

**Univerzita Palackého v Olomouci**

**Přírodovědecká fakulta**

**Katedra geoinformatiky**

**IDENTIFIKACE KOMÁŘÍCH TŮNÍ  
S VYUŽITÍM OPTICKÝCH A LASEROVÝCH DAT**

**Bakalářská práce**

**autor**

**Dominik VLASÁK**

Vedoucí práce

**RNDr. Jakub Miřijovský, Ph. D.**

**Olomouc 2024**

**Geoinformatika a kartografie**

# **ANOTACE**

Bakalářská práce si klade za cíl otestovat a vytvořit efektivní metodiku pro identifikaci komářích luhů z dat dálkového průzkumu Země. Jedná se jednak o optická data z leteckého snímání pořízena v kanálech RGB (červené, zelené a modré), jednak o data z laserového skenování (LiDAR) a optická data v blízkém infračerveném pásmu (NIR). V práci je uvedena rešerše aktuálních poznatků řešené problematiky. Dále je prostor věnován charakteristice zkoumaného území CHKO Litovelské Pomoraví a rozboru vlastností komářích luhů pro možnosti identifikace. Stěžejní část práce je zaměřena na vlastní postup zpracování dat a tvorby efektivního pracovního postupu pro identifikaci komářích luhů za pomoci zmíněných nástrojů. Představená metodika slouží pro využití v oblastech lužních lesů. Dílčí část práce je věnována testování limitů jednotlivých vstupních dat pro potřeby identifikace komářích luhů. V diskuzi je rozebrán potenciál dalšího výzkumu v tomto oboru a využití multispektrálních dat.

## **KLÍČOVÁ SLOVA**

LiDAR data; optická data, deprese, komáří luh, CHKO Litovelské Pomoraví

Počet stran práce: 51

Počet příloh: 12 (z toho 1 volná a 11 uložených na externím úložišti)

## **ANOTATION**

*The bachelor theses aims to develop an efficient methodology for identifying mosquito breeding sites from remote sensing data. The method is based on optical data from aerial photography taken in RGB (red, green, and blue) channels, laser scanning data (LiDAR), and optical data in the near-infrared (NIR). Furthermore, space is devoted to the characteristics of the studied area of the Litovelské Pomoravi Protected Landscape Area (PLA) and to the analysis of mosquito hatchery characteristics for identification possibilities. The main part of the work is focused on the actual procedure of data processing, and development of an effective workflow for the identification of mosquito breeding sites using the mentioned tools. The methodology presented is for use in floodplain forest areas. Part of the thesis is devoted to testing the limits of individual input data for the identification of mosquito hatcheries. The potential for further research in this field and the use of multispectral data is discussed in the discussion section.*

## **KEYWORDS**

LiDAR data; optical data, depressions, mosquito breeding grounds, Litovelské Pomoravi Protected Landscape Area

Number of pages 51

Number of appendixes: 12

**Prohlašuji, že**

- bakalářskou/diplomovou práci včetně příloh, jsem vypracoval samostatně a uvedl jsem všechny použité podklady a literaturu.

- jsem si vědom, že na moji bakalářskou/diplomovou práci se plně vztahuje zákon č.121/2000 Sb. - autorský zákon, zejména § 35 – využití díla v rámci občanských a náboženských obřadů, v rámci školních představení a využití díla školního a § 60 – školní dílo,

- beru na vědomí, že Univerzita Palackého v Olomouci (dále UP Olomouc) má právo nevydělečně, ke své vnitřní potřebě, bakalářskou/diplomovou práci užívat (§ 35 odst. 3),

- souhlasím, že údaje o mé bakalářské/diplomové práci budou zveřejněny ve Studijním informačním systému UP,

- v případě zájmu UP Olomouc uzavřu licenční smlouvu s oprávněním užití výsledky a výstupy mé bakalářské/diplomové práce v rozsahu § 12 odst. 4 autorského zákona,

- použít výsledky a výstupy mé bakalářské/diplomové práce nebo poskytnout licenci k jejímu využití mohu jen se souhlasem UP Olomouc, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly UP Olomouc na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Olomouci 7. srpna 2024

Dominik Vlasák

Bakalářská práce byla vypracována v rámci projektu číslo: 3211100011 s názvem „MOSPREMA: Predikce a management kalamitních stavů komárů pro zachování biodiverzity v lužních lesích“, který byl řešen na Katedře geoinformatiky UP Olomouc.

Děkuji vedoucímu práce RNDr. Jakubu Miřijovskému, Ph. D. za trpělivost, vstřícnost a v neposlední řadě za poskytnuté podněty a připomínky při vypracování práce. Dále děkuji mým rodinným příslušníkům a přátelům, kteří mi byli nezpochybnitelnou podporou při procesu zpracování práce.

# UNIVERZITA PALACKÉHO V OLOMOUCI

Přírodovědecká fakulta  
Akademický rok: 2021/2022

## ZADÁNÍ BAKALÁŘSKÉ PRÁCE

(projektu, uměleckého díla, uměleckého výkonu)

Jméno a příjmení: **Dominik VLASÁK**  
Osobní číslo: **R200215**  
Studijní program: **B0532A330011 Geoinformatika a kartografie**  
Téma práce: **Identifikace komářích tůní s využitím laserových a optických dat**  
Zadávací katedra: **Katedra geoinformatiky**

### Zásady pro vypracování

Cílem práce je otestovat a stanovit postupy pro identifikaci komářích lůhnišť s využitím laserových a optických dat. Student se bude podílet na vybraných leteckých kampaních s laserovým skenerem a na fotogrammetrickém snímování ve viditelném i v blízkém infračerveném pásmu. Měřená data zpracuje do podoby několika datových sad digitálních modelů terénu a ortofoto mozaiek. Následně provede analýzu dat s cílem stanovit možnosti a limity jednotlivých sad pro identifikaci lůhnišť. Budou testovány různé faktory, které ovlivňují kvalitu identifikace (stíny, olistění atd.). Práce bude prováděna na území CHKO Litovelské Pomoraví a v blízkém okolí.

Celá práce (text, přílohy, výstupy, zdrojová a vytvořená data) se odevzdá v digitální podobě na paměťovém nosiči (CD, DVD, SD karta, flash disk). Text práce s vybranými přílohami bude odevzdán ve dvou svázaných výtiscích na sekretariát katedry. O diplomové práci student vytvoří webovou stránku v souladu s pravidly dostupnými na stránkách katedry. Práce bude zpracována podle zásad dle Voženílek (2002) a závazné šablony pro diplomové práce na KGI. Povinnou přílohou práce bude poster formátu A2.

Rozsah pracovní zprávy: **max. 50 stran**  
Rozsah grafických prací: **dle potřeby**  
Forma zpracování bakalářské práce: **elektronická**

### Seznam doporučené literatury:

ZEMEK, František. Letecký dálkový průzkum Země: teorie a příklady hodnocení terestrických ekosystémů. Centrum výzkumu globální změny AV ČR, 2014.  
Pavelka, K. (2002). Fotogrammetrie 10, 2.přepřac. vyd. Praha: FSv ČVUT, 198 s.  
CAMPBELL, J., B., WYNNE, R. H. Introduction to Remote Sensing. 5th ed. Guilford Press, New York, 667 s., 2011.  
Voženílek, V. (2002): Diplomové práce z geoinformatiky. Vydavatelství Univerzity Palackého, Olomouc, UP, 31 s.

Vedoucí bakalářské práce: **RNDr. Jakub Miřijovský, Ph.D.**  
Katedra geoinformatiky

Datum zadání bakalářské práce: 5. května 2022

Termín odevzdání bakalářské práce: 9. května 2024

LS.

---

doc. RNDr. Martin Kubala, Ph.D.  
děkan



---

prof. RNDr. Vilém Pechanec, Ph.D.  
vedoucí katedry

# OBSAH

<b>SEZNAM POUŽITÝCH ZKRATEK .....</b>	<b>10</b>
<b>ÚVOD .....</b>	<b>11</b>
<b>1 CÍLE PRÁCE .....</b>	<b>12</b>
<b>2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY .....</b>	<b>13</b>
2.1 KOMÁROVITÍ PŘENÁŠEJÍCÍ ZÁVAŽNÉ NEMOCI V ČR .....	14
2.1.1 Komáří druhy v CHKO Litovelské Pomoraví .....	14
2.2 ŽIVOTNÍ CYKLUS KOMÁROVITÝCH ( <i>CULICIDAE</i> ) .....	15
2.3 ÚZEMNÍ VYMEZENÍ ZKOUMANÉ OBLASTI .....	17
2.4 VEGETAČNÍ KRYT ZKOUMANÉ OBLASTI .....	17
2.5 PŮDNÍ CHARAKTERISTIKY ZKOUMANÉ OBLASTI .....	18
2.6 KLIMATICKÉ PODMÍNKY ZKOUMANÉ OBLASTI .....	18
2.7 PERIODICKÉ TŮNĚ .....	19
2.7.1 Vznik a charakteristiky periodických tůní .....	19
2.8 PROJEKT MOSPREMA .....	20
2.9 STUDIE ZABÝVAJÍCÍ SE OBDOBNÝM TÉMATEM .....	20
2.9.1 Studie zpracované v České republice .....	20
2.9.2 Vybrané studie zpracované v zahraničí .....	21
<b>3 METODY A POSTUP ZPRACOVÁNÍ .....</b>	<b>24</b>
3.1 Identifikace komářích tůní pomocí laserových dat .....	24
3.1.1 Lidar: A Python package (Wu et al., 2019) .....	24
3.1.2 Identifikace na základě vygenerovaných kontur .....	25
3.1.3 Vlastní metoda identifikace depresí .....	26
3.2 Identifikace komářích tůní pomocí optických dat .....	27
3.2.1 Simple methodology for water data extraction using QGIS .....	27
3.2.2 Řízená klasifikace Random Forest .....	27
3.2.3 Klasifikace Support Vector Machine .....	28
3.3 Použitá data .....	29
3.4 Software pro zpracování metod .....	31



<b>4</b>	<b>VLASTNÍ ŘEŠENÍ I</b> .....	<b>32</b>
4.1	Identifikace depresí z laserových dat.....	32
4.1.1	Identifikace pomocí balíčku lidar .....	32
4.1.2	Identifikace pomocí Contour Tree Tools Public (Wu et al., 2018) .....	37
4.1.3	Identifikace spojením metod Wu2 a vlastního řešení.....	38
4.2	Porovnání dat z dronu a letadla .....	41
4.3	Fyzické zaměřování depresí .....	41
4.4	Identifikace komářích tůní z optických dat .....	44
4.4.1	Klasifikace pomocí prahování rastru NDWI .....	45
4.4.2	Klasifikace pomocí metody Random Forest.....	45
4.4.3	Klasifikace pomocí metody Support Vector Machine .....	47
4.4.4	Interpretace výsledků testovaných metod .....	48
4.5	Testování limitů dat .....	49
4.5.1	Testování limitů optických dat .....	49
4.5.2	Testování limitů laserových dat.....	51
<b>5</b>	<b>VLASTNÍ ŘEŠENÍ II</b> .....	<b>54</b>
<b>6</b>	<b>VÝSLEDKY</b> .....	<b>56</b>
<b>7</b>	<b>DISKUZE</b> .....	<b>58</b>
7.1	Problematika identifikace pomocí laserových dat .....	58
7.2	Problematika identifikace pomocí optických dat.....	58
<b>8</b>	<b>ZÁVĚR</b> .....	<b>60</b>
	<b>POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE</b>	
	<b>PŘÍLOHY</b>	

## SEZNAM POUŽITÝCH ZKRATEK

<b>Zkratka</b>	<b>Význam</b>
AOPK ČR	Agentura ochrany přírody a krajiny ČR
DMP	digitální model povrchu
DMR	digitální model reliéfu
DPZ	dálkový průzkum Země
GIS	geografický informační systém
GPS	Global Positioning System
GPX	GPS exchange format
CHKO	chráněná krajinná oblast
IDW	Inverse Distance Weighted
INS	inerciální navigační systém
LAS	nativní formát laserových dat
LiDAR	Light Detection and Ranging
LST	Land Surface Temperature index
ML	machine learning
NIR	near-infrared
NDBI	Normalized Difference Built-up Index
NDMI	Normalized Difference Moisture Index
NDSI	Normalized Difference Snow Index
NDVI	Normalized Differential Vegetation Index
NDWI	Normalized Difference Water Index
RGB	red, green, blue
SHP	Shapefile
SVM	Support Vector Machine
UAV	unmanned aerial vehicle
ZABAGED	Základní báze geografických dat

# ÚVOD

Negativní dopad existence komářích druhů reflektují data IDPH (Illinois Department of Public Health) a ECDPC (European Centre for Disease Prevention and Control). Komáři a nemoci, které šíří, mají na svědomí více lidských obětí než všechny války v posledních dvou stoletích. I dnes komáři přenášející malárii každoročně zabijí 1-3 miliony lidí a nakazí dalších nejméně 200 milionů jedinců. Komár je schopen přenášet virem infikovanou krev, nebo svým tělem slouží jako hostitel různých parazitů. Mezi nejnebezpečnější nemoci přenášené druhy komárů patří malárie, horečka dengue a virus zika. (Danasekaran et al. 2014)

V roce 2015 zemřelo pouze na následky malárie 438 000 lidí. Nemoci přenášené komárovitými druhy způsobují zdravotní újmu hospodářským zvířatům, čímž působí i finanční škody hospodářům. Kvůli klimatickým změnám, převážně zvyšování průměrných teplot, se dostávají do mírného klimatického pásu druhy komárů přenášející smrtelné nemoci původní pro tropické oblasti světa. Výjimkou není CHKO Litovelské Pomoraví, které je významně postiženo přemnožením komárů díky lužním lesům, které svým charakterem tvoří ideální habitat pro komáři reprodukci a existenci.

Obyvatelé přilehlých měst a obcí jsou téměř každoročně vystavováni život nepříjemnější přítomnosti stovek komárů, kteří omezují jejich životy a ohrožují jejich zdraví. Hubení komáři populace zde probíhá pomocí plošného aplikování chemických látek insekticidů, které mají častokrát devastující dopad na životní prostředí. Tím, že se tyto látky po aplikaci dostávají do půdy a vody, sekundárně hubí i další živočichy a rostliny. Stovky milionů lidí jsou globálně vystaveny působení pesticidů, a to především v zemědělství. Ročně trpí otravou pesticidy více než 26 milionů lidí a téměř 220 000 z nich zemře (Ansari et al., 2014). Z těchto důvodů je důležitá prostorově přesná identifikace komářích lůhnišť pro lokální aplikaci postřiku. Zde nacházejí využití nástroje dálkového průzkumu Země, konkrétně letecké snímkování a snímkování drony.

Identifikace pomocí optických a laserových dat byla testována na katedře Geoinformatiky a kartografie Univerzity Palackého v Olomouci v diplomové práci *Identifikace a prostorové analýzy komářích lůhnišť v CHKO Litovelské Pomoraví* (Šulc, 2018). V této práci byla pro identifikaci použita výškopisná data z datové sady DMR 5G (digitální model reliéfu 5. generace) a letecké ortofotografie v barevných kanálech RGB. Výškopisná datová sada DMR 5G představuje digitální formu záznamu zemského reliéfu v České republice s prostorovým rozlišením 2 m/px. Tento model zachycuje stav reliéfu z let 2011 až 2012. V případě této bakalářské práce byl výzkum metodiky identifikace komářích lůhnišť proveden na dvou detailních a aktuálních datových sadách laserových dat (LiDAR) nasnímaných na jaře 2023. První z nich s prostorovým rozlišením 50 cm/px, druhá z nich s prostorovým rozlišením 10 cm / px. Při leteckém snímkování území CHKO Litovelské Pomoraví byla použita kamera se snímačem pro blízké infračervené pásmo (NIR), čímž byly rozšířeny možnosti klasických RGB snímků pro identifikaci komářích lůhnišť.

Kombinací těchto dat byla v rámci této bakalářské práce vytvořena metodika identifikace komářích lůhnišť, která je způsobilá sloužit jako nástroj pro management přemnožení komárů se sníženým dopadem na životní prostředí.

# 1 CÍLE PRÁCE

Cílem práce bylo otestovat a stanovit postupy pro identifikaci komářích láníšť s využitím laserových a optických dat. Měřená data byla zpracována do podoby několika datových sad digitálních modelů terénu a ortofoto mozaik. Následně byla provedena analýza dat s cílem stanovit možnosti a limity jednotlivých sad pro identifikaci láníšť. Byly testovány různé faktory, které ovlivňují kvalitu identifikace (stíny, olístění a další.). Zájmovým územím výzkumu bakalářské práce bylo CHKO Litovelské Pomoraví a jeho blízké okolí.

Autor práce nebyl schopen se podílet na vybraných leteckých kampaních s laserovým skenerem a na fotogrammetrickém snímkování ve viditelném i v blízkém infračerveném pásmu.

Stěžejním cílem práce bylo vytvoření metodiky identifikace komářích láníšť jako souboru doporučení a výsledků testování způsobů identifikace komářích láníšť za pomoci různých konfigurací dat (Tabulka 1). Zmíněná metodika je obsažena v textu bakalářské práce.

Tabulka 1: Přehled a vlastnosti zpracovávaných dat poskytnutých v rámci projektu Mosprema

	<b>Celoplošné laserové skenování</b>	<b>Doplňkové laserové skenování</b>	<b>Optické skenování</b>
<b>Minimální počet bodů na 1 m<sup>2</sup></b>	8	20	-
<b>Snímaná EM spektra</b>	-	-	RGB + NIR
<b>Výsledný produkt</b>	DMR, DMP	DMR, DMP	ortofotomozaika
<b>Klasifikace</b>	kategorie LAS ASPRS	-	-
<b>Prostorové rozlišení 1 px ve skutečnosti</b>	≤ 50 cm	≤ 30 cm	8 cm
<b>Formát dat</b>	LAS	LAS	TIFF + TFW, GEOTIFF
<b>Formát rastrové reprezentace</b>	TIFF + TFW, GEOTIFF	GEOTIFF	GEOTIFF

Výsledná metodika a zpracovaná data naleznou své uplatnění jako efektivní návrh řešení identifikace komářích láníšť za využití dronů a leteckého snímkování. Porovnání různých konfigurací dat může přinést odpovědi i na ekonomické otázky v plánování projektu managementu komářích kalamit.

Obdobným tématem se v České republice zabývá již několik prací. Jedinečnost této práce tkví ve využití laserových i optických dat ve vysokém rozlišení a podrobnějším rozboru použitelnosti jednotlivých datových konfigurací. Snahou autora není vyrovnat se rozsahu a přínosu diplomových prací či prací tvořených týmy vědeckých pracovníků.

## 2 SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

Management komářích populací není novou oblastí zájmu v 21. století. Zmínky o plošném hubení komárů za pomoci chemikálií jsou datovány až do začátku druhé poloviny 19. století. Ve Spojených státech amerických dochází po občanské válce k mohutnému hospodářskému rozvoji, který se dotkl i zemědělského sektoru. V roce 1867 američtí farmáři zjistili, že petrolej je účinnou látkou pro hubení komárů líhnoucích se ve vodních korytech. Ve Spojených státech se petrolej začal hojně používat a v roce 1892 schválilo Ministerstvo zemědělství Spojených států petrolej jako prostředek k hubení komárů. (Patterson, 2016)

Na přelomu 19. a 20. století bylo zjištěno, že existuje příčinná souvislost mezi komáry a takovými nemocemi, jako je horečka dengue, malárie, žlutá zimnice a západonilský virus. Zásadní změna přišla v roce 1939, kdy švýcarský vědec vyvinul nový pesticid, dichlordifenyltrichlorethan (DDT). Podle Agentury pro ochranu životního prostředí začala vláda a armáda používat dichlordifenyltrichlorethan koncem roku 1940 a do konce 50. let 20. století jej armáda hojně používala k hubení komárů, což následně pomohlo snížit výskyt malárie (History of mosquito control, 2017).

S vývojem výpočetních technologií, vědeckých nástrojů v oboru biologie, chemie a v neposlední řadě nástrojů GIS a dálkového průzkumu Země, se management komářích líhnišť stal v průběhu 20. a 21. století komplexní disciplínou. Multidisciplinární týmy vědců, inženýrů, úředníků a pracovníků z neziskových organizací se podíleli na vývoji systému integrované ochrany proti komárům (Integrated Mosquito Management , dále jen IMM), jimž předcházela již zmíněná mechanická a chemická éra hubení komárů (Patterson, 2016). IMM využívá kombinaci metod prevence a kontroly komárů, kteří šíří viry, jako je západonilská horečka, dengue a další. Odborníci na kontrolu komárů provádějí dohled nad komáry, odstraňují místa, kde komáři kladou vajíčka, kontrolují larvy a kukly komárů, kontrolují dospělé komáry a monitorují důsledky svých opatření. Obecně se systémy IMM skládají ze 3 základních pilířů:

- 1) Odstranění komářích stanovišť,
- 2) Kontrolu komárů v larválním stádiu,
- 3) Kontrolu dospělých komárů.

Nástroje GIS se uplatňují ve všech pilířích IMM. Využívají se pro mapování, prostorové analýzy či prostorovou predikci vývoje komářích populací. Dálkový průzkum Země nachází uplatnění zejména v části odstraňování komářích stanovišť. Komáři líhniště je nejprve nutné identifikovat. V případě nevyužití digitálních technologií a dat se jedná o velmi zdoluhavý a náročný proces, v některých situacích dokonce neproveditelný v plném rozsahu. V urbánním prostředí využívají komáři pro kladení svých larev nejen různých vodních ploch na zemském povrchu, ale převážně otevřených nádob antropogenního původu – kontejnerů, barelů – které jsou schopné dlouhodobě zadržovat vodu. Bez detailních leteckých nebo satelitních snímků, je identifikace těchto potenciálních míst pro komáři reprodukci téměř nereálná. Přírodní prostředí může být svým charakterem nedostupné, čímž je fyzická identifikace komářích tůní opět znemožněna. Kombinace optických snímků a digitálního modelu reliéfu či povrchu je vhodným nástrojem pro plošnou identifikaci komářích líhnišť. Při znalosti zkoumaného prostředí a charakteristik komářích líhnišť jsou limity této metody identifikace sníženy a metodika může sloužit nejen pro určení stávajících komářích stanovišť, ale i pro označení potenciálních míst pro vznik komářích tůní.

