

ČESKÁ ZEMĚDĚLSKÁ UNIVERZITA V PRAZE

FAKULTA LESNICKÁ A DŘEVAŘSKÁ

KATEDRA OCHRANY LESA A ENTOMOLOGIE



VLIV VYBRANÝCH OBRANNÝCH OPATŘENÍ NA POPULAČNÍ RŮST

LÝKOŽROUTA SMRKOVÉHO:

APROXIMACE POMOCÍ NELINEÁRNÍ REGRESE

DIPLOMOVÁ PRÁCE

Autor: Mgr. et Bc. Ondřej Průcha

Vedoucí práce: doc. Ing. Jaroslav Holuša, Ph.D.

2013

„Prohlašuji, že jsem diplomovou práci na téma Vliv vybraných obranných opatření na populační růst lýkožrouta smrkového: aproximace pomocí nelineární regrese vypracoval samostatně pod vedením doc. Ing. Jaroslava Holuši, Ph.D., a použil jen prameny, které uvádím v seznamu použitých zdrojů.

Jsem si vědom, že zveřejněním diplomové práce souhlasím s jejím zveřejněním dle zákona č. 111/1998 Sb., o vysokých školách v platném znění a to bez ohledu na výsledek její obhajoby.“

V Plzni dne 15.dubna 2013

Poděkování

Děkuji svému školiteli, panu doc. Ing. Jaroslavu Holušovi, Ph.D., za obětavé metodické vedení, za možnost podílet se na výzkumných projektech i za poskytnutý datový materiál týkající se populační dynamiky lýkožrouta smrkového a jeho regresorů ve vybraných výzkumných lokalitách. Můj vřelý dík patří i dalším pedagogickým a vědecko-výzkumným pracovníkům z FLD ČZU v Praze a FBMI ČVUT v Praze, bez jejichž kvalifikované a kreativní metodické pomoci by předložená diplomová práce mohla jen stěží vzniknout. Stejně tak jsem zavázán všem známým i neznámým kolegům, podílejícím se na terénním sběru i kamerálním předzpracování nezbytných dat, z nichž moje práce vycházela. V neposlední řadě děkuji své rodině a kolegům v zaměstnání, jejichž podpory a pochopení si velmi vážím.

Abstrakt

Předložená práce nově zavádí do regresních modelů pro aproximaci populační dynamiky lýkožrouta smrkového nelinearity typu necitlivosti kolem nuly. Tím jsou mimo jiné získány zpřesněné hodnoty indexů determinace vybraných regresorů. Tyto indexy determinace jsou poté uplatněny při výpočtu parametrů modelu predikce předpokládaného objemu kůrovcových těžeb v následujícím roce. Použitý matematický prediktor je přitom zkonstruován na bázi algoritmů PID (PSD) regulátorů pro zpětnovazební automatizované řízení dynamických systémů. Tím je dosaženo zcela nového přístupu k aproximaci populační dynamiky lýkožrouta a rovněž tak ke kvantifikaci vybraných obranných opatření. Vyvinuté modely byly úspěšně uplatněny ve dvou lokalitách (Opava-Hlubočec 2005-2009, Opava-Pustá Polom 2002-2009).

Klíčová slova:

Lýkožrout smrkový, *Ips typographus* L., populační dynamika, regresní model, nelineární regrese, pásmo necitlivosti kolem nuly, PID regulace, PSD regulace, apriorní odhad, predikce.

Abstract

This thesis introduces the regression model for approximation of the spruce bark beetle population dynamics nonlinearity type of insensitivity around zero. Apart from other things determination indexes refined values of selected regressors are obtained. These determination indexes are then put into effect in the calculation of the model parameters prediction of estimated bark beetle output volume in the following year. Used mathematical predictor is constructed on the basis of PID (PSD) controller algorithm for automated feedback control of dynamic systems. This provides a completely new approach to the approximation of bark beetle population dynamics, as well as the quantification of selected defensive measures. The developed models have been successfully applied in two locations (Opava-Hlubočec 2005-2009, Opava-Pustá Polom 2002-2009).

Key words:

Spruce bark beetle, *Ips typographus*, population dynamics, regression model, nonlinear regression, insensitivity around zero area, PID regulation, PSD regulation, a priori estimate, prediction.

Obsah:

Úvod.....	6
Obecné informace o lýkožroutu smrkovém.....	7
Matematická východiska.....	10
Materiál a metodika	16
Výsledky 1 – aplikace nelinearity v regresních modelech.....	21
Výsledky 2 – aplikace diskrétní PID regulace s parametry nelineárních regresních modelů – LS Opava Hlubočec.....	37
Výsledky 2 – aplikace diskrétní PID regulace s parametry nelineárních regresních modelů – LS Opava Pustá Polom.....	49
Diskuse	56
Závěr.....	58
Literatura	59

Úvod

Předložená práce si klade za cíl přispět dosud netradičním způsobem k matematickému modelování populační dynamiky lýkožrouta smrkového na základě znalosti některých faktorů, o kterých lze předpokládat, že tuto dynamiku ovlivňují. Na základě datového materiálu získaného z lokality LS Opava – Hlubočec v letech 2005 – 2009 byly pro tyto faktory – tzv. regresory vytvořeny nejprve lineární regresní modely, které byly následně modifikovány zavedením nelinearity typu necitlivosti kolem nuly pro vysvětlující i vysvětlovanou proměnnou. Ukázalo se, že tímto postupem lze vesměs zvýšit indexy determinace jednotlivých regresních modelů. Jako přínosná se rovněž projevila transformace vysvětlované proměnné v podobě rozdílu objemů kůrovcových těžeb ve dvou po sobě následujících letech (meziroční rozdíl), nahrazující dosud běžně používaný podíl, respektive logaritmus podílu těchto veličin. Uvedený přístup, spočívající v zavedení nové (tzn. rozdílové) transformace vysvětlované proměnné a zároveň v uplatnění nelineárních regresních modelů, zdůraznil absenci role časového vývoje v dosud používaných matematických výpočtech vycházejících výlučně z regresního modelování. S cílem zdokonalení aproximace populačního růstu lýkožrouta smrkového byl tudíž aplikován model zpětnovazebního řízení v uzavřené smyčce, vyvíjejícího se v diskrétním čase. Pro tento účel byly modifikovány algoritmy PID, resp. PSD regulátoru, které byly uplatněny s parametry získanými z předem vytvořených nelineárních regresních modelů. Tímto způsobem byla vypočítávána predikce objemu kůrovcových těžeb v následujícím roce. Vyvinutý predikční model byl uplatněn nejen na datech týkajících se lokality Opava-Hlubočec, ale vynikající výsledky poskytl i při simulaci s daty z další výzkumné lokality Opava-Pustá Polom. I přes značnou limitovanost uvedených modelů, která pramení především z nedostatku adekvátních vstupní dat, poskytuje vytvořená aproximace až nečekaně reálné výstupy a tím i značnou šanci dalšího rozvoje a přínosného uplatnění této metody, a to zejména pro účely kvantifikace vybraných obranných opatření.

Obecné informace o lýkožroutu smrkovém

Lýkožrout smrkový (*Ips typographus* L.), lidově nazývaný také jen „kůrovec“, je předmětem velkého množství ryze vědeckých prací, ale i častým tématem mediálních publikací a společenských debat. Ačkoliv jsou kůrovci obecně vnímáni jako škodlivý hmyz, jen velmi malá část druhů z této podčeledi se projevuje natolik agresivně, že je schopna napadat živé stromy a působit jejich zánik. Tyto druhy, zvláště pak zmíněný lýkožrout smrkový, mají ovšem značný ekonomický význam a to především v jehličnatých lesích severního boreálního a mírného pásu. Vzhledem k těmto ekonomickým a společenským souvislostem je lýkožrout smrkový již po řadu desetiletí intenzivně a všestranně studován. Je možno odhadnout, že z oblasti základního i aplikovaného výzkumu bylo publikováno až kolem 40000 prací (Matoušek, P., 2012).

Ontogenéze lýkožrouta smrkového není jednoduchá ani jednotná. V jednom požerku se obvykle nachází současně vajíčka, larvy i kukly. Stádium vajíčka trvá nejméně 6 – 18 dnů. Lýkožrout v této fázi nikdy nepřezimuje. Samička klade 1 – 2 vajíčka za den a za život naklade 20 – 100 vajíček, která pak ukládá v matečných chodbách do jednotlivých zářezů vzdálených 1 – 10 mm (Zumr, V., 1995). Produkce vajíček je závislá na teplotě, optimum je 29- 30°C; při teplotě pod 11,4 °C kladení ustává. Larvy se líhnou po 16-18 dnech a doba jejich vývoje je 6-50 dnů, dle toho, jak byla vajíčka kladena. Dospělá larva měří 5- 7 mm a vyhlodává tzv. larvové chodby. Zakuklená larva setrvává v tomto stádiu 6 – 17 dnů (Zumr, V., 1995; Matoušek, P., Modlinger, R., Holuša, J., Turčáni, M., 2012), průměrně 8 dnů. Následný zralostní žír dospívajícího jedince trvá pak 2 – 3 týdny. Dospělý brouk žije 2 – 3 měsíce, jednotlivě i déle. Bylo vypočteno, že celkový vývoj první generace lýkožrouta trvá 7-10 týdnů (Skuhřavý, V., 2002). Největší počet přezimujících brouků se nachází ve stádiu dospělého; z toho většina přezimuje pod kůrou napadených stromů – ležících i stojících, jen malá část v hrabance. Brouci svá zimoviště opouštějí při teplotách 18 – 20°C a nalétávají na další stromy. V našich podmínkách tomu bývá od poloviny dubna do průběhu května. Druhá generace tudíž může za příznivých podmínek realizovat své rojení již od poloviny června až do července a srpna. Za zvláště výhodných klimatických podmínek se uskuteční ještě 3. rojení. Kromě toho jsou častá i založení sesterských pokolení. Přitom rozptyl lýkožrouta může být značný, i když 90 % nových zamoření se objevuje ve vzdálenosti do 100 m od místa starého útoku (Becker, T., Schröter, H., 2000).

Při těchto předpokladech je zřejmé, že lýkožrout může způsobovat nedozírné ztráty, a to především na smrku ztepilém (*Picea abies*), jen vzácně na introdukovaných druzích smrků, na modřínu a zcela výjimečně na borovici nebo jedli (Skuhřavý, V., 2002). Kolonizaci zahajují jednotliví samci. Byla provedena řada výzkumů (Matoušek, P., 2012; Zumr, V., 1995; Lubojacký, J. 2012; Hlásny, T., Holuša, J., Turčáni, M. 2011), které měly za úkol objasnit, jakými mechanismy si tyto samci zvolí strom, který napadnou. I když byla snesena celá řada argumentů pro vliv chemických atraktantů hostitelské dřeviny, pro vliv zraťových podnětů, pro „náhodný výběr“ dřeviny i pro vliv dalších faktorů (Matoušek, P., 2012), není tento problém dosud zcela objasněn. Po zvolení hostitelského stromu začínají samci tvořit snubní komůrku a produkovat agregační feromon, který láká samice k páření a obě pohlaví k další kolonizaci. Zničení stromu však závisí na hustotě napadení i na odolnosti stromu, který se brání především uvolňováním pryskyřice z pryskyřičných kanálků během zavrtávání kůrovců do kůry. Lepkává pryskyřice představuje fyzickou bariéru a ve vyšších koncentracích jsou pryskyřičné terpeny pro lýkožrouta toxické; zároveň působí i repelentně.

Tradiční pojetí pěstování hospodářských lesů předpokládá, že v těchto lesích s krátkými vývojovými cykly, pravidelnými probírkami a pečlivým asanováním, vyklízením, resp. vyvážením vytěžených stromů, včetně včasných likvidačních důsledků živelných těžeb, lze udržet populaci lýkožrouta pod kontrolou. Na druhé straně převažující smrkové monokultury, silně podléhající antropogenním vlivům, vlivům přísušky, vlivům nízké hladiny spodní vody, monokultury s oslabenými stromy, příp. se stromy nevhodné provenience a s porosty otevřenými silnými probírkami a těžbami, mohou populační růst lýkožrouta příznivě ovlivňovat a působit napadání i zcela zdravých stromů.

Škody způsobené lýkožroutem, zvláště po jeho gradacích posledních let, jsou katastrofální. Např. v německém Národním parku Bavorský les bylo od roku 1992 do roku 2010 zničeno cca 1,5 mil. smrků na 3700 ha. Během kůrovcové kalamity na území Národního parku Šumava bylo jen v letech 1995-1998 zničeno přes 1 milion m³ dřevní hmoty (Heurich, M. Reinelt, A., Fahse, L., 2001; Krejčí, F., 2000), přičemž vzniklo minimálně 5400 ha mrtvého lesa nebo holin. V roce 2009 bylo v ČR celkem cca 2,6 mil. m³ kůrovcových těžeb.

Klasickým obranným opatřením v boji proti kůrovci je - stále zřejmě nejúčinnější - kladení stromových lapáků. Těmi se rozumí zdravý, odvětvený smrk o výčetní tloušťce min. 20 cm. Počet lapáků pro první sérii se určí z tzv. kalamitního základu, kterým je celkový objem stromů napadených kůrovcem, vytěžených v době od 1. srpna předešlého roku do 31. března roku následujícího. Vydělí-li se tento kalamitní základ [m³] průměrnou hmotností těchto stromů [m³], dostaneme počet kůrovcem napadených stromů. Jedna osmina z tohoto počtu definuje počet lapáků 1. série. Tyto lapáky musí být připraveny do 15. dubna. Lapáky se kladou též před 2. nebo před případným 3. rojením. Počet těchto lapáků se stanovuje dle intenzity jarního rojení: je-li slabé nebo střední, klade se jen polovina. Přitom za silné napadení se považuje více než-li 1 závrt / 1 dm² lapáku; střední stupeň je do 0,5 závrtu / 1 dm².

Stromové lapáky se využívají i pro zachycení sesterských pokolení po 1. nebo po 2. vlně rojení. Při zjištění silného napadení se pro tento účel klade 1/5 první série (jarní); při středním napadení 1/10.

Pokud byly zjištěny vylétlé kůrovcové stromy nebo lapáky, klade se za každý takový případ 1 lapák; v případě vyššího rizika 2 lapáky.

V případě, že je kůrovec zcela pod kontrolou (těžilo se méně než-li 1 m³ kůrovcového dřeva na 5 ha smrkových porostů starších 60-ti let), přesto se klade 1 lapák na 5 ha se zastoupením smrku 20% a vyšším ve stáří více než-li 60 let (jako kontrolní), popřípadě se volí pouze kontrola pochůzkami (Zumr, V., 1995).

Ochranu pomocí stromových lapáků vykazuje nepochybnou účinnost. Je však vykoupena obětováním značného počtu zdravých stromů a značnými ekonomickými náklady (těžba, následná nezbytná asanace), jakož i nároky na přírodní prostředí lesa (úbytek zdravých stromů, použití chemie pro asanaci). Proto je snaha nahrazovat stromové lapáky adekvátními opatřeními v podobě lapáků vytvořených jako „trojnožka“, tzn. ze tří čerstvých stromových výřezů o délce 1,5 – 2 m a tloušťce min. 20 cm (výjimečně možno min. 15 cm), v horní části pevně spojených, ošetřených (příp. i opakovaně) insekticidem a dále pak s feromonovou návnadou na vrcholu. Řada autorů

se zabývá účinností této formy obranného prostředí (Juha, M., Lukášová, K., Holuša, J., Turčáni, M., 2012; Juha, M., Turčáni, M., 2008) a dospívá k závěrům plné srovnatelnosti s klasickými stromovými lapáky. Pro účely naší práce nebudeme mezi klasickým lapákem a tímto obranným lapákem „trojnožkovým“, vybaveným feromonovou pastí, rozlišovat.

Norma ČSN 481000 od těchto uvedených obranných opatření nerozlišuje ani „stojící“ lapáky a dokonce ani feromonové lapače. Názory na feromonové lapače jsou však značně rozporuplné (Matoušek, P., 2012) a v naší práci je mezi sledované regresory vůbec nezařazujeme.

Populační dynamika lýkožrouta je velmi složitá (Matoušek, P., 2012) a závisí na řadě faktorů, mezi nimiž lze jmenovat nabídku potravy (smrkové porosty na nevhodných stanovištích, s nevhodnou proveniencí apod. a jejich následné oslabení), teplotu, vlhkost, hydrologické poměry, výši srážek, stanovištní poměry, polomy a jejich následky, vitalitu stromů, hustotu porostu, stáří porostu, půdní poměry, přítomnost škůdců a chorob stromů, vlivy emisí, následky chřadnutí lesů, následky defoliace stromů, ale též vztahy kompetice a konkurence týkající se samotného lýkožrouta a přítomnost a působení jeho predátorů, vliv chorob, kterým tento hmyz podléhá apod. Mnohé z těchto faktorů jsou velmi komplexní, složité, rozporuplné, vzájemně závislé a zároveň závislé na řadě dalších vlivů, silně zprostředkované, nebo málo průkazné. V běžné lesnické praxi jsou též obvykle stěží ovlivnitelné, přinejmenším v krátkodobém časovém horizontu; navíc nejsou podchytitelné nebo alespoň podchycené v dostupném datovém materiálu. V souvislosti s uskutečňovaným rozsáhlým výzkumem (Holuša, J., Lukášová, K., Lubojacký, J.: 2012; Holuša, J., Weiser, J., Žižka, Z.: 2009; Lubojacký, J. 2012; Matoušek, P., 2012; Matoušek, P., 2012) se tudíž v naší práci zaměříme jen na vliv objemu kůrovcových těžeb v předchozím roce, na vliv těžeb živelných (polomů) v minulém, resp. i předminulém roce, na vliv objemu vytěžených lapáků (ekvivalentní jejich počtu), na vliv objemu těžeb smrků napadených tracheomykózou (václavkou) a na vliv počtu dnů s přísuškem.

Matematická východiska

Lesnický výzkum uplynulých let umožnil shromáždit značné množství datového materiálu týkajícího se změn populační hustoty lýkožrouta smrkového, *Ips typographus* L., v různých lesních lokalitách České republiky. Studovaná období zahrnovala vesměs intervaly z prvního decenia tohoto století a pokrývala tak časové úseky dramatického přemnožení kůrovce. Tímto způsobem byla získána data spojená jak s mimořádnou populační dynamikou tohoto hmyzího lesního škůdce, tak i s dopadem řady intenzivně využívaných obranných opatření. Velké množství datového materiálu za uplynulé období je nepochybně cenným zdrojem informací. Vypreparováním těchto informací ze značně nepřehledných primárních dat se naskytá šance zpřesnění našich znalostí o populační dynamice kůrovce i šance objektivní kvantifikace příslušných obranných opatření. Ovšem získání těchto informací, z nich vyplývajících nových poznatků a rovněž tak praktických prognostických lesnických nástrojů je nemožné bez využití poměrně náročných matematických metod. Uplatnění těchto metod je náročné nejen matematicky, nýbrž i metodicky. Hrozí zde totiž riziko, že matematika, v našem případě zvláště matematická statistika, poskytne celou řadu výsledků, jejichž interpretace bude problematická, ne-li zavádějící, ačkoliv výpočetní postup bude zcela správný. Stejně tak se může stát, že pracně výpočetně získané výsledky budou vykazovat jen malý přínos k poznání, poněvadž skutečně cenné informace zůstaly i nadále skryty v nepřehledném a šumy zatíženém datovém materiálu. Čelit těmto rizikům je nutno účinným interdisciplinárním spojením nástrojů matematické statistiky a znalostí z oboru lesnictví případně i dalších oborů přírodovědy a techniky.

