

Diplomová práce

KLASIFIKACE UAV OBRAZOVÝCH DAT V RÁMCI VYBRANÝCH ÚZEMÍ

Autor: Bc. Jakub Ešpandr

Vedoucí: Ing. Jakub Jech Ph.D.

Datum obhajoby: 27. 8. 2025



CÍL PRÁCE

- Cílem práce je analyzovat a porovnat metody řízené a neřízené klasifikace pro zpracování reálných obrazových dat s velmi vysokým prostorovým rozlišením získaných pomocí UAV. Práce se zaměřuje na proces zahrnující od přípravy letu, sběr dat, až po jejich zpracování a interpretaci. Součástí práce bude praktické ověření vybraných metod na reálném datovém souboru pro potřeby vnitřní analýzy podniku.



ÚVOD DO PROBLEMATIKY

Teoretická část

- DPZ
 - spektrum, platformy, senzory
- Digitální zpracování obrazových dat
 - zvýraznění, klasifikace
- Současný stav ve směru práce
 - limity, identifikované mezery

Praktická část

- Zpracování a klasifikace dat
 - využití UAV a zájmová území
 - příprava dat
 - trénování a vyhodnocení
 - tvorba tematických snímků
- Případové studie



PŘÍPADOVÉ STUDIE

- **Vraclav:** klasifikace vegetace (indexy)
- **Albánie:** klasifikace spáleného porostu
- **Loučky:** klasifikace vegetace
- **Hrádek:** klasifikace vegetace (3 třídy)
- **Čestice:** klasifikace zaplavených ploch
- **Čestice II:** porovnání modelů
- **Trpík:** detekce jednotlivých stromů



POUŽITÁ UAV


OPEN A1/A3 & A2




* GSD při 50 m AGL

POUŽITÉ NÁSTROJE


- **ArcGIS PRO**
- **6 vlastních nástrojů (open source GitHub):**
 - GeoShrink (zmenšení velikosti ortofota)
 - FCC MS ImageProcessor (zpracování spektrálních indexů)
 - MetriCalc (výpočet klasifikačních metrik)
 - ImageMetaLocator (získání prostorových metadat snímků)
 - UAVAreaCalc (výpočet plochy snímku)
 - OrthophotoTool (extrakce metadat ortofota)



OrthophotoTool



ImageMetaLocator 6



UAVAreaCalc



LETOVÉ PLÁNOVÁNÍ A AKVIZICE DAT

- **PIX4Dcapture**
- **Single 2D Grid**
- H80% a V75% překryv
- Výška dle GSD a doby letu
- Kamera kolmo k zemi




PŘÍPRAVA DAT A SPEKTRÁLNÍ ZVÝRAZNĚNÍ

- Ortofotomozaika WebODM Lightning
- FCC MS Image Processor



ZÁKLADNÍ SNÍMEK VE VIDITELNÉM RGB SPEKTRU pole po povodni Čestice

Red: Band_1
Green: Band_2
Blue: Band_3




0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

SNÍMEK SE SPEKTRÁLNÍM ZVÝRAZNĚNÍM GBRWI pole po povodni Čestice

1 nezaplavená plocha
-1 zaplavená plocha





$$\text{GBRWI} = [(1,2 \times \text{Green}) + (0,8 \times \text{Blue}) - \text{Red}] / [(1,2 \times \text{Green}) + (0,8 \times \text{Blue}) + \text{Red} + 0,5]$$

0 100 200 m


Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

TRÉNOVÁNÍ A VYHODNOCENÍ



VYHODNOCENÍ PŘESNOSTI KLASIFIKACE

OBJECTID	ClassValue	C_1	C_2	Total	P_Accuracy	Kappa
-1	C_1	32,0000	32,0000	64,0000	0,5000	0,0000
-1	C_2	32,0000	504,0000	536,0000	0,9403	0,0000
-1	Total	64,0000	536,0000	600,0000	0,0000	0,0000
-1	P_Accuracy	0,5000	0,9403	0,0000	0,8933	0,0000
-1	Kappa	0,0000	0,0000	0,0000	0,0000	0,4403



The image shows a screenshot of the MetriCalc web application interface. The interface is titled "MetriCalc" and has a subtitle "Export metrics from confusion matrix". It features a language selector set to "English". There are two tabs: "Single Processing" (active) and "Batch Processing". The "Single Processing" tab contains three main steps: 1. "Select CSV File" with a blue button labeled "Select CSV File" and a text input field showing "File: none". 2. "Select Output Location" with a blue button labeled "Select Output Location" and a text input field showing "Save as: not selected". 3. "Start Processing" with a green button labeled "Start Processing".

