



CHARLES UNIVERSITY  
Faculty of Science



Přírodovědecká fakulta UK

Ústav Gisat, s.r.o.

TRL Space

Projekt TAČR SS07010417

## Využití technologií DPZ pro dozorovou činnost ČIŽP

# Postup pro automatizovaný detailní monitoring pro potřeby dozorové činnosti v oblasti ochrany přírody – vegetace – s využitím UAV multispektrálních dat

Autoři: Lucie Červená, Jakub Lysák, Jakub Fuchsig

Přírodovědecká fakulta UK, prosinec 2025

## OBSAH

Úvod .....	3
1. Načasování pořízení dat .....	3
2. Pořízení UAV dat a jejich předzpracování .....	3
3. Sběr pozemních dat pro trénování a validaci modelů hlubokého učení.....	4
4. Výběr vhodného modelu hlubokého učení a ladění parametrů sítě.....	6
5. Automatizovaný detailní monitoring.....	9
Krok 1: Označení trénovacích dat (Labeling) .....	9
Krok 2: Export trénovacích dat .....	9
Krok 3: Trénování modelu.....	9
Krok 4: Detekce (Inference) .....	10
Krok 5: Výpočet přesnosti.....	10
Krok 6: Interpretace výsledků.....	10
Skript automatizující vybrané části postupu.....	11
Závěr .....	12
Odkaz na výsledek .....	13

## Úvod

Cílem bylo navrhnout postup mapování jednotlivých rostlin (vybrané chráněné druhy) s využitím dat z UAV. Automatizovat postup analýzy obrazových dat a provést vyhodnocení přesnosti.

Následující text shrnuje obecný doporučený postup pro mapování jednotlivých rostlin (chráněných druhů) aproximovaných jejich květem. Popisuje, jak danou aktivitu naplánovat, na co je potřeba si dát pozor, jak postupovat při zpracování dat a které kroky lze efektivně automatizovat a které nikoliv. Kurzívou jsou pak popsány konkrétní příklady, na kterých byl postup vyvíjen a testován. Postup zahrnuje tyto kroky: pořízení RGB dat z dronu a jejich předzpracování, sběr trénovacích a validačních dat, výběr vhodného modelu hlubokého učení a ladění jeho parametrů a validaci výsledků. Je též ukázáno, které kroky lze zautomatizovat pomocí skriptu, který je zde též zahrnut.

## 1. Načasování pořízení dat

Znalost přesné doby kvetení pro úspěch metody je klíčová, neboť se detekuje počet květů. Ke zjištění doby kvetení je kromě znalosti/zkušenosti botaniků možné využít Náleзовou databázi ochrany přírody (AOPK ČR) a databázi [iNaturalist.org](https://www.inaturalist.org), kde se dá zjistit, v jakém období byly pozorovány kvetoucí jedinci a kde.

## 2. Pořízení UAV dat a jejich předzpracování

UAV data musí mít co nejlepší prostorové rozlišení (v řádu milimetrů), ale zároveň je dobré mít senzor, se kterým lze létat dostatečně vysoko nad porostem, aby nedocházelo k jeho rozfoukávání z dronu, neboť pohyb vegetace znemožňuje tvorbu výsledného ortofota. Při vybírání senzoru pro danou úlohu je tedy třeba zohlednit skutečnou ohniskovou vzdálenost a fyzickou velikost pixelu senzoru dle vzorce:

$$GSD = (\text{letová výška nad terénem} \times \text{fyzická velikost pixelu senzoru}) / \text{skutečná ohnisková vzdálenost},$$

ze kterého plyne, čím větší ohnisko a menší pixel, tím menší GSD při stejné výšce.

Při letu v nízké výšce též může být problém s hloubkou ostrosti, na výsledek bude mít velký vliv jakákoli nepřesnost v kopírování terénu a výsledné snímky mohou být mimo hloubku ostrosti. Vzhledem k tomu, že k detekcím se osvědčily RGB snímky, doporučují se používat pouze RGB kamery, které mají typicky lepší vlastnosti než kamery smíšené s multispektrálními senzory.


