


EN STUDIE OM TRÅLNINGENS PÅVERKAN PÅ SJÖPENNOR I KATTEGATT.



Rasmus Thorslund

Uppsats för avläggande av naturvetenskaplig kandidatexamen med huvudområdet marin vetenskap
MAR 302, Examensarbete för kandidatexamen i marin vetenskap, inriktning biologi, 15 hp, Grundnivå

Termin/år: Vt 2022

Handledare: Matthias Obst (Institutionen för marina vetenskaper)

Bitr.

handledare: Andreas Emanuelsson (Medins Havs och Vattenkonsulter)

Examinator: Erik Selander (Institutionen för marina vetenskaper)

Rasmus Thorslund

Maskininlärning för framtida miljöövervakning

Kattegatt är ett havsområde som sträcker sig från Öresund i syd till Marstrand i norr. Detta område har trålats länge, vilket gjorde stor skada på det marina livet. För att kunna undersöka hur det marina livet påverkas och återhämtar sig från trålning behövs storskalig miljöövervakning, problemet är att miljöövervakning över stora marina områden tar lång tid och är tidskrävande.

För att underlätta i miljöövervakning har forskare utvecklat maskininlärningsmodeller som automatiskt kan upptäcka och artidentifiera bottenlevande marina arter från bilder och filmer. Detta kan sedan användas för att till exempel analysera hur den biologiska mångfalden har påverkats av trålning över tid i Kattegatt.

I denna studie undersöktes hur sjöpennearterna röd fjäderpenna (*Pennatula phosphorea*) och liten piprensare (*Virgularia mirabilis*) påverkas av trålning. Påverkan uppskattades genom att analysera filmer från Kattegatt, dessutom undersöktes det om skillnader fanns i hur olika människor med samma metod analyserade filmerna. Ett ytterligare syfte var att undersöka om en maskininlärningsmodell tränad på samma filmer kunde skapa artobservationsdata för sjöpennor. Detta gjordes genom att bilder med sjöpennor markerades, så att modellen lärde sig hur arterna såg ut.

Resultaten visa att sjöpennor påverkas negativt av trålning. *P. phosphorea* verkar vara känsligast för trålning, då antalet sjöpennor sjönk med minst 35% efter lätt trålpåverkan. Till skillnad mot *V. mirabilis* som verkar vara mer resistent, då den bara sjönk i antal efter mer ihärdig trålning. Sjöpennor, och habitatet de bildar, klassas av Oslo-Pariskonventionen (OSPAR) som skyddsvärda, och borde därför övervakas i svenska vatten. Här kan en maskininlärningsmodell hjälpa till och automatisera arbetet, då det förkortar analysiden. Maskininlärningsmodellen kan efter träning urskilja sjöpennearterna med en säkerhet på 80%, och kan räknas som redo att användas i fält för framtida miljöövervakning i Kattegatt området. Skillnaden mellan de mänskliga analys och modellen låg på 40%, detta kan kompenseras för vid användning och tränas bort i framtiden.

Sammanfattning

Kattegatt är ett marint område som sträcker sig från Öresund i syd till Marstrand i norr vid Sveriges västkust. I detta område har omfattande trålning skett i jakt på kommersiella arter så som havskräfta, vilket har visat sig ha en negativ effekt på det marina livet. För att få bättre förståelse hur detta område fortsätts att påverkas av trålning och hur det ska förvaltas behövs storskalig miljöövervakning. Problemet är att miljöövervakning över stora marina områden genererar väldigt mycket data, tar lång tid att analysera och kostar mycket pengar vilket gör att det sällan genomförs på en regelbunden basis och över större områden. Detta gör det svårt att observera förändringar i abundans och biodiversitet över tid. För att underlätta och effektivisera miljöövervakning har det medborgarforskningsbaserade projektet Koster Seafloor Observatory utvecklat maskininlärningsmodeller som automatiskt kan artidentifiera djur från bilder och videoklipp.

I denna studie undersöktes om det finns en trålpåverkan på arterna *Pennatula phosphorea* och *Virgularia mirabilis*, kan man träna en maskininlärningsmodell för att övervaka abundans och utbredning av sjöpenor på dropvideo och hur stor är skillnaden inom manuell övervakning av sjöpenor och mellan manuell och maskinbaserad övervakning. Resultaten visar att båda arterna av sjöpenor påverkas negativt av trålning, där *P. phosphorea* verkar påverkas mest av lätt trålning medan *V. mirabilis* påverkas vid hårdare trålning. Modellen presterar bra med ett precision-värde på 0,8 och ett recall-värde på 0,7 vid konfidensvärdet 0,4. Men kan optimeras då den fortfarande har FP/FN kvar. Detta kan göras igenom att ha ett större träningsdataset och fler bilder med artefakter. Skillnaden inom manuell övervakning låg på 35 % och skillnaden mellan manuell och maskinbaserad låg på 40 % för fem analyserade filmer. Skillnaden mellan manuell-manuell och manuell-maskin är inte stor och kan kompenseras för vid miljöövervakning över stora marina områden.

