

**M A S A R Y K O V A
U N I V E R Z I T A**

PŘÍRODOVĚDECKÁ FAKULTA

Identifikace jedinců mořských želv na Šrí Lance

Diplomová práce

SARAH MAYA ŽIDEK

Vedoucí práce: Mgr. Marie Zhai, Ph.D.

Ústav botaniky a zoologie
Program Ochrana přírody – Zoologie

Brno 2025



Bibliografický záznam

Autor:	SARAH MAYA ŽIDEK Přírodovědecká fakulta Masarykova univerzita Ústav botaniky a zoologie
Název práce:	Identifikace jedinců mořských želv na Šrí Lance
Studijní program:	Ochrana přírody – Zoologie
Vedoucí práce:	Mgr. Marie Zhai, Ph.D.
Rok:	2025
Počet stran:	120
Klíčová slova:	mořské želvy; degradace mořských ekosystémů; lov karet; rozpoznávání jedinců; ochrana přírody; fotoidentifikace; Šrí Lanka; neuronové sítě; MegaDescriptor

Bibliographic record

Author: SARAH MAYA ŽIDEK
Faculty of Science
Masaryk University
Department of Botany and Zoology

Title of Thesis: Identification of individuals of sea turtles in Sri Lanka

Degree Programme: Nature Conservation – Zoology

Supervisor: Mgr. Marie Zhai, Ph.D.

Year: 2025

Number of Pages: 120

Keywords: sea turtles; degradation of marine ecosystems; nature conservation; identification of individuals; photo-identification; Sri Lanka; neural networks; MegaDescriptor

Abstrakt

Z celkového počtu sedmi druhů mořských želv jich pět každoročně připlouvá na pláže Šrí Lanky v počtech několika stovek jedinců. Čelí zde, stejně jako na mnohých dalších místech světa, vážným hrozbám jako jsou lov, sběr vajec a ničení přirozených habitatů. Legislativa chránící želvy před lovem není vymáhána, takže lov na mnohých místech pokračuje. Mořské želvy mají přitom nenahraditelný pozitivní vliv na mnohé mořské ekosystémy, na nichž jsou závislí především nejchudší lidé, a to nejen na Šrí Lance. Součástí efektivní ochrany populací mořských želv je monitoring založený na neinvazivní identifikaci jedinců. Tato práce se zaměřuje na možnosti využití neuronových sítí pro účely identifikace jedinců mořských želv na Šrí Lance na základě fotografického záznamu.

V této práci jsou shrnuty poznatky o druzích mořských želv, o jejich ohrožení a způsobech ochrany, a to jak v globálním měřítku, tak se zaměřením na Šrí Lanku. Dále jsou představeny modely neuronových sítí a jejich fungování. Hlavním cílem pak bylo hodnocení úspěšnosti modelu neuronové sítě MegaDescriptor při identifikaci jedinců na základě fotografií pravé a levé strany hlavy. Data byla sbírána mnou a rančery šrílanských záchranných stanic, a to v noci na plážích při kladení a během dne buď v soukromých záchranných stanicích s líhněmi nebo ve vodě při šnorchlování. Úspěšnost identifikace byla hodnocena při různém poměru velikosti databáze a počtu identifikovaných fotografií.

Celkem byly pozorovány čtyři druhy mořských želv, nejčastěji kareta obrovská *Chelonia mydas* a ojedíněle kareta zelenavá *Lepidochelys olivacea*, kareta obecná *Caretta caretta* a kareta pravá *Eretmochelys imbricata*. Model vykazoval jednoznačně vyšší úspěšnost (až 90 %) při identifikaci jedinců z denních fotografií v porovnání s nočními, což nejspíš souvisí s natrénováním modelu a lepší kvalitou fotek. Nejméně úspěšná (do 19 %) byla identifikace jedinců na základě opačných stran hlavy. Nepodobnost stran je pravděpodobně vlastností populace a nemá dosud jasnou příčinu. Vhodným pokračováním by bylo natrénovat model na noční fotografie a dále zvětšovat databázi fotografiemi s vysokou kvalitou.

Abstract

Out of the total of seven species of living sea turtles, five come to the beaches of Sri Lanka every year in the numbers of several hundreds of individuals. Here, just as in many other places in the world, they face threats such as hunting, egg poaching and destruction of habitats. Legislation meant to protect them from being hunted is not enforced, so the hunting continues in many places. Sea turtles have an irreplaceable positive impact on many marine ecosystems, on which the poorest people depend, not only in Sri Lanka. An effective protection of sea turtles requires monitoring using non-invasive identification of individuals. This thesis focuses on using neural networks for the purpose of identifying sea turtle individuals in Sri Lanka using photos.

I summarized current knowledge on sea turtles, their threats and methods of conservation, both on a global scale and with a focus on Sri Lanka. Models of neural networks and their functioning were described. The main goal was to assess the accuracy of the neural network model MegaDescriptor in identifying individuals based on photographs of sides of the head. Data was collected by me and ranchers from Sri Lankan rescue stations, at night on beaches when egg laying, and during the day either in rescue stations with hatcheries or in the sea while snorkeling. The accuracy of identification was evaluated at different ratios of database size and number of identified photos.

Four species of sea turtles were observed, most often the green turtle *Chelonia mydas*, and occasionally the Olive Ridley *Lepidochelys olivacea*, the loggerhead *Caretta caretta* and the hawksbill *Eretmochelys imbricata*. The model showed a higher accuracies (up to 90% of correct identification) when identifying daytime photos compared to night photos, which was probably related to the training of the model and a better quality of the daytime photos. The least successful (up to 19%) was the identification of individuals based on the opposite sides of the head. The differences between the sides within an individual is probably characteristic for the population, and lacks clear explanation so far. It is advisable to train the model using night photos and further expand the database with new high-quality photos.

ZADÁNÍ
DIPLOMOVÉ PRÁCE

Akademický rok: 2024/2025

Ústav:	Ústav botaniky a zoologie
Studentka:	Bc. Sarah Maya Židek
Program:	Ochrana přírody
Specializace:	Ochrana přírody - zoologie

Ředitel ústavu PřF MU Vám ve smyslu Studijního a zkušebního řádu MU určuje diplomovou práci s názvem:

Název práce:	Identifikace jedinců mořských želv na Šrí Lance
Název práce anglicky:	Identification of individuals of sea turtles in Sri Lanka
Jazyk práce:	čeština

Oficiální zadání:

Mořské želvy jsou důležitým článkem v koloběhu živin mezi souší a mořem a podílí se na udržování zdraví korálových útesů a mořských luk. Avšak zejména kvůli ničení jejich habitatů, domorodému lovu a incidentům v důsledku intenzivního rybolovu, výrazně narůstá potřeba jejich ochrany.

Jedním z možných způsobů monitoringu mořských želv je fotoidentifikace jedinců. Na rozdíl od značení ploutví a připevňování vysílaček na krunýře se jedná o neinvazivní a cenově dostupnou metodu, při které může s ochranáři spolupracovat i široká veřejnost. Nevýhodou však zůstává, že manuální vyhodnocení fotodokumentace je pracné a zcela závislé na zkušenosti pozorovatele. V této situaci je výhodné zapojit do identifikace možnosti strojového učení ve formě umělých neuronových sítí, avšak tyto postupy jsou teprve ve vývoji a nejsou dosud příliš rozšířené.

Z celkem sedmi druhů mořských želv jich pět sezónně hnízdí na plážích Srí Lanky. Ačkoli zde na některých místech probíhá aktivní snaha o ochranu lůhnišť, identifikaci jedinců se zde dosud nikdo nevěnoval. Tato práce by měla sloužit k prozkoumání využití neuronových sítí pro identifikaci jedinců některé z místních populací karet (např. k. obrovská *Chelonia mydas*, k. obecná *Caretta caretta*, k. pravá *Eretmochelys imbricata*) za účelem jejich efektivnějšího monitoringu.

Cílem této práce je:

- 1) Rešerše obsahující úvod do a) biologie, ohrožení a ochrany mořských želv, b) rozpoznávání jedinců pro účely ochrany druhů, c) strojového učení, se zaměřením na neuronové sítě;
 - 2) Vytvoření databáze fotografií hlav karet (z pravé a levé strany od každého jedince), vlastnoručně pořízenými fotografiemi a fotografiemi od pracovníků z některých záchranných stanic;
 - 3) Příprava dat zahrnující identifikaci jedince, denní dobu a soubor metadat;
 - 4) Aplikace neuronové sítě MegaDescriptor pro rozpoznání jedinců (případně skupin menšího počtu jedinců) a vyhodnocení její funkčnosti v závislosti na složitosti;
 - 5) Vyhodnocení spolehlivosti identifikace při využití znaků z pravé vs. levé strany;
 - 6) V případě shromáždění dostatečného materiálu karety obecné srovnání výsledků s populací z ostrova Zakynthos (s využitím on-line dostupné databáze) a vytvoření binárního stromu, který predikuje příslušnost jedince k populaci.
- Literatura: - Schofield G., Katselidis K. A., Dimopoulos P. & Pantis J. D. 2008: Investigating the viability of photo-identification as an objective tool to study endangered sea turtle populations. *Journal of Experimental Marine Biology and Ecology* 360: 103 - 108. - Rajakaruna R. S., Dissanayake N. J., Ekanayake L. & Ranawana K. B. 2009: Sea turtle conservation in Sri Lanka: assessment of knowledge, attitude and prevalence of consumptive use of turtle products among coastal communities. *Indian Ocean Turtle Newsletter* 10: 1 - 13. - Carpentier A. S., Jean C., Barret M., Chassagneux A. & Ciccione S. 2016: Stability of facial scale patterns on green sea turtles *Chelonia mydas* over time: A validation for the use of a photo-identification method. *Journal of Experimental Marine Biology and Ecology* 476: 15 - 21. Další literatura dle doporučení vedoucího a konzultantů. Vedoucí bakalářské práce: Mgr. Marie Zhai, Ph.D. Konzultanti: Mgr. Hana Svobodová Mgr. Lukáš Adam, Ph.D.

Vedoucí práce:	Mgr. Marie Zhai, Ph.D.
-----------------------	------------------------

Konzultant:	Mgr. Lukáš Adam, Ph.D.
--------------------	------------------------

Datum zadání práce:	31. 10. 2023
----------------------------	--------------

V Brně dne:	25. 4. 2025
--------------------	-------------

Zadání bylo schváleno prostřednictvím IS MU.

Bc. Sarah Maya Židek, 7. 4. 2025

Mgr. Marie Zhai, Ph.D., 7. 4. 2025

Mgr. Iveta Hodová, Ph.D., 7. 4. 2025

Čestné prohlášení

Prohlašuji, že jsem svoji diplomovou práci vypracovala samostatně pod vedením vedoucího práce s využitím informačních zdrojů, které jsou v práci citovány.

Poděkování

Především bych chtěla poděkovat svému konzultantovi Mgr. Lukášovi Adamovi, Ph.D. za jeho trpělivost a nedocenitelnou pomoc ve válce s neuronovými sítěmi a skriptem v Pythonu. Můj velký dík patří mé vedoucí Mgr. Majce Zhai, Ph.D. za její dozor a mnohé rady a mé konzultantce Mgr. Hance V. Svobodové za její pomoc, že mě nasměrovala na správná místa a předala důležité kontakty na Šrí Lance.

Obrovské poděkování patří i Vojtovi, který mi věnoval mnohé hodiny a z nefunkčních řádků kódu kouzlil funkční. Děkuji Ing. Channu Suraweerovi, který mi umožnil vstup do záchranných stanic a mnohým rančerům z Rekawy, že se mnou běhali od želvy k želvě. Velký dík patří Mart'asovi! Také musím poděkovat svému otci, který mi byl mecenášem, Bohu, zbytku rodiny a mnohým dalším přátelům za veškerou podporu.

And of course this thesis would never come to exist without my sweet srilankan friend Dulvin. Without you I wouldn't find my way from Colombo airport to my accomodation and would be getting robbed at every turn.

So thanks for never leaving your lame white friend~

Obsah

1. Úvod	21
2. Cíle práce	22
3. Mořské želvy	23
3.1 Charakteristika	23
3.2 Role želv v mořských ekosystémech.....	28
3.3 Ohrožení mořských želv.....	33
4. Ochrana a její metody	37
4.1 Monitoring populací mořských želv	40
5. Mořské želvy Šrí Lanky	44
5.1 Historie poznání želv na Šrí Lance	44
5.1.1 Lov.....	44
5.1.2 První podoby ochrany želv na Šrí Lance	46
5.2 Legislativa chránící mořské želvy	47
5.3 Současná ohrožení mořských želv, další způsoby jejich ochrany a jejich nedostatky	48
5.4 Možná řešení problémů v ochraně želv na Šrí Lance.....	54
6. Základy strojového učení	58
6.1 Plně propojené sítě.....	59
6.2 Konvoluční sítě	62
6.3 Učení neuronových sítí	66
6.4 Ztrátovost a funkce CrossEntropyLoss.....	68
6.5 Vytváření modelu neuronové sítě v programu PyTorch.....	68
6.6 Inference na nových datech a <i>image retrieval</i>	72
7. Metodika	75
7.1 Popis území	75
7.1.1 Záchranné stanice ve městě Koggala.....	76
7.1.2 Turtle Point Batigama.....	76
7.1.3 Wildlife Turtle Project Kapuhenwalla a Turtle Watch Rekawa.....	76

7.2	Sběr dat	77
7.3	Zpracování dat	78
7.4	Analýza data setu.....	79
8.	Výsledky	82
8.1	Počty fotografií, jedinců a druhů.....	82
8.2	Porovnávání úspěšnosti modelu MegaDescriptor	85
9.	Diskuze	91
10.	Závěr	95
	Použité zdroje	96
Příloha A	Výpis úspěšností modelu při identifikaci jedinců ze všech fotografií	114
Příloha B	Výpis úspěšností modelu při identifikaci jedinců z fotografií z jednotlivých stran hlavy	115
1.	Levá strana	115
2.	Pravá strana	115
Příloha C	Výpis úspěšností modelu při identifikaci jedinců z fotografií z různých částí dne	117
1.	Noční fotografie.....	117
2.	Denní fotografie	117

1. Úvod

Tato práce se věnuje identifikaci jedinců mořských želv na Šrí Lance pomocí modelu neuronové sítě MegaDescriptor. Mořské želvy obývají moře a oceány celého světa a hnízdí na tropických plážích. Jejich role v mořských ekosystémech, jako jsou korálové útesy či mořské louky, je nezastupitelná (Lutz *et al.* 2003), ovšem čelí dnes mnoha antropogenním ohrožením a historicky byly na mnoha místech intenzivně loveny jako zdroj obživy (Poonian *et al.* 2016, Mazaris *et al.* 2017). Posledních několik dekád postupně vzrůstala snaha o jejich ochranu s různými výsledky (Mazaris *et al.* 2017). Dnes jsou mořské želvy chráněny mezinárodní i regionální legislativou, ale na mnohých místech není vymáhána a nadále pokračují nelegální praktiky. Jednou z takových oblastí je i Šrí Lanka, kde jsou želvy i přes mezinárodní i národní zákony loveny zdejšími obyvateli pro obživu a jejich vejce jsou konzumována (Kapurusinghe & Saman 2001, Jayathilaka *et al.* 2017). Důvodem výběru tohoto státu jako místa studie bylo působení organizace Chráníme mořské želvy z.s., kterou založila moje konzultantka, Mgr. Hanka V. Svobodová.

Pro monitoring populací mořských želv se používá mnoho metod, jednou ze stále častěji používaných je metoda fotoidentifikace, kdy jsou jedinci poznáváni z fotografií (Carpentier *et al.* 2016). Tato metoda je méně invazivní a má různý stupeň automatizace, kdy modely neuronových sítí představují plně automatizované způsoby (Adam *et al.* v tisku). Úspěšnost modelu při identifikaci je ovlivněna mnoha způsoby, a může se tedy značně lišit v závislosti na způsobu provedení analýzy (Goodfellow *et al.* 2016). Nicméně představuje cenově dostupnou a spolehlivou metodu výzkumu želvích populací, tolik potřebnou pro jejich ochranu (Adam *et al.* v tisku).

2. Cíle práce

Cíly této práce jsou:

- sepsat rešerši týkající se biologie, ohrožení a ochrany mořských želv, dále rozpoznávání jedinců pro účely ochrany a strojového učení, se zaměřením na neuronové sítě;
- vytvořit data set fotografií hlav karet z obou stran hlavy (z vlastních fotografií a fotografií od pracovníků z některých záchranných stanic);
- příprava dat zahrnující identifikaci jedince, denní dobu a soubor metadat;
- použití modelu neuronové sítě MegaDescriptor k rozpoznání jedinců a vyhodnocení jeho úspěšnosti při různých rozděleních data setu;
- vyhodnotit úspěšnost identifikace jedinců modelem při využití znaků z pravé i levé strany a
- v případě shromáždění dostatečného fotografií karety obecné *C. caretta* srovnání výsledků s populací z ostrova Zakynthos (s využitím on-line dostupné databáze) a vytvoření binárního stromu, který predikuje příslušnost jedince k populaci.

3. Mořské želvy

Mořské želvy jsou velcí živočichové představující důležitý článek mořských ekosystémů, kteří tráví drtivou většinu života v mořích a oceánech a na souš se vrací pouze pro zahníždění (Amorim 2025). Mají nezastupitelnou roli při udržování zdraví ubývajících korálových útesů a mořských luk, na jejichž ekosystémové služby spoléhá mnoho milionů lidí (Selig *et al.* 2019). Jsou též důležité pro udržování stavů populací mnohých bezobratlých (např. medúzy, salpy, krabi, mlži) (Frick *et al.* 2009, NOAA Fisheries 2025a-f).

V současnosti čelí mořské želvy značnému antropogennímu tlaku, přitom za sebou již mají staletí intenzivního lovu kvůli želvovině, masu či vejcím (Mancini *et al.* 2011). Vztah člověk k želvám není pouze vykořisťující a nacházíme tisíciletí staré doklady zobrazování želv jako symbolů či sošek božstev (Frazier 2005). Již několik desetiletí stoupá povědomí o jejich ohroženosti i vůle člověka tyto živočichy chránit, a to dokonce s pozitivními výsledky (Mazaris *et al.* 2017).

3.1 Charakteristika

Všechny dnešní žijící druhy mořských želv spadají do jednoho taxonu (nadčeledi) Chelonioida, do které patří čeledi Cheloniidae (karetovití) a Dermochelyidae (kožatkovití). Do první čeledi patří všechny druhy mořských želv s tvrdým krunýřem. Druhá čeleď je monotypická s jediným současným zástupcem s měkkým krunýřem. Mořské želvy tráví naprostou většinu života v mořích a oceánech, na souš se vrací pouze samice pro naklazení vajec, samci zůstávají celý život ve vodě (Amorim 2025).

Jde obecně o dlouhověké živočichy skvěle přizpůsobené k životu ve vodě, například tvarem těla, prodlouženými ploutvemi i stavbou cévní soustavy. Při potápění jsou mořské želvy schopné změnit proudění krve v cévách tak, že vynechávají plicní oběh. Krev je při potopu tedy hnána do jiných vnitřních orgánů, což může být prospěšné pro trávení (Kardong 2006). Pod vodou se mořské želvy krmí, páří i spí. Významnou adaptací na život ve slané vodě jsou

i dobře vyvinuté slzné žlázy, kterými vylučují přebytečnou sůl z těla, a tak se vyhýbají dehydrataci a udržují homeostázu (Yoshida *et al.* 2022).

První fosilní záznamy předků mořských želv nacházíme již z křídý. V současnosti je nejstarším známou fosilií *Desmatochelys padillai* popsáný z jihoamerické lokality Paja v Kolumbii. Jeho stáří se odhaduje na 120 miliónů let, což odpovídá spodní křídě (Cadena & Parham 2015). Dalšími významnými objevy v paleontologii mořských želv jsou donedávna nejstarší *Santanachelys gaffneyi* Hirayama, 1998 z Brazílie (Cadena & Parham 2015) a obrovský *Archelon ischyros* Wieland, 1896 z americké Jižní Dakoty (Wieland 1896).

Dnes obývá světové oceány celkem sedm druhů mořských želv. V čeledi Dermochelyidae jde o kožatku velkou *Dermochelys coriacea* (Vandelli, 1761). V čeledi Cheloniidae jsou to:

- kareta obrovská *Chelonia mydas* (Linnaeus, 1758),
- kareta obecná *Caretta caretta* (Linnaeus, 1758),
- kareta zelenavá *Lepidochelys olivacea* (Eschscholtz, 1829),
- kareta menší *Lepidochelys kempii* (Garman, 1880),
- kareta pravá *Eretmochelys imbricata* (Linnaeus, 1766) a
- kareta plochá *Natator depressus* (Garman, 1880).

Nejzajímavějším a nejodlišnějším druhem mořské želvy je bezpochyby kožatka velká. Jde o největší žijící druh mořské želvy (340-454 kg, 150-180 cm) téměř černé barvy s narůžovělou ventrální stranou. Má kožovitý krunýř se sedmi podélnými hřebeny, kterému chybí kostěné štítky. Místo nich tvoří jejich krunýř do sebe zapadající dermální kosti. Dospělé kožatky dokáží migrovat na obrovské vzdálenosti až 15 tisíc kilometrů ročně a jsou rovněž schopny potápět se do více než kilometrové hloubky. K tomu mají speciálně uzpůsobené ploutve; přední jsou poměrem mnohem delší než u zbylých druhů želv a zadní mají pádlovitý tvar (NOAA Fisheries 2025a). Vyhledávají potravu v mírných a sub-polárních oblastech, ale hnízdí na plážích tropického podnebného pásma (Hirth & Ogren 1987, NOAA Fisheries 2025a). Živí se především organismy s měkkým tělem jako jsou medúzy a salpy, k čemuž mají uzpůsobené ostré čelisti a dozadu směřující hroty v hltanu (NOAA Fisheries 2025a). Jako jediná z mořských želv má schopnost udržet vyšší tělní teplotu oproti okolní vodě, což jí umožňuje rychlejší růst (Caracappa *et al.* 2017). Jejich věk dožití není přesně

znám, ale předpokládá se 50 a více let. V současnosti je na vedena v Příloze I. úmluvy CITES a na Červeném seznamu IUCN jako *zranitelná* (VU) s klesající početností (IUCN Red List 2025a).

Kareta obrovská je největší mořskou želvou s tvrdým krunýřem (113-180 kg, 91-121 cm). Ventrální strana tohoto druhu je mnohem světlejší než dorsální. Vyskytují se v subtropických a tropických vodách celého světa a též jde o migranty na dlouhé vzdálenosti, kteří za hnízděním putují stovky až tisíce kilometrů. Předpokládá se u nich dožití 70 let a více. Mladé želvy se ihned po vylíhnutí vrhají do moře a plavou na otevřený oceán, kde stráví několik let života. Po dosažení určité velikosti se vrací ke břehům, kde dosahují dospělosti. Pohlavně dospělé oplodněné samice vrací na rodné pláže, aby zde nakladly vejce. Jde o primárně herbivorní druh karety a požídané řasy zbarvují jejich tkáň dozelená (NOAA Fisheries 2025b). U havajské, australské, mexické a galapážské populace bylo pozorováno vyhřívání na souši a jde o jediný druh, u kterého bylo toto chování pozorováno (Whittow & Balazs 1982). V úmluvě CITES je vedena v Příloze I. a na Červeném seznamu IUCN jako *ohrožená* (EN) s klesající početností (IUCN Red List 2025b).

Karetu obecnou nejlépe vystihuje její anglické jméno *loggerhead turtle*. Jsou charakteristické svou velkou hlavou vzhledem k tělu a srdčitým tvarem krunýře. Velikostí se pohybují mezi 90-160 kg a 76-110 cm. Vyskytují se v oceánech celého světa, ovšem nejrozšířenější jsou v Atlantském a části Tichého oceánu, který dokáží překonat (okolo 12 tisíc kilometrů). Mladé želvy tráví prvních 7–15 let svého života na otevřeném oceánu, poté se vrací ke břehům. Pohlavně dospívají v asi 35 letech, hnízdí na rodných plážích a nejspíš se dožívají i nad 80 let. Oproti předchozímu druhu jsou karety obecné více masožravé a zaměřují se zejména na bentické korýše a měkkýše. (Casale *et al.* 2008, NOAA Fisheries 2025c). Na Červeném seznamu IUCN je vedena jako *zranitelná* (VU) s klesající početností (IUCN Red List 2025c) a v Příloze I. úmluvy CITES.

Druhové jméno karety zelenavé odráží charakteristickou olivovou barvu jejího srdčitého krunýře. Jde o jednu z nejmenších karet (maximum 45 kg, 60-76 cm), největší jedinci byli zaznamenáni u západního pobřeží Afriky. Na každé ploutvi mají karety zelenavé jeden až dva drápy. Pro tento a následující druh je charakteristické tzv. *arribada nesting*. Pojem *arribada* je původem ze španělštiny, znamená *příchod*, a vystihuje dokumentovaná hromadná

hnízdění karet zelenavých. Vyskytují se v tropických vodách po celém světě a dokáží se potápět až do 150m hloubek. Dospívají okolo 14. roku a dožívají se 30–50 let (NOAA Fisheries 2025d). V současnosti je na Červeném seznamu IUCN vedena jako *zranitelná* (VU) s klesající početností (IUCN Red List 2025d).


Kareta menší je vůbec nejmenší (32–45 kg, až 61 cm) mořskou želvou. Má srdčitý krunýř stejné délky i šířky a na zadních ploutvích mohou být dva drápy, zatímco na předních je vždy jen jeden. Vyskytuje v Mexickém zálivu a navazujícím severním pobřeží Spojených států amerických, ač existují záznamy o karetách menších poblíž Azor a Maroka. Dospívají okolo 13. roku života a dožívají se nejspíš okolo 30 let. Mladé želvy vyplouvají na otevřenou vodu a nechávají se unášet Golfským proudem. Stejně jako karety zelenavé podnikají masová hnízdění *arribada*. Vyhledávají shluky řasy *Sargassum* sp., které využívají jako úkryt a živí se v jejich blízkosti. Takto dorůstají během roku či dvou do velikosti asi 20 cm a migrují do mělkých vod Mexického zálivu, kde se živí korýši a uhynulými rybami odmítnutými rybáři (NOAA Fisheries 2025e). Na Červeném seznamu IUCN je vedena jako *kriticky ohrožená* (CR) s klesající početností (IUCN Red List 2025e) a v Příloze I. úmluvy CITES.

