

Bakalářská práce



České
vysoké
učení technické
v Praze

F3

Fakulta elektrotechnická
Katedra kybernetiky

Počítání škůdců v obraze

Jiří Dolejš

Vedoucí: Ing. Vladimír Smutný, Ph.D.
Studijní program: Kybernetika a robotika
Obor: Robotika
Květen 2017

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Student: Jiří Dolejš
Studijní program: Kybernetika a robotika (bakalářský)
Obor: Robotika
Název tématu: Počítání škůdců v obraze

Pokyny pro vypracování:

1. Seznamte se s metodami rozpoznávání objektů v obrazových datech. Vyhledejte literaturu vztahující se k danému praktickému problému.
2. Pro existující data navrhnete algoritmus, který bude v obraze počítat zachycené škůdce.
3. Algoritmus implementujte a vyzkoušejte. Proveďte případné modifikace a vylepšení pro nová data.
4. Program opatřete vhodným uživatelským rozhraním a zdokumentujte.
5. Výsledky vyhodnoťte a navrhnete možná zlepšení.

Seznam odborné literatury:

- [1] Robot Operating System, available documentation
- [2] Open Motion Planning Library, <http://ompl.kavrakilab.org/>
- [3] T. Chettibi, H.E. Lehtihet, M. Haddad, S. Hanchi, Minimum cost trajectory planning for industrial robots, European Journal of Mechanics - A/Solids, Volume 23, Issue 4, 2004, Pages 703-715, ISSN 0997-7538, <http://dx.doi.org/10.1016/j.euromechsol.2004.02.006>

Vedoucí bakalářské práce: Ing. Vladimír Smutný, Ph.D.

Platnost zadání: do konce letního semestru 2017/2018

L.S.

prof. Dr. Ing. Jan Kybic
vedoucí katedry

prof. Ing. Pavel Ripka, CSc.
děkan

V Praze dne 9. 11. 2016

Poděkování

Na tomto místě bych rád poděkoval Ing. Vladimíru Smutnému, Ph.D. za cenné rady a ochotu při vedení mé bakalářské práce.

Prohlášení

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

V Praze dne

.....
podpis autora práce

Abstrakt

Tato bakalářská práce se zabývá využitím počítačového vidění za účelem počítání škůdců v obraze. V rámci této práce byl navržen a implementován algoritmus, pomocí kterého lze rozpoznat blýskáčka řepkového v obrazových datech a určit jeho celkový počet v záchytném zařízení. Algoritmus byl navržen na základě dostupných trénovacích dat a jeho funkce byla otestována na prototypu monitorovacího záchytného zařízení.

Klíčová slova: blýskáček řepkový, rozpoznávání, počítačové vidění

Vedoucí: Ing. Vladimír Smutný, Ph.D.
Jugoslávských partyzánů 3,
160 00 Praha 6

Abstract

This bachelor thesis deals with the use of computer vision for the purpose of counting pests in an image. In this work, an algorithm has been designed and implemented to identify the *Meligethes aeneus* in image data and to determine its total number in a capture device. The algorithm was designed based on the available training data and its function was tested on the prototype of monitoring capture device.

Keywords: *Meligethes aeneus*, recognition, computer vision

Title translation: Pest Counting in Image Data

Obsah

1 Úvod	1	5 Výsledky	21
2 Současný stav	3	5.1 Popis trénovacích dat	21
2.1 Cíl práce	4	5.2 Výsledky na trénovacích datech	22
3 Teoretická část	5	5.2.1 Klasifikace s automatickým odhadem průměrných hodnot příznaků	23
3.1 Blýskáček řepkový	5	5.2.2 Klasifikace se statickým odhadem průměrných hodnot příznaků	24
3.2 Segmentace prahováním	6	5.2.3 Klasifikace s adaptivním odhadem průměrných hodnot příznaků	24
3.3 Detekce a klasifikace objektů	10	5.3 Popis reálných dat	25
3.3.1 Detekce objektů	10	5.4 Výsledky na reálných datech	26
3.3.2 Klasifikace	11	5.5 Možná vylepšení	28
3.3.3 Metody pro odhad průměrné hodnoty příznaků	11	6 Závěr	29
3.3.4 Jednotlivci	14	A Literatura	31
3.3.5 Shluky	14	B Obsah příloženého DVD	35
4 Popis programu	17		
4.1 Popis funkce	18		
4.2 Popis výstupních dat	18		
4.3 Ovládání a nastavení	20		

Obrázky

2.1 Mörickeho miska [6]	3	4.1 Obrazový výstup	19
2.2 TrapView [8]	4	4.2 Hlavní okno programu	20
3.1 Blýskáček poškozující květ řepky [9]	5	4.3 Okno nastavení	20
3.2 Barevný prostor RGB	7	5.1 Označení brouka	22
3.3 Nastavení roviny	8	5.2 Prototyp monitorovacího zařízení	25
3.4 Rozdělení bodů v RGB prostoru	8	5.3 Obraz poskytnutý pro návrh algoritmu	26
3.5 Body v RGB prostoru	9	5.4 Obraz pořízený prototypem monitorovacího zařízení	27
3.6 Binární obraz	10	5.5 Detail chybné klasifikace	27
3.7 Příznaky	10		
3.8 Histogram ploch objektů	12		
3.9 Histogram excentricit objektů	13		
3.10 Histogram délek objektů	13		
3.11 Histogram šířek objektů	13		
3.12 Detail jednotlivců	14		
3.13 Detail shluku	15		

Tabulky

4.1 Použité externí moduly	17
4.2 Výsledky v textové formě	19
5.1 Význam použitých zkratk	22
5.2 Výsledky klasifikace s využitím automatického odhadu průměrných hodnot příznaků	23
5.3 Výsledky klasifikace s využitím statického odhadu průměrných hodnot příznaků	24
5.4 Výsledky klasifikace s využitím adaptivního odhadu průměrných hodnot příznaků	24

Kapitola 1

Úvod

Při pěstování zemědělských plodin se k jejich ochraně před škůdci využívají mimo jiné i chemické metody. Aby bylo využití těchto chemických prostředků co nejefektivnější, je nutné jejich aplikaci správně načasovat [1]. Toho je možné docílit kontinuálním monitorováním letové aktivity škůdců, kteří mohou danou plodinu poškodit či zničit, a na něž bude případná aplikace chemických prostředků cílena. Tímto způsobem lze zachytit období, kdy výskyt škůdce dosáhne definovaného prahu škodlivosti, a je tedy nutné aplikovat dané insekticidy. V případě nízké aktivity škůdce je také možné zamezit zbytečnému použití chemických přípravků, které by mohlo vést ke zvýšení rezistence škůdců vůči látkám obsažených v užitých přípravcích [2]. Nezanedbatelným přínosem je také ekonomická úspora vznikající díky zamezení zbytečnému použití těchto prostředků.

