Univerza
v Ljubljani

Fakulteta za
gradbeništvo in
geodezijo

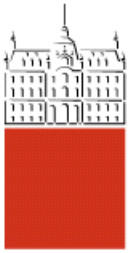

Kandidat:

mag. ANDREJ KOBLER, univ. dipl. inž. gozd.

NOVE METODE ZA OBDELAVO PODATKOV LETALSKEGA LASERSKEGA SKENERJA ZA MONITORING GOZDNIH EKOSISTEMOV

Doktorska disertacija štev.: 216

NEW METHODS OF PROSESSING AERIAL LASER SCANNER DATA FOR FOREST ECOSYSTEM MONITORING

Doctoral thesis No.: 216

Soglasje k temi doktorske disertacije je dal Senat Univerze v Ljubljani na 5. seji dne 21. marca 2006. Za mentorja je bil imenovan doc. dr. Krištof Oštir, za somentorja pa prof. dr. Saša Džeroskega, Institut “Jožef Stefan”.

Ljubljana, 25. julij 2011

Univerza
v Ljubljani

Fakulteta za
gradbeništvo in
geodezijo

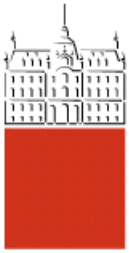

Komisijo za oceno ustreznosti teme doktorske disertacije v sestavi

- izr. prof. dr. Dušan Kogoj
- doc. dr. Mojca Kosmatin Fras
- doc. dr. Krištof Oštir
- izr. prof. dr. Sašo Džeroski, Institut "Jožef Stefan"

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 3. redni seji dne 28. septembra 2005.

Komisijo za oceno doktorske disertacije v sestavi

- doc. dr. Mojca Kosmatin Fras,
- dr. Tatjana Veljanovski, znanstvena sodelavka, ZRC SAZU
- prof. dr. Marko Debeljak, prof. ekologije na Univerzi v Novi Gorici in profesor gozdarstva na University of Tennessee, ZDA

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 20. redni seji dne 20. aprila 2011.

Komisijo za zagovor doktorske disertacije v sestavi

- prof. dr. Matjaž Mikoš, dekan UL FGG, predsednik
- izr. prof. dr. Krištof Oštir, mentor
- prof. dr. Sašo Džeroski, Institut "Jožef Stefan", somentor
- doc. dr. Mojca Kosmatin Fras
- dr. Tatjana Veljanovski, znanstvena sodelavka, ZRC SAZU
- prof. dr. Marko Debeljak, prof. ekologije na Univerzi v Novi Gorici in profesor gozdarstva na University of Tennessee, ZDA

je imenoval Senat Fakultete za gradbeništvo in geodezijo na 22. redni seji dne 22. junija 2011.

ERRATA

Stran z napako	Vrstica z napako	Namesto	Naj bo

IZJAVA O AVTORSTVU

Podpisani mag. Andrej KOBLER, univ. dipl. inž. gozd., izjavljam, da sem avtor doktorske disertacije z naslovom: » NOVE METODE ZA OBDELAVO PODATKOV LETALSKEGA LASERSKEGA SKENERJA ZA MONITORING GOZDNIH EKOSISTEMOV«.

Izjavljam, da je elektronska različica v vsem enaka tiskani različici.

Izjavljam, da dovoljujem objavo elektronske različice v repozitoriju UL FGG.

Ljubljana, 25. julij 2011 Andrej Kobler

……..
(podpis)

BIBLIOGRAFSKO-DOKUMENTACIJSKA STRAN IN IZVLEČEK

UDK: **528.7/.8:630*5:(043.3)**
Avtor: **Andrej Kobler**
Mentor: **izr. prof. Krištof Oštir**
Somentor: **prof. dr. Sašo Džeroski**
Naslov: **Nove metode za obdelavo podatkov letalskega laserskega skenerja za monitoring gozdnih ekosistemov**
Obseg in oprema: **126 strani, 15 preglednic, 25 slik, 10 prilog**
Ključne besede: **lidar, gozd, DMR, strojno učenje, model**

Izvleček:
Naloga je sestavljena iz dveh sklopov. V prvem sklopu smo razvili novo metodo izdelave lidarskega DMR, v drugem pa smo lidarske vertikalne profile vegetacij uporabili za modelno napovedovanje deležev drevesnih vrst v gozdu in svetlobnih lastnosti gozda. Obstoječi algoritmi za izračun DMR iz lidarskih podatkov imajo v strmem gozdnatem reliefu težave z razlikovanjem talnih odbojev od vegetacije, saj ima v strmem reliefu lokalna okolica v oblaku podobne značilnosti kot vegetacija. V prvem sklopu naloge smo razvili novo metodo izdelave DMR, imenovano REIN, posebej namenjeno uporabi v strmem gozdnatem reliefu: Metoda za zmanjšanje napak izkorišča preobilje lidarskih odbojev (redundanco) in ne spada v nobeno od skupin znanih algoritmov, saj uporablja naključno vzorčenje oblaka lidarskih odbojev. REIN ima večjo zmožnost prilagajanja raznolikim razmeram v strmem gozdnatem terenu. Ker ima vsak del analiziranega območja enako možnost biti izbran v vzorec, je izračunan DMR homogen tudi pri nehomogenih vhodnih podatkih. REIN rešuje tudi problem negativnih osamelcev, ki so rezultat mnogokratnih odbojev. V drugem sklopu naloge smo lidarske vertikalne profile vegetacije, izračunane iz podatkov diskretnega lidarja majhnega odtisa, uporabili za modelno napovedovanje deležev drevesnih vrst v gozdu in svetlobnih lastnosti gozda. Za gradnjo modelov smo uporabili ansambelske metode strojnega učenja ter različne kombinacije pojasnjevalnih spremenljivk, izpeljanih iz diskretnih lidarskih podatkov in iz infrardečih aeroposnetkov. Za osem najbolje napovedanih ciljnih spremenljivk modelne korelacije znašajo od 0,76 do 0,83. Razmeroma nizke vrednosti pripisujemo raznolikosti gozda v testnem območju, napakam v učnem vzorcu in nenatančnemu pozicioniranju vzorčnih ploskev (nenatančen GPS v gozdu), zaradi česar je lahko prišlo do zamika terenskih glede na daljinsko zaznane podatke. Pri ciljnih spremenljivkah, ki se nanašajo na drevesno sestavo, k točnosti napovedi največ prispevajo infrardeče pojasnjevalne spremenljivke, lidarski podatki pa so boljši pri pojasnjevanju svetlobnih značilnosti gozda, ki so tesno povezane s prostorsko razporeditvijo biomase. Strojno naučeni ansambelski modeli so točnejši in robustnejši od lineranih regresijskih modelov, večciljni modeli pa so primernejši od modelov z eno ciljno spremenljivko, saj je skupen čas za pripravo enega modela krajši od časa za pripravo mnogih enociljnih modelov, pa tudi lažje jih je implementirati. Gozdni prostor smo razčlenili na gozdne sestoje s slikovno segmentacijo na podlagi modelnih rastrskih kart.

BIBLIOGRAPHIC-DOCUMENTALISTIC INFORMATION AND ABSTRACT

UDC: **528.7/.8:630*5:(043.3)**
Author: **Andrej Kobler**
Supervisor: **Ass. Prof. Krištof Oštir**
Co- supervisor: **Prof. Dr. Sašo Džeroski**
Title: **New Methods of Processing Aerial Laser Scanner Data for Forest Ecosystem Monitoring**
Notes: **126 pages, 15 tables, 25 figures, 10 appendices**
Key words: **lidar, forest, DTM, machine learning, model**

Abstract:
The thesis is composed of two parts. In the first part we developed a new method for lidar DTM generation. In the second part we used vertical lidar profiles for model-based prediction of the percentages of individual tree species in the forest and to predict different light properties of the forest In steep forested relief, the existing algorithms for computing DTM from the lidar data have problems to distinguish between the ground returns and the vegetation returns, because on the steep slopes the local cloud neighborhood has properties similar to the vegetation. In the first part of the thesis we introduced a new method of DTM computation from the lidar data, called REIN, which is especially adapted to the steep forested topography. The method makes use of the lidar point redundancy to mitigate errors. It does not belong into any of the known algorithm groups, because it randomly samples the point cloud. REIN has a greater ability to adapt to variations in the terrain and forest cover. Because of ensuring that each part of the area of interest gets equal probability of being sampled, REIN results in a homogeneous DTM even under non-homogeneous data input conditions. REIN also takes care of the problem of negative outliers due to multi-path reflections. In the second part of the thesis we used vertical vegetation profiles, computed from the small-footprint discrete lidar data, to predict the percentages of individual tree species in the forest and to predict different light properties of the forest. The ensemble methods of machine learning were used together with different combinations of the explanatory variables, derived both from the discrete lidar data and from the aerial infra-red imagery. The correlations for the eight best modeled target variables are between 0,76 and 0,83. Relatively modest correlations are attributed to the heterogeneity of forests in the test area, to the errors in the training set, and to the imprecise positioning of the field plots (due to GPS errors under the forest canopy), resulting in a possible spatial shift between the field data and lidar data. Infrared explanatory variables contribute the most to the predictions of target variables referring to the tree composition. Lidar data are better suited to explain the forest light properties, which in turn are linked to the spatial distribution of the above-ground forest biomass. The machine-learned ensemble models are more accurate and more robust than the linear regression models. The multi-target models are more suitable than the single-target ensemble models, because the total time to set up a multi-target model is shorter than the time needed to set up multiple single-target models. The multi-target models are also easier to implement. The forest has been delimited into the forest stands by image segmentation based on the model-based raster maps.

ZAHVALA

Za pomoč pri nastajanju naloge se iskreno zahvaljujem mentorju doc. dr. Krištofu Oštirju in somentorju prof. dr. Sašu Džeroskemu. Hvala tudi Gozdarskemu inštitutu Slovenije za financiranje naloge, ki je deloma potekala v okviru naslednjih raziskovalnih projektov: Obdelava lidarskih podatkov (L2-6575) in Napovedovalni GIS model požarne ogroženosti naravnega okolja (M1-0032). Poleg tega se za pomoč v raznih fazah dela zahvaljujem prof. dr. Norbertu Pfeiferju za kritičen in temeljit pregled rezultatov REIN, za pomoč pri pregledu stanja na področju lidarskega DMR ter za izračun DMR testnega območja Litija po standardni morfološki metodi, Petru Ogrincu za vključitev metode Triangle v pythonsko kodo ter za številne koristne nasvete pri programiranju, dr. Ljupču Todorovskemu za pomoč pri programiranju, pri zapisu pseudokode algoritma in določanju njegove časovne kompleksnosti, Robertu Krajncu in Špeli Jagodic za požrtvovalno terensko zbiranje podatkov za učni vzorec, dr. Matjažu Čatru za razlago in izračun svetlobnih značilnosti gozda iz hemisfernih fotografij, dr. Poloni Kalan Carson za navdihujoč pogovor o filtriranju, dr. Ladu Kutnarju za nasvete glede združevanja drevesnih vrst v skupine ter Alenki Kobler za jezikovni pregled naloge. Ministrsvu za obrambo ter javnemu podjetju ELES Elektro-Slovenija se zahvaljujem za dovoljenje za brezplačno uporabo njunih lidarskih podatkov. Firmi Definiens se zahvaljujem za brezplačno licenco orodja eCognition. Slednjič in ne navsezadnje se zahvaljujem Jasni in Ani za potrpežljivost in moralno podporo.

KAZALO

ERRATA II
IZJAVA O AVTORSTVU III
BIBLIOGRAFSKO-DOKUMENTACIJSKA STRAN IN IZVLEČEK IV
BIBLIOGRAPHIC-DOCUMENTALISTIC INFORMATION AND ABSTRACT V
ZAHVALA VI
KAZALO VII
KAZALO PREGLEDNIC IX
LIST OF TABLES X
KAZALO SLIK XI
LIST OF FIGURES XIV
SEZNAM PRILOG XVII
LIST OF APPENDICES XVIII
1 Uvod 1
1.1 Motivacija in cilji naloge 1
1.2 Lasersko skeniranje 2
1.3 Kratek pregled stanja uporabe lidarja v gozdu 4
1.4 Prispevek k znanosti 7
1.5 Organizacija naloge 7
2 Testna območja 9
2.1 Testno območje Litija 9
2.2 Testno območje Kras 11
2.3 Testno območje Slivnica 12
3 Izdelava lidarskega digitalnega modela reliefa 15
3.1 Pregled stanja in opredelitev problema 15
3.2 Algoritem REIN za izračun digitalnega modela reliefa 18
3.2.1 Vpliv gostote lidarskega oblaka na točnost digitalnega modela reliefa 24
3.3 Rezultati 25
3.3.1 Izbira parametrov delovanja REIN in vizualna analiza 25
3.3.2 Primerjava z morfološkim filtriranjem 28
3.3.3 Ocena REIN glede na terensko izmerjene talne točke 29
3.3.4 Vpliv gostote lidarskega oblaka na točnost digitalnega modela reliefa po metodi REIN 30
3.4 Razprava in ugotovitve 33
4 Modelno napovedovanje sestojne temeljnice, drevesne sestave gozda in svetlobnih razmer v gozdu iz lidarskih podatkov in letalskih fotografij 35
4.1 Pregled stanja in opredelitev problema 35
4.1.1 Drevesne vrste 37
4.1.2 Sestojna temeljnica 38
4.1.3 Svetlobne razmere 38
4.1.4 Vertikalni profil vegetacije 39
4.1.5 Souporaba lidarja in drugih daljinsko zaznanih podatkov 40
4.1.6 Strojno učenje 41
4.1.7 Opredelitev problema 43
4.2 Metoda 43
4.2.1 Ciljne spremenljivke 44
4.2.1.1 Definicije in postopek terenskega dela 44
4.2.1.2 Razpored vzorčnih ploskev 47

4.2.2 Pojasnjevalne spremenljivke ... 49
4.2.2.1 Vertikalni profili ... 49
4.2.2.2 Teksture profilov ... 51
4.2.2.3 Aeroposnetki ... 52
4.2.3 Modelno napovedovanje značilnosti gozda ... 53
4.2.4 Kartiranje rezultatov ... 55
4.3 Rezultati ... 60
4.4 Ugotovitve ... 73
5 Razprava in zaključek ... 75
6 Povzetek ... 83
7 Summary ... 87
8 Viri ... 91
9 Priloge ... 103

KAZALO PREGLEDNIC

Preglednica 1: Tipične vrednosti parametrov diskretnega lidarja za snemanja gozda (povzeto po Evans in sod. 2009). 4

Preglednica 2: Pseudo koda algoritma REIN. 22

Preglednica 3: Gostote lidarskih točk, dobljene z redčenjem osnovnega oblaka. Začetno gostoto podaja prvi stolpec (faktor redčenja = 1). Skupne gostote, ki so bile uporabljene za izračun DMR (zadnji + edini odboji) so podane v spodnji vrstici. 24

Preglednica 4: Vrednosti RMSE v metrih za morfološko filtriranje. Vrednosti za REIN (pri samplesize = 10000 in numsamples = 4) so podane za primerjavo. Število talnih točk pri REIN ustreza številu pri začetnem filtriranju oblaka. 29

Preglednica 5: Statistika razlik DMR1 – DMRx (x je faktor redčenja) na Slika 9. 31

Preglednica 6: Pregled drevesnih vrst v terenskem vzorcu za kontrolo višin. 57

Preglednica 7: Ciljne spremenljivke, rangirane po doseženem modelnem koeficientu korelacije. Debelo uokvirjene so tiste, katerih korelacija presega 0,7 in le te so upoštevane v nadaljnjih presojah. Legenda spremenljivk je v Prilogi A. 63

Preglednica 8: Povprečne korelacije vseh modelov za posamezni par ciljne spremenljivke in skupine pojasnjevalnih spremenljivk..... 64

Preglednica 9: Razvrstitev najuspešnejših 40 (od 217) pojasnjevalnih spremenljivk po povprečnih rangih doseženih preko vseh ciljnih spremenljivk posamezne skupine in združeno za vse 3 polmere veljavnosti. Majhna vrednost povprečnega ranga pomeni, da pojasnjevalna spremenljivka dobro pojasnjuje ciljno spremenljivko. Legenda spremenljivk je v Prilogi A. 66

Preglednica 10: Rang lestvice skupin pojasnjevalnih spremenljivk glede na skupino ciljnih spremenljivk. 67

Preglednica 12: Povprečna korelacija vseh modelov za posamezen par tip modela / ciljna spremenljivka. Stolpec Splošno podaja aritmetično sredino vseh vrednosti levo od sebe..... 68

Preglednica 13: Maksimalna dosežena korelacija za par tip modela / skupina pojasnjevalnih spremenljivk, prikazano posebej za vsako ciljno spremenljivko. 69

Preglednica 14: Povprečne korelacije za pare polmer veljavnosti / ciljna spremenljivka. Stolpec Splošno podaja aritmetično sredino vseh vrednosti levo od sebe. 69

Preglednica 15: Povprečne korelacije za pare zorni kot hemisferne fotografije / ciljna spremenljivka. Stolpec Splošno podaja aritmetično sredino vseh vrednosti levo od sebe..... 70

Preglednica 16: Lidarsko podcenjevanje višin, ocenjeno na vzorcu 257 dreves. Napaka lidarske višine posameznega drevesa je bila izračunana kot $H_{dejanska} - H_{lidar}$..... 70

LIST OF TABLES

Table 1: Typical values of discrete lidar parameters for acquisition of forests (summarized from Evans et al. 2009).....4

Table 2: Pseudo-code of the REIN algorithm. 22

Table 3: Lidar point densities obtained by thinning the basic dataset. The starting point density is given in the first column (thinning factor = 1). Total point densities used to calculate DEMs (last returns + only returns) are given in the bottom line.....24

Table 4: RMSE values for the filtering with the morphological filtering. The values for REIN (at samplesize = 10000 and numsamples = 4) are shown for comparison. The number of ground points for REIN corresponds to the initially filtered point cloud.....29

Table 5: The statistics for the difference images DEM1 – DEMx (x is the thinning factor) shown in Figure 9 31

Table 6: Overview of represented tree species in the field sample for height control. 57

Table 7: Target variables, ranked according to achieved model correlation. Bold framed are the ones with correlation coefficient exceeding 0,7 and only those are taken into account in further judgments. Legend of the variables is given in Appendix A.....63

Table 8: Average correlatiosn of all models for a pair target variable / group of explanatory variables.....64

Table 9: Ranking of the best 40 (out of 217) explanatory variables according to the average ranks, achieved over all target variables of a group, irrespective of radius of validity. Small value of the average rank indicate that the explanatory variable is a good predictor of the target variable. Legend of the variables is given in Appendix A. 66

Table 10: Ranks of explanatory variable groups according to the target variable group.....67

Table 11: Average correlation of all models for each pair model type / target variable. The right-most column gives the arithmetic mean of all the values to the left. 68

Table 12: Maximum obtained correlation for each pair model type / group of explanatory variables, shown individualy for each target variable. 69

Table 13: Average correlations for pairs validity radius / target variable. The right-most column gives the arithmetic mean of all the values to the left. 69

Table 14: Average correlations for pairs viewing angle of hemspherical photography / target variable. The right-most column gives the arithmetic mean of all the values to the left. 70

Table 15: Lidar underestimation of tree heights, estimated with a sample of 257 trees. Lidar height errors are comuted as H_{actual} - H_{lidar}. 70

KAZALO SLIK

Slika 1: (a) prikazuje digitalni model površin, (b) pa letalsko ortofotografijo širše okolice testnega območja Litija. Območje je prekrito z mešanim gozdom na strmih pobočjih. Izrez na (a) spodaj levo prikazuje celotno skenirano območje. Manjša pravokotnika na (a) in (b) označujeta lego testnega območja. (c) prikazuje testno območje, kjer potekajo trije transekti v smeri S-J z vizuelno prepoznanimi talnimi točkami ter raztresene točke, izmerjene s totalno postajo. 10

Slika 2: Testno območje Kras, ki meri 400 m (V-Z) krat 250 m (S-J) je prikazano na (a) aeroposnetku, (b) senčenem digitalnem modelu površin, (c) senčenem digitalnem modelu reliefa golih tal in (d) na digitalnem modelu krošenj. Karte na (b), (c) in (d) so bile izračunane z največjo razpoložljivo gostoto podatkov. Beli pravokotnik na označuje področje, ki je podrobno prikazano na Slika 10. 12

Slika 3: Gozdnogospodarski enoti Menišija in Slivnica skupaj predstavljata testno območje Slivnica, veliko 8618 ha. 13

Slika 4: Skupna gostota prvih in edinih odbojev, ki so bili osnova za izračun lidarskih pojasnjevalnih spremenljivk za modelno napovedovanje lastnosti gozda v testnem območju Slivnica. 14

Slika 5: Filtriranje lidarskih podatkov z namenom zaznavanja tal (Kobler in sod. 2007). (a) Strukturni element kaže dovoljeno višinsko razliko glede na oddaljenost (enote so metri). (b) Oblak točk je prikazan v stranskem pogledu skupaj s tlemi, streho in vegetacijskimi točkami, okna so postavljena na dveh specifičnih točkah (črne pike). Pri desnem primeru sta dve točki (kroga) prepoznani kot ne-talni točki. (c) Trikotnik prej prepoznanih talnih točk (B1, B2, B3) s koti ($\alpha 1$, $\alpha 2$, $\alpha 3$) odloča o tem, ali bo točka P uvrščena med talne točke. (d) Zgornja črta prikazuje prvi približni model površine, ki ga izračunamo iz celotne množice točk (stranski pogled), spodnja črta pa prikazuje DMR v naslednji iteraciji. (e) Prikazana je utežna funkcija, ki jo računamo iz ostankov oziroma razdalj točk do površine. (f) Prikazana je segmentacija lidarskega oblaka točk v 3D pogledu, različni segmenti so v različnih tonih sivine. 17

Slika 6: Prikaz algoritma REIN, ki ga uporabimo v končni stopnji filtriranja. (a) Rezultat začetnega filtriranja (z uporabo, na primer, morfološkega filtra) so talne točke s posameznimi preostalimi nefiltriranimi vegetacijskimi točkami in brez negativnih osamelcev. Opozarjamo na preobilje talnih točk znotraj pasu napak. Raztros točk znotraj pasu napak je posledica meritvenih napak, trave in nizkih zelišč. (b) Ponavljajoča se naključna vzorčenja lidarskih točk uporabimo za gradnjo trikotniških modelov TIN, iz katerih na lokacijah mreže DMR interpoliramo množice ocen nadmorske višine. Opozarjamo tudi na možnost, da preostale nefiltrirane vegetacijske točke lahko postanejo vozlišča TIN. (c) Nadmorske višine DMR aproksimiramo tako, da globalni srednji zamik prištejemo k spodnjim mejam porazdelitev nadmorskih višin. Spodnje meje porazdelitev so neodvisne od preostalih nefiltriranih vegetacijskih točk. 21

Slika 7: Primerjava senčenih reliefov začetno filtriranega osnovnega DMR (a), morfološko filtriranega DMR (b in c) ter rezultatov REIN filtriranja (d-h). Vsi DMR imajo horizontalno ločljivost 1 m. Opozarjamo na učinke ekstremnih vrednosti parametrov REIN: majhna vrednost numsamples povzroči generalizacijo reliefa (d, e), majhna vrednost samplesize pa vnese artefakte zaradi preostale nefiltrirane vegetacije (d, f). Velike vrednosti numsamples in samplesize povzročijo najmanj artefaktov (g), vendar pa visoka vrednost numsamples z zmerno vrednostjo samplesize (h) omogoči rahlo boljšo RMSE in skrajša čas računanja. 26

Slika 8: (a) Vpliv parametrov REIN numsamples in samplesize na kakovost DMR, ocenjeno z RMSE. Povprečno RMSE smo izračunali iz 50 ponovitev REIN za vsako kombinacijo vrednosti parametrov. (b) Stabilnost rezultatov REIN, ocenjeno s standardnim odklonom RMSE iz 50 ponovitev REIN za vsako kombinacijo vrednosti parametrov. 28

Slika 9: Razlike nadmorskih višin zaradi redčenja podatkov: (a) DMR1 – DMR2, (b) DMR1 – DMR4, (c) DMR1 – DMR8. Razlike so največje na ostrih lomnih črtah in pri izraženem mikroreliefu (na primer nizki kraški zidovi, skalni izdanki, terase). 31

Slika 10: Žični prikaz DMR, izsek na Slika 2c, pogled iz zahoda. (a) DMR1, (b) DMR2, (c) DMR4, (e) DMR8. Mere izseka so 80 m krat 60 m. Raster vseh mrež je 1 m. 32

Slika 11: Primer razporeditve ploskev znotraj traktov. Pika označuje z diferencialnim GPS izmerjeno lokacijo središča trakta, križec pa s polarnimi koordinatami določeno lokacijo podrejene ploskve. Dejanske lokacije ploskev odstopajo od teoretičnih (10 m od središča trakta na V, Z, S, J) zaradi prilagajanja lokalnim razmeram. 45

Slika 12: Štetje dreves za ugotavljanje sestojne temeljnice po Bitterlichovi kotnoštevni metodi. Drevo na levi sliki štejemo, drevo na desni pa ne. Vir: http://en.wikipedia.org/wiki/Wedge_prism. 46

Slika 13: Oprema za hemisferno fotografiranje svetlobnih razmer v sestoju. Vir: Matjaž Čater. 46

Slika 14: Izrez raziskovalnega območja z 200-metrskimi pasovi (100 m do 300 m od cest, pasovi označeni z rdečo), znotraj katerih smo naključno določali lokacije raziskovalnih traktov. 48

Slika 15: Naključna porazdelitev traktov (črne pike) v testnem območju Slivnica znotraj gozdnega prostora (zelena barva) in znotraj pasu od 100 do 300 m od cest. 49

Slika 16: Primerjava surovih in korigiranih profilov za tri tipične sestoje (iglavci-mladovje, listavci-debeljak, iglavci-debeljak). 50

Slika 17: Porazdelitve vrednosti profilov na 950 vzorčnih ploskvah v odvisnosti od načina postavljanja meja med razredi: (a) porazdelitev v 20 razredov glede na ekvidistantno postavitev mej, (b) porazdelitev v 8 razredov glede na logaritemsko postavitev mej, (c) porazdelitev v 4 razrede glede na logaritemsko postavitev mej. 52

Slika 18: Iskanje vrhov dreves na DMK po metodi lokalnih maksimumov. Prozorni kvadratki prikazujejo kandidatne piksle pri polmeru iskanja 5 m, rdeče pike pa prepoznane vrhove dreves, ki jih izračunamo kot težišča kandidatnih pikslov. Kandidatne piksle, ki pripadajo istemu drevesu, prepoznamo po tem, da so neposredni sosedje. 58

Slika 19: Vpliv polmera iskanja na iskanje vrhov lokalnih maksimumov: (a) 2 m, (b) 5 m, (c) 10 m. 59

Slika 20: Vpliv števila podmodelov na točnost ansambelskega STRF modela za delbukev, upoštevajoč vse razpoložjive pojasnjevalne spremenljivke. Prikazani so vplivi pri vseh treh polmerih veljavnosti pojasnjevalnih spremenljivk 5 m, 10 m in 20 m. 61

Slika 21: Primerjava deležev terensko ocenjenih neničelnih deležev drevesnih vrst v učnem vzorcu s korelacijami najboljšega modela za ciljno spremenljivko. 64

Slika 22: Porazdelitev frekvenc višin vegetacije na DMK. 67

Slika 23: Raztros terenskih odčitkov višine dreves glede na pravo (povprečno) višino drevesa. 70

Slika 24: Lidarska napaka višine drevesa. 71

Slika 25: Lidarska razmejitev na sestoje (modra črta) in razmejitev Zavoda za gozdove (črna črta). V ozadju je kompozitna slika DOF in DMK. Izsek prikazuje območje vrha Slivnice ter njeno severno in južno pobočje. Legenda prikazuje višine vegetacije. Sever je na levo. 72

LIST OF FIGURES

Figure 1: In (a) and (b) the Litija test site and its surroundings is shown as a digital surface model and in an aerial orthophoto, respectively. The area is covered with mixed forest on steep terrain. The inset in lower left of (a) presents the DSM of the entire scanned area. The embedded rectangles in (a) and (b) represent the location of the Litija test area. In (c) the filtered DEM of the test area is shown (white rectangle), where the three North-South transects contain the visually identified ground points and the scattered points, that were measured by a total station. 10

Figure 2: The Kras test area measuring 400 m (E-W) by 250 m (N-S) is shown (a) on an aerial orthophoto, (b) on a shaded forest surface model, (c) on a shaded DEM of the bare ground, and (d) nDSM. The maps shown in (b), (c), and (d) were computed using the highest available point densities. The white rectangle in (c) denotes the detail rendered as wireframe model in Figure 10. 12

Figure 3: Forest management units Menišija and Slivnica together represent the Slivnica test area, encompassing an area of 8618 ha. 13

Figure 4: Total density of the first and only returns, which were used to compute lidar-based explanatory variables for the model-based predictions of forest parameters in the Slivnica test area. 14

Figure 5: Filtering of ALS data for ground detection (Kobler et al. 2007). In (a) the structure element shows the admissible height differences based on distance (units are meters). In (b) a point cloud is shown in a profile with ground, a roof and vegetation points, where at two specific points (black dots) windows are centered. In the right case two points (bold circles) are identified as not-ground points. In (c) a triangle of previously identified ground points (B1, B2, B3) is shown and measures (α1, α2, α3) to determine, if the investigated point (P) shall be classified as ground point. In (d) a first, rough surface model is shown as the upper line computed from the entire point set (profile view) and the lower line shows the DTM in the next iteration. In (e) a weight function is plotted which takes as input the residuals, i.e., the signed distance of the points to the surface. In (f) the segmentation of an ALS pointset is shown in a 3D view with different grey tones for different segments. 17

Figure 6: Illustration of the REIN algorithm used in the final stage of the filtering. (a) The result of the initial filtering stage (using, e.g., a slope threshold filter) are ground points with few remaining unfiltered vegetation points and no negative outliers. Note the redundancy of ground points within the error band. The scattering within the error band is caused by measurement errors, grass and low herbal vegetation. (b) Repeated random selections of lidar points are used to build a set of TINs, out of which sets of elevation estimates are interpolated at the locations of DTM grid points. Note that also the remaining unfiltered vegetation points may become TIN nodes. (c) DTM elevations are approximated by adding global mean offset to the lower bounds of elevation distributions, which are unaffected by the unfiltered vegetation points. 21

Figure 7: Comparison of the shaded relief images of the slope filtered baseline DEM (a), morphologicaly filtered DEM (b and c), and results of REIN filtering (d-h). All DEMs have 1 m by 1 m horizontal resolution. Note the effects of extreme values of REIN parameters: low numsamples values cause relief generalization (d, e) and low samplesize values cause artefacts due to remaining unfiltered vegetation (d, f). High numsamples and high samplesize

values yield fewest artefacts (g), however high numsamples with moderate samplesize (h) yields marginally better RMSE and saves computation time. 26

Figure 8: (a) Influence of the REIN parameters numsamples and samplesize on the quality of the DTM according to the average RMSE. The average RMSE was obtained by averaging RMSE values of 50 runs of REIN for each parameter combination. (b) Stability of REIN results as indicated by the standard deviation of RMSE based on 50 runs of REIN for each parameter combination. 28

Figure 9: The elevation difference images due to data thinning: (a) DEM1 – DEM2, (b) DEM1 – DEM4, (c) DEM1 – DEM8. The differences are the greatest at sharp break-lines and at locations of pronounced micro-relief, e.g., low manmade walls, rock outcrops, or terraces. 31

Figure 10: The wireframe DEM rendering of the DEM subset indicated in Figure 2, as seen from the west. (a) DEM1, (b) DEM2, (c) DEM4, (d) DEM8. The subset area is 80 m by 60 m. All wireframes are shown using 1 m raster. 32

Figure 11: An example of plot layout within tract. Dots indicate differential GPS-located tract center , crosses indicate corresponding plots, located with relative polr coordinates. Due to adaptation to local circumstances the true plot locations differ from theoretical ones (10 m from tract center in 4 cardinal directions). 45

Figure 12: Tree counting for estimation of basal area according to the Bitterlich method. The tree on the left is counted, while the tree on the right is not. Source: http://en.wikipedia.org/wiki/Wedge_prism. 46

Figure 13: Equipment for estimation of forest stand light parameters by hemisferical photography. Source: Matjaž Čater. 46

Figure 14: Subset of the test area showing 200 m buffers (100-300 m to roads, indicated by red), containing random locations of research tracts. 48

Figure 15: Random distribution of tracts (black dots) in the Slivnica test area are located within forests (green) and within 100-300 m road buffers. 49

Figure 16: Comparrison of raw and corrected profiles for three typical forest stands (young coniferous, mature deciduous, mature coniferous). 50

Figure 17: Distribution of profile values at 950 sample plots, in relation to class breaks: (a) distribution into 20 classes according to equidistant class intervals, (b) 8 classes with logarithmic class breaks, (c) 4 classes with logarithmic class breaks. 52

Figure 18: Searching for tree tops on the digital canopy model according to the local maximum method. The transparent squares indicate candidate pixels at a 5 m search radius, the red dots indicate the identified tree tops, computed as the centers of gravity of the corresponding candidate pixels. The candidate pixels, belonging to the same tree are identified by being immediate neighbours. 58

Figure 19: Influence of search radius on finding the local maxima: (a) 2 m, (b) 5 m, (c) 10 m. 59

Figure 20: Influence of the number of sub-models on the accuracy of the ensemble STRF model for delbukev (percentage of beech), taking into account all available explanatory variables. Influences are shown separately for all three validity radii of explanatory variables 5 m, 10 m in 20 m. 61

Figure 21: Comparrison of percentages of estimated non-zero percentages of tree species in the training sample vs. correlation coefficients of the best model per target variable. 64

Figure 22: Frequency distribution of vegetation heights in the digital canopy model. 67

Figure 23: Scattering of height readouts in the field vs. the true (average) tree height. 70

Figure 24: Lidar tree height error. 71

Figure 25: Lidar-based delimitation of forest stands (blue line) ina the Forestry service delimitation (black line). In the background there is a composite BW aerial image colour coded with digital canopy model. The subset shows the Mt. Slivnica summit with northern and southern flanks. The legend shows vegetation heights. North is towards left. 72

SEZNAM PRILOG

Priloga A: Seznam ciljnih in pojasnjevalnih spremenljivk

Priloga B: Način izračuna teksturnih indeksov po Haralicku (1979)

Priloga C: Korelacije ciljnih spremenljivk z modelnimi vrednostmi

Priloga D: Modelne rastrske karte testnega območja Slivnica

Priloga E: Digitalni model krošenj testnega območja Slivnica

Priloga F: Korelacijske tabele ciljnih in pojasnjevalnih spremenljivk

Priloga G: Korelacijske tabele pojasnjevalnih spremenljivk

Priloga H: Korelacijske tabele ciljnih spremenljivk

Priloga I: Najboljši (minimalni) rangi posamezne pojasnjevalne spremenljivke glede na skupino ciljnih spremenljivk in glede na polmer veljavnosti pojasnjevalne spremenljivke

Priloga J: Povprečni rangi posamezne pojasnjevalne spremenljivke glede na skupino ciljnih spremenljivk in glede na polmer veljavnosti pojasnjevalne spremenljivke

LIST OF APPENDICES

Appendix A: List of the target and explanatory variables

Appendix B: Texture indices computation method (Haralicku 1979)

Appendix C: Correlations of the target variables and the modeled values

Appendix D: Model-based raster maps of the Slivnica test area

Appendix E: Digital canopy model of the Slivnica test area

Appendix F: Correlation tables of the target and explanatory variables

Appendix G: Correlation tables of the explanatory variables

Appendix H: Correlation tables of the target variables

Appendix I: Best (i.e., minimal) ranks of individual explanatory variables relative to groups of target variables and relative to the radius of validity of the explanatory variable

Appendix J: Average ranks of individual explanatory variables relative to groups of target variables and relative to the radius of validity of the explanatory variable

1 Uvod

1.1 Motivacija in cilji naloge

Gozd za Slovenijo predstavlja pomemben obnovljivi naravni vir. Naša država je s 60-odstotno pokritostjo z gozdom na tretjem mestu po gozdnatosti v Evropi. Gozd nima le ekonomskega pomena, ampak je tudi pomemben dejavnik pri snovnih in energetskih tokovih v naravnem okolju. V obdobju od leta 1990 do leta 2005 je gozd akumuliral 60 odstotkov letnih slovenskih emisij CO_2, zato ima bistveno vlogo pri izpolnjevanju obveznosti zmanjševanja emisij toplogrednih plinov po Kjotskem protokolu. V prihodnosti se bodo potrebe po proizvodnih, predvsem pa po neproizvodnih gozdnih funkcijah povečevale. Zaradi učinkov klimatskih sprememb, ki se bodo kazali kot prenamnožitev gozdnih škodljivcev, kot širjenje novih bolezni gozdnega drevja ali kot močnejše vremenske ujme (Ayres in Lombardero 2000, Kajfež-Bogataj 2003, Cegnar 2003, Jurc 2003, Jurc in Ogris 2005), pa se bo zmanjšala sposobnost gozda da zadovoljuje te funkcije. Pri upravljanju gozdnih ekosistemov v tako zahtevnih okoliščinah bodo zato med drugim potrebna orodja, ki bodo omogočila čim točnejšo in čim popolnejšo oceno stanja in trendov razvoja gozda.

Uveljavljene metode terestrične inventure gozdov so drage in zamudne (Kozorog 2003), zato se inventure opravljajo v daljših časovnih razmakih. V Sloveniji, ki ima 14 gozdnogospodarskih območij, ki se naprej delijo na gozdnogospodarske enote, se inventura gozdov v posamezni gozdnogospodarski enoti ponovi vsakih 10 let. Pri tem izmed metod daljinskega zaznavanja uporabljajo kartiranje gozdnih sestojev (razmejevanje in klasifikacija sestojev) s fotointerpretacijo letalskih posnetkov gozda (MKGP 1998).

V sedemdesetih letih prejšnjega stoletja je bil za vojaške namene in za topografska merjenja razvit lidar (angleška kratica za LIght Detection And Ranging). Sredi devetdesetih let so se začeli poskusi uporabe lidarja za pridobivanje informacij o gozdu. Lidar je aktiven senzor, ki nudi podrobne informacije o notranji zgradbi gozdnega sestoja in o reliefu pod gozdom, ki jih je zelo težko dobiti s pasivnimi optičnimi ali radarskimi tehnikami daljinskega zaznavanja. Neposredno ali z modeli so iz lidarskih podatkov že ocenjevali številne parametre gozdnih sestojev. Pregled metod v poglavju 4.1 nakazuje, da je lidar primerno orodje za monitoring gozdnih ekosistemov. Vendar je opaziti, da se objavljene metode v glavnem osredotočajo na umirjen relief in na borealni gozd, ki sta s stališča daljinskega zaznavanja, še posebej pa iz stališča lidarskega snemanja, bistveno enostavnejši problem, kot pa strma pobočja, pokrita z raznolikim listnatim in mešanim gozdom, kakršen prevladuje v Sloveniji. Eden od potrebnih pogojev za postopno uveljavitev lidarja pri monitoringu gozdnih ekosistemov v Sloveniji je torej testiranje in prilagoditev posameznih že uveljavljenih metod interpretacije lidarskih podatkov v primerljivih razmerah.

Čeprav so danes cene lidarskih podatkov še previsoke za intenzivno velikoprostorsko uporabo v gozdarstvu, pa v zadnjih letih beležimo dramatični napredek lidarske tehnologije, predvsem glede večanja frekvence laserskih pulzov, boljše pozicijske točnosti lidarskih odbojev ter zmožnosti snemanja iz večjih višin in s tem širjenja snemalnih pasov. Vse to pri enakem času leta (kar je ključni element končne cene podatkov) pomeni večjo posneto površino, višjo gostoto snemanja ter večjo točnost podatkov. To pa pomeni vse nižje stroške lidarskih podatkov na enoto površine, zaradi česar se lidar v svetu vse hitreje seli v operativno

gozdarsko uporabo. Pričakujemo lahko, da bo v nekaj letih tudi v slovenskem gozdarstvu postal rutinsko orodje, kot so na primer pred desetletjem to postali letalski ortoposnetki.

Splošni cilj te raziskave je predlagati in na praktičnem primeru preizkusiti nekatere novosti pri metodah interpretacije lidarskih podatkov, ki naj bi olajšale uporabo lidarskega letalskega snemanja za informacijsko podporo intenzivnemu malopovršinskemu in sonaravnemu načinu gospodarjenja z gozdnimi ekosistemi v Sloveniji. Da bi to dosegli, smo si zastavili dva med seboj povezana posamična cilja, ki sta obdelana vsak v svojem sklopu:

1. razviti in preizkusiti novo metodo filtriranja talnih lidarskih odbojev iz celotnega oblaka točk in izdelave rastrskega digitalnega modela reliefa (DMR), ki bo prispevala k rešitvi problema izdelave lidarskega DMR na strmem gozdnatem reliefu. Uresničitev tega cilja je v goratih predelih Slovenije predpogoj za zanesljivejše ugotavljanje relativne višine nad tlemi za vse zabeležene lidarske odboje in s tem za točnejše lidarsko ocenjevanje lastnosti gozda. Ta sklop naloge je predstavljen v poglavju 3;
2. primerjalno testirati različne metode modelnega napovedovanja parametrov gozda (kot so sestojna temeljnica, drevesna sestava gozda ter svetlobne razmere v gozdu) iz lidarsko zaznanih vertikalnih profilov vegetacije in iz hkrati posnetih letalskih ortofotografij ter nazadnje uporabiti te podatke za razmejevanje in povzemanje lastnosti gozdnih sestojev. Ta sklop naloge je predstavljen v poglavju 4.

Ciljema ustrezata hipotezi naloge.

1. Mogoče je razviti metodo, ki z upoštevanjem preobilja lidarskih odbojev (redundance) v oblaku lidarskih točk doseže v strmem gozdnatem reliefu manjše napake digitalnega modela reliefa od doslej znanih metod.
2. Z metodami strojnega učenja je mogoče razviti empirične modele, ki iz lidarsko zaznanih vertikalnih profilov vegetacije in iz infrardečih letalskih ortofotografij omogočajo napovedovanje nekaterih značilnosti gozda.

1.2 Lasersko skeniranje

Letalsko lasersko skeniranje (angl. airborne laser scanning – ALS), imenujemo ga tudi letalski lidar (LIght Detection And Ranging), je ena od številnih laserskih tehnik daljinskega zaznavanja (Measures 1992). Z merjenjem časa povratnega potovanja Δt oddanega laserskega pulza od senzorja do odbojne površine in spet nazaj do senzorja lahko določimo razdaljo d od senzorja do odbojne površine s pomočjo znane hitrosti svetlobe c skozi zrak in obrazca $d = c \Delta t/2$. Za merjenje topografije terena ali strukture gozda iz letala moramo v vsakem trenutku poznati položaj in orientacijo letala v prostoru. Te parametre določamo z globalnim pozicijskim sistemom (Global Positional System – GPS) in enoto za inercialno merjenje (Inertial Measurement Unit – IMU), (Ip in sod. 2004). S periodičnim odklanjanjem smeri laserskega oddajanja prečno na smer leta (s pomočjo nihajočega ali vrtečega se ogledala) ob premikanju letala v smeri leta vzorčimo gost oblak točk odbojev na zemeljskem površju in v strukturi gozdnega rastlinstva. Ta oblak ima obliko snemalnega pasu. Z nizanjem snemalnih pasov lahko z lidarskimi podatki prekrijemo velike površine. Komercialni laserski skenereji lahko delujejo do višine 3 km nad terenom in dosegajo frekvenco 150000 točk na sekundo in več, ob čemer je točnost določanja višin do nekaj cm. Na ta način lahko dosežemo tipične gostote točk (odvisno od hitrosti leta, frekvence snemanja in širine snemalnega pasu) od ene do nekaj deset točk na m^2. Lidarski sistemi za opazovanje gozda delujejo v bližnjem do srednjem IR spektralnem območju, tipično pri 1,064 µm. Pri tej valovni dolžini je prosojnost atmosfere velika in tudi albedo rastlinstva in tal je dovolj visok.

Letalsko lidarsko skeniranje je podobno radarskemu po aktivnem oddajanju signala in sprejemanju odboja od tarče, od radarskega snemanja pa se razlikuje, ker je sled signala na tleh (angl. footprint) mnogo manjša (Bufton 1989). Radarsko merjenje zato ne more zagotoviti tako visoke prostorske ločljivosti kot lidarsko snemanje. Ločljivost lahko sicer povečamo s SAR (Synthetic Aperture Radar), vendar pa ne dosegamo točnosti lidarskega snemanja (Andersen in sod. 2004). Laserski pulz lahko prodre skozi drevesno krošnjo, oziroma prodre skozi majhne vrzeli med listjem in seže tudi do tal. Zato omogoča tudi merjenje topografije pod gozdnim sklepom. Pri pasivnih tehnikah optičnega daljinskega zaznavanja topografije (fotogrametriji) je treba zaznati dovolj močan odboj sončne svetlobe od tal na obeh slikah stereopara, zaradi česar je merjenje topografije oziroma nadmorskih višin tal pod gozdom skoraj nemogoče (Kraus in Pfeifer 1998).

Zaradi takojšnjega tvorjenja 3D-podatkov, prostorske ločljivosti in točnosti postajajo lidarski podatki priljubljen vir za rekonstrukcijo digitalnih modelov reliefa (DMR), (Sithole in Vosselman 2004), in virtualnih modelov mest (Kaartinen in sod. 2005). Ker pa se lidarski signal, ko prodira skozi listje in vejevje gozda, odbija od različnih delov dreves, lidar vse bolj uporabljamo tudi za merjenje značilnosti gozda (Hyyppä in sod. 2004).

Mehanizem odboja svetlobe, ki ga uporabljamo pri laserskem skeniranju, je razpršeni odboj. Laserska svetloba, ki prispe iz ene smeri (od senzorja), se na odbojni površini razprši v vse smeri. Majhen del se je odbije tudi nazaj do senzorja, kjer izmerimo potovalni čas. Ker premer žarka ni neskončno majhen, ampak ima določen odtis (angl. footprint), tipično od pol do enega metra, je več predmetov lahko vir odboja. Sodobni sprejemniki lahko zaznajo več odbojev, na primer prvega, drugega, tretjega in zadnjega. Tovrstne, tako imenovane diskretne sisteme majhnega odtisa (angl. discrete return small footprint systems) je treba razlikovati od sistemov, ki beležijo celotno valovno obliko (angl. full waveform) odbite svetlobe (Wagner in sod. 2006), prav tako pa od sistemov z velikim odtisom, na primer Vegetation Canopy Lidar (VCL; NASA, Blair in sod. 1999) in GLAS (Zwally in sod. 2002). Sicer pa letalske lidarje na splošno lahko razdelimo v tri tipe: profilne, diskretne in valovne. Najprej so bili razviti profilni lidarji, ki so se v gozdarstvu uporabljali za ocenjevanje višin krošenj in lesne zaloge. Profilni lidarji so najenostavnejša oblika teh senzorjev, kjer senzor vzorči višine v ravni črti pod letalom. Z dodatkom skenerja, se je diskretni lidar izboljšal do te mere, da ga sedaj lahko uporabljamo za velikopovršinska merjenja gozdov. Vsak od naštetih tipov lidarjev ima svoje prednosti, tako da je izbira odvisna od nameravane uporabe. Danes je na voljo veliko število diskretnih lidarjev za gozdno inventuro. Največ uporabljajo naprave proizvajalcev Optech (serija ALTM), Leica (serija ALS), RIEGL (serija LMS) in TopoSys (serija Falcon). Letalski diskretni laserski skenerji tipično delujejo v načinu prvi-zadnji odboj ali pa zaznavajo večje število odbojev. Ker je mogoče posnetke lidarja in fotokamere georeferencirati z istimi tehnikami zunanje orientacije, lahko lidarske senzorje zlahka opremimo z dodatnimi kamerami, kar pripomore k lažji interpretaciji lidarskih podatkov (van Leeuwen in sod. 2010). Preglednica 1 je primer tipičnih snemalnih parametrov diskretnega lidarja.

Preglednica 1: Tipične vrednosti parametrov diskretnega lidarja za snemanja gozda (povzeto po Evans in sod. 2009).
Table 1: Typical values of discrete lidar parameters for acquisition of forests (summarized from Evans et al. 2009).

Valovna dolžina	1,064 µm
Frekvenca ponavljanja pulzov	50-150 kHz
Odbojev na pulz	3-4
Divergenca žarka	10-80 mrad
Kot skeniranja	< 15 ° od nadirja
Višina leta	100-3000 m nad terenom
Premer talnega odtisa	10-30 cm
Gostota pulzov	> 4 m^{-2}
Vertikalna točnost	< 15 cm

Na trgu se pojavljajo že tudi valovni lidarji z majhnim odtisom, vendar je valovna tehnologija za zdaj še manj zrela od diskretne za visokoločljive aplikacije, predvsem pa valovni lidar z majhnim odtisom proizvaja enormne količine podatkov (Evans in sod. 2009). Njihova uporaba je zato za zdaj še omejena na znanstvene kroge in še ni prodrla v prakso. Primeri takih skenerjev so SLICER in LVIS, ki ju je razvila NASA (Blair in sod. 1999, Koetz in sod. 2006), ter nedavno tudi komercialni RIEGL LMS-Q560, Optech ALTM 3100 in TopEye MK II (Hug in sod. 2004, Wagner in sod. 2006, Kirchhof in sod. 2008). Za diskretne sisteme z majhnim odtisom (reda velikosti 1 m) je v primerjavi z valovnimi sistemi velikih odtisov (reda velikosti 10 m) sicer res značilno sistematično podcenjevanje višin, vendar pa ponujajo visoko gostoto odbojev in s tem natančnejšo rekonstrukcijo reliefa golih tal in krošenj. Pri praktični gozdarski uporabi je poleg tega ključna sposobnost diskretnega lidarja, da prodre mimo prve odbojne površine v globino sestoja, celo do tal.

V tej nalogi se bomo ukvarjali tako z lidarskim zaznavanjem tal kot tudi zaznavanjem posameznih značilnosti gozdnih sestojev z letalskim diskretnim lidarjem majhnega odtisa. Vse ugotovitve v nadaljevanju bomo podajali le še v kontekstu takega senzorja, ne da bi to nujno posebej poudarjali.

1.3 Kratek pregled stanja uporabe lidarja v gozdu

Izdelava digitalnih modelov reliefa (DMR) je najhitreje rastoče polje uporabe lidarja, še posebej v gozdnatih območjih, kjer fotogrametrične tehnike niti zdaleč ne dosegajo točnosti lidarja (Haugerud in Harding 2001, Wulder 2003). Kvaliteten DMR je predpogoj za nepopačene ocene relativnih višin posameznih lidarskih točk nad tlemi in s tem za analizo notranje strukture gozda. Predpostavka, da najnižji odboji predstavljajo tla, lahko drži le na odprtem (travnik, redko poraščene površine). Zato algoritmi za izdelavo DMR razvrstijo oblak lidarskih točk na tiste, ki predstavljajo odboje od golih tal in na druge odboje (rastlinstvo, grajeni objekti). Ta postopek se imenuje filtriranje. Predlagani so bili različni načini filtriranja. Vosselman (2000) je prvi razvil morfološke filtre za lidarske podatke. Ime so dobili po matematični morfologiji. Uporabljajo strukturni element, ki opisuje dopustno višinsko razliko pri določeni horizontalni oddaljenosti med sosednjimi točkami oblaka. Manjša kot je horizontalna oddaljenost, manjša je dopustna višinska razlika med talnimi točkami. Strukturni element lahko ugotovimo iz podatkov o reliefu, ali pa ga privzamemo iz predpostavke o največjem naklonu reliefa. Druga skupina filtrov deluje progresivno. Najprej

le nekaj točk prepoznamo kot talne točke, nato pa jim dodajamo nove. Axelsson (2000) je na ta način razvil metodo zgoščanja TIN (Triangulated Irregular Network). Začetni, redek TIN zgradi iz lokalnih višinskih minimumov, nato pa posamezne trikotnike TIN postopoma zgošča z dodajanjem točk iz oblaka, če kot med stranico, ki vodi do nove točke in ravnino prvotnega trikotnika ne presega dopustnega praga. Tretja skupina algoritmov zgradi približni model reliefa, nato pa ga iterativno približuje pravemu poteku reliefa. Začetni model služi izračunu vertikalnih odmikov točk (angl. residuals). Točke, ki ležijo nad njim, imajo manjši vpliv pri izračunu reliefa v naslednji iteraciji (Kraus in Pfeifer 1998). Četrta skupina algoritmov deluje s pomočjo segmentiranja. Sithole (2003) navaja metodo, ki skupine sosednjih točk segmentira in klasificira glede na njihove medsebojne višinske razlike. Našteti algoritmi delujejo avtonomno in z enakimi nastavitvami obdelajo celotno površino, na primer nekaj sto km^2. Zato rezultati praviloma niso optimalni na vseh delih obdelane površine.

V zgodnjih osemdesetih letih prejšnjega stoletja so prvič uporabili profilni lidar za merjenje višine, gostote in vrstne sestave gozdov vzdolž transektov v smeri leta (Nelson in sod. 1984, Maclean in Krabill 1986). V devetdesetih letih so vrstični lidarji nadomestili profilne lidarje, uporaba GPS v kombinaciji z INS pa je omogočila letalsko lidarsko snemanje tridimenzionalnih koordinat točk odbojev. Prve uporabe v gozdu so bile določanje nadmorskih višin reliefa (Kraus in Pfeifer 1998), ocena povprečne sestojne višine in povprečne sestojne lesne zaloge (Næsset 1997a, b), klasifikacija drevesnih vrst (Brandberg 2003a, b) ter ocena rasti gozda in zaznava posekanih dreves (Yu in sod. 2004). Do sedaj so lidar v gozdarstvu uporabljali za daljinsko zaznavanje reliefa pod gozdom, ocenjevanje značilnosti gozdnih sestojev in ocenjevanje značilnosti posameznih dreves. Mnenje številnih avtorjev je, da se ob razpoložljivi podrobnosti in pozicijski točnosti lidarskih podatkov in ob hitrem nadaljnjem razvoju senzorjev na področju gozdarstva odpirajo številne še neraziskane možnosti njihove uporabe (Steinvall 2003, Lim in sod. 2003, Hyyppa in sod. 2004).

Struktura gozdnega pokrova (t.j. njegova prostorska razporeditev, dimenzije, oblike, povezanost in hierarhija njegovih elementov) posredno nakazuje stanje, funkcioniranje in trend razvoja posameznega gozdnega ekosistema. V tem poglavju na kratko povzemamo raziskave, ki se nanašajo na ocenjevanje poglavitnih značilnosti gozdnih sestojev in s tem na razmejevanje med različnimi sestoji. Podrobnejši pregled raziskav na področju modelnega napovedovanja nekaterih izbranih značilnosti gozdnih sestojev bomo podali v poglavji 4.1.

Pogosta metoda ugotavljanja višin krošenj v gozdu iz lidarskih podatkov je izdelava digitalnega modela krošenj (DMK), ki prikazuje relativne višine gozdne vegetacije nad golimi tlemi. Pomembno je upoštevati, da diskretni lidar z majhnim premerom žarka, kakršnega največrat uporabljamo, podcenjuje drevesne višine. Vzrok je način snemanja, ki z merjenjem posameznih točk objekte le vzorči, pri čemer pogosto zgreši sam vrh drevesa. Stopnja podcenjevanja višin krošenj v gozdnem sestoju kot tudi višin posameznih dreves je odvisna od gostote snemanja in premera žarka (Lefsky in sod. 2002) ter od koničnosti vrha krošnje, slednja pa od drevesne vrste. Na podcenjevanje višin vplivajo tudi način izračuna DMK in DMR, stopnja prodiranja laserskega žarka skozi vegetacijo (angl. penetration rate) in količina podrasti v gozdu (Hyyppa in Inkinen 1999, Persson in sod. 2002, Leckie in sod. 2003, Yu in sod. 2004). Možne so tudi grobe napake DMK zaradi napak v DMR, ker slednji v strmem ali zelo gozdnatem terenu včasih prikazuje vrh dreves, namesto golega reliefa (Riaño in sod. 2005). Hyyppa in Inkinen (1999) navajata tipično podcenitev za iglavce (smreka) velikostnega reda 1 m (RMSE) oziroma sistematično za 0,1 m. Pri listavcih je zaradi bolj zaobljenega vrha krošnje napaka praviloma manjša kot pri iglavcih, razen kjer imamo gosto podrast, ki se lahko odrazi v precenjevanju višin DMR in s tem v močnejšem podcenjevanju

višin DMK (Leckie in sod. 2003). Magnussen in Boudewyn (1998) sta sistematično razliko med dejanskimi in lidarsko izmerjenimi drevesnimi višinami pojasnila z uporabo geometričnega modela. Means in sod. (2000) ter Næsset in Okland (2002) so višine ocenjevali regresijsko na podlagi percentilov odbojev po višinskih razredih nad tlemi.

Maclean (1982) je pokazal, da je površina vertikalnega prereza skozi gozdni sestoj sorazmerna z logaritmom sestojne lesne zaloge. Maclean in Krabill (1986) sta nato ugotovila, da to površino lahko ocenimo z lidarskim snemanjem in tako napovemo sestojno lesno zalogo. Višinski percentili odbojev so bili uporabljeni v borealnem iglastem gozdu za regresijsko napovedovanje povprečne višine dreves v sestoju, sestojne temeljnice in lesne zaloge (Means in sod. 1999, Næsset in Okland 2002). Holmgren in Persson (2004) sta v borealnem iglastem gozdu za klasifikacijo drevesnih vrst posameznih dreves (rdeči bor, smreka) uporabila veliko število spremenljivk, izračunanih na ravni segmentov, med drugim standardni odklon višin odbojev, delež prvih odbojev, delež odbojev od vegetacije, oblika vrha krošnje (ki sta jo ugotovila s prilagajanjem paraboloida oblaku točk), standardni odklon in srednja intenzivnost odbojev itd. Na ta način sta dosegla 95% točnost pri razlikovanju dveh drevesnih vrst.

Pojavljajo se tudi meritve sestojnih značilnosti, ki pred lidarjem niso bile izvedljive. Tako so Lefsky in sod. (1999) ter Harding in sod. (2001) v severnoameriških sestojih duglazije razvili meritev prostorske porazdelitve volumna krošenj z valovnim lidarjem, ki temelji na 3D rastrski podatkovni strukturi, kjer se elementi 3D matrike razlikujejo glede na vsebnost in osvetljenost krošnje. Te informacije so nato uporabili za boljše razumevanje strukture zrelih sestojev ter za klasifikacijo sestojev glede na kvalitativne in kvantitativne razlike po starostnih razredih. Na primer mladi sestoji v tej analizi kažejo homogeno zgornjo površino krošenj ter odsotnost sestojnih vrzeli. Po drugi strani imajo zreli sestoji zelo neenakomerno zgornjo površino krošenj, hkrati pa tu zasledimo široko vertikalno porazdelitev strukturnih razredov krošenj.

Omenjeni rezultati nakazujejo, da je lidar primerno orodje za oceno sestojnih značilnosti v borealnih gozdovih, ki so bili objekt velike večine objavljenih raziskav (Lim in sod. 2003). Iz stališča daljinskega zaznavanja je najpomembnejša razlika borealnega gozda glede na mešane in listnate gozdove, kakršni se pojavljajo v Srednji Evropi in prevladujejo tudi v Sloveniji, velika vrstna in strukturna homogenost. Zato so dosežene regresijske korelacije oziroma točnosti klasifikacije v borealnih gozdovih višje, kot poročajo za listnate gozdove (Thies in sod. 2002, Brandtberg 2003a, Hirata in sod. 2003, Todd in sod. 2003).

Dodatni olajšavi borealnega gozda iz stališča lidarskega snemanja sta prevladujoča konična oblika krošenj, zaradi česar je segmentacija dreves enostavnejša, ter na splošno redkejši sklep krošenj in s tem večji delež odbojev iz notranjosti sestoja, kar olajša proučevanje njegove notranje strukture. Poleg visoke cene snemanja in interpretacije lidarskih podatkov je tako glavna ovira uveljavitvi lidarja v gozdarskih in okoljskih aplikacijah v Sloveniji pomanjkanje raziskav v primerljivih okoljskih in gozdnogospodarskih razmerah. Kaže se torej jasna potreba po testiranju posameznih že uveljavljenih metod interpretacije lidarskih podatkov v slovenskih razmerah in po njihovi prilagoditvi ali dopolnitvi.

1.4 Prispevek k znanosti

V nalogi se bomo ukvarjali tako z lidarskim zaznavanjem tal kot tudi zaznavanjem posameznih značilnosti gozdnih sestojev z letalskim diskretnim lidarjem majhnega odtisa.

Znani algoritmi imajo v strmem gozdnatem reliefu težave z izdelavo DMR, saj ima v strmem reliefu lokalna okolica v oblaku podobne značilnosti kot vegetacija: velike višinske razlike pri majhnih vodoravnih razdaljah, zaradi česar je težavno razlikovanje talnih odbojev od vegetacije. Predstavili bomo novo metodo izdelave DMR, posebej namenjeno uporabi v strmem gozdnatem reliefu, ki bo izkoriščala preobilje lidarskih odbojev (redundanco) za zmanjšanje tovrstnih napak v DMR.

Nekaj znanih študij prikazuje modeliranje gozdnih značilnosti s profili, ki jih neposredno daje valovni lidar velikega odtisa (tipičen primer je Lefsky in sod. 1999). Lidarski vertikalni profili vegetacije, izračunani iz podatkov diskretnega lidarja majhnega odtisa, se pojavljajo kot obetajoča nova skupina pojasnjevalnih spremenljivk pri modelnem napovedovanju različnih lastnosti gozda. Med tako napovedovanimi lastnostmi v virih še ni primera modeliranja temeljnice, deleža drevesnih vrst, indeksa listne površine (angl. leaf area index – LAI) in sestojnega sklepa. Na primeru dveh gozdnogospodarskih enot bomo prikazali različne načine napovedovanja omenjenih lastnosti gozda z različnimi večciljnimi ansambelskimi metodami strojnega učenja ter z uporabo različnih kombinacij pojasnjevalnih spremenljivk, izpeljanih iz diskretnih lidarskih podatkov in iz infrardečih aeroposnetkov.

Razlogi za izbiro večciljnih ansambelskih modelov so naslednji:

- njihova uporaba je enostavna, ker so manj občutljivi na ustrezen izbor pojasnjevalnih spremenljivk, oziroma so neprimerne spremenljivke sposobni sami izločiti;
- znotraj ansambelskih modelov so za naš namen večciljni modeli primernejši od modelov z eno ciljno spremenljivko., ker je poraba časa za gradnjo enega večciljnega modela manjša od porabe za gradnjo mnogih enociljnih modelov, še posebej če upoštevamo tudi porabo časa za manipulacijo s podatk;
- večciljne modele je lažje implementirati in izračun kart iz teh modelov je bistveno hitrejši, saj na koncu vsake poti po odločitvenem drevesu dobimo napovedi za vse ciljne spremenljivke hkrati in ne le za eno samo.

1.5 Organizacija naloge

V poglavju 2 bomo predstavili testna območja in daljinsko zaznane podatke, ki smo jih uporabili v tej nalogi. V poglavjih 3 in 4 sledita dva ločena, vendar vsebinsko soodvisna dela naloge. V poglavju 3 se bomo ukvarjali s prepoznavanjem reliefa golih tal pod gozdom in predlagali povsem novo metodo izdelave rastrskega digitalnega modela reliefa DMR, ki bo prispevala k rešitvi problema izdelave točnejšega lidarskega DMR na strmem gozdnatem reliefu. Točen in podroben DMR je v goratih predelih Slovenije predpogoj za zanesljivejše ugotavljanje relativne višine nad tlemi za vse zabeležene lidarske odboje in s tem za točnejše lidarsko ocenjevanje lastosti gozda; to bo tema poglavja 4, kjer bomo predstavili uporabo lidarskih in terensko zbranih podatkov za modelno napovedovanje temeljnice, drevesne sestave in svetlobnih značilnosti gozda ter prikazali kartiranje modelnih napovedi. V poglavju

5 bomo povzeli ugotovitve ter jih sklenili s pregledom mogočih uporab doseženih rezultatov in mogočimi nadaljnjimi smermi raziskave.

2 Testna območja

V nadaljevanju bomo opisali uporabljene raziskovalne objekte. Novo metodo izdelave digitalnega modela reliefa DMR smo preizkusili na objektu Litija, kjer smo relief tudi geodetsko posneli. Vpliv gostote lidarskih točk na točnost DMR smo preizkusili na objektu Kras, ker ga odlikuje izrazitejši mikrorelief. Objekt Slivnica je daleč največji, uporabili pa smo ga za primerjavo različnih metod modelnega napovedovanja lastnosti gozda.

2.1 Testno območje Litija

Učinkovitost algoritma REIN (angl. REpetitive INterpolation), ki bo opisan v poglavju 3.2, smo ocenili na 2 ha velikem testnem območju blizu Litije, ki ga označujeta strm relief in sklenjen gozdni pokrov. Slika 1a prikazuje DMR testnega območja, ki predstavlja 0,17 % površine 1179 ha, ki je bila 30. aprila 2003 posneta za potrebe gradnje bodočega daljnovoda Beričevo-Litija. Podatke smo uporabili z dovoljenjem lastnika, javnega podjetja ELES Elektro-Slovenija, d.o.o. Posnetek je bil narejen, ko je bilo rastlinstvo že skoraj povsem olistano. Stopnja prodiranja do tal je za zadnje odboje ocenjena na 47%. Snemanje je bilo opravljeno v načinu prvi odboj-zadnji odboj z lidarskim skenerjem Optech ALTM 1020 na helikopterju. Višina leta je bila 260-300 m nad terenom, talna hitrost leta pa 25-50 km/h. Divergenca laserskega žarka je znašala 0,3 mrad; pri dani višini leta to pomeni približno 20-centimetrski premer žarka na tleh, kar je manj od tipičnega premera 50-100 cm. Dosežena gostota oblaka točk je znašala 6,4 m^{-2} za prve odboje in 8,5 m^{-2} za zadnje odboje. Pri izračunu DMR smo upoštevali le zadnje odboje. Višina leta je bila dokaj nizka, vendar je bila po drugi strani nizka tudi frekvenca laserskih pulzov (20 kHz), če upoštevamo da trenutni laserski skenerji zmorejo frekvence 100-150 kHZ. Tehnični podatki inštrumenta za dano višino leta navajajo navpično točnost merjenja ±15 cm, vodoravno pa ±35 cm. Slika 1b prikazuje DOF (digitalni letalski ortofoto) testnega območja.

Povprečni naklon terena testnega območja znaša 30º, največji nakloni (brežine cest, erozijski jarek) pa znašajo do 70º. Območje je prekrito z mešanim gozdom rdečega bora in kostanja povprečne višine 18 m, kar smo ocenili iz digitalnega modela krošenj DMK (rastrska karta, ki prikazuje višine gozdne vegetacije). V podrasti prevladujeta bukev in navadna krhlika, v zeliščnem sloju pa orlova praprot in borovnica. Povprečni sklep krošenj znaša 67%, največji pa 86%. Sklep krošenj smo ocenili kot razmerje prvih in zadnjih odbojev, ki so več kot 1 m od tal glede na vse prve in zadnje odboje in sicer znotraj okroglih vzorčnih ploskev s polmerom 5 m, katerih središča predstavljajo referenčne talne točke.

Iz oblaka talnih točk smo znotraj treh sistematično razmeščenih transektov v smeri sever – jug vizualno prepoznali 563 talnih točk za oceno kvalitete DMR. Vsak transekt je 0,5 m širok in 100 m dolg (Slika 1c). Da bi talne odboje lahko vizualno ločili od rastlinskih, smo vsak transekt interaktivno zarotirali. Ročno filtriranje imamo ob odsotnosti dodatnih informacij lahko za najboljši mogoči način filtriranja. Sithole in Vosselman (2004) sta to metodo predlagala pri svoji primerjavi filtrirnih algoritmov. Praksa je pokazala, da so napake računalniškega filtriranja pogosto zlahka prepoznavne za človeško oko, zato dobavitelji podatkov to metodo klasifikacije uporabljajo rutinsko.

Ključna kontrola učinkovitosti algoritma REIN pa je temeljila na 744 terensko izmerjenih talnih točkah (Slika 1c), ki smo jih izmerili s totalno postajo Leica TC605L. Dve točki sta bili izmerjeni z GPS in iz njiju smo vlekli transekte za izmero višin golih tal pod gozdnim pokrovom. Upoštevajoč prenos napak, točnost terensko izmerjenih točk znaša ±5 cm v smeri X-Y, če pa upoštevamo povprečni naklon terena 45°, je višinska napaka ±9 cm.

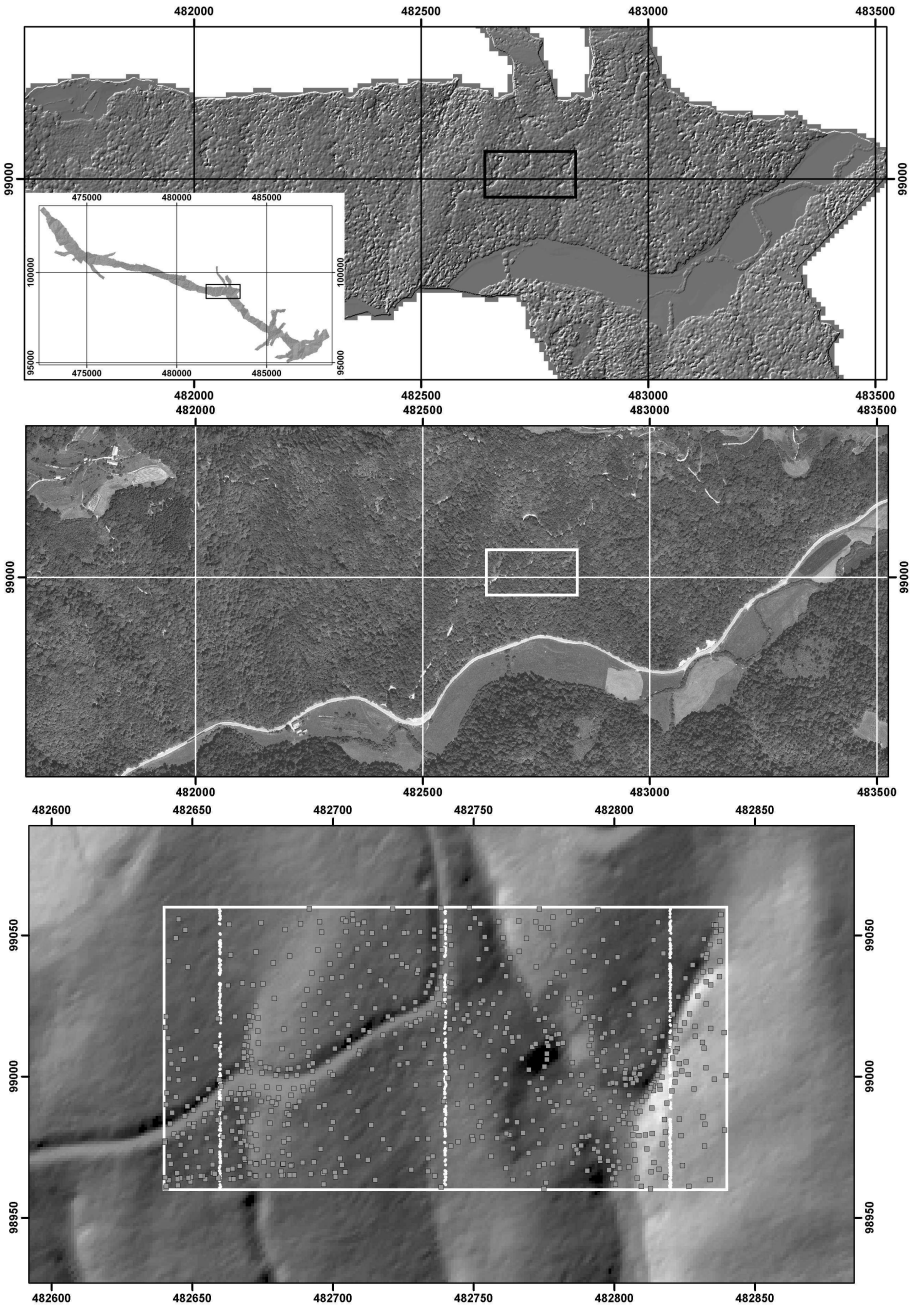

Slika 1: (a) prikazuje digitalni model površin, (b) pa letalsko ortofotografijo širše okolice testnega območja Litija. Območje je prekrito z mešanim gozdom na strmih pobočjih. Izrez na (a) spodaj levo prikazuje celotno skenirano območje. Manjša pravokotnika na (a) in (b) označujeta lego testnega območja. (c) prikazuje testno območje, kjer potekajo trije transekti v smeri S-J z vizuelno prepoznanimi talnimi točkami ter raztresene točke, izmerjene s totalno postajo.
Figure 1: In (a) and (b) the Litija test site and its surroundings is shown as a digital surface model and in an aerial orthophoto, respectively. The area is covered with mixed forest on steep terrain. The inset in lower left of (a) presents the DSM of the entire scanned area. The embedded rectangles in (a) and (b) represent the location of the Litija test area. In (c) the filtered DEM of the test area is shown (white rectangle), where the three North-South transects contain the visually identified ground points and the scattered points, that were measured by a total station.

2.2 Testno območje Kras

Testno območje Kras, ki leži severovzhodno od vasi Brestovica, tik ob italijanski meji, na nadmorski višini med 71 in 233 m, je veliko 10 ha, dolgo 400 m (vzhod–zahod) in široko 250 m (sever–jug). Izbrano je bilo za testiranje vpliva gostote lidarskih točk na točnost DMR, ker vsebuje tipičen kraški mikrorelief. Relief je razgiban, z nakloni do 60° in s povprečnim naklonom 22°. Kraški mikrorelief vključuje skale, visoke do 1 m, ozko sotesko in zarasle vinogradniške terase. Posebnost testnega območja so ostaline doberdobskega odseka soške fronte (avstrijski obrambni jarki, bombni kraterji), ki pa jih je preraslo gosto grmovje in drugo rastlinstvo (Slika 2c). Podatki diskretnega lidarja (uporabljeni so bili z dovoljenjem lastnika, Ministrstva za obrambo) so bili posneti 27. aprila 2005, kmalu po začetku olistanja, vendar še pred popolnim olistanjem. Uporabili smo laserski skener Optech ALTM-3100 na helikopterju. Talna hitrost leta je znašala 120 km/h, višina leta pa je bila 1000 m nad tlemi. Frekvenca lidarskih pulzov je znašala 100 kHz, frekvenca skeniranja 30 Hz, kot skeniranja 20°, divergenca laserskega žarka pa 0,3 mrad. Za vsak pulz so bili zabeleženi do 4 odboji. Gostote oblaka so bile v testnem območju 5,15 m^{-2} za prve odboje, 0,56 m^{-2} za vmesne odboje, 7,64 m^{-2} za zadnje odboje in 3,21 m^{-2} za edine odboje. Testno območje prerašča submediteranski panjevski gozd. Glavne drevesne vrste so črni gaber, črni bor in poljski brest. Povprečna višina dreves je 9 m, posamezna najvišja drevesa presegajo 20 m, kar smo ocenili z DMK pri največji razpoložljivi gostoti lidarskih točk. Sklep krošenj je zaradi zaraščanja nekaterih donedavna obdelanih površin z gozdom precej raznolik in znaša med 5 in 91 %, povprečje je 64 %. Sklep krošenj smo ocenjevali kot razmerje med prvimi odboji in vsoto prvih in edinih odbojev za vsako delno površino velikosti 10 krat 10 m.

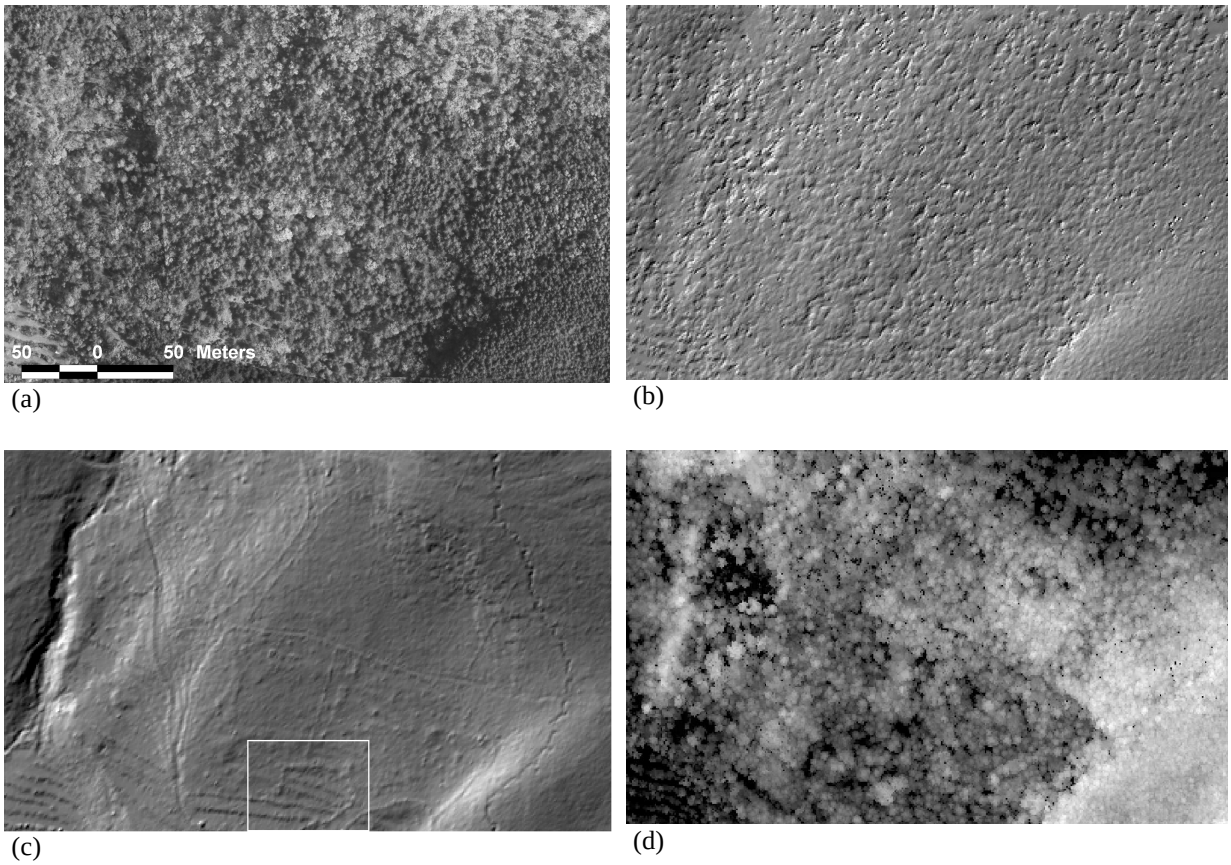

Slika 2: Testno območje Kras, ki meri 400 m (V-Z) krat 250 m (S-J) je prikazano na (a) aeroposnetku, (b) senčenem digitalnem modelu površin, (c) senčenem digitalnem modelu reliefa golih tal in (d) na digitalnem modelu krošenj. Karte na (b), (c) in (d) so bile izračunane z največjo razpoložljivo gostoto podatkov. Beli pravokotnik na označuje področje, ki je podrobno prikazano na Slika 10.
Figure 2: The Kras test area measuring 400 m (E-W) by 250 m (N-S) is shown (a) on an aerial orthophoto, (b) on a shaded forest surface model, (c) on a shaded DEM of the bare ground, and (d) nDSM. The maps shown in (b), (c), and (d) were computed using the highest available point densities. The white rectangle in (c) denotes the detail rendered as wireframe model in Figure 10.

2.3 Testno območje Slivnica

Testno območje Slivnica (Slika 3) , ki smo ga uporabili za primerjavo različnih metod modelnega napovedovanja lastnosti gozda, obsega dve sosednji gozdnogospodarski enoti (GGE): GGE Menišija in GGE Slivnica. Obe spadata v Območno enoto Postojna Zavoda za gozdove, izbrali pa smo ju zaradi velike pestrosti gozda, saj na tem območju najdemo širok spekter razvojnih tipov, kot na primer grmišča in borovja na opuščenih kmetijskih površinah, različne kulture bora in smreke pa tudi gospodarsko pomembne bukove ter bukove in jelove gozdove. Površina testnega območja znaša 8618 ha, od tega 2700 ha GGE Menišija (od tega 2392 ha ali 88,6 % gozda) in 5918 ha GGE Slivnica (od tega 3759 ha ali 63,5 % gozda). Relief v GGE Menišija je kraška planota z mnogimi vrtačami, v GGE Slivnica pa najdemo aluvialne ravnine, pobočja zmernih do strmih naklonov ter nekaj erozijskih jarkov s strmimi brežinami.

Lidarsko snemanje je izvedlo podjetje GEOIN iz Maribora z lidarjem Optech Gemini 167 na letalu. Prvo lidarsko snemanje je bilo 8. in 9. maja 2007, dopolnilno lidarsko snemanje ter

fotosnemanje pa 21. in 24. maja 2007, torej kmalu po začetku vegetacijske sezone. Hitrost leta je bila 160 km/h, višina leta pa je bila 8. in 9. maja 1700 m nad morjem oziroma 600 do 1100 m nad terenom, 21. in 24. maja pa 1900 m nad morjem oziroma 800 do 1300 m nad terenom. Frekvenca laserskih pulzov je bila 100 kHz, odklon skeniranja od nadirja 15º, divergenca laserskega žarka 0,3 mrad, odtis žarka na tleh pa (glede na višino leta) od 18 do 40 cm. Pri lidarskem snemanju so beležili do 4 odboje. Povprečne gostote odbojev znotraj testnega območja so bile 4,0 m^{-2} za prve odboje, 4,0 m^{-2} za zadnje odboje, 11,4 m^{-2} za edine odboje in 0,6 m^{-2} za vmesne odboje. Skupna povprečna gostota vseh odbojev je bila 20,0 m^{-2}. Skupna gostota zadnjih in edinih odbojev (ki smo jih uporabili za izdelavo DMR) je znašala 15,4 m^{-2}, enako pa tudi skupna gostota prvih in edinih odbojev (ki smo jih uporabili za modelno napovedovanje značilnosti gozda). Gostota snemanja je bila precej neenakomerna, vendar pa je bilo relativno malo površin, kjer bi bila nižja od 10 m^{-2}.

Infrardeče fotosnemanje je bilo opravljeno z digitalno kamero Optech Applanix DS 322, podjetje GEOIN pa je posnetke tudi ortorektificiralo pri ločljivosti 25 cm. Poleg teh smo uporabili tudi infrardeče ortofotoposnetke Geodetske uprave RS, ker so bili sicer posneti eno sezono prej, vendar kasneje v vegetacijski dobi (27. junija in 18. julija 2006). Ti posnetki imajo ločljivost 1 m.

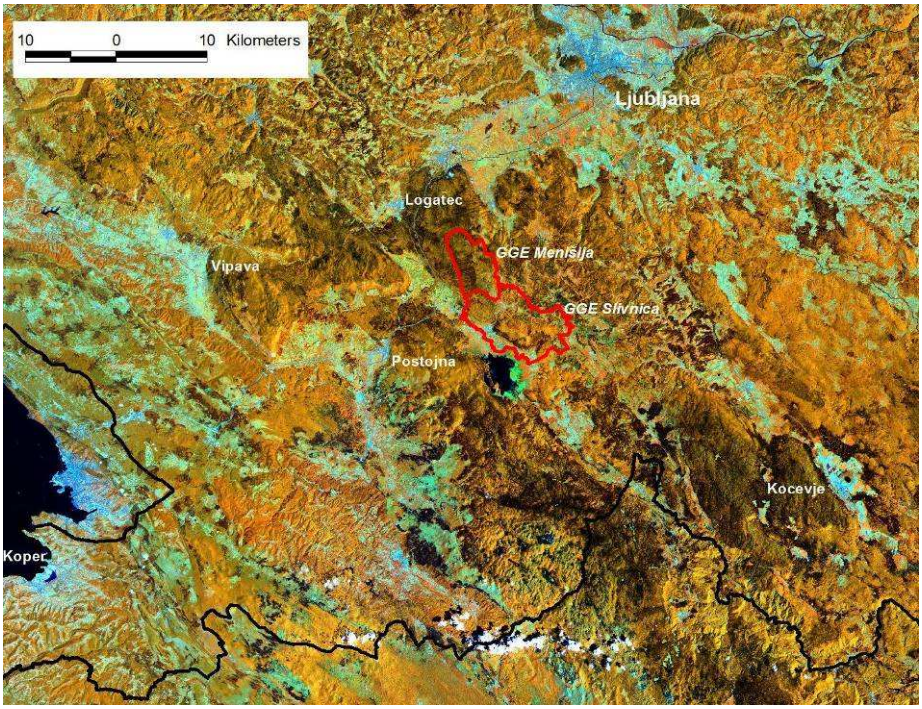

Slika 3: Gozdnogospodarski enoti Menišija in Slivnica skupaj predstavljata testno območje Slivnica, veliko 8618 ha.
Figure 3: Forest management units Menišija and Slivnica together represent the Slivnica test area, encompassing an area of 8618 ha.

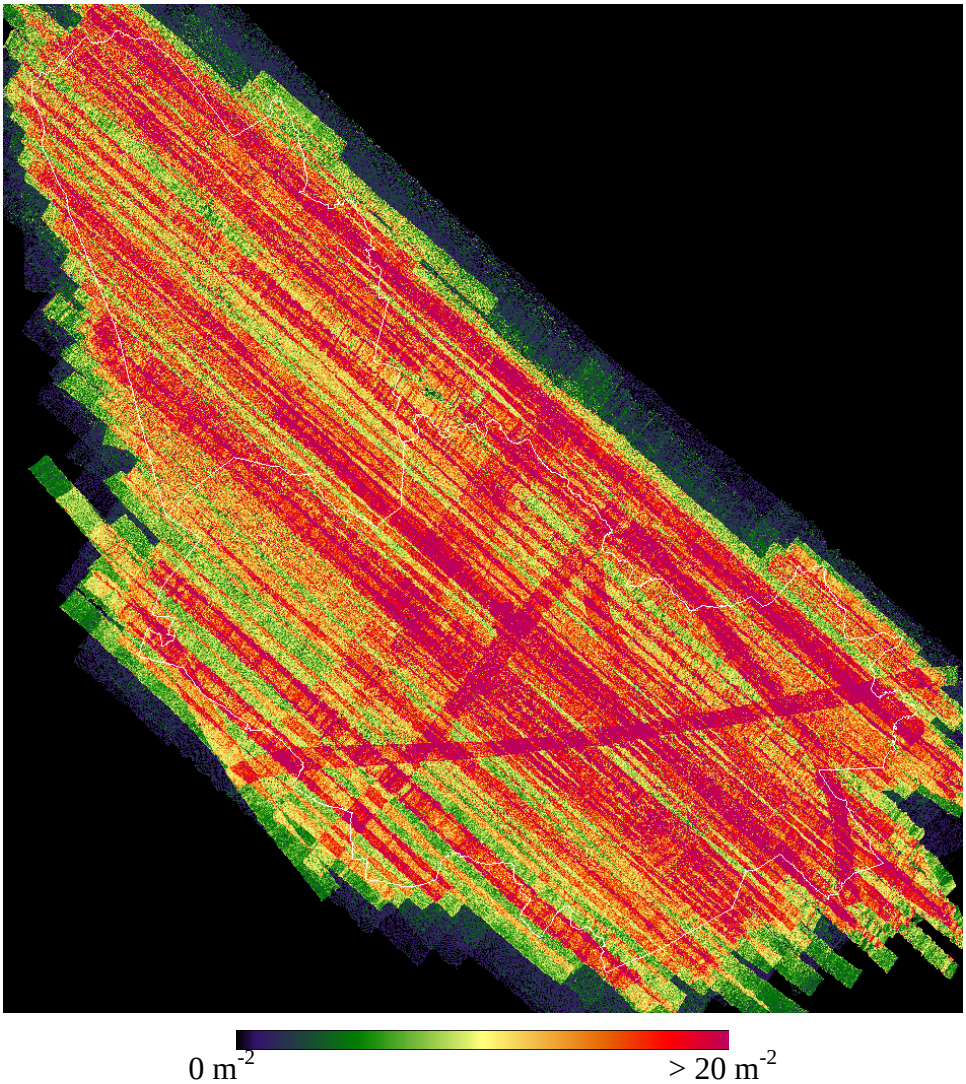

Slika 4: Skupna gostota prvih in edinih odbojev, ki so bili osnova za izračun lidarskih pojasnjevalnih spremenljivk za modelno napovedovanje lastnosti gozda v testnem območju Slivnica.
Figure 4: Total density of the first and only returns, which were used to compute lidar-based explanatory variables for the model-based predictions of forest parameters in the Slivnica test area.

3 Izdelava lidarskega digitalnega modela reliefa

V tem poglavju bomo predstavili prvi sklop naloge, katerega cilj je razviti novo metodo izdelave lidarskega digitalnega modela reliefa (DMR). Glede na prevladujoč gorat relief Slovenije ter pretežno pokritost z gozdom je lidarsko izračunan DMR ključen podatek ne le za gozdarstvo, ampak tudi za mnoge druge dejavnosti v neposeljenem prostoru, ki potrebujejo podrobne in točne informacije o konfiguraciji terena. V ožjem gozdarskem smislu je podroben in točen lidarski DMR potreben za izračun relativnih višin lidarskih točk nad tlemi in s tem za gozdarsko interpretacijo lidarskih podatkov. Tak DMR pa omogoča tudi nove aplikacije na področju gradnje gozdnih prometnic, gradnje gozdnih žičnic za spravilo lesa ter pri urejanju in nadzoru hudourniških in erozijskih območij.

3.1 Pregled stanja in opredelitev problema

Z laserskim skeniranjem izmerimo točke na predmetih med senzorjem in tlemi, odvisno od česa se laserski žarek odbije. Lahko se odbije od daljnovodov, rastinskih listov in vej, hišnih streh in podobnega, zato mnoge točke ne ležijo na tleh. Klasifikacijo točk na talne in druge točke imenujemo filtriranje. Filtriranje je bistvena faza izračunavanja DMR, včasih pa je pomembno tudi za rekonstrukcijo netopografskih predmetov, kot so daljnovodi in hiše, ter seveda tudi gozda.

Zaradi mnogokratnih odbojev (angl. multi-path reflection) včasih zaznamo tudi točke, ki na videz ležijo pod zemljo. To se zgodi, če se del oddane energije ne odbije neposredno nazaj v senzor, ampak pred tem še od neke druge površine, zaradi česar izmerjen potovalni čas ustreza razdalji, ki je daljša od razdalje med senzorjem in tlemi. Posledično bo izračunani položaj točke ležal pod tlemi.

Metode filtriranja delujejo popolnoma avtomatsko, torej z nespremenjenimi vrednostmi parametrov na celotni posneti površini, ki lahko znaša od nekaj km^2 do nekaj sto km^2. Izračunan DMR zato ni optimalen v vseh delih posnete površine. Strm gozdnat teren je za filtriranje še posebej težaven. V nadaljevanju bomo predstavili nov algoritem za strm relief pod strnjenim gozdnim pokrovom, kjer imajo drugi algoritmi filtriranja tipične težave pri razlikovanju med talnimi odboji in odboji od rastlinstva. Algoritem je nov tudi v smislu, da ga ni mogoče uvrstiti v nobeno od štirih glavnih kategorij, ki jih opisujemo v naslednjem razdelku. Po eni strani lahko deluje z redkimi talnimi odboji pod strnjenim gozdnim pokrovom, po drugi strani pa tudi z zelo gostimi in preštevilnimi (redundantnimi) talnimi odboji v gozdnih vrzelih in na jasah. Raznolika gostota talnih odbojev lahko nastopa pri vseh merilih, ker je posledica razlik v rastlinstvu ter lastnostih terena in skenerja. Različna gostota rastlinstva lahko privede do različnih deležev talnih točk zaradi različnih stopenj prodiranja žarka skozi rastlinstvo. Sistemi laserskega skeniranja imajo različne stopnje vzorčenja v sredini ali ob robovih snemalnega pasu, kar tudi privede do razlik pri gostoti talnih točk. Pri skenerjih z nihajočim ogledalom so točke gostejše ob robu snemalnega pasu, pri vrtečem se ogledalu pa na sredini snemalnega pasu. Novi algoritem se loteva tudi problema negativnih osamelcev (angl. outliers), ki so posledica mnogokratnih odbojev.

Predlaganih je bilo več konceptov filtriranja, ki jih razporejamo v štiri skupine: morfološko filtriranje, progresivno filtriranje, iterativno filtriranje in segmentno filtriranje (Kobler in sod.

2007). Prva skupina filtrov je dobila ime po matematični morfologiji (Haralick in Shapiro 1992) in se uporablja pri morfološkem filtriranju (Vosselman 2000). Pri tem filtriranju uporabljamo strukturni element, ki glede na vodoravno razdaljo med dvema točkama opisuje njuno dovoljeno višinsko razliko (Slika 5a). Manjša kot je razdalja med talno točko in njeno sosednjo točko, manjša je sprejemljiva višinska razlika. Strukturni element postavimo na vsako točko, s čimer netalne točke prepoznamo kot tiste, ki presegajo dovoljeno višinsko razliko. Strukturni element lahko optimalno ocenimo glede na dani teren, lahko pa ga določimo kar glede na predpostavko največjega pričakovanega naklona terena. Različice morfoloških filtrov je opisal Sithole (2001), kjer je strukturni element odvisen od terena. Za strmejša območja so dovoljene večje višinske razlike. Strmino določamo s povprečenjem na velikih površinah. Podobno zamisel predstavljata Zakšek in Pfeifer (2006), kjer se strukturni element nagiba v celoti in na ta način sledi terenu, s čimer je rotacijska simetrija okoli osi *z* izgubljena. Razlog je v tem, da imajo višinske razlike, gledane navzdol, drugačne lastnosti, kot če so gledane navzgor, česar drugi morfološki filtri ne upoštevajo. Kilian in sod. (1996) uporabljajo več strukturnih elementov hkrati v okviru morfološke operacije odpiranja (angl. opening). Ta metoda deluje na rastrskih podatkih, medtem ko prejšnje metode delujejo neposredno na oblaku točk. S strukturnimi elementi oziroma okni različnih velikosti se lotevajo različnih objektov (majhni avtomobili, velike zgradbe). Točkam priredijo uteži glede na velikost okna. Zhang in sod. (2003) opisujejo primerljivo metodo, ki uporablja različne velikosti okna ter dovoljene višinske razlike znotraj vsakega okna (Slika 5b), pri čemer posebej podajajo metodo za izbiro teh parametrov. Lohmann in sod. (2000) uporabljajo morfološki operaciji erozijo (angl. morphological erosion) in širjenje (angl. morphological dilation), s katerima rastrske nadmorske višine nadomestijo s filtriranimi.

Druga skupina filtrov deluje progresivno, pri čemer postopoma vse več točk klasificiramo kot talne. Axelsson (2000) uporablja najnižje točke znotraj velikih rastrskih celic kot prve talne točke, iz katerih s triangulacijo vzpostavi referenčno površino. Znotraj vsakega trikotnika se določi dodatna talna točka, pri čemer je kriterij odmik neklasificirane točke od referenčne površine (Slika 5c), definiran kot trojica kotov med površino trikotnika in robovi, ki povezujejo novo točko z oglišči trikotnika. Na ta način triangulacijo progresivno zgoščamo. Von Hansen in Veogtle (1999) opisujeta podobno metodo, vendar z drugačnim izborom začetnih točk (spodnji del konveksnega ovoja oblaka točk) in z drugačnimi merami odmika. Sohn in Dowman (2002) v progresivno zgoščanje vključujeta korak navzdol, pri katerem dodajata točke pod triangulacijo, in nato korak navzgor, ko dodajata eno ali več točk nad vsakim trikotnikom.

Tretja skupina algoritmov temelji na modelu površin, ki teče skozi celoten oblak točk, ki ga iterativno približujemo nivoju tal. Prvi model površine uporabimo za izračun ostankov (residuals) od površine do točk (Slika 5d). Točke, ki ležijo nad površino, imajo v naslednji iteraciji manj vpliva na obliko površine kakor tiste pod njo (Slika 5e). Kraus in Pfeifer (1998) uporabljata linearno napovedovanje (navaden kriging) in utežno funkcijo, ki temelji na ostankih (residuals) za robustno napovedovanje uteži. Pfeifer in sod. (2001) so to metodo vgradili v hierarhični pristop za rekonstrukcijo velikih zgradb in za zmanjšanje časa računanja. Elmqvist (2001) ter Kass in sod. (1988) uporabljajo kačasti pristop, kjer notranje sile površine določajo njeno togost, zunanje sile pa negativno težnost. Iteracija se začne z vodoravno površino pod vsemi točkami in se nato dviga do točk, vendar ji notranja togost preprečuje, da bi segla do vegetacijskih odbojev ali streh hiš.

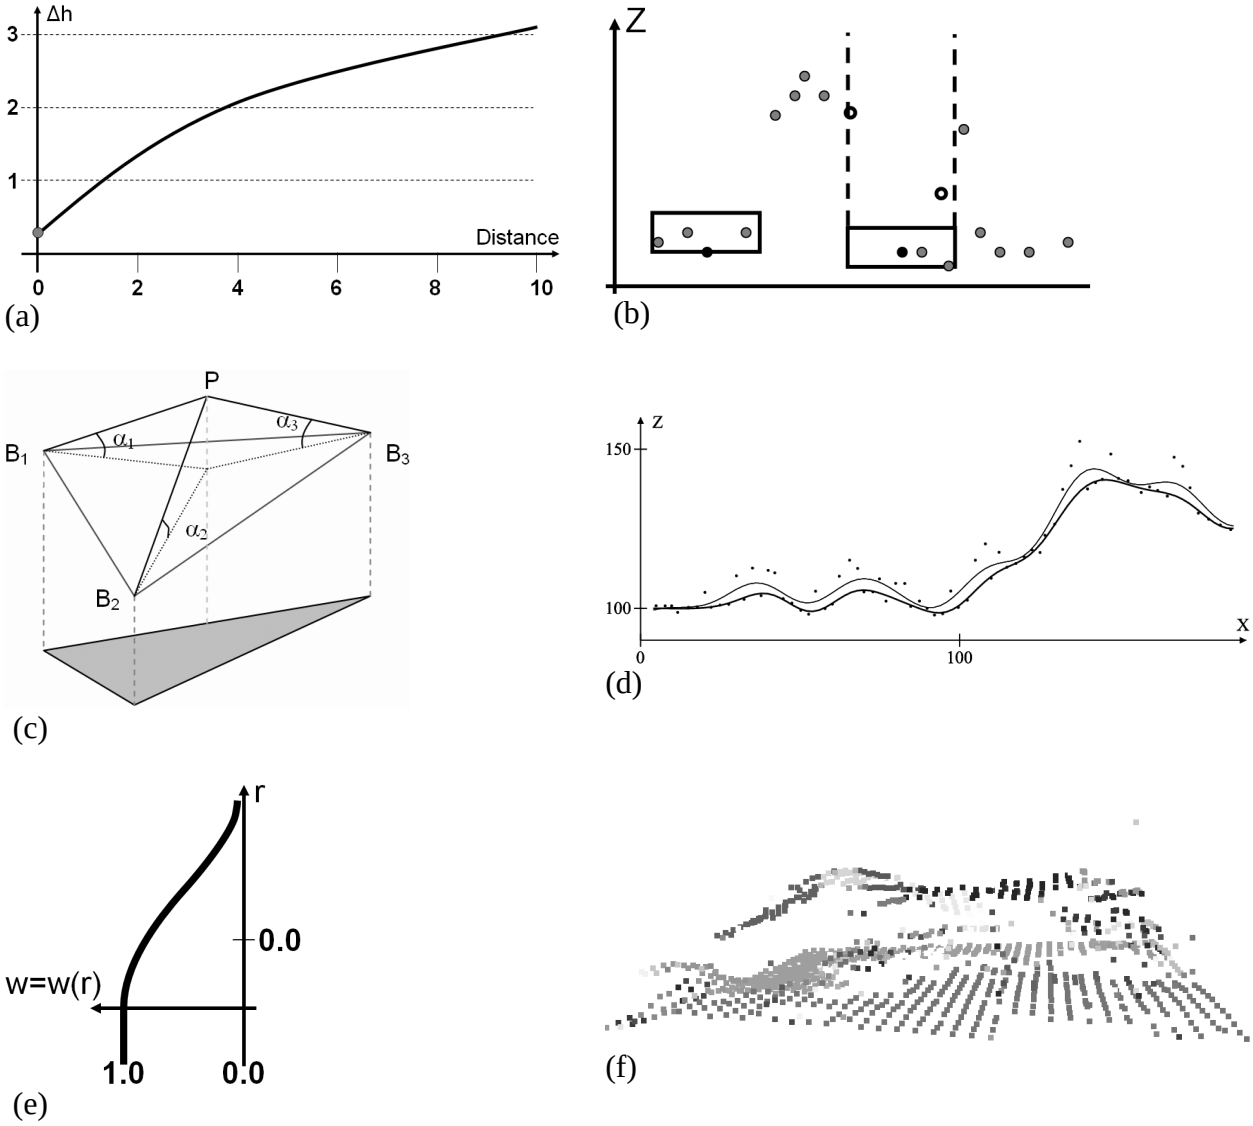

Slika 5: Filtriranje lidarskih podatkov z namenom zaznavanja tal (Kobler in sod. 2007). (a) Strukturni element kaže dovoljeno višinsko razliko glede na oddaljenost (enote so metri). (b) Oblak točk je prikazan v stranskem pogledu skupaj s tlemi, streho in vegetacijskimi točkami, okna so postavljena na dveh specifičnih točkah (črne pike). Pri desnem primeru sta dve točki (kroga) prepoznani kot ne-talni točki. (c) Trikotnik prej prepoznanih talnih točk (B1, B2, B3) s koti (α1, α2, α3) odloča o tem, ali bo točka P uvrščena med talne točke. (d) Zgornja črta prikazuje prvi približni model površine, ki ga izračunamo iz celotne množice točk (stranski pogled), spodnja črta pa prikazuje DMR v naslednji iteraciji. (e) Prikazana je utežna funkcija, ki jo računamo iz ostankov oziroma razdalj točk do površine. (f) Prikazana je segmentacija lidarskega oblaka točk v 3D pogledu, različni segmenti so v različnih tonih sivine.
Figure 5: Filtering of ALS data for ground detection (Kobler et al. 2007). In (a) the structure element shows the admissible height differences based on distance (units are meters). In (b) a point cloud is shown in a profile with ground, a roof and vegetation points, where at two specific points (black dots) windows are centered. In the right case two points (bold circles) are identified as not-ground points. In (c) a triangle of previously identified ground points (B1, B2, B3) is shown and measures (α1, α2, α3) to determine, if the investigated point (P) shall be classified as ground point. In (d) a first, rough surface model is shown as the upper line computed from the entire point set (profile view) and the lower line shows the DTM in the next iteration. In (e) a weight function is plotted which takes as input the residuals, i.e., the signed distance of the points to the surface. In (f) the segmentation of an ALS pointset is shown in a 3D view with different grey tones for different segments.

Četrta skupina filtrov temelji na segmentih (Slika 5f). Sithole (2005) opisuje metodo, ki klasificira segmente glede višinske razlike v soseščini. Nardinocchi in sod. (2003) za tvorjenje segmentov uporabljajo tehniko rasti območja (angl. region growing). Geometrijski in topološki opis regij sestavljajo dva grafa in množica pravil, ki določa nadaljnjo tvorbo segmentov, klasificiranih v tri glavne razrede: teren, zgradbe in vegetacija. Jacobsen in Lohmann (2003) uporabljata orodje eCognition na rastrskih podatkih, segmente pa ustvarjata s povečevanjem površin. Med drugim upoštevata tudi kompaktnost segmentov in njihovo višinsko razliko glede na sosednje segmente ter tako zaznavata različne tipe površin, tudi relief. Schiewe (2001) uporablja maksimalne in povprečne gradiente za klasifikacijo podatkov. Vse te metode so manj občutljive za šum, ker delujejo z velikimi površinami, ne pa s posameznimi točkami ali piksli. To kaže Slika 5f, kjer vidimo dva velika segmenta na tleh, nekaj segmentov na strehi ter posamezne točke in majhne segmente, ki pripadajo vegetaciji. Eksperimentalno primerjavo sposobnosti algoritmov opisujeta Sithole in Vosselman (2004). Četrta skupina algoritmov (segmentacijski algoritmi) kaže prednosti na območjih z jasno ločenimi segmenti, na primer na močno pozidanih območjih. To ne drži v gozdnatih območjih, kjer imajo težave tudi drugi algoritmi, predvsem tam, kjer je relief strm, zaradi česar ima lokalna okolica v oblaku podobne značilnosti kot vegetacija: velike višinske razlike pri majhnih vodoravnih razdaljah.

3.2 Algoritem REIN za izračun digitalnega modela reliefa

V okviru doktorske naloge smo razvili novo metodo, namenjeno izdelavi DMR v strmem reliefu (Kobler in sod. 2007), pokritem s heterogenim gozdom, ki povzroča veliko raznolikost v stopnji prodiranja in posledično v številu talnih odbojev na enoto površine. Na ravnem terenu z redkim gozdnim pokrovom, ki dovoljuje visoko stopnjo prodiranja in visoko gostoto talnih točk, so obstoječi algoritmi točni in učinkoviti. Njihovo delovanje pa postane manj zanesljivo na strmem terenu, pokritem s strnjenim gozdom. Za take okoliščine predlagamo dvostopenjsko metodo, ki jo lahko povzamemo takole:

1. V začetni stopnji filtriranja odstranimo vse negativne osamelce (outliers), torej točke pod nivojem tal, ter večino (ne pa nujno prav vse) odbojev nad tlemi. Slednje dosežemo z uporabo obstoječih algoritmov, na primer katerega iz skupine morfoloških filtrov.
2. V končni stopnji filtriranja in izračuna DMR slednjega izpeljemo iz delno filtriranih točk, ki so rezultat prve stopnje filtriranja. V ta namen predlagamo nov algoritem, ki lahko obdela delno filtriran oblak točk v strmem reliefu. Filter smo poimenovali REIN (REpetitive INterpolation), saj izkorišča več mogočih ocen nadmorske višine tal na posameznih točkah DMR v rastrski ali trikotniški mreži, interpoliranih iz okoliških talnih odbojev. Te ocene nadmorskih višin izračunamo iz mnogih neodvisnih vzorcev, izbranih iz začetno filtriranega oblaka točk. Trikotniško mrežo uporabljamo tudi za interpolacijo višin na točkah rastrske mreže DMR.

Začetna stopnja filtriranja je potrebna, saj z njo zadovoljimo dva potrebna pogoja za zanesljivo delovanje REIN. Prvi pogoj je, da v začetno filtriranem oblaku ne ostane noben negativni osamelec. Drugi pogoj je, da naj bo pred uporabo REIN iz oblaka točk odstranjena večina (ne pa tudi nujno vsi) odbojev od rastlinstva nad tlemi. Začetna stopnja filtriranja ima torej dva koraka.

V prvem koraku odstranimo negativne osamelce iz oblaka. Za vsako točko v oblaku izračunamo njegovo navpično razdaljo D glede na povprečno nadmorsko višino k najbližjih

sosednjih točk, pri čemer soseščino opazujemo v ravnini X–Y. Nato vse točke v oblaku rangiramo glede na *D* in iz oblaka odstranimo *P* točk, ki imajo največje negativne vrednosti *D*. *P* naj bo majhen, a vseeno dovolj velik, da zagotavlja odstranitev vseh motečih negativnih osamelcev, četudi za ceno odstranitve nekaterih »zdravih« talnih odbojev.

V drugem koraku začetnega filtriranja odstranimo večino rastlinskih odbojev. V našem primeru smo uporabili morfološki filter, ki temelji na največjem dovoljenem kotu med dvema sosednjima točkama. Začnemo z najnižjo točko in preiščemo vse točke v okolici, ki jo določa *k* najbližjih sosedov. Če kot presega dani prag, višjo od dveh točk odstranimo. Prag postavimo na rahlo višjo vrednost, kot je naklon najbolj strmega dela reliefa, ki ga obdelujemo. S tem preprečimo, da bi po nesreči izločili posamezne talne odboje v najbolj strmih delih reliefa. Po drugi strani pa nam v začetno filtriranem oblaku ostane več rastlinskih odbojev, s katerimi se potem ukvarjamo v končni fazi filtriranja in izračuna DMR.

Vhodni podatek za končno fazo filtriranja in izračuna DMR je torej delno filtriran oblak točk (angl. Filtered Point Cloud – FPC), ki pretežno vsebuje talne odboje znotraj pasu napak (angl. error band), nekaj pozitivnih osamelcev (odbojev od rastlinstva) in nobenega negativnega osamelca. Pas napak je pas (angl. buffer zone) vzdolž površine golih tal (Slika 6a) in je posledica napak lidarja pri merjenju razdalj, napak pri kotih skeniranja, napak georeferenciranja pa tudi posledica odbojev od trave in nizkih zelišč. Dodaten element, ki določa pas napak, so podrobnosti reliefa, ki so manjše od vzorčne napake lidarja, zato jih ta ne more zajeti. Zaradi visokega praga filtriranja (kota pri morfološkem filtriranju) nekaj pozitivnih osamelcev ostaja v FPC (Slika 6a). Ti osamelci bi povzročili napake v DMR, če bi slednjega izračunali neposredno iz FPC. Namesto tega DMR približamo tlom s pomočjo algoritma REIN.

Osnovna ideja algoritma REIN (Slika 6, pseudokoda v Preglednica 2) je v izkoriščanju preobilja točk v FPC, s čimer blažimo vpliv preostalih pozitivnih osamelcev na DMR. Točne nadmorske višine na tistih mestih v ravnini X–Y, kjer želimo oceniti prave nadmorske višine terena in jih vpisati v DMR (imenujemo jih lokacije DMR), lahko aproksimiramo z neodvisnimi ponavljajočimi se ocenami reliefa. Vsaka od teh ocen temelji na neodvisnem naključnem vzorcu (imenovanem FPC_s), ki ga vzamemo iz FPC. Pri vsaki ponovitvi uporabimo točke FPC_s kot vozlišča za gradnjo trikotniškega modela. Nadmorske višine na lokacijah DMR interpoliramo iz vsake od teh trikotniških mrež (Slika 6b). Namesto trikotniške mreže bi lahko uporabili katero koli prostorsko metodo interpolacije. Poudariti je treba tudi, da so lokacije DMR lahko v ravnini X–Y razporejene sistematično (kot na primer v rastrskem DMR) ali neenakomerno (kot v trikotniški mreži) ali celo na lokacijah, ki nas posebej zanimajo (ključne točke reliefa, lomi terena ipd.). Ko smo tako interpolacijo višin ponovili mnogokrat, na vsaki lokaciji DMR dobimo porazdelitev ocen višine terena. Iz teh porazdelitev lahko ocenimo pravo višino terena, če upoštevamo dve opažanji:

1. Spodnje meje porazdelitev so skoraj neobčutljive za pozitivne osamelce. Po drugi strani pa negativni osamelci na porazdelitve sploh nimajo učinka, ker smo jih prej popolnoma odstranili. To pomeni, da ležijo – v okviru primerljivega gozda in reliefa – spodnje meje porazdelitev bolj ali manj na konstantni navpični razdalji od dejanskega reliefa golih tal (Slika 6b, Slika 6c). S primerljivim gozdom in reliefom mislimo na omejeno variabilnost v sposobnosti prodiranja laserja do tal, kar omogoča bolj ali manj konsistentno učinkovitost filtriranja v začetni fazi postopka. S primerljivim reliefom mislimo na približno enako hrapavost (variabilnost višin pri določenem merilu opazovanja).

