er mange data. Men kan man indsnævre den opgave, som modellen skal trænes til at løse, kan man også forbedre nøjagtigheden.



Figur 1. Fire udvalgte smådyr, som findes i vandløb, og rangeret fra lave (venstre) mod høje (højre) værdier af DVFI. A. *Oligochaeta*; B. *Simuliidae*; C. *Gammarus*; D. *Leuctra*.

Box 1.

Neurale netværk kan trænes til at udføre mange forskellige opgaver ved brug af billeder. Det simpleste er klassifikation, hvor der til hvert billede er en korrekt mærkat ud af en række kandidater. Her fodres modellen med et billede, og der kommer et tal ud for hver klasse, som modellen er trænet til at genkende. Tallet angiver modellens sikkerhed (Figur 2A). Denne metode er tilstrækkelig, hvis man oftest ser på et objekt ad gangen. Ser man på mange objekter samtidigt, fx på mikroskopslides, kan en model trænes til at afgrænse og klassificere alle objekter i billedet samtidigt (Figur 2B). Det giver også den fordel, at man automatisk kan beskrive objekternes rumlige dimensioner. Endelig kan "segmentering" forbedre afgrænsning af objekter, hvor en model trænes til at estimere, hvilken klasse hver pixel i billedet tilhører.




Figur 2. A. Eksempel på billedklassifikation af vandløbs smådyr. Input til modellen er et billede (Nemoura) og output er mål for sikkerheden (%) for mulige alternative taxa. B. Eksempel på identifikation af kiselalger. Input til modellen er et billede og output er afgrænsninger (farvede firkanter) og klassifikation (artsnavne) af algerne. Modellen (YOLOv5) er trænet med data fra et tyrkisk studium /4/.

Det gælder især, hvis man har et mindre men meget specifikt datasæt, fx vandløbenes smådyr. Vi har trænet en model til at genkende taxa i DVFI (Figur 3). Modellen er derefter indbygget i en applikation, der kan kobles til en stereolup og derved løbende sætte navn på dyret under luppen, samt en procentsats for sikkerheden (Figur 4).

Identifikation af smådyr

Neurale netværk består af mange lag og har mange parametre (millioner), der optimeres ved gentagelser (iterativt), hvilket kræver store datasæt og computerressourcer. Neurale netværk har dog den egenskab, at de kan genbruges til lignende opgaver. Modeller, der er trænet til at klassificere billeder af hverdagsobjekter, kan derfor fordelagtigt bruges som udgangspunkt for en model til at

genkende smådyr. Det kan lade sig gøre, fordi de lag som udgør modellerne gradvist lærer at ekstrahere mere og mere komplicerede former og mønstre i billederne /1/. Derfor kan man blot fjerne det allersidste lag, hvor den endelige klassifikation foretages, og dermed genbruge de tidligere lag, hvoraf generelle mønstre uddrages, fx linjer og punkter. Vi har sammensat et datasæt til identifikation af smådyr ved bestemmelse af DVFI bestående af i alt 4971 fotos, som tilhører 25 taxa af smådyr. De 2665 fotos har vi selv skaffet ved at indsamle og under stereolup fotografere smådyr fra Fønstrup Bæk, Pøle Å og Usserød Å, mens 2306 fotos er hentet fra GBIF (Global Biodiversity Information Facility). Det var nødvendigt, fordi der kun findes få foto-data med national relevans /5,6/. I alt er 4596 billeder brugt til træning af modellerne og 15 tilfældige billeder fra hver klasse er udelukkende anvendt til at bestemme nøjagtighed af bestemmelserne. Adskillelsen af datasættet i et træningssæt og evalueringssæt er essentiel for at opnå et retvisende billede af modellernes ydeevne. Modellerne trænes iterativt og ser træningsdata over flere omgange. Det uafhængige datasæt bruges derfor også til at stoppe træningen. Ellers lærer modellerne blot at huske alle billederne i træningssættet. Desuden kan træningsdata gøres kunstigt større ved at rotere, spejle, ændre lysforhold eller blot bruge et udklip af det originale billede under træningen. Det forbedrer modellernes



