

Sem vložte zadání Vaší práce.



**FAKULTA
INFORMAČNÍCH
TECHNOLGIÍ
ČVUT V PRAZE**

Diplomová práce

Detekce želvých plastrů pro rozpoznávání

Bc. Zdeněk Svatoň

Katedra teoretické informatiky

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

6. května 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 6. května 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 plastrů 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 jedince 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 a jejich orientace bylo dosaženo úspěšnosti **84,52 %**. Model pro detekci a validaci obrazů palstronů byl nasazen na webový server a je možné ho využít v kombinaci s mobilní aplikací pro OS Android.

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 and their orientation was **84,52 %** success rate. The detection model was deployed on web server and together with Android OS application can be used to validate pictures of plastrons.

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	9
3.1.2 Vzdálenosti mezi spojnicemi švů	10
3.2 Označení datové sady obrazů	11
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	20
4.5	Grafový algoritmus pro detekci švů (GADS)	21
4.5.1	Optimalizace algoritmu GADS	23
4.5.2	Srovnání GADS algoritmů	25
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	Doba mezi pořízením obrazů	35
6.2	Rozlišení obrazů	35
6.3	Dpi	36
7	Výsledky	37
7.1	IoU Metrika pro posouzení kvality detekce	37
7.2	Výstup algoritmu detekce	38
7.3	Úspěšnost detekce plastronu	39
7.4	Úspěšnost detekce centrálního švu	39
7.5	Úspěšnost detekce anální části	40
7.6	Úspěšnost detekce oblasti spojů	40
7.7	Vyhodnocení úspěšnosti detekce	41
7.8	Měření přesnosti detekce spojů	41
7.8.1	Měření přesnosti detekce J_{L1} a J_{R1}	42
7.8.2	Měření přesnosti detekce J_{L2} a J_{R2}	43
7.8.3	Měření přesnosti detekce J_{L3} a J_{R3}	44
7.8.4	Měření přesnosti detekce J_{L4} a J_{R4}	45
7.8.5	Měření přesnosti detekce J_{L5} a J_{R5}	46
7.8.6	Měření přesnosti identifikace	47
7.8.7	Nasazení modelu a mobilní aplikace	49
8	Diskuse	51
8.1	Budoucí práce	51
8.2	Mobilní aplikace	51
8.3	Optimalizace algoritmu GADS	52
	Závěr	53
	Literatura	55

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	Ukazka aplikace GADS.	22
4.9	Žebroví listu nalezené pomocí algoritmu GADS	22
4.10	Ilustrace redundantních hran v grafu.	23
4.11	Ilustrace iterace přes matici D_{dist}	24
4.12	Graf pro L2 vzdálenost.	24
4.13	Graf s konstantní vzdáleností 1	24
4.14	Ilustrace grafu $G_{redundat}$	25
4.15	Ilustrace grafu G_{nr}	25
4.16	Ukazka benchmarku	26
4.17	Srovnání Redundantní a upravené verze GADS	26
4.18	Průměrný počet hran v grafu Redundantního a upraveného algoritmu GADS	26
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	31

5.6	Ilustrace maskovaných binárních obrazů	32
5.7	Ilustrace výstupu algoritmu	32
6.1	Silně rozostřený a nekompletní plastron	34
6.2	Chybějící horní část	34
6.3	Ukázka plastronu se čtyřmi švy	34
6.4	Ukázka plastronu s prsty	34
7.1	Ilustrace vypočtu metriky IoU	37
7.2	Vizualizace výstupu detekce	38
7.3	Histogram IoU pro třídu plastron	39
7.4	Histogram IoU pro třídu centrální šev	39
7.5	Histogram IoU pro třídu Spodní část	40
7.6	Histogram IoU pro třídu Spoj	40
7.7	Úspěšnost detekce	41
7.8	Histogram chyb pro spoj J_{L1}	42
7.9	Histogram chyb pro spoj J_{R1}	42
7.10	Histogram chyb pro spoj J_{L2}	43
7.11	Histogram chyb pro spoj J_{R2}	43
7.12	Histogram chyb pro spoj J_{L3}	44
7.13	Histogram chyb pro spoj J_{R3}	44
7.14	Histogram chyb pro spoj J_{L4}	45
7.15	Histogram chyb pro spoj J_{R4}	45
7.16	Histogram chyb pro spoj J_{L5}	46
7.17	Histogram chyb pro spoj J_{R5}	46
7.18	PCA projekce ručně změřených dat.	47
7.19	PCA projekce dat změřených modelem.	47
7.20	Výsledky k-NN pro ruční měření	48
7.21	Výsledky k-NN pro automatické měření	48
7.22	Nevalidní snímek pořízený mobilní aplikací	49
7.23	Validní snímek pořízený mobilní aplikací	49