2. Če predpostavimo, da (a) stopnja vzorčenja FPC_s ni bila prenizka in (b) da je v FPC preostalo relativno malo pozitivnih osamelcev, potem večina mej porazdelitev sovpada s pasom napak. Predpostavka (a) implicira, da interpolacije reliefa le redko zgladijo ukrivljenost reliefa med vzorčnimi točkami, predpostavka (b) pa, da imajo le redke porazdelitve netipično zgornjo mejo (Slika 6c). Če še naprej predpostavljamo, da je širina pasu napak konstantna v okviru primerljivega gozda in reliefa, potem lahko ocenimo globalni srednji zamik *gmo* (*global mean offset*) med spodnjo mejo porazdelitev in resničnim reliefom golih tal. *Gmo* je enak povprečju razlik $d_{ij} = z_{ij} - z_{j,min}$ preko vseh lokacij DMR, kjer je z_{ij} i-ta ocena nadmorske višine na j-ti lokaciji DMR, $z_{j,min}$ pa je najnižja ocena nadmorske višine na j-ti lokaciji DMR.

Ko izračunamo *gmo* in vse $z_{j,min}$, znaša ocena dejanske nadmorske višine z_j na j-ti lokaciji DMR:

$$z_j = z_{j,min} + gmo \qquad (1)$$

V enačbi (1) je *gmo* količina, ki je izračunana iz vseh z_{ij} in je zato robustna, $z_{j,min}$ in posledično tudi z_j pa so količine za posamezno lokacijo DMR. Naj opozorimo, da bi preprosto jemanje naključnega vzorca iz razpoložljivih talnih točk ob vsaki ponovitvi REIN pripeljalo do trikotniških mrež, ki so preveč podrobne na območjih z visoko gostoto talnih točk ter preveč posplošene na območjih z nizko gostoto točk. Take neenakomernosti povzročajo raznolike stopnje prodiranja v raznolikih gozdovih ter neenakomerno razmaknjene linije skeniranja. Pomembno je torej, da je naključni vzorec pri vsaki ponovitvi v prostorskem smislu čim bolj nepristranski. To zagotovimo s postopkom izbire, kjer znotraj mej FPC ustvarimo najprej množico povsem naključnih lokacij v ravnini X–Y, ki je povsem neodvisna od morebitnih lokalnih zgostitev v FPC. Potem pa za vsako od teh naključnih lokacij poiščemo najbližjo točko v FPC. Na ta način dobijo razredčene točke v FPC, ki ležijo na primer pod tesnim sestojnim sklepom, večjo verjetnost, da bodo izbrane, kot pa bolj goste točke v redkejših sestojih, zaradi česar lahko REIN daje bolj konsistentne rezultate, ne glede na tesnost sestojnega sklepa.

Delovanje REIN usmerjata dva parametra – *samplesize* (število točk v vsakem FPC_s) in *numsamples* (število ponovitev). Oba vplivata na kvaliteto DMR, njun učinek pa bomo prikazali v poglavju 3.3.1.

Preglednica 2 podrobno definira algoritem REIN ter postopek izbire pri vzorčenju. Algoritem REIN smo zaradi lažjega programiranja imlementirali v objektno orientiranem jeziku Python. Za vse izračune na ravni rastrskih lokacij DMR smo uporabili Pythonovo učinkovito knjižnico Numarray, ki je namenjena hitremu numeričnemu računanju. Za triangulacijo vzorčnih točk smo uporabili obstoječo implementacijo Triangle (Shewchuk 2005). Obdelava zelo obsežnih baz lidarskih podatkov, kakršna je bila tudi naša, ne dovoljuje uporabe lidarskih podatkov v obliki navadnih seznamov, ampak terja uporabo neke metode prostorskega indeksiranja, ki naj pospeši iskanje posameznih točk v bazi glede na njihovo geografsko lokacijo. V naši implementaciji algoritma smo oblak točk shranili v podatkovno strukturo, namenjeno učinkovitemu indeksiranju točk, imenovano quadtree (Samet 1984). Metodo rangiranja razdalj (Hjaltason in Samet 1995) pa smo uporabili za iskanje *n* najbližjih sosednjih točk znotraj strukture quadtree. Tako v začetni fazi filtriranja kot tudi kasneje pri ponavljajočem se vzorčenju znotraj FPC sta se prostorsko indeksiranje in hitro iskanje točk izkazali kot bistven predpogoj za še sprejemljivo hitrost obdelave podatkov.

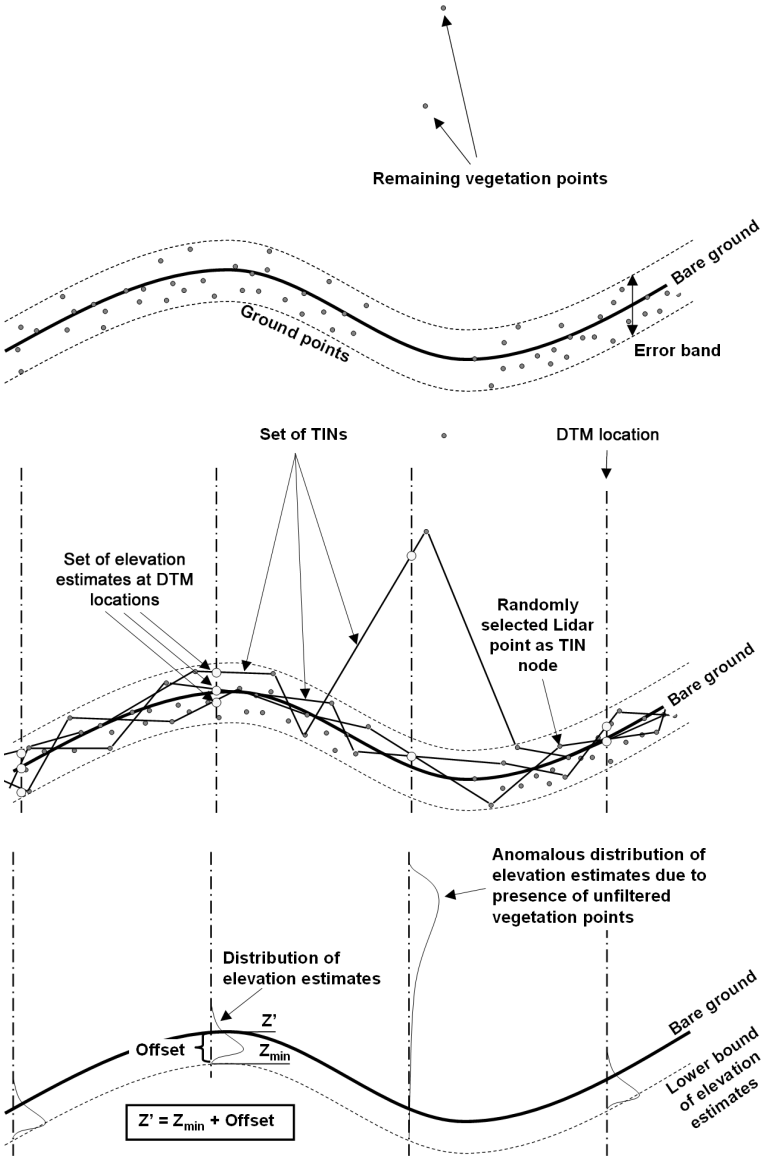

Slika 6: Prikaz algoritma REIN, ki ga uporabimo v končni stopnji filtriranja. (a) Rezultat začetnega filtriranja (z uporabo, na primer, morfološkega filtra) so talne točke s posameznimi preostalimi nefiltriranimi vegetacijskimi točkami in brez negativnih osamelcev. Opozarjamo na preobilje talnih točk znotraj pasu napak. Raztros točk znotraj pasu napak je posledica meritvenih napak, trave in nizkih zelišč. (b) Ponavljajoča se naključna vzorčenja lidarskih točk uporabimo za gradnjo trikotniških modelov TIN, iz katerih na lokacijah mreže DMR interpoliramo množice ocen nadmorske višine. Opozarjamo tudi na možnost, da preostale nefiltrirane vegetacijske točke lahko postanejo vozlišča TIN. (c) Nadmorske višine DMR aproksimiramo tako, da globalni srednji zamik prištejemo k spodnjim mejam porazdelitev nadmorskih višin. Spodnje meje porazdelitev so neodvisne od preostalih nefiltriranih vegetacijskih točk.
Figure 6: Illustration of the REIN algorithm used in the final stage of the filtering. (a) The result of the initial filtering stage (using, e.g., a slope threshold filter) are ground points with few remaining unfiltered vegetation points and no negative outliers. Note the redundancy of ground points within the error band. The scattering within the error band is caused by measurement errors, grass and low herbal vegetation. (b) Repeated random selections of lidar points are used to build a set of TINs, out of which sets of elevation estimates are interpolated at the locations of DTM grid points. Note that also the remaining unfiltered vegetation points may become TIN nodes. (c) DTM elevations are approximated by adding global mean offset to the lower bounds of elevation distributions, which are unaffected by the unfiltered vegetation points.

Preglednica 2: Pseudo koda algoritma REIN.
Table 2: Pseudo-code of the REIN algorithm.

```
# Inputs:
#       FPC - list of filtered (3-D) LiDAR points
#       DTMxy – list of points in the X-Y plane (2-D) we want to include in DTM
#       num_samples - number of iterations (samples)
#       sample_size - number of points in each sample
#
# Output:
#       DTM - digital terrain model providing elevation for each point in DTMxy
#
# Time complexity of the algorithm governed by performing Delaunay triangulation (DT)
# is O(num_samples * sample_size * log sample_size)

function ComputeDTM(FPC, DTMxy, num_samples, sample_size)

        # for each point in DTMxy...
        foreach (x,y) in DTMxy do
                EE[x,y] = empty list

        # ...   collect elevations estimated (EE) on different samples taken from FPC
        iteration = 1
        while iteration <= num_samples do
                FPCs = GetSample(FPC, sample_size)
                DT = GenerateDT(FPCs)
                foreach (x,y) in DTMxy do
                        Zest = ElevationDT(DT, (x,y))
                        append Zest to EE[x,y]
                iteration = iteration + 1

        # based on elevations calculate global mean offset (gmo)
        OS = empty list
        foreach (x,y) in DTMxy do
                offset = Mean(EE[x,y]) - Min(EE[x,y])
                append offset to OS
        gmo = Mean(OS)

        # using estimated elevations and gmo, calculate digital terrain model DTM
        DTM = empty list
        foreach (x,y) in DTMxy do
                z = Min(EE[x,y]) + gmo
                append (x, y, z) to DTM
        return DTM
```

(se nadaljuje)

(nadaljevanje)

```
# Inputs:
#       FPC - list of filtered LiDAR points
#       sample_size - number of points in each sample
#
#
# Output:
#       FSP - list of sample_size randomly selected points from FPC

function GetSample(FPC, sample_size)

        FSP = empty list
        while Length(FSP) < sample_size do
                (x,y) = random point uniformly distributed over X-Y projection of FPC
                find (x_S,y_S,z_S) in FPC that is closest to (x,y) in the X-Y plane
                if (x_S,y_S,z_S) not in FSP
                        append (x_S,y_S,z_S) to FSP
        return FSP


# Input:
#       P - list of points
#
# Output:
#       DT - Delaunay triangulation over the points in P

function GenerateDT(P)

#       implemented using the Triangle software package available at
#       http://www-2.cs.cmu.edu/~quake/triangle.html
        return DT
```

3.2.1 Vpliv gostote lidarskega oblaka na točnost digitalnega modela reliefa

REIN izkorišča preštevilnost točk v FPC, zato gostota oblaka točk vpliva na točnost DMR. Ta vpliv smo preučili na primeru testnega območja na Krasu.

Različne gostote lidarskega snemanja smo simulirali z zaporednim redčenjem gostote originalnega oblaka s faktorjem 2, kar je dalo faktorje redčenja 2, 4, in 8. Točke, ki naj ostanejo v razredčenem oblaku smo izbrali tako, da smo jih najprej sortirali glede na njihove GPS časovne znamke (natančen čas snemanja posamezne točke) in nato izbrali vsako drugo točko v vrsti. Ta postopek smo izvedli posebej za vsako vrsto točk. Gostote točk, ki smo jih dobili, prikazuje Preglednica 3. Za izračun DMR smo uporabili le zadnje in edine odboje. Njihovo skupno gostoto prikazuje zadnja vrstica preglednice.

Gostota točk [m^{-2}]		Faktor redčenja podatkov			
		1	2	4	8
Tip odboja	Prvi	5.15	2.58	1.29	0.64
	Vmesni	0.56	0.28	0.14	0.07
	Zadnji	7.64	3.82	1.91	0.96
	Edini	3.21	1.61	0.80	0.40
	Z + E	10.85	5.43	2.71	1.36

Preglednica 3: Gostote lidarskih točk, dobljene z redčenjem osnovnega oblaka. Začetno gostoto podaja prvi stolpec (faktor redčenja = 1). Skupne gostote, ki so bile uporabljene za izračun DMR (zadnji + edini odboji) so podane v spodnji vrstici.
Table 3: Lidar point densities obtained by thinning the basic dataset. The starting point density is given in the first column (thinning factor = 1). Total point densities used to calculate DEMs (last returns + only returns) are given in the bottom line.

DMR smo izračunali po metodi REIN za vsako gostoto oblaka posebej. Rastrska ločljivost izračunanega DMR je znašala 1 x 1 m, celoten raster je obsegal torej 400 stolpcev krat 250 vrstic. Uporabili smo naslednje vrednosti parametrov REIN:

- prag začetnega morfološkega filtriranja 60°, kar ustreza največjemu naklonu reliefa v testnem območju
- *numsamples* (število podvzorcev FPC_s) = 20
- *samplesize* (delež točk FPC v vsakokratnem vzorcu FPC_s) = 10 % zadnjih in edinih odbojev, kar znaša 1,09, 0,54, 0,27 in 0,14 m^{-2} – po vrsti za faktorje redčenja 1, 2, 4 in 8.

DMR smo označevali glede na faktor redčenja za DMR1 (izračunan iz nerazredčenih točk) in DMR2 do DMR8 (iz razredčenih točk). Točnost DMR, izračunanih iz razredčenih točk, smo ocenjevali s primerjavo z DMR1. Kot osnovo za ocenjevanje smo vzeli sliko razlik DMR1 – DMRx, iz nje izračunali nekaj statistik in jo ocenili tudi vizualno. Poleg tega smo vizualno ocenili tudi žične 3D-modele DMR.

3.3 Rezultati

V tem poglavju bomo opisali način izračuna DMR in metodo ocenili z več plati. Z vizualno analizo bomo preiskali morebitne očitne napake filtriranja ali artefakte algoritma ter primerjali rezultate z vizualno filtrirano podmnožico talnih odbojev, kot je opisano v poglavju 3.3.2. Poleg tega bomo rezultate REIN primerjali z rezultati morfološkega filtriranja. Na koncu bomo rezultate REIN primerjali tudi s terensko izmerjenimi talnimi točkami. Vsaka od teh primerjav poudarja določen vidik algoritma REIN. Najprej pa bomo opisali izbiro parametrov delovanja REIN.

3.3.1 Izbira parametrov delovanja REIN in vizualna analiza

Vsi rastrski DMR v tej analizi imajo horizontalno ločljivost 1 m. Optimalni vrednosti parametrov za izločanje negativnih osamelcev sta bila ugotovljeni eksperimentalno: $k = 10$ in $P = 0{,}2$ %. Povprečje vseh višinskih razlik točk v primerjavi z 10 najbližjimi sosedi znaša –0,1 m s standardnim odklonom ±7 m. Ekstremne vrednosti znašajo do 27 m (na obe strani), kar je precej več od povprečne višine dreves (18 m). Povprečna vertikalna razdalja 0,2 % izbranih točk do svojih 10 sosedov znaša 17,5 m, kar glede na višino dreves pomeni, da smo lahko z negativnimi osamelci odstranili tudi nekaj talnih točk.

Prag naklona za morfološki filter v začetni fazi postopka smo določili 70º, ker je to enako najbolj strmemu naklonu reliefa v testnem območju. Na ta način smo zagotovili, da ne izločamo pomotoma tudi talnih točk. Slika 7a kaže osnovni DMR, ki je rezultat morfološkega filtriranja s pragom 70º. Z morfološkim filtriranjem smo razredčili zadnje odboje, ki so bili osnova za izračun DMR, z 8,5 m^{-2} na 4,3 m^{-2}, kar je torej gostota po prvi (začetni) fazi postopka REIN. Osnovni DMR (Slika 7a) smo izračunali, tako da smo vse točke začetno filtriranega oblaka zadnjih odbojev uporabili za gradnjo trikotniške mreže, iz nje pa izračunali rastrski DMR. Srednja kvadratična napaka višine (RMSE) tega DMR glede na terensko izmerjene višinske točke znaša ±0,30 m. Če pa pogledamo sliko Slika 7a, je očitno, da rezultat ni zadovoljiv. V oblaku talnih točk so namreč ohranjene mnoge netalne (off-ground) točke, ki se odražajo kot majhne izbokline na senčenem reliefu. Primerjava z vizualno prepoznanimi talnimi točkami kaže RMSE ±0,13 m, kar je preveč optimistično, saj se v tej številki ne odraža vpliv artefaktov. Terensko izmerjene točke v nasprotju z vizualno klasificiranimi točkami ne ležijo v ozkih transektih, ampak so enakomerno razsejane po površini in zato kažejo višjo RMSE.

Zgoraj opisani začetno filtrirani oblak je identičen s FPC, ki smo ga v naslednji fazi uporabili v algoritmu REIN. Kakovost DMR je v drugi fazi postopka odvisna od vrednosti parametrov *samplesize* in *numsamples*. Kot kazalnik za kakovost DMR smo vzeli RMSE, izračunano na podlagi vizualno klasificiranih talnih točk. Vpliv obeh parametrov smo preučevali znotraj testnega območja: *samplesize* je imel vrednosti med 1000 in 10.000 v korakih po 1000, *numsamples* pa vrednosti 1, 2, …, 10 (Slika 7d-h). Ker REIN pri vsaki ponovitvi uporabi naključni vzorec iz FPC, je končni rezultat algoritma REIN pri vsakem zagonu malo drugačen. Zato smo REIN z vsakokratno kombinacijo dveh parametrov pognali 50-krat in iz tega izračunali povprečno RMSE, ločeno glede na vizualno klasificirane talne točke in glede na terensko izmerjene talne točke. Čeprav smo RMSE računali le za testno območje, smo

DMR izračunali za območje, razširjeno za 10 m na vsaki strani, da bi na ta način izločili robne učinke na ponavljajoče se interpolacije TIN.

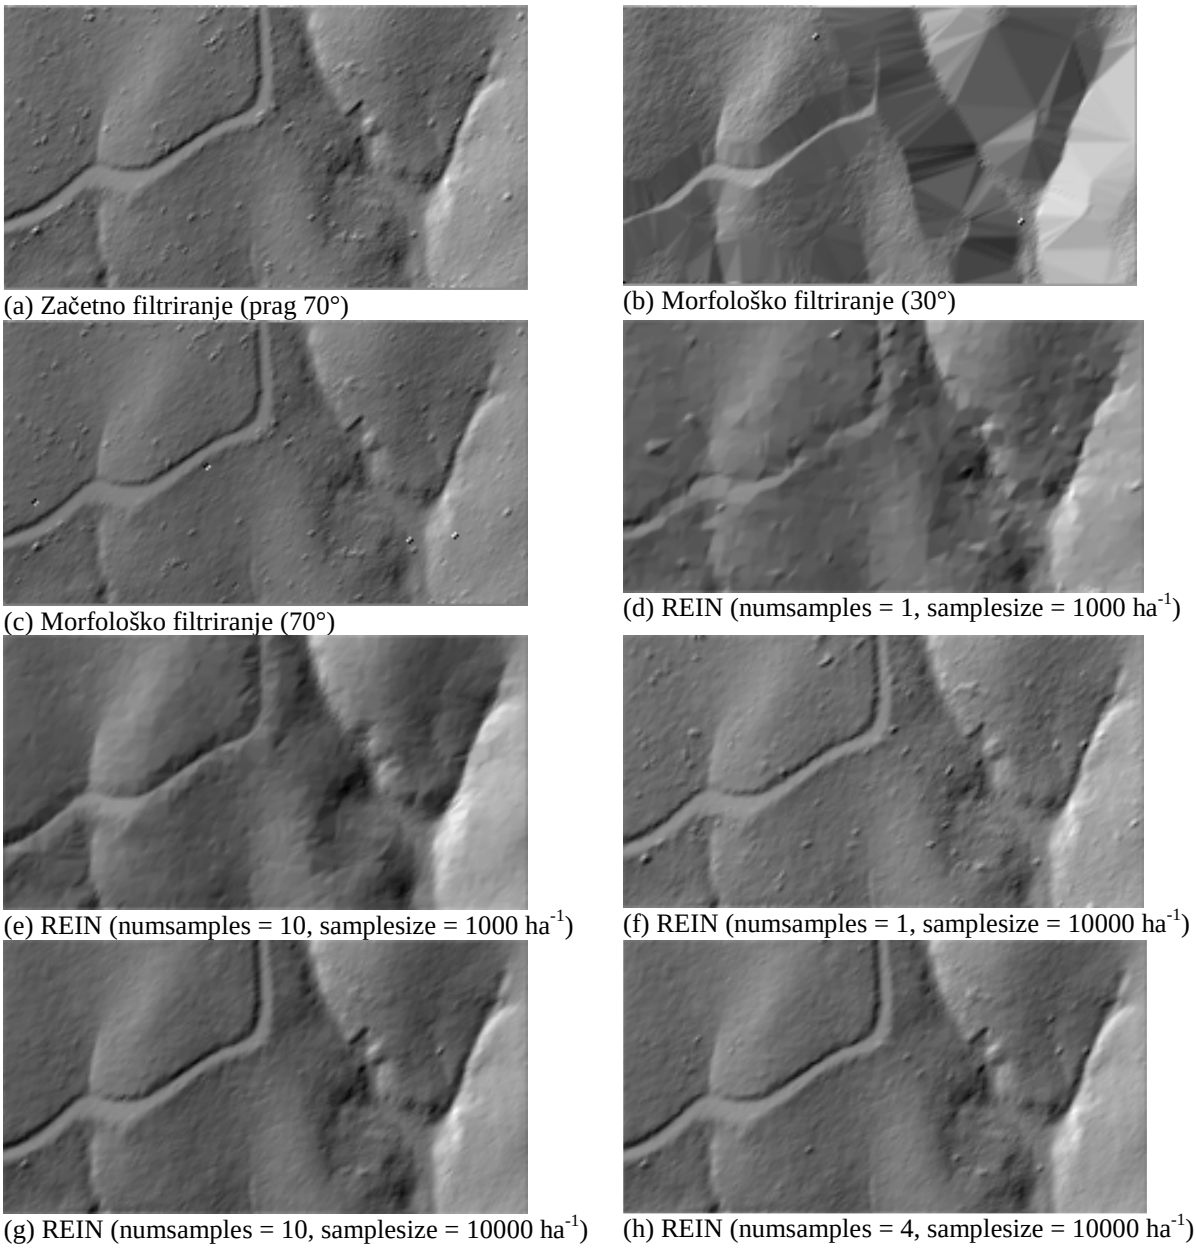

(a) Začetno filtriranje (prag 70°)
(b) Morfološko filtriranje (30°)
(c) Morfološko filtriranje (70°)
(d) REIN (numsamples = 1, samplesize = 1000 ha^{-1})
(e) REIN (numsamples = 10, samplesize = 1000 ha^{-1})
(f) REIN (numsamples = 1, samplesize = 10000 ha^{-1})
(g) REIN (numsamples = 10, samplesize = 10000 ha^{-1})
(h) REIN (numsamples = 4, samplesize = 10000 ha^{-1})

Slika 7: Primerjava senčenih reliefov začetno filtriranega osnovnega DMR (a), morfološko filtriranega DMR (b in c) ter rezultatov REIN filtriranja (d-h). Vsi DMR imajo horizontalno ločljivost 1 m. Opozarjamo na učinke ekstremnih vrednosti parametrov REIN: majhna vrednost numsamples povzroči generalizacijo reliefa (d, e), majhna vrednost samplesize pa vnese artefakte zaradi preostale nefiltrirane vegetacije (d, f). Velike vrednosti numsamples in samplesize povzročijo najmanj artefaktov (g), vendar pa visoka vrednost numsamples z zmerno vrednostjo samplesize (h) omogoči rahlo boljšo RMSE in skrajša čas računanja.

Figure 7: Comparison of the shaded relief images of the slope filtered baseline DEM (a), morphologicaly filtered DEM (b and c), and results of REIN filtering (d-h). All DEMs have 1 m by 1 m horizontal resolution. Note the effects of extreme values of REIN parameters: low numsamples values cause relief generalization (d, e) and low samplesize values cause artefacts due to remaining unfiltered vegetation (d, f). High numsamples and high samplesize values yield fewest artefacts (g), however high numsamples with moderate samplesize (h) yields marginally better RMSE and saves computation time.

Primerne vrednosti parametrov za REIN smo izbrali glede na vizualno klasificirane talne točke (N = 563). Ta izbira je upoštevala zgolj točnost filtriranja, ne pa tudi šum zaradi merjenja različnih komponent letalskega skeniranja. Predvsem napake georeferenciranja laserskega oblaka točk v tem primeru niso mogle motiti ocene točnosti filtriranja.

Iz 50 DMR, pridobljenih za vsako kombinacijo parametrov z REIN, smo izračunali povprečne vrednosti RMSE glede na vizualno določene talne točke. Te znašajo med ±0,16 in ±0,37 m (Slika 8a). Standardni odklon 50 vrednosti RMSE leži med ±3 in ±90 mm (Slika 8b). Slika 8a kaže, da povečevanje *samplesize* izboljša povprečno RMSE, predvsem pri nizkih vrednostih *samplesize*. Najmanjšo vrednost RMSE ±16 cm smo dosegli s *samplesize* 10.000 ha^{-1}, iz česar lahko izračunamo stopnjo vzorčenja začetnega FPC, ki je znašala 23 %. Odvisno od *samplesize* potrebuje REIN le 3 do 5 ponovitev (parameter *numsamples*) za optimalno vrednost RMSE. Nadaljnje ponovitve dajo bolj gladek DMR z manj artefaktov, ki so posledica nefiltriranega rastlinstva, vendar pa ob tem začne RMSE spet rahlo naraščati (Slika 7g in h).

Slika 7 kaže filtrirni učinek REIN v primerjavi z osnovnim DMR in z morfološko filtriranim DMR. Visoka raven šuma v osnovnem DMR (Slika 7a) in v morfološko filtriranem DMR (Slika 7c) je posledica netalnih (off-ground) točk, ki so ostale v FPC zaradi visokega praga kota filtriranja. REIN z zelo nizko vrednostjo *samplesize* na slikah Slika 7d in Slika 7e (1000 ha^{-1}, kar ustreza stopnji vzorčenja 2%) je odstranil vse artefakte, vidne na osnobnem DMR (Slika 7a), vendar pa je zagrešil pretirano posplošitev (generalizacijo) značilnosti reliefa. Na drugi strani pa je REIN z visoko vrednostjo *samplesize*=10000 ha^{-1} (Slika 7g) odstranil večino artefaktov in hkrati obdržal podrobnosti reliefa, kar se vidi iz lomnih črt soteske in cestnih brežin. Glede na dosežene vrednosti RMSE in glede na vizualno oceno je vrednost *numsamples*=4, ki je bila uporabljena na Slika 7h optimalna (Slika 8a) v danem testnem območju. Nizka vrednost *numsamples* pa nakazuje, da je kjub iterativni naravi REIN hitro računanje vseeno mogoče. Po drugi strani lahko zaradi slučajnostne narave REIN pričakujemo večje fluktuacije kvalitete DMR. Slika 8b to potrjuje z višjim standardnim odklonom RMSE pri vrednostih *numsamples* 4 in manj ter pri vrednostih *samplesize* 4000 ha^{-1} in manj. Za testno območje to vodi do sklepa, da sta optimalni vrednosti parametrov *numsamples* = 4 in *samplesize* = 10000 ha^{-1}. Vendar pa lahko skoraj optimalno RMSE dosežemo tudi že s 7000 točkami na hektar in 3 ponovitvami. V operativni praksi bi bili verjetno primerni vrednosti za *samplesize* med 4000 in 10000 ha^{-1}, odvisno od zaželenega kompromisa med kakovostjo DMR in stroški računanja.

Analiza na podlagi terensko izmerjenih talnih točk kaže podobne rezultate, le da je povprečna RMSE za približno 50% višja. Analiza v testnem območju ni pokazala nobenega vpliva naklona reliefa in sestojnega sklepa na povprečno RMSE.

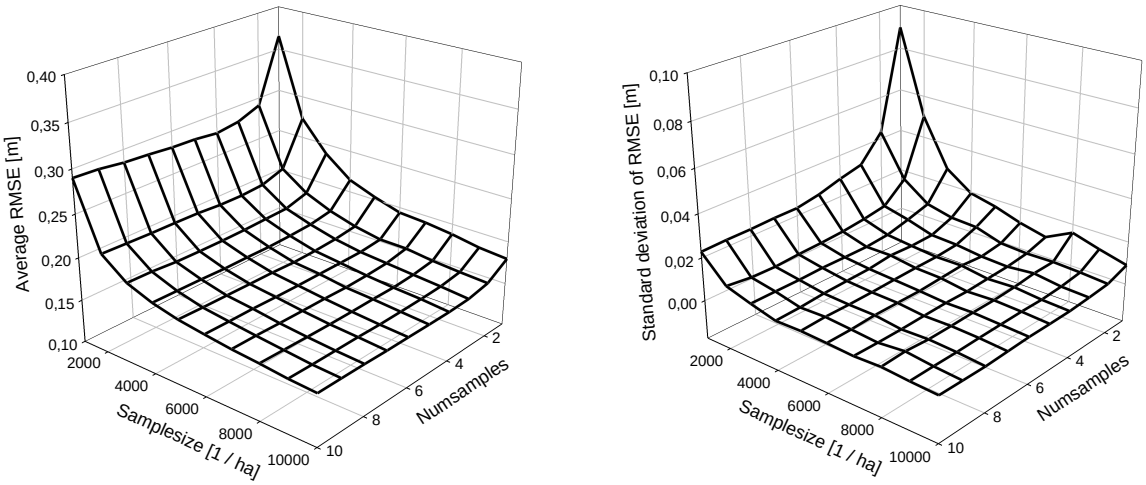

(a) Povprečna RMSE (b) Standardni odklon RMSE

Slika 8: (a) Vpliv parametrov REIN numsamples in samplesize na kakovost DMR, ocenjeno z RMSE. Povprečno RMSE smo izračunali iz 50 ponovitev REIN za vsako kombinacijo vrednosti parametrov. (b) Stabilnost rezultatov REIN, ocenjeno s standardnim odklonom RMSE iz 50 ponovitev REIN za vsako kombinacijo vrednosti parametrov.
Figure 8: (a) Influence of the REIN parameters numsamples and samplesize on the quality of the DTM according to the average RMSE. The average RMSE was obtained by averaging RMSE values of 50 runs of REIN for each parameter combination. (b) Stability of REIN results as indicated by the standard deviation of RMSE based on 50 runs of REIN for each parameter combination.

3.3.2 Primerjava z morfološkim filtriranjem

REIN smo primerjali z morfološkim filtriranjem, kot ga opisuje Vosselman (2000). Jedro filtra (angl. filter kernel) smo določili s konstantnim zamikom ±53cm, pri čemer smo upoštevali vertikalno napako merjenja višinske razlike med dvema točkama ter dovoljene naklone med talnimi točkami od 30 do 70° s koraki po 10°. Ti nakloni pokrivajo interval od povprečnega do ekstremnega naklona v testnem območju. Radij filtra smo postavili na 10 m. Filtrirane oblake točk smo triangulirali in izračunali rastrske DMR. Preglednica 4 predstavlja vrednosti RMSE glede na vizualno filtrirane talne točke in glede na terensko izmerjene talne točke. Število morfološko prepoznanih talnih točk močno narašča s kotom filtriranja, kajti pri nizkih kotih filtriranja mnoge talne točke nepravilno odstranimo kot vegetacijske točke. Površine z večjim naklonom so pravzaprav odsekane in nadomeščene z velikimi površinami trikotniške mreže (Slika 7b), kar tudi pojasnjuje negativne razlike (residuals) pri nizkih kotih filtriranja. Ta artefakt izgine pri 70° (Slika 7c), vendar pa so vegetacijske točke še vedno v filtriranem oblaku. Tak rezultat je pričakovan, saj je morfološki filter namenjen splošni uporabi, REIN pa je posebej namenjen gozdnatim območjem, ne pa na primer pozidanim območjem. Večje vrednosti RMSE glede na vizualno določene talne točke so posledice delnega sovpadanja transektov z lomnimi črtami reliefa.

Preglednica 4: Vrednosti RMSE v metrih za morfološko filtriranje. Vrednosti za REIN (pri samplesize = 10000 in numsamples = 4) so podane za primerjavo. Število talnih točk pri REIN ustreza številu pri začetnem filtriranju oblaka.
Table 4: RMSE values for the filtering with the morphological filtering. The values for REIN (at samplesize = 10000 and numsamples = 4) are shown for comparison. The number of ground points for REIN corresponds to the initially filtered point cloud.

Prag filtriranja	RMSE [m] glede na vizualno filtrirane talne točke	RMSE [m] glede na terensko izmerjene talne točke	Povprečni ostanki [m] glede na terensko izmerjene talne točke	Število talnih točk na hektar
30°	1.209	1.639	-0.885	12970
40°	4.416	0.770	-0.196	28506
50°	5.857	0.411	0.080	35708
60°	3.318	0.305	0.196	38455
70°	3.239	0.315	0.217	39208
70° + REIN	0.158	0.248	0.215	40581

3.3.3 Ocena REIN glede na terensko izmerjene talne točke

Skupno delovanje algoritma REIN in danih podatkov smo preverili s primerjavo DMR s talnimi točkami, izmerjenimi na terenu s totalno postajo (Preglednica 4). Preglednica 4 prikazuje rezultate, dobljene z optimalnimi vrednostmi REIN parametrov, prikazanimi v poglavju 3.3.1, torej je vsak vzorec velikosti 10000 točk na hektar, uporabimo pa 4 ponovitve. RMSE za REIN znaša ±25 cm za terensko določene talne točke in ±16 cm za vizualno določene talne točke. Srednja vrednost razlik glede na terensko določene talne točke znaša +22 cm, kar nakazuje, da laserske točke na splošno ležijo višje kot tahimetrično izmerjene talne točke. To opažanje potrjuje tudi analiza rezuzltatov morfološkega filtriranja (Preglednica 4, stolpec Razlike glede na terensko izmerjene talne točke).

Mogoča razlaga za zamik algoritma REIN bi lahko bila prevelika vrednost *gmo*, vendar podoben zamik opažamo tudi pri rezultatih morfološkega filtriranja, zato tako razlago izključujemo. Tudi morebitno pretirano odstranjevanje negativnih osamelcev ne more pojasniti tega zamika, saj ležijo osamelci, odstranjeni iz testnega območja, od 91 do 45 cm pod DMR.

Zamik lahko razložimo z značilnostmi laserskega skenerja. Pri strmem terenu je mogoč sistematičen zamik laserskih točk navzgor, kar je posledica dejstva, da del odtisa laserja zaradi nagnjenosti terena pade na višji teren, algoritmi zaznavanja odbojev v lidarju pa dajejo prednost naraščajočemu delu vračajoče se krivulje laserskega odboja, ki prihaja iz višjega dela odtisa (angl. footprint). Poleg tega je treba upoštevati tudi vpliv zeliščne vegetacije, ki navidezno prestavlja talni odboj še nekaj cm višje. Ni mogoče izključiti tudi napake georeferenciranja laserskih točk, ki pa ni nujna za razlago zamika.

3.3.4 Vpliv gostote lidarskega oblaka na točnost digitalnega modela reliefa po metodi REIN

Če za osnovo analize vzamemo razlike med DMR1 (to je DMR, ki temelji na nerazredčenih točkah) in »razredčenimi« DMR, vidimo učinke redčenja točk na Sliki 9, Preglednica 5 pa podaja pripadajoče statistične povzetke. Slika 9 in Slika 10 kažeta, da so višinske napake zaradi redčenja točk največje na ostrih lomih reliefa ter na mestih izrazitega mikroreliefa, na primer na nizkih kraških zidovih na mejah parcel, skalnih izrastkih, terasah ali izrazitih depresijah. Standardna napaka »razredčenih« DMR glede na DMR1 tako linearno narašča od 11 cm pri DMR2 do 17 cm pri DMR8 (Preglednica 5). Linearno se povečuje tudi povprečna razlika od 2 cm za DMR2 do 5 cm za DMR8, razredčeni DMR ležijo torej v povprečju nekaj cm pod referenčnim DMR1. Vzrok je v bolj pristranski oceni *gmo*, ki je posledica nižje gostote vzorcev. Vizualna ocena žičnih 3D-modelov DMR nakazuje, da je uporabljena ločljivost 1 x 1 m primerna za višje gostote točk, z upadanjem vhodne gostote lidarskih točk pa postaja bolj smiselna uporaba nižje ločljivosti, saj razredčeni DMR vse bolj zabrisujejo posebnosti mikroreliefa, ki so v horizontalni ravnini manjše od nekaj metrov. Deloma gre to pripisati tudi naši odločitvi za zelo agresivno filtriranje (parameter *numsamples* = 20, stopnja vzorčenja 10 %, kar je linearno povezano z vrednostjo parametra *samplesize*, ki torej znaša 10850, 5430, 2710 in 1360 ha^{-2}, po vrsti za faktorje redčenja 1, 2, 4 in 8), da bi zagotovo izločili vse napake DMR zaradi vegetacijskih odbojev.

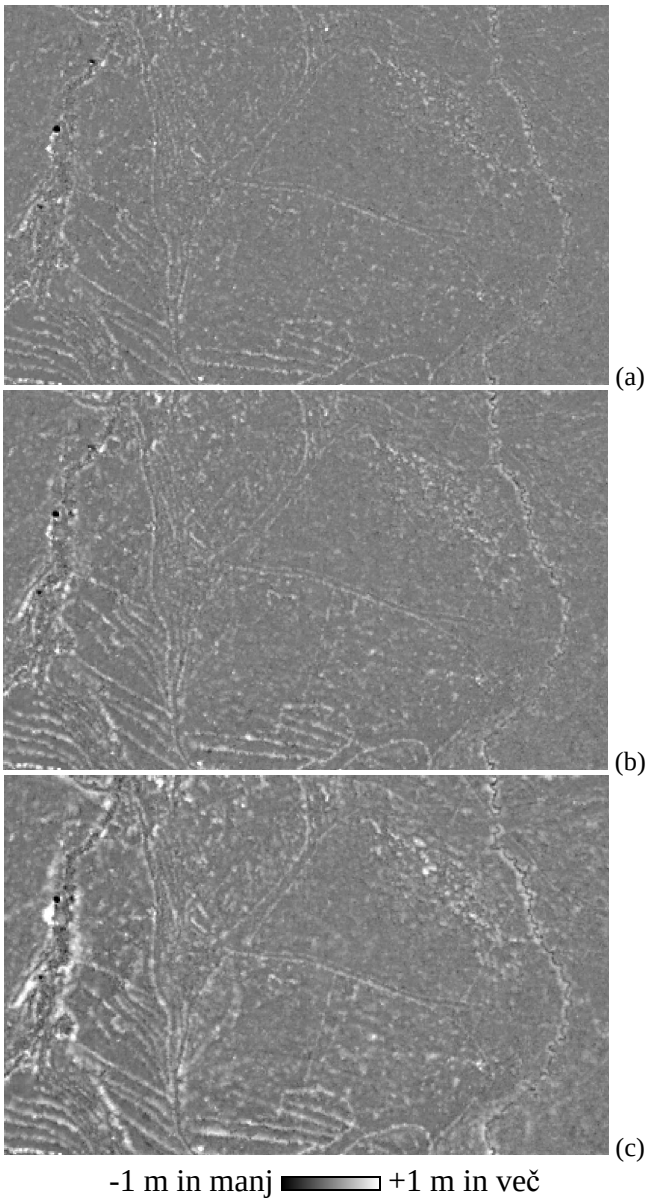

Slika 9: Razlike nadmorskih višin zaradi redčenja podatkov: (a) DMR1 – DMR2, (b) DMR1 – DMR4, (c) DMR1 – DMR8. Razlike so največje na ostrih lomnih črtah in pri izraženem mikroreliefu (na primer nizki kraški zidovi, skalni izdanki, terase).
Figure 9: The elevation difference images due to data thinning: (a) DEM1 – DEM2, (b) DEM1 – DEM4, (c) DEM1 – DEM8. The differences are the greatest at sharp break-lines and at locations of pronounced micro-relief, e.g., low manmade walls, rock outcrops, or terraces.

Preglednica 5: Statistika razlik DMR1 – DMRx (x je faktor redčenja) na Slika 9.
Table 5: The statistics for the difference images DEM1 – DEMx (x is the thinning factor) shown in Figure 9

[m]	x = 2	x = 4	x = 8
Najmanjša napaka	-2.34	-2.07	-1.98
Največja napaka	1.92	1.85	2.87
Sistematična napaka	0.02	0.03	0.05
Standardna napaka	0.11	0.13	0.17

.

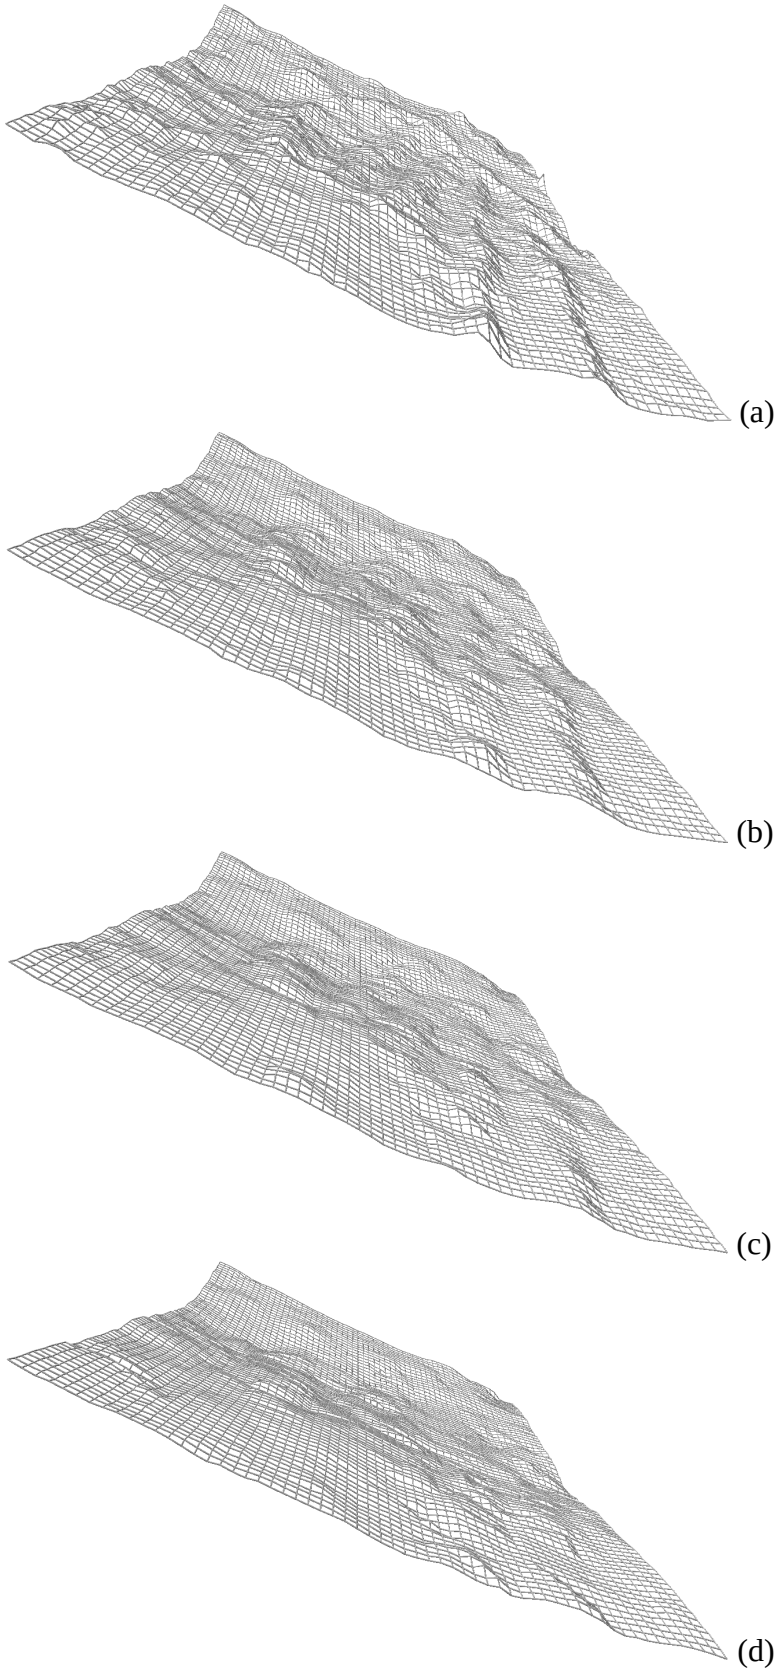

Slika 10: Žični prikaz DMR, izsek na Slika 2c, pogled iz zahoda. (a) DMR1, (b) DMR2, (c) DMR4, (e) DMR8. Mere izseka so 80 m krat 60 m. Raster vseh mrež je 1 m.
Figure 10: The wireframe DEM rendering of the DEM subset indicated in Figure 2, as seen from the west. (a) DEM1, (b) DEM2, (c) DEM4, (d) DEM8. The subset area is 80 m by 60 m. All wireframes are shown using 1 m raster.

3.4 Razprava in ugotovitve

Predstavili smo metodo ponavljajoče se interpolacije REIN za izračun DMR iz oblaka lidarskih točk. Metoda je posebej namenjena uporabi v strmem gozdnatem reliefu, kjer imajo drugi algoritmi tipično težave z razlikovanjem med talnimi in netalnimi (vegetacijskimi) odboji. REIN uporabimo v okviru dvostopenjske metode, kjer v prvi fazi izvedemo začetno filtriranje, ki odstrani vse negativne in večino pozitivnih osamelcev s pomočjo nekega poznanega algoritma, na primer morfološkega filtra. Ključna zamisel REIN je v tem, da izkoristimo preštevilnost talnih točk v začetno filtriranem oblaku točk FPC za blaženje vpliva preostalih netalnih odbojev v FPC. Iz FPC nekajkrat izberemo neodvisen naključen vzorec, pri čemer ima vsak del prostora, ki ga obdelujemo, enako verjetnost, da bo iz njega izbrana kakšna lidarska točka, ne glede na lokalne razlike v gostoti lidarskih točk. Iz vsakega vzorca posebej ocenimo nadmorske višine na lokacijah DMR in pri tem lahko uporabimo poljubno metodo prostorske interpolacije, v našem primeru triangulacijo. Tako na vsaki lokaciji DMR dobimo porazdelitev ocen nadmorske višine. Ker so spodnje meje porazdelitev skoraj neobčutljive za pozitivne osamelce, vse negativne pa smo izločili že v prvi fazi postopka, lahko prave nadmorske višine tal na lokacijah DMR približno ocenimo tako, da spodnjim mejam porazdelitev prištejemo globalno veljaven višinski zamik *gmo*. Če predpostavimo, da je v FPC ostalo malo pozitivnih osamelcev, potem *gmo* lahko ocenimo kot globalno povprečje vseh zamikov ocen nadmorskih višin glede na pripadajoče spodnje meje porazdelitev.

Delovanje REIN smo preizkusili v testnem območju Litija, ki ga označuje razgiban in strm relief in je pokrito z gostim mešanim gozdom. Analizirali smo vpliv velikosti vzorca ter števila ponovitev na DMR. RMSE nadmorskih višin je znašala od ±0,16 do ±0,37 m, odvisno od velikosti in števila vzorcev. Najmanjšo napako ±0,16 m smo dosegli s 4 vzorci in stopnjo vzorčenja 23 %.

REIN sicer uporablja naključno vzorčenje, vendar poskrbi, da ima vsak del analiziranega območja enako možnost biti izbran v vzorec, ne glede na lokalno gostoto lidarskih točk. Ta lastnost zagotavlja homogen DMR tudi pri nehomogenih vhodnih podatkih. REIN v svoji začetni fazi rešuje tudi problem negativnih osamelcev, ki so rezultat mnogokratnih odbojev. Naključno vzorčenje je lastnost, po kateri se REIN razlikuje od vseh znanih algoritmov filtriranja letalsko skeniranih lidarskih podatkov. Ostali algoritmi se obnašajo deterministično in v posebnih okoliščinah vedno zagrešijo enako napako. Zaradi elementa naključnosti REIN ne zagreši enake napake pri vsaki ponovitvi vzorčenja oziroma se napake posameznih ponovitev tipično med seboj izničijo pri končnem izračunu nadmorskih višin DMR. REIN ima zato večjo zmožnost prilagajanja raznolikim razmeram v strmem gozdnatem terenu.

Nadmorske višine v končnem DMR niso sistematično podcenjene, saj najnižji oceni nadmorske višine na vsaki lokaciji DMR prištejemo globalno veljaven navpični zamik.

REIN uporabi več neodvisnih naključnih vzorcev točk iz FPC za izračun DMR, kar pomeni, da si pomaga s preštevilnostjo talnih odbojev pri filtriranju vegetacijskih odbojev. Z zmanjševanjem gostote talnih odbojev se zmanjšuje tudi velikost teh naključnih vzorcev, kar prizadene tako podrobnost kot tudi točnost izračunanega DMR. Z redčenjem vhodne gostote lidarskih točk se povečujejo višinske napake na ostrih lomih reliefa ter na mestih izrazitega mikroreliefa, kot so na primer nizki kraški zidovi na mejah parcel, skalni izrastki, terase ali izrazite depresije. Tako standardna napaka višin kot tudi povprečna napaka višin linearno

naraščata z redčenjem lidarskih točk. Vzrok je v bolj pristranski oceni *gmo,* ki je posledica nižje gostote vzorcev. Vizualna ocena žičnih 3D-modelov reliefa kaže na progresivno izgubo mikroreliefnih detajlov, zato je pri nižjih gostotah točk smiselno računati DMR pri nižji ločljivosti; s tem skrajšamo čas računanja in hkrati zmanjšamo potrebe po diskovnem prostoru za vmesne in končne rezultate REIN.

REIN ne vsiljuje določene podatkovne strukture DMR, saj lahko izračunamo nadmorske višine tako za rastrski DMR z lokacijami v sistematični mreži kot tudi za poljubno nepravilno mrežo točk, kot je na primer trikotniška mreža. Glede lomnih črt reliefa se REIN obnaša podobno kot drugi algoritmi, torej povzroči rahle zaokrožitve DMR vzdolž lomnih črt. Lomne črte je zato treba izločati v ločenem postopku in jih shranjevati posebej.

REIN izračuna končni rezultat iz mnogih neodvisnih vzorcev, zato je mogoče uporabiti paralelno računanje in s tem čas računanja občutno skrajšati.

4 Modelno napovedovanje sestojne temeljnice, drevesne sestave gozda in svetlobnih razmer v gozdu iz lidarskih podatkov in letalskih fotografij

V tem poglavju bomo predstavili drugi sklop naloge, katerega cilj je primerjalno testirati različne metode modelnega napovedovanja sestojne temeljnice[1], drevesne sestave gozda ter svetlobnih razmer v gozdu iz lidarsko zaznanih vertikalnih profilov vegetacije nad tlemi in hkrati posnetih letalskih ortofotografij ter nazadnje uporabiti te informacije za razmejevanje in povzemanje lastnosti gozdnih sestojev. Poglejmo si najprej razvoj tovrstnih raziskav in osnovne opredelitve.

4.1 Pregled stanja in opredelitev problema

Prvo gozdarsko uporabo lidarja zasledimo v zgodnjih osemdesetih letih prejšnjega stoletja, ko so v Kanadi uporabili profilni lidar za oceno sestojnih višin, sestojnega sklepa in nadmorske višine tal pod gozdnim pokrovom (Aldred in Bonner 1985). V istem obdobju so lidar uporabili za kartiranje tropskega gozda v Srednji Ameriki (Arp in sod. 1982), Krabill in sod. (1980) pa so pokazali, da rezultati lidarskega in fotogrametričnega snemanja sovpadajo za 12 do 27 cm zunaj gozda in za 50 cm v gozdu. Uporaba lidarja v operativni gozdarski praksi se je v svetu postopoma začela krepiti pred kakim desetletjem (Lim in sod. 2008). Podatki lidarja se danes uporabljajo predvsem pri ocenjevanju osnovnih strukturnih značilnosti, kot so višina dreves in sestojev, sklep krošenj in vertikalna struktura gozda, posredno pa za ocenjevanje temeljnice, lesne zaloge in biomase gozda (Lefsky in sod. 2005, Tickle in sod. 2006, Goodwin in sod. 2006, Brandtberg 2007, Popescu in Zhao 2008).

Hitrejši prodor lidarja v gozdarsko prakso so do nedavnega preprečevali trije glavni razlogi: visoki stroški, kompleksnost obdelave podatkov ter omejene možnosti lidarja, da zagotovi povsem enake vrste informacij kot tradicionalna gozdna inventura (Suarez in sod. 2005). Vseeno Næsset in sod. (2004) ter Nelson in sod. (2007) opažajo, da narašča število gozdarskih organizacij, predvsem v Skandinaviji in Severni Ameriki, ki uporabljajo lidarske podatke za merjenje strukture gozdov in za gospodarjenje z gozdovi. Poleg tega uporabnost lidarja povečuje tudi njegova primernost za meritve, ki s tradicionalnimi metodami sploh niso mogoče, kot na primer podrobno kartiranje reliefa pod gozdom in monitoring posebnih gozdnih ekosistemov, kot so obrečni in močvirni gozovi ter drugi posebni gozdni habitati (Lucas in sod. 2008).

[1] Sestojna temeljnica (G) je značilnost sestoja in je po Čoklu (1977) pogosto potrebna za ugotavljanje lesne zaloge sestoja po Bitterlichovi metodi, srednjega premera dreves, zarasti sestoja in izkoriščenosti rastnega prostora (izkoriščenosti potenciala rastišča). Čokl jo definira kot vsoto temeljnic (površin presekov posameznih debel na prsni višini 1,3 m od tal) individualnih dreves. Sestojno temeljnico navadno podajamo v m2/ha (GHA), merimo jo z merjenjem premerov vseh dreves, najpogosteje pa jo ocenjujemo po Bitterlichovi metodi (razložena je v poglavju 4.2.1.1).

Danes je glavna prednost daljinskega lidarskega zaznavanja (tako iz zraka kot iz vesolja) v primerjavi s tradicionalnimi terestričnimi inventurami hitro zbiranje podatkov o gozdu in drevesih na velikih površinah (Lovell in sod. 2005). S prostorsko zveznim kartiranjem lahko prepoznamo območja problematičnega razvoja gozda, ki bi jih inventura na podlagi stalne vzorčne mreže prezrla (Donoghue in sod. 2007). Letalski lidar je v primerjavi s satelitskim trenutno bolj uporaben za gozdne inventure. Razloga za to sta njegov manjši talni odtis, s čimer točno zaznava tudi manjše objekte, ter prostorsko nezvezno vzorčenje prostora pri satelitskem lidarju. V primerjavi s pasivnimi tehnikami daljinskega zaznavanja je prednost lidarja njegova sposobnost neposrednega ocenjevanja/merjenja strukturnih značilnosti gozda, s čimer se lidar najbolj približa nekaterim klasičnim metrikam iz terestrične gozdne inventure (van Leeuwen in sod. 2010). Lefsky in sod. (2001) so strukturne značilnosti gozda, ocenjene z lidarjem SLICER, primerjali s podatki, izpeljanimi iz multispektralnih podatkov satelita Landsat TM in AVIRIS letalskega multispektralnega skenerja, in ugotovili, da lidar presega multispektralne senzorje pri oceni temeljnice, biomase ter prsnega premera, višine in števila dreves.

Lidarske podatke je mogoče tudi integrirati z drugimi podatki daljinskega zaznavanja, kar sinergistično poveča uporabnost obojih. S kombinacijo lidarskih podatkov in podatkov optičnih multispektralnih ali hiperspektralnih senzorjev ali radarskih senzorjev je na primer mogoče oceniti strukturo in vrstno sestavo gozda (Hyde in sod. 2005, 2006, Chen in sod. 2007, Nelson in sod. 2007). Zgodnje študije lidarja v gozdarstvu so se osredotočale na statistično izdelavo linearnih napovedovalnih modelov, ki povezujejo podatke profilnega lidarja s terestričnimi meritvami (Nelson in sod. 1984). Z razvojem lidarske tehnologije (dodatek skenerja, gostejši oblaki točk, več odbojev iz enega pulza) središče zanimanja ostaja isto, pri čemer si avtorji obetajo večjo točnost rezultatov ter natančnejšo odslikavo sestave in strukture gozda.

Sestava in struktura gozda določata njegovo funkcioniranje, torej vrsto in potek procesov v njem ter interakcije z živim in neživim okoljem (Franklin in sod. 1981). Sestavo gozda lahko definiramo kot združbo živih in neživih organizmov, ki ga sestavljajo. Pogosto jo kvantificiramo z deleži posameznih vrst. Strukturo gozda definiramo kot fizično in vizualno očitno razporeditev njegovih elementov, na primer drevesne višine ali svetlobnih razmer v gozdnem sestoju (Stone in sod. 1998). Oliver in Larson (1990) ter podobno tudi Franklin in sod. (1981) opredeljujejo strukturo gozda kot prostorsko in časovno porazdelitev dreves, pri čemer v definicijo vključujejo porazdelitev drevesnih vrst, vertikalne in horizontalne prostorske vzorce. Vse te značilnosti gozda agregirajo na neki višji prostorski ravni od posameznega drevesa – na ravni gozdnega sestoja. Gozdni sestoj lahko opredelimo kot skupino gozdnih dreves na določeni zaokroženi površini, ki je dovolj homogena v smislu vrstne sestave, starosti, strukture, lastnosti rastišča in siceršnjega stanja, da jo je mogoče razlikovati od sosednjih delov gozda. Večina značilnosti gozdnih sestojev tradicionalno temelji na tem, kar lahko merimo s tal, na primer višina ali prsni premer dreves. Zaradi zamudnosti postopkov se terestrične meritve izvajajo le na posameznih točkah znotraj sestoja (za opis sestojev) ali na sistematičnih mrežah stalnih vzorčnih ploskev (v okviru velikopovršinskih gozdnih inventur). Tradicionalne terestrične meritve nimajo zvezne ploskovne veljavnosti brez neke navezave na terenu neposredno merjenih ciljnih spremenljivk na neki velikoprostorski vir daljinsko zaznanih podatkov kot osnovo pojasnjevalnih spremenljivk, kar potem omogoči ploskovno ekstrapolacijo (Chen in sod. 2007, Wulder in sod. 2007, Lee in Lucas 2007). Letalski posnetki so tradicionalen vir velikoprostorskih daljinsko zaznanih 2D-podatkov o barvah, teksturah in oblikah objektov. Lidarski podatki s svojo 3D-upodobitvijo objektov odpirajo povzem nove možnosti modelnega napovedovanja

in velikoprostorskega kartiranja strukture in sestave gozda. Zgodnejše lidarske študije gozdov so se osredotočale na ocenjevanje enostavnejših značilnosti strukture gozda, predvsem na podlagi podatkov višin iz DMK (Lucas in sod. 2008), novejše študije pa se ukvarjajo tudi s prsnim premerom dreves, temeljnico, lesno zalogo, biomaso in drevesnimi vrstami (Hudak in sod. 2008, Næsset in Gobakken 2008). Hkratna uporaba lidarskih 3D-podatkov ter letalskih 2D-podatkov (ali visokoločljivih satelitskih multispektralnih podatkov, kot sta Ikonos ali QuickBird) zaradi njihove medsebojne komplementarnosti še izboljša lidarski opis gozdov (Holmgren in sod. 2008). V zadnjem času je to pripeljalo do rutinske souporabe optičnih in lidarskih senzorjev na isti platformi (Lucas in sod. 2008). Iz tovrstnih združenih podatkov so v borealnem gozdu, ki se odlikuje z jasno definiranimi krošnjami, na koregistriranih lidarskih podatkih in aeroposnetkih uspeli prepoznati, locirati in šteti vrhove dreves (na primer z metodo sledenja dolinam, Bunting in Lucas 2006), ocenjevati gostoto sestojev ter s primerjavo lidarskega DMR golih tal in iz arhivskih stereoparov letalskih posnetkov izdelanega DMK celo izvesti retrospektivno analizo teh vrednosti (St-Onge in sod. 2008). Pri odprtih sestojih ali v sadovnjakih, ne pa tudi v strnjenih mešanih in listnatih gozdovih, je točnost teh ocen presegala 70 % (Lee in Lucas 2007, Jang in sod. 2008). Znotraj definiranih obrisov krošenj so določali drevesno vrsto in biomaso z vključitvijo številnih pojasnjevalnih spremenljivk, izpeljanih iz lidarskih in multispektralnih optičnih podatkov. Tovrstne analize so se izkazale uspešne za osamljena drevesa (Antonarakis in sod. 2008, Moffiet in sod. 2005, Brandtberg 2007), manj uspešne pa so bile pri sestojih s tesnim sklepom in prepletenimi krošnjami, se pravi v razmerah, kakršne prevladujejo v Sloveniji.

Uporaba lidarskega daljinskega zaznavanja v gozdarstvu ima, kot vidimo, številne vidike. V naslednjih poglavjih si podrobneje poglejmo tiste vidike, ki so relevantni za nadaljnje delo, prikazano v tej nalogi.

4.1.1 Drevesne vrste

Lidarski podatki se med drugim uporabljajo za kartiranje drevesnih vrst v gozdu. Osnova za napovedovanje sta prostorski razpored odbojev in intenziteta odbojev. Težava pri uporabi intenzitete odbojev je, da se še ni uveljavil noben standardni postopek za radiometrično kalibracijo, saj na intenzivnost odbojev od gozda vplivajo številni elementi: orientacija listov, pojemanje signala v atmosferi, kot skeniranja, dolžina poti in topografija (Donoghue in sod. 2007, Ørka in sod. 2009, Wagner in sod. 2008). Številne raziskave v gozdnih plantažah, borealnih gozdovih in drugih gozdovih z majhno vrstno pestrostjo (majhnim številom drevesnih vrst) so potrdile, da je v relativno homogenih gozdovih (mišljeno v primerjavi z bolj raznovrstnimi gozdovi v Sloveniji) mogoče doseči visoko točnost klasifikacije drevesnih vrst. Holmgren in Persson (2004) sta pri razlikovanju med smreko in rdečim borom dosegla 95-odstotno točnost na ravni segmentiranih dreves. Znotraj posameznih segmentov sta kot napovedovalne spremenljivke uporabila prostorsko razporeditev in intenzivnost odbojev. Brandtberg (2007) je razvil metodo klasifikacije segmentiranih dreves z uporabo usmerjenih grafov, ki opisujejo relacije med posameznimi tipi odbojev v krošnji drevesa. Na primeru 600 neolistanih hrastov, javorov in topolov v Zahodni Virginiji je dosegel 64-odstotno točnost. Na Norveškem so Ørka in sod. (2009) razlikovali med smreko (197 dreves) in brezo (180 dreves). Izračunali so različne statistike intenzivnosti in porazdelitve odbojev v valjih s središči v vrhovih dreves, pri čemer so premeri valjev ustrezali premerom krošenj, izmerjenim na terenu. Točnost klasifikacije je bila 77-odstotna za strukturne pojasnjevalne spremenljivke, 73-odstotna za intenzitetne in 88-odstotna za kombinacijo obojih. Donoghue in sod. (2007) so v gozdni plantaži na Škotskem ugotovili, da z uporabo intenzitete odbojev najbolje napovedo

delež bora in sitke, in to navkljub šumu zaradi topografskih vplivov. Pri modelnem napovedovanju so dosegli koeficient determinacije 0,93. Poleg strukturnih značilnosti so za določitev vrste ključne fiziološke značilnosti dreves, ki se odražajo v barvi. Suratno in sod. (2009) so v Montani klasificirali drevesne vrste v gorskem iglastem gozdu (duglazija, macesen, bor) z lidarskimi podatki gostote manj od 1 m^{-2} in dosegli 68-odstotno točnost na ravni posameznih dreves in 95-odstotno točnost pri deležu dominantne drevesne vrste. Morsdorf in sod. (2009) so se ukvarjali z možnostmi uporabe multispektralnih lidarskih podatkov pri prepoznavanju vrst. Ugotavljajo, da se spektralni podpis odbojev od vegetacije spreminja v skladu s sezonsko vsebnostjo klorofila, pri talnih odbojih pa spektralni podpis ostaja nespremenjen. Z zaznavanjem fenoloških sprememb bi tako lidarski multispektralni podatki lahko občutno izboljšali točnost klasifikacije drevesnih vrst.

4.1.2 Sestojna temeljnica

Sestojna temeljnica je značilnost sestoja, ki je pomembna za ugotavljanje zarasti sestoja in izkoriščenosti rastnega prostora (izkoriščenosti potenciala rastišča) pa tudi lesne zaloge sestoja po Bitterlichovi metodi in srednjega premera dreves. V literaturi smo našli le nekaj omemb modeliranja temeljnice z diskretnimi lidarskimi podatki. Lefsky in sod. (1999) so v listnatem gozdu zahodnega Marylanda korelirali terensko izmerjene temeljnice na 48 ploskvah z različnimi lidarsko ocenjenimi sestojnimi višinami (minimalna, maksimalna, srednja, srednja kvadratična), ocenjenimi iz valovnega profila višin. Srednja kvadratična višina je pojasnila 70 % variabilnosti sestojne temeljnice. Holmgren (2004) je napovedoval temeljnico v borealnih gozdovih Skandinavije. Hudak in sod. (2006) so v iglastem gozdu v severnem Idahu uporabili lidarske podatke gostote 2 m^{-2} v kombinaciji z multispektralnimi podatki satelita ALI (Advanced Land Imager) ločljivosti 30 m multispektralno in 10 m pankromatsko. Pojasnili so 90 % variabilnosti, pri čemer sta se kot najboljša prediktorja izkazala lidarsko ugotovljena višina vegetacije in lidarska intenzivnost odbojev, pojasnjevalne spremenljivke ALI pa so se zaradi slabe prostorske ločljivosti izkazale kot manj informativne. Thomas in sod. (2006) ter Rooker Jensen in sod. (2006) so z različnimi statističnimi merami višin lidarskih odbojev pojasnili od 89 do 91 % variabilnosti temeljnice, odvisno od gostote lidarskih podatkov. Chen in sod (2007) so v savanastem hrastovem gozdu v Kaliforniji znotraj terensko preverjenih tlorisov krošenj posameznih dreves izračunali percentilne višine različnih tipov odbojev in volumen krošenj. Odkrili so eksponentno povezavo med lidarsko izmerjenim volumnom krošnje in temeljnico, ki je bila tem tesnejša, čim točnejši je bil opis tlorisa krošnje.

4.1.3 Svetlobne razmere

Razpoložljivost svetlobe v sestoju je eden od osnovnih parametrov, ki določa razvoj sestoja ter njegovo obnavljanje in pomlajevanje. Uravnavanje svetlobnih razmer je zato glavno orodje gojenja gozdov, ki s selektivnim redčenjem dreves ustvarja primerne svetlobne razmere, te pa v medvrstni konkurenci dajejo prednost tistim drevesnim vrstam in tistim konkretnim drevesom, katerih razvoj želimo pospeševati. Z ustvarjanjem svetlobnih jaškov ustvarjamo pomlajevalna jedra znotraj zrelih sestojev ter s tem določamo intenzivnost, vrstno sestavo in prostorski vzorec bodočega gozda. Svetlobne razmere navadno opisujemo s sestojnim sklepom, to je deležem tal, ki jih pokriva vertikalna projekcija krošenj na tla. V tradicionalnem gozdarstvu sestojni sklep ocenjujemo okularno na 5 stopenj natančno, sodobna tehnologija pa je prinesla tudi natačnejše metode merjenja. Najbolj poznana metoda merjenja

sklepa je s hemisferno fotografijo (navpično navzgor usmerjena fotografija z zornim kotom blizu 180°), s katero zaznamo geometrijo nezastrtega neba na določenem mestu v sestoju. S primernim programskim orodjem je iz hemisferne fotografije mogoče izračunati tudi številne druge količine (na primer indeks listne površine LAI – Leaf Area Index, delež direktne fotosintetsko aktivne svetlobe in delež difuzne fotosintetsko aktivne svetlobe), ki na ravni drevesa opisujejo zmožnost za absorpcijo svetlobe, pomembne pa so tudi na ravni ekosistema, saj odražajo njegov razvoj in produktivnost. LAI podaja maksimalno razmerje med skupno površino listja in tlorisom krošnje (vrednosti segajo od 0 zunaj gozda do 6 v tesno sklenjenem gozdu). Riaño in sod. (2003) so ocenjevali sklep iz razmerja odbojev od krošenj glede na vse odboje, pri čemer točnosti rezultatov niso navedli. Morsdorf in sod. (2006) so v borealnem borovem gozdu v Švici s frekvencami prvih, zadnjih in edinih odbojev modelno pojasnili 69 % variabilnosti hemisferno izmerjenega LAI. Sklep so modelno ocenjevali iz razmerja med prvimi odboji od vegetacije in vsemi prvimi odboji ter pojasnili 73 % variabilnosti. Hopkinson in Chasmer (2008) sta LAI najbolje pojasnila z intenzivnostjo odbojev (R^2 = 0,78), najslabše pa z razmerjem odbojev od krošenj glede na vse odboje (R^2 = 0,70). Sasaki in sod. (2008) so LAI in delež vrzeli oziroma odprtost, kar je komplementarna količina sklepu, ocenjevali z deležem talnih odbojev v razmerju do vseh prvih in edinih odbojev. Delež pojasnjene variabilnosti je bil za obe količini enak, 77 %. Zhao in Popescu (2009) sta v Teksasu v gozdu s prevladujočim borom za oceno hemisferno izmerjenega LAI uporabila normalizirane metrike višin ter globino prodiranja laserskega žarka. Kot najučinkovitejša skupina pojasnjevalnih spremenljivk so se izkazale spremenljivke, ki opisujejo globino prodiranja v sestoj. Z njimi sta pojasnila 84 % variabilnosti LAI, najvišje korelacije sta dosegla pri polmeru ploskve 25 m.

4.1.4 Vertikalni profil vegetacije

Pri modeliranju značilnosti gozda z (diskretnimi) lidarskimi podatki se v zadnjih letih kot pokazatelj pojavlja tudi vertikalni profil vegetacije (v angleški literaturi pogosto poimenovan Canopy Height Profile – CHP). Opisuje vertikalno porazdelitev listne in vejne biomase od tal, skozi krošnje, do vrha sestoja. Vertikalni profil (listne) biomase sta prva omenila MacArthur in Horn (1969). Prvi so tak profil z (valovnim!) lidarjem uporabili Lefsky in sod. (1999), Riaño in sod. (2003) pa so ga prilagodili za diskretni lidar. Coops in sod. (2007) so potrdili določeno sovpadanje med lidarskim in terensko izmerjenim dejanskim profilom. Ugotovili pa so tudi, da lidarski profil pristransko poudarja predvsem zgornje plasti krošenj, poleg tega pa ne odraža povsem natančno vešslojne strukture gozda. Nasprotno od Coopsa in sod. pa so Zimble in sod. (2003) ugotovili, da je na krajinski ravni z lidarskimi profili mogoče razlikovati enoslojne gozdove od večslojnih. Maltamo in sod. (2004) so presegli problem zaznavanja podstojnega sloja na lidarskih profilih z uporabo teoretičnih distribucij. Wang in sod. (2008) so v zrelem, pretežno smrekovem gozdu v južni Nemčiji preslikali oblak točk v vokselski prostor, kjer so za vsak voksel (tridimenzionalen ekvivalent slikovnemu pikslu) izračunali normalizirano verjetnost lidarskih odbojev in nato z morfološkimi operacijami odpiranja in zapiranja (morphological opening, closing) z različnimi oblikami strukturnih elementov segmentirali posamezne drevesne krošnje na 2D-slikah, ki so jih izpeljali z rezanjem vokselskega prostora na vodoravne plasti. Iz segmentiranih 2D-slik so izpeljevali različne strukturne značilnosti, kot so višinski obseg krošenj, volumen krošenj in obseg krošenj na različnih višinah. Angelo in sod. (2010) so v hrastovem grmičastem gozdu na Floridi z lidarskimi profili zaznavali motnje rasti zaradi preteklih gozdnih požarov. S profili so modelno pojasnjevali čas od zadnjega požara. Lidarske odboje so beležili v celicah debeline 1 m in osnovnice 5 x 5 m, nato pa računali profile s povprečenjem celic v oknih

različnih dimenzij, od 0 do 500 m. V listnatih in iglastih gozdovih Wisconsina so Muss in sod. (2011) enako kot predhodniki drugje beležili frekvence lidarskih odbojev po višinskih vokslih, nato pa so tako dobljene profile zgladili s spline funkcijami in jih zaradi analogije z valovnim lidarjem poimenovali psevdovalovi. Primernost profilov za modeliranje višine dreves, strukture krošenj, sestojne biomase so primerjali s statistikami, kakršne se tradicionalno računajo za celotno višino oblaka (na primer povprečna višina, percentilne višine, varianca višin). Ugotovili so, da sta oba pristopa primerljiva po točnosti, vendar pa je psevdovalovni pristop zaradi sovpadanja s fizično zaznavno strukturo sestoja bolj intuitiven, poleg tega pa obeta še neizkoriščene možnosti razvoja novih metrik.

4.1.5 Souporaba lidarja in drugih daljinsko zaznanih podatkov

Slike zemeljske površine, narejene s pasivnimi senzorji, se glede zaznanih značilnosti gozda bistveno razlikujejo od posnetkov, narejenih z aktivnimi senzorji. Raznolikost meril in načinov delovanja različnih senzorjev širi možnosti za kvantifikacijo strukture gozda, biomase, vrstne sestave, ekosistemske dinamike ter ekološkega in ekonomskega vrednotenja gozda. En sam senzor ne more zajeti vseh informacij, ki so pomembne za gospodarjenje z gozdnimi ekosistemi. Zato je smiselno združevanje senzorjev za ocenjevanje in kartiranje značilnosti gozda (Hudak in sod. 2006). Sinergistična uporaba lidarja skupaj z drugimi viri daljinsko zaznanih podatkov je koristna na različnih področjih gozdarstva in upravljanja naravnih virov, kot so gozdne inventure, monitoring dinamike ogljika, biotska raznovrstnost in zaznavanje sprememb na vseh prostorskih ravneh od drevesa do krajine. To spoznanje vodi tudi v razvoj z lidarjem sinergističnih senzorjev na različnih platformah, od brezpilotnih letal do satelitov, kot je DESDynI (Lucas in sod. 2008).

Lefsky in sod. (2001) so primerjali uporabnost različnih načinov daljinskega zaznavanja za ocenjevanje gozdne biomase in ugotovili, da lidar presega letalske in satelitske multispektralne in hiperspektralne posnetke. Leckie in sod. (2003) so pokazali na prednosti lidarja pri ugotavljanju strukturnih značilnosti gozda, medtem ko za zanesljivo ugotavljanje drevesnih vrst in zdravstvenega stanja gozda dajejo prednost pasivno pridobljenim multispektralnim podatkom. McCombs in sod. (2003) so pri napovedovanju drevesne vrste ugotovili, da so združeni multispektralni in lidarski podatki boljši prediktor kot multispektralni podatki sami, pri napovedovanju višin pa so najboljši prediktor lidarski podatki sami. Popescu in Wynne (2004) sta izboljšala ocene drevesnih višin z združevanjem lidarskih in multispektralnih podatkov. Hilker in sod. (2008) so v duglazijevih gozdovih na otoku Vancouver uporabili podatke satelita QuickBird za prostorsko ekstrapolacijo lidarsko ocenjenih sestojnih višin na širše gozdno območje in s tem skušali znižati stroške daljinsko zaznanih podatkov. Model za ekstrapolacijo višin ($R^2 = 0,87$) je temeljil na barvnih, teksturnih in oblikovnih značilnostih satelitskih podatkov znotraj segmentov, dobljenih z orodjem eCognition (Definiens). Breidenbach in sod. (2010) so uporabili lidarske in multispektralne podatke za izboljšano segmentacijo drevesnih krošenj. Stojanova in sod. (2010) so lidarsko ocenjene sestojne višine in sestojni sklep ekstrapolirali v širši prostor z uporabo mnogo cenejših multitemporalnih podatkov satelita Landsat ETM. Višine in sklep so na ravni slikovnih segmentov modelno napovedovali s pomočjo statističnih povzetkov (minimalna in maksimalna vrednost, povprečje, standardni odklon) posameznih spektralnih kanalov, ločeno iz štirih datumov satelitskih slik, ki zajemajo značilne faze vegetacijskega obdobja.

4.1.6 Strojno učenje

Z vidika daljinskega zaznavanja, še posebej lidarskega, katerega značilnost sta zelo velika količina podatkov ter veliko število pojasnjevalnih spremenljivk, ki jih je mogoče izpeljati iz surovih podatkov, je pogosto težko graditi napovedovalne regresijske modele. Taki modeli lahko vsebujejo med seboj močno korelirane pojasnjevalne spremenljivke brez tehtnejše vsebinske povezave s ciljno spremenljivko. Metode strojnega učenja, ki bodo opisane v nadaljevanju, imajo v domeni daljinskega zaznavanja v primerjavi z linearno regresijo naslednje prednosti: niso občutljive za pretirano prilagajanje (angl. overfitting) ter za porazdelitev spremenljivk in njihovo medsebojno koreliranost; zato ni potrebna predhodna faza izbire pojasnjevalnih spremenljivk. Eno izmed številnih področij strojnega učenja so regresijska drevesa.

Kocev in sod. (2009) regresijska drevesa opisujejo takole: regresijska drevesa so odločitvena drevesa, ki napovejo vrednost numerične ciljne spremenljivke (Breiman in sod. 1984). Regresijska drevesa so hierarhične strukture, kjer notranja vozlišča vsebujejo teste pojasnjevalnih spremenljivk. Vsaka veja notranjega testa odgovarja rezultatu testa, napoved vrednosti ciljne spremenljivke pa je shranjena v listu. Vsak list vsebuje konstantno vrednost kot napoved ciljne spremenljivke (regresijska drevesa predstavljajo odsekoma konstantne funkcije). Da bi dobili napoved za nov podatkovni zapis, zapis sortiramo po drevesu navzdol, začenši s korenom (vrhnjim vozliščem drevesa, angl. root). Za vsako vozlišče na poti se izvede test, ki je shranjen v vozlišču. Glede na izid testa se pot nadaljuje vzdolž ustrezne veje (na ustrezno poddrevo). Končno napoved dobimo v listu na koncu poti. Testi v notranjih vozliščih imajo lahko več kot dva izida (kar je običajno, ko testiramo diskretne spremenljivke, za katere se ustvari poddrevesa za vsako od vrednosti). Tipično pa ima vsak test dva izida: test uspe ali ne. Taka drevesa imenujemo binarna drevesa. Večciljna (angl. multi-target) regresijska drevesa (Blockeel in sod. 1998, Struyf in Džeroski 2006) so posplošitev regresijskih dreves za hkratno napovedovanje več numeričnih spremenljivk. V listih večciljnih dreves so shranjeni vektorji namesto posameznih numeričnih vrednosti. Vsaka komponenta vektorja predstavlja napoved ene izmed ciljnih spremenljivk. Večciljno regresijsko drevo (katerega poseben primer je regresijsko drevo z eno samo ciljno spremenljivko) navadno konstruiramo iz učne množice zapisov z algoritmom rekurzivnega deljenja. Algoritem je poznan kot Top-Down Induction of Decision Trees (TDIDT). Zapisi vključujejo izmerjene vrednosti pojasnjevalnih in ciljnih spremenljivk. Testi v notranjih vozliščih se nanašajo na pojasnjevalne spremenljivke, napovedane vrednosti v listih pa se nanašajo na ciljne spremenljivke. Algoritem TDIDT se začne z izbiro testa za korensko vozlišče (angl. root node). Glede na izid testa se učna množica razdeli na podmnožice. V primeru binarnih dreves se razdeli v dve podmnožici: ena vsebuje zapise, za katere je test uspel, druga pa zapise, za katere test ni uspel. Ta postopek se med konstrukcijo drevesa rekurzivno ponavlja. Deljenje se ustavi, ko je zadovoljen ustavitveni kriterij (na primer število zapisov v podmnožicah pade pod določen prag; dolžina poti od korena do tekoče podmnožice preseže nek prag in podobno). V takem primeru se napovedovalni vektor izračuna in shrani v list. Komponente napovedovalnega vektorja so srednje vrednosti ciljnih spremenljivk, izračunane iz vseh zapisov, ki so razporejeni v list. Eden najpomembnejših korakov algoritma je postopek izbire testa. Za vsako vozlišče se izbere iz učnih podatkov s pomočjo hevristične funkcije. Cilj hevristike je voditi algoritem k manjšim drevesom z dobro sposobnostjo napovedovanja. Z ansambelsko metodo konstruiramo množico napovedovalnih modelov, ki jo imenujemo ansambel (Dietterich 2000). Ansambel podaja napoved s kombiniranjem napovedi

svojih modelov. Pri regresijskih modelih se napovedi združujejo kot povprečja. Posamezni modeli morajo biti točni in raznoliki, če naj bo napoved ansambla bolj točna od napovedi posameznih članov ansambla (Hansen in Salamon 1990). Model je točen, če je pri novih primerih boljši od naključnega ugibanja. Množica modelov je raznolika, če modeli na novih primerih zagrešijo različne napake. Raznolikost lahko v ansambel uvedemo na različne načine: s spreminjanjem učne množice (spreminjanje uteži primerov ali uteži spremenljivk) ali pa s spreminjanjem učnega algoritma, s katerim ustvarjamo modele. Ansambli večciljnih regresijskih dreves (angl. multi-target regression trees – MTRT) so množice MTRT, ki jih dobimo z uporabo istega algoritma TDIDT. Napoved ansambla MTRT dobimo s povprečenjem napovedi modelov. Tako je mogoče izboljšati napovedi posameznega MTRT, tudi v primeru ene same ciljne spremenljivke (Breiman 1996, Kocev in sod. 2007). Bagging in random forests sta dve najpogosteje uporabljeni metodi tvorjenja ansamblov MTRT. Bagging (Breiman 1996) je ansambelska metoda, ki konstruira različne modele v ansamblu z ustvarjanjem boostrap ponovitev učne množice. Te se potem uporabi za konstruiranje posameznih modelov. Vsak bootstrap vzorec pridobimo s naključnim vzorčenjem učnih primerov, s ponovitvami, iz izvorne učne množice. Bootstrap vzorec in učna množica imata enako število primerov. Bagging lahko prinese občutno izboljšavo napovedi, če ga uporabimo pri nestabilnih učnih metodah (to so tiste učne metode, kjer majhna sprememba v učni množici prinese velike spremembe v napovedih), kot so klasifikacijska in regresijska drevesa (Breiman 1996). Bagging raznolikost črpa iz spreminjanja učnih množic za konstruiranje posameznih modelov ansambla. Random forest (Breiman 2001) je ansambel dreves, kjer raznolikost pridobimo na dva načina: (1) z bootsrap vzorčenjem in (2) s spreminjanjem nabora pojasnjevalnih spremenljivk med učenjem (to dosežemo z naključnim spreminjanjem algoritma TDIDT). V vsakem vozlišču odločitvenega drevesa naključno izberemo podmnožico pojasnjevalnih spremenljivk in poiščemo najboljšo delitev na osnovi te podmnožice (konec citata Kocev in sod. 2009).

Korpela in sod. (2009) so uporabili random forest pristop za kartiranje različnih tipov barij in močvirnih gozdov na Finskem z lidarskimi podatki. Random forest modeli so temeljili na različnih statističnih merah porazdelitve odbojev ter njihove intenzivnosti. Točnosti napovedovanja za različne diskretne ciljne spremenljivke so bile med 52 in 92 %, odvisno od ločljivosti napovedi (10 x 10 m, 20 x 20 m) in od vrste barja. Falkowski in sod. (2009) so random forest s klasifikacijskimi drevesi uporabili za napovedovanje šestih razvojnih faz gozda iz različnih lidarskih metrik in dosegli 95-odstotno točnost. Chen in sod. (2010) so uporabili metodo strojnega učenja support vector regression za modelno pojasnjevanje lidarskih višin s podatki satelita QuickBird (R^2 = 0,81). Stojanova in sod. (2010) so pri napovedovanju lidarsko merjenega sestojnega sklepa in sestojnih višin z multispektralnimi podatki ugotovili, da ansambelske metode po točnosti napovedi močno prekašajo posamezne modele v obliki regresijskih dreves. Angelo in sod. (2010) so za napovedovanje časa, ki je minil od zadnjega gozdnega požara, primerjalno uporabili support vector machine (SVM) in metodo k-nearest neighbor (k-NN). Model SVM se je izkazal kot najtočnejši. Haywood in Stone (2011) sta na modelu za napovedovanje prisotnosti škodljivega insekta v evkaliptusovih gozdovih Avstralije prikazala sposobnost strojnega učenja za hkratno uporabo raznovrstnih podatkov – lidarskih, multispektralnih SPOT 5 satelitskih podatkov in termatskih GIS-podatkov. Izmed šestih različnih metod modeliranja (logistična regresija, generalizirani aditivni model GAM, regresijsko drevo J48, random forest regresijskih dreves, Adaboost, nevronska mreža) se je kot najuspešnejši izkazal random forest (kappa = 0,84), sledila pa sta mu logistična regresija in nevronska mreža (oba kappa = 0,76). Najslabši je bil model J48 (kappa = 0,56).

4.1.7 Opredelitev problema

Kot smo videli iz pregleda literature, se lidarski vertikalni profili vegetacije, izračunani iz podatkov diskretnega lidarja, pojavljajo kot obetajoča nova skupina pojasnjevalnih spremenljivk pri modelnem napovedovanju različnih lastnosti gozda. Čeprav obstaja nekaj znanih študij modeliranja gozdnih značilnosti s profili, ki jih neposredno daje valovni lidar – tipičen primer je Lefsky in sod. (1999) –, pa v literaturi nismo našli primera modeliranja temeljnice, deleža drevesnih vrst, LAI in sestojnega sklepa s podatki profilov, izračunanih iz diskretnih odbojev. Zadali smo si nalogo, da na realnem gozdarskem primeru dveh gozdnogospodarskih enot primerjalno preizkusimo napovedovanje omenjenih značilnosti gozda z različnimi načini učenja ansambelskih modelov in z linerano regresijo. Kot pojasnjevalne spremenljivke smo želeli preizkusiti različne izpeljanke vertikalnih profilov vegetacije. Ponudniki lidarskih podatkov pogosto brez doplačila hkrati posnamejo še letalske posnetke, za ozemlje Slovenije pa so ti na voljo tudi pri Geodetski upravi RS, v zadnjem času tudi v infrardečem spektru. Zato smo pri modeliranju želeli uporabiti tudi pojasnjevalne spremenljivke na podlagi IR-aeroposnetkov. Iz dosegljive literature ni razvidno, da bi omenjene gozdne značilnosti že bile napovedovane s tako kombinacijo metod modeliranja, pojasnjevalnih spremenljivk ter na tako velikem testnem območju.

4.2 Metoda

Izdelali smo vrsto modelov za napovedovanje izbranih značilnosti gozda s pomočjo lidarskih podatkov in IR-aeroposnetkov. V tem poglavju bomo definirali ciljne spremenljivke in opisali terenske metode njihovega merjenja ali ocenjevanja. Opisali bomo metode izpeljave pojasnjevalnih spremenljivk, metode modeliranja, analizo različnih vplivov na točnost modelov in rangiranja pojasnjevalnih spremenljivk. Seznam vseh ciljnih in pojasnjevalnih spremenljivk je v Prilogi A.

Cilj tega dela naloge je bil za konkreten primer testnega območja Slivnica ugotoviti:

1. katere od izbranih ciljnih spremenljivk je mogoče uspešno napovedovati,
2. kateri način modeliranja je najboljši,
3. katere pojasnjevalne spremenljivke so najprimernejše,
4. kako na točnost napovedi vpliva polmer zajema pojasnjevalnih spremenljivk – v primeru svetlobnih značilnosti gozda zorni kot opazovanja,
5. katero število dreves v ansambelskem modelu je optimalno.

Omeniti je treba izjemno veliko količino vmesnih in končnih rezultatov (skupaj nekaj manj od 1 TB), ki so nastali v okviru testnega območja Slivnica. Za primer naj navedemo, da je zgolj za pripravo učne množice s podatki o profilih bilo treba pripraviti nekaj sto vmesnih rezultatov v obliki rastrskih datotek s 15400 stolpci in 16200 vrsticami, od katerih vsaka na disku zavzame približno 1 GB, če gre za decimalne podatke, oziroma 0,5 GB, če gre za cela števila. Kot bo vidno v nadaljevanju, smo poskuse modelnega napovedovanja zastavili vzdolž petih dimenzij, kar je pomenilo 5508 poskusov. Gradnja modelov je zato terjala več tednov računanja, včasih vzporedno na več računalnikih. Še počasnejša je bila priprava učnih podatkov ter implementacija modelov (izračun kart), saj smo jo izvedli z lastnimi orodji, napisanimi v jeziku Python. Ker poraba časa za programiranje presega čas računanja smo se odločili za Python, saj se ga da zlahka naučiti in je zelo flkesibilen, pa čeprav je pythonska koda počasnejša od C ali C++.

Seveda bi bila pri opretivni rabi lidarja v gozdarstvu poraba časa manjša za en ali dva reda velikosti, saj bi že poznali najprimernejše pristope, orodja bi sprogramirali v hitrejšem jeziku in faze postopka bi bile bolj utečene.

4.2.1 Ciljne spremenljivke

4.2.1.1 Definicije in postopek terenskega dela

Ciljne spremenljivke merimo ali ocenjujemo na vzorčnih ploskvah (Slika 11). Po štiri vzorčne ploskve so združene v trakt in sicer tako, da je vsaka odmaknjena za 10 m od središča trakta v eno od glavnih smeri neba. Na vsaki ploskvi se opravijo naslednje meritve in ocene:

- Z optičnim dvolomcem (optično prizmo za izmero sestojne temeljnice na ploskvah spremenljivega radija) se izmeri hektarska temeljnica sestoja, pri čemer se upoštevajo drevesa nad merilnim pragom, ki znaša 15 cm prsnega premera. Hektarska temeljnica sestoja je vsota površin prerezov vseh dreves v sestoju na prsni višini (1,3 m). Sestojna temeljnica je pomembna sestojna značilnost, saj nakazuje izkoriščenost rastnih potencialov rastišča, pomnožena s sestojno višino in oblikovnim faktorjem (pove, kolikšen delež prostornine valja s prsnim premerom predstavlja prostornina drevesnega debla) pa lahko služi tudi za izračun lesne zaloge sestoja po Bitterlichovi metodi. Po Bitterlichovi kotnoštevni metodi se sestojna temeljnica meri z optičnim dvolomcem, tako da se na izbranem stojišču v krogu 360° preštejejo vsa drevesa, kjer je navidezni zamik debla na prsni višini manjši od navidezne debeline debla (Slika 12). Število takih dreves je enako temeljnici sestoja na tem mestu, izraženi v m^2/ha. Pri mejnih drevesih (tistih, pri katerih z uporabo prizme ni mogoče zanesljivo reči, ali se upoštevajo ali ne) se upošteva vsako drugo drevo. Pri merjenju hektarske temeljnice (spremenljivka gha) smo upoštevali horizontirano razdaljo.
- Vizualno se v radiju, pri katerem je bila ocenjena temeljnica, ugotovijo tri najbolj zastopane drevesne vrste in oceni njihov odstotni delež sklepa v zgornjem sloju sestoja zaokroženo na 10 %. Iz tega smo potem izračunali deleže 13 skupin drevesnih vrst: delež bukve (delbukev), delež vseh javorjev (deljavor), delež belega gabra (delbgaber), delež črnega gabra (delcgaber), delež vseh hrastov (delhrast), delež malega jesena (delmjesen), delež velikega jesena (delvjesen), delež ostalih listavcev (delostalilst), delež smreke (delsmreka), delež jelke (deljelka), delež vseh borov (delbor), delež macesna (delmacesen) in delež ostalih iglavcev (delostaliigl). Dodatno smo s seštevanjem deležev vseh iglavcev izračunali spremenljivko deligl. Delež listavcev je komplement deligl.
- Posname se hemisferna fotografija (Slika 13). Ta fotografija je temelj za izračun svetlobnih razmer, ki jih izračunamo z orodjem Winscanopy (www.regentinstruments.com). Za vsakega od štirih zornih kotov (45, 60, 120 in 170°) posebej izračunamo naslednjih devet svetlobnih značilnosti (v nadaljevanju je veljaven zorni kot razviden iz pripone imenu spremenljivke, na primer openness_120):
    - odprtost kot komplement sklepa, ki je torej definirana kot delež z vegetacijo nezakritega neba v vertikalni projekciji na tla (ime spremenljivke je openness). Zaradi vertikalne slojevitosti gozdne vegetacije je odprtost odvisna od višine postavitve fotoaparata. V našem primeru je bil aparat postavljen 1,3 m nad tlemi, to je nad zeliščnim slojem, tako da odprtost zajema tudi vpliv grmovnega sloja,

- indeks listne površine LAI (lai2000lin); izračun LAI po Miller (1967) ter Welles in Norman (1991),
- generaliziran indeks listne površine LAI (lai2000glin); LAI, izračunan po generalizirani različici zgornje metode,
- delež povprečne direktne svetlobe pod sestojem v primerjavi s prispelo direktno svetlobo nad sestojem (directsitefactor),
- delež povprečne difuzne svetlobe pod sestojem v primerjavi s prispelo difuzno svetlobo nad sestojem (indirectsitefactor),
- delež povprečne vse svetlobe pod sestojem v primerjavi z vso prispelo svetlobo nad sestojem (totalsitefactor),
- količina direktnega fotosintetsko aktivnega sevanja pod sestojem v rastni sezoni, podana v MJ (ppfddirectunder),
- količina difuznega fotosintetsko aktivnega sevanja pod sestojem v rastni sezoni, podana v MJ (ppfddiffuseunder),
- količina vsega fotosintetsko aktivnega sevanja pod sestojem v rastni sezoni, podana v MJ (ppfdtotalunder).

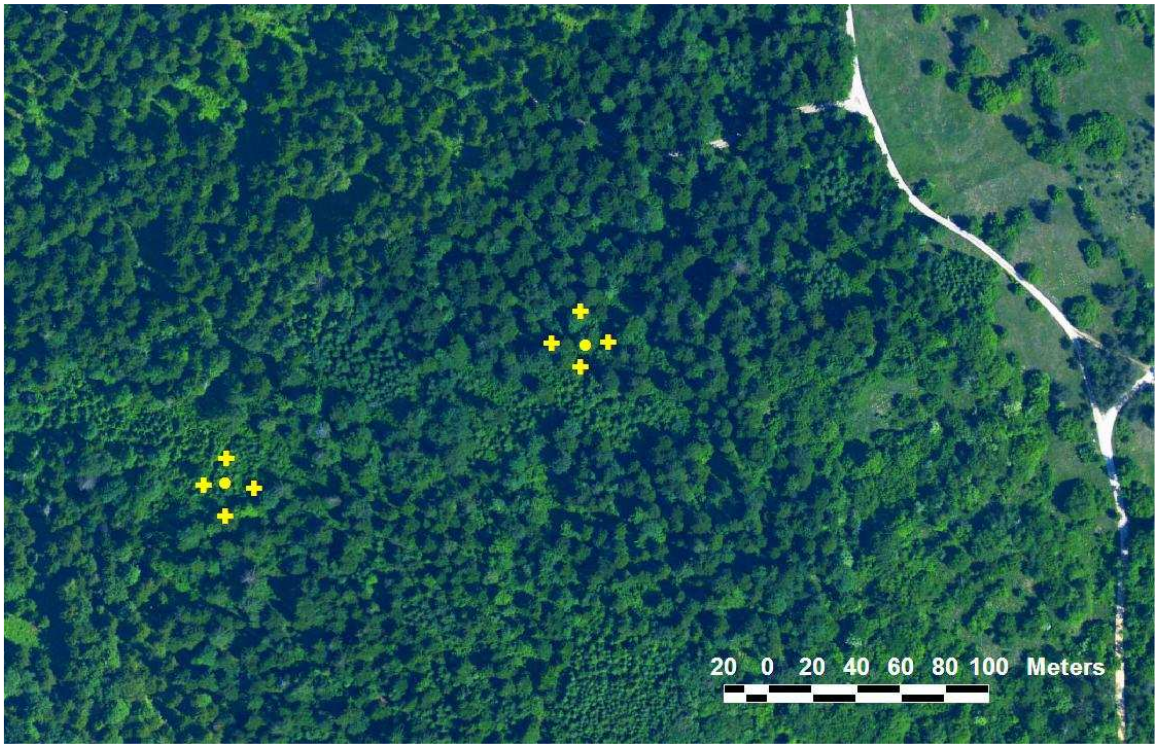

Slika 11: Primer razporeditve ploskev znotraj traktov. Pika označuje z diferencialnim GPS izmerjeno lokacijo središča trakta, križec pa s polarnimi koordinatami določeno lokacijo podrejene ploskve. Dejanske lokacije ploskev odstopajo od teoretičnih (10 m od središča trakta na V, Z, S, J) zaradi prilagajanja lokalnim razmeram.

Figure 11: An example of plot layout within tract. Dots indicate differential GPS-located tract center , crosses indicate corresponding plots, located with relative polr coordinates. Due to adaptation to local circumstances the true plot locations differ from theoretical ones (10 m from tract center in 4 cardinal directions).

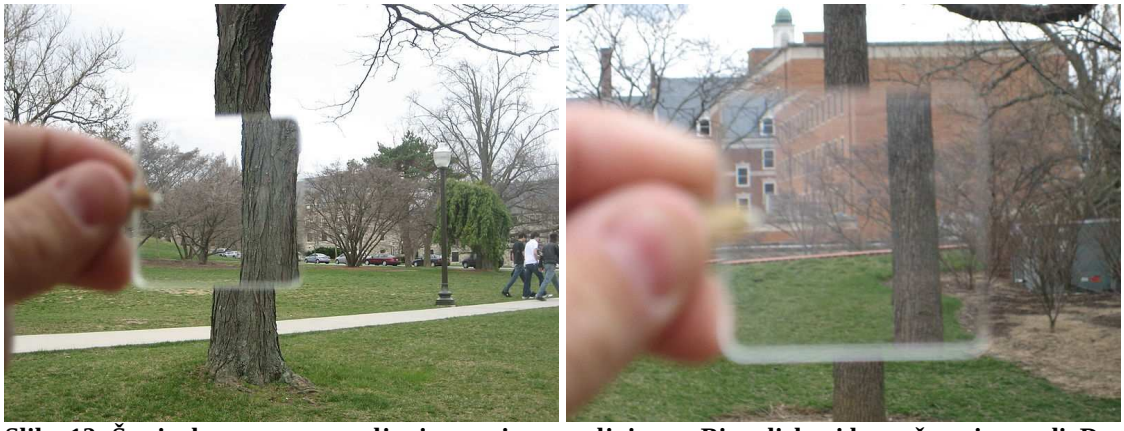

Slika 12: Štetje dreves za ugotavljanje sestojne temeljnice po Bitterlichovi kotnoštevni metodi. Drevo na levi sliki štejemo, drevo na desni pa ne. Vir: http://en.wikipedia.org/wiki/Wedge_prism.
Figure 12: Tree counting for estimation of basal area according to the Bitterlich method. The tree on the left is counted, while the tree on the right is not. Source: http://en.wikipedia.org/wiki/Wedge_prism.

Slika 13: Oprema za hemisferno fotografiranje svetlobnih razmer v sestoju. Vir: Matjaž Čater.
Figure 13: Equipment for estimation of forest stand light parameters by hemisferical photography. Source: Matjaž Čater.

Vnaprej določene koordinate traktov se uporabljajo za navigacijo do središč traktov z GPS sprejemnikom Trimble GeoXT brez sprotne diferencialne korekcije. Čim bolj točno določanje položaja središč ploskev je pomembno zaradi sovpadanja lidarskih in terenskih podatkov, kar je potreben pogoj za empirično modeliranje terensko ugotovljenih značilnosti gozda z lidarskimi podatki. Dejanske lokacije ploskev se izračunajo iz dejanske (in ne teoretične) lokacije središča trakta (gl. pogl. 4.2.1.2) in na terenu izmerjenih polarnih koordinat ploskev. Dejanska lokacija središča trakta se izmeri po postopku naknadne diferencialne korekcije iz GPS izmerjenega položaja. Napaka lociranja ploskve izvira predvsem iz napake GPS pri

lociranju središča trakta, ki v povprečju znaša 2,41 m, saj so polarne koordinate ploskve glede na središče trakta relativno točne (to napako ocenjujemo na 0,2 m).

4.2.1.2 Razpored vzorčnih ploskev

Trakti oziroma ploskve, na katerih smo merili ali ocenjevali vrednosti ciljnih spremenljivk za učni vzorec, so bile razporejene naključno znotraj gozdnega prostora (gozd in grmišča) v raziskovalnem območju. Pričakovali smo, da bo največji del delovnega časa pri terenskem delu porabljen za premike med vzorčnimi ploskvami, zato smo pozornost posvetili optimiranju razporeditve ploskev.

- Ker je testno območje prepredeno z gosto in relativno enakomerno mrežo gozdnih cest, smo ocenili, da je v 300 m širokem pasu ob gozdnih cestah ustrezno zajeta vsa raznolikost tukajšnjih gozdov. Z omejitvijo raziskovalnih ploskev na ta pas smo omogočili uporabo avtomobila za hitre premike med ploskvami. Raziskovalne ploskve smo razporedili naključno znotraj tega pasu (in hkrati znotraj gozdnega prostora), pri čemer smo neposredne vplive prometa na gozd zmanjšali z dodatno omejitvijo, da nobena raziskovalna ploskev ne sme biti manj kot 100 m oddaljena od najbližje ceste (Slika 14). Stometrski pas ob cesti je tudi tisto območje, kjer je intenzivnost človekovega poseganja v gozd največja.
- Porabo časa za premike med ploskvami smo dodatno zmanjšali z združevanjem po štirih ploskev v trakt. Sestavni deli trakta so njegovo središče ter štiri ploskve, ki so (teoretično) razporejene 10 m od središča trakta v štirih glavnih smereh neba. Če je bila teoretična lokacija ploskve zaradi konfiguracije terena ali neprehodne podrasti ali prisotnosti velikega drevesa (ki onemogočajo postavitev merilne opreme) neprimerna, se je ploskev v začeti smeri še dodatno odmaknila (za najmanjšo mogočo razdaljo) od središča trakta, vendar ne več kot za 15 m (Slika 11). Če tudi to ni bilo dovolj, je ploskev izpadla iz vzorca, in trakt je imel manj kot štiri ploskve. Ploskev je iz vzorca izpadla tudi, če je padla iz gozda.
- S tako zasnovo traktov smo hkrati skrajšali tudi čas za določitev koordinat ploskev, saj smo z GPS izmerili le središče trakta, lokacije štirih podrejenih ploskev pa smo nato določili relativno s polarnimi koordinatami s kompasom in merilnim trakom glede na središče trakta.

Velikost vzorca smo določili v okviru danih logističnih možnosti. Za terensko delo smo imeli na voljo 120 človek-dni oziroma obdobje 60 dni z dvočlansko ekipo. Pred začetkom terenskega dela smo ocenili, da bo za delo na enem traktu in prehod do naslednjega trakta skupaj v povprečju potrebnih 60 minut oziroma da je v enem delovnem dnevu mogoče obdelati osem traktov oziroma 32 ploskev. Če kot rezervo za primer slabega vremena prihranimo 20 % oziroma 12 od predvidenih 60 dni, 5 dni pa predvidimo za meritve drevesnih višin (opisano na drugem mestu), nam je za delo na traktih ostalo 43 dni. Določili smo torej (teoretični) vzorec, ki ima 43 * 8 = 344 naključno razporejenih traktov znotraj pasu med 100 in 300 m od cest (Slika 15) oziroma (teoretično) 1376 ploskev. Dejansko je bilo nato obdelanih le 246 traktov oziroma 71,5 % od predvidenih 344. Razlog za manjše število obdelanih traktov je bil – v manjšem delu – nepredvideno veliko število dni s slabim vremenom, pomembnejše pa je bilo deloma slabo delovanje GPS zaradi težavnega reliefa (ozke grape), tesnega sklepa krošenj in občasno neustrezne konstelacije satelitov. Na obdelanih 246 traktih je bilo v skladu s pravili (prisotnost gozda itd.) lahko izmerjenih 950 ploskev oziroma 96,5 % od teoretično mogočih 984 ploskev.

Učna množica vsebuje 950 primerov. Za vsak primer so znane vrednosti ciljnih in pojasnjevalnih spremenljivk, ki jih bomo definirali v naslednjem poglavju. Seznam vseh spremenljivk je v Prilogi A.

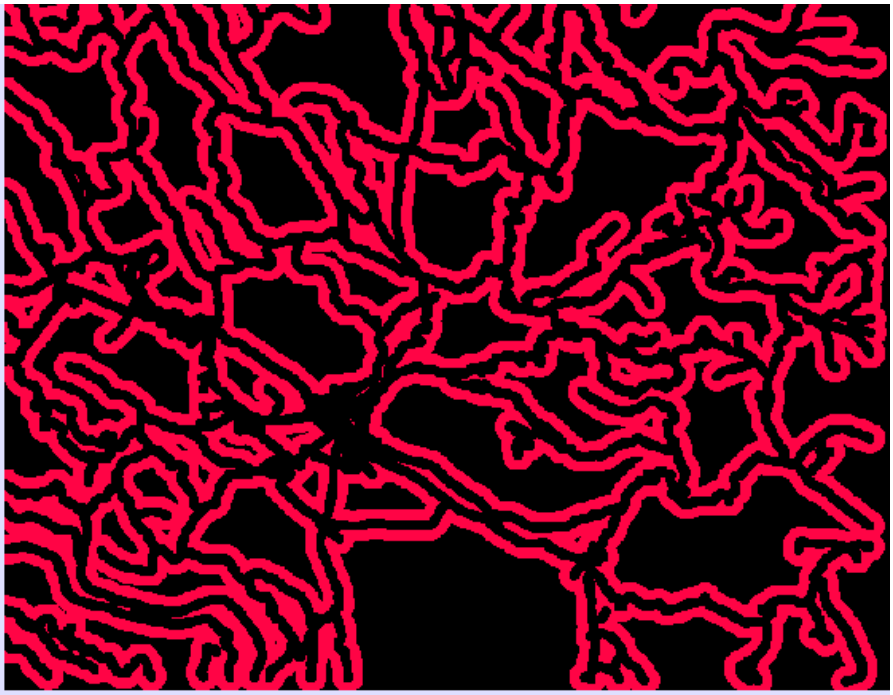

Slika 14: Izrez raziskovalnega območja z 200-metrskimi pasovi (100 m do 300 m od cest, pasovi označeni z rdečo), znotraj katerih smo naključno določali lokacije raziskovalnih traktov.
Figure 14: Subset of the test area showing 200 m buffers (100-300 m to roads, indicated by red), containing random locations of research tracts.

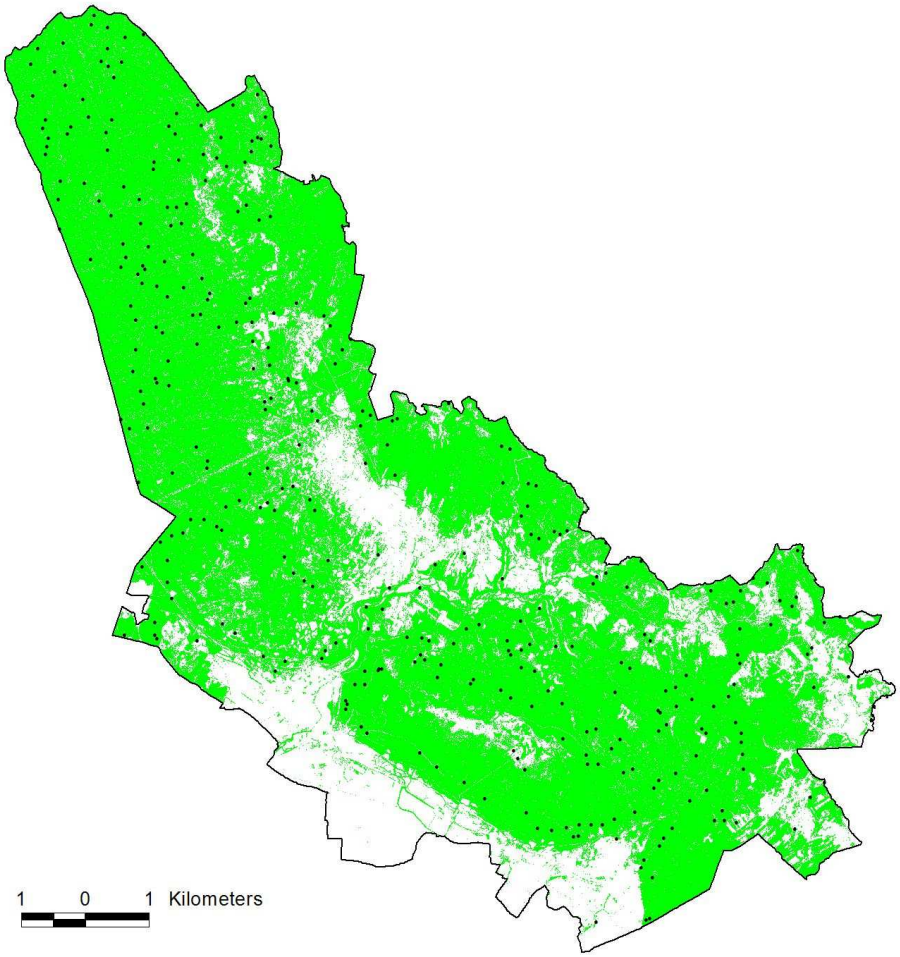

Slika 15: Naključna porazdelitev traktov (črne pike) v testnem območju Slivnica znotraj gozdnega prostora (zelena barva) in znotraj pasu od 100 do 300 m od cest.
Figure 15: Random distribution of tracts (black dots) in the Slivnica test area are located within forests (green) and within 100-300 m road buffers.

4.2.2 Pojasnjevalne spremenljivke

4.2.2.1 Vertikalni profili

Vertikalne profile smo računali iz prvih odbojev (ker večinoma odražajo vegetacijo) in edinih odbojev (deloma predstavljajo odboje od tal, deloma pa od vegetacije), zadnje in vmesne odboje pa smo zanemarili (zadnji odboji večinoma predstavljajo tla, vmesnih pa je zelo malo). Najprej smo po metodi REIN izdelali DMR s horizontalno ločljivostjo 1 x 1 m iz zadnjih in edinih odbojev, katerih skupna povprečna gostota znaša 15,4 m^{-2}. S pomočjo DMR smo za vsako lidarsko točko izračunali njeno relativno višinsko razliko nad tlemi. Prostor nad testnim območjem do višine 32 m nad reliefom smo razčlenili na voksle (3D-piksle) velikosti 1 x 1 x 1 m in za vsak voksel ugotovili skupno frekvenco pripadajočih prvih in edinih odbojev. V praksi smo za vsako metrsko plast izdelali rastrsko sliko z ločljivostjo 1 x 1 m, zaradi osamelcev pa smo dodali še ničelno plast za odboje navidezno pod tlemi in plast za odboje, višje kot 32 m nad tlemi, tako da je bilo vseh plasti 34. Surove frekvence v

posameznem stolpcu vokslov prikazujejo popačen vertikalni profil. Popačen je zato, ker so zaradi zasenčenja spodnjih slojev vegetacije z nadstojno vegetacijo frekvence v spodnjih plasteh krošenj pristransko manjše (Coops in sod. 2007). Popačenje smo popravili z metodo, ki smo jo prilagodili po Harding in sod. (2001), saj je bila v izvirniku uporabljena na podatkih valovnega lidarja. Metoda temelji na Beer-Lambertovem zakonu o pojemanju svetlobe zaradi absorpcije v mediju, skozi katerega potuje. Korekcijski obrazec iz Harding in sod. (2001) smo prilagodili kot prikazuje obrazec (2):

$$F_i = SF_i * [-ln (1 - KSF_i)] \quad (2)$$

F_i … korigirana frekvenca odbojev v *i*-ti plasti (šteto od vrha sestoja proti tlom)
SF_i … surova frekvenca odbojev v *i*-ti plasti
KSF_i … kumulativna vsota surovih frekvenc odbojev od vrha sestoja do vključno *i*-te plasti

Korigirane frekvence v posameznih vokslih smo standardizirali z vsoto vseh korigiranih frekvenc v stolpcu in dobili relativne deleže odbojev oziroma verjetnosti odbojev po plasteh. Profili z osnovnico 1 m^2 so neuporabni zaradi več vzrokov. Prvič, pri gostoti odbojev 15,4 m^{-2} pride v povprečju na en voksel le 0,33 odboja. Drugič, talni odtis 40 cm je le malo manjši od dimenzije voksla. Tretjič, napaka GPS pozicioniranja vzorčnih traktov presega 1 m.

