

Západočeská univerzita v Plzni

Fakulta aplikovaných věd

Katedra kybernetiky

**Automatická segmentace objektů
s využitím dat získaných ze zařízení
pro sledování pohybu očí**

Diplomová práce

Plzeň, 2016

Bc. Tomáš Smolík

Prohlášení

Předkládám tímto k posouzení a obhajobě diplomovou práci zpracovanou na závěr studia na Fakultě aplikovaných věd Západočeské univerzity v Plzni.

Prohlašuji, že jsem diplomovou práci vypracoval samostatně a výhradně s použitím odborné literatury a pramenů, jejichž úplný seznam je její součástí.

V Plzni dne 16. května 2016

.....

Bc. Tomáš Smolík

Poděkování

Rád bych poděkoval Ing. Lukáši Burešovi za odborné vedení diplomové práce a mnoho dobrých nápadů, podnětných názorů a připomínek při její tvorbě.

Dále bych rád poděkoval své rodině a svým přátelům, kteří mě celou dobu studia podporovali a dodávali mi elán a inspiraci.

V neposlední řadě také děkuji všem dvanácti dobrovolníkům, kteří obětovali svůj čas mému výzkumu. Speciální poděkování pak patří mému kamarádovi Jakubu Červinkovi, který mi nezištně a ochotně asistoval po celou experimentální část práce.

Anotace

Tématem práce je segmentace obrazu pomocí dat získaných ze zařízení pro sledování pohybu očí. Pro segmentaci se bude využívat metoda Graph cut, která je implementována v knihovně OpenCV. Součástí práce bude naprogramování skriptů pro automatickou segmentaci. Experimentální část se bude skládat z nahrání několika sad pokusů s nezávislými pozorovateli a jejich evaluací. Kromě subjektivního vyhodnocení budou výsledky porovnány také s poloautomatickou segmentací, kdy stejní pozorovatelé budou označovat oblasti popředí a pozadí na obrazu manuálně.

Klíčová slova: sledování pohybu očí, OpenCV, python, EM algoritmus, graph cut, segmentace obrazu.

Annotation

This work focuses on image segmentation using data obtained from the device for tracking eye movement. Segmentation will use Graph Cut method, which is implemented in the OpenCV library. Part of this work is to program scripts for automatic segmentation. The experimental part will consist of recording multiple sets of experiments with independent observers and its evaluation. Apart from subjective evaluation, the results are also compared with a semi-automatic segmentation, where the same observers will mark the foreground and background areas in the image manually.

Key words: eyetracking, OpenCV, python, EM algorithm, graph cut, image segmentation.

Obsah

1	Úvod	1
2	Motivace úlohy	2
3	Historie Eye Trackingu	6
3.1	Počátky eye trackingu a mechanických systémů	6
3.2	Elektrookulografie	7
3.3	Moderní doba	8
3.4	Požadavky na použitelnost zařízení	9
3.5	Využití eye trackingu v reálných aplikacích	10
4	Fyziologie lidského oka	11
4.1	Zrak	11
4.2	Stavba oka	12
4.3	Mechanismus vzniku obrazu na sítnici	13
4.4	Purkyňovy obrazy	14
4.5	Pohyb očí	14
4.6	Mimovolní oční pohyby	15
4.6.1	Konjugované a disjunktivní pohyby	15
4.6.2	Sakadické oční pohyby	15
4.6.3	Hladké sledovací pohyby	16
4.6.4	Pomalé klouzavé pohyby, rychlé trhavé pohyby	16
4.6.5	Vestibulookulometrický reflex	16
4.7	Volní oční pohyby (pohled)	17

4.8	Poznávací procesy zraku	17
4.8.1	Asociační korové oblasti	17
4.8.2	Poznávání	18
4.8.3	Myšlení	18
5	Použité metody	19
5.1	Hledání obrazu na záběru ze scénické kamery	19
5.1.1	Podmínky nalezení obrazu na snímku z kamery	19
5.1.2	Prahování a morfologická operace otevření	19
5.1.3	Nalezení rohových bodů	20
5.2	Přepočítání souřadnic na skutečný obraz	21
5.3	EM algoritmus	21
5.3.1	Náhodná veličina	22
5.3.2	Normální rozdělení	22
5.3.3	Dvourozměrné normální rozdělení	25
5.3.4	Inicializace algoritmu	26
5.3.5	E krok - expectation	26
5.3.6	M krok - maximalization	27
5.4	Graphcut algoritmus	27
5.4.1	Co je to graf	27
5.4.2	Síťe	28
5.4.3	Řez grafem	28
5.4.4	Popis algoritmu	29
5.4.5	Pevná omezení	30
6	Praktická část	32
6.1	Metodika experimentu	32
6.1.1	Použitý Eye Tracker	32
6.1.2	Nahrávání dat	35
6.1.3	Předzpracovaná data pro segmentaci	35
6.1.4	Zpracování dat, segmentace	36

6.1.5	Získání srovnávacích dat	37
6.2	Vstupní data a ideální výstup	41
6.2.1	Původní fotografie	41
6.2.2	Ground truth	44
6.3	Experimenty	47
6.3.1	Chyba segmentace	48
6.3.2	Sada 1, obrázek 1	50
6.3.3	Sada 1, obrázek 2	51
6.3.4	Sada 1, obrázek 3	52
6.3.5	Sada 1, obrázek 4	53
6.3.6	Sada 1, obrázek 5	54
6.3.7	Sada 1, obrázek 6	55
6.3.8	Sada 1, obrázek 7	56
6.3.9	Sada 1, obrázek 8	57
6.3.10	Sada 1, obrázek 9	58
6.3.11	Sada 2, obrázek 1	59
6.3.12	Sada 2, obrázek 2	60
6.3.13	Sada 2, obrázek 3	61
6.3.14	Sada 2, obrázek 4	62
6.3.15	Sada 2, obrázek 5	63
6.3.16	Sada 2, obrázek 6	64
6.3.17	Sada 2, obrázek 7	65
6.3.18	Sada 2, obrázek 8	66
6.3.19	Sada 2, obrázek 9	67
6.3.20	Sada 3, obrázek 1	68
6.3.21	Sada 3, obrázek 2	69
6.3.22	Sada 3, obrázek 3	70
6.3.23	Sada 3, obrázek 4	71
6.3.24	Sada 3, obrázek 5	72
6.3.25	Sada 3, obrázek 6	73

6.3.26 Sada 3, obrázek 7	74
6.3.27 Sada 3, obrázek 8	75
6.3.28 Sada 3, obrázek 9	76
6.4 Shrnutí výsledků experimentů	77
6.4.1 Sada 1	77
6.4.2 Sada 2	79
6.4.3 Sada 3	80
7 Závěr	82
A Digitální přílohy	86

Seznam obrázků

2.1	Znázornění různých druhů apriorní informace vztažené k fotografii.	3
3.1	Ukázka různého vzoru pohybu očí na dle zadaného úkolu za 3 minuty. [25]	8
4.1	Schéma lidského oka[12]	12
4.2	Lom světla na rozhraní různých optických prostředí.	13
5.1	Postup při nalezení polohy obrazu na vstupu ze scénické kamery	20
5.2	Příklad transformace souřadnic	22
5.3	Znázornění dvourozměrné náhodné veličiny normálního rozdělení ve třech dimenzích. Převeďeno na naší aplikaci jsou na osách x a y odpovídající pixely na fotografii, na ose z pak pravděpodobnost, že se pixel nachází v popředí.	23
5.4	4 Gaussovy křivky znázorňující hustotu normálního rozdělení s různými parametry střední hodnoty μ a rozptylu σ^2	24
5.5	Názorné schéma vytvoření sítě z fotografie.	30
6.1	Systém I4Tracking [®] . [16]	32
6.2	Způsob používání a zapojení systému I4Tracking [®] . [16]	33
6.3	Schéma testování.	36
6.4	Pozorovatel tahem myši oddělí objekt od pozadí.	38
6.5	Výsledek segmentace (pouze po hrubém vyznačení pozadí).	38

6.6	Pozorovatel „štětcem“ označí barevně plochy s omezením. Černou barvou uživatel označil plochu, kterou pokládá za jisté pozadí, bílou barvou za jisté popředí, zelenou barvou za možné popředí a červenou barvou za možné pozadí.	39
6.7	Výsledek segmentace (pouze po jemném vyznačení omezení).	39
6.8	Vstup pro GraphCut.	40
6.9	První sada fotografií - míče.	41
6.10	Druhá sada fotografií - letadla.	42
6.11	Třetí sada fotografií - zvířata.	43
6.12	Ground truth data první sady fotografií.	44
6.13	Ground truth data druhé sady fotografií.	45
6.14	Ground truth data třetí sady fotografií.	46
6.15	Příklad masky s vypočtenými p.p. - sada 2 obrázek 6.	47
6.16	Příklad masky s volnějším p.p. - sada 2 obrázek 6.	48
6.44	Výsledky experimentů pro Sadu 1, obrázek 6.	78
6.45	Časově nejnáročnější obrázek při ručním zadávání pevných podmínek. . . .	79
6.46	Sada 3 obrázek 9 - Zajíc.	81

Seznam tabulek

6.1	Výsledky experimentů pro Sadu 1, obrázek 1.	50
6.2	Výsledky experimentů pro Sadu 1, obrázek 2.	51
6.3	Výsledky experimentů pro Sadu 1, obrázek 3.	52
6.4	Výsledky experimentů pro Sadu 1, obrázek 4.	53
6.5	Výsledky experimentů pro Sadu 1, obrázek 5.	54
6.6	Výsledky experimentů pro Sadu 1, obrázek 6.	55
6.7	Výsledky experimentů pro Sadu 1, obrázek 7.	56
6.8	Výsledky experimentů pro Sadu 1, obrázek 8.	57
6.9	Výsledky experimentů pro Sadu 1, obrázek 9.	58
6.10	Výsledky experimentů pro Sadu 2, obrázek 1.	59
6.11	Výsledky experimentů pro Sadu 2, obrázek 2.	60
6.12	Výsledky experimentů pro Sadu 2, obrázek 3.	61
6.13	Výsledky experimentů pro Sadu 2, obrázek 4.	62
6.14	Výsledky experimentů pro Sadu 2, obrázek 5.	63
6.15	Výsledky experimentů pro Sadu 2, obrázek 6.	64
6.16	Výsledky experimentů pro Sadu 2, obrázek 7.	65
6.17	Výsledky experimentů pro Sadu 2, obrázek 8.	66
6.18	Výsledky experimentů pro Sadu 2, obrázek 9.	67
6.19	Výsledky experimentů pro Sadu 3, obrázek 1.	68
6.20	Výsledky experimentů pro Sadu 3, obrázek 2.	69
6.21	Výsledky experimentů pro Sadu 3, obrázek 3.	70
6.22	Výsledky experimentů pro Sadu 3, obrázek 4.	71
6.23	Výsledky experimentů pro Sadu 3, obrázek 5.	72

6.24	Výsledky experimentů pro Sadu 3, obrázek 6.	73
6.25	Výsledky experimentů pro Sadu 3, obrázek 7.	74
6.26	Výsledky experimentů pro Sadu 3, obrázek 8.	75
6.27	Výsledky experimentů pro Sadu 3, obrázek 9.	76
6.28	Relativní chyby podsegmentování a přesegmentování pro Sadu 1.	78
6.29	Relativní chyby podsegmentování a přesegmentování pro Sadu 2.	80
6.30	Relativní chyby podsegmentování a přesegmentování pro Sadu 3.	81

Kapitola 1

Úvod

Segmentace objektů je proces oddělení určitých částí digitalizovaného obrazu na základě vnitřních nebo vnějších vztahů. Typickým příkladem je oddělení popředí od pozadí na fotografii. Výsledky segmentace jsou pak využitelné v celé řadě oborů včetně lékařství, dálkovém průzkumu Země, marketingu atp.

Segmentace lze provádět zcela automaticky na základě různých matematických přístupů a metodách založených např. na principech prahování, detekci hran, celistvých regionech, sledování hranice a dalších. Druhou možností je provádět segmentaci zcela manuálně. Třetím přístupem je podpořit automatickou segmentaci podpůrnou informací.

Podpůrnou informaci nám může poskytnout lidský zrak. Asi 90% všech počítků (viz 4.1), které člověk vnímá, je získáno pomocí zraku. Na základě těchto počítků pracuje lidská mysl. Lidský mozek dokáže při řešení problémů používat dokonalou kombinaci analýzy, syntézy, odvozených myšlenkových operací a vytváření nových vjemů a procesů směřujících k objevení nového, jedná se o dokonalý nástroj k vytváření podpůrných dat pro segmentaci. Pomyslný most mezi myšlením, mozkem, zrakem a digitální informací by mohl tvořit právě eye tracker - systém pro sledování pohybů očí. Tímto zařízením získáme informace pro zlepšení výsledků segmentace za pomoci lidských schopností.

Kapitola 2

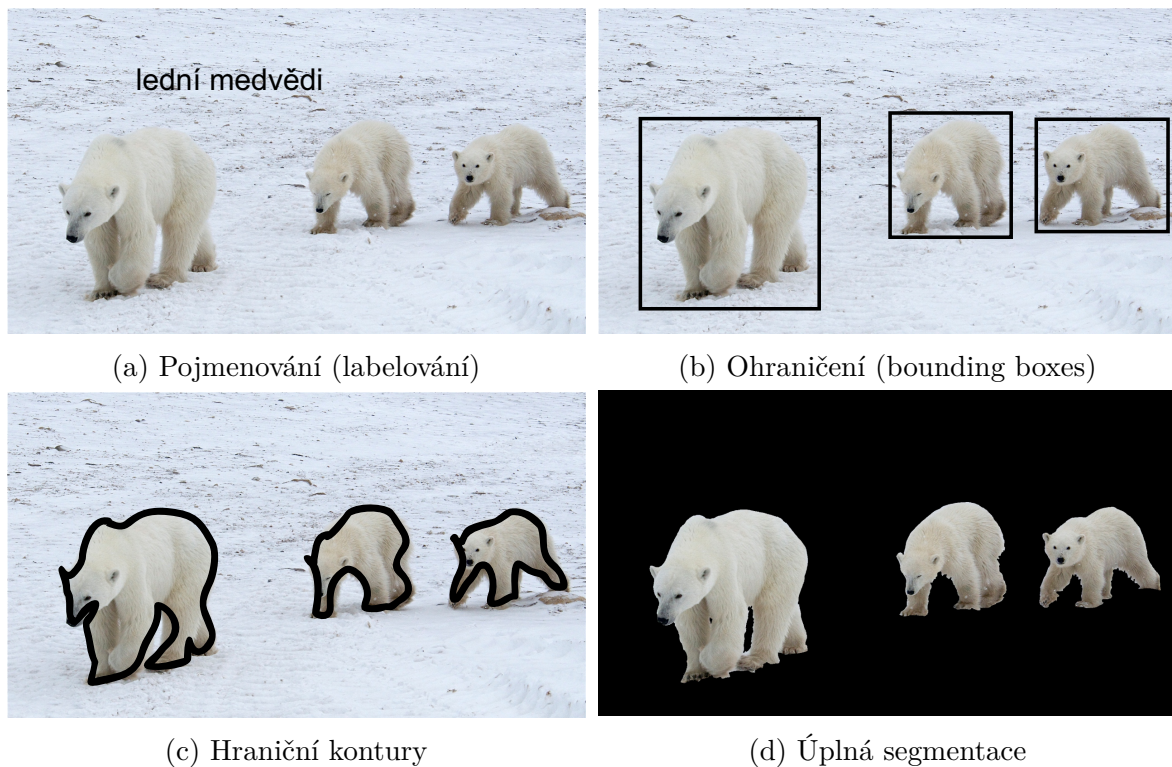
Motivace úlohy

V době digitálních technologií vzniká denně nepřehledné množství informací, z nichž je nemalá část ve formě digitalizovaného obrazu. Zpracování obrazu je však náročné. Některé jednoduché aplikace jsou v dnešní době prováděny již zcela automaticky, na druhou stranu zásadní část je i nadále zpracovávána lidmi. Především aplikace zaměřené na hledání objektů, využití těchto dat k nalezení či dokonce segmentaci objektů na fotografii, je na samém počátku automatizačního procesu.

Problémem je velmi náročné vytvoření obecného způsobu, jak odlišit objekty zájmu od pozadí. K dokonalé segmentaci by takový algoritmus musel zcela pochopit kompozici snímku. A i přesto, že se vytvoření takových algoritmů snaží řada světových odborníků, je většina profesionálů i amatérů, kteří pracují s digitálním obrazem, odkázána na ruční segmentaci.

Zaměříme se tedy na případ takových aplikací, které vyžadují „vyříznutí“ objektu, tedy jeho kompletní oddělení od pozadí snímku. Ruční segmentování je ale časově velmi náročné. Moderní grafické editory jsou vybavené řadou nástrojů, které využívají známé postupy ze strojového zpracování obrazu, jako je prahování, hranové detektory, atd. I přesto je však ruční segmentace otázkou desítek minut, či dokonce hodin. Zvláště, jedná-li se o složité objekty, nebo objekty špatně odlišitelné od pozadí.

Jistým mezikrokem, mezi ruční segmentací a zcela automatizovanou segmentací je získání další informace o hledaných objektech, kterou by bylo možné využít. Do této kategorie je možné zařadit velké množství specifických vyhledávacích programů. Např. bylo možné jmenovat problém hledání státní poznávací značky na snímku z mýtné brány. Zde se nabízí řada apriorních informací, které je možné při hledání značky na dopravním prostředku využít. První informací je tvar státní poznávací značky, který specifický pro automobily či motoroky. Druhou informací je úhel, pod kterým je fotografie značky pořízena, neboť vzájemná poloha kamery a značky je napříč snímky podobná. Další informace je např. poloha poznávací značky vůči čelním světlometům, nebo zpětným zrcátkům. Právě tyto informace, které lze zobecnit pro každou zpracovávanou fotografii, velmi zjednodušují celý problém. Takové informace nazýváme apriorní (z latinského a priori, neboli předem známé).



Obrázek 2.1: Znárodnění různých druhů apriorní informace vztážené k fotografii.

Na obrázku 2.1 lze vidět porovnání několika druhů získaných informací. První informace 2.1a, tzv. labelování může trvat několik vteřin. Uživatel musí nalézt objekty na fotografii

a pojmenovat je, aniž by je označil.

Druhá informace 2.1b, tzv. bounding boxy, neboli ohraničující okna, by měla ohraničit celý objekt. Jejich vytvoření uživateli zabere už desítky vteřin.

Na třetím obraze 2.1c je označení obrysu objektů. To zvláště u složitých objektů může trvat minuty.

V posledním případě 2.1d se nejedná o apriorní informaci, ale o úplnou segmentaci vytvořenou uživatelem. Časová náročnost vytvoření je v řádu hodin.[26]

Tato práce se zabývá mnohem obecnějším vstupem, libovolnou obecnou fotografií. Jak pro takovou fotografii získat apriorní informaci? Automatické porozumění obsahu a kompozici obrazu je velmi složitým problémem. Logickým vyústěním je tedy získání takové informace od člověka. V době moderních technologií existuje takovýchto možností řada. Člověk může ručně zadat, jaký typ objektu by měl program hledat. Například zvíře, pes. Mohl by dále upřesnit jeho barvu. Zadat ji obecně, nebo vybrat z palety barev. Podobně jak to nabízejí některé internetové vyhledávače. Další možností by bylo vybrat hraniční oblast, uvnitř které se pes vyskytuje. Popřípadě označit část fotografie, na které se objekt nachází. Cílem této práce je pokusit se pro to použít eye tracker, zatím úzce zavedenou technologii, která by však v budoucnu mohla být součástí mnoha běžných systémů, jako jsou domácí počítače, tablety, nebo dokonce mobilní telefony.

Myšlenka je vcelku jednoduchá. Lidský mozek je každý den trénován v rozlišování objektů a pozadí, a to při jakékoliv činnosti. To dělá z mozku nejpovolanějšího experta na tuto problematiku. Méně než vteřina mu stačí na nalezení a rozeznání objektu na fotografii. A nalezení proběhne samozřejmě za pomoci zraku a vizuální informace.

Právě tento princip je v této práci využit na nalezení informací o objektu na fotografii. Získáme několik desítek bodů a časových značek, což je při použití vhodných metod dostatek informací pro odhadnutí pozice objektu, a částečně také jeho tvaru. Tento postup

lze použít pro libovolný systém na sledování pohybu očí, který umožňuje získat naměřená data přepočitatelná na souřadnice obrazu.

Velká rychlost mozku při rozpoznávání popředí na promítaných fotografiích znamená i minimální čas, který uživatel musí věnovat k získání apriorní informace. Právě úspora času je tedy nezpochybnitelnou výhodou tohoto přístupu. Uživatel sledováním obrazu stráví jen několik sekund. Dále je třeba připočítat čas nutný ke kalibraci zařízení. Ten je závislý na použitém hardwaru a subjektivních možnostech uživatele.

Proces získávání informací je dynamický a přirozený. Jedná se jen o sledování promítaných fotografií. Uživatel takto může zpracovat velké množství dat. Při rychlosti 15 snímků za minutu (což byla rychlost použitá v experimentální části 6) by bylo možné za 10 minut zpracovat až 150 snímků. Výhodou minimální časové náročnosti je možnost získání velkého množství měření. To umožňuje při segmentaci využívat data z více měření, či různé výběry z těchto dat.

Motivací je také, že v případě použití systému, jenž by pohyby očí dokázal sledovat v reálném čase, by byla možnost vytvoření interaktivního programu pro segmentaci popředí. Ten by v závislosti na pohledu uživatele upravoval vstupní data pro segmentační algoritmy a průběžné výsledky v určité formě zobrazoval. Takový systém využití informací získaných sledováním pohledu pozorovatele by byl časově náročnější a vyžadoval by složitější interakci od uživatele, ale mohl by dosahovat lepších výsledků.

Kapitola 3

Historie Eye Trackingu

3.1 Počátky eye trackingu a mechanických systémů

Historie sledování pohybu očí sahá do konce 19. století. V roce 1879 Louis Émile Javal pomocí odrazu v zrcátku umístěným před čtenářem pozoroval pohyby jeho očí. Při svých pokusech objevil, že pohyb oka se skládá ze sakád a fixací (dále popsáno v Kapitole 4.6). Javal mohl však pouhým okem sledovat jen velké pohyby (přibližně o úhel jednoho stupně), což odpovídá pohybu sítnice asi o 0,2 cm. Metoda byla později zpřesněna přidáním optického zvětšení odrazu od plochy zrcadla.

Na přelomu 19. a 20. století přicházejí další pokusy a způsoby sledování očí. Například pomocí focení. Tato metoda byla však velice složitá a pracná.

V roce 1898 Delabarre přišel s pokusem, kdy je pohyb oka přenášen mechanicky na zapisovací zařízení. V principu je na povrch oka umístěná lehká čočka (Delabarre používal tenkou vrstvu sádry, Orschansky pak o rok později hliník). Uprostřed čočky byl otvor, kterým se na objekt díval a čočka byla propojena lankou se zapisovacím zařízením. I když to byla první metoda, která zaznamenávala pohyb oka během pokusu, byla značně invazivní. Čočka a lanka do jisté míry zabraňovaly oku v přirozeném pohybu a navíc oko muselo být před pokusem znecitlivěno anestetiky. V roce 1911 tento přístup vylepšili Marx a Trendelenburg, kteří k čočce přilepili malé zrcátko. Odraz světla od zrcátka nechával

záznam o pohybu oka na fotocitlivém papíře.

