

Detekce a lokalizace výjimečných stavů v městské dopravě

1 Úvod

Reakce řídícího systému na nastalé výjimečné stavy v dopravě je velice důležitou součástí všech globálních řídících systémů. Než přistoupíme ke zkoumání výjimečných stavů v dopravě, vymezíme nejdříve to, co v této práci budeme považovat za výjimečný stav.

Výjimečným stavem v dopravě rozumíme mimořádnou dopravní situaci, jejíž dopad se podstatným způsobem odrazí v měřených dopravních datech.

P O Z N Á M K A: *Metody, které používáme, jsou založeny na informaci o struktuře zkoumané dopravní oblasti, apriorní znalosti o chování automobilů v dané oblasti a zejména na on-line měřených dopravních datech. Struktura oblasti je daná, apriorní informace vypovídá o "průměrných" vlastnostech oblasti a pouze reálná data nesou informaci o okamžitém dění v oblasti. Všechny dopravní události, které se v měřených datech neodrazí, jsou pro nás nedosažitelné, a nelze je detektovat ani řídit. Tím samozřejmě nemáme na mysli, že bychom potřebovali přímo nastalou poruchu měřit! Požadujeme pouze, aby se porucha v některých datech projevila, abychom ji mohli na základě těchto veličin předpovědět.*

V případě výjimečného stavu je situace odlišná od "běžných situací". Rozdílů je několik

- výjimečná situace nastává většinou ve velmi krátkém časovém intervalu a má přechodnou dobu trvání,
- dopad nastalé výjimečné situace na stav dopravního systému je většinou dosti podstatný,
- jednotlivých skupin podobných výjimečných stavů (alespoň co do dopadu na stav dopravního systému) bývá konečný počet.

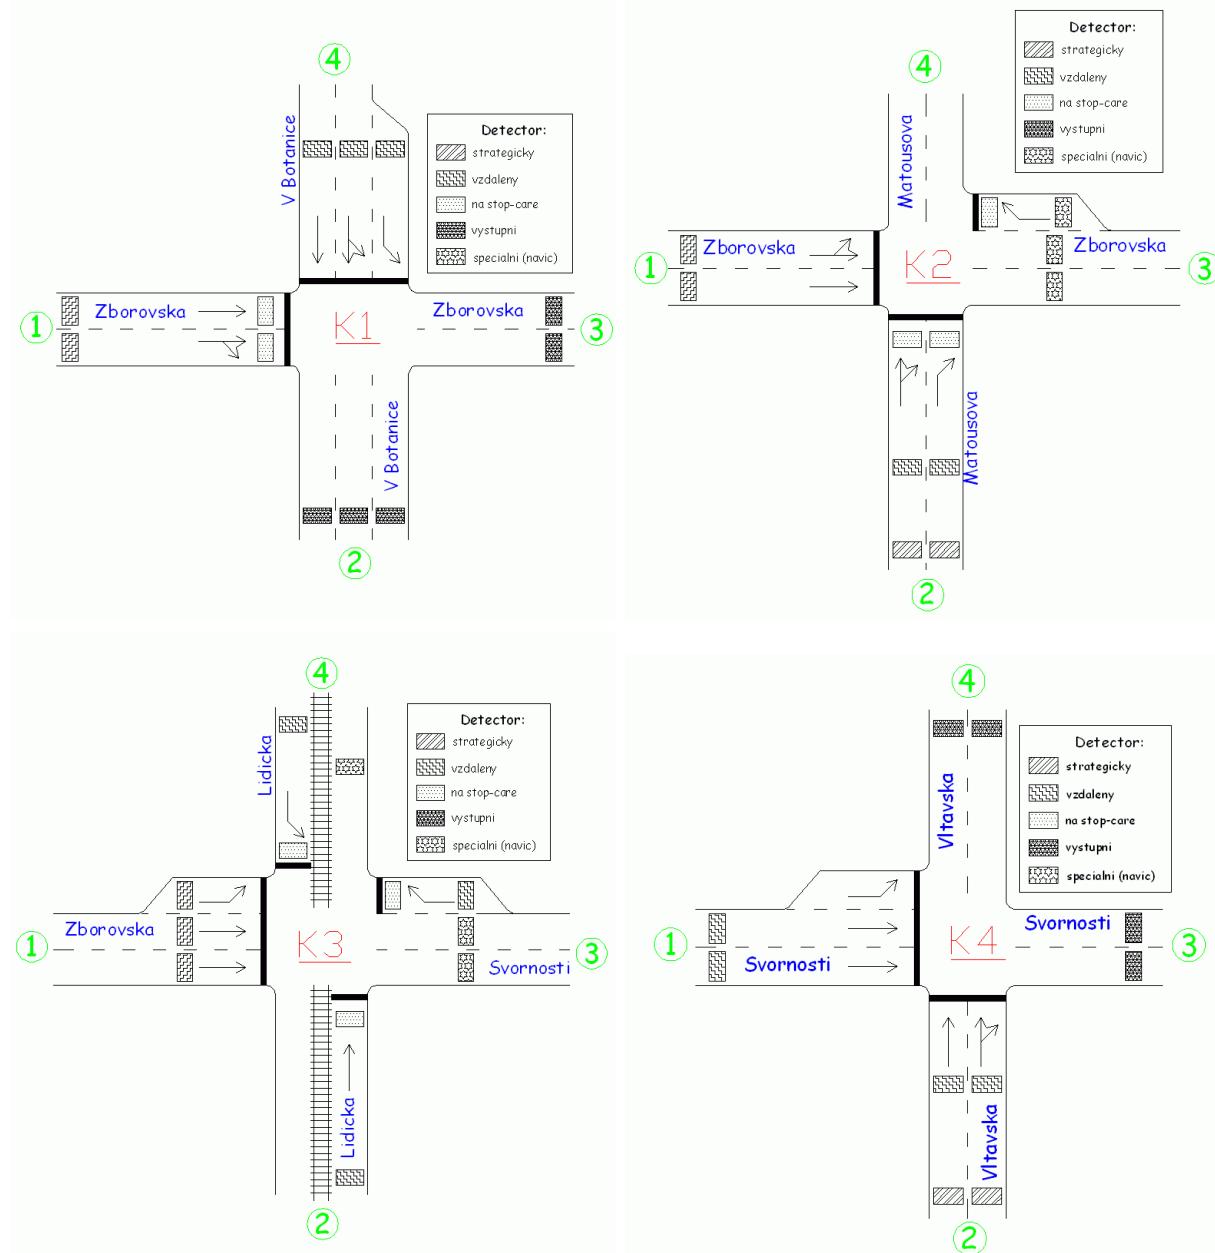
Výjimečné stavы lze samozřejmě klasifikovat podle řady hledisek a zahrnovat pod ně větší nebo menší množství událostí, majících (většinou negativní) vliv na dopravní systém a vymykajících se běžným dopravním podmínkám. My se přidržíme výčtu provedeného v práci [1]. Zde je uvedena poměrně široká škála různých výjimečných dopravních stavů včetně jejich vyhodnocení a návodu pro jejich detekci.