Za vse voksle znotraj polmera 5, 10 in 20 m, katerih središča so na lokacijah 950 vzorčnih ploskev, smo izračunali povprečne vrednosti. Povprečno število odbojev v 1 m visokem valju s polmerom 5 m je 26 m^{-2}, pri polmeru 10 m je 105 m^{-2}, pri polmeru 20 m pa 421 m^{-2}. Slika 16 prikazuje surove in korigirane profile. Iz vrednosti vokslov znotraj 1 m debelega valja s premeri 5, 10 in 20 m smo izračunali standardni odklon na posamezni višini profila. Dodatne pojasnjevalne spremenljivke smo izračunali še kot kumulativne vsote povprečij in standardnih odklonov, računano od vrha sestoja proti dnu. Za vsakega od treh polmerov zajema podatkov (5, 10 in 20 m) imamo tako 136 pojasnjevalnih spremenljivk.

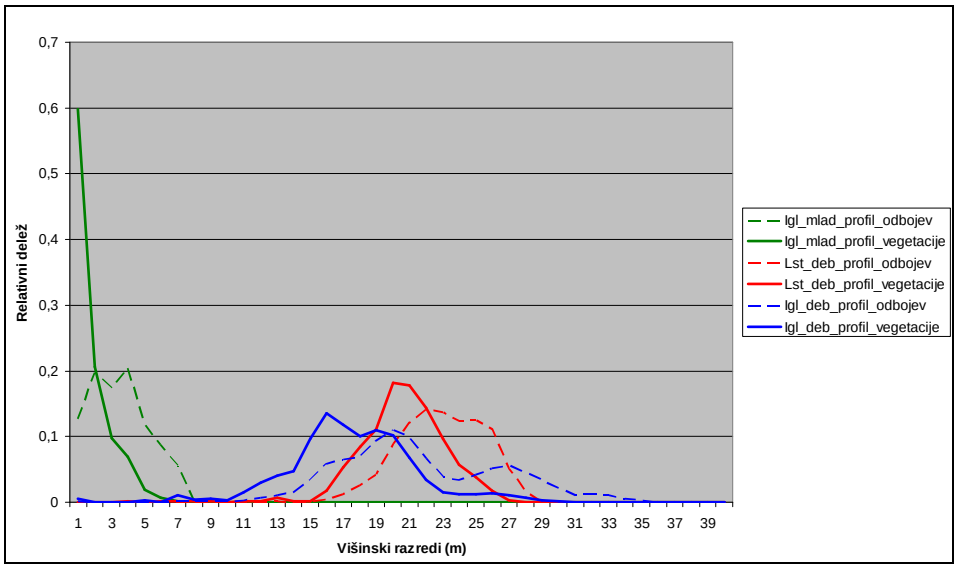

Slika 16: Primerjava surovih in korigiranih profilov za tri tipične sestoje (iglavci-mladovje, listavci-debeljak, iglavci-debeljak).
Figure 16: Comparrison of raw and corrected profiles for three typical forest stands (young coniferous, mature deciduous, mature coniferous).

4.2.2.2 Teksture profilov

Posamezen profil opisuje 34 podatkov, ki pa nič ne povedo o njegovi obliki. Zanimalo nas je, ali bi z vključitvijo metrik, ki opisujejo obliko profila, lahko izboljšali napovedno točnost modelov. Za povzemanje oblike profila bi lahko uporabili na primer polinome, vendar so profili preveč nepravilnih oblik, da bi bilo 34 podatkov dovolj za prilagajanje polinoma dovolj visoke stopnje. Med oblikovne značilnosti profila sodi tudi njegova tekstura. Bogate možnosti kvantifikacije tekstur nudi metoda, ki jo je v domeni digitalnih slik razvil Haralick (1979). Določil je številne indekse, ki opredeljujejo različne vidike teksture na digitalnih slikah. Izračunavajo se iz tako imenovane matrike sosešč in, ki jo je Haralick poimenoval Grey Level Co-occurrence Matrix (GLCM). Dimenzija matrike sosešč in ustreza številu mogočih sivinskih stopenj na sliki. Celica v *i*-ti vrstici in *j*-tem stolpcu matrike za dani piksel na sliki pove, koliko je v njegovi okolici primerov sosešč in med sivinskima stopnjama *i* in *j*. Iz standardizirane matrike sosešč in po Haralicku lahko izračunamo na primer indeks po imenu Contrast, ki ga podaja enačba (3):

$$Contrast = SUM(P_{i,j}\,(i-j)^2) \qquad (3)$$

$P_{i,j}$ je normalizirana frekvenca sosešč in *i*-tega in *j*-tega sivinskega tona. Oklepaj pod kvadratom ima tem večjo vrednost, čim bolj sta si *i* in *j* različna ali drugače povedano, čim bolj se sivinska tona razlikujeta. Vrednost *Contrast* je zato tem večja, čim več imamo sosešč in zelo različnih stopenj sivine.

Ideja Haralickovih matrike sosešč in in teksturnih indeksov se da uporabiti tudi pri naših profilih, le da sosešč ine ne opazujemo v dveh dimenzijah, ampak le v eni. V primerjavi s Haralickom je v našem primeru še ena sprememba – matrika ni simetrična okoli glavne osi, ker je smer sosešč ine v profilu pomembna. Sosešč ine smo beležili do prvega, drugega in četrtega soseda v metrskem profilu. Pred izračunom matrik je bilo treba zvezne vrednosti v profilih diskretizirati. Pri tem je bilo treba najti kompromis med dvema zahtevama:

- z diskretizacijo čim manj popačiti podobo profila, torej naj bo razredov čim več;
- matrika sosešč in naj bo čim manjša, da je čim manjši delež celic matrike enako 0, torej naj bo razredov čim manj.

Meje med razredi morajo biti torej postavljene premišljeno (Slika 17). Osnova za odločanje o mejah je bil seznam vseh vrednosti vseh profilov nad 950 vzorčnimi ploskvami. Ekvidistantna postavitev meja je pokazala približno logaritemski potek frekvenc (Slika 17a), zato smo meje razredov postavili logaritemsko. Preizkusili smo delitev na osem in na štiri razrede (Slika 17b, Slika 17c). Pri delitvi na osem razredov je povprečen delež ničelnih celic v matriki sosešč in 77 %, pri delitvi na štiri razrede pa 46 %, zato smo se odločili za delitev na štiri razrede. Izračunali smo naslednjih 11 teksturnih indeksov: *Contrast*, *Dissimilarity*, *Homogeneity*, *Angular Second Moment*, *Maximum Probability*, *Entropy*, *AEM Mean* (glede na izhodišče), *AEM Mean* (glede na soseda), *Variance* (glede na izhodišče), *Variance* (glede na soseda) in *Correlation*. Način izračuna posameznih indeksov je prikazan v Prilogi B. Vsak indeks smo izračunali glede na tri polmere zajema podatkov in glede na tri rede sosešč in (prvi, drugi in četrti sosed). Poleg tega smo kot pojasnjevalne spremeljivke uporabili tudi vseh 16 vrednosti matrike sosešč in. Za vsakega od treh polmerov zajema imamo tako po 81 pojasnjevalnih spremenljivk.

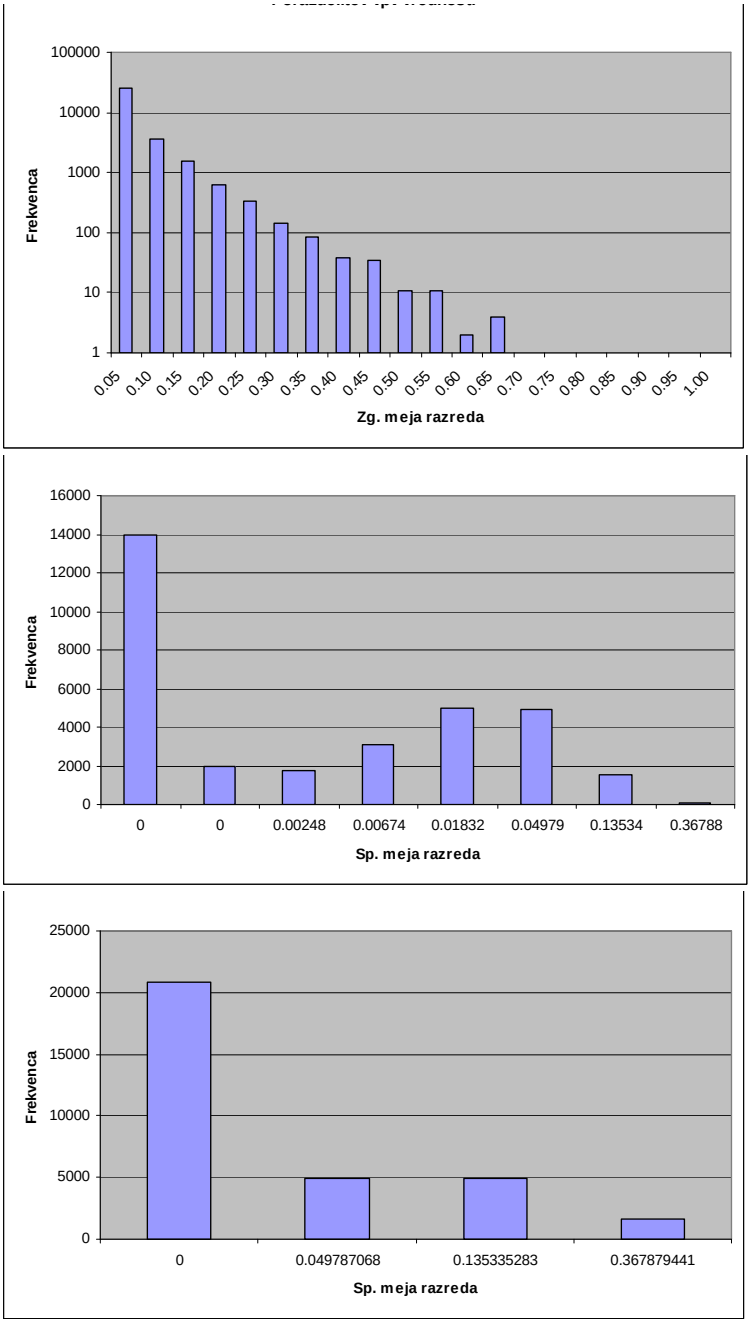

Slika 17: Porazdelitve vrednosti profilov na 950 vzorčnih ploskvah v odvisnosti od načina postavljanja meja med razredi: (a) porazdelitev v 20 razredov glede na ekvidistantno postavitev mej, (b) porazdelitev v 8 razredov glede na logaritemsko postavitev mej, (c) porazdelitev v 4 razrede glede na logaritemsko postavitev mej.
Figure 17: Distribution of profile values at 950 sample plots, in relation to class breaks: (a) distribution into 20 classes according to equidistant class intervals, (b) 8 classes with logarithmic class breaks, (c) 4 classes with logarithmic class breaks.

4.2.2.3 Aeroposnetki

Uporabili smo IR-aerofotografije, ki so bile posnete hkrati z lidarskim snemanjem, in eno leto starejše IR-aerofotografije, ki jih je posnela Geodetska uprava RS. Prve so bile posnete ob začetku vegetacijskega obdobja, druge sredi vegetacije. Oboje so tako predstavljale komplementarne podatke, ki prikazujejo vegetacijo v različnih obdobjih razvoja in s tem

izboljšujejo razlikovanje. Zaradi zmanjšanja vpliva senc smo namesto surovih slik kot osnovo za izračun pojasnjevalnih spremenljivk uporabili vegetacijske indekse NDVI. Kot pojasnjevalne spremenljivke smo za vsako terensko ploskev izračunali aritmetično sredino NDVI pri treh različnih polmerih zajema in standardni odklon NDVI pri treh polmerih. Za vsak polmer smo tako dobili po štiri pojasnjevalne spremenljivke.

4.2.3 Modelno napovedovanje značilnosti gozda

Cilj je bil za konkreten primer testnega območja Slivnica ugotoviti:

1. katere od izbranih ciljnih spremenljivk, ki opisujejo gozd, je mogoče uspešno modelirati in napovedovati s pomočjo izbranih pojasnjevalnih spremenljivk in izbranih načinov modeliranja;
2. kateri način modeliranja je najboljši:
    - strojno naučen ansambelski random forest model za hkratno napovedovanje množice ciljnih spremenljivk (multi target random forest – MTRF),
    - strojno naučen ansambelski bagging model za hkratno napovedovanje množice ciljnih spremenljivk (multi target bagging – MTB),
    - strojno naučen ansambelski random forest za napovedovanje posamezne ciljne spremenljivke (single target random forest – STRF),
    - strojno naučen ansambelski bagging model za napovedovanje posamezne ciljne spremenljivke (single target bagging – STB),
    - linearni regresijski model z izbiro pojasnjevalnih spremenljivk (linear model with feature selction – LMFS); izbira spremenljivk je bila opravljena po metodi avtomatskega postopnega izločanja (stepwise regression),
    - linearni regresijski model brez izbire pojasnjevalnih spremenljivk (linear model – LM); v modelu so uporabljene vse spremenljivke;
3. katere pojasnjevalne spremenljivke so najprimernejše:
    - skupina profili (kratica P): skupina pojasnjevalnih spremenljivk, ki podajajo povprečja normaliziranih in korigiranih frekvenc odbojev, standardni odkloni ter kumulative obojih, kot je razloženo v poglavju 4.2.2.1,
    - skupina ndvi (N): skupina pojasnjevalnih spremenljivk, ki podajajo pretvorjene podatke IR letalskega snemanja, kot je razloženo v poglavju 4.2.2.3,
    - skupina teksture (T): skupina pojasnjevalnih spremenljivk, ki podajajo splošnejši opis oblike vertikalnega lidarskega profila v gozdu in sicer kot kvantifikacijo vzorcev oziroma tekstur, kot je razloženo v poglavju 4.2.2.2,
    - profili + ndvi (PN): kombinacija več osnovnih skupin,
    - profili + teksture (PT): kombinacija več osnovnih skupin,
    - profili + ndvi + teksture (PNT): kombinacija več osnovnih skupin;
4. kako na točnost napovedi vpliva polmer zajema pojasnjevalnih spremenljivk (5, 10 in 20 m) ter dodatno – v primeru svetlobnih značilnosti gozda – zorni kot opazovanja svetlobnih značilnosti (45, 60, 120 in 170°);
5. katero število dreves v ansambelskem modelu je optimalno.

Za strojno učenje ansambelskih modelov iz množice 950 učnih primerov smo uporabili orodje CLUS (Kocev 2011, Kocev in sod. 2007, Struyf in Džeroski 2006, Blockeel in Struyf 2002). Najprej smo s poskusi ugotovili optimalno število podmodelov, in sicer na primeru modela STRF s ciljno spremenljivko delbukev in popolnim naborom pojasnjevalnih spremenljivk. Uporabili smo naslednja števila podmodelov: 10, 20, 40, 80, 160, 320, 640, 1280. Kriterij je

bil 10-kratno navzkrižno preverjan korelacijski koeficient. Kot optimalno število podmodelov se je, ne glede na polmer zajema pojasnjevalnih spremenljivk, izkazalo število 160. To število podmodelov smo potem uporabili pri vseh ansambelskih modelih. Vrednosti pomembnih parametrov za CLUS so bile:

- število podmodelov (Iterations): 160,
- obvejevanje podmodelov (PruneSet): brez obvejevanja,
- največja globina podmodela (MaxDepth): neomejeno.

Regresijske modele smo računali s statističnim paketom R. Pri modelih LMFS smo spremenljivke izbrali po metodi avtomatskega postopnega izločanja (stepwise regression), kot je implementirana v funkciji step statističnega paketa R. Funkcija step kot kriterij za izbiro modelov privzame Akaikejev informacijski kriterij (Akaike's Information Criterion – AIC) (Akaike 1974). Za vsak model smo z 10-kratnim navzkrižnim preverjanjem (cross-validation) na trenažnem vzorcu ocenili Pearsonovo korelacijo med pravimi in modelnimi vrednostmi. Z navzkrižnim preverjanjem smo se izognili lažno visokim korelacijam, ki bi jih dobili pri navadnem preverjanju na trenažnem vzorcu. Navzkrižno preverjanje je po svojih rezultatih blizu preverjanju modelov na neodvisnem vzorcu.

Poskuse modeliranja smo zastavili vzdolž naslednjih dimenzij:

1. 6 tipov modelov,
2. 6 skupin pojasnjevalnih spremenljivk,
3. 3 polmeri veljavnosti spremenljivk,
4. 24 ciljnih spremenljivk, od tega se jih 15 nanaša na drevesno sestavo in temeljnico sestoja, 9 pa na svetlobne razmere (slednje so definirane pri štirih različnih zornih kotih opazovanja – zorni kot opazovanja je torej za to skupino ciljnih spremenljivk 5. dimenzija poskusov).

Skupno število poskusov torej znaša 6 * 6 * 3 * 15 + 6 * 6 * 3 * 9 * 4 = 5508. Zaradi velikega števila poskusov smo posamezne vplive na točnost napovedi presojali z enostavnim povzemanjem korelacijskih koeficientov (maksimum ali aritmetična sredina upoštevanih korelacijskih koeficientov) glede na vsako od zgoraj prikazanih dimenzij poskusov. Pri tem smo za osnovo uporabili le tiste skupine modelov in tiste ciljne spremenljivke, kjer je vsaj eden od modelov v skupini dosegel korelacijski koeficient 0,7. Takih ciljnih spremenljivk je bilo 8 od 24, zajetih v naši raziskavi.

Izjema je bil vpliv izbora pojasnjevalnih spremenljivk, kjer smo poleg presoje vpliva glavnih skupin pojasnjevalnih spremenljivk (P, N, T, PN, PT, PNT) dodatno rangirali še posamezne pojasnjevalne spremenljivke. Rangiranje je bilo opravljeno posebej za vsako od ciljnih spremenljivk in za vsakega od treh polmerov veljavnosti pojasnjevalnih spremenljivk, pri čemer smo upoštevali celoten nabor pojasnjevalnih spremenljivk (217 za vsak polmer veljavnosti). Za rangiranje smo uporabili program Weka (www.cs.waikato.ac.nz/ml/weka/) in metodo Relief (weka.attributeSelection.ReliefFAttributeEval) s privzetimi vrednostmi parametrov. Metoda Relief (Kira in Rendell 1992, Kononenko 1994, Robnik-Sikonja in Kononenko 1997) oceni vrednost posamezne pojasnjevalne spremenljivke s ponavljajočim se vzorčenjem primerov in presojo vrednosti spremenljivke za najbližji primer enakega razreda in različnega razreda. Metoda je primerna tako za numerične kot tudi diskretne ciljne spremenljivke.

Za vsako pojasnjevalno spremenljivko smo znotraj skupin sorodnih ciljnih spremenljivk izračunali povzetek rangov:

- kot minimum rangov, tj. najboljši rang, ki ga je ta pojasnjevalna spremenljivka zasedla pri kateri koli ciljni spremenljivki znotraj dane skupine ciljnih spremenljivk,
- kot povprečje vseh rangov te pojasnjevalne spremenljivke znotraj dane skupine ciljnih spremenljivk.

Sorodne ciljne spremenljivke smo za ta namen združili v naslednje skupine:

- skupina Drevesne vrste vključuje deleže drevesnih vrst (13 spremenljivk: delbukev …),
- 4 skupine Svetloba_x vključuje vse s hemisferno kamero izmerjene spremenljivke pri zornem kotu x, $x \in \{45^o, 60^o, 120^o, 170^o\}$ (4 * 9 spremenljivk: openness_x …),
- skupina Svetloba_vsi_koti združuje vse s hemisferno kamero izmerjene spremenljivke, ne glede na zorni kot (36 spremenljivk),
- skupina Drugo vključuje preostali dve spremenljivki – gha in deligl,
- skupina Vse.

4.2.4 Kartiranje rezultatov

Najtočnejše modele (katerih korelacija presega 0,7) za napovedovanje značilnosti gozda smo uporabili za izdelavo rastrskih kart, ki te značilnosti prikazujejo. Popoln nabor pojasnjevalnih spremenljivk smo izračunali le za 950 vzorčnih ploskev po metodah, ki smo jih opisali v poglavju 4.2.2. Pred izdelavo kart pa smo tiste pojasnjevalne spremenljivke, ki se pojavljajo v izbranih modelih, izračunali tudi v obliki rastrskih kart za celoten prostor testnega območja Slivnica. Zaradi enostavnejše implementacije modelov so imele vse karte pojasnjevalnih spremenljivk enako fizično ločljivost, to je 4 m, ne glede na vsebinsko ločljivost kart pojasnjevalnih spremenljivk, ki je odvisna od polmera zajema surovih podatkov (5, 10 in 20 m). Izračun rastrskih kart značilnosti gozda je potekal na ravni vsakega piksla posebej. Večino opravil pri pretvorbi surovih podatkov v pojasnjevalne spremenljivke, združevanju podatkov v učni vzorec, implementaciji modelov in podobno, smo opravili z lastnimi programi, napisanimi v jeziku Python, osnovne rastrske operacije pa smo opravili z orodjem Idrisi Andes (www.clarklabs.org). Pythonski programi so na voljo pri avtorju, na tem mestu pa jih zaradi velikega obsega ne objavljamo.

Lastnosti gozda, ki smo jih modelno napovedovali, se v prostoru zvezno oziroma gradientno spreminjajo. Prostorski pojavi, ki se gradientno spreminjajo, se v geografskih informacijskih sistemih tipično prikazujejo z rastrskimi kartami. Nasprotno pa v gozdarski praksi prevladuje vektorski zapis podatkov, predvsem zaradi točnega predstavljanja mej, ki so pri gospodarjenju s prostorom pomembne. Slovensko gozdarstvo pozna dve osnovni obliki prostorske delitve – upravno delitev na gozdne odseke, ki se na višjih ravneh združujejo v oddelke in naprej do območnih enot, ter ekosistemsko delitev na gozdne sestoje, ki so osnova za gozdnogojitveno načrtovanje. Zato smo tudi sami izdelali vektorsko sestojno karto. Uporabili smo lidarske in aerofoto podatke in dobro poznane avtomatizirane postopke. Pri tem smo se vsebinsko želeli čim bolj približati fototerestrični metodi izdelave sestojnih kart (Hočevar 1995, MKGP 2010), po kateri so kriteriji za razmejevanje gozda v sestoje: razvojna faza oziroma starost sestoja, sklep sestoja in mešanost drevesnih vrst. Postopek po fototerestrični metodi vključuje razmejevanje in fotointerpretacijo na digitalnih ortoposnetkih in stereofotoposnetkih z vmesno kontrolo na terenu. Podatkov za razvojno fazo oziroma starost nismo imeli in smo jih nadomestili s podatki o višini dreves. Podatke o sestojnem sklepu smo nadomestili s karto odprtosti, ki je komplement sklepa (gl. poglavje 4.2.1.1), podatke o mešanosti pa s kartami deležev treh dominantnih drevesnih vrst.

Višine dreves smo razbrali iz DMK. DMK prikazuje lidarsko izmerjeno višino krošenj, izdelali pa smo ga po naslednjem postopku:

1. za vse prve in edine odboje smo s pomočjo DMR izračunali višino nad tlemi;
2. za vsak piksel na rastrskem DMK z ločljivostjo 1 m smo ugotovili višino najvišjega lidarskega odboja za vse prve in edine odboje, katerih vertikalna projekcija pade v ta piksel;
3. za piksle, ki niso vsebovali nobenega odboja, smo višino DMK interpolirali iz najbližjih okoliških pikslov z znanimi višinami krošenj;
4. ugotovili smo, da je na DMK iz točke (3) 2183 pikslov, katerih višina presega 50 m; očitno gre za napake v lidarskih podatkih, zato smo te piksle nadomestili s povprečji v okolici 3 x 3.

Višina drevesa je definirana kot višinska razlika med panjem in vrhom drevesa. Pri iglavcih je vrh oziroma najvišja točka krošnje navadno navpično nad panjem, pri listavcih pa ni nujno tako. Vrhove dreves je načeloma mogoče razločevati na DMK, lociranje panjev pa je pri dani gostoti podatkov nemogoče. Merjenje lokacij zelo velikega števila dreves na terenu z GPS je tudi neizvedljivo, zato smo višine dreves odčitavali iz DMK ob predpostavki, da je vrh drevesa točno nad panjem. Taka predpostavka seveda lahko vodi do napak, še posebej na strmem terenu. Velikosti tovrstnih napak nismo ocenili.

Druga vrsta napak višine dreves nastopi zaradi sistematičnega podcenjevanja drevesnih višin, kar je znana pomanjkljivost diskretnega lidarja. Nastopi zato, ker laserski žarek le včasih zadene točno vrh drevesa, večina prvih odbojev pa je pod vrhovi dreves. To napako smo ocenili s terenskim merjenjem drevesnih višin po trikotniški metodi z orodjem Vertex III (HAGLÖF, Švedska). Na ravnem terenu smo izbrali 257 osamljenih dreves različnih drevesnih vrst (Preglednica 6). Drevesa smo izbirali na digitalnem ortofoto posnetku DOF in s pomočjo DMK na petih zaokroženih delih testnega območja Slivnica. Ta območja so izbrana tako, da so logistično dostopna in da je zastopan čim širši izbor drevesnih vrst. Drevesa so morala biti osamljena zaradi zagotovitve točnega prostorskega sovpadanja terenskih izmer in lidarskih podatkov. Poleg tega je le pri osamljenih drevesih mogoča natančna vizura vrha in dna drevesa, kar v strnjenem gozdu ni mogoče. Vsako drevo smo izmerili šestkrat z vsakega od dveh stojišč, oddaljenih za drevesno višino od panja in razmaknjenih za 90º glede na panj. Končna terenska ocena višine je bila enaka povprečju 12 meritev.

Preglednica 6: Pregled drevesnih vrst v terenskem vzorcu za kontrolo višin.
Table 6: Overview of represented tree species in the field sample for height control.

Skupina	Drevesna vrsta	Število dreves	Skupaj
Iglavci	Smreka	79	131
	Bor	51	
	Brin	1	
Listavci	Hrast	42	126
	Lipa	9	
	Češnja	7	
	B. gaber	6	
	Mokovec	5	
	Breza	5	
	Hruska	3	
	Bukev	3	
	Javor	3	
	Veliki jesen	3	
	Mali jesen	3	
	Trepetlika	2	
	Č. gaber	2	
	M. jesen	2	
	Oreh	1	
	Jerebika	1	
	Jablana	1	
	Ostali listavci	28	
Skupaj		257	257

Vrhove dreves smo na DMK poiskali z lastno implementacijo znane metode lokalnih maksimumov. Najprej smo v okviru plavajočega okna (angl. flowting window) z določenim polmerom iskali lokalno najvišje piksle na DMK, pri čemer smo upoštevali le tiste, ki so višji od 1 m. Tako smo za večino dreves, še posebej za listavce, ki imajo zaobljene krošnje, tipično dobili več kandidatnih pikslov. Piksle, ki pripadajo enemu drevesu, smo prepoznali po tem, da se med seboj dotikajo. Lokacijo vrha drevesa smo določili kot težišče vseh kandidatnih pikslov, ki pripadajo temu drevesu (Slika 18). Preizkusili smo različne polmere iskanja od 1 do 10 m (Slika 19). Vizualna ocena rezultatov je pokazala, da je polmer 5 m optimalen za naše testno območje (Slika 18).

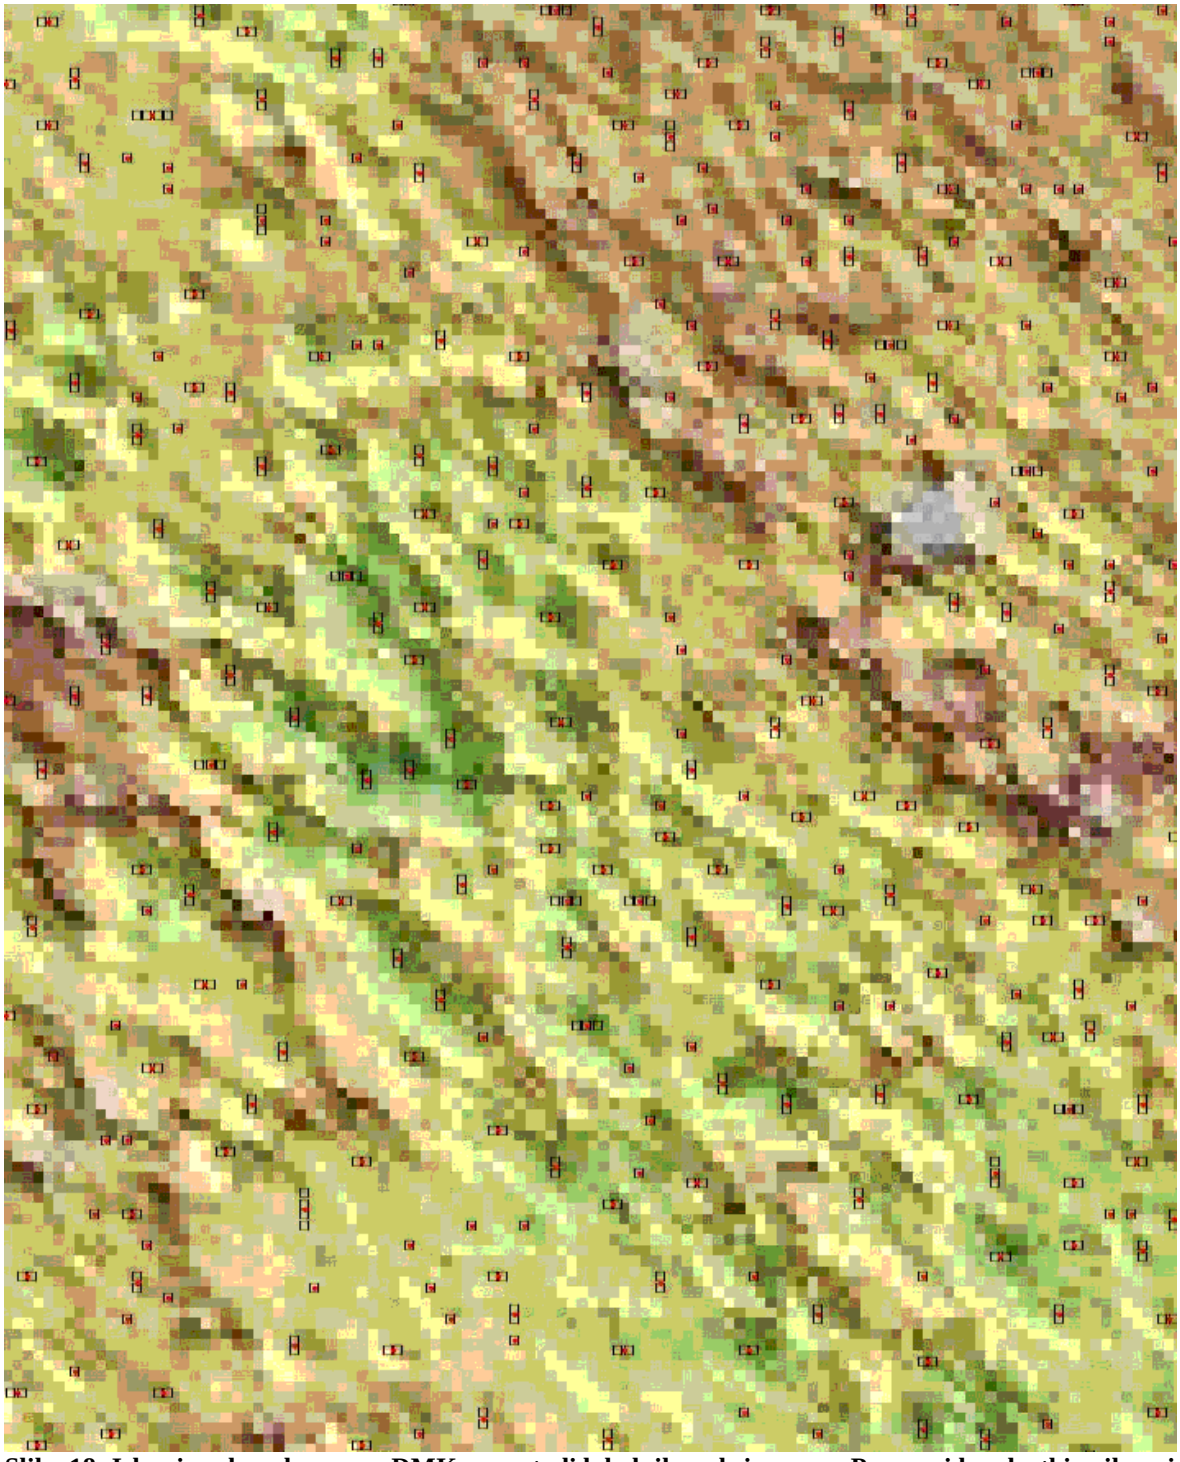

Slika 18: Iskanje vrhov dreves na DMK po metodi lokalnih maksimumov. Prozorni kvadratki prikazujejo kandidatne piksle pri polmeru iskanja 5 m, rdeče pike pa prepoznane vrhove dreves, ki jih izračunamo kot težišča kandidatnih pikslov. Kandidatne piksle, ki pripadajo istemu drevesu, prepoznamo po tem, da so neposredni sosedje.

Figure 18: Searching for tree tops on the digital canopy model according to the local maximum method. The transparent squares indicate candidate pixels at a 5 m search radius, the red dots indicate the identified tree tops, computed as the centers of gravity of the corresponding candidate pixels. The candidate pixels, belonging to the same tree are identified by being immediate neighbours.

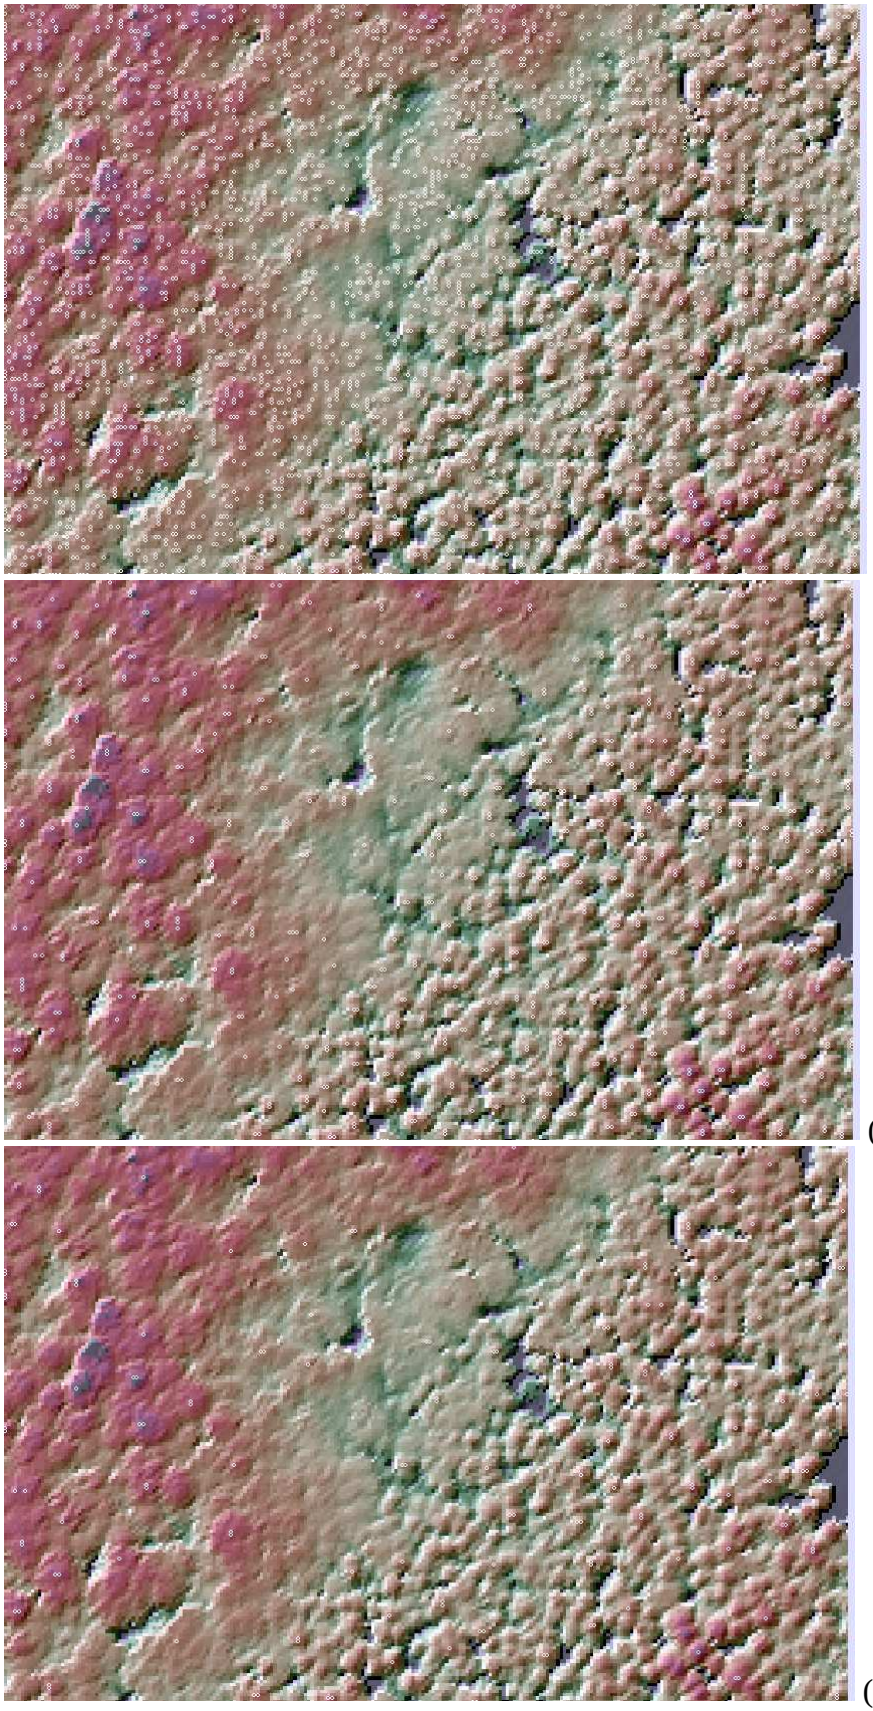

(a)

(b)

(c)

Slika 19: Vpliv polmera iskanja na iskanje vrhov lokalnih maksimumov: (a) 2 m, (b) 5 m, (c) 10 m.
Figure 19: Influence of search radius on finding the local maxima: (a) 2 m, (b) 5 m, (c) 10 m.

Sestojne višine smo računali kot povprečje višin vseh dreves, prepoznanih znotraj meja sestoja. Na DMK so vidna le drevesa zgornjega sloja (razen izjem v sestojnih vrzelih), zato na tak način prepoznana drevesa pripadajo zgornjemu socialnemu položaju. Po Čoklu (1977) zato naša sestojna višina ustreza srednji višini dreves prvega socialnega položaja in je najboljši indikator bonitete rastišča (produkcijska sposobnost rastišča). Tako izračunano sestojno višino smo korigirali zaradi prej omenjenega lidarskega podcenjevanja višin, tako da smo vsem sestojnim višinam prišteli povprečno napako podcenjevanja, ocenjeno na vzorcu vseh dreves.

Sestojem smo pripisali tudi pripadajoče povprečne vrednosti iz rastrskih kart modelno napovedanih gozdnih značilnosti, pri katerih korelacija presega 0,7.

Razmejevanje sestojev je potekalo takole:

1. izdelali smo masko gozda po naslednjih kriterijih:
    a. višina vegetacije na DMK >= 1 m,
    b. raba tal na karti kmetijske rabe tal (MKGP) ni naselje;
2. iz maske gozdov smo izbrisali vse zaplate gozda in vse gozdne jase, manjše od 2500 m^2;
3. znotraj maske gozdov smo prostor razčlenili s segmentacijo slik z eCognition. Za segmentacijo smo uporabili DMK (80 % teže), sliko odprtosti (10 % teže) ter prvo glavno komponento slik deležev bukve, jelke in bora (10 % teže). Vrednost ostalih parametrov v eCognition je bila scale = 100; shape = 0,1; compactness = 0,6;
4. združili smo vse segmente, katerih površina je manjša od 2500 m^2. Pri odločitvi, kateremu od sosedov pridružiti dani segment, smo upoštevali njihovo vsebinsko podobnost. Vsebinsko podobnost smo ugotavljali z razvrščanjem v skupine (angl. clustering) segmentov glede na pripadajoča povprečja vrednosti DMK, odprtosti in prve glavne komponente deležev drevesnih vrst.

4.3 Rezultati

Vsi napovedovalni modeli so na priloženem DVD. Iz njih izvedene karte so v Prilogi D.

Vpliv števila podmodelov na točnost ansambelskega modela smo preiskusili na primeru modela STRF za delbukev s popolnim naborom pojasnjevalnih spremenljivk (PNT), in sicer posebej za vsak polmer veljavnosti pojasnjevalnih spremenljivk posebej . Uporabili smo naslednja števila podmodelov: 10, 20, 40, 80, 160, 320, 640, 1280. Kriterij je bil 10-kratno navzkrižno preverjan korelacijski koeficient. Poskus je pokazal, da točnost v danem primeru (skoraj) neha naraščati pri 160 drevesih, ne glede na polmer veljavnosti spremenljivk. To število dreves smo potem uporabili za vse ansambelske modele v študiji.

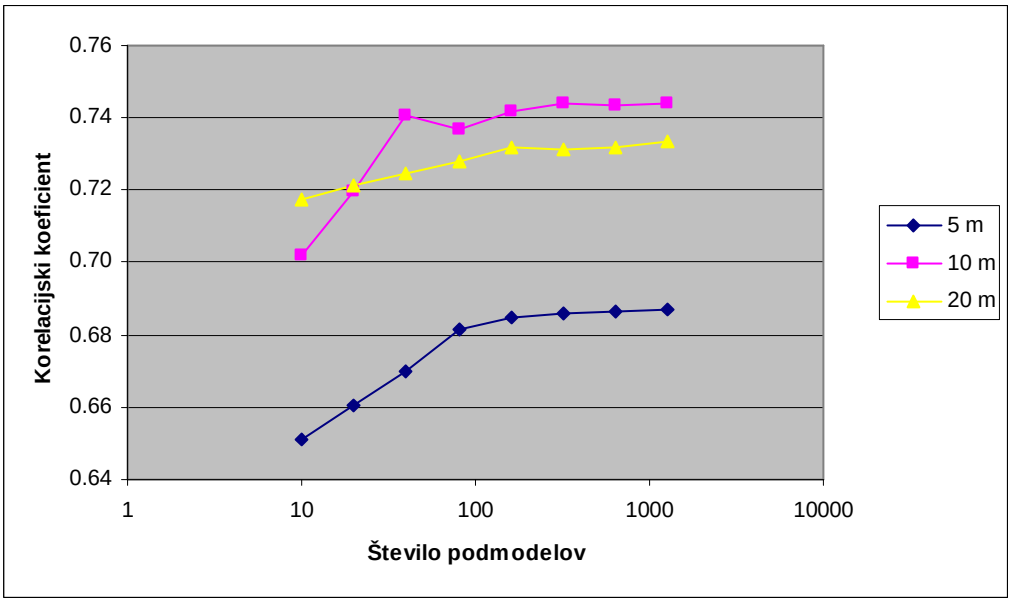

Slika 20: Vpliv števila podmodelov na točnost ansambelskega STRF modela za delbukev, upoštevajoč vse razpoložjive pojasnjevalne spremenljivke. Prikazani so vplivi pri vseh treh polmerih veljavnosti pojasnjevalnih spremenljivk 5 m, 10 m in 20 m.
Figure 20: Influence of the number of sub-models on the accuracy of the ensemble STRF model for delbukev (percentage of beech), taking into account all available explanatory variables. Influences are shown separately for all three validity radii of explanatory variables 5 m, 10 m in 20 m.

Če kot kriterij uporabnosti modela vzamemo mejno vrednost Pearsonovega korelacijskega koeficienta 0,7, potem se v naših poskusih za modeliranje izkaže primernih osem ciljnih spremenljivk od 21 (Preglednica 7). Od tega se štiri spremenljivke (delbukev, deljelka, delbor, deligl) nanašajo na drevesno sestavo (od 13), štiri spremenljivke (openness, indirectsitefactor, ppfddiffuseunder, lai2000lin) pa se nanašajo na svetlobne razmere (od devetih). Od tu naprej bomo za vse presoje vplivov na točnost modelov upoštevali le omenjenih osem izbranih ciljnih spremenljivk, razen če bo posebej drugače navedeno.

Za izbrane ciljne spremenljivke koeficienti korelacije njihovih modelov segajo od 0,76 do 0,83. Razmeroma nizke korelacije, ki jih kažejo celo najboljši modeli, pripisujemo predvsem naslednjim dejavnikom:

1. velika raznolikost drevesnih vrst in slaba prepoznavnost oblik krošenj: predmet raziskave je večinoma mešan dinarski gozd različnih združb jelke in bukve z veliko raznovrstnostjo drevesnih vrst in razvojnih faz celo na majhnih površinah, kjer je določanje deleža posameznih drevesnih vrst iz lidarskih podatkov težavnejša naloga kot v vrstno in oblikovno mnogo bolj homogenih gorskih ali borealnih gozdovih;
2. v primerjavi z gorskimi in borealnimi gozdovi se krošnje v testnem območju Slivnica veliko tesneje prepletajo, zato celo lidarski 3D-podatki z gostoto 15,4 m^{-2} ne nudijo dovolj informacij o obliki krošnje posameznih dreves, kar bi sicer lahko bil prepoznaven znak posamezne drevesne vrste (Lee in Lucas 2007, Jang in sod. 2008). Raziskave, predstavljene v poglavju 4.1.1, so v podobnih okoliščinah pokazale uporabnost cenejših in za obdelavo enostavnejših multispektralnih ali hiperspektralnih slikovnih 2D-podatkov. Kot bo vidno iz kasnejše razlage, to potrjujejo tudi naši rezultati, saj smo pri treh od štirih najboljših modelov za deleže drevesnih vrst z uporabo zgolj IR-aerofoto podatkov dobili enake ali boljše rezultate kot z uporabo zgolj lidarskih podatkov. Kot najboljša pa se je izkazala kombinacija lidarskih in IR-podatkov;

3. velikost vzorca: korelacija drevesnih spremenljivk sovpada s prisotnostjo drevesne vrste v vzorcu oziroma številom podatkov, kjer je delež drevesne vrste večji od 0 (Slika 21). Z drugimi besedami, uporabne modele smo dobili za tiste ciljne spremenljivke, ki imajo dovolj velik trenažni vzorec. Izjema je delež bora, kjer korelacija znaša 0,78, čeprav je neničelnih vzorcev le 23 % (219 od 950);
4. deloma nenatančen način zbiranja trenažnih podatkov na terenu: zaradi omejenega časa za terensko delo smo podatke o deležih drevesnih vrst zbirali z okularnimi ocenami deležev v sklepu krošenj. To je sicer v gozdarstvu uveljavljena hitra metoda, kjer pa se ni mogoče povsem izogniti subjektivnim vplivom. Te smo skušali zmanjšati na dva načina: z uporabo ene same ekipe popisovalcev (kar odpravi sistematične razlike med ekipami) in z začetnim usposabljanjem popisovalcev. Bolj objektiven način bi bil merjenje deležev drevesnih vrst v temeljnici, kar pa bi terensko delo bistveno upočasnilo in s tem močno zmanjšalo velikost učnega vzorca. Vpliv subjektivnosti na točnost terenskih ocen deležev drevesnih vrst nakazuje primerjava korelacijskih koeficientov modelov, ki se nanašajo na drevesne vrste (kjer je šlo za subjektivne ocene trenažnega vzorca) s korelacijskimi koeficienti modelov, ki se nanašajo na svetlobne razmere (kjer je šlo za objektivne meritve). V prvem primeru je povprečje najboljših štirih modelov enako 0,78, v drugem primeru pa 0,81.

Razlog za prostorsko nepopolno sovpadanje terenskih trenažnih in daljinsko zaznanih pojasnjevalnih podatkov je slabo delovanje GPS v težavnem terenu in pod sestojnim sklepom. Horizontalna položajna natančnost, ki jo je poročal GPS, je znašala med 0,9 in 7,7 m, v povprečju pa 2,4 m. Najbolj bi tovrstna napaka morala vplivati na modele, kjer uporabljamo pojasnjevalne spremenljivke z najmanjšim premerom zajema. V prid tej razlagi govori dejstvo, da je povprečje korelacijskih koeficientov pri najboljših štirih modelih, ki se nanašajo na drevesno sestavo (delbukev, deljelka, delbor, deligl), za polmer zajema 5 m nižje (0,71) kot za polmera 10 in 20 m (obakrat 0,77).

Preglednica 7: Ciljne spremenljivke, rangirane po doseženem modelnem koeficientu korelacije. Debelo uokvirjene so tiste, katerih korelacija presega 0,7 in le te so upoštevane v nadaljnjih presojah. Legenda spremenljivk je v Prilogi A.
Table 7: Target variables, ranked according to achieved model correlation. Bold framed are the ones with correlation coefficient exceeding 0,7 and only those are taken into account in further judgments. Legend of the variables is given in Appendix A.

Ciljna spremenljivka	Korelacijski koeficient	Tip modela	Pojasnjevalne spremenljivke	Polmer veljavnosti	Zorni kot
openness	0.83	MTRF	PN	10 m	170º
indirectsitefactor	0.82	MTRF	PN	5 m	120º
ppfddiffuseunder	0.82	MTRF	PN	5 m	120º
delbukev	0.78	STB	PN	10 m	
deljelka	0.78	MTB	PN	20 m	
delbor	0.78	STB	PN	20 m	
deligl	0.77	STB	PN	10 m	
lai2000lin	0.76	LMFS	PN	10 m	120º
delsmreka	0.69	MTB	PNT	20 m	
totalsitefactor	0.66	LMFS	PN	5 m	120º
ppfdtotalunder	0.66	LMFS	PN	5 m	120º
lai2000glin	0.64	LMFS	PN	5 m	120º, 170º
directsitefactor	0.62	LMFS	PN	5 m	120º, 170º
ppfddirectunder	0.62	LMFS	PN	5 m	120º, 170º
gha	0.60	LMFS	PN	10 m	
delbgaber	0.60	MTRF	PNT	20 m	
delostalilst	0.58	MTB	PN	10 m	
delcgaber	0.52	MTB	PN	10m	
deljavor	0.48	LMFS	PNT	20 m	
delmjesen	0.43	MTRF	PN	20 m	
delhrast	0.35	LMFS	PNT	10 m, 20 m	
delvjesen	0.33	LMFS	PN, PNT	10 m, 20 m	
delmacesen	0.00				
delostaliigl	0.00				

Vpliv izbire pojasnjevalnih spremenljivk odraža Preglednica 8, kjer smo podali povprečne korelacije vseh modelov za posamezen par ciljna spremenljivka / skupina pojasnjevalnih spremenljivk. Pri ciljnih spremenljivkah, ki se nanašajo na drevesno sestavo, k točnosti napovedi največ prispeva kombinacija skupin P in N, od osnovnih skupin pa največ prispeva N. To se sklada z ugotovitvami številnih avtorjev (Leckie in sod. 2003, McCombs in sod. 2003, Popescu in Wynne 2004, Hilker in sod. 2008, Suratno in sod. 2009, Morsdorf in sod. 2009, Breidenbach in sod. 2010), da so multispektralni podatki boljši deskriptor za drevesne vrste, kot lidarski podatki (velja za diskretni letalski lidar!). Pri ciljnih spremenljivkah, ki se nanašajo na svetlobne razmere, sta najprimernejši kombinaciji PN in PNT, od osnovnih skupin največ prispevata P in T, N pa zelo malo. To si razlagamo s tesno vsebinsko povezanostjo lidarskih gostot (ki so osnova za izračun spremenljivk P in T) s količino listja in vejevja in posredno z zastrtostjo neba, kar vpliva na svetlobne razmere.

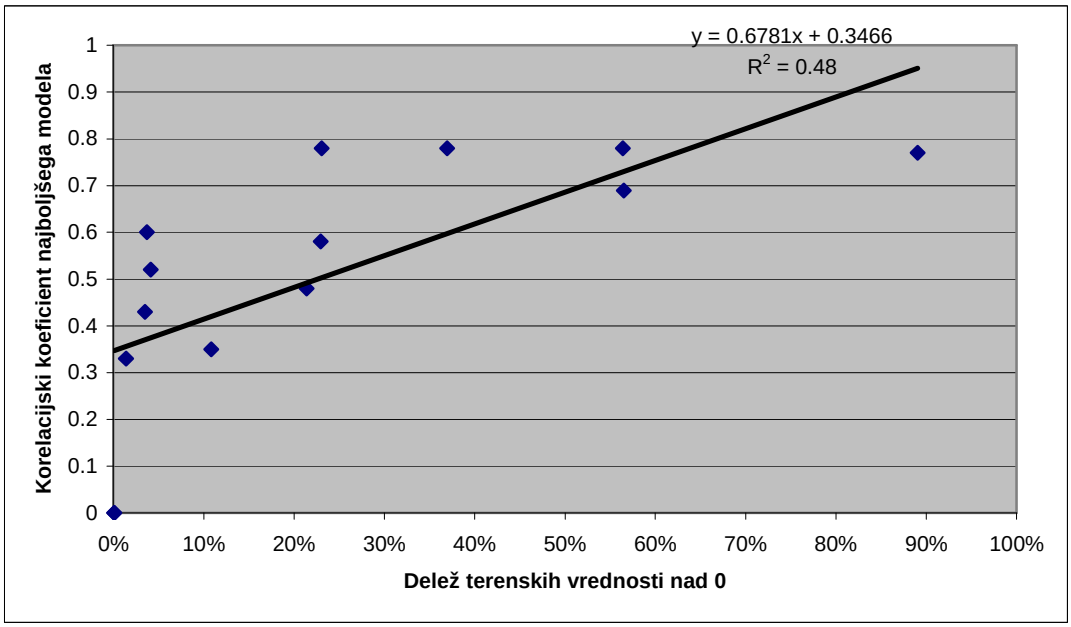

Slika 21: Primerjava deležev terensko ocenjenih neničelnih deležev drevesnih vrst v učnem vzorcu s korelacijami najboljšega modela za ciljno spremenljivko.
Figure 21: Comparrison of percentages of estimated non-zero percentages of tree species in the training sample vs. correlation coefficients of the best model per target variable.

Preglednica 8: Povprečne korelacije vseh modelov za posamezni par ciljne spremenljivke in skupine pojasnjevalnih spremenljivk.
Table 8: Average correlatiosn of all models for a pair target variable / group of explanatory variables.

	P	N	T	PN	PT	PNT
deligl	0.54	0.75	0.38	0.77	0.56	0.76
delbukev	0.66	0.71	0.43	0.78	0.66	0.77
deljelka	0.71	0.60	0.62	0.78	0.71	0.78
delbor	0.66	0.58	0.50	0.78	0.67	0.76
Splošno	0.64	0.66	0.48	0.78	0.65	0.77

(a)

	P	N	T	PN	PT	PNT
openness	0.83	0.39	0.75	0.83	0.82	0.82
lai2000lin	0.75	0.39	0.69	0.76	0.76	0.76
indirectsitefactor	0.81	0.36	0.78	0.82	0.81	0.82
ppfddiffuseunder	0.81	0.36	0.78	0.82	0.81	0.82
Splošno	0.80	0.38	0.75	0.81	0.80	0.81

(b)

Preglednica 9 prikazuje povprečne range najpomembnejših pojasnjevalnih spremenljivk. Če opazujemo range z vsemi ciljnimi spremenljivkami, je najvišje uvrščena ena od teksturnih pojasnjevalnih spremenljivk, tej pa sledi nekaj spremenljivk, ki opisujejo lidarske profile; slednjih je tudi največ uvrščenih med prvih 40. Izrazito izstopajo spodnje plasti profilov bliže tlom oziroma kumulative od vrha sestoja skoraj do tal. Sklepamo, da so ciljne spremenljivke v tej raziskavi na splošno povezane s strukturo rastlinstva po celotni višini profila in ne le v višjih slojih sestoja. Manj je teksturnih pojasnjevalnih spremenljivk. Čeprav v tem delu preglednice opazimo le tri pojasnjevalne spremenljivke iz aeroposnetkov, pa to predstavlja kar 75 % tovrstnih spremenljivk.

Če opazujemo range, izračunane le znotraj ciljnih spremenljivk skupine Drevesne vrste, so med prvimi petimi pojasnjevalnimi spremenljivkami vse tiste, ki so izračunane iz IR-aeroposnetkov, kar ponovno potrjuje pomen multispektralnih podatkov za napovedovanje

drevesnih vrst v primerjavi z lidarskimi podatki. Med prvimi 40 najboljšimi je sicer največ tistih, ki opisujejo lidarske profile. Predvsem so zastopane srednje plasti med 8 in 17 metri nad tlemi. Ta višinski interval sovpada z najpogostejšimi višinami krošenj na DMK (Slika 22), zato sklepamo, da je višina vegetacije med pomembnejšimi prediktorji drevesne vrste.

Pri skupini ciljnih spremenljivk Svetloba_vsi_koti so IR-spremenljivke bolj v ozadju – prva je na 19. mestu. Spet prevladujejo spremenljivke, ki opisujejo lidarske profile, druge po številu so teksturne spremenljivke. Sklepamo, da so svetlobne značilnosti sestoja, kot jih zaznava hemisferna kamera, bolj povezane z izrazitostjo in obliko lidarskega profila (in torej vertikalno strukturo sestoja) kakor pa z multispektralnimi podatki letalskega snemanja.

Zaradi zelo različne številčnosti posameznih skupin pojasnjevalnih spremenljivk je treba pogledati tudi povprečne range skupin pojasnjevalnih spremenljivk (Preglednica 10). Najboljši povprečji imata skupini dof_avg in dof_std, torej povprečja in variance NDVI vrednosti na IR-aeroposnetkih. Izstopajo tudi teksturne skupine spremenljivk haralick_x in naem_x, ki opisujejo soseščine v profilih in oblikovitost profilov. Najmanj so pomembne skupine, ki podajajo gostoto oblaka in njegovo variabilnost. Deloma gre izrazito prednost IR-aerofoto podatkov pripisati njihovi relativno tesni povezanosti s ciljnimi spremenljivkami, deloma pa tudi preštevilnosti spremenljivk, ki ostalim skupinam znižujejo povprečja. Druge skupine so namreč precej bolj raznolike in vsebujejo poleg zelo pomembnih pojasnjevalnih spremenljivk, kot so avg_vpv_4, avg_vpv_5, avg_vpv_6 in naem31_2, ki se pojavijo v vseh treh izborih (Preglednica 9), tudi številne druge, ki so na dnu lestvic. To ilustrira primer iz skupine naem_x, kjer je naem30_2 najbolje rangirana pojasnjevalna spremenljivka, naem02_4 pa najslabše rangirana (upoštevajoč vse ciljne spremenljivke).

Če kot najmanj pomembne pojasnjevalne spremenljivke opredelimo tiste, ki se na zadnjih 40 mestih pojavijo v vseh treh skupinah ciljnih spremenljivk, ki jih prikazuje Preglednica 9, potem lahko sklenemo, da so vrhnje plasti oblaka najmanj pomembne za napovedovanje naših ciljnih spremenljivk. Te spremenljivke so (legenda spremenljivk je v Prilogi A): avg_vpv_21, avg_vpv_23, avg_vpv_24, avg_vpv_25, stdev_vpv_21, stdev_vpv_23, stdev_vpv_24, stdev_vpv_25, stdev_vpv_27, stdev_vpv_28, stdev_vpv_29, stdev_vpv_30, stdev_vpv_kumul_100do25, stdev_vpv_kumul_100do26, stdev_vpv_kumul_100do27, stdev_vpv_kumul_100do28, stdev_vpv_kumul_100do29, stdev_vpv_kumul_100do30. Nepomembnost naštetih spremenljivk razlagamo z dejstvom, da kažejo vrednosti profilov (precej) nad povprečno višino dreves in je zato njihova vrednost večinoma enaka 0. Povprečna višina vegetacije na DMK (pikslov, kjer je DMK >= 1 m) znaša 15,2 m, povprečna višina zaznanih vrhov dreves[2] pa 18,1 m (naj spomnimo, da DMK prikazuje višine vseh vidnih delov krošenj, ne le vrha).

Iz gornjega seznama nepomembnih spremenljivk pa je vidno tudi, da na njem ni najvišjih treh plasti oblaka. Te so nekje pri sredini vseh treh lestvic. Ker v modelih nismo nikjer izrecno uporabili višine rastlinstva (ki jo določa najvišja točka oblaka na določeni površini), sklepamo, da zgornje tri plasti profilov v modelih služijo kot nadomestek za ugotavljanje prisotnosti visokih dreves, saj visoka drevesa vplivajo na svetlobne razmere (skupina Svetloba), njihova prisotnost pa je hkrati tudi povezana z deleži nekaterih dominantnih drevesnih vrst.

[2] V testnem območju Slivnica smo zaznali 1,4 milijona dreves, oziroma 160 dreves na hektar. Glede na metodo zaznavanja, se ta številka nanaša na drevesa zgornjega socialnega položaja.

Preglednica 9: Razvrstitev najuspešnejših 40 (od 217) pojasnjevalnih spremenljivk po povprečnih rangih doseženih preko vseh ciljnih spremenljivk posamezne skupine in združeno za vse 3 polmere veljavnosti. Majhna vrednost povprečnega ranga pomeni, da pojasnjevalna spremenljivka dobro pojasnjuje ciljno spremenljivko. Legenda spremenljivk je v Prilogi A.
Table 9: Ranking of the best 40 (out of 217) explanatory variables according to the average ranks, achieved over all target variables of a group, irrespective of radius of validity. Small value of the average rank indicate that the explanatory variable is a good predictor of the target variable. Legend of the variables is given in Appendix A.

	Vse ciljne spremenljivke, vsi polmeri		Ciljne spremenljivke "Drevesne vrste", vsi polmeri		Ciljne spremenljivke "Svetloba, vsi koti", vsi polmeri	
	Pojasnjevalna spremenljivka	Povprečni rang	Pojasnjevalna spremenljivka	Povprečni rang	Pojasnjevalna spremenljivka	Povprečni rang
1	naem30_2	38.1	dof_ndvi_geoin_avg	51.9	naem30_1	4.0
2	avg_vpv_1	38.2	dof_ndvi_geoin_std	65.9	stdev_vpv_2	7.2
3	stdev_vpv_2	39.5	dof_ndvi_gurs_avg	70.9	naem30_2	10.1
4	avg_vpv_kumul_100do0	39.7	naem32_4	71.1	avg_vpv_1	10.2
5	avg_vpv_0	39.9	dof_ndvi_gurs_std	72.1	avg_vpv_2	11.7
6	avg_vpv_kumul_100do2	41.0	naem32_2	79.9	avg_vpv_kumul_100do0	12.4
7	naem30_1	41.4	avg_vpv_9	80.7	avg_vpv_0	12.6
8	avg_vpv_2	41.5	avg_vpv_15	80.7	avg_vpv_kumul_100do2	13.9
9	avg_vpv_kumul_100do1	41.5	avg_vpv_8	81.4	avg_vpv_kumul_100do1	14.8
10	avg_vpv_kumul_100do3	41.6	naem32_1	82.1	avg_vpv_kumul_100do3	14.9
11	dof_ndvi_geoin_avg	42.2	avg_vpv_10	82.3	avg_vpv_kumul_100do4	19.0
12	dof_ndvi_gurs_std	43.3	avg_vpv_7	83.3	naem31_1	19.9
13	avg_vpv_kumul_100do4	43.8	avg_vpv_13	83.3	avg_vpv_3	22.4
14	avg_vpv_3	45.3	avg_vpv_14	83.4	avg_vpv_kumul_100do5	27.8
15	dof_ndvi_gurs_avg	46.2	stdev_vpv_7	83.6	stdev_vpv_3	31.7
16	naem31_1	46.6	avg_vpv_11	84.0	avg_vpv_4	31.8
17	avg_vpv_kumul_100do5	49.0	stdev_vpv_11	85.4	con_2	32.4
18	avg_vpv_4	49.5	naem22_4	85.9	cor_2	32.8
19	con_2	50.8	avg_vpv_6	86.1	dof_ndvi_gurs_std	34.2
20	naem31_2	52.1	stdev_vpv_8	87.3	naem31_2	35.1
21	avg_vpv_5	54.3	avg_vpv_12	87.5	stdev_vpv_5	37.5
22	stdev_vpv_3	55.0	naem12_2	87.5	dof_ndvi_gurs_avg	38.0
23	stdev_vpv_5	55.4	stdev_vpv_kumul_100do16	87.8	stdev_vpv_4	38.6
24	stdev_vpv_4	55.7	stdev_vpv_10	88.0	avg_vpv_5	39.1
25	avg_vpv_kumul_100do6	56.5	avg_vpv_16	88.3	avg_vpv_kumul_100do6	39.3
26	cor_2	56.6	avg_vpv_5	89.2	naem30_4	39.5
27	stdev_vpv_0	60.0	naem22_2	89.3	dof_ndvi_geoin_avg	39.8
28	stdev_vpv_kumul_100do0	60.1	stdev_vpv_kumul_100do15	89.5	asm_4	43.8
29	stdev_vpv_6	60.9	stdev_vpv_kumul_100do17	89.5	con_1	44.1
30	naem30_4	61.4	naem31_2	89.9	stdev_vpv_0	45.8
31	asm_4	61.7	stdev_vpv_6	90.1	stdev_vpv_kumul_100do0	45.9
32	stdev_vpv_7	62.0	naem13_2	90.5	naem31_4	47.0
33	naem31_4	62.5	naem22_1	90.9	stdev_vpv_6	49.7
34	con_1	62.6	stdev_vpv_kumul_100do14	91.1	cor_1	49.9
35	stdev_vpv_1	64.8	stdev_vpv_9	91.6	stdev_vpv_1	50.1
36	avg_vpv_kumul_100do7	66.0	naem23_2	91.6	ent_4	51.6
37	avg_vpv_7	67.2	avg_vpv_4	92.0	naem11_4	52.0
38	ent_4	67.6	stdev_vpv_12	92.6	naem11_2	53.0
39	avg_vpv_6	67.7	naem20_1	92.9	mn2_2	53.8
40	stdev_vpv_8	68.3	naem03_1	93.2	asm_2	54.2

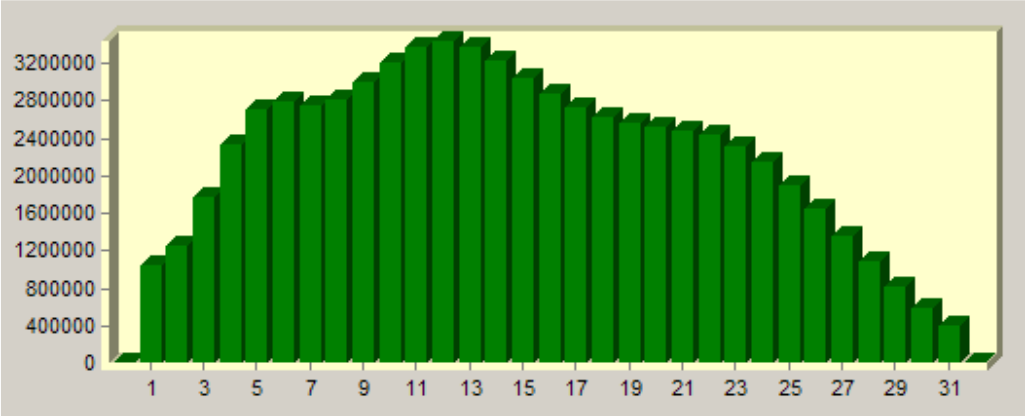

Slika 22: Porazdelitev frekvenc višin vegetacije na DMK.
Figure 22: Frequency distribution of vegetation heights in the digital canopy model.

Preglednica 10: Rang lestvice skupin pojasnjevalnih spremenljivk glede na skupino ciljnih spremenljivk.
Table 10: Ranks of explanatory variable groups according to the target variable group.

Vse ciljne spremenljivke, vsi polmeri veljavnosti		Ciljne spremenljivke "Drevesne vrste", vsi polmeri veljavnosti		Ciljne spremenljivke "Svetloba, vsi koti", vsi polmeri	
Skupina pojas. spremenljivk	Povpr. rang	Skupina pojas. spremenljivk	Povpr. rang	Skupina pojas. spremenljivk	Povpr. rang
dof_avg	44.2	dof_avg	61.4	dof_avg	38.9
dof_std	59.7	dof_std	69.0	dof_std	58.1
haralick_2	79.6	avg_vpv_kumul	74.6	haralick_2	68.8
haralick_4	82.2	naem_2	104.5	haralick_4	70.9
haralick_1	83.4	haralick_2	104.7	haralick_1	73.1
naem_1	97.0	avg_vpv	105.8	naem_1	92.6
avg_vpv_kumul	110.2	haralick_4	106.0	avg_vpv_kumul	108.7
naem_2	113.4	naem_4	106.4	naem_2	116.6
naem_4	114.7	haralick_1	106.7	naem_4	118.0
avg_vpv	115.3	naem_1	108.3	avg_vpv	119.5
stdev_vpv	117.7	stdev_vpv	114.3	stdev_vpv	119.6
stdev_vpv_kumul	128.1	stdev_vpv_kumul	114.9	stdev_vpv_kumul	133.6

Preglednica 11 s povprečno korelacijo nakazuje uspešnost posameznih tipov modelov za napovedovanje določene ciljne spremenljivke. Zaradi majhnih razlik ni mogoče razlikovati med ansambelskimi modeli, in to tako pri posamezni ciljni spremenljivki kot tudi na splošno. Očitna je na splošno manjša točnost linearnih regresijskih modelov, pri čemer je LM slabši od LMFS.

Preglednica 12 za vsako ciljno spremenljivko kaže uspešnost različnih kombinacij tipa modela in skupine pojasnjevalnih spremenljivk. Pri ciljnih spremenljivkah, ki se tičejo deležev drevesnih vrst, je uspešna kombinacija ansambelskih modelov in skupine pojasnjevalnih spremenljivk skupine N, manj pa P. Najuspešnejši so ansambelski modeli v kombinaciji z združenimi skupinami pojasnjevalnih spremenljivk PN in PNT. Skupina T sama zase ima najslabšo napovedovalno moč. Ker med skupinama PN in PNT ni razlik, to kaže na robustnost ansambelskih modelov, ki znajo izločiti nepomembne pojasnjevalne spremenljivke. Tudi tu razberemo manjšo točnost linearnih regresijskih modelov v primerjavi z ansambelskimi modeli.

Pri ciljnih spremenljivkah, ki se tičejo svetlobnih razmer v sestoju, ima večjo napovedno moč skupina P, nekaj manjšo T, N pa je najslabša. Kombinirane skupine PN, PT in PNT se po doseženih korelacijah ne razlikujejo od skupine P. Razlika med ansambelskimi in linearnimi regresijskimi modeli je majhna in verjetno neznačilna.

Preglednica 13 odraža vpliv polmera veljavnosti pojasnjevalnih spremenljivk na točnost napovedi. Pri ciljnih spremenljivkah, ki se nanašajo na deleže drevesnih vrst, najboljše rezultate dajeta polmera 10 m in 20 m, kar ustreza območju, znotraj katerega je potekalo ocenjevanje deleža drevesnih vrst v sestojnem sklepu. Pri spremenljivkah, ki se nanašajo na svetlobne razmere, najboljše rezultate dajeta polmera 10 m in 5 m.

Preglednica 14 kaže vpliv zornega kota, ki ga upoštevamo pri izračunu svetlobnih značilnosti iz hemisferne fotografije. Večji koti (120° in 170°) dajo nekaj boljše rezultate, kar bi bilo deloma mogoče razložiti z večjo zajeto površino, kar izboljša prostorsko sovpadanje terensko izmerjenih ciljnih vrednosti in lidarskih podatkov, uporabljenih za izračun pojasnjevalnih spremenljivk.

Preglednica 11: Povprečna korelacija vseh modelov za posamezen par tip modela / ciljna spremenljivka. Stolpec Splošno podaja aritmetično sredino vseh vrednosti levo od sebe.
Table 11: Average correlation of all models for each pair model type / target variable. The right-most column gives the arithmetic mean of all the values to the left.

	deligl	delbukev	deljelka	delbor	openness	lai2000lin	indirectsitefactor	ppfddiffuseunder	Splošno
MTB	0.58	0.63	0.65	0.61	0.60	0.52	0.60	0.58	0.60
MTRF	0.57	0.62	0.64	0.60	0.61	0.53	0.61	0.59	0.60
STB	0.58	0.63	0.64	0.60	0.60	0.52	0.60	0.58	0.59
STRF	0.57	0.62	0.64	0.60	0.61	0.53	0.60	0.59	0.59
LM	0.35	0.40	0.37	0.36	0.36	0.31	0.36	0.35	0.36
LMFS	0.47	0.48	0.45	0.44	0.50	0.45	0.51	0.51	0.48

Preglednica 12: Maksimalna dosežena korelacija za par tip modela / skupina pojasnjevalnih spremenljivk, prikazano posebej za vsako ciljno spremenljivko.
Table 12: Maximum obtained correlation for each pair model type / group of explanatory variables, shown individualy for each target variable.

deligl	P	N	T	PN	PT	PNT
MTB	0.54	0.74	0.37	0.76	0.56	0.76
MTRF	0.54	0.75	0.37	0.71	0.54	0.71
STB	0.54	0.74	0.38	0.77	0.54	0.76
STRF	0.54	0.75	0.36	0.74	0.54	0.73
LM	0.43	0.69	0.31	0.69	0.35	0.67
LMFS	0.52	0.69	0.34	0.74	0.48	0.75

delbukev	P	N	T	PN	PT	PNT
MTB	0.65	0.71	0.39	0.77	0.65	0.77
MTRF	0.65	0.71	0.38	0.74	0.65	0.73
STB	0.65	0.69	0.39	0.78	0.65	0.77
STRF	0.66	0.71	0.39	0.75	0.66	0.74
LM	0.58	0.62	0.40	0.69	0.55	0.68
LMFS	0.65	0.62	0.43	0.75	0.65	0.75

deljelka	P	N	T	PN	PT	PNT
MTB	0.70	0.60	0.59	0.78	0.70	0.78
MTRF	0.70	0.60	0.60	0.76	0.70	0.76
STB	0.69	0.59	0.59	0.77	0.69	0.77
STRF	0.70	0.59	0.60	0.75	0.70	0.75
LM	0.64	0.42	0.58	0.66	0.58	0.59
LMFS	0.71	0.42	0.62	0.72	0.71	0.71

delbor	P	N	T	PN	PT	PNT
MTB	0.65	0.58	0.50	0.76	0.66	0.76
MTRF	0.66	0.58	0.48	0.74	0.67	0.74
STB	0.65	0.56	0.48	0.78	0.65	0.76
STRF	0.66	0.57	0.48	0.73	0.67	0.73
LM	0.53	0.49	0.41	0.62	0.50	0.62
LMFS	0.58	0.49	0.45	0.66	0.59	0.69

openness	P	N	T	PN	PT	PNT
MTB	0.82	0.37	0.75	0.82	0.82	0.82
MTRF	0.83	0.39	0.75	0.83	0.82	0.82
STB	0.82	0.38	0.75	0.82	0.82	0.82
STRF	0.83	0.37	0.75	0.83	0.82	0.81
LM	0.77	0.30	0.72	0.77	0.74	0.74
LMFS	0.80	0.30	0.75	0.80	0.80	0.80

lai2000lin	P	N	T	PN	PT	PNT
MTB	0.74	0.39	0.68	0.74	0.73	0.74
MTRF	0.75	0.39	0.69	0.75	0.75	0.75
STB	0.74	0.39	0.68	0.74	0.74	0.75
STRF	0.75	0.39	0.69	0.75	0.75	0.75
LM	0.70	0.33	0.67	0.71	0.68	0.69
LMFS	0.75	0.34	0.69	0.76	0.76	0.76

Indirect sitefactor	P	N	T	PN	PT	PNT
MTB	0.80	0.35	0.78	0.81	0.80	0.81
MTRF	0.81	0.36	0.77	0.82	0.81	0.82
STB	0.80	0.36	0.78	0.81	0.81	0.81
STRF	0.81	0.36	0.78	0.82	0.81	0.82
LM	0.78	0.31	0.72	0.79	0.74	0.75
LMFS	0.81	0.32	0.77	0.82	0.81	0.82

ppfddiffuse under	P	N	T	PN	PT	PNT
MTB	0.80	0.35	0.78	0.81	0.80	0.81
MTRF	0.81	0.36	0.77	0.82	0.81	0.82
STB	0.80	0.36	0.78	0.81	0.81	0.81
STRF	0.81	0.35	0.77	0.82	0.81	0.82
LM	0.78	0.32	0.72	0.79	0.74	0.75
LMFS	0.81	0.33	0.77	0.82	0.81	0.82

Preglednica 13: Povprečne korelacije za pare polmer veljavnosti / ciljna spremenljivka. Stolpec Splošno podaja aritmetično sredino vseh vrednosti levo od sebe.
Table 13: Average correlations for pairs validity radius / target variable. The right-most column gives the arithmetic mean of all the values to the left.

	deligl	delbukev	deljelka	delbor	openness	lai2000lin	indirectsitefactor	ppfddiffuseunder	Splošno
Polmer 5 m	0.48	0.51	0.47	0.48	0.59	0.51	0.61	0.59	0.53
Polmer 10 m	0.57	0.64	0.64	0.60	0.63	0.54	0.63	0.61	0.61
Polmer 20 m	0.50	0.55	0.58	0.53	0.41	0.38	0.40	0.40	0.47

Preglednica 14: Povprečne korelacije za pare zorni kot hemisferne fotografije / ciljna spremenljivka. Stolpec Splošno podaja aritmetično sredino vseh vrednosti levo od sebe.
Table 14: Average correlations for pairs viewing angle of hemspherical photography / target variable. The right-most column gives the arithmetic mean of all the values to the left.

	openness	lai2000lin	indirectsitefactor	ppfddiffuseunder	Splošno
Kot 45°	0.46	0.41	0.46	0.40	0.43
Kot 60°	0.52	0.45	0.51	0.51	0.50
Kot 120°	0.61	0.58	0.60	0.61	0.60
Kot 170°	0.60	0.47	0.61	0.61	0.57

Kontrola lidarskih drevesnih višin s terenskim vzorcem je pokazala pričakovano podcenjevanje višin, kar je znana pomanjkljivost letalskega diskretnega lidarja. Pri iglavcih je podcenjevanje 1,1 m, kar je nekoliko več kot pri listavcih, kjer znaša 0,9 m. Razlog so bolj koničaste oblike krošenj pri iglavcih. Slika 23 kaže, da zanesljivost terenskih meritev referenčnih dreves pada z višino drevesa, vendar to ni kritično, saj je tudi pri najvišjih drevesih raztros meritev manjši od povprečne lidarske napake višin. Napaka (njena absolutna vrednost) lidarske ocene pa je neodvisna od višine drevesa (Slika 24). Raztros napak je enak za iglavce in za listavce 0,4 m, kar je več, kot znaša razlika napak iglavcev in listavcev. Zato smo vsem sestojnim višinam, ne glede na razmerje iglavcev in listavcev v sestoju, prišteli enotno korekcijo, ki velja za vsa drevesa in znaša 1 m.

Preglednica 15: Lidarsko podcenjevanje višin, ocenjeno na vzorcu 257 dreves. Napaka lidarske višine posameznega drevesa je bila izračunana kot $H_{dejanska}$ - H_{lidar}.
Table 15: Lidar underestimation of tree heights, estimated with a sample of 257 trees. Lidar height errors are comuted as H_{actual} - H_{lidar}.

	Povprečna napaka	Standardni odklon napak
Vsa drevesa	1.0 m	0.4 m
Iglavci	1.1 m	0.4 m
Listavci	0.9 m	0.4 m

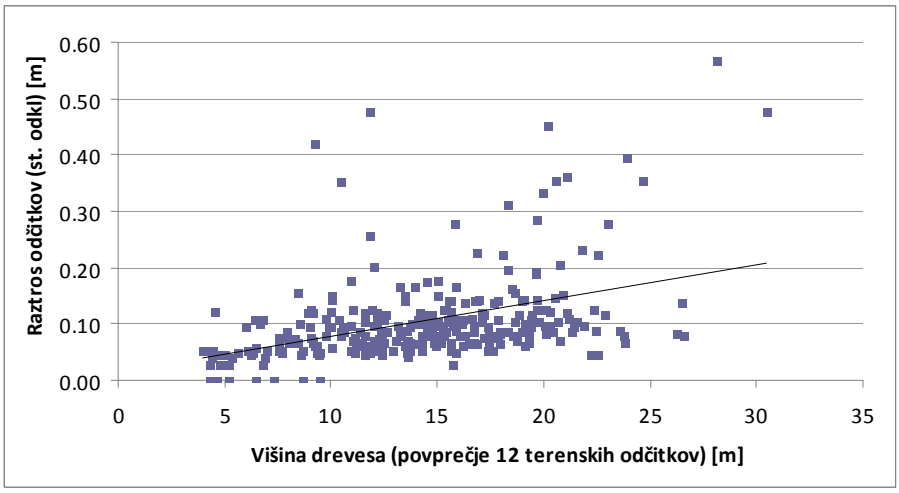

Slika 23: Raztros terenskih odčitkov višine dreves glede na pravo (povprečno) višino drevesa.
Figure 23: Scattering of height readouts in the field vs. the true (average) tree height.

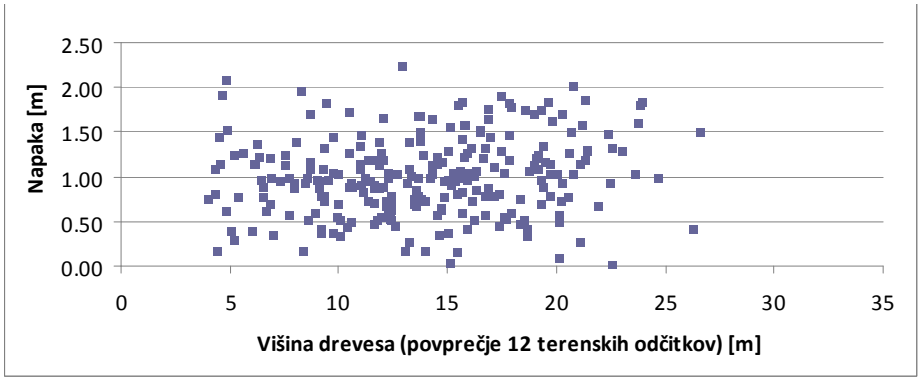

Slika 24: Lidarska napaka višine drevesa.
Figure 24: Lidar tree height error.

Rezultate razmejevanja sestojev na majhnem izseku kaže Slika 25. Celotna karta je priložena na zgoščenki. Povprečna velikost sestojev na lidarski sestojni karti GGE Menišija in GGE Slivnica znaša 2,1 ha, velikost sestojev pa sega od 0,25 do 33,7 ha. Lidarski sestoji pokrivajo 7438 ha, kar pomeni 86,3-odstotno gozdnatost. To je za 1287 ha več od vsote uradnih podatkov Zavoda za gozdove, ki za obe GGE skupaj znaša 6151 ha (71,4-odstotna gozdnatost). Razliko pripisujemo naslednjim vzrokom:

1. pri definiranju gozdne vegetacije smo bili širokosrčni, saj smo upoštevali vse površine, kjer DMK presega 1 m višine. Če bi postavili prag pri 5 m, bi bila naša ocena površine gozdne vegetacije manjša za 640 ha (mišljeno je pred fazo izločanja segmentov, manjših od 0,25 ha), pri pragu 7 m pa za 1189 ha;
2. podatki ZGS so precej starejši od naših, saj so objavljeni v gozdnogospodarskih načrtih GGE iz let 2001 in 2008, ti pa temeljijo na še starejših aerofotoposnetkih. Podatki ZGS tako ne upoštevajo večanja površine gozdov v času do lidarskega snemanja. Gozdne površine naraščajo zaradi zaraščanja opuščenih kmetijskih površin;
3. uradno veljaven prag kartiranja sestojev je 0,5 ha, pri lidarskem kartiranju pa smo zaradi ohranitve podrobnosti informacije uporabili prag 0,25 ha in tako zajeli tudi fragmente gozda, ki jih ZGS ne upošteva;
4. lidarsko kartiranje sestojev temelji na dejanski pokrovnosti, medtem ko evidence ZGS upoštevajo tudi uradno rabo tal.

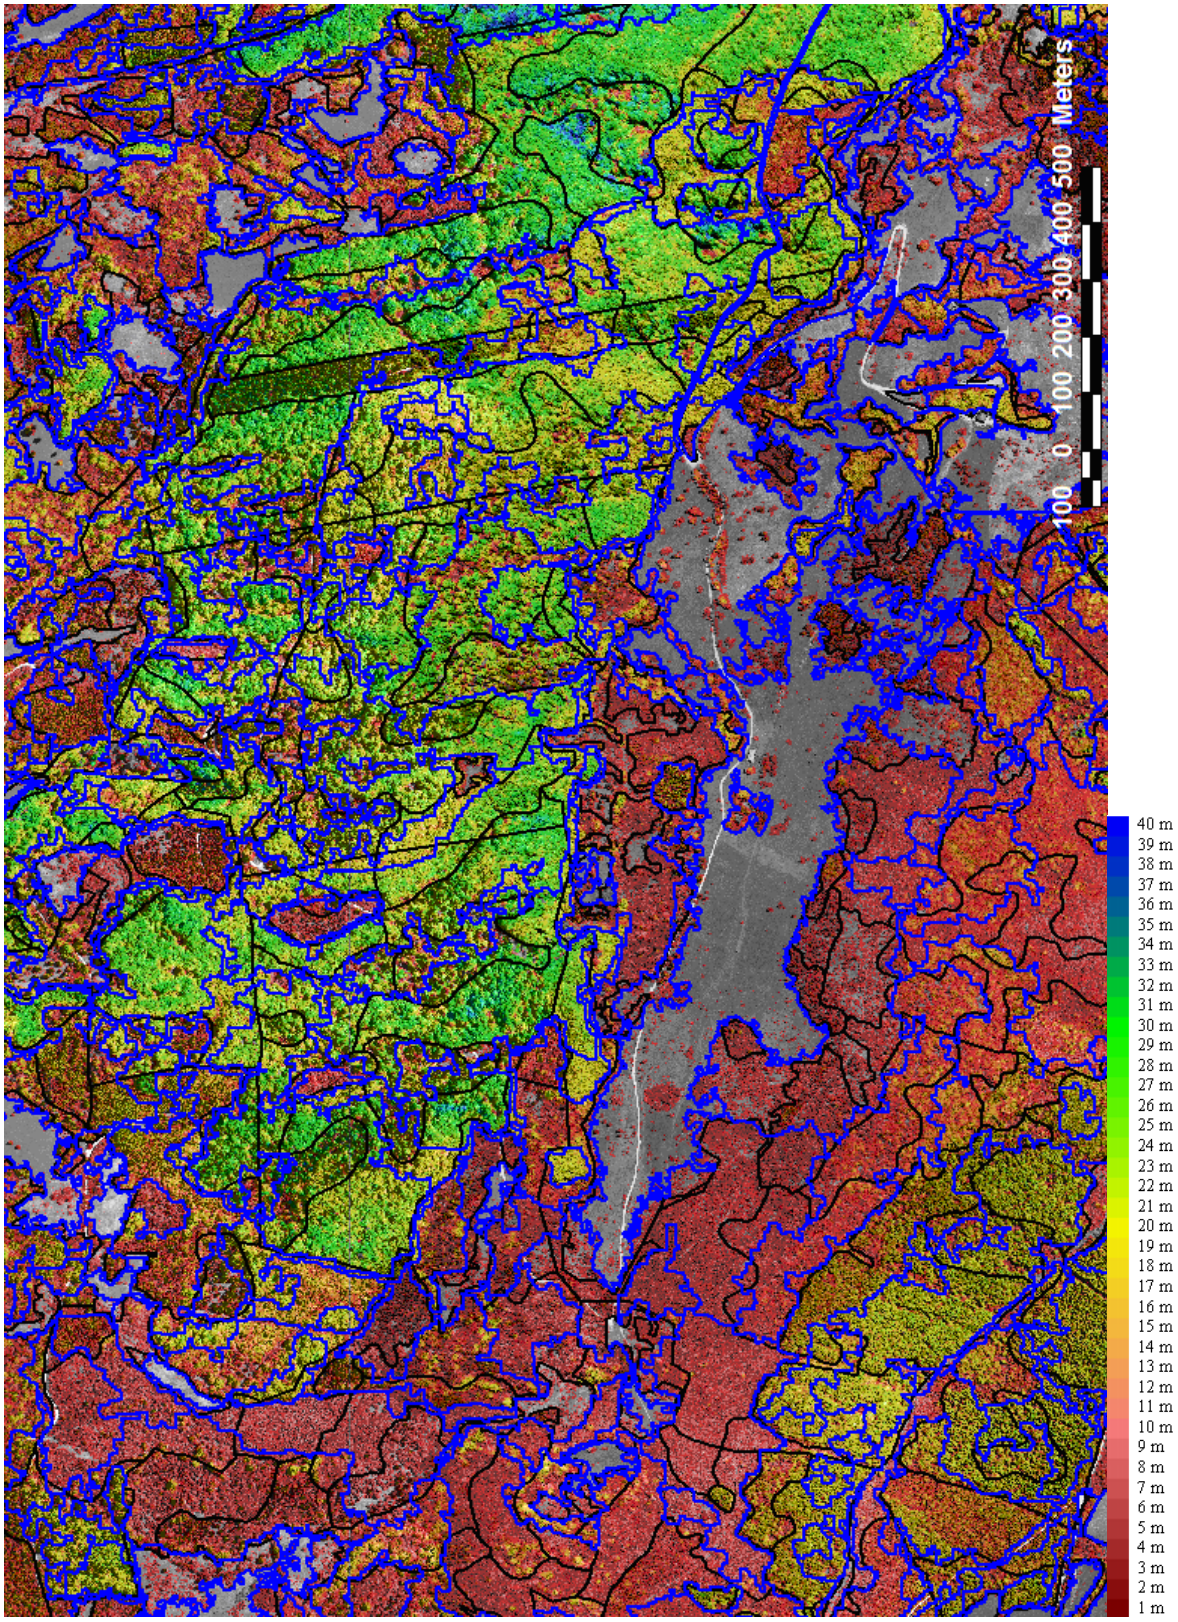

Slika 25: Lidarska razmejitev na sestoje (modra črta) in razmejitev Zavoda za gozdove (črna črta). V ozadju je kompozitna slika DOF in DMK. Izsek prikazuje območje vrha Slivnice ter njeno severno in južno pobočje. Legenda prikazuje višine vegetacije. Sever je na levo.

Figure 25: Lidar-based delimitation of forest stands (blue line) ina the Forestry service delimitation (black line). In the background there is a composite BW aerial image colour coded with digital canopy model. The subset shows the Mt. Slivnica summit with northern and southern flanks. The legend shows vegetation heights. North is towards left.

Vizualna primerjava z veljavno sestojno karto Zavoda za gozdove kaže, da uporabljena metoda lidarskega razmejevanja ni sposobna smiselne prostorske posplošitve. Zato imajo lidarsko izločeni sestoji zelo fragmentirane meje in včasih tudi neprimerno obliko, na primer zelo ozkih in zavitih poligonov. Taki sestoji ne omogočajo oblikovanja notranjega okolja in so za gozdnogojitveno uporabo neprimerni. Po drugi strani sestojna karta ZGS kaže ponekod pretirano subjektivnost interpretatorja in tudi posamezne grobe napake kartiranja, kot je na primer pretirano posploševanje oziroma zanemarjanje očitno izstopajočih sestojev, tudi če ti presegajo prag kartiranja (0,5 ha), včasih pa tudi deljenje homogenih gozdnih površin. V tem smislu je lidarsko razmejevanje bolj objektivno, bolj podrobno sledi razlikam med sestoji in nima grafičnih napak kartiranja. Lidarsko sestojno karto GGE Slivnica in GGE Menišija smo dali v testiranje Zavodu za gozdove in njegovi Območni enoti Postojna. Mnenje predstavnikov ZGS ob prvi predstavitvi lidarske sestojne karte je bilo, da lahko lidarska sestojna karta pomaga izboljšati rezultate sestojnega kartiranja na ZGS. Osnovni problem operativne uporabe lidarja v gozdarstvu je visoka cena snemanja ter kompleksnost in deloma še eksperimentalna narava metod obdelave podatkov. Predstavniki ZGS so poudarili, da bi jim bila v pomoč identifikacija zelo podobnih sestojev na podlagi lidarskih podatkov, saj bi zmanjšala potrebno število terenskih dni pri terenskem opisovanju sestojev. To smo tudi storili z razvrščanjem v skupine (angl. clustering) vseh sestojev na podlagi vertikalnih lidarskih profilov, in sicer na dveh ravneh tematske podrobnosti: 29 in 254 skupin. Koda skupine je bila dodana atributni tabeli lidarske sestojne karte. Odzivov ZGS po prvi predstavitvi lidarske sestojne karte ni bilo.

4.4 Ugotovitve

V nalogi smo na praktičnem primeru prikazali številne načine empiričnega modelnega napovedovanja značilnosti gozda pa tudi uporabo modelov za kartiranje teh značilnosti in njihovo posploševanje na raven sestojev. Od 21 zadanih ciljnih spremenljivk smo jih uspešno modelirali osem (deleži treh dominantnih vrst – bukve, jelke in bora – ter delež iglavcev, ki je komplementaren z deležem listavcev, odprtost, ki je komplementarna s sklepom krošenj, indeks listne površine LAI, relativni delež difuzne svetlobe v sestoju in absolutna letna količina fotosintetsko aktivnega difuznega sevanja v sestoju). Iz modelov smo izdelali karte, ki podajajo prostorsko razporeditev navedenih značilnosti. Za praktično gozdarstvo so pomembne karte treh dominantnih vrst, deleža iglavcev in odprtosti oziroma sklepa krošenj. Karte indeksa listne površine, relativnega deleža difuzne svetlobe v sestoju in absolutne letne količine fotosintetsko aktivnega difuznega sevanja v sestoju lahko najdejo uporabo pri raziskavah fizioloških in energetskih procesov v gozdu. Vse naštete značilnosti se pri terestričnih postopkih zaradi zamudnosti zbirajo vzorčno, zato je prednost omenjenih kart njihova prostorska zveznost, ki omogoča preučevanje ne le povprečij, ampak tudi ekosistemsko in gozdnogospodarsko pomembnih vzorcev in gradientov. Strojno naučeni ansambelski modeli so se izkazali kot točnejši od linearnih regresijskih modelov. Nismo pa ugotovili razlike med uporabljenimi ansambelskimi modeli. Za osem najbolje napovedanih ciljnih spremenljivk korelacije njihovih modelov segajo od 0,76 do 0,83. Razmeroma nizke korelacije, ki jih kažejo celo najboljši modeli, pripisujemo predvsem raznolikosti gozda v testnem območju Slivnica, šumu v učnem vzorcu zaradi subjektivnih napak terenskih ocen in nenatančnemu pozicioniranju vzorčnih ploskev, zaradi česar je lahko prišlo do zamika glede na daljinsko zaznane podatke. Ugotovili smo, da število podmodelov v ansamblu vpliva na točnost ansambelske napovedi, da pa v našem primeru točnost le še rahlo narašča pri ansamblih z več kot 160 podmodeli. Kljub rahlo boljši točnosti gradnja ansamblov z večjim

številom podmodelov od 160 v našem primeru ni smiselna, saj se nesorazmerno podaljšuje tako čas gradnje ansamblov kot tudi čas napovedovanja ciljih spremenljivk.

Ciljne spremenljivke smo modelno povezali s pojasnjevalnimi spremenljivkami, izpeljanimi iz lidarskih in infrardečih aerofoto podatkov. Pri ciljnih spremenljivkah, ki se nanašajo na drevesno sestavo, k točnosti napovedi največ prispevajo infrardeče pojasnjevalne spremenljivke. Pri ciljnih spremenljivkah, ki se nanašajo na svetlobne razmere, pa k točnosti napovedi največ prispevajo lidarske pojasnjevalne spremenljivke. Srednji in nižji deli profilov so boljši prediktor kot zgornji deli profilov (nad 20 m). To razlagamo z dejstvom, da je večina dreves nižjih, zato so na višini 20 m in več nad tlemi vrednosti profilov večinoma 0. Izjema so višine 30 m in več, za katere domnevamo, da so v modelih prisotne kot nadomestek za ugotavljanje prisotnosti visokih dreves. Visoka drevesa imajo namreč močan vpliv na svetlobne razmere, njihova prisotnost pa je hkrati tudi povezana z deleži nekaterih dominantnih drevesnih vrst. Ugotovili smo, da lidarski podatki v našem primeru presegajo multispektralne (pravzaprav barvne infrardeče) aeroposnetke pri ugotavljanju svetlobnih značilnosti gozda, ki so tesno povezane z njegovo prostorsko strukturo oziroma vertikalno in horizontalno razporeditvijo biomase. Napovedovanje drevesnih vrst pa je uspešnejše z združenimi lidarskimi in slikovnimi podatki.

Razmeroma nizke korelacije (bistveno nižje, kot jih dosegajo avtorji v strukturno in vrstno bolj homogenih borealnih gozdovih), ki jih kažejo predvsem modeli deležev drevesnih vrst, pripisujemo v prvi vrsti veliki raznolikosti drevesnih vrst in slabi prepoznavnosti oblik krošenj v dinarskem mešanem gozdu. Predvsem krošnje listavcev so slabo prepoznavne zaradi tesnega sestojnega sklepa, ko se krošnje med seboj spajajo in prelivajo in je s tem zabrisana njihova vrstno značilna oblika. Nadalje se je izkazalo, da točnost napovedi sovpada s prisotnostjo drevesne vrste v učnem vzorcu. Mogoč razlog za nizke korelacije je tudi prostorsko nepopolno sovpadanje terenskih trenažnih in daljinsko zaznanih pojasnjevalnih podatkov zaradi slabega delovanja GPS v težavnem terenu in pod sestojnim sklepom. Vsaj en razlog slabih korelacij pa bi bilo mogoče odpraviti z večjim časovnim vložkom v terensko delo. Zaradi omejenega časa za terensko delo smo podatke o deležih drevesnih vrst namreč zbirali z okularnimi ocenami deležev v sklepu krošenj. To je sicer v gozdarstvu uveljavljena hitra metoda, kjer pa se ni mogoče povsem izogniti subjektivnim vplivom. Bolj objektiven način bi bil merjenje deležev drevesnih vrst v temeljnici, kar bi terensko delo bistveno upočasnilo.

Lidarsko razmejevanje sestojev s segmentacijo kart DMK, odprtosti oziroma sklepa krošenj ter deležev dominantnih drevesnih vrst podrobno sledi razlikam v gradientih, je ponovljivo in v nasprotju s človeškim interpretom ne zagreši grafičnih napak. Po drugi strani pa ni sposobno smiselne prostorske posplošitve (generalizacije). Optimalen postopek bi v prvi fazi vključeval lidarsko razmejevanje, v drugi pa bi človeški interpret lidarske sestoje smiselno posplošil. Za vsak sestoj smo iz rastrskih kart izračunali povprečne vrednosti modelno napovedanih značilnosti gozda pa tudi višin dreves, ki smo jih ugotovili na DMK. REIN implicitno omogoča tudi bolj točen izračun DMK in s tem sestojnih višin, saj je točnost DMK odvisna tudi od točnosti določitve višine tal pod krošnjami. Ta vpliv je največji v posebej težavnih pogojih – na strmem reliefu, v zelo strnjenih gozdovih z nizkim deležem prodiranja laserskih žarkov do tal in pri geomorfološko specifičnih habitatih, kot so kraške vrtače.

5 Razprava in zaključek

V zadnjih letih se je pojavilo veliko število znanstvenih in strokovnih objav na temo uporabe lidarja v gozdarstvu. Že število teh objav kaže, da ima lidar vse možnosti postati eden izmed pomembnih virov informacij za gozdarstvo. Da se to ni že zgodilo v večji meri, gre pripisati ne le visokim stroškom lidarskih snemanj in zamotanosti pridobivanja uporabnih informacij iz surovih lidarskih podatkov, ampak tudi skoraj nepreglednemu številu različnih metod za pridobivanje uporabnih informacij. Kljub temu so lidarske metode na nekaterih področjih že dosegle zrelost, ki omogoča rutinsko uporabo. Tako področje je na primer izdelava DMR, kjer velikih prebojev ne gre več pričakovati, le še postopne izboljšave. Podobno v Skandinaviji in Severni Ameriki postajajo rutinske velikoprostorske gozdne inventure, kjer z lidarjem in DMK posredno ocenjujejo nekatere znake, kot so lesne zaloge, biomasa in druge znake, ki so povezani z višino dreves. Razširjenost lidarskih inventur v borealnih gozdovih gre pripisati tudi enostavnejši sestavi teh gozdov v primerjavi z gozdovi zmernega pasu, kjer ostaja nerešen problem zanesljiva identifikacija vrhov dreves v strnjenih listnatih in mešanih sestojih. Potencial lidarja v gozdarstvu pa še zdaleč ni izkoriščen. Lidar lahko zmanjša subjektivnost in izboljša ponovljivost terestričnih gozdnih inventur. Zaradi tridimenzionalne narave podatkov pričakujemo uveljavitev lidarja na področju indikatorjev biotske raznovrstnosti, ki je pri določenih merilih povezana s strukturnimi lastnostmi gozda. Zelo obetavno področje razvoja je združevanje lidarskega in pasivnega optičnega daljinskega zaznavanja. Kot so pokazali Stojanova in sod. (2010), so ceneni prostorsko zvezni pasivni optični podatki komplementarni prostorsko nezveznim lidarskim podatkom. Hkrati lahko spektralni podatki olajšajo interpretacijo lidarskega oblaka točk.

V nalogi smo razvili nov algoritem, imenovan REIN, za izračun DMR iz oblaka lidarskih točk. Algoritem je posebej namenjen uporabi v strmem gozdnatem reliefu, kjer imajo znani algoritmi tipično težave z razlikovanjem med talnimi in netalnimi (vegetacijskimi) odboji. Ključna zamisel REIN je v tem, da izkoristimo preštevilnost talnih točk za blaženje vpliva tistih preostalih vegetacijskih odbojev, ki jih poznane metode ne morejo filtrirati.

REIN ne spada v nobeno od štirih skupin znanih algoritmov (morfološko filtriranje, progresivno filtriranje, iterativno filtriranje in segmentno filtriranje), saj uporablja naključno vzorčenje oblaka točk. Drugi algoritmi se obnašajo deterministično in v posebnih okoliščinah vedno zagrešijo enako napako. Zaradi elementa naključnosti REIN ne zagreši enake napake pri vsaki ponovitvi vzorčenja oziroma se napake posameznih ponovitev tipično med seboj izničijo pri končnem izračunu nadmorskih višin DMR. REIN ima zato večjo zmožnost prilagajanja raznolikim razmeram v strmem gozdnatem terenu. Ker poskrbi, da ima vsak del analiziranega območja enako možnost biti izbran v vzorec, je izračunan DMR homogen tudi pri nehomogenih vhodnih podatkih. REIN rešuje tudi problem negativnih osamelcev, ki so rezultat mnogokratnih odbojev.

REIN ne vsiljuje določene podatkovne strukture DMR, saj lahko izračunamo nadmorske višine tako za rastrski DMR z lokacijami v sistematični mreži kot tudi za poljubno nepravilno mrežo točk, kot je na primer trikotniška mreža. Glede lomnih črt reliefa se REIN obnaša podobno kot drugi algoritmi, torej povzroči rahle zaokrožitve DMR vzdolž lomnih črt. Lomne črte je zato treba izločati v ločenem postopku in jih shranjevati posebej.

Ker REIN izračuna končni rezultat iz mnogih neodvisnih vzorcev, je mogoče uporabiti paralelno računanje in s tem čas računanja občutno skrajšati.

Dodatne analize bi bile potrebne, da bi REIN preizkusili na širšem spektru praktičnih primerov in tako dobili boljšo predstavo o njegovi vrednosti v različnih tipih reliefa in pri različnih režimih snemanja. V nadaljnjem delu bi bilo mogoče REIN še izboljšati. Eden od zanimivih raziskovalnih problemov bi bilo avtomatsko določanje njegovih parametrov delovanja (stopnja vzorčenja, število ponovitev), ki bi se lahko prilagajalo tipu reliefa in vegetaciji.

Glede na prevladujoče gorat relief Slovenije ter pretežno pokritost z gozdom bi REIN lahko bil primerno orodje ne le za gozdarstvo, ampak tudi za mnoge druge dejavnosti v neposeljenem prostoru, ki potrebujejo podrobne in točne informacije o konfiguraciji reliefa. V ožjem gozdarskem smislu je prednost REIN posredno zagotavljanje točnejše relativne višine nad tlemi za vse zabeležene lidarske odboje in s tem posredno točnejše lidarsko ocenjevanje lastnosti gozda. Točna in podrobna rekonstrukcija reliefa pa omogoča tudi nove aplikacije na področju gradnje gozdnih prometnic, gradnje gozdnih žičnic za spravilo lesa ter urejanja in nadzora hudourniških in erozijskih območij.

V nalogi smo na praktičnem primeru prikazali številne načine empiričnega modelnega napovedovanja značilnosti gozda pa tudi uporabo modelov za kartiranje teh značilnosti in njihovo posploševanje na raven sestojev. Od 21 zadanih ciljnih spremenljivk smo jih uspešno modelirali osem. Štirje modeli se nanašajo na drevesno sestavo (deleži treh dominantnih vrst – bukve, jelke in bora – ter delež iglavcev, ki je komplementaren z deležem listavcev), štirje pa na svetlobne razmere (odprtost, ki je komplementarna s sklepom krošenj, indeks listne površine LAI, relativni delež difuzne svetlobe v sestoju in absolutna letna količina fotosintetsko aktivnega difuznega sevanja v sestoju). Iz modelov smo izdelali karte, ki podajajo prostorsko razporeditev navedenih značilnosti. Za praktično gozdarstvo so pomembne karte treh dominantnih vrst, deleža iglavcev in odprtosti oziroma sklepa krošenj. Karte indeksa listne površine, relativnega deleža difuzne svetlobe v sestoju in absolutne letne količine fotosintetsko aktivnega difuznega sevanja v sestoju lahko najdejo uporabo pri raziskavah fizioloških in energetskih procesov v gozdu. Vse naštete značilnosti se pri terestričnih postopkih zaradi zamudnosti zbirajo vzorčno, zato je prednost omenjenih kart njihova prostorska zveznost, ki omogoča preučevanje ne le povprečij, ampak tudi ekosistemsko in gozdnogospodarsko pomembnih vzorcev in gradientov.

Strojno naučeni ansambelski modeli so se izkazali kot točnejši od linearnih regresijskih modelov. Nismo pa ugotovili razlike med uporabljenimi ansambelskimi modeli. Za osem najbolje napovedanih ciljnih spremenljivk korelacije njihovih modelov segajo od 0,76 do 0,83. Razmeroma nizke korelacije, ki jih kažejo celo najboljši modeli, pripisujemo predvsem raznolikosti gozda v testnem območju Slivnica, šumu v učnem vzorcu zaradi subjektivnih napak terenskih ocen in nenatančnemu pozicioniranju vzorčnih ploskev, zaradi česar je lahko prišlo do zamika glede na daljinsko zaznane podatke.

Ugotovili smo, da število podmodelov v ansamblu vpliva na točnost ansambelske napovedi, da pa v našem primeru točnost le še rahlo narašča pri ansamblih z več kot 160 podmodeli. Kljub rahlo boljši točnosti gradnja ansamblov z večjim številom podmodelov od 160 v našem primeru ni smiselna, saj se nesorazmerno podaljšuje tako čas gradnje ansamblov kot tudi čas napovedovanja ciljih spremenljivk.

Ciljne spremenljivke smo modelno povezali s pojasnjevalnimi spremenljivkami, izpeljanimi iz lidarskih in infrardečih aerofoto podatkov. Pri ciljnih spremenljivkah, ki se nanašajo na drevesno sestavo, k točnosti napovedi največ prispevajo infrardeče pojasnjevalne spremenljivke. Pri ciljnih spremenljivkah, ki se nanašajo na svetlobne razmere, pa k točnosti napovedi največ prispevajo lidarske pojasnjevalne spremenljivke.

Srednji in nižji deli profilov so boljši prediktor kot zgornji deli profilov (nad 20 m). To razlagamo z dejstvom, da je večina dreves nižjih, zato so na višini 20 m in več nad tlemi vrednosti profilov večinoma 0. Izjema so višine 30 m in več, za katere domnevamo, da so v modelih prisotne kot nadomestek za ugotavljanje prisotnosti visokih dreves. Visoka drevesa imajo namreč močan vpliv na svetlobne razmere, njihova prisotnost pa je hkrati tudi povezana z deleži nekaterih dominantnih drevesnih vrst.

Ugotovili smo, da lidarski podatki v našem primeru presegajo multispektralne (pravzaprav barvne infrardeče) aeroposnetke pri ugotavljanju svetlobnih značilnosti gozda, ki so tesno povezane z njegovo prostorsko strukturo oziroma vertikalno in horizontalno razporeditvijo biomase. Napovedovanje drevesnih vrst pa je uspešnejše z združenimi lidarskimi in slikovnimi podatki.

Pri ciljnih spremenljivkah, ki se nanašajo na drevesno sestavo k točnosti napovedi največ prispeva kombinacija skupin P (skupina pojasnjevalnih spremenljivk, ki podajajo povprečja normaliziranih in korigiranih frekvenc odbojev, standardni odkloni ter kumulative obojih, kot je razloženo v poglavju 4.2.2.1) in N (skupina pojasnjevalnih spremenljivk, ki podajajo pretvorjene podatke IR letalskega snemanja, kot je razloženo v poglavju 4.2.2.3), od osnovnih skupin pa največ prispeva N. To se sklada z ugotovitvami številnih avtorjev (Leckie in sod. 2003, McCombs in sod. 2003, Popescu in Wynne 2004, Hilker in sod. 2008, Suratno in sod. 2009, Morsdorf in sod. 2009, Breidenbach in sod. 2010), da so multispektralni podatki boljši deskriptor za drevesne vrste, kot lidarski podatki (velja za diskretni letalski lidar!). Pri ciljnih spremenljivkah, ki se nanašajo na svetlobne razmere, sta najprimernejši kombinaciji PN in PNT (T se nanaša na skupino pojasnjevalnih spremenljivk, ki podajajo splošnejši opis oblike vertikalnega lidarskega profila v gozdu in sicer kot kvantifikacijo vzorcev oziroma tekstur, kot je razloženo v poglavju 4.2.2.2), od osnovnih skupin največ prispevata P in T, N pa zelo malo. To si razlagamo s tesno vsebinsko povezanostjo lidarskih gostot (ki so osnova za izračun spremenljivk P in T) s količino listja in vejevja in posredno z zastrtostjo neba, kar vpliva na svetlobne razmere.