Seznam tabulek

6.1	Datумы pořizení první a druhé fotografie jedince.	35
6.2	Rozlišení obrazů v datové sadě.	36
6.3	Hodnota Dpi obrazů v datové sadě.	36

Seznam zkratk

- T_{high} Spoj švů nejbliže hlavě.
- $D_1 \dots D_6$ Vzdálenost mezi napojením jednotlivých švů
- $d_1 \dots d_6$ Normalizovaná vzdálenost mezi napojením jednotlivých švů
- D_{dist} Matice vzdáleností pro algoritmus GADS
- D_{dist} Matice vzdáleností pro algoritmus GADS
- F_n Vektor vlastností jedince n
- G_{nr} Optimalizovaný graf bez redundatních hran
- $G_{reduntant}$ Graf s redundatními hranami
- G_{nr} Optimalizovaný graf bez redundantních hran.
- $G_{redundant}$ Graf obsahující redundantní hrany, které nemohou být součástí nejkratší cesty.
- $J_{L1} \dots J_{L6}$ 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} Binární obraz plastronu
- O_i^{edge} Binární obraz plastronu obsahující pouze spoj i

SEZNAM TABULEK

P_i^{cs}	Nenulové body centrálního švu v oblasti spoje i
P_i^{left}	Nenulové body levého okraje plastronu v oblasti spoje i
P_i^{right}	Nenulové body pravého okraje plastronu v oblasti spoje i
$R_1...R_6$	Délky segmentů centrálního švu na pravé straně
$r_1...r_6$	Normalizovaná délka segmentu na pravé straně
T_{low}	Spoj švů nejbližze zadním nohám.
JSON	Formát souboru JavaScript Object Notation
k-NN	K Nearest Neighbors klasifikátor.

Úvod

Tato práce se zabývá především možností využití R-CNN neuronových sítí pro detekci plastronů 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 plastronu a jeho orientace. Dále budou prozkoumány možnosti zlepšení detekce spojů s centrálním švem. Proto se práce zaměřuje na zlepšení výsledků v přesné lokalizaci, nikoli vlastní identifikaci. Výsledky práce budou koncovým uživatelům zpřístupněny pomocí mobilní aplikace pro OS Android.

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 2.1. 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 nepříbuzných jedinců a 97.5-99.8 % u jedinců, kteří mají společnou matku.[1]

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.



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 3.2.



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. ROZLIŠOVACÍ VLASTNOSTI ŽELVÍCH KRUNÝŘŮ

3. Spodní část (zelená oblast) analní 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 mylnou detekci. Například detekované třídy Průsečík, které neleží uvnitř oblasti centrální šev lze zanedbat viz 3.3.


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), které přináší nemodifikovaný vstup předchozí vrstvy na vstup další vrstvy. Typické residuální síť tento skok obvykle aplikují mezi dvěma a více vrstvami



Obrázek 4.1: Ilustrace residuální vrstvy [5]

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 mělkých vrstev sítě do hlubších, což pomáhá udržovat šíření signálu i ve velmi hlubokých sítích, u kterých je přeskokování 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 opensource 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 [7]. 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

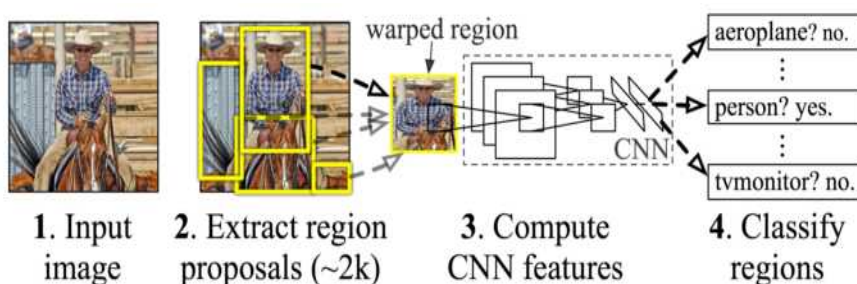
$$S_{size}(a, b)$$

je funkcí velikosti regionu. Algoritmus preferuje menší regiony viz 4.2 [8].

Po segmentaci oblastí se sestaví raméček kterým se oblast vybere, normalizuje a pošle na vstup konvoluční neuronové sítě viz 4.3



Obrázek 4.2: Ilustruje v horní řadě postupné spojování regionů. V dolní řadě regiony zájmu. Zeleně jsou označeny objekty, které jsou cílem detekce. [4]



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 4.4.

