



Akademie věd České republiky  
Ústav teorie informace a automatizace

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

## RESEARCH REPORT

PAVLA PECHERKOVÁ, IVAN NAGY, JINDŘICH DUNÍK

### Odhad délky kolon

2149

listopad 2005

MŠMT ČR 1M0572, MD ČR 1F43A/003/12012

ÚTIA AVČR, P.O.Box 18, 182 08 Prague,  
Czech Republic

Fax: (+420)286890378, <http://www.utia.cas.cz>, E-mail: [utia@utia.cas.cz](mailto:utia@utia.cas.cz)

# 1 Úvod

V předchozích verzích odhadu délek kolon v mikrooblasti [?, ?], jsme předpokládali, že všechny dopravní parametry, určené podle dopravního návrhu, jsou přesné, a co více, jsou konstantní. Tento předpoklad je velmi slabý. Argumentovat můžeme například pomocí parametru směrových vztahů. Tento parametr udává, jaký podíl aut pojedou křižovatkou rovně, jaký doprava a doleva. Je celkem jasné, že hodnoty tohoto parametru nemohou být přes den konstantní. Ráno jedou lidé do práce, odpoledne nakupovat a večer třeba za zábavou. Směr, kterým pojedou se tedy bude přes den nutně lišit.

Další, již dříve popsanou, komplikací při použití lineárního modelu mikrooblasti je jeho špatná pozorovatelnost z měřených výstupů. Počáteční úplná nepozorovatelnost modelu v okamžiku existence kolon byla řešena přidáním vazby mezi obsazeností a délkou kolony v jednotlivých ramenech křižovatek. I v této vazbě byly předpokládány známé a konstantní koeficienty, odvozené na základě minimální obsazenosti v dostatečné vzdálenosti od konce kolony, její maximální hodnotě v blízkosti konce kolony a předpokladu o jejím lineárním nárůstu. I v tomto případě však nebylo dosaženo úplné pozorovatelnosti, konkrétně ramena spojující jednotlivé křižovatky, která byla bez měřících detektorů (což je spíše pravidlo než výjimka), zůstávala v případě existence kolon nepozorovatelná.

Jestliže zůstaneme u již osvědčeného postupu jak ze zbavovat nepozorovatelnosti, a to pomocí přidávání vazeb mezi modelovanými veličinami, zjistíme, že nevhodnějším způsobem, jak zajistit úplnou pozorovatelnost modelu, je přidat vazby mezi obsazenostmi v sousedních ramenech křižovatek. Tyto vazby ale nemají fyzikální opodstatnění, jako ty předešlé, a lze je zdůvodnit "psychologicky", např. takto: bude-li v hlavním směru veliká obsazenost (tj. kolona), budou se řidiči snažit tuto kolonu objet a tím stoupne provoz (obsazenost) i v kapacitě okolí hlavního směru. Koeficienty těchto vazeb však nelze určovat z fyzikální podstaty, ale je nutné je identifikovat z měřených dat (tj. intenzit a obsazeností). Identifikace neznámých parametrů spolu s odhadováním stavu vede, jak již bylo v minulosti zdůrazněno, k problému nelineární filtrace. Nutno ale zdůraznit, že se jedná o poměrně "jednoduchou nelinearitu". Máme lineární model s neznámými parametry (které jsou součástí stavu), a tedy v modelu se vyskytují součiny různých složek stavu. Tento fakt "jednoduchosti nelinearity" byl důležitý pro volbu metody aproximace nelineární verze Kalmanova filtru.

## 2 Dopravní data

### 2.1 Základní veličiny dopravních dat

Dopravní data jsou data, která souvisí s dopravním provozem. Lze je rozdělit na pevná a pohyblivá, podle jejich časové proměnnosti. Do pevných dat lze brát takové údaje, které se zjišťují ze stavební úpravy dané dopravní oblasti (vzdálenost křižovatek, šířka a počet jízdních pruhů atd.) a z občasného měření (odbočovací poměry). I tato data se ovšem mohou časem měnit, ale nebývá to změna výrazná oproti původním měřením. Například u odbočovacího poměru se tento poměr může měnit během jednoho dne. Dopravní data proměnlivá se získávají z detektorů a z řadičů. Tato data mohou dát informaci o reálném provozu v dané chvíli, který se nachází na měřené komunikaci a křižovatce.

Detektory nám mohou poskytnout dopravní proměnné:

- Intenzita - počet vozidel, který projede daným místem za časovou periodu [j.v./per].
- Obsazenost - poměr doby zatíženosti detektoru vozidlem k celkové době periody [%].

Řadiče nám umožňují získat další důležité informace, především:

- doba cyklu - doba, kdy se vystřídají všechny fáze [s].
- doba zelené - délka zelené v jednom cyklu. Doba zelené se rovná délce fáze [s].
- offset - časové zpoždění mezi křižovatkami [s].

Ze stavebních dispozic křižovatky můžeme získat důležitou veličinou, kterou je

- saturovaný tok - maximální počet vozidel, který může projet daným místem křižovatky za časovou periodu za předpokladu, že po celou dobu svítí zelená [j.v./per].

Znalost saturovaného toku a doby zelené umožní získat velmi důležitou proměnnou:

- kapacita - počet vozidel, které mohou projet daným místem křižovatky, vzhledem ke skutečné době zelené za časovou periodu [j.v./per].

## 2.2 Model dopravní mikrooblasti s plnou pozorovatelností

Při konstrukci modelu vyjdeme z stávajícího stavu, tj. uvažujeme (i) hydrodynamickou analogii pro intenzity dopravního proudu a kolony v ramenech křižovatek, (ii) lineární vztah mezi obsazeností na strategickém detektoru a délkou kolony. Situaci naznačíme (nebo lépe řečeno budeme fixovat - neboť i zde je několik variant řešení) nejprve pro jedno rameno.

### 2.2.1 Jedno rameno v křižovatce - známé parametry

Označme:

$\xi_{i,t}$  *délku kolony* v čase  $t$  na rameni  $i$ ;

$I_{i,t}$  *vstupní intenzitu* v čase  $t$  měřenou na strategickém detektoru sledovaného ramene  $i$ ;

$O_{i,t}$  *vstupní obsazenost* v čase  $t$  měřenou na strategickém detektoru sledovaného ramene  $i$ ;

$Y_{i,t}$  *výjezdní intenzitu* z ramene  $i$  do prostoru křižovatky v čase  $t$ ;

$\delta_{i,t}$  *indikátor kolony* v čase  $t$  na rameni  $i$ ;

$\delta = 1$  když kolona existuje a  $\delta = 0$  když kolona neexistuje.

$\alpha_{i,j}$  *poměr odbočení* z ramene  $i$  do ramene  $j$ ;

$S_i$  *saturovaný tok* na rameni  $i$ ;

$z_{i,t}$  *relativní doba zelené* na rameni  $i$  v čase  $t$ ;

$\kappa_{i,t}, \beta_{i,t}, \lambda_{i,t}$  *parametry vztahu* mezi délkou kolony a obsazeností na rameni  $i$  v čase  $t$ ,

$v_{i,j}$  *parametr vztahu* mezi obsazenostmi na sousedících ramenech  $i$  a  $j$  křižovatky,

Potom základní model, popisující tvorbu kolony v rameni je následující:

#### Definice stavu a výstupu

$$\text{STAV: } x_t = \begin{bmatrix} \xi_t & O_t \end{bmatrix}' \quad \text{VÝSTUP: } y_{t+1} = \begin{bmatrix} Y_{t+1} & O_{t+1} \end{bmatrix}'$$

#### Základní stavová rovnice:

$$\xi_{t+1} = \delta_t \xi_t - [\delta_t S + (1 - \delta_t) I_t] z_t + I_t \quad (1)$$

$$O_{t+1} = \kappa \xi_t + \beta O_t + \lambda \quad (2)$$

#### Základní výstupní rovnice:

$$Y_{t+1} = -\xi_{t+1} + \xi_t + I_t \quad (3)$$

$$O_{t+1} = O_{t+1} \quad (4)$$

#### Vektorový tvar stavového modelu

$$\begin{bmatrix} \xi_{t+1} \\ O_{t+1} \end{bmatrix} = \underbrace{\begin{bmatrix} \delta_t & 0 \\ \kappa & \beta \end{bmatrix}}_A + \underbrace{\begin{bmatrix} -\delta_t \cdot S - (1 - \delta_t) \cdot I_t \\ 0 \end{bmatrix}}_B \cdot z_t + \underbrace{\begin{bmatrix} I_t \\ \lambda \end{bmatrix}}_F$$

$$\begin{bmatrix} Y_{t+1} \\ O_{t+1} \end{bmatrix} = \underbrace{\begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix}}_C \begin{bmatrix} \xi_{t+1} \\ O_{t+1} \end{bmatrix} + \underbrace{\begin{bmatrix} \hat{\xi}_t + I_t \\ 0 \end{bmatrix}}_G$$

V tomto modelu nejsou směrové vztahy  $\alpha$  a vztahy mezi jednotlivými rameny  $v$  vidět, protože je popisováno pouze jediné rameno. Při popisování více ramen či dokonce několika křižovatek je postup stejný. Stavový model pro větší mikrooblasti je popsán u experimentů.

## 3 Odhad stavu

### 3.1 Lineární Kalmanův filtr

Shrneme základní fakta, ze kterých tato metoda vychází [?].

#### Model

$$\begin{aligned}x_{t+1} &= Ax_t + Bu_t + v_t \\y_t &= Cx_t + e_t\end{aligned}$$

kde

$$\text{cov}(v_t) = R_v, \text{cov}(e_t) = R_e.$$

Apriorní odhad stavu a jeho kovarianční matice jsou

$$\hat{x}_{1|0} = E[x_1|D_0], \quad P_{1|0} = E[(x_1 - \hat{x}_{1|0})(x_1 - \hat{x}_{1|0})'|D_0].$$

#### Predikce výstupu

Podle rovnice pro výstup a s využitím kovarianční matice odhadu stavu  $P_{t|t-1}$  provedeme predikci výstupu a určíme (nikoliv rekurzivně) jeho kovarianční matici

$$\hat{y}_t = C\hat{x}_{t|t-1} \quad (5)$$

$$Q_t = R_e + CP_{t|t-1}C' \quad (6)$$

#### Datová aktualizace

Využijeme nově změřená data  $y_t$  a opravíme odhad stavu tak, aby ve smyslu nejmenších čtverců co nejlépe vyhovoval modelu (minimalizujeme rozptyl složek stavu). Odtud přepočít

$$\hat{x}_{t|t} = \hat{x}_{t|t-1} + K_t(y_t - \hat{y}_t) \quad (7)$$

$$P_{t|t} = P_{t|t-1} - P_{t|t-1}C'Q_t^{-1}C P_{t|t-1}, \quad (8)$$

kde

$$K_t = P_{t|t}C'Q_t^{-1}$$

#### Predikce stavu

Podle modelu pro stav děláme predikci v čase

$$\hat{x}_{t+1|t} = A\hat{x}_{t|t} + Bu_t \quad (9)$$

$$P_{t+1|t} = AP_{t|t}A' + R_v \quad (10)$$

### 3.2 Volba apriorních kovariančních matic

Pro spuštění Kalmanova filtru je třeba zadat kovarianční matice  $R_v$ ,  $R_e$  a počáteční hodnoty odhadu stavu  $x_{0|0}$  a jeho kovarianční matice  $P_{0|0}$ . Je známo, že správná volba kovariančních matic je pro další výpočty kritická. Volbě těchto matic se nyní budeme věnovat. Souhrnně lze konstatovat, že tyto matice lze volit v diagonální formě a jde nám o volbu velikosti jednotlivých prvků na diagonále. Malé prvky vyjadřují přesnost odpovídající veličiny, velké prvky nepřesnost.

#### Kovarianční matice modelů

Jsou to kovarianční matice šumů v modelech stavu a výstupu. Tyto modely mají obecný tvar

$$z_{t+1} = \hat{z}_{t+1} + e_t,$$

kde

$$\hat{z}_t = E[z_t|D(t)] \quad (D(t) \text{ je okamžitá znalost});$$

$$\text{cov}(e_t) = R \text{ je kovarianční matice šumu.}$$

## Matice $R_v$

Jedná se o kovarianční matici modelu stavu. Její apriorní hodnotu lze počítat tak, že spočteme výběrovou kovarianční matici odchylky stavu od jeho denního průběhu. Denní průběh lze nahradit vyhlazeným průběhem stavu z jednoho dne, např. pomocí průměrování v pevném plovoucím okně.

## Matice $R_e$

Je to kovarianční matice modelu pro výstup. Zatímco model stavu se používá ve smyslu predikce (nový stav ze starého a vstupu), je význam modelu pro výstup jiný. Modelovaná veličina  $y$  se měří a její hodnota se používá pro korekci existujícího odhadu stavu. Tedy stav je, a chyba  $e$  může být způsobena chybou v měření  $y$  (nebo tím, že existující odhad stavu není správný !!!).

