


DÁLKOVÝ PRŮZKUM ZEMĚ A PRECIZNÍ ZEMĚDĚLSTVÍ

Mgr. Daniel Žížala, Ph.D.
doc. Ing. Vojtěch Lukas, Ph.D.
doc. Mgr. Jitka Kumhálová, Ph.D.

2021



DÁLKOVÝ PRŮZKUM ZEMĚ A PRECIZNÍ ZEMĚDĚLSTVÍ

Mgr. Daniel Žížala, Ph.D.¹

doc. Ing. Vojtěch Lukas, Ph.D.²

doc. Mgr. Jitka Kumhálová, Ph.D.³

¹ Výzkumný ústav meliorací a ochrany půdy, v.v.i., laboratoř DPZ a pedometrie

² Mendelova univerzita v Brně, Agronomická fakulta, Ústav agrosystémů a bioklimatologie

³ Česká zemědělská univerzita v Praze, Technická fakulta, Katedra využití strojů

V publikaci jsou prezentovány výsledky výzkumu, který byl podpořen Ministerstvem Zemědělství ČR v rámci projektu QK21010247 Optimalizace hospodaření na nevyrovnaných pozemcích využitím efektivního mapování půdních podmínek a zohlednění změn vláhových poměrů s cílem stabilizace dosahovaných výnosových úrovní a dlouhodobé koncepce rozvoje výzkumné organizace MZE-R00218.



OBSAH

1. Úvod	7	5.7 Indexy hodnotící obsah vody v porostech (Canopy Water Content)	35
2. Precizní zemědělství	9	6. DPZ systémy vhodné pro použití	36
2.1 Technologie využívané v precizním zemědělství	10	6.1 Satelitní systémy	36
2.2 Přínosy precizního zemědělství	12	6.1.1 Multispektrální optická data	36
3. Dálkový průzkum Země	14	6.1.2 Data s velmi vysokým rozlišením	37
3.1 Jaké principy DPZ využívá	15	6.1.3 Radarová data	37
3.1.1 Pasivní dálkový průzkum	16	6.2 Letecké systémy	39
3.1.2 Aktivní dálkový průzkum	16	6.3 Bezpilotní prostředky	39
3.2 Vlastnosti dat dálkového průzkumu Země	18	6.4 Hyperspektrální data	40
3.2.1 Spektrální rozlišení	19	7. Aplikace DPZ pro precizní zemědělství	41
3.2.2 Prostorové rozlišení	19	7.1 Mapování půdních vlastností	41
3.2.3 Radiometrické rozlišení	20	7.2 Optimalizace vzorkování půd	47
3.2.4 Časové rozlišení	20	7.3 Mapování vlhkosti	48
3.2.5 Atmosférické vlivy	20	7.3.1 Optická část elektromagnetického spektra	48
4. Interakce záření s objekty na Zemi	21	7.3.2 Termální oblast elektromagnetického spektra	49
4.1.1 Zjednodušené fyzikální principy pohlcování záření a odrazivosti	21	7.3.3 Mikrovlnná část elektromagnetického spektra	50
4.2 Půda	22	7.4 Určování vláhové potřeby – vodní stres, evapotranspirace	51
4.2.1 Interakce elektromagnetického záření s půdou	22	7.4.1 Odhad hodnot evapotranspirace z dat DPZ	52
4.2.2 Spektrální vlastnosti půdy obecně	23	7.4.2 Data vhodná pro použití při odhadu evapotranspirace	53
4.2.3 Organická hmota	23	7.4.3 Existující služby a aplikace	53
4.2.4 Jílové minerály	24	7.5 Využití DPZ pro návrh variabilně prováděných pěstebních zásahů	54
4.2.5 Sloučeniny železa	24	7.5.1 Identifikace produkčních zón	54
4.2.6 Uhlíčitany	24	7.5.2 Diagnostika výživného stavu porostu a variabilní aplikace hnojiv	56
4.2.7 Voda	24	7.6 Hodnocení poškození porostů pomocí DPZ a diferencovaná ochrana rostlin	63
4.2.8 Půdní textura a morfologie povrchu	24	7.7 Monitoring plodin a výnosů	68
4.2.9 Vegetace a rostlinné zbytky	24	7.7.1 Využití topografických modelů	68
4.3 Vegetace	25	7.7.2 Sledování variability porostů pomocí družicového snímání v optické části spektra	69
5. Vegetační a jiné spektrální indexy	28	7.7.3 Souhrn	78
5.1 Širokopásmové indexy (Broadband Greenness)	29	8. Závěr	80
5.1.1 Indexy využívající pásma ve viditelné části spektra (tzv. RGB indexy)	31	9. Seznam použité literatury	82
5.2 Úzkopásmové indexy (Narrowband Greenness)	32		
5.3 Indexy hodnotící využití světla (Light Use Efficiency)	33		
5.4 Indexy hodnotící celkový obsah dusíku v porostu (Canopy Nitrogen)	33		
5.5 Indexy hodnotící množství uhlíku (Dry or Senescent Carbon)	34		
5.6 Indexy hodnotící obsah pigmentů v listech (Leaf Pigments)	34		



1. ÚVOD

Zemědělství jako již tradiční odvětví národního hospodářství má nezastupitelnou úlohu při výrobě a zásobování obyvatelstva potravinami. Tento tradiční náhled na zemědělství jako na obor, který pouze slouží k výrobě primárních surovin, je však v současné době již ne zcela výstižný. Zemědělství je nyní oborem lidské činnosti, který je široce vnímán i jako prostředek pro péči o krajinu mající významný vliv na fungování přírodních procesů závislých na půdním prostředí. Jedná se například o rozmanitost rostlinných a živočišných společenstev či zadržování a hospodaření s vodou v krajině. Pouze celistvě správně fungující přírodní systém nám tak může zajistit dlouhodobě udržitelný zdroj potravin. Z tohoto pohledu jsou dnes na zemědělství společensky kladeny zvýšené nároky a celý obor tak čelí novým výzvám. Zemědělství je nuceno se oproti předchozím obdobím přizpůsobovat jiným požadavkům na produkci, ať už ze strany nároků zákazníků na vyšší kvalitu potravin či z pohledu výkupních cen jednotlivých komodit, které jsou v dnešní době značně ovlivněny i poptávkou po technických plodinách sloužících k jiným než potravinovým či krmným účelům. Soudobá zemědělská politika, dotační systém a řada legislativních regulací rovněž ovlivňují fungování jednotlivých zemědělských podniků či malých hospodářství a mají vliv na zvýšenou administrativu všech prací. Rovněž odliv pracovníků z oboru, který není dostatečně dotován mladou generací negativně ovlivňuje schopnost zemědělství čelit dalším rizikům a být odolné vůči vlivům ekonomickým, tak i samozřejmě přírodním.

Zemědělství je neodmyslitelně spjato s přírodním prostředím, které tak na něj má zásadní vliv. Výkyvy počasí byly vždy jedním z hlavních činitelů, které ovlivňovaly velikost a kvalitu produkce a určovaly, zda bude konkrétní rok pro zemědělce bohatý či nikoliv. V současné době je však třeba počítat s vyššími extrémními vlivem již zdokumentované a probíhající klimatické změny a těmto změnám se přizpůsobit. Je třeba brát větší ohled na ochranu půdy proti vlivům počasí ať už z hlediska ochrany proti erozi a další degradaci půd nebo z pohledu vytváření vhodných podmínek pro zadržování vody v krajině, které může být vlivem zvýšeného výparu v krajině nedostatek. Nynější stálý úbytek biodiverzity v zemědělské krajině,

tedy rozmanitosti rostlinných a živočišných společenstev může představovat také pro zemědělství zásadní, byť třeba ne tak zjevný problém. Z tohoto pohledu je tak třeba omezovat, respektive zamezit nadužívání chemických, potenciálně škodlivých látek v celém systému výroby.

Tyto pospané problémy a nároky na zemědělskou praxi tak do značné míry mění zažitou představu o celém oboru a vyvíjí tlak na vklad větších prostředků do výroby. Aby však zemědělství bylo v tomto stavu stále udržitelné, životaschopné a konkurenceschopné je jistě potřebné reagovat na současný vývoj a stále zavádět nové postupy a využívat nové technologie.

Vývoj moderních technologií a postupů se tak nevyhýbá ani zemědělství a v tomto smyslu reaguje na výše popsané výzvy. Tento vývoj nejenže historicky vedl a stále vede k dosahování vyšší produkce, ale taktéž může směřovat k omezení zatížení životního prostředí vlivem snížení vstupů do výroby, a tedy i ke snížení nákladů. Jak vývoj ukazuje, zavádění nových technologií do zemědělství má své opodstatnění na různých úrovních zemědělských podniků. Technologie mohou pomáhat jak v rámci řízení podniku pro správné nastavení a vyhodnocení postupů, tak při samotné výrobě. Inovace jsou tak v dnešním zemědělství potřebnější, než kdy byly. Rozvoj technologií nezahrnuje jen zlepšování zemědělských strojů, ale i zavádění zcela nových zařízení, strojů, senzorů či informačních technologií. Dnes jsou tak již v řadě činností běžně používány různé senzory pro měření teploty či vlhkosti, různé roboty např. v živočišné výrobě při dojení, ale také navigační technologie na bázi globálních pozičních systémů (např. GPS) či satelitní snímky v různých spektrálních oblastech. Využití těchto technologií umožňuje jednak zvýšit produkci, ale také snižovat náklady na zdroje, snižovat vliv na životní prostředí a případně i zvyšovat bezpečnost práce.

Jedním z hojně se rozvíjejících odvětví využívajících a aplikujících nové technologie do zemědělství je dálkový průzkum Země, obor, který využívá měření a snímání zájmových objektů na povrchu Země ze vzdálených snímačů ať už umístěných na letadlech, dronech či satelitech, pro



Obrázek 1: Zemědělská krajina v pohledu z hradu Házmburk v České Středohoří

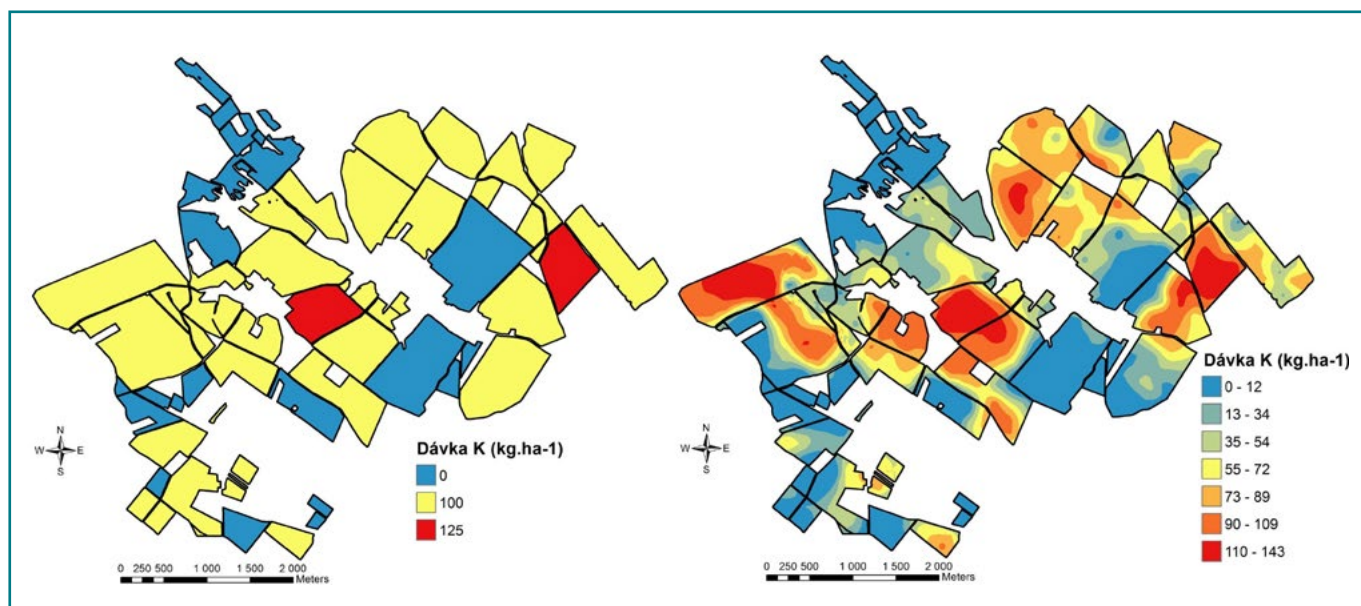
odvození informací o těchto objektech. Tato publikace přináší vhled do možností využití těchto technologií v zemědělství, respektive v jeho oblasti, která je založena na využití moderních technologií, a to v systému tzv. precizního zemědělství. Ambicí této publikace je seznámit Vás – ať už osoby ze zemědělské praxe, odbornou veřejnost, tak i běžné čtenáře – se současnými možnostmi, které dálkový průzkum Země v zemědělství nabízí a jak je využíván. Věříme, že tento text doplněný vysvětlujícími obrázky a příklady Vám přinese nové a pokud možno i v praxi využitelné praktické informace.

2 PRECIZNÍ ZEMĚDĚLSTVÍ

Úrodná půda je jedním z nejvýznamnějších přírodních zdrojů na Zemi. Udržitelné zemědělství by mělo zacházet s půdou takovým způsobem, aby byla zajištěna jak současná, tak budoucí potřeba potravin pro lidstvo při současném zachování přírodních zdrojů a kvality životního prostředí (Schnug et al., 1998). Koncept udržitelného zemědělství je přitom založen na jemné rovnováze maximalizace rostlinné produkce a udržení ekonomické stability při současné minimalizaci využívání neobnovitelných přírodních zdrojů a škodlivých dopadů na životní prostředí (Lowenberg-DeBoer a Erickson, 2000). Systém lokálně cíleného obhospodařování (*site specific management*), často označovaný jako precizní zemědělství (*precision agriculture*), naplňuje cíle trvale udržitelného zemědělství optimalizací produkčních vstupů, zohledňující prostorovou variabilitu v rámci jednotlivých pozemků (Corwin a Plant, 2005). Na pozemky již není nahlíženo jako na nejmenší celistvou jednotku, ale dělí se dále na části, které vycházejí ze znalosti o heterogenitě půdního prostředí a stavu porostů. Znalost variability určitého agronomicky významného znaku (např.

zásoba živin v půdě, zaplevelení) pak představuje základní vstupní informaci pro diferencované provádění pěstebních operací (variabilní aplikace hnojiv, herbicidů). Čím je výraznější heterogenita půdních podmínek (nebo porostů), tím vyšší lze očekávat potenciální uplatnění technologií precizního zemědělství a s tím spojené přínosy.

Podle Mezinárodní společnosti pro precizní zemědělství (ISPA) představuje precizní zemědělství „způsob hospodaření, který sbírá, zpracovává a analyzuje časová, prostorová a individuální data a kombinuje je s dalšími informacemi pro podporu manažerských rozhodnutí podle odhadované variability pro zlepšení efektivity využívání zdrojů, produktivity, kvality, rentability a udržitelnosti zemědělské produkce“ (www.ispag.com). Jedná se o souhrnný pojem pro nové produkční postupy v rostlinné produkci, které intenzivně a ve velkém rozsahu využívají specifická data o stanovišti a porostu plodin a jejíž hlavním cílem je přizpůsobení pěstebních operací lokálním podmínkám stanoviště.




Obrázek 2: Příklad uniformní (a) a variabilní (b) aplikace draselných hnojiv na pozemcích zemědělského podniku o výměře 1500 ha. Dávka hnojiv je stanovena dle zásobenosti živin v půdě (dle Lukas, Ryant et al., 2011).

Precizní zemědělství je řazeno mezi 10 nejvýznamnějších inovací uplatňovaných v současnosti v oblasti pěstování rostlin spolu se šetrným hospodařením s vláhou, pokročilou zemědělskou mechanizací, půdo-ochrannými technologiemi pěstování rostlin, trvale udržitelnou produkcí, biotechnologiemi a metodami genového inženýrství ve šlechtění plodin (Crookston, 2006). Hodnocení využívání technologií precizního zemědělství ve vybraných zemích EU potvrdilo jejich prosazování politickými a poradenskými autoritami jako cestu zvyšování produktivity zemědělské půdy se současným zachováním jejího přírodního bohatství (Barnes et al., 2019). Ačkoli dotační podpora je z hlediska přijetí nových postupů hodnocena pozitivně, významný vliv mohou mít také nepřímé opatření v podobě informační podpory a prokázání ekonomické návratnosti.

2.1 TECHNOLOGIE VYUŽÍVANÉ V PRECIZNÍM ZEMĚDĚLSTVÍ

Pro lokálně cílené hospodaření je nezbytné využívání nejmodernějších technologií, historický vývoj je tedy úzce spjatý s vývojem těchto technologií. Základní principy precizního hospodaření přitom nejsou nové. Dle Stafforda (2006) prostorovou a časovou variabilitu půdních a porostních faktorů v rámci honů si pěstitelé uvědomovali již před staletími. Menší pozemky a jejich vymezení přírodními hranicemi umožňovaly měnit zásahy manuálně. Se zvětšováním pozemků, intenzivní produkcí a mechanizací v polovině minulého století již nebylo možné zohledňovat prostorovou nevyrovnanost honů bez vývoje technologií. Až vývoj zařízení pro počítačem kontrolovanou aplikaci hnojiv a globálních pozičních systémů znovu otevřel otázku vývoje efektivního vzorkování a mapování, které přesně definují prostorovou variabilitu.

Globální navigační satelitní systémy (GNSS) jsou nezbytným prvkem pro přesné určení polohy na zemském povrchu, neboť všechny informace s vazbou na prostorovou variabilitu musí mít přiřazeny souřadnice v daném souřadném systému. Kromě nejstaršího systému Spojených států amerických GPS NAVSTAR lze v současnosti využít také evropský systém GALILEO, systém Ruské federace GLONASS a čínský systém COMPASS/BEIDOU. Princip určení polohy je u všech podobný – na základě doby putování signálu vysílaného z družic je určena přibližná vzdálenost od koncového přijímače. Určení vzdálenosti minimálně od tří družic pak umožňuje stanovit polohu přijímače v prostoru s přesností v řádu několika metrů; tato služba je poskytována bezplatně. Vyšší přesnosti je možné dosáhnout pomocnými technologiemi poskytujícími diferenční korekce přes satelitní systémy (EGNOS), pozemní síť referenčních stanic (např. CZEPOS) nebo RTK systémy. S výjimkou EGNOS se jedná o placené služby, nebo dodatečně pořízené technologie (RTK). Úroveň přesnosti v současnosti dosahuje několika centimetrů, požadavek na přesnost určuje zejména charakter pěstební operace a možnosti uživatelů. Zatímco pro variabilní aplikaci hnojiv bude dostačovat základní přesnost lokalizace pomocí EGNOS, cílená aplikace herbicidních látek řízená po jednotlivých tryskách nebo plečkování širokořádkových plodin vyžadují nejvyšší přesnost lokalizace.



Obrázek 3: Satelitní a pozemní systémy pro určování polohy zemědělských strojů

Informační a komunikační technologie (ICT) zahrnují výpočetní techniku v podobě uživatelských desktopových a mobilních zařízení, palubních počítačů zemědělské techniky, ale současně také serverové technologie, síťové komponenty a řídicí jednotky sensorových a aplikačních zařízení. S ohledem na požadavek přenosu dat je nezbytnou součástí komunikační rozhraní pro bezdrátový přenos dat mezi zařízeními (Bluetooth, Wifi, ZigBee), běžně uživatelsky dostupné celulární mobilní sítě (3G, 4G a připravované 5G), ale také nízkoeenergetické komunikační rozhraní pro internet of things (IoT), jako jsou LoraWAN, Sigfox nebo NB-IoT.

Zpracování prostorových dat (dat s přiřazenou polohou) probíhá v **geografických informačních systémech (GIS)**. Jedná se o desktopové, mobilní nebo cloudové aplikace, které umožňují provádět sběr, zpracování, analýzy a export dvou základních typů dat – vektorů a rastrů. Vektorová data vyjadřují body, linie a polygony, rastry jsou obrazovými daty s definovanou nejmenší jednotkou – pixelem. Záznamy pojezdů strojů, vymezení hranic pozemků, mapy zásobenosti půdy živinami nebo výnosové mapy – to vše jsou prostorová data, která jsou vytvářena a zobrazována pomocí GIS. Zřejmě pro pěstitele nejznámější GIS aplikací je webové rozhraní zpřístupňující registr půdy LPIS.

Senzorová technika umožňuje efektivní stanovení variability pozemku, jejíž zjištění je impulsem pro uplatnění metod precizního zemědělství. Senzory nahrazují nebo vhodně

doplňují tradiční metody zjišťování půdních vlastností a hodnocení porostů polních plodin a snižují tak jejich nákladnost, operativnost a náročnost. Mezi nejpoužívanější patří senzory pro hodnocení spektrálních vlastností porostů cílené pro určení výživného stavu (Yara N-sensor, N-tester, metody leteckého a družicového snímkování a další), pro mapování půdních vlastností (utuzení půdy, měření elektrické vodivosti půdy, vlhkost půdy) a mapování výnosů při sklizni. Uvedená měření jsou prováděna pomocí GNSS a data jsou zpracovávána v GIS.

Aplikační ovládací prvky slouží pro vlastní provedení diferencovaných zásahů. Na základě vstupní informace o intenzitě zásahu, tzn. aplikační mapy, umožňují plynulou změnu dávky hnojiva nebo postřiku, hloubky pracovního nářadí při zpracování půdy či automatickou navigaci mechanizace po pozemku.

2.2 PŘÍNOSY PRECIZNÍHO ZEMĚDĚLSTVÍ

Při využívání technologií precizního zemědělství se setkávají přínosy jak v ekonomické, tak environmentální oblasti.

Ekonomické přínosy vyplývají z optimalizace materiálních vstupů plynoucích do rostlinné produkce. Mezi nejvýznamnější patří hnojiva, přípravky na ochranu rostlin a pohonné hmoty, případně také závlahová voda u řízených závlahových systémů. Ne vždy představuje optimalizace jednoznačně úsporu – variabilní dávkování může představovat zvýšené náklady na hnojiva v porovnání s uniformní aplikací v případě, kdy se na pozemku vyskytují marginální plochy s nízkým obsahem přístupných živin, které vyžadují výrazné dosycení danou živinou. Nedošlo by tedy k úspoře hnojiv, ale byla by dosažena vyrovnaná bilance živin, jejíž ekonomický přínos bude patrný až za delší dobu. Mnohem složitější je situace u variabilní aplikace přípravků na ochranu rostlin, neboť úspěšnost zásahu závisí kromě jiného na spolehlivosti identifikace škodlivého organismu či plevelu. V případě nesprávného vymezení aplikačních zón nebo špatně provedené aplikace se mohou přežít jedinci v krátké době opět rozšířit po pozemku a je nutné zásah opakovat. V daném případě pak může být vhodnější provádět celoplošnou aplikaci a zaměřit se na její správné načasování.

Úspora PHM je dána zefektivněním provozu strojů pomocí navigačních systémů. Pořízení navigačních systémů bývá zpravidla prvním krokem při přechodu na precizní hospodaření. Je ale nutné říct, že samotné navádění mechanizace bez variabilní aplikace plnohodnotně neplní cíle precizního zemědělství z důvodu absence přizpůsobení intenzity zásahů lokálním podmínkám. Technické řešení navigačních systémů dosahuje v současnosti dostatečné přesnosti, vývoj lze očekávat zejména v navigačních aplikacích, které by dokázaly optimalizovat trajektorii pojezdu s ohledem na tvar a reliéf pozemku, pracovní operaci, parametry mechanizační soupravy a konkrétní podmínky na stanovišti (utučení půdy, erozní ohroženost apod.). Kromě optimalizace pracovních operací je možné úspory dosáhnout také efektivním řízením dopravy zemědělských produktů v podniku a managementem využívání strojů.

Další ekonomické výhody v oblasti lidských zdrojů vyplývají ze zjednodušení a zpřehlednění řízení podniku a z automatizace řady pracovních operací v rostlinné a živočišné produkci a s nimi spojené agendě. Na druhou stranu je třeba počítat, že zavedení moderních technologií vyžaduje dostatečně kvalifikované pracovníky.

Přizpůsobení intenzity pěstitelských zásahů konkrétním podmínkám na dané lokalitě a zohlednění aktuálních požadavků rostlin přináší **environmentální výhody** v podobě omezení nadměrného používání materiálních vstupů. Metody precizního zemědělství umožňují také identifikovat ohrožené či chráněné oblasti, kde je nutné hospodařit extenzivně nebo kde je pěstování rostlin zcela nevhodné.

Nejvýznamnější přínosy ve vztahu k životnímu prostředí, při zachování úrovně produkce, jsou připisovány snížení úniku nitrátů z orné půdy, snížení kontaminace prostředí rezidui pesticidů, omezení přehnojování půdy, omezení eroze půdy a následné eutrofizace povrchových vod, snížení spotřeby pohonných hmot a další. Z výsledků studií prováděných v Německu vyplývá zvýšení efektivity využití dusíku u ozimé pšenice o 10–15 % při variabilní aplikaci. V rámci experimentu se simulací úniku nitrátů do vod byla zjištěna 26% redukce těchto ztrát a současně snížení aplikační dávky o 2 % při použití postupů precizního zemědělství.

Vedle těchto přímých účinků lze také zaznamenat nepřímé efekty související s výrobou a používáním agrochemických látek a pohonných hmot (např. snížení spotřeby neobnovitelných surovin a energie při výrobě hnojiv a pohonných hmot, snížení emisí skleníkových plynů, zvýšení biodiverzity volně se vyskytujících rostlinných a živočišných společenstev aplikací pesticidů jen na místech s hospodářsky nebezpečným výskytem škodlivých organismů atd.). Detailní hodnocení pozitivních environmentálních účinků stejně jako porovnávání precizního hospodaření s celoplošně uniformním je v praxi obtížné a dosud citelně chybí.

Zatím nejmenovanou pozitivní vlastností precizního hospodaření je podrobná evidence operací a tedy tzv.

dohledatelnost zemědělských produktů. Každá variabilní aplikace vychází z aplikační mapy, která definuje intenzitu daného zásahu a umožňuje ji zpětně určit pro kterékoliv místo na pozemku. Vyspělé palubní systémy navíc umožňují zpětný zápis reálně aplikované dávky pro případ, že by obsluha změnila nastavení přímo na poli. V kombinaci s podrobnou pěstitelem evidencí se jedná o podrobnou informační základnu pro řešení případných problémů a sporů nebo pro prokázání způsobu produkce prodávané komodity.

Z hlediska hodnocení přínosů využívání technologií precizního zemědělství nejsou dostupné odborné studie jednotné. Ukazuje se, že např. už jen samotné využití navádění zemědělské techniky pomocí GNSS a optimalizace pojezdů mechanizačních souprav po pozemcích formou jednotných kolejových řádků (*Controlled Traffic Farming* – CTF) může přinést významné přínosy v podobě snížení počtu přejezdů po pozemcích, což se projeví na snížení energetické náročnosti zpracování půdy a také zlepšení půdních vlastností (Kroulík et al., 2011). Ačkoli dle Lowenberg-DeBoer a Erickson (2019) bylo navádění s využitím GNSS a přidružené technologie automatizace, jako jsou ovládání sekcí na aplikační technice nebo postupné vypínání řádků sekcí strojů, přijato tak rychle, jako žádné jiné významné technologie v zemědělství, přijímání technologií precizního zemědělství v zemědělských podnicích je velmi pozvolné. Dle jejich studie sotva více jak 20 % zemědělských podniků využívá technologie variabilní aplikace, která přitom byla zemědělci přijímána jako jedno z prvních dostupných řešení precizního zemědělství. Relativně nízkou míru využívání těchto technologií nelze dle autorů považovat za neúspěch, ale spíše za první krok v lokálně cíleném obhospodařování pozemků, který může být časem nahrazen příchodem mnohem pokročilejších technologií, jako jsou autonomní robotické systémy s prvky strojového učení provádějící pěstební zásahy na úrovni rostlin (Lowenberg-DeBoer a Erickson 2019).

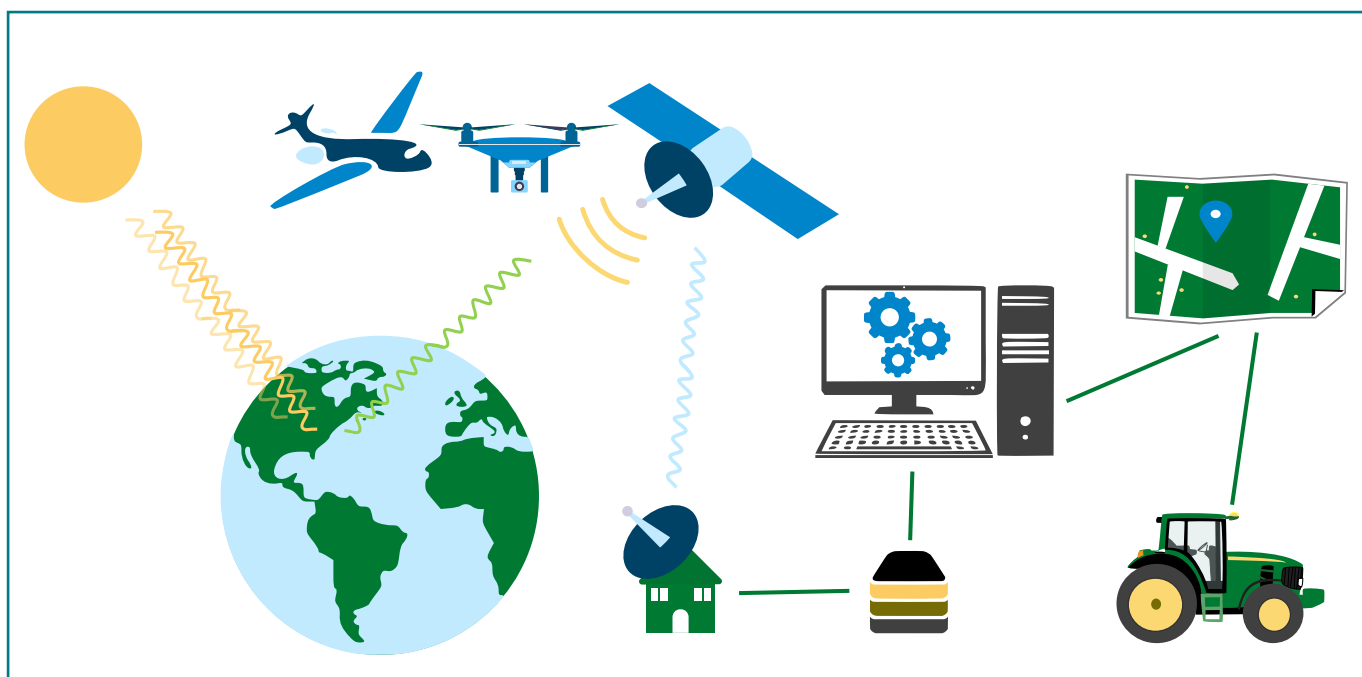
3 DÁLKOVÝ PRŮZKUM ZEMĚ

Dálkový průzkum Země (zkráceně DPZ – angl. *remote sensing*) lze ve zjednodušené definici charakterizovat jako metodu získávání informací o objektech, plochách a jevech na povrchu planety Země prostřednictvím dat měřených na zařízeních, která s těmito zkoumanými objekty, plochami či jevy nejsou v přímém kontaktu. Nicméně například klasické pořízení fotografie na povrchu za dálkový průzkum nepovažujeme. V tomto ohledu se ale v anglické literatuře vyskytuje pojem *proximal sensing*, který evokuje snímání z blízkosti a zahrnuje využití různých senzorů a zařízení pro snímání, které jsou v blízkosti s cílovým objektem, jako jsou například senzory pro snímání vegetace umístěné na zemědělské technice. V českém jazykovém prostředí se tento termín neuvádí, a tak i tyto techniky zahrnujeme pod DPZ.

V rozšířeném pojetí však DPZ nepředstavuje jen souhrn metod, jak konkrétně získat vzdáleně nějakou informaci, ale pod tento termín zahrnujeme i metody zpracování

takto získaných dat a jejich konečnou interpretaci do požadovaného výsledku. Taktéž pod tento termín zahrnujeme všechny součásti celého řetězce zpracování dat:

- nosiče různých kamer a senzorů, kterými mohou být letadla, drony, satelity, ale i například zemědělská technika,
- jednotlivé kamery, senzory, radary a skenery umístěné na těchto nosičích, které nám umožňují měřit či pořizovat požadovanou informaci,
- technické prostředky nejčastěji ve formě počítačů a jejich fyzického vybavení (hardware), které nám umožňují přijímat informace z nosičů, řídit jejich provoz, ukládat, skladovat a zpřístupňovat získané informace, zpracovávat je a vytvářet z nich výsledné produkty,
- programové vybavení (software) ve formě počítačových programů, aplikací či surových naprogramovaných skriptů, které obsluhují příjem, zpracování, analýzu a interpretaci získaných dat.



Obrázek 4: Schematický náčrt procesu dálkového průzkumu Země

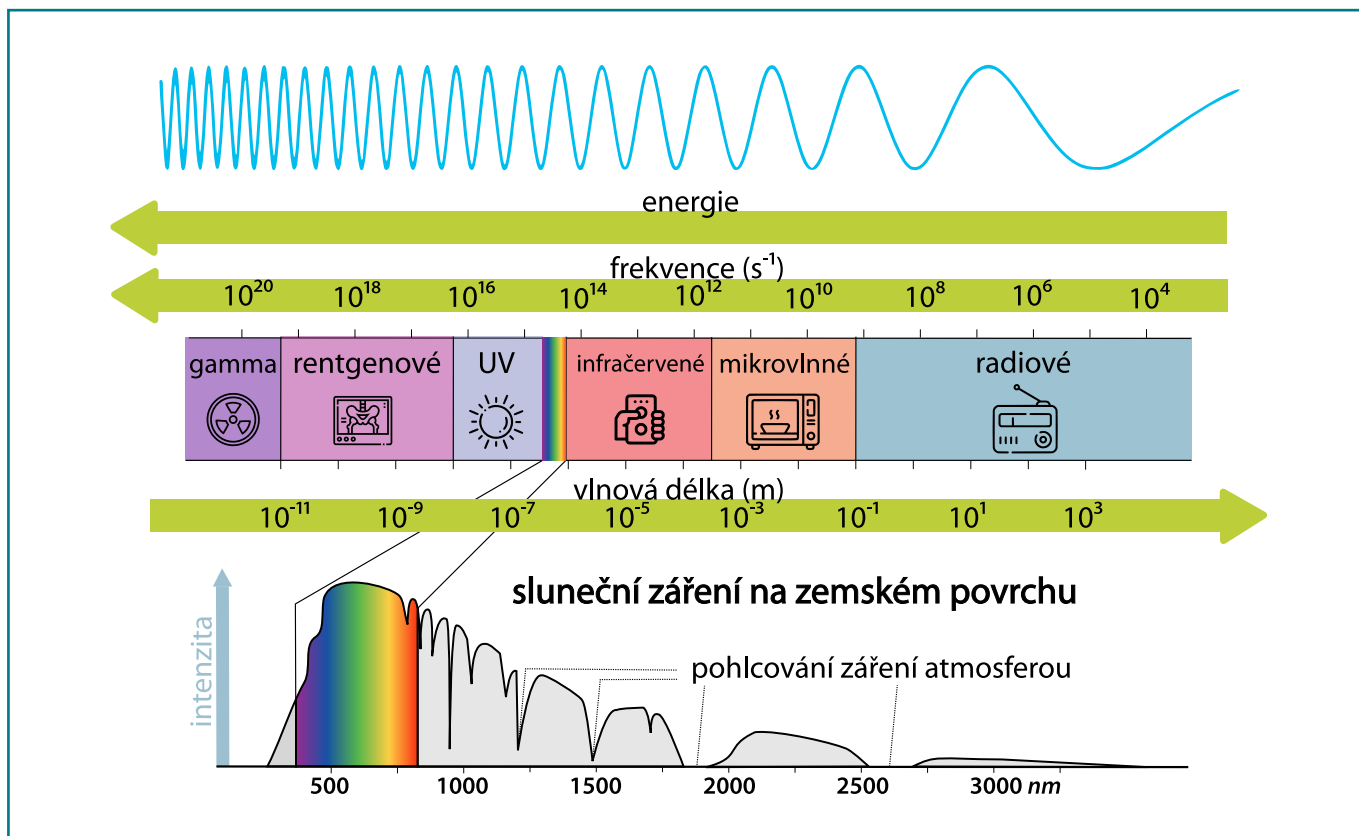
Historicky lze kořeny DPZ hledat už v době, kdy byly pořizovány první fotografie z balónů, draků či dokonce fotoaparáty umístěnými na poštovních holubech. V tomto ohledu sehrával a dodnes sehrává největší význam ve vývoji zejména vojenský sektor. Významný rozvoj technologií přišel s nasazením leteckých nosičů a zejména pak v éře tzv. vesmírných závodů, kdy se začalo se snímáním zemského povrchu z oběžné dráhy Země, tedy ze satelitů. V dalších letech se vývoj výrazně zrychlil a vzájemně s rozvojem výpočetní techniky a optických přístrojů a dalších návazných metod byla vyvinuta celá řada postupů pro využití dálkově snímaných dat. Ty se začali postupně uplatňovat v celé řadě lidských činností a s rozvojem dalších nástrojů jako jsou např. globální polohovací systémy, se začaly výrazně uplatňovat i v zemědělství.

3.1 JAKÉ PRINCIPY DPZ VYUŽÍVÁ?

Dálkový průzkum využívá pro získání informace o vzdálených objektech či plochách měření fyzikálních veličin stejně jako ostatní fyzikální přístroje či třeba i člověk samotný prostřednictvím sluchu či zraku. V rámci DPZ je využíváno zejména měření elektromagnetického záření neboli zjednodušeně světla. Záření je však v přírodním prostředí přítomno v mnoha formách nejenom ve formě viditelného záření, na které je citlivé lidské oko. Viditelné záření je možné zachytávat například pomocí materiálu citlivého na světlo, kde vlivem chemického procesu vyvolaného dopadem světla dochází k zachycení obrazu. Takto známe princip zachycení klasické fotografie na filmový materiál. Tento princip stál i na počátku snímání zemského povrchu. Dopadající světlo je však dnes snímáno především digitálními čipy.

Světlo ať už přirozené, nebo umělé, buď přímo dopadá na snímač nebo dopadá na určitý povrch, kde vlivem různé struktury, tvaru či barvy dochází k různému pohlcení, průchodu či odrazu. Toto odražené světlo je následně zachyceno snímačem. Podle toho, kolik tohoto světla je, můžeme uvažovat o jaký objekt se jedná. Tento proces v podstatě popisuje klasickou černobílou fotografii. V případě barevné fotografie snímáme oddělené části viditelného záření, a tak dostáváme informaci i o barvě objektu. Elektromagnetické záření se vyskytuje i v oblastech mimo vlnové délky viditelného záření. Jistě známe i jiné typy záření jako je rentgenové, UV záření, infračervené, mikrovlnné záření apod. Ve všech případech se jedná o elektromagnetické záření, avšak s různými vlnovými délkami. Celou šíři tohoto záření nazýváme spektrum, které je konvencí rozděleno právě na zmíněné oblasti záření (obrázek 5).

V závislosti na charakteristikách zkoumaného objektu dochází při interakci se světlem v různých vlnových délkách k různým procesům či k různým intenzitě pohlcení a odrazu. Jelikož jsme prostřednictvím různých zařízení schopni zaznamenávat i jiné záření, které je naším zrakem neviditelné, můžeme toho využít pro sledování objektů v rámci DPZ. Jak konkrétně se chovají objekty, které v rámci zemědělské činnosti potřebujeme sledovat, tedy zejména půda a zemědělské plodiny, je podrobněji popsáno v další kapitole. Zde budou více popsány technologické přístupy pro snímání v rámci DPZ.



Obrázek 5: Rozdělení elektromagnetického spektra a umístění viditelného a slunečního záření

3.1.1 PASIVNÍ DÁLKOVÝ PRŮZKUM

Jak již bylo naznačeno, v DPZ se primárně využívá přirozeného záření, a to hlavně záření slunečního. Jak je naznačeno na obrázku 5 dole, záření ze Slunce, které dopadá na zemský povrch má různou intenzitu v různých částech spektra, přičemž největší ve viditelném záření (390–760 nm). I proto se lidské oko nejvíce přizpůsobilo pro vnímání světla v této části spektra. Sluneční záření však zasahuje i do blízkého infračerveného spektra (NIR – *near infrared* 760–1400 nm) a infračerveného spektra krátkých vlnových délek (SWIR – *short wave infrared* 1400–3000 nm), které jsou taktéž v rámci snímání zemského povrchu využívány a souhrnně můžeme hovořit o snímání v tzv. optické části spektra. Na zemský povrch však dopadá jen část slunečního záření. V atmosféře Země totiž dochází k pohlcování a rozptylu záření. Pohlcování je způsobeno zejména chemickým složením atmosféry, kdy se na něm podílí hlavně vodní páry, oxid uhličitý, kyslík nebo například kyslík ve formě ozonu. Části spektra, která naopak atmosféra propouští se nazývají jako tzv. atmosférická okna, do kterých je pak obvykle směřováno měření. I když měření v optické části spektra má své nevýhody, např. i to že záření je pohlcováno přítomnou oblačností, je jeho využití široké a stále nejvyužívanější pro různé aplikace včetně zemědělství.

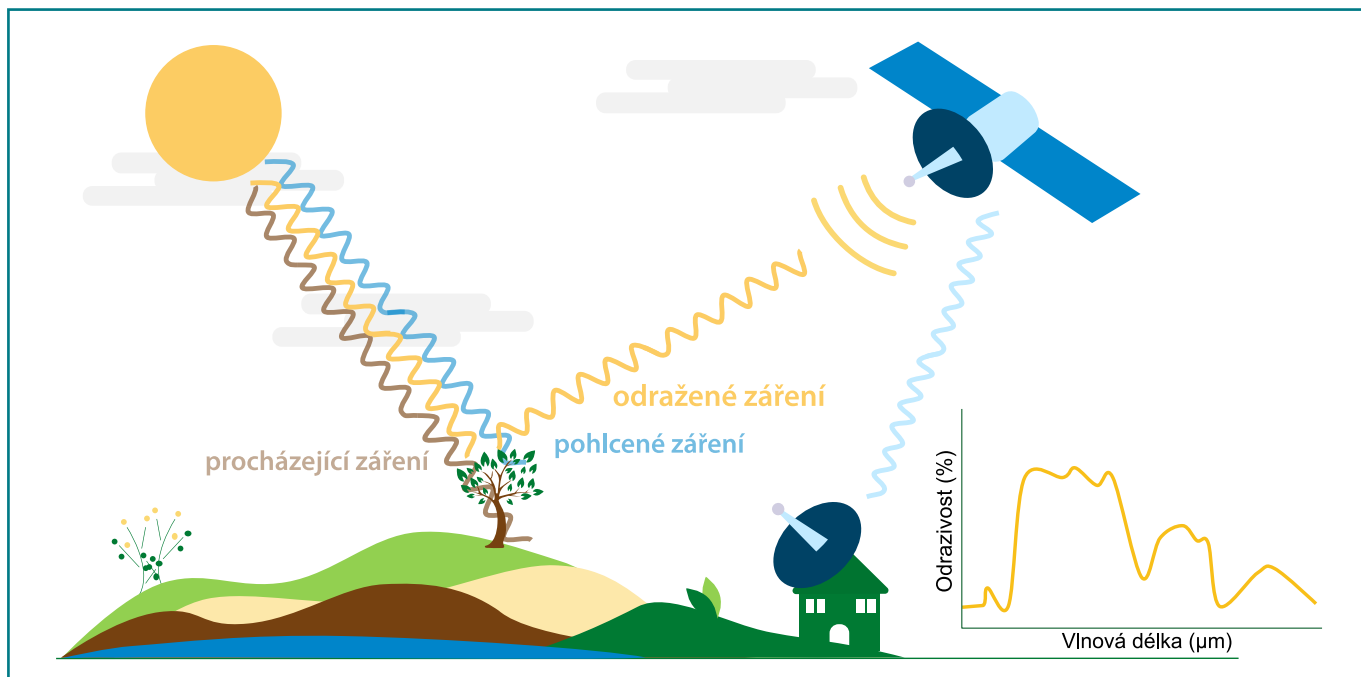
Dalším přirozeným typem záření je to emitované neboli vyzařované zemským povrchem. Každé těleso, které má určitou teplotu, a tedy i energii, totiž vyzařuje elektromagnetické záření. Zjednodušeně, čím chladnější, tím větší je posun do vyšších vlnových délek. Země a objekty

na něm tak vyzařují dlouhovlnné záření v termální části infračerveného spektra. Měřením v této části spektra se zabývá tzv. termální dálkový průzkum Země, který může být využitelný např. při sledování zdravotního stavu rostlin, vlhkosti půdy apod. Souhrnně využívání jiného zdroje záření pro pozorování nazýváme jako tzv. pasivní dálkový průzkum.


3.1.2 AKTIVNÍ DÁLKOVÝ PRŮZKUM

V rámci metod DPZ je také pracováno s umělými zdroji záření, které je aktivně vysíláno z nějakého umělého zdroje, i proto hovoříme o tzv. aktivním dálkovém průzkumu. Tato metoda má své výhody zejména v tom, že může být k pozorování využito i jiných vlnových délek než poskytuje přirozené záření. Rovněž není omezeno na dobu, kdy je přirozený zdroj k dispozici, tzn. například i v noci.

Z pohledu spektra je využíváno zejména mikrovlnného záření. Nejvyužívanějšími představiteli aktivních snímačů jsou radary a laserová zařízení. Radar (zkratka z angl. *Radio Detection and Ranging*) je detekční systém pro měření vzdáleností, úhlů a rychlostí. Jeho aplikací je spousta jak ve vojenském, tak v civilním sektoru, nicméně je hojně využíván i v DPZ. Vlny elektromagnetického záření jsou vytvářeny a přijímány pomocí antén. Jejich délka v kontextu použité vlnové délky pak určuje, s jakou přesností dokáže takový systém pracovat. Jelikož pro dosažení dostatečného rozlišení by bylo potřeba měřit anténou o velkých rozměrech (např. při vlnové délce 5 cm a 10m cílovém




Obrázek 6: Princip pasivního DPZ



Obrázek 7: Princip termálního DPZ

rozlišení by bylo potřeba antény dlouhé 4 250 m), což je velice nepraktické pro umístění na satelitech, byly vyvinuty radary s tzv. syntetickou aperturou, které vytvářejí délku antény uměle. Pro ty se používá známá zkratka SAR (*Synthetic Aperture Radar*). V rámci DPZ je při radarovém pozorování měřen zpětně odražený signál od zkoumaných objektů či povrchů. V tomto se koncepčně neliší od optického DPZ, nicméně způsob zpracování těchto dat je dosti odlišný a odvození potřebné informace z dat není zcela primitivní. K měření se využívá vln o vlnové délce od 1 cm do 1 m. Tyto vlnové délky se konvenčně dělí do několika pásem (viz tabulka 1), přičemž tato délka vlny ovlivňuje,

jak je záření odraženo, k jaké na povrchu dochází interakci a jak hluboko do zkoumaného materiálu je možné proniknout. Využívané vlnové délky tak například procházejí většinou oblačnosti, což je jejich výhodou vzhledem k tomu, že je pak radarové pozorování nezávislé na počasí, respektive výskytu oblačnosti. Odraz záření je mimo vlnové délky závislý na struktuře a drsnosti povrchu, vnitřní struktuře pozorovaného materiálu, úhlu pozorování, polarizaci vysílaného záření či dielektrických vlastnostech objektů (např. jejich vlhkosti). Z pohledu zemědělských aplikací lze radarovými systémy vyhodnocovat jevy jako drsnost povrchu půdy, využití půdy, fenologické fáze rostlin či půdní vlhkost.



Obrázek 8: Princip aktivního DPZ

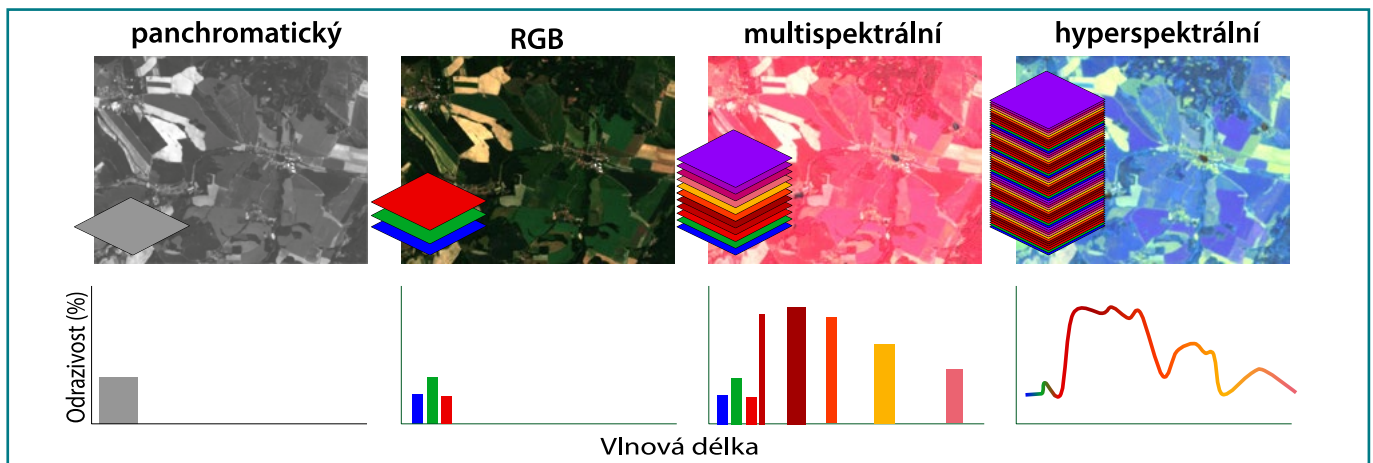
Tabulka 1: Konvenční dělení pásem mikrovlnného záření

Pásmo	Frekvence [GHz]	Vlnová délka [cm]	Aplikace
X	8–12	3,8–2,4	slabý průnik vegetací a jinými materiály, používané pro vojenské účely, průzkum a sledování
C	4–8	7,5–3,8	omezený průnik vegetací a jinými materiály, monitoring nižších plodin, použití pro detekce změn, pozorování ledové pokrývky
S	2–4	15–7,5	Zemědělský monitoring, sledování srážek
L	1–2	30–15	Mapování vyšší biomasy a vegetace, vysoký průnik vegetací, hodnocení vlhkosti
P	0.3–1	100–30	Mapování a hodnocení vegetace

3.2 VLASTNOSTI DAT DÁLKOVÉHO PRŮZKUMU ZEMĚ

Data DPZ jsou zaznamenávána senzory, které jsou umístěny na různých nosičích. Kvalitu a přesnost dat tak ovlivňují nejen charakteristiky jednotlivých sensorů, ale i typ a dráha nosiče, který daný sensor nese. Senzory mohou být umístěny buď na pozemních platformách ať už statických (lešení, jeřáby) či pohybujících se, kterými může být například i zemědělská technika. Obvykle ale jako nosiče sensorů vnímáme ty, které se pohybují ve vzduchu či v kosmickém prostoru vně zemské atmosféry. Takovými jsou například letadla, bezpilotní systémy (drony) nebo v druhém případě družice. Typ nosiče pak také značně ovlivňuje možnosti záznamu potřebné

informace – tj. detail, který je možno zaznamenat a jak velkou plochu je možno nasnímat (prostorové rozlišení), v jakém čase a jak často je možné informace získávat (časové rozlišení) či jak jsou výsledná data ovlivněna průchodem záření atmosférou. Další parametry výsledných dat jsou pak ovlivněny již samotnými senzory, které jsou konstruovány na různých principech ať už se jedná o různé kamery, které zaznamenávají obrazové informace vcelku nebo tzv. skenery, které sestavují obrazovou informaci z jednotlivých měření za pomoci optické soustavy nebo polem detektorů při současném pohybu ve směru snímání.