Probíhaly i další pokusy s čočkami z jiných materiálů (jako například gumy), nebo připevnění zrcátka přímo na povrch oka. Všechny předchozí metody však nebyly vždy aplikovatelné a navíc hrozilo nebezpečí, že se čočka či zrcátko smýkne po povrchu bulvy. Z lidského hlediska byly tyto experimenty vzhledem k pokusným osobám necitlivé. [25]

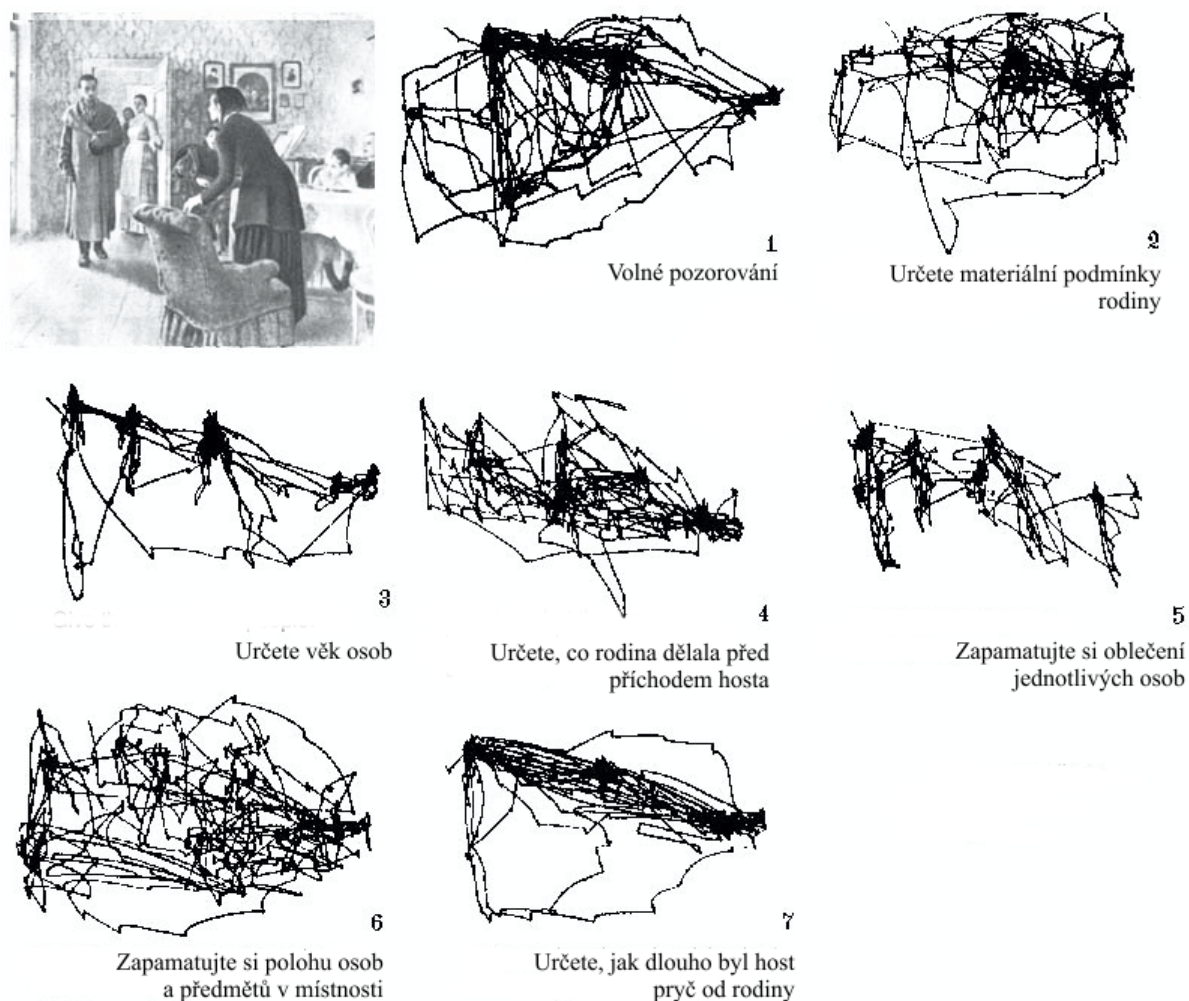
3.2 Elektrookulografie

Další vývoj v oboru sledování pohybu očí se odehrál až ve 30. letech 20. století. Vědci Mowrer, Ruch a Miller v roce 1936 představili metodu dnes známou jako elektrookulografie. V jejich práci byl popsán potenciálový rozdíl mezi rohovkou a sítnicí, který se mění při natočení oka. Tuto změnu lze zachytit pomocí dvojice elektrod umístěných po stranách nebo nad a pod okem. Díky téměř lineární závislosti mezi úhlem otočení a změnou potenciálu lze zpětně určit směr pohledu oka. Dalšími výhodami tohoto přístupu je, že přímo pro oční bulvu je zcela neinvazivní a signál není ovlivněn pohybem hlavy. Hlavní nevýhodou je však velmi nízká přesnost oproti některým jiným metodám. Tohoto přístupu se však využívá i dnes, neboť pohyb očí může být sledován i v naprosté tmě, nebo když jsou oči zavřené. To poskytuje možnost využití v oblastech jako je např. průzkum spánkové aktivity, atp.[25]

Oko lze tedy jednoduše modelovat jako dipól, kde se kladný pól nachází na rohovce a záporný pól na sítnici. Signálu z těchto dvou elektrod se říká elektrookulogram (OEG). Pomocí tohoto signálu lze sledovat vertikální a horizontální pohyby očí. Třetí složkou může být signál citlivý na sakády vyplývající ze stahů okohybných svalů (musculi bulbi) a umožňují detekci i nepatrných sakád. Tento přístup není úplně vhodný ke sledování pomalého pohybu očí a detekci směru pohybu, to znamená, že je obtížné přesně určit, kde je objekt na který se oko dívá. Na druhou stranu je vhodný k aplikacím náročných na citlivost, k detekci sakád spojených s pohybem oka a mrkáním.[25]

3.3 Moderní doba

V 70. letech 20. století se z průzkumu pohybu očí během procesu čtení eye tracking rozšiřuje do dalších oblastí. Při komplexních úlohách zpracování zrakových vjemů se začíná zkoumat vztah oka a mysli, popř. pohledu a pozornosti. Používají se neinvazivní, většinou optické metody a problém sledování pohybu očí se mění na problém sledování pohledu (tzv. gaze tracking). To znamená, že součástí problému se stává i pohyb hlavy. [20]



Obrázek 3.1: Ukázka různého vzoru pohybu očí na dle zadaného úkolu za 3 minuty. [25]

Ve většině moderních aplikací těchto technologií se jedná o optické sledování pohybu bulvy. Kamerou nebo nějakým speciálně navrženým senzorem se snímá odražené světlo (viditelné, nebo infračervené) od povrchu oka. Metody na bázi videozáznamu obvykle

používají jako příznaky střed zornice a první Purkyňův obraz (odraz od vnějšího povrchu rohovky). Citlivější přístroje (dualPurkinje eye tracker) využívají první a třetí Purkyňův obraz (odraz od vnitřní, resp. zadní plochy čočky. Tento obraz je otočený, viz kapitola 4.4. Další možností, jak získat nové příznaky pomocí optického sledování, které jsou přesnější, je pozorovat tkáň uvnitř oka. Například sledovat při pohybu oka změnu polohy cév na sítnici. Optické metody jsou používány nejčastěji, neboť jsou neinvazivní a levné.[25]

3.4 Požadavky na použitelnost zařízení

Požadavky na použitelnost zařízení vzhledem ke Scott & Findley kritériím byly publikovány ve studii *Visual search, eye movements and display units, Human factors report* [24]. Shrnují řadu podmínek, které by zařízení použitelné v obecném měřítku, tzn. na téměř libovolnou aplikaci technologie sledování očí (popř. sledování pohledu) mělo splňovat. Ideální sledovací zařízení:

- umožňuje volné zorné pole s nezakrytou oblastí hlavy a obličeje.
- by nemělo mít žádný přímý kontakt s uživatelem.
- je schopné uměle stabilizovat obraz na sítnici v případě potřeby.
- má přesnost alespoň jedno procento nebo několik obloukových minut.
- poskytuje rozlišení jedné obloukové minuty, čili musí umět detekovat nejjemnější pohyby oka.
- splnit dynamiku rozsahu $1'$ až 45° pro polohu oka ($3000\times$) a $1'$ až 800° za sekundu pro rychlost oka ($50000\times$).
- musí splňovat dobrou časovou dynamiku a malou reakční dobu (velké zesílení, malou dobu odezvy).
- by mělo pracovat realtime (okamžité zpracování za běhu).
- dokáže měřit všechny tři stupně volnosti (horizontální pohyb, vertikální pohyb a rotace oka).

- být snadno rozšiřitelné na sledování obou očí.
- musí být kompatibilní se systémy na sledování pohybu těla a hlavy.
- je snadno použitelné na velkou škálu aplikací.

3.5 Využití eye trackingu v reálných aplikacích

Technologie sledování pohybu očí či sledování pohledu je používána v řadě vědeckých, diagnostických i komerčních aplikacích. V medicíně najde uplatnění v oboru kognitivní psychologie, laserové refrakční chirurgie (zákroky na „odstranění dioptrií“). V průmyslu se jedná o různé školicí simulátory (řízení vozidel, letadel, atd.), detekce únavy, sportovní trénink, komunikační systémy pro tělesně postižené, virtuální realita, vývoj produktů, počítačové vidění (komunikace člověk - stroj), rozpoznávání aktivity uživatele, dále pak komerční sledování a marketing, ovládání počítačů a mobilních zařízení. Existuje však řada dalších aplikací této technologie.

Kapitola 4

Fyziologie lidského oka

4.1 Zrak


Zrak je nejdůležitějším smyslem člověka. Udává se, že až 90% veškerých informací získáváme právě skrze tento smysl. Podstatou vidění je zpracování informačních signálů o vnějším světě ve formě fotonů viditelného světla. Jako viditelné světlo označujeme část spektra elektromagnetického vlnění vnímanou lidským okem. Jedná se o oblast s vlnovou délkou $\lambda = 400nm - 760nm$. Tento rozsah je na jednu stranu dán citlivostí fotoreceptorů na sítnici, který je $315nm - 760nm$, ovšem za normálních podmínek materiál oční čočky pohlcuje oblast pod $400nm$.

Zrakový systém lze zjednodušeně rozdělit na následující funkční části:

1. **Optický systém oka** umožňuje vznik obrazů objektů z vnějšku na sítnici oka.
2. **Fotoreceptory sítnice** transformují elektromagnetické vlnění z viditelného spektra do podoby akčních potenciálů.
3. **Optická dráha** přenáší vizuální informaci do korové projekční oblasti. Ta je zakódována do podoby akčních potenciálů.
4. **Korová zraková oblast** je část mozku, která zpracovává příchozí zrakové informace a umožňuje tak vnímání.[12]

4.2 Stavba oka

Lidské oko je kulovitý orgán o průměru cca 24 mm. Stěnu oční kopule tvoří tři vrstvy. Zevní vrstvu představuje tuhá vazivová **bělima** (sklera). V přední části oka, v oblasti zvané **limbus**, přechází v průhlednou **rohovku** (cornea). Střední vrstva se nazývá **živnatka** (uvea). V zadní části oka, kde se vyskytuje velké množství cév, se označuje také jako **cévnatka** (chorioidea). V přední polovině oka se živnatka rozšiřuje v **řasnaté těleso** (corpus ciliare). Jeho hlavní součástí je jeden z hladkých svalů oka (musculus ciliaris). Těsně za okrajem rohovky se živnatka vzdaluje od zevní stěny a přepažuje prostor za rohovkou jako svíslá přepážka zvaná **duhovka** (iris). Duhovka obsahuje dva hladké svaly. V centru duhovky je kruhovitý otvor nazývaný **zornice** (pupilla). Za duhovkou je uložena **čočka** (lens crystallina). Do jejích partií se upíná velký počet jemných vláken, které vyzařují z řasnatého tělesa. Dohromady jsou tato vlákna nazývána **závěsný aparát čočky** (zonula centralis). Vnitřní vrstvu stěny bulbu ¹ tvoří, počínaje vnitřní plochou duhovky, **sítnice** (retina). V blízkosti zadního pólu oka vzniká mělká jamka. Kolem ní je naopak sítnice valovitě ztlustělá. Kvůli odlišné barvě se celý tento okresek označuje jako žlutá skvrna. Veškerý prostor bulbu za čočkou vyplňuje celý prostor **sklivec**. To je čiré, bezbarvé, rosolovité těleso s řídkou vláknitou strukturou a z 98% se skládá z vody. Mezi vnitřní plochou rohovky a přední plochou sklivce je volný prostor vyplněný komorovou vodou. Ten se ještě dělí na **přední a zadní komoru oční**. [12]



Obrázek 4.1: Schéma lidského oka [12]

¹bulbus oculi = oční koule


4.3 Mechanismus vzniku obrazu na sítnici

Optickým zobrazením se rozumí opětovné zobrazení svítícího nebo osvětleného předmětu na jiném místě (ve stejné nebo jiné velikosti). Představíme-li si předmět jako množinu bodových zdrojů světla, pak z každého tohoto bodu vyzařuje svazek rozbíhavých paprsků. Podstata zobrazení pak spočívá v tom, že tyto paprsky opět soustředíme do jednotlivých bodů. Toho lze docílit buďto lomem nebo odrazem. V souvislosti s optikou oka je významnější lom světla.

Při dopadu paprsků na rozhraní dvou rozdílných optických prostředí² se část paprsků odráží a zbytek proniká do druhého prostředí. Při tomto procesu se lomí, tzn. že nepokračuje dál ve směru dopadu. Index lomu je dán rychlosti šíření světla v v daném prostředí:

$$N = \frac{v}{c},$$

kde c je rychlost světla a N je index lomu.



Obrázek 4.2: Lom světla na rozhraní různých optických prostředí.

Při vytváření obrazu na sítnici musí světelné paprsky projít čtyřmi optickými prostředími. Jmenovitě se jedná o rohovku, komorovou vodu, čočku a sklivce. Tento složitý optický aparát se chová jako spojná optická soustava, která vytváří na sítnici reálný, převrácený a zmenšený obraz sledovaného předmětu. Převrácený obraz si do skutečné polohy

²Jsou-li dvě optická prostředí rozdílná, pak mají různý index lomu (značíme n nebo N). Index lomu lze považovat pro dané prostředí za konstantu ≥ 1 . Index lomu ve vakuu je 1, ve všech ostatních prostředích je pak větší.

transformuje až centrální nervový systém. Celková optická mohutnost oka je 59 D³. Z této soustavy má nejvyšší optickou mohutnost rohovka, asi 42 D. Dalším silně lámavým prostředím je čočka, která navíc díky závěsnému aparátu dokáže měnit svojí křivost. Díky tomu dokáže lidské oko zaostřit do různé vzdálenosti. Změně optické mohutnosti optického aparátu se říká akomodace.[12]

4.4 Purkyňovy obrazy

Akomodace, zmíněná v předchozím odstavci, je docílena procesem vzrůstu zakřivení lámavých ploch oční čočky⁴. Tento proces objevil a na základě experimentů popsal český fyziolog Jan Evangelista Purkyně [12]. Na jeho počest jsou odrazy paprsků na optických rozhraních nazývány Purkyňovy obrazy. Purkyně objevil, že rozsvícená svíčka v temné místnosti postavená před oko se v něm několikanásobně zrcadlí. Purkyně popsal tyto obrazy:

- **První obraz:** Je jasný a přímý. Vzniká odrazem na přední ploše rohovky.
- **Druhý obraz:** Je ze všech tří největší, je přímý a méně jasný. Vzniká odrazem na přední ploše čočky.
- **Třetí obraz:** Je nejmenší, obrácený a nejméně jasný. Vzniká odrazem od zadní plochy čočky.

4.5 Pohyb očí

Na každý oční bulbus se upíná šestice příčně pruhovaných očních svalů. Tato skupina svalů zajišťuje dokonalou pohyblivost bulbu. K praktickému popisu pohybu každého bulbu je vhodné použít tři imaginárních os: vertikální, horizontální a předozadní osy. Tyto tři osy se protínají v centru oční koule. Jestliže se oční bulbus otáčí kolem vertikální osy

³Optická mohutnost je veličina, která vyjadřuje zakřivenost optické čočky nebo soustavy tenkých čoček, což je případ oka. Optická mohutnost je dána převrácenou hodnotou obrazové ohniskové vzdálenosti čočky.

⁴Poloměr křivosti přední plochy čočky je u neakomodovaného oka asi 10 mm, u plně akomodovaného asi 7 mm.

směrem nasálním (k nosu) označujeme tento pohyb jak addukci. Při pohybu opačným temporálním směrem mluvíme o abdukci. Jestliže se bulbus otáčí kolem horizontální osy a pohybuje se přitom vzhůru, mluvíme o elevaci a při opačném pohybu o depresi. Pokud oko rotuje kolem předozadní osy provádí tzv. torzní pohyb. Pokud se přitom horní bod na rohovce pohybuje po kruhové dráze k vnitřnímu koutku oka, nazýváme tento pohyb intorze a v opačném směru extorze.[12]

4.6 Mimovolní oční pohyby

Při analýze dat pohybu očí lze sledovat různé druhy pohybu oka. První velkou skupinou pohybů jsou mimovolní oční pohyby. Jsou to pohyby, které oko vykonává automaticky.[12]

4.6.1 Konjugované a disjunktivní pohyby

O těchto druzích pohybů mluvíme, popisujeme-li zároveň pohyb obou očí. Pokud oči pozorují objekt, který se pohybuje v zorném poli zprava, zleva, shora nebo dolů, vychylují se oba bulby vždy symetricky v témže směru. Při pohybu předmětu směrem k oku zorné osy očí k sobě konvergují a pokud se předmět vzdaluje, osy vzájemně divergují. Za běžných okolností jsou všechny volní a mimovolní pohyby s výjimkou pomalých klouzavých a rychlých trhavých pohybů řazeny do tohoto typu. V klinické medicíně se označují jako pohled.[12]

4.6.2 Sakadické oční pohyby

Sakadické oční pohyby nebo zkráceně sakády slouží k rychlému nasměrování místa nejostřejšího vidění na sítnici, tj. centrální jamky na kontrastní objekt pohybující se v zorném prostoru. Tento pohyb je mimořádně rychlý. Je uskutečněný během desítek milisekund a pohyb dosahuje úhlové rychlosti až $700^\circ \cdot s^{-1}$.

Klíčovou strukturou pro generování sakadických očních pohybů je střední mozek (colliculi superiores). Tato struktura na podkorové úrovni detekuje pohybovou složku optické

informace a transformuje ji do motorického povelového vzorce, který způsobuje stočení očí eventuálně i hlavy za pohybujícím se objektem.[12]

4.6.3 Hladké sledovací pohyby

Jejich úkolem je udržet obraz objektu, který byl zacílen sakádou při jeho pohybu v zorném prostoru, na centrální jamce. Pokud rychlost předmětu nepřekročí $25 - 30^\circ \cdot s^{-1}$, mohou oči přesně sledovat jeho dráhu tak, aby se jeho obraz nepřetržitě promítal na centrální jamku.[12]

4.6.4 Pomalé klouzavé pohyby, rychlé trhavé pohyby

I za situace, kdy se pozorovaný předmět i pozorovatel nehýbají, vykonávají oči dva typy velmi drobných mimovolných pohybů. Jejich zvláštností je, že na rozdíl od všech ostatních pohybů se oči pohybují navzájem nezávisle a tudíž asymetricky. Jsou to pomalé klouzavé pohyby (slow drifts) z jedné strany na druhou a rychlé trhavé pohyby (quick flicks), které navrací obraz na centrickou jamku po předchozím pohybu oka. Tyto pohyby jsou důležité, aby nenastal jev popsáný jako stabilizovaný obraz na sítnici (stabilizovaný jev). Při něm zaniká obrazový vjem optického stimulu. To je zřejmě také důvod, proč nevnímáme stíny retinálních cév na sítnici. Mechanismus, který je za příčinou ztráty vnímání stabilizovaného obrazu na sítnici, není dosud znám.[12]

4.6.5 Vestibulookulometrický reflex

Při náhlé změně polohy hlavy se objeví opačně směřující výchylka obou očí. Například náhlé trhnutí hlavy doprava způsobí spin očí doleva. Tato reakce se nazývá vestibulookulometrický reflex, nebo okulocefatický reflex. Jeho účelem je udržet obraz nazíraného předmětu i při náhlé změně polohy. Tento reflex není iniciován z receptorů sítnice, a proto vzniká např. i při zavřených očích.[12]

4.7 Volní oční pohyby (pohled)

Primární popud k volnímu pohledu zřejmě vychází z kaudální (koncové) části zadní parietální korové oblasti. Tato oblast je součástí dorsální informační cesty, která zajišťuje detekci pohybu a polohy vizuálního podnětu v zorném prostoru. Ve spolupráci s motivačními centry v limbickém systému generuje takový vzorec chování, jenž směřuje pozornost organismu na vizuální objekt, který se objeví v jeho zorném poli. [12]

4.8 Poznávací procesy zraku

4.8.1 Asociační korové oblasti

Soudí se, že anatomickým podkladem složité kognitivní činnosti člověka jsou tzv. asociační korové oblasti. Toto tvrzení však neznamená, že uvedené oblasti mohou pracovat samostatně. Pro jejich zdárnou funkci je třeba, aby spolupracovaly s ostatními korovými a subkorovými oblastmi mozku. Mechanismy fungování těchto polí jsou dosud velmi málo známé. Většina poznatků byla získána pozorováním lidí či zvířat, u nichž došlo k poškození nějaké z těchto oblastí.

Parasensorická asociační korová oblast je oblastí mozkové kůry, jejímž úkolem je shromažďovat elementární sensorické informace rozdílných kvalit a spojovat je do uceleného sensorického vjemu.

Prefrontální asociační korová oblast je oblast, která uskutečňuje procesy plánování úmyslných pohybů.

Paralimbická asociační korová oblast je oblast, jejímž úkolem je zabezpečovat kontrolu (získanou učením) nad vrozenými programy motivačního a emočního chování. Tyto programy jsou uloženy v paměťových médiích v limbickém systému.[12]

4.8.2 Poznávání

Poznávání umožňuje zachycovat různé podněty a na základě jejich zpracování a hodnocení pak jednat. Poznání prostřednictvím smyslových orgánů je čítí. Jeho výsledkem jsou počitky. Při tvorbě poznávání se člověk opírá především o zrak. Počitek je odraz jednotlivých vlastností předmětů a jevů okolního světa, které bezprostředně působí na smyslové orgány, receptory. Vztáhneme-li tento poznatek k diplomové práci, tak proces poznávání probíhá během hledání objektu na fotografiích.

4.8.3 Myšlení

Myšlení je člověkem zobecněné a zprostředkované poznávání předmětů a jevů. Umožňuje předvídat, odhalovat a hodnotit jevy a souvislosti mezi nimi, které smyslové poznávání nedokáže postihnout. Je specificky lidskou formou poznávání. Je to proces analýzy, syntézy a odvozených myšlenkových operací. Myšlení dělíme na konvergentní a divergentní. Konvergentní používá již známých naučených postupů a algoritmů. Divergentní je myšlení směřující k objevení nového, originálního postupu, vjemu, atd.

Kapitola 5

Použité metody

5.1 Hledání obrazu na záběru ze scénické kamery


Než budeme moci data získaná analýzou výstupu z eye trackeru použít, je nutné je přepočítat na souřadnice vstupního obrazu. Protože tracker pracuje v souřadnicích ze scénické kamery, je třeba souřadnice přepočítat. Než to však budeme moci udělat, musíme najít na záběru ze scénické kamery promítnutý obraz.

5.1.1 Podmínky nalezení obrazu na snímku z kamery


Nalezení obrazu vyžaduje dvě podmínky. Hledaný obraz se nachází na bílé ploše a je ohraničený černým rámečkem. Tyto podmínky jsou dodrženy vždy, když se obrázek promítá (viz Obrázek 5.1a). Není-li ohraničení nalezeno, předpokládá se, že je na obraz promítána plocha bez zkoumaného obrazu.

5.1.2 Prahování a morfologická operace otevření


Obraz je nejprve nutné naprahovat. Prahování je metoda segmentace obrazu založená na kontrole hodnoty jasu každého pixelu. V principu jde o nalezení takové hodnoty prahu, aby platilo, že všechny hodnoty jasu jsou nižší než práh odpovídající pozadí, a ostatní hodnoty odpovídají popředí. Určení správné hodnoty prahu může být problematické. Pro automatické hledání prahu je v této práci použita Otsuova metoda [17], která je imple-



(a) Vstup ze scénické kamery.



(b) Automaticky naprahovaný vstup.



(c) Po morfologické operaci otevření.



(d) Nalezené hranice obrazu.

Obrázek 5.1: Postup při nalezení polohy obrazu na vstupu ze scénické kamery

mentována v knihovně OpenCV. Po nalezení prahu se provede segmentace prahováním (viz Obrázek 5.1b).

V dalším kroku, před samotným hledáním obrysu obrazu, provádím morfologickou operaci zvanou otevření (viz Obrázek 5.1c). Tato operace oddělí objekty spojené tenkou šíjí a odstraní drobné detaily a šum. Velikost odstraněných detailů a spojů závisí na velikosti strukturního elementu. [1] Vzhledem k obvyklého šumu jsem vybral element ve tvaru „kruhu“ o průměru 5 pixelů.

5.1.3 Nalezení rohových bodů

Nyní mám připravený vstup pro hledání skutečného obrysu obrazu. Díky podmínkám formulovaných výše si můžeme dovolit použít následující postup. Pomocí funkce hledání

kontur implementované v knihovně OpenCV nalezneme největší konturu, což je bílá plocha na pozadí. Na této ploše najdeme všechny body patřící obrazu, všechny šum by měl být odstraněn po předchozí operaci otevření. Z nich vybereme čtyři body, které mají nejmenší euklidovskou vzdálenost k čtyřem rohům obrazu. Tyto nalezené body jsou vrcholy čtyřúhelníku ohraničující obraz (viz Obrázek 5.1d).

Nakonec bude proveden test, zda jsou nalezené body dostatečně daleko od sebe. Pokud nebudou, znamená to, že na scénické kameře není v tento okamžik snímán zkoumaný obraz.

5.2 Přepočítání souřadnic na skutečný obraz

Abychom data z eye trackeru mohli použít na segmentaci v původním (promítaném) obrazu, musíme přepočítat souřadnice z nalezeného obrazu na výstupu scénické kamery na souřadnice v původním obrazu. Předchozí metoda popisovala, jak získat souřadnice bodů ohraničující sledovaný obraz. To společně s informací o rozměrech původního obrazu stačí, abych našel transformační vztah.

Pro takovou transformaci je nutné body převést do tzv. homogenních souřadnic, kde každý bod je reprezentovaný přímkou v prostoru. Libovolná transformace je pak průnikem přímek a libovolné roviny řezu. Transformační matici této transformace je možné získat pomocí funkce *getPerspectiveTransform* a vypočítat transformované body pomocí *perspectiveTransform*. Obě funkce jsou implementované v knihovně openCV. [14]

5.3 EM algoritmus

Jedná se o algoritmus matematické statistiky, který slouží především k hledání maximálně věrohodných odhadů z neúplných dat. Častou aplikací, stejně jako v této práci, je odhad parametrů pravděpodobnostních směrů.



Obrázek 5.2: Příklad transformace souřadnic

Cílem EM algoritmu v této práci je nalezení dvourozměrné náhodné veličiny. Měla by být taková, aby řez touto veličinou co nejlépe popisoval polohu a tvar objektu na fotografii.


5.3.1 Náhodná veličina

Náhodná veličina, někdy také stochastická veličina, je taková veličina, kterou je možné opakovaně měřit u různých pokusů, a její hodnoty lze zpracovat metodami teorie pravděpodobnosti nebo matematické statistiky. Zde se jedná o opakované měření pozice pohledu lidského oka na ose x . Druhou veličinou je pak stejné měření na ose y .

Formálně je náhodná veličina X definována jako zobrazení přiřazující elementárnímu jevu reálné číslo, tj. $X : \Omega \rightarrow R$, kde Ω je libovolná neprázdná množina - množina elementárních jevů a R je množina reálných čísel. Uvažujme-li výběrový prostor Ω přiřazený k výsledkům určitého pokusu, pak náhodná veličina X je funkce, která prvkům ω z výběrového prostoru Ω přiřazuje reálná čísla x tak, že platí $x = X(\omega)$. Zjednodušeně lze říci, že náhodná veličina je taková veličina, jejíž hodnoty závisí na náhodě.[13]

5.3.2 Normální rozdělení


Jedním z nejdůležitějších spojitých rozdělení náhodných veličin je normální rozdělení. Normální rozdělení má zcela zásadní význam v teorii pravděpodobnosti a matematické statistice a řídí se jím mnoho náhodných veličin, např. chyby měření s velkým počtem neznámých a vzájemně nezávislých příčin, ale i další fyzikální a technické veličiny. Hustota



Obrázek 5.3: Znázornění dvourozměrné náhodné veličiny normálního rozdělení ve třech dimenzích. Převáděno na naši aplikaci jsou na osách x a y odpovídající pixely na fotografii, na ose z pak pravděpodobnost, že se pixel nachází v popředí.

normálního rozdělení je popsána křivkou zvanou Gaussova křivka. Je pojmenována po německém matematikovi Johannu Carlu Friedrichu Gaussovi.[22]

Gaussova křivka má jeden vrchol a je symetrická okolo střední hodnoty, kterou značíme μ , nebo $E(X)$. Pro normální rozdělení platí, že jeho střední hodnota je rovna jeho modu a mediánu. Hustota pravděpodobnosti má zvonovitý tvar a svého jediného globálního maxima dosahuje ve střední hodnotě. Limity hustoty pravděpodobnosti se pak asymptoticky blíží hodnotě 0. Šířka zvonovitého tvaru je dána parametrem zvaným rozptyl (značíme σ^2). Právě střední hodnota μ a rozptyl σ^2 jednoznačně určují normální rozdělení. Lze tedy psát: $X \sim N(\mu, \sigma^2)$. Při řešení různých pravděpodobnostních úloh se často předpokládá, že sledovaná náhodná veličina má normální rozdělení, ačkoliv její skutečné rozdělení má jen podobný tvar, tzn. je jednovrcholové a přibližně symetrické.



Obrázek 5.4: 4 Gaussovy křivky znázorňující hustotu normálního rozdělení s různými parametry střední hodnoty μ a rozptylu σ^2 .

