

Česká zemědělská univerzita v Praze

Fakulta životního prostředí

Katedra aplikované geoinformatiky a územního plánování

**Modelování potenciálního rozšíření  
netvařce křovitého (*Amorpha fruticosa*)  
a kustovnice cizí (*Lycium barbarum*)  
v České republice**

Bakalářská práce

**Vedoucí práce:** Ing. Vítězslav Moudrý, Ph.D.

**Bakalant:** Soňa Müllerová

2016

## ZADÁNÍ BAKALÁŘSKÉ PRÁCE

Soňa Müllerová

Aplikovaná ekologie

Název práce

**Modelování potenciálního rozšíření netvařce křovitého (*Amorpha fruticosa*) a kustovnice cizí (*Lycium barbarum*) v České republice**

Název anglicky

**Modelling potential distribution of invasive plants Indigo bush (*Amorpha fruticosa*) and Goji berry (*Lycium barbarum*) in the Czech Republic**

### Cíle práce

- zpracovat literární rešerši zabývající se využitím modelů druhové distribuce k predikci potenciálního rozšíření invazních druhů rostlin
- zjistit, které faktory prostředí nejvíce ovlivňují rozšíření vybraných druhů
- vytvořit predikční model rozšíření a ověřit jeho přesnost
- vytvořit a interpretovat mapy potenciálního rozšíření

### Metodika

Řešitelka zpracuje literární rešerši na téma modelování druhové distribuce invazních druhů rostlin se zaměřením na volbu vstupních dat – zejména parametrů odvozených z digitálních modelů terénu (např.: svažitost). V praktické části řešitelka získá a zpracuje dostupné záznamy o výskytu netvařce křovitého (*Amorpha fruticosa*) a kustovnice cizí (*Lycium barbarum*) a připraví environmentální faktory prostředí, které by mohly distribuci druhů ovlivňovat. Následně vytvoří predikční model distribuce pro jednotlivé druhy pomocí vhodné modelovací techniky, jehož přesnost ověří na testovacím vzorku dat. Výsledek modelu bude řešitelka prezentovat ve formě mapových výstupů (predikčních map), vyjadřujících rozšíření druhu mírou pravděpodobnosti (0-100%).

## Doporučený rozsah práce

30 – 40 stran

## Klíčová slova

šíření druhu, invazní rostliny, model, GIS

---

## Doporučené zdroje informací

- 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.
- FRANKLIN J. (2010). *Mapping species distribution*. Cambridge University Press.
- JIMÉNEZ-VALVERDE A., PETERSON A. T., SOBERÓN J., OVERTON J. M., ARAGÓN P., & LOBO J. M. (2011). Use of niche models in invasive species risk assessments. *Biological Invasions*, 13: 2785-2797.
- PEARSON R. G. (2010). Species' distribution modeling for conservation educators and practitioners. *Lessons Conservation* 3: 54-89.
- PETERSON A. T., SOBERÓN J., PEARSON R. G., ANDERSON R. P., MARTÍNEZ-MEYER E., NAKAMURA M. & ARAÚJO M. B. (2011). *Ecological niches and geographic distributions (MPB-49)*. Princeton University Press.
- STOHLGREN T. J., MA P., KUMAR S., ROCCA M., MORISETTE J. T., JARNEVICH C. S. & BENSON N. (2010), Ensemble Habitat Mapping of Invasive Plant Species. *Risk Analysis*, 30: 224–235.

---

## Předběžný termín obhajoby

2015/16 LS – FŽP

## Vedoucí práce

Ing. Vítězslav Moudrý, Ph.D.

## Garantující pracoviště

Katedra aplikované geoinformatiky a územního plánování

---

Elektronicky schváleno dne 29. 2. 2016

**doc. Ing. Petra Šímová, Ph.D.**

Vedoucí katedry

---

Elektronicky schváleno dne 7. 3. 2016

**prof. RNDr. Vladimír Bejček, CSc.**

Děkan

V Praze dne 12. 04. 2016

## **Prohlášení**

Prohlašuji, že jsem tuto bakalářskou práci vypracovala samostatně a uvedla všechny literární prameny a publikace, ze kterých jsem čerpala.

V Praze dne 12. 4. 2016

.....

## **Poděkování**

Ráda bych poděkovala Ing. Vítězslavu Moudrému Ph.D. a Ing. Martinu Tejkalovi za odborné vedení, vstřícný přístup a cenné připomínky při zpracování této práce. Poděkování patří rovněž Agentuře ochrany přírody a krajiny České republiky za poskytnutí dat.

## Abstrakt

Za jeden z hlavních procesů, který ohrožuje biodiverzitu, jsou v současnosti považovány biologické invaze. Invazní druhy jsou introdukované, v novém areálu zdomácnělé druhy, jejichž ekologický i ekonomický dopad je znám z řady oblastí světa. V České republice jsou významnou skupinou invazních organismů cévnaté rostliny, které se vyznačují schopností rychlé adaptace, šíření a obsazování nových stanovišť. Včasné zaznamenání potenciálně nebezpečného druhu může být jedním z kroků k zabránění dalšímu šíření. Tato bakalářská práce představuje techniku modelování druhové distribuce, což je jeden z moderních nástrojů sloužící k posouzení invazního potenciálu druhů a predikci jejich rozšíření. Hlavním cílem bylo vytvořit modely potenciálního rozšíření invazních keřů netvařce křovitého (*Amorpha fruticosa*) a kustovnice cizí (*Lycium barbarum*) v České republice a analyzovat významnost jednotlivých proměnných, včetně prediktorů odvozených z digitálního modelu terénu. Modely byly vytvořeny metodou Maxent v rozlišení 100 x 100 m na základě prezenčních dat a deseti prediktorů, z nichž tři jsou prediktory topografické – nadmořská výška, svažítost (*slope*) a expozice (*aspect*). Jako nejvýznamnější prediktory pro výskyt obou druhů se ukázaly nadmořská výška, krajinný pokryv, který měl v případě netvařce křovitého převažující vliv, a roční rozsah teplot. Pro kustovnici cizí je významným prediktorem také svažítost. Expozice byla vyhodnocena jako nevýznamný prediktor. Kriterium AUC dosáhlo u obou modelů vysokých hodnot - dosažená hodnota pro netvařec křovitý je 0,961 a pro kustovnici cizí 0,906. Na věrohodnost výsledného modelu má však zásadní vliv stádium invazního procesu a rovněž kompletnost a přesnost vstupních dat.

**Klíčová slova:** GIS, invazní rostliny, Maxent, model, SDM

## Abstract

Biological invasions are currently considered to be one of the major threats to biodiversity. Invasive species are introduced species naturalized in regions outside their native range with both ecological and economic impact known from many regions all over the world. In the Czech Republic, vascular plants constitute a major group of invasive species. They are characterized by the ability to adapt, spread and occupy new sites. Early identification of potentially dangerous species constitute a possible way to prevent further spread. This bachelor thesis presents the use of species distribution modelling technique as a tool for assessing invasive potential and predicting species invasions. The aim was to create the model of invasive shrub species' Indigo bush (*Amorpha fruticosa*) and Goji berry (*Lycium barbarum*) potential distribution in the Czech Republic and explore the significance of each predictor variable including variables derived from digital elevation model. Models were created in the resolution of 100 m using Maxent method based on presence-only data and ten predictor variables including three topographic variables – elevation, slope and aspect. The results show that the most significant variables for both species are elevation, land cover which is the most important one for *Amorpha fruticosa*, and temperature annual range. Slope variable is significant for *Lycium barbarum*. Aspect is not significant. In terms of AUC discrimination measure, high values were achieved for both species. AUC value for *Amorpha fruticosa* is 0,961 and 0,906 for *Lycium barbarum*. However, the realism and quality of the model is significantly influenced by the stage of invasion and also by complexity and accuracy of input data.

**Key words:** GIS, invasive plants, Maxent, model, SDM

# OBSAH

1 Úvod.....	9
2 Literární rešerše.....	12
2.1 Modelování druhové distribuce .....	12
2.1.1 Teorie .....	12
2.1.2 Modelování distribuce invazních druhů.....	14
2.1.3 Vstupní data .....	16
2.1.4 Modelovací metody.....	20
2.2 Charakteristika vybraných druhů .....	22
2.2.1 Netvařec křovitý.....	22
2.2.2 Kustovnice cizí.....	24
3 Metodika.....	26
3.1 Příprava vstupních dat .....	26
3.1.1 Data o výskytu .....	26
3.1.2 Prediktory.....	28
3.2 Výběr prediktorů.....	33
3.3 Tvorba modelu.....	35
3.3.1 Import vstupních dat .....	35
3.3.2 Interpretace výstupů.....	35
3.3.3 Ověření přesnosti .....	36
3.3.4 Nastavení parametrů .....	38
4 Výsledky.....	39
4.1 Netvařec křovitý .....	39
4.2 Kustovnice cizí .....	46
5 Diskuze.....	53
6 Závěr.....	56
7 Použitá literatura .....	57
8 Přílohy.....	61



# 1 ÚVOD

Za jeden z hlavních procesů, který výrazně ovlivňuje biodiverzitu, je považována úmyslná či neúmyslná introdukce nepůvodních druhů v důsledku lidské činnosti (Pergl et al. 2013). Přestože pouze malá část introdukovaných druhů v novém areálu zdomácní a následně se stane invazními (Pyšek 2001), je třeba věnovat potenciálně nebezpečným druhům patřičnou pozornost. Prevence a včasná reakce je daleko účinnější a také levnější alternativou k řešení následků již probíhající invaze - vedle vlivu na biodiverzitu a ekologické procesy mají totiž nepůvodní druhy rovněž dopady ekonomické. Jak uvádí Pergl et al. (2013), každoročně jsou po celém světě pro likvidaci či omezení nepůvodních druhů vynaloženy značné finanční prostředky. Probíhající invaze však v mnoha případech není včas zaznamenána, zejména z toho důvodu, že identifikovat nebezpečný invazní druh je značně nejisté a spolehlivě možné většinou až ve fázi, kdy je již na efektivní likvidaci pozdě (Pergl et al. 2013).

Předpovídat budoucí chování potenciálně nebezpečného druhu na základě současných poznatků je obtížné a zatížené značnou mírou náhody, která často vede k odstartování invaze druhu, který byl dosud považován za neškodný (Křivánek et al. 2006). V současné době již existují nástroje, s jejichž využitím je možné posoudit invazní potenciál druhů a predikovat jejich rozšíření. Jedním z nich je modelování druhové distribuce (*Species distribution modelling*, např. Elith et Leathwick 2009, Franklin 2009, Miller 2010), což je moderní metoda rozvíjející se v posledních desetiletích. Základ této techniky spočívá ve vyjádření vztahu mezi výskytem druhu a podmínkami prostředí matematickým modelem (Franklin 2009). Cílem je identifikovat a charakterizovat soubor podmínek prostředí, které jsou klíčové pro výskyt daného druhu a následně určit, kde a jakým způsobem jsou tyto podmínky rozmístěny v prostoru (Pearson 2010). V případě biologických invazí je tedy úkolem zjistit, které faktory ovlivňují výskyt invazního druhu a identifikovat lokality, které mohou být druhem potenciálně obsazeny (Franklin 2009).

V současnosti je k dispozici celá řada modelovacích metod (Franklin 2009). Výběr vhodné metody je založen mimo jiné na charakteru biologických dat, charakteru prediktorů, záměru dané studie případně požadovaných výstupech (Miller 2010). Jedním z klíčových kritérií je to, zda metoda pracuje pouze s daty o výskytu (tzv. *presence - only*), či zda jde o více komplexní metodu, která vyžaduje rovněž data o pozorované absenci. Protože data o absenci často nejsou k dispozici, případně nemusí být spolehlivá, roste zájem právě o metody vyžadující pouze prezenční data (Pearson 2010), mezi které patří Maxent (*Maximum entropy*), což je metoda strojového učení s širokým spektrem možných aplikací (Phillips et al. 2006).

Významnou skupinou invazních organismů jsou v České republice cévnaté rostliny (Křivánek et al. 2006). Vyznačují se schopností rychle se šířit na větší vzdálenosti, úspěšně obsazovat nové lokality, konkurovat a vytlačovat původní vegetaci a snižovat tak druhovou diverzitu, či dokonce zcela proměnit druhové složení stanoviště zásahem do živinového režimu (Pyšek 2001, Pergl et al. 2013). Pokud jde o nepůvodní druhy rostlin, patří Česká republika mezi nejlépe prozkoumané evropské země (Křivánek et al. 2006). Díky dlouholeté tradici výzkumu jsou dnes k dispozici data, která poskytují dobrou představu o nepůvodní flóře i rostlinných invazích (Pyšek et al. 2012b).

Pro dosažení co nejlepší predikční schopnosti a kvality modelu by měly být zahrnuty všechny důležité environmentální proměnné (Lassueur et al. 2006). Za nejvýznamnější faktory ovlivňující distribuci rostlin jsou mimo jiné považovány teplotní a světelný režim, dostupnost vody a živinový režim (Miller 2010, Austin et Van Niel 2011). Právě klimatické prediktory jsou však často tvořeny interpolací dat z meteorologických stanic a v mnoha oblastech jsou méně kvalitní a hůře dostupná (Parra et al. 2004 in Miller 2010). Ve většině případů navíc neposkytují informaci o mikroklimatu, které je zcela zásadní pro distribuci rostlin, zvláště v oblastech s členitým reliéfem. Protože mikroklima úzce souvisí s lokálním charakterem reliéfu, digitální model terénu (Digital Elevation Model) a z něj odvozené prediktory jako svazitost terénu (*slope*) nebo expozice (*aspect*) slouží jako velice užitečné nepřímé proměnné nahrazující řadu zásadních, avšak těžko měřitelných prediktorů. Díky dostupnosti digitálního modelu terénu ve velice podrobném měřítku lze odvozovat tyto prediktory s vysokou přesností (Lassueur et al. 2006).

V této práci budou s využitím metody Maxent vytvořeny modely potenciálního rozšíření dvou invazních druhů keřů na území České republiky nacházející se v odlišných fázích invazního procesu. Netvařec křovitý (*Amorpha fruticosa*) je potenciálně nebezpečný druh s počínajícím šířením a nejasným invazním potenciálem, kustovnice cizí (*Lycium barbarum*) je naopak jasně problematickým druhem, jehož invaze již probíhá.

**Cíle práce:**

- zpracovat literární rešerši zabývající se využitím modelů druhové distribuce k predikci potenciálního rozšíření invazních druhů rostlin se zaměřením na vstupní data, zejména prediktory odvozené z digitálního modelu terénu,
- získat a zpracovat dostupné záznamy o výskytu netvařce křovitého a kustovnice cizí na území České republiky,
- zjistit, které faktory prostředí nejvíce ovlivňují rozšíření těchto druhů a zda mají na distribuci významný vliv prediktory odvozené z digitálního modelu terénu,
- vytvořit predikční modely rozšíření s využitím softwaru Maxent a ověřit jejich přesnost,
- vytvořit a interpretovat mapy potenciálního rozšíření, na základě těchto map posoudit, které oblasti České republiky jsou potenciálně ohroženy invazí.

## 2 LITERÁRNÍ REŠERŠE

### 2.1 Modelování druhové distribuce

Modely druhové distribuce jsou numerické nástroje, které hledají vztah mezi výskytem druhu (nálezová data) a podmínkami prostředí vyjádřené environmentálními proměnnými (prediktory) a umožňují identifikovat podmínky vhodné pro výskyt druhu, tedy jeho ekologické požadavky. Následně lze zjistit, které oblasti zájmového území takové podmínky splňují. Tuto techniku je tak možné využít k predikci distribuce živých organismů a především k porozumění ekologickým či evolučním principům, tedy nalezení klíčových faktorů, které distribuci druhů ovlivňují (Phillips et al. 2004, Elith et Leathwick 2009, Pearson 2010).

Klíčové kroky k vytvoření dobrého modelu zahrnují získání relevantních vstupních dat, posouzení jejich přesnosti a úplnosti, vhodný způsob řešení korelací mezi prediktory, výběr vhodné modelovací techniky, fitování modelu s použitím tzv. *training* dat, zhodnocení reálnosti modelu, ověření přesnosti modelu na testovacím vzorku dat a v neposlední řadě tvorba predikčních map (Elith et Leathwick 2009, Miller 2010).

Přestože tento nástroj je nejčastěji označován termínem *species distribution modeling* (dále např. *climate envelopes*, *niche modeling*, *habitat suitability modeling*, *predictive habitat distribution modeling*, *resource selection functions*), je důležité si uvědomit, že ve skutečnosti není modelována distribuce druhu jako taková, ale spíše distribuce vhodných podmínek pro výskyt, či ještě přesněji ekologická nika nebo habitat, což potvrzují uvedené termíny (Elith et Leathwick 2009, Miller 2010, Pearson 2010).

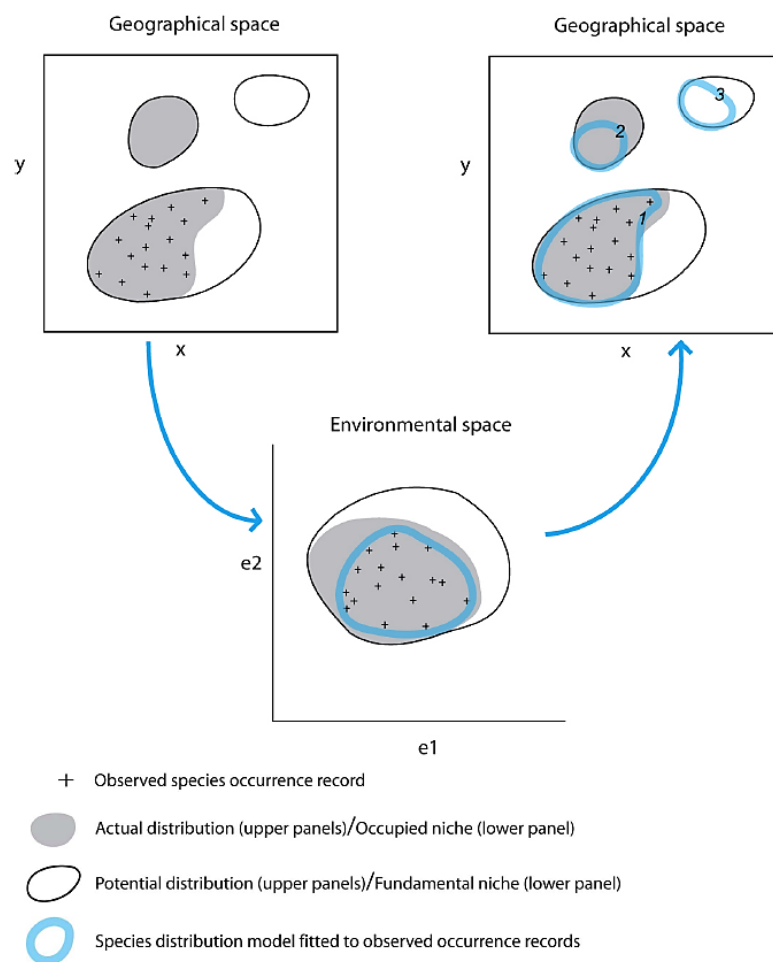
Modely druhové distribuce mají široké spektrum možných aplikací v ekologii i ochraně přírody. Využívají se např. k testování ekologických teorií, porozumění procesu speciace, hledání populací druhů, vymezení areálu druhů, reintrodukcí ohrožených druhů, predikci dopadů klimatických změn a mnoho dalších. Další důležité, rozvíjející se využití se týká analýz rizik nebo problematiky invazních druhů, tedy předpovídání biologických invazí (Franklin 2009, Pearson 2010).

#### 2.1.1 Teorie

Klíčovým pojmem v teorii modelování je již zmíněná ekologická nika druhu. Přestože teorie niky je obecně považována za základní myšlenku v ekologii, její definice a výklad nejsou zcela jednoznačné (Miller 2010). V kontextu modelování druhové distribuce se velice často využívá definice, kterou uvádí Hutchinson (1957). Na niku pohlíží jako na část myšleného,  $n$ -rozměrného prostoru, ve kterém je druh schopen přežít po neurčitou dobu, přičemž dimenze představují jednotlivé faktory (gradienty) prostředí (Hutchinson 1957 in Miller 2010). Tato definice dále rozlišuje mezi fundamentální (*fundamental*) nikou, což je celkový soubor požadavků na abiotické

podmínky umožňující přežití a udržení populace druhu, a realizovanou (*realized*) nikou, což je část fundamentální niky, kterou druh skutečně obsadil. Zbývající část fundamentální niky není obsazena v důsledku přítomnosti omezujících faktorů, tedy biotických interakcí (např. kompetice či predace), případně geografických bariér a disturbancí bránící šíření druhu na vhodná stanoviště (Miller 2010, Pearson 2010).