Sammanfattningsvis är maskininlärningsmodeller något att överväga för övervakning av sjöpenor i Kattegatt och de kan även användas för att göra miljöövervakning över stora marina områden mer regelbunden och effektiv samt utvecklas för objekt så som rödlistade och hotade arter som behöver skyddas och övervakas.

Innehållsförteckning

Innehållsförteckning	4
Introduktion.....	5
Syfte	7
Forskningsfrågor.....	7
Metod.....	7
Filmprovtagning.....	7
Videoanalys.....	8
Klassificering av trålskada.	8
Trålskadeanalys.....	10
Analys av trålgrad.	10
Analys av trålad yta.....	10
Statistisk analys.	10
Modellträning	10
Analys av skillnader.	11
Resultat.....	12
Analys av trålgrad.	12
Analys av trålad yta.....	13
Analys av modellen.....	14
Analys av skillnader.	15
Diskussion	16
Trålgrad.	16
Trålad yta.....	17
Maskinbaserade artobservationer.	18
Slutsats.....	19
Referenslista.....	20

Introduktion

Kattegatt är ett marint område som sträcker sig från Öresund i syd till Marstrand i norr vid Sveriges västkust där det bräckta vattnet från Östersjön möter det saltvattnet från Nordsjön. Detta gör Kattegatt artfattigare än Skagerrak men många marina arter återfinns här så som sjöpennor och hästmussla som är viktiga biotopbyggare (Sverigesvattenmiljö, 2022). Stora delar av bottensubstratet i området består av lera, sand och silt vilket gör att ett omfattande fiske med trålning efter havskräfta och räkor finns här (Sköld m.fl., 2021). Trålningen har visat sig ha en negativ effekt på mjukbottensamhällen där de flesta arter minskar och den biologiska mångfalden sjunker (Sköld m.fl., 2016).

Sjöpennor är koralldjur som förekommer på mjukbottnar och fungerar som viktiga habitatbildare när de finns i stor abundans. Dessa sjöpennor ”skogar” skapar viktiga strukturer på dem annars kala mjukbottnarna där fisk och skaldjur kan söka skydd och föda (Murillo m.fl., 2018). Det har även visat sig att sjöpennor har en positiv effekt på artdiversitet och abundans för makrofaunasamhällen i sedimentet, detta förmodligen igenom att öka tillgången på mat och ge stabilitet (Miatta & Snelgrove, 2022) Tyvärr har tidigare studier visat att sjöpennor och habitaterna de bildar är på nedgång och klassas av OSPAR som hotade arter och habitat (OSPAR, 2008), detta framför allt på grund av skadliga fiskemetoder så som trålning men även från andra hot (IUCN, 2016). Samma sak har observerats i Kattegatt för arterna *Pennatula phosphorea* och *Virgularia mirabilis* (Emanuelsson m.fl., 2021). Genom att förstå hur sjöpennors utbredning och abundans påverkas av till exempel trålning kan man förvänta sig insikt i miljöstatusen på mjukbottnar i Kattegatt och därigenom hjälpa till med förvaltningen och övervakning för detta område.

Övervakning av Kattegatts ekosystem är viktigt för många olika anledningar. Dels för att se hur området påverkas av miljöförändringar och trålning, dels hur det återhämtar sig när man inför trålförbudszoner och för att kunna ha en adaptiv förvaltning och miljöövervakning.

Miljöövervakning över stora marina områden med video ger stora mängder data som måste analyseras innan man får en insikt på statusen. Här kan maskinlärningsmodeller (ML) och artificiell intelligens (AI) komma in och underlätta arbetet då dessa metoder kan analysera videoprover automatiskt och genom detta spara både på tid, pengar och öppnar upp för att kunna göra miljöövervakning på en regelbunden basis.

The Koster Seafloor Observatory (KSO) är ett medborgarforskningsbaserat projekt som utvecklar maskinlärningsmodeller och algoritmer som automatiskt kan upptäcka bottenlevande marina arter (Anton m.fl., 2021). Målet är att kartlägga biodiversitet, abundans och analysera biologiska förändringar över tid och över stora marina områden. Tidigare studier där maskininlärning har använts för att skapa artobservationer (genom så kallade object detection models) är till exempel Lopez-Vazquez m.fl. (2020) och Ditria et al. (2020). En object detection modellens effektivitet kan variera mycket beroende på en rad olika faktorer, som till exempel antal och kvaliteten på träningsdata (labelled images), bildkvalitet och objektens egenskaper som form och färg med flera. En av de viktigaste faktorerna som påverkar prestanda på en object detection model verkar vara kontrasten mellan objektet och bakgrunden. Desto större kontrasten är desto effektivare är modellen. Undervattensbilder från Remotely Operated Vehicles (ROV) eller från dropvideo är ofta dålig kvalitet då det finns lite naturligt ljus under den fotiska zonen (det vill säga under 20m), då vattnet är ofta grumligt och fyllt med partiklar från sedimentet eller marin snö. Även distansen till objektet och dess storlek påverkar hur säker modellen kan bli.

