

**ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA  
V PRAZE**

**FAKULTA ŽIVOTNÍHO PROSTŘEDÍ  
KATEDRA PROSTOROVÝCH VĚD**



Česká  
zemědělská  
univerzita  
v Praze

**Druhovú klasifikace lesních porostů pomocí  
multispektrálních dat velmi vysokého rozlišení pořízených  
družicí WorldView-2 v Krušných horách**

**BAKALÁŘSKÁ PRÁCE**

Vedoucí práce: Ing. Tomáš Klouček, Ph.D.

Bakalant: Lukáš Hošek

2021

## ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Lukáš Hošek

Geografické informační systémy a dálkový průzkum Země v životním prostředí

Název práce

**Druhovú klasifikace lesních porostů pomocí multispektrálních dat velmi vysokého rozlišení pořízených družicí WorldView-2 v Krušných horách**

Název anglicky

**Tree species classification of forest stands using very high-resolution multispectral data acquired by WorldView-2 satellite in the Ore Mountains**

### Cíle práce

Cílem bakalářské práce je klasifikace lesních porostů pomocí multispektrálních dat velmi vysokého rozlišení z družice WorldView-2 pořízených v roce 2015 v Krušných horách.

Dílní cíle práce souvisí s těmito výzkumnými otázkami:

- (a) Je možné pomocí multispektrálních snímků z družice WorldView-2 klasifikovat lesní prostory na úrovni druhů stromů?
- (b) Jak se liší přesnost klasifikace WorldView-2 proti klasifikaci využívající multispektrální data vysokého rozlišení Landsat 8?
- (c) Jaký z vybraných algoritmů pixelové či objektové klasifikace je pro řešení této problematiky nejvhodnější a naopak?
- (d) Lze vytvořit referenční data v dostatečné přesnosti z dostupných "online" zdrojů (například data ÚHUL, ortofoto ČR apod.), nebo je nutné jejich doplnění vlastním terénním průzkumem?

### Metodika

Metodiku bakalářské práce lze rámcově rozdělit na:

- (a) Pořízení a úprava dat pro zájmové území
- (b) Tvorba vhodné legendy dle dostupných "online" podkladů
- (c) Tvorba trénovacích dat a výběr vhodných klasifikačních algoritmů (pixelová vs. objektová klasifikace)
- (d) Klasifikace lesních porostů na úrovni druhů stromů
- (e) Tvorba náhodných bodů k hodnocení přesnosti, terénní průzkum
- (f) Vyhodnocení přesnosti vybraných klasifikačních přístupů
- (g) Zodpovězení výše uvedených výzkumných otázek

## Doporučený rozsah práce

30 – 50 stran

## Klíčová slova

dálkový průzkum Země; WorldView-2; Landsat 8; objektová a bodová klasifikace obrazu; land cover; vegetační pokryv

---

## Doporučené zdroje informací

- Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32. <https://doi.org/10.1201/9780429469275-8>
- Immitzer, M., Atzberger, C., Koukal, T., 2012. Tree species classification with Random forest using very high spatial resolution 8-band WorldView-2 satellite data. *Remote Sens.* 4, 2661–2693. <https://doi.org/10.3390/rs4092661>
- Jombo, S., Adam, E., Odindi, J., 2021. Classification of tree species in a heterogeneous urban environment using object-based ensemble analysis and WorldView-2 satellite imagery. *Appl. Geomatics.* <https://doi.org/10.1007/s12518-021-00358-3>
- Jones, H.G., Vaughan, R.A., 2010. *Remote Sensing of Vegetation: Principles, Techniques, and Applications.* Oxford University Press. ISBN 978-0-19-920779-4
- Li, D., Ke, Y., Gong, H., Li, X., 2015. Object-based urban tree species classification using bi-temporal WorldView-2 and worldview-3 images. *Remote Sens.* 7, 16917–16937. <https://doi.org/10.3390/rs71215861>
- Lillesand, T.M., Kiefer, R.W., Chipman, J.W., 2008. *Remote Sensing and Image interpretation.* John Wiley. ISBN 978-0-470-05245-7
- Song, C., Woodcock, C.E., Seto, K.C., Lenney, M.P., Macomber, S.A., 2001. Classification and change detection using Landsat TM data: When and how to correct atmospheric effects? *Remote Sens. Environ.* 75, 230–244. [https://doi.org/10.1016/S0034-4257\(00\)00169-](https://doi.org/10.1016/S0034-4257(00)00169-)
- Stych, P., Jerabkova, B., Lastovicka, J., Riedl, M., Paluba, D., 2019. A comparison of WorldView-2 and Landsat 8 images for the classification of forests affected by bark beetle outbreaks using a support vector machine and a neural network: A case study in the sumava mountains. *Geosci.* 9. <https://doi.org/10.3390/geosciences9090396>
- 

## Předběžný termín obhajoby

2020/21 LS – FŽP

## Vedoucí práce

Ing. Tomáš Klouček, Ph.D.

## Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 12. 3. 2021

**doc. Ing. Petra Šímová, Ph.D.**

Vedoucí katedry

Elektronicky schváleno dne 15. 3. 2021

**prof. RNDr. Vladimír Bejček, CSc.**

Děkan

V Praze dne 30. 03. 2021

### **Prohlášení**

Prohlašuji, že jsem bakalářskou práci na téma: Druhová klasifikace lesních porostů pomocí multispektrálních dat velmi vysokého rozlišení pořízených družicí WorldView-2 v Krušných horách vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

Jsem si vědom, že na moji bakalářskou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů, ve znění pozdějších předpisů, především ustanovení § 35 odst. 3 tohoto zákona, tj. o užití tohoto díla.

Jsem si vědom, že odevzdáním bakalářské práce souhlasím s jejím zveřejněním podle zákona č. 111/1998 Sb., o vysokých školách a o změně a doplnění dalších zákonů, ve znění pozdějších předpisů, a to i bez ohledu na výsledek její obhajoby.

Svým podpisem rovněž prohlašuji, že elektronická verze práce je totožná s verzí tištěnou a že s údaji uvedenými v práci bylo nakládáno v souvislosti s GDPR.

V Praze dne 31. 3. 2021

.....

Hošek Lukáš

## **Poděkování**

Na tomto místě bych rád poděkoval vedoucímu své bakalářské práce Ing. Tomášovi Kloučkovi, Ph.D., za cenné rady a odborné vedení mé práce.

## **Abstrakt**

Dálkový průzkum Země představuje v současnosti nenahraditelný zdroj informací pro monitoring životního prostředí. Cílem bakalářské práce je klasifikace lesních porostů pomocí multispektrálních dat z družic WorldView-2 (velmi vysoké prostorové rozlišení) a Landsat 8 (vysoké rozlišení) v Krušných horách. Tato práce je zaměřena na výběr a posouzení přesností jednotlivých klasifikačních algoritmů a dokázání, že pomocí metod dálkového průzkumu Země lze poměrně přesně klasifikovat krajinný pokryv na úrovni jednotlivých druhů stromů nacházejících se v zájmové oblasti. U všech metod je následně zjištěna přesnost jednotlivých klasifikací a pro vizuální posouzení výsledků graficky znázorněn krajinný pokryv. Z výsledků bakalářské práce je patrné, že se jeví jako nejvhodnější algoritmus pro druhovou klasifikaci lesních porostů u snímků WorldView-2 (WV-2) metoda klasifikace Maximum Likelihood dosahující celkové přesnosti 68,17 %. Slibných výsledků bylo docíleno i pixelovou klasifikací Random Forest (RF) (67,06 %). Naopak nejméně přesné výsledky byly dosaženy klasifikátorem Minimum Distance (46,85 %). V případě metody Support Vector Machines (SVM) byla získána přesnost 60,36 %. U dat Landsat 8 bylo dosaženo nejvyšší přesnosti u klasifikace RF (50 %) a nejnižší přesnosti dosáhl klasifikátor SVM (26,07 %). Ze závěru práce vyplývá, že snímky pořízené družicí WV-2 jsou vhodným nástrojem pro druhovou klasifikaci lesních porostů.

**Klíčová slova:** dálkový průzkum Země; WorldView-2; bodová klasifikace obrazu; objektová klasifikace obrazu; land cover

**Abstract:**

Earth remote sensing is currently an irreplaceable source of information for environmental monitoring. The purpose of the bachelor thesis is the classification of forest stands using multispectral data from satellites WorldView-2 (very high spatial resolution) and Landsat 8 (high resolution) in the Ore Mountains. This work is focused on the selection and assessment of the accuracy of individual classification algorithms and proving that using remote sensing methods it is possible to relatively accurately classify the landscape cover at the level of individual tree species located in the area of interest. For all methods, the accuracy of individual classifications is then determined and the landscape cover is graphically represented for visual assessment of the results. The results of the bachelor's thesis show that the Maximum Likelihood classification method, which achieves an overall accuracy of 68,17 %, appears to be the most suitable algorithm for the species classification of forest stands in WorldView-2 (WV-2) images. Promising results were also achieved by the pixel classification Random Forest (RF) (67,06 %). On the contrary, the least accurate results were obtained with the Minimum Distance classifier (46,85 %). For the Support Vector Machines (SVM) method, accuracy of 60,36 % was obtained. For Landsat 8 data, the highest accuracy was achieved in the RF classification (50 %) and the lowest accuracy was achieved by the SVM classifier (26,07 %). The conclusion of the thesis shows that the images taken by the WV-2 satellite are a suitable tool for the second classification of forest stands.

**keywords:** remote sensing; WorldView-2; Pixel-based classification; Object-Based classification; land cover

## Obsah

1. Úvod.....	1
2. Cíle práce:.....	2
3. Rešerše literatury.....	2
3. 1 Spektrální chování objektů.....	2
3. 2 Klasifikace obrazu .....	3
3. 2. 1 Klasifikace Per-Pixel .....	4
3. 2. 2 Objektová klasifikace:.....	5
3. 2. 3 Algoritmy klasifikace .....	6
3. 3. Zhodnocení výsledků klasifikace .....	8
3. 4 Využitelný software .....	9
3. 5 Současná satelitní data .....	9
3. 5. 1 WorldView-2 (WV-2).....	10
3. 5. 2 Landsat 8 (L8).....	10
3. 6 ÚHÚL.....	11
3. 7 Zhodnocení současného stavu poznání .....	11
4. Data a metodika .....	12
4. 1 Použitý software .....	12
4. 2 Použitá data: .....	12
4. 3 Charakteristika zájmového území.....	12
4. 4 Legenda .....	13
4. 5 Referenční data .....	17
4. 6 Metodika práce .....	19
4. 7 Předzpracování dat: .....	19
4. 7. 1 Radiometrické korekce:.....	19
4. 7. 2 Geometrická korekce:.....	20
4. 7. 3 Atmosférická korekce: .....	20
4. 8 Úpravy snímků .....	20
4. 9 Klasifikace obrazu: .....	21
4. 10 Post-processing snímků .....	22
4. 11 Hodnocení přesnosti.....	22
5. Výsledky .....	23
5.1 Výsledky podrobné legendy.....	23
5.1.1 Výsledky podrobné legendy snímku Worldview-2.....	23



5.1.2 Výsledky podrobné legendy snímku Landsat 8 .....	27
5.2 Výsledky pro zjednodušenou legendu.....	31
5.2.1 Výsledky zjednodušené legendy snímku Worldview-2.....	31
5.2.2 Výsledky zjednodušené legendy snímku Landsat 8.....	32
5. 3 Porovnání výsledků klasifikace .....	33
6. Diskuse.....	34
7. Závěr.....	36
7.1 Výzkumné otázky: .....	36
8. Seznam zdrojů informací.....	38
9. Seznam obrázků a tabulek.....	41
10. Seznam příloh .....	43

## 1. Úvod

Pro popis lesních ekosystému je jedním ze stěžejních kritérií rozmanitost dřevin. Ta je důležitá pro řešení různých ekologických problémů, jako je například modelování stanovišť volně žijících živočichů. Také je stále důležitějším kritériem pro udržitelnost lesního hospodářství. Získání podrobných, prostorově přesných informací o druhovém složení lesních porostů, či krajinném pokryvu a podobně má proto v dnešní době velký význam. Jelikož je terénním hodnocením téměř nemožné získat tyto informace pro velké plochy, je jednou z obzvláště užitečných metod pro řešení této problematiky dálkový průzkum Země (DPZ) (Immitzer et al., 2012).

Dálkový průzkum Země je věda i umění k vytěžení užitečných informací o plochách, objektech nebo jevech pomocí dat pořízených zařízeními, která s těmito zkoumanými objekty, plochami nebo jevy nejsou v přímém kontaktu (Lillesand et al., 2008). Člověk využívá řadu různých metod a používá pro to různá technologická vybavení, aby získal kvantitativní a kvalitativní informace o těchto jevech a o jejich vlivu na jejich okolí. K tomu je využíváno intervalů vlnových délek elektromagnetického záření (Halounová a Pavelka, 2008).

Zařízení zaznamenávající sílu elektromagnetického záření je umístěno na různých typech nosičů, nejčastěji letadlech nebo družicích. V případě družic lze sledovat zemský povrch a pořizovat data prakticky nepřetržitě, díky neustálému oběhu satelitů kolem Země a vybavenosti potřebnými přístroji. Družice data zaznamenávají, poté je rádiovou cestou předají do přijímacích stanic a z těch jsou následně dostupná zájemcům po celém světě (Hermann a Pomezny, 2003).

Dálkový průzkum Země se čím dál tím více dostává do povědomí odborným i neodborným skupinám lidí a satelitní snímky se tak uplatňují ve spoustě oborů, jak humanitních, tak přírodních věd. Jedná se například o obory zemědělství, geologie, geografie či archeologie. Krom výhod získání prostorových informací pro velké plochy je výhodou také ekonomická stránka věci (Dobrovolný, 1998). Zejména díky satelitním snímkům s (velmi) vysokým prostorovým rozlišením lze provést mapování dřevin za výrazně nižší cenu, než v případě sběru dat přímo v terénu (Li et al., 2015). Jako všechny metody má samozřejmě i tato jisté nevýhody. Konkrétně se jedná o omezené prostorové rozlišení dostupných snímků. Tato nevýhoda je ale postupem času stále více eliminovaná díky technologickému vývoji nových satelitů. V dnešní době tak můžeme pracovat s daty velmi vysokého rozlišení se submetrovou rozlišovací schopností. Navíc díky různým obrazovým vizualizačním

platformám (například Google Earth apod.) má dnes možnost se k těmto datům dostat kdokoli s přístupem na internet (Lillesand et al., 2015).

## **2. Cíle práce:**

Cílem této bakalářské práce byla klasifikace lesních porostů pomocí multispektrálních dat z družic WorldView-2 (velmi vysoké prostorové rozlišení) a Landsat 8 (vysoké rozlišení) v Krušných horách. Tato klasifikace byla provedena několika klasifikátory bodové klasifikace obrazu, jako je algoritmus Maximum Likelihood (ML), Minimum Distance (MD) či Random Forest (RF). Také byla zahrnuta objektová klasifikace Support Vector Machines (SVM). Dílčím cílem bakalářské práce bylo vzájemné posouzení vybraných algoritmů, zhodnocení jejich přesnosti, vyhodnocení jejich potenciálu pro klasifikaci krajinného pokryvu na úrovni jednotlivých druhů stromů v zájmové oblasti a zodpovězení výzkumných otázek ze zadání:

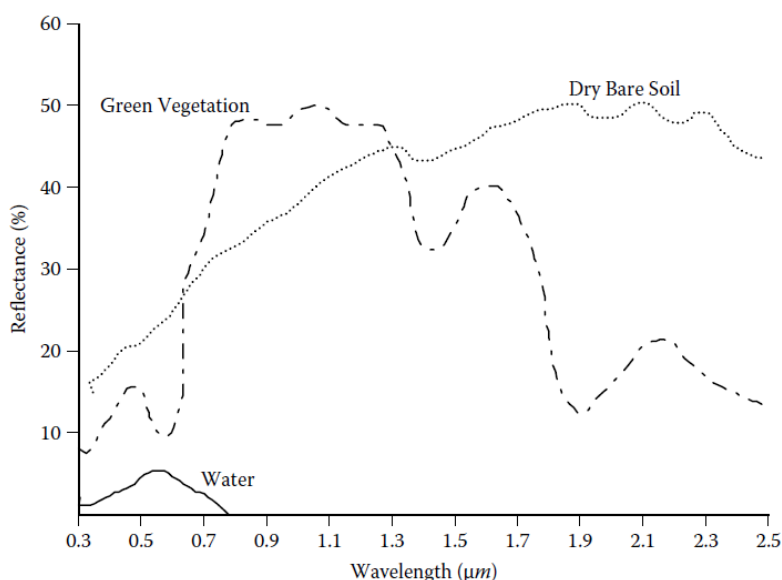
- (a) Je možné pomocí multispektrálních snímků z družice WorldView-2 klasifikovat lesní prostory na úrovni druhů stromů?
- (b) Jak se liší přesnost klasifikace WorldView-2 proti klasifikaci využívající multispektrální data vysokého rozlišení Landsat 8?
- (c) Jaký z vybraných algoritmů pixelové či objektové klasifikace je pro řešení této problematiky nejvhodnější a naopak?
- (d) Lze vytvořit referenční data v dostatečné přesnosti z dostupných "online" zdrojů (například data ÚHUL, ortofoto ČR apod.), nebo je nutné jejich doplnění vlastním terénním průzkumem?

## **3. Rešerše literatury**

### **3.1 Spektrální chování objektů**

Na snímcích nám množství odraženého záření udává viditelnost a rozpoznatelnost objektu. Intenzita odraženého nebo emitovaného krátkovlnného záření závisí na několika faktorech. Především tedy na druhu látky či objektu (např. na jeho chemickém složení), na fyzikálním stavu objektu jako je teplota, obsah vlhkosti a

jiné, na stavu okolí objektu (např. na propustnosti atmosféry, apod.). Pokud máme snímky získané v různých částech elektromagnetického záření a chceme-li je porovnat, můžeme většinou pozorovat rozdílnou „intenzitu šedi“, která nám představuje množství odraženého a přístrojem zaznamenaného záření. Pro konkrétní objekt lze sestavit vztah mezi odrazivostí objektu a vlnovou délkou. Graficky se tento vztah znázorní spektrální křivkou odrazivosti (obr. č. 1), která je projevem spektrálního chování objektu. Množství odraženého záření rozhoduje o tom, zda je objekt na snímku viditelný. Pokud se objekt jeví tmavý, odráží jen málo záření. K rozpoznávání každého objektu jsou důležitým parametrem také vlastnosti sousedních objektů. Jestliže odráží dva sousední objekty, které jsou rozdílné, stejné množství záření dané vlnové délkou, na snímku budou splývat. Díky tomu, že odrazivost objektů se mění s vlnovou délkou záření, lze najít intervaly vlnových délek, ve kterých se projeví rozdílná odrazivost povrchů, na jejichž základě jsou tyto objekty snadno rozpoznatelné (Svatoňová et al., 2010).



Obrázek 1 – Typická spektrální odrazivost (%) tří povrchů: zelená vegetace (green vegetation), suchá holá půda (dry bare soil) a voda (water) (zdroj: Tso a Mather, 2009)

### 3. 2 Klasifikace obrazu

Klasifikace je nástroj umožňující nahradit vizuální interpretaci a ruční vektorizaci obrazových dat dálkového průzkumu Země prostřednictvím klasifikačních přístupů. Možnost zpracovat velký objem dat, jakými jsou například rozsáhlá území či vícerozměrné datové soubory apod., nebo opakované využití se zcela stejnými parametry, jsou výhodou tohoto nástroje. Nejčastějšími výstupy klasifikačních algoritmů bývají tematické mapy, tabulky či datové soubory sloužící následně jako vstupy do různých geoinformačních systémů (Lillesand et al., 2008).

Základní princip klasifikace obrazu je založený na rozčlenění naměřeného datového souboru do daných kategorií, jenž nejčastěji představují jednotlivé druhy krajinného pokryvu v různých podobnostních úrovních. Tyto kategorie jsou většinou rozděleny podle určitého příznaku na základě sady pravidel (algoritmu), která na základě těchto příznaků rozhoduje o přidělení konkrétního pixelu do dané kategorie. Příznak je hodnota měřitelná pro jednotlivé objekty a měla by jasně rozlišovat jednotlivé kategorie. Příznaky v základě dělíme na čtyři – spektrální, prostorový, časový a polarizační (Kolář, 1990).

Jedním z kritérií dělení klasifikace při přiřazení objektu do tříd je, zda se jedná o přiřazení samotného pixelu (poté jde o tzv. per-pixel klasifikaci, jinak řečeno bodovou) nebo skupin pixelů s podobnými znaky (v tomto případě se jedná o objektovou klasifikaci). Jak tvrdí Jombo et al. (2021) ve své studii, tak nevýhodou pro mapování stromů založeném na běžně používaných pixelových přístupech je neúspěch těchto algoritmů prozkoumat prostorové a spektrální charakteristiky obrazu - tzn., že pro klasifikaci dat vysokého prostorového rozlišení (například Landsat 8) je vhodnější využití bodového přístupu, naopak v případě dat velmi vysokého rozlišení (například WV-2) dochází v případě bodové klasifikace často k tzv. „salt and pepper“ efektu, a proto je vhodnější využití technik založených na objektovém přístupu. Proto se v této práci zaměřuji na obě možnosti klasifikace obrazu. Z celé řady dostupných algoritmů klasifikace (Tso a Mather, 2009) budou v další části blíže představeny jen ty, které jsou použity v metodické části práce.

### **3. 2. 1 Klasifikace Per-Pixel**

Vzhledem k typu běžně dostupných obrazových dat vychází celý koncept automatické klasifikace založené na spektrálním chování povrchů z určitých zjednodušení. Jak popisuje Williams (1995), tak citlivost snímače je stejná pro všechna pásma multispektrálních obrazů. Každý obrazový prvek přesně odpovídá ploše na zemi, zároveň představuje stejnorodý povrch ve smyslu jeho spektrálního chování a naměřená data mají v každém pásmu normální rozdělení.

#### ***Řízená klasifikace:***

Je založena na myšlence, že uživatel může vybrat ukázkové pixely v obraze, které jsou reprezentativní pro konkrétní třídy (tzv. trénovací plochy), a poté nasměrovat software pro zpracování obrazu tak, aby je použil jako posudek pro klasifikaci všech ostatních pixelů v obraze. Trénovací plochy jsou vybírány na základě znalostí uživatele. Uživatel také nastavuje hranice toho, jak podobné musí být ostatní pixely, aby je bylo možné seskupit. Tyto

hranice jsou často stanoveny na základě spektrálních charakteristik tréninkové oblasti, plus nebo minus určitý přírůstek (často na základě „jasu“ nebo síly odrazu ve specifických spektrálních pásmech). Uživatel také určí počet tříd, do kterých je obrázek klasifikován (Lillesand et al., 2015).

### **3. 2. 2 Objektová klasifikace:**

Objektově orientované klasifikátory využívají kromě spektrální informace také prostorové uspořádání prvků v obraze – snaží se tedy určit strukturu a souvislost. Při zpracování dat se nejprve pomocí členění obrazu vytvářejí objekty (segmenty). Ty jsou tvořeny souvislými skupinami pixelů, které mají své multispektrální atributy relativně stejnorodé a vyznačují se i jinými vlastnostmi jako je tvar, velikost, textura, apod. Uživatel může ovlivňovat stupeň různorodosti, tvar i velikost základních segmentů.

#### ***Segmentace obrazu***

Segmentace obrazu je definována jako metoda rozdělení obrazu do stejnorodých oblastí (Pal a Pal, 1993). Tyto regiony představují krajinný pokryv, jako jsou budovy, stromy, vodní útvary a travní porosty, který je využíván jako obrazový objekt v geograficky objektové analýze (Costa et al., 2018).

S existencí velkého množství segmentačních metod vznikly různé typy klasifikací segmentačních algoritmů podle způsobu, jakým dosahují výsledné segmentace. Pohled na počet a typy jednotlivých skupin se různě liší. Obecně však můžeme segmentační algoritmy rozdělit do tří základních skupin:

Prahování a shlukování:

Prahování je jedna z nejjednodušších segmentačních metod, která zahrnuje rozpoznání skupiny hodnot, kterým říkáme práh. Jde o rozdělení stupnice jasu pro obraz na dvě části, které se nahradí zástupnou hodnotou. Konkrétně hodnotou 1, ta určuje nalezené objekty a hodnotou 0, která udává pozadí obrazu. Tato technika je však zastaralá a selhává i u velmi jednoduchých obrazů, protože dochází k nepravidelnému osvětlení vstupního obrazu. Nejčastěji používaná je z tohoto důvodu adaptivní metoda s proměnným počtem prahů, v té je snímek rozdělen na více částí a hodnota v nich se určí nezávisle na ostatních. V případě, že hodnota prahu v nějaké části nelze určit, vyjádří se z hodnot prahů v okolí (Hossain et al., 2019).

Segmentace detekcí hran:

Technika založená na hranách, kde se předpokládá náhlá změna ve vlastnostech pixelů mezi hranami. Hrany jsou brány jako hranice mezi objekty a umisťují se na místa, kde dochází ke změnám. Měří se pomocí gradientu vypočítávajícího změnu jasů v obraze a směr změny. Jedná se o vektor, podle jehož velikosti se určuje síla hran v obraze a úhel gradientu. Výpočet pro hranové gradienty může být nahrazen spleť obrazů se skupinou vzorů jednotlivých hran, kde každý ze vzorů odpovídá hraně v daném směru. Existuje mnoho algoritmů dostupných pro identifikaci hran objektů, které zachycují geometrické a fyzikální vlastnosti obrazových objektů. Jedná se například o algoritmus „Watershed Transformation“ (WT), který je nejpopulárnější okrajově segmentační metodou v komunitě dálkového průzkumu Země (Hossain et al., 2019).


Segmentace podle regionů:

Segmentace podle regionů na rozdíl od metod založených na detekci hran nejdříve začíná uvnitř objektu a poté se rozpíná do okolí směrem ven, dokud nenarazí na hranice objektu. Předpokládá se, že sousední pixely jsou stejným regionem s podobnými hodnotami. Obecně je tato technika oproti detekci hran výhodná u zašumělých obrazů, ve kterých je obtížné detekovat hranici objektu. Většinou je založena na postupném spojování či dělení jednotlivých regionů a kombinaci obou těchto přístupů (Hossain et al., 2019).