Zásadním matematickým nástrojem se při všech postupech ovšem jeví regresní analýza (Meloun, M., Militký J., 2004; Holík, M., 1999). V zásadě se jedná o označení statistických metod, pomocí kterých odhadujeme hodnotu jisté náhodné veličiny na základě znalostí jiných veličin. V našem případě půjde o využití regresní analýzy pro zjištění závislostí ve vybrané datové struktuře. Budeme se snažit odhadovat hodnotu jisté náhodné veličiny na základě znalosti jiných náhodných veličin:

$$Y = f(x_1, x_2, \dots, x_p, \beta_1, \beta_2, \dots, \beta_p) + \varepsilon$$

kde Y je náhodná závislá proměnná, tzn. „vysvětlovaná“, obecně vektor řádu n ,

x_1, x_2, \dots, x_p jsou náhodné nezávislé proměnné tzn. „vysvětlující“ čili regresory,

$f(x_1, x_2, \dots, x_p, \beta_1, \beta_2, \dots, \beta_p)$ je hledaná regresní funkce,

$\beta_1, \beta_2, \dots, \beta_p$ jsou parametry modelu a

ε je neodstranitelná ryze náhodná odchylka, chyba, chápána též jako šum.

Pro získání regresní funkce se nejčastěji používá tzv. „metody nejmenších čtverců“. Podstata této metody spočívá v proložení vhodné křivky

$$Y = f(x_1, x_2, \dots, x_p, \beta_1, \beta_2, \dots, \beta_p) + \varepsilon$$

danými body (uspořádanými datovými $(p+1)$ rozměrnými vektory). Maticový zápis:

$$Y = X\beta + \varepsilon,$$

kde X je matice vstupních proměnných, β je vektor regresních koeficientů (které budeme hledat) a ε je vektor náhodných chyb při měření závislosti Y na X .

Po rozepsání:

$$\begin{aligned} Y_1 &= \beta_1 x_{11} + \dots + \beta_p x_{1p} + \varepsilon_1 \\ Y_2 &= \beta_1 x_{21} + \dots + \beta_p x_{2p} + \varepsilon_2 \\ &\cdot \\ &\cdot \\ &\cdot \\ Y_n &= \beta_1 x_{n1} + \dots + \beta_p x_{np} + \varepsilon_n \end{aligned}$$

A opět v maticovém zápisu:

$$\begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{pmatrix} = \begin{pmatrix} x_{11} & \dots & \dots & x_{1p} \\ x_{21} & \dots & \dots & x_{2p} \\ \vdots & & & \vdots \\ x_{n1} & \dots & \dots & x_{np} \end{pmatrix} \begin{pmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_n \end{pmatrix} + \begin{pmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{pmatrix}$$

Uvedenou soustavu rovnic lze řešit jen při splnění řady podmínek, z nichž nejvýznamnější je plná hodnota matice X

$$h(X) = p$$

a nekorelovanost náhodných chyb. Metoda nejmenších čtverců je založena na minimalizaci sumy druhých mocnin odchylek (rozdílů) změřených, čili empirických a „vyrovnaných“, čili teoretických hodnot. Poněvadž tuto minimalizaci mají zajistit vhodně volené hodnoty parametrů β_i , je nutno pro jejich výpočet parciálně derivovat sumu druhých mocnin všech zmíněných odchylek $S(\beta)$ právě podle těchto parametrů β_i . Jelikož pracujeme s druhou mocninou odchylek, můžeme hovořit o „čtvercích“. (Tato interpretace vynikne zvláště názorně v lineárním jednorozměrném případě regresní přímky $y = ax + b$.) Pro náš obecný model lineární regrese řešení metodou nejmenších čtverců tudíž pro $j=1, \dots, p$ dostaneme:

$$\frac{\partial S(\beta)}{\partial \beta_j} = \frac{\partial}{\partial \beta_j} \cdot \sum_{i=1}^n (Y_i - \sum_{l=1}^p x_{il} \cdot \beta_l)^2 = 0$$

$$-2 \cdot \sum_{i=1}^n (Y_i - \sum_{l=1}^p x_{il} \cdot \beta_l) \cdot x_{il} = 0$$

$$\sum_{i=1}^n \sum_{l=1}^p \beta_l \cdot x_{il} \cdot x_{ij} = \sum_{i=1}^n Y_i \cdot x_{ij}$$

což lze zapsat maticově:

$$X^T X \beta = X^T Y$$

Tato soustava rovnic má vždy řešení, které však v případě hodnosti matice X menší než p

$$h(X) < p$$

nemusí být jednoznačné. Pokud však $h(X) = p$, (tzv. regresní model plný hodnosti), pak:

$$h(X^T X) = h(X) = p$$

a matice $X^T X$ je regulární a existuje k ní matice inverzní. Řešením normálních rovnic je tedy vektor parametrů β :

$$\hat{\beta} = (X^T X)^{-1} \cdot X^T \cdot Y.$$

Poněvadž jde o odhad těchto parametrů, byť nejlepší, značíme se stříškou ($\hat{\beta}$).

Z matematického hlediska by bylo nutno pomocí druhých derivací ještě ověřit, zda funkce $S(\beta)$ má v bodě $\hat{\beta}$ skutečně minimum. V této práci však do ryze matematické roviny nehodláme zasahovat. Řešení je navíc dokonale známo a postupy odvození jsou publikovány v množství (Holík, M., 1999; Meloun, M., Militký J., 2004).

Pokud se nám podaří lineární regresní model takto úspěšně vytvořit (v našem případě vycházíme rovnou z modelu regrese vícenásobné, tedy s více nezávislými proměnnými), pak se musíme ještě dále zabývat zhodnocením kvality tohoto modelu. Je dobře možné, že daný model existuje, vektor parametrů $\hat{\beta}$ byl úspěšně vypočítán, ale jeho informační hodnota regresního modelu je malá. Pro účel zhodnocení kvality regresního modelu se obvykle využívá výpočtu koeficientu (indexu) determinace R^2 :

$$R^2 = \frac{S_{y'}^2}{S_y^2}$$

kde $S_{y'}$ je rozptyl získaný z „vyrovnaných“, tedy teoretických hodnot a S_y^2 je rozptyl získaný z empirických, tedy skutečně zjištěných, změřených hodnot. Index determinace vyjadřuje míru závislosti vysvětlované proměnné Y na vysvětlující proměnné X ; konkrétně z kolika % se podařilo veličinu Y vysvětlit pomocí veličiny X . Druhá odmocnina z indexu determinace se nazývá index korelace a má význam analogický známému koeficientu korelace. Index determinace bývá ještě často výpočetně upravován parametry n a p , tedy počtem měření (n) a počtem vysvětlujících proměnných (p). Je-li $n \ll p$, což je žádoucí, se tato úprava v zásadě neprojeví. Nejistota, tedy nízká kvalita regresního modelu, však začne vzrůstat se snižujícím se počtem měření.

Již ze samotné hodnoty indexu determinace lze okamžitě vyčíst mnohé o kvalitě regresního modelu. Je možno však tento index též exaktně testovat na nulovou hypotézu a tím přesně zjistit na jaké hladině významnosti p se s našim regresním modelem nacházíme.

Tyto postupy, aplikované na poskytnutý datový materiál, nám obvykle dosti zakalí radost z vytvořeného lineárního regresního modelu, neboť jeho kvalita, a tím i jeho predikční a regulační použitelnost, nebývá často velká a navíc se lokalita od lokality mění. Shledáváme tak, že metoda nejmenších čtverců, byť je sama o sobě úžasným výplodem lidského intelektu a vše ostatní, co může být vybudováno v oboru regrese, na ní vždy bude více či méně stát, však zdaleka nezaručuje nalezení dokonale přijatelného modelu, a to jak z přírodovědného, tak i z ryze matematického hlediska.

Už na této úrovni přípravy vlastního zpracování datového materiálu je nutno zabývat se rovněž jeho průzkumnou analýzou. Z matematického pohledu je zapotřebí věnovat pozornost zvláště tzv. multikolinearitě, která znamená vážné porušení účinnosti metody nejmenších čtverců. Jedná se o to, aby matice $X^T X$ byla pozitivně definitní, čímž je rovnice pro výpočet parametrů $\hat{\beta}$ jednoznačně řešitelná. Stav, kdy tomu tak není, je právě označován jako multikolinearita. Multikolinearita zapříčiní, že determinant $X^T X$ je číslo blízké nule, popřípadě některá vlastní čísla matice $X^T X$ jsou blízká nule, z čehož plyne řada obtíží při hledání inverzní matice $(X^T X)^{-1}$. To dále ústí ve výpočetní nestabilitu odhadů parametrů $\hat{\beta}_i$, velké rozptyly a široké intervaly spolehlivosti, které prakticky vylučují jakoukoliv úspěšnou interpretaci vypočtených výsledků. Multikolinearita je obvykle důsledkem vysoké míry korelace mezi vysvětlujícími proměnnými (obvykle se za hraniční hodnotu považuje korelační koeficient 0,7 – 0,8). Přitom u mnoha vysvětlujících proměnných je v případě populační dynamiky kůrovce toto ohrožení velmi reálné a pravděpodobné (objem kůrovcových těžeb, objem živelných těžeb, trvání přísušků, síla bořivých větrů, ...). Nabízí se zde vysvětlení tohoto nežádoucího jevu prostřednictvím tzv. „skrytých“ proměnných, ke kterým z technických důvodů stěží pronikneme. Dynamika populace kůrovce je jistě řízena především prostřednictvím mechanismů záporné zpětné vazby (Holuša, J., Lukášová, K., Lubojacký, J.: 2012; Holuša, J., Weiser, J., Žižka, Z.: 2009), jako je např. vnitrodruhová konkurence. Bylo prokázáno, že počet larev klesá s rostoucí hustotou mateřských chodeb (Matoušek, P., Modlinger, R., Holuša, J., Turčáni, M.,

2012). Další zápornou zpětnou vazbou může být vliv přirozených nepřátel, který se s přibývajícím časem zvyšuje (Lukášová, K., Holuša, J., 2011). Naše modely však musí vycházet „pouze“ z převážně provozních údajů, které jsme schopni měřit, evidovat a následně vyhodnocovat.

Kromě „skrytých“ proměnných mohou kvalitu výsledného modelu dále narušovat jak nadbytečné, tak i zcela chybějící nezávislé, tedy vysvětlující proměnné (regresory). Vůbec celá problematika mnohonásobné regrese vyžaduje specifických postupů, z nichž nejběžnějším je standardní postup, tzv. „Enter“ (Holík, M., 1999). Tento postup je využíván tehdy, když chceme zjistit nejen to, jak velký podíl změn (variací) závisle proměnné je vysvětlen sledovanými nezávisle proměnnými, nýbrž rovněž to, jak velký vliv má každá z nezávisle proměnných na výslednou závisle proměnnou za předpokladu, kdy by ostatní nezávisle proměnné byly pod kontrolou a jejich vliv by byl tudíž potlačen. Výsledky se obvykle tabelují, viz vzorové uspořádání tabulky na následujícím obrázku:

Nezávisle proměnná	Koeficient lineárního regresního modelu β_i	Index determinace R^2	Hladina významnosti p

Obrázek 1:

Vzorové uspořádání tabulky pro posuzování kvality regresního modelu metodou „Enter“

Jiný postup, označovaný jako metoda postupného ukládání (Stepwise) ukládá nezávisle proměnné do regresního modelu postupně a kumulativně. Každý v pořadí další model se bude od předchozího lišit tím, že v něm bude o jednu nezávisle proměnnou více. Při tomto postupu bychom už měli mít určitou představu o vlivu jednotlivých vysvětlujících proměnných a přidávat je postupně od té nejvýznamnější. Pro tento účel se využívá jednoduchého korelačního koeficientu každé vysvětlující proměnné fungující samostatně. Po kumulativním vložení každé další potenciálně vysvětlující proměnné se kontroluje nárůst indexu determinace R^2 i hladina významnosti p . Pokud vysvětlující proměnná nesplňuje naše představy, ihned ji vyřadíme a tak postupně získáváme velmi kompaktní regresní model

Průzkumová analýza datového materiálu se ovšem neomezuje na uvedené postupy, nýbrž je nutno se zabývat i dalšími aspekty. Sem patří vyhledání a posouzení jakkoliv vybočujících dat. Pro tento účel je vhodné grafické vyjádření v podobě jednotlivých dílčích grafů v obvyklých kartézských souřadnicích. Snadno tak odhalíme hrubé chyby, ale i body s vysokým vlivem, stejně tak jako zásadní trendy a předpokládané korelační poměry. Přitom je často nutno volit případně různá měřítka a různá matematická vyjádření veličin. Různým matematickým vyjádřením veličin již vlastně vstupujeme na půdu jejich transformací, což znamená jednu z možností přechodu od lineárního k nelineárnímu modelu regrese při zadávání výhod matematického aparátu metody nejmenších čtverců.

Během grafické analýzy datového materiálu vystupuje do popředí problematika tzv. „vlivných bodů“, tedy empiricky (měřením) zjištěných hodnot (bodů), které budou mít na regresní model velký vliv. Mohou to být ovšem i hrubé chyby, které musíme

vyločit, ale i body s vysokou mírou informačního přínosu (tzv. „Golden points“). Tyto Golden points budeme hledat především v těch úsecích datového materiálu, který popisuje nárůst, vrchol a následnou depresi kúrovcové kalamity. Tyto body mají vysokou šanci rozšířit predikční schopnosti regresního modelu.

Naopak některé hodnoty (body) mohou mít jen velmi malou informační hodnotu, avšak mohou se vyskytovat ve značném počtu a tím celý model značně deformovat. V našem případě lze v této roli předpokládat právě taková měření (zajištění), která se budou týkat velmi nízkých hodnot vysvětlujících, resp. vysvětlovaných proměnných. V analogii s technickými systémy bychom mohli hovořit o „pásmu necitlivosti“ kolem nulových hodnot. Představíme si, že sledujeme rotující hmotné těleso na které působí řada vlivů uvádějících jej do otáčivého pohybu různé kruhové rychlosti, jejího vzrůstu či naopak brždění. Pokud je ovšem těleso v klidu, nebo se jen velmi pomalu odvaluje, pak ze změřených hodnot stěží uděláme smysluplné závěry o jeho dynamických setrvačných vlastnostech. Ze zákonitostí klasické fyziky je známo, že těleso má tendenci servat v klidu (nebo rovnoměrném ustáleném pohybu), pokud na něj nebude působit vnější síla, tedy vnější vysvětlující proměnná. Technická praxe navíc ukazuje, že v pohybových stavech blízkých nule se vzhledem k vůlím, tedy záporným rozměrovým tolerancím, resp. též v důsledku vlivu tření, se projevuje určitá „necitlivost“ tělesa k působení malých vnějších sil. Tento stav by bylo možno též ilustrovat řízením hodně opotřebovaného automobilu s vyviklaným volantem. Není důvodu se domnívat, že by se tyto obecné principy neměly uplatňovat i v přírodě, neboť představují jeden z prvků jednotného modelu kybernetického pojetí řízení živých systémů i strojů. Pak bychom ovšem měli odpovídající data racionálně eliminovat a tím náš regresní model významně zpřesnit. Přirozeně, že zavedením pásma necitlivosti regresní model delinearizujeme, tedy vytváříme již nelineární regresní model.

Uplatnění grafů při orientační průzkumné analýze dat nám zároveň dovolí odhalit tzv. vybočující pozorování (outliers), která se významně liší od ostatních vzhledem k ose y . Pomocí grafů lze rovněž odhalit tzv. extrémny (high leverage points), které se liší svým postavením vzhledem k ose x . Pokud zjistíme body významně odchýlené jak vzhledem k ose x , tak i vzhledem k ose y zároveň, jde obvykle buďto o hrubou chybu, nebo o případ multikolinearity.

Graficky lze posoudit i další nutnou podmínku uplatnění metody nejmenších čtverců, a to rozptyl. Hodnoty závisle proměnné Y mají mít pro všechna X konstantní rozptyl. Pokud tomu tak je, hovoříme o tzv. homoskedascitě. Ačkoliv pouhé grafické zhodnocení nelze považovat za matematicky exaktní, lze vzhledem k náhodnosti proměnných hovořit o pravděpodobné homoskedascitě, pokud se rozptyly nebudou lišit o více, než-li 50% (homogenita rozptylu).

Dosud jsme se nezmínili o zcela zásadním požadavku normalnosti, čili gausovosti statistického rozdělení všech uplatněných náhodných proměnných. Pokud není požadavek gausovosti vysvětlujících proměnných splněn, lze sice počítat, ale hrozí velká nepřesnost výsledků. Nejlepším řešením by bylo prozkoumat gausovost celého vícenásobného rozložení, ale v praxi je přijatelné se omezit na ověření každé proměnné zvlášť. I v případě, že normální rozdělení nebude splněno, zbývá nám ještě regulérní šance využití platnosti centrálního limitního teorému, který však striktně předpokládá dostatečně velký soubor dat. Při splnění této podmínky nemá porušení normality příliš vážné početní následky.

Materiál a metodika

Díky důkladnému a intenzivnímu sběru dat jsou pro různé časové intervaly pokrývající zhruba 1. decenium 21. století k dispozici primární data z celé řady lokalit v České republice. Na Fakultě lesnické a dřevařské České zemědělské univerzity v Praze jsou např. k dispozici údaje týkající se populačních hustot lýkožrouta smrkového z lokalit uvedených v následující tabulce (např. Holuša, J., Lubojacký, L., Knížek M., 2010).

Lokalita (Lesní správa, LHC)	Studované období	Populační hustota	Meteorologická stanice (nadmořská výška)
LS Hořice	1998 - 2007	nízká	Jičín (301 m)
LS Chvalšiny	2006 - 2010	vysoká	Vyšší Brod (595 m)
LS Ledec nad Sázavou	2007 - 2010	vysoká	Košetice (534 m)
Lesy města Písek	1998 - 2007	střední	Vráž u Písku (432 m)
LS Opava - Hlubočec	2004 - 2008	vysoká	Opava (272 m)
LS Opava – Pustá Polom	2001 - 2008	vysoká	Opava (272 m)
LS Ostrava	1998 - 2007	vysoká	Ostrava, Poruba (242 m)
LS Vítkov	2003 - 2010	vysoká	Červená u Libavy (750 m)
LS Vodňany - Helfenburk	1998 - 2010	střední	Temelín (500 m)

Tab. 1:

Lokality, studované období, populační hustota l. smrkového a nejbližší meteorologická stanice s její nadmořskou výškou. (Převzato: Holuša, J.: Zhodnocení několika území s podrobnou evidencí obranných opatření za účelem zhodnocení vlivu obranných opatření na populace kůrovce. Katedra ochrany lesa a entomologie FLD ČZU Praha)

Záznamy o těžbách a lapácích byly získány z lesohospodářské evidence, která bývá vedena centrálně na ústředí příslušné lesní správy. Realizované nahodilé těžby byly rozděleny podle podvýkonů nebo skupin podvýkonů (kůrovcová těžba a živelná těžba napadená kůrovci, václavková těžba – čili těžba tracheomykózní, živelná těžba kůrovci nenapadená, těžba lapáků).