5.3.3 Dvourozměrné normální rozdělení

Jak již bylo naznačeno výše, rozdělení používané pro popis apriorní znalosti polohy a tvaru objektu je reprezentováno dvourozměrným normální rozdělením. Jak název napovídá, jedná se o složení dvou normálních rozdělení. Pro charakterizaci jednotlivých náhodných veličin se standardně používají momentové charakteristiky jako jsou střední hodnoty $E(Y)$, $E(X)$ a rozptyly $D(Y)$, $D(X)$. Při charakterizaci rozdělení náhodného vektoru je nutné také definovat míry intenzity vztahu mezi jeho složkami Y a X . Základní takovou mírou je druhý smíšený centrální moment nazývaný kovariance $cov(Y, X)$, která je definována vztahem: $cov(Y, X) = E(Y * X) - E(X) * E(Y)$. Čím je stupeň intenzity vztahu mezi Y a X vyšší, tím je vyšší i kovariance. Pojem intenzita vztahu se týká míry linearitity mezi Y a X . Pro nelineární vztahy může vyjít kovariance nulová. Kovariance je symetrickou funkcí svých argumentů, tj. $cov(Y, X) = cov(X, Y)$.

Dvourozměrné normální rozdělení je určeno šesti parametry. Obvykle se tedy zapisuje maticově:

$$\mu = \begin{bmatrix} \mu_x \\ \mu_y \end{bmatrix}, \Sigma = \begin{bmatrix} \sigma_x^2 & \rho\sigma_x\sigma_y \\ \rho\sigma_y\sigma_x & \sigma_y^2 \end{bmatrix}, \quad (5.1)$$

kde μ je střední hodnota (μ_x je střední hodnota X a μ_y je střední hodnota Y) a Σ je kovarianční matice (ρ je korelační koeficient mezi X a Y , takový že $\rho \in (-1, 1)$ a σ_x, σ_y jsou směrodatné odchylky proměnné X, Y , takové že $\sigma_x = \sqrt{D(X)}$ a $\sigma_y = \sqrt{D(Y)}$).

Sdruženou hustotu pravděpodobnosti lze rozepsat do tvaru:

$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)} \left[\frac{(x-\mu_x)^2}{\sigma_x^2} + \frac{(y-\mu_y)^2}{\sigma_y^2} - \frac{2\rho(x-\mu_x)(y-\mu_y)}{\sigma_x\sigma_y} \right]\right). \quad (5.2)$$

Při odhadování pozice a tvaru objektu ve fotografii hledáme řez touto funkcí.

5.3.4 Inicializace algoritmu

Parametry rozdělení mohou být iniciovány libovolnými parametry. Nejčastěji používanou metodou je náhodné vygenerování parametrů Θ .

Pro účely Expectation-maximalization (zkráceně EM) algoritmu definujme sdruženou věrohodnostní funkci ve tvaru:[9]

$$L_c(\Theta, \mathbf{x}, \mathbf{y}) = \prod_{i=1}^n f_{(X,Y)}(x_i, y_i, p_{x_i}, \theta_{x_i}), \quad (5.3)$$

kde $x_i \in \{1, \dots, k\}$ pro $i = 1, \dots, n$ a $y_i \in \mathbb{R}$ a logaritmus sdružené věrohodnostní funkce je:

$$l_c(\Theta; \mathbf{x}, \mathbf{y}) = \log L_c(\Theta; \mathbf{x}, \mathbf{y}). \quad (5.4)$$

5.3.5 E krok - expectation

Protože hodnoty x_i neznáme, nemůžeme odhadnout neznámé parametry θ maximalizací funkce l_c . V kroku E (expectation) nahradíme hodnotu l_c její podmíněnou střední hodnotou při daných hodnotách $Y = y$ a $\theta = \theta^{(t)}$ a až ve druhém kroku M (maximalization) najdeme odhady parametrů θ maximalizací podmíněné střední hodnoty.[11] [9]

$$\begin{aligned} Q(\Theta, \Theta^{(t)}) &= E_{\Theta^{(t)}} [h(X; y, \Theta) | Y = y] = \\ &= \sum_{j=1}^k \sum_{i=1}^n \omega(j|y_i; \theta_j^{(t)}, p_j^{(t)}) \log p_j + \\ &+ \sum_{j=1}^k \sum_{i=1}^n \omega(j|y_i; \theta_j^{(t)}, p_j^{(t)}) \log f_j(y_i; \theta_j), \end{aligned} \quad (5.5)$$

kde:

$$\Theta = (\theta_1, p_1, \dots, \theta_k, p_k) \quad (5.6)$$

$$\Theta^{(t)} = (\theta_1^{(t)}, p_1^{(t)}, \dots, \theta_k^{(t)}, p_k^{(t)}) \quad (5.7)$$

$$\omega(j|x_i, \theta_j^{(t)}, p_j^{(t)}) = \frac{p_j^{(t)} f_j(y_i, \theta_j^{(t)})}{\sum_{h=1}^k p_h^{(t)} f_h(y_i, \theta_h^{(t)})}. \quad (5.8)$$

5.3.6 M krok - maximalization

Maximalizujeme funkci $Q(\Theta, \Theta^{(t)})$ vzhledem k neznámým parametrům Θ za podmínky, že $p_1 > 0, \dots, p_k > 0, p_1 + \dots + p_k = 1$, čili:

$$\Theta^{(t+1)} = \operatorname{argmax}_{\Theta} Q(\Theta, \Theta^{(t)}). \quad (5.9)$$

Algoritmus opakuje kroky E a M tak dlouho, dokud není dosažena koncová podmínka:

$$\|\Theta^{(t+1)} - \Theta^{(t)}\| < \varepsilon, \quad (5.10)$$

pro předem určenou konstantu $\varepsilon > 0$ a vhodně zvolenou normu $\|\cdot\|$. [11] [9]

5.4 Graphcut algoritmus

Graphcut algoritmus je metoda segmentace obrazů za pomoci teorie grafů. Jedná se o metody s velice dobrými výsledky za předpokladu kvalitní apriorní informace o pozici objektů a pozadí.

5.4.1 Co je to graf

Obecná definice grafu říká, že ten je definován jako uspořádaná dvojice množin $G = (V, E)$, kde V je neprázdná množina vrcholů. Pro množinu E pak platí $E \subseteq V \times V$, tedy že prvky množiny E jsou dvouprvkové podmnožiny z V . Množina E se také nazývá hrany (edges). Hrany spojují dvojice vrcholů. Vážený graf je pak takový, kde buď vrcholy $v_0, v_1, \dots, v_n \in V$ nebo hrany $e_1, e_2, \dots, e_m \in E$ jsou ohodnoceny váhovou funkcí w . Orientované grafy jsou takové grafy, kde hrany $e_1, e_2, \dots, e_m \in E$ mají směr. Hrana může být i obousměrná, ohodnocení se může nebo nemusí v jednotlivých směrech lišit.

5.4.2 Síťe

Grafy pro tento algoritmus musejí být speciálně zkonstruované. Mají na rozdíl od prostých grafů ¹ speciální druhy vrcholů, pro jejich označení se používají anglické termíny sources a sinks a značí se s a t). Ostatní vrcholy, tedy ty co leží mezi nimi, jsou tzv. mezilehlé vrcholy a značí se v . Speciálním druhům vrcholů se také říká terminální vrcholy, nebo zkráceně terminály. Takový druh grafu se nazývá síť.

Hrany sítě jsou ohodnocené a orientované. Váha je nezáporná a označuje se jako kapacita c_{ij} mezi vrcholy v_i a v_j . Platí tedy, že $w_{ij} = c(e_{ij})$. Kapacita hrany udává, jaký maximální tok může hranou protékat. Tok f je nezáporné číslo. Tok hranou e_{ij} značíme f_{ij} . Pokud platí, že $c_{ij} = f_{ij}$, pak hranu nazýváme nasycenou. Pokud platí, že $c_{ij} > f_{ij}$, hranu nazýváme nenasyčenou. Tok hranou musí splňovat následující podmínku:

$$f_{in}(v_i) = f_{out}(v_j), \forall v \in V - s, t \quad (5.11)$$

$$\sum_{e_{ji}} f_{ji} = \sum_{e_{ij}} f_{ij} \quad (5.12)$$

Jinými slovy suma toků vtékajících do vrcholu v se musí rovnat součtu toků z vrcholu v vytékajících. Výjimkou z této podmínky jsou speciální terminální vrcholy s a t . Pro ty platí, že $f_{in}(s) < f_{out}(s)$ a naopak $f_{in}(t) > f_{out}(t)$. Nakonec platí, že celkový tok z s se rovná celkovému přítoku do t . [18]

5.4.3 Řez grafem

Řez grafem G se zdrojem s a stokem t rozdělí vrcholy V do dvou podmnožin, takových že $S = s_1, s_2, \dots, s_n \subset V$ a $T = t_1, t_2, \dots, t_m$, kde $V = s_1, s_2, \dots, s_n, t_1, t_2, \dots, t_m$. Pro tyto množiny platí, že $S + T = V$. To znamená, že hrany spojující množiny T a S jsou oddělené právě tímto řezem, který značíme $C(ST)$, nebo je také nazýván s - t řez. Hodnota řezu $C(ST)$ je rovna součtu kapacit hran v tomto řezu směřujících z S do T (nikoliv z T do S), tedy:

¹V teorii grafů se termínem prostý graf označuje takový graf, jenž neobsahuje žádnou rovnoběžnou hranu. Avšak může obsahovat smyčky.

$$C(ST) = \sum_{v_n \in S} \sum_{v_m \in T} c(e_{mn}) \quad (5.13)$$

Minimální řez je řez s nejnižší hodnotou. Problém hledání maximálního toku je duální k problému hledání minimálního řezu (max-flow min-cut teorém) a je pak snadno řešitelný některým z augmenting paths, nebo push-relabel algoritmů. [7]

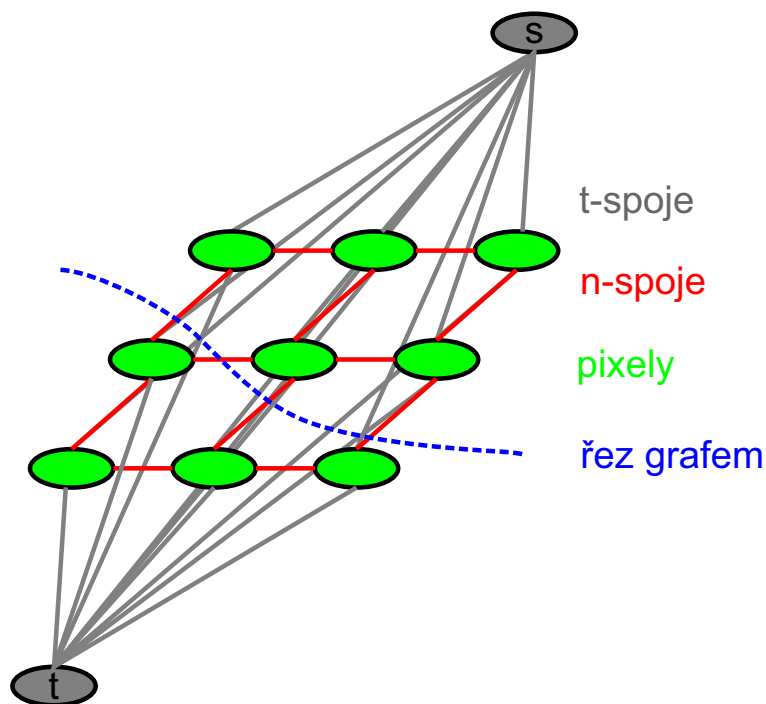
5.4.4 Popis algoritmu

Graphcut algoritmus je segmentační metoda využívající k oddělení objektů od pozadí teorii grafů. Na základě bodů ve fotografii a vztahů mezi nimi je vytvořen graf typu síť. Rozdělení bodů v grafu do dvou množin odpovídajících popředí a pozadí se docílí pomocí řezu. Body v grafu se skládají do logických segmentů. Optimální řez se pak hledá pomocí kritéria minimalizujícího energii. Hodnota energie se obvykle skládá ze dvou informací:

1. jak moc jsou atributy segmentu podobné mezi sebou,
2. jak jsou rozdílné oproti sousedním segmentům.

Graf $G = (V, E)$ je vytvořen z fotografie takovým způsobem, že pixely představují jednotlivé vrcholy grafu. Source s pak představuje označení objektů, sink t představuje označení pozadí. Sousedící pixely či vrcholy jsou navzájem spojeny hranou. Vytvářejí tedy pravoúhlou mřížku. Tyto hrany nazýváme n-spoje (z angl. neighbour - soused). Všechny vrcholy (pixely) jsou navíc spojeny hranou s terminálními vrcholy t a s . Tyto hrany jsou nazývány t-spoje (terminální). Pixely mohou být spojeny jako čtyřokolí (vertikálně a horizontálně sousedící pixely), osmiokolí (navíc i diagonálně sousedící pixely), vzácně i jinak.

Termín *region term* označuje tzv. regionální požadavky, tj. penalizaci za přiřazení pixelu segmentu S či T . Vztahy v algoritmu jsou nastavené tak, že nižší pravděpodobnost bude mít větší penalizaci. Obvykle se při segmentaci požaduje, aby si byly pixely segmentovaného objektu podobné. Jako atribut k porovnávání podobnosti můžeme používat intenzitu barvy, tón, odstín, sytost, atd. Vztah na hranici mezi popředím a pozadím



Obrázek 5.5: Názorné schéma vytvoření sítě z fotografie.

určuje tzv. *boundary term*. Koeficienty vymezují různou významnost regionálního nebo hraničního požadavku pro výslednou segmentaci. Cílem celého algoritmu je nalézt takové nastavení parametrů *region term* a *boundary term*, pro které je energie minimální. Tím je získána globálně optimální segmentace. Přesná hodnota této energie není důležitá.

5.4.5 Pevná omezení

Jelikož reálné fotografie obvykle nemají regionální vlastnosti popředí příliš odlišné od pozadí, zavádějí se pevná omezení. Jedná se o oblasti, jejichž přiřazení k popředí či pozadí je předem dané a výsledný řez grafem ho nesmí změnit, nebo je na určitý typ přiřazení kladem vyšší důraz. Tím se omezí prohledávaná množina možných řešení, zrychlí se průběh algoritmu a zpřesní výsledky. Na druhou stranu to vyžaduje zásah experta, který tyto oblasti označí. Právě automatickým, respektive poloautomatickým hledáním takových oblastí se zabývá experimentální část této práce 6.

Jedná o vytvoření množin F (foreground - popředí), B (background - pozadí) a popřípadě F_P a B_P (possible - možné). Pro ně platí, že $F \subset V \wedge B \subset V \wedge F_P \subset V \wedge B_P \subset V$,

příčemž každý $v \in V$ může být obsažen maximálně v jedné z těchto podmnožin. Z toho také plyne, že ne všechny vrcholy musejí být rozděleny mezi pevná omezení F a B .

Tato pevná omezení bývají využita pro inicializaci algoritmu, ale mohou být použita i pro korekci výsledků. [3]

Kapitola 6

Praktická část

6.1 Metodika experimentu

6.1.1 Použitý Eye Tracker

Systém I4Tracking[®], jehož výrobcem je společnost Medicton Group, s. r. o., využívá videookulografickou metodu, která používá ke sledování polohy oka a jeho stavu dvě kamery - oční pro snímání oka a scénickou pro snímání pozadí. Jedná se o sofistikovanou metodu, která je neinvazivní a přitom dostatečně přesná pro sledování očních pohybů.



Obrázek 6.1: Systém I4Tracking[®]. [16]

Systém I4Tracking[®] je měřicí zařízení, které snímá videookulografickou metodou oční pohyby a umožňuje měřit oční reakce respondenta na vizuální stimul. Systém I4Tracking[®]

je lehké a snadno přenosné zařízení. Základem tohoto zařízení jsou dvě malé kamery, které jsou připevněny k náhlavní části tak, aby z bezprostřední blízkosti snímaly uživatelskou oční pohyby a okolí. Z očních kamery jsou data do osobního počítače přenášena prostřednictvím vysokorychlostního USB kabelu typu USB 3.0, ze scénické kamery jsou data přenášena prostřednictvím USB kabelu typu USB 2.0. Data jsou zpracovávána aplikací I4Tracking[®]. Tato speciální aplikace obsahuje nástroj pro návrh experimentu a současně ukládání naměřených informací, které lze následně exportovat, vizualizovat i částečně statisticky zpracovat.[16]



Obrázek 6.2: Způsob používání a zapojení systému I4Tracking[®]. [16]

Porovnáme-li tento systém s požadavky na použitelnost zařízení na sledování očí zmíněné v kapitole 3.4, zjistíme následující:

Sledovací zařízení:

- umožňuje volné zorné pole s nezakrytou oblastí hlavy a obličeje
Splňuje jen částečně. Konstrukce „brýlových obrouček“ zakrývá část zorného pole, stejně tak část hlavy i obličeje - například nelze využít společně s dioptrickými brýlemi, atp.
- by nemělo mít žádný přímý kontakt s uživatelem
Nesplňuje. Problémem je opět konstrukce typu „brýle“, navíc v pohybu překážejí také kabely, použité pro přenos informací ze zařízení do počítače.

- je schopné uměle stabilizovat obraz na sítnici v případě potřeby.
Nesplňuje. Zařízení není vybavené žádnou formou stabilizace obrazu na sítnici. Například posunutí brýlí tak může zavést velkou chybu.
- má přesnost alespoň jedno procento nebo několik obloukových minut.
Není známo. V příložených dokumentech není dostatečná technická dokumentace.
- poskytuje rozlišení jedné obloukové minuty, čili musí umět detekovat nejjemnější pohyby oka.
Není známo. V příložených dokumentech není dostatečná technická dokumentace.
- splnit dynamiku rozsahu $1'$ až 45° pro polohu oka ($3000\times$) a $1'$ až 800° za sekundu pro rychlost oka ($50000\times$).
Není známo. V příložených dokumentech není dostatečná technická dokumentace.
- musí splňovat dobrou časovou dynamiku a malou reakční dobu (velké zesílení, malou dobu odezvy).
Není známo. V příložených dokumentech není dostatečná technická dokumentace.
- by mělo pracovat realtime (okamžité zpracování za běhu).
Nesplňuje. Výpočty jsou provedeny dodatečně spuštěním analýzy na naměřených datech v dodaném software.
- dokáže měřit všechny tři stupně volnosti (horizontální pohyb, vertikální pohyb a rotace oka).
Splňuje. Použitá videookulografická metoda a analýza získaných dat umožňuje sledovat všechny tři stupně volnosti oka.
- být snadno rozšiřitelné na sledování obou očí.
Nesplňuje. Přesto, že brýlová konstrukce by umožňovala možnost rozšíření o druhé reflexní sklo, instalace infračervené kamery pro druhé oko není možná. Na tomto místě se nachází scénická kamera. Umístění scénické kamery na jiné místo by vyžadovalo miniaturizaci kamery.

- musí být kompatibilní se systémy na sledování pohybu těla a hlavy.

Nesplňuje. Systém nezaručuje kompatibilitu s jinými zařízeními na sledování pohybu těla či hlavy. Právě absence dodatečných oprav, vypočítaných z pohybu těla a hlavy může zavádět do měření nemalou chybu. Před každým pokusem je navíc nutná nová kalibrace systému.

- je snadno použitelné na velkou škálu aplikací.

Nesplňuje. Zařízení nepracuje v reálném čase a uživatele velmi omezuje v pohybu. Navíc nijak v měření nezohledňuje pohyb hlavy či těla a proto není vhodné na širokou škálu aplikací, pouze na krátké experimenty.

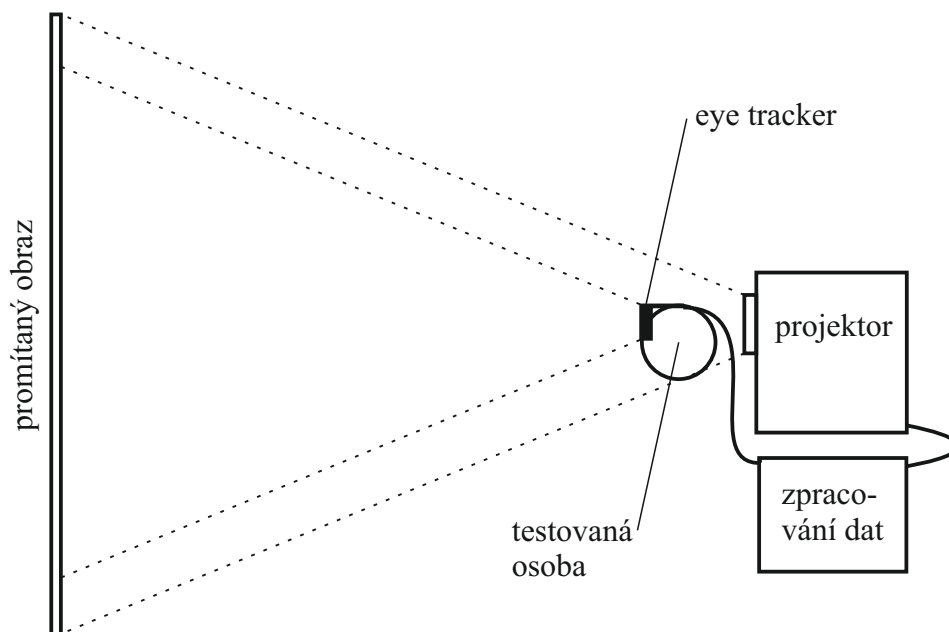
6.1.2 Nahrávání dat

Nahrávání dat pro analýzu probíhá pomocí eye trackeru popsaného v předchozích odstavcích, projektoru a počítače pro zpracování dat. Testovaná osoba sedí před projektorem. Pomocí projektoru během kalibrace trackeru na plátno promítnutý kříž, se kterým obsluha experimentu může pohybovat pomocí myši. Protože zbytek obrazu je černý, kříž je jediný promítnutý objekt na plátně. Po úspěšné kalibraci obsluha experimentu spustí program, který promítne sadu testovacích obrázků. Pro každé nahrávání je třeba zařízení znovu zkalibrovat.

6.1.3 Předzpracovaná data pro segmentaci

Po nahrání dat testované osoby a analýze softwarem dodaným výrobcem eye trackeru získám:

1. Soubor typu *.csv obsahující časovou značku v *ms*, informaci o tom, zda bylo oko otevřené (podařilo se najít zornici), polohu zornice v ose *x* a *y*, šířku a výšku zornice, plochu zornice, úhel rotace oka v ose zorného prostoru a konečně informace o poloze bodu, na který uživatel kouká reprezentovanou taktéž polohou v ose *x* a *y*. Snímkovací frekvence lze nastavit až na 150 snímků za vteřinu.
2. Složku obsahující 8-bitové obrazy pořízené scénickou kamerou. Snímky jsou pojme-



Obrázek 6.3: Schéma testování.

nované podle času v *ms*, kdy byly pořízeny a protože frekvence pořizování snímků je fixní - 25 snímků za vteřinu, neodpovídají vždy časové značce z infračervené kamery. Proto je nutné použít vždy ten snímek ze scénické kamery, jehož časová značka je co nejbližší.

6.1.4 Zpracování dat, segmentace

Pro další zpracování dat jsem použil algoritmy popsané v kapitole 5. Na připravených datech je třeba nejdříve nalézt skutečnou polohu obrazu na snímcích z kamery. K nalezení rohových bodů využíváme prahování Otsuovou metody a morfologickou operaci otevření. Díky tomu je snadné nalézt hranice obrazu. Převedením do homogenních souřadnic a rovinou řezu přepočteme všechny naměřené hodnoty na skutečné souřadnice.

Problémem byla také odchylka měření. Nejpravděpodobnější je, že byla způsobená především nedostatky použitého zařízení na sledování pohybu očí. Např. tím, že nezohledňovalo pohyb těla či hlavy. Pevná konstrukce obrouček zařízení neumožnila přizpůsobení se anatomickým vlastnostem pozorovatele. Odečtení větší části odchylky jsme docílili pomocí prvního měřeného snímku. Ten obsahoval pouze kříž uprostřed bílé plochy. Pozorovatel

soustředil svůj pohled na střed kříže po dobu dvou vteřin. Pro vyhodnocení odchylky experimentu jsem odečetl průměrné místo, kam zařízení vyhodnotilo souřadnice pohledu pozorovatele od pozice kříže (středu obrazu). Tím jsem získal pro každého pozorovatele a pro každý experiment vektor chyby. Dle konzultací s pozorovateli odečtení této chyby značně zpřesnilo výsledky. Na tomto tvrzení se shodli všichni pozorovatelé.

Teprve po vyřešení tohoto problému jsou data vhodně připravená pro segmentaci. Pro další zlepšení výsledků segmentace však potřebujeme nalézt další pevná omezení. Lze je chápat jako určení plochy, na které se s jistotou nachází či nenachází segmentovaný objekt. K odhadu této plochy využijeme EM algoritmu. Tento algoritmus nalezne dvourozměrné normální rozdělení odpovídající zpracovaným datům. Řezem skrz toto rozdělení získáme plochu pro pevné omezení. Naším předpokladem je, že tato plocha je místo, na které se pozorovatel soustředil. Mělo by tak být pro segmentaci objektu význačným místem. Tento předpoklad experimenty jednoznačně prokázaly.

6.1.5 Získání srovnávacích dat

Data získaná z experimentu jsem srovnal pomocí segmentací získaných dalšími dvěma metodami. První skupinu tvoří tzv. ground truth data. V oblasti strojového učení se tento termín používá pro označení sady dat vytvořené expertem na danou oblast. Tato data jsou považována za zcela správný výsledek. Podobně je tomu i u ground truth obrazu. Ten budu považovat za přesné oddělení objektů a pozadí. Vytvoření této sady zahrnovalo náročnou ruční úpravu obrázku, přičemž hranu objektu mezi popředím a pozadím jsem editoval s přesností na 1 pixel. O pixelech, které nepatřily jasně ani k jedné zkoumané skupině, jsem rozhodoval já. Jedná se například o pixely ovlivněné efekty antialiasingu, tedy filtrem, který hranu rozostří a vypočte odpovídající barvu pixelu na rozhraní, různé rušivé prvky jako objekty na pozadí, odrazy, atd. a další anomálie.

Další skupinou dat jsou segmentace spočítané pomocí stejného algoritmu jako u dat z eye trackeru, tedy metodou GraphCut. Rozdílem je, že pevná omezení nejsou určená z naměřených hodnot. Všech 12 účastníků experimentu zadávalo pevná omezení ručně.

Aby zadávání bylo snazší a rychlejší, byl napsán software, kam by bylo možné tato omezení zadat, respektive nakreslit. Software zároveň měřil, jak dlouho označení trvalo. Na obrázcích níže je názorně předvedeno používání aplikace.




Obrázek 6.4: Pozorovatel tahem myši oddělí objekt od pozadí.



Obrázek 6.5: Výsledek segmentace (pouze po hrubém vyznačení pozadí).

Veškerá plocha vně modrého obdélníku je považována za pozadí a uživatel aplikace ji už nemusí označovat. Jak je však vidět na obrázku 6.5, tento krok není pro dobrou segmentaci dostatečný. Některé části oblohy jsou nadále považované za objekt a naopak

některé části letadla jsou považované za pozadí.



