



**FACULTY
OF INFORMATION
TECHNOLOGY
CTU IN PRAGUE**

ASSIGNMENT OF MASTER'S THESIS

Title: Tortoise Recognition
Student: Bc. Zdeněk Svatoň
Supervisor: prof. Ing. Michal Haindl, DrSc.
Study Programme: Informatics
Study Branch: Knowledge Engineering
Department: Department of Applied Mathematics
Validity: Until the end of winter semester 2021/22

Instructions

Unregulated or unsustainable trade in tortoises and freshwater turtles poses a significant threat to wild populations and thus they are protected by CITES (Convention on International Trade in Endangered Species of Wild Fauna and Flora). The Czech Environmental Inspectorate registers all captive legally held tortoises based on their plastron photos.

The thesis objective is to find discriminative carapace features and to develop a tortoise recognition method capable to verify if a tested tortoise is already listed in the registration database, given its species knowledge, or if this tortoise is illegally smuggled.

The resulting method should be efficient and ideally working in a mobile environment.

References

Sedlacek, M. - Haindl, M. - Formanova, D. An Automatic Tortoise Specimen Recognition, 21st Iberoamerican Congress, CIARP 2016, Lima, Peru, Proceedings, ISBN 978-3-319-52276-0, pp. 52 - 59, LNCS, vol. 10125, 2017, Springer.

Duda, R.O., Hart, P.E., Stork, D.G. Pattern Classification, Wiley, 2000, ISBN 978-0-471-05669-0

S.Theodoridis and K. Koutroumbas, Pattern Recognition, Academic Press, 2009

Ing. Karel Klouda, Ph.D.
Head of Department

doc. RNDr. Ing. Marcel Jiřina, Ph.D.
Dean

Prague February 26, 2020



**FAKULTA
INFORMAČNÍCH
TECHNOLÓGIÍ
ČVUT V PRAZE**

Diplomová práce

Detekce želvých plastrů pro rozpoznávání

Bc. Zdeněk Svatoň

Katedra teoretické informatiky

Vedoucí práce: prof. Ing. Michal Haindl, DrSc.

15. ledna 2021

Poděkování

Děkuji především svoji přítelkyni za to, že mi dala dvě krásné děti a svým dětem za to, že mi během práce dopřály klid.

Prohlášení

Prohlašuji, že jsem předloženou práci vypracoval samostatně a že jsem uvedl veškeré použité informační zdroje v souladu s Metodickým pokynem o dodržování etických principů při přípravě vysokoškolských závěrečných prací.

Beru na vědomí, že se na moji práci vztahují práva a povinnosti vyplývající ze zákona č. 121/2000 Sb., autorského zákona, ve znění pozdějších předpisů, zejména skutečnost, že České vysoké učení technické v Praze má právo na uzavření licenční smlouvy o užití této práce jako školního díla podle § 60 odst. 1 citovaného zákona.

V Praze dne 15. ledna 2021

.....

České vysoké učení technické v Praze
Fakulta informačních technologií

© 2021 Zdeněk Svatoň. Všechna práva vyhrazena.

Tato práce vznikla jako školní dílo na Českém vysokém učení technickém v Praze, Fakultě informačních technologií. Práce je chráněna právními předpisy a mezinárodními úmluvami o právu autorském a právech souvisejících s právem autorským. K jejímu užití, s výjimkou bezúplatných zákonných licencí a nad rámec oprávnění uvedených v Prohlášení na předchozí straně, je nezbytný souhlas autora.

Odkaz na tuto práci

Svatoň, Zdeněk. *Detekce želvých plastronů pro rozpoznávání*. Diplomová práce. Praha: České vysoké učení technické v Praze, Fakulta informačních technologií, 2021.

Abstrakt

Žlutohnědá želva (*Testudo hermanni*) je na seznamu ohrožených druhů, a proto je v zájmu ochránců zvířat identifikovat jednotlivce tohoto druhu pomocí biometrických dat z digitálních fotografií. Tato práce navazuje na práci [3], která potvrdila, že biometrická data lze pro jednoznačnou identifikaci využít, nicméně vlastní detekce palstronů, nebyla příliš úspěšná. Proto se tato práce zaměřuje hlavně na datovou sadu postavenou z 323 nekvalitních fotografií s různými kompozicemi scény, orientací krunýře a rozlišením. V detekci palstronů bylo dosaženo úspěšnosti **83,94 %**.

Klíčová slova Rozpoznávání želv, detekce želv, zpracování digitálního obrazu

Abstract

The yellow-brown tortoise (*Testudo hermanni*) is on the list of endangered species, and it is therefore in the interest of animal rights activists to identify individuals of this species using biometric data from digital photographs. This work follows the work [3], which confirmed that biometric data can be used for unambiguous identification, however, the actual detection of plastrons was not very successful. Therefore, this work focuses mainly on a data set built

from 323 low-quality photographs with different compositions of the scene, carapace orientation and resolution. Success rate achieved in the detection of the plastrons was **83.94 %** success rate.

Keywords Recognition of tortoises, tortoise features detection, digital image processing

Obsah

Úvod	3
1 Motivace pro identifikaci jedinců želvy žlutohnědé	5
1.1 CITES a chov suchozemských želv	5
2 Současný stav identifikace želv	7
2.1 Současné metody identifikace	7
2.2 Čipový implantát	7
2.3 Rozlišování želv pomocí obrazu plastronu	8
2.4 Rozlišování želv pomocí délek segmentů	8
3 Rozlišovací vlastnosti želvích krunýřů	9
3.1 Rysy pro identifikaci	9
3.1.1 Délky segmentů	10
3.1.2 Vzdálenosti mezi spojnicemi švů	11
3.2 Označení datové sady obrazů	12
4 Metody použité pro detekci vlastností želvích krunýřů	13
4.1 Segmentace pomocí residuální neuronové sítě	13
4.1.1 Architektura	13
4.1.2 ResNet-101	14
4.1.3 R-CNN neuronové sítě	14
4.1.4 Rozšíření dat	15
4.1.5 Průběh tréninku modelu	16
4.1.5.1 Mask loss	16
4.1.5.2 Bound box loss a Region proposal network loss	16
4.1.5.3 Class loss	16
4.1.6 Výhody lokalizace pomocí neuronové sítě	16
4.2 Detekce hran	17
4.2.1 Canny detektor hran	17

4.2.1.1	Gaussův filtr	18
4.2.1.2	Vypočet gradientu	18
4.3	Harrisův detektor rohů	19
4.4	Rotace obrázků	21
4.5	Grafový algoritmus pro detekci švů (GADS)	21
4.5.1	Optimalizace algoritmu GADS	22
4.5.2	Srovnání GADS algoritmů	23
5	Algoritmus detekce	27
5.1	Lokalizace částí plastronu pomocí neuronové sítě	27
5.2	Odhad orientace plastronu a rotace obrazu	28
5.3	Oříznutí	29
5.4	Aplikace detektoru hran na předpokládané oblasti spojů	30
5.5	Detekce pomocí GADS	31
6	Popis datové sady obrazů plastronů	33
6.1	Rozmezí věku jedinců	33
6.2	Kvalita digitálních obrazů	34
7	Výsledky	37
7.1	IoU Metrika pro posouzení kvality detekce	37
7.2	Úspěšnost detekce plastronu	38
7.3	Úspěšnost detekce centrálního švu	38
7.4	Úspěšnost detekce anální části	38
7.5	Úspěšnost detekce spojů	39
7.6	Měření přesnosti detekce spojů	40
7.6.1	Měření přesnosti detekce J_{L1}	40
7.6.2	Měření přesnosti detekce J_{L2}	40
7.6.3	Měření přesnosti detekce J_{L3}	41
7.6.4	Měření přesnosti detekce J_{L4}	41
7.6.5	Měření přesnosti detekce J_{L5}	41
7.6.6	Měření přesnosti detekce J_{R1}	42
7.6.7	Měření přesnosti detekce J_{R2}	42
7.6.8	Měření přesnosti detekce J_{R3}	42
7.6.9	Měření přesnosti detekce J_{R4}	43
7.6.10	Měření přesnosti detekce J_{R5}	43
7.7	Zhodnocení měření	43
8	Diskuse	45
8.1	Budoucí práce	45
8.2	Nasazení modelu	45
8.3	Optimalizace algoritmu GADS	46
	Závěr	47

Seznam obrázků

2.1	Čipový implantát	7
3.1	Segmentace centrálního švu	10
3.2	Segmentace centrálního švu	11
3.3	Ukázka označeného plastronu.	12
4.1	Ukázka označeného plastronu.	13
4.2	Ilustrace R-CNN.	15
4.3	Ilustrace ROI.	15
4.4	Metriky treninku.	17
4.5	Ukázka výstupů Canny.	19
4.6	Ukázka výstupů Harrisova detektoru.	20
4.7	GADS ilustrace grafu	22
4.8	Ilustrace redundantních hran v grafu.	23
4.9	Ilustrace iterace přes matici D_{dist}	23
4.10	Ilustrace grafu $G_{redundant}$	24
4.11	Ilustrace grafu G_{nr}	24
4.12	Srovnání Redundantní a upravené verze GADS	25
4.13	Průměrný počet hran v grafu Redundantního a upraveného algoritmu GADS	25
5.1	Ilustrace výstupu validní detekce	28
5.2	Ideální rotace a zvětšení obrazu.	29
5.3	Ořezávání	30
5.4	Binární obraz, výstup detektoru hran Canny	30
5.5	Detail spojů D1 a D2 po aplikaci detektoru hran Canny	30
5.6	Ilustrace maskovaných binárních obrazů	31
5.7	Ilustrace výstupu algoritmu	32
6.1	Silně rozostřený a nekompletní plastron	36
6.2	Chybějící horní část	36