Data byla vztažena k nejnižším evidenčním jednotkám prostorového rozdělení lesa, k porostním skupinám, u kterých lze předpokládat jednotnost stanovištních, prostorových, hospodářsko-úpravních i dalších faktorů. Jednotlivé porostní skupiny byly následně spojovány do větších celků. Toto spojování respektovalo jednak požadavek zachování vysoké míry homogenity stanovištních a porostových podmínek, jednak relativní uzavřenost takto vytvářených celků vůči populaci kůrovce. Tímto způsobem byly vylišeny segmenty o velikostech řádově desítek, případně až stovek hektarů, hostící určitou relativně uzavřenou kůrovcovou populaci. Ke každému takto vytvořenému segmentu byly přiřazovány veškeré sledované ukazatele, které sehrávají roli nezávislých, tedy vysvětlujících proměnných (regresorů) i proměnných vysvětlovaných (závislých), reprezentujících nezbytnou kůrovcovou těžbu. Spojením prostorově blízkých segmentů vznikla jednotně posuzovaná lokalita, shodná obvykle s příslušnou lesní správou, respektive lesním hospodářským celkem (LHC), viz tabulka č. 1

Studovány byly následující faktory:

- Kůrovcová těžba v roce k , vyjádřená jako evidovaný objem (m^3) smrkového kůrovcového dříví z nahodilých těžeb provedených v roce k .
- Živelná těžba v roce k , vyjádřená jako evidovaný objem (m^3) smrkového polomového dříví z nahodilých živelných těžeb provedených v roce k .

Poznámka: Je zřejmé, že z údajů evidovaných v určité posloupnosti let lze získat údaje vztahované k roku $k - 1$ (roku předešlému), popřípadě údaje k roku $k + 1$ (roku následujícímu), jsou-li však ještě v posloupnosti k dispozici.

- Tracheomykózní (václavková) těžba v roce k , vyjádřená jako evidovaný objem (m^3) smrkového dříví napadeného václavkou z nahodilých tracheomykózních těžeb provedených v roce k .
- Těžba lapáků v roce k , vyjádřená jako evidovaný objem (m^3) lapáků použitých v roce k ke kontrole, ochraně a obraně proti lýkožroutu smrkovému.
- Přísušek v roce k , vyjádřený jak počet dnů v roce k , ve kterých byl dvojnásobek hodnoty průměrné měsíční teploty ($^{\circ}C$) vyšší než-li měsíční úhrn srážek (mm).

Z databázového výpočetního hlediska jsou k dispozici data uspořádána tabulkově (MS Excel). Tato data jsou poté transformována zlogaritmováním (Holuša, J.: *Zhodnocení několika území s podrobnou evidencí obranných opatření za účelem zhodnocení vlivu obranných opatření na populace kůrovce. Katedra ochrany lesa a entomologie FLD ČZU Praha*). K tomuto kroku nepochybně vedlo jednak velké rozpětí mezi jednotlivými porovnávanými hodnotami výši těžeb (v rozsahu 3 – 5 dekadických řádů), jednak zavedený způsob hodnocení rychlosti populačního růstu kůrovce dle logaritmického vztahu:

$$R = \log N_t - \log N_{t-1} ,$$

kterým jsou oceňovány velké výkyvy v počtu jedinců v roce t (hodnota N_t) a v předchozím roce $t-1$ (hodnota N_{t-1}). Ze získaných dat však přirozeně nelze zjistit počty jedinců – ostatně tento úkol je v praxi vůbec neřešitelný. Roli veličin N_t , N_{t-1} tudíž sehrával objem kůrovcových těžeb v roce t , resp. $t-1$.

Takto uspořádaná a transformovaná data byla následně zpracována profesionálními statistickými programy (STATISTICA 9.0), čímž byly víceméně automaticky vytvářeny lineární regresní modely při využití regresí jednoduchých i vícenásobných. Dle očekávání nebyly výsledky získané pro jednotlivé lokality (lesní správy, LHC) jednotné; každá lokalita poskytovala možnost poněkud jiné interpretace vlivu vysvětlujících proměnných na proměnu vysvětlovanou (objem kůrovcových těžeb, resp. populační růst kůrovce počítaný z objemu kůrovcových těžeb ve dvou po sobě následujících letech). Výsledky převzaté z (Holuša, J.: *Zhodnocení několika území s podrobnou evidencí obranných opatření za účelem zhodnocení vlivu obranných opatření na populace kůrovce. Katedra ochrany lesa a entomologie FLD ČZU Praha*) uvádí tabulka č. 2. Pro jednotlivé lokality a pro jednotlivé faktory (čili vysvětlující, nezávislé proměnné) působící v roce k , respektive v roce $k - 1$, jsou uvedeny

vypočítané korelační koeficienty s objemem kůrovcové těžby v roce $k + 1$ (vysvětlovaná, čili závisle proměnná). Pro každý korelační koeficient je rovněž uvedeno, zda jeho hladina významnosti p je nižší než-li obvyklých 0,05 (tedy statistická signifikantnost na hladině $p = 0,05$), nebo zda je rovna či vyšší než-li 0,05 (tedy statistická nesignifikantnost na hladině $p = 0,05$). Hladina p přitom vyjadřuje riziko s jakým musíme počítat tvrdíme-li, že korelace mezi danou vysvětlující a vysvětlovanou proměnnou, vyjádřená s daným korelačním koeficientem, skutečně existuje. Z výsledků zpracování však není známa skutečná hodnota hladiny významnosti ani průběh zvolené korelační funkce.

Lokalita	Faktory						
	Kůrovcové dříví (t)	Polomové dříví (t)	Polomové dříví (t - 1)	Václavkové dříví (t)	Přísušek (t)	Počet lapačů (t)	Lapáky (t)
LS Hořice	-0,58	+0,16	-0,17		+0,29		-0,22
	$p < 0,05$	$p \geq 0,05$	$p \geq 0,05$		$p < 0,05$		$p \geq 0,05$
LS Chvalšiny	-0,66	+0,56	-0,31		-0,04		-0,61
	$p < 0,05$	$p < 0,05$	$p \geq 0,05$		$p \geq 0,05$		$p < 0,05$
LS Ledec nad Sázavou	-0,72	-0,16	-0,20		+0,07		-0,48
	$p < 0,05$	$p \geq 0,05$	$p \geq 0,05$		$p \geq 0,05$		$p < 0,05$
Lesy města Písek	-0,45	+0,19	+0,09		-0,56	+0,17	+0,17
	$p < 0,05$	$p \geq 0,05$	$p \geq 0,05$		$p < 0,05$	$p \geq 0,05$	$p \geq 0,05$
LS Opava - Hlubočec	-0,21	+0,09	+0,23	+0,28	+0,41		+0,01
	$p < 0,05$	$p \geq 0,05$	$p \geq 0,05$	$p < 0,05$	$p < 0,05$		$p \geq 0,05$
LS Opava – Pustá Polom	-0,49	-0,17	-0,09	+0,44	-0,43		-0,15
	$p < 0,05$	$p < 0,05$	$p \geq 0,05$	$p < 0,05$	$p < 0,05$		$p \geq 0,05$
LS Ostrava	-0,61	-0,44	-0,29		-0,57		-0,39
	$p < 0,05$	$p < 0,05$	$p < 0,05$		$p < 0,05$		$p < 0,05$
LS Vítkov	-0,45	-0,20	-0,13	+0,17	+0,66	-0,09	-0,44
	$p < 0,05$	$p \geq 0,05$	$p \geq 0,05$	$p \geq 0,05$	$p < 0,05$	$p \geq 0,05$	$p < 0,05$
LS Vodňany - Helfenburk	-0,49	+0,01	-0,09		+0,17	-0,31	-0,14
	$p < 0,05$	$p \geq 0,05$	$p \geq 0,05$		$p \geq 0,05$	$p < 0,05$	$p \geq 0,05$

Tab. 2:

Přehled korelačních koeficientů zkoumaných faktorů ve vztahu k populační dynamice lýkožrouta smrkového. Korelační koeficienty byly vypočteny pro obvyklou logaritmickou transformaci vysvětlujících proměnných a pro vysvětlovanou proměnnou vyjádřenou rovněž logaritmickou populační dynamikou lýkožrouta.

Z souhrnných výsledků získaných z jednoduché (jednonásobné) lineární regrese je patrné, že jednotlivé faktory (tedy jednotlivé vysvětlující proměnné) vykazují velké rozdíly a často dokonce pro různé lokality poskytují jak kladnou, tak i zápornou korelaci. Stav je ilustrován diagramem na obrázku č. 2. Tato skutečnost již sama o sobě budí určitou nedůvěru. Pouze kůrovcová těžba je ve všech lokalitách s populační dynamikou l. smrkového korelována záporně. Znamená to, že při vyšším objemu těžby

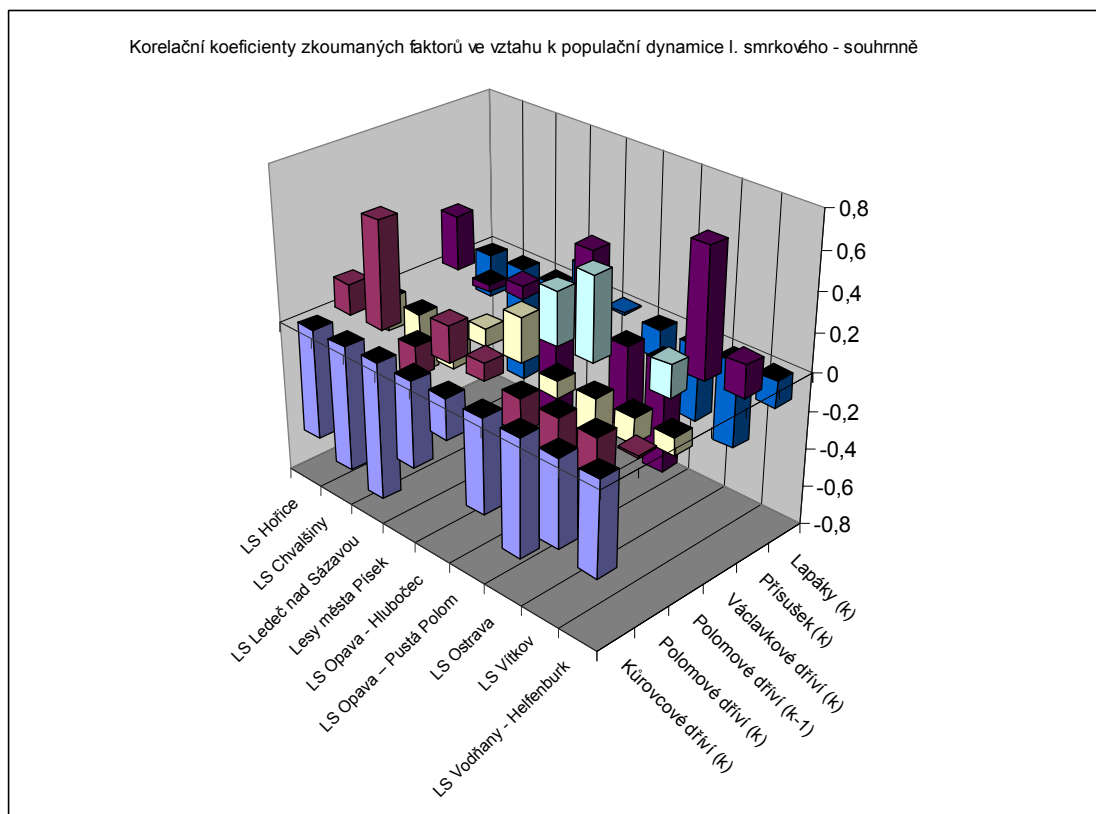
v daném roce lze očekávat nižší kůrovcové těžby v roce následujícím. Průměrné hodnoty koeficientů korelace pro jednotlivé vysvětlující proměnné udává následující tabulka č. 3:

	Faktory						
	Kůrovcové dříví (t)	Polomové dříví (t)	Polomové dříví (t – 1)	Václavkové dříví (t)	Přísušek (t)	Počet lapačů (t)	Lapáky (t)
Průměr	-0,52	0,00	-0,11	0,30	0,00	-0,08	-0,25
Sm.odchylka	0,14	0,27	0,16	0,11	0,41	0,20	0,24

Tabulka č. 3:

Průměry a sm. odchylky korelačních koeficientů pro všechny studované lokality

Vyšších hodnot korelace a přitom nízké směrodatné odchylky dosahuje pouze kůrovcové dříví a snad ještě dříví václavkové. Je zřejmé, že za těchto východisek je vytvoření jednotného regresního modelu, byť vícenásobného, úkolem již z principu dosti nesnadným.



Obrázek č. 2:

Korelační koeficienty zkoumaných faktorů ve vztahu k populační dynamice l. smrkového - souhrnně

Samotná aplikace standardních SW produktů pro výpočty z oboru matematické statistiky je jistě velmi významným a účinným nástrojem, jehož použití je však spojeno s řadou potencionálních potíží. Především uživatel, který není obvykle v roli matematika, ale přírodovědce – specialisty lesnického výzkumu, nemá možnost vidět jaksi „pod pokličku“ matematické konstrukce příslušného softwarového produktu, což

jej vede k pasivnímu přijímání výpočetního postupu, jakož i k pasivnímu přijímání jeho výsledků. Konkrétně mám na mysli to, že je uživateli příslušným SW „podsunut“ obvykle lineární regresní model, který nerespektuje skutečné přírodní zákonitosti, ve kterých je linearita spíše výjimečnou a nanejvýše lokálně omezenou skutečností. Dále pak jsou otázky signifikantnosti či nesignifikantnosti vypočtených výsledků vztahovány k jisté referenční hranici (obvykle $p=0,05$) a tak zůstává utajeno, zda hladina významnosti byla 0,049 (4,9% rizika, že vystavíme chybný závěr) nebo 0,051 / 5,1% rizika, že vystavíme chybný závěr). Přitom v prvním případě je výsledek označen jako signifikantní, ve druhém už jako nesignifikantním. Příroda však nezná takto ostrých hranic. Samotné logaritmování dekadickým logaritmem je v našem případě rovněž jen matematickou pomůckou, která usnadňuje porovnávání čísel lišících se o mnoho řádů, ale s vlastním přírodním procesem nikterak nesouvisí. Nejde zde totiž např. o vnímání světla nebo zvuku živými organismy, kdy (přibližně řečeno) desetinásobné zvýšení intenzity podnětu vyvolá jen dvojnásobné zvýšení vjemu, stonásobné zvýšení intenzity podnětu vyvolá jen trojnásobné zvýšení vjemu atd. Jakákoliv uměle zavedená transformace získaných dat však může práci s nimi sice usnadnit, ale také může zkomplikovat možnost odhalení skrytých vztahů, jakož i výslednou interpretaci výsledků.

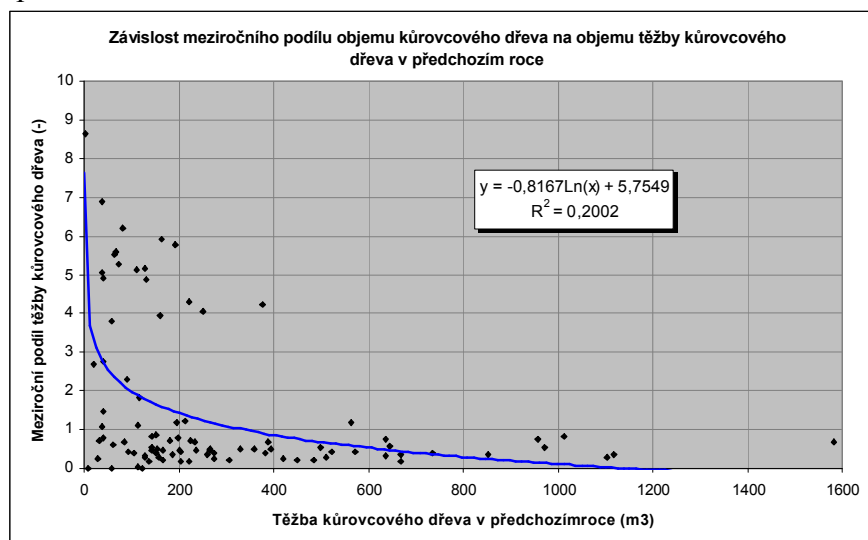
V neposlední řadě se domnívám, že zásadním problémem je rovněž hledat „pouze“ regresní model a nevnímat si regulační, čili řídicí dynamiky časově se vyvíjejícího procesu.

Ze všech těchto důvodů jsem se ve své diplomové práci rozhodl aproximovat populační růst lýkožrouta kůrovcového za využití prvků nelinearity při stanovení regresního modelu a zároveň klást důraz na modelování dynamického řídicího systému, který by mohl pomoci apriorně kvantifikovat efektivní obranná opatření.

Pro tento cíl jsem si zvolil data ze dvou lokalit (lesních správ) ležících nedaleko od sebe, a to Opava-Hlubočec a Opava-Pustá Polom. Na první z nich se pokusím splnit stanovený cíl sestavením regresního modelu s prvky nelinearity a zároveň konstrukcí dynamického řídicího systému, který by byl schopen, alespoň v prvním přiblížení, kvantifikovat potřebu základního obranného opatření, kterým je těžba kůrovcového dřeva, a to s apriorním odhadem na rok kupředu; po uplynulém roce pak s aposterionní korekcí odpovídající skutečným kůrovcovým těžbám (vysvětlovaná proměnná) i skutečným hodnotám dalších vysvětlujících proměnných, a tak dynamicky dále krok za krokem, kdy jeden krok je představován intervalem jednoho roku. Poté budu tento model aplikovat na druhou vybranou lokalitu a ověřím tak jeho funkčnost.

Výsledky 1 – aplikace nelinearity v regresních modelech

Jak bylo stanoveno v předešlé kapitole „Materiál a metodika“, budu se nejprve zabývat lokalitou představovanou Lesní správou Opava – Hlubočec. Jedná se v zásadě o nížinnou lokalitu dubového pásma, ve které je smrkový porost bezpochyby vnesen hospodářskou činností člověka. Setkáváme se zde s vysokou populační hustotou lýkožrouta smrkového indukující nezbytnost dosti vysokých kůrovcových těžeb, které by měly mít charakter včasné asanace napadených stromů a bránit tak vylétávání brouků nových generací. Současně tyto těžby vykazovaly ve sledovaném období pěti let 2004 – 2008 značně vysokou dynamiku, čili časové změny. Závažnosti ohrožení lesa kůrovcem odpovídala i obranná opatření. Vybraná lokalita je tudíž spojena s vysokým využíváním smrkových lapáků a tudíž i s významným objemem jejich těžby. Vybraná lokalita se rovněž vyznačuje i poměrně vysokými těžbami živelnými a zvláště pak vysokými těžbami tracheomykózními. Během sledovaného období byl zaznamenán též přísušek. Souhrnně lze prohlásit, že všechny sledované faktory, tedy vysvětlující proměnné, mohly ve sledovaném období působit s dostatečnou intenzitou i přiměřenou dynamikou, což by mělo vytvořit předpoklady pro vytvoření odpovídajícího regresního modelu i pro konstrukci dynamického řídicího systému. V dané lokalitě bylo vylišeno 23 segmentů s průměrnou plochou lesního porostu 55 ha. Nejprve však zaměříme pozornost na samotné kůrovcové těžby a jejich časový vývoj. Kůrovcové dříví přitom vystupuje ve dvou rolích: Jednak jako vysvětlující proměnná (v roce k) a jednak jako vysvětlovaná proměnná (v následujícím roce $k + 1$). Po uplynutí jednoho roku se objem kůrovcového dříví v tomto daném roce mění z vysvětlované opět na vysvětlující proměnnou a vysvětlovaná proměnná se posouvá dále o rok kupředu. Situaci můžeme pro názornost dále modifikovat tím, že jako vysvětlovanou proměnnou nebudeme uvažovat objem kůrovcového dříví v roce $k + 1$, nýbrž podíl objemu kůrovcového dříví v roce $k + 1$ ku roku k . Obdobně můžeme jako vysvětlovanou proměnnou zavést rozdíl objemu kůrovcového dříví v roce $k + 1$ minus objem kůrovcového dříví v roce k . Nezapomínáme, že ve shodě se zvyklostí vyjadřovat populační dynamiku pomocí logaritmů, můžeme studovanou vysvětlující i vysvětlovanou proměnnou vyjádřit logaritmicky. Tuto možnost však v souladu s výkladem v kapitole „Materiál a metodika“ opouštíme.