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.[7]

4.1.5.2 Bound box loss a Region proposal network loss

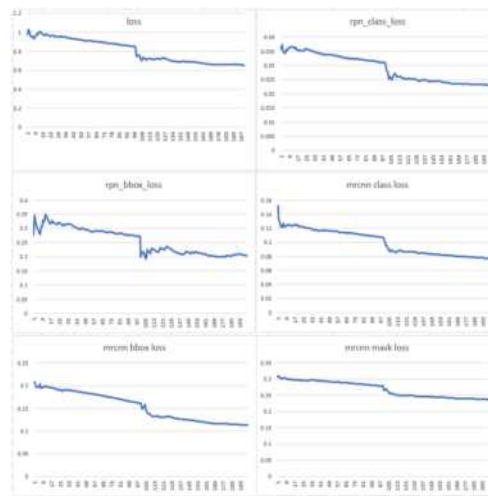
Hodnoty ztrátové funkce ohraničujícího rámečku odrážejí vzdálenost mezi skutečnými rozměry rámečku, viz 4.3. Je to tedy rozdíl mezi predikovanými souřadnicemi umístění rámečku, jeho šířkou a výškou proti těm skutečným. Nakonec tedy ukazuje, jak dobře model v lokalizuje objekty v obraze, v případě Region 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.[7]

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.

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

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 $M(x, y)$ 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 obrázky 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.

$$E(x, y) = \begin{cases} 1 & \text{validní pixel na pozici } (x, y) \\ 2 & \text{nevalidní černýpixel na pozici } (x, y) \end{cases} \quad (4.3)$$



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.

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

Kde $\omega(x, y)$ je obvykle Gaussova konvoluční matice. $I(x_i + \Delta x, y_i + \Delta x)$ je posunutá intezita 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 uvedenou 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 [9].

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


kde

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

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

Pokud je $R < 0$ pak je region hrana. Jestli je $R > 0$ pak je region roh.

Z výsledného obrazu lze pak filtrovat body s největší hodnou 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 otočení 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 uhel θ je popsána následující maticí

$$M_r = \begin{bmatrix} \cos \theta & -\sin \theta & t_x \\ -\sin \theta & \cos \theta & t_y \\ 0 & 0 & 1 \end{bmatrix} \quad (4.4)$$

Vypočet nové velikosti obrazu

$$w_n = h \sin \theta + w \cos \theta \quad (4.5)$$

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

Kde w_n a h_n jsou nová šířka a výška obrazu.

4.5 Grafový algoritmus pro detekci švů (GADS)


GADS slouží k nalezení nejsouvislejší cesty skrze binární obraz ve dvou krocích.

1. Binární obraz je převeden na orientovaný acyklický graf, váhy hran jsou vypočítány z vzájemné polohy bodů z distanční matice D_{dist} . počátek je označen hodnotou -1 viz 4.7
2. Pomocí Dijkstrova algoritmu je nalezena nejkratší cesta tímto grafem mezi dvěma množinami vrcholů (například levý a pravý okraj obrazu), tato cesta (v závislosti na použité matici) je zároveň nejsouvislejší možná cesta mezi těmito množinami.

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

$$D_{dist} = \begin{bmatrix} 9 & 10 & 13 & 18 & 25 \\ 4 & 5 & 8 & 13 & 20 \\ -1 & 2 & 5 & 10 & 17 \\ 4 & 5 & 8 & 13 & 20 \\ 9 & 10 & 13 & 18 & 25 \end{bmatrix} \quad (4.7)$$

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 cestu napříč obrazem představují hrany mezi těsně sousedícími uzly.

Algoritmus má mnoho potenciálních aplikací na rozdíl od běžných detektorů hran poskytuje přesné souřadnice pro všechny pixely, které jsou součástí nalezené cesty je tedy vhodný pro hledání průsečíku hran. Na obrázcích 4.8 a 4.9 použití algoritmu GADS na listu, kde jsem s ním úspěšně detekoval jednotlivá žebra a jejich spoje.



Obrázek 4.8: Ukázka aplikace GADS.



Obrázek 4.9: Žebroví listu nalezené pomocí algoritmu GADS.


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 4.10




Obrázek 4.10: 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} .

Tomuto nedostatku se lze vyhnout upravením algoritmu pro iteraci přes matici D_{dist} tak, aby zanedbával nenulové pixely, které budou jistě navštíveny v jedné z následujících iterací. Toho lze dosáhnout tak, že přes matici D_{dist} budeme iterovat do šířky přes graf viz 4.11. Tento graf je sestavený z nejkratších cest, které vedou z počátku ke všem pixelům v plně zaplněném obraze o stejných rozměrech jako má matice D_{dist} . Všimněte si, že k mnoha pixelům vede více než jedna cesta viz 4.11. Pokud narazíme na nenulový pixel iteraci v této větvi zastavíme a zároveň označíme všechny jeho potomky jako navštívené.


Iterační graf se liší v závislosti na použité matici. Nicméně tuto optimalizaci lze využít pro jakoukoli matici D_{dist} viz. 4.12 a 4.13



Obrázek 4.11: Ilustrace iterace přes matici D_{dist} . Červeně je označen výchozí bod iterace, modře jsou označené nenulové pixely pro konstrukci nových hran a žlutě označené uzly nejsou algoritmem navštíveny. Červené čáry představují zkonstruované hrany.