### 3. 2. 3 Algoritmy klasifikace

#### ***Klasifikace Minimum Distance (MD)***


Porovnává vzdálenost mezi středy shluků ve vícerozměrném prostoru a určovaným pixelem. Středů shluků jsou průměry spektrálních hodnot dané kategorie a každého pásma. Podle pravidla o nejmenší vzdálenosti se pak určovaný pixel zařadí do shluku, k jehož středu má nejbližší (obr. č. 2). Všechny pixely jsou následně klasifikovány do nejbližší třídy, pokud není zadána prahová hodnota směrodatné odchylky nebo vzdálenosti. V takovém případě mohou být některé pixely nezařazeny, pokud nesplňují vybraná kritéria (Dobrovolný, 1998, Richards, 1999).



Obrázek 2 – Schéma zařazování pixelů k jednotlivým spektrálním třídám pomocí klasifikátoru Minimum Distance (zdroj: Lillesand et al., 2015)

### Klasifikace Maximum Likelihood (ML)

Klasifikace maximální pravděpodobnosti je založena na předpokladu normálního rozdělení statistik pro každé pásmo a danou kategorii, z nichž pak vypočítá pravděpodobnost zařazení konkrétního pixelu do dané kategorie (obr. č. 3). V případě, že se nevybere prahová hodnota pravděpodobnosti, klasifikovány budou všechny pixely. Každý pixel je přiřazený kategorii s nevyšší pravděpodobností (tj. Maximální pravděpodobnost). Pixel zůstane nezařazený, pokud je nejvyšší pravděpodobnost menší než zadaná prahová hodnota (Richards, 1999).



Obrázek 3 – Schéma zařazování pixelů k jednotlivým spektrálním třídám pomocí klasifikátoru Maximum Likelihood (zdroj: Lillesand et al., 2015)



### **Random Forest (RF)**

Jednou z nejnovějších metod, kde není nutno nastavovat uživatelem téměř žádné vstupní parametry, je Random Forest. Tento klasifikátor je odolný vůči šumu a dosahuje velké přesnosti. Při porovnání s jinými neparametrickými metodami je nastavení jednoduché díky tomu, že zde není nutné žádné promyšlenější ladění parametrů. Dáno je to relativní necitlivostí na problémy s malými velikostmi trénovacích ploch. V posledních letech se stává stále důležitějším klasifikátorem dat dálkovém průzkumu Země, kde se používá v mnoha analýzách. Například pro klasifikaci krajinného pokryvu, identifikaci spektrálních rozdílů druhů stromů, mapování sesuvů půdy a jiné (Breiman, 2001).

### **Support Vector Machines (SVM)**

Support Vector Machines (SVM) je poměrně nová klasifikační technika využitelná nejen pro mapování krajinného pokryvu. Vychází z teorií statistických učení a do povědomí uživatelů se dostala díky své síle, přesnosti a efektivnosti i při použití malého trénovacího vzorku. Svou povahou jsou SVM v zásadě binární klasifikátory, lze je však přijmout ke zvládnutí několika úkolů klasifikace běžných ve studiích dálkového průzkumu Země. Podstatou algoritmu je převod vstupního prostoru do prostoru vícerozměrného, který umožňuje oddělení tříd. Tyto dva přístupy nazýváme jeden proti jednomu a jeden proti všem (Gidudu et al., 2007).

## **3. 3 Zhodnocení výsledků klasifikace**

U vyhodnocení je základním předpokladem mít referenční data, se kterými lze výslednou klasifikaci srovnávat. Referenční data lze pořídit například terénním průzkumem zájmové oblasti. V případě, že data z terénu nemáme, tak je další možností vytvořit kontrolní dataset vygenerováním náhodných bodů a přiřadit jim třídy legendy na základě dalších dostupných zdrojů jako jsou ortofotomapy nebo jiná obrazová data v lepším prostorovém rozlišení než klasifikovaný snímek. Jedním ze způsobů, jak vygenerovat náhodné body pro zhodnocení výsledku klasifikace (tzv. kontrolní body), je přístup „*Simple random*“, který vygeneruje kontrolní body náhodně po celé ploše snímku. Ovšem u tohoto způsobu může dojít v případě malého zastoupení klasifikované třídy k jejímu opomenutí při generování kontrolních bodů. Dalším ze způsobů je „*Simple systematic*“, který vytvoří body v pravidelné mřížce. I u tohoto způsobu může nastat problém u málo rozlehlých tříd. Další způsob je „*Stratified random*“, který generuje poměrově pro každou třídu legendy tolik bodů podle toho, jak je třída zastoupena v daném území. Pro hodnocení velkých nebo špatně dostupných území je vhodný způsob „*2-Stage Clustered*“. Ten

vytvoří po rozsáhlé ploše několik malých území, ve kterých pak generuje náhodné body pomocí metod zmíněných výše (Lillesand et al., 2008).

K samotnému hodnocení výsledku pak slouží tzv. chybová matice. Ta obsahuje vždy tolik řádků a sloupců, jako je kategorií legendy. V případě vyhodnocování z náhodných kontrolních bodů pak všechna hodnocení přesnosti vycházející z této chybové matice a mají vypovídající hodnotu o přesnosti klasifikace celého obrazu (Lillesand et al., 2008). Dle Lillesanda et al. (2008) z chybové matice můžeme vyčíst hned několik informací. Jedná se o uživatelskou přesnost - ta udává, s jakou pravděpodobností pixel zařazený do určité třídy tuto třídu doopravdy představuje, zpracovatelskou přesnost - poměr mezi správně klasifikovanými pixely a pixely použitými pro testování dané třídy a přesnost celkovou pro celou klasifikaci.

Další důležitý ukazatel přesnosti je tzv. Kappa koeficient. Ten porovnává přesnost provedené klasifikace s přesností dosažitelnou čistě náhodným zařazením pixelů do jednotlivých tříd. Hodnota koeficientu Kappa se může pohybovat v rozmezí hodnot 0 až 1. Vyšší hodnoty znamenají větší shodu, nad 0,75 se jedná o dobrý výsledek klasifikace. Hodnota jedna by říkala, že bychom při klasifikaci neměli ani jednu chybu vzniklou čistě náhodným zařazováním pixelů do jednotlivých tříd (Dobrovolný, 1998).

### **3. 4 Využitelný software**

Jak již bylo uvedeno výše, tak v současnosti si díky rapidnímu technologickému rozvoji a DPZ samotnému, můžeme vybrat z velkého množství softwaru sloužícího ke zpracování a analýze družicových dat. Tyto aplikace mohou být dostupné volně jako například QGIS, SAGA GIS, ESA SNAP, LEOWorks či další, nebo komerčního rázu jako ENVI, ArcGIS apod.

### **3. 5 Současná satelitní data**

Data pořízená metodami DPZ jsou stále více využívána z důvodu technologického vývoje a rozvoje výpočetní techniky, který výrazně zjednodušil dříve složité zpracovatelské metody, kterými bylo možné získat potřebné informace z dostupných dat. Díky tomuto rozvoji se také zpřístupnila obrazová data většímu okruhu potencionálních uživatelů (Dobrovolný, 1998). V minulosti byla data využívána zejména pro vojenské použití. V posledních letech jsou data z družicových nosičů buď poskytována jako volně dostupná pro široký okruh uživatelů, nebo můžeme získat i mnoho snímků na komerční bázi poskytované celou řadou firem, jako je třeba QuickBird společnosti Digital Globe vypuštěná v říjnu 2001.

### **3. 5. 1 WorldView-2 (WV-2)**

WorldView-2 je provozován americkou společností DigitalGlobe (dříve WorldView Imaging Corporation). Společnost založil Dr. Walter Scott v roce 1992. Firma v roce 1993 získala licenci pro pořizování satelitních snímků s vysokým rozlišením. V současnosti je tato firma vlastníkem i dalších satelitů jako je IKONOS, QuickBird a dalších.

WV2- byl vypuštěný v říjnu 2009. Jedná se o první 8pásmový multispektrální komerční satelit s vysokým rozlišením. Operuje v nadmořské výšce 770 km. Poskytuje panchromatické rozlišení 46 cm a multispektrální rozlišení 1,85 m. WorldView-2 má průměrnou dobu přeletu 1,1 dne a je schopen shromáždit až 1 milion km<sup>2</sup> 8pásmových snímků za den (DigitalGlobe, 2012).

Kromě 4 typických pásem (modré, zelené, červené a blízké infračervené) družice snímá i ve 4 dalších pásmech výrazně zvyšující informační obsah a možnosti vyhodnocení těchto dat. Jedná se o tyto pásma: Pobřežní pásmo (400-450 nm), Žluté pásmo (585-625 nm), Červené pásmo (705-745 nm) a Blízké infračervené 2. pásmo (860-1040 nm) (Gisat, 200-?).

### **3. 5. 2 Landsat 8 (L8)**

Program Landsat je misí určený k pozorování Země a zejména životního prostředí. Funguje od roku 1972, kdy byla na oběžnou dráhu vyslána první z těchto družic. Program Landsat je řízený NASA a USGS (United States Geological Survey). První tři družice Landsat byly vybaveny dvěma senzory RBV (Return Beam Vidicon) a multispektrálním skenerem MSS (Multi-spectral Scanner). Druhá generace, odstartována vypuštěním Landsatu 4 v roce 1982, nesla znovu multispektrální skener MSS (Multi-spectral Scanner) a sedmikanálový skener TM (Thematic Mapper). Další družicí, která měla následovat, byla Landsat 6, ale ta havarovala při startu, proto další družice vypuštěná na oběžnou dráhu byla Landsat 7 – ta má několik vylepšení oproti předešlým družicím této řady, avšak zachovává kontinuitu v datové řadě Thematic Mapperu™ zahájenou Landsatem 4 a navíc obsahuje osmikanálový multispektrální skener ETM+ (Enhanced Thematic Mapper) (Gisat, 200-?).

Landsat 8 byl vypuštěn 11. února 2013 z letecké základny Vandenberg v Kalifornii. Užitečné zatížení satelitu Landsat 8 se skládá ze dvou vědeckých přístrojů – Operational Land Imager (OLI) a Thermal Infrared Sensor (TIRS). Tyto dva senzory poskytují sezónní pokrytí globální pevniny v

prostorovém rozlišení 30 metrů (viditelné, NIR, SWIR pásmo), 100 metrů (termální pásmo) a 15 metrů (panchromatické pásmo) (NASA, 200-?).

### **3. 6 ÚHÚL**

Ústav pro hospodářskou úpravu lesů Brandýs nad Labem (ÚHÚL) je organizační složka státu zřízená Ministerstvem zemědělství České republiky. Působí v oblasti celé České republiky. V roce 1935 byla založena vládou tzv. Lesní taxační kancelář umožňující rozvoj lesního hospodářství v oblastech hospodářských úprav lesů a poskytování informací o lesních ekosystémech. Během druhé světové války ústav vypracovával lesní hospodářské plány (LHP) a zeměměřičské či kartografické práce pro potřeby státních lesů. V této době bylo také zahájeno stanovištní mapování lesů se stanovením druhové skladby. Tím byl položen základ typologie lesů v ÚHÚL. V současnosti je hlavním pověřením ÚHÚL především inventarizace lesů v ČR. Dnes též spravuje centrální databázi s informacemi o lesích České republiky a poskytuje ministerstvu zemědělství technickou a odbornou podporu. Katalog mapových informací je provozován na webovém mapovém portálu a můžeme zde najít mapy druhové skladby, smíšenosti lesů, vlastnické poměry, etážovitost atd. (ÚHÚL, 200-?).

### **3. 7 Zhodnocení současného stavu poznání**

V současné době lze najít několik studií zkoumající právě přístupy klasifikačních algoritmů na datech s velmi vysokým rozlišením. Například Immitzer et al. (2012) se ve své studii zabýval klasifikací Random Forest (RF) pro rozpoznání 10 druhů stromů v mírném lese v oblasti Rakouska. Ve výsledku dosáhl celkové přesnosti pro klasifikaci těchto 10 druhů stromů kolem 82 % (8 pásem, objektově). V této práci je taktéž uvedeno, že objektový přístup překonal bodovou klasifikaci.

Další z publikovaných prací s podobnou problematikou je nedávno vydaná publikace, kde Jombo et al. (2021) porovnává objektovou klasifikaci druhů stromů v heterogenním městském prostředí. V této studii využívá taktéž data družice WV-2, testuje užitečnost pásem a dalších funkcí v objektovém mapování – konkrétně opět objektovou klasifikaci RF a SVM. Z výsledků této práce je patrná lepší účinnost klasifikace RF (přesnost 91,9 %) v porovnání se SVM (přesnost 87,3 %).

Porovnání klasifikačních metod nad snímky WV-2 a L8 se taktéž věnuje publikace Štych et al. (2019), ve které zkoumají jejich využitelnost na příkladu zájmové lokality ležící v oblasti Šumavy. Konkrétně pro klasifikaci lesů postižených ohniskem kůrovce. V této práci byla využita opět metoda SVM a také metoda klasifikace Neural Net.

Z výsledků je patrný úspěch klasifikace SVM, který dosáhl u snímku WV-2 celkové přesnosti 86 %. U dat Landsat 8 tento algoritmus dosáhl 71 %. Velmi slibné výsledky zde ovšem přinesl i klasifikátor Neural Net, který měl přesnost u obou snímků přes 80 %.

## **4. Data a metodika**

### **4. 1 Použitý software**

Pro naši práci byl využit software ENVI 5.5, který umožňuje dobrou práci jak s daty Landsat 8, tak WorldView-2 a obsahuje pestrou nabídku klasifikačních nástrojů, které chceme v této práci využít. Také bylo využito volně dostupného programu SNAP Desktop od společnosti ESA, který nabízí v rámci integrovaných nástrojů klasifikační algoritmus Random Forest. Následně bylo pracováno s programem ArcMap 10.8, který je vhodný především pro výsledné zobrazení a vizualizaci výstupů jednotlivých klasifikačních metod nebo ke kategorizaci kontrolních bodů při hodnocení klasifikací nad dostupným ortofotem ČR, které lze díky propojení s WMS (Web Map Service) službami snadno nahrát.

### **4. 2 Použitá data:**

Pro tuto práci byly vybrány snímky ze dvou různých družic s rozdílným prostorovým rozlišením. Jedná se o snímky z komerční družice Worldview-2, která snímá ve velmi vysokém rozlišení a o volně dostupné snímky z družice Landsat 8, které jsou ve vysokém rozlišení. Snímky z WV-2 pochází ze 3. července 2015 a jsou v úrovni zpracování OR (Ortho Ready) standard 2A. Dodavatelem těchto dat je firma GISAT. Snímky z družice Landsat byly staženy z volně dostupného serveru EarthExplorer, též v úrovni zpracování level 2 a ze dne 6. června 2015.

### **4. 3 Charakteristika zájmového území**

Námi zvolenou zájmovou oblastí jsou Krušné hory, dříve též Rudohoří. Jedná se o geomorfologický celek a pohoří podél česko-německé hranice na severozápadě Čech a jihu Saska v Ústeckém kraji. Tvoří souvislé horské pásmo o délce 130 km a průměrné šířce 40 km. Na většině území Krušných hor se průměrná roční teplota pohybuje mezi 5 až 6 °C, ale v místech, kde se nachází izolované vrcholky, se průměrná roční teplota pohybuje mezi 4 až 5 °C. Průměrně se zde ročně vyskytne až 1200 mm srážek. Obecně se v Krušných

horách vyskytuje kolem 1000 mm srážek za rok. Jako modelové území byla vybrána pouze část nacházející se na české straně. Především je to z důvodu dostupných údajů o druhové skladbě z ÚHÚLu (Ústav pro hospodářskou úpravu lesů) nebo určování kontrolních bodů klasifikace nad aktuálním ortofotem, které je dostupné pouze pro ČR. Tato oblast byla vybrána z důvodu dlouhodobého výzkumného sledování na FŽP na ČZU v Praze a díky tomu jsou dostupné komerční snímky družice WV2 právě pro tuto oblast. Modelové území, se kterým pracujeme, má rozlohu 135,8 km<sup>2</sup>.

#### 4. 4 Legenda

Legenda byla zvolena tak, aby nejlépe vystihovala krajinný pokryv zájmové oblasti a vychází z druhové skladby dostupné na webu ÚHÚL (pro rok 2015) a vlastního terénního měření. Navrženy byly dvě legendy: podrobná s dvanácti třídami a zjednodušená legenda s devíti třídami (tabulka č. 1). V podrobné legendě na úrovni druhů stromů jsou vymezeny třídy představující vodní plochy, zástavbu, silnici, stíny, holou půdu, ornou půdu, travu, smrk, modřín, buk, olši a kleč. Ve zjednodušené legendě jsou pak sloučeny jednotlivé druhy stromů pod jehličnany nebo listnáče a zástavba se silnicí pod antropogenní plochy. Grafickou ukázkou jednotlivých kategorií představují Obr. 4 – 13.

*Tabulka 1 – Legenda*

Legenda	
Podrobná legenda na úrovni stromů	Zjednodušená legenda
zástavba	antropogenní plochy
silnice	holá půda
holá půda	orná půda
orná půda	trvalý travní porost (TTP)
trvalý travní porost (TTP)	jehličnany
modřín	listnáče
smrk	kleč
olše	voda
buk	stíny
kleč	
voda	
stíny	

### Zástavba

Představuje veškeré zastavěné oblasti a objekty, jak pro rekreační a průmyslové účely (Corine Land Cover, 2018).



Obrázek 4 – zástavba

### Silnice

Silnice představuje všechny pozemní komunikace v zájmové oblasti určené k dopravě. Pozemní komunikace je dopravní cesta určená k užití silničními a jinými vozidly a chodci, včetně pevných zařízení nutných pro zajištění tohoto užití a jeho bezpečnosti. Jedná se o dálnice, silnice či místní a účelové komunikace (Corine Land Cover, 2018).



Obrázek 5 – silnice

### Holá půda


Jedná se o oblasti bez vegetace, které vznikly přirozeně nebo činností člověka a narušením. Součástí je i bezlesí (Corine Land Cover, 2018).



Obrázek 6 – holá půda

### Orná půda

Jedná se o pozemek obdělávaný za účelem produkce plodin nebo pozemek, který je k dispozici pro rostlinnou výrobu, ale je ponechán ladem, případně pozemek, který je dočasně zatravněn v rámci systému střídání plodin (Vyhláška č. 357/2013 Sb.).



*Obrázek 7 – orná půda*

### Trvalý travní porost (TTP)

Pozemek využívaný k pěstování trav nebo jiných bylinných píceňin, který nebyl zahrnut do systému střídání plodin a na kterém se mohou vyskytovat rozptýlené stromy a keře, případně jejich skupiny, pokud trávy a jiné bylinné píceňiny i nadále převažují (Vyhláška č. 357/2013 Sb.).



*Obrázek 8 – trvalý travní porost (TTP)*



### Jehličnany

Jde o druh lesa, ve kterém převládá množství jehličnatých stromů nad listnatými. Obecně se jedná o jehličnatý les, pokud je podíl jehličnatých dřevin větší než 75 % a minimální výška činí 5 m. V našem zájmovém území rozeznáváme smrk a modřín (Corine Land Cover, 2018).



Obrázek 9 – jehličnany

### Listnáče

Listnáče představují listnaté lesy, ve kterých množství převážně opadavých listnatých stromů přesahuje 75 %. Zbytek tvoří stromy jehličnaté. V našem modelovém území rozlišujeme olši a buk (Corine Land Cover, 2018).



Obrázek 10 – listnáče

### Kleč

Představuje dřeviny nad horní hranicí lesa, které nedosahují výšky jako jejich podobné druhy v nižších polohách. Většinou se jedná o jehličnany, nižšího nebo keřového vzrůstu (Corine Land Cover, 2018).



Obrázek 11 – kleč

### Voda

Pozemek, na němž je koryto vodního toku, vodní nádrž, močál, mokřad nebo bažina. Slouží jako přirozené nádrže, kde dochází k akumulaci vody, jenž se využívá pro hospodářské či pro vodohospodářské účely. Taktéž se hojně využívá i pro rekreační účely. Může se jednat o útvary vzniklé přírodní cestou nebo vytvořené člověkem. Na našem území představuje největší vodní plochu nádrž Fláje (Vyhláška č. 357/2013 Sb.).



Obrázek 12 – voda

### Stíny

Jsou vytvářeny vysokými objekty a nelze je odstranit korekcemi. Vznikají příčinou přímočarého šíření světla (Honskus, 2004).



Obrázek 13 – stíny

## **4. 5 Referenční data**

Trénovací plochy jsou nedílnou součástí řízených klasifikačních algoritmů. Je nutno je definovat před samotnou klasifikací na základně předem stanovené legendy. Trénovací data musí být kompletní a reprezentativní. To znamená, že musí být charakterizovány všechny třídy, které mají být klasifikovány, a to částmi obrazu, které jsou pro ně typické (Dobrovolný, 1998).

Referenční data byla tvořena manuálně nad webovou mapovou službou (WMS) z ÚHÚLu v kombinaci s orofotem ČR. Taktéž bylo zohledněno vlastní terénní měření pomocí mobilní aplikace ArcGis Collector určené pro sběr dat. V ENVI 5.5 se trénovací plochy definují pomocí nástroje ROI tool (Region Of Interest). V naší práci

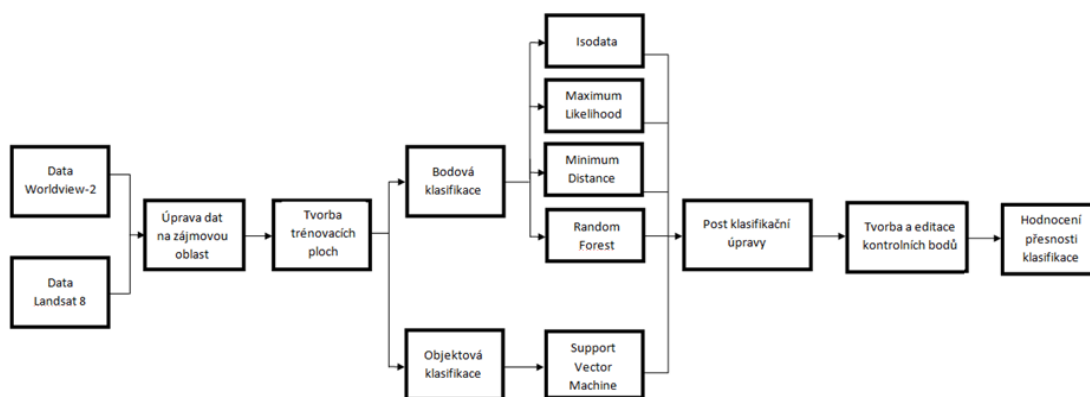
bylo definováno nejprve tedy 12 tříd dle první legendy a poté 9 tříd dle druhé zjednodušené legendy. Podrobně popsané kategorie legendy jsou uvedeny tabulce č. 1. Následně byla vygenerována statistika obsahující informaci o tom, jaké má daná kategorie zastoupení v pixelech. V případě objektové klasifikace kolik segmentů představuje danou kategorii. Obojí je znázorněno v tabulce č. 2.

*Tabulka 2 – počty trénovacích ploch a počty segmentů pro jednotlivé kategorie legendy*

Podrobná legenda na úrovni stromů					Zjednodušená legenda				
	Worldview-2		Landsat 8			Worldview-2		Landsat 8	
kategorie	počet pixelů	počet segmentů	počet pixelů	počet segmentů	kategorie	počet pixelů	počet segmentů	počet pixelů	počet segmentů
Zástavba	5974	62	98	25	Antropogenní plochy	10142	81	164	36
Silnice	4168	44	67	17	Holá půda	8965	30	166	24
Holá půda	8965	40	166	22	Orná půda	175874	26	793	20
Orná půda	175874	26	793	20	Trvalý travní porost (TTP)	23671	25	182	20
TTP	23671	25	182	16	Jehličnany	19361	93	288	18
Modřín	7765	45	99	3	Listnáče	17297	102	209	22
Smrk	11596	36	189	15	Kleč	2623	21	52	8
Olše	3542	42	45	5	Voda	3426	17	45	4
Buk	13755	66	164	17	Stíny	2495	43	129	14
Kleč	2623	27	52	8	Celkem	263854	438	2028	166
Voda	3426	15	45	4					
Stíny	2495	35	129	11					
Celkem	263854	463	2029	163					

## 4. 6 Metodika práce

Je složena z několika kroků, tím prvním bylo předzpracování dat, následně navazovala klasifikace upravených dat, post-processing snímku a poté zhodnocení přesnosti jednotlivých klasifikačních algoritmů. Shrnutí metodiky je znázorněno ve schématu (obr. č. 14).



Obrázek 14 – schéma metodiky

Před spuštěním samotného klasifikátoru je nutné zkontrolovat správnost vymezení trénovacích ploch. K tomu bylo využito číselné zhodnocení pomocí nástroje „Compute ROI separability“ v ENVI. Tento nástroj počítá vzdálenost tříd v příznakovém prostoru, a to dvěma algoritmy – Jeffries-Matusita a Transformed Divergence (výsledky Transformed Divergence obsaženy v přílohách č. 27 - 30). Výsledné hodnoty se pohybují v intervalu od 0 do 2. Hodnoty nad 1,9 indikují dobrou oddělitelnost posuzované dvojice tříd, při nižších hodnotách je třeba zkusit upravit příslušné trénovací plochy. Pokud jsou hodnoty menší než 1, je třeba zvážit, zda by dané třídy neměly být sloučeny v jednu (Richards, 1999, Jeffreys, 1946).

## 4. 7 Předzpracování dat:

### 4. 7. 1 Radiometrické korekce:

Úkolem je úprava DN hodnot jednotlivých pixelů v obraze, aby se co nejvíce podobaly skutečným odrazovým a zářivým vlastnostem objektů. Vznikají vlivem nepřesností náhodné povahy jako výpadek činnosti detektorů v průběhu snímání, vlivem atmosféry a podobně (Dobrovolný, 1998). V našem případě byly staženy snímky v úrovni zpracování level 2, kde je tato korekce provedena před výsledným poskytnutím snímku v datovém skladu či od poskytovatele.