Syfte

Syftet med denna studie är att använda både manuella och maskininlärning (ML)-baserade artobservationer för att undersöka samband mellan förekomst av sjöpennor och trålskador på mjukbottnar i Kattegatt. Detta genom att analysera dropvideodata från Kattegatt för att analysera arterna *P. phosphorea* och *V. mirabilis* har påverkats av trålning samt att träna och testa en maskininlärningsmodell utifrån samma dataset.

Forskningsfrågor.

- 1) Finns det tecken av trålpåverkan på sjöpennor och därmed en anledning till att överväga användningen av ML för att övervaka abundans och utbredning av dessa djur i framtiden?
- 2) Kan man träna en ML-modell för att övervaka abundans och utbredning av sjöpennor på dropvideodata?
- 3) Hur stor är skillnaden inom manuell övervakning av sjöpennor och mellan manuell och maskinbaserad övervakning?

Metod

Filmprovtagning.

Samtliga videoprover tillhandahölls från Länsstyrelsen Halland i ett utdrag av den länstäckande utsjökartering som utförts med dropvideo 2014–2021 (Emanuelsson m.fl., 2021). Medins Havs och Vattenkonsulter som utförde den senaste provtagningen med dropvideo 2020 och 2021 bistod med träning i bildanalys och videoselektion inom ramen för Ocean Data Factory 2 samarbetet 2022 (www.oceandatafactory.se).

I detta delområde filmades 460 korta transekter 20–25m spridda över Norra Halland från ca 20m gränsen för svensk ekonomisk zon (ca 70–80m). Från detta valdes 297 baserat på klassificerat habitat, sjöpennor och grävande megafauna som referensvärden (färdigt analyserade och klassificerad prov av Medins hav och Vattenkonsulter). Utav dessa valdes därefter 93st filmer som redan identifierats som visuellt trålpåverkade för vidare analys i denna studie (trålskadeanalys och felskattningar) samt jämfördes mot referensvärden (trålskada).

Videoanalys.

Videoanalysen gjordes på en stor skärm och med programvara som tillåter export av bilder i JPEG-format, varierande uppspelningshastighet och framstegning. Starttid för analys noterades när videon bedömts tillräckligt stabil. Sjöpennor av arterna *P. phosphorea* och *V. mirabilis* räknades. Inräkning stoppades när kameran började föras upp genom vattenkolumnen och sluttid noterades.

Avgränsningar som gjordes var observationer som inte kan bestämmas till art förkastades, inga observationer i periferin utanför den effektiva synbredden, levande del av djuret synligt samt inga små individer (ca <5mm). Avgränsningar gjordes baserat på riktlinjer för analysarbete från (Emanuelsson m.fl., 2021).

Klassificering av trålskada.

Klassificeringen av trålskada har gjorts enligt den tregradiga skala som presenteras i metodiken för videoundersökning och naturtypskartering i Norra Halland (Emanuelsson m.fl., 2021). Trålpåverkan klassificeras genom en sammanvägning av synintryck från hela transekten, detta utgår från två gränser av låg eller hög påverkans vilket ofta korrelerar med ny eller äldre påverkan.

Trålskada delades även upp i 3 klasser baserat på utseende. ”Raviner” efter trålbord, grunda parallella linjer av trålens ”släp” och uppkastade lerkokor. Under hur lång tid trålpåverkan är synlig klockades för att bedöma trålad yta, stoppuret startades när trålskadan var inom den effektiva synbredden och stoppades när trålskadan var utanför. Varje klass klockades för sig själv för att veta hur länge de är generellt är synliga.

Grad 1 (Låg) ”representerar mindre trålpåverkan eller äldre trålsår, till exempel enstaka tecken på onaturlig kupering och mer diffusa ”raviner” efter trålbord. Oftast i en begränsad del av videotransekten.” (Emanuelsson m.fl., 2021, s.12)

Grad 2 (Intermediär) ”representerar ett mellanläge och fångar upp de ytor med trålpåverkan som inte har tydliga karaktärer av vare sig lätt eller kraftig trålpåverkan, till exempel enstaka kraftiga spår i en begränsad del av provet.” (Emanuelsson m.fl., 2021, s.12)

Grad 3 (Hög) ”representerar kraftig påverkan, till exempel tydliga djupa raviner och kantiga uppkastade lerkokor. Det kan även finnas grunda parallella spår av tråls underställ som tyder på att påverkan skett nyligen. Skadade sjöpenor eller sjöborrar ses ibland i sedimentet och påverkan är oftast i en betydande del av provet.” (Emanuelsson m.fl., 2021, s.12)



Figur 1. Trålsår: överst till vänster: ”ravin” efter trålbord (grad 1), överst till höger: parallella linjer av tråls släp (grad 2), nederst: kantiga uppkastade lerkokor (grad 3).