Obrázek 9: Vliv spektrálního rozlišení na výsledné hodnoty obrazu

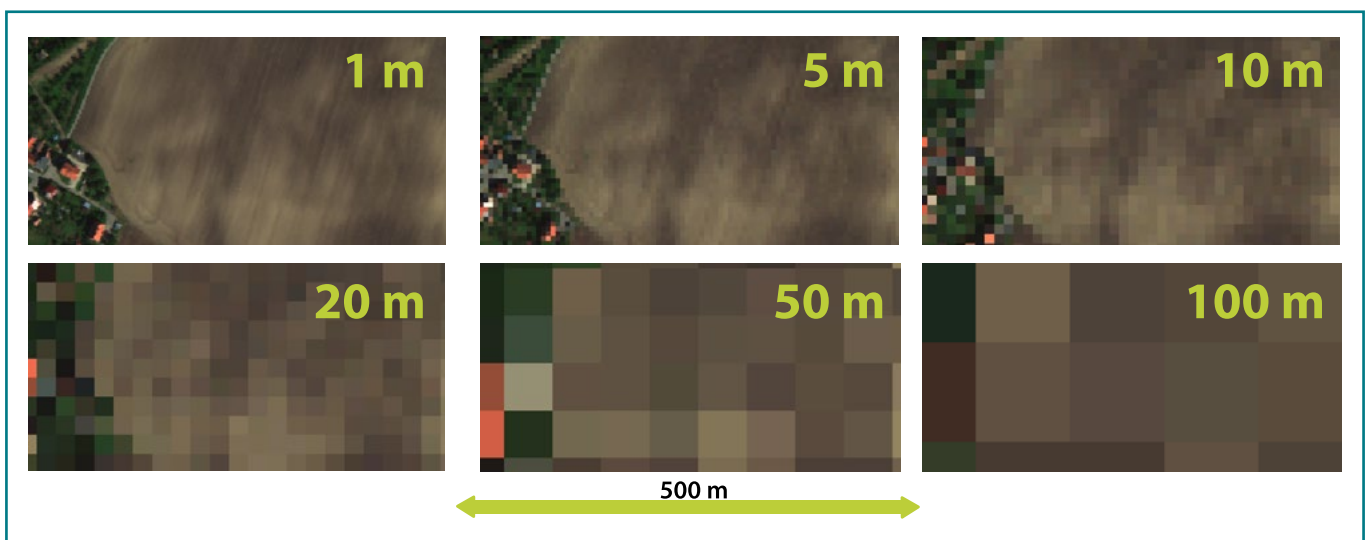
3.2.1 SPEKTRÁLNÍ ROZLIŠENÍ

Jedním z klíčových prvků snímaných dat je jejich spektrální rozlišení. To je charakteristika dat závislá na počtu a rozsahu spektrálních pásem, ve kterých jsou data snímána. Tato charakteristika ovlivňuje kvalitativní i kvantitativní parametry informace, kterou je možno z dat získat. Obecně lze říci, že čím užší spektrální pásy a jejich větší počet, tím je možné lepší odlišení vlivů jednotlivých snímaných objektů a ploch a tím přesnější informace je možno získat. Možnost snímání v užších spektrálních pásmech umožňuje lepší zacílení na konkrétní informace, kterými jsou jednotlivé studované objekty z pohledu spektrální odezvy charakteristické (blíže v další kapitole). Čím ovšem jsou spektrální pásma užší, tím jsou větší nároky na citlivost senzorů, protože v těchto úzkých pásmech je omezená energie, která je následně zaznamenávána. V tomto ohledu hraje roli i geometrie a čas snímání, které určují kolik energie je možno měřit. Například čím vzdálenější senzor, tím užší úhel snímání, a tedy i množství energie dopadající na senzor. Obecně jsou tak pásma zejména satelitních senzorů konstruována pro měření v širších spektrálních pásmech, aby byly schopny měřit

s dostatečnou přesností. Z pohledu časového pak kraje roli denní doba či období roku, které ovlivňuje množství záření přicházející ze Slunce. Počet pásem, který daný senzor má je pak ovlivněn zejména kvalitou detektoru, v jakých pásmech je schopný měřit. S rostoucím počtem pásem je spjat i větší nárok na technologické provedení, a tedy i výsledná cena a například i váha senzoru. Vždy je tedy nutné vážit pro a proti a vybírat nejlepší vhodnou variantu pro daný účel i z pohledu dostupnosti dat, ceny či informační hodnoty.

3.2.2 PROSTOROVÉ ROZLIŠENÍ

Další základní charakteristikou ovlivňující výslednou kvalitu pořízených dat a možnosti jejich využití je prostorové rozlišení. Prostorové rozlišení, respektive velikost obrazového bodu (pixelu) výsledných rastrových obrazových dat, je významným faktorem, který ovlivňuje, jak velký detail je možno pozorovat a jak velké objekty je možno detekovat či dále analyzovat. Pro každý obrazový bod na obrazové scéně (charakterizovaný plochou o dané velikosti) je snímána intenzita odraženého záření. V závislosti na velikosti



Obrázek 10: Vliv spektrálního rozlišení na výsledné hodnoty obrazu

této plochy, pak dochází k mísení spektrální informace ze všech objektů, které do této plochy zasahují. Pro odlišení jednotlivých objektů je tedy velikost snímané plochy zásadní. Z hlediska odlišení menších objektů a ploch je nutné použít data s co nejlepším prostorovým rozlišením, tedy data s velmi vysokým rozlišením. Pokud je dostačující hodnocení plošné různorodosti např. v rámci zemědělských pozemků, může dostačovat rozlišení hrubší, tedy data s vysokým rozlišením (v řádech několika málo desítek metrů).

3.2.3 RADIOMETRICKÉ ROZLIŠENÍ

Radiometrické rozlišení dat je dáno počtem hodnot, které je možno pomocí měření senzorem rozlišit (např.: 8bitová hloubka = $2^8 = 256$ hodnot; 11bitová hloubka = $2^{11} = 2048$ hodnot). Větší radiometrické rozlišení samozřejmě zvětšuje velikost dat, a tak zvyšuje nároky na zpracování. Na druhé straně to má velkou výhodu v možnosti zachytit menší rozdíly intenzity záření, a tak pracovat s větší rozlišovací schopností. Dalším důležitým ukazatelem je poměr signálu k šumu, tzv. signal-to-noise ratio (SNR), který ukazuje na kvalitu získané spektrální informace. Platí, že čím užší jsou spektrální pásma, tím je intenzita přijímaného signálu menší, a tím existuje větší poměr mezi šumem a měřeným signálem. Poměr šumu v datech je závislý na kvalitě snímajícího zařízení (citlivosti, času měření jednoho pixelu), a proto je důležité při hodnocení vhodných zdrojů dat přihlížet i k tomuto parametru.

3.2.4 ČASOVÉ ROZLIŠENÍ

Údaj o časovém rozlišení udává, jak často je možné pořizovat informace ze stejného území, tzn. za jak dlouho může být k dispozici další snímek zájmové lokality. Z pohledu využití pozemních, bezpilotních či leteckých prostředků je takový čas flexibilní a záleží na podmínkách, za kterých je možno data nasnímat. U satelitních systémů je perioda snímání dána zejména drahou družice, která určuje, jak často se daná družice vyskytuje nad zájmovým územím. Některé družice také pracují v konstelaci

více zařízení, jako např. družice Sentinel, které využívají dvě synchronizované zařízení, a tak je doba pořizování dat nad jedním územím zkrácena na polovinu. U satelitních systémů je také důležité, zda pořizují data kontinuálně, či je zapotřebí příslušné snímání objednat, což následně snižuje jejich flexibilitu pro využití. Častá perioda snímání jednak umožňuje lépe pracovat s časovou řadou snímků, a tak lépe analyzovat například vývoj vegetace, ale také usnadňuje nalezení vhodných snímků pro analýzy, které jsou bez vlivu oblačnosti. V oblastech mírného pásu, kde je často, obzvláště v době vegetační sezony, sledování znemožněno vlivem vyskytující se oblačnosti, je tak vyšší časové rozlišení velice žádoucí.

3.2.5 ATMOSFÉRICKÉ VLIVY

Záření, které je využíváno v rámci DPZ, neprochází při své cestě od zdroje k povrchu a zpět k senzoru ideálním prostředím. Záření prochází atmosférou, kde je buď zcela, nebo částečně pohlcováno. Jak již bylo uvedeno, v určitých páslech spektra dochází téměř k plnému pohlcení. Mimo tato pásma v tzv. atmosférických oknech je však záření rovněž ovlivňováno rozptylem v atmosféře. Dochází k rozptylu slunečního záření na molekulách vzduchu (tzv. Rayleighův rozptyl), na částicích (tzv. Mieův rozptyl) nebo se jedná o neselektivní rozptyl. Průchod záření atmosférou je tak ovlivňován i aktuálním stavem atmosféry, a je proto nutné při zpracování leteckých a satelitních snímků počítat s úpravou snímků pomocí atmosférických korekcí nebo využívat snímky již atmosféricky korigované. Korekce eliminují zejména vliv aerosolů a atmosférických plynů na snímaná data.

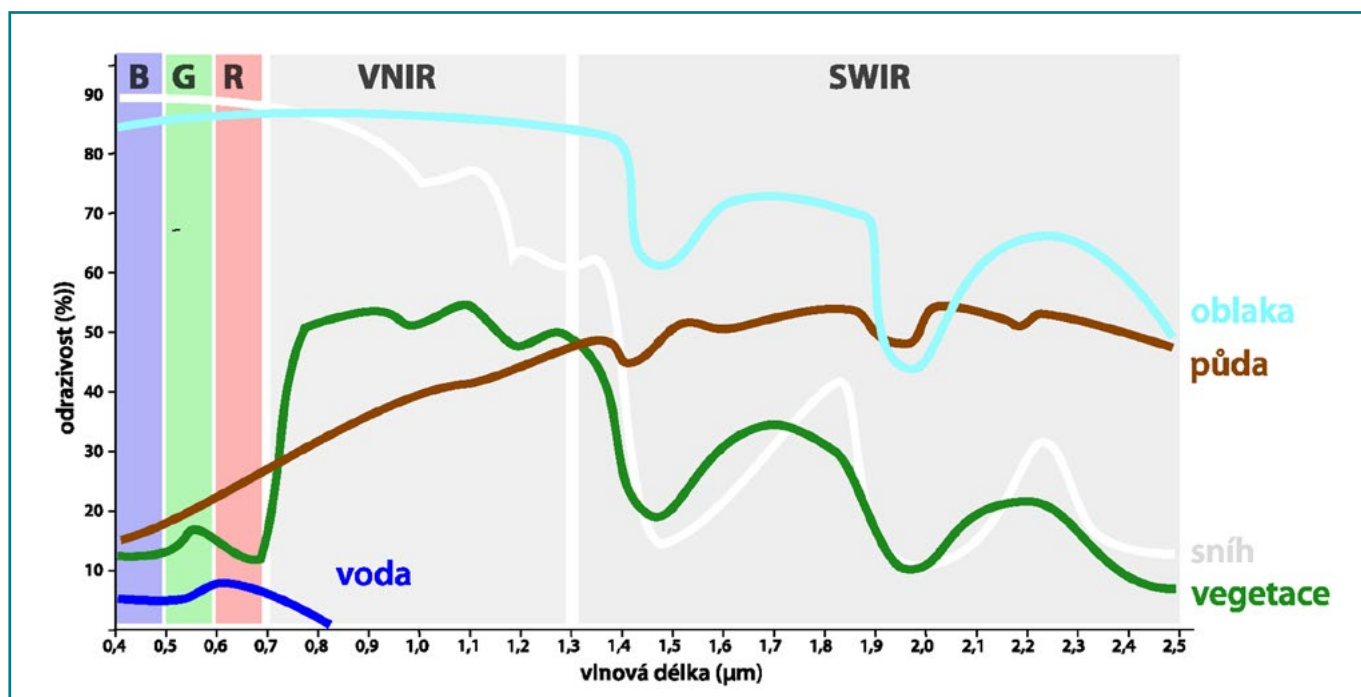
4 INTERAKCE ZÁŘENÍ S OBJEKTY NA ZEMI

Záření, které projde atmosférou dopadá na povrch Země a objekty, které se na něm vyskytují. V závislosti na charakteristikách těchto objektů a vlnové délce záření dochází u objektů k pohlcení záření (absorpci), jeho odrazu (reflektanci) nebo průchodu záření (transmisi) těmito objekty. V rámci DPZ je zaznamenáváno zejména odražené záření, a to ve směru senzoru. Objekty na zemském povrchu jsou tak obvykle hodnoceny na základě jejich aktuální odrazivosti, z které lze usuzovat o charakteristikách těchto objektů. Množství odraženého záření ovlivňuje jednak geometrie snímání, tedy úhel dopadu záření a pozice senzoru, tedy úhel odrazu, a dále fyzikální a chemické vlastnosti sledovaných objektů. Fyzikální charakteristiky jako drsnost povrchu, topografie reliéfu či vnitřní struktura ovlivňují především způsob odrazu záření, zda bude docházet spíše k zrcadlovému odrazu nebo tzv. difuznímu tedy všesměrnému odrazu. Chemické vlastnosti pak ovlivňují především absorpci v různých


částech spektra a zapříčiňují tak různou odrazivost v různých vlnových délkách. Například voda absorbuje téměř všechno záření v infračervené části spektra, ve viditelném potom absorbuje méně a dochází tak k odrazu, největšímu v modré části viditelného spektra, a tak se čistá voda jeví jako modrá. Další části této kapitoly jsou nicméně věnovány spektrálním charakteristikám základních objektů sledovaných v zemědělské praxi, jimiž jsou půda a vegetace, především tedy zemědělské plodiny.

4.1.1 ZJEDNODUŠENÉ FYZIKÁLNÍ PRINCIPY POHLCOVÁNÍ ZÁŘENÍ A ODRAZIVOSTI

V rámci DPZ je klasicky používáno vlnové teorie, tedy konceptu, kdy je na záření pohlíženo jako na vlnu. Na základě této klasické teorie byla odvozena řada principů



Obrázek 11: Spektrální charakteristiky různých materiálů



Obrázek 12: Typy kvantových interakcí elektromagnetického záření s látkami v závislosti na vlnové délce

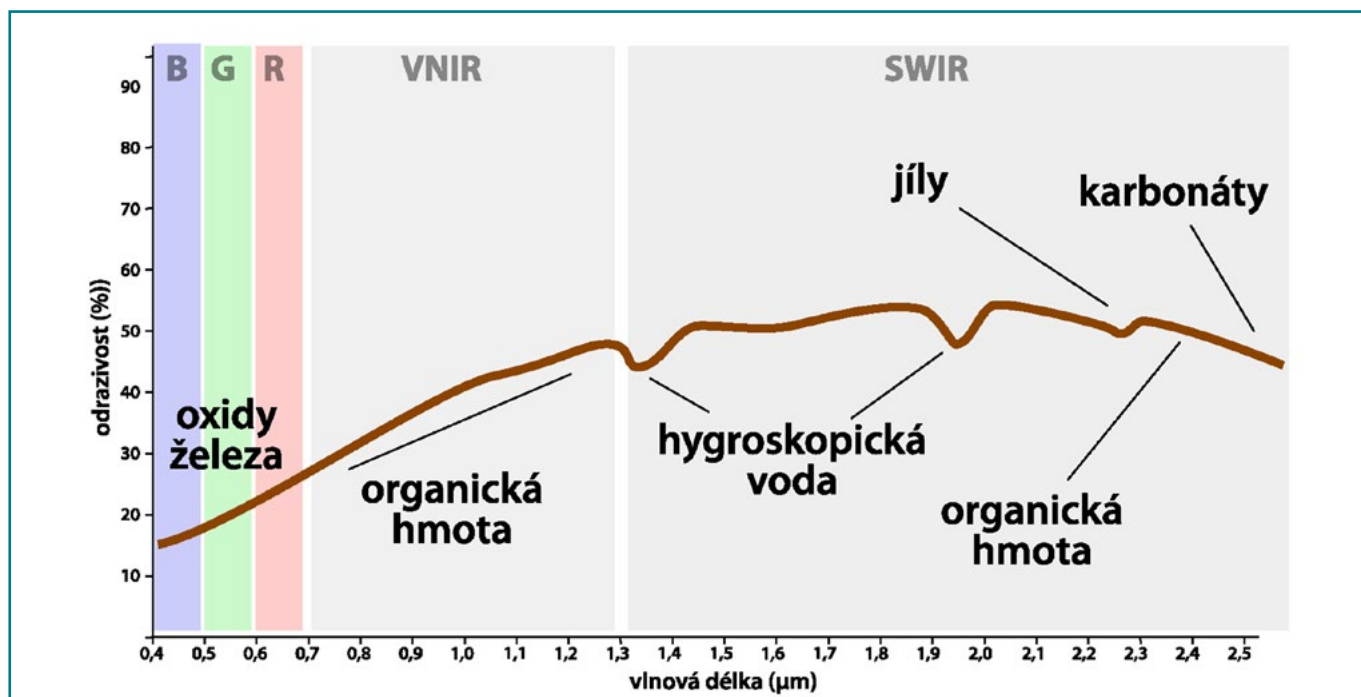
4.2 PŮDA

využívaných v DPZ, a které dokážou vysvětlit řadu jevů a mohou být použity pro interpretaci obrazových dat. Pro pochopení spektrálního chování různých materiálů je však zapotřebí i vzhled do kvantově-mechanických interakcí, které umožňují popsat, jak konkrétně a v jakých konkrétních vlnových délkách může docházet k pohlcování záření, a tedy snížení měřené odrazivosti. Kvantová teorie pohlíží na záření jako na proud částic (fotonů), které v každé vlnové délce mají specifickou energii. Částice určité energie pak při interakci s materiálem, na který dopadají, mu mohou energii předat a způsobit změny na atomové či molekulární úrovni – elektronové přechody (excitace elektronů), vibrační přechody či rotační přechody (změny vibračních a rotačních stavů). Jelikož různé chemické sloučeniny k těmto přechodům potřebují různé množství energie, dochází tak na různých chemických komponentách k pohlcení záření v konkrétních vlnových délkách, což lze využít při detekci komponent pomocí spektra. Jelikož složitější sloučeniny obsahují větší množství různých vazeb, spektrálních absorpčních pásem může být několik. Tyto teoretické znalosti jsou podstatné zejména v laboratorní spektroskopii či při hyperspektrálním měření, nicméně přináší informace, které lze využít i v širokopásmovém snímání v rámci DPZ, protože nám umožňují poznat základní principy interakce záření se sledovanými objekty.

Půda je z pohledu svého složení poměrně hodně různorodý materiál, složený z minerálního materiálu různé velikosti, organické hmoty také poměrně hodně různorodého složení, vody a vzduchu. Odrazivé půdní spektrum je tak výsledkem kombinace vnitřního spektrálního chování různých půdních složek, které různě interagují s dopadajícím zářením. Pomocí DPZ můžeme sledovat pouze svrchní vrstvu půdy. Sluneční záření totiž nemůže proniknout více jak 50 μm pod povrch půdy (Ben-Dor et al. 1999). Pokud nicméně uvažujeme, že vlivem orby dochází k homogenizaci orničního horizontu, dá se hovořit o možnostech sledování složení celého tohoto horizontu. Další limity sledování půdních vlastností a půdní variability jsou spojeny s potřebou sledovat půdu bez dalších ovlivňujících faktorů, jakými jsou pokryv vegetací, rostlinné zbytky, vlhkost či zvýšená drsnost povrchu (např. vlivem orby). Sledování půdních vlastností tak není triviální úlohou, nicméně je možné a možnosti sledování se dále poměrně rychle dynamicky vyvíjejí. Je však zapotřebí znát základní principy, které ovlivňují odrazivé spektrum půdy a také je třeba mít na paměti, že v rámci sledování půdy je, stejně a možná i více jako u jiných disciplín DPZ, zapotřebí pro kalibraci a ověření používat pozemně získaná data.

4.2.1 INTERAKCE ELEKTROMAGNETICKÉHO ZÁŘENÍ S PŮDOU

Jak půda ovlivňuje přicházející záření je výsledkem velkého množství kvantově-mechanických interakcí s velkým množstvím různorodých atomů, molekul a krystalů v makroskopickém objemu půdy. Pro popis



Obrázek 13: Spektrální křivka půdy a absorpční pásma spektrálně aktivních půdních komponent

a vysvětlení působení makroskopického objemu půdy na záření je však používáno i principů klasické vlnové teorie, případně geometrické optiky (Ben-Dor & Demattê 2015, Ben-Dor et al. 1999), protože dochází ke komplexnímu mísení vlivů celé řady půdních komponent a popis absorpce v půdě není tak zcela triviální. Vliv jedné půdní složky může být překryt vlivem působení jiné složky a tak může být přímé hodnocení konkrétní složky komplikovanější a je k jejímu hodnocení často potřeba využít vhodných spektrálních nebo datově založených modelů s využitím kalibračních dat, tedy analytických a statistických metod, například na bázi vícerozměrné analýzy (Gomez et al. 2008, Ge et al. 2011, Ben-Dor et al. 2009). Vzhledem ke komplexitě vztahů v půdě nelze totiž často použít jednoduchých postupů spektrální analýzy či například modelů lineárního mísení (spectral unmixing) základních elementárních prvků (end members), jako je tomu například v geologických aplikacích.

4.2.2 SPEKTRÁLNÍ VLASTNOSTI PŮDY OBECNĚ

Z hlediska chemického složení jsou půdy komplexem různorodých složek (voda, křemičitany, uhličitan, sírany, hydroxidy či nitráty), které se spektrálně projevují různým způsobem nebo nemají spektrální odezvu vůbec. Výsledná spektrální křivka odrazivosti je kombinací křivky spektrální odrazivosti jednotlivých spektrálně aktivních minerálů obsažených v půdě a obsahem organických látek. Vliv na křivku mají i dynamické faktory proměnné v čase a prostoru nebo závislé na podmínkách pozorování. Ve viditelném a blízkém infračerveném spektru (VNIR) se spektrální křivka půdy

vyznačuje pozvolným monotónním nárůstem odrazivosti se zvětšující se vlnovou délkou až k absorpčním pásům vody na vlnových délkách 1400 nm a 2700 nm. Spektrální charakteristiky v krátkovlnném infračerveném pásmu (SWIR) jsou primárně ovlivňovány spektrálními prvky hydroxylů, karbonátů, silikátů a vody. Vliv na snížení odrazivosti v tomto spektrálním rozsahu mají zejména organický materiál společně s půdní vlhkostí.

Na spektrální chování půd mají z chemického hlediska vliv zejména tři základní komponenty: minerály (hlavně jílové a oxidy železa), organický materiál (živý či dekomponovaný) a voda ve všech fázích (Stoner & Baumgardner 1981, Ben-Dor et al. 1999, Ben-Dor & Demattê 2015). Ve viditelném spektru jsou hlavními absorbenty v půdě organický materiál a železo, přičemž voda a jíly jsou hlavními absorbenty v infračervené oblasti spektra.

4.2.3 ORGANICKÁ HMOTA

Půdní organická hmota významně ovlivňuje tvar a podstatu spektra půdní odrazivosti. Poměrně velká variabilita složení organické hmoty a existence řady spektrálně aktivních funkčních skupin v organické hmotě je předpokladem pro celou řadu absorpčních pásem ve spektru této půdní komponenty. Tyto pásy se vztahují k mnoha spektrálně aktivním organickým sloučeninám, jako jsou například huminové kyseliny (např. 1929 a 1932 nm), celulóza (např. 1370, 1725 a 2347 nm) či lignin (2050 a 2351 nm) a k jejich různým funkčním skupinám (Ben-Dor & Demattê 2015, Viscarra Rossel et al. 2006). Zmíněné regiony se však mohou překrývat (Summers et al. 2011).

4.2.4 JÍLOVÉ MINERÁLY

U všech jílových minerálů je v oblasti VNIR-SWIR spektrálně aktivní pouze hydroxylová skupina O-H. Tato skupina se vyskytuje jako součást minerální struktury, nebo jako součást tenké vrstvy vody spojené s minerálním povrchem jílových minerálů (adsorbovaná voda). Pro jílové minerály existují tři hlavní aktivní spektrální regiony v okolí vlnových délek 1300–1400 nm, 1800–1900 nm a 2200–2500 nm.

4.2.5 SLOUČENINY ŽELEZA

Oxidy železa jsou produktem zvětrávání a vyskytují se v půdách velmi často. Tyto minerály jsou obvykle zastoupeny v omezeném množství, ale hrají důležitou roli, protože reflektují typ a stupeň vývoje půdy. Oxidy železa absorbují selektivně ve viditelné části spektra, což se projevuje v jejich výrazném zbarvení od červené, přes žlutou až po hnědou. Absorpční pásma železnatých iontů (Fe^{2+}) se nacházejí na vlnových délkách 430, 450, 510, 550 a 1000 nm. Absorpční pásma železitých (Fe^{3+}) iontů se nacházejí na vlnových délkách 400, 700 a 870 nm.

4.2.6 UHLIČITANY

U uhličitánů je spektrálně aktivní vazba C-O (v rámci radikálu CO_3^-), která umožňuje analyzovat jejich obsah ze spektrálních dat (Ben-Dor & Banin 1990, Ben-Dor et al. 1999, Ben-Dor & Dematté 2015). V pásmu SWIR existuje 5 hlavních absorpčních pásů pro popis vazby C-O, mezi hlavní spektrálně aktivní region patří okolí vlnové délky 2336 nm. Slabší absorpční pásy se nacházejí na úrovni 2160, 1990 a 1870 nm (Ben-Dor & Banin 1990, Stenberg et al. 2010).

4.2.7 VODA

Voda se vyskytuje v půdách ve třech základních formách, přičemž každá tato forma ovlivňuje odrazové spektrum

jinak. Voda může být začleněna v mřížce některých minerálů (tzv. hydratační voda). V tomto případě se výrazně projevují absorpční pásy skupiny O-H v okolí vlnových délek 1400 a 1900 nm. Hygroskopická voda adsorbovaná na povrch jílových minerálů a humusových částic ovlivňuje především celkovou odrazivost půd. Silná absorpční pásma vody se nachází v okolí vlnových délek 1400 a 1900 nm a další se slabšími projevy v okolí 950 a 1200 nm. Volná voda v pórech hraje významnou roli při odrazu světla. Způsobuje pokles odrazivosti v celém rozsahu spektra a tím maskuje vliv dalších možných absorpčních prvků. Z tohoto důvodu je optimální spektrálně sledovat půdy v suchém stavu, kdy je vliv vlhkosti omezený.

4.2.8 PŮDNÍ TEXTURA A MORFOLOGIE POVRCHU

Půdní textura neboli zrnitostní složení úzce souvisí s morfologií povrchu. Spektrální vlastnosti tak ovlivňuje nejen chemicky jako v případě jílových minerálů, ale i fyzikálně, kdy ovlivňuje změny v indexu lomu světla vzhledem ke své geometrii. Půdy tvořené většími texturními částicemi či agregáty obecně odrážejí méně světla vlivem vícenásobných odrazů mezi nerovnostmi na povrchu. Obecně lze říci, že se snižující se velikostí částic a půdních agregátů se zvyšuje odrazivost a snižuje se kontrast mezi absorpčními prvky. Stejně tak působí i zvýšená drsnost povrchu vlivem úpravy pozemků, např. vlivem orby. Pro sledování půdy je tak vždy lepší vybírat termíny, kdy je půda v upraveném stavu s co nejmenší drsností povrchu.

4.2.9 VEGETACE A ROSTLINNÉ ZBYTKY

Vegetace nebo rostlinné zbytky na povrchu půdy způsobují buď přímé zakrytí půdy, nebo částečné ovlivnění výsledného spektra vlivem mísení spektrální informace s vlivem půdy. Pro podrobné spektrální studium půd je tak vhodné odlišit čistě holé půdy bez příměsí vegetace. Problematické z hlediska sledování půdy jsou ovšem i rostlinné zbytky ponechané na povrchu půdy, případně pouze mělce zapracované (např. v případě užití bezorebných technologií).



Obrázek 14: Příklady metod spektrálních měření porostu a jejich vlastnosti spojené s využitím v zemědělství

4.3 VEGETACE

Pro návrh lokálně cílených zásahů v průběhu vegetace plodin jsou vyžadovány celoplošné informace o stavu porostů. Jejich zjišťování tradičním způsobem na potřebné prostorové úrovni je značně náročné a ekonomicky nákladné. Proto jsou využívány postupy dálkového průzkumu Země, které hodnotí stav vegetace na základě spektrálního chování – odrazivosti elektromagnetického záření, nejčastěji v oblasti viditelného a blízkého infračerveného záření. Pro kvantifikaci parametrů vegetace lze využít vegetační indexy, které jsou stanoveny na základě poměru odrazivosti v přesně definovaných pásmech elektromagnetického záření. Odborná literatura uvádí řadu vegetačních parametrů, které lze využít pro diagnostiku stanovení výživného stavu rostlin a stresových projevů (Fu et al. 2014, Li et al. 2014). Pro hodnocení stavu vegetace je využíván družicový dálkový průzkum poskytující multispektrální data s vysokým prostorovým a časovým rozlišením, ale také letecké multispektrální a hyperspektrální snímkování či pozemní mapování s využitím spektrometrických metod. Od volby nosiče snímací soustavy je závislá výška snímkování, která je důležitá s ohledem na eliminaci negativních povětrnostních vlivů – zejména výskytu oblačnosti. Zatímco při silné oblačnosti jsou satelitní data prakticky nepoužitelná, při leteckém snímkování lze většinou výšku přeletu naplánovat a výše položené oblakům se vyhnout. Podobně plodinové senzory jsou díky umělému osvětlení víceméně nezávislé na světelných a atmosférických podmínkách a umožňují vyhodnotit stav porostu přímo při provádění pěstebních zásahů.

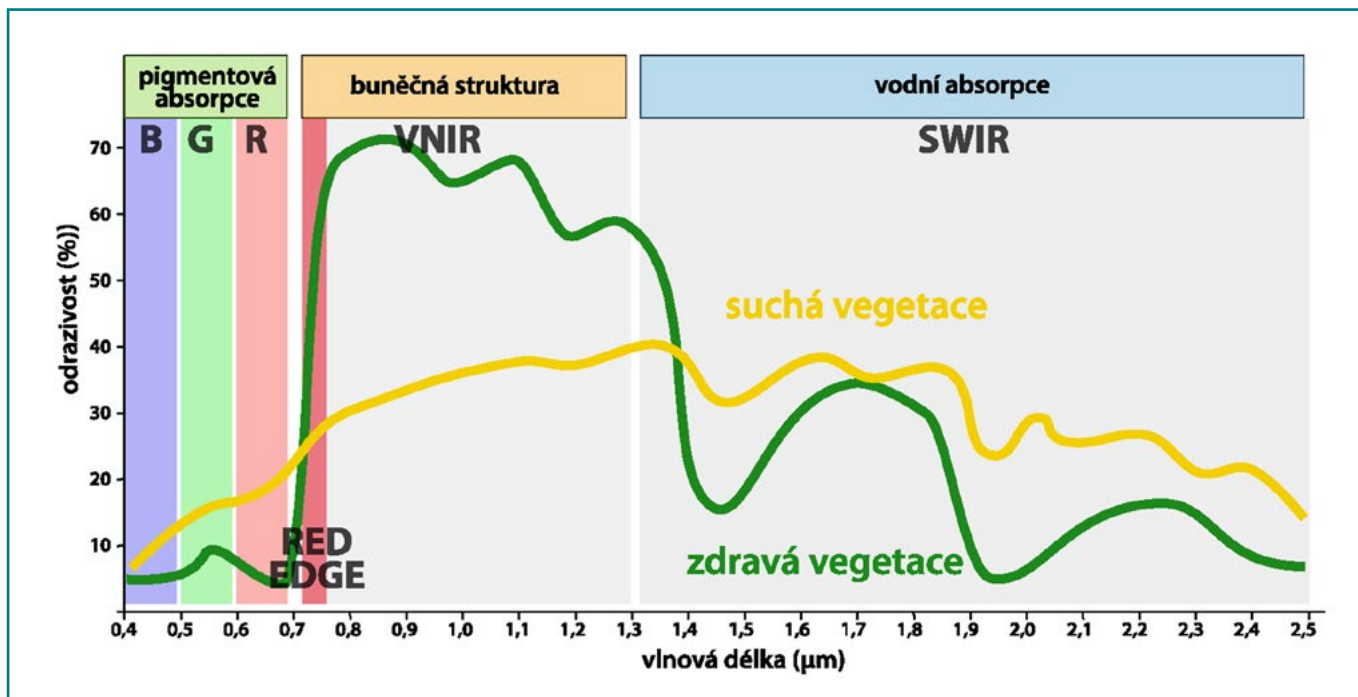
Při diagnostice stavu porostu jsou využívány rozdíly ve spektrálním chování rostlin. Rostliny totiž vykazují specifickou odrazivost v jednotlivých pásmech elektromagnetického záření. Modrá a červená část záření jsou v převážné většině spotřebovávány při procesu fotosyntézy, část

zeleného spektra je odražena (proto se nám rostliny jeví jako zelené). V blízké infračerveném spektru (NIR) je větší na záření odražena. NIR je pro lidské oko neviditelné, pro jeho záznam je nutné speciální detekční zařízení. Zjednodušeně lze říci, že odrazivost ve viditelném záření podává informaci o stavu fotosyntetického aparátu, zatímco v NIR o množství biomasy. Průběh křivky odrazivosti rostlin se zelenými listy jsou podobné, pouze se liší v odchylkách její amplitudy. Typický průběh je patrný z obrázku 15 a je ovlivněn koncentrací chlorofylu a dalšími pigmenty, obsahem vody a strukturou listů.

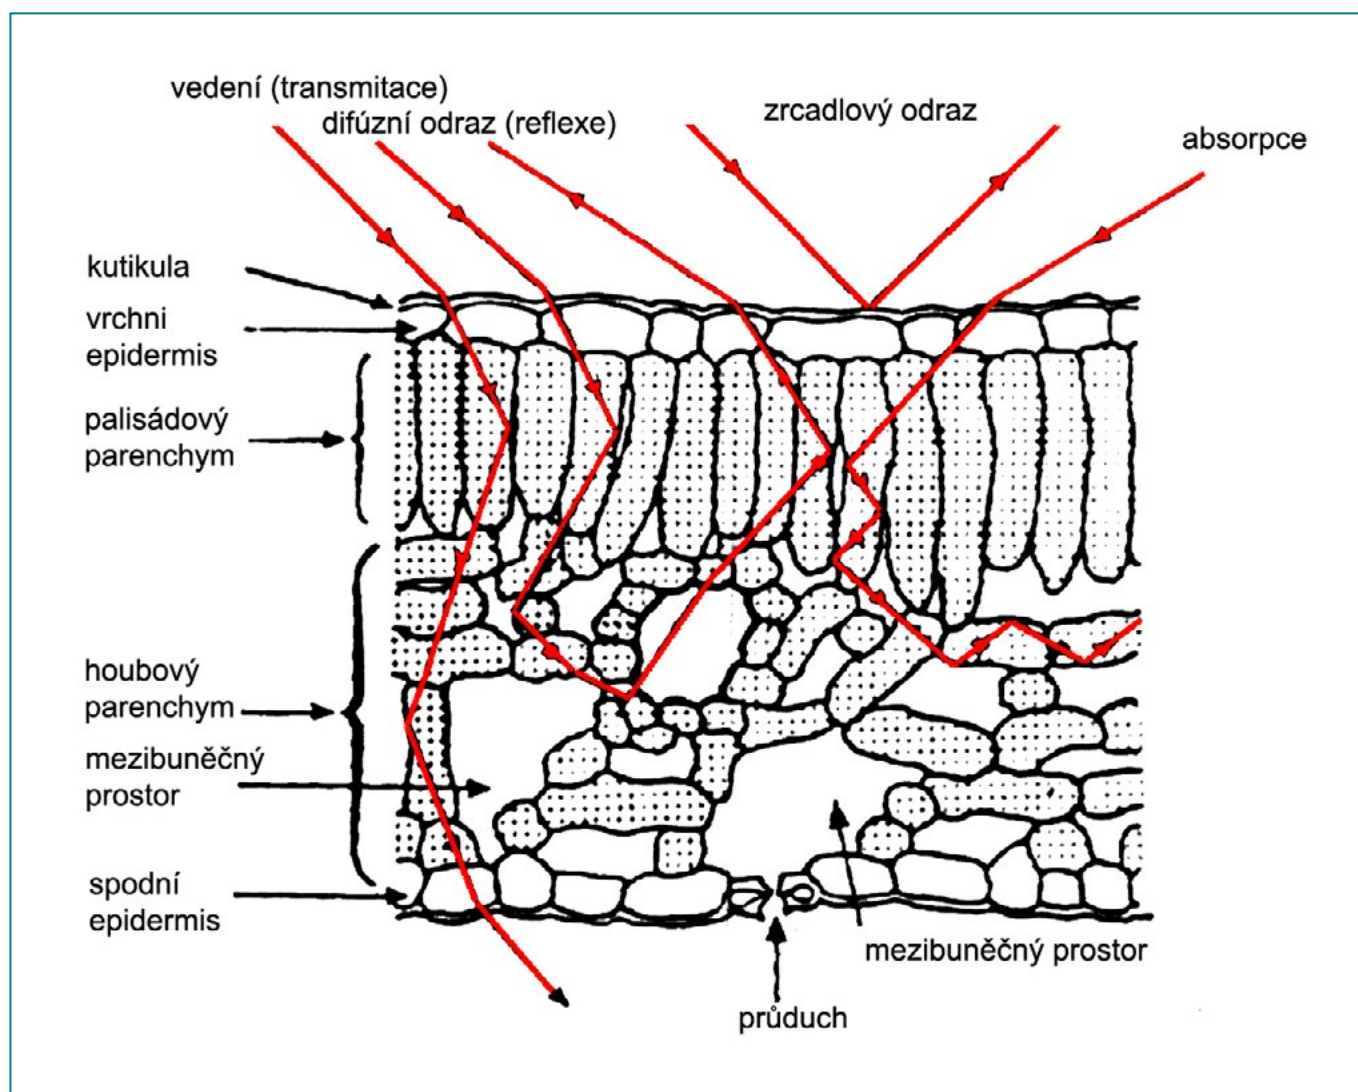
Podle toho se průběh odrazivosti vegetace dělí do tří oblastí – oblast pigmentové absorpce, oblast buněčné struktury a oblast vodní absorpce.

Oblast pigmentové absorpce odpovídá oblasti viditelného záření. Spektrální chování listů je ovlivněno zejména rostlinnými pigmenty. Záření je pohlcováno zejména v modrém a červeném spektru chlorofylem a (430/660 nm) a chlorofylem b (450/640 nm). Takto získaná energie ve formě fotonů vstupuje do fotosyntetických reakcí. Oblast zeleného spektra (kolem 550 nm) je absorbována mnohem méně, což je příčinou zelené barvy rostlin ve vegetačním období. Kromě chlorofylů ovlivňují spektrální chování listů i další rostlinná barviva jako např. karotenoidy a xantofyly. Poměr těchto látek v listech v průběhu vegetace pak způsobuje změny spektrální křivky a tím i barvy listů. Např. při stárnutí listů dochází k rychlejšímu odbourávání chlorofylu než karotenoidů, což se projevuje žlutou barvou. Podobně odumírání je doprovázeno vznikem hnědých barviv, které ovlivňují barvu listů.

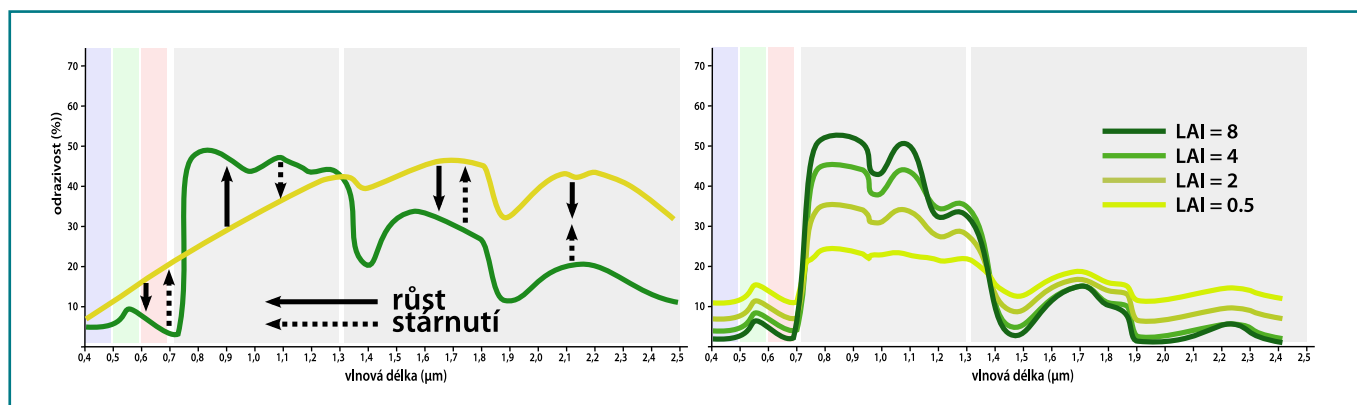
Oblast buněčné struktury je svázána s blízké infračerveným (NIR) spektrem. Hlavním faktorem ovlivňujícím



Obrázek 15: Spektrální křivka odrazivosti vegetace



Obrázek 16: Schématické znázornění interakcí záření na list (Heleborus niger) (Lilienthal, 2003)



Obrázek 17: Změny spektrální křivky vegetace (podle Lilienthal, 2003): (a) v průběhu růstu a stárnutí rostlin, (b) ovlivněno rozdílným množstvím biomasy porostu – indexem listové pokryvnosti (LAI).

odrazivost v této části spektra je morfologická struktura listu. V oblasti vlnových délek 750–780 nm dochází k prudkému nárůstu odrazivosti zhruba na 50 %. Tento jev je nazýván **red-edge** a je typický pro zelené části rostlin. Vysokou odrazivost způsobuje vzduch v rostlinném parenchymu, neboť po infiltraci listů různými tekutinami (voda, olej) byl zřetelný úbytek reflektanci v NIR. Rozdílu v odrazivosti mezi viditelnou částí a NIR je využíváno při rozpoznávání vegetace od ostatních objektů a její kvantifikace pomocí vegetačních indexů. Odlišnosti listové struktury mezi rostlinnými druhy, případně změny v průběhu vegetačního období, se projevují i mírnými rozdíly v odrazivosti, čehož lze využít při rozlišování druhové skladby rostlinných porostů nebo určení vývojového stádia.

V oblasti vodní absorpce (1 300–3 000 nm) je spektrální odrazivost formována absorpčními pásy vody. Vyšší obsah vody v rostlinných pletivech přitom vede ke snížení odrazivosti, neboť voda pohlcuje MIR záření. Při usychání listů dochází k úbytku vody a tím i ke zvýšení odrazivosti. S vazbou na základní metabolické procesy rostlin se změna obsahu vody projevuje na odrazivosti i v ostatních spektrálních oblastech.

Na multispektrálním snímku, který zahrnuje viditelnou a blíže infračervenou část elektromagnetického spektra, se vegetace bude v modré a červené části jevit jako velmi tmavá až černá, v zeleném šedá a v NIR bude světlá až bílá. Takto je popsána zdravá vegetace, rostliny trpící stresem (nebo stárnoucí) vykazují změny odrazivosti – přibývá odrazivost v červeném spektru (žloutnoucí listy) a naopak se snižuje odrazivost v NIR (obrázek 17). Spektrální měření dokáže poměrně spolehlivě detekovat porostní rozdíly (nedostatečná výživa, vodní stres, napadení rostlin), obvykle ale není schopno určit přesnou příčinu identifikovaného stresu. V precizním zemědělství je potenciál dálkového průzkumu nejvíce využíván pro diagnostiku výživného stavu rostlin, detekce stresu rostlin či predikci výnosu zemědělských plodin; z hlediska pěstebních zásahů se jedná o oblast variabilní aplikace hnojiv, v menší míře také pro aplikaci regulátorů růstu a fungicidní ochranu rostlin.

5 VEGETAČNÍ A JINÉ SPEKTRÁLNÍ INDEXY


Struktura a fyziologie porostu či jednotlivých rostlin ovlivňují jejich spektrální odrazivost, tedy množství odraženého záření. Snímky zobrazené ve viditelné části spektra (RGB) mohou poskytnout pouze omezenou informaci o stavu porostu. K tomu, abychom zjistili i to, co není detekovatelné pouhým okem, je potřeba využít kombinace jednotlivých spektrálních pásem dané datové sady v předem definovaném tvaru. Takovýmto kombinacím pásem se říká spektrální či vegetační indexy.

Spektrální indexy se mohou dělit podle různých kritérií. Jedním z nich je členění na dvě skupiny podle tvaru matematické operace, na tzv. poměrové indexy a tzv. ortogonální indexy (Dobrovolný, 1998). Další kritérium, podle kterého lze dělit spektrální indexy, je počet a rozsah pásem vstupujících do procesu a jejich účel využití. Tímto způsobem (např. www.harrisgeospatial.com) jsou indexy sloučeny do sedmi základních kategorií na:

- širokopásmové indexy (*Broadband Greeness*)
- úzkopásmové indexy (*Narrowband Greeness*)
- indexy hodnotící využití světla (*Light use efficiency*)
- indexy hodnotící celkový obsah dusíku v porostu (*Canopy nitrogen*)
- indexy hodnotící množství uhlíku (*Dry or Senescent Carbon*)
- indexy hodnotící obsah pigmentů v listech (*Leaf Pigments*)
- indexy hodnotící obsah vody v porostu (*Canopy Water Content*)

Každý z indexů hodnotí určité vlastnosti porostu, které jsou dány vlnovou délkou a rozsahem všech pásem, které vstupují do výpočtu. Je vždy na zpracovateli, který index si pro své hodnocení vybere. Zde je pak nutno brát v potaz, že každý index se hodí pro jiné hodnocení vlastností porostů. Tento fakt je podpořen i unikátními vlastnostmi stanoviště, kde jsou vybrané porosty hodnoceny. Do výsledné interpretace by se tedy měly zahrnout i všechny vnější vlivy, které mohou výsledek výpočtu ovlivnit. Z tohoto důvodu není vhodné striktně porovnávat výsledky výpočtů u různých pozemků, byť byl pro výpočet použit stejný index. Z unikátních vlastností každého pozemku či plodin vyplývá i cílené použití indexu. Tak jako se jeden index hodí pro výpočet vlastností určitých plodin, tak se pak nemusí hodit pro zjištění vlastností sledovaných porostů jiných plodin. To stejné platí i u fenologických fází, kdy např. může při raných fázích prosvítat půda, která může ovlivnit výsledek výpočtu. Je tedy vždy na zkušenosti a citlivém uvážení zpracovatele, který index použije.

Každému výpočtu spektrálních indexů by mělo předcházet kvalitně provedené předzpracování obrazu, zejména atmosférické korekce na úroveň hodnot odrazivosti povrchu. Jedině tak lze dosáhnout jasně vypovídajících výsledků. V následujícím přehledu indexů náležícím k dané kategorii budou zmíněny jen ty, které se dají využít a zpravidla se využívají v zemědělské praxi.



Obrázek 18: Základní princip využití spektrálních indexů a různá odrazivost v různých částech spektra

5.1 ŠIROKOPÁSMOVÉ INDEXY (BROADBAND GREENESS)

Širokopásmové indexy se vypočítají jako jednoduchý poměr pásem s určitou vlnovou délkou. Zpravidla měří všeobecnou kvalitu a vitalitu zelené vegetace v závislosti na fotosyntetických vlastnostech rostlin. Vybraná spektrální pásma v daných poměrech jsou citlivá na různé kombinované vlastnosti porostu, jako jsou např. obsah chlorofylu, velikost listové plochy, struktura či hustota porostu. Tento typ indexů zpravidla využívá vysokou odrazivost ve vlnových délkách, které odpovídají pásmu GREEN a NIR a absorpci elektromagnetického záření (např. v pásmu RED či BLUE). Zvýšení koncentrace chlorofylu v listech, zvětšení plochy listů nebo změny v povrchové struktuře porostu mohou přispět ke zvýšení hodnot odrazivosti NIR pásma a zároveň snížení hodnot v RED pásmu, což vede k výslednému zvýšení hodnot těchto širokospektrálních indexů. Kombinace zmíněných spektrálních pásem je natolik účinná, že je lze použít i u takových senzorů, které mají rozsah vlnových délek daných pásem poměrně široký (např. u družic Sentinel 2 či řady Landsat). Aplikace těchto typů indexů lze použít např. pro odhad stavu porostu během sledovaných fenologických fází, rozlišení čeledi či odrůdy, využití krajiny a jiné).

Vzhledem k tomu, že mnoho popsaných spektrálních indexů nemá český překlad a zpravidla se užívá zkratka, která vyplývá z jejich původního názvu, bude pak tento název uveden v anglickém jazyce. U výjimek bude uveden i název český.

Difference Vegetation Index (DVI)

$$DVI = NIR - Red$$

Tento index je vhodný pro rozlišení půdy a vegetace, ale nebere v potaz rozdíly mezi spektrální odrazivostí (reflektancí) a zářením (radiancí) způsobenými vlivy atmosféry nebo stíny (Tucker 1979).

Enhanced Vegetation Index (EVI)

$$EVI = 2,5 \times \frac{(NIR - Red)}{(NIR + 6 \times Red - 7,5 \times Blue + 1)}$$

EVI zpravidla vylepšuje informaci získanou již z NDVI indexu (viz dále). Optimalizuje odrazivost vegetace na úrovni

listové plochy tím, že používá modrou část spektra pro korekci signálu, který může být ovlivněn odrazivostí půdy. Tento index by měl také snížit vliv atmosféry, včetně rozptýlu záření vlivem aerosolů (Huete et al. 2002).

Green Difference Vegetation Index (GDVI)

$$GDVI = NIR - Green$$

Tento index byl původně odvozen pro odhad obsahu dusíku v porostech kukuřice při využití barevných infračervených snímků (Sripada et al. 2006).

Green Normalized Difference Vegetation Index (GNDVI)

$$GNDVI = \frac{NIR - Green}{NIR + Green}$$

Tento index je podobný NDVI indexu. Rozdíl spočívá v tom, že měří odrazivost v zelené části spektra v rozsahu vlnových délek 540 až 570 nm namísto červené části spektra. Tímto se index stává mnohem citlivějším k obsahu chlorofylu (Gitelson & Merzylak 1998). Z toho důvodu je velmi často využíván jako indikátor obsahu chlorofylu či dusíku v porostech.