Důležité jsou i vlastnosti samotné mapované lokality - je nutné, aby na snímané ploše byl dostatečný počet jedinců zájmového druhu (nutné pro trénování modelů, a to i v případě využití již předtrénovaného modelu - aby byly výsledky co nejpřesnější, je totiž nutné jeho dotrénování na každé lokalitě). Pokud se na dané lokalitě nachází více kvetoucích druhů (obzvláště kvetoucích stejnou barvou), je nutné geodetické zaměření trénovacích dat (což může být problematické z hlediska rozšlapání lokality) nebo alespoň pořízení fotografií (šikmých fotografií), ze kterých půjdou druhy rozpoznat a určit na ortofotu.

*Pro demonstraci byly v rámci projektu pořízeny dvě sady dat:*

- červen 2024 - kvetoucí **prstnatce na podmáčené louce u Adolfovy vyhlídky na enklávě Lahrovy boudy v Krkonoších** (DJI Mavic 3M se 4 pásmy G, R, RedEdge, NIR a RGB; manuálně pilotovaný let ve výšce 3,6 m nad terénem a odpovídajícím pixelem zhruba 1 mm). Vzhledem k velikosti květů nebylo možné uvažovat o větší GSD. Bohužel se zde projevila nevhodnost dostupného senzoru - kvůli rozfoukávání rostlin vznikly při zpracování ortofota výrazné artefakty, zároveň pořízené snímky nebyly dokonale zaostřené. Lokalita je též velmi malá s omezeným množstvím prstnaticů, což stěžuje natrénování sítě hlubokého učení vyžadující velké množství trénovacích dat. Toto vše spolu s nemožností zmapovat jednotlivé výskyty pomocí geodetické GNSS, aby

nedošlo k rozšlapání lokality, vyústilo k vyhodnocení této datové sady a lokality jako nevhodné pro další experimenty.

- březen 2025 - kvetoucí **hlaváčky jarní v Českém krasu** byly vybrány kvůli větší velikosti květu, a tak i možnosti použít dostupnou techniku. Zároveň se nachází v krátkostébelnaté stepi, takže bylo snadné i mapování rostlin a ještě více minimalizován případný vliv rozfoukávání vegetace dronem. Data byla snímána drony DJI Mavic 3M a DJI Mavic 2 Pro (pouze RGB kamera) z různých výšek nad terénem následovně (též viz obrázek 1):
  - celá lokalita RGB kamerou DJI M3M z výšky zhruba 17 m pomocí automatického letu - výsledné ortofoto s prostorovým rozlišením 0,503 cm
  - plocha 1 - manuální let DJI M3M (RGB) ve výšce zhruba 4 m, pořizování snímků po 1 s, vytvořeno ortofoto s prostorovým rozlišením 0,113 cm + pořizování snímků jednoho místa z různých výšek od 4 do 20 m nad terénem s intervalem 1 m (DJI Mavic 2 Pro)
  - plocha 2 - manuální let DJI M3M (RGB) ve výšce zhruba 1,5 - 2,8 m (nemožné dokonalé sledování terénu), pořizování snímků po 1 s, vytvořeno ortofoto s prostorovým rozlišením 0,096 cm



Obrázek 1 - ortofota pořízená pro hlaváček jarní v Českém krasu

Zpracování snímků do ortofot probíhá standardními fotogrammetrickými způsoby v softwarech Agisoft Metashape či Pix4D. Výsledky z Pix4D se však v případě velmi podrobných ortofot vegetace (tedy povrchu vyloženě fraktálního charakteru) osvědčily více.

