

# BIOMETRICKÉ POSTUPY VHODNÉ NA OBJEKTIVIZÁCIU ÚDAJOV O LESE, OVERENÉ POČÍTAČOVÝMI SIMULÁCIAMI NA DIGITÁLNYCH MODELOCH LESNÝCH PORASTOV

ŠTEFAN ŠMELKO

Národné lesnícke centrum - Lesnícky výskumný ústav Zvolen, T. G. Masaryka 22,  
SK – 960 92 Zvolen, e-mail: smelko@nlcsk.org

ŠMELKO, Š., 2012: Biometric approaches applicable for objectification of forest information, tested by computer simulations using digital models of forest stands. Lesn. Čas. – Forestry Journal, 58(1): 21-34, 3 fig., tab. 11, ref. 16. Original paper. ISSN 0323 – 1046.

The paper is aimed at enhancing the quality of information obtained from forest and land, particularly to identify and eliminate systematic bias of existing information and to correct and update them using a small-scale control sampling. Attention is drawn to the procedure known as „List Sampling“. A digital forest of an area over 1600 ha was created, in which a correct as well biased (from -15 up to -25%) information on basal area of 257 stands are simulated. There are tested three ways of the sampling of control forest stands (simple systematic sampling, and PPS and PPP sampling). In the forest stands, the simulation of real basal area is done using the software STIPSI and the results are processed employing the adequate algorithm (Regression, Ratio, and PPS and PPP). Comparing the biased, revised and correct data, statistical as well as real confidence intervals for all the tested variants are derived and knowledge of their properties and conditions for its wider practical use is formulated.

**Key words:** *objectification of the information on forests using the control survey sampling, the removal of systematic bias, correction and updating of data, sampling procedures and sampling algorithms List sampling – a simple, PPS and PPP sampling, experimentation in the digital forest using computer simulations*

Príspevok je zameraný na zvýšenie kvality informácií získavaných o lese a krajine, najmä na zistenie a odstránenie systematického vychýlenia v existujúcich údajoch a na ich korekciu a aktualizáciu pomocou malého rozsahu kontrolného výberového zisťovania. Pozornosť sa venuje postupom známym pod názvom „List Sampling“. Vytvorený je digitálny les o výmere vyše 1 600 ha, v ktorom sú simulované správne a o -15 až -25 % vychýlené údaje o kruhovej základni 257 porastov. Skúšajú sa tri spôsoby výberu kontrolných porastov (jednoduchý systematický výber, PPS a PPP výber), v nich sa pomocou počítačového programu STIPSI simuluje zistenie skutočnej kruhovej základne na kruhových skusných plochách a výsledky z kontrolného výberu sa spracúvajú zodpovedajúcimi algoritmami (Regresia, Ratio, PPS a PPP). Porovnaním vychýlených, skorigovaných a správnych údajov sa odvodzujú štatistické i skutočné rámce presnosti všetkých skúšaných variantov a formulujú sa poznatky o ich vlastnostiach a podmienkach pre širšie praktické využitie.

**Kľúčové slová:** *objektivizácia informácií o lese kontrolným výberovým zisťovaním, odstránenie systematického vychýlenia (Bias), korekcia a aktualizácia údajov, výberové postupy a algoritmy List sampling – jednoduchý, PPS a PPP výber, experimentovanie na digitálnom lese pomocou počítačových simulácií*

## 1. Problematika a cieľ práce

Údaje o lese zisťované alebo preberané z už existujúcich informačných zdrojov môžu mať rôznu kvali-

tu – tzv. výpovednú hodnotu, čiže mieru zhody so skutočnosťou. Túto kvantifikujú dva ukazovatele: systematické vychýlenie a náhodné kolísanie údajov (ŠMELKO

2007). Za kvalitnejšie sa považujú všeobecne tie údaje, ktoré nie sú zafaržené systematickou chybou (sú správne, skutočný stav ani nepodhodnocujú ani nenadhodnocujú), majú malú variabilitu okolo priemernej hodnoty (vysokú presnosť) a súčasne sa dajú získať s minimálnymi pracovnými i finančnými nákladmi.

Často sa vyskytuje potreba preveriť kvalitu údajov a to z dvoch dôvodov:

- keď vznikne podozrenie, že existujúce údaje sú vychýlené (napr. v lesných hospodárskych plánoch, vo výsledkoch prieskumu ekológie lesa, v evidencii o ťažbe a predaji dreva ap.), alebo
- keď sa zámerne používajú také metódy zisťovania, ktoré priamo vyžadujú následnú kontrolu resp. aj korekciu, tzv. adjustáciu údajov (napr. dvojfázové zisťovanie, kombinácia leteckého a pozemného zisťovania, kombinácia okulárneho odhadu a merania ap.).

Adekvátnymi biometrickými postupmi na riešenie týchto úloh je pre a) tzv. List Sampling – výber zo zoznamu (súpisu) už známych údajov a pre b) tzv. Double Sampling – dvojitý (dvojfázový) výber, prvý väčší o rozsahu  $n_1$  ale menej presný, druhý menší o rozsahu  $n_2$  ale presnejší. Okrem toho existuje aj ďalší postup, tzv. Sequential Sampling – sekvenčný výber, ktorý je špecifický v tom, že umožňuje veľmi hospodárne zistiť určité vopred jednoznačne definované znaky veličín (napr. výskyt určitého množstva cenných sortimentov, stupňa poškodenia, prirodzenosti, ekologickej stability lesného ekosystému ap.). Jeho veľkou výhodou je to, že rozsah výberového zisťovania sa nestanovuje vopred, ale určí sa automaticky, lebo zisťovanie sa ukončí, keď sa zadaná úloha splní so zvolenou, obvyčajne 95 % istotou.

Teoretické princípy týchto výberových postupov sú vo svetovej biometrickej literatúre pomerne dobre rozpracované (napr. LOETSCH & HALLER 1973, COCHRAN 1977, ZÓHRER 1980, DEVRIES 1986, ŠMELKO 1990, SHIVER & BORDERS 1996 a i.). Niektoré z nich boli aj úspešne použité, najmä v rôznych variantoch inventarizácie lesa. Ich vlastnosti, najmä zhoda výberových výsledkov so skutočnosťou, neboli však ešte dostatočne overené a komplexnejšie navzájom porovnané. Preto sa v predkladanej práci zameriame na zhodnotenie vlastností a praktickej použiteľnosti prvej skupiny výberových postupov „List Sampling“, a to maximálne objektívnym spôsobom – počítačovými simuláciami na digitálnom modeli lesa. Ďalšie dve metódy preskúmame podobným spôsobom v nasledujúcom príspevku.

## 2. Základná koncepcia overovania a prípadnej korekcie údajov o lese s využitím postupov „List Sampling“

Problematika bezprostredne súvisí s úlohou, ktorú v súčasnosti riešime v rámci projektu zo štrukturálnych fondov EU v „Centre excelentnosti pre podporu rozhodovania v lese a krajine“ na TU a NLC Zvolen, v aktivite 3.2a „Návrh metódy na zobjektívnenie hospodár-

ske-úpravníckych údajov o stave lesov SR kontrolným výberovým meraním a biometrický model na ich korekciu“. Preto celú koncepciu riešenia predstavíme na príklade súboru porastov nachádzajúcich sa v rámci jedného lesného celku. Vyjdeme z týchto predpokladov:

- V konkrétnom lesnom celku máme k dispozícii údaje o jeho výmere (P) a o veličine  $X$  pre každú jednotku priestorového rozdelenia lesa (JPRL<sub>*i*</sub>,  $i = 1, 2, 3 \dots N$ ). Veličina  $X$  je podozrivá, že je zafaržená systematickou chybou, preto ju nazveme ako „vychýlená“ alebo „overovaná“.
- Pre overenie možného systematického vychýlenia  $X$  voči skutočnosti sa z celého  $N$  súboru JPRL vyberie malý počet  $n$  kontrolných JPRL<sub>*j*</sub> ( $j = 1, 2, 3 \dots n$ ) a v každej z nich sa vykoná kontrolné meranie presnejšou metódou – priamym meraním (napr. celoplošne alebo reprezentatívne na  $m$  kruhových, resp. re-laskopických skusných plochách). Výsledkom bude kontrolný – „správny“, „nevychýlený“ údaj o tej istej veličine, ktorú označíme ako  $Y$ .
- Zhodnotením vychýlených údajov  $X_i$  a údajov kontroly  $Y_j$  v tých istých JPRL<sub>*j*</sub> sa posúdi ich rozdiel na princípe štatistického testu a v prípade potvrdenia systematického vychýlenia sa vychýlené údaje  $X_i$  vo všetkých JPRL<sub>*i*</sub> ( $i = 1, 2, \dots N$ ) primerane skorigujú na hodnoty  $X_{kor(i)}$ .
- Na skorigovanie údajov  $X_{kor}$  a stanovenie rámca presnosti korekcie  $S_{X(kor)}$  sa použije špeciálny biometrický postup patriaci do skupiny „List sampling“, pretože v tomto prípade sú dobre splnené obidve teoretické podmienky, ktoré sa pre jeho správnu aplikáciu vyžadujú, a to:
  - k dispozícii sú údaje o všetkých jednotkách základného súboru (t. j. JPRL v rámci celého LC) a
  - medzi týmito údajmi a novou (presnejšou, objektívnejšou) informáciou o nich možno očakávať tesný lineárny korelačný vzťah.
- Pre samotnú kontrolu a korekciu vychýlených údajov  $X$  do úvahy prichádzajú tieto varianty riešenia:
  - štyri spôsoby výberu kontrolných porastov (jednoduchý výber náhodný alebo systematický, PPS a PPP výber) a
  - štyri algoritmy spracovania výberových údajov (regresná rovnica, pomer R, algoritmus PPS a algoritmus PPP).
- Jednotlivé spôsoby výberu porastov a následnej korekcie údajov sú vo vzájomnej nadväznosti a nesmú sa zamieňať. Aby sme mohli objektívne zistiť ich vlastnosti, posúdiť a porovnať ich efektívnosť a stanoviť podmienky na ich optimálnu praktickú použiteľnosť, všetky podrobíme experimentálnym porovnávacím skúškam.