Leaf Area Index = Index listové plochy (LAI)

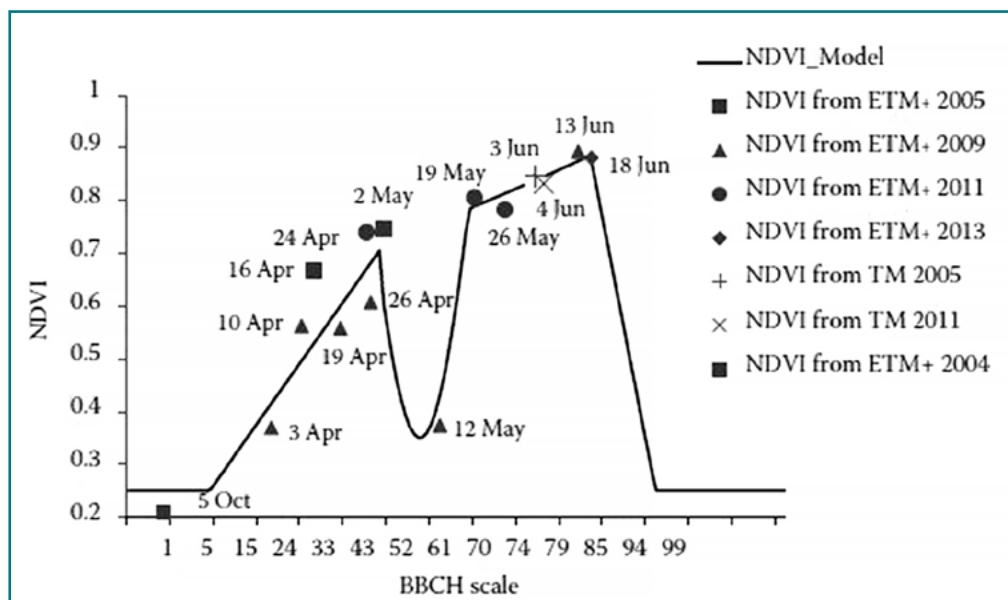
$$LAI = 3,618 \times EVI - 1,118$$

Kde EVI = hodnoty Enhanced Vegetation indexu. Tento index se používá k odhadu plochy listů a pro předpověď růstu a výnosu plodin (Boegh et al. 2002).

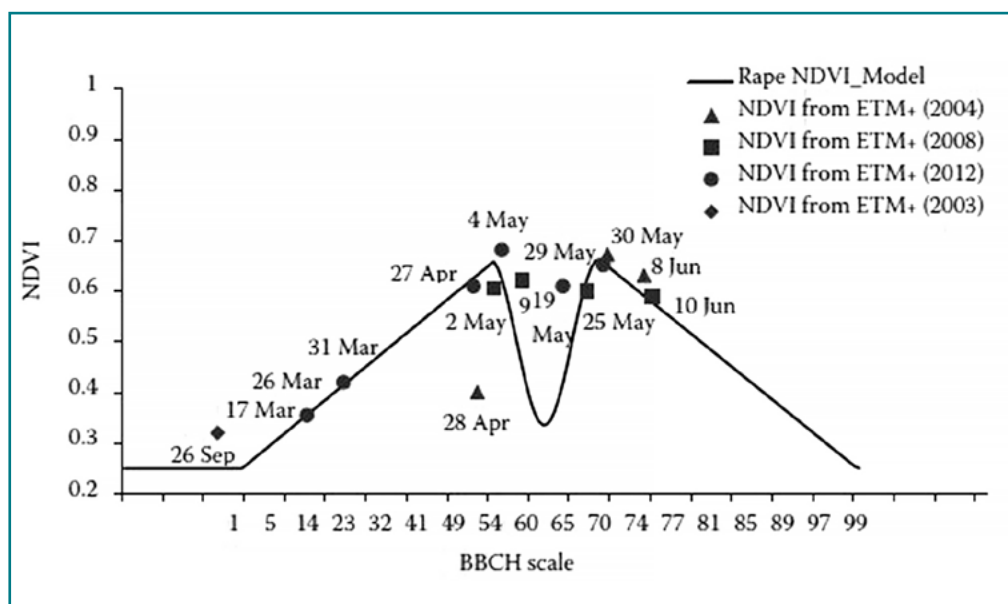
Normalized Difference Vegetation Index = Normalizovaný diferenční vegetační index (NDVI)

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Tento index je měřítkem zdravé, zelené vegetace. NDVI je obecně nejvyužívanějším indexem. Nevýhodou je, že při vysokých hodnotách listové plochy hustého porostu může dojít k tzv. efektu saturace. To znamená, že index již nedokáže při vysokých hodnotách spolehlivě odlišit



Obrázek 19: Vývoj hodnot NDVI v závislosti na fenologické fázi porostu pšenice ozimé podle stupnice BBCH. Vysvětlivky: *Oct* = říjen; *Apr* = duben; *May* = květen; *Jun* = červen; TM = senzor *Thematic Mapper* družice *Landsat 5*; ETM+ = senzor *Enhanced Thematic Mapper+* družice *Landsat 7*; Zdroj: Domínguez et al. 2015



Obrázek 20: Vývoj hodnot NDVI v závislosti na fenologické fázi porostu řepky ozimé podle stupnice BBCH. Vysvětlivky: *Sep* = září; *Mar* = březen; *Apr* = duben; *May* = květen; *Jun* = červen; ETM+ = senzor *Enhanced Thematic Mapper+* družice *Landsat 7*; Zdroj: Domínguez et al. 2015

detailní rozdíly. Nespornou výhodou je však jeho velmi časté využití pro různé druhy porostů. Vývoj hodnot pro různé druhy plodin a situací jsou zpravidla dohledatelné v odborné literatuře. Výsledné hodnoty jsou v rozsahu od -1 do 1. Běžný rozsah hodnot zelené vegetace je od 0,2 do 0,8 (Rouse et al., 1973). Hodnoty 0,2 (0,25) a nižší již zpravidla odpovídají holé půdě. Domínguez et al. (2015) publikovali průměrný vývoj hodnot NDVI indexu na příkladu pšenice a řepky ozimé pěstované v běžných podmínkách agronomické praxe ČR na pozemku Výzkumného ústavu rostlinné výroby, v.v.i. v Praze – Ruzyni (obrázek 19 a 20). Pro modelování grafu vývoje hodnot byly využity snímky z družic *Landsat 5* a *7* v časové řadě let 2004 až 2013.

Výhodou snímků z družic *Landsat* je vzájemná návaznost jednotlivých vývojových typů, a také porovnatelnost se snímky z družice *Sentinel 2*.

Tak, jako se liší vybrané plodiny v závislosti na příslušném řádu, kam plodiny náleží, tak se liší i grafy vystihující vývoj NDVI během jejich růstu. Křivky u obou modelů začínají na hodnotě 0,25, což je hodnota NDVI holé půdy sledovaného pozemku. Hodnoty NDVI u pšenice ozimé poté rostou až do fenologické fáze BBCH 49, kdy se začínají objevovat osiny. Poté začnou hodnoty NDVI prudce klesat vlivem snížené odrazivosti během metání a kvetení. Pokles hodnot je způsoben změnou struktury a barvy

Tabulka 2: Přehled vybraných tzv. RGB indexů

RGB spektrální index	Algoritmus	Reference
Green Percentage Index	$G\% = \frac{Green}{Red + Green + Blue}$	Richardson et al. (2007)
Excess Green	$ExG = 2 \times Green - Red - Blue$	Woebbecke et al. (1995)
Green Leaf Index	$GLI = \frac{(Green - Red) + (Green - Blue)}{2 \times Green + Red + Blue}$	Gobron et al. (2000); Hunt et al. (2013)
Visible Atmospherically Resistant Index	$VARI = \frac{Green - Red}{Green + Red - Blue}$	Gitelson et al. (2002)
Normalised Green Red Difference Index	$NGRDI = \frac{Green - Red}{Green + Red}$	Falkowski et al. (2005); Gitelson et al. (2002); Kawashima & Nakatani (1998); Tucker (1979)
Triangular Greenness Index	$TGI = Green - 0,39 \times Red - 0,61 \times Blue$	Hunt et al. (2013)

na povrchu porostu. Po ukončení fáze kvetení (BBCH 69) opět hodnoty NDVI rostou až do fáze BBCH 80 – dozrávání, kdy se mění barva porostu ze zelené na žlutou a odrazivost porostu opět začne klesat. Tento vývoj je v souladu se studii autorů Li et al. (2015) a Franch et al. (2015). Hodnoty NDVI u řepky ozimé rostou do fenologické fáze BBCH 60 – počátek kvetení. Zde dochází ke změně barvy ze zelené na žlutou a logicky se tak snižuje spektrální odrazivost povrchu porostu. Během této fáze může dojít k výkyvům hodnot NDVI, které mohou být způsobeny nestejným vývojem rostlin. Některé rostliny mohou být již v květu a některé ne. Tento případ se může objevit především na sklonitých pozemcích. Po odkvětu začne hodnota NDVI zase stoupat do fáze zrání, kdy se opět mění barva a hodnoty NDVI poté začnou opět klesat. Popsaný vývoj hodnot NDVI porostu řepky ozimé je v souladu i s autory Pan et al. (2013) nebo Zhu et al. (2008). Na základě modelů odhadů vývoje byl spočítán koeficient determinace mezi vytvořenými modely a reálnými NDVI hodnotami vypočítanými z družicových snímků. Pro řepku ozimou byl koeficient determinace 0,77; pro pšenici ozimou pak 0,93. Tyto hodnoty platí pro hladinu významnosti 0,05. Rozdíly mezi reálným stavem porostu a modely byly zjištěny např. i autory Jongschaap a Schouten (2005). Tito autoři připisují zjištěné rozdíly především různým obhospodařováním pozemků, jinými půdními podmínkami či odlišnými aplikacemi hnojiv.

Soil Adjusted Vegetation Index (SAVI)

$$SAVI = \frac{1,5 \times (NIR - Red)}{NIR + Red + 0,5}$$

Tento index je podobný NDVI indexu, přičemž potlačuje vliv půdy. Používá vyrovnávací faktor L, který je funkcí hustoty vegetace a často také vyžaduje znalosti o stavu vegetace. Huete (1988) navrhl optimální hodnotu L = 0,5.

SAVI je nevhodnější použít pro porosty s řídkou vegetací, kde prosvítá půda.

Optimized Soil Adjusted Vegetation Index (OSAVI)

$$OSAVI = \frac{1,5 \times (NIR - Red)}{NIR + Red + 0,16}$$

Tento index vychází ze SAVI indexu. Využívá standardní hodnotu 0,16 pro eliminaci vlivu půdy. Rondeaux (1996) zjistil, že tato hodnota poskytuje zvýšenou citlivost na vegetační pokryv větší než 50 %. Tento index je nevhodnější na hodnocení řídké vegetace, kde půda prosvítá porostem.

Simple Ratio (SR)

$$SR = \frac{NIR}{Red}$$

Tento index je poměrem vlnové délky s největší odrazivostí a vlnové délky s největší absorpcí. Index je vhodný použít na široké spektrum podmínek a oblastí. Stejně jako u NDVI indexu může dojít k jeho nasycení, a to při velmi vysoké hodnotě listové plochy LAI (Birth a McVey 1968).

5.1.1 Indexy využívající pásma ve viditelné části spektra (tzv. RGB indexy)

RGB indexy (viz tabulka 2) se zpravidla používají v případech, kdy je k dispozici jen kamera nedisponující jinými pásmy, než ve viditelné části spektra (běžná levná kamera). Indexy se mohou využít jako indikátory obsahu chlorofylu v listech či pro oddělení zelené plochy porostu od ostatního povrchu, např. pro účely výpočtu objemu či plochy porostu.

5.2 ÚZKOPÁSMOVÉ INDEXY (NARROWBAND GREENESS)

Stejně jako širokopásmové indexy jsou úzkopásmové indexy založeny na kombinaci spektrálních pásem. Rozdíl je v šířce spektrálních pásem, která vstupují do výpočtu. Zatímco u širokospektrálních indexů lze pracovat se širokými rozsahy vlnových délek zpravidla označenými názvem pásma (RED, NIR atd.), u úzkopásmových indexů vstupují do výpočtů pásma úzká, která jsou zpravidla označena středem vlnové délky. Úzkopásmové indexy jsou vhodné pro detekci konkrétních změn či stavů vegetace, kde by širokopásmové indexy nemohly dostatečně posloužit. Z tohoto důvodu tento typ indexů nachází široké uplatnění v precizním zemědělství. Velmi využívanou vlnovou délkou se pak stává ta, která spadá do oblasti tzv. red-edge. Tato oblast odpovídá nárůstu odrazivosti záření v rozsahu vlnových délek 690 až 740 nm.

Zmíněné indexy najdou spíše uplatnění ve výpočtech u snímků z družice Sentinel 2, především díky většímu počtu spektrálních pásem. Ve většině případů jsou určeny pro hyperspektrální snímky. Následující přehled uvádí nepoužívanější indexy.

Modified Red Edge Normalized Difference Vegetation Index (MRENDVI)

$$MRENDVI = \frac{R_{750} - R_{705}}{R_{750} + R_{705} - 2 \times R_{445}}$$

R = odrazivost (reflectance); 705 = střed vlnové délky

Tento index je modifikací Red Edge NDVI indexu. Využívá citlivost vegetace na vlnové délky odpovídající pásmu red-edge k malým změnám ve struktuře listů či stárnutí rostlin. Aplikace tohoto indexu je významná v oblasti precizního zemědělství, monitoringu lesů, a detekci stresu rostlin. Výsledné hodnoty jsou v rozsahu od -1 do 1. Běžné hodnoty zelené vegetace jsou v rozsahu od -0,2 do 0,7 (Datt 1999 Sims & Gamon 2002).

Modified Red Edge Simple Ration (MRESR)

$$MRESR = \frac{R_{750} - R_{445}}{R_{705} + R_{445}}$$

Tento index je modifikací širokopásmového indexu Simple Ratio (SR). Používá pásma z oblasti red-edge. Hodí se zejména pro využití v oblasti precizního zemědělství, monitorování lesů a detekci stresu vegetace. Výsledné hodnoty jsou v rozsahu od 0 do 30. Běžné hodnoty zelené vegetace jsou v rozsahu od 2 do 8 (Datt 1999, Sims & Gamon, 2002).

Red Edge Normalized Difference Vegetation Index (RENDVI)

$$RENDVI = \frac{R_{750} - R_{705}}{R_{750} + R_{705}}$$

Tento index vychází z tradičního NDVI indexu a je jeho modifikací. Nejvhodnější využití spadá do oblasti precizního zemědělství a detekce stresu vegetace. Jeho efektivita spočívá v zařazení vlnových délek spadajících do red-edge oblasti namísto vlnových délek, které odpovídají maximální hodnotě odrazivosti a absorpci (NIR a RED). Takto je schopen detekovat drobné změny ve stavu vegetace. Výsledné hodnoty jsou v rozsahu od -1 do 1. Běžné hodnoty zelené vegetace jsou v rozsahu od 0,2 do 0,9 (Gitelson & Merzlyak 1994, Sims & Gamon, 2002).

Triangular Vegetation Index (TVI)

$$TVI = 0,5 \times [120 \times (R_{750} - R_{550}) - 200 \times (R_{670} - R_{550})]$$

Tento index je vypočten jako plocha hypotetického trojúhelníku spektra, který spojuje největší odrazivost v zeleném pásmu, minimální hodnoty absorpce chlorofylem a NIR pásmo. TVI index je dobrým prediktorem plochy listů (LAI), přičemž jeho citlivost na chlorofyl se zvyšuje s nárůstem hustoty porostu (Broge & Leblanc 2000).

5.3 INDEXY HODNOTÍCÍ VYUŽITÍ SVĚTLA (LIGHT USE EFFICIENCY)

Tato skupina indexů popisuje účinnost, s níž může vegetace využívat dopadající záření (světlo) pro procesy fotosyntézy. Využívání tohoto záření je úzce spjato s využitím uhlíku a kvalitou růstu rostlin a částečně také souvisí s frakční absorpcí fotosynteticky aktivní radiace (fAPAR). Tyto indexy mohou pomoci odhadnout stav růstové fáze a výnosnost. Uplatňují se především v oblasti precizního zemědělství. Jelikož se jedná o velmi specifické indexy, opět je zde uveden jen příklad.

Structure Intensive Pigment Index (SIPI)

$$SIPI = \frac{R_{800} - R_{445}}{R_{800} + R_{680}}$$

Tento index je maximálně citlivý na poměr karotenoidů (např. alfa-karoten či beta-karoten) vůči chlorofylům, přičemž se snižuje citlivost na zachycení změny ve struktuře porostu (např. LAI). Zvyšující se hodnota tohoto indexu znamená zvyšující se stres porostu. Index se využívá především v oblasti monitoringu zdravotního stavu vegetace, stresu rostlin a analýzy výnosů. Výsledné hodnoty jsou v rozsahu od 0 do 2. Běžné hodnoty zelené vegetace jsou v rozsahu od 0,8 do 1,8 (Penuelas et al. 1995).

5.4 INDEXY HODNOTÍCÍ CELKOVÝ OBSAH DUSÍKU V POROSTU (CANOPY NITROGEN)

Tato skupina indexů poskytuje informaci o obsahu dusíku v porostu. Dusík je důležitou složkou chlorofylu a obecně je v zelené, rostoucí vegetaci přítomen ve vysoké koncentraci. Pro odhad dusíku se velmi často používají širokopásmové indexy, které pracují se zelenou složkou spektra.

Normalized Difference Nitrogen Index (NDNI)

$$NDNI = \frac{\log\left(\frac{1}{R_{1510}}\right) - \log\left(\frac{1}{R_{1680}}\right)}{\log\left(\frac{1}{R_{1510}}\right) + \log\left(\frac{1}{R_{1680}}\right)}$$

Tento index je určen k odhadu relativního množství dusíku v porostu. Odrazivost v oblasti vlnových délek 1510 nm je do značné míry určována koncentrací dusíku v listech, stejně jako celkovou listovou biomasou porostu. Tato odrazivost je srovnávána s referenční odrazivostí ve vlnových délkách 1680 nm, která by měla zajišťovat podobné vlastnosti díky listové biomase, avšak bez vlivu absorpce dusíku. NDNI je spíše experimentální index. Vykazuje silnou citlivost na měnící se obsah dusíku v růstových fázích, když je porost zelený (nikoliv při dozrávání) a je dobře zapojen. Využívá se pro účely precizního zemědělství, analýzy ekosystémů a management lesa (Fourty et al. 1996, Serrano et al. 2002).

5.5 INDEXY HODNOTÍCÍ MNOŽSTVÍ UHLÍKU (DRY OR SENESCENT CARBON)

Tato skupina indexů poskytuje odhad množství uhlíku v ligninu a celulóze v suchém stavu. Lignin je stavební složkou rostlin zajišťující jejich nosnou konstrukci. Celulóza je rostlinný polysacharid, který je součástí stěn rostlinných buněk. Molekuly uhlíku jsou přítomny ve velkém množství v dřevěných materiálech a ve zralé (nebo mrtvé či spící) vegetaci. Tyto materiály jsou v podmínkách sucha vysoce hořlavé. Při stárnutí vegetace je možné detekovat jejich zvyšující se množství. Tyto indexy je možné využít pro stanovení hořlavosti či ohrožení vegetace požárem; zároveň nejsou vhodné pro snímání mokrých povrchů nebo pro detekci suchého materiálu, který je zakryt zeleným porostem.

Cellulose Absorption Index (CAI)

$$CAI = 0,5 \times (R_{2000} + R_{200}) - R_{2100}$$

Tento index indikuje exponované plochy, které obsahují suchý rostlinný materiál. Absorpce v rozmezí vlnových délek 2000 nm až 2200 nm je citlivá na obsah celulózy. Index se využívá pro monitorování rostlinných zbytků, senescence rostlin, management pastvin či pro detekci ohrožení požárem. Výsledné hodnoty jsou v rozsahu od -3 do 4. Běžné hodnoty zelené vegetace jsou v rozsahu od -2 do 4 [Daughtry 2001, Daughtry et al. 2004].

Plant Senescence Reflectance Index (PSRI)

$$PSRI = \frac{R_{680} - R_{500}}{R_{750}}$$

Tento index maximalizuje citlivost na poměr obsahu karotenoidů (alfa-karoten, beta-karoten) k obsahu chlorofylu. Zvýšení hodnoty PSRI indexu naznačuje zvýšení stresového zatížení rostlin či nástup stárnutí a zrání porostu. Využívá se pro detekci zdravotního stavu rostlin, zjišťování fyziologického stresu rostlin či analýzu výnosů. Výsledné hodnoty jsou v rozsahu od -1 do 1. Běžné hodnoty zelené vegetace jsou v rozsahu od -0,1 do 0,2 [Merzlyak et al. 1999].

5.6 INDEXY HODNOTÍCÍ OBSAH PIGMENTŮ V LISTECH (LEAF PIGMENTS)

Tato skupina indexů poskytuje odhad množství stresových pigmentů, které jsou přítomny ve vyšších koncentracích v napadené vegetaci. Tyto indexy nejsou měřítkem obsahu chlorofylu.

Anthocyanin Reflectance Index 1 (ARI1)

$$ARI1 = \frac{1}{R_{550}} - \frac{1}{R_{700}}$$

Anthocyaniny jsou pigmenty rozpustné ve vodě; jsou také zastoupeny ve větším množství v mladých či ve starých listech. Oslabená vegetace obsahuje vyšší koncentrace anthocyaninů, proto je tento index jedním z měřítek stresu vegetace. Zvýšení hodnot ARI1 indexu indikuje změnu v porostu, která může znamenat buď přírůstek nových listů, nebo naopak jejich stárnutí [Gitelson et al. 2001].

Carotenoid Reflectance Index 1 (CRI1)

$$CRI1 = \frac{1}{R_{510}} - \frac{1}{R_{550}}$$

Funkce karotenoidů je zajištění absorpce světla v rostlinách pro podporu fotosyntetických procesů. Stejně tak mohou sloužit jako ochrana proti škodlivým účinkům radiace na rostliny. Oslabená vegetace obsahuje vyšší koncentraci karotenoidů, proto je tento index jedním z měřítek stresu vegetace. Vyšší hodnoty CRI1 indexu znamenají vyšší koncentraci karotenoidů v porovnání s chlorofylem. Výsledné hodnoty jsou v rozsahu od 0 do 15. Běžné hodnoty zelené vegetace jsou v rozsahu od 1 do 12 [Gitelson et al. 2002].

Oba indexy mají své vylepšené modifikace.

5.7 INDEXY HODNOTÍCÍ OBSAH VODY V POROSTECH (CANOPY WATER CONTENT)

Tato skupina indexů poskytuje odhad množství vody obsažené v listech. Voda je důležitý kvalitativní parametr, protože se zvyšujícím se obsahem vody v porostu se zlepšuje nejen jeho kondice, ale porost je také více odolný vůči požárům. Tato skupina indexů dává zpravidla do poměru pásma NIR a SWIR.

Moisture Stress Index (MSI)

$$MSI = \frac{R_{1599}}{R_{819}}$$

Tento index je citlivý vůči zvyšujícímu se obsahu vody v listech. Se zvyšujícím se obsahem vody v listech roste i absorpce EM záření kolem vlnové délky 1599 nm. Absorpce kolem vlnové délky 819 nm je téměř neovlivněná, proto slouží jako reference. MSI index slouží pro detekci stresu nedostatkem vody, je dobrým prediktorem výnosnosti a obecně slouží pro modelování stavu porostu, analýzu ohrožení požárem a studie zabývající se fyziologií ekosystémů. MSI index je inverzní k ostatním indexům, které hodnotí obsah vody. Vysoké hodnoty indikují větší vodní stres a menší obsah vody. Výsledné hodnoty jsou v rozsahu od 0 do 3. Běžné hodnoty zelené vegetace jsou v rozsahu od 0,4 do 2 [Ceccato et al. 2001, Hunt a Rock 1989].

Velmi často se také používá modifikace tohoto indexu známá jako Enhanced MSI (EMSI). Tento index pak používá namísto tzv. SWIR1 pásma (R1610) např. při použití snímku z družice Sentinel 2 SWIR2 pásmo (R2190), tedy delší vlnovou délku.

Normalized Difference Water Index (NDWI)

$$NDWI = \frac{R_{857} - R_{1241}}{R_{857} + R_{1241}}$$

Tento index je citlivý na změny obsahu vody v porostu. Vlnové délky 857 nm a 1241 nm mají mírně rozdílné vlastnosti v absorpci vody. Index je vhodný pro analýzu obsahu vody v porostech, analýzu LAI v hustých porostech, modelování výnosnosti a analýzy výskytu požárů. Výsledné hodnoty jsou v rozsahu od -1 do 1. Běžné hodnoty zelené vegetace jsou v rozsahu od 0,1 do 0,4 [Gao 1995].



6 DPZ SYSTÉMY VHODNÉ PRO POUŽITÍ

Senzory, které jsou schopné pořizovat data v různých spektrálních pásmech jsou umístěna na tzv. nosičích, tedy platformách, které zajišťují pohyb senzoru a jeho polohovou konfiguraci. V závislosti na potřebách snímání, váze a povaze senzoru mohou být tato zařízení umístěna na různých nosičích od statických (jeřáb, lešení) či pohybujících se platformou (zemědělská technika) na zemském povrchu, drony, letadla až po umělé družice na oběžné dráze Země, tedy satelity. Nosič a senzor (či více senzorů) umístěný na nosiči spolu tvoří systém, jehož konfigurace a vlastnosti určují, jak je možné daný systém využít pro konkrétní aplikace. V tomto ohledu se nejedná pouze o spektrální charakteristiky, ale také například o citlivost senzorů, dráhu letu, geometrii snímání (z jaké výšky, z jakého úhlu), čas pro pořízení záznamu (u dronů např. výdrž baterií pro let), u satelitních systémů doba návratu nad stejné místo na povrchu, zda je pořizování záznamu kontinuální či jakým způsobem jsou pořízená data distribuována (komerčně či volně dostupná) apod. Všechny tyto aspekty je třeba vážit při výběru vhodného systému pro pořízení zájmových dat, tedy zda daný systém splňuje požadavky na dané použití.

6.1 SATELITNÍ SYSTÉMY

Obecně zřejmě nepoužívanějšími daty v rámci DPZ jsou tradičně družicová, respektive satelitní data. Nosiče, kterými jsou umělé družice Země se pro potřeby DPZ pohybují po kruhových drahách kolem Země. Tzv. geostacionární družice jsou umístěny na geostacionární dráze ve výšce cca 36 000 km nad zemským povrchem, což umožňuje synchronizaci jejich rotace s rotací Země a tyto družice tak mohou být umístěny nad daným místem nad povrchem Země. Jejich výhodou je velké časové rozlišení, kdy mohou snímat v podstatě neomezeně, ale jejich nevýhodou je malé prostorové rozlišení. Tyto systémy jsou tak používány hlavně pro meteorologické účely, jako např. družice z rodiny Meteosat. Pro aplikace DPZ jsou však vhodněji využitelné systémy, které jsou umístěny na tzv. subpolárních drahách ve výšce cca 700–1 000 km nad povrchem Země. Tyto družice obíhají Zemi v polárníkové směru přes zemské póly a jejich oběh je

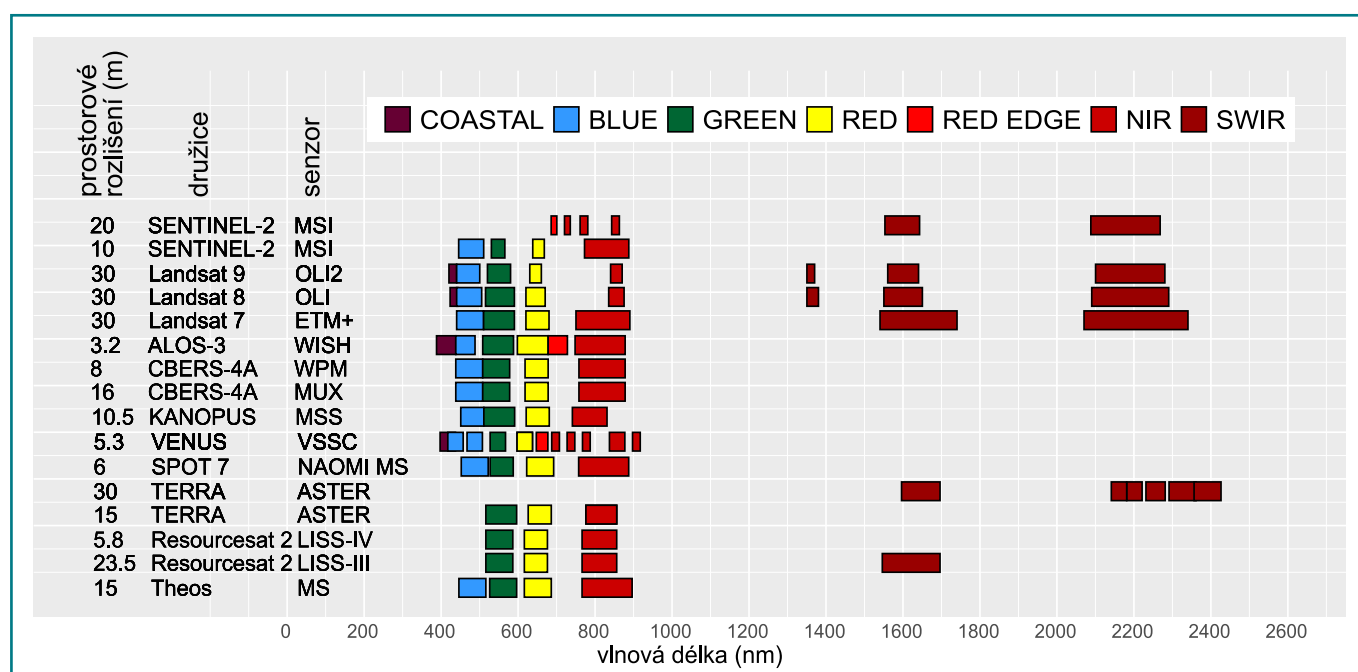
většinou nastaven tak, aby byl synchronizován se Sluncem (tzv. heliosynchronní dráha), tzn. aby přelet daného místa družicí byl vykonán ve stejnou denní dobu. To umožňuje pořizovat sběr dat v nejvhodnější okamžiky dne. Nastavení systému pak definuje i dobu za jakou je možné dané místo na povrchu Země nasnímkovat, což je dáno jednak drahou družice, tak zorným úhlem senzoru. Vliv má ale také zeměpisná šířka, ve které je záznam pořizován, neboť čím blíže k pólům, tím větší překryv jednotlivých drah snímání a tím větší pravděpodobnost pořízení záznamu. Vylepsit tuto dobu je ještě možné prostřednictvím konstelace více satelitů se stejnými parametry. V případě využití dvou satelitů, tak může být doba návratu zkrácena na polovinu. Doba návratu se tak může pohybovat v řádu hodin (např. 6 hodin u meteorologické družice NOAA) až dní (16 dní u družice Landsat 8 či 5 dní u konstelace dvou družic Sentinel 2).

6.1.1 MULTISPEKTRÁLNÍ OPTICKÁ DATA

Nejvýznamnější uplatnění v aplikacích spojených se zemědělstvím dosud nalézají především optické multispektrální systémy, jak již bylo naznačeno v předchozích kapitolách a bude konkrétněji ukázáno v následujících, zaměřených na konkrétní příklady aplikací. Multispektrální senzory jsou schopné snímat záření v několika spektrálních pásmech, obvykle zejména ve viditelném a blízkém infračerveném spektru, případně i ve spektru SWIR, tedy krátkovlnném infračerveném pásmu. Od počátků satelitního snímání spojeného s počátky programu Landsat v 70. letech 20. století byla na oběžnou dráhu vypuštěna řada systémů různého osazení a provenience. Vývoj systémů směřoval k využívání citlivějších a přesnějších senzorů, ke snižování prostorového rozlišení či doby návratu nad stejné místo. V dnešní době tak funguje řada systémů, které na komerční bázi poskytují data s velmi vysokým rozlišením a možností pořizování snímků velice často. Např. systém několika desítek mikrosatelitů (tzv. Cubesat) společnosti Planet dnes nabízí snímky dostupné téměř každý den s rozlišením 3 m na pixel. Pro řadu úloh jak ve vědeckém sektoru, tak i v praktickém provozu je spoléháno nicméně spíše na volně dostupná data, a to

Tabulka 3: Přehled základních optických multispektrálních satelitních systémů s vysokým rozlišením

Družice	Senzor	Prostorové rozlišení [m]	Počet pásem	Záběr senzoru [km]	Perioda snímání [dny]	dostupnost
Sentinel 2	MSI	10,20, 60	13	290	5	2015-d
Landsat 9	OLI2+TIRS2	30, 100 (P 15)	9 + 2	185	16	2021-d
Landsat 8	OLI9+TIRS	30, 100 (P 15)	9 + 2	185	16	2013-d
Landsat 7	ETM+	30, 60 (P 15)	8	185	16	1999-d
ALOS-3	WISH	3,2	7	70	46	2021*
CBERS-4A	WPM,MUX	8, 16	4	92,95	26	2019-d
KANOPUS	MSS, PSS	10,5	4	23		2018-d
VENUS	VSSC	5,3	12	27,5	2	2017-d
SPOT 6/7	NAOMI	6 (P 1,5)	4	10	1	2012-d
Terra	ASTER	15, 30, 90	14	60	16	1999-d
RESOURCESAT-2	LISS	6, 23	4	40, 24	5	1996-2006
THEOS	MS, PAN	15 (P 2)	4	90	26	2008-



Obrázek 21: Spektrální rozlišení vybraných multispektrálních senzorů

především z amerického programu Landsat nebo nověji z evropského programu Copernicus, který poskytuje data z rodiny družic Sentinel (v optické multispektrální oblasti hlavně Sentinel 2). Přehled systémů, jejichž data je v současné době možné použít, jsou představena v tabulce 3.

6.1.2 DATA S VELMI VYSOKÝM ROZLIŠENÍM

Při některých aplikacích je zapotřebí použít co největšího detailu, který snímky nabízejí. V tom případě je na místě využít data s velmi vysokým rozlišením. Ty jsou obvykle poskytována v základních čtyřech pásmech, tedy třech viditelných a blízkém infračerveném pásmu. Tato pásma tak mohou být využita pro sestavení základních vegetačních

indexů. Přehled systémů, které v dnešní době nebo blízké minulosti pořizovaly data je možno nalézt v tabulce 4. Tato data jsou obvykle dostupná komerčně a jejich snímání je prováděno na vyžádání. Některé systémy, obvykle tvořeny řadou malých satelitů v konstelaci, jsou schopny pořizovat snímky i kontinuálně – například Planet či Sky-Sat nebo nově se rozvíjející projekt BlackSky Global.

6.1.3 RADAROVÁ DATA

Radarová satelitní data nenacházejí v rámci zemědělských aplikací tak široké uplatnění jako optické snímky, nicméně i v této oblasti jsou využívány. Využití nacházejí např. při identifikaci plodin a získání informací o parametrech porostů, identifikaci zemědělských operací,

Tabulka 4: Satelitní systémy s velmi vysokým rozlišením

Družice	Senzor	Prostorové rozlišení [m]	Počet pásem	Záběr senzoru [km]	Perioda snímání [dny]	dostupnost
WorldView-3	MSS, SWIR, PAN	1,2; 3,7 (P 0,3)	8 + 8	13	1	2014-
WorldView-4	GIS-2	1,2 (P 0,3)	4	13	1	2016-2019
Pleiades-1A/1B	HiRI	2 (P 0,5)	4	20	26	2011/2-
Pleiades Neo 4	Pleiades Neo	1,2 (P 0,3)	6	14		
Planet-Dove	PlanetScope	3	4			2017-
Cartosat-3	MX, PAN	1,14 (P 0,28)	4	16		2018-
SkySat	SkySat	1 (P 0,8)	4	2,2	2	2017-
Formosat-5	RSI	4 (P 2)	4	24		2017-
RapidEye	REIS	5	5	77	1	2008-2020
Quickbird	Quickbird	2,4 (P 0,6)	4	16	3	2001-2015
IKONOS	OSA	4 (P 1)	4	11	3	1999-2015
Geoeye-1	GIS-MS	1,7 (P 0,5)	4	15	02.VIII	2008-

* P = panchromatické pásmo

Tabulka 5: Vybrané satelitní radarové systémy

Družice / senzor	Pásmo	Prostorové rozlišení [m]	Obrazový mód	Perioda snímání	Polarizace	Dostupnost
Sentinel-1	C	5	Stripmap	12	HH+HV, VH+VV, HH, VV	2014-
		5x20	Interf. wide swath			
		20x40	Extra wide swath			
Gaofen-3	C	1	Spot light	29	Jedna vybraná	2016-
		5	Fine strip		Vybraná duální	
		8	Full polarized strip		Plná polarizace	
Cosmo-Skymed	X	1	SpotLight	16	HH, VV	2007-
		5-15	Interf. wide swath		HH+VV	
		30-100	Extra wide swath		HH+HV, VV+VH	
ALOS-2/ PALSAR-2	L	1x3	SpotLight	14	HH, VV, HV, VH	2014-
		3-10	StripMap		HH+HV, VV+VH	
		60-100	ScanSAR		HH+HV+VH+VV	
RADARSAT-2	C	1	SpotLight	24	HH, VV, HV, VH	2007-
		3	StripMap		HH+HV, VV+VH	
TerraSAR-X	X	1-2	SpotLight	11	HH, VV, HH+VV, HH+HV, VV+VH	2007-
		3	StripMap			
			ScanSAR			

identifikace a vyhodnocení poškození porostů, ale hojně také pro analýzu vlhkosti půdy (Liu et al. 2019). Radarová data jsou totiž ovlivňována drsností a charakteristikou povrchu a dielektrickými vlastnostmi povrchu. Jejich velkou výhodou je malá citlivost na atmosférické vlivy a je tak možné provádět sledování i při výskytu oblačnosti, která je limitem pro optická data. Z pohledu konkrétní aplikace je pak pro daný účel zapotřebí přizpůsobit výběr

vhodných dat. Radarové systémy mají v tomto ohledu různou konfiguraci, která může ovlivnit vhodnost jejich nasazení. Jedná se zejména o dobu návratu systému nad sledovanou lokalitu, frekvenční pásmo, v kterém systém pořizuje data, možnosti polarizace dat, úhel pozorování a také v jaké dráze jsou data pořizována (vzestupná či sestupná dráha). Základní přehled současných radarových systémů viz tabulka 5.

6.2 LETECKÉ SYSTÉMY

Letecké platformy jsou využívány v podstatě od počátků využívání dálkového průzkumu Země. Letecké nosiče mají výhodu v tom, že jsou dostatečně robustní na to, aby unesly těžší měřičská zařízení a mohou pořizovat data z nižších nadmořských výšek, než je tomu u satelitních systémů. Mohou tak být pořizována data s lepším prostorovým rozlišením a vzhledem ke kratší dráze průchodu světla atmosférou i při nízkém šumu. Nevýhodou pak může být snížená operabilita vlivem povětrnostních podmínek či vlivem omezení leteckého provozu v některých oblastech. Vzhledem k malé výšce letu je také užší pás pořizovaných dat a při snímání větší plochy je zapotřebí spojovat data do mozaik z více náletových linií, což má za následek nutnost hlubšího zpracování dat vlivem tzv. BRDF efektu (efekt různého osvětlení objektů vlivem jiného úhlu snímání). Rovněž je vzhledem ke geometrii snímků zapotřebí provádět dostatečné geometrické korekce obrazu. Pořízení leteckých snímků může být z pohledu nákladů srovnatelné či vyšší než u pořízení komerčních satelitních dat, nicméně například v případě hyperspektrálního či termálního snímání je využití leteckých nosičů velice výhodné.

6.3 BEZPILOTNÍ PROSTŘEDKY

Bezpilotní letecké prostředky (UAV – unmanned aerial vehicles) nebo celé bezpilotní systémy (UAS – unmanned aerial systems) jsou označeny pro prostředky, které umožňují let bez posádky na palubě. Jelikož však ve většině případů nejde o zcela autonomní pohyb, ale vzdáleně pilotovaný let, je vhodnější tyto systémy označovat jako dálkově ovládané letecké systémy (RPAS – remotely piloted aircraft systems). Často se v této souvislosti lze také setkat spíše se slangovým názvem drony. Celkově se jedná o velkou škálu různých nosičů, které umožňují nést různé typy senzorů. Na základě vývoje v miniaturizaci digitálních komponent se vyvinul tento segment dálkového průzkumu Země do značně širokého spektra a dnes je využíváno těchto prostředků v celé řadě aplikací. Tyto systémy se vyznačují zejména svou velkou operabilitou, relativně nízkými náklady na pořízení dat a jejich flexibilitou. V závislosti na únosnosti stroje je možné letecký prostředek osadit různými typy senzorů, ať už klasickými kamerami, které umožňují základní inventarizaci a monitoring krajiny a zemědělských ploch po multispektrální či termální systémy, které umožňují již širší analytické uplatnění ve sledování vlastností půd a zemědělských porostů. Pořízení vlastních bezpilotních prostředků, jejich obsluha a zpracování záznamů vyžaduje určité znalosti a dovednosti, případně také mít k dispozici vhodný software pro zpracování, nicméně v dnešní době jsou tyto systémy velice rychle nasaditelné a mají velice široké využití. Samotní zemědělci mohou buď sami využívat těchto prostředků pro vlastní činnost nebo využít řady služeb, které jsou v tomto oboru již také značně rozvinuté. Při samotném provozu bezpilotních prostředků je však třeba dbát na bezpečnost provozu a řídit se současnou legislativou, která jejich provoz upravuje. Existují tak určitá omezení, ale zejména v zemědělské krajině mimo oblast intravilánu či mimo oblast letišť a jiných zakázaných zón není jejich provoz výrazně omezován.

Nasazení bezpilotních prostředků je vhodné zejména tam, kde je potřeba mít detailní informace o pozemcích či stavech porostu ve vysokém prostorovém rozlišení. V závislosti na výšce letu je možno dosáhnout prostorového rozlišení na bázi centimetrů a v případě některých aplikací je tak možno cílit až na úroveň jednotlivých

Tabulka 6: Výběr satelitních hyperspektrálních senzorů (Qian 2021)

Družice	Senzor	Subsystem	Prostor. rozlišení (m)	Počet pásem	Spektrální rozpětí (nm)	Spektrální rozlišení (nm)	Dostupnost
ISS	HISUI	VNIR+SWIR	30	185	400-2500	10(12,5)	2019-
GomX-4B	HyperScout	VNIR	50	45	400-1000	15	2018-
GaoFen-5	AHSI	VNIR+SWIR	30	330	400-2500	5(10)	2018-
IMS-2	HysIS	VNIR+SWIR	30	256	400-2400	10	2018-
PRISMA	PRISMA	VNIR+SWIR	30	237	400-2400	12	2018-
Sentinel-3	OLCI	VNIR	300	520	390-1040	1,25	2016-
FTHSI	HJ-1A	VNIR	100	128	450-950	5	2008-
PROBA	CHRIS	VNIR	25-50	81	400-1050	5,6-32,9	2001-
EO-1	Hyperion	VNIR+SWIR	30	242	360-2580	10	2000-2017
German HS	EnMAP	VNIR+SWIR	30	244	420-2500	5(10)	2021*
CHIME	CHIME	VNIR+SWIR	20-30	210	400-2500	10	2029*

6.4 HYPERSPEKTRÁLNÍ DATA

plodin. Bezpilotní prostředky se uplatní i v případě, že je zapotřebí získat data co nejrychleji, jejich provoz je totiž velice flexibilní a je kromě zakázaných nebo jinak omezených prostorů omezen pouze meteorologickými vlivy (vítr, nízké teploty). Bepilotními prostředky je často také možné nalétnout pouze omezenou část pozemků. V závislosti na kapacitě baterií, letové hmotnosti, výšce letu, případně počtu baterií v zásobě je u vrtulových strojů možné nalétnout pouze omezenou část, která nám tato konfigurace nabízí. Pro potřeby náletu většího území jsou pak vhodnější stroje typu křídlo, které mají obecně větší záběr. V dnešní době je možno využívat široké spektrum zařízení, od komerčně sériově vyráběných strojů až po zařízení, které jsou vyrobeny na zakázku. Stejně tak již existuje celá řada kamer a senzorů, které jsou vhodné pro nasazení na dronech. V případě přesnějších a multifunkčnějších zařízení je však třeba počítat i s většími náklady na pořízení těchto zařízení. Zevrubný popis všech možných využitelných zařízení by byl nad rámec této publikace, proto odkazujeme na další kapitoly, kde je využití některých systému popsáno nebo na další zdroje literatury a zejména celou řadu internetových zdrojů k tomuto tématu.

Specifickou oblast dálkového průzkumu Země tvoří hyperspektrální snímkování neboli tzv. obrazová spektroskopie, tedy pořizování dat s velmi vysokým spektrálním rozlišením. Hyperspektrální systémy jsou vhodné spíše pro vědecké aplikace, ale mohou být využity i pro precizní mapování obzvláště v případě mapování půdních vlastností. Hyperspektrální senzory jsou většinou využívány na leteckých nosičích, nicméně v dnešní době jsou již dostupné i senzory na družicích a dá se očekávat další vývoj v těchto systémech. Starší satelitní hyperspektrální senzory operovaly jen ve viditelném a blízkém infračerveném pásmu, které je důležité zejména pro mapování vegetace. Novější již pořizují data i z pásma SWIR, které je důležité například při mapování některých půdních vlastností. Vývoj však jde stále dál a v tomto oboru lze očekávat výrazné pokroky.

7 APLIKACE DPZ PRO PRECIZNÍ ZEMĚDĚLSTVÍ

V předchozích kapitolách byla popsána především teoretická východiska a technické prostředky, ze kterých vychází využití dat a metod DPZ v zemědělství. V této kapitole a jejích jednotlivých podkapitolách jsou jednotlivé aplikace představeny dle tematických okruhů s ohledem na sledování půdních vlastností a vlastností zemědělských plodin.

7.1 MAPOVÁNÍ PŮDNÍCH VLASTNOSTÍ

Pro hospodaření na zemědělských půdách a obzvláště při využití moderních metod v zemědělství je pro návrh vhodných postupů zcela nezbytné mít k dispozici aktuální a co nejpřesnější mapy půdního prostředí a vlastností půdy. Dostupnost podrobných a aktuálních map půdních vlastností však není obvykle dostatečná v rámci existujících dat z konvenčních map. Tyto mapy jsou většinou zastaralé, ale hlavně neposkytují dostatečné rozlišení pro potřeby cíleného hospodaření v rámci precizního zemědělství.

Dálkový průzkum Země je jednou z metod, které lze pro mapování půdních vlastností využít. Nicméně využití dálkově

pořizovaných dat má svá omezení a předpoklady. Jak již bylo popsáno v kapitole zabývající se spektrálními charakteristikami půd, získání informace o konkrétní půdní vlastnosti není zcela přímé a triviální. Půda je totiž tvořena značně různorodým komplexem různých složek, které se podílejí na spektrálním chování půd a vzájemně se značně ovlivňují. Získat informace z dat DPZ je tak možné převážně pouze pro spektrálně aktivní složky půdy, kterými jsou zejména organická hmota, půdní zrnitost (zejména jílové složka), karbonáty, oxidy železa či půdní vlhkost. Na základě zjištění těchto vlastností je však možné usuzovat na celkovou kvalitu půd a variabilitu jejich vlastností v ploše. Je však třeba brát v úvahu omezení, které ze sledování pomocí metod DPZ vyplývá. Tím je zejména možnost sledování vlastností pouze v povrchové vrstvě půdy. Při předpokladu homogenizace celého orničního horizontu, lze však vztáhnout toto sledování na celou orniční vrstvu. Pokud pomineme analýzu vegetačního pokryvu jako určitý indikátor stavu půdního prostředí (o sledování vegetace v dalších kapitolách), je rovněž zapotřebí brát v úvahu maskující vliv vegetace. Sledování půdních vlastností pomocí DPZ je tak prováděno hlavně na místech, které se nacházejí v holém stavu, tedy bez vzrostlé vegetace či posklizňových zbytků, které



Obrázek 22: Ukázka klasické půdní mapy v analogové podobě (vlevo), vektorizované podobě (uprostřed) a výstup z digitálního mapování půd v rastrové podobě (vpravo)



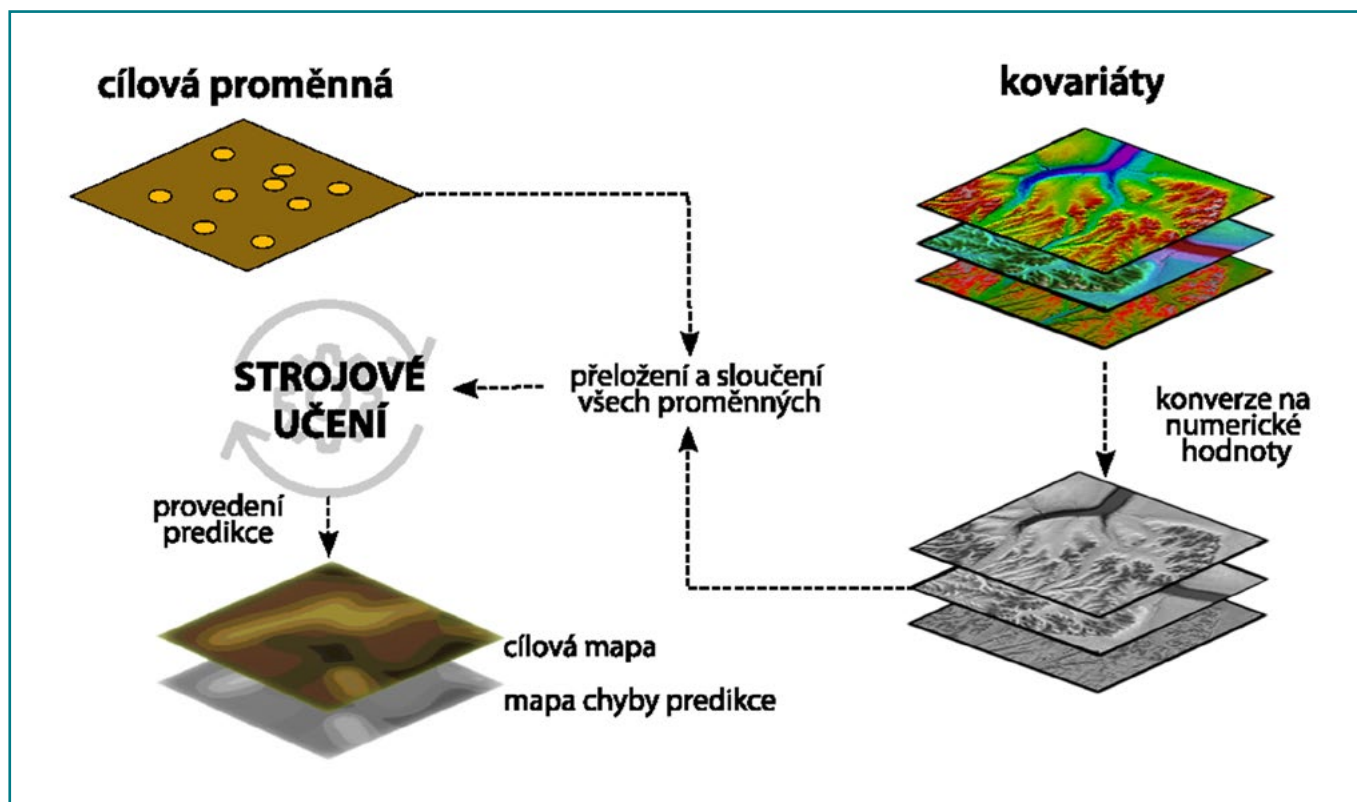
Obrázek 23: Ukázka snímku z družice Sentinel 2 v pravých barvách s půdním povrchem v různém stavu – holé půdy, nezapojená vegetace, zapojená vegetace, rostlinné zbytky

ovlivňují celkový spektrální projev a znesnadňují analýzu půd. Stejně tak působí i vliv zvýšené vlhkosti či drsnosti povrchu (například vlivem orby). Byť je možné určitými metodami vliv všech těchto komponent omezit a tyto metody jsou dále rozvíjeny, využití DPZ při mapování půd se soustředí na sledování zejména při nevhodnějších podmínkách, kterými jsou holé, suché půdy, bez vegetačních zbytků a s minimální vlhkostí.