Obrázek 4.12: Graf pro L2 vzdálenost.




Obrázek 4.13: Graf s konstantní vzdáleností 1.

Použitím výše zmíněného algoritmu iterace 4.11 přes matici D_{dist} dosáhneme konstrukce orientovaného grafu G_{nr} s daleko menším počtem redundantních hran, který ovšem bude obsahovat identické nejkratší cesty mezi všemi vrcholy stejně jako graf s redundantními hranami $G_{redundat}$.



Obrázek 4.14: Ilustrace grafu $G_{redundat}$ s redundantními hranami, který byl zkonstruován iterací přes celou matici D_{dist} .



Obrázek 4.15: Ilustrace grafu G_{nr} bez redundantních hran, který byl zkonstruovaný pomocí nového algoritmu iterace přes matici D_{dist} .


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 hustotou nenulových pixelů cca 5 % viz 4.16


Optimalizovaná implementace GADS se ukázala jako rychlejší viz 4.17.

Je zřejmé, že pro větší obrazy a větší matice D_{dist} , které by umožňovaly 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.

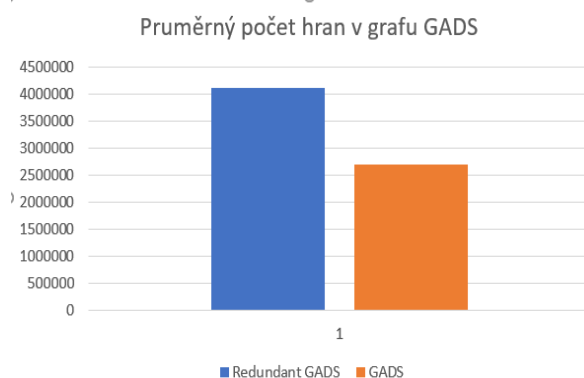
4. METODY POUŽITÉ PRO DETEKCI VLASTNOSTÍ ŽELVÍCH KRUNÝŘŮ



Obrázek 4.16: Ukázka obrazu vygenerovaného pro měření rozdílu mezi původní a optimalizovanou verzí algoritmu GADS. Při testu bylo ověřeno, že obě verze algoritmu vždy přesně zrekonstruují téměř souvislou křivku, která vede vodorovně středem obrazu.



Obrázek 4.17: Box ploty času běhu Redundantní a optimalizované verze GADS



Obrázek 4.18: 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 viz 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 5.4 s parametry $\alpha = 0$, $T_{low} = 0$ 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 viz 5.5. 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} . Masky m_1 pokrývá celou část obrazu nad maskou m_2 a maska m_7 pokrývá celou část obrazu pod maskou m_6 viz 5.6.

1. Masky m_i se aplikuje na obraz s detekovaným centrálním švem a vstupem Harrisova detektoru rohů, tím vznikne množina bodů $P_i^{centralseam}$ které leží na centrálním švu a jsou pravděpodobně rohy.
2. Masky m_i se aplikuje na binární obraz plastronu, tím vznikne obraz O_i^{edge} viz 5.6
3. Z obrazu O_i^{edge} se vyberou nenulové pixely na levé a pravé straně tím vzniknou množiny P_i^{left} a P_i^{right}
4. Z obrazu O_i^{edge} je zkonstruován orientovaný graf G_i
5. V grafu je nalezena nejkratší cesta z množiny bodů P_i^{left} do množiny $P_i^{centralseam}$ poslední bod v této cestě je označen jako spoj J_{Li}
6. V grafu je nalezena nejkratší cesta z množiny bodů $P_i^{centralseam}$ do množiny P_i^{right} , první bod v této cestě je označen jako spoj J_{Ri}

Tento postup je opakován pro všechny odhadnuté oblasti spojů viz 5.6. Následně je z detekovaných švů sestaven výstupní obraz pro manuální kontrolu viz 5.7



Obrázek 5.6: Ilustrace maskovaných binárních obrazů použitých jako vstupy pro algoritmus GADS. Obraz zcela vlevo O_{edge} je použit pro hledání centrálního švu obrazu dále zleva doprava $O_1^{edge}, O_2^{edge}, O_3^{edge}, O_4^{edge}, O_5^{edge}, O_6^{edge}, O_7^{edge}$ jsou použity pro hledání bočních švů a jejich spojů.



Obrázek 5.7: Ilustrace 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 plastronů z toho 30 jedinců má po dvou obrazech.