Ekologická nika odpovídá distribuci druhu v tzv. *environmentálním* prostoru, zatímco nálezová data (body definované zeměpisnými souřadnicemi) představují distribuci v *geografickém* prostoru. Fundamentální nika v environmentálním prostoru teoreticky odpovídá *potenciální* distribuci, realizovaná nika pak *aktuální* distribuci (Pearson 2010, viz obr. 1).



**Obr. 1:** Vztah geografického a environmentálního prostoru a princip modelování druhové distribuce. Křížky označují pozorované výskyty druhu, plnou černou čarou je vyznačena potenciální distribuce a fundamentální nika, šedě aktuální distribuce a realizovaná nika. Modře je znázorněn výsledný model (Pearson 2010).

Záznamy o výskytu informují o *aktuální* distribuci, přičemž tato informace nemusí být kompletní, neboť druh se může vyskytovat ještě na dalších lokalitách, kde nebyl

zaznamenán. Užitečnost modelů druhové distribuce spočívá v převedení informace z geografického do environmentálního prostoru, tedy v kvantifikaci vztahu nálezových dat a sady prediktorů, čímž je identifikována část environmentálního prostoru obsazená druhem. Výsledný model je následně promítnut zpět do geografického prostoru v podobě predikční mapy, která v zájmovém území vyjadřuje např. pravděpodobnost výskytu druhu nebo vhodnost prostředí. Podstatné je, že modelem je definována pouze ta část niky, která je vymezena dostupnými daty (Miller 2010, Pearson 2010).

Do jaké míry a s jakou přesností bude modelem ekologická nika charakterizována, zda bude popsána fundamentální nika, realizovaná nika nebo spíše habitat a zda výsledná predikce bude blíže aktuální či potenciální distribuci, není zcela jednoznačné a má přímou souvislost s charakterem obou typů vstupních dat, tedy jak nálezových dat, tak použitých prediktorů (Franklin 2009, Pearson 2010).

### 2.1.2 Modelování distribuce invazních druhů

Invazní druhy v současnosti představují jedno z hlavních rizik pro původní druhy organismů a přirozené ekosystémy. Tato skutečnost je významným podnětem k tvorbě modelů, které by spolehlivě predikovaly výskyt invazních druhů a jejich další šíření v krajině (Ibáñez et al. 2009). Využití SDM v problematice biologických invazí spočívá v identifikaci lokalit, které mohou být invazními druhy potenciálně obsazeny. Existují dva základní přístupy. První spočívá v predikci invazního potenciálu v nových oblastech, které je založeno na znalosti ekologických preferencí druhu zjištěných v původním areálu rozšíření (Franklin 2009). K tomu se velice často používají pouze klimatické prediktory (Ibáñez et al. 2009). Druhý způsob predikce je založen na dostupné informaci o ekologických podmínkách stanovišť v nepůvodním areálu, které již druh obsadil. Následně je možné identifikovat lokality, které dosud obsazeny nejsou, ale vyznačují se podobnými podmínkami a mohou být tedy ohroženy invazí. Protože invazní druhy mají ekologický i ekonomický dopad v řadě oblastí světa, predikce invazního potenciálu je důležitým nástrojem k posouzení možného rizika a může tak pomoci zahájit monitoring či vhodný management v ohrožených oblastech (Franklin 2009).

Základním předpokladem v modelování druhové distribuce je dosažení rovnováhy mezi druhem a prostředím. V případě biologických invazí však tento předpoklad často není splněn např. z důvodu přítomnosti faktorů, které do různé míry brání druhu v obsazení všech vhodných stanovišť. Do jaké míry jsou schopna nálezová data reprezentovat ekologickou niku druhu, pak závisí na stádiu invazního procesu, ve kterém se druh nachází. To následně ovlivní i predikci potenciálního rozšíření (Václavík et Meentemeyer 2012). Dalším důsledkem je pak obtížné ověření přesnosti a spolehlivosti těchto modelů (Ibáñez et al. 2009).

Václavík et Meentemeyer (2012) zjistili, že modely vytvořené v raných stádiích invazního procesu jsou méně přesné, než modely vytvořené ve stádiích bližších rovnováže a mají větší tendenci podhodnotit velikost plochy, která může být potenciálně obsazena. Při tvorbě modelů, které budou sloužit jako podklady v ochraně přírody nebo k plánování managementu, by mělo být zhodnoceno právě stádium invaze, aby nedošlo k podhodnocení odhadu stanovišť, která mohou být invazí ohrožena (Václavík et Meentemeyer 2012).

Invazní druhy mohou navíc v novém areálu obsadit širší škálu stanovišť než v primárním areálu, např. z důvodu absence konkurentů, predátorů či genetických adaptací, nebo naopak užší škálu kvůli přítomnosti konkurentů nebo omezujících faktorů. Velkou výhodou pak může být dostupnost dat o výskytu ze sekundárního i primárního areálu, na základě kterých lze posoudit, zda je druh striktně vázán na podmínky ze svého primárního areálu nebo je schopen se rychle přizpůsobit odlišným podmínkám a obsadit v novém areálu mnohem širší škálu stanovišť (Franklin 2009).

Z výše uvedených důvodů je predikce rozšíření invazního druhu značně obtížná záležitost. V mnoha studiích zabývajících se predikcí rozšíření invazních druhů rostlin, je používán přístup zvaný „climate envelopes“, což je predikce založená na informaci o požadavcích na klimatické podmínky v původním areálu, v rámci kterých se druh v současnosti vyskytuje a následné extrapolaci do nových oblastí. Distribuce invazních druhů rostlin je však kromě klimatu ovlivněna řadou dalších abiotických i biotických faktorů a jejich interakcemi. Volba souboru prediktorů a vhodného rozlišení se liší v závislosti na druhu a studované oblasti. Ibáñez et al. (2009) zmiňují, že je nedostatečně prozkoumán invazní proces v různých rozlišeních. V návaznosti na tento problém navrhují při předpovídání potenciální distribuce invazních rostlin použít komplexní přístup, který je založen na posouzení vlivu hlavních faktorů ovlivňujících invazní proces v různých rozlišeních. V modelu je pak zahrnuta široká škála prediktorů a rozlišení, které mohou invazní proces ovlivnit a je tak možné dosáhnout poměrně spolehlivé předpovědi budoucího rozšíření.

Ačkoli někdy mohou klimatické podmínky představovat jediná dostupná data, predikce založené pouze na klimatu jsou do určité míry omezené, protože neberou v úvahu další faktory, které přispívají k rozšíření druhu. Významným faktorem ovlivňující šíření a obsazování stanovišť invazními druhy rostlin je například struktura krajiny. Jako významný prediktor se ukázal land use nebo land cover (Ibáñez et al. 2009).

### 2.1.3 Vstupní data

#### **Nálezová data**

Data popisující známou distribuci druhu mohou být různého charakteru, přičemž nejčastěji se lze setkat s daty dvojího typu. Jedná se o data *presence-only*, kdy jsou k dispozici pouze záznamy o prezenci druhu, nebo data *presence-absence*, která poskytují informaci jak o prezenci, tak absenci (nevýskytu) druhu na konkrétních lokalitách (Miller 2010, Pearson 2010). Absenční data však mnohdy nejsou k dispozici, jsou obtížně dostupná, případně nemusí být spolehlivá (Pearson 2010). Za zavádějící jsou považována například tehdy, není-li dosaženo rovnováhy mezi distribucí druhu a prostředím. To je častým problémem právě invazních druhů, zejména v raných stádiích invaze, kdy zatím nemuselo dojít k obsazení všech vhodných stanovišť a zaznamenaná absence tedy nutně nemusí značit nevhodné podmínky (Elith et Leathwick 2009, Václavík et Meentemeyer 2012). Proto v současnosti roste zájem o data *presence-only*. Objevují se snahy co nejvíce využít již existující, zpracované záznamy o výskytu druhu dostupné např. v přírodovědných sbírkách, muzeích či nejrůznějších databázích, které v současnosti představují nejbohatší zdroj právě *presence-only* dat. Nevýhoda těchto dat spočívá v tom, že většinou nepochází ze systematického mapování, často jsou tvořena pouze příležitostnými záznamy o výskytu a nemusí tedy poskytovat kompletní informaci o distribuci druhu (Phillips et al. 2004, Elith et Leathwick 2009, Miller 2010).

#### **Environmentální data (prediktory)**

Prediktory jsou vysvětlující proměnné reprezentující faktory prostředí v zájmové oblasti, přičemž každý z nich lze považovat za jeden rozměr v  $n$ -rozměrném prostoru, ke kterému přirovnal Hutchinson (1957) ekologickou niku druhu (Miller 2010).

Poměrně problematickou záležitostí je volba vhodného rozlišení. Neexistuje totiž univerzální rozlišení vhodné pro reprezentaci a modelování ekologických procesů. Relevantní je takové, ve kterém daný faktor vykazuje největší variabilitu - rozdíly v klimatu jsou například významnější spíše v globálním až regionálním měřítku, zatímco například půdní podmínky nebo dostupnost živin se liší lokálně. Reakce druhu na daný prediktor tedy může být významná pouze v určitém rozlišení, proto není vhodné na základě neprůkaznosti prediktoru v jednom rozlišení vyvozovat shodné závěry pro jiná rozlišení a prediktory. Použité rozlišení by mělo odpovídat také prostorové přesnosti nálezových dat a často je závislé na prostorovém rozsahu studie a dostupných datech (Elith et Leathwick 2009, Miller 2010, Austin et Van Niel 2011). Hledání optimálního rozlišení, ve kterém mají prediktory nejvyšší predikční schopnost, je aktuální oblastí výzkumu. Prediktory odvozenými z DEM se zabývali např. Lassueur et al. (2006).

Před tvorbou modelu je dále důležité vzít v úvahu typ jednotlivých proměnných (gradientů). Austin (1980) in Miller (2010) rozlišuje tzv. přímé (*direct*) gradienty, které



mají přímý vliv na distribuci druhu, ale nejsou spotřebovávány (např. teplota nebo pH), dále tzv. zdrojové (*resource*), které jsou spotřebovávány (např. živiny, voda, světlo) a nakonec nepřímé (*indirect*), které distribuci přímo neovlivňují, ale jsou korelované s určitými přímými gradienty a mohou tak sloužit jako jejich zástupci - např. průměrná roční teplota může být zastoupena nadmořskou výškou (Franklin 2009, Miller 2010, Austin et Van Niel 2011). Pro vytvoření co nejlepšího modelu by měly být zahrnuty všechny klíčové environmentální proměnné, včetně zdrojových (Lassueur et al. 2006), dostupná data však zřejmě neumožní reprezentaci všech faktorů, které mají ve skutečnosti vliv na distribuci druhu (Franklin 2009, Pearson 2010). Jestliže nejsou prediktory voleny s přihlédnutím k ekologii druhu ale pouze na základě dostupných dat, sníží se tím jak výkonnost modelu, tak relevance výstupů (Austin et Van Niel 2011).

Za nejvýznamnější faktory ovlivňující distribuci rostlinných druhů jsou obecně považovány světlo, teplota, dostupnost živin, vody a oxidu uhličitého, disturbance a biotické interakce (Austin et Van Niel 2011). Většinu ze zmíněných faktorů je však obtížné získat, případně nemají požadovanou přesnost nebo charakter. Například prediktory vyjadřující klimatické podmínky jsou zpravidla tvořeny interpolací dat z meteorologických stanic a neposkytují tedy dostatečně přesnou informaci o mikroklimatu, které je zásadní pro distribuci rostlin (Guisan and Zimmermann 2000, Lassueur et al. 2006). V takových případech se nabízí využití zmíněných nepřímých proměnných, např. parametrů odvozených z DEM (Lassueur et al. 2006). Z dalších faktorů je třeba zmínit krajinný pokryv, který se ukázal jako důležitý prediktor při předpovídání potenciální distribuce invazních druhů rostlin (Ibáñez et al. 2009).

#### Prediktory odvozené z digitálního modelu terénu (DEM)

Protože mikroklima je úzce spjato s lokálním charakterem terénu, zejména v hornatých oblastech nebo v oblastech s členitějším reliéfem, DEM představující nadmořskou výšku a z něj odvozené prediktory lze využít jako velice užitečné zástupce řady zmíněných faktorů ovlivňujících distribuci rostlin, což je zejména teplotní, světelný a hydrologický režim stanoviště (Lassueur et al. 2006, Austin et Van Niel 2011).

Digitální model terénu je modelem zemského povrchu a nezahrnuje objekty vytvořené lidskou činností ani vegetaci. Parametry z něj odvozené jsou označovány jako topografické proměnné (Franklin 2009, Lassueur et al. 2006). Rozlišují se tzv. primární parametry, které jsou odvozeny přímo z digitálního modelu terénu a více komplexní, tzv. sekundární parametry, které jsou vypočteny z určité kombinace parametrů primárních (Moore et al. 1991 in Franklin 2009). Na nadmořské výšce vyjádřené samotným DEM jsou obecně závislé dva zásadní gradienty - teplota a srážkový úhrn. Příklady primárních parametrů, které mají přímý nebo nepřímý vztah s gradienty prostředí, jsou svažitost terénu (*slope*) a expozice (*aspect*) (Franklin 2009).

Vliv svažitosti na distribuci rostlin spočívá v tom, že významně ovlivňuje procesy související s gravitací, mezi které patří hydrologický režim stanoviště, tedy povrchový i podpovrchový odtok a akumulace vody, které pak dále ovlivňují půdní vlhkost a další půdní charakteristiky. Dále má pak vliv na proces eroze nebo depozici organické hmoty. Je-li svažitost použita v kombinaci s expozicí, lze vyjádřit také množství přijaté energie povrchem, případně variabilitu v dostupném množství sluneční energie, což většinou nelze zjistit z běžně používaných klimatických proměnných získaných interpolací (Lassueur et al. 2006, Franklin 2009).

Expozice vyjadřuje orientaci svahů ke světovým stranám. Tento parametr má významný vliv na množství dopadajícího slunečního záření a tedy na světelný i teplotní režim stanoviště, což dále ovlivňuje zásobu vody v půdě nebo evaporaci. Ve vyšších polohách má vliv také na dobu, po jakou leží sněhová pokrývka. Již při výzkumu, který provedli Rorison et al. v Anglii (Rorison et al. 1986 in Austin et Van Niel 2011) bylo zjištěno, že průměrná letní teplota byla o 3 °C vyšší na jižně orientovaných svazích než na těch orientovaných severně, což odpovídá rozdílu teplot ekvivalentnímu k posunu v zeměpisné šířce o několik set kilometrů (Austin et Van Niel 2011). Maximální teplota naměřená v dubnu se mezi jižně a severně orientovanými svahy lišila dokonce o 12 °C. Zjištěné rozdíly bezesporu potvrzují významnost lokálního charakteru terénu.

Expozice je spojitá proměnná se specifickým charakterem (tzv. *circular*), která bývá vyjádřena hodnotami od 0 do 360 °. Minimální hodnoty jsou v těsné blízkosti maximálních hodnot a vyjadřují stejnou skutečnost. Proto se ve většině případů provádí transformace goniometrickými funkcemi *sinus* a *cosinus*, přičemž výstupem jsou dvě spojitě proměnné – *northness* vyjádřená jako  $\cos(\text{aspect})$  a *eastness* jako  $\sin(\text{aspect})$ . *Northness* nabývá hodnot blízkých 1 v případě, že expozice je převážně severní, hodnot blízkých -1 pak v případě, že je expozice jižní. Východní či západní expozici odpovídají hodnoty okolo 0. Proměnná *eastness* má obdobný charakter s tím rozdílem, že hodnoty blízké 1 (-1) představují východně (západně) orientované svahy apod. Další možností úpravy proměnné expozice je převedení na kategoriální proměnnou, kde jednotlivé kategorie jsou snadno interpretovatelné a kromě toho lze zařadit i kategorii zastupující buňky „bez expozice“ (Palmer).

Dalším příkladem jsou prediktory vyjadřující zakřivení terénu (*curvature*), které má vliv na akumulaci sněhu během zimy, což ovlivní např. začátek a délku vegetačního období nebo zásobu vody v půdě (Lassueur et al. 2006). Dále je potřeba zmínit komplexní prediktory vyjadřující světelné podmínky (např. *potential solar radiation*). Austin et Van Niel (2011) označují světlo za nezbytnou součást modelů distribuce rostlin a upozorňují na to, že příslušné prediktory nejsou v mnoha studiích vůbec zahrnuty. Dále uvádí, že množství dopadajícího slunečního záření vykazuje variabilitu v podrobném měřítku a pro výpočet je tedy potřeba použít data ve vysokém rozlišení.

Díky vývoji technologií laserového skenování je dnes možné vytvářet digitální modely terénu ve velmi vysokém rozlišení (tzv. VHR DEM s rozlišením až 1 m), což umožňuje výpočet zmíněných parametrů s vysokou přesností (Lassueur et al. 2006). V publikovaných studiích zabývajících se modelováním distribuce rostlinných druhů, ve kterých byly zařazeny topografické prediktory, se lze setkat s poměrně širokou škálou použitých rozlišení i prediktorů.

Již před necelými dvěma desetiletími se objevují studie, kde je použito podrobné rozlišení. Např. Franklin (1998) použila v modelování potenciální distribuce 20 druhů keřů v Kalifornii *slope angle* a *potential solar insolation* v rozlišení 30 m. Ve studii, která byla provedena v Tyrolsku pro 19 vysokohorských druhů rostlin (Gottfried et al. 1998), bylo použito celkem 17 prediktorů (např. *slope*, *easting*, *southing*, *hillshade*, *upslope area*, *curvature*, *roughness*) v 10 rozlišeních (1 m – 100 m). Guisan et al. (1999) použili pro modelování distribuce 23 druhů dřevin v Nevadě *slope angle*, *northness*, *eastness*, *summer insolation*, *spring insolation*, *topographic position* a nadmořskou výšku v rozlišení 30 m. Jelaska et al. (2003) modelovali distribuci 37 rostlin (byliny i dřeviny) v NP Medvednica v Chorvatsku a použili k predikci *slope*, *aspect (northness)*, *flow accumulation potential* a nadmořskou výšku v rozlišení 20 x 20 m.

Setkat se lze i s méně podrobným rozlišením. K predikci potenciálního rozšíření 4 invazních druhů rostlin na území Severní Ameriky použili topografické proměnné Peterson et al. (2003), a to konkrétně *slope*, *aspect*, *flow accumulation*, *flow direction* a *topographic index*, přičemž použité rozlišení není přímo uvedeno, ale jako zdroj dat uvádí Hydro-1K (U. S. Geological Survey), což je databáze topografických prediktorů v rozlišení 1 x 1 km. Shodná data použili také Zhu et al. (2007), kteří predikovali distribuci invazní rostliny *Eupatorium adenophorum* v Číně. 2 topografické prediktory (*slope* a *topographic position*) v rozlišení 100 m zařadili do modelů distribuce 30 druhů stromů ve Švýcarsku Guisan et al. (2007).

Za zmínku dále stojí studie, kterou provedli Lassueur et al. (2006). Zabývali se modelováním distribuce 117 horských druhů rostlin ve Švýcarsku. Byly použity 4 topografické prediktory - *slope*, *aspect*, *plan curvature* a *profile curvature*. Prediktory byly vypočteny v 6 různých rozlišeních (9 – 175 m), přičemž byl nejprve základem DEM ve standartním rozlišení 25 m a poté VHR DEM v rozlišení 1 m. Cílem bylo porovnat predikční schopnost proměnných a zjistit, zda se jejich predikční schopnost zvýší, je-li základem VHR DEM, a v jakém rozlišení predikují distribuci rostlin nejlépe. Ukázalo se, že svažitost i expozice (*northness*) mají významný vliv, přičemž predikční schopnost se výrazně zvýšila, byl-li k výpočtu použit právě VHR DEM. Svažitost měla nejvýznamnější vliv v rozlišení 100 x 100 m, expozice v rozlišení 20 x 20 m.

V případě, že je potřeba prediktory odvozené z DEM převzorkovat na hrubší rozlišení, než má výchozí digitální model terénu (např. z důvodu sjednocení s dalšími

prediktory), je velice důležité zvážit pořadí jednotlivých kroků úpravy. Postup pro výpočet svažitosti a expozice navrhuje Grohmann (2015). Doporučuje nejprve provést výpočet parametru z DEM v původním rozlišení a až ve druhém kroku jej převzorkovat na požadované rozlišení. Pokud je totiž v prvním kroku převzorkován DEM a až poté proveden výpočet, rozdělení hodnot se zejména v případě svažitosti výrazně liší od původního, protože převzorkováním DEM dojde ke zprůměrování hodnot a tedy k „zarovnání“ terénu. Hodnoty svažitosti se pak se snižujícím rozlišením systematicky snižují, dochází ke ztuhlému poklesu maximálních hodnot a tudíž i průměrné hodnoty a směrodatné odchylky. Grohmann (2015) obecně nedoporučuje odvozovat topografické proměnné z DEM v příliš hrubém rozlišení, protože dochází k výraznému znehodnocení informace, což potvrzuje také Austin et Van Niel (2011).

