

***Raport științific anual
privind implementarea proiectului:
„Mobilizarea și monitorizarea efortului cu impact
climatic pozitiv din sectorul forestier”***

**(cod ERANET-FACCE ERAGAS - FORCLIMIT)
Contract 82/2017**

**Etapa 1: Compilarea bazelor de date cu inventarul forestier local și
includerea acestora în bazele de date**

Perioada de implementare: 1.10.2017-31.12./2017

1. Introducere. Contextul științific.

Consortiul FORCLIMIT susține ca potențialul de reducere de emisii asociat pădurilor din Europa este semnificativ, cu toate acestea, este insuficient utilizat în cadrul politicilor UE privind clima, și dăm ca exemplu propunerea LULUCF publicată în Regulamentul 479 din iulie 2016 (Ellison et al., 2014, Comisia Europeană 2016), în acest moment în negociere trilaterală de către instituțiile UE (Parlamentul European, Comisia Europeană) și guvernele naționale (reunite în consiliul UE). Până în prezent, pădurile și resursele forestiere europene au compensat aproximativ 13% din emisiile cauzate de utilizarea combustibililor fosili în Europa, reprezentând aproximativ 569 Mt CO₂/an (Nabuurs et al., 2015), rezultate din sechestrarea carbonului în păduri și din activități de evitare a reducerilor de emisii. În această propunere, ne concentrăm în mod special pe potențialul de reducere de emisii al pădurilor și al resurselor forestiere (o parte semnificativă a așa numitului LULUCF) în cadrul mai larg al sectorului AFOLU (IPCC, 2006). Potențialul suplimentar disponibil de reducere de emisii al pădurilor, al solurilor și al resurselor forestiere este ridicat, însă acest potențial este incert, pe de o parte, din cauza lipsei de stimulente din partea politicilor existente și, pe de altă parte, din cauza incertitudinii privind aplicarea și efectele activităților desfășurate în acest sens de proprietarii de păduri și utilizatorii de resurse lemnoase. Noi abordăm aceste două aspecte împreună, deoarece numai astfel pot fi făcute progrese evidente.

FORCLIMIT are trei **obiective principale**:

(1) să analizeze și să propună îmbunătățiri ale cadrului de contabilizare reduceri de emisii într-un cadru de politici unificate internațional, care să faciliteze o contabilizare consistentă a emisiilor din păduri din diferite țări;

(2) să analizeze strategiile economice și ale politicilor existente în motivarea proprietarilor de terenuri ca aceștia să depună eforturi pentru reducerile de emisii din păduri și lanțul de custodie al lemnului;

(3) să adauge la sistemul MRV actual, care vizează doar estimarea nationala a emisiilor, posibilitatea de estimare îmbunătățită la scara mica, ex. Arboret, unitate de administrare, precum și evaluarea măsurilor economice și a politicilor existente. Acest lucru este demonstrat prin trei studii de caz în trei țări diferite: Olanda, Romania si Suedia.

2. Metode si rezultate

Implementarea activităților prevăzute în pachetul de lucru presupune realizarea bazelor de date pentru rularea modelelor: modelul Yasso15 în grupul de lucru 4 (WP4), și respectiv, modelele CBM-CFS și EFISCEN/EFISCEN space în WP6. Activitățile realizate sunt:

a) **Elaborarea “metodologiei pentru cuantificarea descompunerii litierei prin metoda litter bag”**

Metodologia este descrisa în Anexa 1. Experimentul asociat a constat în amplasarea a 640 plicuri cu litieră și a 448 plicuri cu lemn mort în 4 tipuri de pădure de pe raza O.S. Pădurile Șincii (jud. Brașov). Experimentul va fi urmărit pentru o perioadă de 2 ani prin prelevare de probe potrivit calendarului din metodologie.

b) **Elaborarea bazei de date cu creșterea curentă anuală și volumul pe picior din păduri**

Creșterea curentă anuală pentru perioada post-1990 extrasă din baza de date amenajistică a ocoalelor silvice administrate de Regia Națională a Pădurilor. Baza de date conține descrierea parcellară la nivel de unitate amenajistică (u.a.) pentru 80 de ocoale silvice răspândite în întreaga țară și toate formațiile de relief. Criteriile de clasificare și parametrii disponibili sunt prezentate în Anexa 2.

c) **Elaborarea bazei de date cu volumul lemnului comercial pe picior din Inventarul Forestier National**

Baza de date privind creșterea curentă și volumul lemnului întreg pe picior detaliate pe regiuni de dezvoltare, 10 tipuri de pădure/specii de arbori și clase de vârstă de 10 ani este disponibilă. Criteriile de clasificare și parametrii disponibili sunt prezentate în Anexa 3.

d) **Studiu privind influența amplitudinii variabilei independente asupra incertitudinii modelelor alometrice**

Alometria arborilor este un instrument vital pentru estimarea stocului de carbon în păduri și a modificărilor acestuia. Iar incertitudinea asociată acestor estimări este o componentă esențială deoarece arată cât de multă încredere pot avea factorii de decizie în aceste estimări. Ca urmare, am inițiat elaborarea unui studiu privind influența amplitudinii DBH (diametrul de bază) asupra incertitudinii modelelor alometrice. Rezultatele preliminare ale acestui studiu sunt prezentate în anexa 4.

e) **Ajustarea curbelor volumului pe picior și creșterii în volum a arboretelor**