Vzhledem k tomu, že obrazy želv z této datové sady byly pořízeny různými autory, nebyly pro všechny obrazy zajištěny identické podmínky osvětlení, ostrosti, barevné hloubky, kompozice scény a pozadí. Nicméně největší obtíže v lokalizaci plastronů v této datové sadě jsou různé umístění a orientace plastronů na obrazu. Nedostatečná ostrost pak způsobuje problémy v detekci hran.

V některých případech není vidět celý plastron 6.2 a někdy identifikaci části krunýře zakrývají prsty majitele 6.4. Dále jsem v datové sadě našel několik obrazů želv pravděpodobně odlišného druhu, jejichž centrální šev má pouze 4 spoje 6.3. 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 plastronu, nikoli z tělesných částí jedince jako jsou například přední a zadní nohy nebo hlava, které nejsou na obrazech vždy dobře viditelné.

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

6.1 Doba mezi pořízením obrazů

U 22 obrazů se podařilo získat časové známky toho, kdy byly pořízeny, nicméně věk jedince na první fotce není znám viz tabulka 6.1. Z tabulky 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 pořízení první a druhé fotografie jedince.

6.2 Rozlišení obrazů

Rozlišení jednotlivých obrazů v datové sadě se 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.

V práci se pro měření odlišnosti mezi vypočítanou a skutečnou pozicí spoje využívá vzdálenost v pixelech. Je zřejmé, že odchylka 5 pixelů má zanedba-

6. POPIS DATOVÉ SADY OBRAZŮ PLASTRONŮ

telný význam na obraze s rozlišením 4300x2300 zatímco na obraze s rozlišením 400x200 jde vyznamný rozdíl. Protože plastrony jsou na obrazech různě orientovány nebylo možné odchylky nijak normalizovat.

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

Tabulka 6.2: Rozlišení obrazů v datové sadě.

6.3 Dpi

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.

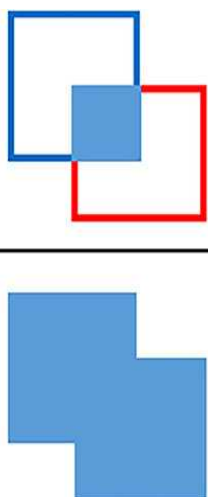
Dpi	Počet
300	117
200	1
180	10
72	101
Jiné	94

Tabulka 6.3: Hodnota Dpi obrazů v datové sadě.

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] [3]. U segmentace a detekce jsem se jako metriku rozhodl využít “Union over Intersection” (Dale jen IoU). Tato metrika dobře zachycuje chybu mezi vypočítanou oblastí a vyžadovanou oblastí viz 7.1

$$IoU = \frac{\text{area of intersection}}{\text{are of union}} = \frac{\text{Diagram 1}}{\text{Diagram 2}}$$



Obrázek 7.1: Ilustrace vypočtu metriky IoU. [10]

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 Výstup algoritmu detekce

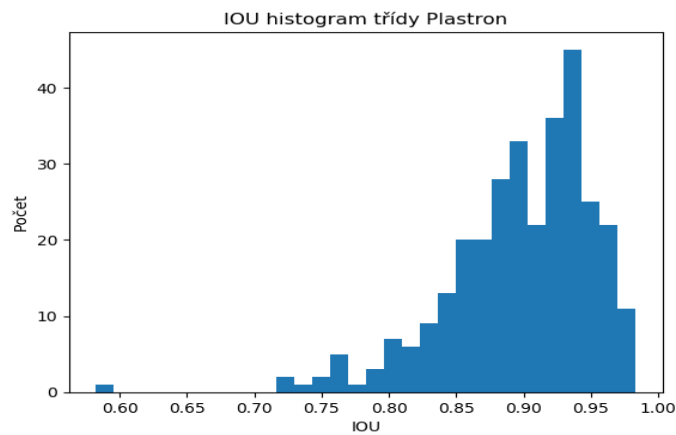
Na obrázku 7.2 je videt výsledek algoritmu detekce. Bílými čarami jsou označeny švy detekované algoritmem gads. Bílé body potom označují detekované spoje s centrálním švem. Na obrázku jsou dobře patrné chyby způsobené chybným ořezáním platronu, obzvláště v pravé horní části.



Obrázek 7.2: Vizulizace výstupu detekce.

7.3 Úspěšnost detekce plastronu


Z histogramu IoU detekce je vidět, že detekce všech plastronů byla úspěšná viz 7.4.



Obrázek 7.3: Histogram IoU pro třídu plastron

7.4 Úspěšnost detekce centrálního švu


Model měl tendenci detekovat oblast centrálního švu obvykle širší, než jak byl označen v tréninkových datech. Proto jsou výsledky histogramu o něco horší než u segmentu plastron a spodní část viz 7.4.