#### 2.1.4 Modelovací metody

Pro aplikaci modelů druhové distribuce je k dispozici celá řada metod (Franklin 2009, Li et Wang 2013). Výběr vhodné metody je založen na několika kritériích, přičemž nejzásadnějším je charakter vstupních náleзовých dat, tedy zda jsou k dispozici pouze prezenční, či rovněž absenční data. To pak úzce souvisí s tím, zda je predikována pravděpodobnost výskytu (*probability*) či spíše vhodnost prostředí, tzv. *suitability* (Miller 2010, Pearson 2010).

Pearson (2010) řadí mezi další důležitá kritéria při výběru vhodné metody její schopnost pracovat i s kategorickými proměnnými nebo to, zda je možné z výstupů posoudit vliv a významnost jednotlivých proměnných. Použitá metoda závisí rovněž na požadovaných výstupech, konkrétním záměru či zájmové skupině organismů (Elith et Leathwick 2009, Miller 2010).

#### **Metody presence-absence**

Princip těchto metod spočívá v porovnání lokalit, kde se druh vyskytoval s lokalitami, kde byla zaznamenána absence. Mezi nejčastěji používané patří klasické statistické metody založené na lineární regresi, tedy zobecněné lineární modely (GLMs) nebo zobecněné aditivní modely (GAMs), které jsou jejich neparametrickým rozšířením. Populárními presence-absence metodami jsou dále *Artificial neural networks* (ANN), *Random forests* nebo *Classification and regression trees* (CART), což jsou techniky založené na strojovém učení nebo vytěžování informací z dat (tzv. *machine learning* a *data mining*) (Elith et Leathwick 2009, Li et Wang 2013). Presence-absence data umožňují predikovat přímo pravděpodobnost výskytu.

#### **Metody presence-only**

Metody nevyžadující absenční data lze dle přístupu dále rozdělit do několika skupin. Některé z nich používají tzv. *pseudo-absence*, což jsou data vybraná ze zájmové oblasti, která zastupují skutečné absence. Další metody (např. Maxent) používají

tzv. *background data*, která slouží k popisu podmínek prostředí v celé oblasti a umožňují srovnání s podmínkami na lokalitách výskytu druhu. Na rozdíl od *pseudo-absencí* v sobě zahrnují i prezence. Nakonec existují metody, které vytváří modely pouze na základě prezencí. Protože není k dispozici kompletní informace o distribuci, u těchto metod hovoříme spíše o predikci vhodnosti prostředí (Phillips et al. 2006, Pearson 2010).

### Maxent

Podstatou metody je odhad rozdělení pravděpodobnosti v určitém prostoru nalezením rozdělení s maximální entropií (maximálně „neuspořádané“ nebo maximálně uniformní) tak, aby se předpokládaná hodnota každé funkce v takovém rozdělení zároveň shodovala s její empirickou průměrnou hodnotou. Prezenční data slouží jako výběr z hledaného rozdělení, zájmová oblast je prostor, ve kterém je rozdělení definováno, funkce představují environmentální proměnné (Phillips et al. 2004). Výhodou metody je možnost použití jak kontinuálních tak kategoriálních proměnných a schopnost modelu zahrnout jejich vzájemné interakce. Výstupem je predikce spojitého charakteru, která umožňuje podrobnější porovnání vhodnosti prostředí v různých oblastech. Protože teorie maximální entropie je matematicky definovaná, je možné provést detailnější analýzu vztahu jednotlivých proměnných k predikované hodnotě *suitability* (Phillips et al. 2006, Pearson 2010).

Phillips et Dudík (2008) uvádí, že Maxent poskytuje kvalitní predikce i v případě ponechání výchozího nastavení – není tedy nezbytně nutná detailní znalost teorie a pokročilé nastavování parametrů. Velmi dobrých výsledků bylo dosaženo i pro méně kvalitní nebo malé soubory dat. Pro aplikaci metody byl navíc vytvořen speciální software s grafickým uživatelským rozhraním, který umožňuje nenáročný import vstupních dat a tvorbu modelu (Phillips et al. 2004, 2006)

Dalším příkladem presence-only metody je GARP (*Genetic algorithm for rule set production*) (Li et Wang 2013).

## 2.2 Charakteristika vybraných druhů

### 2.2.1 Netvařec křovitý

Netvařec křovitý je opadavý, až 4 m vysoký keř z čeledi bobovité (*Fabaceae*) s přímými větvemi a lichozpeřenými listy dlouhými až 30 cm. Květy jsou tmavě fialové, uspořádané v 7 až 20 cm dlouhých, vystoupavých hroznech (obr 2). Květy mají nedokonale vyvinutou, „beztvarou“ květní korunu – odtud pochází jak latinský, tak český název rodu (Buček 2002, Křivánek 2006a). Kvete od května do září, plodem jsou drobné lusky s 1 až 2 semeny. Celá rostlina je mírně jedovatá, obsahuje isoflavonoidy (Rak 2007, Hroneš 2010). Primární areál rozšíření je ve střední a východní části Severní Ameriky, konkrétně v USA (Connecticut až Minnesota a Luisiana až Florida), jihovýchodní Kanadě a severním Mexiku. Zde roste ve společenstvech křovin břehů vod, v mokřadech nebo stinných roklich (Křivánek 2006a, Hroneš 2010).

Sekundární výskyt je udáván z řady evropských i asijských zemí a západní části Severní Ameriky (Křivánek 2006a, Hroneš 2010). V jižní, střední a východní Evropě se druh údajně šíří do vřesovišť, křovin a příbřežních porostů (Křivánek 2006a), což potvrzuje např. Buček (2002) nebo Pyšek et al. (2012a), kteří zmiňují ekologické dopady šíření druhu v Evropě. První údaje o pěstování na území ČR pochází z roku 1852.



V zahradách a parcích byl často vysazován jako okrasný keř, dále se využívá jako větrolam nebo protierozní dřevina zpevňující a obohacující písčité svahy, často podél komunikací, zejména v teplejších oblastech. Oblíbený je také jako medonosná rostlina (Křivánek 2006a, Hroneš 2010). Jedná se o světlomilný druh, velmi dobře snáší sucho i znečištění. První zplanění u nás bylo pozorováno v roce 1932 (Pyšek et al. 2012a).

**Obr. 2:** Netvařec křovitý - květenství. Převzato z: <http://www.wmap.cz/opk/vmp/ros/ros16520.htm>

Co se týče invazního potenciálu v České republice, v posledních 15 letech bylo na netvařec křovitý pohlíženo různě a invazní status byl potvrzen relativně nedávno. Například ještě v roce 2000 byl doporučován jako doprovodný a břehový porost a do lužních lesů (Kender 2000 in Křivánek 2006a). S odlišným názorem pak přichází Buček (2002), který v té době zaznamenal jeho invazi v Srbsku a varuje před možnou invazí v České republice. Uvádí, že pozoroval šíření v nivě řeky Sávy západně od Bělehradu, kde se druh hojně vyskytoval právě v břehových porostech na přirozeném říčním břehu, v tvrdém luhu nebo také v rákosinách. Ve všech zmíněných biotopech byl velmi vitální, výrazně redukoval výskyt ostatních rostlinných druhů a znemožňoval tak přirozenou obnovu. Zmiňuje rovněž zprávu o šíření v Bulharsku. Také uvádí, že

netvařec křovitý má všechny potřebné vlastnosti, aby se mohl stát invazním druhem i v ČR, pravděpodobně zejména v teplejších oblastech, v údolních nivách velkých řek. Jedná se o druh s R - S populační strategií, vyznačuje se produkcí velkého množství semen, šíří se rovněž vegetativně kořenovými výmladky, snáší záplavy i sucho (Buček 2002).

Jako invazní druh pak označuje netvařec Křivánek (2006a), který uvádí, že je nebezpečný zejména v teplých oblastech na chudých písčitéch substrátech, kde byl často vysazován, neboť na kořenech vytváří hlízky s bakteriemi schopnými fixace vzdušného dusíku. Tím může výrazně obohacovat živinami chudá stanoviště, případně celkově měnit podmínky prostředí a vytlačovat tak původní druhy. Druh se údajně šíří převážně do polopřirozených křovinatých a suchých travních porostů, kde je místy hojný. Dále upozorňuje na možné šíření do příbřežních porostů a mokřadů vzhledem k jeho adaptacím v primárním areálu. Podobně na netvařec pohlíží Hroneš (2010). Označuje jej jako méně známou a prozatím podceňovanou invazní rostlinu a upozorňuje na nedostatek údajů o jeho současném výskytu na území ČR a tendencím k šíření. Dále zmiňuje, že je důležité monitorovat současné populace a zhodnotit managementové zásahy, pro které v současnosti není dostatek podkladů. Zmiňuje šíření podél silnic a řek, a jako stanoviště uvádí spíše vlhčí příkopy, okraje silnic či vzácněji břehy větších řek (obr. 3).

Pyšek et al. (2012a) řadí netvařec do skupiny druhů u nás dříve považovaných za invazní, které se však v současné době nešíří a jejich status proto není potvrzen. Dle Návrhu seznamů druhů vyžadujících zvláštní přístup (černý a šedý seznam), který



vypracovali Pergl et al. (2013) je druh zařazen „pouze“ do Šedého seznamu nepůvodních druhů ČR (grey list), což jsou druhy, jejichž výskyt a impakt by měl být určitým způsobem monitorován, nicméně nemusí být likvidovány. Baroš et al. (2014) považují netvařec za dřevinu nevhodnou pro výsadbu do venkovských sídel a označují jej potenciálně invazním druhem. Veselý (2015) řadí netvařec mezi nové nebezpečné druhy a v aktualizovaném Černém a šedém seznamu (Pergl et al. 2016) je již netvařec křovitý řazen do Černého seznamu (black list), konkrétně do kategorie BL2, což jsou druhy se středním ekologickým impaktem, jejichž šíření je výrazně podporováno lidskou činností.

**Obr. 3:** Porost netvařece křovitého. Foto: Michal Hroneš. Převzato z: <http://www.naturabohemica.cz/amorpha-fruticosa/>

### 2.2.2 Kustovnice cizí

Jedná se o opadavý, 1 – 3 m vysoký, bohatě větvený keř z čeledi *Solanaceae* (ilkovité). Větve jsou prutovité, obloukovitě převislé, s asi 5 mm dlouhými kolci. Rostlina kvete od května do srpna (září), květy jsou růžové až fialové, pětičetné (obr. 4). Plodem jsou drobné bobule, ve zralosti korálově červené (Sádlo 2001, Křivánek 2006b, Hoskovec 2008). Celá rostlina je údajně slabě až středně jedovatá (Křivánek 2006b), Hoskovec (2008) zároveň zmiňuje použití plodů v tradičním léčitelství v Číně, i když v mnohem menší míře než plody kustovnice čínské (*Lycium chinense*) označované jako gou qi (goji). Tento druh rozhodně nelze s kustovnicí cizí ztotožňovat (Sekerka 2010).

Původní areál kustovnice cizí není zcela jasný. Sekerka (2010) zahrnuje do areálu druhu Středomoří, teplejší oblasti Sibíře, Střední Asii, Mongolsko a severozápadní Čínu. Uvádí, že dle některých autorů je druh původní pouze ve Středomoří a ve zbývajících



oblastech zdomácnělý, jiní naopak uvádějí jako domovinu Střední Asii. Další uvádějí jako původní areál Čínu, což zmiňuje např. Křivánek (2006b). Pyšek et al. (2012b) považují za pravděpodobný původní areál rovněž Čínu. Ve východním Středomoří je výskyt druhu většinou udáván z člověkem silně ovlivněných lokalit, což znamená, že zde byl patrně spíše pěstován (Sádlo 2001).

**Obr. 4:** Kvetoucí kustovnice cizí. Převzato z: <http://www.wmap.cz/opk/vmp/ros/ros14651.htm>

Druh byl introdukován do mnoha dalších oblastí Evropy a Asie, dále do severní Afriky a severní Ameriky, přičemž první údaje o pěstování v ČR pocházejí z roku 1785. Hojně se pěstuje jako okrasná rostlina, je uváděna v 59 zámeckých parcích. Používána byla v živých plotech, pro stabilizaci půdy a ozelenění svahů, od 19. do poloviny 20. století byla podobně jako trnovník akát (*Robinia pseudoacacia*) vysazována podél železničních tratí. Je rovněž ceněna jako medonosná rostlina. V současnosti se pro zmíněné účely vysazuje jen zřídka (Sádlo 2001, Křivánek 2006b, Hoskovec 2008, Pyšek et al. 2012b).

Jedná se o světlomilný, suchomilný a teplomilný druh vyžadující hlubší, lehké, bazické, živinami bohaté půdy. Dobře snáší městské prostředí, je odolná vůči mrazu a exhalacím (Sádlo 2001, Křivánek 2006b, Pyšek et al. 2012b). Kustovnice cizí je v České republice známým invazním druhem - při neudržování výsadby velmi často zpláňuje (Křivánek 2006b). První zplanění bylo zaznamenáno již v roce 1870 (Pyšek et al. 2012a). Výskyt druhu je u nás soustředěn do teplejších oblastí - optimum růstu má v nížinách až pahorkatinách. V současné době se vyskytuje po celém území roztroušeně až hojně, zejména na sekundárních nebo narušených stanovištích, proniká však



i do přirozených společenstev (Křivánek 2006b, Pyšek et al. 2012b). Stanovištěm bývají neudržované suché svahy a skalnaté stráně, okolí silnic a železnic, náspy, hráze, terasy vinic nebo rumišť (Hoskovec 2008). Vyskytuje se také podél zdí v neudržované zástavbě (obr. 5).

Většina výskytů mimo výsadby vznikla výhradně vegetativním šířením, neboť v České republice se kustovnice semeny nerozmnožuje – plodnost není vysoká, semena mají velmi nízkou klíčivost a semenáčky se tudíž neujmou. Na větší vzdálenosti se šíří prostřednictvím úlomků kořenů nebo větví, které vznikají a šíří se v souvislosti s disturbancemi (např. zemní práce) a velmi snadno pak zakořeňují. Kustovnice má mohutný, hluboko kořenicí kořenový systém, z jehož výběžků často vytváří rozsáhlé porosty. Ty mohou být jak řídké a nízké (1 – 1,5 m) na extrémně suchých, kamenitých stanovištích, tak husté a silně dominantní, vysoké 2 – 4 m, pod kterými se vytváří kompaktní, až 1 m silná vrstva odumřelých větví. Vzácně keř tvoří i liánovité porosty (Sádlo 2001, Pyšek et al. 2012b).

Druh je díky schopnosti svými převislými větvemi rychle zaujmout prostor velmi silnou konkurencí pro ostatní druhy. Husté porosty kustovnice proto bývají zcela bez podrostu. Značně rizikové je pak šíření do přirozených porostů, zejména hodnotných biotopů mezofilních až xerofilních křovin, trávníků a stepních strání, kde by měly být porosty neprodleně likvidovány. Výskyt kustovnice cizí lze tolerovat pouze na stanovištích, která nemohou být ohniskem další invaze do přirozených porostů, tedy např. v sídlištích (Sádlo 2001, Křivánek 2006b).

Zdá se, že invaze kustovnice cizí v České republice již dosahuje vrcholné fáze – současné populace se udržují, případně zvyšují početnost či plochu a nová stanoviště již rostlina tak často neobsazuje (Pyšek et al. 2012b). V aktualizovaném Černém a šedém seznamu (Pergl et al. 2016) je řazena do Černého seznamu (black list), kategorie BL2.



**Obr. 5:** Kustovnice cizí 18. 9. 2008 v Českém Brodu. Převzato z: <http://botany.cz/cs/lycium-barbarum>

## 3 METODIKA

### 3.1 Příprava vstupních dat

Vlastnímu modelování předchází úprava získaných dat dle zvolené modelovací metody. Nejprve je třeba patřičně upravit data o výskytu, dalším krokem je přesné vymezení zájmové oblasti, volba vhodného rozlišení pro modelování a výběr jednotného souřadnicového systému, do kterého budou převedena všechna vstupní data.

Zájmovou oblastí je území vymezené hranicemi ČR. Zvolené rozlišení pro modelování je 100 x 100 m, použitý souřadnicový systém je S-JTSK. Pro zpracování dat, jejich analýzu a tvorbu mapových výstupů byl použit software ArcGIS 10.2 for Desktop.

#### 3.1.1 Data o výskytu

Data o výskytu netvařce křovitého a kustovnice cizí na území České republiky byla poskytnuta z Nálezové databáze ochrany přírody © AOPK ČR 2015. Data jsou ve formátu vektorových vrstev (.shp), jedná se o bodovou, liniovou a polygonovou vrstvu, přičemž každá z nich obsahuje souhrnně nálezy zájmových druhů. Společně s vektorovými vrstvami byla poskytnuta atributová tabulka se specifikací jednotlivých prvků, kterou je k vrstvám nutné připojit. Protože se jedná jak o nálezy bodové, liniové tak plošné, bylo potřeba data upravit tak, aby byla získána pouze bodová vrstva reprezentující jednotlivé výskyty.

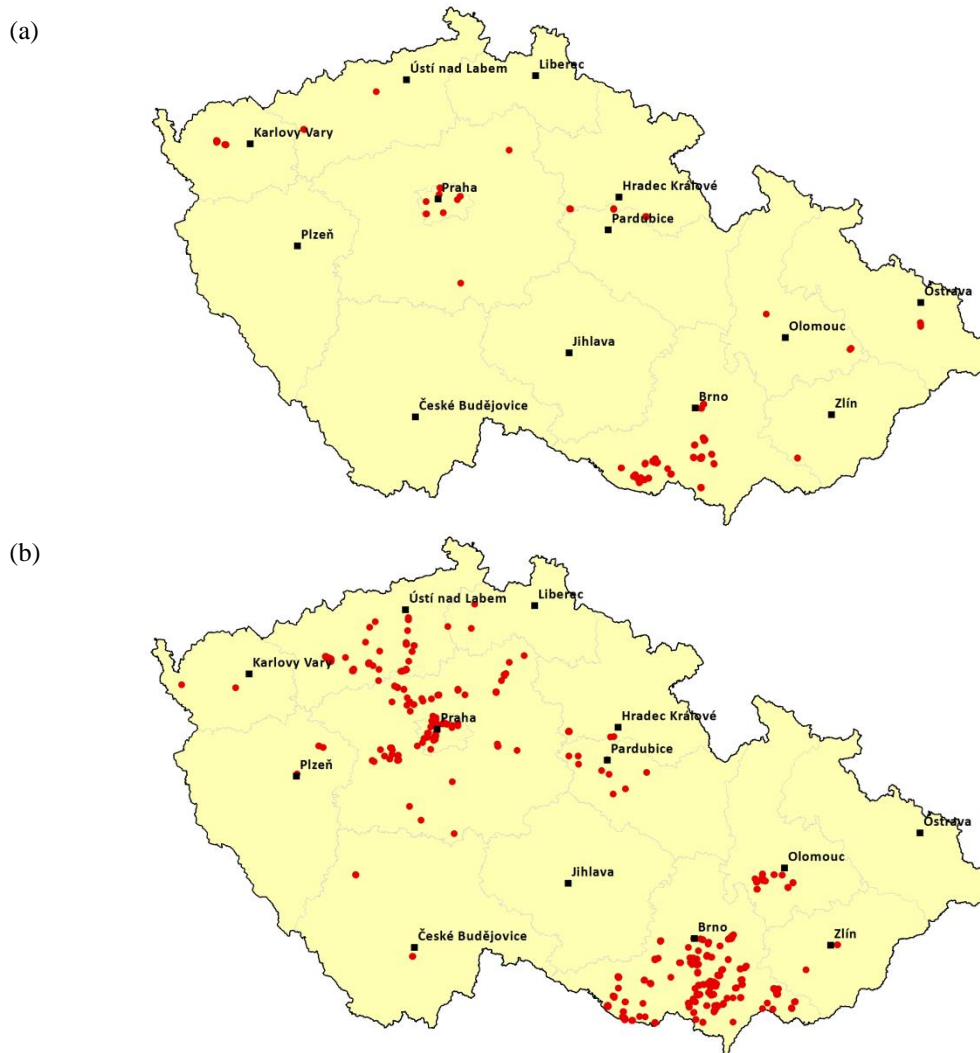
Prvním krokem byla příprava čtvercové sítě v rozlišení 100 x 100 m vymezená hranicemi České republiky. Pro tvorbu sítě jsem využila funkci *Create Fishnet*, kde vstupem byla vrstva hranic z databáze ArcČR® 500 v3.2, výstupem je polygonová vrstva představující síť čtverců o zvolené velikosti. Výsledná síť je tvořena 7 900 773 čtverci.

