



**Výzkumný ústav meliorací  
a ochrany půdy, v.v.i.**

METODIKA

# **Optimalizace vzorkování půd s využitím spektrálních dat pro účely lokálně cílené agrotechniky**

**Robert Minařík, Daniel Žížala a kol.  
2018**

Výzkumný ústav meliorací a ochrany půdy, v.v.i.

# **Optimalizace vzorkování půd s využitím spektrálních dat pro účely lokálně cílené agrotechniky**

Metodika

Robert Minařík  
Daniel Žížala  
Vojtěch Lukas  
Michal Kraus

Praha

2018

## Dedikace

Metodika vznikla jako výstup projektu NAZV QJ1610289 "Optimalizace využití produkčního potenciálu půdy lokálně cílenou agrotechnikou" řešeného v letech 2016–2018.

Metodika byla certifikována Ministerstvem zemědělství České republiky odborem rostlinných komodit pod číslem 73572/2018–MZE–17225

## Oponenti

Doc. Ing. Vít Penížek, Ph.D., Česká zemědělská univerzita v Praze

Ing. Václav Kadlec, Ph.D., Ministerstvo zemědělství České republiky

## Autorský kolektiv

Mgr. Robert Minařík<sup>1</sup>

Mgr. Daniel Žížala, Ph.D.<sup>1</sup>

Ing. Vojtěch Lukas, Ph.D.<sup>2</sup>

Ing. Michal Kraus<sup>3</sup>

<sup>1</sup> Výzkumný ústav meliorací a ochrany půdy, v.v.i., Oddělení půdní služby

<sup>2</sup> Mendelova univerzita v Brně, Ústav agrosystémů a bioklimatologie

<sup>3</sup> ROSTĚNICE, a.s.

Editor Mgr. Daniel Žížala, Ph.D.

Rok vydání 2018

vydání 1. vydání

Vydal Výzkumný ústav meliorací a ochrany půdy, v.v.i.

Tisk Powerprint s.r.o., Praha 6 - Suchbátka

Náklad 50 ks

ISBN 978–80–87361–95–5

<b>ÚVOD</b>	<b>5</b>
<b>CÍLE METODIKY</b>	<b>7</b>
<b>VLASTNÍ POPIS METODIKY</b>	<b>9</b>
<b>Prostorové vzorkování půdy a jeho optimalizace</b>	<b>9</b>
Klasické přístupy vzorkování	14
<i>Jednoduché náhodné schéma vzorkování</i>	15
<i>Utříděné náhodné schéma vzorkování</i>	17
<i>Systematické schéma vzorkování</i>	19
<i>Systematické nerovnoměrné schéma</i>	21
<i>Shlukové schéma</i>	22
<i>Úsudkové vzorkování</i>	23
Nové přístupy a optimalizace vzorkování	24
<i>Využití podpůrných dat</i>	25
<i>Zónové vzorkování</i>	26
<i>Porovnání metod</i>	28
<i>Shrnutí</i>	29
<b>Optimalizace vzorkování pomocí distančních dat</b>	<b>31</b>
Použité datové sady a jejich využití pro optimalizace	
vzorkovacích sítí	31
<i>Satelitní snímky družic Sentinel 2</i>	32
<i>Digitální model reliéfu</i>	36
Příprava dat pro výpočet optimalizace	41
Návrh vzorkovacích sítí	43
<i>Shluková analýza</i>	43
<i>Výběr optimálního počtu vzorků</i>	48
<i>Rozmístění optimálního počtu vzorků</i>	50
Hodnocení výsledků návrhu vzorkování	51
Optimalizace stávající odběrné sítě	52
Aplikace metodiky na zájmovém území	53
<i>Popis území</i>	53
<i>Příprava dat</i>	54
<i>Optimalizace vzorkování</i>	55
<i>Shrnutí</i>	65
<b>SROVNÁNÍ "NOVOSTI POSTUPŮ"</b>	<b>67</b>
<b>POPIS UPLATNĚNÍ METODIKY</b>	<b>68</b>
<b>EKONOMICKÉ ASPEKTY</b>	<b>69</b>
<b>Seznam použité související literatury</b>	<b>70</b>
<b>Seznam publikací, které předcházeli metodice</b>	<b>79</b>



# 1 ÚVOD

V zemědělské praxi je téměř vždy nemožné měřit variabilitu půdních vlastností přímo v celé ploše na všech pozemcích, jak z časových, tak ekonomických důvodů. Přitom je zjištění variability půdních vlastností mající vliv na pěstované plodiny a výnos prvním krokem pro správné a cílené hospodaření na základě principů precizního zemědělství (Pierce a Nowak 1999). Jediným možným řešením mapování variability půdních parametrů je pak adekvátní vzorkování půd (Carter a Gregorich 2007). Jak ale navrhnout adekvátní vzorkovací síť, pokud nemáme informace o variabilitě půdních vlastností z předchozích vzorkování nebo dostatečnou znalost území a historii výnosů?

Prostorová variabilita půdních vlastností je výsledkem působení půdotvorných faktorů klimatu, půdních organismů, vegetace, činnosti člověka, půdotvorného substrátu a podmínek půdotvorného procesu topografie, času a geografické polohy (McBratney et al. 2003). Všechny tyto půdotvorné faktory pak způsobují heterogenitu půdních vlastností v rámci krajiny, jednotlivých polí i půdních bloků. Pokud budeme uvažovat měřítko půdních bloků, jedním z největších lokálních faktorů je geologické podloží, respektive půdotvorný substrát, a s tím spojený tvar reliéfu, který ovlivňuje půdotvorné procesy. Ovlivňuje zejména svahové procesy a proudění vody jak povrchové tak podpovrchové.

S rozvojem geoinformačních technologií, dálkového průzkumu země a sensorových měření je k dispozici velké množství podpůrných informací, jako jsou volně dostupné satelitní snímky, digitální modely reliéfu, půdní mapy a výsledky sensorových měření půdy, ze kterých lze nepřímo odvodit variabilitu půdních vlastností a optimalizovat vzorkování půd. Některé z těchto zdrojů nemusejí být vždy dostupné. Využití však lze minimálně široce dostupné zdroje, jako multispektrální satelitní snímky s vysokým rozlišením či digitální model terénu. S využitím těchto zdrojů je tedy možné navrhnout nové vzorkovací schéma na neznámém území nebo optimalizovat již existující odběrnou síť tak, aby byly sníženy náklady na pořízení a analýzu vzorků bez výrazné ztráty informace o skutečné variabilitě půdních vlastností. Toto schéma je možno doplnit při potřebě dozorkování na základě zjištěných informací, například z výnosových map.



## 2 CÍLE METODIKY

Cílem metodiky je uživatelsky přívětivě představit automatizované postupy návrhu nové odběrné sítě na libovolných pozemcích či optimalizace (redukce) stávající odběrné sítě bez ztráty důležité informace za využití zdarma dostupných satelitních snímků a běžně dostupného státního Digitálního modelu reliéfu 4G (DMR 4G®) bez další znalosti o území.

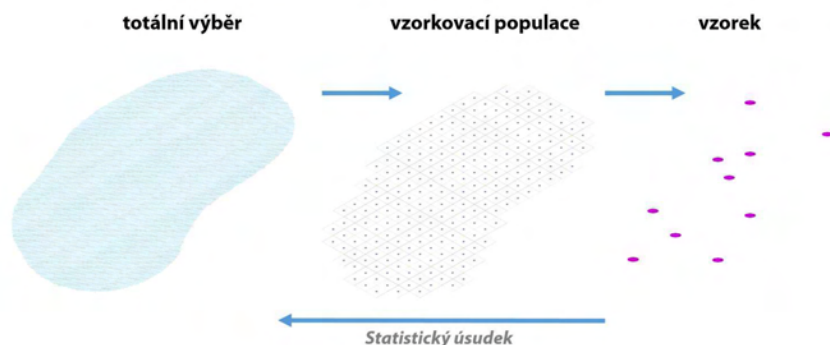
Navržený postup je založen na nejnovějších vědeckých metodách v oboru pedometriky, tedy aplikace statistických metod na data o půdě. Tato metodika využívá běžně dostupné datové zdroje a je možno jí jednoduše automatizovat, např. v open source prostředí R, což umožňuje její širokou aplikovatelnost. Součástí metodiky je i obsáhlý přehled klasických i moderních vzorkovacích schémat se zaměřením na praktická doporučení pro zemědělce převzatá z nejrespektovanějších vědeckých studií.



# 3 VLASTNÍ POPIS METODIKY

## PROSTOROVÉ VZORKOVÁNÍ PŮDY A JEHO OPTIMALIZACE

Prostorové vzorkování půdy a následné statistické usuzování je proces, kdy se na základě výběru podmnožiny jedinců populace odhadují parametry populace (např. odhad prostorové variability organického uhlíku v poli na základě bodových odběrů). Ve srovnání s totálním výběrem – cenzem, kdy do šetření vstupují všichni jedinci, má vzorkovací proces velké výhody. Výsledkem je snížení nákladů, menší časová náročnost a větší pokrytí. Ztráta přesnosti je zanedbatelná ve srovnání s úplným výčtem (Cochran 1977). Navíc statistický vzorek vede k návrhům, které lze opakovaně použít, což vede k malým změnám v odhadech, které naopak poskytují míru nejistoty.



Obrázek 1: Vzorek vs. populace

Celý proces je možné rozdělit do šesti fází (Wang et al. 2012).

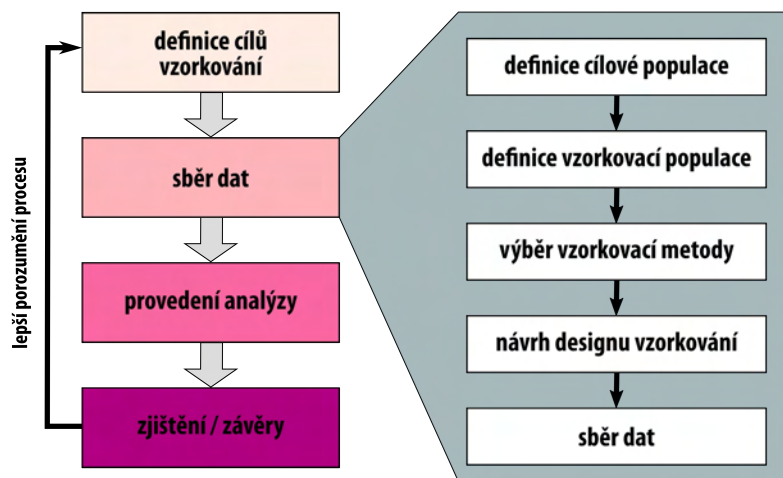
- a) **Definice cílů vzorkování:** Typicky se jedná o zjištění průměru nebo celkové hodnoty parametru na zvolené ploše nebo predikce hodnot na nevzorkovaném území. Je potřeba také ujasnit, zda je cílem usuzování populace „tady a teď“ (mapování v jednom okamžiku) nebo superpopulace (dlouhodobé mapování, časové série, např. zaplevelení v jednotlivých letech). Definice je obvykle zavedena na konceptuální úrovni.
- b) **Definice vzorkované populace a jednotek vzorkování:** Populace tvoří soubor, z něhož jsou vybírány vzorky. Populace je pak rozdělena na nepřekrývající se části, tzv. vzorkovací jednotky (*sampling units*) nebo elementy. V prostorovém kontextu může být populace, ze které jsou vybírány vzorky, a odhadovaná populace prostorově nerovná. Proto je první z nich nazývána vzorkovací populace a druhá odhadovaná populace.

*Příklad: Cílová populace může být každý bod území. Vzorkovací populace je ale „jen“ každý pixel z obrazových dat území o velikosti 5×5 m.*

- c) **Výběr vzorkovací metody a odvození počtu vzorků:** Výběr vzorkovací metody a odvození počtu vzorků podléhá dvěma běžně uplatňovaným omezením. Prvním je rozpočet a druhým kvalita odhadu, která by měla splňovat stanovené požadavky. Celková nejistota odhadu sledovaného parametru je dána třemi aspekty. Prvním aspektem je variabilita sledovaného náhodného jevu (zde pole), druhým aspektem je samotný výběr vzorkovací metody a z ní plynoucí rozmístění a hustota vzorků, třetím aspektem je pak procedura (výběrová statistika) použitá pro odhad parametru.
- d) **Design vzorkování:** Design vzorkování zahrnuje plán kde, kdy a jak budou vzorky odebírány.
- e) **Samotné vzorkování a odběr v terénu**
- f) **Analýza vzorků**



## Fáze v procesu vzorkování



Obrázek 2: Fáze procesu vzorkování (upraveno dle Wang et al. 2012)

Běžně jsou rozlišovány dva základní přístupy vzorkování a následného statistického usuzování: design-based (konstrukčně založené) a model-based (modelově založené) vzorkování (Särndal et al. 1978; de Gruijter a ter Braak 1990). U design-based přístupu jsou vzorkovací body vybírány na základně pravděpodobnostního výběru, kdy každý bod má stejnou pravděpodobnost, že bude vybrán. Nejjednodušším příkladem je prostý náhodný výběr. Náhodnost (stochastika) a níž plynoucí statistický úsudek (např. odhad prostorového průměru) je zanesena v návrhu vzorkování. V modelovém přístupu vzorkování neexistují žádné požadavky na způsob výběru místa odběru vzorků, a obvykle jsou vybírány záměrným (cíleným) vzorkováním, například na základě gridu (mřížky). V rámci statistického úsudku se zavádí model prostorové variability, např. ordinary kriging, za předpokladu konstantního (neznámého) průměru nebo univerzální kriging, ve kterém je modelován průměr jako lineární funkce jednoho nebo více prediktorů. Kromě deterministické části průměru, model obsahuje náhodnou (stochastickou) část popisující rozptyl a kovarianci z reziduí průměru. To má významné důsledky

pro interpretaci míry nejistoty odhadů, např. rozptyl chyby odhadu (predikce).

Pro kvantifikaci nejistoty odhadů sledovaných parametrů se v obou přístupech náhodný experiment opakuje mnohokrát (ne reálně, ale teoreticky). Nicméně, jak se zdroj náhodnosti liší mezi těmito dvěma přístupy, liší se také tento teoretický náhodný experiment (Brus 2010). Design-based přístup si můžeme představit jako opakovaný náhodný výběr vzorkovacích míst s odběrem, ze kterých je odhadován parametr a střední chyba odhadu pro celé konkrétní vzorkované pole, zatímco u model-based přístupu jsou generovány vždy hodnoty pro každý bod v rámci jednoho pole (jedné realizace modelu), přičemž je simulována celá série těchto „polí“.

Výběr mezi těmito dvěma přístupy je jedním z nejdůležitějších rozhodnutí při navrhování vzorkovacích schémat (de Gruijter et al. 2006). Design-based vzorkování je více vhodné pro kvantitativní odhady parametrů populace, typicky se jedná o zjištění průměru nebo celkové hodnoty parametru na zvolené ploše. Efektivnost prostorového vzorkování může být zvýšena dodáním apriorní informace o náhodném poli např. topografie pole, snímky DPZ nebo výnosové mapy (Minasny a McBratney 2006). Z tohoto úhlu pohledu se teorie prostorového vzorkování vyvíjela následovně: vzorkování populace s předpokladem nezávislosti a identické distribuce (Cochran 1977), prostorově autokorelované populace (Haining 2003) a prostorově heterogenní a autokorelované populace s využitím zónování (Wang et al. 2010). Ačkoli má dělení design-based a model-based přístupu smysl, je těžké některé nové metody zařadit do jedné nebo druhé kategorie (Wang et al. 2012). Ve skutečnosti je jednodušší určit, zda se výzkumná otázka týká populace nebo superpopulace a podle toho vybrat vhodnou metodu vzorkování a statistického usuzování s přihlédnutím ke všem příslušným předpokladům a omezením.

Model-based přístup je v jádru kombinací účelového vzorkování s ná-


slednou interpolací a je vhodný zejména pro digitální mapování půd (angl. *Digital Soil Mapping*, DSM), tzn. predikci sledované půdní vlastnosti v celém území na základě malého množství odebraných vzorků. Predikce půdních vlastností je založena na formování vztahů mezi měřenými půdními vlastnostmi vzorkováním (např. obsah organického uhlíku) a pomocných proměnných půdy a okolního prostředí. Výhodou pomocných dat je, že mohou být získána relativně levně nebo zdarma i pro rozsáhlá území (např. digitální modely terénu nebo multispektrální satelitní snímky z družice Sentinel-2). Podmínkou je předpoklad, že tato podpůrná data mají vztah ke sledovaným proměnným (Minasny a McBratney 2006). Odebrané vzorky jsou použity pro sestavení modelů predikující půdní vlastnost v celém území i tam, kde neproběhlo žádné vzorkování. Obecně se používají regresní modely (Lesch 2005) nebo různé varianty krigingu (Webster a Oliver 2007). Pro podrobný přehled geostatistických metod a principů digitálního mapování půd lze odkázat na (Wackernagel 2003; Malone et al. 2017).

## Klasické přístupy vzorkování

Klasická teorie vzorkování je založena na design-based (pravděpodobnostním) vzorkování. Zahrnuje jak samotná vzorkovací schémata, tak i statistické metody odhadu sledovaného parametru. Obecně se dá říci, že čím větší počet vzorků, tím větší je výsledná přesnost odvozených map půdních vlastností. Z hlediska časové i finanční efektivity je však nutné hledat způsoby jak množství vzorků omezit při zachování dostatečné přesnosti podle výzkumného záměru, čehož lze prakticky docílit zejména výběrem vhodného vzorkovacího schématu (Cochran 1977; Van Groenigen et al. 1999). Vhodné schéma vzorkování zahrnují cí optimální počet a rozmístění vzorků je vybíráno na základě analýzy cíle vyhodnocení včetně způsobu vyhodnocení dat, variability sledovaných půdních vlastností na pozemku či v celé studované oblasti a v neposlední řadě i časových i finančních možnostech samotného od-

běru a analytických rozborů. Vzorky jsou vybírány náhodně se stejnou nebo různou pravděpodobností v závislosti na použitém schématu. Mezi klasická schémata vzorkování patří: jednoduché náhodné schéma vzorkování (*Simple random sampling*), utříděné náhodné schéma vzorkování (*Stratified random sampling*), systematické vzorkování (*Systematic sampling*), systematické nerovnoměrné schéma (*Systematic unaligned pattern*), shlukové vzorkování (*Clustered sampling*), vyhledávací vzorkování (*Search sampling*), úsudkové nebo účelové vzorkování (*Purposive or Judgmental sampling*) (Wollenhaupt et al. 1997; McCoy 2005).