6.3	Ukázka plastronu se čtyřmi švy	36
6.4	Ukázka plastronu s prsty	36
7.1	Ilustrace vypočtu metriky IoU	37
7.2	Histogram IoU pro třídu plastron	38
7.3	Histogram IoU pro třídu centrální šev	38
7.4	Histogram IoU pro třídu Spodní část	39
7.5	Histogram IoU pro třídu Spoj	39
7.6	Histogram chyb pro spoj J_{L1}	40
7.7	Histogram chyb pro spoj J_{L2}	40
7.8	Histogram chyb pro spoj J_{L3}	41
7.9	Histogram chyb pro spoj J_{L4}	41
7.10	Histogram chyb pro spoj J_{L5}	41
7.11	Histogram chyb pro spoj J_{R1}	42
7.12	Histogram chyb pro spoj J_{R2}	42
7.13	Histogram chyb pro spoj J_{R3}	42
7.14	Histogram chyb pro spoj J_{R4}	43
7.15	Histogram chyb pro spoj J_{R5}	43
7.16	Ukázka chybné detekce cesty pro silně skloněný šev.	43

Seznam tabulek

6.1	Datумы pořizení první a druhé fotografie jedince.	34
6.2	Seznam zařízení použitých pro vytvoření datové sady.	35
6.3	Rozlišení obrazů v datové sadě.	35
6.4	Hodnota Dpi obrazů v datové sadě.	35

Seznam zkratek

- $D_1 \dots D_6$ Vzdálenost mezi napojením jednotlivých švů
- D_{dist} Matice vzdáleností
- F_n Vektor vlastností jedince n
- G_{nr} Optimalizovaný graf bez redundantních hran
- $G_{reduntant}$ Graf s redundantními hranami
- $J_{L1} \dots J_{L6}$ Spoje bočních švů s centrálním švem na levé straně
- $J_{R1} \dots J_{R6}$ Spoje bočních švů s centrálním švem na pravé straně
- $L_1 \dots L_6$ Délky segmentů centrálního švu na levé straně
- $l_1 \dots l_6$ Normalizovaná délka segmentu na levé straně
- L_l Součet délek segmentů na levé straně
- L_r Součet délek segmentů na pravé straně
- O_{edge} Obraz zpracovaný detektorem Canny
- O_{edge}^i Část obrazu po aplikaci detektoru hran Canny v oblasti spoje i
- $R_1 \dots R_6$ Délky segmentů centrálního švu na pravé straně
- $r_1 \dots r_6$ Normalizovaná délka segmentu na pravé straně
- P_i^c Podmnožina bodů ležících na centrálním švu v oblasti spoje i

Úvod

Tato práce se zabývá především možnostmi využití R-CNN neuronových sítí pro detekci plastrů želvy žlutohnědé (*Testudo hermanni*) na nestandardizovaných fotkách s různou kompozicí scény, osvětlením, rozlišením, pozicí a orientací jedince. Toto by mělo vést ke zlepšení výsledků předchozí práce [3], ve které nebylo dosaženo uspokojivých výsledků při detekci plastru a jeho orientace. Dále budou prozkoumány možnosti zlepšení detekce spojů s centrálním švem. Proto se práce zaměřuje na výsledky v přesné lokalizaci, nikoli vlastní identifikaci.

Motivace pro identifikaci jedinců želvy žlutohnědé

Populace želv žlutohnědých v jejich přirozeném prostředí se rapidně zmenšuje a hrozí jim vyhynutí, z velké části kvůli jejich ilegálnímu odchytu za účelem prodeje jako domácích mazlíčků [1]. Nicméně prodej jedinců narozených v zajetí je legální. Iniciativa CITES se snaží monitorovat stav v zajetí chované populace suchozemských želv pomocí jejich registrace.

1.1 CITES a chov suchozemských želv

CITES je zkratka z anglického „the Convention on International Trade in Endangered Species of Wild Fauna and Flora“. Jedná se tedy o mezinárodní úmluvu (Washingtonská úmluva) o obchodování s ohroženými druhy volně žijících živočichů a rostlin, která nabyla platnosti již v červenci 1975. Jejím smyslem je celosvětová kontrola obchodu s ohroženými druhy volně žijících živočichů a planě rostoucích rostlin. Státy, které přistoupily k podepsání této úmluvy (celkem dosud 162 zemí), se zavázaly bojovat proti nelegálnímu obchodu se vzácnými rostlinami a živočichy. Česká republika podepsala tuto úmluvu 25. 8. 1992 a ta oficiálně vešla v platnost od 1. 1. 1993. [2].

Vzhledem k neblahé situaci ve volné přírodě se tato úmluva více či méně vztahuje na všechny druhy suchozemských želv. Aby se zabránilo jejich pašování, uzákonila se u nás od roku 1997 povinnost registrace každého jedince suchozemské želvy chovaného v zajetí. Od roku 2004 přistoupila Česká republika k Evropské unii, jejíž zákony jsou ještě o něco přísnější než samotný CITES. V Evropě žijí tři druhy suchozemských želv – želva zelenavá (*Testudo hermanni*), želva vroubená (*Testudo marginata*) a želva žlutohnědá (*Testudo graeca*), která je předmětem této práce. Ve všech členských státech Evropské unie, kde se vyskytují, jsou chráněny a jsou zařazeny na evropském seznamu CITES do nejpřísnější kategorie ochrany A. [2]


Současný stav identifikace želv

2.1 Současné metody identifikace

Kvůli výše zmíněným legislativním předpisům je nutné želvy registrovat, to je možné udělat dvěma způsoby.

2.2 Čipový implantát

Tato metoda je relativně snadná a nemá na vnější vzhled želvy vliv, nicméně není permanentním řešením pro celý život jedince. Jedince želvy nelze čipem označit dříve než dosáhnou věku 3-6 let. Chyba při implantaci čipu může výrazně omezit kvalitu života nebo dokonce zkrátit život jedince, viz obrázek 2.2. Čipy jsou náchylné k chybám, vzhledem k tomu, že některé druhy želv se dožívají až 65 let je pravděpodobné, že čip přestane fungovat. Podstatným problémem je také nelegální použití čipu z uhynulých jedinců.



Obrázek 2.1: Srovnání velikosti aplikátoru s jedincem želvy starým přibližně 6 měsíců [2].

2.3 Rozlišování želv pomocí obrazu plastronu

Na rozdíl od identifikace čipem je identifikace z obrazů neinvazivní a pro želvu není nijak škodlivá. Nicméně úspěšnost této metody je závislá na kvalitě fotografie. Úřední fotografie by měla být co nejostřejší, protože musí zachytit co možná nejvíce odchylek růstu jedince. Minimální velikost fotografie splňující tyto parametry je 9 x 13 cm, optimální pak 10 x 15 cm při rozlišení minimálně 200 DPI a ostré kresbě. Plastron zvířete musí vyplňovat alespoň 80 % plochy fotografie, přičemž hlava a nohy jsou v tomto případě její nepodstatnou součástí. Součástí fotografie musí být čitelné měřítko, nejlépe ještě doplněné vhodným podkladem – milimetrovým papírem, který umožňuje odečíst přesné rozměry zvířete [2]. Nicméně většina fotek tyto standardy hrubě nespĺňuje nebo se jedná o skeny.

2.4 Rozlišování želv pomocí délek segmentů

Z článku L. Tichého a K. Kintrové [1] vyplývá, že jako velmi úspěšná metoda identifikace se jeví relativní vzdálenosti mezi nasedáním bočních švů na centrální vertikální šev. S touto metodou dosáhli na ručně měřených obrazech pořízených v rozmezí 2 až 20 měsíců u 90 jedinců želvy žlutohnědé spolehlivosti 99.9 % v identifikaci nepřibuzných jedinců a 97.5-99.8 % u jedinců, kteří mají společnou matku.

Rozlišovací vlastnosti želvích krunýřů

V této kapitole jsou popsány vybrané rysy plastronu vhodné pro identifikaci jedinců. Tyto rysy musí splňovat následující kritéria:

1. Nesmí se výrazně měnit během celého až stoletého života jedince.
2. Musí být dobře viditelné na všech obrazech v datové sadě.
3. Musí se výrazně lišit u každého jedince.

