

Česká zemědělská univerzita v Praze
Fakulta lesnická a dřevařská
Výzkumný projekt NAZV – QJ1320230

***METODIKA FUNKČNĚ INTEGROVANÉ
OPTIMALIZACE VÝCHOVY A OBNOVY NA
ÚROVNI LESNÍHO HOSPODÁŘSKÉHO CELKU Z
POHLEDU TAKTICKÉHO A STRATEGICKÉHO
PLÁNOVÁNÍ***

2017

Metodika funkčně integrované optimalizace výchovy a obnovy na úrovni lesního hospodářského celku z pohledu taktického a strategického plánování

Autoři

Ing. Róbert Sedmák, PhD.

Ing. Jan Kašpar, Ph.D.

prof. Ing. Róbert Marušák, PhD.

Česká zemědělská univerzita v Praze, Fakulta lesnická a dřevařská

Kamýcká 1176, 165 21 Praha 6 - Suchdol

Procentický podíl autorů: Róbert Sedmák – 50 %, Jan Kašpar – 30 %, Róbert Marušák – 20 %

Recenzenti

doc. Dr. Ing. Jan Kadavý

Lesnická a dřevařská fakulta Mendelova univerzita v Brně, Zemědělská 3, 61300 Brno

Ing. Michal Křepela, Ph.D.

Ministerstvo zemědělství, Těšnov 65/17, Praha 1, 11000

Dedikace

Metodika je výsledkem řešení výzkumného projektu NAZV č. QJ1320230 „Systémy pro podporu rozhodování v lesním hospodářství s cílem posílení produkčních i mimoprodukčních funkcí lesa (DSS)“ (100 %).

odpovědný řešitel: prof. Ing. Róbert Marušák, PhD.

ISBN: 978-80-213-2699-6

Cíl metodiky

Všeobecným cílem navrhované metodiky je sestavení a ověření funkčnosti multikriteriální optimalizace výchovy a obnovy souboru lesních porostů. Postup dovoluje naplánovat druh a časovou úpravu těžeb v každém porostu na definovaném území tak, aby došlo v plánovaném časovém horizontu k dosažení cílů hospodaření na úrovni celého lesního hospodářského celku.

Základní snahou je zabezpečení souladu mezi protichůdnými požadavky na současnou maximalizaci plnění produkčních i mimoprodukčních ekosystémových služeb (funkcí lesa) na větším území a vlastnických celcích. Konkrétněji se jedná o sladění požadavků na maximalizaci objemů těžeb a celkové produkce dřeva s požadavky na maximální plnění socio-kulturních služeb a potřebou zabezpečení efektivní ochrany přírodního prostředí, dostatočné biodiverzity, ekosystémové integrity lesa a trvalosti hospodaření v prostorově definovaném souboru porostů.

Hlavním cílem multikriteriální optimalizace je snaha cíleně usměrňovat plnění ekosystémových služeb v lesních porostech na definovaném území v průběhu plánovaného období chtěným směrem. Pod tímto směrem se rozumí kombinace dopředu kvantitativně definovaných úrovní plnění jednotlivých služeb, v kterých by měly být zohledněné často protichůdné požadavky, názory a zájmy rozdílných společenských skupin zainteresovaných na hospodaření v lese. Při plánování tak půjde o hledání optimální kombinace systémů těžeb podle jednotlivých porostů tak, aby bylo dosaženo multikriteriálně optimálního řešení vůči kýženým cílům hospodaření na definovaném území, čímž by mohlo dojít k uspokojení zájmů lidí zainteresovaných na hospodaření v lese.

Plánování a optimalizace těžeb na úrovni lesního hospodářského celku v ČR

V posledních desetiletích se cíle obhospodařování lesů v Evropě a ČR poměrně výrazně změnily. Obhospodařování lesů se v současnosti potýká s narůstajícími protichůdnými požadavky na zvýšenou produkci dřeva a biomasy jako přírodně obnovitelného zdroje v kombinaci s rostoucími požadavky na zmírňování negativních dopadů klimatických změn, zlepšení biodiverzity a ekologické stability lesa a zvyšujícími se nároky lidské populace na plnění sociálních a kulturních služeb (Kulla et al. 2010, Sedmák et al. 2013).

Celkově došlo k ústupu od technického vidění lesa směrem k pohledu na les jako zdroj celé řady dalších benefitů jako je např. regulace klimatu, léčebná a rekreační funkce apod. (Davis et al. 2001, Brodrechtová et al. 2017). Současně došlo k nárůstu celospolečenského tlaku a požadavků na ochranu biodiverzity a ekologické stability lesa jako hlavního prostředku trvale udržitelného obhospodařování lesů, které bere do úvahy ekologické a sociální aspekty se stejnou váhou jako aspekty ekonomické (Hahn, Knoke 2010).

V důsledku toho můžeme v rámci lesnického plánování v střední Evropě registrovat výrazné změny požadavků na kvalitu informací o lese a objektivitu plánovacích postupů. Stejně tak dochází k

podstatnému rozšíření cílů hospodaření a narůstá snaha o lepší vyvážení požadavků ochrany přírody a zvýšení celospolečenské účasti na řešení ekologických problémů (Tuček et al. 2015).

V této souvislosti došlo i k zákonité změně nároků na plánovací principy a postupy, na základě kterých se vytváří taktické a strategické plány hospodaření v lese. Lesnické plánování se stává čím dál tím víc typickým problémem multikriteriální optimalizace se všeobecným cílem najít vyvážené řešení uspokojující parciální zájmy rozdílných skupin lidí zainteresovaných na výsledcích hospodaření. Hlavním cílem lesnického plánování ve světě už není předepisování hospodářských opatření, ale podpora rozhodování v rámci hledání optimální směsi vstupů a výstupů lesní produkce, která nejlépe splní stanovenou množinu cílů hospodaření na určitém území (Kangas et al. 2008).

Současné plánování těžeb v ČR vychází z klasické koncepce lesa věkových tříd a opírá se o použití modelů růstových tabulek (Halaj et al. 1987, Černý et al. 1996). Růstové tabulky (RT) popisují růst zdravých rovnověkových a rovnorodých porostů rostoucích při plném zakmenění za předpokladu optimálního obhospodařování. Optimální způsob hospodaření byl v rámci konstrukce RT stanovený empiricky na experimentálních plochách experty na pěstování a hospodářskou úpravu lesa, avšak jeho explicitní definice způsobu hospodaření podle různých dřevin, věků a bonit není v růstových tabulkách uvedena.

V rámci konstrukce RT byly na podkladu rozsáhlého empirického materiálu zkonstruované i modely kritického zakmenění a decennálních probírkových procent pro hlavní dřeviny ČSSR (Halaj 1985, Halaj, Petráš, Sequens 1986) sloužící v aktuální praxi na odvození modelové výchovné intenzity v jednotlivých porostech. Modelová síla a intenzita probírek se ještě může prověřit na vzorových probírkových plochách při obnově LHP. Při takovémto přístupu se v terénu vyznačí pěstební zásah, který je podle názoru a zkušeností příslušného plánovacího experta anebo odborného lesního hospodáře optimální pro daný stav porostu (Marušák, Kašpar 2015).

Objem výchovné těžby za celý vlastnický celek se potom získává jako součet návrhů probírek v jednotlivých porostech. Získaný těžební ukazatel se ještě porovnává a upravuje na výsledný étát s ohledem na požadavky vyrovnanosti těžeb s kalkulacemi objemů výchovných těžeb pro následující dvě decennia. Kalkulace ukazatelů v 2. a 3. decenniu zohledňují očekávané zásoby dřeva ve věkových stupních v budoucnosti, přičemž předpokládají, že intenzita výchovy bude stejná jako v aktuálním decenniu. Podobný předpoklad se uplatňuje i při výpočet těžebních ukazatelů pro stanovení obnovní těžby pomocí ukazatelů těžební procento nebo normální paseka.

Tato strategie stanovení étátu na 3 desetiletí dopředu platí pro rovnověký les a implicitně předpokládá, že při vytěžení optimálního množství dřeva z lesních porostů dojde automaticky k úpravě jejich stavu a struktury na optimální stav. Ten má garantovat plné využití produkčního potenciálu stanoviště, jako i optimální plnění ostaních mimoprodukčních funkcí lesa a upevnění jeho ekologické stability. Předpokládá se tedy, že stanovení optimálního objemu těžby determinuje i multikriteriálně optimální stav porostů na zájmovém vlastnickém celku.

Tento předpoklad je přinejmenším sporný. Výše výchovné těžby se expertně nastavuje tak, aby převážně došlo k urychlení růstu lesa a zlepšení kvality dřeva a v druhém sledu i k jeho ekologické stabilizaci. Výše obnovní těžby, která je odvozena na metodách platných opět pro rovnovážké porosty obhospodařované holosečným hospodářským způsobem, sleduje především minimalizaci nákladů. Primárně teda jde o maximalizaci produkce dřeva, resp. ekonomických výnosů z lesa v rámci obmýtí. Snaha o maximální využití produkční kapacity stanoviště a maximalizace ekonomických výnosů se tak v aktivně obhospodařovaných rovnovážkých porostech de facto stává nadřazenou nad ostatními funkcemi.

Předpoklad, že více či méně empirické jednokriteriální nastavení výše těžby v jednotlivých porostech způsobí i optimální plnění ostatních funkcí lesa na vlastnickém celku, se explicitně neověřuje. Přitom z povahy problému je zřejmé, že mezi výši těžeb, plněním regulačních a socio-kulturních funkcí a ekologickou stabilitou lesa existují vzájemné protichůdné výměny (např. zvýšení těžby se může projevit zhoršením plnění rekreační funkce, resp. zvýšenou půdní erozí, zhoršením kvality vody a naopak). Celý plánovací postup je tak v podstatě založený na všeobecné premisi, že plné využití potenciálu stanoviště na produkci dřeva je hlavním cílem hospodaření bez ohledu na vůli a jiné potřeby jednotlivce anebo společnosti.

Kromě toho expertní plánování těžeb může být do značné míry subjektivní (i přesto, že se opírá o modely růstových tabulek). Přitom z teorie optimalizace je dobře známo, že těžba naplánovaná separátně podle jednotlivých porostů nemusí nevyhnutelně znamenat optimální výši těžeb za celý vlastnický celek (Kangas et al. 2008, Reynolds et al. 2008).

Klasický plánovací přístup je zároveň poměrně málo flexibilní. Za hospodářský celek je vždy sestavena jen jedna alternativa hospodaření, která sa považuje za optimální a to bez ohledu na potřeby a vůli vlastníka lesa, či měnící se nároky společnosti. Testování optimality plánovaných rozhodnutí se však neprovádí a to ani z jednokriteriálního pohledu optimality etátu těžeb. Poměrně vysoké náklady na tvorbu plánů vedou k jejich nízké adaptivitě při náhlé změně cílů hospodaření (např. v důsledku změny vlastníka) anebo při náhlé změně stavu lesa (např. po rozsáhlé větrné kalamitě). S ohledem na do teď vyjmenované nedostatky aktuální plánovací praxe a stav lesnického plánování ve světě tak narůstá potřeba navrhnout moderní, dostatočně flexibilní postup lesnického plánování založený na simultánní multikriteriální optimalizaci plnění různých cílů hospodaření i u nás.

Idea multifunkčního vyváženého hospodaření není odborné lesnické veřejnosti cizí, protože většina lesních odborníků je v rámci vzdělávání vedená k pochopení principů funkčně integrovaného hospodaření rozvinutého už v 60. a 70. letech 20. století (Papánek 1978, Midriak 1982). Multifunkční hospodaření je v praxi realizované minimálně prostřednictvím funkční typizace a kategorizace lesa na vymezeném území. Multifunkčnosti hospodaření se tak dosahuje vždy na úrovni vlastnického celku na principu územní segregace. Současně platí, že funkční zaměření a kategorizace konkrétního porostu závisí výhradně od ohodnocení přírodních podmínek, dřevinného složení a ekologické stability lesa a

rozhodnutí plánovacího experta, prakticky mimo vůli jiných zainteresovaných stran (s výjimkou kategorie lesů zvláštního určení).

Typicky k zainteresovaným osobám patří vlastníci lesa, odborní lesní hospodáři a pracovníci taxačních kanceláří, státní správa lesního hospodářství, zpracovatelé dřeva a jiní podnikatelé s aktivitami souvisejícími s lesní krajinou, ochrana přírody a krajiny, mimovládni organizace, různé zájmové sdružení - dobrovolní ochranáři, myslivci, turisté, obyvatelé obcí a měst obklopených lesy apod.

Moderní plánování by se mělo orientovat na uživatelsky stanovenou množinu cílů a proto v rámci multikriteriální optimalizace výchovy a obnovy lesa by měla existovat možnost vstupů zástupců různých zájmových skupin do plánovacího procesu a možnost zohlednění jejich zájmů. Zavedení principu participativnosti do plánování hospodaření v lese si však (kromě jiného) vyžaduje změnu myšlení lesnické veřejnosti, která si často myslí, že produkce kulturních, sociálních a regulačních služeb je jen externalita při produkci dřevní hmoty (Konôpka 2010) a multifunkční hospodaření je možné zabezpečit jen územní segregací cílů hospodaření převážně daných kategorií lesa (Sedmák et al. 2016).

Návrh a aplikace počítačem podporované multikriteriální optimalizace výchovy a obnovy lesních porostů v praxi se může stát důležitým prostředkem zefektivnění a objektivizace hospodaření v lese. Multikriteriální postupy kromě tvorby optimálních řešení nabízejí i možnost jejich analýzy, porovnávání a hodnocení kompromisních vztahů mezi plněním jednotlivých ekosystémových služeb. Mezi nesporné výhody patří i možnost učit se o plánování hospodaření v lese, což potenciálně zvýší úroveň pochopení problematiky a přispěje k tvorbě lepšího výsledku. Strany zainteresované do participativního plánování jsou schopné formulovat reálnější požadavky, omezení, resp. preference nutné pro řešení optimalizačního problému. Pravá multikriteriální optimalizace vede k plnohodnotnému dialogu mezi zainteresovanými stranami, přispívá k zmírnění potenciálních konfliktů a v konečném důsledku vede ke zvýšení spokojenosti a ztotožnění se s poskytnutým finálním řešením (Bruña-García, Marey-Pérez 2013).

Plánování hospodářských opatření na základě participativní multikriteriální optimalizace tak může reálně zavést principy uživatelsky zohledněného multifunkčního hospodaření do praxe v kvantifikované a kontrolovatelné formě a to až na úroveň jednotlivého porostu a může vést k posílení spokojenosti různých skupin lidí ovlivňovaných hospodářskou aktivitou v lese na určitém území.

3 Vlastní metodický postup

Navrhovaný postup optimalizace těžby na definovaném vlastnickém celku teoreticky vychází ze všeobecného postupu řešení multikriteriálních problémů. Ten se typicky skládá z: (i) definování řešeného problému – alespoň definování optimalizovaných (záměrně manipulovatelných) proměnných x , cílů optimalizace a indikátorů jejich plnění z , (ii) vytvoření matematické reprezentace řešeného problému – prakticky jde o matematický popis závislostí mezi hodnotami optimalizovaných proměnných a hodnotami indikátorů plnění jednotlivých cílů $= f_j(x)$, (iii) samotné optimalizace –

vyhledání takové kombinace hodnot rozhodovacích proměnných, aby se při předpokládaných závislostích dosáhla simultánní maximalizace anebo minimalizace indikátorů plnění jednotlivých cílů \max v $\min z_j = f_j(x_{opt})$.

Při multikriteriální formě se vždy snažíme o simultánní maximalizaci anebo minimalizaci plnění více než jednoho cíle. Při praktických aplikacích mezi plněním jednotlivých cílů dochází v procesu optimalizace k vzájemným mezivýměnám a interakcím. Ty mají buď podobu pozitivních korelací (vylepšení určitého cíle vede simultánně i k zlepšení plnění jiného cíle) anebo naopak negativních korelací (vylepšení určitého cíle přináší zhoršení plnění jiného). Obzvláště negativní korelace (po anglicky trade-offs) vedoucí k vzájemnému limitování indikátorů plnění jednotlivých cílů představují podstatu každého optimalizačního problému. Při jejich existenci se dá matematicky dokázat, že v průběhu optimalizace je vždy možné získat celou množinu multikriteriálně optimálních řešení $x_{opt}(j)$ (nejen jedno, jako je tomu při unikriteriální optimalizaci).

Samotná multikriteriální optimalizace se tak vždy skládá ze dvou na sebe navazujících fází:

(a) fáze vyhledání množiny optimálních, vzájemně co nejvíce odlišných, ale multikriteriálně rovnocenných řešení $x_{opt}(j)$ (označovaných i jako Pareto-optimální řešení),

(b) fáze výběru finálního, nejvíce upřednostňovaného řešení $x_{opt}(final)$ ze skupiny Pareto-optimálních, většinou řešená za pomoci tzv. skalarizační funkce $U_j = f_{obj}(z_{opt}(j))$ propojující hodnoty indikátorů plnění jednotlivých cílů dosažených při učitím řešení $x_{opt}(j)$ do formy jedné funkce udávající hodnotu skóre multikriteriální užitečnosti U_j . Objektivizační funkce f_{obj} může jako parametry obsahovat kýžené úrovně plnění jednotlivých cílů z_j^* a/nebo váhy významnosti jednotlivých cílů w_j , které musí být specifikované za pomoci doplňkových informací o řešeném problému, explicitně nezohledněných v první fázi optimalizace.

Když promítneme naznačený všeobecný postup multikriteriální optimalizace do problematiky optimalizace výchovy lesa na určitém hospodářském celku, tak můžeme konstatovat, že základním optimalizačním problémem pro navrhovanou metodiku je rozmístění různých výchovných a obnovních systémů do jednotlivých porostů v rámci souboru porostů určitého hospodářského celku tak, aby v definovaném časovém horizontu došlo k simultánní maximalizaci plnění produkčních a mimoprodukčních funkcí lesa a posílení jeho ekologické stability na definovaném území.

Optimalizovanými proměnnými x jsou alternativní systémy výchovy a obnovy definované druhem, silou a časovým harmonogramem zásahů a jejich distribucí do jednotlivých porostů tvořících optimalizovaný soubor. Rozmístění výchovných a obnovních systémů do jednotlivých porostů v optimalizovaném souboru se označuje v metodice i pojmem hospodářský plán.