Graf č. 1:

Závislost meziročního podílu objemu kůrovcového dřeva na objemu těžby kůrovcového dřeva v předchozím roce – lokalita 1 (Lesní správou Opava – Hlubočec).

Graf č. 1 představuje závislost meziročního podílu objemu kůrovcového dřeva na objemu těžby kůrovcového dřeva v předchozím roce. Optimální regresní model je logaritmický, index determinace $R^2 = 0,20$ je vzhledem k očekávání dosti nízký.

Za této situace zavedeme do lineárního modelu první nelinearitu, představovanou pásmem necitlivosti kolem nuly. Poněvadž v roli vysvětlované proměnné vystupuje podíl, nezbyvá nám nic jiného, nežli zavést podíl necitlivosti kolem 1. Prakticky to znamená, že vyloučíme ta pozorování (měření), ty evidované výsledky, při kterých meziročně nedocházelo k větším změnám těžby kůrovcového dříví. Odpovídající interval zvolme (0,5 ; 2,0), čímž docílíme vyloučení případů, kdy meziroční změna v těžbě kůrovcového dřeva nebyla alespoň dvojnásobná. Výsledek zavedení nelinearity demonstruje graf č. 2:



Graf č. 2:

Závislost meziročního podílu objemu kůrovcového dřeva na objemu těžby kůrovcového dřeva v předchozím roce – po zavedení nelinearity (viz výklad v textu) – lokalita 1.

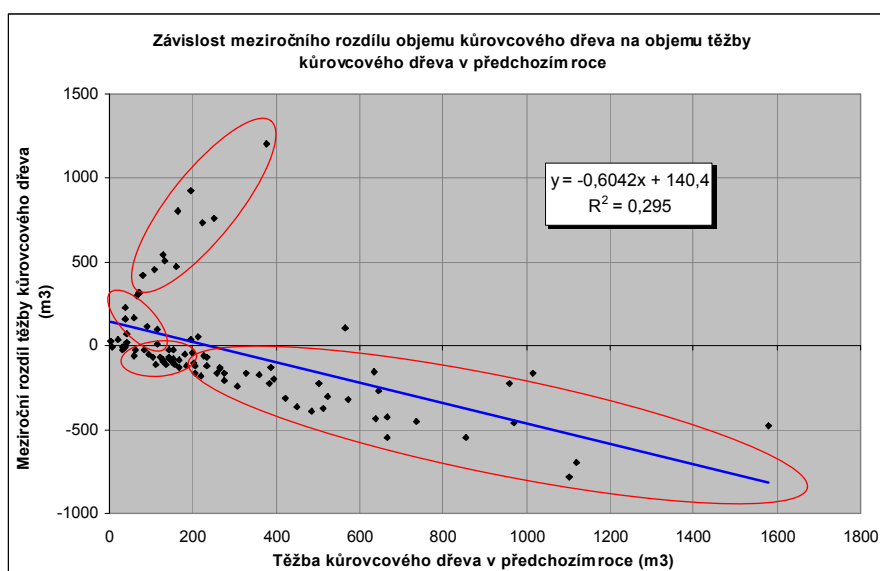
Optimální regresní model je opět logaritmický, ale ve vlastním grafickém vyjádření jsou patrné čtyři v zásadě odlišné oblasti (ohraňované červeně). Jedná se o oblast nízkých hodnot těžby kůrovcového dříví v předchozím roce, kdy v roce následujícím těžby ještě dále klesala, o oblast kdy se v předchozím roce těžilo málo kůrovcového dřeva, ale v následujícím roce jeho těžba musela radikálně narůst, o oblast, kdy byly těžby v předchozím roce vysoké, ale v následujícím roce významně poklesly a o oblast, kdy byly těžby v předchozím roce rovněž již dosti vysoké, ale v následujícím roce ještě dále rostly. Máme tedy obsazeny všechny čtyři kvadranty:

1. Těžíme-li v předchozím roce intenzivně kůrovcové dříví, v následujícím roce bude dynamika populačního růstu hmyzího škůdce významně potlačena. V této oblasti je zřejmá vynikající korelovanost dat.
2. Těžíme-li v předchozím roce málo kůrovcového dříví, v následujícím roce bude dynamika populačního růstu l. smrkového růst. V této oblasti je ovšem z grafu patrna rovněž vynikající korelovanost.

3. Třetí kombinace představuje optimální stav, kdy v předchozím roce těžíme málo kůrovcového dříví a v následujícím roce bude dynamika populačního růstu kůrovce přesto klesat.
4. Čtvrtá kombinace představuje problematický stav, kdy byly těžby v předchozím roce rovněž již dosti vysoké, ale v následujícím roce ještě dále rostly.

Tato čtvrtá oblast dat nekomplikuje ani tak naši hypotézou o vlivu nezbytné a včasné asanace kůrovcového dřeva, ale komplikuje její matematické vyjádření prostřednictvím regresního modelu. Zavedením nelinearity je tento problém jednak zvýrazněn a zároveň je dosaženo zásadního zvýšení hodnoty indexu determinace, takže pro tento delinearizovaný model bude $R^2 = 0,35$, což znamená, že vliv objemu těžby kůrovcového dřeva v daném roce na jeho těžbu v roce následujícím představuje již hypotetický podíl celých 35 % .

Z vytvořeného dílčího regresního modelu však není patrna dekompozice kvadrantů 1, 2 a 3, které odpovídají standardní hypotéze, a kvadrantu 4, který jí neodpovídá. Pro možnost grafické realizace této dekompozice zavedeme jinou transformaci vysvětlované proměnné, sice meziroční rozdíl vytěženého objemu kůrovcového dříví. Přitom nejprve zachováme linearitu dílčího regresního modelu. Výsledek ilustruje graf č. 3:



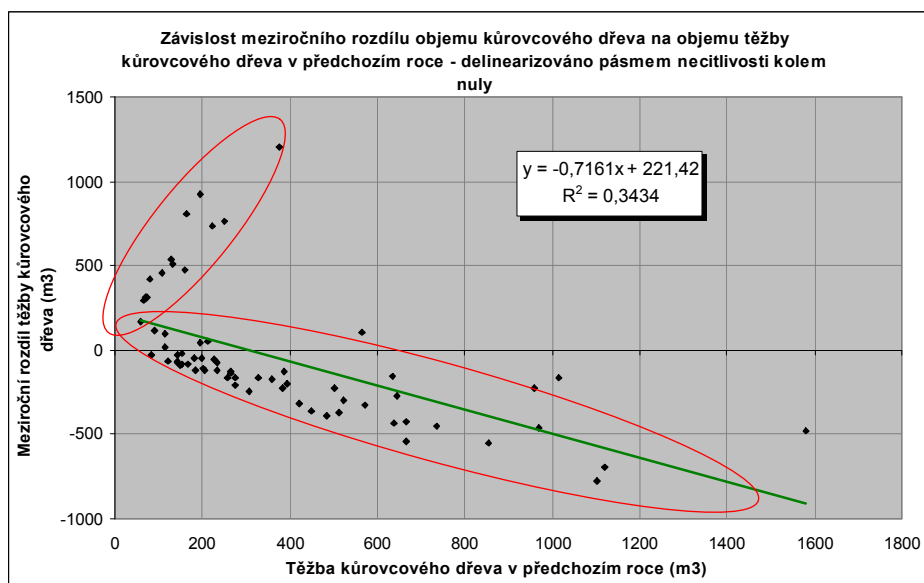
Graf č. 3:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu těžby kůrovcového dřeva v předchozím roce – lokalita 1 (Lesní správou Opava – Hlubočec).

Z grafu č. 3 je zřejmé, že největší potíže nám způsobují měření označená šikmo umístěnou elipsou v levém rohu grafu nahoře. Tato měření odpovídají situaci, kdy i při vzrůstající těžbě kůrovcového dříví v následujícím roce populační dynamika kůrovce dále vzrůstá – kalamitu se ani radikální asanací napadených stromů nepodařilo potlačit. Tato data nemůžeme odstranit zavedením žádné nelinearity, poněvadž jde zřejmě o „vlivné body“. Zároveň nám přítomnost těchto dat snižuje index determinace přímkového regresního modelu ($R^2 = 0,35$), který nyní nabývá pouze hodnoty $R^2 = 0,29$, která je ale stále vyšší, než-li tomu bylo v prvním případě, kdy jako vysvětlovací proměnná byl využit podíl meziročních těžeb kůrovcového dřeva ($R^2 = 0,20$). Tato skutečnost dokazuje, že meziroční rozdíly objemů kůrovcového dříví budou lepší

formou vyjádření transformace vysvětlované proměnné, než-li byly podíly těchto objemů. Poněvadž tyto podíly vystupují i při vyjádření logaritmickém, byl index determinace při logaritmické transformaci též pouze kolem 0,2 (viz Tabulka č. 2).


V lineárním dílčím regresním modelu vyjádřeném v grafu č. 3 ovšem můžeme opět zavést delinearizaci, nyní představovanou skutečným pásmem necitlivosti kolem nuly. V roli vysvětlované proměnné vystupuje rozdíl. Veškeré meziroční rozdíly menší nežli 50 m³ tudíž ze souboru dat vyloučíme. Hranici 50 m³ jsme přitom stanovili kvalifikovaným odhadem, neboť průměr těchto těžeb se pohybuje na desetinásobku této hodnoty. Eliminujeme tak cca 25 % hodnot se zjevně nízkou informační hodnotou, což nám dovolí získat nelineární regresní model (graf č. 4) se značně vyšším indexem determinace $R^2 = 0,34$, prakticky totožným s výsledkem z grafu č. 2. Navíc má regresní přímka strmější průběh. Tento dílčí nelineární model již budeme považovat za výsledný.



Graf č. 4:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu těžby kůrovcového dřeva v předchozím roce - delinearizováno pásmem necitlivosti kolem nuly. – lokalita 1.


Další postup již bude založen na důsledném využití rozdílového tvaru transformace vysvětlované veličiny (náhodnou závisle proměnnou bude meziroční rozdíl objemu těžeb kůrovcového dříví). Tímto způsobem vytvoříme dílčí lineární i nelineární regresní modely pro zbývající vysvětlované, čili náhodné nezávislé proměnné. Nejprve lineární regresní model pro živelné těžby:



Graf č. 5:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu živelných těžeb v předchozím roce – lokalita 1 (Lesní správou Opava – Hlubočec).

Z tohoto grafického vyjádření je opět zřejmé, že meziroční rozdíl těžeb kůrovcového dříví může s rostoucími živelnými těžbami v předchozím roce jak růst, tak i klesat. Poněvadž v souhrnu dat nemůžeme tyto dvě situace od sebe odlišit, je tudíž index determinace zdánlivě velmi nízký. Kdyby bylo zmíněné odlišení z principu možné, pak bychom získali vlastně dva odlišné a značně vysoké indexy determinace. Uplatnění tohoto dílčího regresního modelu dále komplikuje jeho linearita, která umožňuje plné uplatnění i malých hodnot z pásem necitlivosti kolem nuly. K již zavedenému pásmu necitlivosti vysvětlované proměnné definujeme ještě pásmo necitlivosti vysvětlující proměnné: Veškeré těžby živelné o objemu menším 50 m³ rovněž zanedbáme. Výsledek demonstruje graf č. 6:




Graf č. 6:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu živelných těžeb v předchozím roce - delinearizováno pásmem necitlivosti kolem nuly – lokalita 1.

Uvedeným postupem jsme sice nezískali vyšší index determinace, poněvadž obě graficky dekomponované zcela odlišné závislosti mezi objemem živelných těžeb v předchozím roce a následným meziročním rozdílem objemů těžeb kůrovcových jsou jasně vyznačeny, ale získali jsem alespoň poněkud vyšší strmost regresní přímky.

Zajímavou by byla úvaha, proč se objem živelných těžeb tak odlišně promítá do budoucí populační dynamiky kůrovce. Určitým vysvětlením by mohlo být to, že skutečně včasné vyklizená a vyvezená či jinak asanovaná přísně kontrolovaná živelná těžba velkého rozsahu natolik omezí možnost přežívání lýkožrouta, že jeho populační dynamika v příštím roce klesá. Naopak při relativně menších poškozeních porostů větrem či sněhem může být pozornost věnovaná včasnému uskutečnění živelné těžby menší a důsledek se projeví v dalším roce nárůstem napadení zdravých stromů kůrovcem. Dalšíh vysvětlení ale může být celá řada.

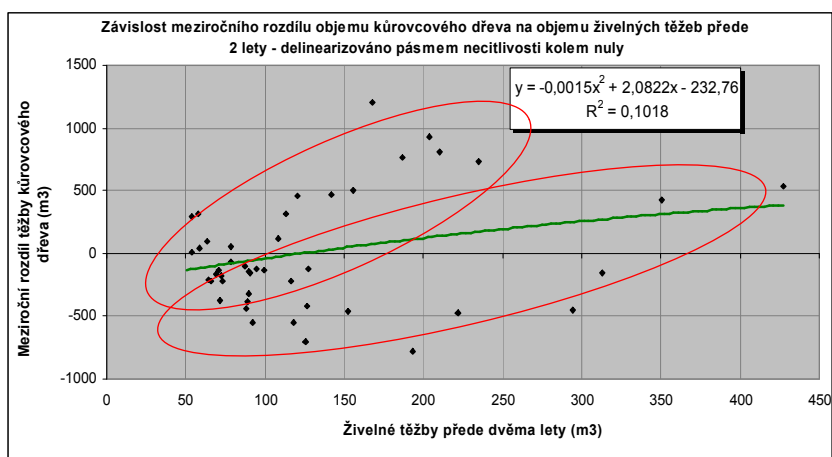
Zajímavé je, že poněkud jinou závislost vykazuje vliv polomů a vývrátů, tedy objemu živelných těžeb, vyjádřený s ročním zpožděním, tedy takový, jaký byl přede dvěma lety (graf č. 7). S rostoucím objemem těchto živelných těžeb roste i populační dynamika kůrovce. Index determinace je sice nízký ($R^2 = 0,09$), ale koeficient korelace je přece jen příznivější ($r = 0,24$), zatímco v předchozím případě závislosti objemu těžeb kůrovcového dříví v daném roce na objemu živelných těžeb minulého roku byl tento koeficient korelace sotva 0,1. Vysvětlením by mohla být úvaha o prolongaci vývoje kůrovce v cyklu zahrnujícím více, než jeden rok. I v tomto grafu lze ovšem dekomponovat dvě regresní přímky různé strmosti, na rozdíl od předchozího grafu však velmi blízké.



Graf č. 7:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu živelných těžeb přede 2 lety – lokalita 1 (Lesní správa Opava – Hlubočec).

Za této situace zavedeme pásmo necitlivosti a tím delinearizujeme vytvořený dílčí lineární regresní model. Výsledek ilustruje graf č. 8




Graf č. 7:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu živelných těžeb přede 2 lety - delinearizováno pásmem necitlivosti kolem nuly – lokalita 1.

Je patrné, že předpokládaná jemná dekompozice zůstává v platnosti. Index determinace nepatrně vzrostl ($R^2 = 0,10$) a koeficient korelace zřetelně vzrostl ($r = 0,30$). Hypotéza o možné prodloužení vývoje kůrovce v cyklu zahrnujícím více, než jeden rok, kdy se v tomto cyklu může uplatňovat dříví z živelných těžeb z předminulého roku, získává tímto výsledkem tudíž další podporu.

Dále se budeme zabývat vlivem další vysvětlující proměnné představované těžbou lapáků. Závislost meziročního rozdílu objemu těžného kůrovcového dříví na objemu těchto těžeb představuje graf č. 9:




Graf č. 9:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu těžeb lapáků jako obranného opatření v předchozím roce – lokalita 1 (Lesní správou Opava – Hlubočec).

Už z pouhého okulárního posouzení je patrné, že zde do úvahy nepřipadá žádná smysluplná dekompozice této závislosti. Dle předpokladu těžba kůrovcového dřeva a tedy i populační růst kůrovce klesá v následujícím roce, pokud je v roce předchozím intenzivně využíváno lapáků jako sice klasického, ale účinného obranného opatření.

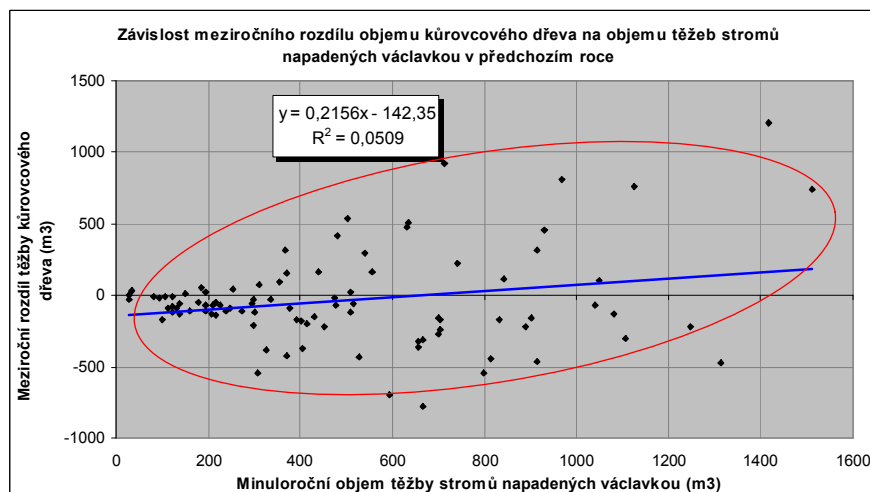
Index determinace je však nižší, nežli bychom hypoteticky předpokládali ($R^2 = 0,08$) a ani koeficient korelace nenabývá nikterak výrazných hodnot ($r = -0,28$). Po provedené delinearizaci (graf č. 10) vzroste jak index determinace ($R^2 = 0,17$), tak i korelační koeficient ($r = -0,41$). Zavedený dílčí nelineární regresní model tudíž vyjadřuje, že těžba lapáků v daném roce má minimálně 17% vliv na kůrovcové těžby v roce následujícím a že koeficient korelace mezi objemem těžby lapáků a populačním růstem kůrovce je záporný a s nezanedbatelnou hodnotou $-0,41$. Testováním hladiny významnosti p pro tyto korelace se budeme souhrnně zabývat později.



Graf č. 10:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu těžeb lapáků jako obranného opatření v předchozím roce - delinearizováno pásmem necitlivosti kolem nuly – lokalita I (Lesní správa Opava – Hlubočec).


Další možnou vysvětlující proměnnou je objem tracheomykózních těžeb, jejichž vliv na meziroční rozdíl objemu těžeb kůrovcového dříví je v podobě jednoduchého, čili dílčího lineárního regresního modelu vyjádřen v grafu č. 11:



Graf č. 11:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu tracheomykózních těžeb v předchozím roce – lokalita I (Lesní správa Opava – Hlubočec).

