

UNIVERZITA KARLOVA

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Bc. Mojmír Polák

**Testování možností extrakce vybraných krajinných charakteristik pro popis
stanovišť výskytu indikačně významných druhů ptáků v Krkonoších z dat
dálkového průzkumu Země**

Testing possibilities to extract selected landscape characteristics
for description of indication-relevant bird species habitats in the Krkonoše Mts.
from remote sensing data

Diplomová práce

Vedoucí práce: doc. RNDr. Lucie Kupková, Ph.D.

Konzultant: RNDr. Dušan Romportl, Ph.D.

Praha 2022

Zadání diplomové práce

pro Mojmíra Poláka

obor Kartografie a geoinformatika

Název tématu:

Testování možností extrakce vybraných krajinných charakteristik pro popis stanovišť výskytu indikačně významných druhů ptáků v Krkonoších z dat dálkového průzkumu Země

Zásady pro vypracování

Pro mapování a ochranu přírody/biodiverzity jsou důležité aktuální a přesné informace o parametrech habitatů/stanovišť v detailní prostorové škále. Dobrá dostupnost dat dálkového průzkumu Země s vysokým a velmi vysokým rozlišením umožňuje integrovat snímky s různou úrovní prostorového rozlišení a derivovat z nich časově-prostorové krajinné charakteristiky popisující různé aspekty stanovišť na úrovni pixelu (jednak spektrální charakteristiky/indexy – např. greenness, brightness, wetness a další vegetační indexy, dále metriky krajinné struktury – mozaikovitost, fragmentace, typ krajinného pokryvu atd.), které mohou být indikátory výskytu vybraných druhů živočichů. V současnosti využívané vrstvy popisující stanoviště (například mapování biotopů Natura 2000, konsolidovaná vrstva ekosystémů apod.) nejsou dostatečně podrobným a informačně vhodným podkladem pro popis stanovišť v potřebné prostorové úrovni. Cílem práce je extrahovat vybrané krajinné časově-prostorové krajinné charakteristiky z dat DPZ (například dat družic Sentinel-2 a PlanetScope) a porovnat možnosti DPZ pro popis stanovišť s výše uvedenými datovými vrstvami získanými terénním mapováním. Dále se práce zaměří na vybrané druhy ptáků v krkonošské tundře a pro ně bude prověřeno (s využitím dat o výskytu daných druhů v terénu), zda na základě krajinných charakteristik získaných z dat

DPZ, které popisují typická stanoviště výskytu těchto druhů, je možné predikovat místa potenciálního rozšíření těchto druhů v krajině (výsledek bude ověřen na základě dat o skutečném výskytu daných druhů z nálezové databáze Agentury ochrany přírody a krajiny).

Rozsah grafických prací: dle potřeby

Rozsah průvodní zprávy: cca 70 stran

Seznam odborné literatury:

BINO, G., LEVIN, N., DARAWSHI, S., VAN DER HAL, N., REICH-SOLOMON, A., KARK, S. (2008): Accurate prediction of bird species richness patterns in an urban environment using Landsat-derived NDVI and spectral unmixing. *International Journal of Remote Sensing*, 13, 29, 3675–3700.

BONTHOUX, S., LEFÈVRE, S., HERRAULT, P. A., SHEEREN, D. (2018): Spatial and temporal dependency of NDVI satellite imagery in predicting bird diversity over France. *Remote Sensing*, 7, 10, 1–22.

OESER, J., HEURICH, M., SENF, C., PFLUGMACHER, D., BELOTTI, E., KUEMMERLE, T. (2020): Habitat metrics based on multi-temporal Landsat imagery for mapping large mammal habitat. *Remote Sensing in Ecology and Conservation*, 1, 6, 52–69.

SHIRLEY, S. M., YANG, Z., HUTCHINSON, R. A., ALEXANDER, J. D., MCGARIGAL, K., BETTS, M. G. (2013): Species distribution modelling for the people: Unclassified landsat TM imagery predicts bird occurrence at fine resolutions. *Diversity and Distributions*, 7, 19, 855–866.

ŠÍMOVÁ, P. (2017): Identifying HNV Areas Using Geographic Information Systems and Landscape Metrics. In: *Birds as Useful Indicators of High Nature Value Farmlands*. Springer, Cham, 124.

ŠÍMOVÁ, P., GDULOVÁ, K. (2012): Landscape indices behavior: A review of scale effects. *Applied Geography*, 34, 385–394.

Vedoucí diplomové práce: doc. RNDr. Lucie Kupková, Ph.D.

Konzultant diplomové práce: RNDr. Dušan Romportl, Ph.D.

Datum zadání diplomové práce: 28. 11. 2019

Termín odevzdání diplomové práce: červenec 2022

.....

Vedoucí diplomové práce

.....

Garant studijního programu

V Praze dne 28. 11. 2021

Prohlášení

Prohlašuji, že jsem diplomovou práci zpracoval samostatně a uvedl všechny použité zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze dne 29. 7. 2022

.....

Mojmír Polák

Poděkování

Rád bych poděkoval vedoucí diplomové práce doc. RNDr. Lucii Kupkové, Ph. D. za věnovaný čas, rady a připomínky během tvorby práce, dále konzultantovi RNDr. Dušanu Romportlovi, Ph.D. za připomínky a data, Mgr. Jaroslavovi Vojtovi za konzultace statistiky. Speciální poděkování náleží Ph.D., RNDr. Jiřímu Flouskovi, Ph.D. ze Správy Krkonošského národního parku za poskytnutá data o výskytu druhů. Děkuji i společnosti Planet Labs, Inc. za poskytnutá data DPZ. Velké poděkování za podporu patří též všem skvělým lidem, které jsem poznal během svého studia na Albertově.

Abstrakt

Diplomová práce využívá data Dálkového průzkumu Země dvou prostorových úrovní (Sentinel-2 s pixelem 10 x 10 m a PlanetScope 3 x 3 m). Práce zkoumá možnosti extrakce vybraných krajinných charakteristik (spektrální indexy, typ land cover, krajinné metriky) s cílem vyhodnotit, jaké charakteristiky a v jakém měřítku jsou statisticky významné pro výskyt 23 vybraných druhů ptáků, druhovou bohatost a počet druhů řádu pěvci v kvadrátech 1400 x 1400 m v Krkonoších. Data o výskytu druhů byla mapována v letech 2012-2014 na české i polské straně. Síla vztahu mezi charakteristikami a výskytem byla určena Pearsonovým korelačním koeficientem. Nepodařilo se potvrdit, že by pro extrakci krajinných charakteristik byla přínosnější data s větším prostorovým rozlišením. Z celkového pohledu krajinné charakteristiky neprokázaly funkční vztahy pro všechny vybrané druhy. Jako relevantní se potvrdily pro vybrané druhy, druhovou bohatost a řád pěvců například faktory průměrná nadmořská výška a land cover. Land cover byl analyzován metodou řízené klasifikace Random Forest v prostředí Google Earth Engine s celkovou přesností 78 % v případě dat Sentinel-2, jak v tundře, tak i ve zbylé části území a pro data PlanetScope v tundře 77 %, ve zbylé části území 66 %. Výsledky klasifikací byly porovnány s datovými produkty CORINE Land Cover (menší prostorové rozlišení), NATURA 2000 (pouze lokální produkt) a vrstvou mapování biotopů NATURA 2000 (neposkytuje potřebnou časovou přesnost, aktualizace probíhá jako dvanáctiletý cyklus). Krajinné metriky byly vypočteny pro jednotlivé kvadráty na úrovni krajiny s využitím balíčku R *landscapemetrics* a ukázaly se jako relevantní v případě šesti druhů – kos horský (*Turdus torquatus*), lejsek černohlavý (*Ficedula hypoleuca*), lejsek šedý (*Muscicapa striata*), puštík obecný (*Strix aluco*), sýc rousný (*Aegolius funereus*) a tetřívek obecný (*Lyrurus tetrix*). U řádu pěvců se potvrdilo např. pomocí metrik – průměrná velikost plošky a počet plošek, že vyhledávají fragmentovanější krajinu s menší průměrnou velikostí plošky nebo větším počtem plošek. Na základě korelací mezi samotnými charakteristikami a výskytem druhů bylo sestaveno šest binárních zobecněných lineárních regresních modelů (pro druhy zmiňované výše), výsledek byl na české straně území porovnán s bodovou nálezovou databází Agentury ochrany přírody a krajiny.

Klíčová slova: Krajinné charakteristiky, Dálkový průzkum Země, Sentinel-2, PlanetScope, řízená klasifikace, Random Forest, krajinné metriky, NDVI, nadmořská výška, land cover, korelace, regresní modely, Krkonoše

Abstract

The thesis uses remote sensing data from two spatial scales (Sentinel-2 with a 10 x 10 m pixel and PlanetScope 3 x 3 m). It explores the possibilities of extracting selected landscape characteristics (spectral indices, land cover type, landscape metrics). In order to evaluate which characteristics and at what scale are statistically significant for the occurrence of 23 selected bird species, species richness in quadrats and the number of species of the order Passeriformes in the Krkonoše Mountains. Data on species occurrence were mapped in the year 2012-2014. The strength of the relationship between characteristics and abundance was determined by Pearson's correlation coefficient. It could not be confirmed that data with higher spatial resolution would be more beneficial for extracting landscape characteristics. Overall, the landscape characteristics did not prove functional relationships for all selected species, but for some species, species richness, and order of Passeriformes, the assumption of elevation and land cover as important factors was confirmed. Land cover was analysed using the Random Forest supervised classification method in Google Earth Engine with an overall accuracy of 78 % for Sentinel-2 data, both in tundra and in the rest of the area, and 77 % for PlanetScope data in tundra, 66 % in other areas. The classification results were compared with the CORINE Land Cover data products (lower spatial resolution), NATURA 2000 (local product only) and the NATURA 2000 habitat mapping layer (does not provide the necessary temporal accuracy, updates are done as a 12-year cycle). Landscape metrics were calculated for each quadrat at the landscape level using the R *landscapemetrics* package and were found to be relevant for six species – ring ouzel (*Turdus torquatus*), European pied flycatcher (*Ficedula hypoleuca*), spotted flycatcher (*Muscicapa striata*), tawny owl (*Strix aluco*), boreal owl (*Aegolius funereus*), black grouse (*Lyrurus tetrix*). For the Passeriformes, it has been confirmed, e.g. using metrics such as average patch size and number of patches, that they seek more fragmented landscapes with smaller average patch size or greater number of patches. Based on correlations between the characteristics themselves and species occurrence, six binary generalized linear regression models were fitted (species mentioned above), and the result was compared with the Nature Conservation Agency's point finding database on the Czech side of the territory.

Key words: Landscape characteristics, Remote sensing, Sentinel-2, PlanetScope, supervised classification, Random Forest, landscape metrics, NDVI, elevation, land cover, correlation, regression models, Krkonoše

Obsah

Seznam obrázků	10
Seznam tabulek	11
Seznam zkratk	13
1. Úvod	15
2. Literární rešerše a úvod do problematiky	17
2.1. Dálkový průzkum	17
2.2. Využití dálkového průzkumu při mapování biodiverzity	18
2.3. Využití spektrálních indexů pro predikce výskytů ptačích druhů	19
2.4. Tematické proměnné	22
2.5. Strukturální proměnné	27
2.6. Statistické hodnocení	31
2.7. Metody průzkumu ptačí populace	34
3. Zájmové území	36
3.1. Krkonoše	36
3.2. Vegetační výškové stupně Krkonoš	37
3.3. Významné biotopy s výskytem ptačích druhů v Krkonoších	38
4. Data a metodika	42
4.1. Použitá data	42
4.2. Metodika	44
5. Výsledky	56
5.1. Topografická charakteristika	56
5.2. Spektrální proměnné (indexy)	57
5.3. Tematické proměnné (land cover)	58
5.4. Strukturální proměnné (krajinné metriky)	62
5.5. Regresní modelování	65
6. Diskuze	79

7. Závěr.....	84
Seznam použité literatury a zdrojů.....	86
Přílohy	97
Elektronické přílohy.....	135
Skripty	136

Seznam obrázků

Obrázek 1: Elektromagnetická vlna	17
Obrázek 2: Elektromagnetické spektrum	17
Obrázek 3: Schéma zobrazující rozdíly v hodnotách NDVI u zdravé a suché vegetace	20
Obrázek 4: Průměrná celková přesnost testovaných metod řízené klasifikace.....	25
Obrázek 5: Příklad jednoduchého rozhodovacího stromu	26
Obrázek 6: Schéma interakce mezi strukturou, funkcí a dynamikou.....	28
Obrázek 7: Typy krajinné struktury	28
Obrázek 8: Princip obecné lineární regrese.....	33
Obrázek 9: Zájmové území s kvadráty, podklad Sentinel-2	37
Obrázek 10: Pravděpodobnost výskytu kosa horského (<i>Turdus torquatus</i>).....	66
Obrázek 11: Rezidua binárního GLR pro kosa horského (<i>Turdus torquatus</i>).....	66
Obrázek 12: Pravděpodobnost výskytu lejska černohlavého (<i>Ficedula hypoleuca</i>)	68
Obrázek 13: Rezidua binární GLR pro lejska černohlavého (<i>Ficedula hypoleuca</i>).....	68
Obrázek 14: Pravděpodobnost výskytu lejska šedého (<i>Muscicapa striata</i>).....	70
Obrázek 15: Rezidua binární GLR pro lejska šedého (<i>Muscicapa striata</i>)	70
Obrázek 16: Pravděpodobnost výskytu puštíka obecného (<i>Strix aluco</i>).....	72
Obrázek 17: Rezidua binární GLR pro puštíka obecného (<i>Strix aluco</i>).....	72
Obrázek 18: Pravděpodobnost výskytu sýce rousného (<i>Aegolius funereus</i>)	74
Obrázek 19: Rezidua binární GLR pro sýce rousného (<i>Aegolius funereus</i>).....	74
Obrázek 20: Pravděpodobnost výskytu tetřívka obecného (<i>Lyrurus tetrix</i>).....	76
Obrázek 21: Rezidua binární GLR pro tetřívka obecného (<i>Lyrurus tetrix</i>)	76

Seznam tabulek

Tabulka 1: Ukazatele získatelné z dat DPZ.....	19
Tabulka 2: Legenda první úrovně VMB NATURA 2000.....	23
Tabulka 3: Parametry metody ee.Classifier.smileRandomForest	26
Tabulka 4: Interpretace hodnot korelačních koeficientů.....	33
Tabulka 5: Dostupné produkty Sentinel-2	42
Tabulka 6: Přehled použitých pásem Sentinel-2A a 2B.....	43
Tabulka 7: Pásma PlanetScope	43
Tabulka 8: Legenda pro oblast tundry s počtem trénovacích bodů a definicí kategorií	46
Tabulka 9: Legenda pro oblast zbylé části území Krkonoš s počtem trénovacích bodů a s popisem kategorií.....	47
Tabulka 10: Převodní tabulka tříd CLC 2018 do legendy klasifikace	49
Tabulka 11: Doporučené krajinné metriky dle literatury na úrovni krajiny.....	50
Tabulka 12: Doporučené krajinné metriky dle literatury na úrovni třídy	51
Tabulka 13: Přehled vybraných druhů pro analýzu, výskyt byl mapován v 1-9 biotopových kategoriích kvadrátů.....	52
Tabulka 14: Přehled vybraných druhů ptactva pro analýzu, výskyt je vázán na biotop krkonošské tundry	53
Tabulka 15: Přehled vybraných druhů ptactva pro analýzu, výskyt byl mapován ve všech dílčích biotopových kategoriích kvadrátů.....	54
Tabulka 16: Přehled vybraných druhů pro GLR a vysvětlujících proměnných.....	55
Tabulka 17: Chybová matice klasifikace oblasti tundry Sentinel-2 z 27. 8. 2016.....	58
Tabulka 18: Chybová matice klasifikace oblasti tundry PlanetScope z 30. 6. 2019.....	59
Tabulka 19: Chybová matice klasifikace zbylé části území Krkonoš z dat Sentinel-2 z 27. 8. 2016	60
Tabulka 20: Chybová matice klasifikace zbylé části území Krkonoš z dat PlanetScope z 30. 6. 2019	60
Tabulka 21: Rozlohy jednotlivých klasifikačních tříd legendy v km ² a CLC 2018	61
Tabulka 22: Přehled GLR kosa horského (Turdus torquatus).....	67
Tabulka 23: Celkové statistiky kosa horského (Turdus torquatus)	67
Tabulka 24: Chybová matice kosa horského (Turdus torquatus).....	67
Tabulka 25: Přehled GLR lejska černohlavého (Ficedula hypoleuca).....	69
Tabulka 26: Celkové statistiky lejska černohlavého (Ficedula hypoleuca)	69

Tabulka 27: Chybová matice lejska černohlavého (<i>Ficedula hypoleuca</i>).....	69
Tabulka 28: Přehled GLR lejska šedého (<i>Muscicapa striata</i>)	71
Tabulka 29: Celkové statistiky lejska šedého (<i>Muscicapa striata</i>).....	71
Tabulka 30: Chybová matice lejska šedého (<i>Muscicapa striata</i>)	71
Tabulka 31: Přehled GLR puštíka obecného (<i>Strix aluco</i>)	73
Tabulka 32: Celkové statistiky puštíka obecného (<i>Strix aluco</i>).....	73
Tabulka 33: Chybová matice puštíka obecného (<i>Strix aluco</i>).....	73
Tabulka 34: Přehled GLR sýce rousného (<i>Aegolius funereus</i>).....	75
Tabulka 35: Celkové statistiky GLR sýce rousného (<i>Aegolius funereus</i>)	75
Tabulka 36: Chybová matice sýce rousného (<i>Aegolius funereus</i>).....	75
Tabulka 37: Přehled GLR tetřívka obecného (<i>Lyrurus tetrix</i>)	77
Tabulka 38: Celkové statistiky tetřívka obecného (<i>Lyrurus tetrix</i>).....	77
Tabulka 39: Chybová matice tetřívka obecného (<i>Lyrurus tetrix</i>)	77
Tabulka 40: Výsledky Global Moran's I indexu reziduí modelů	78

Seznam zkratek

AICc	Akaikeho informační kritérium
AOPK	Agentura ochrany přírody a krajiny
CLC	CORINE Land Cover
CIR	Color-Infrared
DPZ	Dálkový průzkum Země
DN	Digital number
ED	Edge density (hustota okrajů)
GIS	Geografický informační systém
GBM	Gradient Boosted Trees
GEE	Google Earth Engine
GLM	Generalized Linear Model
GLR	Generalized Linear Regression
k-NN	k-Nearest Neighbors (k-nejbližších sousedů)
KRNAP	Krkonošský národní park
LSR	Land surface temperature (povrchová teplota)
LVQ	Learning Vector Quantization
MPS	Mean patch size (průměrná velikost plošky)
N2K	NATURA 2000
NDVI	Normalized difference vegetation index (normalizovaný rozdílový vegetační index)
NDWI	Normalized difference water index (normalizovaný diferenční vodní index)
NEU	Single-Layer Perceptron Neural Networks
NP	Number of patches (počet plošek)
NPP	Net Primary Productivity

OBI	Object-Based Image Analysis (objektově založená analýza obrazu)
PAR	Photosynthetically Active Radiation (fotosynteticky aktivní záření)
PR	Patch richness (bohatost plošek)
RF	Random Forest (náhodný les, metoda pro klasifikaci a regresi)
SAM	Spatial Analysis in Macroecology
SAVI	Soil adjusted vegetation index
SDM	Species distribution modelling (modelování distribuce druhů)
SHDI	Shannon's diversity index (shannonův index diverzity)
SIDI	Simpson's diversity index (simpsonův index diverzity)
SR	Simple ratio index
SST	Sea Surface Temperature (teplota mořské hladiny)
SVM	Support Vector Machines (metoda podpůrných vektorů)
TE	Total edge (celková délka hranic)
TOA	Top of the Atmosphere
VIF	Variance Inflation Factor
VMB	Vrstva mapování biotopů

1. Úvod

Aktuální a přesné informace v detailním měřítku charakterizující habitaty/stanoviště jsou důležité při mapování a ochraně biodiverzity. V současnosti jsou habitaty mapovány převážně pomocí terénního výzkumu, což přináší nejen finanční, ale i časovou náročnost a mnohdy nelze získat delší časové řady (Rocchini et al. 2019). Dálkový průzkum Země (DPZ) naopak při mapování biodiverzity a habitatů živočichů nabízí široké možnosti aplikace a usnadnění práce. K extrakci jinak nesnadno získatelných informací o nárocích ptačích druhů na různé parametry krajiny mohou pomoci data DPZ, která se dnes již poměrně často pro indikaci stanovištních nároků živočichů používají (Bino et al. 2008; Shirley et al. 2013; Sheeren, Bonthoux, Balent 2014; Bonthoux et al. 2018; Bushra, Padalia, Khan 2021).

Různé druhy živočichů, v případě této diplomové práce ptactva, potřebují různé podmínky (stanoviště, typy habitatů) pro život. Některé druhy jsou náročnější na prostředí/parametry habitatu, jiné méně náročné. Současná prostorová data krajinného povrchu, vrstva mapování biotopů (VMB) NATURA nebo CORINE Land Cover (CLC), popisující stanoviště/habitaty, neposkytují mnohdy v dostatečné podrobnosti potřebné informace na tematické a strukturální úrovni, aby bylo možné na základě nich nároky živočichů analyzovat/určit.

Cílem diplomové práce je s využitím dat DPZ (konkrétně dat Sentinel-2 a PlanetScope) extrahovat krajinné časově-prostorové charakteristiky v takové úrovni detailu, která umožní rozlišit (modelovat) nároky vybraných ptačích druhů vyskytujících se v zájmovém území Krkonoš se zaměřením na oblast arкто-alpínské tundry. Práce využívá data o výskytu ptáků v kvadrátech (velikost 1400 x 1400 m) na území Krkonoš poskytnutá RNDr. Jiřím Flouskem, Ph.D. ze Správy Krkonošského národního parku (KRNAP) s cílem ověřit, jaké krajinné charakteristiky (spektrální indexy, typ land cover nebo různé krajinné metriky) jsou pro výskyt vybraných ptačích druhů statisticky významné, a zda mohou být využity k charakteristice typického prostředí/nároků ptačích druhů. Druhým cílem je porovnat využitelnost/přínos (vypovídací schopnost a míru dosažitelné informace) klasifikace land cover s dalšími dostupnými datovými produkty (CLC, NATURA 2000 (N2K) a VMB NATURA 2000).

Třetím cílem je statisticky zhodnotit na základě významných vysvětlujících charakteristik pravděpodobnost výskytu vybraných ptačích druhů v kvadrátech a tento výsledek srovnat s bodovými daty dostupnými na české straně. Analýzy jsou prováděny ve dvou úrovních prostorového rozlišení – jednak pro data s velikostí pixelu 10x10 m (Sentinel-2) a dále 3x3 m (PlanetScope) s cílem ověřit, do jaké míry může rozdílné prostorové rozlišení ovlivnit výsledky analýz.

V práci jsou ověřovány následující výzkumné hypotézy:

- 1) Nadmořská výška, land cover a krajinná struktura představují důležité charakteristiky pro výskyt jednotlivých druhů z hlediska habitatové preference.
- 2) Pro popis výskytu ptactva by měla být užitečnější data s větším prostorovým rozlišením, která detailněji charakterizují vlastnosti prostředí (podrobnější land cover) a lépe zachytí jemnou strukturu a heterogenitu krajiny.
- 3) Pro výskyt řádů pěvců by měla být přínosnější podrobnější data z důvodu výskytu v menších areálech.
- 4) Nalezneme alespoň jeden druh, který je vázaný na určité podmínky a dokážeme pro něj vypočítat pravděpodobnost výskytu v kvadrátu pomocí nalezených charakteristik.


Přínosem práce je propojení DPZ, geografických informačních systémů (GIS) a krajinné ekologie s využitím unikátních dat o výskytu ptačích druhů v 471 kvadrátech z české i polské strany Krkonoš.

2. Literární rešerše a úvod do problematiky

2.1. Dálkový průzkum

DPZ je proces zjišťování a monitorování fyzikálních charakteristik objektů pomocí měření odraženého a vyzařovaného elektromagnetického záření s pomocí dálkových nosičů (družice, letadla, ...). Při měření nedochází k přímému kontaktu s objektem měření, spoléháme na přenos charakteristik, které objekt vyzařuje nebo odráží. Informace jsou získávány prostřednictvím elektromagnetického záření, které je tvořeno elektromagnetickými vlnami (obrázek 1). Tyto vlny jsou složeny ze dvou komponent – elektromagnetického a magnetického pole. Vzdálenost mezi jednotlivými vrcholy vlny představuje vlnovou délku.


Obrázek 1: Elektromagnetická vlna



Zdroj: Novák (2015)

Elektromagnetické záření podle vlnové délky zařazujeme do určitého spektra, ze kterého pouze malou část dokáže vnímat lidské oko (mezi 400 až 700 nm) (obrázek 2). DPZ na rozdíl od lidského oka není nijak omezeno fyzikální šířkou spektra.

Obrázek 2: Elektromagnetické spektrum



Zdroj: LabGuide (2015)

2.2. Využití dálkového průzkumu při mapování biodiverzity

Družicové systémy DPZ poskytují opakovaný a konzistentní pohled na zemský povrch, který má významný aplikační potenciál a najde uplatnění v mnoha oblastech jako je monitorování stavu životního prostředí, monitoring globálních změn, zemědělství, geologický průzkum, meteorologie, mapování či vojenské využití (Schowengerdt 2006). Jednou z oblastí je mapování biodiverzity a habitatů živočichů.

Použití metod DPZ nabízí dva přístupy – prvním přístupem je přímé mapování, které není používané příliš často (Kuenzer et al. 2014). Příkladem využití přímého mapování jsou například studie, které sledují zimoviště plameňáků (Sasamal et al. 2008) či kolonií tučňáků. Schwaller et al. (1989) sledoval změny zimovišť tučňáka kroužkového (*Pygoscelis adeliae*) s použitím dat Landsat TM. Fretwell, Trathan (2009) mapovali kolonie tučňáka císařského (*Aptenodytes forsteri*) s využitím Landsat ETM, kde kolonie byly lokalizovány znečištěním ledu. Dále jsou používána data velmi vysokého rozlišení – detekce hnízd racka chechtavého (*Chroicocephalus ridibundus*) s využitím objektové analýzy obrazu (Martini, Miller 2021) či automatizace procesu mapování tučňáků s využitím konvoluční neuronové sítě (Le, Samaras, Lynch 2021).

Druhým přístupem využití DPZ při mapování biodiverzity je použití „zástupných ukazatelů“, kterými jsou popsány vhodné habitaty nebo preferovaná místa k hnízdění, odpočinku a krmení (Leyequien et al. 2007; Flaspohler et al. 2010; Sheeren, Bonthoux, Balent 2014). Kuenzer et al. (2014) zmiňují, že u ptactva, stejně jako u savců, převažuje druhý přístup a získané ukazatele mohou sloužit k vyhodnocení výskytu druhu. Jednotlivé ukazatele získané z DPZ lze kategorizovat dle Kuenzer et al. (2014) do pěti hlavních kategorií (kompletní přehled uvádí tabulka 1):

- *Geofyzikální* – lze je definovat fyzikálními jednotkami kvantifikující proměnné, např. TOA nebo atmosférická teplota
- *Indexové* – jsou bezrozměrné, poskytují pseudokvantitativní měřítko stavu habitatu, geofyzikální a indexové kategorie jsou vytvářeny podle přesně definovaných vzorců
- *Tematické* – mohou být ovlivněny analytickým zkrácením při zpracování, např. legenda
- *Topografické* – lze odvodit z radarových nebo optických dat
- *Texturní (strukturální)* – závisí na segmentaci obrazu, případně vypočtení z land cover

Tabulka 1: Ukazatele získatelné z dat DPZ

Kategorie	Proměnné
Geofyzikální	<i>Top of the Atmosphere (TOA)</i> <i>Odrazivost na povrchu</i> <i>Photosynthetically Active Radiation (PAR), Land Surface Temperature (LSR),</i> <i>Net Primary Productivity (NPP), Sea Surface Temperature (SST), chlorofyl, sediment,</i> <i>atmosférická teplota, oxidy dusíku a síry, methan, ozon</i>
Indexové	<i>Normalized Difference Vegetation Index (NDVI), Enhanced Vegetation Index (EVI), Soil Adjusted</i> <i>Vegetation Index (SAVI), Leaf Area Index (LAI)</i> <i>Tasseled Cap transformace – (Brightness, Greenness, Wetness)</i> <i>Normalized-Difference Snow Index (NDSI)</i> <i>Drought indices</i> <i>Moisture indices</i>
Tematické	<i>Land cover/land use</i> <i>Jednotlivé dílčí kategorie (např. vegetace/bez vegetace, les/bezlesí)</i>
Topografické	<i>Výška</i> <i>Sklon</i> <i>Orientace</i> <i>Morfologie</i> <i>Drsnost povrchu</i>
Texturální	<i>Velikost objektu</i> <i>Tvar objektu</i> <i>Kompaktnost</i> <i>Homogenita/Heterogenita</i> <i>Fragmentace</i> <i>Konektivita</i> <i>Vztahy mezi objekty</i>

Zdroj: Kuenzer et al. (2014)

2.3. Využití spektrálních indexů pro predikce výskytů ptačích druhů

S využitím neklasifikovaných dat DPZ se můžeme setkat v podobě spektrálních indexů, které představují velmi jednoduchou a snadnou metodu k popisu krajiny. Zároveň dokážou přinést jinou formu informace se srovnatelnými výsledky jako tematické mapy land cover, které jsou vytvořené procesem klasifikace dat DPZ (Bino et al. 2008). Spektrální indexy představují kombinaci spektrální odrazivosti dvou nebo více spektrálních pásem, převedou vztahovou rovnici do jedné relativní hodnoty indexu (Cord et al. 2013). Indexy jsou používány pro hodnocení různých jevů/prvků/typů povrchu: indexy pro hodnocení vegetace, pro plochy spálené ohněm, pro uměle vytvořené prvky, vodu, sněhovou pokrývku či geologické vlastnosti. S výslednými hodnotami spektrálních indexů lze dále pracovat při analýzách – zdravotního stavu vegetace, typu biotopu, mapování organismů atd.


Existuje mnoho příkladů využití spektrálních indexů při hodnocení biodiverzity, predikci, mapování a charakteristiky habitatů a jejich vzorů výskytu. Nejčastěji využívaným indexem je Normalized difference vegetation index (NDVI) (Rouse et al. 1974) (obrázek 3), který

se vypočte jako poměr rozdílu a součtu blízkého infračerveného spektra NIR (silně odráženo vegetací) a viditelného červeného spektra RED (pohlcováno vegetací).

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

NDVI nabývá hodnot -1 až 1 a jednotlivé číselné hodnoty představují spíše orientační zařazení dle druhu povrchu, protože hodnota je ovlivněna např. ročním obdobím (Bonthoux et al. 2018). Orientační zařazení hodnot je následovné – 0,1 až -0,1 reprezentují holé skály, sníh s ledem a vodu, 0,025–0,2 otevřený typ krajiny se zemědělsky obdělávanou ornou půdou, kde hnízdí druhy vázané na tento typ habitatu – skřivan polní (*Alauda arvensis*), křepelka polní (*Common quail*) a 0,2–0,5 řídkou vegetaci s křovinami a keři, pastvinami (Korchagina et al. 2020; USGS 2022). Bonthoux et al. (2018) zmiňuje, že krajina s pastvinami a liniovou vegetací v podobě živých plotů je reprezentována až k hodnotě 0,7 a dle výskytu druhů je typická pro druhy jako konopka obecná (*Linaria cannabina*) nebo strnad obecný (*Emberiza citrinella*). Úplně nejvyšší hodnoty nad 0,7 reprezentují lesy, kde se vyskytují druhy jako červenka obecná (*Erithacus rubecula*) a brhlík lesní (*Sitta europaea*) (Bonthoux et al. 2018).

Obrázek 3: Schéma zobrazující rozdíly v hodnotách NDVI u zdravé a suché vegetace



Zdroj: MyEasyFarm (2021)

Guisan, Thuiller, Zimmermann (2017) zmiňují i další indexy, které se používají při modelování habitatů a distribuce druhů:

- *Simple ratio index* (SR) (Rouse et al. 1974) představuje nejjednodušší index – poměr mezi blízkým infračerveným NIR a červeným spektrem RED. Nabývá rozsahu hodnot od 0 do 30, zdravá vegetace vykazuje hodnoty 2 až 8 (L3HARRIS 2022b):

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

- *Soil adjusted vegetation index* (SAVI) (Huete 1988) představuje lepší možnost pro prostředí s nízkým vegetačním krytem. Parametr L je konstanta (index v případě použití obvyklé hodnoty $L = 0,5$ nabývá rozsahu -0,9 až 1,6), která je určena empiricky a zabraňuje kolísání v odrazivosti u holé půdy, v případě nulové hodnoty parametru L by index odpovídal NDVI (Schowengerdt 2006):

$$SAVI = \frac{(1 + L)(NIR - RED)}{NIR + RED + L}$$

- *Normalized difference water index* (NDWI) (Gao 1996) (nabývá rozsahu -1 až 1, běžný rozsah pro zelenou vegetaci je -0,1 až 0,4) se používá k monitorování obsahu vody v listech. Index je poměrem pásem – blízké infračervené (NIR) a krátkovlnné infračervené (SWIR):

$$NDWI = \frac{NIR - SWIR}{NIR + SWIR}$$

- *Tasseled cap transformace* (Kauth, Thomas 1976) je metoda lineární transformace původních pásem s využitím koeficientů, které jsou specifické pro každý senzor. Metoda se využívá například k odlišení zemědělsky obdělávaných ploch od ostatních kategorií land cover. Výsledkem jsou tři úrovně informací – greenness (podobně jako normalizovaný vegetační index NDVI, který ukazuje fotosyntetický stav vegetace), brightness je spojen s albedem (otevřená stanoviště včetně holé půdy, zemědělské plodiny, zástavba) a wetness, která je spojena s vegetací a vlhkostí půdy. Koeficienty pro Sentinel-2 vyvinuli Shi, Xu (2019). NDVI využili Peterson, Papes (2006), Nieto, Flombaum, Garbulsky (2015) a Santhakumar et al. (2018).

