

Dolování v trajektoriích extrahovaných z videa

Technická zpráva - FIT - VG20102015006 - 2013 - 02

Ing. Martin Pešek



Fakulta informačních technologií, Vysoké učení technické v Brně

9. ledna 2014

Abstrakt

V prostředí dohledových kamerových systémů v současnosti vzniká obrovské množství video dat, ze kterých lze extrahovat užitečné informace o pohybu objektů v podobě trajektorií. Analýza těchto dat pak může významně přispět k pochopení chování objektů pohybujících se ve sledované oblasti. Velmi často se objevuje požadavek na automatizované metody pro popis aktivit a chování objektů na základě dat extrahovaných ze samotného videa, nikoliv na základě manuální specifikace. Takové metody pak poskytují model využitelný pro různé úlohy analýzy chování pohybujících se objektů, zejména pak pro detekci zajímavých či neobvyklých událostí. Tato technická zpráva se nejprve věnuje oblasti dolování v datech pohybujících se objektů na obecné úrovni. Následně popisuje problematiku sémantických trajektorií, které se snaží odrazit myšlenku, že trajektorie má jednak obecné rysy, které jsou aplikačně nezávislé, a dále pak sémantické rysy, které jsou aplikačně závislé. V další části se již zpráva zabývá problematikou automatického modelování pohybu objektů v oblasti sledované dohledovou kamerou. Kromě procesu učení se modelu sledované oblasti jsou popsány i způsoby jeho využití při analýze aktivit a chování objektů.

Obsah

1 Úvod	3
2 Dolování v datech pohybujících se objektů	4
2.1 Dolování vzorů pohybujících se objektů	4
2.2 Shlukování trajektorií	7
2.3 Predikce trajektorií	9
2.4 Klasifikace trajektorií	10
2.5 Detekce odlehlých trajektorií	11
2.6 Sémantické trajektorie	14
2.6.1 Metody pro sémantické obohacení trajektorií	15
3 Dolování v trajektoriích extrahovaných z videa	17
3.1 Modelování sledované oblasti	19
3.1.1 Sledování objektů	20
3.1.2 Význačná místa	21
3.1.3 Cesty objektů	21
3.2 Učení se modelu sledované oblasti	22
3.2.1 Předzpracování trajektorií	23
3.2.2 Shlukování trajektorií	23
3.2.3 Modelování cest	27
3.3 Analýza chování objektů	28
3.3.1 Klasifikace trajektorií	28
3.3.2 Detekce neobvyklých trajektorií	29
3.3.3 Online analýza	29
4 Experimenty s identifikací význačných míst scény	30
5 Závěr	32

1 Úvod

Získávání znalostí z databází je v posledních letech velmi rychle se rozvíjející oblast, která obzvláště vzhledem k obrovskému objemu různých dat nabývá stále více na užitečnosti a důležitosti. Jádrem procesu získávání znalostí je fáze dolování z dat, při které je aplikován konkrétní algoritmus za účelem extrakce požadovaných vzorů.

Se stále zvyšujícím se množstvím ukládaných dat o pohybujících se objektech v podobě trajektorií výrazně roste důležitost a potenciální užitečnost analýzy tohoto typu dat. Při analýze dat pohybujících se objektů lze s výhodou uplatnit různé metody dolování z dat.

Dolováním v datech pohybujících se objektů se zabývá kapitola 2. Cílem této kapitoly je poskytnout širší pohled na problematiku dolování v datech pohybujících se objektů a popsat existující přístupy pro řešení jednotlivých úloh. Nejprve se věnuje hledání vzorů pohybujících se objektů, v další části se pak zaměřuje na dolování v trajektoriích, což zahrnuje úlohy typu shlukování trajektorií, predikci budoucího pohybu, klasifikaci trajektorií a detekci neobvyklých trajektorií.