Aby data časově odpovídala prediktorům, byly z atributové tabulky se specifikací nálezů vybrány pouze záznamy z let 2000 - 2015. Takto vzniklá tabulka byla následně dle druhu rozdělena do dvou dílčích tabulek, se kterými byly propojeny bodové, liniové a polygonové vrstvy. Data pro každý druh jsem exportovala do nových vrstev, aby bylo možné s nimi dále pracovat. Po jejich podrobnějším prostudování jsem se rozhodla pro vyřazení některých polygonových nálezů z důvodu jejich nepřesného charakteru. Jednalo se především o nálezy charakteru mapovacích čtverců, které poskytovaly pouze rámcovou informaci o výskytu druhu v dané oblasti, nebylo však k dispozici přesnější prostorové vymezení. Rozloha těchto ploch se navíc pohybovala od cca 1,3 až do 8 km<sup>2</sup>, což mnohonásobně převyšuje použité rozlišení s velikostí čtverce 1 ha. Pokud by byly použity i tyto nálezy, došlo by k zařazení mnoha bodů s nepravdivou prezencí.

Další krok spočíval v přenesení zpracovaných nálezových dat do připravené čtvercové sítě, k čemuž byl použit nástroj *Select by Location*. Jako cílová vrstva,

ve které mají být prvky vybrány, byla zvolena čtvercová síť a jako zdrojové vrstvy nálezy pro daný druh, které byly promítnuty do čtvercové sítě. Pro všechny bodové a liniové nálezy byla zvolena metoda *intersect the source layer feature*. Pro některé polygonové nálezy bylo vhodnější vybrat pouze čtverce, které mají v polygonech své středy (*have their centroid in the source layer feature*), např. polygony těsně sousedící s plochami odlišného krajiného pokryvu - tak byl omezen např. výběr čtverců s převažující ornou půdou, která neodpovídá skutečným nárokům druhu. V případě polygonových nálezu liniového charakteru a příliš malé rozlohy byla zvolena opět metoda *intersect the source layer feature*, aby nedošlo k vyřazení těchto nálezu.

Takto jsem získala čtverce obsazené daným druhem. Celkový počet obsazených čtverců je pro netvařec křovitý 301 (obr. 6a) a pro kustovnici cizí 1 226 (obr. 6b).



**Obr. 6:** Orientační mapy zobrazující výskyt (a) netvařce křovitého a (b) kustovnice cizí na území České republiky v letech 2000 – 2015. Červeně vyznačené body odpovídají středům obsazených čtverců. Data: © AOPK ČR, ArcČR 500.

Ze čtverců jsem následně pro každý druh vygenerovala funkcí *Feature to Point* bodovou vrstvu, kde body představují středy obsazených čtverců. V atributových tabulkách bodových vrstev jsem přidala tři nové sloupce: *species*, *X* a *Y*, do kterých byly vloženy požadované hodnoty. Sloupec *species* představuje název druhu, sloupce *X* a *Y* zeměpisné souřadnice daného bodu v systému S-JTSK. K určení souřadnic jsem použila nástroj *Calculate Geometry* v atributové tabulce. Vytvořené tabulky jsem poté převedla do formátu *.xls (Table to Excel)* a v softwaru Microsoft Excel provedla jejich konečnou úpravu, která spočívala v ponechání pouze 3 požadovaných sloupců, tedy *species*, *X* a *Y* a uložení ve formátu *.csv*. V této formě jsou vstupní data o výskytu připravena pro import do softwaru Maxent.

### 3.1.2 Prediktory

První krok přípravy prediktorů spočívá ve vytvoření rastrových vrstev představující faktory prostředí, které by potenciálně mohly mít vliv na distribuci zájmových druhů (Pearson 2010). Výsledné rastry musí mít zcela shodný prostorový rozsah, rozlišení (velikost buňky) a souřadnicový systém. Přehled prediktorů, vstupních dat a jejich zdrojů viz tab. 5.

#### **Prediktory odvozené z digitálního modelu terénu**

##### Nadmořská výška

Prediktor nadmořské výšky byl vytvořen z digitálního modelu terénu NASA SRTM V3.0 v rozlišení 3 úhlové vteřiny (~ 60 x 90 m). Prvním krokem byla projekce do souřadnicového systému S-JTSK s využitím funkce *Project Raster*. Rastrová vrstva byla poté převzorkována na rozlišení 100 x 100 m a oříznuta na rozsah zájmové oblasti funkcí *Extract by Mask*.

Z digitálního modelu terénu NASA SRTM V3.0 v původním rozlišení 60 x 90 m byly odvozeny další proměnné. Postup jejich přípravy popsán níže.

##### Svažitost terénu (*slope*)


Svažitost byla vypočtena pomocí funkce *Slope*, zvolené jednotky jsou stupně. Poté byl rastr převzorkován na požadované rozlišení 100 x 100 m a oříznut na rozsah zájmové oblasti.

##### Expozice (*aspect*)

Odvození bylo provedeno s využitím funkce *Aspect*. Dále byl rastr převzorkován na požadované rozlišení 100 x 100 m a oříznut na rozsah zájmové oblasti. Výstupem funkce *Aspect* je spojitá proměnná, která vyjadřuje expozici ve stupních (0 – 360), buňkám s všesměrnou expozicí (rovina) je přiřazena hodnota -1 (obr. 7).

Protože má tato proměnná specifický charakter, pro lepší interpretaci jsem ji převedla na kategoriální proměnnou a rozdělila hodnoty do celkem devíti kategorií (kategorie *North* sloučeny do jedné) dle obr. 1 (funkce *Reclassify*). V případě, že by expozice nabývala pouze hodnot od 0 do 360, bylo by možné provést transformaci a vytvořit proměnné *northness* a *eastness*.

**Obr. 7:** Klasifikace hodnot expozice z automatického výstupu funkce *Aspect*.



## Další významné prediktory

### Vzdálenost od vodních toků

Vodní toky jsou významným vektorem šíření invazních druhů rostlin, proto jsem zařadila prediktor vyjadřující vzdálenost od vodních toků. Pro výpočet byla použita funkce *Euclidean Distance*, vstupními daty byly liniové vrstvy vodních toků, které jsou zdarma dostupné ke stažení z databáze DIBAVOD. Byly vytvořeny dva prediktory, zvláště pro hrubé a jemné úseky vodních toků. Pro tvorbu byl využit nástroj ModelBuilder.

### Vzdálenost od komunikací

Dalším významným vektorem šíření invazních rostlin jsou silnice a železnice. Nejprve jsem sloučila do jedné vrstvy vrstvy silnic a železnic (funkce *Merge*) stažené z databáze ArcČR<sup>®</sup> 500 v3.2, čímž jsem získala vstupní liniovou vrstvu komunikací. Následně jsem postupovala stejným způsobem jako u vzdálenosti od vodních toků.

### Krajinný pokryv

Prediktory byly vytvořeny z rastrové vrstvy CORINE Land Cover 2006. CORINE Land Cover je projekt koordinovaný Evropskou agenturou pro životní prostředí, do kterého je v současné době zapojeno již 39 evropských zemí. Jeho výstupem je databáze vrstev s klasifikací pokryvu zemského povrchu, která je součástí programu Copernicus pro monitorování území. V databázi je celkem 44 tříd (kategorií) krajinného pokryvu, které jsou klasifikovány na třech úrovních. Základní úroveň rozděluje kategorie do 5 skupin, druhá úroveň do 15 skupin a třetí, nejpodrobnější úroveň představuje jednotlivých 44 kategorií označených třímístným číselným kódem.

Data o krajinném pokryvu pro rok 2006 jsou ve formě rastru o rozlišení 100 x 100 m zdarma dostupná pro území Evropy na portálu EEA. Na území ČR se vyskytuje 29 kategorií (tab. 3). Vytvořila jsem celkem tři prediktory odpovídající jednotlivým výše zmíněným úrovním klasifikace. Nejprve jsem provedla projekci do souřadnicového systému S-JTSK pouze pro zájmovou oblast a výsledný rastr ořízla funkcí *Extract by Mask* tak, aby měl zcela shodný prostorový rozsah s dalšími prediktory. Takto vytvořený rastr odpovídá nejpodrobnější klasifikaci a obsahuje 29 tříd krajinného pokryvu (tab. 3). Následnou úpravou byla změna původních hodnot buněk rastru funkcí *Reclassify* na příslušné třímístné kódy dle legendy, která byla součástí dat. Takto připravený prediktor byl základem pro prediktory v dalších úrovních klasifikace. Úprava spočívala ve sloučení kategorií do skupin změnou hodnot rastru opět s využitím funkce *Reclassify* tak, že první dvě číslice třímístného kódu představují druhou úroveň a první číslice základní úroveň (tab. 1 a 2). Pro přehlednost výstupů modelu bylo nakonec potřeba u nejpodrobnější klasifikace změnit třímístné kódy na hodnoty od 0 do 28 funkcí *Reclassify* (tab. 3).

**Tab. 1:** Základní klasifikace CLC – přehled kategorií.

Kód (hodnota)	Kategorie
1	urbanizovaná území
2	zemědělské plochy
3	lesy a polopřirodní oblasti
4	humidní území
5	vodní plochy

**Tab. 2:** Druhá úroveň klasifikace CLC – přehled kategorií vyskytujících se v ČR.

Kód (hodnota)	Kategorie	Kód (hodnota)	Kategorie
11	Obytné plochy	24	Různorodé zemědělské plochy
12	Průmyslové a obchodní zóny, komunikační síť	31	Lesy
13	Doly, skládky a staveniště	32	Plochy s křovinnou a travnatou vegetací
14	Plochy umělé, nezemědělské zeleně	33	Otevřené plochy s malým zastoupením vegetace nebo bez vegetace
21	Orná půda	41	Vnitrozemská humidní území
22	Trvalé kultury	42	Přímořská humidní území
23	Pastviny	51	Pevninské vody

**Tab. 3:** Přehled kategorií CORINE Land Cover vyskytujících se na území ČR.

Kód	Hodnota	Kategorie	Kód	Hodnota	Kategorie
111	0	Souvislá městská zástavba	242	15	Směs polí, luk a trvalých kultur
112	1	Nesouvislá městská zástavba	243	16	Zemědělské oblasti s příměsí přirozené vegetace
121	2	Průmyslové a obchodní areály	311	17	Listnaté lesy
122	3	Silniční a železniční síť s okolím	312	18	Jehličnaté lesy
123	4	Přístavy	313	19	Smíšené lesy
124	5	Letiště	321	20	Přírodní louky
131	6	Oblasti současné těžby surovin	322	21	Stepi a křoviny
132	7	Haldy a skládky	324	22	Přechodová stadia lesa a křoviny
133	8	Staveniště	332	23	Skály
141	9	Plochy městské zeleně	333	24	Oblasti s řídkou vegetací
142	10	Sportovní a rekreační plochy	411	25	Vnitrozemské bažiny
211	11	Nezavlažovaná orná půda	412	26	Rašeliniště
221	12	Vinice	511	27	Vodní toky a cesty
222	13	Sady, chmelnice a zahradní plantáže	512	28	Vodní plochy
231	14	Louky a pastviny			

### Klimatické prediktory

Data byla získána z databáze WorldClim, což je celosvětová databáze klimatických prostorových dat. Nejpodrobnější dostupné rozlišení je 30 úhlových vteřin, což odpovídá přibližně 1 x 1 km (0,93 x 0,93 km). Kromě dat o současných klimatických podmínkách, která byla odvozena interpolací dat z meteorologických stanic a pozorování z let 1950 - 2000, jsou dostupná rovněž data o podmínkách v minulosti a budoucnosti.

Součástí databáze jsou bioklimatické prediktory (Bioclim), které byly odvozeny z původních měsíčních dat (teploty a srážkové úhrny) za účelem získání proměnných, které jsou významnější z hlediska vlivu na distribuci organismů. Celkem je k dispozici 19 proměnných vyjadřující roční trendy, sezónnost i extrémní nebo limitující faktory prostředí (tab. 4). V nejpodrobnějším rozlišení je možné data stáhnout jako rastrové vrstvy pro vybranou oblast. Úprava do požadované formy spočívala v převodu do systému S-JTSK, převzorkování na velikost buňky 100 x 100 m a oříznutí v rozsahu zájmové oblasti. Teplota je vyjádřena v °C\*10, srážkové úhrny v mm.

**Tab. 4:** Přehled dostupných bioklimatických prediktorů z databáze Worldclim.

BIO1	Průměrná roční teplota	BIO11	Průměrná teplota v nejméně chladném čtvrtletí
BIO2	Průměrný denní rozsah teplot	BIO12	Roční úhrn srážek
BIO3	Isotermalita	BIO13	Úhrn srážek v nejdeštivějším měsíci
BIO4	Sezónnost teploty	BIO14	Úhrn srážek v nejsušším měsíci
BIO5	Maximální teplota v nejteplejším měsíci	BIO15	Sezónnost srážek
BIO6	Minimální teplota v nejméně chladném měsíci	BIO16	Úhrn srážek v nejdeštivějším čtvrtletí
BIO7	Roční rozsah teplot	BIO17	Úhrn srážek v nejsušším čtvrtletí
BIO8	Průměrná teplota v nejdeštivějším čtvrtletí	BIO18	Úhrn srážek v nejteplejším čtvrtletí
BIO9	Průměrná teplota v nejsušším čtvrtletí	BIO19	Úhrn srážek v nejméně chladném čtvrtletí
BIO10	Průměrná teplota v nejteplejším čtvrtletí		

Je obecně známo, že klimatické proměnné jsou vzájemně značně korelované a mnoho z nich je navíc korelováno s prediktorem nadmořské výšky. Do výsledného modelu proto většina z nich patrně nebude zahrnuta. Postup výběru prediktorů popsán v další kapitole.

**Tab. 5:** Přehled vytvořených prediktorů a vstupních dat.

Prediktor	Vstupní data	Zdroj dat	Souřadnicový systém
Nadmořská výška	DEM NASA SRTM V3.0 3 arcsec	U.S. Geological Survey <a href="http://gdex.cr.usgs.gov/gdex/">http://gdex.cr.usgs.gov/gdex/</a>	WGS 84
Svažitosť terénu	DEM NASA SRTM V3.0 3 arcsec	U.S. Geological Survey <a href="http://gdex.cr.usgs.gov/gdex/">http://gdex.cr.usgs.gov/gdex/</a>	WGS 84
Expozice	DEM NASA SRTM V3.0 3 arcsec	U.S. Geological Survey <a href="http://gdex.cr.usgs.gov/gdex/">http://gdex.cr.usgs.gov/gdex/</a>	WGS 84
Vzdálenost od vodních toků	Liniové vrstvy vodních toků	DIBAVOD <a href="http://www.dibavod.cz/index.php?id=27">http://www.dibavod.cz/index.php?id=27</a>	S-JTSK
Vzdálenost od komunikací	Liniové vrstvy silnic a železnic	ArcČR 500 verze 3.2 <a href="https://www.arcdata.cz/produkty/geograficka-data/arccr-500">https://www.arcdata.cz/produkty/geograficka-data/arccr-500</a>	S-JTSK
Krajinný pokryv	CORINE Land Cover 2006	European Environment Agency <a href="http://www.eea.europa.eu/data-and-maps/data/corine-land-cover-2006-raster-3">http://www.eea.europa.eu/data-and-maps/data/corine-land-cover-2006-raster-3</a>	ETRS 1989 LAEA
Bioklimatické prediktory	Bioclim BIO1 – BIO19	WorldClim <a href="http://worldclim.org">http://worldclim.org</a>	WGS 84



Druhým krokem přípravy prediktorů bylo převedení vytvořených rastrů do formátu ASCII, což je požadovaný formát pro použití metody Maxent. K tomu jsem použila funkci *Raster to ASCII*, která automaticky generuje formát .txt, proto bylo třeba přepsat koncovku na .asc. Všechny prediktory jsem následně uložila do připravené složky.

### 3.2 Výběr prediktorů

Před vlastním modelováním je potřeba posoudit, zda budou v modelech použity všechny z připravených prediktorů. V tab. 6 jsou pro přehlednost uvedeny vybrané prediktory, jejich označení a charakter. Metodika výběru popsána níže.

**Tab. 6:** Přehled prediktorů vybraných pro použití v modelech.

Prediktor		Označení	Typ proměnné
Nadmořská výška		elev	spojitá
Svažítost terénu		slope	spojitá
Expozice		aspect	kategoriální - 9 kategorií
Vzdálenost od vodních toků	jemné úseky	dist_v1	spojitá
	hrubé úseky	dist_v2	spojitá
Vzdálenost od komunikací		dist_k	spojitá
Krajinný pokryv	základní úroveň	clc_1	kategoriální - 5 kategorií
	druhá úroveň	clc_2	kategoriální - 13 kategorií
	třetí úroveň	clc_3	kategoriální - 29 kategorií
Isotermalita		bio3	spojitá
Roční rozsah teplot		bio7	spojitá
Průměrná teplota v nejsušším čtvrtletí		bio9	spojitá
Sezónnost srážek		bio15	spojitá

Při modelování je důležité zamezit současné přítomnosti významně korelovaných prediktorů, což je jev zvaný multikolinearita (Franklin 2009). Jedním z kritérií výběru tedy může být posouzení míry korelace s využitím výpočtu korelačního koeficientu, který je však možné použít pouze pro prediktory spojitého charakteru.

Vytvoření korelační matice, která souhrnně vyjadřuje hodnoty korelačních koeficientů pro jednotlivé dvojice prediktorů, umožňuje funkce *Band Collection Statistics*. Automatickým výstupem funkce jsou základní statistické ukazatele pro jednotlivé proměnné, po zaškrtnutí volby *Compute covariance and correlation matrices* je výstupem rovněž korelační matice.

V prvním kroku byly vypočteny korelace pro všechny spojitě proměnné vyjma bioklimatických proměnných, tedy nadmořskou výšku, svažítost, vzdálenost od vodních toků a vzdálenost od komunikací. Jak ukazuje tab. 7, žádné z těchto prediktorů nejsou

těsně korelované, a je tedy možné je společně použít v modelech. Kategorické proměnné, tedy expozici a krajinný pokryv, jsem do modelu zařadila automaticky. V případě vzdálenosti od vodních toků a krajinného pokryvu jsem zvolila vždy pouze jeden z prediktorů reprezentující daný faktor na základě významnosti a reakce druhů na prediktor zjištěné po vytvoření prvního modelu. Pro každý druh jsem poté vytvořila konečný model, kde vzdálenost od vodních toků reprezentuje jeden z prediktorů *dist\_v1* a *dist\_v2* a krajinný pokryv jeden z prediktorů *clc\_1*, *clc\_2* a *clc\_3*. (tab. 6).

**Tab. 7:** Korelační matice vyjadřující míru korelace vybraných prediktorů.

Prediktor	elev	slope	dist_v1	dist_v2	dist_k
elev	1,00000	0,39494	-0,11870	0,02430	0,21978
slope	0,39494	1,00000	-0,08339	-0,03886	0,18646
dist_v1	-0,11870	-0,08339	1,00000	0,50709	0,05395
dist_v2	0,02430	-0,03886	0,50709	1,00000	0,11281
dist_k	0,21978	0,18646	0,05395	0,11281	1,00000

Dalším krokem byl výběr bioklimatických prediktorů. Protože do modelu bude zařazen prediktor nadmořské výšky, nejprve jsem určila míru korelace této proměnné se všemi bioklimatickými prediktory (tab. 8).

**Tab. 8:** Korelace bioklimatických prediktorů s nadmořskou výškou.

	elev		elev		elev		elev		elev
bio1	-0,9217	bio5	-0,8475	bio9	-0,3041	bio13	0,6827	bio17	0,7895
bio2	-0,3793	bio6	-0,8067	bio10	-0,9093	bio14	0,7955	bio18	0,7040
bio3	-0,1153	bio7	-0,5725	bio11	-0,8693	bio15	-0,5432	bio19	0,7760
bio4	-0,7227	bio8	-0,9087	bio12	0,7993	bio16	0,7040		

Nejvyšších hodnot korelačního koeficientu (více než 0,9) bylo dosaženo v případě proměnných *bio1*, *bio8* a *bio10*, vysoké hodnoty (0,7 – 0,9) nabýval korelační koeficient rovněž u většiny zbývajících proměnných - *bio4*, *bio5*, *bio6*, *bio11*, *bio12*, *bio14*, *bio16*, *bio17*, *bio18* a *bio19*. Poměrně vysoké hodnoty bylo dosaženo i v případě prediktoru *bio13*. Rozhodla jsem se pro vyřazení všech těchto prediktorů, neboť podstatnou část informace, kterou obsahují, nese již prediktor nadmořské výšky.

