

Univerzita Palackého v Olomouci
Přírodovědecká fakulta
Katedra ekologie a životního prostředí



Prediktivní model rozšíření sovy pálené v České republice

Markéta Trundová
Bakalářská práce

předložená
na Katedře ekologie a životního prostředí
Přírodovědecké fakulty Univerzity Palackého v Olomouci

jako součást požadavků
na získání titulu Bc. v oboru
Ochrana a tvorba životního prostředí

Vedoucí práce: prof. MVDr. Emil Tkadlec, CSc.

Olomouc 2022

Prohlášení:

Prohlašuji, že bakalářskou práci jsem vypracovala samostatně pod vedením prof. MVDr. Emila Tkadlece, CSc. a jen s použitím citovaných literárních pramenů.

V Olomouci 1. května 2022

.....

Podpis

Trundová M. 2022. Prediktivní model rozšíření sovy pálené v České republice [bakalářská práce]. Olomouc: Katedra ekologie a životního prostředí PřF UP v Olomouci. 28 s., 1 příloha, česky.

Abstrakt

Početnost sovy pálené v posledních desetiletích výrazně klesá. V České republice patří k silně ohroženým, a zvláště chráněným druhům. Mezi hlavní důvody úbytku patří nedostatek míst vhodných pro hnízdění a vyrušování. Původní hnízdiště tvořily dutiny stromů nebo skal. Dnes je sova pálená, v důsledku rozšiřování kulturní krajiny, vázána na lidská obydlí, kde vyhledává různá zákoutí, dutiny či věže. Ovšem i těchto hnízdišť ubývá s moderními renovacemi starých domů. Pro podporu sovy pálené lze přijmout některá opatření, mezi které patří např. stavba hnízdních budek a jejich instalace na stromy nebo uvnitř stodol či jiných budov. Díky těmto opatřením začala v devadesátých letech početnost sovy pálené mírně stoupat. Aby tato opatření byla co nejefektivnější, musí být hnízdní budky rozmístěny na místa, která jsou svými podmínkami pro sovu optimální. V předložené bakalářské práci se zabývám nalezením potencionálně vhodných stanovišť pro hnízdění tohoto druhu na základě vytvoření prediktivního modelu. Takový model nebyl doposud vytvořen. K vytvoření modelu jsem použila program *R* s modelovacím algoritmem Maxent. Výsledky modelování ukazují největší pravděpodobnost hnízdění v oblastech velkých nížin. Významnými environmentálními proměnnými jsou nadmořská výška, teplota a srážky. Nová místa pro hnízdění nebyla na základě modelu nalezena. Důvodem je, že ochrana sovy pálené je na území České republiky velmi dobře zajištěná a hnízdní budky již pokrývají veškeré území vhodné pro hnízdění.

Klíčová slova: Hnízdní budky, klimatické proměnné, mapa rozšíření, Maxent, *Tyto alba*

Trundová M. 2022. Predictive model of Barn Owl distribution in the Czech Republic. [bachelor's thesis]. Olomouc: Department of Ecology and Environmental Sciences, Faculty of Science, Palacky University Olomouc, 28 p., 1 Appendix, in Czech.

Abstract

Barn Owl numbers have declined significantly in recent decades. In the Czech Republic, it is one of the most endangered and specially protected species. The main causes of the decline include the lack of places suitable for nesting and disturbance. The original nesting sites were cavities of trees or rocks. Today, the barn owl, due to the expansion of the cultural landscape, is tied to human dwellings, where it seeks out various nooks, crannies, cavities or towers. However, even these nesting sites are declining with modern renovations of old houses. Some measures can be taken to support the barn owl, including the construction of nest boxes and their installation in trees or inside barns or other buildings. As a result of these measures, Barn Owl numbers began to increase slightly in the 1990s. In order for these measures to be as effective as possible, nest boxes must be placed in locations that are optimal for the owl. In the presented bachelor thesis I am concerned with finding potentially suitable areas for nesting sites by developing a predictive model of its distribution in the Czech Republic. Such a model has not yet been developed. To create the model I used the program *R* with the modelling algorithm Maxent. The model results show the highest probability of nesting in large lowland areas. Altitude, temperature and precipitation are important environmental variables. New nesting sites have not been found based on the model. The reason is that the protection of the Barn Owl is very well provided in the Czech Republic and nest boxes already cover all the areas suitable for nesting.

Key words: climatic variables, distribution map, Maxent, nest boxes, *Tyto alba*

Obsah	
Seznam tabulek	vii
Seznam obrázků	viii
Poděkování.....	ix
Úvod.....	1
Pokles biodiverzity.....	1
Sovy	2
Rozšíření sovy pálené	4
Prediktivní model distribuce	7
Modelovací metody	8
Maxent	9
Klíčové kroky modelování.....	9
Hodnocení kvality modelu	10
Cíle práce	11
Materiál a metody	12
Příprava dat	12
Konstrukce modelu	12
Výsledky	16
Diskuze	20
Environmentální proměnné.....	20
Souhrn.....	24
Literatura.....	25
Příloha A	II

Seznam tabulek

Tabulka 1. Počet popsáných a hodnocených druhů obratlovců a % ohrožených druhů jednotlivých skupin obratlovců. Procento ohrožených druhů lze vypočítat pro skupiny, kde je > 80 % vyhodnocených druhů. Skutečný počet ohrožených druhů je často nejistý, protože není známo, zda jsou druhy s nedostatkem údajů (NÚ) skutečně ohrožené, či nikoli. Proto se uvádí rozmezí procentuálních hodnot. Dolní odhad: % ohrožených druhů, kde druhy s NÚ jsou brány jako neohrožené. Nejlepší odhad: % ohrožených druhů, kde druhy s NÚ jsou hodnoceny jako druhy s dostatkem údajů. Horní odhad: % ohrožených druhů, kde druhy s NÚ jsou brány jako ohrožené. Zdroj: The IUCN Red List of Threatened Species: Summary Statistics. 2022. Retrieved January 21, 2022, from https://www.iucnredlist.org	2
Tabulka 2: Druhy sov žijící v ČR a jejich ohrožení (Zdroj: ISOP. 2006. Retrieved December 26, 2021, from www.portal.nature.cz ; Chobot K., Němec M. (Eds.). 2017. <i>Červený seznam ohrožených druhů České republiky: Obratlovci</i> (34 ed.). AOPK ČR).....	3
Tabulka 3: Klimatické proměnné z online úložiště WorldClim. Zdroj: <i>WorldClim</i> . 2020. Retrieved February 7, 2022, from worldclim.org	13

Seznam obrázků

Obrázek 1: Distribuce sovy pálené (<i>T. alba</i>) ve světě. Zdroj: König C., Weick F. 2008. OWLS of the World (2nd ed.). Christopher Helm.....	5
Obrázek 2: Výskyt druhu <i>Tyto alba</i> podle záznamu v ND OP. Zdroj: AOPK ČR. 2022b. Nálezová databáze ochrany přírody. Retrieved April 7, 2022, from www.portal.nature.cz	7
Obrázek 3: Mapa potenciálního výskytu sovy pálené v ČR. (a) Každé hnízdo bylo v datovém vzorku zastoupeno pouze jednou bez ohledu na počet hnízdění ve sledované periodě. (b) Každé hnízdo je ve vzorku zastoupeno tolikrát, kolikrát zde proběhlo rozmnožování.....	17
Obrázek 4: Mapa potenciálního výskytu sovy pálené v ČR. (a) Každé hnízdo je zastoupeno pouze jednou a počet prediktorů je redukován o 7 nevýznamných proměnných. (b) Hnízda jsou ve vzorku zastoupena podle počtu hnízdění a počet prediktorů je redukován o 7 nevýznamných proměnných.	18

Poděkování

Ráda bych poděkovala vedoucímu své bakalářské práce panu prof. Emilu Tkadlecovi, CSc. za obrovskou ochotu, čas i mnoho odborných rad. Také bych mu chtěla poděkovat za pomoc s konstrukcí map a zasvěcení do programu *R*. Mé poděkování patří také Karlu Poprachovi za poskytnutí materiálů týkající se hnízdění sovy pálené v ČR. Dále bych chtěla poděkovat své rodině za podporu při celém bakalářském studiu.

Úvod

Pokles biodiverzity

Lidská aktivita je globální a dominantní příčinnou většiny současných změn životního prostředí, spojených především s úbytkem biodiverzity (Vitousek et al. 1997; Rands et al. 2010; Dirzo et al. 2014; Haddad et al. 2015; Lewis a Maslin 2015; Díaz et al. 2019). Hlavními příčinami změn biologické rozmanitosti v globálním měřítku jsou změny ve využívání půdy k produkci zboží a služeb, které mění strukturu a fungování ekosystémů, koncentrace oxidu uhličitého v atmosféře, depozice dusíku a kyselých dešťů, změny klimatu a biotické výměny (Vitousek et al. 1997; Sala et al. 2000; Díaz et al. 2019). V roce 2014 byly odhadovány roční ztráty okolo 11 000 až 58 000 živočišných druhů ročně. Celosvětově bylo ohroženo 16 až 33 % druhů obratlovců, z nichž nejméně 322 druhů vyhynulo od roku 1500 (Dirzo et al. 2014). Aktuální hodnocení z roku 2021 ukazuje, že nejohroženější skupinou z obratlovců jsou obojživelníci, kde je ohroženo 34 až 51 % druhů (tab. 1) (The IUCN Red List of Threatened Species: Summary Statistics 2022). Přetrvávání masového vymírání druhů může způsobit problém s mnohem trvalejším dopadem než jakýkoli jiný environmentální problém (Myers et al. 2000). Proto je cílem ochrany přírody zachovat běžné druhy, aby se zabránilo vyhubení ohrožených druhů. Tím se zajistí, aby lidé mohli i nadále využívat služeb, které příroda poskytuje, jako je opylování, čistá voda, ochrana před povodněmi, stabilní klima, rekreace a inspirace (BirdLife International 2021).

Pokles ptačích populací je příznakem vážného ohrožení životního prostředí a přírodního dědictví v Evropě (European Environment Agency 2004). Tyto změny nám ukazují, kde dochází k degradaci stanovišť a kde je nejvíce zapotřebí jednat (BirdLife International 2021). Na ochraně ptáků se na území Evropy výrazně podílí soustava Natura 2000 a síť EU-15, která zahrnuje 3 639 zvláště chráněných území o rozloze téměř 280 500 km², což je téměř 8 % rozlohy EU (European Environment Agency 2004).

U většiny ptačích populací stoupá riziko mortality v důsledku různých antropogenních faktorů, jako jsou např. nárazy do oken, větrných turbín nebo vozidel, úrazy na elektrickém vedení nebo otravy pesticidy (Longcore a Smith 2013; Loss et al. 2015). V roce 1997 byla přibližně čtvrtina ptačích druhů na Zemi vyhubena a 11 % zbývajících ptáků ohroženo vyhubutím (Vitousek et al. 1997). Aktuálně je ohroženo

1 445 (13 %) druhů ptáku z celkového počtu 11 162 popsáných druhů z celého světa (The IUCN Red List of Threatened Species: Summary Statistics 2022).

Na území Evropy je z celkového počtu 544 druhů ptáků ohroženo 71 druhů (13 %). Mezi nejvíce ohrožené a ubývající skupiny patří mořské ptactvo, kachny, bahňáci a dravci (BirdLife International 2021).

