



Program TransAdapt

Translace poznatků a transfer postupů pro adaptaci
na klimatickou změnu do zemědělské a lesnické praxe
a veřejné správy: co-creative přístup

Aktivita 2.4

Průvodní zpráva k aktivitě 2.4 – Aktualizace a zpřesnění metodiky pro
stanovení pravděpodobnosti rozpadu lesních ekosystémů v závislosti
na stanovištních podmínkách

Obsah

1	Úvod do problematiky a cíl aktivity	3
2	Hlavní faktory ovlivňující chřadnutí smrkových porostů	4
2.1	Přírodní abiotické faktory	6
2.1.1	Klimatické podmínky	6
2.1.2	Půdní podmínky	6
2.2	Přírodní biotické faktory	6
2.2.1	Václavky	6
2.2.2	Lýkožrouti	7
2.3	Antropogenní faktory.....	7
2.3.1	Imisní zátěž	7
2.3.2	Klimatická změna	8
2.3.3	Nevhodné lesnické hospodaření	9
3	Studie s podobným zaměřením	10
4	Aktualizace metodiky pro stanovení pravděpodobnosti rozpadu lesních ekosystémů v závislosti na stanovištních podmínkách	12
4.1	Zájmové území a zdrojová data	12
4.2	Statistické zpracování dat	15
4.3	Výsledky	18
4.3.1	Klasifikační model	18
4.3.2	Regresní model	23
4.3.3	Celkový výkon kombinovaného přístupu	27
5	Závěr	29
6	Použitý software	30
7	Seznam použitých zkratk	30
8	Literatura	31

1 Úvod do problematiky a cíl aktivity

Od konce 20. století dochází na území České republiky k výraznému úbytku a odumírání smrkových porostů. Tento jev lze charakterizovat jako pokles životaschopnosti smrků, který se projevuje úbytkem asimilačního aparátu a bioreprodukčních schopností stromů, což má negativní dopad na celé lesní ekosystémy (DOBBERTIN, 2005; ŠRÁMEK a kol., 2014). První závažné poškození smrkových porostů v našem prostředí bylo zaznamenáno již v březnu 1977 a opět na začátku roku 1979. Významné škody zasáhly zejména horské oblasti a regiony postižené imisemi, kde dlouhodobé působení kyselých dešťů způsobilo vyplavování klíčových živin, například vápníku a hořčíku, což oslabovalo zdraví stromů (VACEK, LEPŠ, 1999; ŠRÁMEK a kol., 2014).

Ačkoliv tento proces byl ze začátku pozorován především v horských oblastech s chudými půdami a oblastí s vysokým znečištěním ovzduší, výraznější projevy chřadnutí smrku se v některých lokalitách objevily až po extrémně suchých letech, například v roce 2003 (JANKOVSKÝ, 2014). Momentálně je chřadnutí smrkových porostů globálním problémem, který postihuje střední Evropu, především na Moravě, v jižním Polsku, severozápadním Slovensku a části Německa (JENIŠ, 2014; ŠRÁMEK a kol., 2014). Tento jev je důsledkem složitého působení několika stresových faktorů, jež spolu navzájem působí a zhoršují tak předcházející stav lesa (CUDLÍN, MORAVEC, CHMELÍKOVÁ, 2001).

Až do roku 2018 lesy v ČR trvale akumulovaly uhlík, od roku 2019 v souvislosti s kůrovcovou kalamitou se staly v národní inventuře zdrojem uhlíku. Z tohoto důvodu je třeba získat údaje o pravděpodobnosti rozpadu hospodářských lesů s převahou smrku při další kůrovcové kalamitě, způsobené poklesem jejich obrany schopnosti na území ČR. Hlavním záměrem je poskytnout vlastníkově lesa informace o schopnosti jednotlivých porostních skupin s převahou smrku, starších 50 let, přizpůsobit se změně klimatu (včetně klimatických extrémů) a naplánovat podle toho jejich management, případně obnovu. I když skutečná doba rozpadu porostů bude záviset na nepredikovatelném průběhu počasí v jednotlivých letech, bude možné z výsledků vícerozměrné analýzy zjistit, které porosty jsou méně a které více rezistentní vůči současným komplexním stresovým faktorům. Primárně je tedy hodnoceno riziko porostů v oblastech, kde se dosud kůrovcová kalamita naplno nerozběhla. Analýza rezistence smrkových porostů s převahou smrku, starších 50 let, byla provedena na základě vícerozměrné statistické analýzy vztahu vybraných stanovištních a porostních charakteristik s postupujícím rozpadem porostů v posledních zhruba 10 letech, na základě lesnických dat a dat DPZ v prostředí GIS.

Cílem této aktivity bylo aktualizovat a zpřesnit původní metodický postup stanovení pravděpodobnosti rozpadu smrkových porostů při další kůrovcové kalamitě, způsobené poklesem obranyschopnosti smrku ztepilého v závislosti na stanovištních podmínkách, porostních charakteristikách a způsobu hospodaření, vypracovaný řešitelským týmem této aktivity v rámci předchozích výzkumných úkolů (CUDLÍN a kol., 2021). Výrazným inovativním prvkem oproti předchozí podobě metodiky je důraz na využití bezešvých digitálních geodat v rozsahu celé ČR a s důrazem na data dálkového průzkumu Země.

2 Hlavní faktory ovlivňující chřadnutí smrkových porostů

Předkládaná aktualizovaná metodika se zaměřuje na analýzu příčin nahodilé těžby a výskytu stojících souší v porostech s převahou smrku, které jsou v posledních několika letech v naprosté většině případů následkem kůrovcové kalamity. Umožňuje odhalit hlavní faktory, které předurčují nebo napomáhají rozpadu smrkových porostů. Správné určení těchto faktorů je klíčové, jelikož zjištěné poznatky lze aplikovat na vhodné lesní hospodaření a obnovu lesa, které povedou k vývoji stabilních lesních ekosystémů, které navíc napomáhají mírnit následky klimatické změny pohlcováním vzdušného CO₂. Jak uvádí např. Čermák (2014), do budoucna bude klesat plocha lesa vhodného pro pěstování smrku. I z tohoto důvodu je vhodné provést analýzu pravděpodobnosti rozpadu smrkových porostů a odhalit pro smrk nevhodná stanoviště.


Metodika definuje postup vedoucí ke stanovení pravděpodobnosti rozpadu hospodářských lesů s převahou smrku převyšujícího stáří 50 let v příštích 10 letech na území České republiky. Výsledkem je mapové znázornění pravděpodobností vyjádřené kategorickou škálou. Tento výstup lze například uplatnit jako podklad pro vymezení ohrožených lesních porostů, na kterých lze následně provést odpovídající zásahy k jejich ochraně či snížit obmýtí.

Cílem metodiky je poskytnout vlastníkům lesa informace o schopnosti hospodářských lesů s převahou smrku starších 50 let, přizpůsobit se klimatu a naplánovat podle toho jejich management, případně obnovu. Ačkoli skutečná doba rozpadu porostů závisí na nepredikovatelném průběhu počasí v jednotlivých letech, je možné z výsledků vícerozměrné analýzy zjistit, které porosty jsou méně a které více rezistentní vůči současným komplexním stresovým faktorům. Primárně je tedy hodnoceno riziko porostů v oblastech, kde kůrovcová kalamita dosud nenabyla výrazných rozměrů. Analýza rezistence smrkových porostů s převahou smrku starších 50 let se provádí na základě vícerozměrné statistické analýzy vztahu vybraných stanovištních a porostních charakteristik s postupujícím rozpadem porostů v posledních zhruba 10 letech na základě lesnických dat a dat dálkového průzkumu Země (DPZ) v prostředí GIS.

Jak ukázalo mnoho studií, chřadnutí a odumírání smrkových porostů jsou komplexní problémy způsobené synergickým působením přírodních a antropogenních stresových faktorů (CUDLÍN, MORAVEC, CHMELÍKOVÁ, 2001). Toto působení a jeho průběh velice dobře ilustruje tzv. Manionova spirála, která je uvedena na obr. 1 (MANION, 1991). Manion (1991) vymezil tři úrovně stresorů (stresových faktorů), které vedou k zániku lesních porostů. První úroveň je tvořena tzv. predispozičními faktory, které samy o sobě chřadnutí přímo nevyvolávají, ale vytvářejí předpoklad k působení faktorů druhé úrovně. Predispozičními faktory jsou např. urbánní prostředí, nízká úživnost půd, klimatická změna, znečištěné ovzduší a vyšší věk jedinců. Druhou úrovní jsou tzv. spouštěcí (iniciační) faktory, kam spadají mimo jiné listožravý hmyz, sucho až na úroveň vadnutí, mraz a výrazné imisní zatížení. Třetí úroveň, tzv. přispívající (mortalitní) faktory, již vede k zániku lesa. Spadají sem dřevokazné houby (např. václavky) a podkorní a dřevokazný hmyz (např. lýkožrouti).