Tato bakalářská práce se zabývá identifikací komářích líhnišť v oblasti CHKO Litovelské Pomoraví a přilehlých obcích. Z toho důvodu jsou v následujících

subkapitolách kromě aktuálního stavu problematiky identifikace pomocí optických a laserových dat rozebrána témata vegetačních, půdních, hydrologických a meteorologických podmínek zkoumané oblasti. Prostor je zde věnován i charakteristikám komářích lůhnišť, životnímu cyklu komárovitých druhů, jevu periodických tůní a v neposlední řadě projektu *Mosprema*, jehož je tato bakalářská práce součástí.

## 2.1 KOMÁROVITÍ PŘENÁŠEJÍCÍ ZÁVAŽNÉ NEMOCI V ČR

Čeleď komárovitých (Culicidae) obsahuje celosvětově přes 3 000 druhů komárů. V České republice je monitorováno 45 druhů komárovitých. Ačkoliv se globálně jedná o z epidemiologického hlediska nejvíce nebezpečného členovce, který je největším přenašečem viru dengue, viru zika, malárie, japonské encefalitidy, dirofilariózy, žluté zimnice či horečky chikungunya, v České republice se případy výskytu onemocnění přenášených komáry vyskytují ojediněle. Z celosvětového hlediska 90 % evidovaných případů nakažení jednou z chorob přenášených komáři patří do geograficky pod africký kontinent. (WHO, 2020)

Nejsmrtelnější infekční nemoc malárie, vyskytující se na Jižní Moravě až do 50. let 20. století, byla po Druhé světové válce eliminována, od té doby nebyl v České republice hlášeno žádné nakažení malárií po kousnutí komára na území republiky. Globálně rozšířeným virem se stal virus západonilské horečky, jehož přenašeči jsou kromě některých ptáků komáři rodu *Culex*. Od roku 2014 byl na území České republiky (Jižní Moravy a Jižních Čech) přenašeči *Culex modestus* a *Culex pipiens* potvrzen u komárů výskyt nejvíce virulentní linie západonilské horečky. Přestože člověk není primárním hostitelem pro tento rod komárů, byly v roce 2018 zaznamenány první případy onemocnění tímto virem.

Nejaktuálnější data výskytu jednotlivých druhů komárů z března 2022 jsou zprostředkována z projektu *VectorNet* pod záštitou Evropského centra pro prevenci a kontrolu nemocí (ECDC) a Evropského úřadu pro bezpečnost potravin (EFSA). Cílem je přispět ke zlepšení připravenosti a reakceschopnosti na nemoci přenášené vektory, a to na základě přístupu. Síť *VectorNet* podporuje shromažďování údajů o vektorech a patogenech v přenašečích, které se týkají zdraví zvířat i lidí. Kromě druhu *Anopheles plumbeus* je výskyt zmíněných druhů v České republice potvrzen Agenturou ochrany přírody a krajiny ČR (AOPK ČR) v Nálezové databázi ochrany přírody (ND OP).


### 2.1.1 Komáři druhy v CHKO Litovelské Pomoraví

Diplomová práce *Společenstva komárovitých (Diptera: Culicidae) na vybraných lokalitách CHKO Litovelské Pomoraví* (Válová, 2011) dokládá přítomnost celkem 31 druhů čeledi *Culicidae* v celé oblasti CHKO Litovelské Pomoraví. Nejdominantnějším druhem byl zjištěn *Aedes vexans* (21,91% z celého vzorku odchycených jedinců, 653/2938). Dalšími dominantními druhy jsou *Ochlerotatus cantans*, *Ochlerotatus communis*, *Ochlerotatus cataphylla* a *Ochlerotatus sticticus*. Výzkum byl uskutečněn v letech, kdy proběhla jarní i letní kalamitní situace. Existenci zmíněných druhů potvrzuje i Chmelíková ve své práci *Diverzita a biologie komárů podčeledi Culicinae ve vybraných tůních CHKO Litovelské Pomoraví*, kde jsou v rámci rešeršní části shrnuty všechny české zdroje ohledně problematiky druhové skladby komárů od roku 1971. Dle Krajské hygienické stanice Olomouckého kraje v Olomouci (KHS) se komáři populace v CHKO Litovelské Pomoraví již téměř 50 let nezměnila, a proto je možné čerpat i ze starších zdrojů, jako je

například *Komáři kalamitních oblastí Horní Moravy a Dolní Bečvy (Diptera:Culicidae)* (Lauterer a Chmela, 1971).

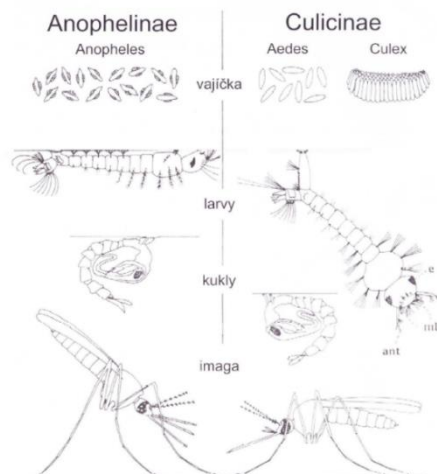
## 2.2 ŽIVOTNÍ CYKLUS KOMÁROVITÝCH (CULICIDAE)

Znalost životního cyklu komárovitých (Culicidae) je nezpochybnitelně nutná pro utváření správného konceptu managementu komářích kalamit. Jedním z ekologicky šetrných způsobů regulace komářích populací je používání regulátorů růstu hmyzu (Insect Growth Regulators IGR). Jsou to sloučeniny napodobující hormony, které ovlivňují růst a vývoj hmyzu (Tunaz et al., 2004). Tyto sloučeniny obvykle kontrolují hmyz buď prostřednictvím regulace metamorfózy zajišťující nevyvíjení reprodukčních dospělců; nebo interferencí s reprodukcí, což vede k vývoji sterilních nebo abnormálních dospělců s určitými morfogenetickými anomáliemi, které ovlivňují jejich vývoj (Riddiford a Truman, 1978).



Obr. 1 Schéma vývoje čeledi Culicidae (Zdroj: autorská tvorba)

Všichni komáři potřebují k dokončení svého životního cyklu vodu, i když některé druhy vyžadují jen velmi málo vody a mohou se vyvíjet v tenké vrstvě vlhkosti. Životní cyklus komárů je příkladem úplné metamorfózy. V životě komára existují čtyři odlišná stádia: vajíčko, larva, kukla, a dospělý jedinec (viz Obr. 1). Stejně jako u většiny hmyzu, který prochází kompletní metamorfózou, i u komárů se vývojová stádia od sebe výrazně liší. Jejich život začíná v malých vajíčkách, která samičky komárů kladou obvykle několik



Obr. 2 Porovnání vývoje komárovitých druhů Anopheles a Culicinae (Zdroj: Šebesta, 2007)

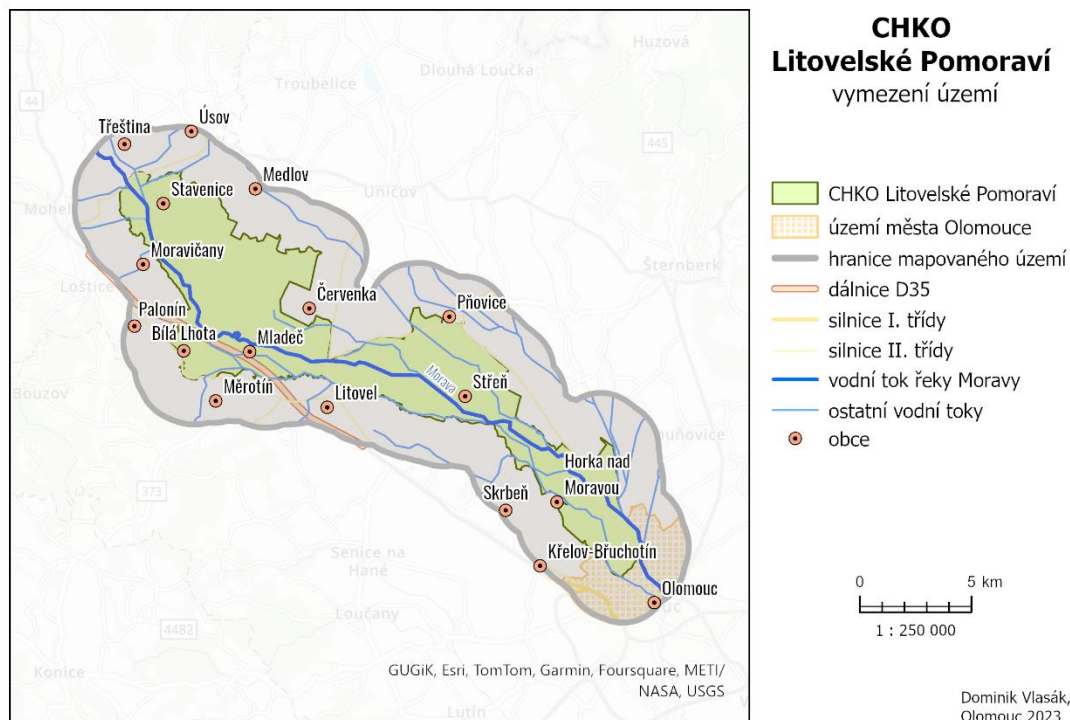
dni po získání krevní moučky. V závislosti na druhu mohou být vajíčka kladena jednotlivě (např. komáři *Aedes aegypti*, Obr. 2) nebo ve vorech (např. komáři *Culex*, Obr. 2) na povrch vody, stěny nádob nebo vlhkou půdu. Speciálně druhy *Aedes* a *Ochlerotatus* kladou svá vejce do vodou zaplavovaných půdních depresí (Országh et al., 2009). Vajíčka komárů rodu *Aedes* a *Ochlerotatus* jsou odolná vůči vyschnutí a mohou bez zaplavení vodou přežívat v povrchové vrstvě půdy i několik let (Kramář, 1955).

Z vajíček se vylíhnou malé, kroutící se larvy, nazývané také "zavíječi", které plavou ve vodě a živí se mikroorganismy nebo rozkládajícími se organickými látkami (Volf et al. 2007). Larvy procházejí čtyřmi vývojovými stádii známými jako instary, během nichž se zvětšují, až dosáhnou relativně neaktivního stádia kukly. Larvy se musí vynořit, aby mohly dýchat (s výjimkou několika specializovaných druhů komárů). Larvy komárů mají na konci ocasu sifon, který jim umožňuje dýchat tak, že prorazí vodní hladinu a dostanou se přímo ke vzduchu. Po čtvrtém larválním instaru se vytvoří neaktivní kukla. Kukly, se neživí. Komáři kukly dýchají pomocí dýchacích "trubic", kterými nasávají vzduch přímo z atmosféry. Larvy a kukly lze usmrtit odříznutím přístupu vzduchu pomocí olejů nebo monomolekulárních fólií. Stadium kukly je obvykle relativně krátké (1-2 dny), poté se z přejde do vývojového stádia dospělého komára.



## 2.3 ÚZEMNÍ VYMEZENÍ ZKOUMANÉ OBLASTI

Oblast CHKO Litovelské Pomoraví, které získalo svůj status ochrany v roce 1990, se rozkládá v centrální části Moravy mezi Olomoucí a Mohelnicí na ploše o celkové rozloze 96 km<sup>2</sup>. Území CHKO Litovelského Pomoraví je vytyčeno 3-8 kilometrů širokým pruhem okolo meandrujícího toku řeky Moravy od jejího 276 kilometru po 239,5 kilometr. V roce 1997 byla část CHKO zařazena do Montreuxského záznamu, seznamu mezinárodně významných mokřadů významně ohrožených lidskou činností, podle Ramsarské úmluvy. Hlavní hrozbou pro tuto oblast je těžba podzemní vody. Status ochrany CHKO je druhý nejvyšší v České republice (AOPK ČR, 2017).



Obr. 3 Mapové vymezení zkoumané oblasti (Zdroj: vlastní tvorba)

## 2.4 VEGETAČNÍ KRYT ZKOUMANÉ OBLASTI

Díky vysoké hladině podzemní vody a opakujícím se jarním záplavám je CHKO Litovelské Pomoraví ideálním prostředím pro lužní lesy, které jsou nejvýznamnějším biotopem tohoto území a tvoří zde rozsáhlé komplexy. Nejzachovalejší úseky lužního lesa se nacházejí vPR Ramena řeky Moravy, Vrpač, PR Litovelské luhy, Hejtmanka, Kenický, ale i v Panenském lese a v Olšínách (Mullerová, 2007). Zavodněný charakter krajiny je důvodem existence nivních luk v okolí řeky Moravy, kde se vyskytují i jilmové doubravy a slatinné olšiny. Dále se zde vyskytují v dřevinatém patře pobřežní vrby a topolo-jilmové jaseniny (Herman, 2015).

## 2.5 PŮDNÍ CHARAKTERISTIKY ZKOUMANÉ OBLASTI

Důležitým aspektem vzniku periodických tůní, sloužícím jako lůžiska komárovitých, je půdní složení, které ovlivňuje průsak vody. Ekologický substrát nivy je tvořen především čtvrtohorními štěrkovými nánosy. V nivě řeky Moravy lze rozlišit tři terasové úrovně. Dvě nižší terasy se nacházejí v úzkých pásech podél současného koryta řeky ve výškách 1,0-1,5 m a 2,0-2,5 m nad hladinou řeky, zatímco nejvyšší terasa je v relativní výšce 3,5-4,5 m. Štěrkové nánosy jsou překryty vrstvami holocenních nivních půd, často o mocnosti až 3 m. V nivě řeky Moravy se nacházejí i štěrkové nánosy. Prerušovaná akumulace lužního humusu, aluviální sedimentace, zvýšená hladina podzemní vody a její periodické kolísání v závislosti na aktuálních průtocích vody v tocích jsou typickými znaky lužních půd (tzv. fluvizemí) v Litovelském Pomoraví.

Litovelské Pomoraví má charakteristické půdní podmínky dané nivou řeky Moravy s podzemní vodou, tzv. říční, která se pohybuje s hladinou vody v korytě toku. Vliv této podzemní vody může v dobře propustném podloží sahát až do vzdálenosti 4-5 km od toku, zatímco v málo propustném podloží sahá jen do několika metrů. V nivě se vyskytují písčité štěrky o průměrné mocnosti asi 4 m a maximální mocnosti až 6 m. Balvany ve štěrcích jsou většinou hrubozrnné a skládají se z křemene, krystalinika a klastických hornin. (Zelinka, 2008)

Ve štěrkopískovém souvrství Moravy se vyskytují tři stupně štěrkopísků, přičemž nejvyšší stupeň má relativní výšku 3,5-4,5 m a bývá překryt holocenními povodňovými hlínami o mocnosti až 3 m. V nejvyšším stupni se vyskytují štěrkopísky o mocnosti až 1,5 m. Fluviální půdy v Litovelském Pomoraví se vyznačují záplavami, fluviálním ukládáním půd, zvýšenou hladinou podzemní vody a periodickým kolísáním v závislosti na průtocích řek. Přirozená tvorba lužních půd je v CHKO stále živým jevem a představuje jedinečný pedologický a krajinně-ekologický fenomén. (Machar a kol, 2003)

## 2.6 KLIMATICKÉ PODMÍNKY ZKOUMANÉ OBLASTI

Území CHKO Litovelské Pomoraví se nachází v mírném klimatickém pásu, který je charakterizován mírnými zimami i léty. Oproti jiným regionům se v tomto pásu vyskytují poměrně nízké srážky, z důvodu západního hřebene zachycujícího většinu vlhkosti, která je přinášena převažujícími západními a severozápadními větry.

Podle klimatického atlasu převažuje většina území teplé klimatické oblasti T-2. Oblast Olomoucko-litovelská a lošticko-mohelnická patří mezi suché oblasti s průměrnými ročními srážkami kolem 600 mm. Během vegetačního období klesá množství srážek na 350 - 400 mm, zatímco v zimním období je pouze 200 - 300 mm. Nejméně srážek obvykle spadne v únoru, s maximem v červenci. Nedostatek srážek v zimě má dopad i na jarní měsíce. V extrémně suchém roce 1947 bylo zaznamenáno pouhých 350 mm srážek. Oblast Třesínského prahu má o něco vyšší srážky, s průměrem kolem 700 mm (v roce 1947 zde bylo jen 450 mm) (Tolasz, 2007).

Počet dnů se srážkami nad 0,1 mm se pohybuje kolem 130 v úvalových částech a stoupá na 160 - 170 směrem do pahorkatin. Průměrný počet dnů s intenzivními srážkami nad 10 mm je 17 za rok. Z celkového počtu dnů se srážkami průměrně 28 dnů ročně připadá na sněžení. Průměrně první sněžení nastává kolem 13. listopadu a poslední kolem 5. dubna. V úvalu je průměrná výška sněhové pokrývky 20 cm, avšak je často nesouvislá. Na Třesínském prahu dosahuje výška sněhové pokrývky 30-35 cm (Tolasz, 2007).

Průměrná roční relativní vlhkost vzduchu činí asi 76 %, s nejvyšší hodnotou v prosinci a nejnižší v květnu. Průměrný počet jasných dnů za rok je 35, přičemž nejvíce jasných dnů připadá na září. Průměrný počet zamračených dnů činí 144 za rok.

Průměrná roční teplota v úvalové části CHKO se pohybuje mezi 8-9 °C, s nejnižšími teplotami v lednu (-2 °C). V pahorkatině Třesínského prahu je průměrná roční teplota kolem 7-8 °C. První mrazivý den bývá obvykle 4. října a poslední 1. května (AOPK, ČR).

## 2.7 PERIODICKÉ TŮNĚ

Periodickými tůněmi (též možné nazývat vysychající tůně) jsou nazývány drobné vodní biotopy přírodního i umělého původu jejichž vodní obsah je odváděn pouze vsakem nebo výparem (Sukop, 1998). Oproti permanentním tůním je v periodických voda zadržována v časovém rozpětí týdnů nanejvýš měsíců. Vodní tůně se obecně označují jako telmy, patří mezi lentické stojaté vody a dělí se na základě místa vzniku.


Předmětem výzkumu této bakalářské práce jsou periodické tůně vyskytující se u slepých a mrtvých ramen řeky jejichž příčinou vzniku je zvýšení podzemní hladiny vod či povodeň. Takto vzniklým tůním náleží termín potamotelmy (Ambrožová, 2003).

Nejpoužívanější dělení periodických tůní v České republice popsal (Sukop, 1998), který vysychající tůně rozdělil dle doby vzniku na jarní a letní. Oba typy tůní spadají do oblasti zájmů této bakalářské práce a ve svých charakteristikách pro identifikaci se neliší.

### 2.7.1 Vznik a charakteristiky periodických tůní

Vznik tůní závisí na faktorech podnebí, povrchové geomorfologie a vegetace. Stěžejním faktorem je voda, zejména ta, která pochází ze srážek. Kromě půdních tůní, při dopadu srážek na zem je voda zachycována na listech stromů či jiné vegetaci, kde vytváří malé nádrže nazývané fytootelmy. Po kontaktu vody s půdou se vsakuje se pod povrch. Rychlost vsakování závisí na typu a hustotě půdy; na jílovém podkladu voda zůstává déle, vytváří drobné kaluže a občasné tůně, které se rychle vsakují do hlubších vrstev puklinami. Tyto tůně mají krátkou životnost a nepravidelně se objevují, označujeme je jako vody epizodické. Většinou nejsou obývány množstvím organismů, pokud se nevytvoří u zdrojů, které rychle kolonizují druhy. Příkladem jsou tůňky vznikající po deštích nebo sněhovém tání, nebo litotelmy v puklinách skal (Williams, 1987).

S nárůstem srážek není země schopna absorbovat veškerou vodu a malé prohlubně na povrchu se naplňují - vytvářejí se kaluže. S dalším deštěm voda stéká po povrchu do těchto prohlubní nebo koryt a pokud může odtékat korytem, vznikají povrchové toky. V opačném případě se voda hromadí v prohlubních a vytvářejí se tůně či jezírka. Pravděpodobně nejdůležitějším faktorem ovlivňujícím dočasně vody je proces infiltrace. Tento proces rozděluje srážky na vodu pronikající do půdy, vodu zůstávající na povrchu a vodu, která stéká po nepropustné vrstvě (Rulík, 2005).



Obr. 4 Ilustrace vzniku periodických tůní (Zdroj: autorská ilustrace)

## 2.8 PROJEKT MOSPREMA

Projekt MOSPREMA se zaměřuje na minimalizaci každoročních kalamitních stavů komárů s ohledem na zachování biodiverzity území CHKO Litovelské Pomoraví a jeho okolí. Využívá moderní geoinformační metody a sensorová data k vytvoření pokročilého informačního systému pro integrovaný management území. Cíle projektu jsou v souladu se Státní politikou životního prostředí ČR 2030 a Strategii přizpůsobení se změně klimatu. Projekt se zaměřuje na selektivní aplikaci laricidů s cílem snížit přísun cizorodých látek do biotopu lužního lesa a zachovat nutnou přítomnost komárů a dalšího hmyzu pro potravní řetězec. Cílovou skupinou jsou obyvatelé obcí v okolí CHKO Litovelské Pomoraví. Projekt bude umožňovat kontrolu kalamitních stavů v návaznosti na strategické dokumenty a zákon o ochraně přírody a krajiny. Jedním z partnerů je Norwegian University of Science and Technology, která přinese zkušenosti s tvorbou predikčního modelu v reakci na měnící se podmínky klimatické změny.