## Apriorní kovarianční matice odhadu stavu

Tato matice vyjadřuje neurčitost apriorního odhadu stavu. Je třeba si uvědomit rozdíl mezi odhadem parametrů a stavu. Při odhadu parametrů dáváme velkou kovarianční maticí parametrům prostor ke zkonvergování ke správným hodnotám. Stav se ale mění stále, a to podle stavového modelu. Velkou kovarianční maticí stavu dáváme tedy prostor stavu zkonvergovat ke svému modelu. Velkou kovarianční maticí dáváme tedy stavu prostor k tomu, aby se srovnal se svým modelem. Navíc, kovarianční matice odhadu stavu může v průběhu filtrace jak "klesat", tak i "narůstat", jak ukážeme dále.

Z pohledu na vývoj kovarianční matice pro odhad stavu (6), (8) a (10) vidíme některé důležité skutečnosti:

- Rovnice (6) a (10) se podílejí na nárůstu  $P$ , zatímco rovnice (8) na jejím poklesu. (Predikce zvyšuje neurčitost, filtrace snižuje.)
- Z rovnice (6) je patrné, že nemá smysl volit apriorní  $P$  menší, než  $R_e$  - ihned by se vyrovnala. Velká kovarianční matice  $P$  odpovídá velké neurčitosti ve výstupním modelu, tj. velké nepřesnosti v apriorním odhadu stavu nebo v měření.
- Ze vztahu pro  $K$  je patrné, že korekce stavu ve filtraci budou
  - větší, jestliže neurčitost odhadu stavu ( $P$ ) je větší,
  - menší, jestliže neurčitost měření výstupu ( $R_e$ ) je větší.
- A nakonec, když  $P$  při filtraci příliš klesne, rovnice (10) ho zase pozvedne podle  $R_v$ .

## 3.3 Odmocninová verze lineárního Kalmanova filtru

Základem odmocninové verze algoritmu pro Kalmanův filtr je rozklad kovariančních matic modelů na odmocniny, tj.  $R_v = r_v r_v'$  a  $R_e = r_e r_e'$  a stejně tak pro kovarianční matici odhadu stavu  $P = pp'$  a pomocnou matici  $Q = qq'$  (s příslušnými indexy). Potom platí: pro (6)

$$q = \text{trg}([r_e, Cp_{t|t-1}]),$$

pro 8 (provede se nějakým kouzlem), a pro 10

$$p_{t+1|t} = \text{trg}([r_v, Ap_{t|t}]),$$

kde  $\text{trg}(\cdot)$  představuje funkci trojúhelníkování.

Inverze při výpočtu  $K$  se provede jako inverze trojúhelníkové matice, což není numericky náchylné.

## 3.4 Metoda Extended Kalman Filter

Metoda Extended Kalman filter neboli metoda rozšířeného Kalmanova filtru je založena na linearizaci nelinearit [?]. Uvažujeme nelineární stavový model ve tvaru

$$\begin{aligned}x_{t+1} &= f(x_t, u_t) + v_t \\y_t &= g(x_t) + e_t\end{aligned}$$

Tento model linearizujeme pomocí prvních dvou členů Taylorova rozvoje v bodě  $\hat{x}_{t|t-1}$ , tj. v optimálním odhadu stavu z minulého kroku. Pro linearizovaný model platí

$$\begin{aligned}x_{t+1} &= f(\hat{x}_{t|t-1}, u_t) + dF [x_t - \hat{x}_{t|t-1}] + v_t \\y_t &= g(\hat{x}_{t|t-1}) + dG [x_t - \hat{x}_{t|t-1}] + e_t\end{aligned}$$

kde

$$dF = \left. \frac{df(x_t, u_t)}{dx_t} \right|_{x_t = \hat{x}_{t|t-1}}, \quad dG = \left. \frac{dh(x_t)}{dx_t} \right|_{x_t = \hat{x}_{t|t-1}}$$

### 3.5 Metoda DD1 pro nelineární filtraci

Metoda DD1 (Divided Difference of the 1st order) aproximuje derivace v Taylorově rozvoji pomocí symetrických diferencí [?].

Při posunu stavu  $x = x_0 + \Delta x$  se využívá transformace  $x_n = S^{-1}x_s$ , kde  $x_n$  je nový stav,  $x_s$  je starý stav a  $S$  je odmocnina z kovarianční matice stavu. Tím se složky stavu "vybělí" - platí pro ně  $E[(x_n - Ex_n)(x_n - Ex_n)'] = I$ , a tedy přírůstky nového stavu  $\Delta x = x_n - Ex_n$  mají nezávislé složky. To zjednodušuje další výrazy.

Postup při konstrukci algoritmu DD1 je následující:

1. Uvažujeme faktorizované kovarianční matice  $R_e$ ,  $R_v$ ,  $P_{t|t}$  a  $P_{t+1|t}$ . Faktory označíme malými písmeny.
2. Z odpovídajících (minulých) kovariancí určíme  $h$  pro diferencování - ve směrech vlastních vektorů.
3. Sestavíme matice diferencí

$$\begin{aligned}S_t^x &= (f(\hat{x}_{t|t-1} + hs_{x,j}, u_t, 0) - f(\hat{x}_{t|t-1} - hs_{x,j}, u_t, 0))/2h \\S_t^y &= (g(\hat{x}_{t|t-1} + hs_{x,j}, u_t, 0) - g(\hat{x}_{t|t-1} - hs_{x,j}, u_t, 0))/2h\end{aligned}$$

Matice diferencí  $I^v$ ,  $I^e$  podle šumů jsou jednotkové, protože šum je v našem případě aditivní.

4. Predikce

$$\begin{aligned}\hat{x}_{t+1|t} &= f(\hat{x}_{t|t}, u_t) \\p_{t+1|t} &= \text{trg}([S_t^x, I^v])\end{aligned}$$


5. Filtrace

$$\begin{aligned}\hat{y}_t &= g(\hat{x}_{t|t}) \\q_t &= \text{trg}([S_t^y, I^e]) \\K_t &= p_{t|t-1} S_t^y [q_t q_t']^{-1}\end{aligned}$$

$$\begin{aligned}\hat{x}_{t|t} &= \hat{x}_{t|t-1} + K_t (y_t - \hat{y}_t) \\p_{t|t} &= \text{trg}([p_{t|t-1} - K_t S_t^y, K_t])\end{aligned}$$

## 4 Jedna tříramenná křižovatka

### Dva vstupy a jeden výstup



Obrázek 1: Tříramenná jednosměrná křižovatka s jedním neměřeným vstupem

### 4.1 Úplný stavový popis

Stavový model lze popsat jako

$$x_{t+1} = Ax_t + Bz_t + F + \epsilon_t \quad (11)$$

$$y_{t+1} = Cx_{t+1} + G + e_t \quad (12)$$

$$x_t = \begin{bmatrix} \xi_{1,t} & \xi_{3,t} & O_{1,t} & O_{3,t} \end{bmatrix}',$$

$$A = \begin{bmatrix} \delta_{1,t} & 0 & 0 & 0 \\ 0 & \delta_{3,t} & 0 & 0 \\ \kappa_{1,t} & 0 & \beta_{1,t} & 0 \\ 0 & \kappa_{3,t} & v_{1,3} & \beta_{3,t} \end{bmatrix}, \quad B = \begin{bmatrix} -b_1 & 0 \\ 0 & -b_3 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}, \quad F = \begin{bmatrix} I_1 \\ I_3 \\ \lambda_1 \\ \lambda_3 \end{bmatrix},$$

kde  $b_i = (1 - \delta_{i,t})I_{i,t} - \delta_{i,t}S_i$  a  $z_t = [z_{1,t} \ z_{2,t} \ z_{3,t} \ z_{4,t}]$ .

$$C = \begin{bmatrix} -\alpha_{1,2} & -\alpha_{3,2} & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \quad G = \begin{bmatrix} \hat{\xi}_{1,t} + I_{1,t} \\ \hat{\xi}_{3,t} + I_{3,t} \\ 0 \\ 0 \end{bmatrix}.$$

### 4.2 Experimenty - simulovaná data A

Z reálných dat bez kolon byly vytvořeny data s kolonami tak, že vstupní intenzity  $I_1$  a  $I_3$  se zvýšily. Touto úpravou se podařilo získat data na reálném základě, ale s kolonami. Simulací se zjišťovala skutečná délka kolony.

#### 4.2.1 Počáteční nastavení

- poměr odbočení:  $\alpha_{32} = 1$ ;  $\alpha_{42} = 1$ ,
- saturovaný tok:  $S_1 = 25$ ;  $S_2 = 130$ ,
- parametry vztahu kolona - obsazenost:  $\kappa_1 = \kappa_2 = 0.07$ ;  $\beta_1 = 0.6$ ;  $\beta_2 = 1.0$ ;  $\lambda_1 = 0$ ;  $\lambda_2 = 1.2$ ,
- parametr vztahu obsazenosti sousedních ramen:  $v_1 = 0.1$ ;

```

load dataR-V6.mat
Ip = data(:,14)*1; % poruchový vjezd na výstupu
I1 = data(:,15)*1.3; % Matousova
I3 = data(:,16)*1.5; % Zborovska
z1 = data(:,3);
z2 = data(:,4);

```

#### 4.2.2 TEST 1

**Cíl:** Zjistit, zda je vhodnější pro odhad použít lineární Kalmanův filtr (KF) nebo nelineární DD1 filtr.

**Nastavení (2):** Apriorní nastavení kovariančních matic (pro test DD1):

```

% odhady stavu a parametru
pred.sqrt_var = diag([1e5*ones(1,4) 1e5 1e-1*ones(1,nx-5)]);
% stredni hodnoty stavoveho sumu a sumu mereni
pwk.mean = zeros(nx,1);
pvk.mean = zeros(ny,1);
% kovariancni matice stavoveho sumu a sumu mereni
pwk.var = diag([1e5*ones(1,4) 1e5 1e-1*ones(1,nx-5)]^1);
pvk.var = 1e-1*diag(ones(1,ny));

```

Apriorní nastavení kovariančních matic (pro test KF):

```

% odhady stavu a parametru
pred.sqrt_var = diag([1e5*ones(1,4) 1e5]^2);
% stredni hodnoty a kovariancni matice sumu mereni a stavoveho sumu
pwk.mean = zeros(nx,1);
pvk.mean = zeros(ny,1);
pwk.var = diag([1e5*ones(1,4) 1e5]);
pvk.var = 1e-1*diag(ones(1,ny));

```

**Postup testu** Testovaná data byla připravena tak, aby se vyskytovaly kolony a neměřený vjezd, podle obrázku 1. Na tato data byl použit lineární Kalmanův filtr a nelineární DD1 filtr. Pro oba filtry bylo použito stejné počáteční nastavení (viz 4.2.1).

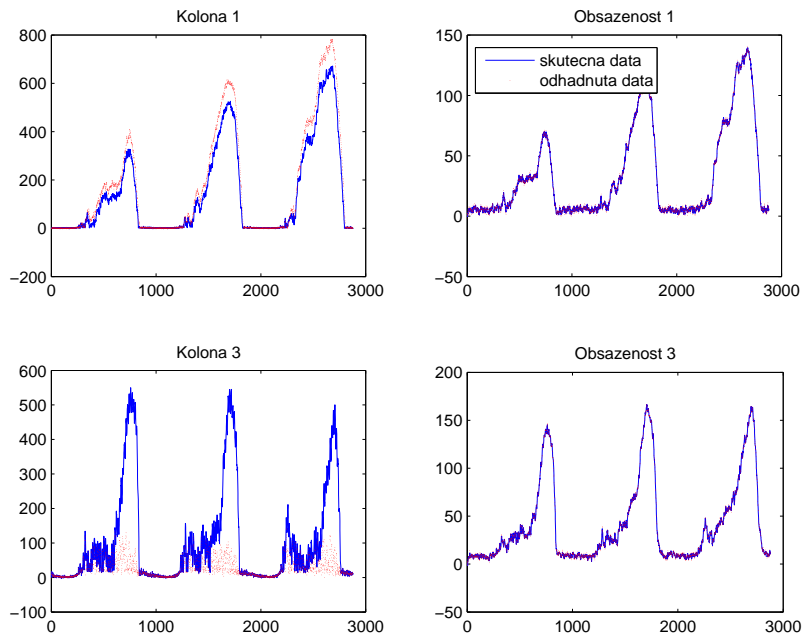
#### **Výsledky:**

**Lineární Kalmanův filtr (KF)** Kalmanův filtr má po celou dobu konstantní parametry, jak je vidět na obrázku 3. Z důvodu existence neměřeného vjezdu lze na obrázku 2 pozorovat, že toto nastavení naprosto nedostačuje. Chyba odhadu délky kolony skutečné a odhadnuté je příliš vysoká. Tato chyba se pohybuje kolem 50 %. Nevhodnost použití KF lze pozorovat i na obrázku 5, kde je znázorněn rozdíl hodnot mezi měřeními a modelem. Filtr není schopen správně spojit měření s modelem.


