

Univerzita Pardubice
Fakulta ekonomicko-správní

Pokročilé přístupy v analýze VHSR dat

Pojednání o tématu disertační práce

Jméno:

Bc. Jakub Ešpandr

Školitel:

prof. Ing. Jitka Komárková, Ph.D.

OBSAH

ÚVOD.....	3
1 ZÁKLADY DÁLKOVÉHO PRŮZKUMU ZEMĚ.....	4
1.1 Klíčové části elektromagnetického spektra v DPZ.....	4
1.2 Platformy pro sběr dat v DPZ.....	5
1.2.1 Kosmické platformy (družice).....	5
1.2.2 Letecké platformy.....	5
1.2.3 Pozemní a mobilní platformy.....	6
1.3 Druhy senzorů a jejich datové výstupy.....	6
1.3.1 Pasivní senzory.....	6
1.3.2 Aktivní senzory.....	6
2 DIGITÁLNÍ ZPRACOVÁNÍ OBRAZOVÝCH DAT.....	7
2.1 Předzpracování (Pre-processing).....	7
2.2 Zvýraznění obrazu (Image Enhancement).....	7
2.3 Klasifikace (Extrakce informací).....	8
2.4 Postklasifikační úpravy a hodnocení přesnosti.....	8
3 SOUČASNÝ STAV VE SMĚRU PRÁCE.....	8
3.1 Potenciál a limity nízkonákladových RGB senzorů.....	9
3.2 Posun v metodách klasifikace směrem k hlubokému učení.....	9
3.3 Ensemble Learning jako současný trend ve výzkumu.....	10
3.4 Identifikovaná mezera ve výzkumu.....	11
4 HLAVNÍ CÍL VÝZKUMU.....	11
4.1 Překonání limitací standardních přístupů.....	12
4.2 Systematický průzkum fúze datových reprezentací.....	12
4.3 Návrh a validace flexibilního metodického rámce.....	12
4.4 Cílené zlepšení klíčových parametrů klasifikace.....	13
5 VÝZKUMNÉ OTÁZKY.....	13
5.1 Hlavní výzkumná otázka (VO).....	14
5.2 Dílčí výzkumné otázky (DVO).....	14
6 NÁVRH METODOLOGIE.....	14
POUŽITÁ LITERATURA.....	16

ÚVOD

Dálkový průzkum Země prošel v posledních letech velikou změnou díky bezpilotním letounům (UAV). Tyto platformy přinesly bezprecedentní dostupnost obrazových dat s velmi vysokým prostorovým rozlišením (VHSR), která dosahují detailu v řádu jednotek centimetrů na pixel. Tato schopnost otevřela nové možnosti pro detailní analýzy v klíčových oblastech, jako je například precizní zemědělství pro včasnou detekci stresu plodin a environmentální monitoring pro rychlé a přesné mapování dopadů přírodních jevů.

Navzdory těmto pokrokům naráží klasifikace VHSR dat na řadu limitů. Standardní přístupy založené na jediném datovém zdroji, typicky RGB, trpí spektrální víceznačností, zatímco pokročilé modely hlubokého učení (Deep Learning) se potýkají s problémem přenositelnosti (Domain shift). Současný výzkum proto směřuje k ensemble learningu, který kombinuje více modelů pro dosažení vyšší spolehlivosti. Systematicky však dosud nebyla prozkoumána kombinovaná fúze klasifikací z různých barevných prostorů (RGB, CIELab, HSV) a současně fúze klasifikátorů. Právě tato dvojúrovňová strategie představuje hlavní výzkumnou mezeru, na kterou práce reaguje.

Hlavním cílem zamýšlené disertační práce je navrhnout, implementovat a komplexně ověřit metodický rámec pro ensemble klasifikaci VHSR dat, založený na syntéze informací z různých datových reprezentací a klasifikačních modelů. Tento přístup bude zkoumat varianty využívající jak stejnou klasifikační metodu v různých barevných prostorech (např. SVM v RGB a CIELab), tak kombinace odlišných metod a datových zdrojů (např. SVM v RGB, ML v HSV, integrace multispektrálních pásem).

Konečným cílem je dosáhnout výsledků, které budou prokazatelně přesnější, robustnější a spolehlivější než u běžně používaných, samostatně aplikovaných postupů přínosných pro teorii a praxi.

1 ZÁKLADY DÁLKOVÉHO PRŮZKUMU ZEMĚ

Dálkový průzkum Země (DPZ) je obor, který se zabývá bezkontaktním získáváním informací o zemském povrchu prostřednictvím analýzy odraženého či emitovaného elektromagnetického (EM) záření, jehož primárním zdrojem je Slunce (Lillesand et al., 2015). Celý proces zahrnuje sběr dat (akvizici) pomocí senzorů na kosmických, leteckých či UAV platformách a následné zpracování, které data převádí na smysluplné informace pro praxi (Kolář, 1990; Lillesand et al., 2015).

Senzory mohou být pasivní, zaznamenávající přirozené záření, nebo aktivní (např. radar, LiDAR), které si scénu osvětlují vlastním signálem, a jsou tak nezávislé na denní době a počasí. Klíčem k DPZ je využití tzv. atmosférických oken – specifických částí EM spektra, které atmosféra neabsorbuje, a umožňuje tak měření (Longley et al., 2015).

1.1 Klíčové části elektromagnetického spektra v DPZ

Viditelné spektrum (VIS, $\sim 0,4\text{--}0,7\ \mu\text{m}$) umožňuje tvorbu intuitivně srozumitelných, pravobarevných snímků. Barevnost objektů je dána poměrem odražené a pohlcené energie. Zdravá vegetace například pohlcuje modré a červené světlo, zatímco zelené odráží, a proto se jeví zeleně (Lillesand et al., 2015).

Blízké infračervené pásmo (NIR, $\sim 0,7\text{--}1,3\ \mu\text{m}$) má zásadní význam pro analýzu vegetace. Zdravá rostlinná biomasa v tomto pásmu silně odráží energii, přičemž míra odrazivosti přímo souvisí s její vitalitou a zdravotním stavem. Voda naopak NIR pohlcuje, a jeví se proto tmavě. Kombinací s viditelnými pásmy vznikají tzv. nepravobarevné kompozity, které zdravou vegetaci výrazně zvýrazňují (Lillesand et al., 2015; Dobrovolný, 1998).