VÝSTUP METRIK Z APLIKACE METRICALC

Metoda: DL - UNET ResNet50						
-- Vypočtené metriky --						
Třída	Precision (uživ.)	Recall (producent.)	F1-skóre	Celková přesnost	Kappa index	
C_1	1,000000000	0,938	0,968			
C_2	0,993	1	0,996			
Průměr	0,996	0,969	0,982	0,993	0,964	
-- Originální výstup z ArcGIS PRO --						
OBJECTID	ClassValue	C_1	C_2	Total	U_Accuracy	Kappa
-1	C_1	60	4	44	0,93750000	
-1	C_2	0	536	536	1,00000000	
-1	Total	60	540	600	0,00000000	
-1	P_Accuracy	1,00000000	0,99259259	0,00000000	0,99333333	
-1	Kappa	0	0	0	0	0,9640287

- **F1-skóre**
- **Kappa**
- **Celková přesnost**
- Uživatelova přesnost, Producentova přesnost

KLASIFIKACE VEGETACE – VRACLAV

porovnání
8 indexů:
řepka,
plevel


F1-skóre klasifikace											
		spektrální zvýraznění									
metoda	zkratka	RGB	TGI	GCC	NGDRI	RGBVI	VARI	EXGI	GLI	MGLI2	průměr
Deep Learning	DL	0,97044	-	-	-	-	-	-	-	-	0,97044
Support Vector Machine	SVM	0,94264	0,89491	0,96794	0,82792	1,00000	1,00000	0,91092	0,82792	1,00000	0,93025
Maximum Likelihood	ML	1,00000	0,87619	0,82421	0,68357	0,87619	0,90341	0,90341	0,94235	0,86563	0,87499
Random Trees	RT	0,86044	0,75294	0,83830	1,00000	0,86508	0,87561	0,83830	0,75294	0,93780	0,85794
K-Nearest Neighbors	KNN	0,80566	0,56250	0,79675	0,77258	0,63617	0,72875	0,83756	0,77258	0,83553	0,74979
ISO cluster	ISO	0,66529	0,93225	0,87500	0,89369	0,62798	0,79675	0,90253	0,83756	0,82282	0,81710
	průměr	0,87408	0,80376	0,86044	0,83555	0,80108	0,86090	0,87854	0,82667	0,89236	0,84872

Kappa koeficient klasifikace											
		spektrální zvýraznění									
metoda	zkratka	RGB	TGI	GCC	NGDRI	RGBVI	VARI	EXGI	GLI	MGLI2	průměr
Deep Learning	DL	0,94090	-	-	-	-	-	-	-	-	0,94090
Support Vector Machine	SVM	0,88550	0,79110	0,93590	0,65660	1,00000	1,00000	0,82190	0,65660	1,00000	0,86084
Maximum Likelihood	ML	1,00000	0,75240	0,65050	0,37100	0,75240	0,80690	0,80690	0,88500	0,73200	0,75079
Random Trees	RT	0,72220	0,50890	0,67680	1,00000	0,73090	0,75120	0,67680	0,50890	0,87560	0,71681
K-Nearest Neighbors	KNN	0,61310	0,14430	0,60320	0,55240	0,28570	0,46040	0,67700	0,55920	0,67110	0,50738
ISO cluster	ISO	0,33820	0,86490	0,75000	0,78870	0,26470	0,59460	0,80520	0,67530	0,64790	0,63661
	průměr	0,74998	0,61232	0,72328	0,67374	0,60674	0,72262	0,75756	0,65700	0,78532	0,69984



KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster
poškozená úroda řepky olejky Vraclav - RGB data


■ zasažená řepka
■ plevel



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - K-Nearest Neighbor
poškozená úroda řepky olejky Vraclav - RGB data



■ plevel
■ zasažená řepka



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Maximum Likelihood
poškozená úroda řepky olejky Vraclav - RGB data


