



Akademie věd České republiky
Ústav teorie informace a automatizace, v.v.i.

Academy of Sciences of the Czech Republic
Institute of Information Theory and Automation

VÝZKUMNÁ ZPRÁVA

Brabec M., Konár O., Kasanický I., Pelikán E.,
Přikryl, J.

Statistická analýza a průzkum vazeb v měřených dopravních datech

Výzkumná zpráva

č. 2340

prosinec 2013

TA01030603

Abstrakt

Jedním z aktuálních problémů v dopravním výzkumu je problém dostupnosti obrovského množství nevyužitých dat, měřených telematickými systémy na městských komunikacích. Tato data obsahují mnohdy informace, jež zůstávají skryty a nejsou využity při řízení dopravy. Cílem práce, popsané v této zprávě, bylo prozkoumat možné další vazby a skryté stavy dopravního systému, ukryté v měřených datech a do této chvíle neuvažované v používaném dopravním modelu. Při statistických analýzách a průzkumu chování dat z detektorů na křižovatkách byla použita celá řada statistických metod, technik a modelů. Postupovali jsme od jednoduchých sumářů (např. grafických charakteristik vztahů mezi různými veličinami, krabicových grafů pro popis základních vlastností rozdelení pravděpodobností pro různé veličiny) ke složitějším postupům (např. neparametrická extrakce trendu pomocí loess smootheningu) a statistickým modelům (např. Hidden Markov chain model, včetně odhadu skrytých Markovovských stavů Viterbiho algoritmem).

Klíčová slova: dopravní data, světelné signalizační zařízení, dopravní řízení, LOESS, HMM, neparametrická regrese, skrytý Markovský model, dopravní stav.

Obsah

1	Úvod	3
2	Poznámky k metodice	3
3	Oblast Praha-Zličín	3
3.1	Experiment 1	5
3.2	Experiment 2	9
3.3	Experiment 3	11
3.4	Experiment 4	14
3.5	Experiment 5	15
3.6	Experiment 6	16
3.7	Experiment 7	25
3.8	Experiment 8	26
3.8.1	Intenzita	26
3.8.2	Obsazenost	27
3.8.3	Vzájemný vztah intenzity a obsazenosti	28
3.9	Experiment 9	29
3.9.1	Různá ramena	29
3.9.2	Fáze	30
3.9.3	Časové řady poměrů a dalších odvozených ukazatelů	31
3.9.4	První diference	32
3.10	Hidden Markov chain modely pro Dstop intenzitu z různých ramen též křížovatky	35
3.10.1	Křížovatka 5.495	35
3.10.2	Křížovatka 5.601	52
3.11	Hidden Markov chain modely pro Dstop s obsazenostmi z různých ramen též křížovatky	73
3.11.1	Křížovatka 5.495	73
3.11.2	Křížovatka 5.601	82
4	Praha Smíchov, hidden Markov chain modely	87
4.1	Obsazenosti+intenzity na Dstop detektorech	87
4.1.1	K014	87
4.1.2	K015	91
5	Korekce na délku zelené	93
5.1	K495, minutová data, MFD (macroscopic Fundamentals diagram), Dstop detektor	94
5.1.1	A	94
5.1.2	B	98
5.1.3	C	99

5.1.4	D	100
5.1.5	E.....	101
5.1.6	F.....	102
5.2	K495, minutová data, intenzity či obsazenosti vzhledem k délce zelené	103
5.2.1	A	103
5.2.2	B.....	104
5.2.3	C.....	105
5.2.4	D	106
5.2.5	E.....	107
5.2.6	F	108
5.2.7	Srovnání směrů	109
5.3	K495, různě dlouhé agregace, intenzita vs. obsazenost (MFD)	110
5.3.1	A	110
5.3.2	B.....	115
5.3.3	C.....	120
5.3.4	D	125
5.3.5	E.....	130
5.3.6	F	135
5.4	K495, MFD z povýběrů s různě dlouhou zelenou	140
5.4.1	A	140
5.5	K496, I/G vs. (O-R)/G či O/G (pokud O<R).....	143
5.5.1	A	143
6	Závěr	144
7	Literatura a reference	146

1 Úvod

Jedním z aktuálních problémů v dopravním výzkumu je problém dostupnosti obrovského množství nevyužitých dat, měřených telematickými systémy na dálnicích či městských komunikacích. Tato data obsahují mnohdy informace, jež – bez využití vhodných matematických nástrojů datové analýzy – zůstávají skryty a nevyužity při řízení dopravy.

V rámci projektu *Nové metody řízení dopravy v kongescích v intravilánu* je naším cílem navrhnut nové algoritmy pro adaptivní řízení městské dopravní sítě. Současná verze algoritmů je založena na linearizovaném modelu vývoje délky fronty vozidel, čekajících na červenou, vycházejícím z klasického bilančního zákona zachování. Tento model je pro případy saturace doplněn alternativním modelem délky fronty jako funkce obsazenosti dopravního detektoru.

Cílem práce, popsané v této zprávě, bylo prozkoumat možné další vazby a skryté stavy dopravního systému, ukryté v měřených datech a do této chvíle neuvažované v používaném dopravním modelu.

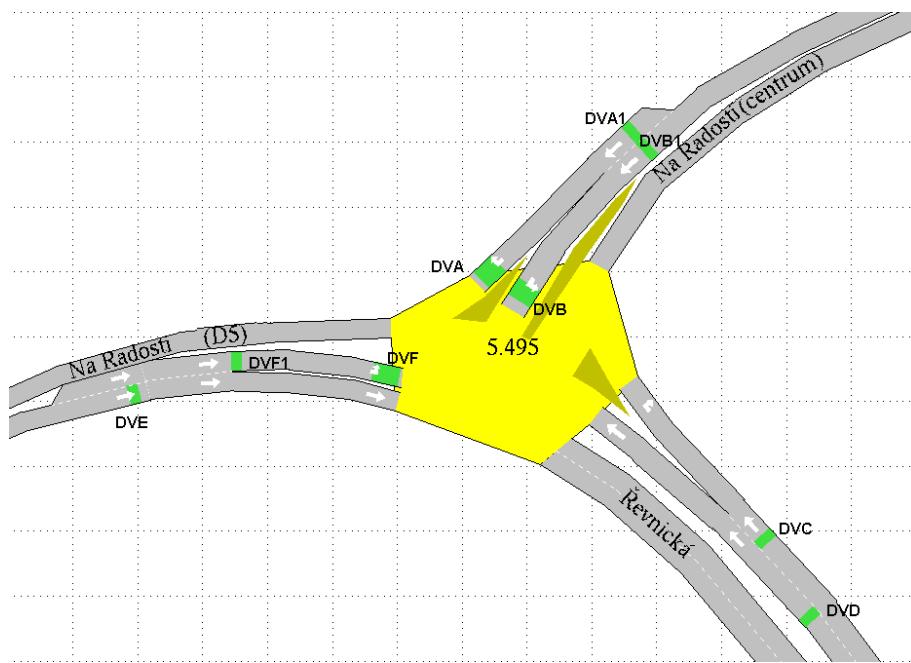
2 Poznámky k metodice

Při statistických analýzách a průzkumu chování dat z detektorů na křižovatkách byla použita celá řada statistických metod, technik a modelů. Postupovali jsme od jednoduchých sumářů (např. grafických charakteristik vztahů mezi různými veličinami, krabicových grafů pro popis základních vlastností rozdělení pravděpodobností pro různé veličiny) ke složitějším postupům (např. neparametrická extrakce trendu pomocí *LOESS regrese* (Cleveland a Devlin 1988)) a statistickým modelům (např. skryté *Markovské řetězce* (Anonymous 2013, Bilmes 1986, Rabiner 1989) včetně odhadu *skrytých Markovských stavů* Viterbiho algoritmem).

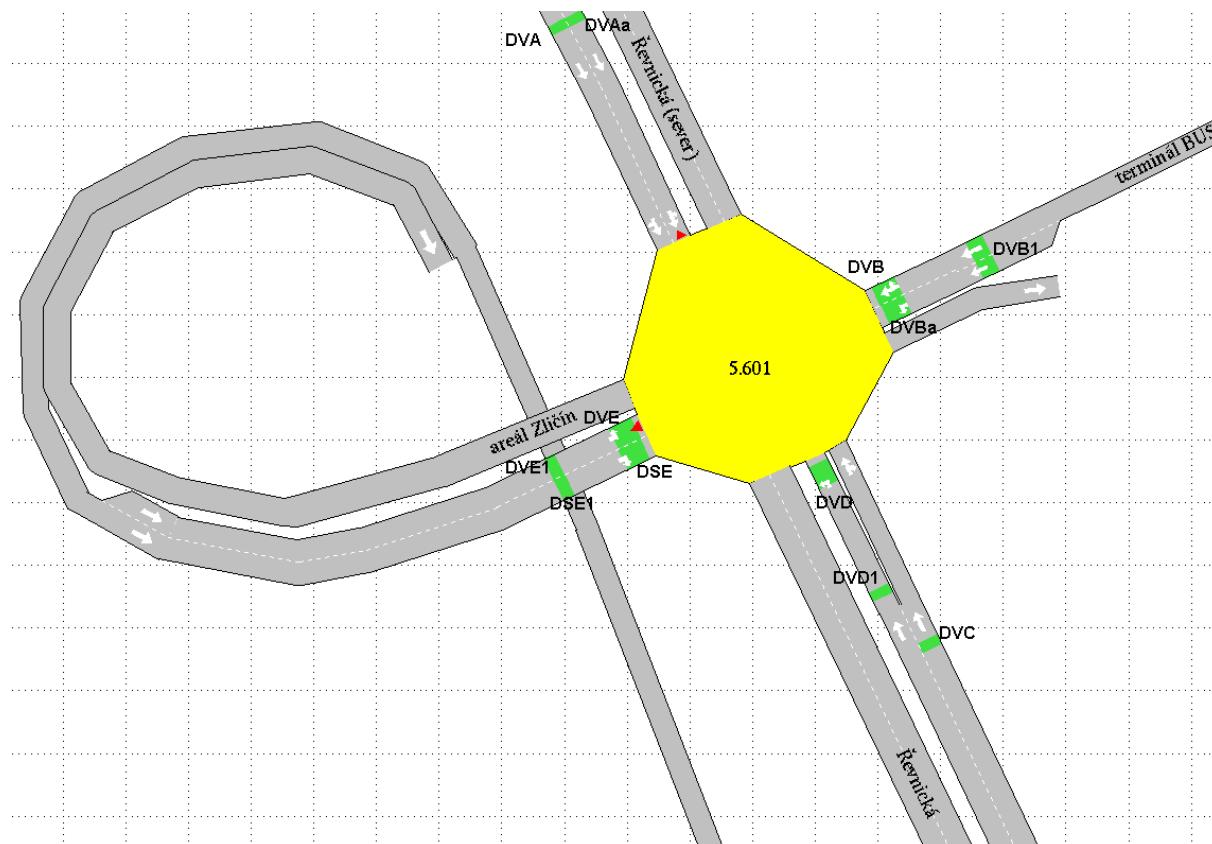
3 Oblast Praha-Zličín

Analyzovaná data jsou z oblasti Praha-Zličín, konkrétně ze dvou křižovatek: 5.495 a 5.601. Jejich schémata ukazuje Obrázek 1 a Obrázek 2. Ramena jsou označena písmeny (A, B, C atd.). Např. pro křižovatku 495 vidíme že pro rameno A máme detektor na stopčáře (Dstop) označený jako DVA a strategický detektor (Dstrat) označený jako DVA1.

Zpracovávaná data byla (pokud není v textu explicitně řečeno jinak) agregována do minutových intervalů (data po sekundách mají vesměs velmi podobné chování).



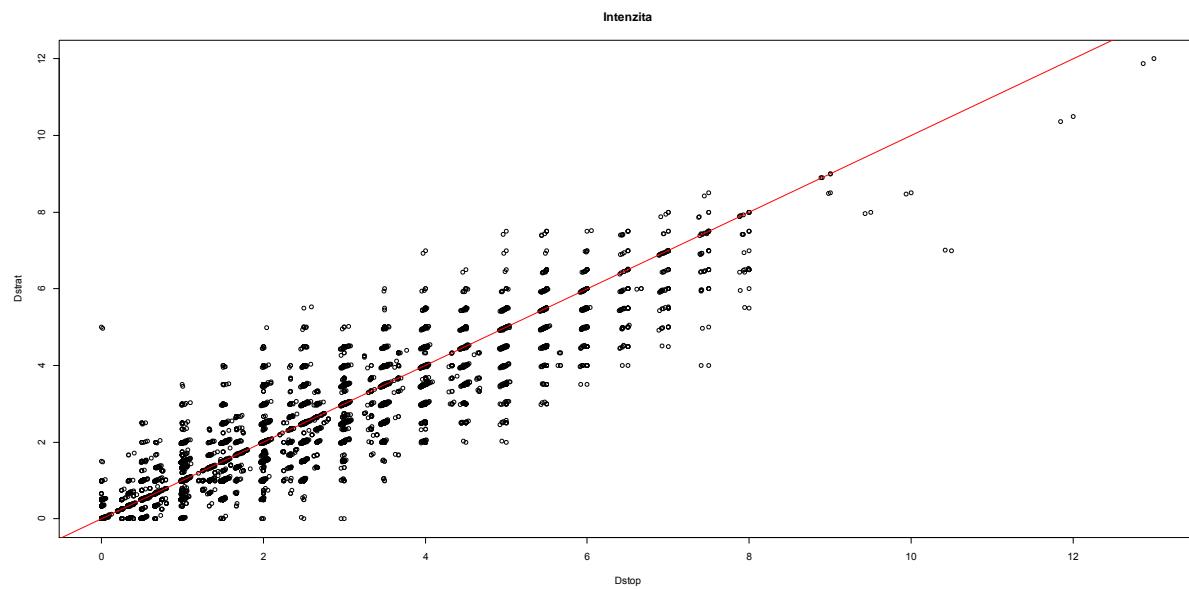
Obrázek 1: Schéma křížovatky 5.495



Obrázek 2: Schéma křížovatky 5.601

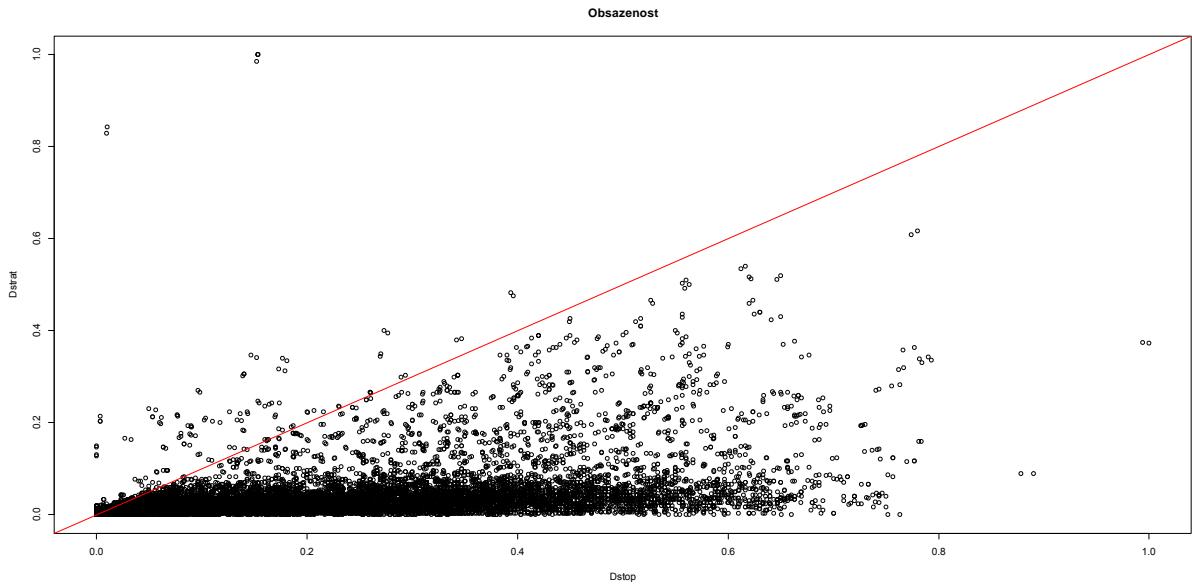
3.1 Experiment 1

Podívejme se na vztah intenzit z Dstrat a Dstop detektorů. Obrázek 3 ilustruje situaci pro data z ramene A křížovatky 5.495 (červená přímka odpovídá identitě). Vidíme, že oba detektory jsou v relativně těsném a téměř lineárním vztahu - byť je při bližším pohledu na obrázku patrné v oblasti velkých intenzit patrné jisté zakřivení (strategický detektor pro extrémní intenzity nesleduje Dstop již tak těsně).



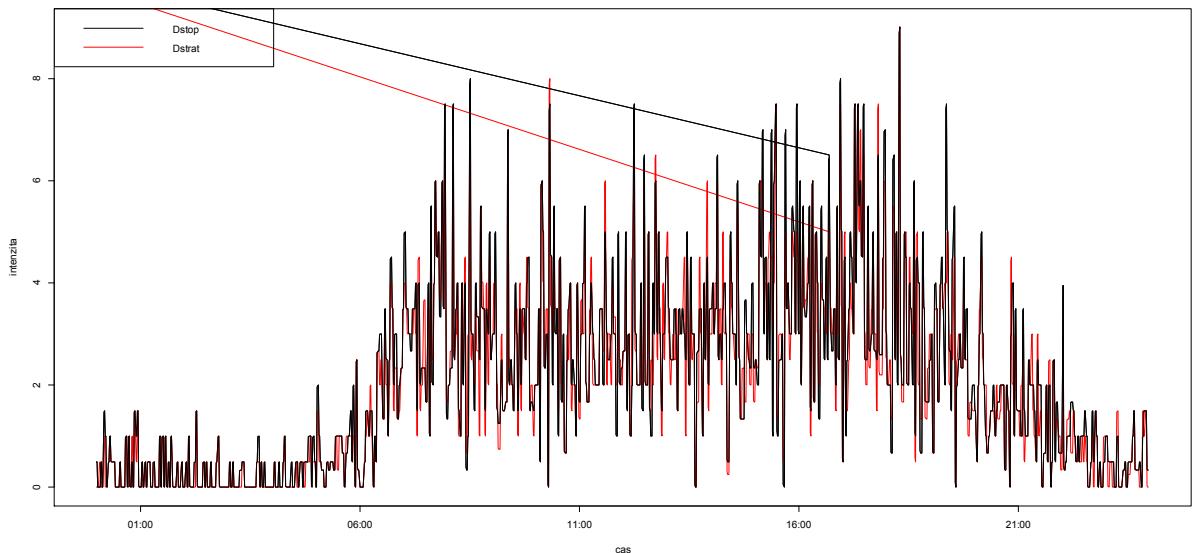
Obrázek 3: Vztah Dstrat a Dstop pro intenzitu a rameno A křížovatky 5.495.

Obrázek 4 oproti tomu ukazuje, že vztah strategického detektoru a detektoru na stop čáre je pro obsazenosti podstatně volnější. Výrazně nižší obsazenost na Dstrat oproti Dstop je samozřejmostí (danou podstatou umístění Dstrat), zajímavá je ale nízká korelace mezi Dstrat a Dstop pro obsazenost. Ta může mj. souviset i s nemalým šumem („měřicí chybou“) detektoru obsazenosti („měřicí chybou“ myslíme nejen skutečné chyby detekčního zařízení a následného zpracování ale i další zdroje variability jako jsou náhodně odlišné chování řidičů ve smyslu pomalého/rychlého dojíždění k semaforu, velikosti mezer mezi vozidly apod.).

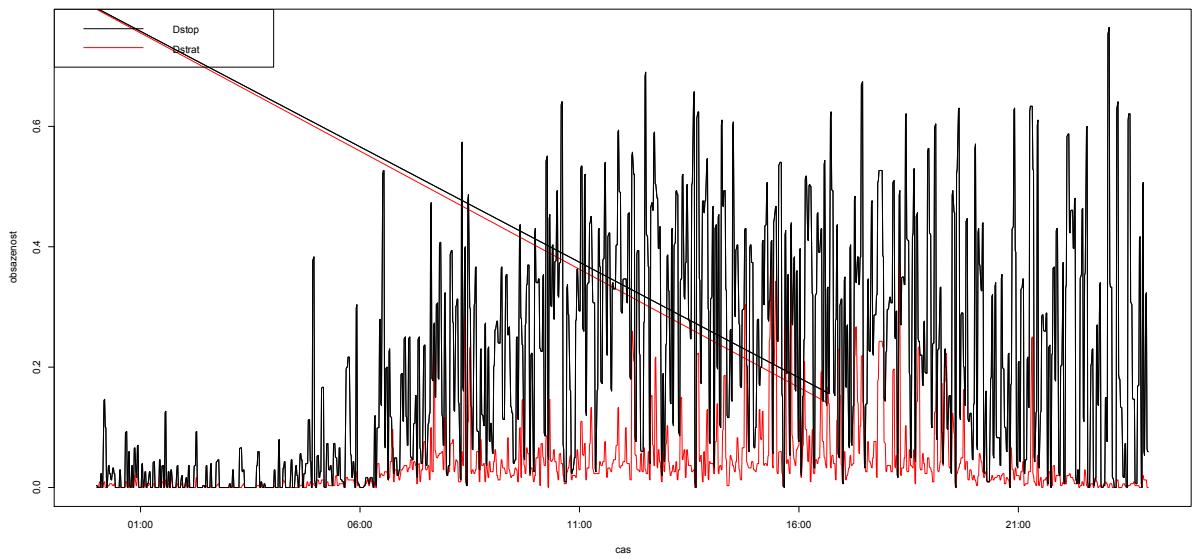


Obrázek 4: Vztah Dstrat a Dstop pro obsazenost a rameno A křižovatky 5.495.

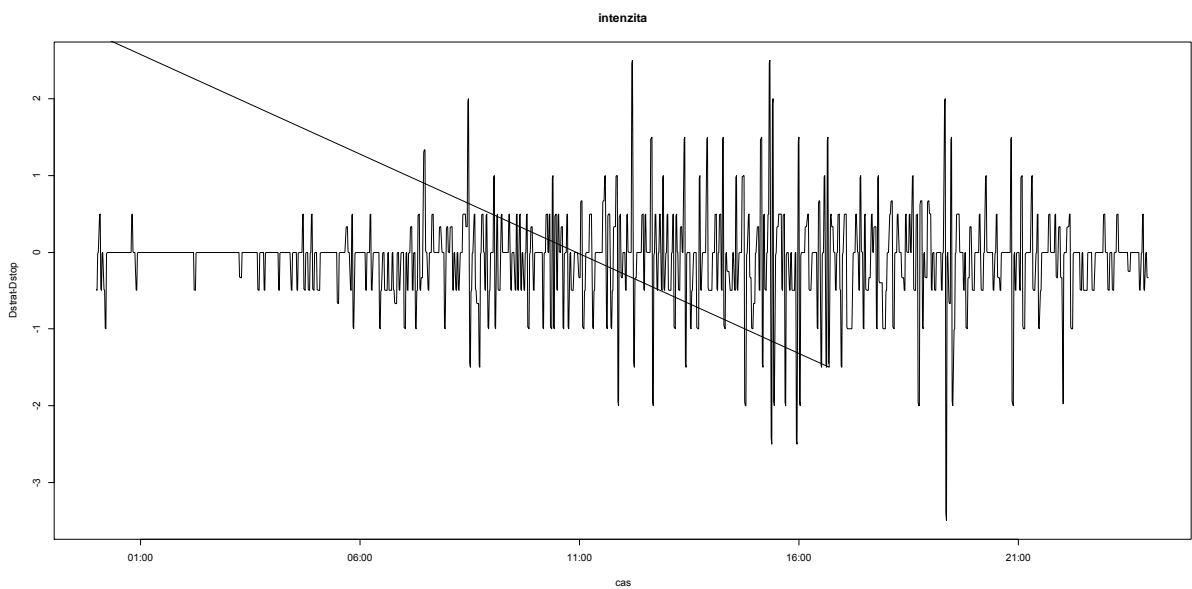
Rozpor mezi vztahem Dstrat a Dstop detektoru pro intenzitu a pro obsazenost lze dobře ilustrovat také na časových řadách naměřených hodnot pro vybraný (vzorový) den, 18.3. (rameno A křižovatky 5.495). Obrázek 5 ukazuje trajektorie obsazenosti na Dstrat a Dstop pro intenzitu. Obrázek 6 pak trajektorie obsazeností. Rozdíly Dstrat-Dstop ukazuje Obrázek 7 a Obrázek 8 (pro intenzitu a obsazenost, respektive). Podíly Dstrat/Dstop ukazuje Obrázek 8 a Obrázek 9 (pro přehlednost jsou v obou relativních obrázcích zobrazeny jen podíly v intervalu [0,5]).



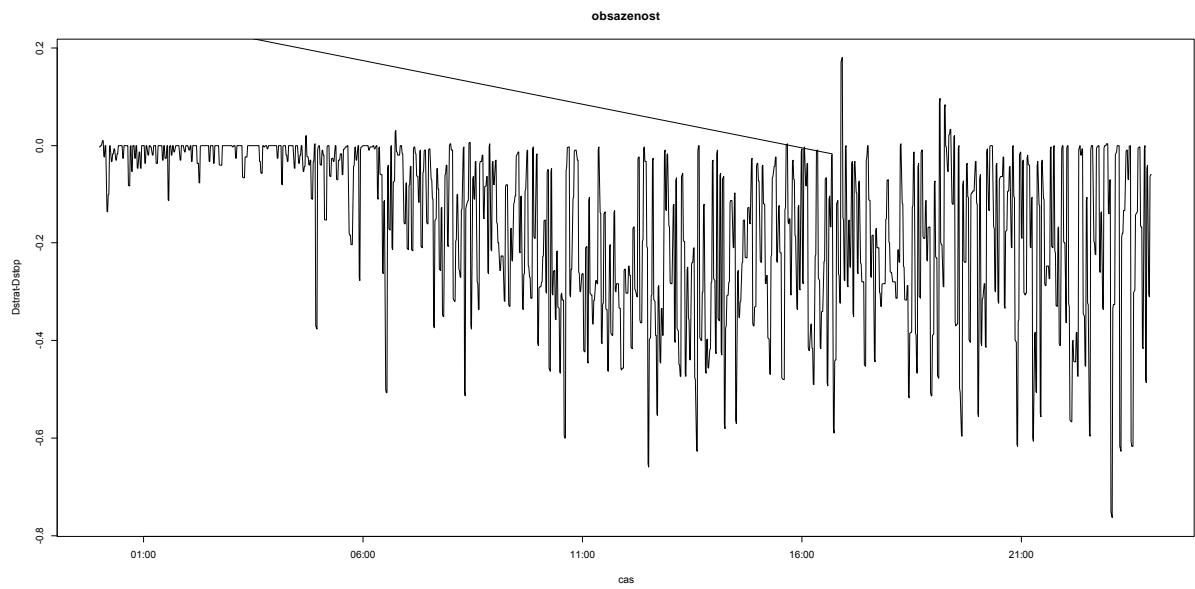
Obrázek 5: Trajektorie intenzit pro vzorový den.



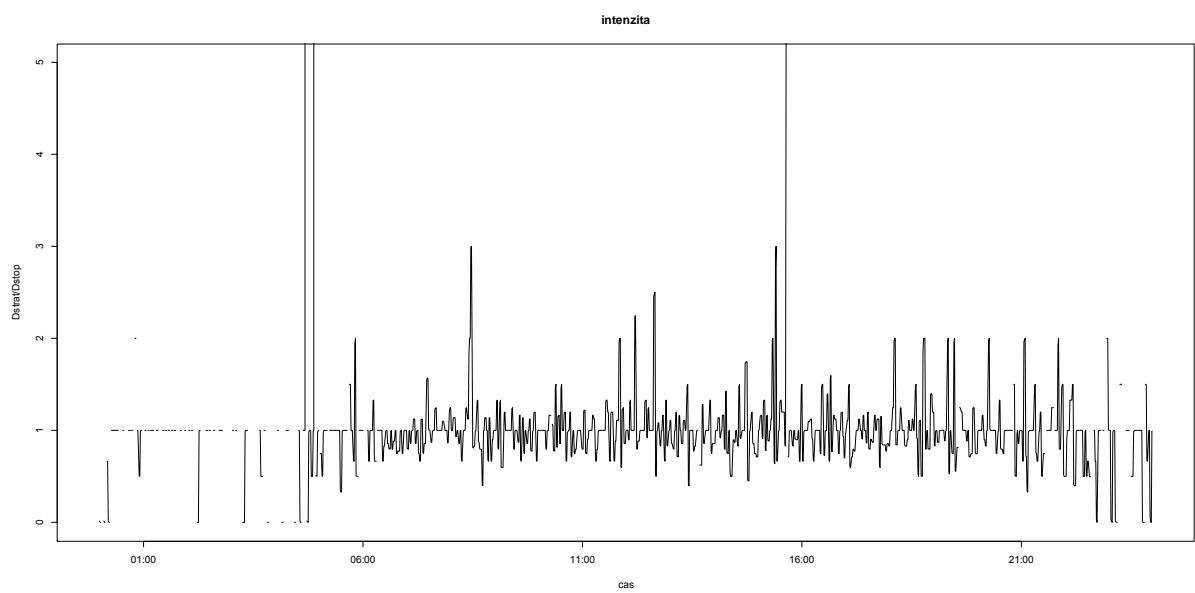
Obrázek 6: Trajektorie obsazeností pro vzorový den.



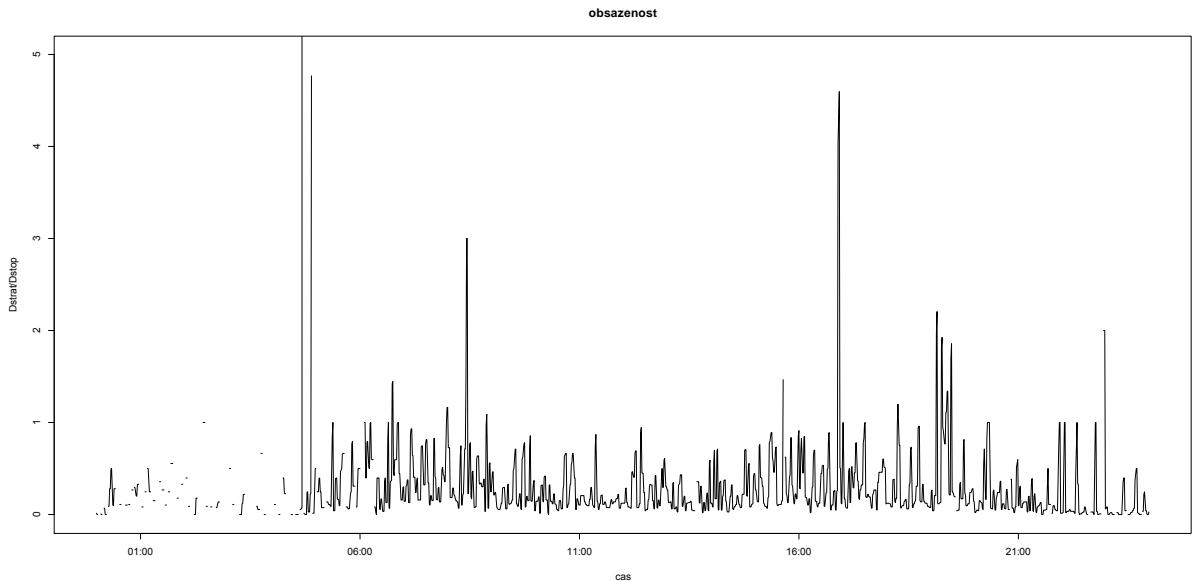
Obrázek 7: Dstrat-Dstop pro intenzitu.



Obrázek 8: Dstrat-Dstop pro obsazenost.



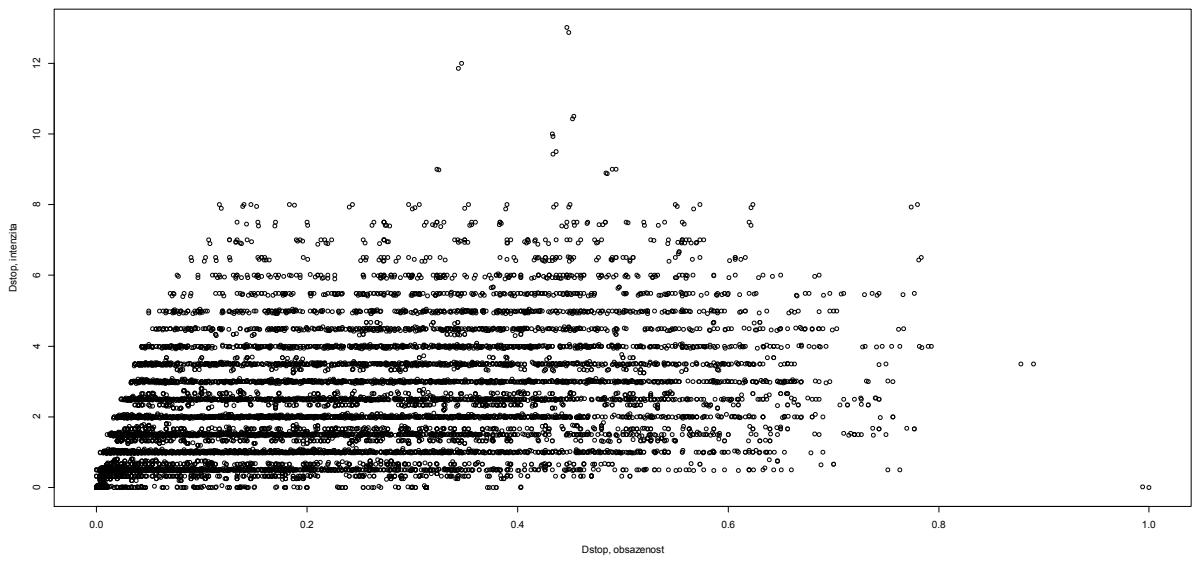
Obrázek 9: Dstrat/Dstop pro intenzitu.



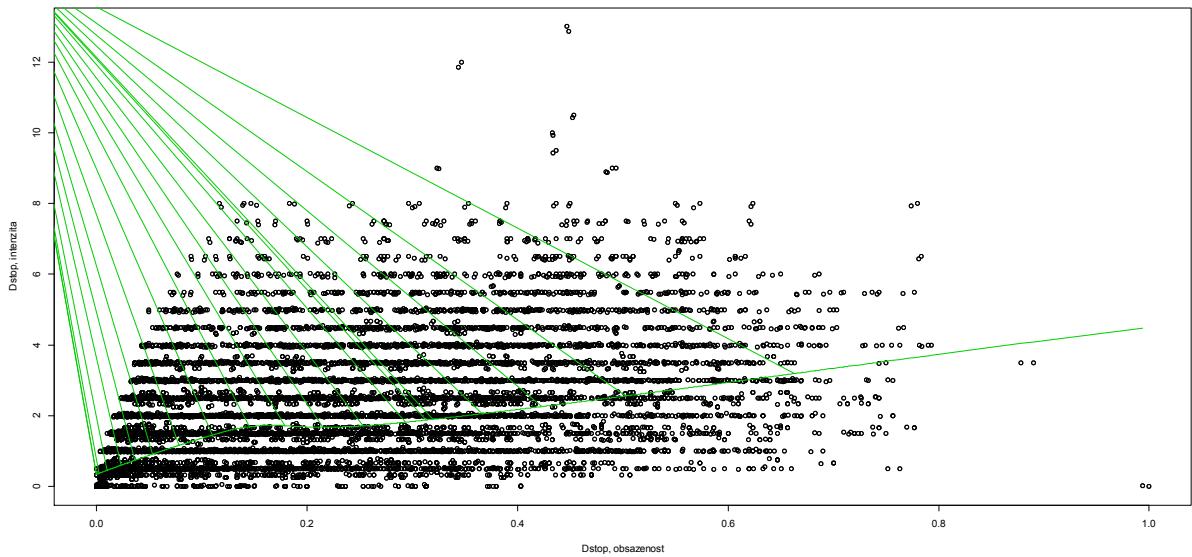
Obrázek 10: Dstrat/Dstop pro obsazenost.

3.2 Experiment 2

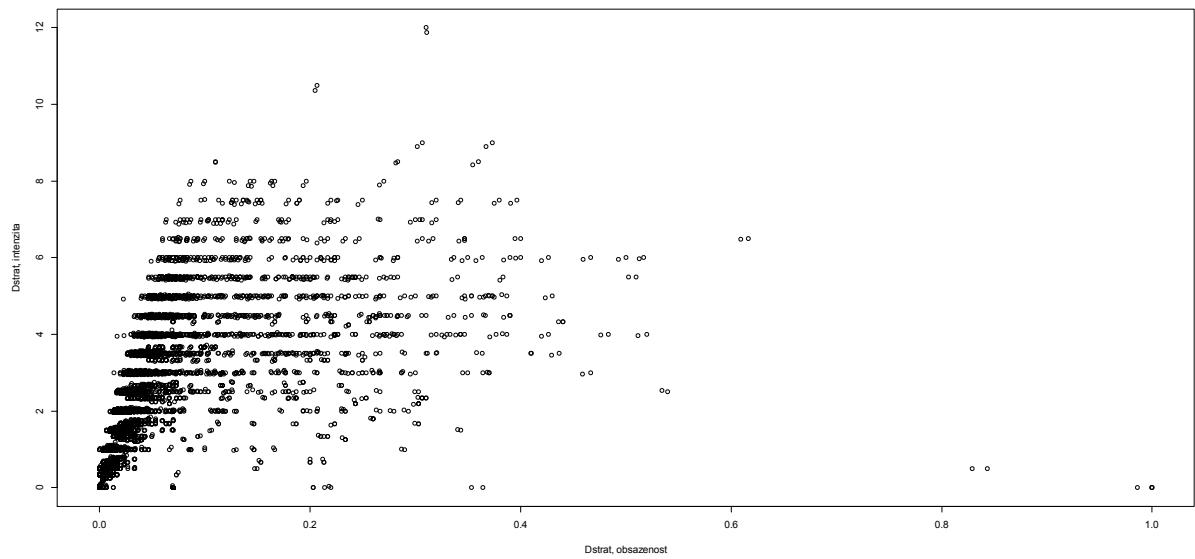
Vztah intenzity a obsazenosti pro rameno A křížovatky 5.495, ukazuje pro všechna dostupná data Obrázek 11. Je z něj jasné patrné že data neleží ani přibližně na křivce diktované nějakým idealizovaným fundamentálním diagramem (kvadratickým, po částech lineárním apod.). Např. ve smyslu „rozostřeného“ protože prostorově neprůměrkovaného FMD z práce Geroliminis, Daganzo (2008). Je zde patrná značná variabilita obsazeností a je také jasné že extrakce nějakého „typického“ vztahu (např. ve smyslu podmíněné střední hodnoty intenzity při dané obsazenosti) není nikterak jednoduchá. Obrázek 12 to ilustruje, je na zeleně vykreslen odhad pořízený (velmi) flexibilním neparametrickým loess smootherem, Cleveland (1979), Cleveland, Devlin (1988), Hastie, Tibshirani, Friedman (2009). Poznamenejme že jde o ilustrativní ukázku. Pro skutečnou extrakci regresního vztahu by bylo (např. vzhledem k Poissonovskému charakteru počtů projíždějících vozidel) vhodné použít GLM (generalized linear model) třídu regresních modelů, viz např. McCullagh, Nelder (1989), Pekár, Brabec (2006), resp. její semiparametrické rozšíření (GAM, generalized additive models), Wood (2006), podobně jako v projektu Brabec et al (2013). Obrázek 13 pak ukazuje vztah mezi intenzitou a obsazeností pro Dstrat detektor téhož ramene též křížovatky. Jde o „kvalitativně podobné“ chování ale s podstatně odlišnými detaily, a celkově jinými parametry podmíněného regresního vztahu (ještě podstatnější jsou odlišnosti v chování podmíněných extrémnějších kvantilů apod.). Tento rozpor mezi Dstop a Dstrat „fundamentálním diagramem“ (resp. jeho náznakem) je samozřejmě konzistentní s chováním dat probíraným v odstavci 3.1. dle našeho názoru tento rozpor může poněkud problematizovat simultánní použití dat z Dstop a Dstrat pro intenzity i obsazenosti, alespoň pro tuto konkrétní lokalitu.



Obrázek 11: Vztah intenzity a obsazenosti na Dstop detektoru.



Obrázek 12: Vztah intenzity a obsazenosti na Dstop detektoru s loess vyhlazením.

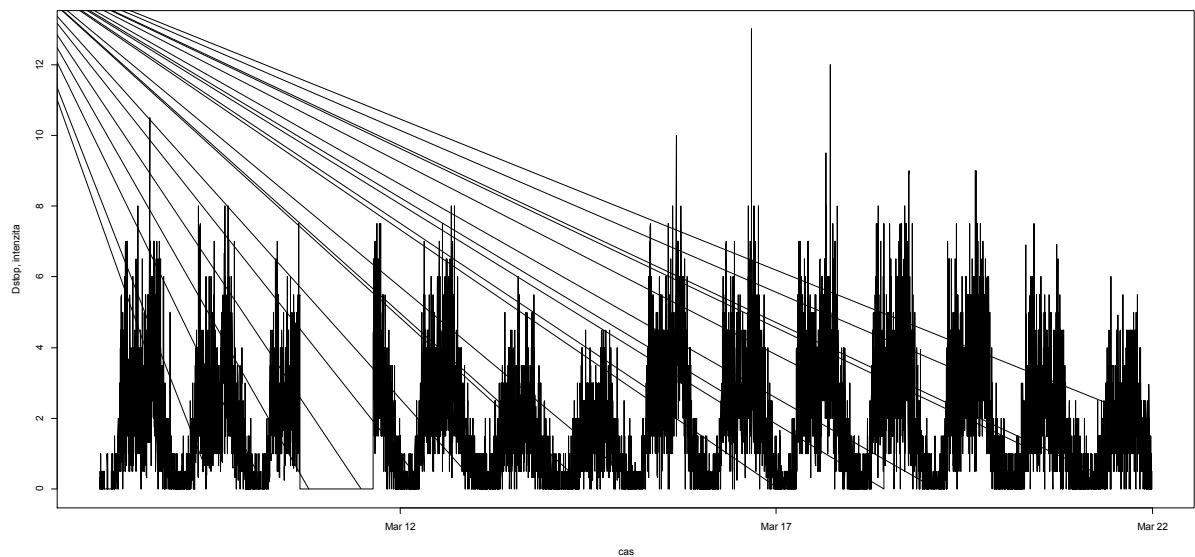


Obrázek 13: Vztah intenzity a obsazenosti na Dstrat detektoru.

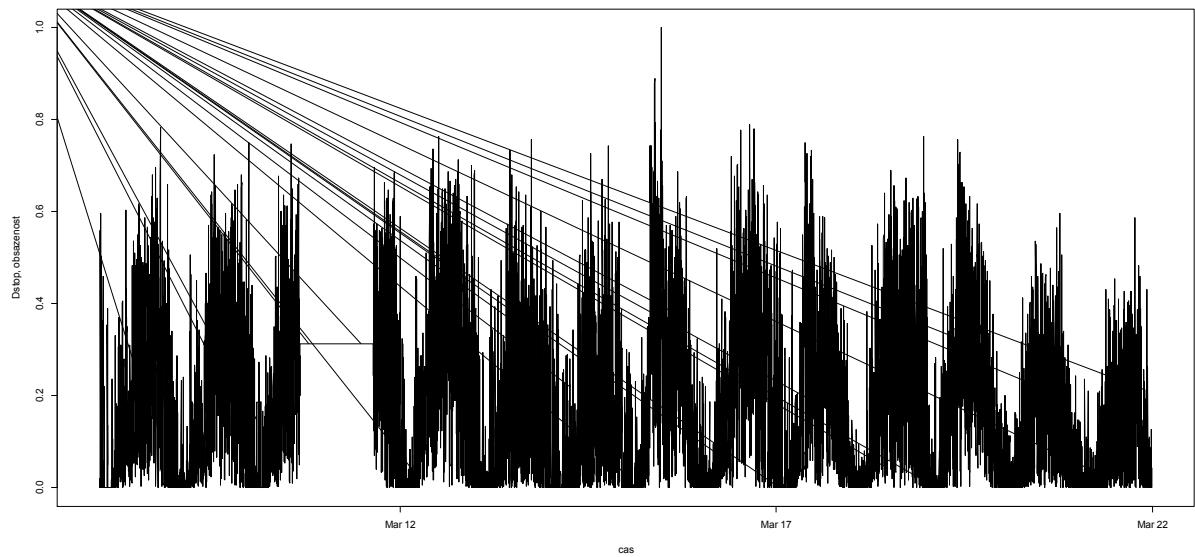
3.3 Experiment 3

Kvalita dat z detektorů není zcela ideální, jak ukazují následující obrázky. Občas dochází k výpadkům (souvislá řada nulových hodnot), ale i „zaseknutí“ čidla na nenulové hodnoty (dokonce různé pro Dstop a Dstrat čidla apod.).

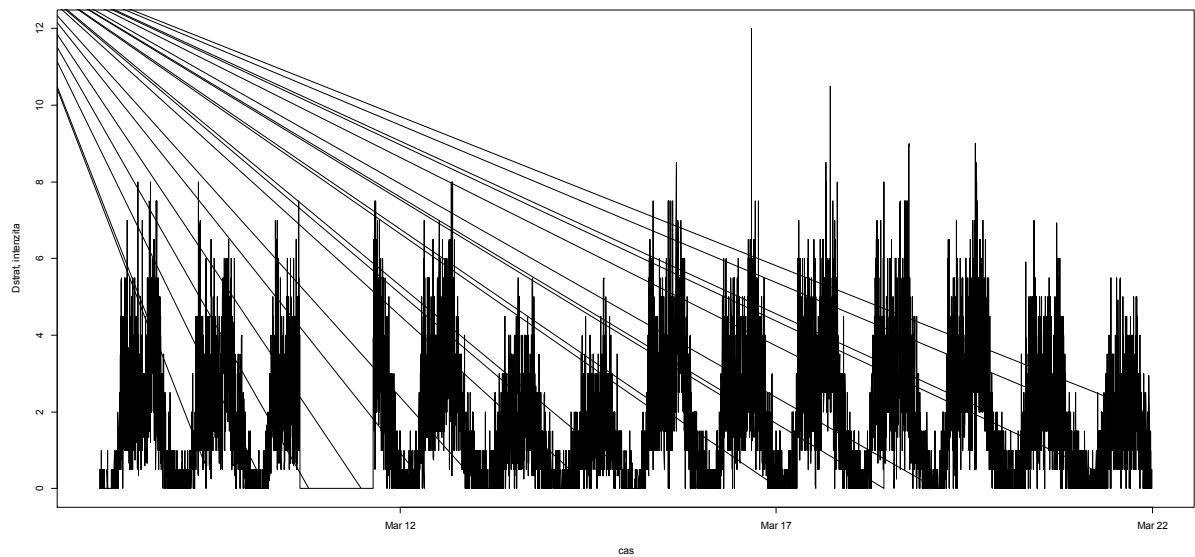
V časových řadách intenzit i obsazeností je (samozřejmě) patrný výrazný denní (a týdenní) chod.



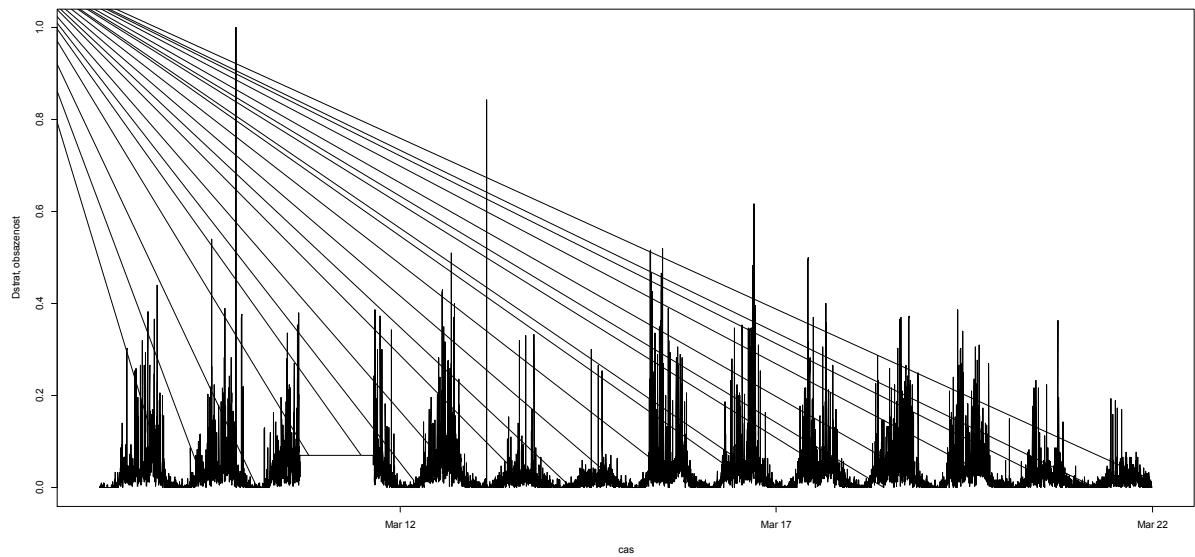
Obrázek 14: Časová řada Dstop detektoru pro intenzity.



Obrázek 15: Časová řada Dstop detektoru pro obsazenosti.

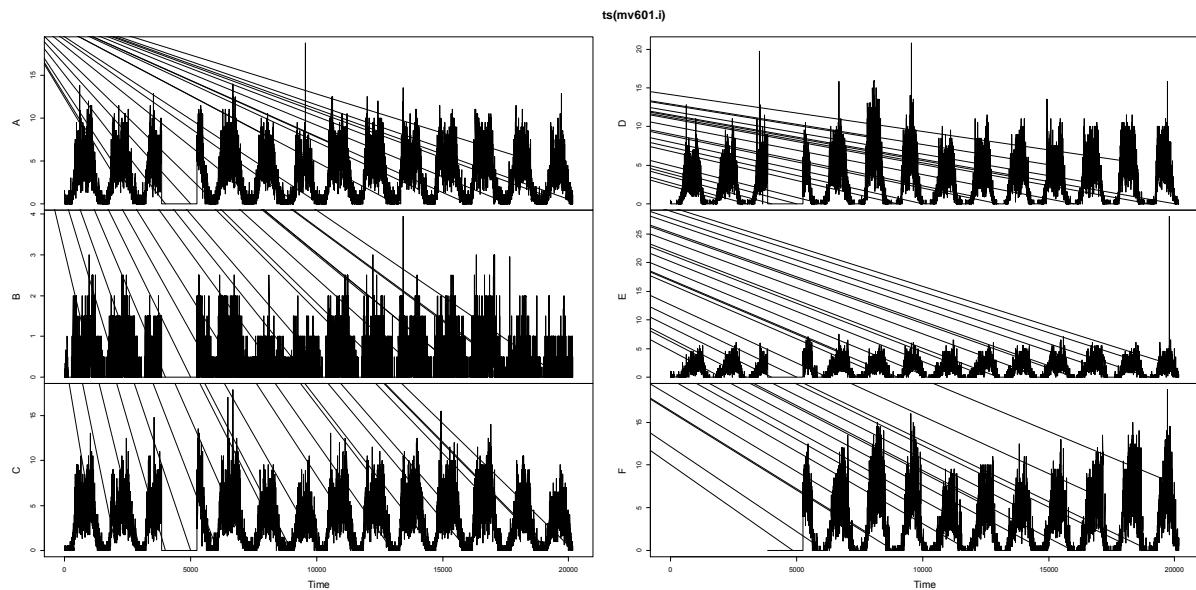


Obrázek 16: Časová řada Dstrat detektoru pro intenzitu.

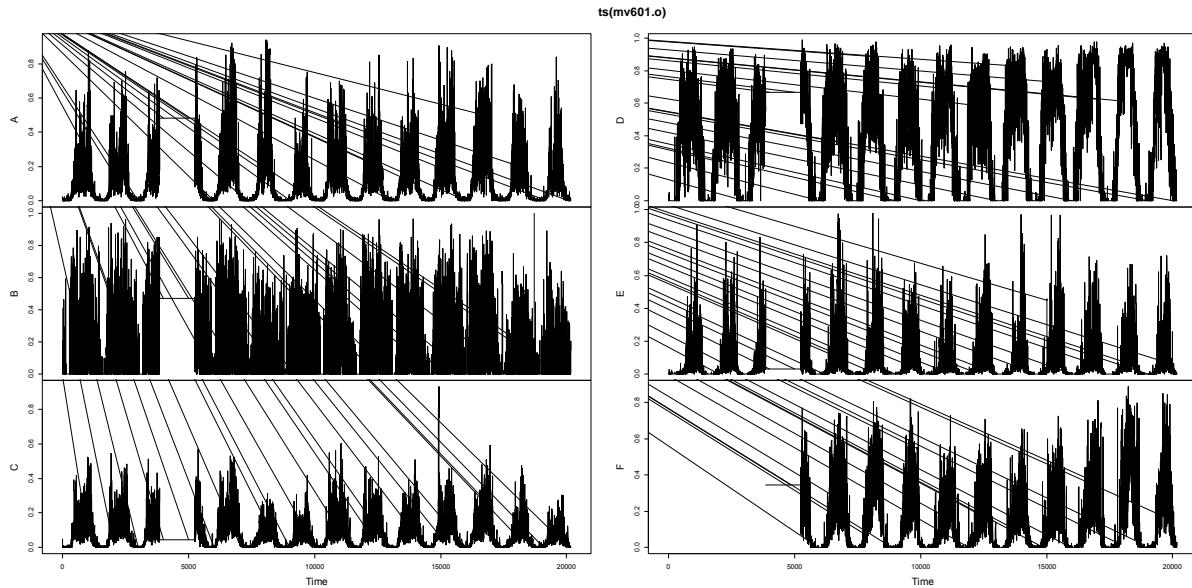


Obrázek 17: Časová řada Dstrat detektoru pro obsazeností.

Pro srovnání chody z křížovatky 5.601 (všechna dostupná data), viz Obrázek 18, Obrázek 19. Jsou tu vidět občasné výpadky, „úlety“ apod.



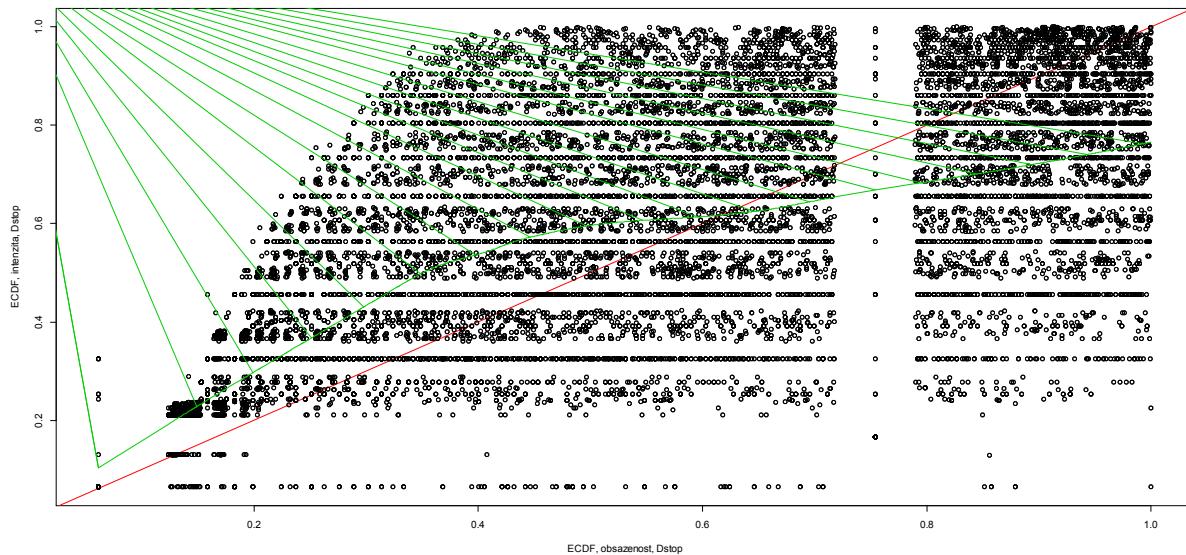
Obrázek 18: Intenzita na jednom rameni, Dstop, 5.601.



Obrázek 19: Obsazenost na jednom rameni, Dstop, 5.601

3.4 Experiment 4

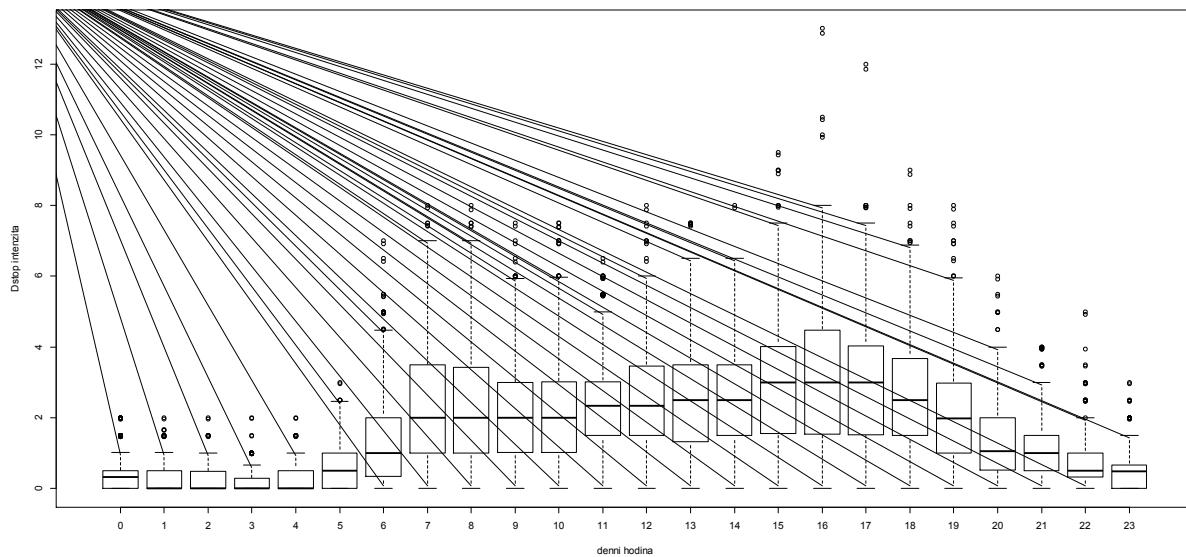
Jiný pohled na vztah mezi intenzitou a obsazeností na Dstop detektoru nabízí Obrázek 20 který vykresluje proti sobě empirické distribuční funkce pro intenzitu a pro obsazenost (spočtené na Dstop detektoru). Pro srovnání je do obrázku přidaná červenáčára odpovídající identitě (ideálnímu vztahu mezi oběma transformovanými proměnnými) a dále též loess smoother naznačující „typický průběh“. Vidíme že skutečná situace se od „ideálu“ dosti liší (vztah mezi obsazeností a intenzitou není jednoduchý ani pro transformaci zohledňující jen uspořádání).



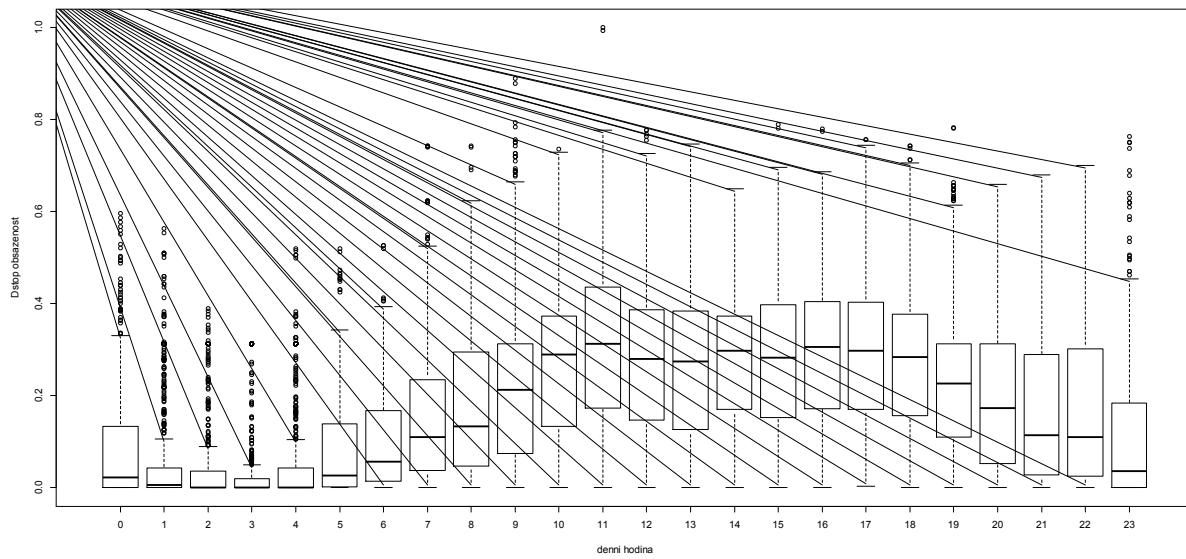
Obrázek 20: ECDF, intenzita vs. obsazenost, Dstop detektor

3.5 Experiment 5

Detailnější pohled na denní chod distribucí Dstop intenzit a obsazeností ukazují Obrázek 21 a Obrázek 22, a to ve formě krabicových grafů (boxplotů), Chambers et al. (1983) pro jednotlivé denní hodiny. Jednotlivý krabicový graf sumarizuje jednoduchým a přehledným způsobem nejpodstatnější rysy rozdělení naměřených hodnot pro danou denní hodinu. Obsahuje jednak „krabici“ která zahrnuje 50% centrálních/„typických“ dat (její spodní okraj odpovídá 25. percentilu, horní percentilu 75.). Vodorovná úsečka uvnitř krabice odpovídá mediánu (ta může v hodinách s malým provozem splývat s horním/spodním okrajem krabice). „Vousy“ (vykreslované nahoru a dolů) dosahují do 1.5 násobku interkvartilového rozpětí (výška krabice odpovídá interkvartilovému rozpětí). Pokud v této vzdálenosti není žádný napozorovaný bod pak sahají jen po nejvzdálenější pozorování. Body za 1.5 násobkem interkvartilového rozpětí jsou pak vykreslovány jednotlivě. Ze srovnání krabicových grafů tak snadno vyčteme denní běh mediánu (výrazná denní periodita je samozřejmostí), změny variability, celkovou tendenci k vyšikmení vpravo, změny šikmosti v průběhu dne. Můžeme porovnat zvlášť chování (např. symetrie) ve středové části dat (krabici) a pro data odlehlejší. Vidíme, že chování intenzit a obsazeností je opět poněkud odlišné. Například zdánlivý nástup a odeznění doby s nejhustším provozem posuzovaný z pohledu středové části rozdělení intenzit a obsazeností jsou časované poněkud jinak (i přes to že jde o detektor ze stejného ramene), apod.



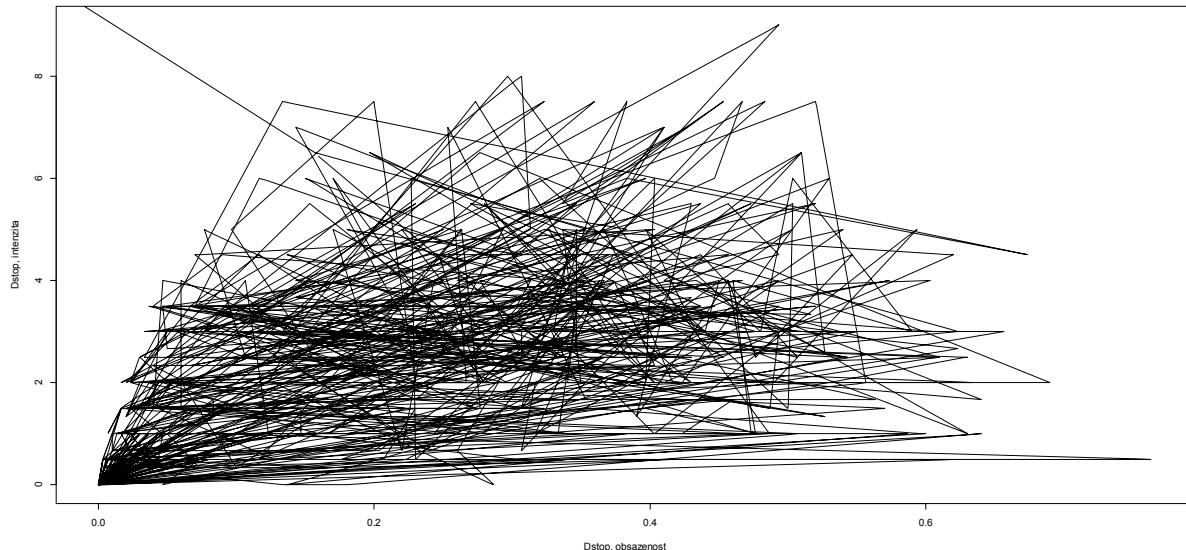
Obrázek 21: Denní chod distribuce intenzit na Dstop detektoru summarizovaný krabicovými grafy (boxplots).



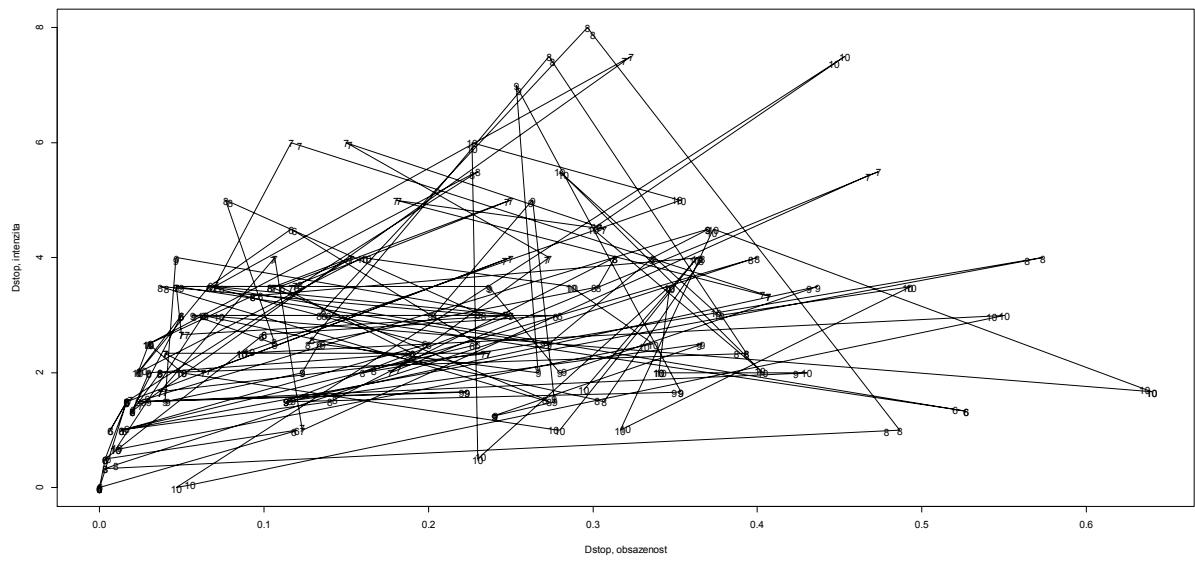
Obrázek 22: Denní chod distribuce obsazeností na Dstop detektoru summarizovaný krabicovými grafy (boxplots).