Kareta pravá je známá především pro svůj charakteristicky vzorovaný krunýř se zubatým okrajem a překrývajícími se štítky. Dalším typickým znakem je jejich prodloužený zobák, který jim dobře slouží při získávání potravy, jimiž jsou řasy, koráli, měkkýši, korýši, ostnokožci a zejména houbovci (Obura *et al.* 2010). Váhou spadají mezi 45–68 kg a délkou mezi 61–110 cm. Dokáží migrovat více než tisíc kilometrů při hledání potravy a obývají různé druhy habitatů, zejména pak korálové útesy v tropickém a subtropickém pásmu (Stampar *et al.* 2007). Mají velmi početné snůšky, mladé želvy stráví v otevřeném oceánu až pět let a vrací se do mělkých vod a estuárů. Dospívají mezi 20. a 35. rokem života, očekávaná doba dožití je pro tento druh až 60 let. Největší populace se v současné době nachází v okolí Austrálie a Šalamounových ostrovů (NOAA Fisheries 2025f). V úmluvě CITES je vedena v Příloze I. a na Červeném seznamu IUCN jako *kriticky ohrožená* (CR) s klesající početností (IUCN Red List 2025f).

Posledním druhem je kareta plochá. Jak napovídá název, má oproti předešlým druhům značně zploštělý krunýř a rovněž má oproti nim mnohem menší areál. Nemigruje, ale

zdržuje se ve vodách Austrálie a Papuy Nové Guiney do 60 m hloubky. Hnízdí na plážích Austrálie, jejich snůšky jsou nejmenší ze všech a rovněž mladé želvy zůstávají blíže pobřeží. Živí se primárně sumýši, medúzami a dalšími bezobratlými a ve vodě je terčem predace mořskými krokodýli a žraloky (Oceana 2025). Je jediným druhem uvedeným v CITES jako *taxon, u něhož chybí údaje* (DD) (IUCN Red List 2025g).

Jak bylo nastíněno, mezi jednotlivými druhy jsou odlišnosti ve tvaru krunýře. Konkrétně se liší horní karapax, a to především počtem štítků, kterými je tvořen (Cherepanov 2014). Druhy se od sebe odlišují uspořádáním těchto štítků a jedince lze tak snadno určit do druhu bez odchytu či manipulace, které jsou pro mořské želvy značně stresující (Adam *et al.* v tisku). Tuto metodu identifikace mohou značně ztížit až znemožnit velké nárosty řas a koryši, zejména svijonožci. Štítky karapaxu lze rozdělit až do šesti typů, nebo zjednodušeně pouze do čtyř. Nad krkem se nachází štítek *pre-centrální*, na něj navazují středem karapaxu se táhnoucí *centrální* štítky. Po obvodu krunýře nacházíme štítky *marginální* a mezi nimi a těmi centrálními se nachází štítky *laterální*. Níže (Obrázek 1) je obecný náčrt mořské želvy z informační tabule připravené šrílanským Oddělením ochrany volně žijících živočichů a planě rostoucích rostlin (Department of Wildlife Conservation, DWC) v záchranné stanici Kapuhenwalla s popsány jednotlivými štítky.



Obrázek 1: Obecný náčrtek mořské želvy se zjednodušeným rozdělením typů štítků.

Významným rysem mimo karapax jsou štítky *pre-frontální* nacházející se na čele. Štítky na hlavě lze použít k identifikaci druhu i jedinců, jelikož jejich tvar a počet jsou neměnné a specifické nejen pro druh, ale i jedince (Carpentier *et al.* 2016). Štítky spodního krunýře, plastronu, se též dělí, ale nehrají při identifikaci tak významnou roli.

3.2 Role želv v mořských ekosystémech

Želvy hrají v mořských ekosystémech velmi významnou roli. Avšak v současnosti, kdy se většina populací mořských želv obnovuje po několik staletí trvajícím lovu pro maso a želvovinu (viz níže, Gulick *et al.* 2021), je jejich vliv pravděpodobně menší než v minulosti před decimací populací lidmi (Lutz *et al.* 2003, Gulick *et al.* 2021). Jednotlivé druhy a jejich přínos pro ekosystémy jsou prozkoumány do různé míry. Málo je známo například o životě mořských želv v pelagiálu oceánů a moří (Briscoe *et al.* 2016). Ačkoliv jde o mořské živočichy, nejvíce informací máme o jejich životě ze souše, kam připlavávají na pláže klást


vejce. Mezi celkově méně prozkoumané druhy patří kareta plochá, potom karety z rodu *Lepidochelys* a kareta obecná (Behera *et al.* 2014, Thums *et al.* 2017, Ramirez *et al.* 2020, Schneider *et al.* 2022, Hounslow 2023).

Značná velikost a dlouhé migrační cesty dávají želvám schopnost ovlivňovat celosvětový koloběh živin, včetně transportu živin z mořského do suchozemského prostředí (Teelucksingh *et al.* 2010, Patel *et al.* 2022). Pláže jsou obecně ekosystémy poměrně chudými na živiny, jelikož ty písek špatně zadržuje. Želví vejce jsou na živiny bohaté, představují dobrý zdroj dusíku, fosforu, uhlíku i lipidů (Bouchard & Bjorndal 2000, Raposo *et al.* 2025). Proto se jimi a vylíhlými mladými želvami živí mnozí živočichové (varani, krabi, ptáci, prasata). Trus, který následně tyto predátory vylučují, též slouží jako zdroj živin pro další články potravního řetězce. Vejce, která nejsou vyhrabána predátory a zůstanou v písku, jsou po rozkladu dobrým zdrojem živin pro pobřežní vegetaci, která má nezastupitelnou roli při udržování struktury pláže a je rovněž důležitá pro mořské želvy, neboť v její blízkosti vyhlubují svá hnízda (Thilakarathne *et al.* 2024). Některé rostliny svými kořeny mohou dokonce vejci prorůst nebo je obrůst, a mít tak k živinám dřívější přístup (Bouchard & Bjorndal 2000). Původ živin lze v rostlinách vystopovat podle zastoupení izotopů, které se od toho běžného na souši odlišuje (Schubert & Calvert 2001). Ze studií vychází, že 13–40 % dusíku ze snůšek bylo využito rostlinami, detritovory a rozkladači a 26–70 % bylo zkonzumováno predátory. Jen malé procento dusíku se vrátilo zpět do moře (Bouchard & Bjorndal 2000, Raposo *et al.* 2025).

Nejlépe prozkoumán je vliv mořských želv na druhy, které představují jejich zdroj potravy. Zatímco kareta obrovská je spíše býložravá a má velký vliv na mořské louky (Gulick *et al.* 2021), kareta pravá i kareta obecná jsou spíše masožravé druhy soustředící se na houbovce, měkkýše a korýše (Lutz *et al.* 2003). Řasa *Thalassia testudinum*, jenž vytváří v Karibském moři a části Mexického zálivu velké porosty, je pro její oblíbenost tamějšími karety anglicky nazývána *turtlegrass* (Lutz *et al.* 2003, Gulick *et al.* 2021). Míra růstu této řasy, její produkce biomasy i složení a tvar jejích listů i délka oddenků závisí na míře spásání herbivory, přičemž role mořských želv, zejména karety obrovské, je zde nezastupitelná.

Karety obrovské si vyvinuly charakteristický způsob, kterým spásají mořské louky (Gulick *et al.* 2020). Podobně jako někteří jiní herbivorní živočichové mořských ekosystémů,

jako například ježovky či dugongové, spásají jen určitou část mořských luk po delší dobu. Oproti ježovkám a dugongům ovšem karety obrovské vytrvávají ve spásání vybraného území po mnohem delší dobu, a to až dva roky, což z nich činí herbivory se strategií nepodobnou většině ostatních herbivorů v mořích a žádnému na souši. Odpovědí *T. testudinum* na toto místně intenzivní spásání je rychlejší míra růstu fotosyntetických pletiv, jelikož nově vzrostlé listy mají více prostoru, a tedy lepší přístup ke světlu (Gulick *et al.* 2021). Takovéto adaptace na spásání jsou pro rostliny klíčové. Názorná ukázka mořského dna spaseného a porostlého loukou je na obrázku níže (Obrázek 2).



Obrázek 2: Vlevo (a) juvenilní kareta obrovská nad spasenou mořskou loukou, vpravo (b) jasná hranice mezi spásanou oblastí a nespásanou. Na fotografii (b) je dobře zřejmé pohlcování světla mořskou loukou oproti sousednímu písčitému dnu s dorůstající *T. testudinum*. Fotografie pocházejí z Karibského moře, převzato z Gulick *et al.* 2021.

Podle studií věnujících se historickému vývoji v Karibském moři mohly tamější mořské louky hostit desítky až stovky milionů jedinců karety obrovské. Takovým množstvím herbivorních spásáčů musely být karibské mořské ekosystémy značně pozměněny oproti současné podobě (Lutz *et al.* 2003). Dnes jsou mořské louky jedny z nejdůležitějších ekosystémů, třebaže pokrývají jen relativně malou část světových moří (de los Santos *et al.* 2020). Představují útočiště a místa zdroje potravy pro mladé ryby i bezobratlé (Unsworth *et al.* 2019), jsou využívány mořskou megafaunou a mnohými ohroženými druhy, slouží jako zásobárny uhlíku, chrání pobřeží před nadměrnou erozí a jsou důležité i pro okolní ekosystémy (de los Santos *et al.* 2020). Druhy s nimi spojené představují značnou část komerčně

významných druhů, zajišťují lidem žijícím při pobřeží obživu a jsou neméně důležité pro velké rybářské společnosti zajišťující dodávku běžně konzumovaných ryb do obchodních řetězců (Unsworth *et al.* 2019, de los Santos *et al.* 2020). Krom sycení rostoucí lidské populace jsou mořské louky obývány mořskými koníky, kteří často představují vlajkové druhy v ochraně, a jsou navštěvovány delfíny, sviňuchovitými, dugongy, tuleni i vydrami kvůli páření či krmení. Tito živočichové následně transportují živiny do okolních ekosystémů, jako jsou například mangrovové lesy, korálové útesy či pláže. Důležité jsou i pro svou schopnost ukládat uhlík do svých pletiv (tzv. *blue carbon*) i substrátu a tím zmírňovat klimatickou změnu. Z některých tropických druhů mořských trav byly v minulosti extrahovány látky vhodné pro medicínské účely (de los Santos *et al.* 2020).

Globální populace karety obrovské se však nespolehají pro obživu pouze na louky. Významná zjištění přinesla studie Wabnitz *et al.* (2010), podle které byl na útesech obklopujících Havajské souostroví pozorován karety obrovské živící se nepůvodními druhy rostoucími na útesu. To je významné zejména z pohledu obnovy degradovaných útesů, které jsou obvykle intenzivně porostlé řasovými nárosty, často tvořenými invazivními druhy. Mořské želvy, zejména karety obrovské, mohou tak významně přispívat k obnově resilience korálových útesů, což je důležité především při současném celkovém úpadku zdraví mořských ekosystémů (Wabnitz *et al.* 2010).

Stejně jako je kareta obrovská důležitým herbivorem pro mořské louky, je kareta pravá důležitým článkem v ekosystému korálových útesů. Ty slouží jako zdroj potravy i úkryty pro mnohé druhy (Kelly *et al.* 2016). Potrava karety pravé se sestává převážně z houbovců, kteří často ve velké míře korálové útesy porůstají, ale i z korálů, sumek a jiných pohyblivých bezobratlých (Obura *et al.* 2010). Biomasa houbovců převyšuje tu korálů především v degradovaných ekosystémech, tak je tomu například v Karibiku (Lutz *et al.* 2003, Kelly *et al.* 2016), ovšem karety pravé se zde živí převážně několika málo druhy houbovců z třídy *Demospongia* a jediným druhem korálu z řádu *Corallimorpharia* (León & Bjorndal 2002). Karety pravé svým okusem přímo vytváří holý substrát pro zahnízdění larev korálů i prostor pro jejich rozvětvený růst (Kelly *et al.* 2016).

Kareta pravá je významná též svou herbivorní strategií. Jedná se nejen o spásáče (*grazer*), který se živí spíše kobercovitými nárosty na skalách a u dna, ale je též tzv. *browser*, který

preferuje okusování rozvětvenějších a listovitých porostů, včetně plovoucích řas, jako např. *Sargassum* sp. Spásači pomáhají útesům udržet si resilience vůči změnám, *browsers* oproti tomu napomáhají návratu degradovaných ekosystémů s převahou řasových porostů do jejich původního, zdravého stavu (Goatley *et al.* 2012).

Rovněž kareta obecná se živí houbovci a mnoha různými bezobratlými i strunatci, ovšem na rozdíl od karety pravé byli nalezeni houbovci v žaludku, střevech či exkrementech karet obecných nestrávení (Casale *et al.* 2008). Role karety obecné je oproti předchozím dvěma druhům mnohem méně popsána, nicméně jde o primárně masožravou mořskou želvu soustředící se na korýše, měkkýše, salpy i medúzy (Frick *et al.* 2009). Podobně nedostatečně prozkoumané jsou i vliv na ekosystémy a charakter potravy karety ploché, karet zelenavé a karety menší.

Kareta zelenavá je primárně masožravý druh zaměřující se na měkkýše, ryby a členovce, ale bylo u ní zjištěno i spásání řas (Behera *et al.* 2014). U karety menší byly za hlavní složku potravy považovány primárně krabi a měkkýši, ovšem ve studiích provedených na jedincích u pobřeží Floridy převažovali pláštěnci a na severní hranici areálu to byly ryby (Ramirez *et al.* 2020). Rovněž kareta plochá je prozkoumána v oblastech zahrnujícím její pobyt na souši; při hnízdění a vylíhnutí a obdobím mezi, nicméně naše znalosti o ekologii tohoto druhu mimo pláže je omezená (Thums *et al.* 2017, Hounslow 2023). Předpokládá se, že se podobně jako ostatní druhy želv živí bezobratlými s měkkými těly (Schneider *et al.* 2022).

Krunýře mořských želv mohou sloužit jako substrát pro mnohé přisedlé organismy a přispívat tak k jejich rozšiřování (Lutz *et al.* 2003). Na krunýřích karet obecných hnízdících na plážích americké Georgie bylo nalezeno více než 100 druhů epibiontů (měkkýši, žahavci, korálnatci) (Frick *et al.* 1998, Pfaller *et al.* 2008) a u jedinců hnízdících na pláži X'cabel v Mexiku bylo nalezeno 37 druhů řas (Lutz *et al.* 2003).

Posledním nezmíněným druhem je kožatka velká, jenž se specializuje na želatinózní plankton, především pak medúzy. Výskyt této želvy často odráží místa se sezónní vysokou koncentrací medúz, kterých dokáže zkonzumovat 200 až 840 kg za den (Houghton *et al.* 2006). Mohou tak zkonzumovat ekvivalent své váhy, což zároveň představuje několikanásobek jejich požadovaného denního příjmu živin (Heaslip *et al.* 2012). Slouží tedy jako významní regulátoři populací medúz, které při přemnožení mohou působit škody na

antropogenních stavbách, zejména ucpávat chladicí systémy lodí, příbřežních elektráren a generátorů. Nezanedbatelné bývají při přemnožení medúz i ztráty turistického průmyslu (Lee *et al.* 2023). Bohužel kvůli stále intenzivnější produkci plastů, zejména plastových obalů a sáčků, které si pletou se svou potravou, jsou tyto želvy stále ohroženější, ačkoliv smrt v důsledku zcpání trávicího traktu je považována za nečastou (Mrosovsky *et al.* 2009).

Jelikož se mořské ekosystémy vyvíjely zároveň s želvami (Gulick *et al.* 2021), jde o provázaný řetězec, kde, pokud selže jeden článek, selže i druhý; mořské želvy potřebují zdravé ekosystémy, které bez nich degradují a kvůli značenému vlivu člověka obrůstají nepůvodními druhy, řasami a houbovci (Bjorndal & Bolten 2003). Vzhledem k tlaku, pod kterým jsou mořské ekosystémy dnes a pod jakým tlakem populace mořských želv bývaly (a někde stále jsou), je důležité zasadit se o jejich ochranu jak snížením nebezpečí a rizik, kterým čelí, tak ochranou jejich ekosystémů (Sounguet *et al.* 2004, Mazaris *et al.* 2017, Gunawan *et al.* 2018).

3.3 Ohrožení mořských želv

V minulosti obývaly moře populace želv mnohem početnější, než je tomu dnes. Jejich úpadek začal intenzivním lovem námořníky při kolonizaci a terčem byly i pro původní obyvatelstvo dlouho před jejich připlutím (Bjorndal & Bolten 2003).

Další ranou pro populace mořských želv je stále pokračující degradace mořských ekosystémů, které již nejsou schopny unést takové počty jedinců, jako tomu bylo v dobách před decimací populací (Lutz *et al.* 2003, Lovich *et al.* 2018, de la Hoz Schilling *et al.* 2023).

Kromě ubývajících původních habitatů jsou želvy v současnosti ohroženy velkým výčtem především antropogenních hrozeb. Zejména nebezpečné je pro ně neustále pokračující výstavba na plážích a jejich degradace i zmenšování těžbou. Pro mořské želvy je charakteristická skvělá orientace ve světových oceánech a jejich schopnost se po dosažení pohlavní dospělosti vrátit se kvůli zahnízdění na rodnou pláž (případně do stejné oblasti) (Costa *et al.* 2023, Hendrix & Pérez-Espona 2024). Urbanizací těchto pláží klesají počty hnízdících želv (Costa *et al.* 2023). Snad největší vliv měl a stále má na populace karet lov.

Lutz *et al.* (2003) píší o cestě Kryštofa Kolumba a neobydlených Kajmanských ostrovech, které pojmenoval *Las Tortugas* pro nezměrné množství mořských želv, které spatřil na jejich plážích. V následujících letech se u těchto ostrovů lodě zastavovaly se záměrem lovu ke konzumaci. Takto byly ročně odváženo až třináct tisíc jedinců, až byly nakonec ve zdejších vodách koncem 18. století mořské želvy vzácné (Lutz *et al.* 2003). V současnosti jsou želvy i nadále ohroženy lovem, ačkoliv jsou všechny zahrnuty v Červeném seznamu IUCN a za posledních několik dekád stále se zvyšující snaze o jejich ochranu (Poonian *et al.* 2016, Mazaris *et al.* 2017).

Pozornost si žádá zejména situace v mexickém státě Baja California Sur rozkládající se na Kalifornském poloostrově. Exploatace populací mořských želv, zejména pak karety obrovské, zde byla velmi intenzivní a během první dekády tohoto tisíciletí bylo uloveno celkem kolem 35 000 mořských želv, které byly následně prodány na černém trhu, mezi místními či konzumovány v rodinách (Mancini *et al.* 2011).

Dalšími z míst, kde lov – ať už v podobě lovu dospělých jedinců či sběru vajec – stále pokračuje, jsou Filipíny (Poonian *et al.* 2016), Mexiko, a zejména pak v Karibském moři a Mexickém zálivu (McClenachan *et al.* 2006, Mancini *et al.* 2011), na Bali v Indonésii (Jensen 2009, Hemelikova *et al.* v tisku) a mnoha dalších místech (Rudrud *et al.* 2007, Jayathilaka *et al.* 2017, Thilakarathne *et al.* 2024). Žádané jsou veškeré části mořských želv; tuk, maso, krev, kosti, orgány, krunýř i vejce a jde často o pokrm považovaný za delikatesu. Konzumace želvího masa je v některých regionech považována za výraz moci (Mancini *et al.* 2011). Některé části, jako například tuk, kosti či krev jsou využívány v tradiční medicíně, zatímco vejce mají údajně afrodisiakální účinky (Hemelikova *et al.* v tisku).

Konzumace želvího masa se přitom ukazuje jako potenciálně nebezpečná. Těžké kovy se akumulují především v játrech, ledvinách, svalech i krunýři a jejich hodnoty mohou přesáhnout normy mezinárodní bezpečnosti. V takových koncentracích mohou způsobovat vývojové vady na dětech (Rudrud *et al.* 2007). Rovněž vejce mohou akumulovat těžké kovy, které škodí lidskému zdraví a zabraňují vývoji želvímu zárodku. Stejný vliv mají i člověkem vypuštěné chemikálie (Rudrud *et al.* 2007).

Byla rovněž zjištěna akumulace mikroplastů v nevylihnutých vejcích, naznačující přenos mikroplastů z matky na potomstvo (Curl *et al.* 2024). Další studie naznačují, že největší vliv

mohou mít mikroplasty na vývoj především jater, ovšem vyjma těch nebyl vývoj zárodku ovlivněn (Chemello *et al.* 2023). Zároveň jsou mikroplasty nacházeny ve většině zkoumaných hnízdišť (Zhang *et al.* 2022, Estrella-Jordan *et al.* 2023, Curl *et al.* 2024).

Mikroplasty ale nejsou zdaleka tím jediným druhem antropogenního materiálu, který je v mořských želvách nacházen. Casale *et al.* (2008) píše o nálezů kousků sítě, dehtu, barvy, háčku, sádry, polystyrénu a mnoha dalších druhů plastů z jedinců karety obecné ve Středozemním moři. Vlastnosti a složení mikroplastů mohou často vést k hromadění kontaminantů a nebezpečných sloučenin, jako jsou například polychlorované bifenylly, které se mohou přichytit do tkání a podnítit nebezpečné infekce. U všech sedmi druhů mořských želv jsou známy případy konzumace nějaké formy mořského odpadu, který je rozměrnější než mikroplasty. Tím může dojít k zablokování trávicího traktu a následné podvýživě, vnitřním zraněním, případně neregulovatelné vznášivosti, a může tak jedince značně oslabit až usmrtit. Zamotání se do odpadu, zejména rybářských sítí, je další velkou hrozbou pro mořské želvy (Nelms *et al.* 2016).

K zamotání může dojít náhodně při hledání potravy, a to do zapomenutých, odhozených či ztracených rybářských sítí nazývaných *ghost nets* (Wilcox *et al.* 2015, Nelms *et al.* 2016). Zároveň vede zamotání k zvýšení výdaje energie a snížené schopnosti útěku před predátory (Nelms *et al.* 2016). V případě zamotání se do rybářských sítí uvíznutých např. na útesech pak může dojít k utonutí (Mayer 2020). Tímto jsou ohroženy zejména ti jedinci, kteří jsou po většinu roku věrni určitým lokalitám, kde by mohly být sítě přichyceny (Hudgins *et al.* 2023). Dle Wilcox *et al.* (2015) se mohou do 100m sítě zamotat až 4 mořské želvy, což znamená, že vzhledem k jejich průměrné velikosti by se za rok mohlo zamotat 4-14 tisíc želv (ve studii bylo zkoumáno celkem 9000 *ghost nets*). Následkem může být i ztráta končetin (Nelms *et al.* 2016). Kromě mořských želv se do těchto sítí zamotávají i různé ryby, žraloci, dugongové a rejnoci (Wilcox *et al.* 2015).

Mořské želvy se velmi často stávají vedlejším úlovkem, což je termín zahrnující jinou skupinu než tu, jenž je při lovu cílená (Rajakaruna *et al.* 2020). Tak se jedinec dostává do extrémní stresové situace, kdy si snahou se osvobodit může přivodit řezná zranění od sítě. Zejména vysokou mortalitu pro mořské želvy znamenají vlečné sítě na lov garnátů (Babcock *et al.* 2018).

Dalšími hrozbami jsou kolize s plavidly, neboť dospělí jedinci mají pomalejší reakce na rychle se pohybující objekty (NOAA 2023), pak také stoupající hladiny moří a klimatické změně. Teplota ovlivňuje vývoj pohlaví želvích embryí a její růst může zapříčinit vývinu většího poměru samic (Hendrix & Pérez-Espona 2024). Rovněž predace zavlečenými i původními druhy má značný vliv (NOAA 2023). Neantropogenní hrozbou, která se na mořské želvy vztahuje, je rozšiřující se výskyt nákazy chelonidním herpesvirem 5, který způsobuje fibropapilomatózu charakteristikou bujením nádorů (Robben *et al.* 2023).

Kvůli stále rozrůstající se lidské populaci a silnému tlaku na mořské ekosystémy je potřeba se zasadit o ochranu těchto druhů a zároveň o zachování ekosystémů, které obývají a udržují ve zdravém stavu tak, aby mohly poskytovat různé ekosystémové služby (Bjorndal & Bolten 2003, Unsworth *et al.* 2019). Bez intenzivní snahy člověka o záchranu těchto živočichů by pokračoval intenzivní lov až k vyhubení, kterému mořské želvy stále docela neunikly. Ochrana a řádný výzkum týkající se vlivů člověka a ohrožení jeho činností jsou nezbytně nutné (Finkbeiner *et al.* 2011, Thilakarathne *et al.* 2024).

4. Ochrana a její metody

Z důvodů, jenž byly vypsány v předchozí kapitole, je nutno mořské želvy chránit a zamezit jejich vyhynutí. První zmínky o ochraně těchto mořských plazů nacházíme z Bermud, a to v britském koloniálním zákoně z roku 1620, vydaném jako reakci na snižující se počty karet obrovských s cílem kontrolovaného lovu pro pokračující dlouhodobý zisk (Carr 1967). Začátkem 20. století následovala opatření například na Floridě, došlo k zákazu lovu želv v období hnízdění, ovšem ochrana se již nevztahovala na želvy v moři ani na sběr vajec (Ankersen 2024).

Opravdu zlomovým bodem v ochraně mořských želv byla až 50. léta 20. století (Mancini *et al.* 2011), a to zejména díky Američanovi Archiemu Carrovi, jenž se zasadil o první výzkumy týkající se mořských želv. Ten vydal knihu s názvem *The Windward Road*, v níž pojednává o svých cestách po Karibiku ve snaze prozkoumat jejich migrační chování. Jeho dílo bylo impulzem k prvním snahám o ochranu mořských želv, především populací hnízdících na Floridě (Ankersen 2024), která je velmi významnou lokalitou pro hnízdění mnoho druhů karet (Engeman *et al.* 2014).

Po staletích poklesu jsou dnešní populace stabilizovány, místy dokonce vzrůstají (Mazaris *et al.* 2017). Stalo se tak díky mnohým podniknutým krokům; zahrnutí mořských želv do ochranné legislativy, ochrana hnízd, vyhlásování chráněných území, preventivní opatření v rybářském průmyslu a další (Godley *et al.* 2020). Jednoznačně nejznámějšími úmluvami, které chrání mořské želvy, jsou Úmluva o mezinárodním obchodu s ohroženými druhy volně žijících živočichů a planě rostoucích rostlin (CITES), kde jsou mořské želvy uvedeny v Příloze I, Úmluva o ochraně stěhovavých druhů volně žijících živočichů (Bonnská úmluva), Úmluva o biologické rozmanitosti (CBD) a pro Karibik významná Úmluva o ochraně a rozvoji mořského prostředí širší karibské oblasti (SPAW). Zároveň jsou mořské želvy uvedeny na Červeném seznamu IUCN, jak bylo popsáno v první kapitole. Dalšími úmluvami, které svým rozsahem spadají do evropského regionálního a národního prostoru nebo přímo nezmiňují mořské želvy, ale cílí na ochranu jejich stanovišť, jsou Úmluva o ochraně mořského prostředí a pobřežní oblasti Středozemního moře (Barcelonská úmluva), Úmluva o ochraně evropské fauny a flóry a přírodních stanovišť (Bernská úmluva) a mnohé další. Tyto úmluvy

zakazují lov, zabíjení a obchod s mořskými želvami i jejich vejci, podněcují k úpravě rybářského vybavení tak, aby co nejméně škodilo želvám, podporují výzkum a zastřešují chráněná území (MEDASSET 2020).