Jak naznačuje toto schéma, spouštěcími faktory chřadnutí a odumírání smrkových porostů nemohou být prioritně lýkožrouti či václavky, ale spouštěcí faktory, jako výrazná imisní zátěž či stres extrémním suchem. I spouštěcí faktory jsou však podmíněny přítomností predispozičních

faktorů, jakými jsou např. pěstování druhu mimo klimatické optimum, poškozená půda či imise. (SLODIČÁK, 2014)



Obr. 1 Manionova spirála znázorňující proces chřadnutí a odumírání lesních porostů. Zdroj: Manion, 1991

V následujícím textu jsou popsány jednotlivé faktory, které významně ovlivňují chřadnutí smrku v České republice. Faktory lze členit na přírodní abiotické (především půdní a klimatické podmínky), přírodní biotické (např. podkorní, tj. kůrovcovití, a listožravý hmyz a dřevokazné houby) a antropogenní (klimatická změna, imisní zátěž, nevhodné pěstební postupy, změny v obhospodařování půd a další).

2.1 Přírodní abiotické faktory

2.1.1 Klimatické podmínky

Klima je významným faktorem ovlivňujícím chřadnutí smrkových porostů. Produkční optimum smrku se nachází v živné řadě čtvrtého a pátého vegetačního stupně, nicméně vzhledem k mělkým kořenům má nižší možnost příjmu vody z půdy, a je proto náchylnější na stres suchem, který navíc snižuje příjem živin z půdy (SLODIČÁK, 2014; ŠRÁMEK, SOUKUP, SLODIČÁK, 2009). Z toho důvodu jsou v těchto oblastech smrkové porosty citlivější k působení stresových faktorů než porosty jiných dřevin (SLODIČÁK, 2014). Jeniš (2014) a Šrámek a kol. (2014) uvádějí, že primární příčinou chřadnutí smrkových porostů se jeví vláhový deficit, následkem kterého dochází k oslabování smrkových porostů, snížení příjmu živin a následně sekundárnímu napadení václavkami a lýkožrouty.

2.1.2 Půdní podmínky

Šrámek, Soukup a Slodičák (2009), kteří se zabývali chřadnutím smrku v revíru Nýdek (spadající do lesní správy Jablunkov), zjistili, že v nejsilněji poškozené oblasti bylo nasycení sorpčního komplexu bazickými živinami minimální v celém půdním profilu a zásadní obsah živin tak zůstal pouze v humusové vrstvě. Tento stav se výrazně projevuje ve výživě dřevin a podstatně nahrává snížení odolnosti smrkových porostů vůči dalším stresovým faktorům. Nízký obsah bazických živin může být dán buď přirozenou chudostí a kyselostí půdy, nebo její antropogenně podmíněnou acidifikací (viz 2.3 Antropogenní faktory). Šrámek a kol. (2014) dále ve své studii upozornili na to, že většina chřadnoucích porostů se nachází na edaficky příznivých stanovištích a role půdního prostředí je tak v některých studiích považována za druhotnou. Nízké obsahy živin prokázané v jehličí jsou pak přikládány nedostatku půdní vody, která působí jako transportní medium, nebo poškození kořenů václavkami. Ve své studii však zjistili, že i na typologicky příznivých půdních kategoriích se mohou vyskytovat svrchní horizonty, které jsou výrazně ochuzené o bazické prvky. Vzhledem k mělkému zakořenění smrku jsou právě tyto horizonty pro jeho výživu podstatné.

2.2 Přírodní biotické faktory

Jak dobře ilustruje Manionova spirála (1991), biotické faktory, mezi které se řadí především různé druhy václavek a lýkožroutů, jsou mortalitními faktory. Představují závěrečný stres vedoucí ke skutečnému odumírání lesa a k jejich nástupu vede snížená vitalita smrkových porostů způsobená predispozičními a spouštěcími faktory (SLODIČÁK, 2014). Jsou důvodem, proč dochází k odumírání lesa v tak rozsáhlém měřítku (ŠRÁMEK, SOUKUP, SLODIČÁK, 2009).

2.2.1 Václavky

Jankovský (2014) uvádí, že václavky jsou významnou součástí lesních ekosystémů, jelikož jejich přirozenou úlohou je rozklad dřevní hmoty uložené v zemi a příležitostných parazitů nacházejících se na predisponovaných jedincích. Ve smíšeném lese napadají oslabené a přestárlé jedince, čímž

napomáhají regulovat druhové i věkové složení ve prospěch klimaxového společenstva. Z hlediska chřadnutí a odumírání smrkových porostů jsou václavky nejvíce problematické v sekundárních porostech nižších a středních poloh. Tedy tam, kde smrk roste na hranici ekologického optima a trpí nedostatkem vody. Narušení vodního provozu rostliny je obecně nejčastější příčinou infekce václavkami. Nemusí se přitom jednat pouze o výskyt sucha, k napadení václavkami může dojít i při výrazném zamokření a následné hypoxii (nedostatek kyslíku). Václavky (spolu s dalšími dřevokaznými houbami) po napadení způsobují kořenovou hnilobu, čímž prohlubují vodní deficit hostitele a predisponují jej k náletu lýkožroutů (kůrovců). Mohou tak být jak spouštěcím faktorem, jelikož prohlubují stresovou zátěž smrku, tak mortalitním faktorem. Hlavním škodlivým druhem václavek, podílejícím se na rozpadu smrkových porostů v nižších a středních polohách, je václavka smrková (*Armillaria ostoyae*).

2.2.2 Lýkožrouti

Lýkožrouti jsou brouci z podčeledi kůrovcovitých, kteří se řadí mezi podkorní hmyz. Mezi nejproblematictější zástupce u nás patří lýkožrout smrkový, severský a lesklý, proti kterým upravuje prevenci, kontrolu, obranu a asanaci kůrovcového dříví norma ČSN 48 1000 Ochrana proti kůrovcům na smrku z roku 2005. Haluša a Trombik (2014) uvádějí, že ačkoli jsou chřadnoucí stromy z lesů pravidelně odstraňovány, populace kůrovců zůstávají na vysokých hladinách nebo se výrazně zvyšují. V mladých smrkových porostech dle autorů bývají nejhojnější lýkožrout lesklý (*Pityogenes chalcographus*) a obecný (*Pityophthorus pityographus*), ve starých porostech pak domují druhy rodu *Ips*, a to lýkožrout severský (*Ips duplicatus*), smrkový (*Ips typographus*) a malý (*Ips amitinus*) spolu s lýkožroutem lesklým (*Pityogenes chalcographus*). Kromě starších a oslabených stromů mohou lýkožrouti napadat i zdravé stromy. Jak uvádí Jankovský (2014), podkorní hmyz na sobě může přenášet spory hub z oslabených stromů, čímž může přenášet patogeny na zdravé stromy. Na těch se následně objevují houbové infekce a dochází k působení patogenu na dřevinu (může se jednat o ucpávání vodivých drah a pryskyřných kanálků či pokles tlaku vody). To vede k rychlému poklesu rezistence a následnému zavadání stromu, který se stává náchylným k náletu lýkožroutů.

2.3 Antropogenní faktory

2.3.1 Imisní zátěž

Imisní zátěž v České republice kulminovala v 70. a 80. letech minulého století. Vacek a Lepš (1991) uvádějí, že vlivem imisí bylo na našem území poškozeno 52,2 % rozlohy lesů. Poškození se týkalo především jehličnatých porostů i proto, že jejich asimilační aparát je vystaven působení polutantů po celý rok, což je činí citlivější na znečištění atmosféry.

Zásadními problémy spojenými s imisní zátěží v souvislosti s chřadnutím smrku jsou přímé působení polutantů a kyselých dešťů, nadměrná depozice dusíku a acidifikace půdy. Hruška a Cienciala (2002) popisují, že při vysokých koncentracích SO₂ v ovzduší vzniká za působení vzdušné vlhkosti roztok H₂SO₄, který naleptává krycí rostlinné orgány. Posléze dochází k přímému

kontaktu kyseliny s asimilačními orgány rostliny, poškozující chlorofyl a funkci průduchů, čímž je prakticky zamezena asimilace. Za vhodných podmínek může k takovému poškození dojít v průběhu desítek minut. Následkem poškození je především žloutnutí jehlic a omezení výdeje vody vlivem ztráty funkčnosti průduchů. To může vést k dysfunkci asimilačních orgánů. Důsledkem je nedostatek energie pro fyziologické procesy v rostlině a dehydratace rostliny, která může znamenat její úhyn fyziologickým suchem. Autoři dále uvádějí, že troposférický ozon, který u rostlin způsobuje oxidační stres, při dlouhodobém působení přispívá k chřadnutí porostů. Na zvýšenou hladinu oxidativního stresu totiž porosty reagují tvorbou antioxidačních komplexů, čímž využívají významnou část produktů fotosyntézy, které slouží jako rezerva pro zvládání stresových situací (ŠRÁMEK, SOUKUP, SLODIČÁK, 2009; SLODIČÁK, 2014).

Zvýšená depozice dusíku vede k podpoře růstu porostů, ale současně zvyšuje nároky rostlin na ostatní živiny (HRUŠKA, CIENCIALA, 2002). Urychlený růst stromů je problematický zejména ve vyšších nadmořských výškách, kde se nacházejí málo úživné půdy a kde došlo k vyplavení bazických kationtů kyselými dešti. Následná nerovnováha živin vede k celkovému oslabení stromů, které znamená vyšší náchylnost ke zlomům, poškození suchem či škůdcům, a projevuje se žloutnutím a opadáváním jehlic a celkovým chřadnutím porostů.

