

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Katedra informačního inženýrství



Diplomová práce

**Nástroj pro rozpoznání nesené potravy pro účel
analýzy dat serveru PtaciOnline.cz**

Bc. Adéla Hamplová

© 2019 ČZU v Praze

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Provozně ekonomická fakulta

ZADÁNÍ DIPLOMOVÉ PRÁCE

Bc. Adéla Hamplová

Informatika

Název práce

Nástroj pro rozpoznání nesené potravy pro účel analýzy dat serveru PtaciOnline.cz

Název anglicky

The birds nests recognition tool used for PtaciOnline.cz data analysis

Cíle práce

Cílem je zpracovat datový proud (či výstup formou jednotlivých snímků uložených v definované složce) z webové kamery umístěné v hnízdě (ptačí budce) sýkor. Za pomoci nástrojů umělé inteligence (konvolučních neuronových sítí), dat ze serveru PtaciOnline.cz a nástroje BirdObserver provozovaného na serveru <http://birdobserver.czu.cz/BirdObserver/> se pokusit klasifikovat druh nesené potravy rodičem. Pro tento účel využijte nástroj TensorFlow nebo Deeplearning4j

Metodika

Sledujte následující postup:

- Prostudujte možnosti použití nástroje TensorFlow, Deeplearning4j a odborné literatury, zabývající se umělou inteligencí.
- Na základě studia literatury a rešeršní práce proveďte výběr vhodného řešení pro definovanou úlohu vyhledání potravy nesené rodičem v ptačím hnízdě.
- Implementujte řešení
- Ověřte řešení v laboratorních podmínkách dat ze serveru <http://birdobserver.czu.cz/BirdObserver/>
- Zhodnoťte řešení a definujte závěry
- Doporučte další možné směry vývoje

Doporučený rozsah práce

60

Klíčová slova

TensorFlow, Konvoluční neuronová síť, Umělá inteligence , Ptačí hnízdo, Potrava, BirdObserver

Doporučené zdroje informací

RIPLEY, B D. *Pattern recognition and neural networks*. Cambridge ; New York: Cambridge University Press, 1996. ISBN 0521460867.

Soft Computing: Integrating Evolutionary, Neural, and Fuzzy Systems, Andrea Tettamanzi, Marco Tomassini, Springer Science & Business Media, 7. 9. 2001

Předběžný termín obhajoby

2018/19 LS – PEF

Vedoucí práce

Ing. Josef Pavlíček, Ph.D.

Garantující pracoviště

Katedra informačního inženýrství

Elektronicky schváleno dne 26. 2. 2019

Ing. Martin Pelikán, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 26. 2. 2019

Ing. Martin Pelikán, Ph.D.

Děkan

V Praze dne 06. 03. 2019

Čestné prohlášení

Prohlašuji, že svou diplomovou práci "Nástroj pro rozpoznání nesené potravy pro účel analýzy dat serveru PtaciOnline.cz" jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou citovány v práci a uvedeny v seznamu použitých zdrojů na konci práce. Jako autorka uvedené diplomové práce dále prohlašuji, že jsem v souvislosti s jejím vytvořením neporušila autorská práva třetích osob.

V Praze dne 19.3.2019

Poděkování

Ráda bych touto cestou poděkovala panu Ing. Josefu Pavlíčkovi, Ph.D., vedoucímu této diplomové práce, za nekonečnou trpělivost, neocenitelnou ochotu a maximálně profesionální vedení. Dále bych chtěla poděkovat své rodině, a to hlavně svému manželovi, mamince a babičce, za pomoc se zajištěním času potřebného na vznik této práce.

Nástroj pro rozpoznání nesené potravy pro účel analýzy dat serveru PtaciOnline.cz

Abstrakt

Tato diplomová práce se zabývá využitím konvolučních neuronových sítí k automatickému rozpoznání určených objektů na snímcích pořízených webovými kamerami v chytrých ptačích budkách v rámci projektu PtaciOnline.cz, a to konkrétně objekty nesené potravy, vajec a dospělých sýkor koňader.

V teoretické části práce je popsáno jak obecné fungování neuronových sítí a jejich tréninku, a to jak pomocí nástroje Tensorflow, tak pomocí DeepLearning4J, a dále výběr nástrojů, metodik a klasifikace kvality modelů k praktické části.

V praktickém řešení je pak popsáno, jakým způsobem jednotlivé modely vznikly, a následně je samotné rozpoznání metodicky hodnoceno na základě předem uvedených kritérií.

Výsledkem práce je vznik vytrénovaných a otestovaných modelů schopných rozpoznat určené objekty v rámci obrázků, zakomponovatelných do projektu PtaciOnline.cz ve formě softwarové knihovny vytvořené v programovacím jazyce JAVA.

Klíčová slova: TensorFlow, Konvoluční neuronová síť, Umělá inteligence, Ptačí hnízdo, Potrava, BirdObserver, DeepLearning4J, detekce vajec, detekce potravy, detekce dospělé sýkory koňadry

The birds' nests recognition tool used for PtaciOnline.cz data analysis

Abstract

This diploma thesis deals with using convolutional neural networks to automatically recognize chosen objects on snaps taken by web cameras placed in smart bird nest-boxes within the project PtaciOnline.cz, specifically carried food, eggs and adult Great Tits.

The theoretical part speaks of general functionality of neural networks and their training, either with the tool TensorFlow or DeepLearning4J, also including options of tools, methodologies and classifications of model quality for the practical part.

The practical part speaks of how each of the models came to exist, and then the recognition of chosen object is methodically rated using advance-stated criteria.

The result of this thesis is the creation of trained and tested models capable of recognizing the chosen objects on snaps, incorporable to the project PtaciOnline.cz in the form of a library written in JAVA.

Keywords: TensorFlow, Convolutional Neural Network, Artificial Intelligence, Bird's Nest, Food, BirdObserver, DeepLearning4J, detection of eggs, detection of food, detection of adult Great Tits

Obsah

1 Úvod.....	6
2 Cíl práce a metodika	7
3 Teoretická východiska	9
3.1 Umělé neuronové sítě.....	9
3.1.1 Motivace k výzkumu neuronových sítí.....	11
3.1.2 Typy modelů neuronových sítí	11
3.1.3 Konvoluční neuronové sítě	12
3.2 Strojové učení.....	12
3.2.1 Kategorie.....	13
3.2.2 Tensor	13
3.2.3 Hluboké učení	14
3.3 Strojové vidění	16
3.3.1 Popis.....	16
3.3.2 Metody	17
3.3.3 Vývoj úloh	18
3.4 Projekt Ptáci Online	18
3.5 Rozpoznání obrazu pomocí TensorFlow Object Detection API.....	20
3.5.1 TensorFlow	20
3.5.2 Hardwarová a softwarová základna potřebná k trénování modelů určených k rozpoznání obrazu	20
3.5.3 Postup při vytváření konkrétního modelu.....	20
3.5.3.1 První krok	21
3.5.3.2 Druhý krok.....	22
3.5.3.3 Třetí krok	22
3.5.3.4 Čtvrtý, pátý a šestý krok	23
3.5.3.5 Sedmý krok.....	23
3.5.3.6 Osmý až desátý krok	24
3.6 Rozpoznání obrazu pomocí DeepLearning4J	25
3.7 Metody kritického zhodnocení kvality modelu.....	25
4 Vlastní práce	28
4.1 Výběr prostředí.....	28
4.2 Zajištění dat	28
4.2.1 Třídění dat.....	28
4.3 Příprava dat	29
4.3.1 Rozpoznání nesené potravy	29
4.3.2 Rozpoznání vajec ve snůšce	30

4.3.3	Rozpoznání dospělého jedince.....	32
4.4	Zpracování dat pro trénink	33
4.5	Trénink	34
4.6	Evaluace a verifikace	35
4.6.1	Prostředí k testování.....	35
4.6.2	Příprava testovacích dat	37
4.6.3	Evaluace modelu rozpoznávajícího nesenou potravu	39
4.6.3.1	Threshold 0,3	39
4.6.3.2	Threshold 0,1	44
4.6.3.3	Threshold 0,05	48
4.6.3.4	Závěr.....	53
4.6.4	Evaluace druhé verze modelu rozpoznávajícího nesenou potravu	53
4.6.4.1	Denní světlo	53
4.6.4.2	Tma.....	54
4.6.4.3	Černobílý noční přísvit	54
4.6.4.4	Fialový noční přísvit.....	55
4.6.4.5	Shrnutí a závěr	55
4.6.5	Evaluace modelu rozpoznávajícího vejce	56
4.6.5.1	Metoda testování	56
4.6.5.2	Testování	56
4.6.5.3	Shrnutí a závěr	57
4.6.6	Evaluace modelu rozpoznávajícího dospělého jedince	57
4.6.6.1	Threshold 0,3	58
4.6.6.2	Threshold 0,1	63
4.6.6.3	Threshold 0,05	67
4.6.6.4	Závěr.....	72
4.7	Verifikace a implementace hotových modelů.....	72
4.8	Uvedení do praxe	72
5	Výsledky a diskuse	73
5.1	Model k rozpoznání nesené potravy	73
5.1.1	Výsledky	73
5.1.2	Prostor pro zlepšení	74
5.2	Model k rozpoznání vajec	74
5.2.1	Výsledky	74
5.2.2	Prostor pro zlepšení	74
5.3	Model k rozpoznání dospělého jedince	74
5.3.1	Výsledky	74
5.3.2	Prostor pro zlepšení	74

5.4	Možnosti využití práce a návrh na budoucí rozvoj	75
6	Závěr.....	76
7	Seznam použitých zdrojů	78

Seznam obrázků

Obrázek 1-	Základní model umělého neuronu	10
Obrázek 2 -	Aktivační funkce threshold	11
Obrázek 3 -	Konvoluční neuronová síť	12
Obrázek 4 -	Grafické znázornění tensoru	14
Obrázek 5 -	Hierarchie UI	15
Obrázek 6 -	Ilustrace algoritmu zpětného šíření chyby	16
Obrázek 7 -	Struktura systému počítačového vidění	17
Obrázek 8 -	Schéma projektu Ptáci Online.....	19
Obrázek 9 -	Označování objektu v programu labelImg.py	21
Obrázek 10 -	Obsah souboru .xml vytvořeného programem labelImg.py.....	22
Obrázek 11 -	Rozpoznaný objekt v obrázku.....	24
Obrázek 12 -	Křivka přesnosti a citlivosti	26
Obrázek 13 -	Zřetelně viditelná nesená potrava	30
Obrázek 14-	Méně zřetelně viditelná nesená potrava	30
Obrázek 15 -	Zřetelně viditelná vejce	31
Obrázek 16 -	Vejce částečně zakrytá vylihnutými mlád'aty	31
Obrázek 17 -	Vejce částečně zakrytá mlád'aty a skořápka	32
Obrázek 18 -	Zřetelný obrázek dospělé sýkory	33
Obrázek 19 -	Méně zřetelný obrázek dospělé sýkory	33
Obrázek 20 -	Označování objektu v obrázku v programu LabelImg.py	34
Obrázek 21 -	Webové rozhraní BirdObserver po přihlášení	35
Obrázek 22 -	Výběr modelu k testování na serveru USPIN.cz	36
Obrázek 23 -	roztažený snímek na 416x416 pixelů s rozpoznaným objektem nesené potravy	37
Obrázek 24 -	Bezchybné rozpoznání nesené potravy na snímku pořízeného za denního světla při thresholdu 0,03	40
Obrázek 25 -	Bezchybné rozpoznání nesené potravy na snímku pořízeného za tmy při thresholdu 0,3.....	41
Obrázek 26 -	Bezchybné rozpoznání nesené potravy na snímku pořízeného za černobílého nočního přísvisu při thresholdu 0,3	42
Obrázek 27-	Bezchybné rozpoznání nesené potravy na snímku pořízeného za fialového nočního přísvisu při thresholdu 0,3	43
Obrázek 28 -	Falešná detekce – zaměnění zobáčků za nesenou potravu na snímku pořízeném za denního světla při thresholdu 0,1	44
Obrázek 29 -	Vícenásobná detekce nesené potravy na snímku pořízeném za tmy při thresholdu 0,1.....	45
Obrázek 30 -	Vícenásobná detekce nesené potravy na snímku pořízeném za černobílého nočního přísvisu při thresholdu 0,1	46
Obrázek 31 -	Vícenásobná detekce nesené potravy na snímku pořízeném za fialového nočního přísvisu při thresholdu 0,1	47
Obrázek 32 -	Falešná a vícenásobná detekce nesené potravy na snímku pořízeném za denního světla při thresholdu 0,05	49

Obrázek 33 - Vícenásobná detekce nesené potravy na snímku pořízeném za tmy při thresholdu 0,05.....	50
Obrázek 34 - Falešná detekce nesené potravy na snímku pořízeném za černobílého nočního při thresholdu 0,05	51
Obrázek 35 - Vícenásobná detekce nesené potravy na snímku pořízeném za fialového nočního při thresholdu 0,05	52
Obrázek 36 - Pozitivní halucinace modelu rozpoznávajícího dospělé ptáky za denního světla při thresholdu 0,3	59
Obrázek 37 - Falešná detekce dospělého ptáka za denního světla při thresholdu 0,3	59
Obrázek 38 - Pozitivní halucinace modelu rozpoznávajícího dospělé ptáky za tmy při thresholdu 0,3.....	60
Obrázek 39 - Úspěšná detekce dospělého jedince za černobílého přisvitu při thresholdu 0,3	61
Obrázek 40 - Úspěšná detekce dospělého jedince za černobílého přisvitu při thresholdu 0,3	62
Obrázek 41 - Mnohonásobné nalezení stejného objektu za denního světla při thresholdu 0,1	64
Obrázek 42 - Mnohonásobné nalezení stejných objektů za tmy při thresholdu 0,1	65
Obrázek 43 - Mnohonásobné nalezení stejného objektu za černobílého nočního přisvitu při thresholdu 0,1.....	66
Obrázek 44 - Mnohonásobné nalezení stejného objektu za fialového nočního přisvitu při thresholdu 0,1.....	67
Obrázek 45 - Extrémní pozitivní halucinace za denního světla při thresholdu 0,05	68
Obrázek 46 - Extrémní pozitivní halucinace za tmy při thresholdu 0,05	69
Obrázek 47 - Pozitivní a negativní halucinace při thresholdu 0,05	70
Obrázek 48 - Falešná detekce sýkory za fialového nočního přisvitu při thresholdu 0,05 ...	71

Seznam tabulek

Tabulka 1 - Výpočet vah světelných kategorií	38
Tabulka 2 - Výsledky rozpoznání nesené potravy na snímcích za denního světla při thresholdu 0,3.....	39
Tabulka 3 - Výsledky rozpoznání nesené potravy na snímcích za tmy při thresholdu 0,3 ..	40
Tabulka 4 - Výsledky rozpoznání nesené potravy na snímcích za černobílého nočního přisvitu při thresholdu 0,3	41
Tabulka 5 - Výsledky rozpoznání nesené potravy na snímcích za fialového nočního přisvitu při thresholdu 0,3	42
Tabulka 6 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,3.....	43
Tabulka 7 - Výsledky rozpoznání nesené potravy na snímcích za denního světla při thresholdu 0,1.....	44
Tabulka 8 - Výsledky rozpoznání nesené potravy na snímcích za tmy při thresholdu 0,1 ..	45
Tabulka 9 - Výsledky rozpoznání nesené potravy na snímcích za černobílého nočního přisvitu při thresholdu 0,1	46
Tabulka 10 - Výsledky rozpoznání nesené potravy na snímcích za fialového nočního přisvitu při thresholdu 0,1	47
Tabulka 11 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,1	48
Tabulka 12 - Výsledky rozpoznání nesené potravy na snímcích za denního světla při thresholdu 0,05.....	48
Tabulka 13 - Výsledky rozpoznání nesené potravy na snímcích za tmy při thresholdu 0,05	49

Tabulka 14 - Výsledky rozpoznání nesené potravy na snímcích za černobílého nočního přisvitu při thresholdu 0,05	50
Tabulka 15 - Výsledky rozpoznání nesené potravy na snímcích za fialového nočního přisvitu při thresholdu 0,05	51
Tabulka 16 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,05.....	52
Tabulka 17- Závěrečné zhodnocení metodických metrik modelu rozpoznávajícího nesenou potravu	53
Tabulka 18 - Výsledky rozpoznání nesené potravy na snímcích za denního světla při thresholdu 0,07.....	54
Tabulka 19 - Výsledky rozpoznání nesené potravy na snímcích za tmy při thresholdu 0,07	54
Tabulka 20 - Výsledky rozpoznání nesené potravy na snímcích za černobílého nočního přisvitu při thresholdu 0,07	55
Tabulka 21 - Výsledky rozpoznání nesené potravy na snímcích za fialového nočního přisvitu při thresholdu 0,07	55
Tabulka 22 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,07.....	56
Tabulka 23 - Výsledky modelu rozpoznávajícího vejce při různých hodnotách thresholdu	57
Tabulka 24 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,3.....	58
Tabulka 25 - Výsledky rozpoznání dospělých sýkor na snímcích za tmy při thresholdu 0,3	60
Tabulka 26 - Výsledky rozpoznání dospělých sýkor na černobílých snímcích při thresholdu 0,3	61
Tabulka 27 - Výsledky rozpoznání dospělých sýkor na snímcích s fialovým nočním přisvitem při thresholdu 0,3	62
Tabulka 28 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,3.....	63
Tabulka 29 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,1.....	63
Tabulka 30 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,1.....	64
Tabulka 31 - Výsledky rozpoznání dospělých sýkor na černobílých snímcích při thresholdu 0,1	65
Tabulka 32 - Výsledky rozpoznání dospělých sýkor na snímcích s fialovým nočním přisvitem při thresholdu 0,1	66
Tabulka 33 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,1.....	67
Tabulka 34 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,05.....	68
Tabulka 35 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,05.....	69
Tabulka 36 - Výsledky rozpoznání dospělých sýkor na černobílých snímcích při thresholdu 0,05	69
Tabulka 37 - Výsledky rozpoznání dospělých sýkor na snímcích s fialovým nočním přisvitem při thresholdu 0,05	70
Tabulka 38 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,05.....	71
Tabulka 39 - Závěrečné zhodnocení metodických metrik modelu rozpoznávajícího dospělé jedince.....	72

1 Úvod

Při výběru diplomové práce jsem volila takové téma, které by se týkalo umělé inteligence. Takové projekty mají podle mého názoru největší přínos, protože využívání umělé inteligence je v současné době sice již běžnou oblastí, ale stále má vysoký potenciál, neustále se rozvíjí a usnadňuje lidem jak práci, tak běžný život.