#### **4. 7. 2 Geometrická korekce:**

Surová data mohou také obsahovat různé geometrické nepřesnosti způsobené zakřivením země nebo například kolísáním zdánlivé polohy objektu způsobené jejich nadmořskou výškou. Účelem je oprava těchto dat, aby odpovídala souřadnicovému systému a kartografickému zobrazení (Dobrovolný, 1998). Tato korekce bývá opět provedena poskytovatelem dat a vzhledem k úrovni zpracování našich snímků ji opět dělat nemusíme. Dokazuje to i překryv snímků s dostupným ortofotem po nastavení stejného souřadnicového systému.

#### **4. 7. 3 Atmosférická korekce:**

U satelitních snímků se můžeme setkat i s chybami způsobenými efekty atmosféry, které způsobují, že naměřené radiační či zářivé hodnoty neodpovídají skutečným vlastnostem. Tato korekce slouží opět k přiblížení skutečných hodnot (Dobrovolný, 1998). U produktů snímků Worldview-2 se zpracováním OR standart 2A nejsou tyto korekce zahrnuty. Hodnoty tedy představují pouze tzv. Top of Atmosphere (TOA) Radiance a nejde o skutečné hodnoty odrazivosti na zemském povrchu (Surface Reflectance – SR). C. Song et al. (2001) ve své studii tvrdí, že korekci na SR dělat nemusíme, protože při klasifikaci jednoho snímku to není potřeba, ale i přesto byla v této práci provedena, aby snímek obsahoval stejné zpracování, jako již pořízená data z družice Landsat 8 v úrovni zpracování level 2, které hodnoty odrazivosti na zemském povrchu (SR) již obsahují a nedošlo tak k nesrovnalostem ve výsledcích při porovnávání těchto dat.

### **4. 8 Úpravy snímků**

Před samotným klasifikováním dat, bylo z důvodu různých velikostí snímků nutné zvolit území modelové oblasti. To bylo zvoleno podle poskytnutého snímku družice Worldview-2, který byl oříznutím upraven, aby zaujímal pouze plochu na území České republiky. To především z důvodů dostupných podkladů z ÚHÚL pro definování trénovacích ploch a tvorbu kontrolních bodů nad ortofotem. U snímků Worldview-2 to bylo vytvořeno pomocí shapefilu pro Ústecký kraj dostupný z webu [cuzk.cz](http://cuzk.cz) a funkce „Build Mask“, kterou vytvoříme masku našeho snímku a následně ji aplikujeme na příslušný snímek. U dat Landsat bylo nutné před aplikováním masky oříznout snímek pomocí „Resize data“. Následně převést masku na soubor \*.roi pomocí nástroje „band threshold to roi“ a přes funkci „subset from roi“ oříznout data na zájmovou oblast. Následně bylo potřeba ještě atmosféricky korigovat snímek

Worldview-2. To bylo provedeno nástrojem „FLAASH Atmospheric Correction“. „Senzor type“ nastaven na Worldview-2, datum a čas letu dle metadat snímku (konkrétně 3. července v 15:03), „Ground Elevation“ upraven na průměrnou výšku zájmové oblasti (1.097 km), „Atmospheric Model“ na Sub-Arctic Summer, „Aerosol Model“ na Rural a v „multispectral setting“ -> „Kaufman-tanre aerosol retrieval“ definován horní a spodní multispektrální kanál – nejvyšší zvolen NIR2 a nejnižší Coastal Blue.



Obrázek 15 – původní velikost snímku Landsat 8 (červená) a WorldView-2 (modrá)

#### 4. 9 Klasifikace obrazu:

Nastavení parametrů níže uvedených metod zůstává stejné pro podrobnou legendu na druhové úrovni stromů i pro legendu zjednodušenou.

U bodové klasifikace je před spuštěním nutno definovat trénovací plochy. Ty se definují pomocí nástroje ROI (Region Of Interest) na základě předem zvolené legendy. Následně byl spuštěn algoritmus pro klasifikaci **Maximum Likelihood**. Zde byly vybrány předem definované trénovací plochy, *probability threshold* nastaven na *None Data* a *Scale Factor* na hodnotu 2047. Ostatní parametry nechány defaultní. U klasifikace **Minimum Distance** nechány všechny hodnoty přednastavené.

Pro algoritmus **Support Vector Machines (SVM)** byl využit nástroj v softwaru Envi 5.5 zvaný „Feature Extraction“. Zde bylo nutné nejprve segmentovat snímek. Toho bylo docíleno definicí parametrů takto: Algoritmus segmentu nastaven na *Edge*, stupnice na 35. sloučení algoritmu definováno jako *Full Lambda Schedule* a stupnice upravena na hodnotu 80. V dalším kroku pak byly vybrány reprezentativní vzorky ploch a přiřazeny různým třídám dle nejpodrobnější legendy (úrovně stromů), následně byly vybrány atributy pro klasifikaci a určeny parametry klasifikace.

Pro provedení klasifikace **Random Forest** bylo nutno přejít do programu ESA SNAP, kde po nahrání snímků bylo třeba importovat stejné trénovací plochy. V tomto případě bylo nutno před přesunutím se do ESA SNAP vyexportovat jednotlivé kategorie jako samostatné \*.shp soubory. Po spuštění definovány parametry: *Number of training samples* na 2500 a *number of trees* na 10. Následně vybrány všechny trénovací plochy a všechny pásma družice.

#### 4. 10 Post-processing snímků

Protože v případě bodové klasifikace často dochází k tzv. salt and pepper efektu, je vhodné klasifikaci upravit nízkofrekvenčním filtrem (Dobrovolný, 1998). K tomu bylo použito nástroje *Sieve Classes*, který zařadí do neklasifikované kategorie pixely o předem stanovené velikosti vyskytující se v izolovaném shluku pixelů ve zvolené oblasti a následně je těmto pixelům pomocí nástroje *Majority/Minority Analysis* přiřazena hodnota nejčastěji se vyskytující v okolí.

U *Sieve Classes* byl nastaven parametr „*pixel connectivity*“ na 8, „*minimum size*“ na 2. U *Majority/minority Analysis* byly vybrány všechny kategorie, zvolena metoda *Majority*, „*Kernel size*“ 3x3 a „*center pixel weight*“ nastaven na hodnotu 1. Vzhledem k výsledku klasifikací u snímků WV-2, kde algoritmy přiřazují oblast nádrže Fláje pod kategorii „zástavba“ či „antropogenní plochy“, bylo v rámci post-processingu vhodné klasifikovaný snímek manuálně doopravit pomocí nástroje *Edit Classification Image* a přiřadit tak nádrží Fláje klasifikační třídu pro vodu.

#### 4. 11 Hodnocení přesnosti

Při zhodnocení přesnosti klasifikačních algoritmů vycházíme z kontrolních bodů napříč celým zájmovým územím. K tomu bylo použito způsobu tvorby náhodných bodů *Stratified random* a k hodnocení byla použita metoda „Generate Random Sample Using Ground Truth Image“, která nám tyto body vytvoří. Následně bylo potřeba si tyto body otevřít v ArcMap 10.8, kde nad ortofotem a mapou druhové skladby ÚHÚL byla přiřazená kategorie a příslušné ID jí odpovídající, případně bod posunut či odstraněn. Každý bod musel mít jasně definovanou třídu. Tímto způsobem vzniklo ve výsledku 236 kontrolních bodů pro snímek Landsat 8 a 337 bodů pro Worldview-2. Tyto body byly posléze nahrány jako upravený shapefile zpět do ENVI 5. 5 a pomocí nástroje „Confusion Matrix Using Ground Truth ROIs“ byly přiřazeny třídy klasifikace třídám kontrolních bodů. Tím se vygeneroval textový soubor obsahující celkovou přesnost, Kappa koeficient a chybovou matici. Z tohoto dokumentu následně byly vytvořeny tabulky v Microsoft Excel 2019.

## 5. Výsledky

Zde se nachází zhodnocení a interpretace jednotlivých klasifikačních algoritmů provedených v rámci metodiky. Pro lepší přehlednost jsou výsledky chybových matic znázorněny v tabulkách, kde se uvádí celková, uživatelská a zpracovatelská přesnost. Všechny údaje jsou převzaty z chybových matic získaných nástrojem „Confusion Matrix Using Ground Truth ROIs“. U této matice jsou sloupce tvořeny referenčními body a všechna hodnocení přesnosti mají dokazující hodnotu o přesnosti klasifikace celého obrazu (Lillesand et al., 2008).

### 5.1 Výsledky podrobné legendy

#### 5.1.1 Výsledky podrobné legendy snímku Worldview-2

Tabulka 3 – chybová matice Maximum Likelihood u WV-2

chybová matice - Maximum Likelihood - WV-2														
kategorie	zástavba	silnice	holá půda	orná půda	TTP	modřín	smrk	olše	buk	kleč	voda	stíny	celkem	uživatelská přesnost [%]
zástavba	15	4	0	0	0	0	0	0	0	0	1	0	20	75,00
silnice	4	22	1	0	1	0	0	0	0	0	3	0	31	70,97
holá půda	0	1	14	3	4	1	0	0	2	1	0	0	26	53,85
orná půda	0		2	11	7	0	0	0	0	0	0	0	20	55,00
trvalý travní porost (TTP)	0	0	0	5	30	0	0	4	1	0	0	0	40	75,00
modřín	0	0	0	0	0	19	9	0	3	1	0	0	32	59,38
smrk	0	0	0	0	0	1	36	0	2	0	0	1	40	90,00
olše	0	0	0	0	10	0	2	7	3	0	0	0	22	31,82
buk	0	0	0	0	0	1	0	0	18	0	0	0	19	94,74
kleč	0	0	1	0	0	3	5	0	0	11	2	0	22	50,00
voda	0	0	0	0	0	0	0	0	0	0	20	0	20	100,00
stíny	0	0	0	0	0	0	16	0	0	0	0	24	40	60,00
celkem	19	27	18	19	52	25	68	11	29	13	26	25	332	---
zpracovatelská přesnost [%]	78,95	81,48	77,78	57,89	57,69	76,00	52,17	63,64	62,07	84,62	76,92	96,00	---	68,17
													kappa	0,65

Kontrolních bodů pro hodnocení klasifikace **Maximum Likelihood** bylo celkem 332. Celková přesnost klasifikace dosáhla 68,17 % (tabulka č. 3). Ze všech provedených metod získala právě tato nejvyšší celkovou přesnost pro klasifikaci na druhové úrovni stromů. V rámci uživatelské přesnosti byla nejlépe klasifikována třída vodních ploch, která dosáhla celých 100 % přesnosti. Naopak nejhorších uživatelských



výsledků docílila třída představující olši (31,82 %). Co se týče přesnosti zpracovatelské, zde nejhůře dopadla kategorie smrk s 52,17 % a nejlépe kategorie zastupující stíny (96 %). Celkově lze říci, že přesnosti klasifikace Maximum Likelihood na úrovni druhů stromů se pohybují v poměrně vysokých číslech a s výjimkou zmíněné olše ani jedna z ostatních kategorií neklesla v přesnosti jak uživatelské, tak zpracovatelské pod 50 %.

Tabulka 4 – chybová matice Minimum Distance u WV-2

chybová matice - Minimum Distance - WV-2														
kategorie	zástavba	silnice	holá půda	orná půda	TTP	modřín	smrk	olše	buk	kleč	voda	stíny	celkem	uživatelská přesnost [%]
zástavba	6	6	4	0	0	0	0	0	0	0	0	0	16	37,50
silnice	5	21	0	0	0	0	0	0	0	0	0	0	26	80,77
holá půda	1	0	10	5	1	0	3	0	1	1	0	0	22	45,45
orná půda	3	0	0	4	6	0	0	0	0	0	0	0	13	30,77
trvalý travní porost (TTP)	0	0	0	9	30	0	0	8	14	0	0	0	61	49,18
modřín	0	0	3	0	0	15	13	0	4	2	0	0	37	40,54
smrk	0	0	0	0	0	3	12	0	1	2	0	0	18	66,67
olše	0	0	0	0	11		1	2	4	0	0	0	18	11,11
buk	0	0	1	1	3	2	1	1	5	0	0	0	14	35,71
kleč	0	0	0	0	0	4	16	0	0	8	0	0	28	28,57
voda	1	0	0	0	1	0	1	0	0	0	26	7	36	72,22
stíny	3	0	0	0	0	1	22	0	0	0	0	17	43	39,53
celkem	19	27	18	19	52	25	69	11	29	13	26	24	332	---
zpracovatelská přesnost [%]	31,58	77,78	55,56	21,05	57,69	60,00	17,39	18,18	17,24	61,54	100,00	68,00	---	46,85
													kappa	0,42

U algoritmu **Minimum Distance** byl opět počet kontrolních bodů 332. Bylo zde dosaženo 46,85 % celkové přesnosti (tabulka č. 4). Nejnižší uživatelskou přesností se vyznačuje opět kategorie pro olši, v případě klasifikace Minimum Distance má nízkou hodnotu 11,11 %. Nejvyšší uživatelskou přesností je naopak třída silnic (80,77 %). Zpracovatelská přesnost se pohybuje ve vysokých číslech u vody, kde je docíleno 100 %, což znamená, že by žádný pixel ve výsledné mapě krajinného pokryvu označený jako voda neměl být jiným povrchem, avšak uživatelská přesnost této kategorie je již o dost nižší (72,22 %), protože několik pixelů ve skutečnosti reprezentující vodní plochu bylo algoritmem označeno za jiný povrch. Nejmenší hodnotu zpracovatelské přesnosti má třída reprezentující buk (17,24 %).

Tabulka 5 – chybová matice Random Forest u WV-2

chybová matice - Random Forest - WV-2															
kategorie	zástavba	silnice	holá půda	orná půda	TTP	modřín	smrk	olše	buk	kleč	voda	stíny	celkem	uživatelská přesnost [%]	
zástavba	17	6	3	0	1	0	0	0	0	0	0	0	27	62,96	
silnice	0	20	0	0	0	0	0	0	0	0	0	0	20	100,00	
holá půda	0	1	9	0	0	1	1	0	0	0	0	0	12	75,00	
orná půda	0	0	4	10	0	0	0	0	0	0	0	0	14	71,43	
trvalý travní porost(TTP)	0	0	0	5	34	0	0	0	1	0	0	0	40	85,00	
modřín	0	0	0	0	1	21	13	0	7	1	0	0	43	48,84	
smrk	0	0	0	0		2	43	0	0	0	1	2	48	89,58	
olše	0	0	0	2	4	0	0	7	1	0	0	0	14	50,00	
buk	0	0	2	2	12	0	3	4	21	1	0	0	45	46,67	
kleč	0	0	0	0	0	3	4	0	0	10	0	0	17	58,82	
voda	0	0	0	0	0	0	0	0	0	0	11	0	11	100,00	
stíny	2	0	0	0	0	1	5	0	0	1	14	23	46	50,00	
celkem	19	27	18	19	52	28	69	11	30	13	26	25	337	---	
zpracovatelská přesnost [%]	89,47	74,07	50,00	52,63	65,38	75,00	62,32	63,64	70,00	76,92	42,31	92,00	---	67,06	

V případě klasifikátoru **Random Forest** byla získána celková přesnost o hodnotě 67,06 % (tabulka č. 5). Celkem bylo určeno a přiřazeno 337 kontrolních bodů, to znamená, že nedošlo k přiřazení žádného z bodů do třídy „neklasifikováno“, jako v předešlých případech. Nejvyšší uživatelské přesnosti dosáhly třídy reprezentující silnice a vodu (100 %). S nejmenší přesností byla určena kategorie buk (46,67 %). U zpracovatelské přesnosti je nejlépe určená třída pro stíny (92 %) a nejmenší přesnost představuje kategorie voda (42,31 %).

Tabulka 6 – chybová matice Support Vector Machines u WV-2

chybová matice - Support Vector Machines - WV-2														
kategorie	zástavba	silnice	holá půda	orná půda	TTP	modřín	smrk	olše	buk	kleč	voda	stíny	celkem	uživatelská přesnost [%]
zástavba	17	2	0	0	1	0	2	0	0	0	0	2	24	70,83
silnice	1	23	0	0	0	0	0	0	0	0	0	0	24	95,83
holá půda	0	1	10	0	1	0	0	0	0	0	0	0	12	83,33
orná půda	0	0	1	17	24	0	0	1	0	0	0	0	43	39,53
trvalý travní porost (TTP)	1	0	1	1	12	0	0	0	2	0	0	0	17	70,59
modřín	0	0	1	0	0	19	14	0	4	0	0	1	39	48,72
smrk	0	1	0	0	0	1	29	0	0	1	0	5	37	78,38
olše	0	0	0	0	6	0	1	5	5	0	0	0	17	29,41
buk	0	0	1		6	1	4	5	17	0	0	0	34	50,00
kleč	0	0	4	1	2	4	7	0	1	12	0	0	31	38,71
voda	0	0	0	0	0	0	0	0	0	0	23	0	23	100,00
stíny	0	0	0	0	0	0	12	0	0	0	3	17	32	53,13
celkem	19	27	18	19	52	25	69	11	29	13	26	25	333	---
zpracovatelská přesnost [%]	89,47	85,19	55,56	89,47	23,08	76,00	42,03	45,45	58,62	92,31	88,46	68,00	---	60,36
													kappa	0,57

Metoda objektové klasifikace **Support Vector Machines** u podrobné legendy docílila celkově 60,36 % (tabulka č. 6). Nejmenší uživatelskou přesnost má olše (29,41 %) a zpracovatelskou trvalý travní porost (TTP) (23,08 %). Nejvyšší hodnoty měla u uživatelské přesnosti voda se 100 % a u zpracovatelské kategorie kleč (92,31 %). V případě tohoto klasifikátoru bylo určeno 333 kontrolních bodů.

## 5.1.2 Výsledky podrobné legendy snímku Landsat 8

Tabulka 7 – chybová matice Maximum Likelihood u L8

chybová matice - Maximum Likelihood - Landsat 8														
kategorie	zástavba	silnice	holá půda	orná půda	TTP	modřín	smrk	olše	buk	kleč	voda	stíny	celkem	uživatelská přesnost [%]
zástavba	3	1	0	0	1	0	0	0	0	0	0	0	5	60,00
silnice	2	4	0	0	0	0	0	0	0	0	0	0	6	66,67
holá půda	1	3	1	1	4	0	1	0	0	3	0	1	15	6,67
orná půda	0	0	0	4	12	0	0	0	0	0	0	0	16	25,00
trvalý travní porost (TTP)	0	1	4	5	14	0	1	0	0	1	0	1	27	51,85
modřín	0	0	1	0	1	8	14	0	0	0	0	1	25	32,00
smrk	0	0	2	0		0	29	0	0	0	0	7	38	76,32
olše	0	1	2	0	1	0	2	5	3	0	0	1	15	33,33
buk	0	1	0	0	2	0	2	0	8	0	0	0	13	61,54
kleč	0	0	2	0	1	2	1	0	0	4	0	0	10	40,00
voda	0	0	0	0	1	0	0	0	0	0	23	1	25	92,00
stíny	1	1	5	0	2	3	11	0	4	1	1	2	31	6,45
celkem	7	12	17	10	39	13	61	5	15	9	24	14	226	---
zpracovatelská přesnost [%]	42,86	33,33	5,88	40,00	32,56	61,54	46,77	100,00	53,33	44,44	92,00	14,29	---	45,26
													kappa	0,39

V případě klasifikátoru **Maximum Likelihood** u snímku z družice Landsat 8 bylo docíleno celkové přesnosti 45,26 % (tabulka č. 7). Celkem bylo určeno a přiřazeno 226 kontrolních bodů. Nejvyšší uživatelské přesnosti dosáhly třídy reprezentující vodu (92 %). S nejmenší přesností byla určena kategorie stíny (6,45 %) a holá půda (6,67 %). U zpracovatelské přesnosti je nejlépe určená třída olše (100 %) a nejmenší přesnost představuje kategorie holé půdy (5,88 %).

Tabulka 8 – chybová matice Minimum Distance u L8

chybová matice - Minimum Distance - Landsat 8														
kategorie	zástavba	silnice	holá půda	orná půda	TTP	modřín	smrk	olše	buk	kleč	voda	stíny	celkem	uživatelská přesnost [%]
zástavba	3	1	1	0	3	0	1	0	0	0	0	0	9	33,33
silnice	3	2	0	0	1	0	0	0	0	0	0	2	8	25,00
holá půda		4	4			2	2			3		2	17	23,53
orná půda	0	0	1	5	16	0	0	1	4	0	0	0	27	18,52
trvalý travní porost (TTP)	1	1	1	4	8	0	0	0	0	0	0	1	16	50,00
modřín	1	1	0	0	2	7	6	0	0	0	0	1	18	38,89
smrk	0	0	1	0	1	0	29	0	0	3	1	6	41	70,73
olše	0	2	1	1	4	0	2	2	5	0	1	0	18	11,11
buk	0	0	0	0	1	0	0	1	3	0	0	0	5	60,00
kleč	0	0	5		2	4	17	0	1	3	0	1	33	9,09
voda	0	0	1	0	1	0	1	0	0	0	22	0	25	88,00
stíny	0	1	2	0	3	1	4	0	1	0	0	1	13	7,69
celkem	8	12	17	10	42	14	62	4	14	9	24	14	230	---
zpracovatelská přesnost [%]	42,86	16,67	23,53	50,00	18,60	50,00	46,77	40,00	20,00	33,33	88,00	7,14	---	38,20
													kappa	0,31

Kontrolních bodů pro hodnocení klasifikace **Minimum Distance** u snímku Landsat 8 bylo celkem 230. Celková přesnost klasifikace dosáhla 38,20 % (tabulka č. 8). V rámci uživatelské přesnosti byla nejlépe klasifikována třída vodních ploch, která dosáhla 88 % přesnosti. Naopak nejhorší uživatelské výsledky získala třída představující stíny (7,69 %). U přesnosti zpracovatelské nejhůře dopadla taktéž kategorie pro stíny s 7,14 % a nejlépe také kategorie voda (88 %).

Tabulka 9 – chybová matice Random Forest u L8

chybová matice - Random Forest - Landsat 8														
kategorie	zástavba	silnice	holá půda	orná půda	TTP	modřín	smrk	olše	buk	kleč	voda	stíny	celkem	uživatelská přesnost [%]
zástavba	4	0	0	0	3	0	1	0	0	0	0	0	8	50,00
silnice	1	6	1	0	0	0	0	0	0	0	0	1	9	67,67
holá půda	0	3	10	0	6	2	6	0	0	3	0	2	32	31,25
orná půda	1	2	2	9	22	0	0	3	4	0	0	0	43	20,93
trvalý travní porost (TTP)	0	0	0	1	8	0	0	0	0	0	0	0	9	88,89
modřín	0	0	1	0	1	9	10	0	1	0	0	2	24	37,50
smrk	0	1	1	0	1	0	32	0	0	0	3	6	44	72,73
olše	0	0	0	0	1	1	1	2	1	0	0	1	7	28,57
buk	1	0	0	0	1	0	2	0	9	0	0	0	13	69,23
kleč	0	0	2	0	0	2	10	0	1	5	1	1	22	22,73
voda	0	0	0	0	0	0	0	0	0	0	23	0	23	100,00
stíny	0	0	0	0	0	0	0	0	0	1	0	1	2	50,00
celkem	7	12	17	10	43	14	62	5	16	9	27	14	236	---
zpracovatelská přesnost [%]	57,14	50,00	58,82	90,00	19,60	64,29	51,61	40,00	56,25	55,56	85,19	7,14	---	50,00

U algoritmu **Random Forest** byl počet kontrolních bodů 236. Bylo zde dosaženo 50 % celkové přesnosti (tabulka č. 9). U klasifikátorů snímků Landsat 8 se jedná o nejvyšší dosaženou přesnost ze všech provedených metod klasifikace. Nejnižší uživatelskou přesností se vyznačuje kategorie pro ornou půdu (20,93 %). Nejvyšší z uživatelské přesnosti je naopak třída vody (100 %). Zpracovatelská přesnost se pohybuje ve vysokých číslech u orné půdy, kde je dosaženo 90 %. Nejmenší hodnotu zpracovatelské přesnosti má třída reprezentující stíny (7,14 %).

Tabulka 10 – chybová matice SVM u L8

chybová matice - Support Vector Machines - Landsat 8														
kategorie	zástavba	silnice	holá půda	orná půda	TTP	modřín	smrk	olše	buk	kleč	voda	stíny	celkem	uživatelská přesnost [%]
zástavba	4	2	0	1	2	0	0	0	0	0	0	0	9	44,44
silnice	1	4	6		1	3	9		1	5		4	34	11,76
holá půda	0	0	0	0	0	0	0	0	0	0	0	0	0	0,00
orná půda	0	0	0	3	17	0	0	0	1	0	0	0	21	14,29
trvalý travní porost(TTP)	0	0	0	0	0	0	3	1	1	0	0	1	6	0,00
modřín	0	0	2	0	0	6	13	0	0	1	0	0	22	27,27
smrk	0	0	0	0	1	1	13	0	0	1	3	2	21	61,90
olše	1	5	8	4	15	3	19	4	6	1	1	6	73	5,48
buk	0	1	0	1	4	0	0	0	6	0	0	0	12	50,00
kleč	0	0	0	1	1	0	1	0	0	0	0	0	3	0,00
voda	1	0	1	0	2	1	1	0	1	1	21	1	30	70,00
stíny	0	0	0	0	0	0	3	0	0	0	0	0	3	0,00
celkem	7	12	17	10	43	14	62	5	16	9	25	14	234	---
zpracovatelská přesnost [%]	57,14	33,33	0,00	30,00	0,00	42,86	20,97	80,00	37,50	0,00	84,00	0,00	---	26,07
													kappa	0,20

U objektové klasifikace **Support Vector Machines** na snímku Landsat 8 dosáhla celková přesnost 26,07 %, což je ze všech metod nejnižší hodnota. Jak je možné vidět v tabulce č. 10, nejmenší přesnost mají hned čtyři kategorie krajinného pokryvu. Konkrétně se jedná o holou půdu, trvalý travní porost (TTP), kleč a stíny. Všechny tyto kategorie mají nulovou uživatelskou i zpracovatelskou přesnost, to znamená, že ani jedna z těchto kategorií nebyla na snímku dobře klasifikována. Nejvyšší hodnoty má u uživatelské i zpracovatelské přesnosti voda.