### Jednoduché náhodné schéma vzorkování (*Simple random sampling* – RS)



Obrázek 3: Jednoduché náhodné schéma vzorkování

Ačkoli je tato metoda v praxi řídce používána pro svou nízkou efektivnost, je základem pro všechny design-based metody (Wang et al. 2012). V této metodě mají všechny body nebo části vzorkované plochy stejnou šanci, že budou vybrány bez ovlivnění operátora. Tato podmínka je velmi důležitá pro navazující statistické usuzování, aby byl získán skutečný odhad parametru populace. Klasicky jsou body vybrány náhodnými souřadnicemi z mapy celého vzorkovaného území. Každý

náhodný bod může reprezentovat pouze místo odběru nebo může být středem vzorkovací plochy.

### Kdy použít:

- Může být použito u homogenních pozemků pro zjištění průměrné hodnoty na pozemku.

### Výhody:


- + Minimální ovlivnění operátora, tzn. absolutní náhodnost a nejvyšší platnost statistické inference.

### Nevýhody:

- Nerovnoměrná distribuce bodů na studované ploše vedoucí k vynechání některých částí pozemku může vést u heterogenních lokalit k redukci přirozené variability půdních podmínek plynoucí např. z reliéfu území a zkrácenému odhadu parametru. Reliéf výrazně ovlivňuje vlastnosti půdy, protože kontroluje pohyb vody a půdního materiálu – procesy eroze a akumulace (Florinsky 2012).
- Neumožňuje vůbec žádnou optimalizaci (redukci) vzorkovací sítě pomocí podpůrných dat a znalostí o území (Biswas a Zhang 2018).

Vzhledem k výše uvedeným nevýhodám, existuje pouze málo studií používající v praxi náhodný výběr. Například Evans a Hartemink (2014) a Adhikari a Hartemink (2015) používají prosté náhodné schéma pro mapování jílů a obsahu organického uhlíku v půdě.

## Utříděné náhodné schéma vzorkování (*Stratified random sampling – SRS*)



Obrázek 4: Utříděné náhodné schéma vzorkování

Prakticky bývá celé heterogenní sledované území rozděleno na zóny – kategorie, které jsou více homogenní, což redukuje celkovou varianci (Rodeghiero a Cescatti 2008). Rozdělení může být provedeno na základě předchozí znalosti, předběžného vzorkování nebo podpůrných dat, např. analýzy reliéfu, leteckých či satelitních snímků. Tento přístup přiřazuje konkrétní počet vzorkovacích bodů ke každé kategorii v poměru k velikosti nebo významu kategorie s ohledem na cíle projektu. Pokud jsou všechny kategorie stejného významu pro projekt, pak velikost kategorie sama určí počet vzorků, tzn., větší kategorie jsou zastoupeny více vzorky. Novější studie (Wang et al. 2010) uvádí, že zónování pozemků s následným náhodným výběrem je efektivnější než ostatní metody stratifikace.

### Kdy použít:

- Je k dispozici dlouhá historie výnosových map ukazující variabilitu (Mallarino et al. 2006). Provádí se expertní odhad založený na znalosti území (Ferguson a Hergert 2009).


- Je k dispozici historie vysoké vnitřní variability pole, dvojnásobné až trojnásobné rozdíly ve sledovaném parametru (Dinkins a Jones 2008).
- Dostupná podpůrná data např. výnosové mapy, data dálkového průzkumu země (DPZ) umožňující stanovení zón (Ferguson a Hergert 2009).

### Výhody:

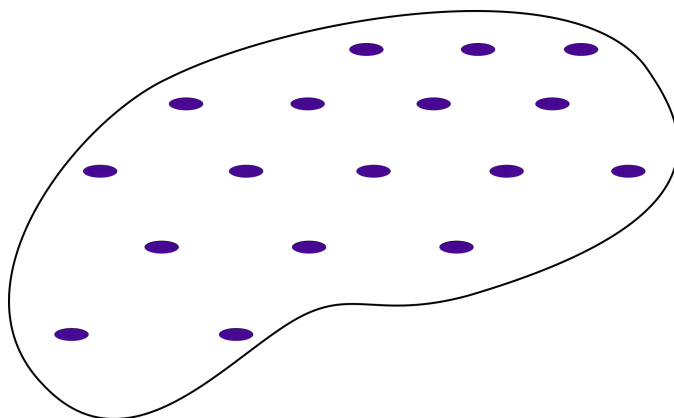
- + Vhodné pro proměnlivé živiny, zvláště dusík (Franzen et al. 1998).
- + Vhodné pro organickou složku půdy ( $C_{ox}$ ) a pH (Mallarino a Wittry 2004).

### Nevýhody:

- Nemá. Utříděné náhodné schéma zachovává potřebnou náhodnost výběru a přitom překonává problém nerovné distribuce vzorku v území.



## Systematické schéma vzorkování (*systematic sampling* – SS)



Obrázek 5: Systematické schéma vzorkování

Při systematickém vzorkování jsou odebírány vzorky v pravidelné síti, která je nejčastěji čtvercová. I přes své nevýhody, je toto schéma široce používáno pro svou jednoduchost (Dinkins a Jones 2008; Ferguson a Hergert 2009). Odebírá se buď v průsečících sítě, nebo ve středu buňky. V druhém případě je možné odebrat jeden vzorek na buňku (střed) nebo tzv. kompozitní či smíšený vzorek (více vpichů náhodně rozmístěných v buňce) a počítá se průměr charakterizující buňku.

### Kdy použít:

- Nikdy nebylo provedeno vzorkování území. V tomto případě se doporučují velmi krátké vzdálenosti (Brus a Heuvelink 2007).
- Předchozí způsob obdělávání výrazně změnil obsah živin v půdě:
  - hnojí se ve vysokých dávkách (Franzen et al. 1998),

- je známa historie hnojení (Franzen et al. 1998),
- silné zavlažování.
- Malé pozemky byly sloučeny do velkých (Franzen et al. 1998).
- Chceme podrobně mapovat variabilitu živin v půdě (Ferguson a Hergert 2009).

### Výhody:


- + Vhodné pro neproměnlivé živiny jako je fosfor, draslík, zinek, zvláště pokud byly předtím aplikovány ve vysokém množství (Franzen et al. 1998).

### Nevýhody:

- Chybí náhodnost pro statistickou inferenci.
- Ve srovnání se zónovým schématem vyžaduje více odběrných bodů k popsání celé variability, zvyšují se náklady na vzorkování, protože se nevyužívá proměnlivé prostorové variability a autokorelace. Navrhuje zbytečně husté odběrné sítě i oblastech, kde není variabilita sledovaného parametru vysoká.

Systematické vzorkování je i přes své nevýhody jedno z nejpoužívanějších (např. Chaplot et al. 2010; Jonard et al. 2013; Poggio et al. 2013).

## Systematické nerovnoměrné schéma (*systematic unaligned pattern* – SUP)



Obrázek 6: Systematické nerovnoměrné schéma vzorkování

Systematické nerovnoměrné schéma také používá grid, ale pozice odběru v rámci buňky je náhodná. Opět může být odebírán jednoduchý nebo složený vzorek.


### Výhody:

- + Zachovaný náhodný výběr a přitom grid zajišťuje, aby bylo pokryto celé území. Nejsou porušeny předpoklady pro statistickou inferenci.
- + Použitelný kompromis odstraňující nevýhody jak prostého náhodného výběru, tak systematického výběru.

### Nevýhody:

- Je potřeba zvolit vhodnou velikost buňky vzhledem k reliéfu. Pokud jsou zvoleny malé buňky, může dojít náhodně k výběru, který se blíží pravidelné síti a náhodnost se vytrácí.

## Shlukové schéma (*cluster sampling pattern – CSP*)



Obrázek 7: Shlukové schéma vzorkování v management zónách

Ve shlukovém schématu jsou náhodně rozmístěny tzv. uzlové body, které jsou požitky jako centroidy pro odběr náhodných vzorků v jejich okolí. Uzlové body mohou být rozmístěny prostým náhodným nebo utříděným náhodným schématem např. v centru management zóny.

### Kdy použít:

- Metoda je vhodná pro jevy, které se přirozeně shlukují, např. ohniska plevelu (Lukas 2009).

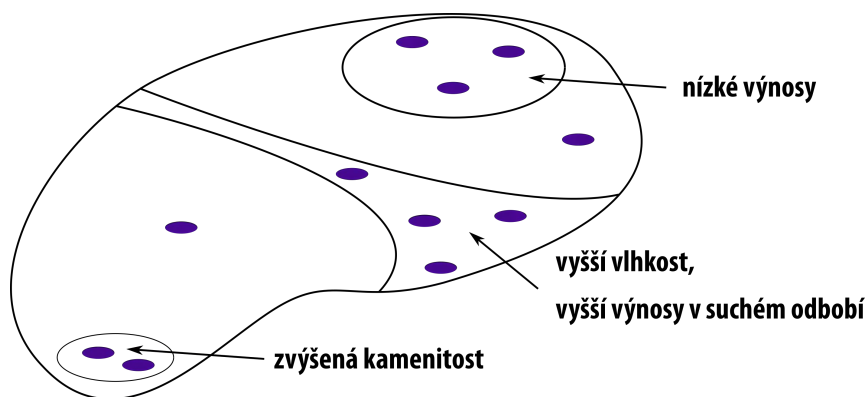
### Výhody:

- + V těžko prostupném terénu je možné vybrat nejdostupnější místa jako uzlové body (Cambule et al. 2013).
- + Náhodný výběr pro statistické usuzování je zachován.

**Nevýhody:**

- Klastrování často vede k nechtěné autokorelaci mezi odebranými vzorky, pokud nejsou odebrány v dostatečné vzdálenosti mezi sebou, proto (McCoy 2005) doporučuje aplikovat jiné schéma výběru, pokud je to možné.

### Úsudkové vzorkování (*Judgemental sampling – JS*)



Obrázek 8: Úsudkové schéma vzorkování

Klasicky je chápáno jako vzorkování dle úsudku experta na daný jev, který je zároveň obeznámen s přírodními podmínkami v území. Nemůže být považováno za náhodný výběr, tudíž je aplikace statistiky problematická a veškeré odhady parametrů a středních chyb odhadu jsou metodicky špatně. Výsledná přesnost závisí na expertním odhadu. Tato metoda však může být použita jako doplněk jiného schématu při potřebě aplikace doplňkového vzorkování.

## Nové přístupy a optimalizace vzorkování

S rozvojem technologie precizního zemědělství, sensorových měření a počítačového zpracování, kdy je k dispozici velké množství pomocných dat, jako jsou analýzy reliéfu, půdní a výnosové mapy, mapy vegetačního pokryvu a sensorová měření, je možné výběrem vhodných statistických metod předem optimalizovat klasická schémata vzorkovacích sítí. Optimalizace je možná jak z hlediska rozmístění, tak z hlediska počtu odebraných vzorků, tak aby byly minimalizovány náklady na pořízení a analýzu vzorků bez ztráty části přirozené variability sledovaného parametru, což by vedlo k jeho zkrácenému odhadu nebo nepřesné predikci parametru v území. Standardně se používá systematické schéma vzorkování s hustotou 1–3 kompozitní vzorky na hektar (Nawar et al. 2017) nebo lze použít dříve zmíněná doporučení autorů. Existují však studie navrhuující efektivnější vzorkovací techniky pro účely predikce.

První skupinou jsou optimalizace založené na rovnoměrném geografickém rozložení vzorkovací sítě v prostoru (*spatial coverage sampling*). Cílem metody je dosáhnout rovnoměrného vzorkování v prostoru minimalizací čtverce nejkratší vzdálenosti použitím algoritmu shlukové analýzy *k-means* (Walvoort et al. 2010). Royle a Nychka (1998) publikovali vzorkovací schéma rovnoměrně pokrývající geografický vzorkovací prostor. Odběrná místa jsou vybírána tak, aby bylo minimalizováno kritérium, které je funkcí vzdálenosti mezi vzorkovaným a nevzorkovaným místem. Brus, de Gruijter a van Groenigen (2006) optimalizují schéma vzorkování u nepravidelných pozemků pomocí shlukování geografických souřadnic  $x$  a  $y$ , kdy místo odběru je určeno centroidem shluku. Walvoort, Brus a de Gruijter (2010) dále zjistili, že odhad prostorového průměru environmentálních proměnných je více přesný, když jsou odběrová místa rozmístěna více rovnoměrně v území.

Dalším přístupem jsou optimalizace vzorkování využívající podpůrná data mající vztah k půdě a tvorba zón s podobnými půdními vlastnostmi a hodnotami environmentálních proměnných s následným stratifikovaným náhodným výběrem vzorků.

## Využití podpůrných dat

Rozšířeným přístupem je geostatistické vzorkování metodami krigingu, kdy optimalizace probíhá minimalizací průměrné nebo maximální variance krigingu (Vašát et al. 2010). Heuvelink et al. (2004) navrhli optimalizační schéma prostorové predikce pro kriging minimalizací variance predikce. Vašát et al. (2010) prezentují metodu implementovanou jako R-kód (R core team 2018) na optimalizaci průměrné variance krigingu pro více půdních vlastností najednou.

Penížek et al. (2014) se zabývali optimalizací vzorkovací sítě pomocí analýzy reliéfu pro popis prostorové variability půdních bloků. Autoři rozčleňují experimentální pozemky na podoblasti vzniklé klasifikací derivátů digitálního modelu terénu, které slouží pro následný utříděný náhodný výběr. Výsledky prokazují, že ve srovnání se systematickou metodou a náhodným výběrem při stejném počtu odběrů, dosahuje predikce půdních vlastností založená na vzorcích ze stratifikovaného výběru vyšší přesnosti.

Minasny a McBratney (2006) navrhli metodu cLHS (*conditioned Latin Hypercube sampling*) speciálně pro případy, kdy je k dispozici velké množství podpůrných vrstev. Algoritmus neoperuje s geografickým prostorem, ale s multidimenzionálním příznakovým prostorem, jehož osy jsou definovány jednotlivými environmentálními proměnnými. Stratifikované schéma pak plně pokrývá příznakový prostor minimálním množstvím odběrných bodů tak, aby byla postižena variabilita celého souboru, byla redukována nejistota a chyby z extrapolace.

Lesch (2005) vyvinul algoritmus prostorového vzorkování (*response surface sampling*) vhodný pro kalibraci a validaci regresního vztahu přímého měření elektromagnetické indukce půdy a salinity půdy. Kromě základních lineárních regresních modelů se používají i metody strojového učení jako jsou náhodné stromy – *random forest* (Grimm et al. 2008). Gessler et al. (1995) navrhli schéma, které náhodně vybírá body v celém rozsahu topografického vlhkostního indexu pro modelování půdních podmínek. Hengl et al. (2003) uvádějí schéma vzorkování podél hlavních komponent environmentálních proměnných. Počet vzorků vybraných z každé komponenty proporčně odpovídá míře variability vysvětlené danou komponentou.

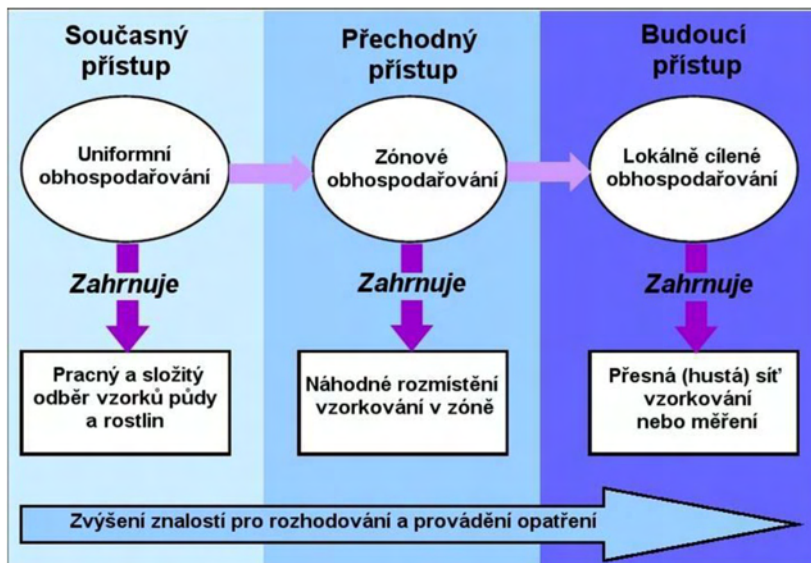
Kromě doporučení uvedených dříve v textu, Mallarino a Wittry (2001) uvádí, že intenzivní vzorkování je více efektivní pro popis variability s faktorem malého měřítka než jiné metody. Je ale více nákladné, protože vyžaduje větší počet odebraných vzorků. Vždy však záleží na volbě vhodného odběrného gridu. Statistické testy založené na zónovém vzorkování mohou mít naproti tomu nižší sílu, protože je odebráno menší množství vzorků, což snižuje faktor měřítka.

## Zónové vzorkování

Jafari et al. (2012) použili per pixel klasifikátor k vytvoření map půdních typů vycházející z digitálního modelu terénu. Sun et al. (2012), stratifikovali území podle mateční horniny a vlhkosti a poté použili rovnoměrné vzorkování v prostoru. Cambule et al. (2013) kombinovali stratifikaci a klastrování k výběru jednoduše dostupných částí studovaného území pro odběr vzorků.

Nejčastěji používaným algoritmem shlukové analýzy je *k-means* nebo *fuzzy k-means* shlukování (Ortega a Santibáñez 2007). Burrough et al. (2000) úspěšně aplikovali *fuzzy k-means* klasifikátor na data digitálního modelu terénu. Kidd et al. (2015) aplikovali náhodný výběr v zónách vzniklých *fuzzy k-means* shlukováním.

Podle novějších prací (Wang et al. 2010; Nawar et al. 2017) je v precizním zemědělství za posledních dvacet let zónový management na vzestupu, protože je možné analýzou podpůrných dat sestavit tak zvané "management zóny", kde může být aplikováno vhodné klasické schéma vzorkování. Management zóny jsou definovány jako dílčí území pole, která jsou homogenní z hlediska půdních a přírodních podmínek, což se projevuje na podobném výnosu při stejné plodině a agrotechnice. Dle Taylora a Whelana (2005) je zónový management mezistupněm mezi uniformním hospodařením a lokálně cíleným hospodařením a je vhodný zejména tam, kde zemědělská technika není přímo vybavená senzory hodnotící stav porostu nebo půdy přímo pro lokálně cílené hospodaření. Po vymezení management zón se pro vzorkování aplikuje náhodné stratifikované schéma. Stratifikovaný náhodný výběr je efektivní vzorkovací metoda. Zabraňuje klastrování bodů odběrné sítě, potřebuje méně vzorků k dosažení požadované přesnosti než jiné metody a poskytuje rovnoměrnější pokrytí v příznakovém prostoru tvořeným environmentálními proměnnými mající vztah k půdním vlastnostem (Biswas a Zhang 2018).