Cíle optimalizace představuje maximalizace plnění různých funkcí lesa (anebo i ekosystémových služeb) a ekologické stability lesa. Pod indikátory plnění jednotlivých cílů se rozumí indikátory plnění sledovaných ekosystémových služeb. Jde o veličiny logicky provázané s plněním určité ekosystémové služby, které jsou buď přímo měřitelné v lese (např. zakměnění jako indikátor plnění regulační služby

vázání uhlíku anebo ochrany půdy před erozí) anebo jde o sekundární veličiny odvozené z přímo měřitelných veličin pomocí tzv. linkovacích funkcí (např. z údajů o počtu stromů, jejich tloušťkové a výškové struktury umíme odvodit informace o zásobě a těžbě v určitém porostu, které se dají logicky použít jako indikátor plnění funkce produkce dřeva).

Matematickou reprezentaci řešeného problému v případě navrhované metodiky představují rovnice simulačního modelu růstu lesa použitého na nasimulování dopadů aplikace různých alternativ těžebních zásahů v jednotlivých porostech. Modely růstu lesa obsahují celou sérii rovnic dovolujících simulovat dopady různých těžebních zásahů na růst lesa. Z matematického pohledu vlastně popisují závislosti mezi druhem, silou a časovou úpravou těžebních intervencí v určitém simulovaném období a hodnotami dendrometrických veličin stromů a porostů v konkrétním porostu příp. z nich odvozených specializovaných indikátorů a jejich změn v čase. V růstových modelech je tedy vždy obsažená celá sada rovnic popisujících vztahy mezi hodnotami rozhodovacích proměnných x (druh, síla a časová úprava zásahů) a hodnotami indikátorů plnění jednotlivých cílů na úrovni jednotlivých porostů (dendrometrické veličiny porostů a z nich odvozené speciální indikátory plnění rozličných ekosystémových služeb).

Samotná multikriteriální optimalizace je v navrhované metodice po matematické stránce řešená použitím zvolené metody heuristické evoluční optimalizace NSGA II (Srinivas, Deb 1995, Deb et al. 2000, Deb et al. 2017) zkombinované s objektivizační funkcí globálního kritéria charakteristickou pro matematické cílové programování. Metoda NSGA II patří mezi nejpokrokovější metody ze skupiny velmi rychle se vyvíjejících metod evoluční multikriteriální optimalizace (EMO) a používá se na vyhledání („vyšlechtní“) množiny („populace“) Pareto optimálních plánů hospodaření, v rámci první podetapy samotné optimalizace. Objektivizační anebo i skalarizační funkce zase slouží na řešení výberu finálního plánu z množiny Pareto optimálních řešení, v rámci druhé podetapy multikriteriální optimalizace.

Velmi důležitým rysem navrhované metodiky je fakt, že postup předpokládá, resp. v případě potřeby umožňuje, spolupráci analytika (optimalizačního experta) a rozhodovatele/lů (jako konečných uživatelů optimalizace). Pod analytikem se rozumí optimalizační expert, který má celý proces technicky pod kontrolou a dobře zná jeho matematický algoritmus optimalizace a jeho vlastnosti. Pod rozhodovatelem/konečným uživatelem se chápe osoba anebo skupiny osob zainteresované na výsledcích plánování např. odborný lesní hospodář, pracovník taxační kanceláře, vlastník lesa, orgán státní správy lesního hospodářství, zástupce státní ochrany přírody, zástupcové měst a obcí, různá občanská sdružení, jednotliví občané apod. Spolupráci představuje schopnost analytika měnit a nastavovat kroky a parametry optimalizačního postupu tak, aby jeho aplikace směřovala k vyhledání takového řešení optimalizovaného problému, které v co největší míře uspokojí požadavky rozhodovatelů vyjádřené v rámci vzájemné komunikace.

Spolupráce obou základních subjektů – analytika a rozhodovatele – může mít různé podoby. První možností je aplikace optimalizace v přednastavené formě, při které se předpokládá určitá kombinace

základních rozhodnutí o spektru cílů optimalizace a míře jejich preferování. Při takovémto nastavení rozhodovatel jen pasivně bere na vědomí zvolené nastavení (aktivně jich neovlivňuje) a na konci procesu se seznámí s finálním řešením poskytnutým analytikem. Přednastavenou formou optimalizace většinou bývá optimalizace plného spektra cílů s idealistickou představou maximálního plnění všech cílů najednou, přičemž každý cíl se považuje za stejně důležitý. Takováto optimalizace se označuje i jako uživatelsky neutrální, protože finální řešení nebývá ovlivněné samotným rozhodovatelem a postup nezávisle od vůle rozhodovatele směřuje k vyhledání „středního“, plně kompromisního finálního řešení (můžeme hovořit i o plně vyváženém, funkčně integrovaném řešení).

Druhou možností je aktivní zapojení rozhodovatelů do procesu optimalizace. Při něm dochází k aktivní komunikaci mezi analytikem a rozhodovatelem o cílech a osobních preferencích jednotlivých cílů. Podle toho, zda se tak děje před začátkem procesu vyhledání množiny Pareto optimálních řešení (1. fáze optimalizace), po jeho proběhnutí anebo opakovaně v jeho rámci, hovoříme o apriorní, aposteriorní anebo interaktivní optimalizaci. Rozhodovatel může při tom podle vlastního uvážení: (i) zúžit počet optimalizovaných cílů - vyjádření tzv. absolutní preference, pokud cíl nezařazený do seznamu optimalizovaných je považovaný z pohledu rozhodovatele za úplně nedůležitý, (ii) sám stanovit kýženou úroveň plnění jednotlivých cílů - úrovně, které by chtěl dosáhnout anebo mu postačují, (iii) vyjádřit, které cíle v rámci optimalizovaného spektra považuje za důležitější a které za méně důležité.

Výsledné řešení potom plně aproximuje odkomunikované požadavky koncového uživatele/ů a ani zdaleka nemusí být „plně vyvážené“ z klasického pohledu. Rozhodnutí o formě optimalizačního postupu z pohledu komunikace rozhodovatele a analytika patří k prvním, základním rozhodnutím, které musí být vykonané před začátkem samotné optimalizace.

Stejně tak před začátkem samotné optimalizace musí být rozhodnuto o délce optimalizačního období. Metodika umožňuje optimalizaci těžeb pro libovolnou délku plánovacího období – od 5 let. Je teda flexibilně použitelná jak pro taktické, tak i pro střednědobé a dlouhodobé strategické plánování (do a nad 10 let). Volba délky plánovacího období závisí primárně od plánovacích potřeb. Když se za optimalizované období zvolí období 10 let, optimalizace a plánování nabyde charakteru taktického plánování, a naopak, pokud si analytik anebo rozhodovatel zvolí délku optimalizace těžby obmýtní a více, plánování bude mít charakter dlouhodobého strategického (rámcového) plánování.

Celkově je celý systém optimalizace z tohoto pohledu univerzální, protože plánovací horizont je dán realizovatelnou délkou simulací růstu lesa a ta může být u moderních simulátorů od 1 roku až po několik stovek let. Všeobecně se však s ohledem na rychle klesající přesnost simulací růstu lesa s rostoucí délkou predikce, v čase se kumulující rizika hospodaření a dnešní praxi vyrovnávání těžebních ukazatelů na 3 desetiletí dopředu, doporučuje časový horizont 30 let.

Posledním rozhodnutím vykonaným ještě před započítáním optimalizace je rozhodnutí o základní jednotce optimalizace. Tou může být dřevina v porostu anebo celý porost. Při volbě jednotky optimalizace se uživatel v podstatě rozhoduje, zda v určitém lesním porostu připouští v době zásahu

uplatnění různého systému výchovy nebo obnovy podle dřevin participujících na dřevinné skladbě (základní jednotka dřevina) nebo předpokládá, že všechny dřeviny jsou vychovávány nebo obnovovány stejným systémem (základní jednotka porost).

Praktický postup multikriteriální optimalizace výchovy a obnovy lesa na zájmovém lesním celku je možné rozdělit do 6 základních etap:

- (i) **Identifikace porostů a sběr podkladových informací o jejich výchozím stavu** - jde především o vytvoření seznamu porostů, v kterých je potřebné optimalizovat výchovu, obnovu nebo obojí a vytvoření databáze vstupních údajů o porostech z inventarizace stavu lesa na začátku optimalizace.
- (ii) **Základní rozhodnutí o formě, délce a hlavní jednotce optimalizace spojené s definováním spektra optimalizovaných cílů a indikátorů jejich plnění** – analytik a/nebo rozhodovatel stanoví formu vzájemné komunikace (neutrální, apriorní nebo aposteriorní), určí délku plánovacího období a vybere základní jednotku optimalizace (porost nebo dřevino-porost). Výběr formy optimalizace je úzce spojený s výběrem spektra optimalizovaných ekosystémových služeb (ES) a s definováním tvaru a parametrů objektivizační funkce, kterými jsou relativní váhy významnosti a/nebo kýžené úrovně plnění ES.
- (iii) **Generování alternativních plánů výchovy a obnovy lesních porostů, modelování a kvantifikace důsledků jejich uplatnění na porostní úrovni** – kvantifikace indikátorů plnění vybraných ES se začíná vytvořením databanky různých způsobů výchovy nebo obnovy lesa aplikovatelných na definovaném území, pokračuje nasimulováním růstu konkrétních porostů za předpokladu aplikace různých výchovných nebo obnovných systémů a končí se výpočtem hodnot indikátorů plnění vybraných ES za každou jednotku optimalizace (porost nebo dřevina) dle jednotlivých systémů výchovy nebo obnovy.
- (iv) **Generování iniciální množiny hospodářských plánů a kvantifikace hodnot indikátorů na úrovni hospodářského celku** – pod alternativními hospodářskými plány (HP) se rozumí různé, alternativní kombinace přiřazení různých výchovných nebo obnovných systémů do jednotlivých předmýtních nebo mýtních porostů/dřevin na uvažovaném hospodářském celku (HC). Z pohledu multikriteriální optimalizace jde o vygenerování iniciálního souboru možných řešení (iniciální „populace“ řešení), který se v dalším postupu bude iterativně vylepšovat („šlechtit“). V rámci kvantifikace indikátorů za HC podle jednotlivých HP jde o odvození informací o hodnotách indikátorů plnění ES za celý soubor optimalizovaných porostů při předpokládané distribuci jednotlivých výchovných nebo obnovných systémů do jednotlivých porostů.
- (v) **Multikriteriální optimalizace a vylepšování iniciální množiny hospodářských plánů** – jedná se o samotnou evoluční multikriteriální optimalizaci založenou na použití NSGA-II algoritmu (Deb at al. 2000) popsanou detailněji v následujícím textu, výsledkem které je

vyšlechtěná populace multikriteriálně (Pareto) optimálních řešení. Prakticky jde o sadu alternativních hospodářských plánů, s takovými hodnotami indikátorů plnění ES na úrovni HC, které se dají považovat za multikriteriálně optimální anebo se přinejmenším multikriteriální optimalitě blíží.

- (vi) **Výběr finálního, rozhodovatelsky preferovaného hospodářského plánu ze skupiny multikriteriálně optimálních plánů** – v tomto posledním kroku v závislosti od zvolené formy optimalizace sám analytik anebo analytik ve spolupráci s rozhodovatelem vybere matematickou formu objektivizační funkce a stanoví její parametry. Objektivizační funkce potom slouží na převod vektoru původních hodnot jednotlivých indikátorů do formy jedné hodnoty (skaláru) skóre multikriteriální užitečnosti U zvláště pro každý multikriteriálně optimální HP a umožňující výběr HP s nejpříznivější hodnotou multikriteriálního skóre označující uživatelsky preferovaný finální plán.

Vytvoření databáze vstupních údajů o jednotlivých porostech v první etapě navrhované metodiky je založené na převzetí údajů z popisu porostů vytvořeného standardně při podrobném zjišťování stavu lesa v rámci pravidelných obnov decennálních lesních hospodářských plánů (LHP). V případě, že se optimalizace nevykonává v souladu s cyklem obnovy LHP, optimalizační expert musí vykonat inventarizaci stavu lesních porostů na vymezeném území na vlastní náklady, nejlépe za pomoci výběrových reprezentativních metod.

Druhá etapa navrhované metodiky se skládá z vykonání rozhodnutí o délce optimalizace (tj. délce plánovacího období), stanovení základní jednotky optimalizace (nejčastěji porost) a také ze stanovení formy optimalizace, která částečně modifikuje celkový postup optimalizace, ale i samotné optimalizační techniky při ní použité. Forma optimalizace zároveň rozhoduje o nárocích kladených na rozhodovatele při definování spektra optimalizovaných služeb a při definování tvaru a parametrů optimalizační funkce, příp. o nárocích na nastudování průběžných výsledků optimalizace v průběhu jejího řešení.

Výběr spektra ES a indikátorů jejich plnění se ve všeobecnosti opírá o návrh vlastního systému indikace plnění produkčních, regulačních a socio-kulturních služeb, ekologické stability lesa a trvalosti hospodaření. Ten je založený na tom, že z každé skupiny služeb (klasifikace MEA 2005) byly vybrány klíčové reprezentativní služby s největším praktickým významem a pro tyto služby se logicky sestavily indikátory jejich plnění. Indikátory se tvořily kompromisně – s ohledem na jejich snadnou a praktickou měřitelnost, dobrou praktickou srozumitelnost a interpretovatelnost a současně s ohledem na možnosti použitého simulačního modelu růstu lesa.

Prezentovaná metodika nabízí na výběr tři formy multikriteriální optimalizace: uživatelsky neutrální, apriorní a aposteriorní variantu. Apriorní a uživatelsky neutrální forma si vyžaduje, resp. obnáší specifikaci objektivizační funkce ještě před začátkem samotné multikriteriální optimalizace (v 2. etapě navrhované metodiky) a umožňuje ji využít na spojení 5. a 6. etapy metodiky prostřednictvím použití modifikované formy NSGA-II algoritmu. Aposteriorní forma požaduje specifikaci objektivizační

funkce až v závěrečné 6. etapě metodiky a předpokládá použití originální podoby NSGA-II podle návrhu autorů Deb et al. 2000.

Při všech formách optimalizace navrhovaná metodika jednotně uvažuje s uplatněním objektivizační skalarizační funkce známé z metody tzv. globálního kritéria, což je jedna z forem matematického cílového programování (Branke et al. 2008). Funkce má tvar jednoduché nebo vážené L_p metriky:

$$\text{minimalizace } U = \left(\sum_{i=1}^k |1 - z_i / z_i^*|^p \right)^{1/p} \text{ resp. } U = \left(\sum_{i=1}^k w_i |1 - z_i / z_i^*|^p \right)^{1/p} \quad (1)$$

kde: $z_i = f_i(x)$ je hodnota indikátoru plnění i -té ekosystémové služby, x je vektor představující hospodářský plán jako kombinaci výchovných a obnovních systémů alokovaných do jednotlivých porostů, z_i^* jsou kýžené hodnoty indikátorů plnění vybraných ES, w_i je relativní váha významnosti i -tého indikátoru a p je tzv. škálovací parametr. Relativní váhy w_i se většinou konstruují tak, aby jejich součet byl 1. Parametr p se často nahrazuje konstantou 2, čímž jednoduchá i vážená objektivizační funkce (1) nabývá kvadratické formy L^2 :

$$\text{minimalizace } U = \sqrt{\sum_{i=1}^k (1 - z_i / z_i^*)^2} \text{ resp. } U = \sqrt{\sum_{i=1}^k w_i (1 - z_i / z_i^*)^2} \quad (2)$$

Funkce exaktně definuje preferenční postoje rozhodovatele a umožňuje objektivní výběr finálního plánu ze skupiny identifikovaných multikriteriálně optimálních možností. Finální Pareto optimální hospodářský plán je daný minimálním skórem multikriteriální užitečnosti, které matematicky v podstatě představuje minimální Euklidovskou odchylku hodnot indikátorů (platné pro vztah 2) při určitém hospodářském plánu od kážených cílových hodnot.

Z uvedeného vidíme, že použití zvolené objektivizační funkce si žádá znalost vektorů kýžených hodnot jednotlivých indikátorů (tj. exaktních cílů hospodaření) a relativních vah jejich významnosti. Oba vektory je možné považovat za parametry objektivizační funkce, které je potřebné analyticky anebo uživatelsky definovat. Způsob jejich stanovení do značné míry závisí od zvolené formy optimalizace.

Výběr uživatelsky neutrální formy optimalizace v rámci navrhované metodiky obnáší použití předdefinované formy objektivizační funkce ještě před začátkem procesu optimalizace v 2. etapě navrhované metodiky. Tou je nevážený tvar funkce globálního kritéria (rovnice 2) obsahující plné spektrum ES, z kterých se každá považuje za rovnocennou, a v kterém jako vektor kýžených úrovní plnění ES vystupuje vektor ideálních hodnot stanovených analytikem nezávisle od vůle rozhodovatele. Ideální úrovně plnění ES na HC se v tomto případě stanoví v dvou krocích.

V prvním kroku se zjistí maximální hodnoty jednotlivých indikátorů zvlášť v každém porostu ze souboru hodnot získaných simulacemi podle jednotlivých těžebních alternativ. Maximální hodnota každého indikátoru v každém porostu je vyhledána pro každý indikátor samostatně, křížem přes prověřované systémy těžby, bez ohledu na hodnoty ostatních indikátorů současně se vyskytujících v konkrétním porostu. V druhém kroku se ze zjištěných porostních unikriteriálních maxim dopočítají ideální unikriteriální maxima za celý HC. Při veličinách a indikátorech vázaných na plochu (např.

zásoba dříví) se ideální hodnota indikátoru za HC získá jako suma ideálních hodnot z jednotlivých porostů, při indikátorech vázaných na základní jednotku optimalizace, kterou je většinou porost (např. index biodiverzity), se ideální hodnoty za HC odvodí váženým průměrováním, v kterém plocha porostu vystupuje jako váha.

Ve finále se tak vytvoří cílový vektor ideálních hodnot indikátorů za celé HC zjištěných teoreticky na základě unikriteriální maximalizace anebo minimalizace hodnot indikátorů v jednotlivých porostech. Takovýto vektor je v důsledku existence negativních korelací mezi hodnotami indikátorů na úrovni porostu, i na úrovni HC nereálný a prakticky nedosažitelný, může však posloužit jako cíl hospodaření odpovídající idealistické snaze o současnou maximalizaci plnění všech ES.