## 5.2 Výsledky pro zjednodušenou legendu

Zde jsou interpretovány výsledky klasifikátorů na základě zjednodušené legendy. Interpretace v této části je pouze textová, tabulky s přehledem chybových matic pro tuto legendu jsou uvedeny v přílohách č. 1 až 8.

### 5.2.1 Výsledky zjednodušené legendy snímku Worldview-2

V případě klasifikace **Maximum Likelihood** došlo k výraznému zlepšení celkové přesnosti na 73,57 %. Kontrolních bodů bylo i v tomto případě 333. Uživatelská přesnost udává nejvyšší hodnotu opět u kategorie antropogenních ploch (91,97 %). V tomto případě je třída antropogenních ploch i nejvíce dosažitelnou hodnotou u zpracovatelské přesnosti (95,65 %). Naopak nejnižší uživatelské přesnosti dosahuje kleč (50 %) a nejnižší zpracovatelskou přesnost má orná půda (57,89 %). V případě této klasifikační metody bylo docíleno vysokých čísel u obou přesností s převyšujícími hodnotami 50 %. V rámci zjednodušené legendy u snímků WV-2 se jedná o nejpresnější výsledek klasifikace. Chybová matice pro zjednodušenou legendu a snímek WV-2 je obsažena v příloze č. 2.

U klasifikátoru **Minimum Distance** pro snímek WV-2 došlo v případě zjednodušené legendy ke zlepšení celkové přesnosti na 51,35 %. Nejvyšší uživatelskou přesnost měla třída antropogenních ploch (87,5 %). Nejmenší uživatelskou přesnost naopak stíny (35,42 %). Co se týče přesnosti zpracovatelské, tam bylo nejvyšší hodnoty dosaženo u kategorie voda (100 %) a nejnižší u třídy listnáče, kde je přesnost na hodnotě 30 %. Celkově bylo rozpoznáno 333 kontrolních bodů. Chybová matice pro zjednodušenou legendu a snímek WV-2 je obsažena v příloze č. 1.

Chybová matice v případě algoritmu **Random Forest** pro snímek WV-2 a zjednodušenou legendu ukazuje na pokles celkové přesnosti (64,39 %). Kontrolních bodů bylo rozeznáno stejně jako u legendy podrobné – 337. Uživatelská přesnost dosahuje nejvyšších hodnot u kategorie voda (95 %) a nejnižší u kategorie kleč (32,36 %). U zpracovatelské přesnosti bylo docíleno nejvyšší přesnosti u třídy antropogenních ploch (95,65 %) a nejmenší přesnosti u jehličnanů (40,2 %). Chybová matice pro zjednodušenou legendu a snímek WV-2 je obsažena v příloze č. 3.

U zástupce objektové klasifikace **Support Vector Machines** došlo v rámci zjednodušení legendy také o zlepšení celkové přesnosti. Konkrétně na 67,27 %. Nejvyšší uživatelská přesnost zde byla získaná pro třídu představující vodu (92 %) Nejvyšší zpracovatelská přesnost byla u třídy orná půda (89,47 %). Naopak k nejmenší přesnosti uživatelské i zpracovatelské došlo u třídy kleč (27,27 % a 23,08



%). Chybová matice pro zjednodušenou legendu a snímek WV-2 je obsažena v příloze č. 4.

### 5.2.2 Výsledky zjednodušené legendy snímku Landsat 8

U snímku Landsat 8 pro klasifikační metodu **Maximum Likelihood** a zjednodušenou legendu došlo taktéž ke zvýšení celkové přesnosti. Konkrétní celková přesnost je 50 %. K hodnocení bylo využito 228 kontrolních bodů. Nejvyšší uživatelskou přesnost dosáhla kategorie antropogenních ploch (88,89 %), nejmenší stíny (9,09 %). Co se týče zpracovatelské přesnosti, zde bylo dosaženo nejvyšší hodnoty u vody (92 %) a nejmenší u holé půdy (5,88 %). Chybová matice pro zjednodušenou legendu a snímek WV-2 je obsažena v příloze č. 6.

Pro klasifikátor **Minimum Distance** bylo využito celkových 232 kontrolních bodů a celková přesnost se oproti podrobné legendě zvýšila o pár procentních bodů na 39,91 %. Nejvyšší uživatelská a zpracovatelská přesnost byla dosažena u třídy voda (81,48 % a 88 %). Nejmenší uživatelskou přesnost představuje třída stínů (5,71 %). U zpracovatelské přesnosti bylo dosaženo nejnižší hodnoty taktéž u kategorie stíny (14,29 %). Chybová matice pro zjednodušenou legendu a snímek WV-2 je obsažena v příloze č. 5.

U **Random Forest** klasifikace se stejně jako u snímků WV-2 výsledek celkové přesnosti pro zjednodušenou legendu o něco snížil. Celková přesnost klasifikace u zjednodušené legendy má hodnotu 43,64 %. I zde byly využity všechny kontrolní body a žádný nebyl identifikován ke třídě „neklasifikováno“. Nulová přesnost uživatelská i zpracovatelská byla vypočtena u tříd jako je trvalý travní porost (TTP) nebo stínů. Nejvyšší uživatelská přesnost byla u vody (87,5 %) a nejlepší zpracovatelskou přesnost představuje třída orné půdy (100 %). Chybová matice pro zjednodušenou legendu a snímek WV-2 je obsažena v příloze č. 7.

U algoritmu založeného na objektovém přístupu **Support Vector Machines** došlo u snímků z družice Landsat 8 také k mírnému zvýšení celkové přesnosti na 33,76 %. U této metody představuje nulovou uživatelskou i zpracovatelskou přesnost třída holá půda. Nejvyšší uživatelské i zpracovatelské přesnosti dosahuje opět voda, která má v obou případech 80% přesnost. Chybová matice pro zjednodušenou legendu a snímek WV-2 je obsažena v příloze č. 8.

### 5.3 Porovnání výsledků klasifikace

Tato část je věnována porovnání provedených klasifikačních metod. Veškeré klasifikační metody proběhly se stejně volenými parametry a stejnými trénovacími plochami jak u snímku Worldview-2, tak u snímku Landsat 8. Konkrétní hodnoty celkových přesností u jednotlivých klasifikačních metod jsou znázorněny v tabulce č. 11.

Tabulka 11 – porovnání celkových přesností využitých algoritmů

Celková přesnost klasifikace [%]				
Klasifikace	WV-2		L8	
	Podrobná legenda	Zjednodušená legenda	Podrobná legenda	Zjednodušená legenda
ML	68,17	73,57	45,26	50,00
MD	46,85	51,35	38,20	39,91
RF	67,06	64,39	50,00	43,64
SVM	60,36	67,27	26,07	33,76
	337 kontrolních bodů		236 kontrolních bodů	

Zde je jasně vidět, že v případě podrobné legendy zaměřující se na rozpoznání jednotlivých druhů stromů v zájmovém území dosahují snímky družice Worldview-2 lepších výsledků a je tedy vhodnější pro tuto problematiku pracovat právě se snímky velmi vysokého rozlišení. Největší přesnosti klasifikace bylo dosaženo u algoritmu bodové klasifikace Maximum Likelihood, kde hodnota překonala 68 % přesnosti. Pro druhové rozpoznání lesních porostů je vhodná dle výsledků i metoda Random Forest, která byla na hodnotě celkové přesnosti 67,06 %.

Pro potřeby získání krajinného pokryvu bez druhového rozlišení dřevin je vhodný opět klasifikátor Maximum Likelihood či metoda založená na objektovém přístupu Support Vector Machines. Naopak u klasifikace Random Forest došlo ke snížení přesnosti oproti druhové klasifikaci u obou snímků WV-2 i L8.

## 6. Diskuse

Dálkový průzkum Země je čím dál tím více využívanější metodou pro získávání informací o Zemi. Díky DPZ lze v dnešní době poměrně přesně získat informace o krajinném pokryvu kdekoli na světě. Se satelitními daty v současnosti může pracovat i méně zkušený uživatel internetu pomocí různých volně dostupných platforem jako je například Google Earth, Google Earth Engine, Sentinel Playground a další.

Mnoho snímků v různém rozlišení je dostupných i volně ke stažení (Landsat, Sentinel aj.) a tak nemusíme vynaložit žádné velké finanční prostředky k získání určitých prostorových informací o krajině. Tyto informace jsou samozřejmě ovlivněny stářím daného snímku, prostorovým rozlišením snímačů a časovým intervalem snímání. Pokud chceme pracovat s kvalitnějšími snímky, ve většině případů se jedná o již komerční záležitost a snímky jsou dostupné koncovým uživatelům za finanční obnos. V rámci mé práce jsem měl možnost provádět analýzy na datech velmi vysokého rozlišení, které byly zakoupeny naší fakultou v rámci řešení jiného projektu. Konkrétně se jednalo o snímky z družice Worldview-2 pro oblast Krušných hor. Vzhledem k datu pořízení snímku, bylo cílem získat volně dostupná data k porovnání klasifikačních metod v podobném časovém období, aby nedocházelo k nesrovnalostem způsobeným jiným ročním obdobími či rokem. Pro účely mé bakalářské práce bylo využito snímku z družice Landsat 8. Původně jsem chtěl využít k porovnání snímků z družice Sentinel-2A, která začala právě v roce 2015 pořizovat data, ale nakonec se mi nepovedl získat bezoblačný snímek pro dané časové období.

Pro potřeby druhové klasifikace na základě snímků s velmi vysokým rozlišením se nejlépe ukázala klasifikační metoda založená na bodovém přístupu – metoda Maximum Likelihood. Osobně jsem se snažil klást důraz na přesnost trénovacích dat i kontrolních bodů se snahou co nejvíce se přiblížit realitě, proto jsem čekal výsledky klasifikací ve vyšších číslech. Po ladění různých parametrů jednotlivých klasifikací a mnoho úpravách a opakování jsem bohužel nedosáhl lepších výsledků, než jsou prezentovány. To může být zapříčiněno chybným přiřazením pixelů vybraných trénovacích ploch, jež mohou představovat pixely jiných typů pokryvu. U metody založené na objektovém přístupu mohla být přesnost snížena taktéž špatným definováním parametrů segmentace, nevhodným výběrem trénovacích vzorků nad ortofotem či zvolením nevyhovujících atributů pro klasifikaci. Taktéž mohlo dojít k chybám při zpětném kontrolování pomocí náhodných bodů, jímž byla přiřazována kategorie na základě dostupných ortofoto snímků, ač tyto body byly

doplněny na základě vlastního terénního průzkumu (např. při vizuální kontrole bodů nad klasifikací bylo odhaleno několik bodů na hranici dvou pixelů). Jednou z dalších možných chyb při výsledném hodnocení může být právě snaha o druhovou klasifikaci, protože se jedná o třídy krajinného pokryvu s podobnými spektrálními vlastnostmi. Ke zlepšení přesnosti by mohlo pomoci nasbírat většinu kontrolních bodů i trénovacích ploch pomocí důkladnějšího terénního měření pomocí přístrojů globálních navigačních systémů (GNSS). Všechny zmíněné chyby jsem se ve své práci snažil co nejvíce eliminovat.

V porovnání s již uvedenými publikacemi zabývajícími se podobným tématem se výsledky této práce poměrně liší. Především co se týče celkových přesností klasifikátorů založených na objektovém přístupu, jako je Support Vector Machine (ty u snímků WV-2 např. v publikaci od Jombo et al. (2021) dosahují 87,3 %, ve studii od Štycha et al. (2019) bylo docíleno 86 %) a přesahují tak algoritmy založené na bodovém přístupu, na rozdíl od zde vyšlé přesnosti pro SVM. Ta dosahovala v této práci 60,3 % pro snímek z družice WV-2. Jednou z příčin rozdílných výsledků publikovaných prací s touto možou být některé z výše uvedených chyb způsobených během průběžné práce s daty. Dalším ovlivňujícím parametrem mezi výsledky této a jiných prací, např. s publikací od Jombo et al. (2021) může být zvolená zájmová oblast, nad kterou jsou analýzy obrazu vytvářeny. Jelikož práce Jombo et al. (2021) je zaměřená především na detekci stromů v městském prostředí, lze dle mého uvážení jasně oddělit kategorie urbanizovaného území a antropogenních ploch, zatímco námi zvolená zájmová oblast se nachází z většiny mimo zastavěné území a rozlišitelnost jednotlivých tříd v krajinně je tak o něco složitější. Určitě by bylo zajímavé rozšířit tuto práci o další metody klasifikace založené právě na objektovém přístupu jako např. Random Forest, Neural Net atd., které byly použity i v již zmíněných publikacích a porovnat celkové výsledky i pro naši lokalitu Krušných hor.

## 7. Závěr

Cílem bakalářské práce byla klasifikace krajinného pokryvu Krušných hor na území ČR na úrovni druhové skladby lesních porostů. Dílčí cíle byly spojeny s tvorbou a úpravou referenčních dat, tvorbou legendy, výběrem klasifikačních algoritmů a následným zhodnocením přesnosti klasifikace.

Bylo použito klasifikačních algoritmů na bázi pixelů (per pixel klasifikace) i jednoho algoritmu založeném na objektovém přístupu klasifikace. Konkrétně bylo tedy použito klasifikačních metod Maximum Likelihood, Minimum Distance, Random Forest a Support Vector Machines.

Pro srovnání byly vytvořeny dvě legendy – první na druhové úrovni stromů s 12 třídami, druhá zjednodušená s 9 třídami. Nejlepší celkové přesnosti u snímku WV-2 dosáhl algoritmus Maximum Likelihood, který na druhové úrovni dosáhl hodnoty 68,17 %. Také hodnoty uživatelské a zpracovatelské přesnosti se zde pohybovaly v číslech přesahujících 50 %, kromě třídy představující olši, která měla hodnotu uživatelské přesnosti necelých 32 %. Na úrovni zjednodušené legendy tento algoritmus dosáhl výsledné přesnosti 73,57 %. U snímků L8 bylo dosaženo nejvyšší druhové přesnosti s hodnotou 50 % u pixelového klasifikátoru Random Forest. U zjednodušené legendy měl nejvyšší hodnotu opět Maximum Likelihood (50 %).

### 7.1 Výzkumné otázky:

- (a) Je možné pomocí multispektrálních snímků z družice WorldView-2 klasifikovat lesní prostory na úrovni druhů stromů?

Pomocí multispektrálních snímků lze poměrně dobře klasifikovat lesní porosty na druhové úrovni. Výsledky se liší v závislosti na použitých klasifikačních metodách. Dokazují to i zveřejněné publikace zabývající se touto tematikou.

- (b) Jak se liší přesnost klasifikace WorldView-2 proti klasifikaci využívající multispektrální data vysokého rozlišení Landsat 8?

Celkově je v rámci použití snímků WV-2 dosaženo větších přesností než u klasifikace snímků L8. Hodnoty se opět liší v závislosti na zvoleném algoritmu a určení kontrolních bodů. V této práci se liší některé klasifikační algoritmy i o několik desítek procent ve výsledku celkové přesnosti. Například u objektové klasifikace SVM se výsledek přesnosti liší o cca 34 % mezi snímkem WV2 a L8.

- (c) Jaký z vybraných algoritmů pixelové či objektové klasifikace je pro řešení této problematiky nejvhodnější a naopak?

V této bakalářské práci se jeví jako nejvhodnější algoritmus pro druhovou klasifikaci lesních porostů u snímků WV-2 metoda Maximum Likelihood, dosahující celkové přesnosti 68,17 %. Slibných výsledků dosahuje i klasifikace Random Forest (67,06 %). Naopak nejméně přesné výsledky byly dosaženy klasifikátorem Minimum Distance (46,85 %).

(d) Lze vytvořit referenční data v dostatečné přesnosti z dostupných "online" zdrojů (například data ÚHUL, ortofoto ČR apod.), nebo je nutné jejich doplnění vlastním terénním průzkumem?

Podle výsledků a průběhu této práce lze říct, že referenční data se dají z online zdrojů, je-li jim věnována dostatečná pozornost, vytvořit v poměrně dobré kvalitě, ovšem doplníme-li je i o body získané vlastním měřením, určitě uděláme dobře. Přesnost se o něco málo zvýší a také si tím ověříme, zdali jsme se při přidělování trénovacích ploch nebo kontrolních bodů nedopustili nějakých výraznějších odlišností.

## 8. Seznam zdrojů informací

1. BREIMAN, L.: Machine Learning [online]. 45(1), 5-32 [cit. 2021-03-16]. ISSN 08856125. Dostupné z: doi:10.1023/A:1010933404324
2. COSTA, H., FOODY, G. M., BOYD, D. S.: Supervised methods of image segmentation accuracy assessment in land cover mapping. Remote Sensing of Environment [online]. 2018, 205, 338-351 [cit. 2021-03-16]. ISSN 00344257. Dostupné z: doi:10.1016/j.rse.2017.11.024
3. DIGITALGLOBE (2012): WorldView-2 [online]. [cit. 2021-01-26]. Dostupné z: <https://www.spectralcam.com/wp-content/uploads/2018/02/WorldView2-DS-WV2-Web.pdf>
4. DOBROVOLNÝ, P.: Dálkový průzkum Země: digitální zpracování obrazu. Brno: Masarykova univerzita, 1998. ISBN 80-210-1812-7.
5. EUROPEAN UNION ©, Copernicus Land Monitoring Service <2021>, European Environment Agency (EEA)", f.ex. in 2018: "© European Union, Copernicus Land Monitoring Service 2018, European Environment Agency (EEA)" dostupné z: <https://land.copernicus.eu/user-corner/technical-library/corine-land-cover-nomenclature-guidelines/html/index.html>
6. GIDUDU, A., GREGG, H., TSHILIDZI, M.: "Image Classification Using SVMs: One-against-One Vs One-against-All." (2007).
7. GISAT (200-?): Landsat 8 [online]. [cit. 2021-02-11]. Dostupné z: <http://www.gisat.cz/content/cz/dpz/prehled-druzicovych-systemu/satelite/landsat-8>
8. GISAT (200-?): Worldview-2 [online]. [cit. 2021-03-02]. Dostupné z: <http://www.gisat.cz/content/cz/dpz/prehled-druzicovych-systemu/worldview/satelite/worldview-2>
9. HALOUNOVÁ, L., PAVELKA, K.: Dálkový průzkum Země. Vydavatelství ČVUT, Praha 2008
10. HERMANN, J., POMEZNÝ, P.: Úvod do Geografických informačních systémů II. 1. vydání str. 57, Ostrava 2003 ISBN 80-7042-932-1
11. HONKUS, J.: Fotografie, Technika snímání, PFŠ, Praha, 2004
12. HOSSAIN, MD., CHEN, D.: Segmentation for Object-Based Image Analysis (OBIA): A review of algorithms and challenges from remote sensing perspective. ISPRS Journal of Photogrammetry and Remote Sensing [online]. 2019, 150, 115-134 [cit. 2021-03-16]. ISSN 09242716. Dostupné z: doi:10.1016/j.isprsjprs.2019.02.009

13. IMMITZER, M., ATZBERGER, C., KOUKAL, T.: Tree Species Classification with Random Forest Using Very High Spatial Resolution 8-Band WorldView-2 Satellite Data. *Remote Sensing* [online]. 2012, 4(9), 2661-2693 [cit. 2021-01-12]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs409266
14. JEFFREYS, H.: An invariant form for the prior probability in estimation problems. *Proceedings of the Royal Society of London. Series A. Mathematical and Physical Sciences* [online]. 1946, 186(1007), 453-461 [cit. 2021-03-16]. ISSN 0080-4630. Dostupné z: doi:10.1098/rspa.1946.0056
15. JOMBO, S., ADAM, E., ODINDI, J.: Classification of tree species in a heterogeneous urban environment using object-based ensemble analysis and World View-2 satellite imagery. *Applied Geomatics* [online]. [cit. 2021-03-16]. ISSN 1866-9298. Dostupné z: doi:10.1007/s12518-021-00358-3
16. KOLÁŘ, J., HALOUNOVÁ, L., PAVELKA, K.: *Dálkový průzkum Země 10*. Praha: České vysoké učení technické, 1997. ISBN 80-01-01567-x.
17. KOLÁŘ, J.: *Dálkový průzkum Země*. Praha: SNTL - Nakladatelství technické literatury, 1990. Populární přednášky o fyzice. ISBN 80-03-00517-5.
18. LI, D., KE, Y., GONG, H., LI, X.: Object-Based Urban Tree Species Classification Using Bi-Temporal WorldView-2 and WorldView-3 Images. *Remote Sensing* [online]. 2015, 7(12), 16917-16937 [cit. 2021-03-02]. ISSN 2072-4292. Dostupné z: doi:10.3390/rs71215861
19. LILLESAND, T. M., KIEFER, R. W., CHIPMAN, J. W.: *Remote Sensing and Image Interpretation*. 7th edition. Hoboken: John Wiley, 2015. ISBN 978-1-118-34328-9.
20. LILLESAND, T. M., KIEFER, R. W., CHIPMAN, J. W.: *Remote sensing and image interpretation*. 6th ed. Hoboken: John Wiley, c2008. ISBN 978-0-470-05245-7.
21. MATHER, P., TSO, B.: *Classification Methods for Remotely Sensed Data*. 2nd Edition. London: CRC Press, 2009. ISBN 9781420090727.
22. NASA (200–?): *Landsat 8 Overview* [online]. [cit. 2021-01-28]. Dostupné z: <https://landsat.gsfc.nasa.gov/landsat-8/landsat-8-overview>
23. PAL, N. R., PAL, S. K.: A review on image segmentation techniques. *Pattern Recognition* [online]. 1993, 26(9), 1277-1294 [cit. 2021-03-16]. ISSN 00313203. Dostupné z: doi:10.1016/0031-3203(93)90135-J
24. RICHARDS, J. A., JIA, X.: *Remote Sensing Digital Image Analysis* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 1999 [cit. 2021-03-16]. ISBN 978-3-662-03980-9. Dostupné z: doi:10.1007/978-3-662-03978-6



25. SONG, C., WOODCOCK, C. E., SETO, K. C., LENNEY, M. P., MACOMBER, S. A.: Classification and Change Detection Using Landsat TM Data. *Remote Sensing of Environment* [online]. 2001, 75(2), 230-244 [cit. 2021-03-16]. ISSN 00344257. Dostupné z: doi:10.1016/S0034-4257(00)00169-3
26. SVATOŇOVÁ, H., LAUERMANN L.: Dálkový průzkum Země - aktuální zdroj geografických informací. Brno: Masarykova univerzita, 2010. ISBN 978-80-210-5162-1.
27. ŠTYCH, P., JEŘÁBKOVÁ, B., LAŠTOVIČKA, J., RIEDL, M., PALUBA, D.: A Comparison of WorldView-2 and Landsat 8 Images for the Classification of Forests Affected by Bark Beetle Outbreaks Using a Support Vector Machine and a Neural Network: A Case Study in the Sumava Mountains. *Geosciences* [online]. 2019, 9(9) [cit. 2021-02-12]. ISSN 2076-3263. Dostupné z: doi:10.3390/geosciences9090396
28. TOU, J. T., GONZALEZ, R. C.: *Pattern Recognition Principles*, Addison-Wesley Publishing Company, Reading, Massachusetts, 1974.
29. ÚHÚL (200–?): Katalog mapových informací [online]. [cit. 2021-03-13]. Dostupné z: <http://www.uhul.cz/mapy-a-data/katalog-mapovych-informaci>
30. Vyhláška č. 357/2013 Sb. ze dne 1. listopadu 2013, katastrální vyhláška, § příloha. [cit. 2021-02-12]. Dostupné z <https://www.zakonyprolidi.cz/cs/2013-357>
31. WILLIAMS, B. D.: Chapter 4 Genetic Mapping with Polymorphic Sequence-Tagged Sites. *Cuenorhubditis elegans: Modern Biological Analysis of an Organism* [online]. Elsevier, 1995, 1995, s. 81-96 [cit. 2021-03-16]. *Methods in Cell Biology*. ISBN 9780125641494. Dostupné z: doi:10.1016/S0091-679X(08)61384-9

## 9. Seznam obrázků a tabulek

Obrázek 1 – Typická spektrální odrazivost (%) tří povrchů: zelená vegetace (green vegetation), suchá holá půda (dry bare soil) a voda (water) (zdroj: Tso a Mather, 2009)

Obrázek 2 – Schéma zařazování pixelů k jednotlivým spektrálním třídám pomocí klasifikátoru Minimum Distance (zdroj: Lillesand et al., 2015)

Obrázek 3 – Schéma zařazování pixelů k jednotlivým spektrálním třídám pomocí klasifikátoru Maximum Likelihood (zdroj: Lillesand et al., 2015)

Obrázek 4 – zástavba

Obrázek 5 – silnice

Obrázek 6 – holá půda

Obrázek 7 – orná půda

Obrázek 8 – trvalý travní porost (TTP)

Obrázek 9 – jehličnany

Obrázek 10 – listnáče

Obrázek 11 – kleč

Obrázek 12 – voda

Obrázek 13 – stíny

Obrázek 14 – schéma metodiky

Obrázek 15 – původní velikost snímku Landsat 8 (červená) a WorldView-2 (modrá)

Tabulka 1 – Legenda

Tabulka 2 – počty trénovacích ploch a počty segmentů pro jednotlivé kategorie legendy

Tabulka 3 – chybová matice Maximum Likelihood u WV-2

Tabulka 4 – chybová matice Minimum Distance u WV-2

Tabulka 5 – chybová matice Random Forest u WV-2

Tabulka 6 – chybová matice Support Vector Machines u WV-2

Tabulka 7 – chybová matice Maximum Likelihood u L8

Tabulka 8 – chybová matice Minimum Distance u L8

Tabulka 9 – chybová matice Random Forest u L8

Tabulka 10 – chybová matice SVM u L8

Tabulka 11 – porovnání celkových přesností využitých algoritmů

## 10. Seznam příloh

Příloha č. 1 – Chybová matice Minimum Distance pro zjednodušenou legendu WV-2

Příloha č. 2 – Chybová matice Maximum Likelihood pro zjednodušenou legendu WV-2

Příloha č. 3 – Chybová matice Random Forest pro zjednodušenou legendu WV-2

Příloha č. 4 – Chybová matice Support Vector Machine pro zjednodušenou legendu WV-2