<sup>1</sup>hodnota kovariance 1e-1 u parametrů zajistí dostatečnou možnost změny parametru

<sup>2</sup>u KF se stavový model nerozšiřuje, proto zde není uvedena kovariance parametrů







Obrázek 2: Skutečné a odhadnuté kolony pomocí KF



Obrázek 3: Vývoj odhadu parametrů v čase u KF

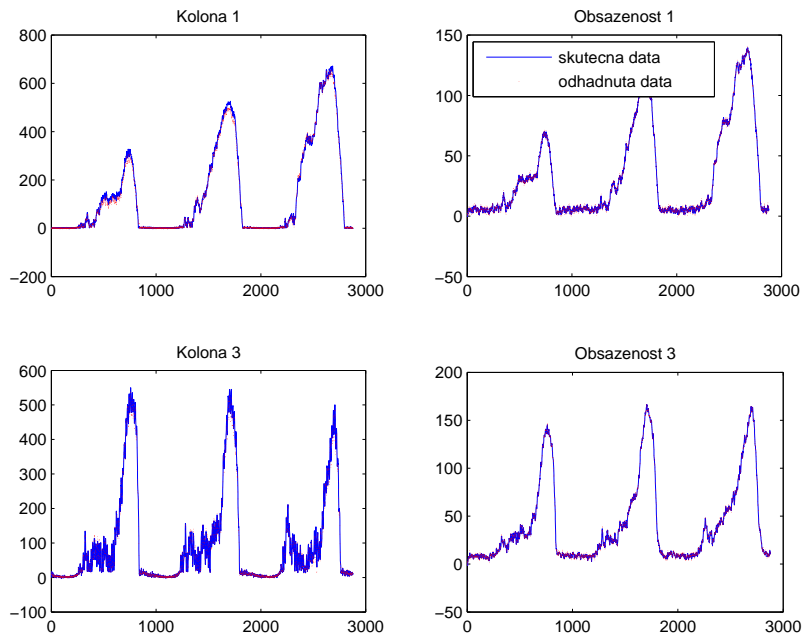


Obrázek 4: Odchyly skutečné a odhadnuté kolony pomocí KF




Obrázek 5: Chyba predikce KF

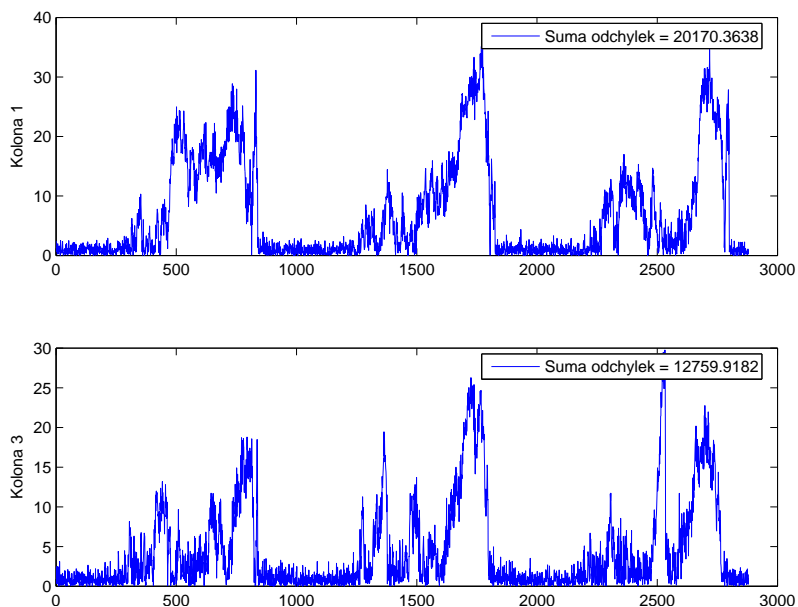
**Nelineární DD1 filtr** Nelineární filtr DD1 umožňuje dělat správné odhady i při jisté neurčitosti, jakou je v tomto případě neměřený vstup  $I_p$ . Parametry jsou odhadovány a v čase proměnné, jak je vidět na obrázku 7. Skutečné délky kolon se příliš neliší od odhadované délky kolon, viz obrázek 6 a tedy i odchyly jsou mnohem menší a pohybují se kolem 5 %. Správnost nastavení filtru si lze ověřit i na obrázku 9. Model byl nejdříve nastaven na špatnou hodnotu, ale díky změně parametrů se filtru podařilo srovnat model s měřením. Tato změna lze nejlépe pozorovat u Kolony 3 na začátku.



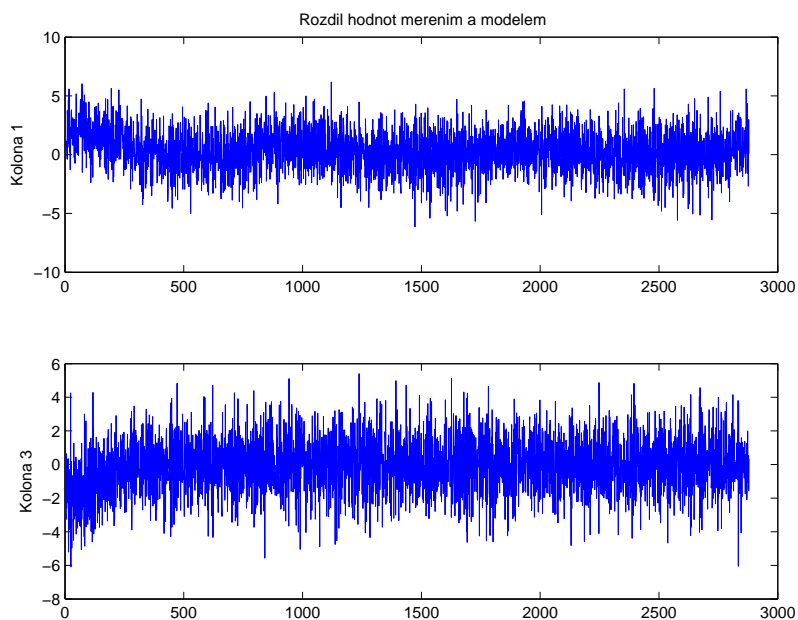
Obrázek 6: Skutečné a odhadnuté kolony pomocí DD1 filtru



Obrázek 7: Vývoj odhadu parametrů v čase u DD1 filtru



Obrázek 8: Odchyly skutečné a odhadnuté kolony pomocí DD1 filtru



Obrázek 9: Chyba predikce u DD1 filtru

**Porovnání KF a DD1 filtru** Pro porovnání bylo vybráno kritérium co nejlepší odhad délky kolony vzhledem ke skutečné. Celkové výsledky jsou zpracované v tabulce 10. Jsou zde zaznamenány odchyly od skutečné délky kolony u KF a DD1 filtru a to jak absolutně, tak i procentuálně. Sloupec zlepšení ukazuje, jakého procentuálního zlepšení jsme dosáhli poté, co jsme místo KF použili DD1 filtr.

Číslo ramene	Délka skut. kolony	KF		DD1 filtr		Zlepšení v %
		odchylka	v %	odchylka	v %	
1	$4,113 \cdot 10^5$	$9,986 \cdot 10^4$	24,28	$2,017 \cdot 10^4$	4,90	+19,38
3	$2,934 \cdot 10^5$	$2,101 \cdot 10^5$	71,62	$1,275 \cdot 10^4$	4,35	+67,27
1+3	$7,047 \cdot 10^5$	$3,100 \cdot 10^5$	43,99	$3,293 \cdot 10^4$	4,67	+39,32

Tabulka 2: Porovnání odhadu pomocí KF a DD1 filtru

**Závěr:** Tento test dokázal, že KF pro tento případ nebylo vhodné použít. Neměřený vjezd a ne zcela přesné nastavení parametrů znamenal pro tento filtr příliš velkou neurčitost, s kterou se neuměl vyrovnat, naopak DD1 s takovou neurčitostí neměl problémy.

#### 4.2.3 TEST 2

**Cíl:** a) Najít lepší nastavení kovarianční matice stavu, tak aby suma odchylek mezi skutečnou a odhadnutou délkou kolony byla co nejmenší.

b) Najít lepší nastavení kovarianční matice stavu a měření tak, aby odhad délky kolony byl co nejlepší.

**Nastavení:** Kovarianční matice šumu měření a kovarianční matice odhadu stavu a parametrů se ponechaly podle počátečního nastavení, viz 4.2.1.

**Postup testu:** Při testování byla použita metoda “vše ze vším” pro stav a parametry v kovarianční matici stavu. Jedná se o hodnoty od  $10^5$  do  $10^{-9}$ , kdy každý další krok je  $10x$  menší nežli ten předchozí. Je to tedy celkem 225 kombinací velikosti kovarianční matice stavu pro parametry a stav. Pro odhad kovarianční matice stavu i měření metodou “vše se vším” to je 3375 kombinací.

**Výsledky:** V předchozím testu byla porovnávána hodnota kvality odhadu mezi KF a DD1 filtrem. Tento test má najít možné zlepšení při jiném nastavení hodnot kovarianční matice stavu. Provedený test zjistil optimální nastavení kovarianční matice:

```
pkw.var = diag([1e1*ones(1,4) 1e5 1e-9*ones(1,nx-5)])
```


Číslo ramene	Délka skut. kolony	pkw.var (5,5,-1)		pkw.var(-1,5,-9)		Zlepšení v %
		odchylka	v %	odchylka	v %	
1	$4,114 \cdot 10^5$	$2,017 \cdot 10^4$	4,90	$1,252 \cdot 10^4$	3,05	+1,85
3	$2,934 \cdot 10^5$	$1,276 \cdot 10^3$	4,35	$1,050 \cdot 10^3$	3,58	+0,77
1+3	$7,048 \cdot 10^5$	$3,293 \cdot 10^4$	4,67	$2,302 \cdot 10^4$	3,27	+1,40

Tabulka 4: Porovnání odhadu DD1 filtru při různém nastavení kovarianční matice stavu


nastavení	kovariance měření	odchylka	v %
optimální	1e-1 až 1e-9	$2,302 \cdot 10^4$	3,11
nejhorší	1e5	$2,881 \cdot 10^4$	3,89

Tabulka 5: Nastavení kovariance měření při optimálním nastavení kovariance stavu


### Vliv kovarianční matice stavu na odhad délky kolony pomocí DD1 filtru




Obrázek 10: Kolona 1



Obrázek 11: Kolona 3



Obrázek 12: Kolona 1+3



Obrázek 13: Odchylky od skutečné kolony

Hledání nejen kovariance stavu, ale i měření se ukázalo, že optimální nastavení je

```

pwk.var = diag([1e1*ones(1,4) 1e5 1e-9*ones(1,nx-5)]);
pvk.var = 1e3*diag(ones(1,ny));

```

kde pwk.var je kovarianční matice stavu a pvk.var je pro měření.

Tímto nastavením se celková odchylka snížila na hodnotu  $2,159 \cdot 10^4$ , což je zlepšení o 0,21%. Toto zlepšení je ovšem velmi malé vzhledem k zvýšené potřebě výpočetního času. Proto je výhodné hledat pouze optimální nastavení kovarianční matice stavu. Pro tento předpoklad je ovšem ještě důležité zjistit, jak moc může ovlivnit výsledek nezávislé nastavení kovarianční matice měření.

Výsledky při nastavení kovariance stavu

```

pwk.var = diag([1e1*ones(1,4) 1e5 1e-9*ones(1,nx-5)]).

```

Nejhorší nastavení se od optimálního liší v řádu několika desítek setin %.

**Závěr:** Optimální nastavení kovarianční matice stavu vede na lepší výsledky, ale není potřeba hledat ideální poměr mezi kovarianční maticí stavu a měření. Velikost zlepšení neodpovídá výpočetní náročnosti na hledání tohoto měření. Optimální nastavení vzhledem k poměru kvalita : náročnost vychází

```
pwk.var = diag([1e1*ones(1,4) 1e5 1e-9*ones(1,nx-5)]);
pvk.var = 1e-1*diag(ones(1,ny));
```

kde pwk.var je kovarianční matice stavu a pvk.var je pro měření.

#### 4.2.4 TEST 3

**Cíl:** Najít lepší nastavení kovarianční matice odhadu stavu a parametrů, tak aby suma odchylek mezi skutečnou a odhadnutou délkou kolony byla co nejmenší. Zjištění, jak moc je tento odhad důležitý pro celkový odhad kolony, zda je pro něj statisticky významný či nikoliv.

**Nastavení:** Kovarianční matice šumu měření a kovarianční matice stavu se nastavily podle nejlepšího výsledku, který se podařilo získat z předchozího testu. Kovarianční matice jsou tedy:

```
pwk.var = diag([1e1*ones(1,4) 1e5 1e-9*ones(1,nx-5)])
pvk.var = 1e-1*diag(ones(1,ny))
```


kde pwk.var je kovarianční matice stavu a pvk.var je pro měření.

**Postup testu:** Při testování byla použita metoda “vše ze vším” pro stav a parametry v kovarianční matici stavu. Jedná se o hodnoty od  $10^5$  do  $10^{-4}$ , kdy každý další krok je 10x menší nežli ten předchozí. Je to tedy celkem 100 kombinací velikosti kovarianční matice odhadu stavu a parametrů.