V České republice bylo od roku 1940 registrováno 226 hnízdních druhů. Od roku 2000 byl zaznamenán pokles a registrováno bylo 211 druhů. Mezi druhy, které se na území České republiky nevyskytují od roku 1999, patří např. hvízdák eurasijský (*Mareca penelope*), morčák malý (*Mergellus albellus*), volavka bílá (*Ardea alba*), orlík krátkoprstý (*Circaetus gallicus*), orel nejmenší (*Hieraaetus pennatus*) a další (Šťastný a Krištín 2021). Natura 2000 zaujímá 14 % z celkové rozlohy ČR. Na našem území se skládá ze 41 ptačích oblastí a z 1 112 evropsky významných lokalit (AOPK ČR 2022a).

Tabulka 1. Počet popsáných a hodnocených druhů obratlovců a % ohrožených druhů jednotlivých skupin obratlovců. Procento ohrožených druhů lze vypočítat pro skupiny, kde je > 80 % vyhodnocených druhů. Skutečný počet ohrožených druhů je často nejistý, protože není známo, zda jsou druhy s nedostatkem údajů (NÚ) skutečně ohrožené, či nikoli. Proto se uvádí rozmezí procentuálních hodnot. Dolní odhad: % ohrožených druhů, kde druhy s NÚ jsou brány jako neohrožené. Nejlepší odhad: % ohrožených druhů, kde druhy s NÚ jsou hodnoceny jako druhy s dostatkem údajů. Horní odhad: % ohrožených druhů, kde druhy s NÚ jsou brány jako ohrožené. Zdroj: The IUCN Red List of Threatened Species: Summary Statistics. 2022. Retrieved January 21, 2022, from <https://www.iucnredlist.org>

Taxon	Počet popsáných druhů	Počet	Procento	Počet	Odhadované % ohrožených druhů v roce 2021		
		vyhodnocených druhů v roce 2021	hodnocených druhů v roce 2021	ohrožených druhů v roce 2021	Dolní odhad	Nejlepší odhad	Horní odhad
Savci	6578	5968	91	1333	23	26	37
Ptáci	11162	11162	100	1445	13	13	14
Plazi	1169	10148	87	1839	18	21	33
Obojživelníci	8395	7296	87	2488	34	41	51
Ryby	36058	22581	63	3332	nedostatečný rozsah		
Mezisoučet	73883	57155	77	10437			

Sovy

V rámci ptáků se sovy řadí ke druhům ohroženým (tab. 2). Největší hrozbou pro sovy je stále větší destrukce jejich přirozeného prostředí, např. kácení tropických deštných pralesů, úbytek biotopů na malých izolovaných ostrovech, používání pesticidů a černý trh. V některých regionech jsou sovy stále pronásledovány jako nositelé smůly (König a Weick 2008).

Sovy z celého světa rozdělujeme do dvou základních čeledí: Sovovití–Tytonidae a puštíkovití–Strigidae (König a Weick 2008). Čeleď puštíkovitých obsahuje 227 druhů, z nichž je 24 druhů zranitelných, 13 ohrožených a 3 kriticky ohrožené. Čeleď sovovitých obsahuje pouze 16 druhů, z nichž jsou čtyři považovány za zranitelné, jeden za ohrožený a o jednom není dostatek údajů. Sovu pálenou řadíme do čeledi sovovitých. V evropském červeném seznamu je uvedena jako druh málo dotčený, ale s klesající početností (BirdLife International 2021). V globálním měřítku jsou kriticky ohrožené druhy: Výreček komorský (*Otus pauliani*), výreček anjouanský (*Otus capnodes*), výreček ostrovní (*Otus insularis*) a sýček lesní (*Athene blewitti*) (König a Weick 2008).

Podle Nálezové databáze ČR se na našem území vyskytuje celkem 12 druhů sov (ISOP 2006). Z tohoto počtu je 8 druhů považováno za zvláště chráněné druhy (tab. 2). Jiná literatura uvádí výskyt pouze 10 druhů sov. Podle tohoto zdroje se druhy jako sovice krahujová (*Surnia ulula*), sovice sněžní (*Bubo scandiacus*) a výreček malý (*Otus scops*) na našem území již nevyskytují (Šťastný a Krištín 2021). Sova pálená (*T. alba*) je v České republice považována za zvláště chráněný a silně ohrožený druh (ISOP 2006). Červený seznam ji uvádí jako kriticky ohrožený druh (Chobot a Němec 2017).

Tabulka 2: Druhy sov žijící v ČR a jejich ohrožení (Zdroj: ISOP. 2006. Retrieved December 26, 2021, from www.portal.nature.cz; Chobot K., Němec M. (Eds.). 2017. Červený seznam ohrožených druhů České republiky: Obratlovci (34 ed.). AOPK ČR).

Druh	Čeleď	Ohrožení v ČR	Ohrožení dle IUCN
Kalous pustovka (<i>Asio flammeus</i>)	Strigidae	SO	NA
Kalous ušatý (<i>Asio otus</i>)	Strigidae	bez ochrany	LC
Kulíšek nejmenší (<i>Glaucidium passerinum</i>)	Strigidae	SO	VU
Puštík bělavý (<i>Strix uralensis</i>)	Strigidae	KO	CR
Puštík obecný (<i>Strix aluco</i>)	Strigidae	bez ochrany	LC
Sova pálená (<i>Tyto alba</i>)	Tytonidae	SO	CR
Sovice krahujová (<i>Surnia ulula</i>)	Strigidae	bez ochrany	nehodnocen
Sovice sněžní (<i>Bubo scandiacus</i>)	Strigidae	bez ochrany	nehodnocen
Sýc rousný (<i>Aegolius funereus</i>)	Strigidae	SO	VU
Sýček obecný (<i>Athene noctua</i>)	Strigidae	SO	CR
Výr velký (<i>Bubo bubo</i>)	Strigidae	O	EN
Výreček malý (<i>Otus scops</i>)	Strigidae	KO	NA

Abychom sovy podpořili, můžeme provést některá lokální opatření. Osvědčila se stavba hnízdních budek a jejich instalace na stromy nebo uvnitř stodol či jiných budov. Mezi druhy, které hnízdí v umělých hnízdních budkách patří např. sýc rousný (*A. funereus*), kulíšek (*Glaucidium*), puštík bělavý (*S. uralensis*), puštík obecný (*S. aluco*)

a sova pálená (*T. alba*) (König a Weick 2008). Malým druhům sov můžeme pomoci upevněním hnízdních trubek na svislý strom. Díky těmto opatření se povedlo úspěšně reintrodukovat druhy jako je výr velký (*B. bubo*) ve střední Evropě nebo Kulíšek nejmenší (*G. passerinum*) v Černém lese (König a Weick 2008). U sov pálených přinesla instalace hnízdních budek velký přínos pro udržení nebo dokonce zvětšení jejich populací (König a Weick 2008). Pozitivní vliv hnízdních budek na populace tohoto druhu se prokázal např. v Nizozemsku (de Bruijn 1994), Velké Británii (Glue 1992) nebo v USA (New Jersey) (Colvin 1984).

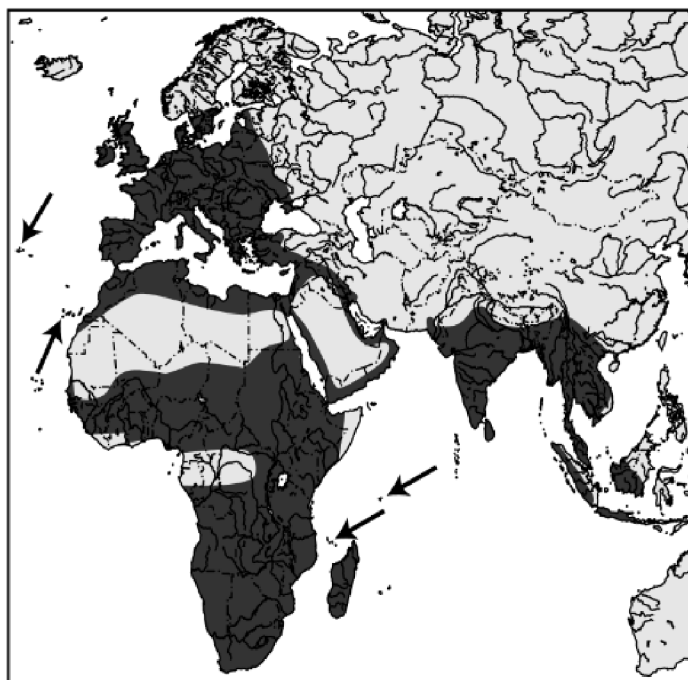
Rozšíření sovy pálené

Sova pálená je silně ubývajícím druhem (de Bruijn 1994, Šťastný a Bejček 2015). V současné době čelí značným problémům a tlakům způsobených ztrátou stanovišť a vyrušováním. S úbytkem druhu jsou spojené rozsáhlé změny v krajině, které nastaly v průběhu 50. a 60. let 20. století, kdy docházelo k zvětšování ploch zemědělské půdy na úkor luk a volné přírody (Poprach 2007, 2009). S těmito změnami zanikla spousta přirozených lovišť sovy pálené. V zemědělství se také začaly používat toxické rodenticidy k hubení hlodavců, které způsobily otravu mnoha jedincům (de Bruijn 1994, Roulin 2020). Změny ve využívání zemědělských budov, rekonstrukce či uzavírání kostelních věží vedlo k zániku mnoha vhodných hnízdišť. Negativní vliv má také hustota silniční a železniční dopravy (de Bruijn 1994, Roulin 2020). Mezi nebezpečné technické nástrahy, které se většinou nachází na zemědělských pozemcích patří vertikálně stojící roury či komíny, kam sova zaletí a už se nemůže dostat zpět (Poprach 2003). Nebezpečné jsou i nádrže s melasou, kde už mnoho sov i jiných druhů ptáků utonulo (Poprach 2007, 2009). Mezi přirozené faktory úhynu patří predace kunou skalní (*Martes foina*) a nedostatek potravy především v průběhu tuhých zim, které jsou charakteristické silnými mrazy, hlubokým sněhem a vytrvalou sněhovou pokrývkou (de Bruijn 1994). Na chladné podmínky není sova dobře přizpůsobená (Poprach 2009).

Sova pálená je rozšířená kosmopolitně. To znamená, že jsou její poddruhy zastoupeny na všech kontinentech kromě Antarktidy a jiných extrémních oblastí. Poddruhů je známo celkem 28 (Poprach 2009). Na základě DNA rozlišujeme tři základní skupiny poddruhů sovy pálené: Sova pálená (*Tyto alba*), která se nachází v Evropě, Africe (s výjimkou oblastí deštných pralesů a Somálska), na Madagaskaru, v Indii a Malajsii (obr. 1). Dále pak americká sova pálená (*Tyto furcata*), která je rozšířená v Severní,

Střední a Jižní Americe a nakonec australská sova pálená (*Tyto delicatula*) hnízdící v Austrálii, na Novém Zélandu a Polynésii (König a Weick 2008).

Na území Evropy se vyskytují celkem čtyři podruhy: *T. a. alba* v jižní Evropě a Velké Británii, *T. a. guttata* v severovýchodní Evropě, *T. a. ernesti* na Sardinii a Korsice a *T. a. erlangeri* na Krétě a Kypru (Poprach 2009, Roulin 2020). V Evropě se početnost sovy pálené odhaduje na 100 000 až 250 000 párů. Nejpočetněji je zastoupená na Pyrenejském poloostrově. Obrovský pokles hnízdní populace sovy pálené zaznamenalo např. Nizozemsko, kde se před rokem 1963 vyskytovalo 1 800–3 500 párů a mezi lety 1982–1984 pouze 300–500 párů. Podobná situace nastala ve Velké Británii, kde do roku 1932 hnízdilo cca 12 000 párů a v letech 1995 až 1997 klesl počet na pouhé 4 000 párů (Roulin 2020).