Optimálními podmínkami pro spektrální analýzu půd jsou nejlépe přizpůsobeny laboratorní spektroskopické analýzy. Při těchto analýzách, které jsou prováděny na spektrech měřených hyperspektrálními spektrometry na suchých a nadrcených vzorcích, byla prokázána účinnost spektrálních metod pro stanovení půdních vlastností. Tyto metody mají potenciál nahradit chemické analýzy v laboratořích, což by výrazně mohlo urychlit a zlevnit laboratorní rozborů. I přes velice přesné měření na upravených vzorcích však není možné přímé hodnocení vlivu jednotlivých půdních komponent. Pro jejich stanovení na základě měřených spekter je tak využíváno spektrálních knihoven, které jsou sestaveny z velké řady vzorků, na kterých jsou naměřena jak spektra, tak provedeny chemické analýzy. Pro odvození vlastností na konkrétním spektru je pak využíváno statistických mnohorozměrných metod, s pomocí kterých je ze známých dat vytvořen model, který je následně aplikován na data z neznámými vlastnostmi. V podstatě jde o jakousi metodu učení na základě velké řady známých dat – proto se často pro toto odvození používají i metody strojového učení. Obdobně je tomu při získávání informací ze spekter z dálkového průzkumu. Jelikož ty jsou ale pořizovány za celé šíře atmosférických podmínek, různými senzory s různou geometrií snímání (výška, sklon, rozlišení) a za jiných osvitových podmínek vlivem jiné denní a roční doby a při různých stavech povrchu, je vytváření spektrálních knihoven pro data DPZ téměř nereálné. Známá data, která jsou využita

pro „učení“ modelů, jsou tak nahrazována půdními vzorky z míst, které jsou zachyceny na jednotlivých snímcích. Pro mapování půdních vlastností pomocí DPZ je tak zapotřebí využít skupinu pozemně zjištěných dat, konkrétně půdních vzorků a nějaké mnohorozměrné statistické regresní metody pro predikci v ploše. Těmito regresními metodami modelující vztah mezi cílovou proměnnou (např. obsah humusu) a odrazivostí v jednotlivých spektrálních pásmech, mohou být jak jednoduché lineární modely, tak složitější matematicko-statistické metody, až po metody strojového učení. Obecně se dá předpokládat, že s využitím metod, které jsou schopny lépe popsat složité nelineární vztahy v řešené problematice, se dá dosáhnout lepších výsledků při konečné predikci. V dnešní době je nejlepšími výsledky dosahováno s využitím metod tzv. hlubokého učení založeném na neuronových sítích, nicméně je třeba také říci, že se jedná o poměrně výpočetně náročnou metodu, jejíž nasazení vyžaduje pokročilé znalosti a dovednosti. Pro mapování půdních vlastností lze využít i některé spektrální indexy (příkladem může být index SOCI pro odvození půdního organického uhlíku na bázi dat z pásem ve viditelném spektru – Thaler et al. 2019), nicméně jejich nejistota v predikci je poměrně značná a jsou vhodné spíše jen pro mapování regionálních rozdílů.

Obecně nejlepší perspektivu v rámci DPZ má mapování z hyperspektrálních senzorů, které nabízí nejvyšší možné spektrální rozlišení a pokud je k dispozici i v pásmu SWIR, tak je předpoklad pro zachycení úzkých absorpčních pásem jednotlivých půdních komponent, a tedy i možnost jejich analýzy. Mapování na lokální úrovni v různých půdně-klimatických oblastech ČR pomocí leteckých hyperspektrálních senzorů v rámci studie Žižala et al. (2017) ukázalo, že mapování lze provádět s poměrně přesnými výsledky, přičemž nejlépe predikovatelnými vlastnostmi byl obsah organické hmoty, karbonátů, jílů



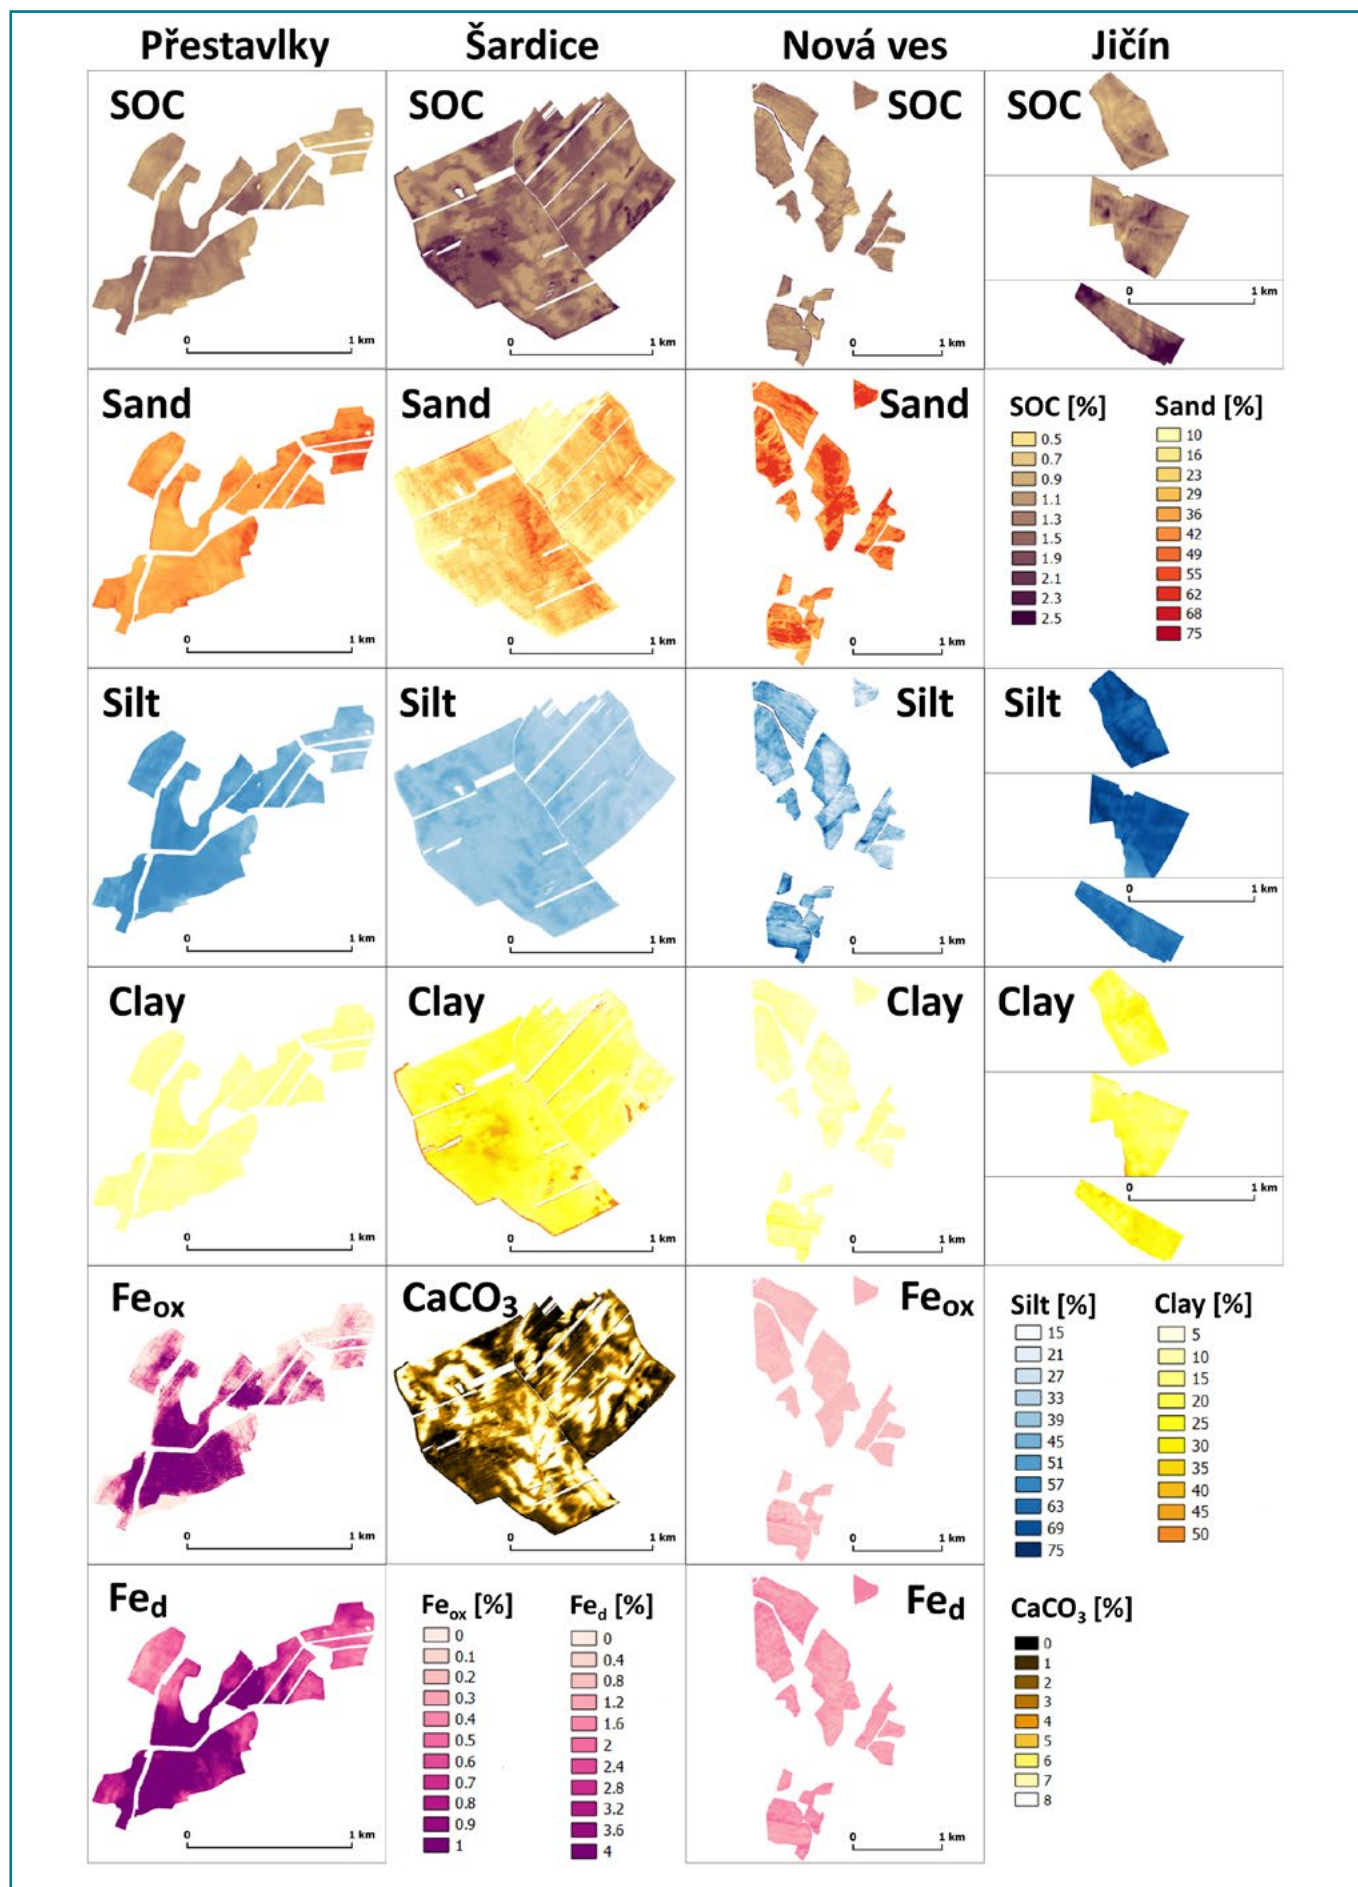
Obrázek 24: Schéma metody mapování půdních vlastností s využitím půdních vzorků, pomocných proměnných a regresních metod

a železa. U mapování obsahu písku a prachu byla predikční schopnost nižší, ale i tak průměrná chyba dosahovala dostatečné úrovně pro zhodnocení variability v rámci pozemku. K obdobným zjištěním dospěli dříve i studie z jiných států využívající hyperspektrální data (Casa et al. 2013, Denis et al. 2014, Hbirkou et al. 2012, Hively et al. 2011, Stevens et al. 2012). Využití hyperspektrálních dat je však omezené. Pořizování dat leteckými senzory není příliš levnou záležitostí, zpracování těchto dat vyžaduje vyšší nároky na technické provedení všech korekcí a jejich časová dostupnost je tak vcelku malá. Satelitní hyperspektrální senzory jsou zatím ve vývoji nebo nasazeny pouze krátce a jejich využití je tak spíše otázkou budoucnosti, kdy budou dostatečně dostupná data a bude k dispozici více ověřených uživatelských aplikací.

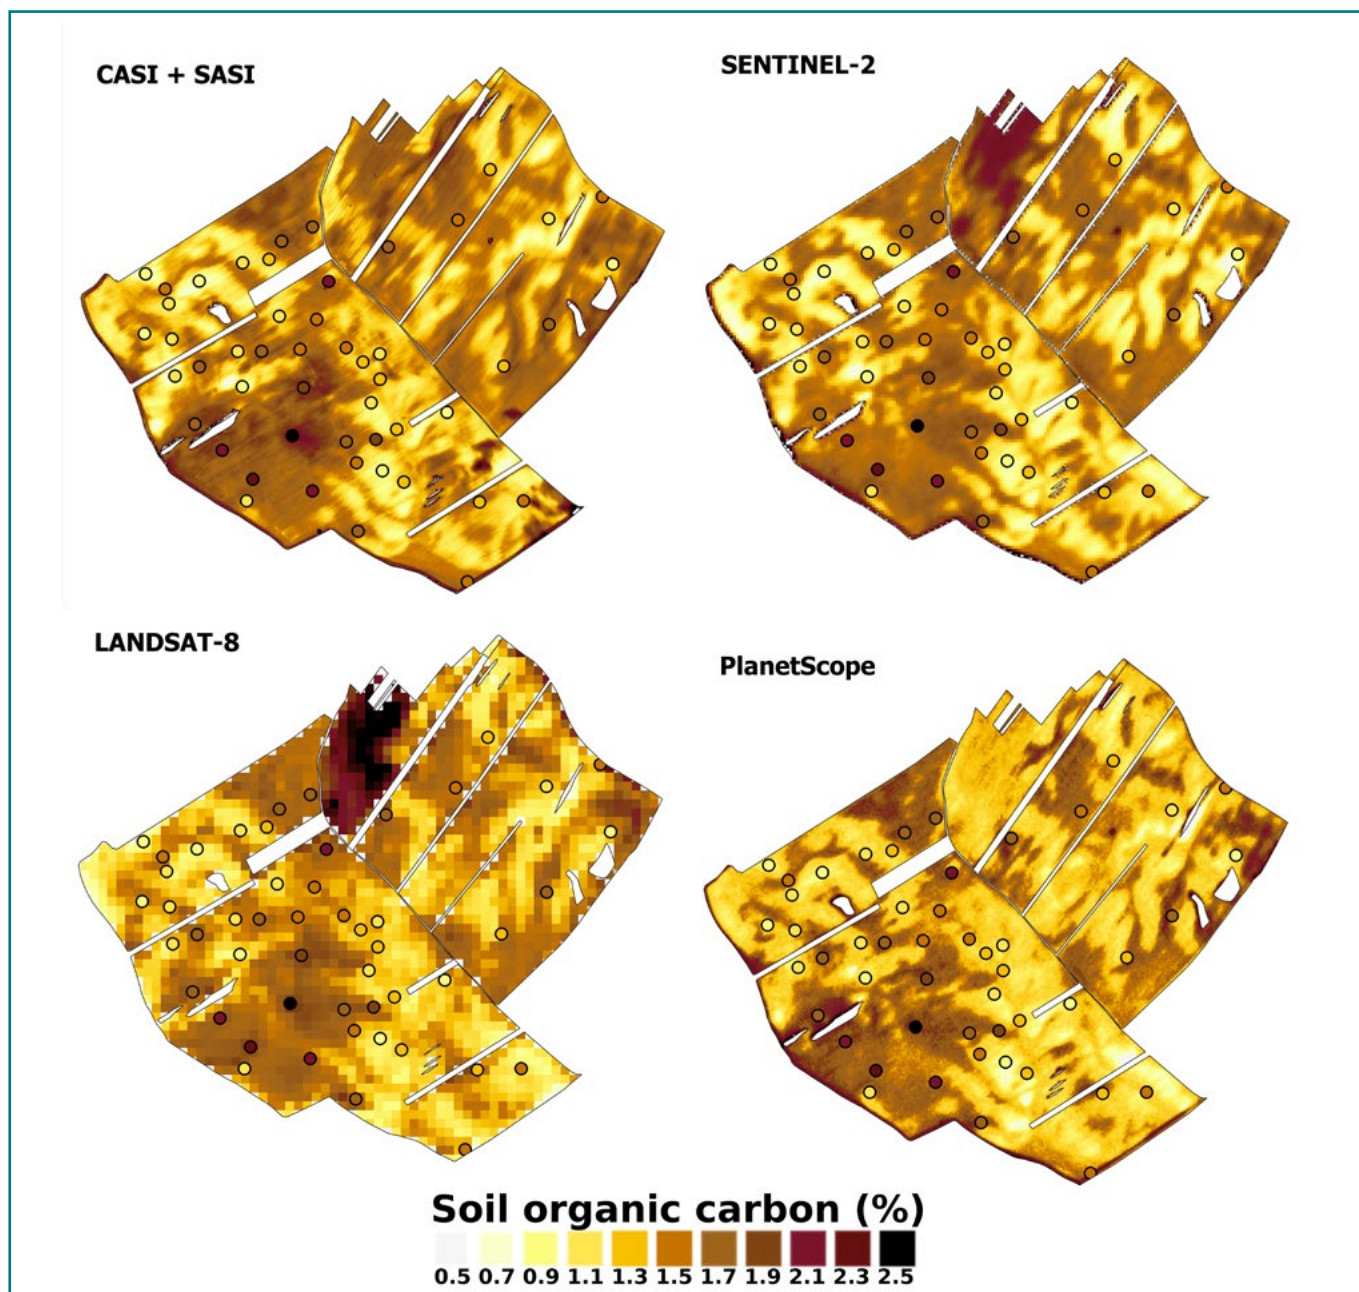
Větší perspektivu z pohledu dostupnosti dat mají multispektrální satelitní systémy, kterých existuje již celá řada a například i díky dlouhodobé dostupnosti dat z programu Landsat jsou nastaveny a ověřeny postupy pro jejich zpracování a využití. Senzory nabízejí dostatečné prostorové rozlišení a rovněž časové, které umožňuje nalezení vhodných snímků pro analýzu. Jak je to ovšem s možnostmi mapování půdních komponent v závislosti na sníženém spektrálním rozlišení? Je možno využít snímání v širokých spektrálních pásmech pro mapování půdních vlastností? Odpověď zní ano, ale s menší přesností. Multispektrální data nenabízejí tak spektrálně úzký pohled, který by umožnil lépe analyzovat jednotlivá absorpční pásma, a tak vychází spíše z hodnocení celkového tvaru spektrální křivky (popsané v několika málo bodech). Pro přesnější odvození absolutních hodnot půdních vlastností je však potřeba využít pozemních dat

– vzorků půd a zmíněných regresních statistických metod. Toto bylo ověřeno celou řadou studií ze světa (např. Castaldi et al. 2016, Dematte et al. 2016, Ebengo et al. 2018, Silvero et al. 2021) i z území ČR (Gholizadeh et al. 2018). Jednotlivé aplikace se zaměřují hlavně na mapování organického uhlíku (organické hmoty) v půdě, jednak z důvodů jeho důležitosti, jednak z důvodu toho, že jeho predikce vychází z multispektrálních dat nejlépe. Na mapování půdního uhlíku a vývoj operačních nástrojů pro jeho monitoring jsou v současnosti zaměřeny i některé mezinárodní projekty jako projekt WORDLSOILS financovaný Evropskou kosmickou agenturou (ESA) či projekt STEROPES v rámci společného evropského programu EJP SOIL. V rámci podmínek ČR byl zkoumán vliv využití různých multispektrálních senzorů s různým spektrálním a prostorovým rozlišením na predikci uhlíku (Žíža et al. 2019). Porovnání ukázalo, že byť s daty s vyšším spektrálním rozlišením lze dosáhnout lepších výsledků predikce, celkovou distribuci uhlíku lze postihnout i s daty s menším spektrálním či prostorovým rozlišením. Multispektrální systémy tak lze za vhodných podmínek využít při mapování organického uhlíku, respektive organické hmoty v půdě.

Jak se však ukazuje využití multispektrálních dat je již méně vhodné pro mapování dalších individuálních půdních vlastností. Dobré predikční schopnosti lze dosáhnout ještě u mapování obsahu jílu, u dalších půdních komponent vede ale nižší spektrální rozlišení již k vyšší míře nejistoty. Nicméně variabilita půdního prostředí je ve spektrálních datech do velké míry obsažena a je tak vhodné jejich využití v kombinaci s dalšími pomocnými proměnnými, jako jsou výnosové mapy či digitální model



Obrázek 25: Ukázka výsledků mapování půdních vlastností na lokální úrovni s využitím leteckých hyperspektrálních dat (Žižala et al. 2017)



Obrázek 26: Porovnání výsledků predikce organického uhlíku s využitím různých satelitních multispektrálních dat v porovnání s přesnými hyperspektrálními daty (CASI + SASI = letecké hyperspektrální senzory) (Žížala et al. 2019)


terénu, pro zvýšení predikční schopnosti vytvářených modelů. Na tomto principu fungují metody digitálního mapování půd (digital soil mapping), které umožňuje mapování půdních vlastností pomocí prostorových statistických metod a je účelné ho pro mapování využívat na různých měřítkových úrovních. Toto téma nicméně již přesahuje rozsah této publikace. Informace k tomuto tématu jsou dostupné v řadě anglicky psané vědecké literatury nebo pro zájemce v českém prostředí lze doporučit metodiku Žížala et al. (2020) Tvorba půdních map pedometrickými metodami.

Metody DPZ pro mapování půdních vlastností, jak již bylo naznačeno, mají svá omezení a to především z pohledu regionálního mapování, případně i mapování větších územních celků nebo jen několika půdních bloků v přímém sousedství. Tímto limitem je zejména fakt, že

na jednom konkrétním snímku se pozemky nacházejí v různém stavu z pohledu vývoje plodin a zemědělských operací a jen některé půdní bloky jsou holé a vhodné pro analýzu (jak naznačuje obrázek 23). Při analýze tak může být hodnocena jen část pozemků a pro vyhodnocení celé plochy tak musí být případně využito několik snímků. Řešení tohoto problému může být sestavení mozaiky holých půd z více snímků, tak aby výsledný produkt mohl být využit najednou. Přístupů pro tvorbu takové mozaiky či jinak řečeno kompozitu je několik (Demattê et al. 2020, Diek et al. 2017, Roberts et al. 2019, Rogge et al., 2018, Vaudour et al. 2021), nicméně všechny tyto přístupy řeší problém, jak na jednotlivých snímcích identifikovat holé půdy a jak z této časové řady následně vytvořit koncový produkt. Z časové řady je také zapotřebí odstranit ty části na nichž se vyskytuje oblačnost. Obvykle jsou pro identifikaci holých půd využívány prahové hodnoty některých



Obrázek 27: Výřezy v pravých barvách z mozaiky holých půd; nahoře – kambizemě na permokarbonu Českého masivu na Rakovnícku, uprostřed – černozemě a černice na spraši na Prostějovsku, dole – regozemě na písčitéch terasách na Pardubicku)



Obrázek 28: Základní vzorkovací schémata; zleva – náhodné schéma, pravidelné schéma, utříděné schéma

vegetačních či jiných indexů (např. NDVI pro vegetaci, NBR2 pro stárnoucí vegetaci a posklizňové zbytky) a pokud se ve zkoumané časové řadě vyskytuje více holých půd, tak je za výsledek brán medián hodnot nebo jiná statistika. Výsledný produkt tak může vypadat tak, jako by byl nasnímán v době, kdy jsou všechny půdy holé, a to i ve stejných spektrálních pásmech. Takto vzniklý kompozit lze s výhodou použít i pro regionální mapování, jak již bylo ukázáno v některých studiích (Dvorakova et al. 2021, Safanelli et al. 2020, Sorenson et al. 2021, Vaudour et al. 2021, Zepp et al. 2021). Mozaika holých půd vznikla i pro ČR, konkrétně z časové řady snímků z družic Sentinel 2 pořizovaných mezi roky 2015-2020 se stejným spektrálním rozlišením a v 20m prostorovém rozlišení a byla využita pro mapování půdních vlastností na národní úrovni (Žížala et al. 2020).

7.2 OPTIMALIZACE VZORKOVÁNÍ PŮD

Zjištění variability půdních vlastností mající vliv na pěstované plodiny a výnos je prvním krokem pro správné a cílené hospodaření na základě principů precizního zemědělství. S popisem této variability mohou pomoci, jak bylo nastíněno i metody DPZ. Nicméně i při použití těchto metod je vždy zapotřebí využívat pozemní data, tedy informace z půdních vzorků. Navíc řada důležitých půdních vlastností nebo komponent nemá přímý odraz ve spektrálních charakteristikách měřených dat. Jsou i ty, které jsou z pohledu zemědělské praxe a obzvláště v rámci využití metod precizního zemědělství ty podstatné, zejména živiny a půdní reakce (pH). Tyto informace lze získat především půdním vzorkováním. Nicméně v této souvislosti vyvstává řada otázek – V jaké hustotě vzorkovat? Jak by měla vypadat vzorkovací síť? Mohou být použity pro pomoc se vzorkovacím schématem nějaká jiná dostupná data? Na tyto otázky obecně není jednoduché odpovědět vzhledem k velké variabilitě půdních a klimatických podmínek na našem území. Respektive jednou z jednoduchých odpovědí by mohlo být, že je potřeba vzorkovat co nejpodrobněji. To však naráží na finanční nákladnost takového vzorkování a je zajisté výhodné hledat jiné cesty a vzorkování optimalizovat z pohledu jeho efektivity a ekonomické náročnosti.

Často je pro vzorkování používáno pravidelného vzoru pro odběr vzorků. Toto schéma není však úplně ideální, zejména z důvodu potřeby většího množství vzorků pro celkový popis území. Obdobně náhodné vzorkování má své nevýhody, zejména z pohledu možného vynechání důležitých míst na pozemku. Vhodnější je tedy používat tzv. stratifikovaná neboli utříděná schémata s využitím dalších podpůrných dat. Dnes existují a jsou dostupná prostorová data, která umožní vzorkování lépe zacílit a nevyužívat jen optimalizování na základě tvaru pozemků, ale i v závislosti na variabilitě, která je v těchto pomocných datech zachycena. Jedním z takových podkladů může být například digitální model terénu, ale také právě data DPZ, která nesou informace o variabilitě půdy, ale také o variabilitě porostů, a to i v časové dlouhodobé řadě.

Použití volně dostupných dat DPZ pro optimalizaci vzorkování bylo popsáno v metodice Optimalizace vzorkování

půd s využitím spektrálních dat pro účely lokálně cílené agrotechniky (Minařík et al., 2018). Bylo ukázáno, že s použitím multispektrálních dat Sentinel 2 lze optimalizovat vzorkovací síť a ušetřit tak náklady na vzorkování při zachování vypovídající schopnosti vzorků o celém mapovaném území. Metodika založená na statistických prostorových metodách je dále vyvíjena v dalším výzkumu ve spolupráci se zemědělským podnikem využívajícím principy precizního zemědělství s cílem zjednodušit postup, tak aby metoda byla jednodušeji aplikovatelná. Výhodné v tomto smyslu je využití dalších pomocných dat vycházejících z dat DPZ, konkrétně výnosové mapy vytvořené na základě multispektrálních dat DPZ či mapy relativních rozdílů ve vlhkostním režimu části pozemků získaných s pomocí radarových dat z družice Sentinel 1.

U vzorkování na pozemcích je však také třeba upozornit na způsob odběru jednotlivých vzorků. Velikost plochy, ze které je jednotlivý vzorek odebírán je optimální provádět z plochy, která odpovídá rozlišení podkladů, respektive cílové mapy. To znamená například při rozlišení cílové mapy 10 metrů na pixel, je vhodné kvůli reprezentativnosti vzorku odebírat směsný vzorek právě z velikosti plochy 10x10 m. V této souvislosti je také vhodné upozornit na ne vždy zcela správné využívání dat agrochemického zkoušení půd (AZZP) pro účely precizního zemědělství. Dle metodiky tohoto vzorkování se odebírá průměrný, tedy směsný vzorek z jednotně obhospodařované plochy, kdy průměrná plocha u orné půdy je 7-10 ha. Při kruhovém odběru se odebírá z kružnice o poloměru 100, respektive 120 m. V případě silně variabilních půdních podmínek, může toto být poměrně značná plocha a pokud je hodnota prisuzována nesprávně jen k centroidu (geometrickému středu), tak může být výsledná průměrná hodnota špatně interpretována.

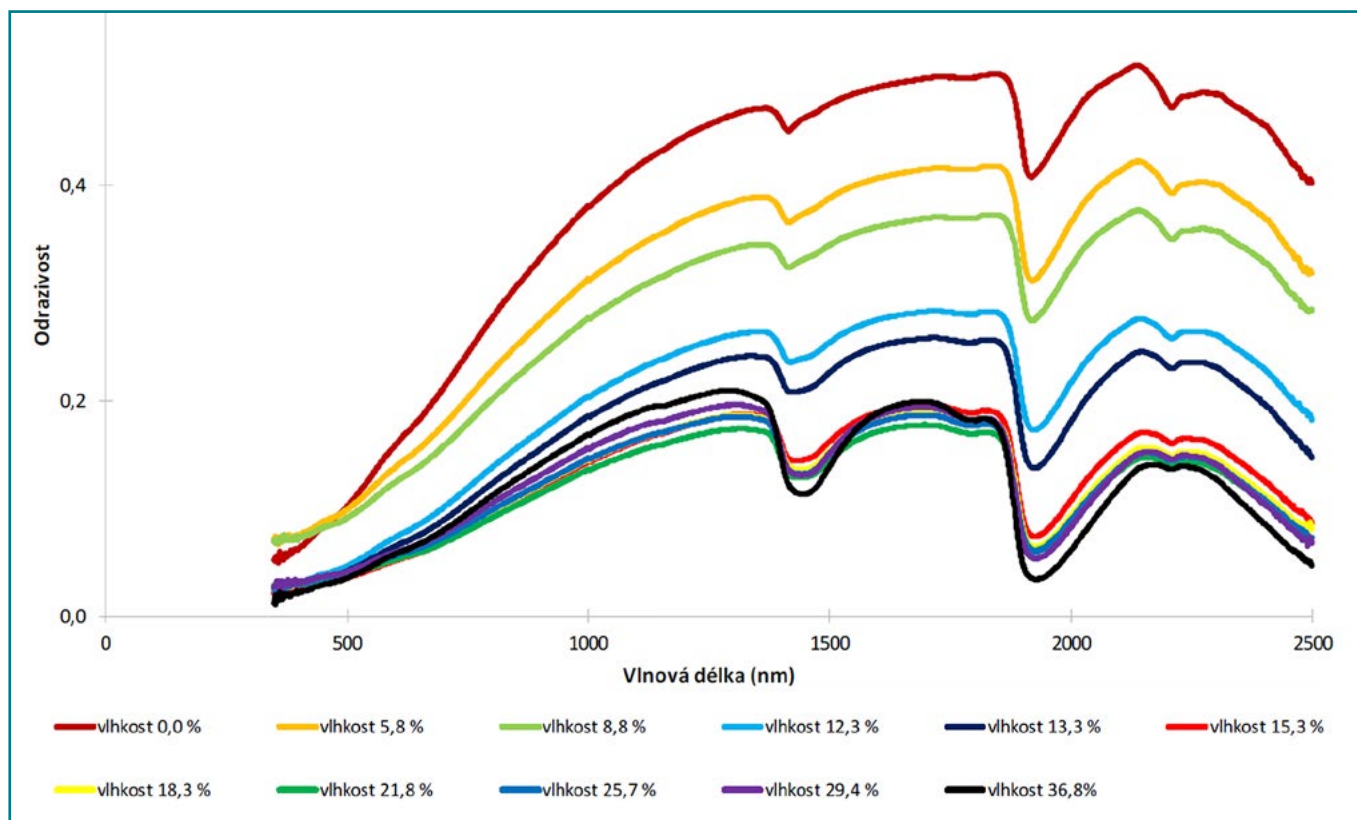
7.3 MAPOVÁNÍ VLHKOSTI

Půdní vlhkost je jedním z kritických faktorů pro vývoj zemědělských plodin. Obsah vody v půdě zejména v kořenové zóně rostlin silně determinuje stav a zdravý růst vegetace. Mapování vlhkostních podmínek, tak může přinést velice důležité informace o variabilitě pozemků z pohledu vláhových charakteristik. Z principů DPZ, tak jak byly popsány, je patrné, že metody využití elektromagnetického spektra umožňují sledování vlhkosti v půdě pouze v její svrchní vrstvě. Oproti bodovému sensorovému měření mají však tu výhodu, že umožňují mapování v ploše. Pro odvození vlhkosti v kořenové zóně je ovšem zapotřebí využít dodatečných terénních dat a například některých modelů schopných modelovat vztahy vlhkosti v kořenové zóně s vlhkostí v povrchové vrstvě půdy.

Pro mapování půdní vlhkosti je využíváno různých částí elektromagnetického spektra. Zatímco optické systémy jsou využívány ve spojitosti se změnami povrchové odrazivosti ve vztahu k obsahu vlhkosti, termální metody využívají k odhadu vlhkosti změny v teplotě půdy v závislosti na vlhkosti. Metody využívající mikrovlnou část spektra využívají hodnocení dielektrických vlastností půdy, které jsou půdní vlhkostí ovlivňovány. Vždy je však odvození vlhkostních charakteristik nepřímé a je třeba počítat s rušivými vlivy dalších půdních vlastností a charakteristik prostředí, které je nutné od signálu ovlivněného vlhkostí odlišit. Metody tak nejsou zcela triviální a obvykle umožňují spíše relativní odlišení vlhčích a sušších ploch, přičemž přesné absolutní stanovení vlhkosti je obtížné.

7.3.1 OPTICKÁ ČÁST ELEKTROMAGNETICKÉHO SPEKTRA

Odrazivost záření ve viditelné, blízké infračervené a středněvlnné infračervené oblasti spektra je obecně snižována s vyšší vlhkostí. Obecně lze tedy říci, že čím více vody v půdě (ať již vázané na povrchu půdních částic, tak volné vody v pórech) tím více se snižuje její celková odrazivost. Tento efekt je nejvýraznější v absorpčních pásech vody ve všech částech spektra, kde dochází k pohlcování záření vlivem chemického uspořádání. Celkový pokles odrazivosti vlivem vlhkosti lze vysvětlit i fyzikálně změnou v in-



Obrázek 29: Rozdíly v charakteristikách spektrální odrazivosti půdy v závislosti na změně půdní vlhkosti, převzato z: Klement (2014)

dexu lomu světla (refractive index) v závislosti na mediu obklopujícím půdní částice. Pokud je jím voda, je index lomu světla vyšší než v případě vzduchu. Nicméně obecný vztah mezi celkovou odrazivostí a vlhkostí (gravimetrickou nebo volumetrickou) není jednoduché naleznout, vzhledem k tomu, že porozita a index lomu se výrazně mění mezi půdami a je značně heterogenní. Rovněž i jiné půdní komponenty se mohou spektrálně chovat obdobně. Příkladem může být organická hmota, kdy při jejím zvýšeném obsahu dochází stejně tak k snížení celkové odrazivosti. Tyto různé vlivy pak nelze jednoduše oddělit. Metody založené na spektrální odrazivosti půdy v optické části spektra tak nejsou příliš vhodné pro měření vlhkosti a v praxi se moc nevyužívají. Dalším důvodem může být také fakt, že hloubka, ze které lze získat informace o vlhkosti, je úměrná použité vlnové délce. Tudíž např. viditelná oblast elektromagnetického spektra umožňuje detekci pouze z několika málo svrchních milimetrů půdního profilu.

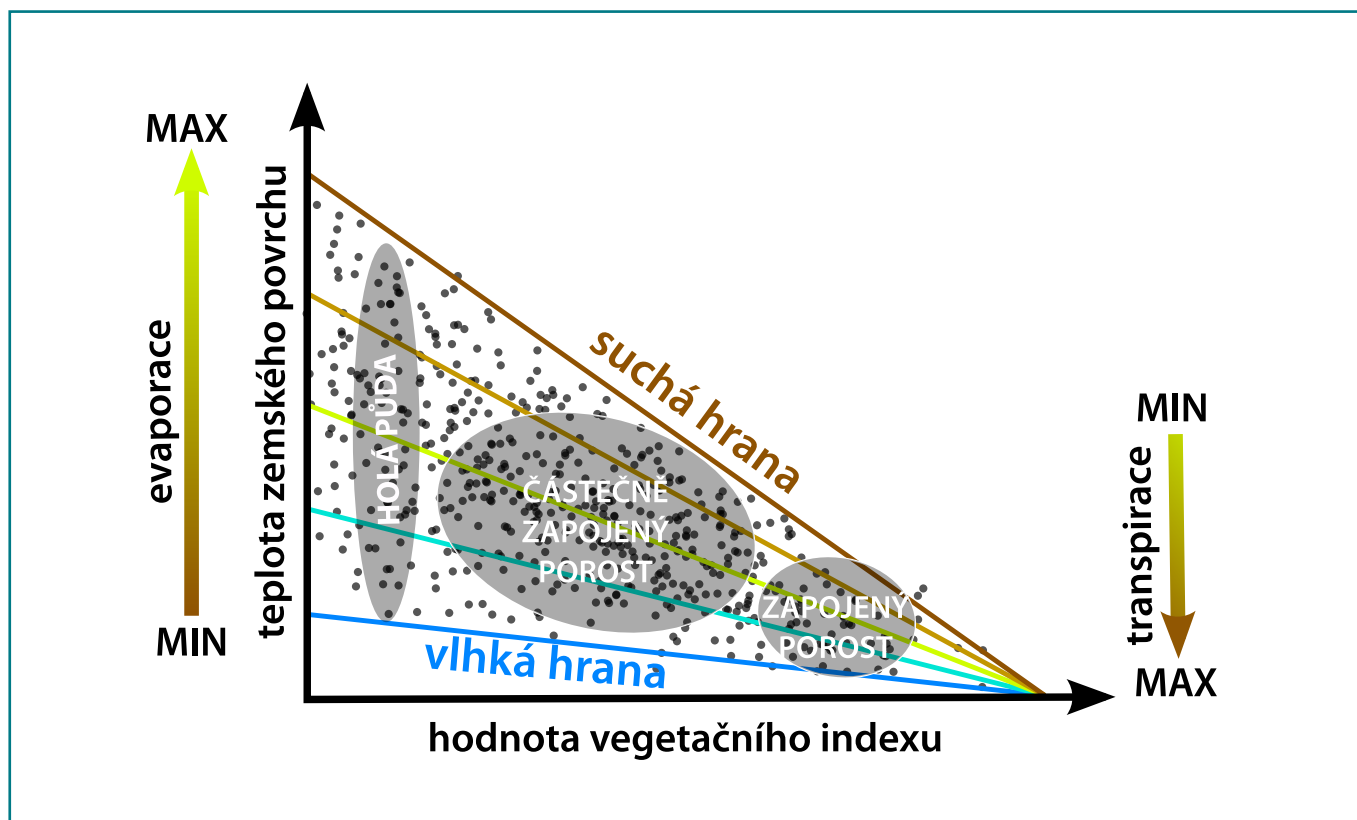
Možnostmi využití optické části spektra jsou tak spíše založené na potřebě většího množství pozemních kalibračních dat a využití statistických metod například na bázi strojového učení nebo kombinace optických dat s jinými typy dat, například termálními. Určité možnosti nabízí také předpoklad, že změna v množství půdní vláhly vede rovněž k fyziologickým změnám vegetačního krytu, což má v důsledku vliv na spektrální charakteristiku listů, a tudíž i na celkovou odrazivost vegetace. Tohoto zjednodušeného přístupu pak lze využít při mapování porostů a jejich vláhového stavu.

7.3.2 TERMÁLNÍ OBLAST ELEKTROMAGNETICKÉHO SPEKTRA

Odhady půdní vlhkosti lze také provádět na základě analýzy tepelných vlastností povrchu půdy. V tomto případě se využívá výrazné odlišnosti tepelných vlastností mezi suchou půdou a vodou. Malá změna v obsahu vody v půdě může vést k velkým změnám teploty povrchu půdy. Vlivem vyššího vypařování obvykle dochází u vlhčích půd k poklesu teploty. Tepelné vyzařování z půdního povrchu však nezávisí pouze na jeho teplotě. Ale také na koeficientu vyzařování půdy – tzv. emisivitě (míra vyzařovací schopnosti každého reálného tělesa ve srovnání s absolutně černým tělesem). Proto je zapotřebí při analýzách emisivitu vždy zohledňovat. Velkou nevýhodou a limitujícím faktorem při využití termálních dat k odhadu půdní vlhkosti jsou vlivy atmosféry (výskyt oblačnosti a obsah vodní páry ve vzduchu), přítomnost vegetace či vliv terénu a krajinných prvků na různé oslunění povrchu půdy. V rámci využití dat z termální oblasti spektra lze vyčlenit několik metod, které jsou používány při analýzách vlhkosti půdy.

7.3.2.1 METODA TEPELNÉ SETRVAČNOSTI

Voda má obecně vyšší tepelnou setrvačnost než suchá půda a vykazuje tudíž menší výkyvy během dne. Těto znalosti je využíváno v metodě tepelné setrvačnosti, pomocí níž je možné dosáhnout velmi přesných výsledků při odhadu vodního obsahu v půdě (Wang a Qu 2009).



Obrázek 30: Trojúhelníkový diagram teplota vs. vegetační index

7.3.2.2 KOMBINACE POVRCHOVÉ TEPLoty A VEGETAČNÍHO INDEXU

Tato metoda označovaná jako trojúhelníková metoda je založena na rozložení pixelů uvnitř bodového grafu mezi teplotou půdy a vegetačním indexem. Výhodou této metody je nezávislost na dalších datech. Předpokladem pro použití metody je však dostupnost vysokého počtu obrazových bodů na snímku odrážejících celý rozsah půdní vlhkosti a pokryvnosti půdy vegetací, aby trojúhelníkový graf mohl být zkonstruován. Ostré hranice na bodovém grafu pak představují reálné fyzikální limity, tj. holá půda versus 100% pokrytí vegetací, dolní versus horní limit vlhkosti půdy. Největší slabinou trojúhelníkové metody je tak vnesení subjektivity při identifikaci teplého okraje a limitních hodnot husté vegetace a holé půdy. Z trojúhelníkové techniky vychází i další přístupy, zmínit lze například index TVDI (*Temperature-Vegetation Dryness Index*).


7.3.2.3 MODELY ENERGETICKÉ BILANCE

Dalším přístupem je hodnocení půdní vlhkosti pomocí modelů energetické bilance povrchu. Tato metoda je využitelná obvykle pouze na lokální úrovni. Produktem metody je časoprostorová predikce aktuální evapotranspirace (ET), která může být spojena s půdní vlhkostí. Hlavní nevýhodou při použití modelů energetické bilance je potřeba získání řady nezbytných dat pro správné prostorové rozlišení a kalibraci modelu. Blíže bude tato metoda popsána v další kapitole Určování vláhové potřeby.

7.3.3 MIKROVLNNÁ ČÁST ELEKTROMAGNETICKÉHO SPEKTRA

Klíčovým poznatkem, na kterém je založeno měření vlhkosti v mikrovlnné části spektra je velký rozdíl mezi dielektrickými vlastnostmi vody a suché půdy. Dielektrické vlastnosti lze popsat dielektrickou konstantou. Tuto změnu pak lze detekovat mikrovlnnými senzory. Obecně platí, že vysoké hodnoty této konstanty způsobují vysoké hodnoty zaznamenaného odraženého signálu. Pro odvození půdní vlhkosti se nejčastěji používá pásem mikrovlnného spektra L – 150–300 mm (1-2 GHz) a C – 37,5–74,9 mm (4-8 GHz). V závislosti na použité vlnové délce mikrovlnného záření lze získat informace o vlhkosti z hloubky několika centimetrů půdního profilu, přičemž platí, že čím vyšší vlnová délka (nižší frekvence) tím větší průchod půdním materiálem a možnost detekovat vlhkost ve vyšších hloubkách. Z hlediska detekce půdní vlhkosti nejvíce signál negativně ovlivňují drsnost povrchu a vegetační složka. Rušivý efekt obou těchto vlastností povrchu se také snižuje s použitím delších vlnových délek.

Vzhledem k tomu, že je množství vyzářené mikrovlnné energie ze zemského povrchu příliš malé, odpovídá tomu také malé prostorové rozlišení vytvořených družicových snímků (v řádu desítek km). Pasivní metody lze tedy použít pouze pro mapování na globální či regionální úrovni. Příklady mohou být systémy SMOS (*Soil Moisture and Ocean Salinity*) či SMAP (*Soil Moisture Active Passive*). Tuto slabinu může kompenzovat naopak vyšší časové rozlišení. Vzhledem k tomuto faktu se často používají aktivní systémy, které používají vlastní zdroj elektromagnetického



Obrázek 31: Referenční evapotranspirace (ET_0), plodinná evapotranspirace při standardních podmínkách (ET_c) a při nestandardních podmínkách ($ET_{c\ adj}$)

záření a vysílají tedy krátký a intenzivní mikrovlnný signál směrem k povrchu a po odrazu zaznamenávají jeho navrácenou část. Obecně lze říci, že větší hodnoty intenzity signalizují vyšší vlhkost. Nejčastěji používaným zařízením je radar se syntetickou aperturou (SAR). Systémy SAR mohou poskytovat rozlišení v řádu desítek metrů při šířce záběru 50–500 km. Nicméně vzhledem k úzkému záběru je pak limitováno rozlišení časové.

Teoretické (fyzikální) přístupy pro vyhodnocení radarových dat jsou založeny na difrakční teorii elektromagnetických vln. Odrazový koeficient je predikován na základě známé charakteristiky drsnosti povrchu půdy. Tu je potřeba znát (z pozemních pozorování) nebo ji odvodit s pomocí měření různé polarizace. Problematické je rovněž měření při vzrostlém porostu, který signál ovlivňuje komplexně a je velice obtížné vliv porostu (a vlhkosti porostu) odstranit. Nicméně tyto metody založené na empirických, semiempirických či fyzikálních vztazích jsou v dnešní době nejslibnějšími metodami pro mapování vlhkosti.

7.4 URČOVÁNÍ VLÁHOVÉ POTŘEBY

Data DPZ mohou být použita i pro určení, respektive odhad, vláhové potřeby rostlin. Aktuální potřeba závlahového množství je dána vývojem plodiny, různou dynamikou vláhového režimu půdy a počasím, což vše odráží průběh aktuální evapotranspirace (ET) plodin. Hodnoty ET, resp. tzv. plodinových koeficientů, je v současné době možné téměř v reálném čase úspěšně stanovit ze satelitních dat prostřednictvím vegetačních indexů (NDVI, EVI, aj.) (Marshall et al. 2016, Pôças et al. 2015) nebo hodnot tzv. globální radiace (Bastiaanssen et al. 1998), jak je realizováno již v poloprovozních podmínkách v řadě zemí při závlaze polních plodin (Calera et al. 2017, Vuolo et al. 2015). Jednou z nejrozšířenějších metod pro stanovení vláhové potřeby je metodika FAO 56 (Allen et al. 1998, Pereira et al. 2015, Sims et al., 2017), podle níž je efektivní management závlahy klíčovou otázkou udržitelného využívání vodních zdrojů. Vláhová plodinná potřeba, potažmo tzv. plodinná evapotranspirace (ET_c) je dle metodiky FAO 56 počítána z referenční evapotranspirace (ET_0) vypočtené dle metody Penman-Monteith (Monteith, 1973) vynásobením plodinovým koeficientem (K_c). Referenční evapotranspirace (evapotranspirace srovnávací plodiny či povrchu) je definována jako evapotranspirace z hypotetické plodiny a je podobná evapotranspiraci z extenzivního povrchu zelené trávy stejné výšky, aktivně rostoucí, se zcela zastíněným povrchem půdy a netrpící nedostatkem vody. V metodice FAO 56 lze nalézt tabulku plodinových koeficientů, které odrážejí stav porostu a vývojové fáze dané plodiny. K jejich určení v reálných podmínkách však mohou sloužit i data DPZ. Závlahové množství vycházející z metodiky FAO 56 je následně vypočítáváno jako rozdíl mezi plodinovou evapotranspirací a tzv. efektivní srážkou závislou na vývoji plodiny a popisovanou pomocí indexu listové plochy (LAI) a pokrývnosti plodiny (fractional vegetation cover).

7.4.1 ODHAD HODNOT EVAPOTRANSPIRACE Z DAT DPZ

Metody odhadu hodnot evapotranspirace z dat DPZ zahrnují tři základní přístupy (Calera et al., 2017). Prvním z těchto přístupů je odvození plodinového koeficientu (Kc) využívající přímý a kvantifikovaný vztah mezi hodnotami tohoto koeficientu a vegetačními indexy získanými z optických spektrálních dat. Dalším přístupem je odvození parametrů Penman-Monteith rovnice z dat DPZ, konkrétně na základě stanovení indexu listové plochy (LAI), výšky porostu a povrchového albeda (odrazivosti). Třetím přístupem je využití termálních dat pro modely energetické bilance.

7.4.1.1 ODVOZENÍ PLODINOVÉHO KOEFICIENTU Z DAT DPZ

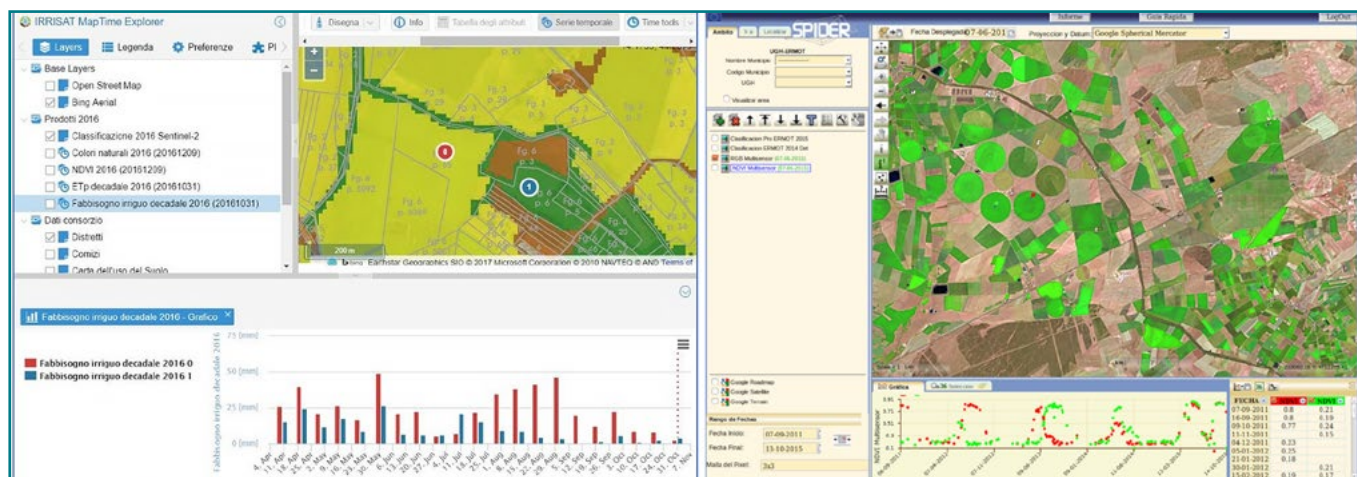
Plodinový koeficient je běžně získáván z pozemního hodnocení vývoje plodiny a její fenologické fáze s využitím tabelárních hodnot reportovaných v metodice FAO 56. Plodinový koeficient lze tak vnímat jako zástupce parametrů popisujících vývoj plodiny, tj. LAI (index listové plochy), celkovou odrazivost a výšku plodiny. Tyto parametry rovněž ovlivňují spektrální chování vegetací pokrytého povrchu a pomocí spektrálních dat je tak možné odvozovat hodnoty plodinového koeficientu (Drerup et al. 2017, Garrido-Rubio et al. 2018, Pôças et al. 2015, Vuolo et al. 2015). Přímý vztah mezi plodinovým koeficientem a hodnotami vegetačních indexů odvozených z multispektrálních dat DPZ je již dlouhou dobu empiricky ověřen (Kasampalis et al., 2018). Jelikož se používá koncept v tomto opírá o empirické vztahy je zapotřebí tyto vztahy odvozovat pro dané území a dané plodiny. V rámci určování plodinových koeficientů lze zvolit jednoduchý nebo tzv. duální přístup k odvození hodnoty Kc. V jednoduchém přístupu jsou plodinová transpirace a půdní evaporace časově průměrovány do jednotného koeficientu (Kc). V duálním přístupu jsou uvažovány oddělené koeficienty Kcb, značící denní basální plodinový koeficient a Ke reprezentující koeficient denní půdní evaporace. Výsledně tedy $Kc = Kcb + Ke$ (Pôças et al. 2015).