Mezi následky acidifikace půdy, kterou způsobuje či urychluje kyselá depozice, se řadí snížení úživnosti půd a vyplavování bazických prvků z půdy, což znamená sníženou dostupnost některých živin, a tedy sníženou vitalitu porostů. Kupříkladu Slodičák (2014), který analyzoval chřadnutí smrků na Opavsku, uvádí, že nízké obsahy živin v půdě jsou s největší pravděpodobností následkem dlouhodobé imisní zátěže. Šrámek a kol. (2014) popisují, že přímé působení oxidu siřičitého (SO_2) se projevilo až od poloviny 90. let, a to především v západním Krušnohoří a v Jizerských a Orlických horách. Ve smrkovém jehličí byly zjištěny kriticky nízké obsahy hořčíku, které vedly ke žloutnutí jehličí, blokování fotosyntézy a narušení celkové energetické bilance stromů, které vedly až k odumírání smrkových porostů.

2.3.2 Klimatická změna

Jak již bylo uvedeno, sucho je významným predispozičním stresorem, který v konečném důsledku může způsobovat mortalitu smrkových porostů i v případech, kde samo o sobě mortalitní není (ČERMÁK, 2014). Mnoha autorů ho považuje za primární příčinu chřadnutí a odumírání smrkových porostů (JENIŠ, 2014; MRKVA, 2000; ŠRÁMEK a kol., 2014). Vzhledem k tomu, že jsou do budoucna očekávány častější a delší epizody sucha (TRNKA a kol., 2015), a to spolu se zvýšenou četností extrémních klimatických jevů, jako jsou bořivé větry, extrémně horké dny a přívalové deště (ČERMÁK, 2014), hraje antropogenně podmíněná změna klimatu významnou roli. Jak uvádí Čermák (2014), rizikovými situacemi v souvislosti s klimatickou změnou jsou dále především extrémní teploty ve vegetačním období, kdy rostliny potřebují přijímat vodu nejvíce, zvýšení četnosti přisušků, prodloužení vegetační doby, vyšší hodnoty ozáření rizikové pro elongační růstovou fázi, prodloužení období s teplotami pod (v noci) a nad (ve dne) $0\text{ }^{\circ}\text{C}$, zvyšující riziko poškození rostliny vytranspirováním, i prodloužení vegetační doby, a to např. z důvodu pozdní lignifikace a následného poškození mrazem. Dle autora se jako vhodná délka vegetační doby smrku na území České republiky odhaduje 120–130, přičemž ve čtvrtém lesním vegetačním

stupni (LVS) činí přibližně 140–150 dní. Podle prognóz změny klimatu by však v roce 2030 mohla být ve čtvrtém LVS o 10–15 dní delší.

2.3.3 Nevhodné lesnické hospodaření

Hruška a Cienciala (2005) shrnují přímé antropogenní působení na lesní ekosystémy, které často destabilizují a oslabují lesní ekosystémy, čímž mohou vést nebo přispívat k chřadnutí či odumírání lesních porostů. Patří k nim přeměna lesních ekosystémů mimo přirozený stav, kam lze mimo jiné zařadit změnu druhové skladby či věkového složení a výchovu porostů; změny v obhospodařování půd, tedy zalesňování či odlesňování; export biomasy; degradace a odnos povrchových vrstev půd; dlouhodobá depozice imisních látek a dusíku a globální změna prostředí, tedy velkoplošné změny chemismu ovzduší a klimatických charakteristik.

V případě smrku je zásadním problémem jeho vysazování v nevhodných podmínkách, tzn. na nevhodných stanovištích a mimo jeho přirozený areál. Jak uvádí např. Slodičák (2014), optimální podmínky pro růst smrku začínají v šestém LVS, přičemž nejhojněji je smrk zastoupen až v sedmém LVS. Optimální podmínky pro růst smrku jsou totiž perhumidní, tedy průměrná roční teplota by se měla pohybovat kolem 6 °C a roční srážky přesahovat 800 mm (ČERMÁK, 2014). Už z tohoto plyne, že jeho vysazování v nižších LVS je zcela nevhodné. Čermák (2014) doporučuje extrémní omezení či ukončení pěstování smrku ve třetím LVS a omezení pěstování ve čtvrtém LVS. Dle autora je výsadba vhodná pouze na nejpříznivějších stanovištích a pokud možno ve směsích. Novák, Dušek a Slodičák (2014) uvádějí, že změna druhové skladby by měla ústít v minimalizaci smrku ve čtvrtém LVS a snížení jeho zastoupení v pátém LVS. Dušek (2014) popisuje poznatky z praxe, které poukazují na to, že u silně poškozených porostů v oblasti chřadnutí je pravděpodobně jedinou možností přechodná změna druhové skladby lesa s vyloučením obnovy smrku do pátého LVS s výsadbou dřevin rezistentních vůči stresorům, které chřadnutí vyvolávají.

Dalším negativní praktikou je zakládání smrkových monokultur, která přispívá ke snižování úživnosti půd vlivem sekundárního okyselování opadem jehličí. I proto je doporučována bohatá druhová skladba lesa se zastoupením listnatých dřevin a určitým poměrem tzv. melioračních dřevin, které pomáhají zlepšovat půdní vlastnosti, včetně její úživnosti. Příklady těchto dřevin uvádí např. Novák, Dušek a Slodičák (2014), včetně jejich vlivu na půdní prostředí. Autoři zmiňují např. buk lesní (především díky charakteru zakořenění); duby; jasan ztepilý, mající prakticky stejný vliv na půdu jako buk; habr obecný, jehož opad se dobře rozkládá a bazické živiny se tak rychleji uvolňují do ekosystému; javory a lípu srdčitou, která se řadí mezi nejlepší z hlediska udržení vyšší hodnoty pH a obsahu bazických živin v půdě a která je schopna setrvávat v podúrovni.

3 Studie s podobným zaměřením

Odumíráním smrku se zabývá řada autorů, přičemž řada z nich již byla zmíněna (např. MRKVA, 2000; ŠRÁMEK, SOUKUP, SLODIČÁK, 2009; ČERMÁK, 2014; HOLUŠA, TROMBIK, 2014; JENIŠ, 2014, SLODIČÁK, 2014; ŠRÁMEK a kol., 2014). Velmi detailně studovali vztah mezi stanovištními a porostními charakteristikami prostředí a chřadnutím smrkových porostů např. Samec, Tuček a kol. (2012). Autoři pomocí statistické analýzy vytvořili tzv. zóny ochrany lesa (ZOL), které znázorňují intervaly růstových podmínek lesa zahrnující jeho náchylnost k chřadnutí. Při výběru stanovištních a porostních charakteristik se soustředili především na klimatické charakteristiky, složky celkové kyselé depozice, vlastnosti minerálních půdních horizontů, taxační charakteristiky, veličiny DPZ, předpokládanou evapotranspiraci a chemické vlastnosti nadložního humusu.

Cudlín, Čermák a Jankovský (2004) zjišťovali riziko rozpadu smrkových porostů na území přírodní lesní oblasti (PLO) Český les v podmínkách daných různými scénáři klimatické změny. Riziko bylo vyjádřeno jako tzv. faktor ohrožení, který byl vypočten na základě expertního odhadu destabilizace smrkových porostů založeném na syntéze dosavadních poznatků o působení stresových faktorů v dané oblasti.

Kulla a Hlásný (2010) provedli multi-faktoriální analýzu chřadnutí smrkových porostů ve Slovenské části Beskyd. Statistické analýzy ukázaly, že k chřadnutí byly nejnáchylnější starší porosty s vyšším zastoupením smrku lokalizované v blízkosti zvýšené aktivity biotických škůdců. Cienciala a kol. (2014) provedli multikriteriální analýzu faktorů podmiňujících zdravotní stav porostů v lesním hospodářském celku (LHC) Jablunkov, která umožnila detekovat vazbu nezávislých veličin na zdravotní stav porostů. Vícerozměrnou regresí vznikl model o třech statisticky významných proměnných (depozice síry, geologie a teplotní poměry), který umožnil prostorové znázornění rizika pro zdravotní stav smrku. Analýzy dále ukázaly, že zásadním rizikem pro pěstování smrku jsou lokální chemismus půd a teplotní režim stanoviště. Chemismus půd byl ve studované oblasti významně narušen acidifikací a eutrofizací, způsobené dlouhodobou atmosférickou depozicí.

Bažazy a kol. (2019) analyzovali vitalitu smrkových porostů v jihozápadní části Polska v pohraničních oblastech s využitím údajů odvozených ze satelitních snímků. Pomocí metody posílené regrese rozhodovacího stromu (BRT – *Boosted Regression Trees*) zjistili, že nejlepším prediktorem vitality smrkových porostů za období 2012–2016 byla elevace a druhým nejvýznamnějším věk porostů.

Roessiger, Kulla a Sedliak (2020) zjišťovali, zda je rozpad smrkových porostů, (vyjádřený podílem objemu dřeva zpracovaného nahodilou těžbou za období 10 let), na území CHKO Beskydy a CHKO Kysuce na Slovensku statisticky významně ovlivněn věkem a podílem zastoupení smrku v porostu. Zjistili, že riziko rozpadu porostů se významně zvyšuje s rostoucím věkem a vyšším zastoupením smrku. Ukázalo se, že se ve smrkových porostech výrazně snižuje pravděpodobnost rozpadu zastoupení jiných dřevin od 25 % výše.