■ plevel
■ zasažená řepka



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Random Trees
poškozená úroda řepky olejky Vraclav - RGB data



■ plevel
■ zasažená řepka



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Support Vector Machine
poškozená úroda řepky olejky Vraclav - RGB data



■ plevel
■ zasažená řepka



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Deep Learning
poškozená úroda řepky olejky Vraclav - RGB data


■ plevel
■ zasažená řepka



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

VÝSEČ ZÁJMOVÉHO ÚZEMÍ
poškozená úroda řepky olejky Vraclav

□ zájmové území





Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633



VÝSEČ ZÁJMOVÉHO ÚZEMÍ
poškozená úroda řepky olejky Vraclav



□ zájmové území



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Random Trees
poškozená úroda řepky olejky Vraclav - RGB data



plevel
zasažená řepka



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Random Trees
poškozená úroda řepky olejky Vraclav - MGLI2 zvýraznění

plevel
zasažená řepka



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633


F1: 0,86; OA: 0,868; Kappa: 0,722

8,3 % ↑

F1: 0,938; OA: 0,88; Kappa: 0,876

VÝSEČ ZÁJMOVÉHO ÚZEMÍ poškozená úroda řepky olejky Vraclav

□ zájmové území




0 15 30 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster poškozená úroda řepky olejky Vraclav - RGB data

■ zasažená řepka
■ plevel




0 15 30 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster poškozená úroda řepky olejky Vraclav - MGLI2 zvýraznění

■ zasažená řepka
■ plevel



0 15 30 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 | GSD: 1.4 cm/px | CRS: EPSG:32633

F1: 0,665; OA: 0,768; Kappa: 0,338

19 % ↑

F1: 0,823; OA: 0,9; Kappa: 0,648

KLASIFIKACE SPÁLENÉHO POROSTU – ALBÁNIE


požárem
spálená
vegetace

F1-skóre klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	SNDGR	průměr
Deep Learning	DL	0,98798	0,94518	0,96658
Support Vector Machine	SVM	0,94103	0,91223	0,92663
Maximum Likelihood	ML	0,96462	0,89133	0,92797
Random Trees	RT	0,93048	0,84668	0,88858
K-Nearest Neighbors	KNN	0,88312	0,70129	0,79221
ISO cluster	ISO	0,70479	0,91530	0,81004
	průměr	0,90200	0,86867	0,88534

Kappa koeficient klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	SNDGR	průměr
Deep Learning	DL	0,97596	0,89000	0,93298
Support Vector Machine	SVM	0,88219	0,82500	0,85359
Maximum Likelihood	ML	0,79978	0,68800	0,74389
Random Trees	RT	0,92931	0,69500	0,81216
K-Nearest Neighbors	KNN	0,76668	0,41400	0,59034
ISO cluster	ISO	0,40965	0,83100	0,62033
	průměr	0,79393	0,72383	0,75888




VÝSEČ ZÁJMOVÉHO ÚZEMÍ
spálený porost Albánie



0 25 50 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32634

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Deep Learning
spálený porost Albánie - RGB data




zdravá vegetace
spálená vegetace

0 25 50 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32634

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Deep Learning
spálený porost Albánie - SNDGR zvýraznění



zdravá vegetace
spálená vegetace

0 25 50 m


Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32634

F1: 0,988; OA: 0,99; Kappa: 0,976


4,5 % ↓

F1: 0,945; OA: 0,96; Kappa: 0,89


VÝSEČ ZÁJMOVÉHO ÚZEMÍ
spálený porost Albánie



KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster
spálený porost Albánie - RGB data



KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster
spálený porost Albánie - SNDGR zvýraznění



F1: 0,705; OA: 0,77; Kappa: 0,41

23 %



F1: 0,915; OA: 0,94; Kappa: 0,831

KLASIFIKACE POŠKOZENÍ OBILNIN – LOUČKY

obilniny
poškozené
bouřkou

F1-skóre klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	TGI	průměr
Deep Learning	DL	0,95900	0,92900	0,94400
Support Vector Machine	SVM	0,69000	0,64900	0,66950
Maximum Likelihood	ML	0,80000	0,70300	0,75150
Random Trees	RT	0,84900	0,70900	0,77900
K-Nearest Neighbors	KNN	0,87000	0,52800	0,69900
ISO cluster	ISO	0,62700	0,41100	0,51900
	průměr	0,79917	0,65483	0,72700