## 2.9 STUDIE ZABÝVAJÍCÍ SE OBDOBNÝM TÉMATEM

Následující sekce obsahuje rešerši vědeckých prací zabývajících se stejným či obdobným tématem. Jsou zde stručně popsány poznatky a postupy prací zahraničních i tuzemských. Oproti pracím zpracovaných v České republice je tato práce unikátní ve využití laserových dat s vyšším prostorovým rozlišením a podrobnějším rozbohem použitelnosti jednotlivých konfigurací dat. Tematicke identifikace komářích líhnišť s využitím nástrojů a technologií dálkového průzkumu Země se v zahraničí dostává více prostoru a pozornosti, než v akademické sféře v České republice. Převážně v tropických oblastech světa, jako jsou státy Sahelu a střední Afriky, jihovýchodní Asie, střední nebo jižní Ameriky, je každodenní ohrožení komářích druhy přenášejícími smrtelné nemoci mnohonásobně vyšší, tudíž je zde kladen větší důraz na výzkum v této oblasti. Na výzkumných projektech se zde podílejí experti z oborů IT, jako je automatické zpracování obrazu nebo umělá inteligence, čímž je přinesena vyšší míra automatizace a přesnosti výsledků identifikace. Oproti tuzemským pracím je u zahraničních vyšší četnost publikací na dané téma. V rešerši této práce je věnována pozornost nejaktuálnějším a nejprínosnějším z nich.

### 2.9.1 Studie zpracované v České republice

#### **ANALÝZA RIZIKA ŠÍŘENÍ KALAMITNÍCH KOMÁRŮ V OKOLÍ VYBRANÝCH LÍHNIŠŤ OLOMOUCKÉHO KRAJE, Petr Pachta (2009)**

Cílem diplomové práce Petra Pachty bylo zpracování analýzy rizika šíření kalamitních druhů komárů na území vybraných líhnišť v rámci CHKO Litovelské Pomoraví. Dílčími výstupy byl postup mapování komářích líhnišť pomocí informačních technologií. Využití geoinformačních technologií našlo uplatnění především v uložení zmapovaných dat a následnému provedení prostorové analýzy na simulačním modelu šíření komářích jedinců. Práce byla vypracována pod dohledem expertů z Krajské hygienické stanice Olomouckého kraje (KHSOL).

Autor práce zanášel mapované informace do digitální podoby za využití mobilního přístroje GPS připojenému k zařízení PDA (Personal Digital Assistant). Pro provedení analýzy byl pro KHSOL byl použit software ArcMap, pro vlastní analýzy ArcGIS 9.1 s modifikovanými skripty za pomoci skriptovacího jazyku Python 2.4.

Simulační model distribuce komárů byl vytvořen na principu opakování cyklu *for*, do kterého vstupovali podmínky popisující prostředí pro šíření komárů, díky kterým s pomocí zavedeného indexu distribuce bylo možné aplikovat výpočet fokální funkce,

jehož výsledky byly rastry s hodnotami šíření komárovitých druhů. Výstupem byly mapové vizualizace šíření komára pro daná časová období.

### **IDENTIFIKACE A PROSTOROVÉ ANALÝZY ROZMÍSTĚNÍ KOMÁŘÍCH LÍHNIŠŤ V CHKO LITOVELSKÉ POMORAVÍ, David Šulc (2018)**

Stěžejním cílem diplomové práce Davida Šulce bylo sestavení technického postupu pro správnou identifikaci komářích líhnišť z dat DPZ za přičinění vlastních dat sesbíraných pomocí zařízení GPS. Navíc byla testována aplikace pro operační systém Android ke sběru dat, propojení s online aplikací pro správu líhnišť a byl ověřen výskyt identifikovaných tůní v terénu. Autor jako zdroj dat pro tvorbu DMR využil model DMR 5G dostupný z databáze ZABAGED což způsobilo limitaci v identifikaci povrchových depresí menších než 5 x 5 metrů.

## **2.9.2 Vybrané studie zpracované v zahraničí**

### **MAPPING MOSQUITO LARVAL DENSITIES AND ASSESSING AREA EGYPT, Alaa Nagy et al. (2021)**

Egyptská studie vedená odborníky z Univerzity Al-Azhar v Káhiře využila satelitních technologií dálkového průzkumu Země k posouzení environmentálních charakteristik hnízdišť komárů a k mapování zranitelnosti přenosu nemocí v Nilském údolí u města Gíza.

Zkoumaným předmětem práce bylo hned několik typů komářích líhnišť: povrchy odpadních vod, vysychajících jezer, vysychajících kanálů, závlahových kanálů a povrchy průsakové vody. V kombinaci s terénním výzkumem a laboratorní analýzou vzorků vody odebraných z komářích líhnišť byl popsán soubor pozorovatelných charakteristik a jejich hodnot na satelitních snímcích. Pro obrazovou analýzu byl použit snímek ze snímače Landsat-8 (OLI), který umožnil výpočet spektrálních indexů (NDVI, NDBI, NDMI, NDWI, NDSI a LST) potřebných pro určení optimálního prediktora hnízdišť komárů. U snímku bylo provedeno georeferencování, radiometrická a atmosférická korekce. Zmíněných úkonů bylo dosaženo v softwarovém programu ENVI. Průměrné hodnoty různých environmentálních faktorů (NDVI, NDBI, NDMI, NDWI, NDSI a LST) a hustoty larev sbíraných druhů komárů byly odhadnuty pro každé hnízdiště. V programu ArcGIS (verze .10.5) byl využit geostatistický analytický nástroj k předpovědi hodnot hustoty larev na neovzorkovaných oblastech na základě průzkumných míst. Metody inverzní vzdálenosti (IDW) a kriging jsou nejběžnějšími geostatistickými metodami. V této studii byl zvolen přístup IDW, z důvodu přesnosti a snadné implementace ve srovnání s metodou krigingu, která vyžaduje více času a úsilí pro nastavení správných parametrů.

Naměřené hodnoty charakterizující jednotlivá prostředí komářích líhnišť byly shrnuty v přehledové tabulce (viz Obr. 5). Výsledky práce ukázaly, že komáři mohou přežívat a rozmnožovat se v široké škále environmentálních a klimatických podmínek. Střední části Nilského údolí u Gízy jsou hlavně ovlivněny vysokou hustotou komárů, zejména druhem *Culex pipiens*, který je nejhojnějším druhem. To zvyšuje riziko přenosu filariasis v zkoumaných oblastech, což vyžaduje adekvátní a efektivní program kontroly komárů. Lze tedy konstatovat, že satelitní snímky, terénní průzkumy a laboratorní analýzy larev komárů pomáhají získat přesnější charakterizaci a posouzení míst s rozmnožováním komárů.

Studii byly prozkoumány možnosti multispektrálních optických dat pro detekci vodních těles s výskytem komářích líhnišť. Postupy nejsou použitelné ve výzkumu této bakalářské práce, jelikož datová sada neobsahuje elektromagnetické pásmo SWIR (short-wave infrared), které je stěžejní pro kalkulaci většiny spektrálních indexů zmíněných v rešerši. Důležitou součástí metody identifikace líhnišť pomocí optických dat je také

chemický rozbor vody, díky kterému je možné získat. Jedinou přínosnou možností identifikace zaplavených depresí je spektrální index NDWI (Normalized Difference Water Index), díky kterému je možné detekovat vodní povrchy avšak bez dalších informací navíc, které by indikovaly přítomnost komářích lánů.

Indices	NDVI	NDBI	NDMI	NDWI	NDSI	LST (°C)
Drainage Canals						
Min.	0.13	-0.20	-0.05	-0.34	-0.39	19.31
Max.	0.39	0.05	0.20	-0.17	-0.13	24.74
Mean	0.24	-0.06	0.06	-0.24	-0.24	21.76
SD	0.10	0.09	0.09	0.08	0.10	1.79
Irrigation Canals						
Min.	0.12	-0.19	-0.01	-0.33	-0.37	20.37
Max.	0.37	0.01	0.19	-0.10	-0.12	23.52
Mean	0.23	-0.07	0.07	-0.22	-0.23	21.66
SD	0.09	0.06	0.06	0.07	0.09	1.03
Sewage						
Min.	0.20	-0.09	0.02	-0.32	-0.33	21.12
Max.	0.33	-0.02	0.09	-0.18	-0.20	24.82
Mean	0.26	-0.06	0.06	-0.25	-0.26	22.22
SD	0.05	0.03	0.03	0.06	0.05	1.74
Seepage						
Min.	0.16	-0.02	-0.04	-0.24	-0.17	21.24
Max.	0.17	0.04	0.02	-0.22	-0.16	22.56
Mean	0.16	0.01	-0.01	-0.23	-0.16	21.90
SD	0.00	0.04	0.04	0.01	0.00	0.93

Obr. 5 Tabulka spektrálně získaných parametrů charakteristik jednotlivých typů komářích lánů (Zdroj: Nagy et al., 2021)

### UNMANNED AERIAL VEHICLES FOR SURVEILLANCE AND CONTROL OF VECTORS OF MALARIA AND OTHER VECTOR-BORNE DISEASES, Frank Mechan et al.(2023)

Elaborát mezinárodního týmu výzkumníků popisuje aktuální postavení dronů (UAV) ve využití pro sledování a kontrolu vývoje nánků přenášených vektory (organismy přenašejícími nánku z jiných organismů). Rychle se rozvíjející integrace dronů do sledování a kontroly komárů představuje zásadní pokrok v boji proti šíření nemoci přenášených komáry. Přehled zdůrazňuje řadu výhod, které v této oblasti přinášejí drony, včetně jejich schopnosti rychle pokrýt rozsáhlé oblasti, získat přístup k vzdáleným nebo nepřístupným místům a poskytnout data v reálném čase, která jsou nezbytná pro informované rozhodování.

Přijetí dronů má potenciál zefektivnit provozní procesy, snižovat závislost na manuální práci a vytvářet úspory nákladů ve srovnání s tradičními metodami sběru dat. Studie popisuje několik hmatatelných výsledků, které naznačují transformační potenciál intervencí založených na využití dronů.

Zaprvé drony umožňují změnu paradigmatu ve strategiích kontroly komárů, umožňují cílené a efektivní intervence, které snižují přenos nemoci a zmírňují zátěž pro veřejnou zdravotní infrastrukturu. Zadruhé, integrace dronů zvyšuje schopnosti sledování, poskytující v reálném čase poznatky o populacích komárů a místech rozmnožování nezbytných pro preventivní řízení nemoci. Zatřetí, přijetí dronů vytváří úspory nákladů optimalizací alokace zdrojů a eliminuje potřebu rozsáhlé pracovní síly a vybavení. Pozitivem je ekologicky šetrná povaha intervencí založených na využití dronu snižuje environmentální dopad.

Studie v závěru zdůrazňuje katalytickou roli technologie dronů v podněcování výzkumu a inovací v oblasti biologie a kontroly vektorů, čímž se otevírá cesta k novým metodologiím a osvědčeným postupům. Celkově výsledky této studie signalizují změnu paradigmatu směrem k efektivnějším, udržitelnějším a proaktivním přístupům sledování a kontrole komárů, což podtrhuje klíčovou roli využití dronů při ochraně veřejného zdraví a ochraně životního prostředí.

## **THE USE OF DRONES FOR MOSQUITO SURVEILLANCE AND CONTROL, Gabriel Carrasco Escobar et al. (2022)**

V práci byly použity drony vybavené běžnými RGB a multispektrálními kamerami ke sběru snímků s vysokým rozlišením za účelem určení spektrální signatury (charakteristiky světla odraženého od povrchu Země) Pro klasifikaci byla zvolena metoda řízené klasifikace (celková přesnost na základě pixelů: 86,73-96,98 %) k identifikaci vodních ploch a pozitivních, resp. negativních oblastí v rámci identifikovaných vodních ploch pomocí technik strojového učení. Byl aplikován dvoustupňový proces zahrnující nejprve klasifikaci několika typů povrchů půdy a poté maskování a klasifikaci pouze vodních ploch.

Hlavní výzvou řešené studie je překonání obtížnosti lokalizace míst hnízdění komárů, zejména těch mimo obydlené oblasti, které přispívají k reziduálnímu přenosu v oblastech endemických pro malárii. Práce navrhuje integraci dronů do strategií sledování vektorů a intervencí během celého životního cyklu komárů.

Jedním z diskutovaných témat byla předletová příprava, jako je zvážení místních předpisů, ochrany osobních údajů, bezpečnosti a zapojení komunity. Data z dronů byla využita pro mapování hnízdních nádob mladých komářích jedinců a pro intervenční studie k rozptylu biologických kontrolních látek, larvicidů, komárů nesoucích Wolbachii nebo sterilních samců.

V práci je prosazováno využívání dat z dronů s vysokým rozlišením v prediktivních distribučních modelech a analýzách vhodnosti životního prostředí k posouzení rizika usazení a šíření komáry přenášených patogenů.

## 3 METODY A POSTUP ZPRACOVÁNÍ

Následující kapitola vytyčuje souhrn použitých metod pro zpracování dat a cílů bakalářské práce. Obsah je rozřazen do podkapitol referujících ke konkrétním postupům zpracování ve všech fázích procesu. Zmíněna jsou též použitá data a jejich charakteristiky. V kapitole jsou též zmíněny softwarové programy, pomocí nichž byla data zpracována.

### 3.1 Identifikace komářích tůní pomocí laserových dat

Data získaná pomocí technologie LiDAR (Light Detection and Ranging) jsou používána k tvorbě výškových modelů terénů. Zařízení LiDAR, které zahrnuje laserový skener, globální polohový systém (GPS) a inerciální navigační systém (INS), je obvykle umístěné na trupu letadla či dronu. Laserový skener emituje krátké světelné impulsy na povrch země. Tyto impulsy se odrážejí nebo rozptylují zpět a čas trvání jejich návratu je použita k výpočtu vzdálenosti mezi laserovým skenerem a skenovaným objektem. Data z LiDAR se zpočátku shromažďují jako "mračno bodů" jednotlivých bodů odražených od povrchu terénu, včetně antropogenních objektů a vegetace. Aby bylo možné vytvořit digitální model reliéfu (DMR), jsou antropogenní prvky a vegetace odstraněny.

K identifikaci povrchových depresí existuje řada dostupných nástrojů prostorové analýzy v geoinformačních softwarech jako je ArcGIS Pro či QGIS s otevřenou licencí pro použití. Je-li záměrem při identifikaci uvažovat charakteristiky depresí, jako jsou minimální hloubka, vnořené deprese či prostorový tvar, je nutné využít sofistikovanějších nástrojů. Metodami identifikace komářích lánů byly zvoleny 2 různé postupy navržené dr. Qiusheng Wu, docentem na katedře geografie a udržitelnosti na University of Tennessee v Knoxville (USA). Oba je možné aplikovat jako toolbox v rozhraní ArcGIS Pro nebo skrze skript v programovacím jazyce Python (verze 3.12.).

#### 3.1.1 Lidar: A Python package (Wu et al., 2019)

Lidar (dále jako *Wu1*) je balíček v jazyce Python určený k vymezení vnořené hierarchie povrchových depresí v digitálních modelech reliéfu (DMR). V tradiční hydrologické modelaci jsou povrchové deprese v DMR obvykle považovány za artefakty a jsou proto vyplňovány a odstraněny, aby vznikl bezpropadlinový DMR, který lze poté použít k vytváření síťových toků. Ve skutečnosti jsou povrchové deprese v DMR obvykle kombinací falešných a skutečných terénních prvků. DMR s jemným rozlišením odvozené z dat z laserového snímání LiDAR mohou zachytit a reprezentovat skutečné povrchové deprese. V nedávné době byla navržena metoda založená na úrovně sadě založená na teorii grafů k vymezení vnořené hierarchie povrchových depresí. *Wu1* v jazyce Python implementuje metodu úrovně sady a umožňuje vymezení vnořené hierarchie povrchových depresí. Kroky zpracování pomocí metody *Wu1* jsou následující:

- vyhlazování DMR pomocí průměru, mediánu a Gaussových filtrů,
- vymezení povrchových depresí z DMR pomocí tradiční metody vyplňování depresí,
  - vymezení vnořené hierarchie povrchových depresí pomocí metody úrovně sady; výpočet topologických a geometrických vlastností depresí; a exportování vlastností depresí jako souboru CSV,
  - vymezení vnořené hierarchie zvýšených prvků (vrcholů) pomocí metody úrovně sady; výpočet topologických a geometrických vlastností vrcholů; a exportování vlastností vrcholů jako souboru CSV.

Proces skriptu nebyl dokončen zcela úspěšně v krocích rozdělení vnořených depresí a nastavení hraniční hodnoty minimální hloubky deprese validní pro identifikaci.



Tyto nedostatky byly vyřešeny vlastním zpracováním v softwaru QGIS (verze 3.38.0). (viz kapitola 4.1.1). Tuto metodu využívá ve své bakalářské práci Zapletal (2023). Odlišení od této práce je převážně v krocích postprocessingu zmíněných nedostatků. Metoda Wu1 byla bakalářské práce zařazena především jako jedna z možností zpracování identifikace povrchových depresí pro zadaný účel. Výstupy z této metody slouží pouze pro komparaci s dalšími navrhovanými postupy.

V následujících částech práce jsou popsány další dvě metody, které jsou prezentovány jako stěžejní a autor je využil pro zpracování výsledných dat.

### 3.1.2 Identifikace na základě vygenerovaných kontur

#### **Efficient Delineation of Nested Depression Hierarchy in Digital Elevation Models for Hydrological Analysis Using Level-Set Methods (Wu et al., 2018)**

Soubor nástrojů z této studie (dále Wu2) představuje nový koncept a reprezentaci stromu kontur založený na teorii grafů poprvé k řešení problému detekce a vymezení povrchových prohlubní. Nad rámec detekce a vyplnění prohlubní, který byl řešen v rastrových metodách dřívějších studií, metoda lokalizovaného konturového stromu odvozuje polohu, obvod, povrchovou plochu, hloubku, hladinu přelivu, objem úložiště, index tvaru a další geometrické vlastnosti pro všechny jednotlivé povrchové prohlubně, stejně jako vnořené topologické struktury pro složité povrchové prohlubně. Kombinace různých geometrických vlastností a popisů vnořených topologických struktur poskytuje komplexní a zásadní informace o povrchových prohlubních napříč různými měřítky pro různé environmentální aplikace. Aplikovaný příklad prokázal, že metoda lokalizovaného konturového stromu je funkčně křivá a výpočetně účinná. Mezi kroky zpracování dat patří:

- vyhlazení DMR pomocí Gaussova nebo mediánového filtru,
- generování kontur z vyhlazeného DMR volbou výšky základní kontury a konturového intervalu,
- identifikace zárodků kontur a konstrukce lokálního konturového stromu na základě topologického vztahu mezi koncentrickými uzavřenými konturami,
- vyhledání a identifikace všech kvazi-výlevkových kontur a zjednodušení lokálního konturového stromu na strom prohlubní,
- určení pravých výlevkových kontur a jejich hladiny přelivu na základě kvazi-výlevkové kontury pomocí algoritmu inkrementální expanze,
- výpočet planimetrických, objemových a tvarových vlastností pro každou povrchovou prohlubeň definovanou pravou výlevkovou konturou.

Algoritmus byl implementován pomocí programovacího jazyka Microsoft Visual C++ .NET a ArcObjects SDK pro .NET. Posloupnost jednotlivých operací použitých v metodě Wu2 je popsána na Obr. 6.

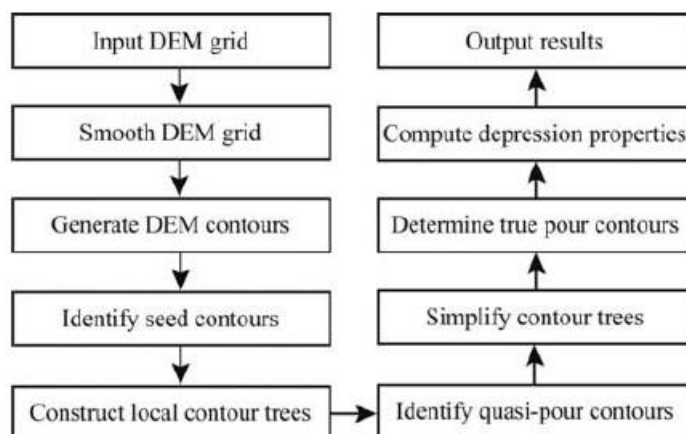


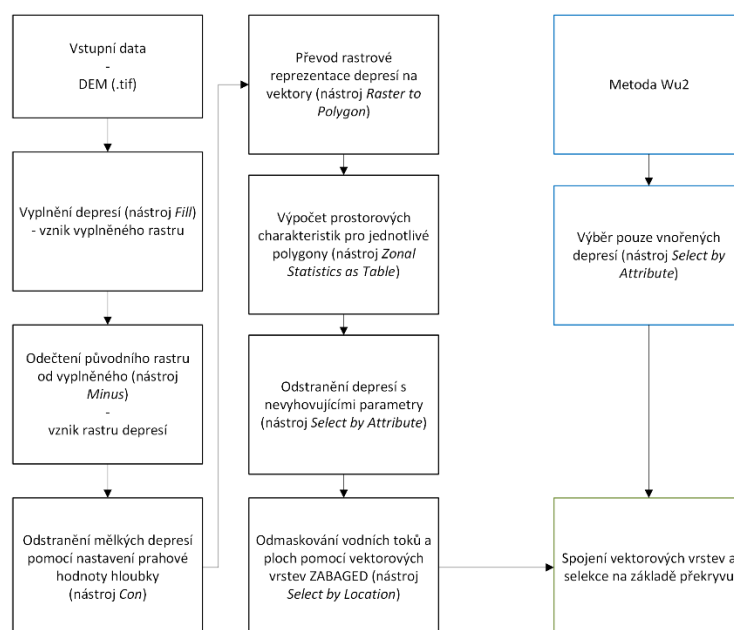
Figure 4. Flowchart in our localized contour tree method.

Obr. 6 Posloupnost operací v metodě Wu2 (Zdroj: Wu et al., 2018)

### 3.1.3 Vlastní metoda identifikace depresí

Vlastní metoda identifikace depresí byla navržena pro nedostatky metody Wu2 a pro použití metody Wu1 v práci *Modelování dynamiky vodního režimu ve vybraných tůních v CHKO Litovelské Pomoraví* (Zapletal, 2023). Vlastní přístup je sestaven ze souboru geoprocessingových nástrojů dostupných v programu ArcGIS Pro (verze 3.1.1). Autorovi práce se nepodařilo najít funkční řešení pro identifikaci vnořených depresí, které by bylo založeno na uživatelsky nastavitelných parametrech. Z toho důvodu je do této metodiky zakomponovaná i část procesu pocházející z metody Wu2.

Proces vlastní metody je hrubě popsán grafickým schématem níže (Obr. 7) pro utvoření představy o jednotlivých krocích a funkčnosti celého postupu. Detailní popis je obsažen v kapitole 4.1.3.