Kamińska a kol. (2021) se zabývali odumíráním smrkových porostů v Bělověžském lese v Polsku, které vypuklo v roce 2012 spolu s výskytem kůrovce. Studovanou oblast rozdělili do čtverců o hraně 100 m a míru odumírání smrků vymezili prostorovým modelováním. Následně zjišťovali závislost mezi stanovištními a porostními charakteristikami a mírou pravděpodobnosti napadení smrkových porostů kůrovci. Mezi analyzované charakteristiky zařadili např. procentuální zastoupení smrku a odumřelého smrku, převažující druhy stromů a věky stromů, procento pokrytí

čtverců korunami stromů a průměrnou výšku smrku a všech stromů. Konečný počet prvků analýzy činil 60 292. Metoda BRT ukázala, že klíčovými faktory pro napadení smrkových porostů kůrovci jsou výška smrku, stáří porostů, zastoupení smrku, podíl plochy pokryté korunami stromů mimo smrk a dominantní druhy stromů v porostech. Zároveň byla provedena hot-spot analýza znázorňující podobnosti mezi sousedícími lokacemi. Lokace byly charakterizovány především nejvyšším podílem smrku, převažujícím věkem porostů, výškou smrku a nejmenší plochou pokrytou korunami stromů mimo smrk.

4 Aktualizace metodiky pro stanovení pravděpodobnosti rozpadu lesních ekosystémů v závislosti na stanovištních podmínkách

4.1 Zájmové území a zdrojová data

V průběhu řešení této aktivity byl na základě předchozích znalostí navržen výchozí metodický postup a poté byly identifikovány vhodné datové zdroje, buď pro celou ČR již existující, nebo pro tuto analýzu nově vytvořené. Analyzované datové zdroje zahrnují jak lesnická data, tak data z dálkového průzkumu Země a další specializované tematické datasety. Jednotlivá data byla následně sesbírána/aktualizována a jednotně zpracována v pravidelné čtvercové síti s plochou 50 m v rozsahu zájmového území, a následně vzájemně integrována.

Na základě analýzy přírodních podmínek a dopadů kůrovcové kalamity prostřednictvím tzv. „Kůrovcové mapy“ (NLI, 2021) byla vybrána Přírodní lesní oblast č. 16 – Českomoravská vrchovina (PLO16). Vybrané základní charakteristiky PLO 16 pro tvorbu modelu, vyjádřené pomocí počtu pixelů v rastrových datasetech, jsou uvedeny v Tab. 1.

Tab. 1 Základní charakteristiky Přírodní lesní oblasti 16 Českomoravská vrchovina

Rozloha PLO 16	3 140 077 px
Aktuálně zalesněná plocha	389 995 px
Detekovaná holina (2018-2021)	161 670 px
Detekovaná holina v roce 2018	16 630 px
Pixelů zcela pokryto holinou	86 px

Na základě původní metodiky (CUDLÍN a kol. 2021), literární rešerše a odborných konzultací bylo vytipováno celkem 72 proměnných. Byla sesbírána a zpracována digitální data, pomocí kterých je možné uvedené faktory popsat. Některá data/faktory byla postupně vyřazena, protože a) na území ČR jsou produkována v příliš hrubém měřítku (místy 10 až 20násobně hrubším), b) měla silnou vzájemnou korelaci. Přehled všech vytipovaných proměnných, včetně jejich slovního popisu a datového typu je uveden v Tab. 2.

Následně byla definována základní podmínka pro selekci validních záznamů: validní (do další analýzy zahrnutý) pixel musel obsahovat více než 51 % výskytu smrku a současně musí mít více než 51 % výměry lesní plochy a současně musí být dosažena růstová fáze porostu – kmenovina (tedy věk 50+).

Na základě analytických a překryvných prostorových operací byla ve finální fázi vygenerována matice obsahující celkem 58 proměnných a 361 385 řádků, která byla dále statisticky analyzována.

Tab. 2 Přehled vytipovaných proměnných (metadata připravené a očištěné matrice pro PLO16)

Název proměnné	Slovní popis	Datový typ
Value (gid)	Identifikátor, označení kvadrátu (q) v GIS datech	číslo
Holina2018-2021	Identifikace, zda se v q vyskytuje holina ve sledovaném období; 1=0výskyt, - = nevyskytuje se	číslo
Celková výměra holin	Výměra holin v q za celé období (m ²)	číslo
% holiny z výměry podmínky	Procento (%) výměry celkové holiny z výměry průniku podmínek SM50+/kmenovina50+ v q	číslo
% holiny z výměry lesa	Procento (%) výměry celkové holiny z výměry plochy lesa v q	číslo
Holina18_Area	Výměra holiny v q v roce 2018 (m ²)	číslo
Holina19_area	Výměra holiny v q v roce 2019 (m ²)	číslo
holina20_area	Výměra holiny v q v roce 2020 (m ²)	číslo
Holina_2021	Identifikace, zda se v q vyskytuje holina ve v roce 2021; 1=0výskyt, - = nevyskytuje se	číslo
vymera_podminka_sm-k	Výměra průniku SM a kmenoviny (pokud měl každý přes 50 % z plochy q) (m ²)	číslo
procento_podminka_q	Procento zastoupení průniku SM a kmenoviny (pokud měl každý přes 50 % z plochy q) z plochy q	číslo
procento_podminka_les	Procento zastoupení průniku SM a kmenoviny (pokud měl každý přes 50 % z plochy q) z plochy LPF v q	číslo
kmenovina_procento	Procento zastoupení růstové fáze kmenoviny v q – v roce 2017	číslo
vymera_les_q	Výměra (m ²) lesní plochy (LPF) v q v roce 2017	číslo
vymera_lesa_procento	Procento výměry lesní plochy (LPF) v q v roce 2017	číslo
SM_procento	Procento výměry smrku z LPF (v q) v roce 2017	číslo
NDVI (avg)	Hodnota NDVI v roce 2017	číslo
TCI (avg)	Hodnota TCI v roce 2017	číslo
elevace (avg)	Průměrná nadmořská výška v q	číslo
slope	Medián sklonu v q	číslo
aspect	Medián orientace v q	číslo
prepocet1	Přepočet orientace vz. 1	číslo
přepočet2	Přepočet orientace vz. 2	číslo
curvature	Zakřivení reliéfu v q	číslo
profile C	Profilová křivost v q	číslo
planC	Planární křivost v q	číslo
Sox	5leté roční průměry (2013-2017) koncentrace SOx	číslo
Nox	5leté roční průměry (2013-2017) koncentrace Nox	číslo
SRA	Roční úhrn srážek (2017)	číslo
temp	Průměrná roční teplota (2017)	číslo
min_temp	Průměrná minimální teplota (2017)	číslo

sum_effect	Suma teplot v roce 2017	číslo
TPI	Topographic position index	číslo
TPI02	Topographic position index – verze 2	číslo
LVS	Lesní vegetační stupeň – plošně dominantní kategorie v q	kategorie
pedo_LVS	Edafická řada – plošně dominantní kategorie v q	kategorie
ISP	Infiltrační skupina půd – plošně dominantní kategorie v q	kategorie
BS	Basická saturace půdy	číslo
Bowen19_5	Bowenův poměr - vyjádření vodního stressu pro 19.5 2017	číslo
Bowen23_8	Bowenův poměr - vyjádření vodního stressu pro 23.8 2017	číslo
Bowen20_6	Bowenův poměr - vyjádření vodního stressu pro 20.6 2017	číslo
Bowen01_4	Bowenův poměr - vyjádření vodního stressu pro 1.4 2017	číslo
NDMI	Vlhkost povrchu v roce 2017	číslo
NDVI_2	NDVI v roce 2017 odlišný kompozit	číslo
fapar_jaro	FAPAR ¹ pro jarní období 2017	číslo
fcover_jaro	FcoVer ² pro jarní období 2017	číslo
lai_jaro	LAI ³ pro jarní období 2017	číslo
lai_cab_jaro	CAB ⁴ pro jarní období 2017	číslo
lai_cw_jaro	CW pro jarní období 2017	číslo
fapar_let	FAPAR ¹ pro jarní období 2017	číslo
fcover_let	FcoVer ² pro jarní období 2017	číslo
lai_let	LAI ³ pro jarní období 2017	číslo
lai_cab_jaro	CAB ⁴ pro jarní období 2017	číslo
lai_cw_let	CW pro jarní období 2017	číslo
fapar_podzim	FAPAR ¹ pro jarní období 2017	číslo
fcover_podzim	FcoVer ² pro jarní období 2017	číslo
lai_podzim	LAI ³ pro jarní období 2017	číslo
lai_cab_podzim	CAB ⁴ pro jarní období 2017	číslo
lai_cw_podzim	CW pro jarní období 2017	číslo
fapar_zima	FAPAR ¹ pro jarní období 2017	číslo
fcover_zima	FcoVer ² pro jarní období 2017	číslo
lai_zima	LAI ³ pro jarní období 2017	číslo
lai_cab_zima	CAB ⁴ pro zimní období 2017	číslo
lai_cw_zima	CW pro zimní období 2017	číslo
B8_homogeneity	Homogenita povrchu 2017	číslo
B8_contrast	Kontrast ploch 2017	číslo
SRA_normal	Dlouhodobá průměrný úhrn srážek za období 1991-2020	číslo

Tavg_normal	Dlouhodobá průměrná roční teplota za období 1991-2020	číslo
Tmax_normal	Dlouhodobá maximální roční teplota za období 1991-2020	číslo
Tmin_normal	Dlouhodobá minimální roční teplota za období 1991-2020	číslo

¹ FAPAR – Frakce absorbovaného fotosynteticky aktivního záření, tj. podíl příchozího slunečního záření ve spektrální oblasti fotosynteticky aktivního záření, které je absorbováno organismem (zkratka z angl. „*Fraction of Absorbed Photosynthetically Active Radiation*“)

² Fcover – frakce vegetačního pokryvu („*vegetation cover fraction*“)

³ LAI – index listové plochy („*leaf area index*“)

⁴ CAB – chlorofyl a + b

Každému čtverci byly přiřazeny odpovídající stanovištní a porostní charakteristiky (prediktory), vč. případného výskytu aktuálních holin a souší, které sloužily jako vysvětlující proměnná. Finální analýza se zaměřila na čtverce, kde: i) plocha lesa tvořila > 50 % rozlohy čtverce a ii) procento zastoupení smrku bylo > 50 %.

