

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA
V PRAZE
FAKULTA ŽIVOTNÍHO PROSTŘEDÍ
KATEDRA PROSTOROVÝCH VĚD

**SPEKTRÁLNÍ VARIABILITA JAKO INDIKÁTOR
DRUHOVÉ DIVERZITY PTÁKŮ A
ORNITOLOGICKÉ HODNOTY ÚZEMÍ
V PODROBNÉM MĚŘÍTKU HODNOCENÍ**

BAKALÁŘSKÁ PRÁCE

Vedoucí práce: prof. Ing. Petra Šímová, Ph.D.

Bakalant: Vojtěch Šebek

2024

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

Fakulta životního prostředí

ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Vojtěch Šebek

Geografické informační systémy a dálkový průzkum Země v životním prostředí

Název práce

Spektrální variabilita jako indikátor druhové diverzity ptáků a ornitologické hodnoty území v podrobném měřítku hodnocení

Název anglicky

Spectral variability as an indicator of bird species diversity and ornithological value of an area at a detailed scale

Cíle práce

Vysvětlení prostorové variability biodiverzity je jedním ze zásadních úkolů současného výzkumu v ekologii i v praktické ochraně přírody. Jelikož ale reálně nelze získat všechna data o výskytu druhů na Zemi a všechna data o ekologických podmínkách a procesech, které biodiverzitu ovlivňují, je třeba hledat indikátory (proxy proměnné), které mohou vysvětlit distribuci a diverzitu druhů. Jednou ze zásadních a datově nejlépe podložených skupin organismů pro takový výzkum jsou ptáci. Ze současného stavu poznání zároveň plyně, že vhodným indikátorem diverzity ptáků může být spektrální variabilita odvozená ze satelitních multispektrálních snímků. Použitelnost spektrální variabilita jakožto indikátoru diverzity ptáků nicméně závisí na typu krajiny a měřítku hodnocení. Rámcovým cílem bakalářské práce je tedy zjistit, do jaké míry lze spektrální variabilitu využít jako prediktor druhové diverzity ptáků a ornitologické hodnoty území v podrobném prostorovém měřítku. Formulace dílčích cílů je úkolem autora.

Metodika

V teoretické části práce autor vypracuje literární rešerši, která se bude zabývat zejména obecným úvodem do problematiky vztahu druhů k jejich prostředí, faktory ovlivňujícími druhovou diverzitu, základy modelování vztahů druhů a prostředí a problematikou prostorového měřítka (škálování, scaling) v takovém modelování. Do toho vhodně zasadí možnosti využití multispektrálních satelitních snímků, zejména spektrální variabilita, jakožto prediktorů diverzity (nejen) ptáků. Na úrovni obvyklé pro BP shrne současný stav poznání v kombinaci všech zmíněných okruhů.

Pro experimentální část autor použije jako základ pro výpočet vysvětlovaných proměnných poskytnutá ornitologická data z bodového sčítání ptáků v CHKO Ždárske vrchy. Pro každý bod vypočítá (i) druhovou diverzitu jako počet zaznamenaných druhů (species richness), popř. pro srovnání i jako Shannonův index diverzity, a (ii) ornitologickou hodnotu založenou na vzácnosti druhů v ČR (dle Atlasu hnězdího rozšíření ptáků). Kandidátními vysvětlujícími proměnnými budou (i) mediány a spektrální variabilita z hodnot pásem z družicových dat Landsat, (ii) mediány a spektrální variabilita ze spektrálních indexů, jako je NDVI, NDWI

apod. Spektrální variabilitu je doporučeno vyjádřit směrodatnou odchylkou nebo koeficientem variance v okolí sčítacího bodu.

Vztah mezi získanými vysvětlovanými (diverzita, ornitologická hodnota) a vysvětlujícími proměnnými autor vyhodnotí s využitím znalostí statistiky na úrovni bakalářského studia, popř. si nastuduje a použije zobecněné lineární modely (GLM).



Doporučený rozsah práce

40 – 60 stran

Klíčová slova

formulace klíčových slov je úkolem autora

Doporučené zdroje informací

- Moudry V., Šimová P., 2012: Influence of positional accuracy, sample size and scale on modelling species distributions: a review. International Journal of Geographical Information Science 26 (11), 2083-2095.
- Rocchini D., Salvatori N., Beierkuhnlein C., Chiarucci A., de Boissieu F., Förster M., Garzon-Lopez C. X., Gillespie T. W., Hauffe H. C., He K. S., Kleijn D., Kleinschmit B., Lenoir J., Malavasi M., Moudry V., Nagendra H., Payne D., Šimová P., Torresani M., Wegmann M., Féret J.-B., 2021: From local spectral species to global spectral communities: a benchmark for ecosystem diversity estimate by remote sensing. Ecological Informatics 61, 101195.
- St-Louis V., Pidgeon A. M., Kuemmerle T., Sonnenschein R., Radeloff V. C., Clayton M. K., Locke B. A., Bash D., Hostert P., 2014: Modelling avian biodiversity using raw, unclassified satellite imagery. Philosophical Transactions of the Royal Society B 369 (1643), 20130197.
- Šimová P., Moudry V., Komárek J., Hrach K., Fortin M.-J., 2019: Fine scale waterbody data improve prediction of waterbird occurrence despite coarse species data. Ecography 42 (3), 511-520.
- Šimová P., 2005: Analýza vlivu krajinných atributů na ptáci společenstva s využitím vybraných geodat. Česká zemědělská univerzita v Praze, Fakulta lesnická a environmentální, Praha. Disertační práce, 115 s.
- Šťastný K., Bejček V., Mikuláš I., Telenský T., 2021: Atlas hnízdního rozšíření ptáků v České republice: 2014-2017. Aventium, Praha.

Předběžný termín obhajoby

2023/24 LS – FŽP

Vedoucí práce

prof. Ing. Petra Šimová, Ph.D.

Garantující pracoviště

Katedra prostorových věd

Elektronicky schváleno dne 21. 3. 2024

prof. Ing. Petra Šimová, Ph.D.

Vedoucí katedry

Elektronicky schváleno dne 21. 3. 2024

prof. RNDr. Michael Komárek, Ph.D.

Děkan

V Praze dne 23. 03. 2024

Čestné prohlášení

Prohlašuji, že jsem bakalářskou práci na téma: Spektrální variabilita jako indikátor druhové diverzity ptáků a ornitologické hodnoty území v podrobném měřítku hodnocení vypracoval samostatně a citoval jsem všechny informační zdroje, které jsem v práci použil a které jsem rovněž uvedl na konci práce v seznamu použitých informačních zdrojů.

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

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

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

V Lounech dne 26.3.2024

.....

Poděkování

Děkuji prof. Ing. Petře Šímové Ph.D. za námět a odborné vedení mé bakalářské práce.
Dále bych rád poděkoval svým rodičům za trpělivost a podporu během celého studia.

Abstrakt

Bakalářská práce se zabývá predikcí druhové diverzity a ornitologické hodnoty ptáků ve Žďárských vrších za použití multispektrálních satelitních snímků Landsat. Hlavním cílem je ověřit platnost a využitelnost hypotézy o spektrální variabilitě. Tato hypotéza předpokládá, že vyšší variabilita spektrálních charakteristik snímku indikuje heterogennější prostředí, což by mělo vést k vyšší diverzitě druhů. Tuto hypotézu řešilo již mnoho studií a některé ji potvrdily, jiné vyvrátily. Velmi zde záleží na měřítku výzkumu, čemuž se věnuje rešeršní část bakalářské práce.

V metodické části bakalářská práce nejprve popisuje výpočet vysvětlovaných proměnných (počet druhů, Shannonův index diverzity, ornitologická hodnota) na zkoumaných lokalitách. Následuje odvození vysvětlujících proměnných neboli prediktorů ze satelitního snímku, jimiž jsou medián a směrodatná odchylka jednotlivých spektrálních pásem a spektrálních indexů ve 150metrovém okolí zkoumaných lokalit. Vztah mezi vysvětlovanými proměnnými a jejich prediktory je analyzován pomocí zobecněného lineárního modelu.

Výsledky ukázaly, že použití spektrální variability je problematické. Pouze některá spektrální pásma a indexy reagovaly dle této hypotézy, většinou v případě, kdy bylo využito blízké infračervené pásma (v rámci indexu NDVI nebo jako samotné čtvrté spektrální pásma). To potvrzuje jeho užitečnost, poněvadž se používá pro posouzení biodiverzity velice často. Z výsledků lze usoudit, že druhová diverzita i ornitologická hodnota ptáků ve Žďárských vrších rostla v heterogenním prostředí se zdravou hustou vegetací a proměnlivou vlhkostí.

Avšak kombinace 30metrových pixelů ze snímku Landsat 5 a 7hektarových zkoumaných lokalit se neukázala jako příliš vhodná k posouzení biodiverzity nebo ornitologické hodnoty pomocí spektrální variability. Vhodné by bylo postup ověřit v jiném měřítku a v různých fenologických fázích.

Klíčová slova: GIS, Landsat, NDVI, Shannonův index, modely druhové distribuce

Abstract

The bachelor thesis examines the prediction of bird species diversity and ornithological value in Žďárské vrchy using Landsat multispectral satellite imagery. The primary objective is to validate the applicability and usefulness of Spectral Variability Hypothesis. This hypothesis assumes that higher variability in spectral characteristics of the image indicates more heterogeneous environment which should lead to higher species diversity. The hypothesis has been explored in numerous studies and some of them confirmed it, others rejected it. It is hugely dependent on the scale of the research which is summarised in the literary research of the thesis.

In the methodology section, the thesis describes the calculation of the response variables (species richness, Shannon diversity index, ornithological value) at study sites. This is followed by deriving the explanatory variables or so-called predictors from the satellite image. The median and standard deviation of each spectral band and of several indices are calculated within a 150-meter surroundings of the sites. The relationship between the response variables and their predictors is then analyzed using a generalized linear model.

The results reveal that using spectral variability is problematic. Only some of the spectral bands and indices supported the hypothesis, mostly when using the near-infrared band (within the NDVI indice or the fourth spectral band alone). This confirms its utility, as it is very often used for biodiversity assessment. The results show that bird species diversity and ornithological value in Žďárské vrchy increased in heterogeneous environment with healthy dense vegetation and variable wetness.

However, the combination of 30-meter pixels from Landsat 5 imagery and 7-hectare study sites did not prove to be very suitable for assessing biodiversity or ornithological value using spectral variability. It would be appropriate to verify the approach at a different scale and during various phenological stages.

Keywords: GIS, Landsat, NDVI, Shannon index, species distribution models

Obsah

1.	Úvod.....	11
2.	Cíle práce	11
3.	Literární rešerše.....	12
3.1	Dálkový průzkum Země.....	12
3.1.1	Neklasifikovaná a klasifikovaná data.....	13
3.1.2	Spektrální pásma a spektrální indexy.....	14
3.2	Biodiverzita	15
3.2.1	Druhová diverzita.....	15
3.2.2	Biodiverzita a prostorové měřítka.....	16
3.2.3	Ekologická nika.....	16
3.2.4	Metriky biodiverzity.....	17
3.3	Hypotéza o spektrální variabilitě	18
3.4	Modely druhové distribuce	19
3.4.1	Neurčitost v modelech druhové distribuce.....	20
3.4.2	Problematika dat o výskytu druhů.....	20
3.4.3	Problematika environmentálních proměnných	22
4.	Metodika	23
4.1	Popis zájmového území.....	23
4.2	Landsat	25
4.3	Použitá data a použitý software.....	26
4.4	Určení vysvětlovaných proměnných.....	27
4.4.1	Ornitologická hodnota.....	27
4.4.2	Druhová diverzita.....	28
4.5	Určení vysvětlujících proměnných – prediktorů	29
4.6	Analýza vysvětlovaných proměnných a prediktorů	30
4.7	Korelace a multikolinearita prediktorů	31

4.8	Zobecněné lineární modely	33
5.	Výsledky	35
6.	Diskuse	47
7.	Závěr	50
8.	Přehled literatury a použitých zdrojů	51
9.	Přílohy	60

1. Úvod

Biodiverzita neboli rozmanitost života na Zemi je klíčovou složkou jeho správného fungování. V poslední době však dochází vlivem lidské činnosti k narušování a úbytku biodiverzity. Její správné posouzení a vyhodnocení je tedy stále naléhavější, avšak velmi náročné. Velkou pomocí se zdají být moderní technologie, zejména dálkový průzkum Země a geografické informační systémy. Tyto disciplíny se dynamicky vyvíjejí a poskytují širokou škálu nástrojů k analýzám v prostoru. Díky velkému rozvoji výpočetních technologií se také stále více využívá i modelování různých jevů, jako je například rozšíření druhů. Významnou součástí všech ekosystémů jsou ptáci. Jedná se o velice oblíbenou a snadno pozorovatelnou skupinu organismů, která je často předmětem výzkumu. A bylo tomu tak i v této bakalářské práci.

2. Cíle práce

Hlavním cílem bakalářské práce bylo zjistit, zda či jakým způsobem je druhová diverzita vysvětlitelná daty pořízenými prostřednictvím systémů dálkového průzkumu Země a zda platí tzv. hypotéza spektrální variability. Konkrétně byla zkoumána diverzita ptačích druhů na území Žďárských vrchů.

Cílem byly také výsledky jednotlivých dílčích kroků. Druhová diverzita byla vyjádřena počtem zaznamenaných druhů na určitých lokalitách a také hodnotami Shannonova indexu diverzity. Spočtena byla ornitologická hodnota lokalit podle hodnot vyskytujících se druhů.

Získány byly informace ze satelitních snímků. Pro jednotlivá spektrální pásmá byl zjištěn medián a spektrální variabilita určená směrodatnou odchylkou pro 150metrové okolí zkoumaných lokalit. Ze spektrálních pásem byly odvozeny spektrální indexy a rovněž byl zjištěn jejich medián a spektrální variabilita pro 150metrové okolí lokalit.

Závěrečné modelování mělo za cíl zjistit, zda prediktory odvozené ze satelitních snímků mohou predikovat diverzitu daného území v daném měřítku.

3. Literární rešerše

3.1 Dálkový průzkum Země

Dálkový průzkum Země je věda a do jisté míry i umění zabývající se získáváním informací o zemském povrchu bez přímého kontaktu s ním. To umožňuje snímání odražené či vyzářené elektromagnetické energie (CCRS ©2019). Tato energie se šíří prostorem v podobě vln a rychlostí světla. Vzdálenost měřená mezi dvěma vrcholy takovýchto vln se nazývá vlnová délka. Počet vrcholů vln, který projde určitým bodem za určitý čas se označuje jako frekvence. Elektromagnetické spektrum zahrnuje různé formy a kategorie elektromagnetického záření dle jejich vlnové délky. Jsou jimi gamma záření, rentgenové záření, ultrafialové záření, viditelné světlo, infračervené záření, mikrovlnné záření a rádiové záření (Lillesand et al. 2015).

V dálkovém průzkumu Země se využívají dva systémy sběru dat. Pasivní systémy zaznamenávají elektromagnetické záření odražené od terénu či terénem vyzářené. K tomu využívají multispektrální senzory, které snímají v pásmech o různé šířce vlnové délky (Jensen 2015). Poté existují aktivní senzory jako RADAR nebo LiDAR, které k terénu vysílají své záření a sledují jeho odraz (Tempfli et al. 2009).

Snímání může probíhat ze zemského povrchu, z leteckých prostředků uvnitř zemské atmosféry nebo ze satelitů vně zemské atmosféry. Satelity obíhají Zemi po dráhách zvaných orbitu v různých výškách a různou rychlostí. Od toho se odvíjí některé vlastnosti multispektrálního snímání. Prostorové rozlišení je určeno nejmenším možným rozpoznatelným objektem na snímku. Časové rozlišení říká, za jakou dobu satelit Zemi obletí (CCRS ©2019). Spektrální rozlišení je určeno počtem a šírkou jednotlivých spektrálních pásem. Radiometrické rozlišení závisí na citlivosti senzoru zaznamenat rozdíly v přijaté energii (Jensen 2015).

Všechno elektromagnetické záření urazí velké vzdálenosti napříč atmosférou, kde je různými způsoby ovlivňováno. Dochází k rozptylu, pohlcení a absorpci. Záření je absorbováno zejména vodní párou, oxidem uhličitým a ozónem (Tempfli et al. 2009). Míra absorpcie závisí na vlnové délce záření. Části elektromagnetického spektra, kde je absorpcie nejnižší a záření zde prochází lépe, se nazývají atmosférická okna, a právě s těmi pracují senzory dálkového průzkumu Země (Lillesand et al. 2015).

Záření reaguje taktéž se zemským povrchem, může být odraženo, absorbováno či propuštěno. Proporce těchto tří složek jsou závislé na typu materiálu (zemského povrchu) a vlnové délce záření (Tempfli et al. 2009). Proto se například dva různé prvky zemského povrchu mohou jevit v jednom spektrálním pásmu naprosto identicky a v jiném spektrálním pásmu pak zcela rozdílně. Mnoho systémů dálkového průzkumu Země pracuje s vlnovými délkami, u kterých převládá odražená energie. Důležité jsou proto odrazivé vlastnosti zemského povrchu vyjádřené jako odražená část z příchozího záření a nazývané spektrální odrazivost. Graf spektrální odrazivosti určitého objektu zobrazený jako funkce vlnové délky se označuje jako křivka spektrální odrazivosti. Mnoho prvků zemského povrchu má svou typickou křivku, která je charakterizuje (Lillesand et al. 2015).

Multispektrální snímky dálkového průzkumu Země jako jeden z prvních oborů využívala meteorologie. Dnes je jejich využití mnohem širší v mnoha oborech jako zemědělství, lesnictví, geologie nebo hydrologie (CCRS ©2019). Jsou významným zdrojem dat pro rozlišení typů krajinného pokryvu a využití (Tempfli et al. 2009).

3.1.1 Neklasifikovaná a klasifikovaná data

Data dálkového průzkumu Země se dají rozdělit na dvě skupiny. První jsou satelitní snímky, které uchovávají původní spojitou povahu dat a označují se jako neklasifikovaná data. Druhou skupinou jsou klasifikovaná data, která se často ze satelitních snímků odvozují a člení krajinu na diskrétní kategorie jako například třídy krajinného pokryvu (Hopkins et al. 2022). V ekologii a ochraně přírody byly nejběžněji používány právě takovéto klasifikované mapy, které však mají určité nevýhody (Duro et al. 2014, Oeser et al. 2019).

Existuje jen pár volně dostupných produktů poskytujících tato data pro celé státy a kontinenty (Corine Land Cover) či celý svět (Global Land Cover Project). Prostorové rozlišení těchto map je obvykle nízké, takže jsou malé plošky habitatů a přechody mezi nimi (ekotony) přehlíženy (Prajzlerová et al. 2024), stejně jako další klíčové prvky prostředí (Oeser et al. 2019). Dalším omezením je tematické rozlišení. Krajina je totiž většinou klasifikována do kategorií dle vnímání člověka, což se nemusí shodovat s nároky jiných druhů (Coops et Wulder 2019).

Přechody mezi jednotlivými kategoriemi též nejsou kontinuální, tak jako tomu je ve skutečném světě. Klasifikací dochází ke značné ztrátě původních kontinuálních kvantitativních informací (Palmer et al. 2000). Přesnost klasifikace navíc není nejvyšší, kolem 65 až 80 % (Gong et al. 2013, Chen et al. 2015), tedy až třetina pixelů může být klasifikována chybně. Proces klasifikace je časově náročný i nákladný. Data jsou navíc dostupná jen pro omezená období, což omezuje například analýzy změn. Neklasifikované snímky jsou tak alternativou, která výše zmíněnými nedostatky netrpí. Uchovávají totiž původní informaci v každém pixelu zvlášť (Prajzlerová et al. 2024).