Termální infračervené pásmo (TIR, $\sim 8\text{--}14\ \mu\text{m}$) nezaznamenává odražené sluneční světlo, ale tepelnou energii vyzařovanou samotným povrchem, což umožňuje měření teploty ve dne i v noci. Využívá se ke sledování městských tepelných ostrovů, detekci požárů nebo k identifikaci vodního stresu u zemědělských plodin (Lillesand et al., 2015).

Mikrovlnné pásmo ($\sim 1\ \text{mm}\text{--}1\ \text{m}$) využívají aktivní systémy RADAR, které díky vlastnímu signálu pronikají oblačností a deštěm (Sabins, 2007). Intenzita zpětného odrazu (backscatter) závisí na drsnosti povrchu a obsahu vody (dielektrických vlastnostech), což je ideální pro mapování záplav, sledování vlhkosti půdy a tvorbu přesných digitálních modelů terénu (InSAR) (Lillesand et al., 2015).

Konečným smyslem DPZ je poskytovat přesná a aktuální prostorová data, která slouží jako podklad pro rozhodování v široké škále oborů od zemědělství a lesnictví až po hydrologii a krizové řízení (Kolář, 1990; Lillesand et al., 2015).

1.2 Platformy pro sběr dat v DPZ

Volba platformy, která nese senzor, zásadně určuje vlastnosti výsledných dat, zejména jejich prostorové rozlišení, plošné pokrytí a frekvenci snímání. Platformy se dělí na tři základní kategorie: kosmické, letecké a pozemní (Lillesand et al., 2015).

1.2.1 Kosmické platformy (družice)

Družice jsou páteří globálního a dlouhodobého monitoringu Země, klíčového pro sledování jevů jako klimatické změny (Lillesand et al., 2015; Kolář, 1990).

Nízké polární dráhy (LEO): Družice jako Landsat či Sentinel zde pořizují data s vysokým prostorovým rozlišením. Většinou se pohybují po tzv. slunečně-synchronní dráze, která zaručuje konzistentní osvětlení a umožňuje tak spolehlivé porovnávání snímků v čase (Lillesand et al., 2015).

Geostacionární dráhy (GEO): Z jedné pozice vysoko nad rovníkem družice (např. Meteosat) nepřetržitě sledují obrovskou část Země. Mají tak extrémně vysoké časové rozlišení, které je nepostradatelné pro meteorologii, avšak za cenu nižšího prostorového detailu (Lillesand et al., 2015).

Komerční systémy (např. WorldView) doplňují státní programy a nabízejí data s velmi vysokým rozlišením na vyžádání (Longley et al., 2015).

1.2.2 Letecké platformy

Tyto systémy vyplňují mezeru mezi globálním družicovým pokrytím a lokálním měřením.

Pilotovaná letadla jsou flexibilní pro detailní regionální mapování (např. tvorba ortofotomap) a mohou nést těžké senzory (LiDAR), jejich provoz je ale nákladnější a závislý na počasí (Lillesand et al., 2015).

Bezpilotní systémy (drony) představují revoluci v DPZ díky nízkým nákladům, operativnosti a schopnosti pořídít data s extrémně vysokým (centimetrovým) rozlišením. Jsou ideální pro lokální projekty a jejich data jsou typicky zpracovávána fotogrammetrickou metodou SfM (Structure from Motion) (Boon et al., 2017; Lillesand et al., 2015; Chiabrando, 2015).

1.2.3 Pozemní a mobilní platformy

Pozemní systémy slouží ke dvěma hlavním účelům: k referenčním měřením pro kalibraci a validaci dat z letadel či družic a k extrémně detailnímu 3D skenování jednotlivých objektů a infrastruktury (TLS, MMS) (Lillesand et al., 2015).

1.3 Druhy senzorů a jejich datové výstupy

Senzor v DPZ je zařízení, které bezkontaktně detekuje elektromagnetickou energii. Dle zdroje této energie je dělíme na dvě základní skupiny: pasivní, které zaznamenávají přirozené sluneční či tepelné záření, a aktivní, které si scénu osvětlují vlastním signálem a jsou tak nezávislé na denní době a často i na počasí (Lillesand et al., 2015; Kolář, 1990).

1.3.1 Pasivní senzory

Tyto senzory jsou (s výjimkou termálních) závislé na denním světle a bezoblačné obloze. Liší se především svými spektrálními schopnostmi.

RGB kamery zaznamenávají viditelné světlo (červenou, zelenou, modrou) a poskytují intuitivní obraz. Jsou základem pro tvorbu ortofotomap a 3D modelů povrchu (Boon et al., 2017).

Multispektrální senzory snímají v několika (typicky 3–15) oddělených pásmech, včetně neviditelného blízkého infračerveného (NIR). To umožňuje kvantitativní analýzu vegetace pomocí vegetačních indexů (např. NDVI) pro hodnocení její vitality a biomasy. Jsou standardem na družicích jako Landsat nebo Sentinel-2 (Lillesand et al., 2015).

Hyperspektrální skenery představují technologickou špičku, jelikož zaznamenávají stovky sousledných pásem. Pro každý pixel tak vytvářejí kompletní spektrální podpis, který umožňuje přímou identifikaci různých materiálů, druhů rostlin či minerálů (Lillesand et al., 2015; Longley et al., 2015).

Termální kamery měří tepelnou energii vyzařovanou povrchem, nikoli odražené světlo. Fungují ve dne i v noci a využívají se k detekci tepelných ztrát, požárů či vodního stresu rostlin (Lillesand et al., 2015).

1.3.2 Aktivní senzory

Tyto systémy si nesou vlastní zdroj energie, což jim dává unikátní vlastnosti.

LiDAR (Light Detection and Ranging) vysílá laserové pulzy a z doby jejich návratu počítá přesnou vzdálenost, čímž vytváří husté 3D mračno bodů. Jeho klíčovou výhodou je, že proniká

vegetací a umožňuje tak mapovat nejen povrch (DSM), ale i skutečný terén pod ním (DMT) (Lillesand et al., 2015).

Radar (Radio Detection and Ranging) využívá mikrovlny, které pronikají oblačností, deštěm i mlhou. Měří zpětný odraz (backscatter), který je citlivý na drsnost povrchu a obsah vody. Je proto ideální pro mapování záplav a vlhkosti půdy. Moderní techniky jako SAR a InSAR navíc umožňují dosáhnout vysokého rozlišení a měřit drobné posuny povrchu (Lillesand et al., 2015).