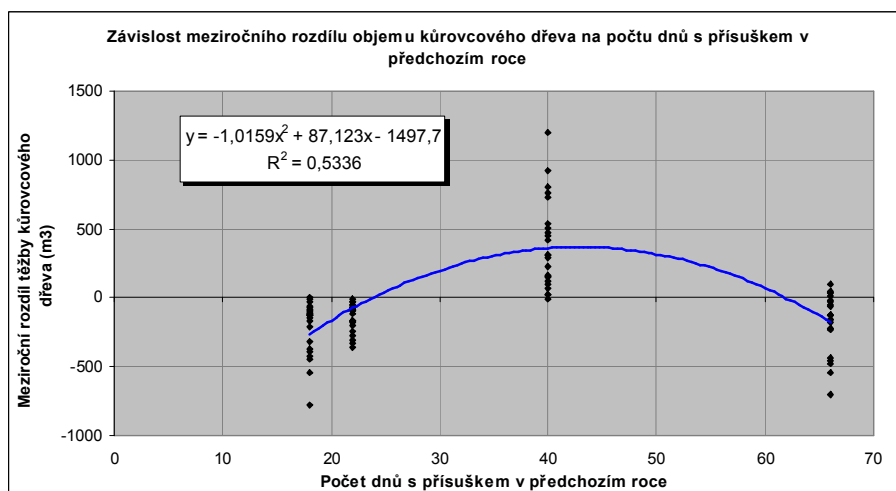
Je zřejmé, že s rostoucím objemem těžby václavkového dříví v předchozím roce roste i objem vytěženého kůrovcového dříví v následujícím roce, tedy populační dynamika kůrovce. Index determinace ($R^2 = 0,05$) i korelační koeficient ($r = 0,23$) jsou ovšem, alespoň pro zavedenou transformaci proměnných, velmi nízké. Realizujeme proto opět zavedením pásma necitlivosti kolem nuly delinearizaci tohoto regresního modelu. Tak získáme model demonstrováný grafem č. 12. Index determinace ($R^2 = 0,07$) i koeficient korelace ($r = 0,26$) vzrostly jen nepatrně, ale i tak je patrné, že nelineární model představuje trend směřující ke zřetelnějšímu vyjádření modelovaných kauzalit a lze mu tudíž dávat oprávněně přednost. Problematiku testování signifikantnosti indexů determinace a koeficientů korelace budeme studovat v dalším textu této práce.



Graf č. 12:


Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu tracheomykózních těžeb v předchozím roce- delinearizováno pásmem necitlivosti kolem nuly – lokalita 1.

Jako poslední vysvětlující proměnná, kterou se v předložené práci budeme zabývat, je přísušek, kvantifikovaný počtem dnů v daném roce. Vliv tohoto faktoru na meziroční rozdíl objemů těžby kůrovcového dřeva při lineárním modelu ilustruje graf č. 13 a při nelineárním modelu graf č. 14.



Graf č. 13:


Závislost meziročního rozdílu objemu kůrovcového dřeva na počtu dnů s přísuškem v předchozím roce – lokalita 1(Lesní správou Opava – Hlubočec).



Graf č. 14:

Závislost meziročního rozdílu objemu kůrovcového dřeva na počtu dnů s přísuškem v předchozím roce- delinearizováno pásmem necitlivosti kolem nuly – lokalita 1.

Pro matematické vyjádření závislosti byl použitím metody nejmenších čtverců zvolen jako nejvhodnější polynom 2. řádu, který zároveň dobře vystihuje lokální maximum nacházející se v intervalu kolem 40 – 50 dnů přísušku. Z poskytnutých dat vyplývá, že při nižším, ale i při vyšším počtu přísuškových dnů vliv přísušku na růst populační dynamiky lýkožrouta smrkového v sledujícím roce klesá. Index determinace ($R^2 = 0,53$) dosahuje vysoké hodnoty. Tuto hodnotu musíme brát s jistou rezervou, poněvadž je nejen důsledkem skutečných přírodních závislostí, ale zřejmě i ryzím důsledkem vhodně voleného matematického modelu polynomu 2. řádu. I tak však nasvědčuje významnému vlivu přísušku na populační dynamiku kůrovce. Koeficient korelace je ovšem malý ($r = 0,08$), což je zřejmým důsledkem specifického charakteru vysvětlující této proměnné, která je schopna nabývat jen několika málo hodnot stejných vždy pro všechny segmenty (18, 22, 40, 66). Pokud dílčí jednoduchý lineární regresní model zavedením pásma necitlivosti kolem nuly delinearizujeme, získáme ještě vyšší index determinace ($R^2 = 0,65$), ale nízký koeficient korelace se v zásadě nezmění ($r = 0,06$), což je pochopitelné vzhledem ke konstrukci koeficientu korelace, který předpokládá přísnou gausovost obou náhodných proměnných. Využijme proto této diskrepance k tomu, abychom alespoň orientačně posoudili otázku související normálnosti, čili gausovosti. Histogram meziročních změn objemů těžeb kůrovcového dříví (graf č. 15) vykazuje přinejmenším určitou podobnost gausovskému rozdělení.



Graf č. 15:
Histogram vysvětlované proměnné – lokalita 1 (Lesní správou Opava – Hlubočec).


Přitom bylo zvoleno 11 tříd, neboť empirické vzorce pro výpočet optimálního počtu tříd dávají čísla 7 až 10:

$$k = 2,5 \cdot \sqrt[4]{n} = 2,5 \cdot \sqrt[4]{92} \approx 8$$

$$k = 5 \cdot \log n = 5 \cdot \log 92 \approx 10$$

$$k = 1 + 3,3 \cdot \log n = 1 + 3,3 \cdot \log 92 \approx 7$$

a zároveň hraje roli snaha zavést přehledné a snadno a názorně dělitelné intervaly. Medián (-76) a aritmetický průměr (-36) jsou sice hodnoty dosti odlehlé, ale vzhledem k šíři intervalu (1985) danou rozdílem maxima (1206) a minima (-779) není tento rozdíl příliš markantní. Nyní bychom měli přistoupit k exaktnímu testování. Za tímto účelem je ovšem nutno zkonstruovat model ideálně gausovsky rozdělené náhodné proměnné se stejným aritmetickým průměrem a stejnou směrodatnou odchylkou (graf č. 16) a otestovat toto rozdělení vzhledem k empiricky získanému rozdělení pomocí chí-kvadrát testu.



Graf č. 16:
Hypotetické modelové Gaussovo rozdělení meziroční změny objemu těžeb.

Pravděpodobnost p získaná chí-kvadrát testem je pro tento náš případ s deseti stupni volnosti zhruba $p = 0,0002$, což je tak nízká hodnota. Tato hodnota vyjadřuje, že mezi ideálně gaussovským a reálným rozdělením je obrovská míra nahodilosti, takže riziko se kterým bude spojeno naše prohlášení o tom, že empiricky získaná data nejsou rozdělena gaussovsky bude spojeno pouze s 0,02% rizikem omylu. V zásadě jsme tedy gausovost dat popisujících meziroční rozdíly objemů kůrovcových těžeb nepotvrdili (viz tabulka č.4).

Středů tříd	Gauss.	Skuteč.	Rozdíl
-700	0,92	2	1,27
-500	5,62	7	0,34
-300	18,12	12	2,07
-100	30,82	43	4,81
100	27,64	14	6,73
300	13,07	4	6,30
500	3,26	5	0,93
700	0,43	2	5,76
suma chí-kvadrát			28,21
odpovídající p-st p			0,0002

Tabulka č. 4:






Testovací tabulka chí-kvadrát testu pro hypotézu Gaussova rozdělení meziročních rozdílů objemů těžeb kůrovcového dříví.

Podobně budou vyznívat i výsledky pro další, tentokrát vysvětlující náhodné proměnné. Nejprve jsem vytvořili histogramy jednotlivých vysvětlujících proměnných (viz tabulka č. 5). Tyto histogramy už z okulárního posouzení ukazují na rozdělení, která jsou velmi vzdálena od rozdělení normálního – Gaussova. Snad jen objem živelných a tracheomykózních těžeb vykazuje alespoň minimální náznak normálního rozdělení, ovšem nepochybně kvalitativně menší, než-li tomu bylo u vysvětlované proměnné.


Ani kvantitativní posouzení deskriptivních statistických charakteristik (viz tabulka č. 6) neukazuje na gausovost rozdělení vysvětlujících náhodných proměnných. Pro přehlednost uvádíme též grafickou představu o těchto základních deskriptivních charakteristikách (graf č. 17).

Stejně tak ani posouzení šikmosti a špičatosti pro rozdělení jednotlivých vysvětlujících proměnných neposkytuje výsledky, které by nasvědčovaly normálnímu rozdělení těchto náhodných veličin (graf č. 18, tabulka č. 8).


V našich výpočtech a modelováních musíme tudíž spíše spoléhat na centrální limitní teorém, který v zásadě vyjadřuje skutečnost, že pokud je znak určen působením většího počtu navzájem nezávislých vlivů, ať je každý z těchto jednotlivých vlivů či faktorů rozdělen jakkoli, musíme vždy dospět alespoň přibližně k normálnímu rozdělení. Pro uplatnění centrální limitní věty je však nezbytné, aby rozsah výběrového souboru dosáhl alespoň určité minimální velikosti. V úlohách pilotního výzkumu se požaduje rozsah alespoň kolem 100 prvků, což náš datový materiál přibližně splňuje.



Tabulka č. 5:
Histogramy jednotlivých vysvětlujících proměnných – lokalita 1.




Tabulka č. 6:
Základní deskriptivní statistika jednotlivých vysvětlujících proměnných.



Graf č. 17:
Grafická představa o statist. deskriptivních charakteristikách vysvětlujících proměnných.

Šikmost a špičatost vysvětlované a vysvětlujících náhodných proměnných



Graf č. 18:

Šikmost a špičatost vysvětlované i vysvětlujících náhodných proměnných.

Statistické char-ky	Šikmost	Špičatost
Kůrovcové dříví - meziroční rozdíl roků (k+1) - k	1,2	2,7
Kůrovcové dříví (k)	1,9	4,1
Živelné těžby (k)	1,7	4
Těžby lapáků (k)	1,9	3,5
Těžby tracheomykózní (k)	0,9	0,2
Přísušek (k)	0,6	-1,2

Tabulka č. 8: Šikmost a špičatost vysvětlované i vysvětlujících náhodných proměnných.

Po získání těchto dalších východisek naší práce se vraťme opět k otázce konstrukce a využití představených dílčích (jednoduchých) delinearizovaných regresních modelů. Je především zřejmé, že s pojmy jako korelace a index determinace musíme zacházet poněkud opatrně, poněvadž se nemůžeme příliš spoléhat na gausovost rozdělení jednotlivých náhodných proměnných. Přesto bude dalším užitečným východiskem shrnutí vypočtených hodnot indexů determinace vysvětlujících proměnných a koeficientů korelace těchto vysvětlujících proměnných s proměnnou vysvětlovanou pro případ lineárního i delinearizovaného regresního modelu (tabulka č. 9):

		Kůrovcové dříví(t)	Živelné těžby (t)	Živelné těžby (t - 1)	Václavkové dříví (t)	Přísušek(t)	Lapáky(t)	Součet
Index determinace	Lineární model	0,29	0,04	0,09	0,05	0,53	0,08	1,08
	Nelineární model	0,34	0,04	0,10	0,07	0,65	0,17	1,37
Koeficient korelace	Lineární model	-0,54	-0,21	0,24	0,23	0,08	-0,28	---
	Nelineární model	-0,59	-0,19	0,30	0,26	0,06	-0,41	---

Tabulka č. 9:

Indexy determinace, koeficienty korelace s vysvětlovanou proměnnou a posouzení jejich statistické významnosti.

Z vypočtených hodnot je patrné, že ve většině případů korelační koeficienty i indexy determinace po zavedení nelinearity vzrostou. Zjevně se zvýší kvantitativní ohodnocení významu vysvětlujících proměnných. Zbývá nám ještě posoudit statistickou významnost těchto koeficientů. Otestujeme je tudíž podle testovacího kritéria

$$T = \frac{r}{\sqrt{1-r^2}} \cdot \sqrt{n-2} ,$$

kde r je koeficient korelace a n je počet prvků souboru. Následně vypočteme odpovídající hladinu významnosti p . Počet stupňů volnosti je Z ískáme tak tabulku č. 10, přičemž otestováním koeficientů korelace v zásadě testujeme i indexy determinace.

		Kůrovce dříví(t)	Živelné těžby (t)	Živelné těžby (t-1)	Václavkové dříví (t)	Přísušek(t)	Lapáky(t)
Lineární model	Hodnota kritéria	6,14	2,01	2,35	2,20	0,77	2,79
	Hladina význam. p	20E-9	0,05	0,02	0,03	0,44	0,006
Nelineární model	Hodnota kritéria	6,86	1,81	2,94	2,55	0,56	4,33
	Hladina význam. p	1E-9	0,07	0,004	0,01	0,58	0,000 04

Tabulka č. 10:

Statistická významnost koeficientů korelace mezi vysvětlovanou a vysvětlujícími náhodnými proměnnými.

Lze uzavřít, že až na přísušek lze všechny ostatní korelace považovat za signifikantní s dosti nízkými hladinami, ačkoliv korelace živelných těžeb minulého i předminulého roku splňují zavedené hranice pro hladinu významnosti jen hraničně.

Poněvadž veškeré provedené výpočty předpokládají gausovost náhodných veličin, můžeme i při využití centrálního limitního teorému dělat jakékoliv závěry jen velmi zdrženlivě. Přitom od gausovosti je bezpochyby nejvíce odchýlen právě přísušek, který se jinak jeví jako nejvýznamnější faktor pro ovlivnění populační dynamiky kůrovce. Této diskrepance se můžeme při vytváření regresních modelů zbavit jen stěží, zvláště když nemáme k dispozici dlouhodobé časové posloupnosti adekvátně shromážděných dat po celé dlouhé roky sledování.

Výsledky 2 – aplikace diskrétní PID regulace s parametry nelineárních regresních modelů – LS Opava Hlubočec


Jednu z cest, jak se s tímto problémem vypořádat a zároveň vytvořit zcela nový model regulace populační dynamiky kůrovce, bude představovat zavedení dynamiky, tedy sledování náhodných veličin (vysvětlované i vysvětlujících) ve vztahu k jejich realizaci v jednotlivých letech. Nebudeme se tudíž dále zabývat všemi uspořádanými $(n + 1)$ vektory představovanými jednou vysvětlovanou a několika vysvětlujícími proměnnými, jakožto prvky statistického souboru, nýbrž prvky statistického souboru budou nyní představovat jednotlivé vylišené segmenty, kterých je celkem ve sledované lokalitě 23. Pro tyto segmenty vypočteme střední hodnoty vysvětlované i vysvětlujících náhodných veličin pro jednotlivé roky 2004 až 2008. Tímto způsobem zavedeme do regresního modelu dynamiku. Žlutě vyznačené sloupce v tabulce č. 11 představují dynamiku vývoje jednotlivých náhodných proměnných. Porovnání průměrů získaných tímto postupem akcentujícím časový vývoj náhodných proměnných a postupem odpovídajícím předchozímu „sumárním“ pojetí, kde není přihlíženo k tomu, z kterého roku byly evidované údaje získány, ukazuje, že nové pojetí nevnáší příliš velké odchylky:

	Kůrovcové dříví (m ³)	Živelné těžby (m ³)	Tracheomykózní těžby (m ³)	Těžby lapáků (m ³)	Přísušek (-)
2004	258	162	511	119	28
2005	143	113	660	95	50
2006	536	109	584	81	64
2007	343	188	337	199	30
2008	141	---	---	---	---
Součet	1421	572	1993	494	172
Průměr za roky	284	143	498	123	43
Průměr sumární	291	121	495	98	37
% odchylky	2,4	15,4	0,6	20,3	13,9

Tabulka č. 11:


Hodnoty odpovídající časovému vývoji jednotlivých náhodných proměnných.

Pro lepší názornost lze výsledky vyjádřit třírozměrným grafem č. 19 (šipka zdůrazňuje běh času):



Graf č. 19:
 Třírozměrné vyjádření časového vývoje studovaných náhodných proměnných po jednotlivých letech.

Dostí nepřehlednou situaci lze dokreslit otočením os pravoúhlého souřadného systému v horizontální rovině (graf. č. 20).



Graf č. 20:
 Třírozměrné vyjádření časového vývoje studovaných náhodných proměnných po jednotlivých letech – osy souřadného systému v horizontální rovině pro názornost otočeny.

Nyní bude naším cílem uplatnit výsledky získané vytvořením nelineárních regresních modelů pro účely konstrukce dynamického řídicího systému, který by měl být schopen predikovat hodnotu vysvětlované proměnné představované kvantitativně stanoveným nárůstem nebo poklesem těžby kůrovcového dříví v budoucím roce, tedy odezvu změn populační dynamiky kůrovce. Tuto predikci bude náš řídicí systém (čili model) uskutečňovat na základě znalostí hodnot vysvětlujících proměnných v daném roce. Poněvadž mezi tyto vysvětlující proměnné patří i objem těžby kůrovcového dříví v daném roce, má vysvětlovaná veličina přímý matematický vztah s touto veličinou vysvětlující:

$$\text{Meziroční rozdíl objemů těžeb kůrovcového dříví } (k+1) = \\ \text{Objem kůrovcového dříví } (k+1) - \text{Objem kůrovcového dříví } (k)$$

Pro jednoduchost dalšího matematického popisu zavedeme následující symboliku (tab. č. 12):

Veličina	Symbol
Meziroční rozdíl objemů těžeb kůrovcového dříví mezi po sobě následujícími lety $k+1$ a k	$Dif(k+1)$
Kůrovcové dříví (k)	$Ty(k)$
Živelné těžby (k)	$Živ(k)$
Těžby lapáků (k)	$Lap(k)$
Těžby tracheomykózní (k)	$Vac(k)$
Přísušek (k)	$Pris(k)$

Tabulka č. 12: Zavedená symbolika pro vysvětlující i vysvětlovanou proměnnou.

Proměnná k přitom vyjadřuje stav v roce k a proměnná $k+1$ stav v následujícím roce $k+1$. Pak vysvětlovanou proměnnou můžeme vyjádřit vztahem

$$Dif(k+1) = Ty(k+1) - Ty(k).$$

Ovšem naším cílem je vytvořit takový model, kterým bychom byli schopni hodnotu $Dif(k+1)$ určit s vysokou mírou spolehlivosti ještě v roce k , tedy ve smyslu apriorního odhadu. Naš model pak bude pracovat jako prediktor, který umožní předvídat vývoj populační dynamiky kůrovce a tím rovněž umožní se na tento aktuální vývoj náležitě a v předstihu připravit.

Určitá potíž je v tom, že predikujeme výši kůrovcových těžeb v následujícím roce, respektive rozdíl meziročních objemů těžeb kůrovcového dříví (dle předchozí rovnice) a nikoliv skutečnou ryze řídicí veličinu. Tato potíž je přirozeně následkem toho, že zatímco rozdíl meziročních objemů těžeb kůrovcového dříví $Dif(k+1)$ je v regresním modelu veličinou vysvětlovanou, je objem těžby kůrovcového dříví v roce k veličinou vysvětlující.


Pak ovšem, aniž bychom vnesli do úvah a výpočtů jakoukoliv chybu nebo nepřesnost, můžeme za vysvětlovanou veličinu považovat i objem těžby kůrovcového dříví v roce $k+1$, tedy predikovanou veličinu $Ty(k+1)$. Budeme-li znát predikci $Ty(k+1)$, můžeme ji už dále využít pro stanovení či zpřesnění skutečných ryze řídicích veličin.