Razmeroma nizke korelacije (bistveno nižje, kot jih dosegajo avtorji v strukturno in vrstno bolj homogenih borealnih gozdovih), ki jih kažejo predvsem modeli deležev drevesnih vrst, pripisujemo v prvi vrsti veliki raznolikosti drevesnih vrst in slabi prepoznavnosti oblik krošenj v dinarskem mešanem gozdu. Predvsem krošnje listavcev so slabo prepoznavne zaradi tesnega sestojnega sklepa, ko se krošnje med seboj spajajo in prelivajo in je s tem zabrisana njihova vrstno značilna oblika. Nadalje se je izkazalo, da točnost napovedi sovpada s prisotnostjo drevesne vrste v učnem vzorcu. Mogoč razlog za nizke korelacije je tudi prostorsko nepopolno sovpadanje terenskih trenažnih in daljinsko zaznanih pojasnjevalnih podatkov zaradi slabega delovanja GPS v težavnem terenu in pod sestojnim sklepom.

Vsaj en razlog slabih korelacij pa bi bilo mogoče odpraviti z večjim časovnim vložkom v terensko delo. Zaradi omejenega časa za terensko delo smo podatke o deležih drevesnih vrst namreč zbirali z okularnimi ocenami deležev v sklepu krošenj. To je sicer v gozdarstvu

uveljavljena hitra metoda, kjer pa se ni mogoče povsem izogniti subjektivnim vplivom. Bolj objektiven način bi bil merjenje deležev drevesnih vrst v temeljnici, kar bi terensko delo bistveno upočasnilo.

Ansambelski modeli bolje napovedujejo vrednosti ciljnih spremenljivk kot linearni regresijski modeli. Zaradi majhnih razlik ni mogoče razlikovati med ansambelskimi modeli, in to tako pri posamezni ciljni spremenljivki kot tudi na splošno. Očitna je na splošno manjša točnost linearnih regresijskih modelov, pri čemer je LM slabši od LMFS. Pri ciljnih spremenljivkah, ki se tičejo deležev drevesnih vrst, je uspešna kombinacija ansambelskih modelov in skupine pojasnjevalnih spremenljivk skupine N, manj pa P. Najuspešnejši so ansambelski modeli v kombinaciji z združenimi skupinami pojasnjevalnih spremenljivk PN in PNT. Skupina T sama zase ima najslabšo napovedovalno moč. Ker med skupinama PN in PNT ni razlik, to kaže na robustnost ansambelskih modelov, ki znajo izločiti nepomembne pojasnjevalne spremenljivke. Pri ciljnih spremenljivkah, ki se tičejo svetlobnih razmer v sestoju, ima večjo napovedno moč skupina P, nekaj manjšo T, N pa je najslabša. Kombinirane skupine PN, PT in PNT se po doseženih korelacijah ne razlikujejo od skupine P.

Sklenemo lahko, da so glede na doseženo točnost napovedi ansambelski modeli primernejši od lineranih regresijskih. Tudi njihova uporaba je enostavnejša, saj so manj občutljivi na ustrezen izbor pojasnjevalnih spremenljivk, oziroma so neprimerne spremenljivke sposobni sami izločiti. Znotraj ansambelskih modelov so večciljni modeli primernejši od modelov z eno ciljno spremenljivko. Pri večciljnih modelih je namreč poraba časa za gradnjo enega modela manjša od porabe za gradnjo mnogih enociljnih modelov, še posebej če upoštevamo tudi porabo časa za manipulacijo s podatki. Večciljne modele je tudi lažje implementirati in izračun kart iz teh modelov je bistveno hitrejši, saj na koncu vsake poti po odločitvenem drevesu dobimo napovedi za vse ciljne spremenljivke hkrati in ne le za eno samo.

Lidarsko razmejevanje sestojev s segmentacijo kart DMK, odprtosti oziroma sklepa krošenj ter deležev dominantnih drevesnih vrst podrobno sledi razlikam v gradientih, je ponovljivo in v nasprotju s človeškim interpretom ne zagreši grafičnih napak. Po drugi strani pa ni sposobno smiselne prostorske posplošitve (generalizacije). Optimalen postopek bi v prvi fazi vključeval lidarsko razmejevanje, v drugi pa bi človeški interpret lidarske sestoje smiselno posplošil. Za vsak sestoj smo iz rastrskih kart izračunali povprečne vrednosti modelno napovedanih značilnosti gozda pa tudi višin dreves, ki smo jih ugotovili na DMK. REIN implicitno omogoča tudi bolj točen izračun DMK in s tem sestojnih višin, saj je točnost DMK odvisna tudi od točnosti določitve višine tal pod krošnjami. Ta vpliv je največji v posebej težavnih pogojih – na strmem reliefu, v zelo strnjenih gozdovih z nizkim deležem prodiranja laserskih žarkov do tal in pri geomorfološko specifičnih habitatih, kot so kraške vrtače.

Posebna prednost lidarskega razmejevanja sestojev je njegova fleksibilnost. Kriterije razmejevanja lahko namreč prilagajamo definiciji sestoja in definiciji gozda, odvisno od namena uporabe. Na primer, za habitatne študije kraških grmišč lahko kot kriterij za razmejevanje gozdnega roba postavimo prag višin na 1 m, pri razmejevanju za potrebe gozdnogospodarskega načrtovanja pa upoštevamo višino 5 m. Ali pa znižamo najmanjšo površino kartiranja in lahko kartiramo majhne, toda ekosistemsko pomembne habitate, kot so omejki ali celo osamljena drevesa.

Čeprav je uporabljena metoda lidarskega razmejevanja v principu enostavna, pa je postopek tehnično zapleten in dolgotrajen. V posameznih fazah postopka je treba prilagajati vrednosti

parametrov lokalnim razmeram ali danim podatkom, zato popolna avtomatizacija postopka ne bi dala dobrih rezultatov.

Prikazane metode napovedovanja in razmejevanja so tehnično zahtevne in zamudne, vendar bi bili (časovni in materialni) stroški obdelave podatkov v primeru operativne rabe lidarja v gozdarstvu manjši za en ali dva reda velikosti, ker bi že poznali najprimernejše pristope, orodja bi sprogramirali v hitrejšem jeziku in faze postopka bi bile bolj utečene.

Uveljavljen postopek sestojnega kartiranja s fototerestrično inventuro je delovno intenziven in drag, vendar pa so sestojne karte bistvene za gozdnogojitveno načrtovanje. Mogoče si je predstavljati neko razmeroma enostavno interpretacijo lidarskih podatkov na vsedržavni ravni, katere proizvodnjo bi bilo mogoče avtomatizirati in poceniti in bi močno olajšala sestojno kartiranje na Zavodu za gozdove. Ker se v kratkem obeta lidarsko snemanje celotnega državnega ozemlja, predlagamo eno od naslednjih dveh možnosti.

Prvič: izdelava DMK za celotno državo, barvno kodiranje višin na DMK (primer kaže Slika 25) in slikovno združevanje s sivinskim letalskim ortofotom. Tako dobimo DOF, ki je obarvan glede na višine drevja in tako povsem intuitivno uporaben v okviru fototerestrične metode, ne da bi jo bilo treba spreminjati. Zgled takega združevanja prikazuje Slika 25.

Drugič: nekaj standardiziranih segmentacij gozda le na podlagi DMK. Posamezne segmentacije bi se med seboj razlikovale glede na višinski prag razmejevanja gozd/negozd (na primer 1, 2, 5, 10 m) in glede na površinski prag kartiranja (na primer 10, 50, 100, 500, 1000, 5000, 10.000 m^2). Segmentacija s pragovi 5 m in 5000 m^2, bi močno zmanjšala negotovost pri fototerestričnem razmejevanju razvojnih faz in posledično izboljšala kakovost sestojnih kart. Segmentacije z drugačnimi pragovi bi koristile uporabnikom na področju varstva narave in prostorskega planiranja.

Ob predpostavki, da se bodo lidarski podatki pocenili in postali široko dostopni (kot so danes na primer podatki cikličnih aerosnemanj) si lahko obetamo vrsto uporab multitemporalnih lidarskih podatkov. Navajamo dva primera:

- veččasovne primerjave DMK bodo omogočile monitoring krčenja gozdov, zaraščanja z gozdovi, črnih sečenj, naravnih ujm v gozdu, zaznavanje sprememb pokrovnosti in rabe tal, zaznavanje sprememb fragmentacije gozdne krajine. Pri dovolj natančnem DMK in dovolj velikem časovnem intervalu bi bilo mogoče površinsko beleženje višinskega prirastka gozdov;
- veččasovne primerjave DMR bodo omogočile monitoring erozijskih procesov, črnih kamnolomov, pomoč pri kartiranju rabe tal.

Splošni cilj te naloge je bil predlagati in na praktičnem primeru preizkusiti nekatere novosti pri metodah interpretacije lidarskih podatkov, ki naj bi olajšale uporabo lidarskega letalskega snemanja za informacijsko podporo intenzivnemu malopovršinskemu in sonaravnemu načinu gospodarjenja z gozdnimi ekosistemi v Sloveniji. V tem okviru sta bila zastavljena dva med seboj povezana posamična cilja:

1. razviti in preizkusiti novo metodo filtriranja talnih lidarskih odbojev iz celotnega oblaka točk in izdelave rastrskega digitalnega modela reliefa (DMR), ki bo prispevala k rešitvi problema izdelave lidarskega DMR na strmem gozdnatem reliefu. Uresničitev tega cilja je v goratih predelih Slovenije predpogoj za zanesljivejše ugotavljanje relativne višine nad tlemi za vse zabeležene lidarske odboje in s tem za točnejše lidarsko ocenjevanje lastnosti gozda;

2. primerjalno testirati različne metode modelnega napovedovanja sestojne temeljnice, drevesne sestave gozda ter svetlobnih razmer v gozdu iz lidarsko zaznanih vertikalnih profilov vegetacije nad tlemi in iz hkrati posnetih letalskih ortofotografij ter nazadnje uporabiti te podatke za razmejevanje in povzemanje lastnosti gozdnih sestojev.

Prvi delni cilj je bil dosežen v celoti. Razvili smo povsem novo metodo REIN za izračun DMR iz podatkov diskretnega lidarja, posebej namenjeno uporabi v strmem gozdnatem reliefu. REIN ne spada v nobeno izmed štirih skupin metod za izračun reliefa iz lidarskih podatkov, saj ni deterministična metoda. Izkorišča preobilje lidarskih odbojev (redundanco) za zmanjšanje napak, ki jih deterministične metode zagrešijo v strmem reliefu zaradi slabega razlikovanja med talnimi in vegetacijskimi odboji. Glede na prevladujoče gorat relief Slovenije ter pretežno pokritost z gozdom bi REIN lahko bil primerno orodje ne le za gozdarstvo, ampak tudi za mnoge druge dejavnosti v neposeljenem prostoru, ki potrebujejo podrobne in točne informacije o konfiguraciji reliefa.

Drugi delni cilj je bil dosežen, vendar nas točnost napovedi ne zadovoljuje. Na relativno velikem testnem območju smo napovedovali nekatere značilnosti gozda s pomočjo empiričnih modelov, naučenih s strojnim učenjem. Pri pripravi pojasnjevalnih spremenljivk smo ubrali pristop z vertikalnimi profili vegetacije, ki v kontekstu izbranih ciljnih spremenljivk (deleži drevesnih vrst, svetlobne značilnosti, temeljnica) še ni bil uporabljen. Uporabljena metoda razmejevanja sestojev je že znana, vendar pa so vhodni podatki za razmejevanje (modelne karte značilnosti gozda) pridobljeni na nov način.

Hipotezi naloge sta bili:

1. Mogoče je razviti metodo, ki z upoštevanjem preobilja lidarskih odbojev (redundance) v oblaku lidarskih točk doseže v strmem gozdnatem reliefu manjše napake digitalnega modela reliefa od doslej znanih metod.
2. Z metodami strojnega učenja je mogoče razviti empirične modele, ki iz lidarsko zaznanih vertikalnih profilov vegetacije in iz infrardečih letalskih ortofotografij omogočajo napovedovanje nekaterih značilnosti gozda.

Prva hipoteza je bila v testnem območju Litija potrjena, saj smo z REIN dosegli manjše vrednosti RMSE kot z morfološkim filtriranjem. Druga hipoteza je bila v testnem območju Slivnica potrjena le delno, saj smo od 21 ciljnih spremenljivk uspešno modelirali le osem, pri čemer so se strojno naučeni ansambelski modeli izkazali kot točnejši od linearnih regresijskih modelov.

V Sloveniji tovrstna gozdarska uporaba lidarja pomeni novost. Na primeru dveh gozdnogospodarskih enot smo prikazali različne načine napovedovanja lastnosti gozda z različnimi ansambelskimi metodami strojnega učenja ter z uporabo različnih kombinacij pojasnjevalnih spremenljivk, izpeljanih iz diskretnih lidarskih podatkov in iz infrardečih aeroposnetkov. Prikazane metode so tehnično zahtevne in zamudne, vendar bi bili (časovni in materialni) stroški obdelave podatkov v primeru operativne rabe lidarja v gozdarstvu manjši za en ali dva reda velikosti, ker bi že poznali najprimernejše pristope, orodja bi sprogramirali v hitrejšem jeziku in faze postopka bi bile bolj utečene. To nalogo zato štejemo za prispevek k postopni uveljavitvi lidarja pri monitoringu gozdnih ekosistemov v Sloveniji.

V nadaljevanju raziskave vidimo potrebo po naslednjih poglobitvah:

- statistično testiranje razlik v korelacijah modelov, zagotovitev boljše primerljivosti navzkrižnega preverjanja z uporabo identičnih podmnožic za vse modele,

- preučitev vpliva gostote lidarskih podatkov na zanesljivost napovedovanja sestojnih značilnosti,
- preučitev vpliva prostorskega nesovpadanja terenskih in lidarskih podatkov na zanesljivost napovedovalnih modelov,
- preučitev racionalizacije in možnosti kvalitetnejšega zajema terenskih podatkov.

6 Povzetek

V nalogi smo se ukvarjali z lidarskim zaznavanjem tal v razgibanem gozdnatem reliefu in z napovedovanjem posameznih značilnosti gozdnih sestojev iz podatkov letalskega diskretnega lidarja majhnega odtisa.

Gozd za Slovenijo predstavlja pomemben obnovljivi naravni vir. Naša država je s 60-odstotno pokritostjo z gozdom na tretjem mestu v Evropi. Gozd nima le ekonomskega pomena, ampak je tudi ključen dejavnik pri snovnih in energetskih tokovih v naravnem okolju. Pri upravljanju gozdnih ekosistemov so zato vse bolj nujna orodja za sprotno, točno in popolno oceno stanja in trendov razvoja gozda. Uveljavljene metode terestrične inventure gozdov, ki vključujejo tudi uporabo aerofoto posnetkov, so drage in zamudne, zato se inventure v Sloveniji opravljajo v 10-letnih razmakih.

V sedemdesetih letih prejšnjega stoletja je bil za vojaške namene in za topografska merjenja razvit lidar (angleška kratica za LIght Detection And Ranging), v devetdesetih letih so se začeli poskusi uporabe lidarja tudi za pridobivanje informacij o gozdu. Lidar je aktiven senzor, ki nudi podrobne informacije o notranji zgradbi gozdnega sestoja in o reliefu pod gozdom, ki jih je zelo težko dobiti s pasivnimi optičnimi ali radarskimi tehnikami daljinskega zaznavanja. Neposredno ali z modeli so iz lidarskih podatkov že ocenjevali številne parametre gozdnih sestojev. Opaziti je, da se objavljene metode v glavnem osredotočajo na umirjen relief in na borealni gozd, ki sta s stališča daljinskega zaznavanja, še posebej pa iz stališča lidarskega snemanja, bistveno enostavnejši problem, kot pa strma pobočja, pokrita z raznolikim listnatim in mešanim gozdom, kakršen prevladuje v Sloveniji.

Obstoječi algoritmi za izračun DMR iz lidarskih podatkov imajo v strmem gozdnatem reliefu težave z razlikovanjem talnih odbojev od vegetacije, saj ima v strmem reliefu lokalna okolica v oblaku podobne značilnosti kot vegetacija: velike višinske razlike pri majhnih vodoravnih razdaljah. Predstavili smo novo metodo izdelave DMR, imenovano REIN, posebej namenjeno uporabi v strmem gozdnatem reliefu: Metoda izkorišča preobilje lidarskih odbojev (redundanco) za zmanjšanje tovrstnih napak v DMR.

REIN ne spada v nobeno od skupin znanih algoritmov, saj uporablja naključno vzorčenje oblaka lidarskih odbojev. Drugi algoritmi se obnašajo deterministično in v posebnih okoliščinah vedno zagrešijo enako napako. Zaradi elementa naključnosti REIN ne zagreši enake napake pri vsaki ponovitvi vzorčenja, oziroma se napake posameznih ponovitev tipično med seboj izničijo pri končnem izračunu nadmorskih višin DMR. REIN ima zato večjo zmožnost prilagajanja raznolikim razmeram v strmem gozdnatem terenu. Ker pa poskrbi, da ima vsak del analiziranega območja enako možnost biti izbran v vzorec, je izračunan DMR homogen tudi pri nehomogenih vhodnih podatkih. REIN rešuje tudi problem negativnih osamelcev, ki so rezultat mnogokratnih odbojev.

REIN ne vsiljuje določene podatkovne strukture DMR, saj lahko izračunamo nadmorske višine tako za rastrski DMR z lokacijami v sistematični mreži kot tudi za poljubno nepravilno mrežo točk, kot je na primer trikotniška mreža TIN. Glede lomnih črt reliefa se REIN obnaša podobno kot drugi algoritmi, torej povzroči rahle zaokrožitve DMR vzdolž lomnih črt. Lomne črte je zato treba izločati v ločenem postopku in jih shranjevati posebej. Ker REIN izračuna

končni rezultat iz mnogih neodvisnih vzorcev, je mogoče uporabiti paralelno računanje in s tem čas računanja občutno skrajšati.

Obstoječe študije prikazujejo modeliranje gozdnih značilnosti s profili, ki jih neposredno daje valovni lidar velikega odtisa. Lidarski vertikalni profili vegetacije, izračunani iz podatkov diskretnega lidarja majhnega odtisa, se v zadnjem času pojavljajo kot obetajoča nova skupina pojasnjevalnih spremenljivk pri modelnem napovedovanju različnih lastnosti gozda. Lidarske vertikalne profile vegetacije smo na primeru dveh gozdnogospodarskih enot na Notranjskem na različne načine uporabili za napovedovanje deležev drevesnih vrst v gozdu in svetlobnih lastnosti gozda. Pri tem smo uporabili ansambelske metode strojnega učenja ter različne kombinacije pojasnjevalnih spremenljivk, izpeljanih iz diskretnih lidarskih podatkov in iz infrardečih aeroposnetkov.

Prikazali smo številne načine empiričnega modelnega napovedovanja značilnosti gozda pa tudi uporabo modelov za kartiranje teh značilnosti in njihovo posploševanje na raven sestojev. Od 21 zadanih ciljnih spremenljivk smo jih uspešno modelirali osem. Štirje od teh se nanašajo na drevesno sestavo (deleži treh dominantnih vrst – bukve, jelke in bora – ter delež iglavcev, ki je komplementaren z deležem listavcev), štirje pa na svetlobne razmere (odprtost, ki je komplementarna s sklepom krošenj, indeks listne površine LAI, relativni delež difuzne svetlobe v sestoju in absolutna letna količina fotosintetsko aktivnega difuznega sevanja v sestoju). Iz modelov smo izdelali karte, ki podajajo prostorsko razporeditev navedenih značilnosti.

Za osem najbolje napovedanih ciljnih spremenljivk korelacije njihovih modelov segajo od 0,76 do 0,83. Razmeroma nizke korelacije (bistveno nižje, kot jih dosegajo avtorji v strukturno in vrstno bolj homogenih borealnih gozdovih) pripisujemo predvsem raznolikosti gozda v testnem območju Slivnica, šumu v učnem vzorcu zaradi subjektivnih napak terenskih ocen in nenatančnemu pozicioniranju vzorčnih ploskev (nenatančen GPS v gozdu), zaradi česar je lahko prišlo do zamika glede na daljinsko zaznane podatke.

Ugotovili smo, da število podmodelov v ansamblu vpliva na točnost ansambelske napovedi, da pa v našem primeru točnost le še rahlo narašča pri ansamblih z več kot 160 podmodeli. Kljub rahlo boljši točnosti bi gradnja ansamblov z večjim številom podmodelov od 160 v našem primeru ne bila smiselna, saj bi se nesorazmerno podaljšal tako čas gradnje ansamblov kot tudi čas napovedovanja ciljih spremenljivk.

Pri ciljnih spremenljivkah, ki se nanašajo na drevesno sestavo, k točnosti napovedi največ prispevajo infrardeče pojasnjevalne spremenljivke, lidarski podatki pa so boljši pri pojasnjevanju svetlobnih značilnosti gozda, ki so tesno povezane prostorsko razporeditvijo biomase. Srednji in nižji deli profilov so boljši prediktor kot zgornji deli profilov (nad 20 m), kar je posledica dejstva, da je večina dreves nižjih od 20 m.

Glede na doseženo točnost napovedi so strojno naučeni ansambelski modeli primernejši od lineranih regresijskih modelov. Tudi njihova uporaba je enostavnejša, saj so manj občutljivi na prisotnost irelevantnih pojasnjevalnih spremenljivk. Od ansambelskih modelov so večciljni modeli primernejši od modelov z eno ciljno spremenljivko, saj je skupna poraba časa za pripravo enega modela manjša od porabe za pripravo mnogih enociljnih modelov. Večciljne modele je tudi lažje implementirati in izračun kart iz teh modelov je bistveno hitrejši.

Gozdni prostor smo razmejili na gozdne sestoje s slikovno segmentacijo na podlagi rastrskih kart DMK, odprtosti oziroma sklepa krošenj ter deležev dominantnih drevesnih vrst. Za vsak sestoj smo iz rastrskih kart nato izračunali povprečne vrednosti modelno napovedanih značilnosti gozda pa tudi višin dreves, ki smo jih po metodi lokalnih maksimumov ugotovili na DMK.

Prikazane metode so tehnično zahtevne in zamudne, vendar bi bili (časovni in materialni) stroški obdelave podatkov v primeru operativne rabe lidarja v gozdarstvu manjši za en ali dva reda velikosti, ker bi že poznali najprimernejše pristope, orodja bi sprogramirali v hitrejšem jeziku in faze postopka bi bile bolj utečene.

7 Summary

This thesis deals with the lidar remote sensing of the bare ground in a steep forested relief and with predictions of some forest stand attributes based on the small footprint discrete aerial lidar data.

In Slovenia forests represent a significant natural resource. By having a 60 percent forest coverage, Slovenia ranks as the third in Europe. Forests are not only of economic importance, they are also a key element in the material and energy flows in the natural environment. In forest management there is an increasing need for accurate, complete, and up-to-date evaluations of forest state and trends. The established methods of terrestrial forest inventory, including the use of aerial imagery, are expensive and time-consuming. This is why forest inventories in Slovenia are repeated only every 10 years.

In the nineteen-seventies the lidar (LIght Detection And Ranging) was introduced in the military and topographic applications. In the nineties the first lidar experiments were conducted in the forestry domain. Lidar is an active sensor providing detailed information both about internal structure of the forest stand and about the topography under the forest cover. This information is difficult to obtain by the passive optical or by the radar remote sensing methods. A number of forest stand parameters were modeled or estimated from the lidar data. The published methods are mainly focused on the moderate relief and on the boreal forests. In comparison with the steep slopes covered by the heterogeneous mixed and deciduous forests prevalent in Slovenia, both foci are considerably less difficult from the point of view of remote sensing in general and lidar remote sensing in particular.

Existing algorithms for computing DTM from the lidar data have problems in steep forested relief. These problems are due to the difficult distinction between the ground returns and the vegetation returns, which occurs because on the steep slopes the local cloud neighborhood has properties similar to the vegetation: large height differences at small horizontal distances. We introduced a new method of DTM computation from the lidar data, called REIN, which is especially adapted to the steep forested topography. The method makes use of the lidar point redundancy to mitigate these kinds of errors in the DTM.

Since REIN employs random sampling of lidar cloud, it does not belong into any of the known algorithm groups. Other algorithms behave deterministically, always generating the same error in special circumstances. Due to the element of randomness, REIN makes different error for every sample, and the errors typically cancel out in the final DTM computation. Therefore REIN has greater ability to adapt to variations in the terrain and in the forest cover. REIN also ensures that each part of the area of interest gets equal probability of being sampled, irrespective of the local ground return density. This results in a homogeneous DTM even under non-homogeneous data input conditions.

REIN does not impose a certain DTM data structure. It can accomodate either DTM as a regular grid or as a TIN. A data structure that includes break lines is favoured. Concerning break lines the presented filter algorithm behaves like other algorithms, i.e., inducing a small round off. Break lines should be extracted by a separate process and stored explicitly. Furthermore, REIN operates by interpolating DTMs from several independent samples of

lidar cloud. This enables a straightforward parallelization of REIN, potentially leading to a considerable reduction of the processing time.

The existing studies demonstrate modeling forest attributes from profiles, which are directly acquired by a large-footprint wave-form lidar. Vertical vegetation profiles, computed from the small-footprint discrete lidar data, have recently appeared as a promising new group of explanatory variables for modeling various forest attributes. We employed these vertical vegetation profiles to predict the percentages of individual tree species in the forest and to predict different light properties of the forest in two forest management units in Notranjska region, Slovenia. The ensemble methods of machine learning were used in combination with different combinations of the explanatory variables, derived both from the discrete lidar data and from the aerial infra-red imagery.

We demonstrated a number of ways to predict forest attributes by empirical modeling, showing also the implementation of the models in order to map the forest attributes and to generalize them at the level of forest stands. From the 21 selected target variables eight were successfully modeled. Four of these refer to the tree species composition (percentages of beech, fir, pine), and the other four models refer to the light properties of the forest (openness, which is complementary to canopy cover, leaf area index, average total diffuse radiation, diffuse photosynthetically active flux density under canopy). The maps showing the spatial distribution of the forest attributes were generated from the models.

The correlations for the eight best modeled target variables are between 0,76 and 0,83. Relatively modest correlations (which are significantly lower compared to the authors in the structurally and species-wise far more homogeneous boreal forests) are attributed to the heterogeneity of forests in the test area Slivnica, to the noise in the training set due to the errors in field data, and to the imprecise positioning of the field plots (due to GPS errors under the forest canopy), resulting in a spatial shift between the field data and lidar data.

The number of the sub-models in the ensemble impacts the prediction accuracy of the ensemble. In the test area accuracy only slightly increases with ensembles beyond 160 sub-models. In spite of the slightly better accuracy, construction of ensembles having more than 160 sub-models is thus unreasonable, because this would prolong both the time needed to construct the ensembles as well the time needed to compute model-based predictions.

Infrared explanatory variables contribute the most to the predictions of target variables referring to the tree composition. Lidar data are better suited to explain the forest light properties, which in turn are linked to the spatial distribution of the above-ground forest biomass. Mid- and lower parts of the profiles are better predictors compared to the upper parts of the profiles (above 20 m). This is due to most trees being lower than 20 m.

With regard to the predicting accuracy the machine-learned ensemble models are more suitable than the linear regression models. They are also easier to use, since they are less sensitive to the presence of irrelevant explanatory variables. The multi-target ensemble models are more suitable than the single-target ensemble models, because the total time to set up a multi-target model is shorter than the time needed to set up multiple single-target models. The multi-target models are also easier to implement and the computation of corresponding maps is considerably faster.

The forest has been delimited into the forest stands by image segmentation based on the raster maps of digital canopy model, openness, and percentages of the dominant tree species. The average forest attribute values were computed from the raster maps for every stand, and the average stand tree heights were computed from the digital canopy model based on the tree locations, estimated according to the local maximum method.

The demonstrated procedures are technically involved and time-consuming. However, in the case of an operational forestry use of lidar, the material costs of the procedures and the time needed to perform them would be lower by one or two orders of magnitude. This would be due to the previous knowledge of the most suitable procedure, to the software tools programmed in a fast computer language, and to the more optimized work-flow.

8 Viri

Akaike, H. 1974. A new look at the statistical model identification. IEEE Transactions on Automatic Control 19, 6, 716-723.

Aldred, A., Bonner, M. 1985. Application of airborne lasers to forest surveys. Canadian Forestry Service, Petawawa National Forestry Centre, Information Report PI-X-51, 62 str.

Andersen, H.-E., McGaughey, R., Carson, W., Reutebuch, S., Mercer, B., Allan J. 2004. A comparison of forest canopy models derived from lidar and InSAR data in a pacific northwest conifer forest. International Archives of Photogrammetry and Remote Sensing, Vol. 35, B3, Istanbul, Turkey.

Angelo, J.J., Duncan, B.W., Weishampel, J.F. 2010. Using Lidar-Derived Vegetation Profiles to Predict Time since Fire in an Oak Scrub Landscape in East-Central Florida. Remote Sensing, 514-525.

Antonarakis, A., Richards, K., Brasington, J. 2008. Object-based land cover classification using airborne LiDAR, Remote Sensing of the Environment 112, 6, 2988-2998.

Arp, H., Griesbach, J., Burns, J. 1982. apping in tropical forests: a new approach using the laser APR. Photogrammetric Engineering and Remote Sensing 48, 91-100.

Axelsson P. E. 1999. Processing of laser scanner data-algorithms and applications. ISPRS Journal of Photogrammetry and Remote Sensing 54, 138-147.

Axelsson, P. 2000. DEM generation from laser scanner data using adaptive TIN models. International Archives of Photogrammetry and Remote Sensing, 33, B4/1, 110−117. Istanbul, Turkey.

Ayres M. P., Lombarder, M. J. 2000. Assessing the consequences of global change for forest disturbance from herbivores and pathogens. The science of the total environment 262: 263-286.

Blair, J., Rabine, D., Hofton, M. 1999. The Laser Vegetation Imaging Sensor: A medium-altitude, digitisation-only, airborne laser altimeter for mapping vegetation and topography. ISPRS Journal of Photogrammetry and Remote Sensing, 54, 115−122.

Blockeel, H., De Raedt, L., Ramon, J. 1998. Top-down induction of clustering trees. V: Machine Learning, Proceedings of the 15th International Conference (J. Shavlik, ur.), Morgan Kaufmann, 1998, 55-63.

Blockeel, H., Struyf, J. 2002. Efficient algorithms for decision tree cross-validation. Journal of Machine Learning Research, 3, 621-650.

Brandtberg T., Warner, T. A., Landenberger, R. E., McGraw, J. B. 2003a. Detection and analysis of individual leaf-off tree crowns in small footprint, high sampling density lidar data from the eastern deciduous forest in North America. Remote Sensing of Environment, 85, 3, 290-303, 2003.

Brandtberg T., Warner, T. A., Landenberger, R. E., McGraw, J. B. 2003b. The Influence of the Forest Type on the Design of an Autonomous System for Individual Tree-Based Analysis of Lidar Data. V: Hyyppa J., E. Naesset, H. Olsson, T. Granqvist Pahlen, H. Reese, 2003. ScandLaser Scientific Workshop on Airborne Laser Scanning of Forests. 3.-4. September 2003, Umea, Švedska, 213-222.

Brandtberg, T. 2007. Classifying individual tree species under leaf-off and leaf-on conditions using airborne lidar, ISPRS Journal of Photogrammetry and Remote Sensing 61, 5, 325-340.

Breidenbach, J., Næsset, E., Lien, V., Gobakken, T., Solberg, S. 2010. Prediction of species specific forest inventory attributes using a nonparametric semi-individual tree crown approach based on fused airborne laser scanning and multispectral data. Remote Sensing of Environment 114:911-924.

Breiman, L. 1996. Bagging predictors. Machine Learning 24, 2, 123-140.

Breiman, L. 2001. Random forests. Machine Learning 45, 1, 5-32.

Breiman, L., Friedman, J.H., Olshen, R.A., Stone, C.J. 1984. Classification and Regression Trees.Wadsworth, Belmont.

Bufton, J. 1989. Laser altimetry measurements from aircraft and spacecraft. Proceedings IEEE, Vol. 70, 463-477.

Bunting, P., Lucas, R. M. 2006. The delineation of tree crowns in Australian mixed species forests using hyperspectral Compact Airborne Spectrographic Imager (CASI) data, Remote Sensing of the Enviroment 101, 230-248.

Cegnar T. 2003. Ekstremni pojavi se bodo stopnjevali : podnebje naše prihodnosti. Delo, 24. mar. 2003, leto 45, št. 68.

Chen, G., Hay, G.J., Zhou, Y. 2010. Estimation of forest height, biomass and volume using support vector regression and segmentation from lidar transects and Quickbird imagery. V: 18th International Conference on Geoinformatics, 18-20 June 2010.

Chen, Q., Gong, P., Baldocchi, D., Tian, Y. 2007. Estimating basal area and stem volume for individual trees from lidar data, Photogrammetric Engineering and Remote Sensing 73, 12, 1355-1365.

Coops, N.C., Hilker, T., Wulder, M., St-Onge, B., Newnham, G., Siggins, A., Trofymow, J.A. 2007. Estimating canopy structure of Douglas-fir forest stands from discrete-return LiDAR. Trees 21:295-310.

Dietterich, T. 2000. Ensemble methods in machine learning. V: Proc. of the 1st Int'l Workshop on Multiple Classifier Systems, vol. 1857 of LNCS. Springer, Berlin, 1-15.

Donoghue, D.N.M., Watt, P.J., Cox, N.J., Wilson, J. 2007. Remote sensing of species mixtures in conifer plantations using LiDAR height and intensity data. Remote Sensing of Environment 110:509-522.

Elmqvist, M. 2001. Ground estimation of lasar radar data using active shape models. OEEPE workshop on airborne laser scanning and interferometric SAR for detailed digital elevation models, Stockholm, Sweden.

Evans, J.S., Hudak, A.T., Faux, R., Smith, A.M.S. 2009. Discrete return LiDAR in natural resources: recommendations for project planning, data processing, and deliverables. Remote Sensing 1: 776-794.

Falkowski, M.J., Evans, J.S., Martinuzzi, S., Gessler, P.E., Hudak, A.T. 2009. Characterizing forest succession with lidar data: an evaluation for the Inland Northwest, USA. Remote Sensing of Environment 113, 946-956.

Franklin, J.F., Cromack Jr., K., Denison, W., McKee, A., Maser, C., Sedell, J., Swanson, F., Juday, G. 1981. Ecological characteristics of old-growth Douglas-fir forests. USDA, For. Serv., General Technical Report PNW-118. Pac. Northwest For. Range Exp. Sta., Portland, Oregon. 48 p.

Goodwin, N., Coops, N., Culvenor, D. 2006. Assessment of forest structure with airborne LiDAR and the effects of platform altitude, Remote Sensing of the Environment 103, 2, 140-152.

Hansen, L., Salamon, P. 1990. Neural network ensembles. IEEE Transactions on Pattern Analysis and Machine Intelligence 12, 993-1001.

Haralick, R. M., 1979. Statistical and structural approaches to texture. Proceedings of the IEEE, Vol. 67, 786-804.

Haralick, R. M., Shapiro, L. G. 1992. Computer and Robot Vision, Vol. I. Reading, MA: Addison Wesley.

Harding, D. J., Lefsky, M. A., Parker, G. G., Blair, J. B. 2001. Laser altimeter canopy height profiles: methods and validation for closed-canopy, broadleaf forests. Remote Sensing of Environment, Vol. 76, 3, 283-297.

Haugerud R. A., Harding D. J. 2001. Some algorithms for virtual deforestation (vdf) of lidar topographic survey data. International Archives of Photogrammetry and Remote Sensing, XXXIV-3/W4:211-217, 2001.

Haywood, A., Stone, C. 2011. Mapping eucalypt forest susceptible to dieback associated with bell miners (Manorina melanophys) using laser scanning, SPOT 5 and ancillary topographical data. Ecological Modelling 222, 2011, 1174-1184.

Hilker, T., Wulder, M.A., Coops, N.C. 2008. Update of forest inventory data with LiDAR and high spatial resolution satellite imagery. Canadian Journal of Remote Sensing 34:5-12.

Hirata Y., Sato K., Shibata M., Nishizono T., 2003. The capability of helicopter-borne laser scanner data in a temperate deciduous forest. V: Hyyppa J., E. Naesset, H. Olsson, T. Granqvist Pahlen, H. Reese, 2003. ScandLaser Scientific Workdhop on Airborne Laser Scanning of Forests. 3.-4. September 2003, Umea, Švedska, 175-180.

Hjaltason, G. R., Samet, H. 1995. Ranking in spatial databases. V: Egenhofer & Herring (ur.), Lecture notes in computer science, Springer, 951, 83-95.

Holmgren, J. 2004. Prediction of tree height, basal area and stem volume in forest stands using airborne laser scanning. Scandinavian Journal of Forest Research, Volume 19, Number 6, December 2004 , 543-553.

Holmgren, J., Persson, A. 2004. Identifying species of individual trees using airborne laser scanning. Remote Sensing of Environment 90, 415-423.

Holmgren, J., Persson, A., Soederman, U. 2008. Species identification of individual trees by combining high resolution LiDAR data with multi-spectral images, Internationl Journal of Remote Sensing 29, 5, 1537-1552.

Hopkinson, C., Chasmer, L., Young-Pow, C., Treitz, P. 2004. Assessing forest metrics with a ground-based scanning LiDAR. Canadian Journal of Remote Sensing 34:573-583.

Hudak, A., Crookston, N., Evans, J., Hall, D., Falkowski, M. 2008. Nearest neighbor imputation of species-level, plot-scale forest structure attributes from LiDAR data, Remote Sensing of the Environment 112, 5, 2232-2245.

Hudak, A.T., Crookston, N.L., Evans, J.S., Falkowski, M.J., Smith, A.M.S., Gessler, P.E., Morgan, P. 2006. Regression modeling and mapping of coniferous forest basal area and tree density from discrete-return lidar and multispectral satellite data. Canadian Journal of Remote Sensing, Vol. 32, No. 2, 126-138.

Hug, C., Ullrich, A., Grimm, A. 2004. Litemapper-5600 — a waveform digitizing LiDAR terrain and vegetation mapping system. The International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences XXXVI part 8/W2: 24-29.

Hyde, P., Dubayah, R., Peterson, B., Blair, J. B., Hofton, M., Hunsaker, C., Knox, R., Walker, W. 2005. Mapping forest structure for wildlife habitat analysis using waveform lidar: Validation of montane ecosystems. Remote Sensing of Environment 96, 3-4, 427-437.

Hyde, P., Dubayah, R., Walker, W., Blair, B. J., Michelle, H., Hunsaker, C. 2006. Mapping forest structure for wildlife habitat analysis using multi-sensor (LiDAR, SAR/InSAR, ETM+, Quickbird) synergy. Remote Sensing of the Environment 102, 63-73.

Hyyppa J., Hyyppa H., Litkey P., Yu X., Haggrén H., Rönnholm P., Pyysalo U., Pitkanen J., Maltamo M. 2004. Algorithms and methods of airborne laser scanning for forest measurements. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. XXXVI, 8/W2, Freiburg, 82-89.

Hyyppa, J., Inkinen, M. 1999. Detection and estimating attributes for single trees using laser scanner. The Photogrammetric Journal of Finland 16, 27-42.

Ip, A., El-Sheimy, N., Hutton, J. 2004. Performance analysis of integrated sensor orientation. International Archives of Photogrammetry and Remote Sensing, Vol. 35, B5, Istanbul, Turkey.

Jacobsen, K., Lohmann, P. 2003. Segmented filtering of laser scanner DSMs. International Archives of Photogrammetry and Remote Sensing, 34, 3/W13. Dresden, Germany.

Jang, J., Payan, V., Viau, A., Devost, A. 2008. The use of airborne lidar for orchard tree inventory, International Journal of Remote Sensing 29, 6, 1767-1780.

Jurc, D., Ogris, N. 2005. First reported outbreak of charcoal disease caused by Biscogniauxia mediterranea on Turkey oak in Slovenia. New Disease Reports 11.

Jurc, M. 2003. Se spremembe podnebja odražajo v povečani prizadetosti gozda in gradacijah žuželk?, Delo, priloga Znanost, 23.9.2003

Kaartinen, H., et al. 2005. Accuracy of 3D city models: EuroSDR comparison. International Archives of Photogrammetry and Remote Sensing, Vol. 36, 3/W19. Enschede, The Netherlands.

Kajfež-Bogataj L., Sušnik A., Črepinšek Z., Bergant K., Kurnik B., Matajc I., Rogelj D., Cegnar T., Žust A., Dolinar M., Pečenko A., Gregorič G. 2003. Ranljivost slovenskega kmetijstva in gozdarstva na podnebno spremenljivost in ocena predvidenega vpliva. Agencija Republike Slovenije za okolje, 146.

Kass, M., Witkin, A., Terzopoulos, D. 1988. Snakes: Active contour models. International Journal of Computer Vision, 1, 321−331.

Kenji Kira, K., Rendell, L.A. 1992. A Practical Approach to Feature Selection. V: Ninth International Workshop on Machine Learning, 249-256.

Kilian, J., Haala, N., Englich, M. 1996. Capture and evaluation of airborne laser data. International Archives of Photogrammetry and Remote Sensing, 31, 3, 383−388. Vienna, Austria.

Kirchhof, M., Jutzi, B., Stilla, U., 2008. Iterative processing of laser scanning data by full waveform analysis. ISPRS Journal of Photogrammetry and Remote Sensing 63:99-114.

Kobler, A., Pfeifer, N., Orinc, P., Todorovski, L., Oštir, K., Džeroski, S. 2007. Repetitive interpolation : a robust algorithm for DTM generation from Aerial Laser Scanner Data in forested terrain. Remote sensing of Environment. 108, 1, 9-23.

Kocev, D. 2011. Ensembles for predicting structured outputs. Doctoral dissertation, Jožef Stefan International Postgraduate School Ljubljana, Slovenia.

Kocev, D., Džeroski, S., White, M.D., Newell, G.R., Griffioen, P. 2009. Using single- and multi-target regression trees and ensembles to model a compound index of vegetation condition. Ecological Modelling, Vol. 220, 8, 1159-1168.

Kocev, D., Vens, C., Struyf, J., and Dzeroski, S. 2007. Ensembles of multi-objective decision trees. In ECML '07: Proceedings of the 18th European Conference on Machine Learning, LNCS 4701, pages 624-631. Springer, Berlin-Heidelberg.

Kocev, D., Vens, C., Struyf, J.,Džeroski, S. 2007. Ensembles of multi-objective decision trees. V: Machine Learning: ECML 2007, 18th European Conference on Machine Learning, Proceedings, volume 4701 of LNCS, 624-631.

Koetz, B., Morsdorf, F., Sun, G., Ranson, K., Itten, K., Allgoewer, B. 2006. Inversion of a Lidar Waveform Model for Forest Biophysical Parameter Estimation, IEEE Geoscience and Remote Sensing Letters, 3, 1, 49-53.

Kononenko, I. 1994. Estimating Attributes: Analysis and Extensions of RELIEF. V: European Conference on Machine Learning, 171-182.

Korpela, I., Koskinen, M., Vasander, H., Holopainen, M., Minkkinen, K. 2009. Airborne small-footprint discrete-return LiDAR data in the assessment of boreal mire surface patterns, vegetation, and habitats. Forest Ecology and Management, Vol. 258, 7, 1549-1566.

Kozorog E. 2003. Časovno in stroškovno ovrednotenje KVM in primerjava z drugimi metodami izmere gozdov v OE Tolmin. V: Hočevar M., Matijašič D., 2003. Monitoring gozdnih ekosistemov-kontrolno vzorčna metoda. Zbornik referatov. Gozdarski inštitut Slovenije in Zavod za gozdove Slovenije, 13.

Krabill, W.B., Collings, J.G., Swift, R.N., Butler, M.L. 1980. Airborne laser topographic mapping results from Initial Joint NASA/U.S. Army Corps of Engineers Experiment. NASA Technical Memorandum 73287, Wallops Flight Center.

Kraus, K., Pfeifer, N. 1998. Determination of terrain models in wooded areas with airborne laser scanner data. ISPRS Journal of Photogrammetry and Remote Sensing, 53, 193−203.

Leckie, D., Gougeon, F., Hill, D., Quinn, R., Armstrong, L., Shreenan, R. 2003. Combined high-density LiDAR and multispectral imagery for individual tree crown analysis. Canadian Journal of Remote Sensing 29:633-649.

Lee, A., Lucas, R. M. 2007. A LiDAR derived canopy density model for tree stem and crown mapping in Australian woodlands, Remote Sensing of the Environment 111, 493-518.

Lefsky M.A., Cohen W. B., Acker S. A., Spies T. A., Parker G. G., Harding D. 1999. Lidar remote sensing of biophysical properties and canopy structure of forest of Douglas-fir and western hemlock. Remote Sensing of Environment 70: 339-361.

Lefsky, M.A., Cohen, W. B., Parker, G. G., Harding, D. J. 2002. Lidar remote sensing for ecosystem studies. Bioscience 52, 1, 19-30

Lefsky, M.A., Cohen, W.B., Spies, T.A. 2001. An evaluation of alternate remote sensing products for forest inventory, monitoring, and mapping of Douglas-fir forest in Western Oregon. Canadian Journal of Remote Sensing 31:78-87.

Lefsky, M.A., Harding, D., Cohen, W.B , Parker, G., Shugart, H.H. 1999. Surface Lidar Remote Sensing of Basal Area and Biomass in Deciduous Forests of Eastern Maryland, USA, Remote Sensing of Environment, Volume 67, Issue 1, 83-98.

Lefsky, M.A., Harding, D.J., Keller, M., Cohen, W.B., Carabajal, C.C., Espirito-Santo, F.D.B., Hunter, M.O., Oliveira Jr., R. 2005. Estimates of forest canopy height and aboveground biomass using ICESat. Geophysical Research Letters, 32, 22.

Lefsky, M.A., Hudak, A. T., Guzy, M., Cohen, W. B. 2005. Combining LiDAR estimates of biomass and Landsat estimates of stand age for spatially extensive validation of modeled forest productivity, Remote Sensing of the Environment 95, 4, 549-558.

Lim, K., Treitz, P., Wulder, M., St-Onge, B., Flood, M. 2003. LiDAR remote sensing of forest structure. Progress in Physical Geography, 27, 88-106.

Lohmann, P., Koch, A., Schaeffer, M. 2000. Approaches to the filtering of laser scanner data. International Archives of Photogrammetry and Remote Sensing, 33, B3/1, 534−541.

Lovell, J.L., Jupp, D.L.B., Newnham, G.J., Coops, N.C., Culvenor, D.S. 2005. Simulation study for finding optimal LiDAR acquisition parameters for forest height retrieval. Forest Ecology and Management 214:398-412.

Lucas, R, Lee, A., Armston, J., Breyer, J., Bunting, P., Carreiras, J. 2008. Advances in forest characterisation, mapping and monitoring through integration of LiDAR and other remote sensing datasets. SilviLaser 2008, Sept. 17-19, 2008. Edinburgh, UK.

MacArthur, R.H., Horn, H.S. 1969. Foliage profile by vertical measurements. Ecology 50:802-804.

Maclean G., Krabill W. 1986. Gross-merchantable timber volume estimation using an airborne lidar system. Canadian Journal of Remote Sensing 12, 7-18.

Maclean, G. 1982. Timber volume estimation using crosssectional photogrammetric and densitometric methods, MSc thesis, University of Wiscousin, Madison, 227 s.

Magnussen, S., Boudewyn, P. 1998. Derivations of stand heights from airborne laser scanner data with canopy-based quantile estimators. Canadian Journal of Forest Research 28, 1016-1031.

Maltamo, M., Eerikainen, K., Pitkanen, J., Hyyppa, J., Vehmas, M. 2004. Estimation of timber volume and stem density based on scanning laser altimetry and expected tree size distribution functions. Remote Sensing of Environment 90:319-330.

McCombs, J.W., Roberts, S.D., Evans, D.L. 2003. Influence of fusing LiDAR and multispectral imagery on remotely sensed estimates of stand density and mean tree height in a managed loblolly pine plantation. Forest Science 49:457-466.

Means, J. E., Acker, S. A., Fitt, B. J., Renslow, M., Emerson, L., Hendrix, C. J. 2000. Predicting forest stand characteristics with airborne scanning lidar. Photogrammetric Engineering and Remote Sensing 66, 1367-1371.

Means, J., Acker, S., Harding, D., Blair, J., Lefsky, M., Cohen, W., Harmon, M., McKee, A. 1999. Use of largefootprint scanning airborne lidar to estimate forest stand characteristics in the western cascades of Oregon. Remote Sensing of Environment 67, 298-308.

Measures, R.M. 1992. Laser remote sensing: fundamentals and applications. Malabar, Fla.: Krieger Pub.

MKGP-Ministrstvo za kmetijstvo, gozdarstvo in prehrano 1998. Pravilnik o gozdnogospodarskih in gozdnogojitvenih načrtih. Uradni list RS, 23. 1. 1998, št. 5, 256-282.

Moffiet, T., Mengersen, K., Witte, C., King, R., Denham, R. 2005. Airborne laser scanning: SilviLaser Exploratory data analysis indicates potential variables for classification of individual trees or forest stands according to species. ISPRS Journal of Photogrammetry and Remote Sensing, 59, 5, 289-309.

Morsdorf, F., Koetz, B., Meier, E., Itten, K.I., Allgoewer, B. 2006. Estimation of LAI and fractional cover from small footprint airborne laser scanning data based on gap fraction. Remote Sensing of Environment 104:50-61.

Morsdorf, F., Nichol, C., Malthus, T., Woodhouse, I.H. 2009. Assessing forest structural and physiological information content of multispectral LiDAR waveforms by radiative transfer modelling. Remote Sensing of Environment 113:2152-2163.

Muss, J.D., Mladenoff, D.J., Townsend, P.A. 2011. A pseudo-waveform technique to assess forest structure using discrete lidar data. Remote Sensing of Environment 115, 824-835.

Næsset E. 1997a. Determination of mean tree height of forest stands using airborne laser scanner data. ISPRS Journal of Photogrammetry and Remote Sensing 52, 49-56.

Næsset E. 1997b. Estimating timber volume of forest stands using airborne laser scanner data. Remote Sensing of Environment 61, 246-253.

Næsset, E., Gobakken, T. 2008. Estimation of above- and below-ground biomass across regions of the boreal forest zone using airborne laser, Remote Sensing of the Environment 112, 6, 3079-3090.

Næsset, E., Gobakken, T., Holmgren, J., Hyyppä, J. Maltamo, M., Nilsson, M., Olsson, H., Persson, Söderman, U. 2004. Laser scanning of forest resources: the Nordic experience. Scandinavian Journal of Forest Research 19, 6, 482-499.

Næsset, E., Okland, T. 2002. Estimating tree height and tree crown properties using airborne scanning laser in a boreal nature reserve. Remote Sensing of Environment 79, 105-115.

Nardinocchi, C., Forlani, G., Zingaretti, P. 2003. Classification and filtering of laser data. International Archives of Photogrammetry and Remote Sensing, 34, 3W13. Dresden, Germany.

Nelson R., Krabill W., Maclean G. 1984. Determining forest canopy characteristics using airborne laser data. Remote Sensing of Environment 15, 201-212.

Nelson, R. F., Hyde, P., Johnson, P., Emessiene, B., Imhoff, M. L., Campbell, R., Edwards, W. 2007. Investigating RaDAR-LiDAR synergy in a North Carolina pine forest. Remote Sensing of Environment 110, 1, 98-108.

Nelson, R., Krabill, W., Maclean, G. 1984. Determining forest canopy characteristics using airborne laser data. Remote Sensing of Environment 15, 201-12.

Oliver, C.D., Larson, B.C. 1990. Forest Stand Dynamics. McGraw-Hill Inc., New York.

Ørka, H.O., Næsset, E., Bollandsas, O.M. 2009. Classifying species of individual trees by intensity and structure features derived from airborne laser scanner data. Remote Sensing of Environment 113:1163-1174.

Persson, A., Holmgren, J., Söderman, U. 2002. Detecting and measuring individual trees using an airborne laser scanner Photogrammetric Engineering and Remote Sensing 68:925-932.

Pfeifer, N., Stadler, P., Briese, C. 2001. Derivation of digital terrain models in the SCOP++ environment. OEEPE workshop on airborne laserscanning and interferometric SAR for detailed digital elevation models, Stockholm, Sweden.

Popescu, S., Wynne, R.H. 2004. Seeing the trees in the forest: using lidar and multispectral data fusion with local filtering and variable window size for estimating tree height. Photogrammetric Engineering & Remote Sensing 70:589-604.

Popescu, S., Zhao, K. 2008. A voxel-based lidar method for estimating crown base height for deciduous and pine trees, Remote Sensing of the Environment 112, 3, 767-781.

Riaño, D., Chuvieco, E., Ustin, S.L., Salas, J., Ribeiro, L.M., Viegas, D.X., Moreno, J.M. and Fernández, H. 2005. Estimation of shrub height for fuel type mapping combining airborne Lidar and simultaneous and co-registered colour infrared images. V: De la Riva J., Pérez-Cabello F., Chuvieco E. (Ur.): Proceedings of the 5th International Workshop on Remote Sensing and GIS Applications to Forest Fire Management: Fire Effects Assessment, European Association of Remote Sensing Laboratories (EARSeL) Special Interest Group on Forest Fires, Zaragoza, 79-84.

Riaño, D., Meier, E., Allgoewer, B., Chuvieco, E., Ustin, S.L. 2003. Modeling airborne laser scanning data for the spatial generation of critical forest parameters in fire behavior modeling. Remote Sensing of Environment 86:177-186.

Robnik-Sikonja, M., Kononenko, I. 1997. An adaptation of Relief for attribute estimation in regression. V: Fourteenth International Conference on Machine Learning, 296-304.

Rooker Jensen, J.L., Humes, K.S., Conner, T., Williams, C.J., DeGroot, J. 2006. Estimation of biophysical characteristics for highly variable mixed-conifer stands using small-footprint lidar. Canadian Journal of Forest Research 36, 5, 1129-1138.

Samet, H. 1984. The Quadtree and related hierarchical data structures. ACM Computing Surveys (CSUR), 16/2, 187−260.

Sasaki, T., Imanishi, J., Ioki, K., Morimoto, Y., Kitada, K. 2008. Estimation of leaf area index and canopy openness in broadleaved forest using an airborne laser scanner in comparison with high-resolution near-infrared digital photography. Landscape and Ecological Engineering 4:47-55.

Schiewe, J. 2001. Ein regionen-basiertes Verfahren zur Extraktion der Geländeoberfläche aus Digitalen Oberflächen-Modellen. Photogrammetrie, Fernerkundung, Geoinformation, 2, 81−90.

Shewchuk, J. R. 2005. Triangle: A two-dimensional quality mesh generator and Delaunay triangulator. http://www.cs.cmu.edu/~quake/triangle.html, accessed September 29, 2005.

Sithole G., Vosselman G. 2003. Automatic Structure Detection in a Point-Cloud of an Urban Landscape. Proc. 2nd GRSS/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas. 67-71.

Sithole, G. 2001. Filtering of laser altimetry data using a slope adaptive filter. International Archives of Photogrammetry and Remote Sensing, 34, 3/W4, 203−210. Annapolis, ML.

Sithole, G. 2005. Segmentation and Classification of Airborne Laser Scanner Data, Dissertation, TU Delft, ISBN 90 6132 292 8, Publications on Geodesy of the Netherlands Commission of Geodesy, Vol. 59.

Sithole, G., Vosselman, G. 2004. Experimental comparison of filter algorithms for bare—Earth extraction from airborne laser scanning point clouds. ISPRS Journal of Photogrammetry and Remote Sensing, 59, 85−101.

Sohn, G., Dowman, I. 2002. Terrain surface reconstruction by the use of tetrahedron model with the MDL criterion. International Archives of Photogrammetry and Remote Sensing, 34, 336−344. Graz, Austria.

Steinvall, O. 2003. Laser Systems for Vegetation and Terrain mapping-a Look at Present and Future Technologies and Capabilities. V: Hyyppa J., E. Naesset, H. Olsson, T. Granqvist Pahlen, H. Reese, 2003. ScandLaser Scientific Workdhop on Airborne Laser Scanning of Forests. 3.-4. September 2003, Umea, Švedska, 9-20.

Stojanova, D., Panov, P., Gjorgjioski, V., Kobler, A., Džeroski, S. 2010. Estimating vegetation height and canopy cover from remotely sensed data with machine learning, Ecological Informatics, Volume 5, Issue 4, 256-266.

Stone, J.N., Porter, J.L. 1998. What is Forest Stand Structure and How to Measure It? Northwest Science, Volume 72, Special Issue No. 2, Washington State University Press.

St-Onge, B., Vega, C., Fournier, R., Hu, Y. 2008. Mapping canopy height using a combination of digital stereophotogrammetry and lidar, International Journal of Remote Sensing 29, 11, 3343-3364.

Struyf, J., Džeroski, S. 2006. Constraint based induction of multi-objective regression trees. In Proc. of the 4th International Workshop on Knowledge Discovery in Inductive Databases KDID, LNCS 3933, 222-233. Springer.

Suarez, J. C., Ontiveros, C., Smith, S., Snape, S. 2005. Use of airborne LiDAR and aerial photography in the estimation of individual tree heights in forestry, Computers and Geosciences 31, 253-262.

Suratno, A., Seielstad, C., Queen, L. 2009. Tree species identification in mixed coniferous forest using airborne laser scanning. ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 64, 683-693.

Thies M., Koch B., Spiecker H. 2002. Einsatzmoeglichkeiten von Laserscannern fuer Wald- und Landschaftsinventuren. AFZ-DerWald 8/2002, 395-397.

Thomas, V, Treitz, P., McCaughey, J. H., Morrison, I. 2006. Mapping stand-level forest biophysical variables for a mixedwood boreal forest using lidar: an examination of scanning density. Canadian Journal of Forest Research 36, 1, 34-47.

Todd K. W., Csillag F., Atkinson P. M. 2003. Three-dimensional mapping of light transmittance and foliage distribution using lidar. Canadian Journal of Remote Sensing, Vol. 29, No. 5, 544-555.

van Leeuwen, M., Nieuwenhuis, M. 2010. Retrieval of forest structural parameters using LiDAR remote Sensing. European Journal of Forest Research 129, 749-770.

von Hansen, W., Voegtle, T. 1999. Extraktion der Geländeoberfläche aus flugzeuggetragenen Laserscanner-Aufnahmen. Photogrammetrie, Fernerkundung, Geoinformation, 4, 229−236.

Vosselman, G. 2000. Slope based filtering of laser altimetry data. International Archives of Photogrammetry and Remote Sensing, Vol. 33, B3/2, 935-942. Amsterdam, The Netherlands.

Wagner, W., Hollaus, M., Briese, C., Ducic, V. 2008. 3D vegetation mapping using small-footprint full-waveform airborne laser scanners. International Journal of Remote Sensing 29:1433-1452.

Wagner, W., Ullrich, A., Ducic, V., Melzer., T., Studnicka, N. 2006. Gaussian decomposition and calibration of a novel smallfootprint full-waveform digitising airborne laser scanner. ISPRS Journal of Photogrammetry and Remote Sensing 60:100-112.

Wagner,W., Ullrich, A., Ducic, V., Melzer, T., Studnicka, N. 2006. Gaussian decomposition and calibration of a novel small-footprint full-waveform digitising airborne laser scanner. ISPRS Journal of Photogrammetry and Remote Sensing, 60, 100−112.

Wang, Y., Weinacker, H., Koch, B. 2008. A Lidar Point Cloud Based Procedure for Vertical Canopy Structure Analysis And 3D Single Tree Modelling in Forest. Sensors 2008, 8, 3938-3951.

Wulder M. A. 2003. The Current Status of Laser Scanning of Forests in Canada and Australia. V: Hyyppa J., E. Naesset, H. Olsson, T. Granqvist Pahlen, H. Reese, 2003. ScandLaser Scientific Workdhop on Airborne Laser Scanning of Forests. 3.-4. September 2003, Umea, Švedska, 21-33.

Wulder, M., Han, T., White, J., Sweda, T., Tsuzuki, H. 2007. Integrating profiling LIDAR with Landsat data for regional boreal forest canopy attribute estimation and change characterization, Remote Sensing of the Environment 110, 1, 123-137.

Yu X., Hyyppa J., Kaartinen H., Maltamo M. 2004. Automatic detection of harvested trees and determination of forest growth using airborne laser scanning. Remote Sensing of Environment 90, 451-462.

Zakšek, K., Pfeifer, N. 2006. An improved morphological filter for selecting relief points from a LIDAR point cloud in steep areas with dense vegetation. Technical Report, Institute of Anthropological and Spatial Studies, Solvenia. http://iaps.zrc-sazu.si/files/File/Publikacije/Zaksek_Pfeifer_ImprMF.pdf, accessed 6.6.2006.

Zhang, K., Chen, S., Whitman, D., Shyu, M., Yan, J., Zhang, C. 2003. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. IEEE Transactions on Geoscience and Remote Sensing, 41, 4, 872−882.

Zhao, K., Popescu, S. 2009. Lidar-based mapping of leaf area index and its use for validating GLOBCARBON satellite LAI product in a temperate forest of the southern USA. Remote Sensing of Environment 113:1628-1645.

Zimble, D.A., Evans, D.L., Carlson, G.C., Parker, R.C., Grado, S.C., Gerard, P.D. 2003. Characterizing vertical forest structure using smallfootprint airborne LiDAR. Remote Sensing of Environment 87:171-182.

Zwally, H. J., Schutz, B., Abdalati, W., Abshire, J., Bentley, C., Brenner, A., Bufton, J., Dezio, J., Hancock, D., Harding, D., Herring, T., Minster, B., Quinn, K., Palm, S., Spinhirne, J., Thomas, R. 2002. ICESat's laser measurements of polar ice, atmosphere, ocean, and land. Journal of Geodynamics, Volume 34/3-4, 405-445.

9 Priloge

PRILOGA A: Seznam ciljnih in pojasnjevalnih spremenljivk

Ciljne spremenljivke so označene z **modro**.

IME SPREMENLJIVKE	OPIS SPREMENLJIVKE	
gha	Hektarska temeljnica	
deligl	Delež iglavcev	
delbukev	Delež bukve	
deljavor	Delež javorjev	
delbgaber	Delež belega gabra	
delcgaber	Delež črnega gabra	
delhrast	Delež hrastov	
delmjesen	Delež malega jesena	
delvjesen	Delež velikega jesena	
delostalilst	Delež ostalih listavcev	
delsmreka	Delež smreke	
deljelka	Delež jelke	
delbor	Delež borov	
delmacesen	Delež macesna	
delostaliigl	Delež ostalih iglavcv	
openness_x	Odprtost kot komplement sklepa krošenj; definirana je kot delež z vegetacijo nezakritega neba v vertikalni projekciji na tla	Pripona x označuje zorni kot (45, 60, 120 in 170°), pri katerem je spremenljivka izračunana
lai2000lin_x	Indeks listne površine LAI	
lai2000glin_x	Generaliziran indeks listne površine LAI	
directsitefactor_x	Delež povprečne direktne svetlobe pod sestojem v primerjavi s prispelo direktno svetlobo nad sestojem	
indirectsitefactor_x	Delež povprečne difuzne svetlobe pod sestojem v primerjavi s prispelo difuzno svetlobo nad sestojem	
totalsitefactor_x	Delež povprečne vse svetlobe pod sestojem v primerjavi z vso prispelo svetlobo nad sestojem	
ppfddirectunder_x	Količina direktnega fotosintetsko aktivnega sevanja pod sestojem v rastni sezoni	
ppfddiffuseunder_x	Količina difuznega fotosintetsko aktivnega sevanja pod sestojem v rastni sezoni	
ppfdtotalunder_x	Količina vsega fotosintetsko aktivnega sevanja pod sestojem v rastni sezoni	

IME SPREMENLJIVKE	OPIS SPREMENLJIVKE	
avg_vpv_0_rx	Povprečna vrednost profila pri tleh	Pripona x označuje polmer veljavnosti (5, 10 in 20 m) spremenljivke
avg_vpv_1_rx	Povprečna vrednost profila na višini do 1 m	
avg_vpv_2_rx	Povprečna vrednost profila na višini 1 do 2 m	
…	…	
avg_vpv_31_rx	Povprečna vrednost profila na višini 30 do 31 m	
avg_vpv_32_rx	Povprečna vrednost profila na višini 31 do 32 m	
avg_vpv_100_rx	Povprečna vrednost profila na višini nad 32 m	
avg_vpv_kumul_100do0_rx	Kumulativna vsota vrednosti profilov od tal navzgor	
avg_vpv_kumul_100do1_rx	Kumulativna vsota vrednosti profilov od višine 1 m navzgor	
avg_vpv_kumul_100do2_rx	Kumulativna vsota vrednosti profilov od višine 2 m navzgor	
…	…	
avg_vpv_kumul_100do29_rx	Kumulativna vsota vrednosti profilov od višine 29 m navzgor	
avg_vpv_kumul_100do30_rx	Kumulativna vsota vrednosti profilov od višine 30 m navzgor	
avg_vpv_kumul_100do31_rx	Kumulativna vsota vrednosti profilov od višine 31 m navzgor	
stdev_vpv_0_rx	Standardni odklon vrednosti profila pri tleh	
stdev_vpv_1_rx	Standardni odklon vrednosti profila na višini do 1 m	
stdev_vpv_2_rx	Standardni odklon vrednosti profila na višini 1 do 2 m	
…	…	
stdev_vpv_31_rx	Standardni odklon vrednosti profila na višini 30 do 31 m	
stdev_vpv_32_rx	Standardni odklon vrednosti profila na višini 31 do 32 m	
stdev_vpv_100_rx	Standardni odklon vrednosti profila na višini nad 32 m	
stdev_vpv_kumul_100do0_rx	Standardni odklon vrednosti profila od tal navzgor	
stdev_vpv_kumul_100do1_rx	Standardni odklon vrednosti profila od višine 1 m navzgor	
stdev_vpv_kumul_100do2_rx	Standardni odklon vrednosti profila od višine 2 m navzgor	
…	…	
stdev_vpv_kumul_100do29_rx	Standardni odklon vrednosti profila od višine 29 m navzgor	
stdev_vpv_kumul_100do30_rx	Standardni odklon vrednosti profila od višine 30 m navzgor	
stdev_vpv_kumul_100do31_rx	Standardni odklon vrednosti profila od višine 31 m navzgor	
dof_ndvi_gurs_rx_avg	Povprečje vrednosti NDVI za DOF (GURS)	
dof_ndvi_gurs_rx_std	Standardni odklon vrednosti NDVI za DOF (GURS)	
dof_ndvi_geoin_rx_avg	Povprečje vrednosti NDVI za DOF (GEOIN)	
dof_ndvi_geoin_rx_std	Standardni odklon vrednosti NDVI za DOF (GEOIN)	

IME SPREMENLJIVKE	OPIS SPREMENLJIVKE	
naem00_y_rx	Matrika soseščin za izračun teksture; normalizirana frekvenca frekvenca soseščin 0. in 0. razreda	Pripona y označuje red sosešcine (1, 2 in 4), pripona x pa polemr veljavnosti (5, 10 in 20 m) spremenljivke
naem01_y_rx	Matrika soseščin za izračun teksture; normalizirana frekvenca frekvenca soseščin 0. in 1. razreda	
…		
naem03_y_rx	Matrika soseščin za izračun teksture; normalizirana frekvenca frekvenca soseščin 0. in 3. razreda	
…		
naem33_y_rx	Matrika soseščin za izračun teksture; normalizirana frekvenca frekvenca soseščin 3. in 3. razreda	
con_1_r5	Contrast po Haralicku (gl. Prilogo B)	
dis_1_r5	Dissimilarity po Haralicku (gl. Prilogo B)	
hom_1_r5	Homogeneity po Haralicku (gl. Prilogo B)	
asm_1_r5	Angular Second Moment po Haralicku (gl. Prilogo B)	
mxp_1_r5	Maximum Probability po Haralicku (gl. Prilogo B)	
ent_1_r5	Entropy po Haralicku (gl. Prilogo B)	
mn1_1_r5	AEM Mean (glede na izhodisce) po Haralicku (gl. Prilogo B)	
mn2_1_r5	AEM Mean (glede na soseda) po Haralicku (gl. Prilogo B)	
vr1_1_r5	Variance (glede na izhodisce) po Haralicku (gl. Prilogo B)	
vr2_1_r5	Variance (glede na soseda) po Haralicku (gl. Prilogo B)	
cor_1_r5	Correlation po Haralicku (gl. Prilogo B)	

PRILOGA B: Način izračuna teksturnih indeksov po Haralicku (1979)

```
def con(self):  # Haralick - contrast
    self.contrast = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.contrast += self.naem[i][j] * (i - j)**2
def dis(self): # Haralick - dissimilarity
    self.dissimilarity = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.dissimilarity += self.naem[i][j] * (i - j)
def hom(self): # Haralick - homogeneity
    self.homogeneity = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.homogeneity += self.naem[i][j] / (1 + (i - j)**2)
def asm(self): # Haralick - Angular Second Moment
    self.angular2ndmoment = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.angular2ndmoment += self.naem[i][j]**2
def mxp(self): # Haralick - Maximum Probability
    self.maxprobability = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.maxprobability = max(self.naem[i][j],self.maxprobability)
def ent(self): # Haralick - entropy
    self.entropy = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.entropy += self.naem[i][j] * (-self.log_(self.naem[i][j]))
def mn1(self): # Haralick - AEM Mean glede na izhodisce (i)
    self.aemmean1 = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.aemmean1 += i * self.naem[i][j]
def mn2(self): # Haralick - AEM Mean glede na soseda (j)
    self.aemmean2 = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.aemmean2 += j * self.naem[i][j]
def vr1(self): # Haralick - variance glede na izhodisce (i)
    self.variance1 = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.variance1 += self.naem[i][j] * (i - self.aemmean1)**2
def vr2(self): # Haralick - variance glede na soseda (j)
    self.variance2 = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.variance2 += self.naem[i][j] * (i - self.aemmean2)**2
def cor(self): # Haralick - correlation
    self.correlation = 0.
    for i in range(self.strazredov): # vrstica
        for j in range(self.strazredov): # stolpec
            self.correlation += self.naem[i][j]*((i-self.aemmean1)*(j-
              self.aemmean2)/math.sqrt(self.variance1*self.variance2))
```

PRILOGA C: Korelacije ciljnih spremenljivk z modelnimi vrednostmi

Pearsonovi korelacijski koeficienti modelnih s pravimi vrednostmi so bili izračunani z 10-kratnim navzkrižnim preverjanjem (angl. cross-validation) na trenažnem vzorcu, s čimer se izognemo lažno visokim korelacijam, ki bi jih dobili pri navadnem preverjanju s trenažnim vzorcem. Navzkrižno preverjanje je po svojih rezultatih blizu preverjanju modelov na neodvisnem vzorcu.

Preglednica ima zaradi boljše preglednosti **s krepkim modrim tiskom pudarjene vrednosti korelacijskih koeficientov, ki so enake ali večje od 0,7**, **s krepkim rdečim tiskom pa tiste, ki so enake ali večje od 0,8**. Z odebeljenim robom so poudarjene največje korelacije znotraj posamezne ciljne spremenljivke.

gha		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.51	0.19	0.47	0.52	0.51	0.52	0.52	
	10	0.54	0.17	0.45	0.55	0.52	0.54	0.55	0.55
	20	0.50	0.16	0.43	0.53	0.50	0.53	0.53	
MTRF	5	0.54	0.20	0.49	0.57	0.55	0.57	0.57	
	10	0.56	0.18	0.49	0.58	0.55	0.57	0.58	0.58
	20	0.51	0.17	0.46	0.54	0.51	0.54	0.54	
STB	5	0.50	0.20	0.47	0.53	0.51	0.53	0.53	
	10	0.52	0.16	0.44	0.54	0.49	0.51	0.54	0.54
	20	0.48	0.18	0.42	0.52	0.48	0.52	0.52	
STRF	5	0.54	0.20	0.50	0.56	0.55	0.56	0.56	
	10	0.56	0.18	0.49	0.57	0.55	0.57	0.57	0.57
	20	0.51	0.18	0.46	0.53	0.51	0.52	0.53	
LM	5	0.47	0.15	-0.03	0.49	-0.02	0.02	0.49	
	10	0.48	0.15	0.48	0.52	0.45	0.49	0.52	0.52
	20	0.43	0.15	-0.02	0.47	-0.02	-0.02	0.47	
LMFS	5	0.54	0.16	0.48	0.57	0.53	0.56	0.57	
	10	0.55	0.15	0.50	0.60	0.55	0.59	0.60	0.60
	20	0.51	0.16	0.47	0.54	0.52	0.56	0.56	
Max (polmer 5)		0.54	0.20	0.50	0.57	0.55	0.57	0.57	
Max (polmer 10)		0.56	0.18	0.50	0.60	0.55	0.59	0.60	
Max (polmer 20)		0.51	0.18	0.47	0.54	0.52	0.56	0.56	
Max (vsi polmeri)		0.56	0.20	0.50	0.60	0.55	0.59		0.60

deligl		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.39	**0.72**	0.24	**0.73**	0.41	**0.73**	**0.73**	
	10	0.46	**0.74**	0.33	**0.76**	0.48	**0.76**	**0.76**	**0.76**
	20	0.54	**0.72**	0.37	**0.74**	0.56	**0.74**	**0.74**	
MTRF	5	0.40	**0.73**	0.26	0.68	0.41	0.67	**0.73**	
	10	0.48	**0.75**	0.33	**0.71**	0.49	**0.71**	**0.75**	**0.75**
	20	0.54	**0.73**	0.37	**0.71**	0.54	**0.71**	**0.73**	
STB	5	0.38	**0.71**	0.23	**0.73**	0.39	**0.73**	**0.73**	
	10	0.48	**0.74**	0.32	**0.77**	0.48	**0.76**	**0.77**	**0.77**
	20	0.54	**0.71**	0.38	**0.74**	0.54	**0.74**	**0.74**	
STRF	5	0.42	**0.72**	0.25	0.69	0.41	0.68	**0.72**	
	10	0.50	**0.75**	0.33	**0.74**	0.50	**0.73**	**0.75**	**0.75**
	20	0.54	**0.72**	0.36	**0.71**	0.54	**0.72**	**0.72**	
LM	5	0.28	0.66	-0.06	0.63	-0.04	-0.05	0.66	
	10	0.35	0.69	0.31	0.69	0.35	0.67	0.69	0.69
	20	0.43	0.67	0.04	0.69	-0.04	-0.04	0.69	
LMFS	5	0.40	0.66	0.31	0.69	0.43	0.68	0.69	
	10	0.47	0.69	0.34	**0.74**	0.48	**0.75**	**0.75**	**0.75**
	20	0.52	0.68	0.04	**0.73**	-0.04	-0.04	**0.73**	
Max (polmer 5)		0.42	**0.73**	0.31	**0.73**	0.43	**0.73**	**0.73**	
Max (polmer 10)		0.50	**0.75**	0.34	**0.77**	0.50	**0.76**	**0.77**	
Max (polmer 20)		0.54	**0.73**	0.38	**0.74**	0.56	**0.74**	**0.74**	
Max (vsi polmeri)		0.54	**0.75**	0.38	**0.77**	0.56	**0.76**		**0.77**

delbukev		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.58	0.67	0.27	**0.74**	0.58	**0.74**	**0.74**	
	10	0.65	0.69	0.37	**0.77**	0.65	**0.77**	**0.77**	**0.77**
	20	0.64	**0.71**	0.39	**0.77**	0.64	**0.77**	**0.77**	
MTRF	5	0.58	0.67	0.27	0.69	0.58	0.69	0.69	
	10	0.65	**0.70**	0.37	**0.74**	0.65	**0.73**	**0.74**	**0.74**
	20	0.65	**0.71**	0.38	**0.73**	0.65	**0.73**	**0.73**	
STB	5	0.57	0.66	0.26	**0.73**	0.56	**0.73**	**0.73**	
	10	0.65	0.68	0.39	**0.78**	0.65	**0.77**	**0.78**	**0.78**
	20	0.64	0.69	0.38	**0.76**	0.64	**0.76**	**0.76**	
STRF	5	0.58	0.66	0.27	0.69	0.58	0.68	0.69	
	10	0.66	0.69	0.38	**0.75**	0.66	**0.74**	**0.75**	**0.75**
	20	0.66	**0.71**	0.39	**0.73**	0.65	**0.73**	**0.73**	
LM	5	0.48	0.57	0.04	0.63	0.05	0.05	0.63	
	10	0.56	0.61	0.40	0.69	0.55	0.68	0.69	0.69
	20	0.58	0.62	0.03	0.69	-0.03	-0.03	0.69	
LMFS	5	0.57	0.57	-0.03	**0.70**	0.04	0.65	**0.70**	
	10	0.65	0.61	0.43	**0.75**	0.65	**0.75**	**0.75**	**0.75**
	20	0.65	0.62	0.43	**0.74**	-0.03	-0.03	**0.74**	
Max (polmer 5)		0.58	0.67	0.27	**0.74**	0.58	**0.74**	**0.74**	
Max (polmer 10)		0.66	**0.70**	0.43	**0.78**	0.66	**0.77**	**0.78**	
Max (polmer 20)		0.66	**0.71**	0.43	**0.77**	0.65	**0.77**	**0.77**	
Max (vsi polmeri)		0.66	**0.71**	0.43	**0.78**	0.66	**0.77**		**0.78**

deljavor		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.38	0.20	0.19	0.36	0.37	0.37	0.38	
	10	0.37	0.23	0.24	0.38	0.37	0.38	0.38	0.43
	20	0.41	0.24	0.23	0.43	0.41	0.43	0.43	
MTRF	5	0.36	0.21	0.16	0.38	0.37	0.39	0.39	
	10	0.38	0.23	0.21	0.40	0.37	0.40	0.40	0.41
	20	0.39	0.24	0.23	0.41	0.39	0.40	0.41	
STB	5	0.33	0.21	0.20	0.34	0.34	0.35	0.35	
	10	0.35	0.24	0.22	0.36	0.33	0.35	0.36	0.39
	20	0.39	0.21	0.21	0.38	0.37	0.37	0.39	
STRF	5	0.34	0.24	0.16	0.36	0.36	0.36	0.36	
	10	0.38	0.25	0.23	0.37	0.38	0.37	0.38	0.41
	20	0.40	0.23	0.22	0.41	0.38	0.39	0.41	
LM	5	0.24	0.23	0.07	0.28	0.07	0.08	0.28	
	10	0.29	0.25	0.21	0.31	0.28	0.29	0.31	0.37
	20	0.36	0.26	0.01	0.37	-0.01	0.02	0.37	
LMFS	5	0.37	0.24	0.26	0.42	0.40	0.41	0.42	
	10	0.42	0.26	0.30	0.44	0.43	0.46	0.46	0.48
	20	0.46	0.27	0.30	0.47	0.47	0.48	0.48	
Max (polmer 5)		0.38	0.24	0.26	0.42	0.40	0.41	0.42	
Max (polmer 10)		0.42	0.26	0.30	0.44	0.43	0.46	0.46	
Max (polmer 20)		0.46	0.27	0.30	0.47	0.47	0.48	0.48	
Max (vsi polmeri)		0.46	0.27	0.30	0.47	0.47	0.48		0.48

delbgaber	Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.38	0.14	0.19	0.52	0.39	0.52	0.52	0.57
	10	0.53	0.24	0.13	0.57	0.52	0.56	0.57	
	20	0.52	0.36	0.17	0.54	0.53	0.53	0.54	
MTRF	5	0.44	0.18	0.18	0.49	0.43	0.48	0.49	0.60
	10	0.55	0.24	0.13	0.58	0.54	0.55	0.58	
	20	0.57	0.36	0.21	0.59	0.58	0.60	0.60	
STB	5	0.31	0.15	0.14	0.33	0.31	0.32	0.33	0.46
	10	0.46	0.21	0.08	0.46	0.43	0.43	0.46	
	20	0.45	0.31	0.17	0.45	0.45	0.45	0.45	
STRF	5	0.41	0.17	0.15	0.42	0.41	0.43	0.43	0.56
	10	0.49	0.25	0.08	0.50	0.46	0.49	0.50	
	20	0.56	0.32	0.20	0.55	0.54	0.53	0.56	
LM	5	0.10	0.12	0.00	0.16	0.00	0.01	0.16	0.22
	10	0.13	0.13	0.08	0.21	0.17	0.21	0.21	
	20	0.16	0.11	-0.01	0.22	-0.01	-0.01	0.22	
LMFS	5	0.19	0.11	0.15	0.25	0.21	0.28	0.28	0.35
	10	0.26	0.13	0.14	0.34	0.29	0.33	0.34	
	20	0.30	0.10	-0.01	0.35	-0.01	-0.01	0.35	
Max (polmer 5)		0.44	0.18	0.19	0.52	0.43	0.52	0.52	
Max (polmer 10)		0.55	0.25	0.14	0.58	0.54	0.56	0.58	
Max (polmer 20)		0.57	0.36	0.21	0.59	0.58	0.60	0.60	
Max (vsi polmeri)		0.57	0.36	0.21	0.59	0.58	0.60		0.60

delcgaber	Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.18	0.14	0.20	0.28	0.18	0.27	0.28	0.52
	10	0.34	0.25	0.04	0.52	0.32	0.49	0.52	
	20	0.33	0.26	0.12	0.50	0.30	0.49	0.50	
MTRF	5	0.23	0.16	0.19	0.27	0.24	0.28	0.28	0.46
	10	0.29	0.31	0.04	0.42	0.30	0.46	0.46	
	20	0.34	0.24	0.13	0.40	0.30	0.40	0.40	
STB	5	0.14	0.10	0.11	0.15	0.14	0.15	0.15	0.37
	10	0.31	0.24	0.03	0.37	0.30	0.35	0.37	
	20	0.27	0.21	0.12	0.32	0.25	0.30	0.32	
STRF	5	0.20	0.18	0.14	0.25	0.20	0.22	0.25	0.41
	10	0.34	0.28	0.03	0.41	0.30	0.38	0.41	
	20	0.33	0.24	0.13	0.41	0.33	0.39	0.41	
LM	5	0.04	0.12	0.01	0.10	0.01	0.01	0.12	0.24
	10	0.14	0.15	0.12	0.24	0.15	0.22	0.24	
	20	0.11	0.15	0.01	0.20	0.01	0.01	0.20	
LMFS	5	0.20	0.12	0.15	0.23	0.18	0.24	0.24	0.35
	10	0.23	0.15	0.17	0.32	0.28	0.35	0.35	
	20	0.24	0.16	0.24	0.30	0.33	0.01	0.33	
Max (polmer 5)		0.23	0.18	0.20	0.28	0.24	0.28	0.28	
Max (polmer 10)		0.34	0.31	0.17	0.52	0.32	0.49	0.52	
Max (polmer 20)		0.34	0.26	0.24	0.50	0.33	0.49	0.50	
Max (vsi polmeri)		0.34	0.31	0.24	0.52	0.33	0.49		0.52

delhrast	Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.13	0.26	0.06	0.27	0.13	0.29	0.29	0.33
	10	0.17	0.24	0.15	0.33	0.16	0.32	0.33	
	20	0.24	0.27	0.17	0.33	0.24	0.32	0.33	
MTRF	5	0.13	0.29	0.07	0.25	0.16	0.26	0.29	0.33
	10	0.20	0.27	0.15	0.32	0.16	0.28	0.32	
	20	0.25	0.30	0.17	0.33	0.21	0.30	0.33	
STB	5	0.08	0.26	0.01	0.21	0.09	0.22	0.26	0.29
	10	0.13	0.22	0.11	0.27	0.13	0.26	0.27	
	20	0.20	0.26	0.17	0.29	0.20	0.28	0.29	
STRF	5	0.13	0.25	0.04	0.19	0.14	0.24	0.25	0.28
	10	0.17	0.23	0.10	0.26	0.14	0.26	0.26	
	20	0.23	0.28	0.21	0.28	0.22	0.26	0.28	
LM	5	0.04	0.18	0.01	0.14	0.01	0.01	0.18	0.20
	10	0.07	0.19	0.15	0.16	0.00	0.20	0.20	
	20	0.13	0.17	0.01	0.18	0.00	-0.01	0.18	
LMFS	5	0.21	0.18	0.09	0.27	0.19	0.27	0.27	0.35
	10	0.24	0.19	0.21	0.31	0.27	0.35	0.35	
	20	0.26	0.18	0.01	0.30	-0.01	0.35	0.35	
Max (polmer 5)		0.21	0.29	0.09	0.27	0.19	0.29	0.29	
Max (polmer 10)		0.24	0.27	0.21	0.33	0.27	0.35	0.35	
Max (polmer 20)		0.26	0.30	0.21	0.33	0.24	0.35	0.35	
Max (vsi polmeri)		0.26	0.30	0.21	0.33	0.27	0.35		0.35

delmjesen	Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.13	0.00	0.07	0.26	0.15	0.26	0.26	0.40
	10	0.26	0.12	0.10	0.40	0.21	0.34	0.40	
	20	0.30	0.18	0.16	0.36	0.32	0.36	0.36	
MTRF	5	0.16	0.00	0.10	0.24	0.19	0.23	0.24	0.43
	10	0.29	0.15	0.15	0.41	0.25	0.36	0.41	
	20	0.30	0.24	0.13	0.43	0.34	0.40	0.43	
STB	5	0.07	0.00	0.06	0.10	0.07	0.09	0.10	0.29
	10	0.17	0.06	0.07	0.21	0.13	0.18	0.21	
	20	0.24	0.09	0.09	0.29	0.25	0.28	0.29	
STRF	5	0.14	0.00	0.10	0.15	0.17	0.19	0.19	0.33
	10	0.27	0.07	0.09	0.32	0.23	0.26	0.32	
	20	0.26	0.12	0.12	0.33	0.30	0.32	0.33	
LM	5	0.12	0.06	0.00	0.13	0.00	0.00	0.13	0.20
	10	0.09	0.07	0.11	0.11	0.07	0.09	0.11	
	20	0.17	0.08	0.01	0.20	0.01	0.01	0.20	
LMFS	5	0.23	0.08	0.10	0.24	0.22	0.23	0.24	0.36
	10	0.23	0.10	0.16	0.28	0.26	0.28	0.28	
	20	0.30	0.10	0.20	0.33	0.33	0.36	0.36	
Max (polmer 5)		0.23	0.08	0.10	0.26	0.22	0.26	0.26	
Max (polmer 10)		0.29	0.15	0.16	0.41	0.26	0.36	0.41	
Max (polmer 20)		0.30	0.24	0.20	0.43	0.34	0.40	0.43	
Max (vsi polmeri)		0.30	0.24	0.20	0.43	0.34	0.40		0.43

delvjesen	Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.14	0.14	0.01	0.16	0.08	0.16	0.16	0.24
	10	0.21	0.23	0.16	0.24	0.18	0.22	0.24	
	20	0.16	0.19	0.02	0.19	0.14	0.19	0.19	
MTRF	5	0.14	0.16	0.03	0.19	0.12	0.16	0.19	0.23
	10	0.19	0.20	0.08	0.23	0.17	0.21	0.23	
	20	0.20	0.17	0.02	0.16	0.15	0.17	0.20	
STB	5	0.11	0.05	0.00	0.11	0.05	0.06	0.11	0.20
	10	0.16	0.20	0.07	0.16	0.17	0.16	0.20	
	20	0.12	0.18	0.07	0.12	0.13	0.12	0.18	
STRF	5	0.14	0.08	0.00	0.12	0.11	0.15	0.15	0.21
	10	0.21	0.19	0.09	0.20	0.18	0.18	0.21	
	20	0.18	0.14	0.04	0.16	0.17	0.15	0.18	
LM	5	0.09	0.03	-0.26	0.09	0.26	0.26	0.26	0.26
	10	0.16	0.00	0.23	0.17	0.15	0.15	0.23	
	20	0.09	0.01	0.00	0.09	0.00	0.00	0.09	
LMFS	5	0.18	0.04	-0.26	0.18	0.04	0.03	0.18	0.33
	10	0.32	0.00	0.29	0.30	0.30	0.33	0.33	
	20	0.32	0.03	0.00	0.33	0.30	0.21	0.33	
Max (polmer 5)		0.18	0.16	0.03	0.19	0.26	0.26	0.26	
Max (polmer 10)		0.32	0.23	0.29	0.30	0.30	0.33	0.33	
Max (polmer 20)		0.32	0.19	0.07	0.33	0.30	0.21	0.33	
Max (vsi polmeri)		0.32	0.23	0.29	0.33	0.30	0.33		0.33

delostalilst	Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.37	0.51	0.18	0.57	0.36	0.57	0.57	0.58
	10	0.48	0.49	0.24	0.58	0.49	0.56	0.58	
	20	0.48	0.45	0.34	0.56	0.45	0.56	0.56	
MTRF	5	0.38	0.53	0.17	0.54	0.36	0.54	0.54	0.57
	10	0.47	0.54	0.29	0.56	0.47	0.57	0.57	
	20	0.46	0.47	0.33	0.54	0.47	0.51	0.54	
STB	5	0.36	0.52	0.11	0.53	0.35	0.52	0.53	0.57
	10	0.45	0.53	0.23	0.56	0.46	0.56	0.56	
	20	0.48	0.47	0.36	0.56	0.49	0.57	0.57	
STRF	5	0.39	0.53	0.13	0.52	0.38	0.51	0.53	0.56
	10	0.47	0.55	0.27	0.56	0.47	0.55	0.56	
	20	0.48	0.49	0.34	0.54	0.47	0.53	0.54	
LM	5	0.28	0.34	0.01	0.35	0.01	0.02	0.35	0.44
	10	0.36	0.36	0.32	0.43	0.34	0.40	0.43	
	20	0.39	0.36	0.01	0.44	0.01	0.01	0.44	
LMFS	5	0.36	0.34	0.29	0.45	0.38	0.44	0.45	0.53
	10	0.45	0.36	0.36	0.50	0.46	0.50	0.50	
	20	0.48	0.36	0.02	0.53	-0.01	0.03	0.53	
Max (polmer 5)		0.39	0.53	0.29	0.57	0.38	0.57	0.57	
Max (polmer 10)		0.48	0.55	0.36	0.58	0.49	0.57	0.58	
Max (polmer 20)		0.48	0.49	0.36	0.56	0.49	0.57	0.57	
Max (vsi polmeri)		0.48	0.55	0.36	0.58	0.49	0.57		0.58

delsmreka		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.46	0.40	0.32	0.61	0.45	0.61	0.61	
	10	0.51	0.48	0.36	0.67	0.51	0.67	0.67	0.69
	20	0.53	0.50	0.38	0.68	0.54	0.69	0.69	
MTRF	5	0.48	0.41	0.31	0.58	0.47	0.58	0.58	
	10	0.51	0.49	0.36	0.63	0.52	0.64	0.64	0.65
	20	0.54	0.50	0.37	0.65	0.55	0.65	0.65	
STB	5	0.45	0.42	0.32	0.59	0.45	0.59	0.59	
	10	0.47	0.48	0.36	0.64	0.50	0.64	0.64	0.67
	20	0.52	0.51	0.39	0.66	0.54	0.67	0.67	
STRF	5	0.45	0.42	0.31	0.55	0.46	0.54	0.55	
	10	0.49	0.49	0.35	0.58	0.51	0.59	0.59	0.61
	20	0.53	0.50	0.37	0.61	0.53	0.60	0.61	
LM	5	0.31	0.29	-0.03	0.42	-0.03	-0.03	0.42	
	10	0.34	0.31	0.34	0.43	0.39	0.46	0.46	0.48
	20	0.41	0.31	0.03	0.48	0.03	0.03	0.48	
LMFS	5	0.41	0.29	0.39	0.51	0.45	-0.03	0.51	
	10	0.44	0.31	0.38	0.53	0.53	0.59	0.59	0.59
	20	0.50	0.31	0.03	0.55	0.03	0.03	0.55	
Max (polmer 5)		0.48	0.42	0.39	0.61	0.47	0.61	0.61	
Max (polmer 10)		0.51	0.49	0.38	0.67	0.53	0.67	0.67	
Max (polmer 20)		0.54	0.51	0.39	0.68	0.55	0.69	0.69	
Max (vsi polmeri)		0.54	0.51	0.39	0.68	0.55	0.69		0.69

delbor		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.51	0.50	0.30	0.69	0.51	0.69	0.69	
	10	0.64	0.54	0.48	**0.75**	0.64	**0.75**	**0.75**	**0.76**
	20	0.65	0.58	0.50	**0.76**	0.66	**0.76**	**0.76**	
MTRF	5	0.53	0.51	0.32	0.65	0.53	0.66	0.66	
	10	0.64	0.55	0.46	**0.72**	0.64	**0.72**	**0.72**	**0.74**
	20	0.66	0.58	0.48	**0.74**	0.67	**0.74**	**0.74**	
STB	5	0.50	0.49	0.31	0.69	0.50	0.69	0.69	
	10	0.63	0.56	0.44	**0.75**	0.63	**0.76**	**0.76**	**0.78**
	20	0.65	0.55	0.48	**0.78**	0.65	**0.76**	**0.78**	
STRF	5	0.52	0.51	0.32	0.66	0.52	0.65	0.66	
	10	0.63	0.57	0.45	**0.72**	0.63	**0.71**	**0.72**	**0.73**
	20	0.66	0.56	0.48	**0.73**	0.67	**0.73**	**0.73**	
LM	5	0.38	0.47	0.02	0.53	0.02	0.02	0.53	
	10	0.45	0.49	0.41	0.58	0.50	0.62	0.62	0.62
	20	0.53	0.49	0.10	0.62	0.10	0.10	0.62	
LMFS	5	0.46	0.47	0.33	0.58	0.49	0.63	0.63	
	10	0.52	0.49	0.45	0.63	0.59	0.69	0.69	0.69
	20	0.58	0.49	-0.10	0.66	-0.10	0.10	0.66	
Max (polmer 5)		0.53	0.51	0.33	0.69	0.53	0.69	0.69	
Max (polmer 10)		0.64	0.57	0.48	**0.75**	0.64	**0.76**	**0.76**	
Max (polmer 20)		0.66	0.58	0.50	**0.78**	0.67	**0.76**	**0.78**	
Max (vsi polmeri)		0.66	0.58	0.50	**0.78**	0.67	**0.76**		**0.78**

delostaliigl		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.00	0.00	0.00	0.00	0.00	0.00	0.00	
	10	-0.01	0.00	0.00	0.00	-0.01	0.00	0.00	0.00
	20	0.00	0.00	0.00	0.00	0.00	0.00	0.00	
MTRF	5	0.00	-0.01	-0.01	-0.01	-0.01	-0.01	0.00	
	10	-0.01	0.00	0.00	-0.01	-0.01	-0.01	0.00	0.00
	20	0.00	-0.01	-0.01	0.00	-0.01	-0.01	0.00	
STB	5	0.00	0.00	0.00	0.00	0.00	0.00	0.00	
	10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	20	0.00	0.00	0.00	0.00	0.00	0.00	0.00	
STRF	5	-0.01	0.00	-0.01	-0.01	-0.01	-0.01	0.00	
	10	-0.01	0.00	0.00	-0.01	-0.01	-0.01	0.00	0.00
	20	0.00	0.00	-0.01	0.00	0.00	-0.01	0.00	
LM	5	0.00	-0.01	0.00	0.00	0.00	0.00	0.00	
	10	0.00	-0.01	0.00	0.00	0.00	0.00	0.00	0.00
	20	0.00	-0.01	0.00	0.00	0.00	0.00	0.00	
LMFS	5	0.00	-0.02	0.00	0.00	0.00	0.00	0.00	
	10	-0.01	-0.02	0.00	-0.01	0.00	0.00	0.00	0.00
	20	0.00	-0.02	0.00	0.00	0.00	0.00	0.00	
Max (polmer 5)		0.00	0.00	0.00	0.00	0.00	0.00	0.00	
Max (polmer 10)		0.00	0.00	0.00	0.00	0.00	0.00	0.00	
Max (polmer 20)		0.00	0.00	0.00	0.00	0.00	0.00	0.00	
Max (vsi polmeri)		0.00	0.00	0.00	0.00	0.00	0.00		0.00

deljelka		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	0.58	0.49	0.46	0.69	0.58	0.69	0.69	
	10	0.67	0.56	0.59	**0.76**	0.67	**0.76**	**0.76**	**0.78**
	20	**0.70**	0.60	0.59	**0.78**	**0.70**	**0.78**	**0.78**	
MTRF	5	0.58	0.50	0.47	0.67	0.59	0.66	0.67	
	10	0.67	0.56	0.60	**0.74**	0.67	**0.74**	**0.74**	**0.76**
	20	**0.70**	0.60	0.59	**0.76**	**0.70**	**0.76**	**0.76**	
STB	5	0.57	0.47	0.47	0.67	0.57	0.67	0.67	
	10	0.66	0.55	0.59	**0.75**	0.66	**0.75**	**0.75**	**0.77**
	20	0.69	0.59	0.59	**0.77**	0.69	**0.77**	**0.77**	
STRF	5	0.58	0.48	0.48	0.65	0.59	0.64	0.65	
	10	0.66	0.56	0.60	**0.72**	0.67	**0.72**	**0.72**	**0.75**
	20	**0.70**	0.59	0.59	**0.75**	**0.70**	**0.75**	**0.75**	
LM	5	0.50	0.39	0.03	0.54	-0.02	0.04	0.54	
	10	0.61	0.42	0.58	0.63	0.58	0.59	0.63	0.66
	20	0.64	0.41	-0.02	0.66	-0.02	0.02	0.66	
LMFS	5	0.61	0.39	0.01	0.64	-0.06	0.08	0.64	
	10	0.69	0.42	0.62	**0.70**	0.68	**0.71**	**0.71**	**0.72**
	20	**0.71**	0.41	-0.01	**0.72**	**0.71**	0.03	**0.72**	
Max (polmer 5)		0.61	0.50	0.48	0.69	0.59	0.69	0.69	
Max (polmer 10)		0.69	0.56	0.62	**0.76**	0.68	**0.76**	**0.76**	
Max (polmer 20)		**0.71**	0.60	0.59	**0.78**	**0.71**	**0.78**	**0.78**	
Max (vsi polmeri)		**0.71**	0.60	0.62	**0.78**	**0.71**	**0.78**		**0.78**

delmacesen		Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	
MTB	5	-0.01	-0.01	0.00	-0.01	0.00	0.00	0.00	
	10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	20	0.00	0.00	0.00	0.00	0.00	0.00	0.00	
MTRF	5	-0.01	-0.01	-0.01	-0.01	-0.01	-0.01	-0.01	
	10	-0.01	-0.01	-0.01	-0.01	-0.01	-0.01	-0.01	###
	20	-0.01	-0.01	-0.01	-0.01	-0.01	-0.01	-0.01	
STB	5	0.00	0.00	0.00	0.00	-0.01	-0.01	0.00	
	10	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
	20	0.00	0.00	0.00	0.00	0.00	0.00	0.00	
STRF	5	-0.01	0.00	-0.01	-0.01	-0.01	-0.01	0.00	
	10	-0.01	0.00	-0.01	-0.01	-0.01	-0.01	0.00	0.00
	20	-0.01	0.00	-0.01	-0.01	-0.01	-0.01	0.00	
LM	5	0.00	-0.02	0.00	0.00	0.00	0.00	0.00	
	10	0.00	-0.02	0.00	0.00	0.00	0.00	0.00	0.00
	20	0.00	-0.02	0.00	0.00	0.00	0.00	0.00	
LMFS	5	0.00	0.00	0.00	0.00	0.00	0.00	0.00	
	10	0.00	-0.02	0.00	0.00	0.00	0.00	0.00	0.00
	20	0.00	0.00	0.00	0.00	0.00	0.00	0.00	
Max (polmer 5)		0.00	0.00	0.00	0.00	0.00	0.00	0.00	
Max (polmer 10)		0.00	0.00	0.00	0.00	0.00	0.00	0.00	
Max (polmer 20)		0.00	0.00	0.00	0.00	0.00	0.00	0.00	
Max (vsi polmeri)		0.00	0.00	0.00	0.00	0.00	0.00		0.00

		45°							60°							120°							170°						
openness		Skupina pojasnjevalnih spremenljivk							Skupina pojasnjevalnih spremenljivk							Skupina pojasnjevalnih spremenljivk							Skupina pojasnjevalnih spremenljivk						
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	P	N	T	PN	PT	PNT	Max	P	N	T	PN	PT	PNT	Max	P	N	T	PN	PT	PNT	Max
MTB	5	0.70	0.19	0.68	0.71	0.70	0.71	0.71	0.76	0.22	0.74	0.77	0.76	0.77	0.77	0.77	0.28	0.75	0.79	0.78	0.79	0.79	0.72	0.25	0.69	0.73	0.73	0.74	0.74
	10	0.59	0.21	0.57	0.60	0.58	0.60	0.60	0.66	0.23	0.63	0.66	0.66	0.66	0.66	0.80	0.34	0.72	0.81	0.80	0.80	0.81	0.82	0.37	0.67	0.82	0.82	0.82	0.82
	20	0.42	0.23	0.37	0.43	0.42	0.43	0.43	0.50	0.26	0.43	0.50	0.49	0.49	0.50	0.66	0.36	0.59	0.66	0.66	0.66	0.66	0.68	0.34	0.61	0.68	0.66	0.67	0.68
MTRF	5	0.71	0.21	0.68	0.72	0.71	0.72	0.72	0.77	0.23	0.75	0.77	0.76	0.77	0.77	0.79	0.29	0.74	0.81	0.80	0.81	0.81	0.76	0.28	0.68	0.77	0.77	0.76	0.77
	10	0.59	0.21	0.57	0.60	0.60	0.60	0.60	0.67	0.24	0.64	0.67	0.67	0.67	0.67	0.81	0.36	0.74	0.82	0.82	0.82	0.82	0.83	0.39	0.69	0.83	0.82	0.82	0.83
	20	0.42	0.23	0.39	0.42	0.42	0.43	0.43	0.49	0.26	0.44	0.50	0.48	0.49	0.50	0.69	0.36	0.60	0.69	0.67	0.67	0.69	0.73	0.34	0.62	0.74	0.70	0.71	0.74
STB	5	0.70	0.18	0.68	0.71	0.70	0.71	0.71	0.75	0.22	0.74	0.76	0.75	0.76	0.76	0.77	0.28	0.75	0.79	0.78	0.79	0.79	0.71	0.23	0.69	0.72	0.72	0.73	0.73
	10	0.57	0.21	0.55	0.59	0.58	0.59	0.59	0.65	0.23	0.62	0.66	0.66	0.66	0.66	0.81	0.34	0.72	0.81	0.81	0.81	0.81	0.82	0.38	0.69	0.82	0.82	0.82	0.82
	20	0.43	0.23	0.37	0.43	0.42	0.43	0.43	0.49	0.25	0.42	0.49	0.48	0.48	0.49	0.66	0.36	0.59	0.66	0.65	0.65	0.66	0.67	0.33	0.61	0.67	0.66	0.66	0.67
STRF	5	0.71	0.21	0.68	0.72	0.71	0.72	0.72	0.76	0.23	0.74	0.77	0.76	0.77	0.77	0.80	0.29	0.75	0.80	0.80	0.80	0.80	0.76	0.26	0.69	0.76	0.77	0.77	0.77
	10	0.59	0.21	0.57	0.59	0.59	0.60	0.60	0.66	0.24	0.64	0.66	0.66	0.67	0.67	0.81	0.35	0.74	0.81	0.82	0.81	0.82	0.83	0.37	0.68	0.83	0.81	0.81	0.83
	20	0.42	0.23	0.38	0.43	0.41	0.42	0.43	0.48	0.25	0.42	0.49	0.48	0.49	0.49	0.69	0.35	0.59	0.69	0.67	0.67	0.69	0.72	0.33	0.62	0.73	0.71	0.71	0.73
LM	5	0.69	0.28	-0.02	0.69	-0.01	-0.02	0.69	0.74	0.30	-0.02	0.75	0.00	-0.01	0.75	0.74	0.30	0.03	0.76	0.02	-0.01	0.76	0.66	0.24	0.00	0.67	0.00	0.00	0.67
	10	0.54	0.24	0.56	0.54	0.50	0.50	0.56	0.62	0.26	0.63	0.62	0.59	0.59	0.63	0.77	0.29	0.72	0.77	0.74	0.74	0.77	0.75	0.25	0.69	0.75	0.73	0.73	0.75
	20	0.38	0.21	-0.01	0.38	-0.01	-0.01	0.38	0.44	0.23	-0.02	0.43	-0.02	-0.02	0.44	0.62	0.27	-0.02	0.62	-0.02	-0.02	0.62	0.63	0.24	0.03	0.63	0.02	0.02	0.63
LMFS	5	0.73	0.28	0.70	0.74	0.73	-0.01	0.74	0.78	0.30	0.75	0.79	0.78	0.79	0.79	0.78	0.30	0.74	0.79	0.79	0.80	0.80	0.71	0.25	0.67	0.72	0.72	0.73	0.73
	10	0.62	0.25	0.59	0.63	0.63	0.63	0.63	0.68	0.27	0.65	0.69	0.69	0.69	0.69	0.80	0.29	0.73	0.80	0.80	0.80	0.80	0.78	0.25	0.70	0.78	0.78	0.79	0.79
	20	0.49	0.23	-0.01	0.48	-0.01	-0.01	0.49	0.55	0.24	-0.02	0.54	-0.02	-0.02	0.55	0.68	0.27	-0.02	0.68	-0.02	-0.02	0.68	0.69	0.24	-0.02	0.69	-0.02	-0.02	0.69
Max (polmer 5)		0.73	0.28	0.70	0.74	0.73	0.72	0.74	0.78	0.30	0.75	0.79	0.78	0.79	0.79	0.80	0.30	0.75	0.81	0.80	0.81	0.81	0.76	0.28	0.69	0.77	0.77	0.77	0.77
Max (polmer 10)		0.62	0.25	0.59	0.63	0.63	0.63	0.63	0.68	0.27	0.65	0.69	0.69	0.69	0.69	0.81	0.36	0.74	0.82	0.82	0.81	0.82	0.83	0.39	0.70	0.83	0.82	0.82	0.83
Max (polmer 20)		0.49	0.23	0.39	0.48	0.42	0.43	0.49	0.55	0.26	0.44	0.54	0.49	0.49	0.55	0.69	0.36	0.60	0.69	0.67	0.67	0.69	0.73	0.34	0.62	0.74	0.71	0.71	0.74
Max (vsi polmeri)		0.73	0.28	0.70	0.74	0.73	0.72	0.74	0.78	0.30	0.75	0.79	0.78	0.79	0.79	0.81	0.36	0.75	0.82	0.82	0.81	0.82	0.83	0.39	0.70	0.83	0.82	0.82	0.83

lai2000lin		45°								60°								120°								170°							
		Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max	
MTB	5	0.61	0.22	0.58	0.63	0.61	0.63	0.63	0.63	0.65	0.24	0.62	0.68	0.65	0.68	0.68	0.68	0.72	0.31	0.68	0.74	0.72	0.74	0.74	0.74	0.55	0.23	0.43	0.55	0.55	0.56	0.56	0.63
	10	0.52	0.23	0.46	0.54	0.51	0.54	0.54		0.57	0.25	0.51	0.58	0.57	0.58	0.58		0.74	0.35	0.68	0.74	0.73	0.74	0.74		0.63	0.33	0.50	0.63	0.62	0.63	0.63	
	20	0.34	0.26	0.30	0.36	0.34	0.37	0.37		0.40	0.27	0.33	0.42	0.40	0.41	0.42		0.63	0.39	0.56	0.64	0.63	0.64	0.64		0.59	0.35	0.49	0.59	0.58	0.58	0.59	
MTRF	5	0.62	0.24	0.58	0.63	0.62	0.63	0.63	0.63	0.66	0.25	0.63	0.67	0.66	0.67	0.67	0.67	0.73	0.33	0.67	0.75	0.73	0.74	0.75	0.75	0.58	0.25	0.43	0.58	0.57	0.58	0.58	0.64
	10	0.51	0.23	0.46	0.54	0.52	0.52	0.54	0.63	0.57	0.25	0.52	0.58	0.57	0.58	0.58	0.67	0.75	0.36	0.69	0.75	0.75	0.75	0.75	0.75	0.64	0.33	0.51	0.64	0.63	0.63	0.64	
	20	0.34	0.25	0.30	0.35	0.34	0.36	0.36		0.39	0.28	0.34	0.40	0.39	0.40	0.40		0.63	0.39	0.57	0.64	0.63	0.64	0.64		0.61	0.34	0.51	0.61	0.60	0.60	0.61	
STB	5	0.60	0.22	0.58	0.63	0.60	0.63	0.63	0.63	0.65	0.24	0.62	0.68	0.65	0.68	0.68	0.68	0.72	0.31	0.67	0.73	0.72	0.74	0.74	0.74	0.59	0.20	0.44	0.60	0.59	0.60	0.60	0.64
	10	0.51	0.21	0.44	0.54	0.51	0.53	0.54		0.57	0.24	0.50	0.58	0.56	0.58	0.58		0.74	0.35	0.68	0.74	0.74	0.75	0.75	0.75	0.64	0.33	0.51	0.64	0.63	0.63	0.64	
	20	0.35	0.24	0.30	0.37	0.33	0.36	0.37		0.39	0.26	0.33	0.41	0.39	0.40	0.41		0.63	0.39	0.57	0.64	0.63	0.63	0.64		0.59	0.34	0.49	0.60	0.58	0.59	0.60	
STRF	5	0.61	0.23	0.58	0.63	0.61	0.62	0.63	0.63	0.66	0.26	0.64	0.67	0.66	0.67	0.67	0.67	0.74	0.32	0.67	0.75	0.73	0.75	0.75	0.75	0.60	0.23	0.43	0.61	0.59	0.60	0.61	0.65
	10	0.53	0.23	0.45	0.54	0.52	0.54	0.54		0.58	0.25	0.52	0.58	0.57	0.58	0.58		0.75	0.37	0.69	0.75	0.75	0.75	0.75	0.75	0.64	0.33	0.51	0.65	0.64	0.64	0.65	
	20	0.33	0.24	0.30	0.36	0.34	0.34	0.36		0.39	0.28	0.34	0.41	0.39	0.40	0.41		0.64	0.39	0.57	0.64	0.63	0.63	0.64		0.61	0.32	0.51	0.61	0.60	0.60	0.61	
LM	5	0.57	0.31	-0.02	0.58	-0.01	-0.02	0.58	0.58	0.61	0.33	-0.02	0.63	-0.02	-0.02	0.63	0.63	0.69	0.33	0.04	0.71	0.04	0.01	0.71	0.71	0.47	0.16	0.02	0.47	0.02	0.01	0.47	0.56
	10	0.43	0.27	0.47	0.44	0.40	0.41	0.47		0.49	0.29	0.52	0.50	0.46	0.47	0.52		0.70	0.32	0.67	0.71	0.68	0.69	0.71		0.56	0.18	0.49	0.55	0.55	0.55	0.56	
	20	0.29	0.25	-0.02	0.30	-0.02	-0.02	0.30		0.33	0.26	-0.03	0.34	-0.03	-0.03	0.34		0.59	0.30	0.03	0.60	0.04	0.04	0.60		0.53	0.17	0.04	0.53	0.04	0.04	0.53	
LMFS	5	0.64	0.32	0.61	0.66	0.65	0.67	0.67	0.67	0.68	0.34	0.66	0.69	0.68	0.69	0.69	0.69	0.74	0.33	0.68	0.76	0.74	0.75	0.76	0.76	0.55	0.16	0.46	0.55	-0.03	-0.02	0.55	0.65
	10	0.54	0.29	0.50	0.54	0.53	0.55	0.55		0.58	0.30	0.55	0.59	0.59	0.60	0.60		0.75	0.32	0.69	0.76	0.76	0.76	0.76	0.76	0.62	0.18	0.53	0.62	0.65	0.65	0.65	
	20	0.43	0.26	-0.02	0.43	-0.02	-0.02	0.43		0.46	0.27	-0.03	0.47	-0.03	-0.03	0.47		0.66	0.30	-0.03	0.66	-0.03	-0.03	0.66		0.60	0.18	0.04	0.60	0.61	0.60	0.61	
Max (polmer 5)		0.64	0.32	0.61	0.66	0.65	0.67	0.67		0.68	0.34	0.66	0.69	0.68	0.69	0.69		0.74	0.33	0.68	0.76	0.74	0.75	0.76		0.60	0.25	0.46	0.61	0.59	0.60	0.61	
Max (polmer 10)		0.54	0.29	0.50	0.54	0.53	0.55	0.55		0.58	0.30	0.55	0.59	0.59	0.60	0.60		0.75	0.37	0.69	0.76	0.76	0.76	0.76		0.64	0.33	0.53	0.65	0.65	0.65	0.65	
Max (polmer 20)		0.43	0.26	0.30	0.43	0.34	0.37	0.43		0.46	0.28	0.34	0.47	0.40	0.41	0.47		0.66	0.39	0.57	0.66	0.63	0.64	0.66		0.61	0.35	0.51	0.61	0.61	0.60	0.61	
Max (vsi polmeri)		0.64	0.32	0.61	0.66	0.65	0.67		0.67	0.68	0.34	0.66	0.69	0.68	0.69		0.69	0.75	0.39	0.69	0.76	0.76	0.76		0.76	0.64	0.35	0.53	0.65	0.65	0.65		0.65

lai2000glin		45°								60°								120°								170°							
		Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max	
MTB	5	0.37	0.09	0.33	0.40	0.37	0.40	0.40		0.44	0.13	0.39	0.48	0.44	0.48	0.48		0.57	0.21	0.55	0.60	0.56	0.59	0.60		0.59	0.23	0.57	0.61	0.59	0.61	0.61	
	10	0.35	0.18	0.26	0.37	0.34	0.36	0.37	0.40	0.39	0.18	0.31	0.41	0.40	0.41	0.41	0.48	0.54	0.24	0.47	0.55	0.54	0.55	0.55	0.60	0.56	0.26	0.50	0.58	0.56	0.58	0.58	0.61
	20	0.22	0.18	0.16	0.23	0.21	0.23	0.23		0.27	0.21	0.20	0.29	0.27	0.28	0.29		0.41	0.31	0.36	0.43	0.41	0.43	0.43		0.46	0.33	0.39	0.47	0.45	0.46	0.47	
MTRF	5	0.39	0.12	0.33	0.41	0.38	0.39	0.41		0.45	0.13	0.41	0.47	0.44	0.46	0.47		0.57	0.23	0.54	0.59	0.58	0.59	0.59		0.60	0.24	0.55	0.61	0.59	0.61	0.61	
	10	0.33	0.18	0.26	0.37	0.34	0.34	0.37	0.41	0.40	0.18	0.32	0.41	0.41	0.41	0.41	0.47	0.54	0.24	0.48	0.55	0.55	0.55	0.55	0.59	0.56	0.27	0.51	0.58	0.57	0.58	0.58	0.61
	20	0.21	0.17	0.16	0.21	0.20	0.23	0.23		0.26	0.21	0.20	0.27	0.26	0.27	0.27		0.41	0.31	0.34	0.43	0.41	0.42	0.43		0.44	0.32	0.38	0.45	0.44	0.45	0.45	
STB	5	0.36	0.09	0.33	0.39	0.36	0.39	0.39		0.44	0.11	0.40	0.46	0.43	0.46	0.46		0.57	0.21	0.53	0.59	0.56	0.59	0.59		0.58	0.23	0.55	0.60	0.58	0.61	0.61	
	10	0.33	0.17	0.23	0.35	0.33	0.36	0.36	0.39	0.39	0.17	0.29	0.40	0.39	0.40	0.40	0.46	0.53	0.24	0.46	0.54	0.53	0.55	0.55	0.59	0.56	0.27	0.48	0.57	0.56	0.57	0.57	0.61
	20	0.21	0.18	0.14	0.23	0.20	0.23	0.23		0.26	0.19	0.19	0.28	0.24	0.27	0.28		0.40	0.29	0.33	0.42	0.39	0.40	0.42		0.43	0.31	0.37	0.45	0.42	0.44	0.45	
STRF	5	0.40	0.09	0.32	0.41	0.39	0.41	0.41		0.46	0.13	0.40	0.47	0.45	0.47	0.47		0.59	0.22	0.53	0.60	0.58	0.60	0.60		0.60	0.22	0.55	0.61	0.60	0.62	0.62	
	10	0.34	0.18	0.25	0.35	0.34	0.35	0.35	0.41	0.38	0.18	0.32	0.40	0.39	0.40	0.40	0.47	0.54	0.25	0.48	0.55	0.54	0.55	0.55	0.60	0.57	0.26	0.50	0.57	0.57	0.58	0.58	0.62
	20	0.21	0.18	0.15	0.21	0.21	0.22	0.22		0.25	0.20	0.19	0.28	0.23	0.26	0.28		0.40	0.30	0.34	0.41	0.40	0.41	0.41		0.43	0.32	0.37	0.43	0.42	0.44	0.44	
LM	5	0.31	0.20	-0.01	0.33	-0.01	-0.01	0.33		0.37	0.22	-0.01	0.39	-0.01	-0.01	0.39		0.50	0.29	-0.02	0.53	-0.02	-0.02	0.53		0.53	0.29	-0.01	0.56	-0.01	-0.01	0.56	
	10	0.22	0.19	0.23	0.23	0.16	0.17	0.23	0.33	0.28	0.22	0.30	0.29	0.23	0.24	0.30	0.39	0.45	0.28	0.45	0.46	0.40	0.41	0.46	0.53	0.49	0.29	0.48	0.50	0.44	0.45	0.50	0.56
	20	0.14	0.19	-0.02	0.15	-0.02	-0.02	0.19		0.18	0.21	-0.03	0.19	-0.03	-0.03	0.21		0.33	0.27	-0.03	0.34	-0.03	-0.03	0.34		0.37	0.28	-0.03	0.38	-0.03	-0.03	0.38	
LMFS	5	0.44	0.21	0.39	0.45	0.45	0.45	0.45		0.49	0.23	0.44	0.51	0.51	0.51	0.51		0.60	0.30	0.56	0.63	0.63	0.63	0.63		0.62	0.30	0.57	0.64	0.00	0.02	0.64	
	10	0.36	0.21	0.31	0.38	0.37	0.38	0.38	0.45	0.41	0.23	0.37	0.42	0.41	0.43	0.43	0.51	0.54	0.29	0.50	0.56	0.55	0.56	0.56	0.63	0.58	0.29	0.51	0.59	0.58	0.59	0.59	0.64
	20	0.29	0.20	0.24	0.30	-0.02	0.34	0.34		0.33	0.22	0.25	0.36	-0.02	0.38	0.38		0.46	0.28	0.36	0.47	0.43	0.47	0.47		0.48	0.28	0.42	0.50	0.49	0.49	0.50	
Max (polmer 5)		0.44	0.21	0.39	0.45	0.45	0.45	0.45		0.49	0.23	0.44	0.51	0.51	0.51	0.51		0.60	0.30	0.56	0.63	0.58	0.63	0.63		0.62	0.30	0.57	0.64	0.60	0.62	0.64	
Max (polmer 10)		0.36	0.21	0.31	0.38	0.37	0.38	0.38		0.41	0.23	0.37	0.42	0.41	0.43	0.43		0.54	0.29	0.50	0.56	0.55	0.56	0.56		0.58	0.29	0.51	0.59	0.58	0.59	0.59	
Max (polmer 20)		0.29	0.20	0.24	0.30	0.21	0.34	0.34		0.33	0.22	0.25	0.36	0.27	0.38	0.38		0.46	0.31	0.36	0.47	0.43	0.47	0.47		0.48	0.33	0.42	0.50	0.49	0.49	0.50	
Max (vsi polmeri)		0.44	0.21	0.39	0.45	0.45	0.45		0.45	0.49	0.23	0.44	0.51	0.51	0.51		0.51	0.60	0.31	0.56	0.63	0.58	0.63		0.63	0.62	0.33	0.57	0.64	0.60	0.62		0.64