Tato práce je motivována zadáním společnosti Leading Farmers CZ, a.s. [3], a zabývá se využitím postupů počítačového vidění pro detekci škůdců v obraze a určení jejich celkového počtu v zachytném zařízení. K tomuto účelu jsem v rámci této práce navrhl a implementoval rozpoznávací algoritmus, který byl použit při testování prototypu zařízení monitorujícího aktivitu škůdců. Při detekci se zaměřuji výhradně na blýskáčka řepkového (*Meligethes aeneus*), což je jeden z nejzávažnějších škůdců řepky olejné [2]. Jeho škodlivost spočívá ve vyžírání tvořících se pupat, které v důsledku poškození opadávají. Během období jejich tvorby tak může být v mimořádných případech zničeno až 70 % květů [4].

Kapitola 2

Současný stav

Pro určení letové aktivity sledovaného druhu škůdce se v současné době využívají mimo jiné i tzv. Mörickeho misky (obrázek 2.1), což jsou záchytné misky žluté barvy, většinou kruhového, šestiúhelníkového či obdélníkového tvaru, které svou barvou lákají různé druhy škůdců. Misky obvykle obsahují směs vody a saponátu, díky čemuž v nich hmyz zůstává zachycen. Namísto misek lze případně použít leповé pásy žluté barvy, na které se díky ošetření nevysychavým lepidlem hmyz přichytí [5]. Misky, resp. pásy, jsou poté pravidelně kontrolovány a počet zachycených škůdců je určován vizuálně. Sledovací zařízení se v tomto případě umísťují do výšky vrcholků rostlin asi 5 m od okraje porostu [2].



Obrázek 2.1: Mörickeho miska [6]

Dalším možným způsobem, který se využívá i spolu s monitorováním pomocí uvedených záchytných zařízení, je pouhá vizuální kontrola stavu rostlin, při které se hodnotí úroveň poškození poupat a určuje se odhadovaný počet škůdců na jednu rostlinu [2].

Mezi moderní přístup k problému patří řešení od slovinské firmy EFOS s názvem TrapView [7]. Toto zařízení (obrázek 2.2) láká různé druhy škůdců do pasti za pomoci feromonů. Záchytná část pasti je pravidelně automaticky fotografována a data jsou odesílána ke zpracování. Následně jsou na pořízených fotografiích vyznačeny a spočítány rozpoznané druhy škůdců.



Obrázek 2.2: TrapView [8]

2.1 Cíl práce

Cílem této práce je navrhnout a implementovat algoritmus, pomocí kterého bude možné detekovat blýskáčka řepkového v obrazových datech, a určit tak jeho celkový počet v zachyceném obraze. Zdrojem dat bude zařízení snímající Mörickeho misku zachytávající škůdce, které bude umístěno přímo v monitorovaném porostu, a ze kterého budou data odesílána ke vzdálenému zpracování. Využitím tohoto algoritmu k automatizovanému monitorování výskytu škůdce by mělo dojít ke snížení nákladů spojených s nutností pravidelné kontroly sledovacích zařízení, a také k usnadnění monitorování většího množství stanic. Ulehčením pravidelné kontroly by mělo být možné přesněji určit dobu překročení prahu škodlivosti, a tím efektivněji použít postřikové prostředky.

Kapitola 3

Teoretická část

3.1 Blýskáček řepkový

Blýskáček řepkový (*Meligethes aeneus*) je druh brouka náležící do čeledi Lesknáčovití (*Nitidulidae*). Dospělí jedinec obvykle dosahuje délky 2 - 2,5 mm a šířky 1,5 mm. Je zbarvený černě, s kovovým leskem do modra či zelena. Přezimuje jako dospělec, a to v půdě, případně ve zbytcích rostlin či listí. Jeho první výskyt může nastat již brzy na jaře, a to v době kdy teplota pravidelně dosahuje 10 °C. Blýskáčci se v tomto období živí převážně pylem časné kvetoucích bylin a dřevin. Po vytvoření poupat na řepce olejné nastává hromadné nalétávání do jejích porostů. S tím také přichází období, kdy dochází k největším škodám. Blýskáčci za účelem získání pylu nakusují nerozkvetlá poupata (obrázek 3.1), v důsledku čehož dochází k jejich usychání a opadávání [2].



Obrázek 3.1: Blýskáček poškozující květ řepky [9]

V této době také samičky kladou vajíčka do polorozvitéch květů či do otvorů vzniklých při nakusování pupat. Každá samička takto v průměru naklade 40 - 50 vajíček. Pokud panují normální teploty, larvy se z vajíček líhnou po 3 - 4 dnech a jejich vývoj trvá zpravidla 20 - 30 dní. Během vývoje se larvy živí převážně pylem z otevřených květů, a rostlinám tak v tomto období téměř neškodí. Poté, co larvy dorostou, padají z porostu na zem a v hloubce 2 - 6 cm se kuklí. Z těchto kukel se následně po 10 - 11 dnech líhnou noví brouci, kteří se stejně jako kukly živí pylem. Během července až září si již brouci hledají úkryty pro přezimování [10].

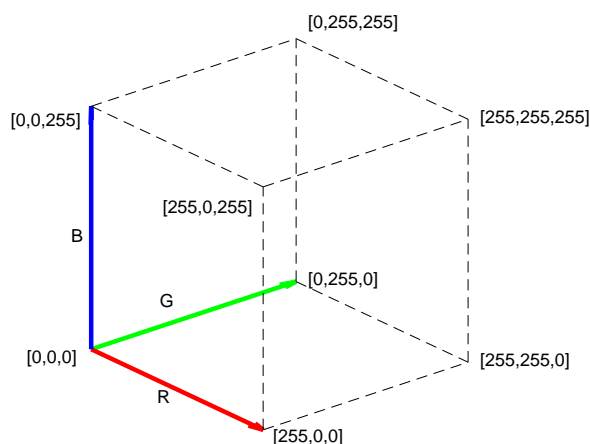
Monitorování aktivity blýskáčka řepkového probíhá přibližně od konce února až začátku března, a to až do počátku květu porostu, kdy se blýskáčci začínají živit jen pylem a nektarem, a plodinám tak již prakticky neškodí [2]. Zpočátku monitorování dosahuje práh škodlivosti počtu 1 - 2 brouků na rostlinu. V době přibližně 14 dní před květem se hodnota zvyšuje na 4 brouky na rostlinu a v období těsně před květem až na 5 - 6 brouků na rostlinu. Je však nutné podotknout, že uvedené prahy jsou pouze orientační a při monitorování silně kvetoucího porostu je třeba hodnoty zdvojnásobit až ztrojnásobit [2].