Obrázek 1: Distribuce sovy pálené (*T. alba*) ve světě. Zdroj: König C., Weick F. 2008. OWLS of the World (2nd ed.). Christopher Helm.

Sova pálená se nachází v mírném nebo teplém podnebí. Preferuje spíše otevřená stanoviště, včetně pouští, pastvin, vřesovišť, pobřežních plání, parků, je rozšířená na mírně zalesněných a kulturních stanovištích, ve vesnicích a městech (König a Weick 2008). Původně obývala skály, kde nalézala úkryt v různých štěrbinách, ale také dutých stromech. Postupem času se stala synantropním ptákem zemědělské krajiny, kde obývá

kostelní věže, půdy, stodoly, seníky i speciální hnízdní budky umístěné uvnitř hospodářských budov; optimální konstrukce mají čtyřhranný otvor 20–15 × 15 cm (Poprach et. al 1996, König a Weick 2008; Šťastný a Krištín 2021). Důležité je zabezpečení budky proti predátorům, kterého docílíme oplechováním vletového otvoru po celém obvodu (Lázničková a Láznička 1995, Poprach 2009).

Sova pálená obývá na našem území převážně nížinné oblasti údolí řek, jako jsou jižní Morava, Polabí a Poodří (Šťastný a Krištín 2021). Je patrná její preference nadmořské výšky do 250 m. n. m., kdy se vzrůstající nadmořskou výškou klesá její početnost a v nadmořských výškách 400 m. n. m. už se vyskytuje pouze výjimečně (Poprach 2001). Výjimky byly zaznamenány v Krkonoších nebo na Šumavě, kde se ojediněle vyskytovala ve výškách 800 m. n. m. (Šťastný a Krištín 2021). Mezi tradiční hnízdní oblasti v České republice patří: Znojmo, Hodonín, Uherské Hradiště, Nový Jičín, Nymburk a Břeclav (Poprach 1999, 2000).

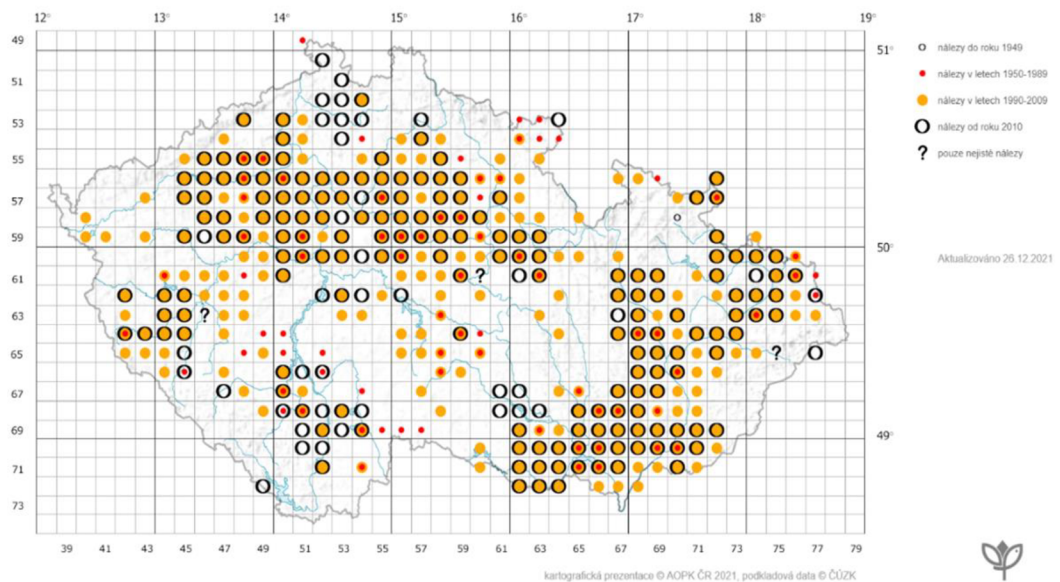
Pro záchranu tohoto druhu byly v devadesátých letech úspěšně instalovány hnízdní budky. Díky těmto opatření začala početnost sovy pálené mírně stoupat. V roce 1999 bylo kontrolováno celkem 1 840 hnízdních budek instalovaných v 44 okresech ČR. Nevíce obsazených budek se nacházelo v okresech Nový Jičín, Uherské Hradiště a Hodonín, přičemž průměrná denzita sovy pálené odpovídala 0,78 párům/100 km² (Karel Poprach 1999). V roce 2000 vzrostl počet instalovaných budek na 2 687, rozmístěných v 51 okresech ČR. Nejosídlenější budky se nacházely v okresech Znojmo, Uherské Hradiště, Hodonín a Břeclav. Průměrná denzita sovy pálené v ČR odpovídala 0,82 párům/100 km² (na území o rozloze 23 177 km² hnízdilo 189 párů sovy pálené, Poprach 2000). Dalšího roku vzrostl počet instalovaných budek na 3 135 a průměrná denzita sovy pálené v ČR odpovídala 1,53 páru/100 km² (na území o rozloze 26 018 km² hnízdilo 398 párů sovy pálené, Poprach 2001).

Zatím existují údaje o rozšíření tohoto druhu pouze v podobě síťových map (obr. 2). Síťové mapy rozdělují dané území (v našem případě Českou republiku) na síť čtverců, do kterých se zaznamenávají výskyty konkrétních druhů. Problémem je, že nemusí být nalezena všechna místa, kde se daný druh nachází a některá stanoviště s výskytem pak mohou chybět. Tudíž nám síťové mapy neposkytují úplné informace o výskytu daných druhů. Z obr. 2 je patrné, že se sova pálená vyskytuje v oblastech velkých nížin ČR (Polabská nížina, Hornomoravský úval, Dolnomoravský úval

a Dyjskosvratecký úval). Dále si můžeme všimnout mírného poklesu početnosti sovy pálené od roku 2010, přičemž výskyty od roku 1990 až 2009 jsou na mapě zaznamenány jako oranžové kruhy a výskyty od roku 2010 jsou zaznamenány jako prázdný kruh s černým ohraničením.

Dosud nebyl vytvořen prediktivní model distribuce sovy pálené pro Českou republiku, který by ukazoval potencionálně vhodná stanoviště pro tento druh. Takovýto model by mohl přispět k efektivnějšímu rozmístování hnízdních budek a možná i k nalezení nových, dosud neznámých vhodných stanovišť.

Výskyt druhu *Tyto alba* podle záznamů v ND OP



Obrázek 2: Výskyt druhu *Tyto alba* podle záznamu v ND OP. Zdroj: AOPK ČR, 2022b. Nálezová databáze ochrany přírody. Retrieved April 7, 2022, from www.portal.nature.cz

Prediktivní model distribuce

Modely rozšíření druhů (SDM) jsou známé také pod názvy modelování habitatu či modelování environmentálních/ekologických nik (ENM). Cílem SDM je vytvoření prostorové předpovědi potencionálně vhodných stanovišť pro konkrétní druhy organismů (Guisan a Thuiller 2005; Elith a Leathwick 2009; Franklin 2010; Hijmans a Elith 2021). Běžně se k předpovědi areálu druhů využívají environmentální údaje, které slouží jako prediktory (Hijmans a Elith 2021). Tyto modely jsou potřebné k řešení mnoha

ekologických otázek, používají se v oblastech ochrany a řízení managementů. Mohou přispět v hodnocení biologické rozmanitosti, navrhování rezervací, správě a obnově stanovišť, plánování ochrany druhů a stanovišť a předpovídání účinků změn životního prostředí na druhy a ekosystémy (Guisan a Thuiller 2005; Elith et al. 2006; Franklin 2010).

SDM mohou dobře charakterizovat přirozené rozšíření druhů, jestliže máme k dispozici kvalitní data z výzkumu a prediktory prostředí jsou vhodné pro specifikovaný model (Elith a Leathwick 2009).

Modelovací metody

Rozlišujeme dva základní přístupy modelování podle typu použitých dat. První přístup používá „presence-only“ data, která poskytují pouze údaje o přítomnosti druhů na lokalitách a nezohledňují místa, kde se daný druh nevyskytuje. Tento přístup je typický například pro algoritmy: Bioclim, Domain, Lives a další. Druhý přístup využívá „presence-absence“ data, která poskytují údaje o „přítomnosti“ i „nepřítomnosti“ druhů na daném území. Tento přístup je typický pro generalizované lineární modely (GLM), generalizované aditivní modely (GAM), model maximální entropie neboli míry neuspořádanosti (Maxent) a další. Protože údaje o nepřítomnosti druhů na lokalitách nejsou ve většině případů k dispozici a mnoho metod je pro svou konstrukci vyžaduje, existuje způsob, jak je nahradit. Poslouží nám k tomu údaje o pozadí neboli „pseudoabsence“, které jsou vytvořeny vygenerováním náhodného vzorku (Elith et al. 2006; Zurell 2020; Hijmans a Elith 2021). Tento přístup je typický pro metodu Maxent.

Modelovací metody můžeme dále rozdělit na parametrické, které předpokládají splnění konkrétních podmínek (např. nastavení prahové hodnoty) a neparametrické, které žádné podmínky splňovat nemusí (Hartmannová 2016).

Při modelování distribuce druhů se používají různé typy algoritmů. Dělíme je na "profilové", "regresní" a "metody strojového učení". Profilové metody zohledňují pouze údaje o přítomnosti, nikoli údaje o nepřítomnosti nebo náhodné body pozadí. Regresní metody a metody strojového učení používají jak údaje o přítomnosti, tak údaje o nepřítomnosti nebo pozadí (Hijmans a Elith 2021). Regresní modely potřebují alespoň 100 záznamů o výskytu, aby predikce byla úspěšná, kdežto modelům strojového učení postačí k úspěšnosti 10 záznamů o výskytu druhů (Hartmannová 2016). K metodám, které využívají strojové učení, patří Maxent.

Maxent

Mezi metody strojového učení patří např.: neuronové sítě (ANN), náhodné lesy (RF), model maximální entropie (Maxent) a další (Hijmans a Elith 2021). Model Maxent, který byl použit v této práci, je algoritmus, který k modelování distribuce druhů používá přesné matematické formulace. Obsahuje řadu aspektů, které jej činí vhodný pro modelování rozšíření druhů (Elith et al. 2006; Phillips et al. 2006; Hartmannová 2016). Na základě tohoto algoritmu se odhaduje cílová distribuce tím, že se nalezne distribuce maximální entropie (blíží se uniformnímu rozdělení). Tato distribuce je omezena tím, že očekávaná hodnota každého faktoru prostředí odpovídá jeho empirickému průměru (Phillips et al. 2006). Maxent je buď k dispozici jako samostatný program Maxent (https://biodiversityinformatics.amnh.org/open_source/maxent/) v jazyce Java, nebo jej můžeme použít v rámci programu *R* prostřednictvím balíčku *dismo*. V něm se nachází funkce `maxent`, která používá shodný algoritmus jako výše uvedený originální program Maxent (Hijmans a Elith 2021).