Vyhlašování chráněných území k ochraně pláží i podvodních stanovišť želv je rovněž metodou ochrany (Mazaris *et al.* 2017), ovšem želvy nemusí tato chráněná území využívat a vyskytovat se více v blízkých nechráněných oblastech (Nel *et al.* 2013, Abalo-Morla *et al.* 2022). Ochrana stanovišť je obtížná i z důvodu značné pohyblivosti mořských želv (Nel *et al.* 2013).

Na svých migračních cestách se mohou kdykoliv zamotat do nějakých z *ghost nets* nebo kvůli srážce s plavidlem přijít o končetinu. Ačkoliv jde o drastické zranění, mořské želvy jsou schopny i taková zranění přežít (Rudrud *et al.* 2007). Často bývají takoví jedinci umístováni do záchranných stanic, jejichž součástí často bývají i vymezené části (pláže) určené k přenosu snůšek, které by byly jinak predovány. Přenos snůšek do záchranných stanic s líhněmi je jednou z *ex situ* ochranných metod a historicky pravděpodobně přinesla pozitivní výsledky v ochraně mořských želv (Mazaris *et al.* 2017, Phillott *et al.* 2021), ovšem jejich efektivita je předmětem diskuzí. Aby byly tyto záchranné stanice s líhněmi přínosné, je nezbytně nutné dodržet všechny dílčí kroky sběru, přenosu a převozu, vlastností nového hnízda a následné péče o vylíhnuté želvy (Phillott *et al.* 2021). Pokud nejsou tyto dílčí kroky dodrženy, pak úspěšnost vylíhnutí a přežití mladých želv bývá nižší oproti člověkem nerušenému vývoji. Detailně jsou sepsány v článcích od Phillott & Shanker (2018) a Phillott *et al.* (2021). Přílišnou prodlevou mezi vyzdvižení snůšky z původního hnízda a přenesení do nového klesá množství vylíhlých mlád'at, zároveň byla u přenesených snůšek opakovaně pozorována různá doba vývoje vajec, často zkrácená oproti hnízdům ponechaným na svých původních místech (Nasiri *et al.* 2023). Nesprávným umístěním přenesené snůšky může být ovlivněn pohlaví vylíhnutých mlád'at (Hendrix & Pérez-Espona 2024).

Vlivnou snahou o ochranu želv bylo zavedení dohledu nad hnízdy, a to jejich zakrýváním před přirozenými či zavlečenými predátory (Engeman *et al.* 2014). Mezi ně patří krysy, jezevci, krabi, psi, varani a prasata a škody mohou způsobit i želvy samotné, když při vyhrabávání hnízda omylem poškodí již dříve nakladenou snůšku (Engeman *et al.* 2014, Thilakarathne *et al.* 2024, Raposo *et al.* 2025). Snůšky želv se přitom mohou nacházet až metr

hluboko v sypkém písku a pro ochranáře monitorující pláž může být náročné udržet přehled o jejich poloze. Lindborg *et al.* (2023) provedli pokus zapojení do detekce snůšek vycvičené psy, což se ukázalo jako různě efektivní pro různé druhy, nicméně může jít o další krok kupředu v ochraně a monitoringu želv.

Jako přínosné se ukázalo začleňování zdejších obyvatel, zejména členů pobřežních komunit, do ochrany, tím jejich edukaci v problematice mořských želv a poskytnutí jim jiný zdroj obživy než využívání zdrojů moře (Kapurusinghe 2012). Státy s nejvyšší biodiverzitou jsou obvykle ty, které jsou zároveň nejchudší a pro jejich obyvatele jsou zdroje obživy z moře častou nejjednodušší a nejdostupnější možností (Pheasey *et al.* 2023). Začlenění chudých pobřežních komunit se celosvětově ukazuje jako efektivní přístup k ochraně želv, neboť tito lidé mají k populacím vyskytujícím se v sousedících vodách nejbližší (Chandarana *et al.* 2017).

Kroky byly podniknuty i k zmenšení počtu mořských želv ulovených jako vedlejší úlovek. Termín pochází z anglického slova *by catch* a zahrnuje živočichy chráněné, nedostatečné velikosti či mimo cílovou skupinu, které byly nechtěně chyceny do rybářského náčiní při rybolovu (Rajakaruna *et al.* 2020). Mezi mitigační opatření rybářských společností patří zavedení zakulacených háčků (z angl. *circular hooks*) místo háčků tvaru J, které mají zpětný hák a při pozření želvou způsobují těžká vnitřní zranění. Počty úmrtí mohou používáním klesnout až o 60 %, a přitom tyto háčky nijak neovlivňují velikost úlovku komerčně žádaných ryb (WWF 2007, Swimmer *et al.* 2017). Vliv má i volba návnady na háčcích. Studie Swimmer *et al.* (2017) potvrdila nejnižší počty mořských želv jako vedlejšího úlovku při využití zakulacených háčků a používáním ryb jako návnady místo desetinožců. Dalším opatřením je používání diod k osvětlení rybářských sítí a tzv. TED, tj. *turtle exclusion devices*, které umožňují lapeným želvám opustit síť (Godley *et al.* 2020). Když je roku 2003 zavedl americký rybářský průmysl jako mitigační opatření, klesly počty úmrtí želv z 71 tisíc (roční úmrtnost mezi roky 1990 a 2003) na necelých pět (roční úmrtnost od r. 2003 po r. 2007) (Finkbeiner *et al.* 2023).

Doposud měly některé snahy o ochranu želv různé výsledky (Mazaris *et al.* 2017) a zejména u záchranných stanic s líhněmi často chybělo sledování úspěšnosti vylíhnutí

relokovanych snůšek. Evaluace úspěšnosti vycházela z mnoha použitých metod a podrobný popis a porovnání některých z nich je sepsán v navazující kapitole.

4.1 Monitoring populací mořských želv

Pro sledování vývoje populací mořských želv se využívají mnohé metody; telemetrie, značení štítky, počítání želv při kladení na plážích, počítání hnízd a množství vajec v nich, využívání letadel, dronů či jiných létajících strojů neřízených člověkem a mnoho dalších. Mořské želvy jsou ovšem dlouhověcí živočichové, kteří dospívají často až po 20. roku života a některé druhy se dožívají ke 100 let, což z nich činí obtížně monitorovatelné druhy vyžadující velké úsilí. Pomocné může být využití dat rybářských společností a jejich záznamů vedlejších úlovků k odhadům velikosti populací, případně zapojení široké veřejnosti (Hendrix & Pérez-Espona 2024).

Satelitní telemetrie je v zoologických výzkumech a v ochraně velmi rozšířená, ale jde o finančně a technologicky náročnou a pro zvířata stresující metodu (Adam *et al.* v tisku). Nicméně může poskytnout velmi důležitá data pro lepší porozumění jejich migračních tras a způsobů, kterými se tyto želvy navigují (Luschi *et al.* 1998). Akustickou telemetrii lze využít při monitoringu pohybu čerstvě vylíhnutých želvích mláďat, o jejichž prvních dnech a týdnech v mořích a oceánech se dozvídáme až v posledních dvou dekadách. Pro monitoring mláďat se využívaly často *particle tracking* modely vysvětlující rozptyl objektů v mořském prostředí (Thums *et al.* 2013).

Želvy jsou též monitorovány pomocí štítků, které jsou jedincům nastřelovány na přední ploutve. Jde o tradiční metodu zpětného odchyty neboli *capture-mark-recapture*. Nevýhodami jsou cena i stres pro jedince, stejně jako v případě telemetrie, ovšem zde může dojít k ztrátě štítku (Balazs *et al.* 1982, Carpentier *et al.* 2016).

Starou, ale stále používanou metodou monitoringu, který ale neumožňuje zohledňování jedinců, je zapisování počtů a druhů želv ochranáři při hlídkování na plážích, když jdou samice klást (Hendrix & Pérez-Espona 2024). Aby byly mořské želvy na plážích při kladení co nejméně rušeny, je důležité používat pouze červené světlo a přistupovat k nim ve


správnou chvíli (Silva *et al.* 2017). Při vylezení na pláž samice nejprve vytvoří tzv. *body pit*, který je velký a tvoří ho předními ploutvemi. Následuje vyhrabávání *egg chamber* pomocí zadních ploutví, která má tvar hrušky, načež naklade asi 100 vajec (Rusli 2019). Samice mořských želv při kladení vajec upadají do jakéhosi transu, kdy jsou tolerantní vůči poměrně intenzivní míře rušení a lze je z bezpečné vzdálenosti fotit (Miller 1997). Poté předními ploutvemi zahází hnízdo a posune se o několik metrů, kde utvoří vrš, pravděpodobně na zmatení predátorů a následně se vrátí do moře (Rusli 2019). V případě, že hlídkující ochránáři a rančeři nezastihnou želvu během kladení, lze podle stop zanechaných v písku určit jedince do druhu (Government of Australia 2021). Pokud želva při vyhrabávání *egg chamber* narazí na kamení, korály či kořeny, ustane a vrátí se jiný večer (Rusli 2019).

K monitoringu na plážích lze využít i drony, na které mohou být připevněny termokamery. Drony představují efektivnější metodu monitoringu než tradiční pozemní hlídky na plážích, pomocí níž lze získat více dat (nalézt více želv, snůšek i stop) a drony s termálními kamerami se ukazují jako ještě úspěšnější (Sellés-Ríos *et al.* 2022). Všechny tyto metody ovšem cílí především na samice při kladení snůšek, a data týkající se samců jsou zastoupena v menší míře (Hudgins *et al.* 2023).

Nově představenou metodou monitoringu je fotoidentifikace, která se s rozvojem technologií stává stále rozšířenější a umožňuje rozlišování jedinců. Oproti výše zmíněným metodám není invazivní a jedinec při monitoringu nemusí přijít do kontaktu s člověkem. Zároveň lze zapojit i nevědeckou veřejnost, neboť přínosná mohou být i data pořízená laiky při šnorchlování či potápění (Papafitsoros *et al.* 2020, Adam *et al.* v tisku). Při tom může být želva stresována přílišnou blízkostí lidí, kteří se mohou snažit želvy dotknout, případně zraněna plavidly (Papafitsoros *et al.* 2020).

K identifikaci jedinců se využívají tvary štítků na hlavě a předních ploutvích, ovšem pigmentace není spolehlivý určovací znak, neboť se s věkem mění. Tvary štítků karet se přitom prokázaly jako stabilní určovací znak v různých stádiích vývoje jedince; ať už byly sledovány změny během několika let u dospělých jedinců, tak u mladých želv od vylíhnutí. Výjimky z tohoto pravidla jsou vzácné (Carpentier *et al.* 2016). Níže je Obrázek 3 zachycující změny pigmentace štítků hlavy mláďete karety obrovské.

V případě kožatky velké, která nemá štítky na hlavě ani ploutvích, se používá tvar pineální žlázy na temeni, jenž má růžovou barvu (Carpentier *et al.* 2016).



Obrázek 3: Zachycené změny pigmentace u konkrétního jedince karety obrovské. Horní řada (A) zachycuje pravou stranu, spodní (B) levou stranu. První sloupec pochází ze dne vylíhnutí, druhý sloupec je 111. den, třetí 366. den, čtvrtý 1114. den a poslední zachycuje první pozorování po vypuštění jedince ze záchrané stanice. V tomto případě šlo o 1136. den. Je patrné prvotní blednutí a následná intenzivní pigmentace, ovšem tvar štítků zůstává stejný. Červená šipka podle autorů znázorňuje necelistvý okraj štítku, kdy šlo o jediné zaznamenané pozorování takové vady celé studie. Převzato z Carpentier *et al.* 2016.

Na obrázku výše jsou uvedeny změny v pigmentaci na štítcích hlavy, nicméně pro identifikaci se dají využít i štítky ploutví. Mills *et al.* (2023) ve své studii dokázali, že identifikace jedinců ze štítků ploutví je úspěšnější než ze štítků hlavy, ačkoliv používaný software vyžadoval manuální označení vrcholů všech štítků, které byly zohledňovány a ploutev nesměla být vyfocena pod úhlem. Čím více štítků bylo zahrnuto to zkoumané oblasti k identifikaci, tím vyšší bylo rozpoznávání jedinců. Manuální umístování bodů na vrcholy štítků by ovšem bylo pro velké počty fotografií nepraktické (Carpentier *et al.* 2016, Mills *et al.* 2023). Efektivnější a méně manuálně náročné je používání takových metod, které nevyžadují velkou lidskou asistenci.

Docela automatizovanou metodou je využití modelů neuronových sítí, o nichž je psáno v jedné z dalších kapitol. Monitoring je nutný napříč oceány pro lepší porozumění migračních tras mořských a přijetí opatření zamezujících jejich úmrtí z různých důvodů. Zejména

Indický oceán se dlouhodobě potýká s nedostatkem výzkumů týkajících se populací želv (Hudgins *et al.* 2023).

5. Mořské želvy Šrí Lanky

Šrí Lanka je ostrovní stát s jednou z nejvyšších mír biodiverzity na světě. Na jejích plážích sezónně hnízdí pět ze sedmi žijících druhů mořských želv, a to zejména na jižním a jihovýchodním pobřeží (Hewavisenthi 1990, Rajakaruna *et al.* 2009, Manzoor *et al.* 2023). Konkrétně jde o karetu obrovskou, karetu obecnou, karetu zelenavou, karetu pravou a kožatku velkou. Kareta plochá na Šrí Lance nehnízdí (Manzoor *et al.* 2023).

Kareta menší se v Indickém oceánu nevyskytuje (Caillouet & Gallaway 2020).

5.1 Historie poznání želv na Šrí Lance

5.1.1 Lov

První zmínky o želvách na Šrí Lance spadají do období Římské říše okolo přelomu letopočtu (de Silva 2006). Šrí Lanka obchodovala s mnoha zeměmi a vyvážela své přírodní bohatství, například do Indie a díky rozvoji Hedvábné stezky i do Římské říše vyvážela kromě rýže, perel a koření i želvovinu (Munasinghe *et al.* 2021).

Zdejší mořské louky, korálové útesy a laguny jsou pro želvy velmi atraktivní a jejich hojnosti se zdejší obyvatelé naučili využívat (de Silva 2006). Želvy sloužily obyvatelům ostrova především jako zdroj obživy. Konzumovaly se všechny měkké části želvy včetně vajec a želvovina ze štítků krunýře pak sloužila jako materiál na výrobu nejen ozdobných předmětů (Hewavisenthi 1990, de Silva 2006). Kvůli popularitě želvího masa, vajec a poptávce po výrobcích z želvoviny byly populace želv několikrát v historii zdecimovány a poptávka musela být naplněna želvovinou importem z jiných zemí (de Silva 2006). To se týká zejména karety pravé (de Silva 2006), která bývala nejhojnějším druhem šrílanských vod od dob před přelomem letopočtu až do druhého století našeho letopočtu, kdy se její populace kvůli příliš intenzivnímu rybolovu zmenšila. Podobná situace se opakovala mezi 16. a 19. stoletím našeho letopočtu, od té doby populace tohoto druhu opět klesá (de Silva 2006).

Podle nálezů v Anuradhapure bylo maso mořských i sladkovodních želv součástí jídelníčku dávno před naším letopočtem (Chandraratne 1997, in de Silva 2006). Zprávy o

konzumaci ovšem pochází až z 19. století, přičemž největší poptávka po želvím masu byla zejména na severozápadě a v okolí města Jaffna (viz Obrázek 4). Významnými místy lovu želv pro maso byly Portugalská zátoka, Mannárský záliv a Palkův průliv (viz Obrázek 4) (de Silva 2006), odkud byly želvy odváženy na tržnice (Hewavisenthi 1990, de Silva 2006). Jen mezi mysem Kudiramalai (mezi Mannárským zálivem a Portugalskou zátokou) a městem Jaffna bylo ročně zabito až tři tisícovky želv, především pak karety obecné, karety pravé a karety zelenavé (Hewavisenthi 1990, Jonklass 1937, in de Silva 2006).

Tennent (1860) píše o krutém zacházení s želvami na tržnicích, kde byly prodávány; želvy zbavené plastronu byly zaživa porcovány a orgány prodávány na váhu zájemcům. Toto zacházení přilákalo pozornost organizace Humane Society International, která apelovala na tehdejší šrilanskou vládu, aby schválila zákon zakazující týrání zvířat (Hewavisenthi 1990, de Silva 2006). V návaznosti na to měla od začátku 20. století zdejší policie povinnost dohlížet na zacházení se zvířaty a bránit jejich týrání, především pak způsobům, jakým byly získávány štitky a porcovány živé želvy (Hewavisenthi 1990). Roku 1907 vydala vláda výnos o Prevenci týrání zvířat (Prevention of Cruelty to Animals Ordinance) (Government of Sri Lanka 1907) a v roce 1938 výnos Fauna and Flora Protection Ordinance (Government of Sri Lanka 1938), ve kterém byly všechny druhy mořských želv uvedeny jako chráněné pod pojmem plaz (v orig. *reptile*). Nicméně jelikož velká část obyvatelstva byla závislá na příjmu z prodeje želvoviny a želvího masa, byl zákaz obchodování na dva roky pozastaven. I přes následné obnovení zákazu obchodování pokračovalo, a to nejen v odlehlých místech ostrova (Hewavisenthi 1990). De Silva (2006) píše o stále trvajícím lovu pro výrobu náramků z želvoviny a pro přípravu polévek, a to zejména pro turisty.

Konzumovala se i krev, o níž se věřilo, že poskytuje povzbuzující a posilující schopnosti (Hewavisenthi 1990, de Silva 2006). Rovněž želví vejce byla prodávána na tržnicích a konzumována (de Silva 2006), a to podle Wickramasinghe (1981, in Hewavisenthi 1990) v odhadovaném množství až dvaceti tisíc kusů za rok.

Významný byl pro zdejší obyvatele i mezinárodní obchod s želvovinou. Řecký historik Strabón (63 př. n. l. – 23 n. l.) zmiňuje odkup želvoviny Římany pro dekoraci nábytku. Co se využití želv šrilanskými obyvateli týče, zmiňuje historik Plinius Starší (23 AD - 79 AD) střechy rybářských domů z želvích krunýřů (Weerakkody 1992, in de Silva 2006).

Vyhlášenost Šrí Lanky v obchodování s želvovinou ustala okolo druhého století našeho letopočtu, kdy většina produktů z želvoviny pocházela z Malajského poloostrova, nicméně i v dobách po kolonizaci byli původní obyvatelé Šrí Lanky známí pro své řemeslo vyrábění tabatěrek, krabiček na cigarety, na šperky, hřebenů na vlasy a psacích stolů (de Silva 2006). Šrílanskými klenotníky byly nejvíce ceněny štítky marginální, které se nachází na obvodu krunýře, ovšem ty byly lovci málokdy sloupávány (de Silva 2006). Želvy zbavené štítků byly vypouštěny zpět do moře s domněnkou, že štítky dorostou (Hewavisenthi 1990, de Silva 2006). De Silva (2006) píše o zprávě v díle Deraniyagala (1939), kde zmiňuje mladou karetu pravou, jenž přišla o tři štítky na krunýři, které jí během následujících sedmi měsíců dorostly.

Lovci vyvinuli různé metody lovu, které se liší napříč ostrovem. Zatímco například v Anamaduwe, která leží na východním pobřeží, se želvy lovily při kladení na pláži obrácením na záda, na poloostrově Jaffna se kromě obrácení na záda k lovu používaly navíc harpuny a různé druhy sítí (Hewavisenthi 1990). Lov želv pro zisk želvoviny probíhal tak, že byla želva na pláži obrácena na záda a byly jí svázány ploutve, následovalo provléknutí bambusových tyčí, poté byl krunýř želvy ohříván nad ohněm, dokud nešly štítky jednoduše sloupnout (Hewavisenthi 1990, de Silva 2006). Lov probíhal zejména během hnízdní sezóny, kdy zdejší obyvatelé stavěli dočasná obydlí na pobřeží, aby dosáhli co možná největšího úlovku, který následně prodávali na tržnici. Prodej řídili takzvaní *fish renters*, kteří odkupovali želvy od ostatních lovců želv. Lebky nalezené na severozápadním pobřeží ostrova v okolí těchto plážových příbytků patřily z drtivé části karetě obecné (de Silva 2006).

5.1.2 První podoby ochrany želv na Šrí Lance

Kromě lovu želv pro maso a želvovinu ale existují naopak též záznamy o značení želv štítky anebo zakládání líhní, tj. míst, kam se umísťovaly želví vejce pro vylíhnutí a kde vylíhlé želvy zůstávaly do dosažení určitého věku nebo velikosti. První želví líhně se začaly zakládat až v půlce 20. století na jihu Šrí Lanky na plážích národního parku Yala (Obrázek 4) a v blízkém městě Palatupana (de Silva 2006). Další záchranné stanice a líhně byly otevřeny v letech 1956 a 1969 a několik dalších jich bylo otevřeno i bez oficiálního povolení. Jejich

počet se v následujících letech i začátkem tohoto století neustále měnil. Samotné líhně se nakonec staly nebezpečím pro populace mořských želv pro nepečlivý postup při ochraně a zneužívání svého postavení k přilákání turistů, nikoliv k ochraně želv (Phillott *et al.* 2018).

De Silva (2006) píše o údajně celosvětově prvním označení želvy z konce 18. století, kdy holandský úředník označil želvu mosazným kruhem s vyrytým datem a vypustil ji. Znovu byla želva chycena o více než 30 let později (de Silva 2006).

5.2 Legislativa chránící mořské želvy

Všechny druhy mořských želv obývajících šrilanské vody jsou dlouhodobě chráněny vládními výnosem o Prevenci týrání zvířat (Prevention of Cruelty to Animals Ordinance) (Government of Sri Lanka 1907), Fauna and Flora Protection Ordinance s mnohými dodatky (Government of Sri Lanka 1938) a zákonem Fisheries and Aquatic Resources Act (Government of Sri Lanka 1996). Ačkoliv v poslední jmenované legislativě nejsou želvy výslovně zmíněny, mnohá opatření daná tímto zákonem jsou pro mořské želvy prospěšná. Rovněž v původním znění výnosu Fauna and Flora Protection Ordinance nebyly mořské želvy zmíněny. Jako přísně chráněný byl z plazů v původním znění tohoto výnosu uveden pouze varan skvrnitý *Varanus salvator* (Laurenti, 1768). Všechny druhy mořských želv byly přidány až dodatkem č. 22 z roku 2009 (Government of Sri Lanka 2009). Krom zákonů existují ještě národní plány pro ochranu biodiverzity a konkrétně mořských želv, jako jsou například *National Conservation Strategy*, ale jejich implementace není dostatečná (de Silva 2006). Nadto je součástí ústavy šrilanské republiky v šesté kapitole o povinnostech občana uvedeno: chránit přírodu a její bohatství (Parliament of Sri Lanka 2022).

Další legislativa, kterou se Šrí Lanka zavazuje k ochraně mořských želv, je mezinárodní úmluva CITES (Convention on International Trade in Endangered Species of Wild Fauna and Flora), ke které přistoupila roku 1979 (Jayathilaka *et al.* 2017), a mezinárodní Úmluva o biologické rozmanitosti (Convention on Biological Diversity, CBD), ke které přistoupila roku 1992 (de Silva 2006). Všechny druhy mořských želv jsou uvedeny v Příloze I úmluvy CITES (CITES 2025) a na Červeném seznamu IUCN ohrožených živočichů jako *zranitelné*

(VU), *ohrožené* (EN) nebo *kriticky ohrožené* (CR). Jediná kareta plochá (Garman, 1880) je uvedena jako *taxon, u něhož chybí údaje* (DD) (IUCN Red list 2025g). V Příloze I Bonnské úmluvy (Convention on the Conservation of Migratory Species of Wild Animals) z roku 1979, jejíž členem je Šrí Lanka od roku 1990, jsou uvedeny všechny mořské želvy kromě karety ploché (Garman, 1880) z čeledi Cheloniidae. Zahrnuta je ovšem v Příloze II (CMS 2024).

Dále ochraně mořských želv napomáhá i spolupráce s mezinárodními organizacemi jako je například Indian Ocean Tuna Comission (Thilakarathne *et al.* 2024). Zároveň jsou mořské želvy zahrnuty v mnoha dokumentech týkajících se snížení jejich poměru jako vedlejšího úlovku (BMIS 2012).

5.3 Současná ohrožení mořských želv, další způsoby jejich ochrany a jejich nedostatky


V současné době je největším nebezpečím pro želvy nelegální pytláčení, srážky s plavidly, ničení habitatů a predace i sběr vajec (Thilakarathne *et al.* 2024). Často se též zamotávají do rybářských sítí přilákány ulovenými rybami nebo se zakousnou do háčků s pro ně atraktivní návnadou jako vedlejší úlovek (Jayathilaka *et al.* 2017). Podle průzkumu mezi léty 1999 a 2000 bylo jako vedlejší úlovek uloveno více než 5 000 želv, avšak dle odhadů by mohl být skutečný počet více než dvojnásobný, jelikož počet dotazovaných rybářů tvořil jen okolo 39 % (Kapurusinghe & Saman 2001).

I přes zavedenou legislativu jsou želvy stále terčem rybářů, kteří s částmi želv obchodují, ačkoliv v posledních dekáдах v mnohem omezenější míře (Kapurusinghe & Saman 2001, Jayathilaka *et al.* 2017, Thilakarathne *et al.* 2024). Zejména na odlehlých místech nejsou opatření na ochranu želv vymáhána. Rajakaruna *et al.* (2009) zaznamenali ve své studii u pětiny respondentů intenzivní zapojení do obchodování s želvími vejci či masem, a to nejvíce ve městech a vesnicích na západním a jihozápadním pobřeží. Co se konzumace vajec týče, ta je stále rozšířená zejména na západním pobřeží Šrí Lanky (Kapurusinghe & Saman 2001, Thilakarathne *et al.* 2024).