Pokud se tedy rozhodovatel rozhodne nevstupovat do optimalizačního procesu, tj. nechce ovlivňovat spektrum optimalizovaných služeb a akceptuje jeho plnou šíři, nechce se vyjadřovat k cílovým (kýženým) hodnotám jednotlivých indikátorů a považuje všechny ES za stejně důležité, optimalizace proběhne v předdefinované, uživatelsky neutrální formě. Rozhodovatel tím dopředu akceptuje snahu o vyhledání plně vyváženého, funkčně integrovaného plánu, bez ohledu na jeho osobní preference. Proces optimalizace je plně v režii analytika.

Zvolení apriorní formy optimalizace vede z pohledu objektivizační funkce k aplikaci vážené formy (rozhodovatel musí specifikovat relativní váhy významnosti jednotlivých ES) v kombinaci s idealistickým vektorem kýžených úrovní plnění ES (stanovených analytikem) a možností vyjádřit absolutní preference určitých ES skrz zredukování plného spektra optimalizovaných ES (rozhodovatel může úplně vyloučit ES, které považuje za irelevantní).

Potenciální redukce optimalizovaného spektra ES a stanovení vah významnosti jednotlivých ES se znovu odehrává ještě před 1. fází multikriteriální optimalizace a proto musí být stanovené rozhodovatelem/li výhradně subjektivně, bez hlubší znalosti optimalizovaného problému, příp. předbežné znalosti multikriteriálně optimálních možností. Na druhé straně apriorní specifikace preferencí a objektivizační funkce dovoluje funkci zapojit přímo do procesu evoluční multikriteriální optimalizace, čímž dochází k jeho racionalizaci (spojení 5. a 6. etapy navrhované metodiky) a v konečném důsledku i ke zvýšení multikriteriální kvality finálního řešení.

Váhy jednotlivých indikátorů matematicky reprezentují osobní preference rozhodovatele/ů, o kterých analytik sám od sebe, bez interakce s konkrétní osobou/ami, nemá žádné informace. Individuální anebo konsenzuální stanovení vah je poměrně lehce a objektivně zvládnutelná úloha, pokud do úvahy přichází použití dobře známé metody AHP (Kangas et al. 2008). Metoda AHP je prakticky lehce realizovatelná a od rozhodovatele/lů se požaduje účast na jednoduchém kvalitativním průzkumu relativní významnosti jednotlivých ES. Artikulované kvalitativní významnosti (např. málo významná, velmi významná apod.) se přes tzv. matice poměrů matematicky převedou na relativní váhy významnosti jednotlivých ES s normalizovaným součtem 1. Metóda AHP je i ideálním prostředkem pro objektivní vyhledání konsenzu více rozhodovatelů, pokud finální váhy můžou být odvozené jako průměr individuálních vah vyjadřujících osobní postoje každé zainteresované osoby.

Definování kýžených hodnot indikátorů plnění jednotlivých cílů je při apriorní formě ponechané na analytikovi, tj. úrovně se stanovují stejným postupem jako v případě neutrální varianty. Takovýto přístup je vzhledem na absenci hlubší znalosti optimalizovaného problému u rozhodovatele považovaný za racionálnější, protože rozhodovatel v takovémto případě většinou nemá představu o možných kombinacích hodnot indikátorů za celý HC dosahovaných v realitě a z tohoto důvodu často není schopený definovat kýžený vektor. Celkově apriorní varianta optimalizace umožňuje rozhodovateli vstupovat do optimalizačního procesu. Ten může definovat spektrum optimalizovaných služeb a může vybraným ES přiřadit jejich relativní významnost. To v konečném důsledku vede k vyhledání hospodářského plánu lépe plnícímu preferované ES při zachování předpokladu Paretovské multikriteriální optimality.

Zvolení aposteriorní formy optimalizace znamená použití vážené formy objektivizační funkce, v které rozhodovatel specifikuje spektrum optimalizovaných ES, relativní váhy významnosti jednotlivých ES a i kýžené úrovně jejich plnění. Specifikace vstupů a parametrů objektivizační funkce je plně podmíněná vstupem rozhodovatele do optimalizačního procesu a vykonává se až na konci optimalizačního postupu, po proběhnutí 1. fáze multikriteriální optimalizace (5. etapa navrhované metodiky). Rozhodovatel je po hlubším obeznámení se předběžnými výsledky optimalizace (tj. s možnými kombinacemi hodnot indikátorů na úrovni HC v souboru multikriteriálně optimálních plánů) schopný lehčeji specifikovat nejen relativní váhy významnosti, ale i realistické úrovně plnění jednotlivých ES. To značně zvyšuje pravděpodobnost, že rozhodovatel bude jako koncový uživatel spokojený s vyhledaným finálním řešením plně respektujícím vyjádřené preference. Nevýhodou jsou zvýšené nároky na intelektuální výkon rozhodovatele a spotřeba jeho času.

Třetí etapa navrhované metodiky se začíná vytvořením množiny nejběžněji používaných a dobře teoreticky i prakticky ověřených systémů výchovy nebo obnovy, co jsou v zásadě různé kombinace druhů výchovných nebo obnovních zásahů aplikovaných různou silou a při různých variantách časového uspořádání.

Následně se pro zvolenou jednotku optimalizace (porost anebo dřevina) nasimuluje její růst za předpokladu aplikace jednotlivých systémů zásahů pomocí vybraného růstového simulátoru. Z důvodu dobré praktické aplikovatelnosti optimalizačního postupu se simulace růstu jednotlivých porostů ovlivněných různými výchovnými nebo obnovními alternativami vykonávají za pomoci „předpřipravených“ simulací růstu jednotlivých dřevin na rozličných bonitách zesumarizovaných do formy tzv. rozšířených růstových tabulek (rRT).

Na tvorbu rozšířených tabulek a vykonání simulační části celého simulačně-optimalizačního postupu (fáze i-iii můžeme označit jako simulační a fáze iv-vi za optimalizační) je potřebné mít k dispozici moderní simulátor růstu lesa, který musí být flexibilně schopný naprojektovat dopady aplikace různých těžebních systémů na plnění požadovaného spektra ekosystémových služeb v jednotlivých porostech. V případě České republiky je pro tyto účely k dispozici růstový simulátor Sibyla vyvinutý na Technické univerzitě ve Zvoleně ve spolupráci s Technickou univerzitou v Mnichově (Pretzsch et al. 2002, Fabrika 2005, Fabrika, Ďurský 2005, Fabrika, Pretzsch 2013) kalibrovaný pro české přírodní podmínky

(Marušák et al. 2016). Detailnější informace o vývoji, struktuře, funkčních principech a možnostech růstového simulátoru je možné najít na adrese <http://etools.tuzvo.sk/sibyla/slovensky/>.

Čtvrtá etapa navrhované metodiky znamená vygenerování zvoleného počtu tzv. alternativních plánů hospodaření, tj. rozličných alokací jednotlivých výchovných nebo obnovních systémů do jednotlivých porostů vyskytujících se na daném vlastnickém celku. Vygenerovaný počet alternativních plánů se nazývá také i jako iniciální populace řešení.

Potenciální počet iniciálních alternativních plánů je většinou enormní. Například při prověřování jen 36 alternativních systémů výchovy na menším vlastnickém celku tvořeném 261 předmýtními porosty vzniká $36 \cdot 261 = 15\,510\,404$ způsobů, jak uspořádat různé výchovné systémy do jednotlivých porostů a tedy můžeme potenciálně vybírat z 15 510 404 hospodářských plánů. Vzhledem k těmto obrovským číslům se počet generovaných plánů subjektivně volí (nejčastěji analytikem) tak, aby optimalizace byla výpočetně zvládnutelná. Praktické zkušenosti s aplikací multikriteriální evoluční optimalizace ukazují, že pro většinu praktických aplikací a při současných výkonových parametrech běžných počítačů postačuje v iniciální populaci vygenerovat od 100 do maximálně 10 000 řešení. Samotné generování je vhodné řešit tak, aby došlo k systematickému zmapování prostoru možných řešení x , čili k důkladnému průzkumu prostoru alternativních hospodářských plánů.

V páté etapě navrhované metodiky dochází k aplikaci heuristické evoluční optimalizace. Jak již bylo zmíněno, optimalizace těžebních zásahů je založena na aplikaci metody NSGA II vytvořené autory Deb et al. (2000). Při aposteriorní formě optimalizace se počítá s použitím originální podoby algoritmu, při apriorní a uživatelsky neutrální formě se používá modifikovaná podoba. Algoritmus se v rámci iterativního vylepšování (šlechtění) iniciální populace vyznačuje třemi charakteristickými rysy: (i) spolehlivě v prověřované populaci vyhledává tzv. nedominantní řešení a tedy vždy konverguje k výsledku, (ii) explicitně používá mechanismy zachování dostatečné rozmanitosti řešení a tedy na konci první fáze optimalizace nabízí rozhodovateli na výběr soubor dostatečně odlišných multikriteriálně optimálních řešení a (iii) používá princip zachování elity, čímž celý proces značně urychluje a v konečném důsledku i zkvalitňuje. V důsledku toho se metoda NSGA II ukázala při srovnávacích testech jako jedna z nejúspěšnějších EMO metod současnosti a byla vyhodnocena jako vhodná pro řešení optimalizace lesních těžeb.

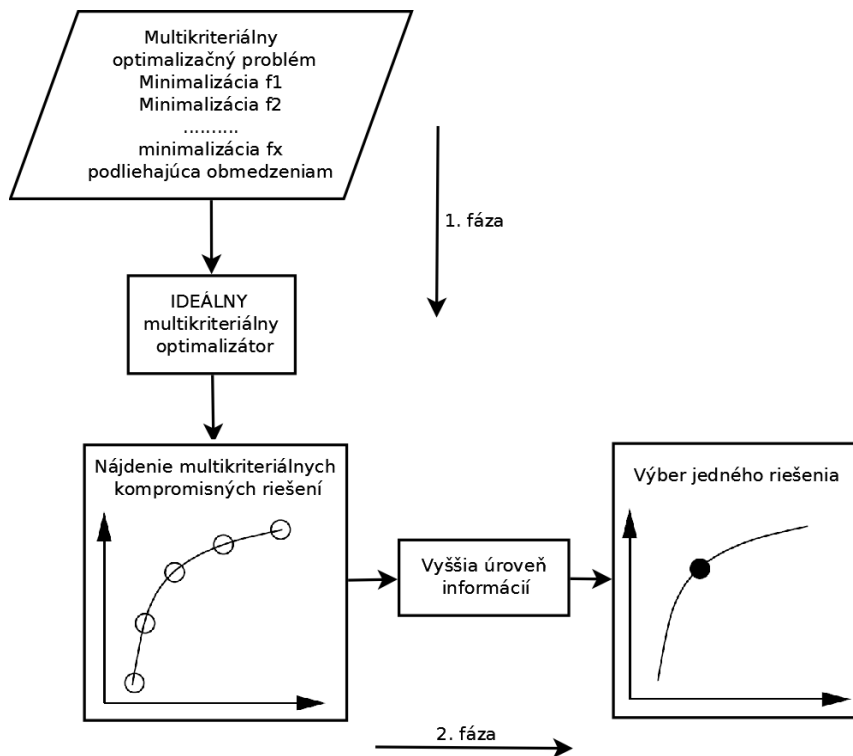
V poslední šesté etapě navrhované metodiky dochází k výběru konečného hospodářského plánu ze skupiny vyšlechtěných multikriteriálně optimálních řešení (plánů). Jak bylo již uvedeno, technicky se tento výběr řeší za pomoci tzv. objektivizační funkce podle vztahu (2), která matematicky transformuje sérii různých hodnot indikátorů plnění ES za celý HC získaných v rámci příslušného hospodářského plánu na jednu bezrozměrnou hodnotu (skalár) nazývaný skóre multikriteriální užitečnosti. Finální, uživatelsky nejvíce preferovaný plán, je indikován nejlepší hodnotou skóre multikriteriální užitečnosti. Šestá etapa se samostatně dělá jen při apriorní formě optimalizace, při jiných formách je sloučena s předchozí pátou etapou, protože tehdy je přímo zapojena do procesu evolučního šlechtění.

V následujícím textu budou detailněji vysvětleny matematické principy evoluční multikriteriální optimalizace a postup její praktické implementace v rámci problematiky výchovy a obnovy lesa. Nakonec bude prezentována metodika prezentována na příkladu jejího aplikování v apriorní formě na reálném, referenčním HC a výsledky optimalizace budou porovnány s výsledky jiných, jednodušších forem optimalizace. V rámci příkladu dojde i k demonstrování vstupu 6 základních typů rozhodovatele do druhé etapy procesu optimalizace a budou tak zkoumány i efekty různých osobních preferencí na výsledky optimalizace.

3.1 Princip evoluční multikriteriální optimalizace

První charakteristickou vlastností evolučních algoritmů (EA) je fakt, že v průběhu optimalizace se iterativně nevylepší jedno řešení (určitá kombinace hodnot rozhodovacích proměnných x), ale paralelně se pracuje s celou množinou/populací alternativních řešení x . EA tak v rámci jednoho výpočetního procesu umožňují efektivně najít celou množinu Pareto optimálních řešení x_{opt} a poskytnout je rozhodovateli pro výběr finální varianty, která nejlépe odpovídá jeho subjektivním preferencím.

Druhým charakteristickým rysem EA je iterativní přístup - postup pracuje s populací předešlých řešení, které si navzájem mezi sebou vyměňují informace a účastní se iterativně vývoje populace nových vylepšených řešení v následujících generacích. Jak již bylo uvedeno v rámci popisu obecného postupu multikriteriální optimalizace, i evoluční multikriteriální optimalizace sestává ze dvou charakteristických fází (Obr. 1).



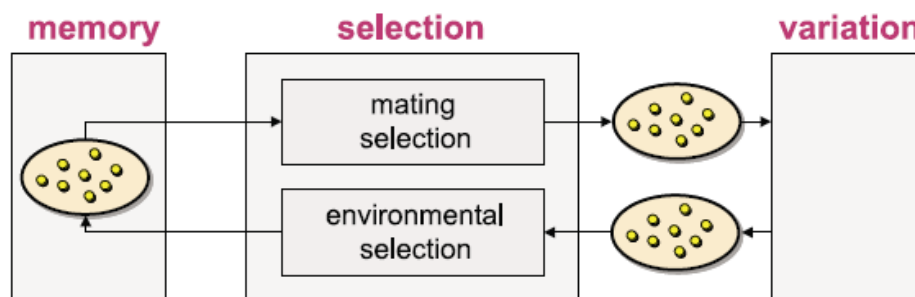
Obrázek 1 Postup multikriteriální optimalizace (Branke et al. 2008)

První fáze začíná formulací multikriteriálního optimalizačního problému a pokračuje jeho samotným řešením - optimalizací realizovanou určitým evolučním algoritmem. Výsledkem je populace obsahující multikriteriálně (Pareto) optimální řešení x_{opt} , z nichž se však každé vyznačuje většinou výrazně odlišnou kombinací indikátorů plnění jednotlivých cílů z_{opt} .

Ve druhé fázi optimalizace pak dochází k výběru finálního řešení. To se provádí na základě hodnocení rozhodovatele, které umožní jednotlivé, původně rovnocenné Pareto optimální, řešení seřadit podle jeho osobních preferencí, nejčastěji na stupnici od nejlepšího po nejhorší. Hodnocení se může dělat za pomoci preferenční objektivizační funkce (skalarizací), podle Goldbergova principu dominance apod.

Všeobecná stochastická evoluční optimalizace aplikovaná v první fázi multikriteriální optimalizace (Obr. 2) sestává vždy ze tří částí: (i) pracovní paměť (ang. Memory) obsahující kandidátské řešení nynější mateřské generace, (ii) selekční modul a (iii) variační modul produkující vylepšené řešení příští generace.

Proces optimalizace začíná naplněním pracovní paměti iniciační populací náhodných řešení. Každá iterace stochastické optimalizace zahrnuje po sobě jdoucí matečnou selekci (ang. Mating selection), variaci, environmentální selekci (ang. Environmental selection) a selekci elity končící naplněním pracovní paměti novou generací vylepšených řešení. Iterace a operátory se cyklicky opakují, dokud není splněno určité ukončovací kritérium. Matematická podstata EA zaručuje, že poslední generace řešení obsahuje řešení přinejmenším těsně se blížícímu k Pareto optimálnímu řešení, tj. proces šlechtění by měl konvergovat k populaci Pareto optimálních řešení.



Obrázek 2 Komponenty všeobecného stochastického vyhledávacího postupu (Zitzler et al. 2004)

Matečná selekce představuje výběr slibných řešení s nadprůměrnou multikriteriální kvalitou plnění cílů vhodných pro vylepšování prostřednictvím variace a obvykle se provádí náhodným způsobem. Oproti tomu, environmentální selekce a selekce elity obvykle deterministicky určuje, která z řešení (nových řešení z následné populace potomků vytvořených variací, ale i z předešlých řešení z mateřské populace již uložených v paměti) budou ponechány v interní paměti a budou tvořit mateřskou generaci v následujícím iteračním kroku. Environmentální selekce se zaměřuje na zajištění dostatečné

rozmanitosti tj. odlišnosti řešení zahrnutých do následné generace a v konečném důsledku tedy i dostatečné diverzity Pareto optimálních řešení tvořících poslední terminální generaci. Selektce elity znamená vyhledání a zkombinování nejlepších řešení v předešlé a následné generaci a byla vyvinuta zejména k zabránění ztráty elitních řešení z předchozí generace v důsledku stochastické povahy optimalizačního procesu. To vede ke zvýšení efektivity celé optimalizace.

Variační modul pracuje s podmnožinou řešení vybraných matečných selekcí do tzv. matečního zásobníku, a ty systematickým nebo náhodným způsobem modifikuje tak, aby došlo k vygenerování vylepšených řešení.

Stochastické vyhledávací algoritmy byly původně navrženy pro jednokriteriální optimalizace a vždy pracovaly pouze s jedním kandidátským řešením. V důsledku toho matečná selektce nebyla nutná a variační modul v jednotlivých iteracích modifikoval a hledal vylepšení jen pro jedno aktuální řešení. Evoluční algoritmy se oproti tomu vyznačují třemi vlastnostmi:

- zachovává se množina/populace kandidátských řešení,
- matečná selektce je nutnou operací a
- variační modul může vytvářet nová řešení rekombinací původních řešení.