4.2 Statistické zpracování dat

Vstupní data obsahují 361 385 čtverců, pro které je k dispozici závislá proměnná, což je procento výměry celkové holiny z výměry plochy lesa ve čtverci za roky 2018 až 2021. Data byla transformována na spojitě hodnoty mezi 0 a 1, včetně krajních hodnot 0 (žádná holina) a 1 (celá výměra je holina). Jako prediktory bylo uvažováno celkem 58 proměnných získaných z dálkového průzkumu i pozemních měření, přičemž pro účely vlastní analýzy bylo následně využito 14 vybraných proměnných (Tab. 3). Prediktory měnící se v čase pocházejí z roku 2017 nebo z delšího období před dobou, kdy vznikly holiny (v případě klimatických dat z období tzv. nového klimatického normálu 1991–2020).

Tímto způsobem bylo zjištěno, které parametry lze použít k identifikaci zatím stojících porostů, které se v příštích letech pravděpodobně rozpadnou a porostů, které se nerozpadnou. Vzhledem k velkému objemu dat a vysokému podílu nulových hodnot v závislé proměnné byl zvolen dvoustupňový přístup k predikci, který kombinuje klasifikační a regresní model. Data pro oba modely byla rozdělena do tří sad – trénovací (60 %), validační (20 %) a testovací (20 %). Trénovací sada sloužila k učení modelů, validační sada k optimalizaci hyperparametrů a testovací sada k finálnímu hodnocení přesnosti predikcí. Toto rozdělení zajistí, že výkon modelů je posuzován na nezávislých datech.

Tab. 3 Přehled vysvětlované a vysvětlujících proměnných a jejich vybrané charakteristiky

	Označení	Popis	Datový zdroj	Producent	Frekvence aktualizace	Měřítko/ rozlišení
Vysvětlovaná proměnná	% holiny z výměry lesa	procento (%) výměry celkové holiny z výměry plochy lesa v q	-	-	-	-
Vysvětlující proměnná	procento_podminka_les	Procento zastoupení průniku SM a kmenoviny z plochy LPF v q	-	-	-	-
	TCI ¹ (avg)	hodnota TCI v roce 2017	Sentinel2 data	ESA (free)	1x5/10 dní	10m/px
	Sox	5leté roční průměry (2013-2017) koncentrace SOx	CHMU: OZKO	CHMU (free)	1x /rok	500m/px
	SRA	roční úhrn srážek (2017)	--	Czechglobe	denní data	500m/px
	pedo_LVS	Edafická řada – plošně dominantní kategorie v q	Lesnická typologie @OPRL	NLI (UHUL; free)	1x/10 let	1: 10 000
	NDMI	NDMI (Normalized Difference Moisture Index) - vlhkost povrchu v roce 2017	Sentinel2 data	ESA (free)	1x5/10 dní	10m/px
	NDVI_2	NDVI (Normalized Difference Vegetation Index) v roce 2017 odlišný kompozit	Sentinel2 data	ESA (free)	1x5/10 dní	10m/px
	fapar_let	FAPAR pro jarní období 2017	Sentinel2 data	ESA (free)	1x5/10 dní	10m/px
	fcover_let	FcoVer pro jarní období 2017	Sentinel2 data	ESA (free)	1x5/10 dní	10m/px
	lai_let	LAI pro jarní období 2017	Sentinel2 data	ESA (free)	1x5/10 dní	10m/px
	B8_homogeneity	homogenita povrchu v roce 2017	Sentinel2 data	ESA (free)	1x5/10 dní	10m/px
	B8_contrast	kontrast ploch v roce 2017	Sentinel2 data	ESA (free)	1x5/10 dní	10m/px
	SRA_normal	Dlouhodobá průměrný úhrn srážek za období 1991-2020	ClimRisk	Czechglobe	denní data	k.ú./ 500m/px

	Tmax_normal	Dlouhodobá maximální roční teplota za období 1991-2020	Climrisk	Czechglobe	denní data	k.ú./ 500m/px
--	-------------	---	----------	------------	---------------	------------------

¹ TCI – Index teplotní podmínek („*Temperature Condition Index*“)

Klasifikační model je prvním stupněm, jehož úkolem je rozlišit, zda podíl holin v čtverci je nulový nebo nenulový. Pro tento účel byly všechny nenulové hodnoty převedeny na hodnotu 1 a závislá proměnná byla transformována na kategoriální proměnnou s hodnotami 0 a 1. Analýza byla provedena modelem „**random forest**“, což je ansámblová metoda založená na kombinaci více rozhodovacích stromů. Každý strom je trénován na náhodném podvýběru dat a prediktorů, což zvyšuje robustnost modelu a snižuje riziko přeučení. *Random forest* model je schopen zachytit nelineární vztahy a interakce mezi prediktory, což je klíčové pro klasifikaci v heterogenních datech, jako jsou tato. **Nejlepší model s 10 prediktory** (viz obr. 2) byl vybrán na základě metriky AUC (*Area Under the Curve*), která měří schopnost modelu rozlišovat mezi třídami. Hodnota AUC blízka 1 značí perfektní klasifikaci, zatímco hodnota 0.5 odpovídá náhodnému odhadu.

Výhody „**random forest**“ modelu:

Robustnost vůči overfittingu („nadměrnému přizpůsobení“): díky použití mnoha stromů a náhodnému výběru prediktorů je random forest méně náchylný k overfittingu ve srovnání s jednotlivými rozhodovacími stromy.

Flexibilita: může být použit pro různé typy úloh a je schopen pracovat s velkým množstvím prediktorů a zvládat složité vztahy mezi nimi (máme původně 52 prediktorů, v GLM nešlo testovat různé interakce).

Odolnost vůči šumu: je odolný vůči šumu, protože agregace výsledků z mnoha stromů pomáhá vyladit chyby způsobené šumem v datech.

Nevýhody „**random forest**“ modelu:

Výpočetní náročnost: trénování velkého počtu stromů může být časově a výpočetně náročné, zejména pro velké datové sady.

Druhým stupněm je **regresní model**, který predikuje konkrétní hodnotu podílu holin pro čtverce s nenulovou predikcí z klasifikačního modelu. Zvolen byl model „**gradient boosting machine**“ (GBM), což je další ansámblová metoda, která postupně vylepšuje predikce pomocí sekvence rozhodovacích stromů a pro tato data měla lehce lepší výsledky než *random forest*. GBM přidává nové stromy tak, aby korigovaly chyby předchozích, což vede k vyšší přesnosti. Stejně jako *random forest* dokáže GBM zachytit nelineární vztahy a interakce mezi prediktory, což jej činí vhodným pro predikci kontinuálních hodnot v těchto datech. **Výsledný model s 13 prediktory** byl vybrán na základě metriky RMSE (*Root Mean Squared Error*), která měří průměrnou kvadratickou chybu predikcí a je citlivá na velké odchylky.

Nejlepší prediktory byly pro oba modely vybrány funkcí „**h2o.modelSelection**“, která umožňuje automatizovaně testovat kombinace vstupních proměnných tak, aby byl nalezen model s co nejvyšší vysvětlující schopností (R^2) pro různé velikosti podmnožin prediktorů. Postupně lze vytvořit více modelů s různými kombinacemi prediktorů o velikosti od 1 až po maximální počet prediktorů (*max_predictor_number*) a z každé velikosti vybrat tu kombinaci, která má nejlepší R^2 na validačních datech. K testování optimálních hyperparametrů (*n_trees*, *max_depth* a další) byla pro oba modely použita metoda „*grid search*“ (typ *random discrete*). *Grid search* systematicky testuje kombinace hyperparametrů, ale kvůli výpočetním limitům nebyl proveden úplný kartézský průzkum (*full cartesian*). Místo toho *random discrete* náhodně vybírá podmnožiny hyperparametrů, což je efektivní alternativa pro velká data, ale nemusí vždy najít absolutní optimum. Pro klasifikaci i regresi byl na zkoušku udělán i minimalistický model se třemi nejvýznamnějšími proměnnými, což může být použitelné pro predikci v případě nedostupnosti všech prediktorů použitých v nejlepších modelech.