Obrázek 9: Evoluce v hospodaření na zemědělských pozemcích (Taylor a Whelan 2005; Lukas 2009).

## Porovnání metod

Srovnáním vhodnosti metod vzorkování pro predikci půdních vlastností na základě modelování vztahu mezi sledovanou půdní vlastností a podpurnými daty se zabývalo několik studií. Jejich poznatky lze však chápat i jako schopnost výběru, získaného aplikací metody vzorkování, odhadnout správně parametry celé populace a tím pádem i variabilitu půdní vlastnosti v území. Pokud je totiž kalibrace modelu provedena na neúplném vzorku populace, model poskytne zkreslené výsledky predikce oproti kontrolnímu měření. Falk et al. (2011) srovnávali RS, SS, SRS a cLHS. Výsledky ukázaly nejnižší přesnost RS, následovanou GS a mírně vyšší přesnost cLHS oproti SRS. Minasny a McBratney (2006) porovnali cLHS, RS a SRS se vzorkováním podél hlavní komponenty. Nejlepších výsledků dosáhla metoda cLHS. Worsham et al. (2012) hodnotí přesnost RS a SRS s metodou cLHS pro popis variability uhlíku v půdě. Populace 903 vzorků byla odebrána v gridu, potom byl proveden dílčí výběr výše uvedenými metodami a porovnány výsledky. Nejlepších výsledků pro popis variability základního souboru výběrem a predikci organického uhlíku bylo dosaženo stratifikovanou metodou a cLHS. Mulder et al. (2012) porovnávali cLHS s RS a uvádí, že cLHS je lepší než ostatní statistická schémata.

Ačkoli by se mohlo zdát, že metoda cLHS je ve všech směrech nejlepší, tak někteří autoři poukazují na její nevýhody. Falk et al. (2011) uvádí, že cLHS byla méně přesná v zachycení vyšších hodnot proměnných než stratifikovaný náhodný výběr. De Gruijter et al. (2010) uvádí dvě nevýhody: (i) metoda cLHS vybírá náhodně vzorky v příznakovém prostoru, ale pro kalibrace predikčních modelů není náhodnost nezbytná a (ii) metoda cLHS není náchylná k výběru extrémních nebo extrému blízkých hodnot, což je ale pro kalibraci modelů vhodné. Ließ (2017a, 2017b) dále argumentuje, že schopnost metody cLHS zachytit heterogenitu a tedy pedodiverzitu krajiny je limitována a její použití při vzorkování může v důsledku vést k vychýleným (*biased*) predikčním modelům.

## Shrnutí


Prakticky používaná schémata pro vzorkování půdy za účelem výzkumu prostorové variability půdy jsou: náhodné schéma vzorkování, zónové vzorkování, cLHS (aplikace zónového vzorkování) a vzorkování v pravidelné síti neboli gridu (Godwin a Miller 2003; Dinkins a Jones 2008; Ferguson a Hergert 2009).

Z klasických metod jsou nejpoužívanější zónové a pravidelné vzorkování, jejichž klady a zápory jsou uvedeny dříve v textu. Nelze však říci jednoznačně, který přístup je lepší. Celkově je možné konstatovat, že pokud neznáme historii pole nebo došlo k výrazným změnám ve způsobu obdělávání a výnosu, je lepší provést komplexní systematické vzorkování. Z rešerše je však patrné, že nelze doporučit žádnou univerzální hodnotu velikosti gridu pro vzorkování, spíše je nutné velikost kroku přizpůsobit sledovanému půdnímu parametru a rozpočtu. Pokud jsou známy faktory, které mohou ovlivňovat variabilitu výnosu (tato variabilita se projevuje ve výnosech a jsou dostupná podpůrná data), je efektivnější z hlediska času a nákladů rozdělit pozemek do homogenních zón a v nich provést vzorkování.

Z rešerše současného stavu poznání vyplývá, že z moderních metod vzorkování je nejpoužívanější cLHS. Dále se v poslední době objevují ojedinělé studie (de Gruijter et al. 2010; An et al. 2018) navrhuující odběrné sítě v dříve stanovených management zónách vzniklých fuzzy shlukováním s výběrem vzorků podle funkce příslušnosti. S unikátní teoretickou a dosud neaplikovanou myšlenkou přichází Thomas et al. (2012), který navrhuje aplikovat metodu cLHS ne na originální data extrahovaná ze snímku a DMR, ale na příslušnost jednotlivých pixelů (potencionálních vzorků) k management zónám. Praktické ověření tohoto teoretického přístupu je obsahem předložené metodiky.

V následujících podkapitolách budou popsány vstupní data a vlastní metodický postup pro dva případy včetně nezbytných teoretických zá-

kladů. Prvním případem je tvorba nové optimální odběrné vzorkovací sítě v území, kterému nejsou k dispozici žádná jiná podpůrná data než digitální model reliéfu 4. generace (DMR 4G) a satelitní snímek družice Sentinel-2. V druhém případě je optimalizována již existující pravidelná odběrná síť. Efektivnost navržené metody je dokumentována na porovnání distribuční křivky proměnných odvozených z DMR 4G nebo reálně zjištěných půdních vlastností z předchozího průzkumu výběru podle metodiky s náhodným výběrem o stejném počtu.



## OPTIMALIZACE VZORKOVÁNÍ POMOCÍ DISTANČNÍCH DAT

Metodika popisuje postup, jak navrhnout novou optimální vzorkovací síť nebo redukovat stávající pravidelnou síť na základě využití spektrálních dat a vlastností reliéfu, tak aby byla dobře zachycena variabilita sledovaných půdních vlastností. Popis této variability může být využit pro účely plánování cílených hospodářských zásahů. Jak dokazuje výše uvedený literární přehled prostorového vzorkování půdy, je vzorkování na základě dostupných podpůrných dat lepší alternativou než náhodný výběr nebo pravidelné vzorkování. Tato schémata nemusí ne-reflektovat heterogenitu půdních vlastností na pozemku a vlivem nahodilosti může dojít k případu, že homogenní oblasti budou vzorkovány zbytečně hustě, zatímco u heterogenních území bude odebranými vzorky popsána pouze část skutečné variability.

### Použití datové sady a jejich využití pro optimalizace vzorkovacích sítí

Spektrální vlastnosti holé půdy získané ze satelitních snímků do jisté míry reflektují složení půdy, zejména množství spektrálně aktivních komponent, jako je množství organického uhlíku, podíl jílových částic, vody, sloučenin železa a karbonátů. Zároveň tvar reliéfu ovlivňuje procesy v půdě a pohyb vody v půdě a po povrchu, což má vliv na vlhkost, obsah živin a erozní a akumulární procesy (Florinsky 2012). Je tedy možné předpokládat, že návrh rozmístění bodů na základě analýzy spektrální heterogenity holých půd ze satelitních snímků a tvaru reliéfu bude z podstaty věci reflektovat i heterogenitu a variabilitu půdních vlastností v území (McBratney et al. 2003; Minasny a McBratney 2006).

## Satelitní snímky družic Sentinel-2


V metodice jsou používány satelitní snímky z tandemu družic Sentinel-2A/2B. Družice Sentinel-2A/2B jsou součástí evropského vesmírného programu na pozorování Země Copernicus a v současné době jsou nejpokročilejšími multispektrálními družicemi. Program vede evropská kosmická agentura (ESA) a pořízená data jsou poskytována k prohlížení, stahování a následným analýzám zdarma. Kosmický segment programu Copernicus v současnosti zahrnuje radarové družice Sentinel-1A/1B, optické multispektrální družice Sentinel-2A/2B, družice Sentinel-3A/3B nesoucí jak optické, tak radarové senzory pro monitoring země a oceánů v kontinentálním a planetárním měřítku a družici Sentinel-5 zaměřenou na monitoring atmosféry (více na: <http://copernicus.gov.cz/copernicus>). V následujícím textu budou blíže popsány pouze družice Sentinel-2A/2B a jejich senzory, které mají uplatnění v předkládané metodice.

První z družic Sentinel-2A je již plně v provozu od června 2015. Druhá družice Sentinel-2B byla vypuštěna 7. března 2017. Na obou družicích je umístěn optický multispektrální senzor MSI (Multi-Spectral Instrument).

*Tabulka 1: Vybrané technické údaje senzoru MSI z družic Sentinel-2A/2B*

Název:	MSI - MultiSpectral Instrument
Princip snímání:	Pasivní skener – měří odražené sluneční záření
Záběr senzoru (FOV):	290 km
Počet spektrálních pásem:	13 (4 VIS, 6 NIR, 3 SWIR)
Prostorové rozlišení (velikost pixelu):	10 m, 20 m, 60 m
Perioda snímání:	Samostatně 10 dní, v tandemu 5 dní, Evropa 2-3 dny
Archiv od:	června 2015

*Pozn. Fyzikálně VIS (visible) znamená viditelné záření od 400 do 760 nm, NIR (Near Infrared) je blízké infračervené záření od 760 nm do 1000 nm a SWIR (Short wave Infrared) je krátkovlnné infračervené záření od 1400nm do 3000 nm.*




Obrázek 10: Spektrální pásma detekována senzorem MSI.

(Zdroj: <http://collgs.czechspaceportal.cz/sentinel-2-datove-specifikace/>)

## Využití multispektrálních snímků Sentinel-2 v mapování půd a zemědělství

Na základě analýzy obrazových spektrálních dat lze kvantifikovat některé půdní vlastnosti a tak hodnotit jejich variabilitu v prostorové doméně. Tyto výsledky jsou potvrzeny nejen výzkumnou činností pracovníků VÚMOP, v.v.i. (Gholizadeh et al. 2018), ale i mnoha vědeckými studiemi (např. Ben-Dor a Demattè 2015). Satelitní snímky z družice Sentinel lze dále využít např. pro identifikaci erozně ovlivněných ploch. Tato místa lze automaticky detekovat metodami obrazové klasifikace (Žížala et al. 2018, 2017). Této problematice se podrobně věnuje certifikovaná metodika Monitoring erozního poškození půd v ČR nástroji dálkového průzkumu Země (Žížala et al. 2016) vydaná VÚMOP, v.v.i.

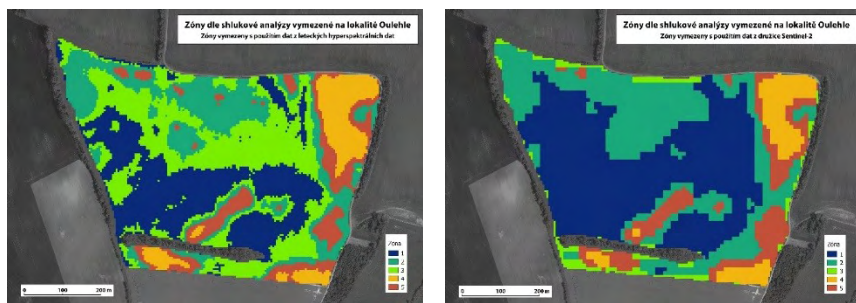


Obrázek 11: Ukázka scény zájmového území družice Sentinel 2, vlevo: v pravých barvách, vpravo: v nepravých barvách v infračerveném spektru.

Praktické výhody využití multispektrálních snímků Sentinel-2 pro zemědělství lze shrnout do následujících bodů:

- a) Satelitní data z družice Sentinel-2 jsou zcela zdarma.
- b) Scény na úrovni zpracování Level-2A jsou poskytovány již po nutném předzpracování. Jsou provedeny atmosférické korekce pro získání odrazivosti na úrovni zemského povrchu a scény jsou georeferencovány, takže umožňují přímé použití uživateli do vlastních analýz.
- c) Prostorové rozlišení (velikost pixelu) 10 m je naprosto dostatečné pro použití v zemědělství na úrovni jednotlivých půdních bloků, jak z hlediska mapování půdních vlastností a návrhu vzorkovací sítě, tak z hlediska monitorování zdravotního stavu rostlin.
- d) Jedna satelitní scéna pokrývá území o rozloze 100 km<sup>2</sup>, což je dostatečně velké území pro zpracování pozemků velkých podniků.
- e) V rámci výzkumné činnosti bylo zjištěno, že multispektrální scény družice Sentinel-2 poskytují stejně hodnotnou spektrální informaci o vlastnostech holé půdy pro účely optima-

lizace vzorkovacích sítí jako nákladná letecká hyperspektrální data. Tento fakt se projevil ve shlukové analýze dat odrazivosti extrahovaných z letecké hyperspektrální a satelitní multispektrální scény do stejného počtu tříd (5) výsledným stejným vzorem půdních zón (obrázek 12). Klasifikace je tak primárně ovlivněná množstvím spektrálně aktivních komponent - organického uhlíku, podílem jílových částic či karbonátů v povrchové vrstvě půdy.



Obrázek 12: Srovnání vzoru 5 klasifikovaných zón leteckého hyperspektrálního snímku (vlevo) a multispektrálního snímku družice Sentinel 2 (vpravo).

V současné době jsou data z družic poskytována v několika úrovních zpracování. Běžný je Level-1C a Level-2A. Level-1C představuje radiometricky a geometricky korigovaná data. Snímky jsou georeferencovány do souřadnicového systému UTM, takže prostorově „sedí“ na mapy a letecké snímky. Použití této úrovně je pro účely spektrálního rozlišení vlastností půd, identifikaci plodin či jejich zdravotního stavu nevhodné, protože hodnoty reflektance jsou počítány na hranici atmosféry (TOA – *Top of Atmosphere*) a nejsou provedeny atmosférické korekce, které si uživatel musí provést sám. Odražené sluneční záření ze zemského povrchu je totiž při cestě k senzoru pohlcováno a rozptýlováno atmosférou a oblačností, tzn. k senzoru dorazí zkreslená informace o odrazivosti povrchu. Pro koncové uživatele je vhodnější produkt na úrovni zpracování Level-2A, kde jsou již atmosférické korekce provedeny a tato úroveň představuje odrazivost na úrovni zemského povrchu (BOA – *Bottom of Atmosphere*).

Data Sentinel-2 úrovně Level-1C a Level-2A jsou dostupná například v aplikaci Copernicus Open Access Hub (<https://scihub.copernicus.eu>) a jsou po provedení registrace zdarma ke stažení. V současné době jsou všechny nově pořízené snímky dostupné rovnou na úrovni Level-2A. Dále je možno využít portál Earth Explorer od americké geologické služby (USGS), kde je možno stáhnout data i z misí Landsat (<https://earthexplorer.usgs.gov>). K dispozici jsou i další služby, které umožňují i prohlížet zpracovaná data, importovat do GIS jako OGC webovou službu či je stahovat jako georeferencované rastry (například: <https://sentinel-hub.com>).

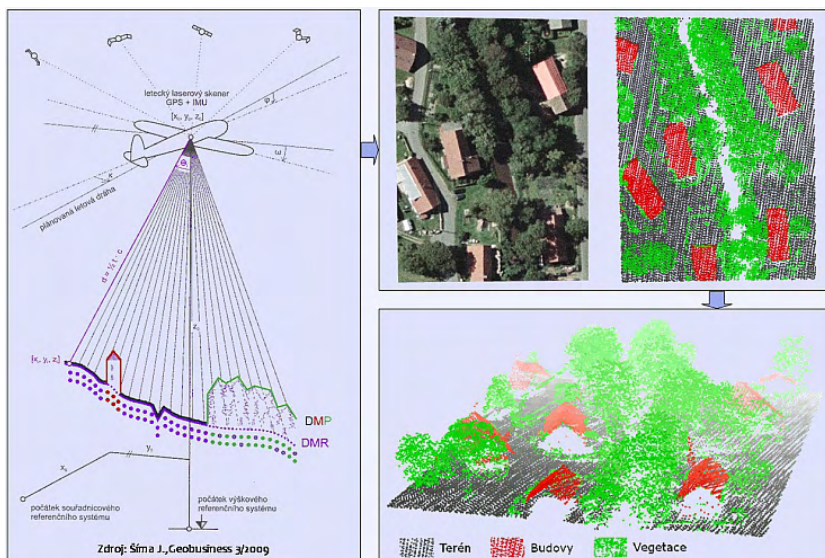
## Digitální model reliéfu

Digitální model reliéfu (DMR, synonymem je Digitální model terénu – DMT) představuje digitální reprezentaci výškopisu zemského povrchu bez přítomných objektů (např. budov a stromů). Má velký význam v zemědělství a pedologii, protože tvar a průběh reliéfu ovlivňuje pohyb vody a půdy na pozemku, způsob hospodaření, intenzitu erozních a akumulčních procesů a tím pádem ovlivňuje heterogenitu půdních vlastností a výnosů na pozemcích. Z tohoto důvodu je nutné jej zahrnout jako vstup do optimalizace vzorkovacích sítí.

Existují tři typy reprezentace DMR. Tradičním modelem je vrstevnicový model, kdy vrstevnice (izolinie) spojují místa se stejnou nadmořskou výškou a jsou vykresleny v pravidelném intervalu. Dnes se s ním můžeme setkat hlavně v tištěných topografických mapách. Vrstevnicový model bývá často odvozen z následujících dvou typů při zpracování mapy v GIS. Druhým typem modelu je model nepravidelné trojúhelníkové sítě (TIN – *Triangular irregular network*). Nadmořská výška je přiřazena vrcholům trojúhelníku, kdy samotný trojúhelník tvoří homogenní plochy. Třetím typem modelu je rastrový model, kdy je stejná nadmořská výška přiřazena celé buňce (pixelu). V současné době, kdy je většina výškopisných dat pořizována leteckým laserovým skenováním nebo fotogrammetrií a prvotním výstupem je mračno

výškopisných bodů, se používají TIN a zejména rastrové DMR, které umožňují snadnou analýzu v prostředí GIS.