**Výsledky:** a) Nejlepší výsledky jsou při nastavení kovarianční matice odhadu:

```
pred.sqrt_var = diag([1e5*ones(1,4) 1e5 1e-1*ones(1,nx-5)])
```

b) Změna kovarianční matice odhadu ovlivňuje celkový odhad velmi výrazně. Důležitá je v tomto případě pouze kovariance odhadu parametrů, protože kovarianční matice pro odhad stavu ovlivňuje celkový odhad délky kolony minimálně. Tento trend lze pozorovat na obrázku 14.



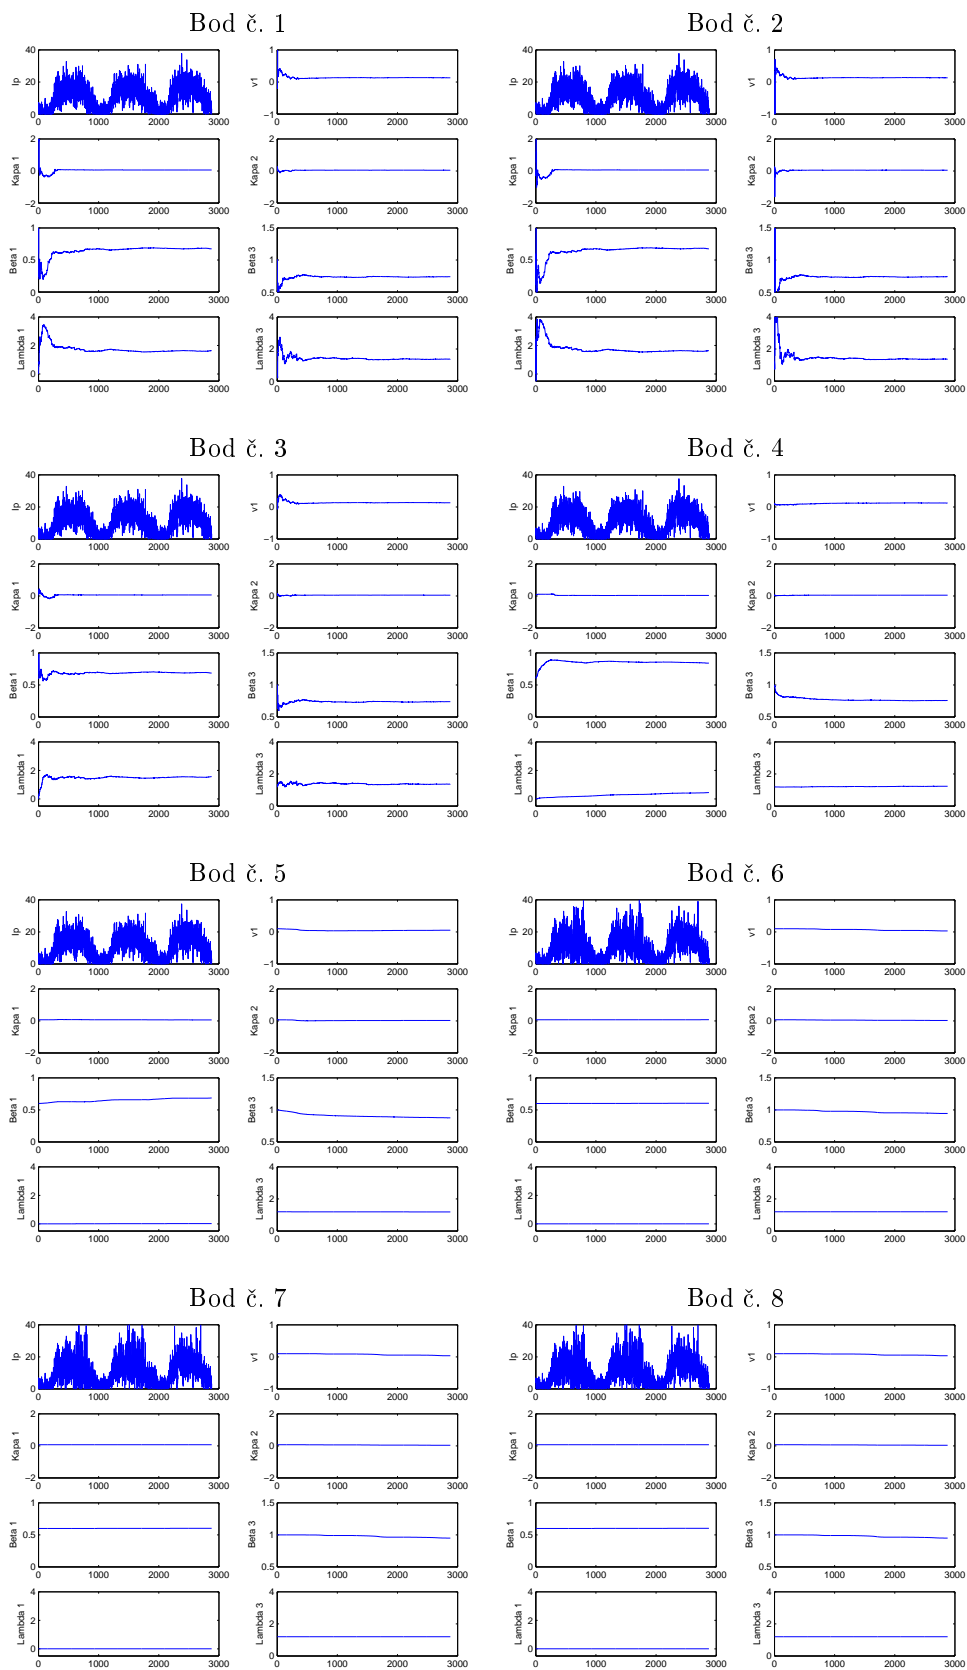
Obrázek 14: Kovariační matice odhadu stavu a parametrů s vyznačenými body pro detailní sledování vývoje parametrů

Byly provedeny v testy v označených bodech nastavení kovarianční matice odhadu (body 1 - 8 na obrázku 14) se zaměřením na průběh odhadu parametrů. Tyto průběhy lze pozorovat na obrázku 15. Lze pozorovat, že snižováním hodnoty kovariční matice odhadu parametrů dochází k “utažení” parametrů. Tento stav má za následek zhoršení celého odhadu, jak lze vidět v tabulce 12.

Bod č.	Kov. matice odhadu		pwk(1,5,-9), pvk(-1)	
	stav	parametry	odchylka	v %
1	$10^{-4}$	$10^5$	$2,374 \cdot 10^4$	4,20
2	$10^5$	$10^5$	$2,373 \cdot 10^4$	4,20
3	$10^5$	$10^0$	$2,216 \cdot 10^4$	3,92
4	$10^5$	$10^{-1}$	$2,071 \cdot 10^4$	3,67
5	$10^5$	$10^{-2}$	$3,792 \cdot 10^4$	6,71
6	$10^5$	$10^{-3}$	$1,266 \cdot 10^5$	22,41
7	$10^5$	$10^{-4}$	$1,364 \cdot 10^5$	24,14
8	$10^{-4}$	$10^{-4}$	$1,364 \cdot 10^5$	24,14

Tabulka 6: Kovariační matice odhadu stavů a parametrů





Obrázek 15: Průběhy odhadovaných parametrů v bodech definovaných na obrázku 14

**Závěr:** U kovarianční matice odhadu je důležité správně určit hlavně kovarianci parametrů. Při špatném nastavení kovariance parametrů může dojít k omezení “volnosti” parametrů a změna povolená v čase nemusí být dostatečná. Tím se úloha začne blížit k úloze bez odhadu parametrů a roste chyba.

### 4.3 Experimenty - simulovaná data B

Z reálných dat bez kolon byly vytvořeny data s kolonami tak, že vstupní intenzity I1 a I3 se zvýšily. Touto úpravou se podařilo získat data na reálném základě, ale s kolonami. Simulací se zjišťovala skutečná délka kolony.

#### 4.3.1 Počáteční nastavení

Neměřený vjezd - ANO (Ip)

- poměr odbočení:  $\alpha_{32} = 1$ ;  $\alpha_{42} = 1$ ,
- saturovaný tok:  $S_1 = 25$ ;  $S_2 = 130$ ,
- parametry vztahu kolona - obsazenost:  $\kappa_1 = \kappa_2 = 0.07$ ;  $\beta_1 = 0.6$ ;  $\beta_2 = 1.0$ ;  $\lambda_1 = 0$ ;  $\lambda_2 = 1.2$ ,
- parametr vztahu obsazenosti sousedních ramen:  $v_1 = 0.1$ ;

```
load dataR-V6.mat
Ip = data(:,15)*1.2; % poruchový vjezd na výstupu
I1 = data(:,14)*1.1; % Matousova
I3 = data(:,17)*1.3; % Zborovska
z1 = data(:,3);
z2 = data(:,4);
```

#### 4.3.2 TEST 1

**Cíl:** Zjistit, zda je vhodnější pro odhad použít lineární Kalmanův filtr (KF) nebo nelineární DD1 filtr.

**Nastavení (2):** Apriorní nastavení kovariančních matic (pro test DD1):

```
% odhady stavu a parametru
pred.sqrt_var = diag([1e5*ones(1,4) 1e5 1e-1*ones(1,nx-5)]);
% stredni hodnoty stavoveho sumu a sumu mereni
pwk.mean = zeros(nx,1);
pvk.mean = zeros(ny,1);
% kovariancni matice stavoveho sumu a sumu mereni
pwk.var = diag([1e5*ones(1,4) 1e5 1e-1*ones(1,nx-5)]);
pvk.var = 1e-1*diag(ones(1,ny));
```

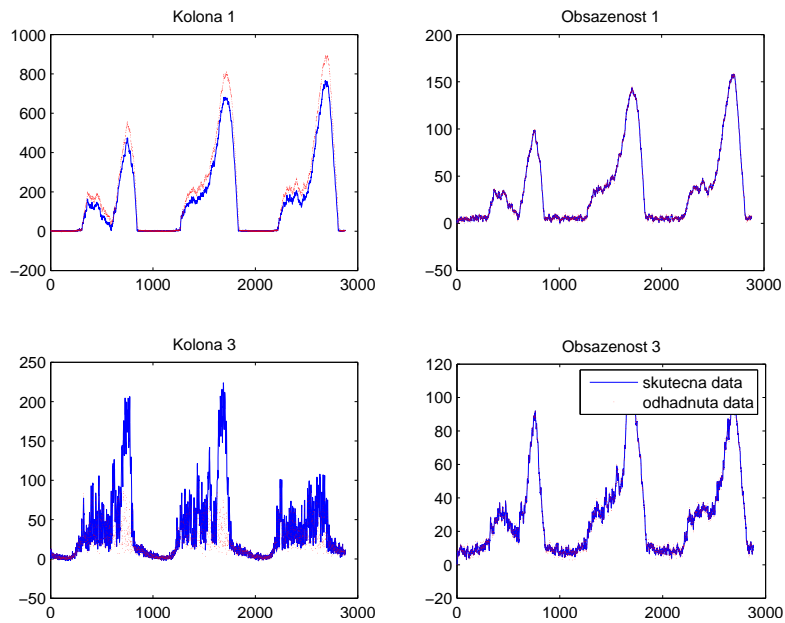
Apriorní nastavení kovariančních matic (pro test KF):

```
% odhady stavu a parametru
pred.sqrt_var = diag([1e5*ones(1,4) 1e5]);
% stredni hodnoty a kovariancni matice sumu mereni a stavoveho sumu
pwk.mean = zeros(nx,1);
pvk.mean = zeros(ny,1);
pwk.var = diag([1e5*ones(1,4) 1e5]);
pvk.var = 1e-1*diag(ones(1,ny));
```


**Postup testu** Testovaná data byla připravena tak, aby se vyskytovaly kolony a neměřený vjezd, podle obrázku 1. Na tato data byl použit lineární Kalmanův filtr a nelineární DD1 filtr. Pro oba filtry bylo použito stejné počáteční nastavení (viz 4.3.1).

**Výsledky:**


**Lineární Kalmanův filtr (KF)** Kalmanův filtr má po celou dobu konstantní parametry, jak je vidět na obrázku 17. Z důvodu existence neměřeného vjezdu lze na obrázku 16 pozorovat, že toto nastavení nedostačuje. Chyba odhadu délky kolony skutečné a odhadnuté se pohybuje od 23 do 40 %. Nevhodnost použití KF lze pozorovat i na obrázku 19.