Obrázek 7.4: Histogram IoU pro třídu centrální šev

7.5 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 a to je pro detekci fatální chyba. Viz 7.5



Obrázek 7.5: Histogram IoU pro třídu Spodní část

7.6 Úspěšnost detekce oblasti spojů

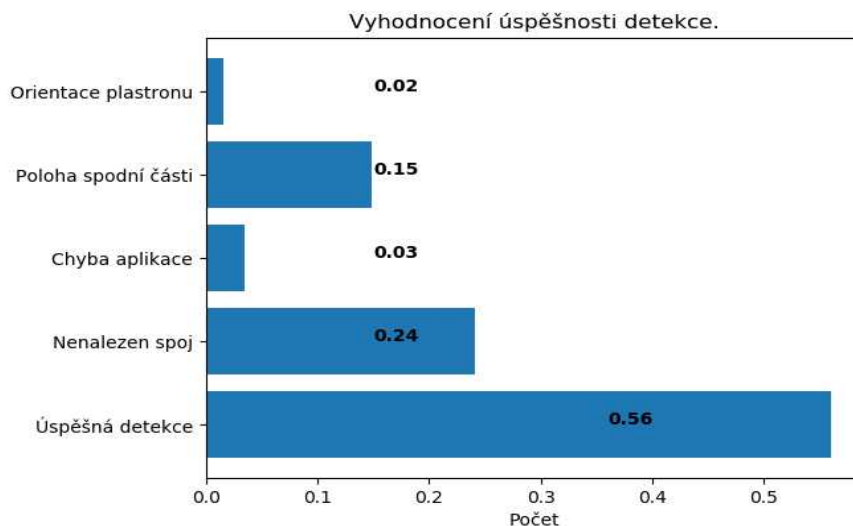
Třída spoj je nejmenším segmentem. Značná rozptyl je způsoben díky rozdílům v ručně označených oblastech, které nemají jasně ohraničené oblasti. Došlo i k několika mylným detekcím mimo oblast centrálního švu viz 7.6 ty bylo ovšem snadné zanedbat a pokračovat v běhu algoritmu. Úspěšné detekce všech pěti oblastí spojů bylo dosaženo na **100 %** plastronů.



Obrázek 7.6: Histogram IoU pro třídu Spoj

7.7 Vyhodnocení úspěšnosti detekce

Detekce plastronu, jeho klíčových částí a odhad orientace byl úspěšný v **56 %** případů. Nejčastějším problémem bylo nenalezení některé z oblastí spoje centrálního a bočních švů. Vzhledem k tomu že algoritmus detekce spojů je na těchto oblastech zavýslé nebylo možné v detekci pokračovat.



Obrázek 7.7: Úspěšnost detekce

7.8 Měření přesnosti detekce spojů

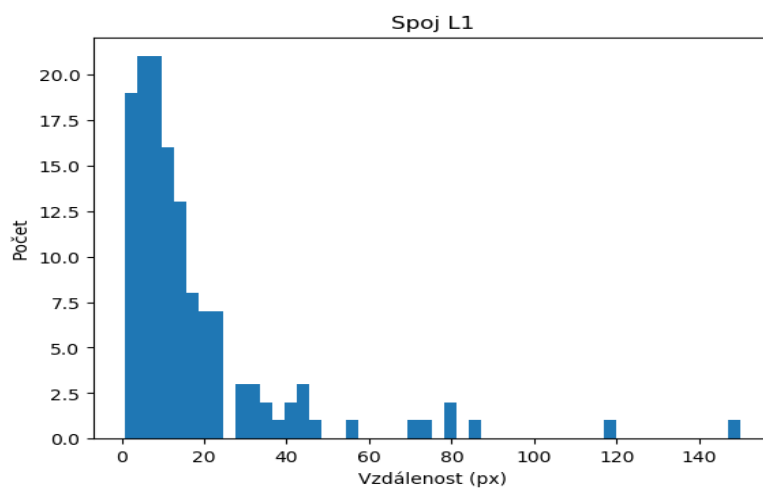
Pro měření přesnosti určení spojů J_{L1} , J_{L2} , J_{L3} , J_{L4} , J_{L5} , J_{R1} , J_{R2} , J_{R3} , J_{R4} , J_{R5} . Byla využita $L2$ metrika.

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


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.

7.8.1 Měření přesnosti detekce J_{L1} a J_{R1}

Boční švy J_{L1} a J_{R1} nevedou ke spoji vodorovně, navíc šev je v této části krunýře relativně krátký, proto je ve výsledných odchylkách v měření velký rozptyl. Jak je patrné z histogramů 7.8 a 7.9.




Obrázek 7.8: Histogram chyb pro spoj J_{L1}




Obrázek 7.9: Histogram chyb pro spoj J_{R1}

7.8.2 Měření přesnosti detekce J_{L2} a J_{R2}

Chyby u spojů J_{L2} a J_{R2} dosahují nízkých hodnot protože boční šev vede k tomuto spoji vodorovně. Z histogramů níže je vidět, že drtivá většina vypočítaných hodnot se nelišila od ručně naměřených o víc než 20 pixelů viz 7.10 a 7.11.