Obr. 7 Grafické schéma vlastního postupu řešení identifikace depresí (Zdroj: autorská tvorba)

## 3.2 Identifikace komářích tůní pomocí optických dat

Obsahem následujících podkapitol je popis metod pro identifikaci tůní z optických dat. S přihlednutím k charakteristice vstupních dat ve spektrálních pásmech RGB a NIR je prvotní hypotézou označena za nejefektivnější metodu tu kombinující zmíněná pásma. Prostor je zde věnován různým typům klasifikačních metod zvolených na základě diskuze s vedoucím práce a relevancí užití ve zkoumané problematice.

### 3.2.1 Simple methodology for water data extraction using QGIS

Jednoduchou metodou pro identifikaci zatopených depresí s potenciálem výskytu komářích líhnišť je výpočet spektrálního indexu NDWI (Normalized Difference Water Index). Výpočetní postup byl popsán v internetovém příspěvku *Simple methodology for water data extraction using QGIS* (Cimpianu, 2018). Vodní tělesa mají silnou absorpční schopnost a nízkou radiaci v rozsahu od viditelných (465 – 630 nm) po infračervené vlnové délky (760 – 1000 nm). Na základě tohoto jevu index využívá zelené a blízké infračervené pásmo (NIR) snímků dálkového průzkumu Země.

#### Rovnice 1 Rovnice výpočtu spektrálního indexu NDWI

$$NDWI = \frac{(X_{green} - X_{nir})}{(X_{green} + X_{nir})}$$

Pixely vodních ploch nabývají hodnot vyšších než 0,4. Vegetace má mnohem menší hodnoty, což má za následek snazší odlišení vegetace od vodních ploch. Zastavěné prvky mají kladné hodnoty mezi nulou a 0,2. (European Commission. NDWI: Normalized Difference Water Index. 2011.

Identifikace všech vodních ploch na snímaném území byla vykonána pomocí řízené klasifikace a prahování. Vybrané hodnoty pixelů byly poté převedeny na vektorové polygony (SHP) pro použití v kombinované analýze s výstupy z identifikačních metod laserových dat.

### 3.2.2 Řízená klasifikace Random Forest

Random Forest klasifikace je technika strojového učení kombinující predikce několika rozhodovacích stromů pro zlepšení přesnosti a stability modelu. Tento algoritmus využívá ansámblového učení, kde je výsledná predikce dosažena agregací predikce jednotlivých stromů. Random Forest používá dva klíčové principy: bagging a náhodný výběr podmnožin atributů při stavbě stromů. (Breiman, 2001)

Bagging zahrnuje vytváření několika trénovacích sad bootstrapováním (náhodným výběrem s opakováním) z původní trénovací sady. Každá z těchto sad je použita k postavení jednoho rozhodovacího stromu, což zlepšuje generalizaci modelu snížením variance. Dalším klíčovým prvkem je výběr náhodné podmnožiny atributů při každém dělení uzlu v rozhodovacím stromě. Tento postup snižuje korelaci mezi jednotlivými stromy a zlepšuje výkon celého ansámblu. (Liaw, 2002)

Random Forest je známý pro spolehlivou schopnost fungování s velkým počtem atributů bez rozsáhlého předzpracování dat. Model je odolným vůči šumu v datech a efektivně zachycuje nelineární vztahy mezi atributy a cílovou proměnnou. Navíc poskytuje metriky důležitosti atributů, užitečné pro interpretaci modelu a výběr atributů. Klasifikace je prováděna hlasováním, kde každý strom přispívá svou predikcí a výsledná třída je určena většinovým hlasováním. Tento mechanismus zajišťuje, že i při chybné predikci některých stromů zůstává celkový model robustní. Random Forest je snadno interpretovatelný, méně náročný na nastavení hyperparametrů a výpočetně efektivní. Random Forest jako

nástroj pro klasifikaci je obsažen v programu ArcGIS Pro, který byl využit pro zpracování této klasifikační metody.

### 3.2.3 Klasifikace Support Vector Machine

Support Vector Machine (dále SVM) je metoda strojového učení využívající regresi pro klasifikaci obrazu. Základním principem SVM je nalezení optimální hyperroviny, která maximálně odděluje různé třídy ve vstupních datech. Tento proces zahrnuje následující kroky (Pal et al., 2005):

- Transformace dat: SVM pracuje na principu transformace původních dat do vyšší dimenze pomocí kernelových funkcí (např. lineární, polynomiální, RBF), kde se složité nelineární vztahy stávají lineárními a tedy lépe separovatelnými,
- Optimalizace vzdálenosti od hyperroviny: SVM hledá hyperrovinu, která maximalizuje vzdálenost mezi nejbližšími body různých tříd, známými jako support vectors. Tím se minimalizuje riziko špatné klasifikace nových dat,
- Výpočet hyperroviny: Hyperrovina je definována rovnicí  $\vec{w} \times \vec{x} + b = 0$ , kde  $w$  jsou váhy,  $x$  je vektor vstupních datových bodů a  $b$  je bias. Optimalizace této rovnice se provádí pomocí Lagrangeovy multiplikátorové metody nebo SMO algoritmu (Sequential Minimal Optimization),
- Kernelové funkce: SVM využívá různé kernelové funkce, aby transformovala nelineárně separovatelné problémy do vyšších dimenzí. Mezi nejčastěji používané kernelové funkce patří lineární kernel, polynomiální kernel a radiální báze (RBF) kernel.
- Trénování modelu: Model je trénován na základě tréninkových dat, kde se učí rozlišovat mezi různými třídami. Proces zahrnuje iterativní úpravu váhových parametrů a biasu, aby se maximalizovala margina mezi třídami,
- Klasifikace: Po natrénování modelu může SVM klasifikovat nové, dosud neviděné data podle toho, na které straně optimalizované hyperroviny se nacházejí.

Metoda Support Vector Machine (SVM) je v geoinformatice široce používána pro klasifikaci satelitních a leteckých snímků díky své schopnosti efektivně zpracovávat vysokodimenzionální a heterogenní data (Mountrakis et al., 2011). Její robustnost vůči šumu a schopnost pracovat s nelineárními separacemi ji činí ideální pro aplikace jako je klasifikace vegetačních typů, detekce vodních ploch a urbanizovaných oblastí. Studie prokázaly, že SVM poskytuje vyšší přesnost než tradiční metody, například maximální věrohodnost, při klasifikaci více spektrálních snímků (Huang et al., 2002). SVM se také osvědčila při monitorování změn krajiny, identifikaci změn ve využití půdy a vegetačním pokryvu. Nicméně, výzvy zahrnují volbu vhodných kernelových funkcí a parametrů, což může ovlivnit celkovou výkonnost modelu. Přes tyto výzvy, SVM zůstává klíčovým nástrojem v geoinformatice díky své vysoké generalizační schopnosti a efektivitě při zpracování komplexních datových sad.

### 3.3 Použitá data

Tabulka 2 Přehled použitých dat

<b>Použitá data</b>						
<b>Data pořízená v rámci projektu MOSPREMA</b>						
<b>Název</b>	<b>Typ</b>	<b>Formát</b>	<b>Rok pořízení</b>	<b>Využití</b>	<b>Popis</b>	<b>Další</b>
MospremaDTM_50cm_5514	rastr	tif	2023	Identifikace povrchových depresí	DMR CHKO Litovelské Pomoraví	S-JTSK Krovak EastNorth (5514), 50 cm/1 px
MospremaLAS	bodové mračno	.las	2023	Tvorba DMR, testování limitů laserových dat	Laserová data celoplošného skenování Litovelského Pomoraví	S-JTSK Krovak EastNorth (5514), minimálně 10 bodů/1 m <sup>2</sup> ), celoplošné laserové skenování
RGB_ortofoto_23	soubor rastrových dlaždic	.tif + .tfw	2023	Identifikace zatopených depresí, tvorba ortomozaiky	Soubor rastrů z leteckého skenování v RGB	S-JTSK Krovak EastNorth (5514), 10 cm/1 px
NIR_ortofoto_23	soubor rastrových dlaždic	.tif+ .tfw	2023	Identifikace zatopených depresí, tvorba ortomozaiky	Soubor rastrů z leteckého skenování v NIR	S-JTSK Krovak EastNorth (5514), 10 cm/1 px
RGB_ortofoto_24	soubor rastrových dlaždic	.tif+ .tfw	2024	Identifikace zatopených depresí, tvorba ortomozaiky	Soubor rastrů z leteckého skenování v RGB	S-JTSK Krovak EastNorth (5514), 10 cm/1 px
NIR_ortofoto_24	soubor rastrových dlaždic	.tif+ .tfw	2024	Identifikace zatopených depresí, tvorba ortomozaiky	Soubor rastrů z leteckého skenování v NIR	S-JTSK Krovak EastNorth (5514), 10 cm/1 px
DJI_Zenmuse_L1_mission_2023	soubor rastrových snímků	.tif	2023	Identifikace zatopených depresí, porovnání s daty z letadla	Soubor rastrů dílčího skenování dronem v RGB a NIR	WGS 84 / UTM zone 33N (32633), >1cm/1 px

Název	Typ	Formát	Rok pořízení	Využití	Popis	Další
DJI_Zenmuse_L1_mission_2024	soubor rastrových snímků	.tif	2024	Identifikace zatopených depresí, porovnání s daty z letadla	Soubor rastrů dílčího skenování dronem v RGB a NIR	WGS 84 / UTM zone 33N (32633), >1cm/1 px
20230406_strens_hriste	bodové mračno	.las	2023	Identifikace povrchových depresí, tvorba DMR, porovnání s daty z letadla	Laserová data územního skenování pomocí dronu v oblasti obce Střeň	WGS 84 / UTM zone 33N (32633), minimálně 20 bodů/1 m2
<b>Doplňková data</b>						
ZABAGED_vodni_toky	vektor	.shp		Maskování vodních toků	Vektorová vrstva linií reprezentující vodní toky v oblasti CHKO Litovelské Pomoraví	
ZABAGED_vodni_plochy	vektor	.shp		Maskování vodních ploch	Vektorová vrstva linií reprezentující vodní plochy v oblasti CHKO Litovelské Pomoraví	
tune_rucni_gpx	vektor	.GPX	2024	Porovnání s automatickými identifikovanými depresemi	Bodová vrstva zaznamenaných souřadnic při fyzickém měření hrany vybraných depresí	

### 3.4 Software pro zpracování metod

Tabulka 3 Přehled použitého software a aplikací

<b>Použitý software</b>			
<b>Název</b>	<b>Verze</b>	<b>Využití</b>	<b>Licence</b>
ArcGIS Pro	3.1.1	zpracování metod identifikace depresí	Advanced, proprietární
QGIS	3.38.0; 3.12.3	zpracování metod identifikace depresí	GNU GPLv2+
Cloud Compare	2.13.2	zpracování laserových dat	GNU GPLv2+
Agisoft Metashape Professional	2.1.2	zpracování ortomozaik	Free trial, proprietární
DJI Terra	V4.2.2	zpracování ortomozaik	Free trial, proprietární
PyCharm Community Edition	2024.1	Procesing metod identifikace depresí	Apache 2.0
<b>Použité doplňkové aplikace</b>			
GPS Waypoints	3.12, trial	Fyzické zaměřování depresí	zdarma dostupné na Obchod Play/AppStore

## 4 VLASTNÍ ŘEŠENÍ I

Následující sekce obsahuje detailní popis postupu zpracování cílů práce a cesty k navržení optimální metodiky pro identifikaci komářích láníšť pomocí kombinace laserových a optických dat. Dosatečný prostor je zde věnován testování limitů laserových a optických dat.

### 4.1 Identifikace depresí z laserových dat

Prvotně zamýšleným přístupem pro zpracování identifikace pomocí laserových dat byla analýza dat ve formátu .las, tedy analýza bodových mračen.

První hypotéza byla založena na myšlence, že vyskytující se shluk komářích larev v tůni, narozdíl od okolní vody, bude schopen odrážet paprsky červeného laserového paprsku a tudíž vzniknou pomyslné ostrůvky bodových mračen uprostřed prázdných polí detekujících přítomnost vody. Praktickým testováním bylo zjištěno, že k odrazu paprsků laserového snímače nedochází s vysokou mírou pravděpodobnosti.

Skutečností, jenž zavrhuje původně stanovenou hypotézu, je nahodilý výskyt objektů v zaplavených tůních (např. listy, větve, odpad). Nimi jsou zachytávány paprsky snímače a v důsledku vytváří zmiňované ostrůvky. Bodová mračna vzniklá odrazem od nespécifikovaných objektů v zaplavených tůních není možné automaticky odlišit od mračen potenciálně vzniklých odrazem od komářích láníšť. Jedinou možnou rozlišovací metodou je fyzická kontrola.

Další možností identifikace povrchových depresí z dat ve formátu .las byl přístup analýzy lokálních charakteristik bodového mračna v oblasti zjištěných depresí. Důkladnou rešerší přístupu byly zjištěny vysoké nároky na znalost zpracování dat pomocí metod machine learningu (ML). Pro dosažení kvalitních výsledků pomocí metod ML neměl autor práce adekvátní zkušenosti, na základě čehož bylo rozhodnuto pro zpracování použít laserová data převedená do podoby výškopisného modelu, tedy v rastrovém formátu. Subjektivním názorem autora je, s přihlédnutím ke složitosti a výpočetní náročnosti analýzy přímo z bodového mračna, že identifikace z dat v rastrovém formátu je efektivnějším přístupem a tudíž v souladu s cíli bakalářské práce.

Bodová mračna laserových dat v ryzím formátu byla využita při analýze limitů, jakožto jednoho z podcílů této bakalářské práce.

Vstupními daty do testovaných metod byly primárně DMR (Mosprema\_DTM\_50cm\_5514, Tabulka 2) a vektorové vrstvy vodních toků a ploch z databáze ZABAGED (Tabulka 2). Vektorové vrstvy byly oříznuty pro území zájmové oblasti CHKO Litovelské Pomoraví a přilehlých obcí. Digitální model terénu byl vytvořen a dodán v rámci projektu Mosprema v rozlišení 50 cm na 1 px v koordinančním systému S-JTSK / Krovak East North. Některé z metod byly použity i pro zpracování dalších odvozených DMR pro možnost porovnání aplikace identifikačních metod se vstupními daty s odlišnými parametry.

Tímto tématem se zabývá kapitola 4.2.

#### 4.1.1 Identifikace pomocí balíčku lidar

Hlavním úkolem v této fázi práce bylo nalézt metodu identifikace bezodtokých povrchových depresí s předem definovanými parametry rozsahu a hloubky. Sofistikovaný přístup poskytl nástrojový balíček *lidar: A Python package for delineating nested surface depressions from digital elevation data* (dále Wu1) vyvinutý týmem vědců pod vedením doktora Qiusheng Wu v roce 2019. Nástroj lidar je možné použít pomocí spuštění skriptu

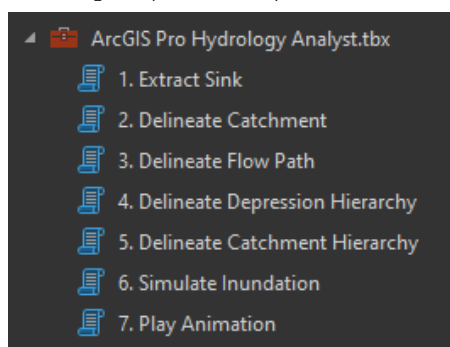


(lidar\_script.py) v programovacím jazyce Python s připojenou knihovnou ArcPy, nebo pomocí toolboxu *ArcGIS Pro Hydrology Analyst* připojitelného do prostředí softwaru ArcGIS Pro. Nástrojový balíček lidar včetně samostatných skriptů i předpřipraveného ArcGIS toolboxu je volně dostupný na webovém adresě <https://www.github.com/opengeos/lidar>.

### Zpracování metody Wu1 pomocí toolboxu ArcGIS Pro Hydrology Analyst toolbox

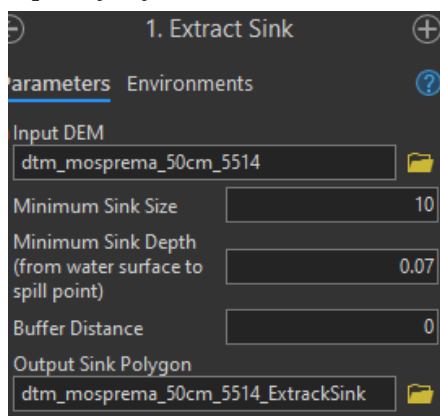
Při testování *ArcGIS Pro Hydrology Analyst* toolbox v uživatelském rozhraní ArcGIS Pro docházelo opakovaně k chybě, již nebylo možné odstranit z důvodu nekompatibility použité funkce s aktuální verzí ArcGIS Pro. Z toho důvodu byl nástroj použit pomocí samostatných skriptů spuštěných v rozhraní PyCharm Community Edition (verze 2021.2.3)

S ohledem na celistvost popisu, či možnou funkčnost v budoucnu, je hrubě nastíněn postup zpracování pomocí zmiňovaného toolboxu. Balíček nástrojů obsahuje sedm samostatných skriptů (viz Obr. 8).



Obr. 8 Skripty toolboxu ArcGIS Pro Hydrology Analyst

Pro záměry problému identifikace depresí postačuje využití skriptů 1. *Extract Sink* a skript 4. *Delineate Depression Hierarchy*. Zbylé skripty jsou pro účely práce nepřínosné. Použitím skriptu *Extract Sink* byly extrahovány deprese ve vstupním DMR dle nastavených parametrů (viz Obr. 9). Hodnoty vstupních parametrů byly nastaveny na základě charakteristik tůň vhodných pro výskyt komářích líhnišť.



Obr. 9 Nastavení vstupních parametrů skriptu *Extract Sink*

Výstupní rastr z tohoto procesu byl dále použit jako vstupní vrstva do skriptu *Delineate Catchment Hierarchy*. Hodnoty vstupních parametrů byly opět nastaveny na základě charakteristik tůň vhodných pro výskyt komářích líhnišť (viz Obr. 10).

LiDAR DEM  
 dtm\_mosprema\_50cm\_5514

Contour Interval: 0.2

Base Contour: 0

Minimum Area: 10

Minimum Depth: 0.07

Output Path  
 dtm\_mosprema\_50cm\_5514\_DepressionIdentification

Obr. 10 Nastavení vstupních parametrů skriptu Delineate Catchment Hierarchy

Výstupem výše uvedeného skriptu je soubor dat obsahující několik různých datových sad (viz Tabulka 4). Z výstupních dat jsou dále ve zpracování identifikace depresí využity pouze vektorové a textové soubory.

Tabulka 4 Výstupní data nástroje Delineate Catchment Hierarchy

Výstupní data nástroje Delineate Catchment Hierarchy	
Rastrová data	Popis
dem.tif	vstupní výškový model
dem_diff.tif	rozdílový výškový model
dem_filled.tif	výškový model se zaplněnými depresemi
depression_id.tif	rastr s hodnotami ID příslušné deprese
depression_level.tif	rastr s hodnotami úrovně deprese
depth.tif	rastr s hodnotami vypočtených hloubek příslušné deprese
median.tif	mediánový rastr
region.tif	rastr regionů depresí
sink.tif	rastr samostatných odečtených depresí
Vektorová data	Popis
depressions.shp	polygonová vrstva jednotlivých identifikovaných depresí s atributovou informací ID
regions.shp	polygonová vrstva identifikovaných regionů depresí (bez identifikace vnoření) s atributovou informací ID
Textová data	Popis
depressions_info.csv	atributové vlastnosti jednotlivých depresí
regions_info.csv	atributové vlastnosti regionů depresí

### Zpracování metody Wu1 pomocí skriptu lidar.py

Jak bylo výše uvedeno, dsikutovaný toolbox nebylo možné úspěšně aplikovat kvůli neidentifikované chybě. Z toho důvodu byla metoda Wu1 spuštěna pomocí samostatného skriptu v konzoly PyCharm (viz Obr. 11). Ačkoliv skript umožňuje a zároveň vyžaduje zadání vstupních parametrů pro identifikaci depresí o konkrétní minimální hloubce (ve veličině m), z neznámého důvodu uživatelsky nastavená hodnota minimální hloubky deprese nebyla aplikována a skript v praxi idetifikuje deprese všech hloubek. Selekcce kýžených depresí na základě požadovaných vlastností byla řešena v programu QGIS a je popsána dále v této kapitole.

V bakalářské práci je uvedeno, že metoda Wu1 je zde aplikována za účelem porovnání výsledků z dalších testovaných metod. Z toho důvodu vstupní parametr *min\_size*, definující minimální plochu identifikované deprese v e čtverečních metrech, byl nastaven na hodnotu 100 pro urychlení procesu zpracování. Parametr *interval* definuje interval

hloubky deprese v němž byly deprese rozřazeny na úrovně vnoření. Pro potřeby identifikace byl nastaven na hodnotu 0,2 (m). Soubor výstupních skriptu lidar.py dat je shodný s výstupními daty v Tabulka 4. Z výstupních dat jsou dále ve zpracování identifikace depresí využity pouze vektorové a textové soubory.

```

1 import os
2 import pkg_resources
3 from lidar import *
4
5 # identify the sample data directory of the package
6 package_name = 'lidar'
7 data_dir = r"C:\Users\dvv\Documents\Bakalářská_práce\dmr\"
8
9 # use the sample dem. Change it to your own dem if needed
10 in_dem = os.path.join(data_dir, 'MospremaDTM_50cm_5514.tif')
11 # set the output directory
12 out_dir = r"C:\Users\dvv\Documents\Bakalářská_práce\metody\Wu\metoda_Wu_DEM\outputs_whole_area"
13
14 # parameters for identifying sinks and delineating nested depressions
15 min_size = 100 # minimum number of pixels as a depression
16 min_depth = 0.3 # minimum depth as a depression
17 interval = 0.2 # slicing interval for the level-set method
18 bool_shp = True # output shapefiles for each individual level
19
20 # extracting sinks based on user-defined minimum depression size
21 out_dem = os.path.join(out_dir, "median.tif")
22 in_dem = MedianFilter(in_dem, kernel_size=3, out_file=out_dem)
23 sink_path = ExtractSinks(in_dem, min_size, out_dir)
24 dep_id_path, dep_level_path = DelineateDepressions(sink_path,
25                                                    min_size,
26                                                    min_depth,
27                                                    interval,
28                                                    out_dir,
29                                                    bool_shp)
30 print('Results are saved in: {}'.format(out_dir))

```

Obr. 11 Skript lidar.py s nastavenými vstupními parametry

### Postprocessing výstupních dat metody Wu1

Pro zmíněné nedostatky metody Wu1 bylo nutné výstupní data zpracovat do kýžené podoby manuálně. K tomuto účelu byl použit program QGIS (verze 3.38.0). Do programu QGIS byly nahrány výstupní vrstvy *depressions.shp*, *regions.shp*, *depressions\_info.csv* a *regions\_info.csv*. Vektorové vrstvy bylo nejprve nutné propojit s atributovými tabulkami pomocí shodného atributu *id*. Atributové propojení bylo provedeno v relaci 1 : 1. Vypočtené atributy depresí a regionů jsou znázorněny v náhledu na Obr. 12 a Obr. 13.