Trajektorie pohybujících se objektů jsou nejčastěji ukládány v podobě sekvence časoprostorových bodů. Pro mnoho aplikací však z trajektorií v této podobě není možné získat zajímavé vzory bez uvažování geografické a aplikačně specifické informace. Objevuje se tak pojem sémantické trajektorie, který odráží myšlenku, že trajektorie má jednak obecné rysy, které jsou aplikačně nezávislé, a dále pak sémantické rysy, které jsou aplikačně závislé. Cílem je tak obohatit časoprostorové trajektorie doménově specifickými sémantickými informacemi ve fázi předzpracování dat. Dotazování a analýza pak probíhá nad vygenerovanými sémantickými trajektoriemi. Problematikou sémantických trajektorií se zabývá závěrečná část kapitoly 2.

V prostředí dohledových kamerových systémů v současnosti vzniká obrovské množství video dat, ze kterých lze extrahovat užitečné informace o pohybu objektů v podobě trajektorií. Analýza těchto dat pak může významně přispět k pochopení chování objektů pohybujících se ve sledované oblasti.

Mnoho technik pro analýzu aktivit pohybujících se objektů ve videu na vyšší úrovni abstrakce vyžaduje navíc určitou doménovou znalost danou konkrétní aplikací. Vzhledem k rychle se rozšiřujícímu používání dohledových kamerových systémů se však velmi často objevuje požadavek na automatizované metody pro popis aktivit a chování objektů na základě dat extrahovaných ze samotného videa, nikoliv na základě manuální specifikace. Takové metody pak poskytují model využitelný pro různé úlohy analýzy chování pohybujících se objektů, zejména pak pro detekci zajímavých či neobvyklých událostí. Problematice automatického modelování pohybu objektů ve sledované oblasti se věnuje kapitola 3. Kromě procesu učení se modelu sledované oblasti jsou popsány i způsoby jeho využití při analýze aktivit a chování objektů. Mezi popsané analytické úlohy patří klasifikace trajektorií, detekce neobvyklých trajektorií a online analýza, která zahrnuje predikci pohybu a detekci neobvyklého chování.

2 Dolování v datech pohybujících se objektů

Zejména s rozvojem lokalizačních či dohledových systémů, sensorových sítí a mobilních zařízení v nedávné době začal prudce narůstat objem ukládaných časoprostorových dat, čímž výrazně stoupá jejich potenciál. Nejčastěji se jedná o data o pohybujících se objektech v podobě jejich trajektorií. Tato data mohou popisovat pohyb lidí, zvířat, dopravních prostředků, ale například i ledovců, bouří a podobně. Kromě rozvoje technologií pro modelování, dotazování a indexování přináší získávání znalostí z dat pohybujících se objektů, hlavně vzhledem k jejich složitosti, mnohé výzvy pro současný výzkum.

Trajektorie pohybujících se objektů jsou obvykle reprezentovány jako sekvence časoprostorových bodů (x, y, t) , kde x, y odpovídají prostorovým souřadnicím pohybujícího se objektu ve dvourozměrném prostoru a t je časové razítko. Pro dotazování a indexování trajektorií v této podobě bylo vytvořeno několik modelů a přístupů, viz například [17] nebo [72]. Vzniklo také několik prototypů databázových systémů pro správu dat o pohybujících se objektech, například Hermes [55] nebo SECONDO [16].

Při analýze dat pohybujících se objektů nacházejí široké uplatnění různé metody dolování z dat. Úlohy dolování v datech pohybujících se objektů lze rozdělit do dvou skupin na *dolování vzorů pohybujících se objektů* a *dolování v trajektoriích* [22]. Do první skupiny úloh patří hledání skupin pohybujících se objektů, dolování frekventovaných pohybů a dolování periodických vzorů. Do druhé skupiny pak lze zařadit shlukovou analýzu, klasifikaci nebo predikci trajektorií a detekci odlehlých trajektorií, tedy takových, které reprezentují neobvyklé chování pohybujících se objektů.

Ve všech těchto případech jsou však uvažovány pouze časoprostorové rysy trajektorií. Chování pohybujícího se objektu je tak popsáno pouze geometrickými vlastnostmi jeho trajektorie, tedy prostřednictvím rysů na nízké úrovni abstrakce. V tomto pohledu na data pohybujících se objektů chybí podpora sémantických vlastností trajektorií, které by umožňovaly dotazování a analýzu těchto dat na vyšší úrovni abstrakce. Začíná se proto často objevovat pojem *sémantické trajektorie*.