Obrázek 6.6: Pozorovatel „štetcem“ označí barevně plochy s omezením. Černou barvou uživatel označil plochu, kterou pokládá za jisté pozadí, bílou barvou za jisté popředí, zelenou barvou za možné popředí a červenou barvou za možné pozadí.



Obrázek 6.7: Výsledek segmentace (pouze po jemném vyznačení omezení).

Nyní uživatel může manuálně pomocí kurzoru vybrat (zabarvit) části, které považuje za popředí objektu, pozadí objektu, možné popředí a možné pozadí. Ty jsou na obrázku 6.6 označené černou barvou pro jisté pozadí, bílou barvou pro jisté popředí, zelenou barvou pro možné popředí a červenou barvou pro možné pozadí. Aby se uživateli některé objekty

lépe označovali, bylo také možné změnit si velikost „štětce“ a označit tak i tenké části objektů.

Jak je vidět na obrázku 6.7, výsledek automatické segmentace se se zadáním pevných omezení uživatelem značně zlepšil. V relativně krátkém čase tímto způsobem je možné získat dobře segmentovaný objekt. V programu bylo navíc možné online sledovat výsledek segmentace při každém označení omezení.



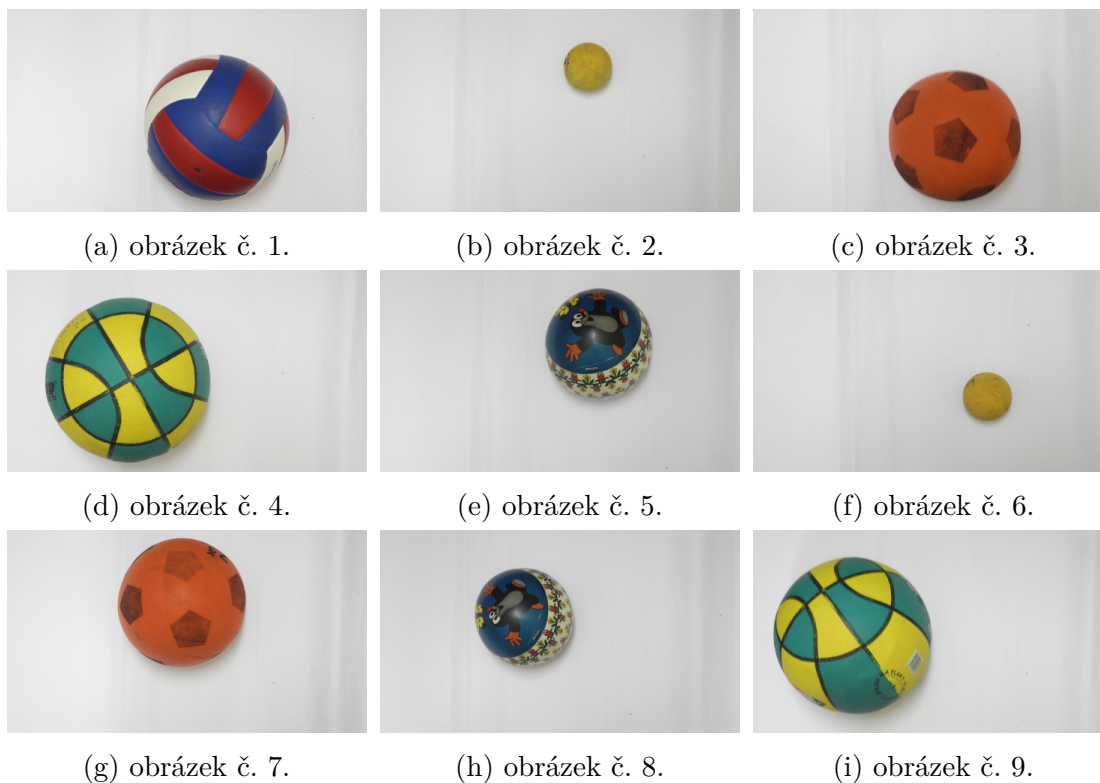
Obrázek 6.8: Vstup pro GraphCut.

Na obrázku 6.8 lze vidět, jak vypadají data vyhodnocená z aplikace. Tento obrázek neodpovídá přesně výstupu programu. Hodnota pozadí zůstává pro daný pixel 0, možného pozadí 170 (2×85), popředí 85 (1×85) a možného popředí 255 (3×85). Z důvodů vizualizace byly všechny hodnoty vynásobeny číslem 85.

6.2 Vstupní data a ideální výstup

6.2.1 Původní fotografie

Sada 6.9 jsou autorovy vlastní fotografie. Jedná se o fotografie míčů, tedy jednoduché geometrické tvary na jednobarevném pozadí. Tato sada by tedy měla představovat nejjednodušší úlohu pro segmentaci. Sady 6.10 a 6.11 jsou obrazy vybrané z internetové galerie tumblr. Všechny vybrané obrázky podléhají licenci Creative Commons a dovolují šíření upravených děl vzniklých z původního díla. Na sadě 6.10 s letadly se jedná o složitější tvary než v prvním případě, pozadí je často jednotné, nebo alespoň zčásti jednotné. Pro segmentaci nejnáročnější by měly být fotografie poslední sady 6.11. Za zvířaty se totiž nachází složité pozadí, které může být těžké odlišit od objektu.



Obrázek 6.9: První sada fotografií - míče.



(a) obrázek č. 1.



(b) obrázek č. 2.



(c) obrázek č. 3.



(d) obrázek č. 4.




(e) obrázek č. 5.



(f) obrázek č. 6.



(g) obrázek č. 7.



(h) obrázek č. 8.



(i) obrázek č. 9.

Obrázek 6.10: Druhá sada fotografií - letadla.



(a) obrázek č. 1.



(b) obrázek č. 2.




(c) obrázek č. 3.



(d) obrázek č. 4.



(e) obrázek č. 5.



(f) obrázek č. 6.



(g) obrázek č. 7.



(h) obrázek č. 8.

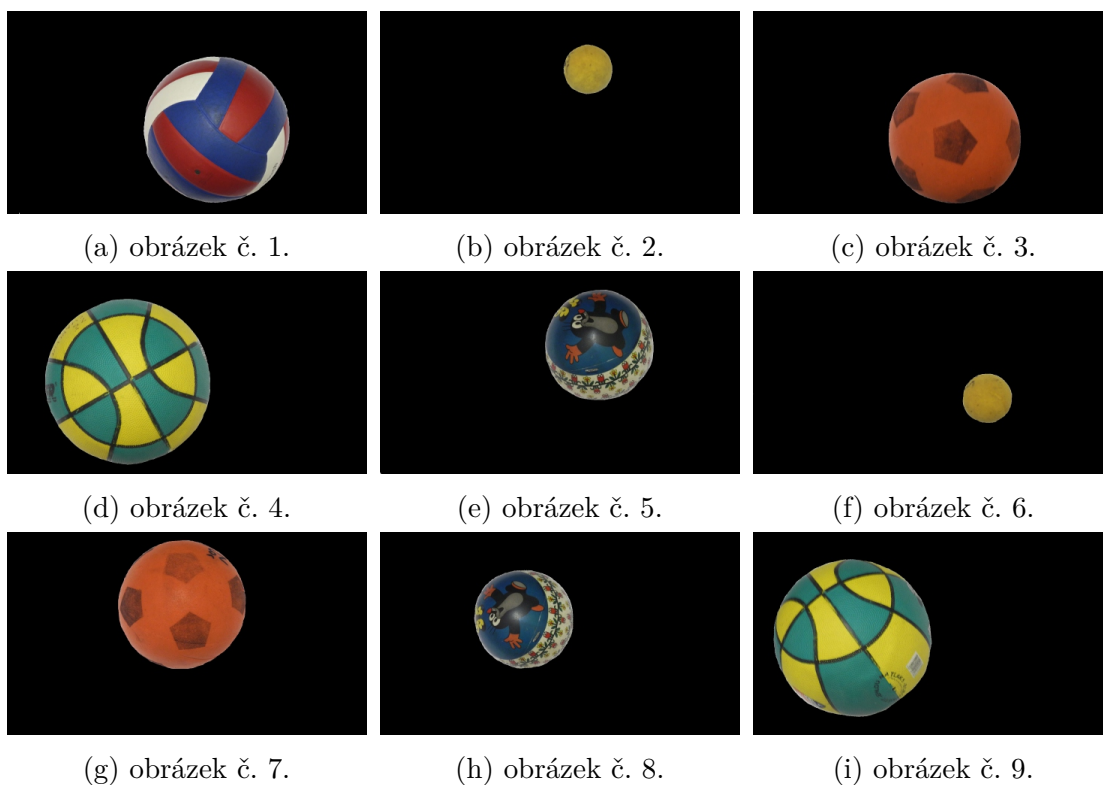


(i) obrázek č. 9.

Obrázek 6.11: Třetí sada fotografií - zvířata.

6.2.2 Ground truth

Jedná se o data vytvořená ručně v grafickém editoru. Manuální extrakce objektu je časově nejnáročnější. K jejich získání je totiž třeba znalostí a i dovedností experta, který data vytváří. Ruční úpravy jsou také časově nejnáročnější. Ve vyhodnocení jsou brána jako bezchybně segmentované obrazy. Dalo by se také říci, že toto je cíl, kterého se snažíme automatickou segmentací dosáhnout. Všechny ostatní výsledky jsou srovnávány právě s touto sadou.



Obrázek 6.12: Ground truth data první sady fotografií.



(a) obrázek č. 1.



(b) obrázek č. 2.



(c) obrázek č. 3.




(d) obrázek č. 4.



(e) obrázek č. 5.




(f) obrázek č. 6.



(g) obrázek č. 7.



(h) obrázek č. 8.



(i) obrázek č. 9.

Obrázek 6.13: Ground truth data druhé sady fotografií.




(a) obrázek č. 1.



(b) obrázek č. 2.




(c) obrázek č. 3.



(d) obrázek č. 4.



(e) obrázek č. 5.



(f) obrázek č. 6.



(g) obrázek č. 7.



(h) obrázek č. 8.



(i) obrázek č. 9.

Obrázek 6.14: Ground truth data třetí sady fotografií.


6.3 Experimenty

Na následujících stránkách je v práci prezentováno 27 experimentů rozdělených do tří sad podle tématu fotografií.

Na následujících stránkách budu hovořit především o výsledcích dvou metod, na které se práce soustředí. Jsou to metody velmi podobné. Obě dvě využívají data získaná ze všech dvanácti měření, která pro každou fotografii jsou k dispozici. Rozdíl je ve způsobu, kterým je vytvořena maska pevných podmínek pro algoritmus GraphCut.

Na začátku každého odstavce hodnotím subjektivně výsledky dvou zmíněných metod, podobně jako v dotazníkovém způsobu ohodnocení segmentace, viz část 6.3.1 Chyba segmentace níže.

Mluvím-li o metodě či algoritmu s vypočtenými pevnými podmínkami (dále p.p.), pak vytvořená maska má čtyři úrovně určené z pravděpodobnostního rozdělení určeného EM algoritmem. Jisté popředí je oblast s 10% kvantilem, možné popředí, možné pozadí jsou 50% a 90% kvantily. Zbytek je pak považován za pozadí. Jedná se tedy o trojici soustředěných stejně orientovaných elips.




(a) Příklad masky s vypočtenými p.p.

(b) Vizualizace masky na fotografii.

Obrázek 6.15: Příklad masky s vypočtenými p.p. - sada 2 obrázek 6.

Mluvím-li o metodě či algoritmu bez pevných podmínek nebo s volnějším pevnými podmínkami (dále bez p.p.), hovořím o masce, která obsahuje pouze 10% kvantil. Tedy

velmi malou elipsu, která by měla být někde ve středu hledaného objektu. Celý zbytek masky je považován za možné pozadí a algoritmus tak musí rozhodnout, kam jej zařadit.



(a) Příklad masky s vypočítanými p.p.

(b) Vizualizace masky na fotografii.

Obrázek 6.16: Příklad masky s volnějšími p.p. - sada 2 obrázek 6.

Proč o těchto metodách hovořím jako o automatických? I když se jedná o poloautomatické metody segmentace, neboť data pro automatický algoritmus vytváří člověk, nazývám tyto metody automatické. Jsou totiž soběstačné z pohledu uživatele. Ten se nesnaží fotografie rozdělovat na popředí či pozadí, pouze si je prohlíží. Mozek sám soustředí zrak a pozornost na objekty v popředí, teprve potom na další detaily. Stejně tak pokud uživatel nakreslí masku sám, jedná se z jeho pohledu o metoda ruční či manuální.

6.3.1 Chyba segmentace

Často kladenou otázkou je, jak segmentaci a její kvalitu hodnotit. Výsledky se totiž člověku jeví velmi subjektivně. Proto je řada metod založená na hodnocení pomocí dotazníků. Odpovědi hodnotitelů jsou pak statisticky zpracovány. V této práci nebyla použita dotazníková metoda a její statistické zpracování. U každého z experimentů je můj subjektivní komentář k výsledkům.

Objektivní hodnocení kvality segmentace použité v této práci je dvojí, založené však na stejných principech. U každého z pokusů jsou hodnoty podsegmentování (v tabulkách sloupce RS podseg. - podsegmentování ruční metody, ET podseg. - podsegmentování automatické metody) a přesegmentování (v tabulkách sloupce RS přese. - přesegmentování

ruční metody, ET podseg. - přesegmentování automatické metody) obrazu. Zkratka RS značí ruční segmentaci, značka ET eye tracking.

Podsegmentování znamená, jaká část celkové plochy, která měla náležet popředí, byla přiřazena k pozadí. Tedy procentuální část plochy, která na vybraném popředí chybí.

Přesegmentování znamená, jaká část celkové plochy, která měla náležet pozadí, byla přiřazena k popředí. Tedy procentuální část plochy, která na vybraném popředí přebývá.

Sloupce označené jako c. chyba, tedy celková chyba, jsou součtem plochy, která na vybraném popředí chybí a plochy, které na vybraném popředí přebývá.


Druhé vyhodnocení, které je použito, je relativní přegmentování a podsegmentování. Jsou vypočtena z předchozích měřítek vydělením plochou, ke které se vztahují. Podsegmentování se dělí plochou popředí a přesegmentování plochou pozadí. Získáme tak informaci o tom, jak velká část objektu chybí, popřípadě jak velká část pozadí přebývá. Přehled relativních výsledků experimentů je v tabulkách v části 6.4 Shrnutí výsledků experimentů.

Všechny výsledky v tabulkách byly vyhodnoceny automaticky pomocí skriptů. Všechny fungovali na principu porovnání bitového ekvivalentu ¹ ke grafickému výsledku metod a ground truth dat. Z těchto bitových matic jsem určil rozdíl automatické a přesné segmentace nutný určení přegmentování a podsegmentování. Sečtením čísel v matici jsem získal obsah těchto ploch v pixelech. Sečtením bitového ekvivalentu ground truth data jsem získal obsah správně segmentovaného objektu a odečtením od 1920×1080 obsah pozadí. Tyto informace jsem použil k určení relativního přegmentování a podsegmentování.

¹Obrázek či matice o rozměrech totožných s předlohou, kde 0 reprezentuje pozadí a 1 reprezentuje pozadí obrázku.

6.3.2 Sada 1, obrázek 1

Výsledek automatické segmentace pro vypočítané pevné podmínky je přesegmentovaný. Výsledek segmentace bez pevných podmínek je naopak silně podsegmentovaný. Problémovou částí u ruční segmentace byla oblast se stínem míče, kde naopak automatická segmentace uspěla. Metoda s vypočítanými pevnými podmínkami (dále jen p.p.) založená na datech od více pozorovatelů našla hledaný objekt. Metoda s daty všech pozorovatelů bez p.p. je výrazně přesnější než experimenty využívající data jen od jednoho z pozorovatelů. Její celková chyba je blízko horším výsledkům ručního vyznačení p.p. a přibližně o 0,472% plochy za průměrným výsledkem. S průměrným časem 66,8 sekundy se jednalo o nejdelsí dobu potřebnou k ručnímu zadání p.p. Jelikož se jednalo o první obrázek (po zkušebním), ovlivnil výsledný čas fakt, že si většina pozorovatelů teprve zvykala na interface programu.




	RS podseg.	RS přeseğ.	c. chyba	ET podseg.	ET přeseğ.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,068 %	0,275 %	0,343 %	13,594 %	0,096 %	13,691 %	31,2 s	2,0 s	8,8 s	653,0 s
pozorovatel 2	0,065 %	0,362 %	0,428 %	22,959 %	0,000 %	22,959 %	70,2 s	2,0 s	6,9 s	653,0 s
pozorovatel 3	0,086 %	0,145 %	0,231 %	5,463 %	0,088 %	5,551 %	23,1 s	2,0 s	7,7 s	653,0 s
pozorovatel 4	0,061 %	0,650 %	0,710 %	1,817 %	0,082 %	1,899 %	72,2 s	2,0 s	8,9 s	653,0 s
pozorovatel 5	0,091 %	0,150 %	0,241 %	22,959 %	0,000 %	22,959 %	123,6 s	2,0 s	10,1 s	653,0 s
pozorovatel 6	0,070 %	0,283 %	0,354 %	11,159 %	0,000 %	11,159 %	28,3 s	2,0 s	11,1 s	653,0 s
pozorovatel 7	0,096 %	0,145 %	0,242 %	22,959 %	0,000 %	22,959 %	103,5 s	2,0 s	9,3 s	653,0 s
pozorovatel 8	0,096 %	0,142 %	0,238 %	4,096 %	0,085 %	4,181 %	135,2 s	2,0 s	8,9 s	653,0 s
pozorovatel 9	0,070 %	0,293 %	0,363 %	6,354 %	0,120 %	6,474 %	30,8 s	2,0 s	8,4 s	653,0 s
pozorovatel 10	0,143 %	0,126 %	0,270 %	22,959 %	0,000 %	22,959 %	60,5 s	2,0 s	9,2 s	653,0 s
pozorovatel 11	0,095 %	0,145 %	0,240 %	13,084 %	0,001 %	13,085 %	51,7 s	2,0 s	8,0 s	653,0 s
pozorovatel 12	0,038 %	1,174 %	1,212 %	11,497 %	0,066 %	11,563 %	71,6 s	2,0 s	10,0 s	653,0 s
průměr	0,082 %	0,324 %	0,406 %	13,242 %	0,045 %	13,286 %	66,8 s	2,0 s	8,9 s	653,0 s
s p. podm.	-	-	-	0,122 %	4,591 %	4,713 %	-	24,0 s	107,3 s	653,0 s
bez p. podm.	-	-	-	8,641 %	0,104 %	8,745 %	-	24,0 s	107,3 s	653,0 s

Tabulka 6.1: Výsledky experimentů pro Sadu 1, obrázek 1.

6.3.3 Sada 1, obrázek 2

Výsledek automatické segmentace pro vypočítané pevné podmínky je silně přesegmentovaný. Výsledek segmentace bez pevných podmínek je mírně přesegmentovaný. Problémovou částí u ruční segmentace byla kontura míče. Oba výsledky automatických segmentací založených na datech od více pozorovatelů obsahovaly hledaný objekt. Metoda bez pevných podmínek byla velmi úspěšná. Byla přesnější než experimenty využívající data jen od jednoho z pozorovatelů, dokonce přesnější než průměrný výsledek ručního vyznačení pevných podmínek asi o 0,134% celkové plochy.




	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,001 %	0,456 %	0,457 %	0,000 %	2,955 %	2,956 %	23,1 s	2,0 s	8,8 s	579,0 s
pozorovatel 2	0,000 %	0,921 %	0,921 %	2,587 %	0,000 %	2,587 %	25,1 s	2,0 s	6,9 s	579,0 s
pozorovatel 3	0,001 %	0,279 %	0,280 %	0,065 %	0,042 %	0,107 %	11,9 s	2,0 s	7,7 s	579,0 s
pozorovatel 4	0,001 %	0,419 %	0,420 %	0,019 %	4,029 %	4,048 %	27,0 s	2,0 s	8,9 s	579,0 s
pozorovatel 5	0,000 %	1,424 %	1,424 %	2,587 %	0,000 %	2,587 %	118,4 s	2,0 s	10,1 s	579,0 s
pozorovatel 6	0,000 %	2,614 %	2,614 %	0,078 %	21,749 %	21,827 %	27,6 s	2,0 s	11,1 s	579,0 s
pozorovatel 7	0,011 %	0,164 %	0,176 %	2,587 %	0,000 %	2,587 %	32,1 s	2,0 s	9,3 s	579,0 s
pozorovatel 8	0,001 %	0,249 %	0,250 %	2,587 %	20,329 %	22,916 %	87,8 s	2,0 s	8,9 s	579,0 s
pozorovatel 9	0,001 %	0,356 %	0,357 %	0,010 %	16,224 %	16,235 %	10,3 s	2,0 s	8,4 s	579,0 s
pozorovatel 10	0,001 %	0,525 %	0,526 %	2,587 %	0,000 %	2,587 %	24,3 s	2,0 s	9,2 s	579,0 s
pozorovatel 11	0,007 %	0,262 %	0,270 %	0,013 %	0,083 %	0,096 %	23,6 s	2,0 s	8,0 s	579,0 s
pozorovatel 12	0,000 %	2,318 %	2,319 %	0,000 %	2,048 %	2,049 %	28,8 s	2,0 s	10,0 s	579,0 s
průměr	0,002 %	0,832 %	0,834 %	1,093 %	5,622 %	6,715 %	36,7 s	2,0 s	8,9 s	579,0 s
s p. podm.	-	-	-	0,000 %	34,440 %	34,440 %	-	24,0 s	107,3 s	579,0 s
	-	-	-	0,001 %	0,699 %	0,700 %	-	24,0 s	107,3 s	579,0 s

Tabulka 6.2: Výsledky experimentů pro Sadu 1, obrázek 2.

6.3.4 Sada 1, obrázek 3

Výsledek automatické segmentace pro vypočítané pevné podmínky je silně přesegmentovaný i podsegmentovaný. Výsledek segmentace bez pevných podmínek je mírně podsegmentovaný. Problémovou částí u ruční segmentace byla oblast se stínem míče. Segmentace bez pevných podmínek založená na datech od více pozorovatelů našla hledaný objekt, segmentace s vypočtenými p.p. jen částečně. Metoda bez pevných podmínek byla velmi úspěšná. Vykazuje výrazně lepší výsledek než experimenty využívající data jen od jednoho z pozorovatelů a srovnatelně přesná jako průměrný výsledek ručního vyznačení pevných podmínek, který byl lepší jen o 0,099% celkové plochy.




	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,003 %	0,788 %	0,791 %	2,819 %	0,024 %	2,843 %	22,8 s	2,0 s	8,8 s	935,0 s
pozorovatel 2	0,001 %	1,212 %	1,214 %	18,751 %	0,000 %	18,751 %	39,7 s	2,0 s	6,9 s	935,0 s
pozorovatel 3	0,001 %	0,847 %	0,848 %	4,537 %	0,340 %	4,877 %	27,7 s	2,0 s	7,7 s	935,0 s
pozorovatel 4	0,001 %	1,351 %	1,352 %	2,140 %	9,352 %	11,492 %	77,7 s	2,0 s	8,9 s	935,0 s
pozorovatel 5	0,001 %	1,224 %	1,225 %	18,751 %	0,000 %	18,751 %	46,9 s	2,0 s	10,1 s	935,0 s
pozorovatel 6	0,002 %	0,644 %	0,646 %	5,565 %	0,000 %	5,565 %	48,4 s	2,0 s	11,1 s	935,0 s
pozorovatel 7	0,005 %	0,535 %	0,539 %	18,751 %	0,000 %	18,751 %	48,6 s	2,0 s	9,3 s	935,0 s
pozorovatel 8	0,004 %	0,662 %	0,666 %	18,746 %	0,000 %	18,746 %	50,5 s	2,0 s	8,9 s	935,0 s
pozorovatel 9	0,134 %	0,795 %	0,929 %	0,396 %	0,270 %	0,666 %	23,5 s	2,0 s	8,4 s	935,0 s
pozorovatel 10	0,003 %	0,534 %	0,536 %	18,751 %	0,000 %	18,751 %	23,4 s	2,0 s	9,2 s	935,0 s
pozorovatel 11	0,001 %	1,062 %	1,063 %	3,260 %	0,400 %	3,660 %	34,1 s	2,0 s	8,0 s	935,0 s
pozorovatel 12	0,001 %	1,337 %	1,338 %	6,478 %	17,396 %	23,874 %	43,8 s	2,0 s	10,0 s	935,0 s
průměr	0,013 %	0,916 %	0,929 %	9,912 %	2,315 %	12,227 %	40,6 s	2,0 s	8,9 s	935,0 s
s p. podm.	-	-	-	4,546 %	31,636 %	36,182 %	-	24,0 s	107,3 s	935,0 s
bez p. podm.	-	-	-	0,963 %	0,066 %	1,028 %	-	24,0 s	107,3 s	935,0 s

Tabulka 6.3: Výsledky experimentů pro Sadu 1, obrázek 3.

6.3.5 Sada 1, obrázek 4

Výsledek automatické segmentace pro vypočítané pevné podmínky je silně přesegmentovaný i podsegmentovaný. Výsledek segmentace bez pevných podmínek je podsegmentovaný. Problémovou částí u ruční segmentace byla oblast se stínem míče. Oba výsledky automatických segmentací založených na datech od více pozorovatelů obsahovaly hledaný objekt jen částečně. Metoda bez pevných podmínek byla úspěšnější, i když velká část objektu je podsegmentovaná. Míč na obrázku je fragmentovaný na plochy tmavým „švem“, což mělo za výsledek, že některé fragmenty sousedící s pozadím nebyly vyhodnocené jako objekt. Metody založené na datech od více pozorovatelů byly opět úspěšnější. Experimenty na datech od jednotlivých pozorovatelů vykazovaly velkou úroveň podsegmentování. Automatické metody byly řádově horší než ruční zadání p.p.