Finální predikce se získá spojením výstupů z obou modelů. Klasifikační model nejprve predikuje pravděpodobnost, že podíl holin není nulový. Pokud tato pravděpodobnost nepřesáhne stanovený práh (je menší než 0,5), je predikce nastavena na 0. Na plochách označených klasifikátorem jako „nenulové“ aplikujeme regresní model GBM, který predikuje konkrétní hodnotu podílu holin jako spojitou veličinu. Celkový výkon kombinovaného modelu byl hodnocen na testovací sadě pomocí tří metrik. RMSE (*Root Mean Squared Error*) měří průměrnou kvadratickou chybu mezi predikcemi a skutečnými hodnotami, přičemž nižší hodnota značí vyšší přesnost; tato metrika je citlivá na velké chyby, což pomáhá identifikovat výrazné odchylky. MAE (*Mean Absolute Error*) měří průměrnou absolutní chybu a je méně ovlivněna extrémními hodnotami, což poskytuje doplňkový pohled na přesnost. R^2 (koeficient determinace) udává, jak dobře model vysvětluje variabilitu v datech, přičemž hodnota blízká 1 značí, že model zachycuje většinu variability.

4.3 Výsledky

4.3.1 Klasifikační model

Vybraný klasifikační „**random forest model**“ byl hodnocen především na základě hodnot pěti metrik (Tab. 3). Metrika AUC (*Area Under the Curve*) byla pro testovací data rovna 0.91, což indikuje vysokou úspěšnost při rozlišování mezi čtverci s nulovým a nenulovým podílem holin. Rozdíl mezi tréninkovou a testovací AUC (0.0094) je malý, což naznačuje jen mírné přeučení a velmi dobrou schopnost generalizace. Nízké hodnoty logaritmické ztráty ukazují, že model je celkově dobře kalibrovaný a pravděpodobnosti odpovídají reálným datům. Zvýšení o necelých 0.01 na testu je opět malé, model udržuje dobrou kvalitu odhadů pravděpodobností. Pokles AUCPR (*Area Under Precision-Recall Curve*) o 0.0463 poukazuje na menší schopnost udržet vysokou přesnost při nižších frekvencích pozitivních případů na testu. Přesto je testovací AUCPR stále na velmi dobré úrovni (> 0.80), což znamená, že model dobře vyvažuje citlivost a specifičnost při různých prahových hodnotách. Střední chyba na úrovni tříd (Mean Per-Class Errors) se zvýšila o 0.0046. Hodnota 0,16 znamená, že v průměru chybí model v přibližně 16 % případů na třídu.

Nízký nárůst po přechodu na testovací data opět potvrzuje robustnost modelu napříč všemi třídami. Matice záměn („*confusion matrix*“) porovnává skutečné třídy s třídami predikovanými modelem a ukazuje, kolik vzorků bylo klasifikováno správně či nesprávně (Tab. 4).


Tab. 3 Metriky kvality klasifikačního „random forest“ modelu pro nejlepší model s 10 proměnnými a minimální model se třemi proměnnými.

klasifikace	nejlepší model		minimální model	
metrika	trénovací data	testovací data	trénovací data	testovací data
AUC	0.9243	0.9149	0.8948	0.8866
Gini	0.8486	0.8299	0.7897	0.7733
LogLoss	0.3518	0.3401	0.3945	0.4006
AUCPR	0.9107	0.8643	0.8575	0.7907
Mean Per-Class Err.	0.1546	0.1591	0.1723	0.1748


Tab. 4 Matice záměn (confusion matrix), porovnání skutečných tříd s třídami predikovanými modelem. Řádky – skutečné třídy, sloupce – predikce, 0 – bez holiny, 1 – holina. Skutečně pozitivní a skutečně negativní hodnoty jsou tučně.

	predikce: 0	predikce: 1	chyba
skutečné: 0	33554	8966	0.211
skutečné: 1	3175	26385	0.107


Nejvýznamnější prediktory pro klasifikaci čtverců s holinami a bez nich byly NDMI, B8_homog a NDVI_2 (Obr. 2). Nízké hodnoty NDMI a B8_homog indikují vyšší pravděpodobnost rozpadu porostu a vzniku holiny, při vyšších hodnotách je malá pravděpodobnost vzniku holiny. NDVI_2 má efekt opačný, vyšší hodnoty predikují vznik holiny (Obr. 3, 4). Následují SRA_norm a B8_contrast. Ostatní prediktory sice model zpřesnily, ale jejich efekt je menší. Minimální model se třemi nejvýznamnějšími prediktory (NDMI, NDVI2 a B8_homog) má AUC rovnu 0.886 a i ostatní parametry jsou mírně horší než u nejlepšího modelu. V případě potřeby rychlé predikce bez nutnosti získávat data 10 prediktorů však může jít o použitelnou alternativu.



Obr. 2 Relativní význam jednotlivých proměnných v klasifikačním modelu.



Obr.3 Klasifikační „random forest“ model, efekty proměnných (jednotlivé datové body) na predikci vzniku holiny. Hodnoty proměnných jsou normalizovány, vysoké hodnoty jsou znázorněny červeně, nízké modře. Shapleyho hodnota (osa x) vyjadřuje příspěvek proměnné k predikci modelu; levá strana negativní dopad (žádná holina), pravá strana kladný dopad (vznik holiny).



Obr. 4 Klasifikační „random forest“ model, parciální efekt (ostatní proměnné nastaveny na průměrnou hodnotu) a) NDMI, b) NDVI_2 a c) B8_homog na vznik holiny. Pravděpodobnost vzniku holiny je vysoká pro nízké hodnoty NDMI a B8_homog a pro vysoké hodnoty NDVI_2.


4.3.2 Regresní model

Regresní model dosahuje na trénovacích datech nízké chyby (RMSE = 0.205, MAE = 0.165) a vysvětluje 41.8 % rozptylu hodnot podílu holin (Tab. 5). Na testovacích datech se chyby mírně zvyšují (RMSE = 0.245, MAE = 0.199), což naznačuje solidní, i když ne perfektní generalizaci. Ve srovnání s předchozím klasifikačním modelem, regresní model vykazuje střední predikční přesnost ve smyslu odhadu procenta pokryvu holiny ($R^2 = 0.411$), což je pro komplexnější přírodní data typické.


Nejvýznamnějším prediktorem pro hodnotu podílu holin je stejně jako v případě klasifikace NDMI následovaný NDVI2 a proměnnou „forest“ (Obr. 5). Ostatní prediktory mají sice relativně menší význam, ale model významně zpřesňují. Při vyšších hodnotách NDVI_2 (vyšších hodnotách biomasy) a proměnné „forest“ (podíl smrkové kmenoviny) lze očekávat vyšší podíl holin (Obr. 6 a 7). Minimální model se třemi nejlepšími prediktory (NDMI, NDVI2 a forest) už má na rozdíl od klasifikačního modelu výrazněji nižší predikční schopnost a nelze jím tedy plnohodnotně nahradit nejlepší model se všemi prediktory.

Tab. 5 Metriky kvality regresního GBM modelu pro nejlepší model s 13 proměnnými a minimální model se třemi proměnnými.


Regrese	nejlepší model		minimální model	
metrika	trénovací data	testovací data	trénovací data	testovací data
MSE	0.0422	0.0601	0.0675	0.0755
RMSE	0.2054	0.2452	0.2598	0.2748
MAE	0.1654	0.1995	0.2172	0.2307
RMSLE	0.1474	0.1751	0.1843	0.1947
R^2	0.4184	0.411	0.3431	0.2603



Obr. 5 Relativní význam jednotlivých proměnných (10 nejlepších) v regresním modelu.



Obr. 6 Regresní GBM model, efekty proměnných (jednotlivé datové body) na predikci vzniku holiny. Hodnoty proměnných jsou normalizovány, vysoké hodnoty jsou znázorněny červeně, nízké modře. Shapleyho hodnota (osa x) vyjadřuje příspěvek proměnné k predikci modelu; levá strana negativní dopad (0, žádná holina), pravá strana kladný dopad (1, holina).




Obr. 7 Regresní GBM model, parciální efekt (ostatní proměnné nastaveny na průměrnou hodnotu)
a) NDMI, b) NDVI_2 a c) podílu smrkové kmenoviny na vznik holiny. Pravděpodobnost vzniku holiny je vysoká pro nízké hodnoty NDMI a vysoké hodnoty NDVI_2 a podílu smrkové kmenoviny.

4.3.3 Celkový výkon kombinovaného přístupu

Finální predikce kombinuje výstupy obou modelů: čtverce s nulovou predikcí z klasifikačního modelu obdrží hodnotu 0 (obr. 8), zatímco pro čtverce s nenulovou predikcí je použita hodnota z regresního modelu. Celkový model má $RMSE = 0.2032$, $MAE = 0.1200$ a $R^2 = 0.51$, což jsou lepší hodnoty než u samotného regresního modelu, a vyplývají z jeho kombinace s přesnějším klasifikačním modelem. Na základě hodnot NDMI, NDVI_2 a B8_homog (pro vyšší přesnost v kombinaci s dalšími prediktory) lze poměrně spolehlivě identifikovat čtverce, ve kterých se v následujících čtyřech letech začaly tvořit holiny. Následná predikce rozlohy těchto holin regresním modelem vyžaduje více proměnných a je méně přesná, ale model přesto vykazuje solidní střední predikční přesnost. **Stejným způsobem budou v navazující aktivitě 2.5 vytvořeny modely z dat pro celou Českou republiku, do modelů pak budou použity jako vstupy aktuální hodnoty prediktorů a výstupy budou použity pro identifikaci porostů s různou pravděpodobností rozpadu a k predikci rozsahu rozpadu v rámci celé ČR.**





Obr. 8 Ukázka výsledku klasifikačního modelu, porovnání skutečných (fialová barva – obr. 8 A) a predikovaných (růžová barva – obr. 8 B) holin pro testovací data (nepoužitá při tvorbě modelu). Zeleně jsou znázorněny čtverce bez holin.