Nejméně korelovaný s nadmořskou výškou je prediktor *bio3*, dále *bio9*, *bio2*, *bio15* a *bio7*. U těchto prediktorů jsem následně posoudila jejich vzájemné korelace (tab. 9). Na základě zjištěných hodnot jsem vyřadila prediktor *bio2*.

**Tab. 9:** Vzájemné korelace vybraných bioklimatických prediktorů, tučně označeny vysoké hodnoty.

Prediktor	bio2	bio3	bio7	bio9	bio15
bio2	1,0000	<b>0,8678</b>	<b>0,8842</b>	0,4285	0,3079
bio3	<b>0,8678</b>	1,0000	0,5665	0,4069	0,1165
bio7	<b>0,8842</b>	0,5665	1,0000	0,3446	0,4560
bio9	0,4285	0,4069	0,3446	1,0000	-0,3232
bio15	0,3079	0,1165	0,4560	-0,3232	1,0000

### 3.3 Tvorba modelu

Pro vytvoření modelů jsem využila samostatný software Maxent verze 3.3.3k dostupný na <https://www.cs.princeton.edu/~schapire/maxent/>, kde je možné získat rovněž doplňující literaturu a tutorial (Phillips et al. 2004, 2006, 2008). Další použitý tutorial viz Young et al. (2011).

#### 3.3.1 Import vstupních dat

Nejprve jsem vložila soubor s daty o výskytu druhu ve formátu .csv (panel *Samples*), dále jsem nastavila cestu ke složce obsahující prediktory ve formátu .asc (panel *Environmental layers*), ze které program automaticky soubory nahraje a načte jejich seznam. V prostředí programu jsem poté zvolila typ proměnných - spojitá (*continuous*) nebo kategoriální (*categorical*). Nakonec jsem v poli *Output directory* vybrala příslušnou složku pro uložení výstupů.

#### 3.3.2 Interpretace výstupů

Všechny zvolené výstupy modelu jsou shrnuty v souboru .html, který je uložen ve složce s vlastními výstupními soubory. Důležitý je soubor .asc, který vyjadřuje pravděpodobnost výskytu pro každou buňku studované oblasti. Tento soubor jsem převedla do formátu rastru funkcí *ASCII to Raster* a následně vytvořila mapy potenciálního rozšíření. Program umožňuje tvorbu dalších výstupů, které jsem rovněž zařadila do výsledků práce. Tyto výstupy jsem využila zejména pro posouzení významnosti jednotlivých prediktorů a reálnosti modelu z hlediska reakce druhů na faktory prostředí.

Maxent odvozuje pro jednotlivé prediktory tzv. *features*, které představují jejich matematickou transformaci (*linear, quadratic, product, threshold, hinge*). Jejich význam je znázorněn graficky křivkami reakce druhu na prediktor (*Response curves*), kde na ose y je predikovaná pravděpodobnost a na ose x hodnoty daného prediktoru. Tyto křivky jsou důležitým nástrojem k posouzení ekologické věrohodnosti modelu, přičemž na zvoleném typu *features* pak závisí možný tvar křivek. Výchozí nastavení zahrnuje použití všech typů (volba *Auto features*), Merow et al. (2013) však doporučují zařadit

*linear*, *quadratic* a *hinge* features, protože lépe odhadují skutečnou reakci druhu na většinu faktorů a jsou snáze interpretovatelné. Program generuje dvě sady grafů – první vyjadřuje, jak se mění predikovaná pravděpodobnost, mění-li se hodnota daného prediktoru a další prediktory jsou ponechány na jejich průměrné hodnotě, druhá sada ukazuje totéž bez vlivu ostatních prediktorů (prediktor je zařazen samostatně) a je tedy vhodnější pro interpretaci, zejména v případě možné korelace a interakcí.

K určení významnosti a přispění jednotlivých prediktorů jsem využila *Analysis of variable contributions*. Automatickou součástí této analýzy je tabulka, která poskytuje odhad procentuální hodnoty přispění jednotlivých prediktorů do modelu. Druhou volitelnou součástí jsou grafy testu *jackknife* (*Jackknife test of variable importance*). Tento test provádí analýzu významnosti prediktorů tak, že je nejprve vytvořen model bez daného prediktoru, poté je prediktor použit samostatně a nakonec je vytvořen model, kde jsou použity všechny prediktory. Výsledky jsou porovnány na základě třech kritérií - *regularized training gain*, *test gain* a *AUC*. Z výsledných grafů je pak patrné, který prediktor nejvíce zvýšil, případně snížil (byl-li vyřazen) hodnoty zmíněných kritérií. *Gain* je ukazatelem toho, do jaké míry je fitovaný model lepší v predikci než náhodný model (hodnota 0), to znamená, jak těsně je model soustředěn okolo vstupních prezenčních dat. Maximalizace *gain* tak odpovídá nalezení modelu, který je schopen nejlépe odlišit *presence* lokality od *background* lokalit (Merow et al. 2013). Z toho vyplývá, že čím vyšší hodnoty *gain* je pro daný prediktor dosaženo, tím vyšší je patrně jeho predikční význam.


Dalším volitelným výstupem je model ve formátu *.png* (*Pictures of the model*), který vyjadřuje barevně predikovanou pravděpodobnost pro každou buňku zájmové oblasti a slouží tedy rovněž jako mapa pravděpodobnosti výskytu.

### 3.3.3 Ověření přesnosti

Přesné a spolehlivé ověření přesnosti modelu vyžaduje použití testovacího vzorku dat (*test data*), který byl získán nezávisle na datech pro tvorbu modelu (*training data*) (Guisan et Zimmermann 2000). Protože takový vzorek často není k dispozici, používají se validační techniky založené na rozdělení datového souboru do nezávislých podsouborů. Zvolila jsem často používanou techniku krosvalidace (*crossvalidation*), která odhaduje objektivnost modelu pomocí opakovaného použití pozorování. Datový soubor je rozdělen do  $k$  nezávislých podsouborů, přičemž jeden podsoubor je vždy použit pro testování ostatních  $k-1$  podsouborů pro tvorbu modelu. Celkem je tedy vytvořeno  $k$  modelů otestovaných na  $k$  testovacích souborech (obr. 8) (Komprdová 2012).

Křížová validace je doporučována, protože efektivně využívá všechna dostupná data a zároveň je určena variabilita, směrodatná odchylka, průměr a další ukazatele, což umožňuje odhalit případné odchylky či nepřesnosti ve výstupech a mezi modely

(Phillips 2008, Merow et al. 2013). Výsledky křížové validace jsou uloženy v souhrnných výstupních souborech a rovněž v souhrnném souboru ve formátu stránky .html.




**Obr. 8:** Princip rozdělení datového souboru do  $k$  skupin (Borovička et al. 2012).

Pro posouzení přesnosti modelů jsem použila statistiku AUC (*Area under the receiver operating characteristic curve (ROC)*), která je součástí výstupu modelu Maxent. Jedná se o standardně používané kritérium pro posouzení predikční schopnosti modelů druhové distribuce. Křivka ROC znázorňuje vztah *sensitivity (Se)*, což je podíl prezencí správně predikovaných jako prezence a *specificity (Sp)*, což je podíl absencí správně predikovaných jako absence, tak, že na ose x je vynesena  $Se$  a na ose y  $1 - Sp$ , což je podíl absencí nesprávně predikovaných jako prezence (*comission error*). Pokud pro daný model leží křivka ROC nad diagonální přímkou odpovídající náhodnému modelu ( $AUC = 0,5$ ), tento model má lepší predikční schopnost než by byla predikce náhodná. V případě ideálního modelu je dosažena 100 % *sensitivita* a zároveň *specificita* (minimální *comission error*) a hodnota AUC je rovna 1. Při použití AUC ke zhodnocení modelů presence-only, které místo absencí pracují s daty background, je graf ROC modifikován tak, že namísto  $1 - Sp$  je na ose x vynesena podíl bodů background predikovaných jako prezence (*fractional predicted area*) a je tedy možné tyto modely rovněž hodnotit dle kritéria AUC (obr. 9) (Phillips et al. 2006, Jiménez-Valverde 2012).

Merow et al. (2013) však upozorňují, že hodnoty AUC mohou být v případě modelů presence-only zavádějící. Vysoké hodnoty AUC zde indikují skutečnost, že model je schopný dobře rozlišit *presence* lokality od potenciálně nezmapovaných lokalit (*background*). *Background* data v sobě však často zahrnují jak prezence, tak absence, zvláště pokud prezenční data nepochází ze systematického průzkumu, tedy že pro jejich získání nebylo vyvinuto dostatečné úsilí. Proto je nejvhodnější použít AUC v případě, jsou-li k dispozici prezenční data pocházející ze systematického mapování, je-li druh v rovnováze s prostředím a *background* data jsou volena manuálně (Merow et al. 2013). Při modelování invazních druhů, zvláště jsou-li v raných stádiích invazního procesu, tyto předpoklady často splněny nejsou (Václavík et Meentemeyer 2012). Merow et al. 2013

ale zároveň uvádí, že neexistuje mnoho alternativních kritérií pro posouzení přesnosti modelů presence-only.



**Obr. 9:** Modifikace ROC pro prezenční a background data (Phillips 2008).

### 3.3.4 Nastavení parametrů

Zvolila jsem typ výstupu, který je nastaven jako výchozí, tedy logistický (*logistic*). Jedná se o nejsnáze interpretovatelný formát, který poskytuje odhad pravděpodobnosti výskytu druhu vyjádřený hodnotou v intervalu 0 až 1. Následně jsem zaškrtnutím možností *Create response curves*, *Make pictures of predictions* a *Do jackknife to measure variable importance* nastavila vytvoření výše uvedených výstupů. Namísto automaticky nastavených *Auto features* jsem zaškrtnula pouze *Linear*, *Quadratic* a *Hinge features*.

Počet bodů „background“ (*Max number of background points*) jsem ponechala na doporučené, automaticky nastavené hodnotě 10 000. V záložce *Advanced* jsem zvýšila *Maximum iterations* na 1000, což poskytne modelu dostatek času pro správné vyhodnocení predikce (maximalizace *gain*) (Young et al. 2011).

Posledním, důležitým krokem bylo nastavení parametrů umožňující testování přesnosti modelu. Bez tohoto nastavení by byl pro fitování i testování použit tentýž vzorek dat (*training*), což by vedlo k nadhodnocení výkonnosti modelu (Young et al. 2011). Tyto parametry jsem nastavila v panelu *Settings* v záložce *Basics*. Pro testování jsem zvolila *Crossvalidate (Replicated Run Type)*, počet opakování (*Replicates*) jsem nastavila na hodnotu 10, která je často uváděna v literatuře.

## 4 VÝSLEDKY

### 4.1 Netvařec křovitý

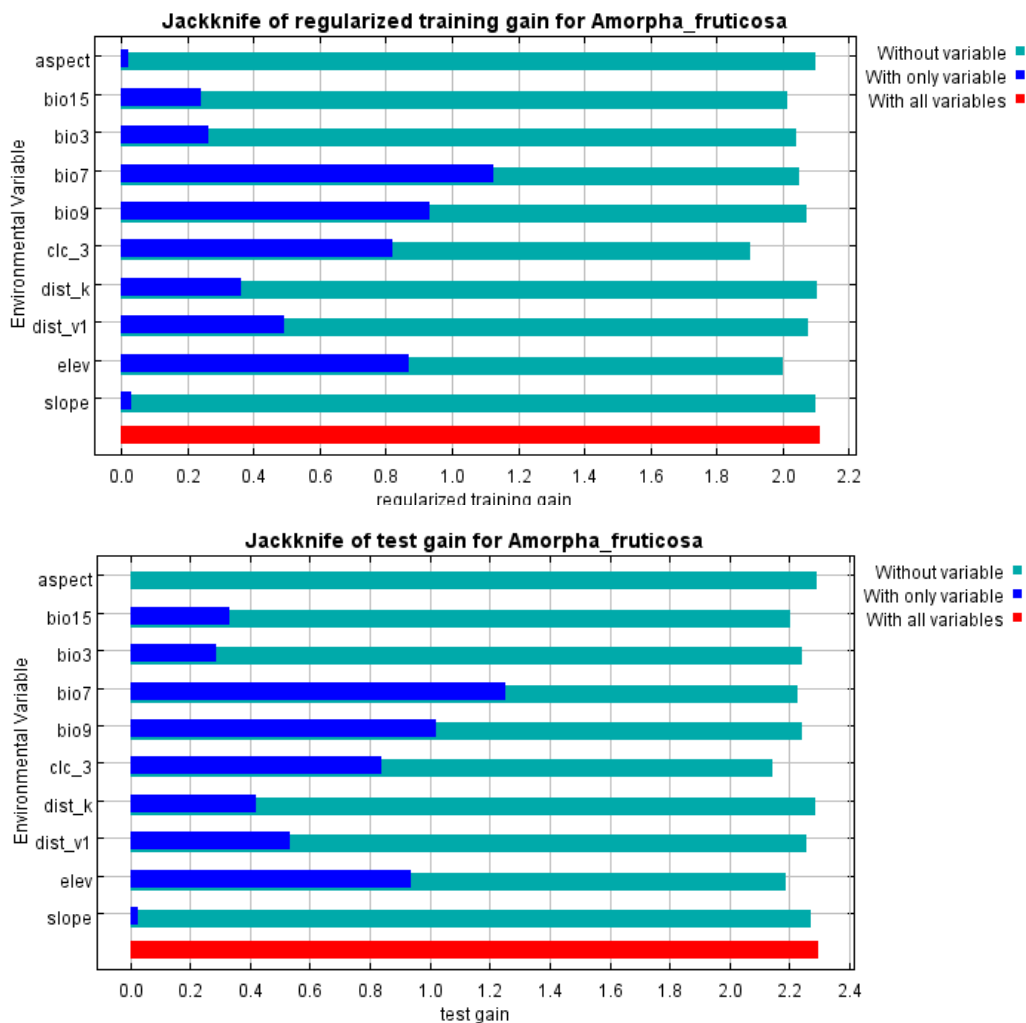
#### 4.1.1 Analýza významnosti a přispění prediktorů

Jak je patrné z tab. 10, prediktorem s největším procentuálním příspěvkem (30,9 %) do modelu je krajinný pokryv, podobně významně přispěla také nadmořská výška (25,3 %). Dalšími významnými prediktory jsou roční rozsah teplot, jehož příspěvek je téměř 20 %, poté vzdálenost od vodních toků a sezónnost srážek. Zbývající prediktory model vyhodnotil jako méně významné, včetně parametrů odvozených z digitálního modelu terénu (*aspect* a *slope*), jejichž příspěvek do modelu je minimální - menší než 1 %.

**Tab. 10:** Analýza procentuálního přispění prediktorů do modelu potenciálního rozšíření netvařce křovitého.

Variable	Percent contribution
clc_3	30.9
elev	25.3
bio7	19.7
dist_v1	10.0
bio15	6.2
bio3	3.3
bio9	1.7
dist_k	1.7
aspect	0.8
slope	0.4

Podrobnější analýzu významnosti prediktorů poskytují výsledky testů jackknife (obr. 10 a 11). Obr. 10 ukazuje průměrné hodnoty ukazatele *gain* pro training data (*regularized training gain*) a testovací data (*test gain*). Světle modře je vynesena dosažená hodnota *gain* bez použití prediktoru, tmavě modře pouze s použitím daného prediktoru a červeně celkový dosažený *gain* při použití všech prediktorů. Stejným způsobem jsou na obr. 11 vyneseny průměrné dosažené hodnoty ukazatele *AUC* pro testovací data.




**Obr. 10:** Výsledky testů jackknife ukazující významnost jednotlivých prediktorů z hlediska vlivu na dosažené hodnoty *regularized training gain* a *test gain*.

Z výsledků těchto testů lze odvodit obdobnou významnost prediktorů, jako ukazuje tab. 10, s tím rozdílem, že míra významnosti některých prediktorů zcela neodpovídá hodnotám procentuálních příspěvků, což je patrně způsobeno přítomností korelací mezi prediktory. Příkladem může být průměrná teplota v nejsušším čtvrtletí (bio9), kterou testy jackknife zhodnotily jako významný prediktor, nicméně její příspěvek do modelu je přesto minimální (1,7 %; viz tab. 10). Znamená to, že při tvorbě modelu byl jako první zřejmě použit jiný prediktor, který nese podobnou informaci a druhý z prediktorů se pak může zdát jako nevýznamný.

Z grafů dále vyplývá, že k největšímu poklesu *gain* a *AUC* výsledného modelu by došlo, pokud by nebyl zařazen krajinný pokryv (clc\_3), což ukazuje, že tento prediktor nese informaci, kterou ostatní prediktory neposkytují. Tomu odpovídá i jeho největší procentuální příspěvek do modelu.





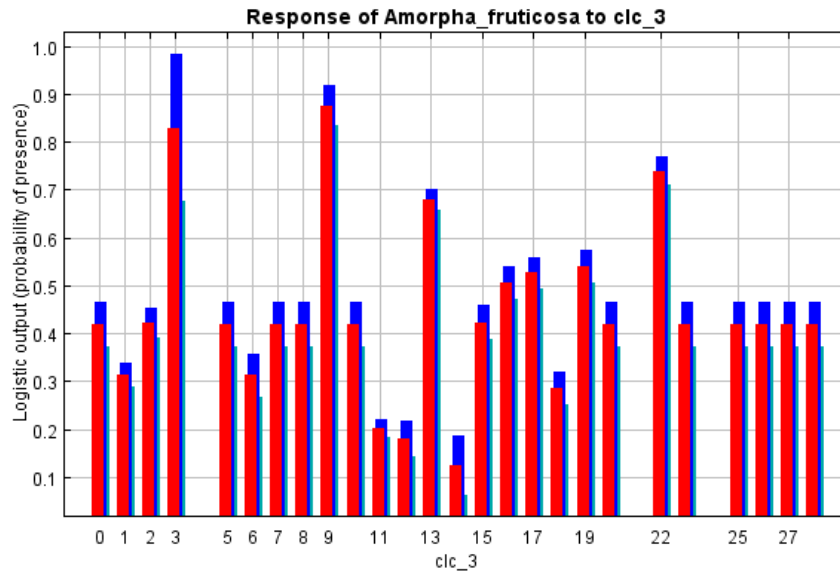
**Obr. 11:** Výsledky testu jackknife ukazující významnost jednotlivých prediktorů z hlediska vlivu na dosaženou hodnotu ukazatele *AUC*.

Prediktor, který má samostatně největší predikční význam, tedy dosahuje při samostatném použití v modelu nejvyšší hodnoty *gain* i *AUC*, je roční rozsah teplot (*bio7*). Znamená to, že nese podstatnou část informace a je ze všech použitých prediktorů schopen samostatně nejlépe predikovat rozšíření. Zařazení prediktorů odvozených z digitálního modelu terénu, tedy svažitosti terénu a expozice, hodnotu *gain* a *AUC* ovlivnilo minimálně.

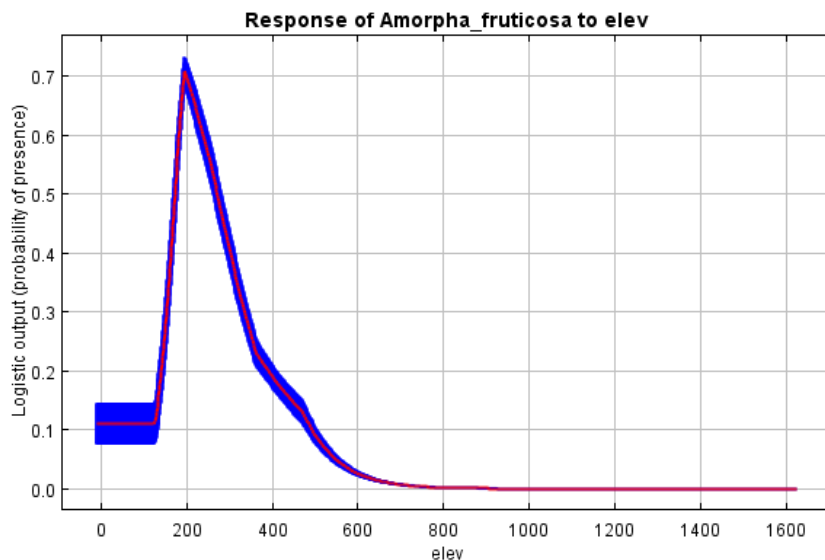
#### 4.1.2 Reakce druhu na významné prediktory (*response curves*)

Jedním z prediktorů mající významný vliv na výskyt netvařce křovitého je krajinný pokryv. Jak konkrétně predikovaná pravděpodobnost závisí na kategorii krajinného pokryvu, ukazuje obr. 12. Nejvyšší predikovaná pravděpodobnost výskytu je v kategoriích 3 (silniční a železniční síť s okolím), 9 (plochy městské zeleně), 13 (sady, chmelnice a zahradní plantáže) a 22 (přechodová stadia lesa a křoviny). Vysoká pravděpodobnost v kategoriích 3 a 9 odpovídá výsadbám ve městech a podél komunikací, kategorie 13 a 22 zřejmě odpovídají výskytům mimo výsadby, kde se objevuje počínající šíření. V kategoriích 16 (zemědělské oblasti s příměsí přirozené vegetace), 17 (listnaté lesy) a 19 (smíšené lesy) se predikovaná pravděpodobnost pohybuje v rozmezí 0,5 – 0,6 a patrně souvisí s výskyt druhu na okrajích lesních porostů nebo mezích v zemědělských oblastech.