Neklasifikovaná data použila v diplomové práci při identifikaci biotopu tetřívka obecného (*Tetrao tetrix*) Seidlová (2018). Shirley et al. (2013) zmiňují, že neklasifikovaná data lze využít pro predikci ptačích druhů a poukazují na to, že průměry a směrodatné odchylky odrazivosti vypočtené z jednotlivých pásem mohou velmi dobře sloužit při identifikaci oblastí s vysokou mírou biodiverzity, predikci a studiu změn stanovišť.

Oeser et al. (2020) použil metriky stanovišť, které zahrnovaly 14 proměnných, rozdělených do pěti skupin (produktivita, fenologie, otevřenost, vlhkost a sněhová pokrývka). Tyto proměnné byly vypočteny pomocí Tasseled Cap transformace (greenness, brightness, wetness). Přesnost modelů založených na metrikách stanovišť byla v průměru $76 \% \pm 0,02$. Sheeren,

Bonthoux, Balent (2014) zmiňuje, že NDVI může představovat alternativu k topografickým mapám, land cover či mapám vytvořených metodou vizuální interpretace.

Druhá bohatost ptactva roste se zvyšující se hodnotou NDVI až k určité prahové hodnotě, která například na zemědělské půdě dosahuje 85 digital number (DN) (Sheeren, Bonthoux, Balent 2014). Například Shirley et al. (2013) testoval využití dat Landsat pro predikci distribuce 40 ptačích druhů v západním Oregonu. Informace o výskytu ptačích druhů byly získány pomocí bodové metody s rádiem 50 m. Data odrazivosti byla získána z družice Landsat s prostorovým rozlišením 30 m, ze kterých vycházela měřítka 150, 500, 1000 a 2000 m. Snímky by podle Shirley et al. (2013) měly být vybrány v určitém období (záleží na fenologických a atmosférických podmínkách). K analýze vztahů mezi odrazivostí a distribucí ptactva byla použita metoda boosted regression tree, průměrná přesnost byla 79 % se směrodatnou odchylkou 10 %. Model byl výkonnější s využitím jednotlivých pásem odrazivosti než při použití vegetačního indexu NDVI. Nejvyšší vliv na predikce mělo pásmo 4 (Red), což souvisí s vegetační biomasou a fotosyntetickou aktivitou.

2.4. Tematické proměnné

Tematické proměnné reprezentuje land cover, který definuje habitat a ukazuje dostupnost ke zdrojům jako jsou vodní plochy či blízkost prostředí, např. zástavba. Existuje široká škála datových sad s různými měřítky.

Na převážné části území Evropy je k dispozici produkt CLC (příloha 1), vytvářený kontinuálně od roku 1990 s daty publikací – 1990, 2000, 2006, 2012 a 2018. Nejnovější vrstva CLC 2018 vytvořená z dat DPZ v období 2017-2018 zaručuje geometrickou přesnost ≤ 10 m. Minimální mapovací jednotka je plošně definovaná jako 25 ha a v případě liniových prvků s minimální délkou 100 m, tematická přesnost je ≥ 85 %. Sheeren, Bonthoux, Balent (2014) zmiňují, že produkt je nevhodný pro sestavení spolehlivých modelů z důvodu mísení tříd.

Podrobnějším produktem jsou lokality N2K (příloha 2), které představují důležitá místa ochrany přírody se zaměřením na analýzu a ochranu travních porostů. Produkt vznikl na základě dat DPZ velmi vysokého rozlišení, klasifikační legenda obsahuje 55 tematických tříd a jeho minimální mapovací jednotka je 0,5 ha (Copernicus 2022c).

Národním produktem AOPK ČR je VMB NATURA 2000, která byla vytvořena jako podklad pro vymezení evropsky významných lokalit přírodních stanovišť v soustavě NATURA (Lustyk, Oušková 2011). Aktualizace původních dat z let 2000-2005 probíhá jako dvanáctiletý cyklus (2007-2018), kdy je každý rok aktualizováno zhruba 10 % okrsků o rozloze 300-1500 ha s pomocí mapovatelů, kteří ověřují stav původních dat a případně zakreslují nové biotopy.

Legenda se skládá ze tří úrovní, první úroveň je zobrazena v tabulce 2. Metodika podle Lustyk, Guth (2011) uvedla jako biotopy dosahující velké rozlohy (minimální plocha 0,15-0,25 ha):

- T1.1 Mezofilní ovsíkové louky;
- T1.2 Horské trojštětové louky;
- T1.3 Poháňkové pastviny;
- T1.4 Aluviální psárkové louky;
- T1.5 Vlhké pcháčové louky;
- T1.7 Kontinentální zaplavované louky;
- T1.9 Střídavě vlhké bezkolencové louky;
- L2.3 Tvrdé luhy nížinných řek;
- L3 Dubohabřiny;
- L5.1 Květnaté bučiny;
- L5.4 Acidofilní bučiny;
- L9.1 Horské třtinové smrčiny.

Maloplošné biotopy (plocha menší než 0,25 ha), případně větší ale s průměrnou šířkou menší než 50 m, lze zaznamenat při mapování jako bod nebo linii, následně je změřena reálná plocha, která je zanesena do systému (Lustyk, Guth 2011).

Tabulka 2: Legenda první úrovně VMB NATURA 2000

Kód	Třída
<i>V</i>	<i>Vodní toky a nádrže</i>
<i>M</i>	<i>Mokřady a pobřežní vegetace</i>
<i>R</i>	<i>Prameniště a rašeliniště</i>
<i>S</i>	<i>Skály, sutě a jeskyně</i>
<i>A</i>	<i>Alpínské bezlesí</i>
<i>T</i>	<i>Sekundární trávníky a vřesoviště</i>
<i>K</i>	<i>Křoviny</i>
<i>L</i>	<i>Lesy</i>
<i>X</i>	<i>Biotopy silně ovlivněné nebo vytvořené člověkem</i>

Zdroj: Chytrý et al. (2010)

Alternativně může přehled o land cover poskytnout datová sada OpenStreetMap, případně národní mapové produkty – v případě Česka například Základní mapa České republiky v měřítku 1 : 10 000, kterou použili Morelli, Benedetti, Šimová (2018).

Otázkou, jaké tematické rozlišení je významné z ekologického hlediska a jaké ze statistického, se zabývají Guisan, Thuiller, Zimmermann (2017) a uvádějí, že pokud máme například mapu s 50 třídami, je nutné si definovat, jestli jsou všechny třídy důležité

pro vysvětlení výskytu sledovaného druhu a jestli bude nutné některé třídy sloučit dohromady. Snížení počtu tříd, které nejsou potřeba, má statistické výhody, případné statistické modely jsou jednodušší a snadněji vysvětlitelné (Guisan, Thuiller, Zimmermann 2017). Land cover a hodnotu nadmořské výšky využili Basnet et al. (2016) při hledání faktorů ovlivňujících diverzitu a rozšíření druhů.

2.4.1. Klasifikace a metody strojového učení

Pro mapování biodiverzity/habitatů se využívají různé datové produkty s rozdílnou metodikou vzniku – jedna z možností, jak získat kvalitní produkt, je využití klasifikace, jehož výstupem je land cover. Následující část představí širší problematiku klasifikace se zřetelem na volbu klasifikační metody, která dosahuje co největší přesnosti při klasifikaci obrazu.

Schowengerdt (2006) definuje klasifikace obrazu jako proces vytvářející v DPZ tematické mapy ze snímků. Existuje velké množství faktorů, které mohou ovlivnit záměnu spektrální signatury, např. topografie povrchu, stíny, atmosférická variabilita, změny v kalibraci snímače a míšení pixelů v rámci prostorového rozlišení snímače.


Klasifikace funguje na principu rozdělení naměřeného datového souboru do menšího počtu informačních tříd podle určitého příznaku s využitím rozhodovacích pravidel – klasifikátoru (Anderson et al. 1976). Existuje mnoho typů klasifikací, mezi nejznámějšími jsou řízená (*anglicky Supervised Classification*) a neřízená (*anglicky Unsupervised Classification*), případně klasifikace založená na základě pixelů nebo objektů vytvořených pomocí segmentace obrazu.

Řízená klasifikace má dvě části: trénovací (učící) a klasifikační. V trénovací části probíhá výběr pixelů o známé hodnotě proměnné pro trénování klasifikátoru z důvodu rozlišení požadovaných tematických tříd a určení rozhodovacích pravidel (Schowengerdt 2006). Klasifikační část představuje aplikaci vytvořených rozhodovacích pravidel na celý obraz.

Z důvodu optimalizace výsledku je nutné se zabývat porovnáním jednotlivých klasifikačních metod řízené klasifikace založených na strojovém učení a vybrat, která je nejvhodnější. Porovnáním metod Random Forest (RF), k-Nearest Neighbors (k-NN) a Support Vector Machines (SVM) na datech Sentinel-2 pro oblast 30 x 30 km² delty Rudé řeky ve Vietnamu se zabývali Thanh Noi, Kappas (2017). Thanh Noi, Kappas (2017) uvádějí, že nejvyšší přesnosti dosáhla metoda RF, jejíž výkonnost ovlivňuje v největší míře nastavení parametrů (ntree a mtry). Nejlepších výsledků dosáhla též RF v článku Praticò et al. (2021), kde byla metoda použita při klasifikaci středomořských lesních biotopů na základě sezónních časových řad Sentinel-2 v prostředí GEE. Výsledek je dále ovlivněn množstvím použitých dat

v trénovacím datasetu – optimální velikost studoval Ramezan et al. (2021) (obrázek 4), který navazuje na předchozí studie (Fassnacht et al. 2014; Qian et al. 2015 a Shang et al. 2018). Počet trénovacích bodů se pohyboval od 40 do 10 000 s využitím šesti řízených algoritmů strojového učení: SVM, RF, k-NN, Neural Networks (NEU), Learning Vector Quantization (LVQ), Gradient-Boosted Trees (GBM). Obecně studie zmiňují, že větší trénovací soubory poskytují lepší výkon než menší soubory (Foody et al. 2006). Ramezan et al. (2021) však našel rozdíly, jak jednotlivé algoritmy reagovaly na změny ve velikosti dat. Ramezan et al. (2021) uvádí, že celková přesnost klasifikátoru RF se začala zvyšovat, když počet trénovacích bodů dosáhl počtu 1250. Rozdíl v přesnosti mezi klasifikacemi s využitím rozmezí bodů 1250 až 10 000 byl pouhých 0,5 %. Pokud klasifikace dosáhne velmi vysoké celkové přesnosti, je zde pouze malý potenciál pro další zvyšování celkové přesnosti (Ramezan et al. 2021).

Obrázek 4: Průměrná celková přesnost testovaných metod řízené klasifikace




Zdroj: Ramezan et al. (2021), pozn: SVM, RF, k-NN, NEU, LVQ, GBM v závislosti na velikosti trénovacího souboru, osa x je v logaritickém měřítku v závislosti na velikosti trénovacího souboru, osa y je v logaritickém měřítku

2.4.2. Random Forest

Rozhodovací pravidlo RF funguje na principu zobecnění metody rozhodovacích stromů (decision trees) (obrázek 5) – metoda kombinuje několik rozhodovacích stromů, které jsou náhodně sestaveny z trénovacích příznaků (Ho 1995). Rozhodovací stromy pracují na principu náhodného výběru o daném počtu prvků ze vstupního trénovacího souboru a sestaví rozhodovací strom. Pixel je vyhodnocen všemi rozhodovacími stromy dle rozhodovacího pravidla vytvořeného na základě trénovacích tříd a odvozených podmínek, které vyplývají z hodnot vektoru příznaku v trénovacích třídách. Trénování klasifikátoru probíhá pomocí

vstupních příznaků, podle kterých jsou vytvořeny uzly stromů a jejich hierarchie. Následně je pixel přiřazen do kategorie s největší četností dle předem definované klasifikační třídy (Breiman 2001). Výhodou metody je robustnost v odlehlých hodnotách v trénovacích datech (Rodriguez-Galiano et al. 2012). Parametry metody RF v Google Earth Engine (GEE) uvádí tabulka 3.

Obrázek 5: Příklad jednoduchého rozhodovacího stromu



Zdroj: Yiu (2019)

Tabulka 3: Parametry metody `ee.Classifier.smileRandomForest`

Název	Datový typ	Výchozí hodnoty	Popis
Počet stromů (<i>numberOfTrees</i>)	<i>Integer</i>	-	Určuje počet stromů v náhodném lese
Počet proměnných v každém stromě (<i>variablesPerSplit</i>)	<i>Integer</i>	Odmocnina z počtu vstupních proměnných	Určuje počet proměnných (pásem) vstupujících do každého stromu
Minimální populace listu (<i>minLeafPopulation</i>)	<i>Integer</i>	1	Ukončuje větvení pod určenou prahovou hodnotou
Část prvků v každém stromě (<i>bagFraction</i>)	<i>Float</i>	0,5	Určuje část (frakci) vstupních trénovacích dat, které vstupují do každého stromu
Větvení (<i>maxNodes</i>)	<i>Integer</i>	Bez limitu	Určení maximálního počtu listových uzlů v každém stromu
Náhodnost (<i>seed</i>)	<i>Integer</i>	0	Určení typu náhodnosti

Zdroj: GEE (2021)

2.4.3. Cloudové vs. desktopové řešení pro zpracování dat DPZ

Pro tvorbu vlastních tematických dat (land cover) bylo zvoleno cloudové řešení GEE. Obě řešení mají své výhody i nevýhody, které jsou stručně představeny níže v této podkapitole. V případě desktopu lze využít software s již předdefinovanými funkcemi s jednoduchým či méně přívětivým uživatelským prostředím. Dále není potřeba připojení k internetu a data jsou umístěna lokálně (jsou tedy pod kontrolou uživatele). Nevýhodou je, že vše závisí na vašem hardwaru uživatele a případně i na internetovém připojení, což může být omezující při

zpracování velkých objemů dat DPZ (např. jedna scéna Sentinel-2 má velikost kolem 1 GB). Dále lze pracovat pouze na jednom počítači a hrozí ztráta dat v případě poškození počítače.

Cloudová řešení pracují pouze s internetovým prohlížečem, k dispozici jsou online jen některá data a předdefinované funkce téměř v okamžitém čase bez nutnosti stahování. Veškeré operace probíhají v cloudu (vzdáleném serveru), tudíž velkou výhodou je rychlost. Nevýhodou je nutnost znalosti programovacích jazyků, některé funkce je nutno naprogramovat a nelze provádět pre-processing dat.

Tamiminia et al. (2020) popisuje GEE jako cloudově založenou platformu pro zpracování geoprostorových dat pro analýzu a monitorování životního prostředí. GEE nabízí petabajty veřejně dostupných snímků dálkového průzkumu s možností vysokorychlostního zpracování s použitím algoritmů strojového učení využívající výkon společnosti Google. API (Application Programming Interface – vývojové prostředí pro tvorbu aplikací) podporují jazyky Python a JavaScript. Nevýhodou GEE je, že nelze dohledat, jak Google definuje jednotlivé funkce, které se mohou měnit v čase.


2.5. Strukturální proměnné

Z hlediska struktury krajiny lze studovat velikost, tvar, konektivitu, fragmentaci, vztahy mezi jednotlivými prvky, homogenitu/heterogenitu či kompaktnost. Pro pochopení principů je nutné definovat význam termínu krajina, který má mnoho definic v závislosti na oboru lidské činnosti. Z obecného hlediska krajina představuje složitý systém tvořený apolitickou, biologickou a lidskou činností. Matějček (2007) definuje krajinu v geografickém pojetí jako územní celek zemského povrchu s geografickou polohou, vlastnostmi a vzhledem odlišným od okolních celků, kde působí zákonité přírodní i člověkem podmíněné procesy. Jedna z nejpoužívanějších definic od Forman, Godron (1993) popisuje krajinu jako heterogenní část zemského povrchu zahrnující vzájemně se ovlivňující a propojené ekosystémy, které se nacházejí několikrát v podobných formách na zemi. Forman, Godron (1993) definuje tři cíle studia krajiny (obrázek 6):

- 1) Krajinná struktura – tvořena ekosystémy a jejich vztahy, tvarem, velikostí, uspořádáním, kontinuitou a historií. Představuje způsob rozmístění jednotlivých krajinných složek (matrice, koridor, plocha). Struktura krajiny může být z hlediska její geometrie a popisné statistiky popsána krajinnými metrikami.
- 2) Funkce krajiny – jedná se o interakci mezi složkami (toky energie, látek a druhů organismů a složení ekosystémů)

- 3) Změny krajiny v čase (dynamika) – změna struktury a funkce krajinné mozaiky v čase, která může mít různé časové a prostorové dimenze

Obrázek 6: Schéma interakce mezi strukturou, funkcí a dynamikou



Zdroj: vlastní tvorba na základě Forman, Godron (1986)


Krajinnou strukturu lze rozdělit na pojmy:

- 1) Mikrostruktura = představuje lokaci jednotlivých krajinných prvků
- 2) Makrostruktura = představuje celkovou rozlohu jednotlivých typů krajiny, statistická hodnota

Existují tři typy krajinné struktury dle Forman, Godron (1993) a McGarigal (2015) (obrázek 7):

- 1) Krajinná matice (matrix)
- 2) Krajinný koridor (corridor)
- 3) Krajinná ploška (patch)

Obrázek 7: Typy krajinné struktury



Zdroj: Lausch et al. (2015)

S rozvojem výpočetní techniky, GIS a DPZ se staly krajinné metriky velmi jednoduchým a užitečným nástrojem, jak ze strukturálního hlediska popsat krajinu určitými prostorovými vlastnostmi (např. velikost, tvar, fragmentace). V posledních desetiletích byly použity a navrženy desítky metrik pro popis struktury (Fortin et al. 2003; Farina 2007; Ferrari, Lookingbill, Neel 2007 nebo Watts, Handley 2010). Další používaná definice krajinných metrik je, že představují určité kvantitativní měřítko běžně pozorovaných prostorových vzorců v krajině (Lopez, Frohn 2017). Kvantitativní popis struktury krajiny je nezbytný pro analýzu ve strukturálních prvcích a ekologických procesech v celé krajině. Krajinné metriky lze využít pro celou řadu aplikací – hodnocení změn ve využívání krajiny, krajinné plánování, rekonstrukci krajiny, lesní hospodářství, sledování biodiverzity, sledování kvality vody, hodnocení urbanizace a dopravních sítí, hodnocení kvality života a trendů městských oblastí či habitatové analýzy nejčastěji zaměřené na savce a ptáky (Šímová, Gdulová 2012). Analýzu krajiny pomocí krajinných metrik lze provádět na třech hierarchických úrovních – na úrovni jednotlivé plošky v mozaice, na úrovni třídy (složené z jednotlivých plošek) nebo na úrovni celku jako krajiny (složené z jednotlivých tříd). Metriky lze použít jako celek, popřípadě analyzovat jednotlivé krajinné složky a kategorie.

Krajinné metriky se dají rozdělit do různých skupin, avšak přesné rozdělení není definované (např. plošné metriky, metriky hranic a kontrastu, metriky tvaru, metriky diverzity a skladby krajinných složek).

2.5.1. Problémy krajinných metrik

Pro výpočet krajinných metrik lze použít mnoho druhů dat (rastrové nebo vektorové produkty) a softwarů. Metriky představují relativně rozšířený a efektivní způsob hodnocení makro a mikrostruktury krajiny, avšak v případě špatného výpočtu nebo chybné interpretace mohou představovat riziko chybného výsledku. Je nutné splnit určité předpoklady – pro vhodné výsledky je nutno znát vstupní data, vzorce metrik a základní princip fungování softwaru, který slouží k výpočtu (Šímová 2017). Výsledky ovlivňuje kvalita vstupních dat, míra generalizace, prostorové měřítko (např. některé metriky je možno využít pouze na jedné prostorové úrovni) (Li, Wu 2004; Bailey et al. 2007; Wheatley 2010; Šímová, Gdulová 2012 nebo McGarigal 2015) a tematické rozlišení, kde se výsledky změnily s nárůstem tematických tříd (Bailey et al. 2007; Buyantuyev, Wu 2007). Použití nevhodného měřítka může přinést nevhodné a zkreslené výsledky (Šímová, Gdulová 2012). Dopady změn v prostorovém a tematickém rozsahu krajinných metrik analyzovali například Delcourt, Delcourt (1996);

Wu (2004); Baldwin et al. (2004); Pascual-Hortal, Saura (2007); Saura, Castro (2007) nebo Šimová, Gdulová (2012).

Pokud se setkáme s využitím DPZ pro mapování biodiverzity a predikci ptactva, převážně se využívají data stejného měřítka, popřípadě proběhne převzorkování na menší prostorové rozlišení. Gottschalk et al. (2011) neporovnával data z různých senzorů jako tato práce, nýbrž převzorkovaná data z color-infrared (CIR) senzoru fotogrammetrické kamery o prostorovém rozlišení 0,5 m z území Německa. Bradley et al. (2012); Lechner et al. (2012) nebo Cord et al. (2013) poukazují na to, že prostorové měřítko prediktorů získané pomocí DPZ často nemusí odpovídat životním strategiím druhů.

Pokud se zaměříme na využití DPZ jako zdroje dat pro prediktory v Species distribution modelling – modelování distribuce druhů (SDM), Cord et al. (2013) zmiňuje, že zatím nedosáhlo plného potenciálu. Jedním z předmětů výzkumu je využití kombinace různých prediktorů získaných z DPZ pro modelování ve více měřítkách. Otázkou je, jak vhodně zvolit celkový rozsah analýzy a měřítkový parametr. Rozsahy analýzy, kde využíváme krajinné metriky musí být koherentní – měřítko dat a měřítko analýzy musí být shodné pro správný výpočet a interpretaci. Důležitost měřítkového parametru zmiňují Šimová, Gdulová (2012), Šimová (2017) a Morelli, Benedetti, Šimová (2018). Nabízí se otestovat více měřítek a zaměřit se na rozdíly v hodnotách metrik ve více měřítkách.

Jednotlivé krajinné metriky mohou definovat různé habitaty. Problematikou se zabývala Šimová (2017), která využila analýzu hlavních komponent pro zjištění metrik vhodných pro určitá prostředí. Pro mozaiky lesních porostů se ukázaly jako vhodné metriky Shannon diversity index (SHDI) a Simpson diversity index (SIDI), v případě krajiny s liniovými prvky Patch richness (PR) a Edge density (ED), pro krajinu s velkými homogenními ploškami Mean patch size (MPS) a ED. Sníženou schopnost predikce mohou mít metriky v lesních porostech, kde je důležitý i vertikální gradient a záleží zde na kvalitě vstupních dat pro výpočet (Morelli, Benedetti, Šimová 2018).

Ceresa et al. (2012) hledal souvislost mezi výskytem ůhýka obecného (*Lanius collurio*) a výskytem krajinných prvků, jakými jsou izolované keře a živé ploty v oblasti Italských Alp, pomocí třech analytických metod – binární logistická regrese, multimodelová inference a hierarchické shlukování. Dle výsledků byl výskyt ptactva pozitivně ovlivněn rozsahem přírodních luk a pastvin, izolovaných keřů a živých plotů. Negativně na výskyt působily lesní porosty.

Regos et al. (2016) porovnával změny land cover mezi lety 2000-2010 s využitím dat DPZ v oblasti Galicie (severozápadní Španělsko) a hodnotil dopady změn na výskytu ptáčích druhů.

Během deseti let došlo ke změnám od holé půdy a otevřených křovin k uzavřeným křovinatým porostům a lesům. V případě třinácti analyzovaných druhů došlo k významnému nárůstu počtů, např. hrdličky divoké (*Streptopelia turtur*), pěnice kaštanové (*Sylvia undata*) nebo budníčka horského (*Phylloscopus bonelli*). Opačný trend byl zaznamenán u čtyř vybraných druhů preferujících otevřenou krajinu, např. ťuhýka obecného (*Lanius collurio*). Důležitost mezní a okrajové vegetace (živé ploty, keře, izolované stromy, obdělávané plochy) potvrzují i Morelli (2013) a Šimová (2017). Šimová (2017) uvádí, že existují druhy vázané na živé ploty, keře nebo neobdělávané oblasti. Okrajovou vegetaci a izolované plošky lze snadno studovat pomocí GIS. Zároveň je lze analyzovat pomocí vhodně zvolených krajinných metrik (Bennett, Radford, Haslem 2006 a Šimová 2017).

Bushra, Padalia, Khan (2021) zkoumali vztah s využitím Generalized linear modelu (GLM) mezi 16 vysvětlujícími proměnnými získanými z dat DPZ (indická data IRS LISS-IV s prostorovým rozlišením 5,8 m) a daty o výskytu ptactva v oblasti, která prochází urbanizací v podhůří Himaláje v Indii. Bushra, Padalia, Khan (2021) uvádějí, že osm proměnných mělo korelaci $R^2 > 0,1$ s ptacími druhy (mezi nejvýznamnější charakteristiky patřila nadmořská výška, NDVI a PD). Hodnota PD byla vysoká v oblasti silnic a měla negativní vliv na druhovou bohatost ptactva (Bushra, Padalia, Khan 2021).

2.6. Statistické hodnocení

Data získaná z oblasti DPZ (v případě další literatury obecně (bio)geografická data) nabízejí mnoho různých možností statistického vyhodnocení. Dále je možné je využít k určení statisticky významné vysvětlující proměnné, případně modelovat výskyt druhů. Historicky první analýzy v oblasti GIS pro modelování rozšíření druhů využívaly velmi jednoduché přístupy v podobě envelopes, convex hulls nebo environmental matching (Elith, Leathwick 2009). Novějším přístupem jsou modely rozšíření druhů, které vznikly propojením statistických metod vzniklých na základě terénních studií s vrstvami geografických informačních systémů (Elith, Leathwick 2009). SDM neboli též habitatové modely jsou používány k vymezení podmínek prostředí, ve kterém se vyskytuje trvale nebo přechodně určitý jedinec nebo populace. Data pro SDM lze rozdělit do dvou kategorií – data, která ukazují přítomnost ale i nepřítomnost druhu označovaná jako „presence-absence“, případně čistá data o výskytu „presence-only“. Případně je také možné data o nepřítomnosti druhu uměle vygenerovat, v takovém případě budou označena termínem „background data“. Z hlediska algoritmů lze použít dělení na parametrické (statistické) modely:

- Regrese a regresní modely

- Obecný aditivní model (GAM)
- Multivariate Adaptive Regression Splines (MARS)

Mezi neparametrické modely též označované jako machine-learning řadíme:

- Maximum Entropy (MaxEnt)
- Boosted Regression Tree (BRT)
- SVM
- RF

Celkově jsou jednotlivé algoritmy dostupné např. v R v balíčcích. Balíček *sdm* nabízí 15 modelovacích metod, mezi které jsou zahrnuty například metody (BTR, GLM, MAXENT, MARS, RF, SVM). Další balíček, který nabízí modelování, se jmenuje *biomod2*. Z hlediska softwarových možností se nabízí využití softwarů openModeller a Spatial Analysis in Macroecology. Přehled dostupných metod pro *biomod2* a openModeller zpracovala v bakalářské práci „Srovnání výpočetních algoritmů pro prostorovou distribuci druhů“ Vlčková (2016). Výsledkem modelů jsou predikce v prostoru, které ukazují aktuální či potenciální rozšíření druhů nebo indexy vhodnosti habitatu. Možnost statisticky zpracovat tyto analýzy nabízí též ArcGIS prostřednictvím toolboxu *Spatial Statistics*.

2.6.1. Korelační a regresní analýza

Korelace se používá k popisu vzájemného vztahu mezi dvěma veličinami x a y a hledá sílu závislosti, směr a stupeň asociace dvou proměnných. Síla je popsána korelačním koeficientem, který nabývá hodnot v rozmezí -1 až 1 v závislosti na tom, zda se jedná o zápornou, nulovou nebo kladnou korelaci. Interpretace hodnot závislosti korelačního koeficientu je nejednoznačná a lze nalézt rozdíly dle použité literatury. V případě této diplomové práce budu při interpretaci hodnot korelačního koeficientu vycházet z Evans (1996) (tabulka 4). Znaménko vyjadřuje směr vztahu – kladný pozitivní vztah, záporný negativní vztah. Významnost vztahu je vyjádřena blízkostí k ± 1 (čím více se blíží hodnota k ± 1 , tím je vzájemný vztah významnější).

Při analýze se můžeme setkat s následujícími koeficienty – Pearsonův, Spearmanův nebo Kendallův. Spearmanův koeficient se využívá u nelineárních vztahů (je počítán z pořadí hodnot, nevyžaduje normalitu dat a je méně citlivý na odlehlé hodnoty). V případě Pearsonova korelačního koeficientu, který byl v rámci analýzy využit v této diplomové práci, musí data splňovat následující předpoklady – dvojrozměrné normální rozdělení, lineární rozložení a intervalový nebo poměrový charakter (MUNI 2022). Jeho vlastností je silné ovlivnění odlehlými hodnotami a citlivost na zešíkmení dat (MUNI 2022).

Tabulka 4: Interpretace hodnot korelačních koeficientů

Hodnota korelace	Interpretace závislosti
$\pm 0,00-0,19$	„velmi slabá“
$\pm 0,20-0,39$	„slabá“
$\pm 0,40-0,59$	„střední“
$\pm 0,60-0,79$	„silná“
$\pm 0,80-1,00$	„velmi silná“

Zdroj: Evans (1996)

2.6.2. Zobecněný lineární regresní model (Generalized linear model)

Regresní analýza je jednou z metod SDM a obecně je jednou z nejčastěji používaných statistických metod. Regrese usiluje o nalezení co nejpresnějšího modelu mezi vysvětlovanou proměnnou (závislou – v případě této diplomové práce výskyt ptačího druhu) a jednou či více vysvětlujícími (nezávislými) proměnnými. Zároveň odpovídá na otázku, jaký tvar vztahu existuje mezi proměnnými a jestli závislou proměnnou lze odhadnout pomocí jedné nebo více nezávislých proměnných (tuto vlastnost lze použít k predikci závislé proměnné) (obrázek 8). Následující vztah představuje lineární tvar rovnice vícenásobné regrese:

$$y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \beta_k x_k + \varepsilon$$

kde:

y = hodnota vysvětlované proměnné,


α = absolutní člen (konstanta),

βx = směrnice přímky,

x = hodnota vysvětlující proměnné pro dané pozorování,

ε = náhodná složka (chyba).

Obrázek 8: Princip obecné lineární regrese



Zdroj: ESRI (2022), pozn. predicted = předpokládaná hodnota, observed = pozorovaná hodnota

Binární (logistická) regrese je jedna z vícerozměrných statistických metod a je charakteristická vysvětlovanou (závislou) proměnnou, která nabývá pouze dvou hodnot (např. přítomnost/nepřítomnost nebo 0-1). V případě ArcGIS Pro při použití funkce Generalized Linear Regression (GLR) se zvoleným binomickým rozdělením v toolboxu *Spatial Statistics* lze správnost výsledků interpretovat podle následujících kritérií:

- *Akaikeho informační kritérium* (AICc) udává míru výkonnosti modelu, nižší hodnota znamená výkonnější model.
- *% deviance explained* (vysvětlená odchylka) udává rozptyl závislé proměnné, který připadá na vysvětlující proměnné.
- *Waldův chí-kvadrát* (Waldova statistika) udává celkovou statistickou významnost modelu na hladině spolehlivosti α . Nulová hypotéza je definována tak, že vysvětlující proměnné modelu nejsou účinné. V případě 95% hladiny α intervalu spolehlivosti (p hodnota je menší než 0,05) můžeme potvrdit model jako statisticky významný.

2.7. Metody průzkumu ptačí populace

Mezi metody využívané pro analýzu ptačích populací patří transekce, mapování a sčítání neboli bodová metoda. Jednotlivé metody mohou generovat mírně odlišené výsledky a jejich přesné vysvětlení nabízí například Tryjanowski (2017).

Metoda mapování je realizována v Evropě většinou od dubna do července v závislosti na lokalitě. Vybrané oblasti (pozemky, pravidelné čtverce) jsou navštíveny šestkrát až desetkrát, převážně v dopoledních hodinách (někdy je nutnost nočních návštěv). Zjištěné ptactvo je zakresleno do map. Metoda mapování je tedy časově náročná a není příliš populární (Tryjanowski 2017).

Jednodušší a méně časově náročnou metodou je transekce. Transekty se nacházejí ve čtvercích o rozměrech 1 km². Během období, kdy se ptactvo rozmnožuje, je zájmová oblast navštívena dvakrát. V oblasti střední Evropy je první návštěva uskutečněna mezi 10. dubnem a 15. květnem a druhá mezi 16. květnem a 30. červnem. V každém čtverci je sčítání provedeno pomocí dvou paralelních jeden kilometr dlouhých transektů od východu na západ a od severu na jih. Každý transekt je rozdělen do pěti dvěstěmetrovných dlouhých úseků, ve kterých je zaznamenáno ptactvo ve třech vzdálenostních úrovních. Průzkum vždy začíná mezi úsvitem a devátou ráno a trvá přibližně 90 minut (Tryjanowski 2017).

Sčítání, tzv. bodová metoda, je jednoduchá a využívá se pro celostátní monitorování. Vybraná místa jsou navštívena dvakrát, jednou v období dubna až května, podruhé v období

konce května až června. V čase od východu slunce do deseti hodin během první návštěvy a během druhé do devíti hodin. Během sčítání by neměl být silný vítr a déšť, návštěva trvá deset minut. Poloměr sčítání je 100 m (Tryjanowski 2017). Bodovou metodu sběru dat využili například Shirley et al. (2013), Sheeren, Bonthoux, Balent (2014), Morelli (2017) nebo Morelli, Benedetti, Šimová (2018). Tryjanowski (2017) uvádí, že bodová metoda nadhodnocuje velikost populace, další problém je odhad vzdálenosti u druhů, které mají dlouhou akustickou komunikaci.