### 3. Sběr pozemních dat pro trénování a validaci modelů hlubokého učení

Trénovací data je ideální označovat přímo na snímcích (nemusí to být ani nad ortofotem, stačí nad jednotlivými snímky, nad kterými je dobré označit všechny výskyty hledaného druhu, aby se algoritmus naučil i to, co daný druh není - tj. vše neoznačené). Pro validaci je však dobré mít data přímo z terénu, např. přesným GNSS zařízením zaměřené méně nápadné zájmové jedince i druhy, se kterými by se mohly jeho detekce plést.

Trénovací data pro hlaváčky jarní byla anotována nad snímkem pořízeným pomocí DJI M3M z výšky zhruba 4 m nad terénem (plocha 1) vybraným tak, aby na něm bylo co nejvíce výskytů hlaváček - celkem bylo anotováno 40 květů (viz obrázek 2). Model natrénovaný na těchto trénovacích datech byl použit jednak pro detekce na stejném snímku, tak na dalších jednotlivých snímcích (i těch z dronu DJI Mavic 2 Pro) a vytvořených ortofotech. Pro snímky a ortofota pořízená z podobné výšky byly výsledky detekcí dobré. Pro ortofoto celé plochy ze 17 m musel být model dotrénován dalšími daty - anotovány tak byly tři výřezy z tohoto ortofota, kde bylo velké zastoupení hlaváčků, ale i takové, kde žádné hlaváčky nebyly a vyskytovaly se v nich žluté lišejníky na stromech, které při použití prvotně natrénovaného modelu byly chybně detekovány. Celkem bylo pro detekce nad ortofotem ze 17 m přidáno 91 anotací.



Obrázek 2 - hlaváčky ručně anotované na snímku DJI\_20250328140647\_0080\_D (DJI M3M, výška letu cca 4 m)

Pro validace hlaváčků byla použita sada dat zaměřených v terénu pomocí GNSS zařízení STONEX S70G RTK doplněná o 136 manuálně určených hlaváčků nad ortofotem celé oblasti. STONEX S70G RTK má anténu přímo propojenou s tabletem a využívá technologii RTK (Real-Time Kinematic), což umožňuje v dobrých podmínkách dosáhnout prostorové přesnosti až 2 cm. Byl použit k zaměření nevýrazných jedinců hlaváček a mochny jako jiného žlutě kvetoucího druhu, se kterým by se mohly detekce hlaváčků plést - celkem bylo v terénu naměřeno 30 bodů. Hodnocení přesnosti nad touto validační sadou bylo možné provést pouze pro detekce na ortofotu pro celou lokalitu.

#### 4. Výběr vhodného modelu hlubokého učení a ladění parametrů sítě

Za účelem uživatelsky přívětivého zpracování bylo vybráno řešení v ArcGIS Pro s využitím toolboxu Image Analyst Tools, který obsahuje nástroje pro Deep Learning. Osvědčil se model Mask R-CNN s architekturou ResNet-50 jako backbone (kromě hlaváček například i na detekce květů lupiny mnohohlísté v rámci bakalářské práce Jakuba Fuchsiga, 2025). Tento model využívá trénovací data ve

formátu RCNN Masks, který na rozdíl od ostatních modelů využívá rastrové masky odpovídající tvaru anotací místo obdélníkových ohraničení (bounding boxes). Tento formát metadat lépe zachycuje nepravidelné tvary přírodních objektů, jako jsou květy rostlin, což může mít pozitivní vliv na přesnost detekce. Výsledkem jsou též polygony respektující tvar květu, snadno se tak dá zjistit jejich počet, který může napovídat o tom, kolik rostlin daného druhu roste na zájmové ploše.

Níže je přehled vybraných parametrů, které se nastavují pro trénování modelu a jejich doporučené hodnoty. Při nastavování parametrů bylo cílem zvolit takové hodnoty, které jednak odpovídají běžným doporučením pro objektovou detekci ve snímcích UAV a zároveň zohledňují dostupné výpočetní zdroje (podrobně též v dokumentaci ArcGIS Pro).