Aplicabilitatea locala a modelelor CBM-CFS, Yasso07/15 si EFISCEN este conditionata de parametrizarea locala. Ca urmare este necesara ajustarea datelor locale din amenajament sau/si din Inventarul Forestier National pentru a obtine curbele volumului pe picior si curbele cresterii anuale. Pentru aceste doua tipuri de curbe s-au testat patru modele teoretice sigmoide de crestere arboretelor: Logistic, Weibull, Gompertz si Chapman-Richards. Metoda de ajustare este regresia neliniara in R folosind aplicatia nlrob (pachetul „robustbase”, URL: <http://robustbase.r-forge.r-project.org/>). Modelul care ajusteaza cel mai bine datele empirice este identificat cu criteriul Akaike. Rezultatele curente sunt prezentate in Anexa 5.

f) Administrarea bazei de date

- procesarea statistică se va face cu prioritate în R (open source): <https://cran.r-project.org/bin/windows/base/>
- modul de stocare și actualizare a bazei de date urmează a fi definit: fișiere Excel actualmente, insa majoritatea urmează a fi convertite în .db – Microsoft Access.

g) Sprijin activități incluse in alte pachete de lucru din FORCLIMIT

- informare continua cu privire la regulile de contabilizare a reducerilor de emisii din sectorul folosinței terenurilor incluse în Pachetul energie clima 2030 (https://ec.europa.eu/clima/policies/strategies/2030_en), in sprijinul Pachetelor de lucru 1 si 2 ale FORCLIMIT
- sprijin pentru pachetul de lucru 5.2. în vederea identificării surselor de incertitudini în modelele allometrice.

3. Managementul proiectului

În primele săptămâni ale derulării proiectului, în paralel cu etapele aferente experimentului de literă, precum și cu procesul de angajare în cadrul proiectului a tuturor membrilor echipei, am dat startul și la achiziția diferitelor echipamente și materiale prevăzute la capitolul logistică pentru etapa 2017. Deoarece perioada de timp scursă din momentul semnării contractului și termenul limită de raportare impus de către UEFISCDI (8 decembrie 2017) a fost una extrem de scurtă, a fost necesar alocarea unui timp și energie suplimentară în vederea soluționării diferitelor aspecte birocratice, atât din partea directorului de proiect cât și din partea personalului aferent de la biroul contabilitate și de la biroul de achiziții publice din cadrul instituției gazdă în care se implementează prezentul proiect.

Însă cel mai important impediment întâlnit în această primă etapă este cel legat de IMPUNEREA de către partea finanțatoare (UEFISCDI) a cheltuirii a aproximativ 30% din bugetul total al proiectului prevăzut pentru 3 ani (1.10.2017-31.05.2020) în mai puțin de 3 luni (!!!), acum la începutul derulării proiectului. Această balanță dezzechilibrată a bugetului dacă nu ar fi fost gestionată cu responsabilitate de către directorul de proiect ar fi putut avea consecințe nefaste asupra întregii activități a proiectului. Solicităm și pe această cale forurilor decizionale din Ministerul Cercetării și din UEFISCDI o reflecție mai profundă în impunerea acestor dezzechilibre bugetare la nivel de ani calendaristici, oricare ar fi motivația ce a condus la o astfel de decizie.

Ca și **vizibilitate internațională** a proiectului FORCLIMIT menționăm lansarea site-ului asociat al proiectului, site ce se regăsește la linkul: <http://www.forestinventory.no/forclimit/>.

Referitor la **comunicarea excelentă avută cu partenerii europeni implicați în proiect** amintim întâlnirea kick-off avută între toate instituțiile partenere în Norvegia, la Oslo, în perioada 14-17 Noiembrie 2017. În prima zi 15 noiembrie 2017, fiecare partener a prezentat echipa și s-au derulat formalitățile privind agenda de lucru pentru cele două zile propuse. Întâlnirea s-a axat pe discutarea progreselor și stabilirea activităților fiecărui pachet de lucru, crearea legăturilor cu stakeholderii, indentificarea provocărilor/riscurilor și necesitatea pentru coordonare între pachetele de lucru prevăzute pe toata perioada proiectului, de asemenea fiecare etapă prevăzută a fost discutată amănunțit. În a doua zi 16 noiembrie 2017 am participat la o videoconferință cu potențiali colaboratori din alt proiect (INVENT) dar cu finanțare de la același program și focusul a fost pe colaborări externe.

Brașov, 4.12.2017

Dr. ing. Viorel Blujdea



Anexa 1. Metodologie pentru cuantificarea a ratei de descompunere a litierei si lemnului more de mici dimensiuni prin metoda "litter bag"

Definitii:

În acest experiment, "litiera" reprezintă frunze în stare naturala la sfârșitul ciclului de vegetație, "lemnul mort de mici dimensiuni" reprezintă lemn de dimensiuni inferioare celui înregistrat de Inventarul Forestier National ca lemn mort (presupunerea fiind ca acea variabila este deja înregistrată de IFN pentru tipurile de pădure în cauza). Ca urmare în acest experiment este inclus lemn sub 5.6 cm diametru.

Design experimental:

Tipuri de pădure majore

- a) *gospodărită*: în molidiș, amestecuri de fag și rasinoase, și făget;
- b) *virgina*: în amestecuri.

Fiecare tip major de pădure va fi reprezentat printr-o suprafață de monitorizare.

Distribuția altitudinală: trei suprafețe de monitorizare (SP) corespunzând altitudinilor la care se găsesc cele trei tipuri de pădure țintă:

- făget (cod Ffa) – 600-700m;
- amestec (AMo; ABr; AFa) – 800-1000m,
- molidiș (Mmo) – peste 1100 m.