Tato kapitola se věnuje problematice dolování v datech pohybujících se objektů a popisuje existující metody pro výše uvedené dolovací úlohy. Závěrečná část této kapitoly se zabývá problematikou sémantických trajektorií se zaměřením na popis metod pro obohacení trajektorií o sémantickou informaci.

2.1 Dolování vzorů pohybujících se objektů

Hledání vzorů pohybujících se objektů je úloha dolování z dat, jejímž cílem je objevit různé typy potenciálně užitečných vzorů v databázích pohybujících se objektů. Tyto vzory mohou být rozděleny do následujících tří kategorií [41]:

- *Vztahy mezi objekty* (anglicky *relationship patterns*) – tento typ vzorů je zaměřen na vztahy mezi jednotlivými pohybujícími se objekty. Nejčastější úlohou je zde hledání skupin objektů, které se pohybují společně, nicméně je možné hledat i jiné typy vztahů mezi objekty.

- *Frekventované vzory pohybu* (anglicky *frequent trajectory patterns*) – tyto vzory reprezentují obecné trendy pohybu všech objektů vzhledem k prostoru (například oblasti navštívené během pohybu) i k času (například doba trvání pohybu).
- *Opakující se vzory* (anglicky *repetitive patterns*) – jedná se o vzory popisující periodické chování pohybujících se objektů, což může být typické například pro některá zvířata nebo lidi.

Popisu jednotlivých typů vzorů se věnuje zbytek této sekce. Některé ze zmíněných vzorů jsou zahrnuty v systému *MoveMine* [41], který poskytuje funkcionalitu dolování z dat se zaměřením na data o pohybu zvířat. Tento systém kromě metod pro hledání vzorů pohybujících se objektů nabízí i metody pro shlukování trajektorií a detekci odlehlých trajektorií, kterým je věnována pozornost v dalších sekcích.

Hledání skupin pohybujících se objektů


Cílem této úlohy je najít skupiny objektů, které vyhovují konkrétnímu chování z pohledu společných pohybů a vzájemných interakcí mezi objekty skupiny.

Hledání skupin objektů, které se pohybují společně, lze chápat jako hledání *pohybujícího se shluku* [30]. Pohybující se shluk značí skupinu objektů pohybujících se geometricky blízko sebe po určitý časový interval. Pro vyhledávání pohybujících se shluků je v [30] navržen algoritmus, který pro každý časový okamžik provede shlukování pomocí metody DBSCAN [19] a nalezené shluky vždy srovná se shluky z předchozího časového okamžiku.

Na konceptu vzájemných pohybů objektů (anglicky *relative motions*) byl vyvinut a v dalších pracích dále rozvíjen rámec nazvaný REMO [32] [18], který specifikuje kolekci časoprostorových skupinových vzorů na základě podobnosti směrů a změn směrů pohybu objektů. Jedná se zejména o následující typy vzorů (uvažujeme parametry $m > 1$, $r > 0$, případně $\tau > 0$, kde m a τ jsou celá čísla a r je reálné číslo):

- *Stádo* (anglicky *flock*) – vzoru vyhovuje skupina nejméně m objektů, které se nacházejí v kruhové oblasti o poloměru r a pohybují se ve stejném směru. Příklad vzoru typu stádo je na obrázku 1 vlevo.
- *Vedení* (anglicky *leadership*) – vzoru vyhovuje skupina nejméně m objektů, které se nacházejí v kruhové oblasti o poloměru r , pohybují se ve stejném směru a alespoň jeden z objektů udržuje tento směr po dobu nejméně τ časových kroků. Příklad vzoru typu vedení je na obrázku 1 vlevo.
- *Sbíhavost* (anglicky *convergence*) – vzoru vyhovuje skupina nejméně m objektů, které dosáhnou stejné kruhové oblasti o poloměru r (za předpokladu udržení stejného směru). Příklad vzoru typu sbíhavost je na obrázku 1 vpravo.

- *Setkání* (anglicky *encounter*) – vzoru vyhovuje skupina nejméně m objektů, které dosáhnou stejné kruhové oblasti o poloměru r současně (za předpokladu udržení stejného směru a stejné rychlosti).