		45°								60°								120°								170°							
directsitefactor		Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max	
MTB	5	0.41	0.05	0.42	0.44	0.41	0.44	0.44	0.44	0.54	0.11	0.54	0.56	0.55	0.55	0.56	0.56	0.57	0.17	0.54	0.58	0.56	0.58	0.58	0.58	0.56	0.17	0.54	0.58	0.56	0.58	0.58	0.58
	10	0.33	0.04	0.36	0.36	0.33	0.35	0.36		0.46	0.08	0.43	0.47	0.46	0.47	0.47		0.56	0.17	0.48	0.57	0.55	0.56	0.57		0.57	0.18	0.49	0.58	0.57	0.58	0.58	
	20	0.23	0.13	0.20	0.24	0.23	0.24	0.24		0.32	0.13	0.27	0.33	0.31	0.32	0.33		0.42	0.19	0.40	0.43	0.42	0.43	0.43		0.44	0.19	0.42	0.45	0.43	0.44	0.45	
MTRF	5	0.43	0.06	0.43	0.45	0.43	0.44	0.45	0.45	0.56	0.12	0.54	0.57	0.55	0.56	0.57	0.57	0.58	0.17	0.54	0.59	0.58	0.59	0.59	0.60	0.59	0.16	0.54	0.60	0.58	0.59	0.60	0.60
	10	0.35	0.03	0.35	0.36	0.35	0.36	0.36		0.48	0.09	0.44	0.49	0.46	0.48	0.49		0.57	0.16	0.49	0.58	0.57	0.57	0.58		0.58	0.19	0.50	0.59	0.57	0.57	0.59	
	20	0.23	0.15	0.23	0.25	0.22	0.25	0.25		0.32	0.14	0.30	0.34	0.33	0.33	0.34		0.44	0.19	0.41	0.46	0.43	0.44	0.46		0.46	0.19	0.44	0.48	0.46	0.47	0.48	
STB	5	0.40	0.03	0.40	0.41	0.41	0.42	0.42	0.42	0.54	0.12	0.53	0.55	0.53	0.54	0.55	0.55	0.56	0.17	0.52	0.58	0.55	0.57	0.58	0.58	0.56	0.16	0.52	0.58	0.56	0.57	0.58	0.58
	10	0.31	0.05	0.34	0.33	0.33	0.34	0.34		0.44	0.09	0.42	0.46	0.44	0.46	0.46		0.55	0.19	0.48	0.56	0.54	0.56	0.56		0.57	0.20	0.48	0.57	0.56	0.57	0.57	
	20	0.22	0.15	0.20	0.24	0.21	0.22	0.24		0.31	0.13	0.28	0.34	0.31	0.34	0.34		0.43	0.18	0.40	0.44	0.42	0.44	0.44		0.44	0.17	0.42	0.46	0.43	0.45	0.46	
STRF	5	0.42	0.06	0.42	0.43	0.42	0.43	0.43	0.43	0.55	0.14	0.53	0.56	0.54	0.55	0.56	0.56	0.58	0.16	0.53	0.59	0.57	0.58	0.59	0.59	0.59	0.16	0.53	0.59	0.58	0.58	0.59	0.59
	10	0.33	0.03	0.34	0.33	0.35	0.34	0.35		0.46	0.10	0.42	0.47	0.46	0.47	0.47		0.57	0.21	0.49	0.58	0.56	0.57	0.58		0.58	0.21	0.50	0.59	0.57	0.57	0.59	
	20	0.22	0.15	0.23	0.22	0.23	0.24	0.24		0.32	0.13	0.30	0.32	0.31	0.33	0.33		0.44	0.18	0.41	0.45	0.44	0.44	0.45		0.46	0.18	0.42	0.48	0.45	0.45	0.48	
LM	5	0.39	0.18	0.03	0.39	0.03	0.03	0.39		0.51	0.22	0.00	0.51	0.04	0.03	0.51		0.54	0.24	0.05	0.55	0.03	0.02	0.55		0.54	0.24	0.05	0.55	0.02	0.02	0.55	
	10	0.24	0.11	0.34	0.25	0.23	0.24	0.34	0.39	0.38	0.15	0.45	0.39	0.37	0.39	0.45	0.51	0.51	0.19	0.51	0.52	0.46	0.47	0.52	0.55	0.52	0.19	0.52	0.53	0.47	0.48	0.53	0.55
	20	0.17	0.09	0.03	0.18	0.03	0.03	0.18		0.29	0.12	0.00	0.30	0.00	0.00	0.30		0.40	0.16	0.01	0.41	0.01	0.01	0.41		0.41	0.16	0.01	0.42	0.01	0.01	0.42	
LMFS	5	0.49	0.18	0.46	0.49	0.48	0.48	0.49		0.59	0.22	0.58	0.60	0.58	0.58	0.60		0.61	0.25	0.58	0.62	0.61	0.61	0.62		0.61	0.24	0.58	0.62	0.60	0.61	0.62	
	10	0.37	0.12	0.38	0.40	0.42	0.41	0.42	0.49	0.50	0.15	0.49	0.50	0.51	0.52	0.52	0.60	0.58	0.19	0.55	0.60	0.58	0.58	0.60	0.62	0.60	0.19	0.55	0.61	0.58	0.59	0.61	0.62
	20	0.33	0.10	0.29	0.32	0.03	0.03	0.33		0.40	0.12	0.00	0.41	0.00	0.00	0.41		0.49	0.16	0.44	0.50	0.01	0.01	0.50		0.50	0.16	0.46	0.51	0.01	0.01	0.51	
Max (polmer 5)		0.49	0.18	0.46	0.49	0.48	0.48	0.49		0.59	0.22	0.58	0.60	0.58	0.58	0.60		0.61	0.25	0.58	0.62	0.61	0.61	0.62		0.61	0.24	0.58	0.62	0.60	0.61	0.62	
Max (polmer 10)		0.37	0.12	0.38	0.40	0.42	0.41	0.42		0.50	0.15	0.49	0.50	0.51	0.52	0.52		0.58	0.21	0.55	0.60	0.58	0.58	0.60		0.60	0.21	0.55	0.61	0.58	0.59	0.61	
Max (polmer 20)		0.33	0.15	0.29	0.32	0.23	0.25	0.33		0.40	0.14	0.30	0.41	0.33	0.34	0.41		0.49	0.19	0.44	0.50	0.44	0.44	0.50		0.50	0.19	0.46	0.51	0.46	0.47	0.51	
Max (vsi polmeri)		0.49	0.18	0.46	0.49	0.48	0.48		0.49	0.59	0.22	0.58	0.60	0.58	0.58		0.60	0.61	0.25	0.58	0.62	0.61	0.61		0.62	0.61	0.24	0.58	0.62	0.60	0.61		0.62

		45°							60°							120°							170°						
	indirectsitefacto	Skupina pojasnjevalnih spremenljivk							Skupina pojasnjevalnih spremenljivk							Skupina pojasnjevalnih spremenljivk							Skupina pojasnjevalnih spremenljivk						
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max	P	N	T	PN	PT	PNT	Max	P	N	T	PN	PT	PNT	Max	P	N	T	PN	PT	PNT	Max
MTB	5	0.70	0.19	0.68	0.71	0.70	0.71	0.71	0.75	0.21	0.74	0.77	0.75	0.76	0.77	0.79	0.28	0.78	0.80	0.79	0.81	0.81	0.78	0.28	0.77	0.79	0.79	0.80	0.80
	10	0.58	0.21	0.56	0.60	0.58	0.60	0.60	0.65	0.23	0.62	0.66	0.65	0.66	0.66	0.79	0.31	0.72	0.79	0.78	0.79	0.79	0.80	0.34	0.73	0.81	0.80	0.81	0.81
	20	0.42	0.23	0.37	0.43	0.42	0.43	0.43	0.49	0.26	0.43	0.50	0.49	0.49	0.50	0.64	0.35	0.58	0.64	0.63	0.64	0.64	0.66	0.35	0.59	0.66	0.65	0.65	0.66
MTRF	5	0.71	0.21	0.68	0.72	0.71	0.71	0.72	0.76	0.22	0.74	0.77	0.76	0.76	0.77	0.81	0.29	0.77	0.82	0.81	0.82	0.82	0.81	0.30	0.76	0.81	0.81	0.81	0.81
	10	0.58	0.21	0.57	0.60	0.59	0.59	0.60	0.66	0.23	0.63	0.67	0.66	0.67	0.67	0.80	0.33	0.74	0.80	0.80	0.80	0.80	0.81	0.36	0.74	0.82	0.81	0.82	0.82
	20	0.42	0.23	0.38	0.42	0.42	0.43	0.43	0.49	0.26	0.44	0.49	0.48	0.48	0.49	0.65	0.35	0.58	0.66	0.64	0.64	0.66	0.68	0.35	0.60	0.69	0.66	0.67	0.69
STB	5	0.70	0.18	0.68	0.71	0.70	0.71	0.71	0.75	0.22	0.74	0.76	0.75	0.76	0.76	0.79	0.28	0.78	0.80	0.79	0.80	0.80	0.78	0.27	0.77	0.79	0.79	0.80	0.80
	10	0.57	0.21	0.54	0.59	0.57	0.59	0.59	0.64	0.22	0.62	0.65	0.65	0.66	0.66	0.78	0.33	0.73	0.78	0.78	0.79	0.79	0.80	0.34	0.73	0.81	0.81	0.81	0.81
	20	0.43	0.23	0.37	0.42	0.42	0.43	0.43	0.48	0.25	0.42	0.49	0.47	0.47	0.49	0.64	0.34	0.57	0.64	0.63	0.63	0.64	0.65	0.36	0.58	0.65	0.65	0.65	0.65
STRF	5	0.71	0.20	0.68	0.71	0.70	0.71	0.71	0.76	0.22	0.74	0.77	0.76	0.77	0.77	0.81	0.29	0.78	0.82	0.81	0.82	0.82	0.80	0.29	0.76	0.81	0.81	0.82	0.82
	10	0.57	0.20	0.57	0.59	0.58	0.59	0.59	0.66	0.25	0.63	0.66	0.65	0.66	0.66	0.79	0.33	0.74	0.80	0.79	0.80	0.80	0.81	0.36	0.74	0.82	0.81	0.81	0.82
	20	0.42	0.23	0.38	0.43	0.41	0.42	0.43	0.49	0.25	0.43	0.49	0.47	0.48	0.49	0.65	0.34	0.56	0.65	0.63	0.64	0.65	0.68	0.34	0.59	0.68	0.66	0.66	0.68
LM	5	0.69	0.27	-0.02	0.69	-0.02	-0.02	0.69	0.74	0.30	-0.02	0.75	0.00	-0.01	0.75	0.78	0.31	0.00	0.79	0.00	-0.01	0.79	0.76	0.30	0.00	0.77	0.00	-0.01	0.77
	10	0.54	0.24	0.55	0.54	0.50	0.50	0.55	0.61	0.26	0.62	0.61	0.58	0.58	0.62	0.76	0.29	0.72	0.76	0.73	0.74	0.76	0.77	0.29	0.72	0.77	0.74	0.75	0.77
	20	0.37	0.21	-0.01	0.37	-0.01	-0.01	0.37	0.43	0.23	-0.02	0.43	-0.02	-0.02	0.43	0.59	0.27	-0.02	0.59	-0.02	-0.02	0.59	0.61	0.27	-0.02	0.61	-0.02	-0.02	0.61
LMFS	5	0.73	0.28	0.70	0.73	0.73	-0.02	0.73	0.78	0.30	0.75	0.78	0.78	0.79	0.79	0.81	0.32	0.77	0.82	0.81	0.82	0.82	0.80	0.31	0.75	0.81	0.80	0.81	0.81
	10	0.62	0.25	0.59	0.62	0.63	0.63	0.63	0.68	0.27	0.65	0.68	0.68	0.69	0.69	0.80	0.30	0.73	0.80	0.79	0.79	0.80	0.80	0.29	0.74	0.81	0.80	0.80	0.81
	20	0.49	0.22	-0.01	0.48	-0.01	-0.01	0.49	0.54	0.24	-0.02	0.53	-0.02	-0.02	0.54	0.66	0.27	-0.02	0.67	-0.02	-0.02	0.67	0.68	0.27	-0.02	0.68	-0.02	-0.02	0.68
Max (polmer 5)		0.73	0.28	0.70	0.73	0.73	0.71	0.73	0.78	0.30	0.75	0.78	0.78	0.79	0.79	0.81	0.32	0.78	0.82	0.81	0.82	0.82	0.81	0.31	0.77	0.81	0.81	0.82	0.82
Max (polmer 10)		0.62	0.25	0.59	0.62	0.63	0.63	0.63	0.68	0.27	0.65	0.68	0.68	0.69	0.69	0.80	0.33	0.74	0.80	0.80	0.80	0.80	0.81	0.36	0.74	0.82	0.81	0.81	0.82
Max (polmer 20)		0.49	0.23	0.38	0.48	0.42	0.43	0.49	0.54	0.26	0.44	0.53	0.49	0.49	0.54	0.66	0.35	0.58	0.67	0.64	0.64	0.67	0.68	0.36	0.60	0.69	0.66	0.67	0.69
Max (vsi polmeri)		0.73	0.28	0.70	0.73	0.73	0.71	0.73	0.78	0.30	0.75	0.78	0.78	0.79	0.79	0.81	0.35	0.78	0.82	0.81	0.82	0.82	0.81	0.36	0.77	0.82	0.81	0.82	0.82

totalsitefactor		45°								60°								120°								170°							
		Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max	
MTB	5	0.45	0.06	0.46	0.47	0.45	0.48	0.48		0.59	0.13	0.58	0.60	0.59	0.60	0.60		0.61	0.18	0.58	0.62	0.60	0.62	0.62		0.60	0.18	0.57	0.61	0.59	0.61	0.61	
	10	0.37	0.05	0.39	0.39	0.37	0.38	0.39	0.48	0.50	0.09	0.47	0.51	0.50	0.50	0.51	0.60	0.60	0.18	0.52	0.61	0.59	0.60	0.61	0.62	0.61	0.20	0.52	0.62	0.60	0.62	0.62	0.62
	20	0.25	0.14	0.22	0.27	0.25	0.27	0.27		0.35	0.14	0.30	0.36	0.34	0.35	0.36		0.45	0.21	0.43	0.47	0.45	0.46	0.47		0.47	0.21	0.45	0.48	0.46	0.47	0.48	
MTRF	5	0.47	0.07	0.47	0.48	0.47	0.48	0.48		0.60	0.14	0.58	0.61	0.60	0.60	0.61		0.62	0.18	0.58	0.63	0.62	0.63	0.63		0.62	0.18	0.58	0.63	0.61	0.62	0.63	
	10	0.38	0.04	0.38	0.39	0.38	0.39	0.39	0.48	0.52	0.11	0.48	0.52	0.50	0.52	0.52	0.61	0.61	0.18	0.53	0.62	0.61	0.61	0.62	0.63	0.62	0.21	0.54	0.63	0.61	0.61	0.63	0.63
	20	0.26	0.16	0.25	0.27	0.25	0.27	0.27		0.35	0.16	0.32	0.37	0.35	0.36	0.37		0.48	0.21	0.44	0.49	0.47	0.47	0.49		0.50	0.21	0.46	0.51	0.49	0.50	0.51	
STB	5	0.45	0.07	0.44	0.45	0.45	0.46	0.46		0.58	0.13	0.57	0.60	0.58	0.59	0.60		0.60	0.18	0.56	0.62	0.60	0.61	0.62		0.60	0.18	0.55	0.61	0.59	0.60	0.61	
	10	0.35	0.04	0.37	0.36	0.36	0.38	0.38	0.46	0.48	0.11	0.46	0.50	0.48	0.50	0.50	0.60	0.59	0.21	0.52	0.60	0.58	0.59	0.60	0.62	0.60	0.22	0.52	0.61	0.59	0.60	0.61	0.61
	20	0.25	0.16	0.21	0.26	0.24	0.25	0.26		0.34	0.14	0.30	0.38	0.34	0.37	0.38		0.46	0.20	0.43	0.48	0.46	0.48	0.48		0.47	0.20	0.44	0.49	0.47	0.49	0.49	
STRF	5	0.46	0.06	0.45	0.48	0.47	0.47	0.48		0.59	0.14	0.58	0.60	0.59	0.60	0.60		0.62	0.18	0.58	0.63	0.61	0.63	0.63		0.62	0.19	0.57	0.63	0.61	0.62	0.63	
	10	0.36	0.06	0.37	0.37	0.37	0.38	0.38	0.48	0.51	0.12	0.47	0.51	0.49	0.51	0.51	0.60	0.61	0.20	0.53	0.62	0.60	0.60	0.62	0.63	0.62	0.23	0.53	0.62	0.61	0.62	0.62	0.63
	20	0.25	0.17	0.25	0.25	0.24	0.27	0.27		0.35	0.15	0.32	0.35	0.34	0.35	0.35		0.48	0.20	0.43	0.48	0.47	0.47	0.48		0.50	0.21	0.45	0.50	0.48	0.48	0.50	
LM	5	0.43	0.19	0.03	0.43	0.03	0.03	0.43		0.56	0.23	-0.01	0.56	0.04	0.04	0.56		0.59	0.25	0.08	0.59	0.03	0.03	0.59		0.58	0.25	0.08	0.58	0.03	0.03	0.58	
	10	0.27	0.13	0.38	0.28	0.26	0.27	0.38	0.43	0.42	0.17	0.48	0.43	0.41	0.43	0.48	0.56	0.55	0.20	0.55	0.56	0.51	0.51	0.56	0.59	0.56	0.20	0.55	0.57	0.51	0.52	0.57	0.58
	20	0.19	0.11	0.03	0.20	0.03	0.03	0.20		0.31	0.13	0.00	0.32	0.00	0.00	0.32		0.43	0.18	0.01	0.44	0.01	0.01	0.44		0.44	0.17	0.01	0.45	0.01	0.01	0.45	
LMFS	5	0.52	0.19	0.50	0.52	0.51	0.52	0.52		0.63	0.24	0.62	0.63	0.62	0.62	0.63		0.65	0.26	0.62	0.66	0.64	0.64	0.66		0.64	0.25	0.61	0.65	0.64	0.64	0.65	
	10	0.41	0.13	0.42	0.43	0.43	0.43	0.43	0.52	0.53	0.17	0.52	0.54	0.55	0.55	0.55	0.63	0.62	0.20	0.58	0.63	0.61	0.62	0.63	0.66	0.63	0.20	0.58	0.64	0.62	0.62	0.64	0.65
	20	0.34	0.11	0.30	0.35	0.03	0.03	0.35		0.43	0.13	0.00	0.44	0.00	0.00	0.44		0.52	0.18	0.47	0.53	0.01	0.01	0.53		0.53	0.18	0.01	0.54	0.01	0.01	0.54	
Max (polmer 5)		0.52	0.19	0.50	0.52	0.51	0.52	0.52		0.63	0.24	0.62	0.63	0.62	0.62	0.63		0.65	0.26	0.62	0.66	0.64	0.64	0.66		0.64	0.25	0.61	0.65	0.64	0.64	0.65	
Max (polmer 10)		0.41	0.13	0.42	0.43	0.43	0.43	0.43		0.53	0.17	0.52	0.54	0.55	0.55	0.55		0.62	0.21	0.58	0.63	0.61	0.62	0.63		0.63	0.23	0.58	0.64	0.62	0.62	0.64	
Max (polmer 20)		0.34	0.17	0.30	0.35	0.25	0.27	0.35		0.43	0.16	0.32	0.44	0.35	0.37	0.44		0.52	0.21	0.47	0.53	0.47	0.48	0.53		0.53	0.21	0.46	0.54	0.49	0.50	0.54	
Max (vsi polmeri)		0.52	0.19	0.50	0.52	0.51	0.52		0.52	0.63	0.24	0.62	0.63	0.62	0.62		0.63	0.65	0.26	0.62	0.66	0.64	0.64		0.66	0.64	0.25	0.61	0.65	0.64	0.64		0.65

		45°								60°								120°								170°							
ppfddirectunder		Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max	
MTB	5	0.41	0.05	0.42	0.44	0.41	0.44	0.44	0.44	0.54	0.11	0.54	0.56	0.55	0.55	0.56	0.56	0.57	0.17	0.54	0.58	0.56	0.58	0.58	0.58	0.56	0.17	0.54	0.58	0.56	0.58	0.58	0.58
	10	0.33	0.04	0.35	0.36	0.33	0.35	0.36		0.46	0.08	0.43	0.47	0.46	0.47	0.47		0.56	0.17	0.48	0.57	0.55	0.56	0.57		0.57	0.18	0.49	0.58	0.57	0.58	0.58	
	20	0.23	0.12	0.20	0.24	0.23	0.24	0.24		0.32	0.13	0.27	0.33	0.31	0.32	0.33		0.42	0.19	0.40	0.43	0.42	0.43	0.43		0.44	0.19	0.42	0.45	0.43	0.44	0.45	
MTRF	5	0.43	0.06	0.43	0.45	0.43	0.44	0.45	0.45	0.56	0.12	0.54	0.57	0.55	0.56	0.57	0.57	0.58	0.17	0.54	0.59	0.58	0.59	0.59	0.60	0.59	0.16	0.54	0.60	0.58	0.59	0.60	0.60
	10	0.35	0.03	0.35	0.36	0.35	0.36	0.36		0.48	0.09	0.44	0.49	0.46	0.48	0.49		0.57	0.16	0.49	0.58	0.57	0.57	0.58		0.58	0.19	0.50	0.59	0.57	0.57	0.59	
	20	0.23	0.15	0.23	0.25	0.22	0.25	0.25		0.32	0.14	0.30	0.34	0.33	0.33	0.34		0.44	0.19	0.41	0.46	0.43	0.44	0.46		0.46	0.19	0.44	0.48	0.46	0.47	0.48	
STB	5	0.40	0.04	0.41	0.41	0.41	0.42	0.42	0.42	0.54	0.12	0.53	0.55	0.53	0.54	0.55	0.55	0.56	0.17	0.52	0.58	0.55	0.57	0.58	0.58	0.56	0.16	0.52	0.58	0.56	0.57	0.58	0.58
	10	0.32	0.05	0.34	0.33	0.33	0.34	0.34		0.44	0.09	0.42	0.46	0.44	0.46	0.46		0.55	0.19	0.48	0.56	0.54	0.56	0.56		0.57	0.20	0.48	0.57	0.56	0.57	0.57	
	20	0.22	0.14	0.19	0.23	0.20	0.23	0.23		0.31	0.13	0.27	0.34	0.31	0.34	0.34		0.43	0.18	0.40	0.44	0.42	0.44	0.44		0.44	0.17	0.42	0.46	0.43	0.45	0.46	
STRF	5	0.42	0.05	0.42	0.43	0.42	0.43	0.43	0.43	0.55	0.13	0.53	0.56	0.55	0.56	0.56	0.56	0.58	0.18	0.53	0.59	0.58	0.58	0.59	0.59	0.59	0.17	0.53	0.59	0.58	0.58	0.59	0.59
	10	0.32	0.04	0.34	0.34	0.34	0.35	0.35		0.47	0.09	0.43	0.48	0.45	0.47	0.48		0.57	0.20	0.49	0.59	0.56	0.56	0.59		0.58	0.20	0.50	0.59	0.57	0.57	0.59	
	20	0.22	0.17	0.21	0.24	0.23	0.23	0.24		0.32	0.14	0.28	0.32	0.31	0.32	0.32		0.45	0.18	0.41	0.45	0.44	0.43	0.45		0.46	0.18	0.43	0.48	0.45	0.45	0.48	
LM	5	0.39	0.18	0.03	0.39	0.03	0.03	0.39	0.39	0.51	0.22	0.00	0.51	0.04	0.03	0.51	0.51	0.54	0.24	0.05	0.55	0.03	0.02	0.55	0.55	0.54	0.24	0.05	0.55	0.03	0.02	0.55	0.55
	10	0.24	0.11	0.34	0.25	0.23	0.25	0.34		0.38	0.15	0.45	0.39	0.37	0.39	0.45		0.51	0.19	0.51	0.52	0.46	0.47	0.52		0.52	0.19	0.52	0.53	0.47	0.48	0.53	
	20	0.17	0.09	0.03	0.18	0.03	0.03	0.18		0.29	0.12	0.00	0.30	0.00	0.00	0.30		0.40	0.16	0.01	0.41	0.01	0.01	0.41		0.41	0.16	0.01	0.42	0.01	0.01	0.42	
LMFS	5	0.49	0.18	0.46	0.50	0.48	0.48	0.50		0.59	0.22	0.58	0.60	0.58	0.58	0.60		0.61	0.25	0.58	0.62	0.61	0.61	0.62		0.61	0.24	0.58	0.62	0.60	0.61	0.62	
	10	0.39	0.12	0.38	0.40	0.42	0.40	0.42	0.50	0.50	0.15	0.49	0.50	0.51	0.52	0.52	0.60	0.58	0.19	0.55	0.60	0.58	0.58	0.60	0.62	0.60	0.18	0.55	0.61	0.58	0.59	0.61	0.62
	20	0.33	0.10	0.28	0.33	0.03	0.03	0.33		0.40	0.12	0.00	0.41	0.00	0.00	0.41		0.49	0.16	0.44	0.50	0.01	0.01	0.50		0.50	0.16	0.46	0.51	0.01	0.01	0.51	
Max (polmer 5)		0.49	0.18	0.46	0.50	0.48	0.48	0.50		0.59	0.22	0.58	0.60	0.58	0.58	0.60		0.61	0.25	0.58	0.62	0.61	0.61	0.62		0.61	0.24	0.58	0.62	0.60	0.61	0.62	
Max (polmer 10)		0.39	0.12	0.38	0.40	0.42	0.40	0.42		0.50	0.15	0.49	0.50	0.51	0.52	0.52		0.58	0.20	0.55	0.60	0.58	0.58	0.60		0.60	0.20	0.55	0.61	0.58	0.59	0.61	
Max (polmer 20)		0.33	0.17	0.28	0.33	0.23	0.25	0.33		0.40	0.14	0.30	0.41	0.33	0.34	0.41		0.49	0.19	0.44	0.50	0.44	0.44	0.50		0.50	0.19	0.46	0.51	0.46	0.47	0.51	
Max (vsi polmeri)		0.49	0.18	0.46	0.50	0.48	0.48		0.50	0.59	0.22	0.58	0.60	0.58	0.58		0.60	0.61	0.25	0.58	0.62	0.61	0.61		0.62	0.61	0.24	0.58	0.62	0.60	0.61		0.62

		45°								60°								120°								170°							
ppfddiffuseunde		Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max	
MTB	5	0.55	0.25	0.54	0.58	0.56	0.58	0.58	0.58	0.75	0.21	0.74	0.77	0.75	0.76	0.77	0.77	0.79	0.28	0.78	0.80	0.79	0.81	0.81	0.81	0.78	0.28	0.77	0.79	0.79	0.80	0.80	0.81
	10	0.49	0.26	0.46	0.52	0.50	0.54	0.54		0.65	0.23	0.62	0.66	0.65	0.66	0.66		0.79	0.31	0.72	0.79	0.78	0.79	0.79		0.80	0.34	0.73	0.81	0.80	0.81	0.81	
	20	0.39	0.29	0.32	0.41	0.38	0.41	0.41		0.49	0.26	0.43	0.50	0.49	0.49	0.50		0.64	0.35	0.58	0.64	0.63	0.64	0.64		0.66	0.35	0.59	0.66	0.65	0.65	0.66	
MTRF	5	0.57	0.27	0.53	0.59	0.57	0.58	0.59	0.59	0.77	0.22	0.74	0.77	0.76	0.76	0.77	0.77	0.81	0.29	0.77	0.82	0.81	0.82	0.82	0.82	0.81	0.30	0.76	0.81	0.81	0.81	0.81	0.81
	10	0.50	0.26	0.45	0.52	0.50	0.52	0.52		0.66	0.23	0.64	0.67	0.66	0.67	0.67		0.80	0.33	0.74	0.80	0.80	0.80	0.80		0.81	0.36	0.74	0.81	0.81	0.81	0.81	
	20	0.39	0.28	0.33	0.40	0.39	0.41	0.41		0.49	0.26	0.44	0.49	0.48	0.48	0.49		0.65	0.35	0.58	0.66	0.64	0.64	0.66		0.68	0.35	0.60	0.69	0.66	0.67	0.69	
STB	5	0.54	0.24	0.52	0.56	0.54	0.56	0.56	0.56	0.75	0.22	0.74	0.76	0.75	0.76	0.76	0.76	0.79	0.28	0.78	0.80	0.79	0.80	0.80	0.80	0.78	0.27	0.77	0.79	0.79	0.80	0.80	0.81
	10	0.46	0.26	0.45	0.51	0.48	0.52	0.52		0.64	0.23	0.62	0.65	0.65	0.66	0.66		0.78	0.33	0.73	0.78	0.78	0.79	0.79		0.80	0.34	0.73	0.81	0.81	0.81	0.81	
	20	0.37	0.26	0.33	0.40	0.37	0.39	0.40		0.49	0.25	0.42	0.49	0.47	0.47	0.49		0.64	0.35	0.56	0.64	0.63	0.63	0.64		0.65	0.36	0.58	0.65	0.65	0.65	0.65	
STRF	5	0.56	0.25	0.53	0.58	0.56	0.58	0.58	0.58	0.76	0.23	0.74	0.76	0.76	0.76	0.76	0.76	0.81	0.29	0.77	0.82	0.81	0.82	0.82	0.82	0.80	0.29	0.77	0.81	0.81	0.82	0.82	0.82
	10	0.48	0.26	0.45	0.51	0.50	0.53	0.53		0.65	0.23	0.64	0.66	0.65	0.66	0.66		0.79	0.33	0.75	0.80	0.80	0.80	0.80		0.81	0.35	0.74	0.82	0.81	0.81	0.82	
	20	0.38	0.28	0.31	0.40	0.38	0.39	0.40		0.48	0.25	0.43	0.49	0.47	0.48	0.49		0.64	0.35	0.57	0.65	0.64	0.63	0.65		0.68	0.35	0.59	0.68	0.65	0.66	0.68	
LM	5	0.51	0.32	0.07	0.54	0.03	0.01	0.54	0.54	0.74	0.30	-0.02	0.75	0.00	-0.01	0.75	0.75	0.78	0.31	0.00	0.79	0.00	-0.01	0.79	0.79	0.76	0.30	0.00	0.77	0.00	-0.01	0.77	0.77
	10	0.41	0.29	0.43	0.42	0.39	0.40	0.43		0.61	0.26	0.62	0.61	0.58	0.58	0.62		0.76	0.29	0.72	0.76	0.73	0.74	0.76		0.77	0.29	0.72	0.77	0.74	0.75	0.77	
	20	0.32	0.27	-0.03	0.33	-0.03	-0.03	0.33		0.43	0.23	-0.02	0.43	-0.02	-0.02	0.43		0.59	0.27	-0.02	0.59	-0.02	-0.02	0.59		0.61	0.27	-0.02	0.61	-0.02	-0.02	0.61	
LMFS	5	0.60	0.33	0.56	0.62	0.59	0.61	0.62	0.62	0.78	0.30	0.75	0.78	0.78	0.78	0.78	0.78	0.81	0.32	0.77	0.82	0.81	0.82	0.82	0.82	0.80	0.31	0.75	0.81	0.80	0.81	0.81	0.81
	10	0.51	0.30	0.47	0.52	0.51	0.53	0.53		0.68	0.27	0.65	0.68	0.69	0.68	0.69		0.80	0.30	0.73	0.80	0.79	0.80	0.80		0.80	0.29	0.74	0.81	0.80	0.81	0.81	
	20	0.43	0.28	-0.03	0.44	-0.03	-0.03	0.44		0.54	0.24	-0.02	0.54	-0.02	-0.02	0.54		0.66	0.27	-0.02	0.67	-0.02	-0.02	0.67		0.68	0.27	-0.02	0.68	-0.02	-0.02	0.68	
Max (polmer 5)		0.60	0.33	0.56	0.62	0.59	0.61	0.62		0.78	0.30	0.75	0.78	0.78	0.78	0.78		0.81	0.32	0.78	0.82	0.81	0.82	0.82		0.81	0.31	0.77	0.81	0.81	0.82	0.82	
Max (polmer 10)		0.51	0.30	0.47	0.52	0.51	0.54	0.54		0.68	0.27	0.65	0.68	0.69	0.68	0.69		0.80	0.33	0.75	0.80	0.80	0.80	0.80		0.81	0.36	0.74	0.82	0.81	0.81	0.82	
Max (polmer 20)		0.43	0.29	0.33	0.44	0.39	0.41	0.44		0.54	0.26	0.44	0.54	0.49	0.49	0.54		0.66	0.35	0.58	0.67	0.64	0.64	0.67		0.68	0.36	0.60	0.69	0.66	0.67	0.69	
Max (vsi polmeri)		0.60	0.33	0.56	0.62	0.59	0.61		0.62	0.78	0.30	0.75	0.78	0.78	0.78		0.78	0.81	0.35	0.78	0.82	0.81	0.82		0.82	0.81	0.36	0.77	0.82	0.81	0.82		0.82

		45°								60°								120°								170°							
ppfdtotalunder		Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk								Skupina pojasnjevalnih spremenljivk							
Model	Polmer [m]	P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max		P	N	T	PN	PT	PNT	Max	
MTB	5	0.45	0.06	0.46	0.48	0.46	0.48	0.48	0.48	0.59	0.13	0.58	0.60	0.59	0.60	0.60	0.60	0.61	0.18	0.58	0.62	0.60	0.62	0.62	0.62	0.60	0.18	0.57	0.61	0.59	0.61	0.61	0.62
	10	0.37	0.06	0.39	0.40	0.37	0.39	0.40		0.50	0.09	0.47	0.51	0.50	0.50	0.51		0.60	0.18	0.52	0.61	0.59	0.60	0.61		0.61	0.20	0.52	0.62	0.60	0.62	0.62	
	20	0.26	0.14	0.23	0.28	0.26	0.27	0.28		0.35	0.14	0.30	0.36	0.34	0.35	0.36		0.45	0.21	0.43	0.47	0.45	0.46	0.47		0.47	0.21	0.45	0.48	0.46	0.47	0.48	
MTRF	5	0.47	0.08	0.47	0.49	0.48	0.48	0.49	0.49	0.60	0.14	0.58	0.61	0.60	0.60	0.61	0.61	0.62	0.18	0.58	0.63	0.62	0.63	0.63	0.63	0.62	0.18	0.58	0.63	0.61	0.62	0.63	0.63
	10	0.38	0.05	0.39	0.40	0.39	0.40	0.40		0.52	0.11	0.48	0.52	0.50	0.52	0.52		0.61	0.18	0.53	0.62	0.61	0.61	0.62		0.62	0.21	0.54	0.63	0.61	0.61	0.63	
	20	0.26	0.17	0.26	0.28	0.25	0.28	0.28		0.35	0.16	0.32	0.37	0.35	0.36	0.37		0.48	0.21	0.44	0.49	0.47	0.47	0.49		0.50	0.21	0.46	0.51	0.49	0.50	0.51	
STB	5	0.45	0.06	0.45	0.46	0.45	0.46	0.46	0.46	0.58	0.13	0.57	0.60	0.58	0.59	0.60	0.60	0.60	0.18	0.56	0.62	0.60	0.62	0.62	0.62	0.60	0.18	0.55	0.61	0.59	0.60	0.61	0.61
	10	0.35	0.06	0.38	0.37	0.37	0.39	0.39		0.48	0.11	0.46	0.50	0.48	0.50	0.50		0.59	0.21	0.52	0.60	0.58	0.59	0.60		0.60	0.22	0.52	0.61	0.59	0.60	0.61	
	20	0.25	0.18	0.23	0.28	0.24	0.25	0.28		0.34	0.14	0.29	0.38	0.34	0.36	0.38		0.46	0.21	0.43	0.48	0.46	0.46	0.48		0.47	0.20	0.44	0.49	0.47	0.49	0.49	
STRF	5	0.46	0.07	0.47	0.47	0.46	0.47	0.47	0.47	0.59	0.14	0.58	0.60	0.59	0.60	0.60	0.60	0.62	0.17	0.57	0.64	0.61	0.62	0.64	0.64	0.62	0.19	0.57	0.63	0.63	0.62	0.63	0.63
	10	0.36	0.05	0.37	0.38	0.38	0.38	0.38		0.51	0.11	0.47	0.52	0.50	0.50	0.52		0.61	0.21	0.53	0.61	0.60	0.61	0.61		0.62	0.21	0.53	0.63	0.61	0.62	0.63	
	20	0.27	0.17	0.24	0.27	0.24	0.26	0.27		0.36	0.15	0.31	0.37	0.35	0.35	0.37		0.47	0.21	0.44	0.49	0.47	0.48	0.49		0.50	0.22	0.47	0.51	0.49	0.48	0.51	
LM	5	0.44	0.19	0.03	0.44	0.03	0.03	0.44	0.44	0.56	0.23	-0.01	0.56	0.04	0.04	0.56	0.56	0.59	0.25	0.08	0.59	0.03	0.03	0.59	0.59	0.58	0.25	0.08	0.58	0.03	0.03	0.58	0.58
	10	0.27	0.13	0.38	0.28	0.27	0.28	0.38		0.42	0.17	0.48	0.43	0.41	0.43	0.48		0.55	0.20	0.55	0.56	0.51	0.51	0.56		0.56	0.20	0.55	0.57	0.51	0.52	0.57	
	20	0.20	0.11	0.02	0.21	0.02	0.02	0.21		0.31	0.14	0.00	0.32	0.00	0.00	0.32		0.43	0.18	0.01	0.44	0.01	0.01	0.44		0.44	0.17	0.01	0.45	0.01	0.01	0.45	
LMFS	5	0.52	0.20	0.49	0.52	0.52	0.52	0.52	0.52	0.63	0.24	0.62	0.63	0.62	0.62	0.63	0.63	0.65	0.26	0.62	0.66	0.64	0.64	0.66	0.66	0.64	0.25	0.61	0.65	0.64	0.64	0.65	0.65
	10	0.41	0.14	0.42	0.43	0.45	0.44	0.45		0.53	0.17	0.52	0.54	0.55	0.55	0.55		0.62	0.20	0.58	0.63	0.61	0.62	0.63		0.63	0.20	0.58	0.64	0.62	0.62	0.64	
	20	0.35	0.12	0.31	0.36	0.02	0.02	0.36		0.42	0.13	0.00	0.44	0.00	0.00	0.44		0.52	0.18	0.47	0.53	0.01	0.01	0.53		0.53	0.18	0.01	0.54	0.01	0.01	0.54	
Max (polmer 5)		0.52	0.20	0.49	0.52	0.52	0.52	0.52		0.63	0.24	0.62	0.63	0.62	0.62	0.63		0.65	0.26	0.62	0.66	0.64	0.64	0.66		0.64	0.25	0.61	0.65	0.64	0.64	0.65	
Max (polmer 10)		0.41	0.14	0.42	0.43	0.45	0.44	0.45		0.53	0.17	0.52	0.54	0.55	0.55	0.55		0.62	0.21	0.58	0.63	0.61	0.62	0.63		0.63	0.22	0.58	0.64	0.62	0.62	0.64	
Max (polmer 20)		0.35	0.18	0.31	0.36	0.26	0.28	0.36		0.42	0.16	0.32	0.44	0.35	0.36	0.44		0.52	0.21	0.47	0.53	0.47	0.48	0.53		0.53	0.22	0.47	0.54	0.49	0.50	0.54	
Max (vsi polmeri)		0.52	0.20	0.49	0.52	0.52	0.52		0.52	0.63	0.24	0.62	0.63	0.62	0.62		0.63	0.65	0.26	0.62	0.66	0.64	0.64		0.66	0.64	0.25	0.61	0.65	0.64	0.64		0.65

PRILOGA D: Modelne rastrske karte testnega območja Slivnica

Karte imajo fizično ločljivost 4 m, vsebinska ločljivost pa ustreza polmeru veljavnosti uporabljenih pojasnjevalnih spremenljivk, ki je razviden iz pripone v imenu modela, zapisanem v naslovu vsake karte. Ker tisk kart na format A4 ne omogoča razločevanja podrobnosti, so karte v obliki jpg slik priložene tudi na DVD.

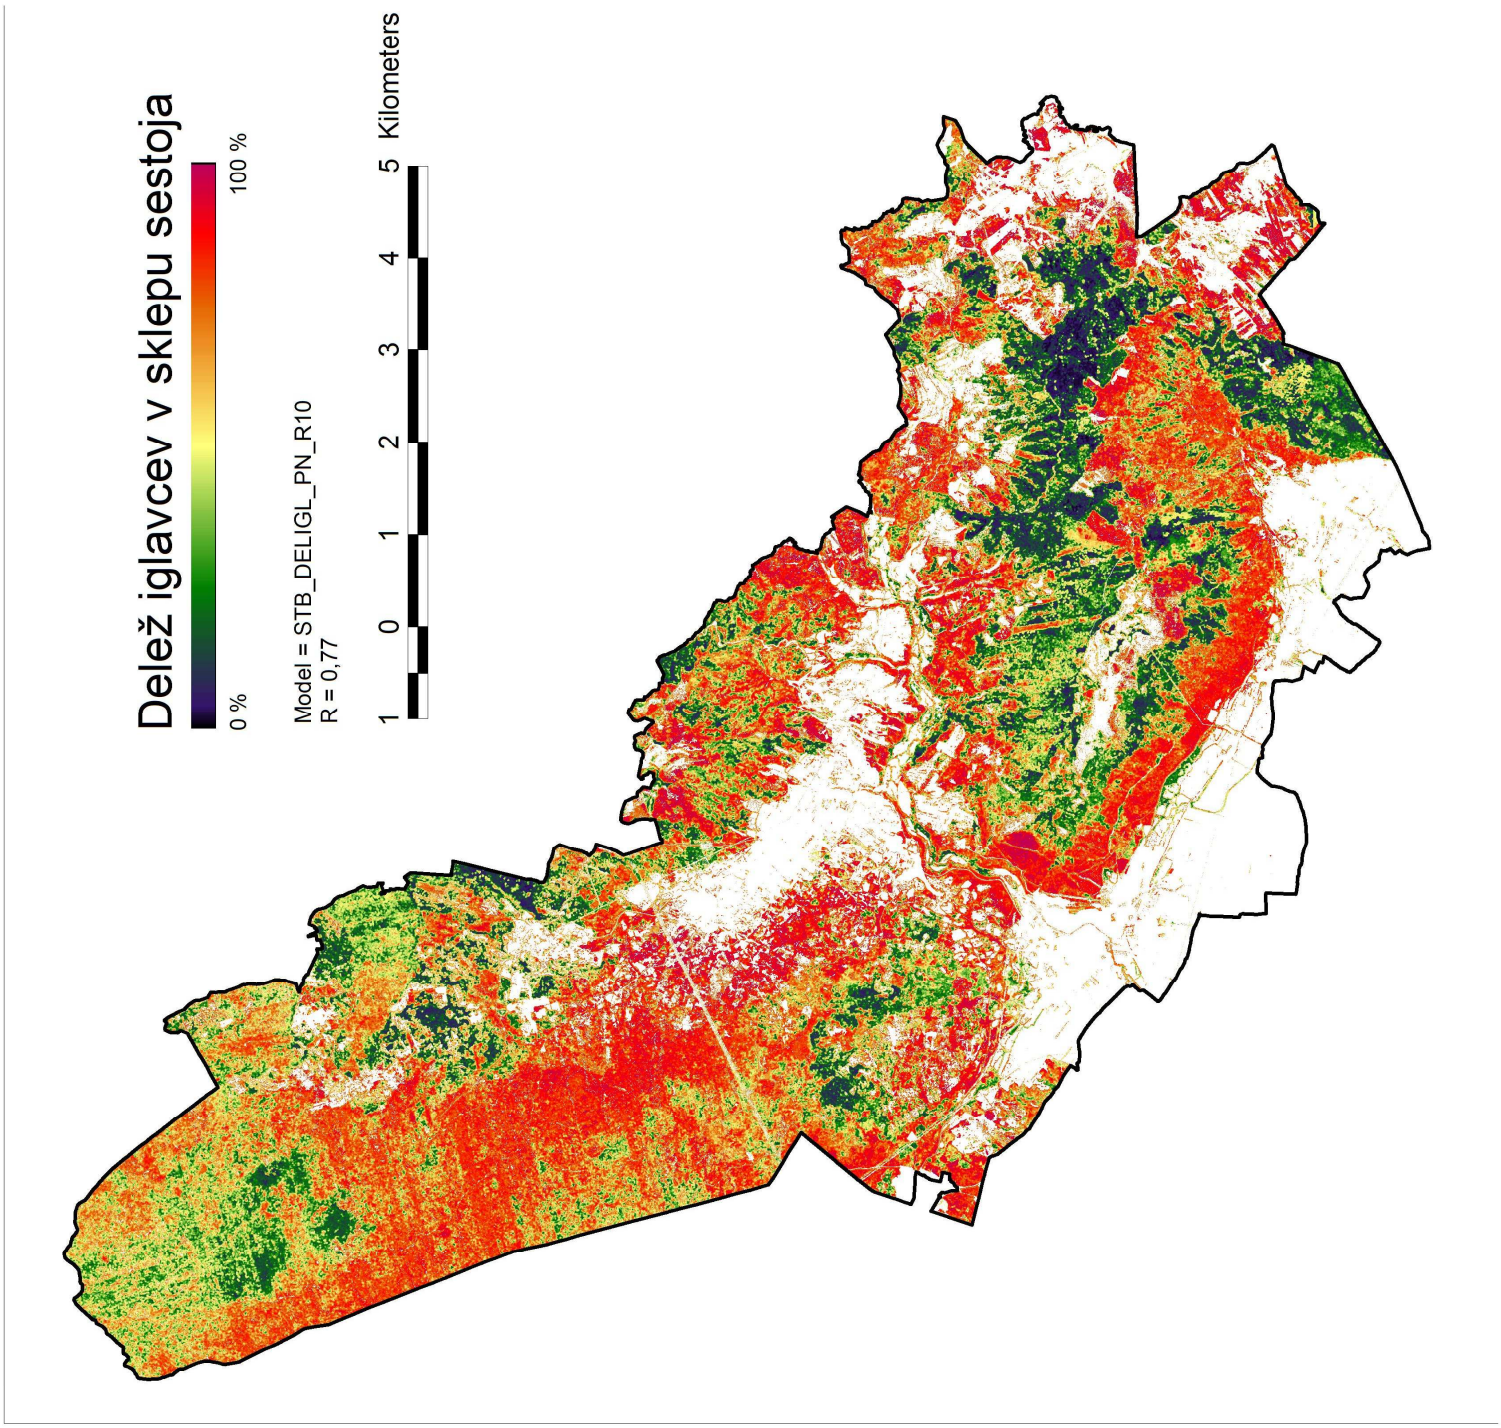
Delež iglavcev v sklepu sestoja
0 %
100 %
Model = STB_DELIGL_PN_R10
R = 0,77
1 0 1 2 3 4 5 Kilometers

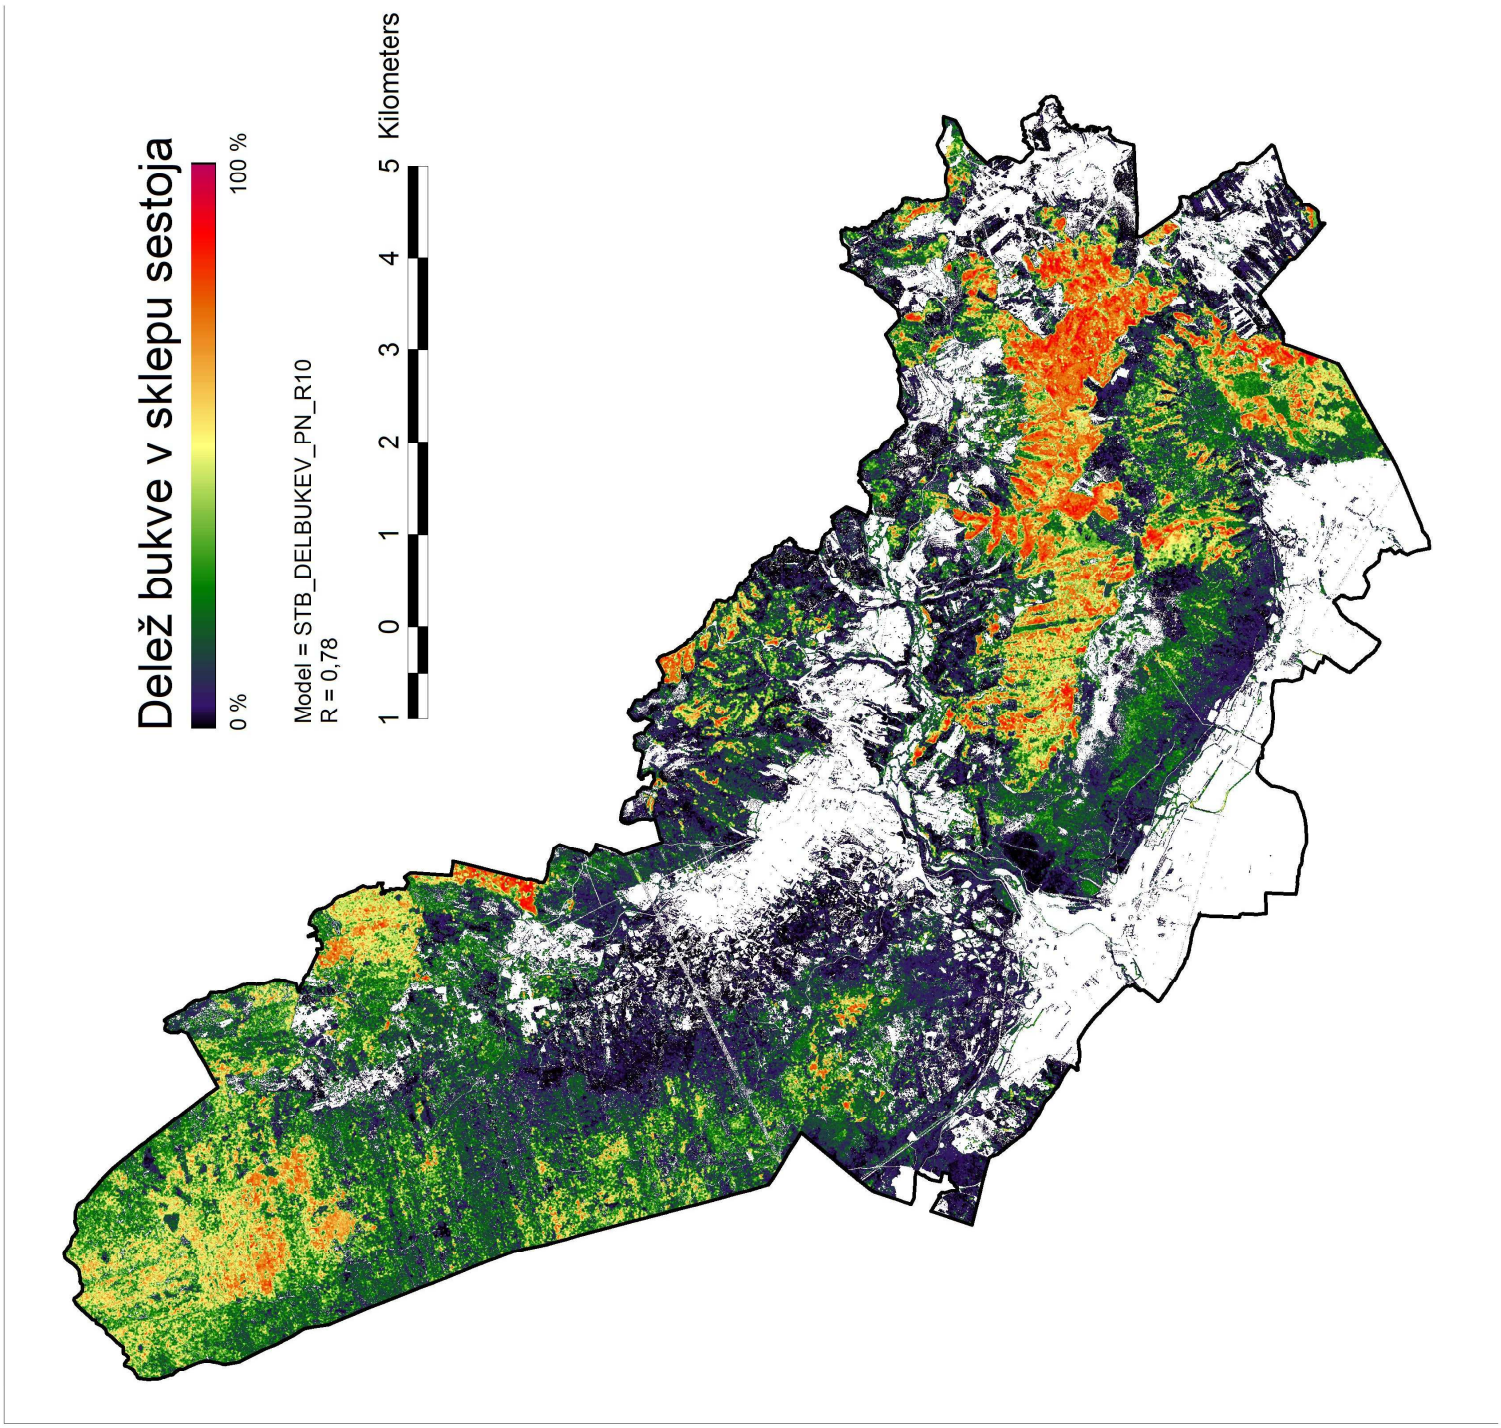
Delež bukve v sklepu sestoja
0 %
100 %
Model = STB_DELBUKEV_PN_R10
R = 0,78
1 0 1 2 3 4 5 Kilometers

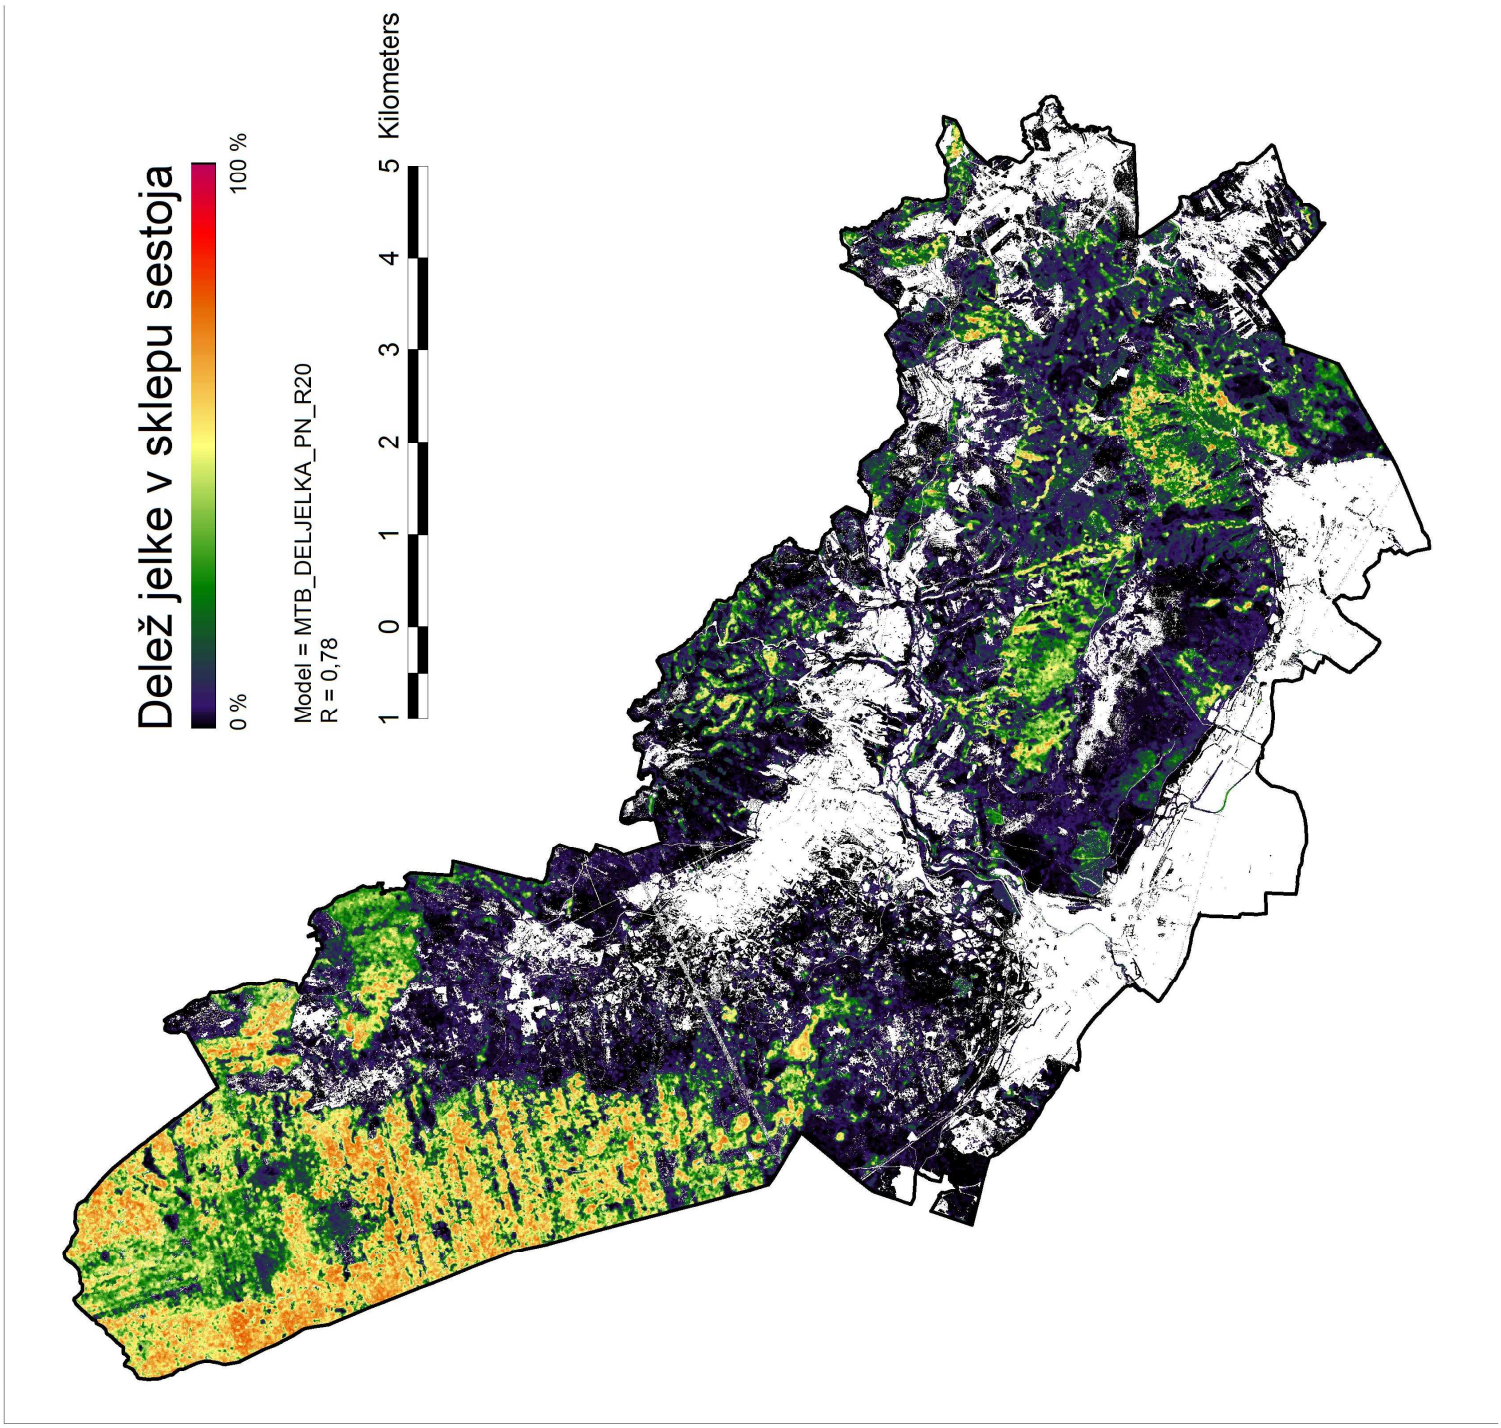
Delež jelke v sklepu sestoja
0 %
100 %
Model = MTB_DELJELKA_PN_R20
R = 0,78
1 0 1 2 3 4 5 Kilometers

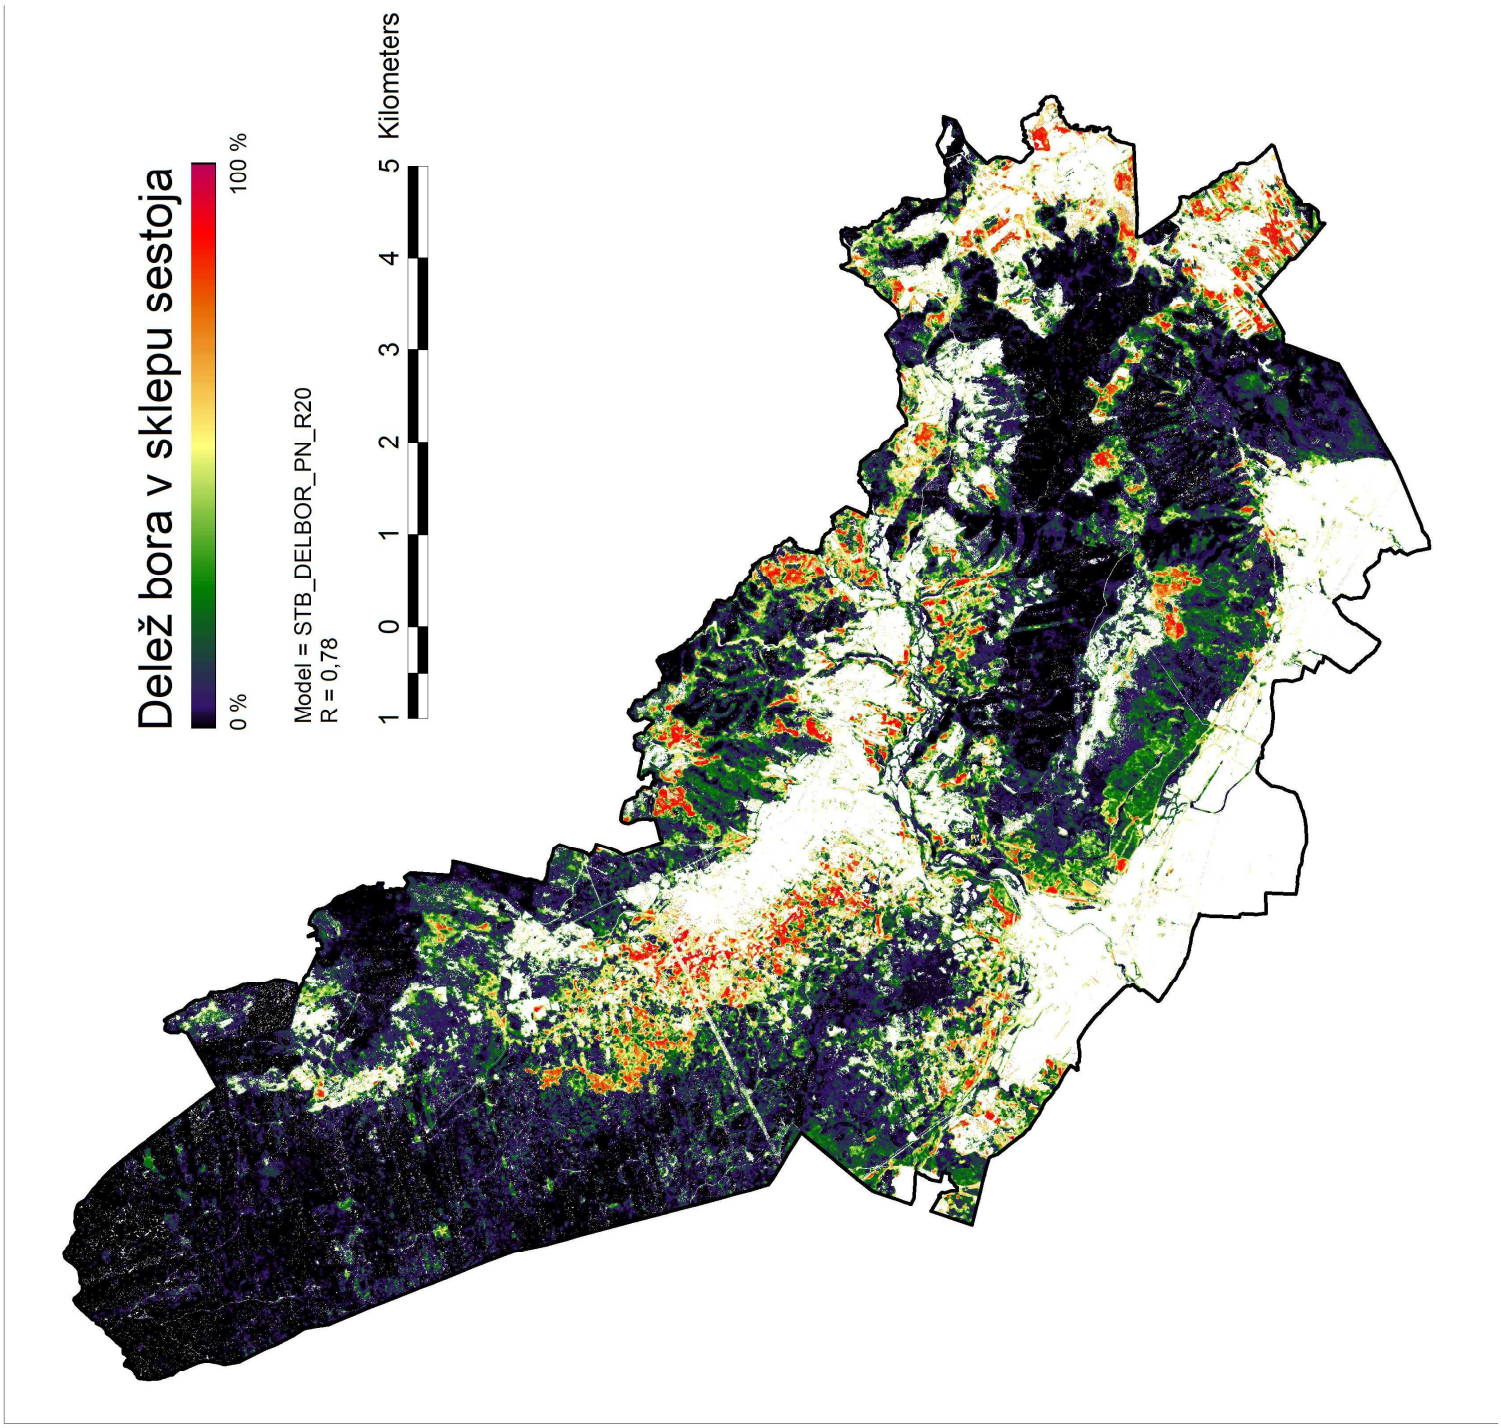
Delež bora v sklepu sestoja
0 %
100 %
Model = STB_DELBOR_PN_R20
R = 0,78
1 0 1 2 3 4 5 Kilometers

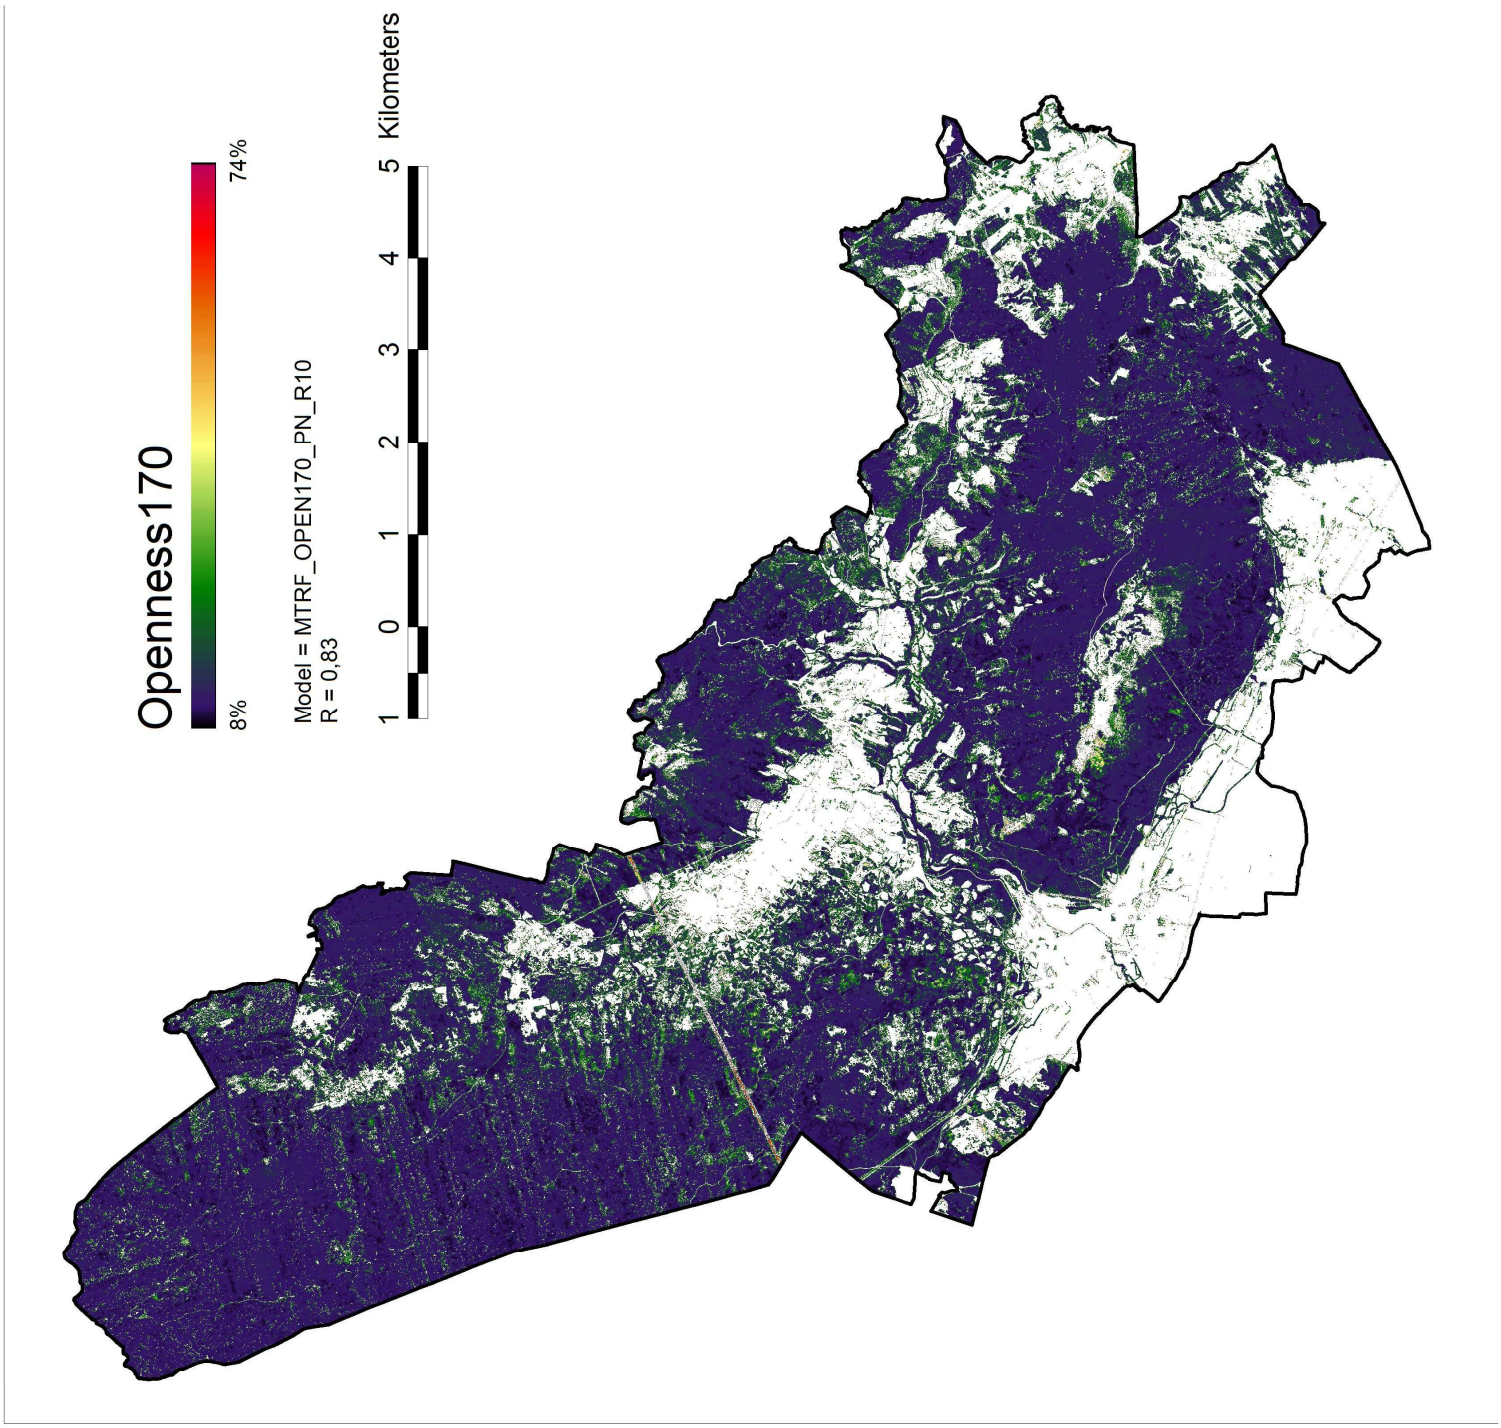
Openness170
74%
8%
Model = MTRF_OPEN170_PN_R10
R = 0,83
1 0 1 2 3 4 5 Kilometers

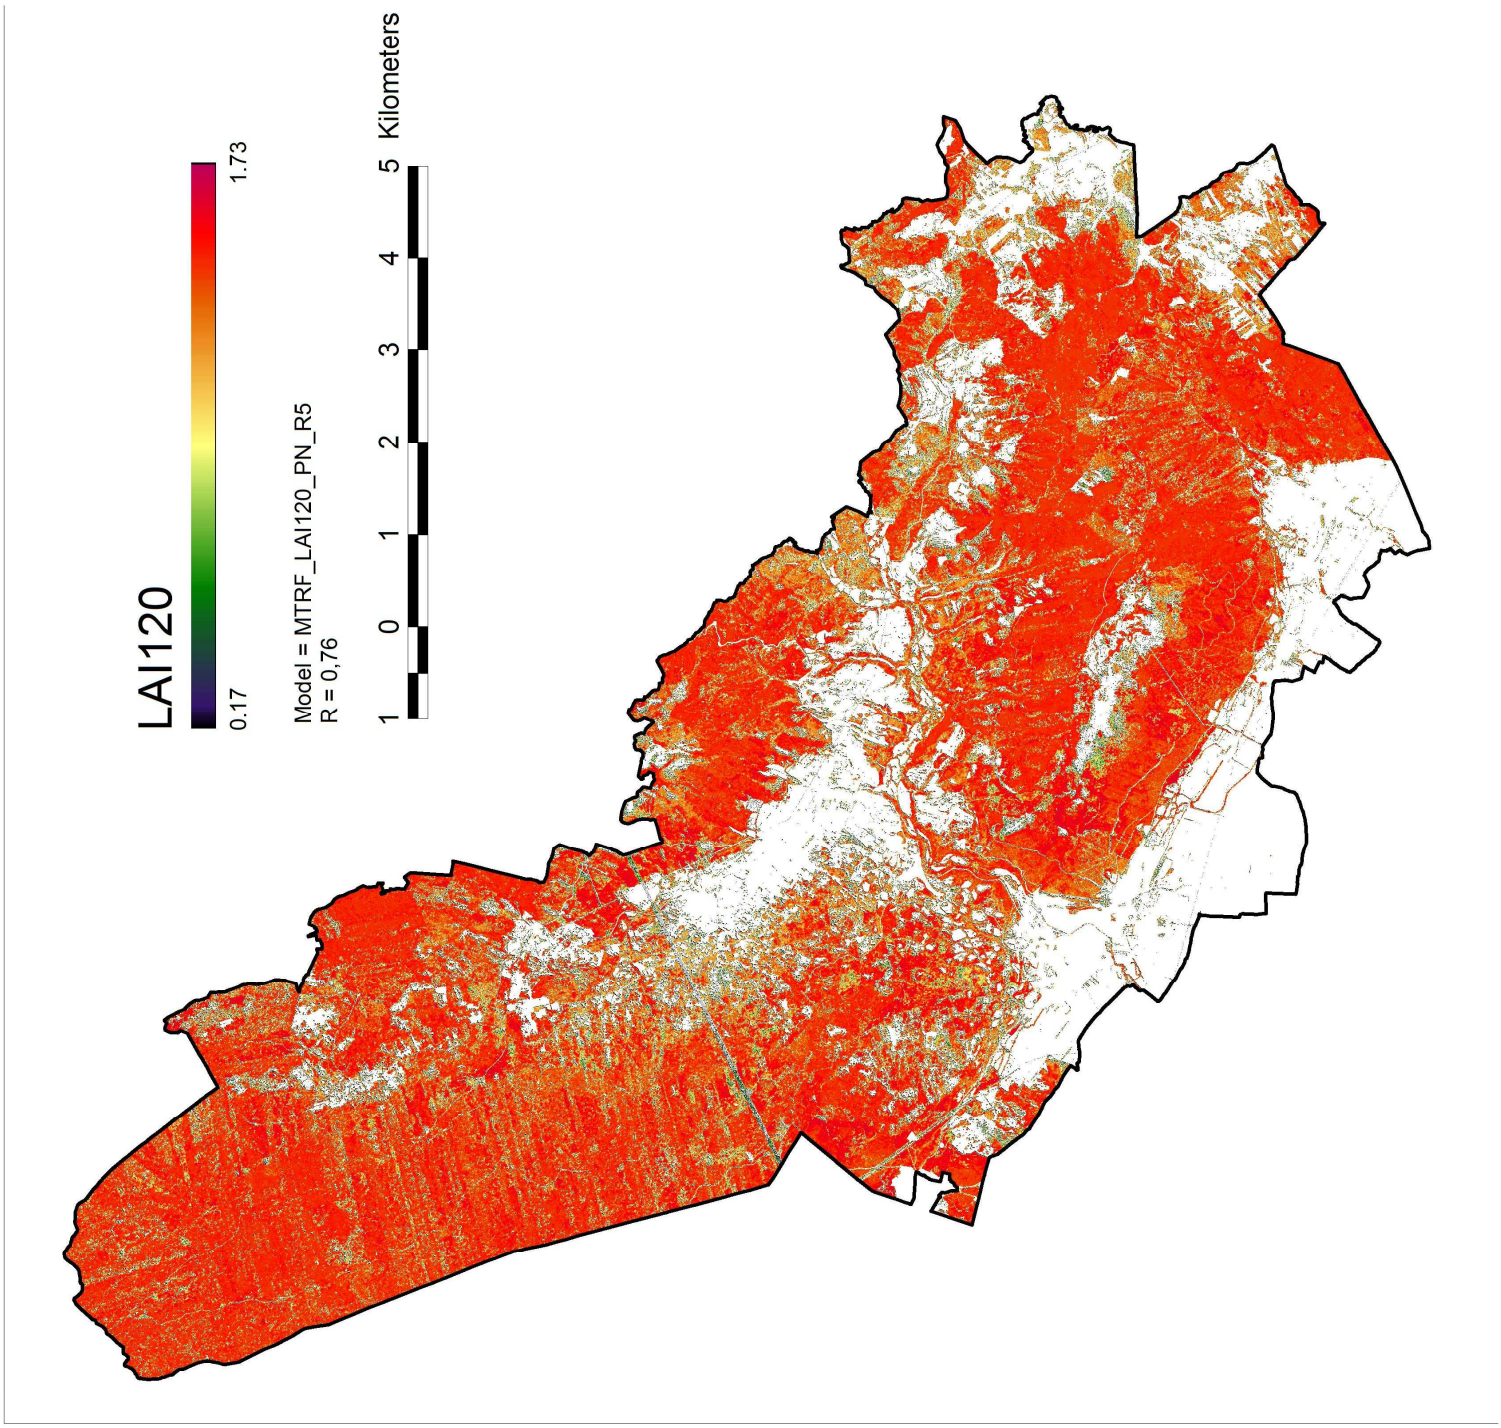
LAI120
1.73
0.17
Model = MTRF_LAI120_PN_R5
R = 0,76
1 0 1 2 3 4 5 Kilometers

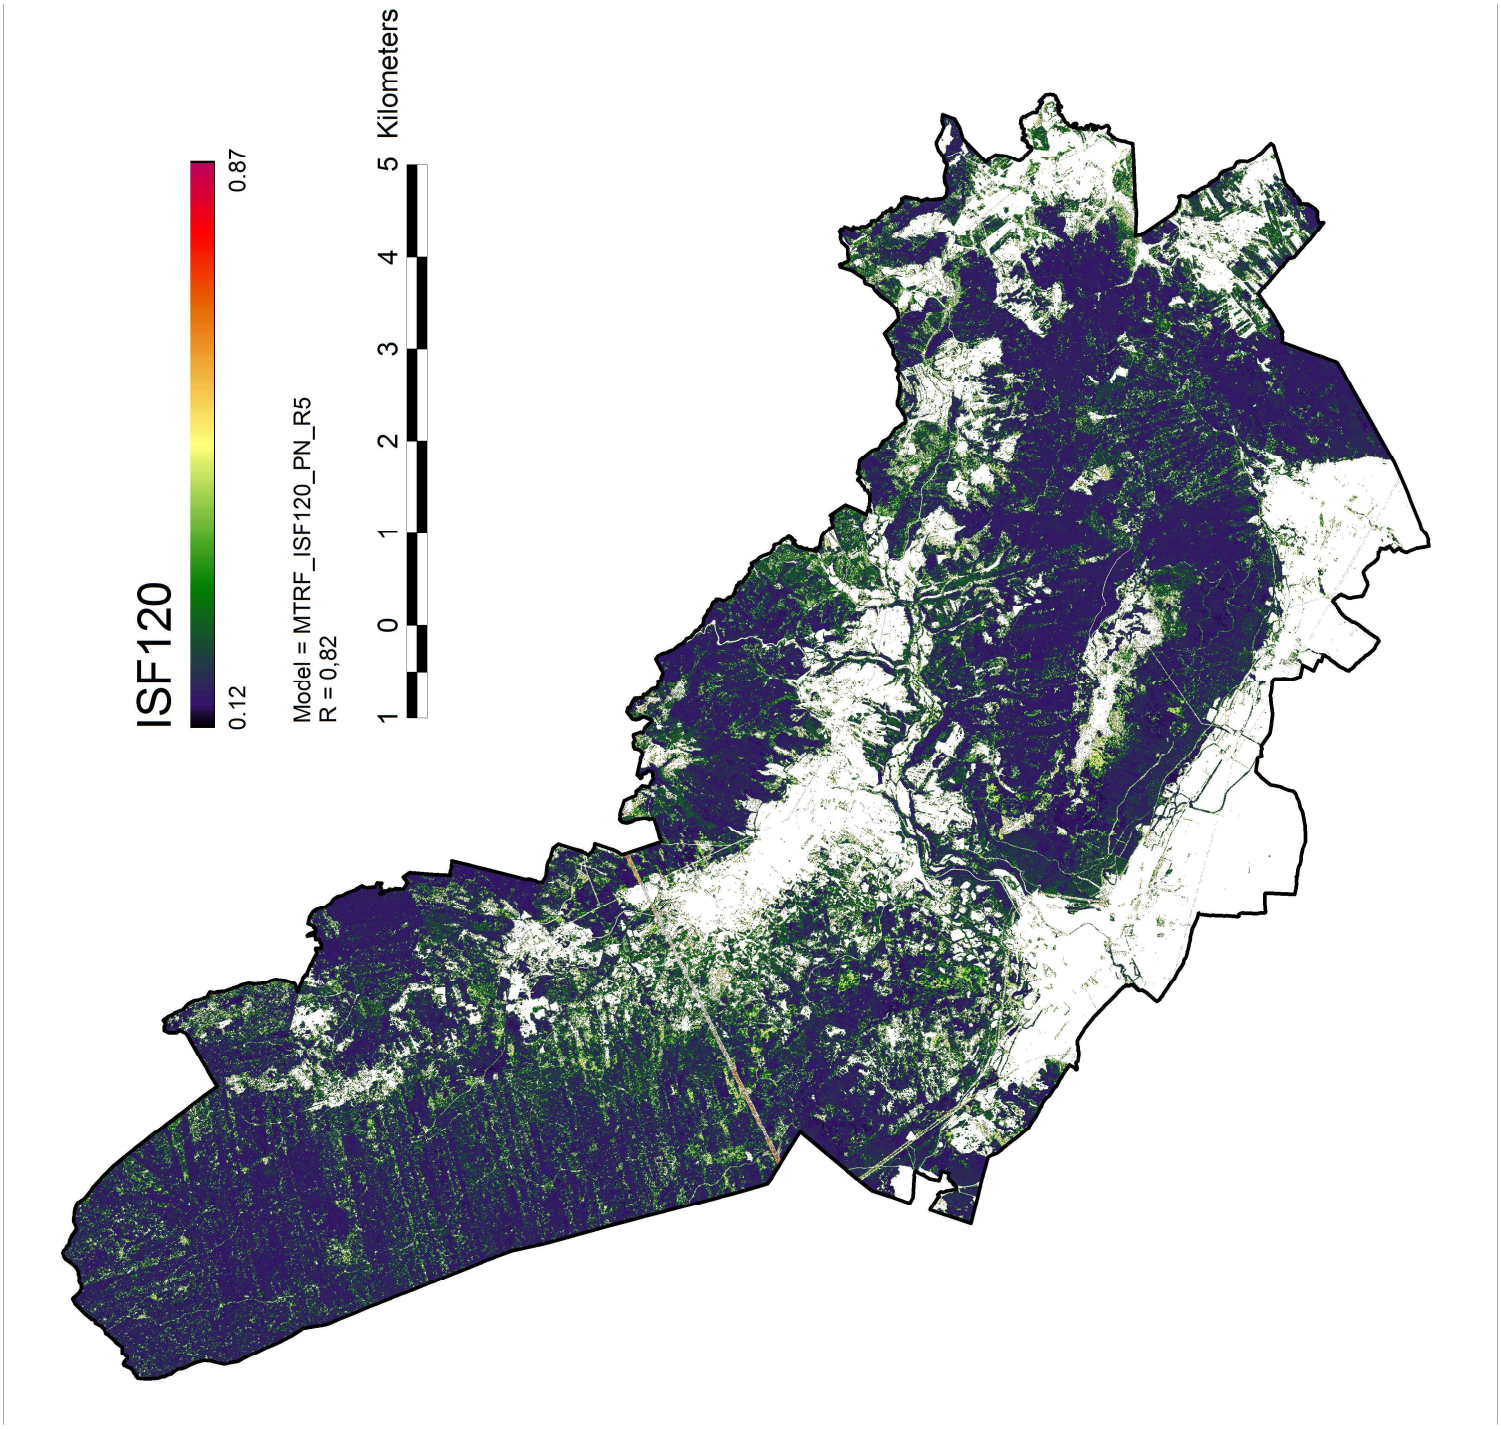
ISF120
0.87
0.12
Model = MTRF_ISF120_PN_R5
R = 0,82
1 0 1 2 3 4 5 Kilometers

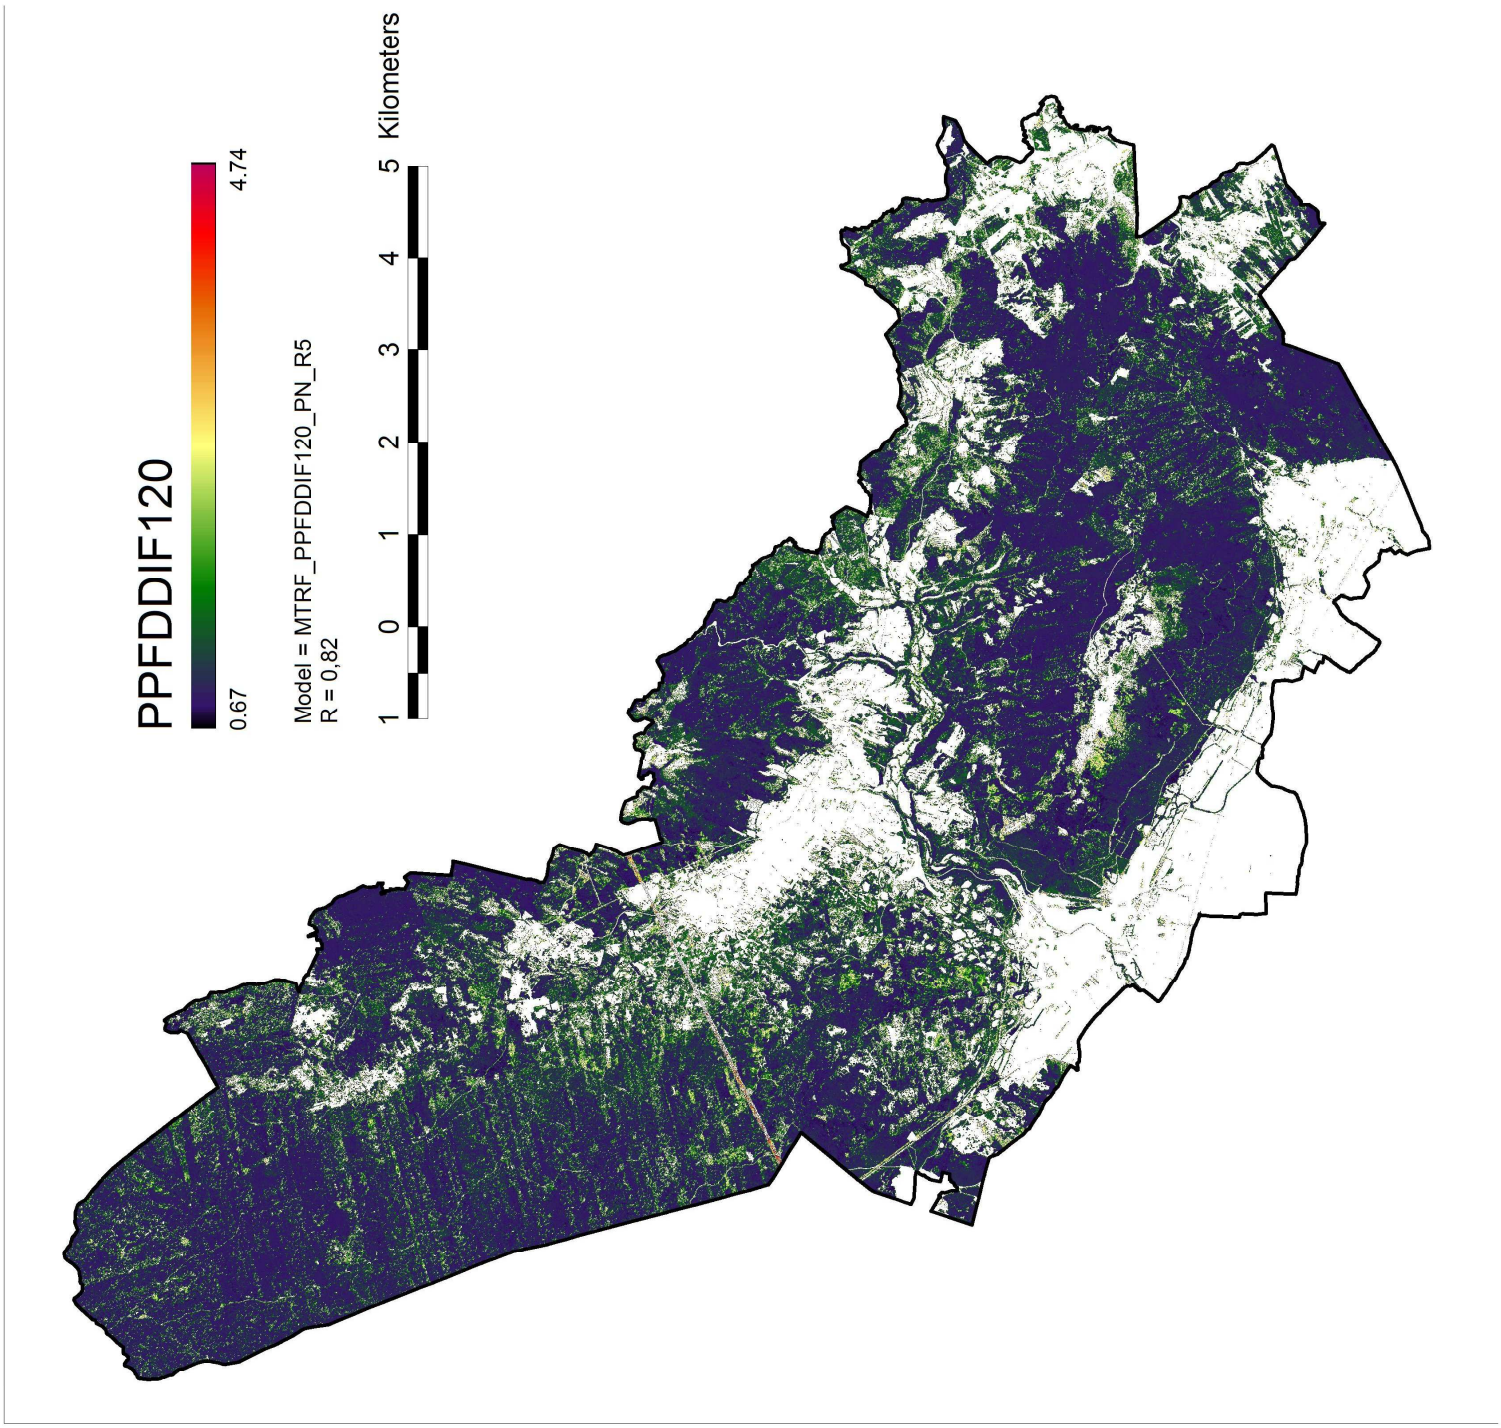
PPFDDIF120
4.74
0.67
Model = MTRF_PPFDDIF120_PN_R5
R = 0,82
1 0 1 2 3 4 5 Kilometers

PRILOGA E: Digitalni model krošenj testnega območja Slivnica

Digitalni model krošenj ima ima ločljivost 1 m. Ker format A4 ne omogoča razločevanja podrobnosti, je karta v obliki jpg slike priložena tudi na DVD.

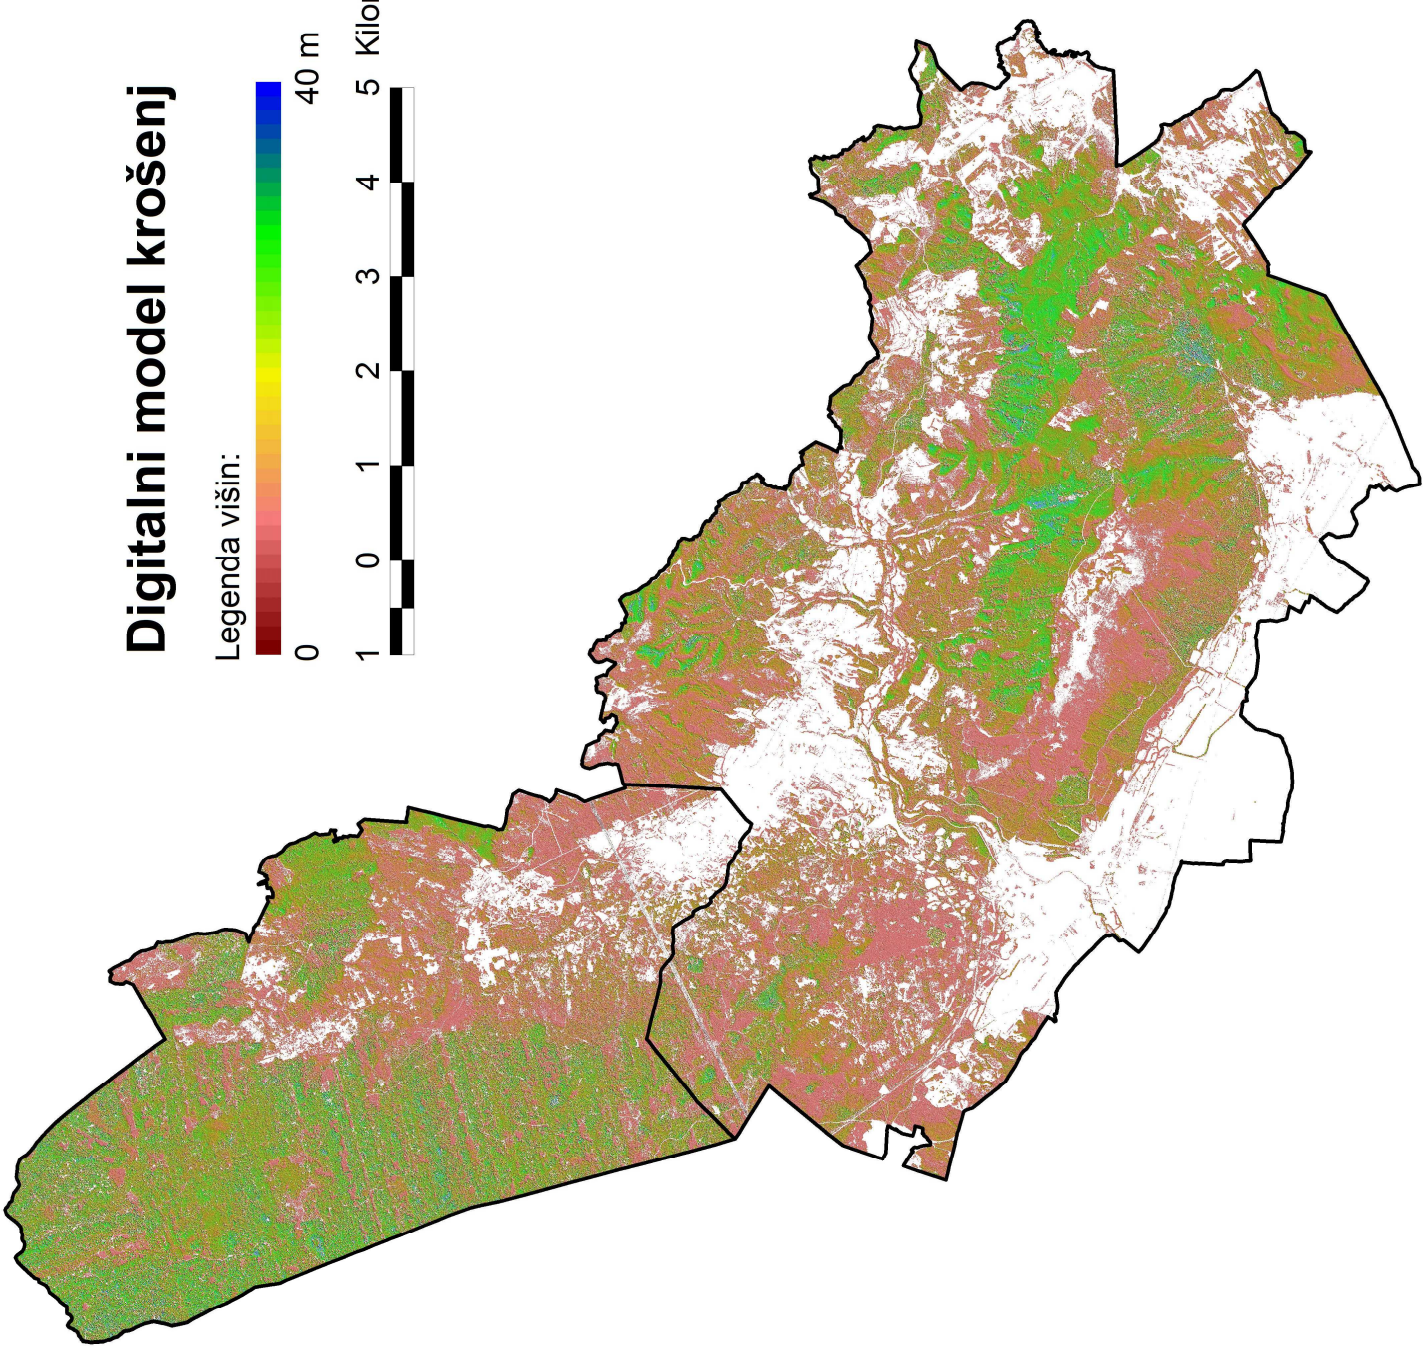
Digitalni model krošenj
Legenda višin:
40 m
0
Kilometers
5
4
3
2
1
0
1

PRILOGA F: Korelacijske tabele ciljnih in pojasnjevalnih spremenljivk

Tabele so zaradi velikosti priložene na DVD.

PRILOGA G: Korelacijske tabele pojasnjevalnih spremenljivk

Tabele so zaradi velikosti priložene na DVD.

PRILOGA H: Korelacijske tabele ciljnih spremenljivk

Tabele so zaradi velikosti priložene na DVD.

PRILOGA I: Najboljši (minimalni) rangi posamezne pojasnjevalne spremenljivke glede na skupino ciljnih spremenljivk in glede na polmer veljavnosti pojasnjevalne spremenljivke

Tabele so zaradi velikosti priložene na DVD.

PRILOGA J: Povprečni rangi posamezne pojasnjevalne spremenljivke glede na skupino ciljnih spremenljivk in glede na polmer veljavnosti pojasnjevalne spremenljivke

Tabele so zaradi velikosti priložene na DVD.