## 3. Metodológia experimentov

Overovacie skúšky všetkých do úvahy prichádzajúcich variantov „List Sampling“ riešenia vykonáme veľmi

efektívnym a maximálne objektívnym metodickým postupom s využitím moderných počítačových a biometrických technológií. Výberovou jednotkou budú jednotlivé porasty (JPRL) a overovanou veličinou bude kruhová základňa všetkých stromov v celom poraste  $G$  a na 1 hektár  $G(\text{ha})$ . Kvôli zjednodušeniu zavedieme túto jednotnú symboliku:

$N$  – počet všetkých porastov v LC,  
 $n$  – počet kontrolných porastov,  
 $X_i$  – „vychýlené“ porastové a  $x_i$  – hektárové údaje jednotlivých porastov  $i = 1, 2 \dots N$ ,  
 $\tau_x$  – úhrn údajov  $X_i$  (total =  $\sum_{i=1}^N X_i$ ) a  $\mu_x$  – priemer údajov  $X_i$  ( $= \tau_x/N$ ),  
 $Y_i, y_i, \tau_y, \mu_y$  – detto, ale pre „správne“ údaje základného súboru (digitálneho lesa),  
 $X_j, x_j, Y_j, y_j$  – údaje kontrolného merania (KM) vo vybratých kontrolných porastoch ( $j = 1, 2 \dots n$ ) „vychýlené“ a „správne“.

### 3.1. Vytvorenie experimentálneho digitálneho lesa

Digitálny les je nový názov pre súbor reálnych alebo počítačom vygenerovaných lesných porastov s rozmanitou vnútornou štruktúrou, v ktorých poloha všetkých stromov je zachytená na súradniciach a známe sú tiež všetky dendrometrické veličiny stromov aj celého porastu a drevín. Z biometrického hľadiska takýto les predstavuje základný súbor, z ktorého sa pomocou špeciálnych počítačových programov môžu simulovať výberové zisťovania rôznymi typmi skusných plôch a získať nie-

len štatistické rámce presnosti uskutočneného výberu, ale aj skutočné chyby (diferencie) výberu voči základnému súboru. Celý postup je veľmi výhodný a vyznačuje sa tým, že údaje o základnom súbore sú určené úplne jednoznačne (správne), zistené výsledky nie sú vôbec ovplyvnené subjektívnymi činiteľmi a skúšky na počítači sa dajú vykonať veľmi rýchlo a hospodárne, čo sa pri bežných experimentoch v teréne vôbec nedá dosiahnuť.

Pre naše pokusy sme takýto digitálny les a počítačový program STIPSI získali vďaka dlhoročnej intenzívnej spolupráci s partnermi v Nemecku (prof. Schöpfer, prof. Hradetzky, Lesnícky výskumný ústav vo Freiburgu i. Br.), ktorým sa podarilo zhromaždiť modelové digitálne porasty z mnohých krajín Európy (vrátane 9 modelov zo Slovenska – ŠMELKO, 1979) a vyvinúť spomínaný program STIPSI (2008). Z týchto podkladov sme vytvorili základný súbor  $N = 259$  porastov o výmere  $P = 1\,632,2$  ha a rozčlenili sme ho na tri homogénne skupiny (agregované rastové stupne – RS). Pre každý porast sme vygenerovali dva údaje o kruhovej základni ( $G$  aj  $G \cdot \text{ha}^{-1}$  v  $\text{m}^2$ ) a to „správnu“ zodpovedajúcu reálnym hrúbkam stromov v porastoch, označenú ako  $G(S)$  a „vychýlenú“ o 25 %, 20 % a 15 %, označenú ako  $G(V)$ .

Súhrnné charakteristiky o tomto digitálnom lese sú v tabuľkách 1 a 2 a v obrázkoch 1(a, b, c). Vyplýva z nich, že

- Zastúpenie porastov v rastových stupňoch digitálneho lesa podľa  $N$  a podľa  $G$  je takmer rovnaké.
- Diferencie  $G(V)$  voči  $G(S)$  dosahujú -25 až -15 %,

**Tabuľka 1.** Základné údaje o výmere ( $P$ ), počte porastov ( $N$ ), kruhovej základni ( $G$ ) vo vytvorenom „digitálnom lese“ a o jeho štruktúre podľa rastových stupňov (RS),  $G(S)$  – správne a  $G(V)$  – vychýlené hodnoty v  $\text{m}^2$

**Table 1.** Basic information on area ( $P$ ), number ( $N$ ) and basal area ( $G$ ) of forest stands in established „digital forest“ and on its structure by growth stages (RS),  $G(S)$  – correct and  $G(V)$  – biased values in  $\text{m}^2$

| RS                  | P(ha)   | P(%)  | N   | N%    | G(S) $\text{m}^2$ | G(S)% | G(V) $\text{m}^2$ | Dif.G% |
|---------------------|---------|-------|-----|-------|-------------------|-------|-------------------|--------|
| 4+5                 | 388,6   | 23,8  | 74  | 28,6  | 9 808,1           | 21,7  | 7 403,9           | -24,5  |
| 6+7                 | 896,6   | 54,9  | 127 | 49,0  | 25 823,4          | 57,2  | 20 658,7          | -20,0  |
| 8+9                 | 347,0   | 21,3  | 58  | 22,4  | 9 523,6           | 21,1  | 8 124,6           | -14,7  |
| Spolu <sup>1)</sup> | 1 632,2 | 100,0 | 259 | 100,0 | 45 155,1          | 100,0 | 36 187,4          | -19,9  |

RS 4 – žrdkoviciny – *small pole stage*, 5 – žrdoviciny – *pole stage*, 6 – mladé – *small-sized*, 7 – stredné – *medium-sized*, 8 – hrubé – *large-sized*, 9 – veľmi hrubé kmeňoviny – *very large-sized large-diameter stands*.

**Tabuľka 2.** Charakteristiky  $P$  a  $G$  digitálneho lesa v RS 4+5,  $N = 74$  porastov  $G(S)$  – správne a  $G(V)$  – vychýlené hodnoty kruhovej základne v  $\text{m}^2$

**Table 2.** Characteristics  $P$  and  $G$  of digital forest in growth stages 4+5,  $N = 74$  forest stands,  $G(S)$  – correct and  $G(V)$  – biased values in  $\text{m}^2$

| Charakteristika <sup>1)</sup> | P (ha) | Gha(V)  | Gha(S)  | G(V)    | G(S)    |
|-------------------------------|--------|---------|---------|---------|---------|
| Suma <sup>2)</sup>            | 388,6  | 1 403,4 | 1 858,8 | 7 403,9 | 9 808,1 |
| Priemer <sup>3)</sup>         | 5,2    | 19,0    | 25,1    | 100,1   | 132,5   |
| SmOdch <sup>4)</sup>          | 3,4    | 6,7     | 8,8     | 70,3    | 92,7    |
| VarKoef. <sup>5)</sup>        | 64,7   | 35,3    | 35,2    | 70,3    | 69,9    |

<sup>1)</sup>Characteristics, <sup>2)</sup>Sum, <sup>3)</sup>Average, <sup>4)</sup>Standard deviation, <sup>5)</sup>Variation coefficient

v priemere -20 %. Toto vychýlenie markantne dokumentuje aj obrázok 1a a vyskytuje sa v celom rozpätí výmery porastov od 0,3 po 16 ha.

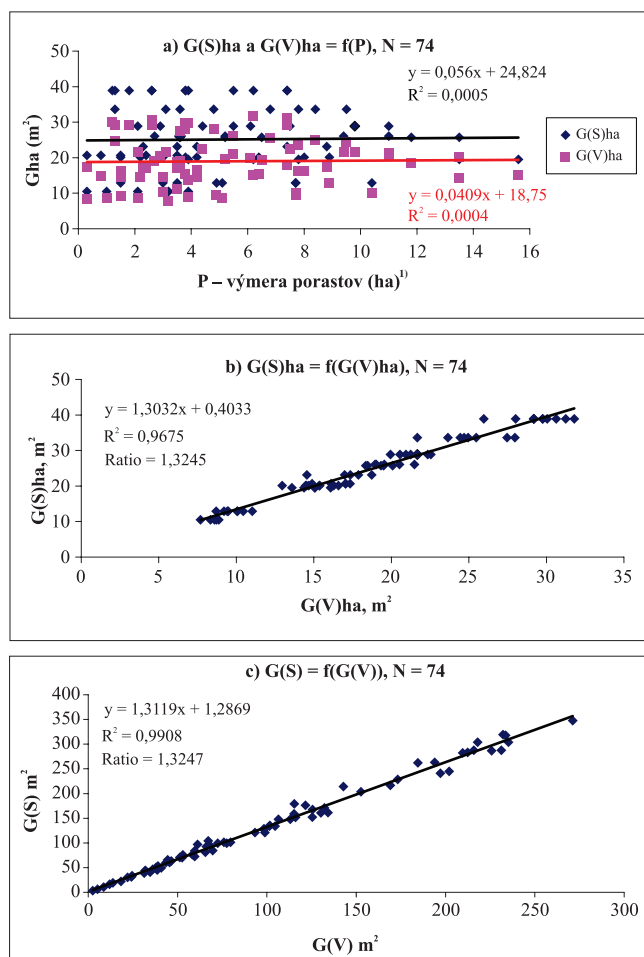
- Na relatívnej variabilite porastových hodnôt  $G$  (asi 70 %) sa výrazne podieľa variabilita výmery  $P$  (65 %), hektárové hodnoty  $G(\text{ha})$  kolíšu menej (35 %).
- Závislosť medzi správnymi a vychýlenými hodnotami  $G$  v celých porastoch je zákonite tesnejšia ako medzi ich hektárovými ekvivalentmi, lebo v porastových údajoch je zahrnutá aj výmera porastov (porovnaj obr. 1b a 1c).

### 3.2. Výbery kontrolných porastov z digitálneho lesa

Skúšaniamu sme podrobili tri výberové postupy prichádzajúce pre daný účel do úvahy, a to:

- JSV (jednoduchý systematický výber) JPRL* z ich priebežného poradia ( $i = 1$  až  $N$ ) v digitálnom lese, s krokom  $k = N/n$  a náhodným štartom v rozpätí 1 až  $k$ . Každá JPRL mala rovnakú pravdepodobnosť dostať sa do výberu, bez ohľadu na jej veľkosť.
- PPS výber JPRL* s pravdepodobnosťou úmernou ich výmere. Vyberali sa z poradia kumulatívnych hodnôt výmery  $P_i$  ( $i = 1$  až  $\sum_i^N P_i$ ). JPRL mali tým väčšiu možnosť dostať sa do výberu, čím boli väčšie.
- PPP výber JPRL* s pravdepodobnosťou úmernou ich kruhovej základni  $G_i$ . Vyberali sa z poradia kumulatívnych hodnôt  $G_i$  ( $i = 1$  až  $\sum_i^N G_i$ ). JPRL mali tým väčšiu možnosť dostať sa do výberu, čím mali väčšiu celkovú kruhovú základňu (a teda aj zásobu).