Jak predikovaná pravděpodobnost závisí na nadmořské výšce, znázorňuje obr. 13. Nejvyšší pravděpodobnosti je dosaženo v nadmořské výšce cca 200 m, s rostoucí nadmořskou výškou pak predikovaná pravděpodobnost významně klesá.



**Obr. 12:** Predikovaná pravděpodobnost v závislosti na kategorii CORINE Land Cover 2006 (číselné označení kategorií v tab. x na str. x). Červeně je vyznačena průměrná hodnota, dvěma odstíny modré variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).

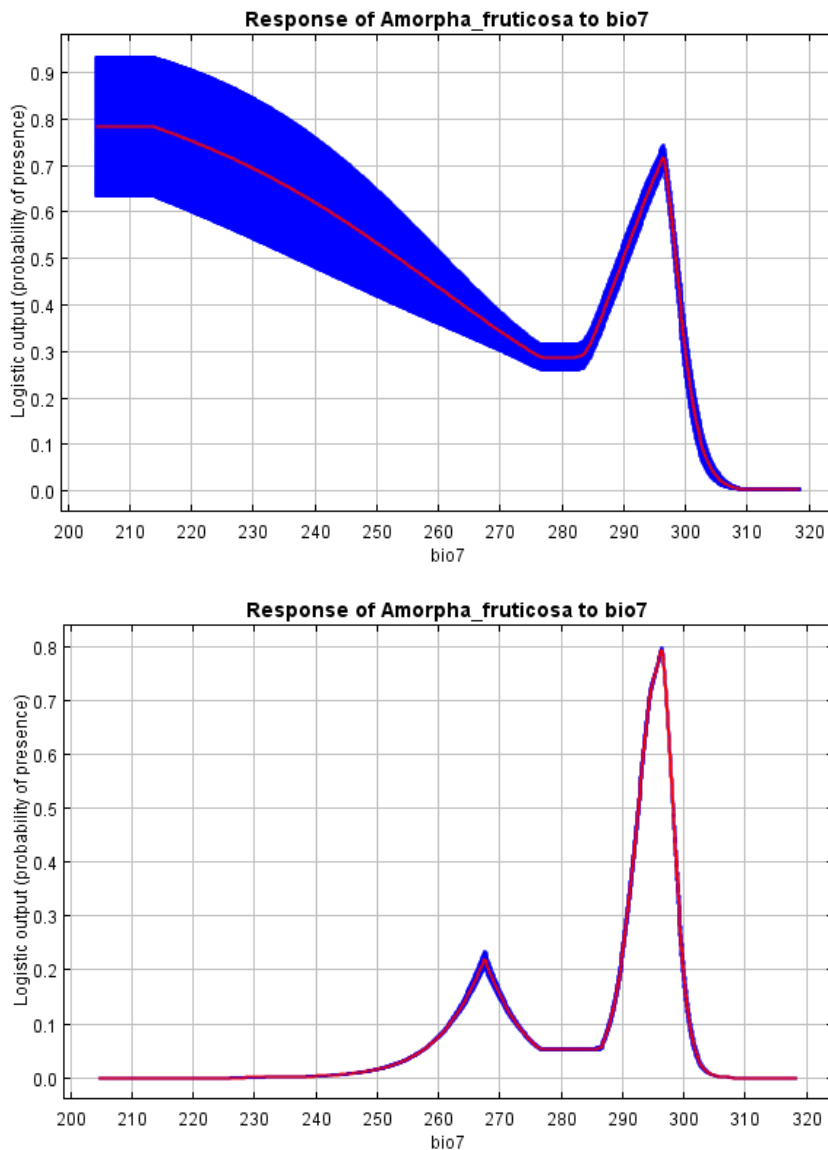


**Obr. 13:** Predikovaná pravděpodobnost v závislosti na nadmořské výšce. Červeně je vyznačena průměrná hodnota, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).

Zjištěný vztah však vzhledem k počínajícímu šíření nemusí odpovídat skutečným ekologickým nárokům druhu, ale pouze tomu, že zatím nedošlo k rozšíření do vyšších nadmořských výšek.

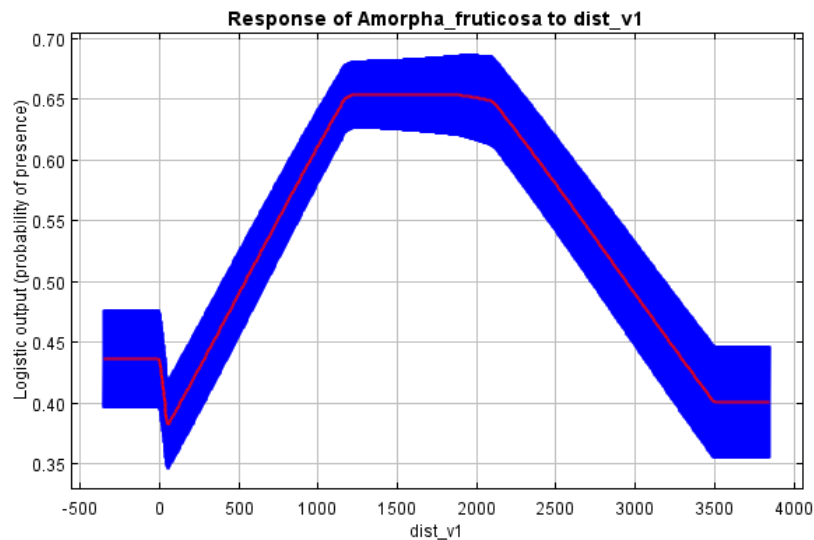
Jako další významný prediktor byl vyhodnocen roční rozsah teploty. Interpretace odezvy druhu na bioklimatické proměnné je však poněkud problematická vzhledem k vlivu ostatních prediktorů – tvar křivky se liší při zařazení prediktoru samostatně a při jeho zařazení s dalšími prediktory (obr. 14). Z obou grafů je ale patrné, že druh je

pravděpodobně schopen tolerovat větší rozsah teplot během roku (predikovaná pravděpodobnost při ročním rozsahu teploty cca 29,5 °C je 0,7 až 0,8), což je výhodnou vlastností při obsazování stanoviště.



**Obr. 14:** Predikovaná pravděpodobnost v závislosti na ročním rozsahu teploty (°C\*10) při vlivu ostatních prediktorů (nahore) a při použití prediktoru samostatně (dole). Červeně je vyznačena průměrná hodnota, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).

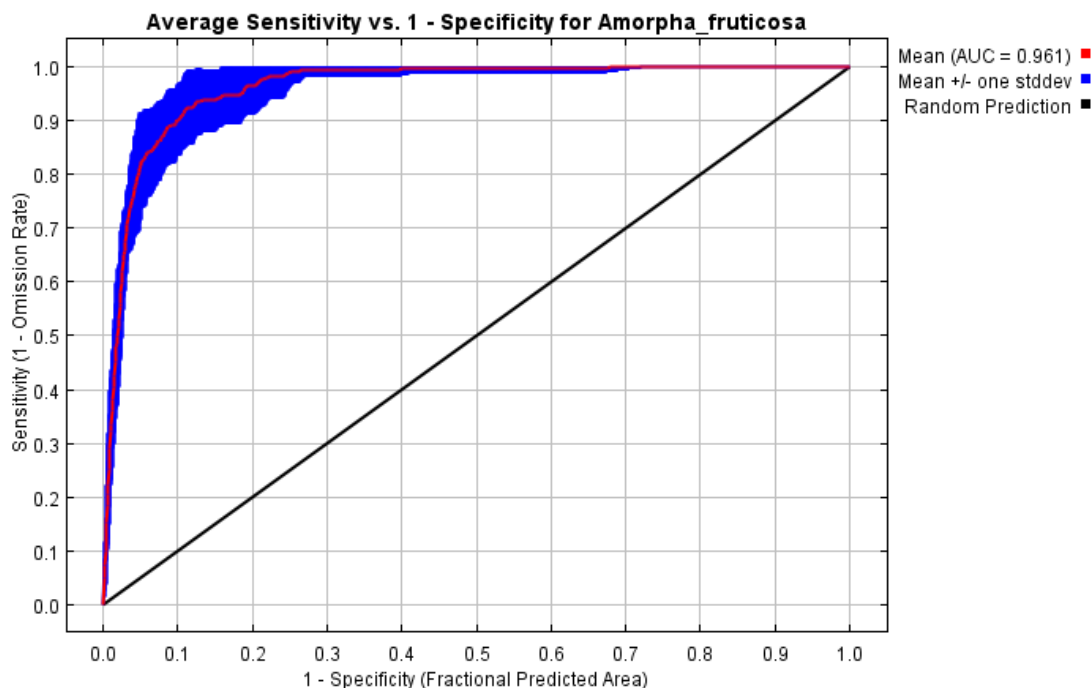
Přestože jako jeden z významných prediktorů byla vyhodnocena také vzdálenost od vodních toků, v tomto případě to zřejmě nesouvisí s přímým šířením druhu, ale spíše s jeho častějším výskytem v určité vzdálenosti od vodních toků. Lze tak usoudit z obr. 15, neboť nejvyšší predikovaná pravděpodobnost je ve vzdálenosti asi 1000 až 2000 m od vodního toku, což nelze považovat za jeho blízké okolí.



**Obr. 15:** Predikovaná pravděpodobnost v závislosti na vzdálenosti od vodních toků. Červeně je vyznačena průměrná hodnota, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).

#### 4.1.3 Přesnost modelu

Na obr. 16 je výsledná křivka ROC vyjadřující průměrnou dosaženou hodnotu AUC pro testovací vzorky dat. Dle průměrné dosažené hodnoty statistiky AUC, která je rovna 0,961, lze model považovat za model s výbornou diskriminační (predikční) schopností, přičemž směrodatná odchylka je 0,017.

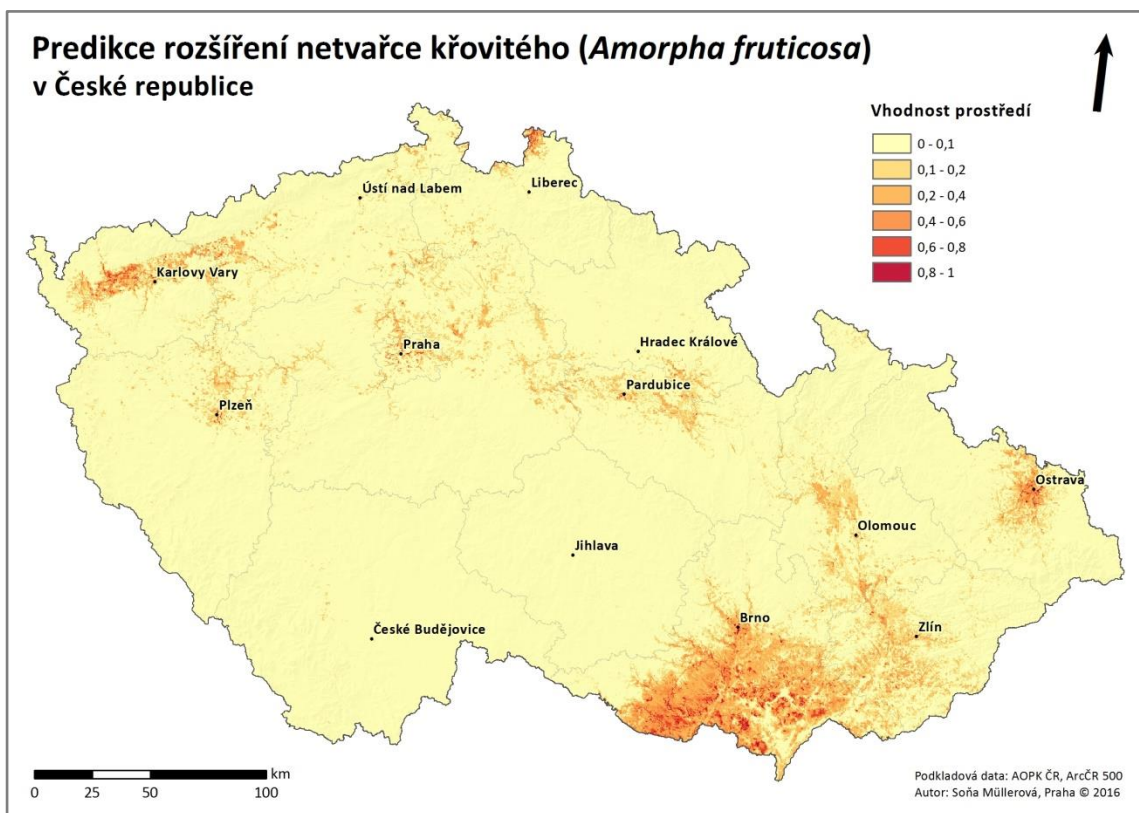


**Obr. 16:** ROC křivka vyjadřující predikční schopnost modelu potenciálního rozšíření netvařce křovitého. Červeně je vyznačena průměrná hodnota AUC, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka). Černá přímka odpovídá náhodné predikci.

#### 4.1.4 Predikce rozšíření

Výsledná predikční mapa (obr. 17 a příloha č. 1) naznačuje, že převážná část oblastí s vhodnými predikovanými podmínkami odpovídá okolí známých lokalit výskytu druhu (viz obr. 6a), což poukazuje na další možné šíření v rámci těchto oblastí. Konkrétně je další šíření ze stávajících stanovišť velice pravděpodobné na jižní Moravě, přesněji na území Jihomoravského kraje, kde jsou v poměrně velké části území predikovány zvláště vhodné podmínky, které potvrzují současné záznamy o výskytu druhu. Zřejmě se tedy jedná o území nejohroženější invazí, i z toho důvodu, že zde již probíhá invaze mnoha dalších rostlinných druhů. Odtud by se mohl netvařec křovitý potenciálně šířit rovněž do Zlínského a Olomouckého kraje, kde je již známý výskyt na několika lokalitách. Vhodné podmínky jsou dále predikovány na Ostravsku a také Karlovarsku, konkrétně v těžbou narušené oblasti Sokolovské pánve, kde je lokálně predikovaná vysoká vhodnost prostředí. Ostravsko i Karlovarsko tedy rovněž vykazují potenciál pro budoucí invazi.

Nová ohniska invaze by mohla vzniknout v okolí Plzně nebo na Frýdlantsku, nicméně lokality současného výskytu jsou od těchto oblastí izolované, vhodné podmínky se nachází spíše roztroušeně a predikovaná vhodnost prostředí je navíc poměrně nízká. Na lokální změny v predikované hodnotě, které jsou patrné např. v oblasti jižní Moravy, má zřejmě vliv hlavně kategorie krajinného pokryvu.



Obr. 17: Predikovaná vhodnost prostředí pro výskyt netvařce křovitého na území České republiky.

## 4.2 Kustovnice cizí

### 4.2.1 Analýza významnosti a přispění prediktorů



Z hodnot v tab. 11 vyplývá, že do modelu nejvýrazněji přispěla nadmořská výška (68,5 %), významným faktorem s příspěvkem 13,8 % je také krajinný pokryv. Jako další významný prediktor se ukázal rovněž jeden z parametrů odvozených z digitálního modelu terénu – svažítost, jehož příspěvek je 9,4 %. Z bioklimatických prediktorů nejvýrazněji přispěl roční rozsah teplot. Dle procentuální hodnoty je pátým nejvýznamnějším prediktorem vzdálenost od vodních toků. Přestože příspěvek není vysoký (1,7 %), z výsledků testů jackknife vyplývá jeho význam z hlediska vlivu na hodnotu *gain* (viz níže). Příspěvek dalšího parametru odvozeného z DEM (expozice) je minimální (0,4 %).

**Tab. 11:** Analýza procentuálního přispění prediktorů do modelu potenciálního rozšíření kustovnice cizí.

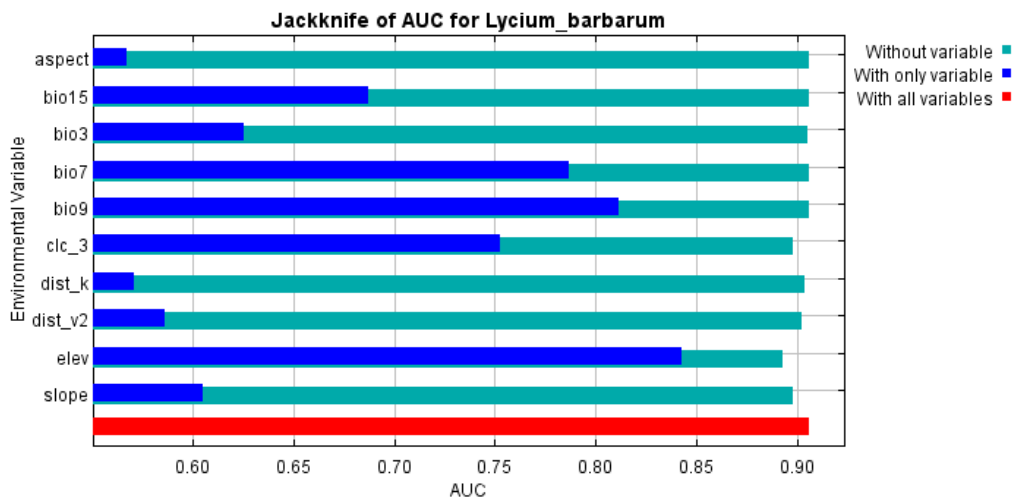
Variable	Percent contribution
elev	68.5
clc_3	13.8
slope	9.4
bio7	4.1
dist_v2	1.7
bio15	0.9
dist_k	0.8
aspect	0.4
bio3	0.4
bio9	0.1

Výsledky testů jackknife (obr. 18 a 19) jasně ukazují nadmořskou výšku jako nejvýznamnější prediktor, jak z hlediska schopnosti nejlépe samostatně predikovat rozšíření, tak z hlediska poklesu *gain* a *AUC* při absenci tohoto prediktoru. Co se týče dosažené hodnoty *gain* při samostatném použití, významný je také krajinný pokryv a bioklimatické prediktory bio9 a bio7. Ty však neposkytují zásadní doplňující informaci neobsaženou v jiných prediktorech, na rozdíl od zmíněného krajinného pokryvu, při jehož absenci by došlo ke snížení *gain* i *AUC*.

Kromě nadmořské výšky a krajinného pokryvu je důležitým prediktorem svažítost terénu a vzdálenost od vodních toků - při jejich absenci by rovněž došlo k poklesu hodnoty *gain* a *AUC*.



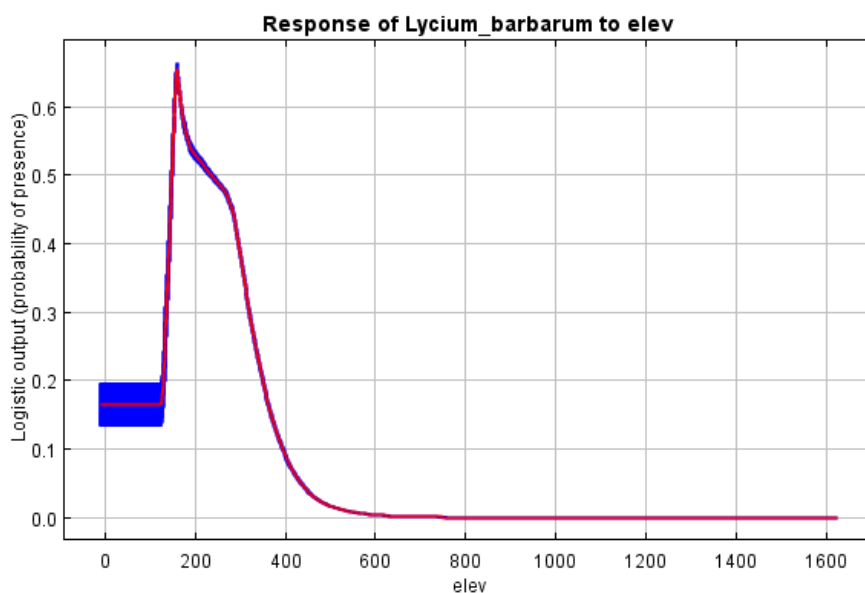
**Obr. 18:** Výsledky testů jackknife ukazující významnost jednotlivých prediktorů z hlediska vlivu na dosažené hodnoty *regularized training gain* a *test gain*.