V této zprávě se však nebudeme ani tak zabývat klasifikací jednotlivých stavů jako obecnou úrovní rozpoznávání výjimečných stavů vůbec a jejich případnou klasifikací, tj. určením kde a jaký výjimečný stav nastal. Budeme se přitom držet jediného, nejpodstatnějšího druhu z výjimečných stavů, a to překážky ve vozovce. Jako jednotlivé výjimečné stavы budeme uvažovat různá místa, kde k této blokádě došlo. Otázkou bude: (I) poznáme vůbec, že někde v oblasti došlo k zablokování jízdního pruhu? (II) poznáme, na kterém místě k tomuto zablokování došlo? Zajímavé okolnosti při těchto experimentech jsou (i) za jak dlouho jsme schopni výjimečný stav zaregistrovat, (ii) s

jakou jistotou jsme schopni výjimečný stav detektovat, (iii) jak dlouho musí výjimečný stav trvat, abychom si jej vůbec všimli, (iv) jak silný dopad musí mít výjimečný stav, abychom jej zachytili. Řešení výjimečných stavů zde necháváme stranou a předpokládáme, že po detekci výjimečného stavu by nastoupilo určité expertní řízení, buď již existující nebo navržené dopravními operátory.

2 Formulace úlohy

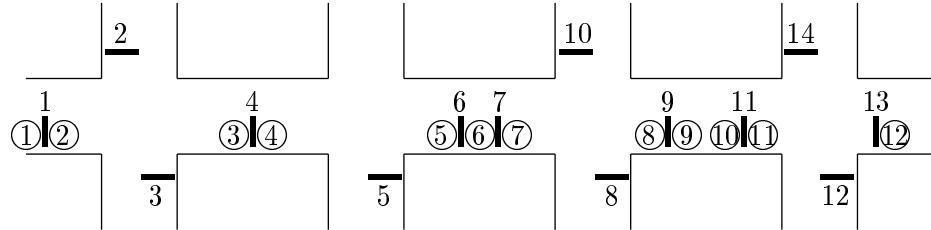
Pro testování byla vybrána liniová mikroblast se čtyřmi křižovatkami, konkrétně ulice Zborovská a Svornosti. Detailní plánek této oblasti, konkrétně jejích čtyřech řízených křižovatek, je na Obrázku 1.