3. Zájmové území


3.1. Krkonoše

Krkonoše jsou nejvyšším pohořím Česka a slezské části Polska (nejvyšší hora Sněžka 1603 m n. m.) s uspořádáním hlavních hřbetů a údolí ve směru severozápad-jihovýchod (obrázek 9). Přibližná délka hor je 35 kilometrů. Jedná se o nejsevernější oblast v rámci regionu střední Evropy (lokalizované 50° zeměpisné šířky), kde se můžeme setkat s ekosystémy nad alpínskou (horní) hranicí lesa (KRNAP 2022b).

Přírodním a kulturním hodnotám Krkonoš, jejich historii i vlivu člověka na jejich utváření se v posledních desetiletích věnovala celá řada obsáhlých monografických a encyklopedických publikací, např. (Fanta 1969; Šourek 1969; Lokvenc 1978; Sýkora 1983 nebo Knapik, Raja 2013). Člověk se podílí na utváření krajiny v Krkonoších po dobu více než 600 let, kdy je oblast osídlena. Krkonoše též představují důležitou křižovatku jak v severo-j jižním, tak západovýchodním směru. (Flousek, Gramsz, Telenský 2015). Flousek, Gramsz, Telenský (2015, s. 17) uvádí: *„Z klasických i moderních studií vyplývá, že Krkonoše fungovaly jako spojující most mezi severskou tundrou, opakovaně zatlačovanou kontinentálním ledovcem směrem k jihu do polské a německé nížiny, a alpínskými či subalpínskými ekosystémy, šířenými vlivem chladného klimatu z hřebenů Alp severním směrem do nížin, pahorkatin a středoevropských pohoří.“*

Geologická stavba hor je tvořena prvohorními krystalickými břidlicemi, dále se zde vyskytují křemence, krystalické vápence, případně v malém množství i třetihorní čedič (KRNAP 2022a). Půdy mají výškovou zonaci, nižší polohy jsou hnědé lesní půdy, ve vyšších polohách jsou podzolové rankery a humusové a rašelinné podzoly (KRNAP 2022c). V nejvyšších polohách se vyskytují alpínské půdy (KRNAP 2022c). Hřeben Krkonoš utváří rozvodí mezi Severním a Baltským mořem. Flousek, Gramsz, Telenský (2015, s. 26) uvádí: *„Tekoucí a stojatá voda v krajině je zásadním faktorem, který zvyšuje její geomorfologickou rozmanitost, pestrost vegetace a následně i diverzitu živočišných druhů včetně ptáků.“*. Síť vodních toků je velmi hustá na obou stranách hor, větší četnost vodních ploch je na polské straně.

Obrázek 9: Zájmové území s kvadráty, podklad Sentinel-2



Zdroj: Vlastní tvorba, Copernicus (2021)

Krkonoše jsou součástí mírného pásu, ve kterém dochází ke střídání čtyř ročních období. Hlavní hřeben představuje překážku pro proudy vlhkého a chladného vzduchu přicházejícího od Atlantského oceánu, což se projevuje nízkými teplotami s velkým množstvím dešťových a sněhových srážek. Flousek, Gramsz, Telenský (2015) uvádí, že větrné proudění je složité, převládá jihozápadní až severozápadní proudění, které je však ovlivněno lokálně reliéfem, kde vznikají zvláštní lokální systémy spojené s dalšími přírodními procesy (ukládání srážek, sluneční svit, vlhkost vzduchu nebo laviny).

3.2. Vegetační výškové stupně Krkonoš

V Krkonoších můžeme podle Flousek, Gramsz, Telenský (2015) nalézt čtyři výškové (vegetační) stupně:

- Submontánní (zhruba do 800 m n. m.)
 - Charakterizován listnatými a smíšenými lesy, které byly v minulosti často vykáceny a nahrazeny smrkovými monokulturami. V současné době je tento stupeň tvořen mozaikou měst a vesnic, různě velkých lesních komplexů, remízků, liniových prvků (zarostlé meze) a zemědělsky obdělávanou krajinou

v podobě trvalých travních porostů či orné půdy. Vodní plochy se vyskytují v podobě rybníků či vodních nádrží.

- Montánní (800-1250 m n. m.)
 - Charakterizován druhotnými horskými smrčínami, které byly v druhé polovině 20. století poškozeny imisemi. Dále zde lze nalézt bezlesí s horskými loukami jako pozůstatek budního hospodářství.
- Subalpínský (1250-1450 m n. m.)
 - Oblast nad horní hranicí lesa s výskytem klečových porostů, subalpínských travních porostů a rašelinišť.
- Alpínský (1450-1603 m n. m.)
 - Oblast chudá na vegetaci, výrazně ovlivněná působením mrazu a větru.

3.3. Významné biotopy s výskytem ptačích druhů v Krkonoších

3.3.1. Jehličnaté lesy

V jehličnatých lesích převládá smrk ztepilý (*Picea abies*). Nalezneme ho od podhůří po horní hranici lesa, která je v Krkonoších kolem 1250 m n. m. (možnost kolísání mezi 1200-1350 m n. m.). Převážně jde o stejně staré druhotné monokultury, původní smrčiny se již dnes vyskytují pouze na těžko přístupných místech (konce horských údolí, prudké svahy, podmáčené plochy nebo oblasti horní hranice lesa) (Flousek, Gramsz, Telenský 2015).

Podle Flousek, Gramsz, Telenský (2015) jsou druhy s vazbou na smrkový les – sýc rousný (*Aegolius funereus*), kulíšek nejmenší (*Glaucidium passerinum*), krahujec obecný (*Accipiter nisus*), sýkora uhelníček (*Periparus ater*), sýkora parukářka (*Lophophanes cristatus*), ořešník kropenatý (*Nucifraga caryo-catactes*), křivka obecná (*Loxia curvirostra*) nebo ve vyšších polohách například datlík tříprstý (*Picoides tridactylus*).

Do biotopu jehličnatých lesů lze zařadit i biotop holin a mlazin – ve většině případů se jedná o oblasti poškozené před rokem 1989 ekologickými kalamitami (Vacek et al. 2007). Holiny a mlaziny jsou dle Flousek, Gramsz, Telenský (2015) vyhledávány druhy – linduška lesní (*Anthus trivialis*), pěnice černohlavá (*Sylvia atricapilla*), pěvuška modrá (*Prunella modularis*), budníček větší (*Phylloscopus trochilus*), budníček menší (*Phylloscopus collybita*), otevřenější plochy vyhledává tetřívka obecná (*Tetrao tetrix*).

3.3.2. Listnaté a smíšené lesy

Listnatým lesům v Krkonoších dominuje asi z jedné třetiny buk lesní (*Fagus sylvatica*) (Vacek et al. 2007). Celkově však listnaté a smíšené lesy tvoří jen asi jednu desetinu lesů Krkonoš. Flousek, Gramsz, Telenský (2015) uvádějí jako charakteristické druhy listnatých a smíšených lesů lejska malého (*Ficedula parva*), čápa černého (*Ciconia nigra*), budníčka lesního (*Phylloscopus sibilatrix*), dlaska tlustozobého (*Coccothraustes coccothraustes*) a dále mnoho dutinových ptáků, jako jsou šplhavci (zejména datel černý (*Dryocopus martius*) a strakapoud velký (*Dendrocopos major*)), brhlík lesní (*Sitta europaea*) nebo sýkora koňadra (*Parus major*) a sýkora modřinka (*Cyanistes caeruleus*).

3.3.3. Zemědělská krajina podhůří a středních poloh

Biotop je reprezentován převážně extenzivně využívanými loukami a pastvinami, necelých 5 % plochy je využíváno jako orná půda (Flousek, Gramsz, Telenský 2015). Dále se tento biotop vyznačuje pravidelně rozptýlenými menšími lesíky a drobnými územími se zelení. Právě menší a rozptýlená území v podílu 10–15 % na celkové rozloze krajiny jsou podle Materny (1991) ideální pro druhovou pestrost i početnost.

Z krajinného hlediska se z důvodu způsobu hospodaření zemědělských družstev před rokem 1989 odlišuje velikost plošek mezi českou a polskou stranou (v Polsku existovala možnost drobného soukromého hospodaření). Typickými druhy zemědělské krajiny v podhůří Krkonoš jsou podle Flousek, Gramsz, Telenský (2015) – strnad obecný (*Emberiza citrinella*), pěnice hnědokřídla (*Sylvia communis*), ťuhák obecný (*Lanius collurio*) a skřivan polní (*Alauda arvensis*), který se vyskytuje především v okolí orné půdy. Rozptýlenou zeleň vyhledává dle Flousek, Gramsz, Telenský (2015) káně lesní (*Buteo buteo*), kalous ušatý (*Asio otus*) nebo straka obecná (*Pica pica*). Vzácně se v tomto biotopu vyskytují druhy jako bramborníček černohlavý (*Saxicola rubicola*), pěnice vlašská (*Sylvia nisoria*) či strnad luční (*Emberiza calandra*). V oblastech lomů se můžeme setkat se společenstvy řádu pěvců, případně s výrem velkým (*Bubo bubo*) a kulíkem říčním (*Charadrius dubius*).

3.3.4. Města a vesnice

Většina sídel na obou stranách hranice je situována podél komunikací v podhůří Krkonoš (výjimku představuje např. Špindlerův Mlýn ležící uprostřed hor) a volně přechází do zemědělské krajiny/lesních porostů (Flousek, Gramsz, Telenský 2015). Městská zástavba je příznivá pro výskyt druhů ptáků z důvodu existence parků, zahrad u rodinných domků, zahrádkářských kolonií, sadů, stromořadí nebo živých plotů. Flousek, Gramsz, Telenský (2015)

uvádějí jako typické druhy ptáků pro oblast měst a vesnic v podhůří Krkonoš kosa černého (*Turdus merula*), pěnici (*Sylvia sp.*), špačka obecného (*Sturnus vulgaris*) nebo zvonka zeleného (*Chloris chloris*).

3.3.5. Vodní toky a vodní plochy

Vodní plochy jsou častější na polské straně Krkonoš, nalezneme tu jak početné soustavy rybníků, tak řadu různých mokřadních biotopů. Důležitým prvkem vodních ploch je břehová vegetace, na kterou jsou vázány druhy jako kachna divoká (*Anas platyrhynchos*) nebo strnad rákosní (*Emberiza schoeniclus*).

Na české i polské straně najdeme rozsáhlou síť vodních toků v podobě různých řek, říčků a potoků. Krkonošské hřebeny tvoří hlavní rozvodí Severního a Baltského moře (Flousek, Gramsz, Telenský 2015). Flousek, Gramsz, Telenský (2015) zmiňují různé druhy vázané na vodní toky – skorce vodního (*Cinclus cinclus*), konipase horského (*Motacilla cinerea*), pisíka obecného (*Actitis hypoleucos*) či ledňáčka říčního (*Alcedo atthis*).

3.3.6. Horské louky

Horské louky jsou v Krkonoších specifické tím, že jsou na české straně tvořeny v montánním vegetačním stupni (800-1250 m n. m.) převážně lučními enklávami. Tato luční území obklopená původními lesními plochami vznikala lidskou činností v době osídlování. Proto se i dnes v těchto oblastech setkáme s ne zcela typickými krajinnými prvky, jako jsou kamenné snosy či zídky, které jsou zarostlé keřovou a stromovou vegetací (Flousek, Gramsz, Telenský 2015). Ptačí druhy vázané na biotop horských luk v Krkonoších jsou např. chřástal polní (*Crex crex*), bramborníček hnědý (*Saxicola rubetra*) či linduška lesní (*Anthus trivialis*) (Flousek, Gramsz, Telenský 2015).

3.3.7. Krkonošská tundra

Oblast tundry, která se rozkládá nad alpskou horní hranicí lesa (rozloha pouhých 16 km²) je nejhodnotnější oblastí Krkonoš (Flousek, Gramsz, Telenský 2015). Krkonošská tundra je kombinací severských, středoevropských a alpských společenstev a organismů (KRNAP 2010). Druhy, které jsou vázány na skály a sutě v ledovcových karech, jsou – sokol stěhovavý (*Falco peregrinus*), pěvuška podhorní (*Prunella collaris*) a linduška horská (*Anthus spinoletta*).

Biotop klečových porostů (kosodřevin), tvořený keři borovice kleč (*Pinus mugo*), je vyhledáván různými druhy ptáků, jako jsou pěvuška modrá (*Prunella modularis*), čečetka zimní (*Carduelis flammea*) a budníček větší (*Phylloscopus trochilus*). Subalpínské a alpské trávníky (přesněji smilkové horské trávníky) jsou domovem pro lindušku luční (*Anthus pratensis*)

a skřivana polního (*Alauda arvensis*). V subarktických rašeliništích kromě druhů zmíněných výše u klečových porostů hnízdí poddruh slavíka modráčka (*Luscinia svecica svecica*), bekasina otavní (*Gallinago gallinago*) nebo konipas citronový (*Motacilla citreola*). Pro nejvyšší oblasti nad 1400 m n. m. se sutěmi a strukturními půdami jsou charakteristickými druhy kulík hnědý (*Charadrius mori*) a bělořit šedý (*Oenanthe oenanthe*).

4. Data a metodika

4.1. Použitá data

Hlavními datovými produkty DPZ použitými v práci jsou data Sentinel-2 a PlanetScope. Data o nadmořské výšce jsou reprezentována digitálním modelem terénu EU-DEM v1.0 (anglicky Digital elevation model) s prostorovým rozlišením 25 x 25 m. Model představuje hybridní produkt založený na datech SRTM a ASTER GDEM sloučených metodou váženého průměrování (Copernicus 2022b). Dále byla použita data vymezující hranici krkonošské tundry na obou stranách hranice, data kvadrátů od RNDr. Jiřího Flouska, Ph.D. s výskytem ptačích druhů a bodová data výskytu z nálezové databáze AOPK.

4.1.1. Sentinel-2

Mise Sentinel-2 představuje dvojici optických družic poskytujících multispektrální snímky s vysokým prostorovým, a i časovým rozlišením, které jsou součástí programu Copernicus (program Evropské unie pro DPZ). V současnosti se mise skládá ze soustavy dvou polárních družic na stejné oběžné dráze, které jsou vzájemně fázované v úhlu 180° vůči sobě. V oblasti středních zeměpisných šířek je místo snímáno každé 2 až 3 dny za předpokladu příznivých bezoblačných podmínek. Šířka záběru je 290 km. Produkt L2A s atmosférickou korekcí je k dispozici od března 2017 (tabulka 5). Přehled spektrálních pásem uvádí tabulka 6.

Tabulka 5: Dostupné produkty Sentinel-2

Jméno	Popis	Způsob distribuce	Velikost
Level-1C	Top-Of-Atmosphere reflectances in cartographic geometry	Systematické generování a online distribuce	~600 MB (100 km x 100 km)
Level-2A	Bottom-Of-Atmosphere reflectances in cartographic geometry	Systematické generování a možnost vlastního zpracování (Sentinel-2 Toolbox)	~800 MB (100 km x 100 km)

Zdroj: ESA (2021)

Tabulka 6: Přehled použitých pásem Sentinel-2A a 2B

Pásmo	Popis	Velikost pixelu [m]	Vlnová délka S2A [nm]	Vlnová délka S2B [nm]
B2	Blue	10	496,6	492,1
B3	Green	10	560,0	559,0
B4	Red	10	664,5	665,0
B5	Red Edge 1	20	703,9	703,8
B6	Red Edge 2	20	740,2	739,1
B7	Red Edge 3	20	782,5	779,7
B8	NIR	10	835,1	833,0
BA8	Red Edge 4	20	864,8	864,0
B11	SWIR 1	20	1613,7	1610,4
B12	SWIR 2	20	2202,4	2185,7

Zdroj: ESA (2022a)

4.1.2. PlanetScope

Data PlanetScope od společnosti Planet jsou získávána přibližně ze 130 malých družic (CubeSats) snímajících denně zemský povrch. Zpracovávaná data obsahují čtyři spektrální pásma (tabulka 7), jejich prostorové rozlišení je 3,125 m. Data byla k dalšímu zpracování stažena v páslech o rozměrech 24 x 8 km.

Tabulka 7: Pásma PlanetScope

Pásmo	Popis	Vlnová délka [nm]
B2	Blue	455-515
B3	Green	500-590
B4	Red	590-670
B5	NIR	780-860

Zdroj: ESA (2022b)

4.1.3. Atlasová ptačí data

Data o výskytu ptactva v Krkonoších byla pořízena a poskytnuta RNDr. Jiřím Flouskem, Ph.D. ze Správy KRNAP. Data jsou k dispozici v celkem 471 kvadrátech velikosti strany 1400 x 1400 m na území Česka a Polska včetně podhůří. Každý druh je zaznamenán pomocí ID, rodového a druhového jména, průkazností a dominantním biotopem v jednotlivých kvadrátech. Data byla získána pomocí mapování, s využitím standartní metody druhového seznamu (Pomeroy, Dranzoa 1997; Bibby, Burgess, Hill 2000) s časovým intervalem v délce 60 minut. V Česku je metoda známá jako hodinová metoda a základní postup je následující – v každém kvadrátu jsou po dobu jedné hodiny zaznamenány všechny druhy ptáků v pořadí, jak byly registrovány

(Flousek, Gramsz, Telenský 2015). Flousek, Gramsz, Telenský (2015, s. 46) uvádějí přesný průběh metody: „Mapovatel po dobu přesně 60 minut procházel celou plochu kvadrátu (asi 205 ha), aby při každé kontrole, pokud možno reprezentativně navštívil všechny zastoupené typy prostředí, aktivně vyhledával ptačí druhy a přesně je determinoval. Zjištěné druhy zaznamenával chronologicky (za sebou podle pořadí pozorování) a odděleně do šesti desetiminutových intervalů (druh zjištěný v některé z předcházejících desetiminutovek se již znovu nezaznamenával). Mapovatel tak procházel terénem, zapisoval každý nový druh, po uplynutí každých 10 minut „udělal čáru“ a pokračoval dále. Na konci hodinového mapování získal šest dílčích seznamů druhů, kde v 1. desetiminutovce byly druhy zjištěné nejdříve a naopak v 6. desetiminutovce druhy registrované jako poslední.“. Mapovaná data lze srovnávat mezi kvadráty a jsou též využitelná při použití stejné metody i při mapování v budoucnosti. U každého druhu je evidována průkaznost dle Hagemeijer, Blair (1997). Průkaznost je vysvětlená v příloze 3. Jednotlivé druhy lze rozdělit do třech hlavních kategorií výskytu hnízdění:

- B: Možné hnízdění
- C: Pravděpodobné hnízdění
- D: Prokázané hnízdění

V zájmovém území mapování zahrnující oblast Česka a Polska včetně podhůří byl mapován výskyt celkem 163 ptačích druhů v letech 2012-2014. Kvadráty byly rozděleny dle dominantního biotopu do deseti jednoduchých kategorií, které jsou popsány v kapitole 3. Celkem 55 druhů bylo mapováno ve všech kvadrátech, naopak 108 druhů nebylo mapováno vždy ve všech kvadrátech.

4.2. Metodika

4.2.1. Předzpracování a příprava dat

4.2.1.1. Data Sentinel-2

Pro účely diplomové práce byly v zájmové oblasti vyhledány bezoblačné scény Sentinel-2 za roky 2015-2020. Pro zpracování byla vybrána scéna z 27. srpna 2016 z důvodu, neboť se jednalo o časově nejbližší bezoblačnou scénu pro data o výskytu ptactva pro celé zájmové území. Data byla dostupná pouze pro úroveň zpracování L1C, a proto byla provedena korekce na úroveň L2A s použitím modulu Sen2cor ve verzi 2.8. V dalším kroku byla v softwaru SNAP odebrána pásma s velikostí pixelu 60 m a pásma s velikostí pixelu 20 m byla převzorkována

metodou nejbližšího souseda na 10 m. Následně byl funkcí *Subset* vytvořen výřez obsahující zájmové území ve formátu *tif*.

V diplomové práci byla využita bezoblačná scéna z 27. srpna 2016 – ID scény: *S2A_MSIL1C_20160827T101022_N0204_R022_T33UWS_20160827T101025*.

4.2.1.2. Data PlanetScope

Jediný termín, pro který byly k dispozici bezoblačné pásy systému PlanetScope, byl 30. červen 2019. Jednotlivé pásy byly mozaikovány v ArcGIS PRO do jedné souvislé mozaiky pomocí funkce *Create New Mosaic*. Výřez obsahující zájmové území byl proveden funkcí *Subset* v prostředí SNAP a uložen ve formátu *tif*.

Pro práci bylo zvoleno těchto 18 bezoblačných pásů, které obsahovaly zájmové území, ze dne 30. června 2019, s ID:

<i>20190630_093451_1032</i>	<i>20190630_093555_103d</i>
<i>20190630_093452_1032</i>	<i>20190630_093556_103d</i>
<i>20190630_093453_1032</i>	<i>20190630_093736_0f3f</i>
<i>20190630_093454_1032</i>	<i>20190630_093737_0f3f</i>
<i>20190630_093455_1032</i>	<i>20190630_093738_0f3f</i>
<i>20190630_093551_103d</i>	<i>20190630_093739_0f3f</i>
<i>20190630_093552_103d</i>	<i>20190630_093740_0f3f</i>
<i>20190630_093553_103d</i>	<i>20190630_093741_0f3f</i>
<i>20190630_093554_103d</i>	<i>20190630_093742_0f3f</i>

4.2.2. Výpočet nadmořské výšky a spektrálních indexů

Pro výpočet průměrné nadmořské výšky jednotlivých kvadrátů pokrývajících zájmové území byl použit digitální model reliéfu (EU-DEM v1.0) z programu Copernicus. Hodnoty průměrné nadmořské výšky byly vypočteny pomocí funkce *Zonal Statistics*. Výsledky byly následně vyexportovány pro další analýzu do souborů *shp* a *xlsx*.

V dalším kroku byly provedeny výpočty průměrných hodnot spektrálních indexů (NDVI, NDWI, SAVI a SR) pro jednotlivé kvadráty z dat Sentinel-2 a PlanetScope v ArcGIS Pro s využitím funkce *zonal*. Výpočet NDWI dle (Gao 1996) zahrnuje použití spektrálního pásma SWIR. Jelikož data PlanetScope nemají požadované pásmo SWIR nebylo možné provést výpočet NDWI.

4.2.3. Klasifikace

Dalšími parametry, které byly analyzovány, jsou procentuální podíly jednotlivých kategorií land cover v kvadrátu. Pro tvorbu land cover území byla zvolena metoda řízené klasifikace RF. V úvodním kroku klasifikace RF byla vytvořena legenda. Vybrané zájmové území bylo rozděleno z důvodu výskytu specifických biotopů v území tundry, na které jsou vázány druhy jako tetřevka obecná (*Lyrurus tetrix*) nebo linduška horská (*Anthus spinoletta*), na dvě části – oblast krkonošské tundry a zbylé části území Krkonoš. Pro oblast tundry byla vytvořena vlastní legenda s pěti klasifikačními třídami (tabulka 8). Antropogenní objekty, jako horské chaty, asfaltové a kamenné cesty, byly před klasifikací odmaskovány pomocí vrstvy, která byla vytvořena vektorizací nad ortofototem. Při tvorbě legendy byly vyzkoušeny neřízené klasifikace ISODATA a K-Means s cílem otestovat, jak se jednotlivé pixely shlukují na základě spektrální podobnosti.

Tabulka 8: Legenda pro oblast tundry s počtem trénovacích bodů a definicí kategorií

Tundra	Počet bodů	Popis kategorie
<i>Horská louka</i>	<i>410</i>	<i>Alpínské a subalpínské přírodní travní porosty</i>
<i>Kamenná moře</i>	<i>150</i>	<i>Kamenná moře, holé skály</i>
<i>Keříčková vegetace</i>	<i>115</i>	<i>Nízká keříčková vegetace: vřes, borůvky, brusinky</i>
<i>Kosodřevina</i>	<i>560</i>	<i>Alpské křoviny s výškou do 3 m</i>
<i>Vodní plocha</i>	<i>15</i>	<i>Přírodní a umělé vodní plochy (ledovcová jezera, rašelinná jezírka)</i>
<i>Celkem</i>	<i>1250</i>	

Zdroj: Vlastní tvorba

Dále byly provedeny v ENVI testy separability trénovacích množin pro data Sentinel-2 a PlanetScope. Výsledky testu se mohou pohybovat v intervalu 0 až 2, pokud je hodnota $\geq 1,9$ lze považovat klasifikační třídy za správně definované (L3HARRIS 2022a). Při výpočtu pro data Sentinel-2 byly zjištěny hodnoty nižší než 1,9 pro kategorie orná půda a trvalý travní porost (1,73), keříčková vegetace a horská louka (1,8).

U dat PlanetScope byly zjištěny hodnoty nižší než 1,9 u následujících kombinací kategorií – trvalý travní porost a orná půda (0,39), horské louky a keříčková vegetace (1,25), holiny-mlaziny a trvalý travní porost (1,21), holiny-mlaziny a orná půda (1,54), keříčková vegetace a kosodřevina (1,66), listnatý a smíšený les a orná půda (1,77), listnatý a smíšený les a trvalý travní porost (1,795), jehličnatý les a listnatý a smíšený les (1,87), jehličnatý les a holiny-mlaziny (1,88), trvalý travní porost a zástavba (1,88). Výsledky testů jsou k dispozici v příloze

4 a 5. Pro zbylé části zájmového území byla využita klasifikační legenda zahrnující sedm základních tříd land cover – tabulka 9. Obrázky všech klasifikačních tříd jsou v příloze 6.

Tabulka 9: Legenda pro oblast zbylé části území Krkonoš s počtem trénovacích bodů a s popisem kategorií

Zbylé části území	Počet bodů	Popis kategorie
<i>Jehličnatý les</i>	<i>400</i>	<i>Vegetace vyšší než 5 m, s převahou jehličnatých dřevin</i>
<i>Listnatý a smíšený les</i>	<i>270</i>	<i>Vegetace vyšší než 5 m s převahou listnatých dřevin a smíšených dřevin, okrajová liniová vegetace</i>
<i>Holiny a mlaziny</i>	<i>140</i>	<i>Vegetace nižší než 5 m, oblasti s mlazinou, paseky, kalamitní holiny</i>
<i>Trvalé travní porosty podhůří a středních poloh</i>	<i>290</i>	<i>Obdělávané louky a pastviny, trvalé kultury, městská zeleň</i>
<i>Orná půda</i>	<i>100</i>	<i>Trvale obhospodařovaná orná půda, holá půda</i>
<i>Vodní plocha</i>	<i>15</i>	<i>Přírodní a umělé vodní plochy a vodní toky (řeky, přehrady, rybníky, jezera)</i>
<i>Zástavba</i>	<i>35</i>	<i>Městská zástavba, průmyslové a obchodní areály, dopravní infrastruktura, prostory těžby nerostných surovin, staveniště</i>
<i>Celkem bodů</i>	<i>1250</i>	

Zdroj: Vlastní tvorba

Sběr 1250 trénovacích bodů pro obě části zájmového území probíhal ručně nad ortofoto z roku 2016 v Česku a z roku 2018 v Polsku. V případě krkonošské tundry byla pro lokalizaci třídy keříčkové vegetace využita data z terénního průzkumu. Jednotlivé trénovací pixely byly z důvodu nepřekrývání testovány v n-dimenzionálním prostoru. Celkový počet bodů pro jednotlivé kategorie odpovídá odhadu procentuálního zastoupení jednotlivých kategorií krajinného pokryvu z legendy. Thanh Noi, Kappas (2017) uvádějí, že velikost trénovacího vzorku by měla tvořit zhruba 0,25 % celkového počtu pixelů ve scéně.

Vyhodnocení přesnosti klasifikace bylo provedeno s využitím 2401 validačních bodů v obou zájmových územích dle metody Foody (2009). Počet bodů n byl získán výpočtem z následujícího vzorce. Výsledná hodnota klasifikace by měla odpovídat 95% intervalu spolehlivosti.

$$n = \frac{z_{\alpha/2}^2 P(1 - P)}{h^2}$$

$$n = \frac{1,96 * 0,5 * (1 - 0,5)}{0,02^2}$$

$$n = 2401$$

Body byly vygenerovány nad klasifikovaným rastrem v ArcGIS Pro funkcí *Create Accuracy Assessment Points* s nastavením *STRATIFIED_RANDOM*, která v rámci každé třídy náhodně rozmístí body, a kde počet bodů ve třídě odpovídá její relativní rozloze.

4.2.4. Práce v Google Earth Engine

Řízená klasifikace metodou RF byla provedena v cloudovém prostředí GEE. Pro klasifikaci tundry bylo v obou měřítkách experimentálně použito v GEE následující nastavení klasifikátoru:

ee.Classifier.smileRandomForest(1200, 4, 1, 1, 9, 1):

Počet stromů v lese: 1200

Počet proměnných v každém stromě: 4

Minimální populace listu: 1

Část prvků v každém stromě: 1

Větvení: 9

Náhodnost: 1

Pro zbylé části území bylo v obou měřítkách experimentálně použito nastavení klasifikátoru:

ee.Classifier.smileRandomForest(1200, null, 1, 0,5, null, 0):

Počet stromů v lese: 1200

Počet proměnných v každém stromě: odmocnina z počtu vstupních proměnných

Minimální populace listu: 1

Část prvků v každém stromě: 0,5

Větvení: bez limitu

Náhodnost: 0

Detailní skripty obsahující komentáře jsou k dispozici na konci práce v části skriptů.

Z důvodu odfiltrování jednotlivých osamocených pixelů, které by mohly negativně ovlivnit výsledky vypočtených strukturálních charakteristik, bylo přistoupeno k filtraci obrazu pomocí většinového filtru. Většinový filtr pracuje na principu zachování hodnoty pixelu, pokud jsou v jeho okolí dva pixely se stejnou třídou. Pokud pixely k dispozici nejsou, výsledná třída je zvolena podle většiny. Ukázka použití filtru ve skriptech je uvedena níže:

// Výpočet velikosti plošek, maximální velikost okolí byla zvolena dva pixely

var patchsize = classified.connectedPixelCount(2, false);

// Aplikace většinového filtru

var majorityfilter = classified.focal_mode();

// Aktualizace obrazu pomocí většinového filtru, kde je velikost plošek malá

```
var filtered = classified.where(patchsize.lt(2),majorityfilter);
```

Klasifikační výstupy oblasti tundry a zbylé části zájmového území byly následně spojeny do jedné výsledné vrstvy funkcí *Mosaic* v ArcGIS Pro.

4.2.5. Porovnání s dostupnými datovými produkty

Výsledné klasifikace land cover byly porovnány s produktem CLC 2018. Ke srovnání zájmového území s kvadráty byl využit výpočet rozloh jednotlivých tříd a byla vytvořena překryvová mapa. Jako agregační klíč legendy tříd CLC 2018 do legendy diplomové práce posloužila tabulka 10. Vrstvy N2K 2018 a VMB NATURA 2000 byly porovnány slovně v rámci diskuze (kapitola 6).

Tabulka 10: Převodní tabulka tříd CLC 2018 do legendy klasifikace

CLC 2018 kód	CLC 2018 Třída	Nový kód	Nová třída
112	Nesouvislá městská zástavba	7	Zástavba
121	Průmyslové a obchodní areály	7	Zástavba
122	Silniční a železniční síť s okolím	7	Zástavba
131	Oblasti současné těžby surovin	7	Zástavba
141	Městské zelené plochy	4	Trvalý travní porost
142	Sportovní a rekreační plochy	4	Trvalý travní porost
211	Nezavlažovaná orná půda	5	Orná půda
231	Louky a pastviny	4	Trvalý travní porost
242	Směsice polí, luk a trvalých plodin	4	Trvalý travní porost
243	Zemědělské oblasti s přirozenou vegetací	4	Trvalý travní porost
311	Listnaté lesy	2	Listnaté a smíšené lesy
312	Jehličnaté lesy	1	Jehličnaté lesy
313	Smíšené lesy	2	Listnaté a smíšené lesy
321	Přírodní louky	9	Horská louka
322	Stepi a křoviny	8	Kosodřevina
324	Nízký porost v lese	3	Holiny a mlaziny
332	Skály	10	Kamenné moře
333	Spáleniště	10	Kamenné moře
412	Rašeliniště	6	Vodní plocha
512	Vodní plochy	6	Vodní plocha

Zdroj: vlastní tvorba

4.2.6. Výpočet strukturálních parametrů

Dalším krokem bylo vypočtení strukturálních parametrů (krajinných metrik) pro všech 471 kvadrátů na úrovni krajiny. Na základě studia literatury a rešerše byly nalezeny metriky s předpokladem korelace. Nalezené metriky jsou na úrovni krajiny (tabulka 11) a třídy (tabulka 12).

Tabulka 11: Doporučené krajinné metriky dle literatury na úrovni krajiny

Název a typ	Zkratka	Vzorec	Popis
Počet plošek (Number of patches)	NP	$NP = N$	Počet plošek souvisí s fragmentací krajiny, velmi vysoký počet plošek bude spíše v městské fragmentované krajině, dále velmi vysoký počet plošek můžeme očekávat v zemědělské krajině středních nadmořských výšek. Rostoucí počet plošek lze předpokládat také s podrobnějším prostorovým rozlišením či podrobnější minimální mapovací jednotkou. Lze vypočítat na úrovni krajiny i třídy.
Celková délka hranic (Total edge)	TE	$TE = E$	Metrika je interpretovatelná jako součet všech hranic všech krajinných tříd v kvadrátu, lze předpokládat, že fragmentovanější krajina bude v oblastech lesních porostů či zemědělské krajin. Fragmentovanější krajina má větší potenciál pro druhovou bohatost. Délka je uváděna v metrech.
Průměrná velikost plošky (Mean patch size)	MPS	$MPS = \frac{A}{N}$	Průměrná velikost plošky, důležitý parametr, avšak závislý na měřítku. Metriku lze vypočítat na úrovni krajiny a třídy. Může být užitečným ukazatelem na úrovni obou tříd. Metrika měla v Morelli, Benedetti, Šimová (2018) vysokou negativní korelaci s počtem ptáčích druhů v krajinných typech orné půdy a smíšené krajiny. V těchto typech krajiny bude velmi dobře reflektovat podmínky pro výskyt. Velikost je uváděna v hektarech.
Bohatost plošek (Patch richness)	PR	Počet tříd	Počet krajinných kategorií ve čtverci dává představu o biodiverzitě. V literatuře Morelli, Benedetti, Šimová (2018) měla metrika vysokou pozitivní korelaci ve smíšených oblastech a v oblastech s ornou půdou.
Shannonův index diverzity (Shannon's diversity index)	SHDI	$SHDI = \sum_{i=1}^m P_i * \ln P_i$ <i>p_i = podíl rozlohy třídy i ve studované krajině</i>	Shannonův index diverzity dosahuje vyšší hodnoty s větším počtem krajinných tříd anebo s rovností plošného zastoupení krajinných tříd (pokud je hodnota 0, krajina je tvořena pouze jednou ploškou o jedné třídě). Nejmenší hodnoty má v homogenních oblastech, které může například reprezentovat horská louka. Rozsah indexu SHDI je ≥ 0 .
Simpsonův index diverzity (Simpson's diversity index)	SIDI	$SIDI = 1 - \sum_{i=1}^m P_i^2$	Hodnota 0 pro krajinu s jednou ploškou (žádná diverzita), hodnota 1 pro krajinu, kde se zvyšuje počet různých typů plošek. Simpsonův index diverzity je méně citlivý na přítomnost minoritní kategorií oproti Shannonovu indexu. Rozsah indexu je $0 \leq SIDI < 1$.