Z tohoto důvodu jsem požádala vedoucího této práce, pana doktora Pavlíčka, o téma, a tak bylo mi nabídnuto zapojení se do již mnoho let běžícího projektu Ptáci Online, v rámci kterého se umělá inteligence vytvořená během vzniku této diplomové práce využije k analýze dat sebraných z kamer umístěných v ptačích budkách, a tato data se budou moci dále využít například pro vědecké nebo vzdělávací účely. Podrobnější informace o tomto projektu budou uvedeny dále v práci.

V roce 1967 řekl Marvin Minsky: „*Umělá inteligence je věda o vytváření strojů nebo systémů, které budou při řešení určitého úkolu užívat takového postupu, který, kdyby ho dělal člověk, bychom považovali za projev jeho inteligence.*” (1) Tato definice samozřejmě není jedinou, ale podle mého názoru je v této souvislosti nejvhodnější.

Jedním z mnoha kritických faktorů úspěšné analýzy dat je totiž časová a potažmo prostředková náročnost. Pokud je stroj schopen data pouze zachytit, ale analýzu poté provádí lidé, náročnost takové analýzy je nejen nepřiměřeně vysoká, ale také nepředvídatelná, a proto je potřeba vytvořit stroj, který bude sám inteligentně data zpracovávat. Efektivním využitím automatizace při analýze dat se dá ušetřit vysoké množství času i prostředků, a to v tomto i mnoha dalších projektech.

Hlavním přínosem této práce je tedy příspěvek ve formě další funkční komponenty do dlouhodobě se rozvíjejícího projektu, který je jako celek v současné době jedinečný, a s dalším jeho postupným rozvojem a se zvyšujícím se povědomím veřejnosti o jeho existenci má veliký potenciál k využití širokou škálou uživatelů.

2 Cíl práce a metodika

Cílem této práce je za pomoci nástroje umělé inteligence jako TensorFlow nebo DeepLearning4J, určeného k automatickému rozpoznávání objektu v obraze, vytvořit tři dostatečně kvalitní modely, které budou pro projekt Ptáci Online automaticky zpracovávat data získaná z chytrých ptačích budek, a kvalitu těchto modelů ověřit v laboratorním prostředí BirdObserver.czu.cz/BirdObserver.

Konkrétně se jedná o rozpoznání nesené potravy dospělými jedinci – tedy model následně vhodný pro automatickou identifikaci, zda v hnízdě probíhá krmení, dále se jedná o rozpoznání vajíček snesených v hnízdě, což může sloužit ke statistikám snůšek jako množství vajec, ověření délky inkubace, během líhnutí mláďat například s tím, jak vejce ubývají, ke spočtení již vylíhnutých jedinců, a pro množství dalších zkoumání, která již nejsou předmětem této práce, a třetí a poslední je rozpoznání, zda se v hnízdě nachází dospělý jedinec, což bude možné použít pro určování odletů z hnízda a příletů do hnízda a na další zpracování, například pro statistiky odletů a příletů za různých ročních období, když mají sýkory mláďata a za dalších podmínek.

V rámci vzniku těchto modelů je důležité si zodpovědět několik otázek, jako například: Co je to umělá neuronová síť a jakým způsobem vzniká? Jakým způsobem se kategorizuje počítačové vidění? Jaké vedou kroky k vytvoření modelu schopného rozpoznat objekt v obraze? Co vlastně projekt Ptáci Online zkoumá a v jaké fázi se zpracování dat v rámci projektu nachází? Jakým způsobem je možné vytvořený model kvalitativně zhodnotit? Jaké jsou možnosti využití těchto modelů a jaké jsou možnosti budoucího vývoje?

Prvním dílčím cílem praktické části je získat dostatečný vzorek dat, tedy obrázků z ptačích budek, které budou sloužit jako podklady pro vznik příslušných modelů. Dalším cílem je z těchto obrázků za použití speciálních softwarových produktů ve výsledku vytrénovat modely. Logicky následujícím dílčím cílem je u těchto hotových modelů zkontrolovat kvalitu, a v případě nedostatečné kvality modely dle časových možností přetrénovat. Pro testování kvality bude nutné zajistit dostatečný počet obrázků, které nebyly použity při trénování, a otestovat je za několika podmínek. Následně se mohou již dostatečně kvalitní modely zavést do praxe a začít používat. Závěrečným cílem této práce je navrhnout další možnosti vývoje, který bude navazovat na tento výzkum.

Pro zjišťování teoretických informací byly využity odborné knihy, jakož i online materiály ve formě odborných článků, a dále vysokoškolské kurzy.

Pro první část praktické části, tedy pro tvorbu modelů, byla kromě nastudovaných materiálů použita také výuková videa doporučená panem inženýrem Pavlíčkem. Zpracování obrázků bylo prováděno v software LabelImg.py, na stahování podkladových dat ze serverů ČZU byl použit software Total Commander a pro další součásti práce bylo využito množství dalšího softwaru. Podrobná metodika vzniku modelu je popsána v teoretické části práce na ukázce modelu rozpoznávajícího housenky ve fotografiích.

Pro druhou část praktické části, tedy pro testování kvality vytrénovaných modelů, byl použit portál USPIN.cz, kam byly hotové modely nahrány, a získané statistiky byly pro přehlednost dále zpracovány do grafů za pomoci programu MS Excel.

Závěrem práce byly všechny výsledky shrnuty a také byl navržen možný postup vývoje navazující na tuto práci a případné návrhy na zlepšení.

3 Teoretická východiska

3.1 Umělé neuronové sítě


(2) Umělé neuronové sítě jsou jednou z oblastí umělé inteligence, vedle expertních systémů, fuzzy systémů a genetických algoritmů. Objevily se v praxi na poli umělé inteligence v 60. letech 20. století po létech předchozího výzkumu.

První jednoduchý model neuronu pochází z roku 1943 od Warrena McCullocha a Waltera Pittseho. (3) V roce byl 1949 v knize The Organization of Behavior od Donalda Hebba poskytnut návod, jak použít učící pravidlo pro synapse neuronů. V roce 1951 vznikl první neuropočítač Snark, u jehož zrodu stál Marvin Minsky. V roce 1957 Frank Rosenblatt zobecnil model neuronu na perceptron počítající s reálnými čísly. V roce 1958 společně s Charlesem Wightmanem sestrojil neuropočítač „Mark I Perceptron“ s 512 parametry, který byl schopen rozpoznávat znaky. V polovině 60. let Bernard Widrow se svými studenty vytvořil ADaptivní LINEární Element (ADALINE) podobný perceptronu, ale jednotlivé elementy oproti perceptronu realizovaly lineární funkce. Dalším průkopníkem v oblasti neuropočítačů byl Karl Steinbuch, který vyvinul model binární asociativní sítě, jejíž princip je založen na asociativní paměti a vybavení určité informace na základě její částečné znalosti.

Po velmi dlouhou dobu byly neuropočítače využívány pouze pro experimentální účely, protože bylo prokázáno, že perceptron není schopen realizovat funkci XOR. Až v 80. letech vynikly grantové projekty od Johna Hopfielda, který prokázal souvislost některých modelů s fyzikálními modely magnetických materiálů, a podle nějž byly nazvány tzv. Hopfieldovy sítě na principu autoasociativní paměti. V roce 1986 skupina PDP (Parallel Distributed Processing) publikovala učící algoritmus zpětného šíření chyby určeného pro vícevrstevné sítě. V 90. letech se začínají vydávat časopisy s tematikou umělých neuronových sítí, i v České republice se od roku 1991 dá sehnat mezinárodní časopis Neural Networks World.

Až v roce 2012 zažily průlom, protože do té doby bylo problematické vytrénovat hlubší než dvouvrstvou síť. (4)

Umělé neurony představují abstrakci mechanismu zpracovávajícího informace podobným způsobem, jako biologické neurony posílají informace do mozku a v rámci mozku, a určují, jak na dané informace reagovat. Základní model umělého neuronu je zobrazen na následujícím obrázku.



x_i	vstupy neuronu (výstupy z předcházející vrstvy), $i = 1, 2, \dots, n$
n	počet vstupů (počet neuronů v předcházející vrstvě)
w_j	váhy spojení
a	vstupní potenciál neuronu
f	aktivační funkce neuronu
o	výstupní funkce neuronu
θ	práh neuronu
y	výstup neuronu


Obrázek 1- Základní model umělého neuronu

Zdroj: (2)

První neuronové vrstvě je předložen vstup, ze kterého potřebujeme získat výstup. Vstupem neuronu do další vrstvy je vždy výstup z vrstvy předcházející a až poslední vrstva ukáže výstup. Celá síť se chová na základě parametrů (vah), které určují průběh sítě, jedná se tedy o orientovaný graf.

Aktivační funkcí se rozumí taková funkce, která agregovaný signál mění na signál výstupní. Jednou z takových aktivačních funkcí je mezní hodnota, též nazývána práh bdělosti (threshold) (5). Tato funkce nabývá hodnot mezi 0 a 1 a definuje výstup neuronu.

Analýza dynamického chování neuronové sítě je bohužel velmi složitá, vzhledem k tomu, že průběh výpočtu není lineární a předvídatelný na rozdíl od klasických algoritmů, kde se dá (u složitějších programů např. v režimu ladění) přímo krok po kroku sledovat běh programu.



Obrázek 2 - Aktivační funkce threshold

zdroj: (5)

3.1.1 Motivace k výzkumu neuronových sítí

František Hakl definuje obecně počítač jako „zařízení, které zobrazuje množinu vstupních dat (např. koeficienty lineární soustavy) na množinu dat jiných (např. řešení této soustavy).“ (6) I nervový systém je tedy jakousi paralelou na počítač, který zpracovává vstupy na výstupy. U živých organismů je schopnost zpracování informací dána komunikací mezi neurony, které jsou elementárními součástmi nervových center. Dá se očekávat, že zjednodušením nervových center živých organismů se dospěje k modelům neuronových sítí, které budou vykazovat podobně inteligentní chování jako živé organismy a budou schopny řešit úlohy, pro něž v klasickém programování neexistuje efektivní algoritmus.

3.1.2 Typy modelů neuronových sítí

Mezi nejznámější typy modelů neuronových sítí patří dva, které jsou nejprozkoumanější, nejrozšířenější a nejčastěji se používají při aplikacích. Prvním typem je perceptron, což je dvouvrstvá síť, která spojuje vstupní neurony s právě jedním výstupním.


(6)

Druhým typem je vrstevnatý model, kde každý neuron v příslušné vrstvě je spojen se všemi neurony vrstev sousedních (předcházející i nadcházející). Tyto sítě se učí metodou zpětné propagace, což bude vysvětleno níže v části kapitoly 3.2.3 - Hluboké učení.

3.1.3 Konvoluční neuronové sítě

(7) Konvoluční neuronové sítě (CNN) jsou zvláštním druhem vícevrstevných neuronových sítí s velkým počtem parametrů. První z těchto vrstev se nazývá konvoluční. Tyto sítě se využívají pro rozpoznávání objektů v obrázku přímo z jednotlivých pixelů, a to bez ohledu na jejich deformaci, posun v rámci obrázku, změnu barvy nebo dalších kritérií. Typickým příkladem využití konvolučních neuronových sítí je rozpoznání psaného písma, rozpoznání SPZ a strojové čtení, a vytvoření konvoluční neuronové sítě je právě předmětem této práce.

Princip fungování těchto neuronových sítí je velmi komplexní. Na první vrstvu je přiveden obrázek, na který se aplikuje 2D filtr (convolution), a v jeho rámci se rozpoznávají jednotlivé součásti objektu jako například rohy nebo hrany. Na jeden obrázek je aplikováno více filtrů, a výstupem každého z těchto filtrů je tzv. příznaková mapa (feature map).



Obrázek 3 - Konvoluční neuronová síť

Zdroj: Živě.cz (8)

Následující vrstvou je tzv. subsamplingová vrstva, která omezí obrázek pouze na tu část, ve které je nalezený objekt, což vede ke zmenšení vstupu. Dále se opakuje několik konvolučních a subsamplingových vrstev, a nakonec vznikne jednorozměrný vektor, ze kterého se vypočte konečný výstup.

3.2 Strojové učení

Strojové učení je proces, při kterém se neuronová síť adaptuje na vnější prostředí

prostřednictvím vzorů objektu, jehož vlastnosti má ve výsledku reprezentovat. (5)

Strojové učení je rozděleno do tří fází, a to trénování, testování a validace. Během trénování je stroji poskytnuta dostatečně obsáhlá množina dat, na které se učí. Při testování je poskytnuta jiná množina a zjišťuje se, jestli bylo učení provedeno správně. Při validaci se využije jeden vzor k otestování hotového modelu a provádějí se na něm statistická vyhodnocení jako rozptyl, průměr a další.

3.2.1 Kategorie


Strojové učení se dělí na dvě kategorie.

První je učení s učitelem, kdy je na základě aktuálního nastavení porovnáván výsledek aktuální s vyžadovaným a je určena chyba. Podle typu neuronové sítě se poté spočte korekce, upraví se hodnoty vah, prahů nebo strmostí aktivačních funkcí ke snížení chybovosti a proces se opakuje až k dosažení minimální chyby.

Druhou kategorií je učení bez učitele, kdy výstup není průběžně vyhodnocován, ale síť dostane větší množství (sadu) dat, které si sama třídí. U tohoto typu sítě je hlavním cílem získat konzistentní výstup, který při stejných vstupech vyhodnocuje stejné výstupy.

3.2.2 Tensor

V matematické analogii tensor znamená zobecnění vektoru. Složky vektoru mohou obsahovat pouze jeden index, zatímco složky tensoru mají indexů větší počet. „*Tenzor či k -tenzor je multilineární zobrazení, které z několika (přesněji $k \in \mathbb{N}$) vektorů vytvoří reálné číslo. (...) Tenzory jsou zároveň i vektory, protože množiny tenzorů daného typu mají přirozenou strukturu reálného vektorového prostoru. Lze je sčítat a násobit reálným číslem.*“ (9)




Obrázek 4 - Grafické znázornění tensoru

Zdroj: WikiMedia (10)

Ve smyslu neuronových sítí tedy tensor znamená několikarozměrnou mapu vedoucí k vyhodnocení nějakého výsledku, jak již bylo ukázáno v kapitole 3.1.3 – Konvoluční neuronové sítě, při postupném „vyrovnávání“ vrstev až do jednoho vektoru. Podle slova Tensor se jmenuje i nástroj umělé inteligence TensorFlow (tedy „plynutí tensorů“), který konvoluční neuronové sítě využívá právě například k rozpoznávání objektů v obrázku.

3.2.3 Hluboké učení

(4) Hluboké učení je podmnožinou neuronových sítí, které spadají pod strojové učení a vše je zastřešeno umělou inteligencí. Jak název značí, neuronové sítě mají stovky vrstev, a tedy učí se do hloubky. Od roku 2012 překonává hluboké učení klasické algoritmy v soutěžních úlohách jako rozpoznání obrazu, přepis obrazu na text a dalších.



Obrázek 5 - Hierarchie UI

Zdroj: (4)


Z dostupných přednášek ke kurzu ČVUT FEL Rozpoznávání a strojové učení je patrné, že existuje množství různých metod učení, každá z nich je vhodná pro různé typy úloh. (11)

V článku od pana Mgr. Jana Matouška na serveru společnosti Data Mind s.r.o. se píše: „*Hluboké neuronové sítě jsou nejlepší tam, kde představují jediné řešení. Tam, kde to nejde dělat jednodušeji. V zásadě vám pro určení, zda používat hluboké neuronové sítě postačí úvaha, zda máte na vstupu stovky až tisíce různých zdrojů signálu.*“ (12) Mělo by se tedy aplikovat pouze na takové úlohy, na které to má smysl, a rozpoznání obrazu mezi ně beze sporu patří.

Hluboké učení je jednou z disciplín strojového učení, která je využívána k tréninku vícevrstvých neuronových sítí. Slouží k rozpoznání obrazu, rozpoznání řeči, automatickým překladům, filtracím příspěvků na sociálních sítích a k dalším komplexním úlohám. (13)

První a nejjednodušší metodou učení je metoda dopředného šíření signálu (feedforward) použitá pro síť s dopřednou architekturou. (1) Druhou, a také pro úlohy rozpoznávání objektů nejpoužívanější metodou hlubokého učení, je algoritmus zpětného šíření chyby, který spočívá v optimalizaci (minimalizaci) chybové funkce (rozdílu mezi skutečným a kýženým výstupem). Detailní popis tohoto algoritmu je možno dohledat ve zdrojové literatuře. (14)

Zjednodušeně se dá postup vysvětlit následujícím způsobem. (15) Vypočtením chyby na výstupech všech neuronů výstupní vrstvy a adaptací této chyby na všechny skryté vrstvy a postupnou optimalizací za pomoci lokálních úprav vah se dojde k dostatečné přesnosti sítě.




Obrázek 6 - Ilustrace algoritmu zpětného šíření chyby

Zdroj: (16)

3.3 Strojové vidění

3.3.1 Popis

(1) Úlohy počítačové vidění znamenají zpracování určité informace z obrazu počítačem. Na rozdíl od klasického zpracování obrazu jako odstranění šumu, změny kontrastu apod. jsou úlohy počítačového vidění určeny převážně pro klasifikaci objektů. Klasické zpracování obrazu je také do určité míry, např. na základě barevné informace, schopno rozpoznat objekty, ale pouze velice omezeně. Cíle úloh počítačového vidění mohou být různé; od rozpoznání vzorů přes detekci a sledování objektů až po analýzu celých scén. Obecná struktura počítačového vidění je následující.