Většinu z námi sledovaných veličin však lze lidskou činností ovlivnit jen velmi málo (objem živelných těžeb), pouze v dlouhodobém horizontu (objem živelných těžeb i těžeb kůrovcových je jistě ovlivnitelný hospodařením směřujícím k druhové i věkové rozrůzněnosti lesa, výběru vhodných proveniencí, posilováním zdravotní odolnosti porostů, snižováním tracheomykóz, pečlivým a včasným zpracováváním polomů a vývratů, jakož i včasnou asanací stromů napadených kůrovcem apod.) nebo vůbec (např. přísušek). Zbývá nám tudíž možnost ovlivnění krátkodobě působících obranných opatření, kde prioritní roli sehraává těžba lapáků, dále pak lapače, využití chemie apod.

Základní krátkodobé obranné opatření spočívá zřejmě ve využití lapáků. Počet potřebných lapáků, např. pro první sérii lze vypočítat různými způsoby, nejčastěji podle tzv. kalamitního základu. Kalamitní základ je množství kůrovcového dříví vytěženého v období od 1. srpna do 31. března. Tento objem dříví vydělíme průměrnou hmotností (vyjde nám zde kolik to bylo stromů) a dále osmi, což dá počet lapáků. Počet lapáků lze pak vyjádřit i objemem jejich hmoty. Tuto hodnotu ryze řídicí veličiny, aktuální pro každé vegetační období, tedy každý rok, by pak bylo možno dále významně zpřesňovat či modifikovat na základě výsledku výpočtu predikované apriorní hodnoty $T_y(k+1)$.

Ovšem po uplynutí dalšího jednoho roku, tedy v roce $k+1$, známe již hodnotu $T_y(k+1)$ přesně, budeme tudíž moci provést tzv. aposteriorní korekci, a následně rok $k+1$ přečíslovat na rok k a znovu aplikovat náš predikční model, jehož konstrukcí se v dalším textu předložené práce hodláme alespoň v prvním přiblížení zabývat. Tento predikční model bude vlastně představován řídicím systémem se zpětnou vazbou.


Řídicí systémy mohou pracovat buď v otevřeném nebo uzavřeném obvodu řízení. Při řízení v otevřeném obvodu (v otevřené smyčce) se k řízení řízeného systému - objektu S využívá jen apriorní informace o tomto objektu a nekontroluje se jeho skutečný stav (obr. č. 1). Takovému způsobu řízení říkáme obvykle ovládání. Je zřejmé, že tento způsob řízení by mohl být využíván jen za neproměnné okolní situace a v našem případě nemá využití.



S	řízený systém, řízený objekt
R	řídicí systém
w	požadavek na řízení
u	řídicí (akční) veličina
y	výstupní veličina
d	porucha, změna v okolí, působící na řízený systém-objekt

Obr. č. 1:
Princip řízení v otevřené smyčce.

Potřebný je naopak systém pracující s uzavřenou smyčkou, někdy též nazývaný regulátor (obr. č.2):



S	řízený systém, řízený objekt
R	řídící systém
w	požadavek na řízení
u	řídící (akční) veličina
y	výstupní veličina
d	porucha, změna v okolí, působící na řízený systém-objekt
e	odchylka

Obr. č. 1:

Princip řízení v otevřené smyčce.

Základem tohoto řízení je vyhodnocení regulační odchylky $e = w - y$, podle jejíž velikosti generuje řídicí systém (regulátor) R řídicí veličinu u , jejíž úspěch může být ovšem narušen poruchou, změnou působící na řízený systém S, takže je vypočítána nová odchylka e a celý postup se opakuje se snahou plnit co nejlépe požadavek w . Povšimněme si ještě důležitou roli času, který může vystupovat v roli spojité, ale i v roli diskrétní veličiny. V našem případě je jasným požadavkem na řízení dosažení minimálních kurovcových těžeb. Role času je přitom diskrétní. V našem modelovém případě je krokem diskrétně pojatého času 1 rok, označován posloupnostmi proměnných $\dots, t-1, t, t+1, \dots$ nebo zde $\dots, k-1, k, k+1, \dots$. Je zřejmé, že tento časový krok je pro skutečně dobrou funkci řídicího modelu příliš dlouhý, poněvadž nedokáže zohlednit dynamické změny během vlastního vegetačního období. Nicméně tento model zkonstruujeme a využijeme jako výchozí pilotní záměr pro ověření pracovní hypotézy o účinnosti a přínosnosti tohoto postupu.

Vzniká otázka, jakého matematického a regulačního modelu pro konstrukci řídicího systému použít. Kybernetika a moderní teorie řízení přinesly za poslední více jak půlstoletí od prvních průkopnických prací Wienera, Kalmana, Shannona, von Neumanna, Bar-Shalona, Zadeha, Pontrjagina a dalších mnoho přístupů pro řešení složitých řídicích problémů. Byly zdůrazněny zásadní systémové analogie mezi přírodními, technickými i společenskými systémy a rozpracován samostatný matematický aparát. Tím je naplňován smysl definice kybernetiky jako „vědy, která se zabývá obecnými principy řízení a přenosu informací ve strojích, živých organismech a společenstvích“. V naší práci však vyjdeme z jednoho z nejjednodušších, ale také neúčinnějších regulačních modelů, a to tzv. PID regulátoru (Aström, J., Hägglund, T., 1995; Balátě, J., 2004; Ožana, Š., 2012; Wittenmak, B., Aström, K. J., Arzen, K.-E., 2001).

Tento výběr byl uskutečněn na základě úvahy, že při řízení objemu těžby kůrovcového dřeva, přeneseně pak při stanovení velikosti těžby lapáků, hodláme využívat všech potencionálně řídicích veličin - tedy momentálně dostupných vysvětlujících proměnných v našich nelineárních regresních modelech – ať jsou již ovlivnitelné lidskou činností, či nikoliv. Hodláme přirozeně využívat samotné aktuální velikosti každé z těchto veličin. Proto jsme vlastně regresní modely konstruovali. Lze například předpokládat, že čím větší bude těžba lapáků v předchozím roce, tím menší bude populační růst typografa a tím budou menší i kůrovcové těžby v roce následujícím (záporná korelace). Nespokojíme se ovšem jen se samotnými hodnotami vysvětlujících proměnných (tedy řídicích veličin), ale budeme předpokládat, že na predikované hodnotě řízené veličiny (tedy veličiny vysvětlované), se bude významně podílet též dynamika minulých změn řídicí (vysvětlující) veličiny. V našem případě diskrétního času to bude např. rozdíl mezi objemem těžby lapáků v minulém a předminulém roce. V případě spojitého času bychom tedy pracovali s derivací, v případě času diskrétního budeme pracovat s diferencí. Podle korelační a regresní závislosti mezi danou vysvětlující a vysvětlovanou (řízenou) veličinou pak úměrně hodnotě této difference (derivace), budeme generovat velikost řídicího zásahu, tedy velikost predikované hodnoty vysvětlované proměnné. Takto generované hodnoty proto s porostou s velikostí změn vysvětlujících proměnných v nedávné minulosti systému. Opačný případ bude představovat generování hodnoty řídicího zásahu na základě součtu hodnot vysvětlujících proměnných z několika minulých let. Tento přístup je založen na sumaci, která je za situace spojitého průběhu času analogická integrálu.

PID regulátor generuje tudíž řídicí zásah složený ze tří složek:

- P – proporcionalní,
- D – derivační (v našem případě diskrétního času diferenční),
- I – integrační (v našem případě diskrétního času sumační).

Právě proto se tento regulátor označuje zkratkou PID.

Základním matematickým vyjádřením tohoto regulátoru je následující rovnice:

$$u(t) = k_p \cdot \left[e(t) + \frac{1}{T_I} \cdot \int_0^t e(\tau) d\tau + T_D \cdot \frac{de(t)}{dt} \right],$$

kde $e(t)$ je regulační odchylka,

$u(t)$ řídicí, čili akční veličina,

T_I je integrační čas. konstanta, čili čas. konstanta integračního členu PID regulátoru a

T_D je časová konstanta derivačního členu PID regulátoru.

Integrační a derivační časovou konstantu lze též zahrnout do koeficientů proporcionalní, integrační a derivační složky PID regulátoru, takže:

$$k_p = k_p$$

$$k_I = \frac{k_p}{T_I}$$

$$k_D = k_p \cdot T_D$$

Nyní musíme vyřešit 4 zásadní problémy:

1. Regulátor PID je určen pro řízení spojitého děje. V našem případě se však setkáváme s dějem z hlediska času diskretním. Tudíž je nutno modifikovat spojité PID regulátor na PID regulátor diskretní. Tento postup je znám a běžně používán (Vítečková, M. , Víteček, A., 2006; Vašek, V. , 1990). Základem je převedení integrálu na sumu a derivace na diferenci. Proto se též často hovoří o PSD regulátoru, někdy též „číslicové“ verzi PID regulátoru.

$$\int_0^t e(\tau) d\tau \rightarrow T \cdot \sum_{i=0}^k e(iT)$$

$$\frac{de(t)}{dt} \rightarrow \frac{e(kT) - e[(k-1)T]}{T}$$

Základní rovnice PSD regulátoru bude tudíž:

$$u(kT) = k_p \cdot \left[e(kT) + \frac{T}{T_I} \cdot \sum_{i=0}^k e(iT) + \frac{T_D}{T} \cdot \{e(kT) - e[(k-1)T]\} \right].$$

Uvedená rovnice platí pro maximální hloubku integrace (sumace), kdy sčítáme všechny regulační odchylky od počátku regulovaného děje. Pokud se spokojíme pouze se součtem vzorků z omezené hloubky historie řízeného procesu, pak nezačínáme sčítat od $i = 0$, ale až od požadované menší hloubky historie. Pokud bude $i = k-1$, pak sčítáme jen dva poslední vzorky.

2. Větším problémem je to, že PID (respektive PSD) regulace počítá regulační zásah (akční veličinu, řízení) pro čas kT , ve kterém máme již též informaci o velikosti regulační odchylky. Je pochopitelné, že při číslicovém čili diskretním snímání informace ze zpětné vazby regulačního obvodu bude na rozdíl od snímání kontinuálního vždy nějaké zpoždění dané intervalem vzorkování spojitého průběhu. V běžné technické praxi však budou tyto intervaly alespoň několik desítek krát vyšší, nežli jsou časové konstanty regulovaného obvodu. Tento luxus nám však není v našem lesnickém případě dostupný. Pokud budeme za časovou konstantu řízeného systému považovat vegetační periodu 1 rok, pak též vzorkování nám dostupných informací má rovněž periodu 1 rok. Proto nemůžeme využít PID (PSD) regulátor jako takový, ale pouze jako prediktor, který nám bude předpovídat hodnoty akční veličiny rok dopředu – lze hovořit o apriorním odhadu. Po uplynutí jednoho roku pak získáme skutečné hodnoty, s jejichž pomocí provedeme aposteriorní korekci a regulátor PID (PSD) opět použijeme jako prediktor dalšího vývoje. Obecnou rovnici tohoto prediktoru pak můžeme zapsat (počítáme již jen s historií dvou let, dvou vzorků):

$$u[(k+1)T] = k_p \cdot \left[e(kT) + \frac{T}{T_I} \cdot \sum_{i=k-2}^k e(iT) + \frac{T_D}{T} \cdot \{e(kT) - e[(k-1)T]\} \right]$$

Jinými slovy: Řídící zásah, který bychom měli udělat co nejdříve, vlastně uděláme až za rok (poněvadž to stejně není jinak možné). Tuto rovnici ještě přepíšeme pouze s koeficienty P, I a D části matematického modelu PID (PSD) regulátoru – prediktoru tak, jak s ní budeme dále pracovat:

$$u[(k+1)T] = k_p \cdot e(kT) + k_I \cdot \sum_{i=k-2}^k e(iT) + k_D \cdot \{e(kT) - e[(k-1)T]\}$$

3. Zatím jsme psali obecné rovnice a stavěli jsme se k odchylce e i řídicímu zásahu u tak, jako by to byly skaláry. V našem případě se však jedná o vektory. Uvedené symboly pak musíme chápat vektorově a operace s nimi jsou pak maticového charakteru (viz dále).

4. Další nezbytnou modifikaci PID (PSD) regulátoru vyžaduje skutečnost, že řídicí veličina je zároveň veličinou výstupní. Jedná se o objem těžby stromů napadených kůrovcem. Přirozeně, že bychom mohli za akční (řídicí) veličinu považovat např. zřejmě nejúčinnější z obranných opatření, tj. objem těžby lapáků, ale tímto postupem bychom problém stejně nevyřešili, pouze přeformulovali. Jediným řešením je tudíž považovat objem vytěženého kůrovcového dřeva v roce k za složku vektoru výstupní veličiny, ale při predikci v roce $k+1$ již za veličinu řídicí. Tento přístup dobře koresponduje s pojetím apriorního odhadu a aposteriorní korekce.

Po vyřešení těchto čtyř diskrepancí již můžeme přistoupit k suboptimálnímu stanovení koeficientů proporcionální, derivační a integrační složky, jejichž prostřednictvím lze nastavit podíl těchto tří složek na výsledném chování regulátoru. Pro tento účel byla vytvořena řada matematických i empirických postupů, uplatňovaných především při řízení technických zařízení. Nejznámější metodou je metoda dle Zieglera a Nicholse a její modifikace dle Seborga (Klán P., Matoušek J., 1992; Klán, P., 2000; Klán, P., 2001). Obě metody vycházejí z předpokladu, že známe zesílení systému, při kterém dojde k netlumeným harmonickým kmitům. Pro náš případ lze aproximovat periodu netlumených kmitů dobou 4 – 6 let. Toto stanovení vychází z úvahy, že v paradoxním idealizovaném případě bychom mohli během 4 až 6 let teoreticky zaznamenat intervenci kůrovce, kterou bychom obrannými prostředky zastavili a stav vrátili na původní minimální hodnotu jeho výskytu. Kritické zesílení, představující nárůst kůrovcové těžby jsme pro tento případ odhadli součinitelem 2. Pak:

Metoda výpočtu	Koeficienty – výpočet dle různých metod		
	Proporcionální k_p	Integrační k_I	Derivační k_D
Ziegler – Nicholsova metoda	$0,6 \cdot k_{krit}$	$1,2 \cdot k_{krit} / T_{krit}$	$0,075 \cdot k_{krit} \cdot T_{krit}$
hodnoty	1,20	0,40	0,90
Modifikace dle Seborga	$0,33 \cdot k_{krit}$	$k_p / (0,5 \cdot T_{krit})$	$k_p \cdot 0,33 \cdot T_{krit}$
hodnoty	0,66	0,22	1,31

Tabulka č. 13:

Orientační výpočet koeficientů PID regulátoru dle dvou různých metod.

Mezi koeficienty vypočtenými různými metodami sledujeme sice značné rozdíly, což však nemusí být na závadu, neboť je nutno počítat s tím, že koeficienty budou „laděny“ v širších mezích a tím bude dosahováno optimálního přizpůsobení regulátoru konkrétním podmínkám jak jednotlivých let, tak i lokality. Zvolíme tudíž výchozí hodnoty koeficientů dle tabulky č. 14. Uskutečněnou volbou koeficientů jednak rámcově akceptujeme výchozí hodnoty získané použitím výše uvedených metod, avšak zároveň volíme koeficienty opatrně, poněvadž jsme si vědomi značně labilního východiska volby periody netlumených kmitů a volby kritického zesílení. Tím, že koeficient proporcionální složky zvolíme roven 1, nedáváme přednost ani trendu k potlačování křovcových těžeb, ani trendu k jejich maximalizaci. Snížením integračního koeficientu poněkud potlačujeme vliv situace minulých let a snížením derivačního koeficientu pak vliv změn. Celkově se bude náš prediktor tedy chovat poněkud opatrně a nebude mít tak silnou tendenci k výpočtu extrémních hodnot.

Koeficienty – výpočet dle různých metod		
Proporcionální k_p	Integrační k_I	Derivační k_D
1,0	0,2	0,5

*Tabulka č. 14:
Zvolené hodnoty koeficientů PID regulátoru.*

Stanovené výchozí a zároveň suboptimální hodnoty koeficientů P, S a D složky modelu regulátoru - prediktoru musíme „rozdělit“ mezi jednotlivé vysvětlující proměnné, čili jednotlivé složky vektoru výstupní veličiny, čili jim přiřadit náležité váhy. Tyto váhy získáme právě z dříve vypočtených indexů determinace. V následujícím maticovém zápisu výsledného modelu prediktoru modifikovaného na základě PID (PSD) regulátoru již použijeme zápisu veličin symbolizujících jednotlivé vysvětlující, respektive vysvětlované proměnné. Poněvadž interval vzorkování je v našem modelu jeden rok, vynecháme pro jednoduchost zápisu parametr T.

$$\begin{aligned}
Ty(k+1) = & k_p \cdot \begin{bmatrix} R_{Ty}^2 & R_{Ziv}^2 & R_{Ziv-1}^2 & R_{Lap}^2 & R_{Vac}^2 & R_{Pris}^2 \end{bmatrix} \cdot \begin{bmatrix} Ty(k) \\ Živ(k) \\ Živ_{-1}(k) \\ Lap(k) \\ Vac(k) \\ Pris(k) \end{bmatrix} + \\
& + k_I \cdot \begin{bmatrix} R_{Ty}^2 & R_{Ziv}^2 & R_{Ziv-1}^2 & R_{Lap}^2 & R_{Vac}^2 & R_{Pris}^2 \end{bmatrix} \cdot \begin{bmatrix} Ty(k-1)+Ty(k) \\ Živ(k-1)+Živ(k) \\ Živ_{-1}(k-1)+Živ_{-1}(k) \\ Lap(k-1)+Lap(k) \\ Vac(k-1)+Vac(k) \\ Pris(k-1)+Pris(k) \end{bmatrix} + \\
& + k_D \cdot \begin{bmatrix} R_{Ty}^2 & R_{Ziv}^2 & R_{Ziv-1}^2 & R_{Lap}^2 & R_{Vac}^2 & R_{Pris}^2 \end{bmatrix} \cdot \begin{bmatrix} Ty(k)-Ty(k-1) \\ Živ(k)-Živ(k-1) \\ Živ_{-1}(k)-Živ_{-1}(k-1) \\ Lap(k)-Lap(k-1) \\ Vac(k)-Vac(k-1) \\ Pris(k)-Pris(k-1) \end{bmatrix}
\end{aligned}$$

Tento predikční model, vyjádřený maticovou rovnicí, lze rozepsat do příspěvků jednotlivých vysvětlujících proměnných:

$$\begin{aligned}
Ty(k+1) = & k_p \cdot R_{Ty}^2 \cdot Ty(k) + k_I \cdot R_{Ty}^2 \cdot [Ty(k-1) + Ty(k)] + k_D \cdot R_{Ty}^2 \cdot [Ty(k) - Ty(k-1)] \\
& + k_p \cdot R_{Ziv}^2 \cdot Živ(k) + k_I \cdot R_{Ziv}^2 \cdot [Živ(k-1) + Ty(k)] + k_D \cdot R_{Ziv}^2 \cdot [Živ(k) - Živ(k-1)] \\
& + k_p \cdot R_{Ty}^2 \cdot Ty(k) + k_I \cdot R_{Ty}^2 \cdot [Živ_{-1}(k-1) + Živ_{-1}(k)] + k_D \cdot R_{Ty}^2 \cdot [Živ_{-1}(k) - Živ_{-1}(k-1)] \\
& + k_p \cdot R_{Ty}^2 \cdot Ty(k) + k_I \cdot R_{Ty}^2 \cdot [Lap(k-1) + Lap(k)] + k_D \cdot R_{Ty}^2 \cdot [Lap(k) - Lap(k-1)] \\
& + k_p \cdot R_{Ty}^2 \cdot Ty(k) + k_I \cdot R_{Ty}^2 \cdot [Vac(k-1) + Vac(k)] + k_D \cdot R_{Ty}^2 \cdot [Vac(k) - Vac(k-1)] \\
& + k_p \cdot R_{Ty}^2 \cdot Ty(k) + k_I \cdot R_{Ty}^2 \cdot [Pris(k-1) + Pris(k)] + k_D \cdot R_{Ty}^2 \cdot [Pris(k) - Pris(k-1)]
\end{aligned}$$

Budeme aplikovat tento algoritmus výpočtu na naše data týkající se lokality LS Opava – Hlubočec (Lokalita 1).