Zdroj: vlastní tvorba, popis metrik vychází z McGarigal (2015)

Výpočet metrik lze provést různými způsoby – FRAGSTATS (umožňuje provádět výpočty jak s vektorovými, tak rastrovými daty), Patch Analyst (plugin pro ArcGIS verze 10.x.), V-LATE (jednoduché rozšíření též pro ArcGIS) či s použitím balíčku *landscapemetrics*

v prostředí R, který byl zvolen z důvodu snadného výpočtu metrik pro jednotlivé kvadráty a následný export výsledků.

Tabulka 12: Doporučené krajinné metriky dle literatury na úrovni třídy

Název a typ	Zkratka	Vzorec	Popis
Rozloha třídy (Class Area)	CA	$CA = \sum_{j=1}^n a_{ij}$ a_{ij} = rozloha plošky třídy i n = počet plošek třídy n	Celková rozloha krajinné třídy.

Zdroj: Vlastní tvorba, popis metriky vychází z McGarigal (2015)

Kromě předpokládaných metrik dle studia literatury proběhl výpočet dalších dostupných metrik z R balíčku na úrovni krajiny – přehled vypočtených metrik je v příloze 7. Detailní popis a vzorce použitých metrik jsou v příručce R balíčku *landscapemetrics* (Landscape Metrics for Categorical Map Patterns), verze 1.5.4. Jako vstupy do výpočtu byly použity klasifikační výstupy dat Sentinel-2, PlanetScope a vektorová vrstva s kvadráty. Skript využitý pro výpočet krajinných metrik je k dispozici na konci práce v sekci skripty.

4.2.7. Analýza a výběr druhů ptactva

V posledním kroku proběhlo vyhodnocení dat popisujících jednotlivé kvadráty a výběr druhů pro analýzu (celkem bylo vybráno 23 druhů ptactva). Hlavním klíčem pro výběr druhu byl výskyt v biotopových kategoriích kvadrátů (celkem bylo deset kategorií). První skupinou byly druhy, které se vyskytují v jednom až devíti kvadrátech (devět druhů) (tabulka 13), druhou skupinou byly druhy, u kterých je předpokládán vztah ke krkonošské tundře (deset druhů) (tabulka 14). Třetí skupina byla tvořena druhy ptactva, které se vyskytují ve všech biotopových kategoriích (čtyři druhy) (tabulka 15). Při výběru bylo nutné provést kontrolu, zda se nejedná o druhy sympatrické, zavlečené, případně chované nebo jejichž přirozený výskyt je v jiných biotopových podmínkách.

Tabulka 13: Přehled vybraných druhů pro analýzu, výskyt byl mapován v 1-9 biotopových kategoriích kvadrátů

Výskyt 1-9 kvadrátů	Biotopové preference
<i>bekasina otavní (Gallinago gallinago)</i>	Oblasti podhůří a nad horní hranici lesa: Břehová vegetace rybníků a nádrží, podmáčené a vlhké nekosené horské louky, bylinné porosty subarktických rašelinišť.
<i>bělořit šedý (Oenanthe oenanthe)</i>	Podhůří až hřebeny: suché kamenité plochy se sporou vegetací a lomy v podhůří, horské louky s kamennými snosy, alpinské trávníky s mozaikou sutí a kamenitá suťová pole na nejvyšších vrcholech.
<i>jestřáb lesní (Accipiter gentilis)</i>	Výskyt od podhůří do cca 800 m, smíšené a smrkové lesní porosty; izolované lesíky v zemědělsky obhospodařované krajině.
<i>kos horský (Turdus torquatus)</i>	Výskyt od středních poloh cca 760 m po nejvyšší partii. Flousek, Gramsz, Telenský (2015) uvádí, že 70 % populace má habitat horské smrkové lesy na okraji lučních enkláv a oblasti při horní hranici lesa, zhruba 30 % populace v porostech kleče i s významností jednotlivých keřů.
<i>kulišek nejmenší (Glaucidium passerinum)</i>	Střední polohy v rozmezí 600-1000 m, nalezen však okolo horní hranice lesa 1200 m. Smrkové porosty různého věku a různou mozaikou (světliny, mýtiny, luční enklávy). Vzácně v izolovaných lesících v zemědělské krajině. Pro výskyt je významná přítomnost dutin ve stromech.
<i>lejsek černohlavý (Ficedula hypoleuca)</i>	Výskyt v celé výškové škále od podhůří až po horní hranici lesa, nejvýznamnější polohy jsou kolem 800 m. Preferuje rozptýlenou zeleň ve městech, vesnicích a zemědělské krajině. V listnatých lesích preference buku, smíšené a smrkové lesy, horské luční enklávy. Důležité je zastoupení dutin, které mohou být přírodní nebo umělé.
<i>lejsek malý (Ficedula parva)</i>	Výskyt ve vhodných biotopech v středních polohách kolem 800 m, nalezen však i výše (např. až 890 m). Starší a pestré bukové nebo smrko-bukové lesy s dutinami a výskytem mrtvého dřeva.
<i>lejsek šedý (Muscicapa striata)</i>	Nižší až střední polohy celého území, nejčastěji do 800 m, ojediněle nalezen kolem 1200 m (nejvyšší nalezen v hnízdím období i v oblasti subalpínského stupně 1340 m). Městská krajina (zahrady, parky, hřbitovy, stromořadí). Zemědělská krajina s rozptýlenou zelení, listnaté, smíšené a smrkové lesy, horské luční enklávy.
<i>sýc rousný (Aegolius funereus)</i>	Střední a vyšší polohy až po horní hranici lesa, v polohách pod 700 m je limitován přítomností predátora puštika obecného (<i>Strix aluco</i>). Smíšené a smrkové porosty se stejným věkem s přítomností mýtin, holin a lučních enkláv, pro výskyt potřeba dutiny (přírodní nebo umělé).

Zdroj: Vlastní tvorba, biotopové preference dle Flousek, Gramsz, Telenský (2015)

Korelace mezi jednotlivými metrikami a druhy/skupinami ptactva byla vypočtena pomocí funkce *corr* v prostředí python z knihovny *pandas*. K výpočtu byl použit Pearsonův korelační koeficient. Hodnoty výskytu druhů byly vyjádřeny hodnotami 0-1. Pro výpočet Pearsonova

korelačního koeficientu v kvadrátech zájmového území byly použity celkové počty druhů ptactva a počty pěvců v jednotlivých kvadrátech.

Tabulka 14: Přehled vybraných druhů ptactva pro analýzu, výskyt je vázán na biotop krkonošské tundry

Výskyt vázán na tundru	Biotopové preference
<i>datlík tříprstý (Picoides tridactylus)</i>	Hlavní poloha výskytu 1100-1300 m ve strukturně pestrých smrkových porostech u horní hranice lesa.
<i>kalous ušatý (Asio otus)</i>	Výskyt převážně na české straně hor, nejvýše mapován v polohách kolem 1100 m. Města, vesnice a zemědělská krajina s rozptýlenou vzrostlou zelení, smíšené porosty sousedící s lučními enklávami.
<i>krutihlav obecný (Jynx torquilla)</i>	Převážně nižší polohy do 500 m na obou stranách pohoří. Suchá, osluněná stanoviště s rozptýlenou zelení v zemědělské krajině (aleje, staré sady, zahrady), vyhledává přírodní nebo umělé dutiny.
<i>linduška horská (Anthus spinoletta)</i>	Nejvyšší polohy nad 1270 m, strmé svahy ledovcových karů, suťová pole alpských vrcholů. Méně často v oblasti tundry s jednotlivými keři kleče a rašeliništi.
<i>pěvuška podhorní (Prunella collaris)</i>	Nejvyšší polohy nad 1280 m, skalní srázy, kamenná pole ledovcových karů a nejvyšších vrcholů.
<i>puštík obecný (Strix aluco)</i>	Podhůří na obou stranách hor, hlavní polohy kolem 800 m, místy kolem 1200 m. Krajiny podhůří s městy a vesnicemi (parky, hřbitovy, stromořadí, půdy). Zemědělská krajiny s rozptýlenou vegetací, smrkové, smíšené a listnaté lety. Nutnost přirozených nebo umělých dutin.
<i>slavík modráček tundrový (Luscinia svecica svecica)</i>	Od podhůří (rybníků) až po nejvyšší partie (rašeliniště). Porosty rákosin na březích vodních ploch, klečové porosty na subarktických rašeliništích a podmáčených subalpínských trávnících.
<i>sokol stěhovavý (Falco peregrinus)</i>	Obě strany hor od 1100 m do 1450 m, při lovu výskyt i v oblastech vrcholových rašelinišť a alpských trávníků (1550 m). Izolovaná skaliska v lesích, skalní stěny ledovcových karů v závěrech horkých údolí.
<i>tetřívek obecný (Lyrurus tetrix)</i>	Vyskytuje se ve výšce od 850 m (vzácně mapován i kolem 620 m) do 1500 m. Luční enklávy, holiny, otevřené plochy v oblasti horských smrčín.
<i>výr velký (Bubo bubo)</i>	Výskyt na obou stranách pohoří do výšky 700 m, v hnízdním období zaznamenán i ve výšce 1150 m. Lomy (opuštěné i provozované) v zemědělské krajině nebo v lesích na úpatí hor na okrajích obcí, skalní výstupy v bukových, smíšených nebo smrkových porostech, méně často na mýtinách, okrajích lesů a luk strmých údolí.

Zdroj: Vlastní tvorba, biotopové preference dle Flousek, Gramsz, Telenský (2015)

Tabulka 15: Přehled vybraných druhů ptactva pro analýzu, výskyt byl mapován ve všech dílčích biotopových kategoriích kvadrátů

Výskyt mapován ve všech kvadrátech	Biotopové preference
<i>hýl rudý (Carpodacus erythrinus)</i>	Výskyt od podhůří (340 m) po hřebenové partie (1430 m) Klečové porosty, rozptýlené plošky neobhospodařovaných horkých luk, vlhké okolí vodních ploch s lemovými porosty, ojediněle zarůstající holiny nebo rozptýlená zeleň v obcích.
<i>konipas horský (Motacilla cinerea)</i>	Celé území od podhůří po nejvyšší partie (jihozápadní svahy Sněžky), hlavní těžiště však mezi 500-900 m. Vodní toky ve městech a vesnicích, smíšené a smrkové lesy, horské louky, holiny, hřebenová rašeliniště, ledovcové kary a svahy.
<i>králíček ohnivý (Regulus ignicapilla)</i>	Od podhůří po horní hranici lesa (1300 m), nejvíce ve středních polohách 600-800 m. Smrkové, smíšené i listnaté lesní porosty, méně izolované lesíky v zemědělské krajině a vzrostlá zeleň v sídlech.
<i>krkavec velký (Corvus corax)</i>	Celé sledované území od podhůří po horní hranici lesa, v případě lovu i hřebeny. Izolované lesíky v zemědělské krajině, smíšené a smrkové lesy s holinami a lučními enklávami – hnízdění na stromech, skalních výstupech, stožárech elektrického vedení.

Zdroj: Vlastní tvorba, biotopové preference dle Flousek, Gramsz, Telenský (2015)

Dalším krokem byl výběr druhů pro sestavení regresního modelu, jehož výstupem byla pravděpodobnost výskytu v kvadrátu. Celkem bylo vybráno šest druhů ptactva (tabulka 16), které dle výsledků významně korelovaly s analyzovanými krajinnými charakteristikami. Podmínkou pro výběr charakteristiky byla alespoň slabá korelace. Další podmínkou bylo, že jednotlivé metriky mezi sebou nesměly mít korelace vyšší než velmi slabé (ošetřeno pomocí korelační matice jednotlivých metrik Pearsonova korelačního koeficientu při výběru – elektronické přílohy 1 a 2). Regresní model byl vypočten funkcí *Generalized Linear Regression* v toolboxu *Spatial Statistics* v ArcGIS Pro. Typ modelu vysvětlované proměnné byl zvolen binární a hodnoty výskytu druhů byly vyjádřeny hodnotami 0-1.

Tabulka 16: Přehled vybraných druhů pro GLR a vysvětlujících proměnných

Druh	Vybrané metriky (vysvětlující proměnné) pro binární regresní model
<i>kos horský (Turdus torquatus)</i>	Nadmořská výška NP Jehličnatý les Listnatý a smíšený les Holiny a mlaziny Trvalé travní porosty Kosodřevina
<i>lejsek černohlavý (Ficedula hypoleuca)</i>	Nadmořská výška TE Listnatý a smíšený les Holiny a mlaziny Orná půda Horská louka
<i>lejsek šedý (Muscicapa striata)</i>	Nadmořská výška NP Listnatý a smíšený les Trvalé travní porosty Orná půda Kosodřevina
<i>puštík obecný (Strix aluco)</i>	Nadmořská výška Listnatý a smíšený les Holiny a mlaziny Trvalé travní porosty Orná půda Kosodřevina
<i>sýc rousný (Aegolius funereus)</i>	Nadmořská výška MPS Planet_Jehličnatý les Planet_Holiny a mlaziny Planet_Trvalé travní porosty Planet_Orná půda
<i>tetřívka obecná (Lyrurus tetrix)</i>	Nadmořská výška MPS Holiny a mlaziny Kosodřevina

Zdroj: Vlastní tvorba, pozn: v případě spektrálních, tematických a strukturálních metrik, pokud není uvedeno, že se jedná o metriku získanou z PlanetScope (popisek Planet), je metrika získána z dat Sentinel-2.

Výsledky jsou na české straně proloženy bodovými daty o výskytu konkrétních druhů ptactva z nálezové databáze Agentury ochrany přírody a krajiny. V posledním kroku byla z hodnot reziduí vypočtena hodnota Moranova I kritéria (funkce *Global Moran's I* v toolboxu *Spatial Statistics* v ArcGIS Pro). Pro otestování prostorové autokorelace s nastavením prostorového vztahu *K nearest neighbors* s nastaveným počtem sousedů na hodnotu osm (O'Sullivan, Unwin 2010).

5. Výsledky

V následující kapitole jsou rozebrány všechny výsledky dle jednotlivých kategorií (topografické, spektrální, tematické, strukturální) charakteristik se zaměřením na ptačí druhy. Hodnoty Pearsonova korelačního koeficientu jsou kategorizovány dle tabulky 4. Dalším výsledkem jsou regresní modely a pravděpodobnosti výskytu vybraných druhů. Všechny vypočtené charakteristiky jsou k dispozici v elektronických přílohách 3 a 4.

5.1. Topografická charakteristika

První vypočtenou charakteristiku představovala topografická proměnná, která je v práci reprezentována průměrnou nadmořskou výškou v kvadrátech (mapové znázornění je v příloze 8). Vypočtené hodnoty Pearsonova korelačního koeficientu mezi průměrnou nadmořskou výškou a jednotlivými druhy/skupinami druhů ptactva jsou v příloze 11. Mezi charakteristikami byla nalezena silná záporná korelace u proměnných počet druhů v kvadrátu (vyjadřující druhovou rozmanitost) (-0,72) a počet druhů řádu pěvci (-0,70). Dle výsledků výrazně ovlivňuje celkovou druhovou rozmanitost a výskyt řádu pěvců výškový gradient, kde v kvadrátech s vyšší nadmořskou výškou klesá celkový počet nalezených druhů ptactva a celkový počet druhů řádu pěvci.

Jednotlivé druhy, jejichž výskyt je vázán na biotop tundry (tabulka 14), měly převážně slabé až střední korelace mezi výskytem a průměrnou nadmořskou výškou, což lze předpokládat, protože oblast tundry představuje nejvyšší partii Krkonoš. Výjimku tvořily druhy datlík tříprstý (*Picoides tridactylus*) a kalous ušatý (*Asio otus*), pro něž byly vypočteny pouze velmi slabé korelace. Nejvyšší kladná silná korelace byla zaznamenána u kosa horského (*Turdus torquatus*) (0,70) (většina populace má těžiště nad 1000 m n. m.) a tetřívka obecného (*Lyrurus tetrix*) (0,68). Naopak silná záporná korelace byla vypočtena v případě lejska šedého (*Muscicapa striata*) (-0,64). Střední korelace byly nalezeny u druhů lejsek černohlavý (*Ficedula hypoleuca*) (-0,58), puštík obecný (*Strix aluco*) (-0,44), linduška horská (*Anthus spinoletta*) (0,41) a sokol stěhovavý (*Falco peregrinus*) (0,40). Slabé kladné korelace (interval hodnot 0,20–0,39) byly nalezeny u hýla rudého (*Carpodacus erythrinus*), pěvušky podhorní (*Prunella collaris*), slavíka modráčka tundrového (*Luscinia svecica svecica*) a sýce rousného (*Aegolius funereus*). Naopak slabé záporné korelace (interval hodnot -0,20 – -0,39) byly zjištěny u výra velkého (*Bubo bubo*), krkavce velkého (*Corvus corax*) a krutihlava obecného (*Jynx torquilla*). U ostatních druhů ptactva byly hodnoty korelací velmi slabé.

5.2. Spektrální proměnné (indexy)

Další charakteristiky (spektrální, tematické a strukturální) byly vypočteny z dat dvou prostorových měřítek. Pokud budou uvedeny v následujícím textu v závorce dvě hodnoty korelací, první hodnota odpovídá datům Sentinel-2 z 27. 8. 2016, druhá hodnota PlanetScope z 30. 6. 2019.

Pro jednotlivé kvadráty proběhl nejprve výpočet průměrných hodnot spektrálních indexů NDVI, NDWI (pouze u dat ze Sentinel-2), SAVI a SR (mapové znázornění výsledků je v přílohách 9 a 10). Hodnoty Pearsonova korelačního koeficientu s jednotlivými druhy/skupinami druhů a spektrálními indexy jsou k dispozici v příloze 11.

V případě korelací počtu druhů s indexy NDVI byly nalezeny hodnoty střední záporné korelace (-0,44, -0,43). U NDWI střední záporné korelace (-0,57), v rámci SAVI také střední záporné korelace (-0,44, -0,43) a u SR slabé záporné korelace (-0,28, -0,28). Při výpočtu stejných indexů v případě počtu pěvců byly hodnoty obdobné nebo se minimálně lišily od hodnot výše. V případě výsledků korelací spektrálních indexů s počtem druhů vyšly při použití dat Sentinel-2 nepatrně vyšší hodnoty korelací u indexů NDVI a SAVI.

Hodnoty výsledků Pearsonova korelačního koeficientu mezi výskytem jednotlivých druhů a spektrálními indexy (NDVI, SAVI a SR) v obou měřítkách byly velmi slabé a slabé (<0,40). Většina hodnot oscilovala v mezích 0,05 až 0,20. Mimo oscilovaný interval hodnot byly korelace výraznější (avšak stále slabé) u druhů – kulíšek nejmenší (*Glaucidium passerinum*), lejsek malý (*Ficedula parva*), lejsek šedý (*Muscicapa striata*) a sýc rousný (*Aegolius funereus*). Z hlediska měřítka měla podrobnější data vyšší hodnoty korelací v případě lejska malého (*Ficedula parva*) (NDVI, SAVI, SR), lejska šedého (*Muscicapa striata*) (NDVI, SAVI, SR). Střední kladnou korelaci s NDWI (0,42) měl sýc rousný (*Aegolius funereus*), velmi slabé kladné korelace druhy kos horský (*Turdus torquatus*) (0,29) a tetřívka obecná (0,29) (*Lyrurus tetrix*). Střední záporná korelace byla zjištěna u lejska šedého (*Muscicapa striata*) (-0,40) a velmi slabá záporná korelace u krutihlava obecného (*Jynx torquilla*) (0,27), výra velkého (*Bubo bubo*) (0,27) a puštíka obecného (*Strix aluco*) (0,24).

5.3. Tematické proměnné (land cover)

V práci byly vytvořeny celkem čtyři klasifikace (data Sentinel-2 a PlanetScope) pro zájmová území krkonošské tundry a zbylé části území Krkonoš v prostředí GEE s využitím metody RF. Hodnocení přesností klasifikací proběhlo výpočty chybových matic a kappa indexu. Výsledné mapové výstupy jsou k dispozici v přílohách 12 a 13.

Tabulka 17 zobrazuje chybovou matici pro klasifikaci tundry z dat Sentinel-2. Celková přesnost klasifikace byla 78 %, hodnota kappa indexu 0,62. Nejnižší uživatelská (27 %) a zpracovatelská (40 %) přesnost byla vypočtena u kategorie keříčkové vegetace. Nejvyšší uživatelská (87 %) a zpracovatelská (86 %) přesnost byla nalezena v kategorii kosodřeviny. Třída kosodřevina má největší rozlohu v rámci tundry. Uživatelské přesnosti nad 70 % dosáhly také třídy horská louka a kamenné moře.

Tabulka 17: Chybová matice klasifikace oblasti tundry Sentinel-2 z 27. 8. 2016

	Horské louky	Kamenná moře	Keříčková vegetace	Kosodřevina	Vodní plocha	Celkem	Uživatelská přesnost
Horské louky	507	12	40	92	1	652	0,78
Kamenná moře	7	78	3	20	0	108	0,72
Keříčková vegetace	44	10	55	91	1	201	0,27
Kosodřevina	124	18	40	1248	5	1435	0,87
Vodní plocha	0	1	0	1	3	5	0,6
Celkem	682	119	138	1452	10	2401	
Zpracovatelská přesnost	0,75	0,66	0,4	0,86	0,3		0,78
Kappa index	0,62						

Zdroj: Vlastní tvorba

Tabulka 18 zobrazuje chybovou matici pro klasifikaci z dat PlanetScope pro oblast tundry. Celková přesnost klasifikace byla 77 %, kappa index 0,59. Nejnižší uživatelskou (17 %) a zpracovatelskou (32 %) přesnost měla kategorie keříčkové vegetace. Nejvyšší uživatelskou (90 %) a zpracovatelskou přesnost (90 %) měla kategorie kosodřeviny.

Tabulka 18: Chybová matice klasifikace oblasti tundry PlanetScope z 30. 6. 2019

	Horské louky	Kamenná moře	Keříčková vegetace	Kosodřevina	Vodní plocha	Celkem	Uživatelská přesnost
Horské louky	546	20	60	126	2	753	0,72
Kamenná moře	6	84	1	8	2	101	0,83
Keříčková vegetace	47	11	45	151	0	254	0,17
Kosodřevina	84	4	32	1167	2	1289	0,9
Vodní plocha	0	0	0	0	4	4	1
Celkem	682	119	138	1452	10	2401	
Zpracovatelská přesnost	0,79	0,7	0,32	0,8	0,4		0,77
Kappa index	0,59						

Zdroj: Vlastní tvorba

Dále proběhly dvě klasifikace pro zbylé části území Krkonoš z dat Sentinel-2 a PlanetScope, kde lepší celkové přesnosti bylo dosaženo u dat s nižším prostorovým rozlišením Sentinel-2 78 % (tabulka 19), hodnota kappa indexu byla 0,71. Nejnížší uživatelskou přesnost má kategorie holiny a mlaziny (42 %), zpracovatelskou kategorie zástavby (51 %). Nad 90 % uživatelské přesnosti mají kategorie jehličnatého lesa a trvalých travních porostů. U zpracovatelské přesnosti mají hodnoty (≥ 80 %) kategorie jehličnatého lesa a zástavby.

V případě klasifikace PlanetScope byla celková přesnost pouze 66 % (tabulka 20), hodnota kappa indexu dosáhla 0,55 %. Nejnížší uživatelská (24 %) a zpracovatelská (21 %) přesnost byla u kategorie orné půdy. Nejvyšší uživatelská přesnost byla u kategorie zástavby (88 %), zpracovatelská přesnost u jehličnatého lesa (79 %).

Tabulka 19: Chybová matice klasifikace zbylé části území Krkonoš z dat Sentinel-2 z 27. 8. 2016

	Jehličnatý les	Listnatý a smíšený les	Holiny a mlaziny	Trvalé travní porosty	Orná půda	Vodní plocha	Zástavba	Celkem	Uživatelská přesnost
Jehličnatý les	717	28	13	2	0	2	0	762	0,94
Listnatý a smíšený les	75	383	20	16	6	2	1	503	0,76
Holiny a mlaziny	92	62	175	63	7	4	15	418	0,42
Trvalé travní porosty	1	6	9	460	26	0	3	505	0,91
Orná půda	2	9	15	27	94	0	11	158	0,59
Vodní plocha	0	0	0	3	0	9	0	12	0,75
Zástavba	0	2	2	3	5	0	31	43	0,72
Celkem	887	490	234	574	138	17	61	2401	
Zpracovatelská přesnost	0,81	0,78	0,75	0,8	0,68	0,53	0,51		0,78
Kappa index	0,71								

Zdroj: Vlastní tvorba

Tabulka 20: Chybová matice klasifikace zbylé části území Krkonoš z dat PlanetScope z 30. 6. 2019

	Jehličnatý les	Listnatý a smíšený les	Holiny a mlaziny	Trvalé travní porosty	Orná půda	Vodní plocha	Zástavba	Celkem	Uživatelská přesnost
Jehličnatý les	699	57	27	15	2	5	1	806	0,87
Listnatý a smíšený les	70	262	26	18	0	0	1	377	0,69
Holiny a mlaziny	102	91	136	68	5	1	1	404	0,34
Trvalé travní porosty	11	69	39	425	102	1	9	656	0,65
Orná půda	5	9	6	44	29	1	26	120	0,24
Vodní plocha	0	1	0	2	0	9	0	12	0,75
Zástavba	0	1	0	2	0	0	23	26	0,88
Celkem	887	490	234	574	138	17	61	2401	
Zpracovatelská přesnost	0,79	0,53	0,58	0,74	0,21	0,53	0,38		0,66
Kappa index	0,55								

Zdroj: Vlastní tvorba

5.3.1. Porovnání klasifikací s CLC 2018

Celkově data CLC 2018 jsou oproti vytvořeným klasifikacím z hlediska struktury hrubší. Porovnání celkových rozloh za všechny kvadráty a rozloh CLC 2018 zobrazuje tabulka 21. V rámci CLC 2018 měla největší rozlohu třída jehličnatého lesa, může to souviset s velikostí minimální mapovací jednotky 25 ha, kde v rámci jehličnatého lesa není mapována jemná heterogenita či menší holiny/mlaziny. Naopak u kategorie listnatého a smíšeného lesa byla největší rozloha v případě Sentinel-2 a následně i u PlanetScope. Velmi výrazný je rozdíl v rozlohách v případě kategorií holiny a mlaziny, což může souviset s rozdílnými definovanými legendami a omezeními, které přinesla agregace CLC 2018. Nejmenší rozlohu orné půdy měla klasifikace PlanetScope, nejspíše v souvislosti s datem snímání. Nejvýraznější rozdíl je v kategorii zástavby – v CLC 2018 je zástavba výrazně nadhodnocena, protože jako třída zástavba je definován celý intravilán obce (příloha 14). Dále lze vidět rozdíly v rozlohách ve třídách legendy v krkonošské tundře, což souvisí s rozdílným přístupem legend. Z hlediska časové dostupnosti je produkt CLC dostupný od roku 1990. Od roku 2000 je CLC dostupný vždy v šestileté periodě.

Tabulka 21: Rozlohy jednotlivých klasifikačních tříd legendy v km² a CLC 2018

Třída	Sentinel-2	PlanetScope	CLC 2018
Jehličnatý les	323,8	325,2	414,3
Listnatý a smíšený les	186,6	146,7	133,9
Holiny a mlaziny	177,9	171,9	58,6
Trvalé travní porosty	160,6	218,4	210,7
Orná půda	44,3	36,1	49,1
Vodní plocha	1,8	2,4	2,4
Zástavba	16,6	10,8	53,9
Kosodřevina	29,8	27,1	25,1
Horská louka	13,5	15,6	8,1
Kamenné moře	2,3	2,0	5,3
Keříčková vegetace	4,2	5,1	-
Celkem	961,5	961,5	961,5

Zdroj: Vlastní tvorba, tučně vyznačené největší rozlohy

Land cover je reprezentovaný charakteristikou celkové rozlohy třídy v kvadrátu (přílohy 15 a 16). Rozdíly v korelacích při porovnání měřítek nejsou výrazné (mírně vyšších hodnot je dosaženo u dat Sentinel-2).

Silné kladné korelace (interval 0,60-0,79) byly nalezeny u proměnných vyjadřujících počet druhů a počet pěvců s kategorií land cover (v obou měřítkách) – trvalé travní porosty a střední kladné korelace v případě orné půdy.

Velmi silné korelace (hodnoty větší ≥ 80) byly vypočteny u slavíka modráčka tundrového (*Luscinia svecica svecica*), u land cover Sentinel-2 třídy keříčková vegetace (0,82/0,79) – jednalo se o vůbec největší korelaci ze všech vypočtených korelací v rámci diplomové práce, a třídy horská louka pro PlanetScope (0,79/0,81). Slavík modráček tundrový (*Luscinia svecica svecica*) byl při výběru druhů (tabulka 14), zařazen mezi druhy, u kterých se předpokládala spojitost s oblastí krkonošské tundry, avšak byla nalezena spojitost s třídami keříčkové vegetace a tundry. U kategorií kosodřevina a kamenné moře byly v obou měřítkách nalezeny střední až silné korelace.

Mezi dalším ptactvem, u kterého se potvrdila spojitost s oblastí krkonošské tundry dle předpokladu výběru (tabulka 14), byly druhy: linduška horská (*Anthus spinoletta*) (např. střední kladná korelace s horskou loukou (0,75/0,76) a keříčkovou vegetací (0,76/0,71)), pěvuška podhorní (*Prunella collaris*) a sokol stěhovavý (*Falco peregrinus*). Střední pozitivní korelace byly vypočteny u bekasiny otavní (*Gallinago gallinago*) – v obou měřítkách s kosodřevinou, horskou loukou a keříčkovou vegetací (naopak kategorie kamenné moře mělo hodnoty pouze (0,13/0,09)). Bělořit šedý (*Oenanthe oenanthe*) měl velmi slabé až střední korelace, nejvyšších hodnot dosahoval u kategorie keříčkové vegetace (0,49/0,50).

Můžeme rozlišit pět druhů ptactva, které mají hodnoty korelací minimálně střední s alespoň jednou třídou land cover mimo tundru v obou měřítkách: kos horský (*Turdus torquatus*), lejsek černohlavý (*Ficedula hypoleuca*), lejsek šedý (*Muscicapa striata*), lejsek malý (*Ficedula parva*), sýc rousný (*Aegolius funereus*) a tetřívka obecná (*Lyrurus tetrix*).

Velmi slabé korelace byly nalezeny v obou měřítkách u datlíka tříprstého (*Picoides tridactylus*), kalouse ušatého (*Asio otus*), konipase horského (*Motacilla cinerea*), králíčka ohnivého (*Regulus ignicapilla*) a u krkavce velkého (*Corvus corax*).

5.4. Strukturální proměnné (krajinné metriky)

V rámci práce proběhl výpočet strukturálních parametrů – krajinných metrik (příloha 7). Výpočet byl uskutečněn s využitím R balíčku *landscapemetrics* na úrovni krajiny, z klasifikací Sentinel-2 a PlanetScope. V dalším kroku proběhl výpočet Pearsonova korelačního koeficientu mezi ptačími daty a krajinnými metrikami. Lze určit druhy, které poměrně dobře reagovaly na metriky, a jejichž korelace byly střední hodnoty – kos horský (*Turdus torquatus*), lejsek

černohlavý (*Ficedula hypoleuca*), lejsek šedý (*Muscicapa striata*), puštík obecný (*Strix aluco*), sýc rousný (*Aegolius funereus*), tetřívka obecná (*Lyrurus tetrix*).

V případě metrik vypočtených z PlanetScope dosahovaly výsledky korelací mírně nižších hodnot. U většiny druhů (mimo výše zmíněných šesti hlavních druhů) byly hodnoty korelací velmi slabé. Případné výjimky budou rozepsány v následující části, kde jsou metriky rozděleny do šesti kategorií podle dělení v dokumentaci R balíčku *landscapemetrics*. Dále jsou okomentovány speciálně metriky, které byly zmíněny v tabulce 9 a 10 dle literatury.