Princip laserového skenování je jednoduchý a můžeme si jej představit jako laserový dálkoměr. Ze skeneru umístěné nejčastěji na letadle je vyslán svazek laserových paprsků, který se odráží od zemského povrchu a jsou detekovány zpět skenerem (tzv. echo). Zaznamenává se intenzita zpětného paprsku pro určení pořadí odrazu, protože paprsek částečně prochází vegetací a odráží se od každého patra. Z rozdílu času mezi vysláním a návratem paprsku při známé rychlosti šíření, pozice a pohybu letadla z palubní navigační jednotky je spočítána vzdálenost mezi skenerem a bodem na zemském povrchu a z ní odvozeny prostorové souřadnice bodu. Bližší informace o principech lze nalézt leteckého laserového skenování a tvorbě DMR lze nalézt v Pavelka (2013) a na geoportálu Českého úřadu zeměměřičského a katastrálního (ČÚZK). V dalším textu bude uveden stručný popis základních národních výškopisných sad a nejvýznamnějších vlastností reliéfu odvozených z DMR, které je možno využít pro aplikace zaměřených na sledování variability půdních vlastností.



Obrázek 13: Princip tvorby digitálního modelu reliéfu z laserového skenování povrchu.

## Základní výškopisné datové sady České republiky

### Základní báze geografických dat ČR (ZABAGED) – výškopis 3D vrstevnice

ZABAGED je digitální geografický model území ČR obsahující jak polohopis, tak výškopis Základní mapy České republiky v měřítku 1 : 10 000. Výškopisná část je tvořena třemi typy vrstevnic se základním intervalem 5, 2, nebo 1 m v závislosti na členitosti území s vybranými terénními hranami a kótami. Přesnost výšky je 0,7–1,5 m v odkrytém terénu, 1–2 m v sídlech a 2–5 m v zalesněném terénu. Výdejní jednotkou je list ZM 10–18 km<sup>2</sup> (Geoportál ČÚZK, 2018). Vzhledem ke své přesnosti a vrstevnicové reprezentaci tento model není vhodný pro analýzy DMR za účelem monitoringu heterogenity půdních vlastností na pozemku.

### DMR 4G a DMR 5G

DMR 4G je reprezentací zemského povrchu ve formě diskrétních bodů v pravidelné síti 5 × 5 m rozmístěných bodů se souřadnicemi XYH, kde XY jsou horizontální souřadnice systému S-JTSK a H je výška v referenčním systému Balt po vyrovnání. Úplná střední chyba výšky je 0,3 m v odkrytém a 1 m v zalesněném terénu a je určen pro analýzy regionálního charakteru. DMR 5G je rovněž bodovou interpretací zemského povrchu v pravidelné síti 5 × 5 m, ale výšková přesnost je 0,18 m v otevřeném a 0,3 m v zalesněném terénu. Model vznikl z dat leteckého laserového skenování a v r. 2016 z něj byla odvozena nová verze DMR 4G. Vzhledem ke své přesnosti je DMR 5G určen k analýzám terénu lokálního charakteru jako jsou pozemkové úpravy, dopravní, vodní a pozemní stavby (Geoportál ČÚZK, 2018).

V současné době se jedná o nejpřesnější běžně dostupné modely, se kterými lze snadno pracovat v prostředí GIS. Oba modely jsou distribuovány v textovém formátu XYH bodů po mapových listech SM 5 (2,5 × 2 km) a mohou být snadno převedeny do rastrového formátu, kdy

u modelu DMT 4G bod tvoří centroid pixelu a nadmořská výška je vztažena k ploše buňky.

Pro následné analýzy jsou, více než samostatný DMR, vhodnější vlastnosti reliéfu vypočítané v GIS, které mají vliv na pohyb hmoty a vody na zemědělských pozemcích a tím pádem mohou ovlivňovat variabilitu půdních vlastností. Každou z vypočítaných vlastností reliéfu lze chápat jako novou rastrovou vrstvu s velikostí pixelu odpovídající původnímu DMR.

### **Sklon (*slope*)**

Je ukazatelem velikosti změny nadmořské výšky ve směru jeho největšího spádu a je řídicím faktorem intenzity gravitačních pochodů vody a půdy na pozemku. Čím je větší sklon pozemku, tím je intenzivnější pohyb půdního materiálu a vody, je intenzivnější vodní eroze a zároveň u paty svahu lze očekávat akumulaci materiálu. Standardně se udává v procentech nebo ve stupních, přičemž platí, že 100% sklon odpovídá úhlu 45°. Z praktického a matematického hlediska autoři doporučují používat stupně.

### **Orientace svahu (*aspect*)**

Charakterizuje orientaci svahu ke světovým stranám podle největšího spádu a je klíčovou vlastností ovlivňující množství dopadajícího slunečního záření a vláh – návětrné, závětrné svahy a s tím související úhrn srážek, trvání sněhové pokrývky, hloubka a doba promrzání půdy. Většího významu nabývá orientace u svažitých pozemků. Většinou je udávána od severu ve směru hodinových ručiček.

### **Křivost povrchu (*Curvature*)**

Křivost povrchu je druhou derivací povrchu terénu, resp. první derivací sklonu a podle roviny, pro kterou je počítána, je dělena na horizontální

(planform) a profilovou (profile). Horizontální křivost je počítána jako změna expozice svahu podél vrstevnice a ovlivňuje sbíhavost či rozbíhavost toku vody v krajině. Pozitivní hodnota pixelu znamená bočně konvexní tvar, který způsobuje rozbíhavost vodních toků. Negativní hodnota znamená bočně konkávní povrch se sbíhavostí toků.

Profilová křivost je pak změnou sklonu svahu po spádnicí. Ovlivňuje akceleraci nebo zpomalení proudění. Pozitivní hodnota pixelu znamená, že je svah vertikálně konvexní (vypouklý) a dochází k akceleraci proudění. Negativní hodnota představuje konkávní (vydutý) svah se sklonem k akumulaci materiálu v depresi.

### ***Flow accumulation a Topography wetness index (TWI)***

Akumulace odtoku vypočítává preferenční cesty odtoku, které formují odtokovou síť na pozemku, a tím pádem identifikuje místa potencionální akumulace materiálu. Je jednou ze vstupních vrstev pro výpočet topografického vlhkostního indexu, který se vypočítá dle vzorce (McKenzie a Ryan 1999):

$$TWI = \ln \left( \frac{a}{\tan \beta} \right),$$

kde  $a$  je hodnota akumulace daného pixelu tzn. počet pixelů, ze kterých stéká voda do daného pixelu, neboli příspěvková plocha a  $\beta$  je sklon svahu daného pixelu ve stupních. TWI je nejrozšířenějším indexem pro modelování vztahu reliéfu a půdních vlastností (Penížek et al., 2014).

## Příprava dat pro výpočet optimalizace

Pro účely metodiky je nutné použít snímky, kde je na zájmových pozemcích holá půda bez vegetace. Pouze v tomto případě odpovídá reflektance vlastnostem půdy. Pokud by byla přítomna vegetace v jakékoli formě (plodiny, zelené hnojivo, posklizňové zbytky), výsledná reflektance by byla mixem vlastností půdy a vegetace, což by vedlo ke zkreslení vstupních vrstev optimalizačního algoritmu.

Samotnému optimalizačnímu algoritmu předchází koregistrace vstupních rastrových vrstev a standardizace hodnot. Koregistrace vstupních vrstev spočívá ve sjednocení souřadnicového systému, prostorového rozlišení rastrů (velikosti pixelu) tak, aby centroidy jednotlivých pixelů byly ve všech vrstvách totožné. Sjednocení rastrových vrstev se neobejde bez převzorkování (*resampling*) vrstev. U převzorkování je nutné vždy použít pouze metodu nejbližšího souseda (*nearest neighbor*), která nepřepočítává hodnoty pixelů. Metody jako biliniární interpolace (*bilinear interpolation*), a kubická konvoluce (*cubic convolution*) jsou nevhodné, protože výsledná hodnota pixelu je průměrem jejího okolí. Pokud uvážíme, že hodnoty pixelů multispektrálního snímku Sentinel-2 jsou hodnotami reflektance povrchu a je ovlivněna vlastnostmi holé půdy, jejichž heterogenitu v prostoru zkoumáme, je jakýkoliv zásah do digitálních hodnot pixelů nepřípustný a zkreslující.

Součástí optimalizačního algoritmu je i shluková analýza (popsána podrobně dále), která je velmi citlivá na měřítka (stupnice) vstupních vrstev, která mají vliv na míru podobnosti (Meloun a Militký, 2004). Shlukovací algoritmus se totiž snaží vytvořit shluky tak, aby se minimalizovala vzdálenost mezi hodnotami v rámci shluku a maximalizovala vzdálenost mezi shluky. V praxi to znamená, že sledované veličiny s řádově většími hodnotami jsou více rozptýlené v prostoru a mají větší váhu při tvorbě centroidu shluku, protože se jeví jako méně podobné než veličiny s nízkými hodnotami. Pokud tedy mají některé vstupní vrst-

vy rozsah hodnot v řádu jednotek a jiné v řádu desetitisíců a chceme, aby měli všechny stejnou „váhu“ při shlukování, je nutné provést standardizaci dat. Také je dobré standardizovat v případě, kdy kombinujeme různé jednotky např. bezrozměrné hodnoty pixelů, sklon ve stupních, desetinná čísla různých indexů.

Součástí přípravy dat pro optimalizační výpočet je vždy koregistrace vstupních vrstev. Standardizace dat je nezbytná pouze u zpracování měřítkově a jednotkově rozdílných vrstev, což nastává téměř vždy, protože snímky družice sentinel mají rozsah hodnot (0–65536), sklon je ve stupních (0°–360°) a hodnoty indexů jsou často desetinná čísla a mají rozsah od -1 do 1 nebo podobně.

Nejčastější metodou standardizace hodnot jednotlivých vrstev je standardizace směrodatnou odchylkou, která se spočítá dle vzorce (Hendl, 2015):

$$x' = \frac{x - \bar{x}}{s_x}$$

kde  $\bar{x}$  je průměr a  $s_x$  směrodatná odchylka. Výsledné hodnoty pak mají průměr 0, směrodatnou odchylku 1 a interval hodnot přibližně od -3 do 3, pokud měly původní hodnoty normální rozdělení.

Shluková analýza je rovněž velmi citlivá na přítomnost odlehých hodnot (*outliers*). Odlehlé hodnoty mohou být (a) skutečně odchýlené patologické objekty, které nejsou součástí populace, nebo (b) odlehlé hodnoty způsobené špatným výběrem z populace (Meloun a Militký, 2004). V obou případech je pak vhodné odlehlé hodnoty odstranit před dalším zpracováním.

V případě výskytu odlehých hodnot je tak lepší alternativou standardizace rozpětím dle vzorce (Hendl, 2015):

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}$$

V rámci předzpracování dat může být ještě u multispektrálního snímku vhodné redukovat počet pásem bez ztráty důležité informace pomocí analýzy hlavních komponent a poté provést standardizaci. Analýza hlavních komponent je často používanou statistickou metodou redukce proměnných (zde redukce počtu spektrálních pásem) do nových proměnných zvaných komponenty, které jsou vzájemně nezávislé (ortogonální). Komponenty jsou pak uspořádány do pořadí podle toho, kolik variability vstupních proměnných popisují. V DPZ je totiž celkem obvyklým jevem, že data z jednotlivých spektrálních pásem spolu korelují, tzn. chovají se podobně. Například hodnoty odrazivosti určitého objektu jsou vysoké nebo naopak nízké ve více nebo ve všech pásmech, a tím pádem představují duplicitní informaci.

## Návrh vzorkovacích sítí

V této podkapitole je popsán samotný optimalizační algoritmus, který navrhuje novou optimální vzorkovací síť nebo redukuje stávající pravidelnou síť podle spektrálních vlastností půdy a vlastností reliéfu tak, aby byla dobře zachycena variabilita sledovaných půdních vlastností. Algoritmus kombinuje fuzzy shlukovou analýzu s metodou vzorkování cLHS tak, jak teoreticky navrhuje (Thomas et al. 2012). Metoda cLHS není aplikována na originální data, na standardizovaná data nebo hlavní komponenty vstupních rastrů, tak jak byla původně navržena metoda, ale na příslušnost jednotlivých pixelů k zónám vzniklým shlukovou analýzou.

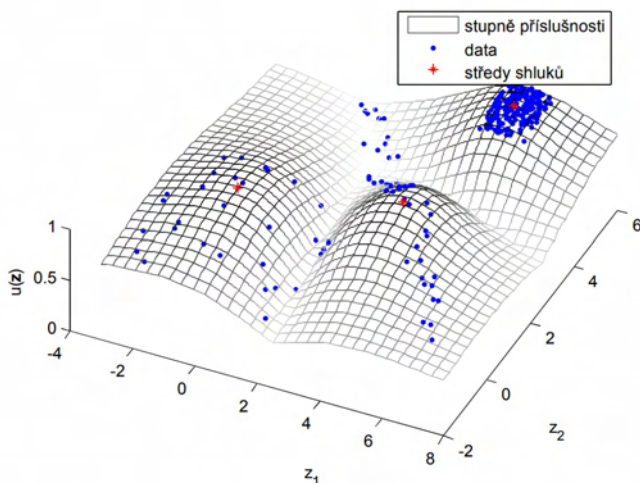
### Shluková analýza

Pro shlukovou analýzu není nutné používat vstupní data ve formě rastru, ale postačují samotné hodnoty jednotlivých pixelů uspořádaných do matice, kdy řádky jsou indexem pořadí pixelu od levého horního rohu rastru čteného po řádcích a sloupce jsou jednotlivé vstupní rastry. V rámci navrženého metodického postupu plní shluková

analýza úlohu neřízené klasifikace obrazu. Na základě vstupních informací prokazatelně spjatých s půdními vlastnostmi (reflektance a vlastnosti DMR) jsou jednotlivé pixely rozřazovány do shluků s podobnými půdními vlastnostmi, které pak v rastru zájmového území tvoří půdní zóny.

Pro neřízenou klasifikaci byla zvolena nehierarchická metoda shlukování *fuzzy k-means* (Bezdek 1973, 1981). Na rozdíl od klasického klasifikátoru *k-means* není každý pixel natvrdo přiřazen do jednoho shluku, ale je členem všech shluků s různým stupněm příslušnosti od 0 do 1. Součet všech stupňů příslušnosti jednoho pixelu je 1. Proces shlukování probíhá v iteracích, dokud není splněno optimalizační kritérium minimalizace váženého součtu čtverců odchylek vzdálenosti jednotlivých pixelů od průměrů skupin. Algoritmus vyžaduje minimum vstupních informací. Je pouze nutné zadat výstupní počet shluků.

Pro lepší interpretaci funkce příslušnosti a její důležitosti je dobré si představit pixely jako body v mnohazměrném prostoru, kdy počet os představuje počet vstupních vrstev vstupujících do analýzy a jejich rozsah je definován minimem a maximem hodnot v dané vrstvě (obrázek 14).



Obrázek 14: Grafické znázornění shlukové analýzy algoritmem fuzzy c-means (Zdroj: Procházka 2008).

Pro názornost je použit trojrozměrný prostor se dvěma vstupními vrstvami  $z_1$  a  $z_2$ . Souřadnice jednotlivých pixelů je pak dvojice hodnot  $[z_1, z_2]$ , kterých pixel nabývá v jednotlivých vrstvách. Algoritmus pak iterativně počítá souřadnice středů shluků a rozřazuje pixely tak, aby celkový součet kvadratických odchylek vzdáleností jednotlivých pixelů od příslušných průměrů skupin představujících středy shluků byl co nejmenší. Dále se vypočítá matice příslušnosti  $u(z)$ . Stupeň příslušnosti pak z geometrického hlediska značí, jak moc je pixel blízký či vzdálený středu shluku. Přeneseně na problematiku metodiky lze stupeň příslušnosti chápat jako míru, jak soubor vstupních vlastností daného pixelu (reflektance, sklon atd.) charakterizuje vlastnosti shluku. Jelikož je celkový součet příslušnosti jednoho pixelu do všech shluků roven 1, lze zjednodušeně hovořit i o pravděpodobnosti, s jakou pixel náleží do shluku  $A, B, C$  atd. Potřebným výsledkem pro další zpracování shlukové analýzy je pak tabulka příslušností jednotlivých pixelů do určitého počtu předem zvolených shluků (obrázek 15).

	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5
<b>24675</b>	0,01311606	0,93336785	0,03164982	0,00875162	0,012634893
<b>24348</b>	0,01620781	0,91896741	0,03897315	0,01093492	0,01566527
<b>23789</b>	0,01674494	0,91695324	0,03895129	0,01137852	0,01626515
<b>24855</b>	0,01726190	0,91149657	0,04342678	0,01158623	0,01645612
<b>23688</b>	0,01757413	0,90926753	0,04337624	0,01166263	0,01700152
<b>28111</b>	0,01826548	0,90823154	0,04262784	0,01259582	0,01772569
<b>22457</b>	0,01859874	0,90725786	0,04462845	0,01265287	0,01806974
<b>26175</b>	0,01896212	0,90556789	0,04262785	0,01276284	0,01804596

Obrázek 15: Ukázka tabulky příslušnosti pixelů (řádky) do pěti shluků (sloupce).

Teoreticky by bylo možné prohlásit za optimální odběrná místa, dobře reprezentující půdní zónu a její vlastnosti, pixel s největší příslušností ke zvolenému shluku (viz obrázek 15, např. pixel 24675, Cluster 2). Slabým místem tohoto přístupu, který znemožňuje jeho nasazení v praxi, je problém se stanovením optimálního počtu tříd, který je diskutován v následující podkapitole a v kapitole Aplikace metodiky na zájmovém území.

## Výběr optimálního počtu shluků

Fuzzy *k-means* algoritmus vyžaduje od uživatele pouze jeden vstup a tím je požadovaný počet shluků. Jak ale určit správný počet shluků? Kromě expertního odhadu je další možností použít pro tento účel sestavené indexy validity. Indexy validity číselně hodnotí, zda je výsledné rozdělení shluků optimální, je minimalizovaná vzdálenost mezi objekty v jednom shluku a platí, že maximální nebo minimální hodnota značí optimální rozložení shluků. Toho lze využít při hledání optimálního počtu shluků následovně:

- Stanoví se interval počtu shluků od 2 do  $x$  a provede se shluková analýza pro každý počet shluků.
- Spočítají se vybrané indexy validity pro každý počet shluků a zpracují se výsledky do tabulky nebo grafu (viz obrázek 18).
- Vybere se optimální počet shluků dle jednoho nebo více indexů.

Výhodou je, že kritérium optimality je počítáno pouze ze vstupních dat a nevyžaduje žádnou další informaci. Nevýhodou navrženého postupu je pak jeho výpočetní náročnost. Jedna iterace výpočtu trvá v závislosti na velikosti území a počtu tříd v řádu hodin, ale v současné době je to jediné řešení, jak určit objektivně optimální počet shluků pouze na základě vstupních dat a je obecně doporučováno. V následujícím textu jsou stručně představeny základní indexy optimality. Podrobnější informace včetně matematického výpočtu lze nalézt v publikaci Ferraro a Giordani (2015).