	RS podseg.	RS přeseg.	c. chyba	ET podseg.	ET přeseg.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,019 %	1,107 %	1,126 %	15,568 %	0,036 %	15,604 %	30,3 s	2,0 s	8,8 s	618,0 s
pozorovatel 2	0,022 %	1,074 %	1,096 %	29,245 %	0,000 %	29,245 %	64,8 s	2,0 s	6,9 s	618,0 s
pozorovatel 3	0,016 %	0,814 %	0,831 %	10,211 %	0,195 %	10,407 %	27,9 s	2,0 s	7,7 s	618,0 s
pozorovatel 4	0,080 %	1,345 %	1,424 %	7,318 %	0,058 %	7,376 %	95,3 s	2,0 s	8,9 s	618,0 s
pozorovatel 5	0,023 %	0,594 %	0,617 %	29,245 %	0,000 %	29,245 %	33,1 s	2,0 s	10,1 s	618,0 s
pozorovatel 6	0,031 %	0,843 %	0,874 %	22,985 %	0,000 %	22,985 %	47,8 s	2,0 s	11,1 s	618,0 s
pozorovatel 7	0,028 %	0,281 %	0,309 %	29,245 %	0,000 %	29,245 %	58,9 s	2,0 s	9,3 s	618,0 s
pozorovatel 8	0,034 %	0,247 %	0,280 %	19,701 %	0,019 %	19,720 %	182,5 s	2,0 s	8,9 s	618,0 s
pozorovatel 9	0,077 %	0,219 %	0,296 %	9,489 %	0,057 %	9,546 %	19,9 s	2,0 s	8,4 s	618,0 s
pozorovatel 10	0,058 %	0,281 %	0,340 %	29,245 %	0,000 %	29,245 %	24,4 s	2,0 s	9,2 s	618,0 s
pozorovatel 11	0,025 %	0,690 %	0,716 %	6,833 %	18,959 %	25,792 %	55,2 s	2,0 s	8,0 s	618,0 s
pozorovatel 12	0,021 %	1,091 %	1,112 %	9,524 %	3,601 %	13,125 %	28,0 s	2,0 s	10,0 s	618,0 s
průměr	0,036 %	0,716 %	0,752 %	18,218 %	1,910 %	20,128 %	55,7 s	2,0 s	8,9 s	618,0 s
s p. podm.	-	-	-	5,461 %	7,756 %	13,216 %	-	24,0 s	107,3 s	618,0 s
bez p. podm.	-	-	-	5,600 %	0,051 %	5,651 %	-	24,0 s	107,3 s	618,0 s

Tabulka 6.4: Výsledky experimentů pro Sadu 1, obrázek 4.

6.3.6 Sada 1, obrázek 5

Výsledek automatické segmentace pro vypočítané pevné podmínky je silně přesegmentovaný. Výsledek segmentace bez pevných podmínek je mírně podsegmentovaný. Problémovou částí u ruční segmentace byla oblast se stínem míče splývající navíc s barvou míče v dolní části obrázku. Oba výsledky automatických segmentací založených na datech od více pozorovatelů našly hledané popředí. Metoda bez pevných podmínek byla úspěšnější, i když část objektu v odstínech oranžové a červené je podsegmentovaná.




	RS podseg.	RS přeseğ.	c. chyba	ET podseg.	ET přeseğ.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,016 %	0,754 %	0,770 %	3,413 %	0,072 %	3,484 %	16,6 s	2,0 s	8,8 s	710,0 s
pozorovatel 2	0,013 %	1,117 %	1,131 %	12,905 %	0,000 %	12,905 %	43,1 s	2,0 s	6,9 s	710,0 s
pozorovatel 3	0,010 %	0,910 %	0,921 %	3,269 %	19,339 %	22,608 %	12,5 s	2,0 s	7,7 s	710,0 s
pozorovatel 4	0,013 %	1,171 %	1,184 %	0,340 %	9,424 %	9,764 %	63,0 s	2,0 s	8,9 s	710,0 s
pozorovatel 5	0,015 %	1,030 %	1,046 %	12,905 %	0,000 %	12,905 %	29,3 s	2,0 s	10,1 s	710,0 s
pozorovatel 6	0,014 %	1,109 %	1,123 %	9,185 %	0,027 %	9,212 %	31,3 s	2,0 s	11,1 s	710,0 s
pozorovatel 7	0,051 %	1,037 %	1,088 %	12,905 %	0,000 %	12,905 %	39,2 s	2,0 s	9,3 s	710,0 s
pozorovatel 8	0,090 %	0,176 %	0,266 %	0,350 %	0,134 %	0,484 %	44,4 s	2,0 s	8,9 s	710,0 s
pozorovatel 9	0,171 %	0,086 %	0,257 %	4,429 %	0,062 %	4,491 %	17,5 s	2,0 s	8,4 s	710,0 s
pozorovatel 10	0,016 %	0,861 %	0,877 %	12,905 %	0,000 %	12,905 %	25,6 s	2,0 s	9,2 s	710,0 s
pozorovatel 11	0,021 %	1,005 %	1,026 %	2,914 %	0,069 %	2,983 %	20,8 s	2,0 s	8,0 s	710,0 s
pozorovatel 12	0,027 %	0,582 %	0,610 %	2,802 %	8,033 %	10,835 %	64,0 s	2,0 s	10,0 s	710,0 s
průměr	0,038 %	0,820 %	0,858 %	6,527 %	3,097 %	9,623 %	34,0 s	2,0 s	8,9 s	710,0 s
s p. podm.	-	-	-	0,004 %	19,533 %	19,537 %	-	24,0 s	107,3 s	710,0 s
bez p. podm.	-	-	-	1,211 %	0,119 %	1,330 %	-	24,0 s	107,3 s	710,0 s

Tabulka 6.5: Výsledky experimentů pro Sadu 1, obrázek 5.

6.3.7 Sada 1, obrázek 6

Výsledek automatické segmentace pro vypočítané pevné podmínky je silně přesegmentovaný. Výsledek segmentace bez pevných podmínek je naprosto chybný. Hledaný objekt je zcela mimo vysegmentovanou oblast. Problémovou částí u ruční segmentace byla oblast stínu a kontury míče. Oba výsledky automatických segmentací založených na datech od více pozorovatelů měly velmi špatné výsledky. Metoda s vypočtenými p.p. byla úspěšnější, podařilo se nalézt hledaný objekt. Metoda bez p.p. dosáhla vůbec nejhoršího výsledku ze všech experimentů. To bylo pravděpodobně určeno výpočtem středu objektu. Vypočtený střed se totiž nacházel mimo hledaný objekt. Za zmínku však stojí výsledek pozorovatele č. 12, jehož výsledek byl přesnější než všechny segmentace s ručně zadanými daty. Co se ruční segmentace týká, bylo vytvoření dat pro tento obrázek nejrychlejší z celé sady, průměrně na zakreslení p.p. pozorovatelé strávili pouze 26,0 sekundy.



	RS podseg.	RS přeseğ.	c. chyba	ET podseg.	ET přeseğ.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,010 %	0,260 %	0,269 %	0,000 %	16,429 %	16,429 %	19,1 s	2,0 s	8,8 s	412,0 s
pozorovatel 2	0,001 %	0,751 %	0,752 %	2,618 %	0,000 %	2,618 %	15,1 s	2,0 s	6,9 s	412,0 s
pozorovatel 3	0,004 %	0,213 %	0,217 %	2,618 %	30,923 %	33,541 %	17,5 s	2,0 s	7,7 s	412,0 s
pozorovatel 4	0,001 %	0,448 %	0,449 %	0,076 %	28,558 %	28,634 %	32,8 s	2,0 s	8,9 s	412,0 s
pozorovatel 5	0,002 %	0,270 %	0,272 %	2,618 %	0,000 %	2,618 %	23,3 s	2,0 s	10,1 s	412,0 s
pozorovatel 6	0,002 %	0,445 %	0,447 %	2,589 %	22,739 %	25,329 %	37,7 s	2,0 s	11,1 s	412,0 s
pozorovatel 7	0,005 %	0,199 %	0,205 %	2,618 %	0,000 %	2,618 %	48,9 s	2,0 s	9,3 s	412,0 s
pozorovatel 8	0,002 %	0,280 %	0,282 %	2,618 %	33,261 %	35,879 %	33,3 s	2,0 s	8,9 s	412,0 s
pozorovatel 9	0,002 %	0,375 %	0,377 %	0,049 %	25,355 %	25,404 %	13,1 s	2,0 s	8,4 s	412,0 s
pozorovatel 10	0,002 %	0,308 %	0,310 %	2,618 %	0,000 %	2,618 %	14,0 s	2,0 s	9,2 s	412,0 s
pozorovatel 11	0,002 %	0,447 %	0,449 %	0,171 %	38,027 %	38,198 %	32,2 s	2,0 s	8,0 s	412,0 s
pozorovatel 12	0,002 %	0,442 %	0,444 %	0,047 %	0,041 %	0,088 %	25,1 s	2,0 s	10,0 s	412,0 s
průměr	0,003 %	0,370 %	0,373 %	1,553 %	16,278 %	17,831 %	26,0 s	2,0 s	8,9 s	412,0 s
s p. podm.	-	-	-	0,000 %	34,031 %	34,032 %	-	24,0 s	107,3 s	412,0 s
bez p. podm.	-	-	-	2,617 %	74,921 %	77,538 %	-	24,0 s	107,3 s	412,0 s

Tabulka 6.6: Výsledky experimentů pro Sadu 1, obrázek 6.

6.3.8 Sada 1, obrázek 7

Výsledek automatické segmentace pro vypočítané pevné podmínky byl velmi přesný. Výsledek segmentace bez pevných podmínek je mírně podsegmentovaný. Problémovou částí u ruční segmentace byla oblast stínu a kontury míče. Oba výsledky automatických segmentací založených na datech od více pozorovatelů měly velmi nízkou celkovou chybovost. Metoda s vypočtenými p.p. byla velmi úspěšná. Její celková chyba dosahuje jen 0,264% plochy, což je méně než jakákoliv segmentace s ručně zadanými p.p. a o 0,571% lepší výsledek než průměrná hodnota. Také metoda bez p.p. si vedla velmi dobře. Chyba byla vyšší jen o 0,938% než průměrná ruční segmentace. Experimenty na datech jen od jednoho pozorovatele měly tendenci podsegmentovat a to v průměru o 8,617%. Oproti tomu výpočty s ručně zadanými p.p. měly tendenci spíše přesegmentovat v problémových částech. Podsegmentovanost byla v průměru pouhých 0,015%. Což je odhadem kolem 300 pixelů. Jen na obvodu míče jich je přitom přibližně přes 4000.



(a) ground truth.

(b) aut. seg. s p. podm.


(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,079 %	0,946 %	1,025 %	5,438 %	0,032 %	5,470 %	28,6 s	2,0 s	8,8 s	593,0 s
pozorovatel 2	0,005 %	1,285 %	1,290 %	17,606 %	0,000 %	17,606 %	31,9 s	2,0 s	6,9 s	593,0 s
pozorovatel 3	0,029 %	0,393 %	0,421 %	17,605 %	0,000 %	17,605 %	21,6 s	2,0 s	7,7 s	593,0 s
pozorovatel 4	0,005 %	1,376 %	1,381 %	0,314 %	0,484 %	0,798 %	82,2 s	2,0 s	8,9 s	593,0 s
pozorovatel 5	0,006 %	1,235 %	1,241 %	17,606 %	0,000 %	17,606 %	40,8 s	2,0 s	10,1 s	593,0 s
pozorovatel 6	0,005 %	0,866 %	0,872 %	5,733 %	0,038 %	5,772 %	51,5 s	2,0 s	11,1 s	593,0 s
pozorovatel 7	0,011 %	0,284 %	0,294 %	17,606 %	0,000 %	17,606 %	53,2 s	2,0 s	9,3 s	593,0 s
pozorovatel 8	0,008 %	0,348 %	0,355 %	0,085 %	17,719 %	17,804 %	41,2 s	2,0 s	8,9 s	593,0 s
pozorovatel 9	0,009 %	0,320 %	0,328 %	0,905 %	0,246 %	1,152 %	39,2 s	2,0 s	8,4 s	593,0 s
pozorovatel 10	0,007 %	0,996 %	1,003 %	17,606 %	0,000 %	17,606 %	33,9 s	2,0 s	9,2 s	593,0 s
pozorovatel 11	0,011 %	0,312 %	0,323 %	2,003 %	0,185 %	2,188 %	35,7 s	2,0 s	8,0 s	593,0 s
pozorovatel 12	0,005 %	1,481 %	1,486 %	0,892 %	0,153 %	1,045 %	28,7 s	2,0 s	10,0 s	593,0 s
průměr	0,015 %	0,820 %	0,835 %	8,617 %	1,572 %	10,188 %	40,7 s	2,0 s	8,9 s	593,0 s
s p. podm.	-	-	-	0,052 %	0,211 %	0,264 %	-	24,0 s	107,3 s	593,0 s
bez p. podm.	-	-	-	1,605 %	0,168 %	1,773 %	-	24,0 s	107,3 s	593,0 s

Tabulka 6.7: Výsledky experimentů pro Sadu 1, obrázek 7.

6.3.9 Sada 1, obrázek 8

Výsledek automatické segmentace pro vypočítané pevné podmínky byl silně přesegmentovaný. Výsledek segmentace bez pevných podmínek je velmi přesný. Problémovou částí u ruční segmentace byla stejně jako u předchozího experimentu se stejným míčem oblast se stínem splývající s barvou míče v dolní části obrázku. Oba výsledky automatických segmentací založených na datech od více pozorovatelů našly hledané popředí. Výsledek metody s výpočtem p.p. byl přibližně srovnatelný s většinou výsledků založených na datech jednoho pozorovatele. Metoda bez p.p. však měla celkovou chybu výrazně menší než průměrná segmentace z dat z eye trackeru i než průměrná ruční segmentace a to o 0,445%. S výsledkem 0,262% se blížila k nejlepším ručním segmentacím.




	RS podseg.	RS přeseğ.	c. chyba	ET podseg.	ET přeseğ.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,048 %	0,847 %	0,896 %	1,020 %	0,089 %	1,108 %	24,2 s	2,0 s	8,8 s	827,0 s
pozorovatel 2	0,049 %	1,715 %	1,764 %	10,549 %	0,000 %	10,549 %	55,4 s	2,0 s	6,9 s	827,0 s
pozorovatel 3	0,149 %	0,395 %	0,544 %	0,708 %	0,158 %	0,866 %	9,0 s	2,0 s	7,7 s	827,0 s
pozorovatel 4	0,071 %	0,484 %	0,555 %	2,565 %	0,052 %	2,617 %	65,2 s	2,0 s	8,9 s	827,0 s
pozorovatel 5	0,037 %	1,974 %	2,010 %	10,549 %	0,000 %	10,549 %	54,6 s	2,0 s	10,1 s	827,0 s
pozorovatel 6	0,059 %	0,656 %	0,715 %	1,690 %	0,058 %	1,749 %	6,2 s	2,0 s	11,1 s	827,0 s
pozorovatel 7	0,143 %	0,034 %	0,177 %	10,549 %	0,000 %	10,549 %	81,8 s	2,0 s	9,3 s	827,0 s
pozorovatel 8	0,057 %	0,565 %	0,622 %	0,120 %	0,254 %	0,374 %	32,0 s	2,0 s	8,9 s	827,0 s
pozorovatel 9	0,163 %	0,031 %	0,195 %	0,086 %	48,681 %	48,768 %	8,9 s	2,0 s	8,4 s	827,0 s
pozorovatel 10	0,111 %	0,044 %	0,155 %	10,549 %	0,000 %	10,549 %	30,3 s	2,0 s	9,2 s	827,0 s
pozorovatel 11	0,125 %	0,034 %	0,159 %	0,222 %	1,453 %	1,675 %	5,0 s	2,0 s	8,0 s	827,0 s
pozorovatel 12	0,057 %	0,636 %	0,693 %	10,542 %	0,000 %	10,542 %	23,2 s	2,0 s	10,0 s	827,0 s
průměr	0,089 %	0,618 %	0,707 %	4,929 %	4,229 %	9,158 %	33,0 s	2,0 s	8,9 s	827,0 s
s p. podm.	-	-	-	0,011 %	9,176 %	9,186 %	-	24,0 s	107,3 s	827,0 s
bez p. podm.	-	-	-	0,123 %	0,139 %	0,262 %	-	24,0 s	107,3 s	827,0 s

Tabulka 6.8: Výsledky experimentů pro Sada 1, obrázek 8.

6.3.10 Sada 1, obrázek 9

Výsledek automatické segmentace pro vypočítané pevné podmínky podsegmentovaný i přesegmentovaný. Výsledek experimentu bez pevných podmínek je velmi přesný. Problémovou částí u ruční segmentace byla podobně jako u dalších obrázků v této kategorii oblast stínu míče. Oba výsledky automatických segmentací založených na datech od více pozorovatelů našly hledané popředí. I když metoda s vypočítanými p.p. jen částečně. Metoda bez p.p. však měla celkovou chybu výrazně srovnatelnou s průměrným výsledkem ručního zadávání. Celkové chyby se lišily jen o 0,086%. Obě metody pracující s daty všech pozorovatelů výrazně zlepšily výsledky oproti datům pouze od jednoho pozorovatele.



(a) ground truth.

(b) aut. seg. s p. podm.

(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,028 %	1,254 %	1,281 %	10,223 %	0,446 %	10,668 %	26,3 s	2,0 s	8,8 s	655,0 s
pozorovatel 2	0,031 %	1,273 %	1,304 %	26,608 %	0,000 %	26,608 %	49,1 s	2,0 s	6,9 s	655,0 s
pozorovatel 3	0,016 %	0,696 %	0,712 %	11,058 %	0,045 %	11,103 %	11,1 s	2,0 s	7,7 s	655,0 s
pozorovatel 4	0,024 %	1,167 %	1,190 %	5,376 %	0,097 %	5,473 %	119,6 s	2,0 s	8,9 s	655,0 s
pozorovatel 5	0,025 %	0,759 %	0,785 %	26,608 %	0,000 %	26,608 %	50,0 s	2,0 s	10,1 s	655,0 s
pozorovatel 6	0,039 %	0,429 %	0,468 %	9,602 %	0,420 %	10,021 %	61,6 s	2,0 s	11,1 s	655,0 s
pozorovatel 7	0,109 %	0,206 %	0,315 %	26,608 %	0,000 %	26,608 %	88,7 s	2,0 s	9,3 s	655,0 s
pozorovatel 8	0,040 %	0,569 %	0,609 %	26,605 %	0,000 %	26,605 %	49,4 s	2,0 s	8,9 s	655,0 s
pozorovatel 9	0,116 %	0,217 %	0,333 %	3,905 %	6,205 %	10,110 %	10,2 s	2,0 s	8,4 s	655,0 s
pozorovatel 10	0,038 %	0,773 %	0,811 %	26,608 %	0,000 %	26,608 %	32,3 s	2,0 s	9,2 s	655,0 s
pozorovatel 11	0,050 %	0,268 %	0,318 %	4,755 %	0,091 %	4,846 %	64,8 s	2,0 s	8,0 s	655,0 s
pozorovatel 12	0,206 %	0,221 %	0,427 %	5,776 %	0,080 %	5,856 %	27,0 s	2,0 s	10,0 s	655,0 s
průměr	0,060 %	0,653 %	0,713 %	15,311 %	0,615 %	15,926 %	49,2 s	2,0 s	8,9 s	655,0 s
s p. podm.	-	-	-	3,259 %	3,239 %	6,498 %	-	24,0 s	107,3 s	655,0 s
bez p. podm.	-	-	-	0,638 %	0,161 %	0,799 %	-	24,0 s	107,3 s	655,0 s

Tabulka 6.9: Výsledky experimentů pro Sada 1, obrázek 9.

6.3.11 Sada 2, obrázek 1

Výsledek automatické segmentace pro vypočítané p.p. je mírně přesegmentovaný. Její celková chyba je blízko průměrným výsledkům ručního vyznačení p.p. a je asi jen o 0,120% plochy za průměrným výsledkem. Výsledek segmentace bez p.p. je mírně přesegmentovaný a zároveň podsegmentovaný. Obě metody našly hledaný objekt. Problémovou částí u ruční segmentace byla část přistávací dráhy dotýkající se podvozku letadla. U automatických metod navíc podobně barevné části mimo popředí. Metody s daty všech pozorovatelů jsou výrazně přesnější než experimenty využívající data jen od jednoho z pozorovatelů. Je třeba si povšimnout, že oproti první sadě se zvedla složitost objektu, což se promítlo nejen na zhoršení výsledků všech segmentací, ale také na času, který pozorovatelé potřebovali k ručnímu zadání p.p.



(a) ground truth.

(b) aut. seg. s p. podm.

(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,189 %	1,041 %	1,230 %	10,939 %	14,810 %	25,749 %	63,3 s	2,0 s	9,1 s	1 863,0 s
pozorovatel 2	0,208 %	1,135 %	1,343 %	14,830 %	44,835 %	59,665 %	39,4 s	2,0 s	5,8 s	1 863,0 s
pozorovatel 3	0,164 %	1,163 %	1,326 %	0,221 %	1,852 %	2,074 %	40,1 s	2,0 s	7,4 s	1 863,0 s
pozorovatel 4	0,111 %	5,205 %	5,316 %	0,340 %	17,794 %	18,134 %	77,4 s	2,0 s	9,2 s	1 863,0 s
pozorovatel 5	0,058 %	4,450 %	4,508 %	5,594 %	1,575 %	7,169 %	53,0 s	2,0 s	9,5 s	1 863,0 s
pozorovatel 6	0,192 %	1,072 %	1,264 %	13,064 %	45,596 %	58,660 %	64,1 s	2,0 s	12,0 s	1 863,0 s
pozorovatel 7	0,115 %	0,535 %	0,650 %	0,807 %	1,232 %	2,039 %	120,3 s	2,0 s	9,7 s	1 863,0 s
pozorovatel 8	0,150 %	1,864 %	2,014 %	0,067 %	12,644 %	12,711 %	138,7 s	2,0 s	7,5 s	1 863,0 s
pozorovatel 9	0,148 %	3,672 %	3,820 %	0,491 %	38,701 %	39,192 %	30,9 s	2,0 s	9,1 s	1 863,0 s
pozorovatel 10	0,185 %	1,054 %	1,238 %	14,843 %	43,588 %	58,431 %	74,1 s	2,0 s	9,9 s	1 863,0 s
pozorovatel 11	0,226 %	0,535 %	0,760 %	13,016 %	40,588 %	53,604 %	42,6 s	2,0 s	7,0 s	1 863,0 s
pozorovatel 12	0,111 %	4,263 %	4,374 %	7,998 %	3,314 %	11,312 %	53,8 s	2,0 s	8,9 s	1 863,0 s
průměr	0,155 %	2,166 %	2,320 %	6,851 %	22,211 %	29,062 %	66,5 s	2,0 s	8,8 s	1 863,0 s
s p. podm.	-	-	-	0,136 %	2,311 %	2,447 %	-	24,0 s	105,1 s	1 863,0 s
bez p. podm.	-	-	-	6,000 %	2,509 %	8,510 %	-	24,0 s	105,1 s	1 863,0 s

Tabulka 6.10: Výsledky experimentů pro Sadu 2, obrázek 1.

6.3.12 Sada 2, obrázek 2

Výsledek automatické segmentace pro vypočítané p.p. je silně přesegmentovaný a mírně podsegmentovaný. Její celková chyba je vyšší než průměrný výsledek experimentů jednotlivců a mnohem vyšší než ručního vyznačení p.p. Výsledek segmentace bez p.p. je mírně přesegmentovaný a zároveň mírně podsegmentovaný. Obě metody však našly hledaný objekt. Problémovou částí u ruční segmentace byla u některých pozorovatelů část oblohy nad letadlem a přední část letadla. U automatickým metod navíc komplikovaly segmentaci podobně barevné části mimo popředí v dolní části fotografie. Metoda bez výpočtu p.p. byla výrazně přesnější než většina experimentů s daty jednoho pozorovatele. V průměru byla celková chyba vyšší o 1,393%. Lepšího výsledku dosáhli jen tři pozorovatelé.



(a) ground truth.

(b) aut. seg. s p. podm.

(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseğ.	c. chyba	ET podseg.	ET přeseğ.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,618 %	3,641 %	4,259 %	1,249 %	14,917 %	16,166 %	51,6 s	2,0 s	9,1 s	1 632,0 s
pozorovatel 2	0,996 %	0,067 %	1,063 %	7,243 %	27,533 %	34,776 %	28,7 s	2,0 s	5,8 s	1 632,0 s
pozorovatel 3	0,650 %	0,089 %	0,739 %	2,025 %	10,500 %	12,525 %	25,9 s	2,0 s	7,4 s	1 632,0 s
pozorovatel 4	0,664 %	6,889 %	7,553 %	5,292 %	20,870 %	26,162 %	66,8 s	2,0 s	9,2 s	1 632,0 s
pozorovatel 5	0,884 %	7,211 %	8,096 %	0,410 %	47,679 %	48,089 %	31,2 s	2,0 s	9,5 s	1 632,0 s
pozorovatel 6	0,842 %	0,083 %	0,925 %	10,992 %	30,687 %	41,678 %	54,2 s	2,0 s	12,0 s	1 632,0 s
pozorovatel 7	0,540 %	0,081 %	0,621 %	5,568 %	33,040 %	38,608 %	60,5 s	2,0 s	9,7 s	1 632,0 s
pozorovatel 8	1,203 %	0,081 %	1,284 %	0,933 %	0,686 %	1,618 %	165,3 s	2,0 s	7,5 s	1 632,0 s
pozorovatel 9	1,290 %	0,074 %	1,364 %	4,852 %	19,546 %	24,398 %	36,8 s	2,0 s	9,1 s	1 632,0 s
pozorovatel 10	0,477 %	0,104 %	0,581 %	6,457 %	25,316 %	31,774 %	61,6 s	2,0 s	9,9 s	1 632,0 s
pozorovatel 11	0,731 %	0,087 %	0,818 %	0,828 %	0,917 %	1,744 %	18,5 s	2,0 s	7,0 s	1 632,0 s
pozorovatel 12	0,763 %	0,085 %	0,847 %	0,505 %	0,295 %	0,800 %	33,0 s	2,0 s	8,9 s	1 632,0 s
průměr	0,805 %	1,541 %	2,346 %	3,863 %	19,332 %	23,195 %	52,8 s	2,0 s	8,8 s	1 632,0 s
s p. podm.	-	-	-	2,289 %	32,930 %	35,220 %	-	24,0 s	105,1 s	1 632,0 s
bez p. podm.	-	-	-	1,171 %	2,568 %	3,739 %	-	24,0 s	105,1 s	1 632,0 s

Tabulka 6.11: Výsledky experimentů pro Sadu 2, obrázek 2.

6.3.13 Sada 2, obrázek 3

Výsledky obou automatických segmentací jsou přesegmentované. Výsledek metody bez vypočtených p.p. však výrazně méně. Obě metody úspěšně našly hledané popředí fotografie. Problémových částí u ruční segmentace byla celá řada. Obloha kolem vrtule, kabiny a částečně i kolem křídel, část travnaté plochy u podvozku letounu, popřípadě i davy lidí a části letadel v pozadí. U některých pozorovatelů se také vyskytovala chyba v podegmentování proskleného kokpitu. Automatická metoda bez p.p. byla výrazně přesnější než většina experimentů s daty jednoho pozorovatele. Lepšího výsledku dosáhl jen jediný pozorovatel a tento výsledek byl s automatickou metodou téměř srovnatelný, lepší pouze o 0,057%. Oproti průměru ručních segmentací byla chyba o 0,960% vyšší. Nepřehlédnutelným faktem je, že průměrný čas strávený jedním uživatelem na tvorbě p.p. (135,9 vteřiny) byl vyšší než součet všech dvanácti časů při použití zařízení na sledování pohybu očí včetně kalibrace (105,1 vteřiny). Toto je jediná fotografie ze všech tří sad, kde taková situace nastala.



(a) ground truth.

(b) aut. seg. s p. podm.