	A	B	C	D	E	F	G	H	I	J	K
1	id	level	count	area	volume	avg-depth	max-depth	min-elev	max-elev	children-i	region-id
2	1	1	177.0	74.78	0.67	0.01	0.03	230.85	230.87	[]	1
3	2	1	687.0	290.26	8.07	0.03	0.11	230.78	230.89	[]	2

Obr. 12 Náhled atributové tabulky vrstvy depressions.shp

	A	B	C	D	E	F	G	H
1	region-id	count	area	volume	avg-depth	max-depth	min-elev	max-elev
2	1	177.0	74.78	0.67	0.01	0.03	230.85	230.87
3	2	687.0	290.26	8.07	0.03	0.11	230.78	230.89

Obr. 13 Náhled atributové tabulky vrstvy regions.shp

Obě vrstvy obsahují další atributy, které nejsou zmíněny z důvodu jejich nevyužití při zpracování metody identifikace. Stěžejními atributy jsou *area* (plocha deprese nebo regionu v m<sup>2</sup>), *volume* (objem deprese nebo regionu v m<sup>3</sup>), *avg-depth* (průměrná hloubka deprese nebo regionu v m) a *max-depth* (maximální hloubka deprese nebo regionu v m). Bylo nutné dopočítat informaci ohledně úrovně deprese, zda se jedná o depresi vnořenou či nikoliv.

Prvním krokem pro naplnění daného cíle bylo propojit údaj o rozsahu plochy regionu ke každé entitě deprese, která pod region spadá. Propojení bylo opět provedeno na základě shodného atributového pole. Na stranách obou vrstev se jednalo o pole region-id. Propojení bylo provedeno v relaci 1 : 1, přeneseným atributem bylo zvoleno pole area z vrstvy regions.shp. Pro odlišení byl název ve vrstvě *depressions.shp* upraven na *regions\_area*. Následoval atributový výběr entit ve vrstvě *depressions.shp*. Entity se shodnou hodnotou area a region\_area byly označeny jako nevnořené, zbylé entity jako vnořené.

V této fázi bylo možné selektovat vhodně identifikované deprese pro potřeby zadaného účelu. Nejprve byly vyselektovány všechny nevnořené vrstvy s hodnotou maximální hloubky nižší než 0,07 (7 cm). Tyto deprese jsou příliš mělké a byly vyřazeny z vektorové vrstvy. Dále byly vyřazeny nevnořené deprese s hodnotou maximální hloubky nižší než 0,12 (12 cm) a zároveň hodnotou průměrné hloubky nižší než 0,06 (6 cm). Tím došlo k eliminaci identifikovaných rozsáhlých depresí s většinou hloubkou pod 0,07 a pouze lokálním maximem zvyšující hodnotu průměrné hloubky.

V dalším kroku byly do analýzy přidány vektorové vrstvy vodních ploch a toků (ZABAGED, Tabulka 2) pomocí nichž byly odstraněny deprese, které protínaly zmíněné vrstvy ZABAGED. Tímto krokem byly odstraněny identifikované deprese říčních toků, rybníků a nádrží, které nejsou ve výzkumném zájmu bakalářské práce.

Vektorová vrstva depression.shp byla uložena pro následné zpracování jejího porovnání s výstupními vrstvami dalších metod. Zároveň byla exportována atributová tabulka zmíněné vrstvy pro vytvoření přehledových statistik identifikovaných depresí pomocí metody Wu1.


Tabulka 5 Souhrnné statistiky identifikovaných depresí pomocí metody Wu1

<b>Metoda</b>	<b>Počet depresí</b>	<b>Počet vnořených depresí</b>	<b>Průměrná hloubka depresí (m)</b>	<b>Průměrná maximální hloubka depresí (m)</b>	<b>Rozloha depresí (m<sup>2</sup>)</b>	<b>Objem depresí(m<sup>3</sup>)</b>
Wu1	15709	1256	0,13	0,36	4241895	690337,94

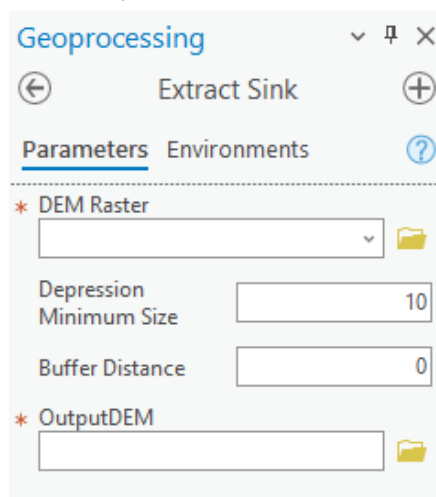
### 4.1.2 Identifikace pomocí Contour Tree Tools Public (Wu et al., 2018)

V druhém přístupu pro identifikaci byl použit toolbox *Contour Tree Tools Public* (dále jako Wu2) vytvořený pro použití v uživatelském prostředí softwaru ArcGIS Pro. Zmíněný nástroj identifikuje ze vstupního DMR pouze vnořené deprese, ve výstupní datové vrstvě se nevyskytují polygony reprezentující deprese úrovně 1. V případě, že je ve výstupní vrstvě samostatný polygon identifikující depresi bez žádné další v ní vnořené, znamená to, že solitérní deprese je vnořenou depresí jiné.

Toolbox obsahuje celkem dva skripty, *Extract Sink a Identify Depression Hierarchy* (viz Obr. 14). První z nich (viz Obr. 15) generuje rozdílový rastr mezi originálním a zaplaveným DMR, který reprezentuje detekované deprese na základě nastavených hodnot vstupního parametru

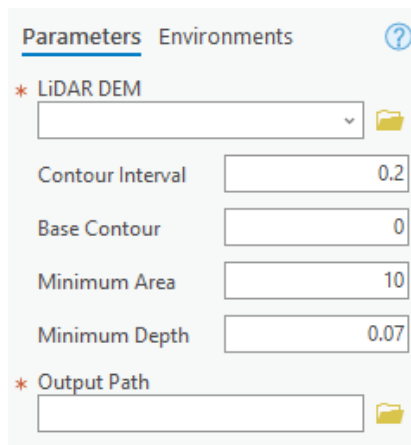


Obr. 14 Rozbalený toolbox Contour Tree Tools Public



Obr. 15 Nastavení vstupních parametrů skriptu Extract Sink

Depression Minimum Size, minimální rozlohy deprese (v m<sup>2</sup>). Tento parametr byl na základě potřeby nastaven na hodnotu 10. Parametr *Buffer Distance* na hodnotu 1. Výstupní rastr skriptu *Extract Sink* je vstupní vrstvou do následujícího skriptu toolboxu. V následujícím kroku byl použit druhý z nabízených skriptů, *Extract Depression Hierarchy* (viz Obr. 16).



Obr. 16 Nastavení vstupních parametrů skriptu Identify Depression Hierarchy

Hodnota prvního vstupního parametru *Contour Interval* byla nastavena na 0,2 (20 cm). Parametr určuje interval pro rozdělení vnořených depesí, hodnota byla nastavena shodně jako v případě metody Wu1. Hodnota druhého vstupního parametru *Contour Base Line* byla nastavena na 0 pro zajištění detekce vnoření depresí od úplného dna. Hodnota třetího vstupního parametru *Minimum Area* byla nastavena na 10 (10 m<sup>2</sup>). Parametr minimální hloubky, *Minimal Depth*, byl nastaven na hodnotu 0,07 (7 cm) jako při zpracování metody Wu1. Pole posledního uživatelsky volitelného parametru *Output Path* slouží k zadání cesty ke složce pro uložení výstupní vrstvy SHP reprezentující identifikované vnořené depese.

Výsledná vektorová vrstva depresí vytvořená metodou Wu2 ve svých atributech neobsahuje informace o hloubce jednotlivých depresí přepočtené na veličinu metrů. Průměrné i maximální hodnoty z oblasti rastru překrytým jednotlivými polygony zaznamenány jsou, avšak jedná se o hodnoty nadmořské výšky, nikoliv relativní výšky (viz Obr. 17).

FID	Shape *	Cont_ID *	FIRST_Cont	SUM_Lap_Ar	Line_Cou	Level_ID	Level_BD	Value	AREA	MIN	MAX	MEAN	
1	0	Polygon	11145	269.6	48.367626	1	1	1	11145	47	269.49054	269.625488	269.567395
2	1	Polygon	11704	269.4	101.503049	1	1	1	11704	99	269.111603	269.416077	269.307307
3	2	Polygon	11712	269.4	191.585423	1	1	1	11712	191	268.596313	269.437714	269.310212

Obr. 17 Náhled atributové tabulky výstupní vrstvy z metody Wu2

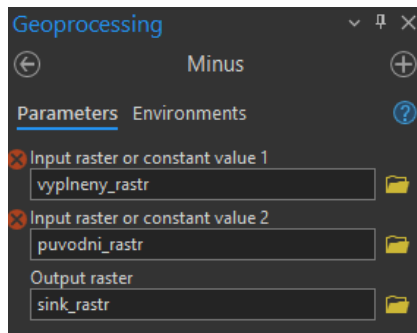
Tento nedostatek byl odstraněn spojením metody Wu2 s vlastním řešením identifikace pomocí laserových dat (viz kapitola 4.1.3). Obě zmíněné metody se svým přístupem doplňují a tvoří validní přístup pro využití v identifikaci vnořených depresí z DMR. Na závěr byly do analýzy přidány vektorové vrstvy vodních toků a ploch (ZABAGED, Tabulka 2) za účelem odstranění depresí identifikovaných na území vodních toků či ploch. Tyto depese nejsou relevantními pro kýžený výstup.

### 4.1.3 Identifikace spojením metod Wu2 a vlastního řešení

Přístup vlastního řešení problematiky identifikace povrchových depresí z laserových dat není automatizovaný v takové míře jako předchozí testované metody. Přesto tvoří ve spojení s metodou Wu2 (kapitola 4.1.2) efektivní metodu pro identifikaci povrchových propadlin. Shodně s ostatními metodami jsou vstupními daty rastr DMR a vektorové vrstvy vodních toků a ploch databáze ZABAGED (Tabulka 2). Vlastní řešení bylo řešeno v geoinformačním systému ArcGIS Pro. Proces identifikace je založen na nástrojích dostupných i v bezplatně dostupném programu QGIS.

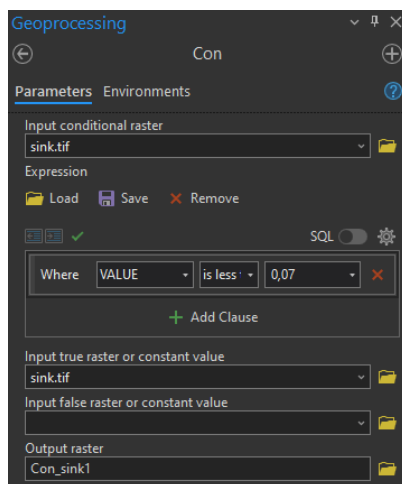
Prvním krokem vlastního řešení je použití nástroje *Fill* pro vytvoření rastru se zaplněnými povrchovými propadlinami. Hodnota vstupního parametru *Z limit*

je ponechána nevyplněna, její využití není relevantní. Vyplněný rastr vzniklý předchozím procesem je společně s původním rastrem DMR vstupem do výpočtu pomocí nástroje *Minus* (viz Obr. 18).



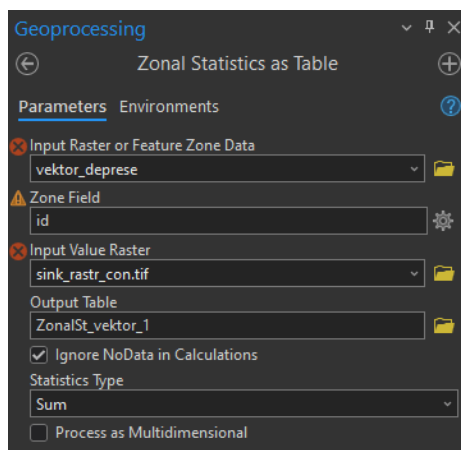
Obr. 18 Nastavení vstupních parametrů v nástroji Minus

Nástroj odečte vstupní vrstvy čímž vznikne rastr identifikovaných povrchových depresí. Jako první parametr v pořadí je vložen vyplněný rastr. Od něj je odečten původní rastr vložený do parametru druhé rastrové vrstvy. Použitím nástroje *Con* je zajištěna eliminace hodnot pixelů reprezentujících nedostatečnou hloubku, která byla pro potřeby práce stanovena na 0,07 m. Vstupní vrstvou do nástroje *Con* je výstupní rastr z předchozího kroku. Do pole logického výrazu pro provedení operace s hodnotami rastru je zadán výraz  $VALUE \leq 0,07$  (viz Obr. 19). Do posledního povinného pole pro zadání parametrů Input true raster or constant value je nahrána stejná vrstva jako do prvního parametru. Výsledkem provedení procesu nástroje *Con* je ořezání rastru o pixely s hodnotu nižší než je zadáno logickým výrazem. Před převedením rastrové reprezentace na vektorovou pro umožnění další práce s analyzovanými daty je nutné naplnit podmínku pro zmíněný převod. Podmínkou nástroje *Raster to Polygon* použitého pro vektorizaci rastru je datový typ vstupní vrstvy integer. Pro účel převodu rastru na požadovaný datový typ je nástroj *Int*. Výstupní vrstvou procesu je rastr přepočtený na hodnoty datového typu integer.



Obr. 19 Nastavení parametrů nástroje Con

Přepočtený rastr je nahrán jako vstupní vrstva do nástroje *Raster To Polygon*. Do parametru Field je vložena jediná dostupná hodnota rastru – *value*. Pro zachování přesnější prostorové reprezentace identifikovaných depresí byla možnost Simplify polygons ponechána nezaškrtnutá. Po spuštění nástroje *Raster To Polygon* byla vygenerována vektorová vrstva polygonů reprezentující jednotlivé deprese. Pro zjištění statistik o průměrné hloubce, maximální hloubce a objemu depresí byl použit nástroj *Zonal Statistics as Table* (viz Obr. 20).



Obr. 20 Nastavení parametrů nástroje Zonal Statistics as Table

Jako první parametr je vložena vektorová vrstva definující zóny pro výpočet statistik z hodnot rastru. Atributovým polem k němuž bude statistika připsána je zvoleno *id*. Jako vrstva rastru z níž je statistika počítána je nastaven rastr depresí vygenerovaný nástrojem *Con*. Pro výpočet průměrné hloubky je nastaven statistický typ *Mean*, pro zjištění maximální hloubky je nastaven statistický typ *Maximum*. Pro následující výpočet objemu je nutné provést zonální statistiku pomocí statistického typu *Sum*. Vygenerované tabulky se statistickými hodnotami jednotlivých polygonů jsou propojeny s polygonovou vrstvou na základě atributu *id* obou vrstev. Pro výpočet objemu jednotlivých depresí je hodnota zjištěná statistikou *Sum* vynásobena hodnotou prostorového rozlišení jednoho pixelu ve veličině metrů.

Stejný přístup výpočtu statistických hodnot z výstupního rastru nástroje *Con* je aplikován i na vektorovou vrstvu identifikovaných vnořených tůň pomocí metody *Wu2*. Tímto je odstraněn jeden z nedostatků zmíněné metody.

V této fázi je možné přejít k odstranění polygonů depresí s nežádoucími parametry identifikovaných vlastním přístupem pomocí výběru na základě atributových hodnot. Eliminace depresí s nízkou hodnotou hloubky byla provedena již pomocí nástroje *Con*. Na základě atributu *Shape\_AREA* byly odstraněny deprese s rozlohou menší než 10 m<sup>2</sup>. Po odmaskování depresí alespoň protínajících vektorové vrstvy vodních ploch a toků (*ZABAGED*, Tabulka 2) byla vyselektovaná vektorová vrstva reprezentující deprese uložena. Z vrstvy byla vygenerována atributová tabulka. Tabulka byla vygenerována i z vrstvy vnořených depresí. Díky textové formě mohly být propojeny navzájem se doplňující hodnoty z obou vrstev.



## 4.2 Porovnání dat z dronu a letadla

V této kapitole je věnován prostor porovnání identifikovaných depresí a jejich charakteristik při použití dvou datových sad odlišné geneze. První vstupní datovou vrstvou je DMR MospremaDTM\_50cm\_5514 přepočtený na prostorové rozlišení 10 cm/1 px. Druhou vstupní datovou vrstvou je DMR odvozený z laserových dat skenovaných dronem v rámci doplňkové letecké kampaně v okolí fotbalového hřiště u obce Střeň. Druhý zmíněný rastr má stejné prostorové rozlišení jako první zmíněný rastr, ale na rozdíl od prvního rastru byl v tomto rozlišení naskenován. První zmíněný rastr má nativní rozlišení 50 cm/1 px.

Identifikace povrchových depresí z výše zmíněných dat proběhla pomocí metody vlastního řešení (kapitola 4.1.3). Identifikovány byly deprese s rozlohou vyšší než 100 m<sup>2</sup>. Výsledné vektorové vrstvy jsou uloženy na fyzickém disku s digitálními přílohami. Porovnání atributů prostorových charakteristik identifikovaných depresí bylo provedeno v programu Microsoft Excel.

Tabulka 6 Porovnání výstupů identifikace depresí z dat letadla a dronu

Původ vstupního DMR	Počet identifikovaných depresí	Průměrná hloubka depresí (m)	Průměrná maximální hloubka depresí (m)	Rozloha identifikovaných depresí (m <sup>2</sup> )
Letecké skenování	11	0,179	0,433	9825
Skenování dronem	9	0,225	0,565	5821,6



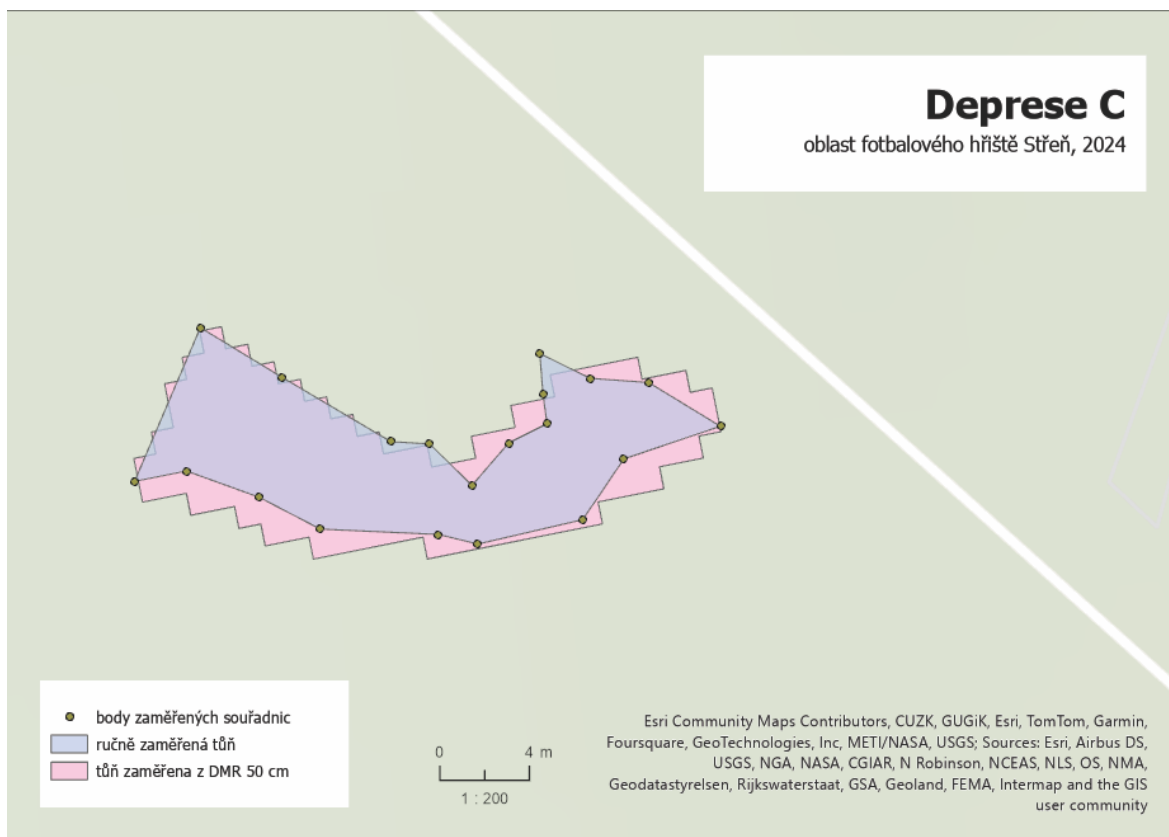
Obr. 21 Vizuální porovnání identifikovaných depresí z dat z dronu (vlevo) a letadla (vpravo)

## 4.3 Fyzické zaměřování depresí

Pro validaci automatických metod identifikování povrchových depresí bylo provedeno manuální fyzické měření v terénu. Ačkoliv k fyzickému měření nebyly využity nejpřesnější zaměřovací nástroje (jako je totální stanice), komparace dat identifikovaných depresí z různých zdrojů má přínos nejen pro validaci identifikace depresí z DMR, ale též prezentuje výhody automatické metody. Srovnání bylo založeno na porovnání hodnot maximální hloubky, naměřené délky mezi stanovenými body, rozsahu plochy deprese a překryvu polygonů souhlasných depresí.