Trålskadeanalys

Analys av trålgrad.

För att se hur sjöpennor påverkas av olika trålgrader och om det är någon skillnad mellan hur påverkat det är analyserades datan med hjälp av Excel. Medelvärde för antalet sjöpennor räknades ut i respektive trålgrad.

Analys av trålad yta.


Även en undersökning av korrelationen gjordes mellan sjöpennor och trålad yta genomfördes. Detta för att se om antalet sjöpennor sjönk när trålytan steg. Genom att klocka hur länge trålskador uppträder kunde korrelationen mellan antalet sjöpennor och med trålad yta räknas ut.

Statistisk analys.


Den statistiska analysen gjordes i Excel. För att se om det fanns en signifikant skillnad mellan antalet sjöpennor i de olika trålgraderna gjordes t-test: Två sampel antar olika varians. T-testen gjordes mellan varje trålgrad med ett alfavärde på 0,05, detta resulterade i att tolv t-tester gjordes. För att se att skillnaden inte hade uppstått av slump gjordes ett Kruskal-Wallis test med ett alfavärde på 0,05. Testet visar även om det finns en signifikant skillnad mellan de olika trålgradernas medianer men inte var denna skillnad finns. Anledningen till att Kruskal-Wallis test användes istället för one way anova är på grund av att sampelstorlekarna var olika.

Modellträning

Underlag för modellen att tränas på gjordes genom att annotera bilder med *P. phosphorea* och *V. mirabilis*, detta gjordes genom att använda medborgarforskningmodulen i Koster Seafloor Observatory (KSO). Olika färgade boxar användes för att berätta för modellen vilket objekt som fanns inom boxen (figur 2). Sammanlagt annoterades 128 bilder (figur 3). Modellen tränades sedan i plattformen Weights & Biases (<https://wandb.ai/site>) av en dataexpert på KSO. Träningen gjordes genom att modellen tränades på 80% av bilder för att sedan verifieras på resterande 20%. Precisionen uppmätts igenom att modellen jämförs mot bilder som har annoterats av en människa. Dessa bilder används som en ground truth, modellen har sedan kört igenom samma bilder vilket ger ett mått på hur stor sannoliken är att den kan skilja på sjöpenna och ej sjöpenna.



Figur 2. Annotering av sjöpennor: Vänstra onoterad, högra annoterad.



Figur 3. Antalet annoterade bilder som modellen har tränats på. Phosphorescent sea pen = *P. phosphorea* (74 bilder), slender sea pen = *V. mirabilis* (54 bilder).

Analys av skillnader.


För att få ett mått på skillnaden inom manuell övervakning av sjöpennor och mellan manuell och maskinbaserad övervakning analyserades fem filmer av modellen som redan hade manuellt analyserats två gånger oberoende av varandra. Antalet observerade individer av *P. phosphorea* och *V. mirabilis* summerades och jämfördes sedan mellan analyserna analyserna.

Resultat

Analys av trålgrad.

Sammanlagt analyserades 93 prover genom att räkna antal individer i varje trålgrad (figur 4). Ytligare 204 prover användes för att få data på antalet sjöpennor i otrålade prover. För *P. phosphorea* var medelvärdet 17 individer vid trålgrad 0 (T0), 6 individer vid trålgrad 1 (T1), 7 individer vid trålgrad 2 (T2) och 4 individer vid trålgrad 3 (T3). T-tester gjordes och visade att det bara fanns signifikanta skillnader mellan T0 och alla andra trålgrader.