Počet kontrolných porastov (rozsah výberu  $n$ ) sa zvolil rovnaký pre všetky tri výberové postupy, v jednotlivých rastových stupňoch (RS) bol  $n = 5 - 20 - 15$ , spo-



**Obr. 1(a, b, c).** Základný súbor – digitálny les, RS 4+5,  $N = 74$  porastov. Porovnanie hektárových a celkových hodnôt vychýlenej  $G(V)$  a správnej  $G(S)$  kruhovej základne a ich vzájomné závislosti

**Fig. 1(a, b, c).** Entire population – digital forest, growth stages 4+5,  $N=74$  forest stands. Comparison of per hectare and total values of biased  $G(V)$  and correct  $G(S)$  basal area and their relationships

<sup>1)</sup>Forest area (ha)

**Tabuľka 3.** Výbery  $n = 15$  porastov z  $N = 74$  porastov digitálneho lesa, RS 4+5

**Table 3.** Samples of  $n = 15$  forest stands from  $N = 74$  stands in the digital forest, GS 4+5

| JSV<br>Por.<br>číslo | PPS       |              | PPP                    |                        |                |
|----------------------|-----------|--------------|------------------------|------------------------|----------------|
|                      | P<br>(ha) | Kumul.<br>P  | G(S)<br>m <sup>2</sup> | G(V)<br>m <sup>2</sup> | Kumul.<br>G    |
| 1                    | 9,8       | 9,8          | 283,2                  | 212,4                  | 283,2          |
| 2                    | 6,1       | 15,9         | 176,3                  | 121,6                  | <b>459,5</b>   |
| <u>3</u>             | 4,4       | <b>20,3</b>  | 127,2                  | 98,3                   | 586,7          |
| 4                    | 2,9       | 23,2         | 83,8                   | 59,6                   | 670,5          |
| 5                    | 11        | 34,2         | 317,9                  | 233,7                  | <b>988,4</b>   |
| 6                    | 7,5       | 41,7         | 216,8                  | 169,0                  | 1 205,1        |
| 7                    | 5,5       | <b>47,2</b>  | 159,0                  | 115,2                  | 1 364,1        |
| <u>8</u>             | 2,1       | 49,3         | 60,7                   | 45,5                   | 1 424,8        |
| 9                    | 8,9       | 58,2         | 178,9                  | 115,4                  | 1 603,6        |
| 10                   | 4,2       | 62,4         | 84,4                   | 69,6                   | 1 688,1        |
| 11                   | 3,0       | 65,4         | 60,3                   | 43,6                   | 1 748,4        |
| 12                   | 1,5       | 66,9         | 30,2                   | 22,0                   | <b>1 778,5</b> |
| <b>13</b>            | 8,0       | <b>74,9</b>  | 160,8                  | 130,2                  | 1 939,3        |
| .                    | .         | .            | .                      | .                      | .              |
| .                    | .         | .            | .                      | .                      | .              |
| 70                   | 7,8       | 349,4        | 152,0                  | 125,4                  | <b>9 044,1</b> |
| 71                   | 3,9       | 353,3        | 76,0                   | 53,0                   | 9 120,1        |
| 72                   | 15,6      | <b>368,9</b> | 304,0                  | 235,2                  | 9 424,2        |
| <b>73</b>            | 6,2       | 375,1        | 120,8                  | 93,3                   | 9 545,0        |
| 74                   | 13,5      | <b>388,6</b> | 263,1                  | 194,0                  | <b>9 808,1</b> |

Poznámka – Note: 3, 20,3, 459,5 – označenie vybraných porastov – designation of selected forest stands; JSV jednoduchý systematický výber – z poradia č. 1 – 74, krok 74/15 = 5, štart č. 3 – JSV (simple systematic sample) – selection from sequence numbers 1–74, step  $k = 74/15 = 5$ , starting number (snb) = 3; PPS výber – z poradia kumulatívnych hodnôt  $P = 0 - 388,8$ ,  $k = 25,9$ , šč. = 17 – PPS sample – selection from cumulative values  $P = 0 - 388,8$ ,  $k = 25,9$ , snb = 17; PPP výber – z poradia kumulatívnych hodnôt  $G = 0 - 9808,1$ ,  $k = 653,8$ , šč. 387 – PPP sample – selection from cumulative values  $G = 0 - 9808,1$ ,  $k = 653,8$ , snb = 387.

lu 50 JPRL. Intenzita výberu  $n/N$  v rastových stupňoch dosahovala 20,3 – 15,7 – 25,9 % a v celom digitálnom lese 19,3 %. Rozdielne princípy a výsledky skúšaných výberových postupov dokumentuje príklad pre RS 4+5 v tabuľke 3. Vidno, že do výberu sa dostali vždy iné porasty digitálneho lesa. Okrem toho, je dôležité všimnúť si aj niektoré všeobecné poznatky, ktoré treba zobrať do úvahy pri praktických aplikáciách skúšaných výberových postupov:

- Jednoduchý, PPS a PPP výber sa môže uskutočniť úplne náhodne alebo systematicky s náhodným štartom.
- Pri PPS a PPP výbere sa tie isté jednotky (porasty) môžu dostať do výberu aj dvakrát, stáva sa to pri veľkých porastoch, ktorých výmera alebo zásoba je väčšia ako výberový krok. Teória obidvoch výberov takéto dvojnásobné zisťovanie nevylučuje, ale naopak vyžaduje.
- PPS výber sa dá ľahko uskutočniť pomocou výberovej siete ( $s$  rozstupom  $s = \sqrt{P/n}$ ), ktorá sa „položí“ na porastovú mapu, prekryje sa s ňou.

### 3.3. Počítačové simulácie STIPSI vo vybratých kontrolných porastoch

V každom vybratom poraste sme programom STIPSI simulovali kontrolné výberové meranie založením optimálne veľkých (20 stromových) kruhových skusných plôch s hustotou zaručujúcou zistenie kruhovej základne  $G$  s presnosťou  $\pm 10$  až 15 % (pri spoľahlivosti  $P = 0,95$ ). Počítač umiestnil stredy skusných plôch do modelového digitálneho porastu, vybral stromy patriace do skusnej plochy a vypočítal všetky parametre uskutočneného výberu pre počet stromov, kruhovú základňu a strednú hrúbku a nakoniec ich porovnal aj s údajmi platnými pre celý súbor stromov v poraste (v základnom súbore). Príklad takejto simulácie v jednom modelovom digitálnom poraste (č. 66, založenom na Slovensku, na VŠLP Zvolen, ŠMELKO 1979) prezentuje príklad v tabuľke 4.

**Tabuľka 4.** Výsledky simulácie  $m = 24$  kruhových skusných plôch o výmere 300 m<sup>2</sup> vo vybratom 4,18 ha kontrolnom poraste pomocou počítačového programu STIPSI

**Table 4.** Simulation results of  $m=24$  circular sample plots 300 m<sup>2</sup> area in selected 4,18 ha control forest stand using computer program STIPSI

| Dreviny <sup>1)</sup> | Porastové veličiny na 1 ha <sup>2)</sup> |     |                    |      |       |      | Štatistické charakteristiky $G$ <sup>3)</sup> |                      |         |                      |         |
|-----------------------|--|-----|--------------------|------|-------|------|---|----------------------|---------|----------------------|---------|
|                       | N(ks)                                    |     | G(m <sup>2</sup> ) |      | $d_s$ |      | $s_{d_s}$ %                                   | $s_G$ m <sup>2</sup> | $s_G$ % | $S_G$ m <sup>2</sup> | $S_G$ % |
| DB <sup>4)</sup>      | 642                                      | 667 | 22,2               | 22,2 | 21,0  | 20,6 | 36  | 9,9                  | 44,6    | 1,7                  | 7,7     |
| OL <sup>5)</sup>      | 71                                       | 56  | 1,2                | 1,0  | 14,7  | 14,8 | 29  | 3,0                  | 250,1   | 0,5                  | 40,6    |
| Spolu <sup>6)</sup>   | 713                                      | 724 | 23,4               | 23,2 | 20,4  | 20,2 | 37  | 10,0                 | 42,9    | 1,7                  | 7,4     |

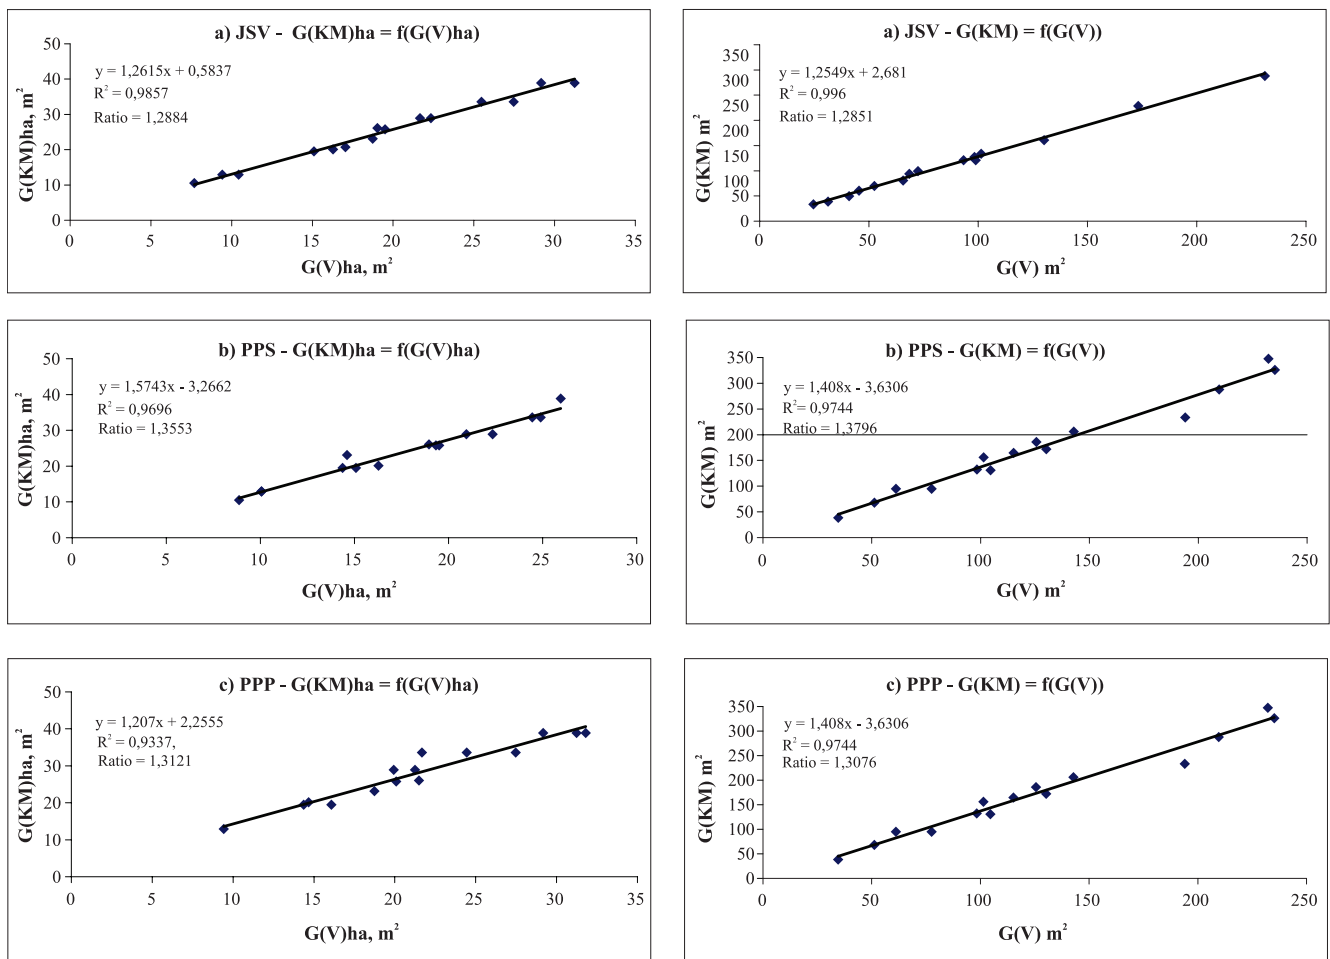
<sup>1)</sup>Tree species, <sup>2)</sup>Forest stand variables per ha, <sup>3)</sup>Statistical characteristics of basal area  $G$ , <sup>4)</sup>Oak, <sup>5)</sup>Broadleaved, <sup>6)</sup>Together  
 Vysvetlivky – Explanatory notes: N/(ks) – počet stromov – Number of trees, G(m<sup>2</sup>) – kruhová základňa – basal area,  $d_s$ (cm) – stredná hrúbka – mean diameter,  $s_{d_s}$  % – variačný koeficient strednej hrúbky – variation coefficient of  $d_s$ ,  $s_G$ (m<sup>2</sup>) – smerodajná odchýlka  $G$  – standard deviation of  $G$ ,  $s_G$  % – variačný koeficient  $G$  – variation coefficient of  $G$ ,  $S_G$ (m<sup>2</sup>) – stredná chyba  $G$  v m<sup>2</sup> – stanard error of  $G$  in m<sup>2</sup>,  $S_G$  % – stredná chyba  $G$  v % – standard error of  $G$  in %.