Matečná selektce sestává obvykle ze dvou kroků: ohodnocení multikriteriální kvality (fitness nebo kondice) jednotlivých řešení a náhodného výběru. V prvním kroku, řešení v mateřské populaci jsou posouzeny podle hodnot indikátorů plnění jednotlivých cílů a je jim za pomoci určité funkce (zde nazývané také fitness funkce) přiřazena skalární hodnota multikriteriální užitečnosti (nebo i fitness hodnota) reflektující jeho kvalitu. Pak se náhodným výběrem z původní mateřské populace vytvoří tzv. matečný zásobník (mating pool), přičemž se kvalitnější řešení s lepší "kondicí" (vyšší fitness hodnotou) dostávají do zásobníku s mnohem vyšší pravděpodobností než méně kvalitní řešení se slabší "kondicí" (nižší fitness hodnotou). Asi nejběžnější používanou výběrovou metodou je tzv. binární turnajová selektce. Při ní se z mateřské populace náhodně vyberou dvě řešení, z nichž se do matečných zásobníků dostane řešení s lepší fitness hodnotou. Procedura se opakuje, dokud se matečný zásobník nenaplní.

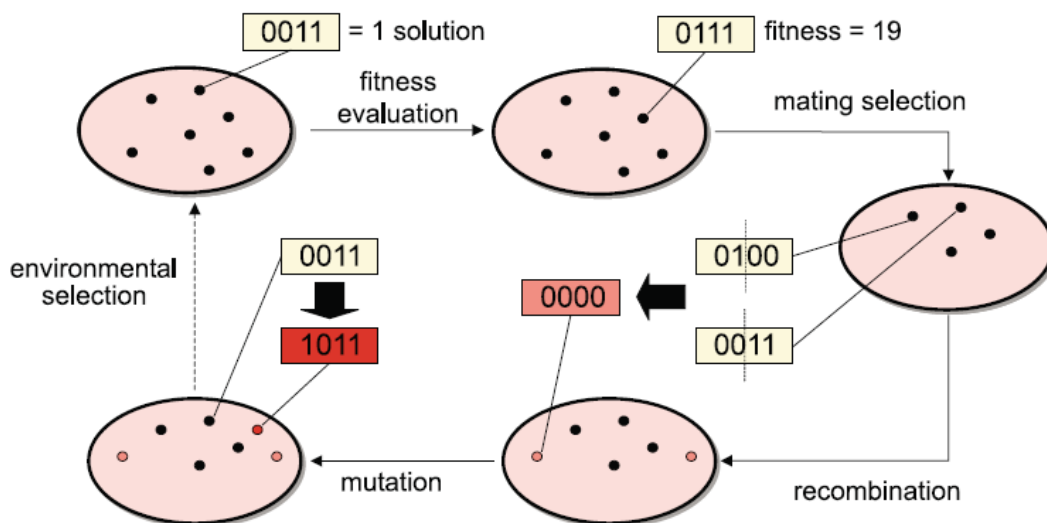
Následně evoluční algoritmus pokračuje aplikací tzv. variačních operátorů. Typicky se používají dva: křížení (rekombinace) a mutace. Rekombinantní operátor (ang. Crossover) bere určitý počet řešení z matečných zásobníků, z nichž stochastickou rekombinací hodnot rodičů vytváří definovaný počet potomků. Ve snaze napodobit stochastickou povahu evoluce, se nemusí rekombinace týkat všech řešení v matečném zásobníku, ale nastává pouze s určitou pravděpodobností křížení. Mutační operátor náhodně modifikuje vždy malé části jednoho, vybraného řešení (tj. některé hodnoty příslušné kombinace (vektoru) hodnot rozhodovacích proměnných x). Každý potomek vytvořený operátorem křížení může být pozměněn operátorem mutace. Každá rozhodovací proměnná je mutovaná s mutační pravděpodobností p_m , která se obvykle určuje jako $1/n$, kde n je počet rozhodovacích proměnných, takže v průměru se mutací pozmění jedna hodnota jedné rozhodovací proměnné. Operátor umožňuje lokální vyhledávání nového řešení v blízkosti aktuálního řešení a je nezávislý na poloze a kvalitě ostatních řešení v populaci. V důsledku stochastické povahy křížení a mutace některé jedinci v následné

generaci potomků jsou jednoduchými kopiemi některých řešení vybraných z mateřské populace do matečného zásobníku.

Následná environmentální selekce a selekce elity určuje, která řešení z původní a nové populace řešení budou zachována ("přežijí") a budou vystupovat jako mateřská populace v následující iteraci. Environmentální selekce je zaměřena na hodnocení fitness hodnoty potomků, která však kromě samotné kvality nového řešení zohledňuje stav a polohu ostatních řešení v blízkém okolí posuzovaného řešení. Přitom platí, že pokud v blízkém okolí posuzovaného řešení leží mnoho kvalitních konkurenčních řešení, jeho fitness hodnota se snižuje. Cílem environmentální selekce je zachování maximální rozmanitosti řešení v nové populaci, přičemž se velmi často kombinuje i s aplikací principu zachování elity, který poprvé popsal De Jong (1975). Elitizmus kombinuje starou populaci s nově vytvořenou populací a vybírá z nich nejlepší řešení. Tento operátor zaručuje, že algoritmus má monotónní nezhoršující se průběh (Zitzler et al. 2004). Kombinace environmentální selekce a elitizmu tak slouží jako nástroj zachování maximální diverzity nejkvalitnějších řešení, tj. řešení s nejlepší fitness hodnotou, která reflektuje kvalitu řešení i hustotu velmi podobných, konkurenčních řešení v jeho blízkém okolí. Favorizované jsou nejkvalitnější řešení ležící v co nejméně pokrytém cílovém prostoru, tj. řešení, která se co nejvíce liší od všech jiných řešení.

Na základě popsaných konceptů jsou iterativní výpočetní postupy schopné simulovat procesy přírodní evoluce (Obr. 3). Startovacím bodem je vytvoření iniciální populace řešení (solutions) a to buď náhodně (tvorba náhodných kombinací hodnot rozhodovacích proměnných a jejich náhodné distribuce mezi jednotkami optimalizace) nebo podle určitého předdefinovaného schématu (obvykle systematicky mapujícího potenciální variační rozpětí optimalizovaných proměnných).

Následně cyklus pokračuje evaluací iniciálních řešení a přiřazením fitness hodnoty každému řešení, matečných selekcí (výběr řešení s nadprůměrnou hodnotou fitness), křížením (rekombinací) a / nebo mutací (odvození nové generace vylepšených řešení variací matečného zásobníku), environmentální selekcí příp. selekcí elity (výběr dostatečně rozdílných řešení, příp. zachování nejlepších řešení předešlé generace). Cyklický proces iterativního vylepšování se opakuje, dokud není splněno jedno nebo více terminálních kritérií, např. často se používá dosažení zvoleného konečného počtu iterací, ale může to být i stagnace populace nebo existence řešení dostatečné kvality apod. Dalším kritériem může být rychlost konvergence mezi poslední a její předchozí populací nebo to mohou být další podmínky optimality (Lotov et al. 2004). Konečným výstupem evoluční optimalizace pak tradičně bývají elitní řešení poslední generace.



Obrázek 3 Koncepte všeobecného evolučního algoritmu (Zitzler et al. 2004)

Evoluční optimalizace je heuristický, stochastický a aproximativní proces, který umožňuje řešit různé typy problémů jako např. dynamicky se měnící problémy, problémy, které nejsou matematicky vyjádřitelné, komplexní, složité strukturované problémy a další. Obecně se s ní dají řešit takové multikriteriální problémy, kdy komplexnost problému prakticky zabraňuje možnosti uplatnění exaktních optimalizací, resp. jejich použití je náročné a zatížené vysokou neurčitostí.

3.1.1 Elitistický nedominovaný třídící genetický algoritmus NSGA-II

NSGA-II je evoluční algoritmus, který má následující tři vlastnosti: i) využívá principu elitismu, ii) využívá explicitní mechanismy pro zachování rozmanitosti populace a iii) nachází pouze nedominovaných řešení (Deb et al. 2017).

Algoritmus se opírá o dvě originální procedury: (i) rychlý třídící postup založený na identifikaci jednotlivých po sobě následujících front (skupin) nedominovaných řešení v populaci (ang. Fast nondominating sorting) a (ii) postup měřící hustotu řešení v okolí posuzovaného prostoru cílových hodnot pomocí tzv. vzdálenosti seskupení (ang. crowding distance). Spojení obou procedur vede k jednoznačnému seřazení řešení v určité populaci od nejlepšího po nejhorší, přičemž v úvahu se současně bere multikriteriální kvalita jednotlivých řešení, jakož i jejich diverzita v posuzované populaci.


Rychlé třídění je založeno na principu dominance, resp. nedominance řešení obsažených v aktuální populaci. Princip dominance lze vysvětlit na příkladu souběžné maximalizace indikátorů plnění definovaného vektoru cílů. Tehdy platí, že řešení p , které má všechny hodnoty cílových indikátorů větší ve srovnání s jiným řešením q , je označováno jako dominující, a naopak řešení q se nazývá dominované. Pokud při porovnávání hodnot cílových indikátorů dvou vybraných řešení zjistíme, že některé indikátory řešení p jsou větší, ale některé menší ve srovnání s řešením q , pak se obě cílové řešení označují jako vzájemně nedominované.

V rámci rychlého multikriteriálního třídění se pro každé řešení p vypočítají nebo sestaví dvě entity: (i) n_p počet řešení, které dominují řešení p , (ii) S_p seznam řešení, kterým řešení p naopak dominuje.

Všechna řešení, která mají $n_p = 0$ se přiřadí do první nedominované fronty F_1 označované také jako aktuální fronta. Postup pokračuje tím, že se každému řešení p obsaženému v aktuální frontě F_1 prověří jeho seznam S_p a všem řešením q obsaženým v příslušném seznamu se zredukuje entita n_q o jednu jednotku. Po prověření všech členů se v dalším kroku zjistí, u kterých řešení mimo aktuálního fronty F_1 došlo k vynulování $n_q = 0$ a ty se uloží do separátní fronty F_2 . Následně se fronta prohlásí za aktuální a celý postup se opakuje. Na závěr procedura rychlého třídění nedominovaných řešení aplikovaná na určitou populaci P poskytuje jako výstup seznamy řešení podle jednotlivých nedominovaných front F .

Seřazení řešení v rámci identifikovaných front pak už probíhá na odlišném principu, jehož hlavním cílem je zachování maximální rozmanitosti řešení v následných populacích zaručující kvalitní zmapování množiny Pareto optimálních řešení.

Druhým klíčovým prvkem algoritmu NSGA-II je tak odhad hustoty řešení v cílovém prostoru obklopující vybrané řešení i . Jako hlavní míra odhadu se používá průměrná vzdálenost dvou nejbližších sousedů z každé strany cílového prostoru odděleně podle jednotlivých cílů. Vzdálenosti sousedy podle hodnot jednotlivých cílových indikátorů se používají k odvození veličiny $i_{distance}$, což je velikost největšího prázdného kuboidu obalujícího řešení i neobsahující žádné jiné řešení (označovaná také jako seskupení). Obr. 4 znázorňuje princip měření seskupení pro případ dvou rozměrného cílového prostoru a pro případ simultánní minimalizace dvou cílů. Seskupení i -tého řešení ve své frontě (vyznačené plnými tečkami) je průměrná vzdálenost jednotlivých stran kuboidu (v tomto případě čárkovaný obdélník).

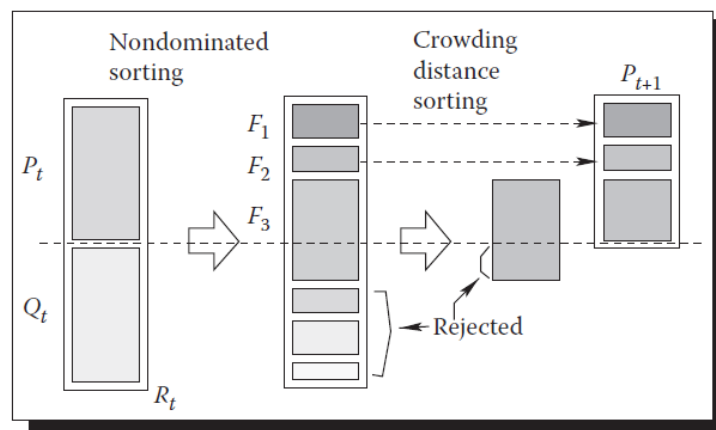


Obrázek 4 Princip určení seskupení řešení při metodě NSGA (Deb et al. 2000)

Bod i reprezentuje i -té řešení daného problému umístěný v cílovém prostoru f_1 a f_2 , body $i + 1$ a $i - 1$ reprezentují nejbližší řešení k řešení i . Obdélník vytvořen čárkovanou čarou je grafické znázornění prázdného prostoru kolem daného řešení i , který je vymezen jeho dvěma nejbližšími sousedy. Průměrná vzdálenost je počítána jako průměrná vzdálenost mezi body $i + 1$ a $i - 1$ napříč všemi jejich cílovými hodnotami.

Kombinace obou procedur rychlého třídění nedominovaných řešení a výpočtu velikosti seskupení řídí selekční proces v různých fázích NSGA-II optimalizace směrem k rovnoměrně pokryté frontě (množině) nedominovaných Pareto optimálních řešení. Základem je seřazení řešení podle jejich kvality a rozmanitosti měřené pořadím nedominované fronty i_{rank} , do které určité řešení patří a seskupením $i_{distance}$. Řešení i má větší optimalizační hodnotu než jiná porovnávaná řešení j , když $i_{rank} < j_{rank}$ nebo pokud $i_{rank} = j_{rank}$, ale současně $i_{distance} > j_{distance}$. To znamená, že pokud máme dvě řešení s různým pořadím nedominované fronty, upřednostňují se řešení s nižším pořadím a pokud obě řešení patří do stejné fronty, upřednostníme řešení umístěné v cílovém regionu s malým počtem řešení (s větším prázdným prostorem kolem sebe).

Hlavní cyklus optimalizačního algoritmu NSGA-II začíná vygenerováním náhodné iniciální mateřské populace P_0 řešení o velikosti N . Iniciální populace je setříděna na principu nedominance a každému řešení je přiřazena jeho fitness hodnota rovná jeho úrovni nedominace (příslušníci 1. nedominované fronty získávají fitness hodnotu 1, druhého 2 atd.). Následně se pomocí procedur binární turnajové selekce, křížení a mutace vytvoří iniciální generace dceřiných řešení Q_0 o velikosti N . Od první generace výše je už postup NSGA-II algoritmu jiný, když se do optimalizace zapojuje operátor zachování elity (Obr. 5).



Obrázek 5 Princip zachování elity v algoritmu NSGA-II (Deb et al. 2017)

Při tom se nejprve vytvoří kombinovaná populace $R_t = P_t \cup Q_t$ o velikosti $2N$. Ta je setříděna procedurou rychlého nedominovaného třídění ve spojení s operátorem seskupení, takže pořadí řešení je dáno i jejich kvalitou i rozmístěním v cílovém prostoru. Nová mateřská populace P_{t+1} se vytvoří převzetím N nejlepších řešení z R_t podle pořadí vytvořeného rychlým třídícím algoritmem. Tato populace o velikosti N se použije na selekci, křížení a mutaci a vytvoří se z ní populace potomků. Pak se postup už cyklicky opakuje, až po splnění předdefinovaného terminálního kritéria (nejčastěji požadovaný počet generací).

Doposud popsaný originální postup NSGA-II poskytuje požadovaný počet multikriteriálních řešení s co největší diverzitou (tj. co nejkompaktněji popisujících Pareto optimální hranici v cílovém prostoru). Snahou je poskytnout rozhodovateli v závěrečné fázi optimalizace na výběr množinu co nejvíce vzájemně se lišících multikriteriálně optimálních řešení. Originální postup je aplikovatelný při uživatelsky aposteriorní formě optimalizačního postupu.

V rámci apriorní a neutrální formy optimalizace se původní postup NSGA-II modifikuje. Při této formě rozhodovatel ještě před spuštěním výpočtů nadefinuje své osobní preference plnění jednotlivých cílů ve formě relativních vah jednotlivých indikátorů vstupujících do skalarizační objektivizační funkce. Tato informace se dá využít na zvýšení efektivity a také kvality vyhledávání finálního řešení při zachování populačního principu a dovoluje spojit 5. a 6. etapu obecného postupu optimalizace (kap. 3) do jednoho kroku.

Modifikace originálního postupu spočívá v tom, že: (i) v rámci rychlého nedominovaného třídění kombinované populace R_t se operátor seskupení (2. kritérium třídění) nahradí přímo hodnotou skóre multikriteriální optimalizace U vykalkulovaným pro každé řešení přímo z již známé, dopředu specifikované objektivizační funkce, (ii) v rámci tvorby dceřiných populací Q_{t+1} se křížení a zmutování dvou mateřských řešení vybraných turnajovou selekcí akceptuje jen pro takové navrhované dceřinné řešení, které má skóre multikriteriální užitečnosti (tj. fitness) lepší než skóre lepšího řešení z mateřského páru, jinak se postup opakuje (v rámci šlechtění Q_{t+1} se tak zavádí nový cyklus).

První modifikace znamená, že řešení v rámci určité nedominované fronty jsou namísto seskupení seřazované podle multikriteriálního skóre užitečnosti, což vede namísto rozšiřování k zúžení prohledávaného cílového prostoru směrem k preferovanému finálnímu řešení. Modifikace slouží primárně ke zvýšení multikriteriální kvality nalezeného finálního řešení.

Druhá modifikace zajišťuje, že průměrná multikriteriální kvalita dceřiných populací (opět ve vztahu k definovaným preferencím) je vždy podstatně vyšší než v mateřských populacích, což značně zvyšuje efektivity a kvalitu vyhledávání finálního řešení, ale na druhé straně snižuje výpočetní efektivity celé optimalizace.

Postup NSGA-II představuje matematické jádro celé multikriteriální optimalizace a aplikuje se ve dvou variantách - originální a modifikované. Výběr varianty závisí od komunikace analytika a rozhodovatele a od schopnosti rozhodovatele artikulovat preferování jednotlivých cílů před započítáním samotné optimalizace.

3.2 Praktická implementace metodiky multikriteriální optimalizace výchovy a obnovy lesa na určitém hospodářském celku

Navrhovaná metodika přímo vychází z metodiky multikriteriální optimalizace výchovy jednotlivého porostu, první etapy v obou postupech jsou prakticky identické. Definice některých specifických pojmů používaných na technickou specifikaci výpočtů v obou metodikách jsou uvedeny v metodice Sedmák et al. (2016).