(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,155 %	2,726 %	2,882 %	1,111 %	23,581 %	24,692 %	188,3 s	2,0 s	9,1 s	2 030,0 s
pozorovatel 2	0,121 %	5,981 %	6,102 %	0,517 %	15,276 %	15,794 %	49,3 s	2,0 s	5,8 s	2 030,0 s
pozorovatel 3	0,217 %	3,532 %	3,749 %	0,419 %	5,603 %	6,022 %	83,5 s	2,0 s	7,4 s	2 030,0 s
pozorovatel 4	0,122 %	19,721 %	19,843 %	17,848 %	2,210 %	20,058 %	154,9 s	2,0 s	9,2 s	2 030,0 s
pozorovatel 5	0,144 %	2,625 %	2,770 %	0,455 %	18,845 %	19,301 %	73,0 s	2,0 s	9,5 s	2 030,0 s
pozorovatel 6	0,135 %	3,574 %	3,709 %	0,996 %	14,428 %	15,424 %	155,6 s	2,0 s	12,0 s	2 030,0 s
pozorovatel 7	0,139 %	3,662 %	3,801 %	0,405 %	7,386 %	7,791 %	218,2 s	2,0 s	9,7 s	2 030,0 s
pozorovatel 8	0,132 %	4,317 %	4,448 %	1,923 %	14,383 %	16,306 %	347,9 s	2,0 s	7,5 s	2 030,0 s
pozorovatel 9	0,297 %	3,607 %	3,903 %	4,659 %	2,044 %	6,703 %	64,0 s	2,0 s	9,1 s	2 030,0 s
pozorovatel 10	0,157 %	3,634 %	3,791 %	0,323 %	9,606 %	9,929 %	104,5 s	2,0 s	9,9 s	2 030,0 s
pozorovatel 11	0,149 %	2,394 %	2,544 %	0,942 %	6,873 %	7,815 %	132,8 s	2,0 s	7,0 s	2 030,0 s
pozorovatel 12	0,108 %	3,781 %	3,888 %	0,736 %	7,854 %	8,590 %	58,4 s	2,0 s	8,9 s	2 030,0 s
průměr	0,156 %	4,963 %	5,119 %	2,528 %	10,674 %	13,202 %	135,9 s	2,0 s	8,8 s	2 030,0 s
s p. podm.	-	-	-	0,084 %	16,859 %	16,943 %	-	24,0 s	105,1 s	2 030,0 s
bez p. podm.	-	-	-	0,132 %	5,946 %	6,079 %	-	24,0 s	105,1 s	2 030,0 s

Tabulka 6.12: Výsledky experimentů pro Sadu 2, obrázek 3.

6.3.14 Sada 2, obrázek 4

Výsledek automatické segmentace pro vypočítané p.p. byl velmi přesný. Výsledek segmentace bez p.p. je podsegmentovaný. Ve vybrané oblasti chybí barevné části letadla. Problémové oblasti z ruční segmentace byly v podstatě zanedbatelné. O tom vypovídá i velmi nízká průměrná celková chyba 0,518%. Oba výsledky automatických segmentací založených na datech od více pozorovatelů měly dobré výstupy, především však metoda s vypočtenými p.p. Její celková chyba dosahuje jen 0,911% plochy, což je méně než jakákoliv segmentace vytvořená na základě dat jednotlivců z eye trackeru. Chyba byla vyšší jen o 0,393% než průměrná ruční segmentace. I zde byly automatické metody úspěšnější, pokud využívaly data od všech pozorovatelů.



(a) ground truth.

(b) aut. seg. s p. podm.


(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,235 %	0,229 %	0,464 %	4,354 %	0,289 %	4,642 %	124,6 s	2,0 s	9,1 s	981,0 s
pozorovatel 2	0,257 %	0,311 %	0,568 %	1,852 %	0,326 %	2,178 %	38,1 s	2,0 s	5,8 s	981,0 s
pozorovatel 3	0,226 %	0,300 %	0,525 %	4,624 %	0,318 %	4,942 %	32,2 s	2,0 s	7,4 s	981,0 s
pozorovatel 4	0,250 %	0,233 %	0,483 %	4,733 %	0,221 %	4,954 %	115,4 s	2,0 s	9,2 s	981,0 s
pozorovatel 5	0,251 %	0,255 %	0,506 %	2,548 %	12,156 %	14,704 %	84,1 s	2,0 s	9,5 s	981,0 s
pozorovatel 6	0,251 %	0,292 %	0,544 %	10,573 %	27,656 %	38,229 %	59,7 s	2,0 s	12,0 s	981,0 s
pozorovatel 7	0,279 %	0,211 %	0,490 %	1,365 %	0,312 %	1,677 %	147,8 s	2,0 s	9,7 s	981,0 s
pozorovatel 8	0,263 %	0,325 %	0,587 %	2,314 %	0,435 %	2,750 %	239,3 s	2,0 s	7,5 s	981,0 s
pozorovatel 9	0,279 %	0,215 %	0,494 %	3,502 %	0,411 %	3,913 %	28,2 s	2,0 s	9,1 s	981,0 s
pozorovatel 10	0,261 %	0,314 %	0,576 %	0,444 %	0,709 %	1,153 %	67,1 s	2,0 s	9,9 s	981,0 s
pozorovatel 11	0,258 %	0,212 %	0,470 %	2,205 %	0,419 %	2,624 %	47,7 s	2,0 s	7,0 s	981,0 s
pozorovatel 12	0,203 %	0,306 %	0,509 %	3,923 %	10,815 %	14,738 %	55,4 s	2,0 s	8,9 s	981,0 s
průměr	0,251 %	0,267 %	0,518 %	3,537 %	4,505 %	8,042 %	86,6 s	2,0 s	8,8 s	981,0 s
s p. podm.	-	-	-	0,359 %	0,552 %	0,911 %	-	24,0 s	105,1 s	981,0 s
bez p. podm.	-	-	-	4,549 %	0,334 %	4,883 %	-	24,0 s	105,1 s	981,0 s

Tabulka 6.13: Výsledky experimentů pro Sadu 2, obrázek 4.

6.3.15 Sada 2, obrázek 5

Oba výsledky automatických segmentací byly velmi dobré. Problémové části ruční segmentace byly zanedbatelné. U automatických metod se jednalo o malou oblast nad středem trupu letounu. Na malý počet kritických oblastí ukazují i nízká čísla u celkových chyb. Ty byly jak pro všechny ruční segmentace tak pro obě metody využívající dat všech 12 pozorovatelů menší než 1%. Výsledky pro jednotlivé pozorovatele u experimentů s eye trackerem už tak uspokojivé nebyly. V polovině případů, tedy v šesti pokusech chyba přesáhla čtvrtinu plochy. Ve 4 případech se dokonce blížila či překročila 40%.



	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,154 %	0,457 %	0,611 %	4,712 %	37,382 %	42,093 %	71,7 s	2,0 s	9,1 s	1 649,0 s
pozorovatel 2	0,165 %	0,237 %	0,401 %	0,047 %	31,766 %	31,813 %	39,4 s	2,0 s	5,8 s	1 649,0 s
pozorovatel 3	0,168 %	0,181 %	0,349 %	0,352 %	0,733 %	1,086 %	25,2 s	2,0 s	7,4 s	1 649,0 s
pozorovatel 4	0,167 %	0,182 %	0,349 %	11,845 %	15,985 %	27,830 %	83,8 s	2,0 s	9,2 s	1 649,0 s
pozorovatel 5	0,215 %	0,164 %	0,379 %	0,196 %	7,524 %	7,719 %	64,9 s	2,0 s	9,5 s	1 649,0 s
pozorovatel 6	0,147 %	0,659 %	0,806 %	13,315 %	25,905 %	39,220 %	67,4 s	2,0 s	12,0 s	1 649,0 s
pozorovatel 7	0,179 %	0,167 %	0,346 %	1,888 %	40,090 %	41,978 %	127,1 s	2,0 s	9,7 s	1 649,0 s
pozorovatel 8	0,206 %	0,193 %	0,398 %	4,964 %	0,102 %	5,066 %	293,4 s	2,0 s	7,5 s	1 649,0 s
pozorovatel 9	0,165 %	0,236 %	0,402 %	0,709 %	0,531 %	1,240 %	20,1 s	2,0 s	9,1 s	1 649,0 s
pozorovatel 10	0,212 %	0,168 %	0,380 %	9,763 %	36,825 %	46,588 %	87,1 s	2,0 s	9,9 s	1 649,0 s
pozorovatel 11	0,174 %	0,166 %	0,340 %	0,525 %	0,294 %	0,819 %	57,2 s	2,0 s	7,0 s	1 649,0 s
pozorovatel 12	0,155 %	0,236 %	0,391 %	1,384 %	2,110 %	3,494 %	51,0 s	2,0 s	8,9 s	1 649,0 s
průměr	0,176 %	0,254 %	0,429 %	4,142 %	16,604 %	20,746 %	82,4 s	2,0 s	8,8 s	1 649,0 s
s p. podm.	-	-	-	0,241 %	0,679 %	0,920 %	-	24,0 s	105,1 s	1 649,0 s
bez p. podm.	-	-	-	0,393 %	0,510 %	0,903 %	-	24,0 s	105,1 s	1 649,0 s

Tabulka 6.14: Výsledky experimentů pro Sadu 2, obrázek 5.

6.3.16 Sada 2, obrázek 6

Výsledek automatické segmentace pro vypočítané p.p. je silně přesegmentovaný. Výsledek segmentace bez p.p. je přesegmentovaný, ale výrazně méně. Problémovou částí u ruční segmentace byly většinou domy nebo části domů pod letadlem, které byly problémové i v automatické segmentaci. Dále problémová mohla být horní část trupu letadla, která splývala s oblohou na pozadí. Oba výsledky automatických segmentací založených na datech od více pozorovatelů našly úspěšně hledaný objekt. Z automatických metod byla přesnější ta bez vypočtených p.p. Byla výrazně lepší než průměr experimentů jednotlivých pozorovatelů, které také trpěly velkou mírou přesegmentování. Oproti průměru ručních metod byla celková chyba o 3,589% vyšší.



(a) ground truth.

(b) aut. seg. s p. podm.


(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseğ.	c. chyba	ET podseg.	ET přeseğ.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,394 %	0,498 %	0,891 %	4,352 %	1,073 %	5,426 %	54,9 s	2,0 s	9,1 s	1 776,0 s
pozorovatel 2	0,372 %	5,351 %	5,723 %	1,361 %	16,974 %	18,336 %	35,3 s	2,0 s	5,8 s	1 776,0 s
pozorovatel 3	0,399 %	0,485 %	0,884 %	1,426 %	28,840 %	30,267 %	36,2 s	2,0 s	7,4 s	1 776,0 s
pozorovatel 4	0,371 %	9,119 %	9,490 %	11,258 %	24,093 %	35,351 %	90,6 s	2,0 s	9,2 s	1 776,0 s
pozorovatel 5	0,479 %	0,452 %	0,931 %	8,568 %	13,021 %	21,589 %	66,7 s	2,0 s	9,5 s	1 776,0 s
pozorovatel 6	0,369 %	6,027 %	6,396 %	14,306 %	29,734 %	44,039 %	86,4 s	2,0 s	12,0 s	1 776,0 s
pozorovatel 7	0,393 %	0,408 %	0,801 %	1,711 %	18,854 %	20,565 %	132,8 s	2,0 s	9,7 s	1 776,0 s
pozorovatel 8	0,454 %	7,879 %	8,333 %	2,049 %	4,562 %	6,611 %	190,0 s	2,0 s	7,5 s	1 776,0 s
pozorovatel 9	0,503 %	0,470 %	0,973 %	2,797 %	4,122 %	6,918 %	34,7 s	2,0 s	9,1 s	1 776,0 s
pozorovatel 10	0,402 %	0,514 %	0,916 %	8,608 %	12,688 %	21,296 %	80,7 s	2,0 s	9,9 s	1 776,0 s
pozorovatel 11	0,124 %	0,443 %	0,567 %	0,967 %	2,629 %	3,596 %	46,4 s	2,0 s	7,0 s	1 776,0 s
pozorovatel 12	0,469 %	0,533 %	1,002 %	1,635 %	2,110 %	3,745 %	50,1 s	2,0 s	8,9 s	1 776,0 s
průměr	0,394 %	2,682 %	3,076 %	4,920 %	13,225 %	18,145 %	75,4 s	2,0 s	8,8 s	1 776,0 s
s p. podm.	-	-	-	2,048 %	19,284 %	21,332 %	-	24,0 s	105,1 s	1 776,0 s
bez p. podm.	-	-	-	1,305 %	5,360 %	6,665 %	-	24,0 s	105,1 s	1 776,0 s

Tabulka 6.15: Výsledky experimentů pro Sadu 2, obrázek 6.

6.3.17 Sada 2, obrázek 7

Výsledek automatické segmentace pro vypočítané p.p. byl silně přesegmentovaný. Výsledek segmentace bez p.p. je velmi přesný. Problémovou částí u ruční segmentace byly oblasti pozadí mezi křídly, motory a mezi koly. U automatické segmentace navíc oblast pozadí nad letadlem. Obě metody využívající automatických segmentací založených na datech od více pozorovatelů našly hledaný objekt. Výsledek metody bez výpočtu p.p. byl přibližně srovnatelný s většinou výsledků založených na ručním zadání p.p. Oproti průměru je dokonce lepší. Je však zkreslený výsledkem pozorovatele č. 2, který měl celkovou chybu 5,90% plochy. Metoda bez p.p. však měla celkovou chybu výrazně menší než průměrná segmentace z dat z eye trackeru. V experimentech s daty jednotlivců měli dva pozorovatelé lepší výsledek.




	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,121 %	1,465 %	1,586 %	10,714 %	5,376 %	16,090 %	57,8 s	2,0 s	9,1 s	2 168,0 s
pozorovatel 2	0,085 %	5,306 %	5,390 %	0,299 %	0,982 %	1,281 %	39,0 s	2,0 s	5,8 s	2 168,0 s
pozorovatel 3	0,138 %	0,907 %	1,045 %	2,031 %	30,036 %	32,067 %	30,4 s	2,0 s	7,4 s	2 168,0 s
pozorovatel 4	0,136 %	0,883 %	1,019 %	0,473 %	0,510 %	0,983 %	82,1 s	2,0 s	9,2 s	2 168,0 s
pozorovatel 5	0,118 %	1,688 %	1,806 %	0,212 %	43,511 %	43,722 %	44,0 s	2,0 s	9,5 s	2 168,0 s
pozorovatel 6	0,133 %	0,950 %	1,084 %	1,567 %	20,566 %	22,133 %	82,7 s	2,0 s	12,0 s	2 168,0 s
pozorovatel 7	0,151 %	0,601 %	0,753 %	1,730 %	21,393 %	23,124 %	89,2 s	2,0 s	9,7 s	2 168,0 s
pozorovatel 8	0,144 %	0,622 %	0,766 %	1,203 %	0,437 %	1,640 %	343,0 s	2,0 s	7,5 s	2 168,0 s
pozorovatel 9	0,151 %	0,602 %	0,753 %	2,869 %	0,393 %	3,262 %	34,4 s	2,0 s	9,1 s	2 168,0 s
pozorovatel 10	0,149 %	0,965 %	1,114 %	2,008 %	28,285 %	30,293 %	82,1 s	2,0 s	9,9 s	2 168,0 s
pozorovatel 11	0,153 %	0,603 %	0,756 %	0,817 %	24,206 %	25,023 %	76,1 s	2,0 s	7,0 s	2 168,0 s
pozorovatel 12	0,136 %	0,868 %	1,004 %	0,341 %	0,520 %	0,862 %	51,0 s	2,0 s	8,9 s	2 168,0 s
průměr	0,135 %	1,288 %	1,423 %	2,022 %	14,685 %	16,707 %	84,3 s	2,0 s	8,8 s	2 168,0 s
s p. podm.	-	-	-	0,229 %	23,010 %	23,239 %	-	24,0 s	105,1 s	2 168,0 s
bez p. podm.	-	-	-	0,316 %	0,831 %	1,147 %	-	24,0 s	105,1 s	2 168,0 s

Tabulka 6.16: Výsledky experimentů pro Sadu 2, obrázek 7.

6.3.18 Sada 2, obrázek 8

Výsledek automatické segmentace pro vypočítané p. p. byl silně přesegmentovaný a podsegmentovaný. Výsledek segmentace bez p.p. je mírně přesegmentovaný a mírně podsegmentovaný. Jedinou problémovou částí u ruční segmentace byla část nebe mezi pravým křídlem a motorem letadla, která sousedí se sklem kabiny. Skleněná plocha a obloha mají v této části velmi podobný odstín. U automatické segmentace navíc problémy dělala podhledová část křídel a kormidla. Obě metody využívající automatických segmentací založených na datech od více pozorovatelů našly hledaný objekt. Výsledky ručních segmentací byly velmi dobré a jejich chyba se až na dvě výjimky pohybovala mírně přes 0,3%. U dvou pozorovatelů došlo k velké chybě přesegmentování. Stejný problém měla i metoda s daty všech pozorovatelů. Oproti průměru ručních metod byla celková chyba o 1,481% vyšší.




	RS podseg.	RS přeseg.	c. chyba	ET podseg.	ET přeseg.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,053 %	0,327 %	0,380 %	1,645 %	0,436 %	2,082 %	88,4 s	2,0 s	9,1 s	1 378,0 s
pozorovatel 2	0,054 %	0,309 %	0,363 %	6,274 %	36,461 %	42,735 %	24,2 s	2,0 s	5,8 s	1 378,0 s
pozorovatel 3	0,054 %	0,309 %	0,363 %	2,003 %	0,238 %	2,241 %	29,9 s	2,0 s	7,4 s	1 378,0 s
pozorovatel 4	0,038 %	9,296 %	9,334 %	0,053 %	2,434 %	2,487 %	67,7 s	2,0 s	9,2 s	1 378,0 s
pozorovatel 5	0,050 %	0,339 %	0,390 %	6,635 %	47,842 %	54,477 %	42,2 s	2,0 s	9,5 s	1 378,0 s
pozorovatel 6	0,042 %	5,543 %	5,585 %	7,065 %	23,668 %	30,733 %	41,5 s	2,0 s	12,0 s	1 378,0 s
pozorovatel 7	0,053 %	0,312 %	0,364 %	3,275 %	41,778 %	45,053 %	96,1 s	2,0 s	9,7 s	1 378,0 s
pozorovatel 8	0,054 %	0,306 %	0,360 %	0,724 %	0,253 %	0,976 %	134,6 s	2,0 s	7,5 s	1 378,0 s
pozorovatel 9	0,085 %	0,231 %	0,316 %	5,007 %	33,031 %	38,038 %	37,1 s	2,0 s	9,1 s	1 378,0 s
pozorovatel 10	0,053 %	0,322 %	0,375 %	3,538 %	13,392 %	16,930 %	58,9 s	2,0 s	9,9 s	1 378,0 s
pozorovatel 11	0,072 %	0,237 %	0,308 %	3,057 %	42,413 %	45,470 %	34,1 s	2,0 s	7,0 s	1 378,0 s
pozorovatel 12	0,052 %	0,321 %	0,373 %	3,789 %	0,040 %	3,829 %	42,2 s	2,0 s	8,9 s	1 378,0 s
průměr	0,055 %	1,488 %	1,543 %	3,589 %	20,165 %	23,754 %	58,1 s	2,0 s	8,8 s	1 378,0 s
s p. podm.	-	-	-	2,624 %	46,018 %	48,642 %	-	24,0 s	105,1 s	1 378,0 s
bez p. podm.	-	-	-	1,925 %	1,099 %	3,024 %	-	24,0 s	105,1 s	1 378,0 s

Tabulka 6.17: Výsledky experimentů pro Sadu 2, obrázek 8.

6.3.19 Sada 2, obrázek 9

U poslední fotografie v druhé sadě je výsledek automatické segmentace pro vypočítané pevné podmínky silně přesegmentovaný, výsledek segmentace bez pevných podmínek je jen mírně přesegmentovaný. Problémovou částí u ruční segmentace byla oblast mezi křídlem a ocasem letounu a také značení silnice v úrovni nad letadlem. Oba výsledky automatických segmentací založených na datech od více pozorovatelů našly hledaný objekt. Metoda bez pevných podmínek byla úspěšná, bohužel vyznačila jako popředí další části fotografie v odpovídajících odstínech, jako je značení přistávací plochy nebo stín letadla na ranveji. Byla přesnější než experimenty průměr jednotlivců s použitím eye trackeru. Za zmínku stojí velice nízká podsegmentovanost v případě ručně zadávaných p.p., která byla v průměru jen 0,055% a vůbec nepřesáhla hodnotu 0,072% plochy.

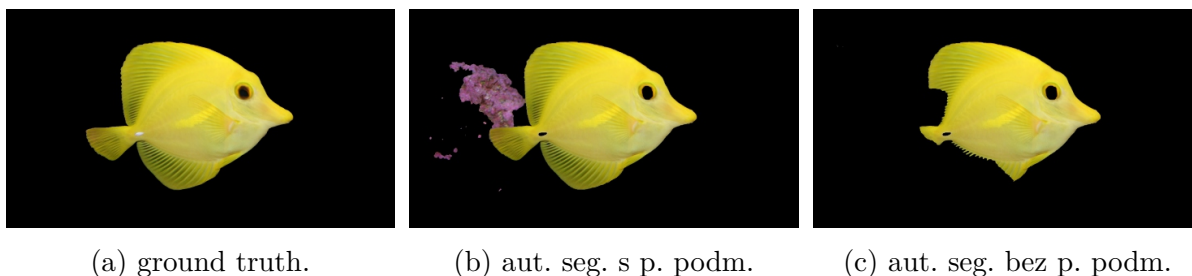


	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,164 %	0,296 %	0,460 %	1,298 %	32,400 %	33,697 %	72,0 s	2,0 s	9,1 s	1 421,0 s
pozorovatel 2	0,124 %	1,748 %	1,872 %	5,524 %	0,000 %	5,524 %	37,1 s	2,0 s	5,8 s	1 421,0 s
pozorovatel 3	0,152 %	0,303 %	0,455 %	0,438 %	20,489 %	20,927 %	16,7 s	2,0 s	7,4 s	1 421,0 s
pozorovatel 4	0,126 %	6,188 %	6,314 %	0,511 %	0,745 %	1,255 %	59,1 s	2,0 s	9,2 s	1 421,0 s
pozorovatel 5	0,142 %	0,314 %	0,456 %	0,099 %	22,699 %	22,798 %	35,6 s	2,0 s	9,5 s	1 421,0 s
pozorovatel 6	0,193 %	0,178 %	0,370 %	2,606 %	15,328 %	17,934 %	48,5 s	2,0 s	12,0 s	1 421,0 s
pozorovatel 7	0,153 %	0,197 %	0,350 %	0,234 %	0,745 %	0,979 %	94,5 s	2,0 s	9,7 s	1 421,0 s
pozorovatel 8	0,120 %	3,013 %	3,133 %	0,185 %	20,372 %	20,556 %	126,5 s	2,0 s	7,5 s	1 421,0 s
pozorovatel 9	0,145 %	0,322 %	0,467 %	0,859 %	2,427 %	3,286 %	63,1 s	2,0 s	9,1 s	1 421,0 s
pozorovatel 10	0,178 %	0,301 %	0,479 %	5,524 %	0,000 %	5,524 %	61,0 s	2,0 s	9,9 s	1 421,0 s
pozorovatel 11	0,141 %	0,319 %	0,459 %	1,342 %	35,722 %	37,064 %	63,7 s	2,0 s	7,0 s	1 421,0 s
pozorovatel 12	0,156 %	0,451 %	0,607 %	0,069 %	19,769 %	19,839 %	98,3 s	2,0 s	8,9 s	1 421,0 s
průměr	0,150 %	1,136 %	1,285 %	1,557 %	14,225 %	15,782 %	64,7 s	2,0 s	8,8 s	1 421,0 s
s p. podm.	-	-	-	0,062 %	20,355 %	20,417 %	-	24,0 s	105,1 s	1 421,0 s
bez p. podm.	-	-	-	0,458 %	4,867 %	5,325 %	-	24,0 s	105,1 s	1 421,0 s

Tabulka 6.18: Výsledky experimentů pro Sadu 2, obrázek 9.

6.3.20 Sada 3, obrázek 1

Výsledek automatické segmentace s vypočítanými p.p. je přesegmentovaný. Výsledek segmentace s volněji p.p. je naopak podsegmentovaný. Problémovou částí u ruční segmentace byla tmavší části ploutví, popřípadě bílá značka mezi tělem a ocasní ploutví, obecně zde ruční segmentace dopadla velmi dobře s průměrnou celkovou chybou jenom 0,456%. Obě metody se chybovostí blížily k řádově vyššímu výsledku chybovosti okolo 4%.



	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,062 %	0,155 %	0,216 %	7,639 %	0,080 %	7,720 %	27,3 s	2,0 s	7,9 s	1 465,0 s
pozorovatel 2	0,048 %	1,643 %	1,691 %	7,102 %	3,786 %	10,888 %	41,8 s	2,0 s	5,9 s	1 465,0 s
pozorovatel 3	0,203 %	0,180 %	0,383 %	4,594 %	0,109 %	4,703 %	22,7 s	2,0 s	8,1 s	1 465,0 s
pozorovatel 4	0,080 %	0,160 %	0,239 %	4,801 %	0,117 %	4,918 %	110,1 s	2,0 s	8,3 s	1 465,0 s
pozorovatel 5	0,082 %	0,156 %	0,238 %	17,613 %	16,809 %	34,422 %	72,0 s	2,0 s	9,0 s	1 465,0 s
pozorovatel 6	0,082 %	0,157 %	0,239 %	21,156 %	19,112 %	40,267 %	35,9 s	2,0 s	9,8 s	1 465,0 s
pozorovatel 7	0,066 %	0,146 %	0,212 %	4,136 %	0,221 %	4,357 %	54,5 s	2,0 s	9,2 s	1 465,0 s
pozorovatel 8	0,198 %	0,164 %	0,362 %	3,108 %	0,135 %	3,244 %	41,5 s	2,0 s	7,6 s	1 465,0 s
pozorovatel 9	0,060 %	0,162 %	0,222 %	0,628 %	0,197 %	0,826 %	20,8 s	2,0 s	9,4 s	1 465,0 s
pozorovatel 10	0,080 %	1,040 %	1,119 %	5,030 %	0,401 %	5,431 %	40,4 s	2,0 s	8,6 s	1 465,0 s
pozorovatel 11	0,166 %	0,156 %	0,322 %	0,637 %	8,021 %	8,658 %	56,3 s	2,0 s	8,0 s	1 465,0 s
pozorovatel 12	0,087 %	0,145 %	0,232 %	21,291 %	0,000 %	21,291 %	29,4 s	2,0 s	9,4 s	1 465,0 s
průměr	0,101 %	0,355 %	0,456 %	8,145 %	4,082 %	12,227 %	46,1 s	2,0 s	8,4 s	1 465,0 s
s p. podm.	-	-	-	0,233 %	3,571 %	3,804 %	-	24,0 s	101,2 s	1 465,0 s
bez p. podm.	-	-	-	3,829 %	0,136 %	3,965 %	-	24,0 s	101,2 s	1 465,0 s

Tabulka 6.19: Výsledky experimentů pro Sada 3, obrázek 1.