3.6 Experiment 6

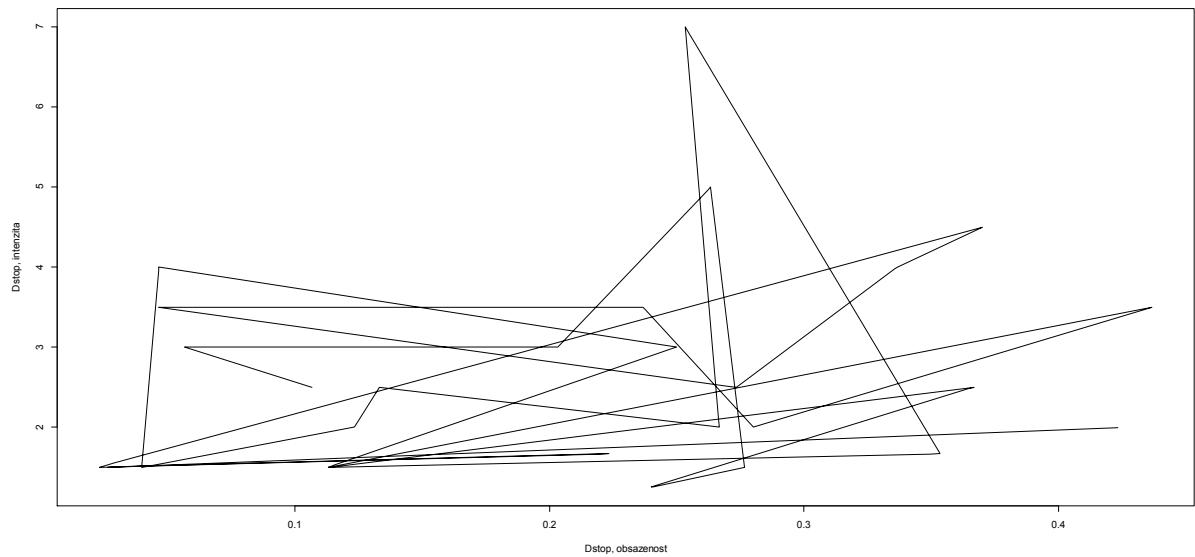
Pro posouzení toho odkud variabilita a ne-ideální chování dat (oproti fundamentálnímu diagramu) na grafu intenzita vs. obsazenost pochází se podívejme na trajektorie v prostoru intenzita x obsazenost (vzniklé pospojováním časově následných datových bodů úsečkami). Trajektorie z ukázkového dne 18.3. ukazuje (v různém detailu) Obrázek 23, Obrázek 24, Obrázek 25, Obrázek 26. Vidíme z nich že podstatná část mikro-variability je spojena s chováním obsazenosti (viz horizontální a téměř horizontální posuny).



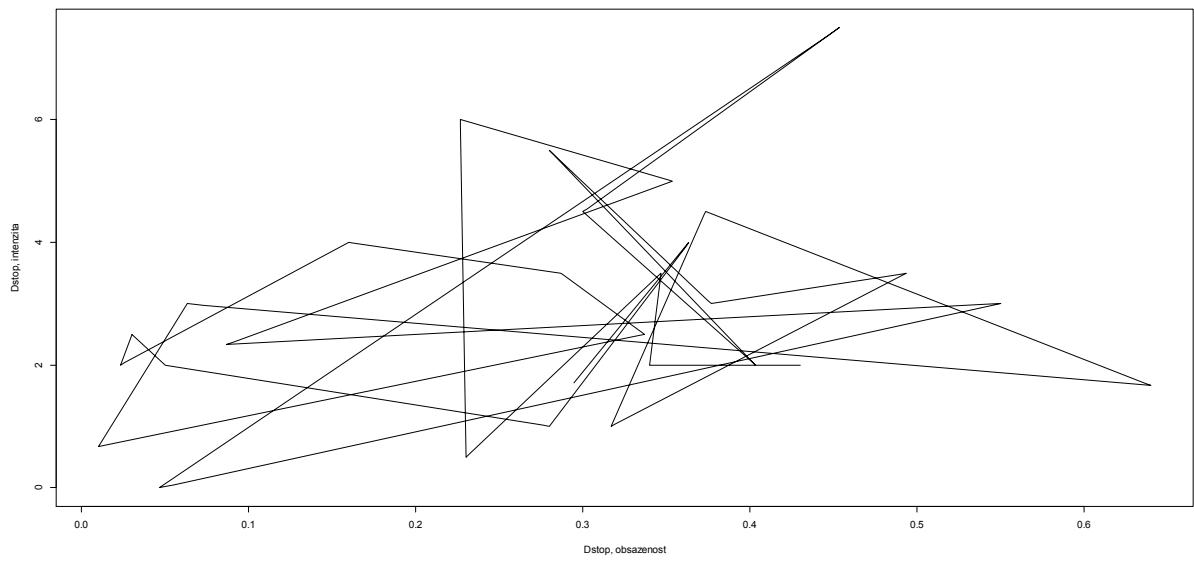
Obrázek 23: Trajektorie v prostoru intenzita x obsazenost, Dstop čidlo celý den 18.3.



Obrázek 24: Trajektorie v prostoru intenzita x obsazenost, Dstop čidlo jen 18.3., hodiny 6-10, s číselným označením denních hodin.

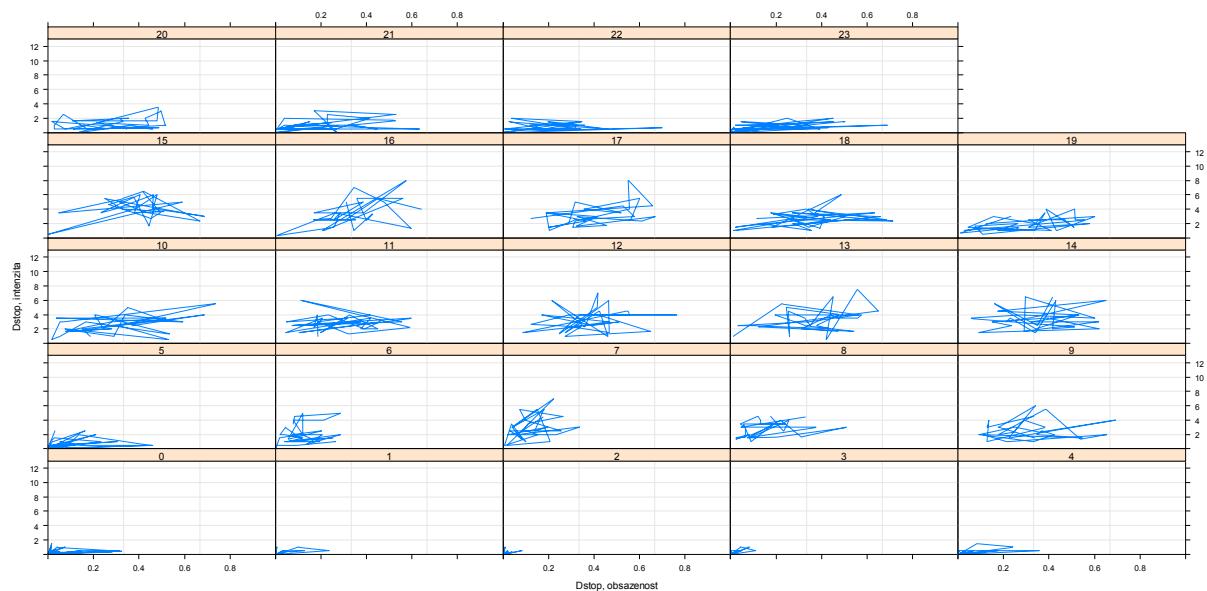


Obrázek 25: Trajektorie v prostoru intenzita x obsazenost, Dstop čidlo jen 18.3., detail hodina 9.

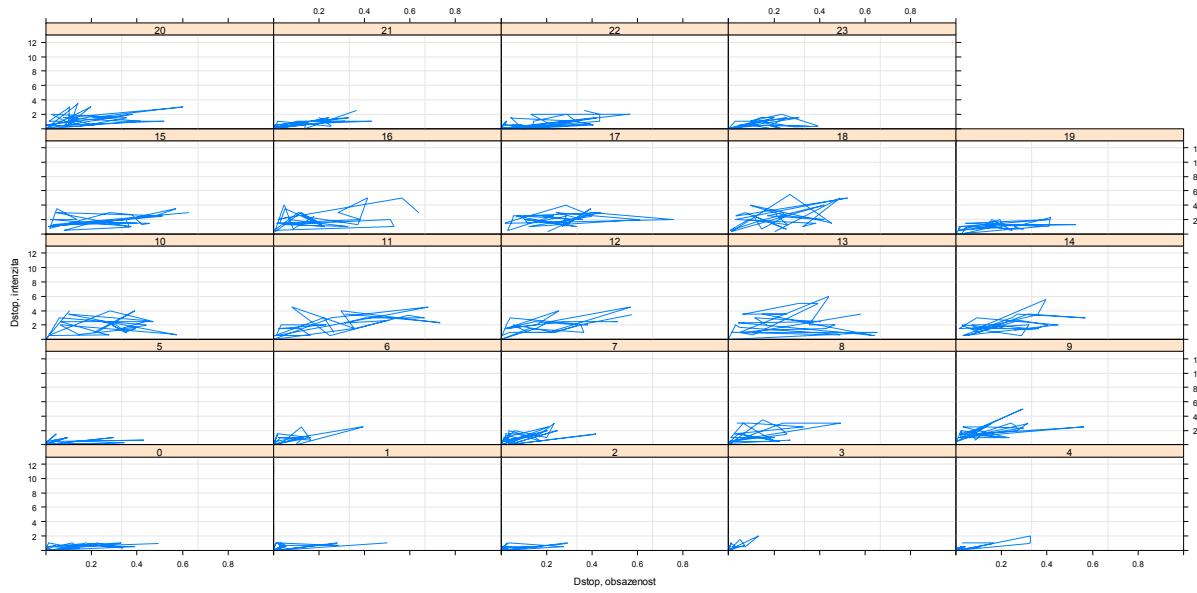


Obrázek 26: Trajektorie v prostoru intenzita x obsazenost, Dstop čidlo jen 18.3., detail hodina 10.

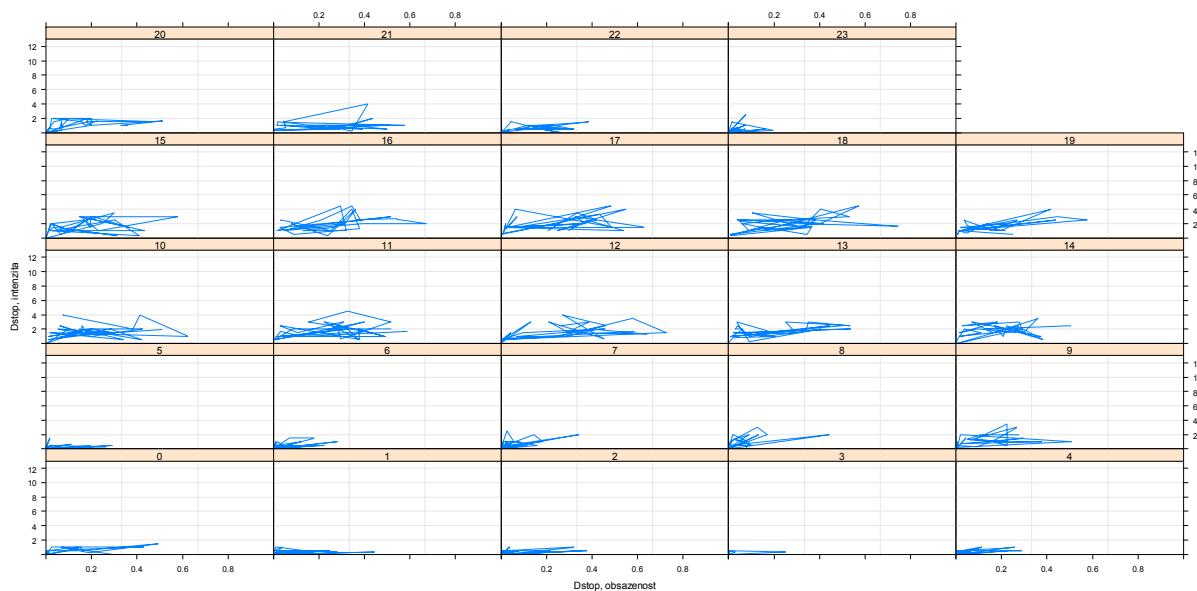
Přehledný pohled na souvztažnost intenzity a obsazenosti Dstop čidla poskytuje tzv. lattice graf, Sarkar (2008) který ukazuje Obrázek 27, Obrázek 28, Obrázek 29, Obrázek 30, Obrázek 31, Obrázek 32, Obrázek 33, Obrázek 34, Obrázek 35, Obrázek 36 (12.3 až 21.3. tj. pátek až neděle). Z obrázků je vidět systematické (s týdenní a hodinovou periodicitou spojené) změny v úrovni i variabilitě obou proměnných, ale i v jejich vzájemné korelací.



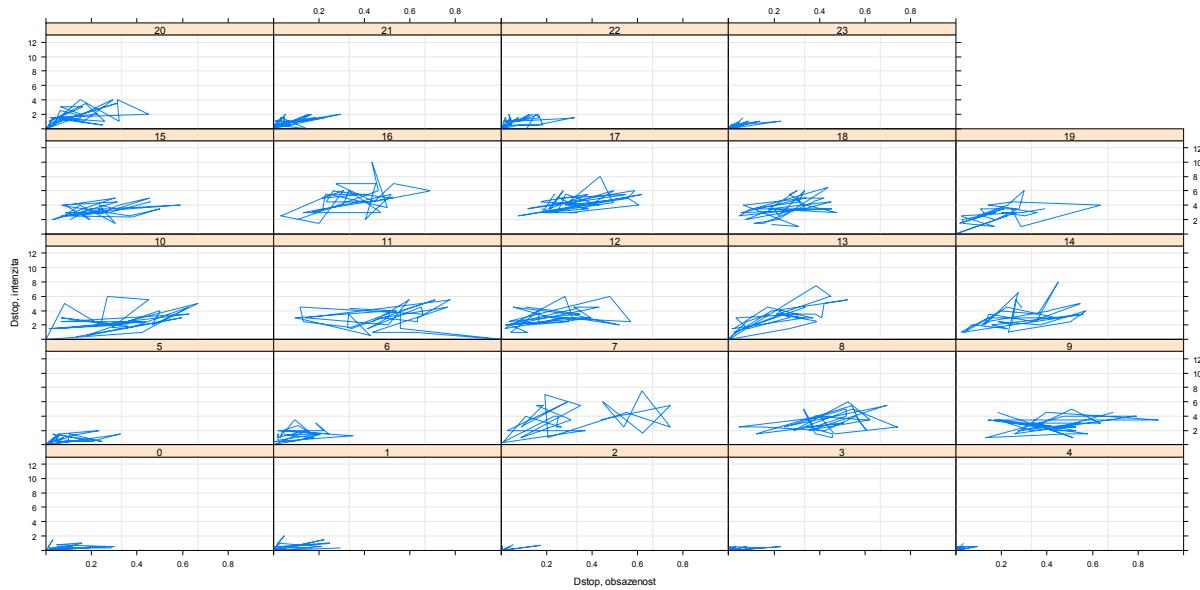
Obrázek 27: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, pátek 12.3.



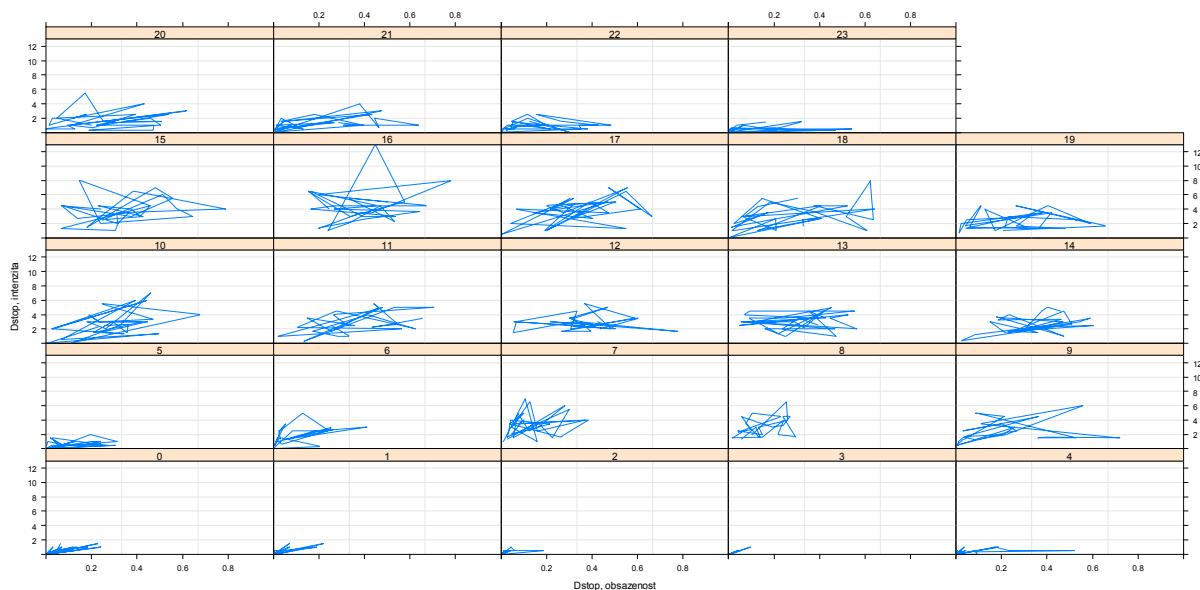
Obrázek 28: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, sobota 13.3.



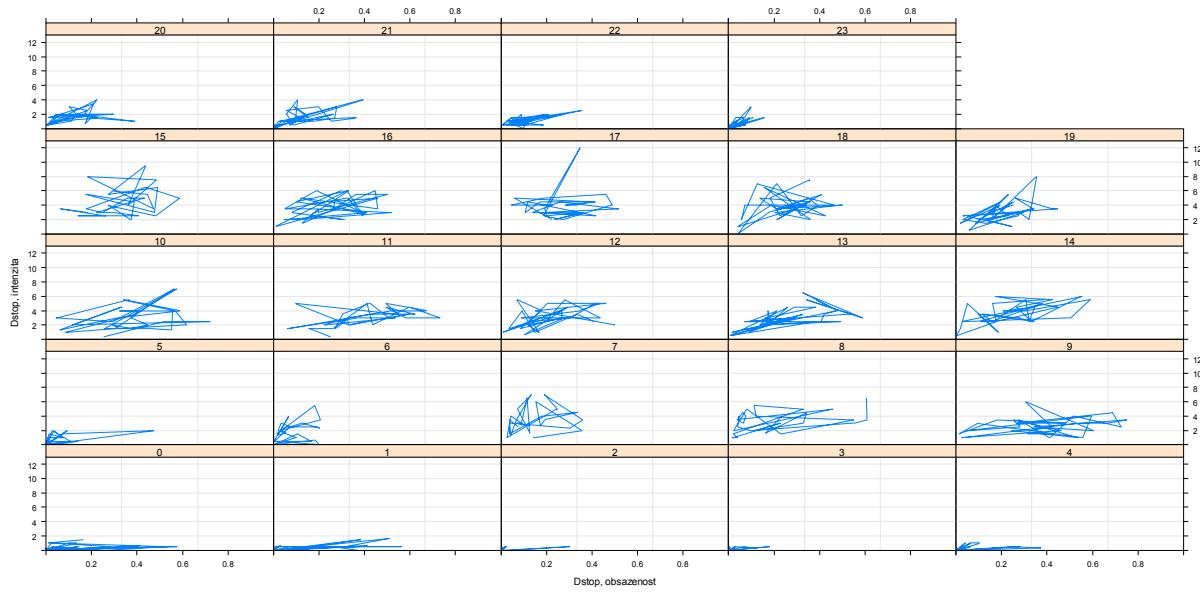
Obrázek 29: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, neděle 14.3.



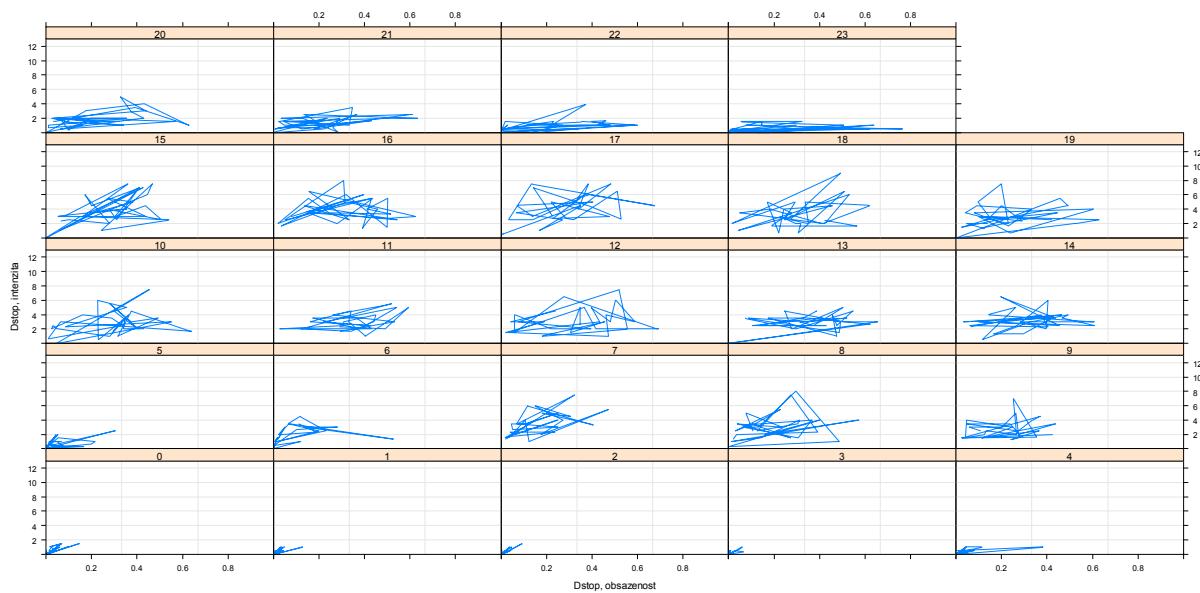
Obrázek 30: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, pondělí 15.3.



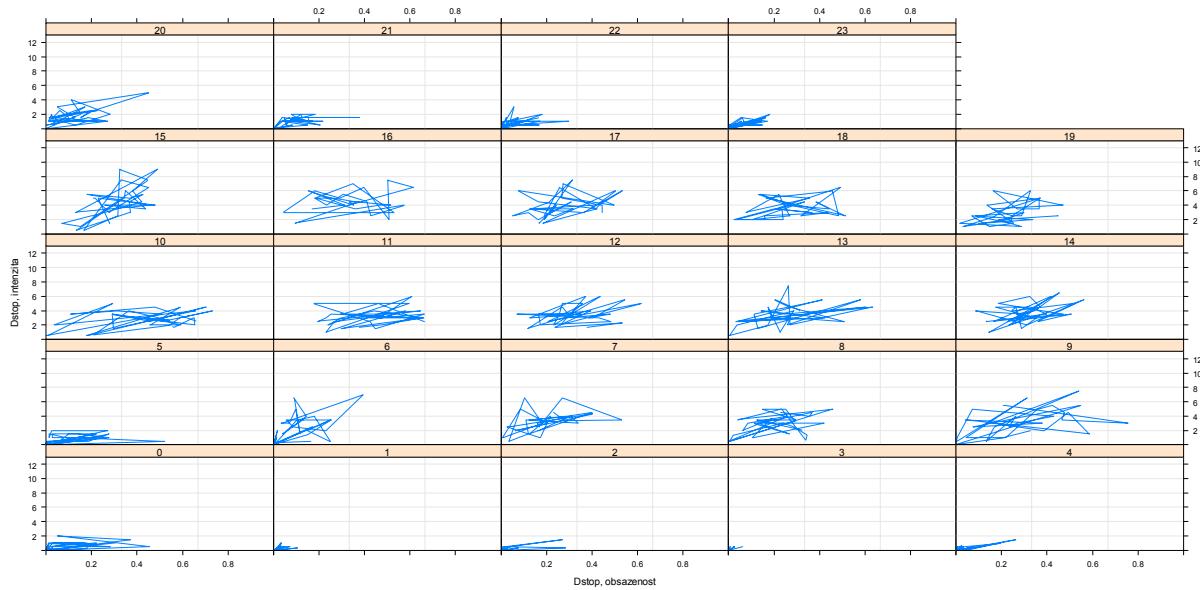
Obrázek 31: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, úterý 16.3.



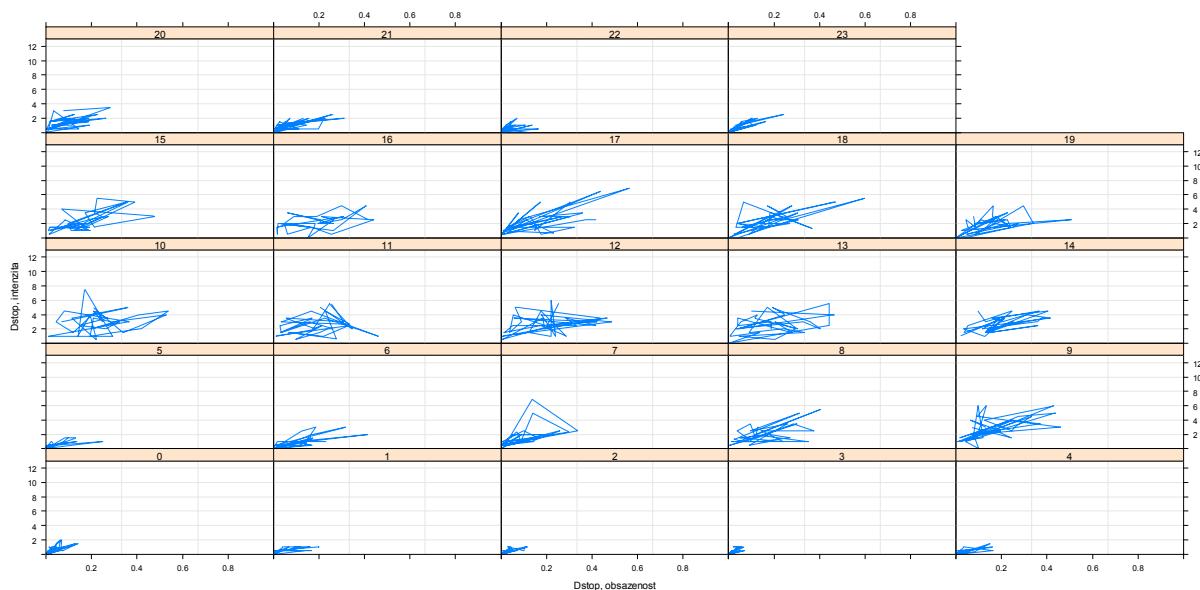
Obrázek 32: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, středa 17.3.



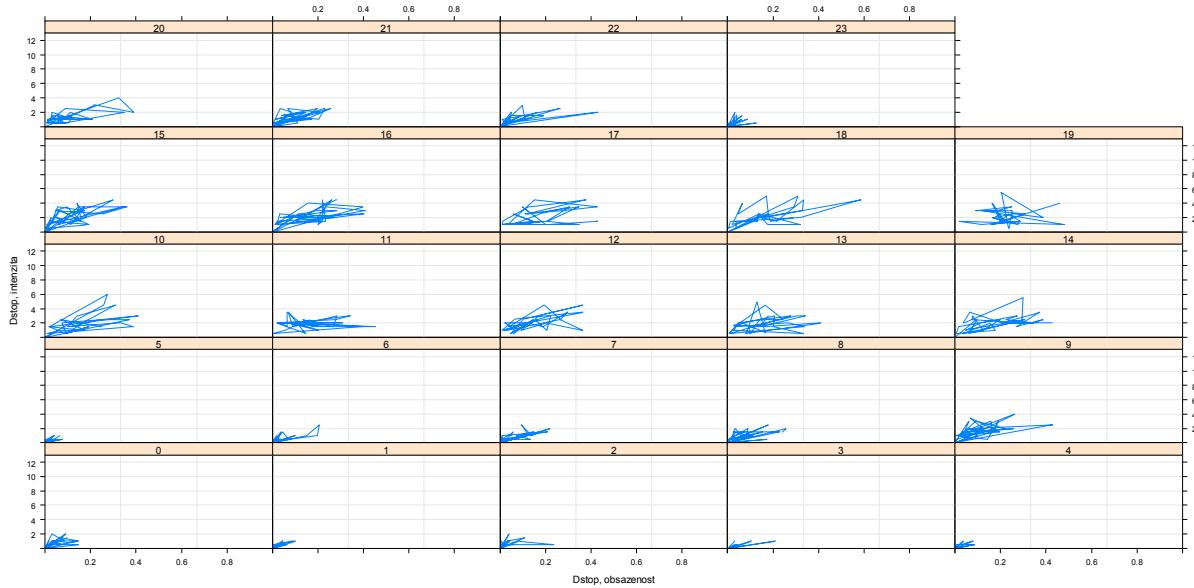
Obrázek 33: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, čtvrtek 18.3.



Obrázek 34: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, pátek 19.3.

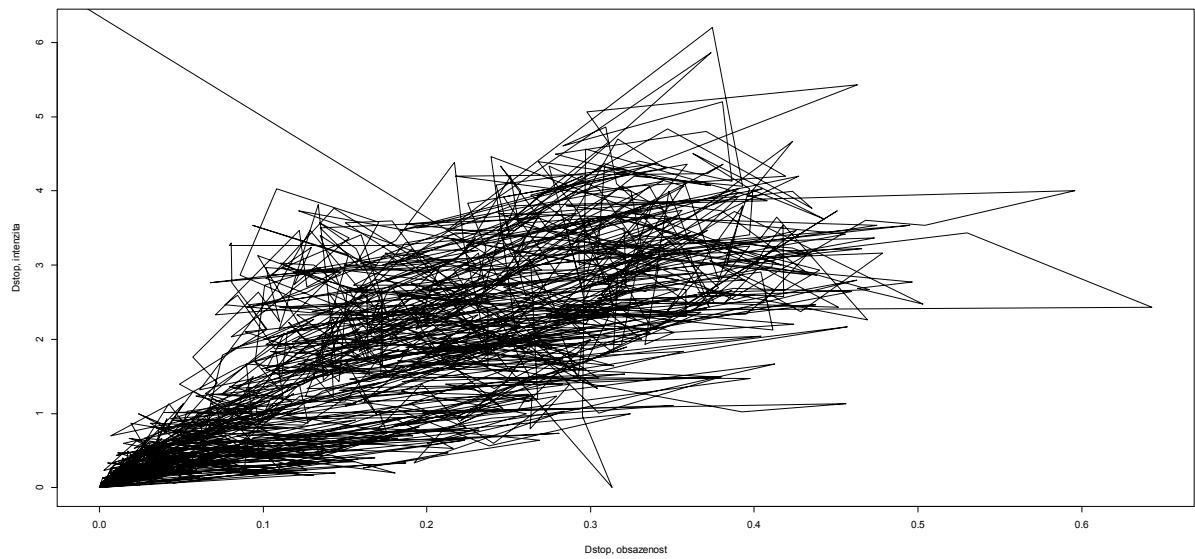


Obrázek 35: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, sobota 20.3.



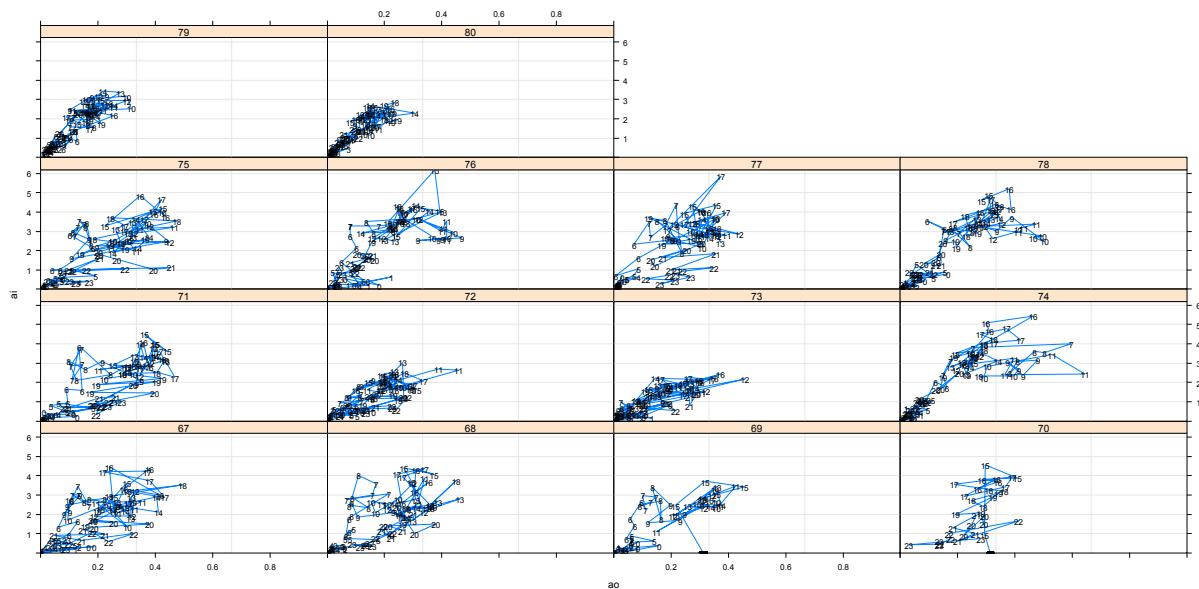
Obrázek 36: Vztah intenzity a obsazenosti, trajektorie na Dstop detektoru, neděle 21.3.

Podívejme se na vztah intenzity a obsazenosti na Dstop detektoru po (velmi jednoduchém) vyhlazení/odšumění pořízeném jen 15-minutovým průměrkováním (agregací). Obrázek 37 ukazuje jak se i po takto jednoduchém „odšumění“ (a potlačení vlivu různě dlouhé doby zelené v různých minutách) vztah mezi intenzitou a obsazeností zlepší (linearizuje a stane více těsným). Jedním z možných pohledů je domněnka že obsazenost a intenzita přináší velmi podobnou informaci (v případě intenzity změřenou přesněji) a že nemalá část variability kterou se obsazenost od intenzity odlišuje je ve skutečnosti šum. Linearita po vyhlazení je zajímavé také z pohledu dopravně inženýrského/praktického: zdá se že např na tomto rameni typicky nedochází k výrazné saturaci (jež by vztah intenzita/obsazenost od linearity odchylovala).



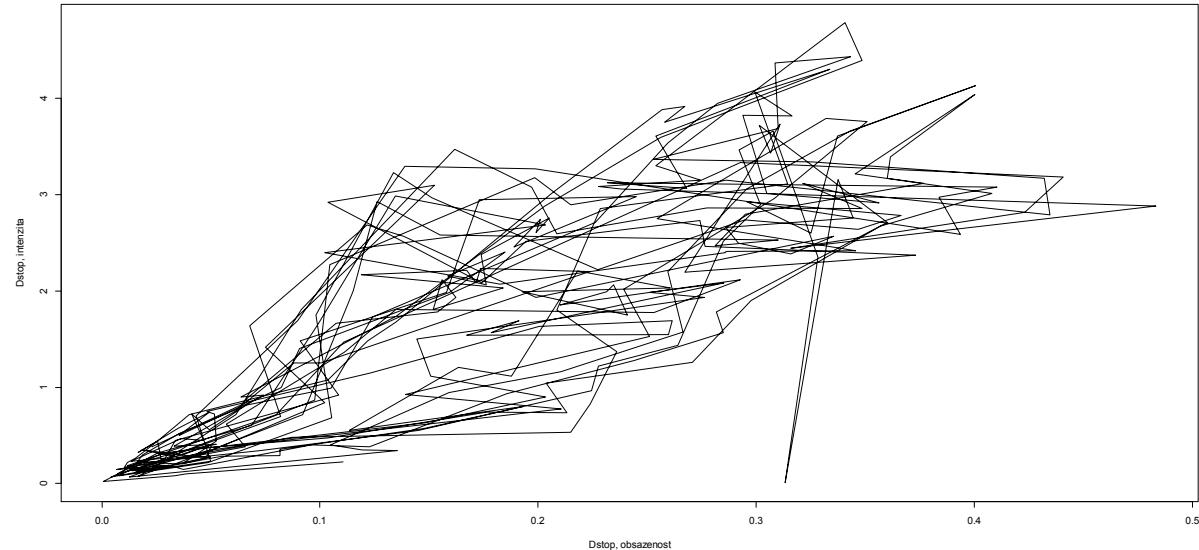
Obrázek 37: Trajektorie v prostoru intenzity a obsazenosti, Dstop, 15-minutová agregace, všechna dostupná data.

Obrázek 38 ilustruje změny chování trajektorií 15-minutových průměrů mezi dny a denními hodinami. Denní i týdenní periodicitu jsou patrné ale celkové chování grafu je podstatně stabilnější a homogennější i vzhledem k času oproti minutovému rozlišení.



Obrázek 38: 15-minutové průměry intenzit a obsazeností Dstop detektoru pro několik dnů (označených v záhlaví pořadovým číslem dne uvnitř roku), denní hodiny jsou označeny čísla uvnitř jednotlivých grafů.

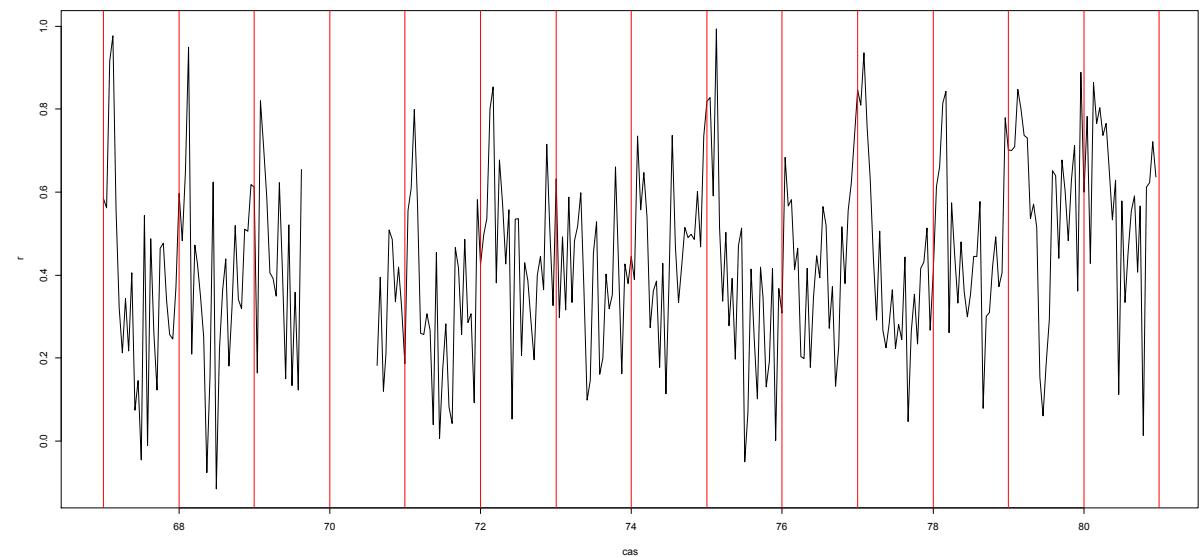
Obrázek 39 ilustruje že hodinové průměrování (které vyhlažuje ještě více ale zachovává podstatné změny hustoty dopravy související s hodinovou a týdenní periodicitou) naznačuje relativně těsný a nepříliš nelineární vztah mezi intenzitou a obsazeností.



Obrázek 39: 1-hodinové průměry intenzit a obsazeností Dstop detektoru pro všechna dostupná data.

3.7 Experiment 7

Korelace mezi intenzitou a obsazeností po hodinách (původní data, bez agregace)



Obrázek 40: Korelace mezi intenzitou a obsazeností, Dstop detektor, původní data bez agregace, červené vertikální čáry označují počátky kalendářích dnů.

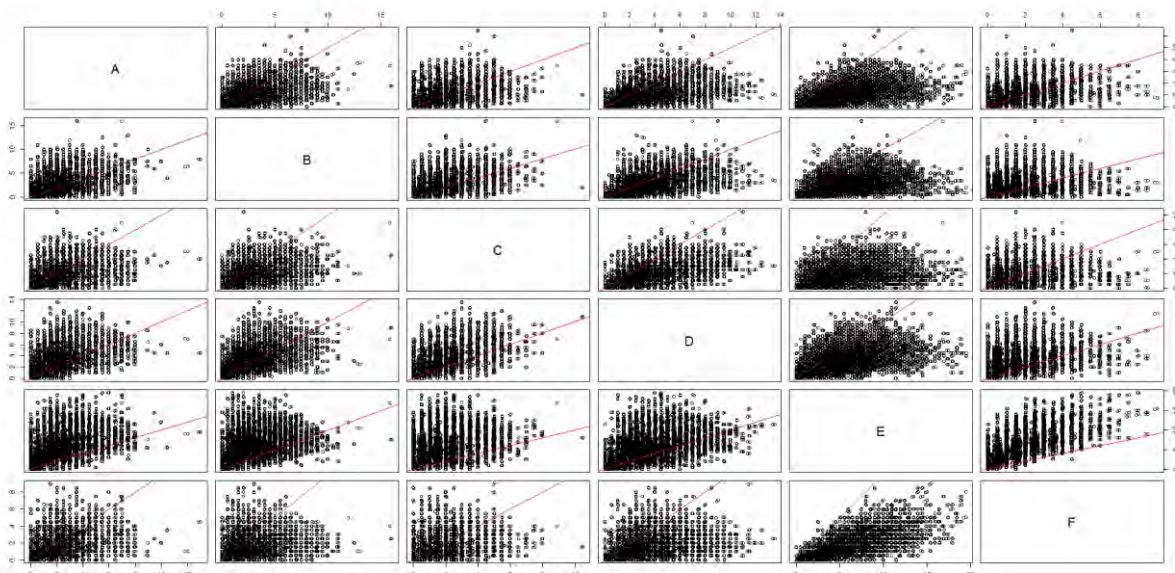
Korelace jsou vesměs kladné. Během noci (stabilně nízkého provozu) jsou nejvyšší. To není nejpříznivější zpráva z pohledu simultánního využití intenzit a obsazeností pro řízení.

3.8 Experiment 8

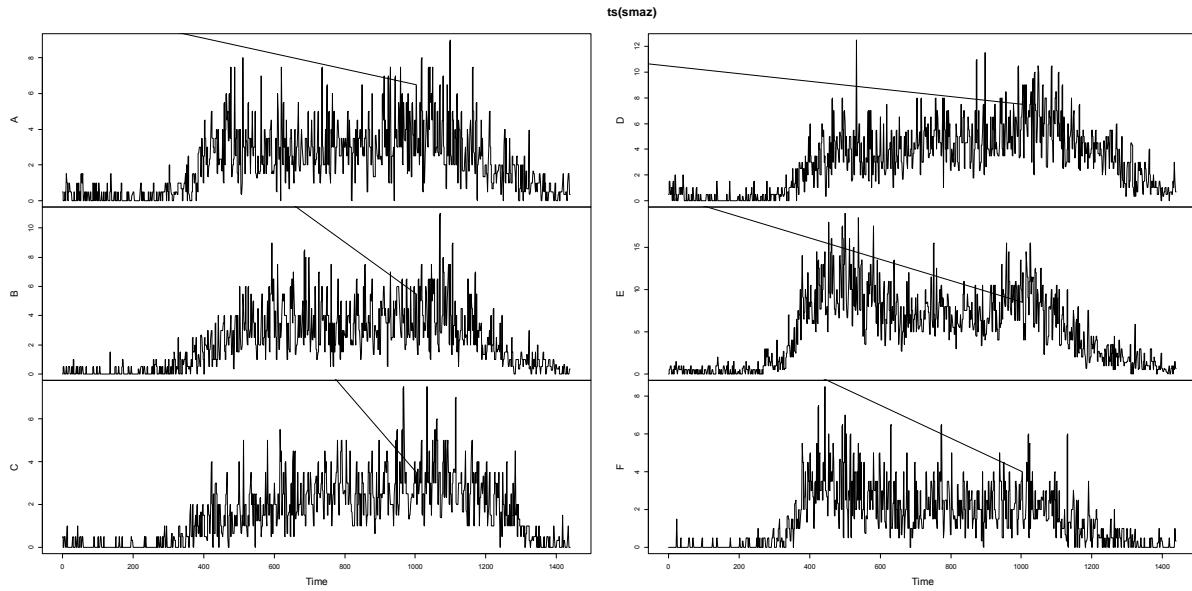
Dosud jsme zkoumali chování intenzit, respektive obsazeností na vybraném rameni křížovatky. V následujících odstavcích se podíváme na souvztažnosti mezi různými rameny téže křížovatky (5.495).

3.8.1 Intenzita

Obrázek 41 ukazuje souvztažnosti Dstop detektorů na různých ramenech téže křížovatky (všechna dostupná data). Obrázek 42 pak zobrazuje časové řady intenzit na Dstop pro různá ramena, ve vzorovém dni, 18.3.



Obrázek 41: Intenzita, Dstop, všechna dostupná data.

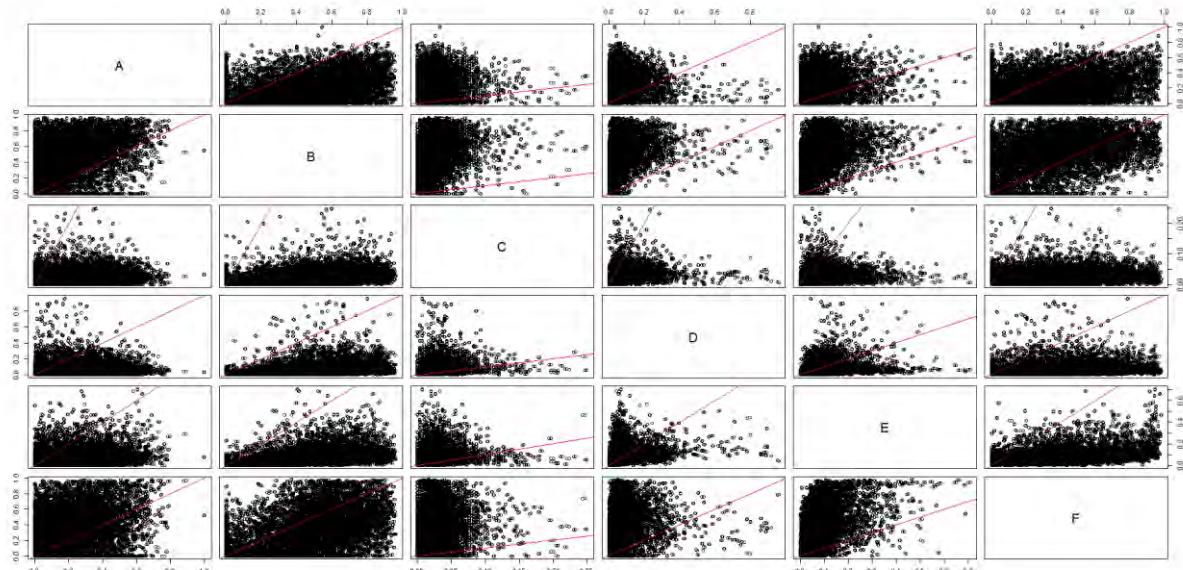


Obrázek 42: Časové řady intenzity, Dstop, vzorový den, 18.3.

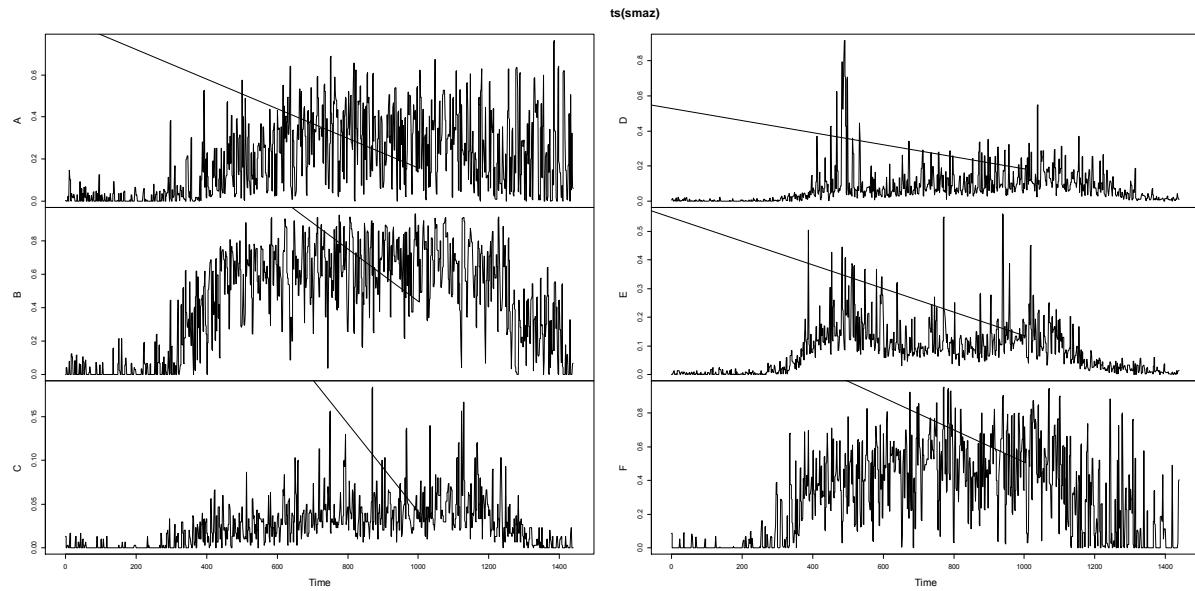
V zásadě jsou různé směry podobné, ale ne zcela kompletně. AB (od města), CD (od Rozvadovské spojky), EF (od D5) jsou si hodně podobné. Zdá se, že podobnější jsou si směry odkud se přijíždí (ty se za křižovatkou štěpí), ne tak protisměry stejné trasy (ED, AF, BC). Je to ale hodně o tom ve kterém směru to jezdí dopoledne/odpoledne či obojí.

3.8.2 Obsazenost

Dstop čidla, obsazenost, všechna data (Obrázek 43) a časové řady pro vzorový den (Obrázek 44).



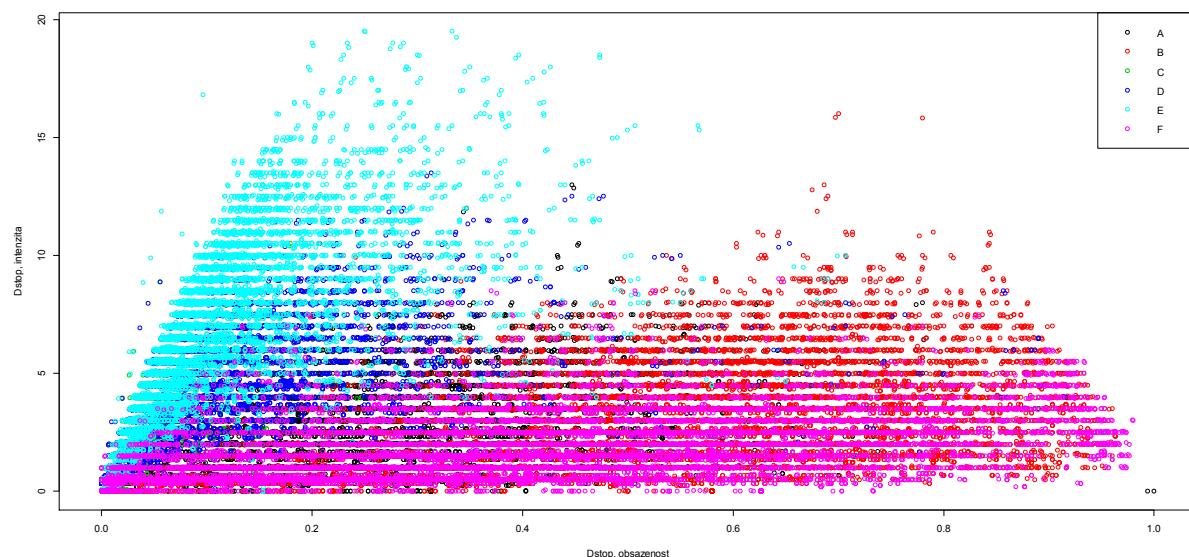
Obrázek 43: Obsazenost, Dstop, všechna dostupná data.



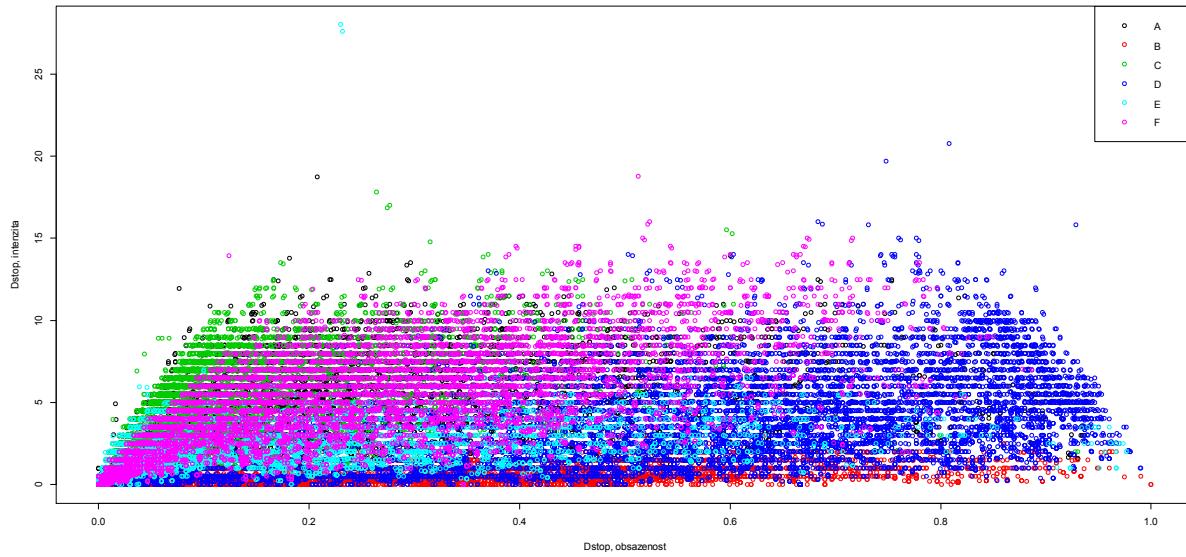
Obrázek 44: Časové řady obsazenosti, Dstop, vzorový den, 18.3.

3.8.3 Vzájemný vztah intenzity a obsazenosti

Obrázek 45, Obrázek 46 ukazují vztah pro různá ramena téže křížovatky (5.495 a 5.601 respektive) na Dstop detektoru.



Obrázek 45: Vztah intenzity a obsazenosti na Dstop detektoru křížovatky 5.495



Obrázek 46: Vztah intenzity a obsazenosti na Dstop detektoru křížovatky 5.601

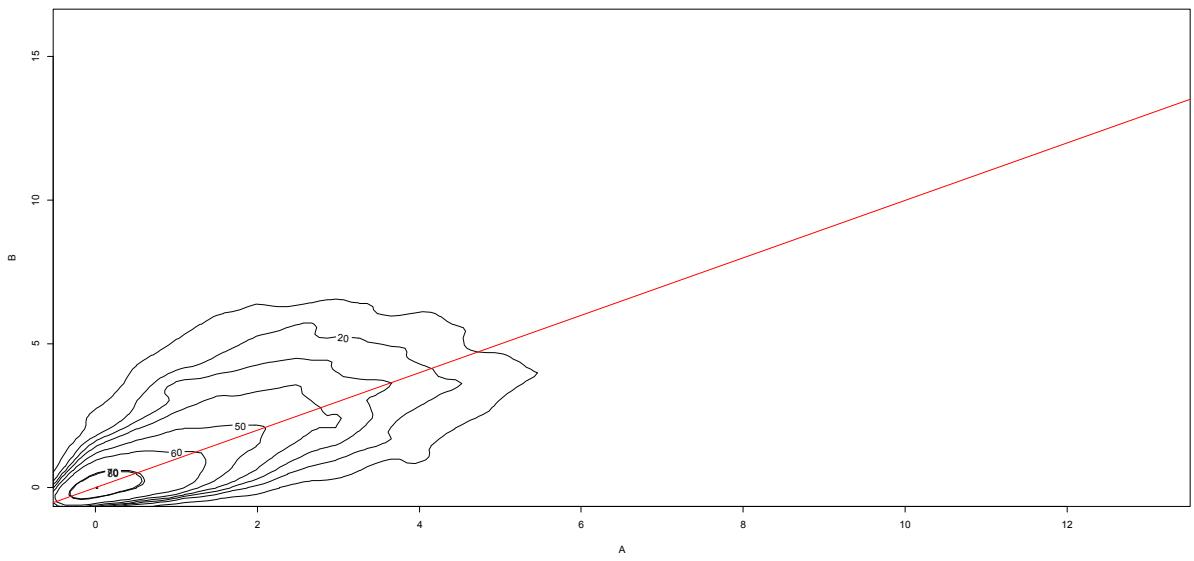
Intenzita vs. obsazenost mají pro různé směry dosti různý tvar, protiproudé jsou ale podobné.

3.9 Experiment 9

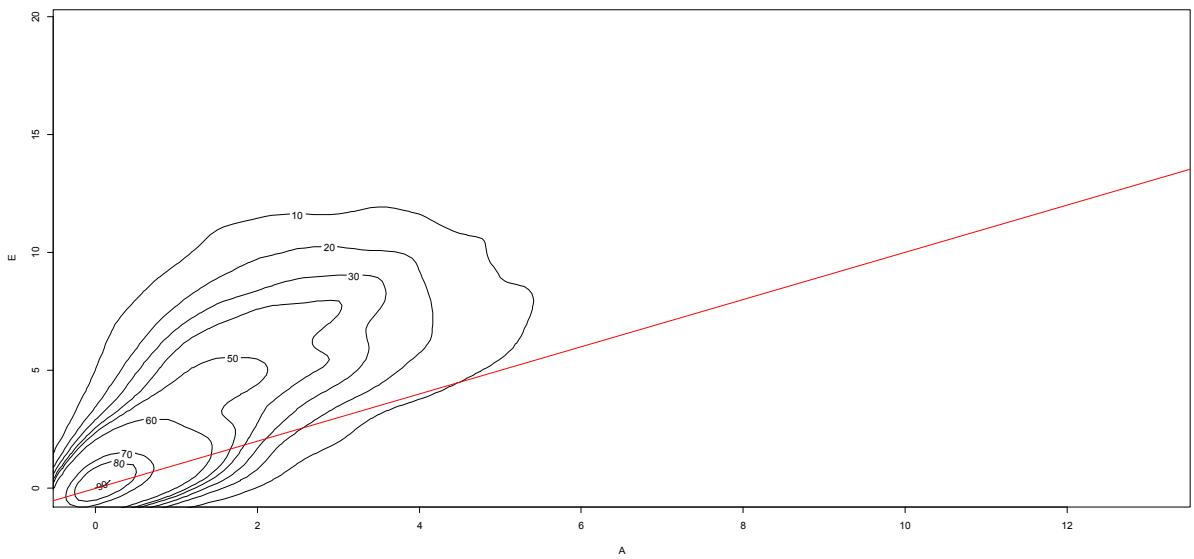
Tento odstavec sumarizuje dvourozměrné hustoty pravděpodobnosti, jádrově vyhlazené (s gaussovským jádrem).

3.9.1 Různá ramena

Obrázek 47 a Obrázek 48 ukazují dvourozměrné, jádrově vyhlazené (s gaussovským jádrem) hustoty intenzit pro vybrané páry ramen křížovatky 5.495, Dstop zobrazené jako kontoury (v % maximální hodnoty hustoty).



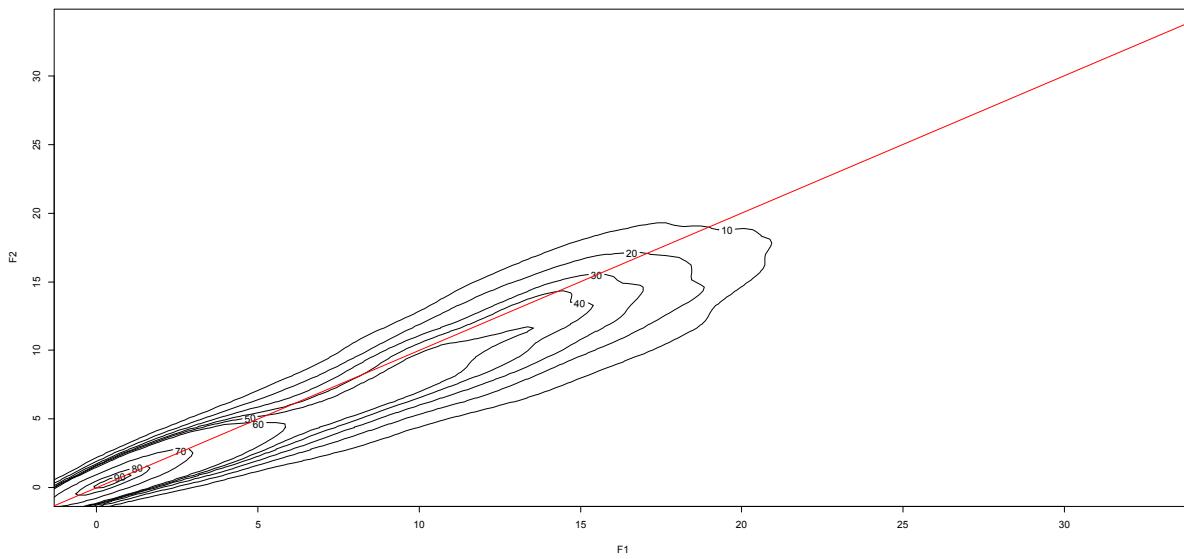
Obrázek 47: Jádrově vyhlazené kontury dvouozměrné hustoty pro ramena A, B detektor Dstop.



Obrázek 48: Jádrově vyhlazené kontury dvouozměrné hustoty pro ramena A, E detektor Dstop.

3.9.2 Fáze

Obrázek 49 ukazuje dvouozměrné rozdělení intenzit pro dvě fáze, detektory Dstop.

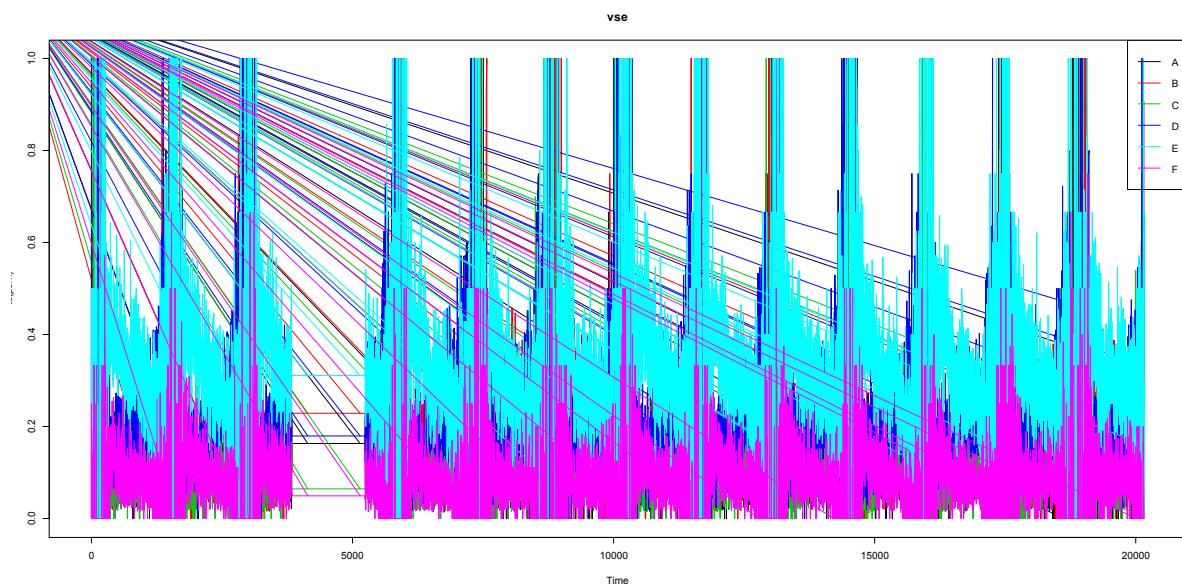


Obrázek 49: Dvourozměrné vyhlazení hustoty pro různé fáze, Dstop detektory

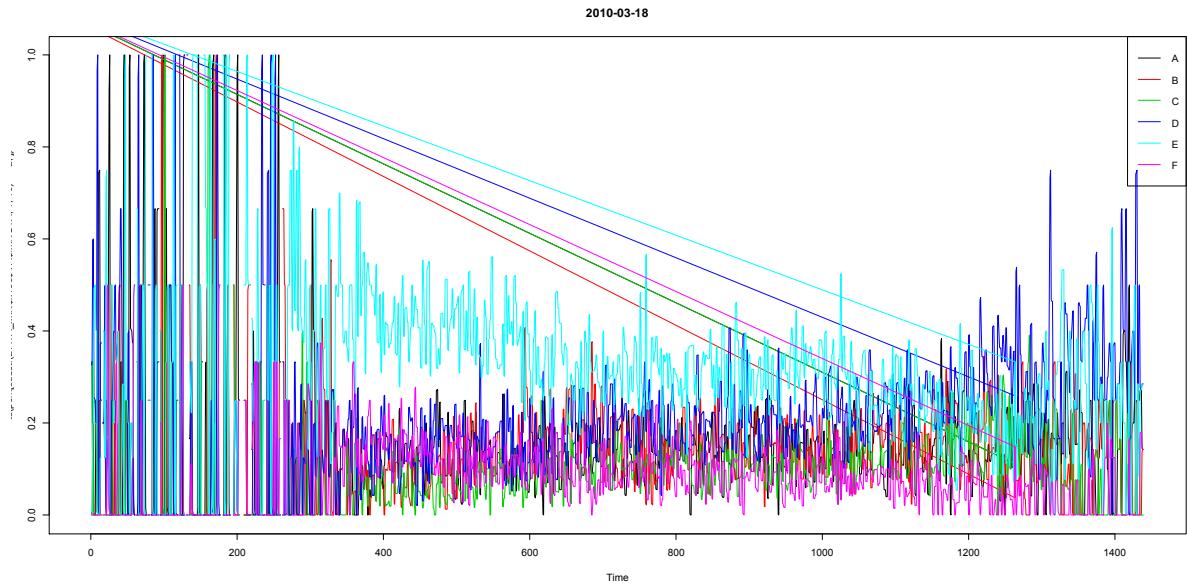
Jde to sice hodně pospolu, ale pro velké F1 je F1 větší než F2 (prostor pro řízení).

3.9.3 Časové řady poměrů a dalších odvozených ukazatelů

Obrázek 50 a Obrázek 51 ukazují časové řady zastoupení jednotlivých ramen křížovatky 495, Dstop detektory dle intenzity (v každé minutě je spočten podíl intenzity daného ramene a součtu intenzit všech ramen). Obrázek 50 ukazuje dostupná data. Obrázek 51 pak pro lepší vykreslení detailů jen jeden vzorový den (18.3.).



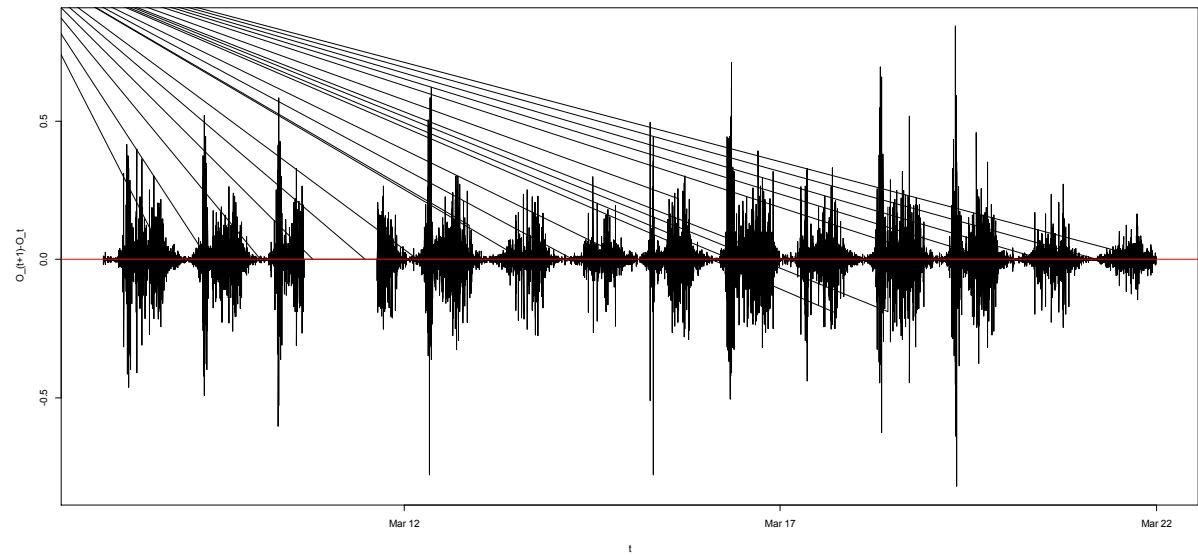
Obrázek 50: Časové řady podílů intenzit jednotlivých směrů.