Sonar (Sound Navigation and Ranging) je akustickou obdobou radaru pro mapování podvodního prostředí. Využívá zvukové pulzy pro tvorbu detailních map mořského či říčního dna (batymetrie) (Lurton et al., 2015).

2 DIGITÁLNÍ ZPRACOVÁNÍ OBRAZOVÝCH DAT

Digitální zpracování obrazu je proces, který transformuje nezpracovaná, chybami zatížená data ze senzorů na smysluplné a přesné geoprostorové informace. Cílem je systematicky odstranit zkreslení a extrahovat z dat relevantní tematickou informaci (Lillesand et al., 2015; Gonzalez a Woods, 2018).

2.1 Předzpracování (Pre-processing)

Je základní fáze opravy dat. Zahrnuje georeferencování (přiřazení snímků do souřadnicového systému pomocí palubního GNSS nebo pozemních vlíčovacích bodů), radiometrické korekce (odstranění vlivu atmosféry ze senzoru pro získání reálné odrazivosti povrchu) a geometrické korekce (ortorektifikace pro odstranění prostorového zkreslení a vytvoření přesného ortofotosnímku) (Lillesand et al., 2015; Kolář, 1990).

2.2 Zvýraznění obrazu (Image Enhancement)

Zvýraznění obrazu je sada technik pro zlepšení vizuální kvality snímků a usnadnění jejich lidské interpretace. Na rozdíl od předzpracování se zaměřuje na subjektivní dojem. Tento proces se dělí do tří hlavních kategorií operací (Lillesand et al., 2015; Gonzalez a Woods, 2018):

Bodové (radiometrické) upravuje kontrast a jas snímku změnou hodnot jednotlivých pixelů, typicky pomocí úpravy histogramu.

Prostorové využívá filtry pro úpravu pixelu na základě jeho okolí, čímž dochází k zostření hran nebo naopak k vyhlazení a potlačení šumu.

Spektrální kombinuje více spektrálních pásem, například výpočtem vegetačních indexů (NDVI) nebo pomocí analýzy hlavních komponent (PCA) pro redukci dat.

2.3 Klasifikace (Extrakce informací)

Klasifikace je klíčovým procesem, při němž jsou pixely automaticky přiřazovány do tematických tříd (např. les, voda, zástavba), čímž vzniká tematická mapa.

Neřízená klasifikace: Algoritmus nejprve automaticky najde v datech přirozené shluky podobných pixelů (spektrální třídy). Analytik jim až následně v kroku zvaném reklasifikace přiřadí reálný tematický význam (Lillesand et al., 2015).

Řízená klasifikace: Analytik nejprve „trénuje“ algoritmus na reprezentativních vzorových plochách pro každou třídu. Algoritmus se naučí jejich spektrální vlastnosti a následně klasifikuje zbytek obrazu. Využívají se jak klasické statistické metody (Maximum Likelihood), tak moderní strojové učení (Random Forest, SVM) a především hluboké učení (CNN) (Lillesand et al., 2015; Goodfellow et al., 2016).

2.4 Postklasifikační úpravy a hodnocení přesnosti

Po klasifikaci následují finální kroky. Nejprve se provádí postklasifikační úpravy, jako je odstranění šumu a drobných chyb pomocí majoritních filtrů. Nepostradatelným závěrem je hodnocení přesnosti, které kvantifikuje spolehlivost mapy. Pomocí matice záměn (confusion matrix) se porovná výsledek s referenčními daty a vypočítají se metriky jako celková přesnost, Precision, Recall a koeficient Kappa (Lillesand et al., 2015; Longley et al., 2015).

3 SOUČASNÝ STAV VE SMĚRU PRÁCE

DPZ v posledních letech prochází dynamickým rozvojem, a to především díky dostupnosti UAV, které dokáží sbírat obrazová data s velmi vysokým prostorovým rozlišením v řádu jednotek centimetrů. Tyto platformy zaplnily kritickou mezeru mezi pozemním měřením a tradičními leteckými či družicovými daty. Například při monitoringu vodních ploch bylo dosaženo rozlišení 1,7 cm (Komárková & Jech, 2020; Sedlák et al., 2019, Sedlák et al. 2019b), při fenotypizaci pšenice dokonce 0,3–0,5 cm (Bhandari et al., 2021), a pro detekci drobných listových chorob se ukazuje jako nutné rozlišení v řádu milimetrů (Görlich et al., 2021).

Takto vysoká úroveň detailu umožňuje provádět analýzy na úrovni jednotlivých rostlin či jejich orgánů, což je zásadní pro aplikace v precizním zemědělství. Tyto aplikace reagují na globální výzvy, jakými jsou zajištění potravin pro rostoucí populaci (United Nations, 2017) a snižování

dopadů biotických i abiotických stresů, které mohou celosvětově redukovat výnosy o 20–40 % (Oerke, 2006).

3.1 Potenciál a limity nízkonákladových RGB senzorů

Ačkoliv jsou pro pokročilé agronomické a environmentální analýzy často využívány drahé multispektrální nebo hyperspektrální kamery, velké množství studií potvrzuje potenciál běžně dostupných nízkonákladových RGB senzorů. Díky své nízké pořizovací ceně a jednoduchosti použití jsou vhodné pro široké spektrum uživatelů. Klíčem k jejich efektivnímu nasazení je však pokročilé softwarové zpracování, které dokáže z pouhých tří spektrálních kanálů získat cenné informace.

Jednou z hlavních strategií je využití vegetačních indexů odvozených z RGB dat. I bez přítomnosti blízkého infračerveného (NIR) pásma lze z RGB snímků vypočítat řadu indexů, například Excess Green (ExG), Normalized Green Red Difference Index (NGRDI) či Visible Atmospherically Resistant Index (VARI). Tyto indexy citlivě reagují na změny v obsahu chlorofylu a umožňují odlišit vegetaci od půdy nebo vodní hladiny (Komárková et al., 2020; De Swaef et al., 2021). Studie potvrdily, že indexy NGRDI a VARI poskytují nejlepší výsledky pro separaci vegetace a vodní plochy (Komárková et al., 2020) a metodiky založené na ExG dosáhly při detekci stresu kukuřice přesnosti přes 89 % (Cvetković et al., 2023).