Bezdek (1973) navrhl dva optimalizační indexy vypočítávané pouze z matice stupňů příslušnosti: *partition coeficient* (PC) a *partiton entropy* (PE). Nevýhodou tohoto přístupu je, že jsou počítány pouze ze stupňů příslušnosti a nezohledňují strukturu dat ve shluku (Bezdek, 1995). Optimálního počtu shluků je dosaženo, když jsou shluky kompaktní, což se

projevuje vysokými stupni příslušnosti jednotlivých objektů a hodnota PC je maximální. Index PC může nabývat hodnot v intervalu  $[1/k, 1]$ . Oproti tomu je optimálního počtu shluků dosaženo, když je index PE minimální. Dave (1991) navrhl modifikaci indexu PC (MPC) pomocí lineární transformace. Výhodou MPC je rozsah výsledných hodnot v intervalu  $[0,1]$ , které jsou jasně interpretovatelné. Opět je dosaženo optimálního počtu shluků, když je hodnota MPC maximální.

Meloun a Militký (2004) doporučují statistiku zvanou silueta (*Fuzzy silhouette index*, SIL), která sumarizuje, jak těsně shlukové uspořádání prokládá analyzovaná data. Při správném počtu shluků je silueta maximalizována. Opět se vychází ze vzdálenosti mezi objekty. Shluky jsou správně uspořádány a silueta je blízká +1, pokud pro každý objekt ve shluku A má podstatně blíže ke svým sousedům ze shluku A, než k nejbližším pixelům ze shluku B. Pokud je hodnota blízká 0, pak je objekt uprostřed mezi shluky A, B a pokud se blíží -1, pak klasifikace proběhla špatně a pixel shluku A má mnohem blíže k objektům shluku B než ke svým sousedům ze shluku A (viz. tabulka 2).

*Tabulka 2: Hodnoty SIL a jejich vztah k uspořádání výsledných shluků (podle: Meloun a Militký, 2004).*

<b>SIL</b>	
Od 0,71 do 1	Silná a dobrá struktura.
Od 0,51 do 0,71	Přijatelná struktura.
Od 0,26 do 0,50	Slabá struktura. Je třeba najít novou.
Od -1 do 0,25	Nevhodná struktura, je třeba najít novou.

Výsledkem této části metodického postupu je tabulka stupňů příslušnosti jednotlivých pixelů k optimálnímu počtu klasifikovaných půdních zón. Tato tabulka pak vstupuje do závěrečné fáze optimalizačního výpočtu, kde jsou vybírány jednotlivé pixely představující místa odběrné sítě algoritmem cLHS.

## Výběr optimálního počtu vzorků

Jedním z klíčových bodů návrhu vzorkovací sítě je správně stanovit optimální počet vzorků pro zájmové území. Extrémní variabilita půdních podmínek v prostoru však znemožňuje stanovit univerzální metodu (Sáňka 1996). Proto je nutné vždy vzorkovací schéma přizpůsobit cíli, rozpočtu a požadované kvalitě (viz kroky procesu vzorkování).

Podle McBratneyho et al. (1999) je standardní odběr jednoho vzorku na hektar nedostatečný a navrhují interval mezi 30 a 80 metry. K obdobným závěrům dochází i Hammond (1993) s intervalem 60 m a David W Franzen, Peck, and Hoeft (1993) s 30 m. Griffin (1999) uvádí, že v Evropě a USA se standardně používají sítě 100 m. Brodský (2003) navrhuje hustotu sítě 40 m pro fosfor, 40 metrů pro draslík, 60 metrů pro hořčík a 20 m pro pH půdy. Vašát et al. (2012) porovnávali dopad počtu vzorků na parametry variogramu a došli k závěru, že 50 vzorků je dostatečných pro tvorbu interpolované mapy půdních vlastností pole o rozloze 24 ha (přibližně dva vzorky na hektar). V reálných podmínkách je však takováto hustota vzorkování spojena s velkými náklady a je zapotřebí optimalizovat vzorkovací sítě tak, aby i při redukci hustoty vzorkování došlo ke ztrátě co nejmenšího množství informace.

Pokud nejsou pro řešené území k dispozici žádná předešlá data, lze pro odhad počtu vzorků využít hodnoty z tabulky 3 z práce Gilberta (1987). Autor uvádí doporučené počty vzorků v závislosti na zvolené konfidenční hladině a hodnotě variačního koeficientu pro získání dobrého odhadu střední hodnoty sledované veličiny z výběru (Tabulka 3).

Tabulka 3: Velikost výběru potřebného pro dobrý odhad průměru sledované veličiny (podle: Gilbert, 1987).

Konfidenční hladina	Relativní chyba, $d_r$	Variační koeficient CV, %					
		10	20	40	50	100	150
0,8	0,1	2	7	27	42	165	370
	0,25			6	7	27	60
	0,5				2	7	15
	1					2	4
0,9	0,1	2	12	45	70	271	609
	0,25			9	12	45	92
	0,5				2	13	26
	1					2	8
0,95	0,1	4	17	63	97	385	865
	0,25			12	17	62	139
	0,5				4	16	35
	1					9	16

Zjednodušeně lze konfidenční hladinu chápat jako pravděpodobnost, se kterou se náš odhad průměru sledovaného parametru, např. obsahu humusu, bude maximálně lišit od skutečného průměru o hodnotu relativní chyby. Relativní chyba je definována jako (Carter a Gregorich 2014):

$$d_r = \frac{|\bar{X}_{vyberu} - \bar{X}_{populace}|}{\bar{X}_{populace}}$$

Kde  $\bar{x}$  značí průměr. Relativní chyba je bezrozměrné číslo, které lze převést na procenta, tzn. hodnota 0,1 odpovídá chybě (odchylce)  $\pm 10$  %. Variační koeficient se vypočítá dle vzorce (Hendl, 2015):

$$CV = \frac{S_x}{\bar{x}}$$

Kde  $s_x$  je směrodatná odchylka sledované veličiny a  $\bar{x}$  je průměrná hodnota. Varianční koeficient je charakteristikou variability náhodné veličiny a vyjadřuje, kolik procent průměru představuje směrodatná odchylka. Pro výpočet CV je možné použít jak hodnoty z předchozího vzorkování území, tak variabilitu podpůrných dat např. sklonu terénu. Pomůckou pro odhad CV může být i tabulka 4 – Variabilita vlastností půdy.

Tabulka 4: Variabilita vlastností půdy (podle: Wilding et al. 1983; Sumner, 2000).

Variační koeficient			
Nízký (CV < 15%)	Střední (CV 15–35%)	Vysoký (CV 35–75%)	Velmi vysoký (CV 75–150%)
barva půdy (odstín a sytost)	podíl pískových částic	hloubka půdy	bilance NO <sub>2</sub>
hodnota pH	podíl jílových částic	výměnný Ca, Mg, K	Elektrická konduktivita nasyčená hydraulická vodivost
mocnost A horizontu	kationtová výměnná kapacita	přístupný N	
mocnost horizontu	satrace	přístupný P	
podíl prachových částic	obsah CaCO <sub>3</sub>	přístupný K	
pórovitost	výnos		
objemová hmotnost	obsah humusu		

V případě, že zájmové území nebylo nikdy vzorkováno a nejsou dostupné žádné údaje o variabilitě půdních podmínek, se doporučuje vycházet při výpočtu optimálního počtu vzorků z uvedených tabulek (tabulka 3 a tabulka 4). Je ale důležité si uvědomit, že výpočet dle tabulek nereflektuje prostorovou heterogenitu území, ale zaměřuje se jen na celkovou variabilitu v daném území. Neříká tedy, kde je potřeba vzorky odebrat, ale kolik je jich celkově potřeba pro odhad sledovaného parametru v populaci. Samotné rozmístění řeší optimalizační algoritmus cLHS.

## Rozmístění optimálního počtu vzorků

Pro vlastní rozmístění odběrných míst v prostoru je využita metoda cLHS – *condition latin hypercube sampling* (Minasny a McBratney 2006), která vychází z tzv. latinských čtverců. cLHS je v podstatě utříděné náhodné schéma vzorkování, které namísto čtvercové matice operuje

v prostoru hyperkrychle (zobecnění krychle do více než tří rozměrů) s osami definovanými vstupními proměnnými (zde stupni příslušnosti jednotlivých pixelů do určitého počtu shluků).

V prvním kroku algoritmus vybírá  $M$  vzorků pro každou z  $K$  proměnných tak, že kumulativní distribuční funkce každé proměnné  $K$  je rozdělena do  $M$  intervalů o stejné pravděpodobnosti. Potom je z každého intervalu náhodně vybrán jeden vzorek.

V případě metodiky je pak  $M$  počet vzorků, odběrných míst (pixelů) stanovený v předchozím kroku. Počet sloupců tabulky stupňů příslušnosti ze shlukové analýzy je počet proměnných  $K$ .

## Hodnocení výsledků návrhu vzorkování


Smyslem optimalizace je navrhnout odběrnou síť tak, aby odebrané vzorky dobře popsaly variabilitu půdních vlastností v území. Pokud nemáme žádné informace o půdní variabilitě, pak lze hodnotit reprezentativnost výběru (variabilita hodnot vybraných pixelů) pouze porovnáním jeho variability s variabilitou základního souboru (variabilita hodnot všech pixelů v území). K tomuto účelu jsou nejvhodnější základní statistické metody popisu variability jako průměr, rozptyl či směrodatná odchylka, ale lepší je použít grafická znázornění jako je histogram, violin plot nebo boxplot. Buď je možné vizuálně porovnat výsledné grafy, nebo je možné porovnat početně, např. zda rozdíl mezi průměrnou hodnotou výběru a základního souboru jsou menší než požadovaná relativní chyba  $dr$ . Pro testování hypotézy zda-li výběr a základní soubor pocházejí ze stejného rozdělení, je možné použít Mann Whitney test pro dva datasets nebo Kruskal Wallis test pro více výběrů.

## Optimalizace stávající odběrné sítě

Výše navržený metodický postup je primárně určen pro návrh nových odběrných sítí na dříve nevzorkovaném území. Po drobných úpravách lze optimalizační algoritmus aplikovat i na stávající odběrnou síť za účelem její redukce.

Dle výsledků testování autorů metodiky je však nejlepším řešením při dostatečné hustotě vzorkování provést redukci stávající odběrné sítě na bázi již zjištěných analytických údajů. Stávajícím odběrným místům lokalizovaným v geografickém prostoru přiřadíme řádky atributové tabulky, která obsahuje všechny dostupné půdní chemické a fyzikální vlastnosti půdy v odběrném místě. Tato tabulka pak slouží jako vstup do shlukové analýzy místo původních vrstev satelitního snímku a vrstev DMR. V tom případě je pak shlukování do zón provedeno přímo podle měřených půdních vlastností a ne nepřímo podle spektrálních vlastností půdy a tvaru reliéfu.


Podrobněji je situace rozebrána ve výsledcích aplikace metodiky na zájmovém území.



## Aplikace metodiky na zájmovém území

### Popis území

Metodika byla sestavena a testována na vybraném zájmovém území o velikosti cca 290 ha v okrese Vyškov v jihomoravském kraji. Půdní bloky (Oulehle, Zákostelní, Zadní u Těšan, Zádvořní a Klínek) jsou obhospodařovány zemědělským podnikem ROSTĚNICE a. s. a nachází se na území střediska Otnice. Půdní kryt je charakteristický pararendzinami na slínitých horninách karpatského flyše a černozeměmi v různém stadiu degradace na sprašových pokryvech různé mocnosti a sprašových hlínách. Vlivem variability matečního substrátu a dlouhodobým působením erozně akumuláčních procesů v členitém terénu se území vyznačuje vysokou heterogenitou půdních vlastností, které se odráží i v nerovnoměrných výnosech zemědělských plodin. Na lokalitách byl proveden podrobný pedologický průzkum, byly popsány půdní profily a byly odebrány porušené vzorky pro půdní a agrochemické analýzy s hustotou vzorkování 3 vzorky/ha (pH, obsah přístupných živin – P, Mg, K, Ca, C<sub>ox</sub>, celk. dusík, zrnitostní frakce, KVK, obsah uhličitánů). Na pozemku Oulehle byla síť zahuštěna na hustotu 0,5 vzorků/ha. U třetiny sond byly odebrány neporušené vzorky pro stanovení fyzikálních parametrů půdy (vlhkost hmotnostní a objemová, pórovitost, vzdušnost momentální a minimální, nasáklivost, retenční vodní kapacita, maximální kapilární vodní kapacita, měrná hmotnost, objemová hmotnost). Vzorky byly odebrány ve vybraných bodech pravidelné vzorkovací sítě, ve které od roku 2006 probíhá ve tříletém cyklu kontinuální agrochemický monitoring pro korekci základního hnojení (obrázek 16). Pro území byly dále k dispozici výnosové mapy (od roku 2013) a průměrné výnosy za pozemky.



Obrázek 16: Originální odběrná síť na zájmovém území.

## Příprava dat

Samotné klasifikaci obrazu předcházelo předzpracování rastrových vrstev. K dispozici byly datové sady: rastrová multispektrální scéna z družice Sentinel-2 (Level-2A), DMR 4G a odvozená data zahrnující sklon, orientaci, planární a profilovou křivost, Flow accumulation a TWI index. Jako referenční byl zvolen rastr multispektrální snímek z března r. 2017, kdy byly všechny zájmové pozemky holé bez vegetačního pokryvu a rostlinných zbytků. Všechny ostatní rastry byly před analýzou transformovány v programu ArcMap 10.4.1 pomocí nástrojů Project Raster a Resample do souřadnicového systému UTM 33N a velikost pi-

xelu byla sjednocena na 5 m tak, aby centroidy jednotlivých pixelů byly ve všech vrstvách totožné.

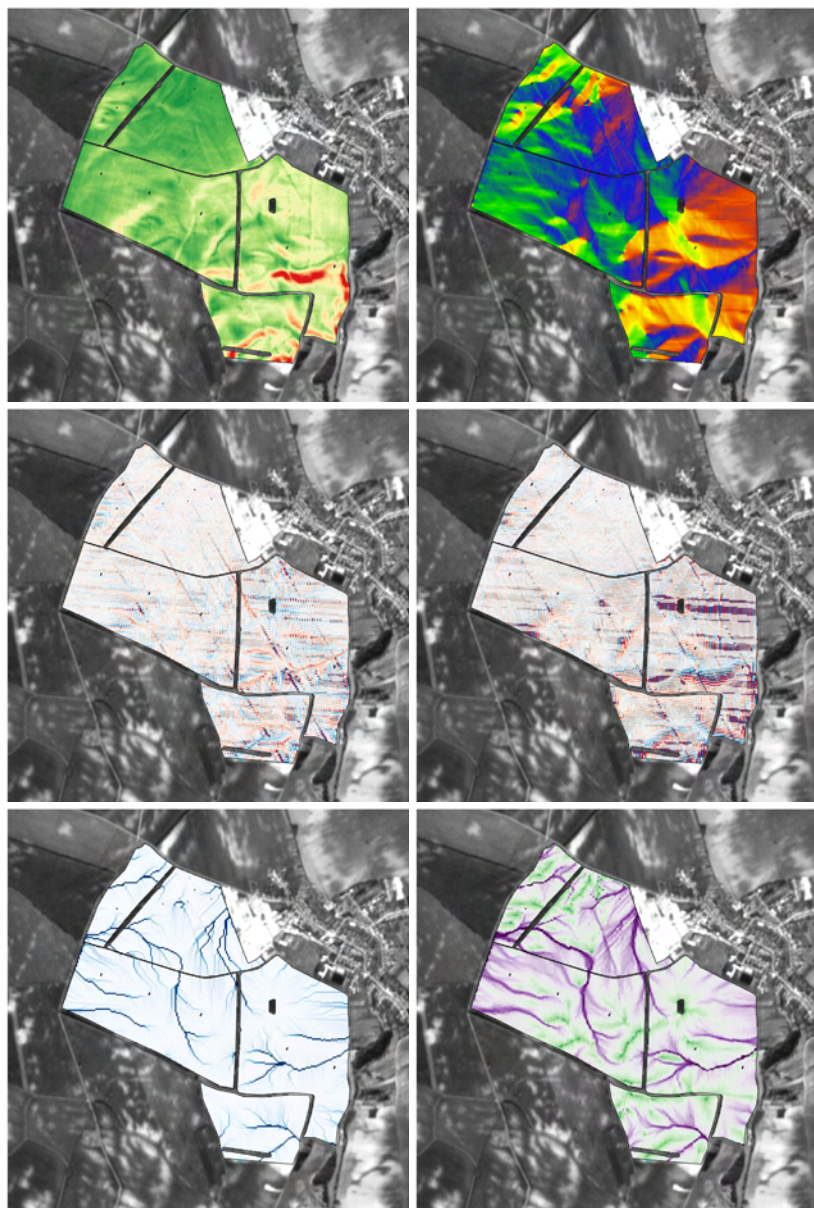
Veškerý další postup byl zpracován v softwaru RStudio, což je grafické rozhraní a vývojové prostředí jazyka R. Byla provedena analýza hlavních komponent snímku Sentinel-2, kdy bylo původních 10 spektrálních pásem transformováno na 3 hlavní komponenty a byla provedena jejich standardizace směrodatnou odchylkou. Ostatní rastrové vrstvy byly standardizovány taktéž dle směrodatné odchylky. Pro samotný optimalizační výpočet nebyly používány rastry vstupních vrstev, ale pouze hodnoty jednotlivých pixelů organizovaných v maticích.

## Optimalizace vzorkování


V rámci případové studie byly na zájmové lokalitě navrženy dva scénáře testující použitelnost metodiky. V prvním případě byla navržena nová odběrná síť pouze na základě vstupních vrstev. V druhém případě byla algoritmem optimalizována stávající odběrná síť, která vznikla pseudo-náhodným výběrem na základě náhodného rozmístění požadovaného počtu vzorků s korekcí agronoma dle znalosti území a požadavku na přibližně rovnoměrné uspořádání.

### 1. Návrh nové odběrné sítě

V prvním případě se jednalo o navržení zcela nové optimalizované odběrné sítě na zájmovém území přesně dle postupu v předkládané metodice. Optimalizační algoritmus byl napsán v jazyce R. Pro shlukovou analýzu byl použit balíček *ppclust* (Cebeci et al., 2008), pro výpočet indexů optimality balíček *fclust* (Ferraro a Giordani 2015) a pro cLHS stejnojmenný balíček *cLHS* (Roudier, 2011). Grafické výstupy byly připraveny pomocí funkcí knihovny *ggplot2* (Wickham 2015). Shluková analýza včetně výpočtu indexů optimality byla vypočítána pro 2 až 10 tříd (obrázek 18).