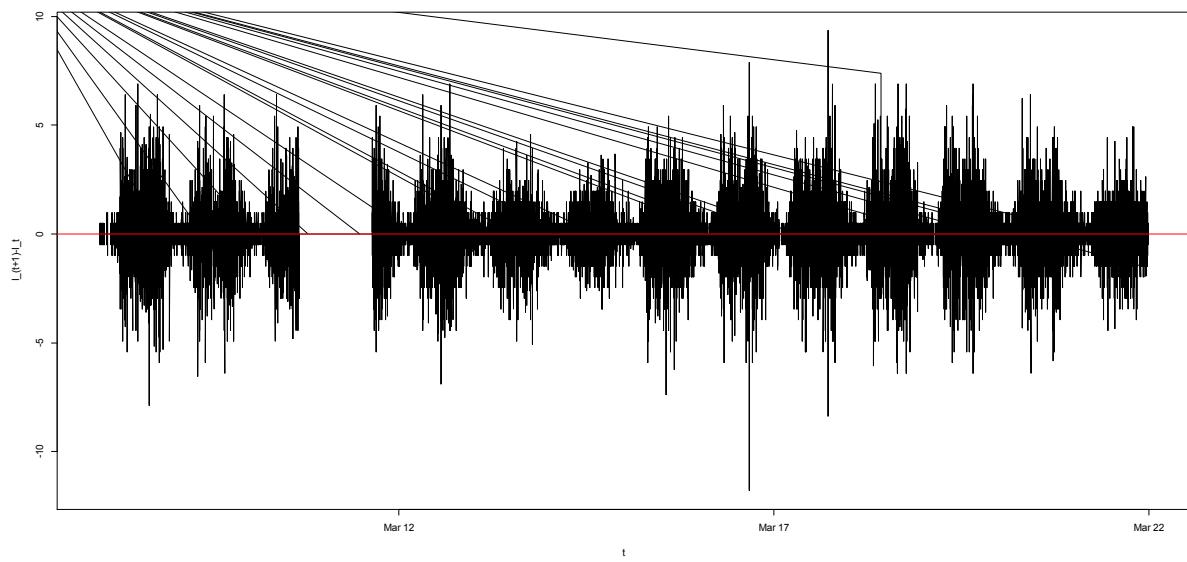
Obrázek 51: Časové řady podílů intenzit jednotlivých směrů, jen 18.3.

3.9.4 První diference

Obrázek 52 ukazuje časovou řadu prvníc diferencí (mezi-minutových rozdílů) obsazenosti z Dstop detektoru. Obrázek 53 pak řadu diferencí pro intenzitu.

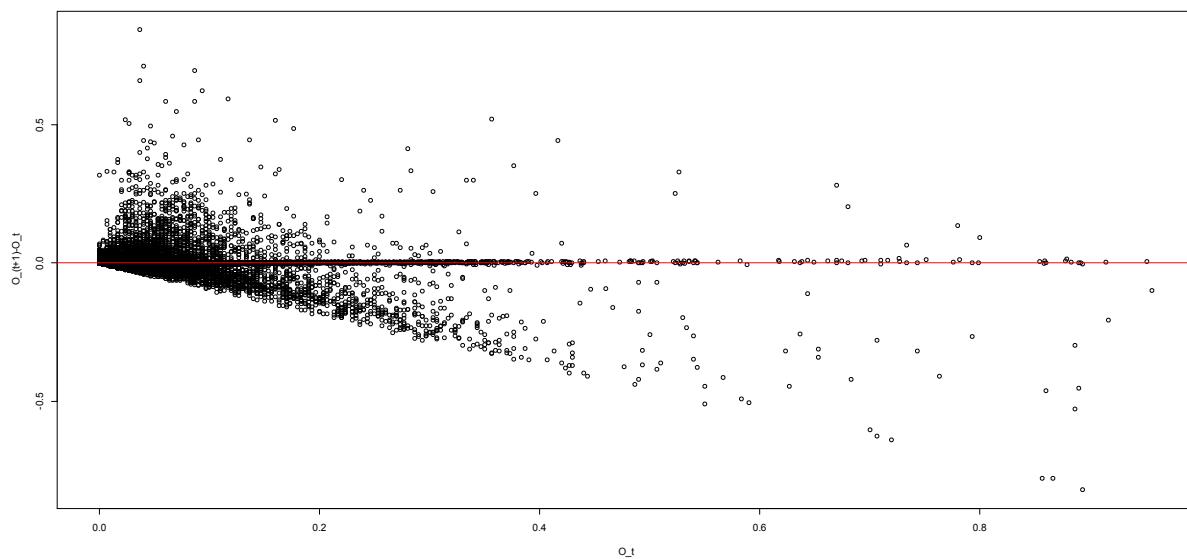


Obrázek 52: Časová řada prvních diferencí obsazenosti.

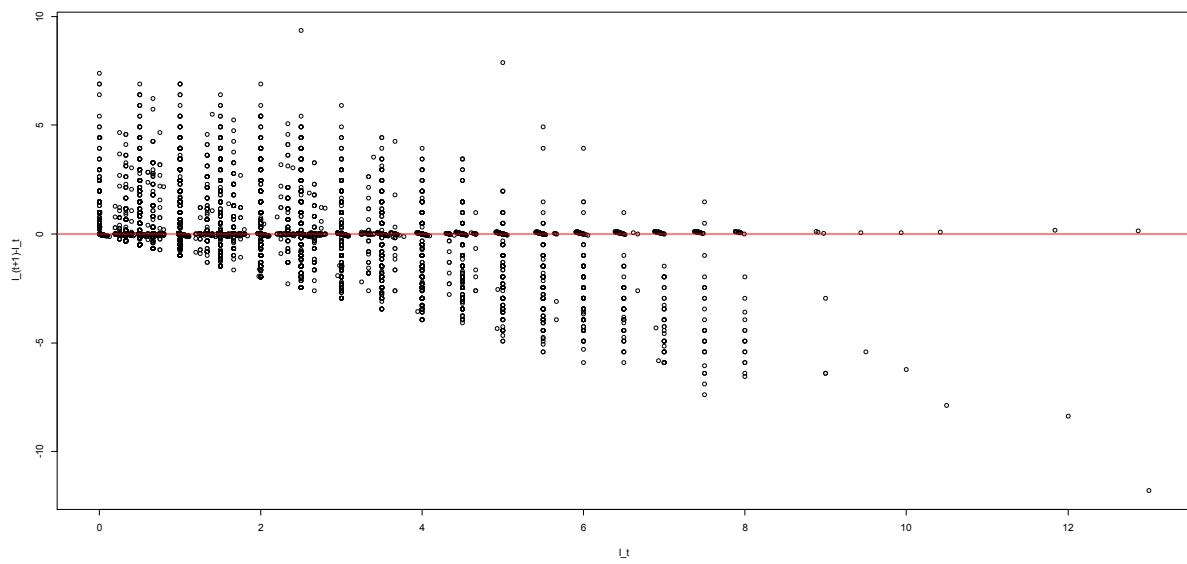


Obrázek 53: Časová řada prvních diferencí intenzity.

Obrázek 54 ukazuje vztah mezi první differencí obsazenosti a obsazeností samotnou (Dstop detektor), Obrázek 55 pak totéž pro intenzitu.

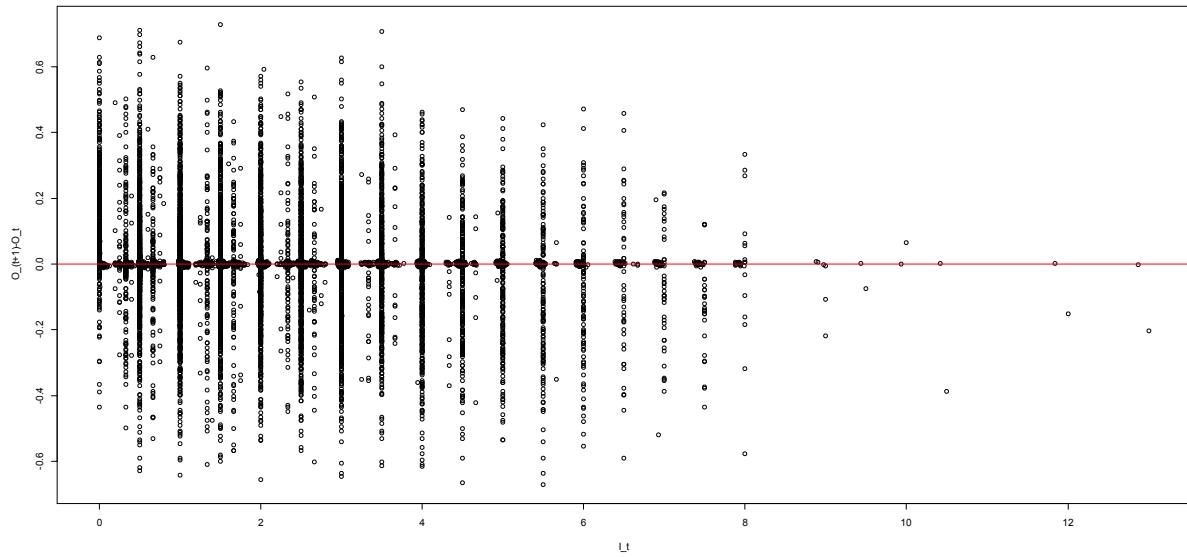


Obrázek 54: Obsazenost a první differenčia obsazenosti.

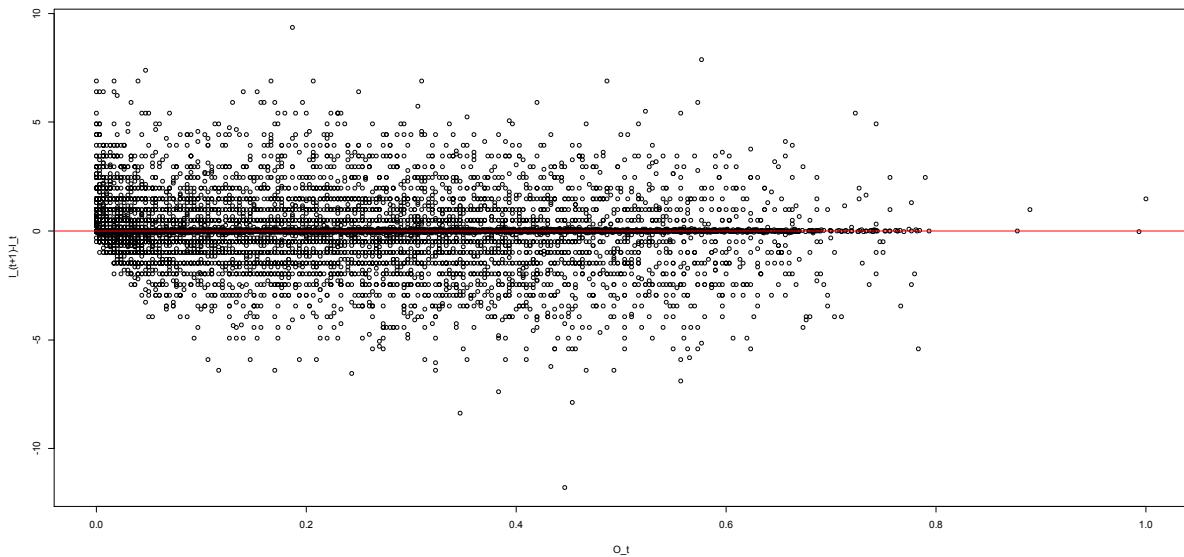


Obrázek 55: Intenzita a první difference intenzity.

Obrázek 56 ukazuje difference obsazenosti proti intenzitě, na Dstop detektoru. Obrázek 57 pak naopak difference intenzit proti obsazenosti.



Obrázek 56: Diference obsazenosti versus intenzita.



Obrázek 57: Diference intenzity versus obsazenost.

Zajímavý je drobný pohyb u diferencí intenzit okolo nuly (daný asi nestejnými délками intervalů a/nebo nesouladem světelného cyklu s průměrovanou minutou měření).

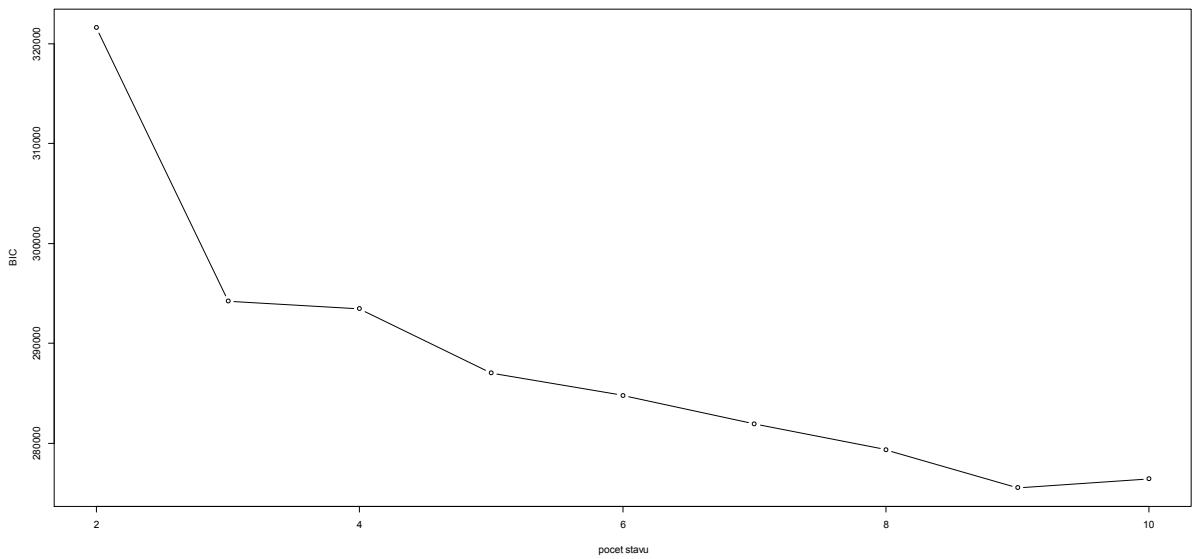
3.10 Hidden Markov chain modely pro Dstop intenzitu z různých ramen též křížovatky

Pozorované rozdělení (za daného diskrétního stavu) bereme jako vícerozměrné normální (s dimenzi danou počtem ramen dané křížovatky). Počet stavů optimalizujeme dle BIC či bereme na základě požadavku interpretovatelnosti (většinou spíše nižší počet stavů).

3.10.1 Křížovatka 5.495

Pozorované rozdělení je 6-rozměrné Gaussovské.

Hledání optima počtu stavů dle BIC ukazuje Obrázek 58.



Obrázek 58: BIC dle počtu stavů v Hidden Markov chain modelu.

Lokální minimum je pro 9.

Další volba by mohla být 3 (nebo 4).

3.10.1.1 Dimenze stavu 9

Výpis:

Call:

```
HMMFit(obs = pom, dis = "NORMAL", nStates = 9, asymptCov = F, control = list(verbose = 1, init = "KMEANS", tol = 0.01))
```

Model:

9 states HMM with 6-d gaussian distribution

Baum-Welch algorithm status:

Number of iterations : 3

Last relative variation of LLH function: 0.008910

Estimation:

Initial probabilities:

Pi 1 Pi 2 Pi 3 Pi 4 Pi 5 Pi 6

3.213514e-85 5.747056e-77 9.944269e-70 5.367754e-66 8.916956e-58 2.462505e-40

Pi 7 Pi 8 Pi 9

5.417177e-37 7.687351e-14 1

Transition matrix:

State 1 State 2 State 3 State 4 State 5

State 1 0.6981449373 0.0280133610 0.058216249 0.050844174 0.0510967073

State 2 0.0426798381 0.7836393483 0.096863367 0.014892205 0.0359118575

State 3 0.0409605453 0.0675956671 0.701141554 0.016199026 0.0736279593

State 4 0.1497967460 0.0420212726 0.019557163 0.687952854 0.0214641857

State 5 0.0688679382 0.0427809229 0.068000629 0.013338906 0.6927161620

State 6 0.0690609208 0.0147719376 0.030460006 0.029110342 0.0392331496

State 7 0.0236903008 0.0145844583 0.055682619 0.004625992 0.0284376195

State 8 0.0029636716 0.0008101456 0.001113329 0.001098254 0.0003081911

State 9 0.0001799487 0.0000000000 0.0000000000 0.0000000000 0.0000000000

State 6 State 7 State 8 State 9

State 1 7.965122e-02 3.021664e-02 3.816707e-03 0.0000000000

State 2 9.465004e-03 1.583541e-02 2.188811e-05 0.0006910861

State 3 3.248530e-02 6.528912e-02 2.700828e-03 0.0000000000

State 4 7.114615e-02 4.477166e-03 3.584467e-03 0.0000000000

State 5 5.908335e-02 5.290172e-02 2.310368e-03 0.0000000000

State 6 7.505212e-01 3.986711e-02 2.647280e-02 0.0005025661

State 7 3.551151e-02 7.798429e-01 5.758821e-02 0.0000363969

State 8 1.618681e-02 2.588970e-02 8.810665e-01 0.0705633834

State 9 1.302043e-08 1.613972e-08 4.777788e-02 0.9520421383

Conditionnal distribution parameters:

Distribution parameters:

State 1

mean cov matrix

2.809233 1.43334393 0.22468725 0.05055396 0.059672784 -0.21073265

2.899009 0.22468725 1.86221161 0.14781445 0.032841383 0.03723631

1.944823 0.05055396 0.14781445 0.93889400 0.017323756 -0.02589730

3.824210 0.05967278 0.03284138 0.01732376 1.648530439 -0.02169701

8.691169 -0.21073265 0.03723631 -0.02589730 -0.021697012 1.67243785

2.758604 0.06222508 -0.18807250 0.01691771 0.003066348 -0.21789659

0.062225076

-0.188072498

0.016917712

0.003066348

-0.217896590

1.391264451

State 2

mean cov matrix

4.186277 3.18309342 0.6656194 -0.237302658 -0.7687968 -0.614277005

4.908152 0.66561942 3.9729102 0.229441001 -0.1476736 -0.431647667

3.348716 -0.23730266 0.2294410 1.923813181 0.2075167 0.004236622
6.509841 -0.76879677 -0.1476736 0.207516685 3.6571578 -0.320545350
9.646729 -0.61427701 -0.4316477 0.004236622 -0.3205453 3.464250958
2.658427 0.01601068 -0.1106501 -0.070960315 -0.2116160 0.281111398

0.01601068

-0.11065009

-0.07096031

-0.21161605

0.28111140

1.10527033

State 3

mean cov matrix

3.212379 2.21084876 0.12869055 -0.09778348 -0.51980484 -0.22650815
3.355636 0.12869055 1.66497414 0.03279697 0.33312620 -0.24391698
2.857157 -0.09778348 0.03279697 1.54120194 0.10356270 0.07103528
5.691365 -0.51980484 0.33312620 0.10356270 2.72516349 -0.18703680
5.930541 -0.22650815 -0.24391698 0.07103528 -0.18703680 1.84618824
1.748984 -0.04330497 -0.01498633 0.05859237 -0.06787907 0.12732491

-0.04330497

-0.01498633

0.05859237

-0.06787907

0.12732491

0.77590875

State 4

mean cov matrix

3.125829 2.50759661 0.15449158 -0.005555070 0.20862836 0.05243956

3.077528 0.15449158 2.53747191 0.080331566 0.08895658 -0.39106873

1.745389 -0.00555507 0.08033157 0.963978373 0.29660607 0.42564911

4.097690 0.20862836 0.08895658 0.296606068 2.83157983 0.55541604

12.850786 0.05243956 -0.39106873 0.425649111 0.55541604 5.50109038

3.936133 0.47982329 -0.43105265 0.001691982 0.10364121 0.54090147

0.479823292

-0.431052652

0.001691982

0.103641215

0.540901470

2.778880828

State 5

mean cov matrix

2.553473 1.71295698 0.25506157 -0.07349708 0.1210253 0.14548825

5.999618 0.25506157 2.40944772 -0.13845994 0.7265134 0.09400206

2.829020 -0.07349708 -0.13845994 1.82040645 0.2621678 -0.07390663

4.082904 0.12102525 0.72651339 0.26216775 2.2819241 -0.43207074

6.399151 0.14548825 0.09400206 -0.07390663 -0.4320707 3.47034003

1.762884 0.02135385 -0.14943715 -0.05565748 -0.2771860 0.56768206

0.02135385

-0.14943715

-0.05565748

-0.27718598

0.56768206

0.80144442

State 6

mean cov matrix

1.686641 0.88889699 0.1632717 0.02872925 0.133229708 0.09072580

2.085028 0.16327168 1.1680450 0.19351257 0.205561005 0.01579560

1.306072 0.02872925 0.1935126 0.57048474 0.172393478 0.09151578

2.376976 0.13322971 0.2055610 0.17239348 0.963769469 0.03176257

5.606404 0.09072580 0.0157956 0.09151578 0.031762569 1.68465335

1.696463 0.05988740 -0.1067929 -0.02541731 -0.008056881 0.20235870

0.059887404

-0.106792889

-0.025417310

-0.008056881

0.202358702

0.686502842

State 7

mean cov matrix

1.828976 1.02007753 0.13297489 -0.02710150 0.02212572 0.07797297

2.562534 0.13297489 1.73170877 -0.15633192 -0.10501644 0.41211616

2.219248 -0.02710150 -0.15633192 1.06498721 0.01381105 0.06328763

3.553558 0.02212572 -0.10501644 0.01381105 1.68659389 0.03358834

3.298536 0.07797297 0.41211616 0.06328763 0.03358834 1.61587643

0.920755 -0.02346569 0.06934267 0.04472389 0.00611523 0.26368998

-0.02346569

0.06934267

0.04472389

0.00611523

0.26368998

0.32509050

State 8

mean cov matrix

0.8096868 0.436102687 0.04035547 0.03200663 0.10282322 0.01166704

0.7214252 0.040355472 0.35728156 0.07015199 0.09954162 0.10265171

0.6213956 0.032006634 0.07015199 0.39638285 0.19658048 0.04718507

1.2211580 0.102823217 0.09954162 0.19658048 0.89049814 0.00765882

1.6317296 0.011667040 0.10265171 0.04718507 0.00765882 1.14396360

0.4357616 -0.008562372 0.02513554 0.01438895 -0.02465148 0.26089650

-0.008562372

0.025135541

0.014388949

-0.024651479

0.260896500

0.219647400

State 9

mean cov matrix

0.18434347 0.090096550 0.009150393 0.0042734752 0.014757440 0.017495722

0.12159538 0.009150393 0.054063607 0.0023891914 0.011121472 0.012199911

0.05400028 0.004273475 0.002389191 0.0213412319 0.008836135 0.004653836

0.17030340 0.014757440 0.011121472 0.0088361354 0.087939602 0.022793513

0.27900441 0.017495722 0.012199911 0.0046538361 0.022793513 0.147535054

0.04639440 0.003009005 0.002558224 -0.0009883778 0.001456954 0.020435551

0.0030090053

0.0025582243

-0.0009883778

0.0014569543

0.0204355507

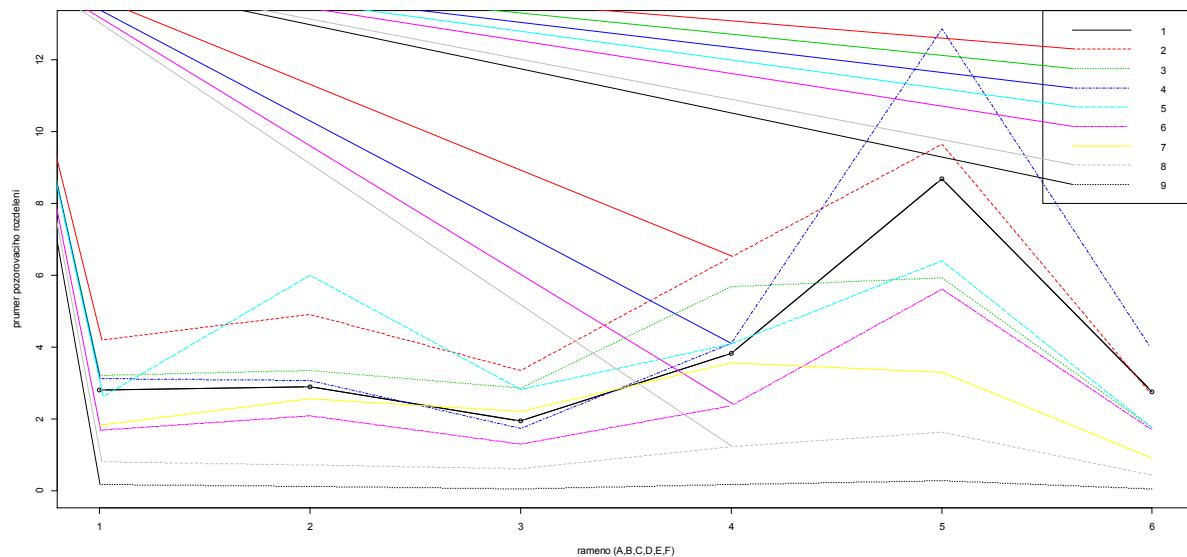
0.0189772835

Log-likelihood: -136169.9

BIC criterium: 275541.1

AIC criterium: 272985.8

Průměry pozorovacího rozdělení ukazuje Obrázek 59.



Obrázek 59: Průměry pozorovacího rozdělení dle stavů.

Přechodová matice:

[.1]	[.2]	[.3]	[.4]	[.5]	[.6]	[.7]	[.8]	[.9]
[1,] 0.70	0.03	0.06	0.05	0.05	0.08	0.03	0.00	0.00
[2,] 0.04	0.78	0.10	0.01	0.04	0.01	0.02	0.00	0.00
[3,] 0.04	0.07	0.70	0.02	0.07	0.03	0.07	0.00	0.00
[4,] 0.15	0.04	0.02	0.69	0.02	0.07	0.00	0.00	0.00
[5,] 0.07	0.04	0.07	0.01	0.69	0.06	0.05	0.00	0.00
[6,] 0.07	0.01	0.03	0.03	0.04	0.75	0.04	0.03	0.00
[7,] 0.02	0.01	0.06	0.00	0.03	0.04	0.78	0.06	0.00
[8,] 0.00	0.00	0.00	0.00	0.00	0.02	0.03	0.88	0.07
[9,] 0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.05	0.95

9: 8

8: 9, 7

7: 8, 3, 6

6: 1, 7, 5

5: 1, 3, 6

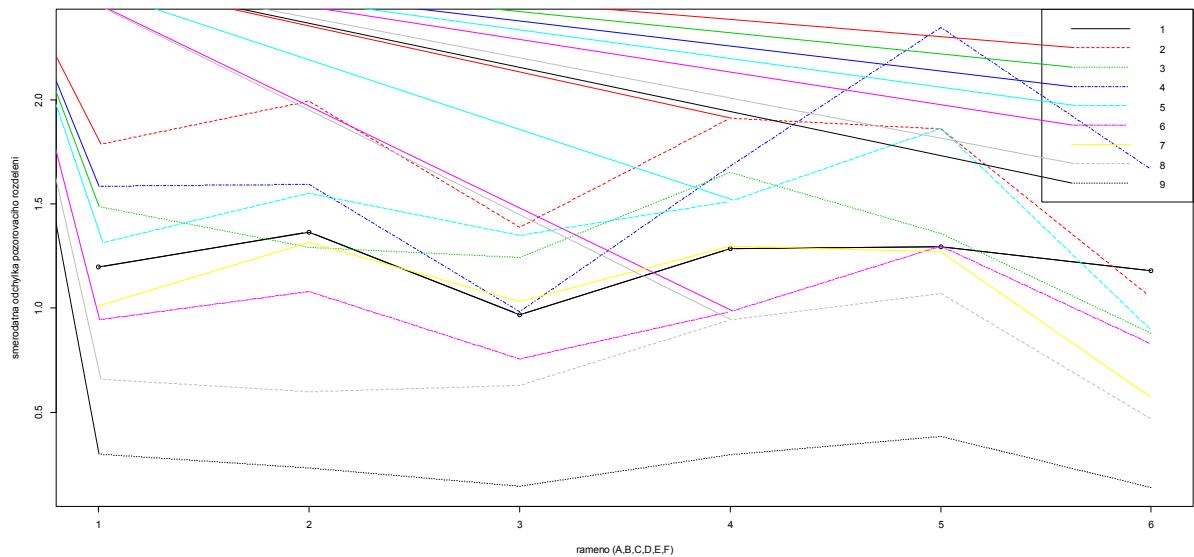
4: 1, 6

3: 2, 5, 7

2: 3, 2, 5

1: 6, 3, 4, 5

Obrázek 60 ukazuje směrodatné odchylky pozorovacího rozdělení, dle stavů.



Obrázek 60: směrodatné odchylky pozorovacího rozdělení dle stavů.

Určitě je tu (pozitivní) vztah mezi variabilitou a průměrem.

3.10.1.2 Dimenze stavu 4

Výpis:

Call:

```
HMMFit(obs = pom, dis = "NORMAL", nStates = 4, asymptCov = F, control = list(verbose = 1, init = "KMEANS", tol = 0.01))
```

Model:

4 states HMM with 6-d gaussian distribution

Baum-Welch algorithm status:

Number of iterations : 5

Last relative variation of LLH function: 0.009580

Estimation:

Initial probabilities:

Pi 1	Pi 2	Pi 3	Pi 4
1.784527e-63	4.63468e-61	4.767599e-29	1

Transition matrix:

State 1	State 2	State 3	State 4	
State 1	0.8442645640	1.063951e-01	0.04934028	1.197090e-08
State 2	0.0643187408	8.908817e-01	0.04459747	2.020887e-04
State 3	0.0336711268	3.952676e-02	0.88101654	4.578557e-02
State 4	0.0003282132	1.683601e-06	0.03746225	9.622079e-01

Conditionnal distribution parameters:

Distribution parameters:

State 1

mean cov matrix

2.940134	2.1442644	0.49938820	0.1282502	0.5071145	0.4368905	0.31611630
2.918869	0.4993882	2.23442134	0.2456359	0.4080783	0.6333527	-0.04290967
1.815023	0.1282502	0.24563593	0.9591725	0.3993866	0.4201382	0.10888892
3.938954	0.5071145	0.40807834	0.3993866	2.8706212	1.1338276	0.24925939
9.342993	0.4368905	0.63335275	0.4201382	1.1338276	7.8566742	1.24605368
2.952359	0.3161163	-0.04290967	0.1088889	0.2492594	1.2460537	2.01276741

State 2

mean cov matrix

3.027939 2.5856070 0.39097429 0.16844177 0.5165112 0.8522595 0.2427884
4.451031 0.3909743 3.72367005 0.07823998 0.1576186 0.7764782 0.1531910
2.945969 0.1684418 0.07823998 1.77798478 0.5051285 0.6195800 0.1668632
5.071535 0.5165112 0.15761861 0.50512854 3.9895905 1.0380637 0.2275239
6.579578 0.8522595 0.77647821 0.61957998 1.0380637 5.2003629 1.0213845
1.831413 0.2427884 0.15319099 0.16686324 0.2275239 1.0213845 0.9249051

State 3

mean cov matrix

1.2025665 0.72663999 0.2479741 0.19436056 0.3511719 0.3353069 0.06053828
1.3633961 0.24797408 1.0374132 0.31264302 0.5291802 0.7075418 0.16342510
1.1628647 0.19436056 0.3126430 0.84144711 0.5893848 0.2996787 0.06888453
2.0639185 0.35117194 0.5291802 0.58938476 1.7781679 0.4868090 0.09940190
2.8619927 0.33530690 0.7075418 0.29967872 0.4868090 3.1298990 0.77706218
0.8089312 0.06053828 0.1634251 0.06888453 0.0994019 0.7770622 0.44965829

State 4

mean cov matrix

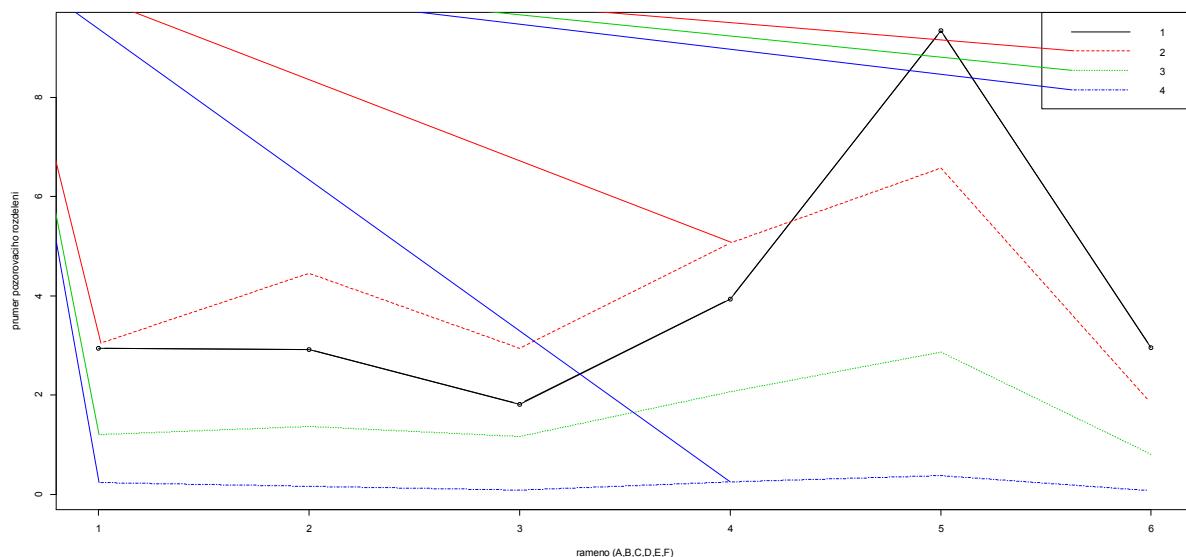
0.23622790 0.12688999 0.019206436 0.010321902 0.032402468 0.04155815 0.007428130
0.16151675 0.01920644 0.077130562 0.007318363 0.025850663 0.02874035 0.006058131
0.08083987 0.01032190 0.007318363 0.033938507 0.019852097 0.01558399 0.001278386
0.24446400 0.03240247 0.025850663 0.019852097 0.152645071 0.05637903 0.005971915
0.37465668 0.04155815 0.028740347 0.015583989 0.056379025 0.23729855 0.034207795
0.06586105 0.00742813 0.006058131 0.001278386 0.005971915 0.03420780 0.027794874

Log-likelihood: -146118.8

BIC criterium: 293456.8

AIC criterium: 292483.7

Průměry pozorovacího rozdělení ukazuje Obrázek 61.



Obrázek 61: Průměry pozorovacího rozdělení

4 – noc, 3 – od Rudné do Řevnické, 2 - ze staré Plzeňské (obou směrů) do Řevnické + z Řevnické na Rudnou, 1 – ze staré Plzeňské (obou směrů) do Řevnické (ale výraznější příjezd od Rudné) + průjezd po Plzeňské od města do Rudné

Přechodová matice:

```
[.1]  [.2]  [.3]  [.4]  
[1,] 0.84 0.11 0.05 0.00  
[2,] 0.06 0.89 0.04 0.00  
[3,] 0.03 0.04 0.88 0.05  
[4,] 0.00 0.00 0.04 0.96
```

3.10.1.3 Dimenze stavu 3

Výpis:

Call:

```
HMMFit(obs = pom, dis = "NORMAL", nStates = 3, asymptCov = F, control = list(verbose = 1, initPoint = start, tol = 0.01))
```

Model:

3 states HMM with 6-d gaussian distribution

Baum-Welch algorithm status:

Number of iterations : 4

Last relative variation of LLH function: 0.004184

Estimation:

Initial probabilities:

Pi 1 Pi 2 Pi 3

1.623363e-30 1.703427e-10 1

Transition matrix:

State 1 State 2 State 3

State 1 0.9790975564 0.02069524 0.0002071994

State 2 0.0495385415 0.88680323 0.0636582286

State 3 0.0001912768 0.04971328 0.9500954399

Conditionnal distribution parameters:

Distribution parameters:

State 1

mean cov matrix

2.751821 2.3754252 0.7117515 0.30476933 0.7850691 1.1559346 0.39647249

3.543806 0.7117515 3.6404710 0.64687496 0.9857483 0.6016883 -0.02014750

2.361523 0.3047693 0.6468750 1.69304019 0.8820980 0.1429150 -0.03373434

4.318703 0.7850691 0.9857483 0.88209803 3.8669954 1.0130197 0.17643136

7.036118 1.1559346 0.6016883 0.14291501 1.0130197 8.7925843 2.15305177

2.073317 0.3964725 -0.0201475 -0.03373434 0.1764314 2.1530518 1.60349586

State 2

mean cov matrix

0.8597984 0.4583949554 0.06161100 0.06775505 0.15337482 0.06498607 0.0002345732

0.8081400 0.0616110032 0.42275226 0.12261557 0.19365074 0.19806974 0.0499472114

0.7214710 0.0677550485 0.12261557 0.50035865 0.33388964 0.12887059 0.0372784002

1.3885426 0.1533748234 0.19365074 0.33388964 1.15424858 0.16365400 0.0252999240

1.8352011 0.0649860724 0.19806974 0.12887059 0.16365400 1.53060004 0.3871414618

0.5038687 0.0002345732 0.04994721 0.03727840 0.02529992 0.38714146 0.2693748066

State 3

mean cov matrix

0.18115894 0.086794428 0.008376062 0.004135159 0.015060283 0.017588116 0.002641085

0.11952728 0.008376062 0.052454918 0.002315218 0.011373272 0.012194362 0.002148614

0.05412715 0.004135159 0.002315218 0.021384902 0.009191393 0.005007905 -0.001013772

0.17195384 0.015060283 0.011373272 0.009191393 0.089399071 0.024377737 0.001342977

0.28070491 0.017588116 0.012194362 0.005007905 0.024377737 0.149593927 0.019966107

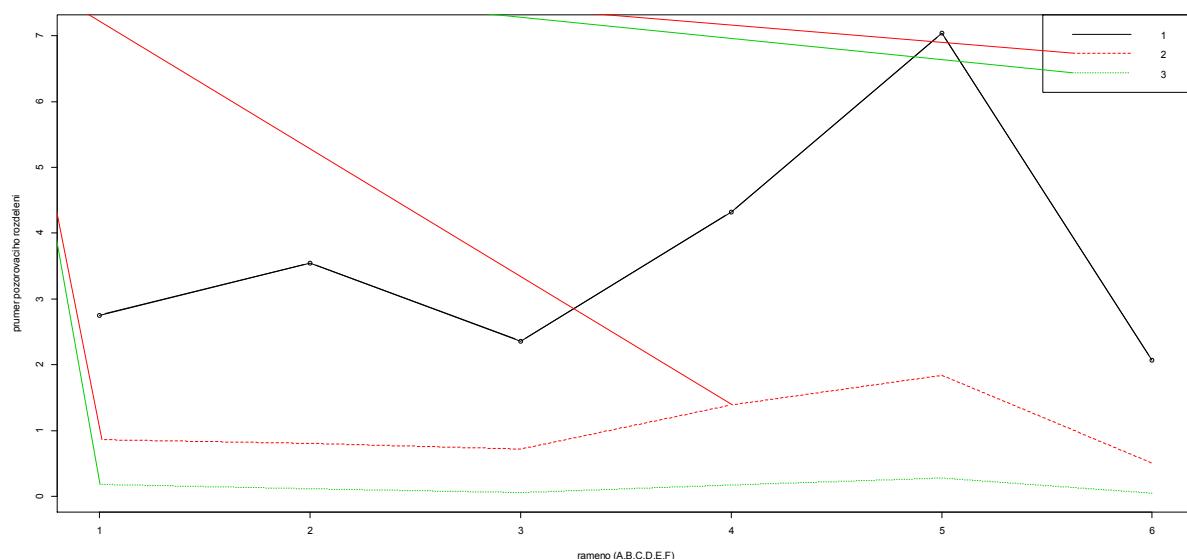
0.04529468 0.002641085 0.002148614 -0.001013772 0.001342977 0.019966107 0.018493757

Log-likelihood: -146672.8

BIC criterium: 294227.7

AIC criterium: 293523.6

Průměry pozorovacího rozdělení dle Markovovských stavů ukazuje Obrázek 62.



Obrázek 62: Průměry pozorovacího rozdělení dle stavů.

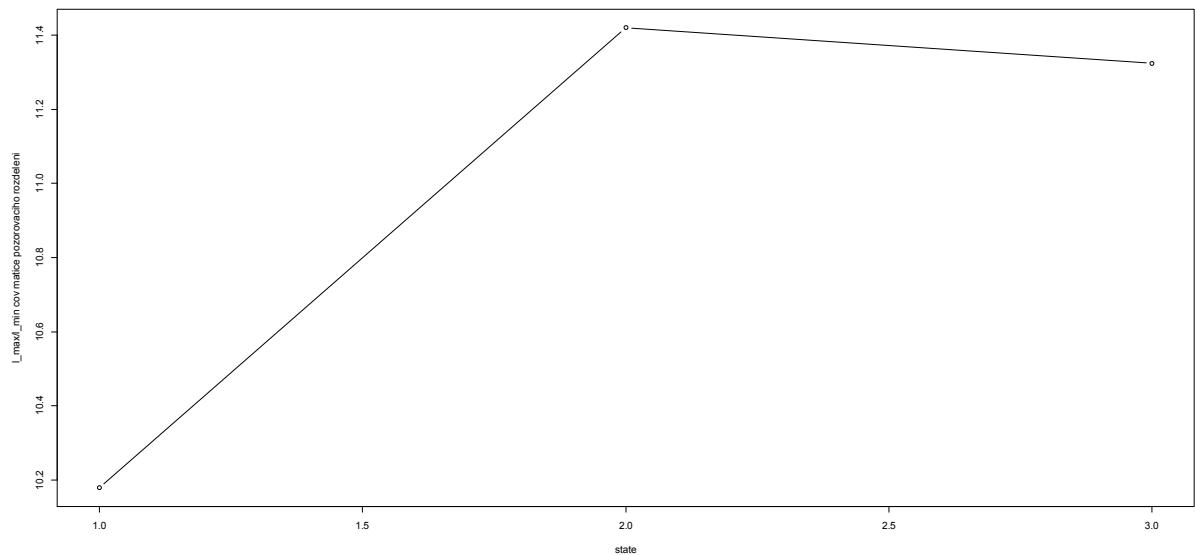
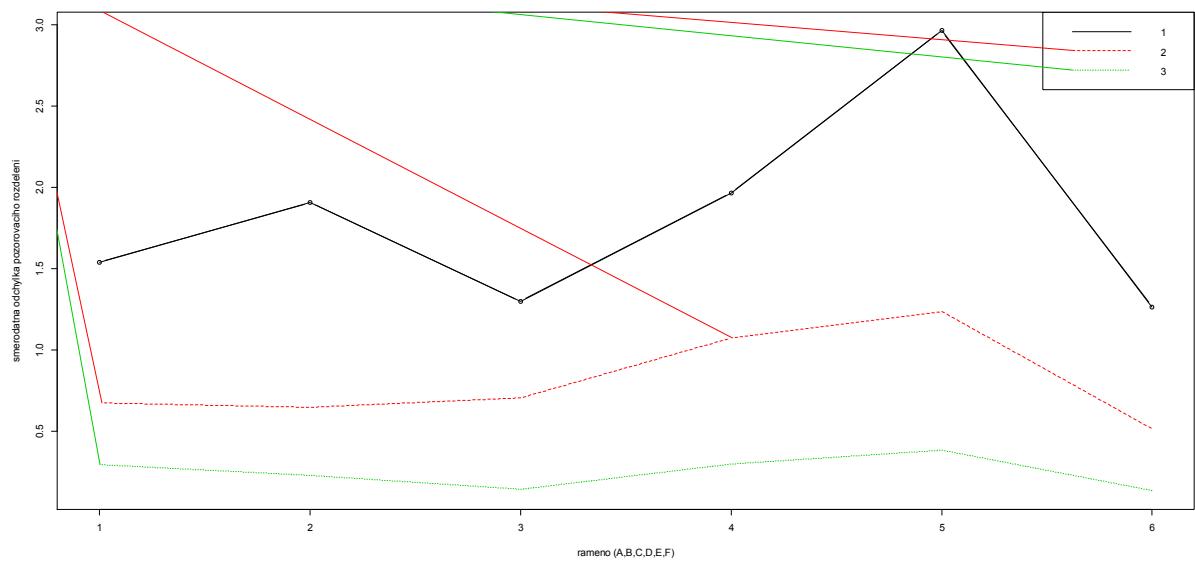
Přechodová matice:

[,1] [,2] [,3]

[1,] 0.98 0.02 0.00

[2,] 0.05 0.89 0.06

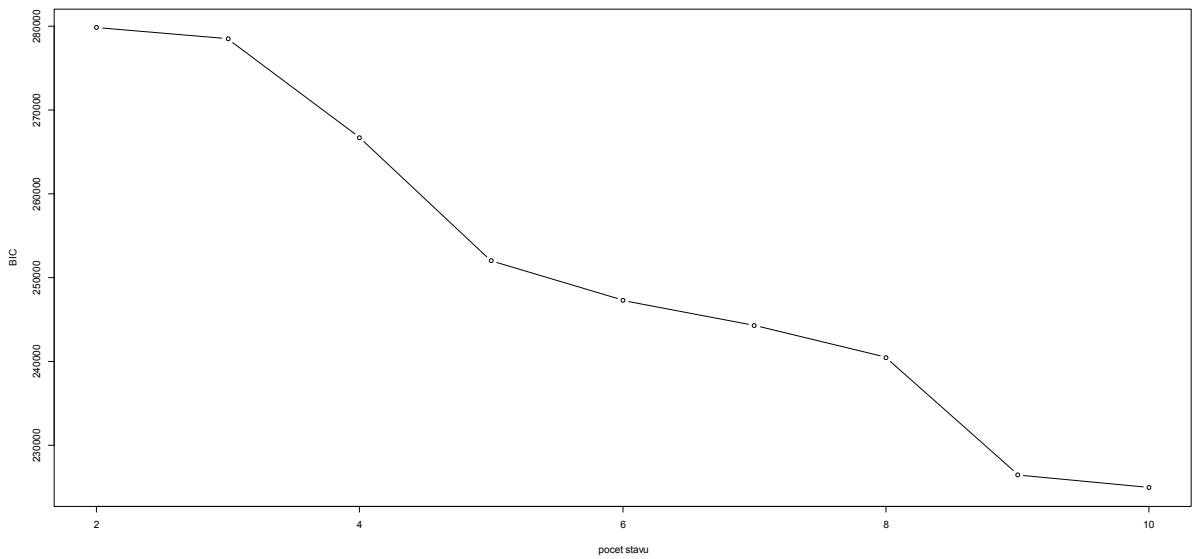
[3,] 0.00 0.05 0.95



3.10.2 Křížovatka 5.601

Pozorované rozdělení je 8-rozměrné Gaussovské.

BIC volba počtu stavů, viz Obrázek 63.



Obrázek 63: BIC a počet stavů.

Nemá to lokální minimum.

Možné volby jsou např. 3, 5 nebo 9.

3.10.2.1 Dimenze stavu 9

Výpis:

Call:

```
HMMFit(obs = pom, dis = "NORMAL", nStates = 9, asymptCov = F, control = list(verbose = 1, init = "KMEANS", tol = 0.1))
```

Model:

9 states HMM with 8-d gaussian distribution

Baum-Welch algorithm status:

Number of iterations : 1

Last relative variation of LLH function: 0.057815

Estimation:

Initial probabilities:

Pi 1	Pi 2	Pi 3	Pi 4	Pi 5	Pi 6	Pi 7	Pi 8	Pi 9
6.353409e-33	6.931395e-32	8.206975e-27	4.100541e-26	4.649457e-26	1.152041e-13	1.885712e-13	4.365121e-08	1

Transition matrix:

	State 1	State 2	State 3	State 4	State 5	State 6	State 7	State 8	State 9
State 1	0.762635673	0.0783792907	0.0626950594	0.011956474	0.0290926224	0.0438781425	0.0002645949	0.011098142	0.0000000000
State 2	0.127330599	0.6966621772	0.0578475177	0.005958077	0.0527957525	0.0533372802	0.0013614529	0.004707143	0.0000000000
State 3	0.066064320	0.0339666685	0.7434025382	0.050251840	0.0310885982	0.0466502490	0.0171981168	0.011377669	0.0000000000
State 4	0.018536086	0.0032823694	0.0625806841	0.752245694	0.0030476498	0.0188173810	0.1238986407	0.017591495	0.0000000000
State 5	0.044216815	0.0604786399	0.0271429867	0.001410823	0.7373465128	0.1125189244	0.0002777514	0.016607547	0.0000000000
State 6	0.032295108	0.0228923980	0.0376759324	0.002624739	0.0538304897	0.8101677548	0.0018861031	0.037619863	0.0010076120
State 7	0.002242825	0.0002365281	0.0347990353	0.079662095	0.0006414719	0.0056112512	0.8284385825	0.048213223	0.0001549879
State 8	0.003596754	0.0010434938	0.0097757474	0.004200100	0.0061745449	0.0245888069	0.0236449087	0.855030378	0.0719452654
State 9	0.0000000000	0.0000000000	0.0001862207	0.0000000000	0.0000000000	0.0003335354	0.0002468255	0.034073473	0.9651599458

Conditionnal distribution parameters:

Distribution parameters:

State 1

mean cov matrix

7.1559239 2.918220308 1.20920369 0.001944567 0.06464692 -0.430855611 -0.247128380 -0.068769782 0.002487191
4.4385018 1.209203695 2.40882690 -0.022347824 0.03261892 -0.201932497 0.201313724 0.058972755 0.072679339
0.8319868 0.001944567 -0.02234782 0.389899266 0.10586002 -0.050860421 -0.003769778 0.020185189 0.018528256
1.7171112 0.064646918 0.03261892 0.105860024 0.76469622 0.129372642 -0.033010689 0.080939238 0.046135502
7.6227190 -0.430855611 -0.20193250 -0.050860421 0.12937264 3.697296701 0.813393204 -0.126170567 -0.006433051
5.4078764 -0.247128380 0.20131372 -0.003769778 -0.03301069 0.813393204 3.428867207 0.074234179 0.247049730
2.8418826 -0.068769782 0.05897276 0.020185189 0.08093924 -0.126170567 0.074234179 1.188331360 0.005479361
6.7714365 0.002487191 0.07267934 0.018528256 0.04613550 -0.006433051 0.247049730 0.005479361 2.651430300

State 2

mean cov matrix

5.5878753 2.706150778 1.03375930 -0.02529038 0.08905418 0.12745197 -0.002464743 -0.23585204 0.02580861
3.5980435 1.033759298 2.19242207 0.06384109 0.07723052 0.04689012 0.317563283 -0.36076216 -0.15211942
0.4450063 -0.025290376 0.06384109 0.21936901 0.02841895 0.18254181 -0.064949049 0.08255948 0.04668170
1.1391240 0.089054184 0.07723052 0.02841895 0.46194782 0.22768255 -0.115595127 0.05318024 0.01303729
5.4355643 0.127451973 0.04689012 0.18254181 0.22768255 2.85247194 0.020971680 0.19171014 0.61186923
8.5820246 -0.002464743 0.31756328 -0.06494905 -0.11559513 0.02097168 4.915836446 -0.44055106 -0.19713303
3.1729716 -0.235852041 -0.36076216 0.08255948 0.05318024 0.19171014 -0.440551064 2.75863785 0.02655243
9.4724726 0.025808609 -0.15211942 0.04668170 0.01303729 0.61186923 -0.197133032 0.02655243 4.73272670

State 3

mean cov matrix

5.5226096 2.00351656 0.793490450 -0.02909059 0.014937460 -0.15147876 0.09161734 -0.02723350 0.012789228
3.4099053 0.79349045 1.679235446 0.05599988 -0.006728554 0.03292845 0.34147578 -0.02061704 0.001296939

0.4682755 -0.02909059 0.055999881 0.19639659 0.073181354 0.05957334 -0.05780590 0.04057065 -0.011605194
 1.1746435 0.01493746 -0.006728554 0.07318135 0.527383542 0.10581323 -0.06388142 0.07153978 0.074198214
 4.9135022 -0.15147876 0.032928452 0.05957334 0.105813232 2.35885886 0.14761673 0.18490689 0.041210786
 6.1216726 0.09161734 0.341475784 -0.05780590 -0.063881417 0.14761673 3.91248180 -0.17939683 -0.374960405
 2.1020859 -0.02723350 -0.020617044 0.04057065 0.071539780 0.18490689 -0.17939683 0.98463098 0.524817007
 4.3942339 0.01278923 0.001296939 -0.01160519 0.074198214 0.04121079 -0.37496041 0.52481701 2.308314553

State 4

mean cov matrix

7.2752146 3.01891892 0.95198824 -0.0890715421 0.07094168 -0.12881219 -0.07124739 -0.0334578363 -0.10407267
 4.9483767 0.95198824 2.33378417 -0.0610991354 -0.01988305 0.07127837 -0.01226705 -0.0812716728 0.03856728
 0.6574085 -0.08907154 -0.06109914 0.3455329473 0.06921365 0.09700077 -0.18027733 0.0005797406 -0.02087338
 1.4859322 0.07094168 -0.01988305 0.0692136518 0.78963027 0.01099011 -0.13973285 -0.0305611924 -0.08403223
 6.0071702 -0.12881219 0.07127837 0.0970007656 0.01099011 4.01865030 -0.69334613 -0.1089542543 -0.34303264
 3.1431191 -0.07124739 -0.01226705 -0.1802773328 -0.13973285 -0.69334613 2.91590213 0.1401038946 0.29881496
 0.9973786 -0.03345784 -0.08127167 0.0005797406 -0.03056119 -0.10895425 0.14010389 0.5732331021 0.54202032
 1.8026770 -0.10407267 0.03856728 -0.0208733790 -0.08403223 -0.34303264 0.29881496 0.5420203224 1.59734464

State 5

mean cov matrix

3.6420268 2.41716508 0.5990203 0.021453574 0.15145200 0.622415337 0.71954998 0.042961099 -0.5321654
 2.2662431 0.59902032 1.9619986 0.231099581 0.14734236 0.496055287 0.48108295 -0.110882518 -0.4113502
 0.5005947 0.02145357 0.2310996 0.275158187 0.07415931 0.203011503 0.08598268 -0.006440179 -0.1081985
 1.1519355 0.15145200 0.1473424 0.074159313 0.50264358 0.294467980 0.14952361 0.010555509 -0.1452135
 4.3912160 0.62241534 0.4960553 0.203011503 0.29446798 2.855155141 0.56460039 -0.002382079 -0.5659644
 3.7512921 0.71954998 0.4810829 0.085982684 0.14952361 0.564600387 2.93703091 -0.151559811 -0.2019427
 3.1069119 0.04296110 -0.1108825 -0.006440179 0.01055551 -0.002382079 -0.15155981 1.333508663 0.0398843
 7.6895125 -0.53216536 -0.4113502 -0.108198520 -0.14521350 -0.565964365 -0.20194269 0.039884301 3.5397784

State 6

mean cov matrix

2.5633897 1.24092993 0.48693520 0.033517687 0.08342815 0.36946300 0.477941297 -0.08013651 -0.18466945
1.4397012 0.48693520 0.67800846 0.018467976 0.05618480 0.25138236 0.413363894 -0.06566371 -0.21964351
0.2836903 0.03351769 0.01846798 0.100136257 0.02742069 0.05383849 -0.001402707 0.02639345 -0.01058417
0.7794925 0.08342815 0.05618480 0.027420686 0.27736030 0.14165176 -0.056401642 0.09420602 0.04614128
2.7512125 0.36946300 0.25138236 0.053838486 0.14165176 1.31960243 0.315087317 0.10489179 0.01246170
2.3664650 0.47794130 0.41336389 -0.001402707 -0.05640164 0.31508732 1.773399071 -0.29518123 -0.33392120
1.7267450 -0.08013651 -0.06566371 0.026393448 0.09420602 0.10489179 -0.295181231 0.85155045 0.38077200
3.9352844 -0.18466945 -0.21964351 -0.010584172 0.04614128 0.01246170 -0.333921200 0.38077200 1.65988123

State 7

mean cov matrix

4.1610702 2.07701365 0.57236533 -0.01078377 0.08420521 0.37503590 0.1082710 0.09354553 0.18520555
2.8123237 0.57236533 1.14835508 0.06856674 0.09456191 0.23067449 -0.1950187 -0.04404659 -0.02850720
0.4935771 -0.01078377 0.06856674 0.25329031 0.12417199 0.14732728 -0.1621750 -0.01638485 -0.05056613
1.0870928 0.08420521 0.09456191 0.12417199 0.48303636 0.20876188 -0.2770706 -0.04067655 -0.10156420
3.4966426 0.37503590 0.23067449 0.14732728 0.20876188 1.83568237 -0.2153054 -0.01036384 -0.01116005
1.7076237 0.10827095 -0.19501868 -0.16217501 -0.27707061 -0.21530536 1.9993322 0.19985332 0.39292059
0.4576402 0.09354553 -0.04404659 -0.01638485 -0.04067655 -0.01036384 0.1998533 0.21675055 0.17680091
0.7623624 0.18520555 -0.02850720 -0.05056613 -0.10156420 -0.01116005 0.3929206 0.17680091 0.51597619

State 8

mean cov matrix

1.3311410 0.759239695 0.262404056 0.004387492 0.03794929 0.175082506 0.14877222 -0.08524839 -0.158849254
0.8691718 0.262404056 0.428838431 0.004268613 0.06747755 0.101191121 0.08724334 -0.08412293 -0.131438180
0.2744988 0.004387492 0.004268613 0.128717419 0.02892799 -0.017104597 -0.03177430 -0.01978507 -0.040273516

0.6198781 0.037949291 0.067477554 0.028927986 0.25366965 0.072345894 -0.04132214 -0.04495276 -0.086575409
 1.3590375 0.175082506 0.101191121 -0.017104597 0.07234589 0.674026766 0.14009966 0.00042553 0.008139997
 0.5174333 0.148772224 0.087243341 -0.031774301 -0.04132214 0.140099665 0.41906675 0.05048843 0.120284992
 0.6101124 -0.085248389 -0.084122929 -0.019785067 -0.04495276 0.000425530 0.05048843 0.34955339 0.361551806
 1.0789796 -0.158849254 -0.131438180 -0.040273516 -0.08657541 0.008139997 0.12028499 0.36155181 0.917309222

State 9

mean cov matrix

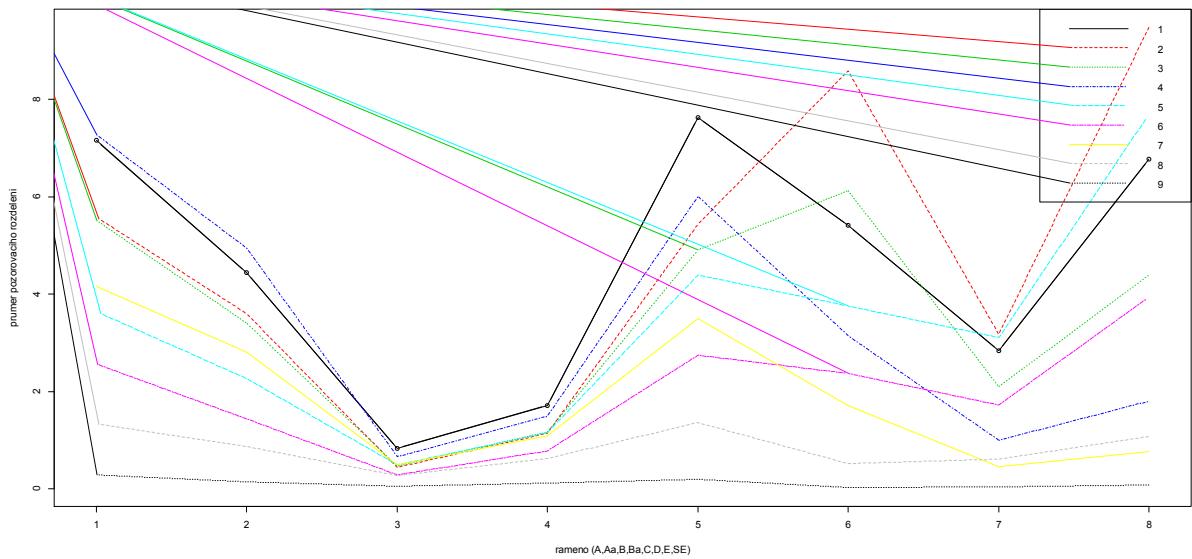
0.28303357	0.159153065	0.037758975	0.0106860710	0.023570359	0.036639159	0.0026021922	0.005064486
0.010799884							
0.14155365	0.037758975	0.070746778	0.0100047461	0.030806745	0.019063283	0.0031219558	0.002852571
0.007177382							
0.05428446	0.010686071	0.010004746	0.0221050312	0.011250147	0.009544913	0.0002056007	0.002580537
0.004227908							
0.11489481	0.023570359	0.030806745	0.0112501468	0.052231890	0.027005940	0.0026127635	0.004151162
0.008637208							
0.19634236	0.036639159	0.019063283	0.0095449131	0.027005940	0.105518314	0.0048939026	0.006742344
0.013234024							
0.02449796	0.002602192	0.003121956	0.0002056007	0.002612763	0.004893903	0.0087250227	0.001200913
0.001608842							
0.04241341	0.005064486	0.002852571	0.0025805373	0.004151162	0.006742344	0.0012009125	0.016521449
0.015172172							
0.08003475	0.010799884	0.007177382	0.0042279079	0.008637208	0.013234024	0.0016088425	0.015172172
0.042763386							

Log-likelihood: -110914.2

BIC criterium: 226445.5

AIC criterium: 222780.4

Průměry pozorovacího rozdělení, Obrázek 64.



Obrázek 64: Pozorovací rozdělení, průměry.

Přechodová matice:

[,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9]

[1,] 0.76 0.08 0.06 0.01 0.03 0.04 0.00 0.01 0.00 Metropole vyrovnáný výjezd i nájezd

[2,] 0.13 0.70 0.06 0.01 0.05 0.05 0.00 0.00 0.00 Metropole výjezd a nájezd z D

[3,] 0.07 0.03 0.74 0.05 0.03 0.05 0.02 0.01 0.00 Metropole spíš nájezd

[4,] 0.02 0.00 0.06 0.75 0.00 0.02 0.12 0.02 0.00 Metropole spíš nájezd z A

[5,] 0.04 0.06 0.03 0.00 0.74 0.11 0.00 0.02 0.00 Metropole spíš výjezd

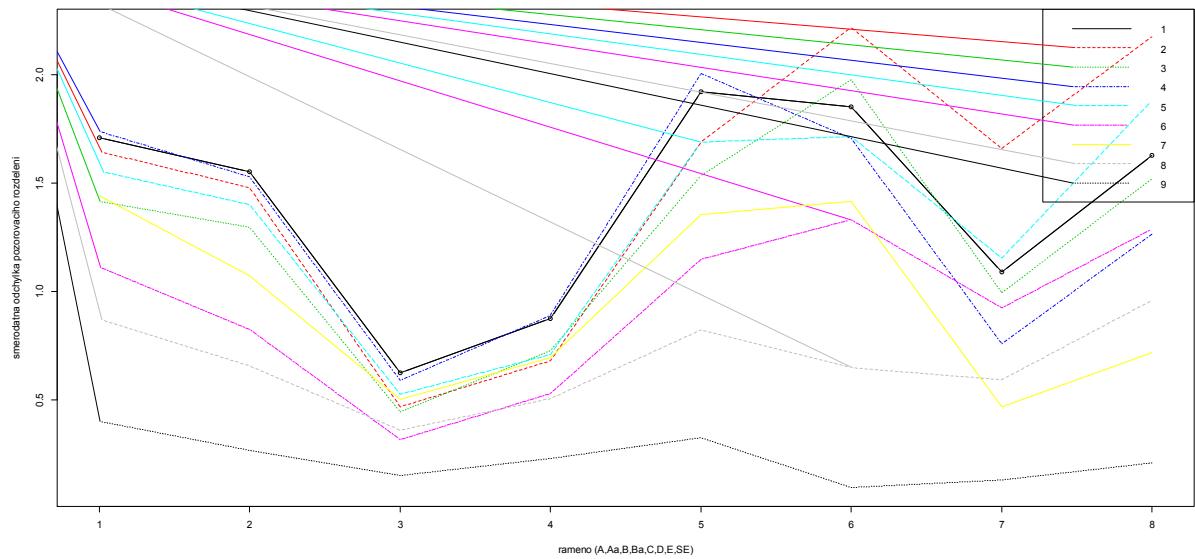
[6,] 0.03 0.02 0.04 0.00 0.05 0.81 0.00 0.04 0.00

[7,] 0.00 0.00 0.03 0.08 0.00 0.01 0.83 0.05 0.00 Metropole spíš nájezd

[8,] 0.00 0.00 0.01 0.00 0.01 0.02 0.02 0.86 0.07

[9,] 0.00 0.00 0.00 0.00 0.00 0.00 0.03 0.97 noc

Pozorovací rozdělení, směrodatné odchylinky, Obrázek 65.



Obrázek 65: Pozorovací rozdelení, směrodatné odchylky.