Zájmové deprese zvolené pro porovnání se nacházejí v oblasti mezi obcemi Střen a Lhota nad Moravou. Deprese byly voleny na základě odlišností v rozsahu plochy, tvaru a otevřenosti terénu. Deprese A a C se vyskytují v oblasti s velmi hustým stromovým porostem. Deprese B se vyskytuje v otevřenějším prostoru, křovinný a stromový porost

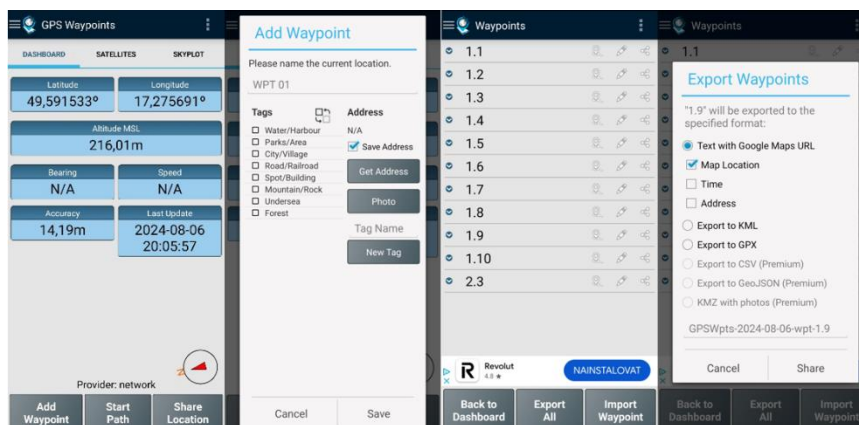
je v bezprostřední blízkosti tůně pouze z jedné strany. Fyzické měření proběhlo ve dne 17.05.2024.



Obr. 22 Porovnání zaměření deprese C (Zdroj: autorská tvorba)

Identifikované tůně se obecně nachází v zalesněných oblastech, v komplikovaném prostoru pro stabilní šíření signálu GPS. Z toho důvodu po diskuzi s vedoucím práce nebyla doporučena práce s totální stanicí, práce s mobilním zařízením s vestavěným GPS přijímačem byla uznána za dostačující. Záměrem porovnání automaticky detekovaných depresí s ručně zaměřenými bylo ověření jejich existence a validace vypočtených hodnot hloubky a plochy.

Pro zaznamenání souřadnic hran depresí byla využita aplikace GPS Waypoints (verze 3.12) volně dostupná ke stažení na platformách Google Obchod a AppStore. Aplikace nabízí základní bezplatnou verzi, která poskytuje měření bodových souřadnic či trasy (linie) a následný export dat ve formátu .GPX nebo .KML (Obr. 23). Zmíněné funkcionality bezplatné verze aplikace jsou pro účely zaměření hran depresí dostatečné a zpoplatněnou prémiovou verzi se širší nabídkou nástrojů nebylo nutné pořizovat.



Obr. 23 Uživatelské prostředí a měřicí nástroje využitě v aplikaci GPS Waypoints

Po fyzickém zaměření bodů podél hranic vytyčených depresí byla exportovaná data ve formátu .GPX převedena na vektorové body v softwarovém programu ArcGIS Pro, ve kterém byly vykonány i zbylé kroky procesu. Následovala tvorba liniového prvku hrany deprese z bodů pomocí nástroje *XY To Line*. Tento nástroj vytvoří linii z bodových souřadnic uložených v atributové tabulce. Tvorba linie začíná v bodě s nejnižší atributovou hodnotou ID a pokračuje vzestupně až propojí všechny body bodové vrstvy. Z toho důvodu je nutné dbát na uložení souřadnic v postupném pořadí, jak byly měřeny. Toto uspořádání bylo zajištěno označením měřených souřadnic vzestupnými čísly již při ukládání v aplikaci GPS Waypoints. Následujícím krokem bylo převést linie na polygon pomocí nástroje *Line To Polygon*. Zástupným prvkem automaticky identifikovaných depresí z DMR byly deprese identifikované pomocí vlastní metody (kapitola 3.1.3) s odpovídající polohou ve vztahu k ručně zaměřeným depresím. Tyto vybrané polygony již obsahovaly prostorové charakteristiky. Prostorové charakteristiky sloužící ke komparativní analýze maximální hloubka a délka deprese ve vyznačených bodech byly měřeny pomocí ručního laserového měřiče a měřičské tyče s vodováhou. Plocha deprese, ta byla vypočítána až z vytvořených polygonů v ArcGIS Pro. Kromě hodnoty překryvu souhlasných depresí, byly ostatní hodnoty porovnávaných vlastností připraveny v atributové tabulce každého z polygonů. Hodnota překryvu byla vypočítána pomocí nástroje XY, výsledky této analýzy jsou zobrazeny v Tabulka 7. Výsledné porovnání ostatních charakteristik je znázorněno v Tabulka 8.

Tabulka 7 Porovnání prostorových charakteristik zaměřených depresí I

<b>Ručně zaměřené deprese</b>	<b>Maximální hloubka (m)</b>	<b>Obvod (m)</b>	<b>Délka v místě měření (m)</b>	<b>Plocha(m<sup>2</sup>)</b>
A	0.88	38.79	14.14	61.97
B	1.5	76.33	25.3	312
C	0.77	66.97	19.64	113.51
<b>Algoritmem zjištěné deprese</b>				
a	0.91	50	14.74	86
b	0.82	78	23.68	199
c	0.62	82	19.32	144

Tabulka 8 Porovnání prostorových charakteristik zaměřených depresí II

<b>Hodnoty překryvu ručně a automaticky zaměřených depresí</b>		
<b>Shodný překryv (%)</b>	<b>Přesah abc (%)</b>	<b>Přesah ABC (%)</b>
69.10%	29.20%	1.70%
52.70%	39%	8.30%
73.40%	23.60%	3%

Z výsledků atributových vlastností polygonů zaměřených depresí vyplývá velká míra shody v hodnotách maximální hloubky, a délky ve stanoveném místě měření. Velké rozdíly v hodnotě rozsahu polygonu byly způsobeny náročným detekováním hrany deprese v terénu při ručním měření. V době měření zájmovou oblast pokrýval bylinný porost a bylo náročné zachytit reálnou hranu deprese. V opozici stojí fakt, že deprese detekované z DMR mohou mít hranu posunutou oproti skutečnosti z důvodu prostorového rozlišení digitálního modelu 50 cm/1 px. Zmíněné skutečnosti mají za důsledek rozdíly i v porovnání délky obvodu depresí a v tvarových odlišnostech.

#### **4.4 Identifikace komářích tůní z optických dat**

Předmětem zájmu následující kapitoly je testování zvolených klasifikačních metod optických dat. Metody byly zvoleny na základě rešerše. Všechny metody byly testovány v geoinformačním systému ArcGIS Pro (verze 3.1.1). Je zde popsán postup testování každé z metod. Na základě porovnání jejich efektivity byla určena metoda nejvhodnější pro využití ve výsledné metodice identifikace potenciálních komářích lůhnišť (

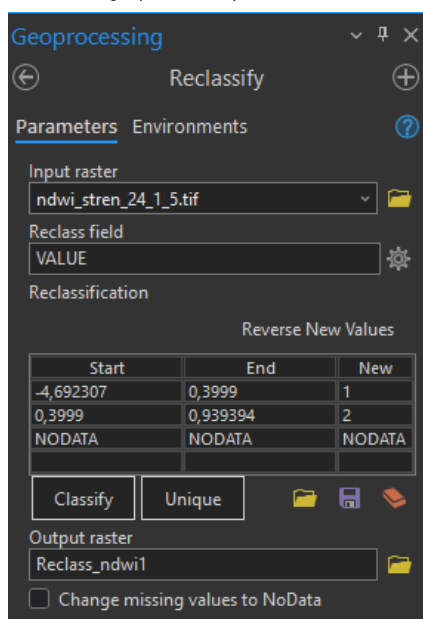
Z důvodu datové náročnosti bylo testování provedeno pouze na části zkoumaného území, konkrétně na snímcích z oblasti okolo obce Střeň a Lhota nad Moravou. Zmíněné území je zaznamenáno v pásmu RGB na rastrové dlaždici *Litovel\_1-5\_RGB.tif* a v pásmu NIR na rastrové dlaždici *Litovel\_1-5.tif*. Obě dlaždice byly vytvořeny v prostorovém rozlišení 10 cm/1 px.

V analýze byl použit též rastr vypočteného indexu NDWI (Rovnice 1). Výpočet byl proveden v programu QGIS (verze 3.38.0) pomocí nástroje Raster Calculator obsaženém v pluginu z knihovny GDAL. Do procesu vstupovaly dvě vrstvy. Jako vrstva A byl nahrán rastr se třemi barevnými kanály RGB zapojených v pravých barvách. Jako vrstva B byl nahrán rastr v pásmu NIR, který obsahoval pouze jeden barevný kanál. V rámci výpočetní rovnice bylo nutné ze vstupní vrstvy A vyselektovat pouze zelené pásmo, které je v pořadí druhé a v GDAL numerické syntaxi je proto nutné za název vrstvy doplnit výraz *\_2*, který implikuje použití pouze druhého pásma z nahrané vrstvy. Celý výpočetní příkaz v GDAL numerické syntaxi vypadal následovně:  $(A\_2 - B)/(A\_2+B)$ . Typ výstupního rastru byl nastaven na unsigned integer 16. Tímto krokem byla připravena všechna rastrová data potřebná k testování klasifikačních metod. Vzhledem k účelu identifikace tůní, které se nacházejí často v zahustěném terénu lužních lesů nebyly do statistiky uvažovány pixely identifikující vodní povrch řek či stojatých vodních ploch (rybníky, jezera, nádrže). Pro odmaskování těchto pixelů byly použity vrstvy vodních toků a ploch z databáze ZABAGED.

### 4.4.1 Klasifikace pomocí prahování rastru NDWI

První testovanou metodou bylo použití jednoduchého prahování hodnot rastru NDWI. Spektrální index NDWI slouží k identifikaci výskytu kapalné vody pomocí optických dat. Kapalná voda dosahuje v indexu specifických unikátních hodnot, díky čemuž je snadné automaticky odlišit pixely reprezentující vodní povrch a pixely reprezentující povrch jiné geneze. Rastr NDWI nabývá hodnot od -1 do 1. Pixely vyjadřující velmi vysokou pravděpodobnost výskytu vody mají hodnotu 0,4 a vyšší. (Xu, 2006)

V programu ArcGIS Pro byl použit nástroj *Reclassify* do něhož byla nahrána vrstva NDWI rastru a nastaveny vhodné parametry (Obr. 24).



Obr. 24 Nastavené parametry pro reklasifikaci rastru

Rozsahu hodnoty pixelů reprezentující vodní povrch byla připsána nová hodnota 2. Hodnota ostatních pixelů byla změněna na hodnotu 1. Po převodu na vektorovou vrstvu pomocí nástroje *Raster To Polygon* byly prostorovou selekcí vybrány a odstraněny polygony identifikující vodu, které se protínaly s vektorovými vrstvami vodních ploch a toků z databáze ZABAGED.

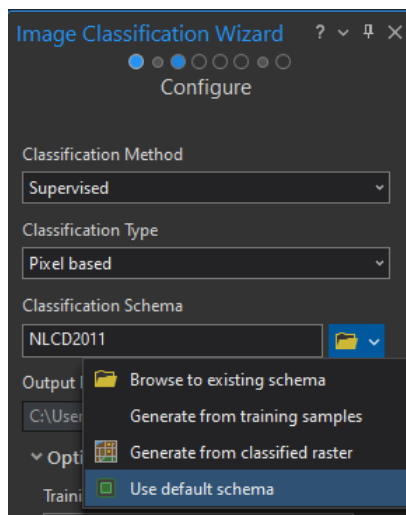
Následovalo validování přesnosti klasifikace touto metodou. Do mapového pole v ArcGIS Pro byla přidána vrstva identifikovaných depresí z DMR. Pomocí nástroje *Select By Location* byly vybrány polygony identifikovaného vodního povrchu, které se neprotínají s vrstvou identifikovaných depresí. Následnou vizuální analýzou bylo zjištěno, že pixely klasifikované jako voda neprotínající vektorovou vrstvu depresí skutečně náležely vodnímu povrchu, pouze v antropogenních nádržích (např. domácí bazény), které není možné identifikovat z DMR. Tímto způsobem bylo zjištěno, že žádný jiný povrch než vodní nebyl interpretován jako voda. Celková hodnota plochy identifikovaného vodního povrchu metodou prahování činila 2119,7 m<sup>2</sup>.

### 4.4.2 Klasifikace pomocí metody Random Forest

Druhá klasifikační metoda byla testována na snímcích v pásmu NIR a v pásmech RGB. Postup zpracování není odlišný v závislosti na vstupních datech, proto je v popisu ke vstupním datům referováno jako k rastru obecně.

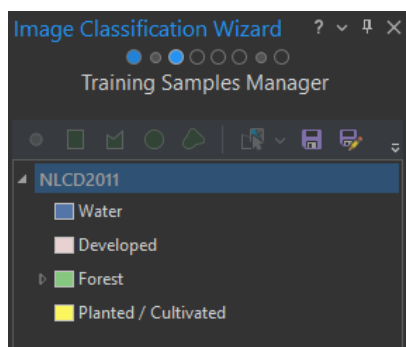
Prvním krokem bylo označení rastru ke zpracování v obsahové nabídce na levé straně uživatelského rozhraní ArcGIS Pro. Následným krokem bylo otevření toolboxu

*Classification Wizard* na záložce *Imagery*. Z nabídky klasifikačních metod byla vybrána řízená klasifikace *Supervised* a typem klasifikace byl zvolen přístup *per pixel*, v nabídce pod názvem *Pixel Based*. Následně bylo klasifikačním schématem zvoleno přednastavené schéma (*Use Default Scheme*), díky čemuž v dalším z kroků bylo umožněno vytvořit trénovací sadu dat pro klasifikaci. Příkladné nastavení parametrů je zaznamenáno na Obr. 25.



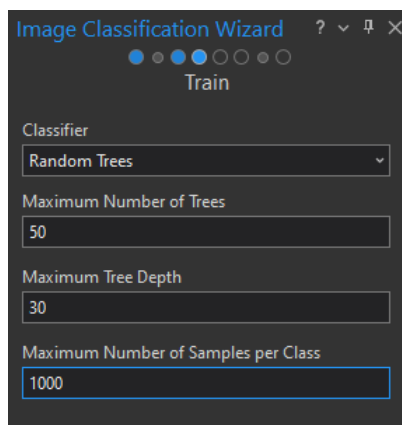
Obr. 25 Nastavení Image Classification Wizard pro metodu Random Forest

Po přejití na následující kartu následovalo vytvoření trénovací sady dat pro klasifikaci obrazu pomocí nástroje *Training Samples Manager* (Obr. 26). V tomto bodě byly nastaveny 4 třídy pro klasifikaci obrazu: voda, zástavba, les a pole. Poté byly vytvořeny polygony ke každé třídě nad územím obsahujícím příslušný povrch. Bylo důležité vytvořit dostatečný počet trénovacích oblastí s rovnoměrným rozložením po snímku. Ačkoliv zájmem klasifikace byly pouze vodní plochy, nastavení a naučení i dalších tříd zpřesní výslednou klasifikaci a schopnost algoritmu odlišit kýžené vodní plochy.



Obr. 26 Nastavení tříd trénovacích dat pro klasifikaci

Následným krokem bylo zvolení klasifikační metody *Random Forest*. Parametry metody byly ponechány v předem nastaveném stavu, jak doporučuje originální dokumentace k nástroji *Image Classification Wizard* (Obr. 27). Po spuštění klasifikace je vytvořen reklasifikovaný rastr na základě klasifikovaných tříd.



Obr. 27 Nastavení parametrů klasifikační metody Random Forest

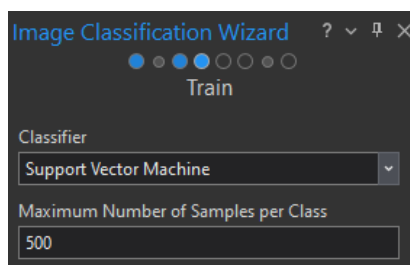
V závěru znovu následovaly kroky validace přesnosti klasifikace touto metodou. Nezbytným krokem byl převod rastru na vektorovou vrstvu pomocí nástroje *Raster To Polygon*. Nástrojem *Select By Location* byly vybrány polygony klasifikované třídy voda, které se neprotínají s vrstvou identifikovaných depresí z DMR. U rastru v pásmu NIR bylo následnou vizuální analýzou zjištěno, že byl značný počet pixelů špatně interpretován jako voda, ačkoliv ve skutečnosti náleží povrchu jiného původu. Zlepšení nepřinesla ani úprava parametrů metody Random Forest. Celková hodnota plochy identifikovaného vodního povrchu metodou Random Forest pro rastr v NIR je zaznamenána ve výsledkové tabulce (Tabulka 10). U analýzy rastru RGB došlo při klasifikaci k velkému množství chybných interpretací pixelů a z toho důvodu tyto statistiky nebyly považovány za relevantní a v tabulce se nevyskytují.

#### 4.4.3 Klasifikace pomocí metody Support Vector Machine

Vstupními daty testování poslední z klasifikačních metod byly snímky v pásmu NIR a v pásmech RGB. Postup zpracování není odlišný v závislosti na vstupních datech, z toho důvodu je v popisu ke vstupním datům referováno jako k rastru obecně.

Postup zpracování této klasifikační metody je shodný jako postup v klasifikaci pomocí metody Random Forest (kapitola 4.4.2) až do kroku nastavení a tvorby tříd trénovacích dat pro klasifikaci.

Po provedení kroků shodných s předešlou metodou následuje výběr klasifikační metody Support Vector Machine v panelu *Train*. Parametry metody jsou opět ponechány v předem nastaveném stavu, jak doporučuje originální dokumentace k nástroji *Image Classification Wizard* (Obr. 28).



Obr. 28 Nastavení parametrů klasifikační metody Support Vector Machine

Kroky validace přesnosti klasifikace touto metodou byly provedeny shodným postupem z předchozí kapitoly (4.4.2). Pevod rastru na vektorovou vrstvu byl proveden za pomoci nástroje *Raster To Polygon*. Nástrojem *Select By Location* byly vybrány polygony klasifikované třídy voda, které se neprotínají s vrstvou identifikovaných depresí z DMR. U rastru v pásmu NIR bylo následnou vizuální analýzou zjištěno, že byl značný počet pixelů



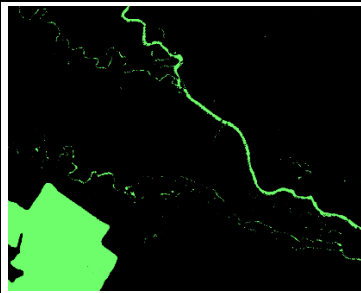
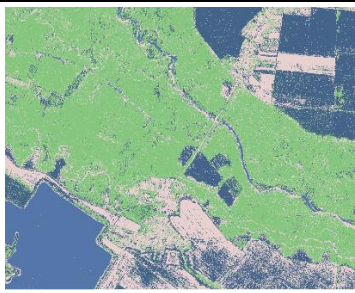

špatně interpretován jako voda, ačkoliv ve skutečnosti náleží povrchu jiného původu. Pozitivní změna nenastala ani po úpravě parametrů klasifikační metody Support Vector Machine. Celková hodnota plochy identifikovaného vodního povrchu metodou Support Vector Machine pro rastr v NIR je zaznamenána ve výsledkové tabulce (Tabulka 10). U analýzy rastru RGB došlo opět při klasifikaci k velkému množství chybných interpretací pixelů a z toho důvodu tyto statistiky nebyly považovány za relevantní a v tabulce se nevyskytují.

#### 4.4.4 Interpretace výsledků testovaných metod

Na základě porovnání výsledků jednotlivých klasifikačních metod (Tabulka 10), které byly provedeny nad vstupními daty v různých konfiguracích, byl označen za nejefektivnější a nejpřesnější způsob identifikace komářích tůní klasifikací rastru NDWI pomocí metody prahování. Tuto metodu nebylo možné aplikovat na zbylé konfigurace dat z důvodu zaměnitelných hodnot pixelu reprezentujících vodní povrch s pixely reprezentujícími povrch jiné geneze. Výsledky prokázaly značnou efektivitu a nepostradatelnost rastru zobrazujícím hodnoty vypočteného indexu NDWI při identifikaci vodních ploch.

Náhled výstupní data v podobě klasifikovaných rastrů ze všech testovaných metod je pro porovnání zaznamenán v Tabulka 9. Možné důvody nevhodnosti využití zmíněných klasifikačních metod nad snímky v RGB jsou popsány v kapitole Testování limitů optických dat 4.5.1.

Tabulka 9 Náhled výstupních rastrů z klasifikačních metod optických dat

<b>Náhled výstupních dat z klasifikačních metod</b>		
Metoda prahování, rastr NDWI	Metoda Support Vector Machine, rastr RGB	Metoda Support Vector Machine, rastr NIR
		
Zelená barva reprezentuje vodní plochy	Modrá barva reprezentuje vodní plochy	Modrá barva reprezentuje vodní plochy
Z rastrových výstupů nejsou vymaskovány vodní plochy a toky prostorově korelující s použitými vrstvami ZABAGED		



Tabulka 10 Porovnání klasifikačních metod optických dat

<b>Identifikovaný vodní povrch z optických dat v oblasti Střeň</b>			
<b>Metoda</b>	<b>Použitá pásma</b>	<b>Identifikovaná vodní plocha (m<sup>2</sup>)</b>	<b>Poznámka</b>
Klasifikace pomocí NDWI, prahování	zelené + NIR	2119.7	nejvhodnější
Řízená klasifikace Random Forest	NIR	4848,33	klasifikovány i neodpovídající body
Klasifikace Support Vector Machine	NIR	4074,83	klasifikovány i neodpovídající body
Řízená klasifikace Random Forest	RGB	x	velmi nepřesné
Klasifikace Support Vector Machine	RGB	x	velmi nepřesné

## 4.5 Testování limitů dat

Jedním z dílčích úkolů této bakalářské práce je otestování a stanovení limitů pro sady použitých dat v otázce identifikace komářích tůní. Tato sekce je rozdělena do dvou částí. První z nich je věnovaná testování a stanovení limitů optických dat. V druhé části je věnován prostor testování a stanovení limitů laserových dat.