Obrázek 1: Příklad vzoru typu *stádo* a *vedení* s vedoucí trajektorií p_2 (vlevo) a vzoru typu *sbíhavost* pro trajektorie p_2, p_3, p_4, p_5 (vpravo) (převzato z [18]).

Nevýhodou vzoru typu stádo je jeho omezení na kruhový poloměr. To může vést ke ztrátě některých objektů, které se pohybují společně se shlukem, ale nejsou uvnitř kruhové oblasti určené definovaným poloměrem. Za účelem odstranění tohoto omezení byl definován vzor *konvoj* (anglicky *convoy*) [27], při jehož hledání je využito shlukování na základě hustoty.

U vzorů stádo a konvoj lze identifikovat společnou nevýhodu danou časovým omezením na tyto vzory, kdy v definicích těchto vzorů jsou uvažovány pouze po sobě jdoucí časové okamžiky. Příkladem tohoto omezení může být ztráta skupiny objektů, z nichž některý objekt dočasně opustí pohybující se shluk. V [40] byl navržen vzor nazvaný *roj* (anglicky *swarm*), který zmíněnou nevýhodu odstraňuje. Vzoru typu roj pak reprezentuje shluk objektů, které se pohybují společně alespoň po určitý počet časových okamžiků, nikoliv však nutně po sobě jdoucích.

Dolování frekventovaných pohybů

Účelem dolování frekventovaných pohybů je nalezení takových trajektorií (nebo sub-trajektorií), které jsou pohybujícími se objekty často sledovány. Takové vzory pak reprezentují obecné trendy pohybu objektů vzhledem k prostoru i k času.

Dolováním frekventovaných vzorů z trajektorií se zabývá například [14]. Zavádí nový typ vzoru, tzv. *T-vzor* (v angličtině *T-pattern*, *Trajectory pattern*), který sjednocuje časovou i prostorovou informaci bez předchozí diskretizace časové či prostorové dimenze. T-vzor je dvojice (S, A) taková, že $S = \langle (x_0, y_0), \dots, (x_k, y_k) \rangle$ je sekvence pozic v prostoru a $A = \langle \alpha_1, \dots, \alpha_k \rangle$ je sekvence časů přechodů mezi prostorovými pozicemi. T-vzor je pak možné reprezentovat jako $(S, A) = (x_0, y_0) \xrightarrow{\alpha_1} (x_1, y_1) \xrightarrow{\alpha_2} \dots \xrightarrow{\alpha_k} (x_k, y_k)$.

Čas přechodu mezi dvěma pozicemi vyjadřuje dobu přesunu pohybujícího se objektu z jedné prostorové pozice do druhé. T-vzor obsahující n prostorových pozic reprezentuje ve vstupní databázi trajektorií všechny sub-trajektorie

s n prostorovými pozicemi takové, že každá pozice sub-trajektorie je přibližně stejná jako odpovídající pozice ve vzoru a všechny časy přechodů mezi pozicemi sub-trajektorie jsou přibližně stejné jako odpovídající časy přechodů ve vzoru. Kromě parametru minimální podpory vzoru je pro dolování frekventovaných T-vzorů nutné určit hodnotu časové tolerance a funkci prostorové sousednosti.

Dolování periodických vzorů

V mnoha případech objekty v pravidelných časových intervalech sledují stejné trasy. Detekce periodického chování pohybujících se objektů může být užitečná například pro sumarizaci historie pohybu, pro predikci budoucího pohybu nebo může pomoci při detekci neobvyklých událostí [21].

Hledáním periodických vzorů se zabývá například [44]. Trajektorie je zde uvažována jako sekvence prostorových pozic. Dolování periodických vzorů zde probíhá pro pevně danou hodnotu periody T . Periodický vzor P je pak sekvence délky T , která se v průběhu analyzované trajektorie vyskytuje alespoň *minsup* krát, kde *minsup* je uživatelsky definovaná hodnota minimální podpory. Dolování periodických vzorů probíhá ve dvou krocích. V prvním kroku jsou s pomocí shlukovacího algoritmu DBSCAN vyhledány všechny frekventované vzory délky 1. Ve druhém kroku pak probíhá postupné hledání delších vzorů. Pro tento krok jsou navrženy dva možné přístupy: zdola-nahoru nebo shora-dolů.