Příloha č. 5 – Chybová matice Minimum Distance pro zjednodušenou legendu L8

Příloha č. 6 – Chybová matice Maximum Likelihood pro zjednodušenou legendu L8

Příloha č. 7 – Chybová matice Random Forest pro zjednodušenou legendu L8

Příloha č. 8 – Chybová matice Support Vector Machines pro zjednodušenou legendu L8

Příloha č. 9 – zájmové území na snímku Worldview-2

Příloha č. 10 – zájmové území na snímku Landsat 8

Příloha č. 11 – Výsledná klasifikace Minimum Distance ze snímku WV-2 na druhové úrovni

Příloha č. 12 – Výsledná klasifikace Minimum Distance pro zjednodušenou legendu ze snímku WV-2

Příloha č. 13 – Výsledná klasifikace Maximum Likelihood ze snímku WV-2 na druhové úrovni

Příloha č. 14 – Výsledná klasifikace Maximum Likelihood pro zjednodušenou legendu ze snímku WV-2

Příloha č. 15 – Výsledná klasifikace Random Forest ze snímku WV-2 na druhové úrovni

Příloha č. 16 – Výsledná klasifikace Random Forest pro zjednodušenou legendu ze snímku WV-2

Příloha č. 17 – Výsledná klasifikace Support Vector Machine ze snímku WV-2 na druhové úrovni

Příloha č. 18 – Výsledná klasifikace Support Vector Machine pro zjednodušenou legendu ze snímku WV-2

Příloha č. 19 – Výsledná klasifikace Minimum Distance ze snímku L8 na druhové úrovni

Příloha č. 20 – Výsledná klasifikace Minimum Distance pro zjednodušenou legendu ze snímku L8

Příloha č. 21 – Výsledná klasifikace Maximum Likelihood ze snímku L8 na druhové úrovni

Příloha č. 22 – Výsledná klasifikace Maximum Likelihood pro zjednodušenou legendu ze snímku L8

Příloha č. 23 – Výsledná klasifikace Random Forest ze snímku L8 na druhové úrovni

Příloha č. 24 – Výsledná klasifikace Random Forest pro zjednodušenou legendu ze snímku L8

Příloha č. 25 – Výsledná klasifikace Support Vector Machine ze snímku L8 na druhové úrovni

Příloha č. 26 – Výsledná klasifikace Support Vector Machine pro zjednodušenou legendu ze snímku L8

Příloha č. 27 - Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - WV-2 - podrobná legenda (zaokrouhлено na 2 desetinná místa)

Příloha č. 28 - Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - L8 - podrobná legenda (zaokrouhлено na 2 desetinná místa)

Příloha č. 29 - Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - WV-2 - zjednodušená legenda (zaokrouhлено na 2 desetinná místa)

Příloha č. 30 - Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - L8 - zjednodušená legenda (zaokrouhлено na 2 desetinná místa)

Příloha č. 1 – Chybová matice Minimum Distance pro zjednodušenou legendu WV-2

chybová matice - Minimum Distance - WV-2 - zjednodušená legenda											
kategorie	Antropogenní plochy	holá půda	orná půda	TTP	jehličnany	listnáče	kleč	voda	stíny	celkem	uživatelská přesnost [%]
Antropogenní plochy	28	4								32	87,5
Holá půda	5	9	5	1	10	3	1			34	26,47
Orná půda	3		4	12						19	21,05
Tráva			9	33		23				65	50,77
Jehličnany		4			32	2	2			40	80
Listnáče		1	1	5	4	12				23	52,17
Kleč					23		10		1	34	29,41
Voda	3			1	1			26	7	38	68,42
Stíny	7				24				17	48	35,42
Celkem	46	18	19	52	94	40	13	26	25	333	---
zpracovatelská přesnost [%]	60,87	50	21,05	63,46	34,04	30	76,92	100	68	---	51,35
										kappa	0,448

Příloha č. 2 – Chybová matice Maximum Likelihood pro zjednodušenou legendu WV-2

chybová matice - Maximum Likelihood - WV-2 - zjednodušená legenda											
kategorie	Antropogenní plochy	holá půda	orná půda	TTP	jehličnany	listnáče	kleč	voda	stíny	celkem	uživatelská přesnost [%]
Antropogenní plochy	44	1		1				2		48	91,97
Holá půda		14	3	4	2	2	1			26	53,85
Orná půda		2	11	7						20	55
Tráva			5	36		8				49	73,47
Jehličnany				2	58	4	1		2	67	86,57
Listnáče				2	5	26				33	78,79
Kleč		1			9		11	1		22	50
Voda	2							22		24	91,67
Stíny					20			1	23	44	52,27
Celkem	46	18	19	52	94	40	13	26	25	333	---
zpracovatelská přesnost [%]	95,65	77,78	57,89	69,23	61,7	65	84,62	84,62	92	---	73,57
										kappa	0,694

Příloha č. 3 – Chybová matice Random Forest pro zjednodušenou legendu WV-2

chybová matice - Random Forest - WV-2 - zjednodušená legenda											
kategorie	Antropogenní plochy	holá půda	orná půda	TTP	jehličnany	listnáče	kleč	voda	stíny	celkem	uživatelská přesnost [%]
Antropogenní plochy	44	3		1				1		49	89,8
Holá půda	1	8			3					12	66,67
Orná půda		5	10							15	66,67
Tráva			8	32	5					45	71,11
Jehličnany					41	8	1			50	82
Listnáče		1	1	19	3	28	1			53	52,83
Kleč		1			21		11		1	34	32,35
Voda	1							19		20	95
Stíny					29			6	24	59	40,68
Celkem	46	18	19	52	102	36	13	26	25	337	---
zpracovatelská přesnost [%]	95,65	44,44	52,63	61,54	40,2	77,78	84,62	73,08	96	---	64,39

Příloha č. 4 – Chybová matice Support Vector Machine pro zjednodušenou legendu WV-2

chybová matice - Support Vectors Machines - WV-2 - zjednodušená legenda											
kategorie	Antropogenní plochy	holá půda	orná půda	TTP	jehličnany	listnáče	kleč	voda	stíny	celkem	uživatelská přesnost [%]
Antropogenní plochy	40	4		1	2				2	49	81,63
Holá půda	4	5		1						10	50
Orná půda		1	17	22						40	42,5
Tráva			1	14		2				17	82,35
Jehličnany		5		2	68	5	8		1	89	76,4
Listnáče		2		11	4	32				49	65,31
Kleč		1	1	1	5		3			11	27,27
Voda	2							23		25	92
Stíny					15	1	2	3	22	43	51,16
Celkem	46	18	19	52	94	40	13	26	25	333	---
zpracovatelská přesnost [%]	86,96	27,78	89,47	26,92	72,34	80	23,08	88,46	88	---	67,27
										kappa	0,616

Příloha č. 5 – Chybová matice Minimum Distance pro zjednodušenou legendu L8

chybová matice - Minimum Distance - Landsat 8 - zjednodušená legenda											
kategorie	Antropogenní plochy	holá půda	orná půda	TTP	jehličnany	listnáče	kleč	voda	stíny	celkem	užívateelská přesnost [%]
Antropogenní plochy	6	1		3						10	60
Holá půda	5	4	1		7		3		3	23	17,39
Orná půda		1	5	15		6				27	18,52
Tráva	2	1	4	11		2			1	21	52,38
Jehličnany		2		2	32		2	1	7	46	69,57
Listnáče	1	0		4	1	7				13	53,85
Kleč	4	4		2	14	1	4		1	30	13,33
Voda				1	4			22		27	81,48
Stíny	1		4	5	18	4		1	2	35	5,71
Celkem	19	13	14	43	76	20	9	24	14	232	---
zpracovateelská přesnost [%]	31,58	23,53	50	25,58	42,11	35	44,44	88	14,29	---	39,91
										kappa	0,311

Příloha č. 6 – Chybová matice Maximum Likelihood pro zjednodušenou legendu L8

chybová matice - Maximum Likelihood - Landsat 8 - zjednodušená legenda											
kategorie	Antropogenní plochy	holá půda	orná půda	TTP	jehličnany	listnáče	kleč	voda	stíny	celkem	užívateelská přesnost [%]
Antropogenní plochy	8			1						9	88,89
Holá půda	4	1	1	4	1		3		1	15	6,67
Orná půda			4	12						16	25
Tráva		5	5	15	1	1	1		1	29	51,72
Jehličnany		4		1	42	1			6	54	77,78
Listnáče	2			3	3	15			1	24	62,5
Kleč		2		1	4		4			11	36,36
Voda				1	1			23	1	26	88,46
Stíny	4	5		4	22	2	1	2	4	44	9,09
Celkem	18	17	10	42	74	19	9	25	14	228	---
zpracovateelská přesnost [%]	42,11	5,88	40	34,88	56	75	44,44	92	28,57	---	50
										kappa	0,416



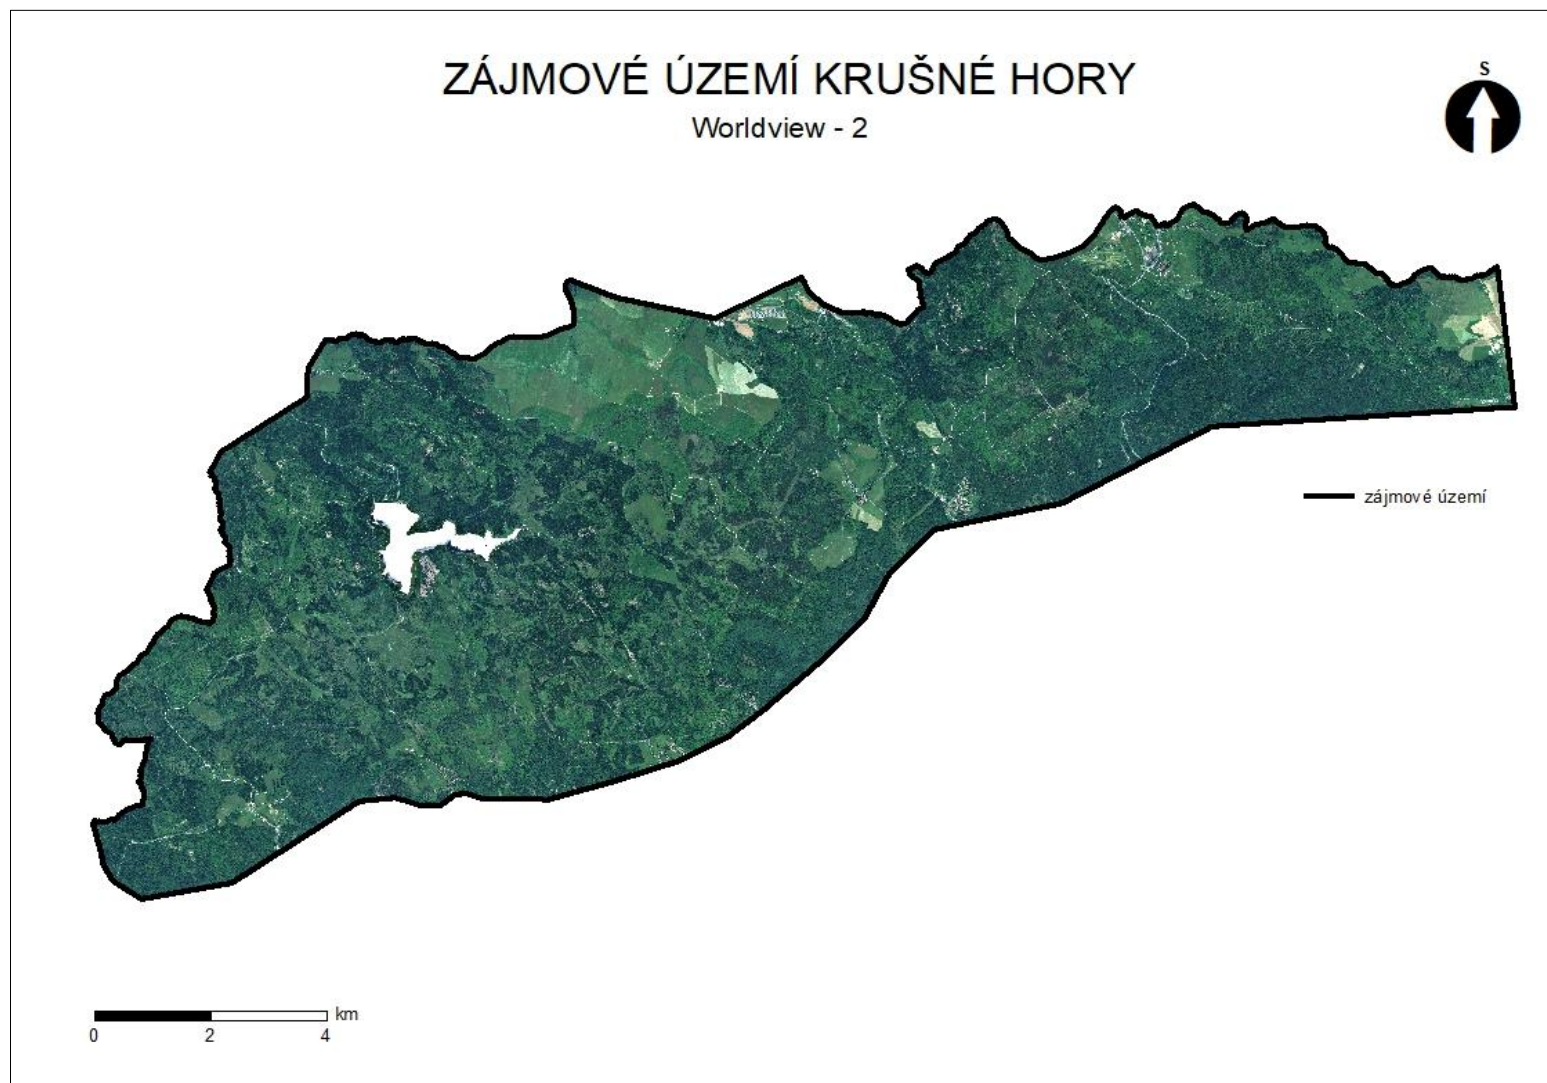
Příloha č. 7 – Chybová matice Random Forest pro zjednodušenou legendu L8

chybová matice - Random Forest - Landsat 8 - zjednodušená legenda											
kategorie	Antropogenní plochy	holá půda	orná půda	TTP	jehličnany	listnáče	kleč	voda	stíny	celkem	zpracovatelská přesnost [%]
Antropogenní plochy	9	1	0	2	0	0	0	0	1	13	69,23
Holá půda	4	5		6	6	1	4	0	2	28	17,86
Orná půda	4	2	10	27	1	11		0	1	56	17,86
Trvalý travní porost (TPP)	0	0	0	0	0	1	0	0	0	1	0
Jehličnany	1	6	0	2	61	1		19	8	98	62,24
Listnáče	1	2	0	5	4	7	1	1	1	22	31,82
Kleč	0	1	0	0	4	0	4	0	1	10	40
Voda	0	0	0	1	0	0	0	7	0	8	87,5
Stíny	0	0	0	0	0	0	0	0	0	0	0
Celkem	19	17	10	43	76	21	9	27	14	236	---
zpracovatelská přesnost [%]	47,37	29,41	100	0	80,26	33,33	44,44	25,93	0	---	43,64

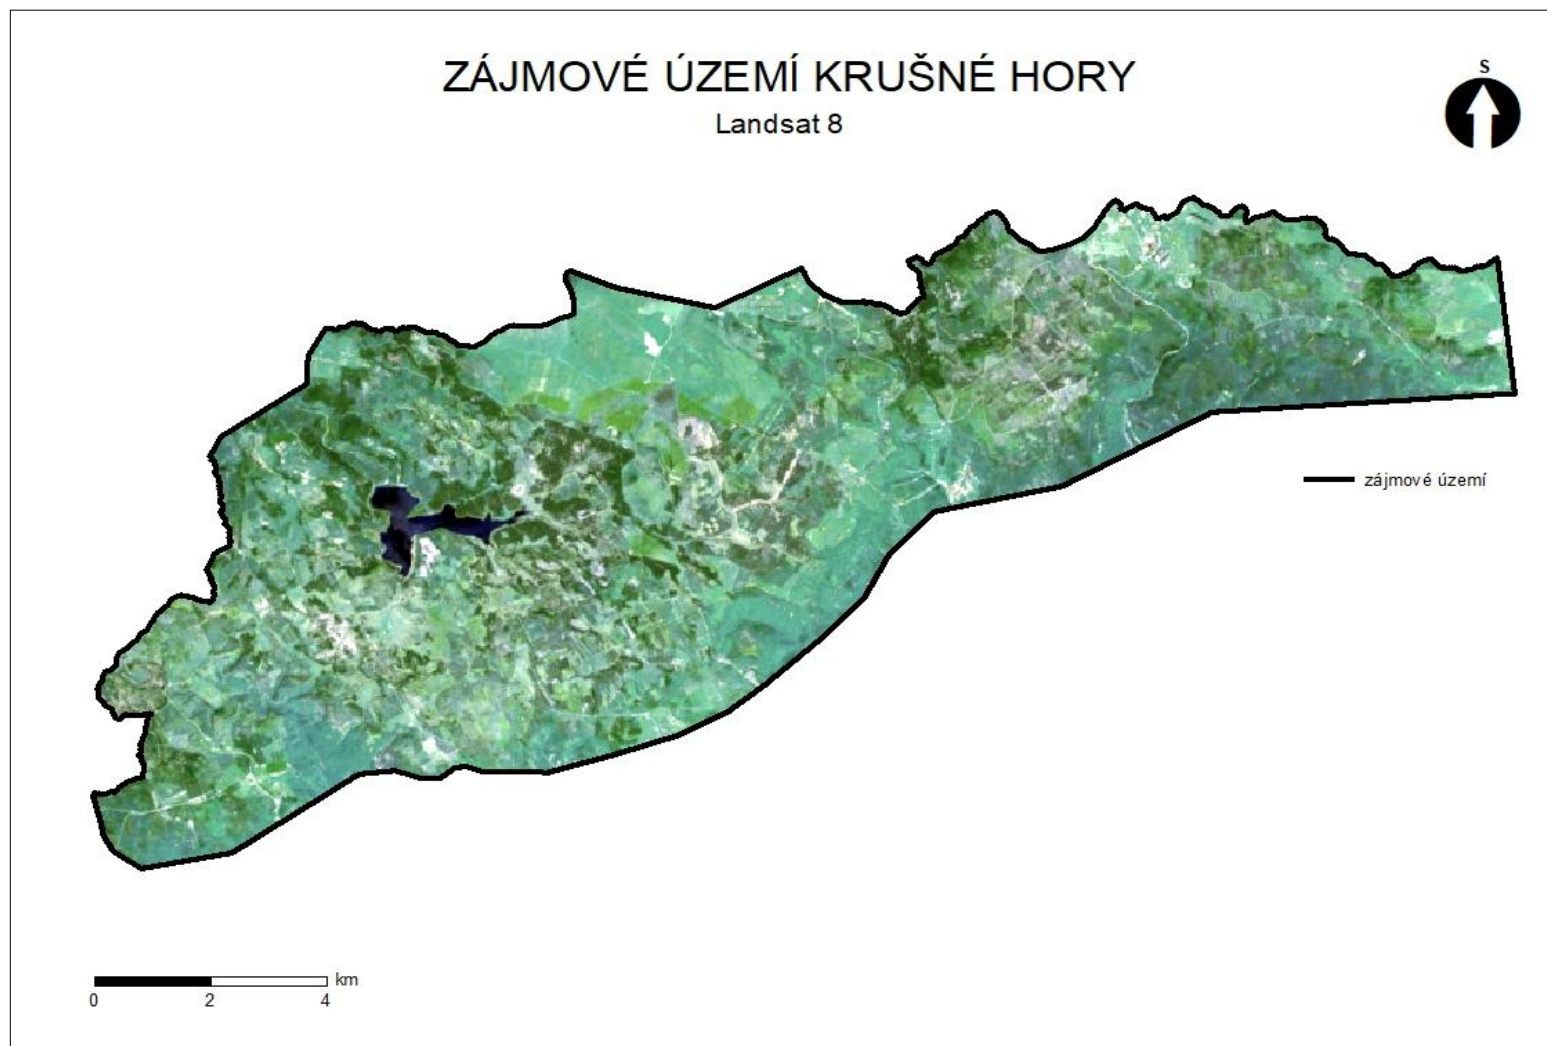
Příloha č. 8 – Chybová matice Support Vector Machines pro zjednodušenou legendu L8

chybová matice - Support Vectore Machines - Landsat 8 - zjednodušená legenda											
kategorie	Antropogenní plochy	holá půda	orná půda	TTP	jehličnany	listnáče	kleč	voda	stíny	celkem	uživatelská přesnost [%]
Antropogenní plochy	8	1	1	2		1			2	15	53,33
Holá půda					1					1	0
Orná půda	1	1	4	21		1				28	14,29
Tráva	3		1	7	7	5			1	24	29,17
Jehličnany	1	1		1	21	1	2	4	3	34	61,76
Listnáče	2	3	3	8	7	12		1	4	40	30
Kleč	1	3	1	1	1	1	3			11	27,27
Voda	1	1		1	1	0	1	20		25	80
Stíny	2	7		2	38		3		4	56	7,14
Celkem	19	17	10	43	76	21	9	25	14	234	---
zpracovatelská přesnost [%]	42,11	0	40	16,28	27,63	57,14	33,33	80	28,57	---	33,76
										kappa	0,248

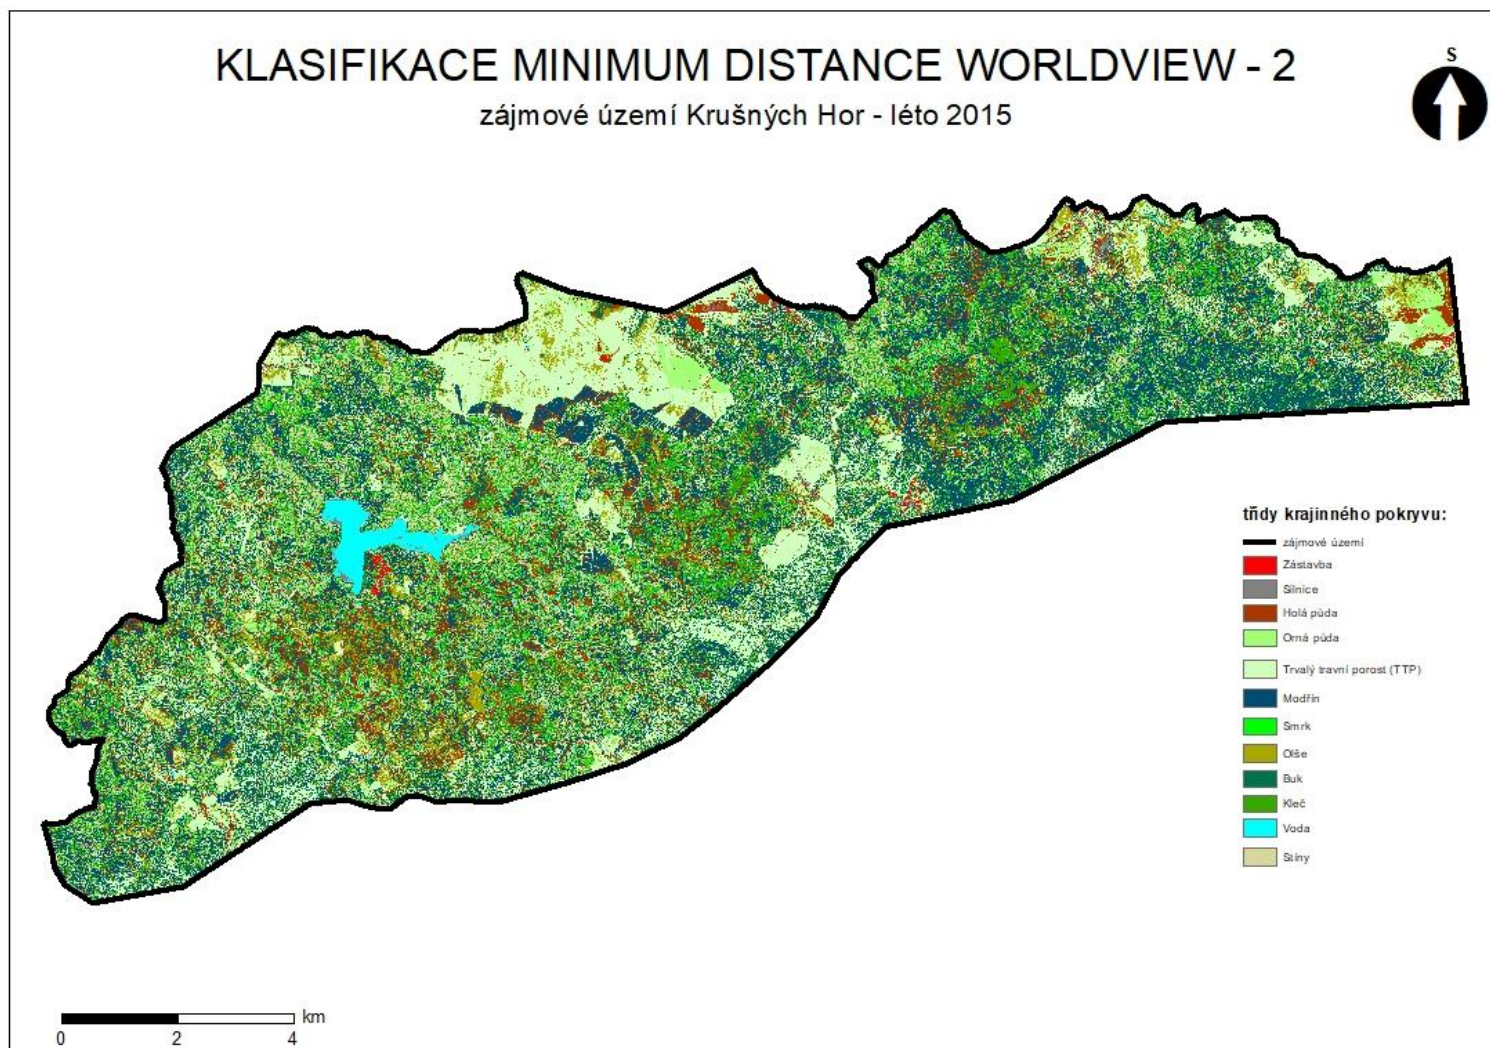
Příloha č. 9 – zájmové území na snímku WorldView – 2