### 4.5.1 Testování limitů optických dat

Prostor v následující kapitole je věnován testování limitů optických dat. Záměrem autora bylo zjistit faktory ovlivňující kvalitu identifikace tůní pomocí optických dat. Hypotézou byly stanoveny jako zásadní limitující faktory zastínění a husté olistění stromů. Autor se pomocí testování různých konfigurací dat snažil zjistit možnosti odstranění či snížení těchto limitů. Limity dat snímaných v RGB a NIR jsou odlišné od limitů dat v NDWI.

#### Limity dat v RGB a NIR

Pro zjištění limitů optických dat posloužily výsledky testování klasifikačních metod obrazových dat (kapitola 4.4.4), kterými bylo dokázáno, že aplikace automatických klasifikačních metod nad daty v RGB je vysoce chybová. Po analýze snímků v oblastech využitých pro trénování klasifikačního algoritmu byla zjištěna častá proměnlivost v hodnotách pixelů vodního povrchu tůní. Nestálost je způsobena výskytem různých napadaných objektů do tůní (větve, listy), přítomností částí kmenů a větví ve vymezené oblasti trénovacích pixelů a také vržených stínů okolními objekty. Tyto faktory ovlivňují barevné hodnoty pixelů, které nejsou unikátní pro povrch tůní, čímž dochází k nesprávné klasifikaci i na místech, kde se tůně nevyskytují.


U rastru NIR byly vržené stíny také překážkou pro přesnou klasifikaci obrazu. V tomto případě nebyla chybovost tak vysoká, jelikož barevné hodnoty pixelu vody v samostatném pásmu NIR nejsou zaměnitelné s pixely prezentujícími jiné povrchy.

V zájmu snížení či odstranění některých z uvedených limitů byla rastrová data RGB podrobena analýze při různých konfiguracích zapojení barevných kanálů (Tabulka 11).

Tabulka 11 Konfigurace dat RGB pro zjištění limitů

<b>Testování možností identifikace komářích tůní pomocí viditelného spektra RGB</b>	
<b>Kombinace</b>	<b>Výhoda</b>
1R 2G 3B	/
1G 2R 3B	/
1R 2B 3G	/
1G 2B 3R	Lepší viditelnost ve stinných místech při manuální klasifikaci
1B 2R 3G	/
1B 2G 3R	/
<i>Pozn.: Číslice odpovídají kanálům zapojení v rastru a písmena příslušným barevným pásmům</i>	

Analýza byla provedena v programu ArcGIS Pro na základě vizuálního porovnání rastrů při různém zapojení barevných pásem do kanálů rastru. Na základě tohoto procesu byla zjištěna výhoda potlačení limitu zastínění při zapojení pásem způsobem 1G 2B 3R. (Obr. 29) U ostatních limitů nedošlo k objevení metod pro jejich odstranění ani snížení jejich efektů.



Obr. 29 Konfigurace snímku v RGB (zapojení kanálů řazeno od levého horního snímku: 1R 2G 3B; 1G 2B 3R; 1G 2R 3B; 1R 2B 3G; 1B 2R 3G; 1B 2G 3R)

### **Limity dat NDWI**

V případě rastru vypočteném pomocí předepsané rovnice (Rovnice 1) ze zeleného a blízkého infračerveného pásma vržené stíny neovlivňují kvalitu klasifikace vodního povrchu. Důkazem je porovnání výřezu snímku se zastíněnou oblastí povrchu vody v RGB a snímku s překryvnou vektorovou vrstvou (zelené barvy) reprezentující oblast klasifikovanou jako vodní povrch pomocí prahovací metody rastru NDWI (Obr. 30).



Obr. 30 Demonstrace nelimitace NDWI snímku vrženými stíny

Výskyt cizích objektů v zatopených tůňkách, husté olistění stromů zabraňující průchodu elektromagnetického vlnění v optickém spektru a výskyt částí kmenů a větví rostoucího porostu ve vymezeném území trénovací množiny pixelů jsou nepřekonatelnými limitujícími faktory.

#### 4.5.2 Testování limitů laserových dat

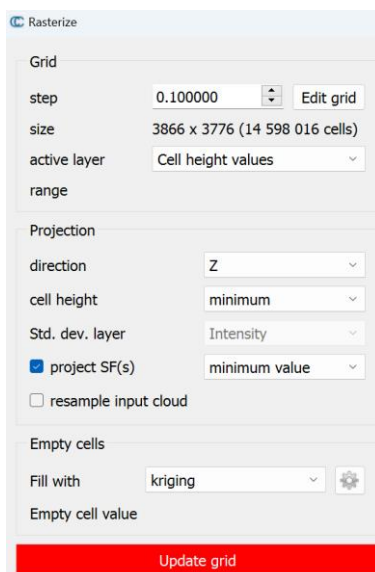
Prostor v následující kapitole je věnován testování limitů laserových dat. Analýza byla provedena nad daty ve formě bodového mračka ve formátu LAS. Testovacím územím byla zvolena oblast poblíž fotbalového hřiště obce Střeň. Zmíněná oblast byla skenována pomocí dronu v rámci doplňkového skenování. Díky tomu bylo možné provést testování dat stejného území získaných dvěma různými způsoby, celoplošným leteckým skenováním a výše zmíněným doplňkovým skenováním dronem.

Testování bylo zaměřeno na hustotu bodového mračka v oblastech depresí a hledání hraniční hodnoty počtu bodů na ploše 1 m<sup>2</sup> dostačujícího k identifikaci povrchové deprese. Pro zpracování bodových mraček ve formátu LAS byl použit software Cloud Compare ve verzi 2.13.2 (Tabulka 3). Pro porovnání zpracovaných dat byla použita vlastní identifikační metoda (kapitola 4.1.3) v programu ArcGIS Pro. Vstupními daty byly dva soubory bodových mraček ve formátu LAS. První z nich vznikl doplňkovým skenováním pomocí dronu. Druhý z nich vznikl celoplošným leteckým skenováním, na základě shodné části s územím skenovaným dronem byla příslušná část vyříznuta. Při zpracování bylo nakládáno se zmíněným výřezem. Postup zpracování obou datových sad byl totožný, z toho důvodu je ke vstupním laserovým datům dále referováno obecně jako k bodovému mračku. Do analýzy vstupovaly vektorové liniové vrstvy (SHP) reprezentující území vybraných identifikovaných depresí do vzdálenosti dvou metrů od jejich hrany. Deprese byly vybrány z výstupních dat identifikovaných depresí pomocí vlastní metody na základě různorodosti tvarů.

Prvním krokem bylo ověření shodného koordinačního systému všech vstupních dat. Do prostředí Cloud Compare byl načten soubor bodového mračka a vektorové vrstvy ohraničení vybraných depresí. Následovalo vyselektování tzv. ground points, tedy bodů náležících povrchu reliéfu. Tento krok byl proveden pomocí nástroje *CSF Filter*. Parametr *Cloth resolution* byl nastaven na hodnotu 0,1 (za účelem generování rastru v rozlišení 10 cm/1 px v jednom z následujících kroků). Maximální počet iterací byl nastaven na 1000 a klasifikační threshold na polovinu hodnoty *Cloth resolution*. Výstupem tohoto nástroje bylo rozdělení bodového mračka na jednotnou sadu ground points a jednotnou sadu zbylých bodů. Dále bylo nakládáno pouze s vrstvou ground points. Zároveň byl vytvořen mesh, spojitá plocha vytvořená triangulací bodů ground points.

V rámci dalšího kroku bylo provedeno čištění ground points mračka pomocí čistícího nástroje *Noise Filter* pro odstranění statisticky odlehklých bodů v definovaném radiusu.

Hodnota radiusu byla nastavena na 0,1 m. Z takto připravených dat bylo možné přejít k tvorbě DMR pomocí nástroje *Rasterize* z nástrojové sekce *Projection*. Parametry procesu byly nastaveny dle Obr. 31.



Obr. 31 Nastavení nástroje Rasterize pro tvorbu a export DMR

Vytvořený digitální model byl exportován ve formátu .tif. Tento model posloužil pro provedení identifikace depresí za pomoci vlastní řešení (kapitola 4.1.3) a pro porovnání s následně vytvořenými modely z bodových mračen s nižší distribuční hustotou bodů.

V následujícím kroku bylo pracováno s vyčištěným bodovým mračnem ground points a vektorovými vrstvami ohraničení oblastí depresí. Pomocí nástroje Set Top View v panelu nástrojů připnutém na levé straně uživatelského prostředí bylo zajištěno přesné zarovnání všech vrstev pro zaručení přesné extrakce bodů. Body náležící do jednotlivých ohraničených území liniiovými vrstvami vektorů byly extrahovány pomocí nástroje Segment. Rozsah ořezu byl nastaven jednotlivými vektorovými vrstvami. Po provedení ořezu byla ponechána vnější i vnitřní ořezová vrstva. Tímto způsobem vznikla „děravá“ vrstva ground points s chybějícími body ve vymezeném území vyznačených depresí. K využití této vrstvy došlo v závěrečných krocích testování. Dále byly vytvořeny ground points mračna jednotlivých depresí.

Jednotlivé ground points mračna depresí byly podrobeny výpočtu lokální statistiky pro zjištění počtu bodů v ploše 1 m<sup>2</sup>. Toho bylo docíleno statistickým nástrojem Local Statistical Test při nastavení radiusu na hodnotu 1. Tím byla zjištěna bodová hustota pro každou depresi a byla zanesena do tabulky. Následně byly vypočteny snížené hodnoty hustoty oproti originálním a to v objemu 75 %, 50 %, 25 % a 10 % z původní naměřené hodnoty. Tyto hodnoty byly opět zaneseny do tabulky a byly využity v následujících krocích.

V následujícím kroku byla mračna ground points jednotlivých depresí převedena na spojitou plochu mesh pomocí nástroje *Compute 2.5 Volume* z nástrojové sekce *Volume*. Následně byly vygenerovány body ve snížených hustotách nad spojitými vrstvami mesh pomocí nástroje *Sample Points on a Mesh*. Požadovaná hustota bodů byla zadána do parametru nástroje. Tímto způsobem byly vygenerovány 4 ground points mračna bodů ve snížené hustotě pro každou depresi.

Jednotlivá mračna ground points depresí se shodným procentuálním snížením hustoty byla připojena k „děravé“ vrstvě mračna bodů zbylého zkoumaného území. Sloučení vrstev bylo docíleno pomocí označení patřičných dat v nabídce připojených vrstev, následným

kliknutím pravým tlačítkem a spuštěním nástroje *Merge* z nabídky. Tento proces byl zopakován celkem čtyřikrát pro všechny hustotní kategorie bodových mračen.

Finálním krokem bylo vygenerování DMR z nově vzniklých bodových mračen. Tento postup je popsán výše v této kapitole. Exportovaná data ve formátu .tif byla dále zpracována vlastní identifikační metodou (kapitola 4.1.3) a prostorové charakteristiky identifikovaných depresí ze všech vytvořených DMR byly porovnány.

V rámci oblastí jednotlivých vrstev depresí byla naměřena vysoká hustota bodů, z toho důvodu v identifikaci většiny depresí nebránilo ani snížení na 50% hustotu. Až při nastavení hustoty bodů na v rozsahu 5 až 10 v rámci plochy 1 m<sup>2</sup> nebylo možné deprese identifikovat v dostačující kvalitě. Tato hodnota hustoty bodového mračna se vyskytuje v sadách laserových dat skenovaných pomocí letadla i dronu. Výjimečně se vyskytují hustě zalesněná místa, kde je hustota bodů v mračnu nižší.

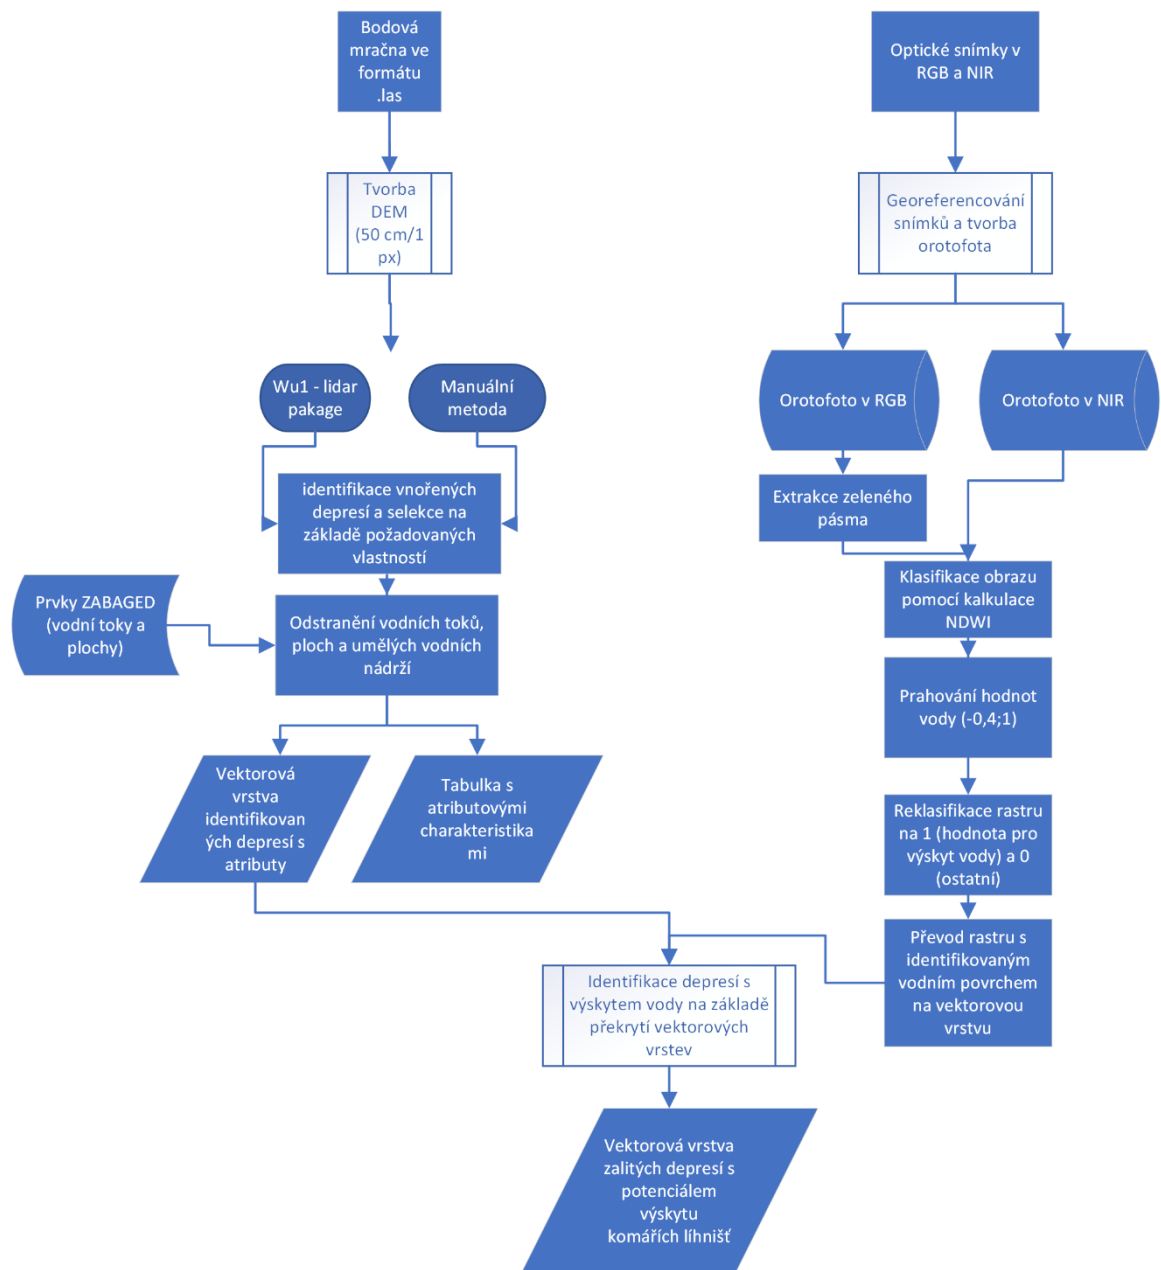
## 5 VLASTNÍ ŘEŠENÍ II

Následující kapitola je samostatně vyčleněna pro přehledný popis výsledné metodiky identifikace potenciálních komářích líhnišť pomocí laserových a optických dat. Zmíněný výstup je považován za hlavní cíl bakalářské práce. Výsledná metodika, která je porovnáním s dalšími přístupy zmíněnými v této bakalářské práci uznána za nejeftektivnější z nich, je sestavena ze dvou oddělených komplexních souborů metod.

První z nich se věnuje identifikaci uzavřených povrchových depresí z laserových dat. Tím jsou vytyčena zájmová území s potenciálem zatopení vodou, čímž dochází ke vzniku přivětivého habitatu pro kladení larev komárovitých druhů. Zmiňovaný soubor metod využívá přístup popsán v kapitole 4.1.3. Výstupem procesu je vektorová vrstva polygonů identifikovaných depresí s atributovými daty, které popisují jejich prosotorvé charakteristiky.

Druhý soubor metod je vytvořen k účelu identifikace zatopených oblastí z optických dat v pásmech RGB a NIR. Testováním různých konfigurací dat a způsobů metod klasifikace obrazu byl zjištěn největší přínos využití dat zeleného a blízkého infračerveného pásma. Kombinací zmíněných pásem je dosaženo výpočtu spektrálního indexu NDWI (Rovnice 1), který usnadňuje identifikaci vodního povrchu z hodnot vypočteného rastru. Klasifikace byla provedena pomocí metody prahování. Detailní popis způsobu identifikace zatopených oblastí za pomoci zmíněného přístupu je uveden v kapitole Klasifikace pomocí prahování rastru NDWI. Výstupními daty jsou opět vektorové vrstvy polygonů vzniklé převodem pixelů rastru indikujících výskyt vodního povrchu.

V závěru dochází k syntéze výstupních dat v programu QGIS či ArcGIS Pro. Pomocí nástroje výběru na základě polohy jsou označeny polygony identifikovaných depresí, které alespoň protínají polygony identifikovaného vodního povrchu. Tyto vybrané polygony vyznačují konkrétní deprese, které jsou v čas optického snímkování zality vodou a vytváří tak přivětivý habitat pro výskyt komářích líhnišť. Vývojový diagram popisující kompletní postup výsledné metodiky je znázorněn na Obr. 32.



Obr. 32 Vývojový diagram postupu zpracování výsledné metodiky



## 6 VÝSLEDKY

Stěžejním výstupem této bakalářské práce je vypracovaný návrh metodiky pro identifikování potenciálních komářích lůhnišť pomocí laserových a optických dat. Pracovní postup metodiky je znázorněn vývojovým diagramem (viz Obr. 32). Detailní popis dílčích kroků, ze kterých je metodika složena, je uveden v sekci práce Vlastní řešení I (kapitola 4). Analýzou dat vzniklých celoplošným skenováním byl identifikován počet a poloha depresí, které mají při zatopení vodou potenciál stát se vhodným prostředím pro kladení komářích larev. Překryvem vrstvy identifikovaných vodních ploch pomocí klasifikace optických dat v pásmech RGB a NIR je možné lokalizovat zatopené deprese s potenciálním výskytem komářích lůhnišť. Analýzou optických dat pořízených v březnu 2023 bylo identifikováno na zkoumaném území CHKO Litovelského Pomoraví celkem 1772 depresí obsahujících vodu (viz Tabulka 12). Analýzou dat pořízených v lednu 2024 bylo identifikováno na zkoumané území celkem 7112 depresí obsahující vodu (viz Tabulka 12). Vektorové vrstvy polygonů zmíněných identifikovaných depresí jsou součástí příloh bakalářské práce uložené ve formátu SHP. Každý z polygonů obsahuje atributová data o průměrné hloubce, průměrné maximální hloubce a objemu reprezentované deprese.

Tabulka 12 Přehled výsledků identifikace pomocí vypracované metodiky

<b>Identifikovaná plocha vody na území depresí v březnu 2023 (m<sup>2</sup>)</b>	147199.5
<b>Identifikovaná plocha vody na území depresí v lednu 2024 (m<sup>2</sup>)</b>	598223.6
<b>Celkový počet identifikovaných depresí z laserových dat</b>	50192
<b>Počet depresí s obsahem vody v březnu 2023</b>	1772
<b>Počet depresí s obsahem vody v březnu 2024</b>	7112

Další výsledky bakalářské práce vzešly z testování a stanovení limitů laserových a optických dat pro účely identifikaci komářích lůhnišť. Této problematice se detailně věnuje podkapitola 4.5 v sekci Vlastní řešení I. U obou typů testovaných byl limitujícím faktorem stanoveno husté olistění porostu na území tůň, které komplikovalo průchod paprsků světla pro optimální zaznamenání povrchu reliéfu. Tento faktor byl menším limitem pro laserové skenování. Testováním byla stanovena limitní hodnota hustoty bodového mračna pro možnost kvalitní identifikace povrchové deprese. Limitní hodnota se nachází v rozsahu 5 až 10 bodů na plochu 1 m<sup>2</sup>.