Hlavní nevýhodou popsaného přístupu je nutnost pevně definovat délku periody. Toto omezení odstraňuje algoritmus *Periodica* navržený v [39]. Jedná se o dvofázový algoritmus, který analýzou vstupních dat nejprve automaticky detekuje vhodné periody a ve druhé fázi pak statisticky sumarizuje periodické chování objektů. Detekce délky periody je prováděna kombinací Fourierovy transformace a autokorelace nad všemi referenčními body, které odpovídají často navštěvovaným oblastem, jež jsou identifikovány pomocí přístupu založeného na hustotě. Sumarizace periodického chování ve druhé fázi je pak prováděna metodou založenou na hierarchickém shlukování.

2.2 Shlukování trajektorií

Požadavkem na shlukování trajektorií pohybujících se objektů může být vyhledání skupin objektů pohybujících se společně nebo vyhledání společných sub-trajektorií, které mohou reprezentovat nějakou významnou oblast.


Hledání shluků objektů, které se pohybují společně, se liší podle toho, zda je společný pohyb objektů požadován po celý časový úsek průběhu trajektorií, nebo pouze po jeho část. V případě částečného časového úseku zde shlukování splývá s hledáním pohybujících se shluků nebo vzorů typu stádo, konvoj či roj, které byly popsány v sekci 2.1. Pro shlukování trajektorií jako celku je možné využít metody pro shlukování vysoce dimenzionálních dat, metody založené na pravděpodobnostních modelech nebo metody založené na hustotě.

Při použití některé metody shlukování vysoce dimenzionálních dat je každý časový okamžik trajektorie uvažován jako samostatná dimenze. Při shlukování

lze pak použít různé vzdálenostní funkce, například Euklidovskou vzdálenost, některé varianty editační vzdálenosti a podobně [21].

Metoda pro shlukování trajektorií na základě hustoty byla navržena například v [52]. Autoři zde definují vzdálenost mezi trajektoriemi jako průměrnou vzdálenost mezi objekty ve všech časových okamžicích. Trajektorie je tedy uvažována jako celek. Pro samotné shlukování je použita modifikace algoritmu OPTICS [19]. Tato modifikace vychází z předpokladu, že v reálném prostředí mají některé časové intervaly vyšší důležitost než jiné (například dopravní špička a podobně) a shlukování trajektorií pouze ve významných časových intervalech může přinést zajímavější výsledky.

Jsou-li při shlukování trajektorie uvažovány jako celek, není možné objevit pouze podobné části trajektorií a může tak dojít ke ztrátě potenciálně zajímavého výsledku. Tento případ ilustruje obrázek 2, na kterém je vyznačena sub-trajektorie společná všem zobrazeným trajektoriím. Tato sub-trajektorie by při reprezentaci trajektorie jako celku nemohla být objevena, protože každá z trajektorií se dále ubírá jiným směrem.



Obrázek 2: Příklad společné sub-trajektorie (převzato z [35]).

Pro objevování společných sub-trajektorií byl v [35] navržen „*partition-and-group*“ rámec a algoritmus *TRACCLUS* na něm založený. Algoritmus *TRACCLUS* probíhá ve dvou fázích. V první fázi dochází k dělení jednotlivých trajektorií na sub-trajektorie, druhou fází je pak samotné shlukování sub-trajektorií následované vygenerováním reprezentativních trajektorií pro každý nalezený shluk. Shlukování je zde prováděno metodou založenou na hustotě, která vychází z algoritmu *DBSCAN*. Použitá vzdálenostní funkce se skládá ze tří složek: kolmé, paralelní a úhlové vzdálenosti. Fáze dělení trajektorií na sub-trajektorie je založena na identifikaci charakteristických bodů, což jsou body, ve kterých se výrazně mění chování trajektorie. Pro tento účel je využito principu *MDL* (*minimum description length*) z oblasti teorie informace. Při dělení se tak dosahuje vhodného kompromisu mezi stručností a přesností.