Figur 3. Andel af fotos af nøglegruppe/diversitetsgruppe taxa (25) i et sammenstillet datasæt. Det består af egne fotos og fotos fra GBIF.

evne til at generalisere, og det er også grunden til at vores eget data er suppleret med data fra GBIF, hvor smådyrene ikke nødvendigvis er afbilledet ved høj opløsning under stereolup. Desuden er det vigtigt, at modellen ser billeder, hvor kun dele af dyret er synligt, da manglende halenokker, ben, mm. er almindeligt i faunaprøver.

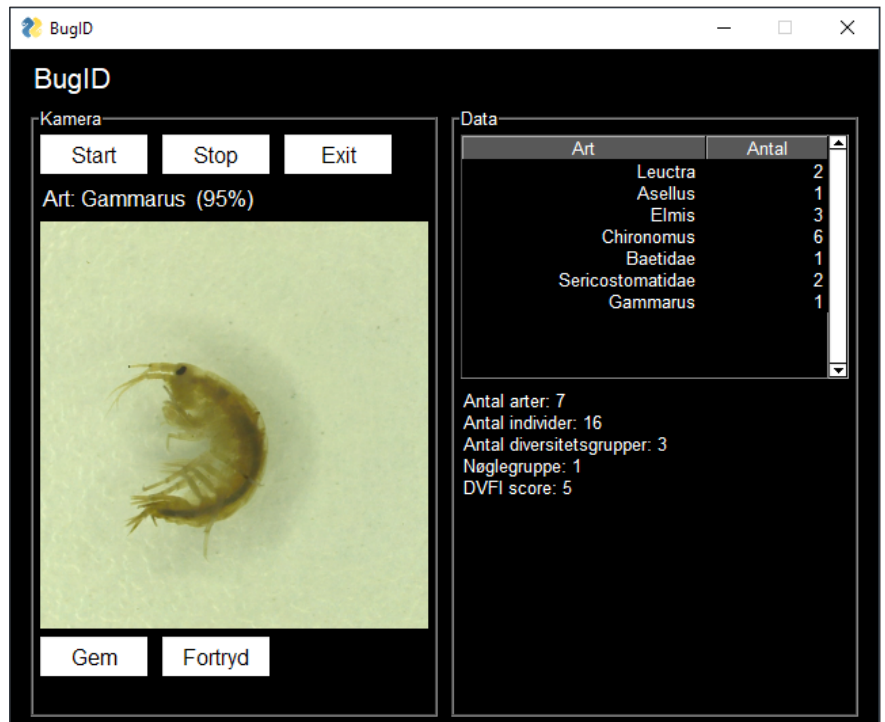
Vi har trænet et udvalg af modeller, som varierer i størrelse (antal parametre) og neural netværks arkitektur (Tabel 1). Modellerne er fin-tunede, og udgangspunktet er derfor en model trænet på ImageNet datasættet, hvor der er 1000 meget forskellige klasser af alt fra hverdagsting til dyr, og deres ydeevne er evalueret på det samme datasæt. Generelt kan man se, at større modeller yder bedre, men også at de "sidste forbedrede procenter" kræver relativt mange flere parametre. For ResNet-34 til ResNet-50 falder ydeevnen endog modsat forventet, hvilket kan skyldes datasættets relativt begrænsede størrelse.

Der er også forskel i arkitektur af Resnet, MobileNet og ConvNext modellerne. Nyere design øger effektiviteten, så en model som ConvNext-nano overgår ResNet-34 på trods af færre parametre. Der er altså en afvejning af ydeevne og modelstørrelse. Skal modellen fungere gnidningsfrit ved begrænset computerkraft, er det svært at komme uden om MobileNet modellerne, som er meget mindre end resten.