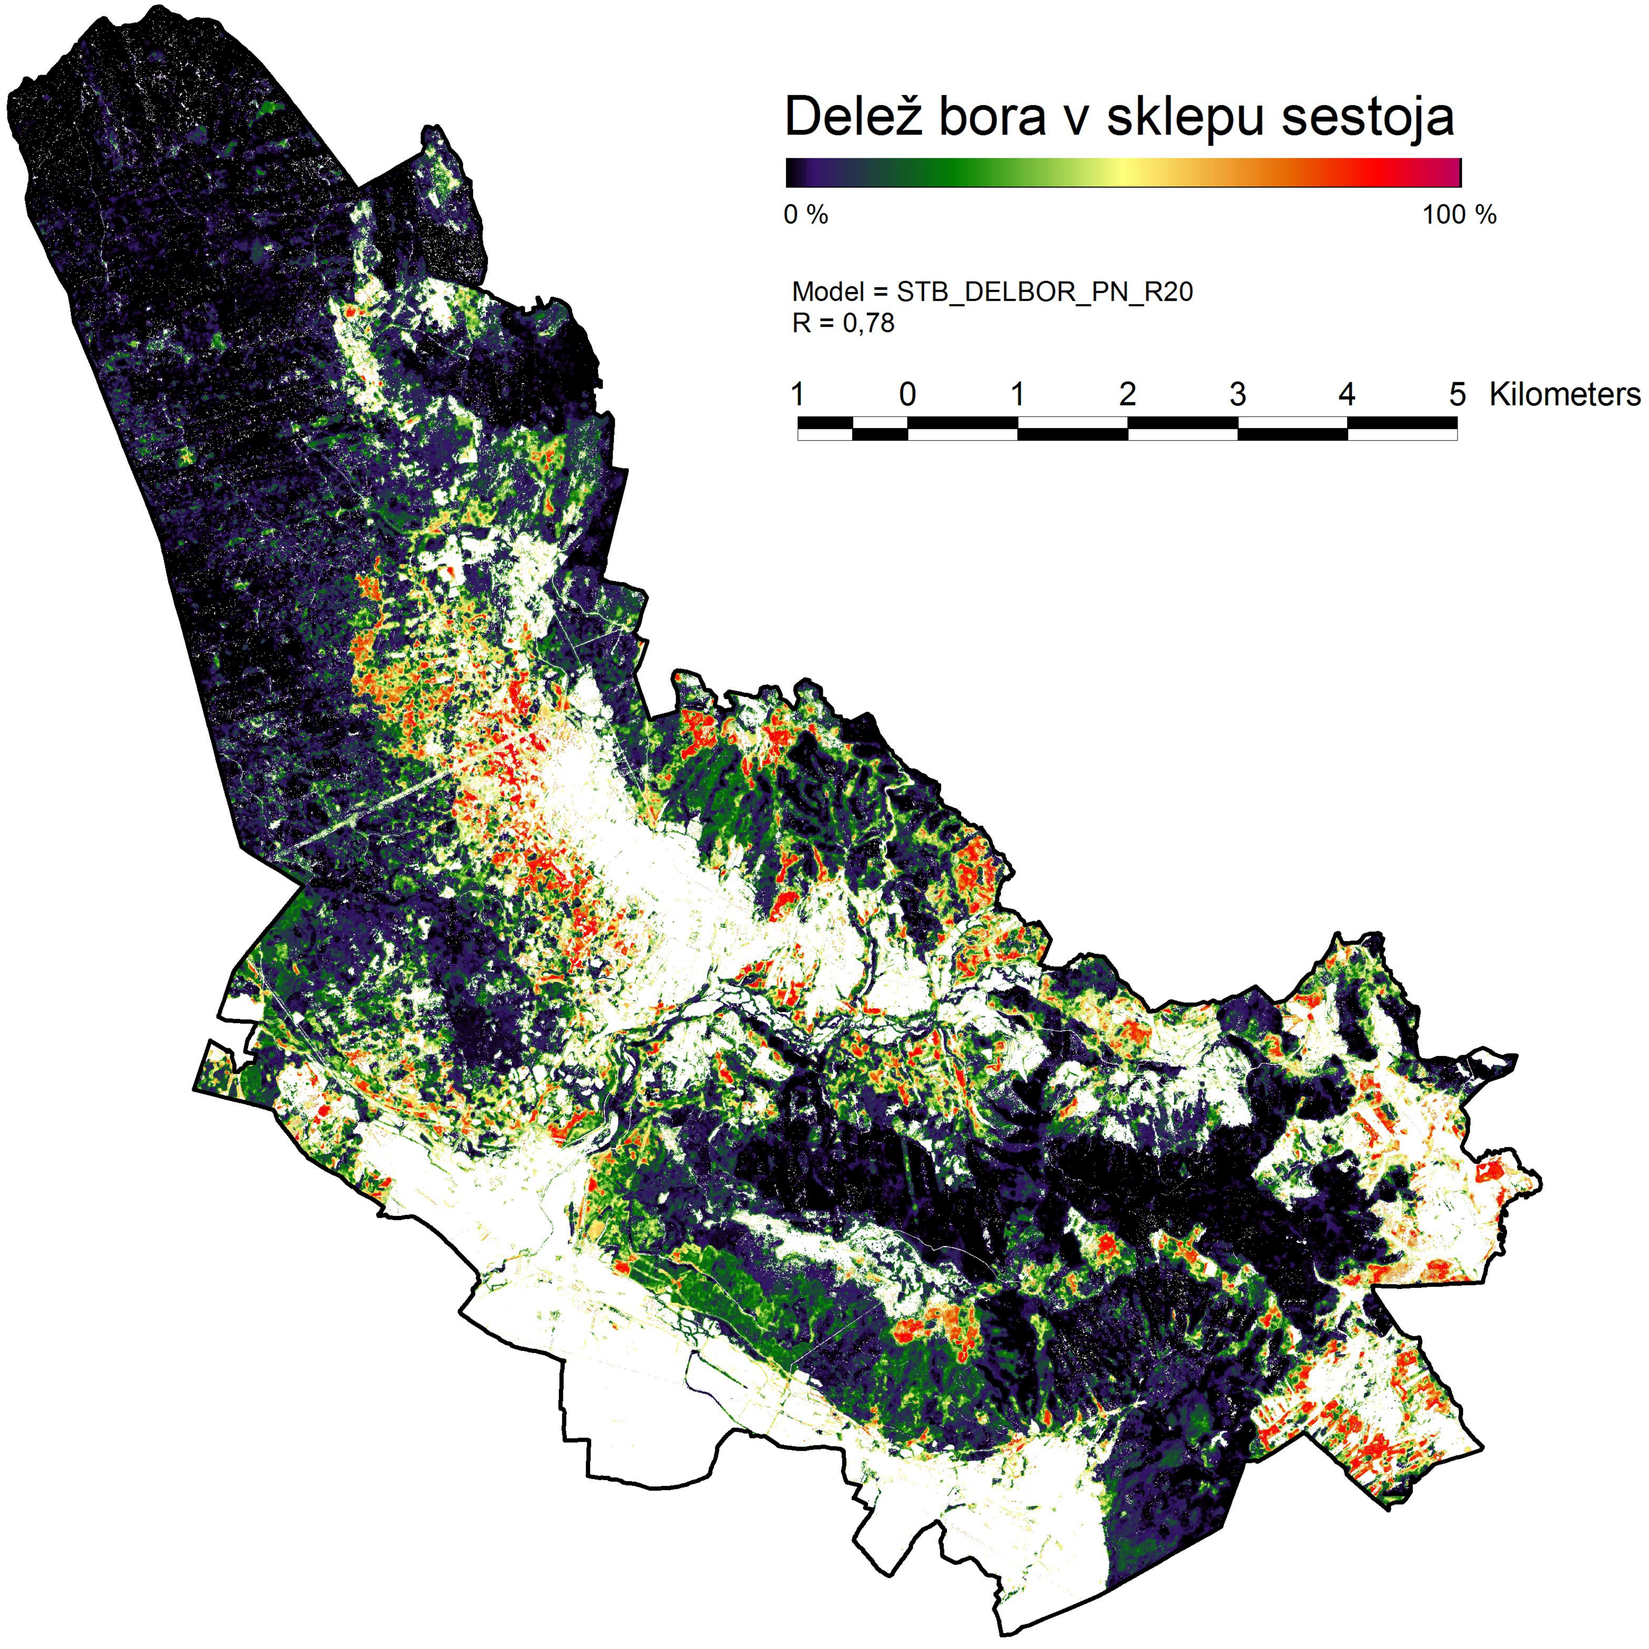
Delež bora v sklepu sestoja
0 %
100 %
Model = STB_DELBOR_PN_R20
R = 0,78
1 0 1 2 3 4 5 Kilometers

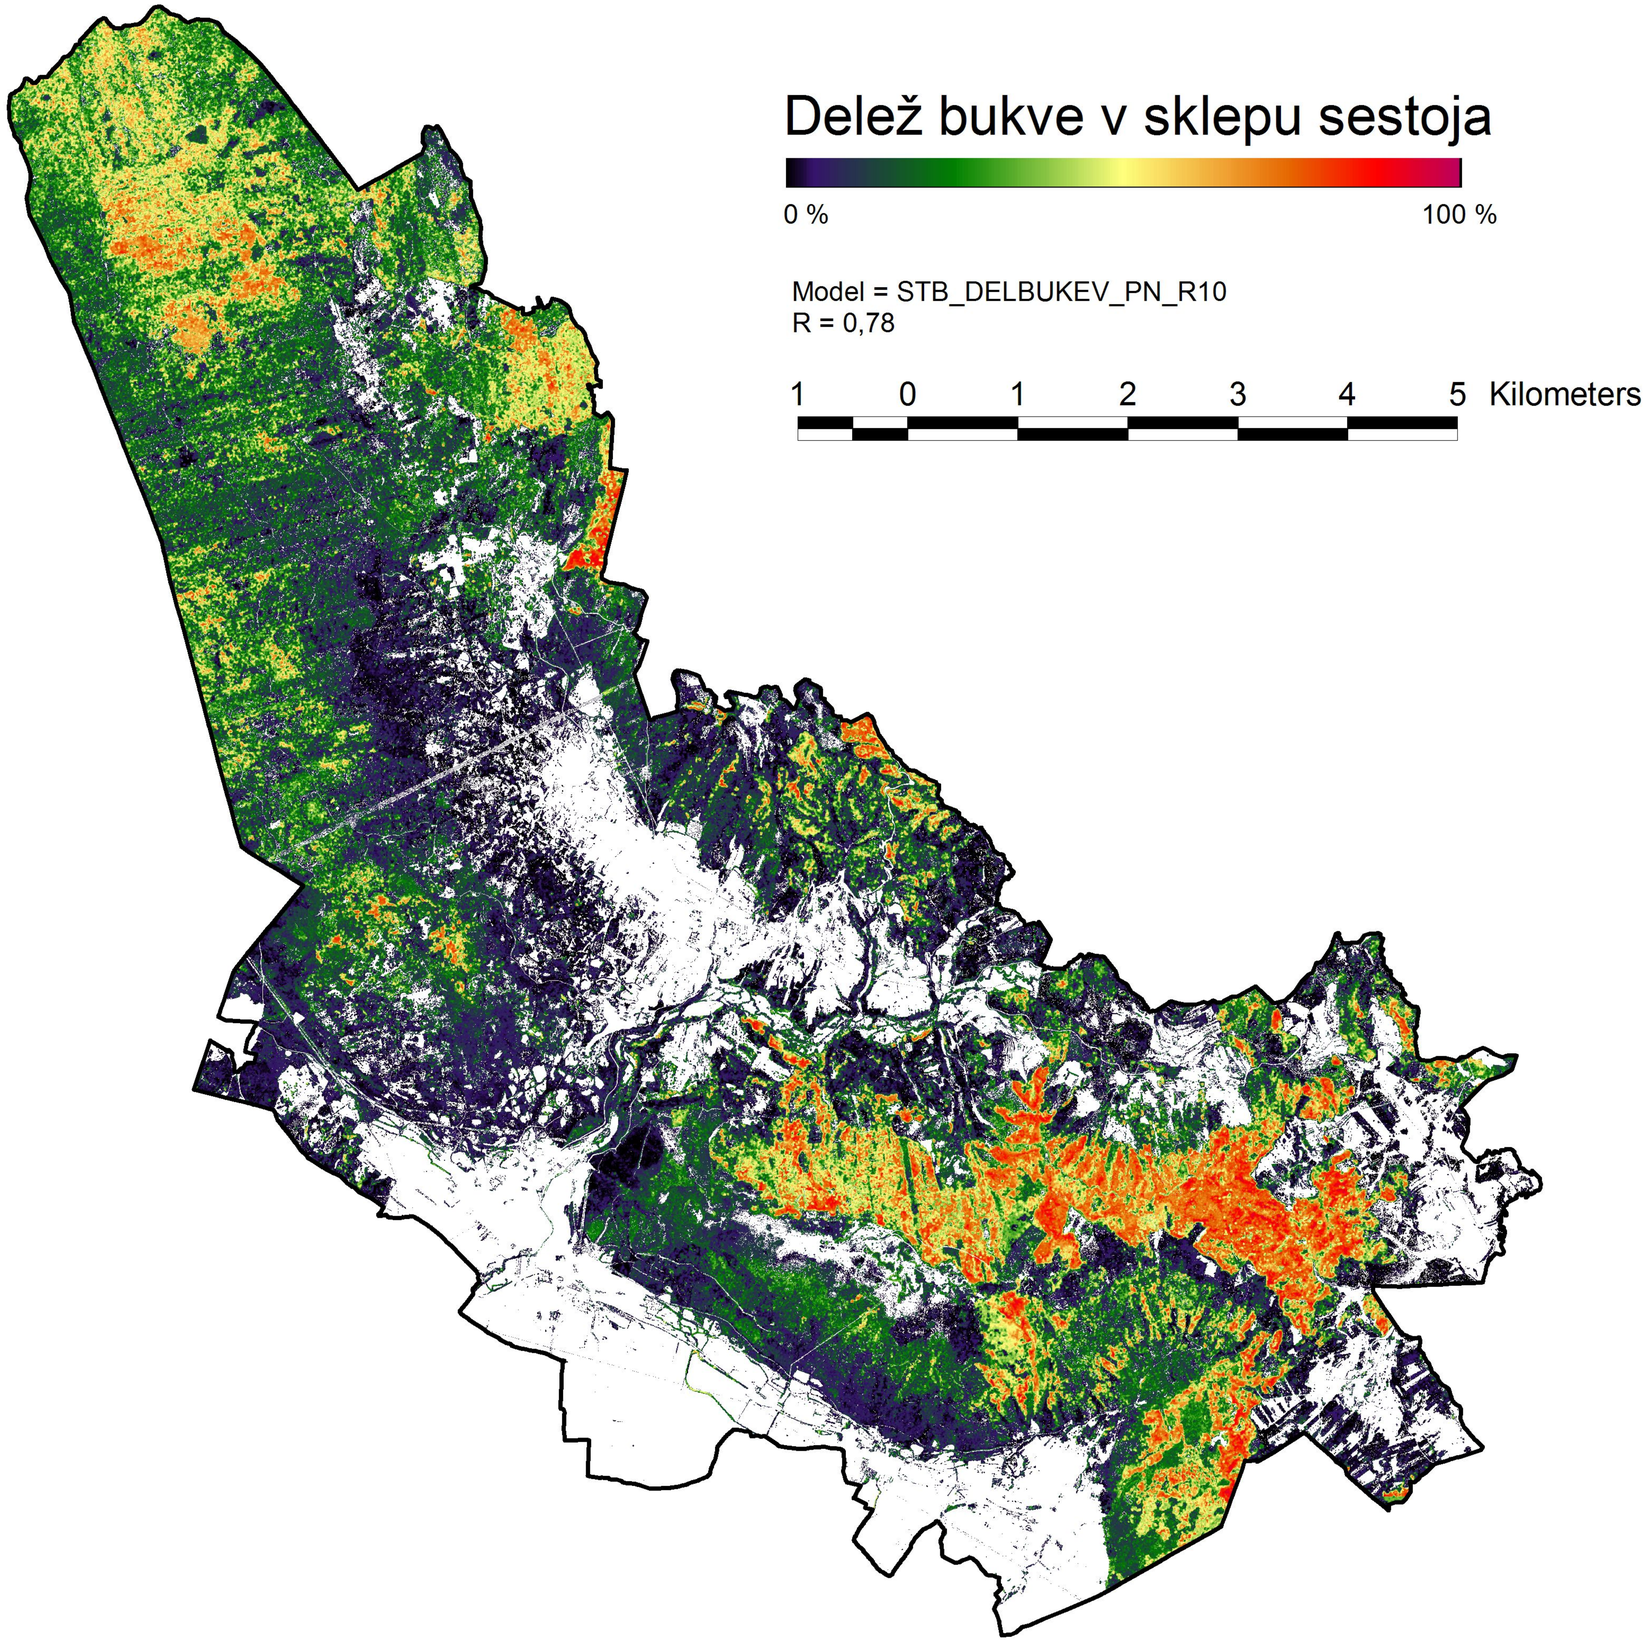
Delež bukve v sklepu sestoja
0 %
100 %
Model = STB_DELBUKEV_PN_R10
R = 0,78
1 0 1 2 3 4 5 Kilometers

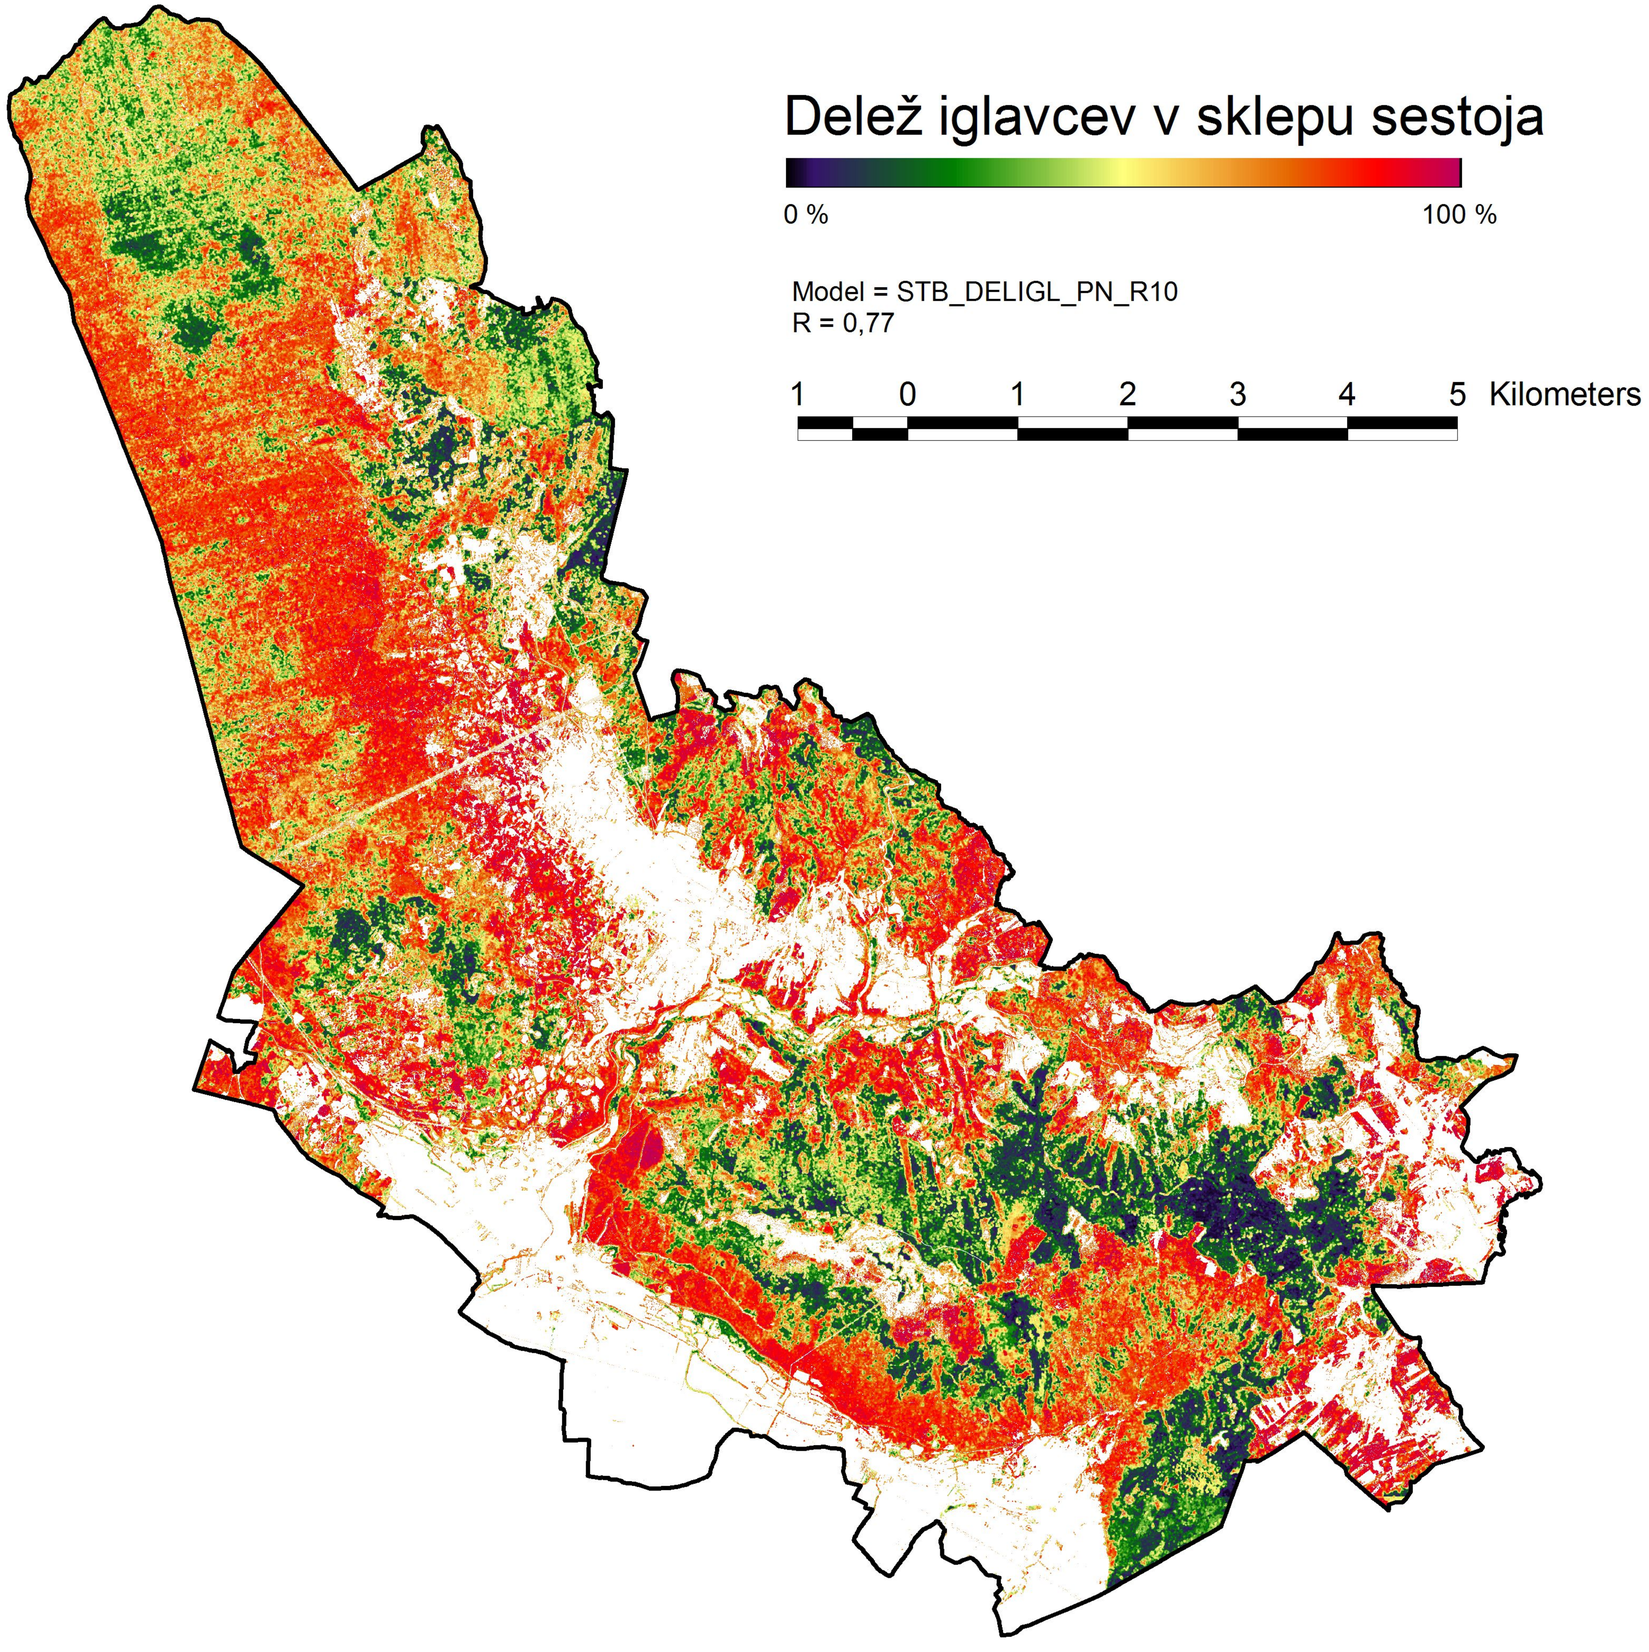
Delež iglavcev v sklepu sestoja
0 %
100 %
Model = STB_DELIGL_PN_R10
R = 0,77
1 0 1 2 3 4 5 Kilometers

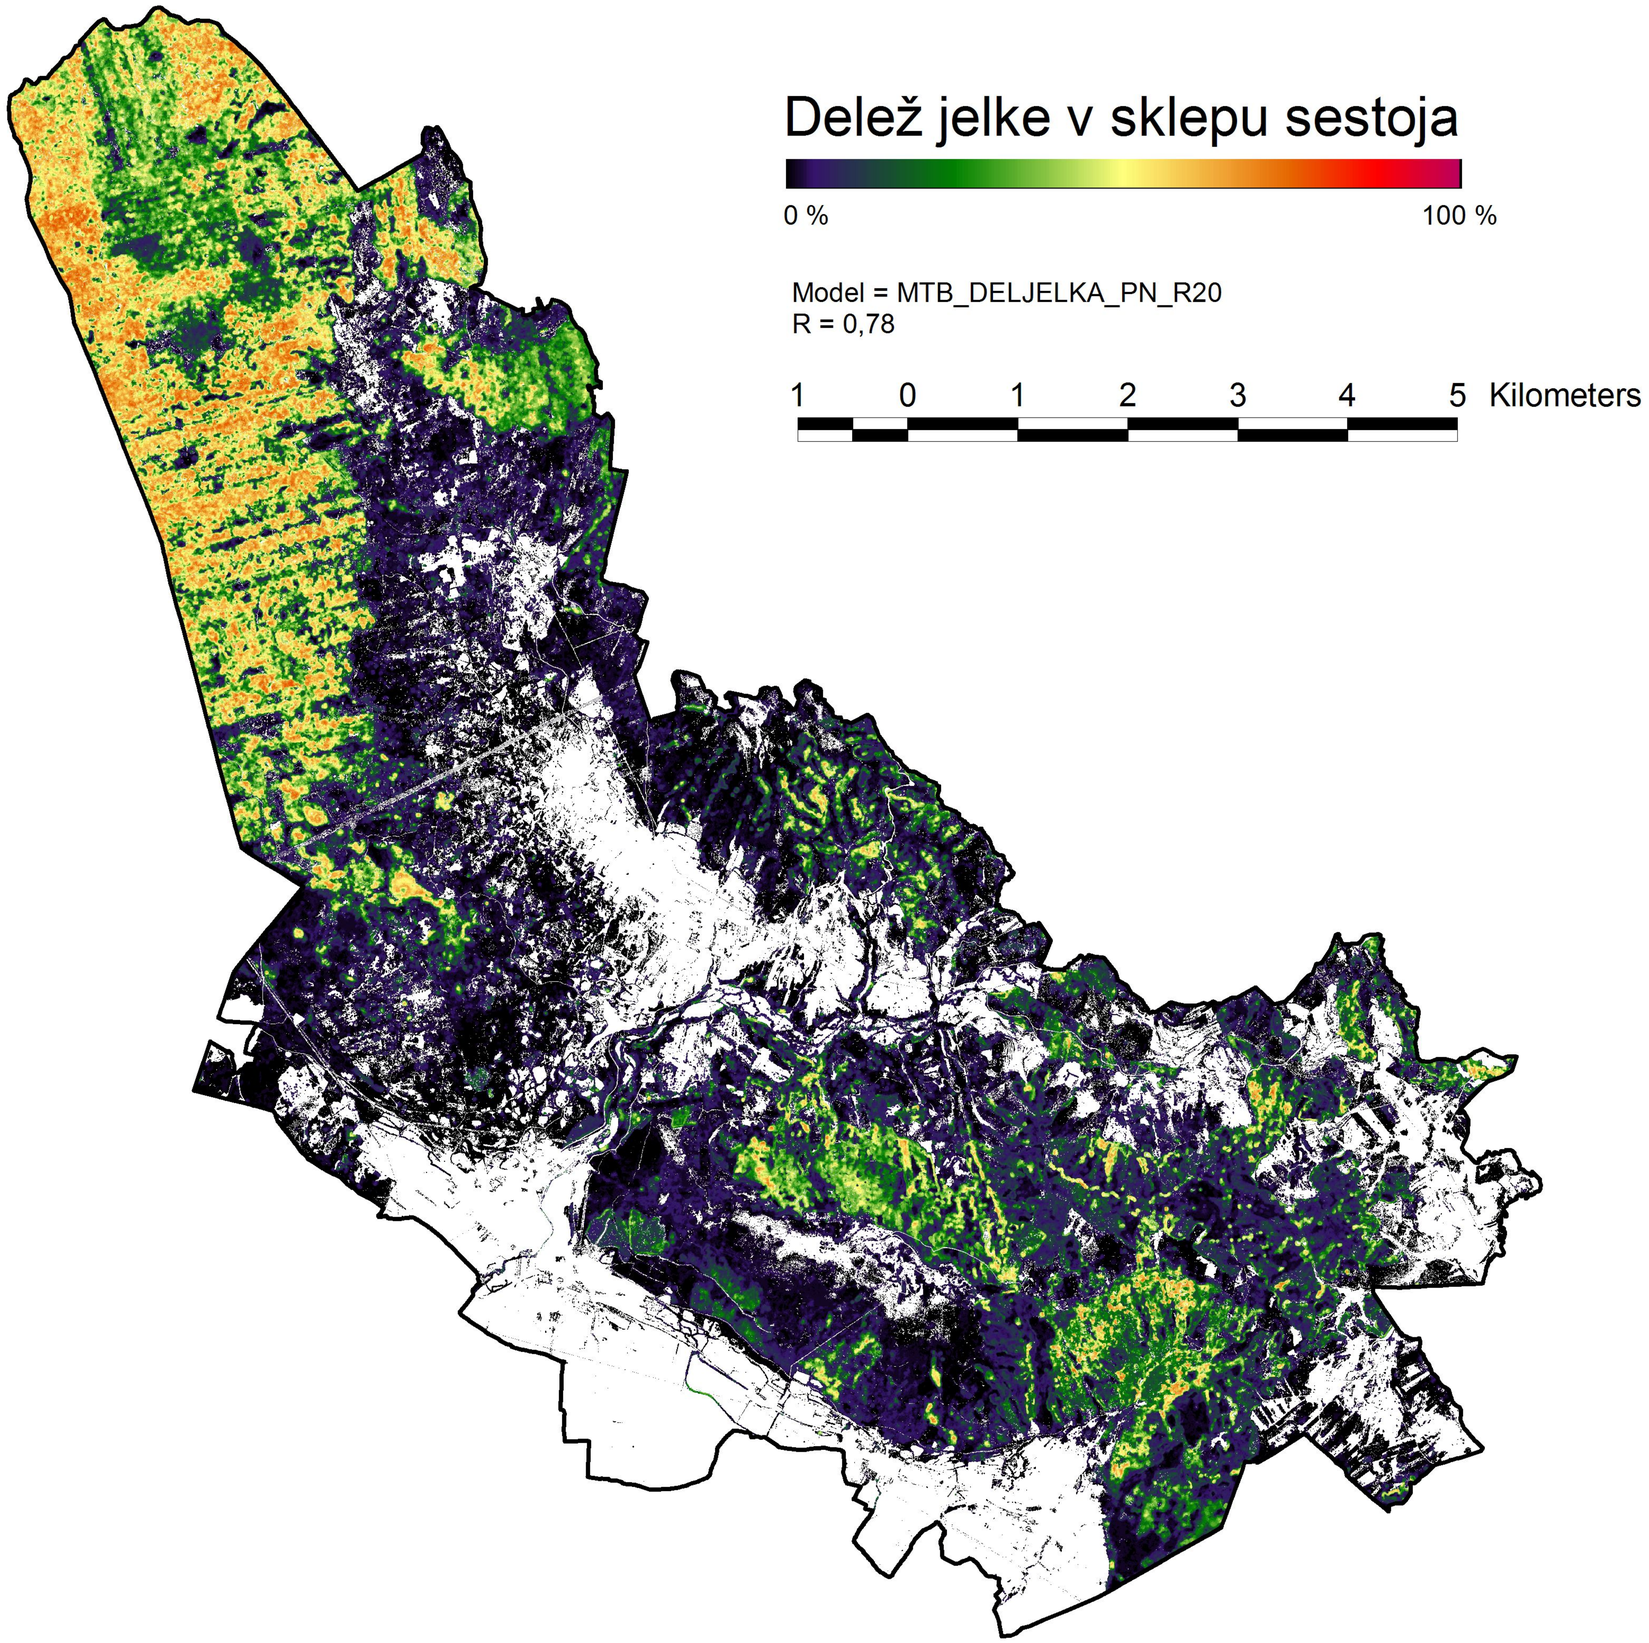
Delež jelke v sklepu sestoja
0 %
100 %
Model = MTB_DELJELKA_PN_R20
R = 0,78
1 0 1 2 3 4 5 Kilometers

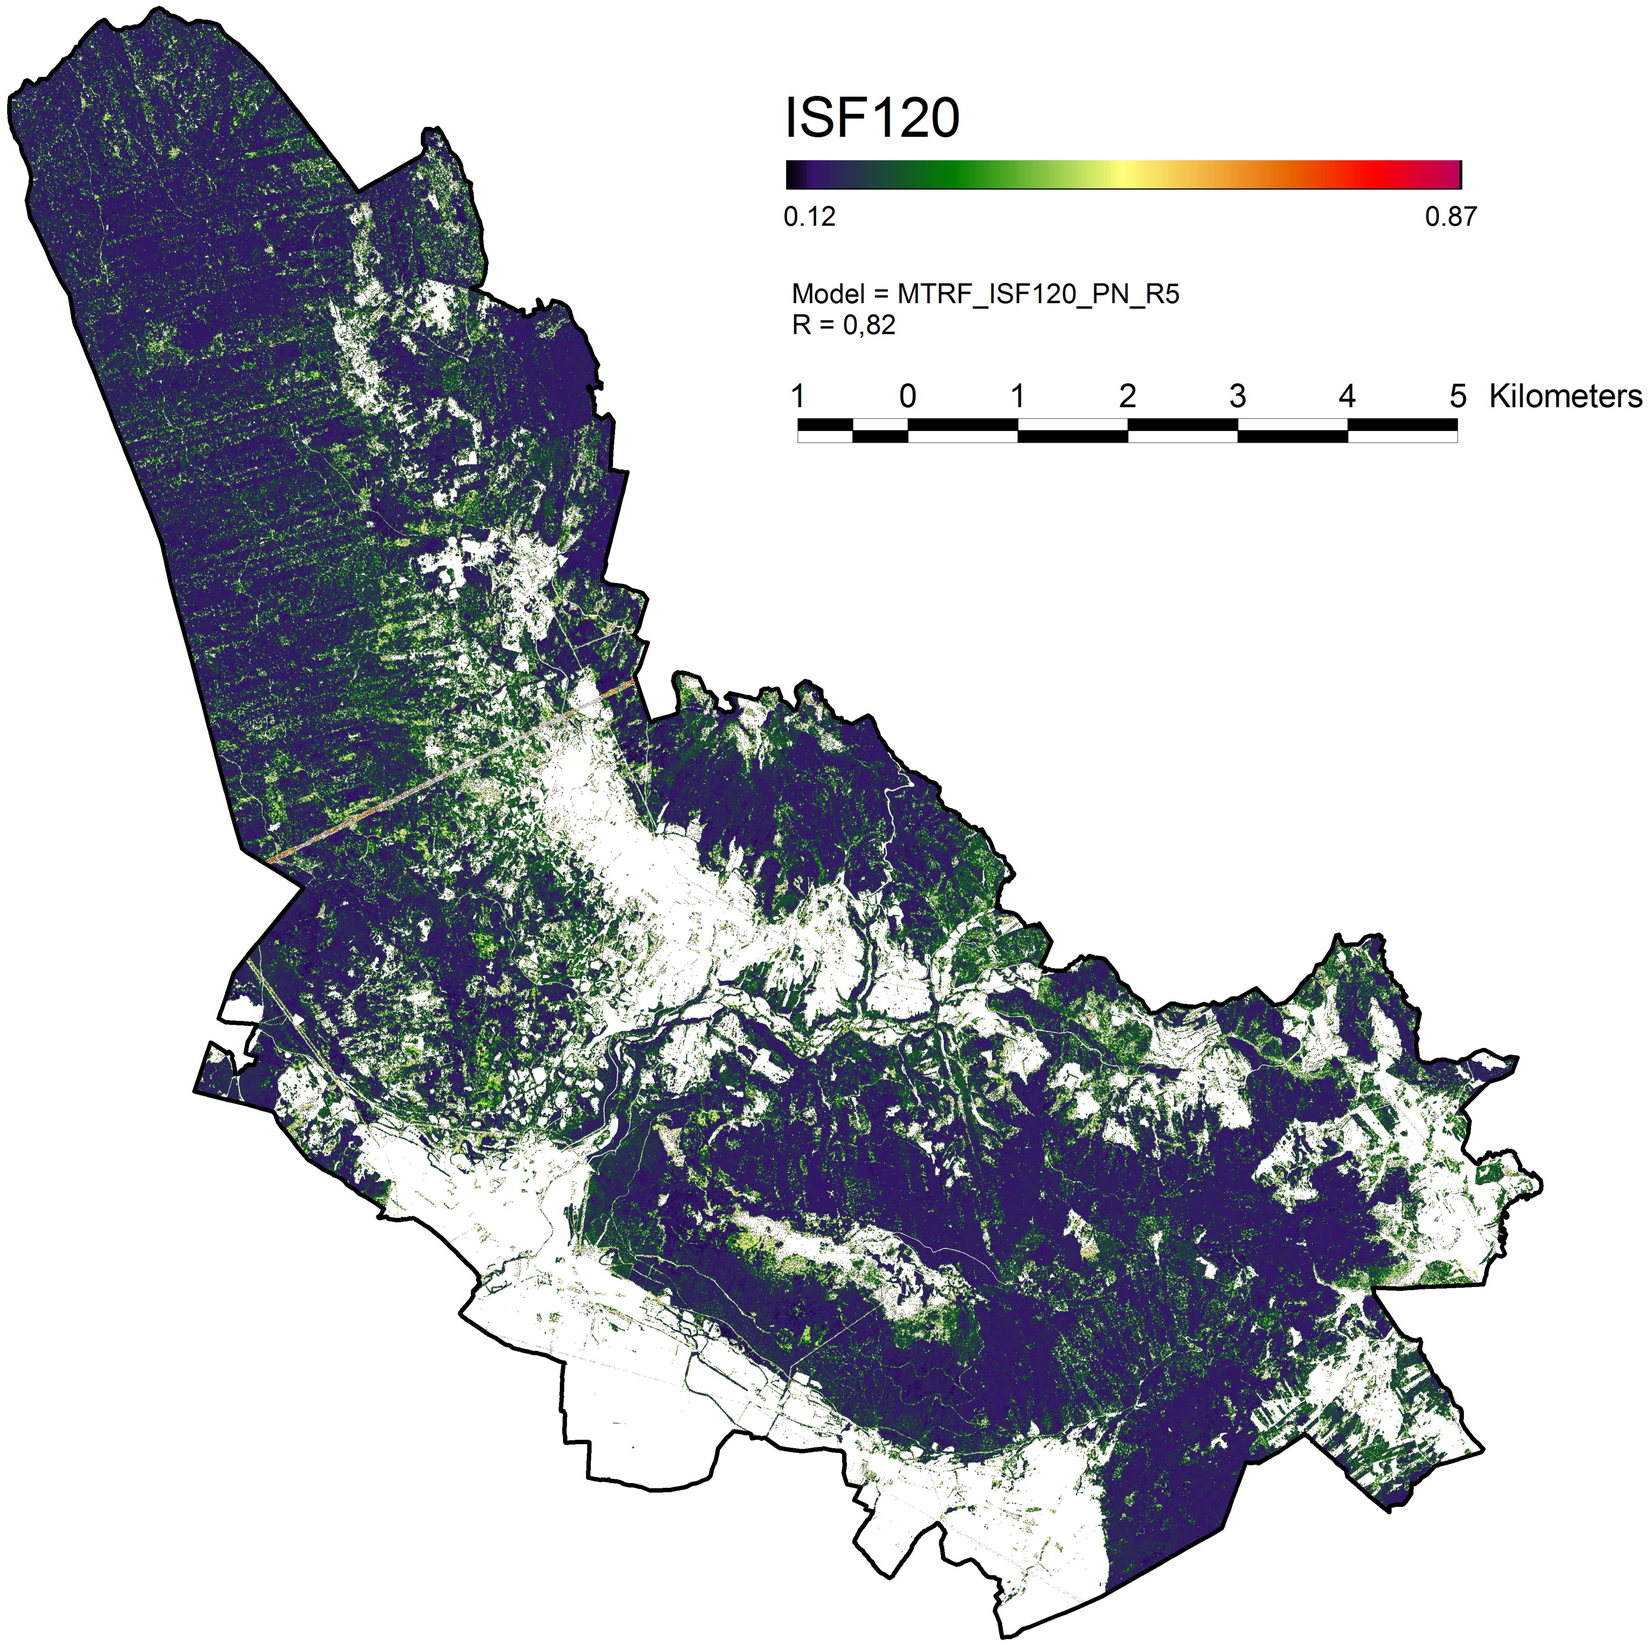
ISF120
0.12
0.87
Model = MTRF_ISF120_PN_R5
R = 0,82
1 0 1 2 3 4 5 Kilometers

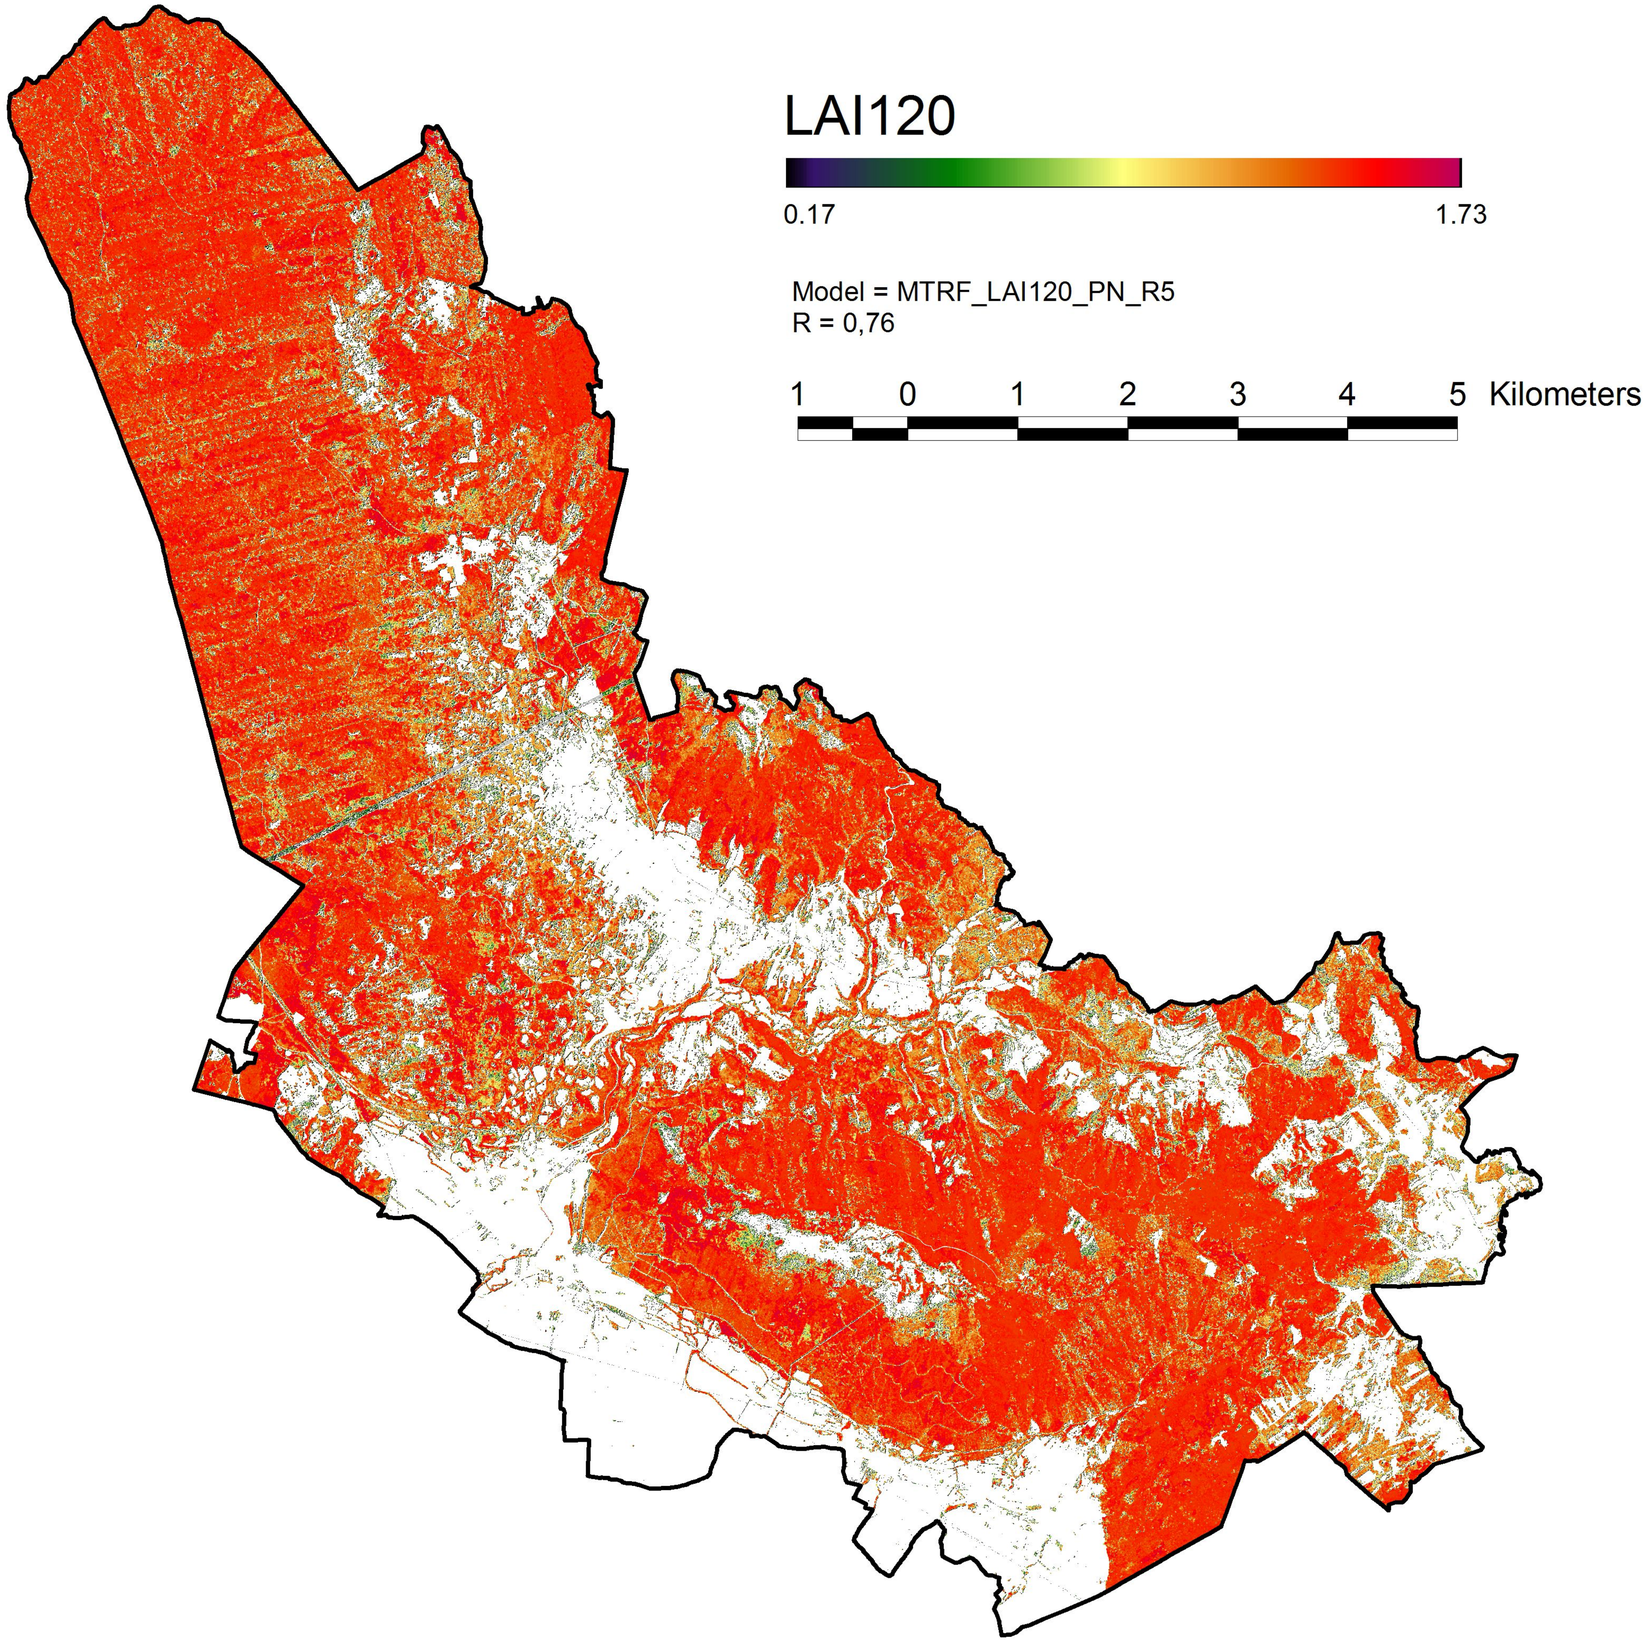
LAI120
0.17
1.73
Model = MTRF_LAI120_PN_R5
R = 0,76
1 0 1 2 3 4 5 Kilometers

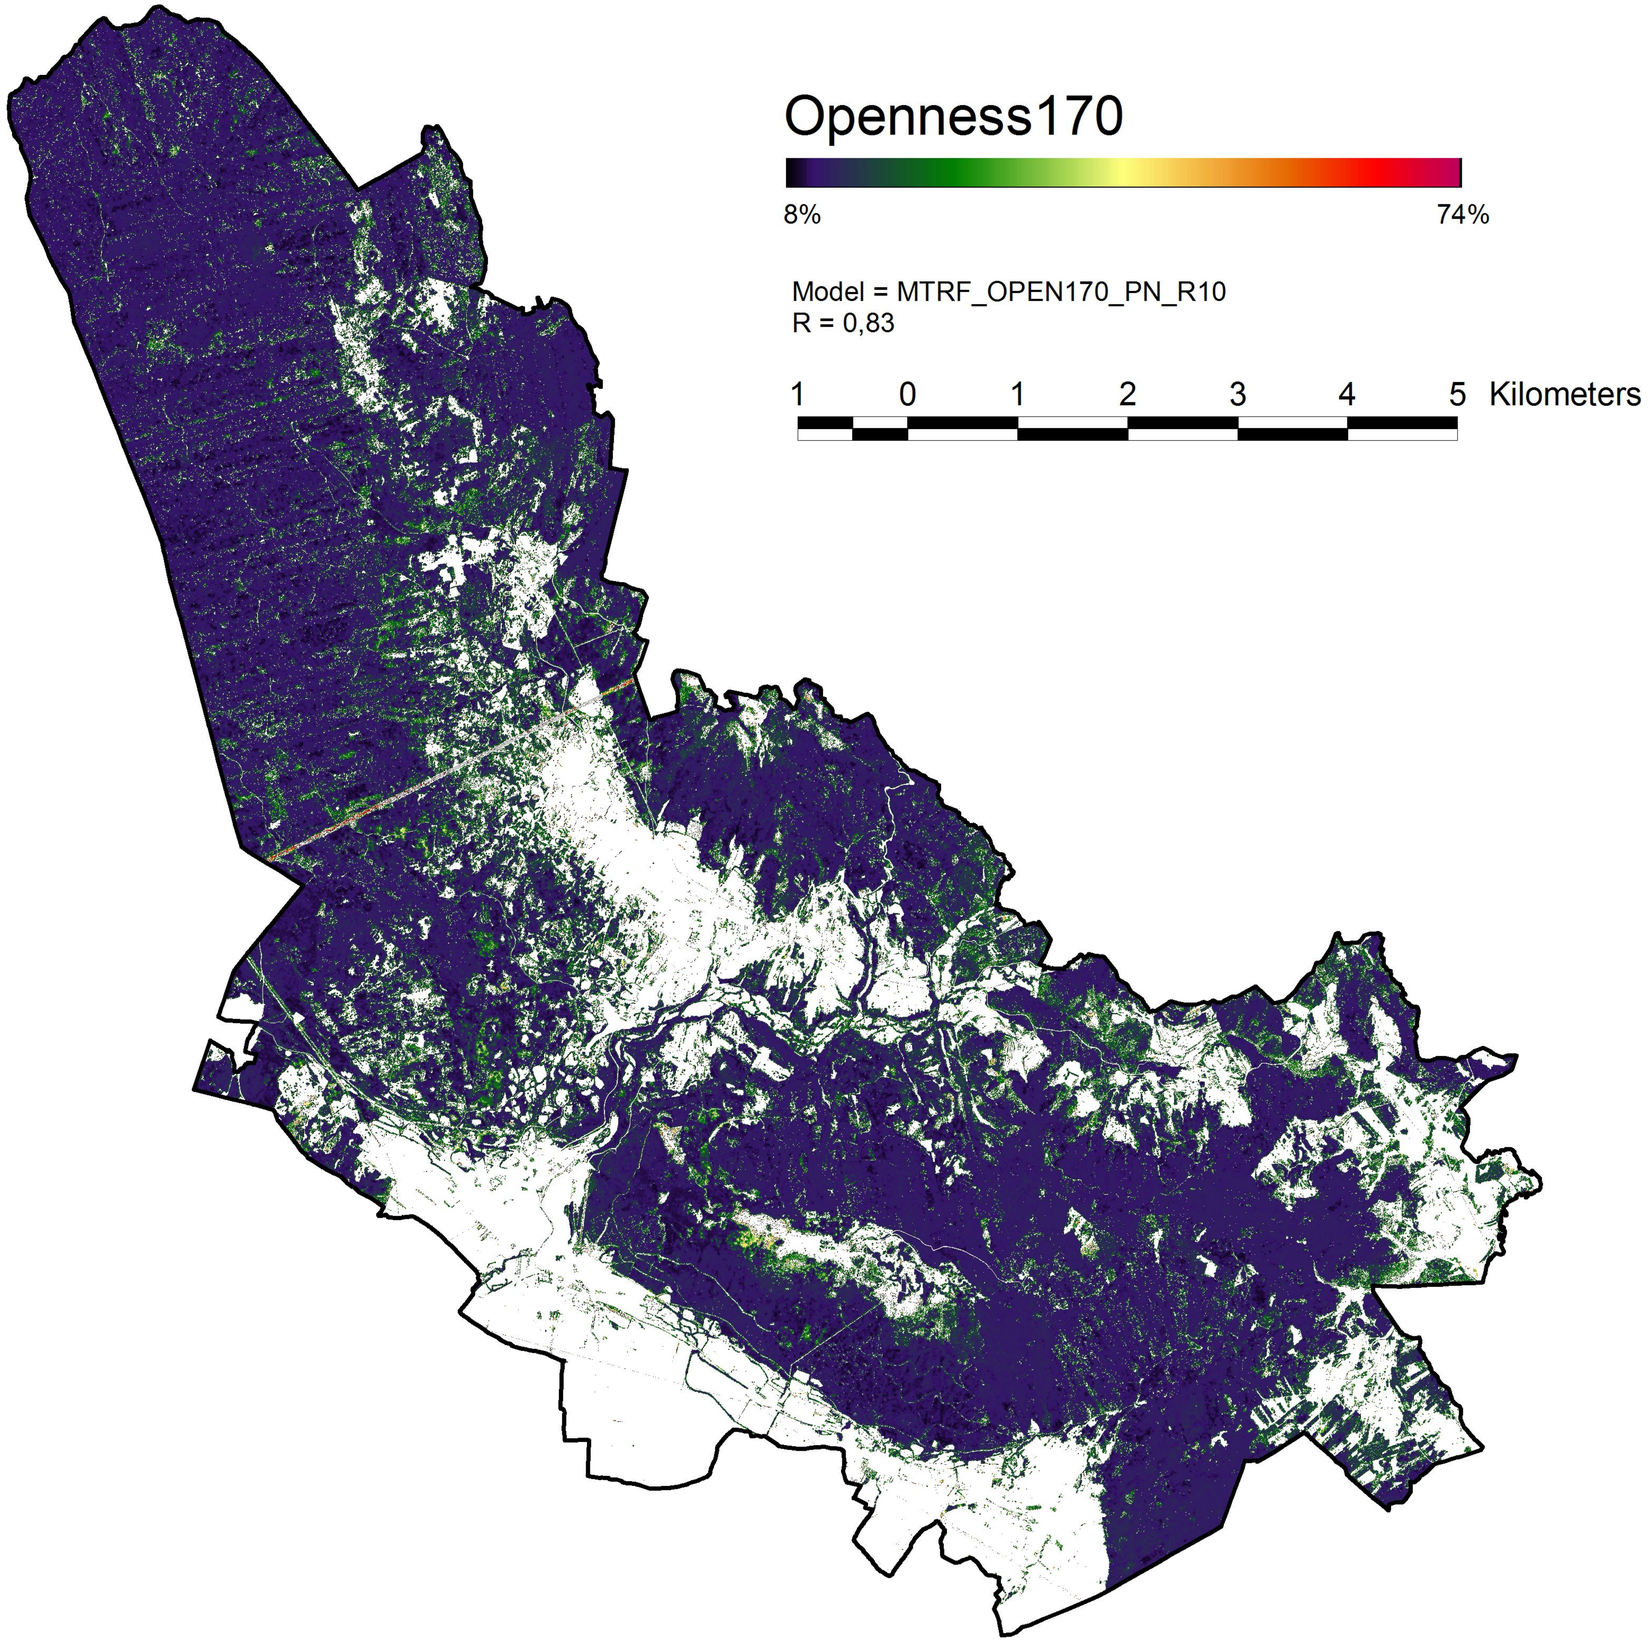
Openness170
8%
74%
Model = MTRF_OPEN170_PN_R10
R = 0,83
1 0 1 2 3 4 5 Kilometers

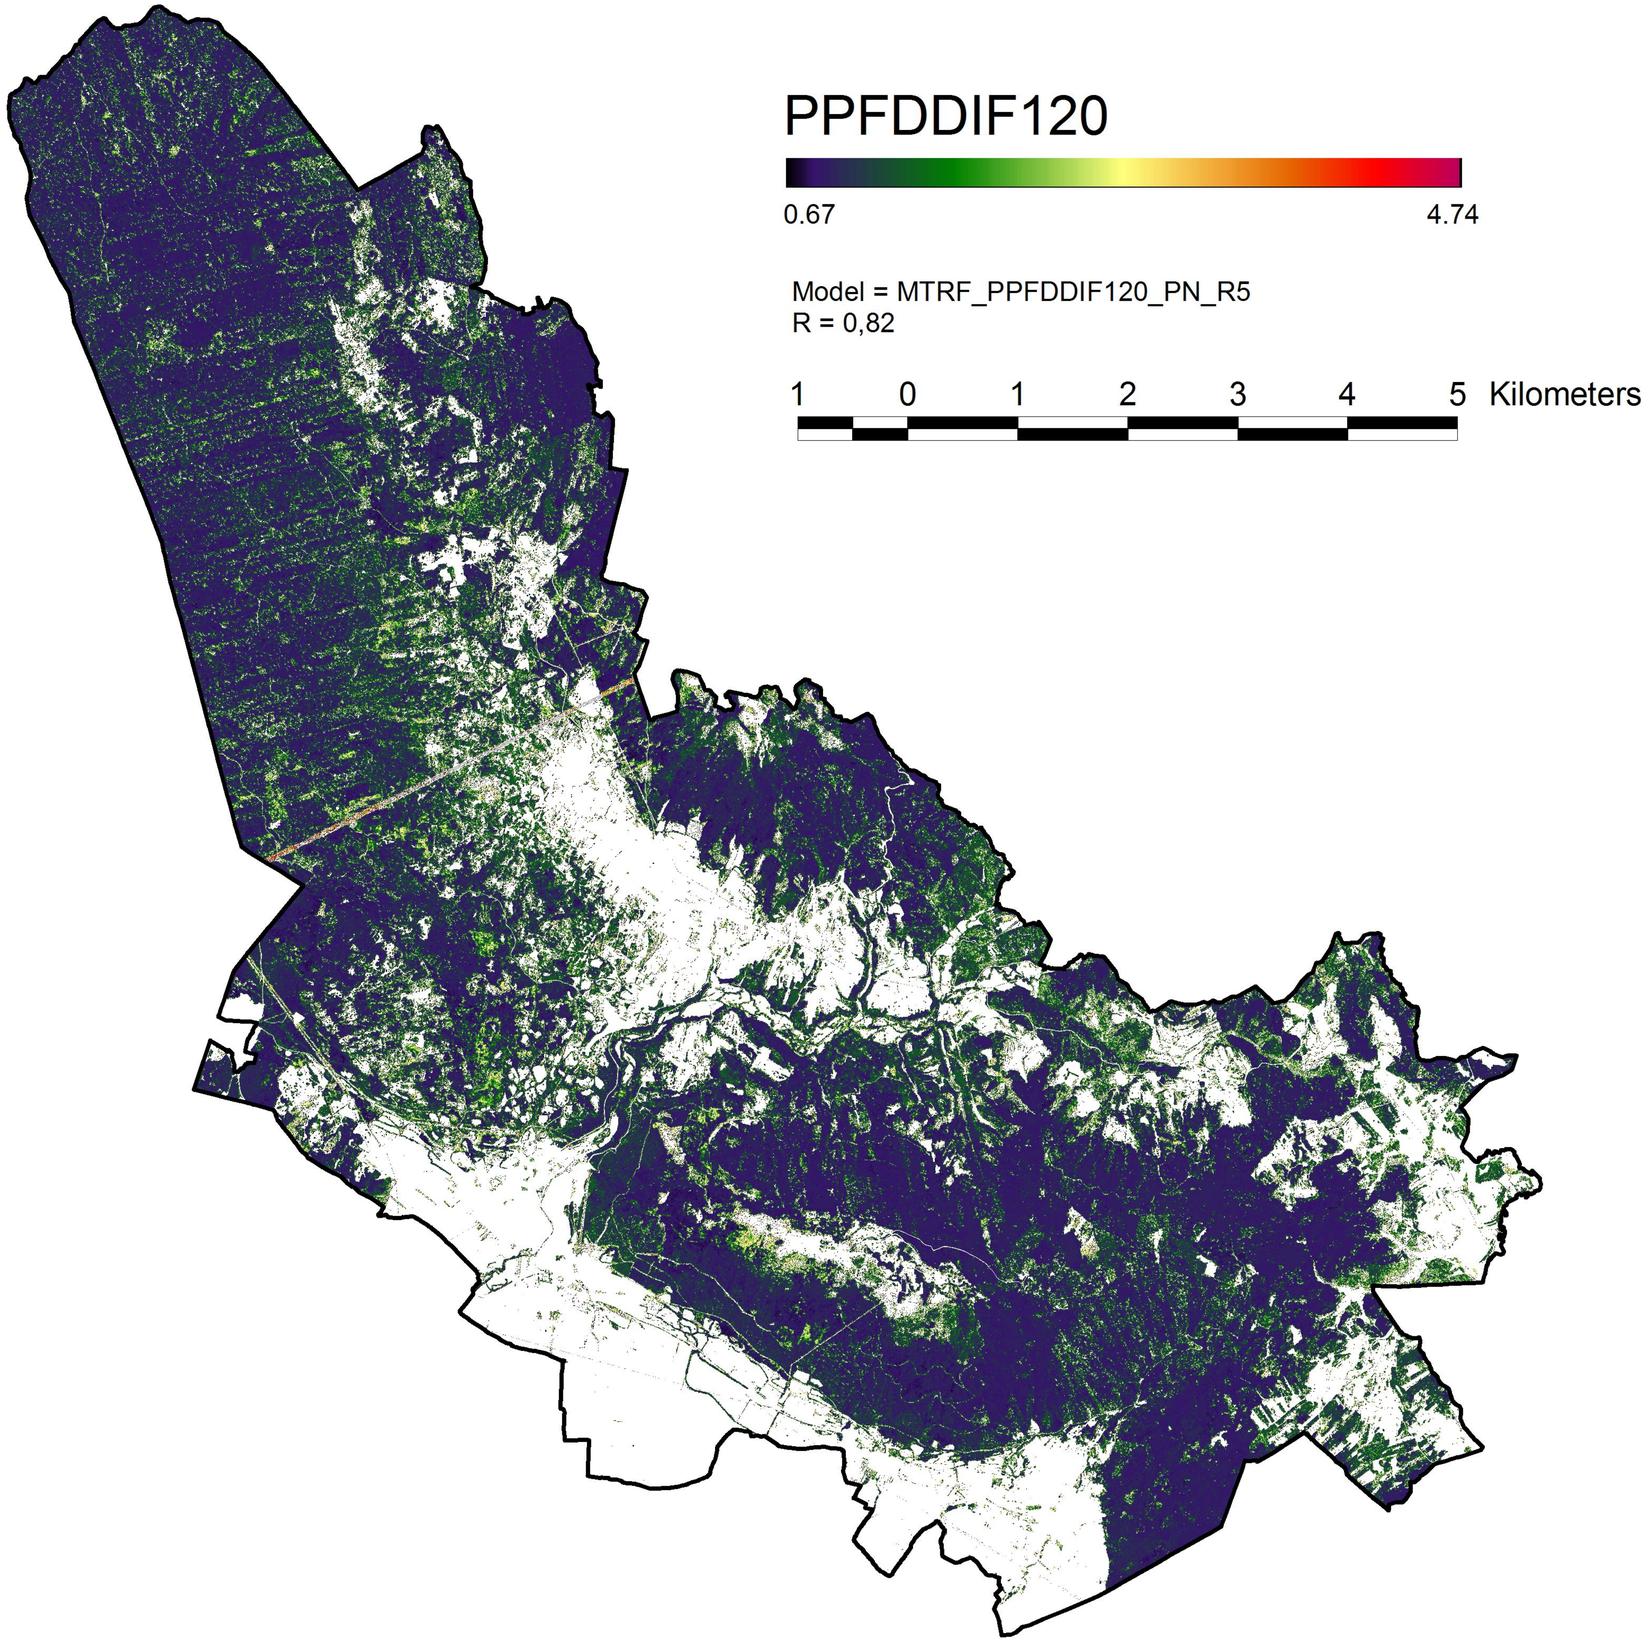
PPFDDIF120
0.67
4.74
Model = MTRF_PPFDDIF120_PN_R5
R = 0,82
1 0 1 2 3 4 5 Kilometers

Digitalni model krošenj

Legenda višin:

0 40 m

1 0 1 2 3 4 5 Kilometers

1.1 Korelacijske tabele ciljnih in pojasnjevalnih spremenljivk

Format tiska omogoča le grob pregled korelacijsih tabel z barvnim kodiranjem vrednosti. Korelacije, ki so po absolutni vrednosti večje od 0,5 so na rumenem ozadju, po absolutni vrednosti večje od 0,7 pa na oranžnem ozadju. Celotne preglednice v bolj berljivem formatu so na priloženem DVD.

R = 5 m	gha	deligl	delbukev	deljavor	delbgaber	delcgaber	delhrast	delmjesen	delvjesen	delostalilst	delsmreka	deljelka	delbor	delmacesen	delostaligl	Openness_45	LAI2000Lin_45	LAI2000GLin_45	DirectSiteFactor_45	IndirectSiteFactor_45	TotalSiteFactor_45	PPFDDirectUnder_45	PPFDDiffuseUnder_45	PPFDTotalUnder_45	Openness_60	LAI2000Lin_60	LAI2000GLin_60	DirectSiteFactor_60	IndirectSiteFactor_60	TotalSiteFactor_60	PPFDDirectUnder_60	PPFDDiffuseUnder_60	PPFDTotalUnder_60	Openness_120	LAI2000Lin_120	LAI2000GLin_120	DirectSiteFactor_120	IndirectSiteFactor_120	TotalSiteFactor_120	PPFDDirectUnder_120	PPFDDiffuseUnder_120	PPFDTotalUnder_120	Openness_170	LAI2000Lin_170	LAI2000GLin_170	DirectSiteFactor_170	IndirectSiteFactor_170	TotalSiteFactor_170	PPFDDirectUnder_170	PPFDDiffuseUnder_170	PPFDTotalUnder_170
avg_vpv_0_r5	-0.3	0.1	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.7	-0.6	-0.3	0.4	0.6	0.5	0.4	0.5	0.5	0.7	-0.6	-0.4	0.5	0.7	0.6	0.5	0.7	0.6	0.7	-0.7	-0.5	0.6	0.7	0.6	0.6	0.7	0.6	0.6	-0.4	-0.5	0.6	0.7	0.6	0.6	0.7	0.6
avg_vpv_1_r5	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.6	-0.6	-0.3	0.4	0.6	0.5	0.4	0.5	0.5	0.7	-0.6	-0.4	0.5	0.7	0.6	0.5	0.7	0.6	0.7	-0.6	-0.5	0.6	0.7	0.6	0.6	0.7	0.6	0.6	-0.4	-0.5	0.6	0.7	0.6	0.6	0.7	0.6
avg_vpv_2_r5	-0.3	0.1	-0.2	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.1	0.0	0.0	0.0	0.0	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.2	0.0	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
avg_vpv_3_r5	-0.3	0.1	-0.2	-0.1	0.0	0.0	0.1	0.0	0.0	0.2	0.2	-0.1	-0.1	0.0	0.0	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.1	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.0	0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
avg_vpv_4_r5	-0.4	0.1	-0.2	-0.1	0.0	0.0	0.1	0.0	0.0	0.3	0.2	-0.2	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_5_r5	-0.4	0.1	-0.3	-0.1	0.0	0.0	0.1	0.0	0.0	0.3	0.2	-0.2	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_6_r5	-0.3	0.1	-0.3	-0.1	0.0	0.0	0.1	0.0	-0.1	0.3	0.3	-0.2	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_7_r5	-0.2	0.2	-0.3	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.1	0.3	-0.2	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_8_r5	-0.2	0.2	-0.3	-0.2	0.0	0.1	0.1	0.1	0.0	0.0	0.3	-0.2	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_9_r5	-0.1	0.2	-0.3	-0.2	0.0	0.1	0.1	0.2	0.0	0.0	0.2	-0.2	0.2	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_10_r5	0.0	0.2	-0.2	-0.2	0.0	0.1	0.1	0.2	0.0	0.0	0.1	-0.2	0.2	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_11_r5	0.1	0.2	-0.2	-0.2	0.0	0.1	0.1	0.2	0.0	0.0	0.1	-0.2	0.3	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_12_r5	0.1	0.1	-0.2	-0.2	0.0	0.1	0.1	0.2	0.0	0.0	0.0	-0.2	0.3	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_13_r5	0.2	0.1	-0.1	-0.2	0.1	0.1	0.1	0.1	0.0	0.0	0.0	-0.1	0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_14_r5	0.2	0.0	-0.1	-0.2	0.2	0.1	0.1	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.2	-0.1	-0.1	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_15_r5	0.3	0.0	0.0	-0.1	0.2	0.1	0.0	0.0	0.0	-0.1	0.0	-0.1	0.1	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	0.0	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
avg_vpv_16_r5	0.3	-0.1	0.0	-0.1	0.2	0.1	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.0	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_17_r5	0.3	-0.1	0.1	0.0	0.2	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.2	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.1	0.0	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
avg_vpv_18_r5	0.3	-0.1	0.2	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	-0.1	0.1	-0.1	0.0	0.0	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.2	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.0	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
avg_vpv_19_r5	0.2	-0.2	0.3	0.1	0.0	0.0	-0.1	-0.1	0.0	-0.2	-0.1	0.2	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.0	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
avg_vpv_20_r5	0.3	-0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.0	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_21_r5	0.3	-0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.0	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_22_r5	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.0	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_23_r5	0.3	-0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.0	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_24_r5	0.2	-0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.0	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_25_r5	0.2	-0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.0	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_26_r5	0.2	-0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_27_r5	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_28_r5	0.2	-0.2	0.2	0.3	0.0	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_29_r5	0.1	-0.2	0.2	0.3	0.0	0.0	-0.1	0.0	0.2	-0.1	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_30_r5	0.1	-0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_31_r5	0.1	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_32_r5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
avg_vpv_100_r5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_kumul_100do0_r5	0.3	-0.1	0.1	0.0	0.0	0.1	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.7	0.6	0.3	-0.4	-0.6	-0.5	-0.4	-0.5	-0.5	-0.7	0.6	0.4	-0.5	-0.7	-0.6	-0.5	-0.7	-0.6	-0.7	0.7	0.5	-0.6	-0.7	-0.6	-0.6	-0.7	-0.6	-0.6	0.4	0.5	-0.6	-0.7	-0.6	-0.6	-0.7	-0.6
avg_vpv_kumul_100do1_r5	0.3	-0.2	0.2	0.0	0.1	0.1	0.0	0.1	0.0	0.0	0.0	0.0	-0.2	0.0	0.0	-0.7	0.6	0.4	-0.5	-0.7	-0.5	-0.5	-0.5	-0.5	-0.7	0.6	0.4	-0.6	-0.7	-0.6	-0.6	-0.7	-0.6	-0.8	0.7	0.6	-0.6	-0.8	-0.7	-0.6	-0.8	-0.7	-0.7	0.4	0.6	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6
avg_vpv_kumul_100do2_r5	0.4	-0.2	0.2	0.0	0.1	0.1	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.7	0.6	0.4	-0.5	-0.7	-0.5	-0.5	-0.6	-0.5	-0.8	0.7	0.4	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6	-0.8	0.7	0.6	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6	-0.7	0.4	0.6	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6
avg_vpv_kumul_100do3_r5	0.4	-0.2	0.2	0.0	0.1	0.1	0.0	0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.7	0.6	0.4	-0.5	-0.7	-0.5	-0.5	-0.6	-0.5	-0.8	0.7	0.4	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6	-0.7	0.7	0.6	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6	-0.6	0.4	0.6	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6
avg_vpv_kumul_100do4_r5	0.5	-0.2	0.2	0.0	0.1	0.1	0.0	0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.7	0.6	0.4	-0.5	-0.7	-0.5	-0.5	-0.6	-0.5	-0.7	0.6	0.4	-0.6	-0.7	-0.6	-0.6	-0.7	-0.6	-0.7	0.6	0.5	-0.5	-0.7	-0.6	-0.5	-0.7	-0.6	-0.6	0.3	0.5	-0.5	-0.7	-0.6	-0.5	-0.7	-0.6
avg_vpv_kumul_100do5_r5	0.5	-0.2	0.3	0.1	0.1	0.1	0.0	0.1	0.0	-0.2	-0.1	0.1	-0.1	0.0	0.0	-0.6	0.6	0.3	-0.4	-0.6	-0.5	-0.4	-0.5	-0.5	-0.7	0.6	0.4	-0.5	-0.7	-0.6	-0.5	-0.7	-0.6	-0.6	0.5	0.5	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5	-0.5	0.2	0.5	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5
avg_vpv_kumul_100do6_r5	0.5	-0.2	0.3	0.1	0.1	0.1	-0.1	0.1	0.0	-0.2	-0.2	0.1	-0.1	0.0	-0.1	-0.6	0.5	0.3	-0.4	-0.6	-0.4	-0.4	-0.5	-0.4	-0.6	0.5	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5	-0.5	0.4	0.4	-0.4	-0.6	-0.4	-0.4	-0.6	-0.4	-0.4	0.2	0.4	-0.4	-0.6	-0.4	-0.4	-0.6	-0.4
avg_vpv_kumul_100do7_r5	0.6	-0.2	0.4	0.1	0.1	0.0	-0.1	0.0	0.0	-0.3	-0.2	0.1	-0.1	0.0	-0.1	-0.6	0.5	0.3	-0.4	-0.6	-0.4	-0.4	-0.5	-0.4	-0.6	0.5	0.4	-0.4	-0.6	-0.5	-0.4	-0.6	-0.5	-0.5	0.4	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.4	0.1	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do8_r5	0.6	-0.2	0.4	0.1	0.1	0.0	-0.1	0.0	0.0	-0.3	-0.3	0.2	-0.1	0.0	-0.1	-0.5	0.5	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.5	0.5	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.4	0.3	0.4	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.3	0.1	0.4	-0.3	-0.5	-0.3	-0.3	-0.5	-0.3
avg_vpv_kumul_100do9_r5	0.6	-0.2	0.4	0.2	0.1	0.0	-0.1	0.0	0.1	-0.2	-0.3	0.2	-0.1	0.0	-0.1	-0.5	0.5	0.3	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.5	0.5	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.4	0.3	0.4	-0.3	-0.5	-0.3	-0.3	-0.5	-0.3	-0.3	0.1	0.4	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do10_r5	0.5	-0.3	0.4	0.2	0.1	0.0	-0.1	0.0	0.1	-0.2	-0.3	0.2	-0.1	0.0	0.0	-0.5	0.5	0.3	-0.3	-0.5	-0.3	-0.3	-0.5	-0.3	-0.5	0.5	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.4	0.3	0.4	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.1	0.4	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do11_r5	0.5	-0.3	0.5	0.2	0.1	0.0	-0.1	-0.1	0.1	-0.2	-0.3	0.2	-0.2	0.0	0.0	-0.5	0.4	0.3	-0.3	-0.5	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.3	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.4	0.3	0.4	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.1	0.4	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do12_r5	0.5	-0.3	0.5	0.2	0.1	0.0	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.5	0.4	0.3	-0.3	-0.5	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.3	-0.3	-0.5	-0.3	-0.3	-0.5	-0.3	-0.3	0.3	0.4	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.3	0.1	0.4	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3
avg_vpv_kumul_100do13_r5	0.5	-0.3	0.5	0.2	0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.3	0.4	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.3	0.1	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2
avg_vpv_kumul_100do14_r5	0.5	-0.3	0.5	0.3	0.0	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.4	0.4	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.3	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do15_r5	0.4	-0.3	0.5	0.3	0.0	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.4	0.4	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do16_r5	0.4	-0.3	0.5	0.3	0.0	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.4	0.4	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2	-0.4	0.4	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do17_r5	0.4	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.4	0.3	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2	-0.4	0.3	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do18_r5	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.4	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do19_r5	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
avg_vpv_kumul_100do20_r5	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.1	0.3	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do21_r5	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do22_r5	0.3	-0.3	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do23_r5	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do24_r5	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do25_r5	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do26_r5	0.2	-0.2	0.2	0.3	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do27_r5	0.1	-0.1	0.2	0.2	0.0	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do28_r5	0.1	-0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do29_r5	0.1	0.0	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do30_r5	0.1	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
avg_vpv_kumul_100do31_r5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
stdev_vpv_0_r5	-0.3	0.2	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	0.0	0.1	0.1	0.0	0.1	0.6	-0.5	-0.3	0.4	0.6	0.4	0.4	0.5	0.4	0.6	-0.6	-0.4	0.5	0.6	0.5	0.5	0.6	0.5	0.6	-0.6	-0.5	0.5	0.7	0.5	0.5	0.6	0.5	0.5	-0.3	-0.5	0.5	0.6	0.5	0.5	0.6	0.5
stdev_vpv_1_r5	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.2	0.0	0.0	0.6	-0.5	-0.3	0.4	0.6	0.4	0.4	0.5	0.4	0.6	-0.6	-0.3	0.5	0.6	0.5	0.5	0.6	0.5	0.5	-0.5	-0.4	0.5	0.6	0.5	0.5	0.6	0.5	0.5	-0.3	-0.5	0.5	0.6	0.5	0.5	0.6	0.5
stdev_vpv_2_r5	-0.3	0.2	-0.2	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.1	-0.1	0.1	0.0	0.0	0.4	-0.3	-0.2	0.2	0.4	0.3	0.2	0.3	0.3	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.3	-0.3	-0.3	0.2	0.4	0.3	0.2	0.4	0.3	0.2	-0.1	-0.3	0.2	0.3	0.2	0.2	0.3	0.2
stdev_vpv_3_r5	-0.4	0.1	-0.2	-0.1	0.0	0.0	0.1	0.0	0.0	0.2	0.2	-0.1	0.0	0.0	0.0	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.1	-0.1	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.1	0.1	-0.2	0.1	0.2	0.1	0.1	0.2	0.1
stdev_vpv_4_r5	-0.4	0.1	-0.3	-0.1	0.0	0.0	0.1	0.0	0.0	0.2	0.2	-0.1	0.0	0.0	0.1	0.2	-0.2	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.1	-0.2	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.2	-0.1	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_5_r5	-0.4	0.1	-0.3	-0.2	0.0	0.0	0.1	0.0	-0.1	0.3	0.3	-0.2	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	-0.1	0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.2	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1
stdev_vpv_6_r5	-0.3	0.2	-0.4	-0.2	0.0	0.1	0.1	0.0	-0.1	0.2	0.3	-0.2	0.1	0.0	0.1	0.1	-0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_7_r5	-0.2	0.2	-0.3	-0.2	-0.1	0.1	0.1	0.0	-0.1	0.1	0.3	-0.2	0.1	0.1	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_8_r5	-0.2	0.2	-0.3	-0.2	-0.1	0.1	0.1	0.1	-0.1	0.0	0.3	-0.1	0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_9_r5	-0.1	0.2	-0.3	-0.2	-0.1	0.1	0.1	0.1	0.0	0.0	0.2	-0.2	0.2	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_10_r5	0.0	0.2	-0.3	-0.2	0.0	0.1	0.1	0.2	0.0	0.0	0.1	-0.2	0.2	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_11_r5	0.1	0.2	-0.3	-0.2	0.0	0.1	0.1	0.2	0.0	0.0	0.1	-0.2	0.3	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_12_r5	0.1	0.2	-0.2	-0.2	0.1	0.1	0.1	0.1	0.0	0.0	0.0	-0.1	0.3	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_13_r5	0.2	0.1	-0.1	-0.2	0.1	0.1	0.1	0.1	0.0	-0.1	0.0	0.0	0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.1	0.0	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_14_r5	0.3	0.1	-0.1	-0.2	0.2	0.1	0.1	0.0	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.1	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	0.0	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_15_r5	0.3	0.0	0.0	-0.1	0.2	0.1	0.0	0.0	0.0	-0.1	-0.1	0.0	0.1	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.2	-0.1	-0.1	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.0	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_16_r5	0.3	-0.1	0.1	-0.1	0.2	0.0	0.0	0.0	0.0	-0.1	-0.1	0.1	0.0	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.2	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.0	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_17_r5	0.3	-0.1	0.2	0.0	0.1	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.1	-0.1	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.0	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_18_r5	0.3	-0.1	0.3	0.1	0.1	-0.1	0.0	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_19_r5	0.3	-0.2	0.4	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.3	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_20_r5	0.3	-0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_21_r5	0.3	-0.2	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_22_r5	0.3	-0.2	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_23_r5	0.3	-0.2	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_24_r5	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_25_r5	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.2	0.3	-0.3	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_26_r5	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_27_r5	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.3	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_28_r5	0.2	-0.1	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.3	-0.2	0.0	0.0	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_29_r5	0.1	-0.1	0.2	0.3	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.3	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_30_r5	0.1	0.0	0.1	0.2	0.0	-0.1	-0.1	0.0	0.1	-0.1	-0.2	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_31_r5	0.1	0.0	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_32_r5	0.1	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
stdev_vpv_100_r5	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
stdev_vpv_kumul_100do0_r5	-0.3	0.2	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	0.0	0.1	0.1	0.0	0.1	0.6	-0.5	-0.3	0.4	0.6	0.4	0.4	0.5	0.4	0.6	-0.6	-0.4	0.5	0.6	0.5	0.5	0.6	0.5	0.6	-0.6	-0.5	0.5	0.7	0.5	0.5	0.6	0.5	0.5	-0.3	-0.5	0.5	0.6	0.5	0.5	0.6	0.5
stdev_vpv_kumul_100do1_r5	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.2	0.0	0.1	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.5	-0.5	-0.3	0.4	0.5	0.5	0.4	0.5	0.5	0.5	-0.5	-0.4	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.2	-0.4	0.4	0.5	0.4	0.4	0.5	0.4
stdev_vpv_kumul_100do2_r5	-0.4	0.2	-0.2	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.2	0.0	0.1	0.5	-0.5	-0.2	0.3	0.5	0.4	0.3	0.4	0.4	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.5	-0.4	0.4	0.5	0.4	0.4	0.5	0.4	0.3	-0.2	-0.4	0.4	0.5	0.4	0.4	0.5	0.4
stdev_vpv_kumul_100do3_r5	-0.4	0.2	-0.2	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.1	0.1	0.0	0.2	0.0	0.1	0.4	-0.4	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.4	-0.3	0.3	0.4	0.4	0.3	0.4	0.4	0.3	-0.2	-0.3	0.3	0.4	0.3	0.3	0.4	0.3
stdev_vpv_kumul_100do4_r5	-0.4	0.2	-0.3	-0.1	-0.1	-0.1	0.1	-0.1	0.0	0.1	0.1	0.0	0.2	0.0	0.0	0.4	-0.4	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.4	-0.4	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.3	-0.3	-0.3	0.3	0.3	0.3	0.3	0.3	0.3	0.2	-0.1	-0.3	0.3	0.3	0.3	0.3	0.3	0.3
stdev_vpv_kumul_100do5_r5	-0.4	0.3	-0.3	-0.1	-0.1	-0.1	0.1	0.0	0.0	0.1	0.1	0.0	0.2	0.0	0.0	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.3	0.3	-0.3	-0.2	0.2	0.3	0.3	0.2	0.3	0.3	0.2	-0.2	-0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.1	0.0	-0.2	0.2	0.2	0.2	0.2	0.2	0.2
stdev_vpv_kumul_100do6_r5	-0.3	0.3	-0.3	-0.1	-0.1	0.0	0.1	0.0	0.0	0.0	0.1	0.0	0.2	0.0	0.0	0.2	-0.3	-0.1	0.2	0.2	0.2	0.2	0.3	0.2	0.2	-0.3	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_kumul_100do7_r5	-0.2	0.3	-0.3	-0.1	-0.1	0.0	0.1	0.0	0.0	0.0	0.1	0.0	0.2	0.0	0.0	0.2	-0.2	-0.1	0.1	0.2	0.1	0.1	0.3	0.1	0.1	-0.2	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.0	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_kumul_100do8_r5	-0.1	0.3	-0.3	-0.1	-0.1	0.0	0.1	0.0	0.0	-0.1	0.1	0.0	0.2	0.0	0.0	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.2	0.1	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_kumul_100do9_r5	0.0	0.3	-0.2	-0.1	-0.1	0.0	0.1	0.1	0.0	-0.1	0.0	0.1	0.2	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0
stdev_vpv_kumul_100do10_r5	0.1	0.2	-0.2	-0.1	-0.1	0.0	0.1	0.0	0.0	-0.1	0.0	0.1	0.2	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.1	0.0	-0.1	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do11_r5	0.1	0.2	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.2	0.1	0.0	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do12_r5	0.2	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.2	-0.1	0.2	0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do13_r5	0.3	0.1	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	-0.2	-0.1	0.3	0.0	0.0	0.0	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do14_r5	0.3	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.0	-0.2	-0.2	0.3	-0.1	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do15_r5	0.3	0.0	0.2	0.1	0.0	-0.1	0.0	-0.1	0.0	-0.2	-0.2	0.4	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.1	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do16_r5	0.3	-0.1	0.2	0.1	0.0	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.4	-0.2	0.0	0.0	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.2	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do17_r5	0.3	-0.1	0.3	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.5	-0.3	0.0	0.0	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do18_r5	0.3	-0.1	0.3	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.5	-0.3	0.0	0.0	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.1	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do19_r5	0.3	-0.1	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.5	-0.3	0.0	0.0	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.1	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do20_r5	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.1	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do21_r5	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.1	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do22_r5	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.1	0.3	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do23_r5	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.3	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.3	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do24_r5	0.2	-0.1	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do25_r5	0.2	-0.1	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.4	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do26_r5	0.2	-0.1	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.4	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do27_r5	0.2	-0.1	0.2	0.2	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.3	-0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do28_r5	0.1	-0.1	0.2	0.2	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.2	0.3	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do29_r5	0.1	0.0	0.1	0.1	0.0	-0.1	-0.1	0.0	0.1	-0.1	-0.2	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do30_r5	0.1	0.0	0.1	0.1	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do31_r5	0.1	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
dof_ndvi_gurs_r5_avg	-0.1	-0.3	0.1	-0.1	0.0	0.1	0.2	0.1	0.1	0.3	0.0	-0.3	-0.1	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.1	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.1	0.2	0.1	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.1	0.1	0.1	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2
dof_ndvi_gurs_r5_std	0.0	0.3	-0.2	0.0	0.1	0.0	-0.1	-0.1	-0.1	-0.2	0.0	0.4	0.0	0.0	0.0	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.1	0.2	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.1	-0.1	-0.1	0.2	0.2	0.2	0.2	0.2	0.2
dof_ndvi_geoin_r5_avg	0.0	-0.6	0.6	0.2	0.1	0.1	0.1	0.0	0.0	0.0	-0.3	0.1	-0.5	0.0	-0.1	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
dof_ndvi_geoin_r5_std	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.1	-0.1	0.0	0.0	0.1	0.0	0.0	0.1	0.0
naem00_1_r5	-0.2	-0.1	0.0	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.4	0.1	0.0	0.0	0.2	-0.1	-0.2	0.1	0.2	0.1	0.1	0.1	0.1	0.2	-0.2	-0.2	0.1	0.2	0.2	0.1	0.2	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
naem01_1_r5	0.1	0.0	0.1	0.2	-0.1	-0.1	0.0	-0.1	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem02_1_r5	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem03_1_r5	0.1	0.0	-0.1	-0.1	0.1	0.1	0.0	0.0	0.0	0.1	0.0	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem10_1_r5	0.1	0.1	0.0	0.1	-0.1	-0.1	0.0	-0.1	0.0	-0.1	0.0	0.3	-0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0
naem11_1_r5	0.1	0.1	0.0	0.1	-0.1	-0.1	0.0	-0.1	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem12_1_r5	0.2	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.3	0.0	0.1	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
naem13_1_r5	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	-0.1	0.0	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem20_1_r5	0.0	-0.1	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.2	0.1	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0
naem21_1_r5	0.1	0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	0.0	-0.1	0.0	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
naem22_1_r5	0.1	0.1	0.0	-0.1	0.0	-0.1	0.1	0.0	0.0	-0.1	0.0	0.1	0.0	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
naem23_1_r5	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.1	0.0	0.0	0.1	-0.2	0.0	0.0	0.0	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.1	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
naem30_1_r5	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	0.0	0.0	0.3	-0.3	-0.1	0.2	0.3	0.2	0.2	0.2	0.2	0.3	-0.3	-0.2	0.3	0.3	0.3	0.3	0.3	0.3	0.3	-0.3	-0.2	0.3	0.3	0.3	0.3	0.3	0.3	0.3	-0.3	-0.3	0.3	0.3	0.3	0.3	0.3	0.3
naem31_1_r5	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.0	0.1	0.1	0.0	0.1	0.1	0.1	-0.1	-0.1	0.0	0.1	0.1	0.0	0.1	0.1
naem32_1_r5	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.1	0.0	0.1	0.1	-0.2	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem33_1_r5	-0.1	-0.2	0.0	0.0	0.1	0.2	0.0	0.1	0.0	0.1	0.0	-0.3	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
con_1_r5	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	-0.2	0.3	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
dis_1_r5	-0.3	0.2	-0.1	0.1	0.0	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.1	0.6	-0.5	-0.3	0.4	0.6	0.4	0.4	0.5	0.4	0.6	-0.6	-0.3	0.5	0.6	0.5	0.5	0.6	0.5	0.6	-0.6	-0.5	0.5	0.6	0.5	0.5	0.6	0.5	0.5	-0.3	-0.5	0.5	0.6	0.5	0.5	0.6	0.5
hom_1_r5	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.1	0.1	-0.3	0.1	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.2	0.1
asm_1_r5	-0.2	-0.1	0.0	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.3	0.1	0.0	0.0	0.2	-0.2	-0.2	0.1	0.2	0.2	0.1	0.1	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.4	-0.2	-0.2	0.2	0.3	0.3	0.2	0.3	0.3
mxp_1_r5	-0.2	-0.1	0.0	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.4	0.1	0.0	0.0	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.1	0.1	0.2	-0.2	-0.2	0.1	0.2	0.2	0.1	0.2	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
ent_1_r5	0.2	0.1	0.1	0.1	-0.1	-0.1	0.0	-0.1	0.0	-0.2	-0.1	0.3	-0.1	0.0	0.0	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.1	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.3	-0.2	-0.3	-0.3	-0.4	0.2	0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3
mn1_1_r5	0.2	0.1	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	-0.2	0.0	0.2	-0.1	0.0	0.0	-0.4	0.3	0.2	-0.2	-0.4	-0.2	-0.2	-0.2	-0.2	-0.4	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
mn2_1_r5	0.3	0.1	0.1	0.0	-0.1	-0.1	0.0	0.0	0.0	-0.2	0.0	0.2	-0.1	0.0	0.0	-0.5	0.4	0.3	-0.3	-0.5	-0.3	-0.3	-0.3	-0.3	-0.5	0.4	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.5	0.5	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.5	0.3	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4
vr1_1_r5	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	0.1	0.0	0.1	0.1	-0.4	0.1	0.0	0.0	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	0.0	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
vr2_1_r5	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	0.1	0.0	0.1	0.1	-0.4	0.1	0.0	0.0	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.1	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	0.0	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
cor_1_r5	0.1	-0.1	0.0	-0.1	0.1	0.1	0.0	0.1	0.0	0.1	0.2	-0.3	0.0	0.0	0.0	-0.3	0.3	0.1	-0.2	-0.3	-0.2	-0.2	-0.2	-0.2	-0.3	0.3	0.1	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	0.3	0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	0.1	0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3
naem00_2_r5	-0.2	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.4	0.1	0.0	0.0	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.1	0.1	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
naem01_2_r5	0.2	0.0	0.1	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.4	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem02_2_r5	0.0	0.0	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
naem03_2_r5	-0.1	0.0	-0.1	-0.1	0.1	0.1	0.0	0.0	0.0	0.2	0.1	-0.2	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem10_2_r5	0.1	0.2	0.0	0.0	-0.1	-0.1	0.0	-0.1	0.0	-0.1	0.0	0.3	-0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.1	0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0

R = 10 m	gha	deligl	delbukev	deljavor	delbgaber	delcgaber	delhrast	delmjesen	delvjesen	delostalist	delsmreka	deljelka	delbor	delmacesen	delostaligl	Openness_45	LAI2000Lin_45	LAI2000GLin_45	DirectSiteFactor_45	IndirectSiteFactor_45	TotalSiteFactor_45	PPFDDirectUnder_45	PPFDDiffuseUnder_45	PPFDTotalUnder_45
avg_vpv_0_r10	-0.3	0.2	-0.2	0.0	0.0	-0.1	0.0	-0.1	0.0	0.1	0.0	0.0	0.2	0.0	0.0	0.6	-0.5	-0.3	0.4	0.6	0.4	0.4	0.4	0.4
avg_vpv_1_r10	-0.4	0.2	-0.2	0.0	-0.1	-0.1	0.0	0.0	0.0	0.1	0.1	0.0	0.2	0.0	0.0	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.4	0.4
avg_vpv_2_r10	-0.3	0.1	-0.2	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.2	-0.1	0.0	0.0	0.0	0.3	-0.2	-0.1	0.2	0.3	0.2	0.2	0.2	0.2
avg_vpv_3_r10	-0.3	0.1	-0.2	-0.1	-0.1	0.0	0.1	0.0	0.0	0.3	0.2	-0.1	0.0	0.0	0.0	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1
avg_vpv_4_r10	-0.4	0.1	-0.3	-0.2	0.0	0.0	0.1	0.0	0.0	0.4	0.2	-0.2	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
avg_vpv_5_r10	-0.4	0.1	-0.3	-0.2	0.0	0.0	0.1	0.0	0.0	0.4	0.3	-0.2	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0
avg_vpv_6_r10	-0.3	0.1	-0.3	-0.2	0.0	0.1	0.1	0.0	-0.1	0.3	0.3	-0.3	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0
avg_vpv_7_r10	-0.3	0.2	-0.3	-0.2	0.0	0.1	0.1	0.1	-0.1	0.2	0.3	-0.3	0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0
avg_vpv_8_r10	-0.2	0.2	-0.3	-0.2	0.0	0.1	0.1	0.2	0.0	0.1	0.3	-0.3	0.1	0.0	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0
avg_vpv_9_r10	-0.1	0.2	-0.3	-0.2	0.0	0.2	0.0	0.2	0.0	0.0	0.2	-0.3	0.2	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0
avg_vpv_10_r10	0.0	0.2	-0.3	-0.2	0.0	0.2	0.0	0.2	0.0	0.0	0.2	-0.3	0.2	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	-0.1	0.1	0.0
avg_vpv_11_r10	0.0	0.2	-0.3	-0.2	0.0	0.2	0.1	0.2	0.0	0.0	0.1	-0.2	0.3	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1
avg_vpv_12_r10	0.1	0.2	-0.3	-0.2	0.1	0.2	0.0	0.2	0.0	0.0	0.1	-0.2	0.3	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1
avg_vpv_13_r10	0.2	0.1	-0.2	-0.2	0.2	0.1	0.1	0.1	0.0	0.0	0.0	-0.2	0.3	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1
avg_vpv_14_r10	0.3	0.1	-0.1	-0.2	0.3	0.1	0.0	0.1	0.0	-0.1	0.0	-0.1	0.2	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_15_r10	0.3	0.0	0.0	-0.1	0.3	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1
avg_vpv_16_r10	0.3	-0.1	0.1	-0.1	0.3	0.0	0.0	0.0	0.0	-0.1	-0.1	0.1	0.0	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_17_r10	0.3	-0.1	0.2	0.0	0.2	0.0	0.0	0.0	0.0	-0.1	-0.1	0.1	-0.1	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_18_r10	0.3	-0.2	0.3	0.1	0.1	0.0	0.0	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_19_r10	0.3	-0.2	0.4	0.2	0.0	-0.1	0.0	-0.1	-0.1	-0.2	-0.2	0.2	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
avg_vpv_20_r10	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.2	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.2
avg_vpv_21_r10	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.2	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
avg_vpv_22_r10	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
avg_vpv_23_r10	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
avg_vpv_24_r10	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1
avg_vpv_25_r10	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_26_r10	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_27_r10	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_28_r10	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	0.0	0.3	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.1
avg_vpv_29_r10	0.2	-0.2	0.2	0.3	-0.1	-0.1	-0.1	0.0	0.3	-0.1	-0.2	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_30_r10	0.1	-0.1	0.2	0.3	0.0	-0.1	-0.1	0.0	0.3	-0.1	-0.2	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_31_r10	0.1	-0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.2	-0.1	-0.1	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_32_r10	0.1	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_100_r10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.2	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_kumul_100do0_r10	0.3	-0.2	0.2	0.0	0.0	0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.2	0.0	0.0	-0.6	0.5	0.3	-0.4	-0.6	-0.4	-0.4	-0.4	-0.4
avg_vpv_kumul_100do1_r10	0.4	-0.2	0.2	0.0	0.1	0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.2	0.0	0.0	-0.6	0.5	0.3	-0.4	-0.6	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do2_r10	0.4	-0.2	0.2	0.0	0.1	0.1	0.0	0.1	0.1	-0.1	0.0	0.0	-0.2	0.0	0.0	-0.6	0.5	0.3	-0.4	-0.6	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do3_r10	0.4	-0.2	0.3	0.1	0.1	0.1	0.0	0.1	0.1	-0.1	-0.1	0.0	-0.2	0.0	0.0	-0.6	0.5	0.3	-0.4	-0.6	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do4_r10	0.5	-0.2	0.3	0.1	0.1	0.1	-0.1	0.1	0.1	-0.2	-0.1	0.1	-0.2	0.0	0.0	-0.6	0.5	0.3	-0.4	-0.6	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do5_r10	0.5	-0.2	0.4	0.1	0.1	0.1	-0.1	0.1	0.1	-0.3	-0.2	0.1	-0.2	0.0	0.0	-0.5	0.5	0.3	-0.4	-0.5	-0.4	-0.4	-0.4	-0.4
avg_vpv_kumul_100do6_r10	0.6	-0.2	0.4	0.1	0.1	0.0	-0.1	0.1	0.1	-0.3	-0.2	0.2	-0.1	0.0	0.0	-0.5	0.4	0.3	-0.3	-0.5	-0.3	-0.3	-0.4	-0.4
avg_vpv_kumul_100do7_r10	0.6	-0.2	0.4	0.2	0.1	0.0	-0.1	0.0	0.1	-0.3	-0.3	0.2	-0.2	0.0	0.0	-0.5	0.4	0.3	-0.3	-0.5	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do8_r10	0.6	-0.3	0.4	0.2	0.1	0.0	-0.1	0.0	0.1	-0.3	-0.3	0.2	-0.2	0.0	-0.1	-0.4	0.4	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do9_r10	0.6	-0.3	0.5	0.2	0.1	0.0	-0.1	0.0	0.1	-0.3	-0.3	0.2	-0.2	0.0	-0.1	-0.4	0.4	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do10_r10	0.5	-0.3	0.5	0.2	0.1	0.0	-0.1	0.0	0.1	-0.3	-0.3	0.3	-0.2	0.0	-0.1	-0.4	0.4	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do11_r10	0.5	-0.3	0.5	0.3	0.1	0.0	-0.1	-0.1	0.1	-0.3	-0.3	0.3	-0.2	0.0	0.0	-0.4	0.4	0.2	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3
avg_vpv_kumul_100do12_r10	0.5	-0.3	0.5	0.3	0.1	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.3	-0.3	0.0	0.0	-0.4	0.4	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3
avg_vpv_kumul_100do13_r10	0.5	-0.3	0.6	0.3	0.0	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.3	-0.3	0.0	0.0	-0.4	0.4	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2
avg_vpv_kumul_100do14_r10	0.5	-0.3	0.6	0.3	0.0	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.3	-0.3	0.0	0.0	-0.4	0.3	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2
avg_vpv_kumul_100do15_r10	0.4	-0.4	0.6	0.3	0.0	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.4	-0.3	0.0	0.0	-0.4	0.3	0.2	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2
avg_vpv_kumul_100do16_r10	0.4	-0.4	0.6	0.4	0.0	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.4	-0.2
avg_vpv_kumul_100do17_r10	0.4	-0.3	0.6	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.3	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.4	-0.2
avg_vpv_kumul_100do18_r10	0.4	-0.3	0.6	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do19_r10	0.4	-0.3	0.6	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do20_r10	0.3	-0.3	0.5	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do21_r10	0.3	-0.3	0.5	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
avg_vpv_kumul_100do22_r10	0.3	-0.3	0.5	0.4	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.2
avg_vpv_kumul_100do23_r10	0.3	-0.3	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do24_r10	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do25_r10	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.1	-0.2	0.3	-0.2	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do26_r10	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do27_r10	0.2	-0.2	0.2	0.3	-0.1	-0.1	-0.1	0.0	0.3	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do28_r10	0.2	-0.1	0.2	0.3	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do29_r10	0.1	-0.1	0.1	0.2	0.0	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do30_r10	0.1	0.0	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do31_r10	0.1	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1
stdev_vpv_0_r10	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	0.0	0.1	0.2	0.0	0.0	0.5	-0.4	-0.2	0.3	0.5	0.4	0.3	0.4	0.4
stdev_vpv_1_r10	-0.3	0.2	-0.3	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.2	0.0	0.0	0.5	-0.4	-0.2	0.3	0.5	0.4	0.3	0.4	0.4
stdev_vpv_2_r10	-0.4	0.2	-0.3	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.1	-0.1	0.1	0.0	0.0	0.3	-0.3	-0.1	0.2	0.3	0.2	0.2	0.3	0.2
stdev_vpv_3_r10	-0.4	0.2	-0.3	-0.2	-0.1	0.0	0.1	0.0	0.0	0.2	0.2	-0.1	0.0	0.0	0.0	0.2	-0.2	-0.1	0.1	0.2	0.1	0.1	0.2	0.1
stdev_vpv_4_r10	-0.4	0.2	-0.4	-0.2	-0.1	0.0	0.1	0.0	0.0	0.3	0.3	-0.2	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.2	0.1
stdev_vpv_5_r10	-0.4	0.2	-0.4	-0.2	0.0	0.0	0.2	0.0	0.0	0.3	0.3	-0.2	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_6_r10	-0.3	0.2	-0.4	-0.2	-0.1	0.1	0.2	0.0	-0.1	0.3	0.3	-0.2	0.1	0.1	0.0	0.1	-0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0
stdev_vpv_7_r10	-0.3	0.2	-0.4	-0.2	-0.1	0.1	0.1	0.1	-0.1	0.2	0.3	-0.2	0.1	0.0	0.0	0.1	-0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0
stdev_vpv_8_r10	-0.2	0.2	-0.4	-0.2	0.0	0.1	0.1	0.1	-0.1	0.1	0.3	-0.2	0.2	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.0
stdev_vpv_9_r10	-0.1	0.3	-0.3	-0.3	0.0	0.2	0.1	0.2	-0.1	0.1	0.2	-0.2	0.2	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0
stdev_vpv_10_r10	-0.1	0.2	-0.3	-0.3	0.0	0.1	0.1	0.2	0.0	0.1	0.2	-0.2	0.2	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0
stdev_vpv_11_r10	0.0	0.2	-0.3	-0.3	0.0	0.2	0.1	0.2	0.0	0.0	0.1	-0.2	0.3	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1
stdev_vpv_12_r10	0.1	0.2	-0.2	-0.2	0.1	0.1	0.1	0.1	0.0	0.0	0.1	-0.1	0.3	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1
stdev_vpv_13_r10	0.2	0.1	-0.2	-0.2	0.1	0.1	0.1	0.1	0.0	-0.1	0.0	0.0	0.2	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1
stdev_vpv_14_r10	0.3	0.1	-0.1	-0.2	0.2	0.1	0.0	0.0	0.0	-0.1	-0.1	0.0	0.1	0.0	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_15_r10	0.3	0.0	0.0	-0.1	0.2	0.0	0.0	0.0	0.0	-0.2	-0.1	0.1	0.0	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_16_r10	0.3	-0.1	0.1	0.0	0.2	0.0	0.0	-0.1	0.0	-0.2	-0.2	0.2	-0.1	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_17_r10	0.3	-0.1	0.2	0.0	0.2	0.0	0.0	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.2	-0.1
stdev_vpv_18_r10	0.4	-0.2	0.4	0.1	0.1	-0.1	0.0	-0.1	0.0	-0.2	-0.2	0.3	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_19_r10	0.4	-0.2	0.4	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_20_r10	0.4	-0.3	0.5	0.3	0.0	-0.1	-0.1	-0.1	0.0	-0.3	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_21_r10	0.4	-0.3	0.5	0.3	-0.1	-0.2	-0.1	-0.1	0.0	-0.3	-0.3	0.4	-0.4	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_22_r10	0.4	-0.3	0.6	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.3	-0.3	0.4	-0.4	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_23_r10	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.3	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_24_r10	0.3	-0.2	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_25_r10	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1
stdev_vpv_26_r10	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_27_r10	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_28_r10	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.3	0.4	-0.2	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_29_r10	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.1	-0.3	0.4	-0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_30_r10	0.2	-0.1	0.2	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.1	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_31_r10	0.1	0.0	0.1	0.2	-0.1	-0.1	-0.1	-0.1	0.2	-0.1	-0.2	0.3	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_32_r10	0.1	0.0	0.1	0.1	0.0	-0.1	-0.1	0.0	0.1	-0.1	-0.2	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_100_r10	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
stdev_vpv_kumul_100do0_r10	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	0.0	0.1	0.2	0.0	0.0	0.5	-0.4	-0.2	0.3	0.5	0.4	0.3	0.4	0.4
stdev_vpv_kumul_100do1_r10	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	0.1	0.2	0.0	0.0	0.4	-0.4	-0.2	0.3	0.4	0.3	0.3	0.4	0.3
stdev_vpv_kumul_100do2_r10	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.1	0.0	0.1	0.2	0.0	0.0	0.4	-0.4	-0.2	0.3	0.4	0.3	0.3	0.4	0.3
stdev_vpv_kumul_100do3_r10	-0.3	0.2	-0.3	-0.1	-0.1	-0.1	0.1	-0.1	0.0	0.1	0.1	0.1	0.2	0.0	0.0	0.4	-0.3	-0.1	0.3	0.4	0.3	0.3	0.4	0.3
stdev_vpv_kumul_100do4_r10	-0.4	0.3	-0.3	-0.1	-0.1	-0.1	0.1	-0.1	0.0	0.1	0.1	0.0	0.2	0.0	0.0	0.3	-0.3	-0.1	0.3	0.3	0.3	0.3	0.3	0.3
stdev_vpv_kumul_100do5_r10	-0.3	0.3	-0.4	-0.1	-0.1	-0.1	0.1	-0.1	0.0	0.1	0.2	0.0	0.2	0.0	0.0	0.3	-0.3	-0.1	0.2	0.3	0.2	0.2	0.3	0.2
stdev_vpv_kumul_100do6_r10	-0.3	0.3	-0.4	-0.1	-0.1	-0.1	0.1	0.0	0.0	0.0	0.2	0.0	0.2	0.0	0.0	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.3	0.2
stdev_vpv_kumul_100do7_r10	-0.2	0.3	-0.4	-0.1	-0.1	0.0	0.1	0.0	0.0	0.0	0.1	0.1	0.2	0.0	0.0	0.2	-0.2	-0.1	0.1	0.2	0.1	0.1	0.2	0.1
stdev_vpv_kumul_100do8_r10	-0.1	0.3	-0.3	-0.1	-0.1	0.0	0.1	0.0	0.0	-0.1	0.1	0.1	0.2	0.0	0.0	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.2	0.1
stdev_vpv_kumul_100do9_r10	0.0	0.3	-0.2	-0.1	-0.1	-0.1	0.1	0.0	0.0	-0.1	0.1	0.2	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.0
stdev_vpv_kumul_100do10_r10	0.1	0.3	-0.2	-0.1	-0.1	-0.1	0.0	0.0	0.0	-0.2	0.0	0.2	0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.1	0.0
stdev_vpv_kumul_100do11_r10	0.2	0.2	-0.1	-0.1	0.0	-0.1	0.0	0.0	0.0	-0.2	0.0	0.3	0.1	0.0	-0.1	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	0.0	0.0
stdev_vpv_kumul_100do12_r10	0.2	0.2	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	-0.2	-0.1	0.3	0.0	0.0	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	0.0	0.0
stdev_vpv_kumul_100do13_r10	0.3	0.1	0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	-0.3	-0.1	0.4	-0.1	0.0	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do14_r10	0.3	0.0	0.2	0.1	0.0	-0.1	0.0	-0.1	0.0	-0.3	-0.2	0.4	-0.2	0.0	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do15_r10	0.3	0.0	0.2	0.1	0.0	-0.1	-0.1	-0.1	0.0	-0.3	-0.2	0.5	-0.3	0.0	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do16_r10	0.3	-0.1	0.3	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.3	-0.2	0.5	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do17_r10	0.3	-0.1	0.4	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.3	-0.2	0.6	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do18_r10	0.3	-0.1	0.4	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do19_r10	0.3	-0.2	0.4	0.3	-0.1	-0.2	-0.2	-0.1	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do20_r10	0.3	-0.2	0.5	0.3	-0.1	-0.2	-0.2	-0.1	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do21_r10	0.3	-0.2	0.5	0.3	-0.1	-0.2	-0.2	-0.1	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do22_r10	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do23_r10	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.2	-0.3	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do24_r10	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do25_r10	0.3	-0.1	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do26_r10	0.2	-0.1	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do27_r10	0.2	-0.1	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.4	-0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do28_r10	0.2	-0.1	0.2	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do29_r10	0.2	-0.1	0.2	0.2	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do30_r10	0.1	0.0	0.1	0.1	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do31_r10	0.1	0.0	0.1	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.2	0.4	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
dof_ndvi_gurs_r10_avg	-0.2	-0.4	0.1	0.0	0.0	0.1	0.2	0.1	0.0	0.4	0.0	-0.3	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
dof_ndvi_gurs_r10_std	0.0	0.3	-0.2	0.0	0.1	0.0	-0.1	-0.1	-0.1	-0.1	0.0	0.4	0.0	0.0	0.0	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.1	0.1
dof_ndvi_geoin_r10_avg	-0.1	-0.7	0.6	0.2	0.1	0.2	0.1	0.0	0.0	0.0	-0.3	0.1	-0.5	0.0	-0.1	-0.2	0.3	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1
dof_ndvi_geoin_r10_std	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	0.0
naem00_1_r10	-0.2	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.2	-0.5	0.2	0.0	0.0	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.1	0.1
naem01_1_r10	0.2	0.0	0.1	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem02_1_r10	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem03_1_r10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem10_1_r10	0.1	0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.1	0.4	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0
naem11_1_r10	0.1	0.1	0.0	0.1	-0.1	-0.1	0.0	-0.1	0.0	-0.2	-0.1	0.5	-0.2	0.0	0.0	0.0	0.0	0.1	0.1	0.0	0.1	0.1	0.0	0.1
naem12_1_r10	0.2	0.0	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	-0.1	-0.1	0.2	0.0	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1
naem13_1_r10	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem20_1_r10	0.0	-0.1	0.1	0.1	0.0	0.0	0.1	0.0	0.1	0.0	-0.1	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0
naem21_1_r10	0.1	0.1	0.0	-0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	0.0	0.2	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1
naem22_1_r10	0.2	0.0	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.2	-0.2
naem23_1_r10	0.0	-0.1	0.0	0.0	0.1	0.2	0.0	0.1	0.0	0.1	0.1	-0.3	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem30_1_r10	-0.1	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.1	0.0	0.0	0.3	-0.3	-0.2	0.2	0.3	0.3	0.2	0.3	0.3
naem31_1_r10	-0.2	0.1	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.0	-0.1	0.2	0.0	0.1	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1
naem32_1_r10	-0.1	-0.1	0.0	0.0	0.1	0.1	0.0	0.0	0.0	0.1	0.1	-0.3	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0
naem33_1_r10	-0.1	-0.1	0.0	0.0	0.1	0.2	-0.1	0.1	0.0	0.1	0.1	-0.3	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
con_1_r10	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	-0.2	0.2	0.1	0.0	0.0	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1
dis_1_r10	-0.3	0.2	-0.2	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	0.0	0.0	0.2	0.0	0.0	0.5	-0.4	-0.2	0.3	0.5	0.4	0.3	0.4	0.4
hom_1_r10	-0.1	0.0	-0.1	0.0	0.1	0.1	0.0	0.1	0.0	0.1	0.2	-0.3	0.1	0.0	0.0	0.1	0.0	-0.1	0.0	0.1	0.0	0.0	0.0	0.0
asm_1_r10	-0.2	-0.1	-0.1	0.0	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.4	0.1	0.0	0.0	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.1	0.1
mxp_1_r10	-0.2	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.2	-0.5	0.1	0.0	0.0	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.1	0.1
ent_1_r10	0.2	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	-0.2	-0.1	0.3	-0.1	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.1	-0.1
mn1_1_r10	0.2	0.0	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	-0.2	-0.1	0.3	-0.1	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.2	-0.2
mn2_1_r10	0.3	0.0	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	-0.2	-0.1	0.3	-0.1	0.0	0.0	-0.4	0.3	0.2	-0.2	-0.4	-0.3	-0.2	-0.3	-0.3
vr1_1_r10	-0.1	-0.2	0.0	-0.1	0.1	0.2	0.0	0.1	0.0	0.2	0.1	-0.5	0.1	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1
vr2_1_r10	-0.1	-0.2	0.0	-0.1	0.1	0.2	0.0	0.1	0.0	0.2	0.1	-0.5	0.1	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1
cor_1_r10	0.1	-0.1	0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.1	0.2	-0.4	0.0	0.0	0.0	-0.3	0.3	0.1	-0.3	-0.3	-0.3	-0.2	-0.2	-0.3
naem00_2_r10	-0.2	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.2	-0.5	0.2	0.0	0.0	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.1	0.1
naem01_2_r10	0.2	0.0	0.2	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.5	-0.2	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem02_2_r10	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem03_2_r10	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.2	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem10_2_r10	0.0	0.2	0.0	0.0	-0.1	-0.1	0.0	-0.1	0.0	-0.1	-0.1	0.4	-0.1	0.0	0.0	0.1	0.0	0.0	0.1	0.1	0.1	0.1	0.0	0.1