3.2 Segmentace prahováním

Před další analýzou je nutné vstupní obrazová data vhodně upravit. Tato úprava spočívá v oddělení obrazů hledaných objektů od pozadí. Vzhledem k výraznému kontrastu mezi detekovaným druhem brouka a pozadím, tj. miskou, jsem se rozhodl pro segmentaci prahováním, což je nejjednodušší metoda segmentace. Právě díky své jednoduchosti se jedná o široce využívanou metodu ať už samostatně při jednoduchých úlohách nebo jako součást složitější metody [11].

Tato metoda rozděluje obraz podle hodnoty určité vlastnosti vzhledem ke zvolenému prahu. V mém případě dochází k dělení obrazu na základě barevného odstínu. Pro toto kritérium jsem se rozhodl z důvodu eliminace záměny blýskáčka a krytonosce. Krytonosci totiž mají obdobný tvar i rozměry jako blýskáček, liší se však právě barvou.

Dalším důležitým krokem je zvolení prahové funkce. Vzhledem k segmentaci vstupních obrazových dat na základě barevného odstínu jsem se rozhodl provést dělení obrazu v barevném prostoru RGB (obrázek 3.2). Tento trojrozměrný prostor je definován pravoúhlo souřadnou soustavou, kde každá osa reprezentuje jednu barevnou složku (červená, modrá, zelená).



Obrázek 3.2: Barevný prostor RGB

Jako prahovou funkci jsem následně zvolil obecnou rovnici roviny

$$a \cdot R + b \cdot G + c \cdot B + d = 0, \quad (3.1)$$

kde hodnoty a , b , c jsou prvky normálového vektoru roviny, d je koeficient určující posunutí roviny a R, G, B jsou souřadnice bodu, resp. jeho barevné složky.


Užitím rovnice 3.1 pro prahování vznikne z původního barevného obrazu binární obraz O podle funkce 3.2.

$$O(x, y) = \begin{cases} 0, & \text{když } a \cdot R(x, y) + b \cdot G(x, y) + c \cdot B(x, y) + d > 0, \\ 1, & \text{když } a \cdot R(x, y) + b \cdot G(x, y) + c \cdot B(x, y) + d \leq 0 \end{cases} \quad (3.2)$$


Souřadnice x a y ve funkci 3.2 popisují pozici bodu v obraze a funkce $R(x, y)$, $G(x, y)$ a $B(x, y)$ udávají hodnotu barevných složek daného bodu.

Zcela zásadní pro správnou funkci segmentace je určení prahu, v tomto případě umístění roviny, podle něhož bude segmentace provedena. Rovinu, podle jejíž rovnice bude segmentace provedena, označím písmenem S . K umístění roviny S jsem využil vektor \vec{v} vedoucí z bodu M do bodu P . Bod M odpovídá předem definovanému průměrnému barevnému odstínu blýskáčka a bod P průměrnému barevnému odstínu celého obrazu.

V základní pozici prochází rovina S body M a P a je kolmá na rovinu, která také prochází body M, P , ale je zároveň kolmá na rovinu RG . Pozici roviny S je ještě možné modifikovat dvěma parametry, a to posuvem δ ve směru vektoru \vec{v} , a dále aditivním sklonem β v rovině procházející body M, P kolmé na rovinu RG . Díky závislosti umístění roviny S na pozici bodu P , tj. průměrném barevném odstínu obrazu, dochází k naklonění roviny S podle celkového barevného vyznění obrazu. Příklad možného umístění roviny S je uveden na obrázku 3.3.


**Obrázek 3.3:** Nastavení roviny

Na obrázku 3.4 je vyobrazena rovina oddělující body obrazu. Zelené body zde reprezentují barevné odstíny brouka, a červené naopak odstíny misky. Takto vypadá ideální případ, při kterém je možné oddělit škůdce od pozadí bez chyb.

**Obrázek 3.4:** Rozdělení bodů v RGB prostoru

Většinou však nelze objekty od pozadí oddělit zcela, a je tedy třeba nalézt kompromis mezi zachováním užitečných dat a potlačením těch nepodstatných či rušivých. Takový příklad je zobrazen na obrázku 3.5.

Pomocí experimentů s nastavením parametrů β a δ jsem našel takovou jejich kombinaci, při které byly výsledky klasifikace nejlepší.



Obrázek 3.5: Body v RGB prostoru

Problém při použití segmentace prahováním s globálním prahem mohou způsobovat výrazné rozdíly v osvětlení vstupních obrazových dat [11]. To lze částečně obejít vhodnou úpravou těchto dat, např. pomocí jasové transformace, či použitím odlišné metody určování prahu, např. víceúrovňovým nebo adaptivním prahováním [12]. V mém případě se však problémy s různými úrovněmi osvětlení při analýze trénovacích dat neprojevovaly, a obraz tak nemusel být z tohoto důvodu upravován.

3.3 Detekce a klasifikace objektů


3.3.1 Detekce objektů

Vstupními daty pro detekci objektů jsou binární obrazy získané pomocí segmentace prahováním. Příklad takového obrazu můžeme vidět na obrázku 3.6



Obrázek 3.6: Binární obraz

V tomto obrazu následně dochází k detekci jednotlivých objektů a zároveň jsou uloženy jejich příznaky (obrázek 3.7). Pro každý detekovaný objekt je zjištěna jeho délka, šířka, excentricita, obvod a plocha.



Obrázek 3.7: Příznaky

Pomocí experimentálního zjištění z trénovacích dat jsem určil rozsahy jednotlivých příznaků, do kterých spadají objekty odpovídající jednotlivcům či shlukům hledaného škůdce. Díky tomu je možné odfiltrout objekty, které jsou příliš velké, např. listy, a nebo naopak příliš malé, např. různé drobné nečistoty.

Po odstranění nežádoucích objektů tak zůstanou oblasti, které budou podrobeny klasifikaci.