- **Parametr chip size** (v tomto případě nastavený na 256 pixelů) určuje velikost čtvercových výřezů, na které je vstupní obraz během trénování rozdělen. Cílem této strategie je zvýšit počet trénovacích vzorků a zároveň přizpůsobit velikost vstupu sítě, která často vyžaduje fixní rozměr. Zvolená hodnota 256 px představuje kompromis mezi pokrytím dostatečného množství kontextu v okolí objektu (např. celé rostliny hlaváčku) a zachováním dostatečně jemného rozlišení. Příliš malý výřez by mohl zobrazit pouze část objektu, což by mohlo negativně ovlivnit trénink, zatímco příliš velký výřez by snížil počet dostupných trénovacích vzorků a zvýšil paměťové nároky.
- **Parametr batch size**, tedy počet trénovacích vzorků zpracovávaných v jednom kroku učení, má zásadní vliv na průběh optimalizace modelu. Určuje, kolik trénovacích vzorků (v našem případě obrazových dlaždic) projde modelem najednou, než dojde k aktualizaci vnitřních vah sítě. Při trénování AI se neprocházejí všechna data najednou (to by se nevešlo do paměti), ani se neaktualizují váhy po každém jednotlivém obrázku (to by bylo neefektivní a chaotické). Data se dělí do dávek (batches). Nižší hodnoty mohou urychlit výpočet, ale bývají méně stabilní a vedou k většímu kolísání při učení. Naopak vyšší hodnoty snižují šum v odhadu gradientu, avšak zvyšují nároky na paměť. U modelu Mask R-CNN, který je výpočetně náročnější, je vhodnější použít spíše nižší hodnoty blízké standardním výchozím doporučením (typicky 2, 4, 8) v závislosti na konkrétní hardwarové konfiguraci.
- **Rychlost učení (Learning rate)** byla nastavena na výchozí hodnotu 0,001. Tento parametr určuje, jak velké kroky model dělá při učení — tedy jak moc se mění jeho „nastavení“ po každé chybě. Pokud by byla hodnota příliš vysoká, model by mohl při učení oscilovat a nikdy by nenašel správné řešení. Naopak příliš nízká hodnota by mohla způsobit, že se model učí velmi pomalu a trénování by trvalo zbytečně dlouho. Hodnota 0,001 je běžně používaná jako rozumný výchozí kompromis a dobře funguje pro první trénovací pokusy bez nutnosti podrobného ladění.
- **Rozdělení na trénovací a validační část:** Validační sada tvořila 10 % trénovacích dat a sloužila ke sledování průběhu učení a k vyhodnocení rizika přeučení modelu (overfittingu). Na základě validační ztráty (VALID\_LOSS) byla také aktivována podmínka pro předčasné ukončení trénování (STOP\_TRAINING), která zabrání dalším epochám v případě, že se model již nezlepšuje. Tím se snižuje riziko degradace generalizace modelu na jiných datech.
- **Augmentace trénovacích dat** byla zvolena defaultní, která automaticky zahrnuje náhodné transformace jako rotace, změny jasu a kontrastu, přibližování a ořez. Tato augmentace zvyšuje variabilitu trénovacích vzorků a napomáhá modelu lépe se generalizovat na nové snímky, které mohou být pořízeny za různých světelných podmínek nebo z mírně odlišného úhlu.

*Ukázky výstupů modelu nad datasetem hlaváčku jarního jsou vidět v obrázcích 3 a 4. Tabulka 1 shrnuje přesnosti modelů použitých na ortofoto pro celou lokalitu nad validačními daty – jednak přeneseného modelu, který byl natrénován nad snímkem pořízeným ze 4 m (obrázek 2), tak i tohoto modelu, který*


byl dotrénován pomocí dalších 91 anotací ve třech výřezech ortofota celé lokality. Je vidět, že po dotrénování dává model výrazně lepší výsledky, především pak pro na ortofotu hůře viditelné hlaváčky. Pozitivní je, že ani jeden z modelů nedetekoval chybně žlutě kvetoucí mochnu jako hlaváček jarní.