Nejprve vypočteme „váhy“ jednotlivých vysvětlujících proměnných, viz tabulka č. 15:

		R ²	p	k _P	k _D	k _I
				1	0,5	0,2
Kůrovec (t)	Ty	0,34	8,46E-10	0,34	0,17	0,068
Živelné (t)	Živ	0,04	4,74E-02	0,04	0,02	0,008
Živelné (t-1)	Živ-1	0,1	2,10E-02	0,1	0,05	0,02
Lapáky (t)	Lap	0,17	6,43E-03	0,17	0,085	0,034
Václavka (t)	Vac	0,07	3,04E-02	0,07	0,035	0,014
Přísušek (t)	Pris	0,65	4,43E-01	0,65	0,325	0,13
		1,37				

Tabulka č. 15:

Váhy jednotlivých vysvětlujících proměnných vyjádřené indexem determinace R² v roli multiplikativních váhových faktorů, jejich hladiny významnosti, zvolené suboptimální koeficienty PID regulátoru a jejich součiny s váhovými faktory.

Z tabulky č. 15 je dále patrné, že většina indexů determinace vyniká dosti vysokou hladinou významnosti. Nejnižší riziko, že zamítnutím nulové hypotézy o nezávislosti vysvětlované vysvětlující proměnné se dopustíme omylu, je pro případ tohoročních kůrovcových těžeb. Obvyklému 5% riziku by ale vyhověly všechny vysvětlující proměnné až na přísušek. Jeho hladina významnosti $p = 0,44$ je naprosto nesignifikantní. Tento závěr sice zpochybňuje vysokou hodnotu indexu determinace $R^2 = 0,65$, tedy i vysokou hodnotu multiplikativního faktoru koeficientů P, S a D části regulátoru, avšak je pochopitelný z charakteru vstupních dat týkajících se přísušku. Jediným řešením je další sběr a validace relevantních dat. Ze stejného (respektive stejných) důvodů není součet všech dílčích R² roven 1, nýbrž 1 převyšuje. To znamená, že jednotlivým vysvětlujícím proměnným byly přiřčeny indexy nadhodnocené, přičemž pravděpodobnost tohoto nadhodnocení roste (zřejmě nelineárně) s rostoucí hladinou významnosti dané proměnné. Z tohoto pohledu by tudíž bylo rozumné hodnotu 0,65 poněkud snížit a tím i součet indexů významnosti posunout k 1. Je však zároveň zcela zřejmé, že uvažované proměnné netvoří vyčerpávající množinu a zároveň, že jsou tyto proměnné do jisté míry i na sobě závislé, tedy korelované. Za této složité situace je tedy možné aplikovat přibližný model i s jeho diskrepancemi jako odpovídající suboptimální řešení.


S pomocí takto určených koeficientů již lze určit apriorní odhady predikčního regulátoru a srovnat je s reálnými hodnotami:

LOKALITA 1		Skutečnost						LOKALITA 1							Model	
Rok	k	Vysvětlující náhodné proměnné						Vysvětlující náhodné proměnné						Vysvětlovaná proměnná Ty+1 (m ³)	Odhledy od skutečnosti	
		Ty (m ³)	Živ (m ³)	Živ-1 (m ³)	Lap (m ³)	Vac (m ³)	Pris (dny)	Ty (m ³)	Živ (m ³)	Živ-1 (m ³)	Lap (m ³)	Vac (m ³)	Pris (dny)			
2004	1	258	162	162	119	511	28									
2005	2	143	113	113	95	660	50									
2006	3	536	109	109	81	584	64	0	6	14	-21	68	247	313	-223	
2007	4	343	188		199	337	30	295	6	15	-19	56	149	502	159	
2008	5	141						0	11	-3	-53	28	102	85	-56	
Suma za posl. 3 roky		1020												900	-120	
														Odhledy vůči skutečnosti	-40 / rok	

Tabulka č. 16:

Srovnání skutečnosti a simulace PID prediktorem pro data získaná z LS Opava – Hlubočec (Lokalita 1).

Lepší názornost výsledku podává trojrozměrný graf č. 21:



Graf č. 21:

Grafické vyjádření časového vývoje objemu kůrovcových těžeb dle skutečnosti a dle predikčního modelu – lokalita 1.

Je patrné, že predikční model skutečnost sice velmi dobře sleduje, ale se zpožděním daným vzorkovacím intervalem jednoho roku. Proto prediktor v roce 2006 nezbytný objem kůrovcové těžby podcenil, avšak toto „dopravní“ zpoždění napravil vyšším objemem kůrovcových těžeb v následujícím roce 2007. V dalším roce 2008 již na hodnoty vysvětlujících proměnných z roku 2007 a 2006 správně zareagoval výrazným snížením předpokládaných kůrovcových těžeb. Celkově prediktor generuje poněkud nižší objemy kůrovcových těžeb. Rozdíl za tři porovnávané roky činí - 40 m³ / rok.

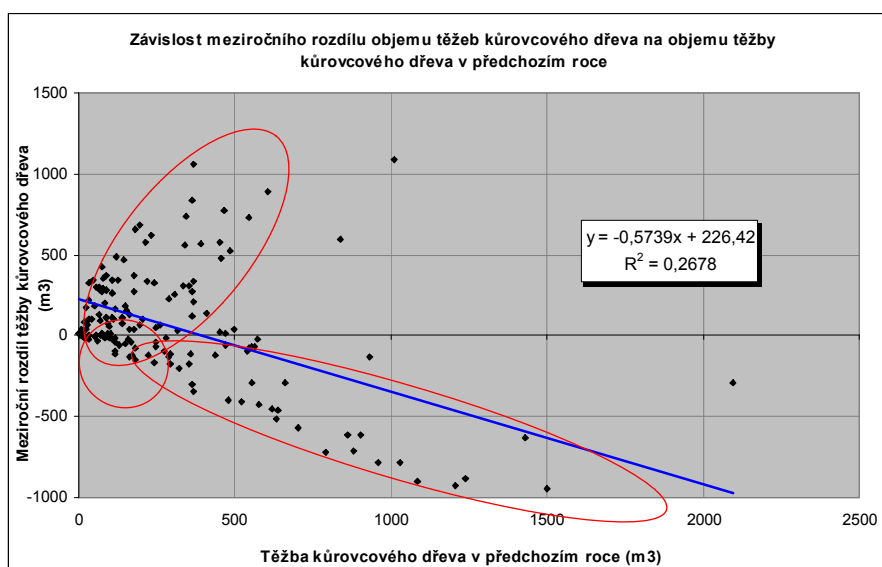
Je až překvapující skutečností, že i při značně limitovaných datech i diskrepancích matematického modelu lze hodnotit výsledky získané tímto modelem jako velmi uspokojivé. Dosažený výsledek by bylo možno ovšem dále zásadně zdokonalit, zvláště následujícími cestami:

- Pokud by byla k dispozici data za delší období, v nichž by se střídaly intervaly radikálního populačního růstu kůrovce s intervaly relativně stabilizované situace, bylo by možno nejen daleko lépe vyladit koeficienty regulátoru, ale také značně přesněji určit indexy determinace.
- Z pohledu dat z delšího časového období bude nutno zaměřit se rovněž na další zpřesnění stanovených vysvětlujících proměnných a především odstranit jejich skryté závislosti a nejednoznačnosti.
- Nezbytné a velice přínosné bude též vyhledání a stanovení ještě alespoň několika dalších, nových a efektivních vysvětlujících proměnných, s jejichž pomocí by bylo možno zároveň zkrátit interval vzorkování a tím zásadně zlepšit dynamiku predikčního regulátoru.

Výsledky 2 – aplikace diskrétní PID regulace s parametry nelineárních regresních modelů – LS Opava Pustá Polom

Poněvadž jsou v rámci dat dostupných v současnosti výše uvedené možnosti a. až c. dosud neproveditelné, zaměříme se na simulaci predikčního modelu s využitím dat z jiné, byť blízké lesní správy, kde lze očekávat podobné stanovištní, porostové, hospodářské a další podmínky a na následné porovnání výstupů poskytovaných predikčním modelem se skutečností. Výchozí údaje byly získané z LS Opava – Pustá Polom v letech 2002 až 2009.

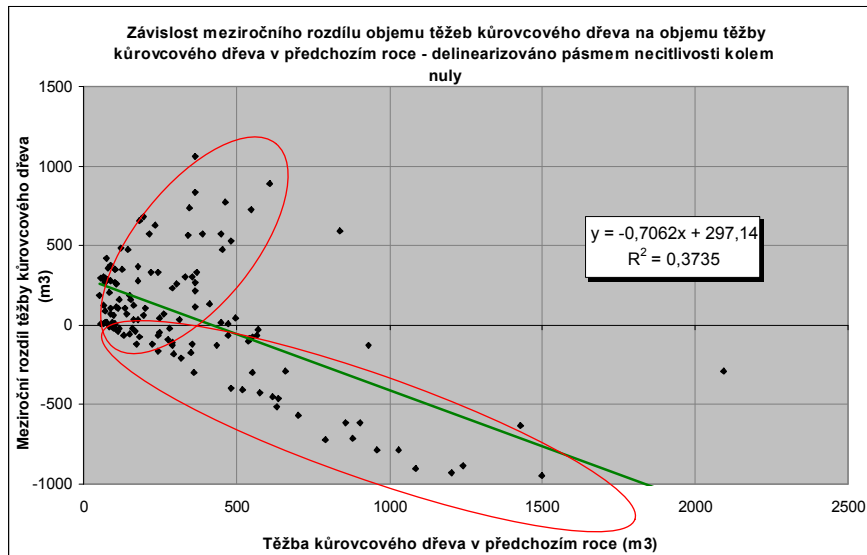
Zavedeme opět transformaci vysvětlované proměnné v podobě meziročního rozdílu vytěženého objemu kůrovcového dříví. Přitom nejprve zachováme linearitu dílčího regresního modelu. Výsledek ilustruje graf č. 22:



Graf č. 22:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu těžby kůrovcového dřeva v předchozím roce – lokalita 2 (Lesní správou Opava – Pustá Polom).

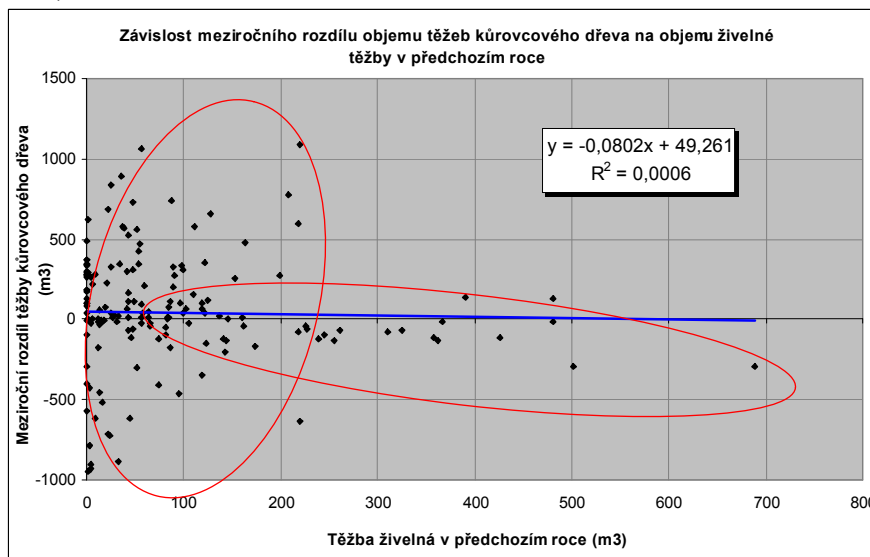
Index determinace přímkového regresního modelu činí $R^2 = 0,27$. Po zavedení nelinearity v podobě pásma necitlivosti kolem nuly vzroste tento index na hodnotu 0,37, viz graf č. 23:



Graf č. 23:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu těžby kůrovcového dřeva v předchozím roce - delinearizováno pásmem necitlivosti kolem nuly. – lokalita 2.

Tímto způsobem vytvoříme dílčí lineární i nelineární regresní modely pro zbývající vysvětlované, čili náhodné nezávislé proměnné lokality 2. Nejprve lineární regresní model pro živelné těžby (graf č. 24), který poskytuje velice malý index determinace ($R^2 = 0,0006$).




Graf č. 24:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu živelných těžeb v předchozím roce – lokalita 2 (Lesní správa Opava – Pustá Polom).

Z tohoto grafického vyjádření je opět zřejmé, že meziroční rozdíl těžeb kůrovcového dříví může s rostoucími živelnými těžbami v předchozím roce jak růst, tak i klesat. Poněvadž v souhrnu dat nemůžeme tyto dvě situace od sebe odlišit, je tudíž index determinace zdánlivě velmi nízký. Kdyby bylo zmíněné odlišení z principu možné, pak bychom získali vlastně dva odlišné a značně vysoké indexy determinace. Uplatnění tohoto dílčího regresního modelu dále komplikuje jeho linearita, která umožňuje plné uplatnění i malých hodnot z pásem necitlivosti kolem nuly. Ve shodě s dřívějším

postupem k již zavedenému pásmu necitlivosti vysvětlované proměnné definujeme ještě pásmo necitlivosti vysvětlující proměnné: Veškeré těžby živelné o objemu menším 50 m³ rovněž zanedbáme. Výsledek demonstruje graf č. 25:

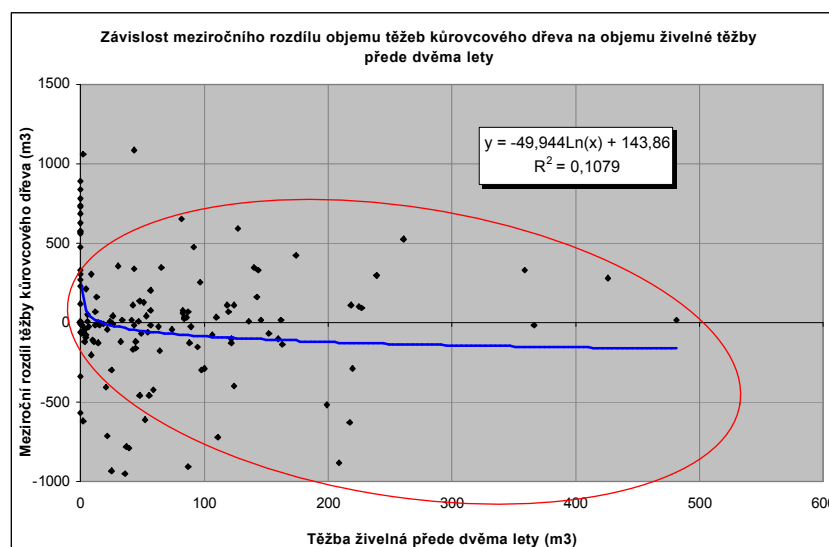


Graf č. 25:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu živelných těžeb v předchozím roce - delinearizováno pásmem necitlivosti kolem nuly – lokalita 2.

Získali jsme vyšší index determinace ($R^2 = 0,082$) a obě graficky dekomponované zcela odlišné závislosti mezi objemem živelných těžeb v předchozím roce a následným meziročním rozdílem objemů těžeb kůrovcových jsou jasněji vyznačeny. Zároveň jsme dosáhli alespoň poněkud vyšší strmosti regresní přímky.


Ovšem zcela jinou, stěží dekomponovatelnou závislost vykazuje vliv polomů a vývrátů, tedy objemu živelných těžeb, vyjádřený s ročním zpožděním, tedy takový, jaký byl přede dvěma lety (graf č. 26). Index determinace je přitom poměrně malý ($R^2 = 0,11$)



Graf č. 26:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu živelných těžeb přede 2 lety – lokalita 2 (Lesní správou Opava – Pustá Polom).

Za této situace ani zavedení pásma necitlivosti a tím delinerizace regresního modelu nepřináší nijaký efekt, index determinace se naopak ještě snižuje. Výsledek ilustruje graf č. 27




..

Graf č. 27:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu živelných těžeb přede 2 lety - delinearizováno pásmem necitlivosti kolem nuly – lokalita 2.


Další vysvětlující proměnnou je těžba lapáků. Závislost meziročního rozdílu objemu těžného kůrovcového dříví na objemu těchto těžeb představuje graf č. 28.



Graf č. 28:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu těžeb lapáků jako obranného opatření v předchozím roce – lokalita 2 (Lesní správa Opava – Pustá Polom).

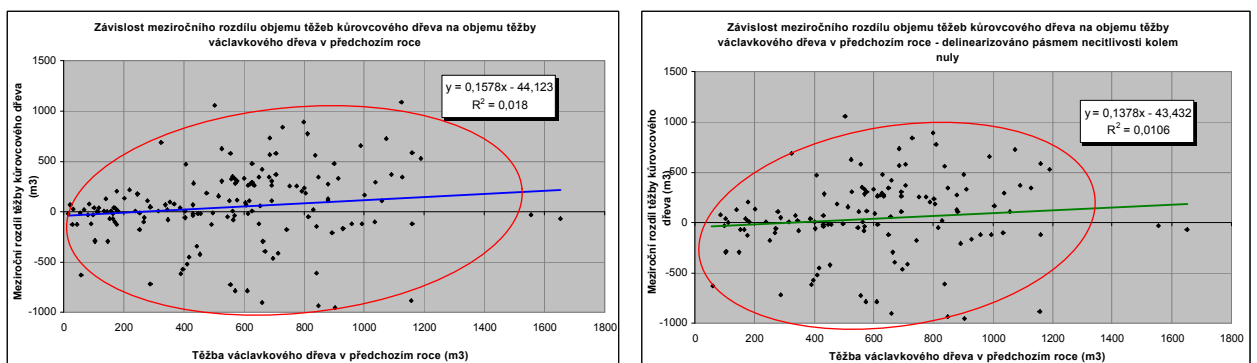
Je patrné, že zde do úvahy nepřipadá žádná smysluplná dekompozice této závislosti a index determinace je velice nízký ($R^2 = 0,008$), takže bychom zde mohli pochybovat o vlivu jinak obecně nejuznávanějšího obranného opatření. Ovšem po zavedení nelinearity se situace zásadně změní (graf č. 29) a index determinace už bude vyjadřovat 13% vliv na vysvětlovanou proměnnou.



Graf č. 29:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu těžeb lapáků jako obranného opatření v předchozím roce - delinearizováno pásmem necitlivosti kolem nuly – lokalita 2 (Lesní správou Opava – Pustá Polom).

Další možnou vysvětlující proměnnou je objem tracheomykózních těžeb, jejichž vliv na meziroční rozdíl objemu těžeb kůrovcového dříví je v podobě jednoduchého, čili dílčího lineárního regresního modelu i nelineárního regresního modelu vyjádřen v grafu č. 30:




Graf č. 30:

Závislost meziročního rozdílu objemu kůrovcového dřeva na objemu tracheomykózních těžeb v předchozím roce, lineární a nelineární model – lokalita 2 (Lesní správou Opava – Pustá Polom).