3.3.2 Klasifikace

Cílem klasifikace je na základě příznaků objektů rozhodnout, zda daný objekt je či není blýskáček řepkový. Pomocí analýzy trénovacích dat jsem určil maximální odchylky příznaků od průměrných hodnot, při kterých ještě bude objekt považován za blýskáčka. Objekt je tedy klasifikován jako blýskáček pokud hodnoty všech jeho příznaků spadají do definovaných intervalů. Ke správné klasifikaci je proto důležité správně odhadnout hodnoty příznaků, kterých by měl průměrný brouk dosahovat. Pro tento účel jsem navrhl a využil následující metody.

3.3.3 Metody pro odhad průměrné hodnoty příznaků

Statická

Tato metoda vychází z předpokladu, že hodnoty pozorovaných příznaků detekovaných brouků se pohybují v omezených rozsazích, a výrazně se tak od sebe neodlišují. Ke splnění tohoto předpokladu je však nutné, aby byly analyzované obrazy pořizovány kolmo nad miskou či deskou, a nevznikaly tak výrazné rozdíly mezi velikostmi brouků v popředí a pozadí.

Vstupem této metody jsou předpokládané rozměry brouka, tj. délka l a šířka w , v pixelech. Z nich jsou následně dopočítány předpokládané hodnoty plochy a excentricity. Pro dopočítání těchto hodnot předpokládám, že tvar blýskáčka je obecně eliptický, plocha se tedy vypočítá podle vztahu

$$S = \pi \cdot \frac{l}{2} \cdot \frac{w}{2}, \quad (3.3)$$

a excentricita podle vztahu

$$e = \frac{\sqrt{\frac{l^2}{2} - \frac{w^2}{2}}}{\frac{l}{2}}. \quad (3.4)$$

Tímto postupem se získají všechny potřebné hodnoty příznaků. Ty jsou však shodné pro veškeré klasifikované obrazy. V případě výraznější změny snímací vzdálenosti je tedy nutné upravit hodnoty l a w .

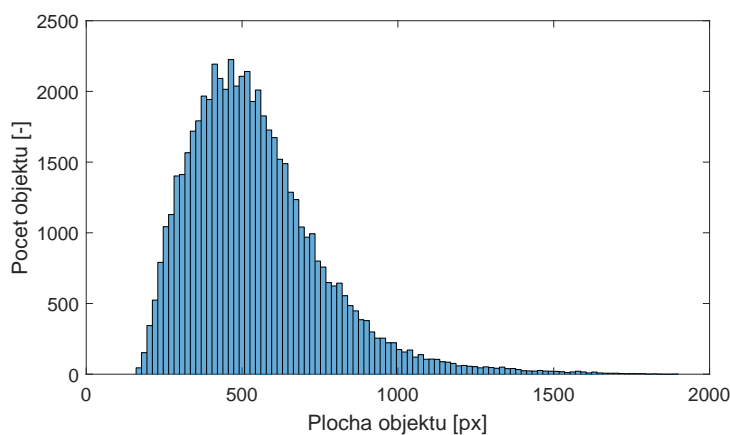
■ Adaptivní

Tato metoda vychází z předchozí uvedené. Vstupem je opět délka l a šířka w . V prvním kroku dojde ke klasifikaci objektů s využitím zadaných hodnot, resp. hodnot dopočítaných podle vtaů 3.3 a 3.4. Následně se z příznaků objektů klasifikovaných jako jednotlivci vypočtou nové průměrné hodnoty příznaků. Pomocí těchto aktualizovaných hodnot se poté provede nová klasifikace.

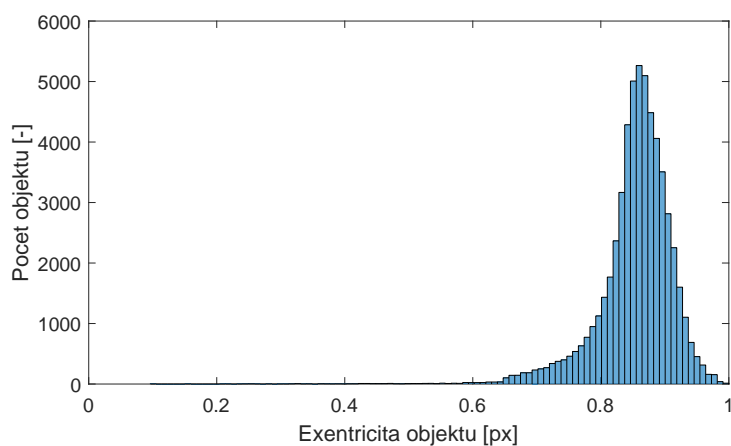
Tímto postupem lze docílit zlepšení oproti statické metodě obzvláště v případech, kdy se v malém rozsahu mění pořizovací vzdálenost obrazů, jelikož dochází k přizpůsobení hodnot pro každý obraz zvlášť.

■ Automatická


Při využití této metody dochází k určení průměrných hodnot příznaků zvlášť pro každý pořizovaný obraz, nevychází se tedy z žádných předem daných hodnot. Nejprve je nutné zanedbat objekty, jejichž příznaky nespádají do vymezených intervalů pro velikost jednotlivce. Následně dojde k vytvoření histogramu pro každý pozorovaný příznak (obrázky 3.8, 3.9, 3.10, 3.11). Hodnota příznaku, při níž dosahuje histogram maxima, a je tedy nejčastější, je označena za průměrnou hodnotu.



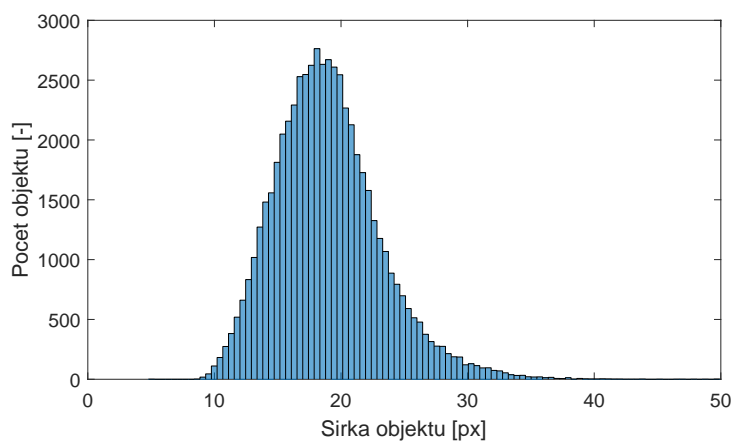
Obrázek 3.8: Histogram ploch objektů



Obrázek 3.9: Histogram excentricit objektů



Obrázek 3.10: Histogram délek objektů



Obrázek 3.11: Histogram šířek objektů

Tato metoda však selhává v případech, kdy se ve vstupním obraze nevyskytují žádné jednotlivě detekovatelné brouci, shluky podobných rozměrů převažují nad jednotlivci nebo pokud se v obraze vyskytuje velké množství menších objektů, které nebyly odstraněny při filtraci. V těchto případech maxima histogramů neodpovídají průměrným hodnotám příznaků jednotlivce, a z tohoto důvodu se výsledky výrazně odlišují od skutečnosti.