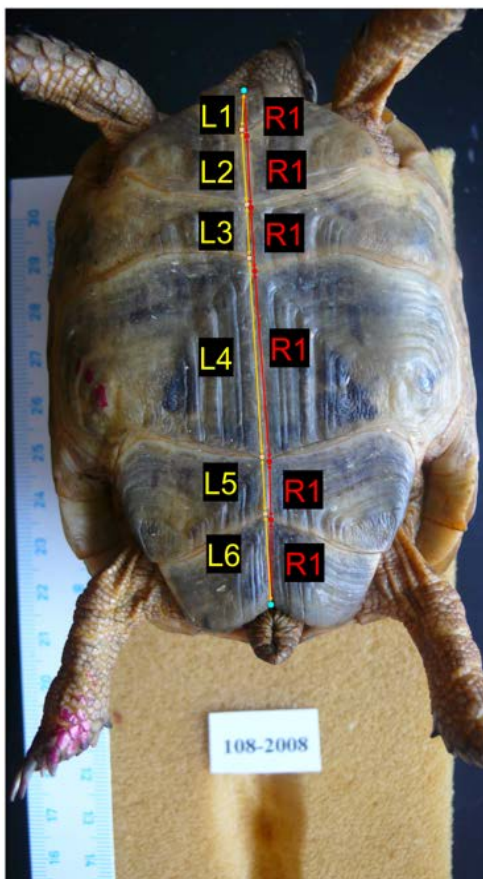
Tato kapitola popisuje jen rysy použité v této práci, vlastnosti ostatních rysů, které nesplňují výše zmíněná kritéria, se v této práci nezabývám. Toto vychází z práce [1], kde byly rysy jako tvar černých skvrn na plastronu, úhly svírané centrálním a bočními švy, tvary spojů, segmenty a tvar bočních švů označeny jako nevhodné pro použití k automatické identifikaci plastronů jedinců želv.

3.1 Rysy pro identifikaci

V této sekci jsou popsány vlastnosti plastronů, kterými jsou dvě sady segmentů na pravé a levé straně centrálního švu. Jejich hlavní výhodou je, že na rozdíl od rysů na jiných částech krunýře, jsou tyto na obrazech vždy zřetelně viditelné a jejich poměr k celkové délce centrálního švu se s věkem jedince nemění.

3.1.1 Délky segmentů

Hlavní součástí vektoru rysů jsou vzdálenosti mezi švy na pravé a levé straně centrálního švu. Na levé straně jsou označeny $L_1, L_2, L_3, L_4, L_5, L_6$ na pravé straně pak nesou označení $R_1, R_2, R_3, R_4, R_5, R_6$ a jsou vypočítány jako euklidovská vzdálenost mezi švy viz 3.1.1.



Obrázek 3.1: Ukázka segmentace centrálního švu.

Tyto vzdálenosti jsou normalizovány celkovou délkou centrálního švu příslušné strany.

$$L_l = \sum_{i=1}^6 L_k \quad L_r = \sum_{i=1}^6 R_k$$

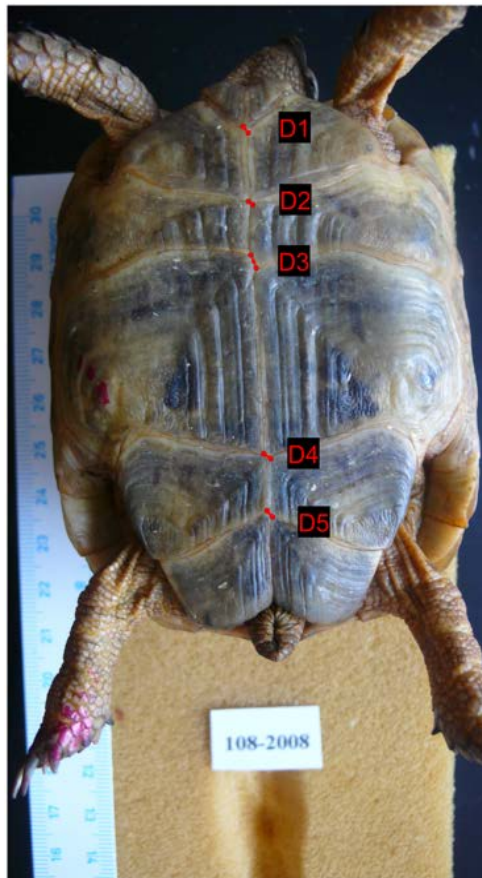
Normalizací se vyhneme problémům s velikostí obrazu, jeho rozlišením a především změnám ve velikosti jedince během jeho života.

$$l_i = \frac{L_i}{L_l} \quad r_i = \frac{R_i}{L_r}$$

Sada pravých a levých segmentů je klíčová pro identifikaci.

3.1.2 Vzdálenosti mezi spojnicemi švů

Další sadou rysů jsou vzdálenosti mezi spojnicemi švů D_1 , D_2 , D_3 , D_4 , D_5 . Tyto rysy se během života jedince také výrazně nemění, nicméně jejich hodnoty jsou ve srovnání s hodnotami L_i a R_i velmi malé a mohou nabývat i záporných hodnot. Pokud je J_{li} výše než J_{ri} je hodnota D_i negativní viz 3.1.2.



Obrázek 3.2: Ukázka Segmentace centrálního švu.

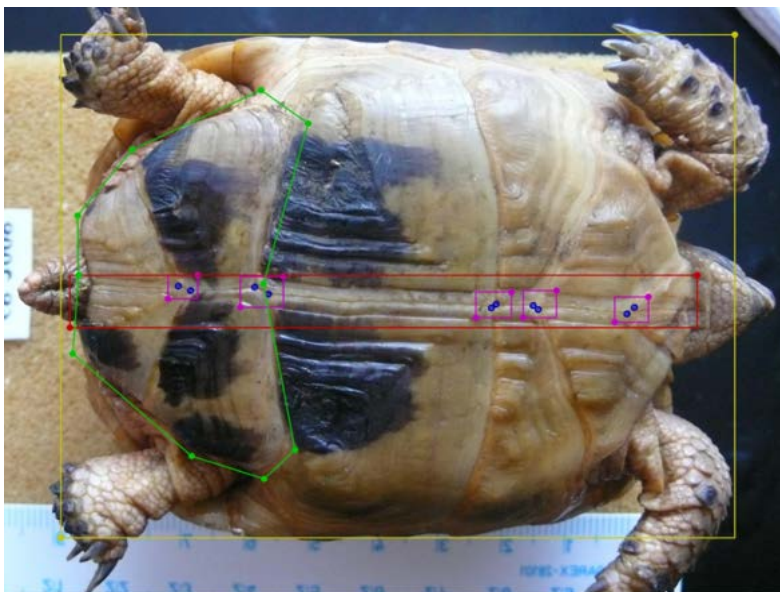
Kompletní vektor atributů pro jedince n tedy vypadá následovně

$$F_n = (l_1 \dots l_6, r_1 \dots r_6, d_1 \dots d_5,)$$

3.2 Označení datové sady obrazů

Pro označení segmentů plastronů byl použit nástroj labelme na obrazu bylo označeno 5 tříd:

1. Plastron (žlutý rámeček) označující výskyt celého krunýře
2. Centrální šev (červený rámeček) prostřední část obsahující všechny spojnice švů
3. Spodní část (zelená oblast) anální část krunýře želvy, která se využívá pro zjištění orientace
4. Průsečík (fialová oblast) oblast obsahující spoj z obou stran
5. Spoj (modrý bod) přesné místo napojení bočního švu na centrální šev



Obrázek 3.3: Ukázka označeného plastronu.

Rozdělení části plastronu do více tříd a podtříd je motivováno vyloučením případných falešných detekcí. Dá se předpokládat, že menší oblasti budou mít nižší přesnost detekce a to znamená, že pokud neleží uvnitř oblasti jim nadřazené, jde s největší pravděpodobností o milnou detekci. Například detekované třídy Průsečík, které neleží uvnitř oblasti centrální šev lze zanedbat viz 3.2.


Metody použité pro detekci vlastností želvích krunýřů

Pro práci bylo nutné vybrat vhodné metody detekce a segmentace. Pro segmentaci byla vybrána neuronová síť resnet101_coco, jako detektory hran byly vyzkoušeny Harrisův detektor rohu a detektor hran Canny. Z předchozí práce [3] potom byla použita myšlenka převodu obrázku na orientovaný graf, kde nejkratší cesta mezi okraji obvykle představuje šev.

4.1 Segmentace pomocí residuální neuronové sítě

4.1.1 Architektura

Architektura residuálních neuronových sítí využívá takzvané zkratky (viz 4.1.1), které přináší nemodifikovaný vstup předchozí na vstup další vrstvy. Typické residuální síť tento skok obvykle aplikují mezi dvěma a více vrstvami



Obrázek 4.1: Ilustrace residuální vrstvy [4]

Hlavní motivací k použití tohoto modelu je slábnoucí gradient, což v nejhorším případě znemožňuje další změnu dané váhy, při jejím tréninku a

umožňuje hlubším vrstvám pracovat i s informací nezkreslenou předchozími vrstvami. To umožňuje předávání informací z mělčích vrstev sítě do hlubších, což pomáhá udržovat šíření signálu i ve velmi hlubokých sítích, u kterých je přesakování spojení kritickou součástí jejich architektury.