Podstatnou hrozbu představuje pro želvy i neekologické nakládání s odpady po celém ostrově včetně odpadu a hluku z lodní dopravy, dále pak světelné znečištění spojené s narůstající intenzitou turismu a degradace pláží (Arachchige *et al.* 2021, Svobodová *et al.* 2021). Do poslední kategorie patří i změna vegetačního složení pláží nebo úplné odstranění vegetace, jelikož želvy často vyhlubují hnízda těsně u horní hrany pláže s více méně souvislým pokryvem vegetace (Thilakarathne *et al.* 2024). Změna druhového složení vegetace nebo její úplná absence mění teplotní režim na plážích, což ovlivňuje poměr mezi pohlavími želvích mláďat (Ekanayake *et al.* 2002, Svobodová *et al.* 2021, Thilakarathne *et al.* 2024). Značný vliv měla pravděpodobně na populaci i havárie nákladní lodi X-Press Pearl poblíž šrilanských břehů začátkem června 2021, kdy zemřelo přes 150 želv a několik kytovců, ačkoliv souvislost mezi úmrtími a havárií nebyla nikdy oficiálně potvrzena (Rodrigo 2021).


Z ne-antropogenních hrozeb je nejvýznamnější predace divokými prasaty, ptáky, varany a introdukovanými divokými psy (Thilakarathne *et al.* 2024). V prosinci roku 2004 zasáhla Šrí Lanku i velkou část Indického oceánu tsunami, která pravděpodobně zničila veškeré již nakladené snůšky, ale překvapivě nebyly pozorované počty hnízdících želv po tsunami ve srovnání s předchozími i navazujícími roky nijak odlišné (Brodie *et al.* 2008).

Podle Rathnayake (2016) jsou pro želvy nejvíce lákavé k hnízdění pobřeží jižní a části jihozápadního a jihovýchodního, jak zachycuje mapa na následující stránce (vyznačeno modře, Obrázek 4).



Obrázek 4: Mapa z článku Rathnayake (2016) poskytnutá šrilanským Oddělením ochrany volně žijících živočichů a planě rostoucích rostlin (DWC). Jihozápadní, jižní a jihovýchodní pobřeží jsou želvami nejnavštěvovanější. Byly dopsány české názvy a poloha města Jaffna.

Na plážích Kosgody, Induruwy, Rekawy a Bundaly je v současnosti potvrzeno hnízdění všech pěti druhů mořských želv. Tamější vody jsou pro želvy lákavé zejména díky rozsáhlým plochám mořských luk a korálových útesů, nicméně kvůli velké zastavěnosti v blízkosti pláží a přítomnosti psů musí být hnízda želv vyhrabána a vejce přemístěna do záchranných stanic (Jayathilaka *et al.* 2017). Počet záchranných stanic se za posledních téměř třicet let různě měnil. Amarasooriya & Jayathilaka (1997) píše o devíti záchranných stanicích s líhněmi, Rajakaruna *et al.* (2013) píše o sedmi záchranných stanicích s líhněmi v okrese Galle na jihozápadě Šrí Lanky, zatímco Jayathilaka *et al.* (2017) i Svobodová *et al.* (2021) udávají 15 stanic. Za využití Map Google a vyhledání pojmu *sea turtle hatcheries* se v současnosti zobrazí více než 20 výsledků. Na mapě níže (Obrázek 5) jsou zachyceny záchranné stanice s líhněmi v Jižní provincii Šrí Lanky (Thilakarathne *et al.* 2024).



Obrázek 5: Mapa Šrí Lanky zachycující její Jižní Provincii, kde se nachází velká část záchranných stanic různého typu. *Ex situ* záchranné stanice s líhněmi jsou znázorněny modrým trojúhelníkem. Místa, kde jsou želvy chráněny *in situ* ve svém přirozeném prostředí jsou znázorněna kolečky různých barev s tečkou. Převzato z Thilakarathne *et al.* 2024.

Do těchto stanic s líhněmi jsou přemísťovány snůšky z různě vzdálených lokalit, jsou zahrabávány do vyhrazené oblasti, ovšem ne vždy s dostatečným rozestupem mezi jednotlivými hnízdy (Phillott *et al.* 2018). Rovněž původ vajec (odkup od pytláků či vlastní sběr) v líhních je často nejistý; snůšky jsou často pomíchány sběrači, kteří je přiváží do líhní a prodávají, a mezi sběrem na pláži a dodání líhním uplyne mnoho hodin až dní, což prokazatelně snižuje úspěšnost vylíhnutí (Phillott *et al.* 2018). Podle výnosu Fauna and Flora Protection Ordinance a jeho dodatku z č. 49 z roku 1993 je navíc obchodování s vejci za jakýmkoliv účelem nelegální (Government of Sri Lanka 1993). Přestože primárním cílem bylo chránit želví vejce a dopomoci vylíhnutí co možná největšímu množství želvích mláďat, Amarasooriya (2000) odhaduje, že počty želvích vajec v líhních jsou třetinové oproti skutečnému množství nakladených vajec, a že zbylé dvě třetiny jsou zkonsumovány. Přitom dle několikaletého průzkumu počtu hnízdicích želv na jižním pobřeží Šrí Lanky celkové počty nakladených vajec dosahují pravidelně každý rok statistických hodnot (Jayathilaka *et al.* 2017). Problematický je i způsob hodnocení úspěšnosti líhnutí jednotlivých hnízd v líhních spočítáním vylíhnutých jedinců bez zohlednění počtu nevylíhnutých vajec zbylých v hníždě. Takovýto postup značně podkopává věrohodnost informací, které je možné z líhní získat (Phillott *et al.* 2018).

Ve stanicích není vždy o čerstvě vylíhnuté želvy správně postaráno, mladé želvy jsou ponechávány v bazéncích se stojatou vodou (Obrázek 6), což způsobuje špatný vývin svalstva a plic a po vypuštění do volného moře želvy rychle hynou (Phillott *et al.* 2018, Svobodová *et al.* 2021). Kapurusinghe (2012) ve své studii píše, že mláďata želv zadržovaná v bazénech stráví první den plaváním bez krmení se, další den naopak tráví jen krmením a plavou méně. Pokud jsou tedy třetí den mláďata vypuštěna, místo toho, aby odplavala z pobřežních vod na relativně bezpečnější otevřený oceán, zůstávají při břehu, kde jsou mnohem více ohrožena predátory.



Obrázek 6: Fotografie dvou různých bazénků z jedné z navštívených záchranných stanic s líhněmi v rámci této práce. Mladé želvy různého věku jsou v několika málo centimetrech vody v zastřešeném prostoru bez umělého osvětlení a příliš se nepohybují. Návštěvníci na ně mohou sahat a případně vzít do ruky.

Toto má negativní dopad i na migrační schopnost želv, které se při pozdním vypuštění do moře hůře orientují (Okuyama *et al.* 2009, Rathnayake 2016). Turistům je dovolováno mladé želvy vybírat z mělkých bazénků a nosit je na pláž. Nejpravděpodobnějším důvodem, proč všechny tyto praktiky zadržování mláďat stále pokračují i přes jednoznačné nevýhody pro ochranu, je přilákání turistů, kteří jsou důležitým zdrojem financí stanic (Rathnayake 2016, Phillott *et al.* 2018, Svobodová *et al.* 2021).

Sami turisté jsou často pro mořské želvy spíše hrozbou, a to spíše kvůli nedbalosti než přímému úmyslu ublížit. Často ignorují rozmístěné informační cedule v záchranných stanicích *in situ*, které zakazují dotýkat se a vyrušovat želvy (viz Obrázek 7 níže).



Obrázek 7: Informativní cedule pro návštěvníky ve dvou jazycích. První dvě zleva pochází ze záchranné stanice Rekawa na stejnojmenné pláži, cedule vpravo pochází z pláže v Dikwelle poblíž města Batigama. Na obou místech jsou želvy chráněny *in situ*, v Rekawě též *ex situ*. Na obou místech jsem byla svědkem bezostyšného porušování všech pravidel a zákazů uvedených na cedulích.

Mnohdy ovšem nedbají přímých pokynů zdejších rančerů a ochranářů a jednají v přímém rozporu s tím, co jim bylo nakázáno (např. fotí v noci kladoucí želvy bleskem mobilního telefonu), navíc z bezprostřední blízkosti (nepublikovaná data).

5.4 Možná řešení problémů v ochraně želv na Šrí Lance

Efektivní ochrana začíná shromážděním dostatečného množství kvalitní dat, jejich analýzou a z ní vyvozených postupů. Přesně takové analýzy a data zde zatím chybí, ač se na Šrí Lance nachází několik vládních i nevládních institucí, jež by se tohoto úkolu mohly chopit (Thilakarathne *et al.* 2024). Mezi nimi jsou univerzity, NARA (National Aquatic Resources Research and Development Agency), zabývající se zejména výzkumem, dále mezinárodní organizace jako jsou IOTC (Indian Ocean Tuna Commission), IUCN, WCS (Wildlife Conservation Society), nespočet menších neziskových organizací jako například Blue Resources Trust, Sri Lanka Turtle Conservation Project a mnoho dalších (Thilakarathne *et al.* 2024).

Je zde i možnost zapojení dobrovolníků, kteří na Šrí Lanku přijíždí pomáhat s ochranou mořských želv (H. Svobodová, osobní komunikace).

Pro ochranu mořských želv je rovněž důležitý přístup rybářů. Pokud si rybáři neosvojí ekologičtější a udržitelnější způsoby lovu, pak se nepodaří snížit mortalitu želv jako vedlejšího úlovku (Thilakarathne *et al.* 2024). Způsobem, jak napomoci změně v praktikách rybářů, je jejich vzdělávání, a zároveň vzdělávání veřejnosti, o což se stará NARA (National Aquatic Resources Research and Development Agency), která pořádá různé vzdělávací programy (Jayathalika *et al.* 2017). Pokud budou obyvatelé pobřeží seznámeni s důležitostí mořských želv a jejich role v mořských ekosystémech a se způsoby dlouhodobě udržitelného využívání mořských zdrojů, pak by mohli být sami motivováni se držet praktik, které tolik neškodí mořskému prostředí (Thilakarathne *et al.* 2024). Zároveň je nutno zmínit, že mnozí místní občané závisí na mořských želvách jako na zdroji obživy, často bez možnosti alternativních zdrojů. Těmto lidem, kteří se živí především jako pytláci a překupníci s vejci, je nutno nabídnout možnosti jiných způsobů obživy (Phillott *et al.* 2018). Neméně důležité je i vzdělávání turistů, kteří často navštěvují ty záchranné stanice, které neplní svou úlohu ochrany a uchylují se k lákání nevzdělaných návštěvníků. Vhodné by bylo rozšiřování povědomí o správném zacházení s mořskými želvami ve všech státech, aby turisté tyto stanice nenavštěvovali.

V záchranných stanicích fungujících na principu *in situ*, kdy chrání želvy v jejich prostředí, jako je například Rekawa či Kapuhenwalla, jsou po areálu stanice rozmístěny informační cedule nejen v anglickém jazyce. Ty informují návštěvníky o druzích hnízdících na Šrí Lance, výzkumu, jejich roli v ekosystémech a jejich ohroženích (nepublikovaná data).

Spolupráce pobřežních komunit z měst a vesnic je při ochraně mořských želv klíčová. Jelikož nejsou zákony dostatečně vymáhány nejen z důvodu nedostatku lidských sil, je nutné zahrnout do ochrany právě pobřežní komunity (de Silva 2006).

Příkladem fungující ochrany zapojující pobřežní komunity a turismu je chráněná pláž Rekawa v Jižní Provincii v okrese Hambantota. Její úspěch se pojí se vznikem významné šrílanské nevládní organizace Turtle Conservation Project (dále jako TCP), založené roku 1993. Začala spolupracovat s místní komunitou a podnikala všechny kroky k vylepšení vztahu mezi chudým obyvatelstvem a zdrojovými mořskými ekosystémy. Tak vznikla

Turtle Watch Rekawa, turistická atrakce, kdy turisté platí určitou částku za možnost celovečerního sledování kladení vajec želvami (Kapurusinghe 2012, nepublikovaná data). Podle IUCN (2005) jde o skvělý habitat pro mořské želvy a roku 2006 ji DWC, IUCN a TCP prohlásili za chráněné území podle FFPO a všech jejích dodatků (Government of Sri Lanka 1938, Rathnayake 2016).

Přínosem je pro ochranu želv i vyhlásování důležitých území za chráněná. Dle studie Jayathalika *et al.* (2017) by měla být několikakilometrová pláž mezi městy Kosgoda a Induruwa na jihozápadním pobřeží, kde jsou zaznamenávány vysoké počty zahníždění karet, vyhlášena za chráněnou. Vyhlášení území za chráněné totiž znemožňuje developerům na těchto územích stavět, a chrání tak prostředí želv (Government of Sri Lanka 1938).

Významnou pomocí v ochraně mořských želv bylo vyhlášení *National Environmental Action Plan and Turtle Conservation Action Plan* roku 2022, jenž je rozdělen do devíti Strategií. Ve Strategii 2 je uveden Krok (orig. *Actions*) 3.2, jehož cílem je „zajistit ochranu hnízdištěm mořských želv a jejich líhním“. Rozpočet tohoto kroku činí deset milionů šrilanských rupií, hlavní zodpovědnou agenturou je Oddělení ochrany volně žijících živočichů a planě rostoucích rostlin (Department of Wildlife Conservation, dále jako DWC) s několika dalšími uvedenými klíčovými agenturami, mezi nimi i NARA. Dílčími kroky jsou pak: očíslování a vytvoření seznamu všech hnízdišť, registrace všech líhní se správným přístupem k mláďatům, implementaci legislativy potřebné k posílení managementu a osvěta komunit a ostatních zúčastněných stran při ochraně mořských želv (Government of Sri Lanka 2022). Za zvláštní zmínku z tohoto dokumentu stojí snaha o implementaci legislativy týkající se ochrany želv. Jayathalika *et al.* (2017) píše o potřebě vytvořit směrnice o fungování a oprávnění líhní a dohlédnutí na dodržování již existujících zákonů. Podle Phillott *et al.* (2018) je potřeba rovněž zkrátit dobu prevozu vajec mezi nakladením a předáním záchrané stanici s líhněmi a omezit manipulaci s nimi. Málokde se dbá na dodržení rozestupů mezi novými hnízdy a na dostatečnou hloubku hnízda, jenž má vliv na výsledný poměr pohlaví a zamezuje potenciálnímu přenosu infekcí (Svobodová *et al.* 2021). Zanedbávané bývá i značení hnízd popiskem druhu, datem nakladení a počtem vajec. Líheň splňující tyto podmínky je zachycena na fotografii níže (Obrázek 8).



Obrázek 8: Fotografie oblasti vymezené pro přenesená vejce v jedné ze záchranných stanic s líhněmi ve městě Koggala. Jde o *ex situ* ochranu mořských želv. Pro vzdálenost ode mě nebylo možné přesně určit rozestupy mezi hnízdy a neznámá byla i hloubka oněch hnízd. Problematické je celkové provedení této oblasti, jelikož je kvůli ohrazení a pletivu nutno mladé želvy vzít do ruky a odnést.

Toto přemísťování vajec (a případné držení zraněných jedinců v bazéncích do vyléčení) je příkladem *ex situ* ochrany, která je na Šrí Lance spíše problematická, zaměřená spíše na zisk z turismu (Kapurusinghe 2012).

Jako úspěšná metoda *in situ* ochrany se ukázaly síťované klece umístěné přímo nad hnízdo s dostatečně velkými oky, aby se vyhrabávající se mláďata dokázala dostat skrz (Phillott *et al.* 2018). Přínosem pro želvy Šrí Lanky by mohlo být i rozvinutí eko-turismu (Jayathalika *et al.* 2017), zde je ovšem riziko, že provozovatelé se uchýlí k zakázaným praktikám s vidinou většího zisku (Kapurusinghe 2012, Phillott *et al.* 2018). V případě eko-turismu je důležité minimalizovat množství chovaných želv a neponechávat v záchranných stanicích zdravé jedince nebo jedince s takovými zraněními, se kterými dokáží přežít bez lidské péče (Phillott *et al.* 2018).

6. Základy strojového učení

Strojové učení má v současné době velké množství aplikací a velkou roli v něm hrají neuronové sítě, kterých je několik druhů. Jsou často využívány k rozpoznávání obličejů a tvarů, řeči, překládání textu či detekci neobvyklých tvarů a mnohému dalšímu (Goodfellow *et al.* 2016). Jejich schopnosti rozpoznávat tvary a vzory jsou využívány velkými společnostmi jako jsou Google (Goodfellow *et al.* 2016), v ekonomickém sektoru (Sharkawy 2020), ve zdravotních oblastech při vyšetřeních a diagnózách (Sharkawy 2020, Kufel *et al.* 2023) a v přírodních vědách věnujících se výzkumu živočichů pro rozpoznávání jedinců i druhů (Tabak *et al.* 2019, Tan *et al.* 2021, Zhang *et al.* 2023).

Strojové učení se aplikuje na data sety, které jsou příliš obsáhlé, než aby je dokázal efektivně zpracovat lidský mozek. Cílem neuronové sítě je pomocí algoritmů nacházet vzory a spojitosti ve velkém množství dat, která musí být označena štítky, jenž je blíže popisují a mohou představovat například identitu jedince, datum, orientaci a další. Pro vylepšení výkonu algoritmů strojového učení se využívá tzv. trénování. Algoritmy umělého učení tak umožňují bez dalšího programování provádět rychlejší a lepší rozhodnutí za kratší dobu. Modely strojového učení jsou trénovány tak, aby byly predikce (tj. predikované štítky) co nejblíže skutečným štítkům. Zároveň jsou tyto modely tvořeny obvykle velkým množstvím neuronů, které jsou uspořádány do početných vrstev, a proto se označují jako neuronové sítě. Tyto neuronové sítě obsahují parametry, které mohou být na základě rozdílů mezi predikovanými a skutečnými štítky upravovány (Goodfellow *et al.* 2016).

Vstupní hodnoty, jež každý neuron obdrží, jsou zpracovány a předány neuronům v další vrstvě, které operují paralelně. Takovémuto druhu strojového učení, kdy je analyzováno velké množství dat za použití mnoha vrstev neuronů, se říká *hluboké učení* (Nielsen 2015, Goodfellow *et al.* 2016). Počáteční vrstvy neuronových sítí extrahují jednodušší informace jako například hrany nebo rohy a pozdější vrstvy neuronových sítí je spojují do složitějších informací (např. hlava). Existuje mnoho modelů, které jsou schopny extrahovat obecnou informaci, jako například EfficientNet (Koonce 2021) nebo Dino (Fan 2024). Já se zaměřila na model MegaDescriptor, který je specializován na detekci a identifikaci jednotlivých jedinců zvířat (Adam *et al.* v tisku).

Existuje mnoho typů neuronových sítí. V práci popíšu pouze plně propojené sítě a konvoluční sítě (Goodfellow *et al.* 2016). Další sítě jako například rekurentní (Sharkawy 2020) nebo transformery (Castangia 2023) jsou mimo rozsah této práce. Všechny tyto sítě ale mají společné následující:


- skládají se z vrstev skládajících se z neuronů,
- vrstvy jsou uspořádány sekvenčně a pouze sousední vrstvy spolu komunikují.

6.1 Plně propojené sítě

Umělé neuronové sítě fungují na podobném principu jako jejich biologické protějšky, kterými jsou inspirovány (Goodfellow *et al.* 2016, Kufel *et al.* 2023). Biologický neuron, který tvoří nervovou soustavu, se skládá z těla (soma) a axonu (neurit). Z těla i axonu vybíhají větvené výběžky, ty vybíhající z těla se nazývají dendrity a slouží k přijímání vzruchů od sousedících buněk. Větvené výběžky axonu naopak slouží k přenosu vzruchu na sousední buňky. Spojení mezi buňkami se nazývají synapse. Příchozí vzruch tak projde přes tělo neuronu do zúžené části na pomezí těla a axonu zvané iniciální segment, kde dochází ke sčítání vzruchů z dendritů a podle toho k následnému šíření či inhibici vzruchu. Následuje samotný axon končící rozvětvením.

Na principu vstupů a výstupů fungují i umělé neurony (Kufel *et al.* 2023). Avšak přibližování se biologické stavbě při vytváření neuronových sítí nevede vždy ke zlepšenému výkonu, a navíc není biologické učení ještě dostatečně prozkoumáno, a tak nelze biologické systémy plně využít k modelování umělých neuronových sítí (Goodfellow *et al.* 2016).

Typicky jsou propojené neurony uspořádány do mnoha vrstev, z nichž první je vstupní a poslední je výstupní. Vrstvy mezi nimi se nazývají skryté (Nielsen 2015). Na Obrázek 9 níže vidíme matematický model nejjednodušší neuronové sítě o jediném neuronu, tzv. *perceptron*:



Obrázek 9: Matematický model perceptronu, převzato z portal.matematickabiologie.cz (2024).

Přicházející vzruchy tu představují vstupy $x_1, \dots, x_n$ a $w_1, \dots, w_n$ jsou umělé váhy. Hodnoty vstupů se poté násobí s příslušnými hodnotami vah, výsledné hodnoty jsou sečteny a je od nich odečtena hodnota prahu h . Rovnici takového výpočtu zapisujeme následovně:

$$\xi = \sum_{i=1}^n x_i w_i - h$$

Práh (také nazývaný *bias*) představuje hodnotu, kterou musí výsledek součet součinů vstupů a vah převyšovat, pokud má dojít k aktivaci umělého neuronu (Nielsen 2015). Pokud výsledek jeho hodnotu nepřevýší, pak zůstane neuron neaktivovaný.

Další důležitou částí neuronových sítí jsou aktivační přenosové funkce, které definují výstup a aplikují se na výsledek předchozí rovnice (Bishop 2006, Nielsen 2015). Aktivačních přenosových funkcí je několik typů, například skoková funkce, hyperbolický tangent, ReLU či sigmoid a vždy jde o nelineární funkci (Bishop 2006). Některé aktivační přenosové funkce (jako např. ReLU) se aktivují pouze při překročení určité hodnoty. Zápis skokové funkce je následující:

$$\sigma = \begin{cases} 1 & \text{jestliže } \xi \geq 0, \\ 0 & \text{jestliže } \xi < 0. \end{cases}$$


Tato funkce přesně je aproximací aktivace neuronu, kdy je neuron buď aktivován (hodnota 1) nebo není (hodnota 0). Protože ale tato funkce není spojitá, tak se vůbec nepoužívá, a je nahrazena spojitými aproximacemi. Jedna z prvních aproximací byla funkce sigmoid, která modifikuje skokovou funkci na okolí nuly. Protože má ale derivace blízké nule na většině definičního oboru, tak způsobuje určité problémy při trénování neuronových sítí a též se nepoužívá.

Jednou z nejvíce využívaných nelineárních funkcí pro učení neuronových sítí je již výše zmíněná funkce ReLU (Nielsen 2015). Zkratka vychází ze slov *rectified linear unit*, její vzorec je následující:

$$f(x) = \max(0, x)$$

kde x je hodnota vstupní a $f(x)$ je výstupní.

Výše byla popsána nejjednodušší neuronová síť o jediném neuronu. V neuronových sítích využívaných na analýzy velkého množství dat je ovšem také velké množství neuronů, a to ve všech vrstvách (vstupní, skrytých, výstupní). Neurony ve vrstvách spolu komunikují předáváním vážených výsledků a tvoří dopředné neuronové sítě. Na obrázku níže (Obrázek 10) je zachycena tzv. plně propojená neuronová síť složená z plně propojených vrstev, kdy jsou všechny neurony navzájem propojeny a komunikují spolu. Vzájemné propojení a komunikace jsou znázorněny úsečkami, jenž mají své váhy. Tato konkrétní síť má čtyři vrstvy, z nichž je jedna vstupní (levý sloupec), jedna výstupní (pravý sloupec) a dvě jsou skryté (sloupce uprostřed). Jak bylo uvedeno výše, pouze sousední vrstvy spolu komunikují (jsou spojeny úsečkami).




Obrázek 10: Dopředná plně propojená neuronová síť o čtyřech vstupních neuronech (vlevo – modře), dvou skrytých vrstvách a dvou výstupních neuronech (vpravo – zeleně). Převzato ze Zhou 2019.

6.2 Konvoluční síť

Konvoluční neuronové sítě jsou vhodné především pro analýzu vizuálních dat, jako jsou fotografie či videozáznamy (Ye *et al.* 2015). Důvodů jejich rozšířeného využívání je několik, například jejich schopnost extrahovat znaky s odlišnou hierarchií a rozpoznávat na poskytnutých datech nejprve hrany a v pokročilejších vrstvách tvary a objekty. Zároveň jsou schopné poznávat znaky i při posunu či rotaci fotografovaného objektu. Další výhodou je i jejich relativní jednoduchost oproti plně propojeným sítím, jelikož využívají mřížkový filtr na oblast poskytnutých dat a neanalyzují každý pixel jednotlivě (Cong & Zhou 2023). Jejich další výhodou je relativně malý počet vah (úseček na Obrázek 9). Například kdyby plně propojena síť měla jako vstupní vrstvu obrázek velikosti 2000×3000 pixelů (tedy vrstva by měla 6 miliónů neuronů) a první skryta vrstva měla velikost 1 milión neuronů, tak by tato síť potřebovala 6 biliónů vah, které by bylo nutné učit. Konvoluční síť tento počet parametrů obchází tím, že uvažují pouze lokální informaci obsaženou v dvojrozměrné mřížce zvané jádro, tedy propojuje pouze pixely, které jsou na obrázku blízko.

Stavba konvoluční neuronové sítě je variabilní, nicméně obvykle se skládá ze vstupní vrstvy, jíž je fotografie, a následuje ji několik střídajících se konvolučních vrstev a tzv. *pooling layers*, které budou popsány níže. Po nich následuje jediná plně propojená vrstva, která vstupní data klasifikuje do několika výstupů (Bishop 2006, Nielsen 2015). Zároveň je v konvoluční neuronové síti využívána aktivační funkce (například ReLU).

V konvolučních vrstvách se převádí pixely na číselné hodnoty, které představují neurony sítě – například bílá barva pixelu je znázorněna číslem 0, černá barva číslem 1 a odstíny šedé mají rozsah mezi – a z nich jsou extrahovány vzory. Na vstupní konvoluční vrstvy je aplikováno jádro, které vytváří na fotografii *feature map* (Goodfellow *et al.* 2016). *Feature maps* jsou vymezené oblasti na původní fotografii, hodnoty v této oblasti se následně násobí s hodnotami v mřížce jádra (Obrázek 11), jejíž obsah se odvíjí od toho, jak chceme data analyzovat či upravit (například zaostření či rozmazání fotografií). Tímto procesem dochází ke zmenšení rozměrů výsledku. Pokud máme vstupní fotografii o rozměrech 28×28 neuronů a jádro o rozměrech 5×5 , pak můžeme tímto jádrem posunout po vstupních datech pouze 24krát, než nedosáhneme okraje fotografie. Výsledkem je tedy výsek fotografie, který je v tomto případě o čtyři pixely-neurony menší než vstup. Následně se tato mřížka posune po vstupní fotografii na další oblast. Toto se opakuje, dokud není analyzována celá fotografie a výsledkem je mřížka hodnot (Nielsen 2015).