3.3.4 Jednotlivci

Klasifikace objektu jako jednotlivce probíhá přímo na základě všech zjišťovaných příznaků. Pokud jejich hodnoty spadají do vymezených intervalů v okolí průměrných hodnot příznaků, je daný objekt považován za jednotlivce blýskáčka řepkového. Příklad takovéto situace je zobrazen na obrázku 3.12.




Obrázek 3.12: Detail jednotlivců

Pokud však hodnoty příznaků do vymezených intervalů nespádají a plocha objektu zároveň přesahuje předpokládanou plochu jednotlivce, je daný objekt považován za shluk. Klasifikace tohoto případu je popsána v 3.3.5.

3.3.5 Shluky

Z důvodu použití kapaliny v miskách mají jednotliví brouci tendenci utvářet shluky, a to jak na volné hladině, tak hlavně u okrajů misky.



Obrázek 3.13: Detail shluku

Na obrázku 3.13 lze vidět, že pokud se brouci nachází blízko u sebe, nedochází při segmentaci prahováním k ideálnímu oddělení jednotlivých objektů a vznikají tak větší spojité oblasti. Z tohoto důvodu nelze uplatnit postup použitý při klasifikaci jednotlivců. V těchto případech je pak počet brouků odhadnut z plochy objektu, a to prostým vydělením průměrnou plochou jednotlivce.

Kapitola 4

Popis programu

Návrh algoritmu a testování použitých metod probíhalo v programu MATLAB [13] ve verzi R2015b. Samotný program byl následně vytvořen v programovacím jazyce Python [14] ve verzi 3.5 za využití vývojového prostředí NetBeans 8.2 [15] doplněného o Python plugin [16]. V programu jsou mimo standardní moduly využity i moduly externí, které jsou uvedeny v tabulce 4.1.

Název	Použití
matplotlib [17]	vizualizace dat
numpy [18]	práce s numerickými daty
PIL [19]	práce s obrázky
psutil [20]	informace o běžících procesech
scikit-image [21]	zpracování obrazu
watchdog [22]	sledování změn v souborovém systému

Tabulka 4.1: Použité externí moduly

Program byl po vytvoření převeden do samostatně spustitelného souboru pomocí nástroje pyinstaller [23]. To umožňuje snadné spuštění bez nutnosti instalace Pythonu a všech potřebných externích modulů na cílovém stroji.

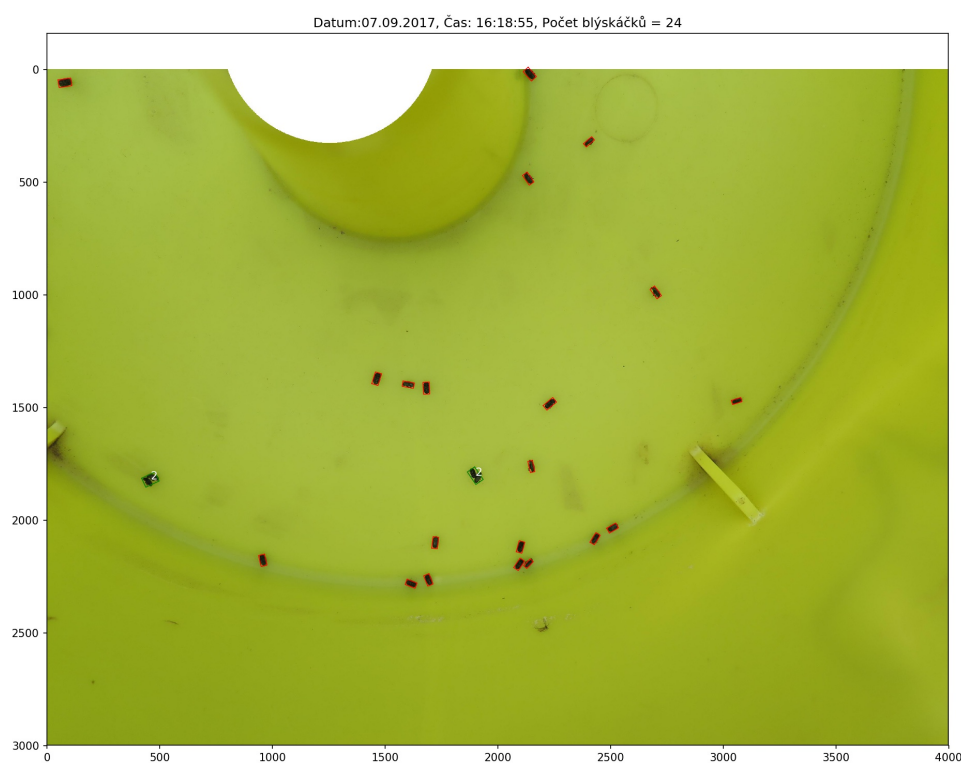
4.1 Popis funkce

Program lze spustit buď přímo pomocí souboru **OIR.exe** nebo přes spouštěč **OIR_launcher.exe**, který obsahuje grafické uživatelské rozhraní a pomocí něhož je také možné provést úpravu nastavení či program ukončit (obrázek 4.2).

Po spuštění programu je nejprve ověřena existence adresáře určeného pro vstupní data, který je v případě neexistence vytvořen. Následně je monitorován vznik nového souboru v daném adresáři. V případě vzniku souboru odpovídajícího formátu, tj. *.jpg, *.png, je tento soubor načten a je na něm provedena segmentace prahováním. Následně jsou ve vzniklém binárním obrazu nalezeny objekty a po odstranění příliš velkých a příliš malých objektů je provedena klasifikace. Výsledky jsou uloženy v obrazové i textové formě a jsou popsány v 4.2. Obrazová data jsou ukládána zvlášť do adresáře, jehož název odpovídá identifikačnímu označení monitorovací stanice. Do odpovídajícího adresáře jsou po ukončení analýzy přesunuty i původní vstupní obrazy. Pokud název souboru neodpovídá požadovanému formátu (popsáno v 5.3), je uložen do zvláštního adresáře určeného pro tyto případy.