4.1.2 ResNet-101

ResNet-101 je konvoluční neuronová síť, která má 101 vrstev. ResNet sestává z jednoho kroku konvoluce a sdružování (oranžově) následovaného 4 vrstvami podobného chování. Každá z vrstev má stejnou architekturu a provádí konvoluci jádrem o rozměrech 3x3 pixely s přeskokem mezi každými dvěma vrstvami. Pro účely této práce byla vybrána verze natrénovaná na datové sadě Common Objects in Context (COCO), která je jedna z nejpopulárnějších open-source datových sad pro rozpoznávání objektů, které se používají k trénování modelů strojového učení. Tato databáze obsahuje stovky tisíc obrazů s miliony již označených objektů pro trénink. Datová sada COCO obsahuje 330 000 obrazů s více než 1 500 000 označených instancí v 80 kategoriích [5]. Síť předtrénovaná na této datové sadě je vhodný kandidát pro detekci želvích krunýřů a relativně přesnou lokalizaci švů. V práci byl využit předtrénovaný model `mask_rcnn_coco.h5`, tento model obsahuje váhy, které představují funkce datových sad COCO, na kterých byl natrénován. Natrénované funkce jsou často přenositelné a výhodné i pro jiné datové sady. Například model trénovaný na velké datové sadě obrázků zvířat bude obsahovat naučené funkce, které budou dobře zachycovat hrany a křivky, které se mohou často vyskytovat i v datových sadách plastronů použitých v této práci.

4.1.3 R-CNN neuronové sítě

R-CNN (Region Based Convolutional Neural Networks) využívají k výběru regionu selektivní vyhledávání postupným zvětšováním velmi malých oblastí s odlišnými texturami. K postupnému růstu regionu se využívá hladový algoritmus, který vždy vyhledá dvě nejpodobnější oblasti a spojí je dohromady. Podobnost mezi oblastmi a a b je vyjádřena následujícím vzorcem.

$$S(a, b) = S_{texture}(a, b) + S_{size}(a, b)$$

Kde

$$S_{texture}(a, b)$$

popisuje vizuální podobnost regionu a

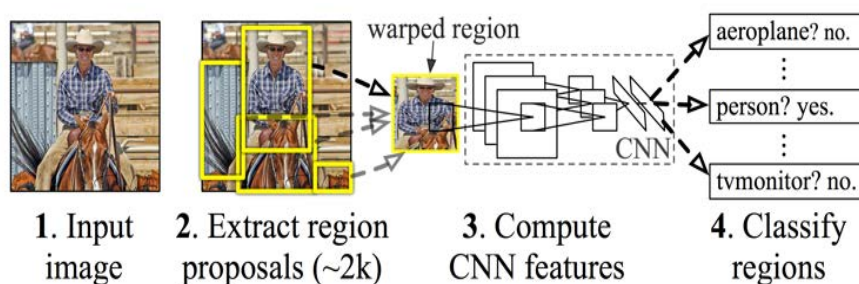
$$S_{size}(a, b)$$

je funkcí velikosti regionu. Algoritmus preferuje menší regiony viz 4.1.3 [6].

Pos segmentaci oblastí se sestaví rámček kterým se oblast vybere, normalizuje a pošle na vstup konvoluční neuronové sítě viz 4.1.3



Obrázek 4.2: Ilustruje v horní řadě postupné spojování regionů. V dolní řadě regiony zájmu. Zeleně jsou označeny objekty, které jsou cílem detekce. [6]



Obrázek 4.3: popisuje způsob zpracování R-CNN zleva doprava 1. Vstupní obraz. 2. Návrh regionu a transformace obrazu z regionu 3. zpracování konvoluční neuronovou sítí a vlastní klasifikace.[6]

4.1.4 Rozšíření dat

Augmentace obrazů je velmi účinná technika, používaná k umělému vytváření variací ve stávajících obrazech určená k rozšíření existující obrazové datové sady. Toho lze dosáhnout použitím různých transformačních technik, jako je zvětšení stávajícího obrázku, otočení existujícího obrázku o několik stupňů, stříh nebo oříznutí existující sady obrazů. V této práci bylo vzhledem k malému

množství dat velice výhodné využití, právě této techniky. Vzhledem k povaze a malé velikosti datové sady byly vybrány následující augmentace:

- zrcadlové otočení
- Gaussovské rozostření
- rotace o náhodný úhel

4.1.5 Průběh tréninku modelu

Při tréninku modelu je dobré sledovat průběh níže uvedených typu metrik, které nejlépe popisují vlastnosti trénovaného modelu. Pokud se mezi epochami přestanou tyto hodnoty významně měnit, je vhodné trénink ukončit viz 4.1.5.3.

4.1.5.1 Mask loss

Chyba sítě masky (Region Proposal Network), podobně jako ztráta klasifikace, penalizuje nesprávnou binární klasifikaci podle jednotlivých pixelů z popředí a pozadí. Metrika tedy popisuje jak dobře model odlišuje masku obrázku od pozadí.[5]

4.1.5.2 Bound box loss a Region proposal network loss

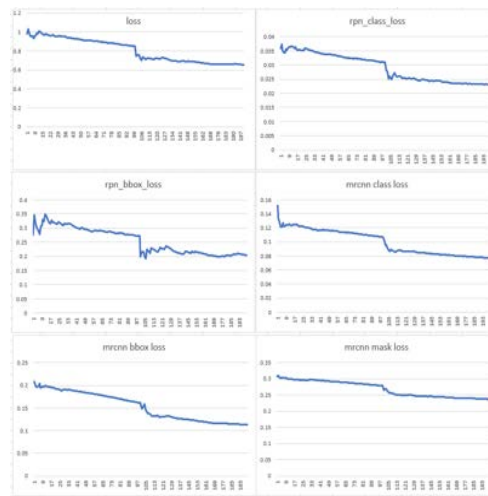
Hodnoty ztrátové funkce ohraničujícího rámečku odrážejí vzdálenost mezi skutečnými rozměry rámečku, viz 4.1.3. Je to tedy rozdíl mezi predikovanými souřadnicemi umístění rámečku, jeho šířkou a výškou proti těm skutečným. Nakonec tedy ukazuje, jak dobře model v lokalizuje objekty v obraze, v případě Region proposal network loss jak dobrý je model v přesné předpovědi oblasti v obraze.

4.1.5.3 Class loss

Ztrátové funkce klasifikace jsou v zásadě závislé na skóre predikce správné třídy, a proto ztrátové funkce klasifikace odrážejí, jak dobrý je model při predikci správné třídy. V případě Mask ronn loss jsou brány v úvahu všechny třídy objektů, popisuje tedy jestli pixel z obrazu byl přiřazen správné třídě, zatímco v případě Region Proposal Network Class loss je jedinou klasifikací, která se provádí, označení segmentů jako popředí nebo pozadí, což je důvod, proč tato ztráta má obvykle nižší hodnoty, protože existují pouze dvě třídy, které lze predikovat.

4.1.6 Výhody lokalizace pomocí neuronové sítě

Oproti ostatním metodám lokalizace, například Generalizovaná Houghova transformace nebo vyhledávání pomocí šablony, je tato metoda velice robustní, není



Obrázek 4.4: Sledované metriky z průběhu treninku neuronové sítě resnet na plastronech

třeba brát v úvahu rotaci krunýře v obrazu. Metoda se dobře vypořádá i s obrazy v různých rozlišeních a barevné hloubce. Osvětlení scény nebo artefakty pozadí také nemají na detekci velký vliv. Pro záměry této práce je to nepodstatné, nicméně tato metoda umožňuje detekovat i více želv na jednom obraze.

4.2 Detekce hran

Pro extrakci informace o pozici švu a jejich průsečíku je nutné obraz převést do binární podoby, pro tyto účely bylo vyzkoušeno několik různých technik i jejich kombinace.

4.2.1 Canny detektor hran

Canny detektor hran je technika vhodná pro extrakci strukturální informace z obrazu, která dramaticky snižuje množství dat k dalšímu zpracování. Je velice často aplikovaná v mnoho systémech pro zpracování obrazu. Je možné ho upravit podle intenzity jednotlivých kanálu, nicméně pro potřeby práce byl využit standardní převod.

4.2.1.1 Gaussův filtr

Pro odstranění šumu z obrazu se využívá Gaussův konvoluční filtr. Rozměry tohoto filtru jsou jedním z parametrů Canny algoritmu.

$$H_{ij} = \frac{1}{2\rho^2} e^{-\frac{(i-(k+1))^2 + (j-(k+1))^2}{2\rho^2}}; 1 < i, j < (2k + 1)$$

ρ parametr je standardní odchylka Gaussova rozdělení a je jedním z parametrů pro Canny algoritmus, pokud je σ roven nule znamená to, že Gaussův filtr není aplikován.

Ukázka Gaussova kernelu pro filtraci. B je výsledná matice A je původní matice a znaménko * označuje konvoluci

$$A = \frac{1}{159} \begin{bmatrix} 2 & 4 & 5 & 4 & 2 \\ 4 & 9 & 12 & 9 & 4 \\ 5 & 12 & 15 & 12 & 5 \\ 4 & 9 & 12 & 9 & 4 \\ 2 & 4 & 5 & 4 & 2 \end{bmatrix} \quad (4.1)$$

Rozměry konvoluční matice mají vliv na odstranění šumu z obrazu, nicméně při použití příliš velkého filtru může dojít ke ztrátě užitečných informací.