7.4.1.2 ODVOZENÍ PARAMETRŮ PENMAN-MONTEITH ROVNICE Z DAT DPZ

Penman-Monteith rovnice může být využita pro přímý výpočet evaporace z půdy a transpirace z listů rostlin pomocí pozemně měřených meteorologických veličin (teplota, relativní vlhkost, rychlost větru a intenzita přichozího krátkovlnného záření) a dalších přímo měřitelných parametrů. Model využívá předpoklad, který uvažuje porost jako jednotnou vrstvu (tzv. „big leaf“), která je charakterizována listovou plochou (LAI), výškou porostu (hc) a albedem (r), které je nutné pro výpočet radiační bilance (Rn). Tyto parametry je možno získat z analýzy multispektrálních dat DPZ. Index listové plochy (LAI) lze získat z dat DPZ na základě využití odvozených vztahů mezi hodnotami LAI a vegetačními indexy, případně na základě některých modelů založených na strojovém učení. Výška porostu je buď brána jako konstantní nebo opět vychází ze vztahů mezi LAI a výškou plodiny, protože tyto spolu korelují. Albedo je následně počítáno jako širokopásmová odrazivost, tedy vážený průměr odrazivosti v několika spektrálních pásmech. Při využití těchto parametrů a měřených meteorologických veličin lze následně vypočítat evapotranspiraci. Byť je tento postup výpočetně komplikovaný, je obecně vhodný z hlediska možnosti validace s pozemně měřenými hodnotami a je využíván v aplikační sféře v již běžících nástrojích v Itálii, Rakousku či Austrálii (Vuolo et al. 2015).

7.4.1.3 VYUŽITÍ TERMÁLNÍCH DAT DPZ PRO MODEL Y ENERGETICKÉ BILANCE

Přístupy výpočtu intenzity evapotranspirace pomocí energetické bilance odvozují energetické toky z rovnice energetické bilance aktivního povrchu, na němž probíhá fázová změna kapalné vody na vodní páru. Pomocí DPZ lze získat vstupy do této rovnice na základě odvození primárních a sekundárních veličin, a to zejména dvousměrové (bi-hemispherical) odrazivosti povrchu a radiometrické teploty povrchu, kterou lze odvodit z termálních snímků a je využitelná pro výpočet toku zjevného tepla. Na základě teplotní mapy povrchu, znalosti povrchu a výsledků



Obrázek 32: Ukázka systémů pro odhad vláhové potřeby – italský IRRISAT a španělský SPIDER

z kalibračních stanic potom lze s dostatečnou přesností odhadnout (vypočítat) energetické toky i mimo kalibrační body (Calera et al. 2017). K určování teploty povrchu se využívá zejména termálních pásem obrazových senzorů. Přesnost jejího určení je závislá na přesném určení emivity povrchu a velice důležité je i provedení precizních atmosférických korekcí vstupních termálních snímků. Důležité je rovněž precizní měření a určení měřených vstupních meteorologických veličin a jejich dostatečná prostorová reprezentativnost. Dalším kritickým předpokladem ve využívání popsaného principu je možnost získání dat s dostatečným prostorovým a časovým rozlišením. Zejména velké časové rozestupy a horší prostorové rozlišení jsou hlavním limitem pro operační využití (Liou & Ka 2014), stejně jako komplexita algoritmů postavených na popsaném principu (Vuolo et al. 2015, Wang et al. 2019).

7.4.2 DATA VHDNÁ PRO POUŽITÍ PŘI ODHADU EVAPOTRANSPIRACE

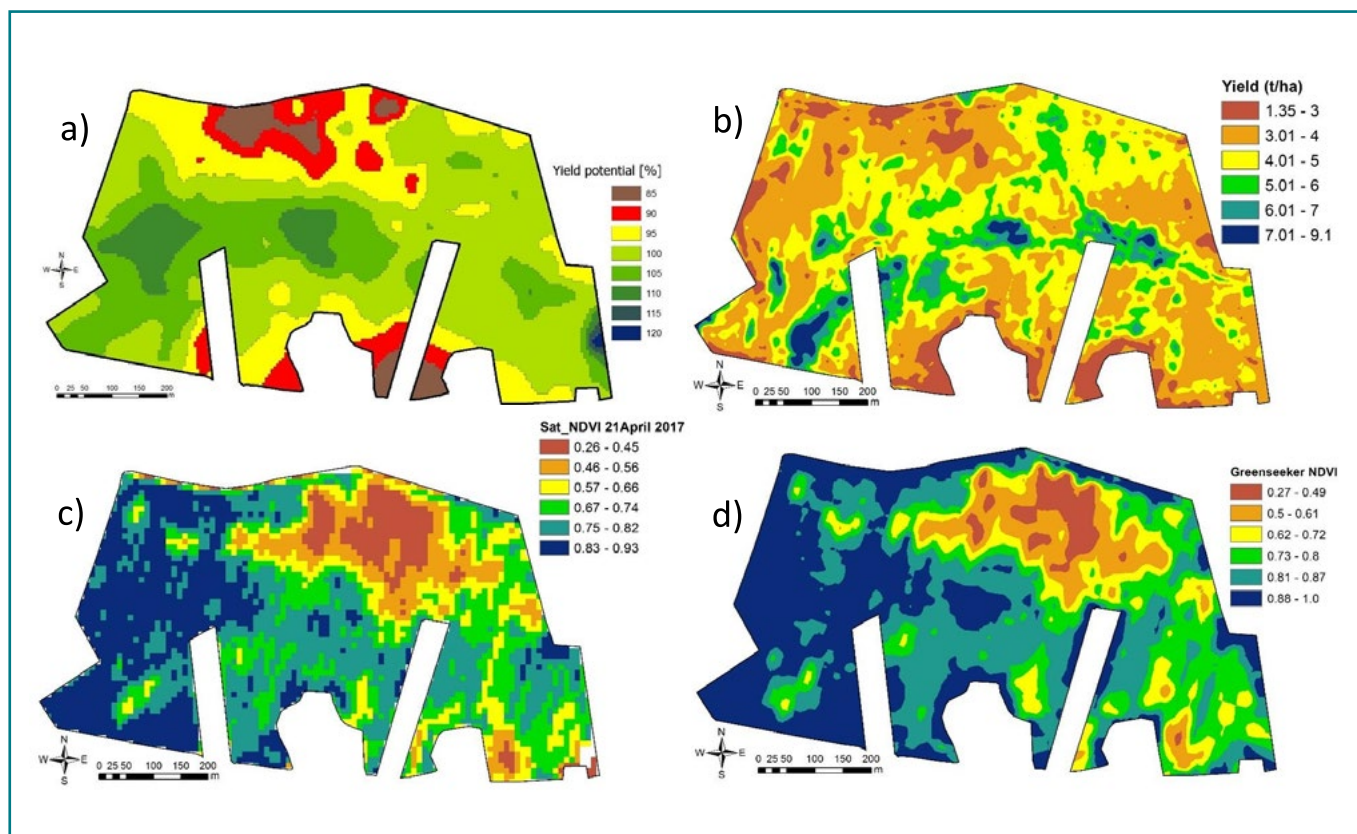
Operabilní použití dat DPZ pro závlahový management vyžaduje data s vhodným časovým a prostorovým rozlišením, tak aby bylo možné podrobně popsat fázový vývoj plodin a zároveň popsat variabilitu porostu v rámci půdních bloků. Z tohoto pohledu jsou přístupy využívající satelitní termální data omezeny pouze na globální a regionální měřítko, jelikož se jejich prostorové rozlišení pohybuje v řádu 100 (TIRS – Landsat 8) – 1000 m/px (SLSTR – Sentinel 3, MODIS – TERRA). Budoucí rozvoj v této oblasti však lze očekávat. Od roku 2018 je například na Mezinárodní vesmírné stanici umístěn experimentální multispektrální termální senzor ECOSTRESS, který má asymetrický pixel o velikost cca 38x69 m. Časové rozlišení je 1 den. Další termální multi- a hyperspektrální senzory jsou aktuálně ve vývoji. Využívány jsou tak hlavně přístupy přes získání vegetačních indexů pomocí kontinuálně snímaných dat ve viditelném a blízkém infračerveném spektru s vysokým rozlišením. Vhodné pro využití jsou zejména volně dostupné satelitní snímky z programů Landsat a evropského programu Copernicus z družic Sentinel 2. Možné je také využít tzv. virtuální konstelace a zkombinovat data z více zdrojů.

Tak je možné získat data s odstupem 2–5 dní. Tento časový krok je obvykle uvažován jako dostatečný pro monitorování fázového vývoje plodin v rámci vegetační sezóny (Vuolo, D'Urso, et al., 2015). Vlivem výskytu oblačnosti se interval prodlužuje, nicméně i tak je možno zajistit dostatečnou kontinuitu dat. K analýzám je možné rovněž využít dat z komerčních zdrojů, např. data s velmi vysokým rozlišením (WorldView, Rapid Eye, Pléiades, Deimos, GeoEye). Jejich nevýhodou je ovšem zejména absence kontinuálního snímání a velké náklady na jejich pořízení.

S výhodou ovšem mohou být použity i bezpilotní prostředky vybavené adekvátní senzorovou technikou. Využití bezpilotních prostředků přináší výhody zejména s ohledem na velmi vysoké rozlišení snímků a operabilitu v otázce pořízení snímků. Nevýhodou pak může být obtížnější zpracování snímků zejména s ohledem na jejich kalibraci. Vzhledem k výbornému až subcentimetrovému rozlišení je možné sledovat charakteristiky porostu v mnohem větším detailu, což může být užitečné hlavně v produkci zeleniny. Drony byly pro odhad evapotranspirace využity již v několika studiích (Gago et al. 2015, Gonzalez-Dugo et al. 2013, Tang et al. 2019, Zhang et al. 2019).

7.4.3 EXISTUJÍCÍ SLUŽBY A APLIKACE

Výše zmíněných dat a přístupů využívají některé lokální systémy pro plánování a předpovídání potřeby závlah přenášející výsledné informace k uživatelům pomocí webových GIS nástrojů a aplikací. Přestože technická realizace nástrojů pro vláhový management na bázi využití satelitních dat je velice komplexním procesem, lze zmínit již některé funkční systémy jako IRRISAT (Itálie), EO4Water (Dolní Rakousko), IRRiEYE (jižní Austrálie) založené na odvození parametrů P-M rovnice nebo IrriSat-SMS (Austrálie), TOP-SIMS (Kalifornie), SPIDER (Španělsko, Portugalsko) založené na vegetačních indexech. Tyto systémy jsou již běžně zemědělci využívány v praxi (Rakousko, Itálie, Španělsko, Austrálie, USA, J. Amerika). Analýzu nákladů a benefitů z některých těchto systémů provedli Vuolo et al. [2015].



Obrázek 33: Příklad mapování nevyrovnanosti 40ha pozemku s pšenicí ozimou ve velmi suchých podmínkách (Dolní Dubňany / Dukovany, 2017). Zatímco mapa produkčních zón (a) z časové řady družicových snímků vykazuje obdobné členění méně výnosných zón jako výnosová mapa (b) z toho roku, aktuální stav porostu hodnocení pomocí NDVI ze Sentinel 2 (c) a senzoru Greenseeker (d) z druhé poloviny dubna 2017 vykazoval mírně odlišné rozložení (Neudert and Lukas 2017).

7.5 VYUŽITÍ DPZ PRO NÁVRH VARIABILNĚ PROVÁDĚNÝCH PĚSTEBNÍCH ZÁSAHŮ

Při tvorbě podkladů pro variabilní provádění pěstebních zásahů se vychází z mapování prostorové nevyrovnanosti nejruznějšími metodami a následné kombinace výsledných mapových záznamů. Stanovení intenzity zásahu může vycházet z **měření aktuálního stavu** daného agronomicky významného jevu, jako je stanovení zásobenosti půdy živinami z půdního vzorkování pro aplikaci zásobního hnojení, hodnocení výživného stavu ze spektrálních měření plodinových senzorů pro variabilní přihnojování porostů, měření elektrické vodivosti půdy pro variabilní zpracování půdy, snímkování pomocí bezpilotních prostředků pro hodnocení zaplevelení a přípravu cílené aplikace herbicidů apod.

Druhým přístupem při tvorbě aplikačních map je **zohlednění dlouhodobých trendů produktivity** půdy. Jedná se o tradiční postup agronomického rozhodování v podobě očekávaného výnosu plodin, který je v případě precizního zemědělství zpřesněn do podoby **vymezení výnosových hladin** v rámci jednotlivých pozemků. Informace o výši očekávaného výnosu plodiny je významná pro agronomické rozhodování. Běžnou praxí je kalkulace průměrné hodnoty pro celý pozemek, na nevyrovnaných pozemcích ale tento postup znamená chybné nastavení intenzity zásahu, které se může projevit např. přehnojením porostů na méně produktivních plochách, a naopak nedostatečnou aplikaci hnojiv na místech s nadprůměrnou produkcí.

V mnoha případech je ideální **kombinovat** tyto dva přístupy, kdy např. u stanovení dávky dusíkatého hnojení se vychází z pokrytí potřeby odběru N na očekávanou úroveň výnosu v dané části pozemku, odvozené z víceletých výnosových map, a tato dávka je korigována dle diagnostiky výživného stavu rostlin pomocí spektrálních měření plodinovými senzory (tzv. režim map overlay) nebo metodami dálkového průzkumu. Výsledek prostorového členění stavu porostu z průběžného monitoringu se totiž může odlišovat od rozložení konečných výnosových hladin (obrázek 33).


7.5.1 IDENTIFIKACE PRODUKČNÍCH ZÓN

Podstatou identifikace produkčních jednotek v rámci jednotlivých pozemků je přizpůsobení agrotechniky lokálním podmínkám stanoviště a určení intenzity pěstebních zásahů pro jednotlivé části pozemků, tzv. management zóny, s ohledem na jejich nevyrovnanost. Běžný způsob identifikace produkčních zón vychází z identifikace podprůměrně a nadprůměrně výnosných částí pozemků z víceletých výnosových map (Blackmore 2000, Kleinjan et al. 2007). Ucelený sběr výnosových záznamů sklízecí technikou je však v zemědělských podnicích spíše výjimečný a výsledné výnosové záznamy vyžadují pokročilé postupy filtrace odlehých a chybných hodnot.

Alternativní postup představuje vymezení produkčních zón včetně kvantifikace odchylky od průměru pozemku na



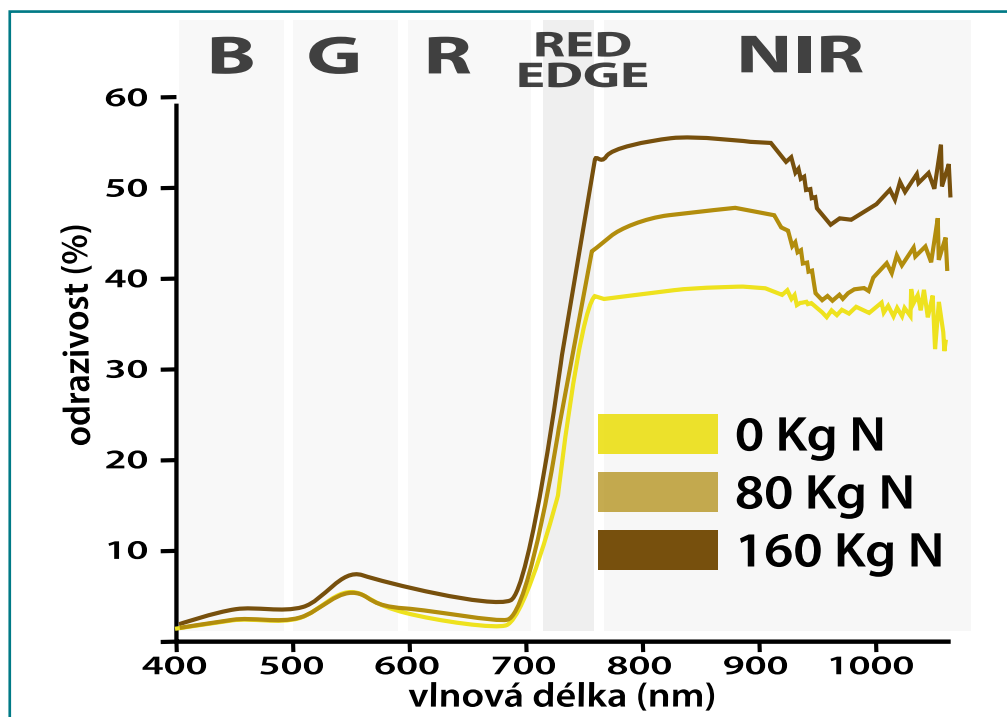
Obrázek 34: Vymezení produkčních zón z družicových snímků vychází z hodnocení zapojení stavu porostů v jednotlivých ročních – méně produkční místa vykazují opakovaně nižší hodnoty vegetačních indexů (příklad NDVI ze Sentinel 2) (Lukas, V., 2021)



Obrázek 35: Dostupnost družicových snímků umožňuje stanovit produkční zóny za velké území – příklad vymezení produkčních zón pro ČR za období 2013–2020 vytvořený ve spolupráci MENDELU a Lesprojekt-slужby s.r.o. (dostupné na www.agrihub.cz)

základě prostorové analýzy časové řady multispektrálních družicových dat. Vymezení zón relativního výnosového potenciálu vychází z analýzy víceleté řady družicových dat.

Jedná se o alternativu pro případy absence dat z mapování výnosů při sklizni plodin, ať z důvodu nedostupnosti dostatečného technického vybavení sklízecích mlátiček, anebo



Obrázek 36: Rozdíl odrazivosti porostu pšenice ozimé v BBCH 39 při různé úrovni výživy N (upraveno dle Edrees et al., 2013). Vodorovná osa vyjadřuje oblasti elektromagnetického záření dle vlnové délky (UV – ultrafialové, B – modré, G – zelené, R – červené, RE – red edge, NIR – blízce infračervené)

pro plodiny, jejichž měření výnosu při sklizni není rozšířeno (silážní kukuřice, pícniny, okopaniny a další skupiny plodin). Relativní výnosový potenciál je vypočten jako procentuální vyjádření dosažené produktivity na daném místě vůči průměrné hodnotě za celý pozemek; vždy jednotlivě pro každé sledované vegetační období s následným zprůměrováním za celou časovou řadu dat. Bližší popis postupu výpočtu produkčních zón uvádí Lukas et al. [2018].

V případě využití dat DPZ je základním principem hodnocení analýza nevyrovnanosti porostů ve vybraných částech vegetačního období na základě vegetačních indexů a kvantifikace vůči průměrné hodnotě pozemku v daném termínu sledování. Výsledkem je identifikace výnosově podprůměrných nebo nadprůměrných oblastí na pozemcích napříč sledovanými ročníky. Toto stanovení lze provést pro jakékoli území pokryté dostatečným počtem bezoblačných družicových snímků a digitálním zmapováním hranic pozemků (např. registr zemědělské půdy LPIS) doplněné o základní agronomickou evidenci pěstovaných plodin. V případě dostupnosti výnosových map lze procentuální rozpětí relativního výnosového potenciálu korigovat o reálně zmapované výnosy na daném území.

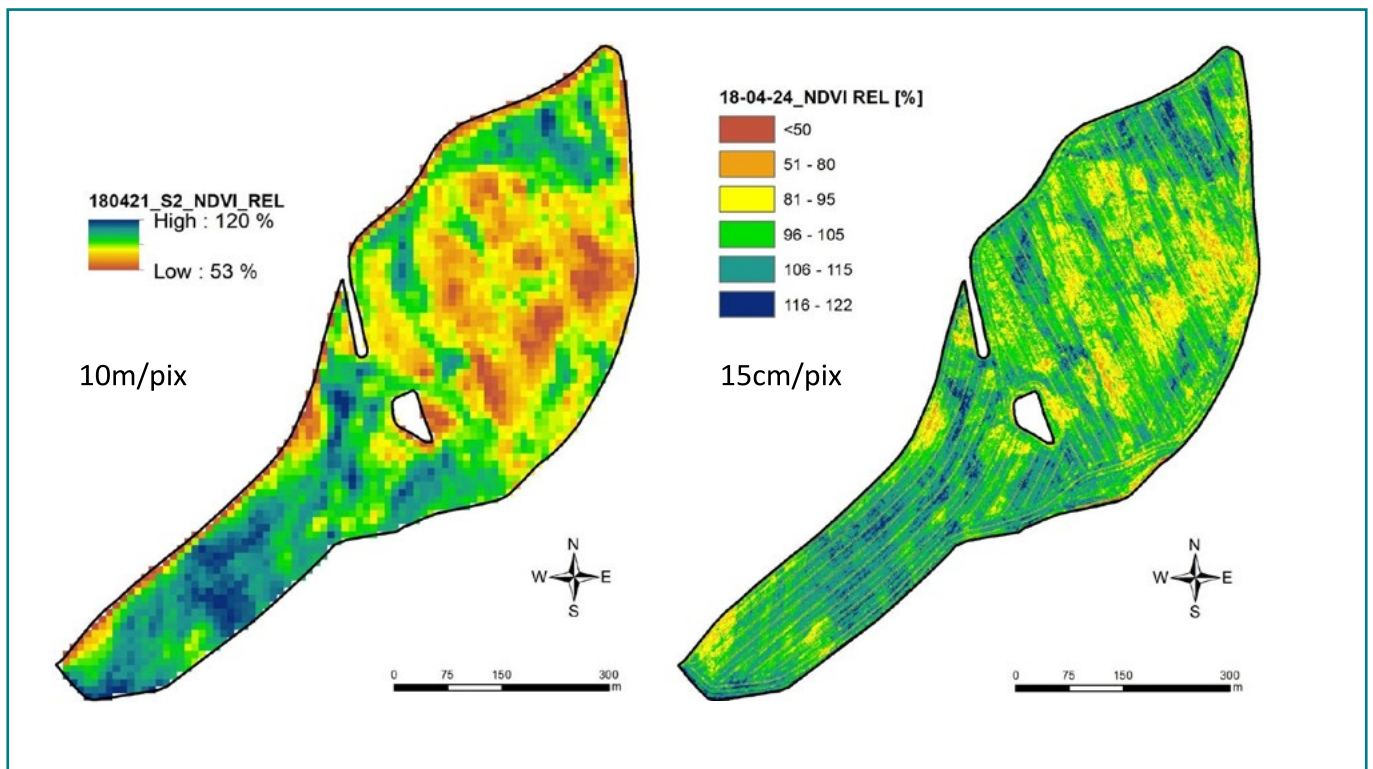
7.5.2 DIAGNOSTIKA VÝŽIVNÉHO STAVU POROSTU A VARIABILNÍ APLIKACE HNOJIV

Senzorovou diagnostiku porostů plodin na principu spektrálního měření lze využít k odhadu strukturního stavu porostu a obsahu dusíku v rostlinách, např. pomocí vegetačních indexů získaných z pozemních on-the-go plodinových senzorů


nebo dálkového průzkumu Země. Na základě odvození obsahu chlorofylu v rostlinách je možné připravit předpisové mapy pro cílenou aplikaci dusíkatých hnojiv. Zjednodušeně lze říci, že dusíkatá výživa působí na odrazivost porostu dvojnásobkem: (1) zvyšuje obsah chlorofylu v listech, (2) má vliv na růst rostlin (množství biomasy) a tedy LAI (obrázek 36). Pro úspěšné využití optických metod při řízení výživy dusíkem je důležité zachytit oba tyto parametry, nejčastěji pomocí vegetačních indexů. Oba tyto parametry lze vyjádřit množstvím chlorofylu na jednotce plochy. Optimalizace dávky dusíku se provádí dle jeho obsahu v rostlinách, který s obsahem chlorofylu vykazuje lineární regresi.

Odborná literatura uvádí řadu vegetačních indexů, které lze využít pro diagnostiku stanovení výživného stavu rostlin a stresových projevů (Fu et al. 2014, Li et al. 2014). Popis nejvýznamnějších z nich je uveden v kapitole zabývající se spektrálními indexy. Nejčastěji využívaným vegetačním indexem je Normalizovaný diferenční vegetační index (NDVI), který je vypočten z odrazivosti z červené a blízce infračervené části elektromagnetického záření. Pokročilejší systémy detekují záření v úzké red-edge oblasti, jako je např. vegetační index NDRE, NRERI nebo Red Edge Inflection Point (REIP).

Výsledky polních pokusů s ozimou pšenicí a jarním ječmenem ukázaly, že vyšší hodnoty NDVI indikují větší množství biomasy, hmotnost rostlin, vyšší počet rostlin na m², počet odnoží na rostlinu a lepší výživný stav (vyšší obsah chlorofylu), které se následně projevily na dosažení vyššího výnosu plodin (Křen et al. 2009). Vztah mezi hustotou porostu a NDVI není lineární, neboť NDVI vykazuje tzv. nasycení při



Obrázek 37: Porovnání družicového (Sentinel 2) a bezpilotního (Red-Edge MX) snímkování v podobě relativní hodnoty NDVI (20ha pozemek ZD Kojčice, 2018, Pelhřimov)



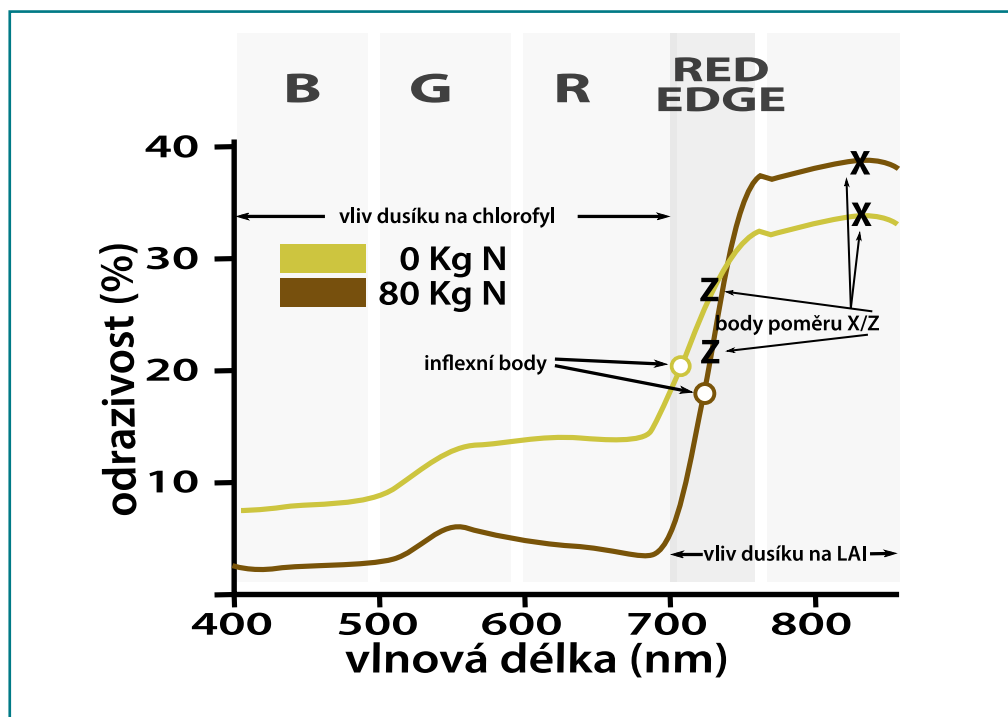
Obrázek 38: Porovnání vztahu odběru N rostlinami (Nupt) s vegetačními indexy NDVI a REIP (Sentinel 2, různé lokality 2017-2020). Vegetační index NDVI jednoznačně vykazuje saturační efekt (Mezera et al., 2020)

vysoké hustotě porostu (Baret & Guyot 1991). Při dosažení určitého stupně indexu listové pokrývnosti (LAI – leaf area index), které odpovídá množství nadzemní biomasy, se již NDVI nemění, dochází k saturačnímu efektu, kdy zvyšující se hustota porostu již není pomocí NDVI indikována. Tento jev nastává při hodnotě LAI mezi 1 až 3, příp. 2 až 6, podle typu a pokrývnosti vegetace (Lilienthal 2003). Vegetační indexy využívající red-edge spektrální pásma jsou více citlivé na změny v obsahu chlorofylu v rostlinách a netrpí jako NDVI saturačním efektem (viz obrázek 38).

Red-edge pásmo využívá také vegetační index NRERI, který Klem et al. (2014) doporučují pro stanovení výživného stavu obilnin, konkrétně ječmene jarního pro sladovnické účely. Index je vypočítán jako normalizace pásem červeného, red-edge a blízkého infračerveného spektra dle rovnice:

$$NRERI = (R780 - R720) / (R780 - R680)$$

Autoři popisují vysokou citlivost NRERI ve vztahu k dusíkaté výživě a ke struktuře porostu (hustota, nadzemní biomasa



Obrázek 39: Vliv aplikace N v období produkčního hnojení na odrazivost ozimého žita a posun inflexního bodu v red-edge oblasti (upraveno dle Heege et al.,2008).

a index listové plochy LAI) v širokém rozsahu vyskytující se hodnot dusíku. Současně normalizovaný výpočet dvou pásem R a NIR zajišťuje robustnost vůči změnám světelných podmínek. V rámci publikované metodiky je uveden postup hodnocení výživného stavu ječmene pomocí indexu výživy NNI (Nitrogen Nutrition Index), který vychází z optimální křivky závislosti mezi hmotností sušiny na jednotku plochy a koncentrací dusíku v sušině.

Modifikací NDVI indexu vznikl také vegetační index NDRE, kdy namísto pásma blízce infračerveného záření je použito red-edge pásmo. Kalkulaci, kterou ve své studii navrhli Barnes et al. (2000) využívá vlnových délek 790 nm (RE) a 720 nm (R).

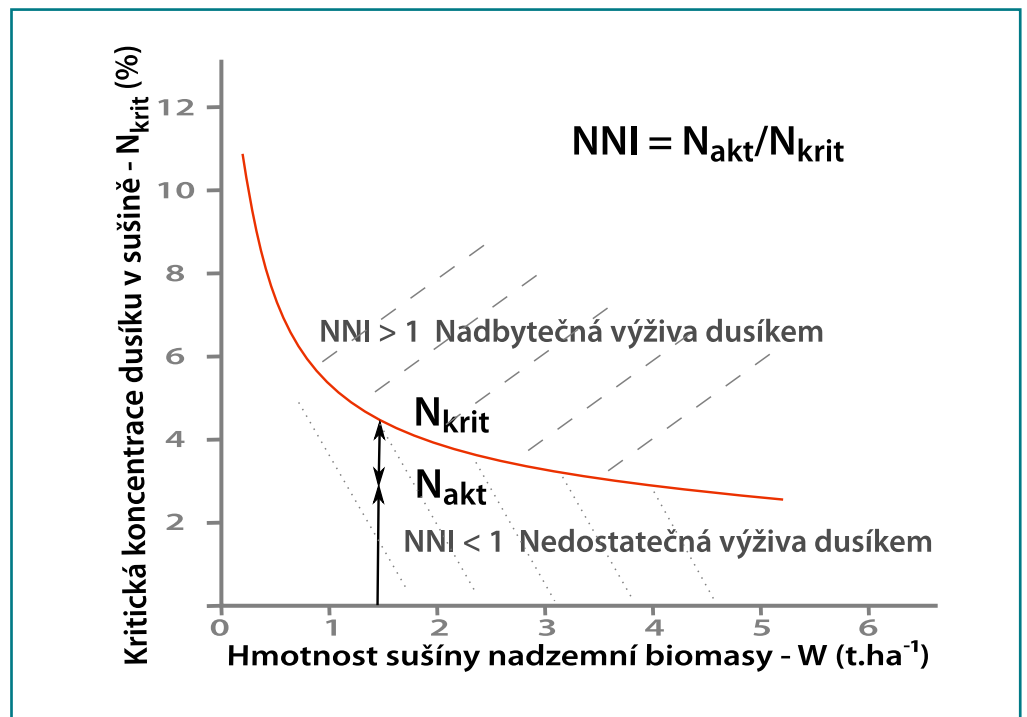
$$NDRE = (RE - R) / (RE + R)$$

Index NDRE vykazuje vyšší citlivost na změny obsahu chlorofylu a je často využíván pro stanovení výživného stavu zemědělských plodin multispektrálními senzory.

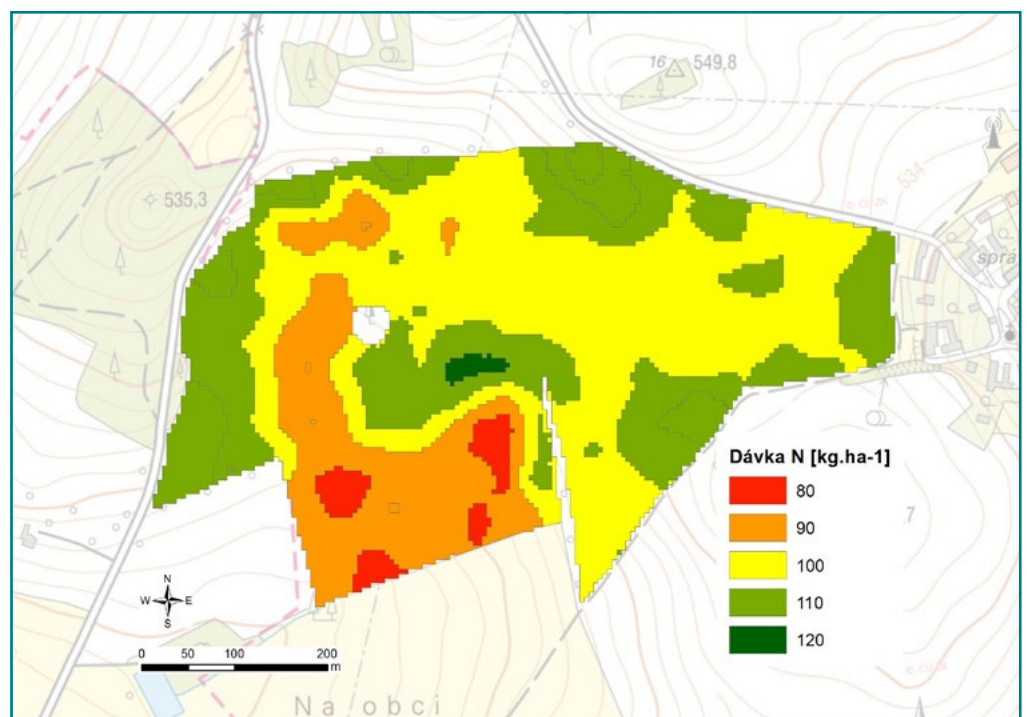
Podrobnější zachycení spektrální odrazivosti v jednotlivých vlnových délkách umožňuje kalkulaci vegetačního indexu REIP. Zjednodušený způsob výpočtu REIP vyžaduje minimálně dvě spektrální pásma v oblasti red-edge, což je vlastnost dat např. z družic Sentinel 2, ale není to běžné pro standardně dostupnou snímací techniku. Pozitivní vlastností REIP je nižší citlivost k rušivým faktorům, jako jsou odražené záření od půdního pozadí a atmosférické vlivy, a zároveň vysoká citlivost k požadovaným porostním charakteristikám (obsah chlorofylu a hustota porostu). Na rozdíl od NDVI nedochází k nasycení při vyšších hodnotách LAI.

Citlivost vegetačních indexů na koncentraci dusíku v listech rostlin byla sledována v řadě odborných studií. Podle Mariotto et al. (2013) zachycují úzkopásmové hyperspektrální senzory o 25 % vyšší variabilitu při modelování růstu rostlin a 20 % vyšší přesnost rozlišení druhů plodin v porovnání s širokopásmovými senzory. Současně bylo zjištěno, že 3–7 úzkých pásem vysvětluje přes 90 % variability v modelech plodin. Výsledky studie Heege et al. (2008) ukazují, že změna REIP o 1 nm indikovala rozdíl 15 kg N dodaným hnojením 6 týdnů před vlastním měřením. Pro určení výchozí dávky v porostu na základě optických metod je ale nutné provést kalibraci pro jednotlivé druhy plodin, odrůdy, růstové fáze a specifické stanovištní podmínky.

Strategie vyhodnocení spektrálního měření se liší dle plodiny. Implementaci vegetačních indexů pro optimalizaci výživy **ječmene jarního** podrobně popisují Klem et al. [89]. Vychází ze stanovení indexu výživy dusíkem (**Nitrogen Nutrition Index – NNI**) vegetačním indexem NRERI či NDVI a stanovení kritické koncentrace dusíku v sušině v závislosti na hmotnosti sušiny nadzemní biomasy z tzv. zřetovací křivky. Hodnoty NNI > 1 značí nadbytečnou úroveň dusíkaté výživy, NNI = 1 optimální výživný stav a NNI < 1 nedostatečnou výživu dusíkem. Pro **řepku ozimou** lze využít pro přihnojování během vegetace provedení sensorového měření na podzim, to potom stanoví dávku hnojení dle vyhodnocení pokryvnosti a hustoty porostu. Vlastní aplikace dusíkatých hnojiv pro regeneraci rostlin je pak provedena v obvyklém časně jarním termínu, který by z důvodu snížené listové plochy rostlin a špatných povětrnostních podmínek (výskyt sněhu či námrazy) výrazně znesnadňoval optické měření.



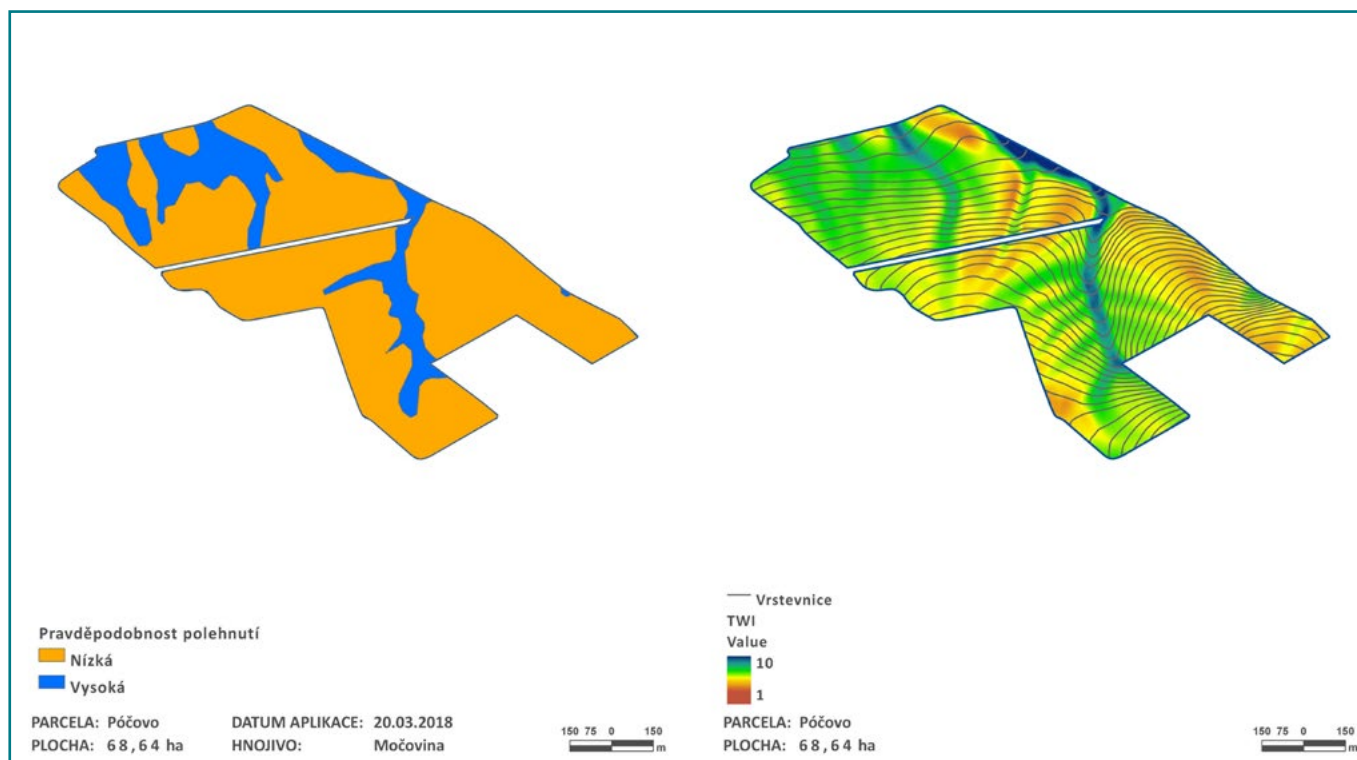
Obrázek 40: Znázornění křivky koncentrace N v rostlinách a NNI indexu (upraveno dle Klem, 2014)



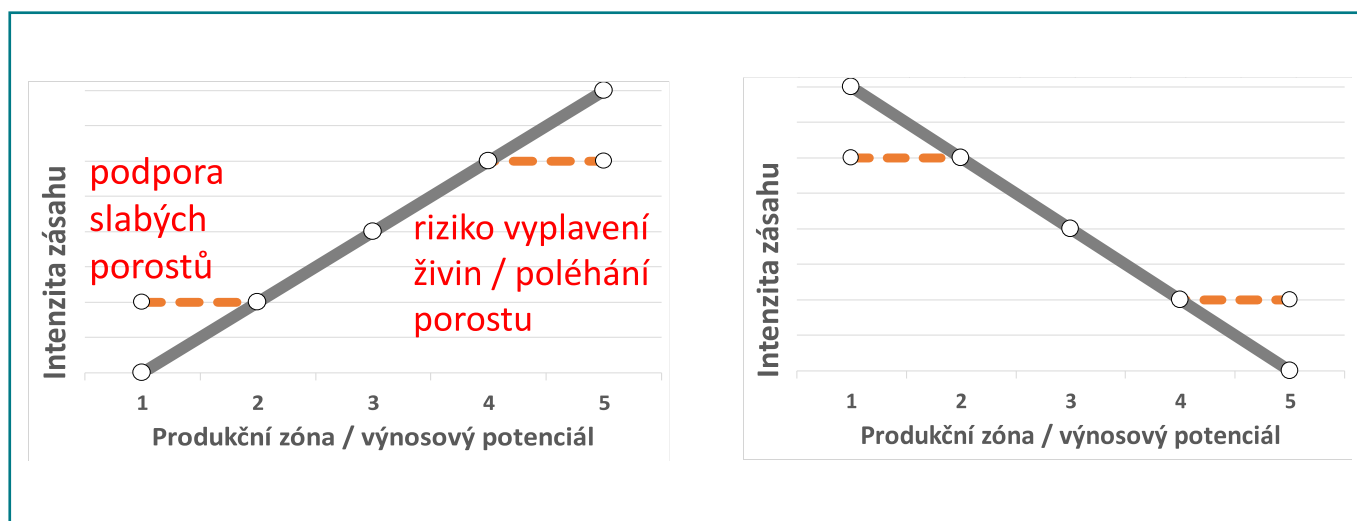
Obrázek 41: Návrh rozložení dávek produkčního přihnojení porostu dusíkatými hnojivy dusíku na základě mapy produkčních zón pro produkční hnojení ozimé pšenice (25ha pozemek, ZD Kojčice). Vyšší úroveň výživy je adresována do míst s vyšším očekávaným výnosem

Jistým omezením použití vegetačních indexů pro hodnocení porostů je vyšší citlivost k půdnímu pozadí. Ta je příčinou nižší spolehlivosti stanovení dávky N v raných fázích vývoje porostu, kdy není plně zapojen, nebo u širokořádkových plodin. Nedostatek N u rostlin má na plošný vegetační index podobný vliv jako výskyt holé půdy ve snímané scéně. Aplikátor nedostatek N kompenzuje zvýšením aplikační dávky, což v tomto případě znamená zbytečné přehnojení.

Pro přihnojení v raných fázích lze z důvodu méně spolehlivé diagnostiky stavu rostlin využít pouze mapu produkčních zón. Cílem je hnojením podpořit porost s předpokladem dosažení vyššího výnosu. Naopak na místech s obvykle dosahovaným nižším výnosem je dávka snižována. Nedochozí tedy ke srovnání porostu aplikací zvýšené dávky u porostu v horší kondici, ale k diferenciaci dle rozložení očekávaného výnosu. Výše maximální dávky je stanovena s ohledem na odběr živiny a průběhu



Obrázek 42: Mapy s identifikací míst s vysokou pravděpodobností poléhání porostu (vlevo) na základě reliéfu terénu z DEM (vpravo), v tomto případě klasifikací topografického vlhkostního indexu TWI (Neudert et al., 2018).



Obrázek 43: Strategie stanovení dávky N – posilovací (vlevo) a kompenzační (vpravo) (Lukas, 2021)

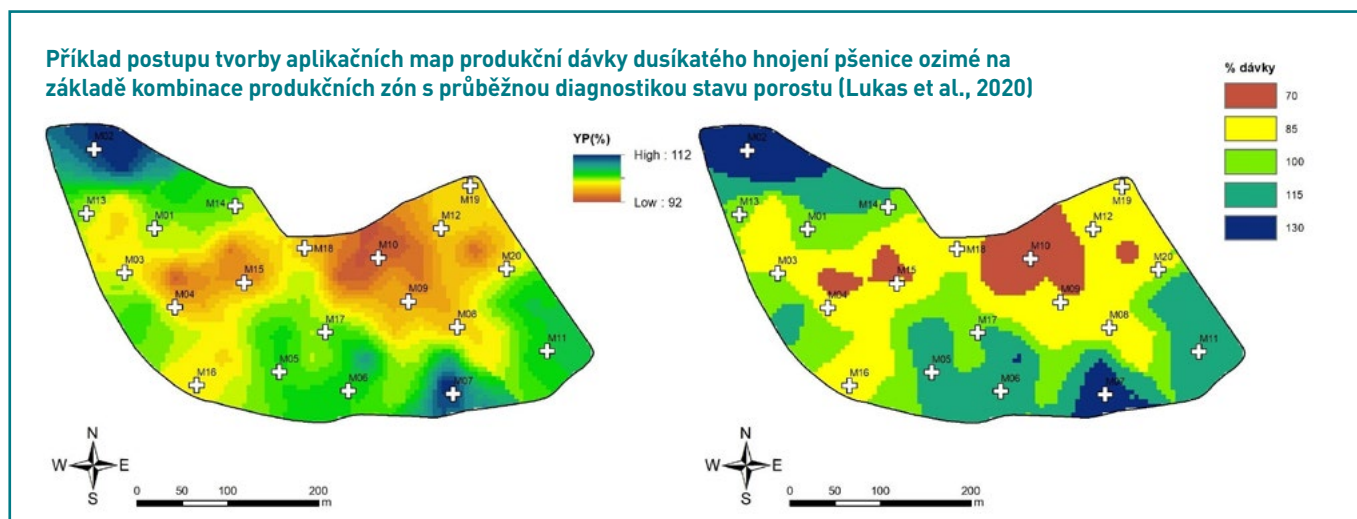
povětrnostních podmínek v daném roce. V oblastech s opakovaným výskytem poléhání porostu lze doporučit významné snížení úrovně hnojení, pro vymezení těchto míst lze využít mapu produkčních zón v kombinaci s reliéfem terénu (DEM – Digital Elevation Model). V zónách s nejvyšším výnosovým potenciálem v terénních depresích lze doporučit snížení dávky hnojení z důvodu akumulace dusíku ze svažitých částí pozemku.

Z hlediska strategie stanovení dávky variabilní aplikace rozlišujeme dva přístupy a jejich možné kombinace (obrázek 43):

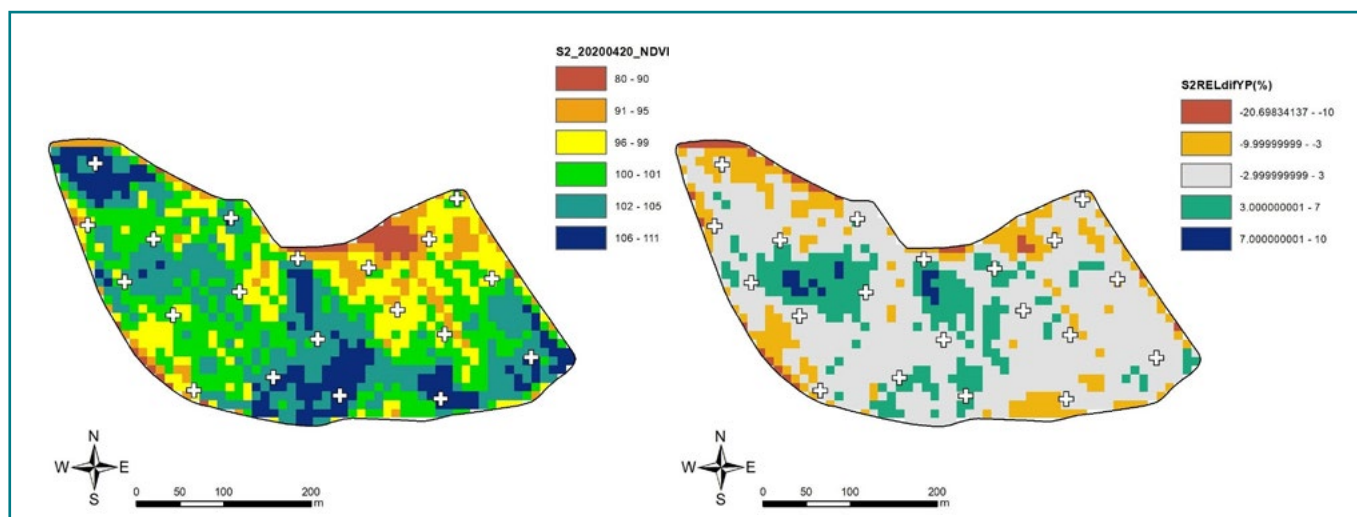
- **Strategie posilovací (aditivní)** – S vyšší hodnotou očekávaného výnosu se zvyšuje intenzita zásahu. Úprava

extrémních hodnot dle aktuální situace (riziko poléhání porostů, výsušné stanoviště, podpora slabých porostů apod.). Lze využít také pro aplikaci regulátorů růstu nebo fungicidního ošetření.

- **Strategie kompenzační** – intenzita zásahu se snižuje se zvyšující se hodnotou výnosového potenciálu. Dochází k podpoře výnosově slabých míst a k homogenizaci nevyrovnanosti. Opět lze upravit krajní hodnoty aplikace.
- **Kombinovaná strategie** – zvyšování intenzity zásahu s vyšší hodnotou očekávaného výnosu, přičemž v maximální hodnotě produkční zóny dochází ke snížení aplikační dávky (riziko vyplavování dusíku, poléhání porostů apod.).




Obrázek 44: Výchozí podkladová mapa relativního výnosového potenciálu (vlevo) členěného po 1 % odchylky výnosu pro pozemek o výměře XX a YY ha. Body vyznačují místa pozemního průzkumu. Mapa reprezentuje dlouhodobé rozložení výnosových hladin odvozených od hodnocení kondice vegetace za posledních 8 let. Mapa vpravo znázorňuje procentuálního rozložení dávky dusíkatého hnojení, vycházející z rozložení výnosového potenciálu a na základě konzultace rozpětí dávek dusíku s agronomeem.