LITIERA

Număr de probe definit în funcție de speciile prezente: 8 probe/specie * 10 momente de recoltare = 80 probe

Total probe de amplasat:

FFa = 80 probe

AFa, ABr, AMo = 80 probe Fag + 80 probe Brad + 80 probe Molid (total = 240)

MMo = 80 probe molid

VFa, Br, Mo = 80 probe Fag + 80 probe Brad + 80 probe Molid (total = 240)

TOTAL = 640 probe litieră

LEMN MORT dimensiuni mici sub 5.6 cm (diam min IFN)

Număr de probe definit funcție de speciile prezente: 3 dimensiuni lemn mort * 8 probe/specie * 2 momente de recoltare an 1 * 3 momente de recoltare an 2 * 1 momente de recoltare an 3 * 1 momente de recoltare an 4 = 56 probe

Fiecare plic (cu 3 compartimente) conține bucăți de lemn mort de cca. 15 cm lungime și 3 categorii de diametre (<2, 2-4, 4-5.6 cm)

Total probe:

FFa = 56 plicuri (fiecare cu lemn de 3 dimensiuni)

AFa, ABr, AMo = 56 plicuri Fag + 56 plicuri Brad + 56 plicuri Molid (Total = 168)

MMo = 56 plicuri molid

VFa, VBr, VMo = 56 plicuri Fag + 56 plicuri Brad + 56 plicuri Molid (Total = 168)

TOTAL = 448 plicuri cu lemn mort

Recoltare necromasă și preprocesare LITIERA: recoltare de necromasă din anul curent din locațiile stabilite. Se aduce în saci în laborator și se lasă să se usuce în aer la temperatura constantă pentru 5-7 zile. Pași:

- se pregătesc plicurile (bags);
- se cântărește plicul gol împreună cu eticheta. Denumirea probei înscrisă pe etichetă în momentul cântăririi este compusă din SP și nr. de ordine, e.g. AFa49 – proba 49 de *fag* amplasată în *amestecuri*;
- se încarcă plicul cu biomasă (cca. 15 grame la fag, 10 gr. la rășinoase) și se cântărește din nou pentru a determina biomasa;
- înregistrarea astfel (Fișierul Excel: *Litiera_forclimit_data* ultimei actualizări) (poate fi revizuit la prima recoltare de probe ML1):

Nr.	Cod probă	MT0 (grame)	MLT0 (grame)	ULT	Data și momentul recoltării	MLTf (grame)	Tc	Uso
1					e.g. 23/07/2018 (M3)			
2								

MT0 – masă plic și etichetă

MLT0 – masa plic, etichetă și litieră

ULT – Umiditate relativă proba la momentul inițial, % și STD

Data și momentul recoltării – se va indica data recoltării și momentul (unul din cele 10 momente de recoltare, ML1 până la ML10);

MLTf – masă finală probă (masa plic, eticheta și probă)

Tc – temperatura

Uso – umiditate sol

Recoltare necromasă și preprocesare LEMN MORT:

Lemn din arbori vii pentru toate cazurile pentru a surprinde stocul de C corespunzător arborilor vii. Se usucă în laborator la temperatura constantă pentru o săptămână. Se taie în lungime de cca. 15 cm. Se măsoară diametrul la mijloc.

Se cântăresc înainte de a fi introduse în plicuri și se înregistrează astfel (Fișierul excel: *LemnMort_forclimit_data* ultimei actualizări):

Nr.	Cod probă	MT0 (grame)	MLT0 (grame)	ULT	Data și momentul recoltării	MLTf (grame)	Tc	Uso
1					e.g. 23/07/2018 (M3)			
2								

MT0 – masă plic și etichetă

MLT0 – masa plic, etichetă și lemn mort

ULT – Umiditate relativă proba la momentul inițial, % și STD

Data și momentul recoltării – se va indica data recoltării și momentul (unul din cele 10 momente de recoltare, ML1 până la ML10);

MLTf – masă finală probă (masa plic, eticheta și probă)

Tc – temperatura

Uso – umiditate sol

Estimarea factorului de corecție a umidității necromase la momentul inițial. După uscare în aer în laborator se colectează o probă omogenizată (din mai multe locuri) pe specie și se determină umiditatea relativă. Se usucă până la masă constantă în etuvă, la 80°C, se înregistrează masa înainte și după uscare, și se calculează valoarea medie a umidității biomasei.

Probele colectate în diverse momente de recoltare ulterioare se usucă individual în etuvă, deci nu necesită factor de corecție pentru umiditate.

Colectarea datelor de umiditate a solului în momentul recoltării se măsoară gravimetric astfel: se colectează proba de sol de la 0-10 și 10-20 cm adâncime, se pune într-o pungă închisă ermetic. În laborator se cântărește masa totală proaspătă, se usucă la 105°C până la masă constantă, se cântărește masa pungii. Umiditatea se calculează în procente (%).

Colectarea datelor de temperatură la nivelul literei și la 2 m în aer – vor fi prelevate cu senzori cu înregistrare automată.

Construcția plicurilor. "Bag" este un plic: a) cu dimensiuni 20*30 cm pentru fag din plasa de țânțari cu dimensiunea ochiului de 1 mm și b) cu dimensiuni 10*10 cm pentru rășinoase din plasa de perdea fină. Plicul rezultă din plasa pliată și lipit la cald pe două margini, latura nelipită va fi capsată cu un număr egal de capse pentru plicurile de fag, sau lipită la cald la rășinoase.