4.2.1.2 Vypočet gradientu

Pro vypočet obrazu gradientu g_x a g_y z obrazu rozostřeného pomocí Gaussova filtru se používá konvoluce Sobelovým operátorem.

$$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (4.2)$$

$$\begin{bmatrix} -1 & 0 & -1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad (4.3)$$


Výsledný obraz M je vypočítán následujícím vzorcem:

$$M(x, y) = \sqrt{g_x(x, y)^2 + g_y(x, y)^2}$$

$$\theta = \text{atan2}(g_x, g_y)$$

Poté je aplikovaná metoda ztenčení skeletonizace, takže výsledné hrany budou mít tloušťku pouze jednoho pixelu. Za prvé, jeden ze čtyř hlavních směrů (vodorovný, svislý a dva úhlopříčné směry) jsou přiřazeny všem hodnotám z obrazu α podle nejbližšího směru k danému $\alpha(x, y)$. Pak jsou potlačena non-maxima obrazu g_N , výsledek ztenčovací techniky, je definován jako $g_N(x, y) = 0$. Pokud je hodnota $M(x, y)$ je menší než alespoň jeden ze dvou sousedů $\alpha(x, y)$. Jinak $g_N(x, y) = M(x, y)$. Dalším krokem je aplikování minimální a maximální prahové hodnoty. Aplikaci prahu T_{low} a prahu T_{high} na obraz g_N vzniknou obrazy g_{low} a g_{high} . Pote je obraz g_{low} podroben analýze konetivity a zvalidován proti g_{high} . Výsledkem je binární obraz E viz 4.2.1.2.

$$E(x, y) = \begin{cases} 1 & \text{validní pixel na pozici } (x, y) \\ 2 & \text{nevalidní černýpixel na pozici } (x, y) \end{cases} \quad (4.4)$$



Obrázek 4.5: Ukázka výstupů Canny detektoru hran pro různé parametry σ aplikované na ořezaný centrální šev plastronu.

4.3 Harrisův detektor rohů

Rohy jsou oblasti v obraze s velkou variací intenzity ve všech směrech. Tuto jednoduchou myšlenku lze přenést do matematické podoby. Detektor v podstatě najde rozdíl v intenzitě pro posunutí (u, v) ve všech směrech. To je vyjádřeno níže.

$$(u, v) = \sum_{x, y} \omega(x, y) [I(x_i + \Delta x, y_i + \Delta x) - I(x_i, y_i)]^2$$

4. METODY POUŽITÉ PRO DETEKCI VLASTNOSTÍ ŽELVÍCH KRUNÝŘŮ

Kde $\omega(x, y)$ je obvykle Gaussova konvoluční matice. $I(x_i \Delta x, y_i + \Delta y)$ je posunutá intenzita a $I(x_i, y_i)$ je vlastní intenzita obrazu na souřadnicích x a y . Tuto funkci $E(u, v)$ musíme maximalizovat pro detekci rohů. Použitím Taylorovy expanze na výše uvedené rovnici získáme konečnou rovnici:

$$E(u, v) \approx \begin{bmatrix} u & v \end{bmatrix} M \begin{bmatrix} u \\ v \end{bmatrix}$$

Kde:

$$M = \sum_{x,y} \omega(x, y) \begin{bmatrix} I_x I_x & I_x I_y \\ I_x I_y & I_y I_y \end{bmatrix}$$

Zde jsou I_x a I_y deriváty obrazu ve směrech x a y . Ty lze snadno najít pomocí příslušného Sobelova operátoru. Poté lze vypočítat výsledné skóre, které určuje, zda okno ω může obsahovat roh nebo ne [7].

$$R = \det(M) - k(\text{trace}(M))^2$$

Kde:


$$\det(M) = \lambda_1 \lambda_2$$

$$\text{trace}(M) = \lambda_1 + \lambda_2$$

Pokud je $R < 0$ pak je region hrana.

Pokud je $R > 0$ pak je region roh.

Z výsledného obrazu lze pak filtrovat body s největší hodnotou R , ať už globálně, nebo lokálně podle oblastí dle našeho výběru 4.3.



Obrázek 4.6: Výstup Harrisova algoritmu pro detekci rohů. Z výstupu je vidět, že Harrisův detektor rohů není nejvhodnějším kandidátem pro samostatnou detekci spojů. Nicméně v kombinaci s jinými metodami by mohl přinést jisté zlepšení.

4.4 Rotace obrázků

Vzhledem k různému umístění želvích plastronů na obrázku bylo nutné implementovat metodu, která provede jejich otečení a zároveň vypočítá nutnou změnu velikosti obrazu tak aby nedošlo ke ztrátě dat. Tato metoda musí být použitelná i pro rotaci predikovaných oblastí pro ořez centrálního švu a oblastí predikovaných spojů s bočními švy. Toho lze dosáhnout aplikací rotační matice, jako střed pro rotaci byl vždy vybrán střed oblasti predikovaného plastronu. Rotace o úhel θ je popsána následující maticí

$$M_r = \begin{bmatrix} \cos \theta & -\sin \theta & t_x \\ -\sin \theta & \cos \theta & t_y \\ 0 & 0 & 1 \end{bmatrix} \quad (4.5)$$

Vypočet nové velikosti obrazu

$$w_n = h \sin \theta + w \cos \theta \quad (4.6)$$

$$h_n = h \cos \theta + w \sin \theta \quad (4.7)$$


Kde w_n a h_n jsou nová šířka a výška obrazu.

4.5 Grafový algoritmus pro detekci švů (GADS)

Binární obraz vytvořený libovolným algoritmem například Canny detektorem hran, je transformován na orientovaný graf [3]. Pomocí následujícího dvou-rozměrného pole vzdáleností:

$$D_{dist} = \begin{bmatrix} -1 & -1 & 14 & 16 \\ -1 & 2 & 10 & 12 \\ -1 & 1 & 4 & 9 \\ -1 & 2 & 10 & 12 \\ -1 & -1 & 14 & 16 \end{bmatrix} \quad (4.8)$$

Oproti předchozí práci byla matice sestavena pouze na základě experimentů. Vzhledem k tomu, že bylo nutné prohledávat daleko menší oblasti, bylo nutné vzít v úvahu větší úhel, který mohou postranní švy svírat s centrálním švem. Algoritmus provede vlastní detekci nenulových bodů na okrajích binárního obrazu nebo je možné ho spustit s vlastní kolekcí počátečních a cílových bodů, které jsou mu předány jako vstupní parametr, viz 4.5. GADS algoritmus byl v této práci implementován jen ve směru zleva doprava, takže je nutné provést příslušnou rotaci obrazu před jeho použitím.



Obrázek 4.7: Ukázka grafu vytvořeného pomocí algoritmu GADS. Čtvercové uzly představují nenulové pixely v obrazu. Váhy byly nastaveny pomocí hodnot z pole D_{dist} . Díky vahám grafu pak nejkratší cesty napříč obrazem představují těsně navazující hrany.

4.5.1 Optimalizace algoritmu GADS

Jedním z nedostatků, implementace algoritmu GADS v předchozí práci [3] je redundance hran. Hrany jsou do grafu přidány i v případě, kdy k uzlu již existuje kratší cesta, která je sestavená z hran s menším součtem vah, než má přímá hrana. Toto má vliv na čas běhu Dijkstrova algoritmu, který byl v implementaci pro hledání nejkratší cesty použit.


Časová složitost Dijkstrova algoritmu je dána vzorcem.

$$\theta(V + E \log V)$$


Kde V je počet vrcholů grafu a E počet hran. Na velkých obrazech toto vede k podstatnému prodloužení běhu GADS algoritmu. Nadbytečné hrany jsou vidět na obrázku 4.5.1

Tomuto nedostatku se lze vyhnout upravením algoritmu pro iteraci přes matici D_{dist} , tak aby zanedbával nenulové pixely, které budou nebo byly jistě navštíveny v jedné z následujících iterací. Toho lze dosáhnout tak, že přes matici D_{dist} budeme iterovat po nikoli po řádcích a sloupcích, ale po nejkratších cestách, zkonstruovaných z počátečního bodu, a iteraci po takové cestě zastavíme v okamžiku, kdy narazíme na první nenulový pixel. Optimalizovaný graf je vidět na obrázku 4.5.1

Použitím výše zmíněného algoritmu iterace 4.5.1 přes matici D_{dist} dosáhneme konstrukce orientovaného grafu G_{nr} , s daleko nižším počtem redundantních hran, který ovšem bude obsahovat všechny nejkratší cesty mezi všemi vrcholy stejně, jako graf s redundantními hranami $G_{redundat}$.



Obrázek 4.8: Ilustrace redundantních hran v grafu. Z obrázku je patrné, že hrany s vahami 4 a 9 nemohou být součástí nejkratší cesty, vyznačené zelenými šipkami. Toto platí pro souvislé přímky ve všech směrech podporovaných maticí vah D_{dist} .