Obrázek 1: Reálná oblast jejíž model byl použit pro testování

Oblast se nalézá v místě malého smíchovského okruhu. Tato oblast obsahuje ve skutečnosti 10 křížovatek, z nichž zbylých šest je neřízených a intenzita provozu v nich není velká. Proto jsme brali v úvahu jen uvedené čtyři světlenně řízené křížovatky.

Model této mikroblasti byl vytvořen pomocí dopravního simulátoru simuloval AIMSUN. Schema modelu je na Obrázku 2.



Obrázek 2: Mikroblast se zkoumanými výjimečnými stavami

Mikroblast je tvořena čtyřmi křížovatkami seřazenými v jedné linii - podrobnosti viz Obr. 1. Je zde vyznačeno 12 čísel v kroužku, která označují místa, kde byla postupně umisťována blokáda. Silnější svislé úsečky označují měřicí detektory, označené rovněž čísly.

Na vyznačených místech 1-12 byla simulována porucha ve formě stojícího automobilu. Na detektorech v oblasti (viz obr. 2) byla měřena data (obsazenosti dopravního proudu) pro stav bez poruchy (zádné stojící auto) a 12 poruchových stavů (porucha i odpovídá autu stojícímu v pozici i , $i = 1, 2 \dots, 12$). Pro stav bez poruchy a každý poruchový stav (určitá doba stání automobilu na zvolené pozici) je tedy k dispozici 13 datových souborů, charakterizujících stav oblasti.

Otázka je: (i) lze vůbec tímto způsobem poruchu detektovat? (ii) s jakou jistotou lze tvrdit, že tato porucha skutečně existuje jako pravdivá? (iii) jak dlouhé je třeba měření jak pro off-line, tak i pro on-line identifikaci, aby získaná informace o poruše byla dostatečná?

3 Model směsi distribucí a jeho odhad

V této kapitole naznačíme základy teorie odhadu směsového modelu metodou Quasi-Bayes. Protože zmíněná teorie je značně obtížná a její programová realizace využívá dosti nepřehledné ale zato velmi účinné odmocninové algoritmy, zůstaneme jen u odvození základních vztahů aniž bychom je převáděli do podoby algoritmu. Ten je zpracován v systému MIXTOOLS vytvořeném v AS ÚTIA AV ČR - viz [2]. Úplná teorie odhadu směsových modelů je popsána v [3].

Komponenty modelu

Předpokládáme n modelů, indexovaných přirozenými čísly $c \in \{1, 2, \dots, n\} = c^*$ a modelovaná data d_t , $t \in t^*$. Modely jsou popsány svými podmíněnými hustotami pravděpodobnosti hp

$$f(d_t | d(t-1), c, \Theta_c).$$

Dále předpokládáme, že v každém časovém okamžiku je aktivní pouze jeden model - **komponenta** směsového modelu, tj. že právě jen tato komponenta odráží skutečný stav sledovaného systému.

Ukazatel

Aktivity jednotlivých komponent označuje **ukazatel** - náhodná veličina c_t s hodnotami $1, 2, \dots, n$. $c_t = c$ znamená, že v okamžiku t je aktivní komponenta c .

Pravděpodobnosti aktivity jednotlivých komponent c , bez znalosti aktuálních dat d_t , předpokládáme konstantní a rovny α_c , tedy

$$f(c_t = c | d(t-1), \alpha) = f(c_t = c | \alpha) = \alpha_c$$

P O Z N Á M K A: Výrazem $f(c_t = c)$ myslíme $f_{c_t}(c) = P(c_t = c)$ kde $P(\cdot)$ označuje pravděpodobnost.

V okamžiku, kdy naměříme data d_t , máme další informaci o skutečném aktuálním stavu. Hp vyjadřující tento stav je

$$f(c_t | d(t)).$$

Náhodná posloupnost c_t je neznámá a její hodnoty nelze měřit a je třeba je odhadovat.

4 Odhad modelů směsi distribucí

4.1 Vnitřní popis směsi

Sdružená hp dat a ukazatele

Tato hp popisuje jak data, tak i ukazatele

$$f(d_t, c_t | d(t-1), \Theta, \alpha). \quad (1)$$

Je to sdružená hp, parametrizovaná vektorem parametrů $[\Theta, \alpha]$. Tato hp určuje pravděpodobnost, že data d_t pochází z komponenty c_t .