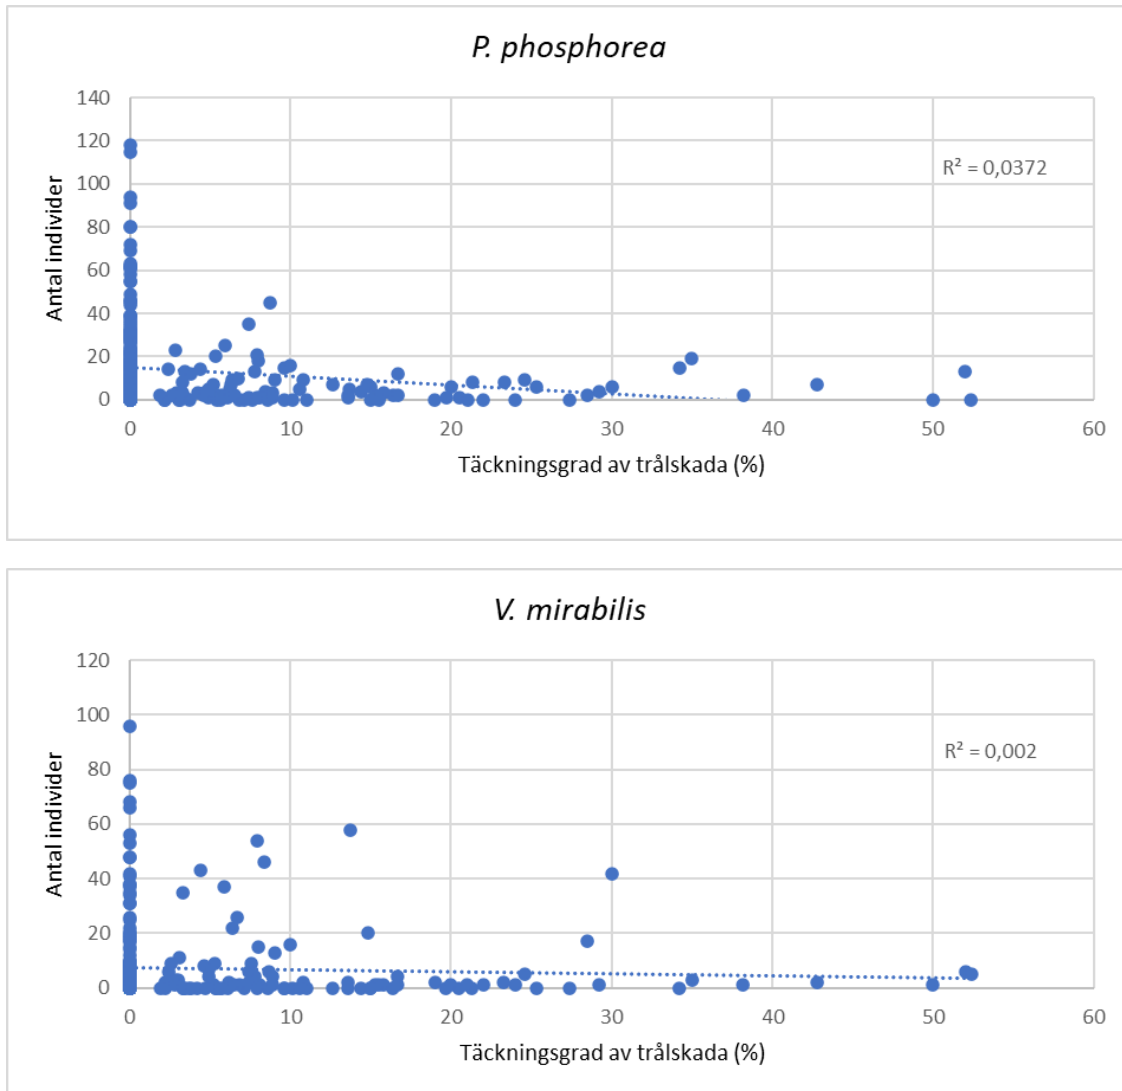
För *V. mirabilis* var medelvärdet 7 individer vid T0, 6 individer vid T1, 8 individer vid T2 och 2 individer vid T3. Signifikanta skillnader fanns endast mellan T3 och alla andra trålgrader.



Figur 4. Visar medelvärdet av antalet individer för de två arterna i varje trålgrad. T0 = trålgrad 0, T1 = trålgrad 1, T2 = trålgrad 2 och T3 = trålgrad 3. Felstaplarna visar standardfel, klammrarna visar mellan vilka trålgrader som signifikant skillnad testas och stjärnorna representerar om det finns en signifikant skillnad. Färgen på stjärnan visar vilken art den representerar. Antalet prover = n.

Analys av trålad yta.


Figur 5 visar varje videoprov med antalet sjöpennor och hur stor del som var visuellt trålskadad. R^2 representerar hur väl dessa två korrelerar där 1 är den starkaste korrelationen och 0 är igen korrelation.



Figur 5. Korrelationen mellan antal sjöpennor och hur stor del av videoproven som var visuellt trålskadad. Varje punkt representerar ett videoprov och R^2 -värdet visar hur stark korrelationen är med maxvärde på 1,0

Analys av modellen.