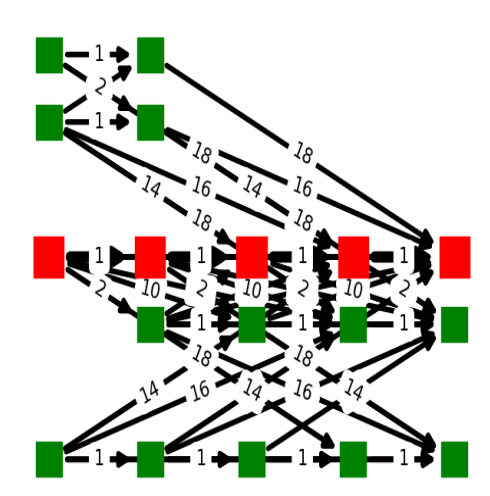


Obrázek 4.9: Ilustrace iterace přes matici D_{dist} . Modře je označen výchozí bod iterace, zeleně označené jsou nenulové pixely pro konstrukci nových hran a červená pole nejsou algoritmem navštívena.


4.5.2 Srovnání GADS algoritmů

Pro srovnání času běhu byla provedena série 100 testů na pseudonáhodně vygenerovaných binárních obrazech o rozměrech 1000x3000 pixelů s průměrným počtem nenulových pixelů 905836.76. Nová neredundantní implementace GADS se ukázala jako mírně rychlejší, nicméně výsledky mohou být zkresleny relativně nízkým počtem opakování měření.

Je zřejmé, že pro větší obrázky a větší matice D_{dist} , které by umožňovali efektivní detekci švů s většími mezerami, by počet redundantních hran exponenciálně rostl a tím pádem by se výrazně zhoršoval i čas běhu. Nicméně test byl proveden jen na obrazech, které se velikostí blížily obrazům použitým v této práci. Algoritmus je závislý na hodnotách vah v matici D_{dist} proto, aby



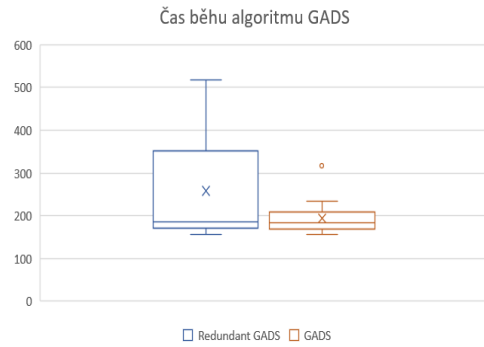
Obrázek 4.10: Ilustrace grafu $G_{redundat}$ s redundantními hranami, který byl zkonstruován iterací přes celou matici D_{dist} . (kvůli nevhodně zvolenému rozvržení grafu nejsou bohužel vidět redundantní hrany mezi horizontálními uzly)




Obrázek 4.11: Ilustrace grafu G_{nr} bez redundantních hran, který byl zkonstruován pomocí nového algoritmu iterace přes matici D_{dist} .

fungoval obecně pro jakoukoli matici D_{dist} , bylo by nutné provést úpravu tak, aby se přidávání nových hran do grafu zastavilo pro pixely, pro které platí, že existuje pixel, který leží na nejkratší možné cestě skrze strom, sestavený z nejkratších cest nad maticí D_{dist} . To klade komplexní nároky na vlastnosti matice D_{dist} , řešení této optimalizace je tedy relativně komplikované a v práci nebylo prozkoumáno.

4.5. Grafový algoritmus pro detekci švů (GADS)



Obrázek 4.12: Box ploty času běhu Redundantní a upravené verze GADS



Obrázek 4.13: Průměrný počet hran v grafu Redundantního a upraveného algoritmu GADS


Algoritmus detekce

V této kapitole je popsán postup a aplikace metod zmíněných v předchozích kapitolách pro vlastní detekci, odhad orientace, rotace obrazu, oříznutí části kritické pro detekci spojů švů nutných k určení délky segmentů $D_1, D_2, D_3, D_4, D_5, L_1, L_2, L_3, L_4, L_5, L_6, R_1, R_2, R_3, R_4, R_5, R_6$.

5.1 Lokalizace částí plastronu pomocí neuronové sítě

Prvním krokem algoritmu je detekce 5.1 plastronu, tato detekce může najít některé třídy vícekrát a proto je vhodné provést jejich jednoduchou validaci podle následujících pravidel.

1. Centrální šev se nachází uvnitř oblasti ohraničující plastron.
2. Střed spodní části se nachází uvnitř centrálního švu.
3. Středy všech detekovaných průsečíků švů se nachází v oblasti detekovaného centrálního švu.



Obrázek 5.1: Ilustrace výstupu validní detekce neuronovou sítí. Zeleně je označena oblast centrálního švu, modře anální část. Uvnitř centrálního švu jsou pak patrné oblasti spojů s bočními švy.

5.2 Odhad orientace plastronu a rotace obrazu

Odhad orientace plastronu je nezbytný pro další detekci. K odhadu orientace bylo využito především segmentu spodní části krunýře a detekovaných oblastí průsečíku, nezbytné bylo vypočítat úhel rotace ve směru hodinových ručiček. Podrobný popis jednotlivých kroků postupu je uveden níže.

1. Z pěti nalezených průsečíků se naleznou dva nejvzdálenější použitím euklidovské vzdálenosti.
2. Střed průsečíku švů, který se nachází v oblasti spodní části je označen jako $T_{low} = (x_{low}, y_{low})$, druhý z nalezené dvojice jako $T_{high} = (x_{high}, y_{high})$
3. Z těchto hodnot je vypočítán vektor $\vec{v}_o = (x_{high} - x_{low}, y_{high} - y_{low})$
4. Úhel rotace θ je vypočítán jako úhel mezi \vec{v}_o a vektorem $\vec{v}_x = (1, 0)$

$$\theta = \arcsin \frac{\vec{a}_1 \vec{b}_2 - \vec{a}_2 \vec{b}_1}{\|\vec{a}\| \|\vec{b}\|}$$

5. Obrázek je otočen o úhel θ a zvětšen pomocí rotační matice 5.2
6. Jako poslední krok rotace jsou stejnou maticí aplikovanou na obraz přepočítány, i souřadnice všech polygonů ohraničujících detekované oblasti se stejným středem rotace.



Obrázek 5.2: Ideální rotace a zvětšení obrazu podle orientace centrálního švu.

5.3 Oříznutí

K dalšímu zpracování je potřeba jen obraz centrálního švu. Ten je oříznut na základě obdélníku detekovaného neuronovou sítí. Hranice pro oříznutí je spočítána jako

$$x_{max} = \max \{p_x^1, \dots, p_x^4\}$$

$$x_{min} = \min \{p_x^1, \dots, p_x^4\}$$

$$y_{max} = \max \{p_y^1, \dots, p_y^4\}$$

$$y_{min} = \min \{p_y^1, \dots, p_y^4\}$$

Tím je dosaženo svislého obdélníku, který obsahuje centrální šev přibližně na své svislé ose a dostatečně dlouhé segmenty bočních švů pro aplikaci GADS algoritmu viz 5.3



Obrázek 5.3: Výsledná červeně označená oblast zkonstruovaná z centrálního švu detekovaného neuronovou sítí.

5.4 Aplikace detektoru hran na předpokládané oblasti spojů

Na ořezanou oblast je aplikován detektor hran Canny viz 5.3 s parametry $\sigma = 0$, $T_{low} = 0$ a $T_{high} = 1$ které by měly vést k maximálnímu množství nalezených artefaktů ve výsledném binárním obraze.



Obrázek 5.4: Binární obraz, výstup detektoru hran Canny


Ve střední části je možné si všimnout souvislých segmentů centrálního švu. Tento fakt zajišťuje, že nejkratší cesta zleva doprava povede grafem zkonstruovaným z binárního obrazu právě skrze tento šev.



Obrázek 5.5: Detail spojů D1 a D2 po aplikaci detektoru hran Canny


5.5 Detekce pomoci GADS

GADS je pro detekci aplikován na obraz s detekovanými hranami z předchozího kroku celkem patnáctkrát, nejprve ve svislém směru (toho je dosaženo rotací obrazu o 90°). Poté jsou postupně vytvořeny masky m_2, \dots, m_6 z detekovaných oblastí spoj výběrem jejich maximálních souřadnic Y_{max} a Y_{min} . Maska m_1 pokrývá celou část obrazu nad maskou m_2 a maska m_7 pokrývá celou část obrazu pod maskou m_6 viz 5.5. Nejprve se maska m_i aplikuje na obraz s detekovaným centrálním švem, tím vznikne obraz O_{cs}^i všechny pixely z tohoto obrazu jsou vybrány do množiny P_{cs}^i , následně se aplikuje na obraz s detekovanými hranami, tím vznikne obraz O_{edge}^i . GADS je potom spuštěn se vstupem O_{left}^i a s body detekovanými na levém okraji obrazu O_{edge}^i jako možným počátkem nejkratší hledané cesty a množinou bodů P_{cs}^i jako možnými konci hledané nejkratší cesty $Path_{min}^i$. Platí, že průnikem množin $Path_{min}^i$ a P_{cs}^i je jediný bod, ten je pak označen jako L_i . Podobně se algoritmus spustí na obrazu O_{edge}^i podruhé jen se záměnou parametrů. P_{cs}^i je použita jako množina možných počátku nejkratší cesty k bodům z množiny O_{right}^i , průnik $Path_{min}^i$ a P_{cs}^i je pak opět jediný bod, který je označen jako R_i . Tento postup je opakován pro všech sedm obrazů O_{cs}^i a O_{edge}^i .