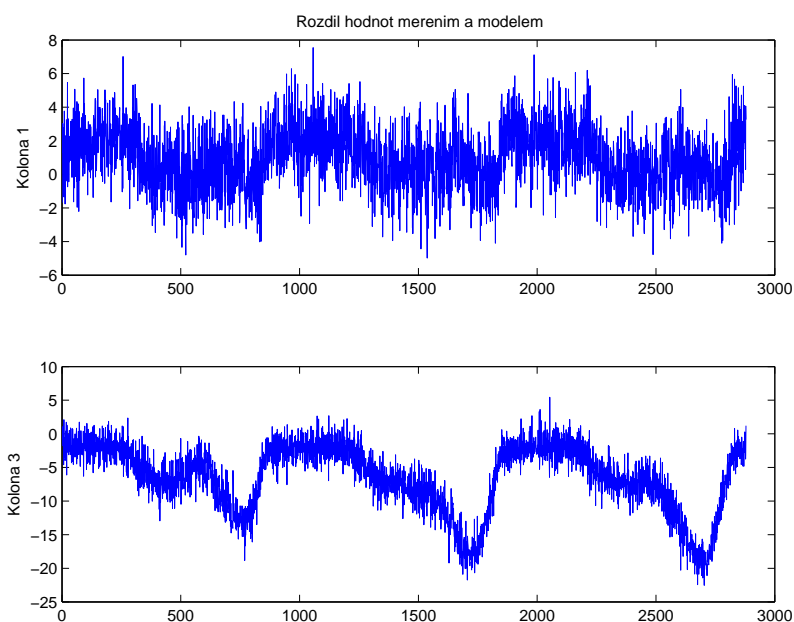
Obrázek 16: Skutečné a odhadnuté kolony pomocí KF



Obrázek 17: Vývoj odhadu parametrů v čase u KF

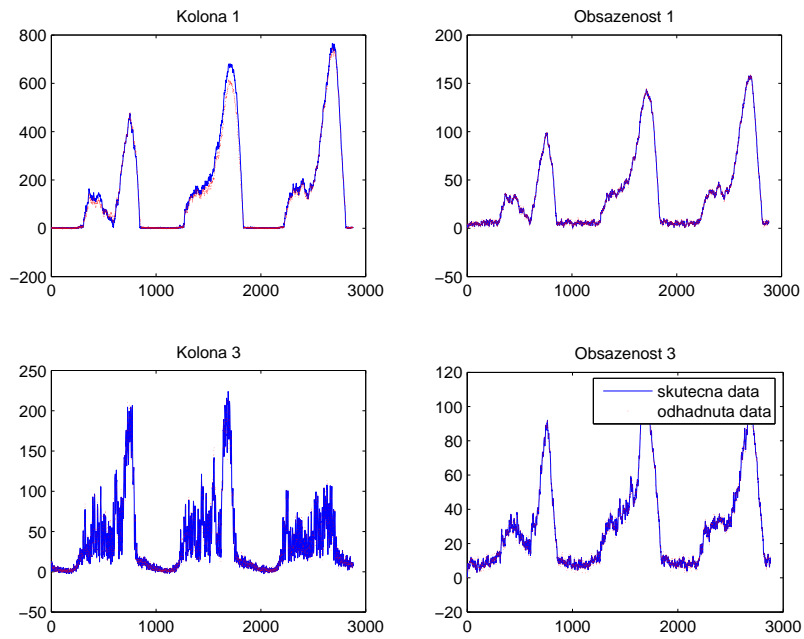


Obrázek 18: Odchyly skutečné a odhadnuté kolony pomocí KF




Obrázek 19: Chyba predikce u KF


**Nelineární DD1 filtr** Nelineární filtr DD1 umožňuje dělat správné odhady i při určité neurčitosti, jakou je v tomto případě neměřený vstup  $I_p$ . Parametry jsou odhadovány a v čase proměnné, jak je vidět na obrázku 21. Skutečné délky kolon se příliš neliší od odhadované délky kolon, viz obrázek 20 a tedy i odchyly jsou mnohem menší a pohybují se kolem 8 %. Správnost nastavení filtru si lze ověřit i na obrázku 23. Model byl nejdříve nastaven na špatnou hodnotu, ale díky změně parametrů se filtru podařilo srovnat model s měřením. Tato změna lze nejlépe pozorovat u Kolony 3 na začátku.




Obrázek 20: Skutečné a odhadnuté kolony pomocí DD1 filtru



Obrázek 21: Vývoj odhadu parametrů v čase u DD1 filtru



Obrázek 22: Odchylky skutečné a odhadnuté kolony pomocí DD1 filtru



Obrázek 23: Chyba predikce u DD1 filtru

**Porovnání KF a DD1 filtru** Pro porovnání bylo vybráno kritérium co nejlepší odhad délky kolony vzhledem ke skutečné. Celkové výsledky jsou zpracované v tabulce 10. Jsou zde zaznamenány odchylky od skutečné délky kolony u KF a DD1 filtru a to jak absolutně, tak i procentuálně. Sloupec zlepšení ukazuje, jakého procentuálního zlepšení jsme dosáhli poté, co jsme místo KF použili DD1 filtr.

Číslo ramene	Délka skut. kolony	KF		DD1 filtr		Zlepšení v %
		odchylka	v %	odchylka	v %	
1	$4,563 \cdot 10^5$	$1,087 \cdot 10^5$	23,82	$3,840 \cdot 10^4$	8,42	+15,40
3	$1,087 \cdot 10^5$	$4,352 \cdot 10^4$	40,04	$6,641 \cdot 10^3$	6,11	+33,93
1+3	$5,650 \cdot 10^5$	$1,522 \cdot 10^5$	26,94	$4,504 \cdot 10^4$	7,97	+18,97

Tabulka 8: Porovnání odhadu pomocí KF a DD1 filtru

**Závěr:** Tento test dokázal, že KF pro tento případ nebylo vhodné použít. Neměřený vjezd a nepřesné nastavení parametrů znamenaly pro tento filtr příliš velkou neurčitost, s kterou se neuměl vyrovnat, naopak DD1 s takovou neurčitostí neměl problémy.

#### 4.3.3 TEST 2

**Cíl:** Najít lepší nastavení kovarianční matice stavu, tak aby suma odchylek mezi skutečnou a odhadnutou délkou kolony byla co nejmenší.


**Nastavení:** Kovarianční matice šumu měření a kovarianční matice odhadu stavu a parametrů se ponechaly podle počátečního nastavení, viz 4.2.1.

**Postup testu:** Při testování byla použita metoda “vše ze vším” pro stav a parametry v kovarianční matici stavu. Jedná se o hodnoty od  $10^5$  do  $10^{-9}$ , kdy každý další krok je  $10x$  menší nežli ten předchozí. Je to tedy celkem 225 kombinací velikosti kovarianční matice stavu pro parametry a stav.


**Výsledky:** V předchozím testu byla porovnávána hodnota kvality odhadu mezi KF a DD1 filtrem. Tento test má najít možné zlepšení při jiném nastavení hodnot kovarianční matice stavu. Provedený test zjistil optimální nastavení kovariační matice:

```
pwk.var = diag([1e-1*ones(1,4) 1e5 1e-9*ones(1,nx-5)])
```


## Vliv kovarianční matice stavu na odhad délky kolon u DD1 filtru




Obrázek 24: Kolona 1



Obrázek 25: Kolona 3



Obrázek 26: Kolona 1+3



Obrázek 27: Odchylyky od skutečné kolony

Číslo ramene	Délka skut. kolony	pkw.var (5,5,-1)		pkw.var (-1,5,-9)		Zlepšení v %
		odchylka	v %	odchylka	v %	
1	$4,563 \cdot 10^5$	$3,840 \cdot 10^4$	8,42	$1,321 \cdot 10^4$	2,90	+5,52
3	$1,087 \cdot 10^5$	$6,641 \cdot 10^3$	6,11	$5,124 \cdot 10^3$	4,71	+1,40
1+3	$5,650 \cdot 10^5$	$4,504 \cdot 10^4$	7,97	$1,833 \cdot 10^4$	3,25	+4,72

Tabulka 10: Porovnání odhadu DD1 filtru při různém nastavení kovarianční matice stavu

Hledání nejen kovariance stavu, ale i měření se ukázalo, že optimální nastavení je

```
pkw.var = diag([1e1*ones(1,4) 1e5 1e-9*ones(1,nx-5)]);
pvk.var = 1e0*diag(ones(1,ny));
```

Tímto nastavením se celková odchylka snížila na hodnotu  $1,707 \cdot 10^4$ , což je zlepšení o 0,23%. Toto zlepšení je ovšem velmi malé vzhledem k zvýšené potřebě výpočetního času. Proto je výhodné hledat pouze optimální nastavení kovarianční matice stavu. Pro tento předpoklad je ovšem ještě důležité zjistit, jak moc může ovlivnit výsledek nezávislé nastavení kovarianční matice měření.

Výsledky při nastavení kovariance stavu



nastavení	kovariance měření	odchylka	v %
optimální	1e-1	$1,834 \cdot 10^4$	2,30
nejhorší	1e5	$3,120 \cdot 10^4$	5,52

Tabulka 11: Nastavení kovariance měření při optimálním nastavení kovariance stavu

```
pwk.var = diag([1e-1*ones(1,4) 1e5 1e-9*ones(1,nx-5)]).
```

Nejhorší nastavení se od optimálního liší v řádu několika %.

**Závěr:** Optimální nastavení kovarianční matice stavu vede na lepší výsledky, ale není potřeba hledat ideální poměr mezi kovarianční maticí stavu a měření. Velikost zlepšení neodpovídá výpočetní náročnosti na hledání tohoto měření. Optimální nastavení vzhledem k poměru kvalita : náročnost vychází

```
pwk.var = diag([1e-1*ones(1,4) 1e5 1e-9*ones(1,nx-5)]);
pvk.var = 1e-1*diag(ones(1,ny));
```

kde pwk.var je kovarianční matice stavu a pvk.var je pro měření.

#### 4.3.4 TEST 3

##### Zadání:

a) Najít lepší nastavení kovarianční matice odhadu stavu a parametrů, tak aby suma odchylek mezi skutečnou a odhadnutou délkou kolony byla co nejmenší. Zjištění, jak moc je tento odhad důležitý pro celkový odhad kolony, zda je pro něj statisticky významný či nikoliv.

b) Zjistit závislost modelu na kovarianční matici odhadu stavu a parametrů.

**Nastavení:** Kovarianční matice šumu měření a kovarianční matice stavu se nastavily podle nejlepšího výsledku, který se podařilo získat z předchozího testu. Kovarianční matice jsou tedy:

```
pwk.var = diag([1e1*ones(1,4) 1e5 1e-9*ones(1,nx-5)])
pvk.var = 1e-1*diag(ones(1,ny))
```


kde pwk.var je kovarianční matice stavu a pvk.var je pro měření.

**Postup testu:** Při testování byla použita metoda “vše ze vším” pro stav a parametry v kovarianční matici odhadu. Jedná se o hodnoty od  $10^5$  do  $10^{-4}$ , kdy každý další krok je 10x menší nežli ten předchozí. Je to tedy celkem 100 kombinací velikosti kovarianční matice odhadu stavu a parametrů.

**Výsledky:** a) Nejlepší výsledky jsou při nastavení kovarianční matice odhadu:

```
pred.sqrt_var = diag([1e5*ones(1,4) 1e5 1e-1*ones(1,nx-5)])
```

b) Změna kovarianční matice odhadu ovlivňuje celkový odhad velmi výrazně. Ale důležitá je v tomto případě pouze kovariance odhadu parametrů, která ovlivňuje odhad výrazně. Kovarianční matice pro odhad stavu ovlivňuje celkový odhad délky kolony minimálně. Tento trend lze pozorovat na obrázku 28.