**Obr. 19:** Výsledky testu jackknife ukazující významnost jednotlivých prediktorů z hlediska vlivu na dosaženou hodnotu ukazatele AUC.

#### 4.2.2 Reakce druhu na významné prediktory (*response curves*)

Z obr. 20 je zřejmé, že nejvyšší predikovaná pravděpodobnost výskytu je v nížinách (cca 150 m n. m.) a druh s velkou pravděpodobností nevystupuje výše než 400-500 m n. m. Vzhledem k pokročilejšímu stádiu invaze lze předpokládat, že nálezová data poměrně dobře popisují nároky druhu a charakter obsazených stanovišť. Šíření do výrazně vyšších poloh je tudíž málo pravděpodobné.




**Obr. 20:** Predikovaná pravděpodobnost v závislosti na nadmořské výšce. Červeně je vyznačena průměrná hodnota, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).


Co se týče krajinného pokryvu, nejvýznamnější pro výskyt druhu jsou kategorie 9 (plochy městské zeleně), 20 (přírodní louky) a 22 (přechodová stadia lesa a křoviny), z čehož vyplývá, že druh je schopen pronikat i do přirozených společenstev luk a křovin, jako k tomu již na mnoha lokalitách došlo. Vyšší predikovaná pravděpodobnost je také v kategoriích 2 (průmyslové a obchodní areály), 12 (vinice), 15 (směs polí, luk a trvalých kultur), 16 (zemědělské oblasti s příměsí přirozené vegetace), což odpovídá výskytu druhu v blízkosti stanovišť ovlivňovaných činností člověka a v blízkosti sídel. Z výsledků lze mimo jiné vyvodit, že druh preferuje spíše otevřenou kulturní krajinu bez výraznějšího zapojení vegetace (obr. 21).

Významným prediktorem rozšíření kustovnice cizí je svažítost terénu, čemuž odpovídá i výsledná křivka (obr. 22). Je patrné, že s rostoucí svažítostí výrazně roste predikovaná pravděpodobnost – od cca 0,3 v rovinnatém terénu až po 0,75 při svažítosti 30 – 35°. Výskyt druhu tak lze očekávat spíše na svažitéjších stanovištích.



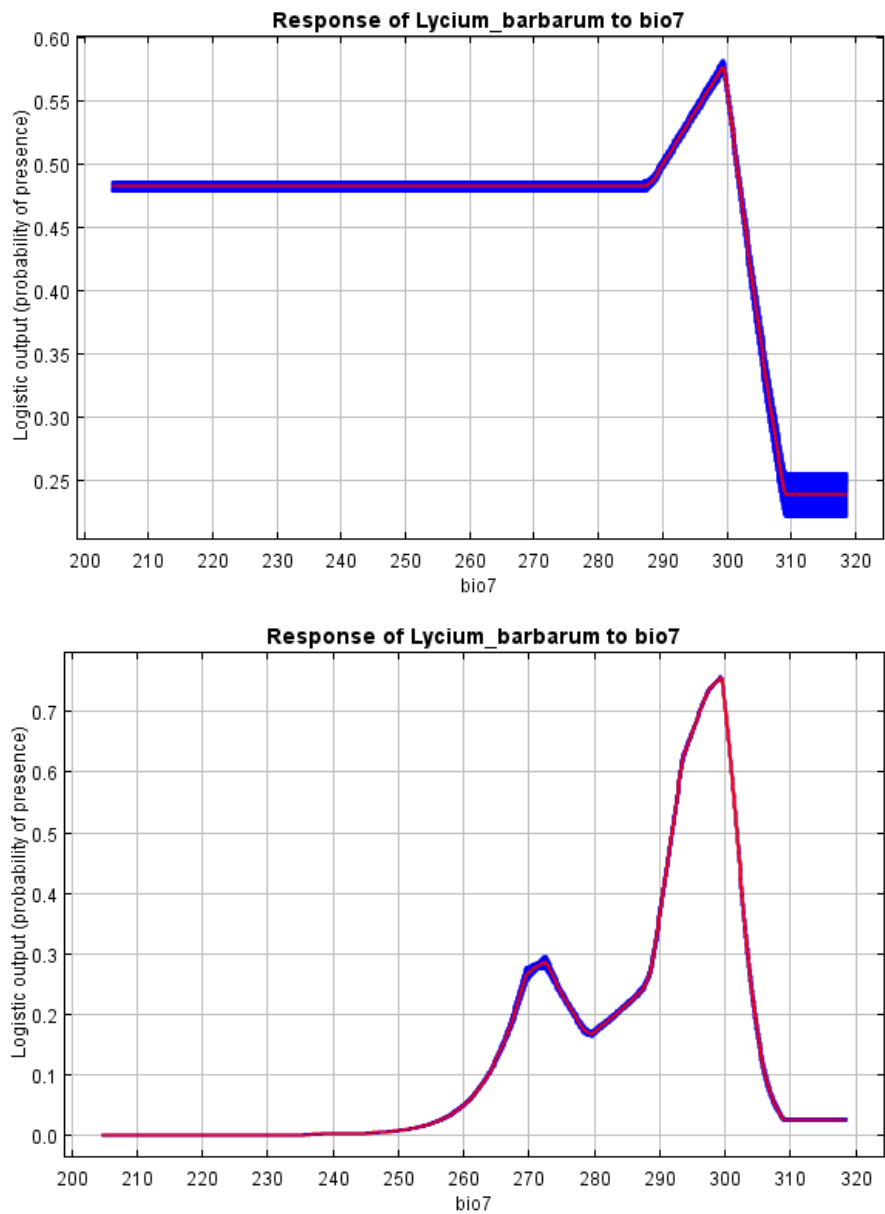


**Obr. 21:** Predikovaná pravděpodobnost v závislosti na kategorii CORINE Land Cover 2006 (číselné označení kategorií v tab. x na str. x). Červeně je vyznačena průměrná hodnota, dvěma odstíny modré variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).




**Obr. 22:** Predikovaná pravděpodobnost v závislosti na svažitosti terénu. Červeně je vyznačena průměrná hodnota, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).

Jak již bylo zmíněno, z bioklimatických prediktorů do modelu nejvíce přispěl roční rozsah teplot (obr. 23). Podobně jako v případě netvařce křovitého se bioklimatické prediktory vzájemně ovlivňují, což má za následek obtížnější interpretaci. Grafy však naznačují, že kustovnice cizí se vyskytuje i v oblastech s vyššími výkyvy teploty během roku a je tedy pravděpodobně schopna, podobně jako netvařec křovitý, tolerovat podprůměrné i nadprůměrné teploty.



**Obr. 23:** Predikovaná pravděpodobnost v závislosti na ročním rozsahu teploty ( $^{\circ}\text{C}\cdot 10$ ) při vlivu ostatních prediktorů (nahore) a při použití prediktoru samostatně (dole). Červeně je vyznačena průměrná hodnota, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).

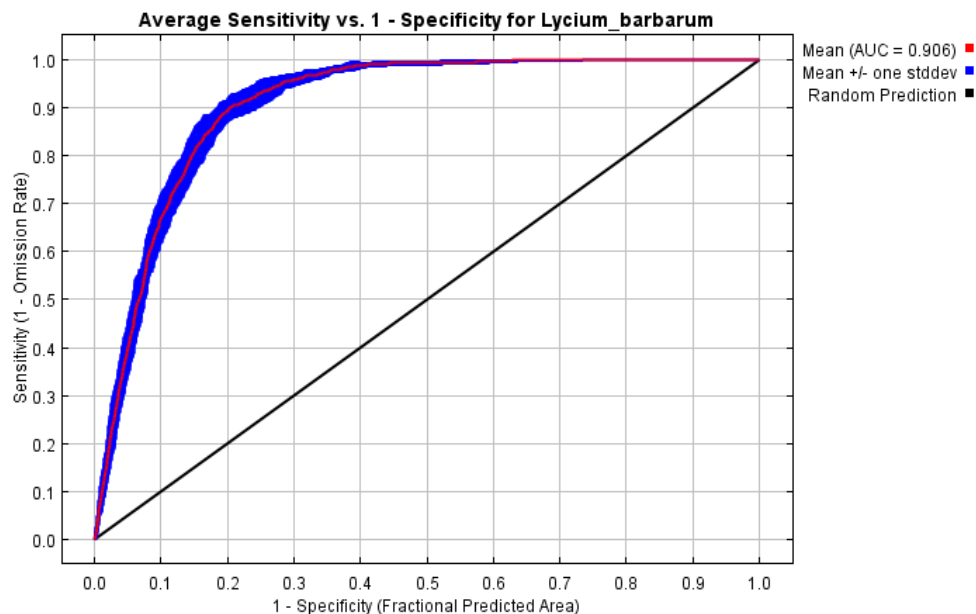
Obr. 24 znázorňuje vztah výskytu kustovnice cizí a vzdálenosti od vodních toků. Maximální pravděpodobnosti je dosaženo v hodnotě 0, tedy v bezprostřední blízkosti vodního toku, dále je patrný výrazný klesající trend. Ze zjištěného vztahu vyplývá, že vodní toky mohou být jedním z vektorů šíření druhu.



**Obr. 24:** Predikovaná pravděpodobnost v závislosti na vzdálenosti od vodních toků. Červeně je vyznačena průměrná hodnota, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka).

#### 4.2.3 Přesnost modelu

Průměrná dosažená hodnota AUC pro testovací vzorky dat je 0,906 (obr. 25). Ve srovnání s výsledky pro netvařec křovitý je hodnota AUC nižší, na druhou stranu ale vykazuje mírně nižší variabilitu - směrodatná odchylka je 0,010. V případě kustovnice cizí vykazují menší variabilitu také křivky vyjadřující reakci druhu na jednotlivé prediktory.

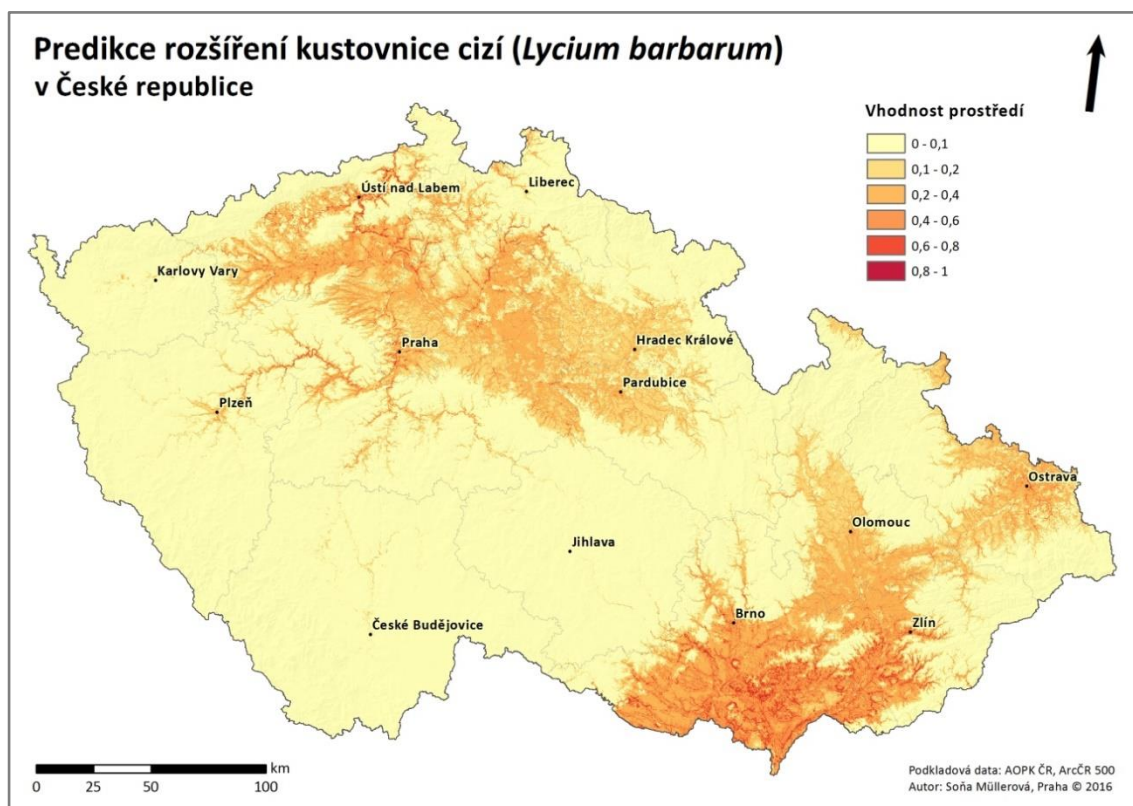


**Obr. 25:** ROC křivka vyjadřující predikční schopnost modelu potenciálního rozšíření k. Červeně je vyznačena průměrná hodnota AUC, modře variabilita mezi modely (průměrná hodnota +/- směrodatná odchylka). Černá přímka odpovídá náhodné predikci.

#### 4.2.4 Predikce rozšíření

Z výsledné predikční mapy (obr. 26 a příloha č. 2) je zřejmé, že vhodné podmínky pro výskyt jsou soustředěny do nižších poloh. Zvláště vhodné prostředí je predikováno v oblasti jižní Moravy, konkrétně jde o Jihomoravský kraj, kde se druh v současnosti hojně vyskytuje a patrně zde již obsadil velkou část vhodných stanovišť, a o jihozápadní část Zlínského kraje, odkud je naopak známo pouze několik lokalit výskytu (obr. 6b). Okolí stávajících výskytů ve Zlínském kraji tedy vykazuje potenciál pro další šíření. Ze stávajících stanovišť je možné další šíření také na území Olomouckého kraje, kde je však predikovaná vhodnost podmínek nižší. Další vhodná stanoviště pro výskyt jsou roztroušeně situována v celé oblasti Polabí, dále na Mostecku a Teplicku nebo v Praze a okolí, kde je v současnosti zaznamenán roztroušený výskyt. V rámci těchto oblastí opět platí potenciální riziko další invaze.

Vektorem šíření by se teoreticky mohly stát některé vodní toky, konkrétně Berounka a Sázava ve Středočeském kraji, což naznačuje vyšší predikovaná vhodnost prostředí soustředěná do jejich bezprostředního okolí, přičemž zvláště vhodné podmínky jsou pak predikovány podél Labe a Ploučnice v Ústeckém kraji. Potenciál pro novou invazi je patrný na Ostravsku, kde zatím výskyt nebyl zaznamenán, predikovaná vhodnost prostředí je zde však nižší než např. na jihu Moravy.



Obr. 26: Predikovaná vhodnost prostředí pro výskyt kustovnice cizí na území České republiky.

Obecně je patrné, že výskyt druhu je limitován nadmořskou výškou. V rámci jednotlivých oblastí s vhodnými podmínkami jsou pak dobře znatelné lokální změny ve vhodnosti podmínek, což v případě kustovnice cizí odpovídá místnímu charakteru terénu, zejména svažitosti, která se pro druh ukázala jako významný prediktor, dále charakteru krajinného pokryvu nebo blízkosti vodních toků.

## 5 DISKUZE

Pro netvařec křovitý byly predikovány vhodné podmínky převážně v oblasti jižní Moravy. Buček (2002), který zaznamenal šíření druhu v Srbsku a Bulharsku v údolních nivách velkých řek, odhadoval, že v České republice budou pravděpodobně obsazena podobná stanoviště, která jsou navíc blízká habitatu v přirozeném areálu (Křivánek 2006a). Tomu by mohly odpovídat právě říční nivy v oblasti jižní Moravy, nicméně výsledky ukázaly, že významnost vzdálenosti od vodních toků v tomto případě neznáčí častější výskyt v bezprostředním okolí řek. Druh tedy buď zatím zmíněná stanoviště neobsadil, případně obsadil, ale výskyt nebyl zaznamenán, a do modelu tedy vstupovala nekompletní či nekvalitní data. Protože Hroneš (2010) šíření druhu podél řek přímo uvádí, zřejmě byl problémem skutečně nedostatek nálezových dat. Použitá data totiž nepochází ze systematického mapování a navíc se jednalo převážně o plošné nálezy, které je obtížné vyjádřit jako jednotlivé body, což má za následek výrazné zkreslení informace. Podobný problém zřejmě nastal v případě vzdálenosti od komunikací, u které jsem také předpokládala významný vliv, neboť v literatuře se uvádí, že netvařec křovitý byl vysazován podél komunikací, kde se údajně dále šíří (Křivánek 2006a, Hroneš 2010).

Z nevýznamnosti proměnných odvozených z digitálního modelu terénu, tedy svažitosti a expozice, lze vyvodit několik závěrů. Jednak to může být jejich skutečná nevýznamnost, dále se u druhu v novém areálu zatím nemusela projevit preference určitých hodnot těchto proměnných, případně není z důvodu nedostatku dat dostatečně popsána. Další možností je použití nedostatečně podrobného rozlišení. Austin et Van Niel (2011) nebo Grohmann (2015) upozorňují na znehodnocování informace při snižujícím se rozlišení u těchto prediktorů, Lassueur et al. (2006) např. ukázali, že expozice má optimální predikční schopnost v rozlišení 20 m. Jednalo se však o vysokohorská stanoviště, která příliš neodpovídají reliéfu České republiky. Pro použití takto podrobného rozlišení by bylo také nutné získat nálezová data odpovídající přesnosti. V případě krajinného pokryvu je vzhledem k dosažené významnosti zřejmě použité rozlišení 100 x 100 m dostačující, což potvrzuje i to, že kategorie s vyšší vhodností prostředí odpovídají stanovištím uváděným v literatuře. Je třeba zmínit, že jako jedna z nejméně významných kategorií byla vyhodnocena silniční a železniční síť

s okolím, což příliš neodpovídá nevýznamné vzdálenosti od komunikací. Problém tedy mohl být rovněž v datech, ze kterých byla vzdálenost odvozována.

Protože netvařec křovitý je druh s počínajícím šířením, velice pravděpodobně dosud neobsadil většinu vhodných stanovišť a nebylo tedy dosaženo požadované rovnováhy, která je jedním ze základních předpokladů v modelování druhové distribuce (Václavík et Meentemeyer 2012). Je-li druh v rané fázi invazního procesu, není možné na základě dat o aktuální distribuci kompletně vystihnout jeho ekologickou niku, zvláště pokud jsou tato data navíc nekompletní nebo méně přesná, což je pravděpodobně tento případ. Nedosažená rovnováha v raném stádiu invaze může dále způsobit, že odhad stanovišť ohrožených invazí může být do určité míry podhodnocen (Pearson 2010, Václavík et Meentemeyer 2012).

V případě kustovnice cizí jsem vzhledem k informacím uváděným v literatuře předpokládala významný vliv blízkosti komunikací, zejména železnic. Pyšek et al. (2012b) uvádí, že současné výskyty dosud do jisté míry odpovídají dřívějším výsadbám podél železničních tratí, násypy železnic nebo okolí silnic uvádí jako jedny z častých stanovišť také např. Hoskovec (2008). Vliv komunikací není patrný ani z kategorií krajinného pokryvu, které byly vyhodnoceny jako významnější. Zajímavé je, že vzdálenost od vodních toků byla naopak vyhodnocena jako významný prediktor, přestože jsem v literatuře nenašla žádnou zmínku o šíření podél řek, případně současném výskytu kustovnice cizí v okolí vodních toků. Dle mého názoru zde měla určitý vliv korelace vzdáleností od vodních toků a železnic, neboť některé úseky železničních tratí jsou vedeny souběžně s významnějšími toky, například právě s Beroučkou, Labem nebo Sázavou, v jejichž okolí byly predikovány zvláště vhodné podmínky pro výskyt druhu. Korelace mezi proměnnými sice dosáhla hodnoty pouze 0,11, což ale souvisí spíše s tím, že prediktor zahrnuje i silnice, které významnější souvislost s vodními toky nemají. Vzhledem k tomu, že se jedná o suchomilný druh rostoucí na sušších svazích nebo rumišťích, je příznivé stanoviště podél vodních toků rovněž značně nepravděpodobné. Jednou z možností by tak mohlo být vytvoření samostatného prediktoru vyjadřující vzdálenost od železniční sítě. Problémem zde opět může být použité měřítko, protože pokud jsou od sebe železnice a vodní tok vzdáleny méně než 100 m, nelze je při použitém rozlišení 100 x 100 m spolehlivě odlišit.

Určitou souvislost s vodními toky má také svažitost terénu, která se pro kustovnici cizí ukázala jako významný prediktor. Údolí některých toků se vyznačují členitějším reliéfem se strmějšími svahy, které mohou představovat vhodná stanoviště pro výskyt druhu. Jako důležitý prediktor pro kustovnici cizí jsem očekávala také expozici. Vzhledem ke světlo- a suchomilnosti a teplomilnosti druhu (Sádlo 2001, Pyšek et al. 2012b) by se dala očekávat preference svahů určité orientace, konkrétně jižní, jihozápadní nebo jihovýchodní. Proto by jistě bylo vhodné analyzovat významnost

prediktoru v podrobnějším rozlišení, což by samozřejmě vyžadovalo také přesná data o výskytu druhu ve formě bodových nálezů. Svažitost se ukázala jako významná i při použitém rozlišení 100 x 100 m.