”Precision curve” (figur 6) visar modellens förmåga att upptäcka sjöpenor och skilja dessa från falska positiva (FP). Desto högre precision desto fler sjöpenor och färre FP ingår i observationer. ”Recall curve” visar däremot modellens förmåga att inte missa observationer, det vill säga undviker falska negativa (FN). Desto högre recall desto fler objekt har upptäckts av modellen. Varje observation har ett konfidensvärde (mellan 0–1) som beskriver sannolikheten att observationen är sann, det vill säga hur säker modellen är på att det är en sjöpena. Analysen av modellens prestanda (figur 6) visar att under låga konfidensvärden har modellen för många FP (det menas med att många objekt tolkas som sjöpenor), medan under höga konfidensvärden har modellen för många FN (många sjöpenor som inte känns igen). Det optimala konfidensvärdet är den sammanlagda minsta antalet FP och FN och den ligger kring en konfidens på 0,4.



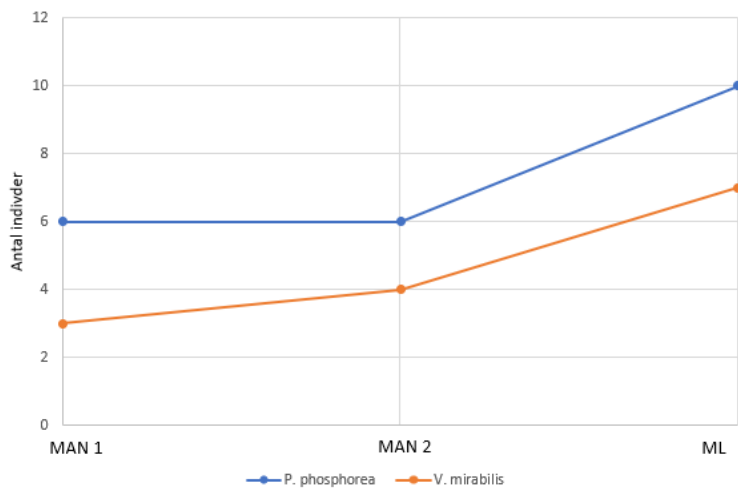
Figur 6.” Precision curve” till vänster och “Recall curve” till höger.

Konfidensvärde	True positive (TP)	False positive (FP)	False negative (FN)	Precision	Recall
0,25	20	0	3	0,7	0,67
0,5	14	0	5	0,81	0,55
0,75	4	0	13	0,75	0,1

Figur 7. TP, FP, FN, precision och recall vid olika konfidensvärden för modellen.

Analys av skillnader.

Skillnaden inom manuell övervakning av sjöpenner och maskinbaserad övervakning på 5 filmer (figur 8). En helt vågrät kurva visar på att det inte finns någon skillnad. Desto mer lutning kurvan har desto mer skillnad är det i mellan två analyser.



Figur 8. Skillnaden i mellan tre olika analyser, manuell 1 (MAN 1), manuell 2 (MAN 2) och ML-modellen. Varje punkt representerar antalet sjöpenner i de 5 filmer som analyserades.

Diskussion

Trålgrad.

Resultaten visar att trålskador har en negativ påverkan på antalet sjöpennor (figur 4) vilket stödjer Emanuelsson m.fl. (2021) och Sköld m.fl. (2021) rapport om att det är färre sjöpennor där det trålas. Det finns en signifikant skillnad för båda arterna mellan T0 och T3 vilket visar på att de påverkas negativt av hård trålning. Sedan varierar det, *P. phosphorea* verkar vara känsligare för trålning än vad *V. mirabilis* är. Arten tappar ett medelvärde på 17–7 mellan T0-T1 för att sedan gå ner till 4 vid T3. Det fanns ingen signifikant skillnad mellan de olika trålgraderna förutom mellan T0 och resterande för *P. phosphorea*. *V. mirabilis* har däremot bara signifikanta skillnader när man jämför trålgrader med T3. Kruskal-Wallis testet visade att för *P. phosphorea* att det finns en signifikant skillnad mellan dess medianer, vilket betyder att antalet sjöpennor i varje trålgrad inte kan ha uppstått av slumpen. För *V. mirabilis* fanns det ingen signifikant skillnad mellan dess olika medianer, därför kan antalet sjöpennor i varje trålgrad ha uppstått av slump. Sammanfattningsvis indikerar resultaten på att *P. phosphorea* är mer känslig för trålning än vad *V. mirabilis*, och att *P. phosphorea* verkar påverkas mest av lätt trålning medan *V. mirabilis* påverkas vid hårdare trålning.

Båda arter har förmågan att dra sig ner i sedimentet, *P. phosphorea* kan bara dra sig ner delvis medan *V. mirabilis* kan göra det fullständigt (Hughes, 1998). Detta kan göra arten mer resistent vid lägre trålgrader. Andra faktorer som kan ha en påverkan är arternas tillväxt och reproduktionsstrategi, beroende på om arten har en snabb tillväxt och när den blir könsmogen kommer påverka hur känslig arten är för störning av miljön så som när en trål drar förbi. Fortsatt övervakning av sjöpennors abundans och utbredning i Kattegatt är viktigt då dom påverkas negativt av trålning och för att OSPAR klassar habitatet som hotade arter och habitat (OSPAR, 2008).