R = 10 m	Openness_60	LAI2000Lin_60	LAI2000GLin_60	DirectSiteFactor_60	IndirectSiteFactor_60	TotalSiteFactor_60	PPFDDirectUnder_60	PPFDDiffuseUnder_60	PPFDTotalUnder_60	Openness_120	LAI2000Lin_120	LAI2000GLin_120	DirectSiteFactor_120	IndirectSiteFactor_120	TotalSiteFactor_120	PPFDDirectUnder_120	PPFDDiffuseUnder_120	PPFDTotalUnder_120	Openness_170	LAI2000Lin_170	LAI2000GLin_170	DirectSiteFactor_170	IndirectSiteFactor_170	TotalSiteFactor_170	PPFDDirectUnder_170	PPFDDiffuseUnder_170	PPFDTotalUnder_170
avg_vpv_0_r10	0.6	-0.5	-0.3	0.5	0.6	0.5	0.5	0.6	0.5	0.7	-0.7	-0.5	0.5	0.7	0.6	0.5	0.7	0.6	0.7	-0.5	-0.5	0.5	0.7	0.6	0.5	0.7	0.6
avg_vpv_1_r10	0.6	-0.5	-0.3	0.5	0.6	0.5	0.5	0.6	0.5	0.7	-0.7	-0.5	0.5	0.7	0.6	0.5	0.7	0.6	0.6	-0.4	-0.5	0.5	0.7	0.6	0.5	0.7	0.6
avg_vpv_2_r10	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.2	-0.1	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
avg_vpv_3_r10	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
avg_vpv_4_r10	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_5_r10	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_6_r10	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_7_r10	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_8_r10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_9_r10	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_10_r10	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_11_r10	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_12_r10	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_13_r10	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_14_r10	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.0	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_15_r10	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.1	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
avg_vpv_16_r10	-0.2	0.2	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_17_r10	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
avg_vpv_18_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_19_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_20_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_21_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_22_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
avg_vpv_23_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_24_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_25_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_26_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_27_r10	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_28_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_29_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_30_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_31_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_32_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1
avg_vpv_100_r10	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
avg_vpv_kumul_100do0_r10	-0.6	0.5	0.3	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5	-0.7	0.7	0.5	-0.5	-0.7	-0.6	-0.5	-0.7	-0.6	-0.7	0.5	0.5	-0.5	-0.7	-0.6	-0.5	-0.7	-0.6
avg_vpv_kumul_100do1_r10	-0.7	0.6	0.3	-0.5	-0.7	-0.5	-0.5	-0.7	-0.5	-0.8	0.7	0.5	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6	-0.7	0.5	0.5	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6
avg_vpv_kumul_100do2_r10	-0.7	0.6	0.3	-0.5	-0.7	-0.5	-0.5	-0.7	-0.5	-0.8	0.7	0.5	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6	-0.7	0.5	0.5	-0.6	-0.8	-0.6	-0.6	-0.8	-0.6
avg_vpv_kumul_100do3_r10	-0.7	0.6	0.3	-0.5	-0.7	-0.5	-0.5	-0.7	-0.5	-0.7	0.7	0.5	-0.6	-0.7	-0.6	-0.6	-0.7	-0.6	-0.7	0.4	0.5	-0.6	-0.7	-0.6	-0.6	-0.7	-0.6
avg_vpv_kumul_100do4_r10	-0.6	0.5	0.3	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5	-0.7	0.6	0.5	-0.5	-0.7	-0.5	-0.5	-0.7	-0.5	-0.6	0.4	0.5	-0.5	-0.7	-0.5	-0.5	-0.7	-0.5
avg_vpv_kumul_100do5_r10	-0.6	0.5	0.3	-0.4	-0.6	-0.5	-0.4	-0.6	-0.5	-0.6	0.5	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5	-0.5	0.3	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5
avg_vpv_kumul_100do6_r10	-0.5	0.5	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.5	0.5	0.4	-0.4	-0.6	-0.4	-0.4	-0.6	-0.4	-0.5	0.2	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do7_r10	-0.5	0.4	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.5	0.4	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.4	0.2	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do8_r10	-0.5	0.4	0.3	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.5	0.4	0.3	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.4	0.2	0.3	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4
avg_vpv_kumul_100do9_r10	-0.5	0.4	0.3	-0.3	-0.5	-0.3	-0.3	-0.5	-0.3	-0.4	0.4	0.3	-0.3	-0.5	-0.3	-0.3	-0.5	-0.3	-0.4	0.1	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do10_r10	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.1	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do11_r10	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.1	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do12_r10	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.1	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do13_r10	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.3	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.3	0.1	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3
avg_vpv_kumul_100do14_r10	-0.4	0.4	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.3	0.3	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2	-0.3	0.1	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2
avg_vpv_kumul_100do15_r10	-0.4	0.3	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.3	0.3	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do16_r10	-0.4	0.3	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do17_r10	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do18_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do19_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do20_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do21_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
avg_vpv_kumul_100do22_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do23_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do24_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do25_r10	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do26_r10	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do27_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do28_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do29_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do30_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1
avg_vpv_kumul_100do31_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
stdev_vpv_0_r10	0.6	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.6	-0.6	-0.4	0.5	0.6	0.5	0.5	0.6	0.5	0.5	-0.4	-0.4	0.5	0.6	0.5	0.5	0.6	0.5
stdev_vpv_1_r10	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.5	-0.5	-0.4	0.5	0.6	0.5	0.5	0.6	0.5	0.5	-0.3	-0.4	0.5	0.5	0.5	0.5	0.5	0.5
stdev_vpv_2_r10	0.3	-0.3	-0.2	0.3	0.3	0.3	0.3	0.3	0.3	0.3	-0.3	-0.2	0.2	0.3	0.3	0.2	0.3	0.3	0.3	-0.1	-0.2	0.2	0.3	0.3	0.2	0.3	0.3
stdev_vpv_3_r10	0.2	-0.2	-0.1	0.1	0.2	0.2	0.1	0.2	0.2	0.1	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.1	0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_4_r10	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.2	-0.1	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_5_r10	0.1	-0.1	-0.1	0.0	0.1	0.1	0.0	0.1	0.1	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_6_r10	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_7_r10	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_8_r10	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.2	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_9_r10	0.0	0.0	-0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_10_r10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_11_r10	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_12_r10	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.1	0.1	0.0	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2
stdev_vpv_13_r10	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_14_r10	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_15_r10	-0.2	0.2	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_16_r10	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_17_r10	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_18_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_19_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_20_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_21_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_22_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_23_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_24_r10	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.1	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_25_r10	-0.3	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_26_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_27_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_28_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_29_r10	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_30_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_31_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_32_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_100_r10	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
stdev_vpv_kumul_100do0_r10	0.6	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.6	-0.6	-0.4	0.5	0.6	0.5	0.5	0.6	0.5	0.5	-0.4	-0.4	0.5	0.6	0.5	0.5	0.6	0.5
stdev_vpv_kumul_100do1_r10	0.5	-0.4	-0.2	0.4	0.5	0.4	0.4	0.5	0.4	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.3	-0.3	0.4	0.5	0.4	0.4	0.5	0.4
stdev_vpv_kumul_100do2_r10	0.5	-0.4	-0.2	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.3	-0.3	0.4	0.4	0.4	0.4	0.4	0.4
stdev_vpv_kumul_100do3_r10	0.4	-0.4	-0.2	0.3	0.4	0.4	0.3	0.4	0.4	0.4	-0.4	-0.3	0.3	0.4	0.3	0.3	0.4	0.3	0.3	-0.2	-0.3	0.3	0.4	0.3	0.3	0.4	0.3
stdev_vpv_kumul_100do4_r10	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.3	-0.3	-0.2	0.3	0.3	0.3	0.3	0.3	0.3	0.2	-0.1	-0.2	0.3	0.3	0.3	0.3	0.3	0.3
stdev_vpv_kumul_100do5_r10	0.3	-0.3	-0.2	0.2	0.3	0.3	0.2	0.3	0.3	0.2	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.1	0.0	-0.2	0.2	0.2	0.2	0.2	0.2	0.2
stdev_vpv_kumul_100do6_r10	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.1	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.1	0.0	-0.1	0.1	0.2	0.1	0.1	0.2	0.1
stdev_vpv_kumul_100do7_r10	0.2	-0.2	-0.1	0.1	0.2	0.2	0.1	0.2	0.2	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_kumul_100do8_r10	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	0.0	0.1	0.0	0.1	0.1	0.0	0.1	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_kumul_100do9_r10	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_kumul_100do10_r10	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.2	0.2	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1
stdev_vpv_kumul_100do11_r10	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.2	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do12_r10	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do13_r10	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do14_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do15_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do16_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do17_r10	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do18_r10	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do19_r10	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do20_r10	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do21_r10	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do22_r10	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do23_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do24_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do25_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do26_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do27_r10	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do28_r10	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do29_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do30_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do31_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
dof_ndvi_gurs_r10_avg	-0.1	0.2	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.1	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.1	0.1	0.1	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2
dof_ndvi_gurs_r10_std	0.2	-0.2	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.1	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
dof_ndvi_geoin_r10_avg	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
dof_ndvi_geoin_r10_std	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	-0.1	0.0	0.0	0.1	0.0	0.0	0.1	0.0
naem00_1_r10	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
naem01_1_r10	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.2	0.2	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem02_1_r10	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem03_1_r10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem10_1_r10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem11_1_r10	0.0	0.0	0.1	0.1	0.0	0.1	0.1	0.0	0.1	-0.1	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem12_1_r10	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
naem13_1_r10	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem20_1_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem21_1_r10	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem22_1_r10	-0.3	0.3	0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	0.3	0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	0.2	0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3
naem23_1_r10	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem30_1_r10	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.4	-0.4	-0.3	0.3	0.4	0.3	0.3	0.4	0.3	0.3	-0.3	-0.3	0.3	0.4	0.3	0.3	0.4	0.3
naem31_1_r10	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.3	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.3	-0.2	-0.1	0.2	0.3	0.2	0.2	0.3	0.2
naem32_1_r10	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	0.0
naem33_1_r10	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.2	-0.1	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.2	-0.1	-0.2	0.1	0.2	0.1	0.1	0.2	0.1
con_1_r10	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
dis_1_r10	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.6	-0.6	-0.4	0.4	0.6	0.5	0.4	0.6	0.5	0.5	-0.4	-0.4	0.4	0.6	0.5	0.4	0.6	0.5
hom_1_r10	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.2	-0.2	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.2	-0.2	-0.1	0.1	0.2	0.1	0.1	0.2	0.1
asm_1_r10	0.2	-0.2	-0.2	0.1	0.2	0.2	0.1	0.2	0.2	0.4	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.4	-0.3	-0.3	0.2	0.4	0.2	0.2	0.4	0.2
mxp_1_r10	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.3	-0.3	0.2	0.3	0.2	0.2	0.3	0.2
ent_1_r10	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.4	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.4	0.3	0.2	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2
mn1_1_r10	-0.3	0.3	0.2	-0.2	-0.3	-0.3	-0.2	-0.3	-0.3	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.5	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
mn2_1_r10	-0.5	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.6	0.5	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.5	0.4	0.4	-0.4	-0.6	-0.4	-0.4	-0.6	-0.4
vr1_1_r10	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1
vr2_1_r10	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1
cor_1_r10	-0.3	0.3	0.1	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	0.3	0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	0.1	0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3
naem00_2_r10	0.2	-0.2	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.3	-0.3	0.2	0.3	0.2	0.2	0.3	0.2
naem01_2_r10	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem02_2_r10	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.1	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.1	0.1	0.1	-0.2	-0.1	-0.2	-0.2	-0.1	-0.2
naem03_2_r10	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1
naem10_2_r10	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	0.0	0.1	0.0	0.1	0.1	0.0	0.1	-0.1	0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0

R = 20 m

	gha	deligl	delbukev	deljavor	delbgaber	delcgaber	delhrast	delmjesen	delvjesen	delostalist	delsmreka	deljelka	delbor	delmacesen	delostaligl	Openness_45	LAI2000Lin_45	LAI2000GLin_45	DirectSiteFactor_45	IndirectSiteFactor_45	TotalSiteFactor_45	PPFDDirectUnder_45	PPFDDiffuseUnder_45	PPFDTotalUnder_45	Openness_60	LAI2000Lin_60	LAI2000GLin_60	DirectSiteFactor_60	IndirectSiteFactor_60	TotalSiteFactor_60	PPFDDirectUnder_60	PPFDDiffuseUnder_60	PPFDTotalUnder_60	Openness_120	LAI2000Lin_120	LAI2000GLin_120	DirectSiteFactor_120	IndirectSiteFactor_120	TotalSiteFactor_120	PPFDDirectUnder_120	PPFDDiffuseUnder_120	PPFDTotalUnder_120	Openness_170	LAI2000Lin_170	LAI2000GLin_170	DirectSiteFactor_170	IndirectSiteFactor_170	TotalSiteFactor_170	PPFDDirectUnder_170	PPFDDiffuseUnder_170	PPFDTotalUnder_170
avg_vpv_0_r20	-0.3	0.2	-0.2	-0.1	0.0	-0.1	0.1	-0.1	-0.1	0.2	0.0	0.0	0.2	0.0	0.0	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.3	0.3	0.5	-0.4	-0.2	0.3	0.5	0.4	0.3	0.5	0.4	0.6	-0.6	-0.4	0.4	0.6	0.4	0.4	0.6	0.4	0.6	-0.5	-0.4	0.4	0.6	0.5	0.4	0.6	0.5
avg_vpv_1_r20	-0.3	0.2	-0.3	-0.1	-0.1	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	0.2	0.0	0.0	0.4	-0.4	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.5	-0.4	-0.2	0.4	0.5	0.4	0.4	0.5	0.4	0.6	-0.6	-0.4	0.5	0.6	0.5	0.5	0.6	0.5	0.6	-0.5	-0.4	0.5	0.6	0.5	0.5	0.6	0.5
avg_vpv_2_r20	-0.3	0.1	-0.2	-0.1	-0.1	0.0	0.0	0.0	0.0	0.2	0.2	-0.1	0.0	0.0	0.0	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.3	-0.2	-0.1	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.2	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.2	-0.1	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
avg_vpv_3_r20	-0.3	0.1	-0.3	-0.1	-0.1	0.0	0.1	0.0	0.0	0.3	0.2	-0.1	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
avg_vpv_4_r20	-0.4	0.1	-0.3	-0.2	-0.1	0.0	0.1	0.0	0.0	0.4	0.2	-0.2	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.1	0.0
avg_vpv_5_r20	-0.4	0.1	-0.3	-0.2	0.0	0.1	0.1	0.0	0.0	0.3	0.3	-0.2	0.0	0.0	0.0	0.1	0.0	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_6_r20	-0.3	0.1	-0.3	-0.2	0.0	0.1	0.1	0.0	-0.1	0.2	0.3	-0.3	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1
avg_vpv_7_r20	-0.3	0.2	-0.3	-0.2	0.0	0.1	0.1	0.1	-0.1	0.2	0.3	-0.3	0.1	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_8_r20	-0.2	0.2	-0.3	-0.2	0.0	0.2	0.0	0.2	-0.1	0.1	0.3	-0.3	0.2	0.0	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_9_r20	-0.1	0.2	-0.3	-0.3	0.0	0.2	0.0	0.2	-0.1	0.1	0.3	-0.3	0.2	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1
avg_vpv_10_r20	-0.1	0.2	-0.3	-0.2	0.0	0.1	0.0	0.2	0.0	0.0	0.2	-0.3	0.3	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1
avg_vpv_11_r20	0.0	0.2	-0.3	-0.3	0.0	0.2	0.1	0.3	0.0	0.0	0.2	-0.3	0.3	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_12_r20	0.1	0.2	-0.3	-0.2	0.1	0.2	0.1	0.2	0.0	0.0	0.1	-0.2	0.3	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_13_r20	0.1	0.1	-0.2	-0.2	0.2	0.2	0.1	0.1	0.0	-0.1	0.0	-0.2	0.3	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_14_r20	0.2	0.0	-0.1	-0.2	0.3	0.1	0.1	0.1	0.1	-0.1	0.0	-0.1	0.2	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_15_r20	0.2	0.0	0.0	-0.1	0.3	0.1	0.0	0.0	0.1	-0.1	-0.1	-0.1	0.1	0.0	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.1	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
avg_vpv_16_r20	0.3	-0.1	0.1	-0.1	0.3	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_17_r20	0.3	-0.1	0.2	0.0	0.2	0.0	0.0	0.0	0.0	-0.2	-0.1	0.1	-0.1	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
avg_vpv_18_r20	0.3	-0.2	0.3	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	0.0	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_19_r20	0.3	-0.2	0.4	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.3	-0.3	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_20_r20	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.3	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_21_r20	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.2	0.3	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
avg_vpv_22_r20	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_23_r20	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_24_r20	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_25_r20	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_26_r20	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_27_r20	0.2	-0.3	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.1	-0.3	0.2	-0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_28_r20	0.2	-0.2	0.3	0.4	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_29_r20	0.2	-0.2	0.3	0.4	-0.1	-0.1	-0.1	0.0	0.3	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_30_r20	0.2	-0.2	0.2	0.3	-0.1	-0.1	-0.1	0.0	0.3	-0.1	-0.2	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_31_r20	0.1	-0.1	0.2	0.2	0.0	0.0	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_32_r20	0.1	0.0	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_100_r20	0.1	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
avg_vpv_kumul_100do0_r20	0.3	-0.2	0.2	0.1	0.0	0.1	-0.1	0.1	0.1	-0.2	0.0	0.0	-0.2	0.0	0.0	-0.4	0.3	0.2	-0.3	-0.4	-0.3	-0.3	-0.3	-0.3	-0.5	0.4	0.2	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.6	0.6	0.4	-0.4	-0.6	-0.4	-0.4	-0.6	-0.4	-0.6	0.5	0.4	-0.4	-0.6	-0.5	-0.4	-0.6	-0.5
avg_vpv_kumul_100do1_r20	0.3	-0.2	0.3	0.1	0.1	0.1	0.0	0.1	0.1	-0.1	0.0	0.0	-0.2	0.0	0.0	-0.5	0.4	0.2	-0.3	-0.5	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.7	0.6	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5	-0.6	0.5	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5
avg_vpv_kumul_100do2_r20	0.4	-0.2	0.3	0.1	0.1	0.1	0.0	0.1	0.1	-0.2	0.0	0.1	-0.2	0.0	0.0	-0.5	0.4	0.2	-0.3	-0.5	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.7	0.6	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5	-0.6	0.5	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5
avg_vpv_kumul_100do3_r20	0.4	-0.2	0.3	0.1	0.1	0.1	-0.1	0.1	0.1	-0.2	-0.1	0.1	-0.2	0.0	0.0	-0.5	0.4	0.2	-0.3	-0.5	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.6	0.6	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5	-0.6	0.5	0.4	-0.5	-0.6	-0.5	-0.5	-0.6	-0.5
avg_vpv_kumul_100do4_r20	0.4	-0.2	0.3	0.1	0.1	0.1	-0.1	0.1	0.1	-0.3	-0.1	0.1	-0.2	0.0	0.0	-0.4	0.4	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.2	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.6	0.6	0.4	-0.4	-0.6	-0.5	-0.4	-0.6	-0.5	-0.6	0.4	0.4	-0.4	-0.6	-0.5	-0.4	-0.6	-0.5
avg_vpv_kumul_100do5_r20	0.5	-0.2	0.4	0.1	0.1	0.1	-0.1	0.1	0.1	-0.3	-0.2	0.2	-0.2	0.0	0.0	-0.4	0.3	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.2	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.5	0.5	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.5	0.4	0.4	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do6_r20	0.5	-0.2	0.4	0.2	0.1	0.0	-0.1	0.0	0.1	-0.3	-0.2	0.2	-0.2	0.0	0.0	-0.4	0.3	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.3	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4	-0.5	0.3	0.3	-0.4	-0.5	-0.4	-0.4	-0.5	-0.4
avg_vpv_kumul_100do7_r20	0.5	-0.2	0.4	0.2	0.1	0.0	-0.1	0.0	0.1	-0.3	-0.3	0.2	-0.2	0.0	0.0	-0.4	0.3	0.2	-0.3	-0.4	-0.3	-0.3	-0.3	-0.3	-0.4	0.3	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.5	0.4	0.3	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.4	0.3	0.3	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4
avg_vpv_kumul_100do8_r20	0.5	-0.3	0.5	0.2	0.1	0.0	-0.1	0.0	0.1	-0.3	-0.3	0.3	-0.2	0.0	-0.1	-0.4	0.3	0.2	-0.2	-0.4	-0.3	-0.2	-0.3	-0.3	-0.4	0.3	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.2	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do9_r20	0.5	-0.3	0.5	0.2	0.1	0.0	-0.1	0.0	0.1	-0.3	-0.3	0.3	-0.2	0.0	-0.1	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.4	0.3	0.2	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.2	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do10_r20	0.5	-0.3	0.5	0.3	0.1	0.0	-0.1	-0.1	0.1	-0.3	-0.3	0.3	-0.2	0.0	-0.1	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.4	0.3	0.2	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.4	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.2	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do11_r20	0.5	-0.3	0.5	0.3	0.1	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.3	-0.3	0.0	-0.1	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.4	0.3	0.2	-0.2	-0.3	-0.3	-0.2	-0.3	-0.3	-0.4	0.3	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.3	0.2	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
avg_vpv_kumul_100do12_r20	0.5	-0.3	0.5	0.3	0.1	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.3	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.4	0.3	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.3	0.2	0.3	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3
avg_vpv_kumul_100do13_r20	0.5	-0.3	0.6	0.3	0.0	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2	-0.3	0.2	0.3	-0.2	-0.4	-0.2	-0.2	-0.4	-0.2
avg_vpv_kumul_100do14_r20	0.4	-0.3	0.6	0.3	0.0	-0.1	-0.1	-0.1	0.1	-0.3	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do15_r20	0.4	-0.3	0.6	0.4	0.0	-0.1	-0.2	-0.1	0.1	-0.3	-0.3	0.4	-0.4	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do16_r20	0.4	-0.3	0.6	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.3	-0.3	0.4	-0.4	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do17_r20	0.4	-0.3	0.6	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.3	-0.3	0.4	-0.4	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do18_r20	0.4	-0.3	0.6	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.3	-0.3	0.4	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do19_r20	0.3	-0.3	0.6	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
avg_vpv_kumul_100do20_r20	0.3	-0.3	0.5	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.1	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2
avg_vpv_kumul_100do21_r20	0.3	-0.3	0.5	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do22_r20	0.3	-0.3	0.5	0.4	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do23_r20	0.3	-0.3	0.4	0.4	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.3	0.3	-0.3	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do24_r20	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do25_r20	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.3	0.3	-0.2	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do26_r20	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
avg_vpv_kumul_100do27_r20	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do28_r20	0.2	-0.2	0.2	0.3	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.2	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do29_r20	0.1	-0.1	0.2	0.2	-0.1	-0.1	-0.1	0.0	0.2	-0.1	-0.2	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do30_r20	0.1	-0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.2	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_kumul_100do31_r20	0.1	0.0	0.1	0.1	0.0	0.0	-0.1	0.0	0.1	-0.1	-0.1	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1
stdev_vpv_0_r20	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.1	-0.1	-0.1	0.1	0.0	0.1	0.2	0.1	0.0	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.3	0.3	0.4	-0.4	-0.2	0.3	0.4	0.4	0.3	0.4	0.4	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.5	-0.4	-0.3	0.4	0.5	0.4	0.4	0.5	0.4
stdev_vpv_1_r20	-0.3	0.3	-0.3	-0.1	-0.1	-0.1	0.1	0.0	-0.1	0.1	0.1	0.0	0.2	0.0	0.0	0.4	-0.3	-0.1	0.3	0.4	0.3	0.3	0.3	0.3	0.4	-0.4	-0.2	0.4	0.4	0.4	0.4	0.4	0.4	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.5	-0.4	-0.3	0.4	0.5	0.4	0.4	0.5	0.4
stdev_vpv_2_r20	-0.3	0.2	-0.3	-0.1	-0.1	0.0	0.1	-0.1	0.0	0.2	0.2	-0.1	0.1	0.0	0.0	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.3	-0.2	-0.1	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.2	-0.1	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
stdev_vpv_3_r20	-0.3	0.2	-0.3	-0.1	-0.1	0.0	0.1	-0.1	0.0	0.2	0.2	-0.1	0.1	0.0	0.0	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.1	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.1	0.0	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_4_r20	-0.4	0.2	-0.4	-0.2	-0.1	0.0	0.1	0.0	0.0	0.3	0.3	-0.2	0.1	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.2	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	-0.1	0.0	0.1	0.1	0.0	0.1	0.1	0.0	0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0
stdev_vpv_5_r20	-0.4	0.2	-0.4	-0.2	-0.1	0.1	0.2	0.0	-0.1	0.3	0.3	-0.2	0.1	0.1	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_6_r20	-0.3	0.2	-0.4	-0.2	-0.1	0.1	0.2	0.0	-0.1	0.3	0.3	-0.2	0.1	0.1	0.0	0.1	-0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_7_r20	-0.3	0.3	-0.4	-0.3	-0.1	0.1	0.1	0.1	-0.1	0.2	0.3	-0.2	0.1	0.0	0.0	0.1	-0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.1	-0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_8_r20	-0.2	0.3	-0.4	-0.3	0.0	0.1	0.1	0.2	-0.1	0.1	0.3	-0.2	0.2	0.0	0.1	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_9_r20	-0.1	0.3	-0.4	-0.3	0.0	0.2	0.1	0.2	-0.1	0.1	0.3	-0.2	0.2	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_10_r20	-0.1	0.2	-0.3	-0.3	0.0	0.1	0.1	0.2	-0.1	0.1	0.2	-0.2	0.3	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1
stdev_vpv_11_r20	0.0	0.2	-0.3	-0.3	0.1	0.2	0.1	0.2	-0.1	0.0	0.1	-0.2	0.3	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_12_r20	0.1	0.2	-0.2	-0.2	0.1	0.1	0.1	0.2	0.0	0.0	0.1	-0.1	0.3	0.0	0.0	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_13_r20	0.2	0.1	-0.2	-0.2	0.2	0.1	0.0	0.1	0.0	-0.1	0.0	-0.1	0.2	0.0	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.0	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.0	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_14_r20	0.2	0.1	-0.1	-0.2	0.2	0.1	0.0	0.0	0.0	-0.2	0.0	0.0	0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_15_r20	0.3	0.0	0.0	-0.1	0.2	0.0	0.0	0.0	0.0	-0.2	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_16_r20	0.3	-0.1	0.2	0.0	0.2	0.0	0.0	-0.1	0.0	-0.2	-0.2	0.2	-0.1	0.0	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
stdev_vpv_17_r20	0.3	-0.1	0.3	0.1	0.2	-0.1	0.0	-0.1	0.0	-0.2	-0.2	0.2	-0.2	0.0	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_18_r20	0.3	-0.2	0.4	0.2	0.1	-0.1	-0.1	-0.1	0.0	-0.3	-0.2	0.3	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_19_r20	0.3	-0.2	0.5	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.3	-0.2	0.4	-0.3	0.0	0.0	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_20_r20	0.4	-0.2	0.5	0.3	-0.1	-0.1	-0.1	-0.1	0.0	-0.3	-0.3	0.4	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_21_r20	0.3	-0.3	0.5	0.3	-0.1	-0.2	-0.2	-0.1	0.0	-0.3	-0.3	0.4	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.2	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.3	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.3	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
stdev_vpv_22_r20	0.3	-0.3	0.6	0.3	-0.1	-0.2	-0.2	-0.1	0.0	-0.3	-0.3	0.5	-0.4	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_23_r20	0.3	-0.3	0.5	0.3	-0.1	-0.2	-0.2	-0.1	0.0	-0.3	-0.3	0.5	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_24_r20	0.3	-0.3	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.3	-0.3	0.5	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_25_r20	0.3	-0.2	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.3	-0.3	0.5	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_26_r20	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_27_r20	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_28_r20	0.2	-0.2	0.4	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.4	-0.3	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_29_r20	0.2	-0.2	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.3	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_30_r20	0.2	-0.1	0.2	0.3	-0.1	-0.1	-0.1	-0.1	0.2	-0.2	-0.3	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_31_r20	0.2	-0.1	0.2	0.2	-0.1	-0.1	-0.1	-0.1	0.2	-0.1	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.1	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_32_r20	0.1	0.0	0.2	0.1	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_100_r20	0.1	0.0	0.1	0.1	0.0	-0.1	-0.1	0.0	0.0	-0.1	-0.2	0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do0_r20	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.1	-0.1	-0.1	0.1	0.0	0.1	0.2	0.1	0.0	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.3	0.3	0.4	-0.4	-0.2	0.3	0.4	0.4	0.3	0.4	0.4	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.5	-0.4	-0.3	0.4	0.5	0.4	0.4	0.5	0.4
stdev_vpv_kumul_100do1_r20	-0.3	0.2	-0.3	-0.1	-0.1	-0.1	0.1	-0.1	-0.1	0.1	0.0	0.1	0.2	0.0	0.0	0.4	-0.3	-0.1	0.3	0.4	0.3	0.3	0.3	0.3	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.3	-0.3	0.4	0.5	0.4	0.4	0.5	0.4
stdev_vpv_kumul_100do2_r20	-0.3	0.2	-0.3	-0.1	-0.1	-0.1	0.1	-0.1	-0.1	0.1	0.0	0.0	0.2	0.0	0.0	0.4	-0.3	-0.1	0.3	0.4	0.3	0.3	0.3	0.3	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.4	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.3	-0.3	0.4	0.4	0.4	0.4	0.4	0.4
stdev_vpv_kumul_100do3_r20	-0.3	0.3	-0.3	-0.1	-0.1	-0.1	0.1	-0.1	-0.1	0.1	0.1	0.0	0.2	0.0	0.0	0.3	-0.3	-0.1	0.3	0.3	0.3	0.3	0.3	0.3	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.4	-0.4	-0.3	0.3	0.4	0.4	0.3	0.4	0.4	0.4	-0.3	-0.3	0.3	0.4	0.3	0.3	0.4	0.3
stdev_vpv_kumul_100do4_r20	-0.3	0.3	-0.4	-0.1	-0.1	-0.1	0.1	-0.1	-0.1	0.1	0.1	0.0	0.2	0.0	0.0	0.3	-0.3	-0.1	0.2	0.3	0.2	0.2	0.3	0.3	0.3	-0.3	-0.1	0.3	0.3	0.3	0.3	0.3	0.3	0.3	-0.4	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.3	-0.2	-0.2	0.3	0.3	0.3	0.3	0.3	0.3
stdev_vpv_kumul_100do5_r20	-0.3	0.3	-0.4	-0.1	-0.1	-0.1	0.1	-0.1	-0.1	0.1	0.2	0.0	0.2	0.0	0.0	0.3	-0.2	-0.1	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.2	-0.1	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.2	-0.1	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
stdev_vpv_kumul_100do6_r20	-0.3	0.4	-0.4	-0.2	-0.1	-0.1	0.1	0.0	-0.1	0.1	0.2	0.0	0.2	0.0	0.0	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.3	0.2	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.2	-0.2	-0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.1	0.0	-0.1	0.2	0.2	0.2	0.2	0.2	0.2
stdev_vpv_kumul_100do7_r20	-0.2	0.4	-0.4	-0.2	-0.1	-0.1	0.1	0.0	-0.1	0.0	0.2	0.0	0.2	0.0	0.0	0.2	-0.2	-0.1	0.1	0.2	0.2	0.1	0.2	0.2	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_kumul_100do8_r20	-0.1	0.4	-0.3	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	0.2	0.1	0.2	0.0	0.0	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.2	0.1	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1	0.0	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_kumul_100do9_r20	0.0	0.4	-0.3	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	0.1	0.1	0.1	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	0.1	0.1	0.1	0.1	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_kumul_100do10_r20	0.1	0.3	-0.2	-0.1	-0.1	-0.1	0.0	0.0	-0.1	-0.2	0.1	0.2	0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.2	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
stdev_vpv_kumul_100do11_r20	0.1	0.2	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	-0.2	0.0	0.3	0.0	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do12_r20	0.2	0.2	0.0	0.0	0.0	-0.1	0.0	-0.1	0.0	-0.3	-0.1	0.3	0.0	0.0	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do13_r20	0.3	0.1	0.1	0.1	0.0	-0.1	0.0	-0.1	0.0	-0.3	-0.1	0.4	-0.1	0.0	-0.1	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do14_r20	0.3	0.0	0.2	0.1	0.0	-0.1	-0.1	-0.1	0.0	-0.3	-0.2	0.4	-0.2	0.0	-0.1	-0.2	0.1	0.1	0.0	-0.2	-0.1	0.0	-0.1	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do15_r20	0.3	0.0	0.3	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.3	-0.2	0.5	-0.3	0.0	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do16_r20	0.3	-0.1	0.3	0.2	0.0	-0.1	-0.1	-0.1	0.0	-0.3	-0.2	0.5	-0.4	0.0	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do17_r20	0.3	-0.1	0.4	0.2	0.0	-0.2	-0.1	-0.1	0.0	-0.3	-0.2	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do18_r20	0.3	-0.1	0.4	0.3	-0.1	-0.2	-0.1	-0.2	0.0	-0.3	-0.2	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
stdev_vpv_kumul_100do19_r20	0.3	-0.2	0.5	0.3	-0.1	-0.2	-0.2	-0.2	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do20_r20	0.3	-0.2	0.5	0.3	-0.1	-0.2	-0.2	-0.2	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do21_r20	0.3	-0.2	0.5	0.3	-0.1	-0.2	-0.2	-0.2	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do22_r20	0.3	-0.2	0.5	0.3	-0.1	-0.2	-0.2	-0.1	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.2	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1	-0.3	0.2	0.3	-0.1	-0.3	-0.1	-0.1	-0.3	-0.1
stdev_vpv_kumul_100do23_r20	0.3	-0.2	0.5	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do24_r20	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.0	-0.3	-0.3	0.6	-0.4	0.0	0.0	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do25_r20	0.3	-0.2	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.6	-0.3	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do26_r20	0.3	-0.1	0.4	0.3	-0.1	-0.1	-0.2	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do27_r20	0.2	-0.1	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do28_r20	0.2	-0.1	0.3	0.3	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.3	0.5	-0.3	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.2	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do29_r20	0.2	-0.1	0.2	0.2	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.2	0.5	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
stdev_vpv_kumul_100do30_r20	0.2	0.0	0.2	0.2	-0.1	-0.1	-0.1	-0.1	0.1	-0.2	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do31_r20	0.1	0.0	0.2	0.1	-0.1	-0.1	-0.1	-0.1	0.1	-0.1	-0.2	0.4	-0.2	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
dof_ndvi_gurs_r20_avg	-0.2	-0.4	0.1	0.0	0.0	0.1	0.2	0.1	0.0	0.3	0.0	-0.3	-0.1	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
dof_ndvi_gurs_r20_std	0.0	0.3	-0.2	0.0	0.0	-0.1	-0.1	-0.1	-0.1	0.0	0.0	0.3	0.0	0.0	0.0	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.1	0.1	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
dof_ndvi_geoin_r20_avg	0.0	-0.7	0.6	0.3	0.1	0.2	0.1	0.0	0.0	0.0	-0.3	0.1	-0.5	0.0	-0.1	-0.2	0.3	0.2	-0.1	-0.2	-0.1	-0.1	-0.3	-0.1	-0.2	0.3	0.2	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.3	0.3	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2	-0.2	0.2	0.3	-0.1	-0.3	-0.2	-0.1	-0.3	-0.2
dof_ndvi_geoin_r20_std	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem00_1_r20	-0.2	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.5	0.2	0.0	0.0	0.2	-0.1	-0.2	0.0	0.2	0.0	0.0	0.1	0.0	0.2	-0.1	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.3	-0.2	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.3	-0.3	-0.2	0.1	0.3	0.2	0.1	0.3	0.2
naem01_1_r20	0.1	0.0	0.2	0.2	0.0	0.0	-0.1	0.0	0.0	-0.2	-0.2	0.4	-0.1	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem02_1_r20	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	0.0	-0.1	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem03_1_r20	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem10_1_r20	0.0	0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.3	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0
naem11_1_r20	0.1	0.2	0.0	0.1	-0.1	-0.2	-0.1	-0.1	0.0	-0.2	-0.1	0.5	-0.2	0.0	0.0	0.0	0.0	0.1	0.1	0.0	0.1	0.1	0.0	0.1	0.0	0.0	0.1	0.1	0.0	0.1	0.1	0.0	0.1	0.0	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.1	0.0	0.0	0.0	0.0	0.0	0.0
naem12_1_r20	0.2	-0.1	0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	0.0	0.1	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.2	0.2	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.1	0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2
naem13_1_r20	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	-0.1	0.1	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem20_1_r20	0.1	-0.1	0.1	0.1	0.1	0.0	0.0	0.0	0.0	0.0	-0.2	0.1	0.0	0.0	0.0	0.0	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
naem21_1_r20	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	0.1	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1
naem22_1_r20	0.2	0.0	0.1	-0.1	0.0	0.0	0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.0	0.0	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
naem23_1_r20	-0.1	-0.1	0.0	0.0	0.1	0.2	-0.1	0.1	0.0	0.1	0.0	-0.2	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0
naem30_1_r20	-0.1	0.1	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.3	-0.2	-0.1	0.2	0.3	0.3	0.2	0.3	0.3	0.3	-0.3	-0.2	0.3	0.3	0.3	0.3	0.3	0.3	0.3	-0.3	-0.2	0.3	0.3	0.3	0.3	0.3	0.3
naem31_1_r20	-0.1	0.1	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.0	-0.1	0.2	0.0	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.2	-0.2	-0.1	0.2	0.2	0.2	0.2	0.2	0.2	0.3	-0.2	-0.2	0.2	0.2	0.2	0.2	0.2	0.2
naem32_1_r20	-0.1	-0.2	0.0	0.0	0.1	0.2	0.0	0.1	0.0	0.2	0.0	-0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem33_1_r20	-0.2	-0.1	-0.1	0.0	0.1	0.2	0.0	0.1	0.0	0.2	0.1	-0.3	0.0	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1
con_1_r20	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.2	0.1	0.1	0.0	0.0	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	0.0	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.2	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
dis_1_r20	-0.3	0.2	-0.2	0.0	-0.1	-0.1	0.1	-0.1	-0.1	0.1	0.0	0.0	0.2	0.0	0.0	0.4	-0.3	-0.2	0.3	0.4	0.3	0.3	0.3	0.3	0.4	-0.4	-0.2	0.3	0.4	0.3	0.3	0.4	0.3	0.5	-0.5	-0.3	0.4	0.5	0.4	0.4	0.5	0.4	0.4	-0.4	-0.3	0.4	0.5	0.4	0.4	0.5	0.4
hom_1_r20	-0.1	0.1	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.2	-0.2	0.0	-0.1	0.0	0.1	-0.1	-0.1	0.0	0.1	0.0	0.0	0.1	0.0	0.1	-0.1	-0.1	0.0	0.1	0.1	0.0	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	-0.1	-0.1	0.1	0.1	0.1	0.1	0.1	0.1
asm_1_r20	-0.2	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.3	0.1	0.0	0.0	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.1	0.1	0.2	-0.2	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
mxp_1_r20	-0.2	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.3	0.1	0.0	0.0	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.1	0.1	0.2	-0.1	-0.1	0.1	0.2	0.1	0.1	0.2	0.1	0.3	-0.2	-0.2	0.2	0.2	0.2	0.2	0.2	0.2	0.3	-0.3	-0.2	0.2	0.3	0.2	0.2	0.3	0.2
ent_1_r20	0.2	0.0	0.1	0.1	-0.1	-0.1	0.0	0.0	0.0	-0.2	-0.1	0.2	0.0	0.0	0.0	-0.2	0.2	0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.1	-0.2	0.2	0.1	-0.1	-0.2	-0.2	-0.1	-0.2	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
mn1_1_r20	0.2	0.0	0.1	0.0	-0.1	-0.1	0.0	0.0	0.0	-0.2	-0.1	0.3	-0.1	0.0	0.0	-0.3	0.2	0.2	-0.1	-0.3	-0.1	-0.1	-0.2	-0.1	-0.3	0.2	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3	-0.4	0.4	0.3	-0.3	-0.4	-0.3	-0.3	-0.4	-0.3
mn2_1_r20	0.3	0.0	0.1	0.0	-0.1	-0.1	0.0	0.0	0.0	-0.2	-0.1	0.3	-0.2	0.0	0.0	-0.3	0.3	0.2	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.4	0.3	0.2	-0.2	-0.4	-0.3	-0.2	-0.4	-0.3	-0.5	0.5	0.3	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4	-0.5	0.4	0.4	-0.3	-0.5	-0.4	-0.3	-0.5	-0.4
vr1_1_r20	-0.1	-0.2	0.0	-0.1	0.1	0.2	0.1	0.1	0.0	0.2	0.1	-0.5	0.2	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0
vr2_1_r20	-0.1	-0.2	0.0	-0.1	0.1	0.2	0.1	0.1	0.0	0.2	0.1	-0.5	0.2	0.0	0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	-0.1	0.0	-0.1	-0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0
cor_1_r20	0.1	-0.1	0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.0	0.1	-0.3	0.0	0.0	0.0	-0.2	0.2	0.0	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.2	0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	0.3	0.1	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2	-0.2	0.1	0.1	-0.2	-0.3	-0.2	-0.2	-0.3	-0.2
naem00_2_r20	-0.2	-0.1	-0.1	-0.1	0.1	0.1	0.0	0.1	0.0	0.2	0.1	-0.5	0.2	0.0	0.0	0.2	-0.1	-0.2	0.0	0.2	0.1	0.0	0.1	0.0	0.2	-0.1	-0.2	0.1	0.2	0.1	0.1	0.2	0.1	0.3	-0.3	-0.2	0.1	0.2	0.2	0.1	0.2	0.2	0.3	-0.3	-0.2	0.1	0.3	0.2	0.1	0.3	0.2
naem01_2_r20	0.2	-0.1	0.3	0.2	-0.1	-0.1	-0.1	-0.1	0.0	-0.2	-0.3	0.5	-0.2	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.1	0.1	0.0	-0.1	0.0	0.0	-0.1	0.0
naem02_2_r20	-0.1	0.0	-0.1	-0.1	0.1	0.1	0.1	0.1	0.0	0.0	0.1	-0.2	0.0	0.1	0.0	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.2	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.1	0.1	-0.1	-0.1	-0.2	-0.1	-0.1	-0.2
naem03_2_r20	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.2	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
naem10_2_r20	0.0	0.1	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.4	-0.1	0.0	0.0	0.0	0.0	0.1	0.1	0.0	0.1	0.1	0.0	0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.2	0.1	0.0	0.0	0.0	0.0	0.0	0.0

1.1 Korelacijske tabele pojasnjevalnih spremenljivk

Format tiska omogoča le grob pregled korelacijsih tabel z barvnim kodiranjem vrednosti. Korelacije, ki so po absolutni vrednosti večje od 0,5 so na rumenem ozadju, po absolutni vrednosti večje od 0,7 pa na oranžnem ozadju. Celotne preglednice v bolj berljivi obliki so na priloženem DVD.

R = 5 m
avg_vpv_0_5
avg_vpv_1_5
avg_vpv_2_5
avg_vpv_3_5
avg_vpv_4_5
avg_vpv_5_5
avg_vpv_6_5
avg_vpv_7_5
avg_vpv_8_5
avg_vpv_9_5
avg_vpv_10_5
avg_vpv_11_5
avg_vpv_12_5
avg_vpv_13_5
avg_vpv_14_5
avg_vpv_15_5
avg_vpv_16_5
avg_vpv_17_5
avg_vpv_18_5
avg_vpv_19_5
avg_vpv_20_5
avg_vpv_21_5
avg_vpv_22_5
avg_vpv_23_5
avg_vpv_24_5
avg_vpv_25_5
avg_vpv_26_5
avg_vpv_27_5
avg_vpv_28_5
avg_vpv_29_5
avg_vpv_30_5
avg_vpv_31_5
avg_vpv_32_5
avg_vpv_100_5
avg_vpv_kumul_100d0_5
avg_vpv_kumul_100d1_5
avg_vpv_kumul_100d2_5
avg_vpv_kumul_100d3_5
avg_vpv_kumul_100d4_5
avg_vpv_kumul_100d5_5
avg_vpv_kumul_100d6_5
avg_vpv_kumul_100d7_5
avg_vpv_kumul_100d8_5
avg_vpv_kumul_100d9_5
avg_vpv_kumul_100d10_5
avg_vpv_kumul_100d11_5
avg_vpv_kumul_100d12_5
avg_vpv_kumul_100d13_5
avg_vpv_kumul_100d14_5
avg_vpv_kumul_100d15_5
avg_vpv_kumul_100d16_5
avg_vpv_kumul_100d17_5
avg_vpv_kumul_100d18_5
avg_vpv_kumul_100d19_5
avg_vpv_kumul_100d20_5
avg_vpv_kumul_100d21_5
avg_vpv_kumul_100d22_5
avg_vpv_kumul_100d23_5
avg_vpv_kumul_100d24_5
avg_vpv_kumul_100d25_5
avg_vpv_kumul_100d26_5
avg_vpv_kumul_100d27_5
avg_vpv_kumul_100d28_5
avg_vpv_kumul_100d29_5
avg_vpv_kumul_100d30_5
avg_vpv_kumul_100d31_5
stdev_vpv_0_5
stdev_vpv_1_5
stdev_vpv_2_5
stdev_vpv_3_5
stdev_vpv_4_5
stdev_vpv_5_5
stdev_vpv_6_5
stdev_vpv_7_5
stdev_vpv_8_5
stdev_vpv_9_5
stdev_vpv_10_5
stdev_vpv_11_5
stdev_vpv_12_5
stdev_vpv_13_5
stdev_vpv_14_5
stdev_vpv_15_5
stdev_vpv_16_5
stdev_vpv_17_5
stdev_vpv_18_5
stdev_vpv_19_5
stdev_vpv_20_5
stdev_vpv_21_5
stdev_vpv_22_5
stdev_vpv_23_5
stdev_vpv_24_5
stdev_vpv_25_5
stdev_vpv_26_5
stdev_vpv_27_5
stdev_vpv_28_5
stdev_vpv_29_5
stdev_vpv_30_5
stdev_vpv_31_5
stdev_vpv_32_5
stdev_vpv_kumul_100d0_5
stdev_vpv_kumul_100d1_5
stdev_vpv_kumul_100d2_5
stdev_vpv_kumul_100d3_5
stdev_vpv_kumul_100d4_5
stdev_vpv_kumul_100d5_5
stdev_vpv_kumul_100d6_5
stdev_vpv_kumul_100d7_5
stdev_vpv_kumul_100d8_5
stdev_vpv_kumul_100d9_5
stdev_vpv_kumul_100d10_5
stdev_vpv_kumul_100d11_5
stdev_vpv_kumul_100d12_5
stdev_vpv_kumul_100d13_5
stdev_vpv_kumul_100d14_5
stdev_vpv_kumul_100d15_5
stdev_vpv_kumul_100d16_5
stdev_vpv_kumul_100d17_5
stdev_vpv_kumul_100d18_5
stdev_vpv_kumul_100d19_5
stdev_vpv_kumul_100d20_5
stdev_vpv_kumul_100d21_5
stdev_vpv_kumul_100d22_5
stdev_vpv_kumul_100d23_5
stdev_vpv_kumul_100d24_5
stdev_vpv_kumul_100d25_5
stdev_vpv_kumul_100d26_5
stdev_vpv_kumul_100d27_5
stdev_vpv_kumul_100d28_5
stdev_vpv_kumul_100d29_5
stdev_vpv_kumul_100d30_5
stdev_vpv_kumul_100d31_5
DOF_NDVI_GURS_RS_AVG
DOF_NDVI_GURS_RS_STD
DOF_NDVI_GEOIN_RS_AVG
DOF_NDVI_GEOIN_RS_STD

R = 10 m

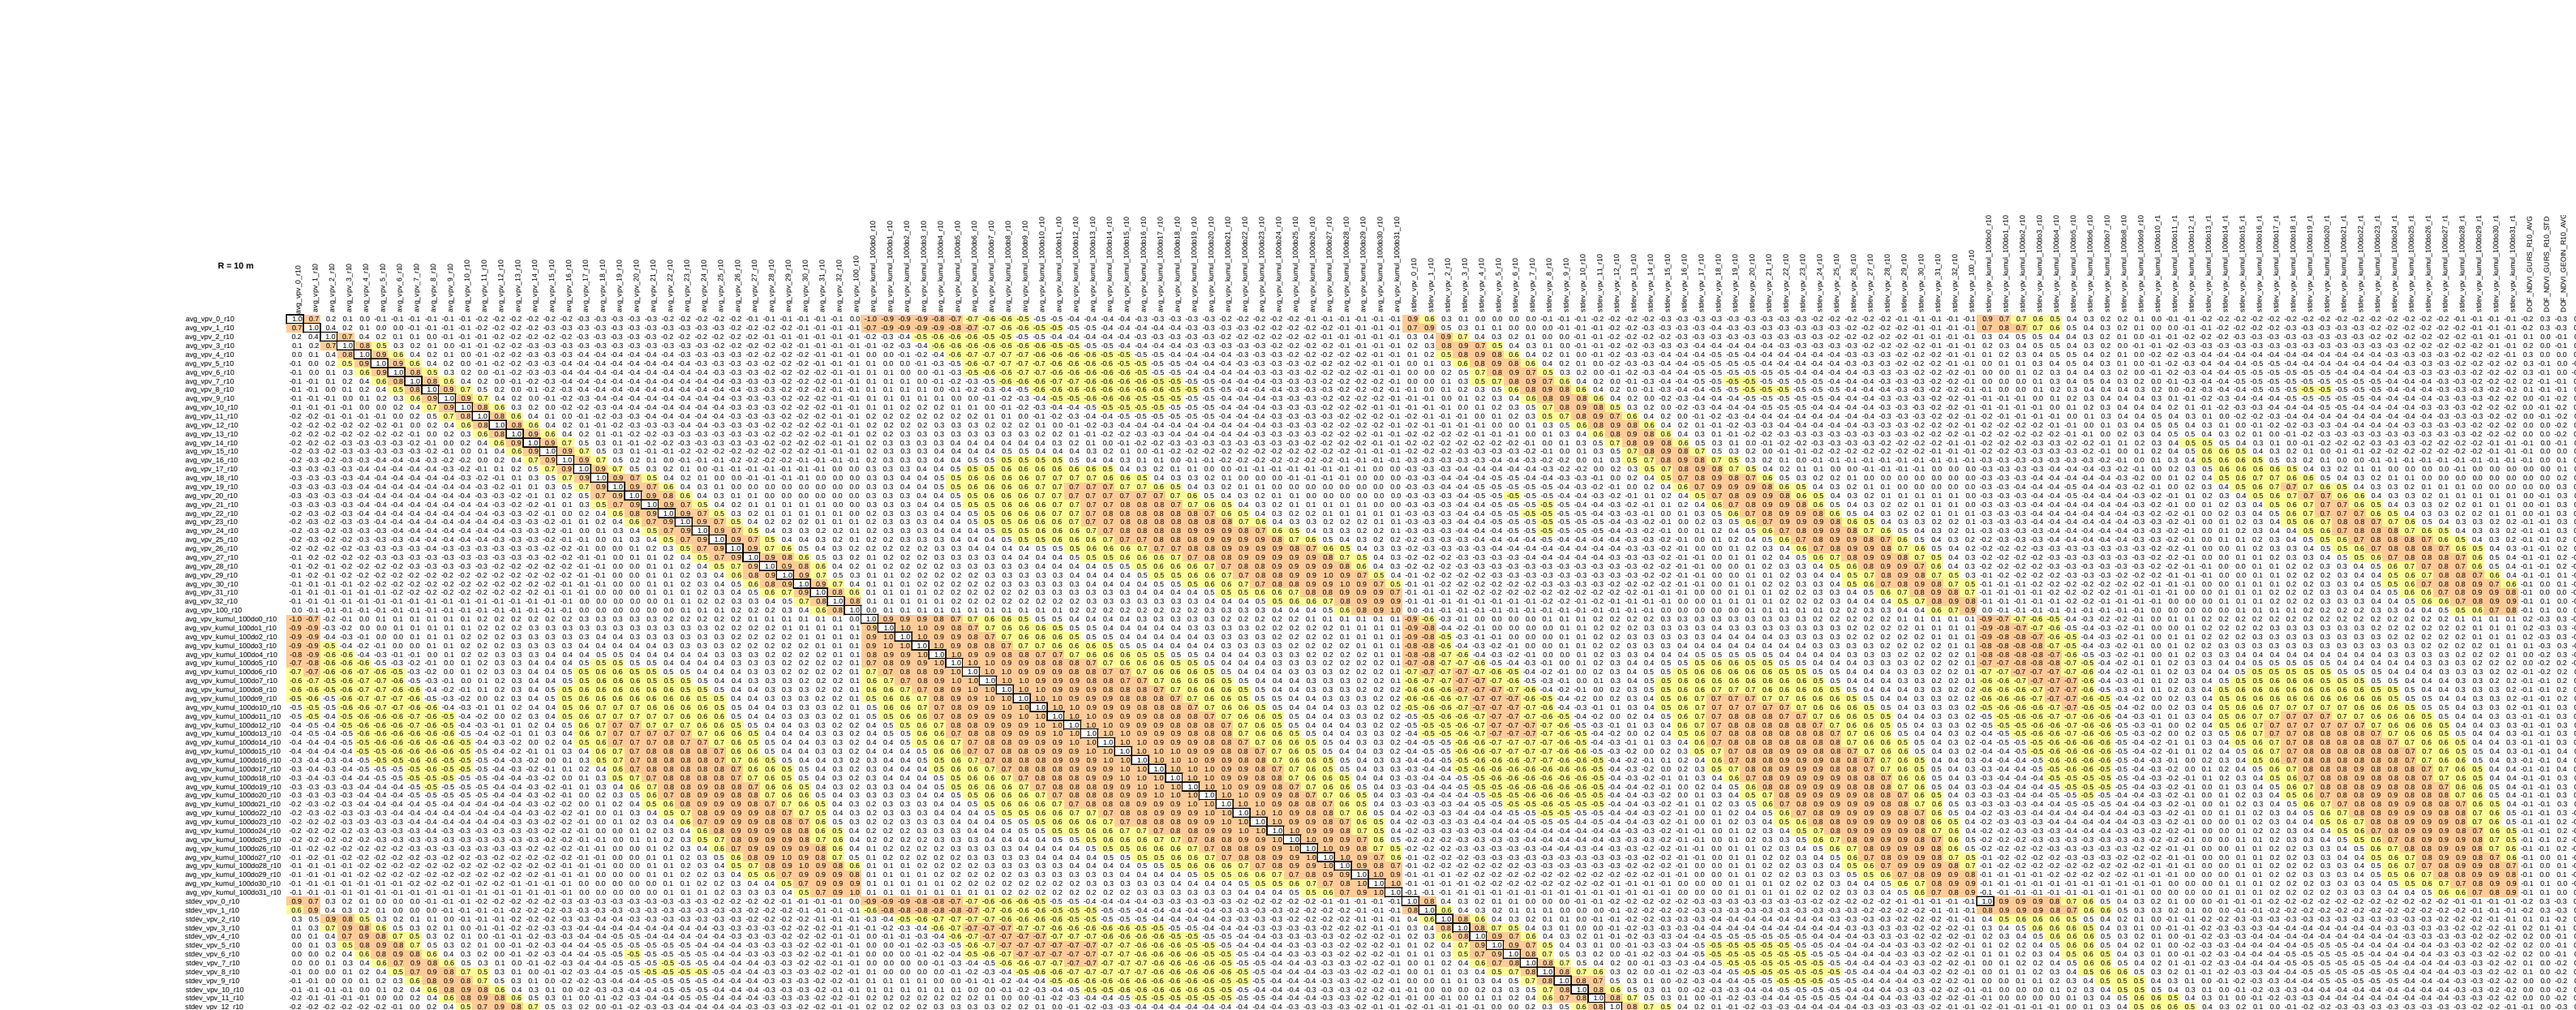

R = 20 m

	avg_vpv_0_r20	avg_vpv_1_r20	avg_vpv_2_r20	avg_vpv_3_r20	avg_vpv_4_r20	avg_vpv_5_r20	avg_vpv_6_r20	avg_vpv_7_r20	avg_vpv_8_r20	avg_vpv_9_r20	avg_vpv_10_r20	avg_vpv_11_r20	avg_vpv_12_r20	avg_vpv_13_r20	avg_vpv_14_r20	avg_vpv_15_r20	avg_vpv_16_r20	avg_vpv_17_r20	avg_vpv_18_r20	avg_vpv_19_r20	avg_vpv_20_r20	avg_vpv_21_r20	avg_vpv_22_r20	avg_vpv_23_r20	avg_vpv_24_r20	avg_vpv_25_r20	avg_vpv_26_r20	avg_vpv_27_r20	avg_vpv_28_r20	avg_vpv_29_r20	avg_vpv_30_r20	avg_vpv_31_r20	avg_vpv_32_r20	avg_vpv_100_r20
avg_vpv_0_r20	1.0	0.7	0.2	0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_1_r20	0.7	1.0	0.4	0.3	0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1
avg_vpv_2_r20	0.2	0.4	1.0	0.8	0.5	0.3	0.1	0.1	0.0	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1	-0.1
avg_vpv_3_r20	0.1	0.3	0.8	1.0	0.8	0.6	0.4	0.2	0.1	0.0	-0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1
avg_vpv_4_r20	0.0	0.1	0.5	0.8	1.0	0.9	0.7	0.5	0.3	0.1	0.0	-0.1	-0.2	-0.2	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1
avg_vpv_5_r20	0.0	0.0	0.3	0.6	0.9	1.0	0.9	0.7	0.4	0.2	0.1	0.0	-0.1	-0.2	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1
avg_vpv_6_r20	-0.1	0.0	0.1	0.4	0.7	0.9	1.0	0.9	0.6	0.4	0.2	0.1	0.0	-0.2	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1
avg_vpv_7_r20	-0.1	-0.1	0.1	0.2	0.5	0.7	0.9	1.0	0.9	0.7	0.5	0.3	0.1	0.0	-0.2	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
avg_vpv_8_r20	-0.1	-0.1	0.0	0.1	0.3	0.4	0.6	0.9	1.0	0.9	0.7	0.5	0.3	0.1	-0.1	-0.2	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
avg_vpv_9_r20	-0.1	-0.1	-0.1	0.0	0.1	0.2	0.4	0.7	0.9	1.0	0.9	0.7	0.5	0.3	0.1	-0.1	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
avg_vpv_10_r20	-0.1	-0.1	-0.1	-0.1	0.0	0.1	0.2	0.5	0.7	0.9	1.0	0.9	0.7	0.4	0.2	0.0	-0.2	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
avg_vpv_11_r20	-0.2	-0.2	-0.1	-0.1	-0.1	0.0	0.1	0.3	0.5	0.7	0.9	1.0	0.9	0.7	0.4	0.2	0.0	-0.1	-0.2	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1
avg_vpv_12_r20	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	0.0	0.1	0.3	0.5	0.7	0.9	1.0	0.9	0.7	0.5	0.2	0.1	-0.1	-0.2	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1
avg_vpv_13_r20	-0.3	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	0.0	0.1	0.3	0.4	0.7	0.9	1.0	0.9	0.7	0.5	0.3	0.1	-0.1	-0.2	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
avg_vpv_14_r20	-0.3	-0.3	-0.2	-0.3	-0.3	-0.3	-0.3	-0.2	-0.1	0.1	0.2	0.4	0.7	0.9	1.0	0.9	0.7	0.5	0.3	0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
avg_vpv_15_r20	-0.3	-0.3	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.1	0.0	0.2	0.5	0.7	0.9	1.0	0.9	0.7	0.5	0.3	0.1	0.0	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1
avg_vpv_16_r20	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	0.0	0.2	0.5	0.7	0.9	1.0	0.9	0.7	0.5	0.3	0.1	0.0	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1
avg_vpv_17_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.1	0.1	0.3	0.5	0.7	0.9	1.0	0.9	0.7	0.5	0.3	0.2	0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0
avg_vpv_18_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.1	0.3	0.5	0.7	0.9	1.0	0.9	0.7	0.6	0.4	0.3	0.2	0.1	0.0	-0.1	-0.1	-0.1	-0.1	0.0	0.0	0.0
avg_vpv_19_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.1	0.3	0.5	0.7	0.9	1.0	0.9	0.8	0.6	0.5	0.4	0.2	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_20_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.1	0.3	0.5	0.7	0.9	1.0	0.9	0.8	0.7	0.5	0.4	0.2	0.1	0.0	0.0	0.0	0.0	0.0	0.0
avg_vpv_21_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	0.0	0.1	0.3	0.6	0.8	0.9	1.0	0.9	0.8	0.7	0.5	0.3	0.2	0.1	0.1	0.1	0.1	0.1	0.1
avg_vpv_22_r20	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.0	0.2	0.4	0.6	0.8	0.9	1.0	0.9	0.8	0.6	0.4	0.3	0.2	0.1	0.1	0.1	0.1	0.1
avg_vpv_23_r20	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.1	0.3	0.5	0.7	0.8	0.9	1.0	0.9	0.7	0.5	0.4	0.3	0.2	0.2	0.2	0.2	0.1
avg_vpv_24_r20	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.0	0.2	0.4	0.5	0.7	0.8	0.9	1.0	0.9	0.7	0.6	0.5	0.4	0.3	0.3	0.2	0.2
avg_vpv_25_r20	-0.2	-0.3	-0.2	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.2	-0.1	0.0	0.1	0.2	0.4	0.5	0.6	0.7	0.9	1.0	0.9	0.8	0.6	0.5	0.4	0.3	0.3	0.2
avg_vpv_26_r20	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.1	0.0	0.1	0.2	0.3	0.4	0.5	0.7	0.9	1.0	0.9	0.8	0.6	0.5	0.4	0.3	0.2
avg_vpv_27_r20	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1	0.0	0.1	0.2	0.3	0.4	0.6	0.8	0.9	1.0	0.9	0.8	0.6	0.5	0.4	0.2
avg_vpv_28_r20	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.1	0.2	0.3	0.5	0.6	0.8	0.9	1.0	0.9	0.8	0.6	0.5	0.3
avg_vpv_29_r20	-0.1	-0.2	-0.1	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.1	0.1	0.2	0.4	0.5	0.6	0.8	0.9	1.0	0.9	0.7	0.6	0.3
avg_vpv_30_r20	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.1	0.1	0.2	0.3	0.4	0.5	0.6	0.8	0.9	1.0	0.9	0.8	0.5
avg_vpv_31_r20	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.0	0.1	0.1	0.2	0.3	0.3	0.4	0.5	0.6	0.7	0.9	1.0	0.9	0.6
avg_vpv_32_r20	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.1	0.1	0.2	0.2	0.3	0.3	0.4	0.5	0.6	0.8	0.9	1.0	0.8
avg_vpv_100_r20	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.1	0.1	0.2	0.2	0.2	0.2	0.3	0.3	0.5	0.6	0.8	1.0
avg_vpv_kumul_100do0_r20	-1.0	-0.7	-0.2	-0.1	0.0	0.0	0.1	0.1	0.1	0.1	0.1	0.2	0.2	0.3	0.3	0.3	0.3	0.3	0.3	0.3	0.3	0.3	0.3	0.3	0.2	0.2	0.2	0.2	0.1	0.1	0.1	0.1	0.1	0.1
avg_vpv_kumul_100do1_r20	-0.9	-0.9	-0.3	-0.2	-0.1	0.0	0.1	0.1	0.1	0.1	0.2	0.2	0.2	0.3	0.3	0.3	0.3	0.3	0.4	0.4	0.3	0.3	0.3	0.3	0.3	0.3	0.2	0.2	0.2	0.2	0.1	0.1	0.1	0.1
avg_vpv_kumul_100do2_r20	-0.9	-0.9	-0.4	-0.3	-0.1	0.0	0.0	0.1	0.1	0.1	0.2	0.2	0.2	0.3	0.3	0.3	0.3	0.4	0.4	0.4	0.4	0.3	0.3	0.3	0.3	0.3	0.2	0.2	0.2	0.2	0.1	0.1	0.1	0.1
avg_vpv_kumul_100do3_r20	-0.9	-0.9	-0.5	-0.4	-0.3	-0.1	0.0	0.0	0.1	0.1	0.2	0.2	0.3	0.3	0.3	0.3	0.4	0.4	0.4	0.4	0.4	0.3	0.3	0.3	0.3	0.3	0.2	0.2	0.2	0.2	0.1	0.1	0.1	0.1
avg_vpv_kumul_100do4_r20	-0.8	-0.9	-0.6	-0.6	-0.5	-0.3	-0.2	-0.1	0.0	0.1	0.1	0.2	0.3	0.3	0.4	0.4	0.4	0.4	0.5	0.5	0.5	0.4	0.4	0.4	0.4	0.4	0.3	0.3	0.2	0.2	0.2	0.2	0.1	0.1
avg_vpv_kumul_100do5_r20	-0.8	-0.8	-0.6	-0.7	-0.6	-0.5	-0.3	-0.2	-0.1	0.0	0.1	0.2	0.3	0.3	0.4	0.4	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.4	0.4	0.3	0.3	0.3	0.2	0.2	0.2	0.2	0.1
avg_vpv_kumul_100do6_r20	-0.7	-0.7	-0.6	-0.7	-0.7	-0.6	-0.5	-0.3	-0.2	0.0	0.1	0.2	0.2	0.3	0.3	0.4	0.5	0.5	0.6	0.6	0.6	0.5	0.5	0.5	0.5	0.4	0.4	0.3	0.3	0.3	0.2	0.2	0.2	0.1
avg_vpv_kumul_100do7_r20	-0.6	-0.7	-0.6	-0.7	-0.7	-0.7	-0.6	-0.5	-0.3	-0.1	0.0	0.1	0.2	0.3	0.4	0.5	0.5	0.6	0.6	0.6	0.6	0.6	0.5	0.5	0.5	0.5	0.4	0.4	0.3	0.3	0.3	0.2	0.2	0.1
avg_vpv_kumul_100do8_r20	-0.6	-0.6	-0.5	-0.7	-0.7	-0.7	-0.6	-0.6	-0.4	-0.2	-0.1	0.0	0.2	0.3	0.4	0.5	0.5	0.6	0.6	0.7	0.6	0.6	0.6	0.6	0.6	0.5	0.4	0.4	0.3	0.3	0.3	0.2	0.2	0.2
avg_vpv_kumul_100do9_r20	-0.5	-0.6	-0.5	-0.6	-0.7	-0.7	-0.7	-0.6	-0.5	-0.4	-0.2	-0.1	0.1	0.3	0.4	0.5	0.5	0.6	0.7	0.7	0.7	0.6	0.6	0.6	0.6	0.6	0.5	0.4	0.4	0.3	0.3	0.3	0.2	0.2
avg_vpv_kumul_100do10_r20	-0.5	-0.6	-0.5	-0.6	-0.7	-0.7	-0.7	-0.7	-0.6	-0.5	-0.3	-0.2	0.0	0.2	0.3	0.5	0.5	0.6	0.7	0.7	0.7	0.7	0.6	0.6	0.6	0.6	0.5	0.4	0.4	0.3	0.3	0.3	0.2	0.2
avg_vpv_kumul_100do11_r20	-0.5	-0.5	-0.5	-0.6	-0.7	-0.7	-0.7	-0.7	-0.6	-0.5	-0.4	-0.3	-0.1	0.1	0.3	0.4	0.5	0.6	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.6	0.5	0.5	0.4	0.4	0.3	0.3	0.3	0.2
avg_vpv_kumul_100do12_r20	-0.5	-0.5	-0.4	-0.5	-0.6	-0.6	-0.6	-0.7	-0.7	-0.6	-0.6	-0.5	-0.4	-0.2	0.0	0.2	0.4	0.5	0.6	0.7	0.7	0.7	0.7	0.7	0.7	0.7	0.6	0.5	0.5	0.4	0.4	0.3	0.3	0.2
avg_vpv_kumul_100do13_r20	-0.4	-0.5	-0.4	-0.5	-0.6	-0.6	-0.6	-0.7	-0.6	-0.6	-0.5	-0.4	-0.3	-0.1	0.1	0.3	0.4	0.6	0.7	0.7	0.8	0.7	0.7	0.7	0.7	0.7	0.6	0.5	0.5	0.4	0.4	0.3	0.3	0.2
avg_vpv_kumul_100do14_r20	-0.4	-0.4	-0.4	-0.5	-0.6	-0.6	-0.6	-0.7	-0.6	-0.6	-0.6	-0.5	-0.3	-0.2	0.0	0.2	0.4	0.5	0.6	0.7	0.8	0.8	0.8	0.8	0.8	0.7	0.6	0.6	0.5	0.4	0.4	0.4	0.3	0.2
avg_vpv_kumul_100do15_r20	-0.4	-0.4	-0.4	-0.5	-0.6	-0.6	-0.6	-0.6	-0.6	-0.6	-0.6	-0.5	-0.4	-0.3	-0.1	0.1	0.3	0.4	0.6	0.7	0.8	0.8	0.8	0.8	0.8	0.8	0.7	0.6	0.5	0.5	0.4	0.4	0.3	0.2
avg_vpv_kumul_100do16_r20	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.6	-0.6	-0.6	-0.6	-0.6	-0.5	-0.4	-0.3	-0.2	0.0	0.2	0.4	0.5	0.7	0.8	0.8	0.8	0.8	0.8	0.8	0.7	0.6	0.6	0.5	0.5	0.4	0.3	0.2
avg_vpv_kumul_100do17_r20	-0.3	-0.4	-0.3	-0.4	-0.5	-0.5	-0.5	-0.6	-0.6	-0.6	-0.6	-0.6	-0.5	-0.4	-0.2	-0.1	0.1	0.3	0.5	0.6	0.7	0.8	0.8	0.9	0.8	0.8	0.7	0.7	0.6	0.5	0.5	0.4	0.4	0.3
avg_vpv_kumul_100do18_r20	-0.3	-0.4	-0.3	-0.4	-0.5	-0.5	-0.5	-0.6	-0.6	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	0.0	0.2	0.4	0.5	0.7	0.8	0.8	0.9	0.9	0.9	0.8	0.7	0.6	0.6	0.5	0.4	0.4	0.3
avg_vpv_kumul_100do19_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	-0.1	0.1	0.3	0.5	0.6	0.7	0.8	0.9	0.9	0.9	0.8	0.8	0.7	0.6	0.6	0.5	0.4	0.3
avg_vpv_kumul_100do20_r20	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	-0.1	0.0	0.2	0.4	0.5	0.7	0.7	0.8	0.9	0.9	0.8	0.8	0.7	0.6	0.5	0.4	0.3	0.3
avg_vpv_kumul_100do21_r20	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.3	-0.1	0.0	0.1	0.3	0.4	0.6	0.7	0.8	0.9	0.9	0.9	0.9	0.8	0.7	0.6	0.5	0.5	0.3
avg_vpv_kumul_100do22_r20	-0.2	-0.3	-0.2	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.5	-0.4	-0.5	-0.4	-0.4	-0.3	-0.3	-0.2	-0.1	0.1	0.2	0.3	0.4	0.6	0.7	0.8	0.9	0.9	0.9	0.8	0.8	0.7	0.6	0.5	0.4
avg_vpv_kumul_100do23_r20	-0.2	-0.3	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.1	0.0	0.1	0.2	0.3	0.4	0.6	0.8	0.9	0.9	0.9	0.9	0.8	0.7	0.6	0.5	0.4
avg_vpv_kumul_100do24_r20	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.1	0.0	0.1	0.1	0.2	0.3	0.5	0.7	0.8	0.9	0.9	0.9	0.9	0.8	0.7	0.6	0.4
avg_vpv_kumul_100do25_r20	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1	0.0	0.1	0.2	0.2	0.4	0.6	0.7	0.9	0.9	1.0	0.9	0.8	0.7	0.6	0.4
avg_vpv_kumul_100do26_r20	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1	0.0	0.1	0.1	0.2	0.3	0.5	0.6	0.8	0.9	1.0	1.0	0.9	0.8	0.7	0.5
avg_vpv_kumul_100do27_r20	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.1	0.2	0.3	0.4	0.5	0.7	0.8	0.9	1.0	0.9	0.8	0.7	0.5
avg_vpv_kumul_100do28_r20	-0.1	-0.2	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.1	0.1	0.2	0.3	0.4	0.5	0.7	0.8	0.9	1.0	0.9	0.8	0.6
avg_vpv_kumul_100do29_r20	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.1	0.1	0.2	0.3	0.4	0.4	0.5	0.6	0.8	0.9	1.0	0.9	0.8
avg_vpv_kumul_100do30_r20	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.1	0.1	0.2	0.2	0.3	0.4	0.4	0.5	0.6	0.8	0.9	1.0	0.9
avg_vpv_kumul_100do31_r20	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.1	0.1	0.1	0.2	0.2	0.3	0.3	0.4	0.5	0.6	0.8	0.9	1.0
stdev_vpv_0_r20	0.9	0.7	0.3	0.2	0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_1_r20	0.6	0.9	0.5	0.4	0.2	0.1	0.0	0.0	0.0	-0.1	-0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_2_r20	0.3	0.5	0.9	0.8	0.6	0.4	0.2	0.2	0.1	0.0	-0.1	-0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_3_r20	0.2	0.3	0.7	0.9	0.8	0.6	0.5	0.3	0.2	0.1	0.0	-0.1	-0.1	-0.2	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1	-0.1
stdev_vpv_4_r20	0.1	0.2	0.5	0.8	0.9	0.8	0.7	0.5	0.4	0.2	0.1	0.0	-0.1	-0.1	-0.2	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1
stdev_vpv_5_r20	0.0	0.1	0.3	0.6	0.8	0.9	0.9	0.7	0.5	0.4	0.3	0.1	0.0	-0.1	-0.2	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1
stdev_vpv_6_r20	0.0	0.0	0.2	0.4	0.7	0.8	0.9	0.8	0.7	0.5	0.4	0.3	0.1	-0.1	-0.2	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.1
stdev_vpv_7_r20	0.0	0.0	0.1	0.3	0.5	0.6	0.8	0.9	0.8	0.7	0.6	0.4	0.2	0.1	-0.1	-0.2	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.6	-0.6	-0.5	-0.5	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.1
stdev_vpv_8_r20	-0.1	0.0	0.0	0.1	0.3	0.4	0.6	0.8	0.9	0.8	0.7	0.6	0.4	0.2	0.0	-0.1	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.6	-0.6	-0.5	-0.5	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.1
stdev_vpv_9_r20	-0.1	-0.1	0.0	0.0	0.2	0.3	0.4	0.7	0.8	0.9	0.9	0.7	0.6	0.4	0.1	0.0	-0.2	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.6	-0.5	-0.5	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.1
stdev_vpv_10_r20	-0.1	-0.1	-0.1	-0.1	0.0	0.1	0.2	0.5	0.7	0.8	0.9	0.9	0.7	0.5	0.3	0.1	0.0	-0.1	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.1
stdev_vpv_11_r20	-0.2	-0.1	-0.1	-0.1	-0.1	0.0	0.1	0.3	0.5	0.7	0.8	0.9	0.8	0.7	0.5	0.3	0.1	0.0	-0.1	-0.2	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.1
stdev_vpv_12_r20	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	0.1	0.3	0.5	0.6	0.8	0.9	0.8	0.7	0.5	0.3	0.2	0.1	-0.1	-0.2	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.1
stdev_vpv_13_r20	-0.3	-0.2	-0.2	-0.2	-0.3	-0.2	-0.2	-0.1	0.1	0.3	0.4	0.6	0.8	0.9	0.8	0.7	0.5	0.4	0.2	0.1	-0.1	-0.2	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1
stdev_vpv_14_r20	-0.3	-0.3	-0.2	-0.3	-0.3	-0.3	-0.3	-0.2	-0.1	0.0	0.2	0.4	0.7	0.8	0.9	0.8	0.7	0.6	0.4	0.2	0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
stdev_vpv_15_r20	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.3	-0.3	-0.1	0.0	0.2	0.5	0.7	0.8	0.9	0.8	0.7	0.6	0.4	0.2	0.1	0.0	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_16_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	0.0	0.2	0.5	0.7	0.8	0.9	0.9	0.8	0.6	0.4	0.3	0.2	0.1	0.0	-0.1	-0.1	-0.1	-0.2	-0.2	-0.1	-0.1	-0.1	0.0
stdev_vpv_17_r20	-0.3	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.1	0.1	0.3	0.5	0.7	0.8	0.9	0.9	0.7	0.6	0.4	0.3	0.2	0.2	0.1	0.0	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.0
stdev_vpv_18_r20	-0.3	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.1	0.1	0.3	0.5	0.7	0.8	0.9	0.9	0.7	0.6	0.5	0.4	0.3	0.2	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0
stdev_vpv_19_r20	-0.3	-0.4	-0.3	-0.4	-0.5	-0.5	-0.5	-0.6	-0.5	-0.5	-0.5	-0.4	-0.2	0.0	0.1	0.3	0.5	0.7	0.9	0.9	0.9	0.8	0.7	0.6	0.5	0.3	0.2	0.1	0.1	0.0	0.1	0.1	0.1	0.1
stdev_vpv_20_r20	-0.3	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.6	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	0.0	0.2	0.4	0.6	0.8	0.9	0.9	0.9	0.8	0.7	0.6	0.4	0.3	0.2	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_21_r20	-0.3	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.1	0.0	0.2	0.4	0.6	0.8	0.9	0.9	0.9	0.8	0.7	0.6	0.4	0.3	0.2	0.2	0.1	0.1	0.1	0.1
stdev_vpv_22_r20	-0.3	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	-0.1	0.1	0.3	0.5	0.7	0.8	0.9	0.9	0.9	0.8	0.7	0.5	0.4	0.3	0.2	0.2	0.2	0.2	0.1
stdev_vpv_23_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.2	-0.1	0.0	0.2	0.4	0.6	0.8	0.8	0.9	0.9	0.9	0.8	0.6	0.5	0.4	0.3	0.3	0.2	0.2	0.1
stdev_vpv_24_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	0.0	0.1	0.3	0.5	0.6	0.7	0.8	0.9	0.9	0.9	0.7	0.6	0.5	0.4	0.4	0.3	0.3	0.2
stdev_vpv_25_r20	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.1	0.2	0.4	0.5	0.6	0.7	0.8	0.9	0.9	0.8	0.7	0.6	0.5	0.4	0.4	0.3	0.2
stdev_vpv_26_r20	-0.2	-0.3	-0.2	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.0	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	0.9	0.8	0.7	0.6	0.5	0.4	0.4	0.3
stdev_vpv_27_r20	-0.2	-0.2	-0.2	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.2	-0.1	0.0	0.1	0.2	0.3	0.4	0.4	0.6	0.7	0.9	0.9	0.9	0.8	0.7	0.6	0.5	0.4	0.3
stdev_vpv_28_r20	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.1	-0.1	0.0	0.1	0.2	0.3	0.3	0.5	0.6	0.8	0.9	0.9	0.9	0.8	0.7	0.6	0.5	0.3
stdev_vpv_29_r20	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	0.0	0.0	0.1	0.1	0.2	0.3	0.4	0.5	0.7	0.8	0.8	0.9	0.8	0.7	0.6	0.4
stdev_vpv_30_r20	-0.1	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.1	-0.1	0.0	0.1	0.1	0.2	0.2	0.3	0.5	0.6	0.6	0.7	0.8	0.8	0.9	0.8	0.7	0.5
stdev_vpv_31_r20	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.1	0.1	0.2	0.3	0.4	0.5	0.5	0.6	0.6	0.7	0.9	0.9	0.8	0.6
stdev_vpv_32_r20	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.0	0.1	0.1	0.2	0.2	0.3	0.4	0.4	0.4	0.5	0.6	0.8	0.8	0.9	0.7
stdev_vpv_100_r20	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.0	0.0	0.1	0.1	0.1	0.2	0.2	0.3	0.3	0.3	0.4	0.6	0.7	0.8	0.9
stdev_vpv_kumul_100do0_r20	0.9	0.7	0.3	0.2	0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do1_r20	0.7	0.8	0.4	0.3	0.2	0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do2_r20	0.7	0.8	0.5	0.4	0.3	0.1	0.0	0.0	0.0	-0.1	-0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do3_r20	0.6	0.7	0.5	0.5	0.4	0.3	0.2	0.1	0.0	0.0	-0.1	-0.1	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1
stdev_vpv_kumul_100do4_r20	0.5	0.6	0.4	0.5	0.5	0.4	0.3	0.2	0.1	0.0	0.0	-0.1	-0.1	-0.2	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
stdev_vpv_kumul_100do5_r20	0.4	0.5	0.4	0.4	0.5	0.5	0.4	0.4	0.3	0.2	0.1	0.0	-0.1	-0.1	-0.2	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
stdev_vpv_kumul_100do6_r20	0.3	0.4	0.3	0.3	0.4	0.4	0.4	0.4	0.4	0.3	0.3	0.2	0.1	0.0	-0.2	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1
stdev_vpv_kumul_100do7_r20	0.2	0.3	0.2	0.2	0.3	0.3	0.3	0.4	0.4	0.4	0.4	0.3	0.2	0.1	-0.1	-0.2	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.2	-0.2	-0.1	-0.1
stdev_vpv_kumul_100do8_r20	0.1	0.2	0.1	0.1	0.1	0.1	0.2	0.3	0.4	0.4	0.4	0.4	0.3	0.2	0.1	-0.1	-0.1	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.3	-0.2	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do9_r20	0.0	0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.2	0.3	0.4	0.4	0.5	0.4	0.3	0.2	0.1	0.0	-0.1	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	-0.1	-0.1
stdev_vpv_kumul_100do10_r20	0.0	0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.1	0.3	0.4	0.4	0.5	0.4	0.3	0.2	0.1	0.1	0.0	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0
stdev_vpv_kumul_100do11_r20	-0.1	0.0	-0.1	-0.2	-0.3	-0.3	-0.2	-0.1	0.0	0.1	0.2	0.4	0.5	0.5	0.4	0.4	0.3	0.2	0.2	0.1	0.0	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.0
stdev_vpv_kumul_100do12_r20	-0.2	-0.1	-0.2	-0.2	-0.3	-0.3	-0.4	-0.3	-0.3	-0.2	-0.1	0.1	0.2	0.4	0.5	0.5	0.5	0.4	0.4	0.3	0.3	0.2	0.1	0.0	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	0.0
stdev_vpv_kumul_100do13_r20	-0.2	-0.1	-0.2	-0.3	-0.4	-0.4	-0.4	-0.4	-0.3	-0.2	-0.1	0.1	0.2	0.4	0.5	0.5	0.5	0.5	0.5	0.4	0.3	0.2	0.1	0.1	0.1	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.1
stdev_vpv_kumul_100do14_r20	-0.2	-0.2	-0.2	-0.3	-0.4	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	-0.1	0.1	0.3	0.4	0.5	0.6	0.6	0.6	0.5	0.4	0.3	0.2	0.2	0.2	0.1	0.1	0.0	0.0	0.0	0.0	0.0	0.1	0.1
stdev_vpv_kumul_100do15_r20	-0.2	-0.2	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	0.0	0.2	0.3	0.5	0.6	0.7	0.7	0.6	0.5	0.4	0.3	0.3	0.3	0.2	0.1	0.1	0.0	0.0	0.1	0.1	0.1	0.1
stdev_vpv_kumul_100do16_r20	-0.3	-0.2	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.1	0.0	0.2	0.4	0.5	0.7	0.7	0.7	0.6	0.5	0.4	0.4	0.4	0.3	0.2	0.2	0.1	0.1	0.1	0.1	0.1	0.1
stdev_vpv_kumul_100do17_r20	-0.3	-0.2	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.2	-0.1	0.1	0.3	0.4	0.6	0.7	0.7	0.7	0.6	0.5	0.5	0.5	0.4	0.3	0.2	0.1	0.1	0.1	0.2	0.2	0.2
stdev_vpv_kumul_100do18_r20	-0.3	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	0.0	0.2	0.3	0.5	0.7	0.7	0.7	0.7	0.6	0.6	0.6	0.5	0.4	0.3	0.2	0.2	0.2	0.2	0.2	0.2
stdev_vpv_kumul_100do19_r20	-0.3	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.3	-0.2	-0.1	0.1	0.2	0.4	0.6	0.7	0.8	0.7	0.7	0.7	0.6	0.6	0.4	0.3	0.3	0.2	0.2	0.2	0.2	0.2
stdev_vpv_kumul_100do20_r20	-0.3	-0.3	-0.3	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	0.0	0.1	0.3	0.5	0.7	0.7	0.8	0.7	0.7	0.7	0.6	0.5	0.4	0.3	0.3	0.3	0.3	0.3	0.2
stdev_vpv_kumul_100do21_r20	-0.2	-0.3	-0.3	-0.3	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.3	-0.2	-0.1	0.1	0.3	0.4	0.6	0.7	0.8	0.8	0.8	0.8	0.7	0.6	0.5	0.4	0.3	0.3	0.3	0.3	0.3
stdev_vpv_kumul_100do22_r20	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.1	0.0	0.2	0.4	0.5	0.6	0.7	0.8	0.8	0.8	0.8	0.6	0.5	0.4	0.4	0.4	0.4	0.3	0.2
stdev_vpv_kumul_100do23_r20	-0.2	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	0.0	0.1	0.3	0.4	0.6	0.6	0.7	0.8	0.8	0.8	0.7	0.6	0.5	0.5	0.4	0.4	0.3
stdev_vpv_kumul_100do24_r20	-0.2	-0.2	-0.2	-0.3	-0.4	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.5	-0.5	-0.4	-0.4	-0.3	-0.2	-0.1	0.1	0.2	0.3	0.5	0.5	0.6	0.7	0.8	0.9	0.8	0.7	0.6	0.5	0.5	0.5	0.4
stdev_vpv_kumul_100do25_r20	-0.2	-0.2	-0.2	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.5	-0.5	-0.5	-0.4	-0.4	-0.4	-0.3	-0.2	-0.1	0.0	0.1	0.3	0.4	0.4	0.5	0.6	0.8	0.8	0.8	0.7	0.6	0.6	0.6	0.5	0.4
stdev_vpv_kumul_100do26_r20	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.2	-0.1	0.0	0.1	0.2	0.3	0.3	0.4	0.5	0.7	0.8	0.8	0.8	0.8	0.7	0.7	0.6	0.6	0.5
stdev_vpv_kumul_100do27_r20	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.1	0.0	0.0	0.1	0.2	0.3	0.3	0.4	0.6	0.7	0.8	0.8	0.8	0.8	0.8	0.7	0.7	0.5
stdev_vpv_kumul_100do28_r20	-0.1	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.4	-0.4	-0.4	-0.3	-0.3	-0.2	-0.2	-0.1	0.0	0.0	0.1	0.2	0.2	0.3	0.4	0.5	0.6	0.7	0.7	0.8	0.8	0.8	0.7	0.6
stdev_vpv_kumul_100do29_r20	-0.1	-0.1	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	0.0	0.0	0.1	0.1	0.2	0.2	0.3	0.4	0.5	0.6	0.6	0.7	0.7	0.8	0.8	0.7
stdev_vpv_kumul_100do30_r20	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.3	-0.2	-0.2	-0.1	0.0	0.0	0.1	0.1	0.2	0.2	0.3	0.4	0.4	0.5	0.5	0.6	0.8	0.8	0.9	0.7
stdev_vpv_kumul_100do31_r20	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.2	-0.3	-0.2	-0.3	-0.2	-0.2	-0.2	-0.1	-0.1	0.0	0.0	0.0	0.1	0.1	0.2	0.2	0.3	0.3	0.4	0.4	0.5	0.7	0.8	0.9	0.8
DOF_NDVI_GURS_R20_AVG	-0.2	-0.2	0.1	0.2	0.3	0.3	0.3	0.2	0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1
DOF_NDVI_GURS_R20_STD	0.3	0.3	0.1	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.1
DOF_NDVI_GEOIN_R20_AVG	-0.3	-0.3	-0.1	-0.1	0.0	0.0	0.0	-0.1	-0.2	-0.2	-0.2	-0.2	-0.3	-0.2	-0.2	-0.1	0.0	0.1	0.1	0.2	0.3	0.3	0.4	0.4	0.3	0.3	0.3	0.2	0.2	0.2	0.1	0.1	0.1	0.0
DOF_NDVI_GEOIN_R20_STD	0.1	0.1	0.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.1	0.1	0.1	0.0	0.0	0.0	-0.1	-0.1	-0.2	-0.2	-0.2	-0.2	-0.1	-0.1	-0.1

1.1 Korelacijske tabele ciljnih spremenljivk

	gha	deligl	delbukev	deljavor	delbgaber	delcgaber	delhrast	delmjesen	delvjesen	delostalilst	delsmreka	deljelka	delbor	delmacesen	delostaliigl	Openness_45	LAI2000Lin_45	LAI2000GLin_45	DirectSiteFactor_45	IndirectSiteFactor_45	
gha	1.0	0.0	0.1	0.1	0.0	0.0	-0.1	0.0	0.0	-0.2	-0.1	0.2	0.0	0.0	0.0	-0.3	0.2	0.1	-0.2	-0.3	-0
deligl	0.0	1.0	-0.7	-0.2	-0.2	-0.2	-0.2	-0.2	-0.1	-0.3	0.6	0.1	0.4	0.0	0.0	0.2	-0.2	-0.2	0.1	0.2	0
delbukev	0.1	-0.7	1.0	0.2	-0.1	-0.1	-0.2	0.0	0.0	-0.2	-0.4	0.1	-0.4	0.0	0.0	-0.2	0.3	0.2	-0.1	-0.2	-0
deljavor	0.1	-0.2	0.2	1.0	-0.1	-0.1	-0.1	-0.1	0.0	-0.1	-0.2	0.2	-0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
delbgaber	0.0	-0.2	-0.1	-0.1	1.0	0.1	0.1	0.0	0.0	0.0	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
delcgaber	0.0	-0.2	-0.1	-0.1	0.1	1.0	0.0	0.3	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	-0.1	0.1	0.1	-0.1	-0.1	-0
delhrast	-0.1	-0.2	-0.2	-0.1	0.1	0.0	1.0	0.0	0.0	0.1	-0.1	-0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
delmjesen	0.0	-0.2	0.0	-0.1	0.0	0.3	0.0	1.0	0.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.0	-0
delvjesen	0.0	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	-0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0
delostalilst	-0.2	-0.3	-0.2	-0.1	0.0	0.0	0.1	0.0	0.0	1.0	-0.2	-0.2	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.1	0
delsmreka	-0.1	0.6	-0.4	-0.2	-0.1	-0.1	-0.1	-0.1	-0.1	-0.2	1.0	-0.4	-0.2	0.0	0.0	0.1	-0.1	-0.1	0.1	0.1	0
deljelka	0.2	0.1	0.1	0.2	-0.1	-0.1	-0.2	-0.1	-0.1	-0.2	-0.4	1.0	-0.3	0.0	0.0	-0.1	0.1	0.1	0.0	-0.1	0
delbor	0.0	0.4	-0.4	-0.2	-0.1	0.0	0.0	0.0	0.0	0.0	-0.2	-0.3	1.0	0.0	0.1	0.1	-0.2	-0.2	0.0	0.1	0
delmacesen	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0.0	0
delostaliigl	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	1.0	0.0	0.0	0.0	0.0	0.0	0
Openness_45	-0.3	0.2	-0.2	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.1	-0.1	0.1	0.0	0.0	1.0	-0.9	-0.8	0.5	1.0	0
LAI2000Lin_45	0.2	-0.2	0.3	0.0	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.1	-0.2	0.0	0.0	-0.9	1.0	0.8	-0.5	-0.9	-0
LAI2000GLin_45	0.1	-0.2	0.2	0.0	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.1	-0.2	0.0	0.0	-0.8	0.8	1.0	-0.3	-0.8	-0
DirectSiteFactor_45	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.5	-0.5	-0.3	1.0	0.5	1
IndirectSiteFactor_45	-0.3	0.2	-0.2	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.1	-0.1	0.1	0.0	0.0	1.0	-0.9	-0.8	0.5	1.0	0
TotalSiteFactor_45	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.6	-0.5	-0.3	1.0	0.5	1
PPFDDirectUnder_45	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.5	-0.5	-0.3	1.0	0.5	1
PPFDDiffuseUnder_45	-0.2	0.2	-0.3	-0.1	0.0	-0.1	0.0	0.0	0.0	0.0	0.2	-0.1	0.2	0.0	0.0	0.8	-0.8	-0.7	0.4	0.8	0
PPFDTotalUnder_45	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	-0.1	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.6	-0.5	-0.3	1.0	0.6	1
Openness_60	-0.3	0.2	-0.3	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.1	-0.1	0.2	0.0	0.0	1.0	-0.9	-0.7	0.5	1.0	0
LAI2000Lin_60	0.2	-0.2	0.3	0.0	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.1	-0.2	0.0	0.0	-0.9	1.0	0.8	-0.5	-0.9	-0
LAI2000GLin_60	0.1	-0.2	0.2	0.0	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.1	-0.2	0.0	0.0	-0.8	0.9	1.0	-0.3	-0.8	-0
DirectSiteFactor_60	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.6	-0.5	-0.3	0.8	0.6	0
IndirectSiteFactor_60	-0.3	0.2	-0.3	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.1	-0.1	0.2	0.0	0.0	1.0	-0.9	-0.7	0.5	1.0	0
TotalSiteFactor_60	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.6	-0.6	-0.3	0.8	0.6	0
PPFDDirectUnder_60	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.6	-0.5	-0.3	0.8	0.6	0
PPFDDiffuseUnder_60	-0.3	0.2	-0.3	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.1	-0.1	0.2	0.0	0.0	1.0	-0.9	-0.7	0.5	1.0	0
PPFDTotalUnder_60	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.0	0.0	0.6	-0.6	-0.3	0.8	0.6	0
Openness_120	-0.3	0.1	-0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	-0.1	0.3	0.0	0.0	0.7	-0.6	-0.4	0.4	0.7	0
LAI2000Lin_120	0.2	-0.1	0.2	0.0	0.0	0.0	0.0	0.0	0.0	-0.1	0.1	0.1	-0.4	0.0	0.0	-0.6	0.6	0.4	-0.4	-0.6	-0
LAI2000GLin_120	0.2	-0.2	0.3	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	-0.1	0.1	-0.3	0.0	0.0	-0.8	0.9	0.9	-0.4	-0.8	-0
DirectSiteFactor_120	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.5	-0.4	-0.2	0.6	0.5	0
IndirectSiteFactor_120	-0.3	0.2	-0.2	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	-0.1	0.3	0.0	0.0	0.8	-0.7	-0.5	0.5	0.8	0
TotalSiteFactor_120	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.5	-0.5	-0.2	0.6	0.5	0
PPFDDirectUnder_120	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.5	-0.4	-0.2	0.6	0.5	0
PPFDDiffuseUnder_120	-0.3	0.2	-0.2	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	-0.1	0.3	0.0	0.0	0.8	-0.7	-0.5	0.5	0.8	0
PPFDTotalUnder_120	-0.2	0.1	-0.1	0.0	0.0	-0.1	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.5	-0.5	-0.2	0.6	0.5	0
Openness_170	-0.2	0.1	-0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.2	-0.1	-0.1	0.3	0.0	0.0	0.6	-0.5	-0.3	0.4	0.6	0
LAI2000Lin_170	0.1	0.0	0.1	0.0	0.0	0.0	0.0	-0.1	0.0	-0.1	0.2	0.1	-0.4	0.0	-0.1	-0.2	0.2	0.1	-0.2	-0.2	-0
LAI2000GLin_170	0.2	-0.2	0.3	0.0	0.0	0.1	0.0	0.0	0.0	-0.1	-0.1	0.1	-0.3	0.0	0.0	-0.8	0.9	0.9	-0.4	-0.8	-0
DirectSiteFactor_170	-0.2	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.4	-0.4	-0.2	0.6	0.4	0
IndirectSiteFactor_170	-0.3	0.1	-0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	-0.1	0.3	0.0	0.0	0.8	-0.7	-0.5	0.5	0.8	0
TotalSiteFactor_170	-0.2	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.5	-0.4	-0.2	0.6	0.5	0
PPFDDirectUnder_170	-0.2	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.4	-0.4	-0.2	0.6	0.4	0
PPFDDiffuseUnder_170	-0.3	0.1	-0.2	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	-0.1	0.3	0.0	0.0	0.8	-0.7	-0.5	0.5	0.8	0
PPFDTotalUnder_170	-0.2	0.1	-0.1	0.0	0.0	0.0	0.0	0.0	0.0	0.1	0.0	0.0	0.1	0.0	0.0	0.5	-0.4	-0.2	0.6	0.5	0

1.1 Najboljši (minimalni) rangi posamezne pojasnjevalne spremenljivke glede na skupino ciljnih spremenljivk in glede na polmer veljavnosti pojasnjevalne spremenljivke

Meje barvnega označevanja:

visoki rangi do 217 * 0.05 =	10.9
srednji rangi do 217 * 0.10 =	21.7
nižji rangi do 217 * 0.20 =	43.4

Skupina ciljnih spremenljivk	Drugo				Drevesne vrste				Svetloba 45				Svetloba 60				Svetloba 120				Svetloba 170				Svetloba, vsi koti				Vse				Vse		
Pojasnjevalna spremenljivka	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	min	min	
avg_vpv_0	57	50	53	50	15	11	15	11	4	9	7	4	4	6	6	4	3	6	7	3	2	6	7	2	2	6	6	2	2	6	6	2	2		
avg_vpv_1	46	42	59	42	25	15	22	15	6	6	8	6	3	5	9	3	5	9	6	5	5	4	7	4	3	4	6	3	3	4	6	3	3		
avg_vpv_2	48	65	108	48	12	8	10	8	9	4	6	4	11	8	8	8	9	4	5	4	8	5	5	5	8	4	5	4	8	4	5	4	4		
avg_vpv_3	11	27	51	11	6	8	15	6	18	8	4	4	18	12	8	8	18	15	8	8	19	19	8	8	18	8	4	4	6	8	4	4	4		
avg_vpv_4	24	25	13	13	4	6	6	4	13	6	7	6	20	13	7	7	15	17	20	15	19	21	26	19	13	6	7	6	4	6	6	4	4		
avg_vpv_5	8	18	27	8	2	7	11	2	21	5	2	2	32	18	23	18	18	21	33	18	22	17	45	17	18	5	2	2	2	5	2	2	2		
avg_vpv_6	5	11	18	5	3	5	5	3	34	13	13	13	48	39	37	37	32	24	26	24	34	28	51	28	32	13	13	13	3	5	5	3	3		
avg_vpv_7	18	7	6	6	8	9	4	4	17	16	25	16	18	24	36	18	30	34	28	28	36	39	58	36	17	16	25	16	8	7	4	4	4		
avg_vpv_8	16	6	8	6	1	7	5	1	32	32	21	21	35	36	49	35	26	28	35	26	39	48	54	39	26	28	21	21	1	6	5	1	1		
avg_vpv_9	7	15	15	7	6	12	14	6	43	51	31	31	101	73	48	48	53	51	25	25	70	78	46	46	43	51	25	25	6	12	14	6	6		
avg_vpv_10	39	24	47	24	5	9	8	5	40	47	38	38	81	91	64	64	50	56	40	40	74	81	67	67	40	47	38	38	5	9	8	5	5		
avg_vpv_11	60	32	42	32	1	11	9	1	60	71	57	57	80	94	91	80	60	66	71	60	80	82	94	80	60	66	57	57	1	11	9	1	1		
avg_vpv_12	40	48	50	40	10	10	7	7	68	61	51	51	88	101	105	88	72	87	85	72	98	105	104	98	68	61	51	51	10	10	7	7	7		
avg_vpv_13	28	39	77	28	11	17	9	9	64	83	67	64	62	112	111	62	97	132	101	97	126	132	124	124	62	83	67	62	11	17	9	9	9		
avg_vpv_14	13	79	79	13	5	16	8	5	125	115	48	48	87	115	104	87	124	123	125	123	145	128	131	128	87	115	48	48	5	16	8	5	5		
avg_vpv_15	14	13	70	13	4	3	3	3	92	131	110	92	104	123	115	104	131	143	137	131	151	141	120	120	92	123	110	92	4	3	3	3	3		
avg_vpv_16	49	57	82	49	7	13	17	7	95	87	130	87	137	113	137	113	159	148	138	138	165	150	135	135	95	87	130	87	7	13	17	7	7		
avg_vpv_17	35	59	61	35	3	11	13	3	63	143	171	63	109	167	176	109	173	164	156	156	181	175	164	164	63	143	156	63	3	11	13	3	3	1.0	
avg_vpv_18	47	52	30	30	15	15	12	12	134	160	185	134	149	170	194	149	181	188	199	181	185	195	206	185	134	160	185	134	15	15	12	12	12		
avg_vpv_19	33	74	29	29	10	17	17	10	162	134	139	134	165	156	169	156	194	176	184	176	197	183	184	183	162	134	139	134	10	17	17	10	10		
avg_vpv_20	60	50	23	23	20	16	18	16	101	113	85	85	133	149	114	114	174	177	140	140	168	184	139	139	101	113	85	85	20	16	18	16	16		
avg_vpv_21	63	49	67	49	26	24	26	24	98	70	47	47	132	107	70	70	173	151	92	92	175	157	96	96	98	70	47	47	26	24	26	24	24		
avg_vpv_22	85	82	71	71	31	27	40	27	119	54	36	36	147	97	80	80	167	148	106	106	168	154	106	106	119	54	36	36	31	27	36	27	27		
avg_vpv_23	96	98	94	94	33	29	29	29	108	89	42	42	142	121	77	77	163	161	119	119	157	167	116	116	108	89	42	42	33	29	29	29	29		
avg_vpv_24	103	136	111	103	22	19	18	18	137	82	52	52	158	93	64	64	165	136	89	89	165	146	97	97	137	82	52	52	22	19	18	18	18		
avg_vpv_25	122	148	116	116	9	14	16	9	178	132	54	54	190	151	67	67	191	169	87	87	191	178	92	92	178	132	54	54	9	14	16	9	9		
avg_vpv_26	138	169	131	131	28	32	37	28	130	74	49	49	146	122	108	108	144	155	133	133	141	156	135	135	130	74	49	49	28	32	37	28	28		
avg_vpv_27	142	166	120	120	18	22	21	18	144	77	50	50	151	119	128	119	138	139	143	138	132	146	152	132	132	77	50	50	18	22	21	18	18		
avg_vpv_28	140	153	122	122	12	13	19	12	129	108	87	87	132	116	122	116	123	140	137	123	121	134	148	121	121	108	87	87	12	13	19	12	12		
avg_vpv_29	135	162	140	135	3	10	15	3	119	90	91	90	131	100	116	100	118	137	141	118	117	133	143	117	117	90	91	90	3	10	15	3	3		
avg_vpv_30	112	164	152	112	2	2	1	1	120	112	126	112	139	113	145	113	134	141	153	134	129	148	155	129	120	112	126	112	2	2	1	1	1		
avg_vpv_31	95	144	132	95	13	3	3	3	113	110	105	105	126	106	130	106	106	130	139	106	107	130	141	107	106	106	105	105	13	3	3	3	3		
avg_vpv_32	69	104	127	69	40	23	6	6	77	73	106	73	96	73	121	73	76	88	128	76	67	98	146	67	67	73	106	67	40	23	6	6	6		
avg_vpv_100	62	81	121	62	62	63	72	62	79	71	82	71	94	72	72	72	93	62	84	62	89	73	104	73	79	62	72	62	62	62	72	62	62		
avg_vpv_kumul_100do0	58	49	52	49	14	10	14	10	3	8	8	3	3	5	7	3	4	5	6	4	3	5	6	3	3	5	6	3	3	5	6	3	3		
avg_vpv_kumul_100do1	56	56	67	56	10	30	18	10	8	11	13	8	6	11	12	6	6	10	13	6	6	10	11	6	6	10	11	6	6	10	11	6	6		
avg_vpv_kumul_100do2	47	57	65	47	13	26	16	13	5	12	14	5	4	12	14	4	7	11	13	7	7	11	9	7	4	11	9	4	4	11	9	4	4		
avg_vpv_kumul_100do3	42	46	72	42	16	21	17	16	4	13	16	4	8	13	16	8	9	12	15	9	9	13	10	9	4	12	10	4	4	12	10	4	4		
avg_vpv_kumul_100do4	51	52	64	51	17	20	34	17	6	16	18	6	10	17	17	10	12	16	18	12	12	16	13	12	6	16	13	6	6	16	13	6	6		
avg_vpv_kumul_100do5	83	68	70	68	27	24	33	24	13	24	26	13	15	25	25	15	21	23	21	21	20	24	16	16	13	23	16	13	13	23	16	13	13		
avg_vpv_kumul_100do6	70	101	78	70	21	33	15	15	21	27	32	21	20	28	30	20	31	36	23	23	23	30	20	20	20	27	20	20	20	27	15	15	15		
avg_vpv_kumul_100do7	59	67	72	59	20	27	13	13	26	38	41	26	29	45	41	29	37	49	27	27	27	35	27	27	26	35	27	26	20	27	13	13	13		
avg_vpv_kumul_100do8	46	51	66	46	24	23	21	21	33	45	48	33	36	61	52	36	41	57	37	37	31	42	36	31	31	42	36	31	24	23	21	21	21		
avg_vpv_kumul_100do9	53	30	81	30	27	24	30	24	35	49	65	35	38	64	53	38	49	71	47	47	37	54	44	37	35	49	44	35	27	24	30	24	24		
avg_vpv_kumul_100do10	36	27	74	27	21	28	38	21	39	62	95	39	43	63	66	43	69	87	69	69	48	75	53	48	39	62	53	39	21	27	38	21	21		
avg_vpv_kumul_100do11	34	29	58	29	18	37	52	18	47	85	105	47	57	68	76	57	78	98	90	78	67	90	59	59	47	68	59	47	18	29	52	18	18		
avg_vpv_kumul_100do12	25	34	43	25	20	54	58	20	54	106	126	54	67	82	95	67	93	106	104	93	90	102	79	79	54	82	79	54	20	34	43	20	20		
avg_vpv_kumul_100do13	30	43	37	30	28	57	55	28	56	129	133	56	61	94	107	61	77	113	115	77	92	114	98	92	56	94	98	56	28	43	37	28	28		
avg_vpv_kumul_100do14	39	42	38	38	31	49	51	31	51	144	151	51	56	106	120	56	80	126	126	80	99	126	110	99	51	106	110	51	31	42	38	31	31		
avg_vpv_kumul_100do15	45	58	36	36	26	43	46	26	71	147	163	71	80	116	130	80	107	135	136	107	126	133	134	126	71	116	130	71	26	43	36	26	26		
avg_vpv_kumul_100do16	61	77	41	41	25	41	38	25	83	129	144	83	88	128	134	88	120	144	143	120	135	144	137	135	83	128	134	83	25	41	38	25	25	2.0	
avg_vpv_kumul_100do17	66	83	46	46	25	31	28	25	75	100	121	75	84	107	136	84	124	137	132	124	138	140	124	124	75	100	121	75	25	31	28	25	25		
avg_vpv_kumul_100do18	73	93	56	56	21	28	24	21	76	90	94	76	85	98	113	85	125	131	118	118	145	135	113	113	76	90	94	76	21	28	24	21	21		
avg_vpv_kumul_100do19	92	92	75	75	19	29	25	19	70	81	81	70	86	89	99	86	126	125	108	108	146	131	105	105	70	81	81	70	19	29	25	19	19		
avg_vpv_kumul_100do20	102	103	88	88	23	32	28	23	67	71	75	67	91	82	85	82	123	114	100	100	139	121	98	98	67	71	75	67	23	32	28	23	23		
avg_vpv_kumul_100do21	115	119	99	99	23	33	30	23	80	66	67	66	100	76	76	76	127	107	96	96	144	111	99	99	80	66	67	66	23	33	30	23	23		
avg_vpv_kumul_100do22	116	125	107	107	21	30	32	21	90	65	68	65	116	77	75	75	131	106	95	95	150	107	102	102	90	65	68	65	21	30	32	21	21		
avg_vpv_kumul_100do23	129	141	119	119	24	31	31	24	105	72	73	72	124	83	73	73	135	108	94	94	154	110	109	109	105	72	73	72	24	31	31	24	24		
avg_vpv_kumul_100do24	133	152	128	128	25	29	27	25	112	80	87	80	131	92	98	92	136	116	116	116	145	122	127	122	112	80	87	80	25	29	27	25	25		
avg_vpv_kumul_100do25	132	160	136	132	11	21	25	11	115	88	90	88	146	101	135	101	135	126	144	126	136	128	156	128	115	88	90	88	11	21	25	11	11		
avg_vpv_kumul_100do26	136	163	144	136	7	15	18	7	140	114	115	114	143	115	150	115	133	134	158	133	130	136	161	130	130	114	115	114	7	15	18	7	7		
avg_vpv_kumul_100do27	123	156	150	123	5	9	12	5	131	126	134	126	141	126	150	126	131	144	157	131	125	139	159	125	125	126	134	125	5	9	12	5	5		
avg_vpv_kumul_100do28	111	154	154	111	4	4	4	4	123	108	136	108	137	110	161	110	128	138	166	128	122	145	164	122	122	108	136	108	4	4	4	4	4		
avg_vpv_kumul_100do29	94	137	141	94	20	6	2	2	103	92	132	92	122	90	151	90	111	109	158	109	110	116	158	110	103	90	132	90	20	6	2	2	2		
avg_vpv_kumul_100do30	71	117	123	71	31	19	9	9	94	86	114	86	118	80	116	80	102	85	125	85	99	96	142	96	94	80	114	80	31	19	9	9	9		
avg_vpv_kumul_100do31	63	92	115	63	55	49	25	25	86	70	89	70	109	66	87	66	95	65	97	65	91	75	120	75	86	65	87	65	55	49	25	25	25		
stdev_vpv_0	65	33	23	23	12	27	3	3	2	3	27	2	2	3	20	2	1	4	24	1	2	7	24	2	1	3	20	1	1	3	3	1	1		
stdev_vpv_1	32	63	66	32	24	10	27	10	7	32	29	7	6	37	31	6	10	39	34	10	10	38	32	10	6	32	29	6	6	10	27	6	6		
stdev_vpv_2	20	77	52	20	4	6	8	4	1	1	4	1	2	7	5	2	2	3	4	2	2	4	4	2	1	1	4	1	1	1	4	1	1		
stdev_vpv_3	15	111	51	15	2	20	49	2	2	21	12	2	3	21	12	3	3	17	20	3	3	16	21	3	2	16	12	2	2	16	12	2	2		
stdev_vpv_4	45	53	43	43	6	21	35	6	3	8	31	3	17	6	36	6	7	13	39	7	10	19	46	10	3	6	31	3	3	6	31	3	3		
stdev_vpv_5	37	38	41	37	3	24	54	3	6	12	25	6	16	16	25	16	6	20	33	6	6	15	42	6	6	12	25	6	3	12	25	3	3		
stdev_vpv_6	10	19	49	10	2	8	19	2	8	37	33	8	5	43	70	5	8	27	62	8	11	19	65	11	5	19	33	5	2	8	19	2	2		
stdev_vpv_7	14	5	12	5	6	23	16	6	3	11	33	3	4	14	45	4	4	19	50	4	8	18	48	8	3	11	33	3	3	5	12	3	3		
stdev_vpv_8	17	12	9	9	4	21	9	4	27	47	49	27	13	46	65	13	17	30	36	17	23	54	54	23	13	30	36	13	4	12	9	4	4		
stdev_vpv_9	3	8	19	3	4	18	31	4	42	82	52	42	48	81	40	40	39	52	24	24	40	64	41	40	39	52	24	24	3	8	19	3	3		
stdev_vpv_10	27	20	26	20	14	27	15	14	49	52	56	49	39	32	46	32	46	59	48	46	47	59	63	47	39	32	46	32	14	20	15	14	14		
stdev_vpv_11	49	16	10	10	12	19	27	12	67	65	61	61	59	63	72	59	58	48	56	48	54	40	59	40	54	40	56	40	12	16	10	10	10		
stdev_vpv_12	51	26	32	26	20	34	22	20	91	68	42	42	85	81	65	65	70	72	71	70	95	76	75	75	70	68	42	42	20	26	22	20	20		
stdev_vpv_13	68	54	40	40	19	30	14	14	100	32	28	28	90	100	71	71	113	125	75	75	124	118	72	72	90	32	28	28	19	30	14	14	14		
stdev_vpv_14	10	86	60	10	34	23	16	16	103	130	44	44	131	107	92	92	164	102	100	100	163	95	97	95	103	95	44	44	10	23	16	10	10		
stdev_vpv_15	11	38	58	11	13	20	26	13	104	134	95	95	97	111	84	84	160	120	111	111	164	122	92	92	97	111	84	84	11	20	26	11	11		
stdev_vpv_16	32	108	112	32	23	37	47	23	46	69	94	46	77	75	97	75	133	127	100	100	167	127	86	86	46	69	86	46	23	37	47	23	23	1.0	
stdev_vpv_17	15	56	62	15	9	25	34	9	49	104	130	49	52	115	131	52	134	145	127	127	163	144	108	108	49	104	108	49	9	25	34	9	9		
stdev_vpv_18	21	60	28	21	16	23	18	16	96	122	147	96	110	164	150	110	167	167	142	142	184	180	141	141	96	122	141	96	16	23	18	16	16		
stdev_vpv_19	18	70	39	18	8	21	14	8	92	121	136	92	112	141	136	112	138	165	120	120	172	163	122	122	92	121	120	92	8	21	14	8	8		
stdev_vpv_20	16	35	7	7	1	15	23	1	36	119	112	36	57	154	118	57	104	177	131	104	134	184	132	132	36	119	112	36	1	15	7	1	1		
stdev_vpv_21	27	18	60	18	3	6	20	3	44	109	126	44	74	136	126	74	142	160	124	124	174	168	125	125	44	109	124	44	3	6	20	3	3		
stdev_vpv_22	44	11	20	11	4	2	12	2	50	51	88	50	79	60	117	60	169	99	134	99	186	117	123	117	50	51	88	50	4	2	12	2	2		
stdev_vpv_23	78	25	40	25	3	8	8	3	15	74	76	15	28	87	110	28	84	163	130	84	113	168	118	113	15	74	76	15	3	8	8	3	3		
stdev_vpv_24	81	65	33	33	1	10	3	1	33	36	20	20	66	55	41	41	110	121	66	66	165	144	66	66	33	36	20	20	1	10	3	1	1		
stdev_vpv_25	157	69	31	31	4	1	10	1	41	44	15	15	76	64	27	27	117	129	54	54	141	153	55	55	41	44	15	15	4	1	10	1	1		
stdev_vpv_26	161	128	73	73	15	15	14	14	28	32	66	28	34	46	86	34	50	79	120	50	69	119	130	69	28	32	66	28	15	15	14	14	14		
stdev_vpv_27	198	158	42	42	13	8	11	8	35	24	47	24	48	30	94	30	79	56	145	56	122	91	167	91	35	24	47	24	13	8	11	8	8		
stdev_vpv_28	189	171	103	103	14	10	9	9	45	55	37	37	55	69	58	55	64	93	99	64	101	124	136	101	45	55	37	37	14	10	9	9	9		
stdev_vpv_29	192	202	143	143	8	5	6	5	98	48	75	48	104	61	112	61	128	97	142	97	138	127	162	127	98	48	75	48	8	5	6	5	5		
stdev_vpv_30	173	204	192	173	1	5	7	1	146	64	128	64	150	75	142	75	156	112	169	112	152	147	176	147	146	64	128	64	1	5	7	1	1		
stdev_vpv_31	145	185	181	145	9	1	5	1	111	104	135	104	145	112	139	112	139	146	154	139	137	164	182	137	111	104	135	104	9	1	5	1	1		
stdev_vpv_32	111	168	172	111	38	11	7	7	88	58	110	58	72	67	128	67	65	102	153	65	75	123	176	75	65	58	110	58	38	11	7	7	7		
stdev_vpv_100	78	119	162	78	46	34	24	24	64	54	79	54	89	53	78	53	61	48	103	48	59	60	140	59	59	48	78	48	46	34	24	24	24		