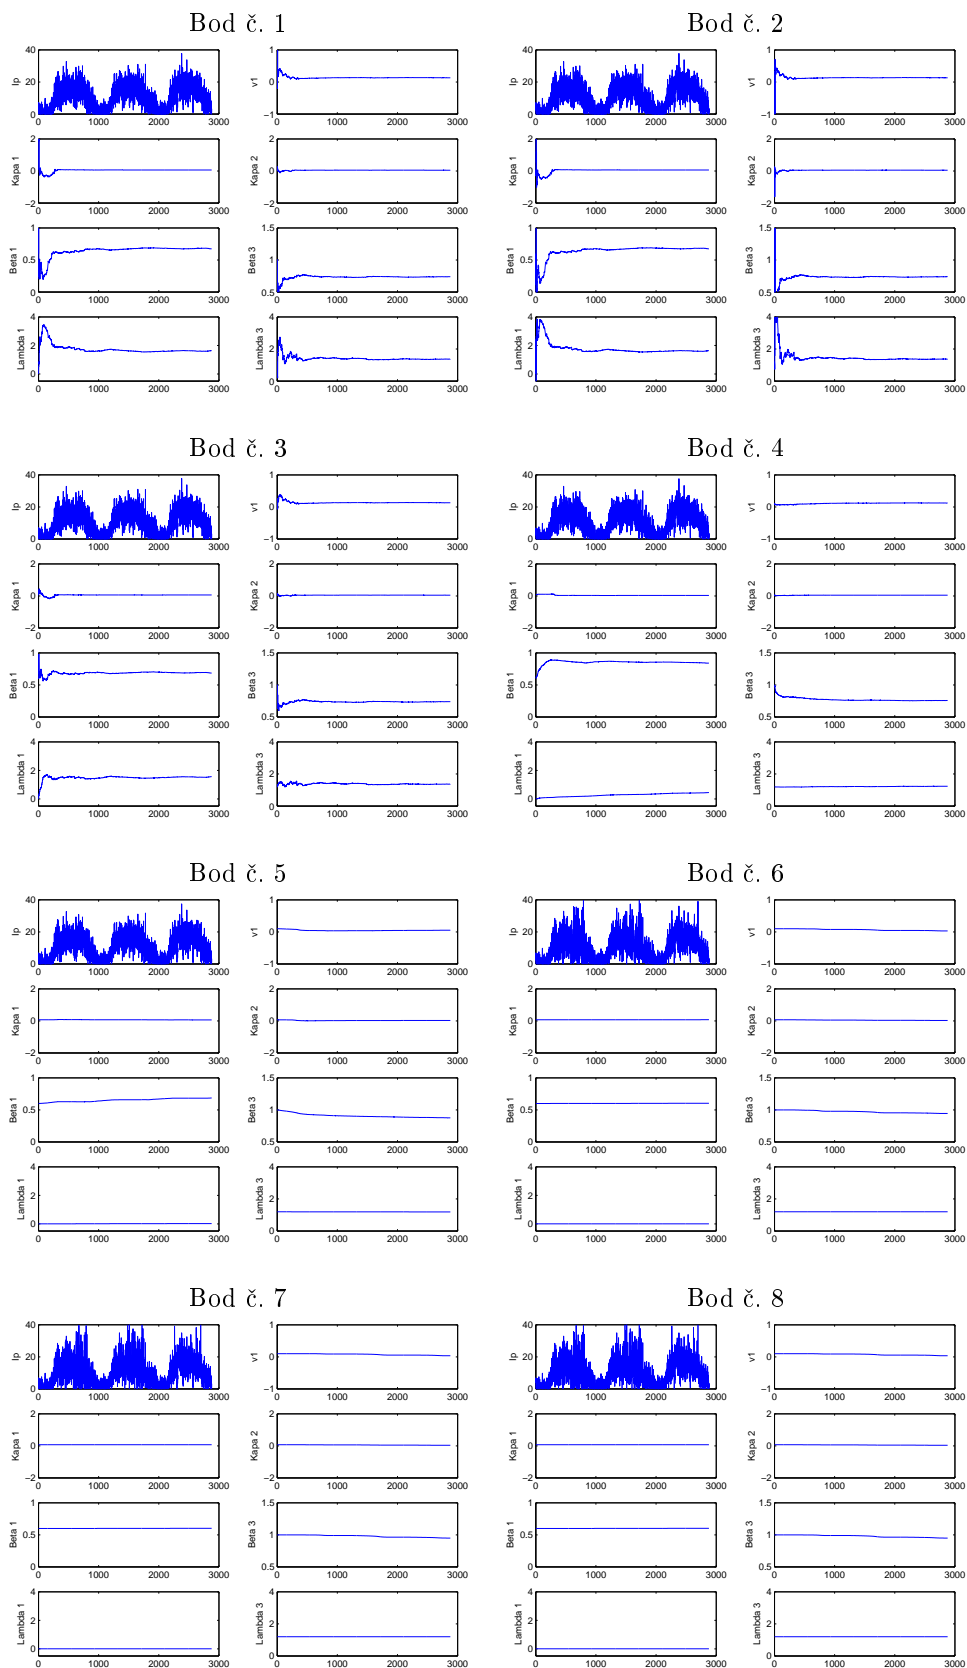


Obrázek 28: Kovariační matice odhadu stavu a parametrů s vyznačenými body pro detailní sledování vývoje parametrů

Byly provedeny v testy v označených bodech nastavení kovarianční matice odhadu (body 1 - 8 na obrázku 28) se zaměřením na průběh odhadu parametrů. Tyto průběhy lze pozorovat na obrázku 15. Lze pozorovat, že snižováním hodnoty kovariační matice odhadu parametrů dochází k “utažení” parametrů. Tento stav má za následek zhoršení celého odhadu, jak lze vidět v tabulce 12.

Bod č.	Kov. matice odhadu		pwk(1,5,-9), pvk(-1)	
	stav	parametry	odchylka	v %
1	$10^{-4}$	$10^5$	$2,374 \cdot 10^4$	4,20
2	$10^5$	$10^5$	$2,373 \cdot 10^4$	4,20
3	$10^5$	$10^0$	$2,216 \cdot 10^4$	3,92
4	$10^5$	$10^{-1}$	$2,071 \cdot 10^4$	3,67
5	$10^5$	$10^{-2}$	$3,792 \cdot 10^4$	6,71
6	$10^5$	$10^{-3}$	$1,266 \cdot 10^5$	22,41
7	$10^5$	$10^{-4}$	$1,364 \cdot 10^5$	24,14
8	$10^{-4}$	$10^{-4}$	$1,364 \cdot 10^5$	24,14

Tabulka 12: Kovariační matice odhadu stavů a parametrů




Obrázek 29: Průběhy odhadovaných parametrů v bodech definovaných na obrázku 28

**Závěr:** U kovarianční matice odhadu je důležité správně určit kovarianci parametrů. Při špatném nastavení kovariance parametrů může dojít k omezení “volnosti” parametrů a změna povolená v čase nemusí být dostatečná. Tím se úloha začne blížit k úloze bez odhadu parametrů a roste chyba.

## 5 Dvě čtyřramenné křižovatky

### Šest vstupů a výstupů

Křižovatky mají veličiny a parametry očíslovány proti směru hodinových ručiček, kdy je levé rameno křižovatky označeno jako první. Křižovatka č. 1 má indexy od č. 1 do č. 4 a křižovatka č. 2 od č. 5 do č. 8, viz obrázek 30.



Obrázek 30: Dvě čtyřramenné křižovatky

### 5.1 Zkrácený stavový popis

Vzhledem k propojování křižovek se ukazuje výhodnost “kompaktního uspořádání”, kdy stejné veličiny stojí vedle sebe. Toto uspořádání použijeme i zde, pro dvě propojené křižovatky vedle sebe. Pro zjednodušení a přehlednost sloučíme jednotlivé veličiny a parametry z celé křižovatky do jedné. Parametry a veličiny křižovatky č. 1, které mají index od 1 do 4, se budou označovat u dané veličiny horním indexem <sup>1</sup> a pro druhou křižovatku (indexy 5-8) horním indexem <sup>2</sup>. To znamená, že například délka kolony pro křižovatku č. 1 je  $\xi_t^1$  a pro křižovatku 2 je  $\xi_t^2$ , kde

$$\xi_t^1 = [\xi_{1,t} \ \xi_{2,t} \ \xi_{3,t} \ \xi_{4,t}]', \quad \xi_t^2 = [\xi_{5,t} \ \xi_{6,t} \ \xi_{7,t} \ \xi_{8,t}]'.$$

Stejný postup je ostatní parametry a veličiny, intenzita je značena  $I_t^1$  a  $I_t^2$ , obsazenost  $O_t^1$  a  $O_t^2$ , matice poměru odbočení  $\alpha^1$  a  $\alpha^2$ , atd. Výstupní intenzita je měřena na výstupních ramenech, tj. ramenech, které vedou ven z měřené oblasti, v tomto případě jsou to ramena 1, 2, 4, 6, 7, 8, viz obrázek 30. Výstupní intenzita je tedy  $y_t^1$  pro křižovatku č. 1 a  $y_t^2$  pro křižovatku č. 2, kde

$$y_t^1 = [y_{1,t} \ y_{2,t} \ y_{4,t}]', \quad y_t^2 = [y_{6,t} \ y_{7,t} \ y_{8,t}]'.$$

**Stavový model** Stavový model je tedy

$$x_{t+1} = Ax_t + Bz_t + F + \epsilon_t \quad (13)$$

$$y_{t+1} = Cx_{t+1} + G + e_t \quad (14)$$

Stav modelu vzhledem je k rovnici (13)  $x_{t+1} = [\xi_{t+1}^1 \ \xi_{t+1}^2 \ O_{t+1}^1 \ O_{t+1}^2]'$ .

Výstupní model je vzhledem k (14)  $y_{t+1} = [Y_{t+1}^1 \ Y_{t+1}^2 \ O_{t+1}^1 \ O_{t+1}^2]'$ , kde  $Y_{t+1}^{1(2)}$  je vektor výjezdů.

Matice stavového modelu jsou:

$D(a)$  je diagonální matice s vektorem  $a$  na diagonále,  
 $D(a, b)$  je subdiagonální matice s vektorem  $a$  na hlavní diagonále a s vektorem  $b$  pod hlavní diagonálou,  
 $\emptyset$  je nulová matice s potřebným rozměrem.

$$A = \begin{bmatrix} D(\delta_t^1) & \emptyset & \emptyset & \emptyset \\ \emptyset & D(\delta_t^2) & \emptyset & \emptyset \\ D(\kappa_t^1) & \emptyset & D(\beta_t^1, v_t^1) & \emptyset \\ \emptyset & D(\kappa_t^2) & \emptyset & D(\beta_t^2, v_t^2) \end{bmatrix},$$

$$B = \begin{bmatrix} B_t^1 & \emptyset \\ \emptyset & B_t^2 \\ \emptyset & \emptyset \\ \emptyset & \emptyset \end{bmatrix}, \quad F = \begin{bmatrix} I_t^1 \\ I_t^2 \\ \lambda_t^1 \\ \lambda_t^2 \end{bmatrix},$$

kde  $B_t^{1(2)} = \begin{bmatrix} -b_{1(5)} & 0 & -b_{3(7)} & 0 \\ 0 & -b_{2(6)} & 0 & -b_{4(8)} \end{bmatrix}'$  a  $b_i = \delta_{i,t} S_i + (1 - \delta_{i,t}) I_{i,t}$ .

$$C = \begin{bmatrix} -\alpha^1 & \emptyset & \emptyset & \emptyset \\ \emptyset & -\alpha^2 & \emptyset & \emptyset \\ \emptyset & \emptyset & D(1) & \emptyset \\ \emptyset & \emptyset & \emptyset & D(2) \end{bmatrix}, \quad G = \begin{bmatrix} -\alpha^1 G^1 \\ -\alpha^2 G^2 \\ \emptyset \\ \emptyset \end{bmatrix},$$

kde  $G^{1(2)} = [g_{1(5)} \ g_{2(6)} \ g_{3(7)} \ g_{4(8)}]'$  a  $g_i = [\hat{\xi}_{i,t} + I_{i,t}]$ .

Parametry  $\beta, \kappa$  a  $\lambda$  jsou koeficienty vztahu mezi délkou kolony a obsazeností. Parametr  $v$  popisuje vztah mezi obsazenostmi sousedících ramen. Parametr  $\delta_{i,t}$  nabývá hodnoty 1, když kolona existuje, nebo 0 jindy.

**Rozšířený stavový model** Parametry  $\beta, \kappa, \lambda$  a  $v$  jsou proměnné v čase ani neznáme jejich přesné počáteční nastavení. Z těchto důvodů není vhodné označit je jako konstanty, ačkoliv jejich proměnnost v čase je velmi pomalá. Jako vhodná cesta odhadu se ukazuje jejich “zabudování” do stavového modelu a udělat tedy rozšířený stavový model.

V tomto případě je tedy rozšířený stavový model

$$\tilde{x}_{t+1} = \begin{bmatrix} x_{t+1} \\ \theta \end{bmatrix} \quad (15)$$

kde  $\theta = [\beta_{t+1}^1 \ \beta_{t+1}^2 \ \kappa_{t+1}^1 \ \kappa_{t+1}^2 \ \lambda_{t+1}^1 \ \lambda_{t+1}^2 \ v_{t+1}^1 \ v_{t+1}^2 \ S_{t+1}^1 \ S_{t+1}^2]$ . Proměnná  $\theta$  může nabývat různých rozměrů, podle počtu odhadovaných parametrů.

Vzhledem k rovnici (15) je nutná úprava matic ve stavovém modelu. Po úpravě tedy budou matice:

$$\tilde{A} = \begin{bmatrix} A & \emptyset \\ \emptyset & D(1) \end{bmatrix}, \quad \tilde{B} = \begin{bmatrix} B \\ \emptyset \end{bmatrix}, \quad \tilde{F} = \begin{bmatrix} F \\ \emptyset \end{bmatrix}, \quad \tilde{C} = [C \ \emptyset], \quad \tilde{G} = G.$$

V matici  $\tilde{A}$  velikost vektoru  $D(1)$  odpovídá velikosti proměnné  $\theta$ .

## 5.2 Experiment A

V programu AIMSUN byla vytvořena mikrooblast (obrázek 30) skládající se ze dvou čtyřramenných křížovatek, kde jsou do ramen pouštěny reálná data. Z AIMSUNu jsou pak brány data z detektorů, vstupních i výstupních, (Intenzita a Obsazenost) a maximální a průměrná délka kolon.