Obrázek 17: Vrstvy vstupující do algoritmu optimalizace vzorkovací sítě ve vzorové studii (od horního levého obrázku): Sklon, orientace, planární a profilová křivost, flow accumulation, TWI.




Obrázek 18: Hodnoty validačních indexů pro shlukovou analýzu zájmového území do různého počtu klastrů. Pozn.: Křivka spojující jednotlivé body neznamená interpolaci. Slouží pouze pro lepší vizualizaci.

Z výsledků výpočtu validačních indexů jasně vyplývá, že neoptimální počet tříd jsou dvě, kdy je maximalizována hodnota PC, MPC, minimalizována hodnota PE a zároveň je hodnota siluety 0,7, což značí přijatelnou strukturu shluků. Použití více shluků pro další zpracování nepřinášelo užitek, protože shluky se navzájem překrývaly a vzrůstala míra neurčitosti— entropie (viz index PE). V našem případě to znamenalo, že při vyšším počtu shluků měly pixely velmi podobné stupně příslušnosti k jednotlivým shlukům a pro jednoznačné zařazení by bylo nutné dodat další informace.

Mohlo by se zdát, že klasifikace pozemků zájmového území o rozloze 300 ha pouze do dvou tříd je nedostatečná a je způsobena nevhodným výběrem vstupních vrstev, které nedostatečně reflektují variabilitu půdních podmínek. Proto byla pro ověření provedena shluková analýza včetně výpočtu indexu optimality 100 bodů referenční sítě se známými půdními vlastnostmi do 2–10 tříd. Výsledky ukázaly, že nejlepších hodnot indexů optimality bylo dosaženo pro 2 shluky. Ověření tedy potvrdilo výsledky a je možné konstatovat, že v území se nacházejí pouze 2 zóny se statisticky významně rozdílnými půdními vlastnostmi.

Analýzou výsledků pedologického průzkumu a vizuálním srovnáním klasifikovaného snímku do dvou tříd a výřezu originálního snímku bylo zjištěno, že modrá zóna (obrázek 19) odpovídá silně erodovaným místům na pozemcích, kde vystupuje podorničí. Je potřeba si uvědomit, že byl použit „měkký“ *fuzzy* klasifikátor, který nezařadil pixel pouze do jedné třídy, ale spočítal stupeň příslušnosti k oběma třídám. Pro přehlednost byl klasifikovaný snímek obarven podle vyšší hodnoty stupně příslušnosti. Přesnější je tedy interpretovat modrou barvu spíše jako erodovanou půdu než neerodovanou.

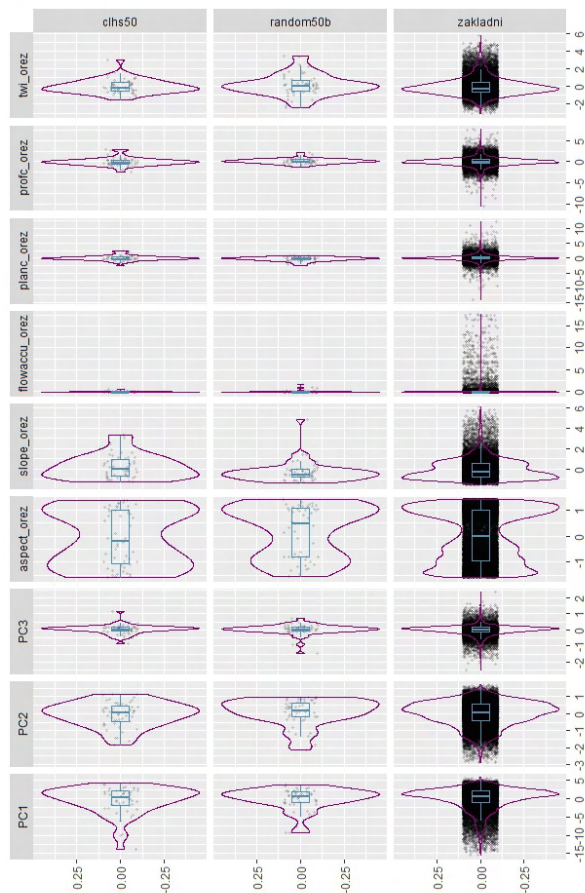


Obrázek 19: Srovnání fuzzy klasifikace zájmového území se snímkem Sentinel-2. Šedou barvou je označena zóna 1 - spíše neerodované půdy. Modrou barvou je označena zóna 2 - spíše erodované půdy.

Aby byla zachována porovnatelnost nově navržené sítě s originální, bylo rozhodnuto zachovat počet 100 odběrných míst, které algoritmus cLHS automaticky rozmístil po celém zájmovém území na základě analýzy matice příslušnosti pixelů do dvou tříd. Rovněž výběr 100 bodů odpovídal doporučením z tabulky 2 a 3. Variační koeficient vstupních vrstev byl maximálně 50 %. Pokud uvažujeme nejnižší hodnotu relativní chyby a nejvyšší konfidenční hladinu 0,95, pak je dle tabulky 3 nutný výběr 97 bodů. Závěry byly pak formulovány na základě srovnání variability optimalizovaného výběru s náhodným výběrem a celým základním souborem (obrázek 20).

Bylo zjištěno, že výběr 100 bodů představuje dostatečný, ale až příliš velký výběr pro popis variability všech proměnných (spektrální odrazivosti půdy v kombinaci s vlastnostmi reliéfu). Jak optimalizovaná síť, tak náhodný výběr odpovídali distribuční křivce základního souboru včetně zachycení extrémů. Opakovanými náhodnými výběry 100 bodů bylo zjištěno, že není rozdíl mezi náhodnými výběry. Proto bylo přistoupeno k redukci na 50, 25, a 10 odběrných míst. Zde se již ukázala síla optimalizačního algoritmu, který byl schopen navrhnout optimalizovanou síť o 50 bodech stále odpovídající rozdělení hodnot

souboru, zatímco průměry opakovaných náhodných výběrů kolísaly, zejména u hlavních komponent a orientace svahu (viz obrázek 20). Statistické testování Mann Whitney testem ukázalo, že není možné zamítnout nulovou hypotézu ( $p \text{ value} > 0,5$ ) o shodnosti populací reprezentovaných optimalizovaným výběrem a základním datovým souborem.



Obrázek 20: Srovnání rozdělení hodnot vstupních proměnných optimalizovaného výběru, náhodného výběru a základního souboru.

Pozn.: Surové hodnoty jsou černě. Červená křivka představuje hustotu rozdělení pravděpodobnosti (violin plot). Boxploty (modře) jsou konstruovány standardně. Obdélník zobrazuje interkvartilové rozpětí a prostřední čára medián.


## 2. Redukce počtu odběrných míst stávající odběrné sítě.


Ve druhém scénáři byl testován optimalizační algoritmus jako prostředek redukce stávající odběrné sítě (obrázek 16) dle návrhu metodiky, kdy do shlukové analýzy vstupovaly půdní vlastnosti zjištěné na 100 odběrných místech. Jak už bylo uvedeno výše v textu, nejlepších hodnot indexů optimality bylo dosaženo pro 2 shluky a území lze klasifikovat pouze do dvou statisticky významných zón s podobnými vlastnostmi. Variabilita půdních vlastností v jednotlivých zónách je graficky znázorněna na obrázku 21.

Vymezené zóny se z pohledu půdních vlastností liší zejména s ohledem fyzikální charakteristiky, pH, obsah živin, obsah uhličitánů a celkového dusíku. Tyto rozdíly lze popsat různým stupněm erozního poškození. Erodivní plochy vymezené v zóně 2 mají vyšší pH a vyšší obsah uhličitánů, což souvisí s obnažováním podorní (vápnité spraše a slíny), takže dochází k selektivnímu vymílání bazických a odplavování živin. Z pohledu fyzikálních charakteristik je patrný rozdíl zejména v orniční vrstvě, kdy vlivem erozních procesů dochází k narušení půdní struktury a s tím spojenými změnami v pórovitosti a hydrologických vlastností půdy.

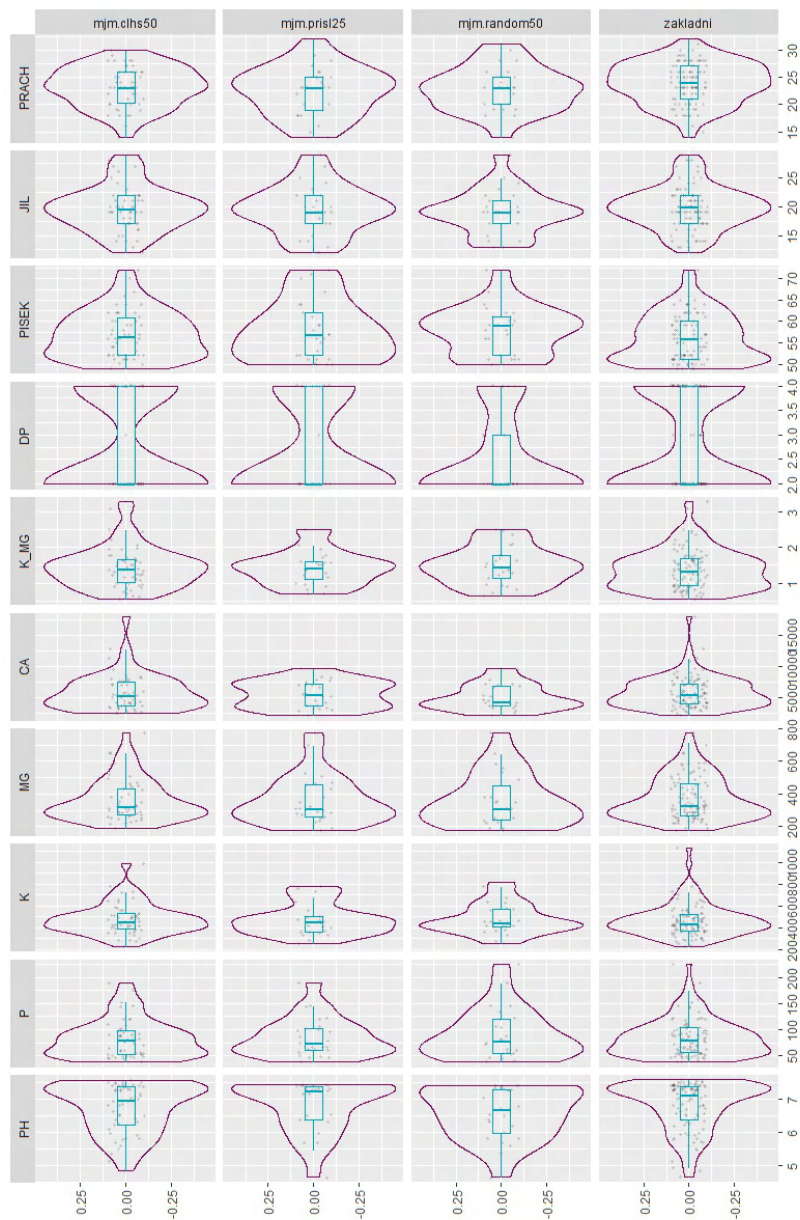
Postupnou redukcí původních 100 bodů odběrné sítě na 75, 50, 25, a 10 bodů bylo zjištěno, že optimalizační algoritmus je schopen ze stávající odběrné sítě vybrat 50 vzorků, které dostatečně přesně popisují variabilitu půdních vlastností v zájmovém území včetně extrémů, což je dobře patrné na křivkách hustoty pravděpodobnosti v porovnání se základním souborem (obrázek 22). Naproti tomu náhodný výběr 50 bodů ze sítě vede k značnému vychýlení průměru výběru sledované vlastnosti od základního souboru (hlavně pH, K, Ca a písek) a nepostihuje extrémy. Pokud by bylo nutné z finančních důvodů redukovat více, i odebrání 25 bodů je dostatečné a je stále lepší než náhodný výběr. Redukci o více jak 50 % však již nelze doporučit, pokud to není ne-

zbytečně nutné, z důvodu limitované schopnosti uvedené metody cLHS zachytit heterogenitu a tedy pedodiverzitu krajiny. Přílišná redukce při vzorkování může v důsledku vést k vychýleným odhadům. Míra redukce také závisí na potřebě vzorkování. Pokud je cílem monitorovat vysoce variabilní vlastnosti, jako např. obsah živin, lze doporučit menší redukci, případně doplnění redukované sítě o vzorkovací body dle zkušenosti, resp. expertního odhadu nebo na základě dalších dostupných dat – typicky přesných výnosových dat upravených o nahodilé vlivy (výskyt plevelů a chorob, polehnutí porostu apod.)





Obrázek 21: Srovnání variability zjištěných půdních vlastností ve dvou klasifikovaných zónách. Zóna 1 (zde fialově) představuje spíše neerodovanou půdu, zóna 2 (modrozelená) silně erodovanou půdu..



Obrázek 22: Srovnání rozdělení hodnot vstupních proměnných optimalizovaného výběru o 50 a 25 vzorcích, náhodného výběru o 50 vzorcích a základního souboru.

## Shrnutí

Navržený metodický postup se uplatní při návrhu nové optimální sítě v území, které nebylo nikdy vzorkováno nebo při redukci stávajících odběrných sítí pouze na základě snadno dostupných multispektrálních satelitních snímků a DMR. Využití spektrálních dat přitom přináší značný užitek v porovnání s využitím pouze terénních dat, jelikož tato data popisují reálný stav půdního prostředí (ovšem jen v povrchové vrstvě) a jsou tak schopná v modelech popsat i stochastickou část variability na pozemku.

Výsledky aplikace metodiky na zájmovém území prokázaly, že při stejném počtu vzorků optimalizovaná odběrná síť lépe popsala variabilitu základního souboru než náhodný výběr. Zároveň je metoda aplikovatelná i na redukční optimalizace stávajících sítí. V případové studii byl původní počet vzorků redukován o 50 % bez výrazné ztráty informace o variabilitě půdních vlastností.

Výše uvedená analýza jasně poukazuje na základní nevýhody náhodného výběru či pravidelné vzorkovací sítě, které byly diskutovány v širší části metodiky. Náhodný či pravidelný výběr bodů v ploše vede k nemožnosti využít dostupné informace o heterogenitě půdy, tím pádem mohou být homogenní části vzorkovány příliš hustě a heterogenní části příliš řídky. Výsledky v obou scénářích jasně ukazují, že optimalizované sítě navržené dle metodického postupu vytěžují dostupné informace o heterogenitě území a optimalizují odběrnou síť tak, aby byla popsána variabilita půdních podmínek v celém území.



# 4 SROVNÁNÍ „NOVOSTI POSTUPŮ“

Metodika přináší přehled metod pro tvorbu a optimalizaci vzorkovací sítě s využitím spektrálních a dalších doplňkových dat. Tyto metody umožňují efektivní návrh vzorkovací sítě pro účely cíleného hospodaření na základě principů precizního zemědělství. Metodika svým obsahem navazuje na certifikovanou metodiku Penížek et al. (2014), která se zabývá optimalizací vzorkovací sítě pomocí využití analýzy reliéfu. Nová metodika využívá k optimalizaci vzorkovací sítě nově spektrální data, jejichž využití přináší výhodu v možnostech popisu i stochastické části variability nezávislé na parametrech reliéfu, která se odráží právě ve spektrálním chování půd. Navržený postup je založen na nejnovějších vědeckých metodách v oboru pedometrie, tedy aplikace statistických metod na data o půdě. Tato metodika využívá běžně dostupné datové zdroje a je možno ji jednoduše automatizovat, např. v open source prostředí R, což umožňuje její širokou aplikovatelnost. Metodika využívá principy stratifikovaného náhodného vzorkování, kdy je náhodný výběr pomocí metody cLHS aplikován na zóny vzniklé fuzzy k-means shlukováním. Postup tak jednak umožňuje tvorbu tzv. management zón, ale zejména jejich využití pomocí funkce příslušnosti pro stratifikovaný návrh vzorkovací sítě, případně pro optimalizaci stávající sítě.



# 5 POPIS UPLATNĚNÍ METODIKY

Zjištění variability půdních vlastností mající vliv na pěstované plodiny a výnos je prvním krokem pro správné a cílené hospodaření na základě principů precizního zemědělství. Metodika přináší široce aplikovatelný postup s volně dostupnými zdroji dat, který je možno využít pro návrh vzorkovací sítě i v místech s výraznou variabilitou půdních vlastností. Postup byl vyvinut v rámci výzkumného projektu ve spolupráci se zemědělským podnikem ROSTĚNICE, a.s. a Mendelovou univerzitou v Brně. V tomto kontextu je uplatnění metodiky směřováno zejména na zemědělské podniky, které využívají lokálně cíleného hospodaření zohledňující heterogenitu půdních podmínek s cílem zefektivnit využívání agrochemických vstupů do rostlinné produkce. Zapojení akademické sféry zároveň zajišťuje efektivní přenos navržených postupů do praxe.



## 6 EKONOMICKÉ ASPEKTY

Popsané metodické postupy jsou navrženy tak, aby využívaly obecně dostupné zdroje a byly implementovatelné i v prostředí nekomerčních softwarů. Z tohoto pohledu zavedení postupů nepřináší žádné náklady spojené s infrastrukturou a daty. Náklady jsou tak spojeny pouze s lidskými zdroji potřebnými pro přípravu dat a nasazení postupu. Na druhou stranu postup přináší možnost optimalizace vzorkovací sítě, která umožní snížení celkových nákladů na vzorkování při zachování přesnosti určení půdních parametrů oproti tradičním vzorkováním na bázi pravidelné či náhodné sítě. V závislosti na přírodních podmínkách a stanovovaných půdních parametrech je tak možné uvažovat o snížení počtu vzorků a tedy i celkových nákladů na vzorkování v rozmezí 10–50 %. V závislosti na velikosti podniku se tak může jednat o úsporu v řádech desítek tisíc korun.