Dalšími zjištěnými limity optických dat jsou vržený stín a výskyt nehomogenních objektů v zatopených tůňkách (větve, listy, odpad). Oba faktory na optických snímcích mění barevnou hodnotu pixelu, což znesnadňuje řízenou klasifikaci obrazových dat. Stín není limitujícím. Zobrazení optických dat pomocí spektrálního indexu NDWI, složeného ze zeleného a blízkého infračerveného pásma, je limitace stínem eliminována. Důkazem je porovnání výřezu snímku se zastíněnou oblastí povrchu vody v RGB a snímku s překryvnou vektorovou vrstvou (zelené barvy) reprezentující oblast klasifikovanou jako vodní povrch pomocí prahovací metody rastru NDWI (Obr. 33)





Obr. 33 Demonstrace nulového vlivu vrženého stínu při klasifikaci rastru NDWI

Testováním různých konfigurací zapojení barevných kanálů RGB rastru byl zjištěn jeden konkrétní způsob, který snižuje efekt limitu vrženého stínu. (viz Tabulka 13)

Tabulka 13 Konfigurace dat RGB pro zjištění limitů

<b>Identifikovaný vodní povrch z optických dat v oblasti Střeň</b>			
<b>Metoda</b>	<b>Použitá pásma</b>	<b>Identifikovaná vodní plocha (m<sup>2</sup>)</b>	<b>Poznámka</b>
Klasifikace pomocí NDWI, prahování	zelené + NIR	2119.7	nejvhodnější
Řízená klasifikace Random Forest	NIR	4848,33	klasifikovány i neodpovídající body
Klasifikace Support Vector Machine	NIR	4074,83	klasifikovány i neodpovídající body
Řízená klasifikace Random Forest	RGB	x	velmi nepřesné
Klasifikace Support Vector Machine	RGB	x	velmi nepřesné

## 7 DISKUZE

### 7.1 Problematika identifikace pomocí laserových dat

Nejzásadnější problém při zpracování zadání bakalářské práce nastal v situaci, kdy byla provedena rešerše přístupů identifikace povrchových depresí analýzou laserových dat ve formě bodových mračen. Studií, zabývajících se zmíněným postupem, neexistuje velké množství. Nejčastěji bývají bodová mračna laserových dat pro potřeby identifikace povrchových změn převedena na výškové modely (DEM) a následné analýzy jsou vykonány s daty rastrové reprezentace povrchu terénu. Nevšední přístup je zvolen v práci *Automated extraction of ground surface along urban roads from mobile laser scanning point clouds* (Wu et al., 2015), ve které byl popsán automatizovaný procese extrakce povrchu terénu z hustých bodových mračen získaných pomocí mobilního laserového skenování (MLS). Terén v této studii představuje městské prostředí se zástavbou a dopravní infrastrukturou. Cílem procesu je automatická extrakce bodů reprezentujících povrch silnice. Extrakce s mírou chybovosti pouhých 1,9 % je docílena dvěma způsoby:

1) Algoritmem adaptivních alfa tvarů:

- Alfa tvary jsou geometrickým nástrojem, který slouží k nalezení obrysů bodových sad. Tradiční alfa tvary jsou vylepšeny adaptivní verzí, která dynamicky upravuje své parametry podle hustoty bodů v sadě.
- Tento adaptivní algoritmus využívá parametr  $\alpha$  pro řízení úrovně detailu obrysů bodové sady. Při práci se sadami bodů vypočítává algoritmus vzdálenosti mezi sousedními body a podle toho upravuje velikost obrysu.

2) Filtrem variace výšky:

- Po extrakci kandidátních bodů terénu pomocí adaptivního algoritmu alfa tvarů je použit filtr variace výšky pro zjemnění těchto bodů.
- Tento filtr porovnává sklon mezi třemi sousedními body a zajišťuje, zda jsou body se značným výškovým rozdílem považovány za body terénu.

Zmíněné algoritmy strojového učení je možné použít například pomocí skriptovacího jazyka Python či softwaru MATLAB. Vzhledem k autorovy neznalosti principů fungování algoritmů strojového učení nebyl tento přístup zařazen do metod zpracování. Vystává zde také otázka, s jakou mírou chybovosti by byly algoritmy schopné detekovat, oproti rovným silnicím, geometricky složitější povrchy depresí v hustém porostu lužních lesů. Na základě těchto důvodů byla analýza laserových dat v bakalářské práci provedena nad odvozeným digitálním modelem.

### 7.2 Problematika identifikace pomocí optických dat

Využití optických dat v elektromagnetickém spektru RGB a NIR bylo ověřeno jako dostačující pro potřeby identifikace tůní s potenciálem výskytu komářích líhnišť. Pro potřeby detekce reálného výskytu komářích líhni v zatopených depresích jsou možnosti zmíněných spekter vyčerpány. Nezpochybnitelný přínos by zajistilo zapojení více multispektrálních pásem, jako je například SWIR (short-wave infrared), do procesu klasifikace obrazu. Začlenění pásma SWIR by rozšířilo možnosti výpočtů spektrálních indexů, které umožňují identifikaci vody na základě chemických vlastností. V případě zjištění určitých nezaměnitelných chemických charakteristik vody způsobených přítomností komářích larev by mohlo dojít k definici hodnoty zjistitelné pomocí některým spektrálním indexem. Nastíněná analýza by vyžadovala spolupráci hydrologů pro zajištění

chemického rozboru vody. O obdobném přístupu je pojednáno ve studii *Mapping mosquito larval densities and assessing area egypt* (Nagy et al., 2021). Vědecké práci egyptského týmu expertů je věnován prostor v rešeršní části bakalářské práce (viz kapitola 2.9.2).

## 8 ZÁVĚR

Hlavním účelem bakalářské práce bylo otestování a vytvoření efektivních postupů pro identifikaci komářích láníšť s využitím laserových a optických dat. Rešerší i praktickým testováním bylo zpočátku práce zjišřeno, že za pomoci dostupných dat není možné identifikovat tůně s aktuálním výskytem komářích láníšť. Výskyt tůní s potenciálem existence komářích láníšť je identifikovatelný vícero způsoby. Vzhledem k nestálosti komářích láníšť je identifikace míst s potenciálem lánnutí komářích jedinců velmi přínosná a naplňuje stěžejní vytyčený cíl bakalářské práce. Zjišřeno bylo více způsobů pro identifikaci a byly popsány výhody a nevýhody jednotlivých přístupů.

Fyzickým, manuálním, zaměřením vybraných depresí byly validovány metody automatické a byla potvrzena jejich efektivita a přesnost.

Ačkoliv byla vyvinuta velká snaha při testování možností identifikace povrchových depresí analýzou laserových dat ve formě bodových mračen, výsledek zmíněného testování nelze prohlásit za pozitivní. Důkladnou rešerší byly nalezeny metody pro daný účel využívající složité algoritmy strojového učení, o kterých autor práce nemá dostatečné znalosti pro jejich použití. Po snaze porozumět základům problematiky identifikace povrchových depresí z bodového mračna pomocí metod strojového učení, došel autor k závěru, že využití zpracovaných laserových dat do podoby digitálního modelu reliéfu je, z hlediska výpočetní náročnosti a dostupnosti nástrojů pro zpracování, efektivnějším přístupem. Tato rešerší zjišřená informace je považována za jeden z validních výstupů korelující se zadanými cíly práce.

Testováním odlišných konfigurací a limitů optických dat pro identifikaci zatopených depresí, potenciálních tůní s komářími láníšťi, byly potvrzeny autorovy hypotézy. Hlavními limity optických dat jsou zastínění a husté olistění stromů. Stíny se stávají limitem v případě použití pouze RGB dat pro klasifikaci, kdy znemožňují určit původ povrchu v zastíněných oblastech. Husté olistění stromů je problémem i při využití dat v blízkém infračerveném pásmu (NIR) jelikož znemožňují zachycení povrchu reliéfu pod nimi. Při dostupnosti optických dat v červeném, zeleném, modrém a blízkém infračerveném (RGB a NIR) spektrálním pásmu byla identifikace provedena nejpřesněji při použití kombinace zeleného a blízkého infračerveného pásma. Z těchto pásem byl vypočten spektrální index *Normalized Difference Water Index* (NDWI). Prahováním hodnot byly vyselektovány pixely rastru identifikující přítomnost kapalné vody. Při testování dalších konfigurací dat a metod klasifikace byla zjišřena výhoda potírající limit zastínění při nepravém zapojení pásem RGB do barevných kanálů rastru. Zapojení zeleného pásma do kanálu 1, modrého pásma do kanálu 2 a červeného pásma do kanálu 3 redukuje efekt zastínění, zlepšuje možnost rozlišení objektů v zastíněných oblastech. Tento přístup je možné využít při manuální klasifikaci.

Při testování limitů laserových dat ve formě bodového mračna byl zjišřen hraniční počet bodů pro identifikaci povrchové deprese. Limit byl po testování stanoven na 5-10 bodů na plochu 1 m<sup>2</sup>. Této hodnoty dosahuje i bodové mračno skenované plošně pomocí skeneru upevněného na trup letadla. Skenování pomocí dronu nabízí detailnější zaznamenání prostorových charakteristik jednotlivých depresí a možnost identifikovat deprese s plochou menší než přibližně 1 m<sup>2</sup>.

Na základě otestovaných přístupů, konfigurací dat a testování jejich limitů autor došel k závěru, že data, optická i laserová, získaná plošným skenováním pomocí letadlového nosiče, jsou zcela dostačující pro přesnou identifikaci potenciálních komářích láníšť. V případě záměru identifikace láníšť na ploše v takovém rozsahu, jako je zkoumaná oblast

CHKO Litovelské Pomoraví, není nutné využívat doplňkové skenování oblasti pomocí dronu.

## POUŽITÁ LITERATURA A INFORMAČNÍ ZDROJE

Agentura ochrany přírody a krajiny. Správa CHKO Litovelské Pomoraví. *Rozbory Chráněné krajinné oblasti Litovelské Pomoraví* 2008[online]. [cit. 2017-09-26]. Dostupné z:<http://litovelskepomoravi.ochranaprirody.cz/res/archive/082/012118.pdf?seek=1371462343>

Agentura ochrany přírody a krajiny ČR. *Maloplošná chráněná území* [online] c. [cit. 2017-09-15]. Dostupné z:[http://www.ochranaprirody.cz/lokality/?filter\\_rp=870&filter\\_vzchu=84&filter\\_ko=0&filter\\_text=&page=2](http://www.ochranaprirody.cz/lokality/?filter_rp=870&filter_vzchu=84&filter_ko=0&filter_text=&page=2)

Agentura ochrany přírody a krajiny ČR: *Mokřady* [online] emo. [cit. 2017-10-15]. Dostupné z: <http://mokrady.ochranaprirody.cz/o-mokradech-mokrady/>

Agentura ochrany přírody a krajiny ČR. *Územní ochrana* [online] a. [cit. 2017-09-15]. Dostupné z: <http://www.ochranaprirody.cz/uzemni-ochrana/>

Agentura ochrany přírody a krajiny ČR.: *Poldry* [online] d. [cit. 2017-10-11]. Dostupné z: <http://www.dotace.nature.cz/voda-opatreni/poldry.html>

ANSARI, M, M MORAIET a S AHMAD, 2014. Insecticides: Impact on the Environment and Human Health. In: MALIK, Abdul, Elisabeth GROHMANN a Rais AKHTAR. *Environmental Deterioration and Human Health: Natural and anthropogenic determinants* [online]. Springer Dordrecht, s. 99-123 [cit. 2023-03-17]. ISBN 978-94-007-7890-0. Dostupné z: doi:10.1007/978-94-007-7890-0\_6

BREIMAN, Leo. Random Forests. *Machine Learning*. 2001, 45(1), 5-32. ISSN 0885-6125

CIMPIANU, Catalin, 2018. *Simple methodology for water data extraction using QGIS and Sentinel 2 images*. Online. In: Giscourse.com. 22.01.2018. Dostupné z: <https://www.giscourse.com/simple-methodology-for-water-data-extraction-using-qgis-and-sentinel-2-images/>. [cit. 2024-08-08].

DANASEKARAN, Raja; MANI, Geetha; ANNADURAI, Kalaivani a RAMASAMY, Jegadeesh, 2014. Small Bite, Big Threat: The Burden of Vector-borne Diseases. Online. *Iran Journal of Public Health*. Roč. 2014, č. 43. Dostupné z: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4401047/>. [cit. 2024-08-09].

FALK, Thorsten, Dominic Mai, Robert Bensch, et al. U-Net: deep learning for cell counting, detection, and morphometry. *Nature Methods*. 2019, 16(1), 67-70. ISSN 1548-7091.

HAY, Simon; WILLIAM SNOW, Robert a JOHN ROGERS, David, 1998. From Predicting Mosquito Habitat to Malaria Seasons Using Remotely Sensed Data: Practice, Problems and Perspectives. Online. *Parasitology Today*. Roč. 1998, č. 14, s. 306-313. ISSN 0169-4758. Dostupné z: [https://doi.org/10.1016/S0169-4758\(98\)01285-X](https://doi.org/10.1016/S0169-4758(98)01285-X). [cit. 2024-08-06].

History of Mosquito Control, 2017. Mosquitocontrol.net [online]. [cit. 2023-03-18].  
Dostupné z: <https://mosquitocontrol.net/history-of-mosquito-control/>

HUANG, C.; DAVIS, L. S. a TOWNSHEND, J. R. G., 2002. An assessment of support vector machines for land cover classification. Online. In: *International Journal of Remote Sensing*. Taylor & Francis, s. 725-749. Dostupné z: <https://doi.org/10.1080/01431160110040323>. [cit. 2024-08-07].

JOSHI, Ananya a MILLER, Clayton, 2021. Review of machine learning techniques for mosquito control in urban environments. Online. *Ecological Informatics*. Roč. 2021, č. 61, s. 2041-2061. ISSN 1574-9541. Dostupné z: <https://doi.org/10.1016/J.ECOINF.2021.101241>. [cit. 2024-08-06].

KRAMÁŘ, J. 1955: Komáři r. *Aedes* v ČSR. *Rozpravy Československé Akademie Věd* 65: 1 - 67.

LI, Shujuan; GOUGE, Dawn; FOURNIER, Al; NAIR, Shaku a BAKER, Paul. Mosquitoes: The mosquito life cycle. Dostupné také z: [https://cales.arizona.edu/backyards/sites/cals.arizona.edu.backyards/files/asset/document/summer14\\_Page10-18.pdf](https://cales.arizona.edu/backyards/sites/cals.arizona.edu.backyards/files/asset/document/summer14_Page10-18.pdf).

LIAW, Andy a Matthew WIENER. Classification and Regression by randomForest. *R News*. 2002, 2(3), 18-22. ISSN 1609-3631

MOUNTRAKIS, Giorgos; OGOLE, Caesar a IM, Jungho, 2011. Support vector machines in remote sensing: A review. Online. *ISPRS Journal of Photogrammetry and Remote Sensing*. Roč. 2011, č. 66, s. 247-259. ISSN 0924-2716. Dostupné z: <https://doi.org/10.1016/J.ISPRSJPRS.2010.11.001>. [cit. 2024-08-07].

N. HASSAN, Ali; EL NOGOUMY, Nihad a A. KASSEM, Hala, 2021. Characterization of landscape features associated with mosquito breeding in urban Cairo using remote sensing. Online. *The Egyptian Journal of Remote Sensing and Space Sciences*. Roč. 2013, č. 16, s. 63-69. ISSN 0198-9715. Dostupné z: <https://doi.org/10.1016/J.EJRS.2012.12.002>. [cit. 2024-08-06].

NAGY, Alaa; EL-ZEINY, Ahmed; SOWILEM, Mohamed; ATWA, Wedad a ELSHAIER, Manal, 1998. Mapping mosquito larval densities and assessing area vulnerable to diseases transmission in Nile valley of Giza, Egypt. Online. *The Egyptian Journal of Remote Sensing and Space Sciences*. Roč. 2022, č. 25, s. 63-71. ISSN 1110-9823. Dostupné z: <https://doi.org/10.1016/J.EJRS.2021.12.009>. [cit. 2024-08-06].

ORSZÁGH, I., MINÁŘ, J. a HALGOŠ, J. 2009: Culicidae Meigen, 1818. v: JEDLIČKA, L., STLOUKALOVÁ, V. a KÚDELA, M. (eds.): Check list of Diptera of the Czech Republic and Slovakia. Elektronick version 2. <http://zoology.fns.uniba.sk/diptera2009>.

PAL, M a MATHER, P. M., 2005. Support vector machines for classification in remote sensing. Online. *International Journal of Remote Sensing*. Roč. 2011, č. 26, s. 1007-1011. Dostupné z: <https://doi.org/10.1080/01431160512331314083>. [cit. 2024-08-07].

PATTERSON, Gordon M, 2016. Looking Backward, Looking Forward: The Long, Torturous Struggle with Mosquitoes. Online. *Insects*. Roč. 2016, č. 7, s. 14. Dostupné z: <https://doi.org/10.3390/insects7040056>. [cit. 2024-08-08].

ŠEBESTA, O. 2007: Vliv lužního lesa na výskyt komárů na jižní Moravě. Biosférická rezervace Dolní Morava, o. p. s., 72 pp.

ŠULC, David. *Identifikace a prostorové analýzy rozmístění komářích lůhnišť v CHKO Litovelské Pomoraví* [online]. Olomouc, 2018 [cit. 2023-03-17]. Dostupné z: <https://theses.cz/id/1xxfcg/>. Diplomová práce. Univerzita Palackého v Olomouci, Přírodovědecká fakulta. Vedoucí práce RNDr. Jakub Mirijovský, Ph.D.

TOLASZ, Radim. *Atlas podnebí Česka: Climate atlas of Czechia*. Praha: Český hydrometeorologický ústav, 2007, 255 s. ISBN 978-80-86690-26-1.

TREVISAN BRAVO, Daniel; ARAUJO LIMA, Gustavo; ALEXANDRE LUZ ALVES, Wonder; PESSOA COLOMBO, Vitor a DJOGBÉNOU, Luc, 2021. Choice of unmanned aerial vehicles for identification of mosquito breeding sites. Online. *Computers, Environment and Urban Systems*. Roč. 2021, č. 90, s. 1-13. ISSN 0198-9715. Dostupné z: <https://doi.org/10.1016/J.COMPENVURBSYS.2021.101692>. [cit. 2024-08-06].

TUNAZ, Hasan a UYGUN, Nedim, 2004. Insect Growth Regulators for Insect Pest Control. Online. *Turkish Journal of Agriculture and Forestry*. Roč. 2004, č. 28, s. 377-388. Dostupné z: <https://journals.tubitak.gov.tr/agriculture/vol28/iss6/1/>. [cit. 2024-08-08].

Vector-borne diseases. In: World Health Organization [online]. 2.2.2020 [cit. 2023-02-22]. Dostupné z: <https://www.who.int/news-room/fact-sheets/detail/vector-borne-diseases>

VELOZO ARAGÃO, Franciely; CAVICCHIOLI ZOLA, Fernanda; HENRIQUE NOGUEIRA MARINHO, Luis; MARIA DE GENARO CHIROLI, Daiane; BRAGHINI JUNIOR, Aldo et al., 2020. *Choice of unmanned aerial vehicles for identification of mosquito breeding sites*. Online. *Geospatial Health 2020: Department of Industrial Engineering, Federal University of Technology (UTFPR), Paraná*. Dostupné z: <https://www.geospatialhealth.net/index.php/gh/article/view/810>. [cit. 2024-08-06].

VOLF, P., HORÁK, P., ČEPIČKA, I., FLEGR, J., LUKEŠ, J., MIKEŠ, L., SVOBODOVÁ, M., VÁVRA, J. a VOTÝPKA, J. 2007: *Paraziti a jejich biologie*. 318 pp, Triton, Praha.

WU, Bin; YU, Bailang; HUANG, Chang; WU, Qiusheng a WU, Jianping, 2015. Automated extraction of ground surface along urban roads from mobile laser scanning point clouds.



Online. In: Remote Sensing Letters. 7. S. 170-179. Dostupné z:  
<https://doi.org/10.1080/2150704X.2015.1117156>. [cit. 2024-08-09].

WU, Qiusheng; LIU, Hongxing; WANG, Shujie; YU, Bailang; BECK, Richard et al., 2015. A localized contour tree method for deriving geometric and topological properties of complex surface depressions based on high-resolution topographical data. Online. *International Journal of Geographical Information Science*. Roč. 2015, č. 12, s. 2041-2061. ISSN 1362-3087. Dostupné z: <https://doi.org/10.1080/13658816.2015.1038719>. [cit. 2024-08-06].

Xu, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. *International Journal of Remote Sensing*. 2006, 27(14), 3025-3033. DOI 10.1080/01431160600589179

YOUSSEFI, Fahimeh; JAVAD VALADAN ZOEJ, Mohammad; ALI HANAFI-BOJD, Ahmad; BORAHANI DARIANE, Alireza; KHAKI, Mehdi et al., 2022. Predicting the location of larval habitats of Anopheles mosquitoes using remote sensing and soil type data. Online. *International Journal of Applied Earth Observations and Geoinformation*. Roč. 2022, č. 108, s. 1-19. ISSN 1569-8432. Dostupné z:  
<https://doi.org/10.1016/J.JAG.2022.102746>. [cit. 2024-08-06].

ZAPLETAL, Jakub, 2023. Modelování dynamiky vodního režimu vybraných tůní v CHKO Litovelské Pomoraví. Bakalářská práce. Olomouc: Univerzita Palackého v Olomouci.

## **PŘÍLOHY**

# SEZNAM PŘÍLOH

## **Přílohy uložené u vedoucího práce:**

- Příloha 1** Bodové mračno laserových dat ve formátu .las vzniklé celoplošným s kenováním oblasti CHKO Litovelské Pomoraví.
- Příloha 2** Dlaždice RGB snímků ve formátu.tif celoplošného snímkování z roku 2023
- Příloha 3** Dlaždice RGB snímků ve formátu.tif celoplošného snímkování z roku 2024
- Příloha 4** Dlaždice NIR snímků ve formátu.tif celoplošného snímkování z roku 2023
- Příloha 5** Dlaždice NIR snímků ve formátu.tif celoplošného snímkování z roku 2024

## **Přílohy uložené na školním uložišti**

- Příloha 6** Vektorové vsrty identifikovaných depresí pomocí metody Wu1
- Příloha 7** Vektorové vsrty identifikovaných depresí pomocí metody vlastního řešení
- Příloha 8** Vektorové vsrty identifikovaných tůní z dat snímaných v roce 2023
- Příloha 9** Vektorové vsrty identifikovaných tůní z dat snímaných v roce 2024
- Příloha 10** Skript a toolbox pro provedení identifikace depresí dle metody Wu1 (lidar\_script.py; ArcGIS Pro Hydrology Analyst.tbx)
- Příloha 11** Toolbox pro provedení identifikace depresí dle metody Wu2 (Contour Tree Tools Public.tbx).

## **Volné přílohy**

- Příloha 12** Poster ve formátu A2 (poster\_vlasak.pdf)

Přílohy se vstupními daty byly uloženy na disku u vedoucího práce z důvodu velkého objemu dat (v řádu stovek GB)