Obrázek 5.6: Ilustrace maskovaných binárních obrazů, použitých jako vstupy pro GADS. Obraz zcela vlevo O_{edge} je použit pro hledání centrálního švu obrazu, dále zleva doprava $O_{edge}^1, O_{edge}^2, O_{edge}^3, O_{edge}^4, O_{edge}^5, O_{edge}^6, O_{edge}^7$

5. ALGORITMUS DETEKCE



Obrázek 5.7: Ilustrace maskovaných finálního výstupu algoritmu. Na obrázku jsou bíle označeny detekované švy a jejich spoje.

Popis datové sady obrazů plastronů

Datová sada použitá v této práci pochází od České Inspekce Životního Prostředí (ČIŽP) a byla zapůjčena pro potřeby této práce z ÚTIA AV ČR. Tato sada obsahuje 323 obrazů z toho 30 jedinců má po dvou obrazech. U 22 obrazů se podařilo získat časové známky toho, kdy byly pořízeny, nicméně věk jedince na první fotce není znám.

6.1 Rozmezí věku jedinců

Z tabulky 6.1 je vidět, že podle data první a druhé fotky byly jedinci foceni v intervalu 3 nebo 5 měsíců.

Id jedince	Datum 1	Datum 2
262	2010:10:24	2011:03:09
261	2010:10:24	2011:03:09
260	2010:10:24	2011:03:09
259	2010:10:24	2011:03:09
258	2010:10:24	2011:03:09
257	2010:10:24	2011:03:09
256	2010:10:24	2011:03:09
255	2010:10:24	2011:03:09
254	2010:10:24	2011:03:09
253	2010:10:24	2011:03:09
252	2010:10:24	2011:03:09
251	2010:10:24	2011:03:09
250	2010:10:24	2011:03:09
249	2010:10:24	2011:03:09
248	2010:10:24	2011:03:09
247	2010:10:24	2011:03:09
246	2010:10:24	2011:03:09
245	2010:10:24	2011:03:09
243	2010:10:24	2011:03:09
242	2010:10:24	2011:03:09
143	2009:05:05	2009:08:16
142	2009:05:05	2009:08:16

Tabulka 6.1: Datумы pořizení první a druhé fotografie jedince.

6.2 Kvalita digitalních obrazů

Z EXIF meta data bylo možné získat i jména zařízení, kterými byly obrazy pořizeny viz 6.2.

[!tbh]

Rozlišení jednotlivých obrazů se také velice různí v tabulce 6.2 jsou uvedeny přibližné počty obrazů rozdělených podle jejich rozlišení, zaokrouhlenému k nejbližší celé stovce. První tři skupiny lze považovat za velmi kvalitní. U ostatních obrazů je kvalita sporná.

Jedním z parametrů požadovaných pro registraci želv je i kvalita obrazu, která by měla dosahovat alespoň 200 Dpi, to splňuje pouze 118 obrazů z datové sady.

Vzhledem k tomu, že obrazy želv z této datové sady byly pořizeny různými autory, nebyly pro všechny obrazy zajištěny identické podmínky osvětlení, ostrosti, barevné hloubky, kompozice scény a pozadí. Nicméně největším obtíží v

Model	Počet
DMC-LX2	92
NIKON D50	102
DMC-FZ20	8
COOLPIX S210	5
Canon PowerShot A70	5
Canon PowerShot S3 IS	5
DMC-FX8	1
Canon MF8100	1
E4200	1
COOLPIX L3	1
Neznámý	94

Tabulka 6.2: Seznam zařízení použitých pro vytvoření datové sady.

Rozlišení	Počet
4300x2400	49
3100x2000	102
1300x800	43
Jiné	129

Tabulka 6.3: Rozlišení obrazů v datové sadě.

Dpi	Počet
300	117
200	1
180	10
72	101
Jiné	94

Tabulka 6.4: Hodnota Dpi obrazů v datové sadě.

lokalizaci plastronů v této datové sadě je různé umístění a orientace plastronů na obrazu. V některých případech na obrazu není vidět celý plastron 6.2 a někdy identifikaci části krunýře zakrývají prsty majitele 6.2. Dále jsem v datové sadě našel několik obrazů želv pravděpodobně odlišného druhu, jejichž centrální šev má pouze 4 spoje 6.2.

Z těchto obrazů je možné vidět, že detekce nemůže být založená pouze na hledání obrysu krunýře, a orientace musí být určena z dobře viditelných částí krunýře, nikoli z tělesných částí jedince jako jsou například přední a zadní

6. POPIS DATOVÉ SADY OBRAZŮ PLASTRONŮ



Obrázek 6.1: Silně rozostřený a nekompletní plastron.



Obrázek 6.2: Chybějící horní část plastronu kritická pro identifikaci L1 a R1.



Obrázek 6.3: Ukázka plastronu se čtyřmi švy.




Obrázek 6.4: Ukázka plastronu s prsty

nohy nebo hlava, které nejsou na obrazech vždy dobře viditelné. Produktem tréninku na takovéto datové sadě by tedy měl být robustní klasifikační model.

Výsledky

7.1 IoU Metrika pro posouzení kvality detekce

V této práci byla měřena pouze kvalita detekce nikoli vlastní identifikace jedinců podle jejich naměřených dat, které byly předmětem několika předchozích prací [1] []. U segmentace a detekce jsem se jako metriku rozhodl využít “Union over Intersection” (Dale jen IoU)



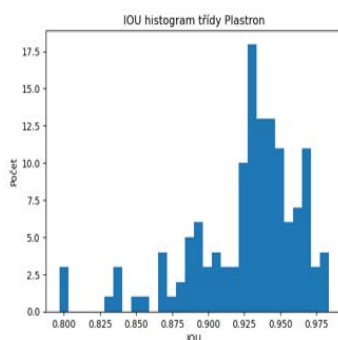
Obrázek 7.1: Ilustrace vypočtu metriky IoU.

Na rozdíl od metrik jako je f1 skóre nebo accuracy, se využívá pro výpočet této metriky koncept podobnosti oblastí S_1 a S_2 a je vypočítán jako.

$$IoU(S_1, S_2) = \frac{|S_1 \cap S_2|}{|S_1 \cup S_2|}$$

7.2 Úspěšnost detekce plastronu


Z histogramu IoU detekce je vidět, že detekce všech plastronů byla úspěšná, všechny hodnoty IoU větší než 0.7 obvykle obsahují všechny potřebné části pro pokračování detekce.



Obrázek 7.2: Histogram IoU pro třídu plastron

7.3 Úspěšnost detekce centrálního švu

Model měl tendenci detekovat oblast centrálního švu obvykle širší, než jak byl označen v tréninkových datech. Proto se zdají výsledky histogramu o něco horší než u segmentu plastron a spodní část. Nicméně to nebrání dalšímu zpracování obrazu.

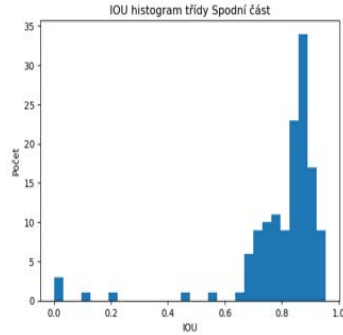


Obrázek 7.3: Histogram IoU pro třídu centrální šev

7.4 Úspěšnost detekce anální části

Spodní část byla pro detekci více problematická, protože je relativně snadné ji zaměnit s jinou částí plastronu, nejčastěji jeho přední částí. V případě chybné

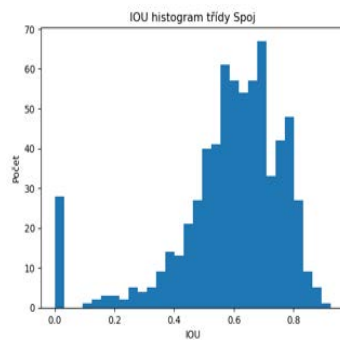
detekce je špatně vypočítán úhel rotace plastronu, to ještě nemusí znamenat, že další detekce selže, nicméně ve vymaskovaném obraze budou s velkou pravděpodobností chybět části bočního švu.



Obrázek 7.4: Histogram IoU pro třídu Spodní část

7.5 Úspěšnost detekce spojů

Třída spoj je nejmenším a nejhůře detekovatelným segmentem. Chyby v detekci této části mají bohužel zásadní vliv na pokračování běhu algoritmu, bez nich není možné sestavit masky nutné pro přesnou detekci spojů a v případě chybné detekce je spoj detekován na nesmyslné pozici. Tato část by se měla nahradit odhadem oblastí z poměru velikosti obrazu, jak bylo provedeno v předchozí práci [3].