Poznámka – Note: tučne – údaje zo simulácie – bold – data obtained by simulation, normálne – údaje základného súboru (digitálneho lesa) – normal – data of entire population (digital forest).

### 3.4. Niekoľko zaujímavých vzťahov medzi správnymi a vychýlenými údajmi tej istej veličiny (kruhovej základne) v kontrolných porastoch získaných rôznymi výberovými postupmi

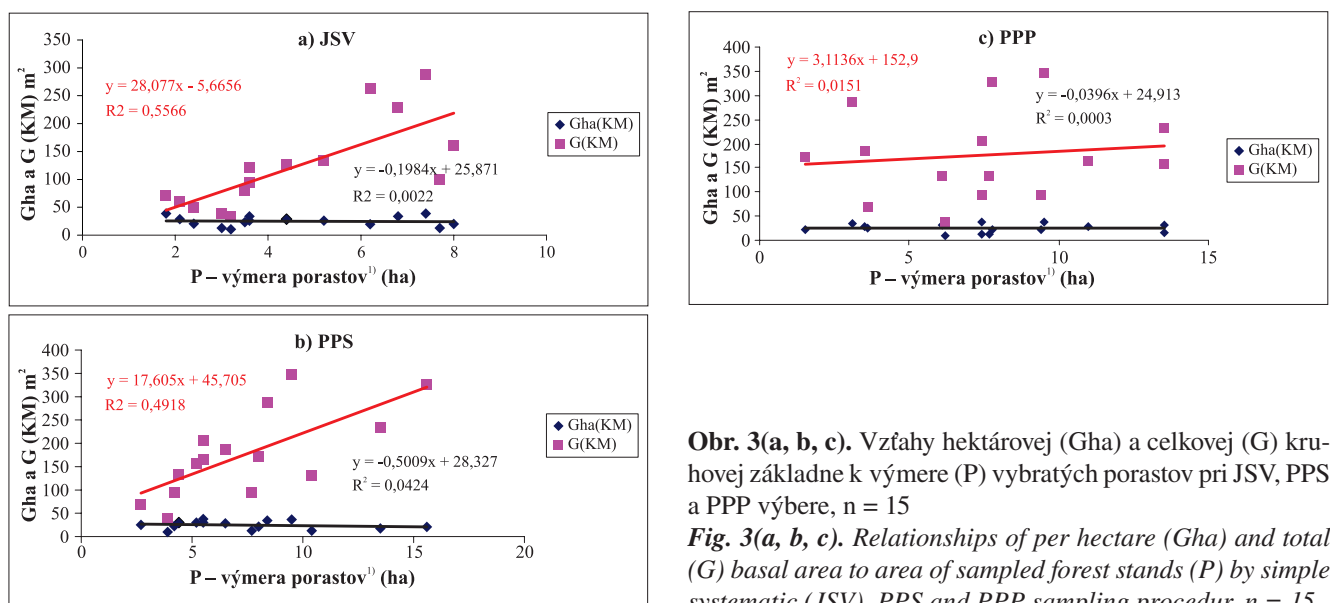
Realizáciou rôznych spôsobov výberu z toho istého základného súboru (digitálneho lesa) sa získala veľmi cenná databáza umožňujúca lepšie pochopiť vlastnosti skúšaných výberových postupov. Dobré sa prejavujú pri grafickom znázornení získaných výsledkov, ktoré pre RS 4+5 prezentuje obrázok 2 a 3. Z ich porovnania vyplývajú tieto skutočnosti:

- Do výberov sa dostali porasty s rozdielnymi hodnotami  $G$ (ha) aj  $G$ .
- Pri všetkých výberoch je závislosť správnych hodnôt  $G$ (S) z kontrolného merania od ich vychýlených ekvivalentov  $G$ (V) lineárna a neprechádza počiatkom súradníc (absolútny koeficient  $a$  sa nerovná nule). Hodnota „Ratio“ udáva strmhosť stúpania priamok za predpokladu, že by bolo  $a = 0$ , preto sa do určitej miery líši od regresného koeficienta  $b$  znázornenej priamky.
- Tesnosť korelácie (vyjadrená indexom determinácie  $R^2$ ) je veľmi vysoká, ale relatívne najvyššia je pri JSV, nižšia pri PPS a najnižšia pri PPP. Pri JSV sme ju preverili ďalšími piatimi opakovanými výbermi (tromi úplne náhodnými a dvomi systematickými). Potvrdili, že závislosť v ukážke 2a) nie je výnimočná, hodnoty  $R^2$  v opakovaných výberoch kolísali od 0,971 do 0,994. Vo vyšších rastových stupňoch 6+7 a 8+9 nadobudol  $R^2$  pri JSV tiež pomerne vysoké hodnoty 0,989 a 0,984. Hektárové hodnoty  $G$ (ha) pri všetkých troch spôsoboch výberu nezávisia od výmery porastov.
- Porastové hodnoty  $G$  závisia od výmery pri JSV a PPP stredne silno (koeficient determinácie  $R^2 =$  asi 0,50). Pri PPP je táto závislosť iba náhodná ( $R^2 = 0,02$ ) zrejme preto, že porasty s väčšou hodnotou kruhovej základne nemusia mať vždy aj väčšiu výmeru.



**Obr. 2(a, b, c).** Ukážky výsledkov výberu  $n = 15$  kontrolných porastov z  $N = 74$  porastov RS 4+5 tromi spôsobmi – jednoduchým systematickým (JSV), PPS a PPP výberom. Závislosti medzi meranou  $G(KM)$  a vychýlenou  $G(V)$  kruhovou základňou,  $G_{ha}$  – hektárové hodnoty,  $G$  – celkové porastové hodnoty

**Fig. 2(a, b, c).** Illustration results obtained by single systematic (JSV), PPS and PPP sampling of  $n=15$  control forest stands from  $N = 74$  forest stands in growth stages 4+5. Relationships between measured  $G(KM)$  and biased  $G(V)$  basal area,  $G_{ha}$  – per hectare values,  $G$  – total values



**Obr. 3(a, b, c).** Vzťahy hektárovej ( $G_{ha}$ ) a celkovej ( $G$ ) kruhovej základne k výmere ( $P$ ) vybraných porastov pri JSV, PPS a PPP výbere,  $n = 15$

**Fig. 3(a, b, c).** Relationships of per hectare ( $G_{ha}$ ) and total ( $G$ ) basal area to area of sampled forest stands ( $P$ ) by simple systematic (JSV), PPS and PPP sampling procedur,  $n = 15$

#### 4. Zhodnotenie experimentov

Nadväzuje na údaje získané v predchádzajúcich krokoch (v statiach 3.1 – 3.4). Obsahuje posúdenie existencie systematického vychýlenia, algoritmy spracovania údajov z kontrolného výberového zisťovania osobitne pre každý skúšaný variant, samotnú korekciu údajov i kvantifikáciu dosiahnutej správnosti a presnosti získaných výsledkov.

##### 4.1. Posúdenie prítomnosti systematického vychýlenia v overovaných údajoch

Údaje získané počítačovými simuláciami vo vybraťých kontrolných porastoch umožňujú túto úlohu riešiť porovnaním vychýlenej kruhovej základne  $G(V)$  voči správnej kruhovej základni  $G(S)$ . Keďže medzi obidvomi údajmi sa očakáva (a aj skutočne existuje) silná korelácia, na porovnanie sa použije t-test párových diferencií. Za štatisticky dokázané vychýlenie (Bias) s 95 %, resp. 99 % istotou sa považuje diferenciu  $d_j = X_j - Y_j = G(V)_j - G(S)_j$ , ktorej priemerná hodnota  $\bar{d}$  a smerodajná odchýlka  $s_d$  spĺňajú nasledovné kritérium

$$t = \frac{\bar{d}}{s_d} \cdot \sqrt{n} \geq t_{0,05(n-1)}, \text{ resp. } \geq t_{0,01(n-1)} \quad [1]$$

pričom  $n$  je rozsah výberu (počet kontrolných porastov). Pre kontrolné výbery v RS 4+5 tento test poskytol informácie v tabuľke 5 a preukázal, že výsledky  $G(V)$  sú skutočne systematicky podhodnotené a že ich treba korigovať.