3.1.2 Spektrální pásma a spektrální indexy

Spektrální pásmo označuje interval elektromagnetického záření, ve kterém senzor zaznamenává odražené záření (Tempfli et al. 2009). Multispektrální systémy mají několik takovýchto pásů, hyperspektrální systémy jich mají stovky. Vybírájí se většinou tak, aby se maximalizoval kontrast mezi zkoumaným objektem a jeho pozadím (Jensen 2015).

Nejkratší vlnovou délku má modré spektrální pásmo (B), hodí se pro monitorování vodních ekosystémů, poněvadž proniká hlouběji, dále pro rozlišení holé půdy a vegetace nebo odlišení jehličnatých a listnatých stromů. Zelené spektrální pásmo (G) se hodí pro posouzení stavu vegetace. Pro zjištění zdraví vegetace či odlišení jejích různých typů lze použít také červené spektrální pásmo (R), protože vegetace absorbuje téměř všechno červené záření (Geospatial Innovation Facility ©2008, USGS ©2024a). Tato tři spektrální pásma, nazývaná též viditelná, se rovněž dají využít k identifikaci člověkem vytvořených objektů (Portland State University ©2001). Dalším pásmem je blízké infračervené (NIR), které je téměř zcela pohlcené vodou. Vodní plochy se tak jeví velmi tmavé (Geospatial Innovation Facility ©2008). Toto pásmo je také velmi citlivé na množství biomasy. Krátkovlnné infračervené pásmo (SWIR) reaguje na vlhkost, což se opět hodí k monitorování vegetace a půdy (USGS ©2024a).

Spektrální indexy vznikají různými kombinacemi spektrálních pásů. Zvýrazňují konkrétní krajinné prvky na základě jejich spektrálních vlastností. Nabývají určitého rozsahu hodnot, kde vyšší hodnoty reprezentují daný prvek (Alessandrini et al. 2022). Spektrální index NDVI (Normalized Difference Vegetation Index) se používá

k posouzení zdraví vegetace. Spočte se: $(\text{NIR} - \text{R}) / (\text{NIR} + \text{R})$. Podobný je index EVI (Enhanced Vegetation Index), který potlačuje vlivy atmosféry a pozadí, a je také více citlivý v oblastech s hustší vegetací. K tomu využívá koeficienty C, L, G a modré spektrální pásmo. Spočte se: $G * ((\text{NIR} - \text{R}) / (\text{NIR} + \text{C1} * \text{R} - \text{C2} * \text{B} + \text{L}))$. Index SAVI (Soil Adjusted Vegetation Index) se používá ke korekci NDVI v místech se světlou půdou a malým vegetačním pokryvem. Spočte se: $((\text{NIR} - \text{R}) / (\text{NIR} + \text{R} + \text{L})) * (1 + \text{L})$. L je korekční faktor. Index NDMI (Normalized Difference Moisture Index) slouží k určení obsahu vody ve vegetaci. Spočte se: $(\text{NIR} - \text{SWIR}) / (\text{NIR} + \text{SWIR})$ (USGS ©2024b).

3.2 Biodiverzita

Slovo biodiverzita pochází ze spojení biologická diverzita a označuje veškerou rozmanitost živé přírody na různých úrovních. Lze měřit genetickou diverzitu přímo s použitím sekvencí DNA, počítat druhy nebo vyšší taxony, stanovovat funkční rozmanitost ekosystémů nebo počítat spektrální variabilitu zeleně z družicových snímků. Zřejmě nejčastěji se řeší druhová diverzita (Storch 2019). Druh je dle morfologické definice skupina jedinců, kteří se morfologicky, fyziologicky nebo biochemicky odlišují od jiných skupin v nějaké důležité charakteristice. Biologická definice říká, že druh je skupina jedinců, kteří se mohou v přírodě navzájem křížit a kteří se nekříží s jedinci jiných skupin (Primack et al. 2011).

3.2.1 Druhová diverzita

Druhová diverzita se nejčastěji vyjadřuje jako počet druhů, což lze též nazvat druhovou bohatostí (Boháč 2013). V takovém případě ovšem dochází k zanedbání obrovských rozdílů v početnosti daných druhů, a tedy i jejich ekologického významu. Každé společenstvo se přitom vyznačuje jen několika hojnými druhy a velkým množstvím druhů vzácnějších (Šálek et Harabiš 2015). Proto vznikly různé indexy zohledňující i relativní vyrovnanost druhů, například Shannonův index diverzity. Pokud ale kupříkladu tento index dosahuje vysoké hodnoty, tak z něj nelze vyčíst, zda je dané společenstvo druhově početné, nebo spíše početně vyrovnané. Obecně nastávají situace, kdy různé míry biodiverzity s počtem druhů dobře korelují, a stačí tedy použít rovnou počet druhů, nebo naopak nekorelují, a pak však nelze zjistit, co

vlastně dané míry znamenají. Je tedy pragmatické biodiverzitu vyjadřovat jako počet druhů a doufat, že to vystihne i jiné aspekty biologické rozmanitosti (Storch 2019).

3.2.2 Biodiverzita a prostorové měřítko

Biodiverzita závisí na prostorovém měřítku. Větší počet druhů bývá na větších plochách (Storch 2019). Procesy udržující biodiverzitu na lokální úrovni jsou jiné než na úrovni regionální (Storch et Mihulka 1997). O lokální diverzitě rozhoduje schopnost druhů koexistovat spolu na jedné ploše a také intenzita či pravděpodobnost kolonizace dané lokality. Regionální diverzita je rozmanitost velkých území jako biomů či kontinentů, kde se předpokládá, že většina druhů vznikla právě na nich a nepřišla odjinud. Rozhodují zde tedy evoluční procesy speciace neboli vznik druhů a extinkce neboli vymírání (Storch 2019).

Dle těchto hledisek se rozlišuje alfa-diverzita jako počet druhů na jedné studované lokalitě a gama-diverzita jako počet druhů na velkém území. Gama-diverzita často, ale ne vždy, představuje tzv. species pool, což je množina druhů, které jsou potenciálně schopné osídlit danou lokalitu (Storch 2019). Beta-diverzita spojuje alfa-diverzitu a gama-diverzitu přibližně jako změnu v druhovém složení mezi dvěma prostředími (Primack et al. 2011). Je klíčovým měřítkem, vyjadřuje totiž heterogenitu mezi lokalitami (Rocchini et al. 2021). Často je brána jako ekvivalent k pojmu species turnover, což je podobnost mezi lokalitami z hlediska druhového složení (Storch 2019).

3.2.3 Ekologická nika

Každý organismus je během svého života trvale ovlivňován okolním prostředím, které jej do jisté míry limituje. Je tvořené abiotickými a biotickými faktory. Abiotické jsou horniny, minerály, organické sloučeniny, voda, plyny, světlo či teplo. Biotické je působení ostatních organismů v rámci mezidruhových vztahů, jako jsou konkurence, predace, parazitismus či symbióza (Šálek et Harabiš 2015).

Komplexní začlenění druhu v prostředí vyjadřuje ekologická nika. Ta zahrnuje jeho zapojení v potravních sítích, požadavky na další zdroje (např. světlo, voda), prostorové nároky (např. umístění hnizda, místo výskytu), časové rozložení aktivity (denní a

sezonní rytmus), požadavky na místa a období rozmnožování či jiné životní projevy. Každý druh se vyznačuje specifickou ekologickou nikou. Čím jsou si ekologické niky dvou druhů podobnější, tím více interakcí mezi nimi nastává (Laštůvka et Krejčová 2000). Větší množství ekologických nich je dostupných ve více heterogenním prostředí, které může hostit více druhů (Rocchini et al. 2010). Vyšší heterogenita prostředí tedy znamená vyšší biodiverzitu (Stein et al. 2014).

3.2.4 Metriky biodiverzity

Zásadním úkolem ekologie a ochrany přírody je vysvětlit, proč a jak se biodiverzita v prostoru mění, a umět ji také přesně zmapovat. Je však logicky nemožné sesbírat data o rozšíření druhů organismů k určení biodiverzity rozsáhlých území nebo ke sledování její změny v čase. Proto je nutné určit jakýsi indikátor neboli proxy proměnnou (Prajzlerová et al. 2024). Tím může být v případě ptačí diverzity třeba i výskyt určitého druhu (Morelli et al. 2017) nebo složení a struktura krajiny (Morelli et al. 2018).

Tradiční metoda spočívá v řízené klasifikaci multispektrálních snímků, která odliší jednotlivé třídy krajinného pokryvu (Prajzlerová et al. 2024). Z nich se poté dají odvodit krajinné metriky (Morelli et al. 2018), například rozloha jednotlivých tříd, počet tříd či polygonů na určité ploše nebo rozloha největšího polygonu. S jejich pomocí se pak dá diverzita charakterizovat (Šimová et Gdulová 2012).

Duro et al. (2014) či Prajzlerová et al. (2024) však došli k závěru, že modely založené na neklasifikovaných datech dálkového průzkumu Země vysvětlují diverzitu ptačích druhů lépe než modely a metriky založené na klasifikovaných datech. Kombinací obou typů dat se dosáhne jen malého zlepšení výsledků (Prajzlerová et al. 2024). Proxy proměnnou tak může být například i spektrální variabilita multispektrálních satelitních snímků (Lopes et al. 2017).

3.3 Hypotéza o spektrální variabilitě

Palmer et al. (2000) navrhli hypotézu spektrální variability neboli spectral variability hypothesis (SVH). Ta říká, že environmentální heterogenita a tím i počet druhů pozitivně koreluje s variací spektrálních charakteristik snímků pořízených v rámci dálkového průzkumu Země (Palmer et al. 2002).

Hypotéza byla testována na různých typech organismů jako jsou savci (Oeser et al. 2019) či ptáci (Hunt et al. 2022), nejvíce však cévnaté rostliny (Rocchini et al. 2004, Levin et al. 2007, Perrone et al. 2023). Snímky z multispektrálních senzorů totiž obsahují přímé informace o vegetaci na zemském povrchu, čímž však pouze popisují habitat živočichů (Prajzlerová et al. 2024).

Spektrální variabilita závisí na měřítku výzkumu. Rocchini et al. (2004) na prostorových měřítkách 100 m² a 1 ha potvrdili, že její vysvětlující schopnost roste se zvětšující se plochou analyzované oblasti. Tato plocha však nesmí být příliš velká a zároveň nesmí být rozlišení příliš nízké, jak zjistili Schmidlein et Fassnacht (2017) na rozsahu 12 x 11 km a rozlišení 0,5 km. Úspěšnost spektrální variability je též závislá na typu krajiny (Schmidlein et Fassnacht 2017) a ročním období pořízení snímku (Torresani et al. 2019).

Existuje mnoho způsobů, jimiž lze vyjádřit spektrální variabilitu. Příkladem je směrodatná odchylka nebo variační koeficient pro jednotlivá spektrální pásma či indexy (Wang et Gamon 2019). Komplexnějším způsobem, avšak náročnějším na výpočet, je například Rao's Q index (Rocchini et al. 2016).

Na základě spektrální variability byl také odvozen tzv. koncept spektrálních druhů, který předpokládá, že skupiny druhů mají podobný spektrální projev (Rocchini et al. 2021).

3.4 Modely druhové distribuce

Modely druhového rozšíření či druhové distribuce (species distribution models – SDM) jsou důležitým nástrojem v biogeografii i ekologii. Pomáhají porozumět vztahu mezi druhy a jejich habitaty neboli přirozeným prostředím. Využívají data o výskytu druhů a environmentální proměnné. S jejich pomocí vytváří pravidla pro rozdělení prostoru, podle toho, kde druh byl pozorován a kde by pro něj dále mohly být vhodné podmínky (Moudrý et Šimová 2012). Druhovou distribuci lze modelovat různými metodami, často s použitím geografických informačních systémů neboli GIS (Franklin 2010). Lze se setkat i s názvy jako modely habitatu nebo modely ekologické niky (Elith et Leathwick 2009). Každopádně mají tyto modely druhového rozšíření využití v mnoha aspektech environmentálního výzkumu a ochrany přírody (Franklin 2010).

Byly použity například k vyhodnocení relativního vlivu environmentálních faktorů na druhovou distribuci (Storch et al. 2003, Moudrý et Šimová 2013), k identifikaci dosud neznámých populací ohrožených druhů (Jackson et Roberston 2011), k odhadnutí potenciální distribuce invazních druhů (Chytrý et al. 2012), k predikování rozdílu v druhové distribuci i početnosti způsobeném klimatickou změnou (Hongoh et al. 2012, Renwick et al. 2012) nebo k posouzení vlivu změn v krajinném využití na druhovou distribuci (Schleupner et Link 2008).

Je nutné rozlišovat potenciální a skutečnou distribuci. Potenciální distribuce se vztahuje k místům, kde by daný druh mohl žít (Jiménez-Valverde et al. 2008). Je určena rozmezím environmentálních podmínek, které je druh schopen fyziologicky tolerovat (Moudrý et Šimová 2012). Skutečná distribuce se vztahuje k místům, kde druh opravdu žije (Jiménez-Valverde et al. 2008). Typicky se jedná o podmnožinu potenciální distribuce, poněvadž je druh ovlivňován faktory jako kompetice či disturbance (Moudrý et Šimová 2012). Důležité je, že oba tyto koncepty odkazují na určitý moment nebo rozmezí v čase (Jiménez-Valverde et al. 2008). Jakýkoli časový nesoulad mezi daty o výskytu druhů a environmentálními proměnnými zhoršuje výsledný model (Roubicek et al. 2010). Časové rozlišení obou datových sad by proto mělo být srovnatelné (Moudrý et Šimová 2012).

3.4.1 Neurčitost v modelech druhové distribuce

Modely druhové distribuce jsou ovlivňovány mnoha podstatnými zdroji neurčitosti, které vznikají rozdílem mezi kontinuitou reálného světa a jeho zjednodušenou diskrétní reprezentací v geografických informačních systémech. Neurčitost plyně z vysvětované a vysvětlující proměnné a z algoritmu či funkce, která je porovnává (Moudrý et Šimová 2012). Neurčitosti v datech o výskytu druhů se týkají velikosti zkoumaného vzorku, polohové přesnosti a tzv. sampling bias (Moudrý et al. 2024). Důležitá je také dostupnost dat skutečné absence. V případě vysvětlujících environmentálních proměnných neurčitost plyně z původu dat a jejich prostorového rozlišení a také z výběru relevantních proměnných (Moudrý et Šimová 2012). Pro dobrý model je totiž klíčové vybrat vhodné environmentální proměnné. Bývá tomu však věnována menší pozornost, než například výběru modelovací metody (Williams et al. 2012).

3.4.2 Problematika dat o výskytu druhů

Studií zkoumajících vliv neurčitosti na modely v dnešní době výrazně přibývá. Dostupných je stále více polohově přesnějších dat o výskytu druhů, která využívají technologie globálních navigačních satelitních systémů (Moudrý et Šimová 2012). Přesto data o výskytu už ze své podstaty obsahují určitou chybu v polohové přesnosti, která má na model druhové distribuce významný vliv (Gábor et al. 2022).

Úspěšnost modelu klesá se zvyšující se polohovou chybou a také se snižujícím se prostorovým měřítkem analýzy. Snížení rozlišení s cílem kompenzovat polohovou chybu výsledky modelu nezlepší (Gábor et al. 2022). Pokud jsou do modelu zahrnuta data o výskytu druhů v hrubším prostorovém i časovém rozlišení, úspěšnost modelu se snižuje i navzdory případnému zvýšení množství těchto dat (Moudrý et Šimová 2012). Někdy může být na výběr mezi velkým množstvím výskytových dat s nízkou přesností a malým množstvím dat s vysokou přesností. Kaliontzopoulou et al. (2008) zjistili, že modely založené na přesnějších datech byly lepší, přestože zde bylo dat méně.

Polohová nepřesnost výskytových dat může vést k chybné charakterizaci podmínek výskytu druhu, zvláště v oblastech, kde se podmínky rychle mění, což jsou například hory (Feeley et Silman 2010). Vliv takovéto chyby se zvyšuje s podrobnějším měřítkem, kdy se často daný druh nenachází ve svém vhodném prostředí. Nedokázal se tam rozšířit, působily na něj nepříznivé biotické faktory a podobně. Proměnné spojené s těmito náhodnými či ekologickými procesy by do modelu skutečné distribuce měly také vstupovat (Moudrý et Šimová 2012). Více ovlivněné polohovými nepřesnostmi jsou taktéž modely pro druhy s úzkou ekologickou nikou, tedy specialisty, než pro generalisty (Gábor et al. 2019).

Data o výskytu druhů bývají ovlivněna prostorovým zkreslením, kdy jsou některé lokality nebo environmentální podmínky pozorovány častěji než ostatní. Data častěji vznikají například na snadno přístupných místech než na místech odlehлých či méně oblíbených. Tato problematika se nazývá sampling bias (Moudrý et al. 2024). Modelování skutečné distribuce také vyžaduje data o skutečné absenci druhu. Bývají však často nedostupná či složitá k interpretaci. Použití dat pouze o přítomnosti druhu není dostatečné a zhoršuje model, podobně jako využití dat pseudo-absence (Václavík et Meentemeyer 2009), kde velice záleží na metodě jejich vygenerování (Chefaoui et Lobo 2008).

Moudrý et Šimová (2012) rozlišují dva případy využití vhodné pro data s různou přesností. Při modelování skutečné distribuce druhu, která je potřebná pro managementové a ochranářské cíle vyžadující minimalizování nejistot, navrhují používat polohově přesná a početná data o výskytu. Méně početná data mohou sloužit k modelování potenciální distribuce, a tedy k predikování území splňující minimální fyziologické požadavky daného druhu. Taková data často pochází z méně prozkoumaných oblastí a modely tak mohou pomoci s objevením dosud neznámých populací. Vhodná filtrace dat by pak měla být rutinním postupem s cílem minimalizovat možný vliv polohové nepřesnosti v datech o výskytu. Navíc se proměnné popisující variabilitu polohové přesnosti dají využít též jako prediktory (Moudrý et Šimová 2012).

3.4.3 Problematika environmentálních proměnných

Prostorové měřítko environmentálních proměnných je určené rozlišením, například velikostí pixelu, a rozsahem zkoumaného území. Měřítko je nutné volit optimálně pro konkrétní druh či účel výzkumu (Moudrý et Šímová 2012). Data o vysokém rozlišení umožňují počítat s prostorově menšími prvky, jako jsou například jednotlivé stromy nebo malé vodní plochy, což zlepšuje výsledky modelu (Gottschalk et al. 2011), i pokud jsou data o výskytu druhů v rozlišení hrubším (Šímová et al. 2019).

Vliv prostorového rozlišení environmentálních proměnných byl předmětem mnoha výzkumů. Kaliontzopoulou et al. (2008) prokázali lepší výsledky modelu s daty o rozlišení 1 km^2 oproti 10 km^2 . Graf et al. (2005) snižovali rozlišení z 1 ha na cca 1100 ha (11 km^2) a nejlepší výsledky modelu zaznamenali kolem 1 až 2 km^2 . Heikkinen et al. (2007) dosáhli dokonce lepších výsledků s rozlišením 1 ha a 25 ha než 1 km^2 .

Moudrý et Šímová (2012) navrhují, že s daty, která jsou v současnosti dostupná, je vhodné studovat environmentální podmínky limitující rozšíření druhu v měřítku 1 až 100 km^2 . Se zvyšující se dostupností prostorově přesnějších dat se toto doporučení bude pravděpodobně měnit, což dokládají Gottschalk et al. (2011), jejichž modely ptačí distribuce byly nejpřesnější s daty o rozlišení 1 až 3 m. Podrobná data umožňují pochopit třeba ptačí výběr mikrohabitátů a jeho přizpůsobování měnícím se klimatickým podmínkám (Alessandrini et al. 2022) nebo určení lokální početnosti druhu na úrovni jeho teritoria či domácího okrsku (Brambilla et al. 2023). Záleží však na zkoumaném druhu, krajině i environmentálních proměnných (Moudrý et Šímová 2012). Různé druhy totiž reagují na svá prostředí v různých prostorových měřítkách (Holland et al. 2004).