Klíčové kroky modelování

Ke konstrukci SDM je nezbytné nejdříve shromáždit dostatečný počet záznamů o výskytu studovaného druhu, tj. data o přítomnosti na určité lokalitě. Každý záznam výskytu druhu se skládá ze zeměpisné šířky a délky. Takové záznamy označujeme jako georeferencované (Phillips et al. 2006). Je zvláště důležité, aby údaje o výskytu druhů adekvátně reprezentovaly skutečné rozšíření studovaných druhů. Druh by měl být správně identifikován, zeměpisné souřadnice dostatečně přesné a vzorek by měl být nezkreslený nebo doplněný informacemi o známých zkreslení (Elith a Leathwick 2009; Zurell 2020; Hijmans a Elith 2021). Souřadnice výskytu druhů získáme terénním mapováním, z muzeí či herbárií nebo z on-line zdrojů, jako jsou databáze GBIF, OBIS, IUCN, Nature Serve a Movebank (Zurell 2020).

Z prostorových databází získáme hodnoty environmentálních predikčních proměnných (např. klimatu) v lokalitách výskytů (Elith a Leathwick 2009; Zurell 2020; Hijmans a Elith 2021). Informace o klimatu nalezneme na online úložišti jako je WorldClim nebo CHELSA. Zde nalezneme také informace o nadmořské výšce. Informace o krajinném pokryvu a dalších produktech dálkového průzkumu Země nalezneme na stránkách Copernicus (Zurell 2020). Velmi důležité je, aby takto získaná data měla shodné rozlišení.

Poté můžeme vztáhnout jednotlivá pozorování druhů (data o přítomnosti) k převládajícím podmínkám prostředí (environmentálním prediktorům) na těchto místech. K tomu jsou nám k dispozici různé modelovací algoritmy (Zurell 2020; Hijmans a Elith 2021). V dalším kroku se vypořádáme s korelovanými predikčními proměnnými (Elith a Leathwick 2009). Nakonec na základě nejlepšího odhadnutého modelu vytvoříme predikci pravděpodobnosti výskytu pro celé studované území (Zurell 2020; Hijmans a Elith 2021).

Hodnocení kvality modelu

K hodnocení modelů se používají statistiky plocha pod křivkou (AUC) a korelace (COR) (Elith et al. 2006). AUC slouží k hodnocení rozdílu mezi modelovanou distribucí a distribucí náhodnou (Hartmannová 2016). Hodnota AUC se pohybuje v rozmezí od 0 do 1. Model je lepší než náhodný odhad distribuce, pokud je hodnota AUC větší než 0,5. Hodnoty menší než 0,5 naznačují, že jde o model nízké kvality, který je dokonce horší než náhodný odhad distribuce (Elith et al. 2006; Hijmans a Elith 2021). COR slouží k testování asociace mezi párovými vzorky (pro presence–absence data), lze ji vypočítat jako Pearsonův korelační koeficient (Elith et al. 2006).

Většina modelářů se spoléhá na kontrolu pomocí křížové validace. Ta se provádí rozdělením souboru dat na tréninkovou a testovací sadu. Běžně jsou trénovací a testovací data vytvářena náhodným vzorkováním (bez nahrazování) z jediné datové sady. V programu *R* se křížová validace modelu provádí pomocí funkce `evaluate` z balíčku `dismo`, k použití této funkce potřebujeme jak údaje o přítomnosti, tak údaje o nepřítomnosti/pseudoabsenci (Hijmans a Elith 2021).

Cíle práce

V České republice zatím nebyl vytvořen kvantitativní prediktivní model rozšíření sovy pálené. Cílem mé bakalářské práce je proto vytvořit takový model rozšíření na základě dat o budkové populaci sovy pálené a přispět tak k povědomí o lokalitách, které jsou svými podmínkami vhodné pro hnízdění tohoto druhu. Uvedený model by proto měl přispět k lepší ochraně daného druhu a současně poukázat na místa, kde by se mohly potenciálně rozmístit další hnízdní budky, které jsou pro tento druh velmi efektivním ochranným opatřením

Materiál a metody

Příprava dat

Jako zdroj dat o jednotlivých výskytech sovy pálené v České republice (data přítomnosti) jsme použili zeměpisné souřadnice obsazených hnízdních budek z výzkumu od Karla Popracha provedeného v letech 1998–2013 (Poprach 2013, Pavlůvčík et al. 2015). Tyto záznamy dokládají nejen výskyt, ale také reprodukci daného druhu. Data z výzkumu byla nadále zpracována jako textový dokument, aby se dala využít programem *R* (R Core Team 2021). Dále byl zpracován textový dokument, který obsahoval souřadnice velkých měst ČR a složitější soubory shapefile zahrnující informace o tocích, okresech a hranicích ČR.

Konstrukce modelu

Model jsme vytvořili v programu *R* a použili metodu, která využívá „presence–absence“ data (příloha A). Aby model fungoval jak má, museli jsme přinstalovat verzi Javy z 32bitové na 64bitovou Javu, která odpovídá verzi *R*, která byla použita. Pro konstrukci modelu bylo třeba nainstalovat balíčky `rgdal`, `raster`, `dismo`, `rgeos` a `prettymapr` pomocí funkce `install.packages`. Následně jsme nainstalované balíčky načítali do programu *R* pomocí funkce `library`. Pomocí funkce `read.table`, která slouží ke čtení záznamů, které jsou uvedeny v textovém souboru, jsme do programu *R* načítali textový soubor se souřadnicemi výskytů sovy pálené na území ČR a soubor se souřadnicemi velkých měst ČR. Ke čtení jednotlivých souborů ve formátu shapefile jsme použili funkci `readOGR`, která načte zdroj dat a vrstvu OGR do vhodného prostorového vektorového objektu. V našem případě nesou soubory shapefile informace o tocích, okresech a hranicích ČR. Následně bylo potřeba vymezit hranice ČR. To jsme provedli funkcí `extent`, kde jsme nastavili nejsevernější ($51^{\circ} 03' \text{ s. š.}$), nejnižnější ($48^{\circ} 33' \text{ s. š.}$), nejvýchodnější ($18^{\circ} 52' \text{ v. d.}$) a nejzápadnější bod ($12^{\circ} 06' \text{ v. d.}$) ČR.

Jako zdroj environmentálních proměnných nám posloužilo online úložiště WordClim verze 2.1 (WorldClim 2020), odkud bylo staženo celkem 19 klimatických proměnných (tab. 3). Data byla stažena jako rastrový objekt v nejvyšším rozlišení prostřednictvím funkce `getData`, která je součástí balíčku `raster` v programu *R*. Tento rastrový objekt bylo třeba oříznout na velikost ČR pomocí funkce `crop`.

Tabulka 3: Klimatické proměnné z online úložiště WorldClim. Zdroj: *WorldClim*. 2020. Retrieved February 7, 2022, from worldclim.org.

Název klimatické proměnné	Význam
BIO1	Průměrná roční teplota
BIO2	Průměrný denní rozsah (průměr měsíčních (max. teplota - min. teplota))
BIO3	Izotermnost (BIO2/BIO7) ($\times 100$)
BIO4	Sezónnost teploty (směrodatná odchylka $\times 100$)
BIO5	Maximální teplota nejteplejšího měsíce
BIO6	Minimální teplota nejchladnějšího měsíce
BIO7	Roční rozsah teplot (BIO5–BIO6)
BIO8	Průměrná teplota nejvlhčího čtvrtletí
BIO9	Průměrná teplota nejsuššího čtvrtletí
BIO10	Průměrná teplota nejteplejšího čtvrtletí
BIO11	Průměrná teplota nejchladnějšího čtvrtletí
BIO12	Roční úhrn srážek
BIO13	Srážky v nejvlhčím měsíci
BIO14	Srážky nejsuššího měsíce
BIO15	Sezónnost srážek (variační koeficient)
BIO16	Srážky v nejvlhčím čtvrtletí
BIO17	Srážky v nejsušším čtvrtletí
BIO18	Srážky v nejteplejším čtvrtletí
BIO19	Srážky v nejchladnějším čtvrtletí

Data o nadmořské výšce České republiky byla rovněž stažena z webu WorldClim 2.1 a jsou odvozena z mezinárodního výzkumného programu SRTM (SRTM Data 2022). SRTM obsahuje nejúplnější digitální model reliéfu Země s nejvyšším rozlišením 1 úhlové vteřiny neboli asi 30 m (Farr et al. 2007). Tento program rozděluje celý svět na síť čtverců s údaji o nadmořské výšce. Jelikož se ČR nachází na rozhraní čtyř čtverců v databázi SRTM, bylo potřeba stáhnout informace ze čtyř čtverců, pomocí funkce `getData` a následně tyto informace sloučit v programu *R* pomocí funkce `merge`. Jelikož se rozlišení lišilo, v případě klimatických proměnných odpovídalo 1000×1000 m a v případě nadmořské výšky 90×90 m, použili jsme funkci `disaggregate` na klimatické proměnné a rozlišení dat rozdělili 10krát. V dalším kroku jsme použili funkci `crop` a vymezili tak, aby se nadmořské výšky načítaly pouze na území ČR. Následně jsme tuto vrstvu přidali k již existujícímu rastrovému objektu pro klimatické proměnné pomocí funkce `addLayer`.

Dále bylo třeba doplnit údaje o nepřítomnosti. V programu *R* je možné generovat náhodné body a získat „pseudoabsence“ neboli údaje o pozadí. Tato čísla jsou generována pomocí algoritmu, který k inicializaci vyžaduje nastavení seed. Být pseudonáhodný místo čistě náhodný znamená, že pokud známe seed a generátor, můžeme předvídat a reprodukovat výstup. Použili jsme tedy funkci `set.seed` a nastavili seed na 1. Při použití této funkce program *R* standardně používá generátor Mersenne-Twister (Soage 2022). Tento krok jsme dokončili funkcí `sampleRandom` a získali 10000 náhodných bodů (bez náhrady).

Pro kontrolu jsme postupně zobrazili některé vrstvy mapy prostřednictvím funkce `plot`. Nejprve jsme načítli vrstvu prediktorů, která se skládala z klimatických proměnných a nadmořské výšky, poté vektor jednotlivých výskytů sovy pálené na území ČR, kde se každý výskyt označil černým křížkem a hranice ČR. Je nutné podotknout, že prediktory a výskyty se k sobě zatím nevztahovaly.

Abychom mohli hodnotit přesnost modelu, tak jsme náhodně rozdělili data s jednotlivými výskyty na trénovací a testovací sadu. Nejprve jsme nastavili seed na 1, abychom mohli reprodukovat výstup, a následně jsme náhodně vybrali 50 % vzorků pro trénovací sadu. Pro výběr náhodného vzorku jsme použili funkci `sample`. Zbytek dat jsme označili jako testovací sadu. V dalším kroku jsme vztáhli environmentální podmínky jak na trénovací a testovací sadu dat, tak na body pozadí pomocí funkce `extract`.

Dále jsme nastavili, aby číslo 1 bylo indikátorem přítomnosti a číslo 0 indikátorem nepřítomnosti. Funkce `c` kombinuje tyto jedničky a nuly do nového vektoru, který může být přidán do datového rámce tabulky `Maxent` pomocí environmentálních atributů přítomnosti a nepřítomnosti na konkrétním místě. Posléze byl funkcí `maxent` (verze 3.4.1) vytvořen model SDM. Model jsme zobrazili pomocí funkce `predict(mod, predictors)` a jednotlivé vrstvy mapy načítli pomocí funkce `plot`. Nejprve byla načtena vrstva s pravděpodobnostmi výskytů sovy pálené na konkrétních území, následně hranice ČR, toky a jednotlivá města. Následně jsme do mapy přidali kompas pomocí funkce `addnortharrow` a měřítko funkcí `addscalebar`.

Hodnocení výkonnosti modelu jsme provedli křížovou validací modelu pomocí funkce `evaluate` z balíčku `dismo`. Funkcí `print` jsme zobrazili hodnotící statistiky jako je hodnota AUC a korelační koeficient.