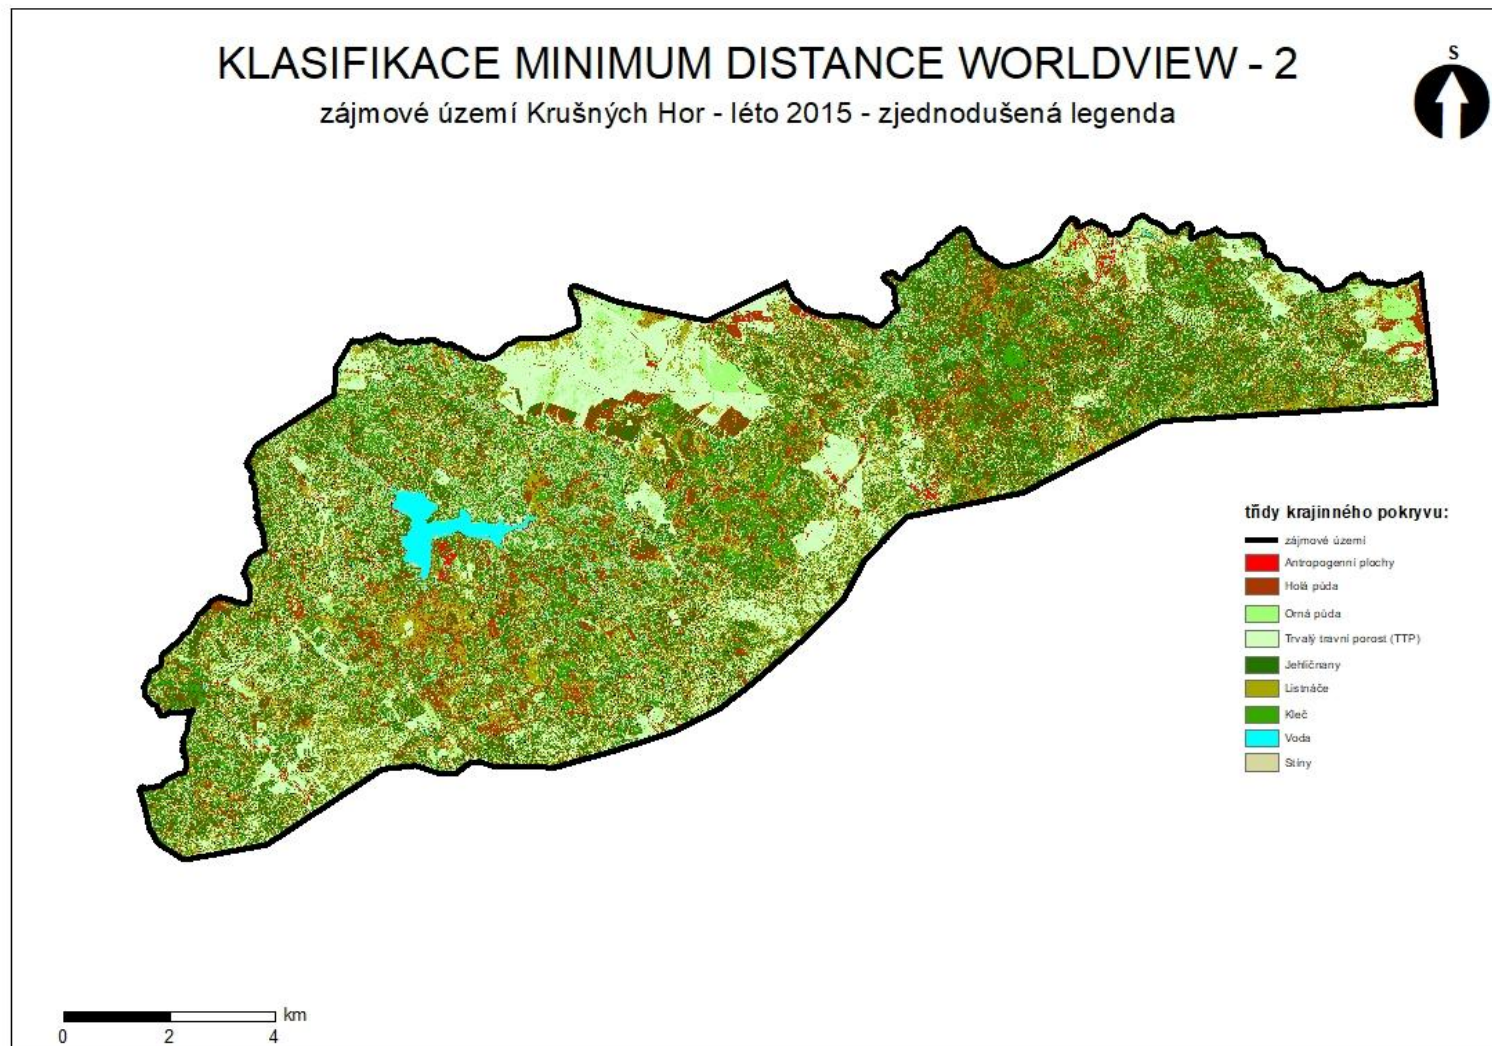
Příloha č. 10 – zájmové území na snímku Landsat 8




Příloha č. 11 – Výsledná klasifikace Minimum Distance ze snímku WV-2 na druhové úrovni



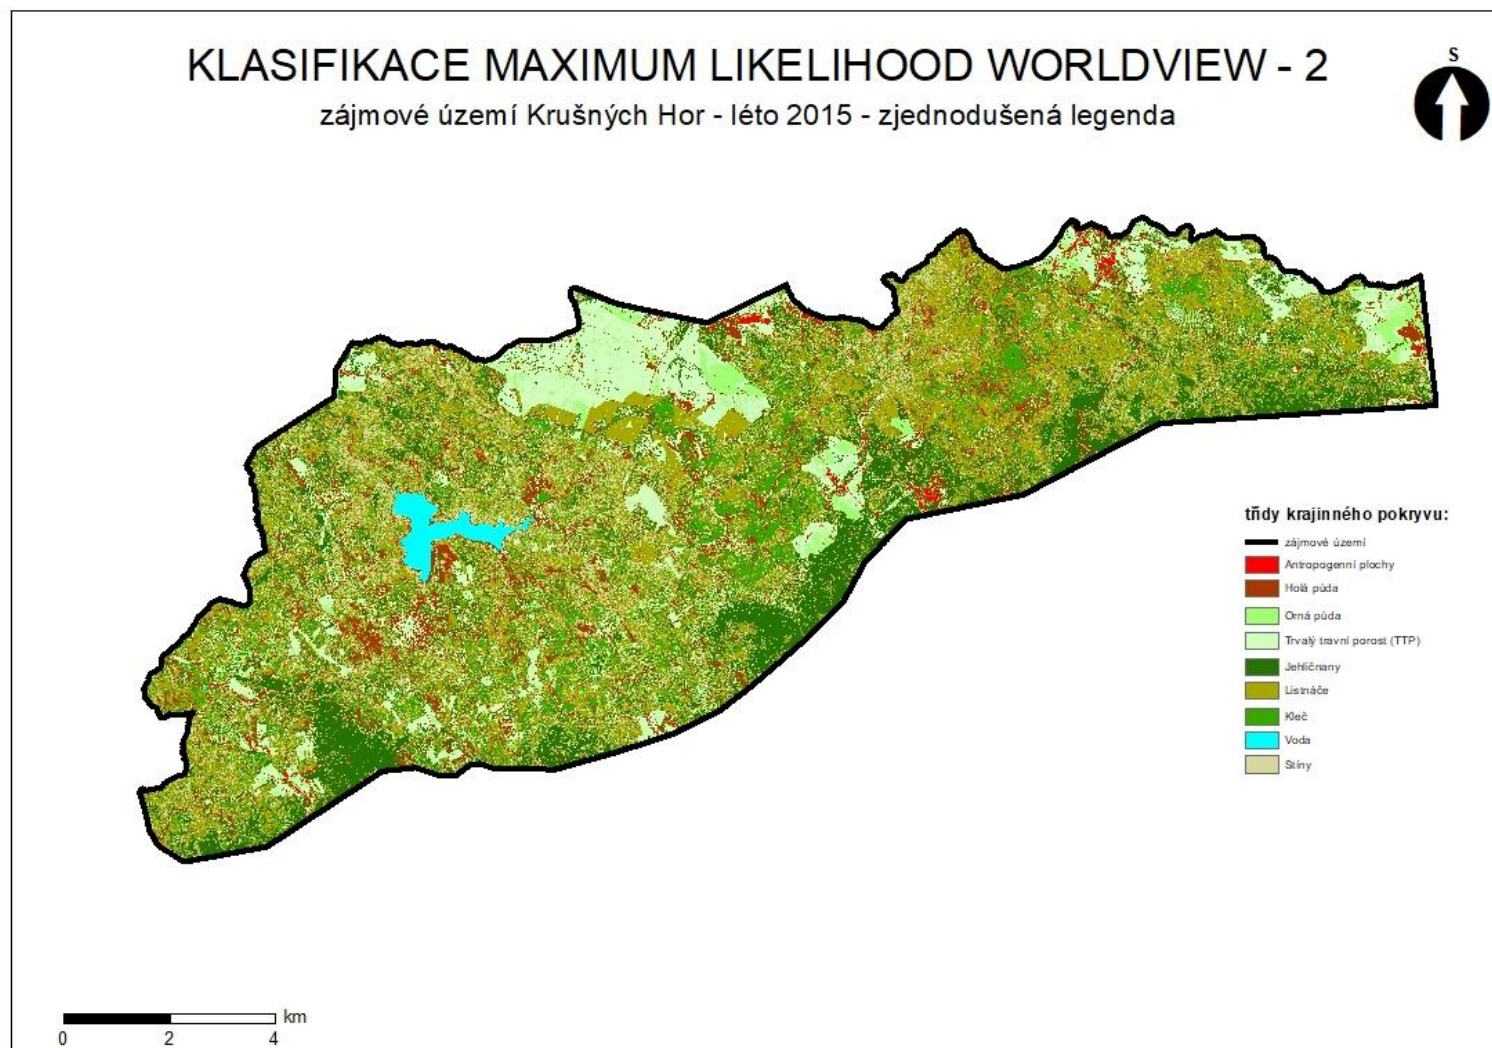
Příloha č. 12 – Výsledná klasifikace Minimum Distance pro zjednodušenou legendu ze snímku WV-2



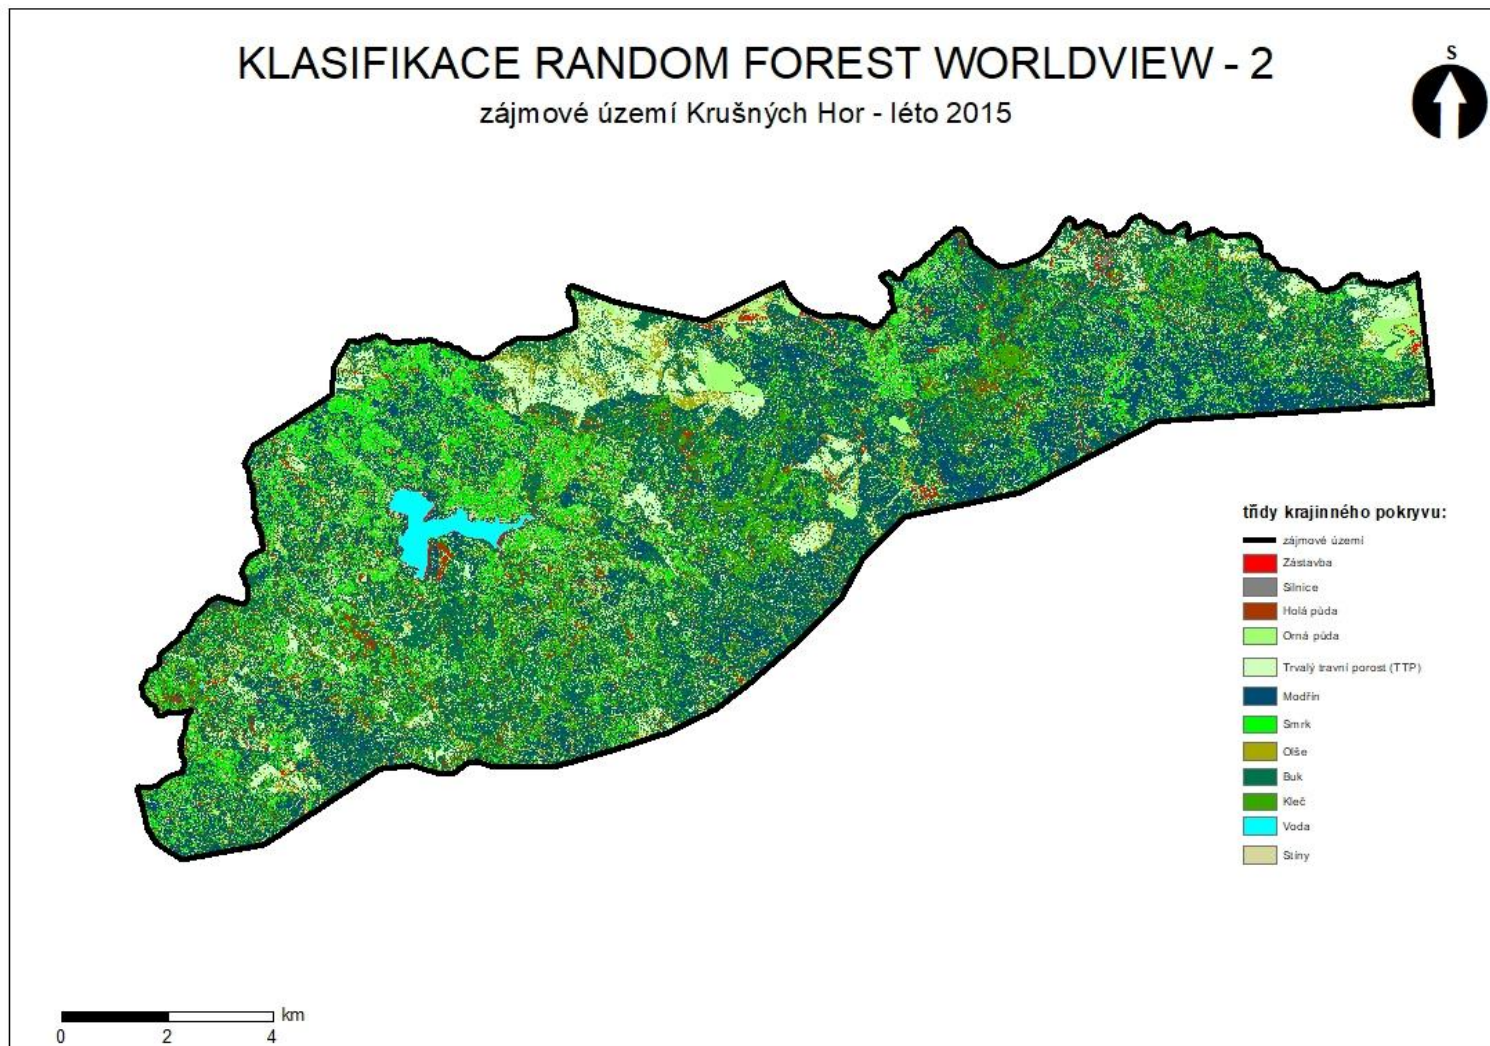
Příloha č. 13 – Výsledná klasifikace Maximum Likelihood ze snímku WV-2 na druhové úrovni



Příloha č. 14 – Výsledná klasifikace Maximum Likelihood pro zjednodušenou legendu ze snímku WV-2

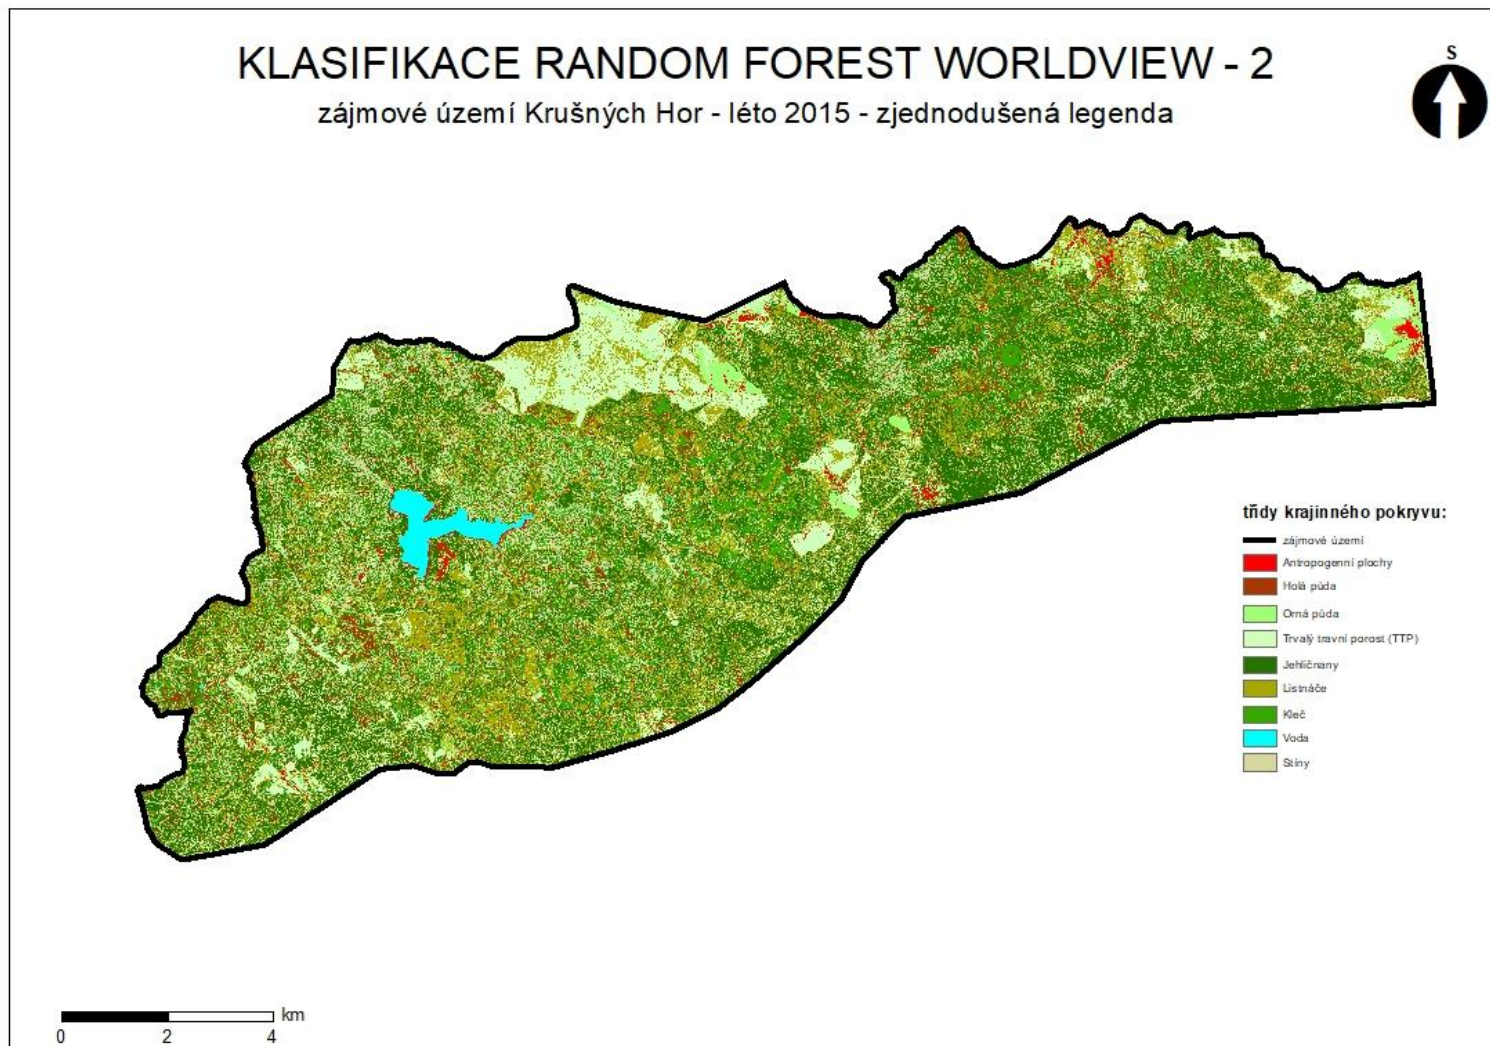


Příloha č. 15 – Výsledná klasifikace Random Forest ze snímku WV-2 na druhové úrovni