Kappa koeficient klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	TGI	průměr
Deep Learning	DL	0,91800	0,86000	0,88900
Support Vector Machine	SVM	0,38000	0,53600	0,45800
Maximum Likelihood	ML	0,60300	0,42400	0,51350
Random Trees	RT	0,69900	0,42400	0,56150
K-Nearest Neighbors	KNN	0,74000	0,05500	0,39750
ISO cluster	ISO	0,26700	-0,13700	0,06500
	průměr	0,60117	0,36033	0,48075



VÝSEČ ZÁJMOVÉHO ÚZEMÍ
poškozená úroda obilí Loučky

☐ zájmové území



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Deep Learning
poškozená úroda obilí Loučky - RGB data


nezasazená úroda
zasazená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Deep Learning
poškozená úroda obilí Loučky - TGI zvýraznění

nezasazená úroda
zasazená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

F1: 0,959; OA: 0,96; Kappa: 0,918

3,2 % ↓

F1: 0,929; OA: 0,93; Kappa: 0,86

VÝSEČ ZÁJMOVÉHO ÚZEMÍ
poškozená úroda obilí Loučky

☐ zájmové území



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - K-Nearest Neighbor
poškozená úroda obilí Loučky - RGB data


nezasazená úroda
zasazená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - K-Nearest Neighbor
poškozená úroda obilí Loučky - TGI zvýraznění

nezasazená úroda
zasazená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

F1: 0,87; OA: 0,87; Kappa: 0,74

40 % ↓

F1: 0,528; OA: 0,53; Kappa: 0,055

VÝSEČ ZÁJMOVÉHO ÚZEMÍ poškozená úroda obilí Loučky

☐ zájmové území



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster poškozená úroda obilí Loučky - RGB data


nezasazená úroda
zasažená úroda



0 50 100 m
Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster poškozená úroda obilí Loučky - TGI zvýraznění

nezasazená úroda
zasažená úroda



0 50 100 m
Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

F1: 0,627; OA: 0,65; Kappa: 0,267

34 % ↓

F1: 0,411; OA: 0,53; Kappa: **-0,137**


KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster
poškozená úroda obilí Loučky - RGB data

nezasažená úroda
zasažená úroda

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster
poškozená úroda obilí Loučky - TGI zvýraznění

nezasažená úroda
zasažená úroda

Porovnání spektrálních indexů napříč
klasifikačními metodami (Kappa index)



0 50 100 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

0 50 100 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.04 cm/px | CRS: EPSG:32633

F1: 0,627; OA: 0,65; Kappa: 0,267

34 % ↓

F1: 0,411; OA: 0,53; Kappa: **-0,137**

KLASIFIKACE VEGETAČNÍCH SLOŽEK – HRÁDEK

vegetace:
zdravá
poškozená
plevel


F1-skóre klasifikace		
metoda	zkratka	RGB
Deep Learning - UNET	DL	0,94412
Support Vector Machine	SVM	0,79252
Maximum Likelihood	ML	0,79015
Random Trees	RT	0,76110
K-Nearest Neighbors	KNN	0,75824
ISO cluster	ISO	0,42901
	<i>průměr</i>	0,74586

Kappa koeficient klasifikace		
metoda	zkratka	RGB
Deep Learning - UNET	DL	0,89000
Support Vector Machine	SVM	0,56000
Maximum Likelihood	ML	0,64800
Random Trees	RT	0,50500
K-Nearest Neighbors	KNN	0,51400
ISO cluster	ISO	0,24400
	<i>průměr</i>	0,56017



KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster poškozená úroda obilí Hrádek


nezasažená úroda
zasažená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.53 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - K-Nearest Neighbor poškozená úroda obilí Hrádek



plevel
nezasažená úroda
zasažená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.53 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Maximum Likelihood poškozená úroda obilí Hrádek

plevel
nezasažená úroda
zasažená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.53 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Random Trees poškozená úroda obilí Hrádek


plevel
nezasažená úroda
zasažená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.53 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Support Vector Machine poškozená úroda obilí Hrádek

plevel
nezasažená úroda
zasažená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.53 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Deep Learning poškozená úroda obilí Hrádek

plevel
nezasažená úroda
zasažená úroda



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.53 cm/px | CRS: EPSG:32633

VÝSEČ ZÁJMOVÉHO ÚZEMÍ poškozená úroda obilí Hrádek

zájmové území



Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.53 cm/px | CRS: EPSG:32633

ØF1: 0,746
ØOA: 0,855
ØKappa: 0,56

KLASIFIKACE ZAPLAVENÉ PLOCHY – ČESTICE

zaplavené
plochy

F1-skóre klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	GBRWI	průměr
Deep Learning	DL	0,92900	0,80700	0,86800
Support Vector Machine	SVM	0,89630	0,90250	0,89940
Maximum Likelihood	ML	0,80740	0,81360	0,81050
Random Trees	RT	0,80810	0,78490	0,79650
K-Nearest Neighbors	KNN	0,73780	0,67270	0,70525
ISO cluster	ISO	0,74590	0,79240	0,76915
	průměr	0,82075	0,79552	0,80813

Kappa koeficient klasifikace				
		spektrální zvýraznění		
metoda	zkratka	RGB	GBRWI	průměr
Deep Learning	DL	0,85900	0,61700	0,73800
Support Vector Machine	SVM	0,79339	0,80519	0,79929
Maximum Likelihood	ML	0,61944	0,63152	0,62548
Random Trees	RT	0,63425	0,57483	0,60454
K-Nearest Neighbors	KNN	0,48037	0,37472	0,42755
ISO cluster	ISO	0,49438	0,58609	0,54024
	průměr	0,64680	0,59823	0,62252



KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Support Vector Machine pole po povodni Čestice - RGB data



KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - Support Vector Machine pole po povodni Čestice - GBRWI zvýraznění

VÝSEČ ZÁJMOVÉHO ÚZEMÍ pole po povodni Čestice

□ zájmové území

■ zaplavená plocha
■ nezaplavená plocha

■ zaplavená plocha
■ nezaplavená plocha



0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

F1: 0,896; OA: 0,93; Kappa: 0,793

1% ↑

F1: 0,903; OA: 0,94; Kappa: 0,805

VÝSEČ ZÁJMOVÉHO ÚZEMÍ pole po povodni Čestice

□ zájmové území




0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster pole po povodni Čestice - RGB data

■ zaplavená plocha
■ nezaplavená plocha




0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

KLASIFIKACE ZÁJMOVÉHO ÚZEMÍ - ISO Cluster pole po povodni Čestice - GBRWI zvýraznění

■ zaplavená plocha
■ nezaplavená plocha



0 100 200 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.8 cm/px | CRS: EPSG:32633

F1: 0,746; OA: 0,82; Kappa: 0,494

5,8 % ↑

F1: 0,792; OA: 0,90; Kappa: 0,586

POROVNÁNÍ KLASIFIKAČNÍCH MODELŮ – ČESTICE

F1-skóre klasifikace


metoda	zkratka	RGB
Deep Learning - U-NET	DL - U-NET - ResNet50	0,98200
Deep Learning - U-NET	DL - U-NET - VGG16	0,87400
Deep Learning - PSPNet	DL - PSPNet	0,88700
Deep Learning - PSPNet - PointRend	DL - PSPNet - P.R.	0,98300
Deep Learning - DeepLabV3	DL - DeepLabV3	0,91600
Deep Learning - DeepLabV3 - PointRend	DL - DeepLabV3 - P.R.	0,96500
Support Vector Machine	SVM	0,86100
Maximum Likelihood	ML	0,81100
Random Trees	RT	0,84100
Random Trees - depth 100	RT - depth 100	0,75200
K-Nearest Neighbors	KNN	0,63400
ISO cluster	ISO	0,72000
	<i>průměr</i>	0,85217