Data o hnízdění sovy pálené pochází z let 1998 až 2013 a zahrnují pouze obsazené hnízdní budky. V obsazenosti budek byly velké rozdíly. Některé byly obsazeny pravidelně, jiné pouze jednou. Proto jsme se rozhodli, že k vytvoření modelů použijeme jak kompletní data (některé budky se opakují vícekrát), tak data zbavená duplikovaných řádků, v nichž se každá hnízdní budka vyskytuje pouze jednou. U každého souboru jsme se rozhodli vytvořit model rozšíření pro všechny environmentální proměnné a pro redukovaný model, v němž byly vypuštěny proměnné s malým významem. Byly proto sestaveny celkem čtyři výsledné mapy na základě dvou metod. První metoda se týká dat se souřadnicemi hnízd sovy pálené na území ČR a rozděluje je na data, kde je použita jen jedna souřadnice pro každé hnízdo, tzn. že byla odstraněna duplikovaná hnízdění v budkách v průběhu let výzkumu a na data, kde se používají opakovaně všechny souřadnice hnízd ve vzorku. Druhá metoda se týká klimatických proměnných a rozděluje je na data, kde se buď využívají všechny proměnné, a nebo jsou proměnné bez významu či s minimálním významem odstraněny. Výsledné čtyři mapy jsou kombinací těchto metod.

Výsledky

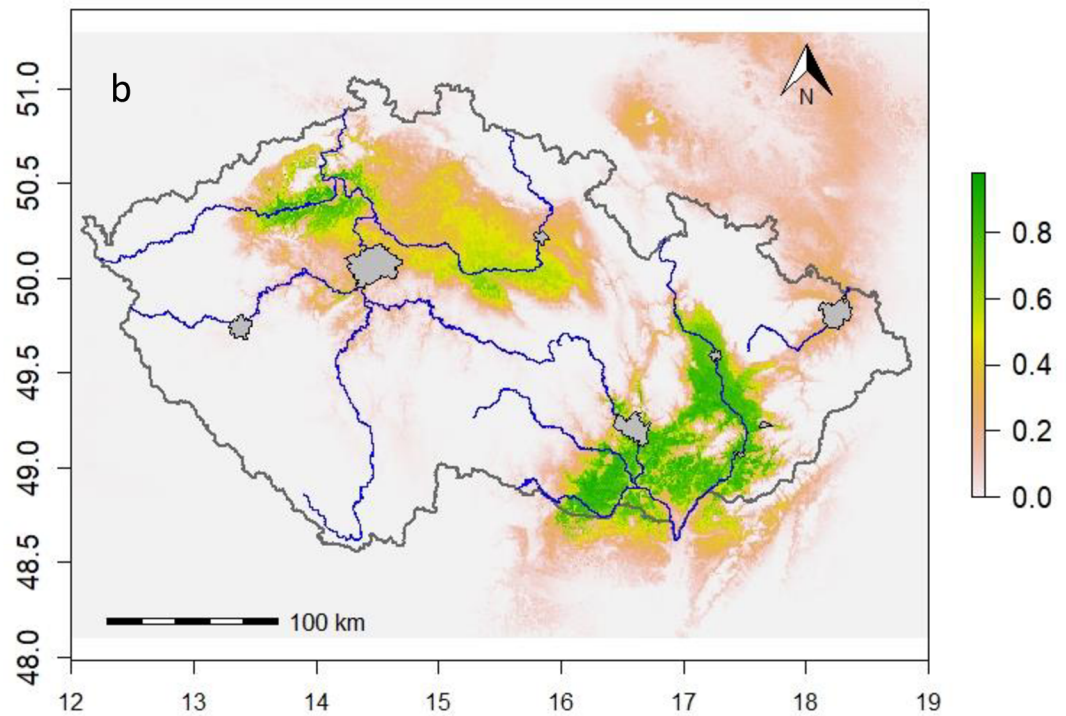
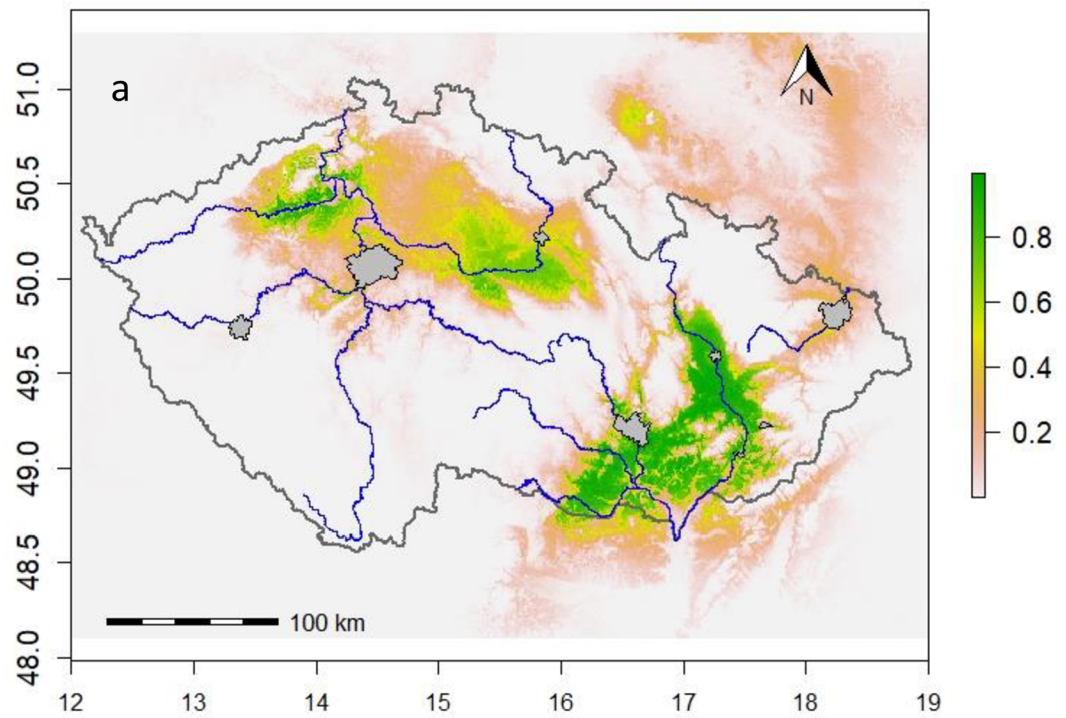
Prvním výstupem je mapa (obr. 3a), kde byla použita jen jedna souřadnice pro každé hnízdo a zároveň jsou použity všechny klimatické proměnné. Tato mapa je založena na 244 bodech přítomnosti a na 10 000 bodech pseudoabsencí. Hodnotící statistika AUC ukazuje vysokou hodnotu 0,947. Ta nám říká, že model je velmi dobrý.

Druhým výstupem je mapa (obr. 3b), kde se používají opakovaně všechny souřadnice hnízd ve vzorku a zároveň jsou použity všechny klimatické proměnné. Tato mapa je založena na 1 284 bodech přítomnosti a na 10 000 bodech pseudoabsencí. Hodnotící statistika AUC ukazuje vysokou hodnotu 0,915.

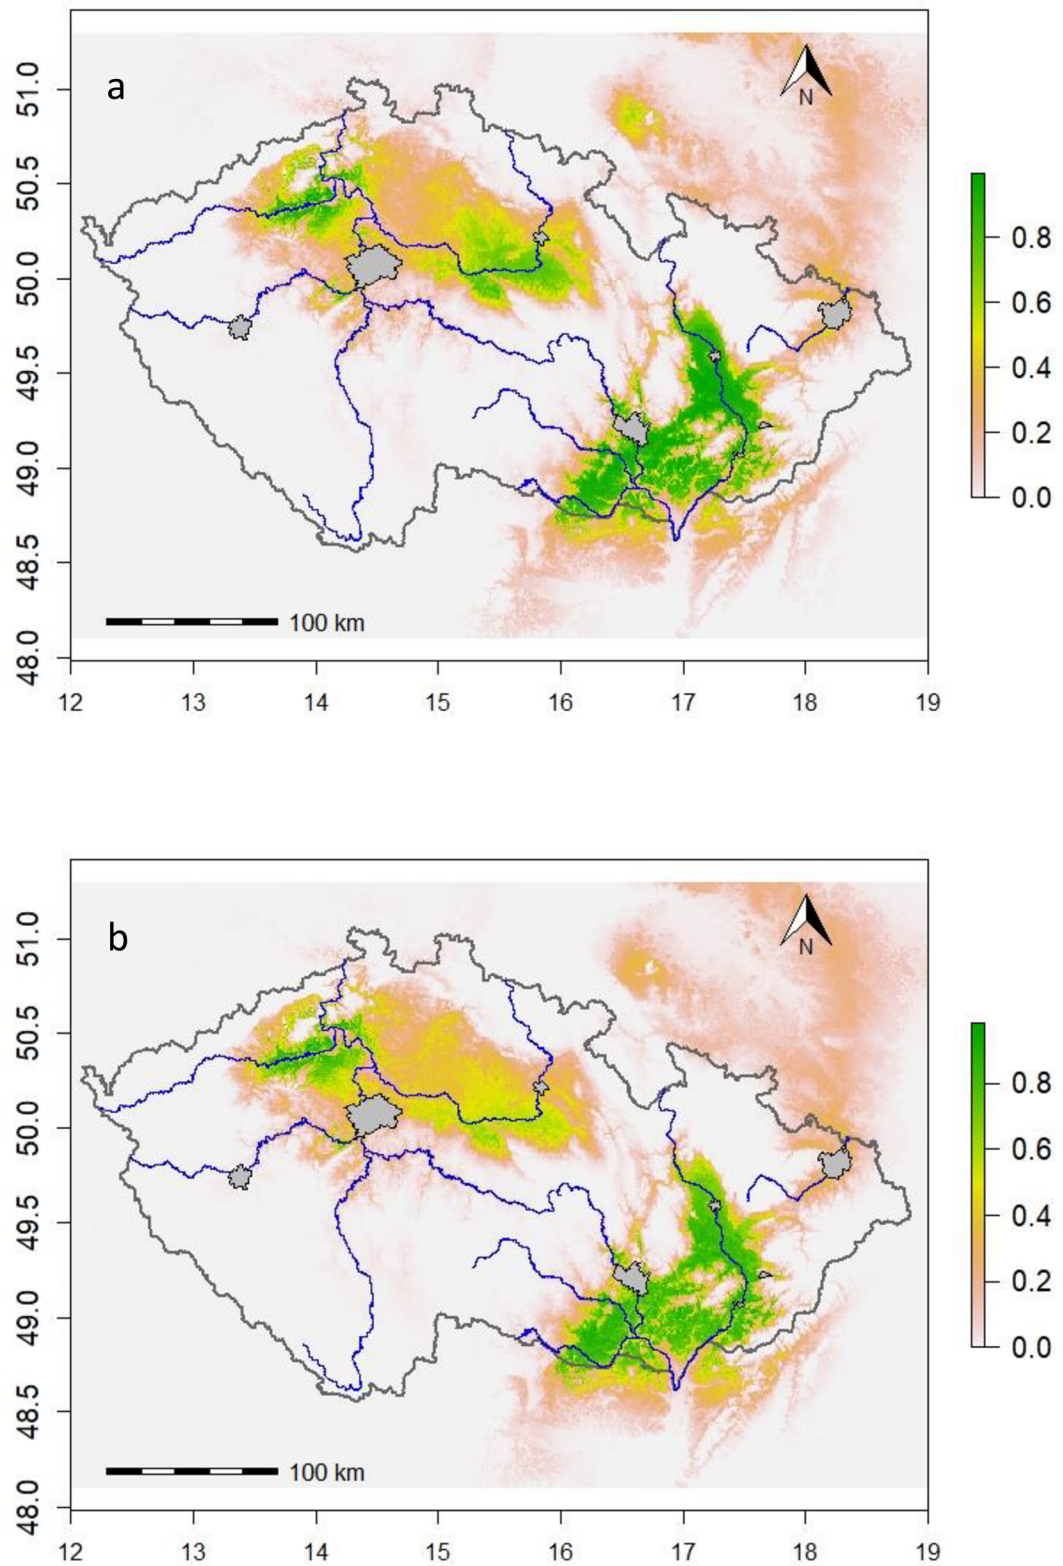
Jakmile jsme vytvořili mapu vhodných stanovišť pro sovu pálenou, bylo třeba zhodnotit, které proměnné hrají významnou roli pro hnízdění a které jsou naopak bez významu. To jsme provedli tím způsobem, že jsme zhodnotili procentuální příspěvek jednotlivých proměnných (hodnoty jsme získali v rámci funkce `maxent`, při interpretaci výsledků). Proměnné bez významu nebo s minimálním významem pro hnízdění byly odstraněny.