Codificare. Fiecare plic/bag are un cod inscripționat cu marker permanent pe eticheta care va fi introdusă în plic.

Amplasarea probelor în suprafața de proba. Plicurile vor fi așezate în buzunarul creat prin plierea plasei cu muchia în aval, care să limiteze/împiedice aderarea necromasei de plicuri. Buzunarul va fi fixat pe sol cu țărugi. Buzunarele vor fi întinse pe sol în șiruri, într-un dispozitiv care să permită găsirea lor ulterioară la momentele de recoltare. Plicurile se așază în buzunar. Dispozitivul fotografiat. Arborii de lângă locul amplasării și cel care marchează accesul de la drumul rutier însemnați cu vopsea.



Probele trebuie așezate înainte de căderea majorității frunzelor astfel încât să fie acoperite natural, ori frunze proaspete vor fi împrăștiate peste plicuri.

Cordonatele geografice ale amplasamentelor Litiera&Lemn Mort

Data amplasarii plicurilor	Locatia (OS, alte repere geografice)	Coord. geografice	Comentarii
			EX. LT+LM, LT

Termene de recoltare/prelevare probe. Amplasare probe in luna octombrie-noiembrie 2017. In anul 2018 se vor efectua 7 recoltări in lunile M4 (aprilie), M5, M6, M7, M8, M9, M10. In anul 2019 se vor efectua 3 recoltări în M5 (Mai), M7 si M9. In total 10 recoltări.

Recoltare la termenele stabilite: La termenul stabilit de prelevare, se identifica locația, plicurile vor fi acoperite de frunze si posibil nevizibile. Se culeg cele 8 plicuri, i.e. primul + al 9-lea + al 17-lea +....., în așa fel să nu se piardă nimic prin ochiuri. Este foarte importanta separarea impurităților externe: cu o pensula sau lama fina se îndepărtează toata masa atașata de plic pe ambele părți, se pune apoi într-o punga. Pungile se aduc în laborator, se lasă deschisa sa se usuce în aer, apoi se usucă in etuva la 80°C (80C este compatibil cu factorul de corecție al umidității). Se cântărește conținutul total al plicului se înregistrează în tabelul de mai sus.

Alte analize necesare/posibile:

1. Gradul de descompunere poate fi descris și vizual (fotografiat) pentru fiecare moment, ca o completare de informație la partea cântărită.
2. Concentrația de minerale și azot la fiecare moment (C/N).

Parametrii obținuți privind descompunere ne sunt utili la modelul Yasso.

3. **Fracțiunile Yasso pentru probe inițiale** (pregatite pentru posibila prelucrare in laborator de catre partenerul Finnish Meteorological Institute, FMI (P5))

Anexa 2. Criteriile de clasificare si parametrii inclusi in descrierea amenajistica

Cod	Descriere
ADM	Administratie:1-de stat;2-particular
ALT	Altitudine
AMS	Amestec 1-7
CAL	Calitate(este reprez lemnul de lucru din total%)
CEL	compoziția țel la nivel de u.a.
CLP	Clasa de productie
CNF	Configuratia terenului
CNS	Consistenta
COMPOZ	Compoziția actuală
CP	Clasa de productie pentru elemente
CPC	clasa de producție calculată de program, în corelație cu ceilalți parametri ta*atorici-specie, vârstă, înălțimea dată de proiectant
CPR	proporția speciilor din compoziția țel?
CRS	creștere anuală impusă de proiectant pe fiecare element (mc/ha)
CRSC	creșterea curentă (mc/an/ha) pentru elementul respectiv, dată de calculator
CRSNULL	creștere anuală, în cazul în care dorim să ignorăm creșterea dată de calculator
CRTI	Caracterul tipului de padure
DC	Date complementare
DEC	Reprezintă, în zecimi, suprafața pe care se aplică lucrarea propusă. Sunt trei celule, corespondente celor trei lucrări ce se pot propune într-o u.a.
DM	Diametrul mediu
DMC	diametrul mediu calculat de program, în corelație cu ceilalți parametri ta*atorici- specie, vârstă, înălțime, clasă de producție...
DRM	codul drumului ce deservește u.a.
DS	Desimea arboretelui (3 inseamna 30% din suprafata
DST	distanța, în hectometri, din centrul de greutate al u.a. și până la drumul ce deservește u.a.
ELG	Elagaj(1-4)
ELM	Element de arboret
ELMPRINC	elementul principal (în funcție de acesta se colorează harta arboretelor)
ERZ	Eroziune
EX	EXploatabilitatea
EXP	EXpozitia
FCT	categoria funcțională
FF	Fond Forestier
FIL	Filiala
FLR	Flora
FLS	Folosinta
GF	Grupa functionala
HM	Inaltimea medie
INC	Inclinare in grade centesimale
INV	Inventariat

Anexa 3. Criteriile de clasificare si parametrii agregati regional pentru baza de date națională din Inventarul Forestier National

Criteria	Specificatii
Tip de padure/ specii	Rasinoase, Molid, Brad, Predom rasinoase, Amestecuri, Predom foioase, Foioase, Fag, Cvercinee, Salcam
Clase de varsta	1-10, 11-20, 21-30, 31-40, 41-50, 51-60, 61-70, 71-80, 81-90, 91-100, 101-110, 111-120, 121-130, 131-140, 141-150, 151-160, >160, Unevenaged
Regiuni administrative (NUTS-2)	RO11, RO12, RO21, RO22, RO31, RO32, RO41, RO42
Volum pe picior	Volume annual, m3 y-1
Recolta de masa lemnoasa	Volume annual, m3 y-1
Suprafata	Area, ha
Creserea neta anuala	Net annual growth, m3 y-1 ha-1
Eroarea de eşantionare (in %) pentru toți parametrii de mai sus	Estimation error, %

Anexa 4. How important is the range of covariate for biomass allometric models?