- Metriky agregace (Aggregation metrics) (přílohy 21, 27)
 - Ze skupiny metrik agregace lze najít šest zmíněných druhů, které dobře reagují na metriky a jejichž hodnoty korelací se pohybují od velmi slabých až po střední. Ostatní druhy mají hodnoty korelací v obou měřítkách velmi slabé až na výjimečné případy přesahující hodnotu korelace lehce nad 0,20. Do skupiny agregačních metrik je zařazena např. dle rešerše zmiňovaná metrika NP (přílohy 17, 21, 27). Z hlediska počtu druhů a počtu pěvců byla vypočtena silná pozitivní korelace z dat Sentinel-2. Největších kladných korelací bylo dosaženo u NP v případě lejska šedého (*Muscicapa striata*) (0,56/0,27) a lejska černohlavého (*Ficedula hypoleuca*) (0,44/0,24). Tyto druhy preferují fragmentovanější krajinu s větším počtem plošek. Největší záporné korelace byly vypočteny u tetřívky obecné (*Lyrurus tetrix*) (-0,52/-0,29) a kosa horského (*Turdus torquatus*) (-0,46/-0,31), kteří preferují otevřenou krajinu s menším počtem plošek. Hodnoty korelací jsou pro metriku NP menší z dat PlanetScope. Ostatní druhy mají hodnoty korelací pro NP velmi slabé až slabé.
- Metriky ploch a okrajů (area and edge metrics) (přílohy 22 a 28)
 - Metriky ploch a okrajů se ukázaly jako relevantní pro šest zmíněných ptáčích druhů. Do skupiny plošných metrik řadíme dle literatury zmiňovanou metriku MPS (přílohy 18, 22, 28), v případě balíčku *landscapemetrics* existuje pod názvem *area_mn*. V případě MPS byly nalezeny největší záporné korelace u lejska šedého (*Muscicapa striata*) (-0,52/-0,29), lejska černohlavého (*Ficedula hypoleuca*) (-0,43/-0,19) a puštíka obecného (*Strix aluco*) (-0,29/-0,13). Naopak kladné korelace byly nalezeny pro druhy – kos horský (*Turdus torquatus*) (0,39/0,28), sýc rousný (*Aegolius funereus*) (0,26/0,19) a tetřívka obecná (*Lyrurus tetrix*) (0,56/0,26). Druhy s kladnými hodnotami korelací s větší hodnotou MPS vyhledávají otevřenější typ krajiny, naopak druhy se zápornou korelací a menší hodnotou MPS preferují fragmentovanější krajinu. Metrika TE (přílohy 19, 22, 28), která byla vybrána na základě literatury, vykazovala v obou měřítkách podobné výsledky jako ostatní metriky tvarů a okrajů, oproti MPS byly však u hodnot

korelací znaménka opačná. V případě počtu druhů řádu pěvci byly hodnoty nepatrně vyšší v obou měřítkách než u celkového počtu druhů, lze tedy potvrdit, že řád pěvců vyhledává krajinu s větší délkou hranic.

- Metriky komplexnosti (complexity metrics) (přílohy 23, 29)
 - Skupina šesti druhů dosahovala slabých až středních korelací, nejmenší hodnoty korelací měla metrika *mutinf*. V případě korelace metriky *condent* s počtem druhů vyšly korelace (0,66/0,45), u počtu druhů řádu pěvci (0,69/0,50). Metrika *condent* vyjadřuje geometrickou složitost prostorového vzoru – obecně tedy druhově pestřejší a vhodnější pro pěvce je krajina, kde je mix menších plošek s různými třídami. Podobných (lehce horších výsledků) dosáhla také metrika *joinent*, která vyjadřuje prostorově-tematickou složitost tříd v krajině. V případě jednotlivých druhů měla metrika *condent* u lejska šedého (*Muscicapa striata*) hodnoty (0,55/0,33), *relmutinf* u kosa horského (*Turdus torquatus*) hodnoty (0,48/0,30), to můžeme označit jako preferenci méně komplexního typu krajiny s většími plochami. Mimo šesti hlavních druhů oscilovalo několik druhů u metriky *relmutinf* mezi hodnotami 0,20-0,30 v obou měřítkách – linduška horská (*Anthus spinoletta*), pěvuška podhorní (*Prunella collaris*) a sokol stěhovavý (*Falco peregrinus*).
- Metriky jádrové oblasti (core area metrics) (přílohy 24, 30)
 - V případě kategorie metrik jádrové oblasti je opět zřetelný trend šesti druhů ptactva zmíněných v úvodu, které mají hodnoty korelací u většiny metrik velmi slabé až střední. V případě dat PlanetScope neexistuje však tak výrazný rozdíl v hodnotách korelací v porovnání s ostatními druhy, které jsou velmi slabé. U některých metrik byly rozdílné hodnoty v případě měřítek (např. metrika *cai_mn* – v případě počtu druhů a počtu pěvců střední korelace s použitím Sentinel-2, v případě PlanetScope velmi slabé korelace).
- Metriky diverzity (diversity metric) (přílohy 25, 31)
 - Opět se jedná o trend šesti hlavních druhů. Zbylé hodnoty byly převážně velmi slabé korelace v obou měřítkách, mimo metriky *PR* a *PRD*, které jsou závislé na počtu klasifikačních tříd. V případě metriky *PR* byly slabé kladné korelace u kosa horského (*Turdus torquatus*) (0,38, 0,41), hýla rudého (*Carpodacus erythrinus*) (0,35/0,36) a lindušky horské (*Anthus spinoletta*) (0,31/0,36). Tyto druhy by měly směřovat k habitatům o větším počtu krajinných tříd. Záporné slabé korelace byly zjištěny u lejska černohlavého (*Ficedula hypoleuca*) (-0,31/-0,34) – preference menšího počtu krajinných tříd. Vybraná metrika dle literatury *SHDI* (přílohy 20, 25 ,31) měla u obou měřítek větší hodnotu korelace s počtem pěvců než pro celkový počet druhů ptactva.

Z jednotlivých druhů měl největší kladnou korelaci s *SHDI* lejsek šedý (*Muscicapa striata*) (0,42/0,21). Ten v případě použití měřítka dat Sentinel-2 směřoval k preferenci habitatu s větším počtem krajinných tříd, které mají mezi s sebou rovnoměrné zastoupení. Největší zápornou korelaci v obou měřítkách měli sýc rousný (*Aegolius funereus*) (-0,30/-0,16) a tetřívka obecná (*Lyrurus tetrix*) (-0,32/-0,10). Tyto druhy by měly spíše směřovat k habitatu s menším počtem krajinných tříd, kde převažuje určitá dominantní krajinná kategorie. Další testovanou metrikou dle literatury byla *SIDI*, která vykazovala podobné (mírně nižší) hodnoty pro obě měřítka jako *SHDI*. Oproti *SHDI* je *SIDI* méně citlivá na počet krajinných tříd.


- Metriky tvaru (shape metrics) (přílohy 26, 32)
 - Opět trend šesti hlavních druhů nabývá slabých až výjimečně středních hodnot, avšak v porovnání s ostatními druhy není tak výrazný rozdíl v hodnotách korelací (ostatní druhy měly velmi slabé korelace, vzácně až slabé korelace). V případě počtu druhů ptactva a počtu pěvců byly nalezeny velmi slabé až střední kladné korelace u skupin metrik *circle*, *frac* a *shape*.

5.5. Regresní modelování

V rámci regresního modelování proběhlo sestavení šesti GLR modelů pro vybrané druhy (tabulka 16), u kterých byl zjištěn vztah dle použité metodiky mezi zkoumanými metrikami a výskytem druhů. Nejvýkonnější model dle hodnoty AICc byl sestaven pro tetřívka obecného (*Lyrurus tetrix*) $\hat{=}$ 218, nejméně výkonný naopak pro druh: sýc rousný (*Aegolius funereus*) $\hat{=}$ 491. U každého modelu v této kapitole lze vidět ve sloupci *probability* statisticky významné koeficienty na hladině ($p < 0,01$) (označené jsou hvězdičkou). Hodnoty sloupce Variance Inflation faktor (VIF) by neměly přesáhnout 7,5, což všechny vysvětlující proměnné ve všech modelech splňují. Podíl vysvětlující proměnné na rozptylu závislé proměnné (hodnota Deviance Explained) byl nejvyšší pro tetřívka obecného (*Lyrurus tetrix*) $\hat{=}$ 0,58, nejnižší pro sýce rousného (*Aegolius funereus*) $\hat{=}$ 0,22.


5.5.1. Kos horský (*Turdus torquatus*)

Obrázek 10: Pravděpodobnost výskytu kosa horského (*Turdus torquatus*)



Zdroj: Vlastní tvorba, Copernicus (2021), pozn. proložení bodovými daty z náleзовé databáze AOPK

Obrázek 11: Rezidua binárního GLR pro kosa horského (*Turdus torquatus*)



Zdroj: Vlastní tvorba, Copernicus (2021)

Tabulka 22: Přehled GLR kosa horského (*Turdus torquatus*)

Proměnná	Koeficient	Směrodatná chyba	z-statistika	Prav.	Odds Ratio	Wald's Low (95%)	Wald's High (95%)	VIF
Intercept	-21,186206	4,085094	-5,186222	0,000000*	0,000000	0,000000	0,000002	-----
Nadmořská výška	0,017341	0,002664	6,508458	0,000000*	1,017492	1,012192	1,022819	5,915588
NP	0,008390	0,003087	2,718199	0,006564*	1,008426	1,002343	1,014545	2,866509
Jehličnatý les	0,024299	0,012599	1,928593	0,053781	1,024596	0,999604	1,050213	5,946488
Listnatý a smíšený les	0,004176	0,014748	0,283175	0,777043	1,004185	0,975573	1,033637	2,720529
Holiny a mlaziny	-0,003172	0,012501	-0,253769	0,799674	0,996833	0,972706	1,021558	3,304388
Trvalé travní porosty	0,006551	0,015838	0,413667	0,679118	1,006573	0,975807	1,038309	5,010224
Kosodřevina	0,010179	0,026297	0,387092	0,698688	1,010231	0,959481	1,063666	5,257604

Zdroj: Vlastní tvorba, pozn. prav. = pravděpodobnost

Do modelu pro kosa horského (obrázek 10) vstupovalo sedm vysvětlujících proměnných (nadmořská výška, NP, jehličnatý les, listnatý a smíšený les, holiny a mlaziny, trvalý travní porost a kosodřevina (tabulka 22)). Statisticky významné koeficienty na 99% hladině α ($p < 0,01$) byly nadmořská výška a NP. Jediným záporným vztahem v modelu je třída holin a mlazin.

Tabulka 23: Celkové statistiky kosa horského (*Turdus torquatus*)

Waldova statistika	302,248061
AICc	252,917942
Deviance Explained	0,560908
Prob (> chi-squared), degrees of freedom	0,000000*

Zdroj: Vlastní tvorba

Celková výkonnost modelu AICc je 252,9, podíl vysvětlující proměnné na rozptylu závislé proměnné (hodnota Deviance Explained) je 0,56 (tabulka 23).

Tabulka 24: Chybová matice kosa horského (*Turdus torquatus*)


	0	1
0	328	21
1	28	94

Zdroj: Vlastní tvorba

Chybová matice ukazuje porovnání hodnot vstupních dat a regresního modelu (tabulka 24). Obrázek 11 zobrazuje distribuci reziduí a lze vidět oblasti, kde jsou hodnoty pravděpodobnosti výskytu lehce podhodnocené – v severozápadních oblastech středních nadmořských výšek, ve středu území v Česku a na východě území.


5.5.2. Lejsek černohlavý (*Ficedula hypoleuca*)

Obrázek 12: Pravděpodobnost výskytu lejska černohlavého (*Ficedula hypoleuca*)



Zdroj: Vlastní tvorba, Copernicus (2021), pozn. proložení bodovými daty z náleзовé databáze AOPK

Obrázek 13: Rezidua binární GLR pro lejska černohlavého (*Ficedula hypoleuca*)



Zdroj: Vlastní tvorba, Copernicus (2021)

Tabulka 25: Přehled GLR lejska černohlavého (*Ficedula hypoleuca*)

Proměnná	Koeficient	Směrodatná chyba	z-statistika	Prav.	Odds Ratio	Wald's Low (95%)	Wald's High (95%)	VIF
Intercept	3,313793	1,491927	2,221149	0,026341*	27,489187	1,476413	511,818558	-----
Nadmořská výška	-0,003545	0,001343	-2,639588	0,008301*	0,996461	0,993841	0,999088	4,859944
TE	0,000010	0,000012	0,810595	0,417598	1,000010	0,999986	1,000035	2,078567
Listnatý a smíšený les	0,025423	0,008837	2,876870	0,004016*	1,025749	1,008135	1,043671	2,347820
Holiny a mlaziny	-0,015579	0,007237	-2,152839	0,031331*	0,984542	0,970676	0,998605	1,736144
Orná půda	-0,021614	0,010139	-2,131780	0,033025*	0,978618	0,959363	0,998260	2,078563
Horská louka	-0,047739	0,034938	-1,366406	0,171812	0,953382	0,890282	1,020955	1,595823

Zdroj: Vlastní tvorba, pozn. prav. = pravděpodobnost

Do modelu (obrázek 12) pro lejska černohlavého (*Ficedula hypoleuca*) vstupovalo šest vysvětlujících proměnných. Na 99% hladině α ($p < 0,01$) byly nalezeny statisticky významné koeficienty – nadmořská výška, listnaté a smíšené lesy, holiny a mlaziny a orná půda (tabulka 25).

Tabulka 26: Celkové statistiky lejska černohlavého (*Ficedula hypoleuca*)

Waldova statistika	224,200975
AICc	374,807750
Deviance Explained	0,383402
Prob (> chi-squared), degrees of freedom	0,000000*

Zdroj: Vlastní tvorba

Celková výkonnost modelu je $\hat{=} 374,8$, podíl vysvětlující proměnné na rozptylu závislé proměnné je pak následně $\hat{=} 0,38$ (tabulka 26).

Tabulka 27: Chybová matice lejska černohlavého (*Ficedula hypoleuca*)


	0	1
0	95	52
1	27	297

Zdroj: Vlastní tvorba

Tabulka 27 představuje chybovou matici vstupních dat a výsledků regresního modelu. Obrázek 13 zobrazuje distribuci reziduí, mírně jsou podhodnoceny hodnoty pod horní hranicí lesa na obou stranách hranice.


5.5.3. Lejsek šedý (*Muscicapa striata*)

Obrázek 14: Pravděpodobnost výskytu lejska šedého (*Muscicapa striata*)



Zdroj: Vlastní tvorba, Copernicus (2021), pozn. proložení bodovými daty z náleзовé databáze AOPK

Obrázek 15: Rezidua binární GLR pro lejska šedého (*Muscicapa striata*)



Zdroj: Vlastní tvorba, Copernicus (2021)

Tabulka 28: Přehled GLR lejska šedého (*Muscicapa striata*)

Proměnná	Koeficient	Směrodatná chyba	z-statistika	Prav.	Odds Ratio	Wald's Low (95%)	Wald's High (95%)	VIF
Intercept	3,669615	1,539670	2,383377	0,017155*	39,236778	1,919108	802,208575	-----
Nadmořská výška	-0,005675	0,001425	-3,981752	0,000068*	0,994342	0,991568	0,997123	6,670224
NP	0,002877	0,001545	1,862622	0,062515	1,002881	0,999850	1,005922	2,500841
Listnatý a smíšený les	0,002204	0,006321	0,348673	0,727335	1,002206	0,989867	1,014699	2,451907
Trvalé travní porosty	0,016894	0,006364	2,654625	0,007940*	1,017038	1,004430	1,029803	2,322366
Orná půda	-0,021537	0,011020	-1,954351	0,050660	0,978694	0,957782	1,000062	2,168726
Kosodřevina	-0,002941	0,012728	-0,231065	0,817264	0,997063	0,972498	1,022249	1,840555

Zdroj: Vlastní tvorba, pozn. prav. = pravděpodobnost

Do modelu (obrázek 14) pro lejska šedého (*Muscicapa striata*) vstupovalo šest vysvětlujících proměnných. V rámci analýzy byly nalezeny statisticky významné proměnné (na 99% hladině α , $p < 0,01$) – nadmořská výška a trvalé travní porosty (tabulka 28).

Tabulka 29: Celkové statistiky lejska šedého (*Muscicapa striata*)

Waldova statistika	254,161886
AICc	401,030474
Deviance Explained	0,396539
Prob (> chi-squared), degrees of freedom	0,000000*

Zdroj: Vlastní tvorba

Celková výkonnost modelu je $\hat{=} 374,8$, podíl vysvětlující proměnné na rozptylu závislé proměnné je $\hat{=} 0,38$ (tabulka 29).

Tabulka 30: Chybová matice lejska šedého (*Muscicapa striata*)


	0	1
0	148	50
1	32	241

Zdroj: Vlastní tvorba

Tabulka 30 zobrazuje chybovou matici vstupních dat výskytu a výsledků regresního modelu, na obrázku 15 lze vidět hodnoty reziduí, které jsou podhodnoceny na obou stranách hranice v oblastech pod horní hranicí lesa, dále směrem do podhůří jsou nadhodnoceny.


5.5.4. Puštík obecný (*Strix aluco*)

Obrázek 16: Pravděpodobnost výskytu puštíka obecného (*Strix aluco*)



Zdroj: Vlastní tvorba, Copernicus (2021), pozn. proložení bodovými daty z nálezkové databáze AOPK

Obrázek 17: Rezidua binární GLR pro puštíka obecného (*Strix aluco*)



Zdroj: Vlastní tvorba, Copernicus (2021)

Tabulka 31: Přehled GLR puštika obecného (*Strix aluco*)

Proměnná	Koeficient	Směrodatná chyba	z-statistika	Prav.	Odds Ratio	Wald's Low (95%)	Wald's High (95%)	VIF
Intercept	-0,251018	1,172639	-0,214062	0,830499	0,778009	0,078129	7,747379	-----
Nadmořská výška	-0,002307	0,001131	-2,039495	0,041401*	0,997696	0,995487	0,999910	6,525939
Listnatý a smíšený les	0,028377	0,006009	4,722467	0,000002*	1,028784	1,016738	1,040972	2,490477
Holiny a mlaziny	-0,003233	0,007681	-0,420935	0,673803	0,996772	0,981879	1,011891	1,809074
Trvalé travní porosty	0,001463	0,004329	0,337862	0,735467	1,001464	0,993002	1,009997	2,108874
Orná půda	0,012116	0,008836	1,371171	0,170322	1,012190	0,994810	1,029873	2,180941
Kosodřevina	-0,006858	0,016084	-0,426362	0,669844	0,993166	0,962344	1,024974	2,060827

Zdroj: Vlastní tvorba, pozn. prav. = pravděpodobnost

Do modelu (obrázek 16) pro puštika obecného (*Strix aluco*) vstupovalo šest vysvětlujících proměnných. Jako statisticky významné na 99% hladině α ($p < 0,01$) můžeme označit proměnné – nadmořská výška, listnaté a smíšené lesy (tabulka 31).

Tabulka 32: Celkové statistiky puštika obecného (*Strix aluco*)

Waldova statistika	139,854989
AICc	484,466626
Deviance Explained	0,229240
Prob (> chi-squared), degrees of freedom	0,000000*

Zdroj: Vlastní tvorba

Celková výkonnost modelu je $\hat{=} 484,4$, podíl vysvětlující proměnné na rozptylu závislé proměnné je následně $\hat{=} 0,23$ (tabulka 32).

Tabulka 33: Chybová matice puštika obecného (*Strix aluco*)


	0	1
0	257	49
1	62	103

Zdroj: Vlastní tvorba

Tabulka 33 zobrazuje chybovou matici mezi vstupními daty a výsledkem regresního modelu, na obrázku 17 jsou hodnoty reziduí, kde jsou vidět oblasti nadhodnocení/podhodnocení modelu v území pod horní hranicí lesa směrem do podhůří.


5.5.5. Sýc rousný (*Aegolius funereus*)

Obrázek 18: Pravděpodobnost výskytu sýce rousného (*Aegolius funereus*)



Zdroj: Vlastní tvorba, Copernicus (2021), pozn. proložení bodovými daty z náleзовé databáze AOPK

Obrázek 19: Rezidua binární GLR pro sýce rousného (*Aegolius funereus*)



Zdroj: Vlastní tvorba, Copernicus (2021)

Tabulka 34: Přehled GLR sýce rousného (*Aegolius funereus*)

Proměnná	Koeficient	Směrodatná chyba	z-statistika	Prav.	Odds Ratio	Wald's Low (95%)	Wald's High (95%)	VIF
Intercept	-3,414787	0,914595	-3,733660	0,000189*	0,032883	0,005476	0,197468	-----
Nadmořská výška	0,001339	0,000761	1,758419	0,078676	1,001340	0,999847	1,002835	2,741158
MPS	-0,583266	0,289136	-2,017272	0,043667*	0,558073	0,316645	0,983577	2,140053
Jehličnatý les ^P	0,023349	0,004042	5,776239	0,000000*	1,023624	1,015546	1,031766	2,560183
Holiny a mlaziny ^P	0,014462	0,005646	2,561540	0,010421*	1,014567	1,003402	1,025856	1,587340
Trvalé travní porosty ^P	0,003970	0,006033	0,657961	0,510563	1,003977	0,992175	1,015920	3,965141
Orná půdy ^P	-0,050466	0,027245	-1,852268	0,063987	0,950787	0,901346	1,002940	1,973747

Zdroj: Vlastní tvorba, pozn. prav. = pravděpodobnost; horní index P jsou charakteristiky vypočtené na datech PlanetScope

Do modelu (obrázek 18) pro sýce rousného (*Aegolius funereus*) vstupovalo šest vysvětlujících proměnných. Byly nalezeny na 99% hladině α ($p < 0,01$) tři statisticky významné koeficienty – MPS, Jehličnatý les z PlanetScope, Holiny a mlaziny z PlanetScope (tabulka 34).

Tabulka 35: Celkové statistiky GLR sýce rousného (*Aegolius funereus*)

Waldova statistika	132,528476
AICc	493,019098
Deviance Explained	0,216796
Prob (> chi-squared), degrees of freedom	0,000000

Zdroj: Vlastní tvorba

Celková výkonnost modelu je $\hat{=}$ 491, podíl vysvětlující proměnné na rozptylu závislé proměnné je $\hat{=}$ 0,22 (tabulka 35).

Tabulka 36: Chybová matice sýce rousného (*Aegolius funereus*)


	0	1
0	235	70
1	73	93

Zdroj: Vlastní tvorba

Tabulka 36 zobrazuje chybovou matici mezi vstupními daty a výsledkem regresního modelu. Výkonnost modelu je podhodnocena ve středních polohách na české i polské straně, naopak model nadhodnocuje západní a východní části území (obrázek 19).


5.5.6. Tetřívka obecný (*Lyrurus tetrix*)

Obrázek 20: Pravděpodobnost výskytu tetřívka obecného (*Lyrurus tetrix*)



Zdroj: Vlastní tvorba, Copernicus (2021), pozn. proložení bodovými daty z nálezové databáze AOPK

Obrázek 21: Rezidua binární GLR pro tetřívka obecného (*Lyrurus tetrix*)



Zdroj: Vlastní tvorba, Copernicus (2021)

Tabulka 37: Přehled GLR tetřívka obecného (*Lyrurus tetrix*)

Proměnná	Koeficient	Směrodatná chyba	z-statistika	Prav.	Odds Ratio	Wald's Low (95%)	Wald's High (95%)	VIF
Intercept	-12,63160	1,686945	-7,487851	0,000000*	-12,63160	1,686945	-7,487851	0,000000*
Nadmořská výška	0,010255	0,002074	4,943575	0,000001*	0,010255	0,002074	4,943575	0,000001*
MPS	1,267060	0,443271	2,858428	0,004257*	1,267060	0,443271	2,858428	0,004257*
Holiny a mlaziny	0,012821	0,007977	1,607348	0,107978	0,012821	0,007977	1,607348	0,107978
Kosodřevina	-0,008822	0,010761	-0,819809	0,412325	-0,008822	0,010761	-0,819809	0,412325

Zdroj: Vlastní tvorba, pozn. prav. = pravděpodobnost

Do modelu (obrázek 20) pro tetřívka obecného (*Lyrurus tetrix*) vstupovaly čtyři vysvětlující proměnné. Z toho byly na 99% hladině α ($p < 0,01$) zjištěny statisticky významné pouze dvě proměnné – nadmořská výška a MPS (tabulka 37).

Tabulka 38: Celkové statistiky tetřívka obecného (*Lyrurus tetrix*)

Waldova statistika	291,905685
AICc	218,040121
Deviance Explained	0,584025
Prob (>chi-squared), degrees of freedom	0,000000*

Zdroj: Vlastní tvorba

Celková výkonnost modelu je $\hat{=} 218$, podíl vysvětlující proměnné na rozptylu závislé proměnné je $\hat{=} 0,58$ (tabulka 38).

Tabulka 39: Chybová matice tetřívka obecného (*Lyrurus tetrix*)

	0	1
0	328	21
1	28	94

Zdroj: Vlastní tvorba

Chybová matice zobrazuje rozdíl mezi vstupními daty a výsledky regresního modelu (tabulka 39). Výkonnost tohoto modelu je podhodnocena v oblastech pod horní hranicí lesa (obrázek 21).

Tabulka 40: Výsledky Global Moran's I indexu reziduí modelů

Druh	Global Moran's I	z-score	p-hodnota
<i>kos horský (Turdus torquatus)</i>	0,16	7,23	0
<i>lejsek šedý (Muscicapa striata)</i>	0,11	4,82	0,000001
<i>lejsek černohlavý (Ficedula hypoleuca)</i>	0,13	6,28	0
<i>puštík obecný (Strix aluco)</i>	0,05	2,20	0,028
<i>sýc rousný (Aegolius funereus)</i>	0,18	8,25	0
<i>tetřívka obecná (Lyrurus tetrix)</i>	0,15	7,15	0

Zdroj: Vlastní tvorba

Na výsledných modelech byl na závěr spuštěn výpočet Global Moran's I (vyhodnocení celkové autokorelace v modelu). Global Moran's I definuje nulovou hypotézu jako náhodné rozložení prvků. Při pohledu na tabulku 40 jsou hodnoty z-score kladné a p-hodnoty jsou statisticky významné, tím pádem lze zamítnout nulovou hypotézu. V případě puštíka obecného (*Strix aluco*) je méně než 5% šance, že se jedná o náhodné rozložení (z-score 2,20 a p-hodnota 0,028). U ostatních druhů je pravděpodobnost náhodného rozložení méně než 1 %. Dle výsledků dochází k prostorovému shlukování reziduí a v modelech je pozitivní prostorová autokorelace, nejvyšší hodnota Global Moran's I byla v modelu pro sýce rousného (*Aegolius funereus*) (0,18), nejmenší u puštíka obecného (*Strix aluco*) (0,05).

6. Diskuze

Cílem práce bylo získat vybrané topografické, spektrální, tematické a strukturální charakteristiky pro popis krajiny z dat DPZ. Krajina zájmového území byla analyzována v kvadrátech o délkách stran 1400 x 1400 m, ve kterých bylo provedeno v letech 2012-2014 mapování jednotlivých ptačích druhů se čtyřmi pravděpodobnostmi výskytu. Výhodou mapování v kvadrátech bylo, že na rozdíl od bodových dat z nálezové databáze AOPK, byla data k dispozici jak pro českou, tak polskou stranu Krkonoš. Kvadráty lze navíc porovnávat mezi sebou v rámci času. Nevýhodou naopak je, že data v kvadrátech na rozdíl od bodových dat představují určitou formu generalizace a agregace dat. Pro popis krajiny metodami DPZ byly z důvodu zodpovězení otázky, do jaké míry může rozdílné prostorové rozlišení ovlivnit výsledky, analyzovány dva typy dat s rozdílnou velikostí pixelu, a to Sentinel-2 10 x 10 m/pixel a PlanetScope 3 x 3 m/pixel. Roli ale jistě hrálo i rozdílné spektrální rozlišení dat. V úvodním kroku bylo nutné najít optimální bezoblačné scény. Pro data Sentinel-2 byla nejbližší bezoblačná scéna k termínu mapování nalezena 27. 8. 2016. Pro data PlanetScope byla termínově nejbližší bezoblačná data pro celé území z 30. 6. 2019, což představuje rozdíl pěti let od ukončení mapování. To mohlo do určité míry ovlivnit například výsledky hodnocení/srovnání krajinného pokryvu a jeho vlivu na výskyt ptačích druhů.

V případě jednotlivých typů charakteristik se dle očekávání jako důležitý faktor výskytu jednotlivých druhů a druhové bohatosti ukázala topografická proměnná (nadmořská výška). Počet druhů klesal s nadmořskou výškou. Na nadmořské výšce jsou závislé následující druhy – kos horský (*Turdus torquatus*), tetřívek obecný (*Lyrurus tetrix*) a lejsek šedý (*Muscicapa striata*). Naopak výskyt některých druhů nadmořská výška neovlivňuje.

Spektrální indexy dle literatury naznačovaly velký potenciál (Peterson, Papes 2006; Nieto, Flombaum, Garbulsky 2015; Santhakumar et al. 2018; Seidlová 2018; Bonthoux et al. 2018). Výhodou spektrálních indexů je jednoduchost výpočtu a zpracování dat. Bonthoux et al. (2018) uvádí, že použití může být podobně efektivní jako při použití klasifikovaných dat pro vstupy SDM. V našem případě však indexy pro většinu druhů neprokázaly korelace větší než velmi slabé. Výjimky tvořily v případě NDWI vypočteného ze Sentinel-2 sýc rousný (*Aegolius funereus*) a lejsek šedý (*Muscicapa striata*). Výsledky neukázaly (mimo indexu NDWI pro Sentinel-2) výraznější přínos pro popis jednotlivých kvadrátů, do budoucna by bylo přínosné rozvinout téma spektrálních indexů pro popis stanovišť s využitím bodových dat na větším zájmovém území.

V případě využití klasifikace zmiňuje literatura několik problémů – při rozdělení do jednotlivých klasifikačních tříd dochází ke ztrátě spektrální informace a klasifikační třídy nemusí být vždy kompatibilní s habitatovými potřebami jednotlivých druhů (Foody 2002; Gottschalk, Huettmann, Ehlers 2005; Gillespie et al. 2008). Dalším problémem může být počet klasifikačních tříd, který při výpočtu krajinných metrik ovlivňuje výsledné hodnoty, např. metrika PR.

Jedním z cílů diplomové práce bylo zjistit a otestovat možnosti DPZ, využít časově odpovídající data na potřebné tematické a strukturální úrovni a porovnat je s dostupnými datovými sadami. Území bylo pro klasifikaci rozděleno na dvě části s důrazem na oblast vysokohorské tundry, kde byly klasifikovány třídy – kosodřevina, horská louka, keříčková vegetace a kamenné moře. Antropogenní objekty (zpevněné asfaltové silnice či zástavba) byly v tundře odmaskovány z důvodu zpřesnění klasifikace. V případně tundry se ukázala v obou případech problematická kategorie keříčkové vegetace (borůvky, brusinky a vřes). U dat PlanetScope byla problematická kategorie orné půdy, což může souviset s termínem pořízení scény 30. června 2019, kdy je orná půda osetá zemědělskými plodinami a může docházet k záměně s třídou trvalých travních porostů. Druhým důvodem může být nízké spektrální rozlišení dat PlanetScope.

V rámci práce se podařilo najít způsob, jak rychle a efektivně vypočítat krajinné metriky s využitím prostředí R za použití dvou měřítek. Výsledná data představují potenciál dalšího možného budoucího výzkumu, např. jak jsou hodnoty ovlivňovány měřítkem. Přesnost metrik se odvíjí od přesností klasifikací. Dle hodnocení přesností klasifikací by měly být přesnější hodnoty v případě výsledků ze Sentinel-2. Při zpracování dat se ukázalo, že většina metrik je mezi sebou silně až velmi silně korelována (to představuje problém při sestavení regresního modelu). Strukturu habitatu lze ale mnohdy popsat jednou jednoduchou metrikou např. NP nebo MPS.

Na základě studia související literatury šlo předpokládat, že metriky z tabulky 11 a 12 by měly mít výraznější korelaci s výskytem ptačích druhů, a měly by tudíž být přínosné pro popis habitatu ptačích druhů. Pokud se zaměříme na charakteristiku celková rozloha třídy v kvadrátu, je relevantní v obou měřítkách u většiny krajinných tříd pro následující druhy – kos horský (*Turdus torquatus*), lejsek černohlavý (*Ficedula hypoleuca*), lejsek šedý (*Muscicapa striata*), pušтік obecný (*Strix aluco*), sýc rousný (*Aegolius funereus*) a tetřev obecný (*Lyrurus tetrix*). Naopak pro některé druhy je charakteristika celkové rozlohy třídy v kvadrátu relevantní pouze v případě území tundry. Těmito druhy jsou bekasina otavní (*Gallinago gallinago*), bělořit šedý (*Oenanthe oenanthe*), hýl rudý (*Carpodacus erythrinus*), linduška horská (*Anthus spinoletta*),

pěvuška podhorní (*Prunella collaris*), slavík modráček tundrový (*Luscinia svecica svecica*) a sokol stěhovavý (*Falco peregrinus*).

Pro všechny druhy ptactva nebyla nalezena souvislost ani v případě krajinných metrik NP, TE, MPS, PR, SHDI a SIDI. Ze všech testovaných metrik se podařilo najít relevantní metriky jen pro určité druhy ptactva. Souvislost se prokázala u počtu druhů v kvadrátu a počtu pěvců v kvadrátu. Krajinné metriky lze tedy použít pro popis prostředí ptactva. Regresní analýzu lze provádět na úrovni řádu či celkového počtu druhů v kvadrátu, případně přímo pro jednotlivé druhy ptactva. Pro druhy – kos horský (*Turdus torquatus*), lejsek černohlavý (*Ficedula hypoleuca*), lejsek šedý (*Muscicapa striata*), puštík obecný (*Strix aluco*), sýc rousný (*Aegolius funereus*) nebo tetřívka obecná (*Lyrurus tetrix*) byl nalezen vztah mezi zkoumanými charakteristikami a výskytem dle použité metodiky, a proto byly vybrány jako vhodné druhy pro regresní analýzu.

Druhým cílem bylo porovnání klasifikací s datovými produkty CLC 2018 a NK2 2018 a mapování VMB NATURA 2000. V diplomové práci byla použita metoda pixelové klasifikace Random Forest. Výsledek klasifikace byl upraven pomocí většinového filtru z důvodu odstranění osamocených pixelů. Porovnávané datové produkty mají plošně, případně liniově, definovanou minimální mapovací jednotku. Data CLC 2018 mají nejméně podrobné prostorové rozlišení ve srovnání s klasifikacemi a ostatními zmiňovanými datovými produkty (minimální mapovací jednotka je 25 ha). Výhodou dat CLC 2018 je dostupnost pro velkou část území Evropy – data byla dostupná pro plochu všech mapovacích kvadrátů a bylo možné provést porovnání s klasifikacemi.