3.2.1 Příprava podkladů pro optimalizaci

Příprava spočívá v identifikaci souboru optimalizovaných lesních porostů a zjištění informací o jejich výchozím stavu. Předmětem optimalizace výchovy může být libovolný porost, ve kterém má alespoň jedna z dřevin na začátku optimalizačního období fyzický věk menší než věk začátku obnovy porostů a současně větší než výchozí věk výchovy pro dřevinu na dané bonitě zmenšený o délku plánovacího období (v porostech z více dřeviny se vezme v úvahu minimální věk). Předmětem optimalizace obnovy jsou pak analogicky porosty, ve kterých má alespoň jedna z dřevin na začátku optimalizačního období fyzický věk větší než věk začátku obnovy zmenšený o délku plánovacího období. V první fázi jde tedy o vytvoření seznamu porostů. V každém porostu zařazeném do optimalizačního seznamu je třeba pro výpočet indikátorů plnění rozličných ekosystémových služeb znát jeho věk (s přesností na 5 let), zakmenění, zastoupení, bonity a skutečné zásoby jednotlivých dřevin na 1 hektar na začátku optimalizace. Uvedené informace je třeba získat buď přímým měřením v terénu nebo převzetím údajů z platných LHP.

3.2.2 Definování základních rozhodnutí, cílů a indikátorů optimalizace

Po sestavení seznamu optimalizovaných porostů a získání základních informací analytik s rozhodovatelem určí délku optimalizačního období, vyberou základní jednotku optimalizace a dohodnou se na formě optimalizačního postupu. Kromě toho se v druhé etapě optimalizace přistupuje k stanovení spektra optimalizovaných ES a indikátory jejich plnění. Stanovení sestává z 2 kroků: (i) definování plného spektra potenciálně optimalizovaných ES a indikátorů jejich plnění, (ii) výběr ES a indikátorů, které jsou předmětem aktuálního užšího zájmu.

Obecním cílem optimalizace výchovy a obnovy lesních porostů je maximalizace funkčních účinků podpůrných, produkčních, regulačních a socio-kulturních ES při současném posílení trvalosti hospodaření, posílení biodiverzity, statické stability a celkové ekosystémové integrity lesa. Z tohoto důvodu systém indikace plnění jednotlivých služeb používaných v navrhované metodice na úrovni HC logicky vychází z klasifikace ES podle zprávy Mezivládního panelu expertů iniciativy OSN Millenium Ecosystem Assesment (MEA 2005) a plně se kryje se systémem indikace na úrovni jednotlivého porostu. Logika odvození, technická specifikace a přesný návod jak vypočítat jednotlivé indikátory pro každý porost na zájmovém území jsou popsány v metodice Sedmák et al. 2016.

Výsledný systém používá k indikaci: (i) plnění produkčních služeb zásobu dřeva v lesních porostech a objem těžeb, (ii) plnění regulačních služeb relativní index hustoty porostů SDI_r , (iii) plnění socio-kulturních služeb index estetiky lesa a jeho rekreační hodnoty I_r a (iv) stavu biodiverzity a ekologické stability lesa speciální index biodiverzity B podle Jaehne, Dohrenbusch (1996).

V rámci druhé etapy optimalizace může dojít k upřesnění cílů optimalizace prostřednictvím výběru kombinace optimalizace ES. Komplexní multifunkční optimalizace výchovy a obnovy lesních porostů by měla brát v úvahu celé spektrum ES, avšak v rámci obecního a poměrně komplexního cíle může mít rozhodovatel nebo určitá skupina rozhodovatelů zájem pouze na řešení dílčích problémů, jakými jsou např. konflikt mezi produkčními a regulačními ekosystémovými službami nebo mezi produkčními

službami a biodiverzitou apod. V krajním případě se rozhodovatel může soustředit jen na optimalizaci jedné ES a jednoho indikátoru např. objemu výchovné či obnovní těžby, čímž se původně multikriteriální optimalizační změna na optimalizaci jednokriteriální.

Proto v druhé fázi optimalizace může (i když nemusí) dojít k individuálnímu nebo participativnímu výběru spektra optimalizovaných ekosystémových služeb a indikátorů jejich plnění. Výběr optimalizovaných služeb z plně předdefinované sady se dá chápat i jako vyjádření absolutní preference rozhodovatele určitých ES ve vztahu k původně úplnému portfoliu optimalizovaných ES.

3.2.3 Definování alternativních způsobů výchovy lesních porostů, modelování a kvantifikace dopadů jejich uplatnění na porostní úrovni

Kvantifikace indikátorů plnění vybraných ES začíná definováním množiny různých systémů výchovy a obnovy lesa použitelných v daných přírodních podmínkách, pokračuje nasimulováním vlivu různých systémů výchovy nebo obnovy na růst konkrétních porostů v optimalizovaném období a končí se výpočtem hodnot indikátorů plnění vybraných ES na konci optimalizačního období podle jednotlivých výchovných a obnovních systémů a porostů (Sedmák et al. 2016).

3.2.4 Generování iniciální populace alternativních hospodářských plánů a kvantifikace indikátorů plnění ekosystémových služeb na úrovni hospodářského celku

Pod alternativním plánem se rozumí různé kombinace přiřazení různých výchovných nebo obnovních systémů do jednotlivých porostů identifikovaných na uvažovaném HC. Z pohledu multikriteriální optimalizace každý alternativní hospodářský plán představuje jedno možné řešení optimalizačního problému. V tomto kroku jde tedy o vygenerování iniciálního souboru náhodných řešení, které se v dalším postupu budou iterativně vylepšovat ("šlechtit").

V rámci prezentované metodiky byla jednotlivá náhodná řešení - kombinace systémů výchovy a obnovy v souboru porostů nazývaných také hospodářské plány - získána za pomoci optimalizace výchovy a obnovy lesa vycházející z úrovně jednotlivého porostu (Sedmák et al. 2016). Z rozšířených růstových tabulek jsou známé kvantifikace plnění ES (indikátory) pro každý výchovný a obnovní systém a porost. Z těchto hodnot je možné za předpokladu náhodně vygenerovaných parametrů objektivizační funkce vypočítat optimalizační skóre U každého systému v každém porostu. Následně je možné pro každý porost zvlášť vybrat optimální výchovný nebo obnovní systém z pohledu definované objektivizační funkce a vytvořit tak náhodný hospodářský plán.

Náhodné generování parametrů objektivizační funkce se řeší vygenerováním náhodné patice čísel z intervalu 0-1 a jejich následné standardizace tak, aby jejich součet dosáhl hodnotu 1. Takový vektor se pak použije jako náhodný vektor vah objektivizační funkce s cílovými hodnotami stanovenými jako idealistický vektor unikriteriálních maxim. Takto se na základě náhodného nastavování vah plnění jednotlivých ES ve zvolené objektivizační funkci a tedy náhodného mapování možných preferenčních nastavení vytvoří požadovaný počet hospodářských plánů tvořících iniciální populaci.

V rámci kvantifikace indikátorů za HC jde o výpočet indikátorů plnění vybraných ES za celý HC z hodnot indikátorů jednotlivých porostů podle jednotlivých náhodných hospodářských plánů (řešení).

Odvození informací za celé HC je poměrně jednoduché - při všech porostních veličinách vázaných na plochu (zásoba a objem těžeb na ha) jde o součiny hodnot indikátorů a výměr porostů, při veličinách vázaných na porost ($SDI_r, I_r, B, H / D$) se součiny hodnot indikátorů a výměr porostů ještě dělí výměrou HC, takže se jedná o vážený aritmetický průměr.

3.2.5 Multikriteriální optimalizace a iterativní vylepšování populace alternativních hospodářských plánů

V této etapě jde o samotnou evoluční multikriteriální optimalizaci založenou na aplikaci NSGA II algoritmu. Výsledkem je vyšlechtěná populace hospodářských plánů s různými kombinacemi hodnot indikátorů plnění ES na úrovni HC, které se všechny dají považovat za multikriteriálně (Pareto) optimální.

Optimalizace iniciální populace hospodářských plánů začíná evaluací kvality jednotlivých jednotlivých plánů spojenou s přiřazením fitness hodnoty a pokračuje matečnou selekcí - výběrem plánů s nadprůměrnou kvalitou. Následně dochází k variaci (křížení a mutaci) nadprůměrných plánů, které vzniknou do vytvoření nové dceřiné generace hospodářských plánů. Nová generace plánů pak prochází kombinovanou selekcí (environmentální a elity), která zabezpečí výběr nejkvalitnějších a co nejvíce rozdílných hospodářských plánů do mateřské populace následujícího optimalizačního cyklu.

Cyklický proces iterativního vylepšování se opakuje, dokud není dosažen zvolený počet iterací, kterým je v navrhované metodice roven 100. V praxi se tak při navrhované optimalizaci prověří 100 generací, přičemž každá generace sestává ze 100 hospodářských plánů. Zvolená kombinace odpovídá běžné optimalizační praxi a možnostem běžných počítačů a zaručuje dobrou praktickou upotřebitelnost metodiky při dosažení dobré kvality optimalizace.

Technicky je celý postup řešen algoritmem NSGA-II. Ten jako jeden z hlavních mechanismů optimalizace opakovaně využívá tzv. rychlý řadící algoritmus nedominovaných řešení. Řadící algoritmus slouží k vytvoření pořadí plánů populací podle jejich multikriteriální kvality a rozmanitosti. Vytvořené pořadí řídí selekční proces v různých fázích NSGA-II optimalizace a ve finále vede k vytvoření rovnoměrně pokryté fronty (množiny) nedominovaných Pareto optimálních plánů.

Řadící algoritmus využívá na třídění dvě procedury: (i) proces identifikace následných front (skupin) nedominovaných hospodářských plánů v cílovém prostoru hodnot indikátorů plnění ES a (ii) výpočet průměrné vzdálenosti nejbližších hospodářských plánů v okolí posuzovaném v cílovém prostoru ES.

Identifikace nedominovaných front hospodářských plánů se opírá sérii párových porovnávání vybraného plánu se všemi ostatními plány v populaci. V případě snahy o simultánní maximalizaci indikátorů plnění definovaného spektra ES platí, že hospodářský plán p , který má všechny hodnoty indikátorů plnění ES větší ve srovnání s jiným plánem q , je považován za dominující, zatímco plán q se označuje jako dominován (překonán). Pokud při porovnávání hodnot indikátorů plnění ES dvou vybraných hospodářských plánů zjistíme, že některé indikátory plánu p jsou větší, ale některé menší ve srovnání s plánem q , pak se oba plány považují jako vzájemně nedominované.

V rámci rychlého multikriteriálního třídění se pro každý plán p stanoví na základě párového porovnávání dvě entity: (i) n_p počet hospodářských plánů, které překonávají řešení p , (ii) seznam plánů, kterým hospodářský plán p naopak dominuje. Všechny hospodářské plány, které mají $n_p = 0$ a tedy nebyly ani jednou při vzájemném porovnávání s jinými plány překonány, se přiřadí do první nedominované fronty F_1 označované také jako aktuální fronta. Postup pokračuje tím, že se každému plánu p obsaženému v aktuální frontě F_1 prověří jeho seznam plánů S_p , které překonává, a všem dominovaným plánům q obsažených v příslušném seznamu se zredukuje entita o jednu jednotku.

Po prověření všech členů F_1 se v dalším kroku zjistí, u kterých plánů mimo aktuální frontu došlo k vynulování $n_q = 0$ a ty se uloží do separátní fronty F_2 . Následně se fronta F_2 prohlásí za aktuální a celý postup se opakuje. Na závěr procedura rychlého třídění nedominovaných řešení poskytuje jako výstup seznamy plánů podle jednotlivých sousledných front F , což dovoluje jednotlivé plány částečně seřadit.

Úplné seřazení plánů v rámci jednotlivých identifikovaných front se provádí na základě změření hustoty plánů obklopujících vybrané řešení p v cílovém prostoru indikátorů plnění ES. Jako hlavní míra se používá průměrný rozměr prázdného kuboidu obalujícího plán p neobsahujícího žádný jiný plán v cílovém prostoru ES (označovaná také jako seskupení). Princip a postup stanovení seskupení pro každý hospodářský plán byl již názorně ilustrovaný v kap. 3.1.1 (obr. 4).

Úplné seřazení hospodářských plánů v populaci se tedy dělá primárně podle jejich kvality měřené pořadím nedominované fronty, ke které patří a sekundárně podle rozmanitosti plánů měřené seskupením. To znamená, že pokud máme dva hospodářské plány patřící k různým nedominovaným frontám, upřednostňuje se plán s nižším pořadím fronty. Pokud oba srovnávané plány patří do stejné fronty, upřednostníme plán umístěný v slabě pokryté části cílového prostoru ES (tj. s větším prázdným prostorem kolem sebe). Plány objevující se v méně pokrytých částech cílového prostoru se tak považují za cennější než ostatní.

Aplikace NSGA-II algoritmu v rámci problematiky výchovy a obnovy lesa na LHC začíná seřazením iniciační populace hospodářských plánů rychlým nedominovaným algoritmem. Poté se pomocí procedur binární turnajové selekce, křížení a mutace vytvoří následná generace řešení o velikosti N .

Binární turnajová selekce je založena na dvou opakovaných výběrech dvojice hospodářských plánů. Z každé dvojice přechází do následující operace křížení vždy pouze jeden plán patřící k nižší nedominované fronty, nebo pokud oba plány patří ke stejné frontě, tak dále prochází plán s vyšší hodnotou seskupovací vzdálenosti. Výsledkem matečné selekce je pak dvojice mateřských plánů s vyšší multikriteriální kvalitou a rozmanitostí. Operace křížení je prováděna operátorem-subalgoritmem polo-uniformního křížení, při kterém se obě plné sekvence výchovných nebo obnovních postupů od prvního po poslední optimalizovaný porost tvořících mateřské hospodářské plány rozdělí na náhodný počet subsekvencí náhodné délky (např. plná sekvence 200 porostů může být náhodně rozdělena na 3 sekvence: od 1 po 47, od 48 po 92 a od 93 do 200).

Následně se ze subsekvencí rodičovských plánů náhodně vytvoří nová plná sekvence dceřiného plánu tak, že se při každé dceřině subsekvenci náhodně losuje, od kterého rodiče bude převzata. Počet subsekvencí a jejich délka může být generována plně náhodným způsobem, v prezentované metodice však je podle doporučení z literatury zavedeno omezení na počet subsekvencí, který nesmí překročit 25 % z délky plné sekvence optimalizovaných porostů. Nový dceřiný plán vytvořen ze dvou rodičovských plánů vybraných v rámci matečné selekce je pak sekvence plánů přiřazených do jednotlivých porostů vytvořená náhodným mixem subsekvencí plánů mateřského páru.

Dceřiný plán získaný křížením v dalším kroku může být podroben mutaci. Mutace představuje plně náhodnou modifikaci sekvence těžebních plánů v souboru optimalizovaných porostů nahrazením aktuálního systému výchovy nebo obnovy ve vybraném porostu jiným náhodně vybraným systémem. Mutační pravděpodobnost (frekvence náhodných nahrazení) je standardně nastavena na hodnotu $1/n$, kde n je počet optimalizovaných porostů v sekvenci. Z nastavení vyplývá, že mutační událost nastává průměrně jednou u každého kontrolovaného dceřiného plánu. Mutace znamenají drobnou náhodnou modifikaci původní sekvence výchovných nebo obnovních plánů tvořících určitý hospodářský plán ve snaze prozkoumat blízké okolí aktuálního plánu v rozhodovacím prostoru, které primárně brání stagnaci optimalizace. Jak již bylo uvedeno, operace matečné selekce, křížení a mutace se opakují, dokud se nevytvoří následná generace řešení Q_0 o velikosti N .

Od první generace výše NSGA-II algoritmus začíná v rámci optimalizace používat i operátor zachování elity. Operátor elity funguje tak, že po variaci hospodářských plánů P_t a vytvoření následné generace Q_t se vytvoří spojená, kombinovaná populace $R_t = P_t \cup Q_t$ o velikosti $2N$. Ta se nově setřídí procedurou rychlého nedominovaného třídění. Nová mateřská populace P_{t+1} se vytvoří převzetím N nejlepších plánů R_t z pořadí vytvořeného rychlým třídícím algoritmem. Tato populace plánů P_{t+1} o velikosti N se pak použije na matečnou selekci, křížení a mutaci plánů v další iteraci a pro vytvoření populace vylepšených plánů Q_{t+1} , R_{t+1} a P_{t+2} . Dále se postup už cyklicky opakuje, až po splnění předdefinovaného terminálního kritéria 100 generací.

Elitní řešení sté generace představuje 100 multikriteriálně (Pareto) optimálních plánů využitých v následující poslední etapě optimalizace pro identifikování finálního plánu preferovaného rozhodovatelem, případně skupinou rozhodovatelů zainteresovaných na hospodaření na definovaném HC. Toto platí při uživatelsky aposteriorní verzi optimalizace.

Při apriorní a uživatelsky neutrální variantě se na šlechtění používá modifikovaná metoda NSGA-II, v jejímž rámci šlechtění populace plánů a výběr finálního splývá. Modifikace NSGA-II spočívá v: (i) nahrazení veličiny seskupení v rámci rychlého nedominovaného třídění kombinované populace R_t hodnotou skóre multikriteriální optimalizace U vykalkulovaná pro každý šlechtěný plán za pomoci předem specifikované objektivizační funkce, (ii) v rámci tvorby dceřiných populací hospodářských plánů Q_{t+1} se křížení a zmutování dvou mateřských plánů vybraných turnajovou selekcí z P_{t+1} akceptuje jen takový dceřiný plán, který má skóre multikriteriální užitečnosti U lepší než skóre lepšího

řešení z mateřského páru, jinak se postup křížení a mutace při tvorbě Q_{t+1} opakuje. Podobně jako u předešlé varianty, postup se cyklicky opakuje, až po splnění předdefinovaného terminálního kritéria 100 generací, který při apriorní variantě současně znamená ukončení šlechtění a současně stanovení finálního hospodářského plánu. Tím je plán s nejlepším optimalizačním skóre U ze skupiny elitních plánů terminální generace.

3.2.6 Výběr finálního hospodářského plánu z množiny multikriteriálně optimálních plánů

Tato fáze optimalizace se používá pouze v případě aplikace tzv. aposteriorní formy optimalizační procedury. Při ní v poslední etapě multikriteriální optimalizace analytik ve spolupráci s rozhodovatelem/i vybere finální matematickou formu objektivizační funkce (rov. 1 a 2, kap. 3) a stanoví její parametry (váhy a požadované hodnoty indikátorů plnění ES) na zájmovém LHC.