Dalším krokem je transformace dat do alternativních barevných prostorů, jako jsou HSV (Hue, Saturation, Value) nebo CIELab. Tento postup se ukázal jako účinný při potlačení vlivu proměnlivých světelných podmínek a při lepší vazbě na fyziologický stav rostlin. Například analýza a^* kanálu v prostoru CIELab významně zpřesnila odhad stresu ze sucha u rýže (Giamerti et al., 2024), zatímco index Hue z prostoru HSV se ukázal jako velmi spolehlivý prediktor indexu listové plochy (LAI) u pšenice (Rufo et al., 2021).

Přesto má analýza založená výhradně na RGB datech své limity. Typickým problémem je saturace signálu v hustých porostech, kdy vegetační indexy přestávají reagovat na další nárůst biomasy (Maimaitijiang et al., 2020; De Swaef et al., 2021). Jako efektivní řešení se ukazuje fúze dat, kdy jsou spektrální informace kombinovány s daty strukturními (např. výška porostu získaná z digitálního modelu povrchu). Tato kombinace výrazně zvyšuje přesnost odhadu biomasy i LAI (Maimaitijiang et al., 2020; Li, 2019).

3.2 Posun v metodách klasifikace směrem k hlubokému učení

Výzkum v oblasti klasifikace VHRS dat se po dlouhou dobu zaměřoval na porovnávání přesnosti jednotlivých klasifikačních metod. Řízené metody, jako jsou Support Vector Machine

(SVM), Random Forest (RF) a Maximum Likelihood (ML), systematicky vykazují vyšší přesnost než metody neřízené (Krátký & Komárková, 2023; Pádua et al., 2020). Například při mapování vodních ploch dosáhla metoda ML hodnoty Kappa až 0,9246, zatímco neřízený ISO Cluster poskytl pouze 0,4576 (Komárková & Jech, 2020). Existují však inovativní postupy, které kombinují neřízené metody s automatickou analýzou spektrálních trendů a dosahují tak přesnosti srovnatelné s řízenými přístupy (Boonrang et al., 2024). Přesto žádná z metod není univerzálně nejlepší a jejich výkon je silně závislý na charakteru dat. SVM například může selhávat v situacích s nízkým vizuálním kontrastem mezi třídami (Pádua et al., 2020).

Výrazný posun v přesnosti nastal až s nástupem hlubokého učení (Deep Learning, DL), zejména konvolučních neuronových sítí (CNN). Tyto sítě, na rozdíl od tradičních metod, dokáží automaticky extrahovat komplexní hierarchické příznaky od jednoduchých hran a textur až po složité tvary objektů. Jejich využití v klasifikaci VHRS dat však naráží na tři zásadní bariéry.

- Vysoká datová náročnost – efektivní trénink vyžaduje tisíce ručně anotovaných snímků (Kerdegari et al., 2019; Khan et al., 2021).
- Výpočetní náročnost – trénink je časově i hardwarově náročný a vyžaduje specializované GPU.
- Problém doménového posunu (Domain Shift) – model natrénovaný na datech z jedné lokality dramaticky ztrácí výkon, pokud je aplikován na snímky z jiné oblasti nebo v odlišných podmínkách (Görlich et al., 2021).

Navíc je třeba si uvědomit, že volba nejvhodnějšího postupu je úzce spjata s charakterem sledovaného jevu. Jiné přístupy jsou voleny pro detekci fyziologického stresu a jiné pro hodnocení makroskopických strukturních změn, jako je poléhání plodin, kde klíčovou roli hraje analýza textury a dat z výškového modelu (Yang et al., 2022), nebo pro hodnocení škod po požáru, kde jsou spektrální změny dramatické a skokové (Simes et al., 2024).

3.3 Ensemble Learning jako současný trend ve výzkumu

Jedním z hlavních trendů současného výzkumu je snaha překonat limity jednotlivých metod pomocí ensemble learningu. Tento přístup vychází z myšlenky, že kombinací více modelů lze vytvořit systém, který je celkově spolehlivější a přesnější než každý model samostatně. Tato snaha je podpořena i přetrvávající absencí jednotných a standardizovaných protokolů pro akvizici a zpracování dat, což ztěžuje porovnatelnost výsledků mezi studiemi a zvyšuje potřebu robustních metod, které jsou méně citlivé na variabilitu vstupních dat (Gano et al., 2024; Shu et al., 2022).

Nedávne studie ukazují vysokou efektivitu tohoto přístupu v DPZ. Hybridní modely, jako FusionNet-Remote, propojují silné stránky CNN (extrakce prostorových příznaků) a RF (robustní klasifikace), přičemž dosahují testovací přesnosti až 98,7 % (Alyahyan, 2025). Výrazného zlepšení lze dosáhnout také pomocí fúze dat z více kanálů, kdy každá dílčí CNN pracuje s jinou kombinací spektrálních pásem, a tím překonává výsledky jednotlivých sítí (Nanni & Brahnham, 2024). Inovativní rámce, jako DBECF, navíc ukazují, že diverzitu modelů lze generovat i v rámci jediného klasifikačního rámce, což vede nejen ke zvýšení přesnosti, ale i ke snížení výpočetní složitosti (Dou et al., 2024).

Dalším účinným přístupem je fúze na úrovni rozhodnutí, kdy jsou kombinovány výstupy více jednodušších klasifikátorů (např. Decision Tree, RF, SVM). Toho lze dosáhnout buď na základě jejich skóre spolehlivosti (confidence scores), čímž se dosahuje vysoké celkové přesnosti (K. et al., 2023), nebo návrhem hybridních metod, jako je přístup CMCA (Conventional Multi Classifier Approach). Tato metoda využívá spojení výstupních dat z více klasifikací do společného výstupního snímku, čímž rovněž zvyšuje celkovou přesnost a ve vybraných případech dosahuje lepších výsledků než standardně použité samostatné klasifikátory (Jech, 2024).

3.4 Identifikovaná mezera ve výzkumu

Přestože přínosy ensemble přístupů jsou jednoznačné, dosavadní výzkum se většinou soustředí buď na fúzi v rámci jednoho typu dat, například multispektrálních snímků, nebo na kombinaci více modelů nad stejným vstupem. Systematicky však nebyla zkoumána možnost propojit oba přístupy současně – tedy fúzi klasifikací z různých barevných prostorů (RGB, CIELab, HSV) a zároveň fúzi klasifikátorů. Právě tato dvojúrovňová syntéza představuje logický krok vpřed ke zvýšení spolehlivosti a praktické využitelnosti klasifikace obrazových dat v DPZ.