Obrázek 11: Znázornění konvoluční vrstvy, kde jsou neurony představeny čtverci s písmeny; vstupní *feature map* a jádro, které se mezi sebou násobí (Goodfellow *et al.* 2016).

Vizuálně lze konvoluční neuronové síť znázornit jako dvojrozměrnou síť neuronů, oproti výše popsané plně propojené síti, která je znázorněna jako jednorozměrný sloupec neuronů. V plně propojené síti byly neurony znázorněny kolečky, na Obrázek 11 jsou neurony znázorněny čtverci s písmeny. Obdobou vah/spojení (úseček na Obrázek 9) je zde jádro, které „skáče“ po dvojrozměrné neuronové síti předem nastaveným způsobem (velikostí kroku) (Nielsen 2015). Velikost tohoto „kroku“ (anglicky *stride*) je specifikovatelný parametr. Komplettní zobrazení modelu konvoluční neuronové sítě je na Obrázek 11.

Po konvoluční vrstvě obvykle následuje *pooling layer*, kde dochází ke zjednodušení zhuštěním výsledku konvoluční vrstvy, a to zprůměrováním či získáním maxima (Nielsen 2015). Při použití *pooling layer* o velikosti 2×2 neuronů dojde ke zmenšení výsledné mřížky na polovinu. Pokud tedy vstupní fotografie měla rozměry 28×28 neuronů-pixelů, po zpracování první konvoluční vrstvou s velikostí kernelu 5×5 neuronů bude mít výsledná vrstva 24×24 neuronů. Výsledkem navazující *pooling layer* o velikosti 2×2 neuronů bude síť o velikosti 12×12 (Nielsen 2015).

Konvoluční vrstvy sítě mívají různé velikosti vstupu, výstupu a mohou mít i jinou velikost jádra. Různí se i počet kanálů. Pokud je vrstva černobílý obrázek, tak má jeden kanál, pokud je obrázek barevný, tak má tři kanály, které jsou RGB (poměr červené, zelená a modré) reprezentací pixelu (Bishop 2006). Výše jsme ukázali, že konvoluční vrstva snižuje velikost obrázku. Zároveň většinou zvětšuje počet kanálů, které už v dalších vrstvách (na rozdíl od vstupní) nemají jednoduchou reprezentaci. Obrázek 12 ukazuje příklad konvoluční vrstvy zvětšující počet kanálů.

Po poslední konvoluční (či *pooling*) vrstvě většinou následuje jedna nebo vícero plně propojených vrstev, kdy výstup poslední plně propojené vrstvy má stejný počet neuronu jako je tříd v data setu. Zde též dochází ke klasifikaci, kdy jsou analyzovaná data, fotografie, roztržena do existujících tříd (např. přiřazení nejpravděpodobnějšího štítku k analyzovanému písmenu či číslice). Klasifikace může být buďto binární o dvou konečných třídách, kdy výstup má hodnotu 0 nebo 1, anebo může být vícetřídová klasifikace. Pokud bychom měli daný počet finálních tříd se štítky, pak model spočítá podobnost mezi vektory analyzovaných dat a dříve analyzovanými daty, popřípadě databází. Čím větší je hodnota pro výstupní neuron, tím větší je pravděpodobnost, že vstupní obrázek reprezentuje danou třídu. Pokud má data set například 100 jedinců, poslední vrstva bude mít 100 neuronů a pokud má první neuron vysokou hodnotu, vstupní obrázek bude pravděpodobně obsahovat jedince, který je reprezentován jako první (Nielsen 2015).



Obrázek 12: Kompletní model konvoluční neuronové sítě. Jsou znázorněny tři konvoluční vrstvy s jádrem a střídající se *pooling* vrstvy, na kterou navazuje plně propojená vrstva klasifikující vstupní data (Haque 2023).

6.3 Učení neuronových sítí

Nedílnou součástí analýz dat pomocí neuronových sítí je jejich učení pomocí algoritmů. Učení neuronových sítí spočívá v přibližování se predikovanými hodnotami, jež jsou výsledkem neuronové sítě, ke skutečným štítkům, které jsou v poskytnutých datech. Modely neuronových sítí jsou programovány tak, aby byly výsledné predikce (tj. predikované štítky) co nejblíže těm skutečným. Tyto neuronové sítě obsahují parametry, které mohou být na základě rozdílů mezi predikovanými a skutečnými štítky upravovány. Čím bližší je hodnota predikce ke skutečnému štítku, tím efektivnější je trénování neuronové sítě, tím přesnější bude její schopnost nacházet vzory a spojitosti v nových datech a tím rychleji a lépe bude neuronová síť operovat. Úspěšně natrénovanou síť je možno poté využít při analýze dalších data setů (Nielsen 2015).

Zde následuje matematický zápis výše popsaného. Necht' má data set n bodů, kde každý bod je reprezentován obrázkem x_i a štítkem y_i . Označme dále parametry neuronové sítě jako w (tedy parametry jsou buď váhy pro plně propojené sítě, nebo parametry jádra pro

konvoluční síť) a jako $\text{pred}(w, x_i)$ predikci pro obrázek x_i . Máme-li nakonec ztrátovou funkci loss , která je malá pro podobné hodnoty a velká pro rozdílné hodnoty, tak matematicky trénování neuronové sítě můžeme zapsat jako minimalizaci funkce:

$$m_w = \frac{1}{n} \sum_{i=1}^n \text{loss}(y_i, \text{pred}(w, x_i))$$

V této funkci máme průměr všech bodů data setu, to znamená, že každý bod data setu přispívá rovnoměrně do trénování. Protože funkce loss má malou hodnotu pro stejné argumenty, minimalizace m_w se snaží k sobě přiblížit hodnoty y_i a $\text{pred}(w, x_i)$, tedy hodnoty skutečného štítku a jeho predikce. Z toho vyplývá, že dobře natrénovaná síť (s malou hodnotou m_w) bude dobře predikovat štítky.

Toto trénování má za úkol naladit parametry w , tak aby síť dobře predikovala štítky, což se provádí zvolením vhodných parametrů w . Vhodné parametry w jsou získávány metodou *gradient descent*, která v každé iteraci – která představuje každý jednotlivý krok udělaný k lepšímu výsledku – spočítá derivaci funkce m_w . Jelikož derivace je směr největšího růstu funkce, pohne se v každé iteraci v opačném směru k této derivaci. Protože tento směr odpovídá směru největšího poklesu m_w , dochází k minimalizaci této funkce. Velikost posunu v tomto směru je označován jako *learning rate* (Goodfellow et al. 2016).

Tento algoritmus by byl ale výpočetně příliš náročný, neboť v každé iteraci by se musel spočítat průměr přes celý data set, který může obsahovat milióny bodů. Z toho důvodu se od *gradient descent* přechází k metodě *stochastic gradient descent* (Goodfellow et al. 2016), kde je není počítána derivace na celém data setu (průměr všech bodů v m_w), ale pouze na tzv. *batch* (průměr přes například 32 hodnot v m_w). Toto má následek nepřesný gradient, ale jeho výrazně rychlejší výpočet, který se provádí přes specializovaný algoritmus zvaný *backpropagation* (Bishop 2006, Goodfellow et al. 2016).

6.4 Ztrátovost a funkce `CrossEntropyLoss`

Ztrátovost souvisí s tvořením predikcí. Vstupní data jsou funkcí `CrossEntropyLoss` zpracována a výsledky jsou porovnány se skutečnými štítky. Také je zakončena funkcí `softmax`, jejíž zápis je následující:

$$\sigma(z) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

kde z_i představuje i -tý prvek vstupního vektoru, e je exponenciální funkce a K je počet tříd. Každý jednotlivý výstup funkce `softmax` se nachází v rozmezí hodnot 0 až 1 a jejich součet je vždy 1. Její úlohou je převádění vstupních hodnot do pravděpodobností, což je užitečné zejména při klasifikaci s více než dvěma konečnými třídami (Nielsen 2015). Toho se využívá například v medicínských oborech, při detekci vad výrobků, analýzách řeči či právě u identifikace jedinců (Pundlik *et al.* 2016., Silva *et al.* 2021).

Výše byla zmíněna obecná ztrátová funkce *loss*, jedna z jejích variant je `CrossEntropyLoss`. Jde o ztrátovou funkci běžně využívanou ve strojovém učení, především při měření spolehlivosti klasifikačních modelů. Funkce `CrossEntropyLoss` kvantifikuje rozdíly mezi dvěma pravděpodobnostmi a umožňuje jejich lepší porovnatelnost. Může jít například o porovnání skutečných štítků dat a výstupních pravděpodobností funkce `softmax`. Využívání `CrossEntropyLoss` zlepšuje výkonnost modelů jejichž součástí je právě tato funkce (Nielsen 2015, Goodfellow *et al.* 2016).

6.5 Vytváření modelu neuronové sítě v programu PyTorch

Tato podkapitola obsahuje vytváření modelu konvoluční neuronové sítě při mém vlastním učení se programování v jazyce Python, abych lépe porozuměla své práci. Pro analýzy zde byl využit data set MNIST obsahující 70 000 obrázků ručně psaných číslic (LeCun *et al.* 2024).

Před samotným modelováním neuronové sítě je nutno stáhnout balíčky s funkcemi, které při tom budeme využívat a importovat data set. Důležité je rozdělení data setu na učící (trénovací) podmnožinu a testovací podmnožinu s tím, že trénovací podmnožina by měla být nadpoloviční. Trénovací podmnožina je následně využita pro trénování data setu a testovací pro testování. Pokud bychom data set nerozdělili na tyto dvě podmnožiny, pak by nebylo možné zjistit spolehlivost neuronové sítě a její schopnosti se učit, jelikož by byla k testování využita stejná data jako k učení a nemohli bychom data správně analyzovat. Výsledky by tedy byly bezvýznamné a jednoduše by docházelo k tzv. nadměrnému přizpůsobení (anglicky *overfitting*), kdy může dojít k selhání při využití neuronové sítě na jiném data setu (Dietterich 1995).

Následně se vytvoří model neuronové sítě, je zadán počet vrstev, jejich parametry a propojení. Počet výstupních neuronů poslední vrstvy by se měl shodovat s počtem tříd.

```
class ConvolutionalNetwork(nn.Module):
    def __init__(self):
        super().__init__()
        self.conv1 = nn.Conv2d(1, 6, 3, 1)
        self.conv2 = nn.Conv2d(6, 16, 3, 1)
        self.fc1 = nn.Linear(5*5*16, 120)
        self.fc2 = nn.Linear(120, 84)
        self.fc3 = nn.Linear(84, 10)

    def forward(self, X):
        X = F.relu(self.conv1(X))
        X = F.max_pool2d(X, 2, 2)
        X = F.relu(self.conv2(X))
        X = F.max_pool2d(X, 2, 2)
        X = X.view(-1, 16*5*5)
        X = F.relu(self.fc1(X))
        X = F.relu(self.fc2(X))
        X = self.fc3(X)
```

```
return F.log_softmax(X, dim=1)
torch.manual_seed(41)
model = ConvolutionalNetwork()
criterion = nn.CrossEntropyLoss()
optimizer = torch.optim.Adam(model.parameters(), lr=0.001)
epochs = 5
train_losses = []
test_losses = []
train_correct = []
test_correct = []
for i in range(epochs):
    trn_corr = 0
    tst_corr = 0
    for b, (X_train, y_train) in enumerate(train_loader):
        b+=1
        y_pred = model(X_train)
        loss = criterion(y_pred, y_train)
        predicted = torch.max(y_pred.data, 1)[1]
        batch_corr = (predicted == y_train).sum()
        trn_corr += batch_corr
        optimizer.zero_grad()
        loss.backward()
        optimizer.step()
        if b%600 == 0:
            print(f'Epoch:    {i}    Batch:    {b}    Loss:
                  {loss.item()}')
    train_losses.append(loss)
    train_correct.append(trn_corr)
with torch.no_grad():
    for b, (X_test, y_test) in enumerate(test_loader):
```



```
y_val = model(X_test)
predicted = torch.max(y_val.data, 1)[1]
tst_corr += (predicted == y_test).sum()
loss = criterion(y_val, y_test)
test_losses.append(loss)
test_correct.append(tst_corr)
```

Funkce *class* vytváří třídu, model konvoluční neuronové sítě, za využití konstruktoru `__init__`. Na dalších dvou řádcích je vytvořen pár dvourozměrných konvolučních vrstev a jsou udány jejich parametry. První konvoluční vrstva zobrazuje z jednoho do šesti kanálů a její konvoluční jádro má velikost 3×3 . Dále jsou specifikovány i plně propojené sítě, které byly uloženy do proměnných *self.fc*. Zde se výstupy předchozí vrstvy musí shodovat se vstupy následující vrstvy.

Po zadání parametrů neuronové sítě následuje výběr dopředné aktivační funkce a zadání jejích parametrů. V této práci byla využita dopředná aktivační funkce ReLU. Je vytvořena instance a následně je nastaven optimalizátor *loss optimizer*, jehož úkolem je optimalizovat ztrátu během trénování, které bude následovat. Ke sledování ztrátovosti modelu se využívá funkce *criterion*, která vyhodnocuje spolehlivost neuronové sítě během učení tak, že měří rozdíl mezi očekávaným výsledkem a skutečnými hodnotami. Čím větší má parametr *CrossEntropyLoss* hodnotu, tím méně je model spolehlivý a tím větší je chybovost. Zároveň je nastaveno *learning rate (lr)*, které ovlivňuje rychlost učení modelu.

Následuje samotné trénování modelu. Nejprve je nastaven počet epoch, kdy jedna epocha je jedno zpracování analyzovaných dat modelem, a jsou vytvořeny prázdné seznamy, ke kterým budou po zapnutí modelu přidávány hodnoty chyb a správných výsledků. Poté je vytvořeno tzv. *for loop* a nastavena velikost *batch*. *For loop* funguje jako smyčka stále se opakujícího kódu dokud nedojde k ukončení, ať už po skončení dostatečného množství opakování či dosažení stanovené hodnoty (Nielsen 2015). Při programování samotného trénování je třeba nastavit práci s daty po *batch*, zároveň je třeba funkcí *y_pred* získat predikované hodnoty trénovacího setu a srovnávat predikce se správnými daty pomocí *loss*.

Je vytvořeno několik dalších proměnných k sledování úspěšnosti a chybovosti trénování modelu, pomocí *trn_corr* sledujeme úspěšnost modelu při samotném trénování. Klíčová je výše zmíněná *backpropagation*, kdy dochází k pozměňování vážených vstupů neuronů tak, aby byl model co nejpřesnější. Pomocí funkce *print* lze zobrazit vybrané *batch* (zde každá 600.) a jejich hodnoty.

Nyní dochází na testování modelu. Důležité je vypnout tvorbu gradientu, který byl potřebný při trénování modelu, a to pomocí funkce *torch.no_grad*. Takto se nebudou již měnit váhy a *bias* neuronů v jednotlivých *batch*. Je nastaveno přidávání správných predikcí do seznamu a sčítání jejich počtu. Pomocí následujících dvou řádků kódu lze nastavit ukládání výsledků do dříve vytvořených prázdných seznamů.

6.6 Inference na nových datech a *image retrieval*

Po trénování modelu, jenž bylo popsáno v předchozích kapitolách, navazuje inference. Nová data, která dříve nebyla modelem zpracována, jsou analyzována natrénovaným modelem, jehož úlohou je predikovat, ke které z konečných tříd dat analyzovaná informace patří. Podobně jako při testování je i při inferenci výstupem pravděpodobnost. Výsledné predikce jsou následně porovnány mezi sebou a predikce s nejvyšší pravděpodobností je klasifikována jako správná (Wang *et al.* 2015). Oproti trénování neuronových sítí je při inferenci třeba menšího množství dat i kapacit výpočetní technologie (Goodfellow *et al.* 2016).

Inference se aplikuje různými způsoby, jedním je například *batch inference*, kdy jsou data z pozorování zpracovávána po menších částech zvaných *batch* (LDC 2023). Druhým způsobem využití inference je na tzv. *real-time* datech, kdy jsou modelu dána právě získaná data k okamžitému zpracování a je ihned získán výsledek. Inference na *real-time* datech se využívá především u bezpečnostních kamerových systémů nebo analýze přichozích mailů. U zmíněných bezpečnostních kamerových systémů se využívá tzv. re-identifikace, kdy jsou záznamy z různých úhlů porovnávány s existující databází pohřešovaných či podezřelých osob (Ye *et al.* 2021). Nevýhodou tohoto postupu je nutnost předem známého počtu tříd, do kterých je třeba nová data roztrždit, což může být problematické například při analýze


populací živočichů, kdy je zapotřebí plynulého vytváření nových tříd pro přibývajících jedince. Chceme-li natrénovaným modelem analyzovat nová data, je nutno upravit postup a vynechat klasifikační etapu (Obrázek 12) a provést pouze extrakci znaků obrázku. Takto je re-identifikace používána i v zoologii u výzkumu populací tygrů (Xia *et al.* 2024), ledních medvědů (Zuerl *et al.* 2023) a dalších živočichů (Algasov *et al.* v tisku).

Pro re-identifikaci živočichů byl vytvořen model MegaDescriptor, jenž byl trénován na více různých druzích (Čermák *et al.* 2024, Adam *et al.* v tisku) a v této práci je použit na re-identifikaci jedinců mořských želv. V kontextu re-identifikace jedinců odlišných druhů živočichů je třeba zmínit *image retrieval*. Jde o metodu hledání nejpodobnějších fotografií z existující databáze již identifikovaných jedinců k fotografii jiného jedince, který je či není součástí databáze (tzv. *query image*) (Dubey 2022). Z fotografií jsou extrahovány tvary, struktury a jiné důležité body, které jsou vyjádřeny vektory (tzv. *deep feature* vektory) o různých délkách. Hledání nejpodobnějších fotografií spočívá v porovnávání délek těchto vektorů mezi obrázky z databáze a *query image*. V dvourozměrném prostoru mají vektory své souřadnice a při výpočtu podobnosti se využívá tzv. L1 norma, kdy jsou sčítány absolutní hodnoty jejich rozdílů. Pokud mám vektory v_1 a v_2 o souřadnicích $[4,2]$ a $[3,0]$, pak zápis výpočtu výsledné vzdálenosti těchto vektorů bude následující:

$$|4 - 3| + |2 - 0| = 1 + 2 = 3$$

I pokud by byl počet souřadnic větší, bude postup identický. Výpočet podobnosti lze provést rovněž za využití tzv. kosinové podobnosti. Název odkazuje na goniometrickou funkci $\cos$ a hodnota této podobnosti se pohybuje v intervalu $[-1,1]$. Při tomto postupu je počítán kosinus úhlu, který vektory svírají a čím menší tento úhel je, tím jsou si vektory podobnější (Qian *et al.* 2004).

Výsledkem jsou fotografie seřazené podle největší predikované podobnosti. Extrahování vektorů a porovnávání podobnosti za využití MegaDescriptoru je zachyceno níže na Obrázek 13. Následuje manuální ověřování predikce, zda se jedinci na *query image* a fotografii s největší predikovanou podobností shodují (Adam *et al.* v tisku).



Obrázek 13: Z *query image* na levé straně jsou za pomoci neuronových sítí extrahovány vektory popisující znaky na obrázku. Následně je spočítána délka těchto vektorů, zjištěna jejich podobnost a z databáze jsou vybrány podobné fotografie, které jsou sestupně seřazeny podle podobnosti. Schéma převzato z (Adam *et al.* v tisku).

7. Metodika

7.1 Popis území

Šrilanská demokratická socialistická republika se nachází jižně od Přední Indie na ostrově Cejlon. Jde o ostrovní stát s celkem 1 620 km dlouhým pobřežím (Rajasuriya & White 1994) a třemi podnebnými zónami: vlhkou, suchou a přechodnou s rozdílnými ročními úhrny srážek (Karunaweera *et al.* 2014).

Výzkum proběhl na jižním pobřeží Šrí Lanky na dvou vybraných plážích a ve dvou soukromých záchranných stanicích (Obrázek 14). Na pláži Batigama se nacházela lokalita Turtle Point Batigama a na pláži Rekawa se nacházely Wildlife Turtle Project Kapuhenwalla a Turtle Watch Rekawa. Soukromé záchranné stanice, kde byl výzkum také prováděn, se jmenovaly Sea Turtle Farm & Hatchery Koggala a Sea Turtle Farm & Hatchery Harabaduwa. Obě tyto stanice se nachází ve městě Koggala.



Obrázek 14: Mapa jihu Šrí Lanky zachycující všech pět navštívených lokalit. Body 1 a 2 vlevo ukazují soukromé záchranné stanice ve městě Koggala. Bod 3 uprostřed ukazuje Turtle Point Batigama. Body 4 a 5 vpravo se nachází na opačných koncích pláže Rekawa, kde se nacházejí Wildlife Turtle Project Kapuhenwalla a Turtle Watch Rekawa.

7.1.1 Záchranné stanice ve městě Koggala

Během 15. února 2024 jsem za doprovodu úředníků z Oddělení ochrany volně žijících živočichů a planě rostoucích rostlin (DWC) navštívila dvě soukromé záchranné stanice ve městě Koggala, z nichž první byla Sea Turtle Farm & Hatchery Koggala. V této záchranné stanici bylo několik bazénů s více než deseti velkými želvami, které byly v bazénech většinou po jedné, a mnoha desítkami želvích mláďat. Rovněž zde byla zakrytá oplocená část, kam přenášeli pracovníci želví vajíčka a turisté si po jejich vylíhnutí mohli odnést mladé želvy k moři. Majitel této stanice byl ochotný spolupracovat, při fotografování vyzdvihával každou želvu ze svého bazénku a odpovídal na doprovodné otázky.

Druhou navštívenou stanicí byla Sea Turtle Farm & Hatchery Harabaduwa. Zde bylo bazénů o mnoho méně, ovšem dospělé želvy zde byly umístěny do bazénů většinou po několika jedincích. Majitel této záchranné stanice nebyl ochotný želvy ani vyzdvihávat z bazénů, ani odpovídat na otázky.

7.1.2 Turtle Point Batigama

Jedná se o asi 920 m dlouhý pás pláže, který se táhne přes dvě malé zátoky západně od Dikwella Beach a který je asi ze dvou třetin využíváný želvami ke hnízdění. Zdejší pláž chrání soukromník jménem Gayan Sampath, který začal s ochranou želv před několika lety. Vybudoval na pláži stánek s občerstvením a neustále vzdělává turisty o důležitosti správné ochrany želv. Díky podpoře organizace Chráníme mořské z.s. želvy dokázal vybudovat oplocenou ukrytou část pláže, kam přenáší nakladená vejce.

7.1.3 Wildlife Turtle Project Kapuhenwalla a Turtle Watch Rekawa

Obě lokality se nachází na opačných koncích pláže Rekawa. Jde o asi 4 400 m dlouhou, převážně mírně se svažující pláž s krátkými úseky s prudkými svahy. Šířka většiny pláže od břehu po podrost se pohybuje okolo třiceti metrů, ovšem nachází se zde širší i užší úseky. Podrost je tvořen převážně keři vějířovek r. *Scaevola* (L. 1771) a pandány.

Wildlife Turtle Project Kapuhenwalla (dále jen Kapuhenwalla) se nachází na západním konci pláže poblíž města Tangalle a jde o státem vlastněnou a spravovanou záchrannou stanici (Ch. Suraweera, osobní komunikace). Poblíž pláže se nachází vlastní budova stanice s mnoha venku umístěnými informačními cedulemi, kde zdejší pracovníci (rančeři) přebývají. V blízkosti se nachází bazénky využívané při léčení zraněných želv a dvě oplocené oblasti, kam zdejší pracovníci přenášejí želví vejce, jsou-li nakladené daleko od budovy stanice v hůře monitorované zóně, kde by mohly být hnízda vybrána pytláky. Rančeři nevybírají od návštěvníků za vstup na pláž a pozorování želv při kladení poplatků.

Turtle Watch Rekawa (dále jen Rekawa) se nachází na východním konci stejnojmenné pláže a laguny Rekawa a je jednou ze stanic nevládní organizace Turtle Conservation Project. Nachází se zde vlastní budova záchranné stanice s mnoha informačními cedulemi a rovněž pokladna, kde vybírají zdejší pracovníci vstupné. Rančeři z Kapuhenwally i Rekawy spolupracují na ochraně želv a vzájemně mezi sebou komunikují.

7.2 Sběr dat

Data byla sbírána ve dnech 9.-17. února 2024. Navštívené pláže byly Rekawa a Batigama ve stejnojmenné zátocě poblíž města Dikwella, jelikož s tamními stanicemi spolupracovala moje konzultantka, Mgr. Hanka Svobodová. Navštívené soukromé záchranné stanice byly vybrány úředníky z Oddělení ochrany volně žijících živočichů a planě rostoucích rostlin (DWC) v Mirisse na jižním pobřeží Šrí Lanky, zejména zástupcem ředitele pro jižní region, Ing. Channem Suraweerou.

Fotografie byly pořizovány fotoaparátem Pentax z řady RICOH. Během dne byly želvy foceny ve stanicích a na veřejné pláži v Batigamě, kam připlouvaly za potravou. Vždy byly nejdříve foceny želvy plavající blízko břehu, následně jsem želvy aktivně vyhledávala v zátocě. Jelikož jednotliví jedinci od sebe nebyli až na jedinou výjimku rozeznatelní, byla jakákoliv spatřená želva ihned fotografována. Při návštěvě soukromých záchranných stanic jsem byla doprovázena úředníky z Oddělení ochrany volně žijících živočichů a planě rostoucích

roslin (DWC), kteří mi zajistili bezplatný vstup. Želvy byly následně vyzdvihovány z bazénů majitelem stanice nebo úředníkem z Department of Wildlife Conservation a foceny.


V noci byly želvy foceny na pláži Rekawa mezi půl devátou večer a půl čtvrtou ráno tamějšího času. K focení byl využit fotoaparát s větší citlivostí v nižším osvětlení, případně zdejší rančeři fotili svými vlastními mobily a fotografie mi následně zasílali. Želvy byly foceny pouze při kladení, anebo při návratu do oceánu, ať už na pláži kladly nebo se vrátily bez kladení, a to ze vzdálenosti 0,5 až 2 m. K osvětlení želvy bylo vždy používáno výhradně červené světlo, jelikož je díky delší vlnové délce želvami méně vnímáno, a je tedy mnohem méně rušivé (Robertson *et al.* 2016). Mezi mnou a želvou na zpáteční cestě k moři byla udržována dostatečná vzdálenost pod dozorem rančerů pracujících v záchranných stanicích.