6.3.21 Sada 3, obrázek 2

Výsledek automatické segmentace pro vypočítané p.p. byl silně přesegmentovaný a podsegmentovaný. Výsledek segmentace bez p.p. je velmi dobrý. Na tomto obrázku je řada velmi obtížných míst pro automatickou segmentaci. Barva srsti na některých místech splývá s odstíny porostu. Velkým problémem jsou také tmavá místa se stíny. Navíc klokan není na fotografii celý. Problémy byly nejvíce viditelné v okolí končetin a ocasu. Obě metody využívající automatických segmentací založených na datech od více pozorovatelů našly hledaný objekt. I když u metody s vypočtenými p.p. je to sporné, neboť segmentace má velkou celkovou chybu přesahující 60% plochy a tudíž je extrémně nepřesná. Chyba ručních segmentací se pohybovala průměrně kolem 2,608%, což je o 0,387% horší než výsledek metody s volnými p.p. To znamená, že zde tato metoda dosáhla skvělého výsledku. Tato fotografie drží prvenství v nejdělsí tvorbě ground truth data mezi prezentovanými snímky. Důvodem je velmi členitá kontura klokanu (srsti).



(a) ground truth.

(b) aut. seg. s p. podm.


(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,262 %	1,543 %	1,804 %	7,798 %	0,767 %	8,565 %	82,4 s	2,0 s	7,9 s	3 195,0 s
pozorovatel 2	0,189 %	6,723 %	6,912 %	15,691 %	0,049 %	15,741 %	41,8 s	2,0 s	5,9 s	3 195,0 s
pozorovatel 3	0,230 %	1,428 %	1,658 %	1,367 %	0,513 %	1,880 %	32,1 s	2,0 s	8,1 s	3 195,0 s
pozorovatel 4	0,246 %	3,929 %	4,176 %	4,696 %	0,754 %	5,449 %	117,0 s	2,0 s	8,3 s	3 195,0 s
pozorovatel 5	0,019 %	5,148 %	5,167 %	5,823 %	41,697 %	47,519 %	58,9 s	2,0 s	9,0 s	3 195,0 s
pozorovatel 6	0,327 %	2,971 %	3,298 %	18,414 %	7,450 %	25,865 %	63,2 s	2,0 s	9,8 s	3 195,0 s
pozorovatel 7	0,325 %	0,548 %	0,872 %	10,594 %	0,768 %	11,362 %	106,5 s	2,0 s	9,2 s	3 195,0 s
pozorovatel 8	0,301 %	1,267 %	1,568 %	26,131 %	0,000 %	26,131 %	56,8 s	2,0 s	7,6 s	3 195,0 s
pozorovatel 9	0,304 %	1,082 %	1,386 %	20,471 %	28,498 %	48,970 %	94,5 s	2,0 s	9,4 s	3 195,0 s
pozorovatel 10	0,217 %	1,876 %	2,093 %	6,138 %	10,286 %	16,423 %	90,2 s	2,0 s	8,6 s	3 195,0 s
pozorovatel 11	0,308 %	0,668 %	0,976 %	17,402 %	26,981 %	44,383 %	53,8 s	2,0 s	8,0 s	3 195,0 s
pozorovatel 12	0,334 %	1,056 %	1,389 %	26,135 %	0,000 %	26,135 %	46,4 s	2,0 s	9,4 s	3 195,0 s
průměr	0,255 %	2,353 %	2,608 %	13,388 %	9,814 %	23,202 %	70,3 s	2,0 s	8,4 s	3 195,0 s
s p. podm.	-	-	-	9,308 %	51,895 %	61,203 %	-	24,0 s	101,2 s	3 195,0 s
bez p. podm.	-	-	-	0,795 %	1,426 %	2,221 %	-	24,0 s	101,2 s	3 195,0 s

Tabulka 6.20: Výsledky experimentů pro Sadu 3, obrázek 2.

6.3.22 Sada 3, obrázek 3

Výsledek automatické segmentace pro vypočítané p.p. byl silně přesegmentovaný a mírně podsegmentovaný. Výsledek segmentace bez p.p. je mírně podsegmentovaný. Problematickými místy pro segmentaci byly nohy kosa, především levá (na obrázku vpravo), která se nejen lišila barvou, ale navíc byla od těla oddělená listem trávy. Pokud tedy nebyla řádně označená správnými p.p. obvykle byl výsledek bez ní. Mnohem lepšího výsledku opět dosáhla metoda s volnějším p.p., která byla s celkovou chybou 0,857% jen o 0,262% horší než ruční segmentace.

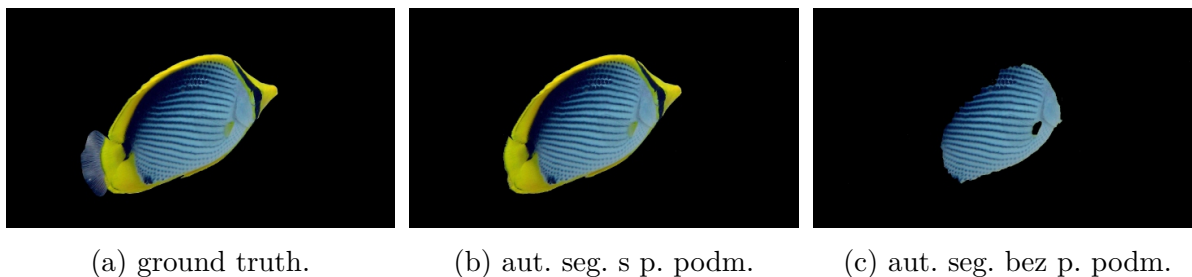


	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,072 %	0,593 %	0,665 %	4,201 %	10,857 %	15,058 %	116,8 s	2,0 s	7,9 s	1 682,0 s
pozorovatel 2	0,081 %	0,779 %	0,861 %	1,936 %	0,178 %	2,114 %	53,3 s	2,0 s	5,9 s	1 682,0 s
pozorovatel 3	0,111 %	0,456 %	0,568 %	1,145 %	0,208 %	1,353 %	17,2 s	2,0 s	8,1 s	1 682,0 s
pozorovatel 4	0,088 %	0,444 %	0,532 %	7,890 %	4,583 %	12,473 %	114,1 s	2,0 s	8,3 s	1 682,0 s
pozorovatel 5	0,147 %	0,434 %	0,581 %	2,566 %	5,919 %	8,485 %	42,4 s	2,0 s	9,0 s	1 682,0 s
pozorovatel 6	0,142 %	0,334 %	0,475 %	19,063 %	17,734 %	36,796 %	44,5 s	2,0 s	9,8 s	1 682,0 s
pozorovatel 7	0,073 %	0,533 %	0,606 %	6,254 %	0,104 %	6,358 %	65,0 s	2,0 s	9,2 s	1 682,0 s
pozorovatel 8	0,087 %	0,455 %	0,542 %	3,526 %	0,305 %	3,831 %	80,2 s	2,0 s	7,6 s	1 682,0 s
pozorovatel 9	0,119 %	0,403 %	0,522 %	6,705 %	0,087 %	6,792 %	61,1 s	2,0 s	9,4 s	1 682,0 s
pozorovatel 10	0,083 %	0,579 %	0,662 %	2,764 %	1,971 %	4,735 %	60,0 s	2,0 s	8,6 s	1 682,0 s
pozorovatel 11	0,121 %	0,415 %	0,536 %	10,748 %	24,242 %	34,990 %	10,5 s	2,0 s	8,0 s	1 682,0 s
pozorovatel 12	0,080 %	0,504 %	0,584 %	19,140 %	0,000 %	19,140 %	33,5 s	2,0 s	9,4 s	1 682,0 s
průměr	0,100 %	0,494 %	0,595 %	7,161 %	5,516 %	12,677 %	58,2 s	2,0 s	8,4 s	1 682,0 s
s p. podm.	-	-	-	1,795 %	20,542 %	22,337 %	-	24,0 s	101,2 s	1 682,0 s
bez p. podm.	-	-	-	0,482 %	0,375 %	0,857 %	-	24,0 s	101,2 s	1 682,0 s

Tabulka 6.21: Výsledky experimentů pro Sadu 3, obrázek 3.

6.3.23 Sada 3, obrázek 4

Výsledek automatické segmentace pro vypočítané p.p. byl mírně podsegmentovaný. Výsledek segmentace bez p.p. je silně podsegmentovaný. Problematickou oblastí segmentace byla především poloprůhledná ocasní ploutev. Oba výsledky automatických segmentací založených na datech od více pozorovatelů obsahovaly hledaný objekt i když druhá metoda nevybrala žlutou část rybího těla.




	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,711 %	0,160 %	0,872 %	11,114 %	0,001 %	11,115 %	86,5 s	2,0 s	7,9 s	1 520,0 s
pozorovatel 2	0,659 %	0,162 %	0,821 %	7,637 %	0,540 %	8,177 %	35,9 s	2,0 s	5,9 s	1 520,0 s
pozorovatel 3	0,821 %	0,163 %	0,985 %	1,224 %	4,710 %	5,934 %	19,1 s	2,0 s	8,1 s	1 520,0 s
pozorovatel 4	0,167 %	0,191 %	0,358 %	4,667 %	0,941 %	5,608 %	90,2 s	2,0 s	8,3 s	1 520,0 s
pozorovatel 5	1,352 %	0,160 %	1,512 %	0,035 %	42,668 %	42,703 %	36,4 s	2,0 s	9,0 s	1 520,0 s
pozorovatel 6	0,201 %	0,175 %	0,377 %	19,135 %	25,877 %	45,012 %	32,4 s	2,0 s	9,8 s	1 520,0 s
pozorovatel 7	0,064 %	0,182 %	0,246 %	12,062 %	0,022 %	12,084 %	40,9 s	2,0 s	9,2 s	1 520,0 s
pozorovatel 8	1,370 %	0,146 %	1,516 %	1,239 %	2,364 %	3,603 %	48,3 s	2,0 s	7,6 s	1 520,0 s
pozorovatel 9	0,186 %	0,192 %	0,378 %	3,242 %	0,258 %	3,500 %	24,8 s	2,0 s	9,4 s	1 520,0 s
pozorovatel 10	1,154 %	0,165 %	1,319 %	1,106 %	4,287 %	5,394 %	44,7 s	2,0 s	8,6 s	1 520,0 s
pozorovatel 11	1,310 %	0,173 %	1,483 %	1,321 %	0,856 %	2,176 %	34,4 s	2,0 s	8,0 s	1 520,0 s
pozorovatel 12	1,072 %	0,157 %	1,230 %	19,221 %	0,000 %	19,221 %	30,0 s	2,0 s	9,4 s	1 520,0 s
průměr	0,756 %	0,169 %	0,925 %	6,833 %	6,877 %	13,711 %	43,6 s	2,0 s	8,4 s	1 520,0 s
s p. podm.	-	-	-	1,330 %	0,205 %	1,534 %	-	24,0 s	101,2 s	1 520,0 s
bez p. podm.	-	-	-	8,561 %	0,005 %	8,566 %	-	24,0 s	101,2 s	1 520,0 s

Tabulka 6.22: Výsledky experimentů pro Sadu 3, obrázek 4.

6.3.24 Sada 3, obrázek 5

Výsledek automatické segmentace je pro vypočítané p.p. mírně podsegmentovaný. Výsledek segmentace bez p.p. je velmi dobrý. Problematické byly části podobné jako na fotografii klokana, kdy některá místa na rozhraní srsti a pozadí splývala. Obě metody však úspěšně našly hledané popředí. Metoda bez vypočtených p.p. dosáhla lepšího výsledku než průměr z ručních segmentací a to o 0,574% s celkovou chybou 1,561%.



(a) ground truth.

(b) aut. seg. s p. podm.


(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,133 %	1,197 %	1,330 %	2,164 %	0,672 %	2,836 %	90,5 s	2,0 s	7,9 s	2 069,0 s
pozorovatel 2	0,109 %	5,916 %	6,025 %	9,885 %	0,666 %	10,551 %	36,0 s	2,0 s	5,9 s	2 069,0 s
pozorovatel 3	0,029 %	3,241 %	3,269 %	0,549 %	0,449 %	0,998 %	17,3 s	2,0 s	8,1 s	2 069,0 s
pozorovatel 4	0,108 %	5,638 %	5,746 %	11,676 %	4,982 %	16,658 %	81,6 s	2,0 s	8,3 s	2 069,0 s
pozorovatel 5	0,121 %	1,470 %	1,591 %	0,052 %	35,234 %	35,286 %	58,4 s	2,0 s	9,0 s	2 069,0 s
pozorovatel 6	0,134 %	1,244 %	1,378 %	23,748 %	25,159 %	48,908 %	49,9 s	2,0 s	9,8 s	2 069,0 s
pozorovatel 7	0,164 %	1,036 %	1,200 %	18,138 %	0,368 %	18,506 %	64,6 s	2,0 s	9,2 s	2 069,0 s
pozorovatel 8	0,148 %	0,938 %	1,086 %	17,392 %	0,010 %	17,402 %	67,7 s	2,0 s	7,6 s	2 069,0 s
pozorovatel 9	0,191 %	0,623 %	0,814 %	16,422 %	0,212 %	16,634 %	55,3 s	2,0 s	9,4 s	2 069,0 s
pozorovatel 10	0,167 %	1,027 %	1,194 %	6,841 %	2,272 %	9,114 %	33,5 s	2,0 s	8,6 s	2 069,0 s
pozorovatel 11	0,148 %	0,882 %	1,030 %	11,068 %	0,278 %	11,347 %	41,1 s	2,0 s	8,0 s	2 069,0 s
pozorovatel 12	0,143 %	0,817 %	0,960 %	23,752 %	0,000 %	23,752 %	34,8 s	2,0 s	9,4 s	2 069,0 s
průměr	0,133 %	2,002 %	2,135 %	11,807 %	5,859 %	17,666 %	52,6 s	2,0 s	8,4 s	2 069,0 s
s p. podm.	-	-	-	2,831 %	0,353 %	3,185 %	-	24,0 s	101,2 s	2 069,0 s
bez p. podm.	-	-	-	1,376 %	0,185 %	1,561 %	-	24,0 s	101,2 s	2 069,0 s

Tabulka 6.23: Výsledky experimentů pro Sadu 3, obrázek 5.

6.3.25 Sada 3, obrázek 6

Výsledky automatické segmentace pro vypočítané p.p. i volné p.p. jsou velmi silně přesegmentované. Při ruční segmentaci byla problémová místa jen na rozhraní drápků a větvičky, na které zvonek sedí. Při automatické segmentaci pak nastala řada dalších problémů. Větvičky často byly označeny jako popředí a taktéž často i prostor mezi nimi. Obě metody ovšem našly hledaný objekt. Přesnost už však byla horší. S metodou s vypočítanými p.p. bylo přes 20% plochy chybně rozlišeno. U metody s volnými p.p. byla chyba přibližně poloviční.

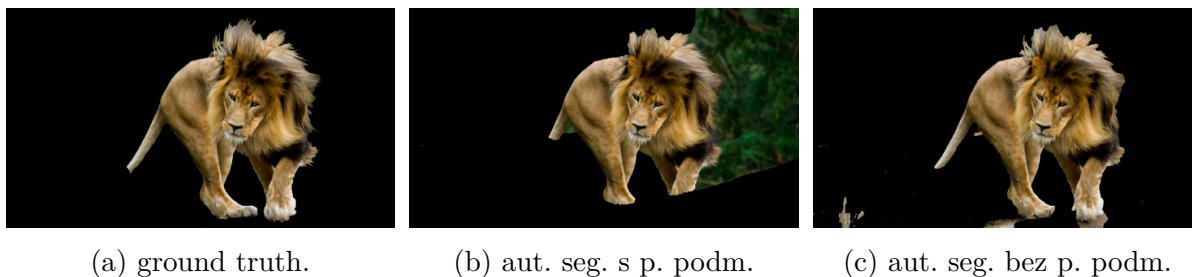


	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,476 %	0,159 %	0,634 %	0,806 %	7,198 %	8,004 %	72,1 s	2,0 s	7,9 s	1 948,0 s
pozorovatel 2	0,375 %	2,728 %	3,102 %	1,508 %	13,603 %	15,112 %	38,2 s	2,0 s	5,9 s	1 948,0 s
pozorovatel 3	0,413 %	0,130 %	0,543 %	0,757 %	0,614 %	1,371 %	18,3 s	2,0 s	8,1 s	1 948,0 s
pozorovatel 4	0,474 %	0,139 %	0,613 %	2,104 %	10,201 %	12,304 %	117,8 s	2,0 s	8,3 s	1 948,0 s
pozorovatel 5	0,558 %	0,113 %	0,671 %	0,695 %	2,631 %	3,326 %	41,9 s	2,0 s	9,0 s	1 948,0 s
pozorovatel 6	0,418 %	1,732 %	2,150 %	10,056 %	21,318 %	31,374 %	56,9 s	2,0 s	9,8 s	1 948,0 s
pozorovatel 7	0,159 %	0,301 %	0,461 %	8,622 %	11,314 %	19,936 %	49,6 s	2,0 s	9,2 s	1 948,0 s
pozorovatel 8	0,263 %	1,157 %	1,420 %	4,439 %	21,069 %	25,508 %	89,1 s	2,0 s	7,6 s	1 948,0 s
pozorovatel 9	0,473 %	0,159 %	0,632 %	0,940 %	6,947 %	7,887 %	42,4 s	2,0 s	9,4 s	1 948,0 s
pozorovatel 10	0,173 %	2,123 %	2,295 %	0,392 %	5,736 %	6,128 %	42,3 s	2,0 s	8,6 s	1 948,0 s
pozorovatel 11	0,444 %	0,143 %	0,587 %	10,136 %	6,835 %	16,971 %	85,9 s	2,0 s	8,0 s	1 948,0 s
pozorovatel 12	0,435 %	2,435 %	2,870 %	10,150 %	0,000 %	10,150 %	36,9 s	2,0 s	9,4 s	1 948,0 s
průměr	0,388 %	0,943 %	1,332 %	4,217 %	8,955 %	13,172 %	57,6 s	2,0 s	8,4 s	1 948,0 s
s p. podm.	-	-	-	0,383 %	21,586 %	21,969 %	-	24,0 s	101,2 s	1 948,0 s
bez p. podm.	-	-	-	0,371 %	11,592 %	11,964 %	-	24,0 s	101,2 s	1 948,0 s

Tabulka 6.24: Výsledky experimentů pro Sadu 3, obrázek 6.

6.3.26 Sada 3, obrázek 7

V třetí sadě u fotografie lva je výsledek automatické segmentace pro vypočítané pevné podmínky silně přesegmentovaný, výsledek segmentace bez pevných podmínek je jen mírně přesegmentovaný. Problémovou částí u ruční segmentace byla oblast konců tlapy, kde se odstín srsti blížil odstínu terénu. Náročnými oblastmi byla také hřívá a další části srsti obecně. Metoda s volnými p.p. byla i na tomto snímku úspěšnější a její výsledná chyba 2,296% se velmi blížila průměru ručních segmentací 2,256%.

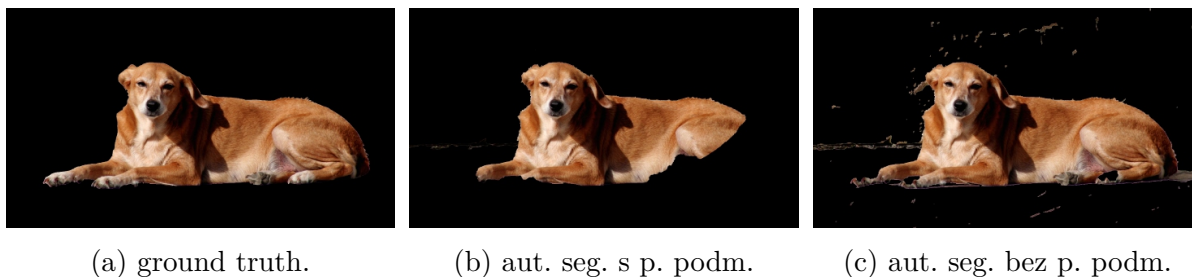


	RS podseg.	RS přeseğ.	c. chyba	ET podseg.	ET přeseğ.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,943 %	0,738 %	1,681 %	6,930 %	0,173 %	7,103 %	73,7 s	2,0 s	7,9 s	2 836,0 s
pozorovatel 2	0,511 %	6,011 %	6,522 %	6,797 %	0,273 %	7,070 %	103,7 s	2,0 s	5,9 s	2 836,0 s
pozorovatel 3	1,409 %	0,492 %	1,901 %	8,632 %	0,121 %	8,753 %	24,6 s	2,0 s	8,1 s	2 836,0 s
pozorovatel 4	0,918 %	0,555 %	1,473 %	6,152 %	9,280 %	15,432 %	125,1 s	2,0 s	8,3 s	2 836,0 s
pozorovatel 5	1,465 %	0,575 %	2,040 %	0,873 %	34,763 %	35,636 %	44,8 s	2,0 s	9,0 s	2 836,0 s
pozorovatel 6	0,579 %	2,035 %	2,614 %	23,916 %	15,251 %	39,167 %	57,2 s	2,0 s	9,8 s	2 836,0 s
pozorovatel 7	0,710 %	0,437 %	1,147 %	7,572 %	0,082 %	7,654 %	84,9 s	2,0 s	9,2 s	2 836,0 s
pozorovatel 8	0,939 %	1,899 %	2,839 %	6,778 %	0,095 %	6,873 %	171,5 s	2,0 s	7,6 s	2 836,0 s
pozorovatel 9	0,834 %	0,372 %	1,206 %	3,588 %	0,438 %	4,026 %	61,8 s	2,0 s	9,4 s	2 836,0 s
pozorovatel 10	1,102 %	0,797 %	1,899 %	7,037 %	10,177 %	17,214 %	84,6 s	2,0 s	8,6 s	2 836,0 s
pozorovatel 11	0,777 %	0,405 %	1,182 %	12,798 %	0,067 %	12,865 %	116,5 s	2,0 s	8,0 s	2 836,0 s
pozorovatel 12	0,940 %	1,625 %	2,565 %	24,219 %	0,000 %	24,219 %	40,5 s	2,0 s	9,4 s	2 836,0 s
průměr	0,927 %	1,328 %	2,256 %	9,608 %	5,893 %	15,501 %	82,4 s	2,0 s	8,4 s	2 836,0 s
s p. podm.	-	-	-	2,754 %	17,900 %	20,653 %	-	24,0 s	101,2 s	2 836,0 s
bez p. podm.	-	-	-	0,929 %	1,367 %	2,296 %	-	24,0 s	101,2 s	2 836,0 s

Tabulka 6.25: Výsledky experimentů pro Sadu 3, obrázek 7.

6.3.27 Sada 3, obrázek 8

Výsledek automatické segmentace pro vypočítané p.p. byl silně podsegmentovaný. Výsledek segmentace bez p.p. je přesegmentovaný. Problémové oblasti jsou většinou drobná místa na zdi za psem, která odstínem odpovídají barvě srsti zvířete a také světlé konce tlap. Obě metody hledaný objekt našly. Metoda s volnými p.p. opět s lepším výsledkem s celkovou chybou 3,146%.



(a) ground truth.

(b) aut. seg. s p. podm.

(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,623 %	0,931 %	1,554 %	14,855 %	0,375 %	15,230 %	49,8 s	2,0 s	7,9 s	2 390,0 s
pozorovatel 2	0,474 %	1,723 %	2,197 %	16,102 %	2,080 %	18,182 %	52,0 s	2,0 s	5,9 s	2 390,0 s
pozorovatel 3	0,039 %	2,763 %	2,801 %	6,173 %	0,378 %	6,551 %	22,6 s	2,0 s	8,1 s	2 390,0 s
pozorovatel 4	0,874 %	0,948 %	1,822 %	2,876 %	1,506 %	4,382 %	122,6 s	2,0 s	8,3 s	2 390,0 s
pozorovatel 5	0,872 %	1,011 %	1,883 %	23,121 %	17,957 %	41,078 %	84,7 s	2,0 s	9,0 s	2 390,0 s
pozorovatel 6	0,635 %	0,527 %	1,162 %	1,752 %	1,650 %	3,402 %	56,4 s	2,0 s	9,8 s	2 390,0 s
pozorovatel 7	0,242 %	0,600 %	0,842 %	21,833 %	0,158 %	21,991 %	55,2 s	2,0 s	9,2 s	2 390,0 s
pozorovatel 8	0,885 %	0,758 %	1,643 %	27,674 %	0,000 %	27,674 %	149,8 s	2,0 s	7,6 s	2 390,0 s
pozorovatel 9	0,874 %	0,580 %	1,454 %	9,991 %	0,712 %	10,702 %	33,1 s	2,0 s	9,4 s	2 390,0 s
pozorovatel 10	0,063 %	0,739 %	0,803 %	12,096 %	0,630 %	12,726 %	52,1 s	2,0 s	8,6 s	2 390,0 s
pozorovatel 11	0,639 %	0,451 %	1,090 %	13,667 %	1,699 %	15,366 %	59,2 s	2,0 s	8,0 s	2 390,0 s
pozorovatel 12	0,948 %	0,542 %	1,490 %	27,675 %	0,000 %	27,675 %	53,5 s	2,0 s	9,4 s	2 390,0 s
průměr	0,597 %	0,964 %	1,562 %	14,818 %	2,262 %	17,080 %	65,9 s	2,0 s	8,4 s	2 390,0 s
s p. podm.	-	-	-	5,666 %	0,704 %	6,371 %	-	24,0 s	101,2 s	2 390,0 s
bez p. podm.	-	-	-	0,458 %	2,688 %	3,146 %	-	24,0 s	101,2 s	2 390,0 s

Tabulka 6.26: Výsledky experimentů pro Sadu 3, obrázek 8.

6.3.28 Sada 3, obrázek 9

Výsledek automatické segmentace pro vypočítané p.p. byl silně přesegmentovaný a mírně podsegmentovaný. Výsledek segmentace bez p.p. je přesegmentovaný. Tento snímek je pro nalezení obrysu popředí, tedy zajíce na fotografii, možná vůbec nejsložitější. Srst zvířete v určitých místech splývá s povrchem nejenom odstínem, ale také strukturou. Problematičtějšími místy jsou tedy všechny stíny, všechny výraznější změny tónu či jasů. U takto těžkého úkolu pro segmentaci obě metody propadly s celkovou chybou 35,667% pro vypočítané p. p. popřípadě 13,692% u volných p.p. Rozdíl mezi automatickou a ruční segmentací je zde značný. Oproti průměrům ručních metod konkrétně 10,879% pro segmentaci s volnými p.p. a 32,854% pro metodu s vypočtenými p.p. I kdyby člověk měl v některých částech problém s rozlišením popředí a pozadí, zapracuje zde dokonale naše zkušenosti a náš mozek, který si tvar zvířete dodatečně domodeluje.



(a) ground truth.

(b) aut. seg. s p. podm.

(c) aut. seg. bez p. podm.