Selvom den underliggende matematik i neurale netværk ikke er særlig avanceret, kan det umiddelbart være svært at forklare, hvad der sker, når modellen omsætter et billede til en række tal. Som alt andet indenfor maskinlæring, bevæger udviklingen sig hurtigt, og det samme gælder vores evne til at fortolke, hvad modellerne 'kigger på'. Derfor kan vi også bruge dette aktivt til at undersøge hvilke karaktertræk, som vægter højt for modellernes klassifikationer (Figur 5). For eksempel lægger modellen særlig vægt på hovedet og brystet af Hydropsychidae (Figur 5, øvre række), mens halenokkerne hos *Nemoura* bidrager positivt, så bidrager de negativt, hvis det drejer sig om halenokkefri Hydropsychidae. Disse værktøjer kan anvendes "eksplorativt" til at forbedre modellerne, da de kan identificere huller i datasættet. Men de kan også være interessante at anvende til at identificere nøgletræk for taxa.

Perspektiver

Man kan altså sagtens træne modeller til at klassificere billeder af smådyr med stor nøjagtighed. Alligevel tyder det på, at computerne endnu ikke har indhentet eksperternes evner. Et studium fra Finland fandt, at eksperter,



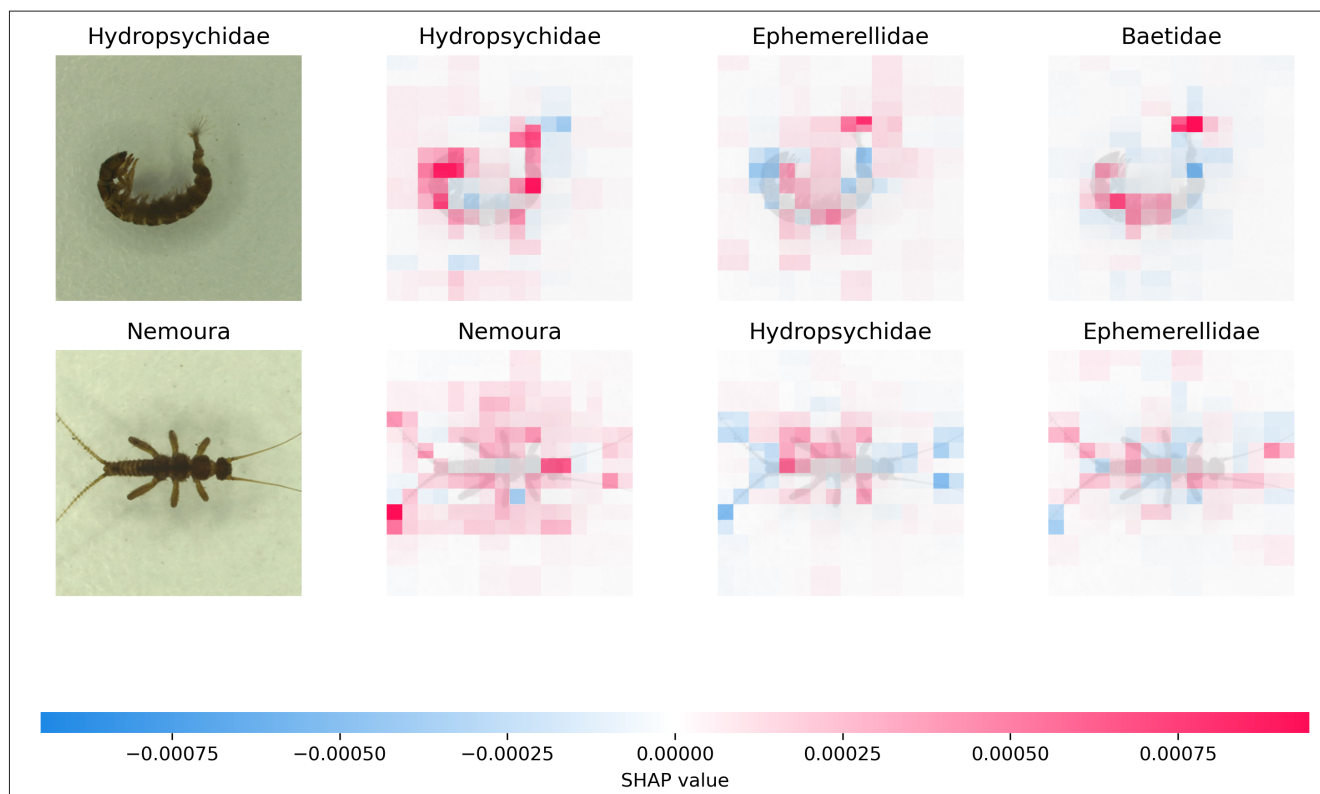
Figur 4. Screenshot af "BugID", som er en software prototype til "live assistance" ved identifikation af smådyr. Programmet kan kobles til en stereolup og inkluderer en model, der løbende giver bud på, hvilket taxon der er i fokus. De fundne taxa og antallet af dem kan gemmes som en liste, og der laves samtidig en DVFI beregning. For nuværende er DVFI beregningen dog ikke retvisende, da modellen endnu ikke kan genkende alle de relevante taxa.