4 HLAVNÍ CÍL VÝZKUMU

Práce se zaměří na návrh a ověření ensemble přístupu pro klasifikaci dat s velmi vysokým prostorovým rozlišením, založeného na kombinaci klasifikací provedených v odlišných barevných prostorech (např. RGB, CIELab, HSV) a na využití multispektrálních dat. Budou zkoumány varianty využívající stejnou klasifikační metodu v různých barevných prostorech či spektrálních kombinacích (např. SVM v RGB a CIELab) i kombinace odlišných metod a datových zdrojů (např. SVM v RGB a CIELab, ML v HSV, integrace vybraných multispektrálních pásem). Cílem práce bude návrh metodického rámce pro tuto fúzi, implementace vybraných variant a jejich ověření na reálných UAV či satelitních datech s cílem zvýšit přesnost, robustnost a interpretovatelnost výsledků.

4.1 Překonání limitací standardních přístupů

Standardní klasifikační postupy, založené na jediném algoritmu aplikovaném na data v RGB prostoru, narážejí na fundamentální omezení. Jedním z nejvýraznějších problémů je spektrální víceznačnost (Spectral ambiguity), kdy se různé typy povrchů v RGB spektru jeví velmi podobně. Tento jev je hlavním zdrojem klasifikačních chyb. Cílem práce je tento problém adresovat systematickým kombinováním informací z více zdrojů, čímž vznikne bohatší a diskriminativnější sada příznaků pro každý pixel. Takto navržený přístup má překonat nejen nedostatky jednotlivých datových reprezentací, ale i slabiny klasifikačních algoritmů, jejichž výkon bývá často podmíněn specifickým charakterem dat.

4.2 Systematický průzkum fúze datových reprezentací

Jádrem výzkumu je systematické zkoumání synergie vyplývající z kombinace různých pohledů na data. Tento průzkum bude probíhat ve dvou rovinách.

Fúze barevných prostorů – výzkum se zaměří na to, jak transformace původních RGB dat do alternativních barevných prostorů, jako jsou CIELab a HSV, přispívají k lepší separaci tříd. Tyto prostory vykazují menší citlivost k proměnlivým světelným podmínkám a zároveň lépe odpovídají lidskému vnímání barev. Cílem je zjistit, zda jejich fúze umožní vytvořit komplexní „spektrálně-percepční“ podpis, který dokáže spolehlivě rozlišit i vizuálně velmi podobné povrchy. Součástí bude rovněž systematické ověření spektrálních indexů navržených pro kombinaci barevných prostorů a jejich přínosu pro zvýraznění sledovaných jevů. Výzkum bude dále rozšířen o analýzu multispektrálních dat a možnost jejich fúze s RGB daty, aby bylo možné ověřit, do jaké míry přispívají dodatečné spektrální kanály k vyšší separabilitě tříd.

Fúze klasifikátorů – druhou rovinou je kombinace výstupů z různých typů klasifikačních algoritmů. Každý z nich vychází z odlišných principů (např. geometrické SVM, pravděpodobnostní ML či ansámblové metody), a proto je náchylný k jiným typům chyb. Jejich fúze má potenciál tyto slabiny kompenzovat a vytvořit robustnější model, který bude stabilnější napříč různými datovými sadami a podmínkami.

4.3 Návrh a validace flexibilního metodického rámce

Výzkum nesměruje pouze k dosažení vyšší přesnosti, ale k vytvoření uceleného, flexibilního a opakovatelného metodického rámce (workflow). Tento rámec má poskytnout jasné strukturovaný postup, který lze opakovaně aplikovat na různá data a situace, a tím zajistit konzistentní a ověřitelné výsledky.

Součástí rámce by měla být implementace různých fúzních strategií. Zamýšleno je testování a porovnávání jak základních technik, například jednoduchého většinového hlasování, tak i pokročilejších přístupů založených na váženém hlasování, které by mohly zohledňovat spolehlivost jednotlivých klasifikátorů.

Nedílnou součástí bude také praktická validace. Navržený rámec bude aplikován a ověřen na reálných případových studiích, aby byla potvrzena jeho praktická použitelnost a zároveň prokázána převaha oproti základním metodám klasifikace. V rámci validace budou testovány i spektrální indexy, a to jak již zavedené, tak i nové návrhy vycházející z kombinace barevných prostorů. Součástí ověření bude rovněž porovnání výsledků dosažených z čistě RGB dat, multispektrálních dat a jejich vzájemné fúze, což umožní kvantifikovat skutečný přínos jednotlivých datových zdrojů. Z pohledu uživatelské aplikace bude navržen metodický rámec směřovat k integraci všech již vyvinutých, tak nových softwarových nástrojů do jednotné platformy (pozn. diplomová práce autora). Ta by měla umožnit intuitivní obsluhu i uživatelům bez hlubších technických zázemí, a to formou desktopové aplikace nebo webového rozhraní s interaktivní nápovědou.

4.4 Cílené zlepšení klíčových parametrů klasifikace

Konečným smyslem navrženého rámce má být dosažení měřitelného zlepšení v nejdůležitějších aspektech klasifikace. Disertační práce se proto zamýšlí soustředit na tři klíčové směry. Prvním cílem je zvýšení přesnosti, a to prostřednictvím dosažení statisticky významného zlepšení hodnoceného pomocí metrik, jako jsou F1-skóre a Cohenův Kappa koeficient. Dalším směrem je posílení robustnosti, tedy vývoj modelu, který by měl být stabilní a poskytovat spolehlivé výsledky napříč různými datasety a podmínkami, čímž by se zmírnily problémy spojené s fenoménem „domain shift“. Třetím přínosem je zlepšení interpretovatelnosti, kdy se očekává, že ensemble přístup povede k přesnějšímu vymezení hranic tříd a spolehlivější klasifikaci v heterogenních a přechodových zónách, čímž se zvýší praktická hodnota výsledků pro koncové uživatele.

5 VÝZKUMNÉ OTÁZKY

Výzkumné otázky převádějí obecný cíl práce do konkrétních problémů, na něž se výzkum zaměří. Jejich formulace vychází z identifikovaných mezer v současném stavu poznání a tvoří základní rámec pro návrh metodologie i následné vyhodnocení výsledků.

5.1 Hlavní výzkumná otázka (VO)

Celý výzkum je zastřešen jednou hlavní otázkou, která odráží ústřední problém práce a nesoustředí se pouze na to, zda je kombinace možná, ale především na to, jak ji provést efektivně, aby byl výsledný synergický efekt maximální a statisticky průkazný.