3.10.2.2 Dimenze stavu 5

Výpis:

Call:

```
HMMFit(obs = pom, dis = "NORMAL", nStates = 5, asymptCov = F, control = list(verbose = 1, init = "KMEANS", tol = 0.1))
```

Model:

5 states HMM with 8-d gaussian distribution

Baum-Welch algorithm status:

Number of iterations : 1

Last relative variation of LLH function: 0.052144

Estimation:

Initial probabilities:

Pi 1	Pi 2	Pi 3	Pi 4	Pi 5	
2.183885e-28	2.377201e-14	2.587632e-13	1.959096e-08	1	

Transition matrix:

State 1	State 2	State 3	State 4	State 5	
State 1	0.85392269	0.0337165295	0.077735002	0.03462578	0.000000000
State 2	0.04730238	0.8430332290	0.020729114	0.08763820	0.001297079
State 3	0.10958234	0.0178667315	0.793470124	0.07487387	0.004206936
State 4	0.02865419	0.0466875173	0.039920028	0.83685910	0.047879160
State 5	0.00000000	0.0009283126	0.001079885	0.02563869	0.972353115

Conditionnal distribution parameters:

Distribution parameters:

State 1	mean	cov	matrix
6.3268005	3.41976352	1.2599992	0.08434096
0.24380138	0.59159896	-0.933170130	-0.184570129
-0.6759945			
4.0388178	1.25999915	2.4602455	0.10194020
0.12935060	0.26661020	-0.328907441	-0.162521864
-0.4299346			
0.6563844	0.08434096	0.1019402	0.34619806
0.11634436	0.24585738	-0.284037062	0.029168026
-0.1348673			
1.4464642	0.24380138	0.1293506	0.11634436
0.69580907	0.47792972	-0.429069434	0.042656718
-0.1944994			
6.5015885	0.59159896	0.2666102	0.24585738
0.47792972	4.42088874	-0.944640882	-0.050594241
-0.6233181			
6.6711507	-0.93317013	-0.3289074	-0.28403706
-0.42906943	-0.94464088	5.910110043	0.008822626
1.2404011			
2.9172822	-0.18457013	-0.1625219	0.02916803
0.04265672	-0.05059424	0.008822626	1.740552464
0.3177039			

7.5839149 -0.67599448 -0.4299346 -0.13486735 -0.19449941 -0.62331813 1.240401120 0.317703929 5.1857783

State 2

mean cov matrix

6.3902846 3.10150421 1.26808497 -0.051213437 0.12237560 0.42240037 -0.3361811 0.018939436 0.11984198
4.1474414 1.26808497 2.39496742 0.040219524 0.11035856 0.57865040 -0.3526684 -0.080027395 -0.04850085
0.6022147 -0.05121344 0.04021952 0.308341652 0.10041839 0.10597064 -0.2789012 -0.008933181 -0.03343576
1.3372913 0.12237560 0.11035856 0.100418389 0.70095285 0.17457064 -0.2826185 -0.029104761 -0.05679416
5.3124081 0.42240037 0.57865040 0.105970640 0.17457064 3.60946117 -0.5146120 0.092855828 0.06140229
3.8808220 -0.33618106 -0.35266841 -0.278901240 -0.28261854 -0.51461200 5.6068293 0.690031983 1.34742957
1.2205271 0.01893944 -0.08002739 -0.008933181 -0.02910476 0.09285583 0.6900320 0.883560202 1.03701073
2.2590382 0.11984198 -0.04850085 -0.033435757 -0.05679416 0.06140229 1.3474296 1.037010731 2.61246280

State 3

mean cov matrix

3.4879126 1.95960366 0.77489391 0.035314093 0.12939830 0.5890102 0.90156775 -0.06374019 -0.424326829
1.9968827 0.77489391 1.15185314 0.068237980 0.09467809 0.3649231 0.63358282 -0.06924784 -0.311819374
0.3937806 0.03531409 0.06823798 0.180564410 0.06117361 0.1106702 0.03802535 0.04787037 0.001975688
1.0449358 0.12939830 0.09467809 0.061173606 0.41548226 0.1983623 0.03459990 0.10029160 -0.016424611
3.9086769 0.58901017 0.36492308 0.110670237 0.19836232 2.3478100 0.60475076 0.11555031 -0.198539062
3.5626485 0.90156775 0.63358282 0.038025351 0.03459990 0.6047508 3.31554336 -0.30429236 -0.348871194
2.5715774 -0.06374019 -0.06924784 0.047870366 0.10029160 0.1155503 -0.30429236 1.35664602 0.659534832
5.9821311 -0.42432683 -0.31181937 0.001975688 -0.01642461 -0.1985391 -0.34887119 0.65953483 4.070154808

State 4

mean cov matrix

2.2271078 1.50732640 0.7209858 0.03809303 0.13256330 0.54797284 0.43514763 -0.17987237 -0.35382125
1.4189094 0.72098577 0.9012539 0.04119460 0.11341406 0.36764080 0.23941288 -0.21655750 -0.45267225

0.3054513 0.03809303 0.0411946 0.13350011 0.05193872 0.04874322 -0.05464042 -0.03401579 -0.09481749
0.7447777 0.13256330 0.1134141 0.05193872 0.31183249 0.13834127 -0.09622751 -0.06461052 -0.16866999
2.1881522 0.54797284 0.3676408 0.04874322 0.13834127 1.18828553 0.32973153 -0.04728721 -0.07867004
1.3615709 0.43514763 0.2394129 -0.05464042 -0.09622751 0.32973153 1.37578985 0.12496282 0.45393352
0.9223591 -0.17987237 -0.2165575 -0.03401579 -0.06461052 -0.04728721 0.12496282 0.57318525 0.73268400
1.9135474 -0.35382125 -0.4526723 -0.09481749 -0.16866999 -0.07867004 0.45393352 0.73268400 2.13246216

State 5

mean cov matrix

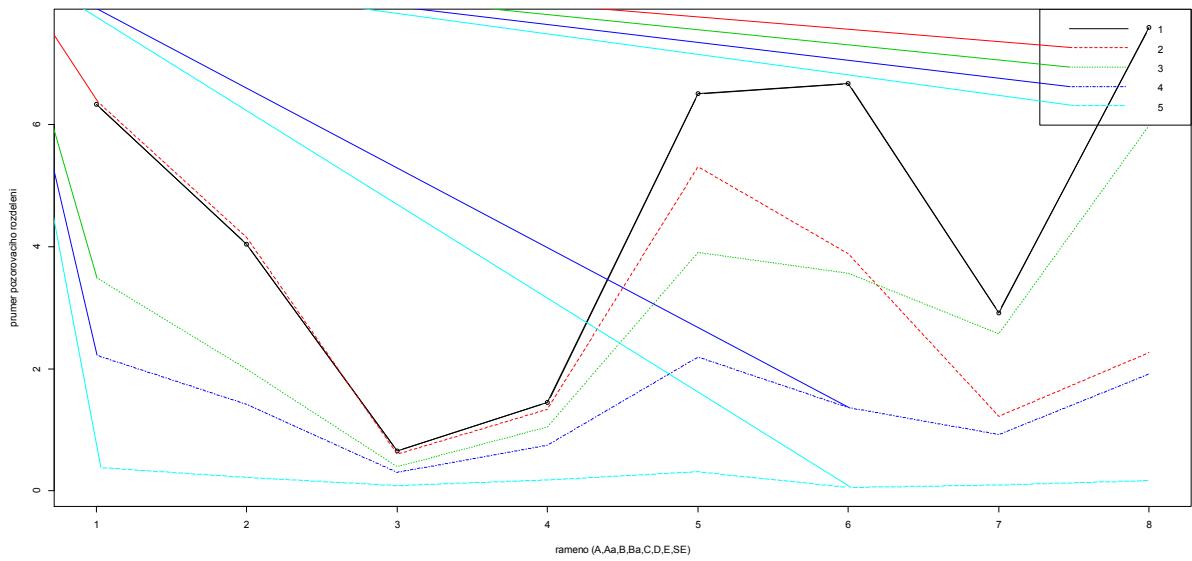
0.38595757 0.25525185 0.08432827 0.025411681 0.056091948 0.09550346 0.017380014 0.024739351 0.04111968
0.21930846 0.08432827 0.12966493 0.022316140 0.062226062 0.06226264 0.013388669 0.017568115 0.03069003
0.08530312 0.02541168 0.02231614 0.041292107 0.023021926 0.02290459 0.002303709 0.008876980 0.01363522
0.17984368 0.05609195 0.06222606 0.023021926 0.095025977 0.06528003 0.009379963 0.017841288 0.02952042
0.30934380 0.09550346 0.06226264 0.022904589 0.065280026 0.21089228 0.022389587 0.031668246 0.05540486
0.05190425 0.01738001 0.01338867 0.002303709 0.009379963 0.02238959 0.021394026 0.008147054 0.01451535
0.09691408 0.02473935 0.01756811 0.008876980 0.017841288 0.03166825 0.008147054 0.055619585 0.06505839
0.17025381 0.04111968 0.03069003 0.013635223 0.029520418 0.05540486 0.014515354 0.065058386 0.14329824

Log-likelihood: -124817.9

BIC criterium: 252002.5

AIC criterium: 250123.7

Průměry pozorovacího rozdělení, Obrázek 66.



Obrázek 66: Pozorovací rozdělení, průměry.

Přechodová matice:

[,1] [,2] [,3] [,4] [,5]

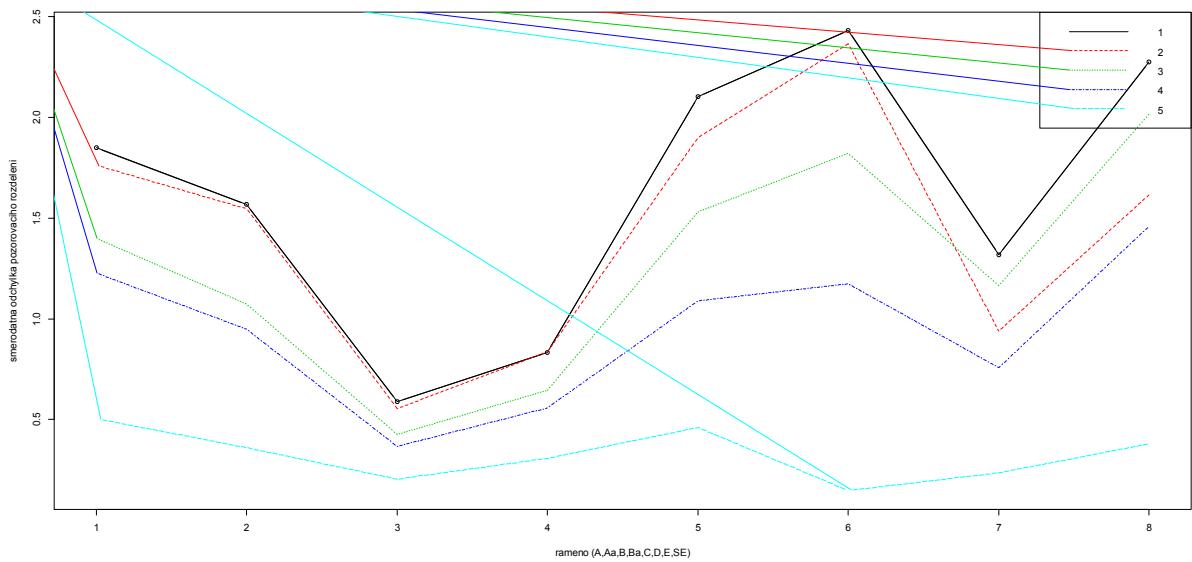
[1,] 0.85 0.03 0.08 0.03 0.00 Metropole vyvážena

[2,] 0.05 0.84 0.02 0.09 0.00 Metropole nájezd

[3,] 0.11 0.02 0.79 0.07 0.00 Metropole výjezd

[4,] 0.03 0.05 0.04 0.84 0.05

[5,] 0.00 0.00 0.00 0.03 0.97



Obrázek 67: Pozorovací rozdělení, směrodatné odchylky.

3.10.2.3 Dimenze stavu 4

Výpis:

```
> # dimenze stavu 4
> a4
```

Call:

```
----
```

```
HMMFit(obs = pom, dis = "NORMAL", nStates = 4, asymptCov = F, control = list(verbose = 1, init = "KMEANS", tol = 0.1))
```

Model:

```
----
```

```
4 states HMM with 8-d gaussian distribution
```

Baum-Welch algorithm status:

```
-----
```

```
Number of iterations : 1
```

```
Last relative variation of LLH function: 0.061213
```

Estimation:

Initial probabilities:

Pi 1	Pi 2	Pi 3	Pi 4
4.221344e-17	1.63825e-10	1.113782e-07	0.9999999

Transition matrix:

State 1	State 2	State 3	State 4	
State 1	0.8889767299	0.027701922	0.08138290	0.001938451
State 2	0.0445176449	0.874692201	0.05590823	0.024881926
State 3	0.0809060391	0.031455294	0.85168795	0.035950719
State 4	0.0008945108	0.008192277	0.01693977	0.973973443

Conditionnal distribution parameters:

Distribution parameters:

State 1

mean cov matrix

5.9688148	3.6159507	1.5089026	0.09764870	0.24104954	0.91644205	-0.22968891	-0.16319539	-0.4427138
3.7760265	1.5089026	2.5587325	0.13233976	0.14463188	0.55126436	0.11370036	-0.14925197	-0.2904142
0.6353621	0.0976487	0.1323398	0.33010130	0.11710332	0.24354876	-0.21845792	0.03179961	-0.1022289
1.4139176	0.2410495	0.1446319	0.11710332	0.66651373	0.42445290	-0.31456540	0.04748785	-0.1435558
6.1842555	0.9164421	0.5512644	0.24354876	0.42445290	4.43552532	-0.36251554	-0.02643992	-0.3955609
6.2479799	-0.2296889	0.1137004	-0.21845792	-0.31456540	-0.36251554	5.91135352	-0.05536156	1.1850581
2.8962521	-0.1631954	-0.1492520	0.03179961	0.04748785	-0.02643992	-0.05536156	1.63767380	0.3508050
7.3263415	-0.4427138	-0.2904142	-0.10222889	-0.14355579	-0.39556088	1.18505814	0.35080498	5.1799302

State 2

mean cov matrix

5.8749701 4.06817432 1.7894147780 -0.1033501589 0.09997324 1.27367936 0.9568223 0.38893652 0.77283756
3.8599448 1.78941478 2.4965501372 0.0005658667 0.09291002 0.96686095 0.3165733 0.09681315 0.23887765
0.5975486 -0.10335016 0.0005658667 0.3071343046 0.09199540 0.07286917 -0.2728883 -0.02878702 -0.07183386
1.3164084 0.09997324 0.0929100206 0.0919953990 0.66326266 0.13918077 -0.2541498 -0.04027199 -0.09931910
4.8809584 1.27367936 0.9668609451 0.0728691676 0.13918077 3.81180662 0.4083928 0.28561249 0.43425445
3.2945811 0.95682229 0.3165733341 -0.2728882957 -0.25414983 0.40839285 5.8840785 0.94266053 1.75951597
0.9788245 0.38893652 0.0968131533 -0.0287870198 -0.04027199 0.28561249 0.9426605 0.77323137 0.93957655
1.7958721 0.77283756 0.2388776485 -0.0718338550 -0.09931910 0.43425445 1.7595160 0.93957655 2.27285961

State 3

mean cov matrix

2.5106260 1.54907201 0.64920997 0.02592602 0.11508694 0.5767392 0.80363430 0.03417551 0.07593038
1.4723313 0.64920997 0.80687587 0.01206796 0.06226234 0.3182787 0.52959647 -0.06939063 -0.15585202
0.2751816 0.02592602 0.01206796 0.10214496 0.02622697 0.0544091 0.01726380 0.03489304 0.03178884
0.7614138 0.11508694 0.06226234 0.02622697 0.28968994 0.1922633 0.02085525 0.10270797 0.14027910
2.6716854 0.57673921 0.31827866 0.05440910 0.19226329 1.5512070 0.64196230 0.27814863 0.57628772
2.1936217 0.80363430 0.52959647 0.01726380 0.02085525 0.6419623 2.18736937 0.07037279 0.54257055
1.6217854 0.03417551 -0.06939063 0.03489304 0.10270797 0.2781486 0.07037279 1.16066566 1.43154015
3.6293243 0.07593038 -0.15585202 0.03178884 0.14027910 0.5762877 0.54257055 1.43154015 4.65766960

State 4

mean cov matrix

0.52635701 0.48095356 0.22246751 0.054403319 0.12988658 0.25955376 0.066219367 0.04945031 0.08462289
0.31553877 0.22246751 0.24942184 0.041353020 0.11230689 0.17596671 0.046447035 0.03147583 0.05469826
0.11178943 0.05440332 0.04135302 0.057243306 0.03719124 0.04592521 0.008701117 0.01513618 0.02465925

```

0.24060273 0.12988658 0.11230689 0.037191240 0.14449086 0.13256320 0.023749568 0.02970246 0.04801817
0.44800637 0.25955376 0.17596671 0.045925210 0.13256320 0.40689607 0.070118249 0.06409364 0.11103763
0.09534528 0.06621937 0.04644703 0.008701117 0.02374957 0.07011825 0.057952992 0.02240853 0.03990069
0.14208433 0.04945031 0.03147583 0.015136183 0.02970246 0.06409364 0.022408526 0.09560723 0.11856689
0.24781585 0.08462289 0.05469826 0.024659247 0.04801817 0.11103763 0.039900693 0.11856689 0.25058717

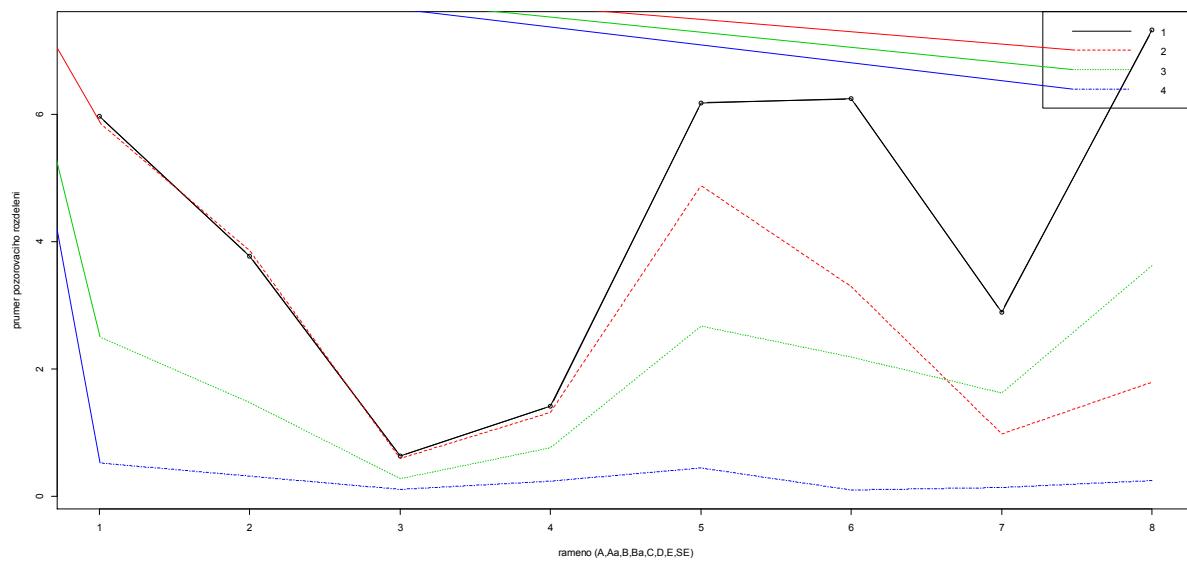
```

Log-likelihood: -132441.3

BIC criterium: 266735.2

AIC criterium: 265264.6

Průměry pozorovacího rozdělení:



Obrázek 68: Pozorovací rozdělení, průměry.

Přechodová matice:

```
> round(a5$HMM$transMat,2)
```

```
[,1] [,2] [,3] [,4] [,5]
```

```
[1.] 0.85 0.03 0.08 0.03 0.00
```

```
[2.] 0.05 0.84 0.02 0.09 0.00
```

```
[3.] 0.11 0.02 0.79 0.08 0.00
```

```
[4.] 0.03 0.05 0.04 0.84 0.05
```

```
[5.] 0.00 0.00 0.00 0.03 0.97
```

3.10.2.4 Dimenze stavu 3

Výpis:

Call:

```
HMMFit(obs = pom, dis = "NORMAL", nStates = 3, asymptCov = F, control = list(verbose = 1, init = "KMEANS", tol = 0.1))
```

Model:

3 states HMM with 8-d gaussian distribution

Baum-Welch algorithm status:

Number of iterations : 1

Last relative variation of LLH function: 0.051414

Estimation:

Initial probabilities:

Pi 1 Pi 2 Pi 3

8.681747e-16 2.829153e-08 1

Transition matrix:

State 1 State 2 State 3

State 1 0.892767897 0.10291431 0.004317793

State 2 0.084999858 0.87935928 0.035640860

State 3 0.001945965 0.02445212 0.973601915

Conditionnal distribution parameters:

Distribution parameters:

State 1

mean cov matrix

6.0527556 3.79368946 1.659539944 0.09136826 0.23557690 0.92300131 -0.375580508 -0.28815489 -0.92356505

3.8268302 1.65953994 2.681858750 0.12506160 0.13653840 0.60189078 0.002170326 -0.23798061 -0.64502440

0.6193545 0.09136826 0.125061595 0.32730141 0.11625906 0.24215227 -0.210835922 0.04203293 -0.06327625

1.3998285 0.23557690 0.136538397 0.11625906 0.68914699 0.39676679 -0.291898212 0.05129483 -0.10948975

6.1051940 0.92300131 0.601890777 0.24215227 0.39676679 4.50732438 -0.402817002 -0.01186629 -0.33275301

6.1419215 -0.37558051 0.002170326 -0.21083592 -0.29189821 -0.40281700 5.857690902 0.01009523 1.16545078

2.7453115 -0.28815489 -0.237980614 0.04203293 0.05129483 -0.01186629 0.010095233 1.69791344 0.94021281

6.8140742 -0.92356505 -0.645024401 -0.06327625 -0.10948975 -0.33275301 1.165450784 0.94021281 6.76686011

State 2

mean cov matrix

3.5595363 4.1458296 2.3368715 0.18335060 0.43039655 1.8737323 0.90690941 -0.48627177 -1.3340921

2.2344875 2.3368715 2.3106607 0.15852715 0.32169144 1.3421755 0.52209608 -0.46828073 -1.1810376

0.3947428 0.1833506 0.1585272 0.19565159 0.08596094 0.1846250 -0.04763595 -0.05431406 -0.1696800

0.9550246 0.4303965 0.3216914 0.08596094 0.45692189 0.3682214 -0.06656760 -0.06195566 -0.2406328
 3.3368671 1.8737323 1.3421755 0.18462502 0.36822144 2.8060584 0.52708714 -0.10944998 -0.4853250
 2.3348446 0.9069094 0.5220961 -0.04763595 -0.06656760 0.5270871 2.72423639 0.17297893 0.5372397
 1.3210572 -0.4862718 -0.4682807 -0.05431406 -0.06195566 -0.1094500 0.17297893 1.13928299 1.6194616
 2.8552777 -1.3340921 -1.1810376 -0.16967998 -0.24063275 -0.4853250 0.53723970 1.61946156 4.6510140

State 3

mean cov matrix

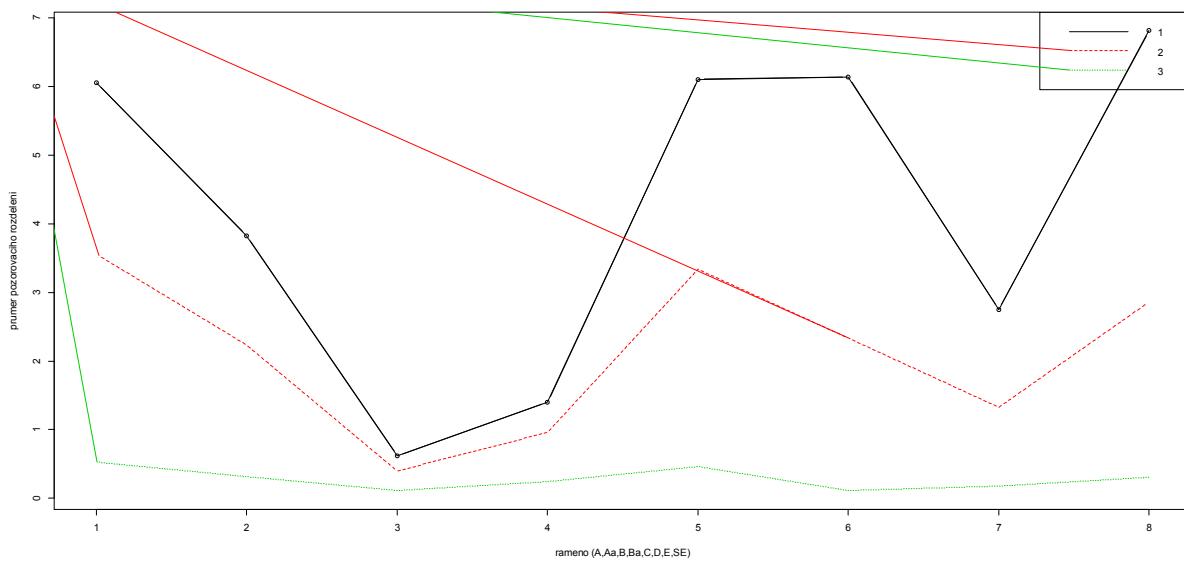
0.5262793 0.44230344 0.19810283 0.045599315 0.11148268 0.24345394 0.077484901 0.07272895 0.12598014
 0.3145095 0.19810283 0.22865765 0.035392545 0.09883464 0.16189874 0.055350514 0.04595665 0.08109842
 0.1094363 0.04559932 0.03539255 0.054138068 0.03282008 0.04124354 0.008208737 0.01744735 0.02831993
 0.2400129 0.11148268 0.09883464 0.032820085 0.13685810 0.12674548 0.024562549 0.03785779 0.06222099
 0.4624075 0.24345394 0.16189874 0.041243537 0.12674548 0.41163979 0.084696210 0.09257649 0.16522554
 0.1118954 0.07748490 0.05535051 0.008208737 0.02456255 0.08469621 0.077112879 0.03839427 0.07060914
 0.1755010 0.07272895 0.04595665 0.017447345 0.03785779 0.09257649 0.038394265 0.13547870 0.17849509
 0.3092100 0.12598014 0.08109842 0.028319930 0.06222099 0.16522554 0.070609138 0.17849509 0.37585041

Log-likelihood: -138577.6

BIC criterium: 278513.2

AIC criterium: 277435.2

Průměry pozorovacího rozdělení:



Obrázek 69: Pozorovací rozdělení, průměry.

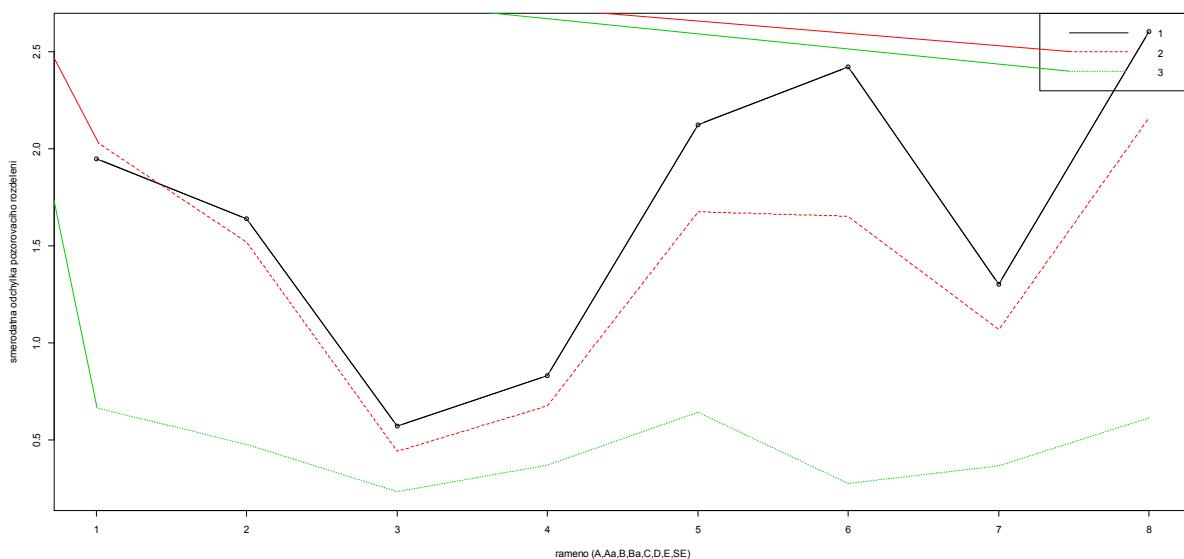
Přechodová matice:

[1] [2] [3]

[1,] 0.89 0.10 0.00

[2,] 0.08 0.88 0.04

[3,] 0.00 0.02 0.97



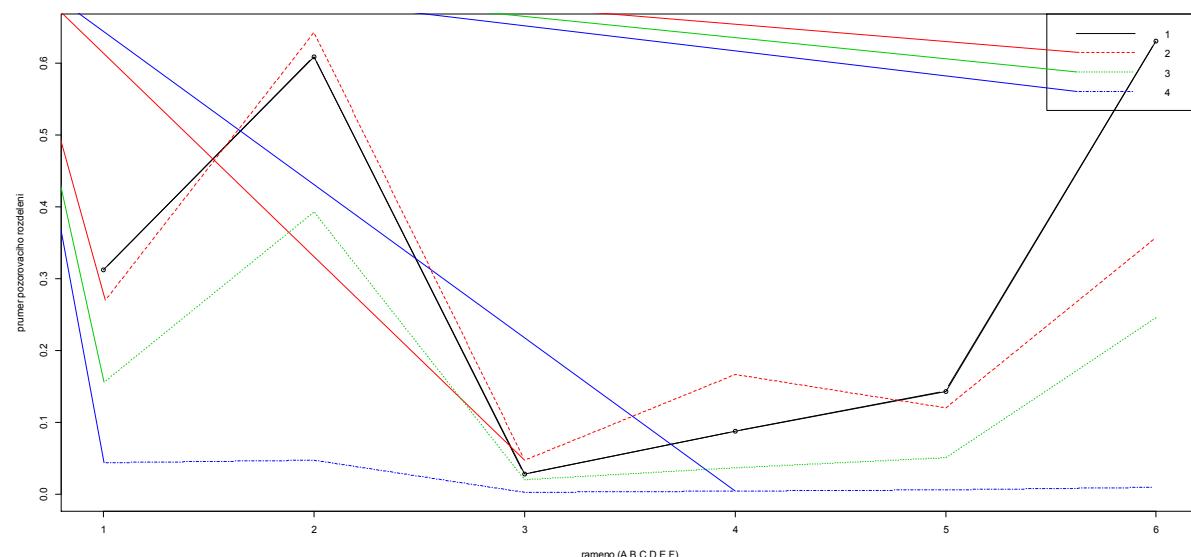
Obrázek 70: Pozorovací rozdělení, směrodatné odchylky.

3.11 Hidden Markov chain modely pro Dstop s obsazenostmi z různých ramen též křížovatky

3.11.1 Křížovatka 5.495

3.11.1.1 Obsazenosti (dimenze pozorování 6, stavu 4)

Průměry pozorovacího rozdělení:



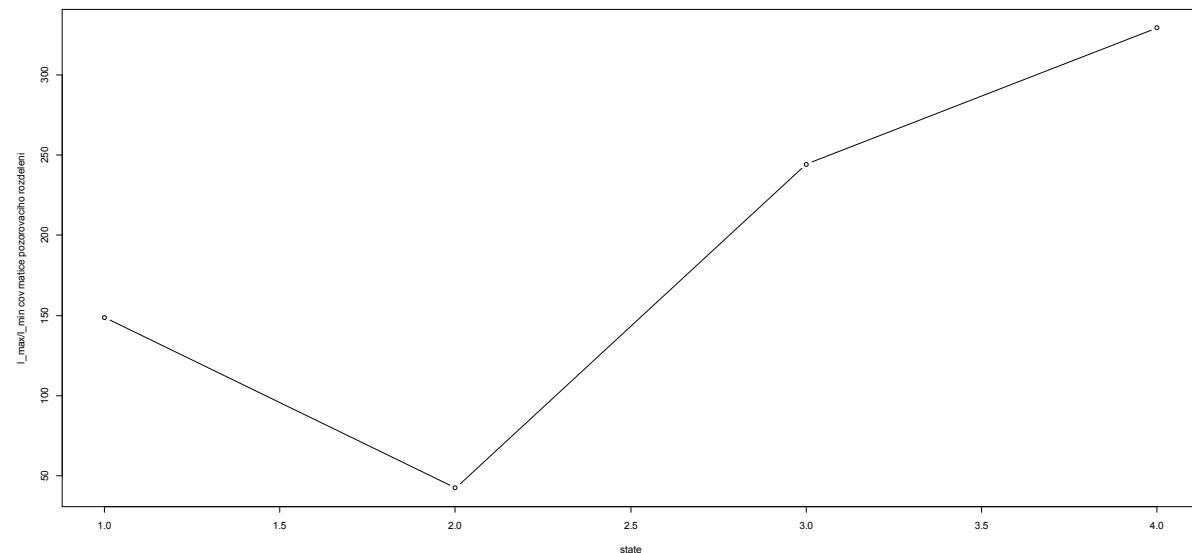
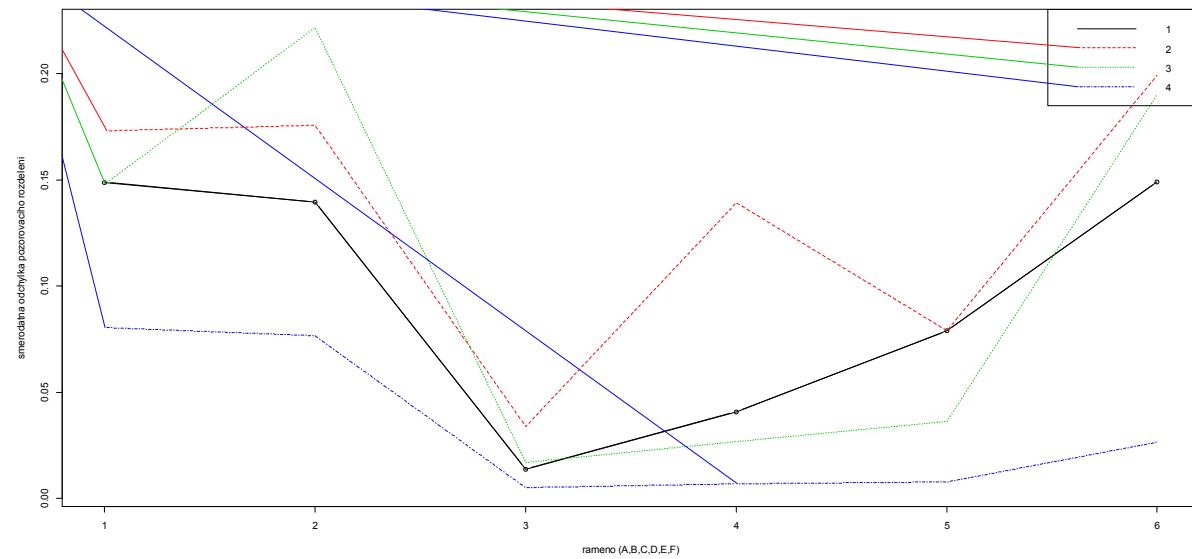
4 – noc, 3 – z města do Řevnické + z Rudné do města 2 – dtto jako 3 + obousměrně Rudná Řevnická,
1 – dtto jako 3 ale výraznější příjezd od Rudné do města, méně z Řevnické do Rudné

Přechodová matice:

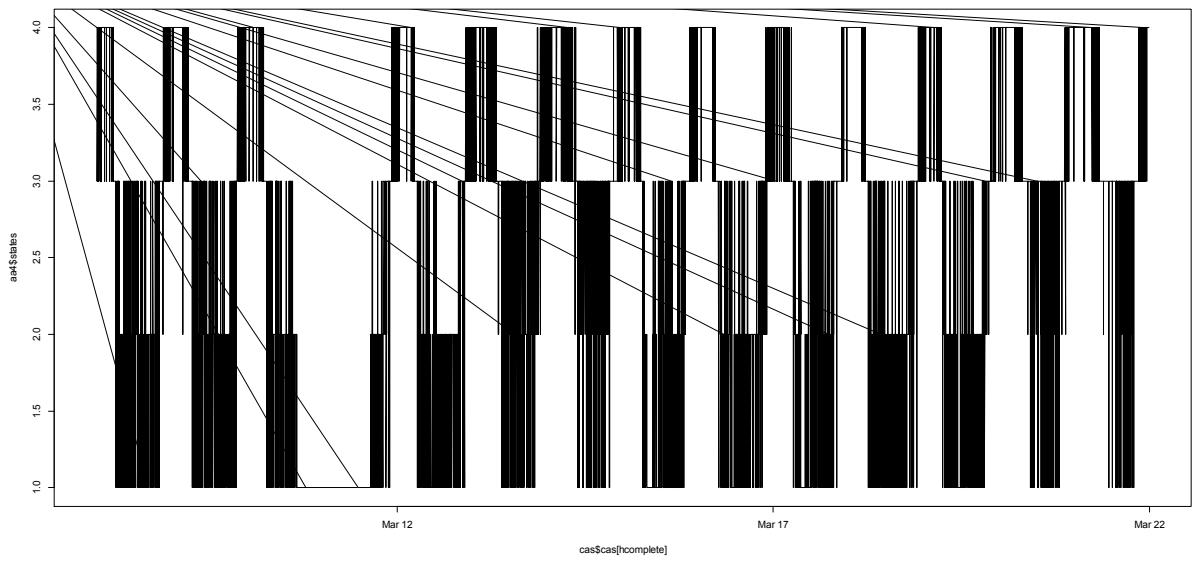
```
> round(a4$HMM$transMat,2)
```

```
[,1] [,2] [,3] [,4]
[1,] 0.86 0.08 0.05 0.00
[2,] 0.14 0.79 0.07 0.00
[3,] 0.04 0.04 0.87 0.05
```

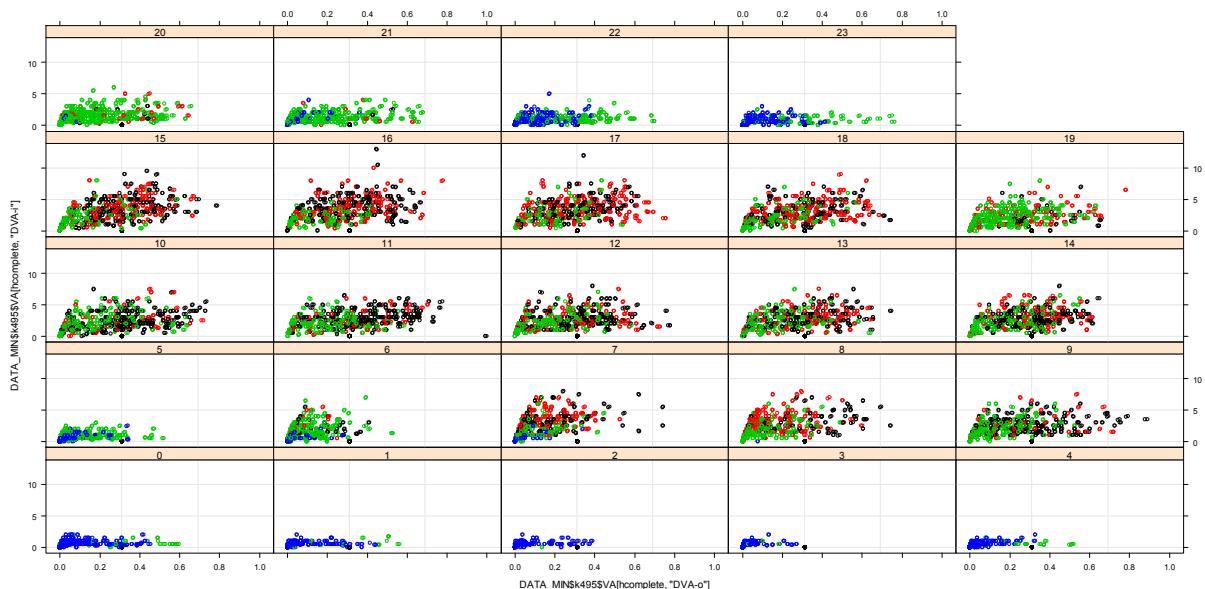
[4.] 0.00 0.00 0.06 0.94



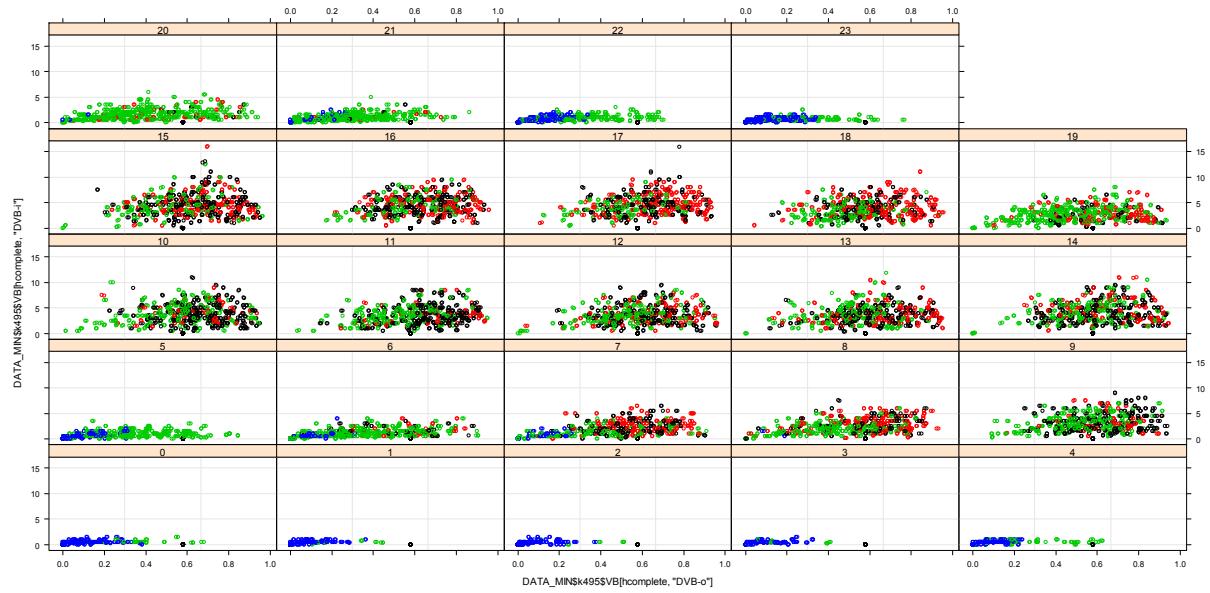
Viterbiho stavy:



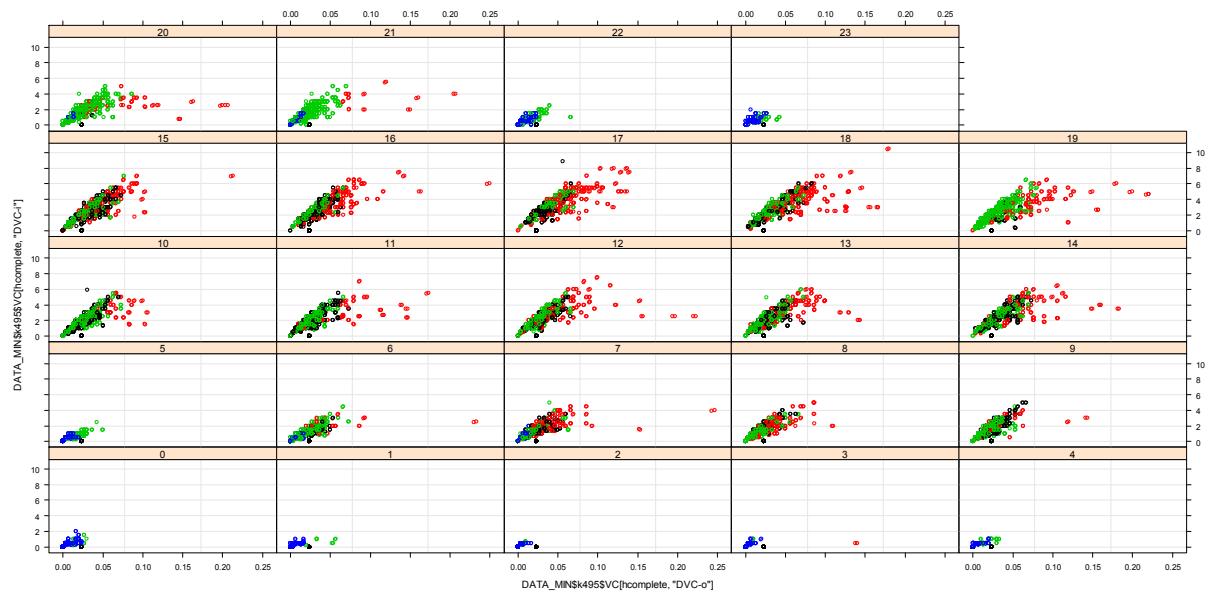
Viterbiho stavy barevně na semaforu A, po hodinách vztahu mezi obsazeností a intenzitou (černě 1, červeně 2, zeleně 3, modře 4 – jako na obrázku průměrných profílů):



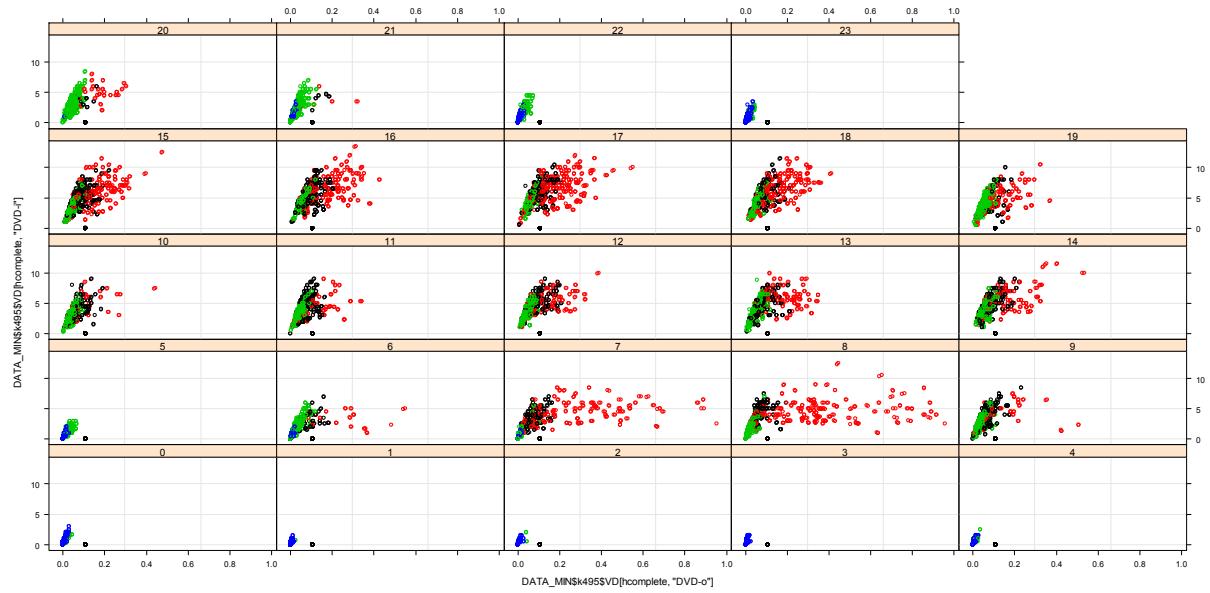
B:



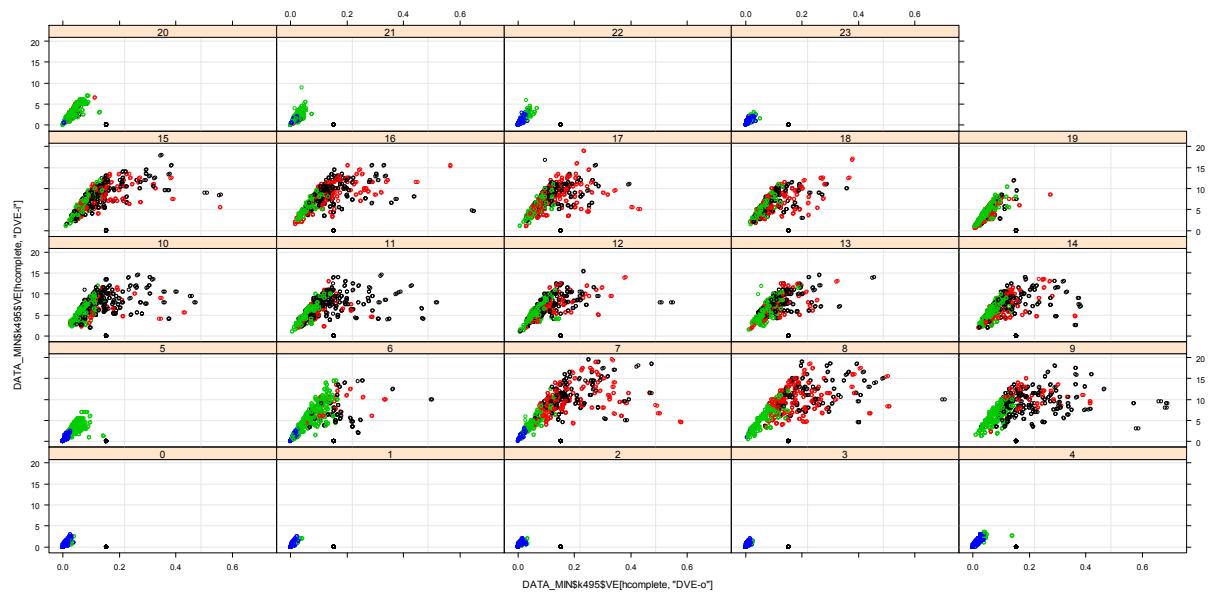
C:



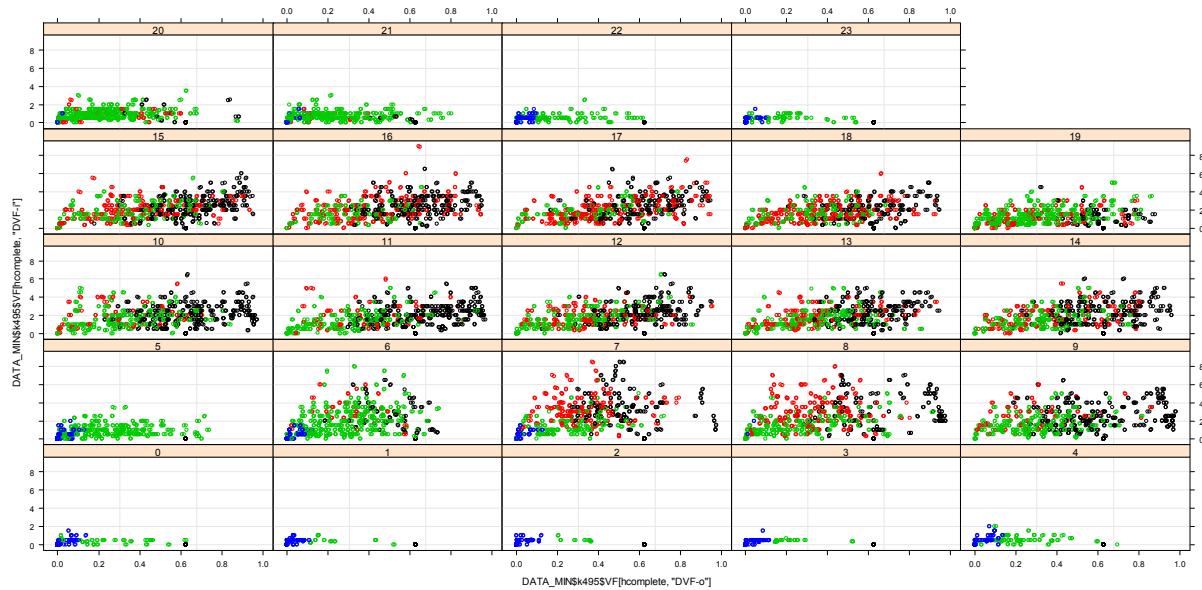
D:



E:

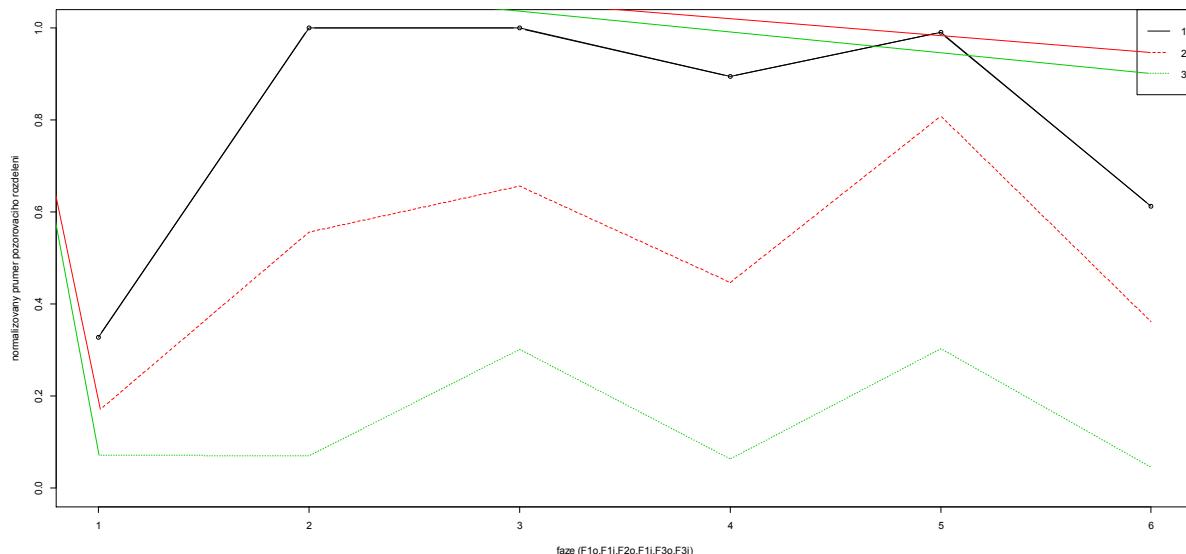


F:



3.11.1.2 Obsazenosti+intenzity (dimenze pozorování 6, stavu 3)

Průměry pozorovacího rozdělení:



Stav 3 je noc, slabý provoz, nemá cenu řídit.

Stav 1 je příliš silný provoz, nemá cenu řídit.

Stav 2 je silnější provoz ve kterém ale je trochu silnější provoz na F3 než na F2, mohla by se posílit F3 na úkor F2 (případně i F1).

Přechodová matic:

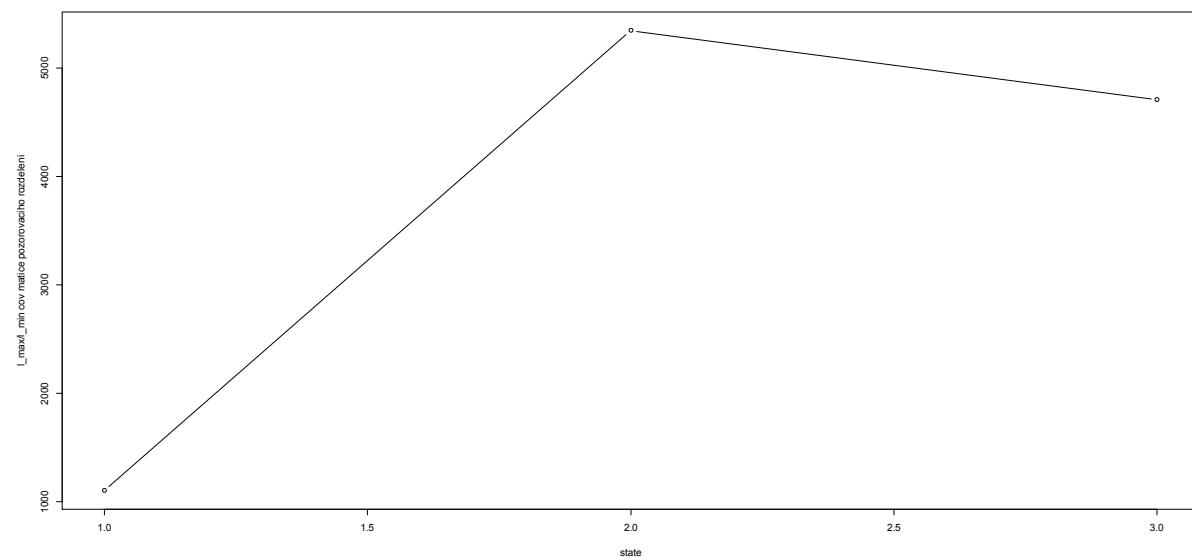
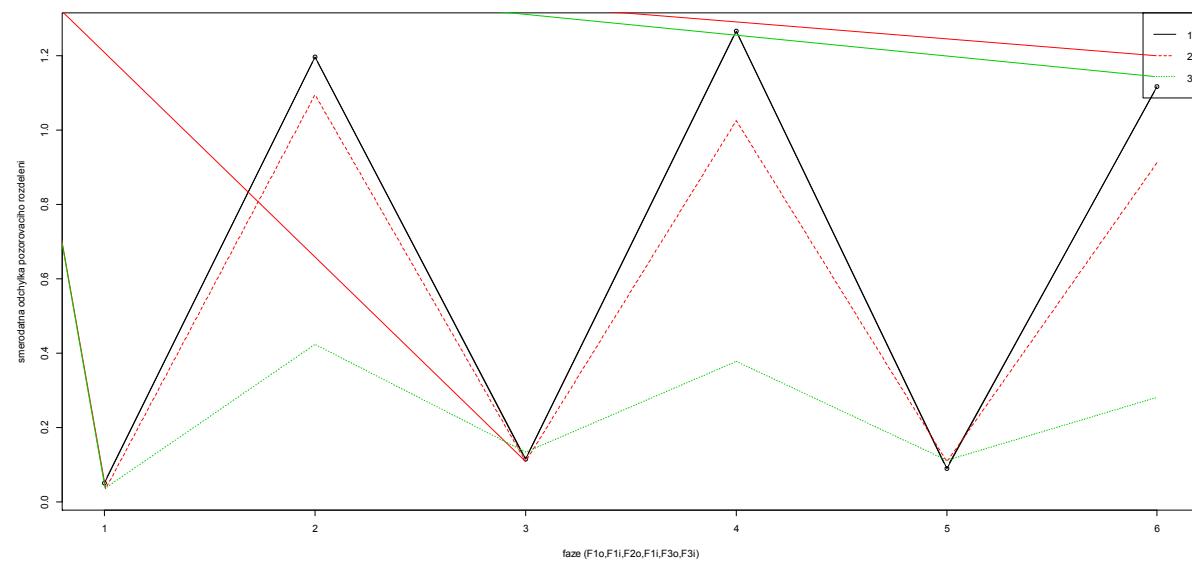
```
> round(a3$HMM$transMat,2)
```

```
[,1] [,2] [,3]
```

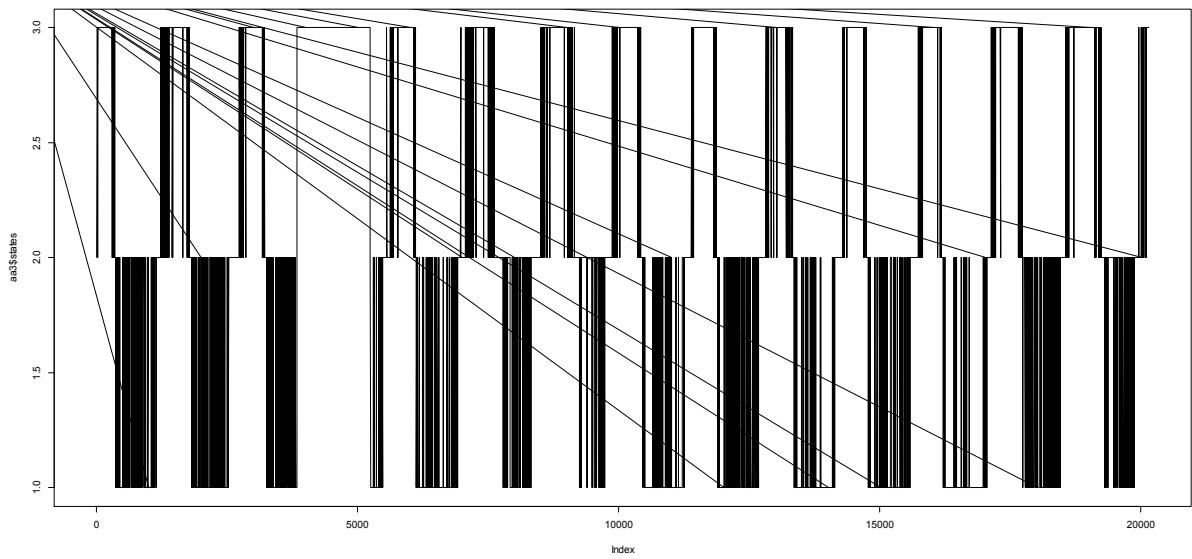
```
[1,] 0.89 0.10 0.00
```

```
[2,] 0.09 0.89 0.02
```

```
[3,] 0.00 0.02 0.98
```

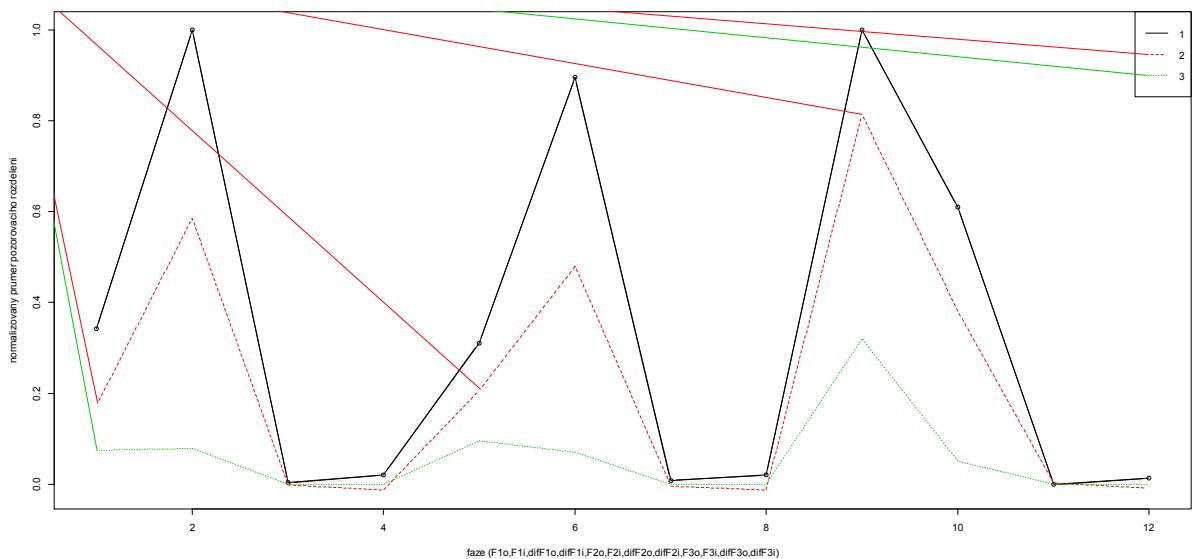


Viterbiho stavy:



3.11.1.3 Obsazenosti+intenzity, současné a lag1 (dimenze pozorování 12, stavu 3)

Průměry pozorovacího rozdělení:



Přechodová matice:

```
> round(a3$HMM$transMat,2)
```

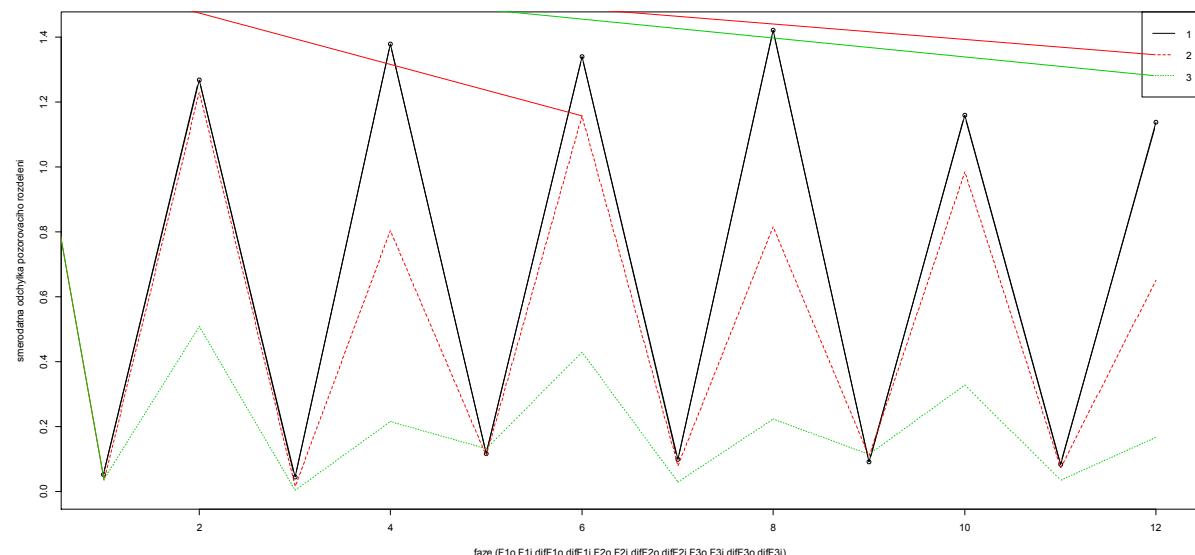
```
[,1] [,2] [,3]
```

```
[1,] 0.84 0.16 0.00
```

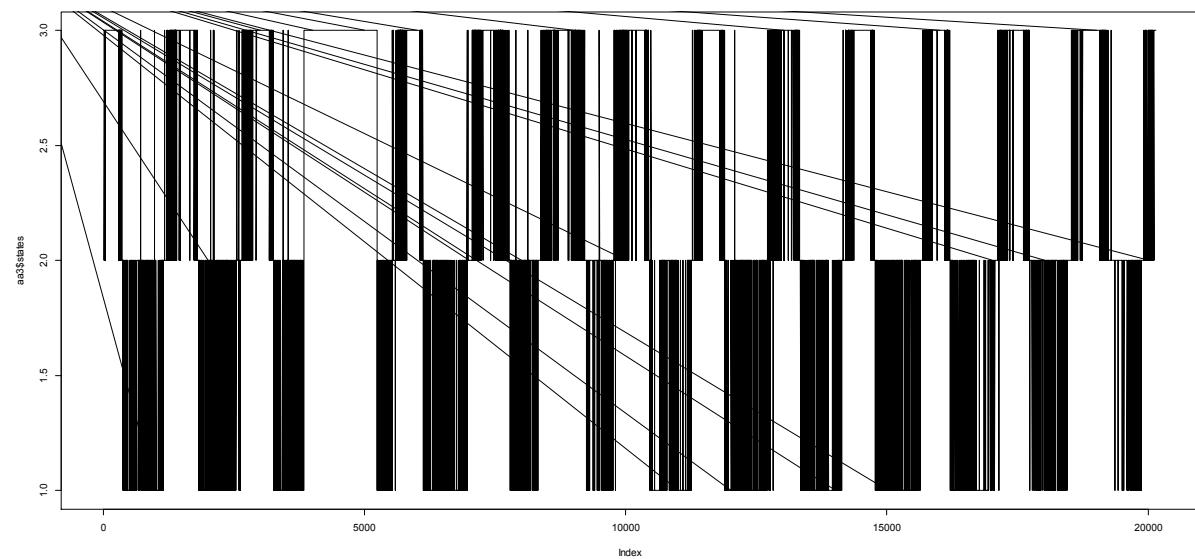
```
[2,] 0.11 0.83 0.07
```

```
[3,] 0.00 0.06 0.94
```

```
..
```



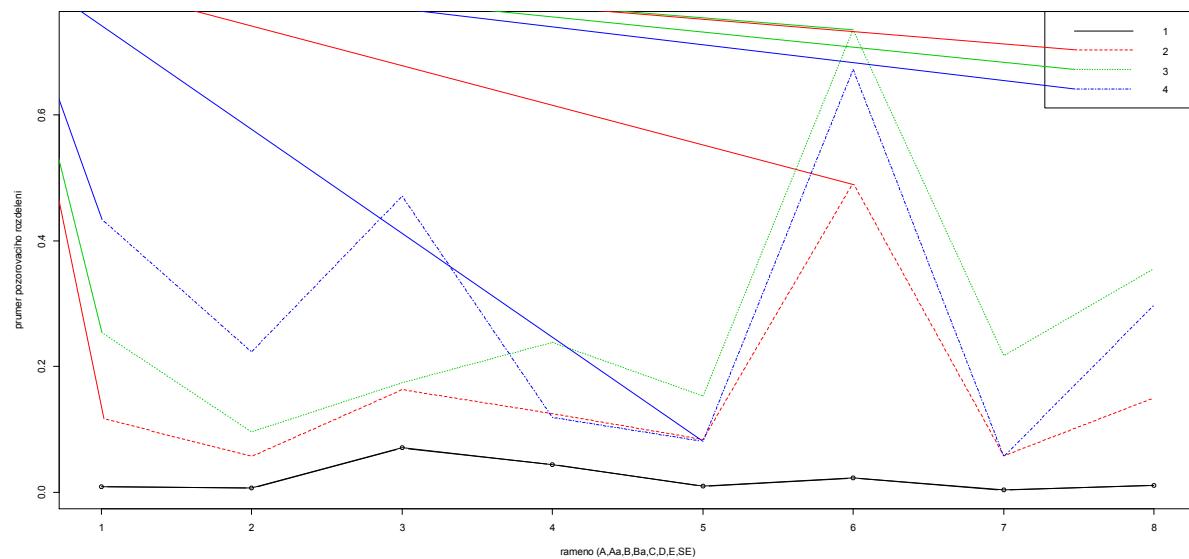
Viterbiho stavy:



3.11.2 Křižovatka 5.601

3.11.2.1 Obsazenosti (dimenze pozorování 8, stavu 4)

Průměry pozorovacího rozdělení:



1 – noc, 2 – od dálnice do Metropole a jen trochu opačný směr, 3 – od dálnice do Metropole i opačně + obousměrný průjezd+ výjezd z parkoviště, 4 – jako 3 ale výraznější výjezd z parkoviště

Přechodová matic:

```
> round(a4$HMM$transMat,2)
```

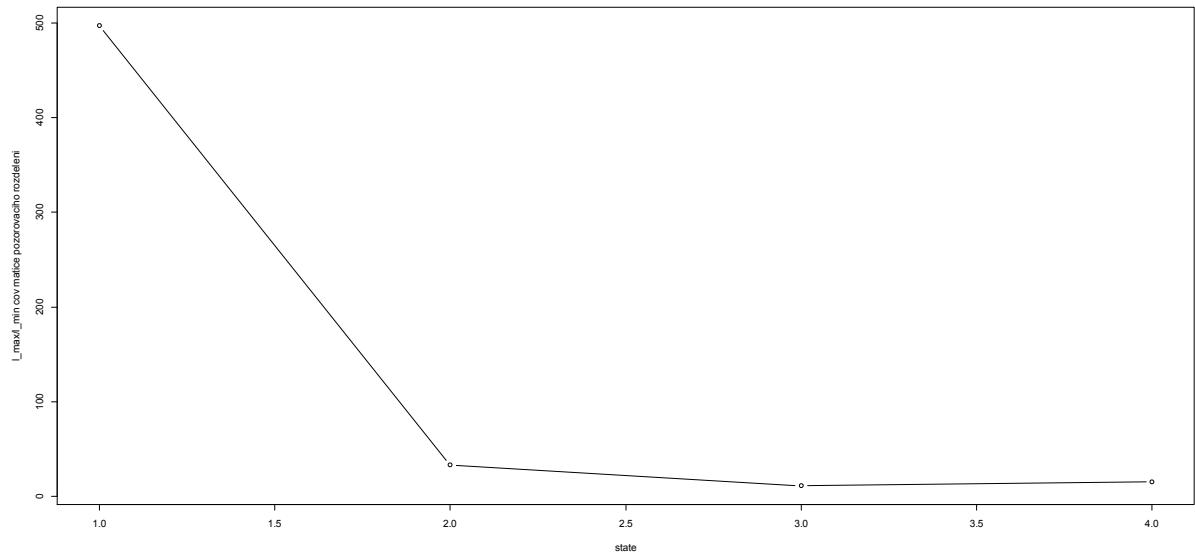
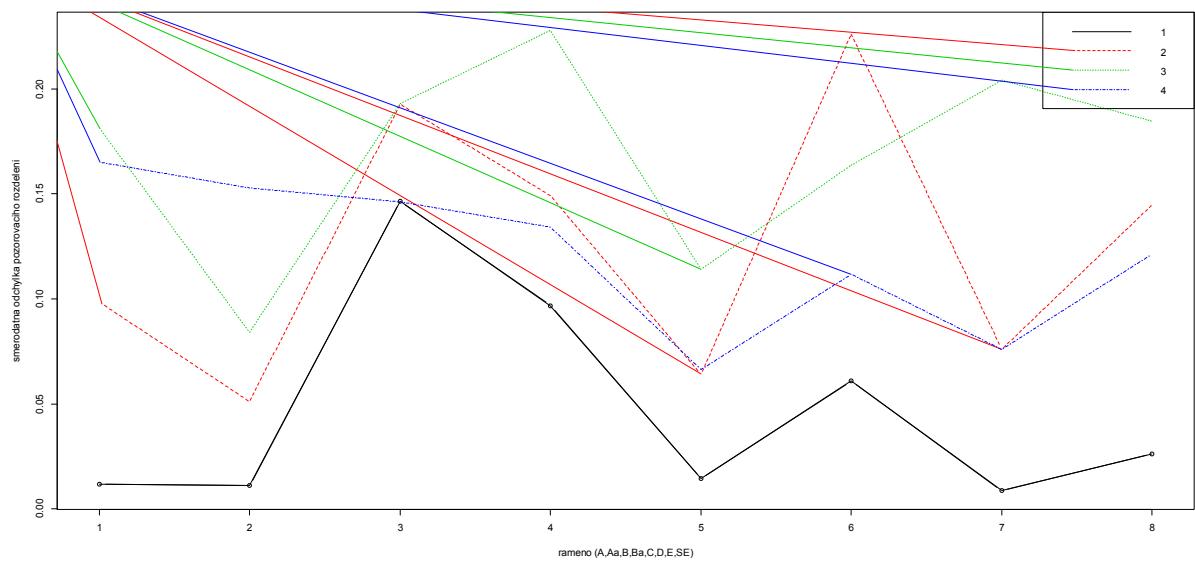
```
[,1] [,2] [,3] [,4]
```

```
[1,] 0.97 0.03 0.00 0.00
```

```
[2,] 0.04 0.88 0.05 0.03
```

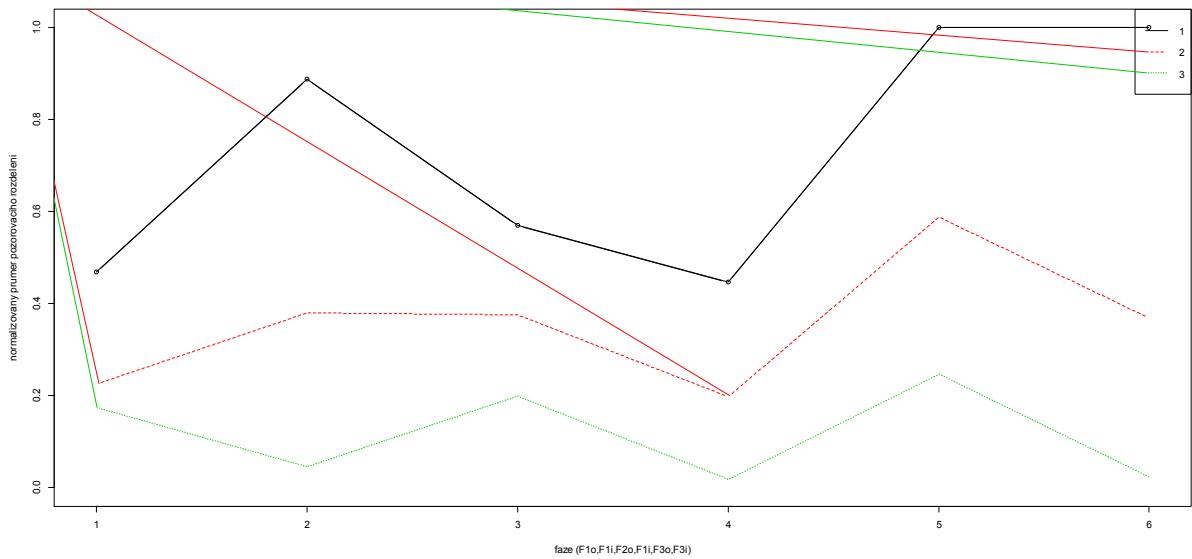
```
[3,] 0.00 0.09 0.86 0.06
```

```
[4,] 0.00 0.05 0.07 0.88
```



3.11.2.2 Obsazenosti+intenzity (dimenze pozorovani 6, stavu 3)

Průměry pozorovacího rozdělení:



Přechodová matică:

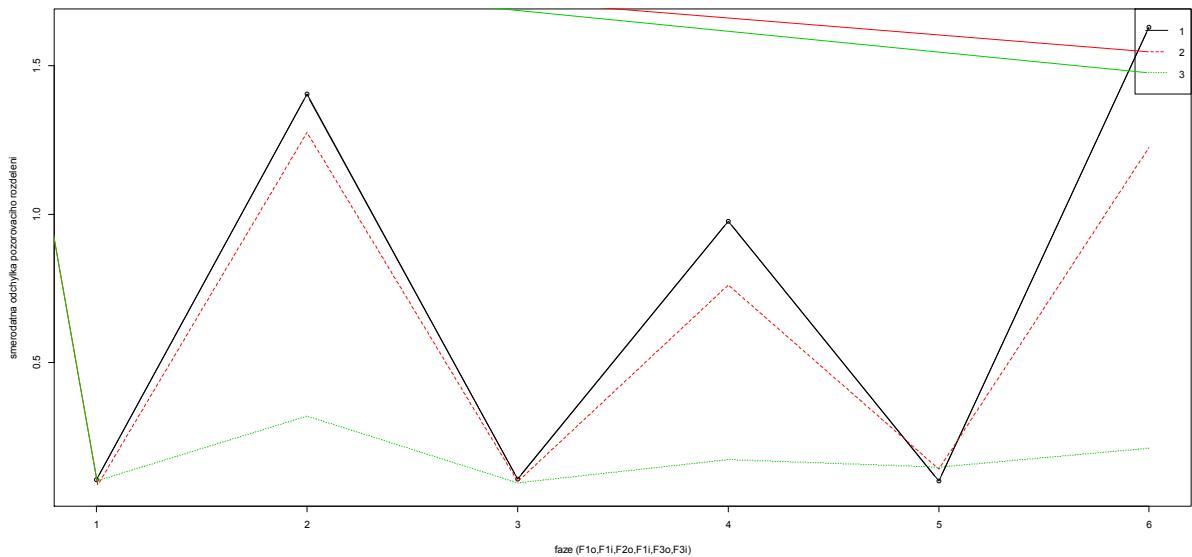
```
> round(a3$HMM$transMat,2)
```

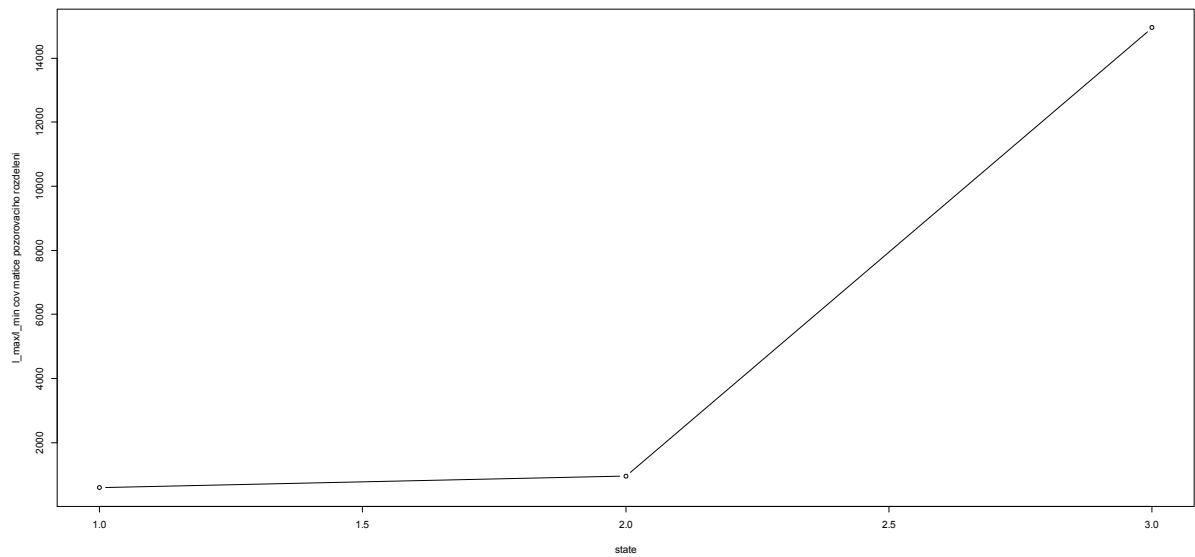
```
[,1] [,2] [,3]
```

```
[1,] 0.91 0.09 0.00
```

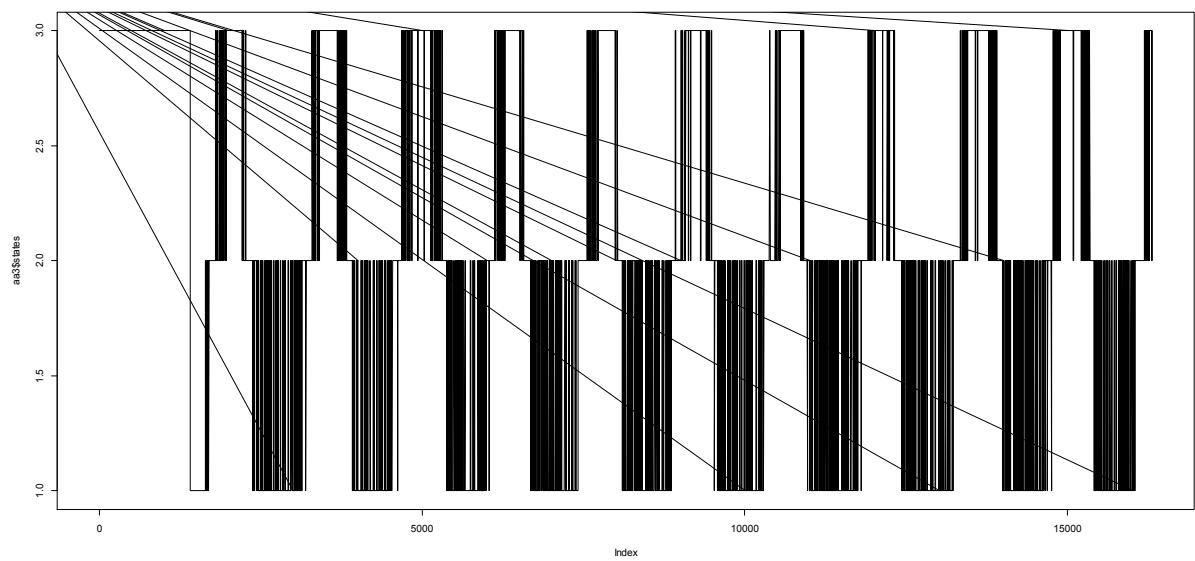
```
[2,] 0.07 0.90 0.03
```

```
[3,] 0.00 0.03 0.97
```



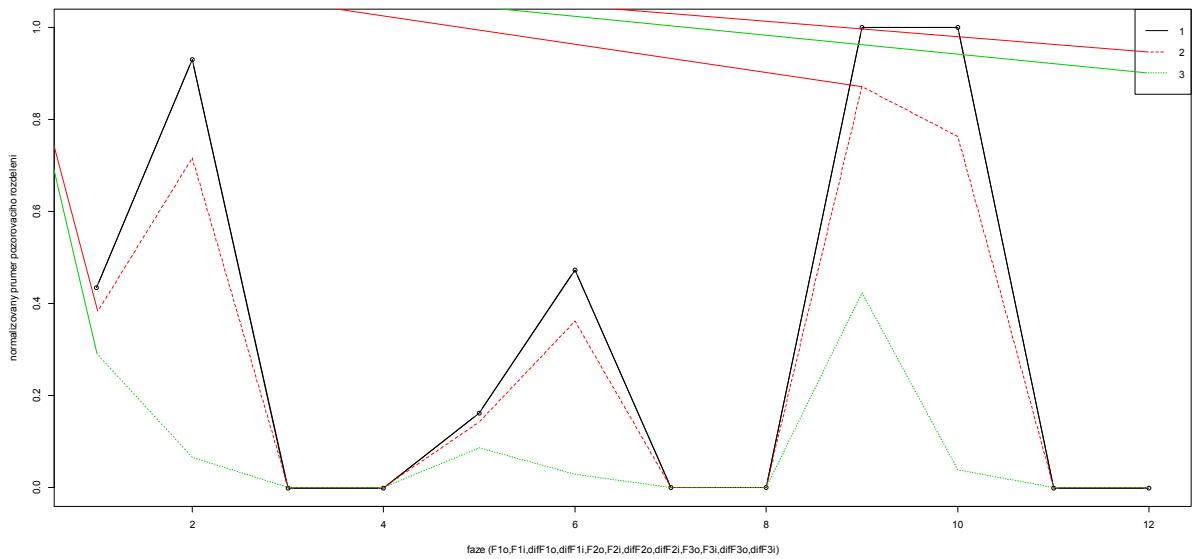


Viterbiho stavy:



3.11.2.3 Obsazenosti+intenzity, současné a lag1 (dimenze pozorování 12, stavu 3)

Průměry pozorovacího rozdělení:



Přechodová matic:

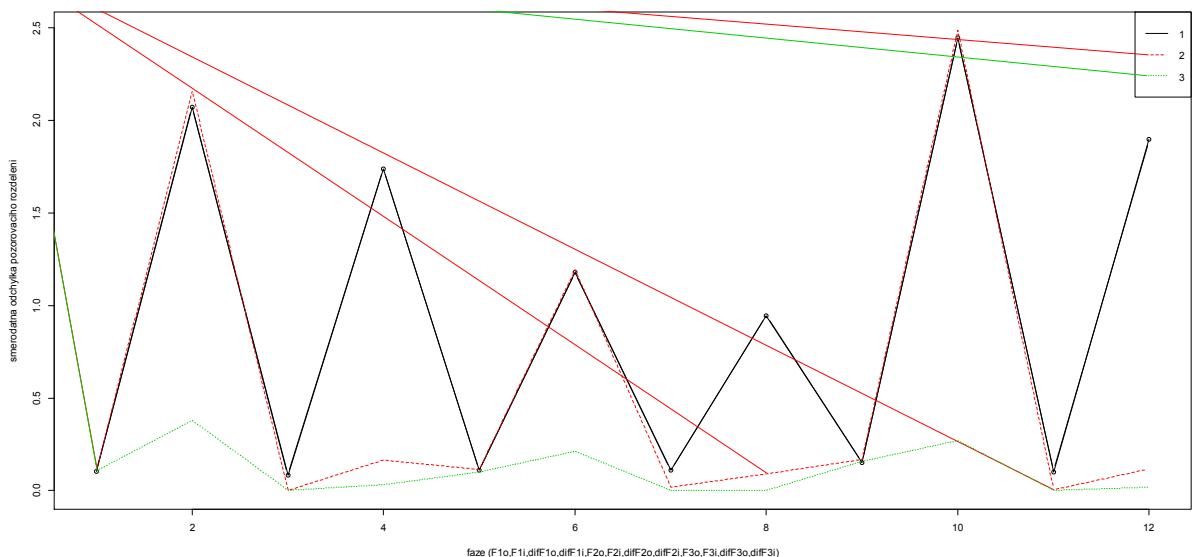
```
> round(a3$HMM$transMat,2)
```

```
[,1] [,2] [,3]
```

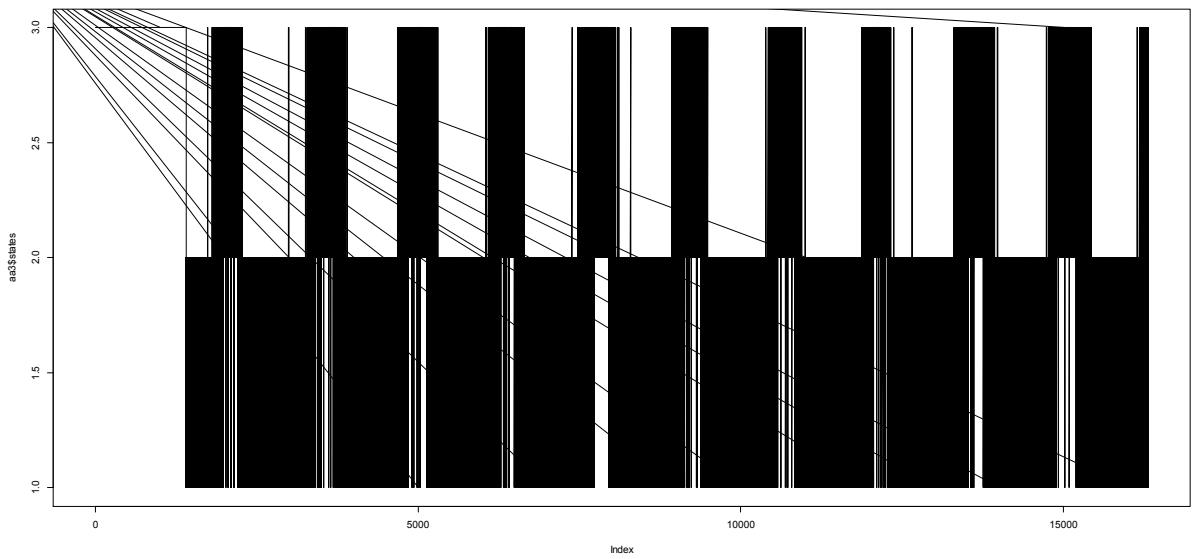
```
[1,] 0.00 0.93 0.07
```

```
[2,] 0.58 0.21 0.20
```

```
[3,] 0.08 0.30 0.62
```



Viterbiho stavy:



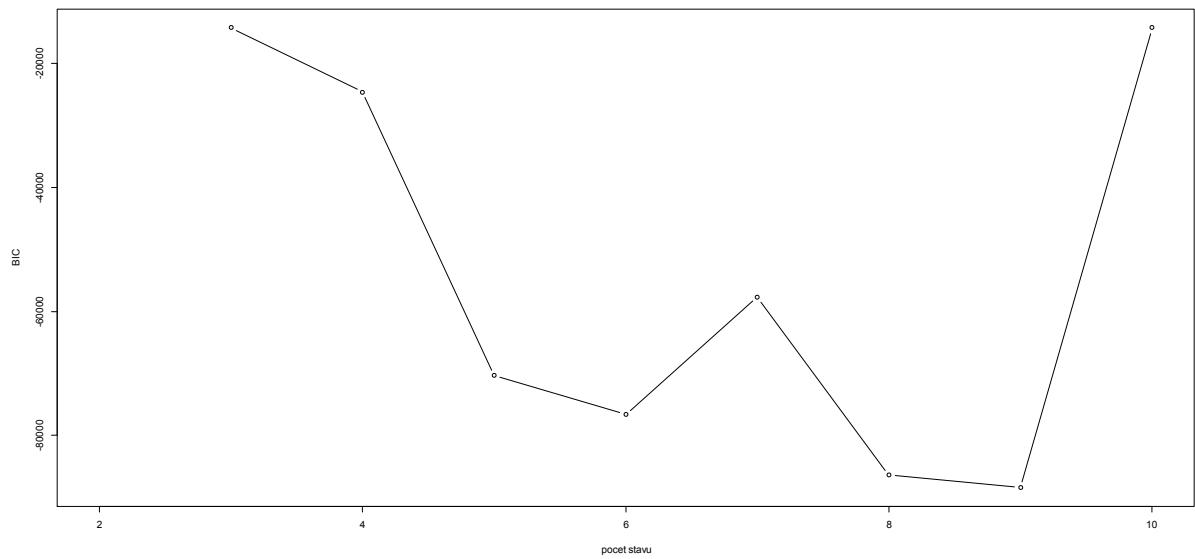
4 Praha Smíchov, hidden Markov chain modely

4.1 Obsazenosti+intenzity na Dstop detektorech

4.1.1 K014

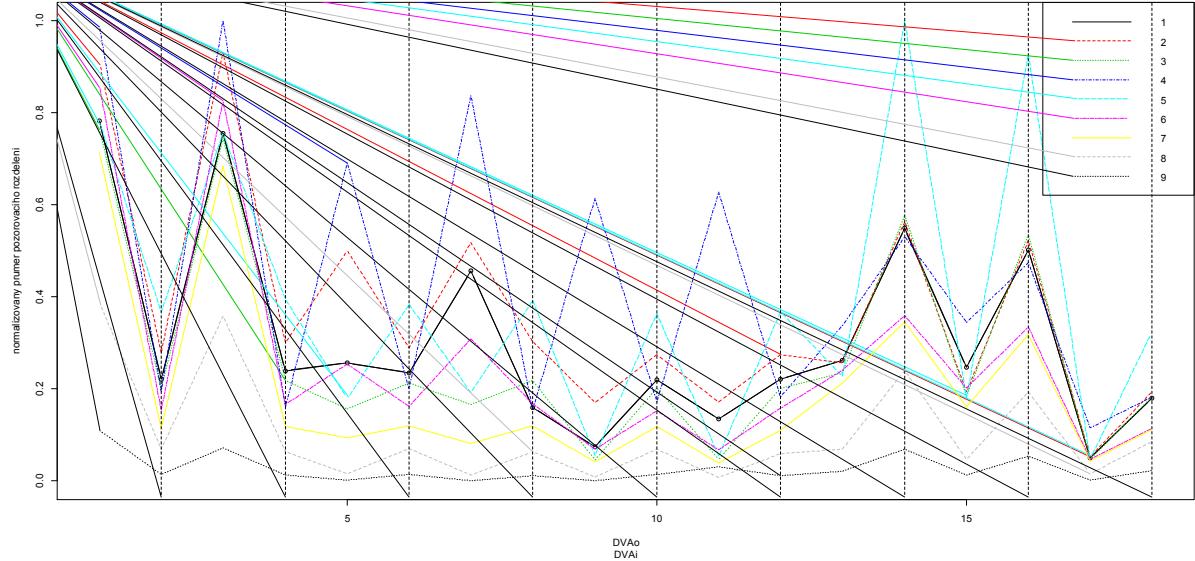
4.1.1.1 Obsazenosti+intenzity na Dstop detektorech (18 rozměrný vektor pozorování, "DVAo" "DVAi" "DVAao" "DVAai" "DVA1o" "DVA1i" "DVA1ao" "DVA1ai" "DVS15o" "DVS15i" "DVS16o" "DVS16i" "DVBo" "DVBi" "DVBao" "DVBAi" "DVBbo" "DVBbi")

4.1.1.1.1 BIC volba rozměru stavu



4.1.1.1.2 Dimenze stavu 9

Průměry pozorovacího rozdělení:



Přechodová matică:

```
> round(a9$HMM$transMat,2)
```

```
[.1] [.2] [.3] [.4] [.5] [.6] [.7] [.8] [.9]
```

```
[1,] 0.48 0.11 0.33 0.05 0.00 0.00 0.00 0.02 0.00
```

[2,] 0.03 0.57 0.35 0.06 0.00 0.00 0.00 0.00 0.00

[3,] 0.02 0.03 0.94 0.00 0.00 0.00 0.00 0.01 0.00

[4,] 0.05 0.04 0.03 0.81 0.04 0.01 0.01 0.01 0.01

[5,] 0.00 0.00 0.00 0.01 0.00 0.47 0.48 0.04 0.00

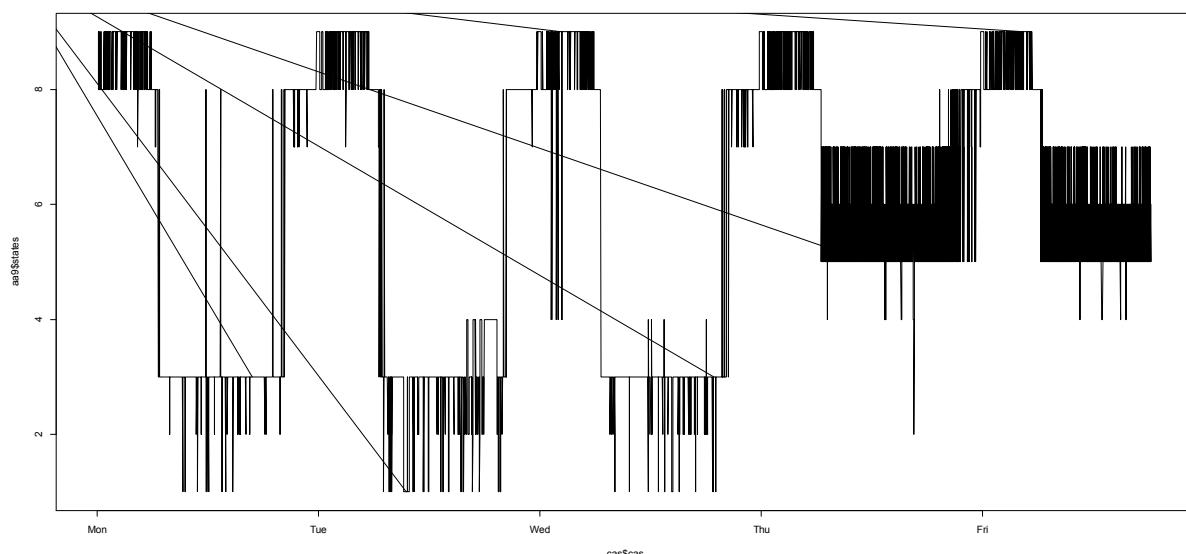
[6,] 0.00 0.00 0.00 0.00 0.49 0.50 0.00 0.00 0.00

[7,] 0.00 0.00 0.00 0.00 0.45 0.00 0.50 0.04 0.00

[8,] 0.00 0.00 0.01 0.00 0.02 0.00 0.02 0.83 0.12

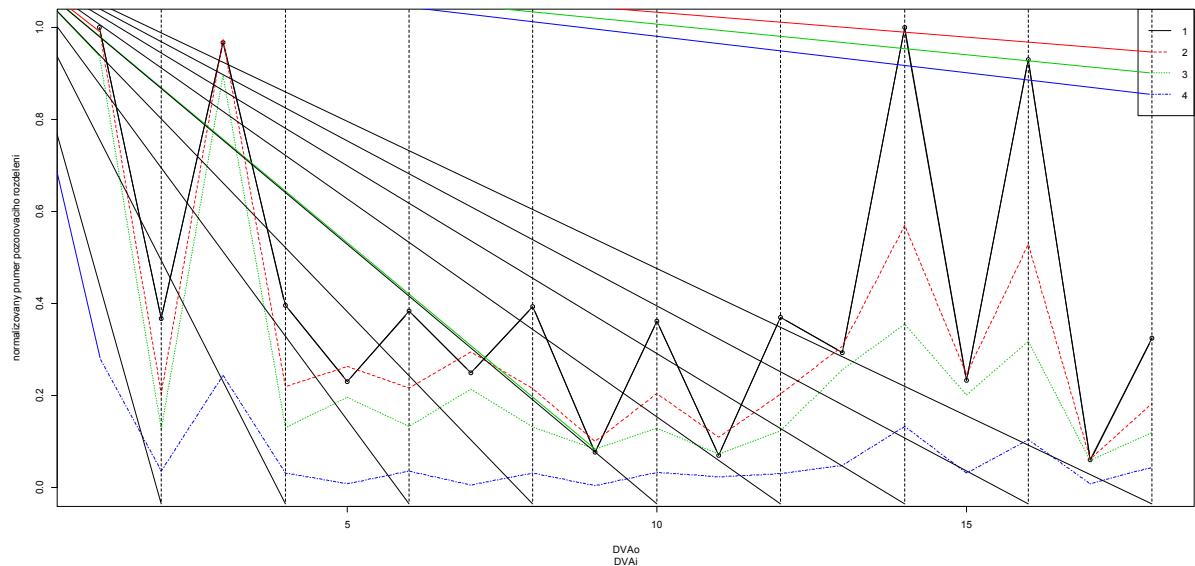
[9,] 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.16 0.84

Viterbiho stavů:



4.1.1.3 Dimenze stavu 4

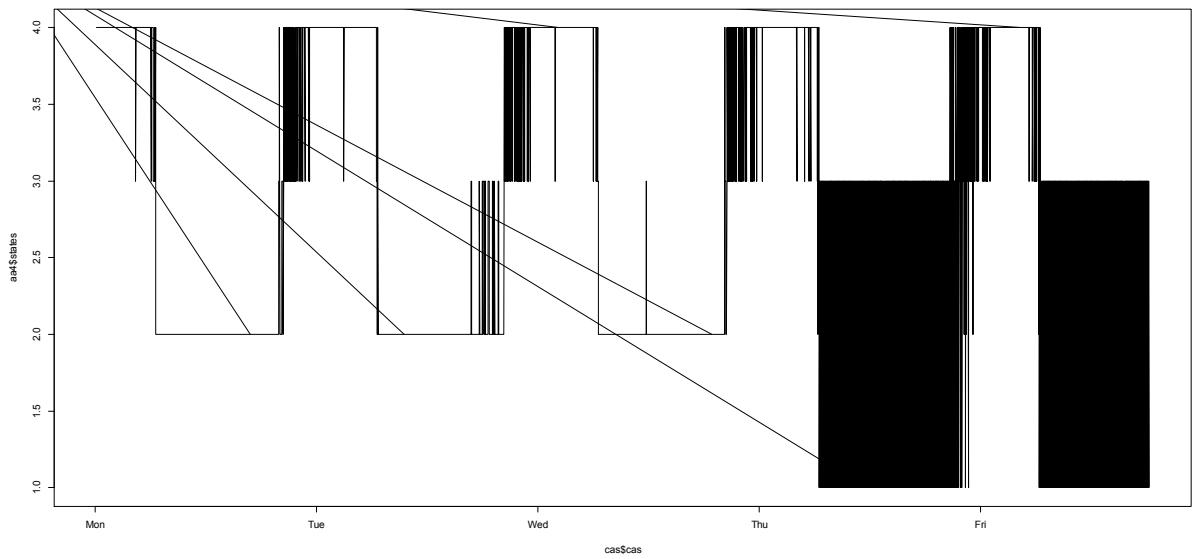
Průměry pozorovacího rozdělení:



Přechodová matică:

```
> round(a4$HMM$transMat,2)
[,1] [,2] [,3] [,4]
[1,] 0.00 0.01 0.98 0.01
[2,] 0.00 0.98 0.01 0.01
[3,] 0.36 0.02 0.52 0.10
[4,] 0.00 0.01 0.06 0.93
```

Viterbiho stavy:

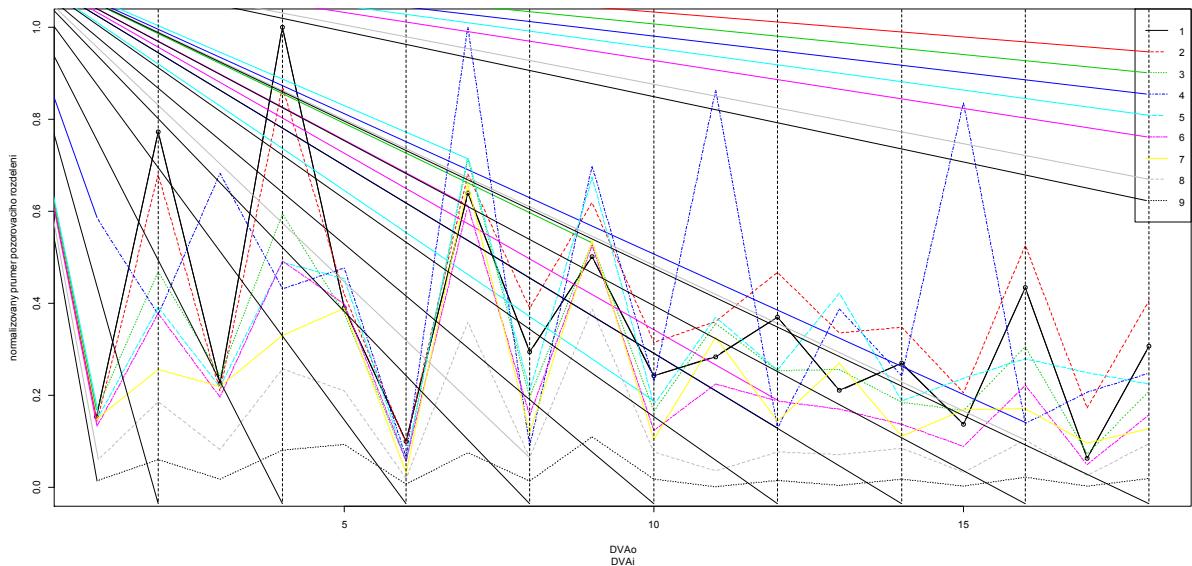


4.1.2 K015

4.1.2.1 Obsazenosti+intenzity na Dstop detektorech (18 rozměrný vektor pozorování, "DVAo" "DVAi" "DVAAo" "DVAAi" "DVCo" "DVCi" "DVDo" "DVDi" "DVDAo" "DVDAi" "DVD1o" "DVD1i" "DVD1ao" "DVD1ai" "DVS20o" "DVS20i" "DVS21o" "DVS21i")

4.1.2.1.1 Dimenze stavu 9

Průměry pozorovacího rozdělení:



Přechodová matic:

```
> round(a9$HMM$transMat,2)

[,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9]

[1,] 0.00 0.00 0.00 0.00 0.01 0.02 0.83 0.14 0.00

[2,] 0.00 0.00 0.00 0.01 0.06 0.01 0.85 0.08 0.00

[3,] 0.00 0.00 0.69 0.01 0.14 0.13 0.00 0.03 0.00

[4,] 0.01 0.00 0.01 0.93 0.02 0.04 0.00 0.00 0.00

[5,] 0.00 0.02 0.11 0.01 0.67 0.18 0.00 0.01 0.00

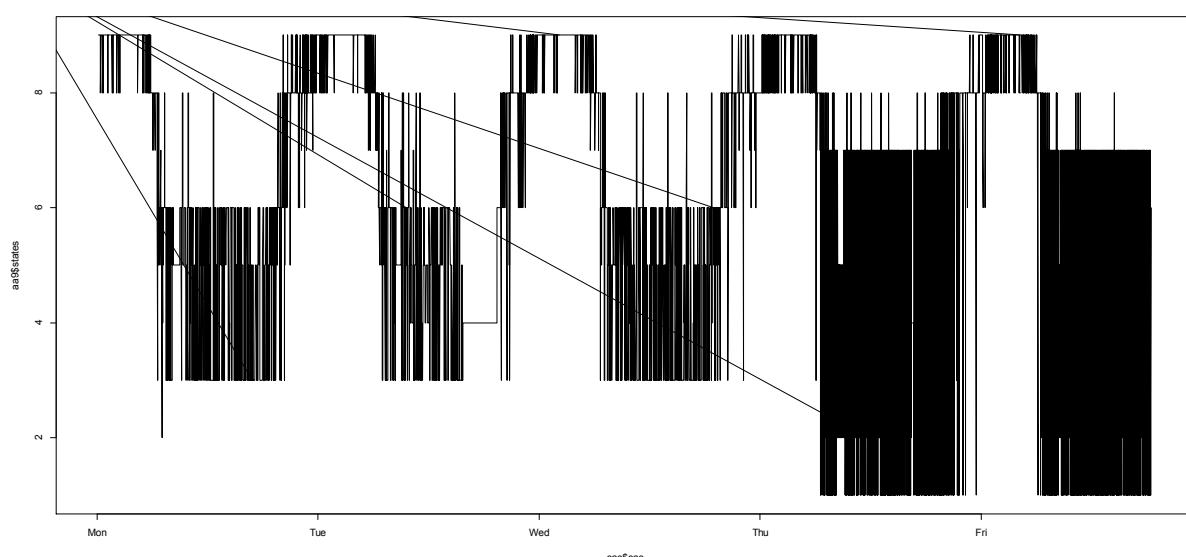
[6,] 0.01 0.00 0.13 0.01 0.10 0.69 0.00 0.06 0.00

[7,] 0.30 0.16 0.01 0.00 0.00 0.00 0.50 0.02 0.00

[8,] 0.03 0.01 0.02 0.00 0.00 0.05 0.02 0.73 0.15

[9,] 0.00 0.00 0.00 0.00 0.00 0.00 0.00 0.12 0.88
```

Viterbiho stavů:



4.1.2.1.2 Dimenze stavu 4

Odhadovací algoritmus (Baum-Welshova typu) nekonverguje.

5 Korekce na délku zelené

Úvaha o obsazenosti a intenzitě na křížovatce (pro případnou korekci intenzit a/nebo obsazeností na délku zelené v daném časovém intervalu agregace, např. minutovém).

Intenzita:

$$I_R = I \cdot Z + 0 \cdot (\Delta - Z)$$

takže: $I = \frac{I_R}{Z}$

Obsazenost:

$$O_R = \frac{O \cdot Z + O_S \cdot (\Delta - Z)}{\Delta}$$

takže: $O = \frac{O_R \cdot \Delta - O_S \cdot (\Delta - Z)}{Z}$

pro 1 minutový interval: $O = \frac{O_R - O_S \cdot (1 - Z)}{Z}$

pro extrémní (asi nerealistické) $O_S = 0$: $O = \frac{O_R}{Z}$ (horní mez)

druhý extrém $O_S = 1$: $O = \frac{O_R}{Z} - \frac{(1 - Z)}{Z}$ (spodní mez)

Kde:

I_R je pozorovaná (rough) intenzita (v časovém intervalu délky Δ)

I je „skutečná“ intenzita (během doby možného průjezdu, tj. zelené)

O_R je pozorovaná (rough) obsazenost (v časovém intervalu délky Δ)

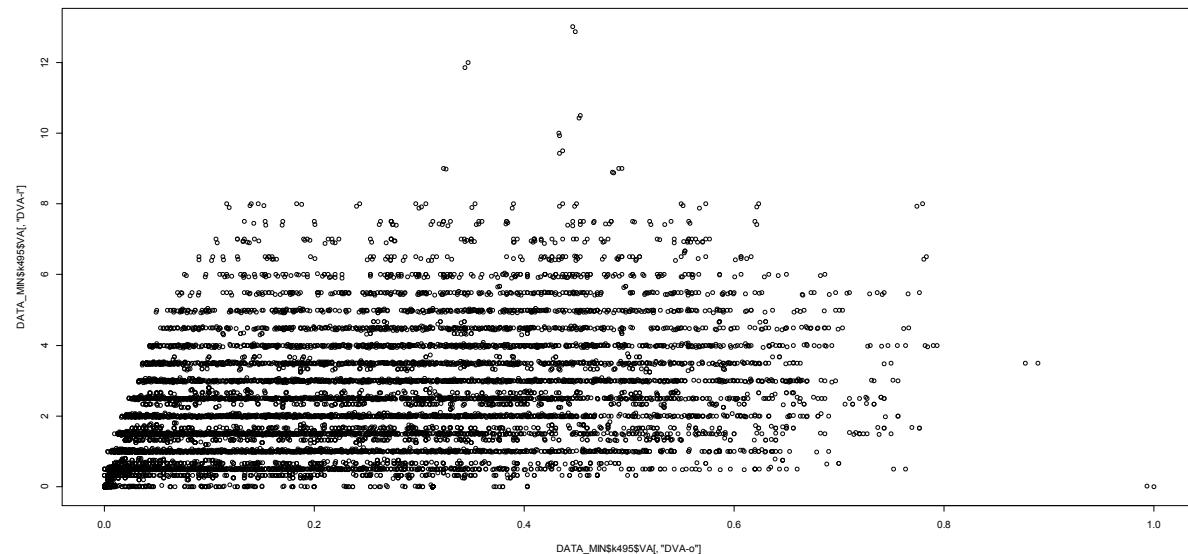
O je „skutečná“ obsazenost (během doby možného průjezdu, tj. zelené)

O_S je (průměrná) obsazenost během doby stání (tj. červené)

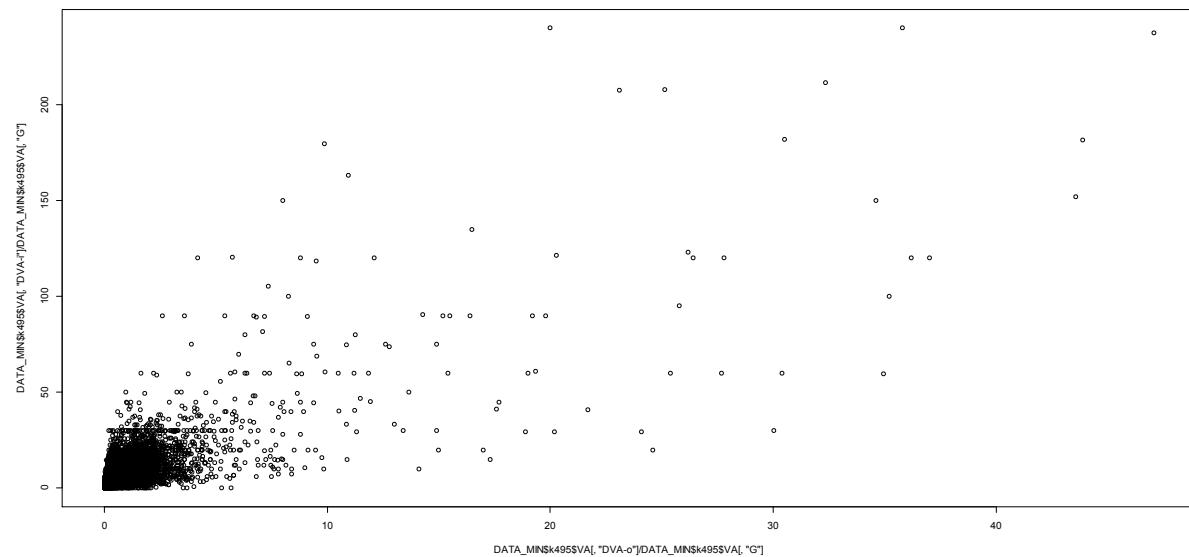
5.1 K495, minutová data, MFD (macroscopic Fundamentals diagram), *Dstop detektor*

5.1.1 A

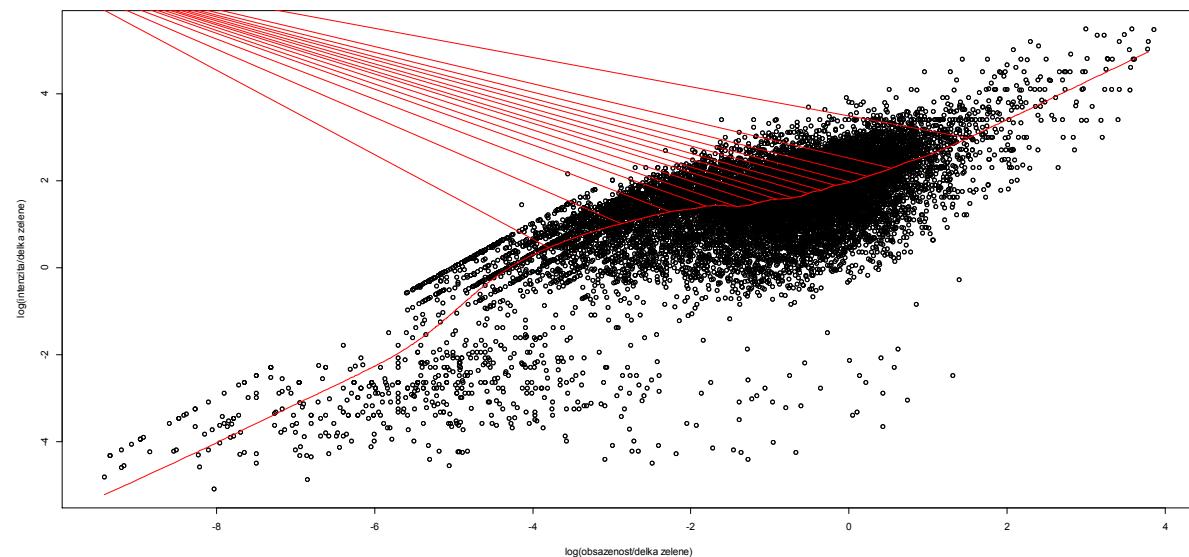
5.1.1.1 Původní data



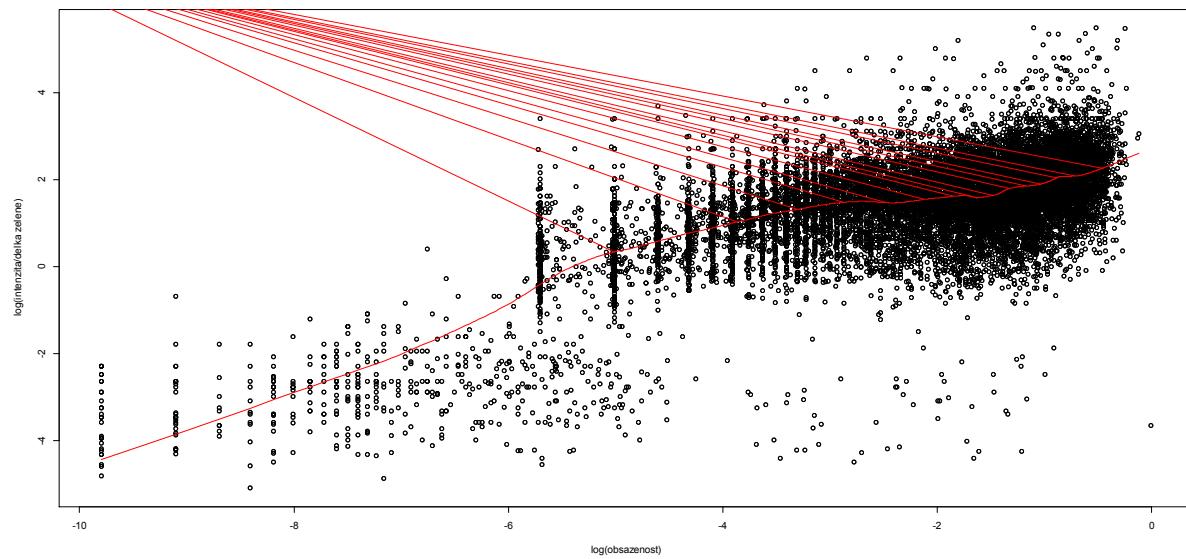
5.1.1.2 Intenzity i obsazenosti vyděleny délkom zelené



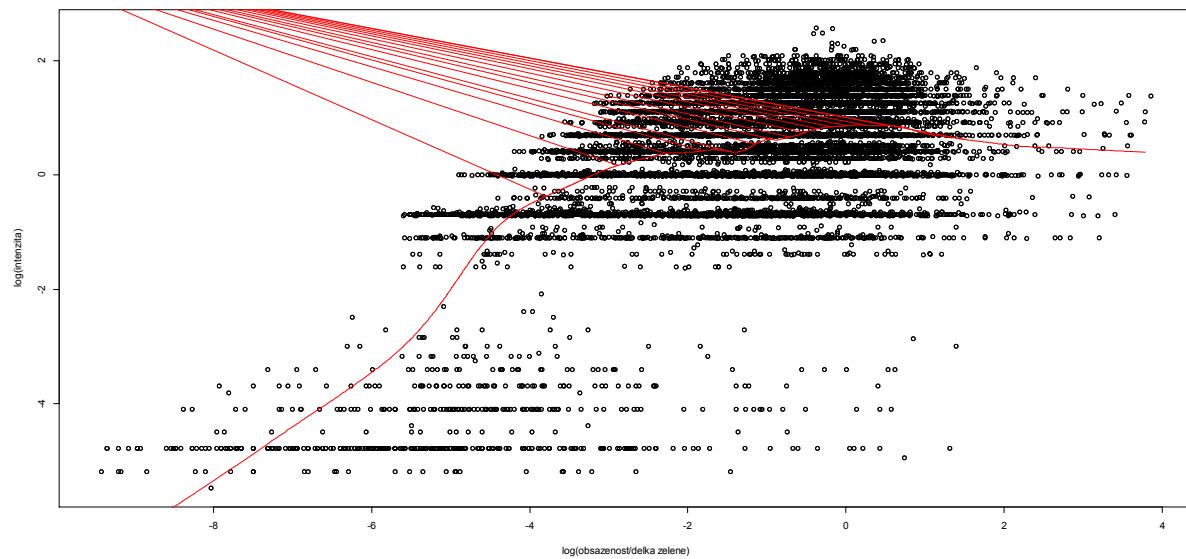
Dtto s oběma osami v logaritmickém měřítku, s loesss smootherem, span=.1:

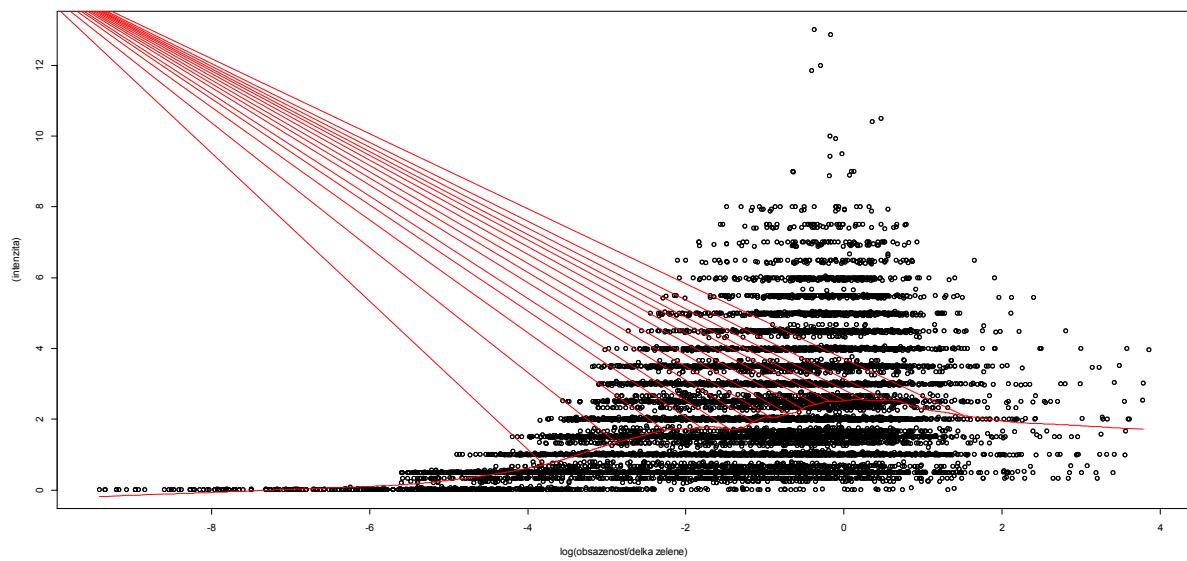
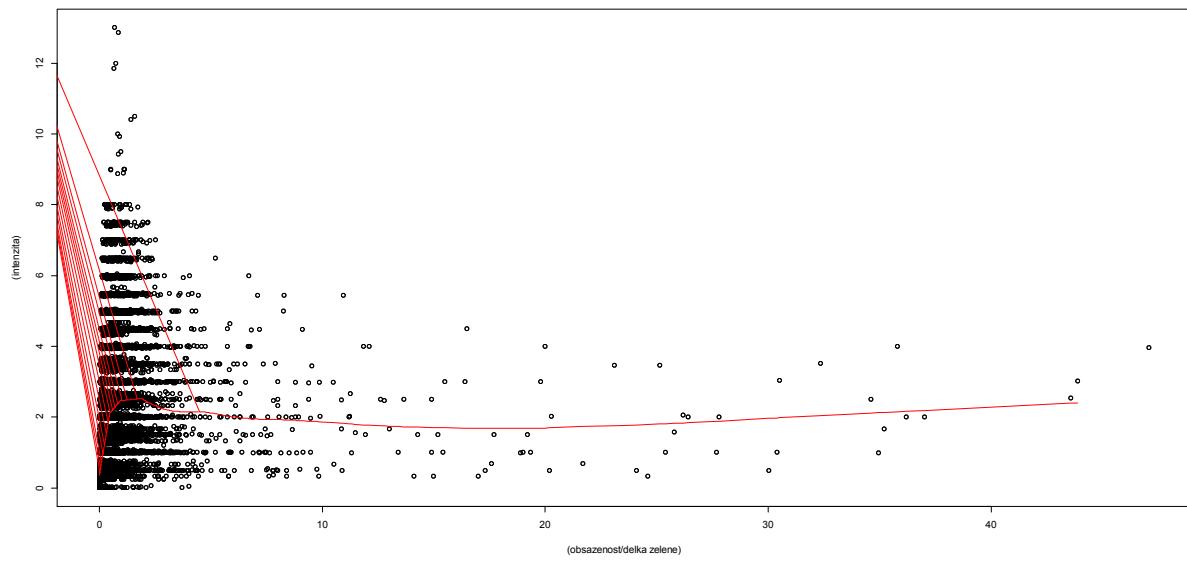


5.1.1.3 Intenzity vyděleny délkou zelené



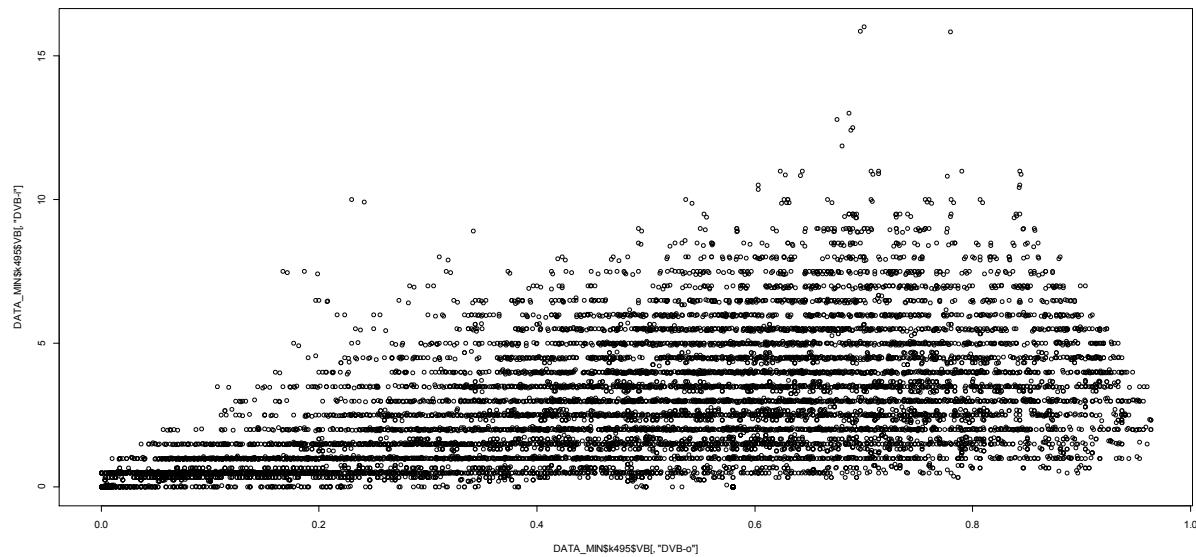
5.1.1.4 Obsazenosti vyděleny délkou zelené