**Tabuľka 5.** Overenie systematického vychýlenia údajov  $X$  voči  $Y$  v RS 4+5 t-testom diferencií

**Table 5.** Verification bias of the  $X$  data against the  $Y$  data in growth stages 4+5 using the t-test of differences

| Výberový postup <sup>1)</sup>     | JSV       | PPS       | PPP       |
|-----------------------------------|-----------|-----------|-----------|
| Diferencie <sup>2)</sup>          | d = X - Y | d = X - Y | d = X - Y |
| Priemer <sup>3)</sup>             | -25,24    | -48,42    | -48,21    |
| Smerodajná odchýlka <sup>4)</sup> | 14,92     | 29,97     | 25,59     |
| Stredná chyba <sup>5)</sup>       | 3,85      | 7,74      | 6,61      |
| t-test <sup>6)</sup>              | -6,551    | 6,256     | -7,296    |
| $t_{0,05(14)}$                    | 2,145     | 2,145     | 2,145     |
| $t_{0,01(14)}$                    | 2,977     | 2,977     | 2,977     |

<sup>1)</sup>Sampling procedure, <sup>2)</sup>Differences, <sup>3)</sup>Average, <sup>4)</sup>Standard deviation, <sup>5)</sup>Standard error, <sup>6)</sup>t-test

##### 4.2. Jednoduchý výber kontrolných porastov a korekcia údajov pomocou regresnej rovnice (RR)

Používa sa v prípade, keď vzťah medzi údajmi  $Y_j$  a  $X_j$  získanými v kontrolných porastoch je lineárny a regresná priamka

$$\hat{Y}_R = f(x) = a + b \cdot X \quad [2]$$

neprechádza počiatkom súradníc, jej absolútny koeficient  $a$  sa nerovná nule. Hodnoty  $Y_i$  a  $X_i$  sa týkajú celého porastu, nie sú prepočítané na 1 hektár, lebo pri uskutočnenom jednoduchom výbere sa nezohľadňovala výmera porastov, takže ju treba zobrať do úvahy teraz. Koeficienty rovnice ( $a$  – absolútny, úsek na osi  $Y$ ,  $b$  – regresný, smerník stúpania priamky) a koeficient determinácie  $r_{YX}^2$  regresnej rovnice [2] sa vypočítajú bežne známym spôsobom. Predpoklad, že priamka neprechádza počiatkom súradníc (pre  $X = 0$  je aj  $Y = 0$ ) sa overí t-testom a hypotéza, že  $a \neq 0$  sa s 95 %, resp. 99 % istotou prijme vtedy, ak platí nerovnosť

$$t_a = \frac{a}{S_a} = \frac{a}{s_{Y \cdot X}} \cdot \sqrt{n} \geq t_{0,05(n-2)}, \text{ resp. } \geq t_{0,01(n-2)} \quad [3]$$

Korigovaná hodnota pre priemer  $\mu_x(kor)$  a total  $\tau_x(kor)$  overovaných (vychýlených) údajov a ich stredné chyby korekcie  $S(\mu_x)$ ,  $S(\tau_x)$  sa určia nasledovne:

$$\mu_x(kor) = \bar{Y} + b(\mu_x - \bar{X}), \quad [4]$$

$$S(\mu_x kor) = \sqrt{\frac{S_Y^2(1-r_{YX}^2)}{n} \cdot \frac{N-n}{N}} = \frac{s_{Y \cdot X}}{\sqrt{n}} \cdot \sqrt{\frac{N-n}{N}}$$

$$\tau_x(kor) = N \cdot \mu_x(kor)$$

$$S(\tau_x kor) = N \cdot S(\mu_x kor) \quad [5]$$

Relatívne chyby obidvoch výsledkov sú totožné:

$$S(\mu_x kor)\% = S(\tau_x kor)\% \quad [6]$$

Vo vzorcach [4 a 5] sa  $\mu_x$  a  $\tau_x$  vzťahujú na celý súbor  $N$  porastov, ale priemery  $\bar{Y}$ ,  $\bar{X}$ ,  $s_Y$  – smerodajná odchýlka hodnôt  $Y_j$  okolo priemeru  $\bar{Y}$ ,  $r_{YX}$  – korelačný koeficient závislosti  $Y_j$  od  $X_j$  a  $s_{Y \cdot X}$  – smerodajná odchýlka hodnôt  $Y_j$  okolo vyrovnaných hodnôt  $\hat{Y}_j$  sú charakteristikami výberového súboru  $n$  kontrolných porastov.

Korigovať možno aj hodnoty  $X_i(kor)$  jednotlivých porastov, a to pomocou rovnice [2] a total  $\tau_x(kor)$  potom získať jednoduchým súčtom porastových skorigovaných údajov  $X_i(kor)$ . Výsledky však nemusia vždy úplne súhlasiť, ale rozdiely možno spravidla tolerovať.

Pre náš príklad, jednoduchý systematický výber  $n = 15$  kontrolných porastov v RS 4+5 sú výsledky regresie zhrnuté v tabuľke 6, príslušná regresná priamka pre porastové hodnoty  $G_{KM}$  a  $G(V)$  je na obrázku 2a.

##### 4.3. Jednoduchý výber kontrolných porastov a korekcia údajov pomocou pomeru $R$ (Ratio)

Používa sa vtedy, keď priamka vyjadrujúca vzťah  $\hat{Y}_j = f(X_j)$  pre vybrané kontrolné porasty prechádza počiatkom súradníc, čiže keď jej absolútny koeficient  $a$  sa rov-

**Tabuľka 6.** Príklad zhodnotenia JSV, RS 4+5, n = 15 – metóda Regresia a Ratio (porastové hodnoty  $X_j, Y_j$ )  
**Table 6.** Example for the evaluation of JSV (simple systematic sampling), GS 4+5, n = 15 – Regression and Ratio procedure (forest stand values  $X_j, Y_j$ )

| P. č.                  | $X_j$     | $Y_j$      | Korekcia <sup>1)</sup>  |  |
|------------------------|-----------|------------|---|--|
|                        | G(V)      | G(KM)      |   |  |
| 3                      | 98,3      | 127,2      | <b>Regresia<sup>2)</sup></b><br>a = 2,682 $t_a = 1,15$ $r_{YX} = 0,998$<br>b = 1,2549 $t_b = 55,99$<br>$\bar{X} = 88,53$ $\bar{Y} = 113,77$ n = 15<br>$\mu_x = 100,05$ $\tau_x = 7403,9$ N = 74<br>$\mu_x(kor) = 113,77 + 1,2549(100,05 - 88,53) = \mathbf{128,22}$ ( $\mu_y = 132,54$ ) Dif. -3,3 %<br>$S(\mu_x kor) \pm \mathbf{0,83}$ (= $\pm 0,65$ %)<br>$\tau_x(kor) = 74 * 128,23 = \mathbf{9489,02}$ (Dif. -3,3 %)<br>$S(\tau_x kor) = 74 * (\pm 0,83) = \pm 61,4$ (= 0,65 %)<br>t-test Dif. = -3,3 % / 0,65 % = -5,08** |  |
| 8                      | 45,5      | 60,7       |   |  |
| 13                     | 130,2     | 160,8      |   |  |
| 18                     | 72,5      | 99,3       |   |  |
| 23                     | 31,3      | 38,7       |   |  |
| 28                     | 40,9      | 49,6       |   |  |
| 33                     | 24,6      | 33,6       |   |  |
| 38                     | 52,5      | 70,0       |   |  |
| 43                     | 231,2     | 287,9      |   |  |
| 48                     | 173,2     | 228,5      |   |  |
| 53                     | 98,9      | 121,0      |   |  |
| 58                     | 68,5      | 93,8       |   |  |
| 63                     | 65,6      | 80,9       |   |  |
| 68                     | 101,4     | 133,9      |   |  |
| 73                     | 93,3      | 120,8      |   |  |
| Suma <sup>3)</sup>     | 1 327,90  | 1 706,55   |   | <b>Ratio</b><br>$R = \mathbf{1\ 706,55 / 1\ 327,9} = 1,2851$<br>$S_R = \mathbf{0,0111}$ (= $\pm 0,86$ %)<br>$\mu_x(kor) = 1,2851 * 100,05 = \mathbf{128,6}$ (Dif. -3,0 %)<br>$S(\mu_x kor) = \pm 0,0111 * 100,05 = \pm 1,11$ (= $\mathbf{0,86}$ %)<br>$\tau_x(kor) = 1,2851 * 7403,9 = \mathbf{9\ 366,7}$ (Dif. -3,0 %)<br>$S(\tau_x kor) = \pm 0,0111 * 9366,7 = \pm 103,9$ (= 0,86 %)<br>t-test Dif. = -3,1 % / 0,86 % = -3,60** |
| Priemer <sup>4)</sup>  | 88,53     | 113,77     |   |  |
| SmOdch <sup>5)</sup>   | 55,82     | 70,19      |   |  |
| VarKoeff <sup>6)</sup> | 63,05     | 61,69      |   |  |
| SumaXi <sup>2</sup> =  | 161 170,6 |            |   |  |
| SumaYi <sup>2</sup> =  |           | 263 120,47 |   |  |
| Suma X.Y=              | 205 807,5 |            |   |  |
| Ratio=                 |           | 1,2851     |   |  |

<sup>1)</sup>Correction, <sup>2)</sup>Regression, <sup>3)</sup>Total, <sup>4)</sup>Average, <sup>5)</sup>Standard deviation, <sup>6)</sup>Variation coefficient

ná nule, alebo jeho odchýlka od nuly sa podľa testu [3] môže považovať za náhodnú. Algoritmus je nasledovný:

- Východiskom sú porastové údaje  $X_j, Y_j$  z kontrolných porastov a ich súčty alebo priemery získané jednoduchým náhodným alebo systematickým výberom o rozsahu  $n$
- Na korekciu údajov slúži pomer (Ratio)  $R$

$$R = \frac{\sum_{j=1}^n Y_j}{\sum_{j=1}^n X_j} = \frac{\bar{Y}}{\bar{X}} \quad [7]$$

Takto definovaný pomer  $R$  je vlastne regresným koeficientom priamky  $\hat{Y} = f(X)$  prechádzajúcej počiatkom súradníc  $\hat{Y}_R = R \cdot X$  a medzi ním a regresným koeficientom  $b$  priamky neprechádzajúcej počiatkom súradníc  $\hat{Y}_{LR} = a + b \cdot X$  platia tieto vzťahy

$$R = b + \frac{a}{\bar{X}} \quad a = b - R \cdot \frac{a}{\bar{X}} \quad [7a]$$

- Korigovaný vychýlený údaj pre jednotlivé porasty  $X_{i(kor)}$ , pre priemer  $\mu_{X(kor)}$  a pre total  $\tau_{X(kor)}$  sa získa po-

dľa týchto vzťahov

$$X_{i(kor)} = R \cdot X_i \quad \mu_{X(kor)} = R \cdot \mu_X = R \cdot \frac{\sum_{i=1}^N X_i}{N} \quad [8]$$

$$\tau_{X(kor)} = R \cdot \tau_X = R \sum_{i=1}^N X_i$$

- Stredná chyba pomeru  $S_R$  a korigovaného totalu  $S(\tau_X)kor$  sa odvodí nasledovne

$$S_R = \sqrt{\frac{\sum_{j=1}^n Y_j^2 + R^2 \sum_{j=1}^n X_j^2 - 2R \sum_{j=1}^n X_j Y_j}{\mu_X^2 \cdot n \cdot (n-1)}} \left( \frac{N-n}{N} \right) \quad [9]$$

- Relatívne stredné chyby pomeru i totalu sú totožné, takže stačí určiť iba jednu

$$S_R \% = S(\tau_X)kor \% \quad [10]$$

- $S_R \%$  sa dá veľmi výhodne a jednoduchšie určiť aj z variačných koeficientov vstupných veličín výberu a korelácie medzi nimi



$$S_R \% = \sqrt{\frac{s_Y \%^2 + s_X \%^2 - 2r_{YX} \cdot s_Y \% \cdot s_X \%}{n} \left( \frac{N-n}{N} \right)} \quad [11]$$

- Celá procedúra sa dá uplatniť aj na hektárové hodnoty  $x_p, y_j$  vybratých kontrolných porastov, výsledky budú rovnaké. Ukážka riešenia na podklade porastových údajov pre náš príklad v RS 4+5 je spolu s regresiou v tabuľke 6.