Tabulka 1 – Přesnost modelů použitých na ortofoto pro celou lokalitu nad validačními daty

Model	původní model použitý nad ortofotem	model po dotrénování nad ortofotem
Nenápadné hlaváčky (detekované / zaměřené v terénu)	8 / 24	16 / 24
Recall [%]	33,33	66,67
Hlaváčky zřetelně viditelné na ortofotu (detekované / ručně označené nad OF)	120 / 136	127 / 136
Recall [%]	88,24	93,38
Mochna (detekovaná jako hlaváček / zaměřená v terénu)	0 / 6	0 / 6



Obrázek 3 - hlaváčky detekované na snímku DJI\_20250328140647\_0080\_D (DJI M3M, výška letu cca 4 m), oproti obrázku 2 je vidět, že model našel i některé hlaváčky, které byly anotátorem opomenuty (např. levá dolní třetina obrazu - hlaváček schovaný v trsu tmavší trávy)



Obrázek 4 - Detekce hlaváčku nad ortofotem celé lokality s pixelem 0,503 cm

## 5. Automatizovaný detailní monitoring

V této části je popsána možnost automatizace uvedeného postupu. Ta je díky předpřipraveným nástrojům v ArcGISu velmi snadná, ale její praktická použitelnost stojí a padá s vytvořením trénovacích dat. Je-li typická úloha "spočítej mi rostliny konkrétního druhu vyskytující se v zájmové oblasti", nemusí být tato technologie dobrou volbou, protože výroba podkladů pro trénování modelu tak, aby byl spolehlivý, bude pravděpodobně pracnější než manuální označení všech výskytů daného objektu na snímku. Výhody tohoto přístupu se projeví ve dvou scénářích:

1. zájmové území je velmi rozsáhlé, resp. jsou tam řádově alespoň tisíce objektů. Pak může dávat smysl na řádově stovkách manuálně označených objektů model natrénovat a spustit na celé území. Natrénování na nižším počtu objektů povede k tomu, že model nebude fungovat spolehlivě.
2. máme více zájmových území se stejným druhem, který chceme detekovat, s tím, že data byla pořízena za srovnatelných podmínek (např. fáze kvetení, ale do určité míry i podmínky snímání). Pak - při dobře natrénovaném modelu - lze použít na jednom zájmovém území natrénovaný model bez nutnosti manuálního označování objektů i na jiné území (nebo s dotrénováním pouze nad desítkami manuálně označených objektů). Klíčové jsou ovšem ty srovnatelné podmínky. Toto lépe odpovídá myšlence použití neuronových sítí, resp. hlubokého učení.

Celkově lze postup v ArcGIS Pro s využitím architektury Mask R-CNN s páteří sítí (backbone) ResNet-50 shrnout následovně:

### Krok 1: Označení trénovacích dat (Labeling)

1. Otevřete panel **Label Objects for Deep Learning** (na kartě *Imagery*).
2. Vytvořte novou klasifikační schémata (např. třída "Kvet").

3. V ortofotu ručně obkreslete květy. Pro Mask R-CNN je ideální používat nástroj **Polygon**, nikoliv jen obdélník, aby se síť naučila přesné tvary.

Tento krok je neautomatizovatelný. Lze ho přeskočit v situaci, kdy již máme natrénovanou síť.

## Krok 2: Export trénovacích dat

Použijte nástroj **Export Training Data For Deep Learning**.

- **Input Raster:** Vaše ortofoto.
- **Input Feature Class:** Vaše polygony květů.
- **Tile Size:** Typicky **256** nebo **512** (podle velikosti květů v pixelech).
- **Meta Data Format:** Pro Mask R-CNN je třeba zvolit **RCNN Masks**.

Tento krok lze udělat automaticky.

## Krok 3: Trénování modelu

Nástroj: **Train Deep Learning Model**.