Třetím výstupem je mapa (obr. 4a), kde byla každé hnízdo zastoupeno jen jednou a počet klimatických prediktorů byl redukován jen na proměnné, které vykazovaly aspoň nějaký vliv. Bylo tak vyřazeno celkem 7 následujících prediktorů: bio8, bio9, bio10, bio11, bio13, bio14 a bio18. Tato mapa je založena na 244 bodech přítomnosti a na 10 000 bodech pseudoabsencí. Hodnotící statistika AUC ukazuje vysokou hodnotu 0,947. Ta nám říká, že model je velmi dobrý.

Čtvrtým výstupem je mapa (obr. 4b), kde byly opakovaně použity všechny souřadnice hnízd ve vzorku a klimatické proměnné bez významu nebo s minimálním významem pro hnízdění byly odstraněny. Šlo o stejné klimatické proměnné, jakojsou ty uvedené výše: bio8, bio9, bio10, bio11, bio13, bio14 a bio18. Tato mapa je založena na 1 284 bodech přítomnosti a na 10 000 bodech pseudoabsencí. Hodnotící statistika AUC ukazuje vysokou hodnotu 0,915.



Obrázek 3: Mapa potenciálního výskytu sovy pálené v ČR. (a) Každé hnízdo bylo v datovém vzorku zastoupeno pouze jednou bez ohledu na počet hnízdění ve sledované periodě. (b) Každé hnízdo je ve vzorku zastoupeno tolikrát, kolikrát zde proběhlo rozmnožování.



Obrázek 4: Mapa potenciálního výskytu sovy pálené v ČR. (a) Každé hnízdo je zastoupeno pouze jednou a počet prediktorů je redukován o 7 nevýznamných proměnných. (b) Hnízda jsou ve vzorku zastoupena podle počtu hnízdění a počet prediktorů je redukován o 7 nevýznamných proměnných.

V jednotlivých výstupech se nacházejí drobné rozdíly, v závislosti na množství vstupních dat. Modely, kde bylo použito větší množství souřadnic hnízd (obr. 3b a 4b) jsou oproti modelům s menším množstvím souřadnic (obr. 3a a 4a) více zdůrazňují polabské populace. Tento rozdíl je dobře pozorovatelný v oblastech okolo Kolína, Pardubic a Hradce Králové, kde pravděpodobnost hnízdění na obr. 3b a 4b dosahuje okolo 50 % (v některých místech až 70 %). Oproti tomu obr. 3a a 4a ukazují na těchto místech pravděpodobnost vyšší než 80 %. Dále obr. 3a a 4a. ukazuje, že se pravděpodobnost hnízdění rozšiřuje od Mostecké pánve směrem na Prahu, oproti obr. 3b a 4b. Oblast jižní Moravy nevykazuje žádné rozdíly mezi modely.

Když porovnáme výsledné mapy, kde bylo použito menší množství souřadnic hnízd (obr. 3a a 4a), tak zjistíme, že jsou téměř totožné. Nepatrný rozdíl nalezneme na mapce, u které bylo odstraněno celkem 7 environmentálních proměnných (obr. 4a), pravděpodobnost hnízdění se zde mírně rozrůstá od Mostecké pánve směrem na Prahu.

Nakonec porovnáme obr 3b. a 4b, které reprezentují výsledné mapy, kde bylo použito větší množství souřadnic hnízd. Opět se mezi mapkami vyskytuje pouze nepatrný rozdíl, kdy se pravděpodobnost hnízdění rozrůstá na obr. 3b severně od Kolína oproti 4b.

Diskuze

Dosud nebyla vytvořena mapa, která by ukazovala pravděpodobnost hnízdění sovy pálené na území ČR. Existují sice záznamy o jejím výskytu na našem území, ovšem v podobě síťových map (Šťastný et al. 2006, Poprach 2015, Poprach et al. 2017, Šťastný a Krištín 2021, AOPK ČR 2022b), u kterých není možné kompletně zaznamenat všechna data. Proto jsem se v této práci věnovala vytvoření prediktivního modelu distribuce sovy pálené pomocí metody Maxent.

Dle vytvořeného prediktivního modelu se nachází vhodná místa pro hnízdění sovy pálené převážně v okolí velkých nížin ČR, jako jsou Dyjskosvratecký úval, Dolnomoravský úval, Hornomoravský úval a oblast Polabské nížiny. Tyto nížiny se vyskytují podél vodních toků Dyje, Svratky, Jihlavy, Moravy, Labe a Ohře. Prediktivní model dále ukazuje velmi malou či dokonce žádnou pravděpodobnost výskytu sovy v jihozápadní části ČR. Ovšem některé síťové mapy uvádí výskyt sovy pálené i v těchto místech, např. v oblasti Plzně (Šťastný et al. 2006, Poprach 2009) a Českých Budějovic (Šťastný a Krištín 2021, AOPK ČR 2022b), takže se může jednat o nedokonalost modelu, kterou mohlo způsobit nedostatečné množství vstupních dat (data o přítomnosti druhu). Naše vstupní data skutečně obsahují velmi malý počet záznamů, kdy by sova obsadila budky v jihozápadní části ČR, ale je nutné podotknout, že i zde byly budky umístěny a kontrovány. Tento faktor může souviset s nadmořskou výškou, která je jednou z environmentálních proměnných, které sehrály v pravděpodobnosti hnízdění velkou roli. Jiné studie uvádí (a potvrzují výsledky našeho modelu), že sova pálená zcela chybí v pahorkatinách jižních Čech nebo zde hnízdí pouze výjimečně (Poprach 2001, Hudec et al. 2005). Zajímavé je, že tomu tak nebylo vždy, protože v 70. letech 20. století hnízdila i v Krkonoších nebo na Šumavě do nadmořské výšky 800 m. n. m. (Šťastný et al. 2006, Šťastný a Krištín 2021).

Environmentální proměnné

Sova pálená obývá převážně nížinné oblasti (Poprach 2009, 2015, Šťastný a Krištín 2021) a preferuje nadmořskou výšku do 250 m. n. m. (Poprach 2001). Naš model ukazuje největší pravděpodobnost hnízdění (> 60 %) v nadmořských výškách 200–300 m. n. m., přičemž v nadmořské výšce 240 m. n. m. je pravděpodobnost hnízdění okolo 70 %. Se vzrůstající nadmořskou výškou pravděpodobnost hnízdění zprudka klesá (ve výšce 400 m. n. m. je pravděpodobnost hnízdění okolo 40 % a ve výšce 800 m. n. m. < 10 %).

V jihozápadní části ČR už se vyskytují pahorkatiny, vrchoviny a hornatiny, kde nadmořská výška kolísá mezi 300–1378 m. n. m. Model v těchto místech ukazuje nízkou či dokonce žádnou pravděpodobnost výskytu. Pravděpodobnost výskytu klesá u našeho modelu i v nižších polohách, než je 200 m. n. m. To je dáno skutečností, že míst s nižší nadmořskou výškou není v ČR mnoho (Poprach 2001).

Dalším velmi významným ukazatelem pravděpodobnosti hnízdění jsou srážky. Podle našeho modelu mají významnou roli proměnné „bio17“, „bio15“ a „bio19“. Průměrný roční úhrn srážek v ČR je 684 mm (ČHMÚ 2021). Nejsušší oblasti se nachází v nížinách na jižní Moravě, v Polabí a dolním Poohří. K místům, kde byly naměřeny nejnižší průměrné hodnoty srážek za rok (méně než 445 mm) patří především Mostecká pánev a Žatecko, které leží ve srážkovém stínu Krušných hor a také Praha (Quitt 1971, Rožnovský et al. 2020). Naopak nejvyšší úhrny srážek za rok nalezneme v horských oblastech, nejvíce na severu (Střešník et al. 2014, Rožnovský et al. 2020).

Srážky v nejsušším čtvrtletí („bio17“) představují součet úhrnů srážek během tří nejsušších měsíců v roce. V roce 2021 se jednalo o měsíce únor, březen, duben. Model ukazuje největší pravděpodobnost hnízdění tam, kde bylo v součtu naměřeno 70–80 mm srážek (pravděpodobnost hnízdění > 80 %), přičemž při množství srážek < 70 mm mírně poklesla pravděpodobnost hnízdění (> 70 %). V porovnání s daty z ČHMÚ, který obsahuje údaje o dlouhodobém měsíčním úhrnu srážek z let 1981–2010 byly tyto podmínky naměřeny v klimatologických stanicích v Polabí (stanice Doksany a Praha), na střední Moravě (stanice Olomouc) a na jižní Moravě (stanice Brno a Kuchařovice). Vyšší úhrny srážek (100–130 mm) byly naměřeny např. na stanicích v Ústí nad Labem, Strážnici, Hradci Králové, Českých Budějovicích, Semčicích a v Holešově (ČHMÚ 2021). V těchto místech poklesla pravděpodobnost hnízdění na 50–30 %. Místa s větším úhrnem srážek než 150 mm mají pravděpodobnost hnízdění < 10 %.

Proměnná „bio15“ neboli sezónnost srážek, představuje míru variability měsíčních úhrnů srážek v průběhu roku. Vypočítá se jako variační koeficient, který vyjadřuje, kolik procent průměru představuje směrodatná odchylka. Model ukazuje největší pravděpodobnost (>60 %) tehdy, když variabilita měsíčních úhrnů srážek dosahuje 35–50 %, přičemž variabilita 45 % má pravděpodobnost hnízdění >70 %. U variability srážek 25 % poklesla pravděpodobnost hnízdění na pouhých 10 %. Když variabilita srážek překročí 50 %, tak se pravděpodobnost hnízdění stabilně drží na 45 %.

Srážky v nejchladnějším čtvrtletí („bio19“) představují součet úhrnu srážek za zimní měsíce. Model ukazuje největší pravděpodobnost výskytu (> 80 %) na místech, kde v průměru spadne < 50–60 mm srážek. Se vzrůstajícím množstvím srážek pravděpodobnost výskytu pozvolna klesá. Při větším množství srážek než 130 mm je pravděpodobnost hnízdění < 50 %. V porovnání s daty z ČHMÚ, který obsahuje údaje o dlouhodobém měsíčním úhrnu srážek z let 1981–2010 byly nejvhodnější podmínky shodné s místy jako u proměnné „bio17“. Dle měsíčních záznamů z roku 2021 byly nejmenší úhrny srážek v zimních měsících naměřeny v okresech: Louny, Rakovník, Opava, Bruntál, Znojmo, Břeclav a Český Krumlov (ČHMÚ 2021). Model poukazuje na to, že sova preferuje nejsušší místa ČR a to především v zimních měsících. V nejsušších měsících preferuje místa suchá, kde spadne okolo 70–80 mm srážek. Je dokázáno, že vysoké množství srážek má negativní vliv na potravní nabídku a znesnadňuje podmínky lovu. Vysoká vlhkost v hnízdě zvyšuje riziko parazitárních infekcí (Heeb et al. 2000).