som så på smådyrene under stereolup havde lavere fejlrate (6,1%) end en computer ud fra fotos (11,4%) /7/. Identifikation af nogle taxa, især hvis der bestemmes til artsniveau, kræver at dyret kan manipuleres for at kunne se specifikke detaljer ved stor forstørrelse, og her kan modeller, der anvender enkeltbilleder, komme til kort. Der er dog flere muligheder for at gøre modellerne bedre og øges datamængden og kvalitet, bør det forbedre nøjagtigheden. Modellerne kan desuden trænes ved at bruge flere billeder af samme dyr fra forskellige vinkler til klassifikationen.

Men der er altså fortsat brug for eksperter, og særligt når det gælder meget sjældne taxa, da de modeller, som er præsenteret her, ikke ved, hvornår de ser en ny art. Men til brug i miljøovervågningen, hvor dyrene oftest identificeres til familie eller slægt, og dyrene samtidig er ret almindelige, kan der være god hjælp at hente fra modellerne. Nogen af fordelene ved computeren er dens hastighed og udholdenhed. Det er dog sjældent, at alle dyr skal forbi stereoluppen, og her kan ekspertens overblik over faunaprøven være svær at matche. Når der så er tvivl, er computeren en

Tabel 1. Klassifikations nøjagtighed for udvalgte modeller, som varierer i både arkitektur og antal parametre. De er alle 'convolutional' neurale netværk; ældst er ResNet (2016), mens Mobilenet (2018) og ConvNext er nyere (2022). Nøjagtigheden er vurderet som top-1 og top-5 succes med en procent for, hvor tit modellen rammer rigtigt ud fra de henholdsvis 1 eller 5 mest sandsynlige taxa.

Model	Antal parametre (i millioner)	Top-1 success (%)	Top-5 success (%)
ResNet-18	11,7	86,4	97,6
ResNet-34	21,8	87,5	98,1
ResNet-50	25,6	82,9	95,5
MobileNetV2-050	2,0	82,4	94,9
MobileNetV2-100	3,6	83,7	96,8
MobileNetV2-140	6,2	84,5	96
ConvNext-nano	15,6	92,8	98,1
ConvNext-tiny	28,6	93,1	98,9



Figur 5. Visualisering af hvilke træk, der lægges vægt på, når det neurale netværk (ConvNext-nano model) klassificerer billeder. De to smådyr under stereoluppen ses til venstre, efterfulgt af de 3 taxa med den højeste sikkerhed. Vægten af de visuelle karakteristika er udtrykt som SHAP værdier og viser om karakteristika trækker ned eller op ved den endelige klassifikation af to smådyr, Hydropsychidae og Nemoura.

assistent, som altid er parat, og endda kan fremhæve de vigtige karakteristika, der ligger til grund for klassifikationen.