Empirical models are often used in forest ecology for either statistical inference or prediction. Although the range of covariate (i.e. independent variable or predictor) is rather selected on a matter of practical convenience or availability, it may have important consequences on regression results. In this paper we investigated the importance of covariate range in regression analysis, and evaluated the implications for biomass allometric models. Simulations of log-transformed linear allometric models (controlling for root mean squared errors - RMSE, number of observations and covariate range) showed that range is an important regression characteristic, affecting the standard error of the slope. Increasing the range of covariate (under constant RMSE and number of observations) reduces the standard errors of the slope. For allometric models, the benefit is higher when expanding the covariate range towards small diameter trees. A larger covariate range reduces model uncertainty and type II errors (increases the information against null hypothesis in t-test and F-test). Therefore, increasing the range of covariate, the treatment effect (in ANCOVA) becomes stronger and the prediction more confident. It is advised therefore that, when sampling trees to develop allometric equations, the covariate range covers all possible values, priority being given to small diameter trees.

Introduction. Linear models are widely used in ecology (Underwood 1997). However, when the relationship between variables is not linear, it is often adopted a transformation to obtain a linear relationship. It is also the case of allometric models (that are regression models using tree diameter and/or height to predict biomass) that nonlinear ‘power’ function relationships are transformed into linear, by logarithmic transformation of variables (Baskerville 1972).

Accurate estimations of forest carbon stock and stock change relies on good prediction models. However, the uncertainty of these models, if all assumptions are met, is given by (i) spread of the data along regression line (defined by RMSE, root mean squared error) and (ii) number of observations. RMSE and number of observations affect the uncertainty of both intercept and slope. A higher RMSE would yield large standard errors of intercept and slope. Likewise, a larger number of observations would produce lower standard errors, Duncanson et al. (2015) stressing that small sample size can yield biased prediction of biomass.

In this paper, we investigated the importance that range of covariate has in allometric models. We hypothesized that: i) a larger range of covariate would yield lower model uncertainty for constant RMSE and number of observations; ii) expanding the range of covariate towards small trees or towards large trees would have a different effect on standard errors.

Material and methods. Simulation study.

R simulations for two models with similar number of observations (n) and similar RMSE (root mean squared error), but different ranges of covariate were performed:

$$(1) \quad \text{Model 1: } y_{1i} = a_1 + b_1 x_{1i} + \varepsilon_i, \quad i = 1 \dots n, \quad \varepsilon_i = N(0, RMSE)$$

$$(2) \quad \text{Model 2: } y_{2i} = a_2 + b_2 x_{2i} + \varepsilon_i, \quad i = 1 \dots n, \quad \varepsilon_i = N(0, RMSE)$$

Further, we simulated log-transformed allometric models for different values of RMSE, number of observations and ranges of covariate:

The simulated values for the range of covariate:

DBH = 1 to 10 cm

DBH = 1 to 20 cm

DBH = 1 to 30 cm

DBH = 1 to 40 cm

DBH = 1 to 50 cm

DBH = 1 to 60 cm

DBH = 1 to 70 cm

DBH = 1 to 80 cm

DBH = 1 to 90 cm

DBH = 1 to 100 cm

The simulated sample size:

n = 50

n = 100

n = 500

n = 1000

The simulated values of Root Mean Squared Error:

RMSE = 0.2

RMSE = 0.3

RMSE = 0.4

Results

The range of covariate affected the standard error of the slope. The relationship between standard errors of the slope of two linear models with similar number of observations (n) and similar root mean squared error (RMSE) is given by the following relation:

$$(3) \quad SE_{b_1} = SE_{b_2} \times \frac{x_2 \max - x_2 \min}{x_1 \max - x_1 \min}$$

where SE_{b_1} is the standard error of the slope of the model 1; SE_{b_2} is the standard error of the slope of the model 2; $x_1 \max$ and $x_1 \min$ are the maximum, respectively minimum, covariate values for the model 1; $x_2 \max$ and $x_2 \min$ are the maximum, respectively minimum, covariate values for the model 2.

In figure 1, can be observed that predicted SE_{b_1} values by Equation 3 do an almost perfect match with the observed SE_{b_1} values.




Figure 1. Predicted standard error of the slope (from Equation 5) versus observed standard error of the slope.

Whereas RMSE and number of observations affects the standard errors of both intercept and slope, the range of covariate affects the standard errors of slope only. The standard errors decreased by the number of times the range of covariate increased (assuming constant RMSE and sample size).

Implications for allometric models

In linear models, the net benefit of expanding the covariate range is dependent on the size of increase only (Fig. 1). For example, an increase of the range by 100%, results in a decrease by 50% of the standard error of the slope (under constant number of observations and RMSE).