Výsledný model pro kustovnici cizí lze považovat za věrohodnější a více odpovídající skutečnosti, neboť kustovnice cizí je již v pokročilé fázi invazního procesu a na rozdíl od netvařce křovitého se více blíží rovnováze s prostředím. S tím souvisí i více záznamů o výskytu, lepší reprezentace ekologické niky a odhad stanovišť ohrožených další invazí více odpovídající skutečnosti (Pearson 2010, Václavík et Meentemeyer 2012). Součástí dat bylo v případě kustovnice cizí 112 přesných bodových nálezů, zatímco u netvařce křovitého to bylo pouhých 17. Pyšek et al. (2012b) uvedli, že nová stanoviště již zřejmě rostlina tak často neobsazuje a spíše dochází ke zvětšování plochy či početnosti jednotlivých populací. To je poměrně v souladu s výslednou predikcí. Kromě Ostravska nebyly identifikovány žádné nové rozsáhlejší oblasti s vhodnými podmínkami, které by byly od současných výskytů izolované.

Významnost nadmořské výšky pro oba druhy potvrzuje známou skutečnost, že důležitými faktory ovlivňující distribuci rostlin jsou teplota a srážkový úhrn, které nadmořská výška zastupuje jako nepřímý prediktor (Franklin 2009, Miller 2010, Austin et Van Niel 2011). Co se týče krajinného pokryvu, výsledky jsou v souladu se studií, kterou provedli Ibáñez et al. (2009). Krajinný pokryv tedy může být užitečným prediktorem při modelování distribuce invazních druhů rostlin.

Modely pro oba druhy lze na základě hodnot uváděných v literatuře (např. Franklin 2009) považovat za modely s vysokou přesností. Zde je však potřeba připomenout, že u modelů presence-only, zvláště pak v případě invazních druhů, mohou být dosažené hodnoty AUC zavádějící (Merow et al. 2013). To se týká zejména netvařce křovitého, kde bylo sice dosaženo velmi vysoké hodnoty - 0,961, která však v tomto případě zřejmě neindikuje přesný a kvalitní model, ale spíše schopnost modelu dobře rozlišit prezence od background dat (Merow et al. 2013).

Pro dosažení co nejlepšího modelu je potřeba zařadit další prediktory reprezentující faktory ovlivňující distribuci rostlin. Jedná se např. o světelné podmínky a půdní podmínky – půdní typ nebo pH (Austin et Van Niel 2011, Lassueur 2006), oba tyto faktory však vykazují variabilitu v podrobném rozlišení. Světelné podmínky lze vyjádřit pomocí dobře dostupných topografických proměnných. Z půdních charakteristik by jistě byl užitečným prediktorem např. půdní typ, nicméně tato data jsou pro Českou republiku obtížně dostupná. Dostupná jsou data pro území Evropy v rozlišení 1 x 1 km (portál *European Soil Data Centre*, <http://esdac.jrc.ec.europa.eu/resource-type/datasets>).

## 6 ZÁVĚR

Z výsledků práce vyplývá, že nejvýznamnějšími prediktory pro výskyt obou druhů jsou krajinný pokryv, nadmořská výška a roční rozsah teplot. Pro kustovnici cizí je dalším významným prediktorem také svažitost, jako jeden z parametrů odvozených z digitálního modelu terénu. Expozice byla pro oba druhy vyhodnocena jako nevýznamná, což může souviset jak s nedostatkem vstupních dat, tak s problematikou použitého rozlišení. Výsledné predikční mapy ukázaly, že jednou z oblastí nejohroženějších invazí je jižní Morava, která již byla obsazena řadou dalších invazních druhů rostlin. Potenciál pro invazi dále mohou představovat těžbou narušené oblasti Sokolovské a Mostecké pánve a také Ostravsko. Důležitým krokem k zabránění rozsáhlejší invaze je monitoring současných populací druhů a zabránění případnému dalšímu šíření do okolí. Kritérium AUC dosáhlo pro oba modely vysokých hodnot. V případě netvařce křovitého bylo dosaženo hodnoty  $0,961 \pm 0,017$ , v případě kustovnice cizí pak  $0,906 \pm 0,010$ . Věrohodnost a kvalita modelu však záleží na kvalitě vstupních dat a v případě invazních druhů také na fázi invazního procesu, v jaké se druh nachází. To je důležité pro posouzení míry rovnováhy, která je základním předpokladem v modelování druhové distribuce. Pro co nejpřesnější model je potřeba získat kvalitní nálezová data pocházející ze systematického mapování a další důležité prediktory ovlivňující distribuci rostlinných druhů. Jsou-li splněny tyto předpoklady, mohou modely druhové distribuce sloužit jako užitečný nástroj k předpovídání biologických invazí. Protože mnoho prediktorů přímo ovlivňujících distribuci rostlin je obtížně dostupných, námětem pro další výzkum mohou být nepřímé proměnné, jako například prediktory odvozené z digitálního modelu terénu a problematika použitého rozlišení.



## 7 POUŽITÁ LITERATURA

- Austin M. P. et Van Niel K. P., 2011: Improving species distribution models for climate change studies: variable selection and scale. – *Journal of Biogeography* 38(1): 1-8.
- Baroš A., Barošová I., Boček S., Businský R., Demková K., Dokoupil L., Kašková M., Kučera Z., Medková L. et Šantrůčková M., 2014: Metodika pro výběr vhodných druhů dřevin a bylin pro venkovská sídla. – VÚKOZ, v.v.i. a Univerzita Karlova v Praze, Přírodovědecká fakulta, Průhonice a Praha.
- Borovička T., Jiřina M. Jr., Jiřina M. et Kordík P., 2012: Selecting representative data sets. – INTECH Open Access Publisher, online: <http://www.intechopen.com/books/advances-in-data-mining-knowledge-discovery-and-applications/selecting-representative-data-sets>, cit. 13. 3. 2016.
- Buček A., 2002: Pozor na netvařec. – *Veronica* 16 (5): 25.
- Elith J. et Leathwick J. R., 2009: Species distribution models: ecological explanation and prediction across space and time. – *Annual Review of Ecology, Evolution, and Systematics* 40(1): 677-697.
- Franklin J., 1998: Predicting the distribution of shrub species in southern California from climate and terrain-derived variables. – *Journal of Vegetation Science* 9(5): 733-748.
- Franklin J., 2009: Mapping species distributions: spatial inference and prediction. – Cambridge University Press.
- Gottfried M., Pauli H. et Grabherr G., 1998: Prediction of vegetation patterns at the limits of plant life: a new view of the alpine-nival ecotone. – *Arctic and Alpine Research*: 207-221.
- Grohmann C. H., 2015: Effects of spatial resolution on slope and aspect derivation for regional-scale analysis. – *Computers & Geosciences* 77: 111-117.
- Guisan A., Weiss S. B. et Weiss A. D., 1999: GLM versus CCA spatial modeling of plant species distribution. – *Plant Ecology* 143(1): 107-122.
- Guisan A. et Zimmermann N. E., 2000: Predictive habitat distribution models in ecology. – *Ecological Modelling* 135(2): 147-186.
- Guisan A., Zimmermann N. E., Elith J., Graham C. H., Phillips S. et Peterson A. T., 2007: What matters for predicting the occurrences of trees: techniques, data, or species' characteristics? – *Ecological Monographs* 77(4): 615-630.

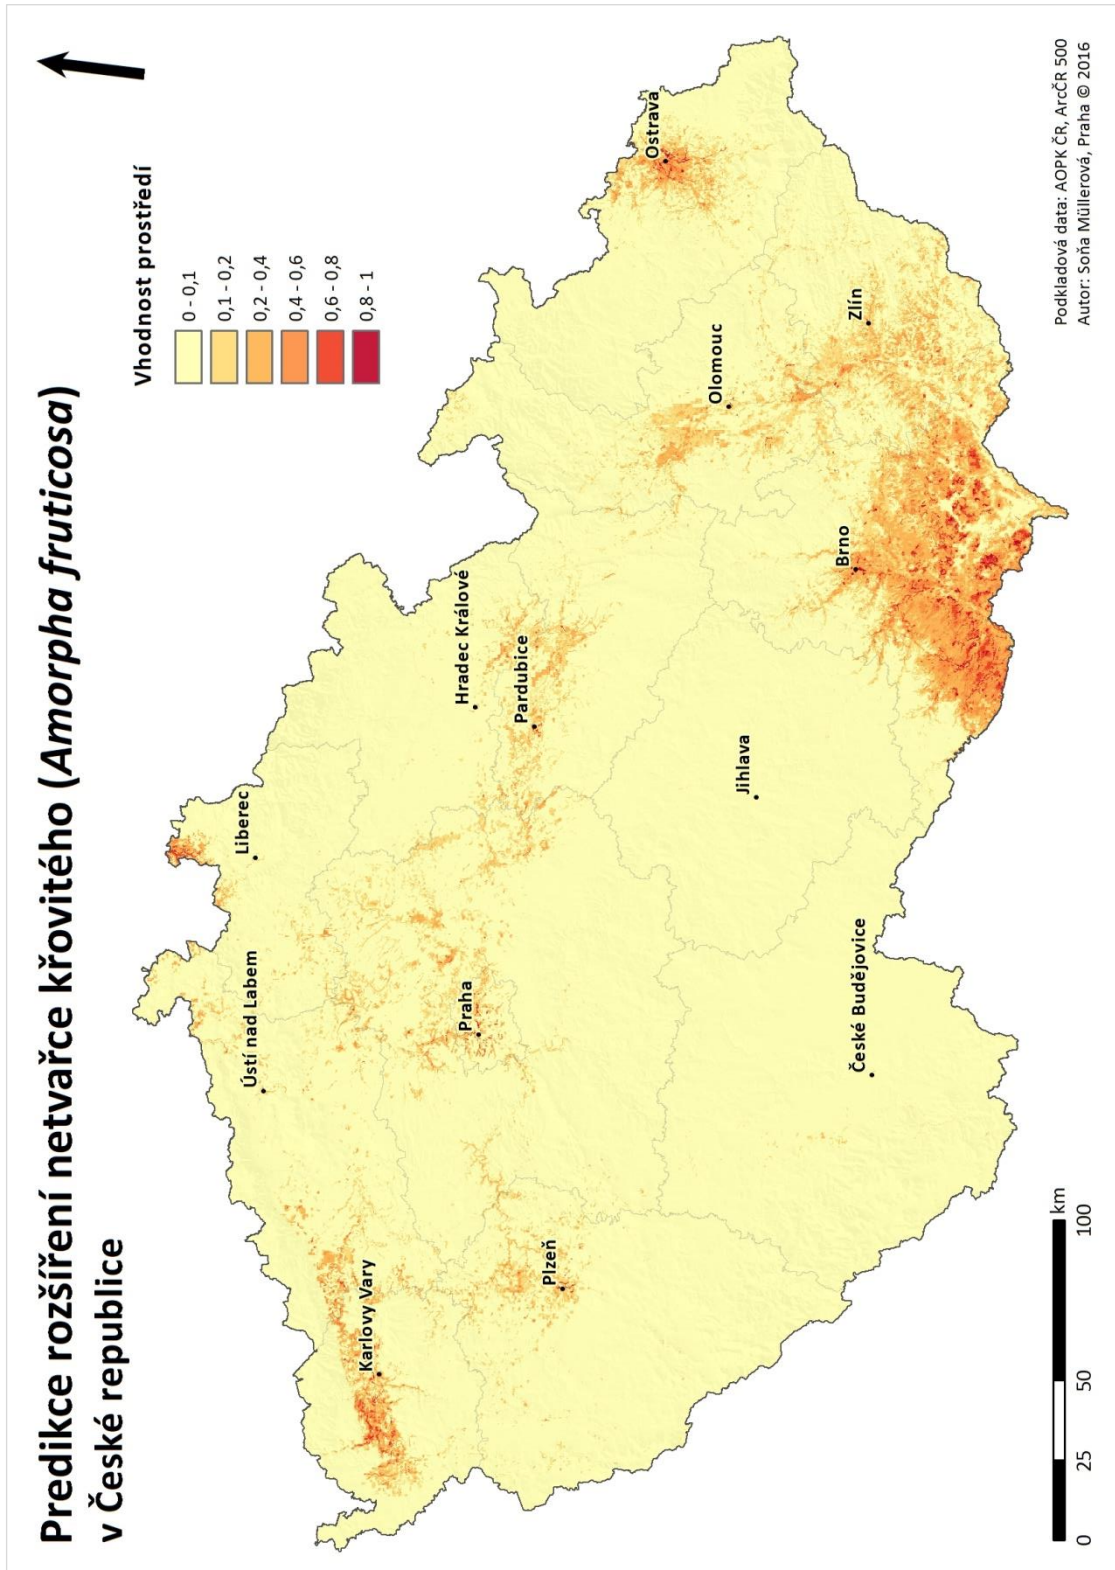
- Hijmans R. J., Cameron S. E., Parra J. L., Jones P. G. et Jarvis A., 2005: Very high resolution interpolated climate surfaces for global land areas. – *International Journal of Climatology* 25: 1965-1978.
- Hoskovec L., 2008: *Lycium barbarum* L. – kustovnice cizí. – BOTANY.cz, online: <http://botany.cz/cs/lycium-barbarum/>, cit. 24. 3. 2016.
- Hroneš M., 2010: *Amorpha fruticosa* – netvařec křovitý. – *Natura bohemica*, online: <http://www.naturabohemica.cz/amorpha-fruticosa/>?, cit. 24. 1. 2016.
- Ibáñez I., Silander, J. A. Jr., Wilson A. M., LaFleur N., Tanaka N. et Tsuyama I., 2009: Multivariate forecasts of potential distributions of invasive plant species. – *Ecological applications* 19(2): 359-375.
- Jelaska S. D., Antonić O., Nikolić T., Hršak V., Plazibat M. et Križan J., 2003: Estimating plant species occurrence in MTB/64 quadrants as a function of DEM-based variables - a case study for Medvednica Nature Park, Croatia. – *Ecological Modelling* 170(2): 333-343.
- Jiménez-Valverde A., 2012: Insights into the area under the receiver operating characteristic curve (AUC) as a discrimination measure in species distribution modelling. – *Global Ecology and Biogeography* 21(4): 498–507.
- Komprdová K., 2012: *Rozhodovací stromy a lesy*. – Akademické nakladatelství CERM, Brno.
- Křivánek M., 2006a: Netvařec křovitý (*Amorpha fruticosa* L.). In: Mlíkovský J. et Stýblo P. [eds.]: *Nepůvodní druhy fauny a flóry České republiky*. – ČSOP, Praha: 46 – 47.
- Křivánek M., 2006b: Kustovnice cizí (*Lycium barbarum* L.). In: Mlíkovský J. et Stýblo P. [eds.]: *Nepůvodní druhy fauny a flóry České republiky*. – ČSOP, Praha: 122 – 123.
- Křivánek M., Pyšek P., Sádlo J. et Mandák B., 2006: Cormophyta – vyšší rostliny. In: Mlíkovský J. et Stýblo P. [eds.]: *Nepůvodní druhy fauny a flóry České republiky*. – ČSOP, Praha: 28 – 33.
- Lassueur T., Joost S. et Randin C. F., 2006: Very high resolution digital elevation models: Do they improve models of plant species distribution? – *Ecological Modelling* 198(1): 139-153.
- Li X. et Wang Y., 2013: Applying various algorithms for species distribution modelling. – *Integrative Zoology* 8(2): 124-135.

- Merow C., Smith M. J. et Silander J. A., 2013: A practical guide to MaxEnt for modeling species' distributions: What it does, and why inputs and settings matter. – *Ecography* 36(10): 1058–1069.
- Miller J., 2010: Species distribution modeling. – *Geography Compass* 4(6): 490-509.
- Mlíkovský J. et Stýblo P. [eds.], 2006: *Nepůvodní druhy fauny a flóry České republiky*. – ČSOP, Praha.
- Palmer M.: *Environmental Variables in Constrained Ordination*. – *Ordination Methods for Ecologists*, online: <http://ordination.okstate.edu/envvar.htm>, cit. 24. 1. 2016.
- Pearson R. G., 2010: Species' distribution modeling for conservation educators and practitioners. – *Lessons in Conservation* 3: 54-89.
- Pergl J., Sádlo J., Petrušek A. et Pyšek P., 2013: *Nepůvodní druhy živočichů a rostlin v ČR: návrh seznamů druhů vyžadujících zvláštní přístup (černý a šedý seznam)*. – Botanický ústav AV ČR, Průhonice.
- Pergl J., Sádlo J., Petrušek A., Laštůvka Z., Musil J., Perglová I., Šanda R., Šefrová H., Šíma J., Vohralík V. et Pyšek P., 2016: Black, Grey and Watch Lists of alien species in the Czech Republic based on environmental impacts and management strategy. – *NeoBiota* 28: 1–37.
- Peterson A. T., Papes M. et Kluza D. A., 2003: Predicting the potential invasive distributions of four alien plant species in North America. – *Weed Science* 51(6): 863-868.
- Phillips S. J., Dudík M. et Schapire R., 2004: A maximum entropy approach to species distribution modeling. – *Proceedings of the Twenty-First International Conference on Machine Learning*: 655–662.
- Phillips S. J., Anderson R. et Schapire R., 2006: Maximum entropy modeling of species geographic distributions. – *Ecological Modelling* 190(3-4): 231–259.
- Phillips S. J., 2008: *A Brief Tutorial on Maxent*, AT&T Research, online: <https://www.cs.princeton.edu/~schapire/maxent/tutorial/tutorial.doc>, cit. 8. 4. 2016.
- Pyšek P., 2001: *Zákonitosti rostlinných invazí*. In: Pyšek P. et Tichý L. [eds.]: *Rostlinné invaze*. – Rezekvítek, Brno: 3 – 9.
- Pyšek P. et Tichý L., 2001: *Rostlinné invaze*. – Rezekvítek, Brno.
- Pyšek P., Danihelka J., Sádlo J., Chrtek J. Jr., Chytrý M., Jarošík V., Kaplan Z., Krahulec F., Moravcová L., Pergl J., Štajerová K. et Tichý L., 2012a: *Catalogue of alien plants of*

- the Czech Republic (2nd edition): checklist update, taxonomic diversity and invasion patterns. – *Preslia* 84: 155–255.
- Pyšek P., Chytrý M., Pergl J., Sádlo J. et Wild J., 2012b: Plant invasions in the Czech Republic: current state, introduction dynamics, invasive species and invaded habitats. – *Preslia* 84: 575–629.
- Rak L., 2007: *Amorpha fruticosa* L. – netvařec křovitý. – BOTANY.cz, online: <http://botany.cz/cs/amorpha-fruticosa/>, cit. 24. 3. 2016.
- Sádlo J., 2001: Kustovnice cizí. In: Pyšek P. et Tichý L. [eds.]: Rostlinné invaze. – Rezekvítek, Brno: 25 – 26.
- Sekerka P., 2010: Obrazový opravník obecně oblíbených omylů 4.: Kustovnice. – BOTANY.cz, online: <http://botany.cz/cs/opravnik-kustovnice-goji/>, cit. 24. 3. 2016.
- Václavík T. et Meentemeyer R. K., 2012: Equilibrium or not? Modelling potential distribution of invasive species in different stages of invasion. – *Diversity and Distributions* 18(1): 73–83.
- Veselý P., 2015: Zkušenosti s likvidací vybraných invazních druhů: Příspěvek k semináři o šíření invazních rostlin a možnostech jejich likvidace. – Ústav botaniky a zoologie, Přírodovědecká fakulta MU, Brno, online: [http://www.ekocentrumkoniklec.cz/wp-content/uploads/2015/03/Invazni\\_druhy\\_zkusenosti\\_Pavel\\_Vesely.pdf](http://www.ekocentrumkoniklec.cz/wp-content/uploads/2015/03/Invazni_druhy_zkusenosti_Pavel_Vesely.pdf), cit. 23. 1. 2016.
- Young N., Carter L. et Evangelista P., 2011: A MaxEnt model v 3.3.3e tutorial (ArcGIS v10). – Fort Collins, Colorado.
- Zhu L., Sun O. J., Sang W., Li Z. et Ma K., 2007: Predicting the spatial distribution of an invasive plant species (*Eupatorium adenophorum*) in China. – *Landscape Ecology* 22(8): 1143–1154.

## 8 PŘÍLOHY

Příloha č. 1: Predikce rozšíření netvaře křovitého v České republice.



Příloha č. 2: Predikce rozšíření kustovnice cizí (*Lycium barbarum*) v České republice.