Tato sdružená hp může být rozložena takto

$$(1) = f(d_t|d(t-1), c_t, \Theta, \alpha) f(c_t|d(t-1), \Theta, \alpha) = \\ = f(d_t|\varphi_{t-1}, c_t, \Theta_{c_t}) f(c_t|\alpha) = \alpha_{c_t} f(d_t|\varphi_{t-1}, c_t, \Theta_{c_t})$$

kde

$$f(d_t|d(t-1), c_t, \Theta, \alpha) = f(d_t|\varphi_{t-1}, c_t, \Theta_{c_t}) \quad (2)$$

je **popis jedné komponenty** (konkrétně s indexem c_t), a

$$f(c_t|d(t-1), \Theta, \alpha) = f(c_t|\alpha) = \alpha_{c_t} \quad (3)$$

je pravděpodobnostní **popis ukazatele** c_t .

P O Z N Á M K A: *Z předchozího plynou požadavky na model*

1. každá komponenta $c = 1, 2, \dots, n$ má své vlastní parametry Θ_c ,
2. data d_t jsou závislá jen na datech, obsažených v regresním vektoru φ_{t-1} (tj. minulých datech až do hloubky řádu modelu),
3. ukazatel je nezávislý na parametrech component Θ_c ,
4. ukazatel je podmíněně nezávislý na starých datech, je-li znám parametr ukazatele - vektor α ,
5. pravděpodobnosti komponent v čase t bez znalosti d_t jsou stacionární.

4.2 Vnější popis směsi

Hp dat bez ohledu na aktivitu component

Tuto hp lze dostat dvěma způsoby (přesně a s approximací):

První způsob je přesný a je dán marginalizací hp (1) vzhledem k ukazateli c_t

$$f(d_t|d(t-1), \Theta, \alpha) = \\ = \sum_{c_t \in c^*} f(d_t, c_t|d(t-1), \Theta, \alpha) = \sum_{c_t \in c^*} \alpha_{c_t} f(d_t, c_t|d(t-1), \Theta, \alpha). \quad (4)$$

kde jsme použili vztah (3).

Druhá možnost je approximace. Ta spočívá v nahrazení ukazatele c_t nějakým jeho bodovým odhadem. Ze sdružené pravděpodobnosti se pak po dosazení bodového odhadu stane hp jediné proměnné, a to d_t . Tak dostaneme marginální hp. Tento postup není, vzhledem k approximaci, optimální, zato ale vede na spočitatelné algoritmy pro odhadování. Touto cestou dostáváme

$$f(d_t|d(t-1), \Theta, \alpha) \propto f(d_t, \hat{c}_t|d(t-1), \Theta, \alpha), \quad (5)$$

kde c_t je bodový odhad počítaný na základě starých dat $d(t-1)$. Bodový odhad je počítán jako podmíněná střední hodnota (viz dále).

4.3 Odhad $[\Theta, \alpha]$ - (Bayesův vzorec)

Bayesův vzorec pro odhad parametru $[\Theta, \alpha]$ má tvar

$$\begin{aligned} f(\Theta, \alpha | d(t)) &= f(\Theta, \alpha | d_t, d(t-1)) \\ &\propto f(d_t | d(t-1), \Theta, \alpha) f(\Theta, \alpha | d(t-1)) \end{aligned} \quad (6)$$

což je rekurze, která přepočítává hp pro jmenovaný parametr. Pro její použití se vyžaduje znalost vnějšího popisu směsi $f(d_t | d(t-1), \Theta, \alpha)$. Protože Bayesův vztah (6) má součinový tvar a vnější popis směsi je dán ve tvaru součtu (4), dostáváme výsledek v tvaru součinu součtů, což je výpočteně nevhodné.

Řešení, které je spočitelné, dostaneme s využitím approximovaného vztahu (5). To je cesta, kterou se budeme dále zabývat.

4.4 Odhad $[\Theta, \alpha]$ - (pro statistiky)

Modely komponent v exponenciálním tvaru

Komponenty vyjádříme pomocí hp z exponenciální třídy

$$f(d_t | \varphi_{t-1}, c, \Theta_c) = \exp\{q_c(\Theta)s(\varphi_{t-1})\}, \quad c \in c^* \quad (7)$$

kde $q_c(\Theta)$ je parametrická funkce c -té komponenty a $s(\varphi_{t-1})$ je statistika (společná všem komponentám).