VO: Jak lze efektivně metodicky navrhnout a prakticky realizovat fúzi klasifikačních výstupů z různých barevných prostorů tak, aby výsledný ensemble model dosahoval prokazatelně vyšší přesnosti a robustnosti než standardní klasifikační přístupy aplikované na VHSR data?

5.2 Dílčí výzkumné otázky (DVO)

Hlavní výzkumná otázka je dále rozpracována do několika dílčích otázek, které povedou jednotlivé fáze experimentů:

DVO1: Jaký vliv má transformace do alternativních barevných prostorů (CIELab, HSV) na výkon klasifikace v porovnání s původními RGB daty?

DVO2: Jaký je přínos fúze klasifikací z více barevných prostorů oproti nejlepším výsledkům dosaženým v jednotlivých prostorech?

DVO3: Poskytuje ensemble model složený z různých typů klasifikátorů (např. SVM, ML, RF) robustnější výsledky než ensemble složený pouze z jednoho typu klasifikátoru?

DVO4: Jaký je efekt fúze klasifikací z různých barevných prostorů a různých klasifikačních metod?

DVO5: Která strategie fúze – například jednoduché většinové hlasování nebo vážené hlasování založené na spolehlivosti modelů vede ke statisticky významně přesnějším výsledkům?

6 NÁVRH METODOLOGIE

Navrhovaná metodologie je koncipována jako kvantitativní experiment, jehož cílem je systematicky porovnat výkonnost navržených ensemble modelů (experimentální skupina) s výkonností standardních samostatných klasifikátorů (kontrolní skupina). Postup navazuje na ověřené workflow z autorovy diplomové práce (Ešpandr, 2025), které ovšem doplňuje a zásadně rozšiřuje o nové kroky zaměřené na transformaci dat a fúzi klasifikačních výstupů. Celý experimentální design je navržen tak, aby byl systematický, transparentní a replikovatelný, což zajistí validitu výsledků.

Základem experimentu budou obrazová data s velmi vysokým prostorovým rozlišením (VHSR), primárně z UAV snímků, která projdou jednotným předzpracováním. Tento proces zahrnuje plánování letu (např. v PIX4Dcapture Pro) a následnou tvorbu ortofotosnímků pomocí algoritmů Structure from Motion (SfM), například v softwaru WebODM Lightning. Pro trénování modelů bude využita část referenčních polygonů, zatímco přesnost bude objektivně vyhodnocena na nezávislé sadě náhodně generovaných bodů, což zajistí prostorově vyváženou validaci. Klíčovým krokem pro vytvoření diverzních vstupů bude transformace původních RGB snímků do alternativních barevných prostorů CIELab a HSV, které jsou, jak bylo doloženo v předchozí práci (Ešpandr, 2025), méně citlivé na kolísání osvětlení.

Jako základní stavební kameny a zároveň jako srovnávací baseline (základní úroveň přesnosti) poslouží tři klasifikátory zvolené pro své odlišné principy např. Support Vector Machine (SVM) jako geometrický přístup, Maximum Likelihood (ML) jako pravděpodobnostní a Random Trees (RT) jako ansámblový. Každý z těchto klasifikátorů bude samostatně aplikován na všechny datové reprezentace, čímž vznikne sada dílčích klasifikačních map. Tyto mapy se stanou vstupem pro klíčovou experimentální fázi fúze dat v rámci ensemble rámce implementovaného v Pythonu. Testovány budou dvě fúzní strategie. První, většinové hlasování (Majority Voting), určí finální třídu pixelu na základě nejčastějšího výsledku napříč dílčími klasifikacemi. Druhá, pokročilejší strategie váženého hlasování (Weighted Voting), přiřadí každému modelu váhu odvozenou z jeho přesnosti (např. F1-skóre), čímž spolehlivější modely získají větší vliv na finální rozhodnutí.

Závěrečná evaluace bude postavena na objektivním kvantitativním zhodnocení. Pro každou výslednou klasifikaci bude z validačních bodů sestavena matice záměn a z ní odvozeny klíčové metriky jako celková přesnost (OA), F1-skóre a Cohenův Kappa koeficient. Následná komparativní analýza se zaměří na porovnání výkonnosti ensemble modelů s nejlepším individuálním klasifikátorem a také na srovnání obou fúzních strategií. Aby bylo zajištěno, že zjištěné rozdíly v přesnosti nejsou náhodné, proběhne statistická validace výsledků. Celý tento evaluační proces tak poslouží k finálnímu ověření navrženého rámce a umožní spolehlivě posoudit, zda jeho aplikace přináší prokazatelný a statisticky významný přínos oproti tradičním metodám.

POUŽITÁ LITERATURA

ALYAHYAN, Saleh, 2025. FusionNet-Remote: A Hybrid Deep Learning Ensemble Model for Remote Image Classification in Multispectral Images. online. In: Discover Computing. Roč. 28, č. 1, 3. Dostupné z: <https://doi.org/10.1007/s10791-025-09498-1>. [cit. 2025-08-18].

BHANDARI, Mahendra; et al., 2021. Assessing the Effect of Drought on Winter Wheat Growth Using Unmanned Aerial System (UAS)-Based Phenotyping. online. In: Remote Sensing. Roč. 13, č. 6, 1144, s. 1-20. Licence: CC BY. Dostupné z: MDPI, <https://doi.org/10.3390/rs13061144>. [cit. 2025-08-19].

BOON, M. A.; DRIJFHOUT, A. P. a TESFAMICHAEL, S., 2017. Comparison of a fixed-wing and multi-rotor UAV for environmental mapping applications: a case study. online. In: The international archives of the photogrammetry, remote sensing and spatial information sciences. Roč. XLII-2/W6, s. 47–54. Dostupné z: <https://doi.org/10.5194/isprs-archives-XLII-2-W6-47-2017>. [cit. 2025-08-15].

BOONRANG, Apinya; PIYATADSANANON, Pantip a SRITARAPIPAT, Tanakorn, 2024. Efficient UAV-Based Automatic Classification of Cassava Fields Using K-Means and Spectral Trend Analysis. online. In: AgriEngineering. Roč. 6, č. 4, s. 4406-4424. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/agriengineering6040250>. [cit. 2025-08-17].

CVETKOVIĆ, Nikola; ĐOKOVIĆ, Aleksandar; DOBROTA, Marina a RADOJIČIĆ, Miroslav, 2023. New Methodology for Corn Stress Detection Using Remote Sensing and Vegetation Indices. online. In: Sustainability. Roč. 15, č. 6, 5487, s. 1-12. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/su15065487>. [cit. 2025-08-18].