Data N2K 2018 představují podrobnější produkt než CLC 2018. Hlavním úkolem datové sady N2K je mapování oblastí bohatých na travní porosty a vyhodnocování jejich změn. Data nepokrývají celé zájmové území kvadrátů, a nelze proto provést úplnou srovnávací analýzu. Dostupnost produktu je pouze lokální (např. produkt není dostupný pro celé území České republiky), což omezuje jeho využitelnost v případě prostorových analýz na větších územích. Datová sada je od roku 2006 k dispozici v šestileté periodě. Dle vizuálního porovnání jsou stejně jako v případě CLC 2018 nadhodnoceny třídy legendy spojené se zástavbou. Na rozdíl od CLC je produkt podrobnější (minimální mapovací jednotka 0,5 ha). Velmi dobře je v zemědělské krajině středních poloh patrná jemná struktura v podobě liniové listnaté a smíšené vegetace. Celkově však nedosahuje N2K podrobného strukturálního rozlišení jako klasifikace Sentinel-2 a PlanetScope. Velkým omezením je délka periody aktualizace produktu, která je šest let.

U dat VMB NATURA 2000 proběhla aktualizace původních dat z let 2000-2005 jako dvanáctiletý cyklus (2007-2018), kdy každý rok bylo aktualizováno zhruba 10 % okrsků s rozlohou 300 až 1500 ha. Omezením je opět délka periody aktualizace produktu. Aktualizace probíhá pomocí terénního mapování, což znamená taktéž časovou a finanční náročnost a do určité míry subjektivní přístup k mapování. Na základě zvolených minimální mapovacích jednotek zmíněných v kapitole 2.4. nemohou data vyjádřit jemnou heterogenitu krajiny. Celkově VMB obsahuje tři úrovně legendy. Ondrušková (2016) zmiňuje v bakalářské práci, že už první nejhrubší úroveň legendy (tabulka 2) je obtížně použitelná jako klasifikační legenda v DPZ. Jako problematické Ondrušková (2016) uvádí na první úrovni legendy rozlišení tříd „sekundární trávníky a vřesoviště“ od skupiny „alpínské bezlesí“. Dále uvádí nízký počet antropogenních tříd v legendě (např. legenda neobsahuje liniové prvky dopravní infrastruktury). Tyto antropogenní třídy byly ve VMB zařazeny v odlišné kategorii (vrstvy N2K obsahují liniové prvky dopravní infrastruktury). Rozlišení dalších skupin na druhé (případně třetí) úrovni legendy bylo ještě více problematické. Zároveň jsou data dostupná pouze pro českou část zájmového území.

Třetím cílem práce bylo statisticky zhodnotit, které z vybraných charakteristik krajiny jsou významné pro vybraný druh nebo skupinu druhů a na základě získaných charakteristik určit jejich výskyt v kvadrátech zájmového území. Výsledek analýzy měl být následně ověřen nezávislou bodovou sadou nálezové databáze AOPK. Bodová data z nálezové databáze AOPK byla k dispozici pouze pro území České republiky a pro některé druhy, např. lejsek černohlavý (*Ficedula hypoleuca*), lejsek šedý (*Muscicapa striata*), puštík obecný (*Strix aluco*) nebo sýc rousný (*Aegolius funereus*). Data z AOPK byla také rozmístěna v rovnoměrných čtvercích, což výrazně snižovalo použitelnost dat.

Samotná problematika SDM představuje velmi obsáhlé a složité téma, jehož šířka přesahuje zadání diplomové práce. Z toho důvodu bylo zvoleno vyhodnocení dat v celém zájmovém území s použitím GLR, která dokáže vypočítat pravděpodobnosti výskytu v kvadrátu, což také splňuje cíl práce (nalezení potenciálního rozšíření druhů v krajině). Výsledné GLR modely byly sestaveny pro šest vybraných druhů ptactva. Následně při vypočtení Global Moran's I indexu z reziduí modelů byla nalezena prostorová autokorelace a shlukování reziduí v jednotlivých modelech. Prostorová autokorelace, která je v případě biogeografických dat převážně pozitivní, je při statistických analýzách prostorových dat častým jevem. V případě prostorové autokorelace platí první zákon geografie podle Tobler (1970), který definuje, že všechno souvisí se vším, ale bližší věci jsou si více podobné než vzdálenější. Jedna z příčin autokorelace může být opomenutí jedné nebo více vysvětlujících proměnných (testovány byly pouze proměnné

z oblasti krajinných charakteristik). Nabízí se tak otázka prozkoumání dalších fyzicko-geografických charakteristik, které jsou používány v oblasti SDM, a případně další komplexní práce na tématu, která by se více prostorovou autokorelací zabývala a na základě níž by bylo možné vybrat soubor krajinných charakteristik, které nejsou prostorovou autokorelací zatíženy.

7. Závěr

Diplomová práce měla tři hlavní cíle. První cílem bylo s využitím moderních metod DPZ (a dat Sentinel-2 10 x 10 m/pixel a PlanetScope 3 x 3 m/pixel) extrahovat krajinné časově-prostorové charakteristiky v takové úrovni detailu, který umožní rozlišit nároky řádu pěvců, druhovou bohatost a 23 vybraných druhů v zájmovém území Krkonoš. DPZ umožňuje snadno opakovaně a objektivně (fyzikální podstata DPZ) získávat aktuální a přesné informace charakterizující habitat/stanoviště v různých měřítkách a rozlišeních.

Práce analyzovala data o výskytu ptactva v kvadrátech o velikosti 1400 x 1400 m pro českou i polskou stranu Krkonoš poskytnutá RNDr. Jiřím Flouskem, Ph.D. z KRNAP. Jednotlivé kvadráty byly popsány topografickou charakteristikou v podobě průměrné nadmořské výšky a ve dvou prostorových měřítkách spektrálními, tematickými a strukturálními charakteristikami s cílem ověřit, jaké charakteristiky jsou statisticky významné a mohou přispět k predikci výskytu. Potvrdila se hypotéza, že pro určité druhy jsou krajinné charakteristiky nadmořská výška, land cover a krajinná struktura důležité pro výskyt z hlediska habitatové preference. Byl prokázán výrazný vztah mezi třemi kategoriemi charakteristik – topografické, tematické a strukturální a výskytem následujících druhů: kos horský (*Turdus torquatus*), lejsek černohlavý (*Ficedula hypoleuca*), lejsek šedý (*Muscicapa striata*), puštík obecný (*Strix aluco*), tetřev obecný (*Lyrurus tetrix*) a sýc rousný (*Aegolius funereus*), v jehož případě nebyl tak výrazný vliv nadmořské výšky. Naopak pro druhy kalous ušatý (*Asio otus*), konipas horský (*Motacilla cinerea*), králíček ohnivý (*Regulus ignicapilla*) a krkavec velký (*Corvus corax*) nebylo možné na základě zvolené metodiky najít korelace větší než velmi slabé a nebyl potvrzen předpoklad nalezení charakteristik jakožto vysvětlujících proměnných výskytu. U těchto druhů tak nebylo možné dále sestavit regresní model.

Tematické charakteristiky z oblasti tundry byly relevantní pro druhy slavíků modráček tundrový (*Luscinia svecica svecica*) a linduška horská (*Anthus spinoletta*).

Nepotvrdila se hypotéza, že v případě použití dat dvou typů dat s různým prostorovým rozlišením (Sentinel-2 a PlanetScope) bude dosaženo pro extrakci krajinných charakteristik lepších výsledků s použitím prostorově podrobnějších dat (PlanetScope). Roli může hrát i rozdílné spektrální rozlišení obou typů dat. Na základě metrik MPS a NP byla ale potvrzena hypotéza, že řád pěvců vyhledává fragmentovanější krajinu s menší průměrnou velikostí plošky nebo větším počtem plošek.

Druhým cílem bylo porovnat využitelnost/přínos, vypovídající schopnost a míru dosažitelné informace klasifikací land cover s dalšími dostupnými datovými produkty (CLC, N2K a VMB

NATURA 2000). Hlavním nedostatkem CLC 2018 bylo nejmenší prostorové rozlišení z testovaných produktů a perioda aktualizace šest let. Data N2K 2018 jsou dostupná pouze pro určitá specifická území a jejich perioda aktualizace je také šest let. VMB NATURA 2000 mají nejdelší periodu aktualizace dvanáct let s použitím časově a finančně náročného terénního mapování. Bylo tedy prokázáno, že časové řady dat dálkového průzkumu Země jsou vhodnějším zdrojem informací než dostupné produkty a že DPZ je vhodnou a důležitou metodou pro analýzy tohoto typu.

Třetím cílem bylo predikovat místa s potenciálním rozšířením vybraných druhů a výsledek porovnat s nálezovou databází AOPK. Pro vybraných šest ptačích druhů, u kterých byly krajinné charakteristiky relevantní, byly sestaveny regresní modely, které určily pravděpodobnosti výskytu druhu v kvadrátu a statisticky významné vysvětlující proměnné. Výsledky regresních modelů tak potvrdily poslední hypotézu, která měla za cíl nalézt alespoň jeden druh vázaný na určité podmínky a vypočítat v kvadrátech zájmového území jeho pravděpodobnost výskytu za pomoci vhodně zvolených vysvětlujících charakteristik.

Téma diplomové práce by mohlo být dále rozvíjeno v několika směrech. Prvním směrem je využít získané výsledky a na základě výběru jedné určité charakteristiky podrobněji prozkoumat, jak může přispět k výskytu určitého druhu. Druhou možností je prozkoumat, jak se jednotlivé habitaty spektrálně měnily v průběhu času (např. využít data programu Landsat v kombinaci s bodovými daty o výskytu). Dalším směrem je využití charakteristik získaných z dat DPZ pro modelování výskytu určitého druhu (problematika SDM je široké téma) na větším zájmovém území (např. celá Česká republika nebo Evropa). Při modelování by mohlo být provedeno otestování různých parametrických (statistických) a neparametrických (machine learning) metod, např. se nabízí možnost použití balíčku SDM v prostředí R či dalších nástrojů (openModeller nebo Spatial Analysis in Macroecology). Náročnější úlohou spíše na úrovni dizertační práce nebo projektového výzkumu je pak analýza vlivu autokorelace prostorových dat a její možné odstranění.

Seznam použité literatury a zdrojů

- ANDERSON, J. R., HARDY, E. E., ROACH, J. T., WITMER, R. E. (1976): A land use and land cover classification system for use with remote sensor data. Geological Survey Professional Paper No. 964, 1–28.
- BAILEY, D., HERZOG, F., AUGENSTEIN, I., AVIRON, S., BILLETER, R., SZERENCSEITS, E., BAUDRY, J. (2007): Thematic resolution matters: Indicators of landscape pattern for European agro-ecosystems. *Ecological Indicators*, 3, 7, 692–709.
- BALDWIN, D. J. B., WEAVER, K., SCHNEKENBURGER, F., PERERA, A. H. (2004): Sensitivity of landscape pattern indices to input data characteristics on real landscapes: implications for their use in natural disturbance emulation. *Landscape Ecology*, 3, 19, 255–271.
- BASNET, T. B., ROKAYA, M. B., BHATTARAI, B. P., MÜNZBERGOVÁ, Z. (2016): Heterogeneous landscapes on steep slopes at low altitudes as hotspots of bird diversity in a Hilly Region of Nepal in the Central Himalayas. *PLoS ONE*, 3, 11, 1–19.
- BENNETT, A. F., RADFORD, J. Q., HASLEM, A. (2006): Properties of land mosaics: Implications for nature conservation in agricultural environments. *Biological Conservation*, 2, 133, 250–264.
- BIBBY, C. J., BURGESS, N. D., HILL, D. A. (2000): Bird census techniques. 2nd Edition. Academic Press, London.
- BINO, G., LEVIN, N., DARAWSHI, S., VAN DER HAL, N., REICH-SOLOMON, A., KARK, S. (2008): Accurate prediction of bird species richness patterns in an urban environment using Landsat-derived NDVI and spectral unmixing. *International Journal of Remote Sensing*, 13, 29, 3675–3700.
- BONTHOUX, S., LEFÈVRE, S., HERRAULT, P. A., SHEEREN, D. (2018): Spatial and temporal dependency of NDVI satellite imagery in predicting bird diversity over France. *Remote Sensing*, 7, 10, 1–22.
- BRADLEY, B. A., OLSSON, A. D., WANG, O., DICKSON, B. G., PELECH, L., SESNIE, S. E., ZACHMANN, L. J. (2012): Species detection vs. habitat suitability: Are we biasing habitat suitability models with remotely sensed data? *Ecological Modelling*, 244, 57–64.

- BREIMAN, L. (2001): Random Forests. *Machine Learning* 2001, 1, 45, 5–32.
- BUSHRA, A., PADALIA, H., KHAN, A. (2021): Predicting spatial patterns of bird richness in an urban landscape in Himalayan foothills, India. *Urban Ecosystems*, 3, 24, 451–467.
- BUYANTUYEV, A., WU, J. (2007): Effects of thematic resolution on landscape pattern analysis. *Landscape Ecology*, 1, 22, 7–13.
- CERESA, F., BOGLIANI, G., PEDRINI, P., BRAMBILLA, M. (2012): The importance of key marginal habitat features for birds in farmland: An assessment of habitat preferences of Red-backed Shrikes *Lanius collurio* in the Italian Alps. *Bird Study*, 3, 59, 327–334.
- COPERNICUS (2021): Copernicus Open Access Hub,
<https://scihub.copernicus.eu/dhus/#/home> (cit. 1. 10. 2021).
- COPERNICUS (2022a): CLC 2018 — Copernicus Land Monitoring Service,
<https://land.copernicus.eu/pan-european/corine-land-cover/clc2018> (cit. 20. 3. 2022).
- COPERNICUS (2022b): EU-DEM v1.0 — Copernicus Land Monitoring Service,
<https://land.copernicus.eu/imagery-in-situ/eu-dem/eu-dem-v1-0-and-derived-products/eu-dem-v1.0?tab=metadata> (cit. 17. 6. 2022).
- COPERNICUS (2022c): N2K 2018 — Copernicus Land Monitoring Service,
<https://land.copernicus.eu/local/natura/n2k-2018> (cit. 20. 3. 2022).
- CORD, A. F., MEENTEMEYER, R. K., LEITÃO, P. J., VÁCLAVÍK, T. (2013): Modelling species distributions with remote sensing data: Bridging disciplinary perspectives. *Journal of Biogeography*, 12, 40, 2226–2227.
- DELCOURT, H. R., DELCOURT, P. A. (1996): Presettlement landscape heterogeneity: Evaluating grain of resolution using General Land Office Survey data. *Landscape Ecology*, 6, 11, 363–381.
- ELITH, J., LEATHWICK, J. R. (2009): Species distribution models: Ecological explanation and prediction across space and time. *Annual Review of Ecology, Evolution, and Systematics*, 40, 677–697.
- ESA (2021): Sentinel-2 - Data Products - Sentinel Handbook - Sentinel Online,
<https://sentinel.esa.int/web/sentinel/missions/sentinel-2/data-products> (cit. 15. 10. 2021).

ESA (2022a): MSI Instrument – Sentinel-2 MSI Technical Guide – Sentinel Online - Sentinel Online, <https://sentinel.esa.int/web/sentinel/technical-guides/sentinel-2-msi/msi-instrument> (cit. 15. 5. 2022).

ESA (2022b): PlanetScope - Earth Online, <https://earth.esa.int/eogateway/missions/planetscope> (cit. 15. 5. 2022).

ESRI (2022): Generalized Linear Regression (GLR) (Spatial Statistics)—ArcGIS Pro | Documentation, <https://pro.arcgis.com/en/pro-app/latest/tool-reference/spatial-statistics/generalized-linear-regression.htm> (cit. 20. 3. 2022).

EVANS, J. D. (1996): Straightforward statistics for the behavioral sciences. Brooks/Cole Pub. Co., Pacific Grove.

FANTA, J. (1969): Příroda Krkonošského národního parku. SZN, Praha.

FARINA, A. (2007): Principles and Methods in Landscape Ecology: Towards a Science of Landscape: Towards a Science of the Landscape. Springer-Verlag New York Inc, New York.

FASSNACHT, F. E., HARTIG, F., LATIFI, H., BERGER, C., HERNÁNDEZ, J., CORVALÁN, P., KOCH, B. (2014): Importance of sample size, data type and prediction method for remote sensing-based estimations of aboveground forest biomass. *Remote Sensing of Environment*, 1, 154, 102–114.

FERRARI, J. R., LOOKINGBILL, T. R., NEEL, M. C. (2007): Two measures of landscape-graph connectivity: Assessment across gradients in area and configuration. *Landscape Ecology*, 9, 22, 1315–1323.

FLASPOHLER, D. J., GIARDINA, C. P., ASNER, G. P., HART, P., PRICE, J., LYONS, C. K. apu, CASTANEDA, X. (2010): Long-term effects of fragmentation and fragment properties on bird species richness in Hawaiian forests. *Biological Conservation*, 2, 143, 280–288.

FLOUSEK, J., GRAMSZ, B., TELENSKÝ, T. (2015): Ptáci Krkonoš – atlas hnízdního rozšíření 2012–2014. Správa KRNAP, Dyrekcja KPN, Vrchlabí, Jelenia Góra.

FOODY, G. M. (2002): Status of land cover classification accuracy assessment. *Remote Sensing of Environment*, 1, 80, 185–201.

- FOODY, G. M., MATHUR, A., SANCHEZ-HERNANDEZ, C., BOYD, D. S. (2006): Training set size requirements for the classification of a specific class. *Remote Sensing of Environment*, 1, 104, 1–14.
- FORMAN, R. T. T., GODRON, M. (1986): *Landscape Ecology*. John Wiley and Sons Ltd, New York.
- FORMAN, R. T. T., GODRON, M. (1993): *Krajinná ekologie*. Academia, Praha.
- FORTIN, M. J., BOOTS, B., CSILLAG, F., REMMEL, T. K. (2003): On the role of spatial stochastic models in understanding landscape indices in ecology. *undefined*, 1, 102, 203–212.
- FRETWELL, P. T., TRATHAN, P. N. (2009): Penguins from space: faecal stains reveal the location of emperor penguin colonies. *Global Ecology and Biogeography*, 5, 18, 543–552.
- GAO, B. C. (1996): NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 3, 58, 257–266.
- GEE (2021): Google Earth Engine Documentation, <https://code.earthengine.google.com/> (cit. 15. 5. 2022).
- GILLESPIE, T. W., FOODY, G. M., ROCCHINI, D., GIORGI, A. P., SAATCHI, S. (2008): Measuring and modelling biodiversity from space. *Progress in Physical Geography*, 2, 32, 203–221.
- GOTTSCHALK, T. K., AUE, B., HOTES, S., EKSCHMITT, K. (2011): Influence of grain size on species-habitat models. *Ecological Modelling*, 18, 222, 3403–3412.
- GOTTSCHALK, T. K., HUETTMANN, F., EHLERS, M. (2005): Thirty years of analysing and modelling avian habitat relationships using satellite imagery data: A review. *International Journal of Remote Sensing*, 12, 26, 2631–2656.
- GUISAN, A., THUILLER, W., ZIMMERMANN, N. E. (2017): *Habitat Suitability and Distribution Models*. Cambridge University Press, Cambridge.
- HAGEMEIJER, W. J. M., BLAIR, M. J. (1997): *The EBCC atlas of European breeding birds: their distribution and abundance*. T & A D Poyser, London.
- HO, T. K. (1995): Random Decision Forests. In: *Proceedings of the 3rd International Conference on Document Analysis and Recognition*. IEEE Computer Society, Montreal, 278–282.

- HUETE, A. R. (1988): A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 3, 25, 295–309.
- CHYTRÝ, M., KUČERA, T., KOČÍ, M., GRULICH, V., LUSTYK, P. eds. (2010): Katalog biotopů České republiky. Ed. 2. Agentura ochrany přírody a krajiny ČR, Praha.
- KAUTH, R. J., THOMAS, G. S. (1976): The Tasselled Cap-A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT. In: *Proceedings, Symposium on Machine Processing of Remotely Sensed Data*. 41–51.
- KNAPIK, R., RAJA, A. (2013): *Przyroda Karkonoskiego Parku Narodowego*. KPN, Jelenia Góra.
- KORCHAGINA, I. A., GOLEVA, O. G., SAVCHENKO, Y. Y., BOZHIKOV, T. S. (2020): The use of geographic information systems for forest monitoring. *Journal of Physics: Conference Series*, 1515, 32077.
- KRNAP (2010): Krkonošská arkto-alpínská tundra | Správa Krkonošského národního parku, <https://www.krnep.cz/krkonosska-arkto-alpinska-tundra/> (cit. 29. 12. 2021).
- KRNAP (2022a): Geologie | Správa Krkonošského národního parku, <https://www.krnep.cz/geologie/> (cit. 13. 6. 2022).
- KRNAP (2022b): Příroda a historie | Správa Krkonošského národního parku, <https://www.krnep.cz/priroda-a-historie/> (cit. 11. 6. 2022).
- KRNAP (2022c): Půdy Krkonoš | Správa Krkonošského národního parku, <https://www.krnep.cz/pudy-krkonos/> (cit. 13. 6. 2022).
- KUENZER, C., OTTINGER, M., WEGMANN, M., GUO, H., WANG, C., ZHANG, J., DECH, S., WIKELSKI, M. (2014): Earth observation satellite sensors for biodiversity monitoring : potentials and bottlenecks. *International Journal of Remote Sensing*, 18, 35, 6599–6647.
- L3HARRIS (2022a): Region of Interest (ROI) Tool, <https://www.l3harrisgeospatial.com/docs/regionofinteresttool.html> (cit. 26. 7. 2022).
- L3HARRIS (2022b): Vegetation Analysis: Using Vegetation Indices in ENVI - L3Harris Geospatial, <https://www.l3harrisgeospatial.com/Learn/Whitepapers/Whitepaper->

Detail/ArtMID/17811/ArticleID/16162/Vegetation-Analysis-Using-Vegetation-Indices-in-ENVI (cit. 17. 6. 2022).

LABGUIDE (2015): ELEKTROMAGNETICKÉ SPEKTRUM | LabGuide.cz, <https://labguide.cz/fluorochromy/elektromagneticke-spektrum/> (cit. 14. 3. 2022).

LAUSCH, A., BLASCHKE, T., HAASE, D., HERZOG, F., SYRBE, R. U., TISCHENDORF, L., WALZ, U. (2015): Understanding and quantifying landscape structure - A review on relevant process characteristics, data models and landscape metrics. *Ecological Modelling*, 1, 295, 31–41.

LE, H., SAMARAS, D., LYNCH, H. J. (2021): A convolutional neural network architecture designed for the automated survey of seabird colonies. *Remote Sensing in Ecology and Conservation*, 2, 8, 251–262.

LECHNER, A., LANGFORD, W., BEKESSY, S., JONES, S. (2012): Are landscape ecologists addressing uncertainty in their remote sensing data? *Landscape Ecology*, 9, 27, 1249–1261.

LEYEQUIEN, E., VERRELST, J., SLOT, M., SCHAEPMAN-STRUB, G., HEITKÖNIG, I. M. A., SKIDMORE, A. (2007): Capturing the fugitive: Applying remote sensing to terrestrial animal distribution and diversity. *International Journal of Applied Earth Observation and Geoinformation*, 1, 9, 1–20.

LI, H., WU, J. (2004): Use and misuse of landscape indices. *Landscape Ecology*, 4, 19, 389–399.

LOKVENC, T. (1978): Toulky krkonošskou minulostí. Kruh, Hradec Králové.

LOPEZ, R., FROHN, R. (2017): *Remote Sensing for Landscape Ecology*. CRC Press, Boca Raton.

LUSTYK, P., GUTH, J. (2011): Metodika aktualizace vrstvy mapování biotopů. Agentura ochrany přírody a krajiny ČR, Praha.

LUSTYK, P., OUŠKOVÁ, V. (2011): Vrstva mapování biotopů a její aktualizace – první možnosti srovnání dat. *Ochrana přírody*, 4, 20–22.

MARTINI, B. F., MILLER, D. A. (2021): Using object-based image analysis to detect laughing gull nests. *GIScience and Remote Sensing*, 8, 58, 1497–1517.

- MATĚJČEK, T. (2007): Malý geografický a ekologický slovník : příručka pro školy i veřejnost. Nakladatelství České geografické společnosti, Praha.
- MATERNA, J. (1991): Vliv rozptýlené zeleně v zemědělské krajině krkonošského podhůří na společenstva hnízdících ptáků. *Prunella*, 17, 14–20.
- MCGARIGAL, K. (2015): Fragstats Help 4.2.,
<https://ibis.geog.ubc.ca/courses/geob479/labs/fragstats.help.4.pdf> (cit. 29. 12. 2021).
- MORELLI, F. (2013): Relative importance of marginal vegetation (shrubs, hedgerows, isolated trees) surrogate of HNV farmland for bird species distribution in Central Italy. *Ecological Engineering*, 57, 261–266.
- MORELLI, F. (2017): Birds as Useful Indicators of High Nature Value Farmlands. Springer, Cham.
- MORELLI, F., BENEDETTI, Y., ŠÍMOVÁ, P. (2018): Landscape metrics as indicators of avian diversity and community measures. *Ecological Indicators*, 90, 132–141.
- MUNI (2022): Pearsonův korelační koeficient | Math and Stats Support Centre | MUNI ECON, https://mathstat.econ.muni.cz/media/12657/pear_cor.pdf (cit. 4. 5. 2022).
- MYEASYFARM (2021): Using NDVI maps on MyEasyFarm - MyEasyFarm,
<https://www.myeasyfarm.com/en/actu-ndvi20200907> (cit. 4. 1. 2022).
- NIETO, S., FLOMBAUM, P., GARBULSKY, M. F. (2015): Can temporal and spatial NDVI predict regional bird-species richness? *Global Ecology and Conservation*, 3, 729–735.
- NOVÁK, I. (2015): Účinky elektromagnetického pole na lidský organismus - TZB-info,
<https://elektro.tzb-info.cz/13319-ucinky-elektromagnetickeho-pole-na-lidsky-organismus> (cit. 14. 3. 2022).
- O’SULLIVAN, D., UNWIN, D. J. (2010): Geographic Information Analysis: Second Edition. John Wiley and Sons, Hoboken.
- OESER, J., HEURICH, M., SENF, C., PFLUGMACHER, D., BELOTTI, E., KUEMMERLE, T. (2020): Habitat metrics based on multi-temporal Landsat imagery for mapping large mammal habitat. *Remote Sensing in Ecology and Conservation*, 1, 6, 52–69.

- ONDRUŠKOVÁ, K. (2016): Porovnání mapování NATURA 2000 s výstupy mapování pomocí dálkového průzkumu Země na příkladu krkonošské tundry. Bakalářská práce. Univerzita Karlova, Přírodovědecká fakulta, katedra aplikované geoinformatiky a kartografie, Praha.
- PASCUAL-HORTAL, L., SAURA, S. (2007): Impact of spatial scale on the identification of critical habitat patches for the maintenance of landscape connectivity. *Landscape and Urban Planning*, 2–3, 83, 176–186.
- PETERSON, A. T., PAPES, M. (2006): Potential geographic distribution of the Bugun *Liocichla Liocichla bugunorum*, a poorly-known species from north-eastern India. *Indian Birds*, 6, 2, 146–149.
- POMEROY, D., DRANZOA, C. (1997): Methods of studying the distribution, diversity and abundance of birds in East Africa - Some quantitative approaches. *African Journal of Ecology*, 2, 35, 110–123.
- PRATICÒ, S., SOLANO, F., DI FAZIO, S., MODICA, G. (2021): Machine Learning Classification of Mediterranean Forest Habitats in Google Earth Engine Based on Seasonal Sentinel-2 Time-Series and Input Image Composition Optimisation. *Remote Sensing*, 4, 13, 586.
- QIAN, Y., ZHOU, W., YAN, J., LI, W., HAN, L. (2015): Comparing machine learning classifiers for object-based land cover classification using very high resolution imagery. *Remote Sensing*, 1, 7, 153–168.
- RAMEZAN, C. A., WARNER, T. A., MAXWELL, A. E., PRICE, B. S. (2021): Effects of training set size on supervised machine-learning land-cover classification of large-area high-resolution remotely sensed data. *Remote Sensing*, 3, 13, 1–27.
- REGOS, A., DOMÍNGUEZ, J., GIL-TENA, A., BROTONS, L., NINYEROLA, M., PONS, X. (2016): Rural abandoned landscapes and bird assemblages: winners and losers in the rewilding of a marginal mountain area (NW Spain). *Regional Environmental Change*, 1, 16, 199–211.
- ROCCHINI, D., MARCANTONIO, M., DA RE, D., CHIRICI, G., GALLUZZI, M., LENOIR, J., RICOTTA, C., TORRESANI, M., ZIV, G. (2019): Time-lapsing biodiversity: An open source method for measuring diversity changes by remote sensing. *Remote Sensing of Environment*, 231, 111–192.

RODRIGUEZ-GALIANO, V. F., GHIMIRE, B., ROGAN, J., CHICA-OLMO, M., RIGOL-SANCHEZ, J. P. (2012): An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 1, 67, 93–104.

ROUSE, J. W., HAAS, R. H., SCHELL, J. A., DEERING, D. W. (1974): Monitoring vegetation systems in the Great Plains with ERTS. In: Fraden, S. C., Marcanti, E. P., Becker, M. A. (eds.). *Third ERTS- 1 Symposium*, Washington DC, 309–317.

SANTHAKUMAR, B., ARUN, P. R., SONY, R. K., MURUGESAN, M., RAMESH, C. (2018): The pattern of bird distribution along the elevation gradient of the Sutlej River basin, western Himalaya, India. *Journal of Threatened Taxa*, 13, 10, 12715–12725.

SASAMAL, S. K., CHAUDHURY, S. B., SAMAL, R. N., PATTANAIK, A. K. (2008): QuickBird spots flamingos off Nalabana Island, Chilika Lake, India. *International Journal of Remote Sensing*, 16, 29, 4865–4870.

SAURA, S., CASTRO, S. (2007): Scaling functions for landscape pattern metrics derived from remotely sensed data: Are their subpixel estimates really accurate? *ISPRS Journal of Photogrammetry and Remote Sensing*, 3, 62, 201–216.

SEIDLOVÁ, J. (2018): Využitelnost neklasifikovaných družicových snímků pro identifikaci biotopu tetřívka obecného (*Tetrao tetrix*) v Krušných horách. Diplomová práce. Česká zemědělská univerzita v Praze, fakulta životního prostředí, katedra aplikované geoinformatiky a územního plánování, Praha.

SHANG, M., WANG, S.-X., ZHOU, Y., DU, C. (2018): Effects of Training Samples and Classifiers on Classification of Landsat-8 Imagery. *Journal of the Indian Society of Remote Sensing*, 9, 46, 1333–1340.

SHEEREN, D., BONTHOUX, S., BALENT, G. (2014): Modeling bird communities using unclassified remote sensing imagery: Effects of the spatial resolution and data period. *Ecological Indicators*, 43, 69–82.

SHI, T., XU, H. (2019): Derivation of Tasseled Cap Transformation Coefficients for Sentinel-2 MSI At-Sensor Reflectance Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10, 12, 4038–4048.

SHIRLEY, S. M., YANG, Z., HUTCHINSON, R. A., ALEXANDER, J. D., MCGARIGAL, K., BETTS, M. G. (2013): Species distribution modelling for the people: Unclassified landsat TM imagery predicts bird occurrence at fine resolutions. *Diversity and Distributions*, 7, 19, 855–866.

SCHOWENGERDT, R. A. (2006): *Remote Sensing: Models and Methods for Image Processing*. Elsevier Inc., Tucson.

SCHWALLER, M. R., OLSON, C. E., MA, Z., ZHU, Z., DAHMER, P. (1989): A remote sensing analysis of Adélie penguin rookeries. *Remote Sensing of Environment* 28, 199–206.

ŠÍMOVÁ, P. (2017): Identifying HNV Areas Using Geographic Information Systems and Landscape Metrics. In: *Birds as Useful Indicators of High Nature Value Farmlands*. Springer, Cham, 124.

ŠÍMOVÁ, P., GDULOVÁ, K. (2012): Landscape indices behavior: A review of scale effects. *Applied Geography*, 34, 385–394.

ŠOUREK, J. (1969): *Květena Krkonoš*. Academia, Praha.

SÝRORA, B. (1983): *Krkonošský národní park*. SZN, Praha.

TAMIMINIA, H., SALEHI, B., MAHDIANPARI, M., QUACKENBUSH, L., ADELI, S., BRISCO, B. (2020): Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 152–170.

THANH NOI, P., KAPPAS, M. (2017): Comparison of Random Forest, k-Nearest Neighbor, and Support Vector Machine Classifiers for Land Cover Classification Using Sentinel-2 Imagery. *Sensors*, 2, 18, 18.

TOBLER, W. R. (1970): A Computer Movie Simulating Urban Growth in the Detroit Region. *Economic Geography*, 46, 234-240.

TRYJANOWSKI, P. (2017): Bird Count Methods for Farmland Systems: Single- Habitat and Multi-habitat Species. In: Morelli, F., Tryjanowski, P. (eds.): *Birds as Useful Indicators of High Nature Value Farmlands*. Springer, Cham, 120.

USGS (2022): NDVI, the Foundation for Remote Sensing Phenology | U.S. Geological Survey, <https://www.usgs.gov/special-topics/remote-sensing-phenology/science/ndvi-foundation-remote-sensing-phenology> (cit. 17. 6. 2022).

VACEK, S., SIMON, J., MINX, T., PODRÁZSKÝ, V., BALCAR, Z. (2007): Struktura a vývoj lesních ekosystémů v Krkonoších. *Opera Corcontica*, 1, 44, 415–424.