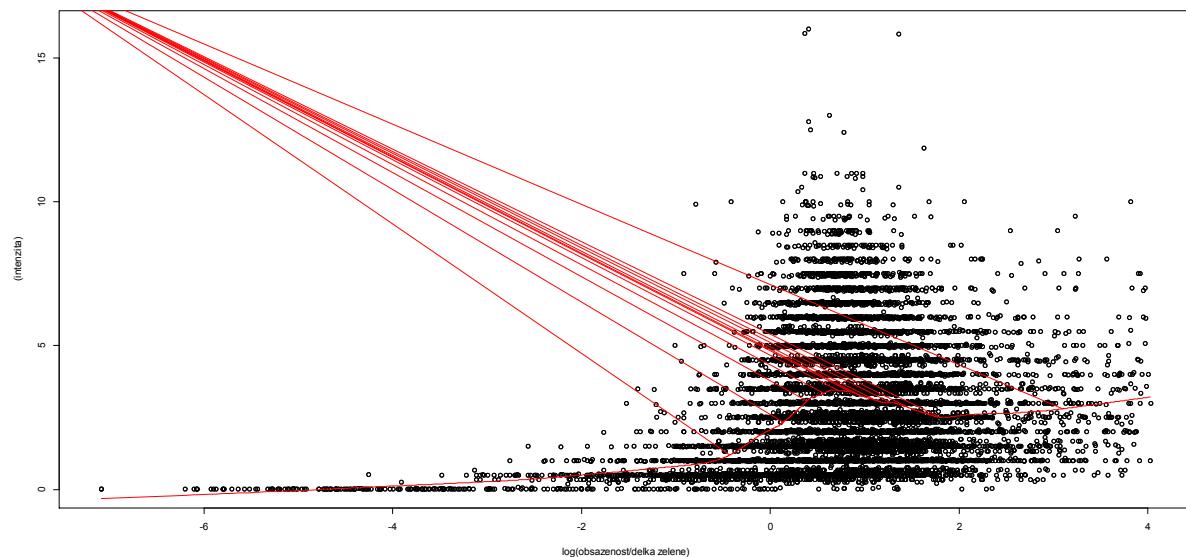


5.1.2 B

5.1.2.1 Původní data

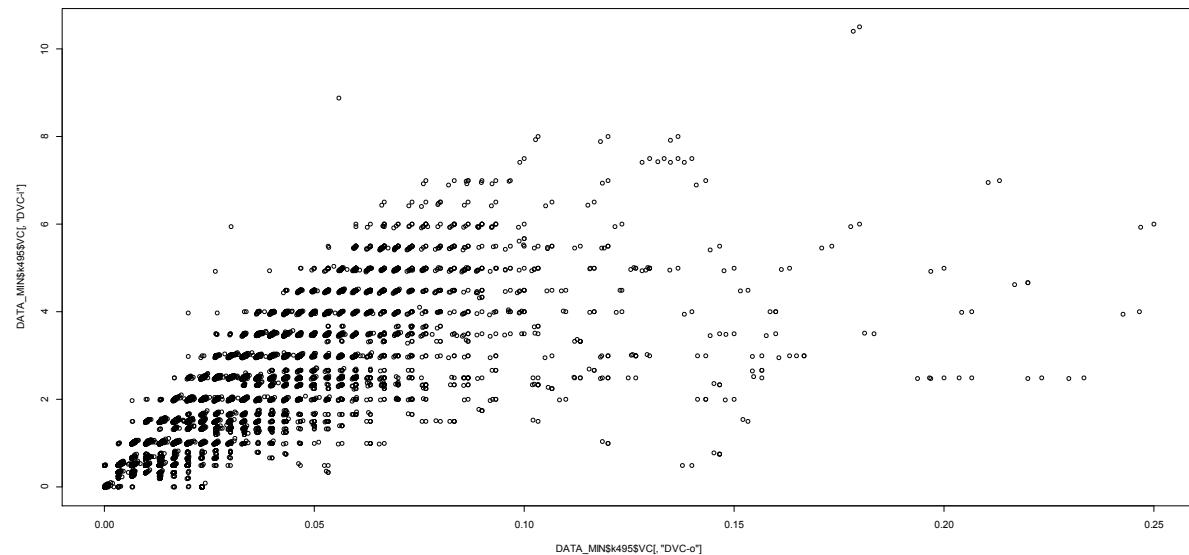


5.1.2.2 Obsazenosti vyděleny délkom zelené

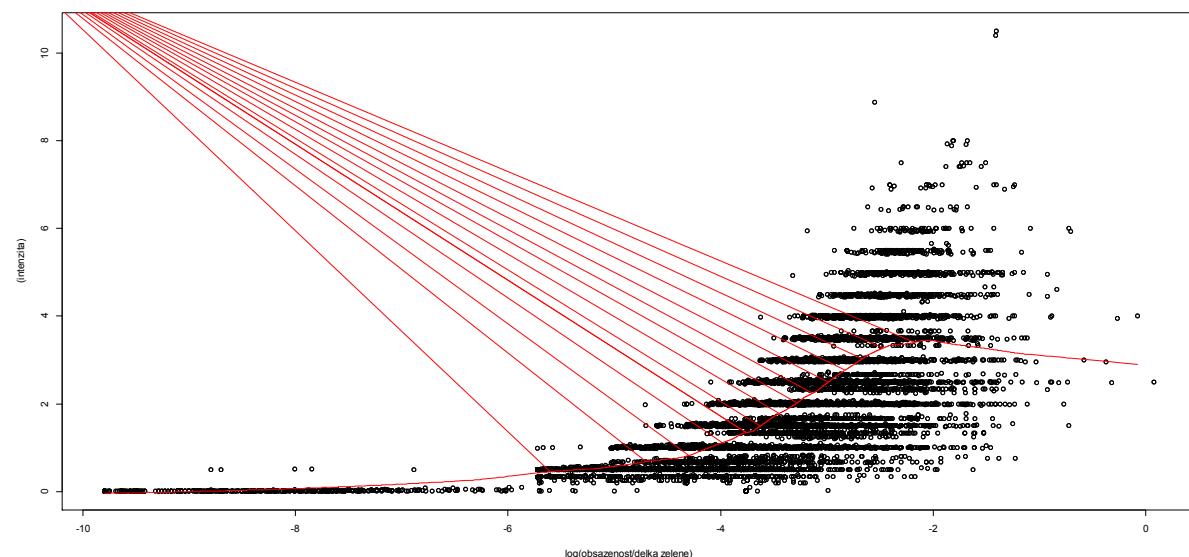


5.1.3 C

5.1.3.1 Původní data

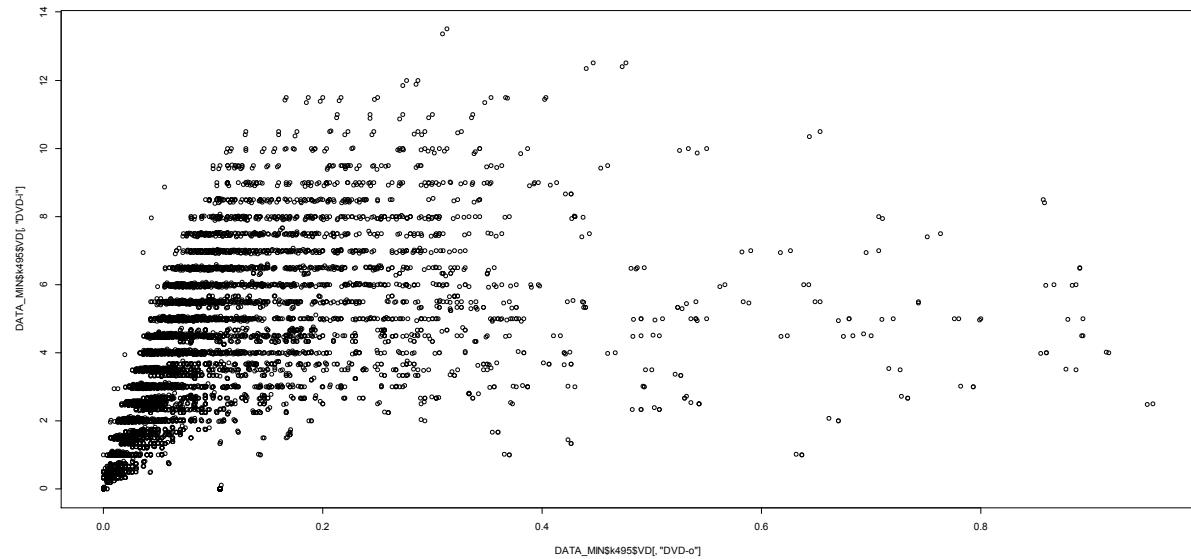


5.1.3.2 Obsazenosti vyděleny délkom zelené

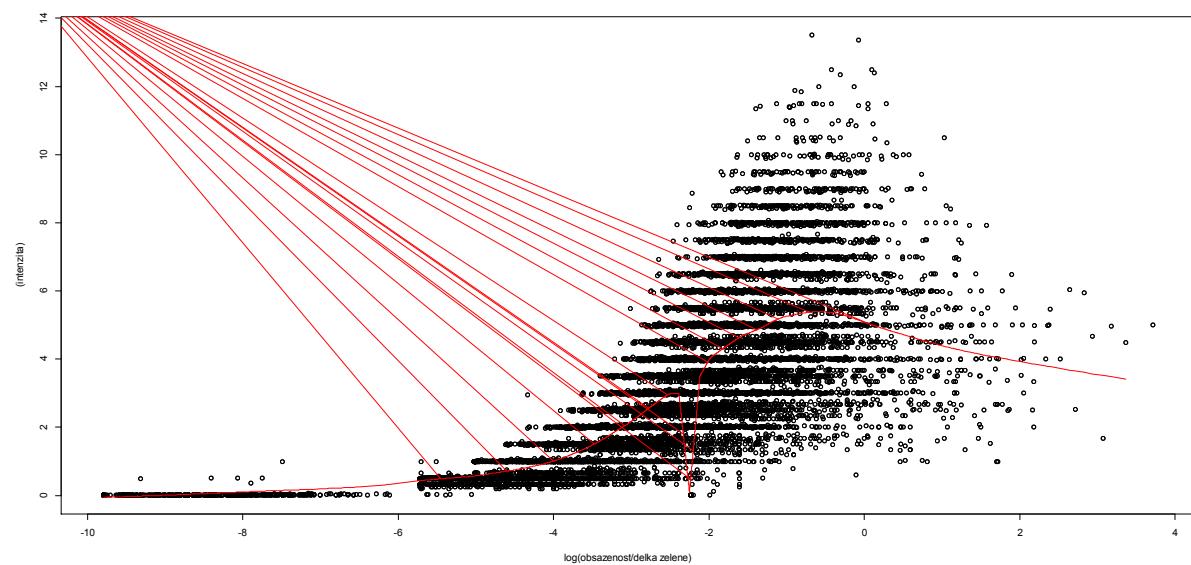


5.1.4 D

5.1.4.1 Původní data

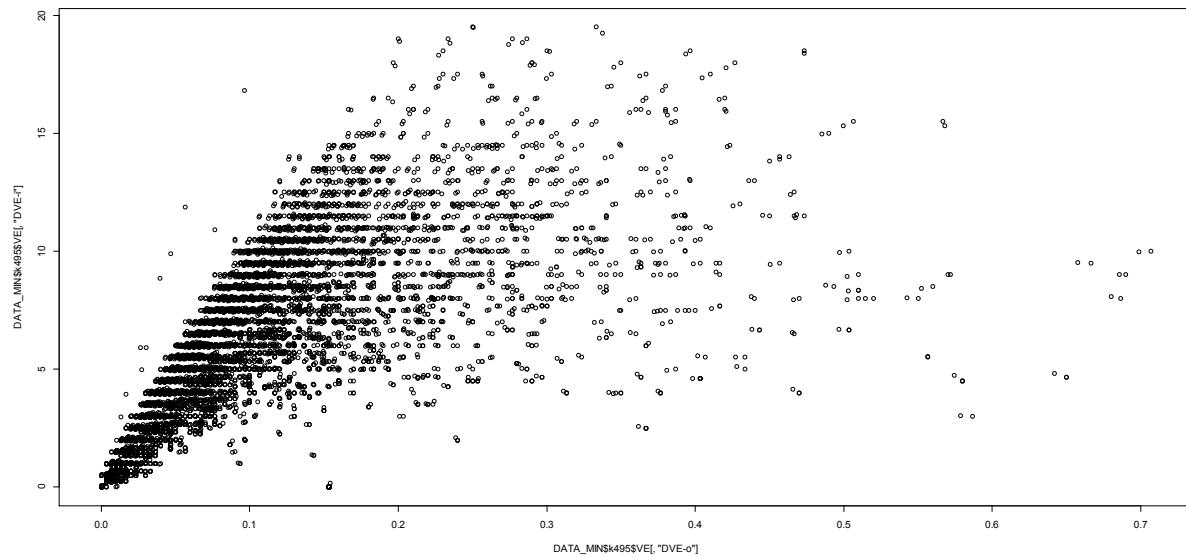


5.1.4.2 Obsazenosti vyděleny délkom zelené

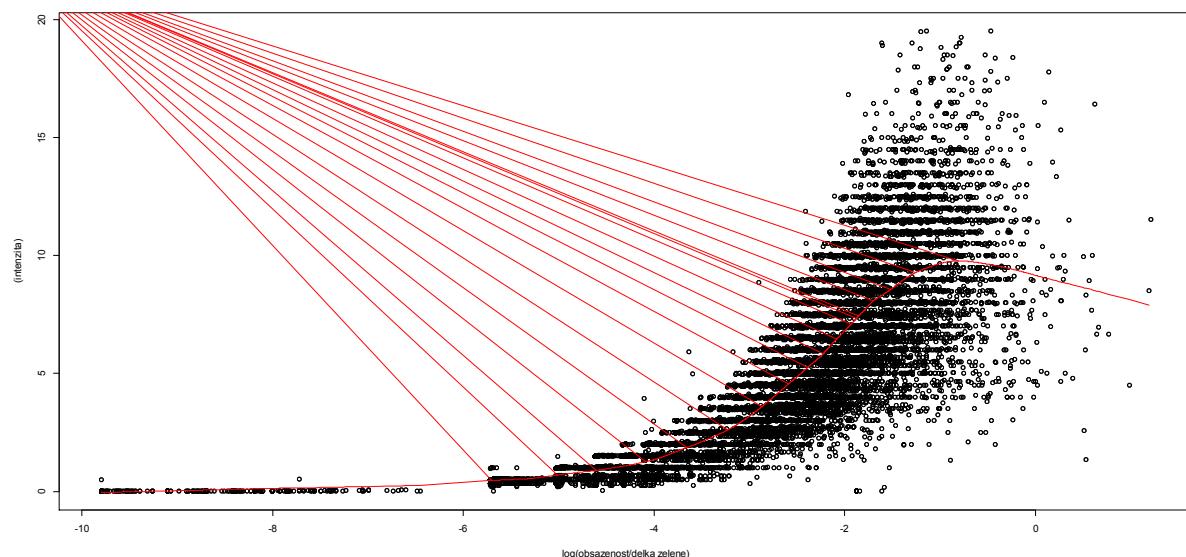


5.1.5 E

5.1.5.1 Původní data

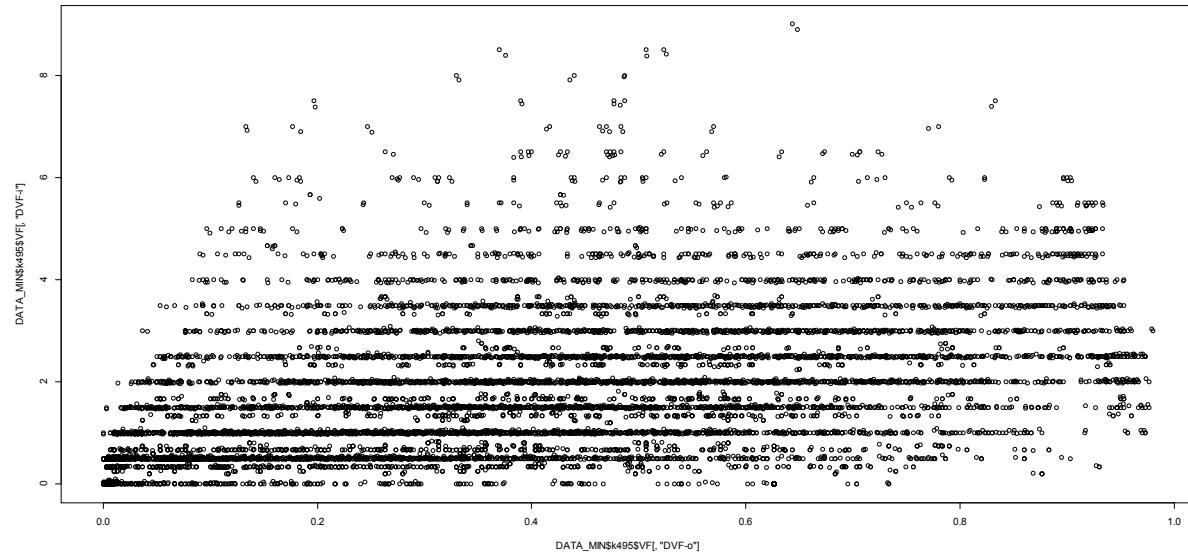


5.1.5.2 Obsazenosti vyděleny délkom zelené

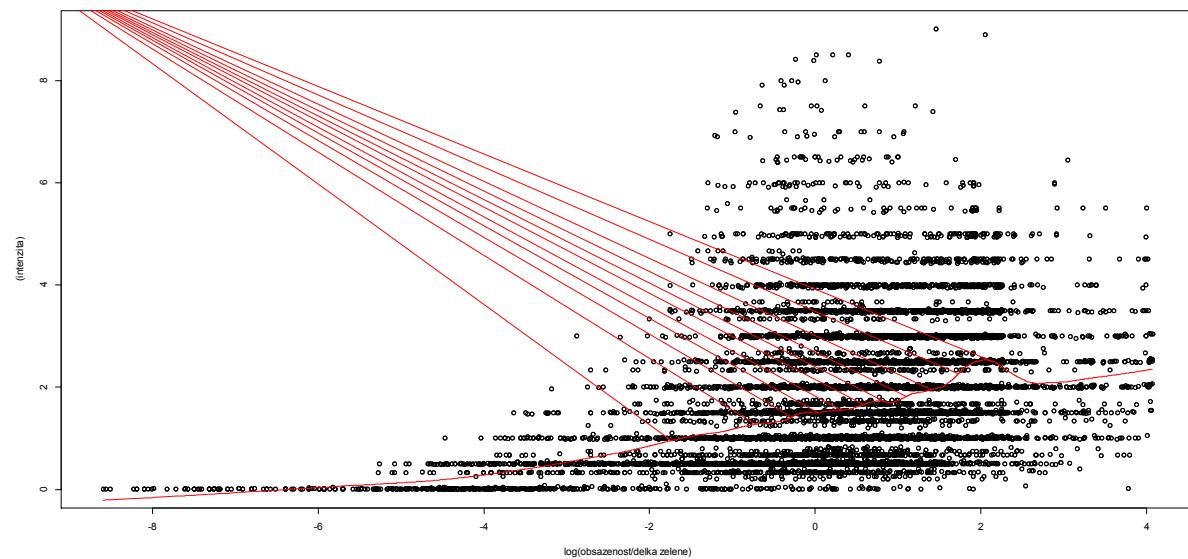


5.1.6 F

5.1.6.1 Původní data



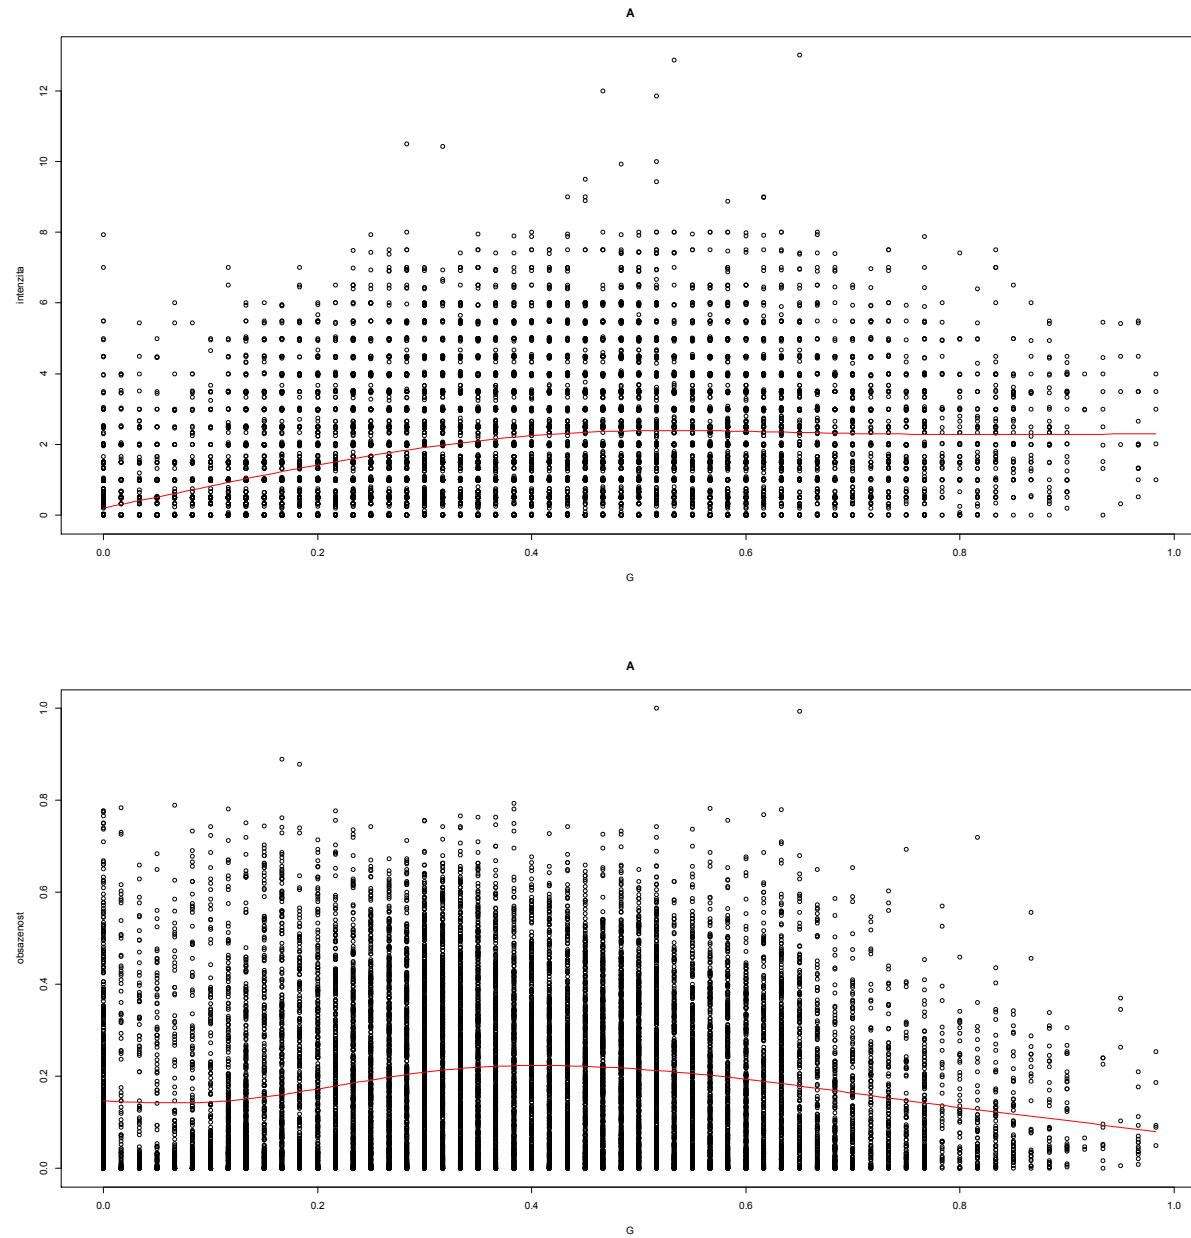
5.1.6.2 Obsazenosti vyděleny délkom zelené



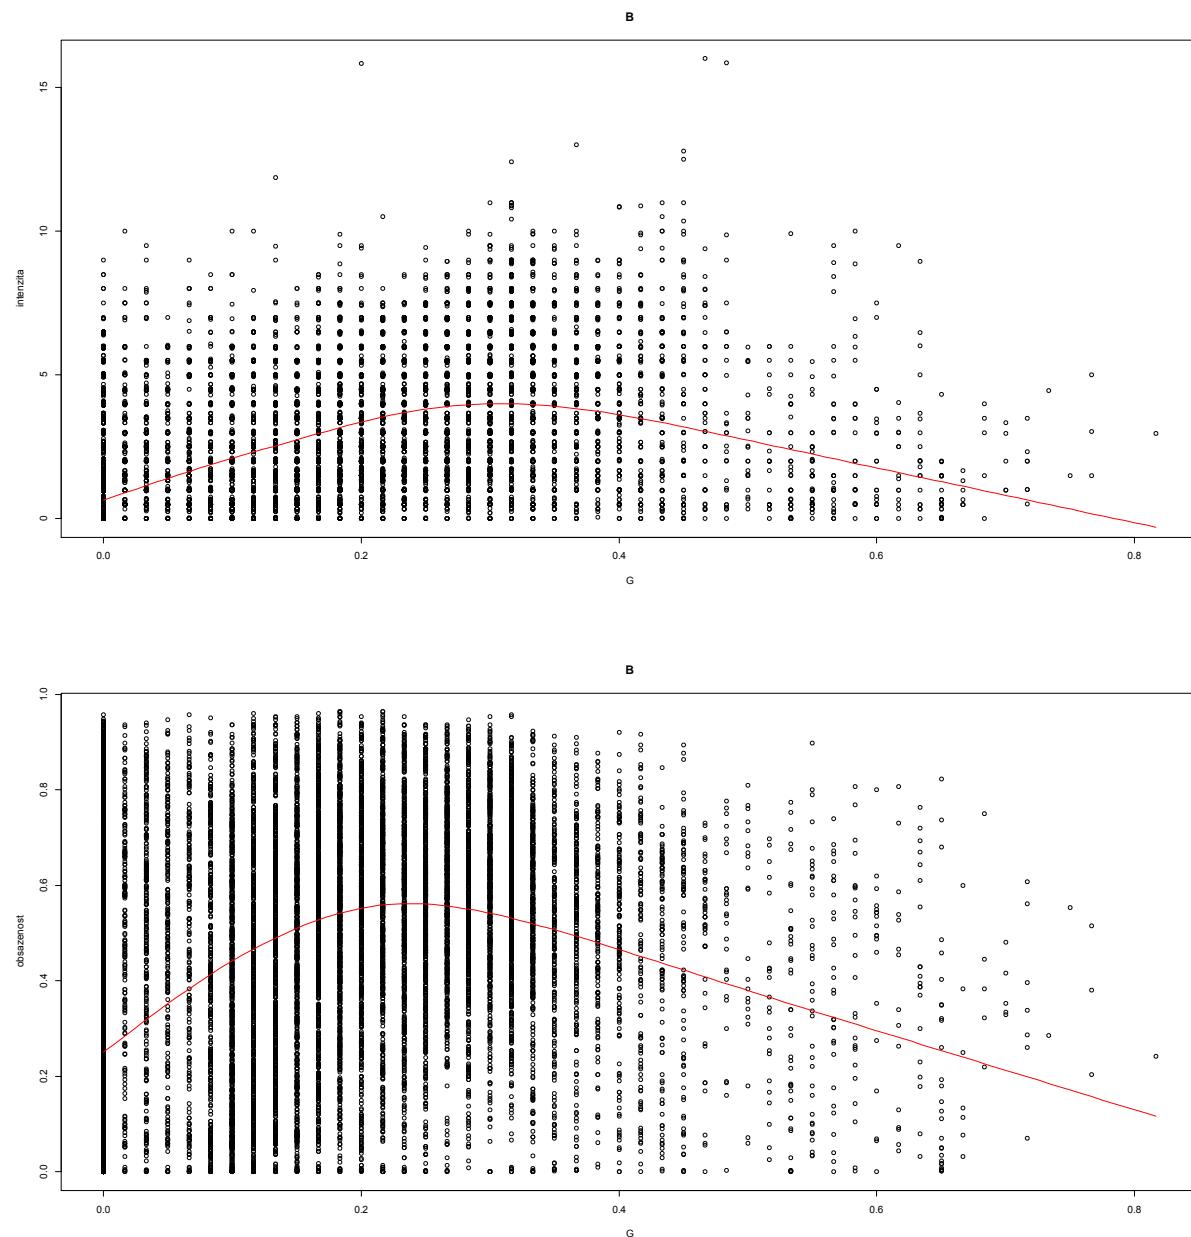
5.2 K495, minutová data, intenzity či obsazenosti vzhledem k délce zelené

Smoothing penalty uměle nastavena na sp=10 (GCV i REML v GAM tedy Generalized additive model algoritmu odhadu vybírájí penalizační koeficient tkterý vede k určitému podhlazení).

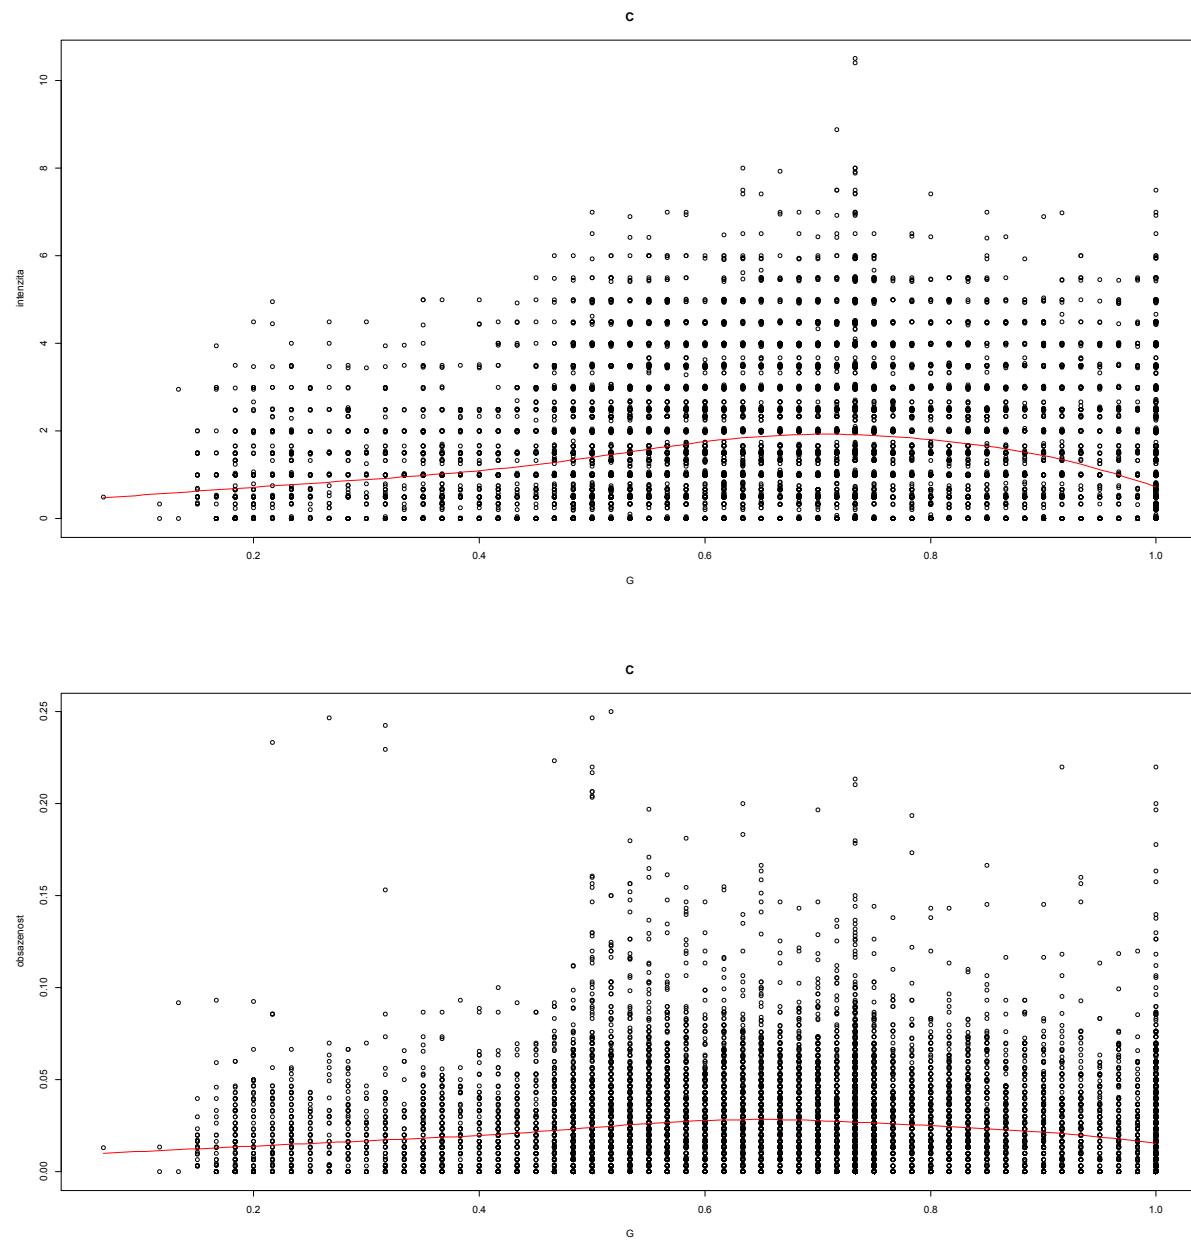
5.2.1 A



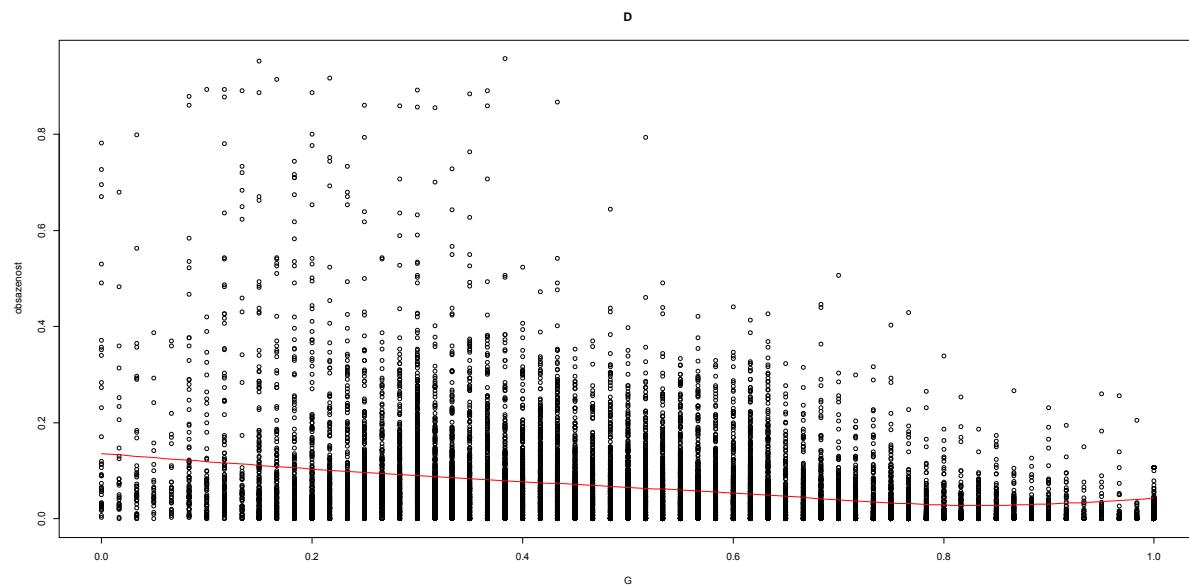
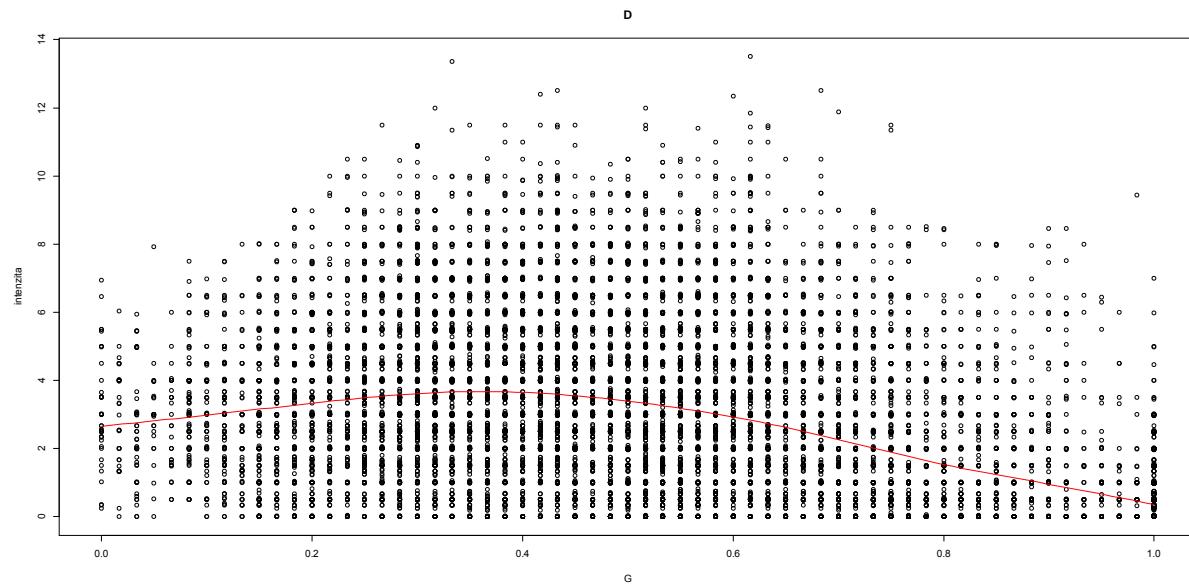
5.2.2 B



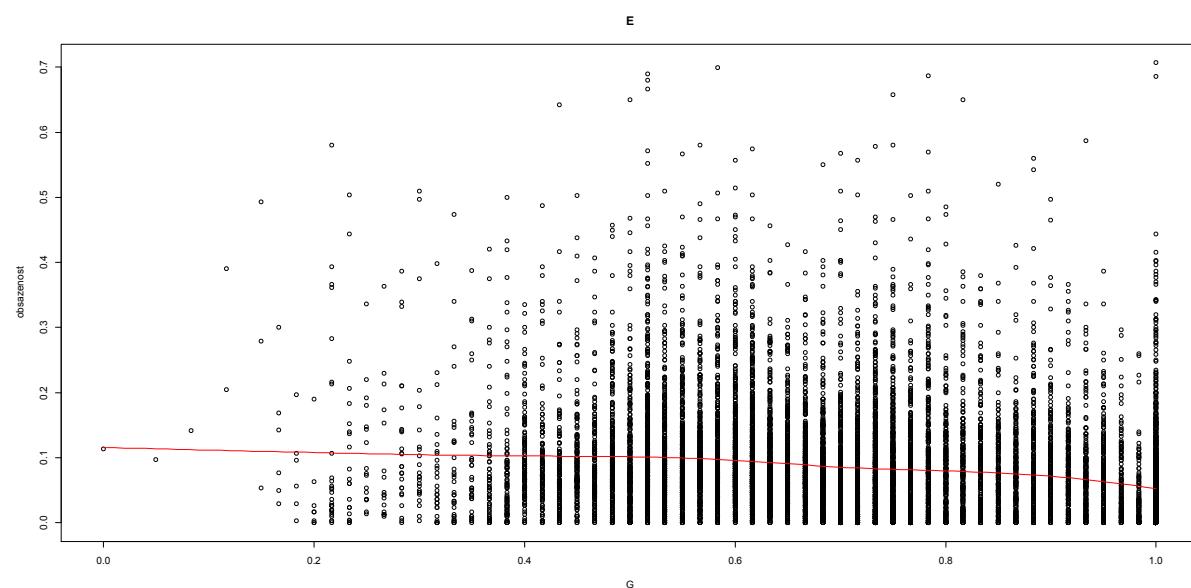
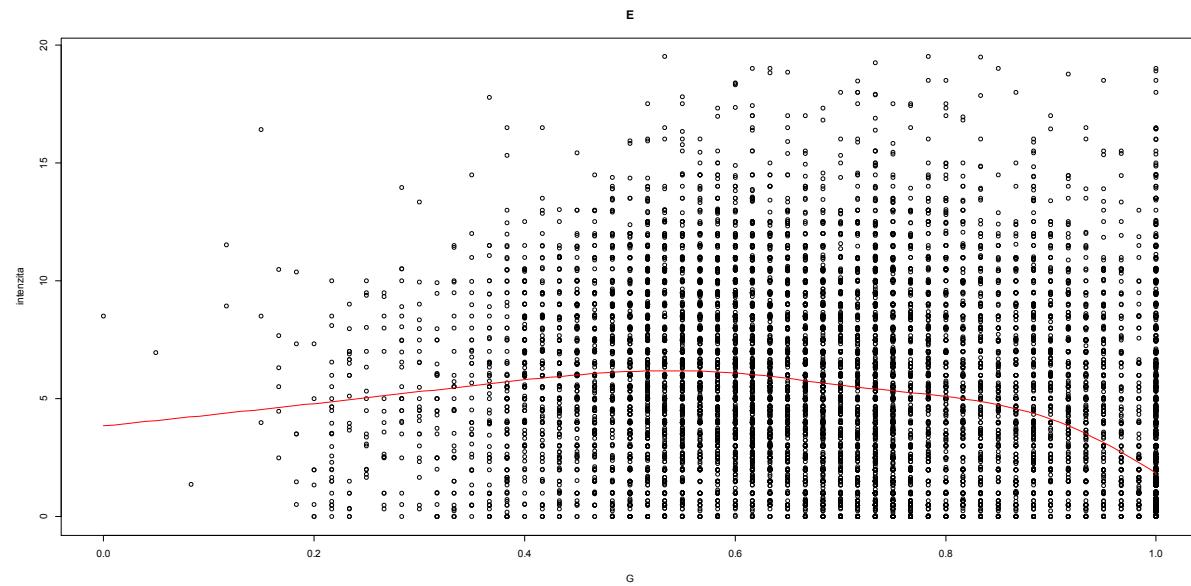
5.2.3 C



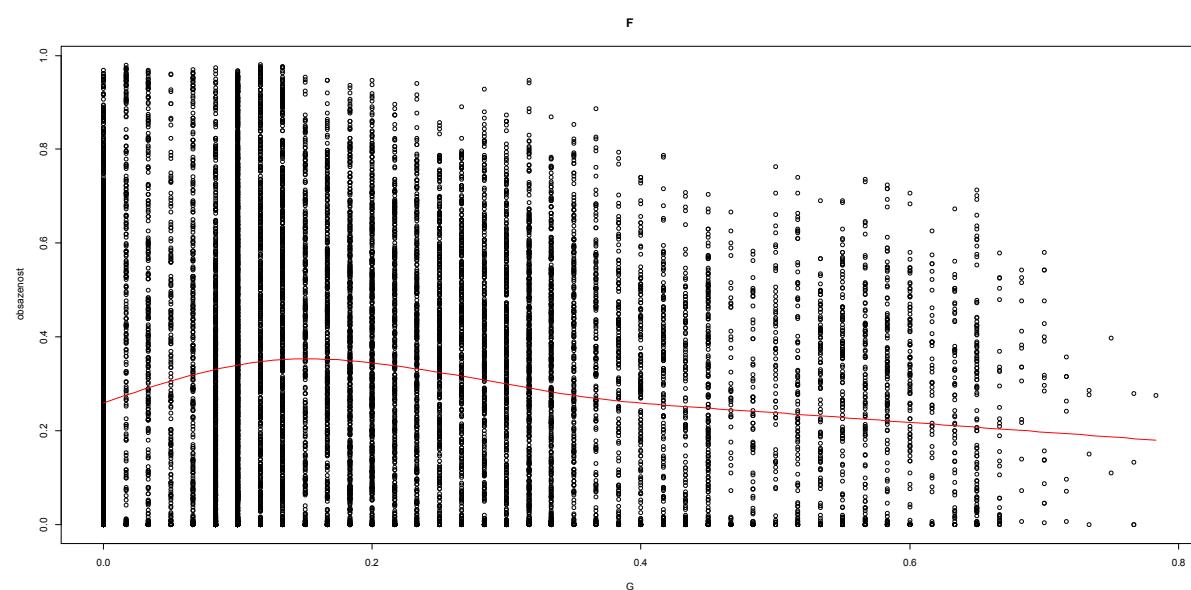
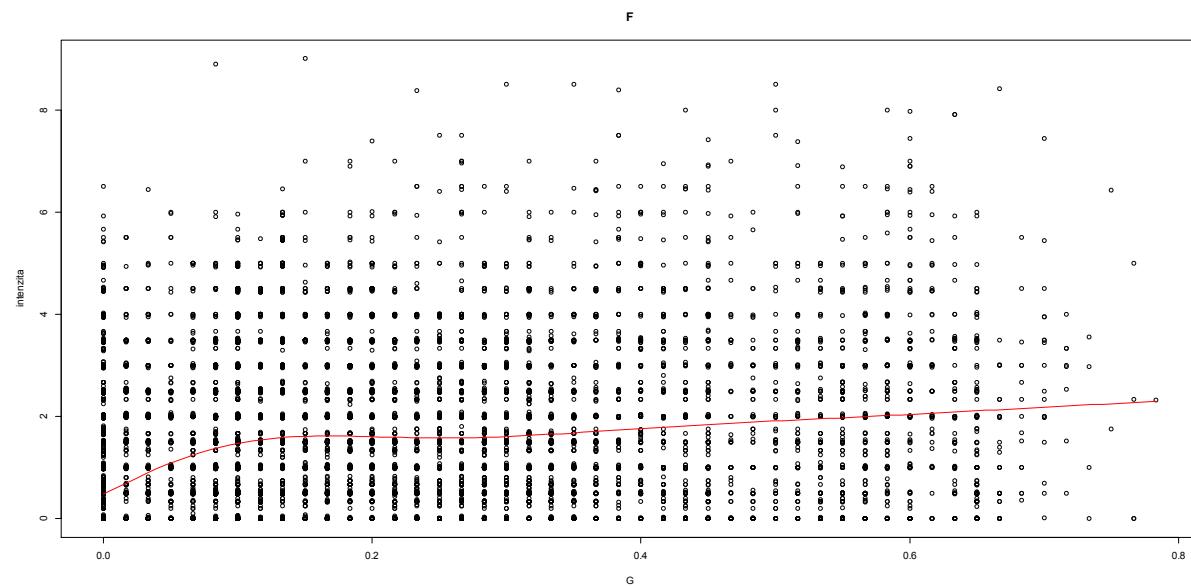
5.2.4 D



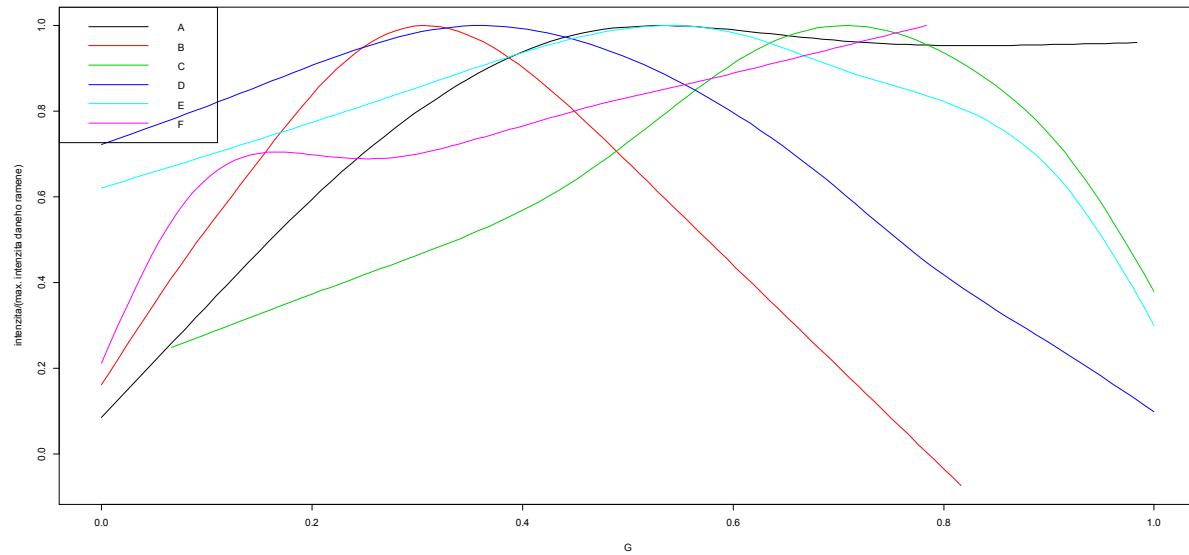
5.2.5 E



5.2.6 F

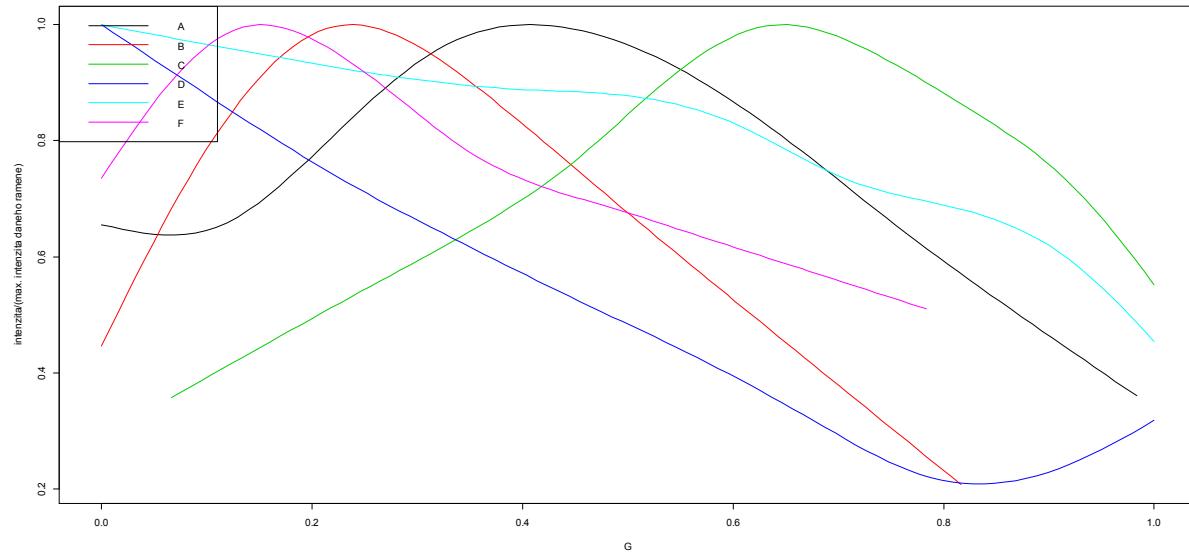


5.2.7 Srovnání směrů



Protisměry se asi mají tendenci chovat podobně (A-F, B-C, D-E).

Směry stejně fáze: F1: C-D-E, F2: A-E-F, F3: A-B-C ne tolik.

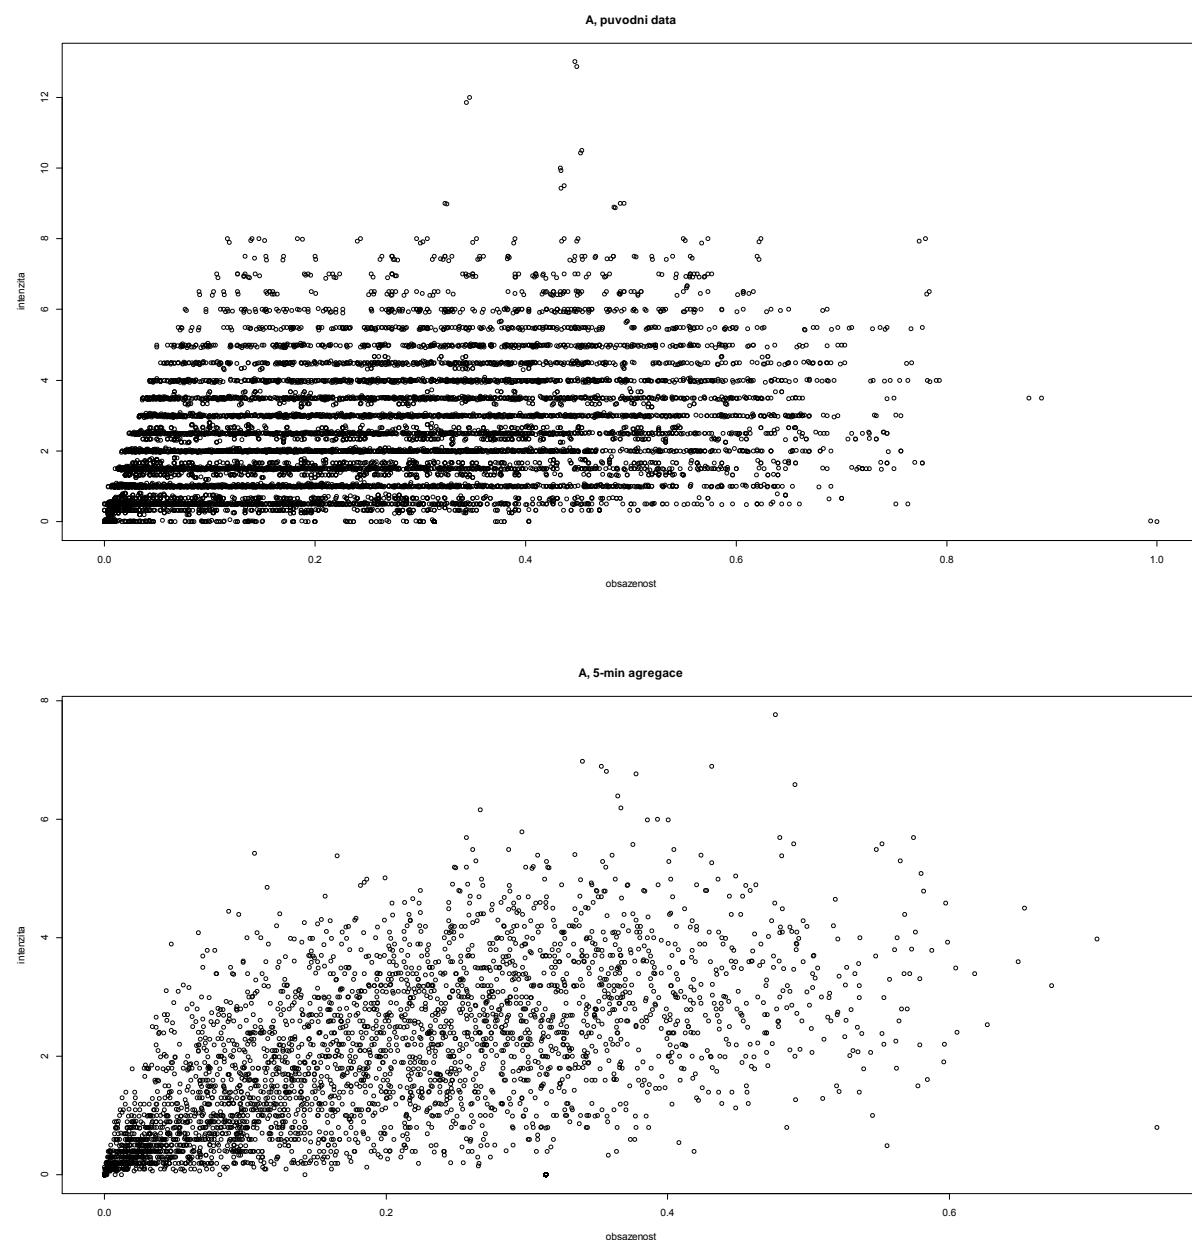


Delší zelená asi obecně vede k nižší obsazenosti ale není to monotonní!!!

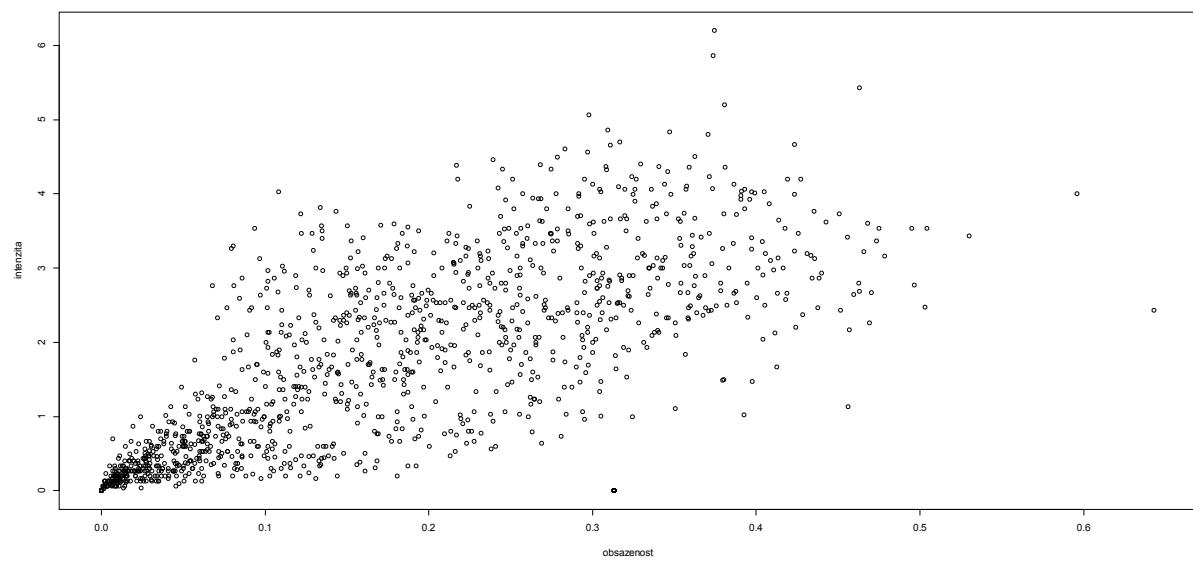
5.3 K495, různě dlouhé agregace, intenzita vs. obsazenost (MFD)

5.3.1 A

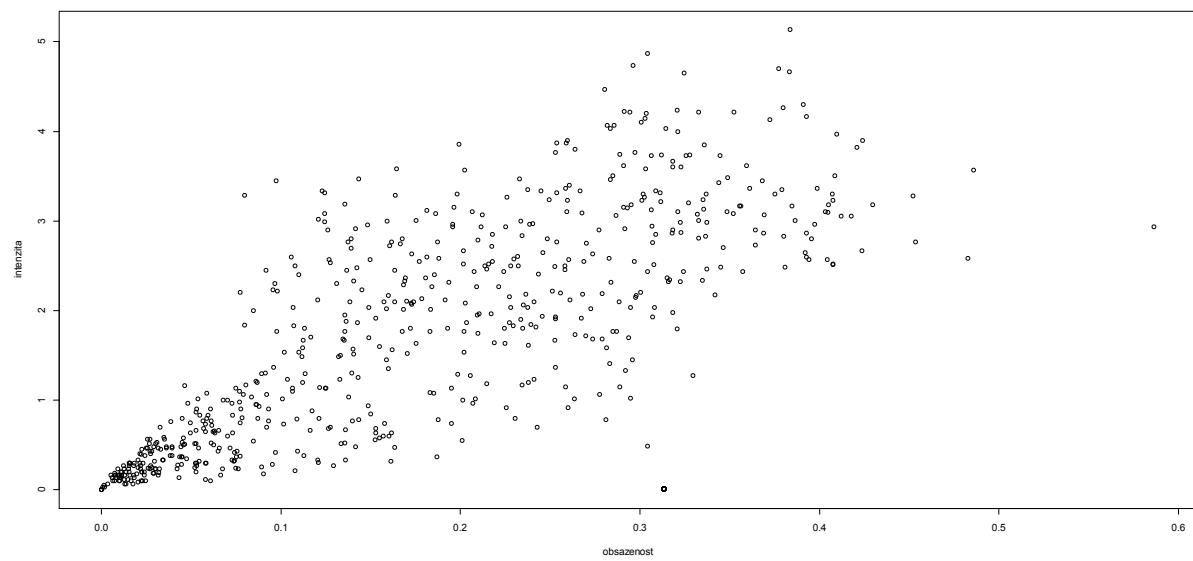
5.3.1.1 Bez dělení intenzity délkou zelené

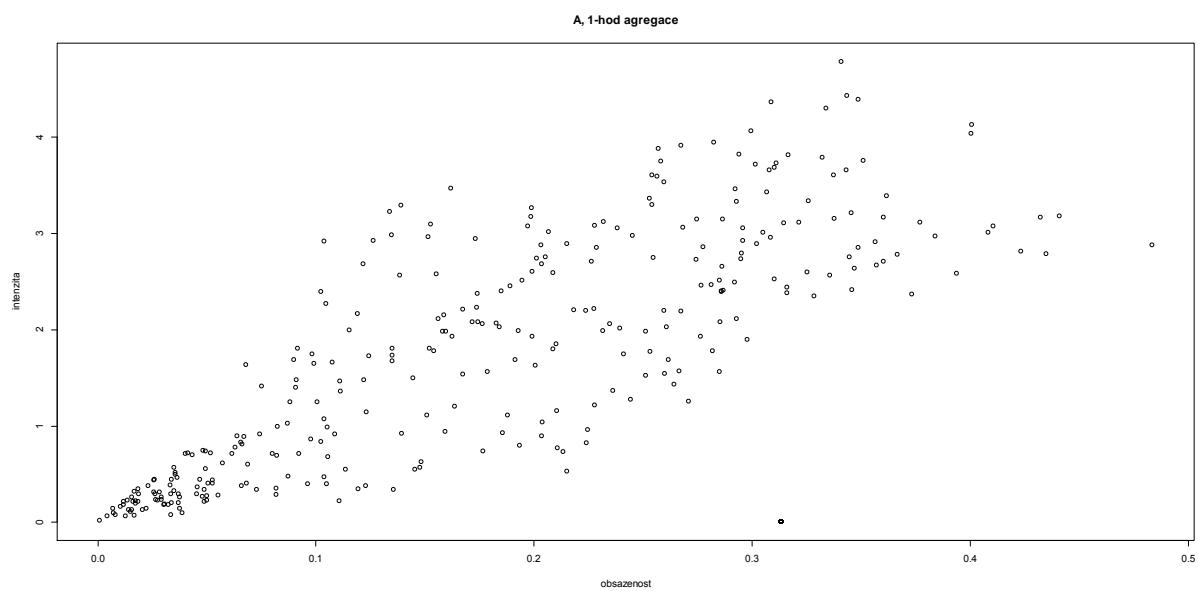


A, 15-min agregace

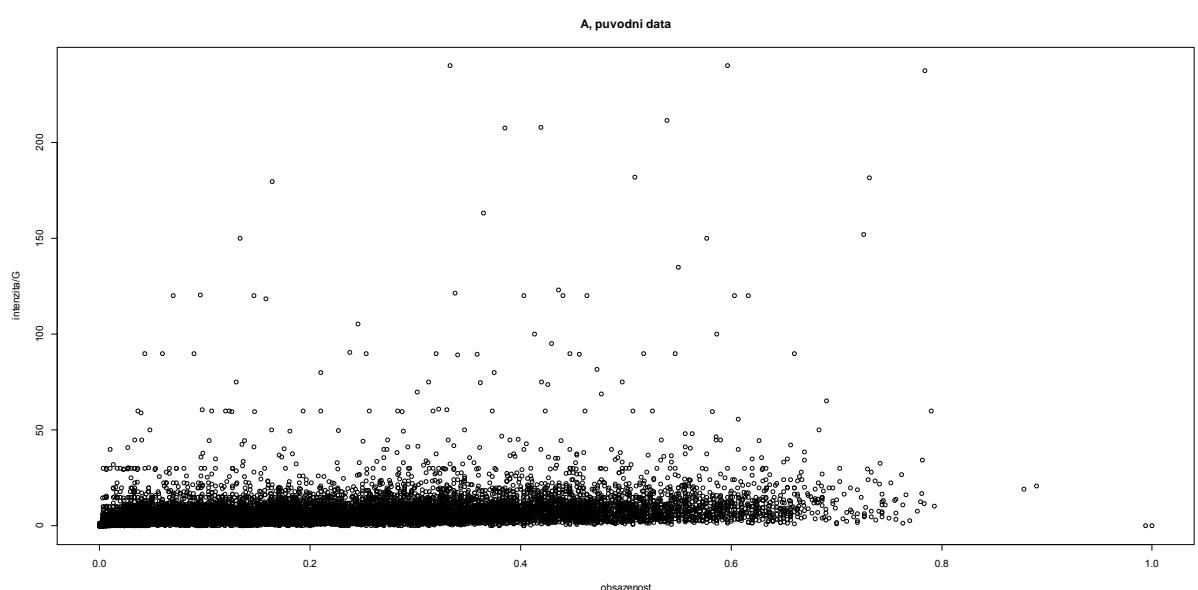


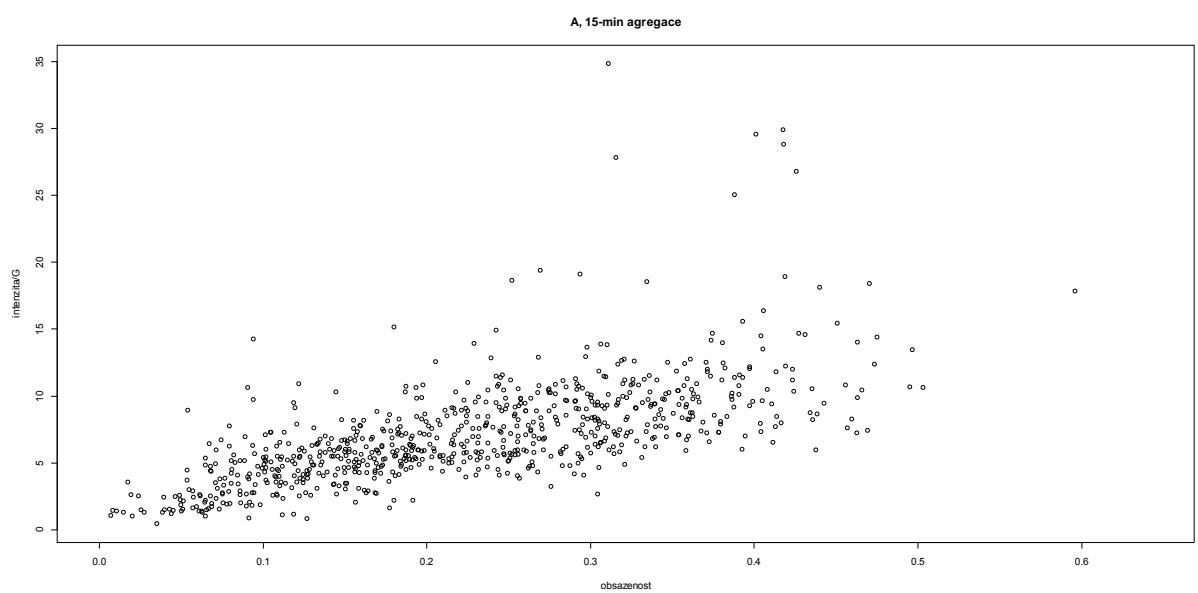
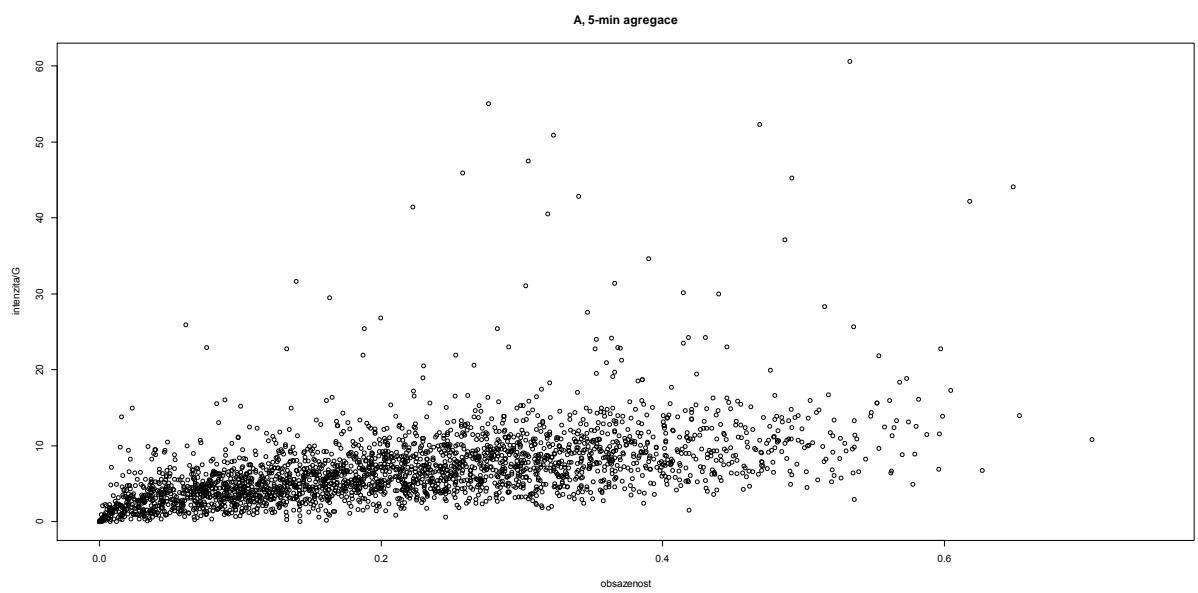
A, 30-min agregace



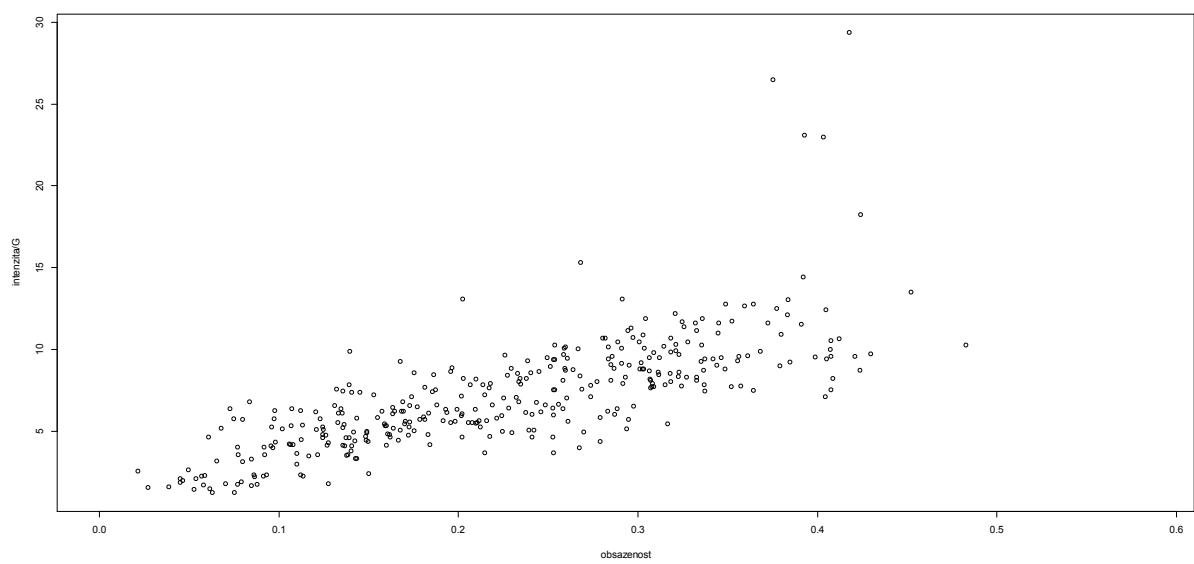


5.3.1.2 S dělením intenzity délkou zelené

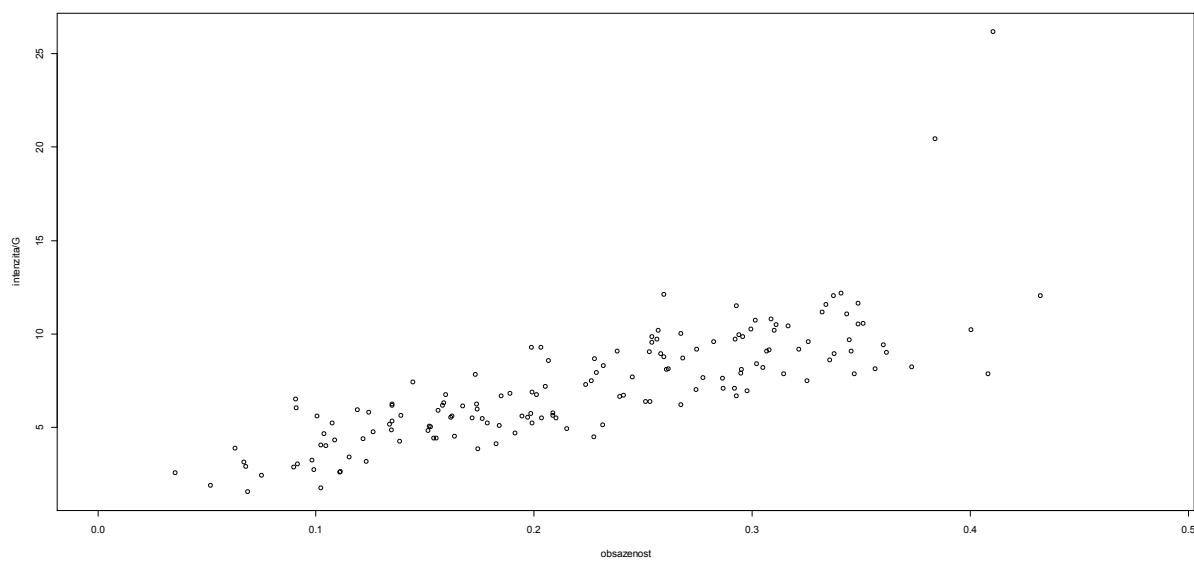




A, 30-min agregace

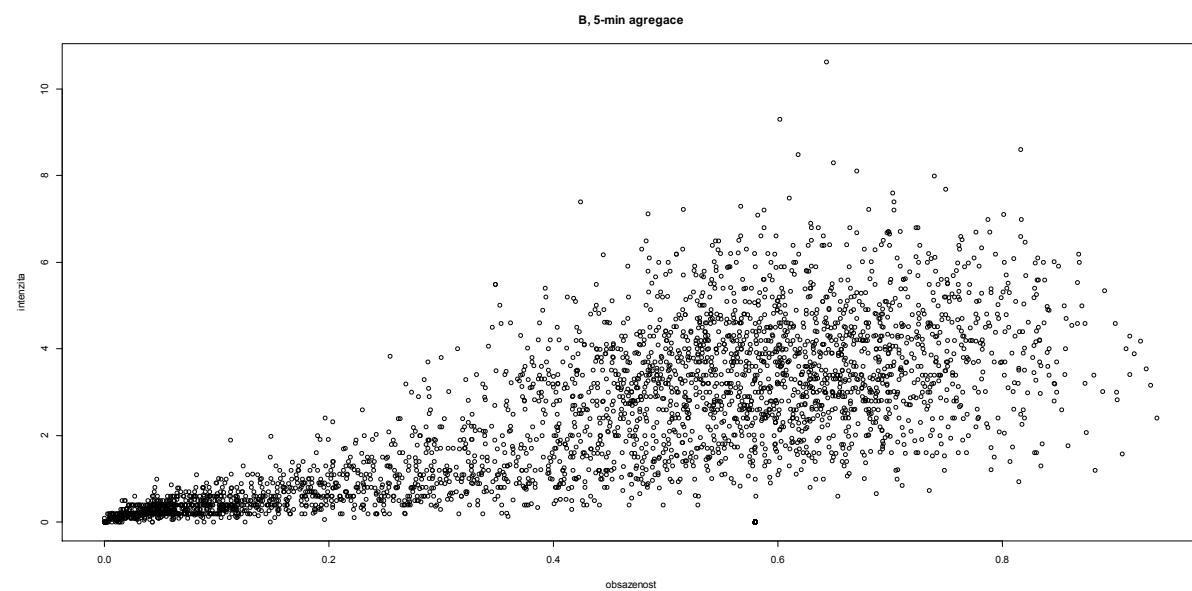
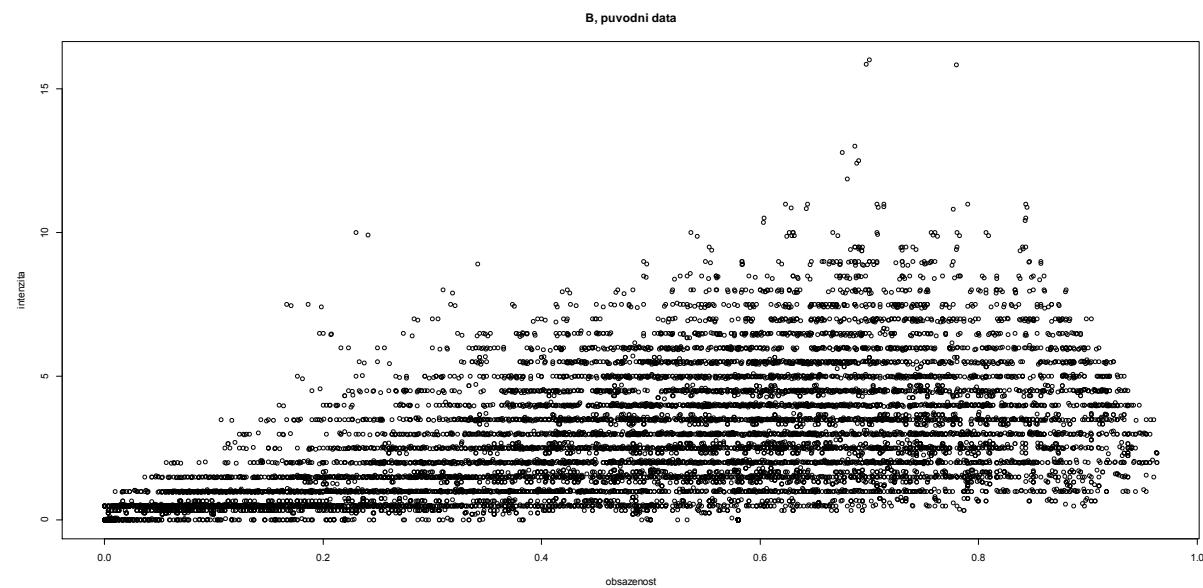