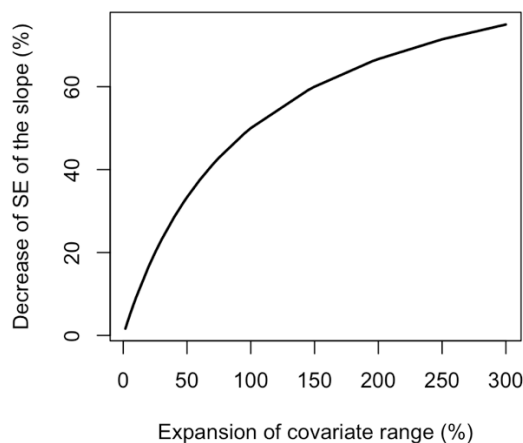


Figure 2. The net benefit on standard error of the slope (expressed as percent decrease), by expanding the covariate range, in linear regression models

However, this is not true for allometric models, because allometric models are not linear, but they can be linearized through log-transformation of both variables. Therefore the range of covariate in Equation 5 is calculated as $\log(x_{\max}) - \log(x_{\min})$, resulting in a lower actual benefit for allometric models.

The standard error of the slope decreased with the increase of DBH range and sample size (table 1). For the same covariate range, the standard errors of both intercept and slope decreased with the increase of sample size.

Table 1. Simulated standard errors of the slope for different DBH ranges and different sample sizes of log-transformed linear model

DBH range (cm)	log(DBH) range	Sample size (n)			
		50	100	500	1000
1 to 10	0 to 2.3026	0.046318	0.030717	0.013764	0.009439
1 to 20	0 to 2.9957	0.035601	0.023610	0.010579	0.007255
1 to 30	0 to 3.4012	0.031357	0.020795	0.009318	0.006390
1 to 40	0 to 3.6889	0.028911	0.019173	0.008591	0.005891
1 to 50	0 to 3.9120	0.027262	0.018080	0.008101	0.005556
1 to 60	0 to 4.0943	0.026048	0.017275	0.007741	0.005308
1 to 70	0 to 4.2485	0.025103	0.016648	0.007460	0.005116
1 to 80	0 to 4.3820	0.024338	0.016141	0.007232	0.004960
1 to 90	0 to 4.4998	0.023701	0.015718	0.007043	0.004830
1 to 100	0 to 4.4652	0.023159	0.015358	0.006882	0.004719

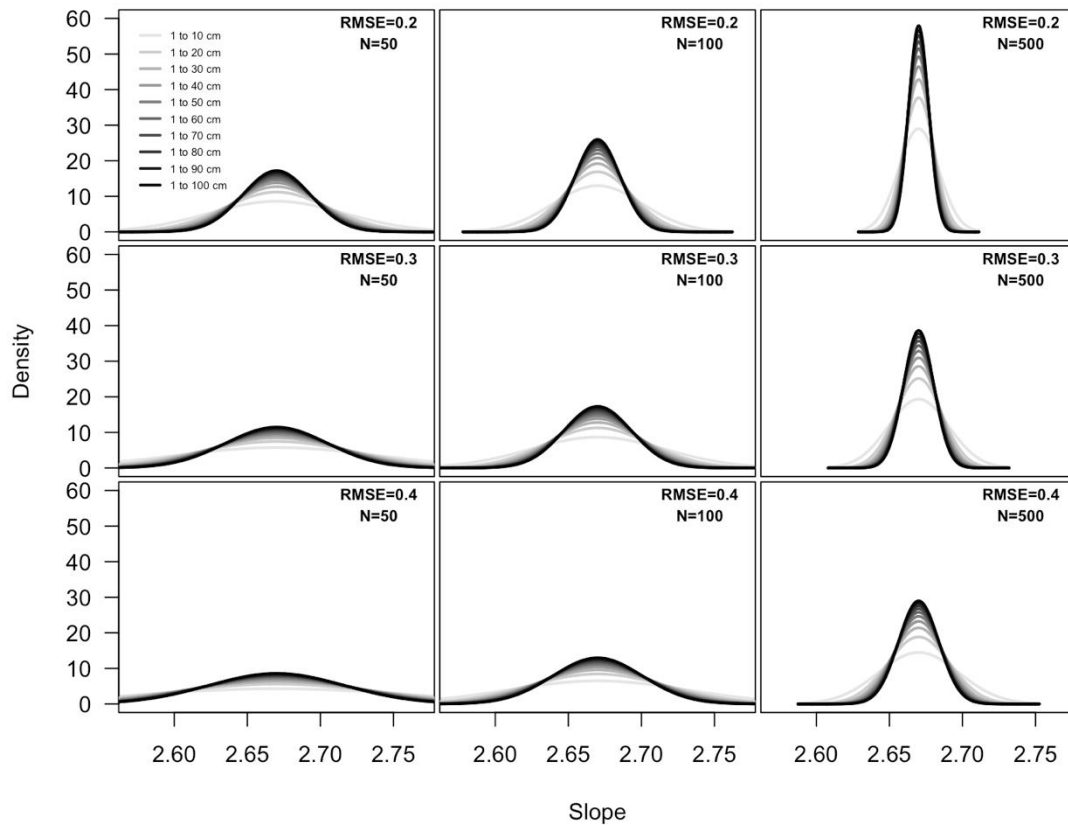


Figure 3. Probability density of the slope, for different values of covariate range (10 intervals for DBH, represented with different shades of grey in each plot), root mean square error (three values of RMSE) and number of observations (three values of N).

Discussion. Why does the range of covariate affect standard error of the slope?

In ordinary least squares methods, the standard error of the slope is calculated using the formula:

$$(4) \quad SE_b = \frac{\sqrt{\frac{\sum(y_i - \bar{y})^2}{n-2}}}{\sqrt{\sum(x_i - \bar{x})^2}}$$

where y_i is the log of observed biomass value of the i^{th} tree, \hat{y}_i is the log of predicted biomass for the i^{th} tree, n is the number of observations (trees); x_i is the log of independent variable's i^{th} value, \bar{x} is the mean of log-transformed independent variable values.