4. Metodika

4.1 Popis zájmového území

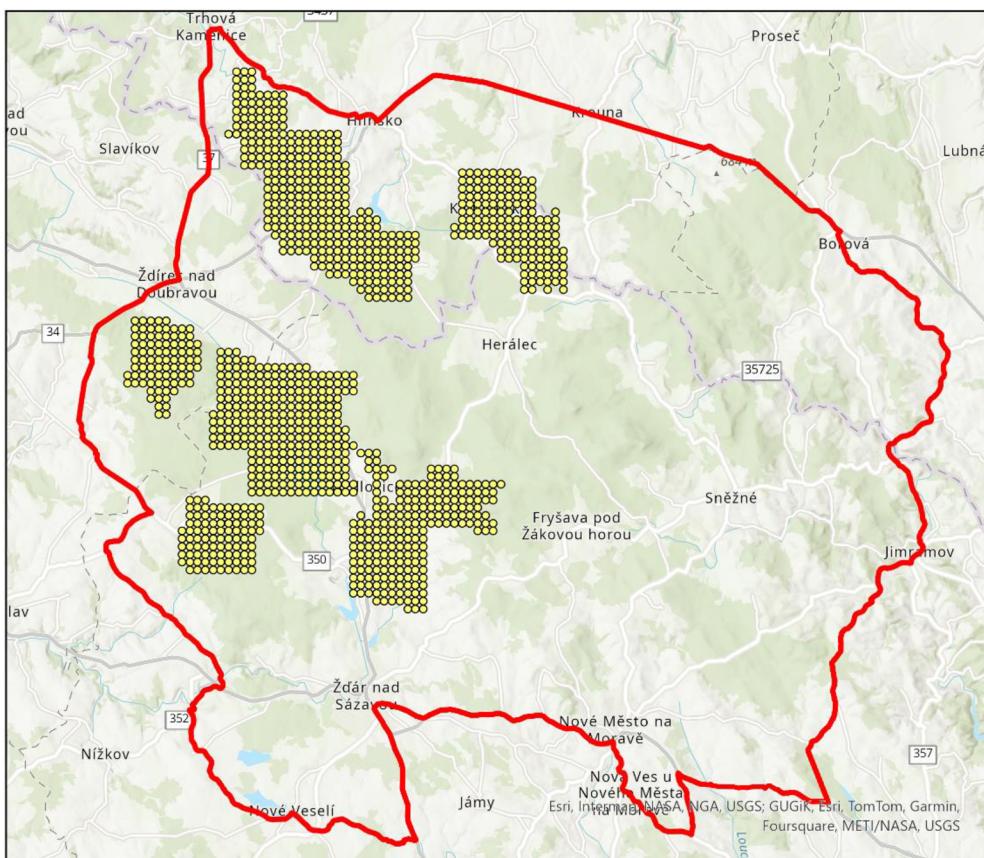
Žďárské vrchy jsou dosud krajinou s výraznou svébytnou atmosférou. Zemědělská činnost omezovaná tvrdými přírodními podmínkami zde po staletí formovala krajinu do půvabné mozaiky lesů a lesíků, květnatých luk i kamenitých pastvin, rybníků, skrčených roubených chalup, políček žita, ovsy, brambor a lnu, omšelých kamenic se solitéry sněhem pokroucených jeřábů (Bajer et al. 2014). Žďárské vrchy jsou oblastí s vrchovinným až pahorkatinným charakterem. Rozkládají se v severozápadní části Českomoravské vrchoviny, převážně v kraji Vysočina (Bajer et al. 2014). Klimaticky patří k chladnějším, vlhčím a značně větrným územím (AOPK ČR ©2024).

Doba intenzifikace zemědělství původní ráz této krajiny na mnoha místech významně změnila, přesto stále zůstává mnoho důvodů, proč chránit hodnoty této jedinečné krajiny i do budoucna. Chráněná krajinná oblast Žďárské vrchy (Obrázek 1) byla vyhlášena v roce 1970. Jejím posláním je zachování harmonicky vyvážené kulturní krajiny s významným zastoupením přírodních fenoménů (Bajer et al. 2014). Nachází se zde čtyři národní přírodní rezervace. Dářko a Radostínské rašeliniště představují rozsáhlá rašeliniště, která vznikala koncem doby ledové. Ransko a Žákova hora pak reprezentují přirodě blízké lesní porosty. Poslední jmenovaná lokalita je už od 30. let minulého století ponechávána z velké části bez lidských zásahů (AOPK ČR ©2024).

Lesy celkově zaujmají cca 48 % rozlohy chráněné krajinné oblasti. Velkou část z nich však tvoří stejnověké smrčiny, které v současné době představují vysoké riziko z hlediska šíření kůrovce (Hlaváč 2020). Lesy jsou domovem mnoha druhů ptáků. Mezi významné lesní druhy oblasti patří datel černý, žluna šedá či strakapoud velký, kteří vytvářejí své dutiny a umožňují tak i zahnízdění dalším druhům. Typickými obyvateli dutin jsou holub doupňák, sýc rousný nebo nejmenší evropská sova kulíšek nejmenší. Vzácnějšími lesními ptáky jsou ořešník kropenatý, sluka lesní, čáp černý, orel mořský, krahujec obecný nebo jestřáb lesní (AOPK ČR ©2024). Některé dříve pravidelně se vyskytující druhy již bohužel vymizely, například tetřívek obecný (Bajer et al. 2014).

CHKO Žďárské vrchy a lokality sčítání ptáků

1:200 000



- CHKO Žďárské vrchy
- lokalita sčítání ptáků

Vojtěch Šebek
Česká zemědělská univerzita, FŽP, Praha 2024
Software: ArcGIS Pro 3.1.0
Souřadnicový systém: S-JTSK Krovak East North
Zdroj dat: data.nature.cz, ČZU

Obrázek 1: Mapa CHKO Žďárské vrchy a lokalit sčítání ptáků

Z dalších přírodních rezervací či přírodních památek tvoří významný podíl vrcholové skály, modelované mrazovým zvětráváním především ve starším období čtvrtoroh. Skály využívá k hnizdění například výr velký nebo krkavec velký (AOPK ČR ©2024). Nejvyšší vrchol Žďárských vrchů, Devět skal, dosahuje 836 metrů nad mořem a je pojmenovaný podle devíti výrazných skalních bloků (Bajer et al. 2014).

Další významnou skupinou cenných území jsou podmáčené až zrašelinělé louky. Zde ve vysoké trávě hnízdí například chřástal polní, bekasina otavní, linduška luční, bramborníček hnědý nebo hýl rudý (AOPK ČR ©2024), který se do oblasti rozšířil teprve nedávno (Bajer et al. 2014).

Žďárské vrchy byly též díky příznivým hydrologickým podmínkám vyhlášeny za chráněnou oblast přirozené akumulace vod (AOPK ČR ©). Pramení zde například Sázava, Svatka a Chrudimka (Bajer et al. 2014). Rybniční hospodaření tu má také dlouhou tradici. V současnosti je zde přes 600 rybníků, nejvýznamnějším je Velké Dářko. Tyto rybničnaté oblasti osídlují druhy vázané na vodu, kterými jsou kopřivka obecná, čírka obecná, polák chocholačka či potápka roháč (AOPK ČR ©2024).

Zemědělská krajina je na živočištvo převážně chudá, obývá ji například křepelka polní nebo tůhýk obecný (AOPK ČR ©2024). Indikátorem stavu zemědělské krajiny je koroptev polní. Kdysi běžný pták se postupně stal ohroženým a chráněným druhem. Novým plánem péče byla koroptev zařazena mezi předměty ochrany chráněné krajinné oblasti Žďárské vrchy (Hlaváč 2020).

4.2 Landsat

Landsat je nejstarší civilní projekt pro dálkové pozorování Země. Řízen je NASA (National Aeronautics and Space Administration) a USGS (United States Geological Survey). První satelit Landsat 1 byl vyslan 23. července 1972. V rozestupu tří až čtyř let následovaly další. Landsat 5 pořizoval globální data zemského povrchu neuvěřitelných 28 let a 10 měsíců, čímž se zapsal do Guinessovy knihy rekordů. Zatím posledním je Landsat 9 vyslaný v září roku 2021 (USGS ©2024c).

Sateliity jsou vybaveny různými senzory, například MSS (Multispectral Scanner) a TM (Thematic Mapper) na Landsatu 5. Nejnovější jsou OLI (Operational Land Imager) a TIRS (Thermal Infrared Sensor) (NASA ©2024).

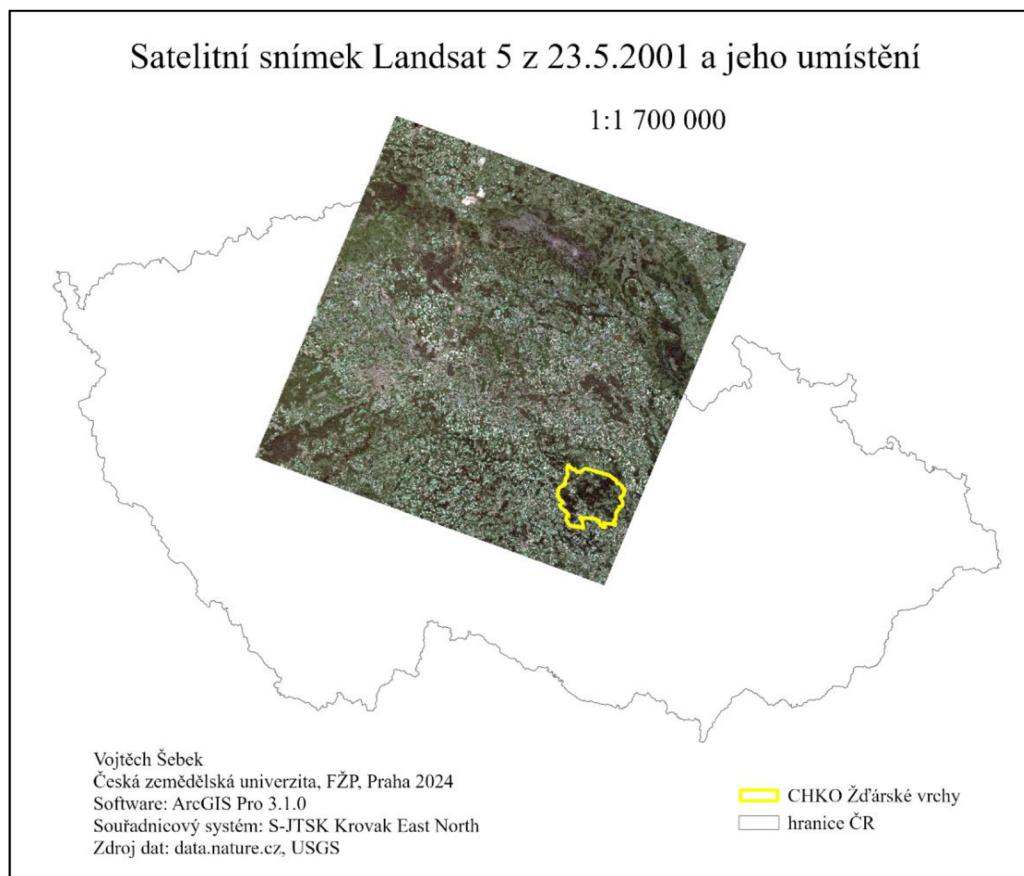
Landsat 5 použitý v této práci obíhal na heliosynchronní a téměř polární dráze ve výšce 705 km. Naskenování celé Země mu trvalo 16 dní (NASA ©2024). Snímal v sedmi spektrálních pásmech (Tabulka 1), jejichž prostorové rozlišení neboli velikost pixelu bylo 30 m. Pouze termální pásmo mělo rozlišení 120 m (USGS ©2024c).

	Spektrální pásmo	Rozsah vlnové délky (μm)	Prostorové rozlišení (m)
1	Viditelné modré	0,45 - 0,52	30
2	Viditelné zelené	0,52 - 0,60	30
3	Viditelné červené	0,63 - 0,69	30
4	Blízké infračervené	0,76 - 0,90	30
5	Krátkovlnné infračervené	1,55 - 1,75	30
6	Termální	10,40 - 12,50	120
7	Krátkovlnné infračervené	2,08 - 2,35	30

Tabulka 1: Spektrální pásma Landsat 5

4.3 Použitá data a použitý software

Použil jsem multispektrální snímek z družice Landsat 5 pořízený 23. května 2001, tedy časově odpovídající vzniku dat o ptácích. Tento snímek jsem stáhl z portálu Earth Explorer (©2024) pro území definované path: 191 a row: 025 (Obrázek 2). Jednalo se o Collection 2, Tier 1, tedy nově zpracovaná data s vyšší kvalitou a přesností, a o Level-2 Surface Reflectance, který již přímo obsahuje hodnoty odrazivosti zemského povrchu bez další nutnosti provádět radiometrickou a atmosférickou korekci.



Obrázek 2: Satelitní snímek Landsat 5 z 23.5.2001 a jeho umístění

Informace o výskytu druhů jsem čerpal z poskytnuté bodové vrstvy a tabulky, které vznikly v rámci sčítání ptáků pro disertační práci Analýza vlivu krajinných atributů na ptačí společenstva s využitím vybraných geodat (Šímová 2005). Obsahovaly celkem 1141 bodů (Obrázek 1), na kterých byly zaznamenány přítomné druhy a jejich počet jednotlivců. Celkově se jednalo o 27476 ptáků náležejících k 99 druhům. Jednoznačně nejpočetnějším druhem byla pěnkava obecná, následovali ji pěnice černohlavá, skřivan polní či strnad obecný. Vyskytovaly se však také druhy vzácné a vázané na biotopy cenné z hlediska ochrany přírody, např. hýl rudý, skřivan luční nebo žluva hajní. Diverzita a ornitologická hodnota byly v otevřené krajině vyšší než v lesích (Šímová 2005).

Při dalším postupu jsem využil software ArcGIS Pro 3.1.0 (ESRI ©2024), SNAP 9.0.0 (ESA ©2024), Excel (Microsoft ©2024) a RStudio (Posit ©2024).

4.4 Určení vysvětovaných proměnných

4.4.1 Ornitologická hodnota

Všechny druhy jsem dle poskytnuté disertační práce (Šímová 2005) zapsal do softwaru Excel. Každému z nich jsem spočetl ornitologickou hodnotu podle vzorce uvedeném v Atlasu hnězdního rozšíření ptáků v České republice: 2014-2017 (Šťastný et al. 2021): $K = 1 - p / 100$; kde p = procento obsazenosti kvadrátu příslušným druhem v ČR.

Po tomto výpočtu se hodnoty pro nejhojnější druhy blíží 0, pro nejvzácnější naopak 1. Zároveň bylo nutné z dalšího postupu vyřadit záznamy o výskytu čečetky zimní, jelikož o tomto druhu nebyly v Atlase hnězdního rozšíření ptáků v České republice: 2014-2017 (Šťastný et al. 2021) potřebné informace k určení ornitologické hodnoty. Ornitologickou hodnotu každého zaznamenaného druhu uvádí Příloha této práce. Nejvzácnějšími druhy v zájmovém území byli kormorán velký a hýl rudý.

Tabulku s ornitologickými hodnotami jsem následně v softwaru ArcGIS Pro pomocí funkce Join přiřadil k bodové vrstvě ptáků. Prostřednictvím nástroje Summary Statistics jsem do nové tabulky spočetl ornitologickou hodnotu každého bodu z hodnot přítomných druhů, pro porovnání jako součet i jako průměr. Spolu s tím se spočetl také

počet druhů na každém bodu. Na dvou bodech se nevyskytoval žádný druh, což bylo nutné do tabulky poznamenat ručně (ornitologická hodnota vyšla automaticky 0, počet druhů ale software uvažoval jako počet záznamů, tedy 1, bylo nutné editovat na 0).

4.4.2 Druhová diverzita

Poskytnutá tabulka s informacemi o výskytu druhů obsahovala pro každý bod více záznamů (pro každý druh zvlášť). Proto jsem ji přetransformoval do přijatelnější podoby k následujícímu výpočtu Shannonova indexu diverzity. Konkrétně jsem vytvořil pro každý druh sloupec obsahující počet jedinců na každém bodě. Toho jsem docílil pomocí nástroje Pivot Table v softwaru ArcGIS Pro.

Shannonův index diverzity se obecně počítá dle vzorce:

$$H' = -\sum p_i \ln p_i;$$

kde $p_i = n_i / N$;

n_i = početnost i-tého druhu; N = celkový počet jedinců (Boháč 2013).

Spočetl jsem jej pro svá data pomocí skriptu v jazyku Python (Obrázek 3), který vytvořil nový sloupec s hodnotou indexu pro každý bod a odstranil dále nepotřebné sloupce.

```
import arcpy
import math
arcpy.env.workspace = r"C:\pivot"
data = "pivot.dbf"

arcpy.AddField_management(data, "Shannon", "DOUBLE")

delete = [field.name for field in arcpy.ListFields(data) if field.name not in ["OID",
                                                                           "KOD_BODU",
                                                                           "Shannon"]]

with arcpy.da.UpdateCursor(data, ["OID", "KOD_BODU", "Shannon"] + delete) as cursor:
    for row in cursor:
        druhy = row[2:]

        jednotlivci = sum(druhy)
        pomer = [pocet / jednotlivci if jednotlivci > 0 else 0 for pocet in druhy]

        shannon = -sum(p * math.log(p) if p > 0 else 0 for p in pomer)

        row[2] = shannon
        cursor.updateRow(row)

arcpy.DeleteField_management(data, delete)
```

Obrázek 3: Python skript – výpočet Shannonova indexu

Vysvětlované proměnné jsem vizualizoval prostřednictvím mapových výstupů, které jsou uvedeny v kapitole Výsledky.

4.5 Určení vysvětlujících proměnných – prediktorů

Satelitní snímek jsem otevřel v softwaru SNAP a oříznul funkci Subset pro zájmovou oblast. Pomocí funkce Band Maths jsem spočetl spektrální indexy EVI, NDVI, SAVI a NDMI následovně:

$$\begin{aligned}evi &= 2.5 * ((sr_b4 - sr_b3) / (sr_b4 + 6 * sr_b3 - 7.5 * sr_b1 + 1)), \\ndvi &= (sr_b4 - sr_b3) / (sr_b4 + sr_b3), \\savi &= ((sr_b4 - sr_b3) / (sr_b4 + sr_b3 + 0.5)) * (1.5), \\ndmi &= (sr_b4 - sr_b5) / (sr_b4 + sr_b5),\end{aligned}$$

kde $sr_b(1,3,4,5)$ označuje jednotlivá spektrální pásma.

Tyto prediktory odvozené ze satelitního snímku jsem ještě doplnil daty o nadmořské výšce. Ta jsem získal prostřednictvím vrstvy vrstevnice stažené z Geoportálu Českého úřadu zeměměřického a katastrálního (ČÚZK ©2020). Funkcí Topo to Raster v ArcGIS Pro jsem z nich vytvořil rastr digitálního modelu terénu.

Poskytnutá bodová vrstva ptáků neměla definovaný souřadnicový systém a také obsahovala nadbytečné body pro následující kroky (bod zvlášť pro každý přítomný druh na identických souřadnicích). Prostřednictvím nástroje Define Projection jsem vrstvě přidal souřadnicový systém S-JTSK Krovak East North. Použitím nástroje Dissolve jsem poté body redukoval, aby na každé lokalitě zůstal jen jeden.

Nástrojem Buffer jsem následně vytvořil obalovou zónu kolem každého bodu o poloměru 150 m. Pro každou tuto zónu jsem pomocí nástroje Zonal Statistics as Table spočetl medián a směrodatnou odchylku z rastrů každého spektrálního pásma a indexu. Vynechal jsem pouze šesté spektrální pásmo – termální, které bylo nasnímáno v nižším prostorovém rozlišení 120 m. Stejným způsobem jsem spočetl též průměr nadmořské výšky.