## SEZNAM POUŽITÉ SOUVISEJÍCÍ LITERATURY

- ADHIKARI, K. a A. E. HARTEMINK, 2015. Digital Mapping of Topsoil Carbon Content and Changes in the Driftless Area of Wisconsin, USA. *Soil Science Society of America Journal* [online]. 79(1), 155. ISSN 0361-5995. Dostupné z: doi:10.2136/sssaj2014.09.0392
- AN, Y., L. YANG, A. X. ZHU, C. QIN a J. J. SHI, 2018. Identification of representative samples from existing samples for digital soil mapping. *Geoderma* [online]. B.m.: Elsevier, 311, 109–119. ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2017.03.014
- BEN-DOR, E. a J. A. M. DEMATTÉ, 2015. Remote sensing of soil in the optical domains. *Land Resources Monitoring, Modeling, and Mapping with Remote Sensing*; Thenkabail, PS, Ed. 733–787.
- BEZDEK, J. C., 1973. Cluster validity with fuzzy sets. *Journal of Cybernetics* [online]. 3(3), 58–73. ISSN 00220280. Dostupné z: doi:10.1080/01969727308546047
- BEZDEK, J. C., 1981. Objective Function Clustering. In: *Pattern recognition with fuzzy objective function algorithms* [online]. Boston, MA: Springer US, s. 43–93. Dostupné z: doi:10.1007/978-1-4757-0450-1\_3
- BISWAS, A. a Y. ZHANG, 2018. Sampling Designs for Validating Digital Soil Maps: A Review. *Pedosphere* [online]. 28(1), 1–15. ISSN 10020160. Dostupné z: doi:10.1016/S1002-0160(18)60001-3
- BRODSKÝ, L., 2003. Využití geostatistických metod pro mapování prostorové variability agrochemických vlastností půd. ČZU v Praze, 120 s. B.m.: ISBN 80-213-1100-2.
- BRUS, D. J., J. J. DE GRUIJTER a J. W. VAN GROENIGEN, 2006. Chapter 14 Designing Spatial Coverage Samples Using the k-means Clustering Algorithm. In: *Digital Soil Mapping An Introductory Perspective* [online]. s. 183–192. ISBN 0166-2481. Dostupné z: doi:http://dx.doi.org/10.1016/S0166-2481(06)31014-8
- BRUS, D. J., 2010. Design-based and model-based sampling strategies for soil monitoring. In: *World Congress of Soil Science: Soil solutions for a ...* [online]. s. 32–34. Dostupné z: http://www.iuss.org/19th WCSS/Symposium/pdf/1309.pdf
- BRUS, D. J. a G. B. M. HEUVELINK, 2007. Optimization of sample patterns for universal kriging of environmental variables. *Geoderma* [online].

- 138(1–2), 86–95. ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2006.10.016
- BURROUGH, P. A., P. F. M. VAN GAANS a R. A. MACMILLAN, 2000. High-resolution landform classification using fuzzy k-means. *Fuzzy Sets and Systems* [online]. 113(1), 37–52. ISSN 01650114. Dostupné z: doi:10.1016/S0165-0114(99)00011-1
- CAMBULE, A. H., D. G. ROSSITER a J. J. STOOORVOGEL, 2013. A methodology for digital soil mapping in poorly-accessible areas. *Geoderma* [online]. 192(1), 341–353. ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2012.08.020
- CARTER, M. R. a E. G. GREGORICH, 2007. *Soil Sampling and Methods of Analysis, Second Edition* [online]. B. m.: CRC Press. ISBN 978-0-8493-3586-0. Dostupné z: doi:10.1201/9781420005271
- CARTER, M. a E. GREGORICH, 2014. *Soil sampling and methods of analysis*. ISBN 1420005278.
- CEBECI, Z., F. YILDIZ, A. T. KAVLAK, C. CEBECI. a H. ONDER, (2018). ppclust: Probabilistic and Possibilistic Cluster Analysis. R package version 0.1.1, URL <https://CRAN.R-project.org/package=ppclust>
- CHAPLOT, V., S. LORENTZ, P. PODWOJEWSKI a G. JEWITT, 2010. Digital mapping of A-horizon thickness using the correlation between various soil properties and soil apparent electrical resistivity. *Geoderma* [online]. 157(3–4), 154–164. ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2010.04.006
- COCHRAN, W. G., 1977. *Sampling techniques* [online]. B. m.: Wiley [vid. 2018-04-25]. ISBN 9780471162407. Dostupné z: <https://www.wiley.com/en-us/Sampling+Techniques%2C+3rd+Edition-p-9780471162407>
- DAVE, R. N., 1991. Characterization and detection of noise in clustering. *Pattern Recognition Letters* [online]. 12(11), 657–664. ISSN 01678655. Dostupné z: doi:10.1016/0167-8655(91)90002-4
- DE GRUIJTER, J. J., A. B. MCBRATNEY a J. TAYLOR, 2010. Sampling for High-Resolution Soil Mapping. In: *Proximal Soil Sensing* [online]. s. 3–14 [vid. 2018-11-28]. ISBN 9789048188598. Dostupné z: doi:10.1007/978-90-481-8859-8\_1
- DE GRUIJTER, J. J., M. F. P. BIERKENS, D. J. BRUS a M. KNOTTERS, 2006. *Sampling for Natural Resource Monitoring* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg. ISBN 978-3-540-22486-0. Dostupné z: doi:10.1007/3-540-33161-1

- DE GRUIJTER, J. J. a C. J.F. TER BRAAK, 1990. Model-free estimation from spatial samples: A reappraisal of classical sampling theory. *Mathematical Geology* [online]. B.m.: Kluwer Academic Publishers-Plenum Publishers, 22(4), 407–415. ISSN 08828121. Dostupné z: doi: 10.1007/BF00890327
- DINKINS, P. a C. JONES, 2008. *Soil Sampling Strategies*.
- EVANS, D. M. a Alfred E. HARTEMINK, 2014. Digital soil mapping of a red clay subsoil covered by loess. *Geoderma* [online]. 230–231, 296–304. ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2014.03.013
- FALK, M. G., R. J. DENHAM a K. L. MENGERSEN, 2011. Spatially stratified sampling using auxiliary information for geostatistical mapping. *Environmental and Ecological Statistics* [online]. 18(1), 93–108. ISSN 13528505. Dostupné z: doi:10.1007/s10651-009-0122-3
- FERGUSON, R. B. a G. W. HERGERT, 2009. *Soil Sampling for Precision Agriculture*.
- FERRARO, M. B., a P. GIORDANI, 2015. A toolbox for fuzzy clustering using the R programming language. *Fuzzy Sets and Systems* [online]. B.m.: North-Holland, 279, 1–16. ISSN 01650114. Dostupné z: doi:10.1016/j.fss.2015.05.001
- FLORINSKY, I. V., 2012. Digital terrain analysis in soil science and geology [online]. B.m.: Academic Press [vid. 2018-05-07]. ISBN 9780123850362. Dostupné z: <https://www.sciencedirect.com/science/book/9780123850362>
- FRANZEN, D. W., L. J. CIHACEK, V. L. HOFMAN a L. J. SWENSON, 1998. Topography-Based Sampling Compared with Grid Sampling in the Northern Great Plains. *jpa* [online]. B.m.: American Society of Agronomy, Crop Science Society of America, Soil Science Society of America, 11(3), 364. ISSN 0890-8524. Dostupné z: doi:10.2134/jpa1998.0364
- FRANZEN, D. W., T. R. PECK a R. G. HOEFT, 1993. Soil sampling for variable rate fertilization. In: *Proc. Illinois Fert. Conf.* s. 81–91.
- GEOPORTÁL ČÚZK [online]. Praha: ČÚZK, 2018. Dostupné z: <https://www.cuzk.cz/>
- GESSELER, P. E., I. D. MOORE, N. J. MCKENZIE a P. J. RYAN, 1995. Soil-landscape modelling and spatial prediction of soil attributes. *International Journal of Geographical Information Systems* [online]. 9(4), 421–432. ISSN 02693798. Dostupné z: doi: 10.1080/02693799508902047

- GILBERT, R. O. Statistical methods for environmental pollution monitoring. New York: Van Nostrand Reinhold Co., c1987. ISBN 0442230508.
- GHOLIZADEH, A., D. ŽIŽALA, M. SABERIOON a L. BORŮVKA, 2018. Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging. *Remote Sensing of Environment* [online]. 218, 89–103. ISSN 00344257. Dostupné z: doi: 10.1016/j.rse.2018.09.015
- GODWIN, R.J. a P.C.H. MILLER, 2003. A Review of the Technologies for Mapping Within-field Variability. *Biosystems Engineering* [online]. B.m.: Academic Press, 84(4), 393–407. ISSN 15375110. Dostupné z: doi:10.1016/S1537-5110(02)00283-0
- GRIFFIN, S. J., 1999. Directed soil sampling as a means of increasing nutrient map accuracy using complementary precision farming data. *Precision Agriculture*. 99, 141–149.
- GRIMM, R., T. BEHRENS, M. MÄRKER a H. ELSENBEEER, 2008. Soil organic carbon concentrations and stocks on Barro Colorado Island - Digital soil mapping using Random Forests analysis. *Geoderma* [online]. 146(1–2). ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2008.05.008
- HAINING, R. P., 2003. Spatial data analysis: theory and practice. B.m.: Cambridge University Press. ISBN 0511040857.
- HAMMOND, M. W., 1993. Cost analysis of variable fertility management of phosphorus and potassium for potato production in central Washington. In: *Proceedings of soil specific crop management*. B.m.: American Society of Agronomy, Crop Science Society of America, Soil Science Society of America, s. 213–228. ISBN 0891182616.
- HENDL, J. Přehled statistických metod: analýza a metaanalýza dat. Páté, rozšířené vydání. Praha: Portál, 2015. ISBN 978-80-262-0981-2.
- HENGL, T., D. G. ROSSITER a A. STEIN, 2003. Soil sampling strategies for spatial prediction by correlation with auxiliary maps. *Australian Journal of Soil Research* [online]. 41(8), 1403–1422. ISSN 00049573. Dostupné z: doi:10.1071/SR03005
- HEUVELINK, G. B. M., D. J. BRUS a J. J. De GRUIJTER, 2004. Optimization of sample configurations for digital soil mapping with universal kriging [online]. [vid. 2018-11-28]. Dostupné z: <https://library.wur.nl/WebQuery/wurpubs/335671>
- JAFARI, A., P. A. FINKE, J. VANDE WAUW, S. AYOUBI a H. KHADEMI, 2012.

- Spatial prediction of USDA- great soil groups in the arid Zarand region, Iran: Comparing logistic regression approaches to predict diagnostic horizons and soil types. *European Journal of Soil Science* [online]. 63(2), 284–298. ISSN 1 3510754. Dostupné z: doi:10.1111/j.1365-2389.2012.01425.x
- JONARD, F., M. MAHMOUDZADEH, C. ROISIN, L. WEIHERMÜLLER, F. ANDRÉ, J. MINET, H. VERECKEN a S. LAMBOT, 2013. Characterization of tillage effects on the spatial variation of soil properties using ground-penetrating radar and electromagnetic induction. *Geoderma* [online]. 207–208(1), 310–322. ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2013.05.024
- KIDD, D., B. MALONE, A. MCBRATNEY, B. MINASNY a M. WEBB, 2015. Operational sampling challenges to digital soil mapping in Tasmania, Australia. *Geoderma Regional* [online]. B.m.: Elsevier B.V., 4, 1–10. ISSN 23520094. Dostupné z: doi:10.1016/j.geodrs.2014.11.002
- LESCH, S. M., 2005. Sensor-directed response surface sampling designs for characterizing spatial variation in soil properties [online]. 2005. ISBN 0168-1699. Dostupné z: doi:10.1016/j.compag.2004.11.004
- LIESS, M, 2017a. Can conditioned Latin hypercube sampling capture pedodiversity? In: *Abstract Book Pedometrics 2017*. s. 138.
- LIESS, M., 2017b. Subsampling for dataset optimisation. In: *EGU General Assembly 2017* [online]. Vienna, Austria: EGU, s. 2175. Dostupné z: <http://meetingorganizer.copernicus.org/EGU2017/EGU2017-2175.pdf>
- LUKAS, V., 2009. METODY HODNOCENÍ VARIABILITY PŮDNÍCH PODMÍNEK JAKO PODKLAD PRO DIFERENCOVANÉ PROVEDĚNÍ PĚSTEBNÍCH ZÁSAHŮ. B.m. Mendelova zemědělská a lesnická univerzita.
- MALLARINO, A. P., D. B. BEEGLE a B. C. JOERN, 2006. Soil sampling methods for phosphorus-spatial concerns. A SERA-17 Position Paper, United States Department of Agriculture.
- MALLARINO, A. P. a D. J. WITTRY, 2004. Efficacy of Grid and Zone Soil Sampling Approaches for Site-Specific Assessment of Phosphorus, Potassium, pH, and Organic Matter. *Precision Agriculture* [online]. B.m.: Kluwer Academic Publishers, 5(2), 131–144. ISSN 1385-2256. Dostupné z: doi:10.1023/B:PRAG.0000022358.24102.1b
- MALLARINO, A. a D. WITTRY, 2001. Management zones soil sampling: A better alternative to grid and soil type sampling? the 13th Annual

- Integrated Crop Management [online]. 6. Dostupné z: [http://www.agronext.iastate.edu/soilfertility/info/ICM\\_2001\\_ZoneSampling\\_Publ.pdf](http://www.agronext.iastate.edu/soilfertility/info/ICM_2001_ZoneSampling_Publ.pdf)
- MALONE, B. P, B. MINASNY a A. B. MCBRATNEY, 2017. Using R for digital soil mapping [online]. ISBN 9783319443256. Dostupné z: doi: 10.1007/978-3-319-44327-0
- MCBRATNEY, A.B, M.L. MENDONÇA SANTOS a B. MINASNY, 2003. On digital soil mapping. *Geoderma* [online]. B.m.: Elsevier, 117(1–2), 3–52. ISSN 00167061. Dostupné z: doi:10.1016/S0016-7061(03)00223-4
- MCBRATNEY, A. B., B. M. WHELAN, D. J. J. WALVOORT a B. MINASNY, 1999. A purposive sampling scheme for precision agriculture. In: *Precision Agriculture'99: Proceedings of the 2nd European Conference on Precision Agriculture held in Odense Congress Centre, Denmark, 11-15 July 1999*/ed. by JV Stafford.-Sheffield Academic Press, 1999. s. 101–110.
- MCCOY, R. M., 2005. *Field Method in Remote Sensing*. ISBN 1593850794.
- MCKENZIE, N. J. a P. J. RYAN, 1999. Spatial prediction of soil properties using environmental correlation. *Geoderma* [online]. 89(1–2), 67–94. ISSN 00167061. Dostupné z: doi:10.1016/S0016-7061(98)00137-2
- MELOUN, M. a MILITKÝ, J. Přednosti analýzy shluků ve vícerozměrné statistické analýze. Zajištění kvality analytických výsledků: sborník přednášek ze semináře, 2004, 22.24.3.
- MINASNY, B. a A. B. MCBRATNEY, 2006. A conditioned Latin hypercube method for sampling in the presence of ancillary information. *Computers and Geosciences* [online]. 32(9), 1378–1388. ISSN 00983004. Dostupné z: doi:10.1016/j.cageo.2005.12.009
- MULDER, V. L., S. DE BRUIN a M. E. SCHAEPMAN, 2012. Representing major soil variability at regional scale by constrained Latin Hypercube Sampling of remote sensing data. *International Journal of Applied Earth Observation and Geoinformation* [online]. 21(1), 301–310. ISSN 15698432. Dostupné z: doi:10.1016/j.jag.2012.07.004
- NAWAR, S., R. CORSTANJE, G. HALCRO, D. MULLA a A. M. MOUAZEN, 2017. Delineation of Soil Management Zones for Variable-Rate Fertilization: A Review. In: *Advances in Agronomy* [online]. B.m.: Academic Press, s. 175–245. ISBN 9780128124215. Dostupné z: doi: 10.1016/bs.agron.2017.01.003
- ORTEGA, R. A. a O. A. SANTIBÁÑEZ, 2007. Determination of management zones in corn (*Zea mays* L.) based on soil fertility. *Computers and*

- Electronics in Agriculture [online]. B.m.: Elsevier, 58(1), 49–59. ISSN 01681699. Dostupné z: doi:10.1016/j.compag.2006.12.011
- PAVELKA, K. (2013) Letecké Laserové Skenování v ČR a Možnosti Využití dat Pro Dokumentaci Historické Těžby Nerostných Surovin.
- PIERCE, F. J. a P. NOWAK, 1999. Aspects of Precision Agriculture. In: Advances in Agronomy [online]. B.m.: Academic Press, s. 1–85. ISBN 9780120007677. Dostupné z: doi:10.1016/S0065-2113(08)60513-1
- PENÍŽEK, V., ZÁDOROVÁ T., KODEŠOVÁ R., KLEMENT, A. Optimalizace vzorkovací sítě pomocí využití analýzy reliéfu pro popis prostorové variability půdních vlastností v rámci půdních bloků: certifikovaná metodika. Praha: Česká zemědělská univerzita v Praze, 2014. ISBN 978-80-213-2533-3.
- POGGIO, L., A. GIMONA a M. J. BREWER, 2013. Regional scale mapping of soil properties and their uncertainty with a large number of satellite-derived covariates. Geoderma [online]. 209–210, 1–14. ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2013.05.029
- PROCHÁZKA, J., 2008. Metody fuzzy shlukové analýzy při modelování nelineárních systémů [online]. B.m. České vysoké učení technické v Praze. Dostupné z: [https://support.dce.felk.cvut.cz/mediawiki/images/f/f8/Bp\\_2008\\_prochazka\\_jan.pdf](https://support.dce.felk.cvut.cz/mediawiki/images/f/f8/Bp_2008_prochazka_jan.pdf)
- R CORE TEAM, 2017. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- RODEGHIERO, M. a A. CESCATTI, 2008. Spatial variability and optimal sampling strategy of soil respiration. Forest Ecology and Management [online]. B.m.: Elsevier, 255(1), 106–112. ISSN 03781127. Dostupné z: doi:10.1016/j.foreco.2007.08.025
- ROUDIER, P. clhs: a R package for conditioned Latin hypercube sampling. 2011.
- ROYLE, J. A. a D. NYCHKA, 1998. An algorithm for the construction of spatial coverage designs with implementation in SPLUS. Computers and Geosciences [online]. 24(5), 479–488 [vid. 2018-11-28]. ISSN 00983004. Dostupné z: doi:10.1016/S0098-3004(98)00020-X
- SÁŇKA, M, 1996. Vzorkování půd – technika, metody, řízení jakosti. Ústřední kontrolní a zkušební ústav zemědělský – Bulletin '96. IV(2), 27–37.
- SÄRNDAL, C. E., I. THOMSEN, J. M. HOEM, D. V. LINDLEY, O. BARNDORFF-NIELSEN a T. DALENIUS, 1978. Design-Based and Model-Based