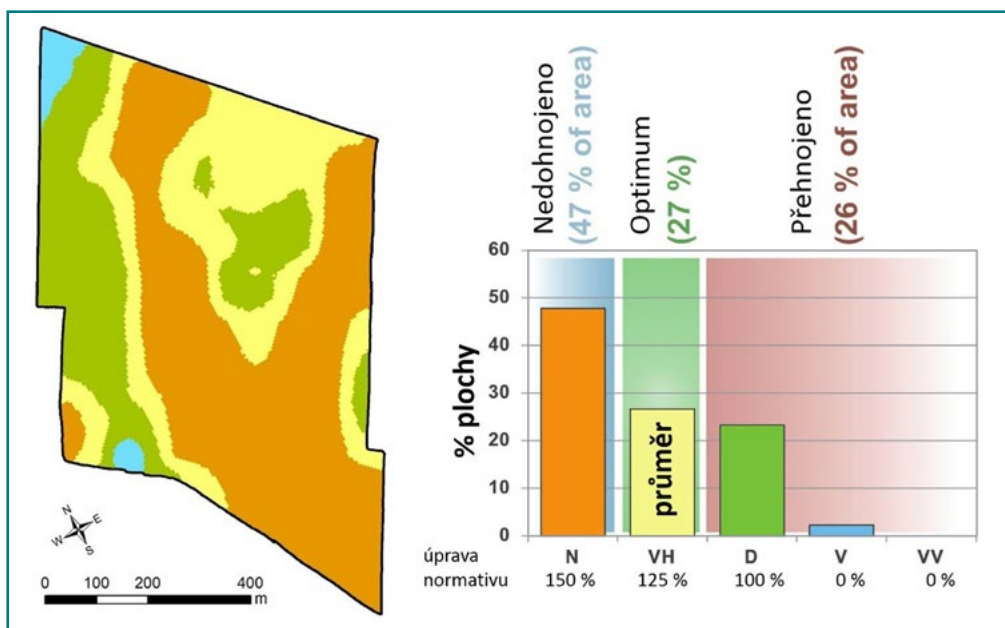
Obrázek 45: Hodnocení aktuálního stavu porostu před aplikací na základě procentuálního rozložení vegetačního indexu NDVI z multispektrálního snímku Sentinel 2 ze dne 20. 4. 2020 (vlevo). Mapa slouží pro korekci normativní dávky dané relativním výnosovým potenciálem (vpravo). Korekce vychází z rozdílu mezi relativním výnosovým potenciálem a aktuálním stavem porostu z NDVI. Kladné hodnoty, reprezentované zelenou až modrou barvou, ukazují na lepší stav porostu, než byl očekáván na daném místě dle rozložení výnosového potenciálu. Pro tyto plochy byla provedena korekce snížením aplikační dávky N. Záporné hodnoty (žluté až červené) ukazují na porost v horší kondici na místě s vyšším výnosovým potenciálem. Tato místa byla korigována zvýšením aplikační dávky pro podpoření slabých porostů v nadprůměrně výnosných plochách. Šedě obarvená plocha značí soulad aktuálního stavu porostu s relativním výnosovým potenciálem ($\pm 3\%$).

Význam variabilní aplikace minerálních hnojiv pro optimalizaci využití dodaných živin zmiňuje celá řada odborných studií. Elbl et al. (2018) poukazují na dosažení o 6 % vyšší efektivity využití dusíku při variabilní dávkování. Jin et al. (2019) ve své studii hodnotili vliv variabilní aplikace dusíkatých hnojiv pomocí simulačních modelů pro cca 2600 pozemků v USA. Z výsledků vyplývá, že (1) variabilní aplikace dusíkatých hnojiv je s těžší zisková pokud se berou v potaz pouze agronomické přínosy; (2) vyšší ziskovost lze očekávat na pozemcích s vyšší

heterogenitou; (3) benefity variabilní aplikace jsou významné, pokud se zohledňují také environmentální přínosy v podobě snížení vyplavování N a emisí N_2O ; a (4) potenciál ovlivnění časové variability (např. mezi-ročníková změna optimálního dávkování N) je více jak trojnásobný než vlastní plošná variabilita sledovaného znaku. Jednoznačnější agronomické přínosy technologií variabilní aplikace lze očekávat při začlenění i dalších postupů, jako jsou variabilní seti či variabilní aplikace přípravků na ochranu rostlin.



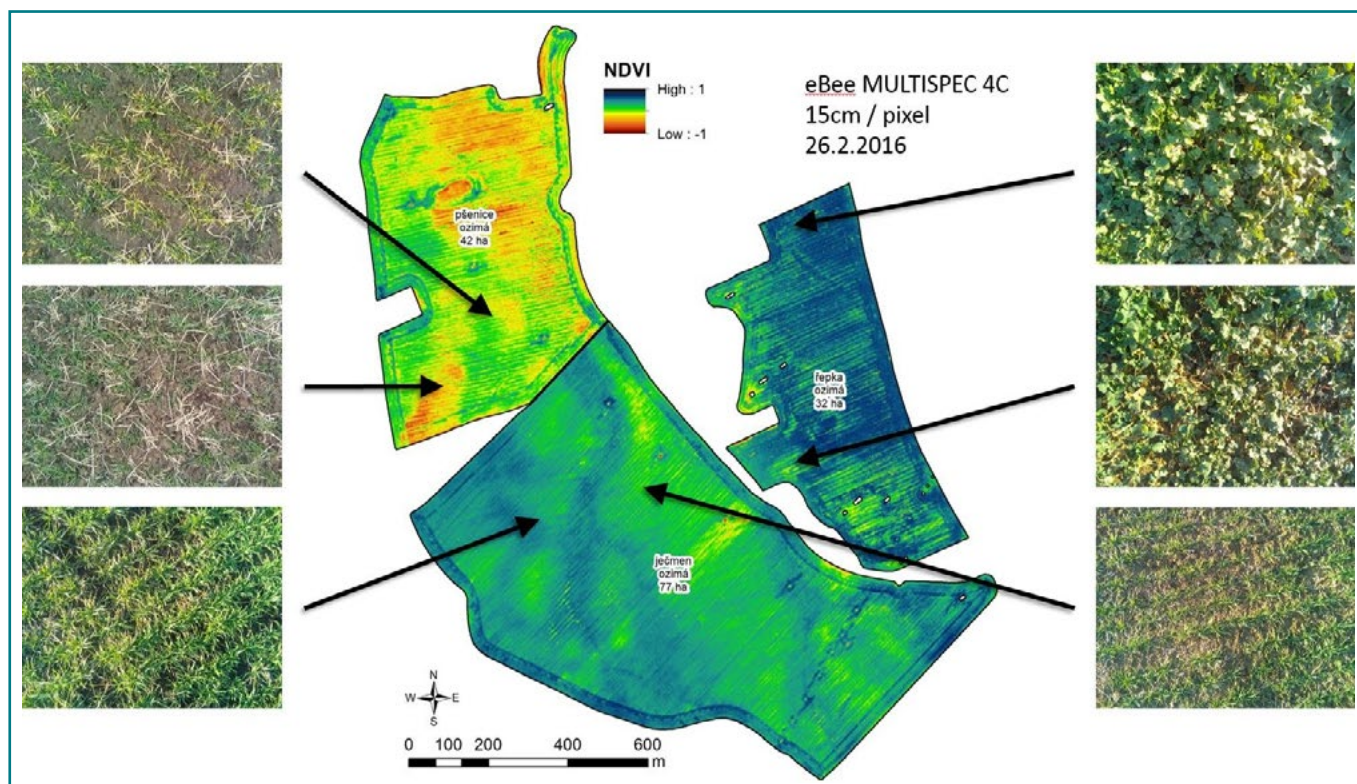
Obrázek 46: Graf s výsledky ověřování variabilního přihnojení pšenice ozimé minerálními dusíkatými hnojivami z experimentální lokality o výměře 26,5 ha (Kojčice, Pelhřimov). Oranžově jsou znázorněny hodnoty dosaženého výnosu zrna (sloupce) a aplikovaná dávka na plochy s variabilní aplikací (linie), zeleně jsou označeny plochy s uniformní dávkou a dosaženým výnosem.



Obrázek 47: Význam variabilní aplikace hnojiv na příkladu obsahu přístupného fosforu v půdě a porovnání s výnosovou úrovní v procentuální škále stanovenou z víceleté řady výnosových map na 52ha pozemku (Přísnovice, okr. Brno-venkov). Vyšší odběr živin v oblastech s nadprůměrnými výnosy vedlo při uniformní aplikaci ke snížení obsahu přístupného fosforu v půdě (Lukas et al., 2017).

Ověřování variabilní aplikace minerálních dusíkatých hnojiv v rámci výzkumného projektu „TH02030133“ (Lukas et al. 2020b) poukázalo na vyšší význam vlivu produkční schopnosti stanovištních podmínek na dosažené výnosy než úroveň výživy dusíkem (obrázek 46). Z tohoto pohledu je jednoznačným doporučením využít při plánování přihnojení porostů pšenice ozimé dusíkatými hnojiv

mapy relativního výnosového potenciálu a snížení úrovně aplikace dusíkatých hnojiv v zónách s nižším očekávaným výnosem zrna formou variabilního dávkování. Současně lze v obdobných produkčních podmínkách doporučit „zastropování“ dávek dusíku na místech s vyšší hodnotou relativního výnosového potenciálu, neboť zvýšení dávky dusíku v zónách s nadprůměrným výnosovým



Obrázek 48: Hodnocení zapojení porostů ozimých plodin (pšenice ozimá, ječmen ozimý, řepka ozimá dle snímku NDVI z bezpilotního prostředku po zimním období. Průzkum byl doplněn o pozemní hodnocení formou fotodokumentace stavu porostu, které sloužilo jako podklad pro vyhodnocení zapojení porostu ozimých plodin (Lukas in Janata et al., 2016)

potenciálem nevedlo k očekávané podpoře vyššího odběru živin pro dosažení vyššího výnosu zrna

Z uvedeného vyplývá, že celková spotřeba aplikovaného dusíku v rámci variabilního hnojení pro pšenici ozimou by měla být nižší oproti homogenní aplikaci, a to z důvodu navrženého snížení dávek N na méně úrodných a propustnějších částech pozemku. Snížené dávky N na propustnějších částech (tj. s vyšší infiltrací) by zároveň snížily i riziko vyplavení dusičnanů do spodních částí půdního profilu (malá nebo žádná dostupnost pro porost) a do povrchových a podzemních vod ve zranitelných oblastech dusičnany. Vliv nevyrovnanosti pozemků na výnos zrna pšenice v podobě prostorové variability výnosového potenciálu byl výraznější v období vodního deficitu, při dostatečné půdní vlhkosti se variabilita půdních podmínek na výši výnosu neprojevila.


Kromě aplikace dusíkatých hnojiv lze princip variabilní aplikace dle výnosových hladin uplatnit také při zásobním hnojení. Mapy produkčních zón slouží pro upřesnění prostorového členění očekávaného výnosu a s tím souvisejícího celkového odběru živin a jeho úhradu normativní dávkou živin. Tato informace se kombinuje s korekcí dávky na základě agrochemického hodnocení zásobenosti živin v půdě ze vzorkování pro udržení stavu půdy v dobré zásobenosti. Cílem je distribuovat dávky hnojiv s ohledem na výnosové rozdíly, neboť rozdílný celkový odběr živin může významně ovlivňovat zásobenost živin v půdě.

7.6 HODNOCENÍ POŠKOZENÍ POROSTŮ POMOCÍ DPZ A DIFERENCOVANÁ OCHRANA ROSTLIN

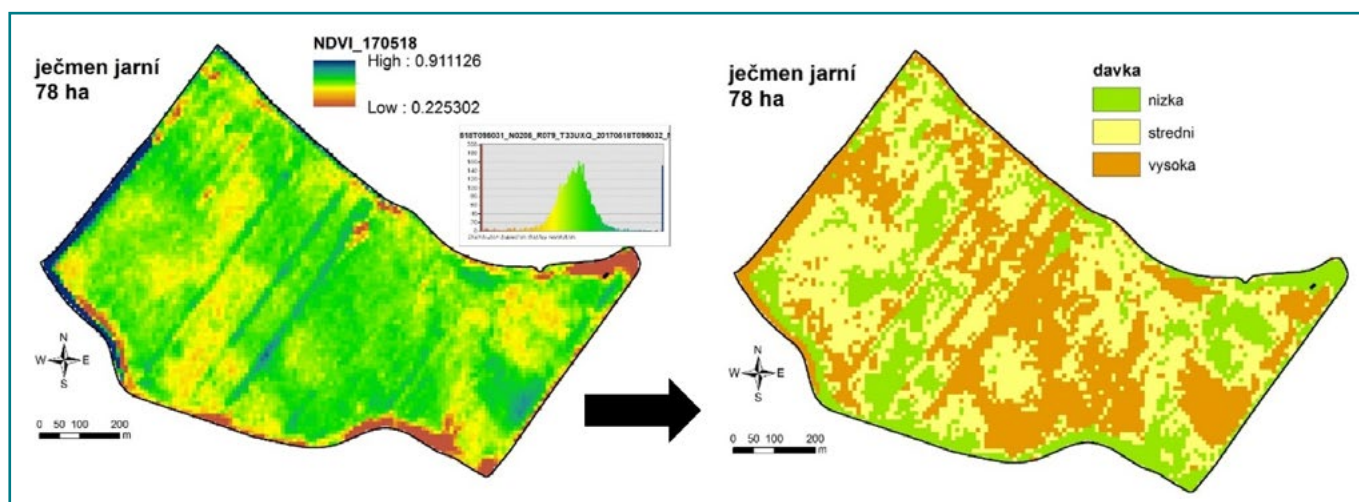
Dálkový průzkum představuje efektivní nástroj uplatnitelný v rámci agrobiologické kontroly porostů polních plodin, neboť umožňuje nahradit vizuální posouzení a jednoduchá měření na náhodně vybraných místech pozemků celoplošným hodnocením stavu porostů při současném snížení pracnosti. Umožňuje tak identifikovat všechna problémová místa a s využitím vegetačních indexů kvantifikovat biofyzikální vlastnosti porostů pro přesné posouzení úrovně problémů.

Jedná se např. o inventarizaci porostů ozimých plodin po přezimování a úrovně poškození rostlin a pro úpravu hnojení dusíkem, využitelné pro ozimé obilniny (pšenice, ječmen, žito, tritikale) a ozimou řepku. Stav porostů ozimých plodin po zimě určuje agrotechnické operace v jarním období, zejména přihnojení porostů. Pro tyto účely lze využít družicový či bezpilotní průzkum a vyhodnotit stav zapojení porostu (viz obrázek 48).

Dálkový průzkum lze využít také pro identifikaci poškození porostů, které zahrnuje přesné vymezení ploch poškozených zvěří, špatně provedenými agrotechnickými operacemi (úlety postřiků, nesprávné založení porostů), poškozených chorobami a škůdci či nežádoucími povětrnostními vlivy (kroupy, sucho, záplavy). Například z multispektrálních snímků pořízených pomocí bezpilotního prostředku bylo možno provést identifikaci poškození porostu řepky ozimé hlodavci (obrázek 49).



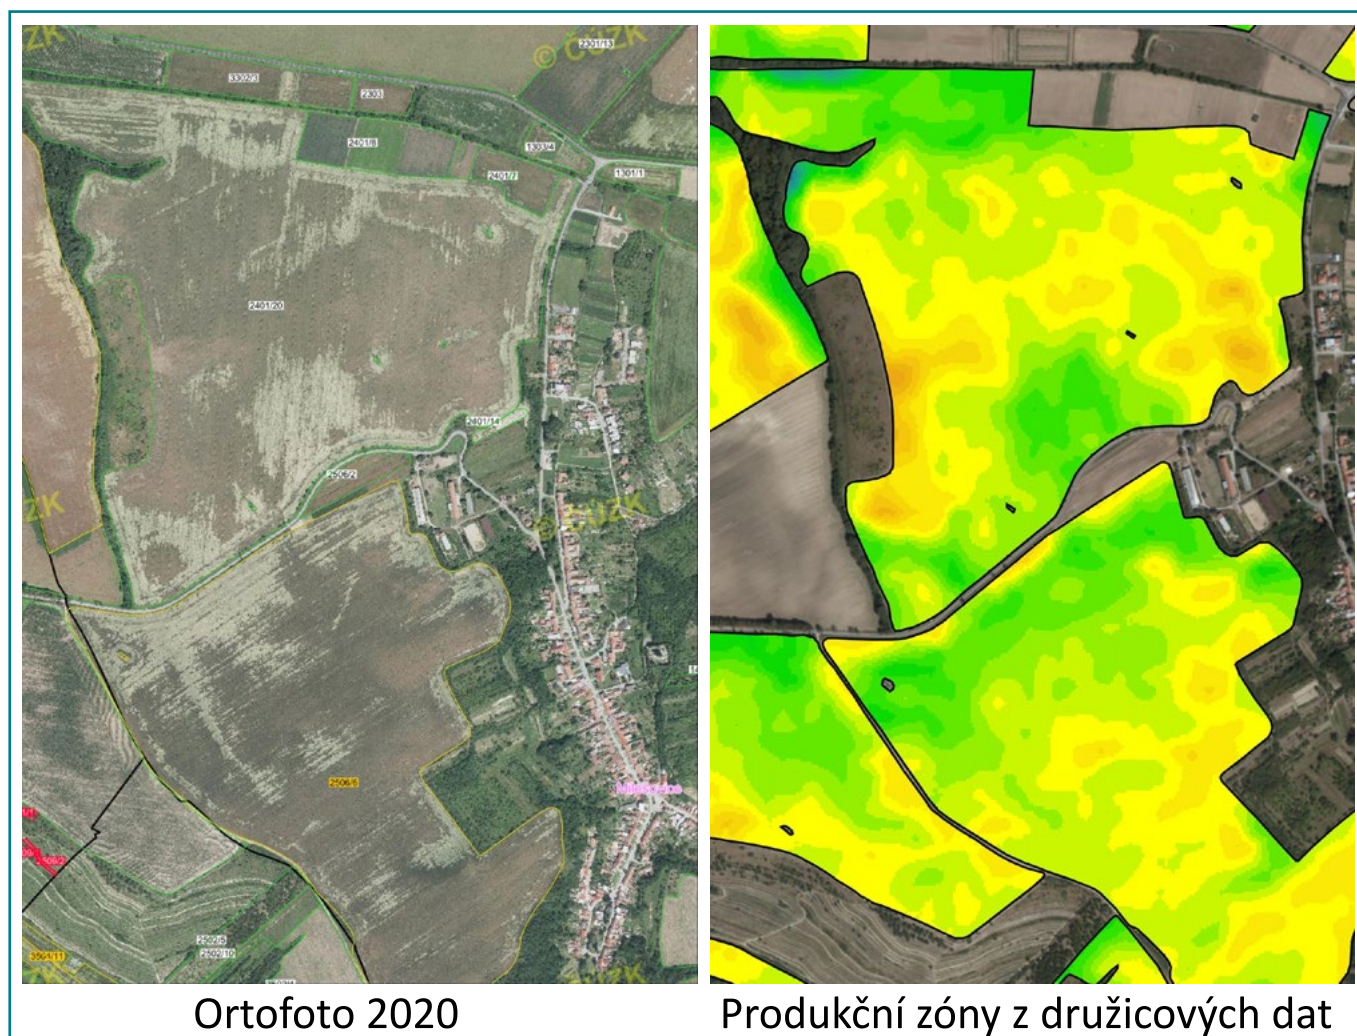
Obrázek 49: Identifikace poškození porostu řepky ozimé hlodavci z multispektrálních snímků pořízených pomocí bezpilotního prostředku



Obrázek 50: Příprava aplikační mapy pro ošetření regulátory růstu na základě analýzy NDVI snímku ze Sentinel 2.

Významnou kapitolou při optimalizaci vstupních látek v precizním zemědělství je variabilně prováděná aplikace přípravků na ochranu rostlin (POR). I přes zřetelné ekonomické a ekologické přínosy není diferencovaná aplikace POR příliš rozšířená. Důvodem je zejména problematická identifikace. Automatizované postupy, využívající sensorická měření, neposkytují při vytváření map napadení porostu škodlivými organismy výsledky s potřebnou spolehlivostí. U optických přístrojů zjišťujících odrazivost rostlin v různých částech spektra elektromagnetického záření je možné úspěšně vysledovat poškození (stres) rostlin, avšak velmi obtížné je rozlišit jeho příčinu (nedostatek vody, nedostatek živin, abiotické a biotické poškození atd.).

V případě prostorového členění dávkování regulátorů růstu rostlin lze využít principu detekce polehlých částí porostů na základě bezpilotních nebo družicových snímků. Chauhan et al. (2020) úspěšně detekovali stupeň polehnutí obilnin na základě časových řad radarových snímků Sentinel 1 a Radarsat-2. Příklad na obrázku 50 znázorňuje doporučení aplikace regulátoru růstu ječmene jarního na základě analýzy hodnoty NDVI z multispektrálního snímku Sentinel 2. Plochy polehlých porostů jsou často lokalizovány v místech terénních depresí a lze je snadno identifikovat na základě produkčních zón (obrázek 51). Zvýšením dávky aplikace regulátorů růstu lze v případě podmínek příznivých pro polehání porostů zmírnit tento jev při současném snížení (nebo omezení) aplikace v ostatních částech pozemků.



Ortofoto 2020

Produkční zóny z družicových dat

Obrázek 51: Soulad mezi polehlými plochami obilnin na lokalitě Otnice (Slavkov u Brna), které lze snadno identifikovat na ortofotosnímku ČÚZK z roku 2020 v podobě světlých ploch (vlevo) a současně mapa produkčních zón znázorňující nejvyšší hodnoty výnosového potenciálu tmavě zelenou barvou (vpravo).

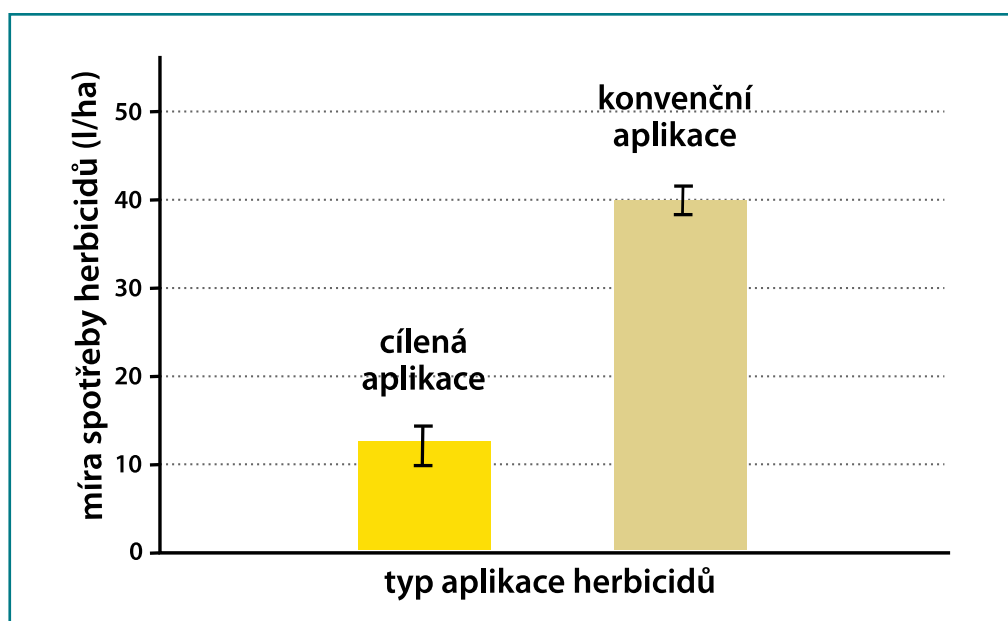
Podobně lze uvažovat také o zvýšení dávek **fungicidních látek** v oblastech s vyšší produktivitou, která odpovídá četnějšímu výskytu porostu s vyšším množstvím nadzemní hmoty za sledované období. Úroveň napadení porostu chorobami je silně ovlivněno od prostorového členění porostu, které závisí na prostorové variabilitě půdních podmínek. Detekce napadení houbovými chorobami je mnohem obtížnější než v případě identifikace zaplevelení, obzvláště pokud cílíme na podchycení napadení porostu v raných fázích infekčního cyklu. Z tohoto důvodu se postupy tvorby podkladových informací pro provedení zásahu orientují na odvození stupně napadení listů dle hustoty porostu (Jensen a Jørgensen, 2016). Úspěšnost detekce napadení chorobami je tak daná prostorovým a spektrálním rozlišením a současně načasováním termínu snímkování (obrázek 52). Výsledky porovnání uniformní a variabilní aplikace fungicidních látek přitom

poukazují na dosažení významné redukce přípravků na úrovni 22–25 % se současným omezením rizika snížení kvality produkce vlivem zvýšeného obsahu mykotoxinů (Whetton et al. 2018).

Další významnou částí ochrany rostlin je regulace zaplevelení formou **ohniskové aplikace herbicidních látek**, která může vést k významné redukci používání POR (viz obrázek 53). Vychází se z identifikace plevelných rostlin s využitím multispektrálních senzorů. Tato identifikace je relativně snadná pro uplatnění aplikace totálních herbicidů bez hlavní plodiny nebo před jejím vzejitím (preemergentní aplikace). V tomto případě jsou plevelné rostliny jedinou vegetační složkou na pozemku a jsou tak snadno multispektrálními senzory identifikovatelné z RGB snímků nebo pomocí vegetačního indexu NDVI (obrázky 54 a 55).




Obrázek 52: Význam načasování při monitoringu jevů s vysokou dynamikou změny v čase na příkladu detekce napadení padlí obilnin. Vývoj napadení chorobou (žlutá linie) je při nízké četnosti pozorování popsán nedostatečně (upraveno dle Oerke et al., 2010)



Obrázek 53: Rozdíl průměrné spotřeby herbicidních látek při celoplošné konvenční a cílené aplikaci (upraveno dle Loghavi a Behzadi Mackvandi, 2008)

Identifikace je obtížně proveditelná v zapojeném porostu. Prvním krokem, který je důležitý pro spektrální rozlišení plevelů a plodin, je získat spojitá spektra rostlin pro každý druh nebo skupinu druhů a vysokého prostorového a spektrálního rozlišení. Obsáhlou přehledovou studii, zaměřenou na využití DPZ při mapování zaplevelení, podává Lamb & Brown (2001). Po nasnímání povrchu půdy s vegetací přichází na řadu metody analýzy obrazu s využitím pokročilých klasifikačních algoritmů. V jednodušší podobě nabízí klasifikaci snímané scény, na pokročilejší úrovni

pak umožňují identifikovat jednotlivé plevelné rostliny s využitím postupů strojového učení, v tomto případě modelu typu Support Vector Machines (SVM). Další možností vyhodnocení zaplevelení je objektově orientovaná analýza digitálního obrazu s rozpoznáním plevelných rostlin na základě porovnávání tvaru částí rostlin, která ale vyžaduje velmi vysoké prostorové rozlišení v řádech mm. Je tedy proveditelná pouze pro bezpilotní průzkum v nízké výšce nebo na základě pozemního snímkování – např. pomocí kamer instalovaných na aplikační technice.



Obrázek 54: Identifikace ohnisek zaplevelení pcháče rolního v porostu máku setého v raném stádiu růstu z multispektrálního leteckého snímku na základě klasifikace NDVI (lokalita Švábenice, jaro 2009).



Obrázek 55: Vyhodnocení zaplevelení pcháče rolního pro preemergentní aplikaci herbicidního přípravku na základě klasifikace RGB snímků z bezpilotního průzkumu (vlevo), odlišení vegetace od holé půdy (uprostřed) a přípravu aplikační mapy se zohledněním možnosti aplikační techniky (vpravo).

Použití postupů precizního zemědělství v ochraně rostlin otevírá nové perspektivy kontroly a dokumentace využívání přípravků na ochranu rostlin. S tím také souvisí další pozitivum spojené se správným používáním agrochemických přípravků mající za cíl omezit vznik rezistence škodlivého činitele na daný přípravek. Rezistence vzniká při nevhodné volbě přípravku, vysoké četnosti jeho používání a nedostatečném střídání přípravků s podobným působením účinných látek. Diferencovaně prováděné zásahy jsou cíleny pouze na místa s aktuálně hospodářsky nebezpečným výskytem škodlivých organismů a umožňují snadnou kontrolovatelnost a dohledatelnost množství a druhu

aplikované účinné látky. Tímto způsobem se lze nevhodnému používání přípravků vyvarovat a možnému vzniku rezistence předcházet. Srinivasan et al. (2006) upozorňují ale, že v případě špatně provedeného variabilního zásahu (chybné ohraničení ohnisek výskytu, nesprávná aplikace, nepřiměřená dávka) se přežijí populace škodlivých činitelů opět rychle rozšíří na pozemku, což znamená opakování aplikace. Při snížené spolehlivosti detekční metody je pak vhodnější provádět celoplošnou aplikaci a zaměřit se spíše na její správné načasování – např. s využitím predikce šíření škodlivých organismů na základě agrometeorologického monitoringu.

7.7 MONITORING PLODIN A VÝNOSŮ

Významný vliv na výnosy zemědělských plodin má mimo jiné bezesporu také reliéf pozemku. Právě tvorba topografických modelů je nezbytná ke správné predikci výnosů, k tvorbě lokálně specifických zón pro aplikaci hnojiv a chemických ochranných prostředků a také pro zmírnění erozní činnosti na pozemku (např. Kravchenko a Bullock, 2000, nebo Schmidt a Persson, 2003). Metody DPZ umožňují sledovat vývoj zemědělských plodin v různých fenologických fázích a popsat tak vliv výnosotvorných faktorů na celkový výnos plodin. Míra intenzity popsání variability pozemku záleží na charakteristice použitého senzoru. Výsledný produkt DPZ se může lišit v různých parametrech. Může se jednat o obrazová či neobrazová data, přičemž obrazová data mohou mít různá rozlišení (radiometrické, spektrální, prostorové či časové), nebo se mohou lišit v závislosti na typu nosiče. Použitím kvalitních dat, získaných jak pomocí senzorové techniky, tak i dat referenčních, tedy převážně ručně odebraných, je možné s pro praxi dostačující pravděpodobností predikovat vývoj, a nakonec i výnos sledovaných plodin na pozemku.

7.7.1 VYUŽITÍ TOPOGRAFICKÝCH MODELŮ

Topografie hraje velmi významnou roli v predikci prostorové variability výnosů, obsahu živin v půdě či kvalitativních prvků porostu. Topografické informace jsou založeny především na hodnotách nadmořské výšky, ze kterých se dají následně odvodit modely sklonu reliéfu, směru odtoku vody či akumulace odtoku vody. V současné době je k dispozici celá řada zdrojů od produktů implementovaných do aplikací přístupných veřejnosti ať již zdarma či za poplatek, po možnost odvodit si topografické modely např. z dat naměřených bezpilotními prostředky. Tato možnost však vyžaduje nutně znalosti dostupného softwarového vybavení. V zemědělské praxi lze také využít data ze strojů, např. ze sklízecí mlátičky, kdy se hodnoty o nadmořské výšce zpravidla ukládají společně s informací o výnosu.

Na základě rešerše literatury lze konstatovat, že jednotlivé metodiky, jak namodelovat akumulaci odtoku vody na pozemku, se liší zejména podle účelu aplikace. Pokud chceme výsledný výnos plošně porovnat s intenzitou

dostupnosti vody (tedy s modelem akumulací odtoku vody), je liniový charakter tohoto modelu nutné převést do formy polygonů. Dá se tak docílit použitím nástroje fokální statistika, který je implementován v dostupných GIS SW, a například jej rozdělit na několik kategorií podle intenzity akumulace odtoku vody tak, aby reálná mapa dostatečně korespondovala s reálným stavem na poli.

Velmi používaným modelem, který indikuje vlhkostní poměry pozemku je tzv. Topografický vlhkostní index (TWI – Topography Wetness Index). Tento index je výsledkem výpočetní kombinace mezi rastrem akumulace odtoku vody a rastrem sklonu. Celkem jednoduše se dá vypočítat pomocí „Raster Calculatoru“ v mapové algebře volně dostupného SW QGIS. Tento index byl poprvé prezentován autory Beven & Kirkby (1979), přičemž v publikaci Wilson a Gallant (2000) je popsáno jeho uzpůsobení různým aplikacím. Pro zemědělské účely byl TWI v průběhu let použit například autory Schmidt a Persson (2003), Iqbal et al. (2005), Sørensen et al. (2006), Qin et al. (2011). Autoři Marques da Silva & Silva (2006) navrhli tzv. DFL index (distance to flow accumulation lines = vzdálenost od linií akumulace odtoku). Tímto indexem potvrdili obecnou domněnku poklesu výnosu se zvýšením vzdálenosti od linie odtoku. DFL index byl zkoušen na porostu kukuřice. Velmi často je používán model akumulace odtoku vody založený na tzv. D8 algoritmu. Alternativu může tvořit tzv. MFD8 algoritmus. Porovnáním těchto dvou algoritmů a různých modelů terénu se zabývá publikace Kumhálová a Moudrý (2014). Autoři pracují se čtyřmi sadami výškových dat, které popisují 11,5ha pokusné pole ve Výzkumném ústavu rostlinné výroby (VÚRV), v.v.i. v Praze-Ruzyni. Základní soubory tvoří 300 výškových hodnot z RTK-GPS, které jsou zaměřeny v pravidelné síti; dále soubor 1 189 hodnot z RTK-GPS naměřených v nepravidelné síti s důrazem na zvláštnosti terénu, kdy více bodů bylo lokalizováno na zvláštějších částech pozemku, méně na rovných částech pozemku; a dále LiDARová (letecké laserové skenování povrchu) data souboru DMR4G v originální verzi a upravená do rastru 1 m × 1 m, zakoupená z ČÚZK.

Porovnáme-li výše zmíněné zdroje dat pro vlastní zpracování, lze konstatovat, že soubor výškových dat z LiDARu je sice přesný soubor dat s velmi hustou sítí hodnot,

avšak v závislosti na objemu dat i hůře zpracovatelný. Všechny jeho odvozené soubory jsou v praxi dobře použitelné. Jako nejméně vhodný soubor dat, co se přesnosti týče, je soubor výškových dat ze sklízecí mlátičky. Zde je nezbytné odstranit extrémní, nevhodné hodnoty stanovením tzv. intervalu spolehlivosti. Na přesnost údajů nejen výnosových map má vliv především velikost sklízecího pozemku (25 %), kalibrace systému podle údajů výrobce (12 %), nedodržování stejné šířky záběru (do 10 %) a dále práce na svahu – mírný svah (5–10 %) a prudší svah (do 20 %), v neposlední řadě také pojezdová rychlost stroje (5 %) (Kumhála, 2004). v současné době platí, že moderní technika dokáže spoustu chyb eliminovat či zmírnit, ale zpravidla záleží na servisu a obsluze.

Výhodou souboru dat z RTK-GPS je subjektivní zhodnocení pozemku v tom smyslu, že lze zvolit síť měření v potřebné hustotě s ohledem na místní zvláštnosti pozemku. Z praktického pohledu si s sebou každý soubor dat nese jistá omezení. Data z LiDARu vyžadují speciální SW i lepší HW vybavení. Data se dají zakoupit ve formě DMR4G a DMR5G na geoportálu ČÚŽK. Naměřit data z RTK-GPS je časově náročné a vyžaduje také určité znalosti, takže z hlediska běžného zemědělského podniku se stává tato metoda nereálnou; respektive do určité míry reálnou, ale pouze pro zaměření specifické části pozemku. Jako nejlépe dostupné řešení pro zemědělskou praxi je využití dat ze strojů, pokud se nebere v úvahu některý z informačních systémů. Například výhodou vizualizace dat pomocí běžného komerčního SW, který zpracovává výnosová data ze sklízecí mlátičky, je to, že nevyžaduje žádnou speciální znalost SW. Uživatel se ovšem musí smířit s jistou nepřesností dat. Data získaná skenováním povrchu pomocí bezpilotních prostředků mají výhodu ve velmi vysoké přesnosti. Nicméně samotné zpracování také vyžaduje určité znalosti především komerčních SW.

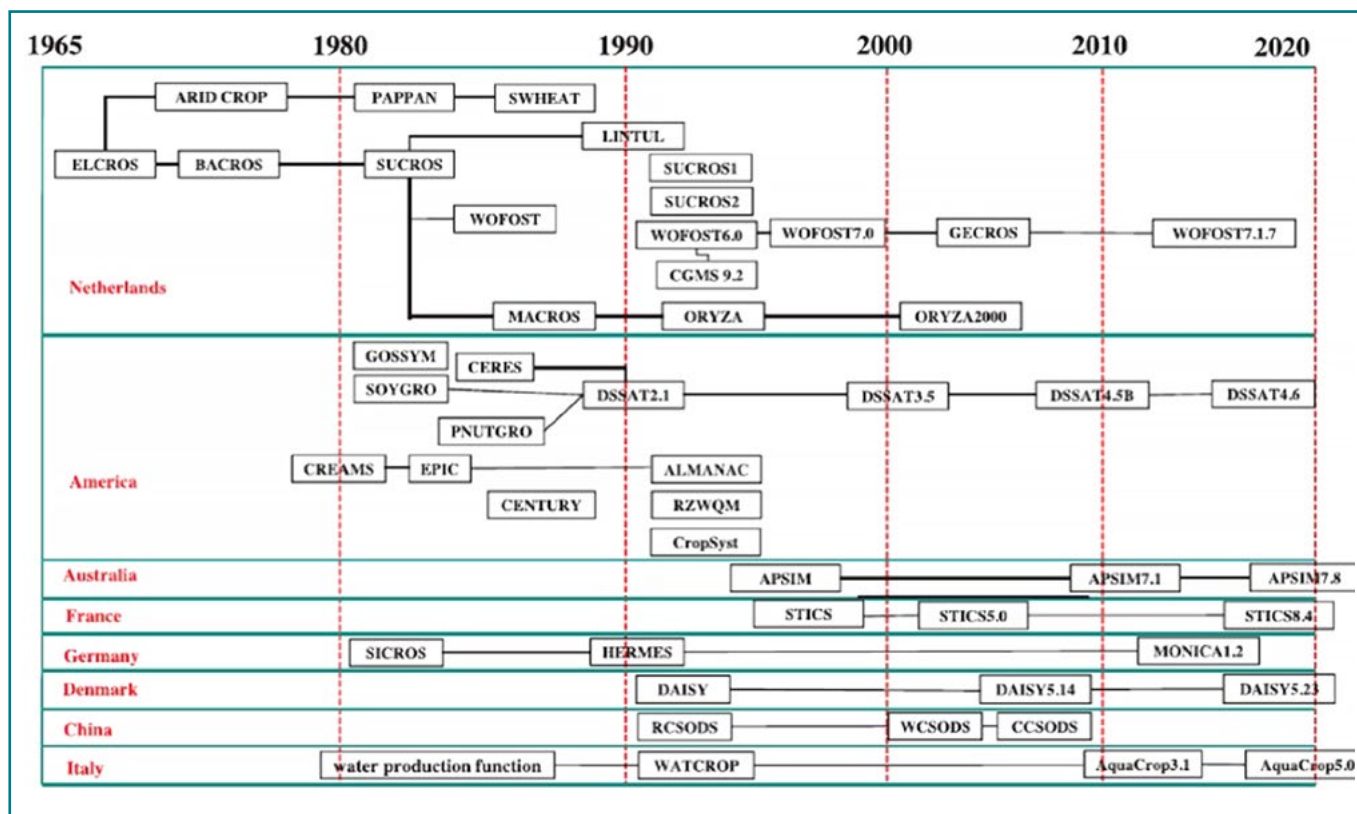
Samotné zpracování a vizualizaci dat vyžaduje jisté znalosti geostatistických a GIS nástrojů. Z hlediska vhodného zpracování dat je dle Kerry & Oliver (2007) doporučeno zvolit počet bodů na pozemku tak, aby přesahoval 100 bodů. Takto se lze vyvarovat výpočetním komplikacím při vizualizaci zkoumaných charakteristik. Dalším úskalím

může být volba vhodné geostatistické metody. Velmi často se pro zemědělské účely používá interpolační metoda Inverse Distance Weighting (IDW) nebo kriging. Kriging je relativně složitá metoda, kde je pro přesný a reálný výsledek nutná znalost geostatistiky (modelování variogramů). Naproti tomu IDW metoda sice nevyžaduje úpravu tolika vstupních parametrů, ale nemusí dávat při nevhodném počtu, rozmístění a anizotropii dat dobrý výsledek. Pokud vstupní parametry nastavíme nevhodně, výsledkem mohou být mapy obsahující tzv. bull eyes (nereálné kruhovitě soustředné útvary), tolik typické při použití metody IDW. Alternativou mohou být i složitější regresní modely, které pro interpolaci dat v prostoru využívají pomocných dat a interpolaci tak provádějí nejen na základě polohové informace či prostorové autokorelace, ale využívají i korelaci s dalšími pomocnými daty.

7.7.2 SLEDOVÁNÍ VARIABILITY POROSTŮ POMOCÍ DRUŽICOVÉHO SNÍMÁNÍ V OPTICKÉ ČÁSTI SPEKTRA

Výnos zemědělských plodin je ovlivněn mnoha faktory, které mohou být časově nezávislé nebo jsou proměnné v čase neboli sezónní. Mezi časově nezávislé faktory náleží např. topografie pozemku, typ a druh půdy, hloubka ornice a obecné vlastnosti půdy. Mezi proměnné čili sezónní faktory ovlivňující růst a vývoj plodin pak patří například počasí, především teplota vzduchu a distribuce srážek, přítomnost chorob a plevelů, a v současné době tolik diskutované klimatické změny projevující se suchem či nadprůměrnými srážkovými událostmi, nebo i distribuce vláhvy pomocí zavlažovacích zařízení (Bégué et al., 2008). Tyto časově nezávislé a časově proměnné faktory se mohou vzájemně prolínat. Výsledkem této interakce je pak zpravidla složitý komplex časoprostorových vztahů popisujících vitalitu rostlin (Machado et al. 2002).

Potřeba včasného a přesného snímání polních plodin a zachycení jejich variability vedlo ke zvýšenému využívání technologií dálkového a blízkého snímání malých i velkých zemědělských pozemků (Cambell & Wynne 2011, Chlingaryan A. et al. 2018).



Obrázek 56: Vývoj hlavních tzv. „crop modelů“ [Zdroj: Jin et al. 2018]

Dálkové snímání využívající viditelnou a blízkou infračervenou část elektromagnetického spektra (VIS-NIR) bylo použito k odvození mnoha spektrálních indexů vhodných pro odhad různých vegetačních či růstových vlastností. Vegetační indexy se často používají pro zjištění výnosového potenciálu či přímo předpovědi výnosu, jak popisují ve svých studiích např. Panda et al. (2010) či Jaafar & Ahmad (2015).

Velmi užitečné je využití historických snímků (Pinter et al. 2003). Tyto snímky nám dávají představu o distribuci výnosotvorných faktorů v čase a lze je kombinovat s agronomickými a klimatickými údaji pro mapování např. oblastí náchylných k vodnímu stresu, nedostatku živin nebo detekci míst napadených škůdci. Studie založené na využívání historických snímků jsou obecně založeny na faktu, že prostorová variabilita výnosu plodin je ovlivněna prostorovou variabilitou půdy, a to ve stejném měřítku (Bodeyll & McBratney 2002). Počet po sobě jdoucích historických snímků požadovaných k odvození přijatelné mapy vystihující výnosový potenciál pozemku se však liší v závislosti na studii, od doporučených pěti let (Bodeyll a McBratney, 2002) po dlouhodobější databázi pro jednotlivé plodiny či alespoň stejné čeledi rostlin při zohlednění proměnlivých podmínek prostředí (Lamb et al. 1997, Schepers et al. 2004). Mapy variability porostu v průběhu několika sezón jsou schopné poskytnout informace o místně specifických podmínkách pro danou lokalitu. Sledují se trvalé faktory (zejména klimatické a půdní vlastnosti) a proměnné faktory. Proměnné faktory ovlivňující produktivitu pozemku se dají ovlivnit vhodnými agrotechnickými zásahy. Jedná se především o zásobenost živinami, problémy se škůdci

nebo jednotnost zavlažování. Aplikační dávky agrotechnických zásahů (dávky osiva a množství vody či dodaných živin) lze tedy na základě map přizpůsobit skutečné poptávce, která je paradigmatem přesného zemědělství (Campos et al. 2019). Možnými alternativami pro mapování variability plodin jsou modely růstu plodin, mapy elektrické vodivosti, výnosové mapy a mapy odvozené z polních měření diagnostickými přístroji využívající elektromagnetické spektrum (Sandras et al. 2015).

Během sezóny se obecně studuje dynamika spektrálních indexů sledovaných plodin, aby se určilo nejlepší období k vymezení produkčních zón (Zarco-Tejada et al. 2005, Yang & Everitt 2002), což je však nedostatečné ke sledování diagnózy např. poškození porostu vnějšími vlivy.

Informace jak z výnosových map, ale také ze snímků je možné využít pro pokročilé modelování. Tyto informace lze tedy použít jako dílčí podklady do velmi složitých modelových algoritmů, které zpravidla predikují vývoj porostů určité plodiny v čase a prostoru (např. Jin et al., 2018 - viz obrázek 56 - graf vývoje modelů) a používají se také pro odhad výnosu; nebo pro odvození tzv. víceletých výnosových map (Mayphanyane et al. 2018).

Evans (1993) definoval tzv. výnosový potenciál (v anglické literatuře označován zpravidla jako Y_p podle *Yield Potential*), který je definován jako výnos plodiny pěstované v prostředí, na které je adaptována, s neomezeným přístupem živin a vody, a s efektivní kontrolou chorob a škůdců. Výnosový potenciál je zpravidla stanoven pro danou odrůdu na konkrétním místě především množstvím dopadajícího

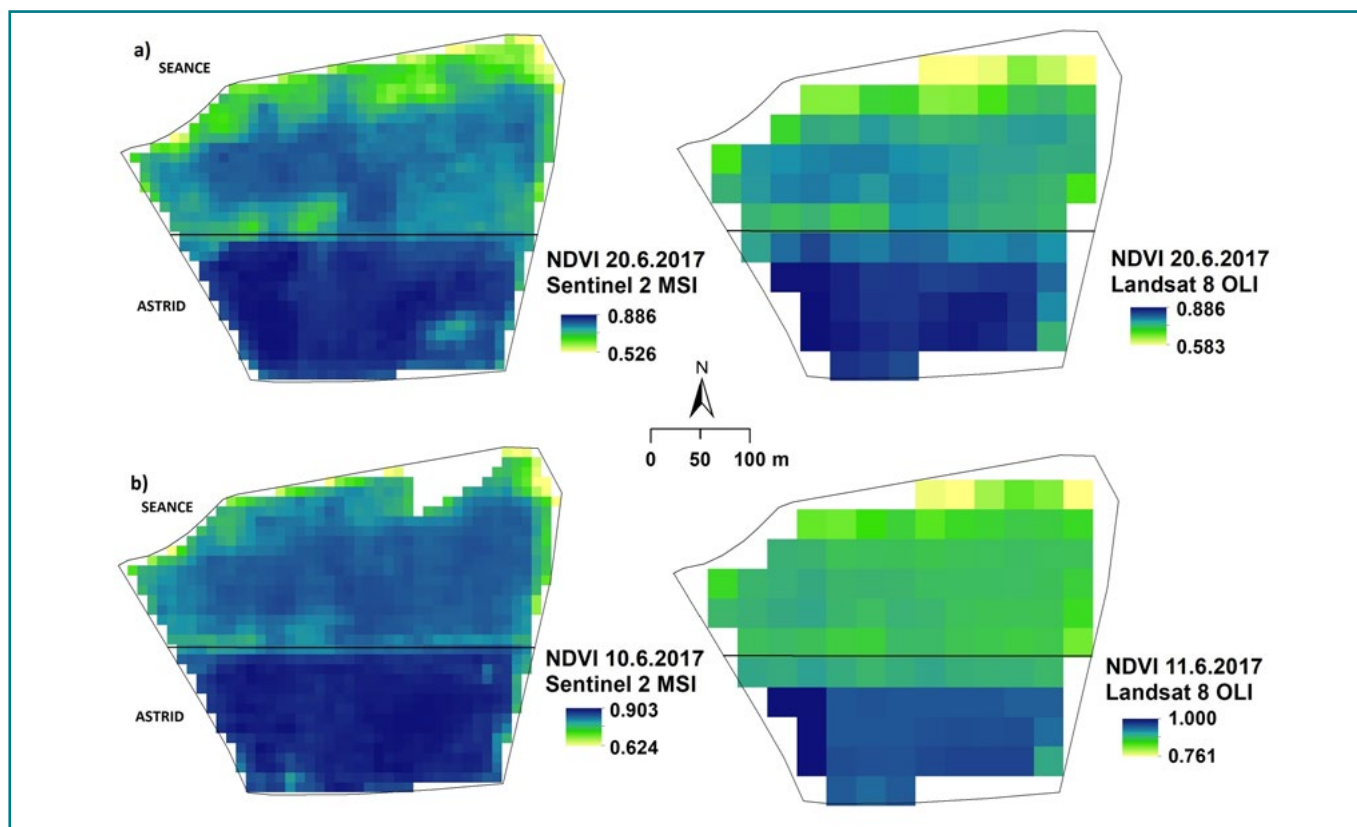
slunečního záření, teplotou, množstvím dostupného oxidu uhličitého, hustotou rostlin, a genetickými vlastnostmi odrůdy, které určují délku vegetačního období, a schopností zachycení slunečního (EM) záření horní částí porostu a jeho přeměnou na biomasu, která pak určuje kvalitu výnosu.

Výnosový potenciál omezený dostupností vody ($Y_w = \text{Water-limited yield potential}$) je určený parametry jako standardní výnosový potenciál, ale bere v potaz i dostupnost vody limitovanou vlastnostmi pozemku (topografií), půdy, kořenovým systémem a schopností odrůdy přijímat živiny ve vodním roztoku (van Ittersum a Rabbinge, 1997). Pro konkrétní místo, porost a rok je definován také Výnosový rozdíl ($\text{Yield gap} = Y_g$ <https://www.yieldgap.org/>) jako rozdíl mezi výnosovým potenciálem Y_p (s neomezenou dostupností vody) či Y_w (na ne/zavlažovaných pozemcích) a průměrným skutečným aktuálním výnosem (Y_a). Velikost výnosového rozdílu ukazuje míru současné produktivity půdy ve vztahu k maximální biofyzikální výnosnosti plodiny (odrůdy). Tedy výnosu, kterého bychom mohli dosáhnout, kdybychom vzali v potaz všechny proměnné, které jej mohou ovlivnit – nikoliv jen soubor výnosových dat či družicových snímků (Grassini et al. 2015).

Snímky z družice Landsat jsou tradičními zdroji při hodnocení variability porostu. Ačkoliv mají tyto snímky střední prostorové rozlišení (30 m na pixel), výhoda jejich využití spočívá ve spektrálním rozlišení a z něj vyplývajících možnostech využití pro výpočet vegetačních indexů. Další z výhod použití těchto snímků je bezplatné prohlížení a stažení snímků z aplikace americké geologické služby (USGS) (<http://earthexplorer.usgs.gov/>). Prostorové rozlišení družice Landsat a využití těchto snímků pro zemědělské účely bylo v literatuře hodně diskutováno. Například Zhang a Pierce (2013) uvedli, že využití tradičních družicových systémů jako jsou Landsat a SPOT je velmi rozšířeno pro zemědělské účely, přičemž se nehodí pro účely precizního zemědělství právě z důvodu malého prostorového rozlišení. Nicméně někteří autoři využili družicové snímky Landsat pro precizní zemědělství, ale většinou se to týkalo pozemků s větší výměrou (Guo et al. 2012, Julien et al. 2011, Doraiswamy et al. 2004, Doraiswamy et al. 2011). Z literární

rešerše vyplývá, že volba družicového snímku je nejen závislá na prostorovém rozlišení, ale je nezbytné brát v úvahu i spektrální rozlišení, které může předčít zmíněné nevýhody. Frekvence snímání (tedy časové rozlišení) družice Landsat je 16 dní, celého družicového systému pak 8 dní. Nepřehlédnutelnou výhodou je dlouhé časové pokrytí, kdy je možné zdarma získat historická data.