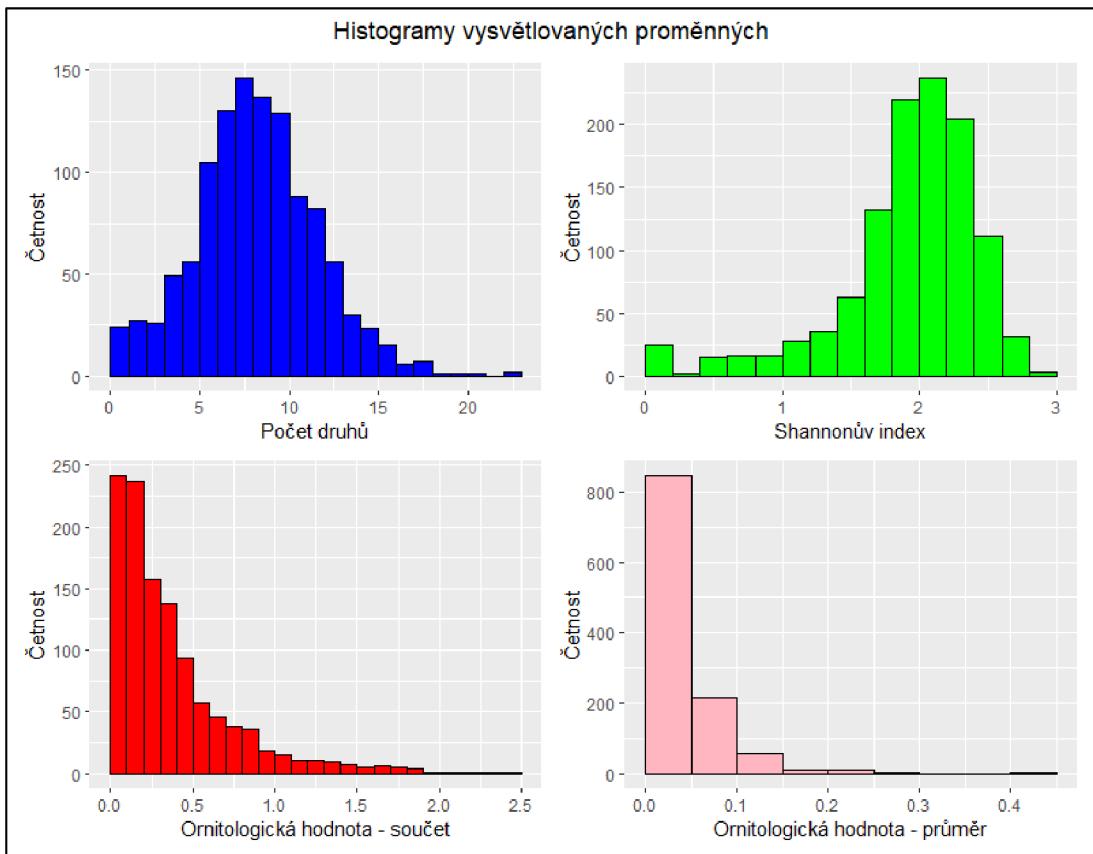
Do atributové tabulky vrstvy ptáků jsem pomocí funkce Join připojil hodnoty z tabulek ornitologické hodnoty (s počtem druhů), Shannonova indexu i všech vypočtených rastrů. Vytvořil jsem nové sloupce, do kterých jsem tyto hodnoty pomocí funkce Calculate Field přepsal. Tabulku jsem nakonec vyexportoval jako csv soubor (tab.csv) k další práci.

4.6 Analýza vysvětlovaných proměnných a prediktorů

Výsledný csv soubor obsahující kód každého bodu a pro něj hodnoty vysvětlovaných i vysvětlujících proměnných jsem otevřel v softwaru RStudio. Nejprve jsem zjišťoval rozdělení či distribuci pravděpodobnosti všech čtyř vysvětlovaných proměnných. Prvním krokem bylo zobrazení histogramů pomocí funkce ggplot, geom_histogram a labs z balíčku ggplot2 (Obrázek 4), které znázornily četnost proměnných v daných intervalech (Obrázek 5).

```
hist_druhy <- ggplot(tab, aes(x = druhy)) +  
  geom_histogram(binwidth = 1, fill = "blue", color = "black", boundary = 0) +  
  labs(x = "Počet druhů", y = "Četnost")
```

Obrázek 4: R skript – vytvoření histogramu pro počet druhů



Obrázek 5: Histogramy vysvětlovaných proměnných

Rozdělení pravděpodobnosti jsem poté testoval. Nejdříve jsem provedl Shapirův-Wilkův test normality pomocí funkce shapiro.test. Nulová hypotéza tohoto testu předpokládá normální rozdělení. Výsledkem je hodnota W. Čím je tato hodnota vyšší (blížící se 1), tím je rozdělení zkoumané proměnné blíže normálnímu rozdělení.

Dále test spočte p-hodnotu, která udává, jak pravděpodobné je, že by dosažený výsledek mohl vzniknout náhodou. Pokud je tato hodnota nižší než stanovená hladina významnosti (nejčastěji 0,05), nulová hypotéza se zamítá. Test jsem provedl pro všechny čtyři vysvětlované proměnné. Nulovou hypotézu jsem pokaždé zamítl.

Dále jsem použil Kolmogorovův-Smirnovův test v podobě funkce ks.test (Obrázek 6). Nulová hypotéza tohoto testu předpokládá zadané rozdělení pravděpodobnosti. Výsledkem je hodnota D. Čím vyššího čísla nabývá, tím je větší rozdíl mezi zadaným rozdělením a rozdělením zkoumané proměnné. Test opět spočte také p-hodnotu.

Obdobně jsem použil ještě Cramer-von Misesův test, kde je výsledkem hodnota ω^2 , která má podobný význam jako D v předchozím případě, a p-hodnota. K tomuto testu jsem využil funkce cvm.test z balíčku goftest (Obrázek 6).

```
ks.test(tab$druhy, "pnorm", mean = mean(tab$druhy), sd = sd(tab$druhy))
cvm.test(tab$druhy, "pnorm", mean = mean(tab$druhy), sd = sd(tab$druhy))
```

Obrázek 6: R skript – Kolmogorovův-Smirnovův a Cramer-von Misesův test pro počet druhů

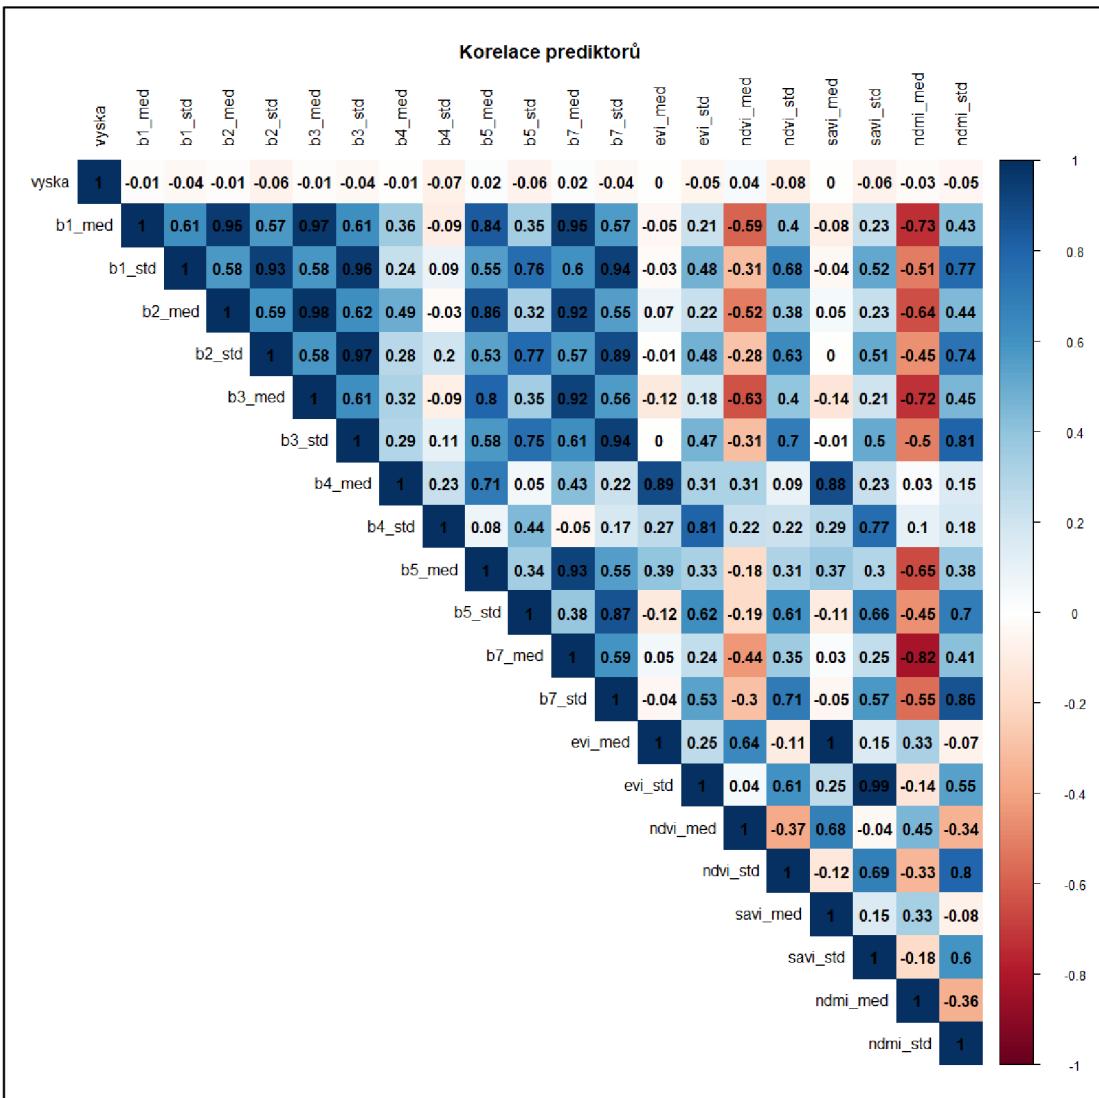
Takto jsem aplikoval Kolmogorovův-Smirnovův test a Cramer-von Misesův test pro všechny čtyři proměnné, přičemž jsem zadával různé typy rozdělení, např. normální, Poissonovo či exponenciální. Dle výsledných hodnot jsem zjistil, jakému rozdělení pravděpodobnosti se rozdělení mých vysvětlovaných proměnných blíží nejvíce, což jsem využil následně při tvorbě modelů.

4.7 Korelace a multikolinearita prediktorů

Korelace definuje vzájemný vztah dvou číselných proměnných. Může být pozitivní i negativní, sílu určuje korelační koeficient nabývající hodnot -1 až 1. V dalším kroku jsem proto posoudil korelací prediktorů prostřednictvím funkcí cor a corrplot z balíčku corrplot (Obrázek 7), které vytvořily korelační matici (Obrázek 8).

```
predictors <- tab[, c("vyska", "b1_med", "b1_std", "b2_med", "b2_std", "b3_med", "b3_std",
                     "b4_med", "b4_std", "b5_med", "b5_std", "b7_med", "b7_std", "evi_med", "evi_std",
                     "ndvi_med", "ndvi_std", "savi_med", "savi_std", "ndmi_med", "ndmi_std")]
cor_matrix <- cor(predictors)
corrplot(cor_matrix, method = "color", addcoef.col = "black", tl.col = "black",
         main = "Korelace prediktorů", mar = c(1, 1, 3, 1), type = "upper")
```

Obrázek 7: R skript – vytvoření korelační matici prediktorů



Obrázek 8: Korelační matici prediktorů

Multikolinearita označuje korelací mezi více proměnnými. Posoudil jsem ji prostřednictvím variačního inflačního faktoru (VIF) pomocí funkce vifcor z balíčku usdm. Samotná funkce některé vysoce korelované proměnné rovnou vyloučila. Dle vypočtených hodnot jsem pak vybral pouze prediktory s nejnižšími hodnotami VIF, které následně vstupovaly do modelů.

Byly jimi medián druhého pásma (b2_med), směrodatná odchylka druhého pásma (b2_std), směrodatná odchylka čtvrtého pásma (b4_std), směrodatná odchylka pátého pásma (b5_std), směrodatná odchylka indexu EVI (evi_std), medián indexu NDVI (ndvi_med), směrodatná odchylka indexu NDVI (ndvi_std), medián indexu NDMI (ndmi_med), směrodatná odchylka indexu NDMI (ndmi_std) a nadmořská výška (vyska).

4.8 Zobecněné lineární modely

Statistické metody sloužící k odhadu náhodné veličiny (vysvětlované proměnné) na základě znalosti jiných veličin (prediktorů) se souhrnně nazývají regresní analýza. Řeší, jakým způsobem jsou na sobě tyto proměnné závislé. Nejjednodušší formou je jednoduchá lineární regrese, která předpokládá lineární závislost mezi proměnnými a využívá jednoduchý lineární model. Zobecněný lineární model je pak rozšířením lineárního modelu s větší tolerancí pro různé distribuční vlastnosti vysvětlovaných proměnných.

K modelování jsem využil právě zobecněný neboli generalizovaný lineární model skrze funkci `glm`. Vytvořil jsem jeden model pro každou vysvětlovanou proměnnou, kterou byly: počet druhů (`druhy`), součet ornitologické hodnoty (`orn_sum`), průměr ornitologické hodnoty (`orn_mean`) a Shannonův index (`shannon`).

Proměnná počet druhů byla v celých číslech, proto jsem v tomto modelu použil Poissonovo rozdělení, které je diskrétní. Pro proměnnou Shannonův index jsem použil normální Gaussovo rozdělení. Ornitologická hodnota, a to vyjádřená oběma způsoby, se nejvíce blížila exponenciálnímu rozdělení. Obě proměnné jsem zlogaritmoval, aby se přiblížily také normálnímu rozdělení. Na některých lokalitách byla ornitologická hodnota rovna nule, tudíž jsem musel před logaritmováním přičíst 0.0000000001, což by na význam výsledků nemělo mít vliv.

Druhou stranu modelů tvořily prediktory vybrané v předchozí podkapitole. R skript pro vytvoření všech čtyř modelů zachycuje Obrázek 9.

```
model_1 <- glm(druhy ~ vyska + b2_med + b2_std + b4_std + b5_std + evi_std +  
ndvi_med + ndvi_std + ndmi_med + ndmi_std, data = tab, family = poisson)  
  
model_2 <- glm(log(orn_sum) ~ vyska + b2_med + b2_std + b4_std + b5_std +  
evi_std + ndvi_med + ndvi_std + ndmi_med + ndmi_std, data = tab, family =  
gaussian)  
  
model_3 <- glm(log(orn_mean) ~ vyska + b2_med + b2_std + b4_std + b5_std +  
evi_std + ndvi_med + ndvi_std + ndmi_med + ndmi_std, data = tab, family =  
gaussian)  
  
model_4 <- glm(shannon ~ vyska + b2_med + b2_std + b4_std + b5_std + evi_std  
+ ndvi_med + ndvi_std + ndmi_med + ndmi_std, data = tab, family = gaussian)
```

Obrázek 9: R skript – vytvoření zobecněných lineárních modelů

Poté jsem modely vylepšil, a to prostřednictvím funkce step, která odstranila některé méně významné prediktory a tím snížila hodnotu AIC.

Akaikoho informační kritérium neboli AIC slouží ke zhodnocení úspěšnosti modelů, posuzuje jejich schopnost vysvětlit variabilitu pozorovaných dat, zohledňuje jak věrohodnost modelu, tak i jeho složitost. Nízké hodnoty AIC naznačují lepší model. Spočet jsem jej pomocí funkce AIC.

Vysvětlující schopnost modelu přibližuje vysvětlená odchylka neboli deviance. Její vyšší hodnoty indikují lepší model. Počítal jsem ji z nulové deviance (měří celkovou variabilitu vysvětlované proměnné) a reziduální deviance (měří modelem nevysvětlenou variabilitu vysvětlované proměnné) za využití funkce deviance (Obrázek 10).

```
residual_deviance_1 <- deviance(model_1)
explained_deviance_1 <- 1 - (residual_deviance_1 / model_1$null.deviance)
print(explained_deviance_1)
```

Obrázek 10: R skript – výpočet vysvětlené odchylky

Výsledné grafy zobrazující závislost vysvětlovaných a vysvětlujících proměnných jsem vytvořil pomocí funkce visreg z balíčku visreg. V grafech ornitologické hodnoty jsem musel osu y přetransformovat zpátky na exponenciální rozdělení, což zajistil argument trans = exp. Příklad R skriptu k vytvoření jednoho z grafů ukazuje Obrázek 11.

```
visreg(model_2, "b2_med", xlab = "B2_med", ylab = "Ornitologická hodnota - součet",
       trans = exp, line = list(col = "red"))
```

Obrázek 11: R skript – vytvoření grafu závislosti ornitologické hodnoty na mediánu druhého spektrálního pásma

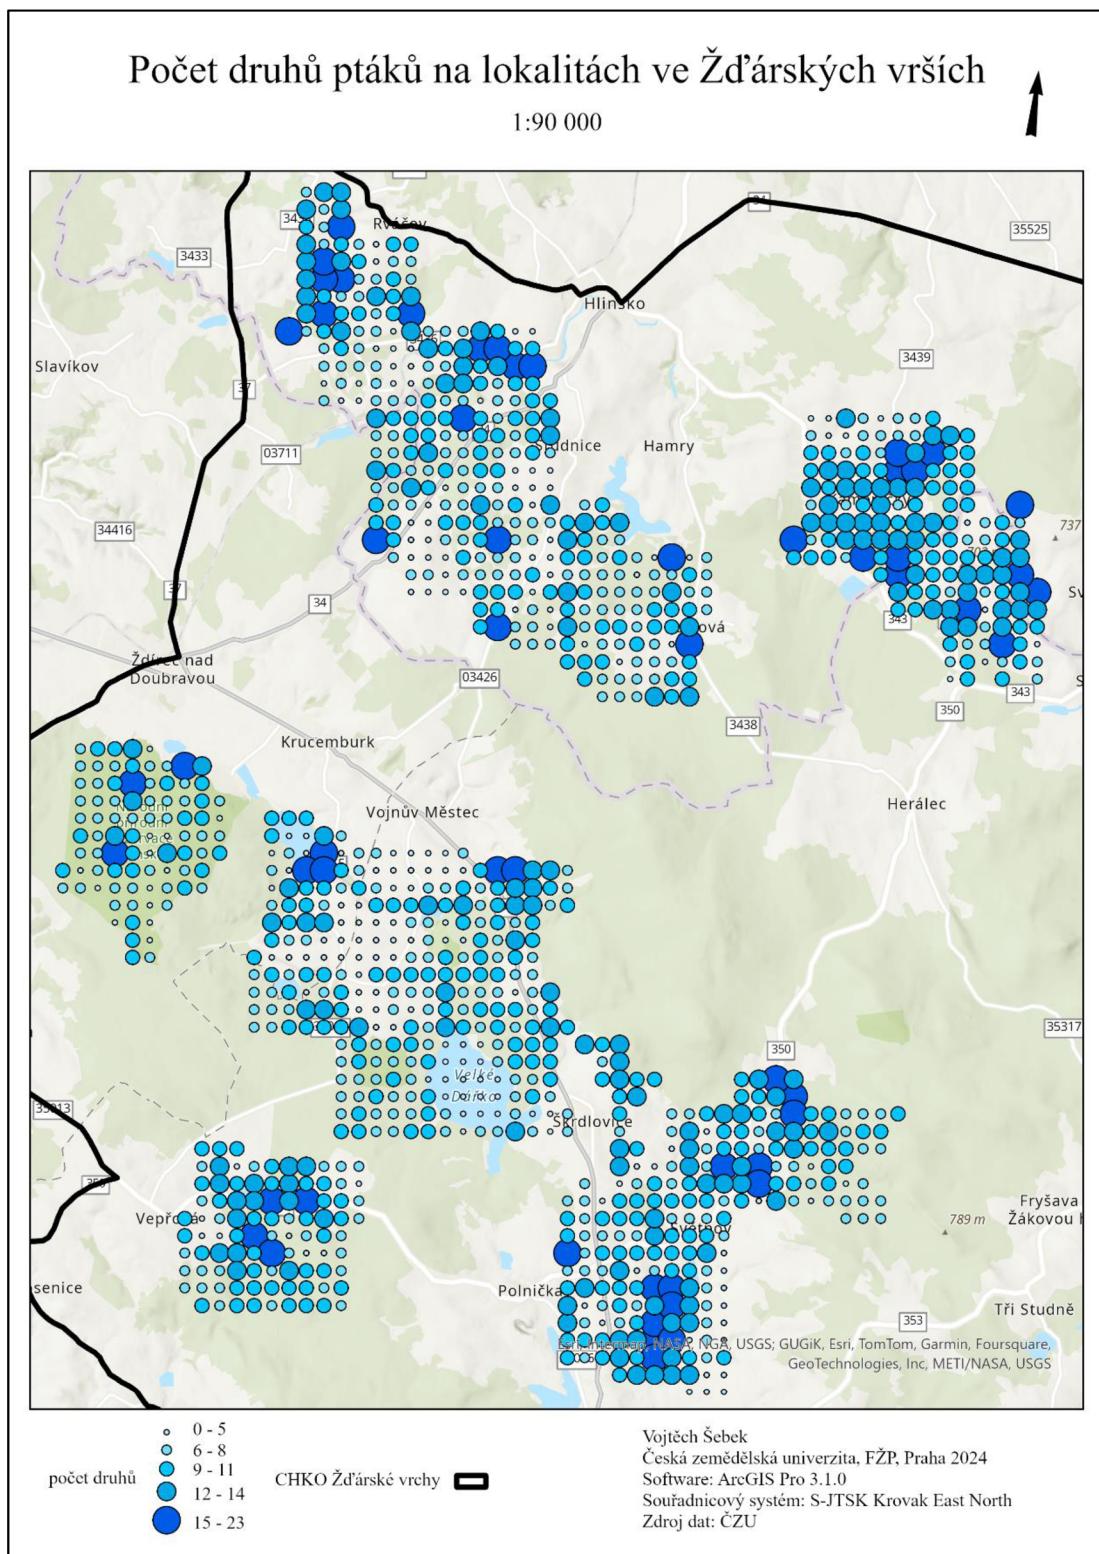
Na závěr jsem udělal diagnostiku modelů zobrazením grafů reziduí (Obrázek 12). Rezidua lze obecně definovat jako rozdíly mezi pozorovanou a predikovanou hodnotou modelované proměnné. Velké hodnoty reziduí (odlehlé hodnoty) či jejich jakékoliv systematické chování naznačují špatný model.

```
plot(model_1, which = 1)
```