Metoda shlukování trajektorií nazvaná *Vector Field k-means* je navržena v [11]. Tato metoda je založená na vektorových polích, které jsou použity pro modelování jednotlivých shluků. Vektorová pole, což jsou funkce přiřazující každému bodu prostoru vektor, zde umožňují přirozeným způsobem reprezentovat rysy trajektorií, jako jsou směr a rychlost pohybu. Cílem shlukování je najít vektorová pole, která co nejlépe aproximují vstupní datovou sadu trajektorií. Výhodou tohoto přístupu je i jednoduchá vizualizace nalezených shluků.

Samotné shlukování využívá princip algoritmu k -means [19], čímž přebírá jeho výhody i nevýhody.


2.3 Predikce trajektorií

Přístupy k predikci budoucí pozice trajektorie pohybujícího se objektu lze rozdělit následovně [21]:

- (a) predikce založená na historii vlastního pohybu,
- (b) predikce založená na historii pohybu všech objektů.

Metody pro predikci budoucí pozice na základě historie vlastního pohybu lze dále dělit na lineární nebo nelineární a vektorové (pro krátkodobé predikce) nebo založené na vzorech (pro dlouhodobější predikce). Lineární predikce není z praktického hlediska příliš použitelná, viz obrázek 3, který znázorňuje její selhání.

Příkladem nelineární vektorové metody pro krátkodobé predikce je *rekurzivní pohybová funkce* [63]. Pozice trajektorie pohybujícího se objektu o v čase t je dána jako $o(t) = \mathbf{C}_1 \cdot o(t-1) + \mathbf{C}_2 \cdot o(t-2) + \dots + \mathbf{C}_f \cdot o(t-f)$, kde \mathbf{C}_i jsou konstantní matice vyjadřující určité typy pohybů a f je parametr udávající úroveň retrospekce.



Obrázek 3: Příklad selhání lineární predikce budoucí pozice (převzato z [63]).

V [26] je uveden model *hybridní predikce*, který za účelem umožnění krátkodobých i dlouhodobých predikcí kombinuje vektorový přístup a přístup založený na vzorech.

Zástupcem metod pro predikci na základě historie pohybu všech objektů je metoda navržená v [45]. Tato metoda vychází z předpokladu, že sleduje-li mnoho objektů stejný vzor pohybu, je pravděpodobné, že daný objekt se bude pohybovat podle tohoto vzoru také. Využity jsou zde T-vzory popsané v sekci 2.1.

2.4 Klasifikace trajektorií

Cílem klasifikace trajektorií je zařadit pohybující se objekty do příslušných tříd na základě jejich trajektorií a případně dalších rysů [21]. Pro klasifikaci trajektorií se používají dva základní přístupy. První možností je využití technik strojového učení a rozpoznávání vzorů, například skrytých Markovských modelů (HMM). Druhou možností je pak klasifikace na základě samotných trajektorií, přičemž tuto skupinu reprezentuje algoritmus TraClass.

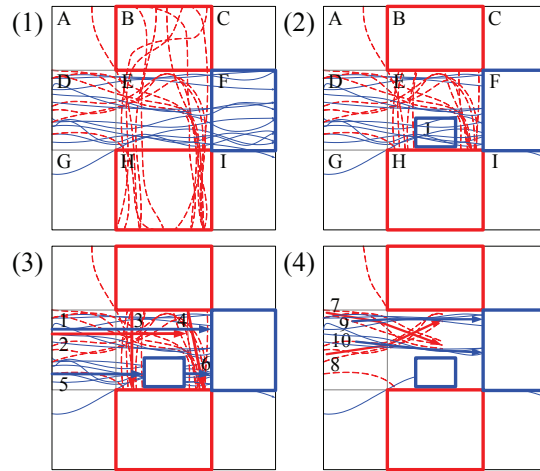
Srovnáním různých technik strojového učení při použití pro klasifikaci trajektorií se věnuje [60]. Byly zde použity metody k -nejbližší sousedství, GMM (Gaussian Mixture Model) s EM (Expectation-Maximization), SVM (Support Vector Machines) a HMM (Hidden Markov Models). Pro popis těchto metod viz [6] nebo [19]. Pro HMM byly jednotlivé trajektorie reprezentovány jako sekvence okamžitých rychlostí, pro ostatní techniky byla každá trajektorie reprezentována pouze průměrnou a minimální rychlostí. Srovnání uvedených metod bylo provedeno na dvou datových sadách.