A, 1-hod agregace

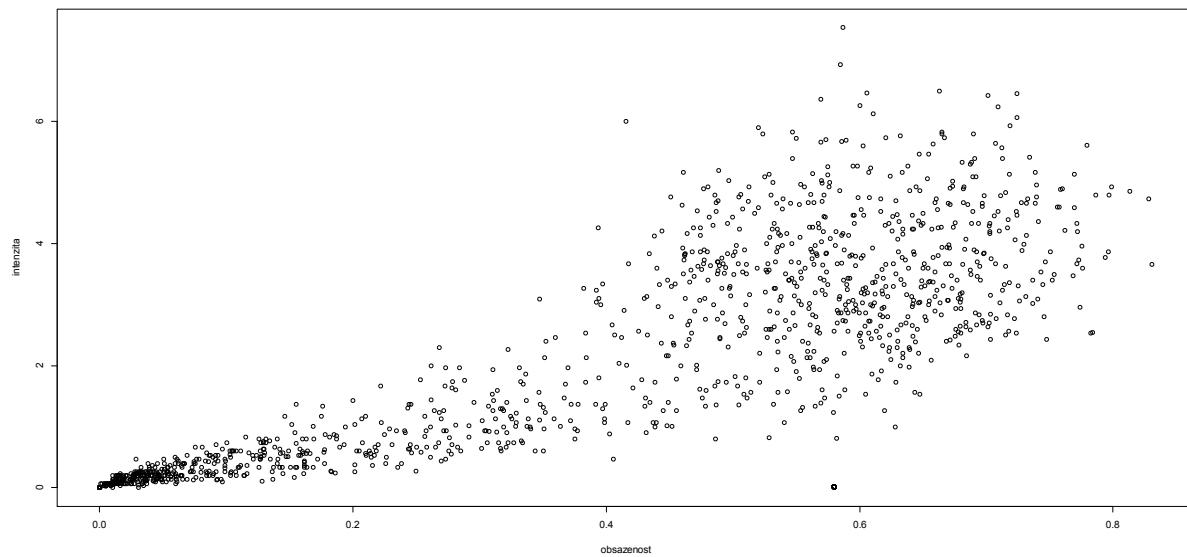


5.3.2 B

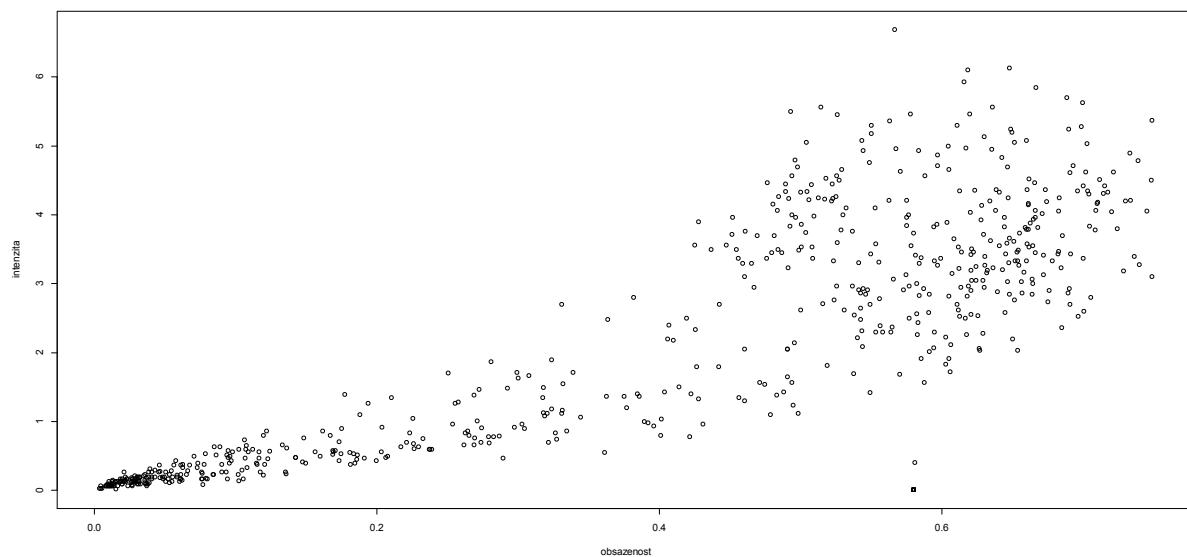
5.3.2.1 Bez dělení intenzity délkom zelené

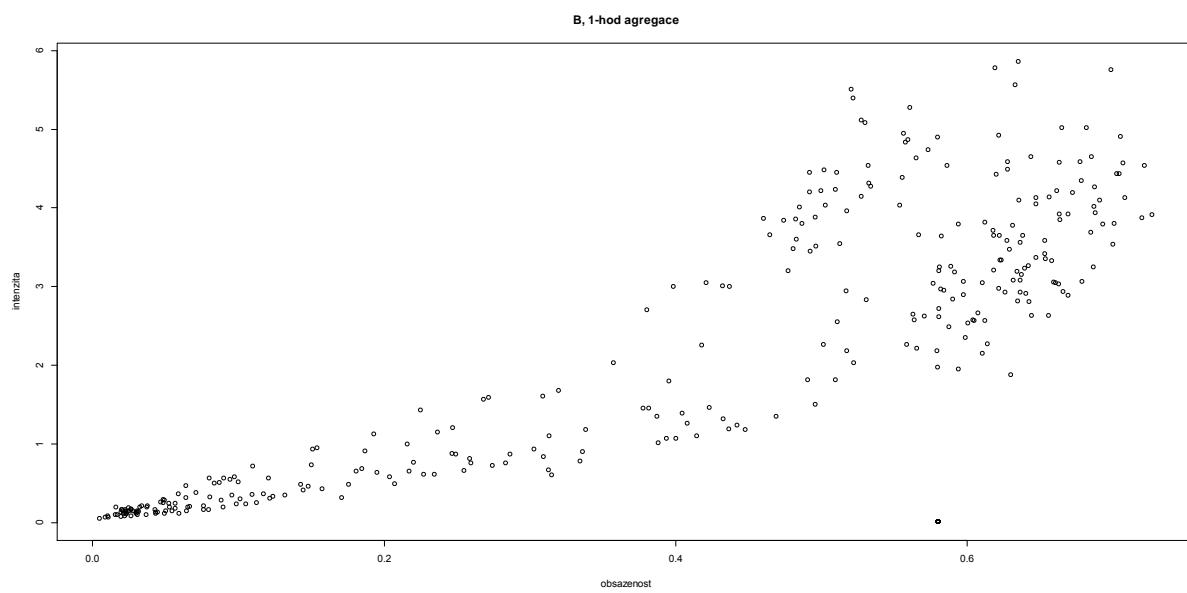


B, 15-min agregace

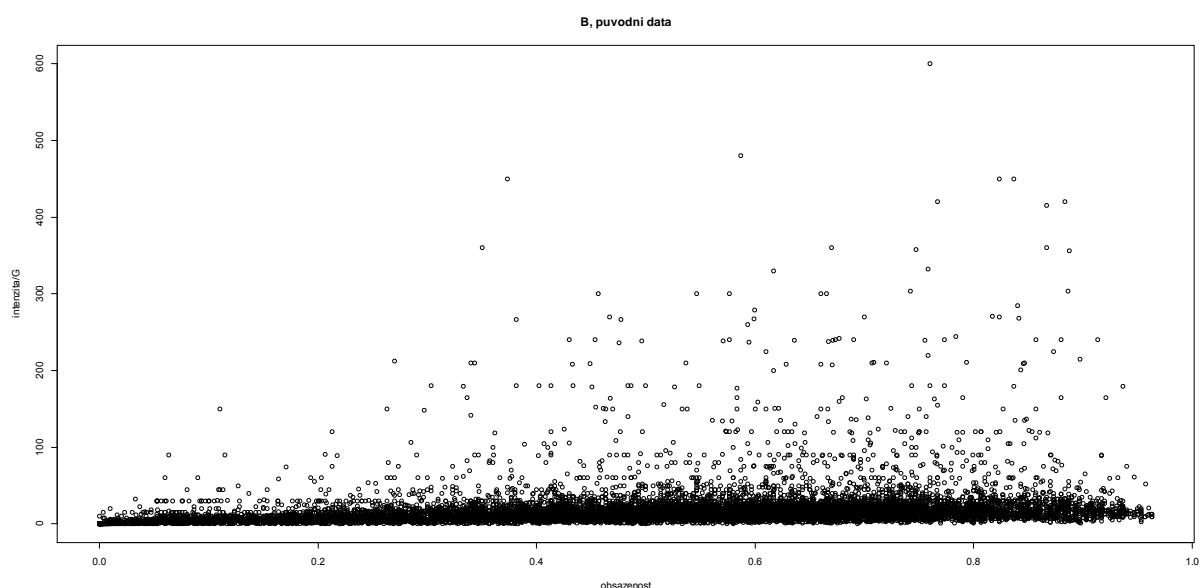


B, 30-min agregace

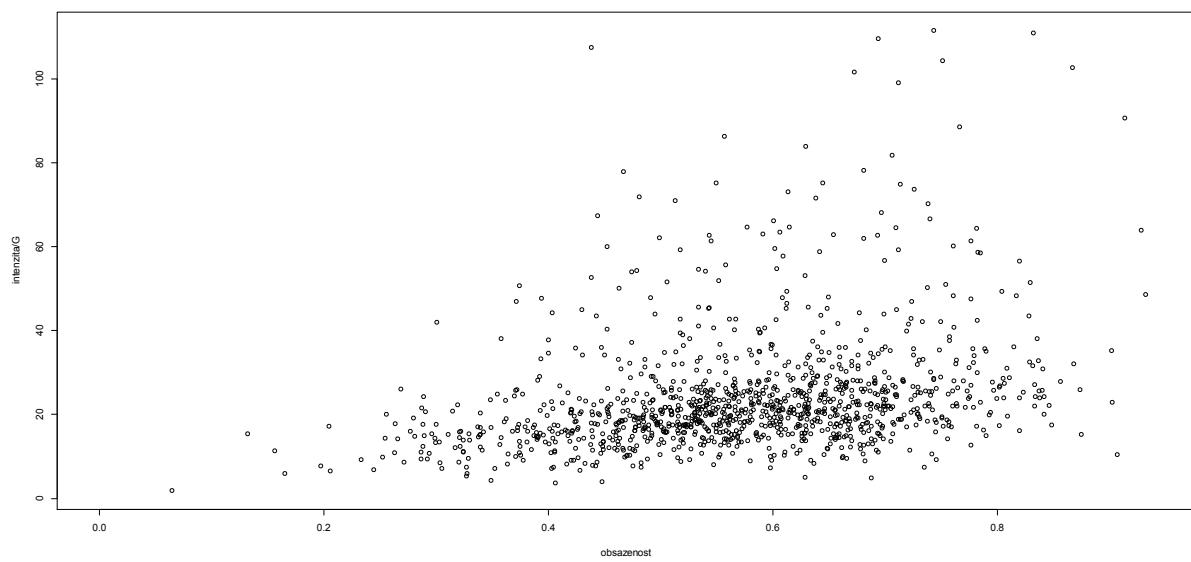




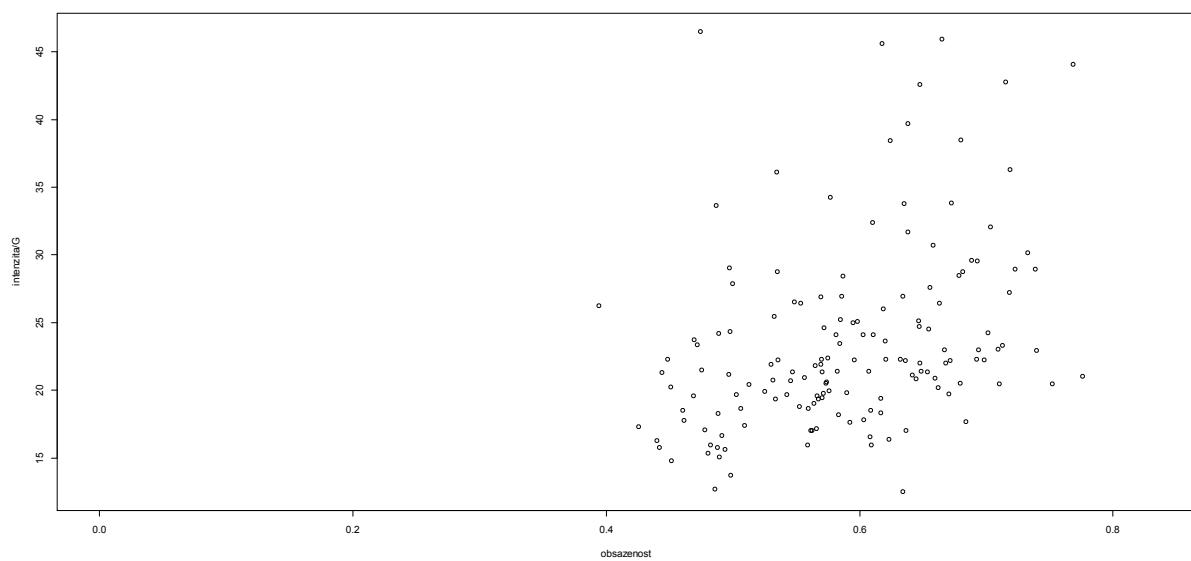
5.3.2.2 S dělením intenzity délkou zelené



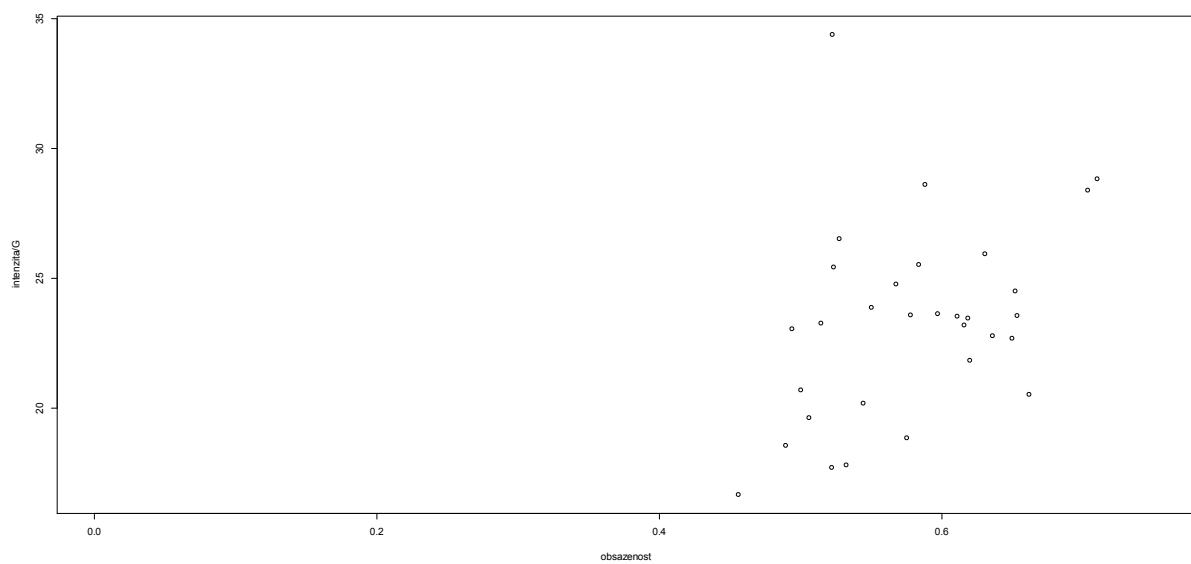
B, 5-min agregace



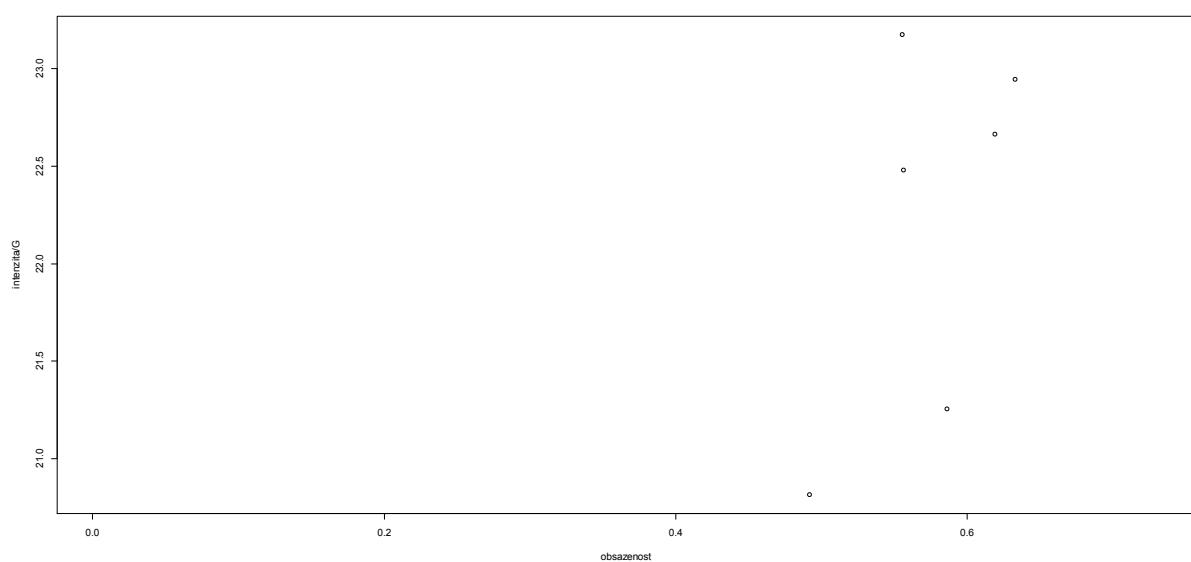
B, 15-min agregace



B, 30-min agregace

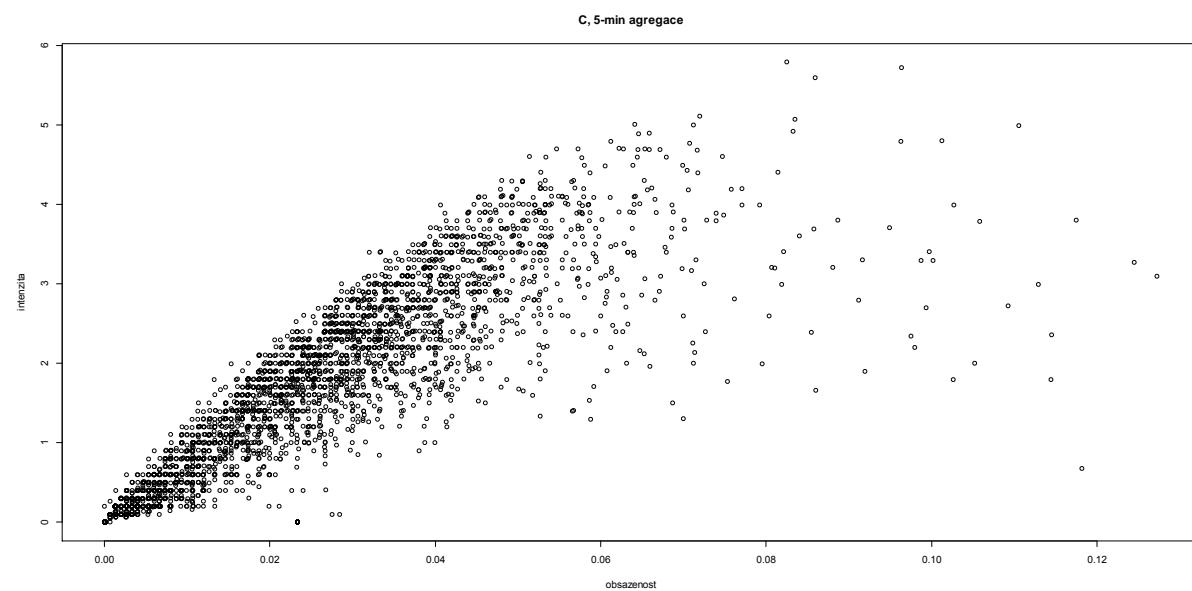
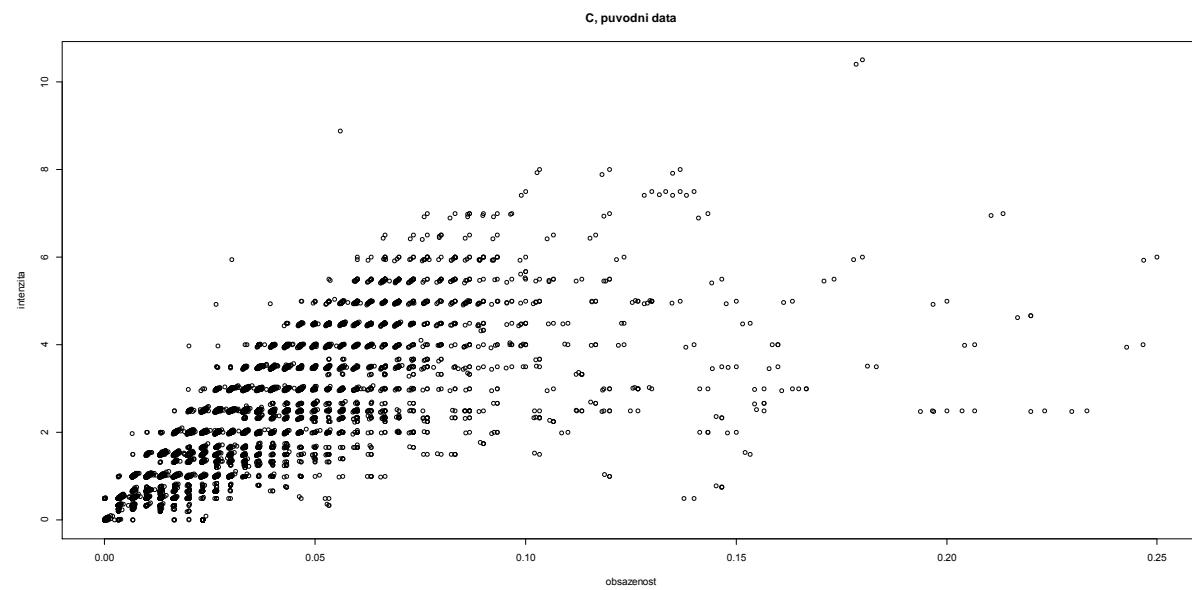


B, 1-hod agregace

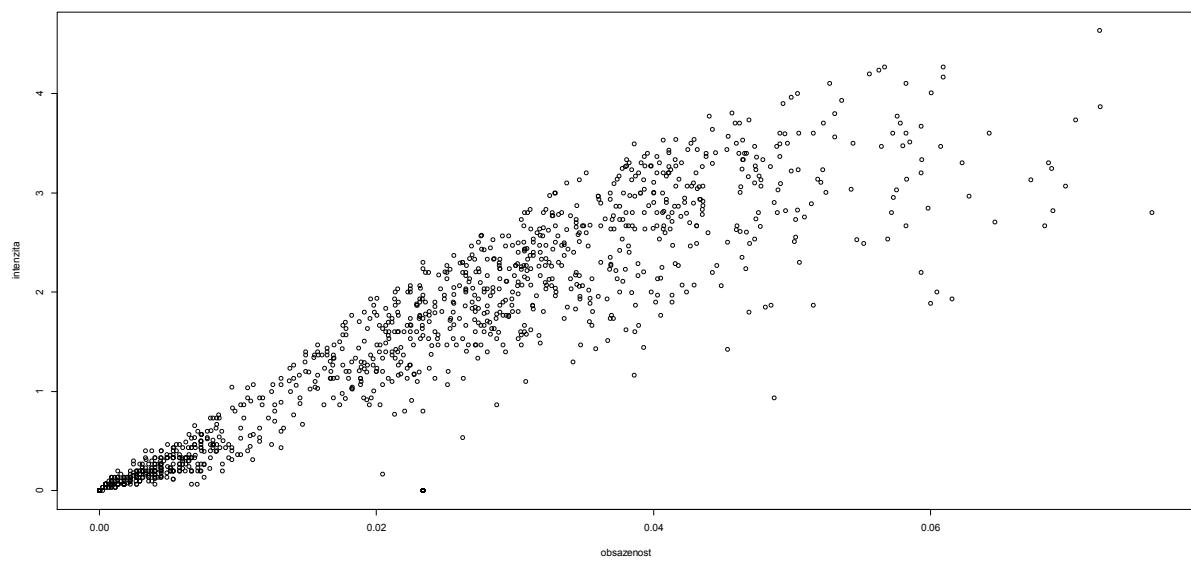


5.3.3 C

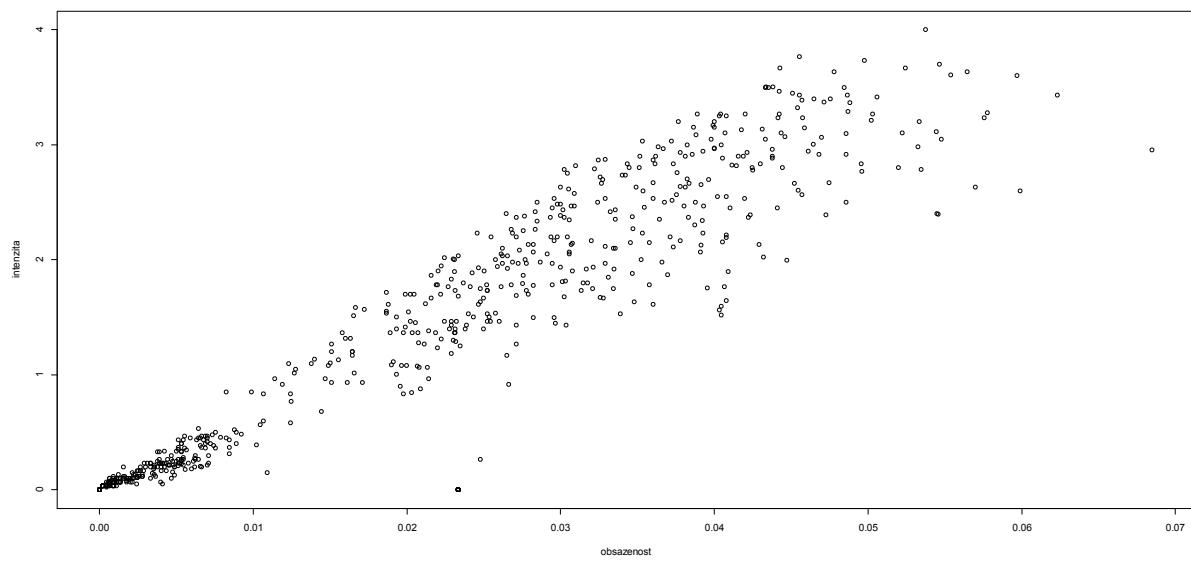
5.3.3.1 Bez dělení intenzity délkom zelené

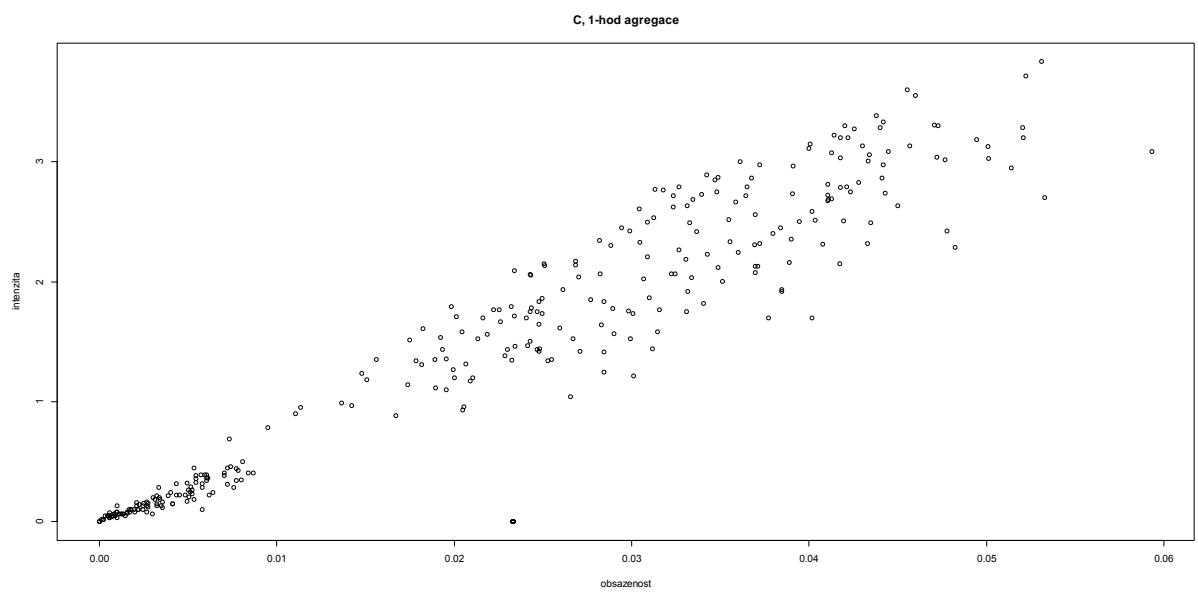


C, 15-min agregace

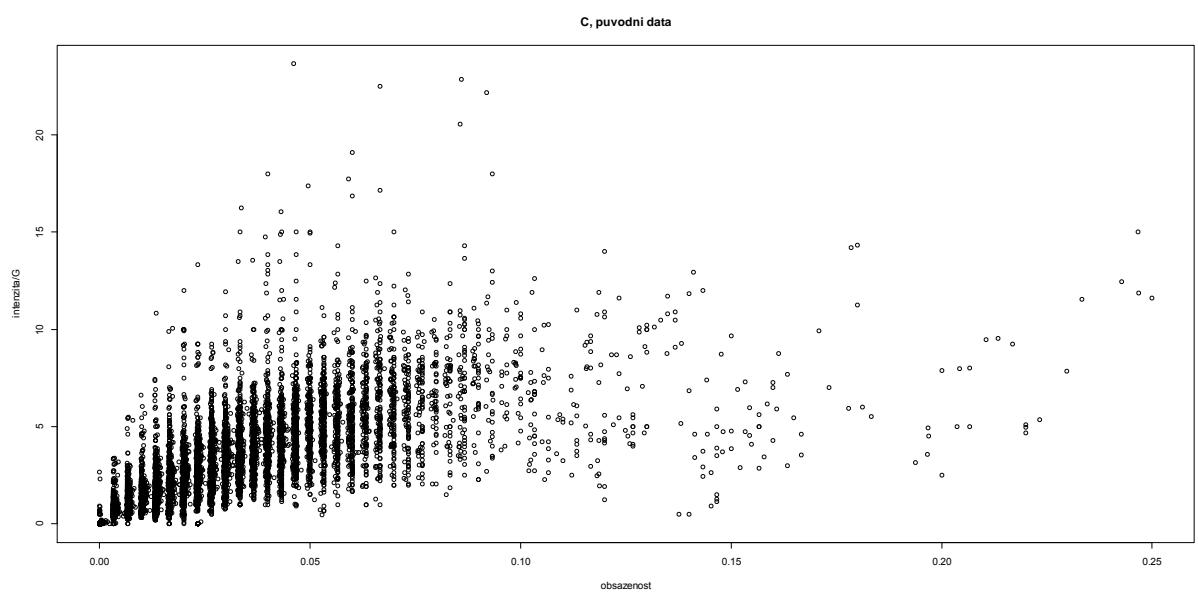


C, 30-min agregace

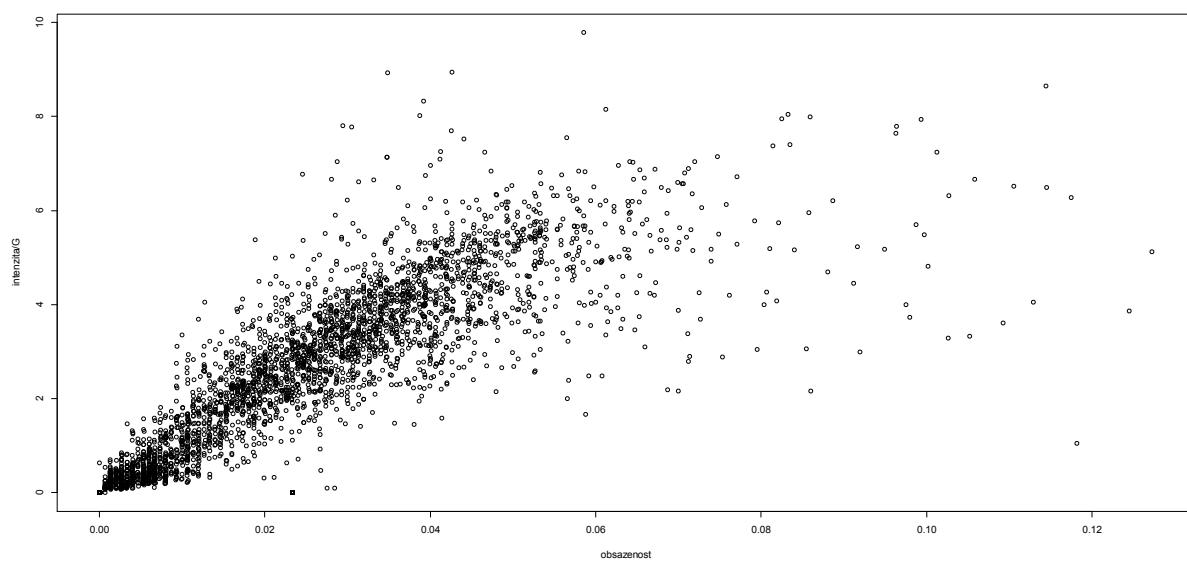




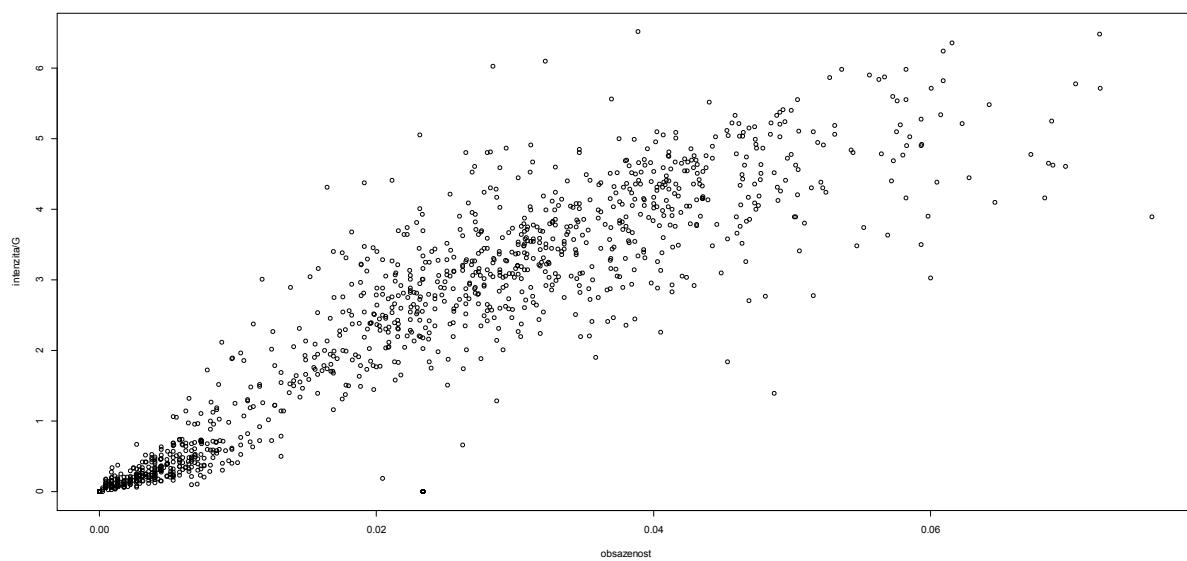
5.3.3.2 S dělením intenzity délkou zelené



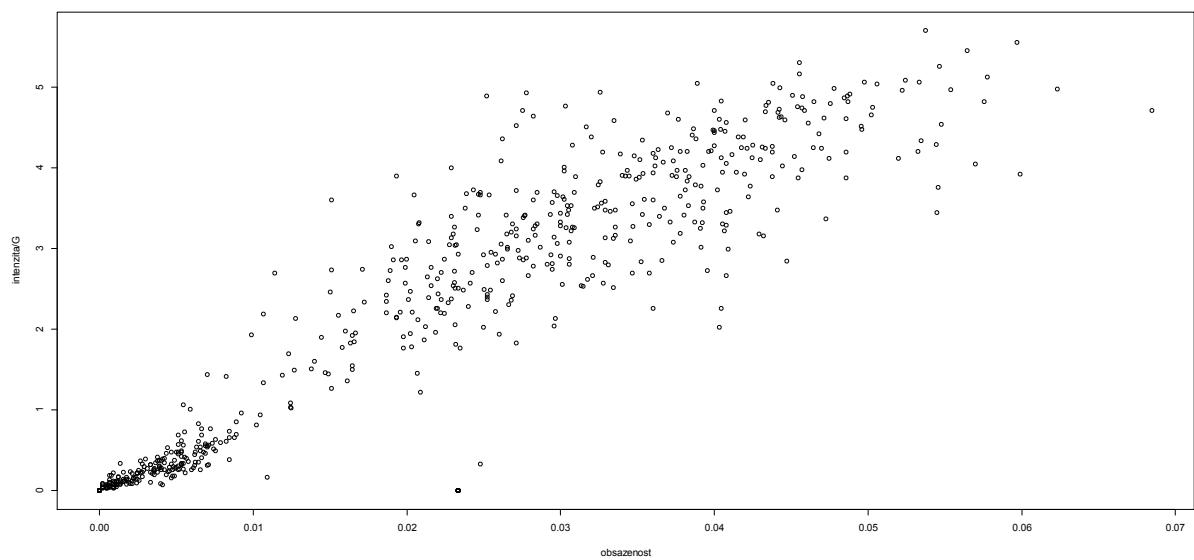
C, 5-min agregace



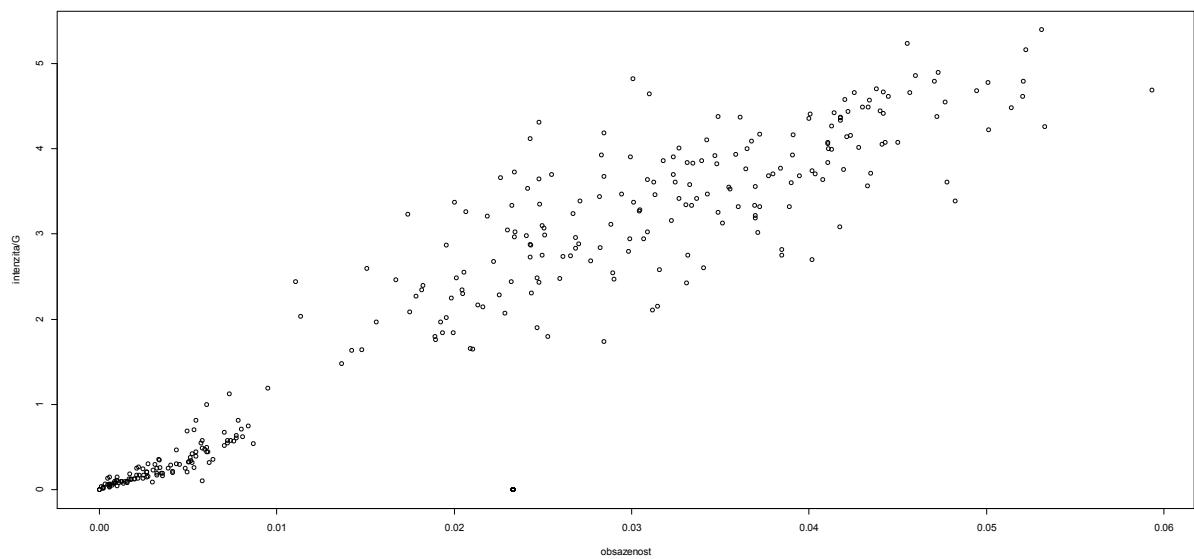
C, 15-min agregace



C, 30-min agregace

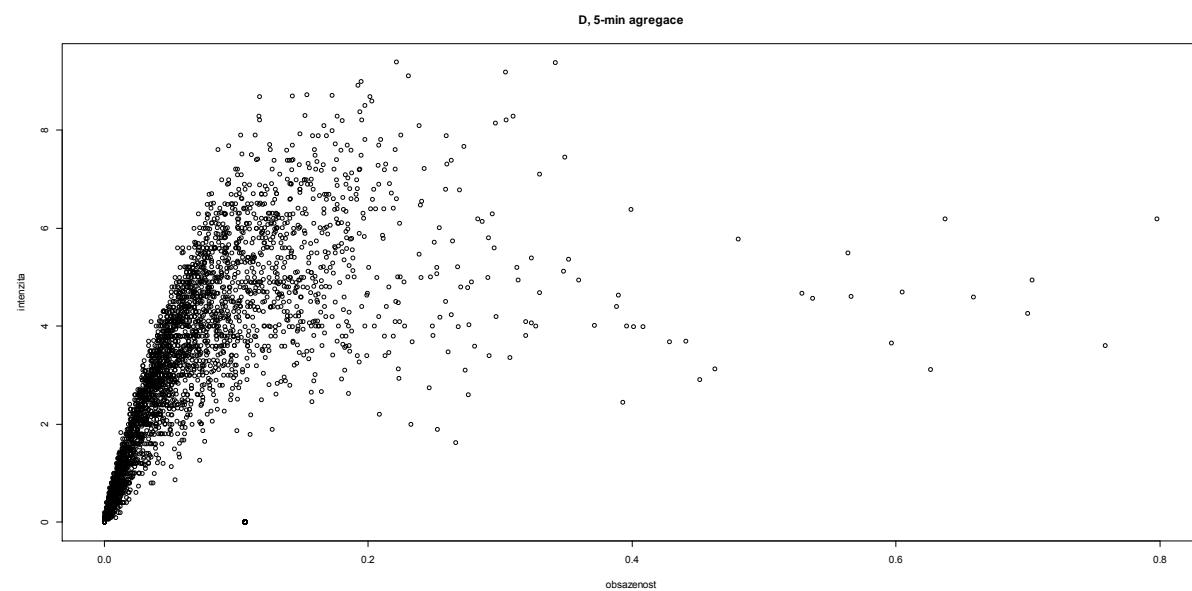
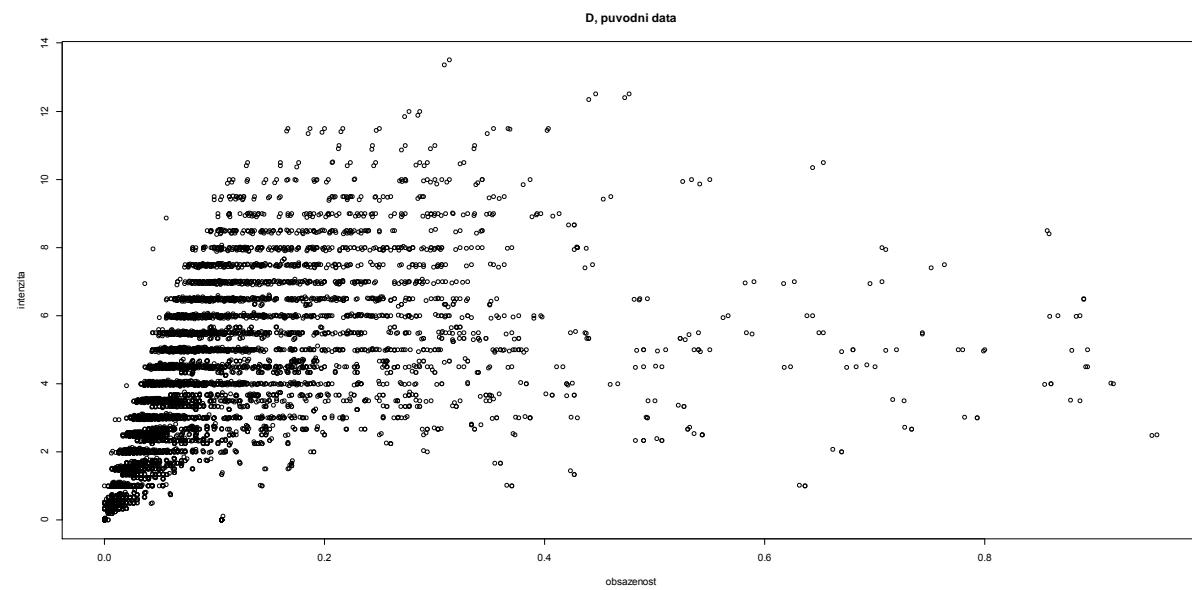


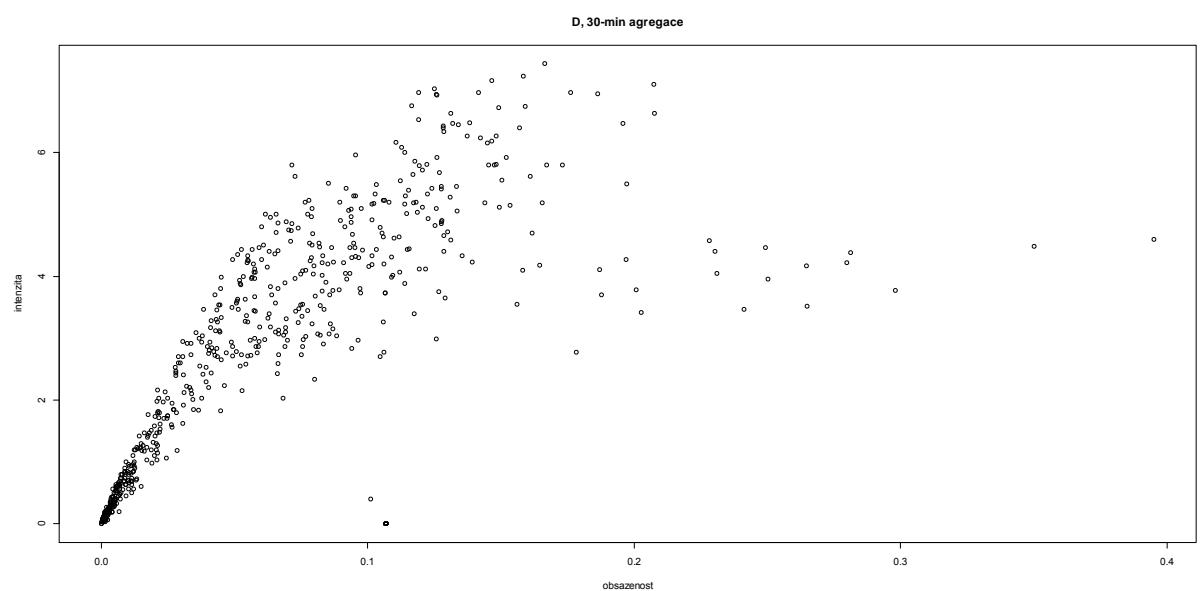
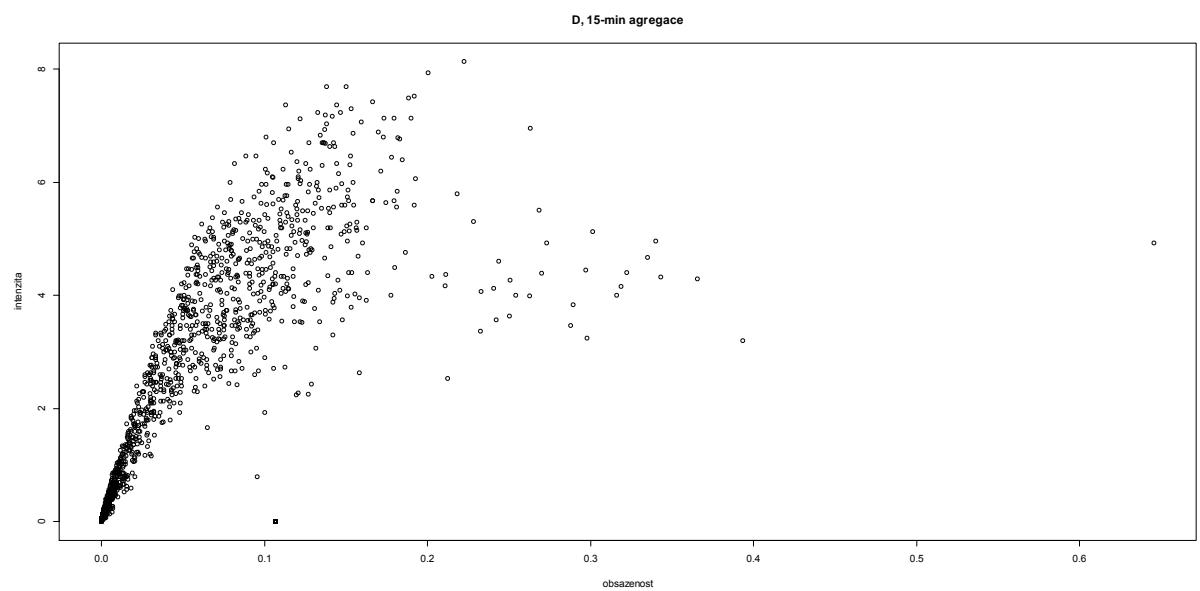
C, 1-hod agregace

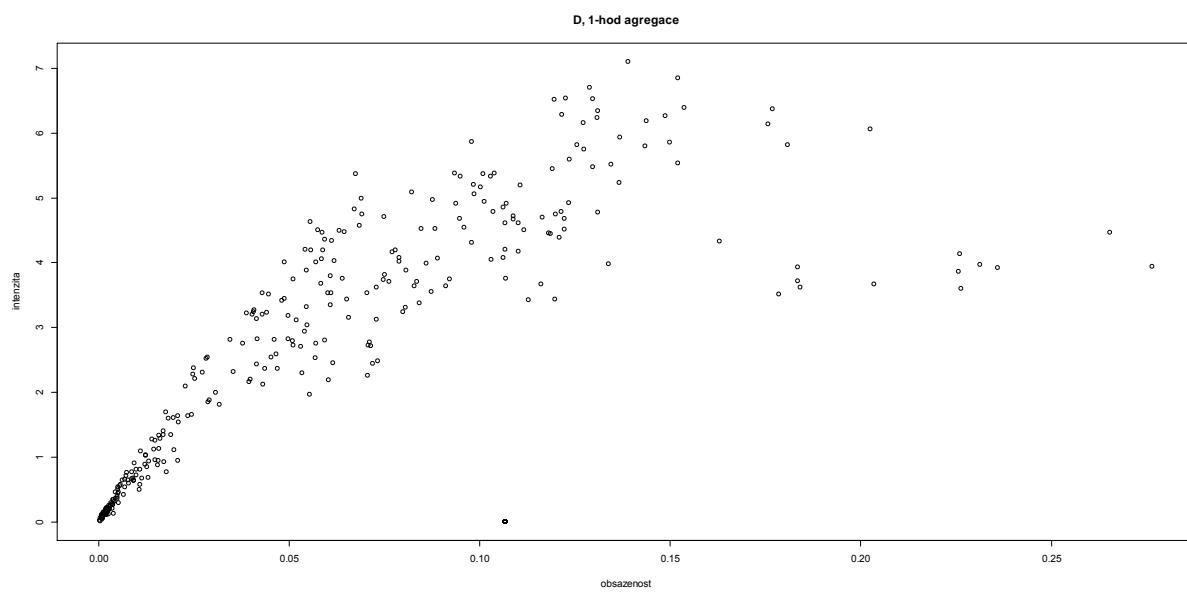


5.3.4 D

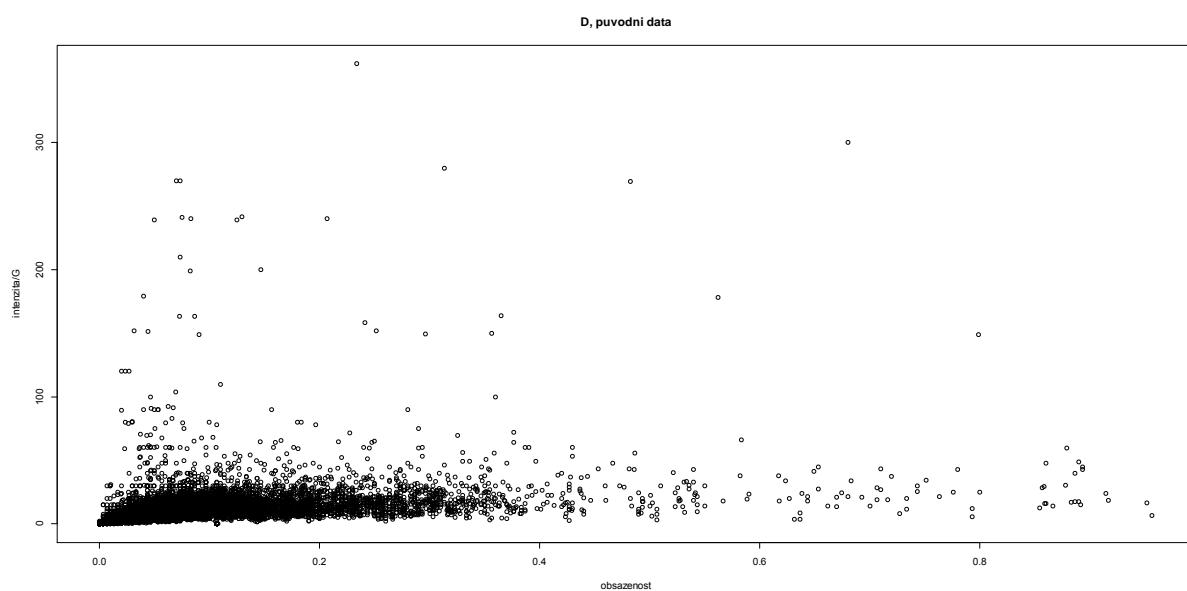
5.3.4.1 Bez dělení intenzity délkom zelené

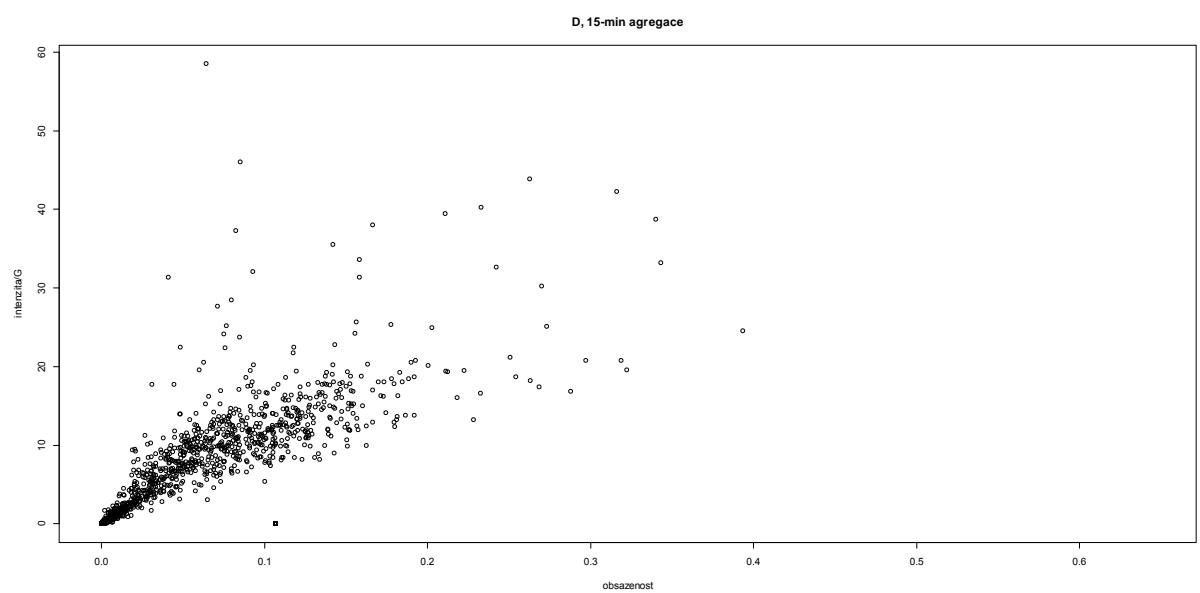
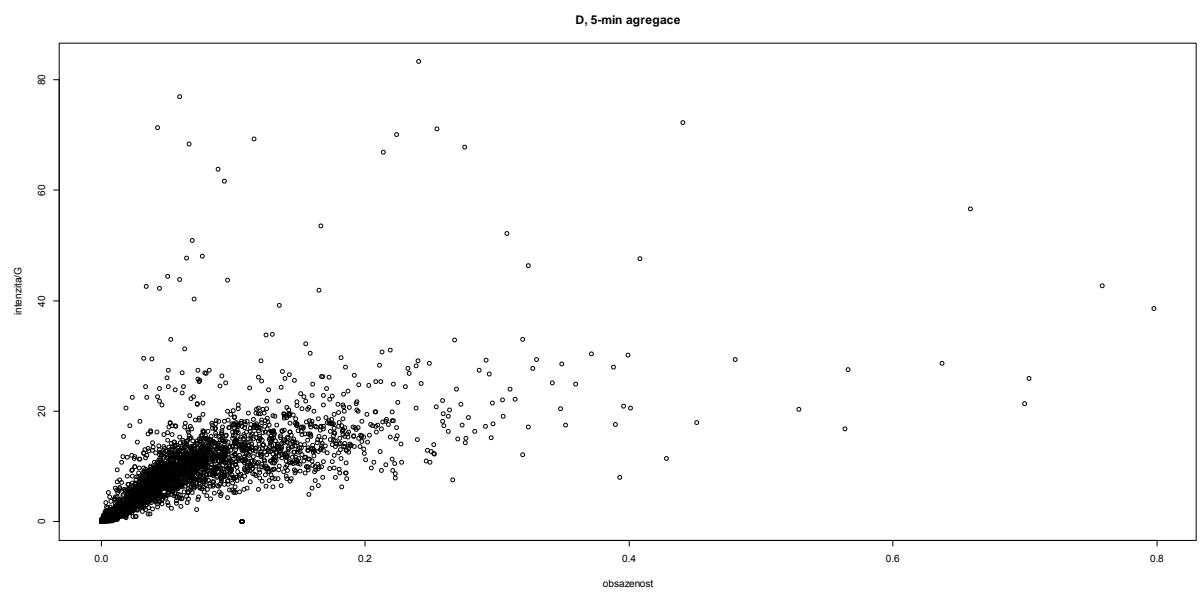




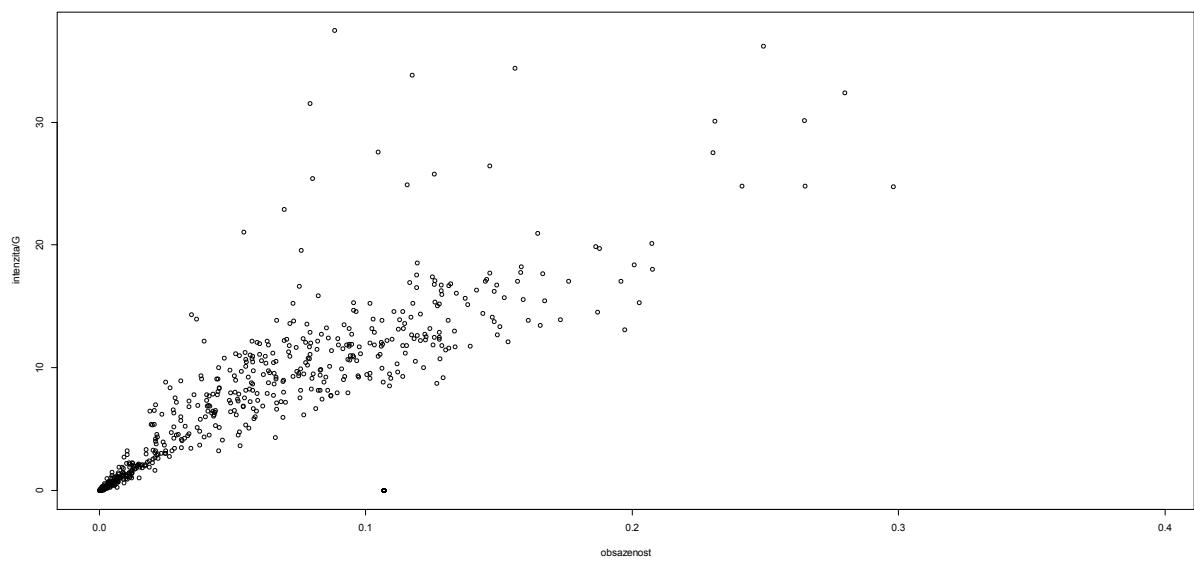


5.3.4.2 S dělením intenzity délkou zelené

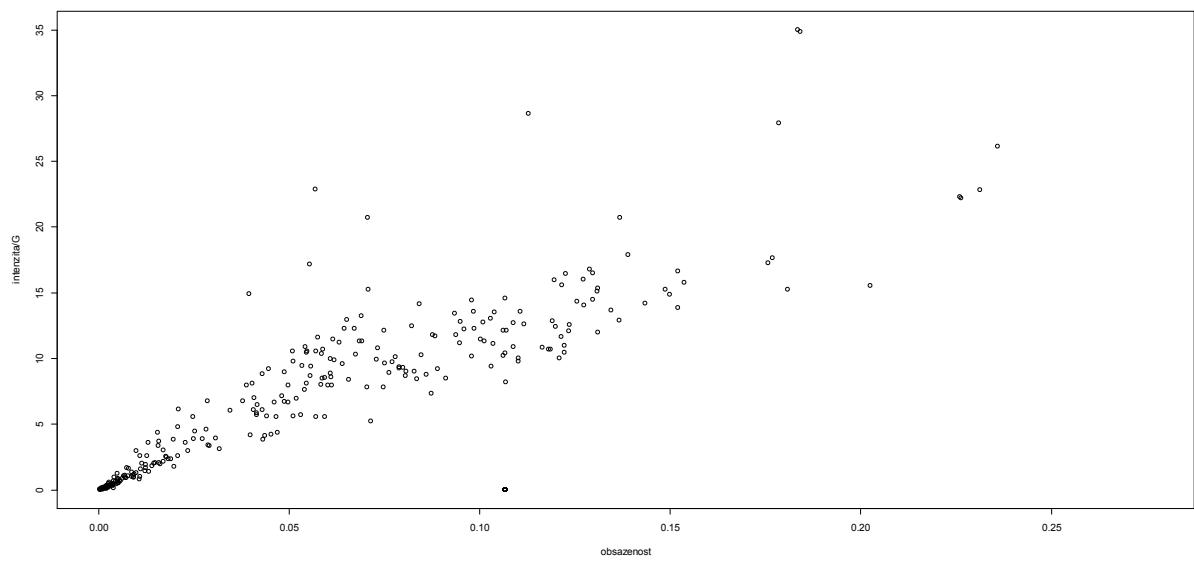




D, 30-min agregace

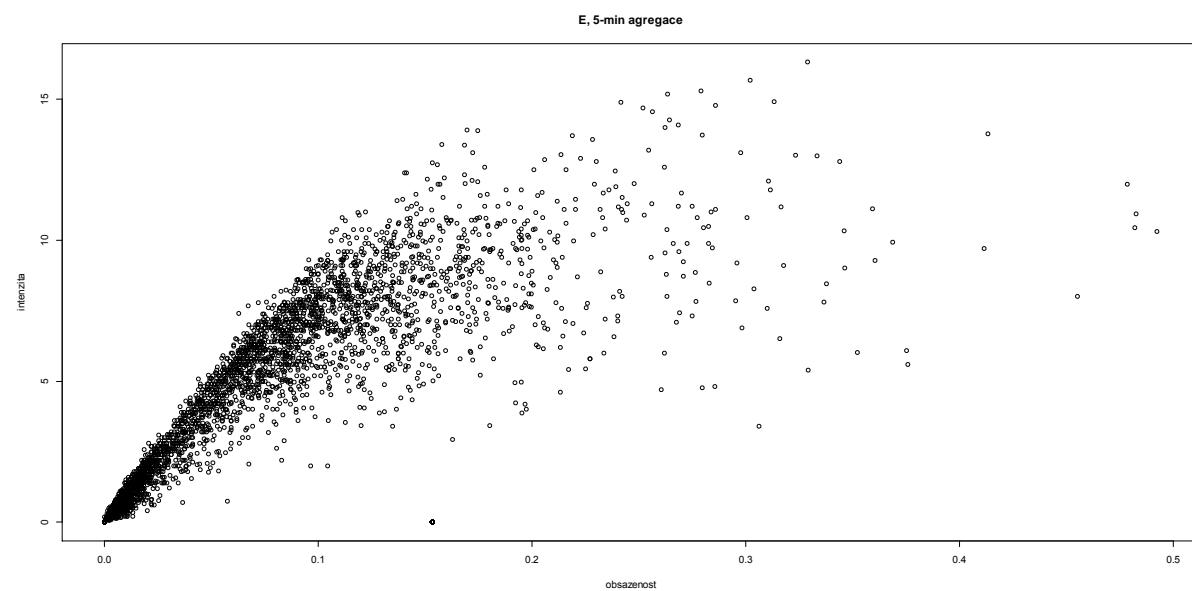
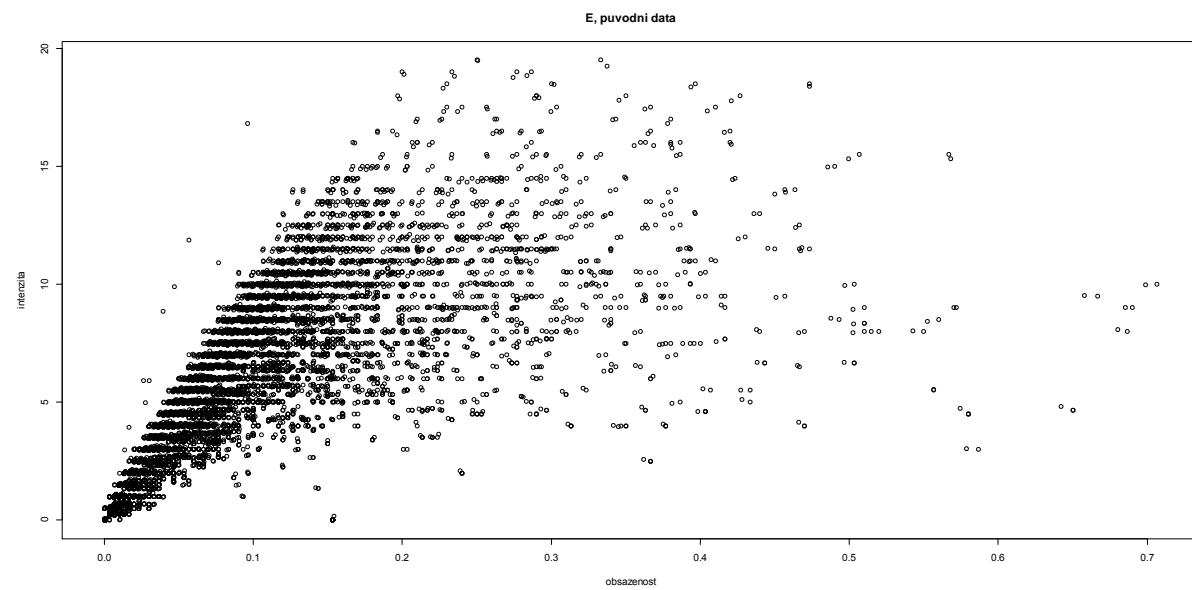