Trålad yta.

Resultaten visar är att det inte finns en tydlig korrelation mellan antalet sjöpenor och trålad yta (figur 5). En förklaring är att det finns andra faktorer som orsakar frånvaron av sjöpenor än trålning. Grafen ser ut som att det verkar finnas en korrelation mellan trålad yta maximala antalet sjöpenor, men eftersom det inte finns kan det vara en brist i metoden. På grund av att sjöpenor mycket sällan har observerats i trålspåren, kamerans vinkel och att visuella trålskador kan passera på kort tid så får man en dålig skattning på hur dessa två står i relation till varandra. Metoden är därför inte lämplig för att uppskatta trålad yta. En förbättring hade varit att ha två kameror bredvid varandra vilket hade gett en ett bredare synfält och på så sett fått ett bättre mått på trålad yta.

En annan metod hade varit att även ha en kamera som vinklas rakt mot botten för att på så sätt få ett större synfält. Detta kan göra det lättare att mäta trålskador och trålad yta men problem uppstår så fort sikten är dålig. För att kunna se ett så stort område och där igenom få den bästa möjliga skattningen måste kameran vara en bit över botten, när sikten blir försämrad krävs det att kameran sänks närmre tills botten är synlig vilket gör att det kan bli svårt att få komparabla data.

Mest optimala hade varit att kombinera videodata med flerstråligt ekolod (MBES) och/eller sidoseende ekolod (SSS). Videodatan ger ett bra mått på antalet sjöpenor medan MBES/SSS ger en detaljerad bild av havsbotten där trålskador är synliga (Newton & Stefanon, 1975).

Maskinbaserade artobservationer.

Modellens prestation på testdata visade att den har ett optimalt konfidensvärde på 0,4. Vid detta värde är ”precision curve” och ”recall curve” båda vid ett högt värde (figur 6). När 0,4 passeras börjar precisionen att öka och recall att sjuka vilket betyder att den missar sjöpennor som finns i bilderna. När konfidensvärdet är 0,75 ligger recall på 0,1 och precisionen på 0,75 vilket ger många FN och få TP (figur 7). Sammanfattningsvis presterar modellen bra, men kan optimeras. På grund av att träningsdatasetet inte var så stort (128 bilder) fanns FP/FN kvar och det skulle vara mycket lätt att öka träningsdatasetet fem gånger och därmed minska antalet FP/FN. Ett sätt att förbättra modellen och få bort FP/FN är att öka diversiteten på träningsdata. I nuläget har modellen bara tränats på att känna igen sjöpennor och inte på att se skillnad mellan sjöpennor och liknade objekt. Genom att inkludera bilder med likande objekt och artefakter så som till exempel stenar, laserstråle och andra organismer kommer modellen att lära sig se skillnad på liknade objekt och sjöpennor.

Skillnaden mellan modellen och manuella resultat visade att modellen observerar fler sjöpennor en vad som egentligen finns. De manuella resultaten gav 6 *P. phosphorea* och 3–4 *V. mirabilis* medan modellen observera 10 och 7 (figur 8). Dessa skillnader är sämre än inom manuella övervakning men eftersom detta endast var på fem filmer och att träningen kan förbättras enligt ovan så är det något som kan förbättras. Dessa skillnader kan även kompenseras för när den används över så stora områden att manuella artobservationer hade varit omöjligt.

Denna metod har potentialen att underlätta och användas när storskalig miljöövervakning behövs. Den ger möjligheten att mer regelbundet kunna övervaka havsbotten och följa upp förvaltningsåtgärder så som fiskeförbudszoner effektivare. Modeller kan även utvecklas för andra objekt så som hotade och rödlistade arter eller på indikatorarter som signalerar en god miljöstatus.

Slutsats

Syftet är att använda både manuella och maskininlärning (ML)-baserade artobservationer för att undersöka samband mellan förekomst av sjöpennor trålskador på mjukbottnar i Kattegatt. Detta genom att analysera dropvideodata från Kattegatt för hur arterna *P. phosphorea* och *V. mirabilis* har påverkats av trålning samt att träna och testa en maskininlärningsmodell utifrån samma dataset.

Resultaten visar att det finns en trålpåverkan utifrån visuella trålskador. *P. phosphorea* visade sig vara känslig för lägre grader av trålpåverkan än *V. mirabilis* men båda arterna uppvisade en förlust av individer ju högre trålgraden blev. Därför vill jag säga att användningen av ML är något att överväga för att övervaka abundans och utbredning av dessa djur i framtiden.