Družicové snímky Landsat byly využity k hodnocení variability porostu i na pozemku VÚRV, v.v.i. v Praze – Ruzyni menší velikosti (11,5 ha). Protože je prostorové rozlišení snímků Landsat 30 m, vyšlo na sledovaném pozemku 127 pixelů, které mohly být následně hodnoceny. Vzhledem k tomu, že jevy doprovázející růst plodin se zpravidla projevují v prostoru spojitě, ukázalo se, že prostorové rozlišení 30 m je v zásadě dostačující. Tyto podklady je vhodné doplnit snímky s velmi vysokým prostorovým rozlišením (např. WorldView-2, QuickBird či snímky z bezpilotního prostředku), aby se případně doplnila detailní informace o porostu, je-li potřeba (např. pro detekci plevelů). Faktem totiž zůstává, že ačkoliv mají snímky z družice Landsat horší prostorové rozlišení (zmíněných 30 m u multispektrálního módu a 15 m u panchromatického), spektrální rozlišení je relativně dobré. Snímky z družice Landsat disponují pásmy od viditelné části spektra přes NIR, SWIR1 a SWIR2 (Short Wave Infrared) po TIR (Thermal Infrared) pásma – záleží na senzoru a nosiči (Landsat 5 TM – 7 pásem, Landsat 7 ETM+ - 8 pásem, Landsat 8 OLI – 11 pásem). Proto je možné namodelovat větší počet spektrálních indexů. Snímky z družic QuickBird a WorldView-2 mají naopak dobré prostorové rozlišení. Jejich nevýhodou je však horší spektrální rozlišení. Družice QuickBird má sice prostorové rozlišení 2,4 m v multispektrálním módu (0,6 m v panchromatickém), ale bohužel snímky mají jen 4 spektrální pásma (3 viditelné a NIR). Podobně je tomu u snímků z družice WorldView-2, kde je prostorové rozlišení sice 1,24 m v multispektrálním módu (0,5 m v panchromatickém), ale spektrální rozlišení je zde opět horší. Disponuje 8 pásmy, ale v rozsahu od „pobřežního“ pásma, přes 4 viditelná (modré zelené, žluté a červené), red-edge a 2 NIR pásma). Pokud tedy budeme chtít zkoumat variabilitu porostu v rámci porovnání stejných spektrálních indexů, budeme se muset omezit pouze na ty indexy, které



Obrázek 57: Porovnání snímků Sentinel 2 a Landsat 8 pořízených ve stejný (a) a přibližný (b) termín na experimentálním pozemku VÚRV, v.v.i. v Praze – Ruzyni pro pšenici jarních odrůd Astrid a Seance.

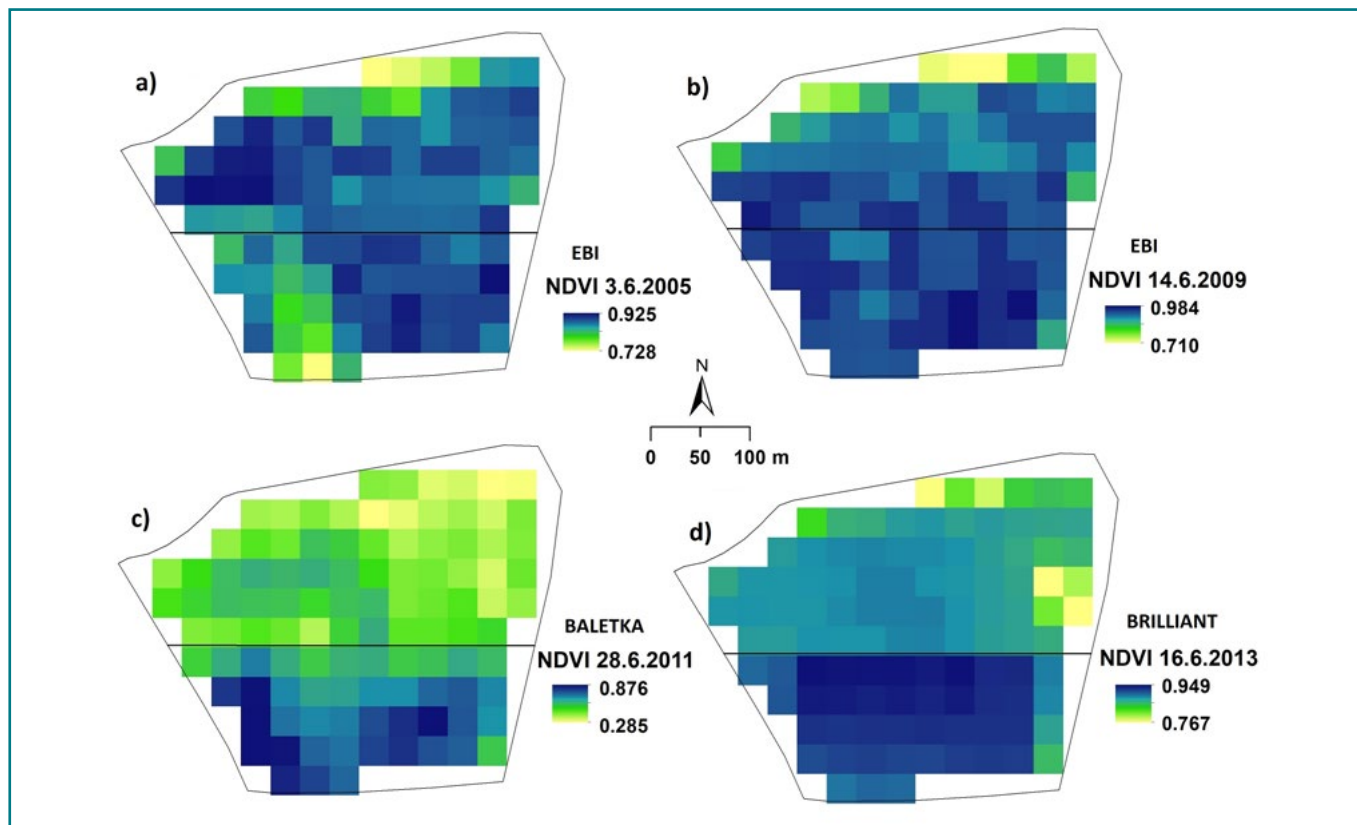
pouze počítají s viditelnými a NIR pásmy. Další neopomenutelnou věcí je, že zatímco snímky z družice Landsat jsou ke stažení zadarmo, snímky QuickBird, či WorldView-2 jsou komerční. Zde se nabízí ještě řešení v podobě využití snímků z družice Sentinel 2. Tyto snímky disponují 13 pásmy, kde 4 pásma mají prostorové rozlišení 10 m, 6 pásem 20 m a 3 pásma 60 m. Cílené využití těchto snímků záleží na dispozici pozemků a účelu využití, tedy zda je v plánu hodnotit pozemky z dlouhodobého hlediska či jen za poslední roky. Družice Sentinel 2A byla vypuštěna na oběžnou dráhu až v roce 2015 (Sentinel 2B pak v roce 2017), proto je její využití historicky relativně omezené.

Tak, jak uvádí např. autoři Scudiero (2016) ve své studii, je potřeba více zkoumat, který senzor je v dané geografické oblasti pro daný typ sledovaného povrchu nejužitečnější. Každý senzor má nejen jiné spektrální rozlišení, tj. jiný počet spektrálních pásem, ale také jiný rozsah individuálních spektrálních pásem s jinou střední hodnotou. Tento fakt může způsobit odlišné výsledky při skenování porostů. Touto problematikou se zabývali v podmínkách české praxe autoři Kumhálová a Matějková (2017), kdy porost experimentálního pozemku VÚRV, v.v.i. v Praze-Ruzyni sledovali pomocí různých družicových snímků: tři snímky z družice QuickBird z 22. 5. 2007 (s ječmenem ozimým na pokusném pozemku), 13. 4. 2009 (pšenice ozimá) a 31. 5. 2011 (pšenice ozimá); WorldView-2 z 23. 3. 2015, kdy byl na pozemku ječmen ozimý; a snímky z družice Landsat paralelně ve stejných nebo přibližných termínech jako dva předchozí zdroje. Výsledky porovnání jednotlivých sad dat s výnosem ukázaly, že každá sada dat bez

ohledu na prostorové rozlišení může dostatečně popsat variabilitu porostu na sledovaném pozemku. Koeficienty korelace mezi NDVI z družice QuickBird a Landsat byly takřka shodné v porovnání s každou sadou dat. Tento fakt se ovšem týkal pouze snímků, které byly pořízeny během pozdějších růstových fází rostlin (cca BBCH 59). Významné rozdíly mezi senzory ovšem ukázaly koeficienty korelace mezi výnosem a snímky z družic WorldView-2 a Landsat, které byly pořízeny v raných fázích růstu rostlin (BBCH 21-22). Výsledky dále ukázaly, že převzorkované snímky na stejné prostorové rozlišení (z důvodu sjednocení prostorových vlastností snímků) si zachovávaly stejný či velmi blízký aritmetický průměr, ale se snižujícím se prostorovým rozlišením se zužoval rozsah hodnot.

Pro pochopení informací o chování a stavu rostlin v daném čase, kterou je možné získat právě z vegetačních indexů vypočítaných z daných snímků, je vhodné zařadit do analýzy minimálně i výnos (aktuální, poslední či průměrné mapy alespoň stejných čeledí), vybrané topografické atributy a meteorologická data (srážky a teploty) rozdělená např. do fenologických fází.

Odlišnosti ve vlastnostech snímků mohou tedy do určité míry ovlivnit vizualizaci a následnou interpretaci snímku. Jako příklad porovnání dvou vizualizací porostu z družicových snímků může posloužit studie autorů Jelínek et al. (2020), kde byly porovnávány snímky z družice Sentinel 2 a Landsat 8 (obrázek 57) pořízené ve stejný den a přibližný čas (cca 10:30 dopoledne). Byl sledován porost pšenice jarních odrůd Astrid (na jižní a plošší části pozemku)



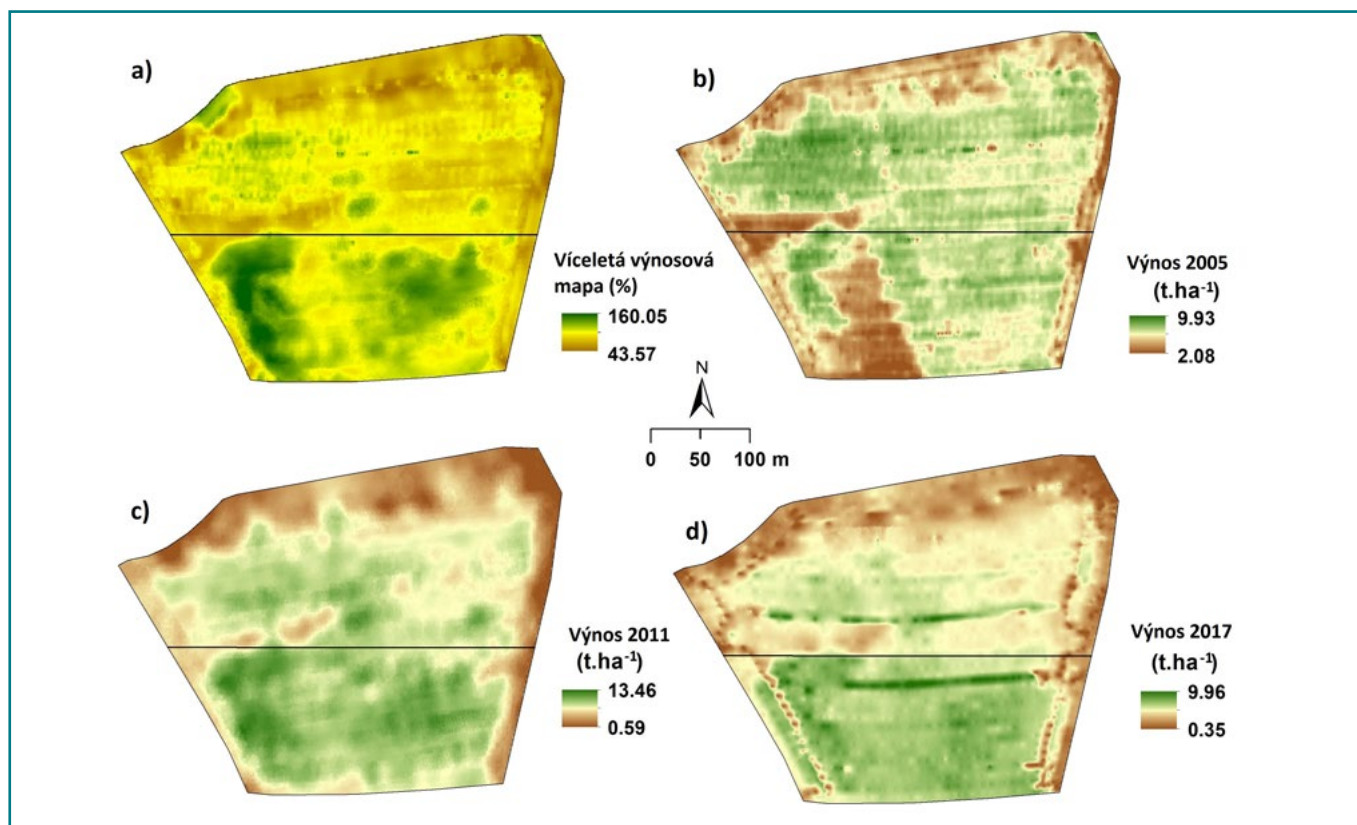
Obrázek 58: Spektrální index NDVI porostů pšenice ozimé různých odrůd – poslední dostupný snímek za sledované vegetační sezóny 2005 – odrůda Ebi (a); 2009 – odrůda Ebi (b); 2011 – odrůda Baletka (c); a 2013 – odrůda Brilliant (d).

a Seance (na severní a sklonitější části pozemku) na experimentálním pozemku VÚRV, v.v.i. v Praze – Ruzyni pomocí spektrálního indexu NDVI.

Koeficient determinace mezi dvěma snímky pořízenými 20. 6. 2017 (BBCH 65) byl 0,876, tedy snímky z družic Sentinel 2 a Landsat 8 si jsou podobné z 88 %, ačkoliv byly pořízeny v takřka stejný okamžik. Byly také staženy a porovnány snímky odpovídající fenologické fázi 55 dle stupnice BBCH v termínu 10. 6. 2017 pro Sentinel 2 a 11. června 2017 pro Landsat 8. Oba snímky byly opět pořízené v cca 10:30 dopoledne. Koeficient determinace mezi těmito snímky byl 0,689, tedy snímky byly shodné z 69 %. Velkou roli zde hrál jednodenní odstup mezi snímky, kdy přes noc přšlo. Voda výrazně mění spektrální vlastnosti povrchu (pohlcuje elektromagnetické záření), což se právě projevilo na mokřem porostu následující den snímání. Navíc na snímku z družice Sentinel 2 z 10. 6. 2017 byla detekována oblačnost na severní části pozemku, která musela být odstraněna z důvodu znehodnocení informace.

U snímků z družice Sentinel 2 lze pro NIR informaci ve výpočtu NDVI využít i speciální spektrální pásmo B8A, které ale není příliš vhodné pro účely zemědělství, jak plyne z odborné literatury. Z výše uvedeného je tedy patrné, že zastupitelnost datových řad je do určité míry omezená a je potřeba ji při interpretaci snímků zohlednit společně s informacemi o počasí. Na již zmíněném experimentálním pozemku byl také analyzován vývoj různých odrůd pšenice ozimé v profilu let 2005 až 2013 v závislosti na místně specifických podmínkách stanoviště, s důrazem na topografii

a počasí hlavní vegetační sezóny sledovaných let. Byly staženy a zanalyzovány volně dostupné snímky z družice Landsat řad 5, 7 a 8 v posledním dostupném termínu, kdy byl porost ještě zelený a šel tedy hodnotit pomocí vegetačních indexů. Experimentální pozemek byl podle topografie pomocí přesných dat z leteckého laserového skenování povrchu poskytnutých z ČÚZK rozdělen na dvě části – severní, více sklonitou; a jižní, rovinnatou část. Ačkoliv byla na celém pozemku zasetá stejná plodina a odrůda, která byla až na výjimku v roce 2005 uniformně ošetřována, snímky NDVI (obrázek 58) ukazují v letech 2011 a 2013 významný rozdíl mezi horní a spodní částí pozemku. V roce 2005 je vývoj opačný z důvodu vyrovnávacího hnojení dusíkem a nerovnoměrné distribuce srážek. Z podrobné analýzy vegetačních sezón plyne, že vybrané odrůdy významně reagovaly na povětrnostní podmínky (úhrn srážek a teplota vzduchu) v hlavních fenologických fázích a topografii pozemku. Vyšší hodnoty NDVI byly s výjimkou roku 2005 zaznamenány ve spodní části pozemku bez ohledu na spektrální vlastnosti vybraných odrůd, které se mohou lišit z různých důvodů, např. rezistence k suchu, schopnost odnožování, barva a struktura porostu aj. Stejně tak byl zaznamenán vyšší výnos (obrázek 59) na spodní části pozemku, opět s výjimkou roku 2005, kdy se projevila strategie vyrovnávacího hnojení dusíkem a distribuce vody, která zajistila tradičně nejvyšší výnos v akumulacích sníženinách pozemku. Také kvalita predikce výnosu v horní a sklonitější části pozemku závisela více na úhrnu srážek a dostupnosti vody. Nelze opominout, že výnos je ovlivněn mnoha dalšími faktory, jako je obsah živin v půdě, fyzikální vlastnosti půdy (zejména technogenní zhutnění), osevnické postupy a jiné.

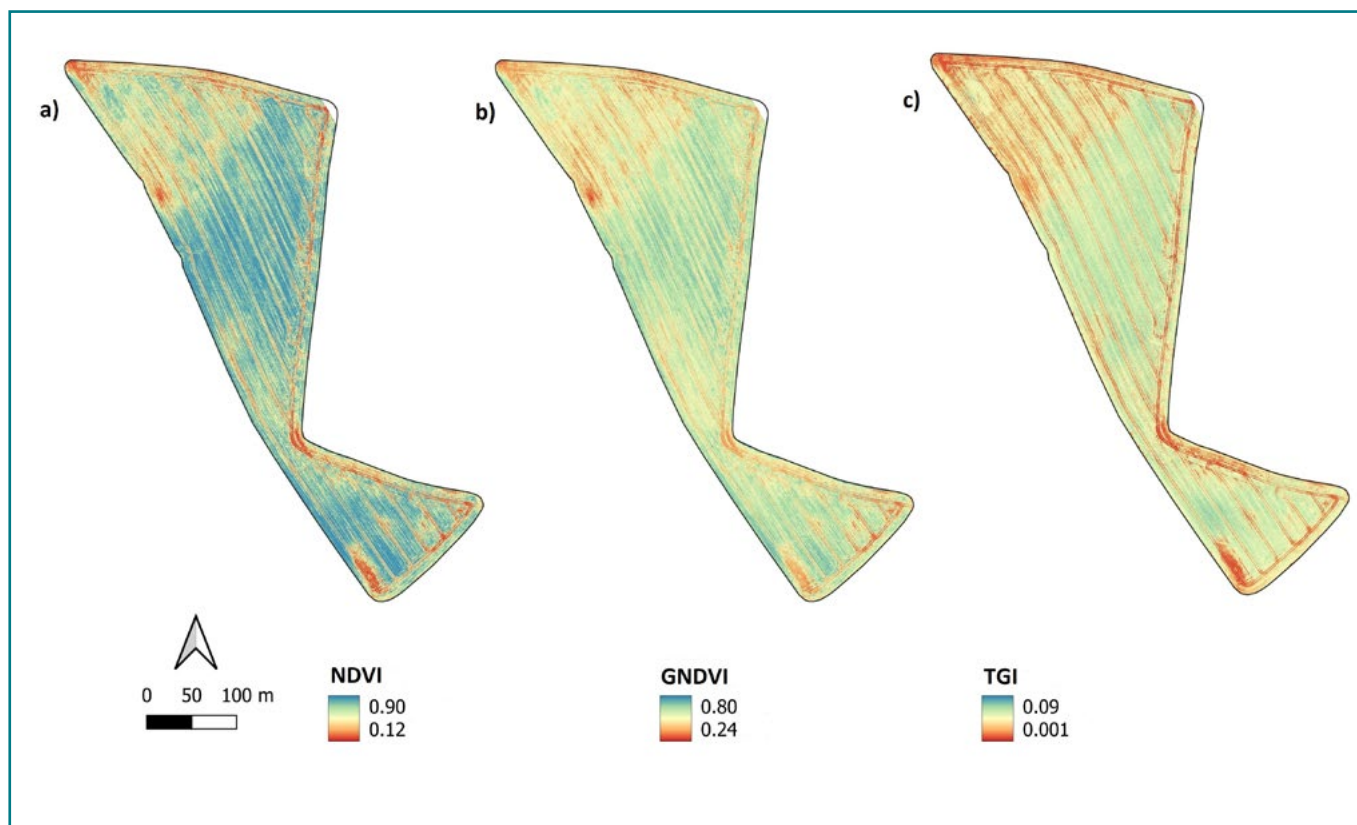


Obrázek 59: Víceletá výnosová mapa (a) odvozená pro obiloviny a výnosové mapy vybraných let (b, c, d) experimentálního pozemku VÚRV, v.v.i. v Praze – Ružyni.

Jiná studie autorů Jelínek et al. (2019) analyzuje porovnání snímků a odvozených spektrálních indexů s aktuálními výnosy i s různou podobou víceletých výnosových map na příkladu pozemku středního zemědělského pozemku. Výsledky studie ukázaly, že informace o výnosu plodin a stavu plodin odvozené ze satelitních snímků mohou být užitečné pro modelování víceletých map. Víceleté mapy výnosů a NDVI mohou být za určitých podmínek užitečným nástrojem pro správu zemědělských pozemků. Tyto modely mají ovšem svá omezení, která mohou být pro zemědělskou praxi klíčová. Studie ukázala, že nejlepším modelem pro odhad výnosu plodin je víceletá výnosová mapa odvozená jen pro obiloviny vysvětlující variabilitu výnosu v průměru ze 44 % pro všechny vybrané roky (při hodnocení porostů pšenice, ječmene a řepky). Nejlepším modelem v této studii pro odhad stavu a variability plodin je víceletá mapa NDVI převzorkovaná do prostorového rozlišení 10 m podle snímku Sentinel 2 pro všechny podklady. Tento model vysvětluje variabilitu porostu pšenice ozimé z 96 % a pak z 38 % pro všechny vybrané snímky NDVI (včetně snímků Landsat a SPOT). Korelace byla významnější pro obiloviny a v sušších a teplejších letech.

Většina vegetačních indexů byla vyvinuta pro úzký okruh zemědělských plodin (např. pro pšenici či obecně pro čeled' lipnicovité) a je tedy na zvážení, zda jsou dostatečně a plnohodnotně využitelné i pro jiné čeledi rostlin, např. pro brukvovité, kam náleží řepka ozimá. Využitelnost nejpoužívanějšího indexu NDVI pro hodnocení porostu řepky již řešili autoři Piekarczyk et al. (2011). Obecné využití metod dálkového průzkumu Země pro hodnocení biofyzikálních

parametrů řepky bylo téma prací autorů Pan et al. (2013) či Li et al. (2014). Ačkoliv je pěstování řepky celosvětově na vzestupu, není (v porovnání s jinými plodinami) příliš publikací, které se monitorováním růstu řepky a odhadem jejího výnosu metodami DPZ zabývají. Využitelností vybraných vegetačních na porosty řepky v podmínkách ČR se zabýval ve své publikaci Domínguez et al. (2017) opět na příkladu experimentálního pozemku ve VÚRV, v.v.i. v Praze – Ružyni. Metodika spočívala v tom, že autoři zkoušeli porovnávat pouze spektrální indexy s výnosem z roku 2012, jelikož právě v tomto roce bylo k dispozici pět snímků (v podmínkách ČR je velkou překážkou oblačnost při hodnocení optických dat). Ty indexy, které měly těsnější korelaci s výnosem, byly pak dále testovány a analyzovány na snímcích z roku 2004 a 2008. Předběžné výsledky jsou v souladu se studiemi jiných autorů (např. Piekarczyk 2001, Piekarczyk et al. 2006, Van Leeuwen and Huete 1996). Tradiční vegetační indexy, které byly použity, nejsou příliš vhodné pro hodnocení porostu řepky ozimé. Jak uvádí Sinclair et al. (1971) a Wolley (1971) vlastnosti odrazivosti a propustnosti jsou zpravidla odlišné mezi listy jednoděložných a dvouděložných rostlin, protože se liší nejen struktura mezofylu listu, ale i odrazivé vlastnosti a struktura svrchní a spodní strany listu. Van Leeuwen and Huete (1996) ve své studii uvádějí, že významnou roli u řepky ozimé hrají také spodní odumřelé listy, které mají jiné optické a histologické vlastnosti než zelená část rostliny. Odumřelé části rostlin mají jinou odrazivost, než zdravé a zelené části rostlin. Rozdíly v odrazivosti jsou významné především v období zralosti (po BBCH 80) nebo mohou být spuštěny stresovými faktory, jako je nedostatek vody a živin či extrémní teploty. Stárnutí rostlin či rozklad



Obrázek 60: Vegetační indexy NDVI (a), GNDVI (b) a TGI (c) získané ze snímků z bezpilotního prostředku ze dne 21. 5. 2020 pro porost máku setého (Zdroj: Lupofyt, s.r.o.).

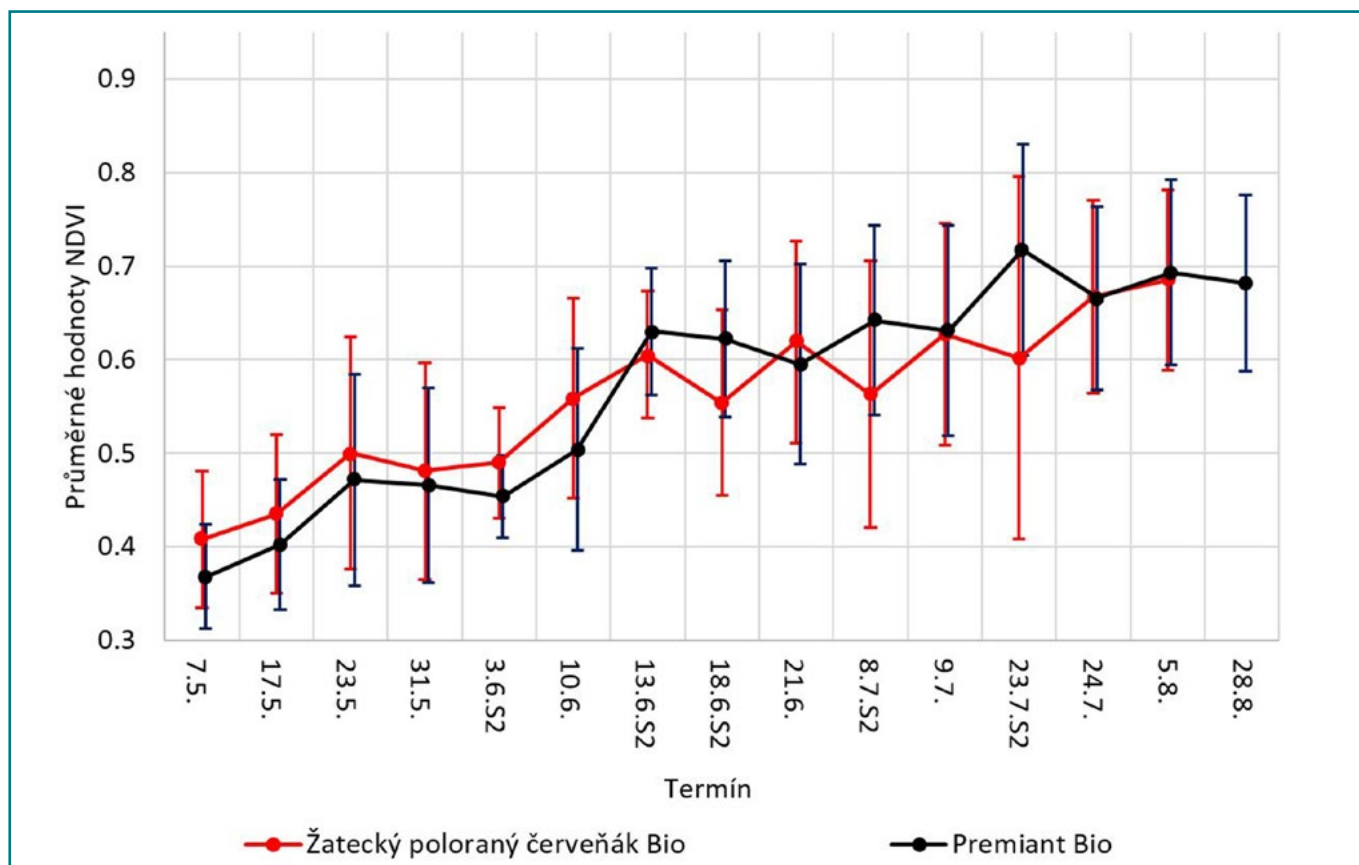
listů nakonec způsobí úbytek všech pigmentů a následnou změnu v odrazivosti porostu. Z uvedeného plyne, že klasické spektrální indexy nejsou příliš vhodné pro popis variability porostu řepky ozimé. Jak vyplynulo z dosavadních výsledků, nejvýznamnější index byl Enhanced Moisture Stress Index (EMSI), který charakterizuje obsah vody či vlhkosti v porostu. Tento index je založen na podílu odrazivosti mezi SWIR 2 a NIR pásmem. Hodnoty EMSI však nebyly stabilní ve všech růstových fázích a lišily se také v závislosti na meteorologických podmínkách v daných letech.

Podobné problémy jako u porostů řepky mohou nastat u máku setého. Jak známo, rostliny máku mají také jinou strukturu než obiloviny vyplývající z jiné čeledi. Opět je zde na zvážení, který index použít při určitých fenologických fázích pro dosažení nejlepších výsledků k zachycení nejen variability porostu, ale také k detekci chorob. Autoři Jelínek et al. [2020] snímali porosty máku bezpilotními prostředky osazenými jako multispektrální kamerou s NIR pásmem, tak i běžně dostupnou kamerou pouze ve viditelné části spektra. Na základě porovnání dat došli k závěru, že NDVI index může v tomto případě snadno nahradit TGI index, který lze odvodit ze snímků z běžné kamery ve viditelné části spektra (obrázek 60). Takové snímky jsou pak vhodné nejen pro zachycení variability, pro následná agrotechnická opatření, ale také pro detekci chorob a škůdců.

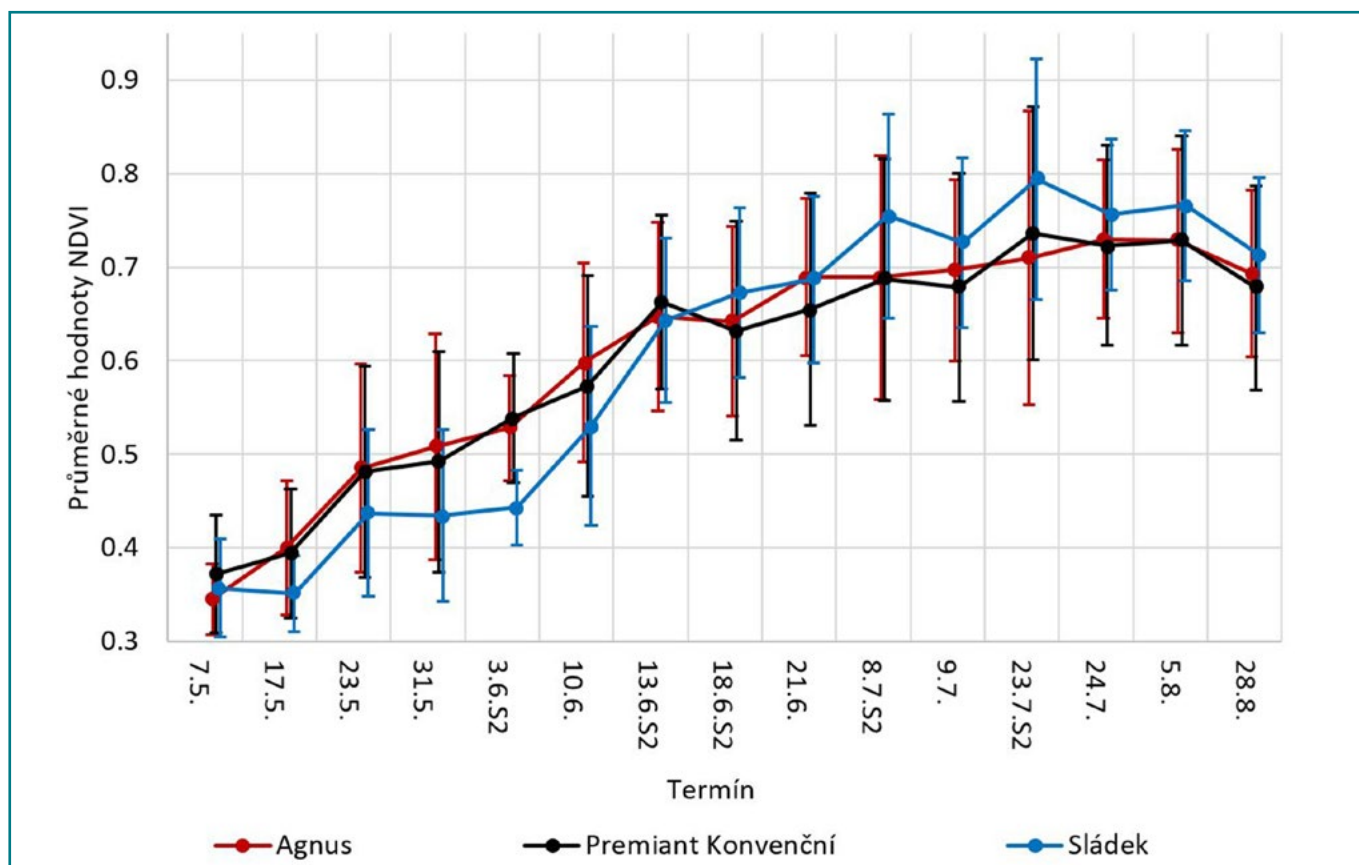
Bezpilotní prostředky jsou vhodným nástrojem ke snímání speciálních plodin jako je vinná réva či chmel otáčivý. Důvodem k monitorování těchto porostů může být jak detekce zdravotního stavu rostlin či obecně vývoj jednotlivých odrůd

v čase s ohledem na pěstební podmínky a vnější nepříznivé vlivy, tak i například detekce mezerovitosti v jednotlivých řadách porostu. Všechny tyto proměnné mohou mít vliv na ekonomickou bilanci hospodaření.

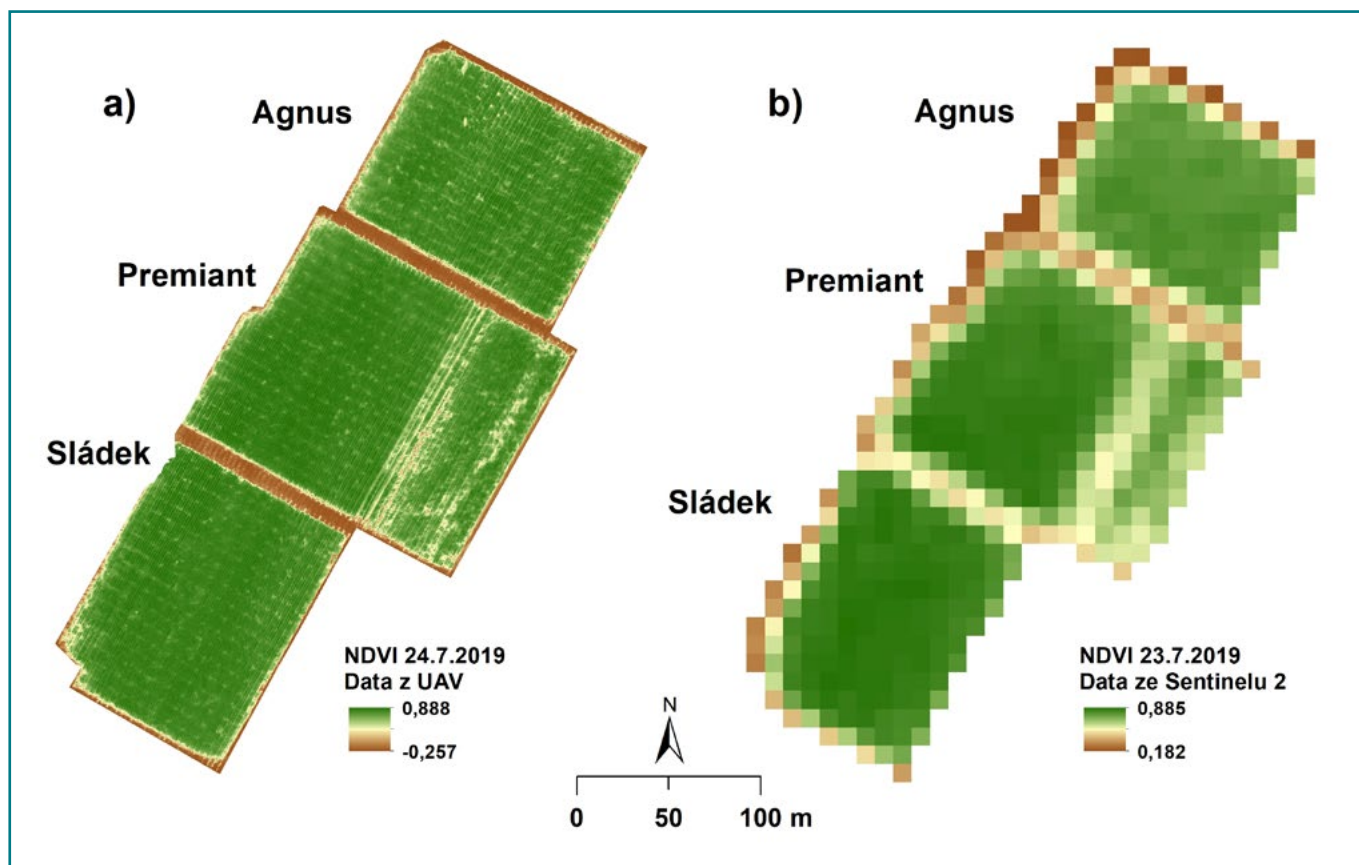
V odborné literatuře existuje mnoho publikací o monitorování vinohradů či sadů. Většina těchto publikací vznikla v přímořských státech Evropy, kde jsou jednak celoročně optimální podmínky pro provozování bezpilotních prostředků, a také tyto státy jsou známy jako významní producenti vína či olivového oleje. O monitorování chmelnic pomocí metod DPZ toho bohužel zatím nebylo příliš mnoho publikováno. Nicméně existuje pár případových studií (Kumhálová et al. 2020 a Kumhálová et al. 2021) vzniklých na základě výzkumného projektu ve spolupráci s Chmelařským institutem s.r.o. v Žatci. Jako pokusné pozemky byly vybrány biochmelnice s odrůdami Žatecký poloraný červeňák a Premiant, a konvenční chmelnice s odrůdami Agnus, Premiant a Sládek. Obě chmelnice leží v lokalitě Stekník pod správou Chmelařského institutu, s.r.o. Žatec. Chmelnice se liší na základě agrotechnických opatření vyplývajících ze své podstaty. Charakteristickými opatřeními v biochmelnici jsou aplikace vybraných hnojiv a prostředků na ochranu rostlin povolených pro ekologické zemědělství. V případě hnojiv se jedná především o chlévskou mrvu z biohnojiv a zelené hnojení, v ochraně rostlin se používají výtažky z různých rostlin a bioagens. Agrotechnická opatření v konvenční chmelnici jsou v souladu s běžnými pěstebními technologiemi tohoto typu. Obě chmelnice jsou uměle zavlažovány kapkovou závlahou. Nicméně podstatnou roli ve vývoji a vitalitě rostlin hrají také místní



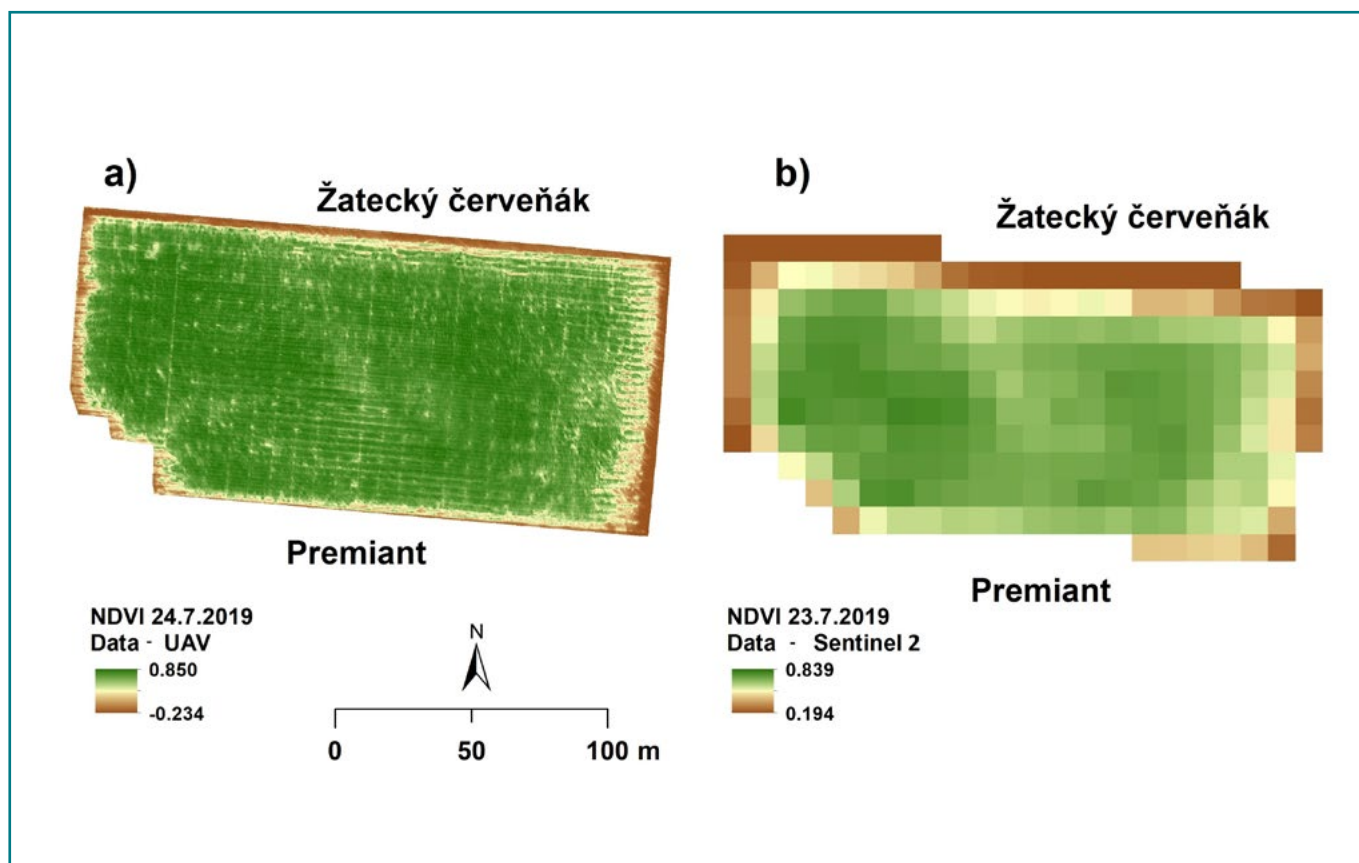
Obrázek 61: Vývoj průměrných hodnot NDVI u odrůd Žatecký červeňák a Premiant v biochmelnici „S2“ u termínu snímání znamená, že data jsou získána z družice Sentinel 2.



Obrázek 62: Vývoj průměrných hodnot NDVI u odrůd Agnus, Premiant a Sládek v konvenční chmelnici. „S2“ u termínu snímání znamená, že data jsou získána z družice Sentinel 2.



Obrázek 63: Normalizovaný diferenční vegetační index vypočítaný pro konvenční chmelnici z dat z bezpilotního prostředku, ze dne 24. 7. 2019 (a) a ze snímku z družice Sentinel 2, ze dne 23. 7. 2019 (b).



Obrázek 64: Normalizovaný diferenční vegetační index vypočítaný pro biochmelnici z dat z bezpilotního prostředku, ze dne 24. 7. 2019 (a) a ze snímku z družice Sentinel 2, ze dne 23. 7. 2019 (b). Hranice mezi odrůdami vede středem chmelnice.

Tabulka 7: Spektrální vlastnosti vybraných senzorů použitých v případové studii pro výpočet vegetačních indexů

Kamera	BLUE Band (nm)	GREEN Band (nm)	RED Band (nm)	NIR Band (nm)
S.O.D.A.	450 (100)	550 (100)	660 (130)	-
Parrot Sequoia+	-	550 (40)	660 (40)	790 (40)
MicaSense RE MX	475 (20)	560 (20)	668 (10)	717 (10)
Sentinel 2	490 (65)	560 (35)	665 (30)	842 (115)

BLUE, GREEN, RED Band = modré, zelené, červené spektrální pásmo; NIR Band = blízké infračervené pásmo; uvedená hodnota značí střed pásma, v závorce je pak šířka celého pásma;

klimatické podmínky a počasí. Odrůdy pěstované v těchto chmelnicích mají své typické vlastnosti, ze kterých vyplývá, že u každé ze studovaných odrůd byl na základě vegetačního indexu NDVI zaznamenán typický vývoj během vegetačního období. Výsledky také ukazují, že jednotlivé odrůdy měly specifický vzorec vývoje rostlin s ohledem na způsob pěstování. Odrůdy chmele pěstované podle pravidel ekologické produkce se ve srovnání s konvenčně pěstovaným chmelem zpozdily ve vývoji, což bylo pravděpodobně způsobeno vyšším tlakem chorob a škůdců v ekologických chmelnicích (obrázky 61 a 62).

Metodologicky stejně byly porovnány snímky z bezpilotních prostředků a družice Sentinel 2 a byla stanovena jejich využitelnost. Z porovnání zdrojů vyplývá, že bezpilotní prostředky s multispektrální kamerou disponující blízkým infračerveným spektrálním pásmem mohou posloužit jako velmi cenný zdroj informací pro sledování vitality a struktury chmelnic až do úrovně jednotlivých rostlin. Stejně tak běžná nízkonákladová kamera disponující pouze pásmo ve viditelné části spektra může spolehlivě sloužit jako cenný zdroj informací pro odvození zelené plochy chmelnic. Snímky z družice Sentinel 2 mají pouze omezené využití vzhledem k prostorovému rozlišení (viz obrázky 63 a 64). Jejich největší benefit spočívá především ve volné dostupnosti a frekvenci snímání. Problémem pak může být častá oblačnost nad územím ČR. Vzájemné doplnění či zastupitelnost obou zdrojů jsou dle dosažených výsledků možné spíše v raných fázích, kdy nejsou ještě chmelnice příliš rozvětvené/vzrostlé. Vzhledem k odlišným spektrálním vlastnostem v blízkém infračerveném pásmu vstupních zdrojů dat se mohou získané výsledky znatelně lišit (viz tabulka 7).

Jak plyne z předchozího textu, snímání v optické části spektra má svá omezení. Nejvýznamnější z nich je častá oblačnost. Výhodou mikrovlnné části spektra je, že elektromagnetické záření v těchto vlnových délkách může pronikat skrz oblačnost a lze tak získávat data bez omezení na denní dobu. Od roku 2014 jsou k dispozici snímky z družice Sentinel 1A. Tuto misi pak v roce 2016 doplnila identická družice Sentinel 1B. Snímky jsou dostupné v archivu ESA (Copernicus Open Access Hub). Družice nesou radarový senzor C-SAR, který snímá zemský povrch pouze v jednom radarovém pásmu

typu C. Z radarových dat je pro účely zemědělství možné vy počítat tzv. Radar Vegetation Index (RVI), který byl primárně odvozen pro zjišťování kvality a úrovně růstu plodin. RVI se pohybuje v rozmezí hodnot 0 až 1, přičemž hodnota 0 odpovídá hladkým povrchům. S rostoucí vegetací zpravidla roste i hodnota RVI, což lze využít například pro odhad fenologické fáze rostlin (Kim et al. 2014). Výkladem RVI signálu se již zabývalo mnoho publikací (např. Koppe et al. 2013, Jiao et al. 2014, Sánchez et al. 2016), ze kterých plyne, že RVI je funkcí struktury povrchu porostu, především tvaru, orientace, výšky, hustoty a množství biomasy a dielektrických vlastností. V České republice se implementací radarových dat do zemědělské praxe zabývali např. autoři Tůma et al. (2021), kteří porovnávali snímky z družice Sentinel 1, Sentinel 2 a Landsat 8 doplněná referenčními daty na porostech pšenice a řepky ozimé v průběhu let 2015 až 2018 na pozemcích středního zemědělského družstva. Byly odvozeny indexy NDVI pro optické a RVI pro radarové snímky. Ze statistické analýzy lze vyvodit, že RVI má podobný vývoj jako fenologická křivka, což potvrdilo hypotézu, že radarová data z mise Sentinel 1 mohou vhodně doplňovat optická satelitní data s adekvátní přesností. To může výrazně zlepšit přesnost satelitních dat a zajistit jejich dostupnost a použitelnost pro implementaci pokročilých prvků řízení v místě hospodaření i za oblačného počasí. Otázkou však zůstává, zda radarová data Sentinel 1 mohou plně nahradit optická data. Při analýze vegetace z časových řad Sentinel 1 by měla být zohledněna anizotropie způsobená rozdílným dopadovým úhlem a úhlem azimutu zpětného odrazu signálu. Zdá se, že typ relativní oběžné dráhy a typ platformy SAR je pro takový přístup zásadní (například ve zmíněné publikaci vycházely nejlepší výsledky z dat relativní orbity 73 a platformy A). Analýza byla provedena v podmínkách České republiky; je však zřejmé, že podobné problémy vyvstanou kdekoli na Zemi. Budoucí výzkum by měl zvážit úpravu RVI v kontextu relativní oběžné dráhy a platformy.

7.7.3 SOUHRN

DPZ coby silný nástroj v precizním zemědělství, může posloužit jako nedestruktivní prostředek při monitoringu porostu během jeho vegetačního období. Vždy záleží na účelu

sledování porostu. Od toho se odvíjí i použití správného prostorového či spektrálního rozlišení snímků, např. pro sledování variability porostu může velmi dobře posloužit i snímek z družice Landsat s prostorovým rozlišením 30 m i v případě pozemku velikého 11,5 ha jako je experimentální pole ve VÚRV, v.v.i. V případě těchto snímků převažuje výhoda spektrálního rozlišení nad rozlišením prostorovým. Chceme-li hodnotit detaily, lze použít data velmi vysokého prostorového rozlišení, mezi které patří např. snímky z družice QuickBird či WorldView-2. Tato volba se může týkat detekce výskytu plevelů. V současné době se nabízí i možnost využití snímků z bezpilotních prostředků, které mají řadu diskutovatelných výhod i nevýhod. Obecně lze ovšem říci, že bezpilotní prostředky se hodí spíše na monitoring menšího územního celku, přičemž jejich převažující výhodou je velmi vysoké prostorové rozlišení (v řádu centimetrů), a naopak nevýhodou nedostatečnost spektrálního rozlišení běžně dostupných kamer. Dalšími dílčími závěry tohoto směru je, že nevýhodou použití optických dat na území České republiky je častá oblačnost, která znemožňuje kontinuální sledování porostu. Zde se pak nabízí využití radarových snímků, kde oblačnost nevádí. Bohužel využitelnost radarových snímků je stále zatím na počátku implementace v praxi.