Je zřejmé, že s rostoucím objemem těžby václavkového dříví v předchozím roce roste i objem vytěženého kůrovcového dříví v následujícím roce, tedy populační dynamika kůrovce. Ovšem indexy determinace pro lineární model ($R^2 = 0,02$) i pro model nelineární ($R^2 = 0,01$) jsou malé.

Jako poslední vysvětlující proměnná, kterou se zde budeme zabývat, je přísušek, kvantifikovaný počtem dnů v daném roce. Vliv tohoto faktoru na meziroční rozdíl objemů těžby kůrovcového dřeva při lineárním i nelineárním modelu ilustruje graf č. 31. Výjimečně vysoký a zřejmě nereálný index determinace lineárního modelu s polynomem 5. řádu ($R^2 = 0,66$) se po delinearizaci a při přímkovém vyjádření závislosti snižuje na reálnější hodnotu ($R^2 = 0,13$).



Graf č. 31:

Závislost meziročního rozdílu objemu kůrovcového dřeva na počtu dnů s přísuškem v předchozím roce – lineární i nelineární model - lokalita 2 (Lesní správou Opava – Pustá Polom).

Z vypočtených a graficky ilustrovaných výsledků je patrné, že i ve velmi blízké lokalitě jsou regresní poměry značně odlišné. O to zajímavější bude následná aplikace predikčního modelu. Při aplikaci v zásadě stejného výše odvozeného matematického modelu tudíž nejprve stanovme příslušné váhy jednotlivých koeficientů PID (PSD) regulátoru, viz tabulka č. 17.

		R^2	p	k_P	k_D	k_I
				1	0,5	0,2
Kůrovec (t)	Ty	0,37	1,00E-10	0,37	0,185	0,074
Živelné (t)	Živ	0,08	5,58E-03	0,08	0,04	0,016
Živelné (t-1)	Živ-1	0,03	1,40E-01	0,03	0,015	0,006
Lapáky (t)	Lap	0,13	4,55E-03	0,13	0,065	0,026
Václavka (t)	Vac	0,02	3,30E-01	0,02	0,01	0,004
Přísušek (t)	Pris	0,5	8,35E-02	0,5	0,25	0,1
		1,13				

Tabulka č. 17:

Váhy jednotlivých vysvětlujících proměnných vyjádřené indexem determinace R^2 v roli multiplikačních váhových faktorů, jejich hladiny významnosti p , zvolené suboptimální koeficienty PID regulátoru a jejich součiny s váhovými faktory.

Zřetelně nesignifikantní je role živelných těžeb v minulém (z dřívějšího pojetí tedy v předminulém) roce ($p = 0,14$) a zvláště pak role tracheomykózních těžeb ($p = 0,33$). Obě tyto vysvětlující proměnné mají však i malý index determinace a tím i malou váhu.

Zajímavé je, že naopak role přísušku je spojena se sice běžně již nadhraniční, ale přece jen poměrně velmi přijatelnou hladinou významnosti ($p = 0,08$).


S pomocí takto určených koeficientů již lze určit apriorní odhady predikčního regulátoru a srovnat je s reálnými hodnotami lokality 2:

LOKALITA 2		Skutečnost								LOKALITA 2		Model				
Rok	k	Vysvětlující náhodné proměnné						Vysvětlující náhodné proměnné						Vysvětlovaná proměnná Ty+1 (m ³)	Odchylky od skutečnosti	
		Ty (m ³)	Živ (m ³)	Živ-1 (m ³)	Lap (m ³)	Vac (m ³)	Pris (dny)	Ty (m ³)	Živ (m ³)	Živ-1 (m ³)	Lap (m ³)	Vac (m ³)	Pris (dny)			
2002	1	99	0	0	95	605	0									
2003	2	327	106	106	65	609	0									
2004	3	802	85	85	87	595	28	195	14	5	-11	17	0	221	-581	
2005	4	216	209	209	91	655	22	468	9	3	-17	17	119	599	384	
2006	5	139	83	83	52	706	40	0	26	10	-17	19	73	111	-28	
2007	6	335	114	114	65	525	66	0	6	2	-8	20	154	174	-161	
2008	7	497	258		110	164	18	195	13	5	-12	14	100	315	-182	
2009	8	429						275	32	-1	-22	2	27	314	-115	
Suma za posl. 6 roků		2418												1734	-684	
														Odchylka vůči skutečnosti	-114 / rok	

Tabulka č. 18:

Srovnání skutečnosti a simulace PID prediktorem pro data získaná z LS Opava – Pustá Polom (Lokalita 2).

Lepší názornost výsledku podává trojrozměrný graf č. 32:



Graf č. 32:

Grafické vyjádření časového vývoje objemu kůrovcových těžeb dle skutečnosti a dle predikčního modelu – lokalita 2 – LS Opava – Pustá Polom.

Získali jsme výsledek, který předčil naše očekávání. Predikované hodnoty kůrovcových těžeb velmi dobře sledují skutečnost. Vzhledem k ročnímu vzorkovacímu intervalu predikční model sice „selhává“ generováním příliš nízké hodnoty výše očekávaných kůrovcových těžeb v roce 2004, ale již v následujícím roce citlivě dohání tuto diskrepanci a následně velmi dobře sleduje trend kůrovcové těžby.

Důležitou okolností je i to, že od predikované kůrovcové těžby lze dosti dobře odvozovat intenzitu potřebných obranných opatření, zejména počty lapáků.

Diskuse

Především je třeba zdůraznit, že zavedené a obvykle používané vyjadřování populační dynamiky v podobě logaritmu podílu, čili vyjadřování změny počtu jedinců určitého organismu v určitých časových intervalech, není žádným dogmatem, ale jen výhodnou matematickou transformací, uplatnitelnou zvláště v případě těch organismů, které jsou schopny rychlé progresse nebo naopak rychlé regrese přes několik dekadických řádů. Pokud však nemůžeme z principu pracovat přímo s počty jedinců, ale pouze s dopadem jejich zhoubného působení, tedy objemem ročních kůrovcových těžeb, pak výhoda této matematické transformace může být sporná, neboť může skrývat určité vazby a vztahy, které tak mohou unikat naší pozornosti a následné analýze. Podobně tomu může být i s vyjadřováním regresorů pomocí logaritmů.

V předložené práci se ukázalo, že vyloučení logaritmických transformací vysvětlované i vysvětlujících náhodných proměnných a vyjádření vysvětlované proměnné novou transformací v podobě meziročního rozdílu objemů kůrovcových těžeb, popřípadě zcela bez transformace „jen“ jako samotný objem kůrovcové těžby, kterou lze očekávat v následujícím roce, vede přinejmenším k odhalení nejednoznačnosti při působení některých regresorů na vysvětlovanou proměnnou. Ukazuje se, že meziroční rozdíl objemů kůrovcových těžeb v závislosti na těžbě kůrovce v předchozím roce sice typicky klesá, ale že někdy může i naopak růst, zvláště při objemu kůrovcových těžeb, které nejsou extrémně velké. Tato dekompozice je zvláště markantní po zavedení nelinearity typu „necitlivosti kolem nuly“ (graf č. 3 a č. 4, resp. č. 22 a č. 23) Vysvětlením tohoto jevu je, že v regresním modelu není zahrnuta jako vnitřní proměnná čas, totiž že roli plynoucího času v regresním modelu zcela zanedbáváme. Body regresního modelu, které odpovídají rostoucím objemům meziročních kůrovcových těžeb při rostoucím objemu těžby kůrovcového dříví v předchozím roce vyjadřují zřejmě situaci, kdy stav napadení porostu lýkožroutem není zvládnut a jeho populační dynamika je tudíž na vzestupu. Naopak, pokud meziroční těžby s rostoucí kůrovcovou těžbou předchozího roku klesají, svědčí to pro dosažení stavu, kdy účinnost radikálních asanací byla již úspěšná, napadení porostu kůrovcem je zvládnuto a populační dynamika lýkožrouta klesá. Zahrnout obě tyto závislosti v jediném regresním modelu neobsahujícím čas matematicky nelze. To je také hlavním důvodem snahy zavést do modelování a predikce populační dynamiky lýkožrouta dynamickou proměnnou čas.

Jak se ukázalo, lze někdy obdobným způsobem dekomponovat i další regresní modely, např. za situace, kdy jsou regresorem (nezávisle proměnnou) živelné těžby (graf č. 6, graf č. 8, resp. graf č. 24 a č. 25). Na vlivu živelných těžeb uskutečněných přede dvěma lety není už tato dekompozice tolik výrazná (grafy č. 7. a č. 8).

Příčinou duálního typu vlivu těchto regresorů na vysvětlovanou veličinu může být jak výše zmíněná parametrizace časem, tak i to, že pod jedinou číselně vyjadřovanou náhodnou proměnnou se ve skutečnosti skrývají dvě vysvětlující proměnné. Jedna z nich se přitom uplatňuje jen málo nebo skoro vůbec ne, druhá naopak velmi silně. Tak například kůrovcové dřevo řádně a včas asanované, vytěžené, vyklizené a vyvezené z lesa může již stěžít ovlivňovat další populační dynamiku lýkožrouta. Stejně tak polomové dříví, které vzniklo např. v lednu – zcela mimo vegetační období – a za období zimních mrazů bylo z lesa řádně v plném objemu odstraněno, nebude už zřejmě populační dynamiku kůrovce nikterak ovlivňovat.

Pro naše regresní modely bychom tudíž spíše než-li sumární roční data potřebovali znát data o objemu živelného i kůrovcového dřeva, které bylo v lese přítomno během období aktivity lýkožrouta, a nikoliv během jeho přezimovací fáze.

Tuto domněnku potvrzuje i ta skutečnost, že regresní modely s vysvětlujícími proměnnými ročním objemem vytěžených lapáků i ročním objemem vytěženého tracheomykózního dříví nelze duálně dekomponovat, neboť tento faktor václavkového oslabení stromů působí dlouhodobě a po celý rok se tudíž uplatňuje konstantně; lapáky jsou zase předmětem důsledné péče lesníků, pravidelných kontrol a důsledné asanace; viz grafy č. 9, 10, 11, 12, 29, 30.

Role přísušku je opět diskutabilní. V našich nelineárních regresních modelech je sice spojena s vysokými hodnotami indexu determinace, ale rozporuplnými hladinami významnosti. Skutečně účinné využití tohoto regresoru pro účely aproximace populační dynamiky lýkožrouta bezpochyby limituje to, že z dostupných dat nevíme, jaké fáze ročního ontogenetického vývoje lýkožrouta vlastně přísušek zasahoval.

Upřesněním regresorů ve smyslu výše uvedené diskuse bychom naše regresní modely jistě dále významně zpřesnili. Tím bychom ovšem zpřesnili i koeficienty PID (PSD) regulátoru a následně i predikci populační dynamiky lýkožrouta pro následující rok. Současně se zpřesněním indexů determinace jednotlivých vysvětlujících proměnných bychom upřesnili i estimaci „periody netlumených kmitů“ a odpovídajícího „kritického zesílení“ řízeného dynamického systému, kterým je náš kůrovcem napadáný smrkový lesní porost. To by přirozeně vedlo k dalšímu vylepšení odhadu koeficientů PID (PSD) regulátoru – prediktoru.

Zásadním krokem by ovšem mohlo být zkrácení „vzorkovacího“ časového intervalu, třeba i za cenu toho, že tento interval bude neekvidistantní. Znamenalo by to, že kromě regresorů validizovaných podle výše naznačených úprav, bychom zavedli další vysvětlující proměnné, spojené již přímo s aktivní životní fází ročního cyklu lýkožrouta. Takovým regresorem by např. mohl být průměrný počet jedinců identifikovaných pod otráveným trojnožkovým lapákem po prvním rojení. Tímto postupem bychom vlastně jen zdokonalovali a matematizovali to, co lesnická praxe i ČSN 481000 ve víceméně kvalitativní podobě běžně používá. Zcela zásadním způsobem bychom tím však zřejmě snížili časové zpoždění prediktoru a přiblížili jeho funkci skutečné regulaci, která by dovozovala rychle a velmi účinně vyhodnocovat dopad obranných opatření a účinně minimalizovat ztráty působené lýkožroutem.

Zůstává však otázka vhodnosti volby PID (PSD) algoritmů regulace. Ač se tento přístup v předložené práci ukázal jako účinný, není v tomto matematickém modelu zahrnuta ani jeho schopnost poznávání a samočinného zpřesňování parametrů tohoto modelu (ta by musela být pro jednotlivé lokality a různá období prováděna ručně), ani jeho schopnost inherentně propojit řídicí (akční) veličinu a veličinu stanovenou. Tuto schopnost by zřejmě měly až algoritmy optimálního stochastického řízení při stanoveném modelu situace (Leigh, J. R., 1992; Balátě, J., 2004; Wittenmak, B., Aström, K. J., Arzen, K.-E., 2001).

Závěr

V předložené diplomové práci byly nejprve zavedením nelinearit typu „necitlivosti kolem nuly“ zpřesněny regresní modely sloužící pro aproximaci populačního růstu *Ips typographus* (*L*). Pro tento účel posloužilo i zavedení matematické transformace vysvětlované proměnné ve formě meziročního rozdílu objemů kůrovcových těžeb. Tato transformace poukázala na skrytou dualitu některých vysvětlujících proměnných. Zpřesněných indexů determinace pak bylo využito při konstrukci matematického prediktoru, založeného na bázi modifikovaných algoritmů PID (PSD) regulace. Takto získaný prediktor se osvědčil při uplatnění s datovým materiálem získaným v lokalitě LS Opava Hlubočec a zvláště pak při simulaci s daty z lokality LS Opava-Pustá Polom.

Literatura

- Aström, J., Hägglund, T., 1995:
PID Controllers: Theory, Design and Tuning.
Second Ed. Research Triangle Park – North Caroline, Instrument Society of America.
- Balátě, J., 2004:
Automatické řízení. BEN tech. lit., 2. vydání, Praha 2004.
- Becker, T., Schröter, H., 2000:
Aushereitung und rindenbrutenden Brohenkafern nach Sturmschaden. Allg. Forstztg.,
55: S. 280 – 282.
- Heurich, M. Reinelt, A., Fahse, L., 2001:
Die Buchdrucker massenvermehrung in Nationalpark BayerischerWald. In: Heurich,
M., (Ed.), Waldentwicklung im Bergwald nach Windwurf und Borkenha ferbefall.
Bayer. Staatsforstverwaltung Wiss. Reihl, Grafenau, vol. 14: 9 – 18.
- Hlásny, T., Holuša, J., Turčáni ,M. 2011:
Oblasti umožňující vývoj daného počtu generací lýkožrouta smrkového (*Ips
typographus*) za rok na území České republiky v období 1961–1990. Česká zemědělská
univerzita v Praze, Ústavb pro hospodářskou úpravu lesů, Brandýs nad Labem,
dostupné přes geoaplikaci na www.climips.cz. Certifikát č. 232846/2011-MZE-
16222/MAPA16. Specializovaná mapa.
- Holík, M., 1999:
Nelineární regrese v chemické kinetice. Studie F 457/1999, Katedra teoretické a fyz.
chemie. Přírodovědecká fakulta MU, Brno, 1999.
- Holuša, J., Lubojacký, L., Knížek M., 2010:
Distribution of double-spined spruce bark beetle *Ips duplicatus* in the Czech Republic:
spreading in 1997–2009. Phytoparasitica, 38: 435-443.
- Holuša, J., Lukášová, K., Lubojacký, J.: 2012:
Comparison of seasonal flight activity of spruce bark beetle (*Ips typographus*) with
flight activity of northern bark beetle (*Ips duplicatus*) (*Coleoptera: Curculionidae*).
Scientia Agriculturae Bohemica, 43: 109-115.
- Holuša, J., Weiser, J., Žižka, Z.: 2009:
Pathogens of the spruce bark beetles *Ips typographus* and *Ips duplicatus*, Central
European Journal of Biology, 4: 567-573.
- Horák, J., Nakládal, O.: 2009:
Predace mezi brouky vázanými na dřeviny: část II. Vliv predace na lesní ekosystémy a
důsledky pro praxi. Lesnický časopis (Forestry Journal), 1: 85-91.
- Juha, M., Lukášová, K., Holuša, J., Turčáni, M., 2012:
Netradiční způsoby boje s lýkožroutem smrkovým – *Ips typographus* (*Coleoptera:
Curculionidae*). Certifikovaná metodika, Lesnický průvodce, Výzkumný ústav lesního
hospodářství a myslivosti, v. v. i., Jíloviště-Strnady, 19 pp. ISBN 978-80-7417-058-4

- Juha, M., Turčáni, M., 2008:
Netradiční způsoby boje s lýkožroutem smrkovým – *Ips typographus* L. (Coleoptera: Scolytidae). Zprávy lesnického výzkumu, 5: 1-5.
- Klán P., Matoušek J., 1992:
Interactive Engineering Software for Control Simulations and PID Tme Expert Advising, ÚTIA ČSAV, Praha, 1992.
- Klán, P., 2000:
Moderní metody nastavení PID regulátorů. Automa, č. 8-9, s 54-57.
- Klán, P., 2001:
Metody zlepšení PI regulace. Automa, č. 12, s. 4-10.
- Krejčí, F, 2000:
Posouzení lesního hospodářství NP Šumava v letech 1991 – 1999. Park Servis Šumava s.r.o., Lesnická práce 79 (12): 555.
- Leigh, J. R., 1992:
Applied Digital Control: Theory, Design and Implementation. Second Edition, Prentice Hall International (UK), 1992.
- Lubojacký, J. 2012:
Vývoj legislativy související s ochranou lesů před lýkožroutem smrkovým (*Ips typographus* L.) v českých zemích do současné podoby. Zprávy lesnického výzkumu, 57: 189-193.
- Lukášová, K., Holuša, J., 2011:
Přirození nepřítelé a biologický boj s *Dendroctonus micans*: review. Zprávy lesnického výzkumu, 56: 15-23.
- Matoušek, P., 2012:
Populační dynamika lýkožrouta smrkového (*Ips typographus* L.) v různých gradačních fázích: Plodnost na klasických lapácích.
Disertační práce, Česká zemědělská univerzita v Praze, Praha, 2012.
- Matoušek, P., Modlinger, R., Holuša, J., Turčáni, M., 2012:
Počet vajíček kladených lýkožroutem smrkovým *Ips typographus* (L.) (Coleoptera: Curculionidae: Scolytinae) na stromových lapácích: vliv vybraných faktorů. Zprávy lesnického výzkumu, 57: 126-132.
- Meloun, M., Militký J., 2004:
Statistická analýza experimentálních dat. AV ČR, Academia, Praha.
- Ožana, Š., 2012:
Navrhování a realizace regulátorů. Technická univerzita Ostrava, Ostrava, 2012.
- Skuhřavý, V., 2002:
Lýkožrout smrkový (*Ips typographus* L.) a jeho kalamity (Der Buchdrucker und ihre seine Kalamitäten). Agrospoj, Praha, 196 s.

- Turčáni. M., 2009:
Šumava: Kostky jsou vrženy, bohužel. Lesnická práce, 10: 8-9.
- Vašek, V. , 1990:
Teorie automatického řízení II., VUT Brno, Brno, 1990.
- Víteček, A., 1988:
Matematické metody automatického řízení. Ostrava: VŠB – TU Ostrava.
- Vítečková, M. , Víteček, A., 2006:
Základní automatické regulace. 1.vyd., Ostrava, VŠB – TU Ostrava.
- Wittenmak, B., Aström, K. J., Arzen, K.-E., 2001:
Computer Control: An Overview. Depart. of Aut. Control., Lund, Sweden, 2001.
- Zumr. V., 1995:
Lýkožrout smrkový – biologie, prevence a metody boje. Matice lesnická, Písek, 131 s.