VLČKOVÁ, E. (2016): Srovnání výpočetních algoritmů pro prostorovou distribuci druhů. Bakalářská práce. Univerzita Palackého v Olomouci, Přírodovědecká fakulta, katedra geoinformatiky, Olomouc.

WATTS, K., HANDLEY, P. (2010): Developing a functional connectivity indicator to detect change in fragmented landscapes. *Ecological Indicators*, 10, 2, 552–557.

WHEATLEY, M. (2010): Domains of scale in forest-landscape metrics: Implications for species-habitat modeling. *Acta Oecologica*, 2, 36, 259–267.

WU, J. (2004): Effects of changing scale on landscape pattern analysis: Scaling relations. *Landscape Ecology*, 2, 19, 125–138.


YIU, T. (2019): Understanding Random Forest How the Algorithm Works and Why it Is So Effective, <https://towardsdatascience.com/understanding-random-forest-58381e0602d2> (cit. 14. 10. 2021).

Přílohy

Příloha 1: CLC 2018 pro zájmové území kvadrátů	99
Příloha 2: N2K 2018 pro zájmové území kvadrátů	100
Příloha 3: Kategorizace průkaznosti výskytu druhů v datech	101
Příloha 4: Výsledky testu separability Sentinel-2	102
Příloha 5: Výsledky testu separability PlanetScope	103
Příloha 6: Klasifikační kategorie legendy	104
Příloha 7: Přehled vypočtených metrik pro úroveň krajiny v balíčku landscape metrics	108
Příloha 8: Průměrná nadmořská výška	110
Příloha 9: Spektrální indexy Sentinel-2 27. 8. 2016	111
Příloha 10: Spektrální indexy PlanetScope 30.6.2019	112
Příloha 11: Pearsonův korelační koeficient mezi nadmořskou výškou, spektrálními metrikami a výskytem druhů	113
Příloha 12: Výsledná klasifikace Krkonoš z dat Sentinel-2 27. srpna 2016	114
Příloha 13: Výsledná klasifikace Krkonoš z dat PlanetScope 30. června 2019	115
Příloha 14: Porovnání třídy zástavba CORINE land cover 2018 a klasifikace dat Sentinel-2	116
Příloha 15: Pearsonův korelační koeficient mezi kategoriemi land cover a ptactvem, Sentinel-2	117
Příloha 16: Pearsonův korelační koeficient mezi kategoriemi land cover a ptactvem, PlanetScope	118
Příloha 17: Počet plošek (NP)	119
Příloha 18: Průměrná velikost plošky (MPS) v hektarech	120
Příloha 19: Celková délka hranic (TE) v metrech	121
Příloha 20: Metriky SHDI a SISI	122
Příloha 21: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky agregace) a ptačími druhy, Sentinel-2	123
Příloha 22: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky plocha) a ptačími druhy, Sentinel-2	124
Příloha 23: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky komplexnosti) a ptačími druhy, Sentinel-2	125
Příloha 24: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky CORE) a ptačími druhy, Sentinel-2	126


Příloha 25: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky diverzity) a ptačími druhy, Sentinel-2	127
Příloha 26: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky tvaru) a ptačími druhy, Sentinel-2	128
Příloha 27: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky agregace) a ptačími druhy, PlanetScope.....	129
Příloha 28: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky plochy (area)) a ptačími druhy, PlanetScope.....	130
Příloha 29: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky komplexnosti) a ptačími druhy, PlanetScope	131
Příloha 30: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky core) a ptačími druhy, PlanetScope	132
Příloha 31: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky diverzity) a ptačími druhy, PlanetScope.....	133
Příloha 32: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky tvaru) a ptačími druhy, PlanetScope.....	134

Příloha 1: CLC 2018 pro zájmové území kvadrátů



Zdroj: Vlastní tvorba, Copernicus (2022a)

Příloha 2: N2K 2018 pro zájmové území kvadrátů



Zdroj: Vlastní tvorba, Copernicus (2022c)

Příloha 3: Kategorizace průkaznosti výskytu druhů v datech

Hodnota	Popis
<i>B 1</i>	<i>Druh pozorovaný v době hnízdění a ve vhodném prostředí</i>
<i>B 2</i>	<i>Pozorování zpívajícího samce (či samců) anebo zaslechnutí hlasů souvisejících s hnízděním ve hnízdním období</i>
<i>C 3</i>	<i>Pár (samec, samice) pozorovaný ve vhodném hnízdním prostředí v době hnízdění</i>
<i>C 4</i>	<i>Stálý okrsek předpokládáný na základě pozorovaného teritoriálního chování (např. zahánění soků, zpěv apod.)</i>
<i>C 5</i>	<i>Pozorování toku a imponování nebo páření</i>
<i>C 6</i>	<i>Hledání pravděpodobných hnízdišť</i>
<i>C 7</i>	<i>Vzrušené chování a varování starých ptáků nejspíše v blízkosti hnízda či mládřat</i>
<i>C 8</i>	<i>Přítomnost hnízdních nažin u chycených starých ptáků</i>
<i>C 9</i>	<i>Starí ptáci pozorováni při stavbě hnízda nebo dlabání hnízdní dutiny</i>
<i>D 10</i>	<i>Odpoutávání pozornosti od hnízda nebo mládřat a předstírání zranění</i>
<i>D 11</i>	<i>Nález použitého hnízda, obydleného či opuštěného během pozorování, se zbytky vaječných skořápek</i>
<i>D 12</i>	<i>Nález čerstvě vylétaných mládřat (u krmivých) nebo mládřat v prachovém opeření (u nekrmivých)</i>
<i>D 13</i>	<i>Pozorování starých ptáků přilétajících či odlétajících z hnízdiště za okolností, které nasvědčují přítomnosti obsazeného hnízda (včetně vysoko umístěných hnízd z/anebo hnízdních dutin, do nichž není vidět), pozorování starých ptáků vysezujících snůšky</i>
<i>D 14</i>	<i>Pozorování starých ptáků při odnášení trusu od hnízda nebo přinášení potravy mládřatům</i>
<i>D 15</i>	<i>Nález hnízda s vejci</i>
<i>D 16</i>	<i>Nález hnízda s mládřaty, viděnými nebo slyšenými</i>

Zdroj: Flousek, Gramsz, Telenský (2015, s. 48)

Příloha 4: Výsledky testu separability Sentinel-2

kat [Trvalý travní porost] a kat [Orná půda] - 1,73436663
kat [Holiny a mlaziny] a kat [Trvalý travní porost] - 1,95737341
kat [Listnatý a smíšený les] a kat [Holiny a mlaziny] - 1,97345188
kat [Jehličnatý les] a kat [Listnatý a smíšený les] - 1,98389344
kat [Jehličnatý les] a kat [Holiny a mlaziny] - 1,98576925
kat [Holiny a mlaziny] a kat [Orná půda] - 1,98601733
kat [Listnatý a smíšený les] a kat [Orná půda] - 1,99308995
kat [Orná půda] a kat [Zástavba] - 1,99379625
kat [Listnatý a smíšený les] a kat [Trvalý travní porost] - 1,99874806
kat [Holiny a mlaziny] a kat [Zástavba] - 1,99995546
kat [Trvalý travní porost] a kat [Zástavba] - 1,99996761
kat [Listnatý a smíšený les] a kat [Zástavba] - 1,99998911
kat [Jehličnatý les] a kat [Orná půda] - 1,99999535
kat [Jehličnatý les] a kat [Zástavba] - 1,99999931
kat [Listnatý a smíšený les] a kat [Vodní plocha] - 1,99999955
kat [Jehličnatý les] a kat [Vodní plocha] - 1,99999975
kat [Vodní plocha] a kat [Zástavba] - 1,99999982
kat [Holiny a mlaziny] a kat [Vodní plocha] - 1,99999983
kat [Jehličnatý les] a kat [Trvalý travní porost] - 1,99999997
kat [Orná půda] a kat [Vodní plocha] - 2,00000000
kat [Trvalý travní porost] a kat [Vodní plocha] - 2,00000000

kat_t [Horská louka] a kat_t [Keříčková vegetace] - 1,80544740
kat_t [Keříčková vegetace] a kat_t [Kosodřevina] - 1,99049287
kat_t [Kamenná moře] a kat_t [Keříčková vegetace] - 1,99338523
kat_t [Horská louka] a kat_t [Kosodřevina] - 1,99969189
kat_t [Kamenná moře] a kat_t [Kosodřevina] - 1,99975106
kat_t [Horská louka] a kat_t [Kamenná moře] - 1,99987901
kat_t [Vodní plocha] a kat_t [Kamenná moře] - 1,99999798
kat_t [Vodní plocha] a kat_t [Kosodřevina] - 1,99999945
kat_t [Vodní plocha] a kat_t [Keříčková vegetace] - 2,00000000
kat_t [Vodní plocha] a kat_t [Horská louka] - 2,00000000


Příloha 5: Výsledky testu separability PlanetScope

kat [Trvalý travní porost] and kat [Orná půda] - 0,38417521
kat [Holiny a mlaziny] and kat [Trvalý travní porost] - 1,31011777
kat [Holiny a mlaziny] and kat [Orná půda] - 1,53691738
kat [Listnatý a smíšený les] and kat [Orná půda] - 1,77672172
kat [Listnatý a smíšený les] and kat [Trvalý travní porost] - 1,79546701
kat [Listnatý a smíšený les] and kat [Holiny a mlaziny] - 1,80876457
kat [Orná půda] and kat [Zástavba] - 1,80994277
kat [Jehličnatý les] and kat [Listnatý a smíšený les] - 1,87715694
kat [Jehličnatý les] and kat [Holiny a mlaziny] - 1,88732651
kat [Trvalý travní porost] and kat [Zástavba] - 1,88842930
kat [Vodní plocha] and kat [Zástavba] - 1,94038718
kat [Jehličnatý les] and kat [Orná půda] - 1,96421678
kat [Jehličnatý les] and kat [Zástavba] - 1,97970987
kat [Holiny a mlaziny] and kat [Zástavba] - 1,98716425
kat [Jehličnatý les] and kat [Trvalý travní porost] - 1,99278722
kat [Listnatý a smíšený les] and kat [Zástavba] - 1,99864039
kat [Listnatý a smíšený les] and kat [Vodní plocha] - 1,99909838
kat [Orná půda] and kat [Vodní plocha] - 1,99941122
kat [Jehličnatý les] and kat [Vodní plocha] - 1,99971448
kat [Holiny a mlaziny] and kat [Vodní plocha] - 1,99984001
kat [Trvalý travní porost] and kat [Vodní plocha] - 1,99997270

kat_t [Horská louka] a kat_t [Keříčková vegetace] - 1,25010238
kat_t [Keříčková vegetace] a kat_t [Kosodřevina] - 1,66104714
kat_t [Kamenná moře] a kat_t [Keříčková vegetace] - 1,92105449
kat_t [Horská louka] a kat_t [Kamenná moře] - 1,94730182
kat_t [Horská louka] a kat_t [Kosodřevina] - 1,99445246
kat_t [Kamenná moře] a kat_t [Kosodřevina] - 1,99698687
kat_t [Kamenná moře] a kat_t [Vodní plocha] - 1,99735808
kat_t [Keříčková vegetace] a kat_t [Vodní plocha] - 1,99983751
kat_t [Kosodřevina] a kat_t [Vodní plocha] - 1,99999273
kat_t [Horská louka] a kat_t [Vodní plocha] - 2,00000000

Příloha 6: Klasifikační kategorie legendy

Horská louka



Kamenné moře



Keříčková vegetace (borůvky, brusinky)




Kosodřevina



Vodní plocha je součástí též druhé klasifikační legendy




Jehličnatý les



Listnatý a smíšený les



Holiny, mlaziny



Trvalé travní porosty




Orná půda



Vodní plocha



Zástavba



Zdroj: ČÚZK (2021)


Příloha 7: Přehled vypočtených metrik pro úroveň krajiny v balíčku landscape metrics

metrika	jméno	typ
<i>ai</i>	<i>aggregation index</i>	<i>aggregation metric</i>
<i>area_cv</i>	<i>patch area</i>	<i>area and edge metric</i>
<i>area_mn</i>	<i>patch area</i>	<i>area and edge metric</i>
<i>area_sd</i>	<i>patch area</i>	<i>area and edge metric</i>
<i>cai_cv</i>	<i>core area index</i>	<i>core area metric</i>
<i>cai_mn</i>	<i>core area index</i>	<i>core area metric</i>
<i>cai_sd</i>	<i>core area index</i>	<i>core area metric</i>
<i>circle_cv</i>	<i>related circumscribing circle</i>	<i>shape metric</i>
<i>circle_mn</i>	<i>related circumscribing circle</i>	<i>shape metric</i>
<i>circle_sd</i>	<i>related circumscribing circle</i>	<i>shape metric</i>
<i>cohesion</i>	<i>patch cohesion index</i>	<i>aggregation metric</i>
<i>condent</i>	<i>conditional entropy</i>	<i>complexity metric</i>
<i>contag</i>	<i>connectance</i>	<i>aggregation metric</i>
<i>contig_cv</i>	<i>contiguity index</i>	<i>shape metric</i>
<i>contig_mn</i>	<i>contiguity index</i>	<i>shape metric</i>
<i>contig_sd</i>	<i>contiguity index</i>	<i>shape metric</i>
<i>core_cv</i>	<i>core area</i>	<i>core area metric</i>
<i>core_mn</i>	<i>core area</i>	<i>core area metric</i>
<i>core_sd</i>	<i>core area</i>	<i>core area metric</i>
<i>dcad</i>	<i>disjunct core area density</i>	<i>core area metric</i>
<i>dcore_cv</i>	<i>disjunct core area</i>	<i>core area metric</i>
<i>dcore_mn</i>	<i>disjunct core area</i>	<i>core area metric</i>
<i>dcore_sd</i>	<i>disjunct core area</i>	<i>core area metric</i>
<i>division</i>	<i>division index</i>	<i>aggregation metric</i>
<i>ed</i>	<i>edge density</i>	<i>area and edge metric</i>
<i>ent</i>	<i>shannon entropy</i>	<i>complexity metric</i>
<i>frac_cv</i>	<i>fractal dimension index</i>	<i>shape metric</i>
<i>frac_mn</i>	<i>fractal dimension index</i>	<i>shape metric</i>
<i>frac_sd</i>	<i>fractal dimension index</i>	<i>shape metric</i>
<i>gyrate_cv</i>	<i>radius of gyration</i>	<i>area and edge metric</i>
<i>gyrate_mn</i>	<i>radius of gyration</i>	<i>area and edge metric</i>
<i>gyrate_sd</i>	<i>radius of gyration</i>	<i>area and edge metric</i>
<i>iji</i>	<i>interspersion and juxtaposition index</i>	<i>aggregation metric</i>
<i>jointent</i>	<i>joint entropy</i>	<i>complexity metric</i>
<i>lpi</i>	<i>largest patch index</i>	<i>area and edge metric</i>
<i>lsi</i>	<i>landscape shape index</i>	<i>aggregation metric</i>
<i>mesh</i>	<i>effective mesh size</i>	<i>aggregation metric</i>

<i>msidi</i>	<i>modified simpson's diversity index</i>	<i>diversity metric</i>
<i>msiei</i>	<i>modified simpson's evenness index</i>	<i>diversity metric</i>
<i>mutinf</i>	<i>mutual information</i>	<i>complexity metric</i>
<i>ndca</i>	<i>number of disjunct core areas</i>	<i>core area metric</i>
<i>np</i>	<i>number of patches</i>	<i>aggregation metric</i>
<i>pafrac</i>	<i>perimeter-area fractal dimension</i>	<i>shape metric</i>
<i>para_cv</i>	<i>perimeter-area ratio</i>	<i>shape metric</i>
<i>para_mn</i>	<i>perimeter-area ratio</i>	<i>shape metric</i>
<i>para_sd</i>	<i>perimeter-area ratio</i>	<i>shape metric</i>
<i>pd</i>	<i>patch density</i>	<i>aggregation metric</i>
<i>pladj</i>	<i>percentage of like adjacencies</i>	<i>aggregation metric</i>
<i>pr</i>	<i>patch richness</i>	<i>diversity metric</i>
<i>prd</i>	<i>patch richness density</i>	<i>diversity metric</i>
<i>relmutinf</i>	<i>relative mutual information</i>	<i>complexity metric</i>
<i>shape_cv</i>	<i>shape index</i>	<i>shape metric</i>
<i>shape_mn</i>	<i>shape index</i>	<i>shape metric</i>
<i>shape_sd</i>	<i>shape index</i>	<i>shape metric</i>
<i>shdi</i>	<i>shannon's diversity index</i>	<i>diversity metric</i>
<i>shei</i>	<i>shannon's evenness index</i>	<i>diversity metric</i>
<i>sidi</i>	<i>simpson's diversity index</i>	<i>diversity metric</i>
<i>siei</i>	<i>simpson's evenness index</i>	<i>diversity metric</i>
<i>split</i>	<i>splitting index</i>	<i>aggregation metric</i>
<i>ta</i>	<i>total area</i>	<i>area and edge metric</i>
<i>tca</i>	<i>total core area</i>	<i>core area metric</i>
<i>te</i>	<i>total edge</i>	<i>area and edge metric</i>


Zdroj: Vlastní tvorba

Příloha 8: Průměrná nadmořská výška




Zdroj: Vlastní tvorba, Copernicus (2021)

Příloha 9: Spektrální indexy Sentinel-2 27. 8. 2016



Zdroj: Vlastní tvorba, Copernicus (2021)

Příloha 10: Spektrální indexy PlanetScope 30.6.2019




Zdroj: Vlastní tvorba, Copernicus (2021)

Příloha 11: Pearsonův korelační koeficient mezi nadmořskou výškou, spektrálními metriky a výskytem druhů

	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřevka obecná	výr velký	Počet druhů	Počet řádu pěvců
Výška	0,17	0,16	0,18	0,35	-0,17	-0,07	0,01	0,70	-0,07	-0,17	-0,19	0,02	-0,58	-0,15	-0,64	0,41	0,30	-0,44	0,38	0,40	0,29	0,68	-0,23	-0,72	-0,70
Sentinel2-NDVI	-0,15	-0,22	0,04	-0,06	0,07	-0,12	0,03	0,18	-0,02	-0,04	-0,24	0,20	-0,05	0,23	-0,27	-0,09	-0,07	-0,11	-0,11	-0,04	0,35	0,17	-0,20	-0,44	-0,41
Sentinel2-NDWI	-0,16	-0,18	0,04	-0,02	0,04	-0,09	0,05	0,29	0,00	-0,09	-0,27	0,20	-0,17	0,14	-0,40	-0,07	-0,04	-0,24	-0,08	0,00	0,42	0,29	-0,27	-0,57	-0,57
Sentinel2-SAVI	-0,15	-0,22	0,04	-0,06	0,07	-0,12	0,03	0,18	-0,02	-0,04	-0,24	0,20	-0,05	0,23	-0,26	-0,09	-0,07	-0,11	-0,11	-0,04	0,35	0,17	-0,20	-0,44	-0,41
Sentinel2-SR	-0,27	-0,27	0,01	-0,13	0,15	-0,06	0,03	0,07	0,00	0,00	-0,18	0,26	0,06	0,26	-0,15	-0,21	-0,12	-0,02	-0,26	-0,14	0,34	0,03	-0,17	-0,28	-0,28
Planet-NDVI	-0,09	-0,17	0,07	0,02	0,10	-0,09	0,04	0,26	0,03	-0,02	-0,19	0,21	-0,15	0,28	-0,33	-0,05	-0,03	-0,08	-0,07	0,01	0,35	0,24	-0,23	-0,43	-0,43
Planet-SAVI	-0,09	-0,17	0,07	0,02	0,10	-0,09	0,04	0,26	0,03	-0,02	-0,19	0,21	-0,15	0,28	-0,33	-0,05	-0,03	-0,08	-0,07	0,01	0,35	0,24	-0,23	-0,43	-0,43
Planet-SR	-0,13	-0,20	0,04	-0,02	0,15	-0,09	0,05	0,15	0,05	0,00	-0,17	0,21	-0,04	0,36	-0,21	-0,12	-0,08	0,01	-0,15	-0,05	0,29	0,11	-0,21	-0,28	-0,29


Zdroj: Vlastní tvorba

Příloha 12: Výsledná klasifikace Krkonoš z dat Sentinel-2 27. srpna 2016




Zdroj: Vlastní tvorba

Příloha 13: Výsledná klasifikace Krkonoš z dat PlanetScope 30. června 2019



Zdroj: Vlastní tvorba

Příloha 14: Porovnání třídy zástavba CORINE land cover 2018 a klasifikace dat Sentinel-2



Zdroj: Vlastní tvorba, Copernicus (2021), Copernicus (2022a)

Příloha 15: Pearsonův korelační koeficient mezi kategoriemi land cover a ptactvem, Sentinel-2

SENTINEL-2	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvci
Jehličnatý les	-0,25	-0,22	0,04	-0,15	0,03	-0,05	0,03	0,20	0,00	-0,10	-0,23	0,21	-0,09	0,10	-0,33	-0,21	-0,11	-0,23	-0,23	-0,12	0,46	0,14	-0,23	-0,53	-0,53
Listnatý les	-0,16	-0,19	-0,15	-0,28	0,25	-0,01	0,02	-0,50	0,08	0,16	0,03	0,12	0,53	0,45	0,43	-0,25	-0,19	0,45	-0,24	-0,24	-0,14	-0,52	0,09	0,43	0,43
Holiny a mlaziny	-0,12	-0,03	0,21	0,14	-0,11	-0,05	0,06	0,36	0,00	-0,05	-0,11	-0,03	-0,43	-0,17	-0,40	-0,08	0,06	-0,27	-0,06	0,07	0,18	0,52	-0,13	-0,35	-0,36
Trvalé travní porosty	0,01	0,00	-0,08	-0,03	0,00	0,09	-0,06	-0,41	-0,04	0,12	0,24	-0,18	0,30	-0,16	0,51	-0,18	-0,14	0,24	-0,17	-0,19	-0,33	-0,40	0,31	0,65	0,66
Orná půda	0,04	0,09	-0,06	-0,11	-0,02	0,18	-0,11	-0,30	0,06	0,06	0,27	-0,13	0,16	-0,14	0,32	-0,11	-0,08	0,21	-0,11	-0,12	-0,32	-0,28	0,20	0,44	0,41
Vodní plocha	0,04	0,04	-0,01	0,14	0,07	-0,02	0,04	-0,05	0,02	0,05	-0,01	-0,04	0,03	-0,04	0,06	0,00	0,00	0,01	-0,01	0,00	-0,06	-0,05	-0,02	0,22	0,15
Zástavba	-0,06	0,02	-0,05	-0,08	-0,08	0,03	0,08	-0,21	0,04	0,00	0,14	-0,11	0,17	-0,09	0,25	-0,09	-0,07	0,04	-0,09	-0,07	-0,18	-0,23	0,08	0,35	0,36
Kosodřevina	0,41	0,34	0,03	0,37	-0,15	-0,05	-0,03	0,47	-0,06	-0,08	-0,03	-0,08	-0,39	-0,13	-0,31	0,63	0,38	-0,20	0,60	0,44	-0,07	0,40	-0,08	-0,32	-0,30
Horská louka	0,55	0,38	0,00	0,34	-0,11	-0,04	0,00	0,34	-0,02	-0,13	-0,05	-0,07	-0,29	-0,09	-0,23	0,75	0,38	-0,15	0,79	0,57	-0,11	0,33	-0,05	-0,24	-0,22
Kamenné moře	0,13	0,44	-0,01	0,22	-0,10	-0,03	0,06	0,30	-0,08	-0,05	0,00	-0,07	-0,26	-0,08	-0,21	0,55	0,52	-0,14	0,45	0,43	-0,11	0,24	-0,05	-0,22	-0,20
Keříčková veg.	0,49	0,49	0,01	0,33	-0,12	-0,04	-0,01	0,37	-0,03	-0,10	-0,05	-0,07	-0,33	-0,10	-0,26	0,76	0,48	-0,17	0,82	0,50	-0,13	0,34	-0,06	-0,26	-0,24


Zdroj: Vlastní tvorba

Příloha 16: Pearsonův korelační koeficient mezi kategoriemi land cover a ptactvem, PlanetScope


PLANETSCOPE	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvci
Jehličnatý les	-0,25	-0,21	0,04	-0,15	0,02	-0,06	0,03	0,17	0,01	-0,09	-0,23	0,20	-0,08	0,11	-0,33	-0,20	-0,10	-0,23	-0,22	-0,13	0,46	0,11	-0,22	-0,54	-0,54
Listnatý les	-0,14	-0,21	-0,10	-0,21	0,25	-0,05	0,04	-0,35	0,08	0,13	-0,01	0,15	0,42	0,52	0,30	-0,22	-0,17	0,35	-0,22	-0,20	-0,04	-0,40	-0,01	0,29	0,29
Holiny a mlaziny	-0,14	-0,09	0,18	0,11	-0,02	-0,01	0,04	0,31	-0,01	-0,01	-0,06	0,07	-0,35	-0,13	-0,35	-0,12	0,02	-0,15	-0,11	0,03	0,21	0,51	-0,10	-0,28	-0,31
Trvalé travní porosty	0,00	0,04	-0,07	-0,08	-0,02	0,12	-0,07	-0,41	0,00	0,11	0,25	-0,21	0,28	-0,19	0,50	-0,19	-0,14	0,27	-0,17	-0,18	-0,38	-0,40	0,31	0,64	0,64
Orná půda	-0,04	0,03	-0,08	-0,14	-0,04	0,14	-0,02	-0,34	-0,03	0,06	0,16	-0,18	0,29	-0,11	0,39	-0,13	-0,10	0,10	-0,12	-0,13	-0,33	-0,34	0,21	0,47	0,48
Vodní plocha	0,08	0,05	-0,01	0,15	0,08	-0,02	0,04	-0,06	0,02	0,05	0,00	-0,04	0,03	-0,05	0,06	0,00	-0,01	0,01	-0,01	-0,01	-0,07	-0,05	-0,02	0,24	0,16
Zástavba	-0,04	-0,03	-0,05	-0,07	-0,07	-0,03	0,09	-0,20	0,03	-0,02	0,11	-0,10	0,16	-0,09	0,21	-0,08	-0,06	0,01	-0,07	-0,07	-0,17	-0,21	0,03	0,32	0,33
Kosodřevina	0,40	0,33	0,03	0,37	-0,15	-0,05	-0,01	0,46	-0,06	-0,08	-0,03	-0,08	-0,39	-0,12	-0,31	0,62	0,38	-0,20	0,57	0,44	-0,07	0,39	-0,08	-0,32	-0,30
Horská louka	0,57	0,39	0,00	0,36	-0,11	-0,04	-0,01	0,36	-0,02	-0,14	-0,05	-0,07	-0,31	-0,09	-0,24	0,76	0,37	-0,16	0,81	0,57	-0,12	0,35	-0,06	-0,25	-0,24
Kamenné moře	0,09	0,45	-0,01	0,21	-0,09	-0,03	0,05	0,29	-0,08	-0,04	0,01	-0,06	-0,25	-0,08	-0,20	0,55	0,54	-0,13	0,44	0,42	-0,11	0,25	-0,05	-0,20	-0,18
Keříčková veg.	0,44	0,50	0,01	0,33	-0,12	-0,04	-0,04	0,38	-0,04	-0,09	-0,04	-0,07	-0,33	-0,10	-0,26	0,71	0,50	-0,17	0,79	0,46	-0,11	0,36	-0,06	-0,26	-0,24

Zdroj: Vlastní tvorba

Příloha 17: Počet plošek (NP)



Sentinel-2




PlanetScope




Zdroj: Vlastní tvorba, Copernicus (2021)


Příloha 18: Průměrná velikost plošky (MPS) v hektarech



Sentinel-2




PlanetScope




Zdroj: Vlastní tvorba, Copernicus (2021)

Příloha 19: Celková délka hranic (TE) v metrech



Sentinel-2




PlanetScope



Zdroj: Vlastní tvorba, Copernicus (2021)

Příloha 20: Metriky SHDI a SIDI



Zdroj: Vlastní tvorba, Copernicus (2021)

Příloha 21: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky agregace) a ptáčími druhy, Sentinel-2

	bekasina otavní	bělorýt šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštílk obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádů pěvců
ai	0,03	0,04	0,11	0,13	-0,04	-0,01	-0,08	0,46	-0,06	-0,11	-0,14	0,14	-0,43	-0,06	-0,53	0,12	0,11	-0,29	0,12	0,16	0,34	0,54	-0,12	-0,62	-0,66
cohesion	0,04	-0,02	0,11	0,08	0,04	-0,05	-0,07	0,37	0,00	-0,07	-0,15	0,18	-0,34	0,05	-0,49	0,10	0,07	-0,25	0,11	0,10	0,28	0,45	-0,13	-0,59	-0,62
contag	0,06	0,02	0,12	0,11	-0,02	-0,05	0,00	0,44	-0,08	-0,10	-0,15	0,15	-0,42	-0,04	-0,54	0,10	0,08	-0,34	0,10	0,11	0,33	0,49	-0,14	-0,65	-0,69
division	-0,05	0,02	-0,05	0,01	-0,05	0,06	0,02	-0,28	0,00	0,10	0,14	-0,13	0,26	-0,01	0,41	-0,07	-0,01	0,28	-0,09	-0,10	-0,25	-0,35	0,11	0,52	0,55
ent	0,00	0,09	-0,06	0,08	-0,04	0,04	-0,01	-0,23	0,02	0,12	0,15	-0,22	0,24	-0,06	0,42	0,07	0,07	0,26	0,02	0,02	-0,30	-0,32	0,13	0,57	0,61
iji	-0,02	0,00	-0,13	-0,08	0,06	0,07	0,01	-0,39	0,06	0,08	0,14	-0,16	0,41	0,05	0,56	-0,05	-0,08	0,30	-0,06	-0,04	-0,27	-0,49	0,17	0,63	0,66
lsi	-0,03	-0,04	-0,11	-0,13	0,03	0,01	0,08	-0,45	0,06	0,12	0,14	-0,14	0,43	0,06	0,53	-0,11	-0,10	0,30	-0,11	-0,15	-0,34	-0,53	0,12	0,62	0,66
mesh	0,05	-0,01	0,05	-0,01	0,05	-0,06	-0,02	0,28	0,00	-0,10	-0,14	0,14	-0,26	0,02	-0,40	0,07	0,02	-0,28	0,10	0,10	0,25	0,35	-0,11	-0,51	-0,54
np	-0,01	-0,02	-0,13	-0,10	0,02	0,03	0,10	-0,46	0,04	0,11	0,15	-0,17	0,44	0,02	0,56	-0,10	-0,09	0,28	-0,08	-0,14	-0,37	-0,52	0,15	0,67	0,72
pd	-0,01	-0,02	-0,13	-0,09	0,02	0,03	0,09	-0,46	0,04	0,11	0,16	-0,17	0,43	0,01	0,56	-0,10	-0,09	0,28	-0,09	-0,14	-0,37	-0,52	0,15	0,68	0,72
pladj	0,03	0,04	0,11	0,13	-0,03	-0,01	-0,08	0,45	-0,06	-0,11	-0,14	0,14	-0,42	-0,05	-0,52	0,12	0,10	-0,29	0,11	0,15	0,34	0,53	-0,12	-0,62	-0,66
split	-0,06	0,00	-0,06	-0,09	-0,05	0,02	0,06	-0,29	0,02	0,09	0,12	-0,15	0,27	-0,04	0,37	-0,10	-0,07	0,23	-0,10	-0,09	-0,26	-0,32	0,10	0,45	0,47

Zdroj: Vlastní tvorba

Příloha 22: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky plocha) a ptáčími druhy, Sentinel-2

	bekasina otavní	bělouh šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulišek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvců
area_cv	0,11	-0,01	-0,06	-0,04	0,15	-0,03	0,02	-0,04	0,03	-0,02	-0,05	0,05	0,09	0,09	0,02	0,06	-0,02	-0,07	0,11	-0,02	0,01	-0,10	0,02	-0,03	-0,03
area_mn	-0,05	-0,01	0,13	0,05	-0,07	-0,03	-0,03	0,39	-0,06	-0,08	-0,12	0,12	-0,43	-0,08	-0,52	0,02	0,05	-0,29	0,01	0,14	0,26	0,56	-0,13	-0,58	-0,61
area_sd	0,00	-0,01	0,09	0,03	-0,01	-0,05	-0,03	0,37	-0,02	-0,10	-0,14	0,14	-0,37	-0,03	-0,51	0,05	0,04	-0,31	0,06	0,13	0,28	0,50	-0,14	-0,60	-0,63
ed	-0,03	-0,04	-0,11	-0,13	0,04	0,01	0,08	-0,45	0,06	0,12	0,14	-0,14	0,42	0,05	0,53	-0,12	-0,10	0,29	-0,11	-0,15	-0,34	-0,53	0,12	0,63	0,67
gyrate_cv	0,05	0,02	0,09	0,14	-0,01	-0,07	-0,03	0,35	-0,02	-0,09	-0,15	0,12	-0,36	0,00	-0,48	0,10	0,08	-0,25	0,12	0,10	0,23	0,50	-0,13	-0,54	-0,57
gyrate_mn	-0,11	-0,01	0,18	0,01	-0,11	0,00	-0,05	0,39	-0,06	-0,07	-0,10	0,12	-0,41	-0,09	-0,46	-0,02	0,04	-0,21	-0,06	0,07	0,29	0,47	-0,11	-0,53	-0,57
gyrate_sd	-0,05	0,00	0,17	0,08	-0,08	-0,04	-0,04	0,44	-0,06	-0,09	-0,14	0,14	-0,46	-0,07	-0,56	0,03	0,07	-0,28	0,02	0,10	0,31	0,58	-0,14	-0,63	-0,67
lpi	0,05	-0,02	0,05	0,00	0,07	-0,05	-0,02	0,27	0,01	-0,10	-0,14	0,14	-0,23	0,03	-0,38	0,06	0,01	-0,26	0,07	0,07	0,25	0,30	-0,11	-0,49	-0,52
ta	-0,01	0,08	-0,03	-0,02	-0,02	0,05	0,04	0,02	0,04	0,01	-0,03	0,02	0,09	0,08	0,07	0,02	0,04	0,06	0,05	0,02	0,00	-0,03	0,05	0,02	0,02
te	-0,04	-0,04	-0,11	-0,13	0,03	0,02	0,09	-0,45	0,07	0,12	0,14	-0,14	0,43	0,06	0,53	-0,11	-0,10	0,30	-0,11	-0,15	-0,34	-0,53	0,13	0,62	0,66