#### 4.4. PPS výber kontrolných porastov a korekcia údajov podľa algoritmu PPS

Je relatívne nová, menej známa a viaže sa jednoznačne na výbery s nerovnakými pravdepodobnosťami.

- Vstupnými údajmi sú porastové hodnoty  $X_j, Y_j$  a výmera kontrolných porastov  $P_j$ . Vďaka tomu, že výber sa robí úmerne k výmere porastov s pravdepodobnosťami

$$p_i = \frac{P_i}{\sum_{i=1}^N P_i} = \frac{P_i}{P} \quad [12]$$

nastáva tzv. samovyváženie vybratých údajov a výsledky sa zhodnocujú na základe hektárových hodnôt  $x_j, y_j$ .

- Základný vzťah pre odvodenie súhrnného výsledku (totalu)  $\tau_{X(PPS)}$  sa tým značne zjednoduší, lebo platí (COCHRAN, 1953, DE WRIES, 1986)

$$\begin{aligned} \tau_{X(PPS)} &= \frac{\sum_{j=1}^n (Y_j / p_j)}{n} = \frac{\sum_{j=1}^n Y_j \left( \frac{P_j}{P} \right)}{n} = \\ &= P \cdot \frac{\sum_{j=1}^n Y_j / P_j}{n} = P \cdot \bar{y} \end{aligned} \quad [13]$$

- Stredná chyba odhadu tohto  $\tau_{X(PPS)}$  má nasledujúci všeobecný výraz a tiež sa dá dobre upraviť na známy zjednodušený tvar

$$\begin{aligned} S(t_{X(PPS)}) &= \sqrt{\frac{P^2}{n \cdot (n-1)} \left[ \sum_{j=1}^n y_j^2 - \frac{(\sum_{j=1}^n y_j)^2}{n} \right] \cdot \left( \frac{N-n}{N} \right)} \\ &= P \cdot \frac{s_y}{\sqrt{n}} \sqrt{\frac{N-n}{N}} = P \cdot S_{\bar{y}} \end{aligned} \quad [14]$$

- Ako vidno, ide v podstate o metódu, pri ktorej stačí v overovanom LC vybrať  $n$  kontrolných porastov úmerne k ich výmere, zistiť priemer a strednú chybu hektárových hodnôt danej veličiny (kruhovej základne, zásoby) a prenásobiť ich celkovou výmerou všetkých lesných porastov v LC prevzatou, napr. z LHP. Ukážka praktického použitia navrhnutého postupu pre náš príklad – PPS výber v RS 4+5 je v tabuľke 7.

**Tabuľka 7.** Príklad zhodnotenia PPS, RS 4+5,  $n = 15$  (hektárové hodnoty  $x_j, y_j$ )

**Table 7.** Example for the evaluation of PPS, GS 4+5,  $n = 15$ , (hectare values  $x_p, y_j$ )

| P. č.                  | x(i)     | y(i)     |   |
|------------------------|----------|----------|---|
|                        | G/ha (V) | G/ha(KM) |   |
| 3                      | 22,3     | 28,9     | <b>PPS algoritmus<sup>1)</sup></b><br>Prevzaté údaje <sup>2)</sup> :<br>P = 388,6 ha<br>$\mu_x = 19,05 \quad \tau_x = 7 \quad 403,9 \quad N = 74$<br><br><b>Údaje získané kontrolným meraním<sup>3)</sup> (<math>y_j</math>):</b><br><br>$S_{\bar{y}} = \frac{8,24}{\sqrt{15}} \sqrt{\frac{74-15}{74}} = \pm 1,9 \quad (\pm 7,9 \%)$<br><br>$\bar{y} = 360,1 / 15 = 24,01$<br><br>$\tau_{X(PPS)} = 388,6 * 24,01 = 9 \quad 330,3$<br>$(\tau_y = 9 \quad 808,1 \text{ Dif. } -477,8 \text{ (-4,9 \%)})$<br><br>$S(\tau_{X,PPS}) = 388,6 * 1,9 = \pm 738,3 \text{ (\pm 7,9 \%)}$<br><br>$\tau_{X(PPS)} / \tau_x = 9 \quad 330,3 / 7 \quad 403,9 = 1,2602$ |
| 7                      | 20,9     | 28,9     |   |
| 13                     | 16,3     | 20,1     |   |
| 17                     | 10,1     | 12,9     |   |
| 21                     | 10,1     | 12,9     |   |
| 34                     | 8,9      | 10,5     |   |
| 40                     | 26,0     | 38,9     |   |
| 47                     | 24,4     | 33,6     |   |
| 51                     | 24,9     | 33,6     |   |
| 56                     | 19,0     | 26,1     |   |
| 60                     | 14,6     | 23,1     |   |
| 65                     | 19,3     | 25,8     |   |
| 68                     | 19,5     | 25,8     |   |
| 72                     | 15,1     | 19,5     |   |
| 74                     | 14,4     | 19,5     |   |
| Suma <sup>4)</sup>     | 265,7    | 360,1    |   |
| Priemer <sup>5)</sup>  | 17,71    | 24,01    |   |
| SmOdch <sup>6)</sup>   | 5,54     | 8,24     |   |
| VarKoeff <sup>7)</sup> | 31,26    | 34,32    |   |

<sup>1)</sup>PPS algorithm, <sup>2)</sup>Taken data, <sup>3)</sup>Data obtained by control measuring, <sup>4)</sup>Total, <sup>5)</sup>Average, <sup>6)</sup>Standard deviation, <sup>7)</sup>Variation coefficient

#### 4.5. PPP výber kontrolných porastov a korekcia údajov podľa algoritmu PPP

Stala sa známou vďaka Američanovi GROSSENBAUCHOVI (1965), ktorý pod touto skratkou vyvinul metódu vhodnú na výberové určovanie objemu stromov v porastoch s využitím pravdepodobností úmerných predikovanej (zistovanej) veličine. Jeho pôvodný návrh na tzv. „a posteriori výber“ (vykonávaný v priebehu zisťovania) rozšíril neskôr LOETSCH (1971) o tzv. „a priori výber“ (vykonávaný pred samotným zisťovaním z vopred pripraveného zoznamu) a ten bol viacerými autormi aj v lesníctve s úspechom aplikovaný (napr. SÜSS, 1982, ULBRICHT, 1984, ŠMELKO, 1990).

Výhoda metódy spočíva v tom, že umožňuje veľmi dobre využiť už existujúce údaje o stave lesa (napr. z LHP), pomocou nich vybrať porasty pre kontrolné meranie s pravdepodobnosťou úmernou veľkosti zisťovanej veličiny (kruhovej základne, zásobe) a podľa takto získaných výsledkov upraviť (skorigovať, spresniť, zhospodárniť) zisťovanie stavu lesa pre rôzne účely. Teoreticky by sa metóda dala aplikovať tak, že by sa do vzťahov [13 a 14] za  $P_j$  dosadila približne známa zisťovaná veličina  $X_j$  (kruhová základňa, zásoba). Zaužíval sa však trochu iný algoritmus, ktorý je nasledovný:

- Z údajov výberového merania  $Y_j$ , a prevzatých údajov  $X_j$  o rozsahu  $n$  sa pre každý pár (dvojicu) hodnôt vypočíta kvocient  $q_j$  a všetky jeho štatistické charakteristiky

$$q_j = \frac{Y_j}{X_j} \rightarrow \bar{q} = \frac{\sum_{j=1}^n q_j}{n}, S_{\bar{q}} = \frac{S_q}{\sqrt{n}} \sqrt{\frac{N-n}{N}},$$

$$S_{\bar{q}} \% = \frac{S_{\bar{q}}}{\bar{q}} 100 \quad [15]$$

- Skoriguje sa vychýlený údaj – pre každý porast  $X_i$ , priemer  $\mu_X$ , total  $T_X$

$$X_i kor = \bar{q} \cdot X_i \quad \mu_X kor = \bar{q} \cdot \mu_X = \bar{q} \frac{\sum_{i=1}^N X_i}{N}$$

$$\tau_X kor = \bar{q} \cdot \tau_X = \bar{q} \sum_{i=1}^N X_i \quad [16]$$

- Stanoví sa stredná relatívna chyba skorigovaného výsledku s využitím zákona o prenášaní chýb

$$S(\tau_X kor) \% = \sqrt{S_{\bar{q}} \%^2 + S(\tau_X) \%^2} \quad [17]$$

s tým, že prvý člen sa prevezme z [15] a druhý člen sa pre náš pokus odvodí na základe tohto predpokladu: kruhová základňa (zásoba) porastov sa pomocou rastových tabuliek v jednotlivých porastoch zistila so strednou chybou približne  $\pm 10 \%$ , má náhodný cha-