- Inference in Survey Sampling [with Discussion and Reply]. *Scandinavian Journal of Statistics* [online]. B.m.: WileyBoard of the Foundation of the Scandinavian Journal of Statistics, 5(1), 27–52. ISSN 03036898. Dostupné z: doi:10.2307/4615682
- SUMNER, M. E. *Handbook of soil science*. Boca Raton, Fla: CRC Press, c2000. ISBN 0849331366.
- SUN, X. L., S. C. WU, H. L. WANG, Y. G. ZHAO, Y. ZHAO, G. L. ZHANG, Y. B. MAN a M. H. WONG, 2012. Uncertainty Analysis for the Evaluation of Agricultural Soil Quality Based on Digital Soil Maps. *Soil Science Society of America Journal* [online]. 76(4), 1379. ISSN 0361-5995. Dostupné z: doi:10.2136/sssaj2011.0426
- TAYLOR, J. a B. WHELAN, 2005. *A general introduction to precision agriculture*. Australian Center for Precision Agriculture.
- THOMAS, M, N. P. ODGERS, A. RINGROSE-VOASE, G. GREALISH, M. GLOVER a T. GOWLING, 2012. Soil survey design for management-scale digital soil mapping in a mountainous southern Philippine catchment. In: *Digital Soil Assessments and Beyond* [online]. B.m.: CRC Press, s. 233–238. ISBN 9780415621557. Dostupné z: doi:10.1201/b12728
- VAN GROENIGEN, J. W., W. SIDERIUS a A. STEIN, 1999. Constrained optimisation of soil sampling for minimisation of the kriging variance. *Geoderma* [online]. B.m.: Elsevier, 87(3–4), 239–259. ISSN 00167061. Dostupné z: doi:10.1016/S0016-7061(98)00056-1
- VAŠÁT, R., G. B. M. HEUVELINK a L. BORŮVKA, 2010. Sampling design optimization for multivariate soil mapping. *Geoderma* [online]. 155(3–4), 147–153. ISSN 00167061. Dostupné z: doi:10.1016/j.geoderma.2009.07.005
- VAŠÁT, R., L. BORŮVKA a O. JAKŠÍK, 2012. Number of sampling points influences the parameters of soil properties spatial distribution and kriged maps. *Digital Soil Assessments and Beyond*. 251–256.
- WACKERNAGEL, H., 2003. *Multivariate Geostatistics: An introduction with applications* [online]. B.m.: Springer Berlin Heidelberg. ISBN 978-3-662-03552-8. Dostupné z: doi:10.1111/ntwe.12079
- WALVOORT, D. J.J., D. J. BRUS a J. J. DE GRUIJTER, 2010. An R package for spatial coverage sampling and random sampling from compact geographical strata by k-means. *Computers and Geosciences* [online]. B.m.: Elsevier, 36(10), 1261–1267. ISSN 00983004. Dostupné z: doi:10.1016/j.cageo.2010.04.005

- WANG, J. F., R. HAINING a Z. CAO, 2010. Sample surveying to estimate the mean of a heterogeneous surface: reducing the error variance through zoning. *International Journal of Geographical Information Science* [online]. 24(4), 523–543. ISSN 1365-8816. Dostupné z: doi: 10.1080/13658810902873512
- WANG, J. F., A. STEIN, B. B. GAO a Y. GE, 2012. A review of spatial sampling. *Spatial Statistics* [online]. B.m.: Elsevier Ltd, 2(1), 1–14. ISSN 22116753. Dostupné z: doi:10.1016/j.spasta.2012.08.001
- WEBSTER, R. a Margaret A. OLIVER, 2007. *Geostatistics for environmental scientists*. B.m.: Wiley. ISBN 0470517263.
- WICKHAM, H., 2015. *Elegant Graphics for Data Analysis*. Media. B.m.: Springer, 35(July), 211. ISSN 0006341X. Dostupné z: doi:10.1007/978-0-387-98141-3
- WOLLENHAUPT, N.C., D.J. MULLA a C. A. GOTWAY CRAWFORD, 1997. Soil Sampling and Interpolation Techniques for Mapping Spatial Variability of Soil Properties. In: *The State of Site Specific Management for Agriculture* [online]. B.m.: American Society of Agronomy, Crop Science Society of America, Soil Science Society of America, s. 19–53. ISBN 978-0-89118-262-7. Dostupné z: doi: 10.2134/1997.stateofsitespecific.c2
- WORSHAM, L., D. MARKEWITZ, N. P. NIBBELINK a L. T. WEST, 2012. A comparison of three field sampling methods to estimate soil carbon content. *Forest Science* [online]. 58(5), 513–522. ISSN 0015749X. Dostupné z: doi:10.5849/forsci.11-084
- ŽÍŽALA, D., A. JUŘICOVÁ, T. ZÁDOROVÁ, K. ZELENKOVÁ a R. MINAŘÍK, 2018. Mapping soil degradation using remote sensing data and ancillary data: South-East Moravia, Czech Republic. *European Journal of Remote Sensing* [online]. 1–15 [vid. 2018-12-04]. ISSN 22797254. Dostupné z: doi:10.1080/22797254.2018.1482524
- ŽÍŽALA, D., T. ZÁDOROVÁ a J. KAPÍČKA, 2017. Assessment of Soil Degradation by Erosion Based on Analysis of Soil Properties Using Aerial Hyperspectral Images and Ancillary Data, Czech Republic. *Remote Sensing* [online]. 9(1), 28. ISSN 2072-4292. Dostupné z: doi: 10.3390/rs9010028
- ŽÍŽALA, D., J. KRÁSA, M. BÁČOVÁ, K. ZELENKOVÁ, T.LABURDA, a I. NOVOTNÝ, 2016. *Monitoring erozního poškození půd v ČR nástroji dálkového průzkumu Země. Certifikovaná metodika*. ISBN 978-80-87361-63-4.

## SEZNAM PUBLIKACÍ, KTERÉ PŘEDCHÁZELI METODICE

- GHOLIZADEH, A., D. ŽÍŽALA, M. SABERIOON a L. BORŮVKA, 2018. Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging. *Remote Sensing of Environment*. 218. 89–103. doi: 10.1016/j.rse.2018.09.015
- GHOLIZADEH, A., D. ŽÍŽALA, M. SABERIOON a L. BORŮVKA, 2018. Soil Organic Carbon and Clay Monitoring and Mapping using Airborne and Sentinel-2 Spectral Imaging. In: *Sixth International Conference on Remote Sensing and Geoinformation of Environment*. Aliathon: Cyprus Remote Sensing Society.
- HRABALÍKOVÁ, M., HUISLOVÁ P., J. UREŠ, D. ŽÍŽALA, O. HOLUBÍK A J. KUMHÁLOVÁ , 2017. Assessment of changes in topsoil depth redistribution in relation to different tillage technologies, *Advances in GeoEcology* 45; M. Zlatic and S. Kostadinov (eds): *Soil and water resources protection in the changing environment*; ISBN 978-3-510-65418-5 and US-ISBN 1-59326-267-1
- LUKAS, V., L. NEUDERT, F. ZEMEK, M. KRAUS a J. NOVÁK 2017. Využití dálkového průzkumu pro lokálně cílenou agrotechniku polních plodin. In: *Praktické využití GIS v lesnictví a zemědělství*. 2017. Mendelova univerzita v Brně. Brno
- ŽÍŽALA, D., A. JUŘICOVÁ, T. ZÁDOROVÁ, K. ZELENKOVÁ a R. MINAŘÍK, 2018. Mapping Soil Degradation using Remote Sensing Data and Ancillary Data - South-East Moravia, Czech Republic. *European Journal of Remote Sensing*. 1–15. doi: 10.1080/22797254.2018.1482524
- ZÁDOROVÁ, T., V. PENÍŽEK, D. ŽÍŽALA, J. MATĚJOVSKÝ A VANĚK, 2018. Influence of former lynchets on soil cover structure and soil organic carbon storage in agricultural land, Central Czechia. *Soil Use and Management*. 34 (1). 60–71. doi: 10.1111/sum.12406
- ŽÍŽALA, D., T. ZÁDOROVÁ a J. KAPIČKA, 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. doi: 10.3390/rs9010028
- ŽÍŽALA, D., J. KAPIČKA a I. NOVOTNÝ, 2016. Monitoring Soil Erosion of Agricultural Land in Czech Republic and Data Assessment of Erosion

- Events from Spatial Database. In: Proceedings from International Conference Soil - the non-renewable environmental resource. Brno, Czech Republic: Mendel University in Brno, s. 354–370.
- ŽÍŽALA, D., M. HRABALÍKOVÁ, A. JUŘICOVÁ, O. HOLUBÍK, P. HUISLOVÁ, I. NOVOTNÝ a J. VOPRAVIL, 2016: Mapy prostorového rozložení vybraných půdních charakteristik na erozně ovlivněných půdách –modelová lokalita Padělky, k.ú. Šardice. Praha: Výzkumný ústav meliorací a ochrany půdy, v.v.i.
- ŽÍŽALA, D. a K. ZELENKOVÁ, 2016. Mapa erozního poškození půd - černozemní oblast JV Moravy. Praha: Výzkumný ústav meliorací a ochrany půdy, v.v.i.
- ŽÍŽALA, D. a J. KRÁSA, 2016. Využití obrazových spektrálních dat při výzkumu eroze. In GIS LZE Mendelova univerzita Brno, 25. 2. - 26. 2., 2016. Sborník příspěvků z konference. ISBN 978-80-7509-414-8
- ŽÍŽALA, D. 2016. Využití obrazové spektroskopie při hodnocení erozního poškození půd. In Pedologické dni 2016 - Poda v krajine, jej význam, postavenie a zraniteľnosť, Dudince, 7. 9. - 9. 9., 2016. Zborník abstraktov. ISBN 978-80-8163-017-0



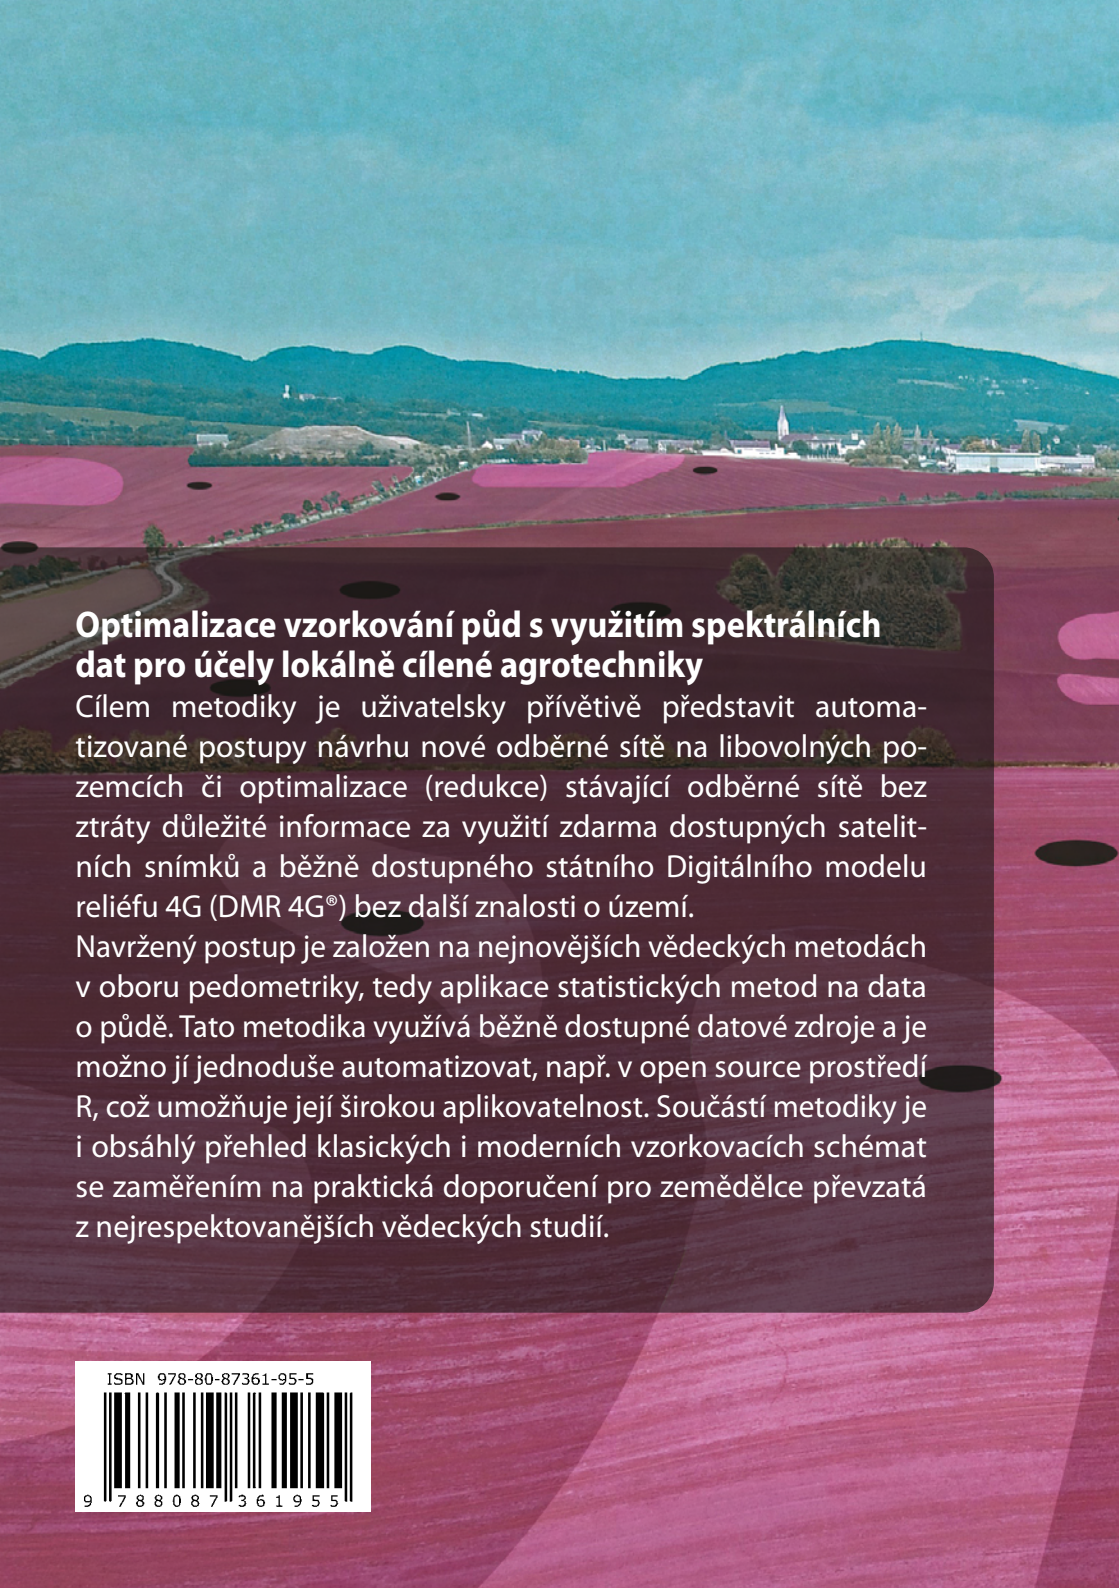
Název metodiky	<b>Optimalizace vzorkování půd s využitím spektrálních dat pro účely lokálně cílené agrotechniky</b>
Autorský kolektiv	Robert Minařík, Daniel Žížala, Vojtěch Lukas, Michal Kraus
Editor	Daniel Žížala
Rok vydání	2018
Vydání	1. vydání
Vydal	Výzkumný ústav meliorací a ochrany půdy, v.v.i.
Tisk	Powerprint s.r.o., Praha 6 – Suchbátka
Grafická úprava	Daniel Žížala
Rozsah	82 stran
Náklad	50 ks
ISBN	978–80–87361–95–5

### Doporučená citace metodiky

Minařík, R., Žížala D., Lukas, V., Kraus, M.: Optimalizace vzorkování půd s využitím spektrálních dat pro účely lokálně cílené agrotechniky. Certifikovaná metodika, VÚMOP, v.v.i., Praha, 2018, ISBN: 978–80–87361–95–5

### Ilustrace

obálka	krajina Mělnická – stylizovaný mapový podklad – management zóny a vzorkovací síť (D. Žížala)
str. 4	výřez scény družice Sentinel-2 v pravých barvách – okolí Ždánického lesa (Copernicus Sentinel data 2018, ESA)
str. 6	snímek holé půdy (D. Žížala)
str. 8	stylizace podrobného vzorkovacího schématu (D. Žížala - podklad archivní ortofotomapa © ČÚZK)
str. 11	pole s obilninou (D. Žížala)
str. 18	výřez scény družice Sentinel-2 v nepravých barvách (Copernicus Sentinel data 2018, ESA)
str. 30	výřez scény družice Sentinel-2 v nepravých barvách (Copernicus Sentinel data 2018, ESA)
str. 52	hyperspektrální letecký snímek v nepravých barvách (CzechGlobe)
str. 62	snímek z družice Worldview-2 v nepravých barvách (DigitalGlobe)
str. 66	zemědělská krajina v okolí Šardic (D. Žížala)
str. 68-69	krajina Mělnická – stylizovaný mapový podklad – management zóny a vzorkovací síť (D. Žížala)
str. 81	výřez scény družice Sentinel-2 v pravých barvách (Copernicus Sentinel data 2018, ESA)



## Optimalizace vzorkování půd s využitím spektrálních dat pro účely lokálně cílené agrotechniky

Cílem metodiky je uživatelsky přívětivě představit automatizované postupy návrhu nové odběrné sítě na libovolných pozemcích či optimalizace (redukce) stávající odběrné sítě bez ztráty důležité informace za využití zdarma dostupných satelitních snímků a běžně dostupného státního Digitálního modelu reliéfu 4G (DMR 4G<sup>®</sup>) bez další znalosti o území.

Navržený postup je založen na nejnovějších vědeckých metodách v oboru pedometriky, tedy aplikace statistických metod na data o půdě. Tato metodika využívá běžně dostupné datové zdroje a je možno jí jednoduše automatizovat, např. v open source prostředí R, což umožňuje její širokou aplikovatelnost. Součástí metodiky je i obsáhlý přehled klasických i moderních vzorkovacích schémat se zaměřením na praktická doporučení pro zemědělce převzatá z nejrespektovanějších vědeckých studií.

ISBN 978-80-87361-95-5



9 788087 361955