Objektivizační funkce slouží k převodu vektoru různorodých hodnot jednotlivých indikátorů plnění ES do podoby finálního skóre multikriteriální užitečnosti (skalár - 1 hodnota) zvláště pro každý multikriteriálně optimální HP. Posledním logickým krokem pak je identifikace hospodářského plánu s nejpříznivější hodnotou optimalizačního skóre nejlépe reflektujícího nastavení objektivizační funkce resp. preference rozhodovatele. Výběrem finálního hospodářského plánu se proces optimalizace končí, i když je vhodné optimalitu zvoleného řešení ještě při praktické implementaci sledovat a testovat.

3.3 Aplikace optimalizace výchovy jednotlivých porostů na referenčním lesním celku

Postup multikriteriální optimalizace výchovy a obnovy lesa na úrovni souboru porostů bude ilustrován na souboru 290 lesních porostů tvořících referenční lesní hospodářský celek tak, aby byla důvěryhodně demonstrována jeho funkčnost při aplikaci v souboru porostů s různým věkem, zakmeněním, dřevinným složením, zastoupením dřevin a bonit v určitých přírodních a hospodářských podmínkách reálného celku.

Zvolenou formou optimalizace je apriorní optimalizace využívající modifikovaný NSGA-II algoritmus spojující šlechtění populací hospodářských plánů s výběrem finálního, uživatelsky preferovaného plánu. Délka optimalizačního období byla ponechána na hodnotě 30 let. Základní jednotkou optimalizace byl zvolen porost.

Za těchto okolností praktický postup optimalizace těžeb na úrovni celého LHC se skládá z následujících kroků:

1) Vytvoření iniciální databáze optimalizovaných porostů a výpočet indikátorů plnění ES pro každý výchovný nebo obnovní systém a porost

2) Výběr formy objektivizační funkce, definování spektra, specifikace vah a kýžených úrovní plnění ekosystémových služeb (vyjádření absolutních a relativních preferencí ES podle nasimulovaných typů rozhodovatelů).

3) Generování iniciální populace hospodářských plánů o počtu 100, tj. vytvoření 100 náhodných rozdělení výchovných nebo obnovních systémů v porostech referenčního celku.

4) Dopočet hodnot indikátorů plnění produkčních, regulačních a kulturních ekosystémových služeb, biodiverzity a ekologické stability lesa z porostních údajů pro úroveň celého HC za každý hospodářský plán tvořící iniciální populaci

5) Iterativní vylepšování iniciální populace plánů podle principů a postupů evoluční multikriteriální optimalizace, vytvoření elitní množiny Pareto optimálních hospodářských plánů o počtu 100 a výběr nejlepšího finálního hospodářského plánu výchovy a obnovy lesa pro referenční HC zaručující multikriteriálně optimální plnění ES preferované určitým typem rozhodovatele.

Finální plán je multikriteriálně optimální plán, při kterém existuje předpoklad, že při jeho aplikaci se plnění ES v definovaném optimalizačním období bude blížit požadavkům a představám rozhodovatele, resp. skupiny rozhodovatelů zainteresovaných na výsledcích výchovy a obnovy lesa na zkoumaném území.

V rámci 2. kroku příkladové aplikace dochází k apriornímu definování vstupů a parametrů objektivizační funkce předcházející samotné optimalizaci (kroky 3-5). V příkladu se přistoupilo k optimalizaci plného spektra ES (5 indikátorů), při které byl výběr finálního, rozhodovatelsky preferovaného plánu proveden za pomoci vážené formy objektivizační funkce L2 s následujícími parametry: (i) vektor žádoucích úrovní plnění jednotlivých ES byl stanoven analytikem jako idealistický vektor unikriteriálních maxim mimo vůli rozhodovatele, (ii) váhy indikátorů plnění jednotlivých ES byly stanoveny uživatelem resp. byly zadány simulovaným typem uživatele.

Apriori specifikovaná objektivizační funkce tak používá idealistické požadované úrovně plnění ES reprezentující plně vyvážené idealistické plnění ES na definovaném LHC v kombinaci s expertně nastavenými váhami jednotlivých indikátorů plnění ES napodobujících chování a preference různých typů rozhodovatelů, kteří idealistickou představu plně vyváženého plnění ES mohou subjektivně značně modifikovat. Vektor žádoucích hodnot sledovaných indikátorů za celý HC byl stanoven analytikem na základě jednokriteriální optimalizace aplikované postupně podle jednotlivých indikátorů.

Prostřednictvím stanovení vah významnosti bylo možné nasimulovat vstup různých typů rozhodovatele do procesu optimalizace. Taková aplikace dovolila jasně demonstrovat možnost a efekty subjektivního nebo participativního rozhodování na tvorbu plánu hospodaření, plnění ES a výchovu lesa na určitém území. Kombinace relativních vah plnění použitých v skalarizační objektivizační funkci matematicky charakterizuje typ rozhodovatele. V příkladové aplikaci je nasimulovaných šest modelových typů rozhodovatele (Tab. 1).

Tabulka 1 Relativní váhy indikátorů plnění cílů optimalizace podle modelových rozhodovatelů

Typ rozhodovatele	Zásoba dřeva (V)	Objem těžeb ($V_{preb.}$)	Index relativní hustoty porostu (SDI)	Index rekreace (Ir)	Index biodiverzity (B)
-------------------	------------------	-----------------------------	---------------------------------------	---------------------	------------------------

Ekonom I	0.75	0.1	0.05	0.05	0.05
Ekonom II	0.1	0.75	0.05	0.05	0.05
Environmentalista	0.05	0.05	0.75	0.05	0.1
Občan	0.05	0.05	0.05	0.75	0.1
Ochranář	0.05	0.05	0.1	0.05	0.75
Lesník	0.2	0.2	0.2	0.2	0.2

První typ je ekonomický rozhodovatel, který je zaměřen převážně na plnění produkčních ES, prostřednictvím maximalizace konečné zásoby dřeva v porostech na konci optimalizovaného období. Jde o typ, který se snaží o maximalizaci výnosů ze dřeva, přičemž na ostatní ES a biodiverzitu přihlíží pouze okrajově. Tento typ rozhodovatele je ochoten jít do většího ekologického rizika při hospodaření než ostatní typy. Typickým příkladem může být velký vlastnický subjekt, pro který výnosy z přejímek nejsou nutné k zajištění rentability a kontinuálních výnosů tj. kontinuitu výnosů si je schopen zajistit díky vlastnictví větších výměr lesa i vyrovnáním obnovních těžeb.

Druhý typ rozhodovatele je rovněž primárně zaměřen na produkční ekosystémové služby, avšak jako hlavní prostředek maximalizace jejich plnění používá objem výchovné těžby. Takový typ rozhodovatele je charakteristický pro menší vlastnický subjekt v LH, pro kterého je kontinuita výnosů důležitější než samotná maximalizace výnosů ze dřeva, protože při menší výměře lesa nedokáže dosáhnout kontinuitu výnosů z plochy a při dlouhých obmýtí používaných v aktuální praxi nedokáže čekat na začátek obnovy lesních porostů.

Třetí typ rozhodovatele je environmentálně orientovaný typ preferující maximalizaci plnění regulačních služeb a zvláště dbá i na posilování ekologické stability lesa. Z těchto důvodů za významnější považuje index relativní hustoty lesa a biodiverzity. Pro uvedený typ rozhodovatele je primárně důležité, aby les bránil erozi půdy, reguloval tok a vylepšoval kvalitu vody, reguloval klimatické poměry v regionu apod. Zároveň si uvědomuje, že regulační funkce mohou být efektivně plněny pouze v případě kontinuální existence lesa úzce související s jeho biodiverzitou a ekologickou stabilitou.

Čtvrtým typem rozhodovatele je sociálně orientovaný rozhodovatel reprezentující širší občanskou veřejnost, která se dnes přímo nepodílí na řízení a plánování hospodaření, ale aktivně a bez omezení využívá kulturní služby, které les poskytuje. Takový rozhodovatel je zaměřen na maximalizaci socio-kulturních služeb prostřednictvím indexu rekreace, následně ještě ve zvýšené míře přihlíží na integritu lesa a o ostatní ES zajímá jen okrajově.

Pátý typ je člověk primárně zaměřen na ochranu přírodních procesů probíhajících v lese a půdě, který za nejdůležitější považuje maximalizaci biodiverzity a ekosystémové integrity lesa zaručující kontinuitu existence lesa na daném území. Proto přikládá větší váhu maximalizaci hodnot indexu biodiverzity, potom indexu relativní hustoty lesa indikující plnění regulačních ES a o ostatní služby se zajímá jen okrajově.

Posledním, šestým typem je vyvážený rozhodovatel, který zvláště nepreferuje žádnou ekosystémovou službu, ale je zaměřen na simultánní plnění všech skupin ES. Jeho primárním cílem tedy je vyvážená, simultánní optimalizace co nejširšího spektra ES, při které jsou váhy významnosti všech ES stejné. Takový rozhodovatel by měl reprezentovat profesionálního odborného lesního hospodáře, který se z titulu svého vzdělání a profesionality snaží vyváženě naplňovat jak požadavky vlastníka lesa na ekonomický profit, tak i požadavky společnosti a ochrany přírody na zachování a ochranu přírodního bohatství země a požadavky širší veřejnosti zaměřené na poskytování socio-kulturních služeb.

Technické detaily jednotlivých etap optimalizačního postupu byly popsány v předešlých kapitolách. V následujícím textu bude praktická aplikace postupu podrobně zdokumentována na reálných datech vybraného HC.

3.3.1 Charakteristika přírodních a hospodářských poměrů a stavu lesa na referenčním hospodářském celku

Celek má rozlohu 330,5 ha a leží ve Středočeském kraji. Většina plochy náleží do územní působnosti obce s rozšířenou působností Rakovník (okres Rakovník). Geomorfologicky jde o přírodní lesní oblast 9 - Rakovnicko - Kladenská pahorkatina. Nadmořská výška území se pohybuje od 196 m do 693 m. Převážná část oblasti tvoří pahorkatina s nadm. výškou 300 až 500 m. Pro oblast 9 je charakteristický malý podíl vodou ovlivněných půd, vysoký podíl kambizemí různých subtypů, často úzce vázané na specifické půdotvorné substráty. Nejčastějšími půdními typy jsou kambizem typická oligotrofná a mezotrofní (26,7 % a 21,2 %) a kambizem luvická oligotrofná (16,2 %). Klimaticky se HC řadí do okrsku B1 charakterizovaném jako mírně teplá a suchá oblast s mírnou zimou. V závislosti na nadmořské výšce se údaje z existujících meteorologických stanic o průměrné letní teplotě v oblasti pohybují zhruba od 7.0 0C do 8.2 0C, údaje o průměrných úhrnech ročních srážek kolísají mezi 463 mm a 569 mm a vegetační doba trvá zhruba 162 až 147 dnů. Základní charakteristika vegetačních poměrů je zachycena v následující Tab. 2.

Tabulka 2 Zastoupení souborů lesních typů na analyzovaném LHC

soubory lesních typů																										
IVS	stanovištní řada																									
	extrémní			kyselá				živná				obohacená				oglejená		podmáčená		Sa %						
	X	Z	Y	M	K	N	I	S	F	C	B	W	H	D	A	J	L	U	V	O	P	Q	T	G	R	
9																										
8																										
7																										
6																										
5					+	+		+						+				+	+	0,1			0,1		0,3	
4					1,6	+		0,7												0,3	0,2		0,2		3,0	
3		+	+	0,9	15,2	0,9	9,5	13,6	0,2	0,4	1,0		2,9	1,1	2,0	0,5	0,7	0,6	0,3	1,5	2,2	0,1			53,8	
2	0,1	0,4	0,1	1,6	10,5	+	7,3	3,0		4,2	0,3		0,8	0,6	0,3		0,1		0,3	0,6	0,6	0,5	+	0,1	31,5	
1	+	0,6		2,3	+					0,2							+						0,2	0,2	3,5	
0		0,2		1,9	3,9														0,7	0,4	0,7	0,1	+		7,9	
Σ	0,1	1,2	0,2	6,8	31,4	1,0	16,8	17,4	0,2	4,9	1,4		3,7	1,7	2,3	0,5	0,8	0,6	0,6	2,9	3,4	1,4	0,4	0,6	100,0	
	1,5			55,8				27,5				4,5				2,0		7,7		1,0		100,0				

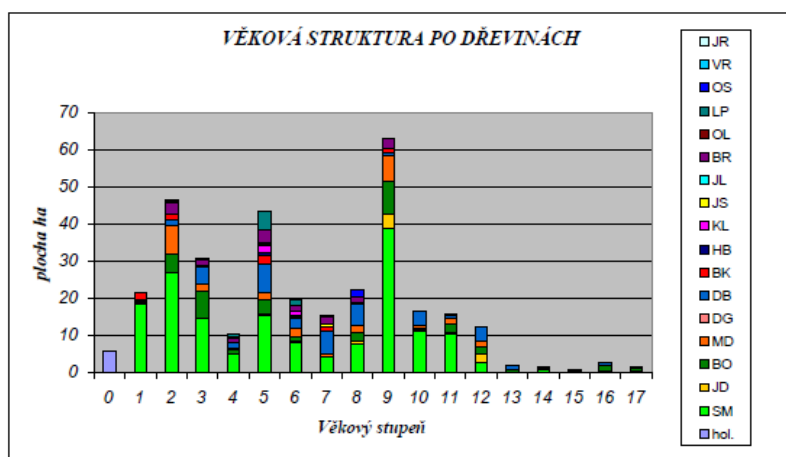
Nejčastějšími stanovištními řady jsou kyselá a živná s těžištěm výskytu v 2. a 3. lesním vegetačním stupni (bukovo-dubovém a bukovo-dubovém). K souborům lesních typů s vyšším zastoupením patří

soubory 2K a 3K, 3I a 3S. Pokud vezmeme v úvahu převažující výskyt oligotrofních nebo mezotrofních půd, dá se konstatovat, že větší část území je produkčně spíše slabší nebo jen průměrná.

Všechny porosty vyskytující se na referenčním HC patří do kategorie lesů hospodářských. K hlavním cílům vlastníka lesa patří snaha pěstovat a obnovovat udržitelný les, využívat přirozenou obnovu porostů, obnovní těžbu provádět zejména tam, kde to příroda naznačuje a udržovat poměrně dobrý zdravotní stav a hygienu lesa.

V současné dřevinné skladbě na referenčním HC dominují jehličnaté dřeviny, jejichž podíl tvoří 73,7 %, zatímco podíl listnatých dřevin tvoří 26,3 %. Nejzastoupenější dřevinou je smrk (50,6 %), pak dub a borovice (12,7 % a 11,5 %). Za nimi následuje modřín (8,5%) a buk a jedle (2,8 % a 2,7 %). V dřevinné skladbě pro zalesnění dominuje smrk ztepilý. Podíl jehličnatých dřevin v předpisu zalesnění činí 69,0 %, podíl listnatých dřevin pak 31,0 %. Až 23,3 % podílu na zalesnění má buk, což je odraz snahy vnášet zpevňující příměs do převážně smrkových porostů.

Na referenčním celku se nachází celkem 290 porostů s celkovou výměrou 350,54 ha. Z nich 261 porostů (291,4 ha) má na počátku optimalizace věk, který zajišťuje jejich vstup do optimalizace výchovy nebo obnovy v průběhu následujících 30 let. Věková struktura porostů na LHC a úplný přehled druhů dřevin účastnících se dřevinné skladbě lesa je zobrazen na obr. 6.



Obrázek 6 Věková struktura a dřevinné složení lesa na referenčním HC

Rozpětí bonit, modální bonita a modelové zásoby dřeviny na ha očekávané ve věku 100 let (orientační začátek obnovy) podle nejzastoupenějších dřevin jsou uvedené v Tab. 3.

Tabulka 3 Charakteristika produkčních poměrů referenčního HC

Dřevina	Zastoupení	Rozpětí bonit	Modální bonita	Zásoba na ha ve věku 100 let (mod. bonita)
Smrk	50,6	18-34	26	450

Dub	12,7	14-32	22	300
Borovice	11,5	16-28	24	240
Modřín	8,5	22-38	28	475
Buk	2,8	16-28	26	350
Jedle	2,7	20-30	24	490

Na HC se nevyskytují výraznější škody biotickými ani abiotickými činiteli. Menší škody způsobuje zvěř na kulturách, okusem trpí zejména listnáče, ale i jehličnaté dřeviny. Celkově lze ale říci, že porosty jsou v dobrém zdravotním stavu. Nejčastějším škodlivým činitelem je vítr. Největší škody vznikly při větrné kalamitě v roce 1990. Vedle mimořádné síly větru se na vzniku polomu podílela i vnitřní stabilita porostů, prostorové rozmístění porostů, terénní podmínky a půdní vlhkost. Naprostá převaha polomu vznikla v předmýtních smrkových porostech na kyselých stanovištích, na kterých je smrk v půdě poměrně dobře zakotven. Zde byla příčinou polomu malá vnitřní stabilita porostů. Vítr podobné síly není v této oblasti častý, přesto je ale potřeba na toto nebezpečí smrkové porosty připravit.

3.3.2 Vytvoření databáze porostů a výpočet indikátorů plnění ekosystémových služeb na porostní úrovni

Optimalizovaný soubor porostů je tvořen 17 dřevinami, z nichž jenom menší část porostů má stejnorodý charakter a většina představuje směs. Absolutní výškové bonity daných dřevin se pohybují v rozmezí 14-38, takže referenční soubor se vyznačuje poměrně velkou rozmanitostí produkčních podmínek. V daných porostních a produkčních podmínkách se počítá se zahájením obnovy porostů v souladu s platnými modely hospodaření a doba zahájení výchovy je stanovena do věků, kdy v souladu s předpoklady platných RT dojde poprvé k tvorbě objemu hroubí bez kůry.

Na podkladu iniciálních informací o dřevinách, věku a bonitě v optimalizovaných porostech na začátku optimalizace je možné pro každý porost v seznamu identifikovat průnikové věky optimalizace a pro tyto věky v databázi rRT vyhledat očekávané hodnoty základních indikátorů plnění ES podle jednotlivých systémů výchovy nebo obnovy.

Ze základních indikátorů se při zohlednění skutečného zakmenění a stavu zásoby v iniciálním věku na začátku optimalizačního období dopočítaly výšky zásob a objemu výchovných a obnovních těžeb v průběhu optimalizačního období a rovněž hodnoty kompozitních indikátorů plnění kulturních služeb (indexu rekreace) a biodiverzity. Příklad výsledků kvantifikace indikátorů plnění ES pro vybraný porost a vybraný výchovný systém je zobrazen v Tab. 4.