**Tabuľka 8.** Príklad zhodnotenia PPP, RS 4+5,  $n = 15$  (porastové hodnoty  $X_j, Y_j$ )

**Table 8.** Example for the evaluation of PPP, GS 4+5,  $n = 15$ , (forest stand values  $X_j, Y_j$ )

| P. č.                  | X <sub>j</sub> | Y <sub>j</sub> | q(j)                           | PPP algoritmus <sup>1)</sup>  |
|------------------------|----------------|----------------|--------------------------------|---|
|                        | G(V)           | G (KM)         | Y <sub>j</sub> /X <sub>j</sub> |   |
| 2                      | 121,6          | 176,3          | 1,450                          | <b>Prevzaté údaje<sup>2)</sup>:</b><br>$\mu_X = 100,05 \quad \tau_X = 7 403,9 \quad N = 74$<br><br><b>Údaje získané kontrolným výberom<sup>3)</sup> (<math>X_j, Y_j</math>):</b><br>$\bar{q} = \frac{19,8}{15} = 1,3200$<br>$S_{\bar{q}} = \frac{0,0992}{\sqrt{15}} \sqrt{\frac{74-15}{74}} = \pm 0,0229 \quad (1,73 \%)$<br>$\mu_X = 1,32 * 100,05 = 132,1$<br>$\mu_X = 132,54 \text{ Dif.} = -0,33 \%$<br>$\tau_{X(kor)} = 1,32 * 7 403,9 = 9 773,15$<br>$\tau_Y = 9 898,1 \text{ Dif.} = -0,33 \%$<br>$S\tau_{X(kor)} \% = \sqrt{1,16^2 + 1,73^2} = \pm 2,08 \%$ |
| 5                      | 233,7          | 317,9          | 1,360                          |   |
| 12                     | 22             | 30,2           | 1,373                          |   |
| 18                     | 72,5           | 99,3           | 1,370                          |   |
| 35                     | 215,9          | 287,9          | 1,333                          |   |
| 39                     | 197,2          | 241,2          | 1,223                          |   |
| 43                     | 231,2          | 287,9          | 1,245                          |   |
| 47                     | 232,2          | 319,2          | 1,375                          |   |
| 50                     | 67,2           | 104,2          | 1,551                          |   |
| 53                     | 98,9           | 121            | 1,223                          |   |
| 59                     | 202,1          | 245            | 1,212                          |   |
| 63                     | 65,6           | 81             | 1,235                          |   |
| 67                     | 271,2          | 347,6          | 1,282                          |   |
| 70                     | 125,4          | 152            | 1,212                          |   |
| 74                     | 194            | 263,1          | 1,356                          |   |
| Suma <sup>4)</sup>     | 2 350,7        | 3 073,8        | 19,800                         |   |
| Priemer <sup>5)</sup>  | 156,71         | 204,92         | 1,3200                         |   |
| SmOdch <sup>6)</sup>   | 78,37          | 101,46         | 0,0992                         |   |
| VarKoeff <sup>7)</sup> | 50,01          | 49,51          | 7,51                           |   |

<sup>1)</sup>PPS algorithm, <sup>2)</sup>Taken data, <sup>3)</sup>Data obtained by control measuring, <sup>4)</sup>Total, <sup>5)</sup>Average, <sup>6)</sup>Standard deviation, <sup>7)</sup>Variation coefficient

rakter (lebo systematické vychýlenie sa už odstránilo pomocou  $\bar{q}$ ), takže pri  $N$  porastoch dosiahne približne hodnotu

$$S(\tau_x)\% = \frac{\pm 10}{\sqrt{N}} \quad [18]$$

pri 100 – 200 – 500 porastoch bude  $\pm 1 - 0,7 - 0,45 \%$ .

- Algoritmus je použiteľný univerzálne pre jednotlivé porasty, ich stredné hodnoty i úhrny, pre porastové i hektárové údaje. Výsledky sú totožné, pretože vo všetkých prípadoch platí ten istý korekčný faktor  $\bar{q}$  (hodnoty výmery  $P_j$  sú v čitateli i menovateli rovnaké a navzájom sa vykrátia). Príklad aplikácie tohto postupu je v tabuľke 8.

## 5. Poznatky získané overovacími skúškami

Hlavným cieľom overovacích skúšok bolo zistiť ako sa jednotlivými výberovými postupmi podarí odstrániť podozrivé systematické vychýlenie v overovaných údajoch a aká je presnosť získaných korigovaných výsledkov. Odpoveďou môžu byť nasledovné tri kvantitatívne ukazovatele.

### 5.1. Relatívne porovnanie celkovej kruhovej základne pred korekciou a po korekcií voči správnej hodnote v celom skúmanom digitálnom lese

Vykonané je v tabuľke 9 osobitne pre jednotlivé rastové stupne i spolu pre celý pokusný objekt. Vyplýva z neho, že

- Veľké systematické vychýlenie  $G(V)$  voči  $G(S)$ , ktoré predstavovalo  $-15$  až  $-25 \%$  sa veľmi dobre odstránilo. Pôvodný index pri  $G(V)$  75,5 až 85,3 sa pri  $G(kor)$  zmenil na 96 až 101.
- Rozdelenie skorigovaných hodnôt je priaznivé, 11 hodnôt  $G(kor)$  má index menší a 5 hodnôt väčší ako 100.
- Medzi výberovými postupmi nie sú v skorigovaných výsledkoch žiadne podstatnejšie rozdiely.

### 5.2. Štatistické rámce presnosti skorigovaných výsledkov

Rámce chýb korekcie, ktoré možno pri jednotlivých výberových procedúrach očakávať so 68 % pravdepodobnosťou a ďalšie s nimi súvisiace charakteristiky sú zhrnuté v tabuľke 10.

Vyplývajú z nich tieto skutočnosti:

- Štatistické stredné chyby (rámce pri 68 % pravdepodobnosti) sú okrem metódy PPS veľmi priaznivé, neprekračujú hodnotu  $\pm 2 \%$  (resp.  $\pm 4 \%$  pri 95 % pravdepodobnosti). Horší výsledok štatistickej presnosti PPS výberu je pravdepodobne v tom, že tento postup preberá z už známych údajov iba celkovú výmeru porastov  $P$ , nevyužíva údaje o  $X_i$  každého porastu, tak ako to robia ostatné tri postupy.
- Variabilita  $y$  aj  $x$  je pomerne veľká, ale tesnosť korelácie  $y = f(x)$  a variabilita  $y_i$  okolo regresnej priamky ( $s_{y,x} \%$ ), ako aj variabilita hodnôt kvocienta  $q$  je veľmi nízka.
- To potvrdzuje výhodnosť postupov RR, R a PPP. Zo všetkých alternatív je však z hľadiska štatistickej pres-

**Tabuľka 9.** Kruhová základňa ( $m^2$ ) v základnom súbore – digitálnom lese: správna  $G(S)$ , vychýlená  $G(V)$  a skorigovaná  $G_{kor}$  štyrmi výberovými procedúrami, vyjadrená pomocou indexu voči  $G(S) = 100$

**Table 9.** Basal area ( $m^2$ ) in the entire population „digital forest“ – correct  $G(S)$ , biased  $G(V)$  and corrected  $G_{kor}$  by four sampling procedures, expressed using the index to  $G(S) = 100$

| RS                  | G (S)    | G (V) | $G_{kor}$ (RR) | $G_{kor}$ (R) | $G_{kor}$ (PPS) | $G_{kor}$ (PPP) |
|---------------------|----------|-------|----------------|---------------|-----------------|-----------------|
| 4+5                 | 9 808,1  | 75,5  | 96,7           | 96,9          | 95,1            | 99,7            |
| 6+7                 | 25 823,4 | 80,0  | 100,5          | 98,1          | 101,2           | 100,3           |
| 8+9                 | 9 523,6  | 85,3  | 97,3           | 102,3         | 96,1            | 96,6            |
| Spolu <sup>1)</sup> | 45 155,1 | 80,1  | 99,7           | 97,9          | 100,9           | 99,2            |

<sup>1)</sup>Together

**Tabuľka 10.** Štatistické stredné chyby priemernej a celkovej korigovanej kruhovej základne ( $\pm S(\mu_c kor)\% = \pm S(\tau_c kor)\%$ ) pri metóde RR, R, PPS, PPP a ďalšie charakteristiky hektárových hodnôt  $y, x$  v pokusných výberoch

**Table 10.** Statistical standard errors for the mean and total of corrected basal area ( $\pm S(\mu_c kor)\% = \pm S(\tau_c kor)\%$ ) obtained from the regression (RR), ratio (R), PPS, PPP method and other characteristics of the per hectare values  $y, x$  in tested samplings

| RS                  | RR   | R    | PPS  | PPP  | $s_y \%$ | $s_x \%$ | $r_{yx}$ | $s_{yx} \%$ | $s_q \%$ |
|---------------------|------|------|------|------|----------|----------|----------|-------------|----------|
| 4+5                 | 0,65 | 0,86 | 7,90 | 1,73 | 52,0     | 50,3     | 0,987    | 9,4         | 7,5      |
| 6+7                 | 1,17 | 1,54 | 6,74 | 1,50 | 56,9     | 57,4     | 0,994    | 6,0         | 7,3      |
| 8+9                 | 1,65 | 1,75 | 8,28 | 0,98 | 58,7     | 60,9     | 0,992    | 7,4         | 4,4      |
| Spolu <sup>1)</sup> | 1,08 | 1,16 | 4,80 | 1,14 | 61,7     | 63,9     | 0,990    | 8,5         | 9,0      |

<sup>1)</sup>Together

**Tabuľka 11.** Skutočné chyby (% odchýlky) korigovaných hodnôt G(kor) voči G(S) v jednotlivých porastoch – ich priemer, smerodajná odchýlka a stredná kvadratická chyba v rámci RS a v celom pokusnom digitálnom lese

**Table 11.** Real errors (% differences) of corrected values G(kor) to G(S) in individual forest stands – their average, standard deviation and mean square error in the growth stages (RS) and throughout the digital forest

| RS                  | Charakteristika <sup>1)</sup> | RR   | R    | PPS  | PPP  |
|---------------------|-------------------------------|------|------|------|------|
| 4+5                 | Priemer <sup>2)</sup>         | -3,3 | -3,0 | -4,9 | -0,3 |
|                     | SmOdch <sup>3)</sup>          | 6,5  | 6,3  | 6,3  | 6,5  |
|                     | Str.kv.chyba <sup>4)</sup>    | 6,8  | 6,7  | 6,7  | 6,5  |
| 6+7                 | Priemer <sup>2)</sup>         | -1,7 | -1,5 | 1,3  | 0,4  |
|                     | SmOdch <sup>3)</sup>          | 6,8  | 7,0  | 7,0  | 6,9  |
|                     | Str.kv.chyba <sup>4)</sup>    | 7,0  | 7,2  | 7,1  | 7,0  |
| 8+9                 | Priemer <sup>2)</sup>         | 2,7  | 2,0  | -4,5 | -4,1 |
|                     | SmOdch <sup>3)</sup>          | 6,0  | 6,1  | 5,7  | 5,7  |
|                     | Str.kv.chyba <sup>4)</sup>    | 6,6  | 6,4  | 7,2  | 7,0  |
| Spolu <sup>5)</sup> | Priemer <sup>2)</sup>         | 1,4  | 0,6  | 0,6  | -1,1 |
|                     | SmOdch <sup>3)</sup>          | 7,9  | 7,7  | 7,7  | 7,6  |
|                     | Str.kv.chyba <sup>4)</sup>    | 8,1  | 7,8  | 7,7  | 7,7  |

<sup>1)</sup>Characteristic, <sup>2)</sup>Average, <sup>3)</sup>Standard deviation, <sup>4)</sup>Mean square error of the % differences, <sup>5)</sup>Together

nosti relatívne najlepšia metóda PPP (pri metóde RR i R sa v niektorých prípadoch nepodarilo celkom odstrániť systematické vychýlenie, aj keď sa podstatne znížilo – napr. v RS 4+5).