Významnou environmentální proměnnou je i teplota. Důležité proměnné jsou především „bio4“, „bio1“, „bio5“ a „bio6“. Obecně lze říci, že průměrná měsíční teplota klesá od jihu k severu (s výjimkou ledna a prosince) a s rostoucí nadmořskou výškou. Průměrná roční teplota na území ČR odpovídá 8,3 °C (ČHMÚ 2021). Většina území ČR se nachází v mírně teplé oblasti, kde se průměrná červencová teplota vzduchu pohybuje okolo 16–18 °C (Quitt, 1971) a průměrná roční teplota odpovídá 7–8 °C. V teplých oblastech, mezi něž patří jižní Morava a nejteplejší části Polabí (především Praha, díky tepelnému ostrovu města), odpovídá průměrná červencová teplota 18–20 °C (Quitt, 1971). Průměrná roční teplota se zde pohybuje okolo 10 °C (ČHMÚ 2021). Náš model ukazuje největší pravděpodobnost hnízdění v teplých oblastech ČR. Ty se mimo jiné nachází do nadmořské výšky 300 m. n. m., což je sovou preferované území. K teplejším místům ČR ovšem patří i Plzeň, České Budějovice a Ostravsko. Tyto místa model hodnotí jako pravděpodobné méně než 40 % (v Českých Budějovicích je pravděpodobnost téměř žádná).

Proměnná „bio4“ představuje sezónnost teploty. Vypočítá se jako směrodatná odchylka z 12 průměrných měsíčních hodnot teploty $\times 100$. Model ukazuje největší pravděpodobnost výskytu (> 80 %) tehdy, když „bio4“ odpovídá 7,2 °C.

Proměnná „bio1“ představuje průměrnou roční teplotu. Dle hodnot, které nám model předpověděl, se sova vyskytuje nejpočetněji v místech, kde průměrná roční teplota dosahuje 10 °C, tj. v teplých oblastech ČR.

Proměnná „bio5“ ukazuje největší pravděpodobnost tehdy, když je maximální hodnota nejteplejšího měsíce rovna 25 °C. Oproti tomu proměnná „bio6“, která představuje minimální teplotu nejchladnějšího měsíce, ukazuje nejvyšší pravděpodobnost hnízdění v místech do teploty -5 °C, s dalším ochlazením klesá pravděpodobnost výskytu. Sova pálená není dobře přizpůsobená na chladné podnebí a není schopná snášet tuhé zimy, zejména kvůli nedostatečné schopnosti hromadit zásobní tuk a peří, které má nižší izolační schopnosti, než je tomu u většiny druhů sov (Šťastný et al. 2006, Poprach 2009).

Drobné rozdíly v jednotlivých výstupech se vyskytují i mezi hodnotami environmentálních proměnných, např. u proměnných „bio1“ a „bio19“. Tyto proměnné jsou u výstupu s menším množstvím dat (obr. 3a a 4a) interpretovány obráceně než u výstupu s větším množstvím dat (obr. 3b a 4b). V tomto případě lépe charakterizuje rozšíření model s větším množstvím vstupních dat, protože hodnoty proměnných se shodují s literaturou a dostupnými informacemi o výskytu sovy pálené.

Ze všech výsledků je zřejmé, že distribuce sovy pálené v ČR je silně determinována nadmořskou výškou, srážkami a vnější teplotou. Ačkoliv je to druh kosmopolitní obývající nejrůznější kontinenty, nežije úplně všude, ale jen tam, kde jsou naplněny její nároky na lokální podmínky prostředí. V dalším studiu by proto určitě stálo za to vedle klimatických faktorů prošetřit také vliv dalších stanovištních a krajinných faktorů, které mohou ovlivňovat její hnízdění v ČR.

Souhrn

Sova pálená patří k našim ohroženým druhům sov. Ačkoliv její rozšíření v ČR bylo studováno v mnoha předchozích pracích, prediktivní model druhové distribuce zatím prezentován nebyl. V bakalářské práci jsem se proto zaměřila na zhotovení takového modelu na základě dat ze sledované budkové populace v letech 1998–2014. S využitím modelu maximální entropie jsem v programu R (ref) sestrojila několik alternativních prediktivních modelů jejího rozšíření. Prokázala jsem následující.

- 1) Největší pravděpodobnost hnízdění sovy pálené se nachází v oblastech velkých nížin.
- 2) Přírodními podmínkami, na které je druh relativně citlivý, jsou nadmořská výška, srážky a teplota.
- 3) Obecně lze říci, že oblasti velkých nížin se vyznačují malou nadmořskou výškou (200–300 m. n. m.), nízkými úhrny srážek a vysokou teplotou (průměrná roční teplota 10 °C), což jsou hodnoty, které sova pro hnízdění preferuje.
- 4) Sova preferuje území, kde v nejsušším čtvrtletí spadne v součtu 70–80 mm srážek, v nejchladnějším čtvrtletí spadne v součtu 50–60 mm srážek a variabilita srážek je 45 %.
- 5) Na preferovaných území dosahuje teplota nejteplejšího měsíce 25 °C, teplota nejchladnějšího měsíce –5 °C a sezónnost teploty odpovídá 7,2 °C.

Z cílů, které jsem si na začátku práce vytyčila, jsem splnila cíl vytvořit prediktivní model distribuce sovy pálené na území ČR. I když vytvořený model dosahuje velké kvality podle hodnotících statistik, tak nebyla nalezena nová místa pro rozmístění hnízdních budek. Důvodem je, že ochrana sovy pálené na území ČR je velmi dobře zajištěná a hnízdní budky již pokrývají území, které model označil jako nejvhodnější.

Literatura

- AOPK ČR. 2022a. Retrieved April 15, 2022, from <https://www.ochranaprirody.cz/>
- AOPK ČR. 2022b. Nálezová databáze ochrany přírody. Retrieved April 7, 2022, from www.portal.nature.cz
- BirdLife International. 2021. *European Red List of Birds* (4 ed.). Office for Official Publications of the European Commission. <https://bookshop.europa.eu/>
- Colvin B. A. 1984. *Barn owl foraging behavior and secondary poisoning hazard from rodenticide use on farms* [dissertation]. Bowling Green State University.
- ČHMÚ. 2021. Územní srážky v roce 2021. Retrieved April 8, 2022, from www.chmi.cz
- de Bruijn O. 1994. Populační ekologie a ochrana sovy pálené *Tyto alba* v biotopech zemědělské půdy v Liemers a Achterhoek (Nizozemsko). *Ardea*, 82 (1), 1–109. http://ardea.nou.nu/ardea_search3.php?key=jaar&keyin=1994&k2=none
- Dirzo R., Young H. S., Galetti M., Ceballos G., Isaac N. J. B., Collen B. 2014. Defaunation in the Anthropocene. *SCIENCE*, 345, 401–406.
- Díaz S., Settele J., Brondízio E. S., Ngo H. T., Agard J., Arneeth A., et al. 2019. Pervasive human-driven decline of life on Earth points to the need for transformative change. *SCIENCE*, 366, 1327. <https://doi.org/10.1126/science.aax3100>
- European Environment Agency. 2004. EU birds directive: protecting Europe's biodiversity for 25 years. *The network of special protection areas*, 2–7. <https://op.europa.eu/s/v1G9>
- Elith J., Graham C. H., Anderson R. P., Dudík M., Ferrier S., Guisan A., et al. 2006. Novel methods improve prediction of species' distributions from occurrence data. *ECOGRAPHY*, 29, 129–151. <https://doi.org/10.1111/j.2006.0906-7590.04596.x>
- 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. <https://doi.org/10.1146/annurev.ecolsys.110308.120159>
- Farr T. G., Rosen P. A., Caro E., Crippen R., Duren R., Hensley S., et al. 2007. The Shuttle Radar Topography Mission. *Rev. Geophys.*, 45, RG2004. doi:10.1029/2005RG000183.
- Franklin J. 2010. *Mapping Species Distributions: Spatial Inference and Prediction*. Cambridge University Press.

- Glue D. 1992. Boxes for owls. *Birds*, 14, 35–38.
- Guisan A., Thuiller W. 2005. Predicting species distribution: offering more than simple habitat models. *Ecology letters*, 89, 993–1009.
- Haddad N. M., Brudvig L. A., Clobert J., Davies K. F., Gonzalez A., Holt R. D., et al. 2015. Habitat fragmentation and its lasting impact on Earth's ecosystems. *Science advances*, 1(2), e1500052. <https://doi.org/10.1126/sciadv.1500052>
- Longcore T., P. A. Smith. 2013. On avian mortality associated with human activities. *Avian Conservation and Ecology* 8(2), 1. <http://dx.doi.org/10.5751/ACE-00606-080201>
- Hartmannová S. 2016. *Modelování výskytu živočichů* [diplomová práce]. Univerzita Palackého.
- Heeb P, Kölliker M, Richner H. 2000. Bird-ectoparasite interactions, nest humidity and ectoparasite communities. *Ecology* 81(4), 958–968.
- Hijmans R. J., Elith J. 2021. Species distribution modeling. <https://rspsatial.org/raster/sdm/index.html>
- Hudec K., Šťastný K., Balát F., Bejček V., Bělka T., Černý V., et al. 2005. *Fauna ČR: Ptáci – Aves. Díl II/2* (2nd ed.). Academia.
- Chobot K., Němec M. (Eds.). 2017. *Červený seznam ohrožených druhů České republiky: Obratlovci* (34 ed.). AOPK ČR.
- ISOP. 2006. Retrieved December 26, 2021, from www.portal.nature.cz
- König C., Weick F. 2008. *OWLS of the World* (2nd ed.). Christopher Helm.
- Lázničková S., Láznička V. 1995. Příspěvek k ochraně sovy pálené (*Tyto alba*). *Ochrana přírody* 50(1), 62–64.
- Lewis S. L., Maslin M. A. 2015. Defining the Anthropocene. *NATURE*, 519, 171–180. <https://doi.org/10.1038/nature14258>
- Loss S. R., Will T., Marra P.P. 2015. Direct Mortality of Birds from Anthropogenic Causes. *Annual Review of Ecology, Evolution, and Systematics*, 46, 99–120.
- Myers N., Mittermeier R. A., Mittermeier C. G., da Fonseca G. A. B., Kent J. 2000. Biodiversity hotspots for conservation priorities. *NATURE*, 403, 853–858. www.nature.com
- Pavluvčík P., Poprach K., Machar I., Losík J., Gouveia A., Tkadlec E. 2015. Barn Owl Productivity Response to Variability of Vole Populations. *PLoS ONE*, 10(12), 1–13. <https://doi.org/10.1371/journal.pone.0145851>