Tabulka 4 Finální hodnoty kompozitních indikátorů na úrovni jednotlivého porostu (porost 169A/5, vých. systém 1)

Porost	Výchovný systém	Dřevina	Zásoba ¹ m ³ .ha ⁻¹	Suma pod. porostů ² m ³ .ha ⁻¹	Index SDIr	Index Ir	Index B
169A	1	Dub	97.8	65.6	0.282	0.391	5.804
		Smrk	86.8	31.5	0.176	0.409	6.595

Borovice	22.2	19.3	0.069	0.397	5.953
Porost	206.8	116.4	0.528	0.399	6.152

¹hodnoty vázané na poslední průnikový věk optimalizačního období ²hodnota získaná jako suma hodnot jednotlivých průnikových věků za celé optimalizační období

Výsledky za celý porost jsou, v souladu s metodikou Sedmák et al. (2016), stanovené buď jako součty dřevinných indikátorů (při indikátorech vázaných na plochu, jako je zásoba, objem probírek nebo index hustoty porostů SDI_r) nebo jako vážený průměr (při indikátorech vázaných na jednotku optimalizace, jakými jsou index estetiky a rekreace I_r nebo index biodiverzity B).

3.3.3 Generování iniciální populace hospodářských plánů a dopočet hodnot indikátorů plnění ekosystémových služeb na úrovni lesního celku

Generování iniciální populace rozmístění jednotlivých systémů těžeb podle jednotlivých porostů bylo učiněno výběrem optimálního systému v porostu za pomoci objektivizační funkce L2 s idealistickými úrovněmi plnění plného spektra ES a náhodně určenými vahami indikátorů plnění (kap. 3.2.4) sériově aplikovaného v každém porostu v optimalizovaném souboru.

Pod plným spektrem ES se rozumí všechny ES (produkční, regulační a socio-kulturní služby a ekologická stabilita lesa) a všechny indikátory jejich plnění - zásoba dřeva V , objem těžeb V_{tez} , index relativní hustoty lesa SDI_r , index estetiky lesa a rekreace I_r a index biodiverzity B pro 30 letou délku optimalizace.

Po vytvoření iniciální populace HP se přistoupilo k odvození indikátorů plnění všech ES za celý HC dle jednotlivých HP. Dopočet indikátorů za HC byl při veličinách vázaných na plochu (zásoba a objem těžeb na ha) proveden jako suma součinů hodnot zásob a těžeb na hektar a výměr porostů. Při veličinách vázaných na porost jako základní jednotku optimalizace (indexy SDI_r , I_r , B , H / D) se údaj za celý HC vypočítá jako suma součinů hodnot indikátorů a výměr jednotlivých porostů vydělená celkovou výměrou HC. Výsledkem celé operace jsou pak vektory hodnot indikátorů plnění ES pro všechny HP tvořící nultou generaci řešení, která je v dalším postupu předmětem paralelního vylepšování (šlechtění).

3.3.4 Multikriteriální evoluční optimalizace iniciální populace hospodářských plánů a výběr uživatelsky preferovaného multikriteriálně optimálního plánu

Iniciální řešení/plány z náhodně vygenerované populace byly heuristicky iterativně vylepšovány modifikovaným evolučním algoritmem NSGA-II využívajícím cyklické operátory matečné selekce, křížení, mutace a výběru elity pomocí rychlého nedominovaného třídění až po dosažení předdefinovaného počtu zdokonalujících generací (100 generací).

Matečná selekce byla v příkladové aplikaci realizována turnajovou binární selekcí, v níž se kvalita dvojice porovnávaných plánů posuzovala primárně pořadím nedominované fronty, ke které plány patřily nebo sekundárně na základě skóre multikriteriální užitečnosti. Křížení bylo aplikováno ve formě uniformní výměny náhodného počtu a délky sekvencí seznamů systémů těžeb podle jednotlivých porostů tvořících dvojici mateřských hospodářských plánů náhodně vybraných matečných selekcí. Nové plány generované křížením procházely vzápětí procesem mutace, při kterém pravděpodobnost mutace

(záměny) systému na jiný náhodně vylosovaný systém v konkrétním porostu byla nastavena v souladu s běžnou praxí na hodnotu 1/261.

Pro každý nově navrhovaný plán byly vypočteny hodnoty indikátorů plnění ES za celý HC a bylo stanoveno skóre multikriteriální užitečnosti. Pokud nově odvozený plán vykazoval skóre multikriteriální užitečnosti lepší než lepší plán z mateřské dvojice, nový plán byl akceptován. V opačném případě byl postup turnajové selekce, křížení a mutace opakován, pokud nebylo dosaženo vylepšené dceřiné řešení nebo pokud nebyl dosažen předdefinovaný maximální počet iterací šlechtění (1000). Celý proces šlechtění byl opakovaně používán, pokud nedošlo k vytvoření nové dceřiné populace plánů o rozsahu 100.

V dalším kroku pak došlo ke spojení mateřské a dceřiné generace plánů, čímž vznikla přechodná kombinovaná populace 200 plánů. Dočasná populace byla vytvořena zejména kvůli zachování nejkvalitnějších, elitních plánů mateřské populace. Výběr elity v dočasné populaci se provádí za pomoci řazení řešení rychlým třídícím algoritmem. Třídění se provádí na základě přiřazení každého plánu dočasné populace k nedominované frontě s určitým pořadím a v rámci téhož pořadí se plány seřazují podle skóre multikriteriální užitečnosti. Přitom platí, že multikriteriálně kvalitnější řešení se vyznačují nízkým pořadím nedominované fronty v kombinaci s malou hodnotou multikriteriální užitečnosti. Selektce elity znamená výběr 100 nejlepších plánů ze spojené populace a to bez ohledu na to, zda se jedná o plány pocházející z původní, mateřské populace nebo jsou to plány z nové, dceřiné populace.

Po výběru elitních plánů se postup cyklicky opakoval, přičemž elitní plány z předešlého kroku sloužily jako mateřská populace v následujících iteracích. Celkový počet iterací/generací řešení byl nastaven kvůli výpočetní zvládnutelnosti a dobré praktické upotřebitelnosti postupu na 100 generací. V průběhu optimalizace se tak pracovalo ze 100 iniciálních plánů iterativně 100 krát modifikovanými a vylepšenými, takže celkově došlo k prověření 10 000 různých plánů, z nichž vznikla finální generace 100 elitních plánů.

Plán s nejlepší, minimální hodnotou objektivizační funkce tj. minimálním skóre multikriteriální užitečnosti z terminální elitní generace se považuje za finální, multikriteriálně optimální plán nejlépe reflektující preference rozhodovatele nebo skupiny rozhodovatele ohledně plnění ekosystémových služeb jako cílů optimalizace.

3.3.5 *Výsledky optimalizace*

Výsledky heuristické evoluční optimalizace výchovy a obnovy lesa na vybraném HC podle jednotlivých modelových typů rozhodovatele spolu s průměrnými výsledky uniformní aplikace jednotlivých systémů těžeb a výsledky sériové optimalizace jednotlivých porostů podle postupu navrženého autory Sedmák et al. (2016) je obsažen v tabulce 5.

Pod jednotnou aplikací systémů těžeb se chápe simulování použití jednoho systému jednotně ve všech porostech vyskytujících se na HC. Vzhledem k faktu, že předdefinovaných bylo 36 systémů, došlo k postupnému prověření všech a k zprůměrování jednotlivých získaných výsledků.

Pod sériovou optimalizací jednotlivých porostů se chápe výběr systému na základě porostních indikátorů a za pomoci specifikované objektivizační funkce v každém porostu zvlášť, bez kontroly indikátorů plnění ES za celé HC (Sedmák et al. 2016). Indikátory plnění ES za celé HC se při této formě optimalizace počítají pouze jednou, na konci optimalizace, po obdržení seznamu individuálně optimálních systémů podle jednotlivých porostů.

Efektivita aplikace určitého systému těžeb jednotně ve všech porostech, resp. sériové optimalizace jednotlivých porostů byla vyhodnocena stejnou rozhodovatelsky neutrální objektivizační funkcí, která byla použita při 6. modelovém typu rozhodovatele (Lesník). Požadované úrovně plnění ES při sériové porostní optimalizaci byly vyhledány jako maximální hodnoty porostních indikátorů křížem přes systémy a porosty.

Tabulka 5 Porovnání výsledků různých metod optimalizace výchovy a obnovy lesa

Rozhodovací situace	Zásoba porostu m ³	Těžba m ³	Index			Optimalizační skóre U
			SDIr	Ir	B	
Idealistický vektor křížených úrovní	101712	24933	1.108	0.464	10.090	
Uniformní těžba (průměr)*	89140	12752	0.856	0.401	8.764	0.261
Sériová optimalizace jednotlivých porostů	96800	17994	1.070	0.447	9.826	0.129
EMO optimalizace						
Ekonom I	95783**	21468	0.995	0.414	9.577	0.075
Ekonom II	89576	24321	0.943	0.419	9.425	0.061
Environmentalista	96149	19501	1.059	0.438	9.741	0.065
Občan	91780	20849	1.017	0.446	9.638	0.059
Ochranář	93382	21357	1.021	0.433	9.861	0.051
Lesník	93028	22404	1.014	0.431	9.681	0.079

* tlustějším písmem jsou vyznačené případy, které mají optimalizační skóre získané optimalizační funkcí se stejnými vahami a jsou tedy přímo porovnatelné, ** červenou barvou jsou vyznačené hodnoty dvou nejvíce preferovaných indikátorů, tlustější červená označuje nejvíce preferovaný indikátor

Případy zvýrazněny hrubším černým písmem jednoznačně dokazují multikriteriální převahu obou optimalizačních postupů nad postupem, kdy by ve všech porostech na definovaném HC byl aplikován jeden výchovný nebo obnovený systém, tj. kdyby všechny porosty byly jednotně vychovávány nebo obnovovány některým z 36 prověřovaných systémů, bez jakékoliv optimalizace. Multikriteriální skóre užitečnosti sériové optimalizace vycházející z úrovně jednotlivého porostu je o 51 % menší v porovnání s průměrným optimalizačním skóre uniformní těžby, multikriteriální skóre EMO optimalizace (rozhodovatel Lesník) zaměřené na celý soubor porostů (HC) překonává průměrný výkon uniformních aplikací až o 70 %.

Menší hodnoty *U* indikují, že vektor indikátorů plnění ES dosažený v rámci optimalizace leží blíže k idealistickým požadovaným maximům a tedy obě optimalizace zaručují lepší plnění plného spektra

ES. To je dobře vidět i na přímém srovnání hodnot indikátorů, kde vidíme, že cílové vektory indikátorů obou optimalizací dominují jednotnému cílovému vektoru. To znamená, že hodnoty libovolného indikátoru jsou při obou optimalizacích (porostní i EMO) větší ve srovnání s hodnotami indikátorů dosažených při uniformní aplikaci, což při snaze o maximalizaci plnění jednoznačně dokladuje lepší plnění uvažovaných ES.

Porovnáme-li podle logiky Pareto dominance cílové vektory obou vyvážených optimalizací (sériová porostní optimalizace vs. EMO-rozhodovatel Lesník), vidíme, že navržené hospodářské plány jsou vzájemně nedominované. To znamená, že některé hodnoty indikátorů jsou větší při sériové optimalizaci (např. indikátor zásoba) a některé zase při EMO optimalizaci (např. objem výchovné těžby).

Přesto pokud sledujeme výsledné skóre multikriteriální užitečnosti U , v souladu s teoretickým očekáváním zjišťujeme, že EMO optimalizace orientovaná na celý HC překonává sériovou porostní optimalizaci při vzájemném srovnání o 40 % (+20 % navíc k vylepšení dosaženému sériovou optimalizací vůči uniformní těžbě). Další vylepšení multikriteriálního skóre U dosažené při EMO optimalizaci lze připsat zejména výraznějšímu vylepšení indikátoru těžba, který je výrazně lepší jako při sériové porostní variantě. To vede k podstanému zmenšení U a to i přesto, že hodnoty ostatních indikátorů jsou při EMO optimalizaci mírně horší.

Efekt různého typu rozhodovatele prakticky se projevující na různých vahách plnění jednotlivých cílů použitých v objektivizační funkci lze dobře studovat zejména na hodnotách jednotlivých indikátorů, protože hodnoty multikriteriálního skóre jsou ve všech případech poměrně podobné. Všechny skóre U jsou velmi malé, výrazně překonávají sériovou optimalizaci a blíží se k ideální nule, která by znamenala absolutní shodu dosaženého cílového vektoru s idealistickým vektorem. Velké rozdíly jsou však v kombinacích hodnot indikátorů, jakými jsou poměrně podobné U dosahované.

Zde jednoznačně vidíme, že postup EMO optimalizace primárně maximalizuje hodnoty indikátorů, kterým příslušný typ rozhodovatele přikládá vyšší důležitost (v Tab. 5 jsou indikátory považovány příslušným rozhodovatelem za nejdůležitější zvýrazněny červeně). Ze srovnání hodnot indikátorů mezi různými rozhodovateli je skutečně vidět, že rozhodovatelé kladoucí důraz na výši zásoby dřeva a hustotu lesa (ekonom I a environmentalista) se vyskytují nejvyšší hodnoty příslušného indikátoru, zatímco ostatní indikátory jsou ve srovnání s jinými rozhodovateli průměrné nebo o něco horší.

Podobně rozhodovatelé kladoucí důraz na maximalizaci plnění biodiverzity a ekologické stability lesa a plnění sociálních ES (např. ochránář a Občan) dosahují vyšší hodnoty indikátorů biologické rozmanitosti a rekreačního indexu a zároveň nižší hodnoty ve srovnání s ostatními rozhodovateli. Ve všech případech jde o vzájemně Pareto nedominovaná řešení, která dobře ilustrují, že množina multikriteriálně optimálních hospodářských plánů je vždy enormně rozsáhlá (prakticky nekonečná) a záleží zejména na rozhodovateli, jeho potřebách, zkušenostech a znalostech, kterou multikriteriálně optimální kombinaci plnění ES osobně preferuje.

Nejdůležitějším faktem vyplývajícím z Tab. 5 je skutečnost, že odůvodněně můžeme očekávat, že aktuální systém hospodářsko úpravnického plánování těžeb založen na použití 2-3 nejběžnějších

systemech alokovaných do jednotlivých porostů vysloveně empiricky a induktivně, bude dosahovat hodnoty multikriteriální užitečnosti na sledovaném HC někde mezi uniformních hodnotou a sériovou porostní optimalizací.

Z toho pak vyplývá, že plnění ES na uvažovaném HC dosahované při dnešním systému plánování je ze skutečně multikriteriálního pohledu v nejlepším případě suboptimální. Mnohem pravděpodobnější je však situace, že dnešní hospodaření je plně neoptimální, neboť aktuální plánování se výrazně více podobá uniformní variantě vyplývající ze sériové aplikace porostní multikriteriální optimalizace podle metodiky Sedmák, Marušák, Kašpar (2016).

Všechny tyto skutečnosti naznačují, že zavedení postupů multikriteriální optimalizace do lesnického plánování může po důkladném empirickém ověření obecně vést ke skutečné implementaci principů funkčně integrovaného hospodaření do každodenní lesnické praxe.

3.4 Softwarová podpora optimalizace

Navržený optimalizační postup vyžaduje použití běžných databázových prostředků (Microsoft Access), tabulkový procesor (Microsoft Excel) pro přípravu údajů a naprogramování algoritmu v libovolném programovacím jazyce (C +, Delphi, Visual Basic, Pascal apod.) pro automatizaci samotné optimalizace.

4 Srovnání novosti postupů

Základním rysem nové metodiky je posunutí obecného plánování na vyšší úroveň. Dosavadní plánování výchovných těžeb má charakter induktivního expertního, do značné míry subjektivního plánování vycházejícího z úrovně jednotlivého porostu. Informace na úrovni HC jsou jen derivátem expertních rozhodnutí provedených v jednotlivých porostech a získávají se jednoduchou kompilací. Plánování obnovních těžeb je pak ve většině případů plánování těžeb v hospodářských lesích čistě deduktivní, také nezahrnující jiné než produkční aspekty. Plnění ES služeb za HC tedy není při současném plánování přímým předmětem optimalizace. Optimalita plánu na úrovni HC se sice předpokládá, ale reálně není ověřitelná.

Nový postup má charakter objektivní, počítačem podporované multikriteriální optimalizace na požadované cílové úrovni celého hospodářského celku. V průběhu optimalizace dochází k automatizovanému zpracování, objektivnímu vyhodnocení a syntéze takového počtu terénních měření a z nich odvozených informací, který přesahuje rozumové možnosti kteréhokoliv individuálního plánovacího experta.

Výběr a naplánování výchovy nebo obnovy na HC se týká přesně definovaného časového horizontu, přizpůsobí se výchozímu stavu porostů, vychází z objektivních údajů inventarizace lesa a hlavně při plánování simultánně bere v úvahu kvantifikované plnění právě definovaného spektra ekosystémových služeb. Vyšší kvalita poskytnutých řešení je tak do značné míry dána právě zpřesněním kvantifikovaného stanovení cílů hospodaření. Nový postup se neopírá o množinu kvalitativně

definovaných pravidel, empirických zkušeností, znalostí a subjektivních úsudků plánovací autority aplikovaných na úrovni jednotlivých porostů, ale objektivně a racionálně vyhledává hospodářský plán optimální vůči požadovanému stavu lesa na definovaném území.

Na základě kvantifikace lze ohodnotit kvalitu různých navrhovaných plánů před jejich aplikací a dá se exaktně kontrolovat multikriteriální optimalita vybraného plánu v průběhu jeho praktické realizace. S tím úzce souvisí vyšší adaptivita nového plánovacího systému, který umožňuje v průběhu plánovacího horizontu průběžný monitoring plnění ES na úrovni HC a v případě odklonu od definovaného cílového stavu umožňuje operativní úpravu vybraného plánu výchovy a obnovy lesních porostů.

Díky využití růstového simulátoru se nový postup vyznačuje značně vyšší flexibilitou ve srovnání s klasickými postupy založenými na použití RT. Plány hospodaření získávají možnost naplánovat hospodaření při libovolné délce plánovacího horizontu, mohou citlivě reagovat na změny klimatu a environmentu, dokáží částečně zohlednit efekty disturbancí, jsou otevřené pro aplikaci nových vědeckých poznatků apod.