Obrázek 7.10: Histogram chyb pro spoj J_{L2}




Obrázek 7.11: Histogram chyb pro spoj J_{R2}

7.8.3 Měření přesnosti detekce J_{L3} a J_{R3}

Chyby u spoje J_{L3} a J_{R3} dosahují nízkých hodnot protože boční ševy vedou k tomuto spoji téměř vodorovně. Navíc spoje s centrálním švem jsou v této oblasti většinou zřetelně viditelné viz viz 7.12 a 7.13.




Obrázek 7.12: Histogram chyb pro spoj J_{L3}



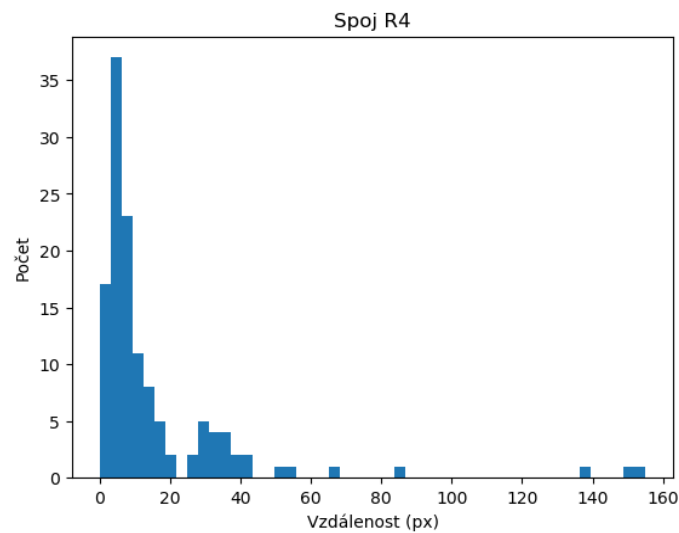
Obrázek 7.13: Histogram chyb pro spoj J_{R3}

7.8.4 Měření přesnosti detekce J_{L4} a J_{R4}

Boční šev vede ke spoji J_{L4} téměř vodorovně, proto zde algoritmus GADS dosahoval dobrých výsledků. Jak je patrné z histogramu 7.14 a 7.15.




Obrázek 7.14: Histogram chyb pro spoj J_{L4}




Obrázek 7.15: Histogram chyb pro spoj J_{R4}

7.8.5 Měření přesnosti detekce J_{L5} a J_{R5}

Výsledek detekce J_{L5} je neuspokojivý kvůli extrémnímu 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. Odchytky od ručně naměřených hodnot zden majo zdaleka největší rozptyl jak je patrné z histogramů 7.17 a 7.16.




Obrázek 7.16: Histogram chyb pro spoj J_{L5}




Obrázek 7.17: Histogram chyb pro spoj J_{R5}

7.8.6 Měření přesnosti identifikace

Pro identifikaci byl použit K-NN klasifikátor využívající L2 metriku. Pro srovnání jsem stejné resty prováděl i na ručně označených plastronech i na datech změřených modelem. Projekce zbavené extrémních hodnot jsou viditelné níže viz 7.19 a 7.19. Datapointy které patří stejnému jedinci jsou označeny barevně a je k nim připojen popisek. Datapointy, ke kterým neexistuje párový obraz jsou označeny světle zelenou barvou.




Obrázek 7.18: PCA projekce ručně změřených dat. Z projekce je vidět, že párove obrazy jsou mnohdy velmi vzdálené.



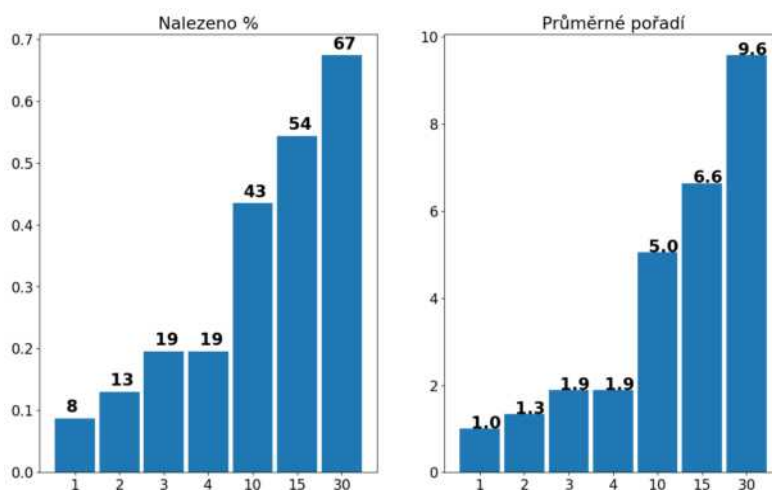
Obrázek 7.19: PCA projekce dat změřených modelem

7. VÝSLEDKY

Jednoznačné classifikace, kdy je obraz nejbližším sousedem stejné třídy bylo dosaženo v **33 %** obrazu z **28** dvojic v datasetu. Pro automaticky naměřená data, kde kvůli chybám v detekci zbylo jen **20** dvojic, bylo dosaženo úspěšnosti **8 %**. Grafy 7.20 a 7.21 ilustrují vývoj úspěšnosti detekce v závislosti na hodnotě a průměrné pořadí párového prvního korektního datapointu v k vybraných datapointech.