DE SWAEF, Tom; MAES, Wouter H.; APER, Jeroen; BAERT, Jan; COUGNON, Mark; REHEUL, Dirk; STEPPE, Kathy; ROLDÁN-RUIZ, Isabel a LOOTENS, Peter, 2021. Applying RGB- and Thermal-Based Vegetation Indices from UAVs for High-Throughput Field Phenotyping of Drought Tolerance in Forage Grasses. online. In: Remote Sensing. Roč. 13, č. 1, 147, s. 1-24. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/rs13010147>. [cit. 2025-08-18].

DOBROVOLNÝ, Petr, 1998. Dálkový průzkum Země, Digitální zpracování obrazu. Brno: MU Brno. ISBN 80-210-1812-7.

DOU, Peng; HUANG, Chunlin; HAN, Weixiao; HOU, Jinliang; ZHANG, Ying a GU, Juan, 2024. Remote sensing image classification using an ensemble framework without multiple classifiers. online. In: ISPRS Journal of Photogrammetry and Remote Sensing. Roč. 208, s. 190-209. Dostupné z: <https://doi.org/10.1016/j.isprsjprs.2023.12.012>. [cit. 2025-08-19].

EŠPANDR, Jakub. (2025). Klasifikace UAV obrazových dat v rámci vybraných území. Diplomová práce. Univerzita Pardubice, Fakulta ekonomicko-správní.

GANO, Boubacar; BHADRA, Subhajyoti; VILBIG, John M.; AHMED, Naser; SAGAN, Vasit a SHAKOOR, Nadia, 2024. Drone-based imaging sensors, techniques, and applications in plant

phenotyping for crop breeding: A comprehensive review. online. In: The Plant Phenome Journal. Wiley Periodicals LLC, roč. 7, e20100, s. 1-28. Licence: CC BY-NC-ND. Dostupné z: <https://doi.org/10.1002/ppj2.20100>. [cit. 2025-08-17].

GIAMERTI, Yuti; DARMADI, Didi; JUNAEDI, Ahmad; LUBIS, Iskandar; SOPANDIE, Didie; MEISHANTI, Ospa Pea Yuanita; SARI, Kartika; HONGO, Chiharu a HOMMA, Koki, 2024. Evaluation Trial of Drought Damage of Rice Based on RGB Aerial Image by UAV. online. In: agriTECH. Roč. 44, č. 4, s. 354-361. ISSN 0216-0455. Dostupné z: <http://doi.org/10.22146/agritech.86077>. [cit. 2025-08-17].

GONZALEZ, Rafael C.; WOODS, Richard E., 2018. Digital Image Processing. 4. vyd. Pearson. ISBN 978-1-292-22304-9.

GOODFELLOW, Ian; BENGIO, Yoshua a COURVILLE, Aaron, 2016. Deep Learning. MIT Press. ISBN 978-0-262-03561-3.

GÖRLICH, Florian; MARKS, Elias; MAHLEIN, Anne-Katrin; KÖNIG, Kathrin; LOTTES, Philipp a STACHNISS, Cyrill, 2021. UAV-Based Classification of Cercospora Leaf Spot Using RGB Images. online. In: Drones. Roč. 5, č. 2, 34, s. 1-15. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/drones5020034>. [cit. 2025-08-19].

CHIABRANDO, F.; DONADIO, E. a RINAUDO, F., 2015. SfM for orthophoto generation: a winning approach for cultural heritage knowledge. online. In: The international archives of the photogrammetry, remote sensing and spatial information sciences. Roč. XL-5/W7, s. 47–54. Dostupné z: <https://doi.org/10.5194/isprsarchives-XL-5-W7-91-2015>. [cit. 2025-08-15].

JECH, Jakub, 2024. Návrh klasifikačního přístupu pro obrazová data s velmi vysokým prostorových rozlišením. Online, disertační práce. Univerzita Pardubice. Dostupné z: <https://hdl.handle.net/10195/84041>. [cit. 2025-08-18].

K., Ashwini; R., Bhuvaneswari a NEHA, Perla Sree, 2023. Remote Sensing Image Classification Based on Confidence Score of Ensemble Machine Learning Classifiers. online. In: 2023 International Conference on Evolutionary Algorithms and Soft Computing Techniques (EASCT). s. 1-6. Dostupné z: <https://doi.org/10.1109/EASCT59475.2023.10392571>. [cit. 2025-08-19].

KERDEGARI, Hamideh; RAZAAK, Manzoor; ARGYRIOU, Vasileios a REMAGNINO, Paolo, 2019. Semi-supervised GAN for Classification of Multispectral Imagery Acquired by UAVs. online. arXiv: 1905.10920. Dostupné z: <https://arxiv.org/abs/1905.10920>. [cit. 2025-08-17].

KHAN, Shahbaz; TUFAIL, Muhammad; KHAN, Muhammad Tahir; KHAN, Zubair Ahmad; IQBAL, Javaid a ALAM, Mansoor, 2021. A novel semi-supervised framework for UAV based crop/weed classification. online. In: PLOS ONE. Roč. 16, č. 5, e0251008, s. 1-18. Licence: CC BY. Dostupné z: <https://doi.org/10.1371/journal.pone.0251008>. [cit. 2025-08-17].

KOLÁŘ, Jan, 1990. Dálkový průzkum Země. Populární přednášky o fyzice, sv. 35. Praha: Státní nakladatelství technické literatury. ISBN 80-03-00517-5.

KOMÁRKOVÁ, Jitka a JECH, Jakub, 2020. Processing UAV Based RGB Data to Identify Land Cover with Focus on Small Water Body: Comparison of Methods. online. In: 2020 15th Iberian Conference on Information Systems and Technologies (CISTI). IEEE, ISSN 2166-0727. Dostupné z: <https://doi.org/10.23919/CISTI49556.2020.9141170>. [cit. 2025-08-19].

KRÁTKÝ, Martin a KOMÁRKOVÁ, Jitka, 2023. Evaluating the Use of Very High-Resolution RGB Imagery from UAV for Vegetation Classification. In: 2023 International Conference on Information and Digital Technologies (IDT). Zilina, Slovakia. s. 51-56. ISSN 2575-677X, 2575-6753. Dostupné z: <https://doi.org/10.1109/IDT59031.2023.10194395>. [cit. 2025-08-17].