Skupina ciljnih spremenljivk	Drugo				Drevesne vrste				Svetloba 45				Svetloba 60				Svetloba 120				Svetloba 170				Svetloba, vsi koti				Vse				Vs	
Pojasnjevalna spremenljivka	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	min	min
stdev_vpv_kumul_100do0	64	34	24	24	11	28	2	2	1	4	28	1	1	2	21	1	2	5	23	2	3	8	23	3	1	2	21	1	1	2	2	1	1	
stdev_vpv_kumul_100do1	41	22	35	22	23	18	9	9	8	50	81	8	5	41	76	5	7	36	88	7	5	30	87	5	5	30	76	5	5	18	9	5	5	
stdev_vpv_kumul_100do2	38	24	45	24	25	15	11	11	11	53	100	11	8	61	94	8	13	33	126	13	13	16	125	13	8	16	94	8	8	15	11	8	8	
stdev_vpv_kumul_100do3	31	55	57	31	39	12	22	12	30	72	132	30	31	109	168	31	32	35	184	32	25	15	179	15	25	15	132	15	25	12	22	12	12	
stdev_vpv_kumul_100do4	26	73	59	26	14	13	31	13	37	102	159	37	42	147	191	42	45	39	183	39	35	18	151	18	35	18	151	18	14	13	31	13	13	
stdev_vpv_kumul_100do5	24	80	73	24	17	58	38	17	46	105	174	46	70	141	178	70	39	42	139	39	37	23	127	23	37	23	127	23	17	23	38	17	17	
stdev_vpv_kumul_100do6	41	71	46	41	31	46	44	31	45	108	164	45	65	124	142	65	34	58	113	34	32	35	98	32	32	35	98	32	31	35	44	31	31	
stdev_vpv_kumul_100do7	33	31	22	22	8	31	45	8	47	125	133	47	57	118	112	57	40	61	79	40	38	36	65	36	38	36	65	36	8	31	22	8	8	
stdev_vpv_kumul_100do8	35	29	16	16	5	29	48	5	54	121	117	54	61	101	88	61	51	57	47	47	42	38	35	35	42	38	35	35	5	29	16	5	5	
stdev_vpv_kumul_100do9	54	39	29	29	30	15	33	15	80	103	102	80	83	81	64	64	72	51	33	33	44	43	29	29	44	43	29	29	30	15	29	15	15	
stdev_vpv_kumul_100do10	93	43	35	35	37	17	7	7	93	106	89	89	102	91	53	53	79	68	23	23	53	58	19	19	53	58	19	19	37	17	7	7	7	
stdev_vpv_kumul_100do11	151	51	37	37	26	26	6	6	112	117	95	95	119	108	70	70	95	84	25	25	87	76	21	21	87	76	21	21	26	26	6	6	6	
stdev_vpv_kumul_100do12	177	80	55	55	24	21	8	8	118	107	82	82	117	116	61	61	120	90	21	21	110	82	16	16	110	82	16	16	24	21	8	8	8	
stdev_vpv_kumul_100do13	143	120	83	83	25	19	21	19	122	113	67	67	122	109	55	55	128	96	24	24	119	85	18	18	119	85	18	18	25	19	18	18	18	
stdev_vpv_kumul_100do14	104	129	103	103	5	14	19	5	124	94	57	57	107	98	54	54	121	83	30	30	121	74	25	25	107	74	25	25	5	14	19	5	5	
stdev_vpv_kumul_100do15	56	84	90	56	7	20	16	7	133	90	49	49	112	95	47	47	107	75	29	29	108	58	21	21	107	58	21	21	7	20	16	7	7	
stdev_vpv_kumul_100do16	37	54	50	37	11	19	21	11	104	93	55	55	128	99	66	66	118	91	30	30	118	79	22	22	104	79	22	22	11	19	21	11	11	1.0
stdev_vpv_kumul_100do17	12	48	27	12	12	6	20	6	85	98	68	68	108	103	77	77	133	103	29	29	137	94	25	25	85	94	25	25	12	6	20	6	6	
stdev_vpv_kumul_100do18	5	31	11	5	13	8	19	8	55	108	86	55	81	111	95	81	146	118	39	39	149	99	29	29	55	99	29	29	5	8	11	5	5	
stdev_vpv_kumul_100do19	8	12	10	8	6	17	10	6	34	110	107	34	62	110	106	62	143	103	56	56	151	104	35	35	34	103	35	34	6	12	10	6	6	
stdev_vpv_kumul_100do20	9	9	15	9	5	21	19	5	14	106	120	14	29	102	103	29	88	104	66	66	135	107	37	37	14	102	37	14	5	9	15	5	5	
stdev_vpv_kumul_100do21	43	14	14	14	9	12	9	9	20	63	128	20	35	74	118	35	116	108	75	75	132	112	48	48	20	63	48	20	9	12	9	9	9	
stdev_vpv_kumul_100do22	89	28	13	13	5	7	6	5	6	43	113	6	22	59	132	22	67	123	86	67	115	130	82	82	6	43	82	6	5	7	6	5	5	
stdev_vpv_kumul_100do23	146	47	16	16	4	4	4	4	2	18	43	2	20	34	62	20	47	77	81	47	88	109	81	81	2	18	43	2	2	4	4	2	2	
stdev_vpv_kumul_100do24	197	64	17	17	3	2	3	2	7	11	23	7	24	31	52	24	48	67	80	48	83	101	93	83	7	11	23	7	3	2	3	2	2	
stdev_vpv_kumul_100do25	207	116	44	44	2	2	1	1	17	25	49	17	33	47	81	33	72	89	129	72	121	129	130	121	17	25	49	17	2	2	1	1	1	
stdev_vpv_kumul_100do26	213	135	65	65	7	1	1	1	23	23	71	23	36	39	109	36	68	69	133	68	118	106	135	106	23	23	71	23	7	1	1	1	1	
stdev_vpv_kumul_100do27	206	114	92	92	11	4	3	3	62	35	76	35	78	62	101	62	114	103	130	103	139	141	132	132	62	35	76	35	11	4	3	3	3	
stdev_vpv_kumul_100do28	196	134	101	101	10	4	4	4	103	40	101	40	111	56	129	56	132	87	146	87	151	132	151	132	103	40	101	40	10	4	4	4	4	
stdev_vpv_kumul_100do29	172	111	102	102	6	7	6	6	128	57	105	57	144	71	122	71	144	82	161	82	144	125	168	125	128	57	105	57	6	7	6	6	6	
stdev_vpv_kumul_100do30	133	81	68	68	16	8	8	8	108	56	86	56	117	65	108	65	115	72	141	72	120	105	164	105	108	56	86	56	16	8	8	8	8	
stdev_vpv_kumul_100do31	97	63	53	53	37	18	9	9	66	31	50	31	67	41	69	41	57	44	114	44	55	70	149	55	55	31	50	31	37	18	9	9	9	
dof_ndvi_gurs_avg	2	2	2	2	3	2	2	2	28	10	8	8	31	14	22	14	26	14	7	7	20	12	11	11	20	10	7	7	2	2	2	2	2	1.0
dof_ndvi_gurs_std	29	3	5	3	6	7	9	6	49	17	5	5	26	16	13	13	22	19	18	18	20	19	18	18	20	16	5	5	6	3	5	3	3	1.0
dof_ndvi_geoin_avg	1	1	1	1	1	1	1	1	18	2	7	2	26	8	19	8	30	17	15	15	27	15	15	15	18	2	7	2	1	1	1	1	1	
dof_ndvi_geoin_std	34	14	6	6	24	13	26	13	16	1	3	1	27	1	16	1	70	47	82	47	43	33	79	33	16	1	3	1	16	1	3	1	1	
naem00_1	126	105	159	105	80	81	82	80	76	50	85	50	73	57	58	57	68	60	58	58	63	59	59	59	63	50	58	50	63	50	58	50	50	
naem01_1	74	32	83	32	36	33	40	33	57	42	39	39	61	50	90	50	58	59	78	58	65	65	81	65	57	42	39	39	36	32	39	32	32	
naem02_1	127	4	82	4	50	1	23	1	32	5	21	5	175	140	126	126	90	105	43	43	147	180	121	121	32	5	21	5	32	1	21	1	1	
naem03_1	1	72	104	1	1	51	66	1	72	57	15	15	47	55	60	47	63	88	93	63	49	77	86	49	47	55	15	15	1	51	15	1	1	
naem10_1	128	105	205	105	41	14	20	14	47	7	44	7	38	15	57	15	36	43	72	36	49	45	72	45	36	7	44	7	36	7	20	7	7	
naem11_1	79	72	138	72	35	26	38	26	31	6	14	6	24	8	14	8	37	24	26	24	45	34	31	31	24	6	14	6	24	6	14	6	6	
naem12_1	113	19	9	9	2	58	9	2	13	15	1	1	84	13	4	4	99	40	13	13	106	50	29	29	13	13	1	1	2	13	1	1	1	
naem13_1	36	131	7	7	18	13	5	5	6	4	3	3	16	4	3	3	31	6	12	6	44	16	15	15	6	4	3	3	6	4	3	3	3	
naem20_1	82	36	22	22	62	2	7	2	64	6	4	4	42	15	6	6	54	73	11	11	57	162	22	22	42	6	4	4	42	2	4	2	2	1.0
naem21_1	77	1	3	1	18	41	8	8	37	10	4	4	32	9	5	5	100	23	10	10	100	40	18	18	32	9	4	4	18	1	3	1	1	
naem22_1	48	2	34	2	32	17	6	6	75	127	54	54	121	108	74	74	159	147	111	111	158	187	143	143	75	108	54	54	32	2	6	2	2	
naem23_1	17	13	30	13	19	1	15	1	56	46	22	22	90	43	15	15	59	74	34	34	52	37	34	34	52	37	15	15	17	1	15	1	1	
naem30_1	3	198	207	3	1	2	4	1	1	1	1	1	1	1	1	1	1	1	2	1	1	1	2	1	1	1	1	1	1	1	1	1	1	
naem31_1	22	75	169	22	1	2	1	1	17	5	1	1	15	4	1	1	11	4	1	1	9	3	1	1	9	3	1	1	1	2	1	1	1	
naem32_1	43	10	3	3	6	3	3	3	40	15	10	10	45	15	6	6	95	15	6	6	91	15	6	6	40	15	6	6	6	3	3	3	3	
naem33_1	50	60	79	50	4	5	4	4	65	14	86	14	56	31	75	31	92	55	49	49	122	71	82	71	56	14	49	14	4	5	4	4	4	
con_1	72	102	68	68	36	22	32	22	52	13	15	13	30	19	19	19	38	36	28	28	39	38	28	28	30	13	15	13	30	13	15	13	13	
dis_1	65	23	61	23	37	22	8	8	1	5	16	1	1	5	16	1	3	3	29	3	6	9	41	6	1	3	16	1	1	3	8	1	1	
hom_1	119	37	63	37	35	37	14	14	55	34	77	34	29	38	91	29	52	57	83	52	51	68	83	51	29	34	77	29	29	34	14	14	14	
asm_1	129	93	131	93	44	49	84	44	51	49	33	33	46	44	41	41	31	24	24	24	32	20	25	20	31	20	24	20	31	20	24	20	20	
mxp_1	121	125	167	121	78	63	65	63	73	81	90	73	69	68	67	67	61	53	51	51	60	51	51	51	60	51	51	51	60	51	51	51	51	
ent_1	126	79	151	79	40	36	72	36	68	68	51	51	64	54	48	48	39	30	30	30	40	27	30	27	39	27	30	27	39	27	30	27	27	1.0
mn1_1	120	87	109	87	46	62	43	43	48	53	33	33	45	56	34	34	46	44	35	35	48	44	36	36	45	44	33	33	45	44	33	33	33	
mn2_1	132	98	121	98	60	70	24	24	42	47	37	37	40	51	36	36	43	42	41	41	44	43	40	40	40	42	36	36	40	42	24	24	24	
vr1_1	124	89	97	89	70	41	38	38	60	83	64	60	91	68	86	68	80	89	110	80	74	87	109	74	60	68	64	60	60	41	38	38	38	
vr2_1	123	94	94	94	71	38	37	37	57	80	61	57	90	67	84	67	79	88	105	79	71	83	107	71	57	67	61	57	57	38	37	37	37	
cor_1	91	33	91	33	52	74	29	29	42	18	22	18	23	24	29	23	25	35	32	25	25	35	39	25	23	18	22	18	23	18	22	18	18	
naem00_2	149	116	153	116	85	73	74	73	79	59	72	59	79	35	47	35	69	46	47	46	66	47	48	47	66	35	47	35	66	35	47	35	35	
naem01_2	117	88	93	88	53	45	40	40	65	23	71	23	62	35	63	35	60	52	49	49	59	54	34	34	59	23	34	23	53	23	34	23	23	
naem02_2	38	76	33	33	23	1	1	1	41	41	45	41	147	45	156	45	169	160	111	111	177	207	145	145	41	41	45	41	23	1	1	1	1	
naem03_2	28	55	45	28	1	14	9	1	54	41	31	31	64	103	50	50	62	110	73	62	121	112	88	88	54	41	31	31	1	14	9	1	1	
naem10_2	162	110	138	110	52	36	13	13	13	20	111	13	17	20	125	17	24	27	109	24	28	32	111	28	13	20	109	13	13	20	13	13	13	
naem11_2	137	26	95	26	33	15	27	15	9	2	9	2	10	2	11	2	23	12	12	12	29	24	20	20	9	2	9	2	9	2	9	2	2	
naem12_2	58	82	1	1	28	6	6	6	18	104	47	18	52	75	68	52	111	101	107	101	116	111	99	99	18	75	47	18	18	6	1	1	1	
naem13_2	2	59	75	2	3	1	4	1	193	2	5	2	166	54	27	27	166	169	86	86	209	211	84	84	166	2	5	2	2	1	4	1	1	
naem20_2	50	41	28	28	50	38	21	21	47	46	27	27	45	52	28	28	59	53	56	53	82	102	60	60	45	46	27	27	45	38	21	21	21	1.0
naem21_2	80	64	2	2	20	19	13	13	17	55	28	17	42	61	58	42	33	42	65	33	40	72	64	40	17	42	28	17	17	19	2	2	2	
naem22_2	55	5	8	5	16	23	10	10	52	154	102	52	130	141	96	96	156	172	152	152	166	201	179	166	52	141	96	52	16	5	8	5	5	
naem23_2	19	15	31	15	4	4	2	2	215	74	168	74	211	85	213	85	183	135	152	135	208	177	198	177	183	74	152	74	4	4	2	2	2	
naem30_2	7	47	200	7	11	4	1	1	14	1	1	1	11	2	1	1	6	2	1	1	6	1	2	1	6	1	1	1	6	1	1	1	1	
naem31_2	9	8	110	8	1	1	2	1	23	2	3	2	21	2	3	2	21	1	2	1	14	1	3	1	14	1	2	1	1	1	2	1	1	
naem32_2	40	30	25	25	21	9	3	3	59	20	28	20	54	37	20	20	63	26	21	21	77	38	26	26	54	20	20	20	21	9	3	3	3	
naem33_2	53	178	168	53	3	6	4	3	71	67	81	67	50	101	104	50	138	141	142	138	156	152	154	152	50	67	81	50	3	6	4	3	3	
con_2	61	21	44	21	49	35	18	18	29	16	14	14	32	18	17	17	33	16	24	16	33	17	24	17	29	16	14	14	29	16	14	14	14	
dis_2	59	17	18	17	49	17	26	17	12	39	48	12	14	50	61	14	16	34	64	16	21	37	74	21	12	34	48	12	12	17	18	12	12	
hom_2	86	61	12	12	81	60	62	60	52	22	98	22	43	22	79	22	41	32	72	32	41	31	74	31	41	22	72	22	41	22	12	12	12	
asm_2	105	89	100	89	54	47	73	47	41	36	25	25	38	35	29	29	27	20	19	19	26	19	18	18	26	19	18	18	26	19	18	18	18	
mxp_2	156	122	77	77	87	65	51	51	74	61	65	61	71	47	55	47	62	38	43	38	61	39	41	39	61	38	41	38	61	38	41	38	38	
ent_2	73	91	136	73	26	53	71	26	59	41	39	39	53	39	32	32	36	32	22	22	37	31	23	23	36	31	22	22	26	31	22	22	22	7.0
mn1_2	112	86	106	86	47	64	44	44	49	55	35	35	47	58	35	35	48	45	36	36	49	45	34	34	47	45	34	34	47	45	34	34	34	
mn2_2	118	107	112	107	51	40	25	25	38	39	41	38	35	42	40	35	42	48	46	42	43	48	44	43	35	39	40	35	35	39	25	25	25	
vr1_2	118	90	104	90	76	43	40	40	61	83	66	61	95	71	89	71	83	90	115	83	79	89	114	79	61	71	66	61	61	43	40	40	40	
vr2_2	116	100	93	93	75	40	36	36	54	73	57	54	91	66	82	66	82	83	101	82	68	79	101	68	54	66	57	54	54	40	36	36	36	
cor_2	70	74	95	70	46	68	20	20	28	19	7	7	22	19	9	9	18	18	7	7	18	18	16	16	18	18	7	7	18	18	7	7	7	
naem00_4	148	115	142	115	72	69	71	69	78	51	57	51	77	30	31	30	73	33	30	30	71	33	31	31	71	30	30	30	71	30	30	30	30	
naem01_4	20	71	194	20	32	19	31	19	61	80	42	42	64	25	25	25	45	51	48	45	100	54	49	49	45	25	25	25	20	19	25	19	19	
naem02_4	4	61	24	4	22	26	5	5	156	35	201	35	197	80	215	80	179	196	216	179	194	205	217	194	156	35	201	35	4	26	5	4	4	
naem03_4	30	175	87	30	2	4	2	2	64	130	128	64	189	213	207	189	152	161	192	152	176	203	194	176	64	130	128	64	2	4	2	2	2	
naem10_4	152	37	56	37	48	38	40	38	49	8	57	8	58	7	55	7	70	8	53	8	72	13	53	13	49	7	53	7	48	7	40	7	7	
naem11_4	71	6	55	6	34	7	15	7	10	3	2	2	11	3	6	3	25	16	6	6	28	22	13	13	10	3	2	2	10	3	2	2	2	
naem12_4	23	7	4	4	55	47	25	25	35	94	37	35	44	105	35	35	52	150	48	48	79	160	78	78	35	94	35	35	23	7	4	4	4	
naem13_4	6	75	76	6	5	3	5	3	46	24	22	22	55	201	144	55	153	200	183	153	191	211	208	191	46	24	22	22	5	3	5	3	3	
naem20_4	194	17	126	17	9	26	10	9	22	37	95	22	33	35	54	33	56	42	124	42	89	51	131	51	22	35	54	22	9	17	10	9	9	1.0
naem21_4	144	21	14	14	40	10	2	2	12	31	61	12	18	28	53	18	27	37	78	27	34	46	88	34	12	28	53	12	12	10	2	2	2	
naem22_4	42	36	11	11	10	6	7	6	44	62	138	44	78	52	124	52	145	146	155	145	171	191	195	171	44	52	124	44	10	6	7	6	6	
naem23_4	25	35	71	25	2	3	2	2	41	62	34	34	39	120	46	39	141	202	141	141	198	208	162	162	39	62	34	34	2	3	2	2	2	
naem30_4	6	129	110	6	6	2	8	2	24	7	4	4	21	16	10	10	27	10	10	10	26	7	6	6	21	7	4	4	6	2	4	2	2	
naem31_4	22	9	48	9	24	1	1	1	30	4	5	4	35	9	5	5	56	9	3	3	59	9	5	5	30	4	3	3	22	1	1	1	1	
naem32_4	23	3	4	3	2	1	1	1	31	15	10	10	37	20	11	11	43	20	10	10	65	31	17	17	31	15	10	10	2	1	1	1	1	
naem33_4	12	62	17	12	16	28	11	11	5	29	11	5	3	22	52	3	30	30	85	30	25	36	80	25	3	22	11	3	3	22	11	3	3	
con_4	55	113	115	55	43	32	43	32	53	37	58	37	81	59	82	59	64	96	98	64	61	92	98	61	53	37	58	37	43	32	43	32	32	
dis_4	68	70	64	64	23	24	27	23	27	37	52	27	37	56	62	37	32	60	68	32	32	55	72	32	27	37	52	27	23	24	27	23	23	
hom_4	107	41	135	41	85	68	66	66	67	29	32	29	39	27	23	23	47	31	34	31	47	27	34	27	39	27	23	23	39	27	23	23	23	
asm_4	100	97	120	97	41	43	75	41	31	27	14	14	29	28	17	17	23	15	13	13	22	14	13	13	22	14	13	13	22	14	13	13	13	
mxp_4	140	130	98	98	68	63	48	48	75	48	19	19	68	34	32	32	66	31	26	26	66	32	26	26	66	31	19	19	66	31	19	19	19	
ent_4	99	124	165	99	21	23	81	21	52	40	29	29	49	38	26	26	29	24	20	20	30	25	20	20	29	24	20	20	21	23	20	20	20	13.0
mn1_4	121	94	102	94	45	66	46	45	53	54	35	35	50	59	38	38	54	40	35	35	53	40	35	35	50	40	35	35	45	40	35	35	35	
mn2_4	107	103	122	103	48	27	28	27	36	46	40	36	35	51	37	35	51	55	40	40	54	56	38	38	35	46	37	35	35	27	28	27	27	
vr1_4	125	95	116	95	80	45	44	44	66	93	54	54	106	79	85	79	90	97	117	90	86	94	117	86	66	79	54	54	66	45	44	44	44	
vr2_4	103	107	96	96	69	37	45	37	62	78	53	53	93	63	77	63	72	70	100	70	71	78	95	71	62	63	53	53	62	37	45	37	37	
cor_4	81	155	125	81	58	88	81	58	87	33	30	30	64	33	49	33	55	45	40	40	60	47	40	40	55	33	30	30	55	33	30	30	30	

1.1 *Povprečni rangi posamezne pojasnjevalne spremenljivke glede na skupino ciljnih spremenljivk in glede na polmer veljavnosti pojasnjevalne spremenljivke*

	Drugo r5	Drugo r10	Drugo r20	Drugo vsi	Drevesne vrste r5	r10	r20	vsi	Svetloba 45 r5	r10	r20	vsi	Svetloba 60 r5	r10	r20	vsi	Svetloba 120 r5	r10	r20	vsi	Svetloba 170 r5	r10	r20	vsi	Svetloba, vsi koti r5	r10	r20	vsi	Vse r5	r10	r20	vsi	min
min	2.5	3.5	5.0	16.3	51.2	50.9	53.7	51.9	5.7	5.4	8.1	8.7	3.6	3.0	1.7	3.6	1.4	1.9	1.1	2.0	1.0	1.7	1.0	1.6	3.5	3.0	3.9	4.0	33.9	35.1	33.9	38.1	1.0
max	214.0	210.5	212.0	202.8	154.6	154.7	153.7	152.9	216.7	196.9	211.9	204.4	216.3	215.4	216.0	211.8	213.0	211.7	216.9	209.9	215.8	215.6	217.0	211.8	215.4	205.3	215.4	206.4	182.0	176.8	185.5	174.8	142.2
avg	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	109.0	58.9
Meje označevanja (a= (max-min)/100):																																	
visoki rangi do (min+5a)	13.1	13.9	15.4	25.7	56.4	56.1	58.7	57.0	16.2	15.0	18.3	18.5	14.2	13.6	12.4	14.0	12.0	12.4	11.9	12.4	11.7	12.4	11.8	12.1	14.1	13.1	14.5	14.1	41.3	42.2	41.5	44.9	8.1
srednji rangi do (min+10a)	23.7	24.2	25.7	35.0	61.6	61.3	63.7	62.0	26.8	24.6	28.5	28.3	24.8	24.2	23.1	24.4	22.6	22.9	22.7	22.8	22.5	23.1	22.6	22.6	24.7	23.2	25.1	24.2	48.7	49.3	49.1	51.8	15.1
nižji rangi do (min+20a)	44.8	44.9	46.4	53.6	71.9	71.7	73.7	72.1	47.9	43.7	48.9	47.8	46.1	45.5	44.5	45.2	43.8	43.8	44.3	43.6	44.0	44.4	44.2	43.6	45.9	43.5	46.2	44.5	63.5	63.4	64.3	65.5	29.2

Skupina ciljnih spremenljivk	Drugo				Drevesne vrste				Svetloba 45				Svetloba 60			
Pojasnjevalna spremenljivka	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi
avg_vpv_0	134.0	129.5	126.5	130.0	100.2	106.3	98.5	101.7	27.3	27.8	23.4	26.2	11.1	10.0	9.0	10.0
avg_vpv_1	128.0	121.5	119.5	123.0	106.8	98.5	102.4	102.5	17.0	11.2	14.0	14.1	9.6	8.6	11.7	9.9
avg_vpv_2	117.5	117.5	116.5	117.2	99.9	115.2	122.3	112.5	23.9	16.7	10.1	16.9	16.2	10.6	9.0	11.9
avg_vpv_3	106.0	84.5	70.0	86.8	92.9	106.2	107.2	102.1	26.6	17.8	11.2	18.5	23.6	17.7	21.7	21.0
avg_vpv_4	106.0	112.5	59.5	92.7	89.7	94.3	92.0	92.0	28.2	23.1	13.9	21.7	30.8	35.2	30.7	32.2
avg_vpv_5	100.5	103.0	102.0	101.8	83.9	93.8	89.8	89.2	35.9	18.2	14.1	22.7	42.3	35.0	33.4	36.9
avg_vpv_6	65.0	95.0	87.0	82.3	87.0	83.8	87.5	86.1	52.1	41.1	34.6	42.6	74.7	69.1	58.7	67.5
avg_vpv_7	41.0	61.0	55.5	52.5	90.4	78.5	80.9	83.3	41.2	35.9	46.7	41.3	58.0	52.2	69.7	60.0
avg_vpv_8	46.0	54.0	72.5	57.5	82.8	82.0	79.4	81.4	72.1	55.7	48.3	58.7	89.2	70.4	70.3	76.7
avg_vpv_9	19.0	19.0	20.5	19.5	80.8	82.8	78.5	80.7	115.1	85.4	81.0	93.9	113.7	98.1	79.4	97.1
avg_vpv_10	61.5	66.0	58.0	61.8	83.7	84.5	78.8	82.3	108.3	119.7	85.9	104.6	113.0	101.9	85.2	100.0
avg_vpv_11	63.5	59.5	75.5	66.2	90.0	82.7	79.4	84.0	114.4	114.6	90.0	106.3	114.1	109.3	106.9	110.1
avg_vpv_12	62.0	58.0	68.5	62.8	91.9	90.8	79.8	87.5	99.0	102.8	111.9	104.6	111.6	115.4	120.7	115.9
avg_vpv_13	47.0	67.5	77.5	64.0	79.3	92.2	78.4	83.3	146.9	132.7	130.8	136.8	125.3	135.1	125.4	128.6
avg_vpv_14	46.0	103.0	82.0	77.0	83.1	87.9	79.2	83.4	144.1	150.8	103.0	132.6	146.3	140.3	121.4	136.0
avg_vpv_15	49.5	48.0	75.5	57.7	78.9	83.2	80.1	80.7	140.3	157.0	137.1	144.8	161.1	144.4	134.0	146.5
avg_vpv_16	72.5	67.5	87.0	75.7	88.0	86.6	90.2	88.3	161.2	137.0	145.7	148.0	171.6	145.4	148.1	155.0
avg_vpv_17	61.0	79.0	99.0	79.7	89.5	98.3	97.2	95.0	165.3	175.4	185.0	175.3	174.1	181.9	183.8	179.9
avg_vpv_18	61.0	71.0	92.0	74.7	102.8	111.8	107.7	107.4	180.8	196.9	208.2	195.3	184.0	198.2	205.7	196.0
avg_vpv_19	53.5	113.5	74.0	80.3	120.8	121.0	113.5	118.4	181.2	190.2	197.7	189.7	199.1	198.8	194.8	197.6
avg_vpv_20	68.0	93.0	73.0	78.0	124.7	134.2	129.8	129.5	167.3	172.8	176.4	172.2	176.7	192.1	183.2	184.0
avg_vpv_21	82.0	99.5	100.0	93.8	133.3	135.2	135.9	134.8	169.7	161.0	142.8	157.8	175.4	172.4	160.0	169.3
avg_vpv_22	117.0	110.5	110.5	112.7	139.2	133.2	137.5	136.6	150.3	107.7	90.7	116.2	173.4	160.8	147.7	160.6
avg_vpv_23	133.5	142.5	133.0	136.3	141.8	144.4	141.6	142.6	140.1	137.3	96.8	124.7	175.2	174.8	165.1	171.7
avg_vpv_24	146.5	167.5	151.0	155.0	136.6	144.3	145.6	142.2	159.2	144.2	144.9	149.4	175.3	173.7	165.1	171.4
avg_vpv_25	163.0	180.0	159.5	167.5	140.9	141.3	139.2	140.5	202.7	166.6	130.9	166.7	200.1	188.3	162.4	183.6
avg_vpv_26	158.0	181.0	164.0	167.7	124.5	132.1	123.3	126.6	147.8	117.6	98.1	121.1	155.7	150.1	137.0	147.6
avg_vpv_27	152.5	173.0	154.5	160.0	123.2	126.9	126.5	125.5	159.8	122.2	105.7	129.2	166.3	141.9	144.3	150.9
avg_vpv_28	161.5	167.0	149.5	159.3	113.4	116.8	117.7	116.0	154.9	128.1	116.0	133.0	152.2	139.9	141.3	144.5
avg_vpv_29	153.5	169.0	164.0	162.2	110.3	112.7	113.5	112.2	137.4	126.0	124.0	129.1	140.0	137.1	147.1	141.4
avg_vpv_30	144.0	185.0	179.0	169.3	115.0	125.5	120.8	120.4	149.0	146.3	145.9	147.1	150.6	155.4	163.6	156.5
avg_vpv_31	96.5	150.5	155.5	134.2	104.0	118.8	115.5	112.7	128.6	141.4	136.4	135.5	135.8	143.3	153.9	144.3
avg_vpv_32	83.0	117.0	152.5	117.5	95.2	112.6	118.8	108.8	98.7	115.4	136.3	116.8	114.6	125.9	156.8	132.4
avg_vpv_100	72.0	95.0	125.0	97.3	93.2	109.3	112.5	105.0	94.7	93.6	115.0	101.1	107.2	104.2	119.8	110.4
avg_vpv_kumul_100do0	135.0	129.5	125.5	130.0	100.0	105.5	98.0	101.2	26.6	26.8	24.4	25.9	11.0	9.0	10.0	10.0
avg_vpv_kumul_100do1	132.5	114.5	131.0	126.0	105.8	101.0	99.7	102.2	15.3	24.0	29.1	22.8	10.6	15.9	16.1	14.2
avg_vpv_kumul_100do2	125.5	107.0	130.5	121.0	107.8	100.6	103.1	103.8	9.9	23.2	23.2	18.8	6.1	16.8	16.1	13.0
avg_vpv_kumul_100do3	120.5	102.5	129.0	117.3	106.8	99.0	105.6	103.8	8.0	22.0	20.6	16.9	8.2	18.6	18.7	15.1
avg_vpv_kumul_100do4	111.0	96.0	115.5	107.5	105.0	97.5	105.4	102.6	10.7	26.6	24.3	20.5	11.4	23.7	22.6	19.2
avg_vpv_kumul_100do5	94.0	95.5	99.5	96.3	100.8	96.9	103.4	100.4	17.3	36.3	35.9	29.9	17.3	33.1	31.8	27.4
avg_vpv_kumul_100do6	78.0	101.0	87.5	88.8	96.4	100.7	100.0	99.0	27.7	48.1	44.1	40.0	26.1	44.9	40.6	37.2
avg_vpv_kumul_100do7	75.5	77.5	78.0	77.0	96.0	94.5	96.9	95.8	37.9	67.7	71.4	59.0	37.3	61.0	49.4	49.3
avg_vpv_kumul_100do8	74.0	71.0	77.5	74.2	97.7	92.8	94.1	94.8	47.1	89.1	89.8	75.3	53.6	78.6	61.0	64.4
avg_vpv_kumul_100do9	84.0	57.0	89.5	76.8	103.2	92.3	92.6	96.1	56.7	105.6	101.9	88.0	65.1	86.0	75.6	75.6
avg_vpv_kumul_100do10	73.0	56.0	89.5	72.8	99.8	94.5	92.4	95.6	62.2	116.6	127.8	102.2	71.1	96.7	94.9	87.6
avg_vpv_kumul_100do11	75.5	73.5	85.5	78.2	96.7	97.2	93.0	95.6	71.2	126.6	135.4	111.1	80.9	109.7	105.7	98.7
avg_vpv_kumul_100do12	79.5	90.0	77.0	82.2	97.9	100.8	94.0	97.6	83.4	137.1	138.9	119.8	88.6	116.0	118.1	107.6
avg_vpv_kumul_100do13	84.0	90.0	80.5	84.8	102.8	102.8	97.2	100.9	98.7	144.3	150.3	131.1	101.2	122.9	129.9	118.0
avg_vpv_kumul_100do14	83.5	87.0	85.0	85.2	99.8	102.2	103.5	101.8	125.6	157.3	166.4	149.8	115.7	130.1	142.9	129.6
avg_vpv_kumul_100do15	77.0	93.0	85.5	85.2	104.2	109.8	112.5	108.8	144.9	161.4	169.4	158.6	137.4	138.9	150.3	142.2
avg_vpv_kumul_100do16	84.5	110.5	90.0	95.0	113.0	116.8	118.7	116.2	161.6	163.1	174.9	166.5	155.6	144.0	154.8	151.4
avg_vpv_kumul_100do17	98.0	108.5	97.5	101.3	126.5	123.7	125.3	125.2	163.9	155.7	169.8	163.1	161.6	142.9	154.9	153.1
avg_vpv_kumul_100do18	102.0	119.0	106.0	109.0	135.3	130.5	136.2	134.0	167.1	144.9	173.1	161.7	169.1	142.1	156.1	155.8
avg_vpv_kumul_100do19	114.0	123.0	117.5	118.2	143.3	137.8	139.5	140.2	159.7	140.0	170.0	156.6	163.6	144.8	163.0	157.1
avg_vpv_kumul_100do20	137.5	133.0	130.5	133.7	146.5	142.2	142.3	143.7	158.9	131.4	157.4	149.3	169.9	146.1	160.8	158.9
avg_vpv_kumul_100do21	149.5	144.5	139.5	144.5	147.8	143.1	142.2	144.3	155.2	121.1	154.1	143.5	167.8	146.2	157.9	157.3
avg_vpv_kumul_100do22	151.5	155.5	146.5	151.2	144.0	139.7	139.8	141.2	150.6	119.2	146.8	138.9	168.6	149.4	157.9	158.6
avg_vpv_kumul_100do23	151.5	164.5	152.0	156.0	138.5	136.7	137.8	137.7	153.4	117.8	137.6	136.3	167.6	150.7	155.9	158.0
avg_vpv_kumul_100do24	151.5	168.0	155.0	158.2	132.4	131.5	133.2	132.4	145.6	117.8	128.9	130.7	158.8	147.7	156.0	154.1
avg_vpv_kumul_100do25	146.0	167.0	155.5	156.2	126.6	127.0	127.3	127.0	142.6	117.4	130.7	130.2	159.8	139.7	159.4	153.0
avg_vpv_kumul_100do26	150.0	171.0	163.5	161.5	120.7	122.7	123.5	122.3	152.2	129.3	139.9	140.5	158.4	140.8	159.2	152.8
avg_vpv_kumul_100do27	141.0	169.5	172.5	161.0	115.2	119.0	122.2	118.8	151.3	133.9	155.3	146.9	152.2	142.8	165.0	153.3
avg_vpv_kumul_100do28	126.5	172.0	182.5	160.3	111.5	124.2	125.0	120.2	138.6	156.9	166.0	153.8	144.6	159.4	176.3	160.1
avg_vpv_kumul_100do29	94.5	151.5	172.5	139.5	101.7	121.5	125.4	116.2	121.1	145.4	163.2	143.3	131.0	143.9	172.1	149.0
avg_vpv_kumul_100do30	81.0	126.0	152.0	119.7	97.2	114.2	119.1	110.1	112.4	122.7	141.1	125.4	122.7	124.6	152.2	133.1
avg_vpv_kumul_100do31	76.5	99.0	133.5	103.0	94.7	110.2	113.9	106.3	101.2	103.1	121.9	108.7	111.7	110.3	129.6	117.2
stdev_vpv_0	76.0	39.0	35.0	50.0	116.3	94.2	92.5	101.0	6.8	42.1	89.7	46.2	9.9	41.4	57.9	36.4
stdev_vpv_1	113.0	74.0	98.0	95.0	104.2	96.7	101.3	100.7	15.9	52.1	76.7	48.2	20.3	50.4	76.0	48.9
stdev_vpv_2	111.5	105.0	107.5	108.0	106.2	116.4	132.4	118.3	5.7	9.0	12.0	8.9	3.6	8.0	9.3	7.0
stdev_vpv_3	105.0	128.0	89.0	107.3	106.9	111.0	116.8	111.6	8.1	32.7	54.3	31.7	10.6	26.8	54.8	30.7
stdev_vpv_4	105.0	126.0	59.5	96.8	92.3	102.6	95.8	96.9	12.4	27.4	63.3	34.4	18.1	32.6	57.1	35.9
stdev_vpv_5	113.5	93.5	103.5	103.5	93.7	107.2	91.8	97.6	27.4	38.4	74.1	46.7	24.0	28.1	49.0	33.7
stdev_vpv_6	55.0	83.0	81.5	73.2	88.8	84.5	97.1	90.1	31.3	57.2	62.4	50.3	24.7	55.7	85.0	55.1
stdev_vpv_7	16.5	10.5	22.0	16.3	91.8	77.1	81.8	83.6	29.7	82.6	109.8	74.0	18.8	44.9	90.4	51.4
stdev_vpv_8	35.5	32.5	75.5	47.8	89.8	91.2	81.0	87.3	52.7	88.0	69.8	70.1	46.3	68.6	79.6	64.8
stdev_vpv_9	12.0	15.0	22.0	16.3	88.5	96.7	89.8	91.6	133.0	124.4	118.4	125.3	74.9	87.3	68.7	77.0
stdev_vpv_10	87.0	103.5	79.5	90.0	83.7	93.1	87.3	88.0	69.0	90.2	86.3	81.9	66.2	54.1	70.2	63.5
stdev_vpv_11	78.5	99.0	89.5	89.0	96.2	79.2	81.0	85.4	94.4	90.1	82.2	88.9	79.1	76.7	84.1	80.0
stdev_vpv_12	59.0	52.0	101.5	70.8	102.8	90.8	84.1	92.6	118.8	122.1	90.8	110.6	98.7	95.9	86.0	93.5
stdev_vpv_13	93.5	90.5	111.5	98.5	112.5	105.8	79.8	99.3	125.3	89.9	69.0	94.7	109.3	117.3	84.4	103.7
stdev_vpv_14	77.5	103.5	72.5	84.5	109.9	102.1	79.5	97.2	149.3	165.7	79.8	131.6	157.9	137.7	97.3	131.0
stdev_vpv_15	103.5	93.0	74.5	90.3	108.0	98.2	87.1	97.8	143.9	177.4	143.0	154.8	160.9	137.1	106.7	134.9
stdev_vpv_16	103.5	119.5	121.0	114.7	111.6	97.2	98.6	102.5	172.4	142.1	117.3	144.0	177.0	120.4	118.7	138.7
stdev_vpv_17	85.5	110.0	118.0	104.5	107.2	100.9	101.9	103.4	142.7	147.4	171.9	154.0	166.2	146.0	151.7	154.6
stdev_vpv_18	84.0	113.5	92.5	96.7	112.6	103.4	101.2	105.7	176.0	156.8	178.4	170.4	185.4	174.3	176.8	178.9
stdev_vpv_19	108.5	127.5	91.0	109.0	124.2	106.8	101.8	111.0	155.3	178.2	174.2	169.3	189.0	183.6	156.3	176.3
stdev_vpv_20	88.5	98.0	62.0	82.8	136.1	123.2	109.2	122.8	174.6	162.8	170.8	169.4	184.3	185.4	159.1	176.3
stdev_vpv_21	85.5	82.5	94.0	87.3	140.5	130.1	122.0	130.8	182.1	182.6	146.0	170.2	191.3	181.1	140.4	171.0
stdev_vpv_22	111.5	38.5	50.0	66.7	152.1	132.4	130.3	138.3	173.6	134.6	119.0	142.4	188.6	141.4	138.2	156.1
stdev_vpv_23	127.5	96.5	65.0	96.3	154.6	148.8	135.5	146.3	138.7	174.1	112.7	141.8	181.2	175.6	141.3	166.0
stdev_vpv_24	146.5	134.5	88.5	123.2	150.1	154.2	148.8	151.0	181.6	164.7	151.9	166.0	191.1	175.9	155.4	174.1
stdev_vpv_25	174.5	141.5	111.5	142.5	147.7	151.8	149.8	149.8	185.6	160.7	136.1	160.8	188.2	179.2	156.0	174.5
stdev_vpv_26	183.0	165.0	133.0	160.3	144.3	148.1	141.2	144.5	161.6	112.3	115.7	129.9	167.8	139.8	156.7	154.7
stdev_vpv_27	199.5	176.0	114.5	163.3	145.2	153.2	151.9	150.1	165.1	117.3	123.0	135.1	174.4	143.8	163.2	160.5
stdev_vpv_28	199.0	183.0	146.5	176.2	139.9	142.6	147.8	143.5	175.1	156.6	124.9	152.2	171.2	171.0	149.1	163.8
stdev_vpv_29	199.0	205.0	176.0	193.3	133.2	139.9	143.5	138.9	153.6	143.0	133.1	143.2	148.2	165.8	164.0	159.3
stdev_vpv_30	194.5	210.5	203.5	202.8	130.4	141.9	142.2	138.2	162.6	157.2	173.1	164.3	161.6	168.7	165.6	165.3
stdev_vpv_31	145.5	190.5	195.5	177.2	116.8	134.1	134.8	128.5	141.9	181.7	180.2	167.9	155.2	168.9	170.0	164.7
stdev_vpv_32	119.0	171.5	192.0	160.8	107.8	132.2	136.9	125.6	111.0	165.3	188.9	155.1	123.7	167.4	183.6	158.2
stdev_vpv_100	79.0	119.5	169.0	122.5	98.1	119.3	132.1	116.5	88.1	124.4	177.9	130.1	111.8	123.8	171.6	135.7

Skupina ciljnih spremenljivk	Svetloba 120				Svetloba 170				Svetloba, vsi koti				Vse				min	Vse min	Vse avg
Pojasnjevalna spremenljivka	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi		min	avg
avg_vpv_0	5.7	6.8	9.8	7.4	4.6	6.2	9.7	6.8	12.2	12.7	13.0	12.6	39.4	41.1	39.2	39.9	4.6	4.6	115.3
avg_vpv_1	7.0	9.2	10.1	8.8	6.2	8.6	9.7	8.1	9.9	9.4	11.4	10.2	39.3	36.5	38.8	38.2	6.2		
avg_vpv_2	11.8	8.3	7.6	9.2	10.9	8.2	7.4	8.9	15.7	10.9	8.5	11.7	41.2	41.7	41.8	41.5	7.4		
avg_vpv_3	22.6	20.0	26.9	23.1	23.0	24.2	34.1	27.1	23.9	19.9	23.5	22.4	44.7	44.5	46.6	45.3	11.2		
avg_vpv_4	26.2	33.9	41.1	33.7	28.2	40.4	50.0	39.6	28.4	33.2	33.9	31.8	47.0	51.9	49.7	49.5	13.9		
avg_vpv_5	40.7	43.7	55.8	46.7	41.1	47.0	61.7	49.9	40.0	36.0	41.3	39.1	53.6	53.4	56.0	54.3	14.1		
avg_vpv_6	61.3	68.0	63.2	64.2	60.4	69.1	70.4	66.7	62.1	61.8	56.7	60.2	68.6	68.7	65.7	67.7	34.6		
avg_vpv_7	59.8	76.2	78.1	71.4	63.6	80.8	84.6	76.3	55.6	61.3	69.8	62.2	63.9	65.7	72.0	67.2	35.9		
avg_vpv_8	79.1	77.0	67.9	74.7	81.9	80.0	72.6	78.1	80.6	70.8	64.8	72.0	79.8	73.0	68.8	73.9	46.0		
avg_vpv_9	94.7	95.3	78.0	89.3	95.7	95.3	78.0	89.7	104.8	93.6	79.1	92.5	95.3	87.9	76.7	86.6	19.0		
avg_vpv_10	115.1	107.8	92.6	105.1	115.7	105.1	95.6	105.4	113.0	108.6	89.8	103.8	103.5	100.8	85.7	96.7	58.0		
avg_vpv_11	134.7	115.4	111.0	120.4	132.2	113.4	113.0	119.6	123.9	113.2	105.2	114.1	112.9	103.3	97.5	104.5	59.5		
avg_vpv_12	117.2	118.2	120.3	118.6	116.3	118.8	124.1	119.7	111.0	113.8	119.3	114.7	104.2	105.8	107.2	105.7	58.0		
avg_vpv_13	151.1	155.2	145.6	150.6	152.8	154.0	149.9	152.2	144.0	144.3	137.9	142.1	123.7	128.0	120.4	124.0	47.0		
avg_vpv_14	164.2	149.1	146.9	153.4	167.3	146.4	149.4	154.4	155.5	146.7	130.2	144.1	132.7	130.0	115.3	126.0	46.0		
avg_vpv_15	163.7	151.9	154.2	156.6	166.2	150.4	149.3	155.3	157.8	150.9	143.7	150.8	133.5	129.6	124.8	129.3	48.0		
avg_vpv_16	177.4	159.4	158.1	165.0	180.3	159.9	153.9	164.7	172.6	150.4	151.4	158.2	147.1	130.9	133.3	137.1	67.5		
avg_vpv_17	187.3	184.4	183.3	185.0	188.8	186.0	185.2	186.7	178.9	181.9	184.3	181.7	151.5	156.6	158.8	155.6	61.0		
avg_vpv_18	187.2	196.1	207.3	196.9	189.9	199.6	208.8	199.4	185.5	197.7	207.5	196.9	159.5	170.8	177.5	169.3	61.0		
avg_vpv_19	198.7	198.1	198.6	198.4	201.3	198.9	200.0	200.1	195.1	196.5	197.8	196.4	170.6	174.0	171.4	172.0	53.5		
avg_vpv_20	180.8	197.9	195.9	191.5	183.2	198.9	196.1	192.7	177.0	190.4	187.9	185.1	159.4	172.3	168.6	166.7	68.0		
avg_vpv_21	182.2	185.3	179.0	182.2	182.8	186.2	180.2	183.1	177.5	176.3	165.5	173.1	162.5	162.8	155.4	160.2	82.0		
avg_vpv_22	178.0	176.0	171.4	175.1	178.3	176.6	173.9	176.3	170.0	155.3	145.9	157.1	160.1	147.9	142.4	150.1	90.7		
avg_vpv_23	176.4	187.2	182.8	182.1	174.8	187.4	183.0	181.7	166.6	171.7	156.9	165.1	159.0	163.6	152.1	158.2	96.8		
avg_vpv_24	174.9	186.8	183.4	181.7	175.4	186.9	182.1	181.5	171.2	172.9	168.9	171.0	161.4	165.4	162.3	163.0	136.6		
avg_vpv_25	194.2	194.3	175.9	188.1	194.7	194.1	175.0	187.9	197.9	185.8	161.1	181.6	182.0	174.3	155.4	170.6	130.9		
avg_vpv_26	151.4	166.7	152.4	156.9	151.6	166.2	152.1	156.6	151.6	150.1	134.9	145.6	144.9	146.7	133.1	141.6	98.1		
avg_vpv_27	147.4	157.6	172.0	159.0	145.4	155.8	172.8	158.0	154.8	144.4	148.7	149.3	146.6	141.0	143.3	143.6	105.7		
avg_vpv_28	132.9	145.0	155.7	144.5	129.1	144.4	157.1	143.6	142.3	139.4	142.5	141.4	135.7	134.7	136.5	135.6	113.4		
avg_vpv_29	129.6	149.6	158.4	145.9	126.6	149.7	160.0	145.4	133.4	140.6	147.4	140.5	128.3	134.6	139.4	134.1	110.3		
avg_vpv_30	148.3	168.9	173.6	163.6	147.3	167.4	174.8	163.2	148.8	159.5	164.4	157.6	140.0	151.9	153.9	148.6	115.0		
avg_vpv_31	122.4	154.9	160.3	145.9	119.3	152.4	160.6	144.1	126.5	148.0	152.8	142.5	119.6	140.7	143.4	134.6	96.5		
avg_vpv_32	99.7	133.7	160.0	131.1	97.0	131.8	158.8	129.2	102.5	126.7	153.0	127.4	99.8	122.7	144.2	122.3	83.0		
avg_vpv_100	96.6	103.0	124.4	108.0	95.0	100.7	126.8	107.5	98.4	100.4	121.5	106.7	96.0	102.4	119.3	105.9	72.0		
avg_vpv_kumul_100do0	6.4	5.8	9.4	7.2	5.1	5.2	9.3	6.6	12.3	11.7	13.3	12.4	39.5	40.2	39.3	39.7	5.1	5.1	110.2
avg_vpv_kumul_100do1	7.6	12.4	14.2	11.4	7.6	12.0	13.2	10.9	10.3	16.1	18.2	14.8	39.4	41.6	43.4	41.5	7.6		
avg_vpv_kumul_100do2	7.8	13.7	14.6	12.0	8.0	13.2	13.7	11.6	7.9	16.7	16.9	13.9	38.0	41.6	43.3	41.0	6.1		
avg_vpv_kumul_100do3	10.4	15.1	16.1	13.9	10.4	15.2	15.1	13.6	9.3	17.7	17.6	14.9	38.5	41.8	44.4	41.6	8.0		
avg_vpv_kumul_100do4	14.2	20.7	19.9	18.3	14.2	21.0	19.3	18.2	12.6	23.0	21.5	19.0	40.0	44.8	46.6	43.8	10.7		
avg_vpv_kumul_100do5	24.0	30.8	25.4	26.7	23.3	32.1	25.8	27.1	20.5	33.1	29.7	27.8	43.9	51.8	51.2	49.0	17.3		
avg_vpv_kumul_100do6	33.0	47.1	39.4	39.9	34.1	48.3	38.4	40.3	30.2	47.1	40.6	39.3	49.0	62.9	57.6	56.5	26.1		
avg_vpv_kumul_100do7	54.1	65.2	47.4	55.6	51.2	64.9	48.2	54.8	45.1	64.7	54.1	54.7	59.3	72.8	66.0	66.0	37.3		
avg_vpv_kumul_100do8	71.9	79.4	59.9	70.4	67.8	75.2	59.0	67.3	60.1	80.6	67.4	69.4	70.2	83.3	74.6	76.0	47.1		
avg_vpv_kumul_100do9	90.2	92.8	72.7	85.2	83.7	90.1	69.8	81.2	73.9	93.6	80.0	82.5	81.8	91.8	83.6	85.7	56.7		
avg_vpv_kumul_100do10	101.3	103.1	91.7	98.7	95.8	101.6	86.7	94.7	82.6	104.5	100.3	95.8	86.6	100.0	97.8	94.8	56.0		
avg_vpv_kumul_100do11	109.0	116.3	106.8	110.7	105.4	114.4	99.9	106.6	91.6	116.8	111.9	106.8	92.3	110.1	106.1	102.8	71.2		
avg_vpv_kumul_100do12	116.3	122.6	118.6	119.1	113.4	120.6	112.9	115.6	100.4	124.1	122.1	115.5	99.0	116.8	113.2	109.6	77.0		
avg_vpv_kumul_100do13	125.4	129.1	129.1	127.9	123.8	126.9	124.2	125.0	112.3	130.8	133.4	125.5	108.8	122.1	122.1	117.6	80.5		
avg_vpv_kumul_100do14	137.4	137.0	138.7	137.7	136.4	136.1	134.4	135.7	128.8	140.1	145.6	138.2	119.6	128.4	132.5	126.8	83.5		
avg_vpv_kumul_100do15	148.4	144.4	144.0	145.6	149.4	143.6	141.2	144.7	145.1	147.1	151.3	147.8	132.0	135.5	138.8	135.4	77.0		
avg_vpv_kumul_100do16	162.2	151.3	148.0	153.9	161.9	151.9	145.3	153.0	160.3	152.6	155.8	156.2	145.3	141.8	143.7	143.6	84.5		
avg_vpv_kumul_100do17	163.9	156.3	149.8	156.7	163.0	154.2	147.8	155.0	163.1	152.3	155.6	157.0	151.2	143.3	145.6	146.7	97.5		
avg_vpv_kumul_100do18	164.2	158.0	151.3	157.9	164.9	157.2	149.2	157.1	166.3	150.6	157.4	158.1	155.9	144.2	150.0	150.0	102.0		
avg_vpv_kumul_100do19	164.7	161.0	154.9	160.2	164.9	159.7	152.9	159.1	163.2	151.4	160.2	158.3	156.2	146.8	153.3	152.1	114.0		
avg_vpv_kumul_100do20	169.2	162.8	154.7	162.2	168.3	161.2	151.6	160.4	166.6	150.4	156.1	157.7	160.3	147.6	151.6	153.2	130.5		
avg_vpv_kumul_100do21	169.2	163.7	154.4	162.4	168.0	162.6	150.9	160.5	165.1	148.4	154.3	155.9	160.0	146.9	150.6	152.5	121.1		
avg_vpv_kumul_100do22	165.2	168.0	157.0	163.4	165.0	164.9	155.0	161.6	162.3	150.4	154.2	155.6	157.2	147.9	150.2	151.8	119.2		
avg_vpv_kumul_100do23	155.7	165.6	159.6	160.3	158.3	162.2	160.0	160.2	158.8	149.1	153.3	153.7	153.3	146.5	149.3	149.7	117.8		
avg_vpv_kumul_100do24	150.1	160.9	165.2	158.7	150.1	158.3	165.8	158.1	151.1	146.2	154.0	150.4	146.4	143.3	148.7	146.1	117.8		
avg_vpv_kumul_100do25	146.0	151.4	169.1	155.5	144.3	149.2	168.7	154.1	148.2	139.4	157.0	148.2	142.6	137.4	149.4	143.1	117.4		
avg_vpv_kumul_100do26	141.2	151.2	169.2	153.9	139.3	149.1	169.9	152.8	147.8	142.6	159.6	150.0	141.0	138.6	150.5	143.4	120.7		
avg_vpv_kumul_100do27	138.4	148.9	171.9	153.1	135.4	147.7	173.4	152.2	144.4	143.3	166.4	151.4	136.8	138.1	155.4	143.4	115.2		
avg_vpv_kumul_100do28	133.2	165.4	181.8	160.1	130.9	163.8	182.2	159.0	136.8	161.4	176.6	158.3	129.9	152.3	163.7	148.6	111.5		
avg_vpv_kumul_100do29	115.7	148.9	174.8	146.4	114.7	148.3	175.6	146.2	120.6	146.6	171.4	146.2	114.8	140.4	159.7	138.3	94.5		
avg_vpv_kumul_100do30	105.7	127.9	152.9	128.8	103.7	125.8	152.6	127.3	111.1	125.2	149.7	128.7	106.4	122.4	142.0	123.6	81.0		
avg_vpv_kumul_100do31	98.4	113.6	133.4	115.1	96.7	113.1	136.1	115.3	102.0	110.0	130.3	114.1	99.1	109.6	126.2	111.7	76.5		
stdev_vpv_0	11.4	48.4	80.8	46.9	13.6	57.7	89.9	53.7	10.4	47.4	79.6	45.8	40.0	59.0	81.1	60.0	6.8	2.4	117.7
stdev_vpv_1	29.9	56.2	66.2	50.8	31.7	56.7	69.4	52.6	24.4	53.9	72.1	50.1	48.3	65.6	80.5	64.8	15.9		
stdev_vpv_2	2.4	6.6	10.2	6.4	2.4	7.2	10.1	6.6	3.5	7.7	10.4	7.2	33.9	39.2	45.3	39.5	2.4		
stdev_vpv_3	11.4	23.4	58.4	31.1	11.0	23.8	64.9	33.2	10.3	26.7	58.1	31.7	38.6	52.1	74.3	55.0	8.1		
stdev_vpv_4	15.3	31.4	74.0	40.3	16.6	31.7	83.1	43.8	15.6	30.8	69.4	38.6	38.7	52.8	75.7	55.7	12.4		
stdev_vpv_5	15.0	25.0	65.0	35.0	14.8	22.3	66.2	34.4	20.3	28.5	63.6	37.5	42.7	51.1	72.3	55.4	14.8		
stdev_vpv_6	17.9	44.1	79.1	47.0	19.6	38.2	81.4	46.4	23.4	48.8	77.0	49.7	41.3	59.2	82.3	60.9	17.9		
stdev_vpv_7	20.0	48.7	81.8	50.1	21.6	47.7	84.9	51.4	22.5	55.9	91.7	56.7	39.9	59.5	86.5	62.0	10.5		
stdev_vpv_8	52.1	54.6	58.4	55.0	56.9	59.1	64.2	60.1	52.0	67.6	68.0	62.5	61.0	72.2	71.6	68.3	32.5		
stdev_vpv_9	66.7	68.8	51.7	62.4	64.7	68.1	52.6	61.8	84.8	87.2	72.8	81.6	82.9	86.8	75.2	81.6	12.0		
stdev_vpv_10	87.9	65.1	75.2	76.1	91.7	63.8	81.3	78.9	78.7	68.3	78.3	75.1	80.3	76.0	80.6	79.0	54.1		
stdev_vpv_11	101.9	72.6	69.3	81.3	98.9	68.3	73.3	80.2	93.6	76.9	77.3	82.6	93.6	78.4	78.7	83.6	68.3		
stdev_vpv_12	109.0	91.4	86.4	95.6	112.8	88.0	87.0	95.9	109.8	99.4	87.6	98.9	106.0	95.3	87.2	96.2	52.0		
stdev_vpv_13	150.1	132.1	99.8	127.3	150.4	128.9	100.4	126.6	133.8	117.1	88.4	113.1	126.8	113.1	87.1	109.0	69.0		
stdev_vpv_14	191.0	132.2	111.8	145.0	192.4	133.2	112.2	146.0	172.7	142.2	100.3	138.4	152.9	130.5	93.9	125.8	72.5		
stdev_vpv_15	184.9	137.8	124.7	149.1	186.6	135.9	119.6	147.3	169.1	147.1	123.5	146.5	150.9	132.5	112.3	131.9	74.5		
stdev_vpv_16	193.9	139.9	119.8	151.2	195.6	139.6	116.2	150.4	184.7	135.5	118.0	146.1	162.9	125.1	113.2	133.7	97.2		
stdev_vpv_17	199.9	164.0	161.4	175.1	201.0	165.7	157.1	174.6	177.4	155.8	160.5	164.6	155.9	140.0	143.9	146.6	85.5		
stdev_vpv_18	200.9	181.8	172.3	185.0	203.0	187.6	173.8	188.1	191.3	175.1	175.3	180.6	167.1	154.4	153.2	158.2	84.0		
stdev_vpv_19	200.2	184.4	149.9	178.2	205.3	183.2	148.8	179.1	187.5	182.4	157.3	175.7	168.3	161.0	140.6	156.6	91.0		
stdev_vpv_20	196.3	189.3	164.3	183.3	201.3	191.4	168.9	187.2	189.1	182.3	165.8	179.1	171.7	163.9	147.3	160.9	62.0		
stdev_vpv_21	203.3	179.9	136.8	173.3	206.4	180.7	134.9	174.0	195.8	181.1	139.5	172.1	177.4	164.2	133.3	158.3	82.5		
stdev_vpv_22	200.7	169.0	142.7	170.8	201.7	168.0	136.7	168.8	191.1	153.3	134.1	159.5	178.0	143.4	129.9	150.4	38.5		
stdev_vpv_23	189.6	194.7	141.4	175.2	191.1	191.3	136.8	173.1	175.1	183.9	133.1	164.0	168.0	171.5	131.0	156.9	65.0		
stdev_vpv_24	195.1	189.7	150.4	178.4	200.9	189.3	143.3	177.9	192.2	179.9	150.3	174.1	179.6	171.6	147.5	166.2	88.5		
stdev_vpv_25	193.3	199.4	147.4	180.1	195.1	199.6	141.6	178.7	190.6	184.7	145.3	173.5	179.0	174.6	145.1	166.2	111.5		
stdev_vpv_26	170.3	159.1	157.3	162.3	170.7	159.2	154.3	161.4	167.6	142.6	146.0	152.1	162.3	144.9	144.3	150.5	112.3		
stdev_vpv_27	171.0	170.4	192.4	178.0	173.7	168.7	191.0	177.8	171.1	150.1	167.4	162.8	165.6	151.9	161.4	159.6	114.5		
stdev_vpv_28	157.0	177.6	171.7	168.7	157.1	179.0	172.2	169.4	165.1	171.0	154.5	163.5	160.0	164.3	152.5	158.9	124.9		
stdev_vpv_29	147.4	177.1	174.6	166.4	147.4	178.8	177.4	167.9	149.2	166.2	162.3	159.2	147.1	161.0	158.0	155.4	133.1		
stdev_vpv_30	166.1	183.2	183.8	177.7	163.4	183.7	184.2	177.1	163.4	173.2	176.7	171.1	156.2	166.7	168.9	163.9	130.4		
stdev_vpv_31	146.9	178.3	182.0	169.1	147.0	177.7	185.0	169.9	147.8	176.6	179.3	167.9	139.8	166.3	168.6	158.2	116.8		
stdev_vpv_32	113.9	168.9	184.2	155.7	112.8	168.9	182.9	154.9	115.3	167.6	184.9	156.0	113.5	158.7	172.9	148.4	107.8		
stdev_vpv_100	99.9	111.7	155.8	122.4	95.8	109.2	157.0	120.7	98.9	117.3	165.6	127.2	97.9	117.9	157.2	124.3	79.0		

min	2.5	3.5	5.0	20.0	51.2	50.9	53.7	51.9	6.9	5.4	8.1	8.7	5.0	3.0	1.7	3.6	1.4	1.9	1.1	2.0	1.0	1.7	1.0	1.6	5.0	3.0	3.9	4.0	33.9	35.1	33.9	38.1	1.0
max	214.0	207.0	212.0	178.2	152.8	154.7	153.7	152.9	216.7	194.3	211.9	204.4	216.3	215.4	216.0	211.8	213.0	211.7	216.9	209.9	215.8	215.6	217.0	211.8	215.4	205.3	215.4	206.4	174.8	176.8	185.5	174.8	142.2
avg	114.1	107.2	109.3	110.2	107.5	106.4	107.5	107.1	108.3	106.7	106.3	107.1	104.3	104.8	103.4	104.2	101.9	99.4	99.8	100.3	101.8	99.7	99.5	100.3	104.1	102.6	102.2	103.0	105.3	103.8	103.9	104.3	51.3
Meje označevanja (a= (max-min)/100):																																	
visoki rangi do (min+5a)	13.1	13.7	15.4	27.9	56.3	56.1	58.7	57.0	17.4	14.9	18.3	18.5	15.6	13.6	12.4	14.0	12.0	12.4	11.9	12.4	11.7	12.4	11.8	12.1	15.5	13.1	14.5	14.1	41.0	42.2	41.5	44.9	8.1
srednji rangi do (min+10a)	23.7	23.9	25.7	35.8	61.4	61.3	63.7	62.0	27.9	24.3	28.5	28.3	26.1	24.2	23.1	24.4	22.6	22.9	22.7	22.8	22.5	23.1	22.6	22.6	26.0	23.2	25.1	24.2	48.0	49.3	49.1	51.8	15.1
nižji rangi do (min+20a)	44.8	44.2	46.4	51.6	71.5	71.7	73.7	72.1	48.8	43.2	48.9	47.8	47.3	45.5	44.5	45.2	43.8	43.8	44.3	43.6	44.0	44.4	44.2	43.6	47.1	43.5	46.2	44.5	62.1	63.4	64.3	65.5	29.2

Skupina ciljnih spremenljivk	Drugo				Drevesne vrste				Svetloba 45				Svetloba 60				Svetloba 120				Svetloba 170				Svetloba, vsi koti				Vse					Vse	Vse
Pojasnjevalna spremenljivka	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	r5	r10	r20	vsi	min	min	avg
stdev_vpv_kumul_100do0	76.0	39.0	36.0	50.3	115.6	94.4	92.6	100.9	6.9	42.0	89.6	46.1	9.3	41.3	58.2	36.3	12.4	48.1	80.7	47.1	14.6	57.8	89.6	54.0	10.8	47.3	79.5	45.9	40.1	59.0	81.1	60.1	6.9		
stdev_vpv_kumul_100do1	62.0	44.5	48.5	51.7	108.2	102.2	99.4	103.3	33.7	89.4	146.4	89.9	52.3	135.8	176.4	121.5	26.8	90.8	168.6	95.4	26.4	88.7	171.1	95.4	34.8	101.2	165.6	100.5	54.6	99.2	144.2	99.3	26.4		
stdev_vpv_kumul_100do2	50.0	59.5	59.5	56.3	106.2	108.4	104.5	106.4	41.1	120.1	163.8	108.3	56.1	144.7	188.6	129.8	26.8	75.0	183.6	95.1	26.9	69.6	186.3	94.3	37.7	102.3	180.6	106.9	55.7	102.2	156.4	104.8	26.8		
stdev_vpv_kumul_100do3	41.5	96.5	85.5	74.5	104.8	108.5	110.3	107.9	76.3	166.0	188.3	143.6	86.1	166.3	204.7	152.4	40.2	80.1	201.8	107.4	38.6	71.4	201.4	103.8	60.3	121.0	199.1	126.8	70.9	116.8	172.0	119.9	38.6		
stdev_vpv_kumul_100do4	58.0	107.0	73.5	79.5	112.5	111.2	110.8	111.5	94.3	184.1	199.9	159.4	105.8	177.6	208.1	163.8	64.4	90.1	198.6	117.7	58.6	79.0	196.3	111.3	80.8	132.7	200.7	138.1	88.0	126.2	172.8	129.0	58.0		
stdev_vpv_kumul_100do5	80.5	103.0	79.5	87.7	113.9	109.6	110.5	111.3	137.7	185.8	200.6	174.7	113.6	170.0	199.3	161.0	64.1	91.6	176.9	110.9	56.0	79.2	178.6	104.6	92.8	131.6	188.8	137.8	97.7	124.9	164.6	129.1	56.0		
stdev_vpv_kumul_100do6	42.5	91.5	102.5	78.8	100.3	110.8	107.4	106.2	137.7	177.6	184.6	166.6	97.9	160.6	174.9	144.4	55.7	92.9	150.8	99.8	47.6	82.4	150.9	93.6	84.7	128.4	165.3	126.1	87.0	122.4	148.1	119.2	42.5		
stdev_vpv_kumul_100do7	71.0	104.5	105.5	93.7	93.4	101.4	105.8	100.2	138.3	179.2	171.0	162.9	99.3	163.4	159.9	140.9	63.6	91.2	114.2	89.7	58.1	82.6	114.2	85.0	89.8	129.1	139.8	119.6	90.0	121.1	129.8	113.6	58.1		
stdev_vpv_kumul_100do8	87.0	111.5	108.5	102.3	91.6	100.8	101.7	98.1	144.3	180.6	165.6	163.5	104.8	159.1	145.8	136.6	73.6	89.2	92.4	85.1	67.4	82.0	90.6	80.0	97.5	127.7	123.6	116.3	95.6	120.2	117.4	111.1	67.4		
stdev_vpv_kumul_100do9	120.0	123.0	116.5	119.8	96.7	98.2	90.7	95.2	160.2	176.3	148.2	161.6	123.7	145.8	125.7	131.7	91.4	89.6	76.4	85.8	84.8	87.0	75.2	82.3	115.0	124.7	106.4	115.4	110.5	117.9	102.8	110.4	75.2		
stdev_vpv_kumul_100do10	137.0	125.5	121.0	127.8	106.5	95.3	82.9	94.9	169.4	177.2	142.3	163.0	141.6	147.4	119.4	136.1	109.1	96.3	68.9	91.4	104.4	94.8	66.0	88.4	131.1	128.9	99.2	119.8	125.1	120.2	95.9	113.7	66.0		
stdev_vpv_kumul_100do11	168.0	128.0	123.0	139.7	112.0	95.1	81.7	96.3	176.8	184.1	139.8	166.9	146.9	160.0	128.7	145.2	128.9	115.1	72.9	105.6	127.8	114.0	72.6	104.8	145.1	143.3	103.5	130.6	137.5	130.4	98.7	122.2	72.6		
stdev_vpv_kumul_100do12	183.0	136.5	128.5	149.3	110.7	97.2	84.5	97.5	177.2	181.4	128.0	162.2	137.7	159.1	119.2	138.7	138.4	116.1	70.9	108.5	135.6	114.0	68.7	106.1	147.2	142.7	96.7	128.9	139.3	130.8	94.8	121.7	68.7		
stdev_vpv_kumul_100do13	172.5	148.5	140.5	153.8	105.8	100.8	85.6	97.4	179.4	181.7	136.2	165.8	143.0	156.4	112.8	137.4	149.2	119.2	71.3	113.3	146.8	115.7	68.3	110.3	154.6	143.3	97.2	131.7	142.9	132.6	95.9	123.8	68.3		
stdev_vpv_kumul_100do14	143.0	136.0	133.5	137.5	91.4	94.2	87.8	91.1	177.7	174.3	147.8	166.6	138.4	136.9	107.7	127.7	143.2	118.9	79.2	113.8	140.7	115.8	73.2	109.9	150.0	136.5	102.0	129.5	134.8	125.7	99.6	120.0	73.2		
stdev_vpv_kumul_100do15	110.5	118.0	115.0	114.5	89.7	89.8	89.1	89.5	165.9	170.3	143.1	159.8	141.1	135.8	105.0	127.3	137.9	119.1	76.2	111.1	134.2	117.8	72.0	108.0	144.8	135.8	99.1	126.5	129.4	123.4	97.2	116.6	72.0	6.9	128.1
stdev_vpv_kumul_100do16	96.0	112.5	104.0	104.2	93.2	86.4	83.8	87.8	147.0	161.9	137.8	148.9	144.1	135.4	115.4	131.7	152.3	124.7	79.1	118.7	148.0	124.2	76.0	116.1	147.9	136.6	102.1	128.8	131.9	122.8	97.5	117.4	76.0		
stdev_vpv_kumul_100do17	102.5	104.0	84.0	96.8	103.5	83.6	81.4	89.5	166.6	148.3	120.7	145.2	166.8	132.0	120.3	139.7	165.8	126.1	77.6	123.1	165.7	126.2	75.7	122.5	166.2	133.2	98.6	132.6	147.7	119.4	93.6	120.2	75.7		
stdev_vpv_kumul_100do18	101.0	100.0	86.0	95.7	111.3	89.1	87.0	95.8	170.2	156.8	130.8	152.6	169.4	130.1	120.2	139.9	172.6	127.3	76.2	125.4	174.4	126.4	72.8	124.6	171.7	135.2	100.0	135.6	153.5	122.0	96.1	123.9	72.8		
stdev_vpv_kumul_100do19	96.5	94.5	58.5	83.2	128.5	104.8	93.4	108.9	161.6	139.2	143.6	148.1	160.6	118.9	127.4	135.6	174.0	123.1	87.4	128.2	177.7	121.7	77.8	125.7	168.4	125.7	109.1	134.4	155.5	119.2	103.1	125.9	58.5		
stdev_vpv_kumul_100do20	102.0	91.0	57.0	83.3	138.4	115.2	104.5	119.4	149.0	137.6	139.6	142.0	157.3	119.8	131.1	136.1	163.4	130.8	95.1	129.8	168.1	127.1	81.2	125.5	159.5	128.8	111.8	133.3	151.8	123.9	107.8	127.8	57.0		
stdev_vpv_kumul_100do21	123.0	84.5	50.0	85.8	148.4	126.4	114.8	129.9	125.2	118.3	146.1	129.9	154.6	120.2	138.7	137.8	164.6	135.9	103.7	134.7	168.4	134.6	89.9	131.0	153.2	127.3	119.6	133.3	150.8	125.4	115.6	130.6	50.0		
stdev_vpv_kumul_100do22	150.0	96.5	73.5	106.7	151.5	142.1	128.9	140.8	132.1	137.6	161.1	143.6	162.9	135.7	143.1	147.2	175.7	153.9	112.0	147.2	178.9	149.1	101.3	143.1	162.4	144.1	129.4	145.3	159.1	141.7	127.1	142.6	73.5		
stdev_vpv_kumul_100do23	179.5	122.0	93.5	131.7	151.2	152.4	143.8	149.2	157.6	146.2	153.3	152.4	168.7	148.7	145.8	154.4	174.1	160.2	123.1	152.5	178.3	156.9	111.7	149.0	169.7	153.0	133.5	152.0	165.4	151.6	134.5	150.5	93.5		
stdev_vpv_kumul_100do24	203.5	134.5	106.5	148.2	152.8	154.7	151.3	152.9	164.8	136.7	135.8	145.7	174.0	149.0	152.6	158.5	175.4	165.9	144.2	161.9	178.6	164.1	137.3	160.0	173.2	153.9	142.5	156.5	169.2	153.4	143.3	155.3	106.5		
stdev_vpv_kumul_100do25	212.0	163.0	121.0	165.3	150.7	154.6	152.2	152.5	163.2	133.6	136.7	144.5	175.1	147.1	160.7	161.0	173.0	161.7	164.1	166.3	177.0	161.0	159.4	165.8	172.1	150.8	155.2	159.4	168.2	152.3	153.1	157.9	121.0		
stdev_vpv_kumul_100do26	214.0	169.0	132.0	171.7	147.2	152.1	153.2	150.8	148.6	133.9	155.3	145.9	165.1	146.4	160.7	157.4	167.8	160.2	171.8	166.6	170.4	161.4	169.2	167.0	163.0	150.5	164.3	159.2	161.0	151.6	160.2	157.6	132.0		
stdev_vpv_kumul_100do27	210.0	160.5	147.0	172.5	142.2	147.7	153.7	147.8	164.8	163.4	168.6	165.6	162.2	166.1	158.3	162.2	153.9	169.2	167.2	163.4	151.6	172.6	166.7	163.6	158.1	167.8	165.2	163.7	156.1	162.4	161.5	160.0	142.2		
stdev_vpv_kumul_100do28	202.0	175.0	157.5	178.2	134.4	144.2	146.7	141.8	144.9	171.2	183.2	166.4	153.1	177.3	171.2	167.2	154.6	175.7	173.8	168.0	154.7	178.6	175.7	169.6	151.8	175.7	176.0	167.8	149.3	167.6	167.8	161.6	134.4		
stdev_vpv_kumul_100do29	181.5	162.0	159.0	167.5	126.8	141.7	144.4	137.6	153.1	173.8	190.7	172.5	156.2	175.9	180.1	170.7	156.1	169.8	182.2	169.4	155.3	171.9	182.4	169.9	155.2	172.8	183.9	170.6	149.0	164.5	172.8	162.1	126.8		
stdev_vpv_kumul_100do30	144.0	136.0	140.5	140.2	119.5	138.6	143.4	133.8	140.3	167.4	183.9	163.9	149.0	169.0	179.7	165.9	139.2	160.1	176.9	158.7	136.8	160.7	177.6	158.3	141.3	164.3	179.5	161.7	135.9	156.6	168.8	153.8	119.5		
stdev_vpv_kumul_100do31	115.5	112.5	127.0	118.3	110.5	134.8	142.2	129.1	110.2	139.4	174.4	141.4	127.2	152.7	174.6	151.5	114.1	137.2	163.6	138.3	110.7	136.9	162.7	136.7	115.6	141.6	168.8	142.0	114.3	138.7	160.4	137.8	110.2		
dof_ndvi_gurs_avg	54.0	34.0	11.5	33.2	63.9	69.0	79.7	70.9	59.6	50.9	46.4	52.3	47.8	41.0	40.7	43.1	30.6	29.3	27.2	29.0	28.2	27.3	27.1	27.6	41.5	37.1	35.4	38.0	47.7	45.1	45.7	46.2	11.5	10.0	44.2
dof_ndvi_gurs_std	52.0	3.5	5.0	20.2	78.6	69.2	68.6	72.1	89.7	35.2	26.7	50.5	51.8	26.7	22.4	33.6	34.1	27.8	20.6	27.5	27.3	26.1	22.4	25.3	50.7	28.9	23.0	34.2	57.9	38.2	33.9	43.3	3.5	3.5	59.7
dof_ndvi_geoin_avg	26.5	23.5	10.0	20.0	51.2	50.9	53.7	51.9	56.4	20.6	23.3	33.4	70.2	47.6	56.7	58.1	36.4	26.7	39.2	34.1	35.0	25.2	40.8	33.7	49.5	30.0	40.0	39.8	49.1	35.1	42.3	42.2	10.0		
dof_ndvi_geoin_std	63.5	17.0	22.0	34.2	64.4	56.2	77.1	65.9	133.1	65.0	58.0	85.4	98.4	59.7	77.0	78.4	78.2	68.6	94.7	80.5	74.1	72.8	104.3	83.7	96.0	66.5	83.5	82.0	86.6	61.9	79.5	76.0	17.0		
naem00_1	138.0	115.5	159.5	137.7	107.5	117.6	129.4	118.2	110.1	83.3	103.4	99.0	78.9	86.2	79.8	81.6	80.3	78.6	67.7	75.5	78.1	69.6	63.4	70.4	86.9	79.4	78.6	81.6	94.1	90.6	94.7	93.1	63.4		
naem01_1	121.0	91.5	133.5	115.3	139.4	125.4	126.4	130.4	83.7	118.3	90.8	97.6	78.2	96.3	121.1	98.6	97.2	93.6	103.1	98.0	94.2	93.4	97.6	95.1	88.3	100.4	103.1	97.3	102.6	106.4	110.3	106.4	78.2		
naem02_1	167.5	31.0	108.0	102.2	114.0	94.4	111.3	106.6	119.6	98.6	126.7	114.9	189.2	200.6	163.9	184.6	165.3	185.1	144.9	165.1	175.1	202.9	165.7	181.2	162.3	171.8	150.3	161.5	150.2	146.5	138.7	145.1	31.0		
naem03_1	2.5	97.0	106.0	68.5	80.5	99.1	100.0	93.2	121.2	76.1	62.0	86.4	100.9	79.6	91.8	90.7	107.6	99.4	102.2	103.1	93.6	95.6	102.0	97.0	105.8	87.7	89.5	94.3	95.3	90.9	92.8	93.0	2.5		
naem10_1	148.5	158.0	205.5	170.7	133.8	140.5	134.6	136.3	80.6	119.3	151.3	117.1	84.2	106.1	125.9	105.4	82.7	104.2	102.4	96.4	79.2	97.2	99.4	92.0	81.7	106.7	119.8	102.7	97.6	117.4	126.9	113.9	79.2		
naem11_1	143.0	114.0	151.0	136.0	135.3	136.6	139.4	137.1	70.0	72.4	89.1	77.2	61.2	62.7	51.2	58.4	79.3	77.9	54.1	70.4	80.3	75.4	45.7	67.1	72.7	72.1	60.0	68.3	91.4	90.2	83.8	88.5	45.7		
naem12_1	133.5	44.0	24.0	67.2	103.6	111.9	100.7	105.4	68.4	96.7	26.6	63.9	104.4	54.4	65.8	74.9	131.4	108.8	122.1	120.8	137.7	113.7	128.7	126.7	110.5	93.4	85.8	96.6	109.6	96.2	87.2	97.7	24.0		
naem13_1	105.0	148.0	30.5	94.5	88.7	116.8	110.5	105.3	54.9	37.4	94.3	62.2	93.1	42.4	64.4	66.7	125.0	102.0	71.1	99.4	135.6	108.3	74.0	106.0	102.1	72.6	76.0	83.6	98.8	86.8	83.0	89.5	30.5	1.0	97.0
naem20_1	101.0	40.5	61.5	67.7	107.8	80.2	90.7	92.9	98.3	60.7	65.3	74.8	77.2	157.3	104.7	113.1	94.1	163.0	152.0	136.4	97.8	190.8	167.2	151.9	91.9	142.9	122.3	119.0	96.3	122.9	111.9	110.4	40.5		
naem21_1	104.0	57.5	30.0	63.8	109.3	111.5	89.1	103.3	70.8	112.2	31.2	71.4	68.4	58.2	34.0	53.6	109.4	86.2	93.2	96.3	113.0	90.1	94.8	99.3	90.4	86.7	63.3	80.1	95.8	91.9	68.6	85.4	30.0		
naem22_1	71.0	63.0	41.5	58.5	99.2	95.5	78.2	90.9	126.9	159.3	145.3	143.9	145.0	172.4	142.3	153.3	178.0	190.8	188.1	185.6	180.1	198.0	191.9	190.0	157.5	180.1	166.9	168.2	139.2	154.0	139.4	144.2	41.5		
naem23_1	53.0	101.5	120.5	91.7	120.2	83.7	98.0	100.6	148.2	99.3	79.9	109.1	121.3	85.8	31.2	79.4	116.3	119.7	44.0	93.3	115.7	120.8	48.0	94.8	125.4	106.4	50.8	94.2	121.2	100.4	65.5	95.7	31.2		
naem30_1	110.0	207.0	212.0	176.3	102.3	147.2	123.8	124.4	12.6	5.4	8.1	8.7	5.0	3.0	2.8	3.6	1.4	1.9	2.7	2.0	1.0	1.7	2.1	1.6	5.0	3.0	3.9	4.0	33.9	47.7	42.6	41.4	1.0		
naem31_1	24.0	144.5	191.0	119.8	80.2	112.0	135.0	109.1	56.4	21.3	18.1	32.0	56.6	8.4	1.7	22.2	34.2	5.3	1.1	13.6	30.6	4.1	1.0	11.9	44.4	9.8	5.5	19.9	52.8	41.1	45.8	46.6	1.0		
naem32_1	56.0	10.0	33.0	33.0	92.5	73.9	79.8	82.1	132.2	91.8	133.0	119.0	121.8	56.0	33.7	70.5	130.9	47.8	25.1	67.9	120.0	44.6	17.3	60.6	126.2	60.0	52.3	79.5	114.9	61.6	58.5	78.3	10.0		
naem33_1	127.5	99.5	133.5	120.2	105.4	91.3	92.4	96.4	129.1	60.3	147.3	112.3	167.3	116.0	129.0	137.4	166.6	126.9	104.0	132.5	178.8	134.4	119.3	144.2	160.4	109.4	124.9	131.6	145.1	104.4	117.0	122.2	60.3		
con_1	72.0	124.0	123.0	106.3	100.9	112.2	108.5	107.2	73.9	28.4	31.4	44.6	64.3	29.6	28.8	40.9	56.1	42.3	33.0	43.8	55.6	51.7	34.0	47.1	62.5	38.0	31.8	44.1	72.6	60.3	54.9	62.6	28.4		
dis_1	84.5	31.5	70.5	62.2	110.1	90.5	106.0	102.2	13.8	59.4	90.0	54.4	27.2	113.1	126.2	88.9	49.7	132.0	159.8	113.8	55.4	143.2	168.1	122.3	36.5	111.9	136.0	94.8	57.2	103.3	125.8	95.4	13.8		
hom_1	130.0	55.0	81.5	88.8	100.1	111.4	114.6	108.7	85.0	60.6	110.2	85.3	78.8	70.3	106.1	85.1	77.6	92.6	94.6	88.2	78.7	92.2	95.6	88.8	80.0	78.9	101.6	86.8	87.1	86.3	104.1	92.5	55.0		
asm_1	148.0	133.5	160.5	147.3	93.9	95.5	116.3	101.9	133.3	92.8	60.2	95.4	76.7	74.4	56.7	69.3	53.8	46.1	36.1	45.3	48.1	36.1	34.2	39.5	78.0	62.4	46.8	62.4	84.8	73.6	69.0	75.8	34.2		
mxp_1	137.0	131.5	171.0	146.5	108.0	117.1	136.9	120.7	120.0	102.8	111.2	111.3	77.3	88.2	92.9	86.1	78.7	74.1	70.9	74.6	75.2	62.4	64.3	67.3	87.8	81.9	84.8	84.8	94.9	92.8	101.5	96.4	62.4		
ent_1	128.0	91.5	172.0	130.5	89.7	89.3	107.2	95.4	137.9	112.2	85.0	111.7	87.8	88.1	69.4	81.8	65.3	53.8	45.0	54.7	60.2	45.0	43.6	49.6	87.8	74.8	60.8	74.4	89.9	79.1	77.0	82.0	43.6	13.8	83.4
mn1_1	145.0	135.5	129.0	136.5	91.3	97.8	103.7	97.6	90.1	76.8	72.3	79.7	60.2	71.9	39.2	57.1	59.6	51.0	41.9	50.8	56.2	50.1	41.2	49.2	66.5	62.4	48.7	59.2	75.9	74.3	65.8	72.0	39.2		
mn2_1	140.0	139.0	134.0	137.7	96.8	101.7	107.0	101.8	82.2	62.6	60.0	68.3	55.6	59.3	41.0	52.0	54.9	49.2	48.7	50.9	50.6	48.6	48.1	49.1	60.8	54.9	49.4	55.1	73.1	70.1	67.4	70.2	41.0		
vr1_1	143.5	100.5	127.0	123.7	129.2	99.5	100.5	109.7	94.6	103.8	85.7	94.7	99.3	92.0	96.2	95.9	89.0	93.3	116.4	99.6	86.2	95.2	115.4	99.0	92.3	96.1	103.4	97.3	103.7	97.1	103.6	101.5	85.7		
vr2_1	143.5	101.5	126.0	123.7	129.0	99.8	99.6	109.5	92.7	101.9	83.7	92.7	98.1	89.1	94.1	93.8	87.6	91.6	114.9	98.0	84.9	92.1	113.7	96.9	90.8	93.7	101.6	95.4	102.6	95.5	102.0	100.1	83.7		
cor_1	96.0	83.0	102.0	93.7	113.5	124.7	118.5	118.9	57.7	35.1	51.2	48.0	46.2	37.4	56.6	46.7	39.3	51.2	70.3	53.6	35.2	52.2	66.0	51.1	44.6	44.0	61.0	49.9	64.2	66.1	77.3	69.2	35.1		
naem00_2	150.5	124.0	163.0	145.8	110.7	116.5	122.7	116.6	105.3	81.7	94.0	93.7	84.4	66.7	73.4	74.9	81.0	65.0	60.0	68.7	75.1	59.4	55.6	63.4	86.5	68.2	70.8	75.1	95.2	82.7	87.6	88.5	55.6		
naem01_2	158.5	140.0	150.5	149.7	136.7	129.5	129.6	131.9	83.9	120.7	130.9	111.8	79.3	68.2	84.6	77.4	87.0	85.1	67.7	79.9	83.2	87.3	63.8	78.1	83.4	90.3	86.7	86.8	99.9	102.3	100.2	100.8	63.8		
naem02_2	96.0	86.0	64.5	82.2	137.2	89.5	83.8	103.5	110.1	169.3	172.2	150.6	159.3	188.2	207.4	185.0	181.1	200.8	199.9	193.9	188.0	209.4	206.2	201.2	159.6	191.9	196.4	182.7	151.4	161.7	162.6	158.6	64.5		
naem03_2	101.5	113.5	107.5	107.5	86.3	109.1	114.9	103.4	102.8	85.1	61.7	83.2	176.2	142.7	97.9	138.9	169.2	141.4	114.9	141.9	176.8	141.7	118.7	145.7	156.3	127.7	98.3	127.4	136.3	122.4	102.9	120.5	61.7		
naem10_2	180.0	141.0	171.5	164.2	135.3	127.5	128.3	130.4	54.1	78.8	179.1	104.0	55.3	85.7	169.3	103.4	72.8	90.3	138.9	100.7	74.7	89.0	132.4	98.7	64.2	85.9	154.9	101.7	86.9	98.7	148.8	111.5	54.1		
naem11_2	147.0	104.0	132.5	127.8	131.1	145.8	133.9	136.9	40.0	41.0	77.8	52.9	35.7	44.4	42.4	40.9	68.1	65.0	51.0	61.4	68.1	60.9	41.2	56.7	53.0	52.8	53.1	53.0	76.6	78.5	76.8	77.3	35.7		
naem12_2	122.0	89.5	11.0	74.2	104.5	86.2	71.7	87.5	89.4	149.3	85.8	108.2	109.1	98.4	109.3	105.6	140.0	123.8	126.0	129.9	146.1	136.7	125.6	136.1	121.2	127.1	111.7	120.0	116.9	115.2	97.5	109.9	11.0		
naem13_2	54.0	135.0	124.5	104.5	88.8	85.4	97.3	90.5	212.0	93.4	49.4	118.3	210.0	192.2	135.9	179.4	208.0	210.6	152.3	190.3	214.1	215.6	160.7	196.8	211.0	177.9	124.6	171.2	173.7	152.7	117.6	148.0	49.4	2.0	113.4
naem20_2	92.5	127.0	115.5	111.7	128.3	89.4	95.5	104.4	66.4	117.6	107.2	97.1	58.8	176.1	160.6	131.8	100.3	182.4	185.6	156.1	108.1	192.8	190.4	163.8	83.4	167.2	160.9	137.2	95.2	145.8	142.5	127.8	58.8		
naem21_2	119.5	91.0	19.0	76.5	106.5	120.1	84.7	103.8	48.6	143.9	65.8	86.1	55.8	80.1	106.6	80.8	98.6	74.2	118.3	97.0	107.3	81.4	116.7	101.8	77.6	94.9	101.8	91.4	86.6	101.2	94.2	94.0	19.0		
naem22_2	84.5	81.5	14.0	60.0	99.5	98.9	69.5	89.3	110.7	194.3	187.8	164.3	155.3	202.7	185.1	181.0	182.7	206.6	204.0	197.7	186.7	212.0	207.3	202.0	158.8	203.9	196.1	186.3	140.8	172.3	156.6	156.6	14.0		
naem23_2	24.0	57.0	107.5	62.8	79.7	97.6	97.6	91.6	216.7	186.0	210.6	204.4	216.3	199.0	215.7	210.3	213.0	190.7	197.3	200.3	215.8	204.6	211.1	210.5	215.4	195.1	208.7	206.4	173.3	164.8	176.4	171.5	24.0		
naem30_2	111.5	132.0	208.0	150.5	73.8	100.6	121.2	98.5	34.1	13.0	10.8	19.3	19.2	7.6	3.4	10.1	11.1	2.2	3.8	5.7	9.9	2.0	3.6	5.1	18.6	6.2	5.4	10.1	36.3	35.2	42.8	38.1	2.0		
naem31_2	111.5	94.5	132.5	112.8	92.8	91.8	84.9	89.9	118.0	26.8	29.1	58.0	71.7	19.2	21.9	37.6	59.9	4.9	6.9	23.9	55.2	3.3	4.4	21.0	76.2	13.6	15.6	35.1	81.8	36.7	37.8	52.1	3.3		
naem32_2	82.0	112.5	108.0	100.8	73.8	78.2	87.7	79.9	170.9	72.0	112.8	118.6	163.1	127.8	121.3	137.4	111.6	80.0	61.7	84.4	113.7	86.4	63.2	87.8	139.8	91.6	89.8	107.0	120.7	89.0	89.9	99.9	61.7		
naem33_2	118.0	187.5	188.0	164.5	120.4	111.7	111.5	114.5	192.0	122.9	114.6	143.1	187.7	182.8	173.4	181.3	183.8	182.3	178.6	181.6	195.2	190.4	192.6	192.7	189.7	169.6	164.8	174.7	169.2	155.5	152.1	159.0	111.5		
con_2	80.0	112.0	114.5	102.2	103.1	89.2	89.8	94.0	42.6	26.6	51.8	40.3	47.0	21.8	22.9	30.6	39.2	18.3	29.9	29.1	37.8	21.3	29.1	29.4	41.6	22.0	33.4	32.4	58.8	42.6	51.0	50.8	18.3		
dis_2	68.0	30.5	43.5	47.3	95.5	92.3	102.8	96.9	27.3	67.3	115.9	70.2	52.3	139.4	170.6	120.8	69.2	143.2	176.6	129.7	75.6	153.9	183.6	137.7	56.1	126.0	161.6	114.6	66.6	113.6	142.0	107.4	27.3		
hom_2	87.0	61.5	33.0	60.5	112.1	108.6	106.2	109.0	62.2	54.0	160.7	92.3	64.1	46.9	116.8	75.9	63.4	65.7	98.2	75.8	58.8	64.4	92.1	71.8	62.1	57.8	116.9	78.9	75.8	70.9	110.9	85.9	33.0		
asm_2	148.0	120.0	148.5	138.8	94.3	94.4	110.0	99.6	128.3	83.1	49.3	86.9	75.8	57.0	43.8	58.9	48.9	36.7	29.6	38.4	41.0	29.6	27.8	32.8	73.5	51.6	37.6	54.2	81.7	65.2	60.4	69.1	27.8		
mxp_2	161.5	136.0	112.5	136.7	112.2	115.0	129.8	119.0	107.2	90.7	93.3	97.1	81.8	66.8	79.8	76.1	79.2	60.4	62.7	67.4	72.3	53.2	57.3	61.0	85.1	67.8	73.3	75.4	95.0	82.5	89.2	88.9	53.2		
ent_2	113.0	95.5	159.0	122.5	83.4	94.2	117.5	98.4	114.3	86.4	66.4	89.1	85.7	60.1	48.7	64.8	59.3	44.7	34.9	46.3	53.6	39.8	33.1	42.1	78.2	57.8	45.8	60.6	80.9	68.5	68.5	72.6	33.1	18.3	79.6
mn1_2	140.5	134.5	125.5	133.5	91.9	98.6	103.9	98.2	88.6	79.3	74.0	80.6	61.9	74.3	40.6	58.9	61.6	51.4	43.8	52.3	57.7	50.9	42.3	50.3	67.4	64.0	50.2	60.5	76.5	75.6	66.8	73.0	40.6		
mn2_2	120.0	149.0	115.0	128.0	93.8	104.5	108.2	102.2	67.1	64.3	61.0	64.1	46.0	59.4	46.2	50.6	47.8	52.9	51.8	50.8	46.9	52.0	50.7	49.9	51.9	57.2	52.4	53.8	65.3	72.8	69.1	69.1	46.0		
vr1_2	139.0	100.0	128.5	122.5	128.7	101.1	101.8	110.5	97.0	102.6	89.2	96.3	103.2	92.6	98.9	98.2	92.1	95.6	120.6	102.7	89.9	96.8	119.2	102.0	95.6	96.9	107.0	99.8	105.7	98.1	106.5	103.4	89.2		
vr2_2	141.0	103.0	124.0	122.7	127.8	102.6	100.3	110.3	91.6	95.9	80.8	89.4	99.2	85.3	90.6	91.7	89.4	87.3	115.1	97.3	87.4	90.1	114.4	97.3	91.9	89.7	100.2	93.9	103.0	93.5	101.2	99.2	80.8		
cor_2	92.0	108.5	131.5	110.7	108.6	116.2	118.2	114.3	48.9	43.4	46.2	46.2	38.1	28.2	26.0	30.8	28.8	22.9	33.4	28.4	25.8	22.6	29.3	25.9	35.4	29.3	33.8	32.8	56.3	54.5	59.1	56.6	22.6		
naem00_4	163.0	118.0	152.5	144.5	107.5	113.1	122.7	114.4	107.7	77.4	77.6	87.6	87.1	57.6	51.7	65.4	80.4	53.2	45.6	59.7	77.7	47.1	40.6	55.1	88.2	58.8	53.8	67.0	96.1	75.0	75.3	82.1	40.6		
naem01_4	104.0	140.0	205.5	149.8	122.0	143.2	148.1	137.7	156.3	142.3	114.8	137.8	119.3	79.7	73.1	90.7	118.8	93.7	82.4	98.3	121.0	86.8	77.6	95.1	128.9	100.6	87.0	105.5	126.1	113.0	107.2	115.4	73.1		
naem02_4	85.0	130.5	85.0	100.2	114.7	110.6	118.2	114.5	195.0	119.7	211.9	175.5	205.6	195.7	216.0	205.7	201.1	211.7	216.9	209.9	204.2	214.1	217.0	211.8	201.5	185.3	215.4	200.7	174.8	164.1	185.5	174.8	85.0		
naem03_4	71.5	182.0	102.0	118.5	83.8	97.2	112.5	97.8	142.2	193.2	181.2	172.2	210.9	215.4	209.0	211.8	199.7	203.8	204.6	202.7	200.9	208.6	204.2	204.6	188.4	205.3	199.8	197.8	157.2	176.8	173.7	169.2	71.5		
naem10_4	166.5	106.5	135.0	136.0	127.5	120.2	118.9	122.2	65.3	99.9	153.9	106.4	64.6	42.4	84.8	63.9	82.3	33.4	71.0	62.3	85.1	35.7	69.6	63.4	74.3	52.9	94.8	74.0	91.5	72.1	102.5	88.7	33.4		
naem11_4	114.5	103.5	124.5	114.2	127.7	151.5	147.3	142.2	51.4	55.2	52.7	53.1	37.9	40.7	41.0	39.9	57.8	60.1	60.9	59.6	59.2	56.9	50.7	55.6	51.6	53.2	51.3	52.0	73.5	80.3	78.6	77.5	37.9		
naem12_4	83.0	111.0	75.5	89.8	111.3	106.1	97.9	105.1	74.8	148.2	80.1	101.0	107.3	142.0	101.4	116.9	149.7	185.0	166.3	167.0	158.7	188.7	168.8	172.0	122.6	166.0	129.2	139.3	118.2	148.5	119.1	128.6	74.8		
naem13_4	9.5	96.0	100.0	68.5	94.1	110.2	93.9	99.4	188.9	122.2	113.2	141.4	195.9	212.6	203.1	203.9	198.0	210.4	206.4	205.0	205.1	213.0	211.6	209.9	197.0	189.6	183.6	190.0	163.4	165.6	157.5	162.2	9.5	5.1	114.7
naem20_4	197.0	106.5	170.5	158.0	123.2	92.8	106.6	107.5	88.8	145.2	165.0	133.0	94.9	155.3	129.4	126.6	124.8	163.6	164.4	150.9	132.8	167.8	169.9	156.8	110.3	158.0	157.2	141.8	117.0	139.3	144.8	133.7	88.8		
naem21_4	153.0	24.5	24.0	67.2	112.9	104.5	89.6	102.3	34.9	131.4	152.4	106.3	61.4	89.4	101.4	84.1	89.3	118.9	117.1	108.4	94.7	127.6	117.2	113.1	70.1	116.8	122.1	103.0	84.3	110.1	109.9	101.4	24.0		
naem22_4	111.0	38.0	47.5	65.5	100.6	83.8	73.3	85.9	140.7	179.7	180.4	166.9	166.9	189.9	192.1	183.0	192.0	201.0	201.6	198.2	195.8	210.2	210.3	205.4	173.8	195.2	196.1	188.4	152.7	160.6	159.0	157.4	38.0		
naem23_4	67.5	98.0	116.0	93.8	92.2	100.5	108.5	100.4	187.3	129.9	114.8	144.0	195.1	203.1	173.7	190.6	200.3	210.4	181.8	197.5	209.2	212.8	199.1	207.0	198.0	189.1	167.3	184.8	165.9	162.9	150.3	159.7	67.5		
naem30_4	110.5	172.0	160.0	147.5	111.5	105.6	109.3	108.8	98.3	35.6	22.1	52.0	86.1	36.0	19.9	47.3	53.9	16.6	18.9	29.8	54.8	14.4	16.9	28.7	73.3	25.6	19.4	39.5	84.5	51.8	47.9	61.4	14.4		
naem31_4	101.0	110.5	130.0	113.8	95.5	107.2	89.9	97.5	77.8	56.0	66.7	66.8	86.0	35.8	15.8	45.9	86.2	23.8	5.8	38.6	88.8	16.2	5.1	36.7	84.7	32.9	23.3	47.0	88.1	54.9	44.5	62.5	5.1		
naem32_4	40.0	104.5	84.5	76.3	66.3	73.8	73.2	71.1	149.2	114.4	85.3	116.3	139.7	85.6	50.7	92.0	121.2	76.8	35.2	77.7	134.0	88.2	38.2	86.8	136.0	91.3	52.4	93.2	114.5	87.3	58.9	86.9	35.2		
naem33_4	76.5	130.0	84.0	96.8	86.7	102.1	99.4	96.1	69.0	52.3	46.9	56.1	57.1	47.8	70.9	58.6	59.7	44.6	103.1	69.1	65.9	49.1	105.4	73.5	62.9	48.4	81.6	64.3	69.5	65.3	86.2	73.7	44.6		
con_4	118.5	127.5	145.5	130.5	101.5	97.3	95.2	98.0	99.9	64.8	85.1	83.3	105.9	91.9	102.0	99.9	90.2	104.9	110.9	102.0	87.6	105.3	110.6	101.1	95.9	91.7	102.1	96.6	98.2	94.5	102.1	98.3	64.8		
dis_4	83.0	73.0	91.0	82.3	94.2	90.9	106.5	97.2	33.9	85.6	76.2	65.2	44.3	86.4	106.0	78.9	51.2	78.9	102.1	77.4	51.6	79.2	103.8	78.2	45.3	82.5	97.0	74.9	59.2	84.3	99.2	80.9	33.9		
hom_4	141.5	95.0	140.0	125.5	117.1	122.2	118.7	119.3	76.4	92.7	53.1	74.1	61.1	35.8	50.0	49.0	59.7	38.2	60.7	52.9	57.7	36.9	54.4	49.7	63.7	50.9	54.6	56.4	80.4	70.8	74.3	75.1	35.8		
asm_4	151.0	143.0	153.5	149.2	89.5	89.8	113.5	97.6	117.3	68.2	25.6	70.4	68.3	48.3	26.9	47.9	45.1	27.4	20.6	31.0	37.6	21.3	19.2	26.0	67.1	41.3	23.1	43.8	76.1	57.7	51.2	61.7	19.2		
mxp_4	162.0	161.0	130.0	151.0	105.7	116.3	134.5	118.8	103.4	77.1	68.4	83.0	85.9	60.3	48.4	64.9	79.7	53.1	49.0	60.6	76.8	45.3	43.4	55.2	86.4	59.0	52.3	65.9	94.3	77.6	76.3	82.7	43.4		
ent_4	139.0	132.0	172.0	147.7	83.8	92.5	122.7	99.7	100.4	81.4	39.9	73.9	77.4	53.2	36.3	55.7	53.2	36.6	29.8	39.9	49.9	32.7	28.0	36.9	70.3	51.0	33.5	51.6	76.4	64.7	61.7	67.6	28.0	19.2	82.2
mn1_4	144.5	140.0	124.0	136.2	92.2	98.5	103.2	97.9	88.1	96.2	83.4	89.3	63.7	73.9	44.2	60.6	65.7	48.3	46.6	53.5	60.6	46.6	45.6	50.9	69.5	66.3	54.9	63.6	78.2	77.4	69.9	75.2	44.2		
mn2_4	123.0	135.0	124.0	127.3	95.1	97.7	108.5	100.4	65.2	68.0	52.2	61.8	46.6	65.3	43.7	51.9	57.4	67.9	50.7	58.7	57.1	66.7	49.3	57.7	56.6	67.0	49.0	57.5	69.0	77.5	67.1	71.2	43.7		
vr1_4	137.5	109.0	127.5	124.7	125.7	103.0	106.9	111.9	102.8	107.7	86.9	99.1	112.3	95.9	98.2	102.1	98.1	100.0	122.3	106.8	96.3	100.9	121.0	106.1	102.4	101.1	107.1	103.5	109.7	101.9	107.9	106.5	86.9		
vr2_4	130.5	110.0	122.0	120.8	122.2	103.2	104.7	110.0	94.8	99.3	79.4	91.2	99.8	78.7	84.9	87.8	85.1	80.0	105.9	90.3	82.3	81.7	105.7	89.9	90.5	84.9	94.0	89.8	100.1	90.5	97.8	96.2	78.7		
cor_4	116.0	157.0	145.5	139.5	104.9	112.3	126.8	114.7	109.1	89.8	68.0	89.0	91.1	72.7	68.1	77.3	78.3	72.2	58.1	69.6	77.7	73.2	56.7	69.2	89.1	77.0	62.7	76.3	94.2	89.1	82.3	88.5	56.7		