Obrázek 7.20: Výsledky k-NN pro ruční měření




Obrázek 7.21: Výsledky k-NN pro automatické měření

7.8.7 Nasazení modelu a mobilní aplikace

Model byl jako Docker image nasazen na server s veřejnou IP adresou. Pro komunikaci s tímto modelem byla zhotovena jednoduchá mobilní aplikace pro zařízení s operačním systémem android. Ta umožňuje pořídit obraz vybranou kamerou na zařízení a zkontrolovat jestli pořízený obraz plastronu je vhodný pro automatickou detekci a identifikaci viz 7.22 a 7.23.



Obrázek 7.22: Nevalidní snímek pořízený mobilní aplikací. Dva spoje a podstatná část analýzy jsou zakryty cizím předmětem.



Obrázek 7.23: Validní snímek pořízený mobilní aplikací. Všechny oblasti důležité pro automatizovanou identifikaci jsou dobře viditelné.

Pro implementaci byl vybrán model klient-server, vzhledem k použitým technologiím a kvůli možnosti integrace detekce s dalšími systémy.

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 Mobilní aplikace

Natrénovaný model ve formátu h5 se bohužel nepodařilo nasadit na OS Android. Konzverze z formátu h5 na tflite je sice možná, ale neexistuje knihovna,

která by umožňovala práci s tímto konkrétním modelem. Proto je nutné nahrát pořízený obraz na webový server, kde je model nasazený. Kvůli tomu je validace obrazu velmi pomalá. Bylo by tedy vhodné najít způsob, jak detekci plastronu spustit přímo na zařízení a validovat obraz již během jeho pořizování.[11]

8.3 Optimalizace algoritmu GADS

Jedním z přínosů práce by mohla být optimalizace algoritmu GADS pro 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, 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 pouze u 76,26 % obrazů [3]. Modul detekce byl nasazen na webový server a byla k němu vytvořena klientská aplikace pro OS Android.

Automatizovaná identifikace plastronů dosáhla pouze 8 % úspěšnosti ve srovnání s identifikací na základě manuálně označených spojů, která dosáhla 33 % úspěšnosti.

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] Schuyler Smith: http://vision.stanford.edu/teaching/cs231b-spring1415/slides/ssearch_schuyler.pdf
 - [5] Connor Shorten: <https://towardsdatascience.com/introduction-to-resnets-c0a830a288a4>
 - [6] Rohith Gandhi: <https://towardsdatascience.com/r-cnn-fast-r-cnn-faster-r-cnn-yolo-object-detection-algorithms-36d53571365e>
 - [7] Viraf May: <https://towardsdatascience.com/master-the-coco-dataset-for-semantic-image-segmentation-part-1-of-2-732712631047>
 - [8] 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-f5685cb30202>

LITERATURA

- [9] https://docs.opencv.org/master/d0d/tutorial_py_features-harris.html
- [10] LogoSENSE: A Companion HOG based Logo Detection Scheme for Phishing Web Page and E-mail Brand Recognition - Scientific Figure on ResearchGate.
- [11] https://www.tensorflow.org/lite/examples/object_detection/overview

Obsah přiloženého CD

readme.....	Stručný popis obsahu CD
gadsimage	Docker image se serverovou aplikaci pro detekci plastronů
dataset	Originální sada obrazů plastronů s ručně vytvořenými popisky ve formátu JSON
detected plastrons....	Sada obrazů plastronů ořezaných detektorem se souřadnicemi oblastí ve formátu JSON
detected junctions.....	Sada obrazů s označenými švy a spoji spolu se souřadnicemi ve formátu JSON
detection.....	Zdrojové kody detekce
evaluation.....	Zdrojové soubory pro zhodnocení identifikace
gads.....	Zdrojové soubory algoritmu GADS
plastron..	Zdrojové soubory pro trenink a použití modelu pro detekci plastronů
junction.....	Zdrojové soubory pro detekci švů a spojů
server ...	Zdrojové soubory pro spuštění detekce na webovém serveru
thesis	Text práce ve formátu PDF
turtle-camera-android	Aplikace pro OS Android