4.2 Popis výstupních dat

Jak již bylo uvedeno, program vytváří dva druhy výstupů. První z nich je ve formě obrazových dat (obrázek 4.1). Obsahuje původní obraz s vyznačenými objekty, které byly klasifikovány jako hledaný druh škůdce. V případě shluku je také uveden odhadovaný počet škůdců ve shluku a orámování je barevně odlišeno. Dále je v horní části obrazu uvedeno datum a čas pořízení snímku, stav nabití baterie zařízení (tyto informace jsou získány z názvu obdrženého obrazu) a nakonec celkový počet detekovaných brouků.



Obrázek 4.1: Obrazový výstup


Druhý výstup programu má textovou formu. Obsahuje informace o názvu analyzovaného souboru, identifikační označení monitorovací stanice, dále datum a čas pořízení snímku a nakonec i celkový počet detekovaných škůdců. Tyto informace jsou s výjimkou celkového počtu škůdců získány z názvu analyzovaného obrazu, jehož formát je uveden v 5.3. Textová data jsou ukládána do souboru ve formátu CSV. Jako oddělovací znak je však použit středník. Výstupní data je zobrazena ve formě tabulky v tabulce 4.2.

Stanice	Datum	Čas	Název	Počet
LFC001	20170105	072446	foto_LFC001_20170105_072446_B051.JPG	27
LFC001	20170106	112025	foto_LFC001_20170106_112025_B062.JPG	114
LFC002	20171029	163202	foto_LFC002_20171029_163202_B082.JPG	111
LFC003	20171029	143257	foto_LFC003_20171029_143257_B032.JPG	62
LFC004	20170106	134852	foto_LFC004_20170106_134852_B049.JPG	114
LFC004	20170915	160927	foto_LFC004_20170915_160927_B037.JPG	52
LFC005	20170429	132618	foto_LFC005_20170429_132618_B099.JPG	25
LFC005	20170430	174727	foto_LFC005_20170430_174727_B029.JPG	52

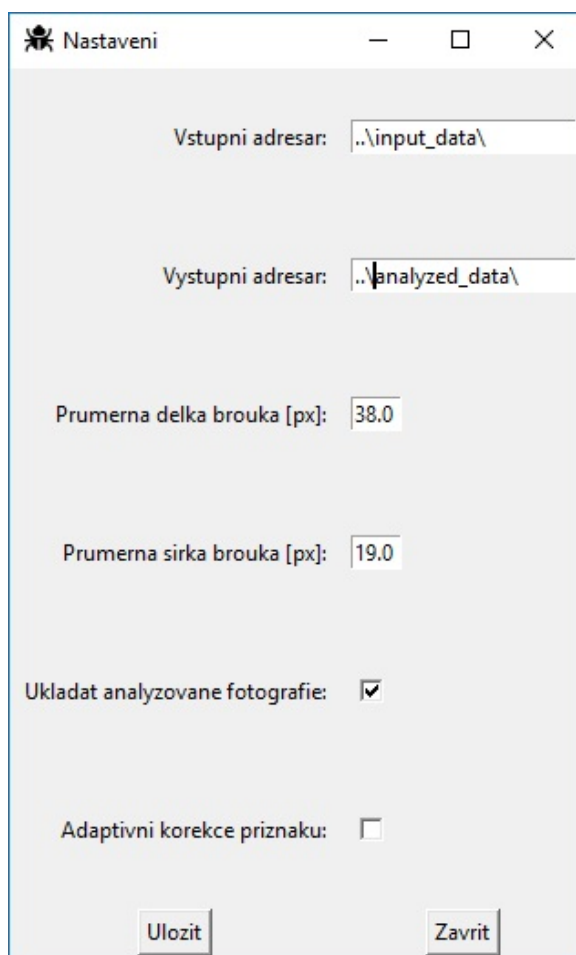
Tabulka 4.2: Výsledky v textové formě

4.3 Ovládání a nastavení

Pro snazší správu obsahuje program jednoduché uživatelské rozhraní (obrázek 4.2), pomocí něhož lze spustit či zastavit rozpoznávání, a dále provést základní úpravy nastavení (obrázek 4.3). To lze modifikovat také přímou úpravou konfiguračního souboru, ve kterém je možné nastavit i další parametry, včetně vlastností prahové funkce.



Obrázek 4.2: Hlavní okno programu



Obrázek 4.3: Okno nastavení


Kapitola 5

Výsledky

Tato kapitola popisuje analyzovaná data a výsledky dosažené využitím algoritmu, a to jak na poskytnutých trénovacích datech, tak později na obrazech pořízených přímo prototypem monitorovacího zařízení.

5.1 Popis trénovacích dat

Data, která byla poskytnuta pro návrh a testování algoritmu, byla pořízena v období od 21.4.2016 do 15.6.2016 pomocí kompaktního fotoaparátu Canon PowerShot G16, a to v rozlišení 12 Mpx s poměrem stran 4:3. Celkem bylo dostupných 1616 obrazů na kterých jsou zachyceny desky žluté barvy i Mörickeho misky, a to jak vyschlé, tak obsahující směs vody a saponátu. Obrazy byly pořizovány ručně, a jsou tak nasnímány z různých úhlů i vzdáleností. Na 1187 obrazech byly ručně označeny pozice jednotlivých objektů a byl také uveden jejich typ, tj. blýskáček, krytonosec, apod. Pro každý obraz byly tyto pozice uloženy v textovém souboru ve formátu x_{TL} , y_{TL} , x_{BR} , y_{BR} , $typ_objektu$, kde hodnoty x_{TL} , y_{TL} , x_{BR} a y_{BR} označují souřadnice obdélníku rámuujícího vybraný objekt (obrázek 5.1).



Obrázek 5.1: Označení brouka

Z analyzovaných obrazů bylo před použitím algoritmu odstraněno pozadí misek a pásů, a to z důvodu falešných detekcí. Tato úprava byla možná, jelikož při reálném nasazení je využita obdélníková miska, která zabírá celé zorné pole fotoaparátu, a není tedy nutné zabývat se automatickým odstraněním pozadí misky.

5.2 Výsledky na trénovacích datech

Pro otestování funkce algoritmu bylo využito všech 1187 obrazů s dostupnými souřadnicemi hledaných objektů. Tyto obrazy byly rozděleny do 7 sérií, které se navzájem liší dobou pořízení a typem záchytného zařízení. V trénovacích datech se vyskytuje celkem 88 926 blýskáček, což v průměru činí téměř 75 blýskáček na jeden obraz.

V tabulkách získaných výsledků jsou použity následující zkratky.