Obrázek 7 - Struktura systému počítačového vidění

zdroj: (1)

- *Zdrojem světla* rozumíme původ osvětlení.
- *Scéna* znamená množinu 3D objektů rozmístěných v prostředí.
- *Vytvoření obrazu* je pořízení snímku např. kamerou.
- *Obraz* je výstup předchozího vytvoření obrazu.
- *Interpretací obrazu* rozumíme proces analýzy a vyhledání objektů.
- *Symbolický popis* znamená modelování analyzované scény pomocí symbolických prostředků.
- *Aplikační a zpětná vazba* lze vyložit jako ovlivnění scény aplikací, např. nalezení objektu a jeho ohraničení.

3.3.2 Metody

Do strojového vidění se řadí dva typy metod.

Prvními metodami jsou příznakové metody, jejichž úkolem je klasifikovat obrazy na základě jejich atributů, které mohou být číselné, binární, pravdivostní nebo výčtové. Jednou z těchto metod je Teitelmanova metoda kódování, která rozpoznává písmena na základě

rozdělení rozpoznávaného znaku na jednotlivé křivky, definování pravoúhlého ohraničení znaku, rozdělení této pravoúhlé oblasti na devět ekvivalentních částí a reprezentování každého tahu prostřednictvím binárního řetězce.

Druhými metodami jsou metody strukturální, které rozpoznávají základní lokální struktury a dají se využít např. pro odstraňování nežádoucích jevů v obraze.

3.3.3 Vývoj úloh

Úlohy počítačového vidění využívajícího konvoluční neuronové sítě zaznamenávají následující vývoj. (17) První skupinou je vyhledání vzorového objektu v jednotlivých snímcích nebo na videosekvenci na základě příznaků. Následující úlohou je detekce objektů, což zobecňuje a rozšiřuje předchozí úlohu a naučí detektory na nové snímky. Další úlohou je sledování objektu ve videu a predikce pohybu objektu. Jinou úlohou je také klasifikace objektů, kde se jedná o více tříd objektů.

Příkladem použití těchto úloh je rozpoznání divoké zvěře na satelitních snímcích za účelem mapování pohybu zvěře a počítání jedinců ve stádě. (18) Součástí této úlohy je rozlišení, kde na snímku se bude zvíře nacházet, resp. segmentace, a poté určení, o jaký druh zvířete se jedná, tedy klasifikace.

3.4 Projekt Ptáci Online

(19) Na informačním serveru pro sledování hnízdění ptactva pro odbornou i laickou veřejnost – Ptáci Online – je možno najít mapu speciálních „chytrých“ ptačích budek, které obsahují 1-2 kamery s nočním přísvitem, senzorem pohybu, teploty, venkovního osvětlení, a také mikrofón. Touto kamerou je zachycen pohyb uvnitř hnízda ve formě videosekvence, která je živě dostupná na serveru Ptáci Online. Kromě jiných informací je na tomto webu možné najít dosavadní výsledky projektu, který je stále živý a dynamicky se rozvíjí.



Obrázek 8 - Schéma projektu Ptáci Online

Zdroj: Ptáci Online – Základní informace o projektu, Ptáci Online (19)

Hlavním cílem projektu je přiblížit veřejnosti vědeckou práci a rozšířit jí obzory.

O tento projekt jeví zájem jak vědecká obec, tak veřejnost, ale také média. Například na kanálu ČT24 byl v květnu roku 2018 odvysílán krátký rozhovor s koordinátorem projektu panem Vlastimilem Osobou a dvěma dětskými účastníky. (20) V televizi byl projekt zmiňován ještě vícekrát (21) a mnohokrát se o něm psalo i v jiných médiích. (19)

Jednou z částí aktuálního rozvoje je automatizace ukládání a zpracování dat, a nedílnou součástí toho je automatické rozpoznání různých objektů v zachycených videích, potažmo sekvencích snímků. V rámci vzniku této diplomové práce byly pro projekt Ptáci Online vytvořeny automatické modely – tedy rozpoznávače nesené potravy, a také vajec v hníždě a přítomnosti dospělých jedinců.

Do současné doby neexistoval model, který by automaticky zpracovával obrazová data pořízená z budek ve smyslu rozpoznávání jednotlivých objektů, a tak i produkt této diplomové práce je pro projekt přínosem.

3.5 Rozpoznání obrazu pomocí TensorFlow Object Detection API

3.5.1 TensorFlow

TensorFlow™ (22) je open-source softwarová knihovna pro číselné operace s vysokým výkonem. Je určena pro hluboké učení včetně tréninku konvolučních neuronových sítí využívaných pro detekci objektů v obraze. Flexibilní architektura nástroje TensorFlow dovoluje využití napříč platformami s různými CPU, GPU i TPU, od stolních počítačů přes servery po mobilní zařízení. Původní vývoj byl zastřešen Google AI.

3.5.2 Hardwarová a softwarová základna potřebná k trénování modelů určených k rozpoznání obrazu

Z návodu dostupného online na webu Python Programming, konkrétně v článku Introduction and Use – Tensorflow Object Detection API Tutorial (23), je ale zřejmé, že pro zprovoznění TensorFlow Object Detection API je zapotřebí mít na své pracovní stanici nainstalovánu řadu různých programů v konkrétních verzích, a pro provoz těchto programů mít patřičný hardware.

Jako první je potřeba zprovoznit GPU verzi nástroje Tensorflow Object Detection. (24) Nutným požadavkem na programovou základnu je nVidia CUDA, a tedy příslušný hardware – nVidia grafická karta – se správnými ovladači, dále je potřeba nainstalovat Python verze 3.5, protoc a Jupyter notebook.

V dalších fázích tréninku je potřeba mít stažené OpenCV, numpy, LabelImg a další drobné programy dostupné z GitHub.

3.5.3 Postup při vytváření konkrétního modelu


(25) Ke správnému vytvoření modelu vede deset kroků, které jsou demonstrovány na následujícím příkladu.

První model, který jsem v rámci studia pro praktickou část této diplomové práce vytvořila, je detektor housenek. Jako jeho základ byl využit před-učený detektor domácích mazlíčků – checkpoint „ssd_mobilenet_v1_coco_11_06_2017“ (26), u kterého bylo učení přesměrováno na housenky.

3.5.3.1 První krok

Prvním krokem je získat určitou sadu dat, která je rozdělena na sadu trénovací, testovací a případně jeden údaj jako validační, a dále je sada zpracována a využita pro učení.

V procesu vytváření detektoru housenek to znamená najít dostatečný počet obrázků jakožto trénovací a testovací sadu. Na trénink bylo použito 142 obrázků a na test 15 obrázků stažených z google images (27), ve kterých byly označeny housenky za pomoci programu labelimg.py. (28) Pro vyzkoušení funkčnosti byl použit snímek, který nebyl obsažen v testovací ani trénovací sadě. Obrázky byly vybrány tak, aby byl objekt housenky snadno rozpoznatelný, tedy pouze ostré snímky a snímky, na kterých housenka dominovala oproti okolí.



Obrázek 9 - Označování objektu v programu labelImg.py

Zdroj: Vlastní bádání

Výstupem z tohoto programu byly soubory s koncovkou „.xml“, které v následující formě obsahovaly informace o pozici housenky na jednotlivých obrázcích:

```
<?xml version="1.0"?>
<annotation>
  <folder>images</folder>
  <filename>housenka (157).jpg</filename>
  <path>C:\Users\Adéla\Desktop\object-detection\images\housenka (157).jpg</path>
  <source><database>Unknown</database></source>
  <size>
    <width>605</width>
    <height>441</height>
    <depth>3</depth>
  </size>
  <segmented>0</segmented>
</annotation>
```

Obrázek 10 - Obsah souboru .xml vytvořeného programem labelImg.py

Zdroj: Vlastní bádání

3.5.3.2 Druhý krok

Dalším krokem je normalizace dat, tedy převedení dat do takového formátu, ve kterém jsou pro TensorFlow čitelná.

V případě detektoru housenek to znamená vytvoření TF záznamů. Podle návodu dostupného v článku „Creating TFRecords - Tensorflow Object Detection API Tutorial“ (29) jsem ze souborů s koncovkou „.xml“ vytvořených v programu „labelimg.py“ vytvořila za pomoci dalšího programu, a to „xml_to_csv.py“, (30) soubory s koncovkou „.csv“, a dále pomocí „generate_tfrecord.py“ (31) vytvořila dva TF záznamy, a to jeden z trénovací sady a jeden z testovacích (vznikly tedy dva soubory – „train.record“ a „test.record“).

3.5.3.3 Třetí krok

V následujícím kroku se nastavují parametry učení, které v průběhu učení zůstávají konstantní. Mezi tyto parametry patří počet iterací, rychlost učení a velikost dávky. Obsah konfiguračního souboru může vypadat například takto:

learning_rate = 0.01

batch_size = 100

iterations = 1000

V projektu detektoru housenek jsem využila výše zmíněný checkpoint (26) a upravený konfigurační soubor (32). Také jsem do adresáře „train“ vložila jednoduchou mapu

– soubor „object-detection.pbtxt“. Pomocí programu „train.py“ byl spuštěn proces tréninku tímto příkazem.

```
python3 train.py --logtostderr --train_dir=training/ --  
pipeline_config_path=training/ssd_mobilenet_v1_pets.config
```

3.5.3.4 Čtvrtý, pátý a šestý krok

Čtvrtým krokem je inicializace proměnných a zástupných symbolů (placeholder). TensorFlow během učení upravuje proměnné a váhy, aby se zoptimalizovala funkce ztráty (loss) na co nejnižší číslo. Aby se toho dalo dosáhnout, data se musí reprezentovat pomocí proměnných a zástupných symbolů, které mají určenou velikost a typ (např. float32).

```
a_var = tf.constant(42)  
x_input = tf.placeholder(tf.float32, [None, input_size])  
y_input = tf.placeholder(tf.float32, [None, num_classes])
```

V pátém kroku se definuje struktura modelu, čehož se dosáhne vytvořením výpočetního grafu.

Šestým krokem je deklarace funkce ztráty (loss), která říká, jak se liší predikce od skutečných hodnot. V průběhu učení chceme dosáhnout co nejnižších hodnot. Jeho struktura může být následující.

```
loss = tf.reduce_mean(tf.square(y_actual - y_pred))
```

Pro čtvrtý až šestý krok byl v detektoru housenek pouze upraven stažený soubor příslušný k původnímu checkpointu.

3.5.3.5 Sedmý krok

Sedmým krokem je inicializace a trénink modelu. Během tréninku je cílovým stavem minimalizace funkce ztráty „loss“, tedy rozdíl mezi predikovanými a skutečnými daty. Pro trénink modelu rozpoznávajícího housenky bylo třeba vložit upravené stažené soubory „object-detection.pbtxt“ a „config“ do složky „train“, a pomocí následujícího příkazu spustit trénink.

```
python train.py --logtostderr --train_dir=training/ --  
pipeline_config_path=training/ssd_mobilenet_v1_pets.btxt
```


Trénink běžel celý den na lokální GPU. Trénink jsem pozastavila nejprve po zhruba 30000 krocích, ale model pozitivně halucinoval, tedy rozpoznával objekt housenky i tam,

kde se nenacházel, takže jsem trénink spustila znovu a zastavila po 46433 krocích, kdy ztráta vykazovala podstatně nižší hodnoty, tedy mezi 1 a 2 místo původních 3-4 a hodnoty se již dlouhodobě nesnižovaly.

3.5.3.6 Osmý až desátý krok

Osmým krokem k úspěšnému vytvoření správně fungujícího modelu je jeho evaluace, tedy zhodnocení, jak si model vede při vyhodnocování dat, a poté verifikace. K tomuto kroku jsou využity obrázky mimo učební sady, a verifikace nebyla vzhledem k absenci verifikačního softwaru provedena.

Pro využití vytrénovaného modelu jsem nechala vyexportovat tzv. „inference graph“ a úpravou kódu v původním souboru s koncovkou „.ipynb“, a vložením testovacích obrázků do patřičné složky podle návodu zprovoznila detektor. Výsledkem této detekce v modelu rozpoznávajícím housenky byly následující výstupy (pro ilustraci je uveden jen jeden).



Obrázek 11 - Rozpoznání objektu v obrázku

Zdroj: Vlastní bádání

V devátém kroku se na základě úspěšnosti modelu upravují hyperparametry a opakují předchozí kroky od čtvrtého výše, případně se může i rozšířit sada testovacích a trénovacích obrázků a začít tedy znovu od začátku. Další variantou je pouze nechat trénink běžet déle.

U modelu rozpoznávajícího housenky byl, jak bylo výše zmíněno, trénink pozastaven po zhruba 30000 krocích a vzhledem k nedostatečnému výkonu modelu bylo prodlouženo trénování bez úpravy hyperparametrů, což se projevilo jako dostatečný postup.

Desátým krokem je využití modelu v praxi. Pro zkušební projekt s housenkami byl samozřejmě tento krok vynechán.

3.6 Rozpoznání obrazu pomocí DeepLearning4J

(33) Eclipse DeepLearning4J je open-source nástroj pro hluboké učení (včetně učení konvolučních neuronových sítí) v programovacím prostředí JAVA a SCALA určené pro Java Virtual Machine. Licencí je Apache Software Foundation License 2.0. Principy učení jsou podobné jako u prostředí TensorFlow s tím rozdílem, že je zapotřebí jiná programová základna a výsledek je založen na jazyce JAVA, nikoliv Python a s tím se pojí drobné rozdíly v postupech.

3.7 Metody kritického zhodnocení kvality modelu

Při detekci objektů není kvalita predikce modelu jednoduše změřitelná a zhodnotitelná, protože tato predikce se skládá ze dvou samostatných částí a dalších doplňujících informací. První z těchto částí je klasifikace, což znamená rozhodnutí, zda se daný objekt v příslušném testovaném obrázku nachází. Při této klasifikaci může model pozitivně nebo negativně halucinovat. Pozitivní halucinací se rozumí rozpoznání objektu, i když se v obraze nenachází, případně duplicity, a negativní halucinace znamená nerozpoznání vyskytujícího se objektu. Druhou nezbytnou částí hodnocení kvality je, zda model správně označil, kde se objekt v obrázku nachází. (34) Také je obvyklé, že modely rozpoznávají více různých objektů, a tak se musí zahrnout také skutečnost, zda model správně rozpoznal třídu objektu, a pokud se v obrázku nachází více objektů, zda je rozpoznal všechny anebo jen jejich část. Všechny tyto součásti poukazují na nesnadnost a komplexnost měření kvality modelu.

Aby se daly zahrnout všechny tyto měřitelné součásti do jedné jednotky, je nutné provést několik výpočtů, z nichž některé je vzhledem k jejich výpočetní složitosti možné provést pouze strojově.


Pro základní měření kvality byly zavedeny dvě jednotky, a to **přesnost** (precision) a **citlivost** (recall), z nichž se dále vypočítá **střední průměrná přesnost** (mean average precision) **mAP**. Přesnost se vypočítá jako počet správně zhodnocených příslušných objektů

vůči celkovému počtu zhodnocených objektů (tedy např. pokud máme 5 obrázků, na nichž je 10 housenek a model jich rozpozná dohromady 12, a jen 9 z těchto 12 jsou skutečně housenky, potom je přesnost $9/12 = 0,75$), zatímco citlivost je vypočítána jako počet správně zhodnocených objektů vůči celkovému počtu vyskytujících se příslušných objektů (na stejném příkladu by to znamenalo, že citlivost je $9/10 = 0,9$).

$$\text{přesnost} = \text{pravdivé zhodnocené} / \text{všechny zhodnocené} \quad (1)$$

$$\text{citlivost} = \text{pravdivé zhodnocené} / \text{všechny existující} \quad (2)$$

Obě tyto měrné jednotky jsou závislé jak na kvalitě modelu, tak na zvolené mezní hodnotě (threshold). Zvolená mezní hodnota může být například 0,6, takže pokud model z 55 % rozpozná, že se v obrázku nachází objekt, tento objekt nebude vyhodnocen a bude vhodné mezní hodnotu snížit. Z vypočtených hodnot se vytvoří křivka přesnosti a citlivosti, kde na ose X je zanesena citlivost a na ose Y přesnost. Může vypadat následujícím způsobem.



Obrázek 12 - Křivka přesnosti a citlivosti

Zdroj: (35)

Z hodnot přesnosti a citlivosti se dá dále vypočítat AP (average precision) a následuje výpočet správné lokalizace objektu. Je potřeba pixel po pixelu označit objekt v obrázku a strojově vypočítat přesnost pomocí predikovaných koordinát, měrnou jednotkou je IoU (Intersection over Union). Ze všech těchto hodnot se dá vypočítat střední průměrná přesnost mAP (mean average precision), která do sebe shrnuje veškeré kvality modelu.

Protože toto měření je svou komplexností a náročností nad úrovní samotného tréninku a hlavním cílem praktické části této práce je model vytvořit, nikoliv takto zevrubně prozkoumat, bude ke zhodnocení kvality modelu v praktické části použita pouze statistika rozpoznání objektů (tedy přesnosti a citlivosti) za tří různých mezních hodnot (threshold) a bude zhodnocena úroveň halucinace.

4 Vlastní práce

V této části diplomové práce je popisována realizace vlastního bádání. Je zde vysvětleno, jakým způsobem bylo postupováno a docházeno k jednotlivým dílčím výsledkům, a to od zajištění vstupních dat přes jejich přípravu pro trénink, dále trénink, evaluaci a verifikaci, až po samotnou implementaci a testování hotových modelů, a nakonec uvedení do praxe.

4.1 Výběr prostředí

Vzhledem k prostředí JAVA na serveru PtaciOnline.cz bylo nutné zvolit DeepLearning4J (DL4J), protože TensorFlow je nástroj Pythonu. Některé výstupy z pythonových komponent (např. LabelImg.py) jsou využitelné i pro trénink V DL4J, protože vytváří data (v případě LabelImg.py se jedná o soubory s koncovkou .xml), takže vzhledem k tomu, že byly na pracovní stanici nainstalovány, byly i použity.