Obrázek 12: R skript – zobrazení grafu reziduí

5. Výsledky

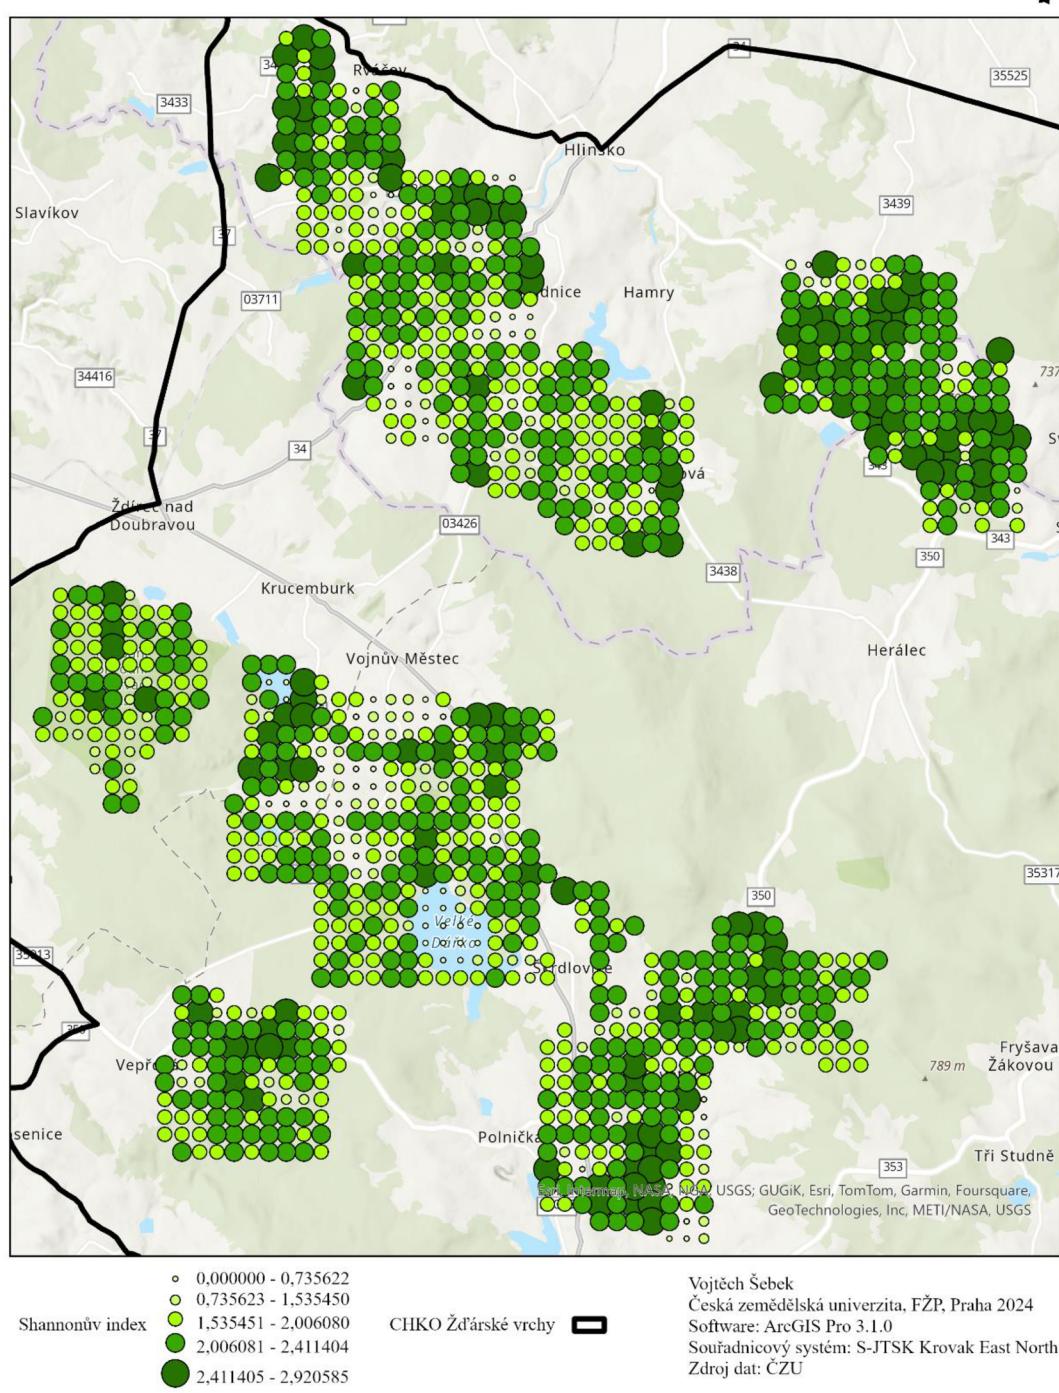
Obrázky 13-15 uvádějí mapy diverzity a ornitologické hodnoty ve Žďárských vrších.



Obrázek 13: Mapa počtu druhů na lokalitách ve Žďárských vrších

Shannonův index diverzity na lokalitách ve Žďárských vrších

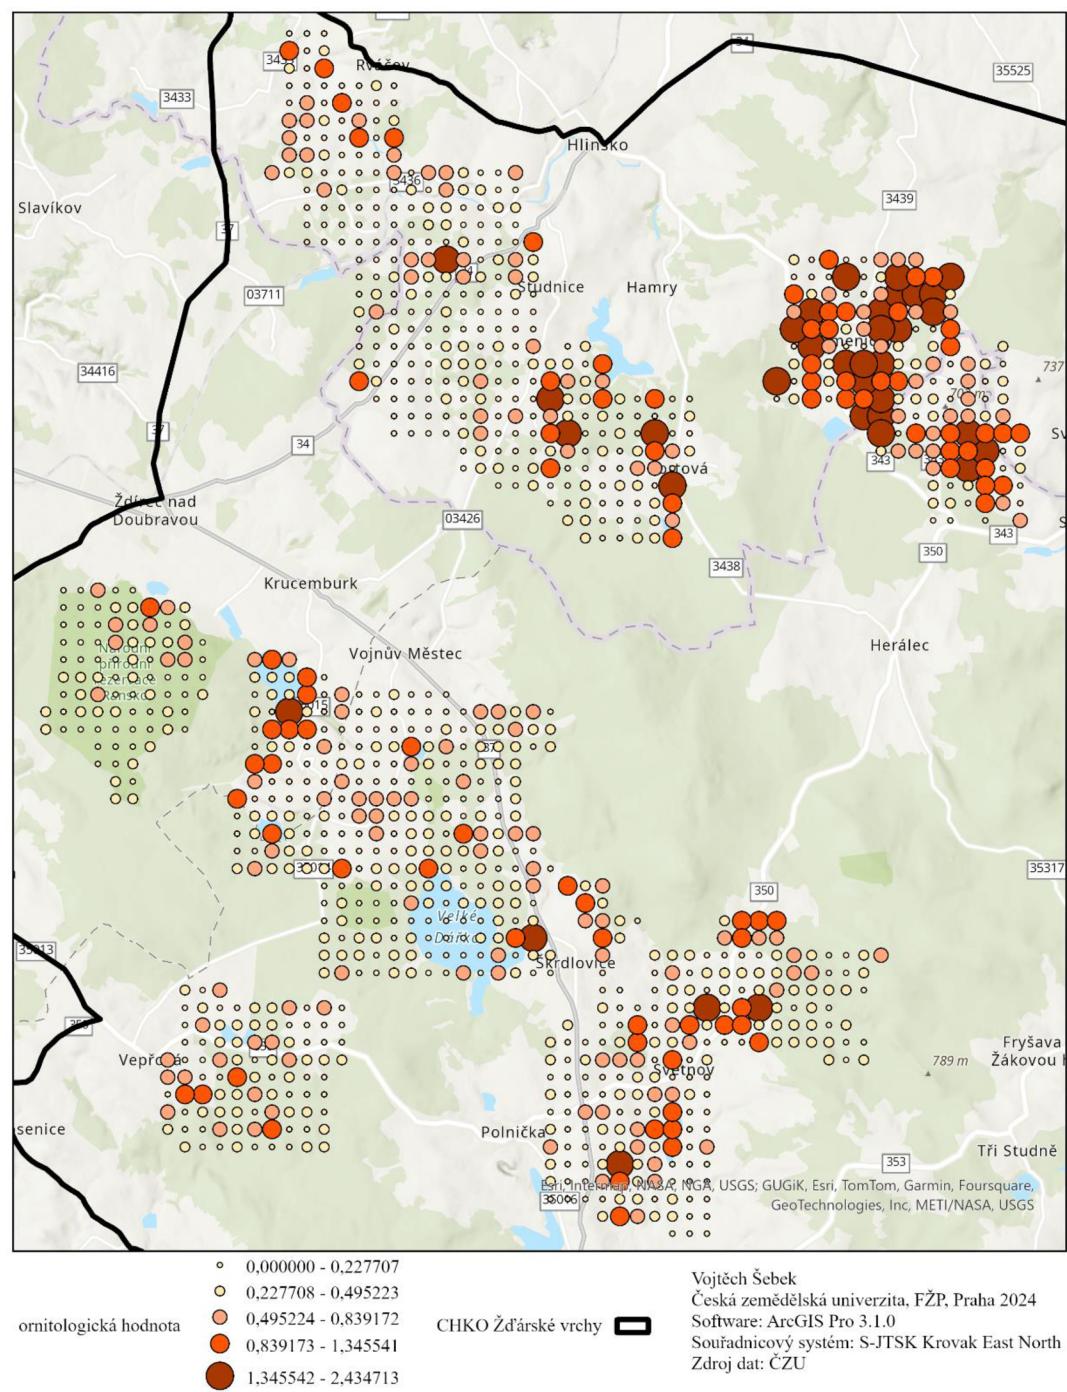
1:90 000



Obrázek 14: Mapa Shannonova indexu diverzity na lokalitách ve Žďárských vrších

Ornitologická hodnota lokalit ve Žďárských vrších

1:90 000



Obrázek 15: Mapa ornitologické hodnoty lokalit ve Žďárských vrších

Výsledné hodnoty každého ze čtyř modelů uvádí níže Obrázek 16-19. První sloupec (Estimate) značí výslednou závislost, konkrétně jako změnu vysvětlované proměnné při zvýšení hodnoty prediktoru. Druhý sloupec (Standard Error) popisuje variabilitu prvního sloupce. Jejich podílem vznikne z-hodnota třetího sloupce, na které závisí ve čtvrtém sloupci p-hodnota. Ta popisuje schopnost prediktorů predikovat hodnoty vysvětlované proměnné. Hvězdičky poté označují hladinu významnosti. Lze tedy vidět, jak je daný prediktor statisticky významný.

```

Call:
glm(formula = druh ~ b2_med + b2_std + b4_std + b5_std + evi_std +
    ndvi_med + ndvi_std + ndmi_med + ndmi_std, family = poisson,
    data = tab)

Coefficients:
            Estimate Std. Error z value Pr(>|z|)
(Intercept) 2.310e+00 2.230e-01 10.363 < 2e-16 ***
b2_med      -7.148e-05 1.845e-05 -3.875 0.000107 ***
b2_std      -8.042e-05 5.260e-05 -1.529 0.126246
b4_std       1.732e-04 2.156e-05  8.031 9.71e-16 ***
b5_std      -1.076e-04 3.165e-05 -3.401 0.000672 ***
evi_std     -1.748e+00 5.594e-01 -3.125 0.001781 **
ndvi_med    1.156e+00 1.150e-01 10.048 < 2e-16 ***
ndvi_std    1.141e+00 2.644e-01  4.315 1.59e-05 ***
ndmi_med   -1.542e+00 1.576e-01 -9.787 < 2e-16 ***
ndmi_std    1.074e+00 4.256e-01  2.523 0.011646 *
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)

Null deviance: 1690.4 on 1140 degrees of freedom
Residual deviance: 1308.7 on 1131 degrees of freedom
AIC: 5793.1

Number of Fisher Scoring iterations: 5

```

Obrázek 16: Výsledek modelu pro počet druhů

```

Call:
glm(formula = log(orn_sum_1) ~ vyska + b2_med + b2_std + b4_std +
    evi_std + ndvi_med + ndvi_std + ndmi_med, family = gaussian,
    data = tab)

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -4.171e+00 1.116e+00 -3.737 0.000195 ***
vyska        3.583e-03 1.230e-03  2.914 0.003636 **
b2_med      -9.829e-05 6.827e-05 -1.440 0.150238
b2_std      -7.280e-04 1.642e-04 -4.433 1.02e-05 ***
b4_std       3.467e-04 8.506e-05  4.076 4.90e-05 ***
evi_std     -5.525e+00 2.374e+00 -2.327 0.020132 *
ndvi_med    2.744e+00 3.465e-01  7.919 5.70e-15 ***
ndvi_std    5.808e+00 1.123e+00  5.172 2.74e-07 ***
ndmi_med   -2.777e+00 5.141e-01 -5.402 8.04e-08 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for gaussian family taken to be 2.357436)

Null deviance: 3050.0 on 1140 degrees of freedom
Residual deviance: 2668.6 on 1132 degrees of freedom
AIC: 4227.5

Number of Fisher Scoring iterations: 2

```

Obrázek 17: Výsledek modelu pro ornitologickou hodnotu – součet

```

Call:
glm(formula = log(orn_mean_1) ~ vyska + b2_std + b4_std + evi_std +
    ndvi_med + ndvi_std + ndmi_med, family = gaussian, data = tab)

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) -6.399e+00 7.192e-01 -8.898 < 2e-16 ***
vyska       3.400e-03 1.086e-03  3.131 0.00179 **
b2_std      -5.664e-04 1.326e-04 -4.273 2.09e-05 ***
b4_std      1.609e-04 7.449e-05  2.160 0.03101 *
evi_std     -3.506e+00 2.069e+00 -1.694 0.09049 .
ndvi_med   1.400e+00 2.854e-01  4.904 1.08e-06 .
ndvi_std   4.138e+00 9.730e-01  4.253 2.28e-05 ***
ndmi_med   -1.102e+00 4.169e-01 -2.642 0.00835 **
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

(Dispersion parameter for gaussian family taken to be 1.83963)

Null deviance: 2195.0 on 1140 degrees of freedom
Residual deviance: 2084.3 on 1133 degrees of freedom
AIC: 3943.5

Number of Fisher Scoring iterations: 2

```

Obrázek 18: Výsledek modelu pro ornitologickou hodnotu – průměr

```

Call:
glm(formula = shannon ~ b2_med + b4_std + b5_std + evi_std +
    ndvi_med + ndvi_std + ndmi_med + ndmi_std, family = gaussian,
    data = tab)

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 2.656e+00 2.202e-01 12.060 < 2e-16 ***
b2_med     -1.337e-04 1.783e-05 -7.502 1.27e-13 ***
b4_std      2.448e-04 2.550e-05  9.603 < 2e-16 ***
b5_std     -1.623e-04 3.116e-05 -5.210 2.25e-07 ***
evi_std    -2.561e+00 6.765e-01 -3.786 0.000161 ***
ndvi_med   1.260e+00 9.559e-02 13.176 < 2e-16 ***
ndvi_std   1.525e+00 3.390e-01  4.499 7.54e-06 ***
ndmi_med   -1.883e+00 1.610e-01 -11.694 < 2e-16 ***
ndmi_std   9.348e-01 5.324e-01  1.756 0.079422 .
---
Signif. codes:  0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

(Dispersion parameter for gaussian family taken to be 0.1826553)

Null deviance: 311.07 on 1140 degrees of freedom
Residual deviance: 206.77 on 1132 degrees of freedom
AIC: 1309.1

Number of Fisher Scoring iterations: 2

```

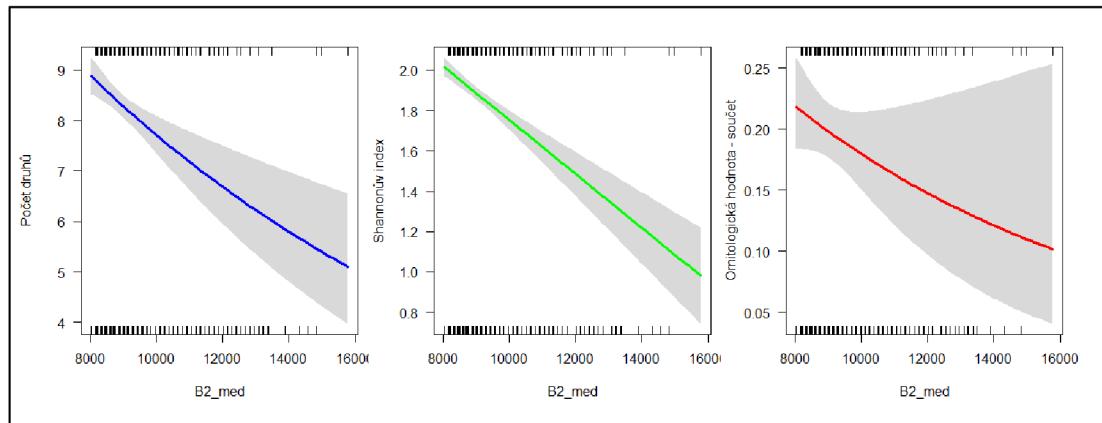
Obrázek 19: Výsledek modelu pro Shannonův index

Nejvyšší hodnota vysvětlené odchylky vyšla pro modely proměnných Shannonův index a počet druhů. Nejnižší hodnoty AIC dosáhl takéž Shannonův index. Výrazně větší vysvětlené odchylky, a tedy lepšího výsledku, dosáhl model ornitologické hodnoty vyjádřené součtem než průměrem (Tabulka 2). Z tohoto důvodu je v dalším textu uvedena jen tato proměnná, přestože měla nižší, tedy lepší, hodnoty AIC.