- **Input Training Data:** Složka z předchozího kroku.
- **Model Type:** **MaskRCNN**.
- **Model Parameters:** Parametr **Backbone Model** nastavte na **resnet50**.
- **Batch Size:** Podle paměti GPU (typicky 2, 4 nebo 8).
- **Epochs:** Začněte na 20–50. Zaškrtněte **Stop when model stops improving**.

Tento krok lze udělat automaticky. Podrobnější poznámky k těmto a dalším parametrům viz výše v části *4 Výběr vhodného modelu hlubokého učení a ladění parametrů sítě*.

## Krok 4: Detekce (Inference)

Nástroj: **Detect Objects Using Deep Learning**.

- **Input Raster:** Nové ortofoto, kde chcete květy hledat.
- **Model Definition:** Soubor **.dlpk** nebo **.emd** vzniklý trénováním.
- **Padding:** Např. 100 (zabrání chybám na okrajích dlaždic).
- **Threshold:** Např. 0.5 (detekuje jen objekty s jistotou nad 50 %).

Tento krok lze udělat automaticky.

## Krok 5: Výpočet přesnosti

Nástroj: **Compute Accuracy For Object Detection**.

- **Detected Features:** Výsledek z nástroje **Detect Objects**.
- **Ground Truth Features:** Vaše ručně digitalizované polygony (testovací sada).
- **Output Accuracy Table:** Tabulka s metrikami.
- **IoU (Intersection over Union) Ratio:** Typicky **0.5**. Určuje, jak velký musí být překryv mezi detekcí a pravdou, aby byl výsledek uznán za správný.

Tento krok lze udělat automaticky.

## Krok 6: Interpretace výsledků

Výsledná tabulka poskytuje následující hodnoty:

Metrika	Význam pro hledání objektů	Výpočet
Precision (Přesnost)	Kolik z nalezených objektů jsou skutečně dané objekty (a ne něco jiného).	$TP/(TP+FP)$
Recall (Úplnost)	Kolik procent ze všech skutečných objektů model dokázal najít.	$TP/(TP+FN)$
F1-Score	Harmonický průměr Precision a Recall. Ideální pro celkové hodnocení.	$2*(Prec*Rec)/(Prec+Rec)$

**TP (True Positive):** Model našel objekt tam, kde skutečně je.

**FP (False Positive):** Model označil za objekt něco, co jím ve skutečnosti není (falešná detekce).

**FN (False Negative):** Model objekt přehlédl/nenašel.

### Jak poznat dobrý model?

- Pokud je **nízké Precision**, model je příliš "odvážný" a plete si s hledanými objekty i jiné věci ve scéně. Snižte **threshold** nebo přidejte negativní vzorky.
- Pokud je **nízký Recall**, model je příliš "opatrný" nebo nedostatečně naučený. Zvyšte počet epoch nebo přidejte více trénovacích dat.

Interpretace výsledků je vždy ovlivněna účelem, kvůli kterému se detekce provádí.

Automatizace navrženého postupu je v ArcGIS velmi snadná, protože funkce jsou poměrně vysokoúrovňové, tj. zahrnují již řešení spousty složitostí v sobě a uživatel je od nich odstíněn. Kroky 2 - 5 lze zautomatizovat např. pomocí Pythonu s využitím následujícího skriptu, v němž je pouze potřeba upravit cesty a dodat data z kroku 1.