4.2 Zajištění dat

Na univerzitním serveru Provozně Ekonomické Fakulty pojmenovaným Athena se nachází sekce Ptáci Online (36), kde jsou uloženy některé snímky z chytrých ptačích budek, které byly vybrány pro použití na trénink tří modelů, a to modelu rozpoznávajícího nesenou potravu – tedy automatické rozpoznání krmení mladých sýkorek dospělým ptákem, dále modelu rozpoznávajícího vejce nakladená v hnízdě, a naposledy modelu rozpoznávajícího přítomnost dospělého jedince v hnízdě. Pro zajištění rychlého převodu dostatečného množství obrázků byl zajištěn FTP přístup na server Athena, protože stahování přes protokol HTTP bylo po vyzkoušení příliš pomalé.

4.2.1 Třídění dat

I přes zajištění rychlého přístupu k datům bylo stále dat příliš velké množství na to, aby se všechny lokálně ukládaly, a až poté třídily. Po několika hrubých průhledech daty přímo na serveru jsem zjistila následující aktivitu ve sledovaném ptačím hnízdě:

19.4.2016 – hníždění pouze dospělce

20.4.2016 – první vejce

1.5.2016 – další vejce

3.5.2016 – finální počet 8 vajec

5.5.2016 – líhnutí

26.6.2016 – opuštěné hnízdo, návštěva jiného druhu ptáka

Z těchto sledování jsem vyhodnotila, že je třeba uložit obrázky z dat mezi 1.5.-26.5.2016, a pomocí programu Total Commander jsem příslušné složky přes FTP přístup stáhla na lokální disk. Soubory byly lokálně uloženy ve složkách tak, jak jsou uloženy na serveru, tedy podle sekvencí spuštěných čidlem pohybu.

4.3 Příprava dat

Ze stažených složek ze serveru Athena jsem ručně vybírala obrázky tak, aby na nich byly přítomny sledované objekty, a následně bylo obrázky potřeba zmenšit tak, aby šířka každého obrázku byla 416 pixelů. K tomuto účelu jsem využila online nástroj BulkResizePhotos. (37)

4.3.1 Rozpoznání nesené potravy

Nejprve jsem vybrala sadu obrázků, kde probíhalo krmení, tedy kde dospělý pták v zobáku nesl potravu mladým, právě vylíhnutým ptáčatům, specificky z data 5.5.2016 a pozdějších dat. Tato sada měla na počátku velikost 544 snímků. Do sady jsem vybírala obrázky tak, aby byla potrava zřetelně viditelná, ale použila jsem i snímky, které nebyly ostré nebo měly jiné barvy, aby výsledný model byl schopen objekt nesené potravy rozpoznat i za neideálních podmínek. Při pozdějším testování prvního modelu jsem zjistila, že sada nebyla vzhledem k různým světelným podmínkám dostatečná a docházelo na snímcích s černobílým i fialovým přisvitem k výrazné negativní halucinaci, a tak došlo k rozšíření učební sady na 947 snímků a přetrénování. Testy uvedené dále v této práci jsem prováděla na první i druhé verzi modelu, přičemž u testů druhé verze jsem již použila zjištěnou ideální hodnotu aktivační funkce threshold.



Obrázek 13 - Zřetelně viditelná nesená potrava

Zdroj: (36)



Obrázek 14- Méně zřetelně viditelná nesená potrava

Zdroj: (36)

4.3.2 Rozpoznání vajec ve snůšce

Druhou sadou byly obrázky, na kterých byla více či méně zřetelně viditelná vejce nebo jejich části zakryté dospělým jedincem na nich sedícím. Tyto obrázky byly z dat 1.5.2016 až 5.5.2016. Z předchozí analýzy jsem zjistila, že maximální počet vajec pro toto pozorování při sledovaném hnízdění bylo 8. Pro trénink tohoto modelu jsem vybrala 723 obrázků, na

kterých byl jak vyšší počet vajec, tak také obrázky, na kterých se již některá ptáčata vylíhla a z části překrývala zbylá vejce. Obrázky jsem také vybírala napříč kvalitou obrazu. Jako vejce jsem označovala i skořápky právě se líhnoucího mláděte.



Obrázek 15 - Zřetelně viditelná vejce

Zdroj: (36)



Obrázek 16 - Vejce částečně zakrytá vylíhnutými mlád'aty

Zdroj: (36)



Obrázek 17 - Vejce částečně zakrytá mládřaty a skořápka

Zdroj: (36)

4.3.3 Rozpoznání dospělého jedince

Třetí a poslední sadou bylo 700 obrázků dospělých jedinců nebo jejich částí, také z dat do 5.5.2016, jako například hlava či ocas. I tyto obrázky jsem vybírala v různých kvalitách, světelných podmínkách a v různých stupních ostrosti. Po iniciálních testech bylo v dalším kroku vzhledem ke špatným výsledkům vyhledávání (v tomto případě pozitivní halucinaci) nutné tuto sadu rozšířit o dalších 316 obrázků na zvýšený počet 1016. Testy jsem prováděla na rozšířené sadě.



Obrázek 18 - Zřetelný obrázek dospělé sýkory

Zdroj: (36)



Obrázek 19 - Méně zřetelný obrázek dospělé sýkory


Zdroj: (36)

4.4 Zpracování dat pro trénink

Vzhledem k názvům souborů jako „snap0001-00000000667.png“ apod. bylo pro přehlednost soubory nutné přejmenovat. K tomu jsem použila program Total Commander.

Všechny vybrané obrázky jsem v BulkResizePhotos zmenšila na požadovanou šířku 416 pixelů. Tato šířka je dána výpočetní kapacitou hardwaru, který byl použit ke trénování modelů.

Do programu LabelImg.py jsem pro každou sadu nahrála celou složku s příslušnými obrázky. Poté jsem navýšila velikost zobrazení, protože zmenšené obrázky na šířku 416 pixelů byly příliš malé na to, aby se objekty daly označovat s dostatečnou přesností v normálním zobrazení. Po zvětšení jsem obrázek po obrázku označila příslušné objekty a jejich umístění jsem uložila ve formátu „.xml“ do samostatné složky.



Obrázek 20 - Označování objektu v obrázku v programu LabelImg.py

Zdroj: Vlastní bádání

Hotové složky s obrázky byly připraveny k dalšímu zpracování.

4.5 Trénink

Podkladová data pro trénink jsem předala vedoucímu této práce, Ing. Josefu Pavlíčkovi, Ph.D., který zajistil trénink jednotlivých modelů. Ten proběhl v prostředí frameworku DeepLearning4J bez architektury CUDA, použitá architektura byla Tini YOLO, která byla předtrénována na ImageNET a Pascal VOC.

Specifické metody učení byly implementovány školitelem a učení proběhlo na pracovní stanici HP PRODESK, Procesor Intel 3.4 GHz, 8 GB operační paměť, 64 bitů Operační systém Windows 10pro, Grafická karta INTEL HD Graphics 630, 8071 MB.

Neuronová síť byla učena pro obrázky velikosti 416x416 pixelů, ve 3 kanálech. Rozdělení učebních dat bylo 80:20, 120 EPOCH, 20 byla učební dávka.

Parametry učení byly následující:

Learning Rate = 1e-3, momentum = 0.9

Doba učení byla přibližně 45 hodin.


Dosažená chyba v poslední iteraci byla rovna hodnotě 0.592803625.

Výsledkem byla vícevrstvá konvoluční neuronová síť vlastního typu.

4.6 Evaluace a verifikace

4.6.1 Prostředí k testování

Podle zadání práce měla být evaluace provedena v laboratorních podmínkách dat ze serveru BirdObserver.czu.cz/BirdObserver/. Vzhledem k tomu, že trénink proběhl na serveru USPIN.cz, kde je prostředí shodné s prostředím BirdObserver, a také vzhledem k tomu, že na BirdObserveru byly modely již testovány jinými uživateli, jak je viditelné z následujících dvou obrázků, prováděla jsem testy na serveru USPIN.cz.



Obrázek 21 - Webové rozhraní BirdObserver po přihlášení

Zdroj: server BirdObserver

Prostředí na serveru USPIN.cz, kde byly modely trénovány, je primárně určené pro průmyslové klienty, které na snímcích potřebují vyhledávat vady na svých výrobcích. (38) Proto systém v současné době nevyhledává nalezený objekt označený příslušným názvem třídy (tedy „potrava“, „vejce“ a „sykora“), ale používá pro všechny vyhledané objekty slovo „vada.“ Od 4.3.2019 je po aktualizaci serveru místo označení „vada“ použito pro rozpoznané objekty slovo „detection.“

Model, který chceme pro rozpoznání námi kýženého objektu ve snímku použít, je, jak je ilustrováno níže, viz „Obrázek 22 – Výběr modelu k testování na serveru USPIN.cz“, nejprve nutné vybrat ze seznamu, inicializovat pomocí tlačítka „Nahrajte model“, a dále vybrat požadovanou mezní hodnotu (threshold), která se, jak bylo vysvětleno v teoretické části práce, nachází mezi 0 a 1. Dále je zapotřebí z lokálního disku vybrat snímek, na němž se daný objekt chce vyhledat, tento obrázek na server nahrát. Po nahrání se tento obrázek roztáhne do čtverce o rozměru 416 x 416 pixelů, což u obrázků o rozměru 416 x 234 pixelů způsobuje deformaci, která ale pro testovací účely nemá žádný významný negativní vliv, jedinou nevýhodou je pouze drobné snížení přehlednosti, které se ale zpětným zmenšením výšky obrázku (např. opět s využitím serveru BulkResizePhotos) na původních 234 pixelů snadno odstraní.

The screenshot displays the 'Výběr komponenty rozpoznání vad' (Fault detection component selection) interface. It features a dropdown menu for model selection, a 'Nahrajte model' (Upload model) button, a 'Velikost tresholdu' (Threshold size) input field with a value of 0.3, a 'Nahrajte snímek 416 x 416 px' (Upload image 416 x 416 px) button, and an 'Ověřte vady na snímku' (Check faults on image) button. A list of available models is shown in a dropdown menu, including paths like /home/uspín/HORServer/models/10_sykoraZoback..., /home/uspín/HORServer/models/adultsV27_10_18..., /home/uspín/HORServer/models/dospolecV08_02_..., /home/uspín/HORServer/models/eggsV04_11_18.zip, and /home/uspín/HORServer/models/sykoraPotravaV1....

Obrázek 22 - Výběr modelu k testování na serveru USPIN.cz

Zdroj: Portál USPIN.cz



Obrázek 23 - roztažený snímek na 416x416 pixelů s rozpoznaným objektem nesené potravy

Zdroj: Vlastní bádání

4.6.2 Příprava testovacích dat

Během iniciačních testů, kdy jsem zkoušela rozpoznání objektů jednotlivými modely na náhodných snímcích, jsem zjistila, že nejvýznamnější roli v úspěšnosti rozpoznání objektů, jednalo se především o dva ze tří pro tuto práci vytvořených modelů, hrají světelné podmínky. Proto jsem pro další testování vytvořila čtyři kategorie, v rámci kterých jsem dále prováděla vyhodnocení. Souhrnné vyhodnocení jsem vypočítala na základě procentuálního výskytu snímků z jednotlivých kategorií v celém dni. Každé kategorii přiřazuje váhu, kterou je výsledek v rámci kategorie vynásoben. Výpočet vah je následující. Pro testovací snímky jsem vybrala snímky ze dvou dnů, a to 6.5.2016 a 8.5.2016, a zároveň snímky, které se nevyskytovaly v žádné učební sadě. Výpočet vah je uveden v následující tabulce.

Datum	Denní světlo	Tma	Černobílý přísvit	Fialový přísvit	CELKEM
06.05.2016	2126	1143	725	58	
08.05.2016	2335	582	1269	70	
SOUČET	4461	1725	1994	128	8308
VÁHA*	0.537	0.208	0.240	0.015	

* = SOUČET / CELKEM

Tabulka 1 - Výpočet vah světelných kategorií

Zdroj: vlastní bádání

Snímky uložené v jednotlivých automaticky vytvořených složkách, zachycující jednotlivé sekvence spuštěné čidlem pohybu, jsem nejprve roztrídila podle data pořízení. Poté jsem všechny snímky z jednotlivých složek vyňala a vložila do jedné nadřazené složky. Následně jsem je roztrídila podle čtyř světelných kategorií, kterými jsou „Denní světlo,“ „Tma,“ „Černobílý noční přísvit“ a „Fialový noční přísvit.“ V rámci každé kategorie jsem vytvořila podsložky „Dospělec,“ „Krmení,“ a pokud se v daném dni nacházely i vejce, tak i složku „Vejce,“ kam jsem zkopírovala obrázky, na kterých se tyto objekty vyskytovaly.

V rámci každé světelné kategorie jsem vybrala pro model rozpoznávající nesenou potravu a pro model rozpoznávající dospělé sýkory 100 snímků, které nejlépe reprezentují různé stavy objektu a kvalitu snímků, pouze v kategorii „Fialový noční přísvit,“ byl počet snímků s nesenou potravou nižší vzhledem k nedostatku příslušných snímků. Vybírala jsem tedy takové snímky, aby se v nich objekty nacházely na různých místech, různě otočené, rozmazané i ostré. Pozitivní výsledky (tedy výsledky, kde byl objekt modelem rozpoznán, ať už se reálně ve snímku nacházel nebo ne) ze serveru USPIN.cz jsem uložila na lokální pracovní stanici, kde jsem je dále analyzovala. Do tabulek jsem vložila vedle sebe vždy původní a zpracovaný snímek, a potom vyplnila skutečný počet objektů, nalezený počet objektů, počet správně vyhodnocených, počet duplicitních vyhodnocení, počet falešných vyhodnocení a typ chyby v analýze. Zjišťovala jsem nejčastější chyby v rámci jednotlivých modelů a vypočítala přesnosti a citlivosti při mezní hodnotě (threshold) rovné 0,3, 0,1 a 0,05 a určila jsem úroveň halucinace.

Mezní hodnoty jsem určila na základě konzultace s vedoucím diplomové práce, Ing. Josefem Pavlíčkem, Ph.D., z jehož zkušenosti jiné modely vytrénované na tomto serveru fungovaly na mezních hodnotách mezi 0,3 a 0,05.

Pro testování modelu rozpoznávajícího vejce jsem použila na menším množství obrázků širší spektrum hodnot aktivační funkce threshold, protože tento model se během

testování choval jinak než ostatní dva, nevykazoval téměř žádné rozdíly mezi světelnými kategoriemi a bylo spíše nutné vyzkoušet citlivěji reagující měnící se threshold.

4.6.3 Evaluace modelu rozpoznávajícího nesenou potravu

Jak jsem již zmínila výše, světelné podmínky hrají pro úspěch rozpoznání objektu nesené potravy významnou roli. Při testování snímků s černobílým a fialovým nočním přísvitem byla úspěšnost nalezení objektů nejnižší, což je dáno nedostatečným počtem takových snímků v učební sadě. Po tomto testování došlo k rozšíření učební sady a přetrénování původního modelu. Zjistila jsem, že čím je nižší threshold, tím je vyšší citlivost, ale snižuje se přesnost. Závěrem tohoto testování tedy byla vybrána hodnota thresholdu pro úspěšné používání tohoto modelu ještě před přetrénováním.

4.6.3.1 Threshold 0,3

4.6.3.1.1 Denní světlo

Na snímcích za denního světla byly výsledky vynikající. Citlivost dosáhla hraničních 80 % a přesnost i bez softwarového odstraňování duplicit dosáhla 80,80 %, s odstraněním duplicitních rámečků potom 97,56 %. Když tedy model vyhodnotí nějaký objekt, dá se z 97,56 % říci, že se skutečně jedná o nesenou potravu. Ve zbylých 2,44 % případů se jednalo o falešnou detekci, kterou byly zobáčky mladých sýkor, ale vzhledem k množství výskytů je tento problém zanedbatelný.

Skutečný počet objektů na snímcích	100
Počet vyhodnocených objektů	99
Nejčastější chyba	Negativní halucinace na 21 snímcích ze 100 Pozitivní halucinace ve 21 případech z 99
Správně vyhodnocených	80
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	18 duplicit 3 falešné detekce na 2 snímcích
Přesnost	80,81 %
Přesnost po SW odstranění duplicit	97,56 %
Citlivost	80 %

Tabulka 2 - Výsledky rozpoznání nesené potravy na snímcích za denního světla při thresholdu 0,3

Zdroj: Vlastní bádání

61 snímků bylo analyzováno bezchybně. Negativní i pozitivní halucinace se vyskytovaly na skoro stejné úrovni, obě v 21 případech.



Obrázek 24 - Bezchybné rozpoznání nesené potravy na snímku pořízeného za denního světla při thresholdu 0,03

Zdroj: Vlastní bádání

4.6.3.1.2 Tma


Na snímcích pořízených za tmy se nepodařilo dosáhnout hranice úspěšnosti. Citlivost dosáhla pouze hodnoty 38,83 %, přesnost ale dosáhla i bez odstranění duplicitních rámečků 83,33 %, po odstranění potom 100 %, takže každým rozpoznávaným objektem byla nesená potrava.

Skutečný počet objektů na snímcích	103
Počet vyhodnocených objektů	48
Nejčastější chyba	Negativní halucinace 58,25 % (60 případů ze 103)
Správně vyhodnocených	40
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	8 duplicit
Přesnost	83,33 %
Přesnost po SW odstranění duplicit	1
Citlivost	38,83 %

Tabulka 3 - Výsledky rozpoznání nesené potravy na snímcích za tmy při thresholdu 0,3

Zdroj: Vlastní bádání

31 snímků bylo analyzováno bezchybně. Nejčastější chybou však byla negativní halucinace, model nebyl schopen rozpoznat 58,58 % výskytů nesené potravy. Bylo by tedy vhodné k dosažení lepší citlivosti snížit hodnotu funkce threshold.