Zkratka	Význam
N	skutečný počet blýskáček
N_alg	počet blýskáček získaný pomocí algoritmu
TP	počet skutečně pozitivních pozorování
FP	počet falešně pozitivních pozorování
TN	počet skutečně negativních pozorování
FN	počet falešně negativních pozorování
TPR	míra skutečně pozitivních pozorování
FPR	míra falešně pozitivních pozorování
TNR	míra skutečně negativních pozorování

Tabulka 5.1: Význam použitých zkratk

Hodnoty TPR, FPR a TNR jsou vypočítány pomocí vztahů 5.1, 5.2 a 5.3.

$$TPR = \frac{TP}{TP + FN} \quad (5.1)$$

$$FPR = \frac{FP}{TN + FP} \quad (5.2)$$

$$TNR = \frac{TN}{TN + FP} = 1 - FPR \quad (5.3)$$

5.2.1 Klasifikace s automatickým odhadem průměrných hodnot příznaků

série	N _{alg} [-]	N[-]	TP[-]	FP[-]	TN[-]	FN[-]	TPR[%]	FPR[%]	TNR[%]
1	5085	2486	2441	2644	5122	45	98,19	34,05	65,95
2	5657	5288	5136	521	1589	152	97,13	24,69	75,31
3	7072	5959	5764	1308	7188	195	96,73	15,40	84,60
4	18294	18721	17891	403	4092	830	95,57	8,97	91,03
5	13624	12960	11872	1752	2681	1088	91,60	39,52	60,48
6	18106	11545	10687	7419	12363	858	92,57	37,50	62,50
7	43826	31967	29967	13859	39192	2000	93,74	26,12	73,88
celkem	111664	88 926	83758	27906	72227	5168	94,19	27,87	72,13

Tabulka 5.2: Výsledky klasifikace s využitím automatického odhadu průměrných hodnot příznaků

Tabulka 5.2 prezentuje výsledky klasifikace dosažené při automatickém odhadu průměrných hodnot příznaků. TPR v tomto případě dosahuje hodnoty 94,19 %, což lze považovat za dostatečnou míru. Oproti tomu je však hodnota TNR pouze 72,13 %, což znamená, že algoritmus v tomto případě chybně považuje velký počet objektů za blýskáčka. Z tohoto důvodu výsledný detekovaný počet brouků výrazně převyšuje ten skutečný. Úroveň klasifikace je tedy při použití této metody nedostatečná.

5.2.2 Klasifikace se statickým odhadem průměrných hodnot příznaků

série	N_alg[-]	N[-]	TP[-]	FP[-]	TN[-]	FN[-]	TPR[%]	FPR[%]	TNR[%]
1	5089	2486	2460	2629	5096	26	98,95	34,03	65,97
2	6572	5288	5192	1380	1587	96	98,18	46,51	53,49
3	6601	5959	5498	1103	7286	461	92,26	13,15	86,85
4	17295	18721	17113	182	4128	1608	91,41	4,22	95,78
5	12650	12960	11611	1039	2683	1349	89,59	27,92	72,08
6	11109	11545	10082	1027	12969	1463	87,33	7,34	92,66
7	31521	31967	27617	3904	39642	4350	86,39	8,97	91,03
celkem	90837	88926	79573	11264	73391	9353	89,48	13,31	86,69

Tabulka 5.3: Výsledky klasifikace s využitím statického odhadu průměrných hodnot příznaků

Z tabulky 5.3 je patrné, že při využití statické metody pro určení průměrné hodnoty je oproti automatickému určení dosaženo horší hodnoty TPR, konkrétně 89,48 %, avšak výrazně se sníží počet objektů chybně klasifikovaných jako hledaný druh škůdce. Celkový detekovaný počet škůdců se tedy více blíží skutečné hodnotě, avšak za cenu většího počtu falešně negativních pozorování.

5.2.3 Klasifikace s adaptivním odhadem průměrných hodnot příznaků

série	N_alg[-]	N[-]	TP[-]	FP[-]	TN[-]	FN[-]	TPR[%]	FPR[%]	TNR[%]
1	3588	2486	2421	1167	7715	65	97,39	13,14	86,86
2	5614	5288	5166	448	890	122	97,69	33,48	66,52
3	6917	5959	5769	1148	6849	190	96,81	14,36	85,64
4	18201	18721	17995	206	3342	726	96,12	5,81	94,19
5	12613	12960	11918	695	2280	1042	91,96	23,36	76,64
6	11139	11545	10531	608	4215	1014	91,22	12,61	87,39
7	33814	31967	28626	5188	52990	3341	89,55	8,92	91,08
celkem	91886	88926	82426	9460	78281	6500	92,69	10,78	89,22

Tabulka 5.4: Výsledky klasifikace s využitím adaptivního odhadu průměrných hodnot příznaků

Z výsledků uvedených v tabulce 5.4 lze pozorovat, že při využití adaptivní metody určení průměrných hodnot příznaků je dosaženo nejlepších kombinovaných výsledků ze všech tří použitých metod. Z tohoto důvodu je tato metoda použita i ve finální verzi rozpoznávacího algoritmu.

5.3 Popis reálných dat

Data pochází z období od 9.5.2017 do 19.5.2017 z demonstračního řepkového pole ČZU a byla pořízena pomocí prototypu monitorovacího zařízení (obrázek 5.2), které bylo vyrobeno třetí stranou. Pořizované obrazy mají rozlišení 8 Mpx v poměru stran 4:3. Celkem bylo pořízeno 669 obrazů z nichž však byla velká část vyřazena z důvodu nedostatečného osvětlení či nízké ostrosti obrazu.

Pro následné zpracování mají obrazy odesílané z monitorovacího zařízení upravené názvy. Formát názvů je následující
foto__ < IDstanice > __ < datum > _ < čas > _ < baterie > .




Obrázek 5.2: Prototyp monitorovacího zařízení

5.4 Výsledky na reálných datech

Při uplatnění algoritmu na data pořízena prototypem monitorovacího zařízení nebyla úroveň dosažených výsledků uspokojivá. Důvodem byl četný výskyt větších druhů hmyzu, které se v trénovacích datech neobjevovaly. Tento rozdíl je patrný při pohledu na obrázky 5.3 a 5.4. Na obrázku 5.3 se vyskytují převážně blýskáčci, případně krytonosci, a dále menší části lístků a trávy. Oproti tomu na obrázku 5.4 se mimo blýskáčků objevuje celá řada větších a tmavě zbarvených druhů hmyzu. To zapříčinilo výrazné nadhodnocení výsledků, jelikož se vzhledem k trénovacím datům s tímto problémem nepočítalo, a větší objekty tak byly považovány za shluky blýskáčků (obrázek 5.5).