### Skript automatizující vybrané části postupu

```
import arcpy
import os
from arcpy.ia import *

# --- Nastavení cest ---
ortho_path = r"C:\Projekt\Data\Ortofoto_Kvetina.tif"
train_labels = r"C:\Projekt\Data\Train_Polygons.shp" # Data pro učení
test_labels = r"C:\Projekt\Data\Test_Polygons.shp" # Data pro validaci
(Ground Truth)
output_base = r"C:\Projekt\DeepLearning"

# Podsložky
training_folder = os.path.join(output_base, "Exported_Tiles")
model_output = os.path.join(output_base, "Models\FlowerModel")
detected_flowers = os.path.join(output_base, "Output\Detected_Flowers.shp")
```

```

accuracy_table = os.path.join(output_base, "Output\Accuracy_Table") #
Tabulka výsledků

# Kontrola licencí
if arcpy.CheckExtension("ImageAnalyst") == "Available":
    arcpy.CheckOutExtension("ImageAnalyst")
else:
    raise Exception("Licence Image Analyst není dostupná.")

# 1. Export trénovacích dat
print("1/4 Exportuji trénovací dlaždice...")
arcpy.ia.ExportTrainingDataForDeepLearning(
    in_raster=ortho_path,
    out_folder=training_folder,
    in_class_data=train_labels,
    image_chip_format="TIFF",
    tile_size_x=256,
    tile_size_y=256,
    metadata_format="RCNN_Masks", # Klíčové pro Mask R-CNN
    class_value_field="Classvalue" # Pole s kódem třídy
)

# 2. Trénování modelu Mask R-CNN s ResNet-50
print("2/4 Zahajuji trénování modelu...")
arcpy.ia.TrainDeepLearningModel(
    in_training_data=training_folder,
    out_model_location=model_output,
    max_epochs=30,
    model_type="MASK_RCNN",

arguments="backbone_model=resnet50;batch_size=4;validation_percentage=10",
    stop_training=True
)

# 3. Detekce (Inference)
print("3/4 Zahajuji detekci na ortofotu...")
model_dlpk = os.path.join(model_output, "FlowerModel.dlpk")

with arcpy.EnvManager(processorType="GPU"):
    arcpy.ia.DetectObjectsUsingDeepLearning(
        in_raster=ortho_path,
        out_feature_class=detected_flowers,
        in_model_definition=model_dlpk,
        arguments="padding=100;threshold=0.5",
        run_nms="NO_NMS"
    )

# 4. Výpočet přesnosti (Accuracy)
print("4/4 Vyhodnocuji přesnost detekce...")
arcpy.ia.ComputeAccuracyForObjectDetection(
    detected_features=detected_flowers,
    ground_truth_features=test_labels,
    out_accuracy_table=accuracy_table,
    detected_label="Kvet", # Název třídy ve výsledku
    ground_truth_label="Kvet", # Název třídy v testovacích datech
    min_iou=0.5 # Shoda plochy aspoň 50 %
)

print(f"Hotovo! Výsledná tabulka přesnosti je v: {accuracy_table}")
arcpy.CheckInExtension("ImageAnalyst")

```

## Závěr

Uvedený postup podrobně popisuje, jak je možné postupovat při detekcích chráněných druhů rostlin a uvádí příklad detekcí hlaváčku jarního. Důležitým prvním krokem pro úspěšné detekce květů jako aproximace počtu chráněných jedinců na sledované lokalitě je načasování pořízení dat a vhodný RGB senzor s parametry, které umožňují létat v dostatečné výšce, aby nedocházelo k pohybu vegetace vlivem proudění vzduchu od vrtulí dronu, a přitom dosáhnout prostorového rozlišení v řádu jednotek milimetrů. Neméně důležitá jsou poté trénovací data kvalitně zaznamenaná nad snímky či v terénu, a to v dostatečném množství na naučení hluboké neuronové sítě. Testováním byla vybrána jako nejvhodnější síť Mask R-CNN s architekturou ResNet-50 jako backbone. Veškeré zpracování i automatizace probíhá v software ArcGIS Pro s toolboxem Image Analyst. Dobře natrénovaný model pro konkrétní chráněný druh lze za podmínky dodržení srovnatelných podmínek při pořizování dat na jiné lokalitě se stejným druhem nebo pro sledování vývoje na stejné lokalitě v rámci let do určité míry použít, většinou je ale lepší alespoň na menší sadě trénovacích dat model i tak dotrénovat.

**Výsledek je volně dostupný zde:** [https://www.eo4inspection.cz/wp-content/uploads/2026/01/V\\_15.pdf](https://www.eo4inspection.cz/wp-content/uploads/2026/01/V_15.pdf)