Obrázek 25 - Bezchybné rozpoznání nesené potravy na snímku pořízeného za tmy při thresholdu 0,3

Zdroj: Vlastní bádání

4.6.3.1.3 Černobílý noční přísvit


Z výsledků uvedených v následující tabulce je patrné, že rozpoznání nesené potravy na snímcích pořízených za černobílého nočního přísvitu má oproti snímkům pořízených za denního světla výrazně nižší úspěšnost. Ačkoliv přesnost dosáhla 93,75 % a po úpravě 100 %, citlivost byla pouze 14,85 %.

Skutečný počet objektů na snímcích	101
Počet vyhodnocených objektů	16
Nejčastější chyba	Negativní halucinace 85,14 % (86 případů ze 101)
Správně vyhodnocených	15
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	1 duplicita
Přesnost	93,75 %
Přesnost po SW odstranění duplicit	100 %
Citlivost	14,85 %

Tabulka 4 - Výsledky rozpoznání nesené potravy na snímcích za černobílého nočního přísvitu při thresholdu 0,3

Zdroj: Vlastní bádání

14 snímků bylo analyzováno bezchybně. 85,14 % nesené potravy se nepodařilo modelu rozpoznat, nejčastější chybou je tedy negativní halucinace a je vhodné snížit threshold.



Obrázek 26 - Bezchybné rozpoznání nesené potravy na snímku pořízeného za černobílého nočního přívitu při thresholdu 0,3

Zdroj: Vlastní bádání

4.6.3.1.4 Fialový noční přívít

Jako na snímcích pořízených za černobílého nočního přívitu vykazoval model rozpoznávající nesenou potravu podobné výsledky na snímcích za fialového nočního přívitu, tedy vysokou přesnost 90,91 % a velmi nízkou citlivost, pouze 16,13 %.

Skutečný počet objektů na snímcích	62
Počet vyhodnocených objektů	11
Nejčastější chyba	Negativní halucinace 83,87 % (52 případů z 62)
Správně vyhodnocených	10
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	1 duplicita
Přesnost	90,91 %
Přesnost po SW odstranění duplicit	1
Citlivost	16,13 %

Tabulka 5 - Výsledky rozpoznání nesené potravy na snímcích za fialového nočního přívitu při thresholdu 0,3

Zdroj: Vlastní bádání

9 snímků bylo analyzováno bezchybně. Nejčastější chybou byla opět negativní halucinace, která dosáhla 83,87 %.



Obrázek 27- Bezchybné rozpoznání nesené potravy na snímku pořízeného za fialového nočního přísvitů při thresholdu 0,3

Zdroj: Vlastní bádání

4.6.3.1.5 Souhrnné výsledky

Bylo analyzováno celkem 363 snímků, na nichž se nacházelo 366 objektů nesené potravy za čtyřech různých světelných podmínek. Při hodnotě aktivační funkce threshold 0,3 bylo úspěšně rozpoznáno celkem 145 objektů, což je na první pohled málo, vážený průměr citlivosti 54,84 % nedosáhl hranice úspěšnosti 80 %. Přesnost rozpoznání byla za tohoto thresholdu velmi vysoká, a to 84,59 % a po softwarovém odstranění duplicitních rámečků dokonce 98,69 %. Byl také potvrzen významný rozdíl mezi úspěšnostmi testování za různých světelných podmínek, za denního světla by byl model i při thresholdu 0,3 úspěšný, pro ostatní světelné podmínky ale nedostačující.

Vzhledem k nízké citlivosti je zapotřebí používat pro úspěšné rozpoznávání nesené potravy nižší hodnoty thresholdu.

Světelné podmínky	Denní světlo	Tma	Černobílý přísvit	Fialový přísvit	Konečný výsledek
Přesnost	0.808080808	0.83333333	0.9375	0.909090909	
Přesnost po odstranění duplicit	0.975609756	1	1	1	
Citlivost	0.8	0.38834951	0.148514851	0.161290323	
Váha	0.537	0.208	0.24	0.015	
Průměrný výsledek citlivosti	0.4296	0.0807767	0.035643564	0.002419355	0.548439618
Průměrný výsledek přesnosti	0.433939394	0.17333333	0.225	0.013636364	0.845909091
Průměrný výsledek opravené přesnosti	0.523902439	0.208	0.24	0.015	0.986902439

Tabulka 6 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,3

Zdroj: Vlastní bádání

4.6.3.2 Threshold 0,1

4.6.3.2.1 Denní světlo

Na snímcích pořízených za denního světla docházelo při snížení thresholdu z 0,3 na 0,1 ke zvýšení správných rozpoznání nesené potravy z 80 na 92, ale také se začala na 8 snímcích objevovat chyba falešného rozpoznání nesené potravy. Model totiž opět považoval zavřené zobáčky mladých sýkor za nesenou potravu, vzhledem k tomu, že mají podobný tvar i výraznou barvu oproti okolnímu prostředí v budce, které je jinak nevýrazné. Přesnost i citlivost dosáhly stejné hodnoty, a to 92 %, což je vzhledem k 80% hranici považováno za úspěšné.

Skutečný počet objektů na snímcích	100
Počet vyhodnocených objektů	195
Nejčastější chyba	Pozitivní halucinace 48,72 % (95 případů ze 195)
Správně vyhodnocených	92
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	88 duplicit 15 falešných vyhodnocení na 8 snímcích
Přesnost	47,18 %
Přesnost po SW odstranění duplicit	92 %
Citlivost	92 %

Tabulka 7 - Výsledky rozpoznání nesené potravy na snímcích za denního světla při thresholdu 0,1

Zdroj: Vlastní bádání

15 snímků bylo analyzováno bezchybně. Model začal nesenou potravu vyhodnocovat častěji duplicitně, což ale vzhledem k booleovské povaze úlohy není tak závažný problém. V tomto typu úlohy nejde ani tolik o počet objektů v obrázku, ale o to, zda se vůbec objekt v obrázku nachází, jedná se tedy o rozhodnutí, zda probíhá nebo neprobíhá krmení. Důležité v tomto případě je spíše to, aby model falešně nevyhodnocoval nesenou potravu na snímcích, kde žádné krmení neprobíhá. Tento problém je i za thresholdu 0,1 pouze zanedbatelný.



Obrázek 28 - Falešná detekce – zaměnění zobáčků za nesenou potravu na snímku pořízeném za denního světla při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.3.2.2 Tma

Na snímcích pořízených za tmy je také patrné zlepšení úspěšnosti rozpoznání nesené potravy. Místo původních 40 se po snížení thresholdu z 0,3 na 0,1 podařilo úspěšně rozpoznat 67 nesených potrav. Citlivost se tedy zvýšila na 65,05 % a přesnost se zhoršila o téměř 30 %, ale po softwarových úpravách stále zůstává v hranicích úspěšnosti na 98,53 %.

Skutečný počet objektů na snímcích	103
Počet vyhodnocených objektů	123
Nejčastější chyba	Pozitivní halucinace 45,53 % (56 případů ze 123)
Správně vyhodnocených	67
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	53 duplicit 3 falešné detekce na 1 snímku
Přesnost	54,47 %
Přesnost po SW odstranění duplicit	98,53 %
Citlivost	65,05 %

Tabulka 8 - Výsledky rozpoznání nesené potravy na snímcích za tmy při thresholdu 0,1

Zdroj: Vlastní bádání

28 snímků analyzováno bezchybně. Nejčastější chybou byly pozitivní halucinace, převážně se jednalo o duplicitní vyhodnocení stejné nesené potravy.



Obrázek 29 - Vícenásobná detekce nesené potravy na snímku pořízeném za tmy při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.3.2.3 Černobílý noční přísvit

I na snímcích pořízených za černobílého nočního přísvit se zvýšil počet správných detekcí, a to třikrát, z 15 na 45, citlivost tedy vzrostla na 44,55 %. Přesnost vzhledem k vyššímu výskytu duplicit a falešných detekcí o něco klesla, ale po úpravě stále dosahuje 90 %.

Skutečný počet objektů na snímcích	101
Počet vyhodnocených objektů	77
Nejčastější chyba	Negativní halucinace 55,45 % (56 případů ze 101)
Správně vyhodnocených	45
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	27 duplicit 5 falešných detekcí
Přesnost	58,44 %
Přesnost po SW odstranění duplicit	90 %
Citlivost	44,55 %

Tabulka 9 - Výsledky rozpoznání nesené potavy na snímcích za černobílého nočního přisvitu při thresholdu 0,1

Zdroj: Vlastní bádání

17 snímků bylo analyzováno bez chyby. Nejčastější chybou zůstává i po snížení thresholdu negativní halucinace, 56 objektů nebylo vůbec rozpoznáno. Vzhledem k dostatečné úrovni upravené přesnosti je možné a vhodné pro lepší výsledky detekcí opět snížit threshold.



Obrázek 30 - Vícenásobná detekce nesené potavy na snímku pořízeném za černobílého nočního přisvitu při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.3.2.4 Fialový noční přisvit

Po snížení thresholdu se na snímcích pořízených za fialového nočního přisvitu více než ztrojnásobila úspěšnost a to, z 10 na 35 úspěšných rozpoznání při zachování dostatečné upravené 97,22% přesnosti.

Skutečný počet objektů na snímcích	62
Počet vyhodnocených objektů	49
Nejčastější chyba	Negativní halucinace 43,54 % (27 případů z 62)
Správně vyhodnocených	35
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	12 duplicit 2 falešné detekce na 1 snímku
Přesnost	71,43 %
Přesnost po SW odstranění duplicit	97,22 %
Citlivost	56,45 %

Tabulka 10 - Výsledky rozpoznání nesené potravy na snímcích za fialového nočního přisvitu při thresholdu 0,1

Zdroj: Vlastní bádání

22 snímků bylo analyzováno bezchybně. Nejčastější chybou zůstává negativní halucinace, nerozpoznaných objektů bylo 43,54 %.



Obrázek 31 - Vícenásobná detekce nesené potravy na snímku pořízeném za fialového nočního přisvitu při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.3.2.5 Souhrnné výsledky

Pro testy jsem použila stejnou sadu obrázků jako při thresholdu 0,3, aby bylo možné porovnávat výsledky. Po snížení thresholdu na 0,1 se zvýšila citlivost na 74,47 %, což je těsně pod hranici úspěšnosti a přesnost klesla na 51,76 %. Po softwarové úpravě dosáhla hodnoty 92,96 %. Úspěšnost rozpoznání se na všech snímcích kromě snímků za denního světla téměř ztrojnásobila.

Vzhledem k hraniční hodnotě citlivosti a ke stále vysoké hodnotě upravené přesnosti bude možné i vhodné použít o něco nižší hodnotu thresholdu než 0,1.

Světelné podmínky	Denní světlo	Tma	Černobílý přísvit	Fialový přísvit	Konečný výsledek
Přesnost	0.471794872	0.54471545	0.584415584	0.714285714	
Přesnost po odstranění duplicit	0.92	0.98529412	0.9	0.972222222	
Citlivost	0.92	0.65048544	0.445544554	0.564516129	
Váha	0.537	0.208	0.24	0.015	
Průměrný výsledek citlivosti	0.49404	0.13530097	0.106930693	0.008467742	0.744739406
Průměrný výsledek přesnosti	0.253353846	0.11330081	0.14025974	0.010714286	0.517628685
Průměrný výsledek opravené přesnosti	0.49404	0.20494118	0.216	0.014583333	0.92956451

Tabulka 11 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.3.3 Threshold 0,05

4.6.3.3.1 Denní světlo

Při dalším snížení thresholdu z 0,1 na 0,05 se podařilo najít o 4 správná vyhodnocení více, ale počet duplicit i falešných vyhodnocení vzrostl významněji. Přesnost po softwarových úpravách dosáhla hodnoty 86,49 % a citlivost 96 %. Z předchozích a těchto výsledků vyplývá, že u snímků pořízených za denního světla je úspěšnost vyhodnocení vyšší než 80 % za všech testovaných hodnot thresholdu.

Skutečný počet objektů na snímcích	100
Počet vyhodnocených objektů	294
Nejčastější chyba	Pozitivní halucinace 67,35 % (198 z 294 případů)
Správně vyhodnocených	96
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	177 duplicit 21 falešných vyhodnocení na 15 snímcích
Přesnost	32,65 %
Přesnost po SW odstranění duplicit	86,49 %
Citlivost	96 %

Tabulka 12 - Výsledky rozpoznání nesené potravy na snímcích za denního světla při thresholdu 0,05

Zdroj: Vlastní bádání

3 snímky byly analyzovány bezchybně. Nejčastější chybou byly pozitivní halucinace, které se vyskytovaly v 67,35 % případů. Protože i za těchto podmínek model splňuje kritérium úspěšnosti, není nutné ani vhodné threshold nadále snižovat.



Obrázek 32 - Falešná a vícenásobná detekce nesené potravy na snímku pořízeném za denního světla při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.3.3.2 Tma

Na snímcích pořízených za tmy se podařilo správně rozpoznat o 17 objektů navíc, citlivost tedy vzrostla nad hranici úspěšnosti na 81,55 % ale významně vzrostl problém s duplicitními vyhodnoceními. Přesnost klesla na 37,17 % a po úpravách dosahuje 95,45 %. Za těchto podmínek by tedy bylo vhodné model používat a není nutné již snižovat threshold.

Skutečný počet objektů na snímcích	103
Počet vyhodnocených objektů	226
Nejčastější chyba	Pozitivní halucinace 62,39 % (141 případů z 226)
Správně vyhodnocených	84
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	137 duplicit 4 falešné detekce na 4 snímcích
Přesnost	37,17 %
Přesnost po SW odstranění duplicit	95,45 %
Citlivost	81,55 %

Tabulka 13 - Výsledky rozpoznání nesené potravy na snímcích za tmy při thresholdu 0,05

Zdroj: Vlastní bádání

11 snímků bylo analyzováno bezchybně. Nejčastější chybou byla pozitivní halucinace, 137 objektů bylo vyhodnoceno duplicitně a došlo ke čtyřem falešným detekcím, což je velmi dobrý výsledek.



Obrázek 33 - Vícenásobná detekce nesené potravy na snímku pořízeném za tmy při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.3.3.3 Černobílý noční přísvit

I na černobílých snímcích se podařilo zvýšit citlivost, a to na 66,34 %, místo 45 správných vyhodnocení jich bylo 67, ale přesnost již ani po odstranění duplicitních rámečků nedosahovala 80 %. Pro úspěšnou analýzu černobílých snímků je tedy vhodné model přetrénovat, protože za žádného thresholdu nedosáhla kritérií úspěchu.

Skutečný počet objektů na snímcích	101
Počet vyhodnocených objektů	162
Nejčastější chyba	Pozitivní halucinace 58,64 % (95 případů ze 162)
Správně vyhodnocených	67
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	58 duplicit 37 falešných detekcí na 30 snímcích
Přesnost	41,36 %
Přesnost po SW odstranění duplicit	69,07 %
Citlivost	66,34 %

Tabulka 14 - Výsledky rozpoznání nesené potravy na snímcích za černobílého nočního přísvitů při thresholdu 0,05

Zdroj: Vlastní bádání

17 snímků bylo analyzováno bezchybně. Nejčastější chybou se z negativní halucinace při vyšším thresholdu stala po snížení pozitivní halucinace, ke které docházelo v 58,64 % případů. Čím dál větší část z těchto detekcí byly falešné detekce, místo 5 na thresholdu 0,1 jich bylo v tomto případě již 37 na 30 snímcích.



Obrázek 34 - Falešná detekce nesené potravy na snímku pořízeném za černobílého nočního při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.3.3.4 Fialový noční přísvit

Na snímcích s fialovým nočním přísvitem se po snížení thresholdu z 0,1 na 0,05 podařilo správně vyhodnotit o 12 objektů navíc. Citlivost vzrostla na 75,81 % při upravené přesnosti 87,04 %. Hranice úspěšnosti nebyla dosažena, i když hraničně, po přetrénování modelu s přidavkem snímků s fialovým nočním přísvitem by se měl problém zlepšit.

Skutečný počet objektů na snímcích	62
Počet vyhodnocených objektů	93
Nejčastější chyba	Pozitivní halucinace 49,46 % (46 případů z 93)
Správně vyhodnocených	47
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	37 duplicit 9 falešných detekcí na 7 snímcích
Přesnost	50,54 %
Přesnost po SW odstranění duplicit	87,04 %
Citlivost	75,81 %

Tabulka 15 - Výsledky rozpoznání nesené potravy na snímcích za fialového nočního přísvitu při thresholdu 0,05

Zdroj: Vlastní bádání

16 snímků bylo analyzováno bezchybně. Nejčastější chybou byla pozitivní halucinace, model začal častěji duplicitně vyhodnocovat a došlo k 9 falešným detekcím.



Obrázek 35 - Vícenásobná detekce nesené potavy na snímku pořízeném za fialového nočního při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.3.3.5 Souhrnné výsledky

Na stejné testovací sadě byly provedeny testy za sníženého thresholdu na 0,05. Hranice úspěšnosti se podařilo dosáhnout na snímcích za denního světla a tmy. Ve váženém průměru bylo dosaženo citlivosti 85,57 %, přesnosti 35,95 % a opravené přesnosti 84,18 %. Z výsledků vyplývá, že model je za tohoto thresholdu použitelný a threshold by se dal i o něco málo zvýšit.

Světelné podmínky	Denní světlo	Tma	Černobílý přísvit	Fialový přísvit	Konečný výsledek
Přesnost	0.326530 612	0.37168 142	0.4135802 47	0.505376 344	
Přesnost po odstranění duplicit	0.864864 865	0.95454 545	0.6907216 49	0.870370 37	
Citlivost	0.96	0.81553 398	0.6633663 37	0.758064 516	
Váha	0.537	0.208	0.24	0.015	
Průměrný výsledek citlivosti	0.51552	0.16963 107	0.1592079 21	0.011370 968	0.85572995 6
Průměrný výsledek přesnosti	0.175346 939	0.07730 973	0.0992592 59	0.007580 645	0.35949657 8
Průměrný výsledek opravené přesnosti	0.464432 432	0.19854 545	0.1657731 96	0.013055 556	0.84180663 8

Tabulka 16 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.3.4 Závěr

Při hodnotě thresholdu 0,3 byla citlivost rovna 54,84 % a opravená přesnost 98,69 %. Při hodnotě thresholdu 0,1 byla citlivost rovna 74,47 % a opravená přesnost 92,96 %. Při hodnotě thresholdu 0,05 byla citlivost rovna 85,57 % a opravená přesnost 84,18 %.