**Základní nastavení:** Pro experiment byly použity všechny dostupné informace z detektorů, tj. 6 vstupních strategických detektorů, 2 vzdálené detektory v meziúseku, 6 výstupních detektorů.

### 5.2.1 Počáteční nastavení

- poměr odbočení:

$$\begin{array}{cccc} \alpha_{12} = 0,3 & \alpha_{31} = 0,5 & \alpha_{56} = 0,3 & \alpha_{73} = 0,5 \\ \alpha_{14} = 0,2 & \alpha_{32} = 0,2 & \alpha_{57} = 0,5 & \alpha_{76} = 0,2 \\ \alpha_{15} = 0,5 & \alpha_{34} = 0,3 & \alpha_{58} = 0,2 & \alpha_{78} = 0,3 \\ \\ \alpha_{21} = 0,3 & \alpha_{41} = 0,2 & \alpha_{63} = 0,3 & \alpha_{83} = 0,2 \\ \alpha_{24} = 0,5 & \alpha_{42} = 0,5 & \alpha_{67} = 0,2 & \alpha_{86} = 0,5 \\ \alpha_{25} = 0,2 & \alpha_{45} = 0,3 & \alpha_{68} = 0,5 & \alpha_{87} = 0,3 \end{array}$$

- saturovaný tok:  $S_1 = S_3 = S_5 = S_7 = 37$  j.v./per;  $S_2 = S_4 = S_6 = S_8 = 34$  j.v./per
- parametry vztahu kolona - obsazenost: ; ;  $\lambda_1 = 0$ ;  $\lambda_2 = 1.2$ ,

$$\begin{aligned} \kappa_1 = \dots = \kappa_8 &= 0 \\ \beta_1 = \dots = \beta_8 &= 1 \\ \lambda_1 = \lambda_3 = \lambda_5 = \lambda_7 &= 0 \quad \lambda_2 = \lambda_4 = \lambda_6 = \lambda_8 = 1.2 \end{aligned}$$

- parametr vztahu obsazenosti sousedních ramen:

$$v_{1,2} = v_{2,3} = v_{3,4} = v_{5,6} = v_{6,7} = v_{7,8} = 0.1 \quad v_{4,1} = v_{8,5} = 0$$

load testik\_14

### 5.2.2 TEST 1

**Cíl:** Zjistit, zda je vhodnější pro odhad délky kolon křižovatky použít lineární Kalmanův filtr (KF) nebo nelineární DD1 filtr.

**Nastavení (2):** Apriorní nastavení kovariančních matic (pro test DD1):

```
% odhady stavu a parametru
Pp = diag([1e1*ones(1,16) 1e-8*ones(1,nx-16)]);
pred.sqrt_var = chol(Pp);
% stredni hodnoty stavoveho sumu a sumu mereni
pwk.mean = zeros(nx,1);
pvk.mean = zeros(ny,1);
% kovariancni matice stavoveho sumu a sumu mereni
pwk.var = diag([1e0*ones(1,4) 1e-3*ones(1,nx-16)]);
pvk.var = 1e-1*diag(ones(1,ny));
```

Apriorní nastavení kovariančních matic (pro test KF):


```
% odhady stavu a parametru
pred.sqrt_var = diag([1e1*ones(1,4)]);
% stredni hodnoty a kovariancni matice sumu mereni a stavoveho sumu
pwk.mean = zeros(nx,1);
pvk.mean = zeros(ny,1);
pwk.var = 3.5*diag(ones(1,nx));
pvk.var = 1e-1*diag(ones(1,ny));
```

Pro testování zůstalo omezení odhadu délky kolon do záporných hodnot.<sup>3</sup>

**Postup testu:** Testovaná data byla vytvořena v programu AIMSUN, což umožnilo získat skutečnou max. a průměrnou délku kolon za periodu (v modelu je počítáno jen s maximální kolonou). Na tato data byl postupně použit lineární Kalmanův filtr a posléze nelineární DD1 filtr. Nastavení poč. hodnot parametrů je stejné jak je popsáno v 5.2.1.

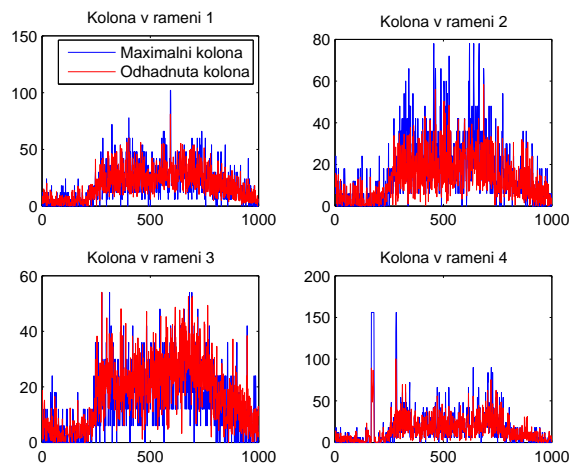
### Výsledky:

<sup>3</sup>Záporné hodnoty se mohou občas při odhadu vyskytnout. Tato chyba může vzniknout přesahem kolony přes možnou délku. Na odstranění tohoto problému se intenzivně pracuje.



Obrázek 31: Délky kolon při použití KF (rameno 1 - 4)

### Lineární Kalmanův filtr (KF)



Obrázek 32: Odhad délky kolon při použití DD1 filtru (rameno 1 - 4)

### Nelineární DD1 filtr

**Porovnání KF a DD1 filtru** Použití lineárního Kalmanova filtru se v tomto případě ukázalo jako velmi vhodné. Tato vhodnost je dána především znalostí celého systému včetně vstupů a výstupů. Nelineární DD1 filtr vykazoval sice o něco lepší výsledky než KF, viz tabulka 14, ale u některých ramen byl tento odhad horší a vzhledem k výpočetní náročnosti se v takovýchto případech jeví jako vhodné použití KF. V reálném případě se ovšem takto celkově známý systém vyskytuje spíše vyjimečně, ve většině případů se vyskytují neměřené vjezdy, které mohou výrazně narušit odhad. Bohužel se při testování ukázalo, že fitry nejsou schopny zachytit náhlé změny délek kolon, které se vyskytnou při rychlém vzrůstu intenzit.

Číslo ramene	Délka skut. kolony	KF		DD1 filtr		Zlepšení v %
		odchylka	v %	odchylka	v %	
1	$1,242 \cdot 10^5$	$4,628 \cdot 10^4$	37,26	$4,564 \cdot 10^4$	36,75	+0,51
2	$9,996 \cdot 10^4$	$4,240 \cdot 10^4$	42,42	$4,255 \cdot 10^4$	42,57	-0,15
3	$9,065 \cdot 10^4$	$4,407 \cdot 10^4$	48,61	$4,286 \cdot 10^4$	47,28	+1,33
4	$8,923 \cdot 10^4$	$3,879 \cdot 10^4$	43,47	$3,856 \cdot 10^4$	43,22	+0,25
5	$7,747 \cdot 10^4$	$4,235 \cdot 10^4$	54,66	$4,101 \cdot 10^4$	52,94	+1,72
6	$1,147 \cdot 10^5$	$4,472 \cdot 10^4$	38,99	$4,415 \cdot 10^4$	38,49	+0,50
7	$1,350 \cdot 10^5$	$4,734 \cdot 10^4$	35,07	$4,691 \cdot 10^4$	34,75	+0,22
8	$8,960 \cdot 10^4$	$3,786 \cdot 10^4$	42,25	$3,790 \cdot 10^4$	42,30	-0,05
celkem	$5,650 \cdot 10^5$	$3,439 \cdot 10^5$	41,90	$3,396 \cdot 10^5$	41,37	+0,53

Tabulka 14: Porovnání odhadu pomocí KF a DD1 filtru

**Závěr:** Tento test ukázal, že použití DD1 dává lepší výsledky než použití KF. Že tento rozdíl není tak veliký je dáno především znalostí celého systému. Tento stav je vhodný právě pro KF. V tomto případě tedy není nutno používat složitější a výpočetně náročnější nelineární filtry.

### 5.2.3 TEST 2

**Cíl:** Vypustit vjezdové detektory D3 a D5, umístěných na ramenech 3 a 5.

**Nastavení (2):** Nastavení kovariančních matic je stejné jako u TESTu 1. V tomto testu nebude umožněn odhad délky kolon do záporných hodnot.

**Postup testu:** Nejdříve byly spočítány intenzity, které mohou projet případně projedou přes vjezdové detektory. Tyto vjezdy z jednotlivých ramen se dále přepočítají pomocí poměru odbočení, aby jsme mohli přesněji určit skutečný vjezd do ramene 5 a 3.

Vjezdová intenzita do ramene 5 je tedy součet intenzit  $I_1$ ,  $I_2$  a  $I_4$ , které mohou projet za dobu zelené, násobené daným poměrem odbočení  $\alpha_{15}$ ,  $\alpha_{25}$  a  $\alpha_{45}$ . Tyto intenzity označme jako  $I_{15}$ ,  $I_{25}$  a  $I_{45}$ . Vjezdová intenzita  $I_5$  je zpožděná o jeden krok, tedy intenzity  $I_{15}$ ,  $I_{25}$  a  $I_{45}$  v čase  $t$  jsou vjezdovou intenzitou  $I_5$  v čase  $t + 1$ .


Vjezdová intenzita do ramene 3 je součet intenzit  $I_6$ ,  $I_7$  a  $I_8$ , které mohou projet za dobu zelené, násobené daným poměrem odbočení  $\alpha_{63}$ ,  $\alpha_{73}$  a  $\alpha_{83}$ . Tyto intenzity označme jako  $I_{63}$ ,  $I_{73}$  a  $I_{83}$ . Vjezdová intenzita  $I_3$  je zpožděná o jeden krok, tedy intenzity  $I_{63}$ ,  $I_{73}$  a  $I_{83}$  v čase  $t$  jsou vjezdovou intenzitou  $I_3$  v čase  $t + 1$ .

Podle napočítaných vjezdových intenzit se ke každé přiřadí odpovídající obsazenost, která odpovídá dané vjezdové intenzitě. Tato obsazenost lze zjistit z dat, u kterých byla intenzita i obsazenost známa.

$I_3$ ,  $I_5$ ,  $O_3$  a  $O_5$  se posléze použije na odhad délky kolon a to jak pomocí KF, tak i DD1 filtru.

**Výsledky:** Z předchozího popisu byla vypočítána hodnota pro vjezdové intenzity  $I_3$  a  $I_5$ . Bohužel neplatí přesně časový posun, kdy vjezd do ramene 3 či 5 je o krok zpožděný vjezd do ostatních ramen. Na obrázku 33 je vidět, že spočtená intenzita není zcela přesná. Nepřesnost vznikla díky tomu, že není zcela přesný předpoklad, že příjezd do ramen 3 a 5 je zpožděn o časovou jednotku, což není zcela přesný předpoklad. Další problém je opět s nerovností délky cyklu a délce periody.





Obrázek 33: Rozdíl mezi naměřenou a spočtenou intenzitou pro rameno 3 a 5

Rozdíl mezi naměřenou a spočtenou intenzitou na jednotlivých ramenech, pro 7000 dat i pro celý datový soubor, je v tabulce 15. Největší rozdíly intenzit jsou v době dopravní špičky, ranní i odpolední, tedy v době nejhustšího dopravního provozu. Rozdíl byl spočten jako:


$$\text{sum}(\text{abs}(I3(5) - I3(5)s)),$$

kde  $I3(5)$  znamená naměřenou intenzitu na detektoru 3 (5) a  $I3(5)s$  je pro spočtenou intenzitu na vjezdu 3 (5). Ačkoliv rozdíl skutečné a spočtené intenzity se jeví jako velmi velký, při přepočtu na rameno a periodu dělá rozdíl v průměru 1,859 j.v./periodu na rameni 3 a 1,740 j.v./periodu na rameni 5.


počet dat	I3 [j.v.]	I5 [j.v.]
7000 dat	12 736	12 281
celý soubor	57 107	53 451

Tabulka 15: Rozdíl mezi naměřenou a spočtenou intenzitou

V tomto případě byla známa intenzita i obsazenost, šla tedy spočítat průměrná obsazenost k dané intenzitě přímo podle dat na rameni. Protože byl do určité intenzity dostatečný počet vzorků obsazenosti, lze říci, že jejich průměr má dostatečnou vypovídací hodnotu a je dostatečně přesný. Zjištěné hodnoty obsazenost - intenzita jsou zobrazeny na obrázku 34. Křivka byla brána jako hyperbola. Pro výpočet jejích bodů nebyly použity všechny získané vztahy, protože vyšší intenzity se vyskytovaly třeba jen několikrát.



Rameno 5



Rameno 3

Obrázek 34: Hodnoty obsazenosti vzhledem k intenzitě

Zjištěné hodnoty I3, I5, O3 a O5 byly použity pro vlastní odhad délky kolon. Nastavení bylo tedy stejné jako u TESTu 1 s jinými intenzitami a obsazenostmi na vnitřních ramenech.