Konklusion

Vi har præsenteret data, modeller og software som et "proof-of-concept" på, hvordan identifikation af smådyr ved bestemmelse af DVFI kan "assisteres" ved brug af maskinlæring og gjort det frit tilgængeligt til brug og videreudvikling. Ekspertene får vi dog stadig brug for, især når det gælder de sjældne arter, men også når der skal opbygges datasæt af høj kvalitet /8/. Vi ser ingen grund til at stoppe her. Maskinlæring til bestemmelse af taxa i miljøovervågningen kan hjælpes hastigt på vej ved udvikling af specialiserede modeller, som kan have væsentlige fordele over eksisterende generelle modeller. Det gælder alt fra identifikation af planter på land til alger i mikroskopslides. Vi ser altså gode muligheder for spændende anvendelser af maskinlæring og billedanalyse i fremtidens miljøovervågning.

Om projektet og en tak

Dette projekt er et samarbejde mellem Ferskvandsbiologisk Laboratorium, Københavns

Universitet og Cphbusiness Laboratorie og Miljø i Hillerød. Det datasæt, som er indsamlet i projektet er frit tilgængeligt på <https://www.kaggle.com/datasets/kennethm/stream-macroinvertebrates>. De trænedede modeller og software, som er præsenteret her, er også frit tilgængelige på https://github.com/KennethTM/macro_inv_id. Tak til emeritus og faunaekspert Peter Wiberg-Larsen for gode forslag.

Referencer

- /1/ Friberg, N., Skriver, J., Larsen, S.E., Pedersen, M.L. & Buffagni, A. (2010). Stream macroinvertebrate occurrence along gradients in organic pollution and eutrophication. *Freshwater Biology*, 55, 1405-1419.
- /2/ Wiberg-Larsen, P. & Sode, A. (2010). Fokus: Fysisk indeks. Side 69-83 i: Wiberg-Larsen, P. (red.) Vandløb 2009. NOVANA. Faglig rapport fra DMU nr. 804.
- /3/ Jensen, M. B., Bahnsen, C. H., Nasrollahi, K. & Moeslund, T. B. (2018). Deep learning – et gennembrud inden for kunstig intelligens. *Aktuel Naturvidenskab*, 2, 8-13.
- /4/ Gündüz, H., Solak, C. N., & Günel, S. (2022). Segmentation of diatoms using edge detection and deep learning. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30, 2268-2285.
- /5/ Larios, N., et al. (2011). Stacked spatial-pyramid ker-

nel: An object-class recognition method to combine scores from random trees. *Proceedings of IEEE Workshop on Applications of Computer Vision (WACV)*, 329-335.

- /6/ Raitoharju, J., et al. (2018). Benchmark database for fine-grained image classification of benthic macroinvertebrates. *Image and Vision Computing*, 78, 73-83.
- /7/ Ärje, J., et al. (2020). Human experts vs. machines in taxa recognition. *Signal Processing: Image Communication*, 87, 115917.
- /8/ Sand-Jensen, K., Martinsen, K. T., Kragh, T. (2022). Intelligente computersystemer i økologien. *Aktuel Naturvidenskab*, 5, 16-19.

KENNETH THORØ MARTINSEN er Post doc ved Ferskvandsbiologisk Laboratorium, Københavns Universitet.

Email: kenneth.martinsen@bio.ku.dk

SØREN THROMSHOLDT CHRISTENSEN er lektor ved Cphbusiness Laboratorie og Miljø i Hillerød.

Email: stc@cphbusiness.dk

KAJ SAND-JENSEN er professor ved Ferskvandsbiologisk Laboratorium, Københavns Universitet.

Email: ksandjensen@bio.ku.dk