7.3 Zpracování dat

Fotografie pořízené ten den byly vždy ještě téhož večera přesunuty z fotoaparátů do počítače a roztríděny podle data (9-2 až 17-2). Každá želva měla svou složku (např. 9-2-1, 9-2-2, ...), ve které byly složky pro fotografie pravé a levé strany hlavy (L, P). Rozmazané a nepoužitelné fotografie byly vymazány a ponechané byly přejmenovány kombinací názvů nadřazených složek pro lepší orientaci, tj. podle data pořízení, pořadí želvy ten večer a levé či pravé strany hlavy. Konkrétní fotografie pak mohla nést název např. 14-2-2-P8.

Na jednotlivých fotografiích bylo na webu makesense.ai manuálně vytvořeny *bounding* boxy, pomocí nich bylo oříznuto okolí želví hlavy, aby se zamezilo co největšímu množství shod na základě pozadí fotografie (Adam *et al.* v tisku). Příklad vytváření *bounding* boxu je zobrazen níže (Obrázek 15).

Následně byly fotografiím přiřazeny štítky jednotlivých identit na základě data pořízení a pořadí toho dne. Též byla přiřazena orientace hlavy (levá, pravá), část dne (noc, den), druh a lokalita pořízení. Vzniklý data set byl zveřejněn pod názvem SouthernProvinceTurtles na webu Kaggle.com (www.kaggle.com/datasets/wildlifedatasets/southernprovinceturtles).



Obrázek 15: Příklad vytváření *bounding boxu* (zvýrazněn žlutě, vlevo) a výsledného výřezu hlavy (vpravo). Velikosti fotografií byly upraveny pro demonstraci.

7.4 Analýza data setu

Pro zápis shody mezi fotografiemi želv při pročišťování data setu byl využit program Microsoft Excel (Microsoft Corporation 1993). Pro pročištění byl využit Google Colab využívající software Jupyter Notebook (Kluyver *et al.* 2016). Následné analýzy byly prováděny v softwaru Visual Studio Code od společnosti Microsoft (Microsoft Corporation 2015).

Ve všech analýzách byl využit model MegaDescriptor-L-384 (dále jen jako MegaDescriptor). Vektory, které model MegaDescriptor extrahoval z poskytnutých dat, byly porovnávány mezi sebou. Konkrétně byly porovnávány vektory fotografií *query* a databáze. Detailněji byl princip fungování modelu MegaDescriptor popsán v předchozích kapitolách.

Nejprve byly srovnány všechny fotografie želv, aby byly objeveny případné vícenásobné výskyty jednoho a téhož jedince během vícero dní/nocí. V tomto případě byly ke každé *query image* zobrazeny čtyři nejpodobnější fotografie, nalezená shoda byla následně manuálně ověřena a potvrzena či vyvrácena. Z porovnávání byly vyřazeny želvy focené během dne v soukromých záchranných stanicích s bazénky. Nalezené vícenásobné výskyty jednoho

a téhož jedince během různých dní/nocí byly sloučeny pod jediné pozorování. Takto bylo sloučeno celkem sedm pozorování;

- 9-2-3 s 10-2-3, kdy byla první den vyrušena před kladením a následujícího večera se vrátila;
- 12-2-1 s 13-2-1, 14-2-4 a 16-2-4 a zároveň
- 12-2-2 s 12-2-3, 14-2-3 a 16-2-5. Tyto želvy byly vyfoceny na lokalitě Dikwella, kam se opakovaně vracely a při sběru dat nebylo možné udržet si přehled o tom, zda byla želva již focena.

Následovaly analýzy s cílem zjištění spolehlivosti natrénovaného modelu MegaDescriptor při identifikaci jedinců z fotografií.

U některých želv se nepodařilo zachytit obě strany hlavy v dostatečném množství fotografií, tj. ve dvou a více fotografiích. Těchto želv bylo celkem sedm; 9. února i 11. února šlo o jednu želvu, dne 15. února byly dvě z nich pořízeny v noci a tři ve dne. Jejich identity jsou vypsány níže:

9-2-1, 11-2-2, 15-2-2, 15-2-3, 15-2-4, 15-2-5, 15-2-17

Po pročištění byly do data setu zahrnuty jen ty identity želv, u nichž byly u každé strany tváře pořízeny dvě a více fotografií. Dále je tento pročištěný data set nazýván pouze *data set*. Funkcí *ClosedSetSplit* byla data rozdělována do databáze a *query* podle nastaveného poměru, a to tak, že poměr byl počítán pro každou identitu, ne pro soubor všech fotografií. Funkce *ClosedSetSplit* navíc zaručovala, že bude do *query* vybrána vždy minimálně jedna fotografie (a to i v případě, že od jedince budou v data setu pouze čtyři fotografie a databáze bude mít velikost 90 % či víc).

Analýzy jsem prováděla při různých splitech v data setu. Rozdělení celkového data setu bylo nastaveno po krocích 2,5 % s velikostí od 40 do 97,5 %, pokud není zmíněno jinak. Udávané procento vždy představovalo velikost databáze. Zároveň byl nastaven počet iterací (500) a pro každou náhodný výběr parametru *seed*, který zajišťuje replikovatelnost a nastavením jeho různých hodnot můžeme ověřovat spolehlivost modelu při různých splitech data

setu. Data nebyla nezávislá, jelikož se při rozdělování dat do *query* a databáze jednotlivé fotografie vyskytovaly střídavě v databázi a v *query*.

Výsledkem jsou grafy zachycující úspěšnost modelu v závislosti na velikosti databáze. První z analýz jsem prováděla bez zohlednění denní doby či orientace hlavy. Cílem bylo zjištění „obecné“ úspěšnosti modelu.

Následně jsem zjišťovala úspěšnost identifikace:

- (a) jednotlivých druhů,
- (b) jedinců podle jednotlivých stran hlavy, a to zvlášť,
- (c) jedinců při rozdělení data setu na denní a noční fotografie
- (d) a jedinců podle opačných stran hlavy, a to už bez rozdělení fotografií na různé poměry *query* a databáze.

K porovnání jsem zvolila rozdělení data setu na průměr velikostí databází, při kterých byla zjištěna nejvyšší úspěšnost při identifikaci z levé a pravé strany. Výsledky analýzy (d) jsem následně porovnávala s úspěšností modelu při identifikaci z jednotlivých stran (b).

Jelikož data nebyla nezávislá, nebyly prováděny žádné navazující analýzy a ke grafům byla zobrazena pouze směrodatná odchylka.

8. Výsledky

8.1 Počty fotografií, jedinců a druhů

Konečný počet želv v data setu byl 44 a celkový počet fotografií činil 454. Z těchto fotografií bylo 278 pořízeno v noci a 176 za dne. V noci bylo fotografováno 24 želv a ve dne 20. Pravou stranu hlavy zachycovalo 231 fotografií a levou 223. Byly pozorovány celkem čtyři druhy mořských želv. Kareta pravá *Eretmochelys imbricata* byla zachycena na 10 fotografiích, kareta obecná *Caretta caretta* na 16, kareta zelenavá *Lepidochelys olivacea* na 55 fotografiích a nejpočetnější kareta obrovská *Chelonia mydas* na 373 fotografiích.

Nejčastěji byla fotografována želva s identitou 12-2-2 s celkem 43 fotkami, dalšími nejpočetnějšími identitami byly 12-2-1 s 28 fotkami, 9-2-2 s 23 fotkami a 17-2-1 s 20 fotkami. Všechny vyjmenované identity patří do druhu karety obrovské.

V noci byly na plážích při kladení fotografovány karety obrovské a karety zelenavé, v záchranných stanicích pak byly za dne fotografovány zbylé dva druhy karet, tj. kareta obecná a kareta pravá. Detailněji jsou jednotlivé počty zachyceny v tabulce na následující stránce (Tabulka 1).

Tabulka 1: Tabulka zobrazuje výčet fotografovaných druhů. Sloupeček *Identity* obsahuje výčet identit, v hranatých závorkách je uveden počet jedinců a za závorkami výčet identit daného druhu. Sloupeček *Denní doba* obsahuje počet denních a nočních fotografií oddělených středníkem, sloupeček *n-L ; n-P* obsahují počet fotografií daného druhu levé či pravé strany. Poslední sloupeček *N* obsahuje celkový počet fotografií daného druhu.

Ve sloupečku *Identity* jsou kurzívou uvedeni i ti jedinci, u kterých nebyl pořízen dostatek fotografií (tj. méně než 2 pro každou stranu) a byly z konečného data setu vyřazeny. Nejsou tedy zahrnuti v součtech jedinců druhu v hranatých závorkách ani v dalších sloupečcích.


Druh	Identity	Denní doba	<i>n-L ; n-P</i>	<i>N</i>
kareta obrovská <i>Chelonia mydas</i>	[37], 9-2-1, 9-2-2, 9-2-3, 10-2-1, 11-2-2, 11-2-3, 11-2-4, 11-2-5, 11-2-6, 11-2-7, 12-2-1, 12-2-2, 12-2-4, 12-2-5, 12-2-6, 12-2-7, 13-2-3, 13-2-4, 14-2-1, 14-2-2, 15-2-3, 15-2-11, 15-2-12, 15-2-13, 15-2-14, 15-2-17, 15-2-18, 15-2-19, 15-2-20, 15-2-21, 15-2-22, 16-2-1, 16-2-2, 16-2-3, 17-2-1, 17-2-2, 17-2-3	123 ; 250	186 ; 187	373
kareta obecná <i>Caretta caretta</i>	[2], 15-2-4, 15-2-15, 15-2-16	16 ; 0	5 ; 11	16
kareta pravá <i>Eretmochelys imbricata</i>	[2], 15-2-6, 15-2-24	10 ; 0	6 ; 4	10
kareta zelenavá <i>Lepidochelys olivacea</i>	[7], 13-2-2, 15-2-1, 15-2-2, 15-2-5, 15-2-7, 15-2-8, 15-2-9, 15-2-10, 15-2-23	27 ; 28	27 ; 28	55

Z 20 želv fotografovaných přes den šlo o všechny jedince druhů karety obecné a karety pravé, které byly foceny v záchranných stanicích s líhněmi ve městě Koggala. Celkem bylo v těchto stanicích s líhněmi nafoceno 22 želv a pořízeno 105 fotografií. Na pláži Rekawa bylo vyfoceno 25 želv a pořízeno 261 fotografií. V zátocě Batigama byly vyfoceny celkem 4 želvy na 88 fotografiích.

8.2 Porovnávání úspěšnosti modelu MegaDescriptor

V první analýze jsem zjišťovala úspěšnost modelu bez rozdělení data setu dle orientace hlavy či denní doby. Z grafu (Obrázek 16) je patrné, že úspěšnost modelu roste s místními poklesy až po 90% velikost databáze, kde dosahuje maxima na 83,8 % a následně klesá na 82 % úspěšnosti při 97,5% databázi.

Úspěšnosti modelu při různých velikostích databáze jsou vypsány v Příloze A.




Obrázek 16: Úspěšnost modelu MegaDescriptor při identifikaci jedinců (bez rozlišení orientace či denní doby) v závislosti na velikosti databáze. Linka představuje průměrné hodnoty úspěšnosti modelu všech 500 iterací, stínovaná oblast vyznačuje směrodatnou odchylku, která se se zvětšující databází rozšiřuje. Hodnoty osy x představují poměr velikosti databáze ku *query*.

Na následujícím grafu (Obrázek 17) jsem vizualizovala úspěšnost identifikace druhů. Nejvyšší úspěšnost (tj. nejvyšší medián) byla u karety pravé a karety obecné, v obou případech

měla hodnotu 100 %. Mezikvartilové rozpětí karety obecné bylo druhé největší, větší bylo patrně u karety zelenavé. Pro karetu obrovskou nečinilo mezikvartilové rozpětí ani 10 % a u karety pravé bylo zdaleka nejmenší.


U karety zelenavé vidíme největší rozpětí hodnot i při zohlednění chvostů. Medián u tohoto druhu ležel na hodnotě 91,7 %. U karety obrovské byl medián na 76,3 %. Horní chvosty sahaly k 89,4 % a dolní k 63,6 %.



Obrázek 17: Vizualizace úspěšnosti při identifikaci druhů. Barevné krabice představují mezikvartilové rozpětí, chvosty představují nejvyšší hodnoty při vynásobení mezikvartilového rozpětí 1,5krát. Okraje krabice představují hranice 75% percentilu a 25% percentilu. U druhů kareta pravá a kareta obecná byly mediány na 100% hodnotě. Počty fotografií / jedinců pro každý druh byly následující: 373 / 33 pro karetu obrovskou, 55 / 7 pro karetu zelenavou, 10 / 2 pro karetu pravou a 16 / 2 pro karetu obecnou.

Analýza úspěšnosti identifikace z fotografií v různou denní dobu (Obrázek 18) ukázala značný rozdíl ve fungování modelu, a to ve prospěch denních fotografií. Pro denní fotografie dosáhl model maxima na 75% velikosti databáze s úspěšností 95,1 %, zatímco pro noční fotografie byla nejvyšší úspěšnost 75,8 % na 85% databázi. Minimální úspěšnost pro denní fotografie byla 88,1 % a pro noční fotografie 61,9 %, a to v obou případech na počátečních 40 % velikosti databáze. Rozdíl v úspěšnosti mezi denní a noční dobou se snižoval se zvětšující se databází. Dosahoval minima na 18,4 % a maxima na 26,7 %. Šlo o největší pozorovaný rozdíl v analyzovaných úspěšnostech modelu při identifikaci v mojí práci.


Úspěšnosti modelu při různých velikostech databáze jsou vypsány v Příloze B.



Obrázek 18: Úspěšnost modelu při identifikaci jedinců vyfocených v noci a ve dne v závislosti na velikosti databáze. V legendě vlevo nahoře jsou v závorkách uvedeny počty fotografií. Linka představuje průměr z 500 iterací, stínovaná oblast směrodatnou odchylku.

Podobně jako v předchozí analýze jsem našla rozdíl v úspěšnosti modelu při rozdělení data setu na fotografie levé a pravé strany (Obrázek 19). Avšak rozdíl byl menší. Zároveň se při menších velikostech databáze úspěšnosti překrývaly a směrodatné odchylky se překrývaly podél celého gradientu velikosti databáze. Oproti předchozí analýze se ale rozdíly v úspěšnosti obou stran zvětšovaly se zvětšující se databází. Na největší databázi byl rozdíl mezi průměrnými úspěšnostmi 6,7 %. Nejvyšší úspěšnost při identifikaci levé strany byla 79,2 % při 80% databázi. Pro pravou stranu to bylo 83,9 % při 85% databázi.

Úspěšnosti modelu při různých velikostech databáze jsou vypsány v Příloze C.




Obrázek 19: Vizualizace úspěšnosti modelu při identifikaci z jednotlivých stran hlavy. Čísla v závorkách v legendě vlevo nahoře představují počty fotografií jednotlivých stran, stínování představuje směrodatnou odchylku.

V následující analýze jsem zjišťovala úspěšnost modelu při identifikaci z opačných stran hlavy. Výsledkem (Obrázek 20) byla úspěšnost nepřesahující 19 %, což byla nejnižší

úspěšnost z celé této práce. Úspěšnost identifikace jedinců z levé ku pravé strany byla 17,9 % a z pravé ku levé 18,2 %.

Úspěšnost identifikace z opačných stran hlavy



Obrázek 20: Graf úspěšnosti modelu při identifikaci z opačných stran hlavy. Tato jediná analýza nebyla dělána způsobem postupného rozdělování data setu na stále se zvětšující se databázi, ale byly použity veškeré fotografie, což je důvodem zobrazení pomocí jednoduchého sloupcového grafu. Hodnoty sloupců nepřekračují 19 %.

Oproti identifikaci ze stejné strany (Obrázek 19) došlo tedy k více než trojnásobnému snížení úspěšnosti.

Skript z Visual Studio Code s jednotlivými analýzami se nachází v elektronické příloze. Úspěšnosti jednotlivých analýz s odpovídajícími velikostmi databáze se nacházejí v Přílohách A-C.

9. Diskuze

Nejpočetnějším pozorovaným druhem byla kareta obrovská s 373 fotografiemi, což bylo více než čtyřnásobek součtu fotografií zbylých tří druhů (kareta zelenavá, kareta obecná, kareta pravá). Nejméně početněm druhem byla kareta pravá, v minulosti intenzivně lovená pro svůj pestře vzorovaný krunýř. Velký počet pozorovaných karet obrovských, a naopak vzácnost karet pravých, souhlasí s mnoha dlouhodobými výzkumy populací na jihozápadním a jižním pobřeží Šrí Lanky (Ekanayake *et al.* 2002, Ekanayake *et al.* 2010, Ekanayake *et al.* 2016). Nejlépe jsou relativní abundance jednotlivých druhů porovnatelné na počtech hnízd. Zatímco u karety obrovské bylo napočítáno mezi roky 2014-2015 přes 2300 hnízd, u karety zelenavé téměř 1000 a zbylé dva druhy dohromady nenakladly ani do 50 hnízd (Thilakarathne *et al.* 2024). U kožatky velké bylo odhadováno 100-200 zahrnutí (Piboon *et al.* 2025). Thilakarathne *et al.* (2024) zmiňují ve své práci pouze 12 napočítaných hnízd kožatky velké mezi roky 2014-2015. V mé práci nebyl tento druh pozorován.

Bohužel kvůli nízkému počtu pozorovaných jedinců karety obecné (tj. 2) nemohly být výsledky srovnány s populacemi stejného druhu obývající Středozemní moře (viz Cíle). Původním důvodem tohoto náměru bylo zjištění rozdílů mezi populacemi. Existují rozsáhlé data sety fotografií karet obecných z okolí Zakynthosu (Adam *et al.* 2024, Čermák *et al.* 2024) a srovnání středomořské a šrilanské populace by mohlo přinést zajímavé výsledky. K uskutečnění takové studie bude potřebný další výzkum.

Analýzy úspěšnosti modelu v identifikaci jedinců vykazovaly do jisté míry společný trend počátečního růstu a následného poklesu. Pokles nastával při různé velikosti databáze. U některých rozdělení pozorujeme převážný nárůst úspěšnosti (například u celkové analýzy, u identifikace z fotografií pravé strany a mírně i u fotografií pořízených v noci). Úspěšnost identifikace z levé strany i z fotografií pořízených za dne nevykazuje zdaleka takový růst, od určité velikosti databáze dokonce mírný pokles. Za zmínku stojí rozšiřování směrodatné odchylky s rostoucí databází, které se objevuje ve všech analýzách. Možným důvodem může být stále zmenšování *query*, kam mohly být náhodným výběrem vybrány méně kvalitní fotografie, a tedy model nemohl dosáhnout takové úspěšnosti.

Želvy mají dobře vyvinuté slzné žlázy, kterými vylučují přebytečnou sůl (Yoshida *et al.* 2022). Pro úspěšnou identifikaci je přitom klíčová dobrá viditelnost znaků, které mohly být kompromitovány často nalepeným pískem na tvářích želv. Model se tak při identifikaci mohl rozhodnout pro shodu na základě podobných hrudek slepeného písku, a ne na základě štítků, jenž jsou pro jedince charakteristické.

Dalším důvodem menší úspěšnosti nočních fotografií může být i samotné červené světlo. Denní fotografie mají širší barevné spektrum i ostrost, zatímco červené světlo může zkreslovat některé ze znaků (Gatto *et al.* 2018). V této práci mohlo jít i o takové znaky, jako je zbarvení štítků, neboť nejde o dlouhotrvající výzkum, a již dříve byla dokázána změna pigmentace během života (Carpentier *et al.* 2016).

Značný vliv na úspěšnost modelu v analýzách, které budou rozebírány v navazujících odstavcích, mohl být způsoben i způsobem, jakým byl trénován. Modely neuronových sítí vykazují největší spolehlivost při aplikaci (po trénování) na datech, která jsou podobná těm, na kterých byly trénovány (Goodfellow *et al.* 2016). MegaDescriptor byl trénován na zhruba 300 tisících fotografiích různých druhů, z toho želvy činily okolo 20 tisíc fotografií (L. Adam, ústní sdělení). Fotografie určené k trénování patřily druhům karety obrovské, karety obecné a karety pravé. Ty byly pořízeny během dne ve vodě a na souši, nikoliv v noci za červeného světla (Adam *et al.* v tisku). V této práci přitom fotografie pořízené v noci převažovaly a často měly značně sníženou kvalitu oproti fotografiím pořízeným během dne.

Při analýze celého data setu bez rozdělení na skupiny podle různé denní doby, druhů či orientace hlavy vyšla najevo rostoucí úspěšnost identifikace. Zlom nastal u velikosti databáze na 90 %, posléze začala úspěšnost modelu klesat, ačkoliv menší poklesy v úspěšnosti jsou patrné v rostoucí části grafu. Pokles v úspěšnosti mohl být způsoben hned dvěma faktory. Značná velikost databáze může poskytnout modelu větší množství zdánlivě podobných fotografií jiných jedinců k porovnání s *query*. Tento problém by byl v praxi řešitelný pořizováním jen velmi kvalitních fotografií, na kterých by byly znaky jednotlivých karet dobře patrné. Vytvoření takové databáze obnáší další pečlivý výzkum jejich populací.

Druhým důvodem poklesu úspěšnosti může být problém velmi malého *query*, které při tvoření při vysoké proporci databáze pouhé nižší jednotky. Potom kvalita těchto fotek, ať už je dobrá nebo špatná, zajisté ovlivní úspěšnost identifikace. Manuálním průzkumem

některých z výsledků všech iterací bylo zjištěno, že se mezi špatně identifikovanými jedinci objevují nejčastěji noční fotografie nízké kvality či zachycující hlavy částečně zakryté pískem, ale také fotografie ze záchranných stanic s bazénky s dobře rozeznatelnými znaky. Důvod nepřesné identifikace těchto fotografií je nejasný. Jedinci mohli vykazovat větší podobnost mezi sebou, což mohlo ovlivnit úspěšnost modelu. Taková situace nastala při počátečním sjednocování vícenásobných pozorování, kdy model opakovaně vyhodnocoval dvojici identit jako shodnou, ačkoliv nebyly.

Model vykazoval různou úspěšnost při rozdělení data setu na jednotlivé druhy, kdy nejvyšší úspěšnost byla jednoznačně u karety obecné a karety pravé. Tyto dva druhy byly fotografovány ve světelných podmínkách podobajících se těm u fotografií u trénovacích data setů modelu. Zároveň by roli mohly hrát počty štítků za okem želvy, kdy u karety obrovské jsou čtyři až pět, a u karety obecné, pravé i zelenavé nacházíme tři. Tento rys mohl mít svůj vliv zejména u karety zelenavé, na které nebyl model trénován, ovšem autoři modelu uvádí, že jelikož byl trénován na velkém množství druhů, měl by být úspěšný i v identifikaci dříve neviděných druhů (Adam *et al.* v tisku). Za druhé to mohly být i nízké počty jedinců i fotografií: od karety obecné a karety pravé byly zachyceny pouze dva jedinci od každé, a to v celkem 26 fotografiích. Při malém počtu jedinců je proto nižší pravděpodobnost záměny.

Největší rozdíly v úspěšnosti identifikace modelem byly u rozdělení data setu na denní a noční fotografie, který činil cca 20-30 %. Nebyly nalezeny jiné studie zkoumající mořské želvy, které by využívaly fotografie hlav pořízené v noci s červeným světlem. Je tedy nutné dotrénovat použitý model na nočních fotografiích, což by mělo zvýšit jeho úspěšnost.

Úspěšnost identifikace se lišila mezi fotografiemi z pravé a levé strany hlavy. Tento rozdíl však nebyl tak velký jako mezi identifikací jedinců z denních a nočních fotografií. Důvodem tentokrát nebyl způsob trénování modelu, protože v trénovacím data setu byly pravé i levé strany zastoupeny rovnoměrně (L. Adam, ústní sdělení). Skutečným důvodem je pravděpodobně v rysech stran. Je možné, že populace šrilanských karet mají méně charakteristickou levou tvář, tedy že na levé straně hlavy se nachází méně znaků typických pro jedince a jsou si zleva navzájem podobnější. To by vysvětlovalo i velmi nízkou úspěšnost identifikace jedinců na základě opačných stran hlavy, která nepřekročila 19 % (Obrázek 20). Studie, které se věnují vytváření štítků během ontogeneze, se soustředí především na štítky tvořící

karapax, kde je též patrná určitá specifická mezi jednotlivci (Casale *et al.* 2017). Variabilita ve štítech krunýře může být důsledkem disturbancí embryí při vývoji ve vejcích, které ovlivňují počet plakod, z nichž se štítky karapaxu vyvíjí, a vedou k asymetrii (Cherepanov 2014). Variabilita ve tvaru štítků na stranách hlav by mohla mít stejný původ, což ale neposkytuje vysvětlení konzistentně obtížné identifikace pouze z jedné strany hlavy. K podobnému výsledku došli i Su *et al.* (2015), kteří zjistili nepodobnost opačných stran hlavy u drtivé většiny studovaných karet obrovských ve vodách u Taiwanu. Velké podobnosti mezi stranami hlavy dosahovalo v jejich studii pouze méně než 20 % karet (Su *et al.* 2015). Naopak populace karety obrovské z okolí ostrova Réunion v Indickém oceánu vykazuje značnou podobnost mezi levou a pravou stranou hlavy (Adam *et al.* v tisku).

Shoda mezi pravou a levou stranou hlav je tedy u želv pravděpodobně vlastností populací u karety obrovské. U dalších druhů zatím hlášena nebyla. Avšak jsou u nich známy některé jiné morfologické rozdíly mezi populacemi. Například u karet obecných z okolí ostrova Lampedusa u Itálie byla pozorována variace v tvaru hlavy a další alometrické rozdíly byly zjištěny i na karapaxu (Casale *et al.* 2017).

10. Závěr

Tato práce přinesla cenné poznatky o populacích mořských želv na Šrí Lance, kde čelí mnohým antropogenním hrozbám a jejich počty zde jsou oproti minulosti značně snižené (Thilakarathne *et al.* 2024).

Prozkoumala jsem úspěšnost identifikace jedinců z fotografií stran hlav modelem Mega-Descriptor, a to vzhledem k denní době pořízení fotografie a stranám hlavy. Ve srovnání s dalšími studiemi, dokumentujícími úspěšnost různých metod identifikace jedinců z fotografií (Su *et al.* 2015, Carpentier *et al.* 2016, Adam *et al.* v tisku), je to první práce, kde převažovala identifikace jedinců mořských želv z nočních fotografií focených při červeném světle.

Nejvyšší úspěšnost identifikace jedinců byla pozorována u fotografií pořízených ve dne, což pravděpodobně souvisí s natrénováním modelu. Dále jsem zjistila negativní vliv nepodobnosti mezi opačnými stranami hlavy na úspěšnost identifikace, což je pravděpodobně vlastností zkoumané populace (Su *et al.* 2015, Adam *et al.* v tisku).