Z těchto hodnot vyplývá, že pro požadovaných 80% rozpoznání je nejvhodnější použít hodnotu aktivační funkce threshold mezi 0,5 a 1, kde budou hodnoty citlivosti i opravené přesnosti vyšší nebo rovny 80 %.

Threshold	0.3	0.1	0.05
Citlivost	0.548439618	0.744739406	0.855729956
Přesnost	0.845909091	0.517628685	0.359496578
Opravená přesnost	0.986902439	0.92956451	0.841806638

Tabulka 17- Závěrečné zhodnocení metodických metrik modelu rozpoznávajícího nesenou potravu

Zdroj: Vlastní bádání

Model rozpoznávající nesenou potravu je tedy podle předem stanovených kritérií považován za úspěšný a provozuschopný.

4.6.4 Evaluace druhé verze modelu rozpoznávajícího nesenou potravu

Přestože byl i původní model rozpoznávající nesenou potravu vzhledem k výsledkům testů úspěšný, zaznamenala jsem významné rozdíly mezi výsledky úspěšnosti na snímcích za denního světla a tmy oproti snímkům za černobílého a fialového přísvitu. Proto byl po dokončení testů pro zvýšení úspěšnosti model přetrénován s větším množstvím černobílých a fialových snímků. Nová učební sada měla 947 snímků. Testy byly prováděny za thresholdu 0,07, což byla hodnota zjištěná při prvním testování jako ideální. Výsledky byly oproti předchozí verzi modelu pro černobílé snímky skutečně lepší, jak je patrné z následujících výsledků.

4.6.4.1 Denní světlo

Na snímcích pořízených za denního světla došlo ke drobnému zhoršení citlivosti na 89 % oproti předchozí verzi modelu, kdy byla při thresholdu 0,1 rovna 92 % a při thresholdu 0,05 rovna 96 %, ale zlepšila se upravená přesnost na 100 %. Chybou byla převážně pozitivní halucinace ve formě duplicit, nedošlo k žádnému falešnému vyhodnocení, které se na předchozí verzi modelu vyskytovalo (při thresholdu 0,1 jich bylo 15 a při thresholdu 0,05 dokonce 21). 28 snímků bylo analyzováno bezchybně.

Skutečný počet objektů na snímcích	100
Počet vyhodnocených objektů	180
Nejčastější chyba	Pozitivní halucinace 50,56 % (91 případů ze 180)
Správně vyhodnocených	89
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	91 duplicit
Přesnost	49,44 %
Přesnost po SW odstranění duplicit	100 %
Citlivost	89 %

Tabulka 18 - Výsledky rozpoznání nesené potravy na snímcích za denního světla při thresholdu 0,07

Zdroj: Vlastní bádání

4.6.4.2 Tma

Na snímcích pořízených za tmy došlo po přetrénování modelu k odstranění většiny falešných vyhodnocení, nepatrně tedy vzrostla přesnost na 98,77 % po odstranění duplicit. Citlivost dosáhla hraničních 77,67 %, což přibližně odpovídá i předchozí verzi modelu. 26 snímků bylo analyzováno bezchybně a ve 47,71 % detekcí se jednalo o pozitivní halucinace ve formě duplicit a vyskytla se pouze jedna falešná detekce.

Skutečný počet objektů na snímcích	103
Počet vyhodnocených objektů	153
Nejčastější chyba	Pozitivní halucinace 47,71 % (73 případů ze 153)
Správně vyhodnocených	80
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	72 duplicit 1 falešná detekce
Přesnost	52,29 %
Přesnost po SW odstranění duplicit	98,77 %
Citlivost	77,67 %

Tabulka 19 - Výsledky rozpoznání nesené potravy na snímcích za tmy při thresholdu 0,07

Zdroj: Vlastní bádání

4.6.4.3 Černobílý noční přísvit

Na snímcích pořízených za černobílého nočního přísvitů jsem předpokládala zvýšení citlivosti, protože převážně o ně byla rozšířena učební sada. Na původním modelu byla při thresholdu 0,1 rovna 44,55 % a při thresholdu 0,05 rovna 66,33 %, přičemž při tomto thresholdu již docházelo k příliš velkému množství falešných detekcí. Citlivost se skutečně zlepšila, ale ne natolik, aby dosáhla hranice úspěšnosti, dosáhla pouze hodnoty 66,34 %. Upravená přesnost se po přetrénování modelu také výrazně zlepšila, dosáhla hodnoty 94,37

%. Na správně vyhodnocených snímcích docházelo často k duplicitám a pouze 4 objekty místo předchozích 37 byly vyhodnoceny falešně. 29 snímků bylo analyzováno bezchybně.

Skutečný počet objektů na snímcích	101
Počet vyhodnocených objektů	129
Nejčastější chyba	Pozitivní halucinace 48,06 % (62 případů ze 129)
Správně vyhodnocených	67
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	58 duplicit 4 falešné detekce na 4 snímcích
Přesnost	51,94 %
Přesnost po SW odstranění duplicit	94,37 %
Citlivost	66,34 %

Tabulka 20 - Výsledky rozpoznání nesené potravy na snímcích za černobílého nočního přisvitu při thresholdu 0,07

Zdroj: Vlastní bádání

4.6.4.4 Fialový noční přisvit

Vzhledem k nízkému počtu snímků s fialovým nočním přisvitem, na kterých by probíhalo krmení, nebylo možné rozšířit příliš učební sadu, a to se projevilo i na výsledcích. Na těchto snímcích nedošlo po přetrénování modelu k žádnému zlepšení. Citlivost dokonce o něco klesla, a to na 51,61 %, a upravená přesnost si zachovala podobnou hladinu 94,12 %. 18 snímků bylo analyzováno bezchybně.

Skutečný počet objektů na snímcích	62
Počet vyhodnocených objektů	51
Nejčastější chyba	Negativní halucinace 48,39 % (30 případů ze 62)
Správně vyhodnocených	32
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	17 duplicit 2 falešná vyhodnocení na 2 snímcích
Přesnost	62,75 %
Přesnost po SW odstranění duplicit	94,12 %
Citlivost	51,61 %

Tabulka 21 - Výsledky rozpoznání nesené potravy na snímcích za fialového nočního přisvitu při thresholdu 0,07

Zdroj: Vlastní bádání

4.6.4.5 Shrnutí a závěr

Po rozšíření učební sady o černobílé snímky vzrostla úspěšnost rozpoznání nesené potravy, a to jak citlivost, tak přesnost, podle předpokladu. Pro ostatní světelné podmínky došlo k nárůstu přesnosti a nepatrnému snížení citlivosti, takže v průměru je druhá verze modelu přibližně stejně úspěšná jako ta první. Podařilo se eliminovat většinu falešných detekcí, upravená přesnost dosáhla hodnoty 97,12 %. Citlivost dosahuje při thresholdu 0,07

hraničních 80,64 %, což znovu dokazuje, že model je pro dosažení úspěšnosti nejvhodnější používat při thresholdu mezi 0,05 a 0,1.

Osvětlení	Den	Tma	BW	Fialové	
Citlivost	0.89	0.776699029	0.663366337	0.516129032	
Přesnost	0.494444444	0.522875817	0.519379845	0.62745098	
Upravená přesnost	0.978021978	0.987654321	0.943661972	0.941176471	
Váha	0.537	0.208	0.24	0.015	
Průměrný výsledek citlivosti	0.47793	0.161553398	0.159207921	0.007741935	0.80643325
Průměrný výsledek přesnosti	0.265516667	0.10875817	0.124651163	0.009411765	0.50833776
Průměrný výsledek upravené přesnosti	0.525197802	0.205432099	0.226478873	0.014117647	0.97122642

Tabulka 22 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,07

Zdroj: Vlastní bádání

4.6.5 Evaluace modelu rozpoznávajícího vejce

4.6.5.1 Metoda testování

Pro testování modelu rozpoznávajícího vejce byla použita jiná metodika než pro testování ostatních dvou modelů. Vzhledem k tomu, že vejce jsou ve snůšce blízko vedle sebe, nelze použít odstraňování duplicitních rámečků, takže nelze vypočítat ani aplikovat upravenou přesnost. Je tedy důležitější najít přesně takovou hodnotu aktivační funkce threshold, aby při ní model správně rozpoznával co nejpřesněji počet vajec.

Vybrala jsem 25 obrázků, na nichž se vejce nacházela v co nejvíce pozicích za různých světelných podmínek a testovala hodnoty thresholdu mezi 0,05 až 0,2 po 0,01. Na každém snímku jsem vybrala hodnotu případně hodnoty aktivační funkce threshold, za kterých byl počet vajec správně zanalyzován. Předpokladem ke splnění kritéria úspěšnosti bylo, aby na 80 % analyzovaných snímků byla stejná hodnota thresholdu, při které jsou vejce rozpoznány ve správném počtu.

4.6.5.2 Testování

Během testování jsem zjistila, že nejvíce snímků bylo správně zanalyzováno při thresholdu 0,09, což bylo 36 % snímků. Na druhém místě byl threshold 0,1, při kterém se podařilo

správně zanalyzovat 32 % snímků. Bohužel ale nebyl nalezen takový threshold, při kterém by se podařilo správně zanalyzovat 80 % snímků.

Threshold	Počet správně vyhodnocených snímků	Procento správně vyhodnocených snímků
0.05	4	0.16
0.06	3	0.12
0.07	6	0.24
0.08	6	0.24
0.09	9	0.36
0.1	8	0.32
0.11	4	0.16
0.12	5	0.2
0.13	6	0.24
0.14	7	0.28
0.15	3	0.12
0.16	3	0.12
0.17	2	0.08
0.18	2	0.08
0.19	4	0.16
0.2	5	0.2

Tabulka 23 - Výsledky modelu rozpoznávajícího vejce při různých hodnotách thresholdu

Zdroj: Vlastní bádání

4.6.5.3 Shrnutí a závěr

Během testování modelu rozpoznávajícího vejce ke snůšce jsem na vzorku obrázků za různých světelných podmínek zjistila, že neexistuje taková hodnota aktivační funkce threshold, aby byl model schopen vejce rozpoznávat s požadovanou citlivostí a přesností.

4.6.6 Evaluace modelu rozpoznávajícího dospělého jedince

Při testování modelu rozpoznávajícího dospělé sýkory na vybraných snímcích také docházelo k významným rozdílům mezi výsledky za různých světelných podmínek, ale na rozdíl od modelu rozpoznávajícího nesenou potravu vykazovaly tmavé snímky a snímky za denního světla podobnější výsledky. Snímky pořízené za nočního přisvitu byly v obou

případech výrazně horší. V následující analýze je vidět, že opět se snižujícím se thresholdem klesá přesnost, ale roste citlivost. Závěrem těchto testů je vybrán nejvhodnější threshold pro použití modelu rozpoznávajícího dospělé sýkory.

4.6.6.1 Threshold 0,3

4.6.6.1.1 Denní světlo

Rozpoznání dospělých jedinců za denního světla dosáhla v poměru k ostatním světelným podmínkám velmi vysoké úspěšnosti. Citlivost dosáhla hodnoty 75,22 %, bylo úspěšně rozpoznáno 85 dospělých ptáků ze 113 na 100 snímcích. Přesnost byla v tomto případě nižší, pouze 54,14 %, což bylo způsobeno duplicitními detekcemi. Po softwarovém odstranění těchto duplicit je upravená přesnost rovna hodnotě 98,84 %. Pokud tedy model pozitivně vyhodnotí objekt, dá se z 98,84 % říci, že se skutečně jedná o dospělé sýkoru.

Skutečný počet objektů na snímcích	113
Počet vyhodnocených objektů	157
Nejčastější chyba	Pozitivní halucinace 45,86 % (72 případů ze 157 detekcí)
Správně vyhodnocených	85
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	71 duplicit 1 falešná detekce na 1 snímku
Přesnost	54,14 %
Přesnost po SW odstranění duplicit	98,84 %
Citlivost	75,22 %

Tabulka 24 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,3

Zdroj: vlastní bádání

Nejčastější chybou byla tedy za těchto světelných podmínek pozitivní halucinace, dospělý pták byl detekován několikrát na stejném místě, jedna detekce byla ve výpočtu přesnosti brána jako pravdivá a ostatní jako nepravdivé. K tomuto jevu docházelo převážně u snímků, na kterých byl dospělý pták velmi zřetelný. Pouze v jednom případě se jednalo o falešnou detekci.

Ve 34 snímcích byla detekce bezchybná, tedy byl detekován správný počet dospělých ptáků bez pozitivní či negativní halucinace.



Obrázek 36 - Pozitivní halucinace modelu rozpoznávajícího dospělé ptáky za denního světla při thresholdu 0,3

Zdroj: vlastní bádání



Obrázek 37 - Falešná detekce dospělého ptáka za denního světla při thresholdu 0,3

Zdroj: vlastní bádání

4.6.6.1.2 Tma

Ve tmavých světelných podmínkách byla úspěšnost rozpoznání o něco nižší než za denního světla, ale stále mnohem vyšší než za přisvitu, ať už černobílém nebo fialovém. Citlivost dosáhla hodnoty 65,89 % a přesnost rozpoznání je 50,30 %. Po softwarovém odstranění duplicit by byla přesnost 100 %, což znamená, že všechny rozpoznané objekty tímto modelem za tmavých světelných podmínek jsou skutečně dospělí ptáci.

Skutečný počet objektů na snímcích	127
Počet vyhodnocených objektů	169
Nejčastější chyba	Pozitivní halucinace (84 případů ze 169 detekcí)
Správně vyhodnocených	85
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	84 duplicit
Přesnost	50,30 %
Přesnost po SW odstranění duplicit	100 %
Citlivost	65,89 %

Tabulka 25 - Výsledky rozpoznání dospělých sýkor na snímcích za tmy při thresholdu 0,3

Zdroj: vlastní bádání

Nejčastější chybou bylo stejně jako za denního světla duplicitní vyhodnocení stejného objektu, což je ilustrováno na následujícím obrázku. Nepodařilo se vypořádat, za jakých podmínek k duplicitnímu vyhodnocení dochází, protože na tmavých snímcích se tato chyba vyskytovala jak u ostrých, tak u rozmazaných snímků. Bezchybná detekce byla provedena na 26 snímcích ze 100. Na ostatních úspěšných snímcích docházelo k halucinacím.



Obrázek 38 - Pozitivní halucinace modelu rozpoznávajícího dospělé ptáky za tmy při thresholdu 0,3

Zdroj: vlastní bádání

4.6.6.1.3 Černobílý noční přísvit

Za černobílého přísvitů byla úspěšnost rozpoznání výrazně nižší. Citlivost dosáhla hodnoty pouze 7,03 %, ze 128 dospělých jedinců na 100 snímcích se podařilo úspěšně detekovat pouze 9. Přesnost byla v tomto případě vyšší, rovna 69,23 %, a po softwarovém odstranění duplicit by se jednalo o přesnost 100 %, takže v tomto případě platí, že pokud model objekt rozpozná, je to ze 100 % dospělý pták.

Skutečný počet objektů na snímcích	128
Počet vyhodnocených objektů	13
Nejčastější chyba	Negativní halucinace 92,97 % (119 výskytů ze 128)
Správně vyhodnocených	9
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	4 duplicity
Přesnost	69,23 %
Přesnost po SW odstranění duplicit	100 %
Citlivost	7,03 %

Tabulka 26 - Výsledky rozpoznání dospělých sýkor na černobílých snímcích při thresholdu 0,3

zdroj: vlastní bádání

Z vysokého výskytu negativní halucinace je patrné, jak významnou roli hraje při detekci objektu světlo. Nejlépe si vedly snímky, na nichž byl pták umístěn vodorovně, což bylo v souladu s učební sadou. Rozšířením učební sady o další černobílé snímky by se dalo dosáhnout lepších výsledků. Za současného stavu se pouze 3 snímky podařilo analyzovat bezchybně. Na ostatních pozitivně vyhodnocených snímcích docházelo k halucinacím.



Obrázek 39 - Úspěšná detekce dospělého jedince za černobílého přisvitu při thresholdu 0,3

Zdroj: vlastní bádání

4.6.6.1.4 Fialový noční přisvit

Za fialového nočního přisvitu model vykazoval podobné chování jako za černobílého přisvitu, s o něco lepšími výsledky. Citlivost dosáhla hodnoty 19,84 % a přesnost 75,75 %. Po softwarovém odstranění duplicitních vyhodnocení přesnost také dosáhla hodnoty 100 %, rozpoznáním objektem byl tedy vždy dospělý pták.

Skutečný počet objektů na snímcích	126
Počet vyhodnocených objektů	33
Nejčastější chyba	Negativní halucinace 80,15 % (101 výskytů ze 126)
Správně vyhodnocených	25
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	8 duplicit
Přesnost	75,75 %
Přesnost po SW odstranění duplicit	100 %
Citlivost	19,84 %

Tabulka 27 - Výsledky rozpoznání dospělých sýkor na snímcích s fialovým nočním přisvitem při thresholdu 0,3

zdroj: vlastní bádání

Nejčastější chybou bylo opět nerozpoznání objektu, tedy negativní halucinace. Ze 126 objektů na 100 snímcích bylo správně rozpoznáno pouze 25 a bezchybně zhodnocených snímků bylo pouze 16.