As the range of independent variable increases, the denominator increases. However, the numerator remains constant, if the RMSE and sample size doesn't change. Therefore, under the assumption of constant RMSE and sample size, the standard error of the slope decreases with the increase of covariate's range.

Range of covariate and t -test

As covariate range affects the standard error of the slope, it is further affected the t -test associated with testing whether the slope is different from zero. Expanding the covariate range makes the slope estimate more certain, decreasing its standard error.

The t -score of the slope is calculated as:

$$(5) \quad t = \frac{b}{\sqrt{SE_b^2}}$$

Because the standard error decreases when covariate's range increases, in Eq. 5 the denominator decreases, whereas the numerator remain unchanged, resulting in an increase of the overall t -score. The increase of t -score is results into a clearer rejection of null hypothesis under t -test. Assuming that the null hypothesis of the slope is false, if covariate's range is small (and therefore the information against null hypothesis is weak), we can fail to reject null hypothesis, committing a type II error. Therefore, the increase of covariate's range, help reducing the false negative errors.

The range of covariate and model uncertainty

The range of covariate affects the model confidence interval. A larger range of covariate, under constant RMSE and number of observations, yields a narrower 95% confidence interval (figure 4).




Figure 4. The 95% confidence interval

Which direction to expand? When deciding to expand the range of covariate is important to know in which direction. Towards small or towards large trees? Sampling trees and measure their biomass is extremely labour intensive. The effort invested in measuring tree biomass increases with tree size. Therefore, in this regard, expanding covariate range towards lower diameters would be more convenient, as small trees are easier to measure. Moreover, expanding the range towards smaller

diameter trees, has a greater reward too (Fig. 3). Expanding the range of covariate by a certain percent seems to have different impact on standard errors of the slope. For example, considering a DBH covariate range between 30 and 70 cm, expanding this range by certain percent towards small or large trees, gives different net benefit; expanding the range by 50% towards small diameter trees, the standard error of the slope decreased by 56.4%, whereas expanding it towards large diameter trees, the standard error of the slope decreased by 22.9% only. The net benefit on standard errors of the slope, becomes larger as the size of expansion increases.

Log-transformation increases the distance between observations for small trees and reduces the distance between observations for large trees. Therefore, for example, in log-transformed space, the DBH length from 5 to 10 cm would be larger than 95 to 100 cm (although in arithmetic space these intervals are similar). As a result, in log-transformed space, the small trees bring a stronger relative contribution, compared to large trees.

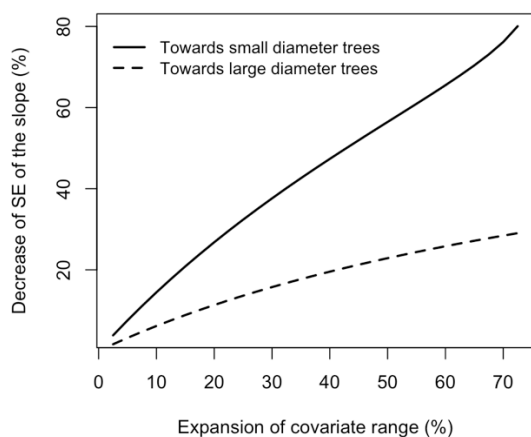


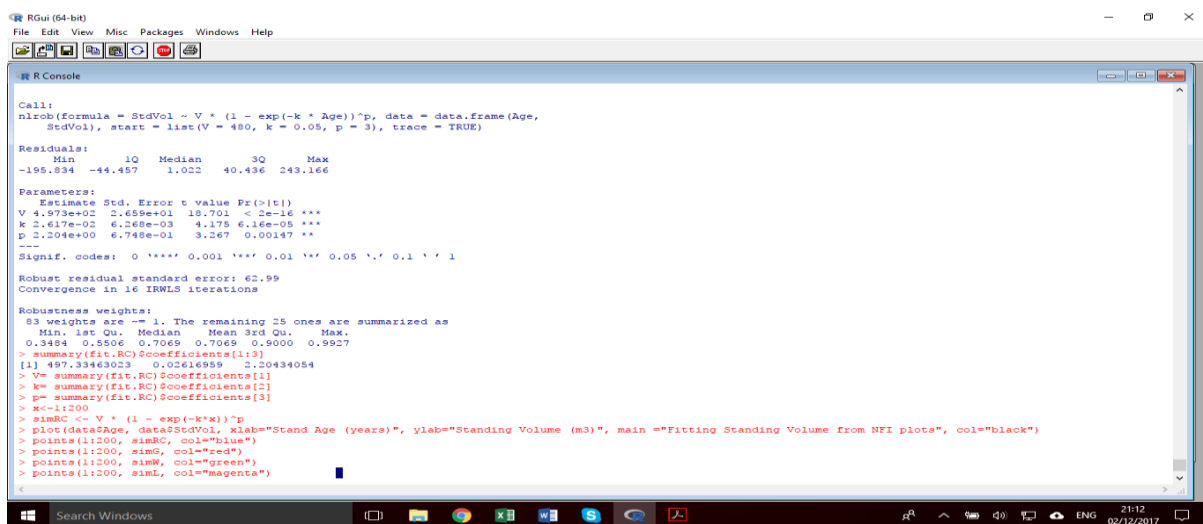
Figure 5. The net benefit on standard error of the slope (expressed as percent decrease), by expanding the covariate range of allometric models towards small diameter trees and towards large diameter trees.