Lze tedy říci, že model funguje, a mohl by tedy být využit pro monitoring populací nejen na Šrí Lance, a to pro zjištění úspěšnosti přežití karet vypuštěných ze záchranných stanic a počty hnízdících jedinců. Proto je vhodné pokračovat ve výzkumu rozšířením existujícího data setu novými kvalitními fotografiemi.

Použité zdroje

Abalo-Morla S., Belda E. J., March D., Revuelta O., Cardona L., Giralt S., Crespo-Picazo J. L., Hochscheid S., Marco A., Merchán M., Sagarminaga R., Swimmer Y. & Tomás J. 2022: Assessing the use of marine protected areas by loggerhead sea turtles (*Caretta caretta*) tracked from the western Mediterranean. *Global Ecology and Conservation* 38: 1–17.

Adam L., Čermák V., Papafitsoros K. & Pícek L. 2024: SeaTurtleID2022: A long-span dataset for reliable sea turtle re-identification. In: *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*, pp. 7146–7156.

Adam L., Papafitsoros K., Jean C. & Rees A. F. (v tisku): Exploiting facial side similarities to improve AI-driven sea turtle photo-identification systems. DOI: 10.1101/2024.09.13.612839

Algasov A., Nepovninnykh E., Eerola T., Kälviäinen H., Stewart C. V., Otarashvili L. & Holmberg J. A. (v tisku): Understanding the Impact of Training Set Size on Animal Re-identification. DOI: 10.48550/arXiv.2405.15976.

Amarasooriya K. 2000: The role of the hatcheries in conservation of sea turtle fauna of Sri Lanka. *21st Annual symposium on sea turtle biology and conservation*, Philadelphia, USA: pp 92–93.

Amarasooriya K. D. & Jayathilaka R.A.M. 1997: Marine Turtle Nesting on the Beaches of the North-Western, Western and Southern Provinces of Sri Lanka. In: Mosier A., Foley A. & Brost B. (eds.): *Proceedings of the 20th Annual Symposium on Sea Turtle Biology and Conservation*. NOAA, Florida, pp. 93–95.

Amorim L., Chieza L., Lasala J. A., Teodoro S. D. S. A., Colombo W. D., Barcelos A. C., Guimarães P. R. L., da Fonseca J. L. G., Marcondes A. C. J., Santos A. & Vargas S. 2025: Reproductive strategies in loggerhead sea turtle *Caretta caretta*: polyandry and polygyny in a Southwest Atlantic rookery. *PeerJ* 13: 1–26.

Ankersen T. 2024: Not for Long a Fishe: The Early History of Sea Turtle Conservation Law and Policy in Florida Part II. *Sea Turtle Conservancy*: 1–12.

Arachchige U. S. P. R., Sathsara K. L. T., Preethika P., Miyuranga K. A. V., de Silva S. J. & Thilakarathne D. 2021: The Impact of Shipping on Marine Environment – A Study of

Sri Lankan Water Ways. *International Journal of Scientific Engineering and Science* 5(7): 30–38.

Babcock E. A., Barnette M. C., Bohnsack J. A., Isely J. J., Porch C. E., Richards P. M., Sasso Ch. & Zhang X. 2018: *Integrated Bayesian models to estimate bycatch of sea turtles in the Gulf of Mexico and southeastern US Atlantic coast shrimp otter trawl fishery*. NOAA, Washington.

Balazs G. H. 1982: Factors affecting the retention of metal tags on sea turtles. *Marine Turtle Newsletter* 20(11-14): 1–4.

Behera S. K., Sivakumar K., Choudhury B., & John S. 2014: Diet preference and prey of olive ridley turtles (*Lepidochelys olivacea*) along East Coast of India, Odisha. *Open Journal of Ocean and Coastal Sciences* 1(1): 73–82.

Bishop C. M. 2006: *Pattern recognition and machine learning*. Springer, New York.

Bjorndal K. A. & Bolten A. B. 2003: From ghosts to key species: restoring sea turtle populations to fulfill their ecological roles. *Marine Turtle Newsletter* 100(100): 16–21.

Bouchard S. S. & Bjorndal K. A. 2000: Sea turtles as biological transporters of nutrients and energy from marine to terrestrial ecosystems. *Ecology* 81(8): 2305–2313.

Briscoe D. K., Parker D. M., Balazs G. H., Kurita M., Saito T., Okamoto H., Polovina J. J. & Crowder L. B. 2016: Active dispersal in loggerhead sea turtles (*Caretta caretta*) during the ‘lost years’. *Proceedings of the Royal Society B: Biological Sciences* 283(1832): 1–8.

Brodie J., Sanjayan M., Corea R., Helmy O. & Amarasinghe C. 2008: Effects of the 2004 Indian Ocean Tsunami on sea turtle populations in Sri Lanka. *Chelonian Conservation and Biology* 7(2): 249–251.

Bycatch Management Information System (BMIS) 2012: *Resolution 12/04 – On The Conservation Of Marine Turtles*. Indian Ocean Tuna Commission, Victoria.

Cadena E. A. & Parham J. F 2015: Oldest known marine turtle? A new protostegid from the Lower Cretaceous of Colombia. *PaleoBios* 32: 1–42.

Caillouet Ch. & Gallaway B. 2020: Kemp's Ridley Sea Turtle Emigration and Immigration Between The Gulf Of Mexico And North Atlantic Ocean Should Not Be Ignored In Age-Structured Population Modeling. *Marine Turtle Newsletter* 161: 9–14.

Caracappa S., Persichetti M. F., Gentile A., Caracappa G., Curro V., Freggi D. & Arculeo M. 2017: New records of leatherback sea turtle, *Dermochelys coriacea* (Vandelli, 1761) (Testudines: Dermochelyidae) in the Strait of Sicily. *Cahiers de Biologie Marine* 58: 353–357.

Carpentier A. S., Jean C., Barret M., Chassagneux A. & Ciccione S. 2016: Stability of facial scale patterns on green sea turtles *Chelonia mydas* over time: a validation for the use of a photo-identification method. *Journal of Experimental Marine Biology and Ecology* 476: 15–21.

Carr A. 1967: A Zoological Puzzle – So Excellent a Fishe. A Natural History of Sea Turtles. *Science* 159: 417–418.

Casale P., Abbate G., Freggi D., Conte N., Oliverio M. & Argano R. 2008: Foraging ecology of loggerhead sea turtles *Caretta caretta* in the central Mediterranean Sea: evidence for a relaxed life history model. *Marine Ecology Progress Series* 372: 265–276.

Casale P., Freggi D., Rigoli A., Ciccocioppo A. & Luschi P. 2017: Geometric morphometrics, scute patterns and biometrics of loggerhead turtles (*Caretta caretta*) in the central Mediterranean. *Amphibia-Reptilia* 38(2): 145–156.

Castangia M., Grajales L. M. M., Aliberti A., Rossi C., Macii A., Macii E., & Patti E. 2023: Transformer neural networks for interpretable flood forecasting. *Environmental Modelling & Software* 160: 1–9.

CMS 2024: Appendices I and II of the Convention on the Conservation of Migratory Species of Wild Animals (CMS). Dostupné z: <https://www.cms.int/en/species/appendix-i-ii-cms>. Verze z: 17. března 2024.

Cong S. & Zhou Y. 2023: A review of convolutional neural network architectures and their optimizations. *Artificial Intelligence Review* 56: 1905–1969.

Convention on International Trade in Endangered Species of Wild Fauna and Flora 2025: *Appendices I, II and III*. Dostupné z: <https://cites.org/sites/default/files/eng/app/2025/E-Appendices-2025-02-07.pdf>. Verze z: 7. února 2025.

Costa L. L., Bulhões E. M. R., Caetano J. P. A., Arueira V. F., de Almeida D. T., Vieira T. B., Cardoso L. J. T. & Zalmon I. R. 2023: Do costal erosion and urban development threat

loggerhead sea turtle nesting? Implications for sandy beach management. *Frontiers in Marine Science* 10: 1–9.

Curl L. F., Hurst S. A., Pomory C. M., Lamont M. M. & Janosik A. M. 2024: Assessing microplastics contamination in unviable loggerhead sea turtle eggs. *Science of the Total Environment* 912:1–11.

Čermák V., Pícek L., Adam L. & Papafitsoros K. 2024: WildlifeDatasets: An open-source toolkit for animal re-identification. In: *Findings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV)*. Waikoloa, USA, pp. 5941–5951.

de la Hoz Schilling C., Diame A., Hernández Ríos A., Mingarro M. & Jabado R. W. 2023: Nowhere to hide: Sea turtle bycatch in Northwest Africa. *Aquatic Conservation: Marine and Freshwater Ecosystems* 33(10): 1131–1153.

de los Santos C. B., Scott A., Arias-Ortiz A., Jones B., Kennedy H., Mazarrasa I., McKenzie L., Nordlund L. M., de la Torre-Castro M., Unsworth R. K. F., Ambo-Rappe R. 2020: Seagrass ecosystem services: Assessment and scale of benefits. In: *Out of the blue: the value of seagrasses to the environment and to people*. UNEP, Nairobi, pp. 21–35.

de Silva A. 2006: Marine Turtles of Sri Lanka: A Historical Account. In: Shanker K. & Choudhury B. C. (eds.): *Marine Turtles of the Indian Subcontinent*. Universities Press, Hyderabad, pp. 324–353.

Deraniyagala P. E. P. 1939: *The tetrapod reptiles of Ceylon. Vol.1*. Colombo Museum, Colombo.

Dietterich T. 1995: Overfitting and undercomputing in machine learning. *ACM Computing Surveys* 27 (3): 326–327.

Dubey S. R. 2022: A Decade Survey of Content Based Image Retrieval using Deep Learning. *IEEE Transactions on Circuits and Systems for Video Technology* 32: 2687–2704.

Ekanayake E. L., Ranawana K. B., Kapurusinghe T., Premakumara M. G. C. & Saman M. M. 2002: Marine turtle conservation in Rekawa turtle rookery in southern Sri Lanka. *Ceylon Journal of Science (Biological Science)* 30: 79–88.

Ekanayake E. M. I., Rajakaruna R. S., Kapurusinghe T., Saman M. M., Rathnakumara D. S., Samaraweera P. & Ranawana K. B. 2010: Nesting behaviour of the green turtle at

Kosgoda rookery, Sri Lanka. *Ceylon Journal of Science (Biological Sciences)* 39(2): 109–120.

Ekanayake E. M. L., Kapurusinghe T., Saman M. M., Rathnakumara D. S., Samaraweera P. & Rajakaruna R. S. 2016: Reproductive output and morphometrics of green turtle, *Chelonia mydas* nesting at the Kosgoda rookery in Sri Lanka. *Ceylon Journal of Science* 45(3): 103–116.

Engeman, R. M. Addison, D. & Griffin J. C. 2014: Defending against disparate marine turtle nest predators: nesting success benefits from eradicating invasive feral swine and caging nests from raccoons. *Oryx* 50(2): 289–295.

Estrella-Jordan B. A., Lango-Reynoso F., Castañeda-Chávez M. D. R., Montoya-Mendoza J. & Reynier-Valdes D. 2023: Microplastic pollution in sea turtle nests on the beaches of Nautla and Vega de Alatorre, Veracruz. *Microplastics* 2(2) 182–191.

Fan Z., Mei W., Liu W., Chen M., Qiu Z. 2024: I-DINO: High-Quality Object Detection for Indoor Scenes. *Electronics* 13 (22): 1–16.

Finkbeiner E. M., Wallace B. P., Moore J. E., Lewison R. L., Crowder L. B. & Read A. J. 2011: Cumulative estimates of sea turtle bycatch and mortality in USA fisheries between 1990 and 2007. *Biological Conservation* 144(11): 2719–2727.

Frick M. G., Williams K. L., Bolten A. B., Bjorndal K. A. & Martins H. R. 2009: Foraging ecology of oceanic-stage loggerhead turtles *Caretta caretta*. *Endangered Species Research* 9(2): 91–97.

Frick M., Williams K. & Robinson M. 1998: Epibionts associated with nesting loggerhead sea turtles (*Caretta caretta*) in Georgia. *Herpetological Review* 29: 211–214.

Gatto C. R., Rotger A., Robinson N. J. & Tomillo P. S. 2018: A novel method for photo-identification of sea turtles using scale patterns on the front flippers. *Journal of Experimental Marine Biology and Ecology* 506: 18–24.

Goatley C. H. R., Hoey A. S. & Bellwood D. R. 2012: The role of turtles as coral reef macroherbivores. *PloS one* 7(6): 1–7.

Godley B. J., Broderick A. C., Colman L. P., Formia A., Godfrey M. H., Hamann M., Nuno A., Omeyer L. C. M., Patrício A. R., Philott A. D., Rees A. F. & Shanker K. 2020: Reflections on sea turtle conservation. *Oryx* 54(3): 287–289.

Goodfellow I., Bengio Y. & Courville A. 2016: *Deep learning (Vol. 1)*. MIT Press, Cambridge.

Government of Australia 2021: *Queensland Marine Turtle Field Guide*. Queensland Parks and Wildlife Service, Department of Environment and Science, Brisbane.

Government of Sri Lanka 1907: *Prevention of Cruelty to Animals Ordinance No. 13*. Ministry of Justice, Colombo.

Government of Sri Lanka 1938: *Fauna and Flora Protection Ordinance*. Department of Wildlife Conservation, Colombo.

Government of Sri Lanka 1996: *Fisheries and Aquatic Resources Act, No. 2 of 1996*. Ministry of Fisheries and Aquatic Resources Development, Colombo.

Government of Sri Lanka 2009: *Fauna and Flora Protection Ordinance (Amendment) Act No. 22*. Department of Wildlife Conservation, Colombo.

Parliament of Sri Lanka 2022: *Constitution of the Democratic Socialist Republic of Sri Lanka*. Parliament Secretariat of Sri Lanka, Colombo.

Government of Sri Lanka 2022: *National Environmental Action Plan 2022-2030: Pathway To Sustainable Development*. Ministry of Environment, Colombo.

Gulick A. G., Johnson R. A., Pollock C. G., Hillis-Starr Z., Bolte A. B. & Bjorndal K. A. 2020: Recovery of a large herbivore changes regulation of seagrass productivity in a naturally grazed Caribbean ecosystem. *Ecology* 101(12): 1–13.

Gulick A. G., Johnson R. A., Pollock C. G., Hillis-Starr Z., Bolten A. B. & Bjorndal K. A. 2021: Recovery of a cultivation grazer: a mechanism for compensatory growth of *Thalassia testudinum* in a Caribbean seagrass meadow grazed by green turtles. *Journal of Ecology* 109(8): 3031–3045.

Gunawan D., Kodir A., Kurniawan T., Subas S., Lidiawati L. & Kurniawan A. 2018: Protecting the green turtle through integrated coastal management. In: Chua T.-E., Chou L. M, G. Jacinto, Ross S.A., & D. Bonga (eds.) 2018: *Local Contributions to Global Sustainable Development Agenda: Case Studies in Integrated Coastal Management in the East Asian Seas Region*. Pemsea, Quezon, pp. 269–282.

Haque N. 2023: What is Convolutional Neural Network — CNN (Deep Learning). Dostupné z: <https://www.linkedin.com/pulse/what-convolutional-neural-network-cnn-deep-learning-nafiz-shahriar/>. Verze z: 13. 1. 2025.

Heaslip S. G., Iverson S. J., Bowen W. D. & James M.C. 2012: Jellyfish Support High Energy Intake of Leatherback Sea Turtles (*Dermochelys coriacea*): Video Evidence from Animal-Borne Cameras. *PloS one* 7(3): 1–7.

Hemelikova A., Chajma P., Ferasyi T. R., Awaluddin A., Fadli N., Sari W., Hof Ch., Riskas K. & Vojar J. (v tisku): *Sea Turtle Exploitation in Sumatra, Indonesia: Disentangling the Roles of Religion, Culture and Socio-Demographics to Support Effective Conservation. Indonesia: Disentangling the Roles of Religion, Culture and Socio-Demographics to Support Effective Conservation*. Dostupné z SSRN: <https://dx.doi.org/10.2139/ssrn.5008057>.

Hendrix H. & Pérez-Espona S. 2024: A Systematic Review of Population Monitoring Studies of Sea Turtles and Its Application to Conservation. *Diversity* 16(3): 1–17.

Hewavisenthi S. 1990: Exploitation of Marine Turtles in Sri Lanka: Historic Background and the Present Status. *Marine Turtle Newsletter* 48: 14–19.

Hirth H. F. & Ogren L. H. 1987: *Some Aspects of the Ecology of the Leatherback Turtle Dermochelys Coriacea at Laguna Jalova, Costa Rica*. US Department of Commerce, Seattle.

Houghton J. D., Doyle T. K., Wilson M. W., Davenport J. & Hays G. C. 2006: Jellyfish aggregations and leatherback turtle foraging patterns in a temperate coastal environment. *Ecology* 87(8): 1967–1972.

Hounslow J. L. 2023: Behavioural ecology of the flatback turtle in the era of big data. Disertační práce, Murdochova univerzita, Perth.

Hudgins J. A., Hudgins E. J., Köhnk S., Riyad E. M. & Stelfox M. R. 2023: A brighter future? Stable and growing sea turtle populations in the Republic of Maldives. *PloS one* 18(4): 1–19.

Chandraratne R. M. M. 1997: Some reptile bones from the Gedige excavation in 1985, the Citadel of Anuradhapura, Sri Lanka. *Lyriocephalus* 3(2): 7–15.

Chemello G., Trotta E., Notarstefano V., Papetti L., Di Renzo L., Matiddi M., Silvestri C., Carnevali O. & Gioacchini G. 2023: Microplastics evidence in yolk and liver of loggerhead sea turtles (*Caretta caretta*), a pilot study. *Environmental Pollution* 337: 1–9.

Cherepanov G. O. 2014: Patterns of scute development in turtle shell: symmetry and asymmetry. *Paleontological Journal* 48: 1275–1283.

Institut biostatistiky a analýz Lékařské fakulty Masarykovy univerzity 2024: Matematická biologie učebnice: Matematický model a aktivní dynamika neuronu. Dostupné z <https://portal.matematickabiologie.cz/index.php?pg=analiza-a-hodnoceni-biologickych-dat--umela-inteligence--neuronove-site-jednotlivy-neuron--jednotlivy-neuron--matematicky-model-a-aktivni-dynamika-neuronu>. Verze z 23. 11. 2024.

IUCN Red List 2025b: Green Turtle – *Chelonia mydas*. Dostupné z: <https://www.iucnredlist.org/species/4615/247654386>. Verze z: 30. dubna 2004.

IUCN Red List 2025a: Leatherback Turtle – *Dermochelys coriacea*. Dostupné z: <https://www.iucnredlist.org/species/6494/43526147>. Verze z: 21. června 2013.

IUCN Red List 2025c: Loggerhead Turtle – *Caretta caretta*. Dostupné z: <https://www.iucnredlist.org/species/3897/119333622>. Verze z: 23. srpna 2015.

IUCN Red List 2025d: Olive Ridley Turtle – *Lepidochelys olivacea*. Dostupné z: <https://www.iucnredlist.org/species/11534/3292503>. Verze z: 30. června 2008.

IUCN Red List 2025e: Kemp's Ridley – *Lepidochelys kempii*. Dostupné z: <https://www.iucnredlist.org/species/11533/155057916>. Verze z: 14. ledna 2019.

IUCN Red List 2025f: Hawksbill Turtle – *Eretmochelys imbricata*. Dostupné z: <https://www.iucnredlist.org/species/8005/12881238>. Verze z: 30. června 2008.

IUCN Red List 2025g: Flatback – *Natator depressus*. Dostupné z: <https://www.iucnredlist.org/species/14363/210612474>. Verze z: 1. září 1996.

J. Frazier 2005: Marine Turtles: The Role of Flagship Species in Interactions Between People and the Sea. *Mast* 2005 3(2) and 4(1): 5–38.

Jayathilaka R. A. M., Perera H. A. C. C. & Haputhanthri S. S. K. 2017: Marine Turtles of Sri Lanka; Status, Issues, Threats and Conservation Strategies. *Working Party on Ecosystems and Bycatch (WPEB) of Indian Ocean Tuna Commission (IOTC)*: 1–12.

Jensen A. 2009: Shifting focus: Redefining the goals of sea turtle consumption and protection in Bali. *Independent Study Project (ISP) Collection*: 1–62.

Jonklass C. 1937: Fishers of Portugal Bay. *Loris* 1: 75–62.

Kapurusinghe T. & Saman M. M. 2001: Marine Turtle by-catch in Sri Lanka. Three year study from September 1996 to September 1999. In: Coyne M. S. & Clark R. D. (eds.): *Proceedings of the 21st annual symposium on marine turtle biology and conservation*. NOAA, Philadelphia, pp. 45–47.

Kapurusinghe T. 2012: Turtle night watch nature tourism: Sharing benefits to sustain local community and sea turtles in Rekawa Sanctuary, Sri Lanka. In: Legrand W., Simons-Kaufmann C., Sloan P. (eds): *Sustainable Hospitality and Tourism as Motors for Development. Case Studies from Developing Regions of the World*. Routledge, London, pp. 377–389.

Kardong K. V. 2006: *Vertebrates: comparative anatomy, function, evolution*. McGraw-Hill, New York.

Karunaweera N., Galappaththy G. & Wirth D. 2014: On the road to eliminate malaria in Sri Lanka: Lessons from history, challenges, gaps in knowledge and research needs. *Malaria journal* 13(59): 1-10.

Kelly E. L. A., Eynaud Y., Clements S. M., Gleason M., Sparks R. T., Williams I. D. & Smith J. E. 2016: Investigating functional redundancy versus complementarity in Hawaiian herbivorous coral reef fishes. *Oecologia* 182: 1151–1163.

Kluyver T., Ragan-Kelley B., Pérez F., Granger B., Bussonnier M., Frederic J., Willing C. 2016: Jupyter Notebooks – a publishing format for reproducible computational workflows. In: Loizides F. & Schmidt B. (eds.): *Positioning and Power in Academic Publishing: Players, Agents and Agendas*. IOS Press, Amsterdam, pp. 87–90.

Koonce B. 2021: *Convolutional Neural Networks with Swift for Tensorflow. Image Recognition and Dataset Categorization*. Apress, Berkeley.

Kufel J., Bargieł-Łączek K., Kocot S., Koźlik M., Bartnikowska W., Janik M., Czogalik Ł., Dudek P., Magiera M., Lis A., Paszkiewicz I., Nawrat Z., Cebula M. & Gruszczyńska K. 2023: What Is Machine Learning, Artificial Neural Networks and Deep Learning? – Examples of Practical Applications in Medicine. *Diagnostics* 13: 1–22.

- LeCun Y., Cortes C. & Burges C. J. 2024: MNIST. Dostupné z: <https://www.tensorflow.org/datasets/catalog/mnist>. Verze z: 1. 6. 2024.
- Lee S. H., Tseng L. C., Yoon Y. H., Ramirez-Romero E., Hwang J. S. & Molinero J. C. 2023: The global spread of jellyfish hazards mirrors the pace of human imprint in the marine environment. *Environment International* 171: 1–10.
- León Y. M. & Bjorndal K. A. 2002: Selective feeding in the hawksbill turtle, an important predator in coral reef ecosystems. *Marine Ecology Progress Series* 245: 249–258.
- Lindborg R. J., Peruyero P. & Witherington B. E. 2023: Use of a scent-detection dog for sea turtle nest monitoring of three sea turtle species in Florida. *PloS one* 18(9): 1–17.
- London Data Consulting (LDC) 2023: Inference in Machine Learning and Deep Learning: What is it? How to use it? Ultimate Guide 2023. Dostupné z: <https://londondataconsulting.medium.com/inference-in-machine-learning-and-deep-learning-what-is-it-how-to-use-it-ultimate-guide-2023-152fed531edc>. Verze z: 19. 1. 2023.
- Luschi P., Hays G. C., Del Seppia C., Marsh R. & Papi F. 1998: The navigational feats of green sea turtles migrating from Ascension Island investigated by satellite telemetry. *Proceedings of the Royal Society of London* 265(1412): 2279–2284.
- Lutz P. L., Musick J. A. & Wyneken J. (eds) 2003: *The Biology of Sea Turtles, Volume II*. Taylor & Francis, Boca Raton.
- Lovich J. E., Ennen J. R., Agha M. & Gibbons, J. W. 2018: Where have all the turtles gone, and why does it matter? *BioScience* 68(10): 771–781.
- Mancini A., Senko J., Borquez-Reyes R., Póo J. G., Seminoff J. A., & Koch V. 2011: To poach or not to poach an endangered species: elucidating the economic and social drivers behind illegal sea turtle hunting in Baja California Sur, Mexico. *Human Ecology* 39: 743–756.
- Manzoor U., Amtyaz S., Usman, M., Hashmi, M., Nasim S., Ponum N., Tanveer J. & Erum M. 2023: Status of Marine Turtles In Some Selected Asian Countries: A Review. *Canadian Journal of Pure and Applied Sciences* 17(1): 5637–5647.
- Mayer C. E. 2020: T-shirts and Turtles. *Pacific Arts* 20(1): 76–87.
- Mazaris A. D., Schofield G., Gkazinou C., Almpanidou V. & Hays G. C. 2017: Global sea turtle conservation successes. *Science advances* 3(9): 1–7.

McClenachan L., Jackson J. B. & Newman M. J. 2006: Conservation implications of historic sea turtle nesting beach loss. *Frontiers in Ecology and the Environment* 4(6): 290–296.

MEDASSET 2020: International Protection. Dostupné z: <https://medasset.org/international-protection/>. Převzato: 30. dubna 2025.

Microsoft Corporation 2015: Microsoft Visual Studio Code For Windows. Verze 1.99.3.

Microsoft Corporation 1993: Microsoft Excel. Verze 2.91.2.

Mills S. K., Rotger A., Brooks A. M., Paladino F. V. & Robinson N. J. 2023: Photo identification for sea turtles: Flipper scales more accurate than head scales using APHIS. *Journal of Experimental Marine Biology and Ecology* 566: 1–6.

Mrosovsky N., Ryan G. D. & James M. C. 2009: Leatherback turtles: the menace of plastic. *Marine pollution bulletin* 58(2): 287–289.

Munasinghe D. S. A., Nanayakkara K. & Fernando D. C. V. 2021: Sri Lanka and Greco-Roman Maritime Trade Relations. *Journal of Archaeological Studies in India* 1(2): 241–249.

Nasiri Z., Mohammadi M., Jebeli S. A., Gholamalifard M. & Ghasempouri S. M. 2023: Hatcheries efficiency for hawksbill sea turtle (*Eretmochelys imbricata*) conservation in the Persian Gulf: Over a decade monitoring of emergence success and incubation period. *Regional Studies in Marine Science* 64: 1–9.

Nel R., Punt A. E. & Hughes G. R. 2013: Are coastal protected areas always effective in achieving population recovery for nesting sea turtles? *PloS one* 8(5): 1–12.