	AIC	Vysvětlená odchylka
Počet druhů	5793,07	22,58%
Ornitologická hodnota - součet	4227,48	12,50%
Ornitologická hodnota - průměr	3943,50	5,05%
Shannonův index	1309,11	33,53%

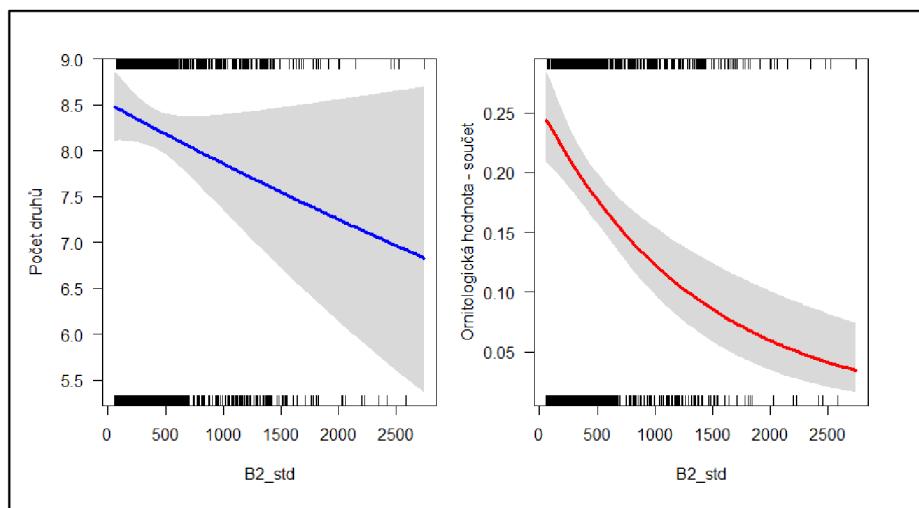
Tabulka 2: Akaikeho informační kritérium a vysvětlená odchylka modelů

První tři spektrální pásma měla vysokou míru korelace, do modelu bylo zahrnuto jen jedno z nich – zelené. Jak lze vyčíst z Grafu 1, diverzita, vyjádřená jako počet druhů a Shannonův index, i ornitologická hodnota klesaly s vyššími hodnotami mediánu odrazivosti tohoto pásma. Ornitologická hodnota však byla statisticky méně významná.



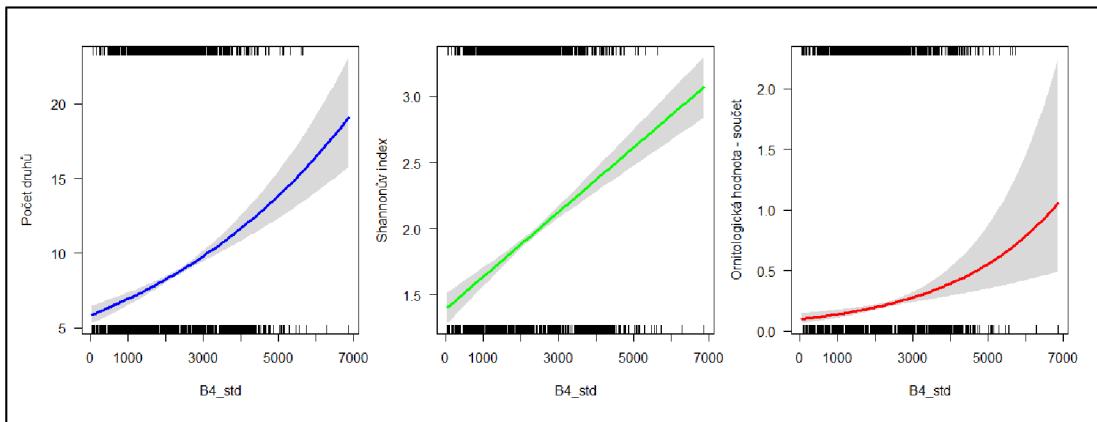
Graf 1: Závislost diverzity a ornitologické hodnoty na mediánu zeleného spektrálního pásma

Směrodatná odchylka zeleného pásma byla významným prediktorem pouze pro ornitologickou hodnotu, méně pak pro počet druhů. Vyšší směrodatná odchylka znamenala pokles obou proměnných (Graf 2). Hypotéza spektrální variability se tu nepotvrdila.



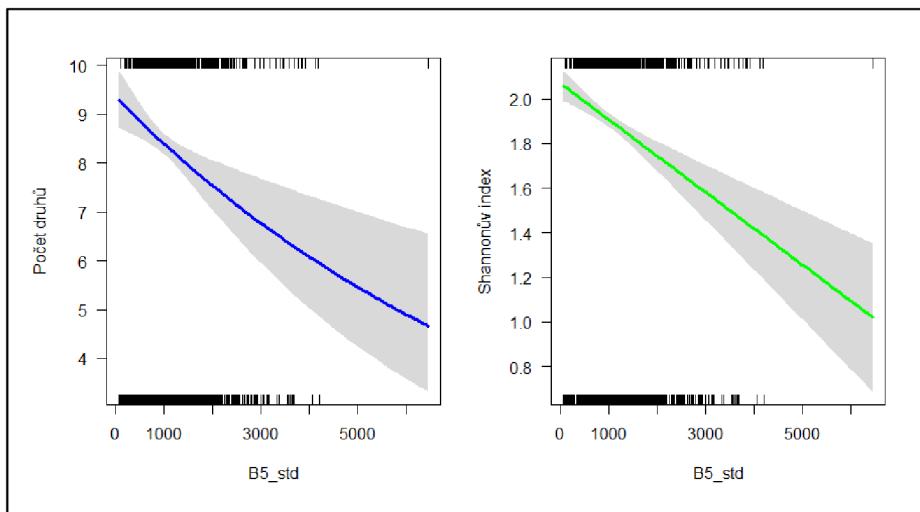
Graf 2: Závislost diverzity a ornitologické hodnoty na směrodatné odchylce zeleného spektrálního pásma

Směrodatná odchylka blízkého infračerveného pásma indikovala heterogenní prostředí s různorodou vegetací. S jejím zvýšením se zvyšoval počet druhů, Shannonův index i ornitologická hodnota (Graf 3). Hypotéza spektrální variability byla tudíž tímto prediktorem potvrzena.



Graf 3: Závislost diverzity a ornitologické hodnoty na směrodatné odchylce blízkého infračerveného pásma

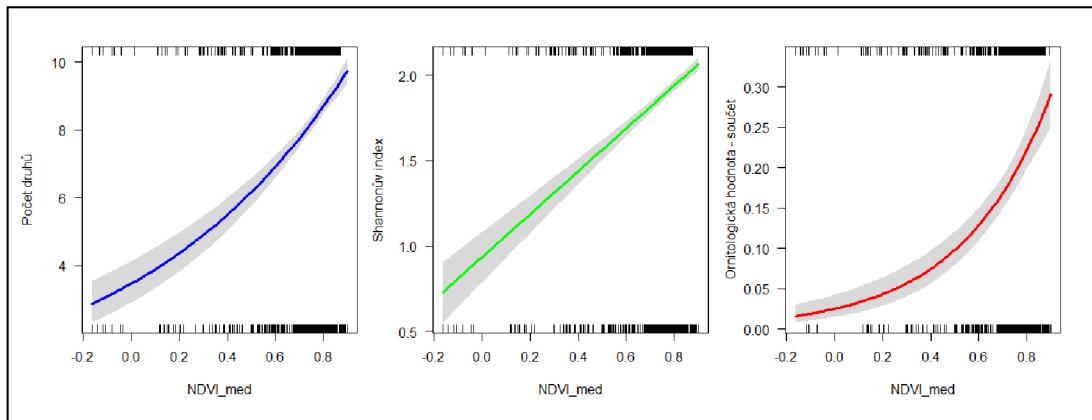
Vyšší směrodatná odchylka krátkovlnného infračerveného pásma naznačovala pokles počtu druhů i Shannonova indexu (Graf 4). Hypotéza spektrální variability se zde tedy nepotvrdila. Pro ornitologickou hodnotu nebyl tento prediktor statisticky významný.



Graf 4: Závislost diverzity na směrodatné odchylce krátkovlnného infračerveného pásma

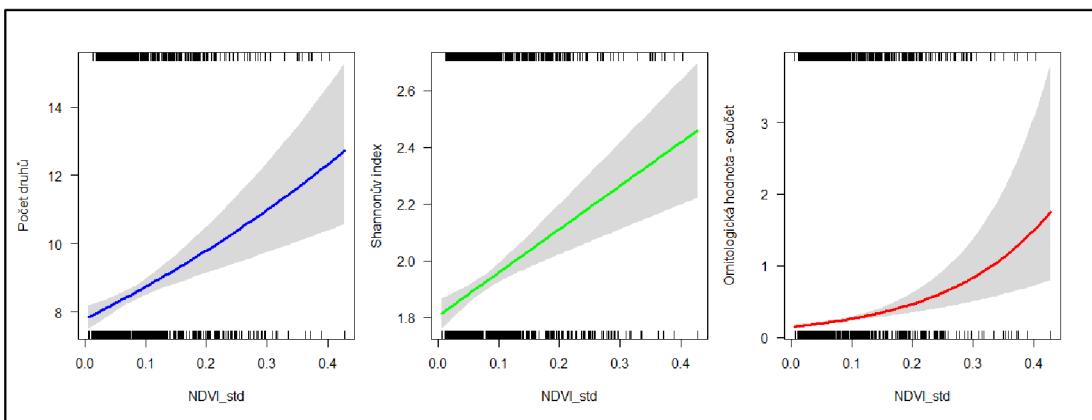
Dalšími prediktory byly spektrální indexy. Z důvodu vysoké korelace byl z modelů zcela vynechán index SAVI.

Prvním indexem byl NDVI. Se zvyšujícím se mediánem docházelo ke zvýšení počtu druhů, Shannonova indexu i ornitologické hodnoty (Graf 5). Oblasti s hustší, zdravější a zelenější vegetací tedy znamenaly vyšší diverzitu ptáků i větší pravděpodobnost výskytu vzácného druhu.



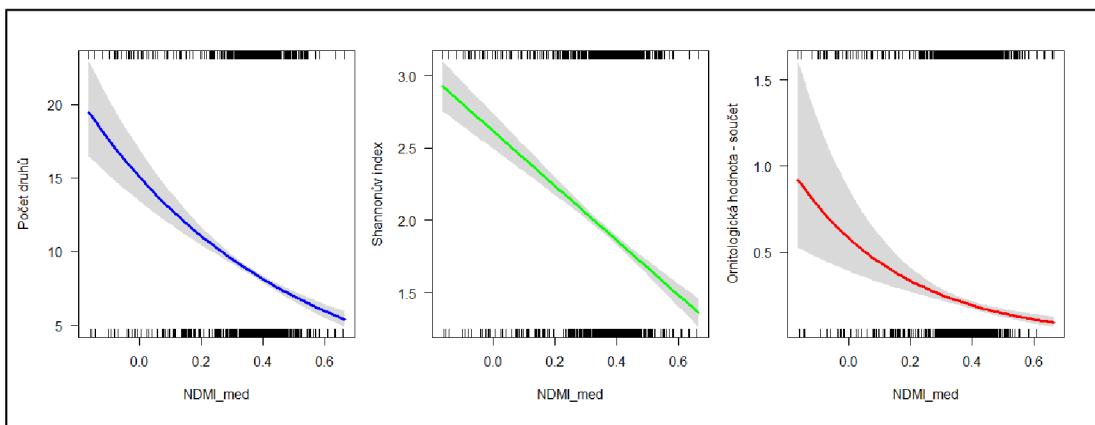
Graf 5: Závislost diverzity a ornitologické hodnoty na mediánu NDVI

Směrodatná odchylka NDVI charakterizuje heterogenitu prostředí. Čím vyšších hodnot nabývá, tím více se střídají plochy pokryté vegetací s holou půdou nebo zamokřenými oblastmi. A s vyšší hodnotou směrodatné odchylky docházelo ke zvýšení počtu druhů a Shannonova indexu. Tento prediktor tudíž potvrdil hypotézu spektrální variability. Ornitológická hodnota také rostla (Graf 6).



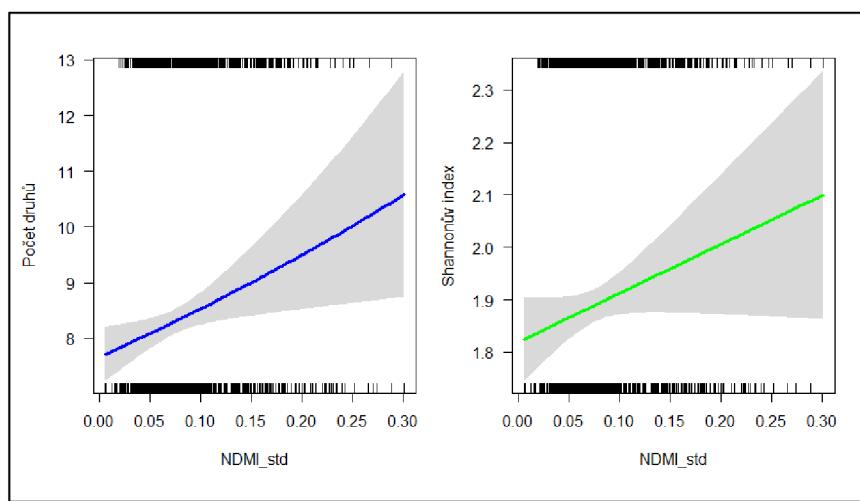
Graf 6: Závislost diverzity a ornitologické hodnoty na směrodatné odchylce NDVI

Index NDMI charakterizuje vlhkost prostředí či obsah vody ve vegetaci. Čím vyšší byl medián tohoto indexu, tím nižší byl počet druhů, Shannonův index a také ornitologická hodnota (Graf 7). Z tohoto vyplývá, že diverzita nebyla nejvyšší v příliš vlhkých prostředích a nevyhledává je ani vzácnější ptactvo.



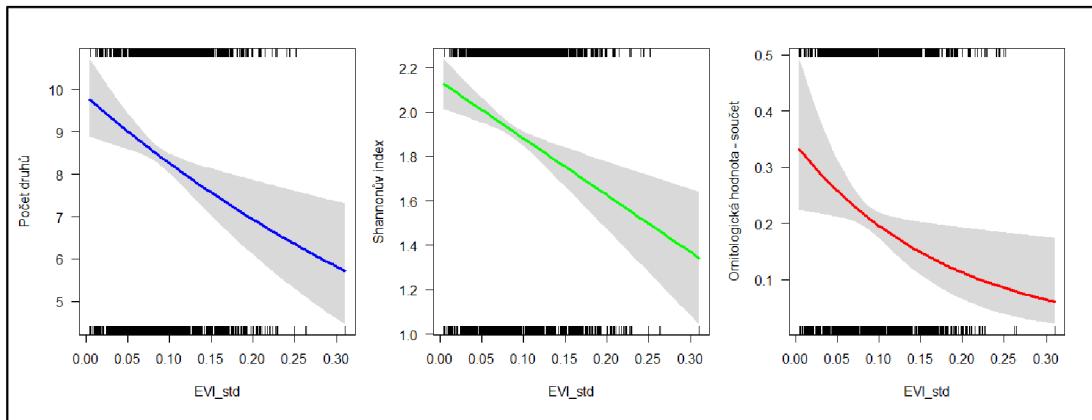
Graf 7: Závislost diverzity a ornitologické hodnoty na mediánu NDMI

Na druhou stranu, směrodatná odchylka NDMI, charakterizující opět heterogenitu prostředí, ukázala důležitost vlhkosti prostředí. Počet druhů a Shannonův index stoupaly s vyšší směrodatnou odchylkou (Graf 8). Čím více se střídaly plochy s různou vlhkostí, tím vyšší byla diverzita. Potvrdila se zde tedy hypotéza spektrální variability. Pro ornitologickou hodnotu nebyl tento prediktor statisticky významný.



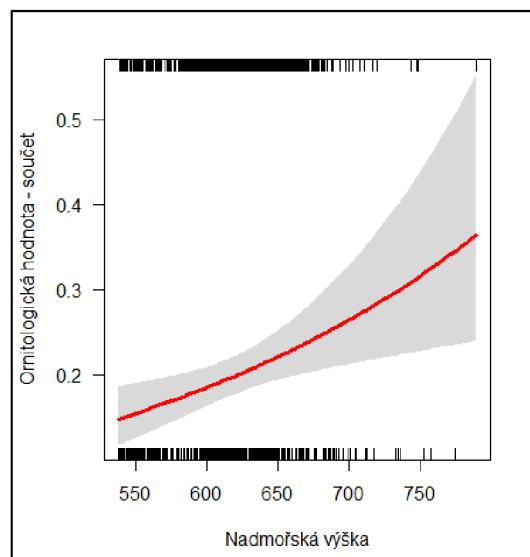
Graf 8: Závislost diverzity na směrodatné odchylce NDMI

Posledním spektrálním indexem, který byl statisticky významný, byl EVI, konkrétně jeho směrodatná odchylka. Předpokladem byla podobnost s NDVI. Model však toto nepotvrdil. Naopak, s vyšší směrodatnou odchylkou EVI docházelo k poklesu jak diverzity, tak ornitologické hodnoty (Graf 9). Zde hypotéza spektrální variability neplatila.



Graf 9: Závislost diverzity a ornitologické hodnoty na směrodatné odchylce EVI

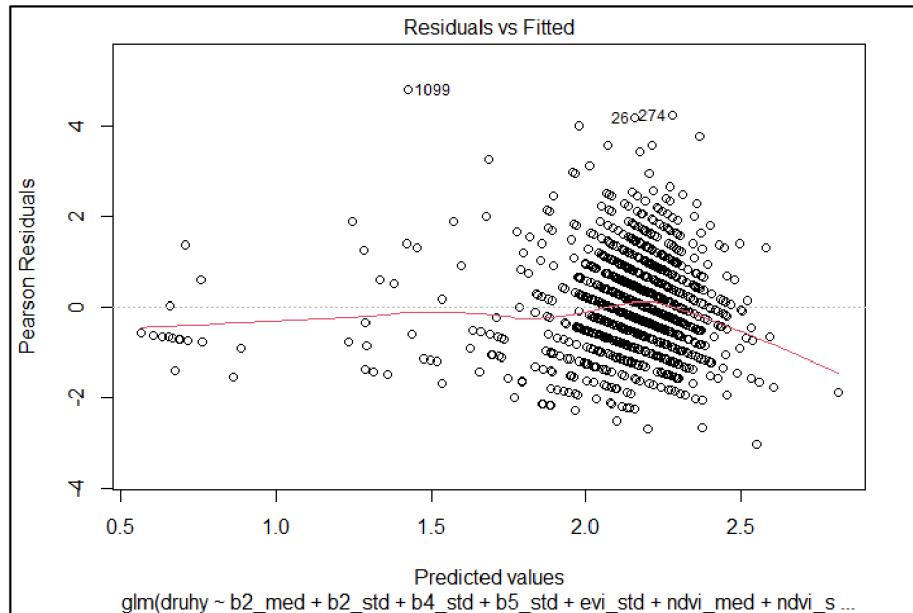
Nadmořská výška byla statisticky významným prediktorem pouze pro ornitologickou hodnotu. Ta se s vyšší nadmořskou výškou zvyšovala (Graf 10). Vzácnější ptáci se ve Žďárských vrších tedy vyskytovali spíše ve vyšších polohách.