	Spočtená I3 a I5		Naměřená I3 a I5	
	Odchylka	MSE	Odchylka	MSE
KF	$3,438 \cdot 10^5$	$5,673 \cdot 10^5$	$3,370 \cdot 10^5$	$5,632 \cdot 10^5$
DD1	$3,386 \cdot 10^5$	$5,555 \cdot 10^5$	$3,252 \cdot 10^5$	$5,466 \cdot 10^5$

Tabulka 16: Porovnání skutečné a napočítané intenzity

**Závěr:** Detektor umístěný v meziúsecích mezi křižovatkami je přesnější než výpočet. Nepřesnost vzniklá dopočtem intenzit a obsazeností na chybějícím detektoru není natolik velká, aby to mohlo výrazněji narušit odhady kolon. Pokud chybí detektory v meziúsecích křižovatek, je možné tyto chybějící intenzity a obsazenosti dopočítat a brát je jako přímo změřené.

### 5.2.4 TEST 3

**Cíl:** Zjistit, zda omezení odhadu kolon do záporu nějakým způsobem zásadně nezhoršuje celkový odhad. Tento test nemá za cíl odstranit problém s odhadem, ale zjistit následky omezení.

**Nastavení (2):** Nastavení apriorních kovariančních matic je stejné jako v TESTu 1. Na rozdíl od minulého testu je umožněn odhad délek kolon do záporných hodnot.

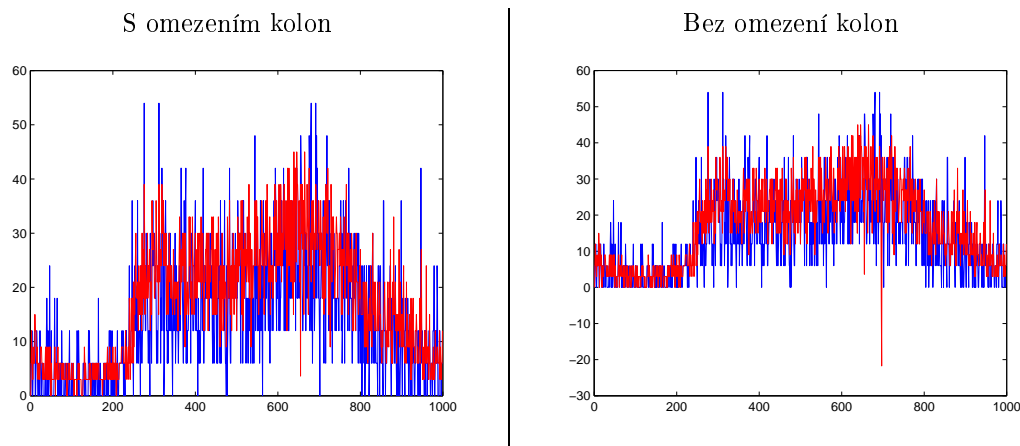
**Postup testu:** Kalmanův filtr a DD1 filtr byl postupně otestován na 7000 datech nejdříve s omezením délky kolon, pak bez tohoto omezení. Omezení spočívá v jednoduchém zákazu odhadu délek kolon do záporných hodnot. Záporné hodnoty se nahradí 0.

**Výsledky:** Odhady délky kolon, které jsou do mínusu, mohou být způsobeny nepřesnostmi ve vstupech (kdy se některé údaje skoro vyvracejí), či nepřesnostmi ve filtrech. Záporné hodnoty odhadu se vyskytují jak u Kalmanova filtru, tak u DD1 filtru.

Test proběhl u KF a DD1 filtru, se stejnými počátečními podmínkami. Výsledky odhadu jsou uvedeny v tabulce 17. S omezením znamená, že odhad, který byl záporný je nahrazen 0. Bez omezení znamená, že k žádné úpravě nedochází a záporný odhad je brán jako smysluplná hodnota. Rozdíl mezi odhadem omezeným a neomezeným je vidět na obrázku 35, kde je zobrazen denní průběh kolon na rameni 3.

	S omezením		Bez omezení	
	KF	DD1	KF	DD1
Odchylka	$3,438 \cdot 10^5$	$3,386 \cdot 10^5$	$3,370 \cdot 10^5$	$3,252 \cdot 10^5$
MSE	$5,673 \cdot 10^5$	$5,555 \cdot 10^5$	$5,632 \cdot 10^5$	$5,466 \cdot 10^5$

Tabulka 17: Omezení odhadu kolon



Obrázek 35: Odhad délek kolon při použití DD1 filtru (rameno 3)

**Závěr:** Omezením možnosti kolon do záporných hodnot bylo dosaženo optického zlepšení ale došlo k zhoršení celého odhadu. Z provedeného testu vyplývá, že je kvůli dalšímu zpracování výhodnější ponechat odhady kolon bez omezení. Při on-line odhadu ale tyto hodnoty mohou zcela narušit řízení. Z tohoto je tato úloha ještě neuzavřena a další postup bude směřovat k odhalení příčin špatných odhadů a následně méně drastickým metodám jejich korekce.

## 6 Shrnutí

Testovali jsme odhad délek kolon na mikrooblasti. Mikrooblast 1 je jedna tříramenná křížovatka s neměřeným vstupem a mikrooblast 2 jsou dvě čtyřramenné křížovatky.

### Mikrooblast 1

Mikrooblast 1 se skládá z jednosměrné tříramenné křížovatky s jedním neměřeným vjezdem, který je umístěn před výjezdový detektor.

V testu 1 jsme porovnávali odhad délek kolon získaných nejdříve pomocí lineárního Kalmanova filtru později nelineárního DD1 filtru. Kalmanův filtr by potřeboval pro správný odhad úplný popis systému, což jsme nemohli zajistit, protože se v mikrooblasti vyskytoval neměřený vjezd. Tato neurčitost naopak nevedla DD1 filtru a i umožněním změny hodnot parametru se zlepšil odhad. Proto lze konstatovat, že na této mikrooblasti se ukázal jako mnohem lepší DD1 filtr.

Testem 2 jsme chtěli zjistit, jak moc velký vliv má, na odhad délky kolony, nastavení kovarianční matice stavu a kovarianční matice měření. Při testech se zjistilo, že velmi záleží na nastavení kovarianční matice stavu, kdy výsledky jednotlivých nastavení se lišily až v řádu několika procent. Na druhou stranu není nutné hledat i optimální nastavení kovarianční matice měření. Ukázalo se, že většinou je dostatečné nastavení podle předpokládané chyby měření.

Testem 3 jsme chtěli zjistit, jaký vliv má kovarianční matice odhadu stavu a parametrů na celkový odhad. Testem se prokázal předpoklad, že u tohoto nastavení bude důležité především nastavení kovariance u parametrů modelu ( $\beta$ ,  $\kappa$ ,  $\lambda$ ,  $\nu$ ). Špatné nastavení těchto hodnot mohlo zhoršit odhad až o několik desítek procent. Díky "utažení" parametrů se značně omezila možnost změny parametrů a výsledek odhadu se blížil výsledku bez odhadu parametrů.

### Mikrooblast 2

Mikrooblast 2 se skládá ze dvou obousměrných čtyřramenných křížovek, kde jsou umístěny detektory na všech vjezdech i výjezdech.

V testu 1 jsme porovnávali odhad délek kolon pomocí Kalmanova filtru a DD1 filtru. Díky úplnému popisu systému (data ze všech detektorů...), vyšel odhad Kalmanova filtru téměř identicky s odhadem kolon pomocí DD1 filtru. Úplný popis systému, který je vhodný právě pro Kalmanův filtr, je v dopravní oblasti spíše výjimkou. DD1 filtr měl sice v tomto testu celkově lepší odhad, ale je výpočetně náročnější.

V testu 2 jsme se zabývali myšlenkou vypuštění vnitřních detektorů na společných ramenech obou křížovek. Zjišťovali jsme, zda se dá obsazenost na ramenech vypočítat z pravděpodobných vjezdových intenzit. Vytvořením správné funkce pro vztah obsazenosti - intenzita se dosáhlo takové přesnosti odhadu intenzity a obsazenosti na případně chybějících detektorech, že nedošlo k výraznému zhoršení odhadu (pomocí DD1 filtru). Lze tedy udělat závěr, že vynechání těchto detektorů se nedoporučuje, ale pokud se v meziúsecích nevyskytují, je možno intenzitu a obsazenost kvalitně dopočítat.

Test 3 měl rozhodnout, zda omezení odhadu kolon do záporných hodnot je vhodný nebo naopak škodlivý pro celý odhad. Odhad délek do záporu se vyskytuje díky předpokladu Gaussovského šumu v modelu. Omezením kolon pouze na kladné hodnoty se sice dosáhlo optického zlepšení odhadu, ale zhoršil se celkový odhad. Narušením a "vnucením" jiné hodnoty do modelu vede k celkové změně, která není úplně vhodná. Ukázalo se tedy, že toto omezení je nevhodné.

### Resumé

Došli k jsme k závěrům, že nelineární filtr DD1 je pro odhad délek kolon obecně výhodnější než lineární Kalmanův filtr. Velmi důležité je nastavení kovariačních matic stavu a měření i kovariančních matic odhadu stavu. V současnosti se kovariační matice nastavuje jako diagonální, což nemusí být optimální, ale tento předpoklad se ukazuje jako dostatečný. Problémem také nejsou neměřené vjezdy, ale musí být samozřejmě zajištěna alespoň částečná znalost systému. Problém s odhadem kolon do záporných hodnot by se měl vyřešit jiným způsobem než tvrdým omezením odhadu, jako třeba nahrazením jiným rozdělením.

## 7 Závěr

Odhad délek kolon je důležitá součást dopravní úlohy. Bohužel díky nelineritám v modelu, potřebě odhadu některých parametrů není vhodné použít lineární Kalmanův filtr. Použití Kalmanova filtru je možné pouze ve velmi omezených případech, kdy jsou známy hodnoty všech parametrů a je znám celkový popis systému.

Pro současné potřeby odhadu se ukázaly jako vhodné nelineární lokální filtry. Pro testy byl používán hlavně DD1. S nasazením dalších lokálních filtrů jako DD2 a UKF (Unscented Kalman Filter) je počítáno v následujícím období. DD2 filtr je vylepšený DD1 filtr, používaný v případech, kdy se vyskytují “složitější” nelinearity. Takové nelinearity se v tuto chvíli nevyskytují, ale v budoucnu se počítá s odhadem poměru odbočení, saturovaných toků, čímž bude pravděpodobně potřeba použít DD2 filtr. U UKF je zatím problém s velkým stavem modelu, který se u několika křižovatek vyskytuje. Na odstranění tohoto problému se usilovně pracuje.

V současnosti jsme tedy schopni odhadnout délku kolon na mikrooblasti s přesností, která je podle dopravních odborníků dostatečná, bohužel ale ne na všech druzích mikrooblastí. Zatím se testovaly takové oblasti, kde byl většinou znám skoro celý systém včetně všech vjezdů a výjezdů atd. Stále se zde také vyskytují problémy, které je potřeba odstranit (např. odhad kolon do záporných hodnot, neschopnost pochytit výrazné nárůsty kolon) a bude potřeba upravit modely na odhady dalších parametrů. Pro řízení je potřeba odhadovat kolony co nejpřesněji a ukazuje se, že po různých úpravách by mělo být možné odhad ještě zpřesnit. Dále je pravděpodobné, že při vlastním řízení dopravy nebude nutno odhadovat všechny parametry, ale některé odhadnout off-line a do modelu je dát pak jako konstanty. Tím by se zrychlil odhad a byl by připraven v mnohem kratším čase na řízení.

V budoucnosti bychom se chtěli zaměřit na odhad kolon i na méně mikrooblasti s většími neurčitostmi a i na odhad kolon na větších mikrooblastech. U odhadu na větší mikrooblasti se mohou vyskytnout problémy s dimenzí stavu modelu a na to je třeba pamatovat. Dále by se měl odhad rozšířit i na odhad poměru odbočení, saturovaného toku atd. a pokusit se vyřešit problém odhadu kolon s velkými změnami v krátkém čase.

## Reference

- [1] Kratochvílová J. and Nagy I. Sestavení obecné metodologie pro zadávání lineárního modelu dopravní mikrooblasti. Technical Report 2105, ÚTIA AV ČR, Praha, 2004.
- [2] R. E. Kalman. A new approach to linear filtering and prediction problems. pages 35–45, 1960.
- [3] J. Kratochvílová and I. Nagy. Lokální řízení městské dopravy. Technical Report 2101, ÚTIA AV ČR, Praha, 2004b.
- [4] M. Norgaard, N.K. Poulsen, and O. Ravn. Advances in derivative-free state estimation for nonlinear system. Technical Report IMM-REP-1998-15, Department of Mathematical Modelling, UNC, 2800 Lyngby, Denmark, 1998.
- [5] Y. Zhang, G. Sommer, and E. Bayro-Corrochano. The motor extended Kalman filter for dynamic rigid motion estimation from line observations. In G. Sommer, editor, *Geometric Computing with Clifford Algebra*, pages 501–530. Springer-Verlag, Heidelberg, 2001.