Obrázek 5.3: Obraz poskytnutý pro návrh algoritmu



Obrázek 5.4: Obrázek pořízený prototypem monitorovacího zařízení

Na obrázku 5.5 je zobrazen detail chybné klasifikace větších druhů hmyzu jako shluku blýskáček. Je vidět, že jedinec blýskáčka byl rozpoznán správně, avšak došlo zde k chybné klasifikaci dvou větších druhů hmyzu jako shluků, a tím došlo k výraznému nadhodnocení výsledků.



Obrázek 5.5: Detail chybné klasifikace

Jako částečné řešení tohoto problému se zdálo být omezení horní hranice počtu škůdců ve shluku a případné zanedbání objektů, které tuto hranici překročili. A i když toto řešení přineslo zlepšení, výsledný počet falešných pozorování byl natolik vysoký, že získané výsledky byly stále nedostatečné. Vzhledem k pozdějšímu začátku testování s využitím prototypu monitorovacího zařízení již nezbýval dostatek času pro nalezení vhodného řešení a jeho implementace.

5.5 Možná vylepšení

Pro vylepšení se nabízí několik oblastí. První z nich je vzhledem k neuspokojivým výsledkům na datech pořízených prototypem monitorovacího zařízení zlepšení klasifikace objektů ve shlucích. K řešení tohoto problému je možné využít hned několik metod. První možností je použití Houghovy transformace pro detekci eliptických objektů v obraze. Výhodou je robustnost této metody, a s ní související odolnost vůči šumu ve stupních datech [24]. Další možností, která by měla vést ke zlepšení klasifikace objektů ve shlucích, je uplatnění postupů uvedených v [25]. V této práci se autoři zabývají problémem segmentace překrývajících se objektů eliptického tvaru, což je případ velice podobný tomu uvedenému v této práci.

Druhou oblastí, o které bych se rád zmínil, jsou vylepšení související s možnostmi pro koncového uživatele. Mezi ně patří implementace upozornění v případě, kdy hladina nabití akumulátoru monitorovacího zařízení poklesne pod definovanou úroveň. Dalším možností je upozornění v případě potřeby vyprázdnění záchytné misky z důvodu přílišného zaplnění hmyzem, a z toho vyplývající nemožnosti detekce škůdců.



Kapitola 6

Závěr

Úkolem této práce bylo navrhnout a implementovat algoritmus schopný rozpoznat blyškáčka řepkového v obraze a určit jeho celkový počet v monitorovaném záchytném zařízení.

Návrh algoritmu i využívaných metod probíhal v programu MATLAB. Finální řešení bylo vypracováno v programovacím jazyce Python.

Algoritmus byl navržen na základě poskytnutých trénovacích dat, která dodal zadavatel práce. Na těchto datech bylo také provedeno testování algoritmu a využívaných metod.

Ověření funkce algoritmu v reálných podmínkách probíhalo na prototypu monitorovacího zařízení vyrobeného třetí stranou. Kvůli pozdnímu nasazení tohoto zařízení, a s tím souvisejícími klimatickými podmínkami, se však v pořízených obrazech vyskytovalo velké množství odlišných druhů škůdců, se kterými se s ohledem na trénovací data nepočítalo. Z tohoto důvodu byly výsledky na těchto datech neuspokojivé.

S ohledem na výsledky dosažené na trénovacích datech však lze předpokládat, že po dokončení vývoje prototypu monitorovacího zařízení a při testování v odpovídajícím ročním období budou výsledky přijatelnější. Pro dosažení optimální úrovně klasifikace bude však stále třeba algoritmus modifikovat.

Příloha A

Literatura

- [1] ROTREKL Jiří. Jak načasovat zásah proti časným škůdcům řepky. In: *Výzkumný ústav pícninářský, spol. s r. o. Troubsko* [online]. [cit. 22.05.2017]. Dostupné z: http://www.vupt.cz/content/files/pub_07/rot_07_03.pdf
- [2] KAZDA, Jan a Josef ŠKEŘÍK. *Metodika integrované ochrany řepky*. 1. Praha: SPZO, 2008. ISBN 9788087065082.
- [3] LeadingFarmers.cz. [online]. Copyright ©2017 LeadingFarmers a.s. [cit. 25.05.2017]. Dostupné z: <http://www.leadingfarmers.cz/>
- [4] Blýskáček řepkový a jeho škodlivost. Agromanual.cz. [online]. [cit. 20.05.2017]. Dostupné z: <http://www.agromanual.cz/cz/clanky/ochrana-rostlin-a-pestovani/skudci/blyskacek-repkovy-a-jeho-skodlivost>
- [5] Ochrana proti blýskáčkovi řepkovému. Úroda [online]. [cit. 20.05.2017]. Dostupné z: <http://uroda.cz/ochrana-proti-blyskackovi-repkovemu/>
- [6] Mörickeho miska. In: *Agromanual.cz* [online]. [cit. 20.05.2017]. Dostupné z: http://www.agromanual.cz/userfiles/image/gall_kalendar/02-2012/02_obr_krytonosec_r_0634.jpg
- [7] TRAPVIEW - Automated pest monitoring. [online]. [cit. 22.05.2017]. Dostupné z: <http://www.trapview.com/v2/en/>
- [8] TRAPVIEW. [online]. [cit. 22.5.2017]. Dostupné z: http://www.trapview.com/v2/content/03-home/hi_res_trap_image_std.jpg



Příloha B

Obsah přiloženého DVD

Na přiloženém DVD se kromě elektronické verze této práce nachází zdrojový kód vypracovaného programu v programovacím jazyce Python, samostatně spustitelná verze rozpoznávacího programu a obrazová data použitá k návrhu a testování algoritmu. Dále je zde umístěn zdrojový kód v jazyce Matlab, který byl použit pro návrh algoritmu a testování použitých metod, a také zdrojové soubory této práce ve formátu $\text{L}^{\text{A}}\text{T}_{\text{E}}\text{X}$

Obsah DVD je rozdělen do následujících adresářů:

- **latex** - zdrojové soubory textu této práce ve formátu $\text{L}^{\text{A}}\text{T}_{\text{E}}\text{X}$
- **matlab** - zdrojové soubory algoritmu v jazyce Matlab
- **oir_bin** - samostatně spustitelná verze rozpoznávacího programu
- **python** - zdrojové soubory programu v jazyce Python
- **training_data** - trénovací obrazová data a textové soubory se souřadnicemi a popisem objektů