Obrázek 40 - Úspěšná detekce dospělého jedince za černobílého přisvitu při thresholdu 0,3

Zdroj: vlastní bádání

4.6.6.1.5 Souhrnné výsledky

Celá testovací sada obsahovala 400 snímků, na nichž se nacházelo 493 dospělých ptáků. Správně rozpoznáno jich bylo celkem 204. Při mezní hodnotě 0,3 se podařilo dosáhnout vážené průměrné hodnoty úspěšnosti rozpoznání, tedy citlivosti, rovné 56,08 %. Přesnost rozpoznání byla vzhledem k častému výskytu pozitivních halucinací 57,29 %, a po softwarovém odstranění duplicitních rámečků by se dala zvýšit na 99,38 %. Rozpoznaným objektem byl vždy dospělý pták ve všech kromě jednoho případu falešné detekce, což také poukazuje na vysokou přesnost rozpoznání.

Světelné podmínky	Denní světlo	Tma	Černobílý přisvit	Fialový přisvit	Konečný výsledek
Přesnost	0.5414	0.503	0.6923	0.7575	
Přesnost po odstranění duplicit	0.9884	1	1	1	
Citlivost	0.7522	0.6589	0.0703	0.1984	
Váha	0.537	0.208	0.24	0.015	
Průměrný výsledek citlivosti	0.4075293	0.1392144	0.016872	0.002976	0.5608306
Průměrný výsledek přesnosti	0.2907318	0.104624	0.166152	0.0113625	0.5728703
Průměrný výsledek opravené přesnosti	0.5307708	0.208	0.24	0.015	0.9937708

Tabulka 28 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,3

Zdroj: Vlastní bádání

Cílovou hodnotou úspěšného rozpoznání objektů je, jak bylo výše zmíněno, 80 %. Při mezní hodnotě 0,3 se podařilo dosáhnout hodnoty 56,08 % citlivosti a 99,38 % opravené přesnosti, takže je vhodné použít pro požadovanou úspěšnost rozpoznání nižší hodnotu thresholdu.

4.6.6.2 Threshold 0,1

4.6.6.2.1 Denní světlo

Stejně jako při thresholdu 0,3 vykazovalo hodnocení snímků pořízených za denního světla častý výskyt pozitivních halucinací. Počet duplicitních správných vyhodnocení dokonce vyrostl ze 71 na 269 a na 6 snímcích došlo k 10 falešným detekcím. Citlivost ale vzrostla z nedostatečných 75,22 % na 92,04 % při opravené přesnosti 94,55 %, což by bylo podle předem stanovených kritérií více než dostatečné. Ze 113 objektů bylo správně nalezeno 104.

Skutečný počet objektů na snímcích	113
Počet vyhodnocených objektů	383
Nejčastější chyba	Pozitivní halucinace 72,85 % (279 případů z 383)
Správně vyhodnocených	104
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	269 duplicit 10 falešných detekcí na 6 snímcích
Přesnost	27,15 %
Přesnost po SW odstranění duplicit	94,55 %
Citlivost	92,04 %

Tabulka 29 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,1

Zdroj: Vlastní bádání

Pouze 5 snímků bylo analyzováno bez chyb, v 72,85 % detekce se jednalo o duplicity, které jsou ale softwarově odstranitelné. Nejčastější chybou byla tedy pozitivní halucinace. Výskyt chyby je pravděpodobně závislý na ostrosti snímku, protože na ostrých snímcích jsou mnohonásobné detekce mnohem častější než na snímcích rozmazaných.



Obrázek 41 - Mnohonásobné nalezení stejného objektu za denního světla při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.6.2.2 Tma

Za tmy se při thresholdu 0,1 také podařilo dosáhnout požadovaných hodnot citlivosti a upravené přesnosti. Citlivost dosáhla hodnoty 87,60 % a upravená přesnost 94,17 %. Snížení přesnosti oproti thresholdu 0,3 je zapříčiněno vyšším výskytem falešných vyhodnocení, ale vzhledem k patrnějšímu zvýšení citlivosti se stále jedná o lepší výsledky. Ze 129 dospělých sýkor bylo správně detekováno 113.


Skutečný počet objektů na snímcích	129
Počet vyhodnocených objektů	381
Nejčastější chyba	Pozitivní halucinace 70,34 % (268 případů z 381)
Správně vyhodnocených	113
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	259 duplicit 9 falešných detekcí na 7 snímcích
Přesnost	29,66 %
Přesnost po SW odstranění duplicit	94,17 %
Citlivost	87,60 %

Tabulka 30 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,1

Zdroj: Vlastní bádání

Pouze 4 snímky byly analyzovány bezchybně, na většině snímků docházelo k pozitivním halucinacím, většina z nich byly duplicity, respektive mnohonásobné detekce.

Docházelo k nim, stejně jako u snímků za denního světla, převážně na ostrých snímcích. Nejčastější chybou byla tedy stejně jako při thresholdu rovnému 0,3 pozitivní halucinace.



Obrázek 42 - Mnohonásobné nalezení stejných objektů za tmy při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.6.2.3 Černobílý noční přísvit

Na černobílých snímcích se při snížení thresholdu z 0,3 na 0,1 podařilo zvýšit počet správně detekovaných dospělých sýkor z 9 na 42. Přesto je citlivost stále příliš nízká, rovná hodnotě 32,81 %. Přesnost po odstranění duplicitních rámečků dosahuje hodnoty 91,30 %, zhoršení oproti thresholdu 0,3 je opět způsobeno zvýšením počtu falešných detekcí. Výsledky jsou ale obecně lepší.

Skutečný počet objektů na snímcích	128
Počet vyhodnocených objektů	80
Nejčastější chyba	Negativní halucinace 67,19 % (86 případů ze 128)
Správně vyhodnocených	42
Nesprávně vyhodnocených (pozitivní halucinace)	34 duplicit 4 falešné detekce na 4 snímcích
Přesnost	52,5 %
Přesnost po SW odstranění duplicit	91,30 %
Citlivost	32,81 %

Tabulka 31 - Výsledky rozpoznání dospělých sýkor na černobílých snímcích při thresholdu 0,1

Zdroj: Vlastní bádání

Za těchto podmínek bylo 11 snímků analyzováno bezchybně. Nejčastější chybou ale stále zůstává negativní halucinace, která dosáhla hodnoty 67,19 %. Většinu dospělých sýkor za černobílého nočního přísvitu se tedy ani za thresholdu 0,1 nepodařilo detekovat.



Obrázek 43 - Mnohonásobné nalezení stejného objektu za černobílého nočního přívitu při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.6.2.4 Fialový noční přívít


Na snímcích s fialovým nočním přívitem došlo opět ke zlepšení výsledků. Z původních 25 správně rozpoznaných sýkor došlo k navýšení na 69. Přesnost se snížila na stále dostatečných 86,25 %, ale citlivost přesto, že se zvýšila, stále není dostatečná a nedosahuje hodnoty 80 %.

Skutečný počet objektů na snímcích	126
Počet vyhodnocených objektů	197
Nejčastější chyba	Pozitivní halucinace 64,97 % (128 případů z 197)
Správně vyhodnocených	69
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	101 duplicit 27 falešných detekcí na 11 snímcích
Přesnost	35,03 %
Přesnost po SW odstranění duplicit	86,25 %
Citlivost	54,76 %

Tabulka 32 - Výsledky rozpoznání dospělých sýkor na snímcích s fialovým nočním přívitem při thresholdu 0,1

Zdroj: Vlastní bádání

10 snímků analyzováno bezchybně. Nejčastější chybou ale nebyla negativní halucinace, jako za thresholdu 0,3, ale pozitivní halucinace, která se skládala jak z vícenásobných vyhodnocení stejného objektu, tak z části z falešných detekcí, což zapříčinilo snížení citlivosti.



Obrázek 44 - Mnohonásobné nalezení stejného objektu za fialového nočního přisvitu při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.6.2.5 Souhrnné výsledky

Na stejnou sadu obrázků byla při analýze snížena hodnota aktivační funkce threshold z 0,3 na 0,1 a došlo k výraznému zlepšení citlivosti. Z původních 56,08 % rozpoznaných sýkor se počet zvýšil na 76,34 %. Přesnost se v průměru snížila na 33,87 % a opravená přesnost na 93,57 %. Vzhledem k požadavku 80 % je nutné threshold ještě o něco snížit.

Světelné podmínky	Denní světlo	Tma	Černobílý přisvit	Fialový přisvit	Konečný výsledek
Přesnost	0.2715	0.2966	0.525	0.3503	
Přesnost po odstranění duplicit	0.9455	0.9417	0.913	0.8625	
Citlivost	0.9204	0.876	0.3281	0.5476	
Váha	0.537	0.208	0.24	0.015	
Průměrný výsledek citlivosti	0.4942548	0.182208	0.078744	0.008214	0.7634208
Průměrný výsledek přesnosti	0.1457955	0.0616928	0.126	0.0052545	0.3387428
Průměrný výsledek opravené přesnosti	0.5077335	0.1958736	0.21912	0.0129375	0.9356646

Tabulka 33 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,1

Zdroj: Vlastní bádání

4.6.6.3 Threshold 0,05

4.6.6.3.1 Denní světlo

Výsledky rozpoznání dospělých sýkor byly už za thresholdu 0,1 dostatečné, ale docházelo k navyšování vícenásobného rozpoznání stejného objektu. Při snížení thresholdu na 0,05 se počet rozpoznaných sýkor zvýšil ze 104 na 111, ale zvýšil se i problém v podobě


falešných detekcí. Za těchto podmínek by tedy bylo vhodné vybrat hodnotu thresholdu mezi 0,5 a 1. Vzhledem k požadavkům jsou ale i tyto výsledky správné a použitelné, citlivost je 98,23 % a přesnost po odstranění duplicitních rámečků dosáhla hraničních 80,43 %.

Skutečný počet objektů na snímcích	113
Počet vyhodnocených objektů	612
Nejčastější chyba	Pozitivní halucinace 81,54 % (499 výskytů z 612)
Správně vyhodnocených	111
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	445 duplicit 57 falešných detekcí na 27 snímcích
Přesnost	18,14 %
Přesnost po SW odstranění duplicit	80,43 %
Citlivost	98,23 %

Tabulka 34 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,05

Zdroj: Vlastní bádání

Jen 3 snímky byly analyzovány bez chyby. Nejčastější chybou, která se při snižování thresholdu navyšuje, je pozitivní halucinace, která dosáhla hodnoty 81,54 % a při dalším snižování thresholdu by dále rostla.



Obrázek 45 - Extrémní pozitivní halucinace za denního světla při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.6.3.2 Tma

Stejně jako za denního světla vzrostl jak počet správně detekovaných sýkor, tak chybovost. Ze 113 správně detekovaných sýkor za thresholdu 0,1 počet vzrostl na 121, ale objevilo se 63 falešných detekcí a duplicit bylo dokonce 485. Citlivost sice vzrostla na 93,80 %, ale přesnost i po softwarových úpravách klesla pod 80 % na 78,57 %.

Skutečný počet objektů na snímcích	129
Počet vyhodnocených objektů	669
Nejčastější chyba	Pozitivní halucinace 81,91 % (548 případů z 669)
Správně vyhodnocených	121
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	485 duplicit 63 falešných vyhodnocení na 33 snímcích
Přesnost	18,09 %
Přesnost po SW odstranění duplicit	78,57 %
Citlivost	93,80 %

Tabulka 35 - Výsledky rozpoznání dospělých sýkor na snímcích za denního světla při thresholdu 0,05

Zdroj: Vlastní bádání

Žádný snímek nebyl analyzován bezchybně. Nejčastější chybou byla pozitivní halucinace, a to jak duplicity, tak falešné detekce, které byly často také duplicitní. Takto nízký threshold tedy není pro tmavé snímky vhodný.



Obrázek 46 - Extrémní pozitivní halucinace za tmy při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.6.3.3 Černobílý noční přísvit

Na černobílých snímcích se ze správně zhodnocených sýkor za thresholdu 0,1 v počtu 42 podařilo výsledek téměř zdvojnásobit na 81, citlivost se zvýšila na 63,28 %. Přesnost i po úpravách ale opět klesla pod 80 %, a to na 78,64 %.

Skutečný počet objektů na snímcích	128
Počet vyhodnocených objektů	220
Nejčastější chyba	Pozitivní halucinace 63,18 % (139 případů z 220)
Správně vyhodnocených	81
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	97 duplicitních vyhodnocení 42 falešných detekcí na 22 snímcích
Přesnost	36,82 %
Přesnost po SW odstranění duplicit	78,64 %
Citlivost	63,28 %

Tabulka 36 - Výsledky rozpoznání dospělých sýkor na černobílých snímcích při thresholdu 0,05

Zdroj: Vlastní bádání

14 snímků bylo vyhodnoceno bezchybně. Nejčastější chybou byla pozitivní halucinace, a to jak ve formě vícenásobného vyhodnocení stejné sýkory, tak ve formě falešných detekcí, které způsobily, že přesnost klesla pod požadovanou hranici. Threshold 0,05 je tedy i pro černobílé snímky příliš nízký.



Obrázek 47 - Pozitivní a negativní halucinace při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.6.3.4 Fialový noční přísvit

Z 69 rozpoznávaných sýkor za thresholdu 0,1 vzrostl počet na 101, čímž se podařilo zvýšit citlivost na 80,16 %, což dostačuje pro úspěšnost modelu. I upravená přesnost dosáhla hodnoty 80,80 %.

Skutečný počet objektů na snímcích	126
Počet vyhodnocených objektů	441
Nejčastější chyba	Pozitivní halucinace 77,10 % (342 případů z 441)
Správně vyhodnocených	101
Nesprávně vyhodnocených (duplicitní vyhodnocení – pozitivní halucinace)	256 duplicit 84 falešných vyhodnocení na 24 snímcích
Přesnost	22,90 %
Přesnost po SW odstranění duplicit	80,80 %
Citlivost	80,16 %

Tabulka 37 - Výsledky rozpoznání dospělých sýkor na snímcích s fialovým nočním přísvitem při thresholdu 0,05

Zdroj: Vlastní bádání

Pouze 4 snímky byly analyzovány bezchybně. Na ostatních docházelo k duplicitním vyhodnocením a v 84 případech se jednalo o falešná vyhodnocení. Pro snímky s fialovým nočním přísvitem je ale toto hodnocení stále použitelné.



Obrázek 48 - Falešná detekce sýkory za fialového nočního přísvitu při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.6.3.5 Souhrnné výsledky

Identická sada obrázků jako při předchozích testech modelu rozpoznání dospělých sýkor byla otestována při hodnotě aktivační funkce threshold 0,05. Zatímco citlivost vzrostla ve váženém průměru na 88,65 %, přesnost dále klesla. Snižující se hodnota funkce threshold způsobuje u detekcí častější výskyt pozitivních halucinací za všech světelných podmínek a poměrně velká část těchto halucinací jsou při hodnotě 0,05 falešné detekce. Opravená přesnost klesla na 79,62 %, což je těsně pod hranicí úspěšnosti stanovené na 80 %.

Světelné podmínky	Denní světlo	Tma	Černobílý přísvit	Fialový přísvit	Konečný výsledek
Přesnost	0.1814	0.1809	0.3682	0.229	
Přesnost po odstranění duplicit	0.8043	0.7857	0.7864	0.808	
Citlivost	0.9823	0.938	0.6328	0.8016	
Váha	0.537	0.208	0.24	0.015	
Průměrný výsledek citlivosti	0.5274951	0.195104	0.151872	0.012024	0.8864951
Průměrný výsledek přesnosti	0.097418	0.0376272	0.088368	0.003435	0.226842
Průměrný výsledek opravené přesnosti	0.4319091	0.1634256	0.188736	0.01212	0.7961907

Tabulka 38 - Souhrnné výsledky přesnosti a citlivosti při thresholdu 0,05

Zdroj: Vlastní bádání

4.6.6.4 Závěr

Při hodnotě thresholdu 0,3 byla citlivost rovna 56,08 % a opravená přesnost 99,38 %. Při hodnotě thresholdu 0,05 byla citlivost rovna 88,65 % a opravená přesnost 79,62 %. Při hodnotě thresholdu 0,1 byla citlivost rovna 76,34 % a opravená přesnost 93,57 %.

Z těchto hodnot vyplývá, že pro požadovaných 80 % rozpoznání je, stejně jako u modelu rozpoznávajícího nesenou potravu, nejvhodnější použít hodnotu aktivační funkce threshold mezi 0,5 a 1, kde budou hodnoty citlivosti i opravené přesnosti vyšší nebo rovny 80 %.

Threshold	0.3	0.1	0.05
Citlivost	0.560831	0.763421	0.886495
Přesnost	0.57287	0.338743	0.226842
Opravená přesnost	0.993771	0.935665	0.796191

Tabulka 39 - Závěrečné zhodnocení metodických metrik modelu rozpoznávajícího dospělé jedince

Zdroj: Vlastní bádání

Model rozpoznávající dospělé jedince byl tedy podle předem stanovených kritérií úspěšný a provozuschopný.

4.7 Verifikace a implementace hotových modelů

Vzhledem k tomu, že trénink probíhal přímo na serveru USPIN.cz, byla implementace do portálu provedena krátce po jejich vytrénování, a testování hotových modelů bylo provedeno až po implementaci. Verifikace nebyla provedena vzhledem k absenci softwaru provádějícího verifikaci, byly provedeny pouze testy a vypočítány předem vybrané metriky.

4.8 Uvedení do praxe

Hotové modely byly ještě před ukončením testování využívány k testům jinými uživateli portálu BirdObserver. Po dokončení všech testů a přetrénování modelů určených pro rozpoznání nesené potravy a dospělých sýkor bylo vše připraveno na další výzkum. Bude vytvořena knihovna v jazyce JAVA, která využije modely tím způsobem, že automaticky vyhodnotí rámečky vytvořené modelem a výsledky zaznamená do databáze, a tato knihovna bude implementována do prostředí PtaciOnline.cz.