5 Závěr

Pravděpodobností rozpadu smrkových porostů se v ČR zabýval např. tým doc. Cudlína v rámci projektu probíhajícího v letech 2007–2011 (PRETEL a kol., 2011). Podobně jako i v této práci určovali autoři pravděpodobnost na základě regresní rovnice. Výpočet provedli pro plochy v lesní správě Jablunkov ve Slezských Beskydách a v PLO Orlické hory. Ke zpracování přitom použili data z LHP a LHE. Cudlín, Čermák a Jankovský (2004) počítali pravděpodobnost chřadnutí na území PLO 11 Český les. Jedinečnost výstupu této metodiky tedy spočívá i v tom, že analýza byla provedena pro celé území ČR, a to především díky dostupnosti satelitních dat s vyšším rozlišením, na kterém bylo možné analýzu založit. Jak se ukázalo v průběhu zpracování, ačkoli mohou být data z LHE či LHP velmi přesná, může být problém je získat pro území celého státu, nebo mohou být data v době zpracování neaktuální. V tomto tedy mohou mít data zpracovaná z výstupů DPZ nespornou výhodu. Kulla a Hlásný (2010) analyzovali vliv prediktorů na výskyt kritického poškození lesních porostů ve dvou částech slovenských Beskyd. Zjistili, že lepších výsledků bylo dosaženo při analýze obou oblastí zvlášť, než když data z obou území analyzovali společně. Na tomto základě lze usuzovat, že vzhledem k rozloze studovaného území (celé ČR) by mohlo být dosaženo přesnějších a detailnějších výsledků, pokud by se studovaná oblast ČR rozdělila do více částí (homogennějších) a analyzovala zvlášť.

Chřadnutí a následné odumírání smrkových porostů jsou komplexní problémy způsobené synergickým působením přírodních a antropogenních stresových faktorů. Tento stav (snižování životaschopnosti dřevin) se negativně se projevuje úbytkem asimilačního aparátu a bioreprodukce, což následně ovlivňuje navazující procesy v ostatních lesních subsystémech, jako jsou např. produkce biomasy, vázání uhlíku, ochlazování povrchu a produkce kyslíku.

Představená aktualizovaná metodika popisuje možný postup odhalení oblastí náchylných k rozpadu lesních porostů v hospodářských lesích na základě datových sad pokrývajících Českou republiku. Hlavní přínos metodického postupu lze spatřit v tom, že data potřebná pro vyhodnocení prediktorů jsou snímána periodicky, jednotným senzorem a pokrývají celé území republiky. V krátkém časovém okamžiku je možno získat prostorově variabilní obraz stavu porostu/krajiny. To umožňuje rychlejší a častější aktualizaci dat, s eliminací nedostupnosti dat na základě vlastnických a majetkoprávních vztahů. Výsledná mapa, která bude vytvořena v rámci navazující aktivity 2.5 může být uplatněna jako podklad pro vymezení ohrožených lesních porostů, na kterých lze následně provést odpovídající zásahy k jejich ochraně či snížit obmýtní dobu. Mapa může také sloužit jako informace o stavu porostů pro vlastníky lesa s převahou smrku staršího 50 let, kteří podle ní mohou napláňovat vhodný lesní management, případně obnovu.

6 Použitý software

Veškeré zpracování geodat proběhlo v GIS programu ArcGIS Pro., 3.x s využitím standardních nástrojů pro překryvné operace. Alternativní možností je, která byla testována též, je využití opensource nástroje QGIS3.x

Statistické analýzy byly provedeny v programovacím jazyce R, verze 4.5.0 (R Core Team, 2025), v prostředí RStudio (Posit Team, 2025) a s využitím platformy H2O (Fryda et al., 2025), což je open-source nástroj pro strojové učení optimalizovaný pro velká data díky distribuovanému výpočtu a in-memory zpracování.

Z modelu H2O lze exportovat predikce na základě existujících datových bodů a uložit je ve formátu kompatibilním s GIS (např. CSV, GeoTIFF, shapefile). Pro možnost dynamických predikcí lze celý model exportovat ve formátu MOJO (Model Object Optimized).

7 Seznam použitých zkratk

BRT	Boosted Regression Trees; posílená regrese rozhodovacího stromu
CO ₂	oxid uhličitý
CO ₂ eq	emise uvažovaných skleníkových plynů přepočtené na CO ₂ ; vyjadřuje množství CO ₂ , které by mělo ekvivalentní příspěvek ke skleníkovému jevu atmosféry jako jiný skleníkový plyn za standardizovanou dobu
ČHMÚ	Český hydrometeorologický ústav
DMR 5G	digitální model reliéfu České republiky 5. generace
DPZ	dálkový průzkum Země
EEA	Evropská agentura pro životní prostředí (European Environmental Agency)
GIS	geografický informační systém
LHP	lesní hospodářský plán
LVS	lesní vegetační stupeň
NDVI	Normalized Difference Vegetation Index
NLI	Národní lesnický institut (dříve Ústav pro hospodářskou úpravu lesa – ÚHÚL)
NO _x	oxidy dusíku
PLO	přírodní lesní oblast
SO ₂	oxid siřičitý
TPI	Topographic Position Index
ZOL	zóny ochrany lesa (SAMEC, TUČEK a kol., 2012)

8 Literatura

- BAŁAZY, R., HYCZA, T., KAMIŃSKA, A., OSIŃSKA-SKOTAK, K. (2019): Factors Affecting the Health Condition of Spruce Forests in Central European Mountains-Study Based on Multitemporal RapidEye Satellite Images. *Forests*, 10, č. 943, 18 s.
- CIENCIALA, E., ZATLOUKAL, V., BERANOVÁ, J., KUČERA, J., RUSS, R., HOLÁ, Š., ČERNÝ, M., EXNEROVÁ, Z., APLTAUER, J., MÁLEK, P., MICHALEC, M., LITSCHMAN, P., HEMER, L., VOPĚNKA, P., URBAN, J., MACFELDA, M., STRNAD, L. (2014): LESNICKÁ ADAPTAČNÍ STRATEGIE PRO MĚNÍCÍ SE PROSTŘEDÍ V PODMÍNKÁCH MORAVSKOSLEZSKÝCH BESKYD (LASPROBES). Projekty Grantové služby LČR. Jílové u Prahy, 108 s.
- COLLINS, J. B., WOODCOCK, C. E. (1996): An assessment of several linear change detection techniques for mapping forest mortality using multitemporal Landsat TM data. *Remote Sensing of Environment*, 56, s. 66–77.
- COUNCIL OF THE EU (2018): Lepší ochrana a obhospodařování půdy a lesů v celé Unii: Rada přijala nové nařízení, <https://www.consilium.europa.eu/cs/press/press-releases/2018/05/14/better-protection-and-management-of-land-and-forests-across-the-union-council-adopts-a-new-regulation/pdf>
- CRIBARI-NETO, F., ZEILEIS, A. (2010): Beta Regression in R. *Journal of Statistical Software*, 34, 2, 24 s.
- CUDLÍN, P., ČERMÁK, P., JANKOVSKÝ, L. (2004): ANALÝZA RIZIK DESTABILIZACE SMRKOVÝCH POROSTŮ VLIVEM KLIMATICKÉ ZMĚNY. Bioklimatologické pracovní dny 2004, Viničky, 23.–26. 8. 2004. 9 s.
- CUDLÍN, P., MORAVEC, I., CHMELÍKOVÁ, E. (2001): Retrospektivní sledování stavu smrkových ekosystémů v Národním parku Šumava. *Silva Gabreta. Vimperk*, 6, s. 249–258.
- ČERMÁK, P. (2014): JAK REAGUJE SMRK NA KLIMATICKÉ ZMĚNY. In: NOVÁK, J., DUŠEK, D. Chřadnutí smrku v oblasti severní a střední Moravy. Sborník přednášek odborného semináře. Budišov nad Budišovkou, 2014, s. 9–15.
- ČHMÚ (2021): Kvalita ovzduší, <https://www.chmi.cz/?tab=2> (11. 1. 2022)
- ČSÚ (2020): Nahodilá těžba dřeva je na vzestupu, <https://www.czso.cz/csu/czso/nahodila-tezba-dreva-je-na-vzestupu> (7. 1. 2022)
- DOBBERTIN, M. (2005): Tree growth as indicator of tree vitality and of tree reaction to environmental stress: a review. *European Journal of Forest Research*, 124, s. 319–333.
- EEA (2021): National emissions reported to the UNFCCC and to the EU Greenhouse Gas Monitoring Mechanism, <https://www.eea.europa.eu/data-and-maps/data/national-emissions-reported-to-the-unfccc-and-to-the-eu-greenhouse-gas-monitoring-mechanism-17>
- ESRI (2021): ArcPro. Environmental Systems Research Institute, Redlands, Kalifornie, USA, <https://www.esri.com/en-us/arcgis/products/arcgis-pro/overview> (12. 1. 2022)
- FRANKLIN, S. E., MOSKAL, L. M., LAVIGNE, M. B., PUGH, K. (2000): Interpretation and classification of partially harvested forest stands in the Fundy model forest using multitemporal Landsat TM digital data. *Canadian Journal of Remote Sensing*, 26, č. 4, s. 318–333.
- FRYDA T, LEDELL E, GILL N, AIELLO S, FU A, CANDEL A, CLICK C, KRALJEVIC T, NYKODYM T, ABOYOUN P, KURKA M, MALOHLAVA M, POIRIER S, WONG W (2025). *_h2o: R Interface for the 'H2O' Scalable Machine Learning Platform_*. R package version 3.46.0.7, <<https://github.com/h2oai/h2o-3>>.