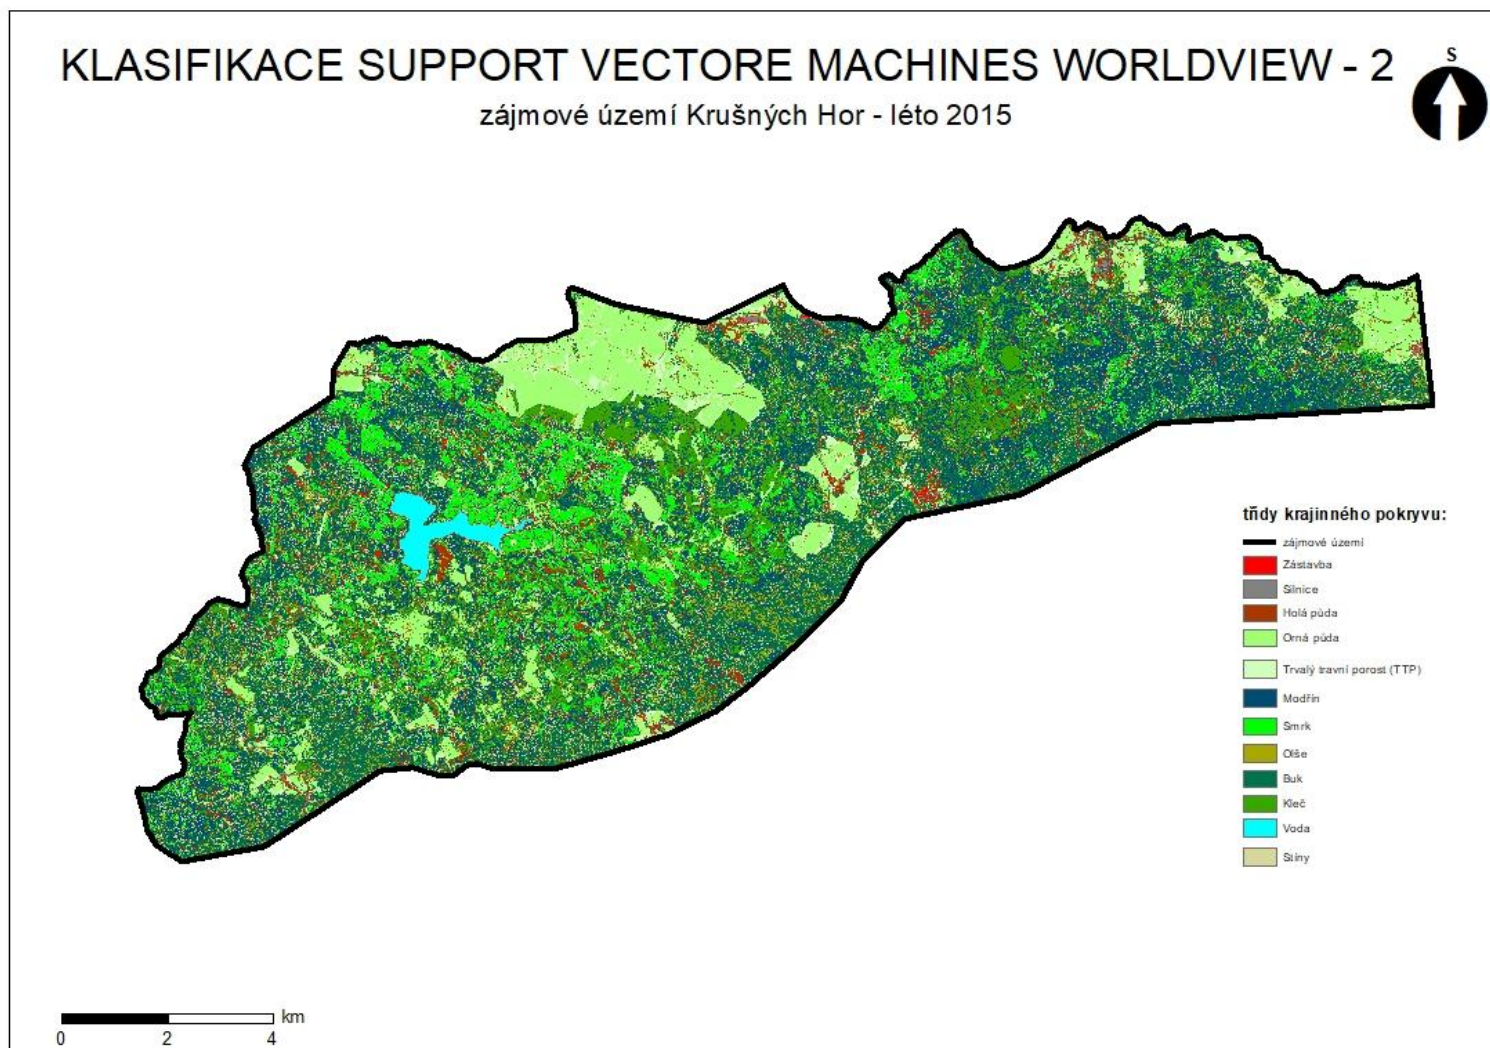




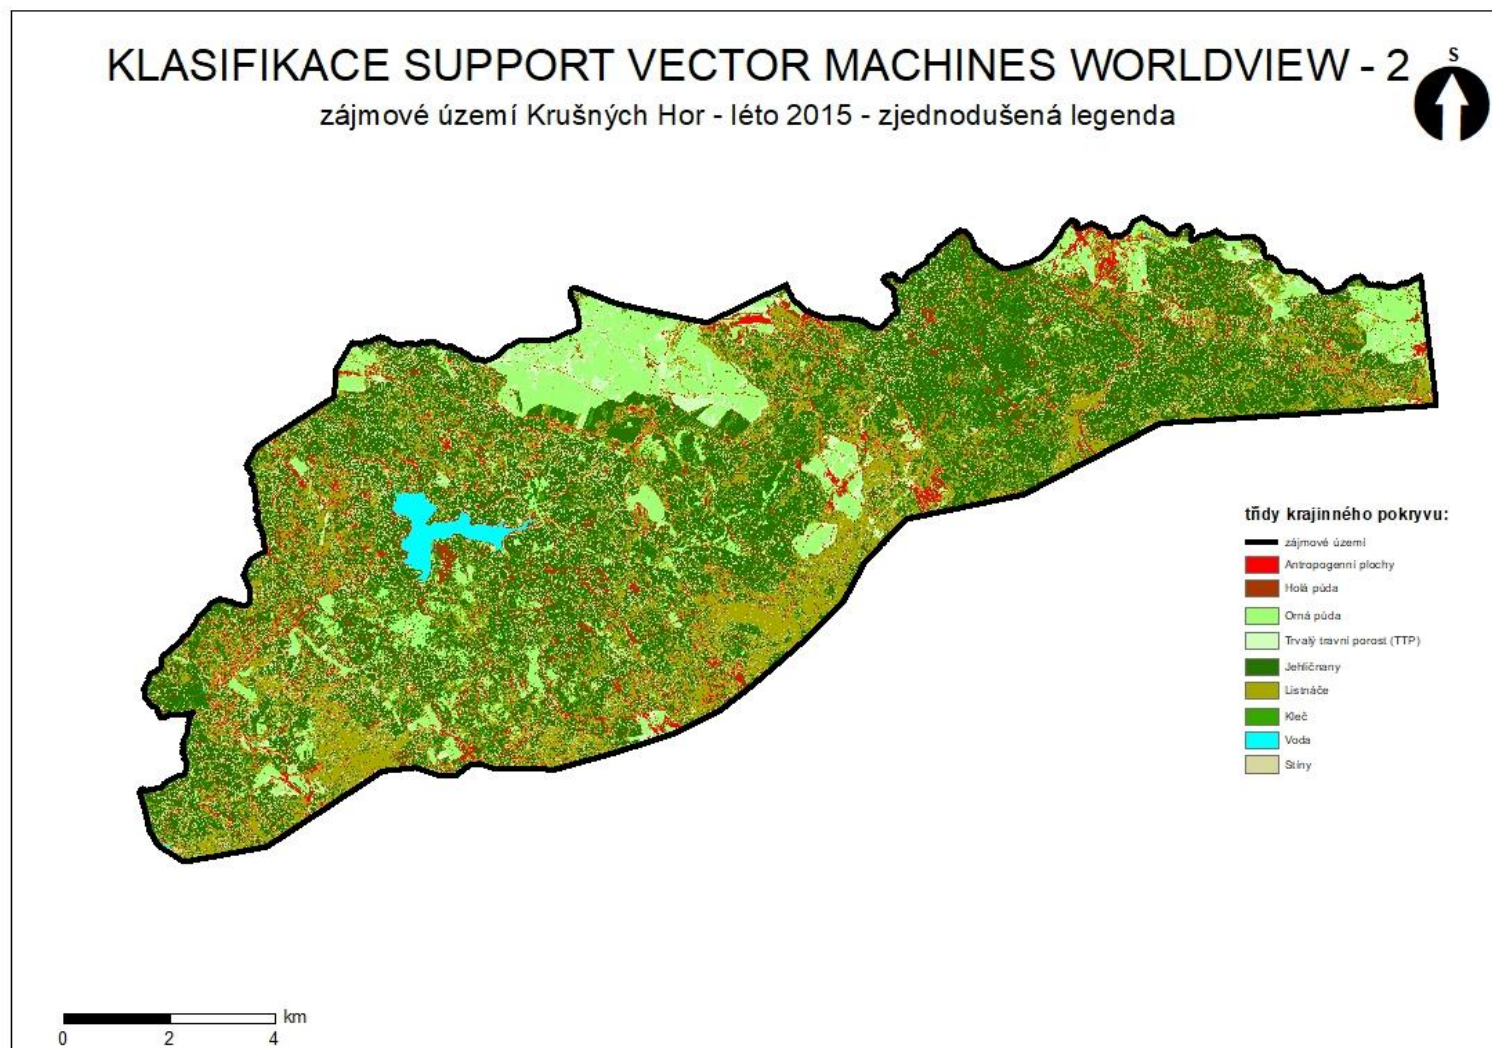
Příloha č. 16 – Výsledná klasifikace Random Forest pro zjednodušenou legendu ze snímku WV-2



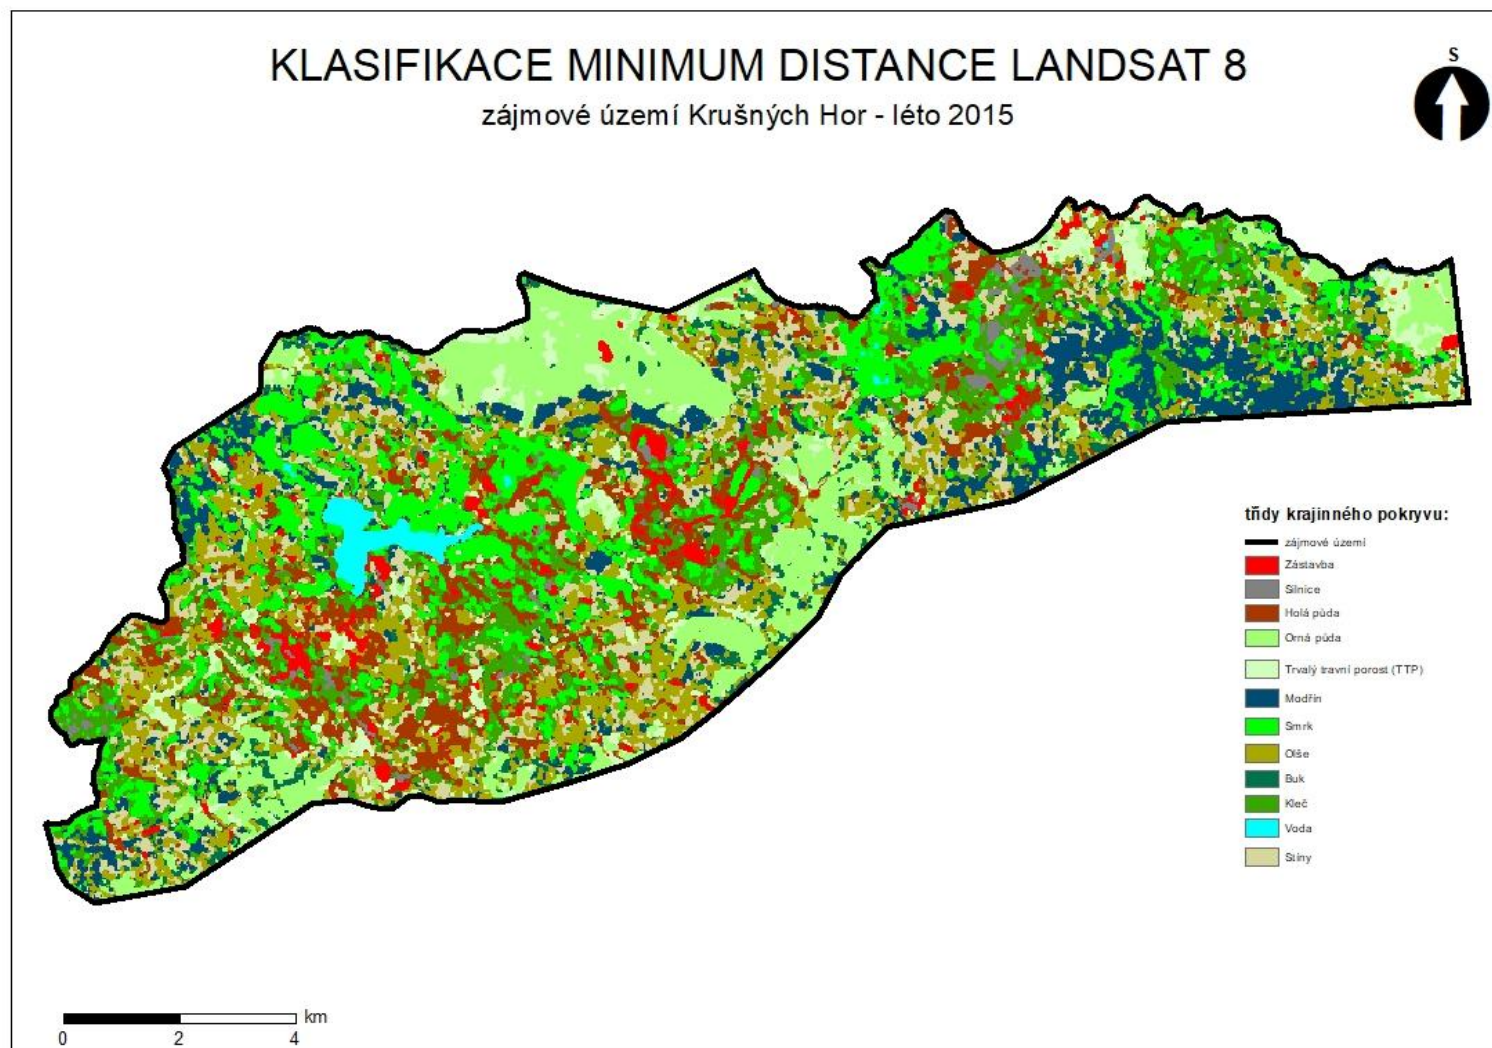
Příloha č. 17 – Výsledná klasifikace Support Vector Machine ze snímku WV-2 na druhové úrovni



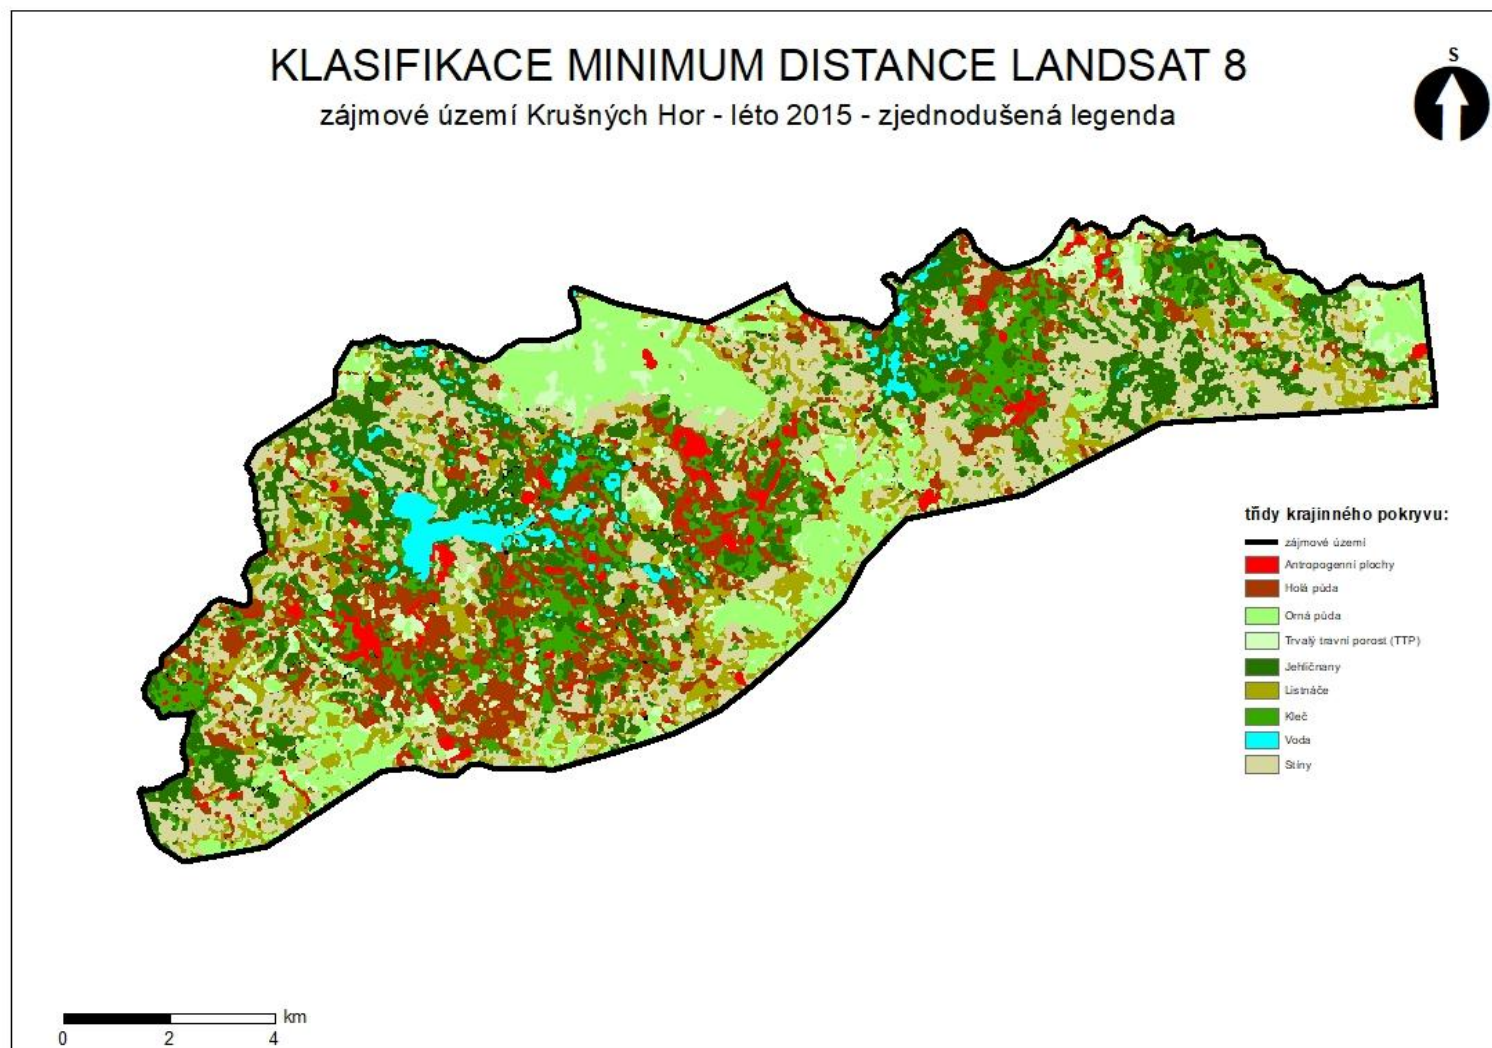
Příloha č. 18 – Výsledná klasifikace Support Vector Machine pro zjednodušenou legendu ze snímku WV-2



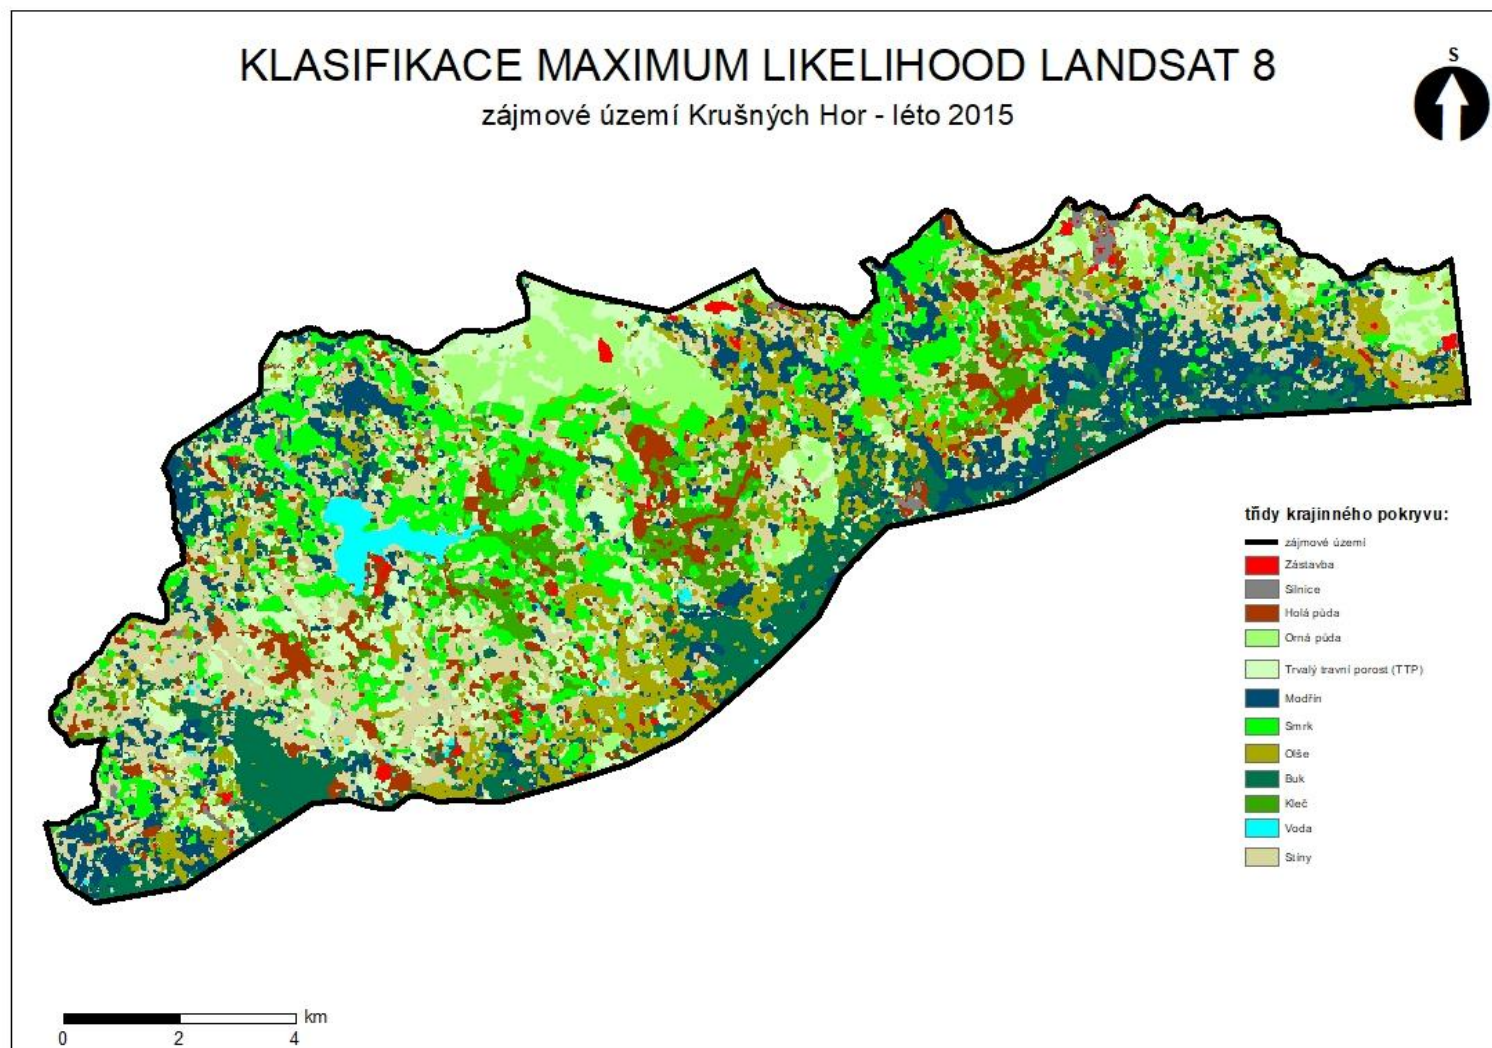
Příloha č. 19 – Výsledná klasifikace Minimum Distance ze snímku L8 na druhové úrovni



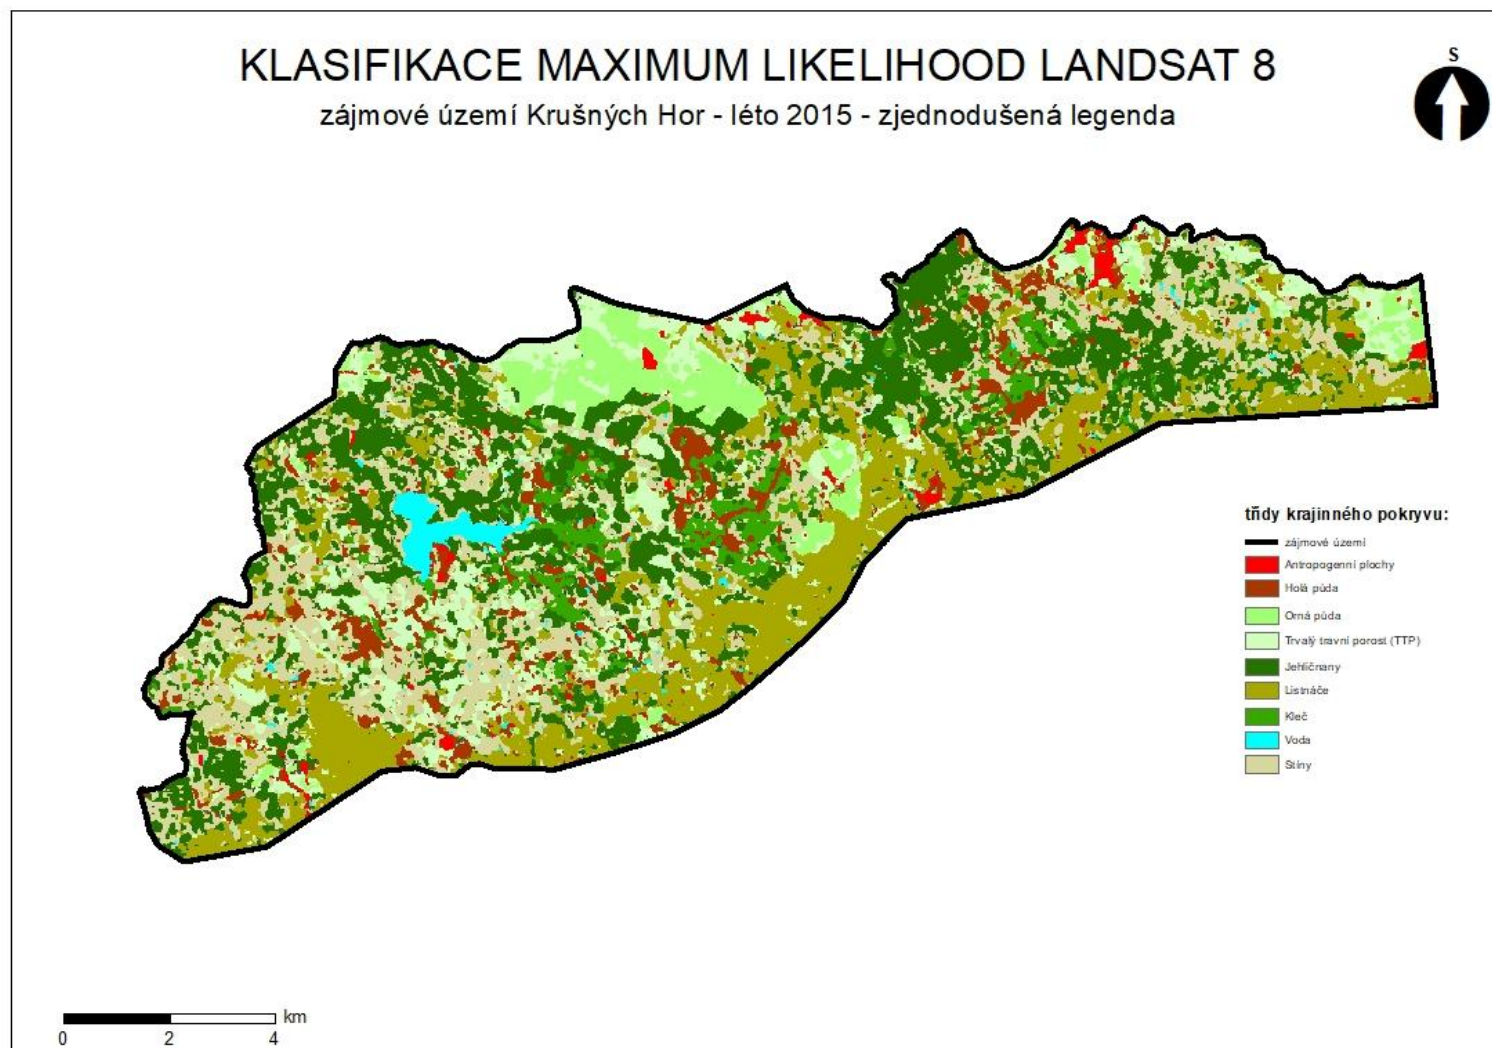
Příloha č. 20 – Výsledná klasifikace Minimum Distance pro zjednodušenou legendu ze snímku L8