Součinový tvar modelu a apriorní hp

Pro další odvození je výhodné formálně vyjádřit jak model, tak i apriorní hp v následujícím součinovém tvaru

$$\begin{aligned} \alpha_{c_t} f(d_t | \varphi_{t-1}, c_t, \Theta_{c_t}) &= \alpha_{c_t} \exp\{q_{c_t}(\Theta)s(\varphi_{t-1})\} \\ &= \prod_{c \in c^*} [\alpha_c \exp\{q_c(\Theta)s(\varphi_{t-1})\}]^{\delta(c, c_t)} \\ &= \prod_{c \in c^*} \alpha_c^{\delta(c, c_t)} \prod_{c \in c^*} \exp\{q_c(\Theta)s(\varphi_{t-1})\} \delta(c, c_t) \end{aligned} \quad (8)$$

a

$$f(\Theta, \alpha | d(t-1)) = \prod_{c \in c^*} \alpha_c^{\kappa(t-1)} \prod_{c \in c^*} \exp\{q_c(\Theta)S(t-1)\}, \quad (9)$$

kde $\kappa(t-1)$ a $S(t-1)$ jsou statistiky hp parametrů v čase $t-1$.

P O Z N Á M K A: $\delta(c, c_t)$ je Diracova δ -funkce, definovaná takto

$$\delta(c, c_t) = \begin{cases} 1 & \text{for } c = c_t \\ 0 & \text{for } c \neq c_t \end{cases}$$

Bayesův vzorec pro součinový tvar hp

Dosadíme součinové tvary (8) and (9) do Bayesova vzorce (6) a dostaneme

$$\begin{aligned} \prod_{c \in c^*} \alpha_c^{\kappa(t)} \exp\{q_c(\Theta)S(t)\} &= \prod_{c \in c^*} \alpha_c^{\delta(c, c_t)} \prod_{c \in c^*} \exp\{q_c(\Theta)s(\varphi_{t-1})\delta(c, c_t)\} \\ &\quad \prod_{c \in c^*} \alpha_c^{\kappa(t-1)} \prod_{c \in c^*} \exp\{q_c(\Theta)S(t-1)\} \\ &= \prod_{c \in c^*} \alpha_c^{[\delta(c, c_t) + \kappa(t-1)]} \prod_{c \in c^*} \exp\{q_c(\Theta)[s(\varphi_{t-1})\delta(c, c_t) + S(t-1)]\} \end{aligned}$$

Z této rekurze pro hp získáme rekurzi pro statistiky

$$\kappa(t) = \kappa(t-1) + \delta(c, c_t) \tag{10}$$

$$S(t) = S(t-1) + \delta(c, c_t) s(\varphi_{t-1}) \tag{11}$$

která říká: přepočítej pouze tu statistiku, jejíž komponenta byla v čase t aktivní.

Tato rekurze ale není prakticky použitelná, neboť obsahuje neznámou proměnnou c_t . Protože se ale tato proměnná vyskytuje pouze ve funkci δ , budeme approximovat celou tuto funkci.

4.5 Aproximace

Místo funkce $\delta(c, c_t)$ dosadíme její střední hodnotu

$$\delta(c, c_t) \sim E[\delta(c, c_t)|d(t)] \equiv w_c(t). \tag{12}$$

Výpočet střední hodnoty

$$E[\delta(c, c_t)|d(t)] = \int \delta(c, c_t) f(c_t|d(t)) \mathrm{d}c_t = f(c|d(t)) \equiv w_c(t), \quad c \in c^*,$$

což vyžaduje znalost hp $f(c|d(t))$, $c \in c^*$.

Konstrukce hp $f(c|d(t))$

Potřebnou hp lze získat takto

$$f(c|d(t)) = f(c|d_t, d(t-1)) \propto f(d_t, c|d(t-1)) = f(d_t|c, d(t-1))f(c|d(t-1)).$$

Poslední dvě hp mohou být parametrisovány

$$\begin{aligned} f(d_t|c, d(t-1)) &= \int f(d_t, \Theta_c|c, d(t-1)) \mathrm{d}\Theta_c = \\ &= \int f(d_t|c, d(t-1), \Theta_c) f(\Theta_c|d(t-1)) \mathrm{d}\Theta_c = \\ &= \int f(d_t|\varphi_{t-1}, c, \Theta_c) f(\Theta_c|d(t-1)) \mathrm{d}\Theta_c \end{aligned}$$

a

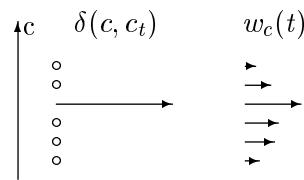
$$\begin{aligned}
 f(c|d(t-1)) &= \int f(c, \alpha_c|d(t-1)) d\alpha_c = \\
 &= \int f(c|d(t-1), \alpha_c) f(\alpha_c|d(t-1)) d\alpha_c = \\
 &= \int \alpha_c f(\alpha_c|d(t-1)) d\alpha_c
 \end{aligned}$$

Tak dostáváme

$$w_c(t) = f(c|d(t)) = \int f(d_t|\varphi_{t-1}, c, \Theta_c) f(\Theta_c|d(t-1)) d\Theta_c \int \alpha_c f(\alpha_c|d(t-1)) d\alpha_c \quad (13)$$

v závislosti na známých hp, konkrétně jsou to modely komponent a ukazatele a apriorní hp převzatá z minulého kroku identifikace.