Klasifikace trajektorií vozidel byla cílem v [12]. Jednotlivé trajektorie byly rozděleny do překrývajících se segmentů, v rámci kterých byla trajektorie vždy vyhlazena a přiřazena do jedné ze čtyř kategorií (*vpřed, vlevo, vpravo, stát*). Takto vzniklé řetězce symbolů byly následně klasifikovány pomocí HMM.

Jiný způsob využití HMM pro klasifikaci trajektorií byl navržen v [4]. Trajektorie jsou nejprve rozděleny v bodech změn zakřivení. Každá sub-trajektorie je pak reprezentována koeficienty analýzy hlavních komponent (Principal Component Analysis, PCA). Koeficienty PCA jsou reprezentovány pomocí GMM pro každou třídu. Pro každou třídu je následně vytvořen HMM, jehož každý stav odpovídá sub-trajektorii modelované pomocí GMM.

Nevýhodou popsaných metod může v některých případech být klasifikace trajektorie jako celku. Toto omezení se snaží odstranit již zmíněný algoritmus *TraClass* [34], který vychází z předpokladu, že charakteristické rysy pohybu se vyskytují spíše u částí trajektorií, nikoliv u trajektorií celých. Kromě toho předpokládá, že charakteristické rysy trajektorie nemusí být vyjádřeny jen vzory pohybu, ale mohou být určeny také oblastmi, jimiž trajektorie prochází. Algoritmus TraClass je založen na extrakci rysů nejprve pomocí shlukování podle regionů, následně pak pomocí shlukování podle trajektorií. Trajektorie jsou nejprve rozděleny na sub-trajektorie využitím stejného principu jako u algoritmu TRACCLUS, který je popsán v sekci 2.2, se zahrnutím informace o příslušnosti trajektorií k odpovídajícím třídám. Cílem shlukování podle regionů je najít takové oblasti, kterými procházejí většinou pouze trajektorie jedné určité třídy. Pro tento účel je zde využito MDL principu, který byl zmíněn již v sekci 2.2. Příklad shlukování podle regionů ilustrují kroky (1) a (2) na obrázku 4. Cílem shlukování podle trajektorií je identifikovat společné vzory pohybu, které odpovídají pouze trajektoriím jedné konkrétní třídy. Tohoto cíle je dosaženo pomocí algoritmu TRACCLUS, který je rozšířen o uvažování informace o příslušnosti trajektorie k některé třídě. Příklad shlukování podle trajektorií znázorňují kroky (3) a (4) na obrázku 4.

Při klasifikaci pomocí algoritmu TraClass je každá trajektorie nejprve trans-



Obrázek 4: Příklad shlukování podle regionů (kroky 1 a 2) a podle trajektorií (kroky 3 a 4) (převzato z [34]).

formována na vektor rysů, přičemž každý rys odpovídá buď regionu, nebo vzoru pohybu. Vzniklý vektor rysů je pak zpracován SVM klasifikátorem.

2.5 Detekce odlehlých trajektorií

Automatická detekce neobvyklého nebo podezřelého chování pohybujících se objektů je významnou úlohou v oblasti analýzy časoprostorových dat. Obvykle se jedná o hledání *odlehlých trajektorií*, tedy takových pohybů, které se výrazně odlišují od většiny ostatních.


Mezi hlavní přístupy pro detekci odlehlých trajektorií patří metody založené na vzdálenosti a metody založené na klasifikaci. Další možný přístup pak zastupuje algoritmus TOP-EYE, který je založen na výpočtu vyvíjející se míry odlehlosti trajektorie nad vytvořeným pravděpodobnostním modelem sledované oblasti. Popisu těchto tří přístupů se věnuje zbytek této sekce.