ML-modellens presterade bra på testdata men hade fortfarande FP/FN kvar vilka man kan få bort igenom att träna den på ett större träningsdataset och inkludera mer diversitet i bilderna den tränas på för att lära den se skillnad på liknande objekt och sjöpennor.

Skillnaden inom manuell övervakning av sjöpennor låg vid ca 35 % och mellan manuell och maskinbaserad övervakning låg det vid ca 40 % på fem analyserade filmer. Denna skillnad är inte stor men kan kompenseras för vid användning över stora marina områden och förbättras igenom mer träning för modellen.

Referenslista

Anton, V., Germishuys., Bergström, P., Lindegarth, M., & Obst, M. (2021). An open-source, citizen science and machine learning approach to analyse subsea movies. *Biodiversity Data Journal*, 9. <https://doi.org/10.3897/BDJ.9.e60548>

Ditria, E.M., Sievers, M., Lopez-Marcano, S., Jinks, E. L., & Connolly, R. M. (2020). Deep learning for automated analysis of fish abundance: the benefits of training across multiple habitats. *Environmental Monitoring and Assessment*, 192, 698.

<https://doi.org/10.1007/s10661-020-08653-z>

Emanuelssons, A., Werner, K., Ulltin, F. (2021). *Videoundersökning och naturtypskartering i Norra Halland 2020–2021*. Länsstyrelsen Halland.

Havsmiljöinstitutet. (2022). *Kattegatt*. <https://www.sverigesvattenmiljo.se/undersoka-vattenmiljo/kattegatt>

Hughes, D.J. (1998). *Sea pens and burrowing megafauna (volume III). An overview of dynamic and sensitivity characteristics for conservation management of marine SACs*. Scottish Association for Marine Science (UK Marine SACs Project).

http://ukmpa.marinebiodiversity.org/uk_sacs/pdfs/seapens.pdf

Lopez-Vazquez, V., Lopez-Guede, JM., Marini, S., Fanelli, E., Johnsen, E., & Aguzzi, J. (2020). Video Image Enhancement and Machine Learning Pipeline for Underwater Animal Detection and Classification at Cabled Observatories. *Sensors*, 20(3), 726.

<https://doi.org/10.3390/s20030726>

Miatta, M., & Snelgrove, P.V.R. (2022). Sea pens as indicators of macrofaunal communities in deep-sea sediments: Evidence from the Laurentian Channel Marine Protected Area. *Deep sea research part 1: Oceanographic Research Papers*, 182.

<https://doi.org/10.1016/j.dsr.2022.103702>

Murillo, F.J., MacDonald, B.W., Kenchington, E., Campana, S.E., B. SainteMarie, B., & Sacau, M. (2018). Morphometry and growth of sea pen species from dense habitats in the Gulf of St. Lawrence, eastern Canada, *Marine Biology Research*, 14(4), 366-382.

<https://doi.org/10.1080/17451000.2017.1417604>

Newto, R.S., Stefanon, A. (1975). Application of side-scan sonar in marine biology. *Marine Biology*, 31, 287-291. <https://doi.org/10.1007/BF00387155>

OSPAR. (2008). *Case Reports for the OSPAR List of Threatened and/or Declining Species and Habitats*.

https://www.ospar.org/site/assets/files/44271/seapen_burrowing_megafauna.pdf

Sköld, M., Jonsson, P., Bartolino, V., Bastardie, F., Blomqvist, M., Göransson, P., Agrenius, S., & Nilsson, H C. (2016). *Bottentrålningens effekter på mjukbottenfaunan i Kattegatt. I: Bergström m fl 2016. Ekologiska effekter av fiskefria områden i Sveriges kust- och havsområden*. (Aqua reports 2016:20). Sveriges Lantbruksuniversitet (SLU).

<https://www.slu.se/globalassets/ew/org/inst/aqua/externwebb/radgivning/fiskefria-omraden/delrapporter/bottentrålningens-effekter-pa-mjukbottenfaunan-i-kattegatt--delrapport-4.pdf>

Sköld, M., Ren, E., Jonsson, P., Wernbo, A., Wikström, A., & Wennhage, H. (2021). *Tätheten av sjöpennor i skyddade och bottentrålade områden i Skagerrak och Kattegatt – Förslag till övervakningsprogram för epifaunans status*. (Aqua reports 2021:14). Sveriges lantbruksuniversitet (SLU), Institutionen för akvatiska resurser.

https://pub.epsilon.slu.se/25551/3/sk%C3%B6ld_m_et_al_211004.pdf

The IUCN Red List of Anthozoans in The Mediterranean. (2016).

https://www.iucn.org/downloads/anzothoa_fact_sheet_final_baja.pdf