References

- Baskerville GL (1972) Use of Logarithmic Regression in the Estimation of Plant Biomass. *Can J For Res* 2:49–53. doi: 10.1139/x72-009
- Duncanson L, Rourke O, Dubayah R, et al (2015) Small Sample Sizes Yield Biased Allometric Equations in Temperate Forests. *Sci Rep* 5:17153. doi: 10.1038/srep17153
- Underwood AJ (1997) *Experiments in ecology : their logical design and interpretation using analysis of variance*. Cambridge University Press

Anexa 5. Stadiul curent in procesarea datelor locale privind curbele volumului pe picior si cresterii anuale in volum

1. Metoda de stabilire a valorilor initiale este in ca in stadiu preliminar si urmeaza a fi incorporata in scriptul de ajustare a modelelor (metoda urmareste in principal publicatia Stamatoopoulos, C., and Caddy, J.F. 1989. Estimation of von Bertalanffy growth parameters: A versatile linear regression approach. - J. Cons. int. Explor. Mer, 45: 200-208). Varianta curenta de lucru consta in utilizarea pantei (pentru estimarea „factorului de crestere”) si interceptiei (pentru valoarea „asimptotei” volumului pe picior) regresiei liniare dintre cresterea in volum si volumul pe picior. Factorul „p” este considerat potrivit literaturii in jur de 3 (reflecta procentul natural al mortalitatii).
2. Rezultate privind ajustarea volumului pe picior functie de varsta aboretului cu modelul Chapman – Richards (procedura „nlrob”)



```

RGui (64-bit)
File Edit View Misc Packages Windows Help

R Console

Call:
nlrob(formula = StdVol ~ V * (1 - exp(-k * Age))^p, data = data.frame(Age,
  StdVol), start = list(V = 480, k = 0.05, p = 3), trace = TRUE)

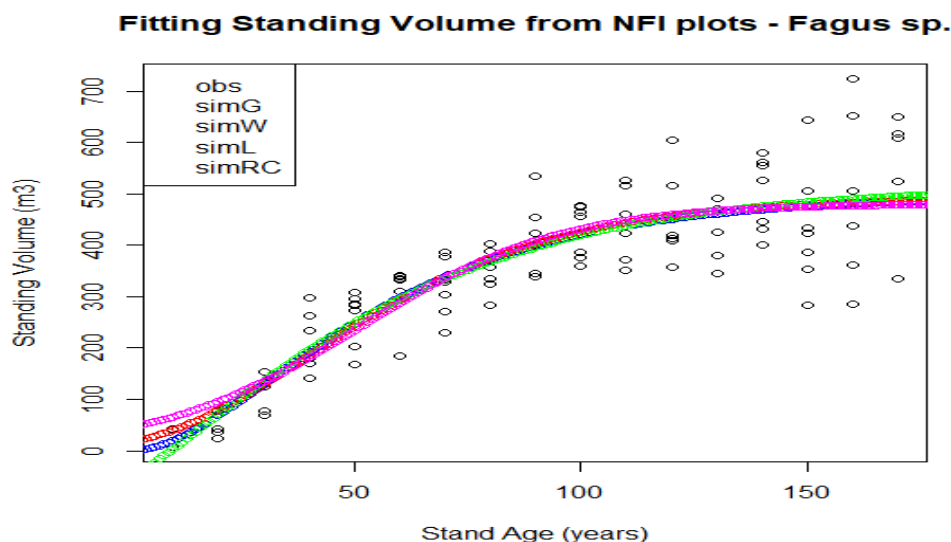
Residuals:
    Min       1Q   Median       3Q      Max
-195.834  -44.457    1.022   40.436  243.166

Parameters:
  Estimate Std. Error t value Pr(>|t|)
V 4.973e+02  2.658e+01  18.701 < 2e-16 ***
k  2.617e-02  6.268e-03   4.175 6.16e-05 ***
p  2.204e+00  6.748e-01   3.267  0.00147 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Robust residual standard error: 62.99
Convergence in 16 IRWLS iterations

Robustness weights:
83 weights are == 1. The remaining 25 ones are summarized as
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 0.3484  0.5806  0.7069  0.7069  0.9000  0.9927
> summary(fit.RC)$coefficients[1:3]
[1] 497.33463023  0.02616959  2.20434054
> V= summary(fit.RC)$coefficients[1]
> k= summary(fit.RC)$coefficients[2]
> p= summary(fit.RC)$coefficients[3]
> x<-1:200
> simRC <- V * (1 - exp(-k*x))^p
> plot(data$Age, data$StdVol, xlab="Stand Age (years)", ylab="Standing Volume (m3)", main="Fitting Standing Volume from NFI plots", col="black")
> points(1:200, simRC, col="blue")
> points(1:200, simG, col="red")
> points(1:200, simW, col="green")
> points(1:200, simL, col="magenta")
  
```

3. Reprezentare grafica a ajustarii cu cele patru modele selectate (i.e. albastru reprezinta curba volumului pe picior pentru Fagus silvatica (date IFN la nivel de NUTS-2) ajustata cu modelul Chapman-Richards, i.e. valoarea initiala este apropiata de zero)



4. Alegerea modelului potrivit criteriului Akaike (AIC) - cel mai potrivit model este cel care estimeaza valoarea cea mai mica a AIC.

Model	df	AIC
fit.Logistic	4	1250.543
fit.Weibull	5	1247.670
fit.Gompertz	4	1246.943
<i>fit.CR</i>	<i>4</i>	<i>1205.237</i>