LI, Jiating, 2019. Unmanned Aerial Vehicle Data Analysis For High-throughput Plant Phenotyping. Online. Master's Thesis. University of Nebraska – Lincoln. Dostupné z: DigitalCommons@University of Nebraska – Lincoln, <https://digitalcommons.unl.edu/biosysengdiss/88>. [cit. 2025-08-16].

LILLESAND, Thomas; KIEFER, Ralph W. a CHIPMAN, Jonathan, 2015. Remote Sensing and Image Interpretation. 7. vyd. Hoboken, John Wiley & Sons. ISBN 978-1-118-34328-9.

LONGLEY, Paul A.; GOODCHILD, Michael F.; MAGUIRE, David J. a RHIND, David W., 2015. Geographic Information Systems and Science. 4. vyd. Hoboken, NJ: John Wiley & Sons. ISBN 978-1-118-67695-0.

LURTON, X.; LAMARCHE, G.; BROWN, C.; LUCIEER, V.; RICE, G.; SCHIMEL, A. a WEBER, T., 2015. Backscatter measurements by seafloor-mapping sonars: guidelines and recommendations. online. 135 [Technická zpráva]. GeoHab. Dostupné z: <https://doi.org/10.5281/zenodo.10089261>; <https://www.researchgate.net/publication/275890570>. [cit. 2025-08-15].

MAIMAITIJANG, Maitiniyazi; SAGAN, Vasi; SIDKE, Paheding; DALOYE, Ahmad M.; ERKBOL, Hasanjan a FRITSCHI, Felix B., 2020. Crop Monitoring Using Satellite/UAV Data Fusion and Machine Learning. online. In: Remote Sensing. Roč. 12, č. 9, 1357, s. 1-23. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/rs12091357>. [cit. 2025-08-17].

NANNI, Loris; BRAHNAM, Sheryl; RUTA, Michelangelo; FABRIS, Davide; BOSCOLO BACHETO, Matteo a MILANELLO, Tommaso, 2025. Deep Ensembling of Multiband Images for Earth Remote Sensing and Foraminifera Data. online. In: Sensors. Roč. 25, č. 3, 2231. Dostupné z: <https://doi.org/10.3390/s25032231>. [cit. 2025-08-17].

OERKE, E.C., 2006. Crop losses to pests. Online. The Journal of Agricultural Science. Roč. 144, č. 1, s. 31-43. ISSN 0021-8596. Dostupné z: Cambridge Core, doi:10.1017/S0021859605005708; <https://doi.org/10.1017/S0021859605005708>. [cit. 2025-08-18].

PÁDUA, Luís; ADÃO, Telmo; HRUŠKA, Jonáš; GUIMARÃES, Nathalie; MARQUES, Pedro; PERES, Emanuel a SOUSA, Joaquim J., 2020. Vineyard Classification Using Machine Learning Techniques Applied to RGB-UAV Imagery. online. In: 2020 IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Waikoloa, HI, USA. s. 6309-6312. ISBN 978-1-7281-6374-1. Dostupné z: <https://doi.org/10.1109/IGARSS39084.2020.9324380>. [cit. 2025-08-18].

RUFO, Rubén; SORIANO, Jose Miguel; VILLEGAS, Dolors; ROYO, Conxita a BELLVERT, Joaquim, 2021. Using Unmanned Aerial Vehicle and Ground-Based RGB Indices to Assess Agronomic Performance of Wheat Landraces and Cultivars in a Mediterranean-Type Environment. online. In: Remote Sensing. Roč. 13, č. 6, 1187, s. 1-19. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/rs13061187>. [cit. 2025-08-17].

SABINS, Floyd F., 2007. Remote Sensing: Principles and Interpretation. Waveland Press. ISBN 1577665074, 9781577665076.

SEDLÁK, Pavel; KOMÁRKOVÁ, Jitka; JECH, Jakub a MAŠÍN, Oldřich, 2019. Low-cost UAV as a Source of Image Data for Detection of Land Cover Changes. Online. Journal of Information Systems Engineering & Management. Roč. 5, č. 1, 1-7. ISSN 2468-4376. Dostupné z: <https://doi.org/10.29333/jisem/5894>; <https://www.jisem-journal.com/download/low-cost-uav-as-a-source-of-image-data-for-detection-of-land-cover-changes-5894.pdf>. [cit. 2025-08-16].

SEDLÁK, Pavel; KOMÁRKOVÁ, Jitka; MAŠÍN, Oldřich a JECH, Jakub, 2019b. The Procedure for Processing Images from a Low-cost UAV. online. In: 2019 14th Iberian Conference on Information Systems and Technologies (CISTI). Coimbra, Portugal. s. 1-4. Dostupné z: <https://doi.org/10.23919/CISTI.2019.8760952>. [cit. 2025-08-18].

SHU, Mengyi; FEI, Suxia; ZHANG, Baojun; YANG, Xiaoyan; GUO, Yan; LI, Bingjie a MA, Yang, 2022. Application of UAV multisensor data and ensemble approach for high-throughput estimation of maize phenotyping traits. online. In: Plant Phenomics. 2022, 9802585. Dostupné z: <https://doi.org/10.34133/2022/9802585>. [cit. 2025-08-19].

SIMES, Tomás; PÁDUA, Luís a MOUTINHO, Alexandra, 2024. Wildfire Burnt Area Severity Classification from UAV-Based RGB and Multispectral Imagery. online. In: Remote Sensing. Roč. 16, č. 1, 30, s. 1-19. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/rs16010030>. [cit. 2025-08-19].

UNITED NATIONS. Department of Economic and Social Affairs. Population Division, 2017. World Population Prospects: The 2017 Revision, Key Findings and Advance Tables. online. Working Paper No. ESA/P/WP/248. Dostupné z: https://www.un.org/en/development/desa/population/events/pdf/other/21/21June_FINAL%20PRESS%20RELEASE_WPP17.pdf. [cit. 2025-08-18].

YANG, Xin; GAO, Shichen; SUN, Qian; GU, Xiaohe; CHEN, Tianen; ZHOU, Jingping a PAN, Yuchun, 2022. Classification of Maize Lodging Extents Using Deep Learning Algorithms by UAV-Based RGB and Multispectral Images. online. In: Agriculture. Roč. 12, č. 7, 970, s. 1-16. Licence: CC BY. Dostupné z: <https://doi.org/10.3390/agriculture12070970>. [cit. 2025-08-19].