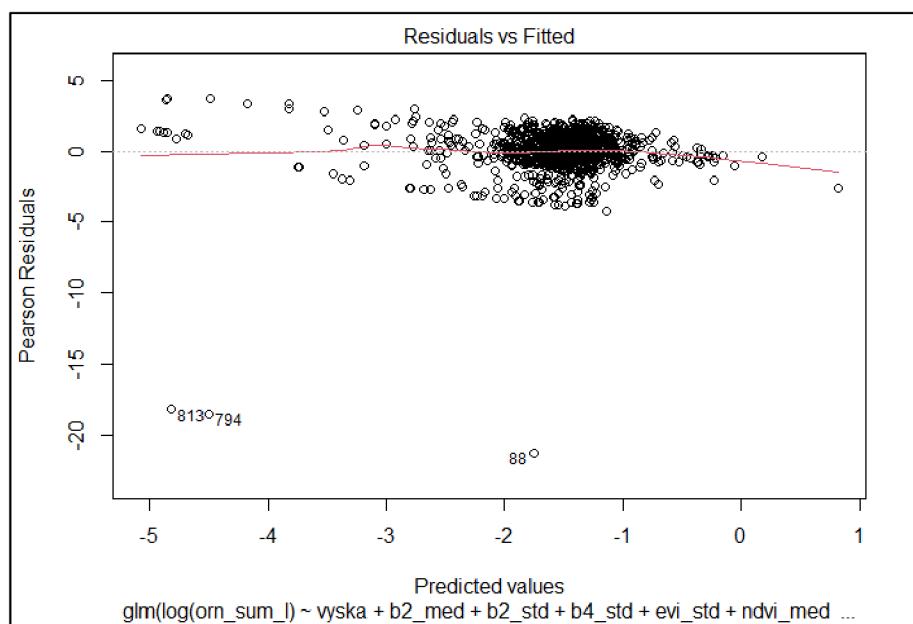
Graf 10: Závislost ornitologické hodnoty na nadmořské výšce

Výsledné koeficienty modelů naznačily, že jednotlivé prediktory mají různě velkou schopnost vysvětlit variabilitu vysvětlovaných proměnných. Nejlepšími prediktory z tohoto pohledu byly: směrodatná odchylka čtvrtého spektrálního pásma, medián i směrodatná odchylka indexu NDVI a také medián indexu NDMI. Dosáhly totiž značné statistické významnosti u všech vysvětlovaných proměnných.

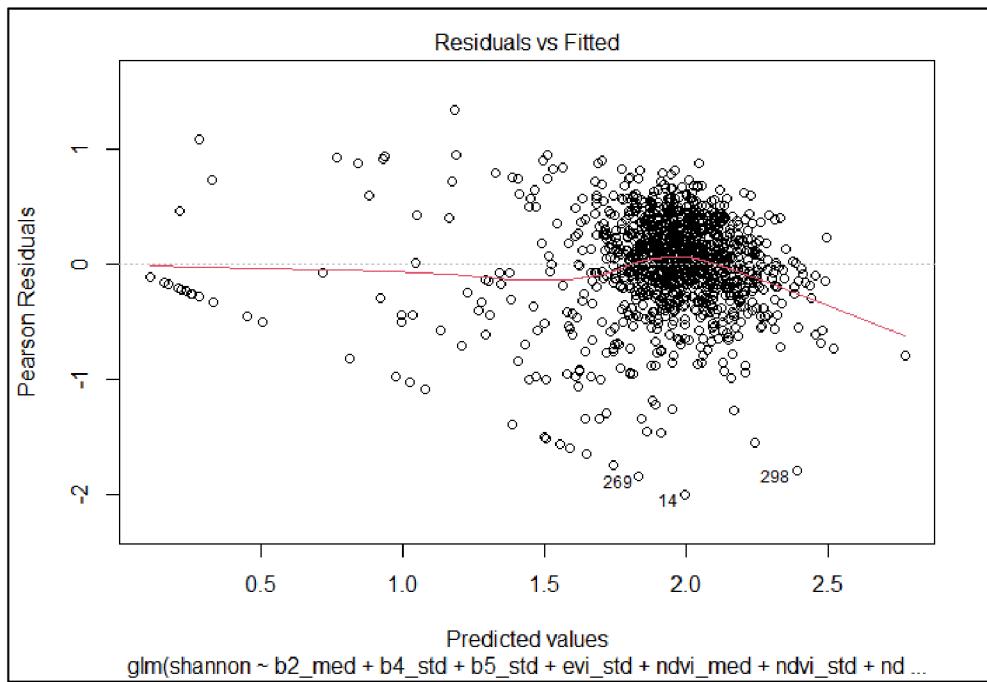
Graf 11-13 zachycuje rezidua pro každý model.



Graf 11: Rezidua modelu pro počet druhů



Graf 12: Rezidua modelu pro ornitologickou hodnotu



Graf 13: Rezidua modelu pro Shannonův index

Grafy rezidiuí nenaznačily žádnou zásadní chybu v modelech. Systematické chování rezidiuí se nevyskytovalo, byla celkem rovnoměrně rozložena kolem nuly, ač u zcela ideálního modelu by se nule blížila více. V datech se vyskytovalo také několik odlehlých hodnot, které mohly modely ovlivnit.

Například bod 1099 (Graf 11) se nacházel na rybníku, takže jeho spektrální charakteristiky byly odlišné. Zároveň se tam vyskytovalo více druhů než na většině jiných bodů, které se nacházely na vodních plochách.

Bod 88 (Graf 12) měl ornitologickou hodnotu rovnu nule. Vyskytovaly se tam pouze dva běžné druhy – pěnkava obecná a sýkora koňadra.

Body 794 a 813 (Graf 12) měly také nulovou ornitologickou hodnotu. Zde se nevyskytovaly vůbec žádné druhy ptáků. Zároveň zde byly i odlišné spektrální charakteristiky, jelikož oba body se opět nacházely na rybníku.

Odlehlé hodnoty tedy znamenaly specifické prostředí z hlediska spektrálního nebo ekologického. Nejednalo se o chybu v datech či výpočtech.

6. Diskuse

Rozmanitost je podstatou zdravého ekosystému. Ovlivňuje produktivitu i odolnost vůči disturbancím. Nezbytnou činností k pochopení biodiverzity je její globální pozorování, jež vede k identifikaci cenných míst z hlediska ochrany přírody. Tradiční monitorování *in situ* je limitováno časem i prostorem, velmi často je též nákladné. Z tohoto důvodu je vhodné využít dálkový průzkum Země, který poskytuje data pro velká území konzistentním a objektivním způsobem (Wang et Gamon 2019). Stále častěji jsou používána k modelování a pochopení druhové diverzity a distribuce v prostoru i čase (St-Louis et al. 2014).

Mnoho výzkumů dokazuje, že environmentální proměnné získané z původních neklasifikovaných satelitních dat se dají použít k tvorbě modelů s vysokou predikční schopností a pro širší časové období, než by bylo možné prostřednictvím klasifikovaných produktů (Shirley et al. 2013). Klasifikovaná data totiž přehlíží vnitřní heterogenitu prostředí a prvky habitatu, které by mohly být pro daný druh ekologicky významné (St-Louis et al. 2014).

Spektrální charakteristiky satelitního snímku a jejich vysvětlující schopnost druhové diverzity ptáků byly analyzovány i v této bakalářské práci. Použita byla jak jednotlivá spektrální pásma, tak i spektrální indexy z nich odvozené. Tyto environmentální proměnné byly získány ze snímku s prostorovým rozlišením (velikostí pixelu) 30 m a spočteny byly pro 150metrové okolí bodů, na kterých byla monitorována ptačí diverzita, tedy cca 7hektarová území.

Výsledky modelů nedosáhly příliš vysoké vysvětlené odchylinky, ale jsou celkem srovnatelné s výsledky jiné studie (Prajlerová et al. 2024) v případě využití jen samotných satelitních dat Landsat. První tři spektrální pásma viditelného záření byla vysoce korelovaná. Použití pouze jednoho z nich je dostatečné, jelikož obsahuje významnou část všech informací. Výhodné by pravděpodobně bylo tato viditelná pásma shrnout pomocí analýzy hlavních komponent (PCA = principal component analysis), což by mohlo schopnost predikce zlepšit (Rocchini et al. 2007).

Ač má zelená vegetace významnou odrazivost v zeleném spektrálním pásmu, ještě vyšší ji mají například budovy, zastavěné plochy apod. Tato prostředí pravděpodobně

nevyhovují velkému počtu druhů ani vzácnějším druhům. V případě směrodatné odchylky zeleného pásma se zřejmě také jednalo o působení antropogenních ploch, např. měst (Prajzlerová et al. 2024), jakožto důvodu poklesu diverzity i ornitologické hodnoty. Hypotéza spektrální variability se v tomto případě nepotvrnila.

Blízké infračervené pásmo reagující na zdraví vegetace a množství biomasy bylo významným prediktorem ptačí diverzity i ornitologické hodnoty. Všechny tři modelované proměnné se zvyšovaly s vyšší heterogenitou prostředí vyjadřenou směrodatnou odchylkou blízkého infračerveného pásma, což bylo v souladu s hypotézou o spektrální variabilitě. Toto spektrální pásmo bylo hojně a úspěšně využíváno i v jiných studiích (Bellis et al. 2008). Rocchini et al. (2007) navrhli právě „blízko-infračervenou cestu“ k posouzení diverzity satelitními daty.

Index NDVI byl také významným prediktorem jako i v mnoha jiných studiích (St-Louis et al. 2014, Ribeiro et al. 2019, Hunt et al. 2022). Vyšší hodnoty mediánu tohoto indexu charakterizují zdravější a hustší vegetaci. V těchto prostředích byla zjištěna vyšší diverzita a vyskytovalo se i více vzácných druhů. Směrodatná odchylka NDVI pak popisuje heterogenitu krajiny, například střídání ploch s různým množstvím vegetace. Čím vyšší byla, tím byla vyšší také diverzita i počet vzácnějších druhů. Hypotéza o spektrální variabilitě se tu tedy potvrdila.

Jiné a překvapivé výsledky ovšem přinesl index EVI. Ten je citlivý spíše na strukturu a vzhled vegetace než na obsah chlorofylu, jako je tomu u NDVI. Při vyšší směrodatné odchylce EVI docházelo k poklesu počtu druhů i ornitologické hodnoty. Otázkou proto je, který z indexů popsal heterogenitu Žďárských vrchů lépe. Hodnoty EVI se vizuálně zdají být více heterogenní. Hypotézu spektrální variability ovšem nepotvrdily. Výsledky zřejmě ovlivnilo velké množství jehličnatých lesů v oblasti, na které oba indexy reagovaly odlišně. Index NDVI obecně není schopen detektovat variaci korun stromů (Huete et al. 2002). Je však pravděpodobně dostačující pro nelesní prostředí, tedy otevřenou krajinu (louky apod.). Indikoval zde totiž zvýšení diverzity i ornitologické hodnoty. A ty jsou právě v otevřené krajině Žďárských vrchů vyšší (Šimová 2005).

Krátkovlnné infračervené pásmo, které je citlivé na vlhkost vegetace či půdy, svou směrodatnou odchylkou neindikovalo zvýšení diverzity ani ornitologické hodnoty. Naproti tomu směrodatná odchylka indexu NDMI přinesla opačný výsledek a hypotézu spektrální variability potvrdila. Příčinou může být opět přítomnost nepřírodních ploch, které index dokáže potlačit. Index také kombinuje krátkovlnné a infračervené spektrální pásmo, v nichž vegetace reaguje různě, což může přidat cenné informace, např. o disturbancích (Hladky et al. 2020), které mohou být klíčové pro vyšší diverzitu či některé vzácnější druhy. Výsledky pro medián NDMI pak ještě ukázaly, že diverzita a ornitologická hodnota klesaly s vyšší vlhkostí prostředí.

Ornitologická hodnota byla úspěšněji vyjádřena pomocí součtu, který lépe vyjadřuje cennost lokality z hlediska ochrany přírody. Tato metoda byla použita i v jiné studii (Šimová 2005). Vyjádření průměrem dosáhlo v modelu velmi nízké vysvětlené odchylky. Průměr totiž může být negativně ovlivněn přítomností mnoha běžných druhů, mezi nimiž se jeden vzácný druh ztratí.

Lokality byly rozmístěny po velké části Žďárských vrchů, nacházely se tedy v různých typech prostředí. Vztah diverzity a spektrální variability se v různých typech krajiny chová odlišně, a hypotéza tak vždy neplatí (Schmidlein et Fassnacht 2017, Perrone et al. 2023, Prajzlerová et al. 2024). Jiné výsledky by zřejmě vzešly při použití dat s vyšším prostorovým rozlišením. Například satelitní systém SPOT poskytuje multispektrální snímky s rozlišením jednotek metrů. Na druhou stranu by rozlišení nemělo být ani příliš vysoké. Poté totiž může nastat situace, kdy se celý pixel vejde kupříkladu do stínu stromu, vedlejší pixel je naopak celý na osvětlené ploše, a to může výsledky negativně ovlivnit (Nagendra et al. 2010). Kromě rozlišení satelitního snímku je možná ještě důležitější velikost mapované plochy. Čím je menší, tím je pravděpodobnější, že obsahuje jen jeden typ krajiny, který může mít vysokou spektrální variabilitu, ale nízkou druhovou diverzitu (Prajzlerová et al. 2024).

Vhodné by dále bylo porovnat výsledky odvozené ze satelitních snímků pořízených v různých ročních obdobích. V této práci jsem použil snímek z května, v jiném ročním období by spektrální charakteristiky byly odlišné (Culbert et al. 2009) a zřejmě tak i výsledky. Vegetace se totiž nachází v různých svých fenologických fázích a tím se mění i habitat živočichů (Ribeiro et al. 2019). Uplatnění hypotézy o spektrální variabilitě není univerzální. Liší se dle zkoumaného ekosystému, ročního období a také použitého senzoru (Ludwig et al. 2024).

7. Závěr

Bakalářská práce zkoumala, zda je ptačí diverzita a ornitologická hodnota v oblasti Žďárských vrchů vysvětlitelná spektrálními charakteristikami odvozenými ze satelitního multispektrálního snímku a zda zde platí i tzv. hypotéza spektrální variability. Vstupními daty byly body reprezentující lokality, kde probíhalo sčítání ptáků. Z nich byly odvozeny vysvětlované proměnné – počet druhů a Shannonův index, charakterizující diverzitu, a ornitologická hodnota, charakterizující vzácnost ptáků. Satelitní snímek systému Landsat 5 poskytl prediktory neboli vysvětlující proměnné, konkrétně medián a směrodatnou odchylku všech spektrálních pásem a vybraných spektrálních indexů. Závislost vysvětlovaných proměnných a prediktorů nakonec prověřil zobecněný lineární model.

Nejvýznamnějšími prediktory byly: směrodatná odchylka blízkého infračerveného pásma, medián i směrodatná odchylka indexu NDVI a medián indexu NDMI. Potvrdily, že ptačí diverzita byla vyšší v oblastech se zelenější, zdravější a hustší vegetací. Tato prostředí vyhledávaly i vzácnější druhy ptáků. Naopak při vyšší vlhkosti území diverzita i ornitologická hodnota klesaly.

Naznačily také důležitost heterogenity krajiny z hlediska vegetace. Čím vyšší heterogenita byla (v podobě směrodatné odchylky blízkého infračerveného pásma i indexu NDVI), tím více druhů, i vzácných, se v lokalitě vyskytovalo. Tyto dva prediktory potvrdily hypotézu spektrální variability. Potvrdila se také v případě indexu NDMI. Tedy čím více se střídaly sušší a vlhčí plochy, tím více druhů, i vzácných, se opět vyskytovalo. Hypotéza však neplatila u směrodatné odchylky zeleného pásma, krátkovlnného infračerveného pásma ani u indexu EVI.

Kombinace 30metrových pixelů ze snímku Landsat 5 a 7hektarových zkoumaných ploch použitá v této práci se celkově neukázala jako příliš vhodná k posuzování biodiverzity nebo ornitologické hodnoty pomocí spektrální variability. Vhodné by bylo postup ověřit v jiném měřítku a v různých fenologických fázích.

8. Přehled literatury a použitých zdrojů

Odborné publikace

- Alessandrini C., Scridel D., Boitani L., Pedrini P., Brambilla M., 2022: Remotely sensed variables explain microhabitat selection and reveal buffering behaviours against warming in a climate-sensitive bird species. *Remote Sensing in Ecology and Conservation* 8 (5), 615-628.
- Bajer A., Hlaváč V., Kirchner K., Kubalíková L., 2014: Za skalními útvary CHKO Žďárské vrchy. Mendelova univerzita v Brně, Brno.
- Bellis L. M., Pidgeon A. M., Radeloff V. C., St-Louis V., Navarro J. L., Martella M. B., 2008: Modeling habitat suitability for Greater Rheas based on satellite image texture. *Ecological Applications* 18 (8), 1956-1966.
- Boháč J., 2013: Ochrana biodiverzity. Jihočeská univerzita v Českých Budějovicích, České Budějovice.
- Brambilla M., Bazzi G., Ilahiane L., 2023: The effectiveness of species distribution models in predicting local abundance depends on model grain size. *Ecology* 105 (2), e4224.
- Chefaoui R. M., Lobo J. M., 2008: Assessing the effects of pseudo-absences on predictive distribution model performance. *Ecological Modelling* 210 (4), 478-486.
- Chen J., Chen J., Liao A., Cao X., Chen L., Chen X., He C., Han G., Peng S., Lu M., Zhang W., Tong X., Mills J., 2015: Global land cover mapping at 30 m resolution: A POK-based operational approach. *ISPRS Journal of Photogrammetry and Remote Sensing* 103, 7-27.
- Chytrý M., Wild J., Pyšek P., Jarošík V., Dendoncker N., Reginster I., Pino J., Maskell L. C., Vilà M., Pergl J., Kühn I., Spangenberg J. H., Settele J., 2012: Projecting trends in plant invasions in Europe under different scenarios of future land-use change. *Global Ecology and Biogeography* 21, 75-87.
- Coops N. C., Wulder M. A., 2019: Breaking the Habit(at). *Trends in Ecology & Evolution* 34 (7), 585-587.
- Culbert P. D., Pidgeon A. M., St-Louis V., Bash D., Radeloff V. C., 2009: The Impact of Phenological Variation on Texture Measures of Remotely Sensed

Imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing 2 (4), 299-309.

- Duro D. C., Girard J., King D. J., Fahrig L., Mitchell S., Lindsay K., Tischendorf L., 2014: Predicting species diversity in agricultural environments using Landsat TM imagery. *Remote Sensing of Environment* 144, 214-225.
- 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.
- Feeley K. J., Silman M. R., 2010: Modelling the responses of Andean and Amazonian plant species to climate change: the effects of georeferencing errors and the importance of data filtering. *Journal of Biogeography* 37 (4), 733-740.
- Franklin J., Miller J. A., 2010: Mapping species distributions: spatial inference and prediction. Cambridge University Press, Cambridge.
- Gábor L., Moudrý V., Lecours V., Malavasi M., Barták V., Fogl M., Šimová P., Rocchini D., Václavík T., 2019: The effect of positional error on fine scale species distribution models increases for specialist species. *Ecography* 43 (2), 256-269.
- Gábor L., Jetz W., Lu M., Rocchini D., Cord A., Malavasi M., Zarzo-Arias A., Barták V., Moudrý V., 2022: Positional errors in species distribution modelling are not overcome by the coarser grains of analysis. *Methods in Ecology and Evolution* 13, 2289-2302.
- Gong P., Wang J., Yu L., Zhao Y., Liang L., Niu Z., Huang X., Fu H., Liu S., Li C., Li X., Fu W., Liu C., Xu Y., Wang X., Cheng Q., Hu L., Yao W., Zhang H., Zhu P., Zhao Z., Zhang H., Zheng Y., Ji L., Zhang Y., Chen H., Yan A., Guo J., Yu L., Wang L., Liu X., Shi T., Zhu M., Chen Y., Yang G., Tang P., Xu B., Giri C., Clinton N., Zhu Z., Chen J., Chen J., 2013: Finer resolution observation and monitoring of global land cover: first mapping results with Landsat TM and ETM+ data. *International Journal of Remote Sensing* 34 (7), 2607-2654.
- Gottschalk T. K., Aue B., Hotes S., Ekschmitt K., 2011: Influence of grain size on species-habitat models. *Ecological Modelling* 222 (18), 3403-3412.
- Graf R. F., Bollmann K., Suter W., Bugmann H., 2005: The importance of spatial scale in habitat models: capercaillie in the Swiss Alps. *Landscape Ecology* 20 (6), 703-717.