P O Z N Á M K A: *Aproximace rozděluje původní deterministický ukazatel c_t s "dirakovskou" hp $\delta(c, c_t)$ na pravděpodobnostní ukazatel s hp $w(t)$. Situace je zachycena na následujícím obrázku:*



Obrázek 3. Efekt approximace ukazovatele

Zatímco původní ukazovatel ukazuje "s jistotou" na jedinou komponentu, approximovaný ukazatel připouští jako aktivní i sousední komponenty s příslušnými pravděpodobnostmi aktivit.

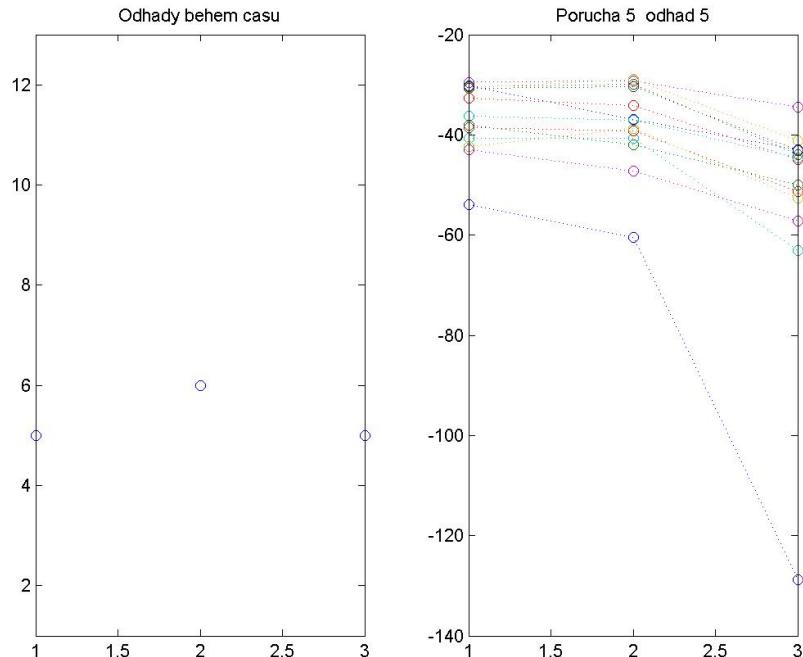
5 Experimenty

Pro rekonstrukci stavu, který určuje místo simulované poruchy, použijeme odhad modelu mikroblasti ve formě směsi distribucí. Off-line odhadneme model pro bezporuchový stav a všechny poruchové poruchové stavy, a s použitím všech dat, která máme k dispozici. Tyto modely uschováme. On-line měříme data s danou poruchou a odhadujeme příslušný model. Porovnáním on-line modelu s jednotlivými modely získanými off-line zjistíme minimální vzdálenost odhadnutého modelu s ostatními a pro který model je vzdálenost minimální, tu poruchu prohlásíme za aktuální. Experiment má tedy dvě části:

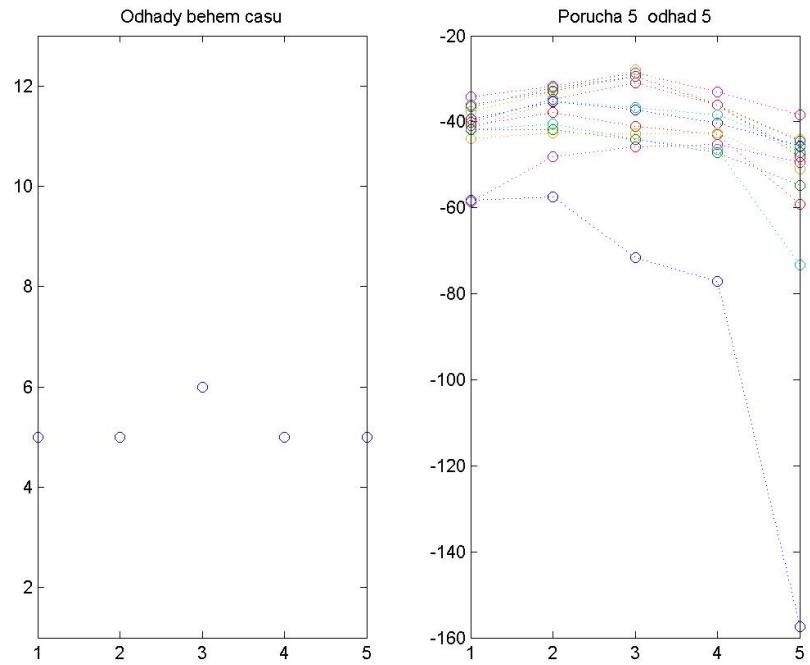
1. Část učení, kdy je použita setrvalá porucha po dobu 15 dní,
2. Část testování, kde jsou použita aktuální data v době trvání 4.5, 7.5, 15 a 22,5 min. Tyto časy, při periodě vzorkování 1.5 min, odpovídají třem, pěti, deseti a patnácti aktuálním vzorkům.