### 5.3. Skutočné chyby skorigovaných výsledkov

Vďaka tomu, že všetky skúšky sa vykonali v digitálnom lese so známymi správnymi údajmi pre každý strom a porast, získali sa informácie o skutočne dosiahnuteľných rámcoch presnosti pri jednotlivých spôsoboch korekcie. Charakterizujú ich údaje v tabuľke 11.

Potvrdzujú, že

- Priemerné chyby majú striedavé znamienko (9 plus, 7 mínus)
- Náhodná zložka chýb (kolísanie okolo priemernej chyby) dosahuje  $\pm 5,7$  až  $\pm 7,9$  %.
- Obidve zložky chyby neprekračujú s pravdepodobnosťou 68 % hodnoty  $\pm 6,4$  až  $\pm 8,1$  % a s pravdepodobnosťou 95 % sú menšie ako  $\pm 12,8$  až  $\pm 16,2$  %.
- Výsledok korekcie je veľmi dobrý. Systematické vychýlenie (Bias) sa odstránilo a chyba určenia G (aj zásoby) v jednotlivých porastoch po korekcii má takú úroveň (zhruba  $\pm 15$  %), aká sa pri určovaní zásob porastov v praxi HÚL očakáva pri aplikácii diferenčovaných rastových tabuliek (pozri ŠMELKO 1988).

## 6. Súhrnné závery a odporúčania

Vykonaný teoretický rozbor a experimentálne skúšky prinášajú nové poznatky o výberových postupoch označených ako „List Sampling“ a o možnostiach ich praktického uplatnenia pri zisťovaní stavu lesa. Umožňujú efektívne využitie už existujúcich údajov, overenie ich správnosti a aktualizáciu pomocou malého rozsahu nového kontrolného merania.

Postup „List Sampling“, čiže výber jednotiek z vopred známeho zoznamu o nich v celom základnom súbo-

re je určený pre prípady, keď takýto zoznam je už k dispozícii z prechádzajúceho zisťovania a keď medzi existujúcimi a novými údajmi možno očakávať tesný lineárny vzťah. Samotný výber jednotiek sa dá vykonať štyrmi spôsobmi (jednoduchým výberom náhodným alebo systematickým bez ohľadu na ich veľkosť, PPS výberom uprednostňujúcim veľkosť jednotiek, napr. výmeru porastov a PPP výberom uprednostňujúcim jednotky s väčšou hodnotou zisťovanej veličiny, napr. zásobou porastov). Naňho nadväzuje zodpovedajúci algoritmus spracovania údajov získaných z kontrolného výberového zisťovania, a to metóda regresnej rovnice (RR), pomeru (Ratio R), PPS a PPP.

Experimentálne skúšky realizované s maximálne možnou objektivitou potvrdili dobrú použiteľnosť všetkých uvedených variantov. Pomocou malého počtu kontrolných porastov (15, resp. 20 v kategórii mladých, stredne starých a starých porastov) sa odstránilo systematické vychýlenie pôvodných preberaných údajov ktoré dosahovalo -15 až -25 % a rámce štatistických i skutočných chýb boli veľmi priaznivé. Chyby skorigovaných, resp. zaktualizovaných údajov neprekročili s 95 % pravdepodobnosťou interval pre celý digitálny les  $\pm 4$  % pre jednotlivé porasty  $\pm 12,8$  až  $\pm 16,2$  %. Výnimkou je iba PPS výber, ktorého štatistická presnosť je asi 2-krát horšia ako pri ostatných troch postupoch, ale v odstránení systematického vychýlenia a v rámcach skutočnej presnosti je s nimi rovnocenný. Preto by nebolo správne jeho použitie a priori zamietnuť, lebo poskytuje aj ďalšie výhody, ku ktorým patrí, napr. už spomínaná „samovyváženosť“ výsledkov výberu.

Získané poznatky predstavujú metodický základ, ktorý je plne využiteľný pre rôzne zisťovania v lese a v krajine, ak sa splnia podmienky, pre ktoré sú dané postupy vhodné. Súčasne sú východiskom pre návrh novej metódy na objektivizáciu hospodársko-úpravníckych úda-

voj o stave lesov v SR, v ktorých je podľa výsledkov Národnej inventarizácie lesa a ďalších lokálnych priamych meraní (ŠMELKO *et al.* 2008, ŠMELKO & ŠEBEŇ 2010) podozrenie na vychýlenie voči skutočnosti o asi -25 %.

### Podakovanie

Práca vznikla vďaka Európskemu fondu regionálneho rozvoja v operačnom programe Výskum a vývoj v rámci „Centra excelentnosti pre podporu rozhodovania v lese a krajine“ na TU a NLC Zvolen, v aktivite 3.2 „Vývoj metód na získavanie informácií o lese v krajine s využitím kombinácie progresívnych technológií pre rôzne veľké územia“ (Agentúra Ministerstva školstva, vedy, výskumu a športu SR pre štrukturálne fondy EU, kód ITMS projektu 26220120069).

### Citovaná literatúra

- COCHRANN, W. G., 1977: Sampling Techniques. John Wiley Inc. New York, 413 pp.
- DE WRIES, P. G., 1986: Sampling Theory for Forest Inventory. Agricultural University Wageningen, Netherlands. 379 pp.
- GROSSENBAUCH, L. R., 1965: Three-Pee Sampling Theory and Program „THRP“ for Computer Generation of Selection Criteria. In: Forest Service Research Paper. PSW-21, Berkeley, 53 pp.
- LOETSCH, F., 1971: Waldinventur mit Hilfe von Listenstichproben. Forstwissen-schaftliches Centralblatt, 90 (1): 3-41.
- LOETSCH, F., HALLER, K. E., 1973: Forest Inventory. Vol. I. München – Basel – Wien, 436 pp.
- SILVER, B., D., BORDERS, B., E., 1996: Sampling Techniques for Forest Resource Inventory. John Wiley & Sons, Inc. New York / Chichester / Brisbane / Toronto / Singapore, 356 pp.
- STIPSI, 2008: Stichproben – Simulator für Waldbestände und Forstbetriebe. Lehrprogramm für Forststudenten. Fortbildungsprogramm für Forsteinrichter. Forstliche Versuchs- und Forschungsanstalt. Baden – Württemberg (FVA), Freiburg i. Br. Version 25. 01. 2008.
- SÜSS, H., 1982: Effektivitätssteigerung betrieblicher Forstinventuren durch 3P- Sampling. VWGÖ, Wien, 79 p.
- ŠMELKO, Š., 1979: Skúšobné plochy pre overovanie reprezentatívnych metód inventarizácie lesa. In: Zborník prác LF VŠLD Zvolen, 21, Bratislava: Príroda, s. 153-182.
- ŠMELKO, Š., 1988: Presnosť nových rastových tabuliek ČSSR pri zisťovaní zásob porastov. Acta Facultatis forestalis, Zvolen, 2: 179-193.
- ŠMELKO, Š., 1990: Zisťovanie stavu lesa kombináciou odhadu a merania dendrometrických veličín. Vedecké a pedagogické aktualita č. 6. Zvolen: Edičné stredisko VŠLD Zvolen, 88 s.
- ŠMELKO, Š., 2007: Dendrometria. II. vydanie. Zvolen: Vydavateľstvo TU Zvolen, 409 s.
- ŠMELKO, Š., ŠEBEŇ, V., BOŠELA, M., MERGANIČ, J., JANKOVIČ, J., 2008: Národná inventarizácia a monitoring lesov SR 2005–2006. Zá-

kladná koncepcia a výber zo súhrnných informácií. Národné lesnícke centrum – Lesnícky výskumný ústav Zvolen, Bratislava: Lesmedium SK, s. r. o., 16 s.

- ŠMELKO, Š., ŠEBEŇ, V., 2010: Nové trendy v metódach zisťovania stavu lesa a potreba ich uplatnenia v HÚL na Slovensku. In: Zborník príspevkov z odborného seminára Súčasnosť a budúcnosť hospodárskej úpravy lesov na Slovensku. 27. 1. 2010, Zvolen: NLC, 9 s.
- ULBRICHT, R., 1984: Bestockungsinventur in der Forsteinrichtung der DDR – ein Beitrag zur Charakterisierung und Rationalisierung der Bestandesinventur. Dissertation. Tharandt, 358 pp.
- ZÓHRER, F., 1980: Forstinventur. Ein Leitfaden für Studium und Praxis. Hamburg und Berlin: Verlag Paul Parey, 207 pp.

### Summary

The performed theoretical analysis and experimental tests provide new knowledge about the sampling methods identified as „List Sampling“, and the possibilities of their practical application in evaluating of forest condition. It enables an effective use of existing data, verifying its accuracy and updating with new small-scale control measures.

Procedure „List Sampling“, i.e. the sampling of units from the predetermined list is designed for cases where such a list is already available from previous surveys, and when one may expect a close linear relationship between existing and new data. The sampling of units can be done in four ways (by simple random or systematic sampling, irrespective of their size, PPS sampling favoring size of units, e.g. area of forest stands, and PPP sampling favoring units with higher value of the examined variables, e.g. growing stock of stands). Following the sampling, an appropriate algorithm for data processing, derived from the control survey sampling, namely the regression analysis, the ratio (R ratio), PPS and PPP, is employed.

Experimental tests carried out with the greatest possible objectivity confirmed the good applicability of all these variants. Using a small number of control stands (15 resp. 20 in the category of young, middle-aged and old stands) the bias of the original data was removed (which reached -15 to -25%) and the statistical and real errors were satisfying enough. The errors of the revised, respectively the updated data did not exceed, with the 95% probability, confidence interval  $\pm 4\%$  for the entire digital forest, and  $\pm 12.8$  to  $\pm 16.2\%$  for each forest stand. The only exception is PPS sampling, where the statistical accuracy is about 2 times worse than the other three techniques, but regarding the removal of the bias and regarding the interval of the real errors it is equivalent to them.

Acquired knowledge is a methodological basis that is fully usable for different surveys in the forest and the land if they meet the conditions for which the procedures are appropriate. At the same time, it serves as a starting point for designing a new method of objectification of management data about the status of forests in Slovakia, where is a suspicion of bias of about -25% comparing to real status.

*Translated by author*