D, 1-hod agregace

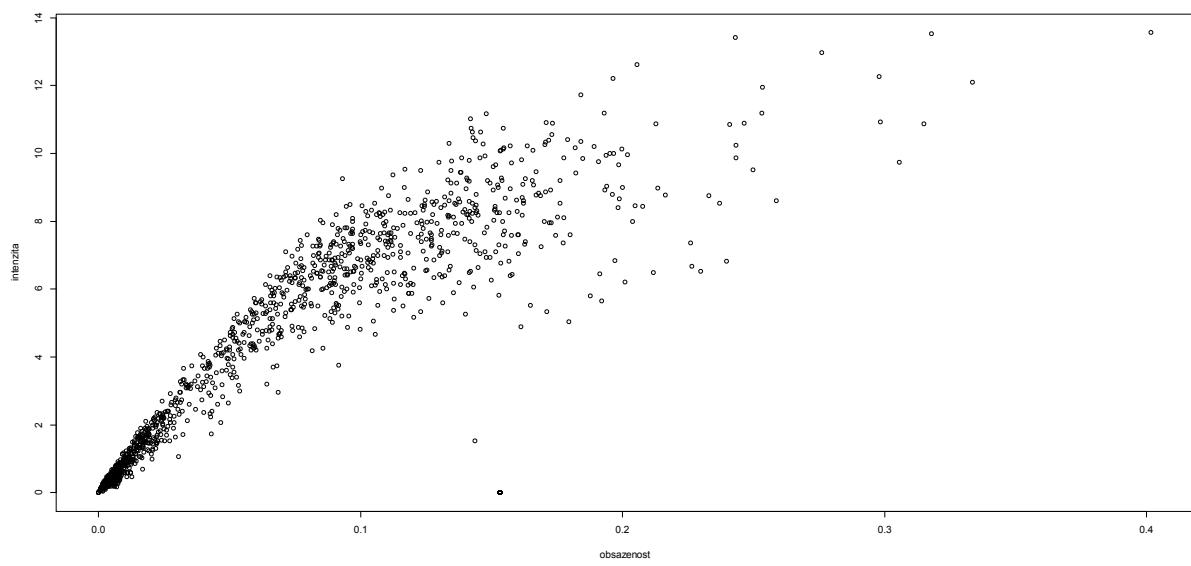


5.3.5 E

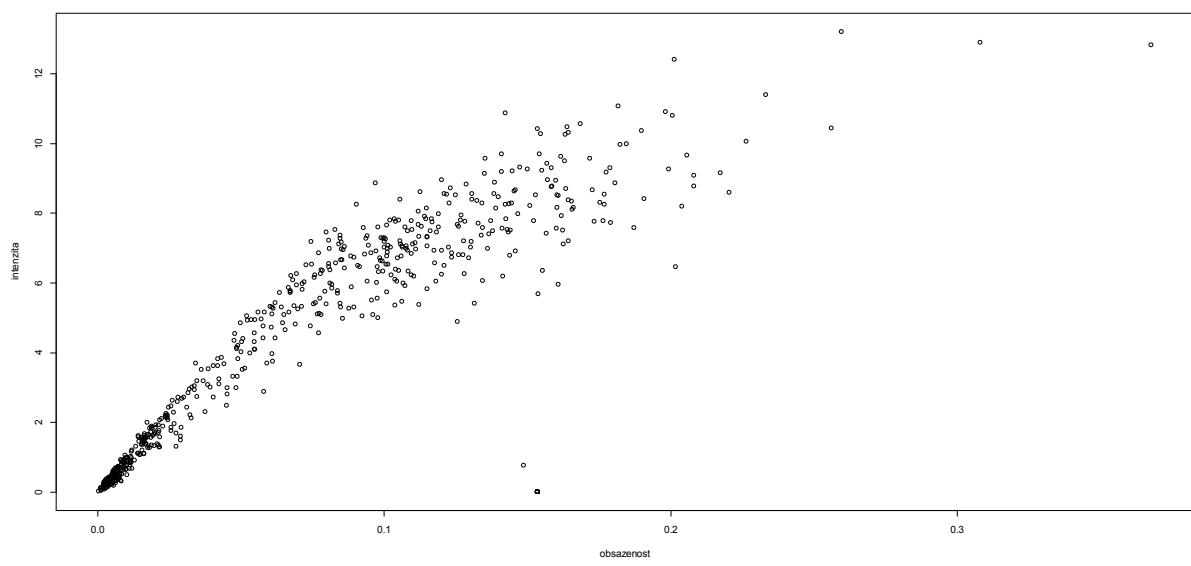
5.3.5.1 Bez dělení intenzity délkom zelené

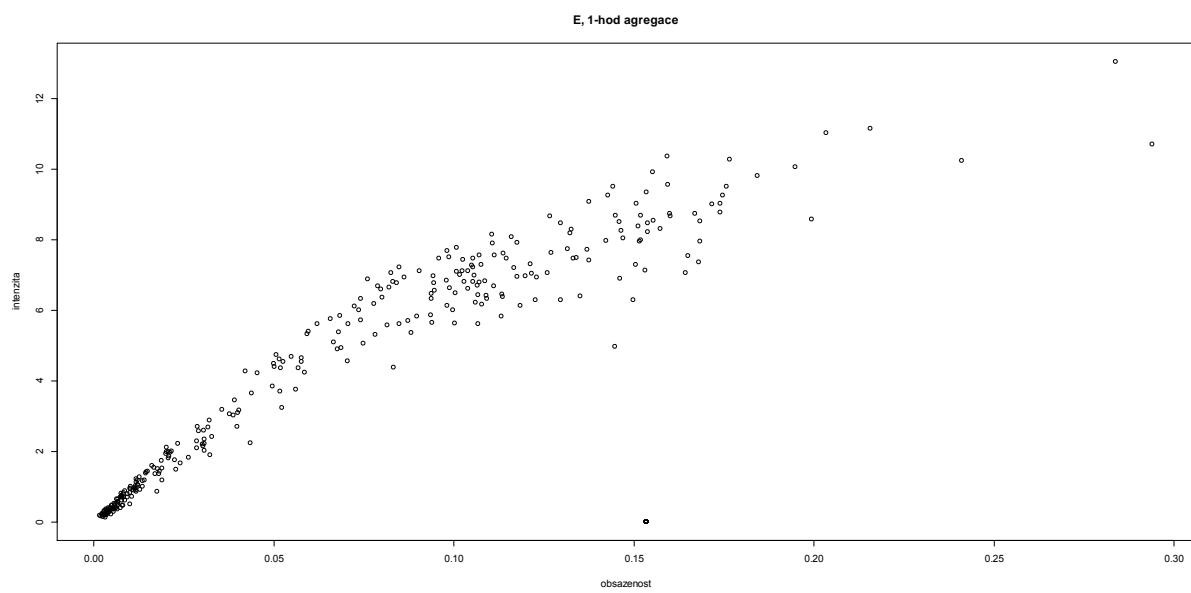


E, 15-min agregace

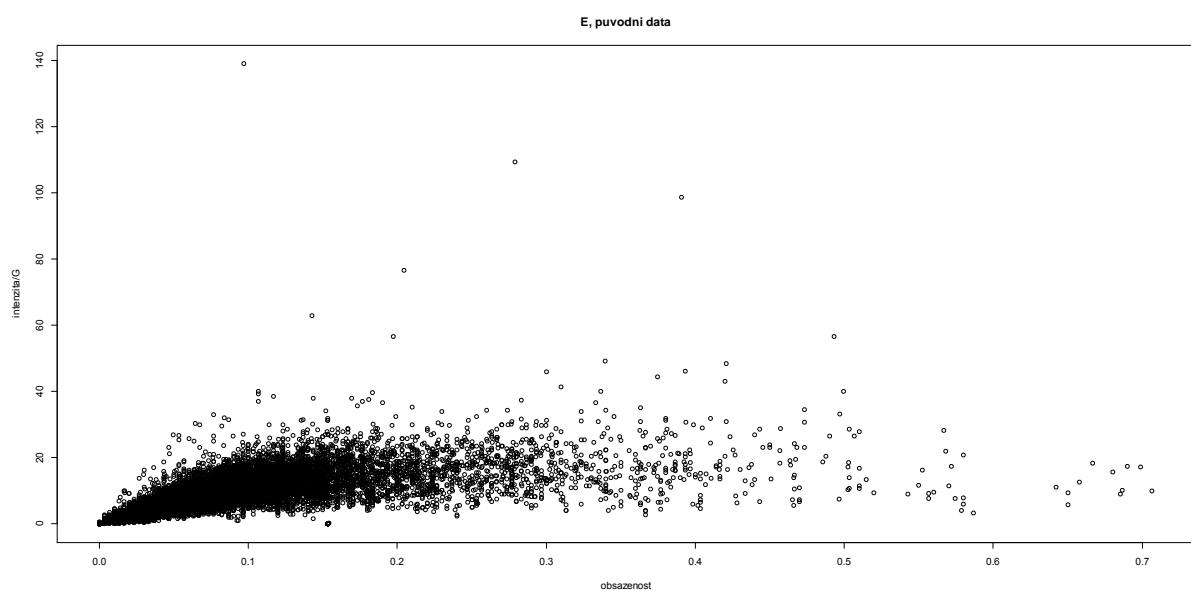


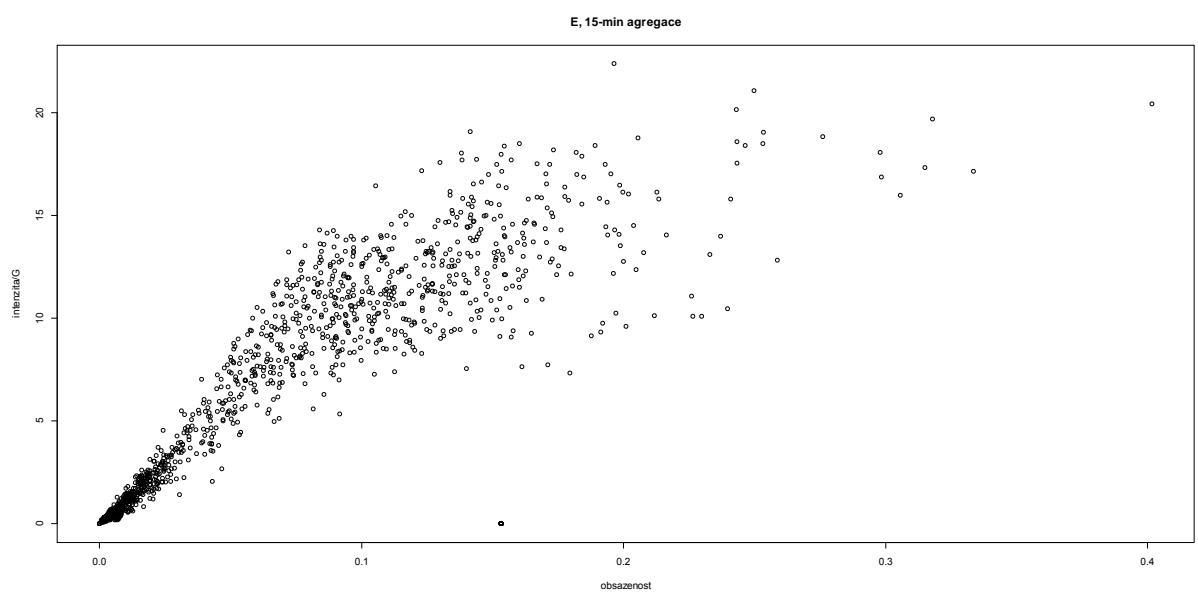
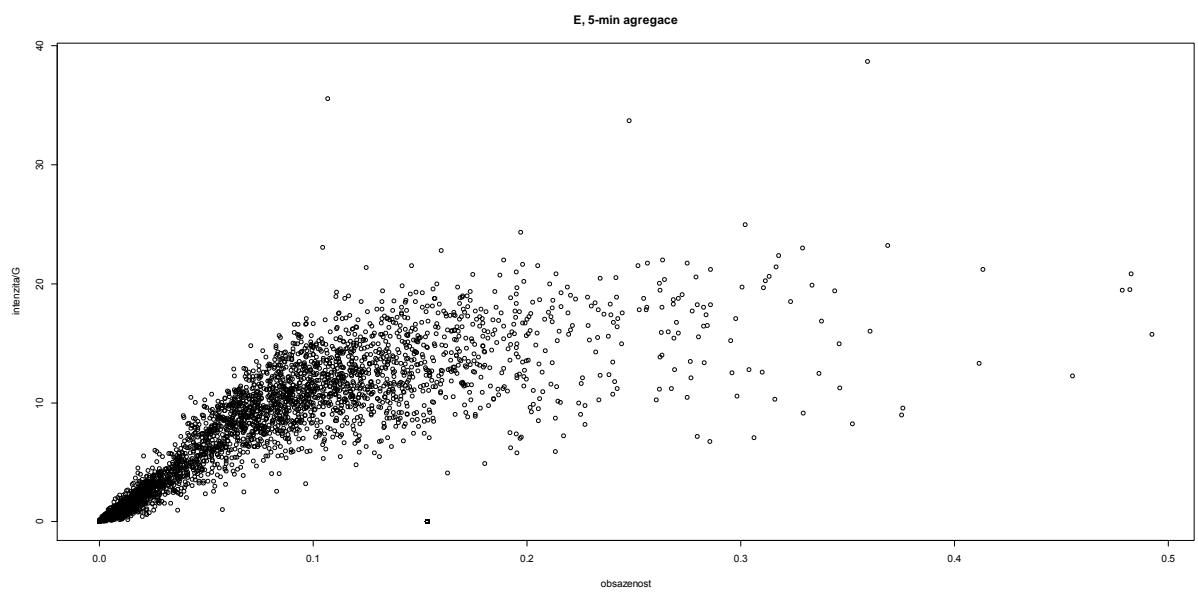
E, 30-min agregace



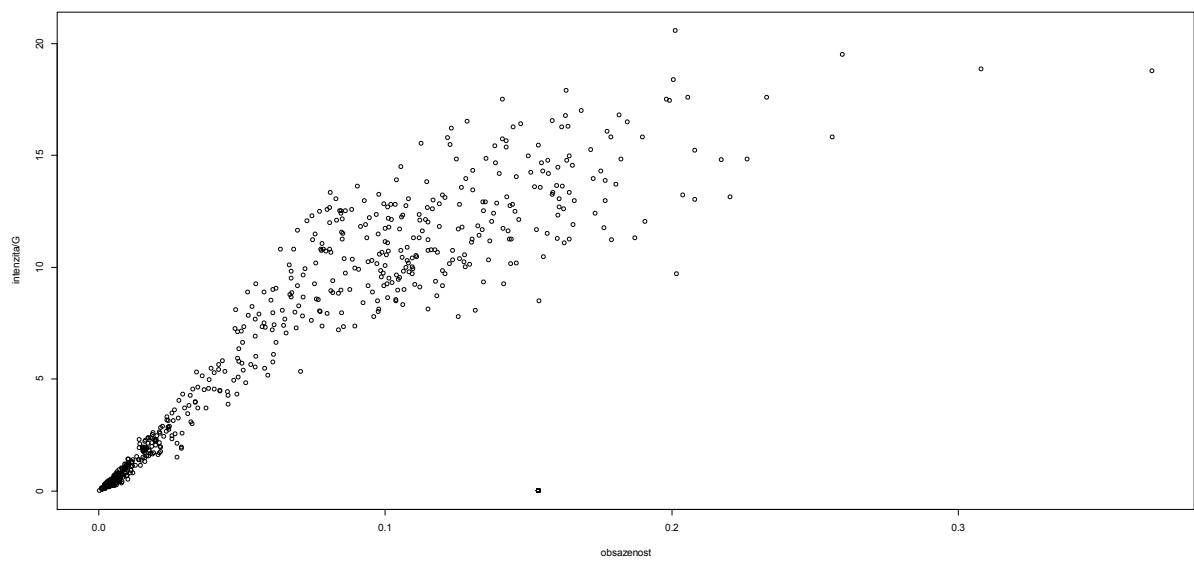


5.3.5.2 S dělením intenzity délkou zelené

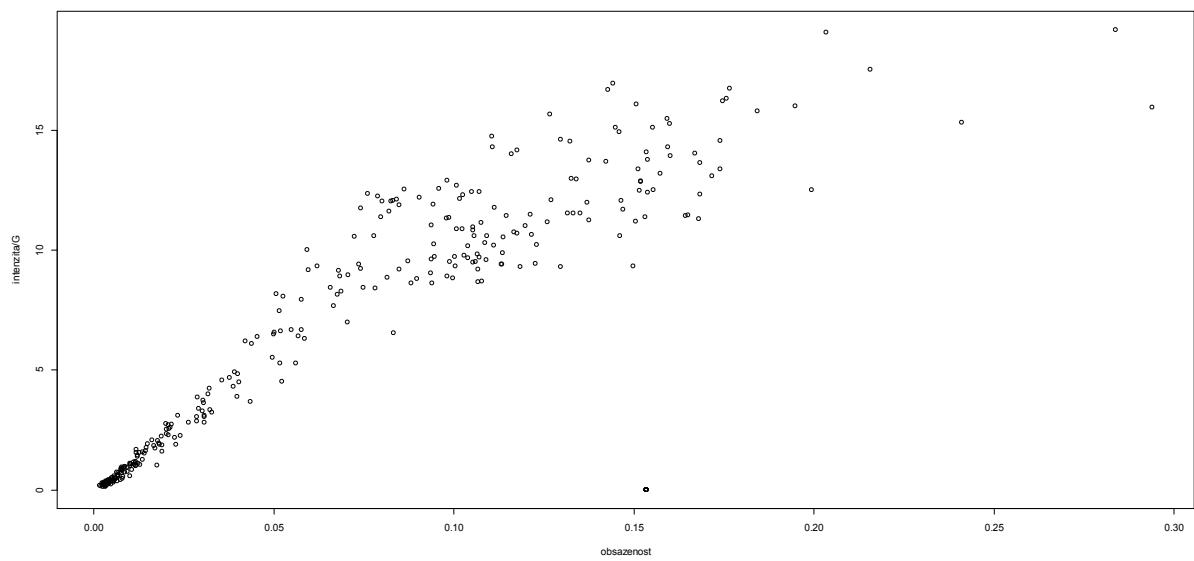




E, 30-min agregace

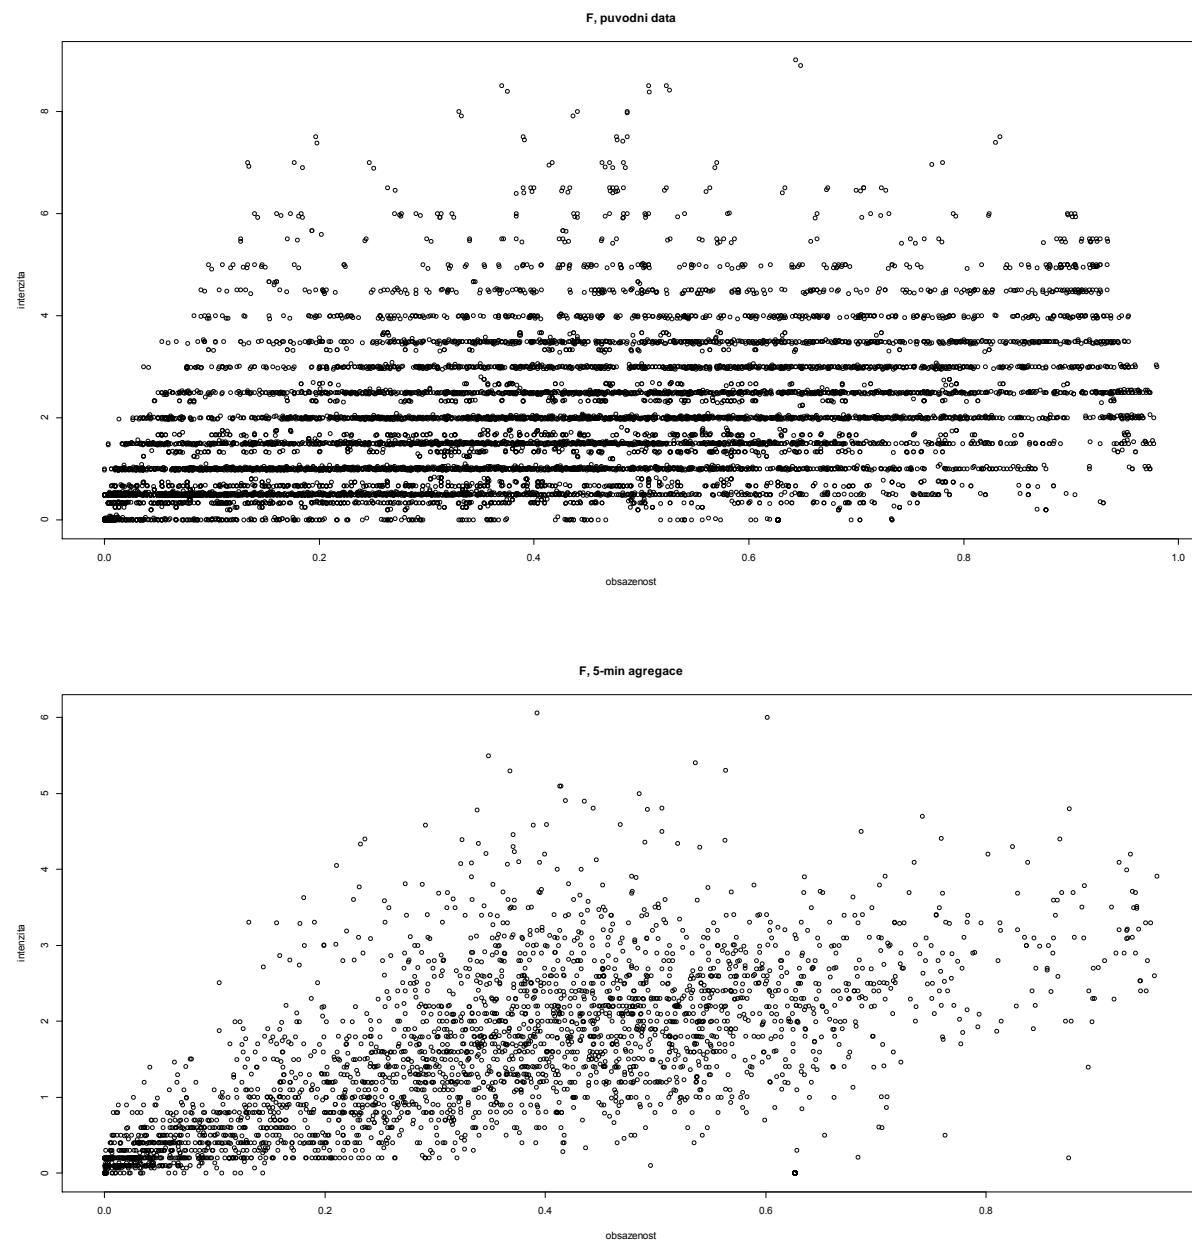


E, 1-hod agregace

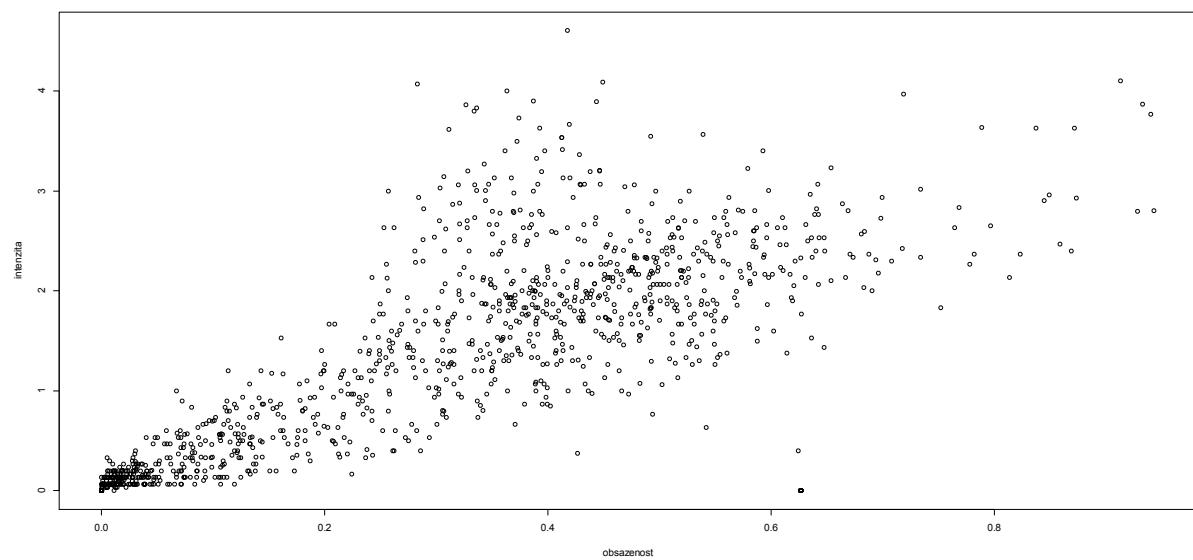


5.3.6 F

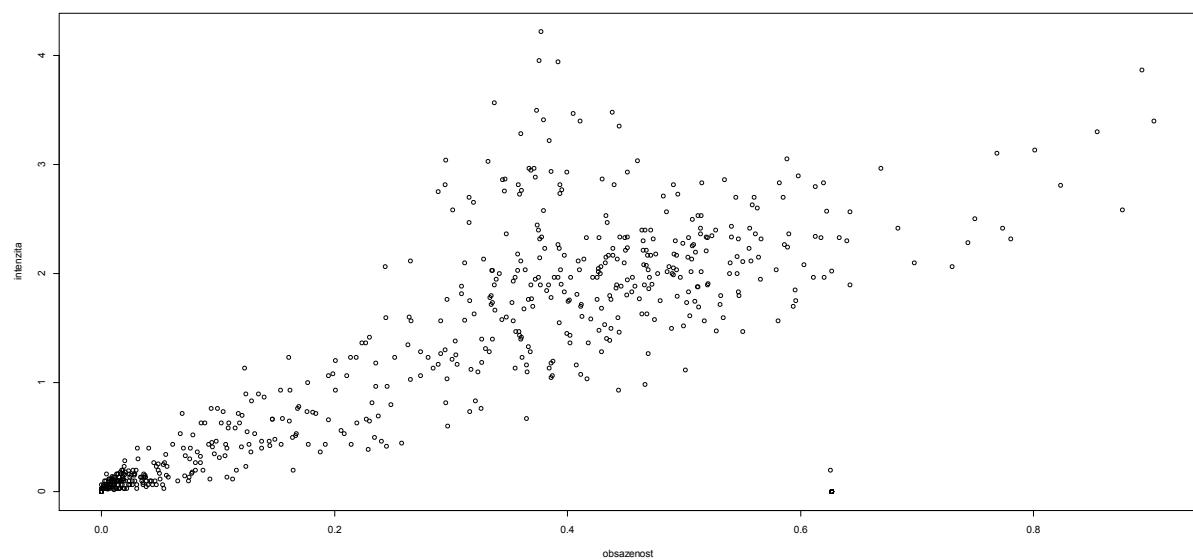
5.3.6.1 Bez dělení intenzity délkom zelené

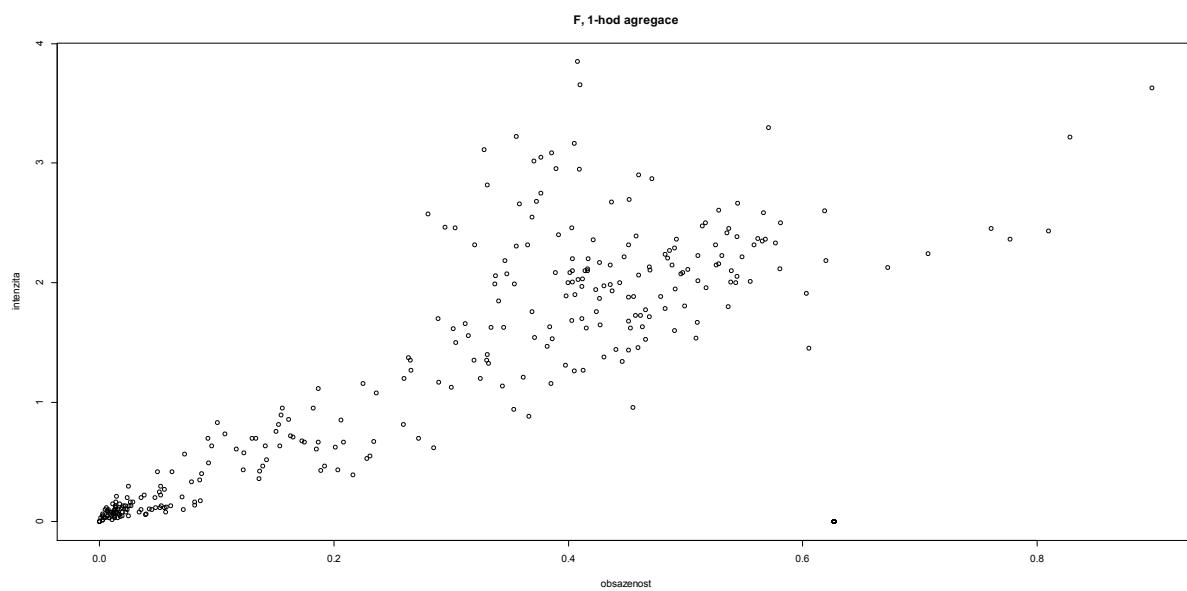


F, 15-min agregace

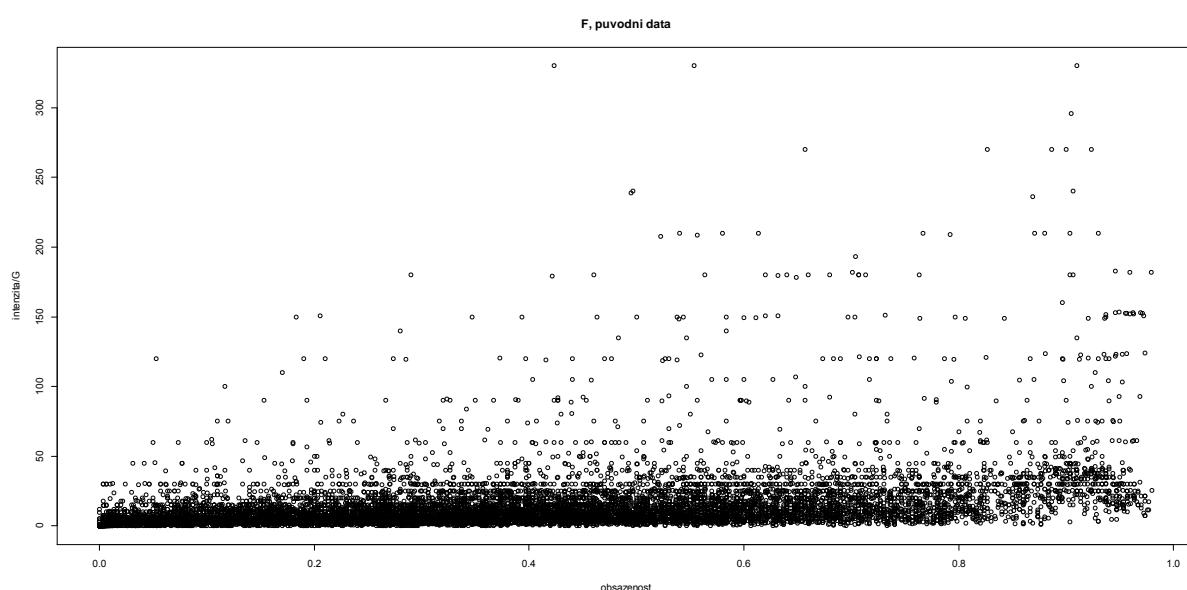


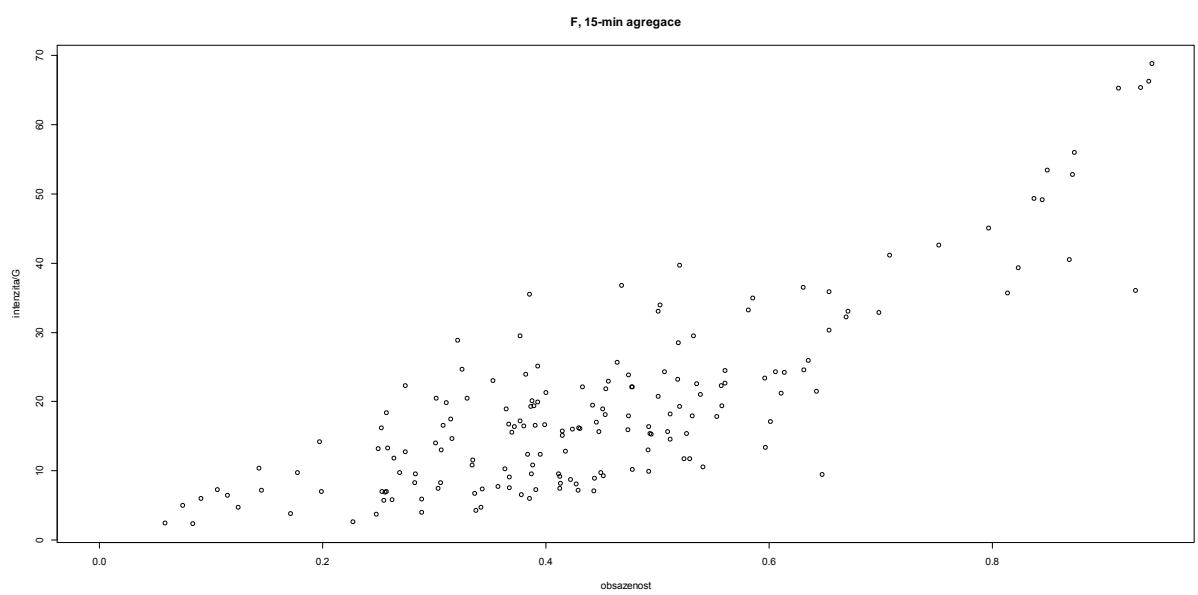
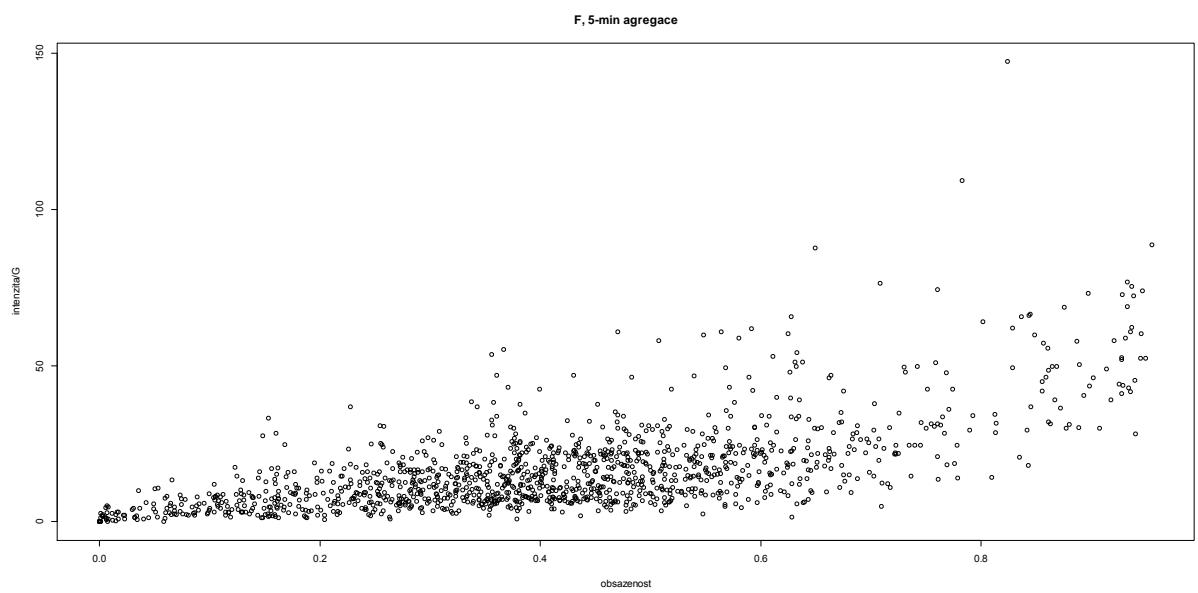
F, 30-min agregace



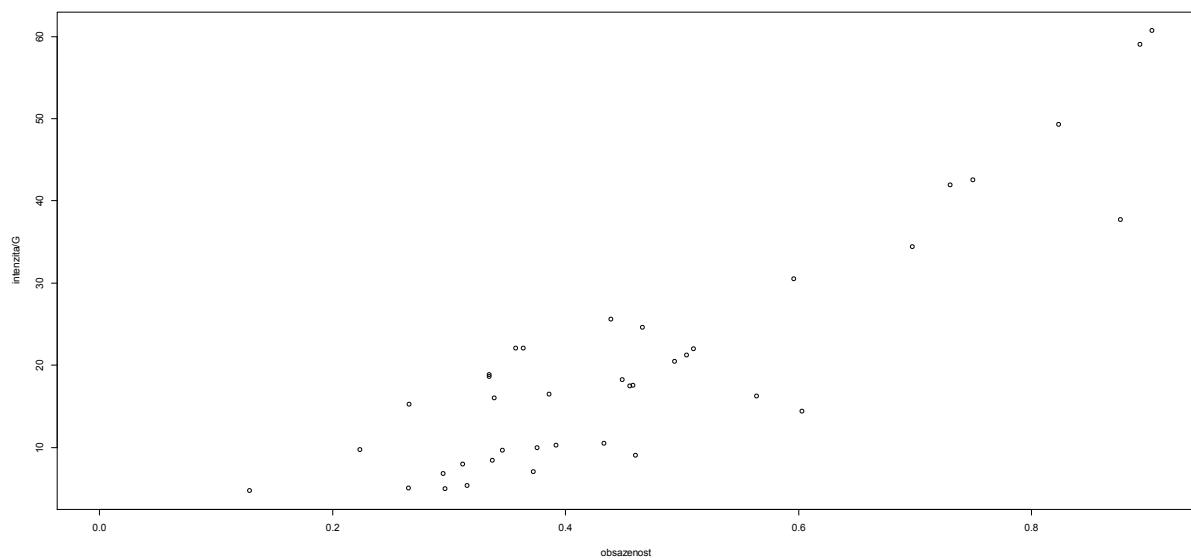


5.3.6.2 S dělením intenzity délkom zelené

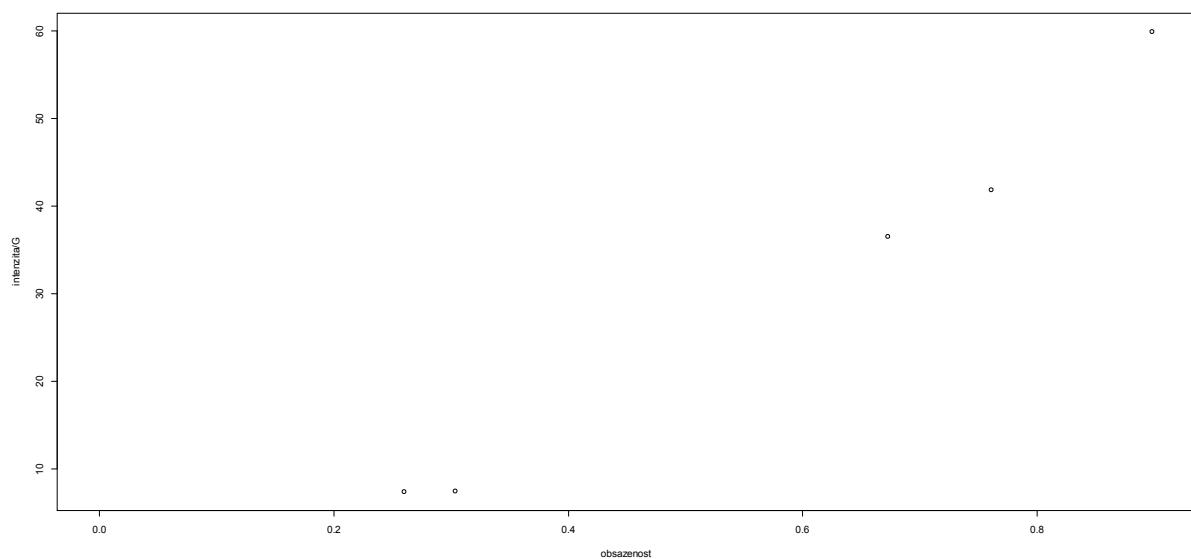




F, 30-min agregace

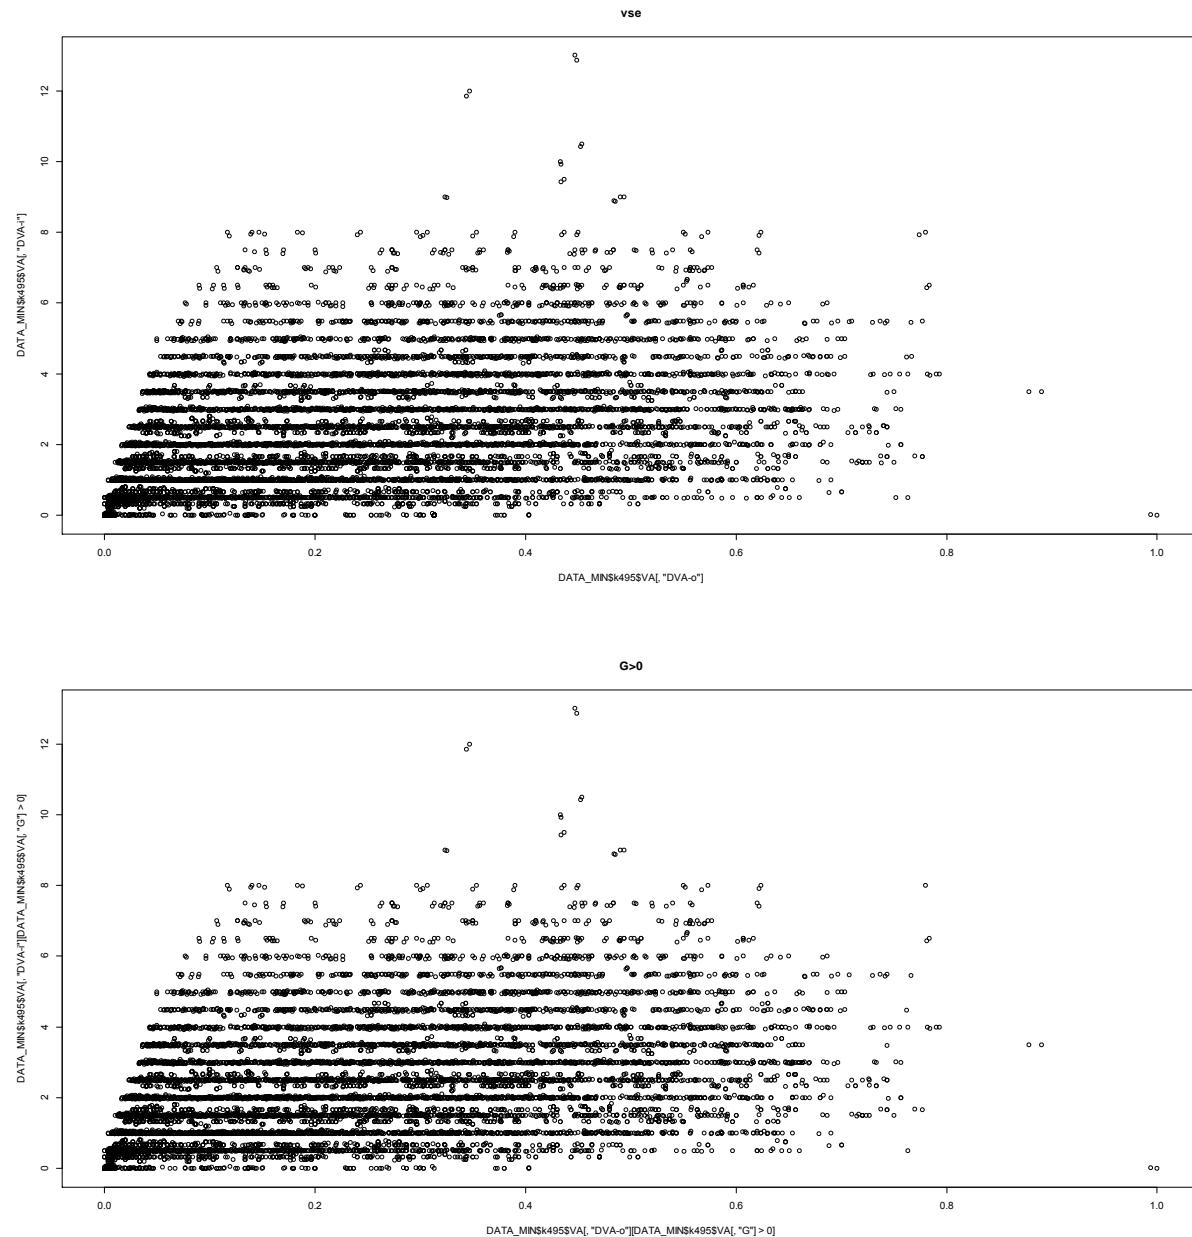


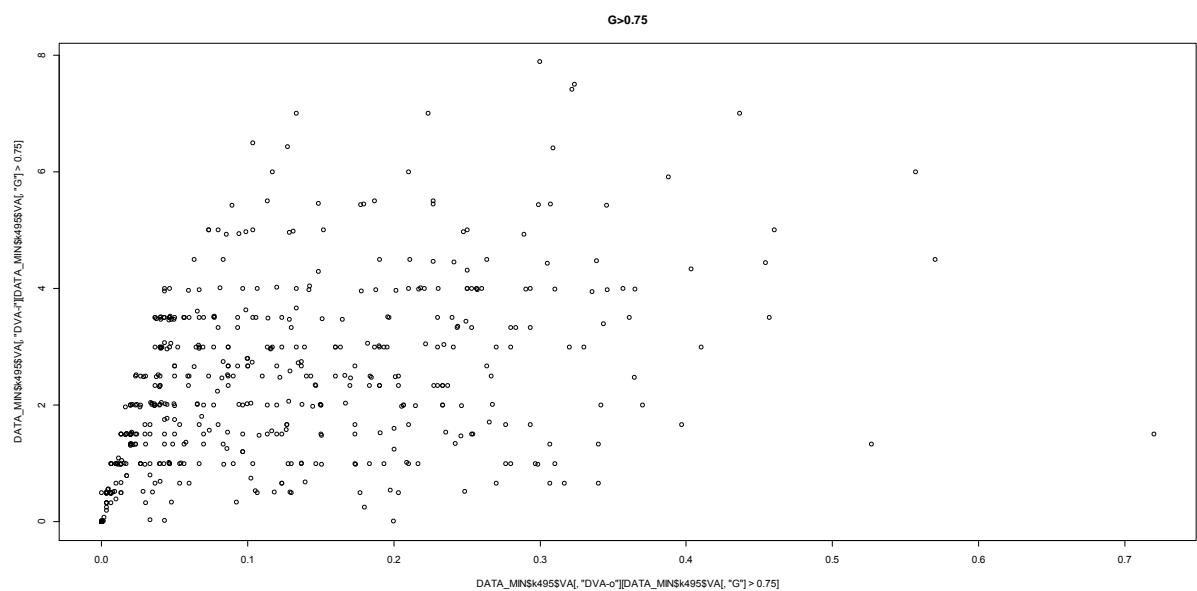
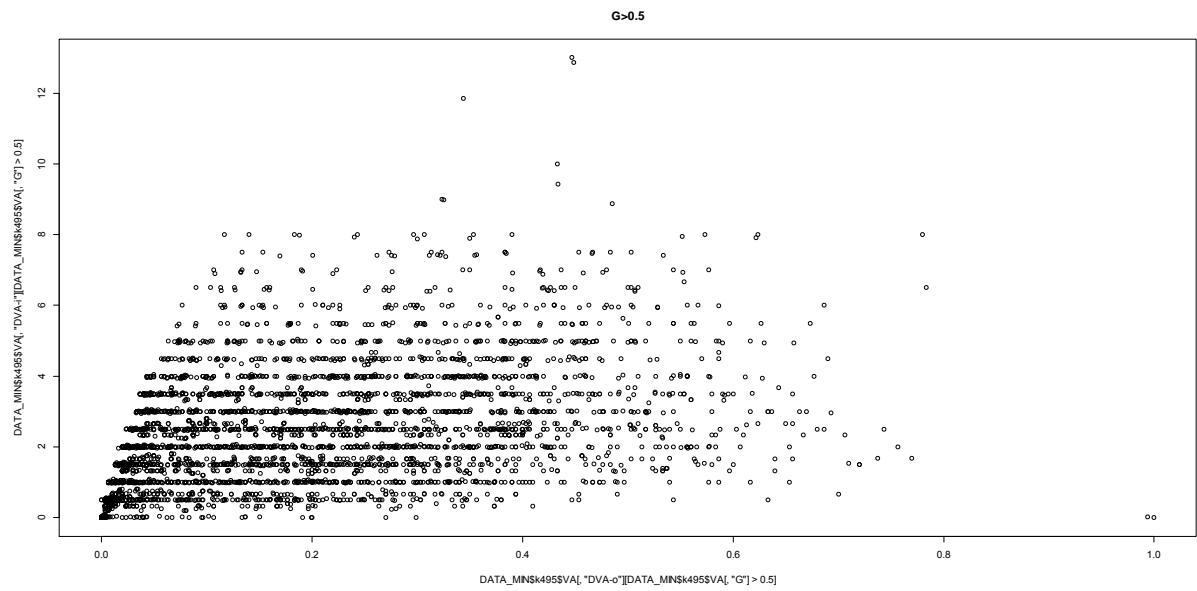
F, 1-hod agregace

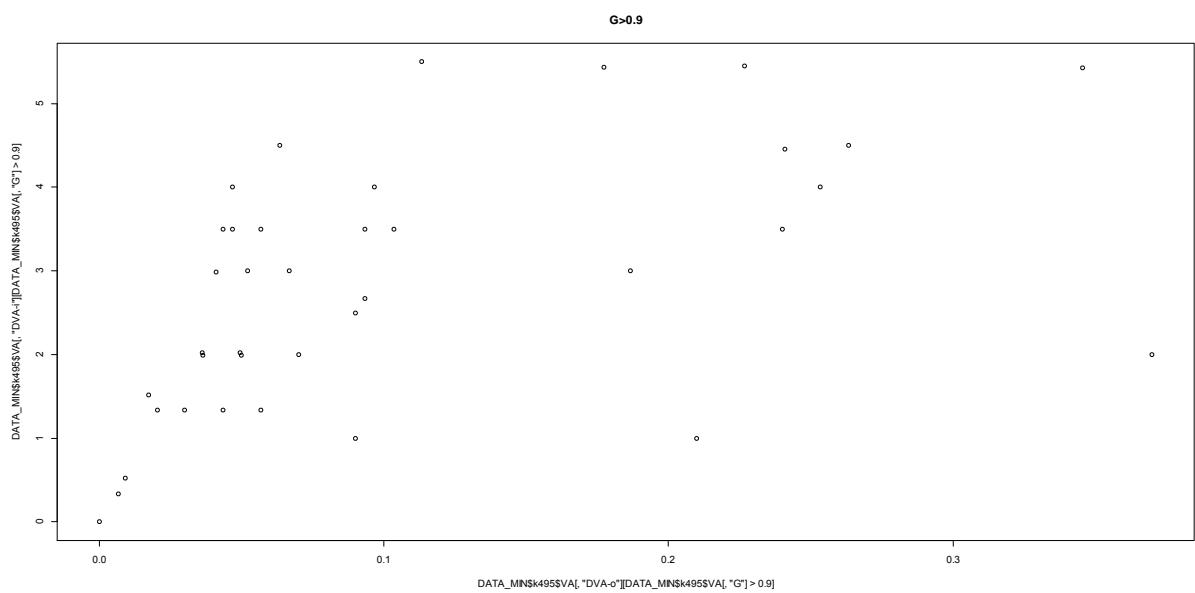
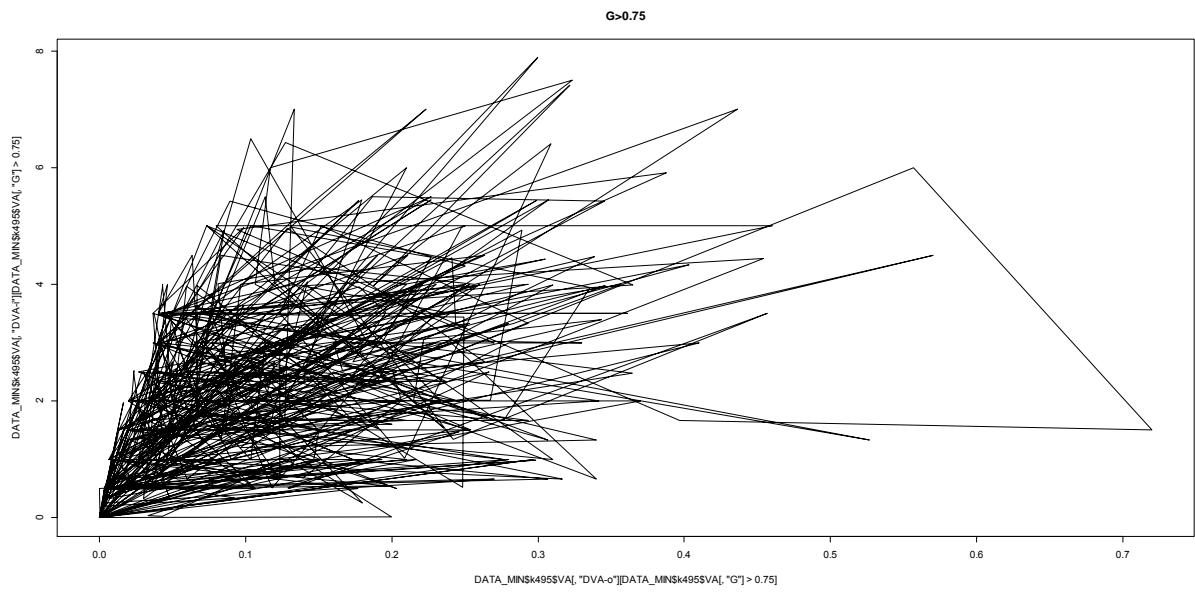


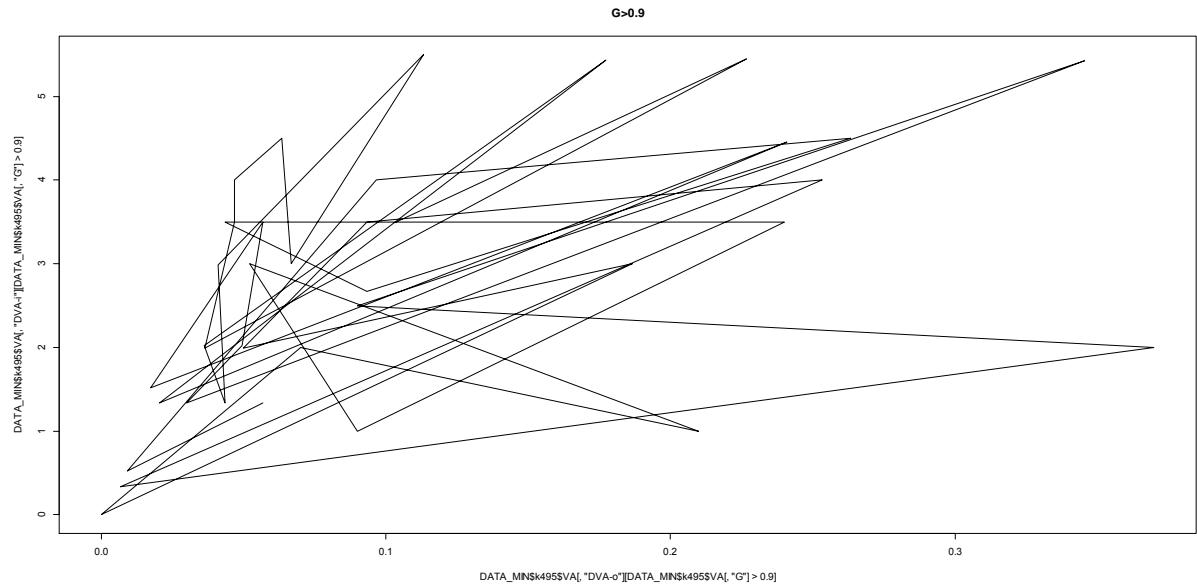
5.4 K495, MFD z povýběrů s různě dlouhou zelenou

5.4.1 A



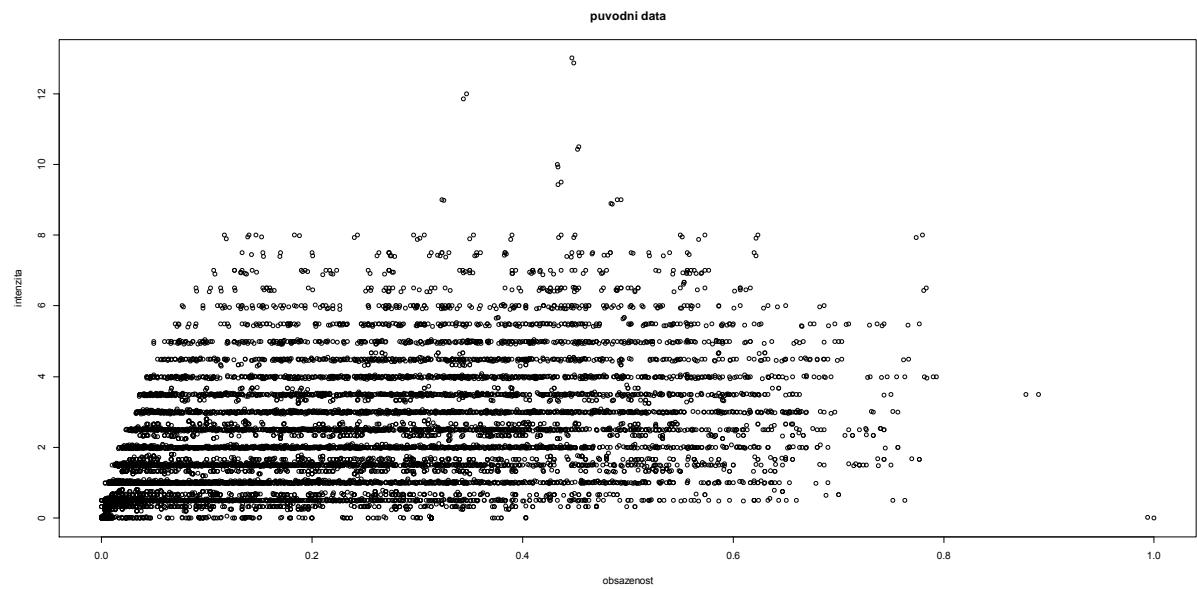


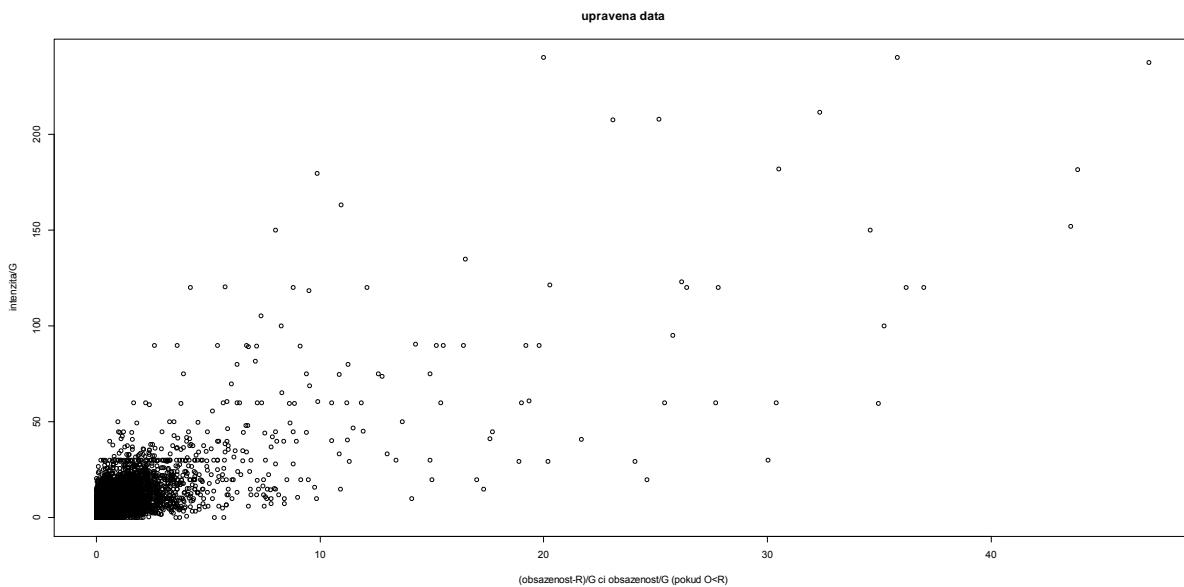




5.5 K496, I/G vs. (O-R)/G či O/G (pokud O<R)

5.5.1 A





6 Závěr

Statistické analýzy dat z detektorů na křížovatkách ukazují na lepší informační výtěžnost měření intenzity oproti obsazenosti. Obě veličiny mohou být postiženy občasnými výpadky či „zasekáváním“ detektoru ale chování intenzit je podstatně vyrovnanější a hladší oproti obsazenostem. Kvalitativně to není překvapivé zjištění uvážíme-li že integrovaný (vyhlazený) charakter intenzit je dán jednak lépe definovaným procesem měření ale hlavně inherentním prostorovým průměrkováním intenzit (které musí např. na sousedních křížovatkách splňovat bilanční rovnice) - oproti tomu obsazenosti jsou značně lokální (v čase i prostoru). Překvapivý je ale rozsah variability v obsazenostech a to jak absolutně tak (zejména) vzhledem k variabilitě intenzit.

Z inspekce různých vlastností dat a porovnání různě agregovaných (vyhlazených) intenzit a obsazeností se zdá že (alespoň pro zkoumané křížovatky) skutečná (či užitečná) informace přinášená intenzitami a obsazenostmi se do značné míry dublují, s tím ale že v obsazenosti je podstatně větší šum. Po (již vcelku malém) vyhlazení je vztah intenzity a obsazenosti do značné míry lineární (chybí nelinearita z teoretického fundamentálního diagramu). Původní data přitom nelinearitu se značným zašuměním (zejména ve směru obsazeností) vykazují – dost možná jen vlivem nezanedbatelných „měřicích“ chyb obsazenosti („měřicí chybou“ zde myslíme nejen skutečnou chybu detektoru ale i variabilní chování řídících ve smyslu pomalého/rychlého dojízdění k detektoru, či ve smyslu ponechávání různě velkých mezer apod.).

Pokud by tato zjištění byla potvrzena (např. na základě dodatečných měření jež by pravděpodobně bylo možné sesbírat a statisticky analyzovat s pomocí formalizovaných modelů v příštím roce), měla by nezanedbatelné konsekvence pro automatické řízení (včetně např. i možnosti potlačení vlivu obsazenosti na řídící algoritmus a/nebo výrazného, např. modelově indukovaného vyhlazení

obsazenosti např. vhodně formulovaným stavovým modelem). Vývoj takového modelu je jedním z možných námětů do budoucna.

Při použití dat v syrové podobě vzniká nezanedbatelné riziko toho že obsazenost může přinášet více šumu než užitečné informace (která by nebyla již obsažena v intenzitě).

Důležitým tématem je vliv rozdílné délky zelené na obsazenost a intenzitu v relativně krátkých intervalech. Odvození případné korekce je netriviálním problémem a zcela jistě by muselo jít za prosté dělení délkou zelené apod. Jednou z možností je naměření dodatečných (mikro) dat vypovídajících o chování vozidel těsně po změně barvy na zelenou a jejich statistická analýza (např. pomocí semiparametrických regresních modelů zformulovaných v součinnosti s dopravními experty a odhadnutých na empirických datech). Korekce by pak mohla být odvozována z odhadnutého modelu namísto ad hoc přístupu typu dělení délkou intervalu který není ani zdaleka optimální (viz nemonotónní průběh intenzit a obsazeností v závislosti na délce zelené).

Jako slibný pro řízení křížovatek s velmi nerovnoměrným provozem (jako např. na Zlíně v okolí Metropole) se ukazuje přístup založený na Hidden Markov chain model (HMM) ve kterém se z pozorovaných vícerozměrných dat (např. vektoru intenzit na Dstop detektoru) odhaduje latentní stav (reprezentující diskrétně definovaný kvalitativní „pracovní režim“ křížovatky).

Právě odhadnutý latentní stav je možné využívat k řízení křížovatek. A to jak samostatně (odlišení kvalitativně různých režimů ve kterých by řízení mělo být zcela jiné) nebo (lépe) ve spolupráci se spojitým řídícím algoritmem vyvíjeným v ÚTIA (spojitý algoritmus fungující pro některé stavy a kvalitativní řízení pro stavy v nějakém smyslu extrémní či speciální). HMM lze používat jak staticky (odhad observačního rozdělení a jeho průměru pro různé stavy pro které by byl napevno nastaven řídící plán), tak dynamicky (predikce stavů z Markovovského řetězce jsou rychlé jednoduché a užitečné pro krátkodobé predikční horizonty).

Pro statické řízení (např. nastavení pevných řídících plánů pro určité části dne dle z dat odvozené periodicity denní*týdenní) je možné v budoucnu využít strukturované statistické modelování semiparametrického regresního typu (např. GAM, generalized additive model se flexibilní splinovou částí a penalizací z dopravně inženýrského hlediska motivovaných funkcionálů). Na tomto základě by bylo možné uvažovat o sestavení obecné metodiky pro odvození periodických plánů pro nové křížovatky (či pro ladění lokalit stávajících) – od sběru dat, přes odhad periodického modelu (denní a týdenní) sezonality až k odvození (na modelových odhadech založených) periodických plánů.

Jednou z výhod takového přístupu je i to, že umožňuje vcelku jednoduchým způsobem zohlednit i „nejistotu“ (tedy zbytkovou variabilitu po extrakci periodické složky) a odvozovat řídící plány s přihlédnutím nejen k průměru ale i k variabilitě.

7 Literatura a reference

Anonymous (2013): Wikipedia heslo o Hidden Markov modelech: http://en.wikipedia.org/wiki/Hidden_Markov_model

Bilmes, J.A. (1986): A gentle tutorial of the EM algorithm and its application to parameter estimation for gaussian mixture and hidden Markov models. International Computer Science Institute and Department of Electrical Engineering and Computer Science, U.C. Berkeley, report TR-97-02, Berkeley, California, USA.

Brabec,M.-Konar,O.-Kasanicky,I.-Pelikan,E.-Maly,M.-Lokaj,Z. (2013): Forecasting system for truck parking based on statistical modeling of indirect, easily available data. The 11th European Transport Congress. Faculty of Transportation, Czech Technical University, Praha, 19-20 September 2013. CD, Proceedings of the 11th European Transport Congress, pages 26-28.

Cleveland, W.S. (1979). Robust Locally Weighted Regression and Smoothing Scatterplots. Journal of the American Statistical Association 74 (368): 829–836.

Cleveland,W.S.-Devlin,S.J. (1988). Locally-Weighted Regression: An Approach to Regression Analysis by Local Fitting. Journal of the American Statistical Association 83 (403): 596–610

Geroliminis,G.-Daganzo,C.F. (2008): Existence of urban-scale macroscopic fundamental diagrams: Some experimental findings. Transportation Research Part B 42 (2008) 759–770

Hastie,T.-Tibshirani,R.-Friedman,J.H. (2009): The elements of statistical learning: data mining, inference, and prediction, 2nd ed., Springer, Berlin.

Chambers,J.M.-Cleveland,W.,S.-Kleiner,B.-Tukey,P.,A. (1983): Graphical Methods for Data Analysis. Wadsworth & Brooks/Cole.

McCullagh,P.-Nelder,J.A. (1989): Generalized Linear Models, Chapman and Hall, London.

Rabiner,L.R. (1989): A tutorial on Hidden Markov models and selected applications in speech recognition. Proceedings of the IEEE, vol 77, no. 2

Pekár,S.-Brabec,M. (2009): Moderní analýza biologických dat (zobecněné lineární modely v prostředí R), Scientia. Praha. 978-80-86960-44-9

R Core Team (2013). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Dostupné z: <http://www.r-project.org/>.

Sarkar, D. (2008): Lattice: multivariate data visualization. Springer.

Schervish,M.J. (1995): Theory of statistics, Springer, New York, 1995.

Taramasco,O.-Bauer,S. (2013). RHmm: Hidden Markov Models simulations and estimations. R package version 2.0.3. Dostupné z: <http://cran.r-project.org/package=RHmm>

Wood,S.N. (2006): Generalized additive models, Chapman and Hall/CRC Press, Boca Raton.