Pro prezentaci jsme vybrali poruchu č. 5 a pro test byla použita data (obsazenost) na detektoru č. 5. Vzájemnou pozici detektoru 5 a stojícího vozidla způsobujícího poruchu 5 je možno nalézt na obrázku 2. Na následujících obrázcích jsou výsledky testů aktuálních dat při poruše 5. Každý z obrázků má dvě části. Na levé straně je vynesen průběh odhadů poruchy - na ose x je pořadí zpracovávaného aktuálního vzorku, na ose y je odhad čísla poruchy. Jako výsledný odhad poruchy bereme nejčastější odhad z jednotlivých kroků.

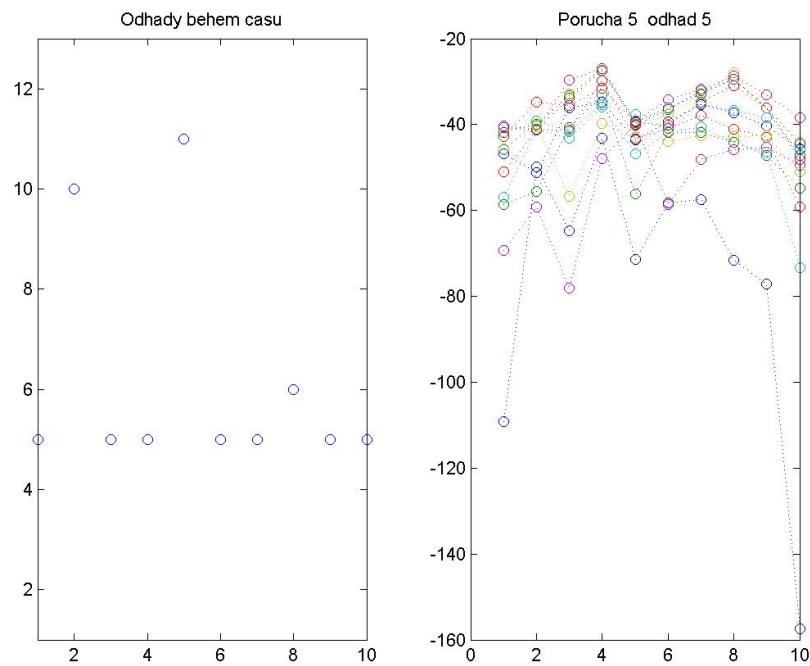
V pravé části každého obrázku jsou vyneseny nenornované logaritmické likelihoody pro všechny směsi naučené na jednotlivé poruchy. Vyhrává ta porucha, která je nejčastěji maximální. V ideálním případě by měl být jeden průběh s určitým odstupem trvale maximální a ostatní menší. Tento ideální stav však nenastává, což svědčí o tom, že informace o poruše není v datech mnoho.