Zdroj: Vlastní tvorba

Příloha 23: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky komplexnosti) a ptáčími druhy, Sentinel-2

	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulišek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštíř obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvci
condent	-0,03	-0,02	-0,11	-0,11	0,03	0,02	0,06	-0,45	0,06	0,12	0,16	-0,16	0,43	0,04	0,55	-0,11	-0,09	0,31	-0,11	-0,14	-0,35	-0,54	0,13	0,66	0,69
ent	0,00	0,09	-0,06	0,08	-0,04	0,04	-0,01	-0,23	0,02	0,12	0,15	-0,22	0,24	-0,06	0,42	0,07	0,07	0,26	0,02	0,02	-0,30	-0,32	0,13	0,57	0,61
jointent	-0,01	0,06	-0,08	0,01	-0,02	0,04	0,02	-0,32	0,04	0,13	0,16	-0,21	0,31	-0,03	0,48	0,01	0,02	0,29	-0,03	-0,04	-0,33	-0,41	0,13	0,62	0,66
mutinf	0,03	0,16	-0,01	0,21	-0,09	0,04	-0,06	0,01	-0,01	0,09	0,11	-0,21	0,02	-0,12	0,21	0,19	0,18	0,15	0,11	0,15	-0,18	-0,07	0,09	0,35	0,38
relmutinf	0,04	0,15	0,12	0,29	-0,13	0,01	-0,11	0,48	-0,06	-0,05	-0,06	-0,03	-0,43	-0,17	-0,39	0,24	0,22	-0,20	0,19	0,24	0,20	0,53	-0,07	-0,36	-0,38

Zdroj: Vlastní tvorba

Příloha 24: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky CORE) a ptáčími druhy, Sentinel-2

	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulišek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštílk obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřívka obecná	výr velký	Počet druhů	Počet řádu pěvců
cai_cv	0,16	0,07	-0,08	0,14	-0,02	0,04	0,04	-0,21	0,04	0,05	0,12	-0,16	0,13	-0,07	0,30	0,03	-0,01	0,15	0,09	-0,02	-0,28	-0,19	0,15	0,47	0,46
cai_mn	-0,13	-0,05	0,13	-0,06	-0,02	-0,01	-0,07	0,32	-0,06	-0,04	-0,11	0,15	-0,29	-0,01	-0,41	-0,02	0,02	-0,16	-0,08	0,05	0,30	0,37	-0,13	-0,53	-0,55
cai_sd	-0,10	-0,02	0,14	0,04	-0,06	0,01	-0,10	0,38	-0,06	-0,03	-0,10	0,13	-0,36	-0,04	-0,43	0,01	0,06	-0,14	-0,06	0,08	0,29	0,46	-0,10	-0,51	-0,54
core_cv	0,08	-0,02	-0,09	-0,08	0,14	-0,02	0,05	-0,16	0,02	0,00	-0,02	-0,01	0,20	0,08	0,17	0,02	-0,04	-0,01	0,06	-0,06	-0,08	-0,25	0,06	0,15	0,16
core_mn	-0,04	-0,01	0,11	0,05	-0,07	-0,03	-0,02	0,37	-0,06	-0,08	-0,11	0,11	-0,41	-0,09	-0,50	0,03	0,05	-0,28	0,02	0,14	0,24	0,55	-0,12	-0,55	-0,58
core_sd	0,00	-0,01	0,08	0,03	-0,02	-0,05	-0,03	0,36	-0,03	-0,11	-0,14	0,13	-0,36	-0,05	-0,49	0,06	0,04	-0,31	0,06	0,14	0,28	0,49	-0,13	-0,58	-0,61
dcad	-0,05	-0,04	-0,10	-0,13	0,03	-0,01	0,10	-0,41	0,04	0,09	0,11	-0,13	0,38	0,04	0,47	-0,11	-0,10	0,22	-0,11	-0,13	-0,30	-0,49	0,08	0,55	0,60
dcore_cv	0,00	-0,04	0,03	0,03	0,06	-0,04	0,10	-0,15	0,07	0,05	0,03	-0,05	0,08	0,05	0,19	-0,04	-0,07	0,08	-0,01	-0,05	-0,23	-0,13	0,04	0,29	0,29
dcore_mn	-0,12	-0,05	0,18	-0,05	-0,02	-0,06	0,05	0,25	-0,02	-0,08	-0,12	0,13	-0,23	0,02	-0,31	-0,05	-0,03	-0,19	-0,08	0,02	0,20	0,18	-0,17	-0,42	-0,42
dcore_sd	-0,08	-0,06	0,16	0,00	0,03	-0,07	0,11	0,07	0,04	-0,02	-0,06	0,05	-0,12	0,05	-0,07	-0,06	-0,07	-0,08	-0,06	0,00	-0,02	0,03	-0,09	-0,07	-0,07
ndca	-0,05	-0,04	-0,10	-0,14	0,03	-0,01	0,11	-0,40	0,04	0,09	0,11	-0,13	0,39	0,04	0,47	-0,11	-0,10	0,23	-0,11	-0,13	-0,30	-0,49	0,09	0,54	0,59
tca	-0,01	0,08	-0,03	-0,02	-0,02	0,05	0,04	0,02	0,04	0,01	-0,03	0,02	0,09	0,08	0,07	0,02	0,04	0,06	0,05	0,02	0,00	-0,03	0,05	0,02	0,02

Zdroj: Vlastní tvorba

Příloha 25: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky diverzity) a ptačími druhy, Sentinel-2

	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous uшатý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvců
msidi	-0,03	0,07	-0,08	0,05	-0,04	0,03	-0,02	-0,26	0,03	0,12	0,15	-0,18	0,25	-0,03	0,40	0,03	0,05	0,28	-0,01	0,01	-0,28	-0,31	0,11	0,55	0,58
msiei	-0,07	0,00	-0,11	-0,06	-0,01	0,04	-0,03	-0,36	0,07	0,11	0,14	-0,14	0,34	0,02	0,47	-0,06	-0,03	0,33	-0,07	-0,06	-0,29	-0,38	0,11	0,58	0,61
pr	0,18	0,20	0,13	0,35	-0,12	-0,04	0,06	0,38	-0,11	0,05	0,02	-0,15	-0,31	-0,17	-0,19	0,31	0,27	-0,14	0,24	0,24	0,02	0,27	-0,02	-0,12	-0,10
prd	0,17	0,19	0,13	0,35	-0,12	-0,05	0,05	0,37	-0,11	0,05	0,03	-0,15	-0,32	-0,18	-0,19	0,30	0,26	-0,14	0,23	0,23	0,02	0,27	-0,03	-0,12	-0,10
shdi	0,01	0,09	-0,06	0,08	-0,04	0,04	-0,01	-0,23	0,02	0,12	0,15	-0,22	0,24	-0,06	0,42	0,07	0,07	0,26	0,02	0,02	-0,30	-0,32	0,13	0,57	0,61
shei	-0,06	0,01	-0,11	-0,06	0,00	0,06	-0,02	-0,37	0,07	0,10	0,15	-0,17	0,36	0,02	0,51	-0,05	-0,03	0,32	-0,07	-0,06	-0,31	-0,43	0,14	0,62	0,66
sidi	-0,03	0,07	-0,07	0,06	-0,03	0,04	-0,02	-0,24	0,03	0,12	0,14	-0,17	0,23	-0,03	0,39	0,03	0,05	0,27	-0,01	-0,03	-0,27	-0,30	0,10	0,53	0,57
siei	-0,05	0,04	-0,09	0,01	-0,02	0,04	-0,02	-0,30	0,05	0,11	0,14	-0,15	0,28	0,01	0,43	-0,01	0,01	0,30	-0,04	-0,06	-0,28	-0,34	0,11	0,55	0,59

Zdroj: Vlastní tvorba

Příloha 26: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky tvaru) a ptačími druhy, Sentinel-2

	bekasina otavní	bělorýt šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous uшатý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvci
circle_cv	-0,01	0,05	0,14	0,03	-0,09	0,00	-0,05	0,08	-0,12	0,00	-0,01	-0,02	-0,07	-0,11	0,07	0,03	0,02	0,05	-0,01	-0,02	0,07	-0,03	0,10	0,04	0,03
circle_mn	0,01	0,06	-0,05	-0,07	-0,07	0,11	-0,06	-0,29	0,03	0,07	0,21	-0,11	0,22	-0,09	0,43	-0,05	-0,01	0,25	-0,06	-0,04	-0,22	-0,39	0,20	0,50	0,49
circle_sd	-0,01	0,07	0,09	-0,01	-0,10	0,05	-0,06	-0,05	-0,08	0,03	0,07	-0,06	0,03	-0,12	0,23	0,00	0,01	0,14	-0,03	-0,03	-0,03	-0,18	0,16	0,23	0,22
contig_cv	0,11	0,02	-0,10	0,19	-0,03	-0,02	-0,02	-0,05	-0,02	0,12	0,04	-0,09	0,01	-0,05	0,13	0,13	0,08	0,15	0,04	0,05	-0,13	-0,02	0,10	0,16	0,17
contig_mn	-0,15	-0,05	0,15	-0,11	-0,01	-0,01	-0,04	0,32	-0,05	-0,09	-0,13	0,17	-0,26	0,02	-0,42	-0,05	0,00	-0,22	-0,07	0,03	0,33	0,34	-0,16	-0,54	-0,56
contig_sd	-0,08	-0,03	0,07	0,05	-0,04	-0,02	-0,08	0,34	-0,07	0,00	-0,14	0,12	-0,30	-0,01	-0,38	0,06	0,08	-0,13	-0,05	0,09	0,28	0,39	-0,10	-0,51	-0,52
frac_cv	0,06	0,08	0,00	-0,01	-0,06	-0,02	0,02	-0,09	0,04	0,00	0,08	-0,02	0,08	-0,05	0,17	0,04	-0,03	0,08	0,04	-0,03	-0,10	-0,25	0,03	0,18	0,18
frac_mn	0,02	0,09	-0,04	-0,07	-0,05	0,08	-0,05	-0,19	0,07	0,04	0,18	-0,06	0,14	-0,04	0,28	0,01	0,00	0,15	-0,01	0,01	-0,15	-0,32	0,10	0,33	0,32
frac_sd	0,06	0,08	0,00	-0,01	-0,06	-0,01	0,01	-0,10	0,04	0,01	0,09	-0,02	0,08	-0,06	0,18	0,04	-0,03	0,08	0,04	-0,03	-0,10	-0,26	0,04	0,19	0,19
pafrac	0,06	0,02	-0,07	-0,08	0,02	-0,03	0,09	-0,31	0,08	0,01	0,10	-0,07	0,30	0,04	0,35	-0,03	-0,09	0,13	0,02	-0,11	-0,23	-0,45	0,04	0,40	0,43
para_cv	-0,11	-0,04	0,12	-0,02	-0,04	-0,02	-0,06	0,39	-0,08	-0,06	-0,15	0,15	-0,33	-0,01	-0,46	0,02	0,05	-0,21	-0,05	0,07	0,33	0,44	-0,15	-0,59	-0,61
para_mn	0,16	0,06	-0,15	0,13	0,01	0,01	0,05	-0,31	0,05	0,10	0,13	-0,18	0,25	-0,02	0,41	0,07	0,01	0,22	0,08	-0,02	-0,33	-0,34	0,16	0,54	0,56
para_sd	-0,05	-0,01	0,07	0,09	-0,05	-0,03	-0,07	0,38	-0,08	-0,01	-0,14	0,10	-0,32	-0,02	-0,40	0,10	0,10	-0,15	-0,01	0,10	0,27	0,42	-0,10	-0,52	-0,53
shape_cv	-0,07	-0,09	0,17	-0,02	0,00	-0,08	0,06	0,12	0,03	-0,04	-0,10	0,08	-0,15	0,08	-0,20	-0,07	-0,06	-0,10	-0,06	-0,08	0,10	0,09	-0,14	-0,26	-0,26
shape_mn	-0,04	0,06	0,08	-0,06	-0,08	0,03	-0,04	0,04	0,04	-0,02	0,07	0,04	-0,07	-0,04	-0,01	-0,01	0,00	0,01	-0,04	0,02	0,04	-0,08	-0,02	-0,04	-0,06
shape_sd	-0,07	-0,07	0,18	-0,03	-0,02	-0,07	0,05	0,12	0,04	-0,04	-0,07	0,09	-0,16	0,06	-0,18	-0,06	-0,05	-0,09	-0,07	-0,06	0,10	0,06	-0,13	-0,25	-0,26

Zdroj: Vlastní tvorba

Příloha 27: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky agregace) a ptáčími druhy, PlanetScope

	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	krkavec velký	králíček ohnivý	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádů pěvců
ai	0,02	0,07	0,01	0,02	0,02	-0,01	-0,12	0,26	-0,07	-0,10	0,11	-0,22	-0,01	-0,32	0,10	0,09	-0,13	0,07	0,12	0,27	0,27	-0,07	-0,44	-0,48
cohesion	0,06	0,10	0,02	0,06	-0,03	0,03	-0,16	0,13	-0,08	0,02	0,05	-0,24	-0,12	-0,22	0,03	0,04	-0,16	0,03	0,04	0,06	0,25	0,05	-0,21	-0,26
contag	0,08	0,08	0,01	0,02	-0,03	0,01	-0,06	0,25	-0,11	-0,09	0,09	-0,27	-0,07	-0,36	0,06	0,04	-0,24	0,07	0,06	0,20	0,29	-0,08	-0,46	-0,50
division	-0,03	-0,06	0,05	0,12	-0,02	-0,03	0,10	0,01	0,06	-0,01	-0,04	0,08	0,12	0,16	0,04	0,04	0,14	0,02	0,01	-0,06	-0,05	-0,02	0,21	0,25
ent	0,00	0,02	0,01	0,16	-0,05	-0,04	0,07	-0,02	0,10	0,06	-0,15	0,09	0,00	0,21	0,14	0,13	0,14	0,08	0,10	-0,16	-0,10	0,04	0,34	0,39
iji	-0,09	-0,09	-0,13	-0,14	0,12	-0,05	0,05	-0,37	0,08	0,03	-0,06	0,35	0,10	0,35	-0,10	-0,11	0,26	-0,15	-0,11	-0,11	-0,50	0,07	0,37	0,41
lsi	-0,02	-0,07	-0,01	-0,02	-0,02	0,01	0,12	-0,26	0,07	0,10	-0,12	0,22	0,01	0,33	-0,09	-0,08	0,13	-0,06	-0,11	-0,27	-0,27	0,07	0,44	0,48
mesh	0,03	0,06	-0,05	-0,12	0,02	0,04	-0,10	-0,01	-0,06	0,00	0,04	-0,08	-0,12	-0,16	-0,04	-0,03	-0,14	-0,02	-0,01	0,06	0,05	0,02	-0,21	-0,25
np	-0,05	-0,10	-0,06	-0,06	-0,02	-0,01	0,13	-0,31	0,07	0,08	-0,08	0,24	0,04	0,27	-0,17	-0,14	0,09	-0,14	-0,17	-0,23	-0,29	0,05	0,37	0,41
pd	-0,04	-0,11	-0,05	-0,05	-0,02	-0,01	0,13	-0,31	0,07	0,08	-0,08	0,23	0,03	0,26	-0,17	-0,14	0,09	-0,14	-0,17	-0,23	-0,29	0,04	0,37	0,41
pladj	0,02	0,07	0,01	0,01	0,02	-0,01	-0,12	0,26	-0,07	-0,10	0,12	-0,22	0,00	-0,32	0,09	0,08	-0,13	0,07	0,12	0,27	0,27	-0,07	-0,44	-0,48
split	-0,06	-0,07	0,03	-0,03	0,03	-0,01	0,13	-0,09	0,08	0,03	-0,06	0,18	0,05	0,18	-0,02	-0,01	0,13	-0,01	-0,02	-0,13	-0,13	-0,03	0,19	0,24

Zdroj: Vlastní tvorba

Příloha 28: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky plochy (area)) a ptačími druhy, PlanetScope

	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	vír velký	Počet druhů	Počet řádů pěvců
area_cv	0,01	0,03	-0,08	-0,10	0,00	0,03	-0,06	-0,14	0,00	-0,06	0,04	0,02	-0,04	-0,11	-0,06	-0,12	-0,10	-0,11	-0,10	-0,10	-0,02	-0,06	0,06	-0,06	-0,08
area_mn	0,07	0,12	0,04	0,02	0,02	0,02	-0,12	0,28	0,00	-0,07	-0,07	0,05	-0,19	-0,04	-0,26	0,19	0,16	-0,13	0,17	0,19	0,19	0,26	-0,04	-0,36	-0,40
area_sd	0,05	0,09	-0,02	-0,07	0,02	0,03	-0,13	0,10	0,01	-0,07	-0,03	0,06	-0,14	-0,09	-0,23	0,04	0,03	-0,16	0,05	0,06	0,12	0,15	0,00	-0,30	-0,34
ed	-0,02	-0,07	-0,01	-0,01	-0,02	0,01	0,12	-0,26	0,02	0,07	0,10	-0,12	0,22	0,00	0,32	-0,09	-0,08	0,13	-0,07	-0,12	-0,27	-0,27	0,07	0,44	0,49
gyrate_cv	-0,04	0,06	0,10	0,02	-0,04	0,01	-0,13	0,25	-0,04	-0,07	-0,07	0,14	-0,32	-0,09	-0,40	-0,02	0,03	-0,18	-0,02	0,04	0,21	0,42	-0,04	-0,43	-0,48
gyrate_mn	0,07	0,06	0,01	0,03	0,04	-0,01	0,04	0,05	0,04	0,00	-0,01	-0,08	0,11	0,04	0,20	0,23	0,16	0,16	0,20	0,14	-0,03	-0,17	0,03	0,13	0,15
gyrate_sd	0,03	0,11	0,12	0,06	0,00	0,00	-0,10	0,28	0,00	-0,07	-0,06	0,06	-0,21	-0,04	-0,20	0,19	0,17	-0,04	0,16	0,16	0,17	0,24	-0,01	-0,28	-0,32
lpi	0,03	0,06	-0,07	-0,10	0,02	0,04	-0,10	-0,03	0,02	-0,06	0,01	0,04	-0,08	-0,10	-0,14	-0,04	-0,04	-0,13	-0,03	-0,02	0,05	0,02	0,04	-0,19	-0,22
ta	-0,01	0,08	-0,02	-0,02	-0,02	0,05	0,04	0,02	0,04	0,01	-0,03	0,02	0,09	0,08	0,07	0,02	0,04	0,06	0,05	0,02	0,00	-0,03	0,05	0,02	0,02
te	-0,02	-0,07	-0,01	-0,02	-0,03	0,01	0,13	-0,25	0,02	0,07	0,10	-0,11	0,22	0,01	0,33	-0,09	-0,08	0,13	-0,06	-0,11	-0,27	-0,27	0,07	0,44	0,48

Zdroj: Vlastní tvorba

Příloha 29: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky komplexnosti) a ptáčími druhy, PlanetScope

	bekasina otavní	bělorýt šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvci
condent	-0,02	-0,07	-0,02	0,00	-0,01	0,00	0,12	-0,25	0,02	0,08	0,11	-0,12	0,23	0,03	0,33	-0,08	-0,07	0,16	-0,06	-0,10	-0,26	-0,27	0,07	0,45	0,50
ent	0,00	0,02	0,01	0,16	-0,05	-0,04	0,07	-0,02	-0,01	0,10	0,06	-0,15	0,09	0,00	0,21	0,14	0,13	0,14	0,08	0,10	-0,16	-0,10	0,04	0,34	0,39
jointent	0,00	0,00	0,01	0,12	-0,04	-0,03	0,09	-0,08	0,00	0,10	0,08	-0,15	0,13	0,01	0,26	0,08	0,08	0,15	0,04	0,05	-0,20	-0,15	0,05	0,39	0,44
mutinf	0,01	0,06	0,02	0,20	-0,06	-0,05	0,04	0,08	-0,02	0,09	0,03	-0,15	0,01	-0,01	0,13	0,21	0,20	0,11	0,12	0,17	-0,09	-0,01	0,02	0,23	0,27
relmutinf	0,01	0,10	0,04	0,18	-0,03	-0,05	-0,09	0,30	-0,03	0,03	-0,07	-0,03	-0,17	-0,02	-0,16	0,25	0,23	-0,03	0,17	0,22	0,16	0,22	-0,04	-0,18	-0,18

Zdroj: Vlastní tvorba

Příloha 30: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky core) a ptáčími druhy, PlanetScope

	bekasina otavní	bělorýt šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	vír velký	Počet druhů	Počet řádů pěvců
cai_cv	-0,07	-0,05	-0,03	-0,09	-0,03	0,06	-0,06	-0,20	-0,05	0,11	0,09	0,10	0,02	-0,09	0,00	-0,27	-0,16	0,05	-0,26	-0,16	-0,05	0,02	0,11	0,10	0,05
cai_mn	0,10	0,08	0,03	0,07	0,06	-0,03	0,01	0,20	0,04	-0,07	-0,08	-0,05	-0,02	0,09	0,00	0,31	0,21	0,02	0,30	0,20	0,06	0,00	-0,09	-0,12	-0,08
cai_sd	0,06	0,06	0,03	0,03	0,09	-0,03	-0,01	0,16	0,02	-0,01	-0,08	0,01	0,02	0,11	0,03	0,27	0,20	0,11	0,24	0,19	0,09	-0,02	-0,05	-0,10	-0,08
core_cv	0,01	0,02	-0,09	-0,12	0,00	0,02	-0,04	-0,17	0,01	-0,06	0,05	0,01	-0,01	-0,10	-0,01	-0,13	-0,11	-0,09	-0,11	-0,12	-0,05	-0,11	0,06	-0,01	-0,03
core_mn	0,06	0,11	0,03	0,01	0,02	0,02	-0,12	0,26	0,00	-0,07	-0,08	0,06	-0,19	-0,03	-0,28	0,17	0,14	-0,13	0,15	0,18	0,20	0,25	-0,05	-0,37	-0,41
core_sd	0,05	0,08	-0,03	-0,08	0,03	0,03	-0,13	0,11	0,01	-0,07	-0,04	0,07	-0,13	-0,08	-0,23	0,04	0,03	-0,15	0,05	0,06	0,14	0,14	-0,01	-0,32	-0,36
dcad	-0,02	-0,06	-0,04	-0,03	-0,02	0,01	0,13	-0,28	0,01	0,05	0,10	-0,13	0,26	0,01	0,34	-0,09	-0,08	0,11	-0,06	-0,12	-0,27	-0,31	0,05	0,44	0,49
dcare_cv	0,02	0,05	0,00	0,06	-0,10	0,09	-0,04	-0,10	-0,05	0,01	0,13	-0,07	-0,06	-0,20	0,07	-0,10	-0,04	-0,07	-0,05	-0,03	-0,20	0,08	0,12	0,22	0,21
dcare_mn	0,07	0,08	0,02	0,05	-0,02	0,02	0,08	-0,04	0,04	-0,04	0,08	-0,16	0,13	-0,04	0,29	0,13	0,09	0,10	0,17	0,06	-0,19	-0,16	0,05	0,33	0,37
dcare_sd	0,04	0,07	0,01	0,07	-0,09	0,09	-0,01	-0,12	-0,03	0,00	0,14	-0,11	0,01	-0,18	0,18	-0,05	0,00	-0,03	0,01	-0,01	-0,24	0,00	0,12	0,31	0,32
ndca	-0,02	-0,06	-0,04	-0,03	-0,02	0,01	0,14	-0,28	0,02	0,05	0,09	-0,13	0,26	0,01	0,34	-0,09	-0,08	0,11	-0,06	-0,11	-0,27	-0,31	0,06	0,43	0,49
tca	0,00	0,09	-0,01	-0,01	0,02	0,01	-0,10	0,23	0,00	-0,06	-0,11	0,12	-0,15	0,03	-0,27	0,08	0,08	-0,10	0,07	0,11	0,26	0,22	-0,05	-0,40	-0,44

Zdroj: Vlastní tvorba

Příloha 31: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky diverzity) a ptačími druhy, PlanetScope

	bekasina otavní	bělořit šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulišek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvci
msidi	-0,03	-0,01	0,01	0,12	-0,02	-0,04	0,07	-0,02	0,00	0,11	0,04	-0,10	0,11	0,06	0,19	0,11	0,11	0,16	0,06	0,09	-0,11	-0,07	0,01	0,29	0,33
msiei	-0,08	-0,08	0,00	0,02	0,03	-0,03	0,05	-0,14	0,03	0,12	0,04	-0,05	0,21	0,11	0,26	0,01	0,02	0,22	-0,02	0,00	-0,11	-0,16	0,03	0,34	0,37
pr	0,18	0,18	0,05	0,36	-0,18	-0,06	0,08	0,41	-0,09	-0,01	-0,02	-0,16	-0,34	-0,15	-0,25	0,36	0,31	-0,19	0,29	0,28	0,00	0,33	-0,07	-0,18	-0,15
prd	0,18	0,16	0,05	0,36	-0,18	-0,07	0,07	0,40	-0,09	-0,01	-0,01	-0,16	-0,35	-0,16	-0,25	0,35	0,29	-0,19	0,27	0,27	0,00	0,33	-0,08	-0,18	-0,15
shdi	0,00	0,03	0,01	0,16	-0,05	-0,04	0,07	-0,02	-0,01	0,10	0,06	-0,16	0,09	0,00	0,21	0,14	0,13	0,14	0,08	0,10	-0,16	-0,10	0,04	0,34	0,38
shei	-0,07	-0,05	-0,01	0,02	0,02	-0,02	0,05	-0,19	0,03	0,12	0,07	-0,10	0,23	0,06	0,33	-0,01	0,01	0,23	-0,04	-0,02	-0,17	-0,24	0,07	0,42	0,46
sidi	-0,04	-0,03	0,02	0,13	-0,02	-0,04	0,07	-0,02	0,01	0,10	0,04	-0,09	0,09	0,07	0,19	0,09	0,09	0,15	0,04	0,05	-0,10	-0,07	0,01	0,29	0,33
siei	-0,06	-0,05	0,02	0,08	0,01	-0,03	0,06	-0,07	0,02	0,10	0,04	-0,07	0,14	0,09	0,22	0,04	0,05	0,18	0,01	0,02	-0,10	-0,11	0,02	0,31	0,35

Zdroj: Vlastní tvorba

Příloha 32: Pearsonův korelační koeficient mezi strukturálními metrikami (kategorie metriky tvaru) a ptačími druhy, PlanetScope

	bekasina otavní	bělorýt šedý	datlík tříprstý	hýl rudý	jestřáb lesní	kalous ušatý	konipas horský	kos horský	králíček ohnivý	krkavec velký	krutihlav obecný	kulíšek nejmenší	lejsek černohlavý	lejsek malý	lejsek šedý	linduška horská	pěvuška podhorní	puštík obecný	slavík modráček tundrový	sokol stěhovavý	sýc rousný	tetřev obecný	výr velký	Počet druhů	Počet řádu pěvců
circle_cv	0,20	0,13	-0,09	0,09	-0,05	0,00	0,06	-0,12	-0,03	-0,02	0,09	-0,19	0,18	-0,08	0,30	0,28	0,16	0,10	0,24	0,12	-0,20	-0,29	0,12	0,33	0,35
circle_mn	0,02	-0,01	-0,14	-0,11	0,02	0,02	0,08	-0,37	0,04	0,07	0,10	-0,13	0,40	0,02	0,48	-0,02	-0,06	0,24	-0,03	-0,08	-0,24	-0,53	0,14	0,52	0,55
circle_sd	0,16	0,10	-0,11	0,04	-0,03	0,00	0,07	-0,20	-0,01	0,01	0,09	-0,18	0,25	-0,06	0,36	0,20	0,10	0,14	0,17	0,07	-0,22	-0,37	0,13	0,40	0,43
contig_cv	0,08	0,08	0,01	0,02	-0,03	0,01	-0,06	0,25	-0,03	-0,11	-0,09	0,09	-0,27	-0,07	-0,36	0,06	0,04	-0,24	0,07	0,06	0,20	0,29	-0,08	-0,46	-0,50
contig_mn	-0,01	0,06	0,00	-0,02	0,00	0,05	-0,08	-0,07	-0,10	0,14	0,06	0,07	0,03	-0,07	0,03	-0,03	0,03	0,11	-0,09	0,00	-0,06	0,02	0,15	0,09	0,06
contig_sd	0,09	0,05	0,03	0,08	0,04	-0,05	0,05	0,20	0,06	-0,10	-0,09	-0,07	-0,03	0,10	-0,01	0,28	0,17	-0,02	0,28	0,18	0,07	0,00	-0,12	-0,12	-0,08
frac_cv	0,10	0,06	-0,11	0,00	-0,04	-0,01	0,11	-0,27	0,01	0,06	0,16	-0,18	0,29	-0,07	0,39	0,07	0,00	0,13	0,06	0,01	-0,28	-0,39	0,12	0,48	0,51
frac_mn	0,01	-0,03	-0,13	-0,10	0,03	-0,01	0,11	-0,32	0,05	0,05	0,08	-0,13	0,39	0,07	0,43	0,00	-0,05	0,19	0,00	-0,04	-0,19	-0,51	0,07	0,44	0,48
frac_sd	0,09	0,05	-0,11	-0,01	-0,04	-0,01	0,11	-0,28	0,01	0,06	0,15	-0,18	0,30	-0,06	0,40	0,06	-0,01	0,13	0,06	0,01	-0,27	-0,40	0,12	0,49	0,52
pafrac	0,00	-0,03	-0,07	-0,05	-0,07	0,02	0,10	-0,30	0,04	0,02	0,16	-0,17	0,21	-0,11	0,32	-0,16	-0,16	0,06	-0,12	-0,16	-0,27	-0,30	0,11	0,46	0,48
para_cv	0,15	0,12	0,04	0,12	0,04	-0,04	0,02	0,26	0,01	-0,06	-0,08	-0,06	-0,06	0,06	-0,03	0,39	0,27	0,00	0,34	0,25	0,06	0,05	-0,09	-0,14	-0,10
para_mn	-0,08	-0,04	-0,02	-0,07	-0,05	0,05	-0,05	-0,19	-0,06	0,10	0,08	0,07	0,01	-0,10	-0,01	-0,27	-0,16	0,01	-0,27	-0,16	-0,07	0,02	0,12	0,11	0,07
para_sd	0,16	0,15	0,05	0,15	0,04	-0,03	0,01	0,27	-0,04	-0,01	-0,07	-0,04	-0,08	0,04	-0,05	0,42	0,30	0,02	0,33	0,29	0,04	0,09	-0,05	-0,13	-0,11
shape_cv	0,07	0,08	0,14	0,10	-0,12	0,03	0,04	0,00	0,02	-0,01	0,13	-0,14	-0,06	-0,17	0,16	0,05	0,05	0,03	0,09	0,02	-0,25	0,04	0,09	0,30	0,31
shape_mn	0,05	0,01	-0,06	-0,04	0,03	-0,01	0,11	-0,19	0,06	0,03	0,08	-0,16	0,29	0,03	0,40	0,10	0,03	0,18	0,09	0,02	-0,19	-0,39	0,06	0,41	0,45
shape_sd	0,07	0,07	0,09	0,07	-0,09	0,02	0,07	-0,06	0,03	0,00	0,13	-0,16	0,04	-0,14	0,25	0,07	0,05	0,08	0,10	0,02	-0,27	-0,08	0,09	0,37	0,39

Zdroj: Vlastní tvorba

Elektronické přílohy

Elektronická příloha 1: Korelační matice Pearsonova korelačního koeficientu mezi charakteristikami z dat Sentinel-2

- Přiložený soubor: *pearson_metriky_Sentinel2.xlsx*

Elektronická příloha 2: Korelační matice Pearsonova korelačního koeficientu mezi charakteristikami z dat PlanetScope

- Přiložený soubor: *pearson_metriky_PlanetScope.xlsx*

Elektronická příloha 3: Hodnoty všech vypočtených charakteristik z dat Sentinel2

- Přiložený soubor: *vypoctene_charakteristiky_Sentinel2.xlsx*

Elektronická příloha 4: Hodnoty všech vypočtených charakteristik z dat PlanetScope

- Přiložený soubor: *vypoctene_charakteristiky_PlanetScope.xlsx*

Skripty

Skripty 1 klasifikace Sentinel-2 a PlanetScope metodou RF v GEE:

Sentinel-2:

<https://code.earthengine.google.com/6e95799f621bd44ec97fd9e2d2955066>

Sentinel-2 Tundra:

<https://code.earthengine.google.com/77196ee2cb6e29a59491b93e12feb97a>

PlanetScope:

<https://code.earthengine.google.com/9a0e17b45b2a80479b3e6b5df0b396a7>

PlanetScope Tundra:

<https://code.earthengine.google.com/1de21772c36189273cc029f1c32b0c21>

Skript 2 pro výpočet krajinných metrik v R:

```
library(landscapemetrics) # knihovna na výpočet krajinných metrik
library(raster)           # knihovna na práci s rastrovými daty
library(sf)               # knihovna na práci s vektorovými daty
library(dplyr)            # knihovna na manipulaci s daty
library(writexl)          # knihovna na export do xlsx

list = list_lsm()         # seznam všech metrik
my_raster = raster("Sentine2.tif") #Načtení land cover
my_grid <- st_read("atlas.shp")    #Načtení kvadrátů

plot(my_raster)           #Vykreslení land cover
plot(my_grid, add = TRUE) #Vykreslení kvadrátů

#Výpočet zvolených metrik na úrovni na krajiny
my_metric = sample_lsm(my_raster, my_grid, level = "landscape",
metric = c("ai", "area"))

write_xlsx(my_metric, "místo_uložení") #Export do xlsx
```