Je potřeba si také uvědomit, že výše zmíněné publikace řešily pokusy, které byly vedeny na vybraných pozemcích s místními specifickými podmínkami, a výsledky citovaných pokusů se tak nestávají obecným návodem, jak obhospodářovat jakékoliv pozemky. U každé studie je obecně v rámci diskuse uvedeno, zda jsou získané výsledky v souladu i s jinými studiemi či v souladu nejsou a proč. Tento fakt se stává velmi důležitým z hlediska uplatnitelnosti výsledků v praxi. Vždy je potřeba velmi citlivě reagovat právě na místní podmínky. Z tohoto důvodu je na místě spolupráce s agronomy zemědělských podniků, kteří znají své pozemky nejlépe.



8 ZÁVĚR


Data a metody Dálkového průzkum Země si již našly své uplatnění v zemědělské praxi a jak bylo ukázáno, paleta jejich využití pro konkrétní aplikace může být velice široká. DPZ může sloužit pouze jako zdroj pomocných dat pro určité návrhy v rámci hospodaření, může ale také sloužit jako přímý prostředek pro cílené získání důležitých informací, na jejichž základě může být prováděno rozhodování v rámci cíleného hospodaření na pozemku. Velkou výhodou v tomto smyslu je prostorový záběr dat a široká škála nástrojů, které lze využít. Doménou poslední dekády se bezesporu stalo nasazování bezpilotních prostředků neboli spíše lidově dronů. Jejich nasazení má ale také svá specifika a jsou vhodné převážně pro detailní mapování či monitoring. Nezastupitelnou roli tak sehrávají, a dále jistě budou, satelitní data, jejichž dostupnost a časové rozlišení se stále zlepšuje. Stejně tak lze předpokládat stálý dynamický vývoj jednak provozovaných systémů satelitů a senzorů, jednak také vývoj v technologiích zpracování obrazových dat včetně vyhodnocování dat v časové řadě. V delším časovém horizontu pak lze očekávat i zlepšování spektrálních charakteristik senzorů, a tedy i vyšší využití hyperspektrálních dat, ale také i zlepšování prostorového rozlišení dat. Obecně se dá také očekávat větší využití radarových dat v zemědělských aplikacích. Ty mají totiž obrovský potenciál, který není zatím zcela naplňován, byť již dnes existuje řada aplikací nad těmito daty.

Nicméně už v této době jsou k dispozici vhodná data a řada aplikací, jak bylo ukázáno, je již rutinně nasazována do praxe. Již dnes tak metody a data DPZ umožňují lépe vyhodnocovat půdní prostředí a zemědělské plodiny, a tak napomáhají k vyšší efektivitě v rámci hospodaření. Přínosy využití těchto dat tak mohou mít i významný ekonomický efekt pro zemědělce a zemědělské podniky, ale zároveň mohou mít přeneseně i efekt celospolečenský prostřednictvím lepšího a cílenějšího hospodaření v krajině s minimalizací dopadů na životní prostředí. Prostřednictvím výstupů z dat DPZ mohou být mnohem lépe zacíleny jednotlivé zemědělské operace a zejména pak optimalizováno množství vstupů do prostředí půda-rostlina, a tak i do životního prostředí. Z popsaných možností využití by měli být takové benefity patrné.

Nicméně není bezpochyby vhodné zapomínat i na nevýhody použití dat DPZ a výzvy, které jsou na jejich nasazení do praxe kladeny.

Obecně využití dat DPZ není jednoduché a vyžaduje řadu předpokladů, které musí být naplněny, aby bylo jejich využití prospěšné. Jednou z věcí, na kterou je vždy při použití dat DPZ potřeba apelovat je nepostradatelnost pozemního ověření získaných informací. Byť z názvu by bylo možné usuzovat, že metody DPZ umožňují sběr a analýzu dat vzdáleně, ověřování informací, případně kalibrace dat, by měla být vždy nedílnou součástí těchto metod, tak aby bylo ověřeno, že následné rozhodování je postaveno na reálném základě. Dalším předpokladem pro využití metod je samozřejmě kvalitní personál, který s daty zachází jak v procesu sběru a analýzy, tak v procesu jejich využití. To samozřejmě vyžaduje dovednosti, které získání požadované informace umožní. Určitě je vhodné znát alespoň základy teorie sběru dat pomocí používaných metod DPZ, ale zejména pak umět pracovat s digitálními prostorovými informacemi a daty, a to zejména v prostředí geografických informačních systémů (GIS), ať už desktopových či integrovaných v nějakých webových či mobilních aplikacích. Pro základní práci s daty DPZ mohou stačit základní prostředky a znalosti. Některé pokročilé aplikace už však sebou nesou zvýšené nároky jak na obsluhující personál, tak na použitou infrastrukturu pro zpracování a uchování dat.

Trendem dnešní doby je ovšem také přenášení řady činností do virtuálního prostředí internetu a nabídka služeb, které je možno využít, se stále rozšiřuje. Stejně tak se rozšiřuje portfolio služeb, které mohou nabídnout již cílové zpracované produkty DPZ v požadované podobě, a tak může být řada výsledků potřebných pro rozhodování dostupných i jednoduše uchopitelnou formou i ne zcela zkušeným uživatelům. V tomto ohledu mohou být benefity využití dat DPZ v precizním zemědělství opravdu pro kohokoli, kdo bude mít chuť a snahu je využít.



ZDROJE

- Barati, S., Rayegani, B., Saati, M., Sharifi, A., & Nasri, M. (2011). Comparison the accuracies of different spectral indices for estimation of vegetation cover fraction in sparse vegetated areas. *Egypt. J. Remote Sens. Space Sci.* 14, 49–56.
- Barnes, E., Clarke, T., Richards, S., Colaizzi, P., Haberland, J., Kostrzewski, M., Waller, P., Choi, C., Riley, E., Thompson, T. (2000) Coincident detection of crop water stress, nitrogen status and canopy density using ground based multispectral data, pp. 16-19.
- Barnes, E.M., Sudduth, K.A., Hummel, J.W., Lesch, S.M., Corwin, D.L., Yang, C., Daughtry, C.S.T., & Bausch, W.C. (2003). Remote – and ground-based sensor techniques to map soil properties. *Photogramm. Eng. Remote Sens.* 6, 619–630.
- Barnes, A.P., Soto, I., Eory, V., Beck, B., Balafoutis, A., Sanchez, B., Vangeyte, J., Fountas, S., van der Wal, T., Gomez-Barbero, M. (2019) Exploring the adoption of precision agricultural technologies: A cross regional study of EU farmers. *Land Use Policy* 80, 163-174.
- Bastiaanssen, W. G. M., Menenti, M., Feddes, R. A., & Holtslag, A. A. M. (1998). A remote sensing surface energy balance algorithm for land (SEBAL). 1. Formulation. *Journal of Hydrology*, 212–213, 198–212.
- Bégué, A., Todoroff, P. & Pater, J. (2008). Multi-time scale analysis of sugarcane within-field variability: improved crop diagnosis using satellite time series? *Precision Agriculture*, 9, 161-171.
- Bellvert, J., Marsal, J., Girona, J., Gonzalez-Dugo, V., Fereres, E., Ustin, S., & Zarco-Tejada, P. (2016). Airborne thermal imagery to detect the seasonal evolution of crop water status in peach, nectarine and saturn peach orchards. *Remote Sens.* 8, 39.
- Ben-Dor, E., & Banin, A. (1990). Near-Infrared Reflectance Analysis of Carbonate Concentration in Soils. *Appl. Spectrosc.*, 44(6), 1064–1069.
- Ben-Dor, E., Irons, J. R., & Epema, G. F. (1999). Soil Reflectance. In A. N. Rencz & A. Ryerson, Robert (Eds.), *Manual of Remote Sensing, Volume 3, Remote Sensing for the Earth Sciences* (3rd ed., Issue January 1999, pp. 111–188). John Wiley & Sons Inc.
- Ben-Dor, E., Chabrillat, S., Demattê, J. A. M., Taylor, G. R., Hill, J., Whiting, M. L., & Sommer, S. (2009). Using Imaging Spectroscopy to study soil properties. *Remote Sensing of Environment*, 113(SUPPL. 1), S38–S55.
- Ben-Dor, E., & Demattê, J. A. M. (2015). Remote Sensing of Soil in the Optical Domains. In P. S. Thenkabail (Ed.), *Land Resources Monitoring, Modeling, and Mapping with Remote Sensing* (Remote Sen, pp. 733–787). CRC Press.
- Beven, K. J. & Kirkby, M. (1979). A physically-based, variable contributing area model of basin hydrology. *Hydrological Sciences Bulletin*, 24, 43-69.
- Birth, G. and McVey, G. (1968). Measuring the Color of Growing Turf with a Reflectance Spectrophotometer. *Agronomy Journal*, 60, 640-643.
- Blackmore, S. (2000) The interpretation of trends from multiple yield maps. *Computers and Electronics in Agriculture* 26(1), 37-51.
- Boegh, E., Soegaard, H., Broge, N., Hasager, C., Jensen, N., Schelde, K. and Thomsen, A. (2002). Airborne Multi-spectral Data for Quantifying Leaf Area Index, Nitrogen Concentration and Photosynthetic Efficiency in Agriculture. *Remote Sensing of Environment*, 81 (2-3), 179-193.
- Boydell, B., & Mc Bratney, A. B. (2002). Identifying potential within-field management zones from cottonyield estimates. *Precision Agriculture*, 3, 9–23.
- Broge, N. and Leblanc, E. (2000). Comparing Prediction Power and Stability of Broadband and Hyperspectral Vegetation Indices for Estimation of Green Leaf Area and Canopy Chlorophyll Density. *Remote Sensing of Environment*, 76, 156-172.
- Calera, A., Campos, I., Osann, A., D’Urso, G., & Menenti, M. (2017). Remote sensing for crop water management: From ET modelling to services for the end users. *Sensors (Switzerland)*, 17(5), 1–25.
- Campbell, J.B., & Wynne, R.H. (2011). *Introduction to Remote Sensing*. fifth ed. Guildford Press.
- Campos, I., González-Gómez, L., Villodre, J., Calera, M., Campoy, J., Jiménez, N., Plaza, C., Sánchez-Prieto, S., & Calera, A. (2019). Mapping within-field variability in wheat yield and biomass using remote sensing vegetation indices. *Precision Agriculture*, 20, 214-236.

- Casa, R., Castaldi, F., Pascucci, S., Palombo, A., & Pignatti, S. (2013). A comparison of sensor resolution and calibration strategies for soil texture estimation from hyperspectral remote sensing. *Geoderma*, 197–198, 17–26.
- Castaldi, F., Palombo, A., Santini, F., Pascucci, S., Pignatti, S., & Casa, R. (2016). Evaluation of the potential of the current and forthcoming multispectral and hyperspectral imagers to estimate soil texture and organic carbon. *Remote Sensing of Environment*, 179, 54–65.
- Ceccato, P. et al. (2001). Detecting Vegetation Leaf Water Content Using Reflectance in the Optical Domain. *Remote Sensing of Environment*, 77, 22–33.
- Chlingaryan, A., Sukkarieh, S., & Whelan, B. (2018). Machine learning approaches for crop yield prediction and nitrogen status estimation in precision agriculture: A review. *Computers and Electronics in Agriculture*, 151, 61–69.
- Corwin, D.L., Plant, R.E. (2005) Applications of apparent soil electrical conductivity in precision agriculture. *Computers and Electronics in Agriculture* 46(1-3), 1-10.
- Crookston, R.K. (2006) A Top 10 List of Developments and Issues Impacting Crop Management and Ecology During the Past 50 Years. *Crop Science* 46(5), 2253-2262.
- Datt, B. (1999). A New Reflectance Index for Remote Sensing of Chlorophyll Content in Higher Plants: Tests Using Eucalyptus Leaves. *Journal of Plant Physiology*, 154, 30–36.
- Daughtry, C. (2001). Discriminating Crop Residues from Soil by Short-Wave Infrared Reflectance. *Agronomy Journal*, 93, 125–131.
- Daughtry, C., Hunt Jr., E. and McMurtrey III., J. (2004). Assessing Crop Residue Cover Using Shortwave Infrared Reflectance. *Remote Sensing of Environment*, 90, 126–134.
- Demattê, J. A. M., Alves, M. R., Terra, F. da S., Bosquilia, R. W. D., Fongaro, C. T., & Barros, P. P. da S. (2016). Is it possible to classify topsoil texture using a sensor located 800 km away from the surface? *Revista Brasileira de Ciencia Do Solo*, 40, 1–13.
- Demattê, J. A. M., Safanelli, J. L., Poppiel, R. R., Rizzo, R., Silvero, N. E. Q., Mendes, W. de S., ... Lisboa, C. J. da S. (2020). Bare Earth's Surface Spectra as a Proxy for Soil Resource Monitoring. *Scientific Reports*, 10(1), 4461.
- Denis, A., Stevens, A., van Wesemael, B., Udelhoven, T., & Tychon, B. (2014). Soil organic carbon assessment by field and airborne spectrometry in bare croplands: Accounting for soil surface roughness. *Geoderma*, 226–227(1), 94–102.
- Diek, S., Fornallaz, F., Schaepman, M. E., & de Jong, R. (2017). Barest Pixel Composite for Agricultural Areas Using Landsat Time Series. *Remote Sensing*, 9(12), 1245.
- Domínguez, J.A., Kumhálová, J., Novák, P. (2015). Winter oilseed rape and winter wheat growth prediction using remote sensing methods. *Plant Soil and Environment*, 61(9), 410–416.
- Domínguez J.A., Kumhálová J., and Novák P., 2017. Assessment of the relationship between spectral indices from satellite remote sensing and winter oilseed rape yield. *Agronomy Res.*, 15, 55–68.
- Doraiswamy, P. C., Hatfield, J. L., Jackson, T. J., Akhmedov, B., Prueger, J., & Stern, A. (2004). Crop condition and yield simulations using Landsat and MODIS. *Remote Sensing of Environment*, 92, 548–559.
- Doraiswamy, P. C., Hollinger, S., Sinclair, T. R., Stern, A., Akhmedov, B., & Prueger, J. (2001). Application of MODIS derived parameters for regional yield assessment. In: *Proceedings of Remote Sensing for Agriculture, Ecosystems, and Hydrology III*, 17–21 September 2001, Toulouse, 1–8. [CD-ROM 4542-1].
- Drerup, P., Brueck, H., & Scherer, H. W. (2017). Evapotranspiration of winter wheat estimated with the FAO 56 approach and NDVI measurements in a temperate humid climate of NW Europe. *Agricultural Water Management*, 192, 180–188.
- Dvorakova, K., Heiden, U., & van Wesemael, B. (2021). Sentinel-2 Exposed Soil Composite for Soil Organic Carbon Prediction. *Remote Sensing*, 13(9), 1791.
- Ebengo, D. M., Vaudour, E., Gilliot, J., Hadjar, D., & Baghdadi, N. (2018). Potential of combined Sentinel 1 / Sentinel 2 images for mapping topsoil organic carbon content over cropland taking into account soil roughness. In *Geophysical Research Abstracts*, vol. 20, EGU General Assembly 2018 (Vol. 20, p. 14368). Wien: EGU.
- Edrees, M.M.R.H., Lukas, V., Křen, J. (2013) Determination of spectral characteristics of winter wheat canopy, pp. 37–42.
- Elbl, J., Lukas, V., Kintl, A., Kynický, J., Brtnický, M. (2018) Variable – rate nitrogen application in wheat production on the basis of satellite images analysis to increase yield and reduce environmental risks, pp. 725–732, International Multidisciplinary Scientific Geoconference.
- El-Shikha, D.M., Waller, P., Hunsaker, D., Clarke, T., & Barnes, E. (2007). Ground-based remote sensing for assessing water and nitrogen status of broccoli. *Agric. Water Manage.* 92, 183–193.
- Evans L. T. (1993). *Crop Evaluation, Adaptation and Yield*. Cambridge University Press, Cambridge)
- Falkowski, M.J., Gessler, P. E., Morgan, P., Hudak, A. T. & Smith, A. M. S. (2005). Characterizing and Mapping Forest Fire Fuels Using ASTER Imagery and Gradient Modeling. *Forest Ecology and Management*, 217, 129–146.
- Fourty, T. et al. (1996). Leaf Optical Properties with Explicit Description of Its Biochemical Composition: Direct and Inverse Problems. *Remote Sensing of Environment*, 56, 104–117.
- Franch, B., Vermote, E.F., Becker-Reshef, I., Claverie, M., Huang, J., Zhang, J., Justice, C., & Sobrino, J. A. (2015). Improving the timeliness of winter wheat production forecast in the United States of America, Ukraine and China using MODIS data and NCAR growing degree day information. *Remote Sensing of Environment*, 161, 131–148.
- Freeman, T. G. (1991). Calculating catchment area with divergent flow based on regular grid. *Computers & Geosciences*, 17(3), 413–422.
- Fu, Y., Yang, G., Wang, J., Song, X., Feng, H. (2014) Winter wheat biomass estimation based on spectral indices, band depth analysis and partial least squares regression using hyperspectral measurements. *Computers and Electronics in Agriculture* 100(0), 51–59.

- Gago, J., Douthe, C., Coopman, R. E., Gallego, P. P., Ribas-Carbo, M., Flexas, J., ... Medrano, H. (2015). UAVs challenge to assess water stress for sustainable agriculture. *Agricultural Water Management*, 153, 9–19.
- Gao, B. (1995). Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water from Space. *Proceedings of SPIE 2480*, 225–236.
- Gao, B. (1996). NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* 58, 257–266.
- Garrido-Rubio, J., Calera Belmonte, A., Fraile Enguita, L., Arellano Alcázar, I., Belmonte Mancebo, M., Campos Rodríguez, I., & Bravo Rubio, R. (2018). Remote sensing-based soil water balance for irrigation water accounting at the Spanish Iberian Peninsula. *Proceedings of the International Association of Hydrological Sciences*, 380, 29–35.
- Ge, Y., Morgan, C. L. S., Grunwald, S., Brown, D. J., & Sarkhot, D. V. (2011). Comparison of soil reflectance spectra and calibration models obtained using multiple spectrometers. *Geoderma*, 161(3–4), 202–211.
- Ge, Y., Thomasson, J. A., & Sui, R. (2011). Remote sensing of soil properties in precision agriculture: A review. *Frontiers of Earth Science*, 5(3), 229–238.
- Gholizadeh, A., Žižala, D., Saberioon, M., & Borůvka, L. (2018). Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging. *Remote Sensing of Environment*, 218, 89–103.
- Gitelson, A.A., Kaufman, Y.J., Stark, R. & Rundquist, D. (2002). Novel Algorithms for Remote Estimation of Vegetation Fraction. *Remote Sensing of the Environment*, 80, 76–87.
- Gitelson, A. and Merzlyak, M. (1994). Spectral Reflectance Changes Associated with Autumn Senescence of *Aesculus Hippocastanum* L. and *Acer Platanoides* L. Leaves. *Journal of Plant Physiology*, 143, 286–292.
- Gitelson, A. and Merzlyak, M. (1998). Remote Sensing of Chlorophyll Concentration in Higher Plant Leaves. *Advances in Space Research*, 22, 689–692.
- Gitelson, A., Merzlyak, M. and Chivkunova, O. (2001). Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. *Photochemistry and Photobiology*, 71, 38–45.
- Gitelson, A., et al. (2002). Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. *Photochemistry and Photobiology*, 75, 272–281.
- Gobron, N., Pinty, B., Verstraete, M. M. & Widlowski, J. L. (2000). Advanced Vegetation Indices Optimized for up-Coming Sensors: Design, Performance, and Applications. *IEEE Transactions on Geoscience and Remote Sensing*, 38(6), 2489–2505.
- Gomez, C., Viscarra Rossel, R. a., & McBratney, A. B. (2008). Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An Australian case study. *Geoderma*, 146(3–4), 403–411.
- Gontia, N.K., & Tiwari, K.N. (2008). Development of crop water stress index of wheat crop for scheduling irrigation using infrared thermometry. *Agric. Water Manage.* 95, 1144–1152.
- Gonzalez-Dugo, V., Zarco-Tejada, P., Nicolás, E., Nortes, P. A., Alarcón, J. J., Intrigliolo, D. S., & Fereres, E. (2013). Using high resolution UAV thermal imagery to assess the variability in the water status of five fruit tree species within a commercial orchard. *Precision Agriculture*, 14(6), 660–678.
- Govender, M., Dye, P.J., Weiersbye, I.M., Witkowski, E.T.F., & Ahmed, F. (2009). Review of commonly used remote sensing and ground-based technologies to measure plant water stress. *Water SA* 35.
- Grassini P., van Bussel L.G.J., van Wart J., Wolf J., Claessens L., Yang H., Boogaard H., de Groot H., van Ittersum M.K., and Cassman K.G., 2015. How good is good enough? Data requirements for reliable crop yield simulations and yield gap analysis. *Field Crops Res.*, 117, 49–63. doi: 10.1016/j.fcr.2015.03.004
- Guo, W., Maas, S. J., & Bronson, K. F. (2012). Relationship between cotton yield and soil electrical conductivity, topography, and Landsat imagery. *Precision Agriculture*, 13, 678–692.
- Gutiérrez, S., Diago, M.P., Fernández-Novales, J., & Tardaguila, J. (2018). Vineyard water status assessment using on-the-go thermal imaging and machine learning. *PLOS One* 13, e0192037.
- Haboudane, D., Miller, J.R., Pattey, E., Zarco-Tejada, P.J., & Strachan, I.B. (2004). Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90, 337–352.
- Hbirkou, C., Pätzold, S., Mahlein, A. K., & Welp, G. (2012). Airborne hyperspectral imaging of spatial soil organic carbon heterogeneity at the field-scale. *Geoderma*, 175–176, 21–28.
- Heege, H.J., Reusch, S., Thiessen, E. (2008) Prospects and results for optical systems for site-specific on-the-go control of nitrogen-top-dressing in Germany. *Precision Agriculture* 9(3), 115–131.
- Hively, W. D., McCarty, G. W., Reeves, J. B., Lang, M. W., Oesterling, R. a., & Delwiche, S. R. (2011). Use of Airborne Hyperspectral Imagery to Map Soil Properties in Tilled Agricultural Fields. *Applied and Environmental Soil Science*, 2011, 1–13.
- Holmgren, P. (1994). Multiple flow direction algorithms for runoff modelling in grid-based elevation models: an empirical evaluation. *Hydrological Processes*, 8(4), 327–334.
- Huete, A.R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25, 295–309.
- Huete, A., et al. (2002). Overview of the Radiometric and Biophysical Performance of the MODIS Vegetation Indices. *Remote Sensing of Environment*, 83, 195–213.
- Hunt, E. R., Doraiswamy, P. C., McMurtrey, J. E., Daughtry, C. S. T., Perry, E. M. & Akhmedov, B. (2013). A Visible Band Index for Remote Sensing Leaf Chlorophyll Content at the Canopy Scale. *International Journal of Applied Earth Observation and Geoinformation*, 21, 103–112.
- Hunt Jr., E. and Rock, B. (1989). Detection of Changes in Leaf Water Content Using Near- And Middle-Infrared Reflectances. *Remote Sensing of Environment*, 30, 43–54.

- Iqbal, J., Read, J. J., Thomasson, A. J., & Jenkins, J. N. (2005). Relationships between soil-landscape and dryland cotton lint yield. *Soil Science Society America Journal*, 69, 872–882.
- Jaafar, H.H., & Ahmad, F.A. (2015). Crop yield prediction from remotely sensed vegetation indices and primary productivity in arid and semi-arid lands. *Int. J. Remote Sens.* 36, 4570–4589.
- Jelínek, Z., Kumhálová, J., Chyba, J., Wohlmuthová, M., Madaras, M., and Kumhála, F. (2020). Landsat and Sentinel-2 images as a tool for the effective estimation of winter and spring cultivar growth and yield prediction in the Czech Republic. *International Agrophysics*, 34, 391–406.
- Jelínek Z., Starý K., and Kumhálová J. (2019). Assessment of production zones modelling accuracy based on satellite imaging and yield measurement of selected agriculture plot. *Agronomy Research*, 17(2), 447–455.
- Jenson, S. K., & Domingue, J. O. (1988). Extracting topographic structure from digital elevation data for geographic information system analysis. *Photogrammetric Engineering and Remote Sensing*, 54, 1593–1600.
- Jiao, X., Kovacs, J. M., Shang, J., McNairn, H., Walters, D., Mab, B., & Geng, X. (2014). Object-oriented crop mapping and monitoring using multi-temporal polarimetric RADARSAT-2 data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 96, 38–46
- Jin, X., Kumare, L., Lia, Z., Fenga, H., Xua, X., Yanga, G., Wangf, J. (2018). A review of data assimilation of remote sensing and crop models. *European Journal of Agronomy*, 92, 141–152.
- Jin, Z.N., Archontoulis, S.V., Lobell, D.B. (2019) How much will precision nitrogen management pay off? An evaluation based on simulating thousands of corn fields over the US Corn-Belt. *Field Crops Research* 240, 12–22.
- Jongschaap, R. E. E., & Schouten, L. S. M. (2005). Predicting wheat production at regional scale by integration of remote sensing data with a simulation model. *Agronomy for Sustainable Development*, 25, 481–489.
- Julien, Y., Sobrino, J. A., & Jimenez-Munoz, J.-C. (2011). Land use classification from multitemporal Landsat imagery using the Yearly Land Cover Dynamics (YLCD) method. *International Journal of Applied Earth Observation and Geoinformation*, 13, 711–720.
- Kasampalis, D. A., Alexandridis, T. K., Deva, C., Challinor, A., Moshou, D., & Zalidis, G. (2018). Contribution of remote sensing on crop models: A review. *Journal of Imaging*, 4(4).
- Kawashima, S. and Nakatani M. (1998). An Algorithm for Estimating Chlorophyll Content in Leaf Using a Video Camera. *Annals of Botany*, 81(1), 49–54.
- Kerry, R., & Oliver, M. A. (2007). Comparing sampling needs for variograms of soil properties computed by the method of moments and residual maximum likelihood. *Geoderma*, 140, 383–396.
- Kim, Y-H., Oh, J-H., & Kim, Y-I. (2014). Comparative analysis of the multispectral vegetation indices and the radar vegetation index. *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, 32, 607–615.
- Kleinjan, J., Clay, D.E., Carlson, C.G., Clay, S.A. (2007) GIS applications in agriculture. Pierce, F.J. and D., C. (eds), pp. 65–80, CRC Press, Boca Raton.
- Klem, K., Míša, P., Míša, M., Křen, J. (2014) Využití měření spektrální odrazivosti a odvozených specializovaných vegetačních indexů v pěstební technologii jarního ječmene [Metodika pro zemědělskou praxi], p. 44, Agrotest fyto ; Mendelova univerzita v Brně, Kroměříž; Brno.
- Klement, A. (2014). Možnosti využití infračervené spektrometrie pro predikci půdních vlastností. *Disertační práce*. Česká zemědělská univerzita v Praze.
- Koppe, W., Gnyp, M., Hutt, C., Yao, Y., Miao, Y., Chen, X., & Bareth, G. (2013). Rice monitoring with multitemporal and dual-polarimetric TerraSAR-X data. *International Journal of Applied Earth Observation and Geoinformation*, 21, 568–576.
- Kravchenko, A. N., & Bullock, D. G. (2000). Correlation of Corn and Soybean Grain Yield with Topography and Soil Properties. *Agronomy Journal*, 92, 75–83.
- Kumhála, F. (2004). Laboratorní měření průchodnosti materiálu rotačním žací strojem. *Habilitační práce*, ČZU v Praze, 179 s.
- Kumhálová, J., Chyba, J., and Krofta, K. (2020). Sledování chmelových odrůd pomocí bezpilotního prostředku a družic Sentinel 2. *Seminář k agrotechnice chmele*. <http://www.chizatec.cz/seminar=-k-agrotechnice-chmele/?arc=1272&back=1>
- Kumhálová, J., Chyba, J., Krofta, K., Starý, K., and Brant, V. (2021). Evaluation of UAV and Sentinel 2 images to estimate condition of hop (*Humulus lupulus* L.) plants. 5th International Humulus Symposium 8–11 March 2021, Stuttgart, Germany.
- Kumhálová, J., Kumhála, F., Kroulík, M., and Matějková, Š. (2011). The impact of topography on soil properties and yield and the effects of weather conditions. *Precision Agric.*, 12, 813–830. doi: 10.1007/s11119-011-9221-x
- Kumhálová, J. and Matějková, Š. (2017). Yield variability prediction by the remote sensing sensors with different spatial resolution. *Int. Agrophys.*, 31, 195–202. doi: 10.1515/intag-2016-0046
- Kumhálová, J. and Moudrý, V. (2014). Topographical characteristics for precision agriculture in conditions of the Czech Republic. *Appl. Geography*, 50, 90–98. doi: 10.1016/j.apgeog.2014.02.012
- Lamb, D.W., & Brown, R.B. (2001). PA—Precision agriculture. *J. Agric. Eng. Res.* 78, 117–125.
- Lamb, J. A., Dowdy, R. H., Anderson, J. L., & Rehm, G. W. (1997). Spatial and temporal stability of corn grain yields. *Journal of Production Agriculture*, 10(3), 410–414.
- Lawes, R.A., Robertson, M.J. (2011) Whole farm implications on the application of variable rate technology to every cropped field. *Field Crops Research* 124(2), 142–148.
- Li, P., Jiang, L. & Feng, Z. (2014). Cross-Comparison of Vegetation Indices Derived from Landsat-7 Enhanced Thematic Mapper Plus (ETM+) and Landsat-8 Operational Land Imager (OLI) Sensors. *Remote Sensing*, 6, 310–329.

- Li, X. M., He, Z. H., Xiao, Y. G., Xia, X. C., Trethowan, R., Wang, H. J., & Chen, X. M. (2015). QTL mapping for leaf senescence-related traits in common wheat under limited and full irrigation. *Euphytica*, 203, 569–582.
- Li, F., Mistele, B., Hu, Y., Chen, X. and Schmidhalter, U. (2014) Reflectance estimation of canopy nitrogen content in winter wheat using optimised hyperspectral spectral indices and partial least squares regression. *European Journal of Agronomy* 52, 198-209.
- Lilienthal, H. (2003) Entwicklung eines bodengestützten Fernerkundungssystems für die Landwirtschaft, Bundesforschungsanst. für Landwirtschaft (FAL), Braunschweig.
- Liou, Y. A., & Kar, S. K. (2014). Evapotranspiration estimation with remote sensing and various surface energy balance algorithms-a review. *Energies*, 7(5), 2821–2849.
- Lipavský, J. (2000). Precizní zemědělství ve světě a v České republice. In: Uplatňování precizního zemědělství v České republice. MJM Group a.s., Olomouc, 8-14.
- Liu, C., Chen, Z., Shao, Y., Chen, J., Hasi, T., & Pan, H. (2019). Research advances of SAR remote sensing for agriculture applications: A review. *Journal of Integrative Agriculture*, 18(3), 506–525.
- Lowenberg-DeBoer, J., Erickson, B. (2019) Setting the Record Straight on Precision Agriculture Adoption. *Agronomy Journal* 111(4), 1552-1569.
- Lukas, V., Neudert, L., Novák, J. (2017) Variabilní aplikace hnojiv v precizním zemědělství. *Agromanuál* 12(8), 64-67.
- Lukas, V., Neudert, L., Duffková, R., Fučík, P., Mezera, J. (2018) Mapa výnosového potenciálu pro Zemědělské družstvo Kojčice p. 40, Mendelova univerzita v Brně, Brno.
- Lukas, V., Elbl, J., Širůček, P., Neudert, L., Mezera, J., Duffková, R. (2020a) Význam zpracování aplikačních map pro lokálně cílenou agrotechniku zemědělských plodin. *Agromanuál* 15(9-10), 78-81.
- Lukas, V., Neudert, L., Duffková, R., Haberle, J., Brom, J., Horniaček, I., Vaněček, M. (2020b) Variabilní přihnojení dusíkem pomocí nástrojů GIS a vyhodnocení efektivity využití živin v rozdílných vláhových podmínkách. *Ověřená technologie*. Mendelova univerzita v Brně, Brno.
- Lukas, V., Charvát, K. jr. (2021) Tvorba mapových podkladů pro variabilní aplikace v precizním zemědělství pomocí webového nástroje. Prezentace na webináři Otevřené jaro, Plan4All, 12.1.2021. <https://www.otevrenejaro.cz/2021/01/13/tvorba-mapovych-podkladu-pro-variabilni-aplikace-v-preciznim-zemedelstvi-pomoci-weboveho-nastroje/>
- Machado, S., Bynum, E. D., Archer, T. L., Lascano, R. J., Wilson, L. T., Bordovsky, J., Segarra, E., Bronson, K., Nesmith, D. M., & Xu, W. (2002). Spatial and temporal variability of corn growth and grain yield: Implications for site-specific farming. *Crop Sciences*, 42, 1564–1576.
- Maes, W.H., & Steppe, K. (2012). Estimating evapotranspiration and drought stress with ground-based thermal remote sensing in agriculture: a review. *J. Exp. Bot.* 63, 4671–4712.
- Maphanyane J.G., Mapeo R.B.M., and Akinola M.O., 2018. Handbook of research on geospatial science and technologies. IGI Global, Hershey, PA, USA: 457.
- Marques da Silva, J. R., & Silva, L. L. (2006). Relationship between distance to flow accumulation lines and spatial variability of irrigated maize grain yield and moisture at harvest. *Biosystems Engineering*, 94 (4), 525–533.
- Marshall, M., Thenkabail, P., Biggs, T., & Post, K. (2016). Hyperspectral narrowband and multispectral broadband indices for remote sensing of crop evapotranspiration and its components (transpiration and soil evaporation). *Agricultural and Forest Meteorology*, 218–219, 122–134.
- Merzlyak, J., et al. (1999). Non-destructive Optical Detection of Pigment Changes During Leaf Senescence and Fruit Ripening. *Physiologia Plantarum*, 106, 135-141.
- Mezera, J., Lukas, V., Elbl, J., Neudert, L., Smutný, V. (2020) Assessment of spatial heterogeneity of winter wheat canopy stand by Sentinel-2 satellite imagery, pp. 44-49, Mendelova univerzita v Brně, Brno.
- Minařík, R., Žižala, D., Lukas, V., & Kraus, M. (2018). Optimalizace vzorkování půd s využitím spektrálních dat pro účely lokálně cílené agrotechniky. *Výzkumný ústav meliorací a ochrany půdy, v.v.i.*
- Monteith, J. L. (1973). *Principles of Environmental Physics*. London: Edward Arnold Limited.
- Mutanga, O., Skidmore, A.K. (2007) Red edge shift and biochemical content in grass canopies. *ISPRS Journal of Photogrammetry and Remote Sensing* 62(1), 34-42.
- Neudert, L., Lukas, V. (2017) Variabilní dávkování hnojiv na základě senzoro- vého monitoringu porostních podmínek (Ověřená technologie Ztech). Brně, Mendelova univerzita v Brně, Brno.
- Neudert, L., Širůček, P., Lukas, V. (2018) Optimalizace intenzity hnojení ječmene jarního ve vztahu ke zjištěné úrovni heterogenity pozemků (Ověřená technologie Ztech).
- Pan Z., Huang J., & Wang F. (2013). Multi range spectral feature fitting for hyperspectral imagery in extracting oilseed rape planting area. *International Journal of Applied Earth Observation and Geoinformation*, 25, 21–29.
- Panda, S.S., Ames, D.P., & Panigrahi, S. (2010). Application of vegetation indices for agricultural crop yield prediction using neural network techniques. *Remote Sens.* 2, 673–696.
- Penuelas, J., Baret, F. and Filella, I. (1995). Semi-Empirical Indices to Assess Carotenoids/Chlorophyll-a Ratio from Leaf Spectral Reflectance. *Photosynthetica*, 31, 221-230.
- Piekarczyk, J. (2001). Temporal variation of the winter rape crop spectral characteristics. *Int. Agrophysics*, 15, 101-107.
- Piekarczyk, J., Sulewska, H., & Szymańska, G. (2011). Winter oilseed-rape yield estimates from hyperspectral radiometer measurements. *Quaestiones Geographicae*, 30(1), 77- 84.
- Piekarczyk, J., Wójtowicz, M., & Wójtowicz, A. (2006). Estimation of agronomic parameters of winter oilseed rape from field reflectance data. *Acta Agrophysica* 8(1), 205-218.
- Pinter, P. J., Hatfield, J. L., Schepers, J. S., Barnes, E. M., Moran, M. S., Daghtry, C. S. T., & Upchurch, D. R. (2003). Remote sensing for crop management. *Photogrammetric Engineering & Remote Sensing*, 69(6), 647–664.

- Pôças, I., Paço, T. A., Paredes, P., Cunha, M., & Pereira, L. S. (2015). Estimation of actual crop coefficients using remotely sensed vegetation indices and soil water balance modelled data. *Remote Sensing*, 7(3), 2373–2400.
- Qi, J., Chehbouni, A., Huete, A.R., Kerr, Y.H., & Sorooshian, S. (1994). A modified soil adjusted vegetation index. *Remote Sens. Environ.* 48, 119–126.
- Qian, S.-E. (2021). Hyperspectral Satellites, Evolution, and Development History. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 7032–7056. <https://doi.org/10.1109/JSTARS.2021.3090256>
- Qin, Ch.-Z., Zhu, A-X., Pei, T., Li, B.-L., Scholten, T., Behrens, T., & Zhou, Ch.-H. (2011). An approach to computing topographic wetness index based on maximum downslope gradient. *Precision Agriculture*, 12, 32–43.
- Quinn, P. F., Beven, K., Chevallier, P., & Planchon, O. (1991). The prediction of hillslope flow paths for distributed hydrological modeling using digital terrain models. *Hydrological Processes*, 5, 59–79.
- Quinn, P. F., Beven, K. J., & Lamb, R. (1995). The $\ln(a/\tan\beta)$ index: how to calculate and how to use it within the TOPMODEL framework. In: Beven, K. J. (ed.) *Distributed hydrological modelling – applications of the TOPMODEL concept*. Wiley, New York.
- Richardson, A. D., Jenkins, J. P., Braswell, B. H., Hollinger, D. Y., Ollinger, S. V. & Smith, M.-L. (2007). Use of Digital Webcam Images to Track Spring Green-Up in a Deciduous Broadleaf Forest. *Oecologia*, 152(2), 323–334.
- Roberts, D., Wilford, J., & Ghattas, O. (2019). Exposed soil and mineral map of the Australian continent revealing the land at its barest. *Nature Communications*, 10(1).
- Robertson, M.J., Lyle, G., Bowden, J.W. (2008) Within-field variability of wheat yield and economic implications for spatially variable nutrient management. *Field Crops Research* 105(3), 211–220.
- Rogge, D., Bauer, A., Zeidler, J., Mueller, A., Esch, T., & Heiden, U. (2018). Building an exposed soil composite processor (SCMaP) for mapping spatial and temporal characteristics of soils with Landsat imagery (1984–2014). *Remote Sensing of Environment*, 205, 1–17.
- Rondeaux, G., Steven, M. and Baret, F. (1996). Optimization of Soil-Adjusted Vegetation Indices. *Remote Sensing of Environment*, 55, 95–107.
- Rouse, J. W., Haas, R. H., Schell, J. A. & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. In: Freden, S. C., Mercanti, E. P., Becker, M. (Eds.), *Third Earth Resources Technology Satellite-1 Symposium, Vol. 1: Technical Presentations*, NASA SP-351. National Aeronautics and Space Administration, Washington, DC, pp. 309–317.
- Sadras, V., Cassman, K., Grassini, P., Hall, A., Bastiaanssen, W., Laborde, A., et al. (2015). Yield gap analysis of rainfed and irrigated crops: Methods and case studies. *FAO water reports* 41. Rome, Italy: Food and Agriculture Organization.
- Safanelli, J. L., Chabrilat, S., Ben-Dor, E., & Demattê, J. A. M. (2020). Multispectral Models from Bare Soil Composites for Mapping Topsoil Properties over Europe. *Remote Sensing*, 12(9), 1369.
- Sánchez, N., Lopez-Sanchez, J. M., Arias-Pérez, B., Valcarce-Diñeiro, R., Martínez-Fernández, J., Calvo-Heras, M., Camps, A., González-Zamora, A., & Vicente-Guijalba, A. F. (2016). New microwave-based missions applications for rainfed crops characterization. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XLI-B8, *Proceedings of XXIII ISPRS Congress, Prague, Czech Republic, 12–19 July 2016*; pp. 101–107.
- Schepers, A. R., Shanahan, J. F., Liebig, M. A., Schepers, J. S., Johnson, S. H., & Luchiari, A. (2004). Appropriateness of management zones for characterizing spatial variability of soil properties and irrigated corn yields across years. *Agronomy Journal*, 96, 195–203.
- Schmidt, F., & Persson, A. (2003). Comparison of DEM data capture and topographic wetness indices. *Precision Agriculture*, 4, 179–192.
- Scudiero, E., Corwin, D. L., Wienhold, B. J., Bosley, B., Shanahan, J. F., & Johnson, C. K. (2016). Downscaling Landsat 7 canopy reflectance employing a multi-soil sensor platform. *Precision agriculture*, 17, 53–73.
- Serrano, L., Penuelas, J. and Ustin, S. (2002). Remote Sensing of Nitrogen and Lignin in Mediterranean Vegetation from AVIRIS Data: Decomposing Biochemical from Structural Signals. *Remote Sensing of Environment*, 81, 355–364.
- Schnug, E., Panten, K., Haneklaus, S. (1998) Sampling and nutrient recommendations - The future. *Communications in Soil Science and Plant Analysis* 29(11-14), 1455-1462.
- Silvero, N. E. Q., Demattê, J. A. M., Vieira, J. de S., Mello, F. A. de O., Amorim, M. T. A., Poppiel, R. R., ... Bonfatti, B. R. (2021). Soil property maps with satellite images at multiple scales and its impact on management and classification. *Geoderma*, 397, 115089.
- Sims, D. and Gamon, J. (2002). Relationships Between Leaf Pigment Content and Spectral Reflectance Across a Wide Range of Species, Leaf Structures and Developmental Stages. *Remote Sensing of Environment*, 81, 337–354.
- Sinclair, T. R., Hoffer, R. M., & Schreiber, M. M. (1971). Reflectance and internal structure of leaves from several crops during a growing season. *Agronomy Journal*, 63, 864– 868.
- Sorenson, P. T., Shirliffe, S. J., & Bedard-Haughn, A. K. (2021). Predictive soil mapping using historic bare soil composite imagery and legacy soil survey data. *Geoderma*, 401, 115316.
- Sörensen, R., Zinko, U., & Seibert, J. (2006). On the calculation of the topographic wetness index: Evaluation of different methods based on field observations. *Hydrology and Earth System Sciences*, 10, 101–112.
- Sripada, R., et al. (2006). Aerial Color Infrared Photography for Determining Early In-season Nitrogen Requirements in Corn. *Agronomy Journal*, 98, 968–977.
- Stafford, J.V. (2006) *Handbook of Precision Agriculture*. Srinivasan, A. (ed), pp. 19 - 56, Food Products Press, Bringhamton, NY.
- Stenberg, B., Viscarra Rossel, R. A., Mouazen, A. M., & Wetterlind, J. (2010). Visible and Near Infrared Spectroscopy in Soil Science. In P. M. Bertsch, R. L. Phillips, K. M. Scow, & L. P. Wilding (Eds.), *Advances in Agronomy* (Vol. 107, Issue 10, pp. 163–215). Elsevier.

- Stevens, A., Miralles, I., & van Wesemael, B. (2012). Soil Organic Carbon Predictions by Airborne Imaging Spectroscopy: Comparing Cross-Validation and Validation. *Soil Science Society of America Journal*, 76(6), 2174.
- Stoner, E. R., & Baumgardner, M. F. (1981). Characteristic Variations in Reflectance of Surface Soils. In *Soil Science Society of America Journal* (Vol. 45, Issue 6, p. 1161).
- Sui, R., Thomasson, J.A., Hanks, J., & Wooten, J. (2008). Ground-based sensing system for weed mapping in cotton. *Comput. Electr. Agric.* 60, 31–38.
- Summers, D., Lewis, M., Ostendorf, B., & Chittleborough, D. (2011). Visible near-infrared reflectance spectroscopy as a predictive indicator of soil properties. *Ecological Indicators*, 11(1), 123–131.
- Taghvaeian, S., Chávez, J., & Hansen, N. (2012). Infrared thermometry to estimate crop water stress index and water use of irrigated maize in Northeastern Colorado. *Remote Sens.* 4, 3619.
- Tang, J., Han, W., & Zhang, L. (2019). UAV multispectral imagery combined with the FAO-56 dual approach for maize evapotranspiration mapping in the North China Plain. *Remote Sensing*, 11(21).
- Tilling, A.K., O'Leary, G.J., Ferwerda, J.G., Jones, S.D., Fitzgerald, G.J., Rodriguez, D., & Belford, R. (2006). Remote sensing of nitrogen and water stress in wheat. *Field Crops Res.* 104, 77–85.
- Thaler, E. A., Larsen, I. J., & Yu, Q. (2019). A New Index for Remote Sensing of Soil Organic Carbon Based Solely on Visible Wavelengths. *Soil Science Society of America Journal*, 83(5), 1443–1450.
- Tucker, C. J. (1979). Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. *Remote Sensing of Environment*, 8(2), 127–150.
- Tůma, L., Kumhálová, J., Kumhála, F., & Krepl, V. (2021). The noise-reduction potential of Radar Vegetation Index for crop management in the Czech Republic. *Precision Agriculture*. Published online: 4.9.2021; <https://doi.org/10.1007/s11119-021-09844-5>
- van Ittersum, M.K., Rabbinge, R. (1997). Concepts in production ecology for analysis and quantification of agricultural input-output combinations. *Field Crops Res.* 52, 197–208.
- Van Leeuwen, W. J. D., & Huete, A. R. (1996). Effects of standing litter on the biophysical interpretation of plant canopies with spectral indices. *Remote Sensing of Environment*, 55, 123–138.
- Vaudour, E., Gomez, C., Lagacherie, P., Loiseau, T., Baghdadi, N., Urbina-Salazar, D., ... Arrouays, D. (2021). Temporal mosaicking approaches of Sentinel-2 images for extending topsoil organic carbon content mapping in croplands. *International Journal of Applied Earth Observation and Geoinformation*, 96, 102277.
- Viña, A., Gitelson, A. A., Nguy-Robertson, A. L. & Peng, Y. (2011). Comparison of different vegetation indices for the remote assessment of green leaf area index of crops. *Remote Sensing of Environment*, 115, 3468–3478.
- Viscarra Rossel, R. a., Walvoort, D. J. J., McBratney, a. B., Janik, L. J., & Skjemstad, J. O. (2006). Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma*, 131(1–2), 59–75.
- Vuolo, F., D'Urso, G., De Michele, C., Bianchi, B., & Cutting, M. (2015). Satellite-based irrigation advisory services: A common tool for different experiences from Europe to Australia. *Agricultural Water Management*, 147, 82–95.
- Vuolo, F., Essl, L., & Atzberger, C. (2015). Costs and benefits of satellite-based tools for irrigation management. *Frontiers in Environmental Science*, 3(JUL), 1–12.
- Wang, T., Tang, R., Li, Z. L., Jiang, Y., Liu, M., & Niu, L. (2019). An improved spatio-temporal adaptive Data fusion algorithm for evapotranspiration mapping. *Remote Sensing*, 11(7), 1–21.
- Wilson, J. P., & Gallant, J. C. (Eds.) (2000). *Terrain Analysis. Principles and Applications*. John Wiley & Sons, New York, USA.
- Wittry, D.J., Mallarino, A.P. (2004) Comparison of Uniform – and Variable-Rate Phosphorus Fertilization for Corn-Soybean Rotations. *Agronomy Journal* 96(1), 26–33.
- Woebbecke, D.M., Meyer, G.E., Vonbargen, K. & Mortensen, D.A. (1995). Color indexes for weed identification under various soil, residue, and lighting conditions. *Trans. ASAE*, 38, 259–269.
- Xue, J., & Su, B. (2017). Significant remote sensing vegetation indices: a review of developments and applications. *J. Sens.* 2017, 17.
- Yang, C., & Everitt, J. H. (2002). Relationships between yield monitor data and airborne multiband multispectral digital imagery for grain sorghum. *Precision Agriculture*, 3, 373–388.
- Zarco-Tejada, P.J., González-Dugo, V., & Berni, J.A.J. (2012). Fluorescence, temperature and narrow-band indices acquired from a UAV platform for water stress detection using a micro-hyperspectral imager and a thermal camera. *Remote Sens. Environ.* 117, 322–337.
- Zarco-Tejada, P. J., Ustin, S. L., & Whiting, M. L. (2005). Temporal and spatial relationships between within-field yield variability in cotton and high-spatial hyperspectral remote sensing imagery. *Agronomy Journal*, 97(3), 641–653.
- Zhang, Q., & Pierce, J. F. (2013). *Agricultural Automation: Fundamentals and Practices*. CRC Press, Boca Raton.
- Zhang, Y., Han, W., Niu, X., & Li, G. (2019). Maize Crop Coefficient Estimated from UAV-Measured Multispectral Vegetation Indices. *Sensors*, 19(23), 5250.
- Zhu, L., Xu, J. F., Huang, J. F., Wang, F. M., Liu, Z. Y., & Wang, Y. (2008). Study on hyperspectral estimation model of crop vegetation cover percentage. *Spectroscopy and Spectral Analysis*, 28, 1827–1831. (In Chinese).
- Žížala, D., Zádorová, T., & Kapička, J. (2017). Assessment of Soil Degradation by Erosion Based on Analysis of Soil Properties Using Aerial Hyperspectral Images and Ancillary Data, Czech Republic. *Remote Sensing*, 9(1), 28.
- Žížala, D., Minařík, R., & Zádorová, T. (2019). Soil Organic Carbon Mapping Using Multispectral Remote Sensing Data: Prediction Ability of Data with Different Spatial and Spectral Resolutions. *Remote Sensing*, 11(24), 2947.
- Žížala, D., Minařík, R., Vašát, R., Skála, J., Juřicová, A., Zádorová, T., ... Beitlerová, H. (2020). Tvorba půdních map pedometrickými metodami. Praha: Výzkumný ústav meliorací a ochrany půdy. v.v.i.



DÁLKOVÝ PRŮZKUM ZEMĚ A PRECIZNÍ ZEMĚDĚLSTVÍ

Autoři:

Mgr. Daniel Žížala, Ph.D.¹

doc. Ing. Vojtěch Lukas, Ph.D.²

doc. Mgr. Jitka Kumhálová, Ph.D.³

¹ Výzkumný ústav meliorací a ochrany půdy, v.v.i., laboratoř DPZ a pedometrie

² Mendelova univerzita v Brně, Agronomická fakulta, Ústav agrosystémů a bioklimatologie

³ Česká zemědělská univerzita v Praze, Technická fakulta, Katedra využití strojů

Vydavatel:

Zemědělský svaz ČR - Česká technologická platforma pro zemědělství

Grafika:

Pavla Brus Ortová

Tiskárna:

SYNERGIE: 4U s.r.o.

Vydání: první

Rok vydání: 2021

Náklad: 1000 výtisků

Za obsahovou a jazykovou správnost díla odpovídá autor.