5 Výsledky a diskuse

Výsledkem kroků podrobněji popsaných v předchozích kapitolách byl vznik a zhodnocení kvality tří samostatných modelů, z nichž byl každý určen k rozpoznání jediné třídy objektů, a to nesená potrava, vejce a dospělá sýkora. Tyto modely budou implementovány do prostředí PtaciOnline.cz za pomoci knihovny v jazyce JAVA. Byly trénovány na portálu USPIN.cz. a testy jsem prováděla rovněž na portálu USPIN.cz.

Testy jsem, kromě u modelu rozpoznávajícího vejce, kde byly rozdíly mezi detekcemi za různých světelných podmínek zanedbatelné, prováděla na čtyřech různých světelných kategoriích a tyto kategorie jsem vyhodnocovala zvlášť, a poté jsem pomocí váženého průměru vypočítala celkovou hodnotu úspěšnosti.

Hodnotu úspěšnosti vyhodnocení snímků jsem měřila pomocí jednotek přesnosti, softwarově opravené přesnosti (po odstranění duplicit) a citlivosti. Požadavek byl 80 % a konečné výsledky byly následující.

5.1 Model k rozpoznání nesené potravy

5.1.1 Výsledky

Model rozpoznávající nesenou potravu se podařilo vytrénovat a otestovat a zjistila jsem, že při použití hodnoty aktivační funkce threshold mezi 0,1 a 0,05 odpovídá kritériím úspěšnosti, a to jak citlivosti, která hodnotí počet úspěšných vyhodnocení oproti všem objektům v obrázcích, tak opravené přesnosti, která hodnotí počet správných detekcí oproti všem detekcím po softwarové úpravě odstranění duplicitních překrývajících se rámečků.

První verze modelu měla výrazně lepší výsledky rozpoznání nesené potravy na snímcích pořízených za denního světla než na snímcích pořízených za nočního přísvitu. Navzdory tomuto faktu byla i první verze v průměrných hodnotách úspěšná.

Poté byla vytvořena druhá verze, u které se rozšířila učební sada o černobílé snímky, a úspěšnost rozpoznání za těchto světelných podmínek vzrostla. V průměru ale obě verze modelu vykazovaly přibližně stejné hodnoty a obě verze odpovídaly oběma kritériím úspěšnosti.

5.1.2 Prostor pro zlepšení

Vzhledem k dobrým výsledkům je model použitelný i tak, jak je, ale vždycky je možné navýšit množství snímků v učební sadě, aby se dosahovalo ještě lepších výsledků.

5.2 Model k rozpoznání vajec

5.2.1 Výsledky

Model určený k rozpoznání vajec ve snůšce byl testován při hodnotách thresholdu 0,05-0,2, protože vykazoval jiné chování než ostatní modely. Pro tento typ úlohy je důležité, aby model správně sčítal počty vajec na snímku a hledala jsem takový threshold, při kterém by byl správně zanalyzováno 80 % snímků. Bohužel během testů takový threshold nebyl nalezen, nejčastější správná analýza byla za thresholdu 0,09, ale pouze na 36 % snímků.

5.2.2 Prostor pro zlepšení

Pro zkvalitnění modelu určeného k rozpoznání vajec bude zapotřebí zvýšit množství snímků v učební sadě. Model v současné verzi nerozpoznává správně ani počty, ani pozice vajec a bude potřeba rozšířit učební sadu a přetrénovat.

5.3 Model k rozpoznání dospělého jedince

5.3.1 Výsledky

Model určený k rozpoznání dospělého jedince se podařilo vytvořit s požadovanými hodnotami úspěšnosti hodnocení, a to jak citlivosti, tak v opravené přesnosti. Pro dosažení nejlepších výsledků je vhodné použít hodnotu aktivační funkce threshold stejnou jako u modelu rozpoznávajícího nesenou potravu, a to mezi 0,1 a 0,05, protože při takových hodnotách dosahuje citlivost i opravená přesnost hodnot vyšších nebo rovných požadovaným 80 %.

5.3.2 Prostor pro zlepšení

Na snímcích, kde jsou dospělé sýkory zobrazeny pod nočním přisvitem, ať už černobílým nebo fialovým, jsou, stejně jako je tomu tak u první verze modelu rozpoznávajícího nesenou potravu, obecně horší výsledky v porovnání s denním světlem a

tmou. Bylo by vhodné rozšířit učební sadu o další snímky za těchto světelných podmínek. Také by bylo vhodné zjistit příčinu častých duplicitních vyhodnocování a odstranit ji, aby nemuselo docházet ke zpětnému softwarovému odstraňování překrývajících se rámečků.

5.4 Možnosti využití práce a návrh na budoucí rozvoj

Každý z modelů je určen k rozpoznání pouze jedné třídy, a proto každý z nich poslouží jinému účelu.

Model rozpoznávající nesenou potravu bude možné použít na sekvenci snímků k rozhodnutí, zda na dané sekvenci proběhlo krmení. Pomocí tohoto modelu bude možné tedy vytvářet např. statistiky, kolikrát za den probíhá krmení v závislosti na věku mládřat.

Model určený k rozpoznání vajec bude po přetrénování možné použít k automatickému rozpoznání počtu vajec ve snůšce a bude možné např. při zvyšujícím se počtu vajec zjišťovat, kdy přibyla do snůšky nová vejce a při snižujícím se počtu detekovaných vajec mapovat, kdy došlo k líhnutí mládřat.

Model detekující dospělé jedince je univerzálně použitelný k mapování příletů a odletů sýkor, bude tedy vhodný pro statistiky těchto aktivit, např. když mají sýkory mladé a případně také rychle zhodnotí, když se v prázdné budce objeví hnízdění.

Do budoucna by bylo vhodné přetrénovat model rozpoznávající vejce tak, aby úspěšně fungoval, a bylo by vhodné vytvořit další modely rozpoznávající další objekty v hnízdě, např. mládřata. Také by bylo zapotřebí pro další automatizaci zpracování dat vytvořit modely rozpoznávající vejce, potravu, mládřata i dospělé jedince jiných druhů ptáků, než jsou sýkory koňadry.

6 Závěr

Cílem této práce bylo vytvořit tři modely k rozpoznání konkrétního objektu v obraze pro projekt Ptáci Online. První model má rozpoznávat nesenou potravu, druhý model je určen k rozpoznání vajec ve snůšce a třetí mapuje, zda se v hnízdě nachází dospělý jedinec.

Bylo položeno několik počátečních otázek týkajících se projektu Ptáci Online jako celku, dále neuronových sítí a postupu vzniku modelů schopných rozpoznávat objekty v obrázku. Na všechny tyto otázky bylo v průběhu práce zodpovězeno. Také byl navržen budoucí postup navazující na tuto práci a byl také popsán prostor pro zlepšení.

Metodou využití volně dostupného nástroje umělé inteligence DeepLearning4J používajícího konvoluční neuronové sítě k rozpoznávání objektů v obraze a také s použitím potřebného přidruženého softwaru byly vybrány tři sady obrázků, ze kterých byly vytrénovány tři samostatné modely schopné rozpoznat potřebný objekt.

Během procesu vzniku těchto modelů jsem u dvou z modelů, a to konkrétně u modelu rozpoznávajícího dospělé jedince a u modelu rozpoznávajícího nesenou potravu, rozšířila datovou základnu obrázků a modely byly přetrénovány, protože model rozpoznávající dospělé jedince již v první fázi testování rozpoznával sýkory navzdory tomu, že se v obrázku nenacházely, a v ostrých obrázcích, kde se nacházela jedna sýkora, viděl duplicity. Model rozpoznávající nesenou potravu naopak nerozpoznával téměř žádné objekty na černobílých snímcích s nočním přisvitem. Po rozšíření učební sady a přetrénování došlo u obou modelů ke zlepšení zmíněných problémů, model rozpoznávající nesenou potravu lépe poznával objekty na snímcích s nočním přisvitem a model rozpoznávající sýkory přestal vykazovat falešné detekce, duplicity se ale odstranit nepodařilo. Model rozpoznávající vejce byl testován jako poslední a ukázal se po testování jako neúspěšný, takže by bylo zapotřebí začít znovu a významně rozšířit učební sadu.

Modely byly po vytrénování prozkoušeny jak v prostředí BirdObserver jinými uživateli, tak jsem je na portálu USPIN.cz, kam byly pro testovací účely nahrány, testovala sama. V průběhu testů jsem zjistila a částečně odstranila nedostatky, ať už se jednalo o negativní či pozitivní halucinaci ve formě duplicit či falešných detekcí. Současné nedostatky modelů by se s určitou pravděpodobností daly odstranit dodatečným rozšiřováním učebních sad, a

v případě duplicitních vyhodnocení objektů se dá navýšit přesnost rozpoznání pomocí softwarového odstranění duplicitních rámečků.

Modely prošly zevrubným testováním, v rámci něžž byly porovnávány původní snímky se snímky, do kterých byly pro každou hodnotu aktivační funkce threshold vkresleny rámečky. Vypočítala jsem jak množství úspěšných detekcí oproti všem skutečně se vyskytujícím objektům v obrázku, tedy citlivost, tak množství detekcí oproti pravdivým detekcím, tedy přesnost, a také upravenou přesnost po softwarovém odstranění duplicitních rámečků. Také jsem určovala úroveň halucinace a nejčastější chybu a stanovila jsem hodnotu thresholdu, za které je nejvhodnější modely používat, aby odpovídaly kritériím úspěšnosti, které byly před začátkem testování stanoveny na 80 %.

Dva modely, a to model rozpoznávající nesenou potravu a model rozpoznávající dospělé sýkory koňadry, prošly úspěšně testováním, byly označeny za dostatečně kvalitní, a dále budou uvedeny do provozu ve formě knihovny v jazyce JAVA. Modely jsou připraveny pro využití v dalším výzkumu.

7 Seznam použitých zdrojů

1. **VONDRÁK, Ivo.** *Umělá inteligence a neuronové sítě*. Ostrava : Vysoká škola báňská - Technická univerzita, 2000. ISBN: 80-7078-949-2.
2. **ÇELEBİ, Ömer Cengiz.** Chapter 7 Neural Network. *Celebi Tutorial: Neural Networks and Pattern Recognition Using MATLAB*. [Online]. Dostupné z: https://www.byclb.com/TR/Tutorials/neural_networks/ch7_1.htm.
3. **ŠÍMA, Jiří, NERUDA, Roman.** *Teoretické otázky neuronových sítí*. Praha : Matfyzpress, 1996. ISBN 80-85863-18-9.
4. **ŠUHADA, Robert.** Úsvit revoluce: umělá inteligence a revoluce hlubokého učení. *IT Systems*. Roč. 20, č. 4 2018.
5. **HAYKIN, Simon S.** *Neural networks and learning machines*, Upper Saddle River : Pearson Education. místo neznámé : Pearson, 2009. ISBN: 978-0-13-147139-9.
6. **HAKL, František, HOLEŇA, Martin.** *Úvod do teorie neuronových sítí*. Praha : České vysoké učení technické, 1998. ISBN: 80-01-01716-8.
7. **KRAJČOVIČOVÁ, Mária.** *KONVOLUČNÍ NEURONOVÁ SÍŤ PRO ZPRACOVÁNÍ OBRAZU*. Brno : VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ, FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ, DIPLOMOVÁ PRÁCE, 2015.
8. **Živě.** Živě.cz. [Online] . Dostupné z: https://www.zive.cz/getthumbnail.aspx?w=1600&h=1000&q=60&id_file=102985407.
9. **KOVÁR, Martin.** Maticový a tenzorový počet. *Fakulta elektrotechniky a komunikačních technologií VUT v Brně*. [Online] 2014. Dostupné z: <http://www.umat.feec.vutbr.cz/~kovar/webs/personal/MMAT.pdf>.
10. **WikiMedia.** [Online]. Dostupné z: https://upload.wikimedia.org/wikipedia/commons/thumb/4/45/Components_stress_tensor.svg/300px-Components_stress_tensor.svg.png.
11. **MATAS, Jiří.** courses:b4b33rpz:lectures. *CourseWare Wiki*. [Online] 2018. Dostupné z: <https://cw.fel.cvut.cz/b181/courses/b4b33rpz/lectures>.
12. **MATOUŠEK, Jan.** Hluboké učení pro každého? Neuronové sítě a spol. *DataMind s.r.o.* [Online] 14. březen 2018. Dostupné z: <http://www.datamind.cz/cz/blog/hluboke-uceni-neuronove-site>.
13. **MARBLESTONE, Adam H., WAYNE, Greg a KORDING, Konrad P.** Toward an Integration of Deep Learning and Neuroscience. *Frontiers in Computational Neuroscience*.

[Online] 14. září 2016. Dostupné z:

<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5021692>.

14. BISHOP, Christopher M. *Neural Networks for Pattern Recognition*. Oxford : Clarendon Press, 1997. ISBN: 0-19-853864-2.

15. Algoritmus zpětného šíření chyby (BP algoritmus). *Matematická biologie učebnice*.

[Online]. Dostupné z: <http://portal.matematickabiologie.cz/index.php?pg=analiza-a-hodnoceni-biologickych-dat--umela-inteligence--neuronove-site-perceptrony--vicevrstvy-perceptron--algoritmus-zpetneho-sireni-chyby-bp-algoritmus>.

16. Neuronové sítě - Perceptrony. [Online] matematickabiologie. Dostupné z:

<http://portal.matematickabiologie.cz/res/f/neuronove-site-perceptrony.pdf>.

17. JIRKOVSKÝ, Jaroslav. Počítačové vidění: od hledání vzoru po Deep Learning.

Automa. Roč. 24, 4 2018. Dostupné z: http://www.automa.cz/cz/casopis-clanky/pocitacove-videni-od-hledani-vzoru-po-deep-learning-2018_04_0_11425/.

18. PAVLÍČEK, Josef, a kolektiv. Automated Wildlife Recognition. *Agris on-line Papers in Economics and Informatics*. 2018, Sv. 10, 1, stránky 51-60.

19. Falukta životního prostředí, Česká zemědělská univerzita v Praze. Titulní stránka.

Ptáci Online - Informační server pro sledování hnízdění ptactva. [Online] . Dostupné z: <https://www.ptacionline.cz/>.

20. Věda24. Inteligentní ptačí budky. *Facebook*. [Online]. Dostupné z:

<https://www.facebook.com/watch/?v=2064616706885008>.

21. UdálostiČT. Online sledování ptáků. *Události - iVysílání - Česká televize*. [Online] 28.

červen 2015. Dostupné z: <https://www.ceskatelevize.cz/ivysilani/1097181328-udalosti/215411000100628/obsah/409622-online-sledovani-ptaku>.

22. TensofFlow. TensorFlow. [Online]. Dostupné z: <https://www.tensorflow.org/>.

23. uživatel, sentdex. Python Programming Tutorials - Introduction and Use - Tensorflow Object Detection API Tutorial. [Online] 2017. Dostupné z:

<https://pythonprogramming.net/introduction-use-tensorflow-object-detection-api-tutorial/>.

24. HUANG, Johnatan. GitHub - Tensorflow Object Detection API. [Online] 2017.

Dostupné z: https://github.com/tensorflow/models/tree/master/research/object_detection .

25. MCCLURE, Nick. *TensorFlow Machine Learning Cookbook*. Birmingham : Packt Publishing Ltd., 2017. ISBN 978-1-78646-216-9.

26. uživatel, datitran.

[object_detector_app/object_detection/ssd_mobilenet_v1_coco_11_06_2017/](https://github.com/datitran/object_detector_app/blob/master/object_detection/ssd_mobilenet_v1_coco_11_06_2017.py). [Online]

GitHub, 19. červen 2017. Dostupné z:

https://github.com/datitran/object_detector_app/tree/master/object_detection/ssd_mobilenet_v1_coco_11_06_2017.

27. GoogleInc. Obrázky Google. [Online] Google Inc. Dostupné z:

<https://images.google.cz/>.

28. uživatel, tzutalin, darrenl. tzutalin/labelImg. [Online] GitHub, 2017. Dostupné z:

<https://github.com/tzutalin/labelImg>.

29. uživatel, sentdex. PythonProgramming.net. [Online] 25. srpen 2017. Dostupné z:

<https://pythonprogramming.net/creating-tfrecord-files-tensorflow-object-detection-api-tutorial/> .

30. uživatel, datitran. raccoon_dataset/xml_to_csv.py. [Online] GitHub, 22. srpen 2017.

Dostupné z: https://github.com/datitran/raccoon_dataset/blob/master/xml_to_csv.py .

31. uživatel, VictorDDT. raccoon_dataset/generate_tfrecord.py. [Online] GitHub, 21.

srpen 2018. Dostupné z:

https://github.com/datitran/raccoon_dataset/blob/master/generate_tfrecord.py .

32. uživatel. ssd_mobilenet_v1_pets.config. [Online] GitHub, 2018. Dostupné z:

https://github.com/tensorflow/models/blob/master/object_detection/samples/configs/ssd_mobilenet_v1_pets.config.

33. Skymind. About Eclipse Deeplearning4j. [Online] Eclipse Deeplearning4j, 2018.

Dostupné z: <https://deeplearning4j.org/about>.

34. ARLEN, Timothy C. Understanding the mAP Evaluation Metric for Object Detection.

[Online] MEDIUM, 1. březen 2018. Dostupné z:

<https://medium.com/@timothycarlen/understanding-the-map-evaluation-metric-for-object-detection-a07fe6962cf3> .

35. Medium. [Online] CDN Images. Dostupné z: [https://cdn-images-](https://cdn-images-1.medium.com/max/800/1*ceYw4cXV4BtB2s7S9e1Exg.png)

[1.medium.com/max/800/1*ceYw4cXV4BtB2s7S9e1Exg.png](https://cdn-images-1.medium.com/max/800/1*ceYw4cXV4BtB2s7S9e1Exg.png).

36. ČZU, PEF. Index of /ptacionline. [Online] PEF ČZU. Dostupné z:

<http://athena.pef.czu.cz/ptacionline/> .

37. BulkResizePhotos. [Online] MIT License, 2009-2014. Dostupné z:

<https://bulkresizephotos.com/>.

38. USPINS.r.o. Referenční projekty. [Online] USPIN s.r.o. Dostupné z:

<https://www.uspin.cz/cz/referencni-projekty>.