	RS podseg.	RS přeseq.	c. chyba	ET podseg.	ET přeseq.	c. chyba	čas RS	čas ET	čas s kal.	čas GT
pozorovatel 1	0,539 %	1,689 %	2,228 %	18,856 %	17,197 %	36,053 %	43,5 s	2,0 s	7,9 s	2 383,0 s
pozorovatel 2	1,306 %	3,730 %	5,035 %	19,018 %	0,000 %	19,018 %	53,8 s	2,0 s	5,9 s	2 383,0 s
pozorovatel 3	0,363 %	1,628 %	1,992 %	1,891 %	6,576 %	8,468 %	28,2 s	2,0 s	8,1 s	2 383,0 s
pozorovatel 4	1,844 %	1,472 %	3,316 %	5,148 %	0,240 %	5,388 %	94,9 s	2,0 s	8,3 s	2 383,0 s
pozorovatel 5	0,468 %	4,340 %	4,808 %	18,973 %	11,937 %	30,910 %	109,4 s	2,0 s	9,0 s	2 383,0 s
pozorovatel 6	0,501 %	2,187 %	2,688 %	18,181 %	23,154 %	41,335 %	41,5 s	2,0 s	9,8 s	2 383,0 s
pozorovatel 7	0,325 %	1,187 %	1,511 %	18,852 %	26,992 %	45,844 %	67,6 s	2,0 s	9,2 s	2 383,0 s
pozorovatel 8	2,111 %	1,525 %	3,636 %	5,394 %	24,345 %	29,739 %	88,8 s	2,0 s	7,6 s	2 383,0 s
pozorovatel 9	0,575 %	1,537 %	2,112 %	9,638 %	22,999 %	32,638 %	61,5 s	2,0 s	9,4 s	2 383,0 s
pozorovatel 10	0,435 %	2,672 %	3,108 %	19,018 %	0,000 %	19,018 %	50,3 s	2,0 s	8,6 s	2 383,0 s
pozorovatel 11	0,632 %	1,143 %	1,774 %	18,882 %	22,615 %	41,496 %	112,3 s	2,0 s	8,0 s	2 383,0 s
pozorovatel 12	0,524 %	1,025 %	1,548 %	19,018 %	0,000 %	19,018 %	39,1 s	2,0 s	9,4 s	2 383,0 s
průměr	0,802 %	2,011 %	2,813 %	14,406 %	13,005 %	27,410 %	65,9 s	2,0 s	8,4 s	2 383,0 s
s p. podm.	-	-	-	3,533 %	32,134 %	35,667 %	-	24,0 s	101,2 s	2 383,0 s
bez p. podm.	-	-	-	1,046 %	12,646 %	13,692 %	-	24,0 s	101,2 s	2 383,0 s

Tabulka 6.27: Výsledky experimentů pro Sadu 3, obrázek 9.

6.4 Shrnutí výsledků experimentů

6.4.1 Sada 1

Jedná se o fotografie míčů, tedy jednoduché geometrické tvary na jednobarevném pozadí. Tato sada by tedy měla představovat nejjednodušší úlohu pro segmentaci.

Z časového hlediska se jedná o zcela nejrychlejší sadu. Průměrné časy, které pozorovatelé potřebovali k ručnímu zakreslení pevných podmínek, byly od 26 do 66 sekund. Časy, které uživatelé strávili na vytvoření dat pomocí zařízení na sledování pohybu očí, jsou totožné pro každý obrázek. Byly to přesně 2 sekundy, tj. doba, po kterou obrázek sledovali. Pokud k tomu připočteme i dobu nutnou pro kalibraci zařízení, byla průměrná doba asi 8,8 vteřiny na jeden snímek. Průměrná doba na kalibraci zařízení je něco málo přes 65 vteřin. Taktéž vytvoření ground truth dat bylo díky jednoduchosti objektů nejrychlejší.


Průměry výsledků segmentací podle ručně zadaných pevných podmínek nikdy v nepřesáhly celkovou chybu 1%. Tím splnily očekávání, kterou měla tato pro segmentaci jednoduchá úloha naplnit. Nejčastějším zdrojem chyby byl stín pod míčem a také nejasná kontura. Oba dva problémy by bylo možné do jisté míry eliminovat lepší fototechnikou. Problém se stínem vytvářelo špatné osvětlení a nejasnou konturu nedostatečná kvalita fotoaparátu. Na druhou stranu podobné problémy se mohou vyskytovat velmi často na amatérských fotografiích, kde je automatizované či poloautomatizované vyhledávání a segmentace objektů oblastí zájmu. Obrovské množství těchto fotografií je totiž takřka nemožné zpracovat ručně, a proto je zde prostor pro automatické či poloautomatické metody.

Dvě automatické metody s daty všech 12 pozorovatelů fungovaly relativně úspěšně vůči pokusům, které využívaly data jen od jednoho konkrétních pozorovatele. I když výsledky jednotlivců byly někdy lepší, vyznačovaly se velkými výkyvy v kvalitě.

Bez hlubší znalosti se nabízí možnost zlepšit kvalitu segmentace pomocí výběru jednotlivců s nejlepšími výsledky. Jenže k tomuto kroku potřebujeme výsledky nejdříve ohodnotit. To by znamenalo vytvoření porovnávacích dat (ground truth data) a v tu chvíli ztrácí

automatická či poloautomatická segmentace smysl.

O výhodnosti složení informací z více pokusů a od více pozorovatelů se můžeme přesvědčit do určité míry u osmi z devíti prezentovaných experimentů z této sady fotografií. S výjimkou obrázku 6.44, kdy obě metody selhaly. Oba případy byly ovlivněné špatným výpočtem středu objektu a od toho i odvozených pevných podmínek. V případě metody, která nepočítala pevné podmínky, dokonce nebylo žádané popředí vůbec nalezeno. Ve všech 27 obrázcích se však jedná o jediný případ. To znamená, že ve všech 53 ostatních experimentech, které využívaly data ze zařízení na sledování očí od všech pozorovatelů, byl objekt nalezen alespoň částečně.



Obrázek 6.44: Výsledky experimentů pro Sadu 1, obrázek 6.

Zajímavé je informace, že metoda využívající vypočítané pevné podmínky má tendenci k přesegmentování. Zatímco metoda bez pevných podmínek jen s určeným středem objektu má tendenci k podsegmentování. Důvodem může být nevhodná forma pevných podmínek ve tvaru elips v prvním případě a absence pevných podmínek ve druhém.

	relativní podsegmentování ruční seg.	relativní přesegmentování ruční seg.	relativní podsegmentování aut. seg. s p.p.	relativní přesegmentování aut. seg. s p.p.	relativní podsegmentování aut. seg. bez p.p.	relativní přesegmentování aut. seg. bez p.p.
obrázek 1	0,356 %	0,421 %	0,531 %	5,959 %	37,638 %	0,135 %
obrázek 2	0,082 %	0,854 %	0,000 %	35,355 %	0,034 %	0,718 %
obrázek 3	0,070 %	1,127 %	24,246 %	38,937 %	5,134 %	0,081 %
obrázek 4	0,124 %	1,011 %	18,672 %	10,962 %	19,147 %	0,073 %
obrázek 5	0,296 %	0,941 %	0,033 %	22,427 %	9,388 %	0,136 %
obrázek 6	0,110 %	0,380 %	0,017 %	34,946 %	99,974 %	76,935 %
obrázek 7	0,084 %	0,995 %	0,296 %	0,257 %	9,114 %	0,204 %
obrázek 8	0,844 %	0,691 %	0,100 %	10,258 %	1,168 %	0,155 %
obrázek 9	0,226 %	0,889 %	12,248 %	4,413 %	2,396 %	0,220 %

Tabulka 6.28: Relativní chyby podsegmentování a přesegmentování pro Sadu 1.



Obrázek 6.45: Časově nejnáročnější obrázek při ručním zadávání pevných podmínek.

6.4.2 Sada 2

Druhá sada, která prezentovala fotografie letadel, obsahovala z hlediska oddělení pozadí a popředí mnohem větší problém. Popředí mělo složitější tvar, dlouhé a tenké prvky jako například křídla, podvozky a rozmanitější paletu barev. V některých případech segmentaci ulehčovalo jednobarevné nebo alespoň snadno odlišitelné pozadí.

Průměrný čas k ručnímu zadání pevných podmínek byl 52,8 sekundy pro nejrychlejší z fotografií a 135,9 sekundy pro nejpomalejší. Nejdéle ze všech trvalo pozorovatelům označit pevné podmínky na obrázku 6.45 z této sady. Kromě složitého obrysu plného děr a zálivů bylo na složitém pozadí mnohdy obtížné správně rozlišit, co k popředí opravdu náleží. Za zmínku rozhodně stojí i fakt, že čas 135,9 sekundy překonal svou délkou i součet časů všech pozorovatelů s eye trackerem. Ten činil 105,1 sekundy a to pokud do tohoto součtu zahrneme čas nutný ke kalibraci zařízení. To znamená, že v tomto konkrétním případě bylo využití eye trackeru pro jednoho pozorovatele více než 15 krát rychlejší. Se složitostí objektů v popředí roste pochopitelně i časová náročnost vytvoření ground truth dat.

I na fotografiích z druhé sady pracovaly obě automatické metody s daty všech 12 pozorovatelů dobře. Viditelně lepších výsledku však dosahovala metoda s volnými podmínkami. Zde téměř jistě můžeme konstatovat, že problémem metody s vypočtenými pevnými podmínkami, bylo to, že tvar podmínek neodpovídal hledanému objektu. Výsledkem toho je větší míra přesegmentování.

Na druhé sadě fotografií lze také sledovat kladný vliv využívání dat od všech pozorovatelů na vyrovnanost výsledků. Zatímco mnoho výsledků pokusů jednotlivců je obvykle silně přesegmentované, použití všech dat s kombinací s volnějšímí pevnými podmínkami vedlo k výraznému vylepšení výsledků. Především ale žádná ze segmentací nedopadla subjektivně špatně. Pokud bychom tyto data používali například k automatickému zvýraznění obrysu objektu, dala by se většina z nich naprosto bezproblémově využít, aniž bychom získali jiná data, než ty o pohybu očí.

	relativní podsegmentování ruční seg.	relativní přesegmentování ruční seg.	relativní podsegmentování aut. seg. s p.p.	relativní přesegmentování aut. seg. s p.p.	relativní podsegmentování aut. seg. bez p.p.	relativní přesegmentování aut. seg. bez p.p.
obrázek 1	1,034 %	2,546 %	0,907 %	2,717 %	40,129 %	2,951 %
obrázek 2	7,029 %	1,740 %	19,994 %	37,188 %	10,224 %	2,900 %
obrázek 3	0,782 %	6,203 %	0,420 %	21,072 %	0,662 %	7,432 %
obrázek 4	2,342 %	0,299 %	3,347 %	0,618 %	42,440 %	0,374 %
obrázek 5	1,294 %	0,294 %	1,780 %	0,785 %	2,900 %	0,590 %
obrázek 6	2,716 %	3,137 %	14,120 %	22,555 %	9,000 %	6,269 %
obrázek 7	1,205 %	1,450 %	2,050 %	25,904 %	2,826 %	0,936 %
obrázek 8	0,767 %	1,602 %	36,643 %	49,568 %	26,881 %	1,184 %
obrázek 9	2,707 %	1,202 %	1,124 %	21,545 %	8,291 %	5,152 %

Tabulka 6.29: Relativní chyby podsegmentování a přesegmentování pro Sadu 2.

6.4.3 Sada 3

Fotografie třetí a poslední sady obsahovaly snímky různých živočichů. Problematická část pro oblast segmentace těchto fotografií je jednak ukrytá ve složitosti tvarů, ale také odstínech zvířat a prostředí, ve kterém jsou zachyceny.

Pozorovatelům ruční zakreslení p.p. trvalo v průměru 43,6 až 82,6 sekundy u těch časově nejnáročnějších. Při započtení času nutného na kalibraci zařízení připadá na každý obrázek 101,2 sekundy času všech dvanácti pozorovatelů dohromady.

Tato sada připravila pro automatickou segmentaci řadu obtížných prvků v podobě nejasných přechodů na rozhraní popředí a pozadí, velmi jemných detailů na objektech či poloprůhledných oblastech. I přesto si však automatické metody nepropadly a v některých případech svou přesností předčily ruční zadávání pevných podmínek.



(a) vstupní fotografie.



(b) aut. seg. bez p. podm.

Obrázek 6.46: Sada 3 obrázek 9 - Zajíc.

Na obrázku 6.46, kde některé části zvířete a pozadí mají takřka totožnou barvu a strukturu, dokáže pozorovatel nalézt obrys zajíce snadno. To je dáno jeho znalostmi a zkušenostmi, které mozek využívá tak, že dokáže dotvořit celý obraz zajíce a pozorovatel jej tak z pozadí rozezná.

Třetí sada potvrdila naši hypotézu o zkvalitnění a především o zlepšení stability výsledků použitím dat více pozorovatelů.

	relativní podsegmentování ruční seg.	relativní přesegmentování ruční seg.	relativní podsegmentování aut. seg. s p.p.	relativní přesegmentování aut. seg. s p.p.	relativní podsegmentování aut. seg. bez p.p.	relativní přesegmentování aut. seg. bez p.p.
obrázek 1	0,475 %	0,451 %	1,094 %	4,536 %	17,986 %	0,172 %
obrázek 2	0,976 %	3,186 %	35,616 %	70,256 %	3,042 %	1,930 %
obrázek 3	0,525 %	0,611 %	9,376 %	25,405 %	2,516 %	0,464 %
obrázek 4	3,932 %	0,209 %	6,918 %	0,253 %	44,540 %	0,006 %
obrázek 5	0,559 %	2,626 %	11,920 %	0,463 %	5,793 %	0,243 %
obrázek 6	3,826 %	1,050 %	3,778 %	24,024 %	3,659 %	12,902 %
obrázek 7	3,829 %	1,753 %	11,370 %	23,620 %	3,835 %	1,804 %
obrázek 8	2,158 %	1,333 %	20,475 %	0,974 %	1,655 %	3,717 %
obrázek 9	4,217 %	2,483 %	18,575 %	39,681 %	5,500 %	15,615 %

Tabulka 6.30: Relativní chyby podsegmentování a přesegmentování pro Sadu 3.

Kapitola 7

Závěr

Cílem diplomové práce bylo vytvořit systém pro automatickou segmentaci objektů z fotografií s využitím dat získaných ze zařízení pro sledování pohybu očí. K dosažení tohoto cíle bylo důležité pochopit, jakým způsobem využívá člověk svou pozornost při pozorování fotografií a vyhodnocování toho, co je popředím a co je pozadím. Lidský mozek je pro tento úkol velmi dobře připraven. Naše mysl obsahuje neuvěřitelně složitou síť, která nám umožňuje velmi rychle hodnotit a odhalovat spojitosti, vztahy, jevy a předměty ve světě kolem nás. Právě zrak nám zprostředkovává až 90% vstupních informací k tomuto procesu [12]. Pozice oka a pohled oka je tedy velmi důležitou informací, která automatickou segmentaci může umožnit.

Zařízení, které umožňuje tyto informace získat, se nazývá eye tracker. Experimenty byly prováděny se systémem I4Tracking[®], jehož výrobcem je společnost Medicton Group, s. r. o., tento systém využívá videookulografickou metodu, což znamená, že používá ke sledování a vyhodnocování polohy oka dvě kamery - oční pro snímání oka a scénickou pro snímání pozadí. Jedná se o pokročilou metodu, která je neinvazivní a přitom dostatečně přesná pro sledování očních pohybů.

Než bylo tento systém možné využít pro experimenty, bylo nutné překonat několik technických problémů vztahených k použitému zařízení. Například metodu kalibrace pomocí laserového ukazovátka jsem zdokonalil promítáním kříže přes projektor. Bohužel i přesto

zůstávala chyba měření značná a vypočtené body zájmu neodpovídaly opravdovému pohledu uživatele. Při pokusech se sledováním jednoho bodu jsem však odhalil, že se chyba jeví jako konstantní posun během celého pokusu. Stačilo tedy tuto chybu přibližně určit před začátkem měření a pak ji odečíst. Před každým experimentem musel pozorovatel zaměřit svou pozornost na bod zvýrazněný křížem uprostřed promítaného obrazu. Díky tomuto postupu se přesnost významně zvýšila.

Zařízení bohužel nijak nereaguje na pohyb hlavy a nekompensuje ho, jak je možné u kvalitnějších systémů. Pozorovatelé se snažili veškeré pohyby co nejvíce minimalizovat. Není však v lidských silách zůstat v klidu, dokonce ani po tak krátkou dobu, jako je jedna minuta, nutná na každou nahrávací sekvenci. Navíc konstrukce typu „brýle“ je v přímém kontaktu s uživatelem a je propojená s vyhodnocovacím zařízením. To znamená, že každý pohyb mohl způsobit posunutí zařízení a tedy změnu jeho polohy vůči očím. To je důležité zdůraznit, neboť při vyhodnocování pohledu hrají roli mikrometry.

Systém nepracoval v reálném čase. Vyhodnocení uložených dat z přibližně minutové nahrávky do formátu, kde jsem s ním mohl dále pracovat, trvalo přibližně 40 minut. Další příprava, jako přepočítání dat, atp. tento čas prodloužila téměř na dvě hodiny. To znamená, že případný problém s nějakým experimentem jsem mnohdy objevil až po týdnech zpracovávání dat. Vhodnější zařízení by tyto problémy minimalizovalo či dokonce eliminovalo.

V diplomové práci hodnotím tři série po devíti fotografiích. Série se liší ve složitosti, dané tématem snímků. Data získaná od genderově vyvážené skupiny dvanácti pozorovatelů byla využita pro automatické vytvoření masky pro algoritmus Graph Cut implementovaný v knihovně OpenCV pro python. Práce se soustředí na dvě metody tvorby masky. Jednu s vypočítanými pevnými podmínkami pomocí kvantilů dvourozměrného normálního rozdělení určeného EM algoritmem. Druhou s volnějšími podmínkami, kde byl EM algoritmus použitý jen k nalezení oblasti středu objektu. První z jmenovaných jsem sledoval pro data od jednotlivých pozorovatelů, obě dvě pak pro data od všech 12 pozorovatelů.

Úspěšnost segmentace jsem hodnotil subjektivně, zvláště pro každý zkoumaný snímek na základě porovnávání výsledků s ground truth daty. To jsou obrázky, které jsem ručně upravil v grafickém editoru a které jsou v diplomové práci používány jako příklad zcela správné segmentace.

Jako objektivní hodnocení výsledků segmentace pomocí eye trackeru jsem používal porovnání se segmentací založené na manuálním nakreslení masky (popředí, pozadí, možné popředí, možné pozadí) všemi dvanácti pozorovateli pro každou ze zkoumaných fotografií. Výsledky jsem srovnával pomocí parametrů podsegmentování a přesegmentování, variant těchto parametrů vztahených k ploše pozadí, popř. popředí, čili relativnímu podsegmentování a přesegmentování.

Po prozkoumání všech výsledků můžeme konstatovat, že je určitě možné použít systém na sledování očí k automatické segmentaci popředí a pozadí z fotografií. Použití dat od více pozorovatelů vedlo ke stabilnějším výsledkům. Automatická segmentace kvalitativně překonala v některých případech výsledky manuální segmentace. Nutno podotknout, že ruční metoda je pro uživatele po všech stránkách mnohem náročnější, především časově.

Kdybychom byli schopni vyřešit problémy použitého systému na sledování očí, nebo jej nahradili dokonalejším zařízením, mohli bychom získat lepší výsledky. K dalšímu zlepšení výsledku algoritmu Graph Cut, by bylo vhodné při vytváření masky zohlednit tvar objektu. Popřípadě využít další informace, které by se nám podařilo z fotografie a pohybu očí extrahovat. Zajímavé by také bylo nechat pozorovatele soustředit svou pozornost na fotografii po delší dobu než jsou dvě vteřiny a pokusit se vyhodnotit, co znamenají další oční pohyby po nalezení nejdůležitějších částí snímku.

Až na několik výjimek byly výsledky pokusů nad očekávání dobré. Lepších výsledků dosahovala metoda, která nebyla tak striktní v zadávání pevných podmínek. Ukázalo se tedy, že je výhodnější nechat segmentační algoritmus najít z centra pozornosti celý objekt, než se mu navrhnout skutečnosti neodpovídající tvar objektu. Druhá metoda totiž nerespektovala tvar objektu, neboť vrstvy masky měly vždy tvar elipsy.

Automatická segmentace objektů z fotografií s využitím dat získaných ze zařízení pro sledování pohybu očí splnila naše předpoklady. Z pohledu uživatele byla rychlejší než ruční označování popředí a pozadí a často dosahovala velmi dobrých výsledků. Ty jsou jistou motivací pro rozvoj tohoto tématu do budoucna. Je třeba eliminovat typické neduhy automatické segmentace, problémy současných zařízení na sledování pohybu očí a používaných algoritmů.

Pokud bychom měli k dispozici zařízení, které by pracovalo real-time, bylo by zajímavé vytvořit program segmentující fotografie v reálném čase. Segmentování by mohlo fungovat jako nástroj v grafickém editoru. Uživatel by jej zapnul a ovládal pouze zrakem, popřípadě by potvrdil, že je segmentace dokončená, nebo že se má začít znovu. Celou funkci by teoreticky bylo možné ovládat jen očima, neboť už existují systémy na ovládání osobních počítačů pouze pohledem.

V rámci diplomové práce vzniklo velké množství dat, které mohou být užitečné pro další experimenty či navazující výzkum. Všechna tato data jsou přiložena jako digitální přílohy k této diplomové práci. Mimo jiné jsou zde všechny skripty použité pro výpočty, data a výsledky ze tří prezentovaných sad fotografií, ale také naměřená a předzpracovaná data z dalších tří sad, které v práci nakonec nebyla využita.

Příloha A

Digitální přílohy

Digitální přílohy jsou rozděleny do několika složek. Zde uvádím stručný obsah disku.

Scripts - obsahuje všechny skripty napsané v jazyce python použité v této práci a navíc některé zkušební skripty.

Results - obsahuje tabulky a některé další soubory s výsledky a mezivýsledky experimentů, parametrů segmentací, obsahů objektů, atp.

Data - raw - obsahuje neupravené sady fotografií.

Data - ground truth - obsahuje ground truth data všech sad fotografií.

Data - by eye - obsahuje výsledky a masky tří testovaných sad fotografií získaných pomocí eye trackeru.

Data - by hand - obsahuje výsledky tří testovaných sad a masky všech sad fotografií. Ručně zadané 12 pozorovatelů.

Source files - obsahuje digitální verzi diplomové práce a zdrojové soubory k jejímu vysázení v systému L^AT_EX.

Literatura

- [1] BATCHELOR, B. – WALTZ, F. *Intelligent Machine Vision: Techniques, Implementations and Applications*. Londýn: Springer, 2012. ISBN 978-14-4710-239-7.
- [2] CARPENTER, R. *Movements of the eyes*. London: Pion, 1988. ISBN 978-08-5086-109-8.
- [3] DEMEL, J. Segmentace 3D obrazových dat s využitím grafové reprezentace. Master's thesis, Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Brno, 2014.
- [4] DOWNEY, A. B. *Think stats: pravděpodobnost a statistika pro programátory: verze 1.6.0*. Brno: Flow, 2014. ISBN 978-80-905480-4-6.
- [5] DUCHOWSKI, A. T. *Eye tracking methodology: theory and practice*. Londýn: Springer, 2007. ISBN 978-18-4628-608-7.
- [6] ŽELEZNÝ, M. *Zpracování digitalizovaného obrazu*. Plzeň: Západočeská univerzita, Fakulta aplikovaných věd, 2014.
- [7] GOLDBERG, A. V. – TARJAN, R. E. *Proceedings of the 18th Annual Acm Symposium on Theory of Computing*. New York: Assn for Computing Machinery, 1986. ISBN 978-08-9791-193-8.
- [8] HARTRIDGE, H. – THOMPSON, L. C. Methods of investigating eye movements. *British Journal of Ophthalmology*. 1948, 31, 9, s. 62–66. ISSN 581–591.
- [9] HOGG, R. V. – MCKEAN, J. – CRAIG, A. T. *Introduction to Mathematical Statistics (7th Edition)*. Londýn: Pearson, 2012. ISBN 978-03-2179-543-4.

- [10] KOWLER, E. *Eye movements and their role in visual and cognitive processes*. New York: Elsevier Science Pub. Co., 2007. ISBN 978-04-4481-254-7.
- [11] KRČILOVÁ, R. EM-algoritmus a směsi normálních rozdělání. Master's thesis, Masarykova Univerzita, Fakulta přírodovědecká, Brno, 2005.
- [12] KRÁLÍČEK, P. *Úvod do speciální neurofyzologie*. Praha: Karolinum, 2002. ISBN 978-80-246-0350-0.
- [13] KROPÁČ, J. *Statistika: náhodné jevy, náhodné veličiny, základy matematické statistiky, indexní analýza, regresní analýza, časové řady*. Brno: Akademické nakladatelství CERM, 2012. ISBN 978-80-7204-788-8.
- [14] KUBÁT, V. – TRKOVSKÁ, D. *Analytická geometrie v afinních a eukleidovských prostorech*. Praha: Matfyzpress, 2011. ISBN 978-80-7378-144-6.
- [15] KVAPILÍKOVÁ, K. *Anatomie a embryologie oka*. Brno: Institut pro další vzdělávání pracovníků ve zdravotnictví, 2000. ISBN 978-80-7013-313-9.
- [16] *Zařízení pro sledování očních pohybů – Návod k obsluze*. Medicton Group, s.r.o., 2013. Datum revize: 20. 4. 2014.
- [17] NOBUYUKI, O. A Threshold Selection Method from Gray-Level Histograms. *IEEE Transactions on Systems, Man, and Cybernetics*. Leden 1979, 9, 1, s. 62–66. ISSN 0018-9472.
- [18] PAPADIMITRIOU, C. H. – STEIGLITZ, K. *Combinatorial Optimization: Algorithms and Complexity (Dover Books on Computer Science)*. New York: Dover Publications, 1998. ISBN 978-04-8640-258-4.
- [19] POSNER, M. I. Orienting of attention. *Quarterly Journal of Experimental Psychology*. 1980, 32, s. 3–25.
- [20] RAYNER, K. Eye movements in reading and information processing: 20 Years of Research. *Psychological Bulletin*. 1998, , 124, s. 372–422.

- [21] RAYNER, K. Eye movements in reading and information processing. *Psychological Bulletin*. 1978, , 85, s. 62–66.
- [22] REIF, J. *Metody matematické statistiky*. Plzeň: Západočeská univerzita, Fakulta aplikovaných věd, 2004. ISBN 978-80-7043-302-7.
- [23] REIF, J. – KOBEDA, Z. *Úvod do pravděpodobnosti a spolehlivosti*. Plzeň: Západočeská univerzita, Fakulta aplikovaných věd, 2004. ISBN 978-80-7043-333-7.
- [24] SCOTT, D. – FINDLEY, J. *Visual search, eye movements and display units, Human factors report*. Durham: University of Durham, 1993.
- [25] YARBUS, A. L. *Eye Movements and Vision*. New York: Plenum Press, 1967. ISBN 978-14-8995-381-0.
- [26] ZHANG, Y. A survey on evaluation methods for image segmentation. *Pattern Recognition*. 1996, 8, 29, s. 1335–1346.