Obrázek 7.5: Histogram IoU pro třídu Spoj

7.6 Měření přesnosti detekce spojů


Pro měření přesnosti určení spojů J_{L1} , J_{L2} , J_{L3} , J_{L4} , J_{L5} , J_{R1} , J_{R2} , J_{R3} , J_{R4} , J_{R5} . Byla využita $L2$ metrika.

$$D_{l1(x,y)} = \sqrt{\sum_{i=1}^I (x_i - y_i)^2}$$

Z histogramů výsledků jsou vidět vzdálenosti detekovaných spojů od spojů označených ručně v datové sadě. Datová sada byla označena autorem této práce, který není biologem, proto je nutné brát v potaz i chyby v označení datové sady.

7.6.1 Měření přesnosti detekce J_{L1}


Boční šev nevede ke spoji J_{L1} vodorovně proto je ve výsledných odchylkách v měření velký rozptyl. Jak je patrné z histogramu níže.



Obrázek 7.6: Histogram chyb pro spoj J_{L1}

7.6.2 Měření přesnosti detekce J_{L2}


Chyby u spoje J_{L2} dosahují nízkých hodnot protože boční šev vede k tomuto spoji vodorovně. Jak je patrné z histogramu níže.



Obrázek 7.7: Histogram chyb pro spoj J_{L2}

7.6.3 Měření přesnosti detekce J_{L3}


Chyby u spoje J_{L3} dosahují nízkých hodnot protože boční šev vede k tomuto spoji téměř vodorovně. Jak je patrné z histogramu níže.



Obrázek 7.8: Histogram chyb pro spoj J_{L3}

7.6.4 Měření přesnosti detekce J_{L4}


Boční šev vede ke spoji J_{L4} téměř vodorovně, proto zde algoritmus GADS dosahoval dobrých výsledků. Jak je patrné z histogramu níže.



Obrázek 7.9: Histogram chyb pro spoj J_{L4}

7.6.5 Měření přesnosti detekce J_{L5}


Výsledek detekce J_{L5} je neuspokojivý kvůli sklonu švů v oblasti tohoto spoje. Proto by bylo vhodné zde použít jinou matici vah pro GADS, která by lépe zachycovala sklon švu. Navíc obraz O_{edge} zde obsahuje mnoho artefaktů vytvořených zadními končetinami nebo ocasem želvy. Jak je patrné z histogramu níže.



Obrázek 7.10: Histogram chyb pro spoj J_{L5}

7.6.6 Měření přesnosti detekce J_{R1}


Zde se projevuje stejná chyba jako u švu J_{L1} . Boční šev nevede ke spoji vodorovně J_{R1} , proto je ve výsledných odchylkách v měření velký rozptyl. Jak je patrné z histogramu níže.



Obrázek 7.11: Histogram chyb pro spoj J_{R1}

7.6.7 Měření přesnosti detekce J_{R2}


Chyby u spoje J_{R2} dosahují nízkých hodnot, protože boční šev vede k tomuto spoji vodorovně. Jak je patrné z histogramu níže.



Obrázek 7.12: Histogram chyb pro spoj J_{R2}

7.6.8 Měření přesnosti detekce J_{R3}


Chyby u spoje J_{R3} dosahují nízkých hodnot, protože boční šev vede k tomuto spoji téměř vodorovně. Jak je patrné z histogramu níže.



Obrázek 7.13: Histogram chyb pro spoj J_{R3}

7.6.9 Měření přesnosti detekce J_{R4}


Boční šev vede ke spoji J_{R4} téměř vodorovně, proto zde algoritmus GADS dosahoval dobrých výsledků. Jak je patrné z histogramu níže.



Obrázek 7.14: Histogram chyb pro spoj J_{R4}

7.6.10 Měření přesnosti detekce J_{R5}


Výsledek detekce J_{R5} je neuspokojivý kvůli sklonu švů v oblasti tohoto spoje. Proto by bylo vhodné zde použít jinou matici vah pro GADS, která by lepe zachycovala sklon švu viz 7.6.10. Navíc obraz *Edge* zde obsahuje mnoho artefaktů vytvořených zadními končetinami nebo ocasem želvy.



Obrázek 7.15: Histogram chyb pro spoj J_{R5}

7.7 Zhodnocení měření

Výsledné hledání přesné pozice spojů vykazuje poměrně velkou chybu v pixelech, obzvláště u spojů J_{R1} , J_{L1} a J_{R5} , J_{L5} kde je sklon bočních švů největší. Moje konfigurace algoritmu GADS, preferuje vodorovné spojitě křivé proto je vidět, že u velmi šikmých spojů dojde ke spojení nejkratší cesty se švem jen velmi těsně před dosažením centrálního švu nebo se se švem vůbec nespojí.



Obrázek 7.16: Ukázka chybné detekce cesty pro silně skloněný šev.

Diskuse

Je zřejmé, že s větší datovou sadou by se dalo dosáhnout daleko lepších výsledků segmentace. Velkou roli jistě také hrála kvalita popisků oblastí připravené datové sady, která jistě obsahovala mnoho chyb. Velkou chybou bylo ořezávání, které se zdálo jako dobrý způsob, jak zlepšit přesnost a rychlost algoritmu. Kointuitivně algoritmus GADS funguje daleko lépe v detekci souvislých oblastí ve velkých grafech, na výstupech je možné vidět, že přesná lokalizace centrálního švu je velmi přesná, zatímco ořezáváním zkrácené boční švy vykazují v detekci velkou chybovost. Nepříliš dobře bylo navržené testování výsledků a označení datové sady, z metriky IoU se dá jen velmi špatně vyhodnotit, zda detekovaná oblast obsahuje všechny kritické části.

8.1 Budoucí práce

Hlavním plánem je nyní zkombinovat modely z předchozí práce [3] s vylepšeným modelem pro segmentaci. To by v případě korektně natrénovaného modelu nad profesionálně změřenou datovou sadou mohlo vést až k praktickému nasazení nad registrem CITES. Tato práce sice nedosáhla potřebného zlepšení, nicméně dokázala, že je dosažitelné. Další možností by bylo vyzkoušet i detekci samotných spojů pomocí RPN neuronové sítě, bylo by zajímavé zjistit, jak přesná by tato detekce byla, nicméně je nepravděpodobné, že by šlo o detekci s přesností na jednotky pixelů, která je k vlastní identifikaci potřebná. Jednou z dalších možností by bylo aplikovat strojové učení na exportované tvary švů, to má opět jen velmi malou šanci překonat úspěšnost identifikace plastronu z ručně změřených dat, která je 99,42 % [1].

8.2 Nasazení modelu

Velkou výhodou natrénovaného modelu sítě resnet ve formátu h5 je možnost nasadit ho i na mobilní zařízení, u fotek pořízených nejlépe skrze aplikaci,

by bylo možné v reálném čase nebo alespoň před odesláním fotografie ověřit, že je vhodná k automatizovanému zpracování a všechny klíčové komponenty plastronu jsou dobře detekovatelné. To by teoreticky mohlo zvýšit kvalitu obrazů v registru CITES.

8.3 Optimalizace algoritmu GADS

Jedním z přínosů práce by mohla být optimalizace algoritmu GADS pro obecné matice s vahami vzdáleností, vzhledem k tomu, že algoritmus lze pravděpodobně použít i pro jiné aplikace než detekce švů na plastronech.

Závěr

Pro vlastní měření úspěšnosti bylo využito 137 obrazů, které byly pečlivě označeny pro detekci švů (obrazy použité pro trénink a validaci sítě musely být ze závěrečného testování vyloučeny). Úspěšné detekce centrálního švu a jeho orientace, která umožňovala pokračování běhu algoritmu a detekci všech spojů, bylo dosaženo u 115 obrazů, což je 83,94 %. V předchozí práci [3] byla na datové sadě CEI dosažena 82,97% úspěšnost detekce centrálního švu a 90,83% úspěšnost detekce plastronu. To znamená, že původní algoritmus detekce mohl pokračovat u 76,26 % obrazů [3]. V práci bylo dokázáno, že standard fotografií CEI není dostatečný, pro přesnou automatickou detekci spojů je potřeba kvalita obrazu alespoň 200 Dpi.

Literatura

- [1] L. Tichý a K. Kintrová: *Specimen identification from time-series photographs using plastron morphometry in testudo graeca iberica*. Journal of Zoology, 281(3):210-217, 2010.
- [2] Lubomír Tichý: https://www.sci.muni.cz/botany/salicornia/zzelvy_clan_cites1.htm
- [3] Matěj Sedláček, Michal Haindl, D. Formanová: *An Automatic Tortoise Specimen Recognition. Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 21st Iberoamerican Congress, CIARP 2016*, 52-59. Springer International Publishing, Cham 2017.
- [4] Connor Shorten: <https://towardsdatascience.com/introduction-to-resnets-c0a830a288a4>
- [5] Viraf May: <https://towardsdatascience.com/master-the-coco-dataset-for-semantic-image>
- [6] Koen E. A. van de Sande, Jasper R. R. Uijlings, Theo Gevers, Arnold W. M. Smeulders: *Segmentation as Selective Search for Object Recognition* University of Amsterdam University of Trento, Amsterdam, The Netherlands Trento, Italy
loss Sik-Ho Tsang: <https://towardsdatascience.com/review-faster-r-cnn-object-detection>
- [7] https://docs.opencv.org/master/dc/d0d/tutorial_py_features_harris.html