- GLOBAL SOLAR ATLAS (2021): Map and data downloads, <https://globalsolaratlas.info/download> (11. 1. 2022)
- GLOBIO (2016): Global biodiversity model for policy support, <http://www.globio.info/home> (11. 1. 2022)
- HOLUŠA, J., TROMBIK, J. (2014): KŮROVCI NA SMRKU A CHŘADNUTÍ SMRKU. In: NOVÁK, J., DUŠEK, D. Chřadnutí smrku v oblasti severní a střední Moravy. Sborník přednášek odborného semináře. Budišov nad Budišovkou, 2014, s. 31–35.
- HRUŠKA, J., CIENCIALA, E. (2002): Dlouhodobá acidifikace a nutriční degradace lesních půd – limitující faktor současného lesnictví. MŽP, Praha, 159 s.
- JANKOVSKÝ, L. (2014): ROLE HOUBOVÝCH PATOGENŮ V CHŘADNUTÍ SMRKU. In: NOVÁK, J., DUŠEK, D. Chřadnutí smrku v oblasti severní a střední Moravy. Sborník přednášek odborného semináře. Budišov nad Budišovkou, 2014, s. 20–30.
- JENIŠ, J. (2014): CHŘADNUTÍ SMRKOVÝCH POROSTŮ VE SPRÁVĚ VLS ČR S.P., DIVIZE LIPNÍK N. B. – POPIS A VÝVOJ SITUACE A STAVU SMRKOVÝCH POROSTŮ. In: NOVÁK, J., DUŠEK, D. Chřadnutí smrku v oblasti severní a střední Moravy. Sborník přednášek odborného semináře. Budišov nad Budišovkou, 2014, s. 43–47.
- KAMIŇSKA, A., LISIEWICZ, M., KRASZEWSKI, B., STEREŇCZAK, K. (2021): Mass outbreaks and factors related to the spatial dynamics of spruce bark beetle (*Ips typographus*) dieback considering diverse management regimes in the Białowieża forest. *Forest Ecology and Management* 498, č. 5, 14 s.
- KHODAEI, M., HWANG, T., KIM, J., NORMAN, S. P., ROBESON, S. M., SONG, C. (2020): Monitoring Forest Infestation and Fire Disturbance in the Southern Appalachian Using a Time Series Analysis of Landsat Imagery. *Remote Sensing*, 12, č. 15, 20 s.
- KULLA, L., HLÁSNÝ, T. (2010): Multi-factorial analysis of spruce forests decline in the Slovak part of Beskydy region. *Beskydy*, 3, č. 1, s. 65–72.
- LAŠTOVIČKA, J., ŠVEC, P., PALUBA, D., KOBLÍK, N., SVOBODA, J., HLADKÝ, R., ŠTYCH, P. (2020): Sentinel-2 Data in an Evaluation of the Impact of the Disturbances on Forest Vegetation. *Remote Sensing*, 12, č. 12, 1914, 26 s.
- MANION, P. D. (1991): Tree disease concept. Prentice-Hall, Inc., Englewood Cliffs, N. J. 402 s.
- MRKVA, R. (2000): CHŘADNUTÍ DŘEVIN JAKO VÝZNAMNÝ A OČEKÁVANÝ PROBLÉM OCHRANY LESA. *Lesnická práce*, 79, č. 6/00.
- NEDKOV, R. (2017): Orthogonal Transformation of Segmented Images from the Satellite Sentinel-2. *Comptes Rendus L'académie Bulg. Sci.*, 70, s. 637–692.
- NLI (2021): Mapa ploch s rizikem šíření kůrovců. Národní lesnický institut. Dostupné na: www.kurovcovamapa.cz
- NOVÁK, J., DUŠEK, D., SLODIČÁK, M. (2014): PĚSTEBNÍ OPATŘENÍ V OBLASTI CHŘADNUTÍ SMRKU. In: NOVÁK, J., DUŠEK, D. Chřadnutí smrku v oblasti severní a střední Moravy. Sborník přednášek odborného semináře. Budišov nad Budišovkou, 2014, s. 36–42.
- PBL NETHERLANDS ENVIRONMENTAL ASSESSMENT AGENCY (2016): PBL Netherlands Environmental Assessment Agency, <https://www.pbl.nl/en> (11. 1. 2022)
- PECHANEC, V., CUDLÍN, P., CUDLÍN, O. (2016): Adaptace modelu GLOBIO3 do lokálních podmínek ČR. In: Inspektor, T., Horák, J., Růžička, J. GIS Ostrava 2016 – Geoinformatika pro společnost. Ostrava, VŠB – Technická univerzita Ostrava, 5 s.

- POSIT TEAM (2025). RStudio: Integrated Development Environment for R. Posit Software, PBC, Boston, MA. URL <http://www.posit.co/>.
- PRETEL, J. a kol. (2011): Zpřesnění dosavadních odhadů dopadů klimatické změny v sektorech vodního hospodářství, zemědělství a lesnictví a návrhy adaptačních opatření. TECHNICKÉ SHRNTÍ VÝSLEDKŮ PROJEKTU 2007–2011. Ministerstvo životního prostředí, 67 s.
- QGIS.ORG (2021): QGIS Geographic Information System. QGIS Association. <http://www.qgis.org> (12. 1. 2022)
- R CORE TEAM (2021): R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vídeň, Rakousko, <https://www.R-project.org> (12. 1. 2022)
- R CORE TEAM (2025). *_R: A Language and Environment for Statistical Computing_*. R Foundation for Statistical Computing, Vienna, Austria. <<https://www.R-project.org/>>.
- ROESSIGER, J., KULLA, L., SEDLIAK, M. (2020): A high proportion of norway spruce in mixed stands increases probability of stand failure. *Central European Forestry Journal*, 66, s. 218–226.
- SAMEC, P., TUČEK, P., BOJKO, J., JANOŠKA, Z., RYCHTECKÁ, P., HÁJEK, F., ZAPLETAL, M., SIROTA, I., MIKLOŠ, L., MLČOUŠKOVÁ, P., ZEMAN, M., SMEJKAL, J., MACH, S., PODRÁCKÁ, O. (2012): Modelování růstových podmínek lesů v České republice. Univerzita Palackého v Olomouci. 312 s.
- SKAKUN, R. S., WULDER, M. A., FRANKLIN, S. E. (2003). Sensitivity of the thematic mapper enhanced wetness difference index to detect mountain pine beetle red-attack damage. *Remote Sensing of Environment*, 86, s. 433–443.
- SLODIČÁK, M. (2014): PŘÍČINY CHŘADNUTÍ SMRKU NA OPAVSKU. In: NOVÁK, J., DUŠEK, D. Chřadnutí smrku v oblasti severní a střední Moravy. Sborník přednášek odborného semináře. Budišov nad Budišovkou, 2014, s. 5–8.
- ŠRÁMEK, V., NOVOTNÝ, R., LOMSKÝ, B., FADRHOŇSOVÁ, V. (2014): CHŘADNUTÍ SMRKOVÝCH POROSTŮ A STAV LESNÍCH PŮD. In: NOVÁK, J., DUŠEK, D. Chřadnutí smrku v oblasti severní a střední Moravy. Sborník přednášek odborného semináře. Budišov nad Budišovkou, 2014, s. 16–19.
- ŠRÁMEK, V., SOUKUP, F., SLODIČÁK, M. (2009): Chřadnutí lesních porostů na LS Jablunkov. *Lesnická práce*, 88, č.3/09.
- TRNKA, M., BRÁZDIL, R., BALEK, J., SEMERÁDOVÁ, D., HLAVINKA, P., MOŽNÝ, M., ŠTĚPÁNEK, P., DOBROVOLNÝ, P., ZAHRADNÍČEK, P., DUBROVSKÝ, M., EITZINGER, J., FUCHS, B., SVOBODA, M., HAYES, M., ŽALUD, Z. (2015): Soil moisture trends in the Czech republic between 1961 and 2012. *International Journal of Climatology*, 35, č. 13, s. 3733–3747.
- VACEK, S., LEPŠ, J. (1999): Vegetační dynamika v lesních ekosystémech Krkonoš. *Zprávy České botanické společnosti*, Praha, Mater. 17, s. 89–101.
- VACEK, S.; LEPŠ, J. (1991): Použití Leslieho matic pro predikci vývoje smrkových porostů pod vlivem imisí. Výzkumná stanice VÚHLM, Opočno; Jihočeské biologické centrum ČSAV, České Budějovice, *Lesnictví* 37, č. 2, s. 133–150.