- Heikkinen R. K., Luoto M., Kuussaari M., Toivonen T., 2007: Modelling the spatial distribution of a threatened butterfly: Impacts of scale and statistical technique. *Landscape and Urban Planning* 79, 347-357.
- Hladký R., Lastovicka J., Holman L., Stych P., 2020: Evaluation of the influence of disturbances on forest vegetation using Landsat time series; a case study of the Low Tatras National Park. *European Journal of Remote Sensing* 53, 40-66.
- Hlaváč V., 2020: 50 let CHKO Žďárské vrchy: Ohlédnutí zpět a krátké zamýšlení nad další cestou. *Ochrana přírody* 4, 2-5.
- Holland J. D., Bert D. G., Fahrig L., 2004: Determining the Spatial Scale of Species' Response to Habitat. *BioScience* 54, 227-233.
- Hongoh V., Berrang-Ford L., Scott M. E., Lindsay L. R., 2012: Expanding geographical distribution of the mosquito, *Culex pipiens*, in Canada under climate change. *Applied Geography* 33, 53-62.
- Hopkins L. M., Hallman T. A., Killbride J., Douglas Robinson W., Hutchinson R. A., 2022: A comparison of remotely sensed environmental predictors for avian distributions. *Landscape Ecology* 37, 997-1016.
- Huete A., Didan K., Miura T., Rodriguez E. P., Gao X., Ferreira L. G., 2002: Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment* 83, 195-213.
- Hunt M. L., Blackburn G. A., Siriwardena G. M., Carrasco L., Rowland C. S., 2022: Using satellite data to assess spatial drivers of bird diversity. *Remote Sensing in Ecology and Conservation* 9 (4), 483-500.
- Jackson C. R., Robertson M. P., 2011: Predicting the potential distribution of an endangered cryptic subterranean mammal from few occurrence records. *Journal for Nature Conservation* 19 (2), 87-94.
- Jensen J. R., 2015: Introductory digital image processing: a remote sensing perspective, fourth edition. Pearson Education, Glenview.
- Jiménez-Valverde A., Lobo J. M., Hortal J., 2008: Not as good as they seem: the importance of concepts in species distribution modelling. *Diversity and Distributions* 14 (6), 885-890.
- Kaliontzopoulou A., Brito J. C., Carretero M. A., Larbes S., Harris D. J., 2008: Modelling the partially unknown distribution of wall lizards (*Podarcis*) in

- North Africa: ecological affinities, potential areas of occurrence, and methodological constraints. Canadian Journal of Zoology 86 (9), 992-1001.
- Laštůvka Z., Krejčová P., 2000: Ekologie. Konvoj, Brno.
 - Levin N., Shmida A., Levanoni O., Tamari H., Kark S., 2007: Predicting mountain plant richness and rarity from space using satellite-derived vegetation indices. Diversity and Distributions 13 (6), 692-703.
 - Lillesand T. M., Kiefer R. W., Chipman J. W., 2015: Remote sensing and image interpretation, seventh edition. Wiley, Hoboken.
 - Lopes M., Fauvel M., Ouin A., Girard S., 2017: Spectro-Temporal Heterogeneity Measures from Dense High Spatial Resolution Satellite Image Time Series: Application to Grassland Species Diversity Estimation. Remote Sensing 9 (10), 993.
 - Ludwig A., Doktor D., Feilhauer H., 2024: Is spectral pixel-to-pixel variation a reliable indicator of grassland biodiversity? A systematic assessment of the spectral variation hypothesis using spatial simulation experiments. Remote Sensing of Environment 302, 113988.
 - Moudrý V., Šimová P., 2012: Influence of positional accuracy, sample size and scale on modelling species distributions: a review. International Journal of Geographical Information Science 26 (11), 2083-2095.
 - Moudrý V., Šimová P., 2013: Relative importance of climate, topography, and habitats for breeding wetland birds with different latitudinal distributions in the Czech Republic. Applied Geography 44, 165-171.
 - Moudrý V., Bazzichetto M., Remelgado R., Devillers R., Lenoir J., Mateo R. G., Lembrechts J. J., Sillero N., Lecours V., Cord A. F., Barták V., Balej P., Rocchini D., Torresani M., Arenas-Castro S., Man M., Prajzlerová D., Gdulová K., Prošek J., Marchetto E., Zarzo-Arias A., Gábor L., Leroy F., Martini M., Malavasi M., Gatti R. C., Wild J., Šimová P., 2024: Optimising Species Distribution Models: Sample size, positional error and sampling bias matter. *in press*.
 - Morelli F., Møller A. P., Nelson E., Benedetti Y., Liang W., Šimová P., Moretti M., Tryjanowski P., 2017: The common cuckoo is an effective indicator of high bird species richness in Asia and Europe. Scientific Reports 7 (1), 4376.

- Morelli F., Benedetti Y., Šímová P., 2018: Landscape metrics as indicators of avian diversity and community measures. *Ecological Indicators* 90, 132-141.
- Nagendra H., Rocchini D., Ghate R., Sharma B., Pareeth S., 2010: Assessing Plant Diversity in a Dry Tropical Forest: Comparing the Utility of Landsat and Ikonos Satellite Images. *Remote Sensing* 2 (2), 478-496.
- Oeser J., Heurich M., Senf C., Pflugmacher D., Belotti E., Kuemmerle T., 2019: Habitat metrics based on multi-temporal Landsat imagery for mapping large mammal habitat. *Remote Sensing in Ecology and Conservation* 6 (1), 52-69.
- Palmer M. W., Wohlgemuth T., Earls P., Arévalo J. R., Thompson S., 2000: Opportunities for Long-Term Ecological Research at the Tallgrass Prairie Preserve, Oklahoma. Cooperation in Long Term Ecological Research in Central and Eastern Europe, 123-128.
- Palmer M. W., Earls P. G., Hoagland B. W., White P. S., Wohlgemuth T., 2002: Quantitative tools for perfecting species lists. *Environmetrics* 13 (2), 121-137.
- Perrone M., Di Febbraro M., Conti L., Divíšek J., Chytrý M., Keil P., Carranza M. L., Rocchini D., Torresani M., Moudrý V., Šímová P., Prajzlerová D., Müllerová J., Wild J., Malavasi M., 2023: The relationship between spectral and plant diversity: Disentangling the influence of metrics and habitat types at the landscape scale. *Remote Sensing of Environment* 293, 113591.
- Prajzlerová D., Barták V., Keil P., Moudrý V., Zikmundová M., Balej P., Leroy F., Rocchini D., Perrone M., Malavasi M., Šímová P., 2024: The relationship between remotely-sensed spectral heterogeneity and bird diversity is modulated by landscape type. *in press*.
- Primack R. B., Kindlmann P., Jersáková J., 2011: *Úvod do biologie ochrany přírody*. Portál, Praha.
- Renwick A. R., Massimino D., Newson S. E., Chamberlain D. E., Pearce-Higgins J. W., Johnston A., 2012: Modelling changes in species' abundance in response to projected climate change. *Diversity and Distributions* 18 (2), 121-132.
- Ribeiro I., Proença V., Serra P., Palma J., Domingo C., Pons X., Domingos T., 2019: Remotely sensed indicators and open-access biodiversity data to assess

- bird diversity patterns in Mediterranean rural landscapes. *Scientific Reports* 9, 6826.
- Rocchini D., Chiarucci A., Loiselle S. A., 2004: Testing the spectral variation hypothesis by using satellite multispectral images. *Acta Oecologica* 26 (2), 117-120.
 - Rocchini D., Ricotta C., Chiarucci A., 2007: Using satellite imagery to assess plant species richness: The role of multispectral systems. *Applied Vegetation Science* 10 (3), 325-331.
 - Rocchini D., Balkenhol N., Carter G. A., Foody G. M., Gillespie T. W., He K. S., Kark S., Levin N., Lucas K., Luoto M., Nagendra H., Oldeland J., Ricotta C., Southworth J., Neteler M., 2010: Remotely sensed spectral heterogeneity as a proxy of species diversity: Recent advances and open challenges. *Ecological Informatics* 5, 318-329.
 - Rocchini D., Marcantonio M., Ricotta C., 2016: Measuring Rao's Q diversity index from remote sensing: An open source solution. *Ecological Indicators* 72, 234-238.
 - Rocchini D., Salvatori N., Beierkuhnlein C., Chiarucci A., de Boissieu F., Förster M., Garzon-Lopez C. X., Gillespie T. W., Hauffe H. C., He K. S., Kleijn D., Kleinschmit B., Lenoir J., Malavasi M., Moudry V., Nagendra H., Payne D., Šimová P., Torresani M., Wegmann M., Féret J.-B., 2021: From local spectral species to global spectral communities: a benchmark for ekosystém diversity estimate by remote sensing. *Ecological Informatics* 61 (4), 101195.
 - Roubicek A. J., VanDerWal J., Beaumont L. J., Pitman A. J., Wilson P., Hughes L., 2010: Does the choice of climate baseline matter in ecological niche modelling? *Ecological Modelling* 221 (19), 2280-2286.
 - Schleupner C., Link P. M., 2008: Potential impacts on important bird habitats in Eiderstedt (Schleswig-Holstein) caused by agricultural land use changes. *Applied Geography* 28 (4), 237-247.
 - Schmidlein S., Fassnacht F. E., 2017: The spectral variability hypothesis does not hold across landscapes. *Remote Sensing of Environment* 192 (18), 114-125.
 - 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* 19 (7), 855-866.

- St-Louis V., Pidgeon A. M., Kuemmerle T., Sonnenschein R., Radeloff V. C., Clayton M. K., Locke B. A., Bash D., Hostert P., 2014: Modelling avian biodiversity using raw, unclassified satellite imagery. *Philosophical Transactions of the Royal Society B* 369 (1643), 20130197.
- Stein A., Gerstner K., Kreft H., 2014: Environmental heterogeneity as a universal driver of species richness across taxa, biomes and spatial scales. *Ecology Letters* 17, 866-880.
- Storch D., 2019: Biodiverzita: co to je, jak ji měřit, co ji podmiňuje a k čemu je to všechno dobré. *Živa* 5, 194-197.
- Storch D., Mihulka S., 1997: *Ekologie*. Vesmír, Praha.
- Storch D., Konvicka M., Benes J., Martinková J., Gaston K. J., 2003: Distribution patterns in butterflies and birds of the Czech Republic: separating effects of habitat and geographical position. *Journal of Biogeography* 30 (8), 1195-1205.
- Šálek M., Harabiš F., 2015: *Obecná ekologie*. Česká zemědělská univerzita v Praze, Praha.
- Šimová P., 2005: Analýza vlivu krajinných atributů na ptačí společenstva s využitím vybraných geodat. Česká zemědělská univerzita v Praze, Fakulta lesnická a environmentální, Praha. 115 s. (disertační práce). „nepublikováno“. Dep. SIC ČZU v Praze.
- Šimová P., Gdulová K., 2012: Landscape indices behavior: A review of scale effects. *Applied Geography* 34, 385-394.
- Šimová P., Moudrý V., Komárek J., Hrach K., Fortin M.-J., 2019: Fine scale waterbody data improve prediction of waterbird occurrence despite coarse species data. *Ecography* 42 (3), 511-520.
- Šťastný K., Bejček V., Mikuláš I., Telenský T., 2021: *Atlas hnízdního rozšíření ptáků v České republice: 2014-2017*. Aventium, Praha.
- Tempfli K., Kerle N., Huurneman G. C., Janssen L. L. F., Bakker W. H., Feringa W., Gieske A. S. M., Gorte B. G. H., Grabmaier K. A., Hecker C. A., Horn J. A., van der Meer F. D., Parodi G. N., Pohl C., Reeves C. V., van Ruitenbeek F. J., Schetselaar E. M., Weir M. J. C., Westinga E., Woldai T.,

2009: Principles of Remote Sensing: an introductory textbook. The International Institute for Geo-Information Science and Earth Observation, Enschede.

- Torresani M., Rocchini D., Sonnenschein R., Zebisch M., Marcantonio M., Ricotta C., Tonon G., 2019: Estimating tree species diversity from space in an alpine conifer forest: the Rao's Q diversity index meets the Spectral Variation Hypothesis. *Ecological Informatics* 52, 26-34.
- Václavík T., Meentemeyer R. K., 2009: Invasive species distribution modeling (iSDM): Are absence data and dispersal constraints needed to predict actual distributions? *Ecological Modelling* 220 (23), 3248-3258.
- Wang R., Gamon J. A., 2019: Remote sensing of terrestrial plant biodiversity. *Remote Sensing of Environment* 231, 111218.
- Williams K. J., Belbin L., Austin M. P., Stein J. L., Ferrier S., 2012: Which environmental variables should I use in my biodiversity model? *International Journal of Geographical Information Science* 26 (11), 2009-2047.

Internetové zdroje

- AOPK ČR, ©2024: CHKO Žďárské vrchy – charakteristika oblasti (online) [cit.2024.02.20], dostupné z <<https://zdarskevrchy.nature.cz/charakteristika-oblasti>>.
- CCRS, ©2019: Fundamentals of Remote Sensing (online) [cit.2024.02.20], dostupné z <<https://natural-resources.canada.ca/maps-tools-and-publications/satellite-imagery-and-air-photos/tutorial-fundamentals-remote-sensing/9309>>.
- ČÚZK, ©2020: Data 200 (online) [cit.2024.02.20], dostupné z <[https://geoportal.cuzk.cz/\(S\(5ctpx0rag3ygzrb3m10xyub\)\)/Default.aspx?mode=TextMeta&side=mapy_data200&text=dSady_mapyData200&head_tab=ekce-02-gp&menu=229](https://geoportal.cuzk.cz/(S(5ctpx0rag3ygzrb3m10xyub))/Default.aspx?mode=TextMeta&side=mapy_data200&text=dSady_mapyData200&head_tab=ekce-02-gp&menu=229)>.
- Earth Explorer, ©2024: Data Sets (online) [cit.2024.02.20], dostupné z <<https://earthexplorer.usgs.gov/>>.
- ESA, ©2024: SNAP (online) [cit.2024.02.20], dostupné z <<https://earth.esa.int/eogateway/tools/snap>>.

- ESRI, ©2024: ArcGIS Pro (online) [cit.2024.02.20], dostupné z <<https://www.esri.com/en-us/arcgis/products/arcgis-pro/overview>>.
- Geospatial Innovation Facility, ©2008: Landsat Spectral Band Information (online) [cit.2024.03.24], dostupné z <<http://gif.berkeley.edu/documents/Landsat%20Band%20Information.pdf>>.
- Microsoft, ©2024: Microsoft Excel (online) [cit.2024.02.20], dostupné z <<https://www.microsoft.com/cs-cz/microsoft-365/excel>>.
- NASA, ©2024: Landsat science: Satellites (online) [cit.2024.02.20], dostupné z <<https://landsat.gsfc.nasa.gov/satellites/>>.
- Portland State University, ©2001: Band Combinations (online) [cit.2024.03.24], dostupné z <https://web.pdx.edu/~nauna/resources/10_BandCombinations.htm>.
- Posit, ©2024: RStudio Desktop (online) [cit.2024.02.20], dostupné z <<https://posit.co/download/rstudio-desktop/>>.
- USGS, ©2024a: What are the best Landsat spectral bands for use in my research? (online) [cit.2024.03.24], dostupné z <<https://www.usgs.gov/faqs/what-are-best-landsat-spectral-bands-use-my-research>>.
- USGS, ©2024b: Landsat Surface Reflectance-derived Spectral Indices (online) [cit.2024.03.24], dostupné z <<https://www.usgs.gov/landsat-missions/landsat-surface-reflectance-derived-spectral-indices>>.
- USGS, ©2024c: Landsat satellite missions (online) [cit.2024.02.20], dostupné z <<https://www.usgs.gov/landsat-missions/landsat-satellite-missions>>.

9. Přílohy

Příloha: Převzatý seznam ptačích druhů (Šimová 2005) a vypočtená ornitologická hodnota (ORN)

DRUH	ORN	DRUH	ORN	DRUH	ORN
Bažant obecný	0,110	Konopka obecná	0,041	Rehek domácí	0,002
Bekasina otavní	0,618	Kormorán velký	0,841	Rehek zahradní	0,049
Bramborňáček hnědý	0,164	Kos černý	0,002	Roryš obecný	0,024
Brhlík lesní	0,002	Krahujec obecný	0,046	Sedmihlásek hajní	0,061
Budníček lesní	0,076	Králíček obecný	0,072	Skřivan polní	0,005
Budníček menší	0,005	Králíček ohnivý	0,226	Slavík obecný	0,497
Budníček větší	0,016	Krkavec velký	0,099	Sojka obecná	0,005
Cvrčilka říční	0,161	Krutihlav obecný	0,312	Stehlík obecný	0,008
Cvrčilka zelená	0,121	Křepelka polní	0,065	Straka obecná	0,038
Čáp bílý	0,283	Křívka obecná	0,277	Strakapoud velký	0,002
Čáp černý	0,213	Kukačka obecná	0,006	Strnad luční	0,554
Čejka chocholatá	0,186	Lejsek černohlavý	0,457	Strnad obecný	0
Červenka obecná	0,002	Lejsek šedý	0,073	Strnad rákosní	0,204
Čížek lesní	0,247	Linduška lesní	0,038	Střízlík obecný	0,005
Datel černý	0,046	Linduška luční	0,467	Sýkora babka	0,078
Dlask tlustozobý	0,059	Lyska černá	0,204	Sýkora koňadra	0
Drozd brávník	0,067	Mlynařík dlouhoocasý	0,059	Sýkora lužní	0,217
Drozd kvíčala	0,061	Moták pochop	0,212	Sýkora modřinka	0,002
Drozd zpěvný	0,002	Ořešník kropenatý	0,460	Sýkora parukářka	0,151
Holub domácí	0,210	Pěnice černohlavá	0,002	Sýkora uhelníček	0,054
Holub doupňák	0,309	Pěnice hnědokřídlá	0,019	Šoupálek dlouhoprstý	0,054
Holub hřívňáč	0,003	Pěnice pokrovní	0,022	Špaček obecný	0,005
Hrdlička divoká	0,051	Pěnice slavíková	0,073	Ťuhýk obecný	0,005
Hrdlička zahradní	0,029	Pěnkava obecná	0	Vlaštovka obecná	0,002
Hýl obecný	0,108	Pěvuška modrá	0,024	Volavka popelavá	0,366
Hýl rudý	0,803	Polák chocholačka	0,285	Vrabec domácí	0,006
Chřástal polní	0,384	Poštolka obecná	0,006	Vrabec polní	0,057
Jiřička obecná	0,002	Potápka malá	0,326	Vrána obecná černá	0,521
Kachna divoká	0,030	Potápka roháč	0,430	Zvonek zelený	0
Káně lesní	0,003	Racek chechtavý	0,543	Zvonohlík zahradní	0,005
Kavka obecná	0,546	Rákosník obecný	0,280	Žluna šedá	0,311
Konipas bílý	0	Rákosník proužkovaný	0,463	Žluva hajní	0,271
Konipas horský	0,059	Rákosník zpěvný	0,083		