Avšak asi největší výhodou a inovací nového postupu oproti staršímu plánování je umožnění objektivního zohlednění názorů a potřeb jednotlivého člověka nebo různých společenských skupin zúčastněných na stavu lesa a výsledků hospodaření v něm.

Aktuální postup plánování vychází z představy, že celospolečenské požadavky na les jsou nadřazené nad zájmy jednotlivce nebo zájmy určitých skupin. Současně se předpokládá, že ekologické podmínky, dřevinné složení, zdravotní stav a aktuální ekologická stabilita lesa předurčují (nezávisle na vůli a potřebách individuálního člověka) jeho možné funkční zaměření a tím i možné cíle hospodaření. V lesích zaměřených primárně na produkci dřeva se zároveň předpokládá, že hospodaření vedoucí k trvalému a plnému využití produkčních možností stanoviště musí zákonitě vést i k optimální ekologické stabilitě a plnění všech ostatních funkcí lesa.

Při takovém pohledu se teoreticky za ideální považuje vyvážené, funkčně integrované hospodaření na větších územních celcích, které se v praxi uskutečňuje prostřednictvím kategorizace lesa. V důsledku toho plánování v lese představuje striktně předepsaný postup realizovaný plánovacími experty taxačních kanceláří, který prakticky nezohledňuje individuální potřeby vlastníka lesa anebo dalších společenských skupin a nepočítá s jejich podstatnějším vstupem do procesu plánování.

Výsledkem je plán, který z ekonomického hlediska vlastníkovi lesa definuje výšku přípustného zisku z těžby a zavádí celou řadu dalších omezení ohledně forem a možností využívání jeho majetku, které se stávají obzvláště nepříjemnými, pokud jde o drobného vlastníka lesa. Současně plán pouze v omezené míře reflektuje i měnící se názory dalších skupin obyvatelstva (jakými jsou profesionální ochránci přírody, nezávislá občanská sdružení, obyvatelé regionu, podnikatelé, turisté, rekreatanti ap.) a jejich rostoucí nároky na plnění regulačních a kulturních služeb či ochranu přírody a tvorbu krajiny, v níž žijí. Následným efektem je pak častá nespokojenost samotného vlastníka lesa nebo i dalších zúčastněných skupin obyvatelstva s plánem a rostoucí intenzita konfliktů mezi nimi.

V této souvislosti nová metodika plánování výchovy a obnovy dovoluje ve stanoveném časovém horizontu dosahovat multikriteriálně optimální stav lesa při zohlednění potřeb a vůle jednotlivce anebo zainteresovaných skupin. Kromě plně vyvážených, uživatelsky neutrálních forem hospodaření přibližně odpovídajícím dnešním plánovacím postupům, nová metodika v případě potřeby dovoluje naplánovat i cíleně orientované hospodaření zaměřené na posilování určitých ES, vše v závislosti na potřebách a osobních preferencích zúčastněných osob.

Plánování výchovy a obnovy lesa tak může být založeno na participativním rozhodování připouštějící možnost konsenzuálního vyvážení protichůdných zájmů různých skupin dotčených hospodařením v lese na sledovaném území. Takovýmto způsobem je pak potenciálně možné dosáhnout celospolečenské (občanské) dohody o prioritách a postupech hospodaření v lese a celkové spokojenosti zainteresovaných stran.

5 Popis uplatnění certifikované metodiky

Certifikovaná metodika najde své uplatnění při optimalizaci výchovy a obnovy lesních porostů na určitém hospodářském celku a to jak při taktickém, tak i při strategickém plánování hospodaření v lese. Metodika má potenciální využití zejména pro tvorbu lesního hospodářského plánu, tvorbu strategických modelů hospodaření, výhledů výchovných a obnovních těžeb, tvorbu různých scénářů těžeb, dále při plánování výchovných a obnovních zásahů v průběhu platnosti lesního hospodářského plánu nebo v průběhu obmýtlí.

Její hlavním cílem je zajištění trvalosti a maximalizace produkce dřeva, ale i plnění ostatních mimoprodukčních ekosystémových služeb, vše podle potřeb vlastníků lesa a jiných subjektů zainteresovaných na hospodaření v lese. Vlastník lesa ve spolupráci s ostatními zájmovými stranami (stát, odborný lesní hospodář, taxační kancelář, orgány státní ochrany přírody, občanská sdružení, ...) si může stanovit zásoby dřeva, výchovné a obnovní těžby, očekávanou úroveň biodiverzity a další priority podle multikriteriálního cíle, který má pro konkrétní soubor porostů (neboli hospodářský celek) stanovený, a zajistit tak soulad v plnění funkcí lesa.

Metodika je tedy určena pro vlastníky lesů, taxační organizace, projektové kanceláře, výzkumné organizace a všechny instituce, které se zabývají hospodářskou úpravou a plánováním na různých úrovních. Taxační kancelář může tento metodický postup využít při tvorbě lesního hospodářského plánu k analýzám vývoje výchovných a obnovních těžeb zařizovaného celku. Pro taxační kanceláře to může být konkurenční výhoda při výběru dodavatele zpracování lesního hospodářského plánu. V neposlední řadě je metodika využitelná pro účely výzkumu a výuky.

6 Ekonomické aspekty

Vzhledem k dlouhé produkční době lesních porostů a není možné přesně specifikovat ekonomické vyjádření výnosů nebo ušetření nákladů v krátkodobém nebo dlouhodobém horizontu. Zvýšení výnosů z optimalizované produkční funkce nebo plnění ekosystémových služeb v podobě výnosů z výchovné těžby a nákladů na její realizaci jsou závislé na věkové struktuře a druhové skladbě lesního majetku. Z tohoto pohledu je velice těžké vyjádřit ekonomické přínosy v absolutních jednotkách.

Uplatnění metodického postupu optimalizace výchovné a obnovní těžby, přináší uživateli metodiky především zvýšení efektivity jejich plánování. Z analýz případových studií vykonaných autory metodiky vyplývá, že tato efektivita je v průměru o 50 % vyšší oproti současnému stavu. Vychází to především z vyjádření plnění ekosystémových služeb a očekávaného zvýšené stability lesních porostů. Vyčíslení ve finančních jednotkách závisí na rozsahu hodnoceného území a jeho věkové struktuře. V rámci plánování obnovní těžby se se na základě námi vykonaných případových studií zvýšená efektivita projeví zvýšením těžeb až o 25 % oproti stavu, kdy se těžby umísťují bez podpory rozhodovacích postupů.

Vzhledem k absenci jakékoliv exaktní podpory plánování výchovné a obnovní těžby v současné hospodářsko-úpravnické praxi z pohledu optimalizace produkční funkce ve vztahu k ekosystémovým službám, použití metodiky přinese uživateli lesa pozitiva, kterých ekonomické vyjádření bude možné až s odstupem času. Zvýšení stability porostů jako jedné z charakteristik prezentovaných v metodice, zajistí bezpečnou produkci, což se výrazně projeví i v ekonomických ukazatelích. Pomocí představených postupů je možné vytvořit těžební bloky, pomocí kterých by pak bylo možné snížit i náklady na těžební činnost a dopravu vytěženého dříví. Úspora závisí na již zmíněné velikosti a věkové struktuře lesního majetku a může se pohybovat až do 40 – 50 %. Dalším nepřímým ekonomickým přínosem je zvýšení reálnosti dosažení naplánované těžby, čímž se podpoří reálnější plánování investičních akcí na lesním majetku.

Pomocí představených postupů multikriteriální optimalizace je možné vytvořit soubory porostů s různou preferencí cílů hospodaření (jenom produkční, jenom ES, nebo kombinace), což je rovněž nepsorným přínosem pro ekonomiku hospodaření na lesním majetku.

Předpokládá se, že uživatelé metodiky mají k dispozici a běžně využívají výpočetní techniku. Se zavedením a aplikací metodiky nejsou proto spojeny žádné jiné další náklady.

Použitá literatura

Branke, J., Deb, K., Miettinen, K., Słowiński, R. (Eds.) 2008. Multiobjective optimization (Interactive and evolutionary principles). Lecture Notes in Computer Science, Springer, Berlin-Heidelberg-NewYork: 480 s.

Brodrechtová, Y., Navrátil, R., Sedmák, R., Tuček, J., 2016. Using the politicized IAD framework to assess integrated forest management decision-making in Slovakia. Land Use Policy, <http://dx.doi.org/10.1016/j.landusepol.2016.10.015>, article in press

Bruña-García, X., Marey-Pérez, M.F. 2014. Public participation: A need of forest planning. *iForest-Biogeosciences and Forestry*, 7 (4): 216–226.

Clark, P.J., Evans, F.C., 1954. Distance to nearest neighbor as a measure of spatial relationships in populations. *Ecology* 35, s. 445-453.

Černý, M., Pařez, J., Malík, Z. 1996. Růstové a taxační tabulky hlavních dřevin České republiky [smrk, borovice, buk, dub]: Příloha č. 3 vyhlášky Ministerstva zemědělství č. 84/1996 Sb. o lesním hospodářském plánování [částka 28/1996 Sbírky zákonů]. Jilové u Prahy : Ústav pro výzkum lesních ekosystémů, 245 s.

Davis, L.S., Johnson, K.N., Bettinger, P.S., Howard, T.E. 2001. Forest management - to sustain ecological, economic and social values. 4th end. New York: McGraw-Hill, 804 s.

K. Deb, S. Agrawal, A. Pratap, T. Meyarivan. 2000. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. In M. Schoenauer et al., editors, *Parallel Problem Solving from Nature (PPSN VI)*, Springer, Berlin: 849–858.

Deb, K., Sindhya, K., Hakanen, J. 2017. Multi-Objective Optimization. In: Sengupta, RN., Gupta, A., Dutta, J. (Eds.) *Decision Sciences: Theory and Practise*, Taylor & Francis Group, USA., 1026 s.

De Jong, KA. 1975. An analysis of the behavior of a class of genetic adaptive systems. Ph. D. thesis, University of Michigan: 105 s.

Fabrika, M., 2005: Simulátor biodynamiky lesa SIBYLA, koncepcia, konštrukcia a programové riešenie. Habilitačná práca. Technická univerzita vo Zvolene, 238 s.

Fabrika, M., Ďurský, J., 2005: Stromové rastové simulátory. EFRA -Vedecká agentúra pre ekológiu a lesníctvo, Zvolen, 112 s.

Fabrika, M., Pretzsch, H. 2013: *Forest Ecosystem Analysis and Modelling*. Technical University in Zvolen, Zvolen, 620 pp.

Goldberg, D.E. 1989. *Genetic Algorithms for Search, Optimization, and Machine Learning*. Addison-Wesley: Reading, 1989.

Hahn W.A., Knoke T. 2010. Sustainable development and sustainable forestry: analogies, differences and the role of flexibility. *European Journal of Forest Research*, 129 (5): 787-801.

Halaj, J. 1985. Kritické zakmenenie porastov podľa nových rastových tabuliek. *Lesnícky časopis*, 31(4): 267 – 276.

Halaj, J., Petráš, R., Sequens, J. 1986. Percentá prebierok pre hlavné dreviny. *Lesnícke štúdie*, 40, Bratislava: Príroda, 99 s.

- Halaj, J., Grék, J., Pánek, F., Petráš, R., Řehák, J. 1987. Rastové tabuľky hlavných drevín ČSSR. Bratislava: Príroda, 362 s.
- Jaehne, S., Dohrenbusch, A. 1996. A method to evaluate forest stand diversity. *Forstwissenschaftliches Centralblatt* 116 (1-6): 333-345.
- Kangas, A., Kangas, J., Kurttila, M. 2008. Decision support for forest management. Berlin: Springer, 222 s.
- Konôpka, J. 2010. Od produkcie k multifunkčnému využívaniu lesných ekosystémov. *Forestry Journal*, 2 (1): 81-92.
- Kulla, L., Bošľa, M., Burgan, K. 2010. Potreba a možnosti inovácie rámcového plánovania HÚL na Slovensku. In: *Súčasnosť a budúcnosť hospodárskej úpravy lesov na Slovensku*. Zvolen: Národné lesnícke centrum: 42-49.
- Lotov, A.V., Bushenkov, V.A., Kamenev, G.K. 2004. Interactive Decision Maps. Approximation and visualization of Pareto frontiers, Kluwer Academic Publishers: 307 s.
- Marušák, R., Kašpar, J., Vopěnka, P. 2015. Decision Support Systems (DSS) optimal—A case study from the Czech Republic. *Forests*, 6(1): 163-182.
- Midriak, R. 1981. Differentiated forest management according to integrated functions. Príroda, Bratislava, 224 p.
- Papánek, F. 1978. Teória a prax funkčne integrovaného lesného hospodárstva. Príroda, Bratislava, 218 s.
- Millennium Ecosystem Assessment 2005. Ecosystems and Human Well-Being: Current State and Trends. Island Press, Washington, DC.
- Pielou, E. C. 1975. Ecological diversity. John Wiley and Sons, New York: 348 s.
- Pretzsch, H. 1992. Konzeption und Konstruktion von Wuchsmodellen für Rein- und Mischbestände. *Forstliche Forschungsberichte München*, Nr.115, 358 s.
- Pretzsch, H., Biber, P., Ďurský, J. 2002. The single tree-based stand simulator SILVA: construction, application and evaluation. *Forest Ecology and Management* 162: 3-21.
- Reineke, L.H. 1933. Perfecting a stand density index for even-aged forests. *Journal of Agricultural Research*, 46 (7), s. 627-638.
- Reynolds, K.M., Twery, M., Lexer, M.J., Vacik, H., Ray, D., Shao, G., Borges, J.G., 2008: Decision Support Systems in Forest Management. In: Frada Burstein and Clyde W. Holsapple (Eds.): *Handbook on Decision Support Systems 2 - Variations International Handbooks Information System 2*, Berlin Heidelberg, Springer: 499-533.
- Sedmák, R., Fabrika, M., Bahýľ, J., Pôbiš, I., Tuček, J., 2013: Application of simulation and optimization tools for developing forest management plans in the Slovak natural and management conditions. In: Tuček, J., Smreček, R., Majlingova, A., Garcia – Gonzalo, J. eds. *Implementation of DSS tools into the forestry practice: reviewed conference proceedings*. Zvolen: Technical University in Zvolen: 139-152.

Sedmák, R., Marušák, R., Kašpar, J. 2016. Metodika funkčně integrované optimalizace výchovy na úrovni lesního porostu na taktické a strategické úrovni plánování. Praha: Česká zemědělská univerzita v Praze: 42 s.

Srinivas, N., Deb, K. 1995. Multi-objective function optimization using non-dominated sorting genetic algorithms. *Evolutionary Computation*, 2 (3): 221-248.

Tuček, J., Sedmák, R., Majlingová, A., Sedliak, M., Marques, S. 2015. Decision support systems in Slovak forestry planning: a review/Systémy na podporu rozhodovania v lesníckom plánovaní na Slovensku: prehľad. *Forestry Journal*, 61(1): 19-30.

Zitzler, E., Laumanns, M., Bleuler, S. 2004. A tutorial on evolutionary multiobjective optimization. *Computer Engineering and Networks Laboratory*, Zurich: Swiss Federal Institute of Technology Zurich, 32 s.

Seznam publikací předcházejících metodice

Biber P., Borges J. Moshammer R., Barreiro S., Botequim B., Brodrechtová Y., Brukas V., Chirici G., Cordero-Debets R., Corrigan E., Eriksson L., Favero M., Galev E., Garcia-Gonzalo J., Hengeveld G., Kavaliauskas M., Marchetti M., Marques S., Mozgeris, G., Navrátil R., Nieuwenhuis M., Orazio C., Paligorov I., Pettenella D., Sedmák R., Smreček R., Stanislovaitis A., Tomé M., Trubins R., Tuček J., Vizzarri M., Wallin I., Pretzsch H., Sallnäs O., 2015: How Sensitive Are Ecosystem Services in European Forest Landscapes to Silvicultural Treatment?. *Forests*, 6(5):1666-1695.

Kašpar J., Hlavatý R., Kuželka K., Marušák R., 2017: The Impact of Assumed Uncertainty on Long-Term Decisions in Forest Spatial harvest Scheduling as a Part of Sustainable Development. *FORESTS*, 8:335

Kašpar J., Marušák R., Bettinger P., 2016 Time Efficiency of Selected Types of Adjacency Constraints in Solving Unit Restriction Models. *FORESTS*, 7(5):102-116.

Kašpar J., Marušák R., Sedmák R., 2016: Spatial considerations of an area restriction model for identifying harvest blocks at commercial forest plantation . *Lesnický časopis (Forestry Journal)*, 62(3):146-151.

Kašpar J., Marušák R., Hlavatý R., 2015 A Forest Planning Approach with Respect to the Creation of Overmature Reserved Areas in Managed Forests. *FORESTS*, 6(2):328-343.

Marušák R., Kašpar J., Hlavatý R., Kotek V., Kuželka K., Vopěnka P., 2015 Alternative Modelling Approach to Spatial Harvest Scheduling with Respect to Fragmentation of Forest Ecosystem. *Environmental Management*, 56(5):1134-1147.

Marušák R., Kašpar J., Vopěnka P., 2015: Decision Support Systems (DSS) Optimal—A Case Study from the Czech Republic. *FORESTS*, 6(1):163-182.

Vopěnka P., Kašpar J., Marušák R., 2015: GIS tool for optimization of forest harvest-scheduling. *Computers and Electronics in Agriculture*, 2015(113):254-259.

Kašpar J., Marušák R., Sedmák R., 2014: Spatial and non-spatial harvest scheduling versus conventional timber indicator in over-mature forests. *Lesnický časopis (Forestry Journal)*, 60(2):81-87.

Marušák R., Kašpar J., 2015: Spatially-constrained harvest scheduling with respect to environmental requirements and silvicultural system. *Lesnický časopis (Forestry Journal)*, 61(2):71-77.

Sedmák R., Scheer L., Marušák R., Bošeľa M., Sedmáková D., Fabrika M., 2015: An Improved Weisse's Rule for Efficient Estimation of Stand Quadratic Mean Diameter. *Forests*, 6(8):2545-2559.

Sedmák R., Scheer L., 2015: Properties and prediction accuracy of a sigmoid function of time-determinate growth. *IForest*, 2015(8):631-637.

Tuček J., Sedmák R., Majlingová A., Sedliak M., Marques S., 2015: Decision support systems in Slovak forestry planning: a systematic review. *Lesnický časopis (Forestry Journal)*, 61(1):19-30.