Nelms S. E., Duncan E. M., Broderick A. C., Galloway T. S., Godfrey M. H., Hamann M., Lindeque P. K. & Godley B. J. 2016: Plastic and marine turtles: a review and call for research. *ICES Journal of Marine Science* 73(2): 165–181.

Nielsen M. 2015: *Neural Networks and Deep Learning*. Determination Press, San Francisco.

NOAA 2023: Sea Turtle Week 2023: Reflecting on Sea Turtle Recovery. Dostupné z: www.fisheries.noaa.gov/leadership-message/sea-turtle-week-2023-reflecting-sea-turtle-recovery. Verze z: 11. června 2023.

- NOAA Fisheries 2025a: Leatherback Turtle. Dostupné z: <https://www.fisheries.noaa.gov/species/leatherback-turtle>. Verze z: 26. února 2025.
- NOAA Fisheries 2025b: Green Turtle. Dostupné z: <https://www.fisheries.noaa.gov/species/green-turtle>. Verze z: 24. února 2025.
- NOAA Fisheries 2025c: Loggerhead Turtle. Dostupné z: <https://www.fisheries.noaa.gov/species/loggerhead-turtle/overview>. Verze z: 26. února 2025.
- NOAA Fisheries 2025d: Olive Ridley Turtle. Dostupné z: <https://www.fisheries.noaa.gov/species/olive-ridley-turtle>. Verze z: 26. února 2025.
- NOAA Fisheries 2025e: Kemp's Ridley Turtle. Dostupné z: <https://www.fisheries.noaa.gov/species/kemps-ridley-turtle>. Verze z: 28. února 2025.
- NOAA Fisheries 2025f: Hawksbill Turtle. Dostupné z: <https://www.fisheries.noaa.gov/species/hawksbill-turtle>. Verze z: 24. února 2025.
- Obura D. O., Harve A., Young T., Eltayeb M. M. & von Brandis R. 2010: Hawksbill turtles as significant predators on hard coral. *Coral Reefs* 29: 759.
- Oceana 2025: Flatback Turtle *Natator depressus*. Dostupné z: <https://oceana.org/marine-life/flatback-turtle/>. Verze z: 4. března 2025.
- Okuyama J., Abe O., Nishizawa H., Kobayashi M., Yoseda K. & Arai N. 2009: Ontogeny of the dispersal migration of green turtle (*Chelonia mydas*) hatchlings. *Journal of Experimental Marine Biology and Ecology* 379: 43–50.
- Papafitsoros K., Panagopoulou A. & Schofield G. 2020: Social media reveals consistently disproportionate tourism pressure on a threatened marine vertebrate. *Animal Conservation* 24(4): 568–579.
- Patel E., Kotera M. & Phillott A. D. 2022: The Roles Of Sea Turtles In Ecosystem Processes And Services. *Indian Ocean Turtle Newsletter* 36: 23–31.
- Pfaller J. B., Bjorndal K. A., Reich K. J., Williams K. L. & Frick M. G. 2008: Distribution patterns of epibionts on the carapace of loggerhead turtles *Caretta caretta*. *Marine Biodiversity Records* 1: 1–4.

Pheasey H., Griffiths R. A., Matechou E. & Roberts D. L. 2023: Motivations and sensitivities surrounding the illegal trade of sea turtles in Costa Rica. *Ecology and Society* 28(4): 1–18.

Phillott A. D. & Shanker K. A. R. T. I. K. 2018: Best practices in sea turtle hatchery management for South Asia. *Indian Ocean Turtle Newsletter* 27: 31–34.

Phillott A. D., Hewapathirana S. & Rajakaruna R. S. 2018: Unregulated Numbers and Management Practices of Sea Turtle Hatcheries an Ongoing Concern in Sri Lanka. *Indian Ocean Turtle Newsletter* 27: 8–17.

Phillott A. D., Kale N. U. P. U. R. & Unhale A. 2021: Are sea turtle hatcheries in India following best practices. *Herpetological Conservation and Biology* 16(3): 652–670.

Piboon P., Brown J., Kaewmong P., Kittiwattanawong K. & Nganvongpanit K. 2025: Biology, Nesting Behavior, Genetic Diversity, and Conservation of Leatherback Sea Turtles: Insights From Thailand and Global Perspectives. *Ecology and Evolution* 15(2): 1–15.

Poonian C. N., Ramilo R. V. & Lopez D. D. 2016: Diversity, habitat distribution, and indigenous hunting of marine turtles in the Calamian Islands, Palawan, Republic of the Philippines. *Journal of Asia-Pacific Biodiversity* 9(1): 69–73.

Pundlik S., Dasare P., Kasbekar P., Gawade A., Gaikwad G., & Pundlik P. 2016: Multiclass classification and class based sentiment analysis for Hindi language. In: *2016 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*. Jaipur, pp. 512–518.

Qian G., Sural S., Gu Y. & Pramanik S. 2004: Similarity between Euclidean and cosine angle distance for nearest neighbor queries. In: *Proceedings of the 2004 ACM Symposium on Applied Computing*. Nicosia, Cyprus, pp. 1232–1237.

Rajakaruna R. S., Dissanayake D. M. N. J., Ekanayake E. M. L. & Ranawana K. B. 2009: Sea turtle conservation in Sri Lanka: assessment of knowledge, attitude and prevalence of consumptive use of turtle products among coastal communities. *Indian Ocean Turtle Newsletter* 10: 1–13.

Rajakaruna R. S., Ekanayake E. M. L., Kapurusinghe T. & Ranawana K. B. 2013: Sea turtle hatcheries in Sri Lanka: their activities and potential contribution to sea turtle conservation. *Indian Ocean Turtle Newsletter* 17: 1–10.

Rajakaruna R., Pemadasa M. G. N. M., Elepathage M. & Abeysundara S. P. 2020: Fisher perceptions and practices and sea turtle bycatch in Sri Lanka. *Indian Ocean Turtle Newsletter* 31: 1–12.

Rajasuriya A. & White A. T. 1994: Coral Reefs of Sri Lanka: Review of Their Extent, Condition, and Management Status. *Coastal Management* 23 (1): 77–90.

Ramirez M., Avens L., Goshe R. L., Snover M., Cook M. & Heppell S. S. 2020: Regional Variation in Kemp's Ridley Sea Turtle Diet Composition and Its Potential Relationship With Somatic Growth. *Frontiers in Marine Science* 7: 1–18.

Raposo C., Patrício A. R., Catry P., Barbosa C., Camará A., Regalla A. & Rebelo R. 2025: Nutrient Input from Green Turtle Eggs and Hatchlings in a West Africa Island and Its Nearshore Environment. *Estuaries and Coasts* 48(3): 1–20.

Rathnayake R. M. W. 2016: 'Turtle watching': A strategy for endangered marine turtle conservation through community participation in Sri Lanka. *Ocean & Coastal Management* 119: 199–207.

Robben D. M., Palaniappan P., Loganathan A. L. & Subbiah V. K. 2023: Increased prevalence and new evidence of multi-species Chelonid Herpesvirus 5 (ChHV5) infection in the sea turtles of Mabul Island, Borneo. *Animals* 13(2): 1–10.

Robertson K., Booth D. T. & Limpus C. J. 2016: An assessment of 'turtle-friendly' lights on the sea-finding behaviour of loggerhead turtle hatchlings (*Caretta caretta*). *Wildlife Research* 43: 27–37.

Rodrigo M. 2021: 'Abnormally high' turtle deaths after acid-laden ship sinks off Sri Lanka. Dostupné z: <https://news.mongabay.com/2021/07/abnormally-high-turtle-deaths-after-acid-laden-ship-sinks-off-sri-lanka/>. Verze z: 26. února 2025.

Rudrud R. W., Kroeker J. W., Leslie H. Y. & Finney S. S. 2007: The sea turtle wars: Culture, war and sea turtles in The Republic of the Marshall Islands. *SPC Traditional Marine Resource Management and Knowledge Information Bulletin* 21: 3–29.

Rusli U. 2019: Nesting of Sea Turtles. In Vonk J. & Shackelford T. (eds): *Encyclopedia of Animal Cognition and Behavior*. Springer Nature Switzerland AG, Cham.

Selig E. R., Hole D. G., Allison E. H., Arkema K. K., McKinnon M. C., Chu J., de Sherbinin A., Fisher B., Glew L., Holland M. B., Ingram J. C., Rao N. S., Russell R. B., Srebotnjak T., Teh L. C. L., Troëng S., Turner W. R. & Zvoleff A. 2019: Mapping global human dependence on marine ecosystems. *Conservation Letters* 12: 1–10.

Sellés-Ríos B., Flatt E., Ortiz-García J., García-Colomé J., Latour O. & Whitworth A. 2022: Warm beach, warmer turtles: Using drone-mounted thermal infrared sensors to monitor sea turtle nesting activity. *Frontiers in Conservation Science* 3: 1–14.

Sharkawy A.-N. 2020: Principle of Neural Network and Its Main Types: Review. *Journal of Advances in Applied & Computational Mathematics* 7: 8–19.

Schneider L., Tucker A. D., Vincent K., Fossette S., Young E. J. & Whiting S. D. 2022: First assessment of mercury (Hg) concentrations in skin and carapace of flatback turtles (*Natator depressus*) (Garman) from Western Australia. *Frontiers in Environmental Science* 10: 1–11.

Schubert C. J. & Calvert S. E. 2001: Nitrogen and carbon isotopic composition of marine and terrestrial organic matter in Arctic Ocean sediments: implications for nutrient utilization and organic matter composition. *Deep Sea Research Part I: Oceanographic Research Papers* 48(3): 789–810.

Silva E., Marco A., da Graça J., Pérez H., Abella E., Patino-Martinez J., Martins S. & Almeida C. 2017: Light pollution affects nesting behavior of loggerhead turtles and predation risk of nests and hatchlings. *Journal of Photochemistry and Photobiology B: Biology* 173: 240–249.

Silva J. C. S., Macêdo D., Zanchettin C., Oliveira A. L., & de Almeida Filho A. T. 2021: Multi-class Mobile money service financial fraud detection by integrating supervised learning with adversarial autoencoders. In: *2021 International Joint Conference on Neural Networks (IJCNN)*. Shenzhen, pp. 1–7.

Sounguet G., Mbina C. & Formia A. 2004: Sea turtle research and conservation in Gabon by Aventures Sans Frontieres, an organisational profile. *Marine Turtle Newsletter* 105: 19–21.

Stampar S. N., da Silva P. F. & Luiz Jr O. J. 2007: Predation on the Zoanthid *Palythoa caribaeorum* (Anthozoa, Cnidaria) by a Hawksbill Turtle (*Eretmochelys imbricata*) in Southeastern Brazil. *Marine Turtle Newsletter* 117: 3–5.

Su C. M., Huang C. T. & Cheng I. J. 2015: Applying a fast, effective and reliable photographic identification system for green turtles in the waters near Luichiu Island, Taiwan. *Journal of Experimental Marine Biology and Ecology* 467: 115–120.

Svobodová H., Stašová P. & Jászayová A. 2021: How to improve the turtle protection in Sri Lanka and make it more efficient. *Wildlanka* 9: 131–144.

Tabak M. A., Norouzzadeh M. S., Wolfson D. W., Sweeney S. J., Vercauteren K. C., Snow N. P., Halseth J. M., Di Salvo P. A., Lewis J. S., White M. D., Teton B., Beasley J. C., Schlichting P. E., Boughton R. K., Wight B., Newkirk E. S., Ivan J. S., Odell E. A., Brook R. K., Lukacs P. M., Moeller A. K., Mandeville E. G., Clune J. & Miller R. S. 2019: Machine learning to classify animal species in camera trap images: Applications in ecology. *Methods in Ecology and Evolution* 10 (4): 585–590.

Tan H. Y., Goh Z. Y., Loh K.-H., Then A. Y.-H., Omar H. & Chang S.-W 2021: Cephalopod species identification using integrated analysis of machine learning and deep learning approaches. *PeerJ* 9: 1–24.

Miller J. D. 1997: Reproduction In Sea Turtles. In: Lutz P. L. & Musick J. A. (eds.): *The Biology of Sea Turtles, Volume I*. CRC Press, Boca Raton.

Teelucksingh S. S., Eckert S. & Nunes P. A. L. D. 2010: Marine Turtles, Ecosystem Services and Human Welfare in the Marine Ecosystems of the Caribbean Sea: A Discussion of Key Methodologies. *Études caribéennes*.

Tennent J. E. 1860: Ceylon: *An Account of the Island, Physical, Historical, and Topographical, with Notices of Its Natural History, Antiquities and Productions* (Vol. 2). Longmans, Green & Co., London.

Thilakarathne E. P. D. N., Lakmini W. A. S. W., Egodaunya K. P. U. T., Bandara T., Srimali A. B. K. M., Ramawickrama N. W., Maldeniya M. U. S. & Coswatte A. C. W. W. M. C. L. K. 2024: Sea Turtles are at Risk: Unraveling the Major Threats and Conservation Challenges Encountered by Sea Turtles in Southern Sri Lanka. *Ocean Science Journal* 59: 1–11.

Thums M., Waayers D., Huang Z., Pattiaratchi C., Bernus J. & Meekan M. 2017: Environmental predictors of foraging and transit behaviour in flatback turtles *Natator depressus*. *Endangered Species Research* 32: 333–349.

Thums M., Whiting S. D., Reisser J. W., Pendoley K. L., Pattiaratchi C. B., Harcourt R. G., McMahon C. R. & Meekan M. G. 2013: Tracking sea turtle hatchlings—a pilot study using acoustic telemetry. *Journal of Experimental Marine Biology and Ecology* 440: 156–163.

Unsworth R. K., Nordlund L. M. & Cullen-Unsworth L. C. 2019: Seagrass meadows support global fisheries production. *Conservation Letters* 12(1): 1–8.

Wang H., Cai Y., Zhang Y., Pan H., Lv W. & Han H. 2015: Deep Learning for Image Retrieval: What Works and What Doesn't. In: Cui P., Dy J., Aggarwal Ch., Zhou Z.-H., Tuzhilin A., Xiong H. & Wu X. (eds): *2015 IEEE International Conference on Data Mining Workshop (ICDMW)*, Atlantic City, pp. 1576–1583.

Weerakkody M. 1992: Sri Lanka as known to Strabo. *The Sri Lanka Journal of Humanities* 15(1-2): 55–64.

Whittow G. C. & Balazs H. G. 1982: Basking Behavior of the Hawaiian Green Turtle (*Chelonia mydas*). *Pacific Science* 36(2): 129–139.

Wickramasinghe S. 1981: Turtles and their conservation. *Loris* 15(6): 313–315.

Wieland G. R. 1896: *Archelon ischyros*; a new gigantic cryptodire testudinate from the Fort Pierre Cretaceous of South Dakota. *American Journal of Science* 4(12): 399–412.

Wabnitz C. C., Balazs G., Beavers S., Bjorndal K. A., Bolten A. B., Christensen V., Hargrove S. & Pauly D. 2010: Ecosystem structure and processes at Kaloko Honokōhau, focusing on the role of herbivores, including the green sea turtle *Chelonia mydas*, in reef resilience. *Marine Ecology Progress Series* 420: 27–44.

Wilcox C., Heathcote G., Goldberg J., Gunn R., Peel D. & Hardesty B. D. 2015: Understanding the sources and effects of abandoned, lost, and discarded fishing gear on marine turtles in northern Australia. *Conservation biology* 29(1): 198–206.

World Wildlife Fund 2007: *WWF Position On Circle Hooks*. WWF International, Gland.

Xia, Y., Hu, Y., Liu, W., Que, T., 2024: Research on Re-Identification of Amur Tigers and Bengal Tigers. In: *2nd International Conference on Big Data and Privacy Computing (BDPC)*, Macau, pp. 141–147.

Ye H., Wu Z., Zhao R.-W., Wang X., Jiang Y.-G. & Xue X. 2015: Evaluating Two-Stream CNN for Video Classification. In: *Proceedings of the 5th ACM on International Conference on Multimedia Retrieval*. ICMR, Shanghai, pp. 435–442.

Ye M., Shen J., Lin G., Xiang T., Shao L., Hoi S. C. H. 2021: Deep Learning for Person Re-identification: A Survey and Outlook. *IEEE transactions on pattern analysis and machine intelligence* 44(6): 2872–2893.

Yoshida M., Motokawa M. & Endo H. 2022: Osteological and vascular morphology and electrolyte homeostasis of sea turtles. *Journal of Veterinary Medical Science* 84(7): 1001–1009.

Zhang T., Lin L., Li D., Wang J., Liu Y., Li R. & Shi H. 2022: Microplastic pollution at Qilanyu, the largest green sea turtle nesting grounds in the northern South China Sea. *PeerJ* 10: 1–15.

Zhang Y. J., Luo Z., Sun Y., Liu J., & Chen Z. 2023: From beasts to bytes: Revolutionizing zoological research with artificial intelligence. *Zoological Research* 44(6): 1115–1131.

Zhou V. 2019: Neural Networks From Scratch. Dostupné z: <https://victorzhou.com/series/neural-networks-from-scratch/>. Verze z 3. 12. 2024.

Zuerl M., Dirauf R., Koefler F., Steinlein N., Sueskind J., Zanca D., Brehm I., Fersen L.V. & Eskofier B. 2023: PolarBearVidID: A Video-Based Re-Identification Benchmark Dataset for Polar Bears. *Animals* 13: 1–16.

Příloha A Výpis úspěšností modelu při identifikaci jedinců ze všech fotografií

velikost databáze: 40,00 %; prům. úspěšnost: 72,07 %
velikost databáze: 42,50 %; prům. úspěšnost: 72,97 %
velikost databáze: 45,00 %; prům. úspěšnost: 74,22 %
velikost databáze: 47,50 %; prům. úspěšnost: 74,60 %
velikost databáze: 50,00 %; prům. úspěšnost: 76,45 %
velikost databáze: 52,50 %; prům. úspěšnost: 76,29 %
velikost databáze: 55,00 %; prům. úspěšnost: 76,48 %
velikost databáze: 57,50 %; prům. úspěšnost: 77,59 %
velikost databáze: 60,00 %; prům. úspěšnost: 77,91 %
velikost databáze: 62,50 %; prům. úspěšnost: 78,53 %
velikost databáze: 65,00 %; prům. úspěšnost: 79,47 %
velikost databáze: 67,50 %; prům. úspěšnost: 79,32 %
velikost databáze: 70,00 %; prům. úspěšnost: 80,66 %
velikost databáze: 72,50 %; prům. úspěšnost: 81,26 %
velikost databáze: 75,00 %; prům. úspěšnost: 80,65 %
velikost databáze: 77,50 %; prům. úspěšnost: 81,34 %
velikost databáze: 80,00 %; prům. úspěšnost: 81,63 %
velikost databáze: 82,50 %; prům. úspěšnost: 81,97 %
velikost databáze: 85,00 %; prům. úspěšnost: 83,08 %
velikost databáze: 87,50 %; prům. úspěšnost: 82,77 %
velikost databáze: 90,00 %; prům. úspěšnost: 83,83 %
velikost databáze: 92,50 %; prům. úspěšnost: 82,94 %
velikost databáze: 95,00 %; prům. úspěšnost: 82,42 %
velikost databáze: 97,50 %; prům. úspěšnost: 82,06 %

Příloha B Výpis úspěšností modelu při identifikaci jedinců z fotografií z jednotlivých stran hlavy

1. Levá strana

velikost databáze: 40,00 %; prům. úspěšnost: 72,48 %
velikost databáze: 42,50 %; prům. úspěšnost: 73,04 %
velikost databáze: 45,00 %; prům. úspěšnost: 72,89 %
velikost databáze: 47,50 %; prům. úspěšnost: 72,83 %
velikost databáze: 50,00 %; prům. úspěšnost: 78,10 %
velikost databáze: 52,50 %; prům. úspěšnost: 77,97 %
velikost databáze: 55,00 %; prům. úspěšnost: 78,02 %
velikost databáze: 57,50 %; prům. úspěšnost: 77,84 %
velikost databáze: 60,00 %; prům. úspěšnost: 78,22 %
velikost databáze: 62,50 %; prům. úspěšnost: 77,95 %
velikost databáze: 65,00 %; prům. úspěšnost: 78,80 %
velikost databáze: 67,50 %; prům. úspěšnost: 78,56 %
velikost databáze: 70,00 %; prům. úspěšnost: 78,89 %
velikost databáze: 72,50 %; prům. úspěšnost: 79,01 %
velikost databáze: 75,00 %; prům. úspěšnost: 78,82 %
velikost databáze: 77,50 %; prům. úspěšnost: 78,45 %
velikost databáze: 80,00 %; prům. úspěšnost: 79,21 %
velikost databáze: 82,50 %; prům. úspěšnost: 78,61 %
velikost databáze: 85,00 %; prům. úspěšnost: 78,44 %
velikost databáze: 87,50 %; prům. úspěšnost: 77,72 %
velikost databáze: 90,00 %; prům. úspěšnost: 76,89 %
velikost databáze: 92,50 %; prům. úspěšnost: 76,89 %
velikost databáze: 95,00 %; prům. úspěšnost: 76,34 %
velikost databáze: 97,50 %; prům. úspěšnost: 76,34 %

2. Pravá strana

velikost databáze: 40,00 %; prům. úspěšnost: 73,76 %
velikost databáze: 42,50 %; prům. úspěšnost: 75,92 %
velikost databáze: 45,00 %; prům. úspěšnost: 76,78 %
velikost databáze: 47,50 %; prům. úspěšnost: 76,86 %

velikost databáze: 50,00 %; prům. úspěšnost: 77,42 %
velikost databáze: 52,50 %; prům. úspěšnost: 77,42 %
velikost databáze: 55,00 %; prům. úspěšnost: 77,38 %
velikost databáze: 57,50 %; prům. úspěšnost: 78,08 %
velikost databáze: 60,00 %; prům. úspěšnost: 80,47 %
velikost databáze: 62,50 %; prům. úspěšnost: 81,13 %
velikost databáze: 65,00 %; prům. úspěšnost: 80,60 %
velikost databáze: 67,50 %; prům. úspěšnost: 80,43 %
velikost databáze: 70,00 %; prům. úspěšnost: 80,42 %
velikost databáze: 72,50 %; prům. úspěšnost: 80,98 %
velikost databáze: 75,00 %; prům. úspěšnost: 83,65 %
velikost databáze: 77,50 %; prům. úspěšnost: 83,20 %
velikost databáze: 80,00 %; prům. úspěšnost: 82,56 %
velikost databáze: 82,50 %; prům. úspěšnost: 83,16 %
velikost databáze: 85,00 %; prům. úspěšnost: 83,90 %
velikost databáze: 87,50 %; prům. úspěšnost: 83,65 %
velikost databáze: 90,00 %; prům. úspěšnost: 83,27 %
velikost databáze: 92,50 %; prům. úspěšnost: 83,03 %
velikost databáze: 95,00 %; prům. úspěšnost: 83,03 %
velikost databáze: 97,50 %; prům. úspěšnost: 83,03 %

Příloha C Výpis úspěšností modelu při identifikaci jedinců z fotografií z různých částí dne

1. Noční fotografie

velikost databáze: 40,00 %; prům. úspěšnost: 61,91 %
velikost databáze: 42,50 %; prům. úspěšnost: 62,69 %
velikost databáze: 45,00 %; prům. úspěšnost: 64,35 %
velikost databáze: 47,50 %; prům. úspěšnost: 64,64 %
velikost databáze: 50,00 %; prům. úspěšnost: 67,14 %
velikost databáze: 52,50 %; prům. úspěšnost: 67,08 %
velikost databáze: 55,00 %; prům. úspěšnost: 67,30 %
velikost databáze: 57,50 %; prům. úspěšnost: 68,79 %
velikost databáze: 60,00 %; prům. úspěšnost: 68,93 %
velikost databáze: 62,50 %; prům. úspěšnost: 69,33 %
velikost databáze: 65,00 %; prům. úspěšnost: 70,54 %
velikost databáze: 67,50 %; prům. úspěšnost: 70,41 %
velikost databáze: 70,00 %; prům. úspěšnost: 72,48 %
velikost databáze: 72,50 %; prům. úspěšnost: 73,10 %
velikost databáze: 75,00 %; prům. úspěšnost: 72,69 %
velikost databáze: 77,50 %; prům. úspěšnost: 73,30 %
velikost databáze: 80,00 %; prům. úspěšnost: 73,15 %
velikost databáze: 82,50 %; prům. úspěšnost: 73,92 %
velikost databáze: 85,00 %; prům. úspěšnost: 75,83 %
velikost databáze: 87,50 %; prům. úspěšnost: 74,24 %
velikost databáze: 90,00 %; prům. úspěšnost: 75,26 %
velikost databáze: 92,50 %; prům. úspěšnost: 73,72 %
velikost databáze: 95,00 %; prům. úspěšnost: 73,43 %
velikost databáze: 97,50 %; prům. úspěšnost: 73,43 %

2. Denní fotografie

velikost databáze: 40,00 %; prům. úspěšnost: 88,07 %
velikost databáze: 42,50 %; prům. úspěšnost: 89,42 %
velikost databáze: 45,00 %; prům. úspěšnost: 89,76 %
velikost databáze: 47,50 %; prům. úspěšnost: 89,71 %
velikost databáze: 50,00 %; prům. úspěšnost: 90,91 %
velikost databáze: 52,50 %; prům. úspěšnost: 90,79 %

velikost databáze: 55,00 %; prům. úspěšnost: 90,70 %
velikost databáze: 57,50 %; prům. úspěšnost: 90,82 %
velikost databáze: 60,00 %; prům. úspěšnost: 91,63 %
velikost databáze: 62,50 %; prům. úspěšnost: 92,87 %
velikost databáze: 65,00 %; prům. úspěšnost: 92,94 %
velikost databáze: 67,50 %; prům. úspěšnost: 92,79 %
velikost databáze: 70,00 %; prům. úspěšnost: 94,12 %
velikost databáze: 72,50 %; prům. úspěšnost: 94,05 %
velikost databáze: 75,00 %; prům. úspěšnost: 95,08 %
velikost databáze: 77,50 %; prům. úspěšnost: 94,91 %
velikost databáze: 80,00 %; prům. úspěšnost: 94,79 %
velikost databáze: 82,50 %; prům. úspěšnost: 94,47 %
velikost databáze: 85,00 %; prům. úspěšnost: 94,22 %
velikost databáze: 87,50 %; prům. úspěšnost: 93,91 %
velikost databáze: 90,00 %; prům. úspěšnost: 93,77 %
velikost databáze: 92,50 %; prům. úspěšnost: 93,37 %
velikost databáze: 95,00 %; prům. úspěšnost: 92,83 %
velikost databáze: 97,50 %; prům. úspěšnost: 92,59 %