- Phillips S. J., Anderson R. P., Schapired R. E. 2006. Maximum entropy modeling of species geographic distributions. *Ecological Modelling*, 190, 231–259.
- Poprach K., Krause F., Láznička V. 1996. Jak pomoci sově pálené (*Tyto alba*). *Buteo*, 8, 150–160.
- Poprach K. 1999. Hnízdní rozšíření a biologie sovy pálené (*Tyto alba*) v České republice v roce 1999: Zpráva Skupiny pro ochranu a výzkum sovy pálené v ČR. *Skupina pro ochranu a výzkum sovy pálené v České republice*, 1–6. <https://www.tyto.cz/tytoalba/titul/vysledky.htm>
- Poprach K. 2000. Hnízdní rozšíření a biologie sovy pálené (*Tyto alba*) v České republice v roce 2000: Zpráva Skupiny pro ochranu a výzkum sovy pálené v ČR. *Skupina pro ochranu a výzkum sovy pálené v České republice*, 1–5. <https://www.tyto.cz/tytoalba/titul/vysledky.htm>
- Poprach K. 2001. Závěrečná zpráva Skupiny pro ochranu a výzkum sovy pálené v ČR za rok 2001, 1–10. <https://www.tyto.cz/tytoalba/titul/vysledky.htm>
- Poprach K. 2003. Nebezpečné technické nástrahy pro sovy a další druhy ptáků: Část I. *OCHRANA PŘÍRODY*, 58(7), 210–213.
- Poprach K. 2007. Sova pálená (*Tyto alba*) v Poodří. *Poodří*. 1/2007: 9–12.
- Poprach K. 2009. Sova pálená. *Naše příroda*, 2009(5), 22–31. <http://www.nasepriroda.cz>
- Poprach K. 2013. Data TYTO ALBA: všechna známá hnízdní sovy pálené v daných oblastech a letech.
- Poprach K. 2015. Sýček obecný (*Athene noctua*) & sova pálená (*Tyto alba*): ohrožené druhy naší přírody (1st ed.). Tyto.
- Poprach K., Berka P., Buchta J., Koubek P., Krause F., Mráz J., et al. 2017. Sova pálená (*Tyto alba*). Zpravodaj SOVDS, 2(17), 28–32. http://www.sovds.info/assets/File.ashx?id_org=200105&id_dokumenty=1215
- Quitt E., Geografický ústav ČSAV (Brno). 1971. *Klimatické oblasti Československa* =: *Climatic regions of Czechoslovakia*. Brno: Geografický ústav ČSAV.
- R Core Team. 2021. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.
- Rands M. R., Adams W. M., Bennun L., Butchart S. H., Clements A., Coomes D., et al. 2010. Biodiversity conservation: challenges beyond 2010. *Science (New York, N.Y.)*, 329(5997), 1298–1303. <https://doi.org/10.1126/science.1189138>

- Roulin A. 2020. *Barn Owls: Evolution and Ecology*. Cambridge University Press. 10.1017/9781316694114
- Rožnovský J., Štreščík J., Štěpánek P., Zahradníček P. 2020. THE DYNAMICS OF ANNUAL AND SEASONAL PRECIPITATION TOTALS IN THE CZECH REPUBLIC DURING 1961–2019. *ACTA HYDROLOGICA SLOVACA*, 21(2), 197–204. <https://doi.org/10.31577/ahs-2020-0021.02.0024>
- Sala O. E., Chapin F. S., Armesto J. J., Berlow E., Bloomfield J., Dirzo R., et al. 2000. Biodiversity – Global biodiversity scenarios for the year 2100. *SCIENCE*, 287(5459), 1770–1774. www.sciencemag.org
- Soage J. C. 2022. *INTRODUCTION TO R*. R CODER. Retrieved March 15, 2022, from <https://r-coder.com/r-introduction/>
- SRTM Data*. 2022. Retrieved March 9, 2022, from <https://srtm.csi.cgiar.org/srtmdata/>
- Štreščík J., Rožnovský J., Štěpánek P., Zahradníček P., 2014. Změna ročních a sezonních srážkových úhrnů v České republice v letech 1961–2012. Sborník referátů konference „Extrémy oběhu vody v krajině“, Ed. J. Rožnovský, T. Litschmann, Mikulov, elektronická publikace, stránky nečíslovány
- Šťastný K., Bejček V. 2015. Co je nového v ornitologii Mapování hnízdního rozšíření ptáků v České republice. *Živa*, 2, 73–77. ziva.avcr.cz
- Šťastný K., Bejček V., Hudec K. 2006. *Atlas hnízdního rozšíření ptáků v České Republice 2001–2003* (1st ed.). Aventinum.
- Šťastný K., Krištín A. 2021. *Ptáci Česka a Slovenska: Ottův obrazový atlas*. Ottovo nakladatelství.
- The IUCN Red List of Threatened Species: Summary Statistics*. 2022. Retrieved January 21, 2022, from <https://www.iucnredlist.org>
- Vitousek P. M., Mooney H. A., Lubchenco J., Metillo J. M. 1997. Human Domination of Earth's Ecosystems. *SCIENCE*, 277(27), 494–499. www.sciencemag.org
- WorldClim*. 2020. Retrieved February 7, 2022, from worldclim.org.
- Zurell D. 2020. Introduction to species distribution modelling (SDM) in R. <https://damariszurell.github.io/SDM-Intro/>

Příloha A

Kód pro prediktivní model sovy pálené v ČR napsaný v programu R

```
1 ### Dvě metody.
2 ### met <- 1 použije se jen jedna souřadnice pro každé hnízdo
3 ### met <- 2 použijí se opakovaně všechny souřadnice hnízd ve vzorku
4 met <- 2
5
6 options(java.parameters = c("-Xss2560k", "-Xmx4g"))
7
8 library(rgdal)
9 library(raster)
10 library(dismo)
11 library(rgeos)
12 library(prettymapr)
13
14 tyto=read.table("tyto.txt", header=T)
15 mesta=read.table("mesta.txt", header=T)
16
17 ### reading the shapefile
18 cr<-readOGR(dsn = "C://Tyto/data", layer = "crWGS84")
19 toky<-readOGR(dsn = "C://Tyto/data", layer = "tokyWGS84")
20 okr<-readOGR(dsn = "C://Tyto/data", layer = "okWGS84")
21 ext <- extent(12,19,48.1,51.3)
22 ta = getData("worldclim", var="bio", res=0.5,lon=15,lat=49.7)
23 ta.crop <- crop(ta,ext)
24 ta.crop.d<-disaggregate(ta.crop,10)
25
26 names(ta.crop.d)<-c("bio1","bio2","bio3","bio4","bio5","bio6","bio7","bio8","bio9",
27 "bio10","bio11","bio12","bio13","bio14","bio15","bio16","bio17","bio18","bio19")
```

```

29 #elevation <- getData("alt", country = "CZE")
30 elevation1 <- getData("SRTM", lon=14,lat=51)
31 elevation2 <- getData("SRTM", lon=14,lat=48)
32 elevation3 <- getData("SRTM", lon=17,lat=51)
33 elevation4 <- getData("SRTM", lon=17,lat=48)
34 el.m <- merge(elevation1,elevation2,elevation3,elevation4)
35 el.m.crop <- crop(el.m,ext)
36 names(el.m.crop)<-"alt"
37 xmin(el.m.crop)<-ext[1]
38 xmax(el.m.crop)<-ext[2]
39 ymin(el.m.crop)<-ext[3]
40 ymax(el.m.crop)<-ext[4]
41 predictors<-addLayer(ta.crop.d,el.m.crop)
42
43
44 ### koordinaty hnizd
45 tyto.clean <- subset(tyto, (!is.na(y)) & (!is.na(x)))
46 cat(nrow(tyto) - nrow(tyto.clean), "records are removed","\n")
47
48 ### odstraneni duplikovanych radku
49 dups <- duplicated(tyto.clean[c("x","y")])
50 if (met==1) tyto.unique <- tyto.clean[!dups,]
51 if (met==2) tyto.unique <- tyto.clean
52 cat(nrow(tyto.clean) - nrow(tyto.unique), "records are removed","\n")
53
54 tyto.unique.ol<-subset(tyto.unique,x>ext[1] & x<ext[2])
55 tyto.unique.ol1<-subset(tyto.unique.ol,y>ext[3] & y<ext[4])
56 #presvals = extract(predictors,dc.dupl.ol1)
57 coordinates(tyto.unique.ol1) <- ~x + y

59 ### Random points
60 set.seed(1)
61 bg <- sampleRandom(x=predictors,
62                   size=10000,
63                   na.rm=T, #removes the 'Not Applicable' points
64                   sp=T) # return spatial points
65
66 windows(10,8)
67 plot(predictors[[1]])
68 # add the background points to the plotted raster
69 #plot(bg,add=T)
70 # add the occurrence data to the plotted raster
71 plot(tyto.unique.ol1,add=T,col="black")
72 plot(cr,add=T, border="grey40", lwd=2)
73
74 ### Split occurrence data into training & testing
75 set.seed(1)
76
77 # randomly select 50% for training
78 selected <- sample(1:nrow(tyto.unique.ol1), nrow(tyto.unique.ol1) * 0.5)
79
80 tyto.train <- tyto.unique.ol1[selected, ]
81 tyto.test <- tyto.unique.ol1[-selected, ]
82
83 # extracting env conditions for training tyto from the raster
84 # stack; a data frame is returned (i.e multiple columns)
85 p <- extract(predictors, tyto.train)
86 # env conditions for testing occ
87 p_test <- extract(predictors, tyto.test)
88 # extracting env conditions for background
89 a <- extract(predictors, bg)
90
91 # repeat the number 1 as many numbers as the number of rows
92 # in p, and repeat 0 as the rows of background points
93 pa <- c(rep(1, nrow(p)), rep(0, nrow(a)))

```

```

95 pder <- as.data.frame(rbind(p, a))
96
97 # train Maxent with spatial data
98 # mod <- maxent(x=predictors,p=tyto.train)
99
100 # train Maxent with tabular data
101 mod <- maxent(x=pder, ## env conditions [c("bio11", "bio16","alt","bio19","bio9")]
102             p=pa, ## 1:presence or 0:absence
103
104             #path=paste0("../output/maxent_outputs"), ## folder for maxent output;
105             # if we do not specify a folder R will put the results in a temp file,
106             # and it gets messy to read those. . .
107             args=c("responsecurves") ## parameter specification
108             )
109 # the maxent functions runs a model in the default settings. To change these parameters,
110 # you have to tell it what you want...i.e. response curves or the type of features
111 mod_eval_train <- dismo::evaluate(p = p, a = a, model = mod)

113 ped3 <- predict(mod, predictors)
114 head(ped3)
115
116 plot(ped3)
117 plot(cr,add=T, border="grey40", lwd=2)
118 plot(toky,add=T,col="bLue" )
119 polygon(mesta$xpraha,mesta$ypraha,col="gray") #
120 polygon(mesta$xbrno,mesta$ybrno,col="gray") #density=25,angle=45,
121 polygon(mesta$xostrava,mesta$yostrava,col="gray") #density=25,angle=45,
122 polygon(mesta$xplzen,mesta$yplzen,col="gray") #density=25,angle=45,
123 polygon(mesta$xolom,mesta$yolom,col="gray") #density=25,angle=45,
124 polygon(mesta$xhkra,mesta$yhkra,col="gray") #density=25,angle=45,
125 polygon(mesta$xuhra,mesta$yuhra,col="gray") #density=25,angle=45,
126 polygon(mesta$xzlin,mesta$yzlin,col="gray") #density=25,angle=45,
127 addnortharrow(scale=.6,padin = c(0.7, 0.25))
128 addscalebar(htin=.04, pos="bottomLeft",padin=c(0.26,.26))
129
130
131 #hist(ped3) # creates a histogram of the prediction
132 mod_eval_train <- dismo::evaluate(p = p, a = a, model = mod)
133 print(mod_eval_train)

```