Kappa koeficient klasifikace












metoda	zkratka	RGB
Deep Learning - U-NET	DL - U-NET - ResNet50	0,96400
Deep Learning - U-NET	DL - U-NET - VGG16	0,74900
Deep Learning - PSPNet	DL - PSPNet	0,77300
Deep Learning - PSPNet - PointRend	DL - PSPNet - P.R.	0,96600
Deep Learning - DeepLabV3	DL - DeepLabV3	0,83200
Deep Learning - DeepLabV3 - PointRend	DL - DeepLabV3 - P.R.	0,93000
Support Vector Machine	SVM	0,72300
Maximum Likelihood	ML	0,62700
Random Trees	RT	0,68400
Random Trees - depth 100	RT - depth 100	0,50700
K-Nearest Neighbors	KNN	0,27500
ISO cluster	ISO	0,44000
	<i>průměr</i>	0,70583




porovnání modelů:
zaplavené plochy



$\emptyset F1$: 0,852
 $\emptyset OA$: 0,93
 $\emptyset Kappa$: 0,706



DETEKCE OBJEKTŮ – SAD TRPÍK




VYPOČÍTANÉ METRIKY	
Uživatelská přesnost klasifikace (Precision)	0,933
Producentova přesnost klasifikace (Recall)	1
F1-skóre klasifikace	0,966
Kappa index	NaN (pouze 1 třída)
Celková přesnost klasifikace (Overall Accuracy)	0,933
DODATEČNÉ POČTY	
True Positives (TP)	687
False Positives (FP)	49
False Negatives (FN)	0
Total Ground Truth Labels	687



detekce objektů:
inventarizace sadu

VYMEZENÉ ZÁJMOVÉ ÚZEMÍ sad Trpík

□ zájmové území




0 50 100 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.11 cm/px | CRS: EPSG:32633

KLASIFIKACE STROMŮ - Object Detection Deep Learning sad Trpík

• ground truth
■ detekované stromy
□ zájmové území



0 50 100 m

Bc. Jakub EŠPANDR, Taipei 2025
DJI Phantom 4 Pro | GSD: 1.11 cm/px | CRS: EPSG:32633

F1: 0,966; OA: 0,933; Uživatelská přesnost: 0,933; Producentova přesnost: 1

ZHODNOCENÍ

- DL a SVM nejvyšší přesnost
- Spektrální indexy přinesly zlepšení
 - MGLI2 – Vraclav 0,943 / 0,86 → **1 / 0,938** (SVM / RT)
 - SNDGR – Albánie 0,705 → **0,915** (ISO)
 - GBRWI – Čestice 0,746 → **0,792** (ISO)
- Problematické přechodové zóny, spektrální šum a nedostatečná barevná separace tříd
- RGB (zvýraznění) → základ i pro složitější jevy
- DL ačkoliv často nejlepší, výpočetní náročnost

DĚKUJI ZA VAŠI POZORNOST



OTÁZKY OD VEDOUcíHO PRÁCE

- Jaké jsou limity využívání RGB dat při klasifikaci vegetačních typů a jak by se výsledky mohly změnit při použití multispektrálních nebo hyperspektrálních senzorů (kdyby nebylo zadání práce omezeno na RGB data)?
 - absence red-edge a NIR/SWIR → slabá citlivost na chlorofyl/vodu
 - RE+NIR → lepší separace vegetace, vody, stresu rostlin
 - SWIR → výrazně lepší separace spáleniště nebo vlhkých ploch
 - hyperspektrál → druhová diferenciacce vegetace
 - nárůst OA/F1/Kappa - lepší separace v přechodových zónách a menší záměně tříd
- nutná radiometrická kalibrace a nižší GSD (komerční kamery)

OTÁZKY OD OPONENTA

1) Jakými pravidly jste se řídil při definování trénovacích ploch pro řízenou klasifikaci obrazu?

2) Jak by se daly navržené softwarové nástroje integrovat do jednotné platformy pro uživatele bez technického zázemí?

1) definované schéma; vizuálně homogenní oblasti (zachycení všech vzorků)

- vyhýbání křížení tříd, stínům; stejné množiny pro strojové učení i DL

2) aktuálně nástroje s jednoduchým GUI prostředím; Python + popis spuštění na GitHub

- možnost sloučení do jedné app s nápovědou a interaktivním UI
- případně desktop app (PyInstaller + Inno Setup) nebo webapp (lokální / serverová):
 - **frontend:** React; **API:** FastAPI + **fronta úloh** Redis; **uložiště:** lokální disk serveru nebo **frontend:** React + Leaflet; **backend:** Node.js; **Python workers:** Docker

PROSTOR PRO DOTAZY