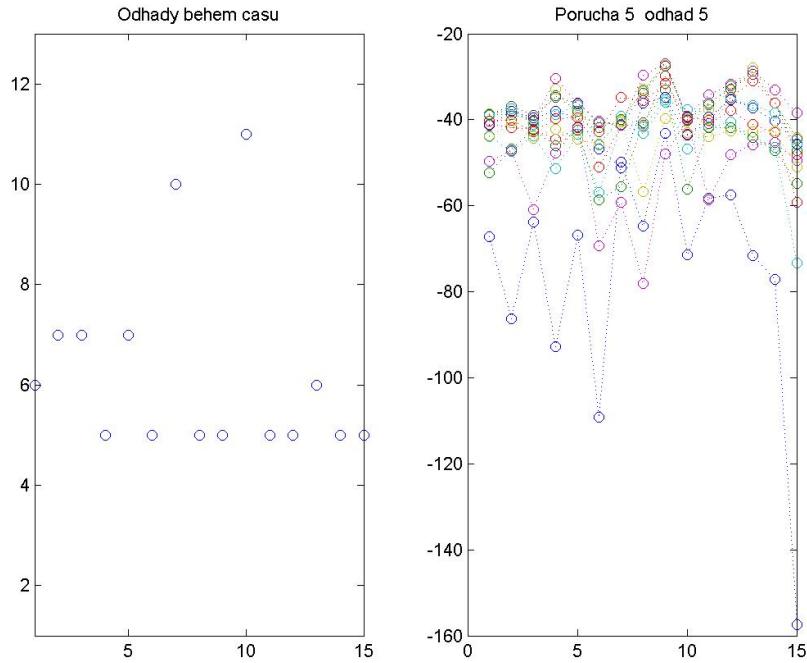
Obrázek 3: Porucha 5, tři vzorky dat = 4.5 minuty



Obrázek 4: Porucha 5, pět vzorků dat = 7.5 minut



Obrázek 5: Porucha 5, deset vzorků dat = 15 minut



Obrázek 6: Porucha 5, patnáct vzorků dat = 22.5 minuty

Z uvedených obrázků je patrné, že porucha č. 5 byla správně detekována ve všech případech. Odhad ze tří dat je dosti nejistý, ale ukazuje se, že pět aktuálních vzorků je pro detekci poruchy dostačující.

Pro úplnost uvádíme výsledky pro 3, 5, 10 a 15 vzorků dat pro všechny typy poruch, tj. poruchu 1 až 13. Čísla poruch je možno sledovat na obrázku 2, přičemž připomínáme: 1 je bezporuchový stav a poruchy 2,3,... jsou označeny jako 1,2,...

Výsledky jsou uvedeny v tabulkách, kde v prvním řádku je skutečné číslo poruchy v druhém řádku je číslo odhadu poruchy.

skutečná porucha	1	2	3	4	5	6	7	8	9	10	11	12	13
odhadnutá porucha	1	5	4	4	5	6	6	8	9	10	10	12	13

Rozhodování po třech vzorcích = 4.5 minuty

skutečná porucha	1	2	3	4	5	6	7	8	9	10	11	12	13
odhadnutá porucha	1	2	4	4	5	6	6	8	9	10	10	12	13

Rozhodování po pěti vzorcích = 7.5 minuty

skutečná porucha	1	2	3	4	5	6	7	8	9	10	11	12	13
odhadnutá porucha	1	2	3	4	5	6	6	8	9	10	10	12	13

Rozhodování po deseti vzorcích = 15 minut

skutečná porucha	1	2	3	4	5	6	7	8	9	10	11	12	13
odhadnutá porucha	1	2	3	4	5	6	2	8	9	10	10	12	13

Rozhodování po patnácti vzorcích = 22.5 minuty

Z uvedeného je patrné, že již rozhodování s pěti vzorky, tj. daty měřenými po dobu 7.5 minuty je velmi dobré.

6 Závěr

Provedené pokusy, testující schopnost pravděpodobnostní směsi popsat a rozlišit dopravní data z různých dopravních situací, prokázaly, že uvedená cesta je perspektivní. Výhodou tohoto přístupu je, že je postavena na globálním pohledu na dopravní oblast, a tedy je v podstatě nezávislý na jejím konkrétním výběru. Zahranutí všech měřených dat do odhadu rovněž zajistuje maximální využití dostupné informace, i když se porucha na některých detektorech neprojeví. Cestou, která zde byla naznačena, se bude dále pokračovat a budou se testovat další zlepšení. Jedním z nich, např. je pro testy brát nejenom měřené obsazenosti, ale dvojice [obsazenost, intenzita], které představují elementární stavy dopravy.

Reference

- [1] Drbohlav J. Pliška Z. Přibyl P., Tichý T., "Návrh expertního systému pro řešení mimořádných událostí- oblast smíchova", Tech. Rep., ELTODO, Praha 4, Novodvorská 14, Praha, 17. prosince 2005.
- [2] P. Nedoma, M. Kárný, T. V. Guy, I. Nagy, and J. Böhm, *Mixtools. (Program)*, ÚTIA AV ČR, Praha, 2003.
- [3] M. Kárný, J. Böhm, T. V. Guy, L. Jirsa, I. Nagy, P. Nedoma, and L. Tesař, *Optimized Bayesian Dynamic Advising: Theory and Algorithms*, Springer, London, 2005.