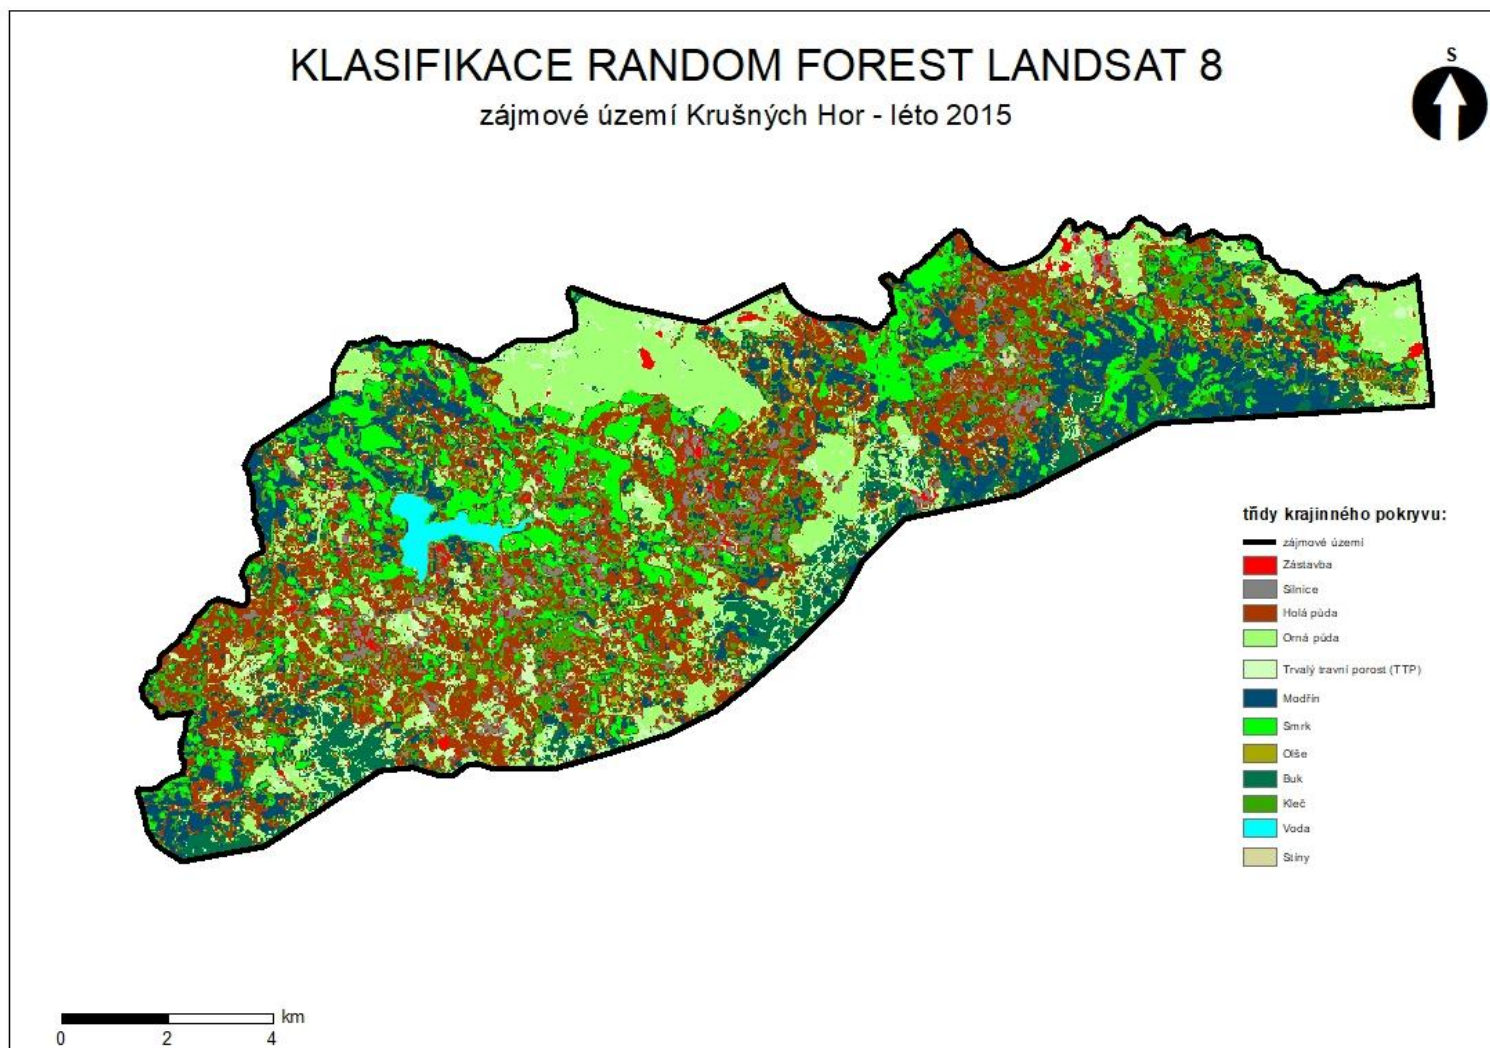
Příloha č. 21 – Výsledná klasifikace Maximum Likelihood ze snímku L8 na druhové úrovni



Příloha č. 22 – Výsledná klasifikace Maximum Likelihood pro zjednodušenou legendu ze snímku L8

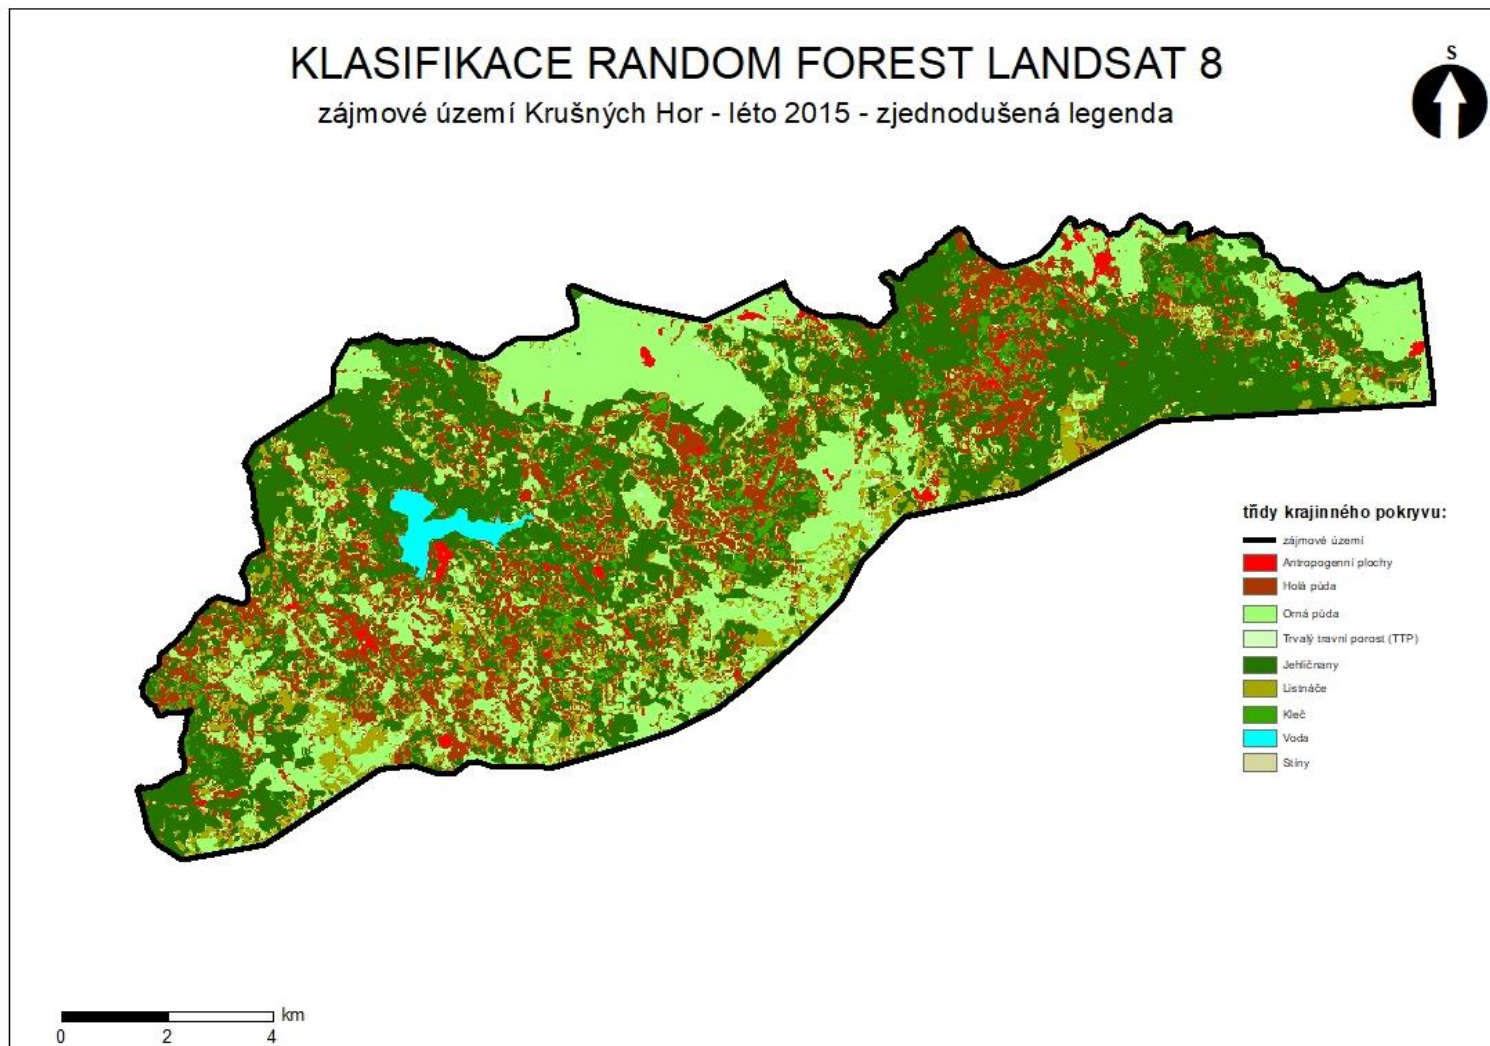


Příloha č. 23 – Výsledná klasifikace Random Forest ze snímku L8 na druhové úrovni

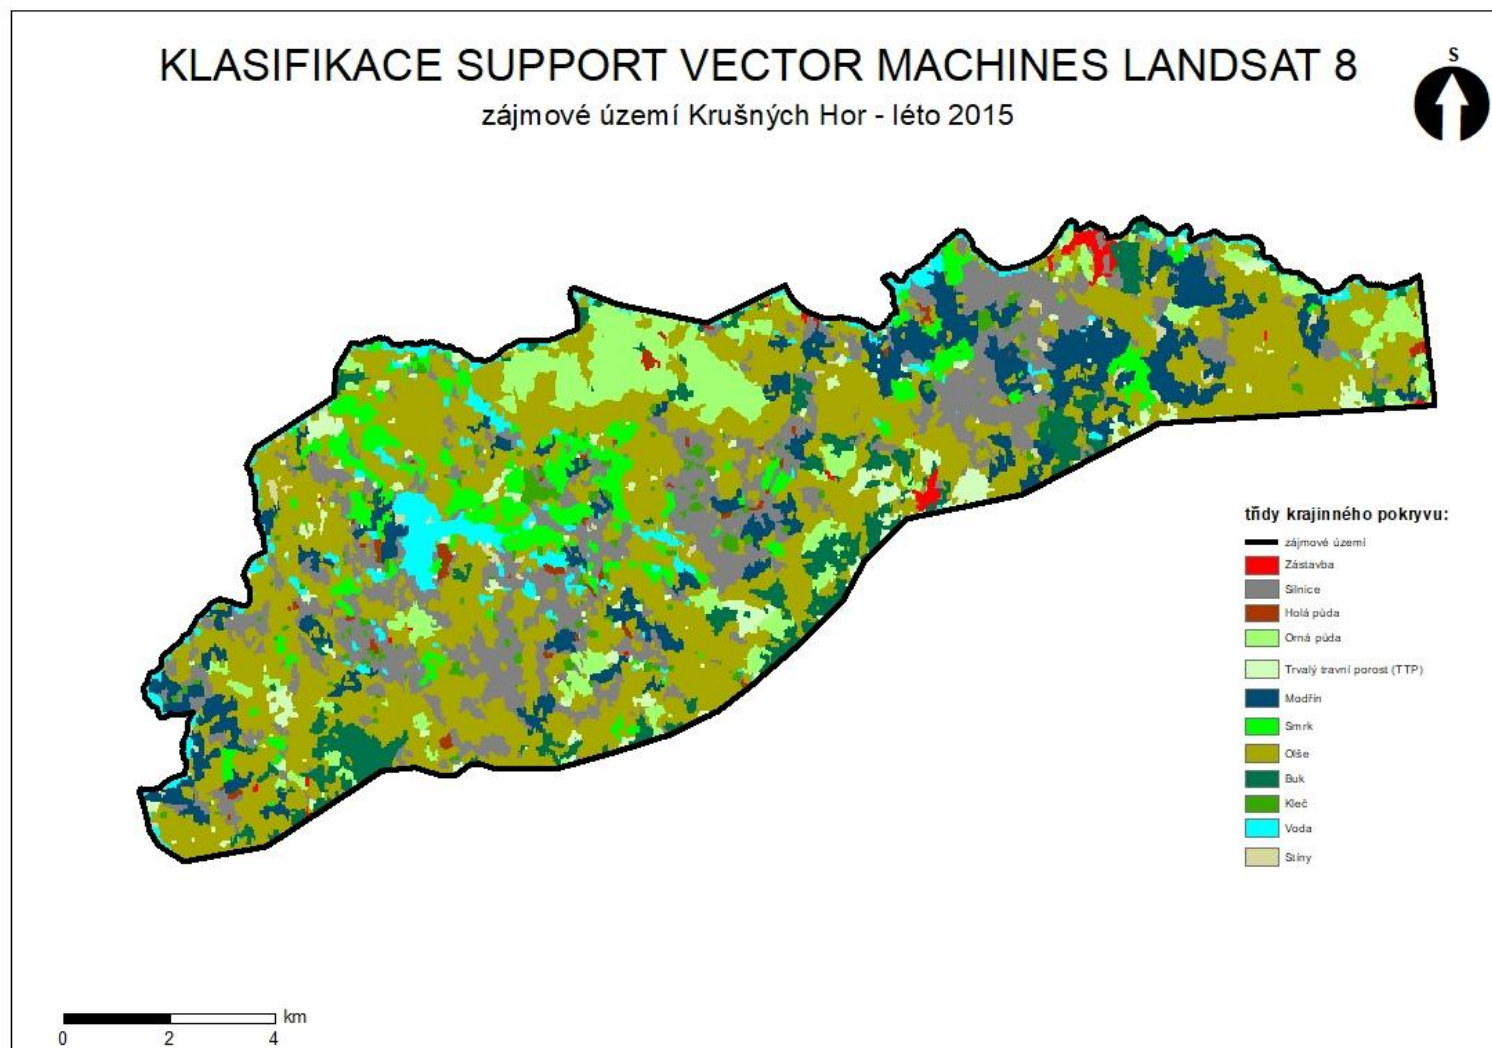




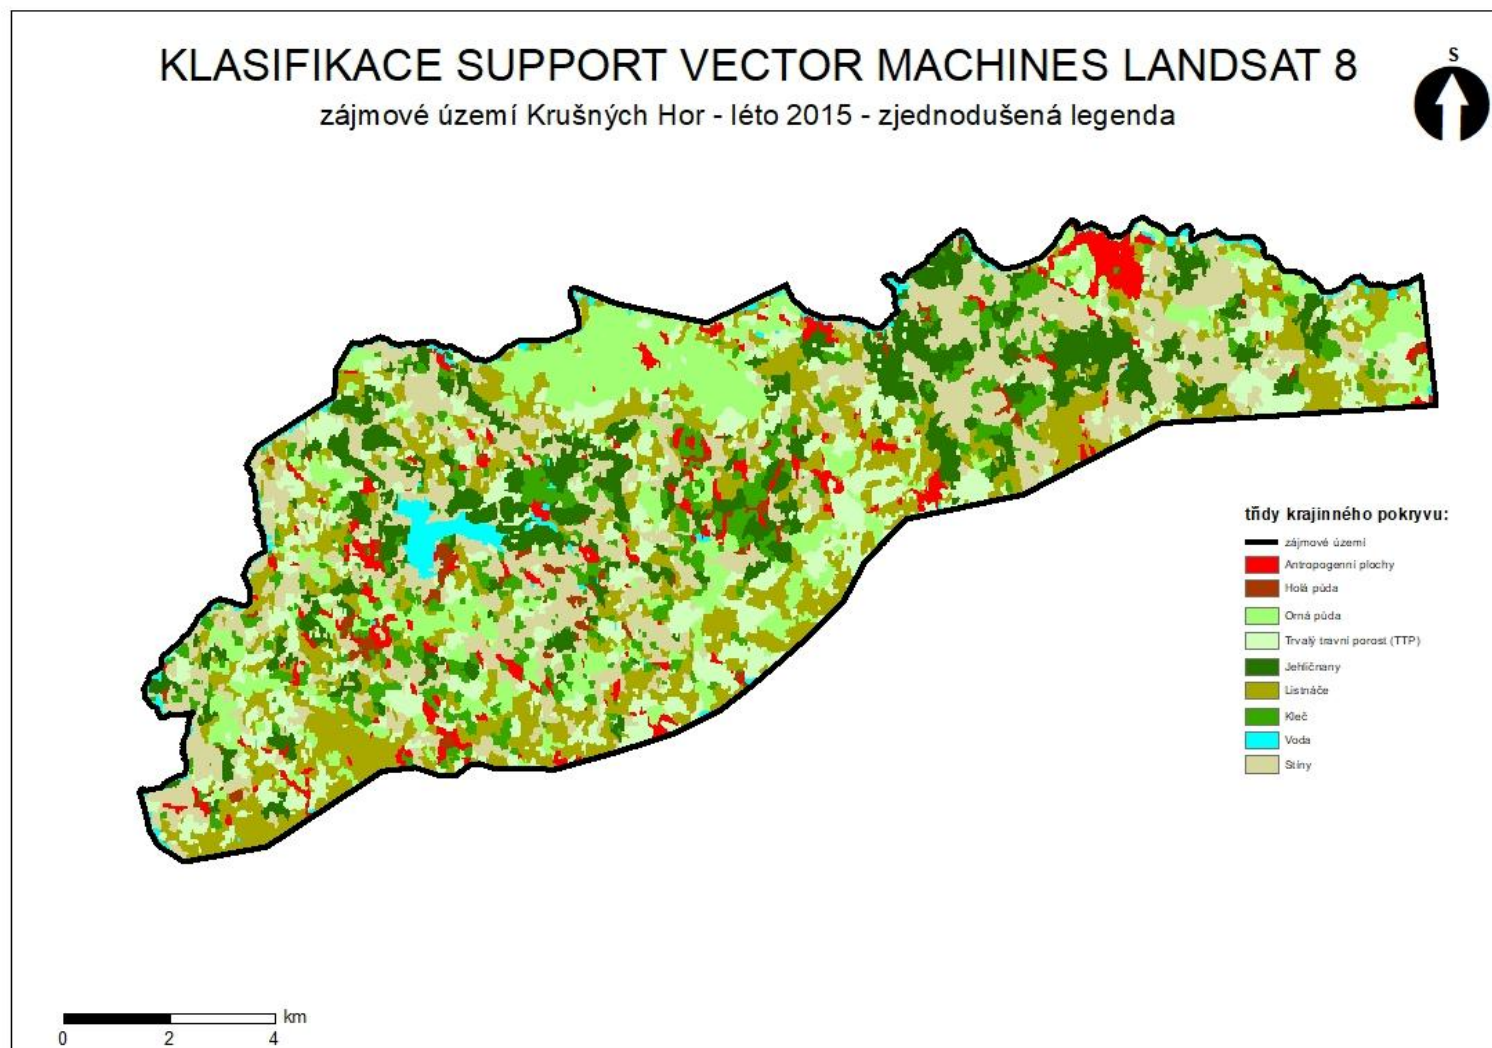
Příloha č. 24 – Výsledná klasifikace Random Forest pro zjednodušenou legendu ze snímku L8



Příloha č. 25 – Výsledná klasifikace Support Vector Machine ze snímku L8 na druhové úrovni



Příloha č. 26 – Výsledná klasifikace Support Vector Machine pro zjednodušenou legendu ze snímku L8



Příloha č. 27 - Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - WV-2 - podrobná legenda (zaokrouhleno na 2 desetinná místa)

Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - WV-2 - podrobná legenda			
kategorie	hodnota	kategorie	hodnota
buk a olše	0,86	holá půda a stíny	1,97
smrk a stíny	1,00	holá půda a silnice	1,97
kleč a smrk	1,01	buk a orná půda	1,97
modřín a olše	1,06	smrk a zástavba	1,98
modřín a smrk	1,11	kleč a zástavba	1,98
buk a modřín	1,14	modřín a voda	1,98
kleč a modřín	1,22	modřín a zástavba	1,99
kleč a stíny	1,24	orná půda a zástavba	1,99
modřín a stíny	1,30	silnice a stíny	1,99
holá půda a orná půda	1,47	silnice a voda	1,99
olše a TTP	1,55	modřín a orná půda	1,99
orná půda a TTP	1,58	orná půda a smrk	1,99
buk a TTP	1,69	kleč a silnice	1,99
holá půda a olše	1,71	silnice a smrk	2,00
holá půda a TTP	1,72	voda a zástavba	2,00
buk a holá půda	1,77	buk a voda	2,00
buk a smrk	1,78	buk a zástavba	2,00
stíny a voda	1,78	smrk a TTP	2,00
holá půda a modřín	1,79	kleč a TTP	2,00
olše a smrk	1,80	modřín a silnice	2,00
buk a stíny	1,80	olše a zástavba	2,00
buk a kleč	1,81	holá půda a voda	2,00
kleč a olše	1,85	kleč a orná půda	2,00
holá půda a kleč	1,90	buk a silnice	2,00
silnice a zástavba	1,90	olše a voda	2,00
holá půda a zástavba	1,91	TTP a zástavba	2,00
smrk a voda	1,93	olše a silnice	2,00
modřín a TTP	1,93	stíny a TTP	2,00
holá půda a smrk	1,94	orná půda a silnice	2,00
olše a stíny	1,95	orná půda a stíny	2,00
olše a orná půda	1,95	silnice a TTP	2,00
kleč a voda	1,96	TTP a voda	2,00
stíny a zástavba	1,97	orná půda a voda	2,00

Příloha č. 28 - Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - L8 - podrobná legenda (zaokrouhлено na 2 desetinná místa)

Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - L8- podrobná legenda			
kategorie	hodnota	kategorie	hodnota
stíny a TTP	1,21	silnice a TTP	1,91
buk a stíny	1,28	modřín a smrk	1,91
silnice a zástavba	1,34	holá půda a kleč	1,91
orná půda a TTP	1,34	kleč a TTP	1,92
buk a TTP	1,36	buk a voda	1,92
modřín a stíny	1,39	olše a voda	1,94
holá půda a stíny	1,42	stíny a zástavba	1,95
olše a TTP	1,43	kleč a voda	1,95
olše a stíny	1,47	modřín a silnice	1,95
buk a olše	1,54	holá půda a smrk	1,96
stíny a voda	1,58	olše a silnice	1,96
smrk a stíny	1,64	TTP a zástavba	1,96
holá půda a TTP	1,65	kleč a modřín	1,96
kleč a stíny	1,69	olše a smrk	1,96
kleč a smrk	1,70	TTP a voda	1,97
holá půda a silnice	1,70	buk a zástavba	1,97
buk a holá půda	1,74	silnice a smrk	1,97
modřín a olše	1,74	orná půda a silnice	1,97
holá půda a orná půda	1,74	smrk a TTP	1,97
silnice a stíny	1,75	kleč a silnice	1,97
olše a orná půda	1,76	orná půda a zástavba	1,98
modřín a TTP	1,78	buk a kleč	1,98
buk a orná půda	1,80	voda a zástavba	1,98
holá půda a olše	1,81	olše a zástavba	1,98
orná půda a stíny	1,83	modřín a zástavba	1,99
buk a modřín	1,85	buk a smrk	2,00
holá půda a zástavba	1,85	smrk a zástavba	2,00
holá půda a voda	1,86	kleč a zástavba	2,00
smrk a voda	1,89	kleč a olše	2,00
modřín a voda	1,89	orná půda a voda	2,00
holá půda a modřín	1,89	modřín a orná půda	2,00
silnice a voda	1,90	kleč a orná půda	2,00
buk a silnice	1,91	orná půda a smrk	2,00

Příloha č. 29 - Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - WV-2 - zjednodušená legenda (zaokrouhleno na 2 desetinná místa)

Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - WV-2- zjednodušená legenda			
kategorie	hodnota	kategorie	hodnota
stíny a jehličnany	1,00	kleč a voda	1,96
kleč a jehličnany	1,03	orná půda a listnáče	1,96
kleč a stíny	1,24	holá půda a stíny	1,97
listnáče a jehličnany	1,31	kleč a antr. plochy	1,97
holá půda a orná půda	1,47	jehličnany a antr. plochy	1,97
orná půda a TTP	1,58	orná půda a jehličnany	1,98
TTP a listnáče	1,63	voda a antr. plochy	1,99
holá půda a TTP	1,72	orná půda a antr. plochy	1,99
holá půda a listnáče	1,74	listnáče a antr. plochy	2,00
stíny a voda	1,78	voda a listnáče	2,00
kleč a listnáče	1,80	kleč a TTP	2,00
stíny a listnáče	1,83	holá půda a voda	2,00
holá půda a jehličnany	1,84	kleč a orná půda	2,00
holá půda a antr. plochy	1,89	TTP a antr. plochy	2,00
holá půda a kleč	1,90	stíny a TTP	2,00
voda a jehličnany	1,95	orná půda a stíny	2,00
stíny a antr. plochy	1,95	TTP a voda	2,00
TTP a jehličnany	1,95	orná půda a voda	2,00

Příloha č. 30 - Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - L8 - zjednodušená legenda (zaokrouhleno na 2 desetinná místa)

Zhodnocení oddělitelnosti trénovacích ploch pomocí algoritmu Transformed Divergence - L8 - zjednodušená legenda			
kategorie	hodnota	kategorie	hodnota
stíny a listnáče	1,12	holá půda a voda	1,86
stíny a TTP	1,21	holá půda a jehličnany	1,87
stíny a jehličnany	1,23	voda a listnáče	1,89
TTP a listnáče	1,25	stíny a antr. plochy	1,91
orná půda a TTP	1,34	holá půda a kleč	1,91
holá půda a stíny	1,42	kleč a TTP	1,92
stíny a voda	1,58	listnáče a antr. plochy	1,95
holá půda a TTP	1,65	TTP a antr. plochy	1,95
holá půda a listnáče	1,67	kleč a voda	1,95
kleč a stíny	1,69	voda a antr. plochy	1,96
orná půda a listnáče	1,72	TTP a voda	1,97
holá půda a orná půda	1,74	kleč a listnáče	1,97
kleč a jehličnany	1,75	orná půda a antr. plochy	1,98
holá půda a antr. plochy	1,79	jehličnany a antr. plochy	1,98
TTP a jehličnany	1,81	orná půda a jehličnany	1,99
orná půda a stíny	1,83	kleč a antr. plochy	1,99
voda a jehličnany	1,83	orná půda a voda	2,00
listnáče a jehličnany	1,84	kleč a orná půda	2,00