Kromě zmíněných přístupů lze narazit i na některé další přístupy k dolování odlehlých trajektorií, jež jsou většinou přizpůsobeny konkrétní aplikační oblasti. Například [10] se zaměřuje na efektivní monitorování anomálií v proudu trajektorií pohybujících se objektů. V [38] je navržena metoda pro detekci časově odlehlých objektů v datech dopravního provozu s důrazem na historický trend podobnosti. Pro každý časový okamžik je pro každý segment silniční sítě určena jeho podobnost s ostatními segmenty a zaznamenána v jeho časovém vektoru podobnosti. Odlehlé objekty jsou pak detekovány na základě výrazných změn v těchto vektorech.

Metody založené na vzdálenosti

Koncept objektů odlehlých na základě vzdálenosti byl uveden v [31]. Objekt O v datové sadě T je $DB(p, D)$ -odlehlý (*distance-based*), jestliže alespoň množství p objektů z T leží ve větší vzdálenosti než D od objektu O . Jednou z uvedených případových studií je právě detekce odlehlých trajektorií. Trajektorie je zde reprezentovaná jako celek v podobě vektoru sumárních charakteristik.

Uvažování trajektorie jako jeden celek v podobě nějaké sumární charakteristiky však nedokáže odhalit neobvyklé chování objektu jen v některé části jeho trajektorie, obzvláště jsou-li trajektorie příliš dlouhé [33]. Z tohoto důvodu je na metody detekce odlehlých trajektorií kladen požadavek, aby uvažovaly každou trajektorii například jako množinu sub-trajektorií. Tímto přístupem lze identifikovat ty části trajektorie, které její odlehlost způsobují. Příklad odlehlé sub-trajektorie je ukázán na obrázku 5.



Obrázek 5: Příklad odlehlé sub-trajektorie (převzato z [33]).

Hlavní rozdíl mezi jednotlivými metodami z této oblasti spočívá v použité vzdálenostní funkci. Například v [42] jsou jednotlivé sub-trajektorie porovnávány pomocí vzdálenostní funkce, která vychází z Hausdorffovy vzdálenosti.

Za účelem detekce odlehlých shluků trajektorií, které mohou reprezentovat například dopravní zácpu, je v [70] navržen algoritmus slučující přístup založený na vzdálenosti se shlukováním. Algoritmus uvažuje trajektorie jako množinu sub-trajektorií. Každá sub-trajektorie je reprezentována pomocí minimálního obalujícího kvádrů (v angličtině *Minimum Bounding Box*, *MBB*), jehož dva rozměry jsou dány prostorovými souřadnicemi a třetí rozměr je určen časovou informací. Vzdálenost dvou trajektorií je pak počítána z objemu průniku jejich MBB. Nad trajektoriemi je následně provedeno shlukování modifikací metody DBSCAN. Pro každý shluk je vypočten stupeň jeho hustoty, který odlišuje normální shluky od odlehlých.

Významným zástupcem metod založených na vzdálenosti je „*partition-and-detect*“ rámec a algoritmus *TRAOD* na něm založený [33]. Algoritmus sestává ze dvou fází. V první fázi je každá trajektorie rozdělena na množinu sub-trajektorií. Za účelem zajištění efektivity a kvality zároveň je dělení prováděno ve dvou krocích: nejprve hrubým způsobem a následně je pak dělení patřičně zjemněno. Dělení podle jemné granularity probíhá jen tehdy, může-li být daný úsek ve výsledku identifikován jako odlehlý. Ve druhé fázi algoritmu probíhá vlastní proces detekce odlehlých trajektorií kombinací přístupů založených na vzdálenosti a na hustotě. Trajektorie je považována za odlehlou, pokud obsahuje alespoň určitý počet odlehlých sub-trajektorií. Sub-trajektorie je odlehlá, pokud je blízká

jen s určitým maximálním počtem trajektorií. Množina trajektorií, které jsou blízké ke konkrétní sub-trajektorii, je určena pomocí vzdálenostní funkce, která se skládá ze tří složek: kolmé, paralelní a úhlové vzdálenosti. Za účelem omezení vlivu hustoty oblasti na posuzování odlehlosti sub-trajektorie je zaveden tzv. upravující koeficient, kterým je násoben zjištěný počet blízkých trajektorií.


Metody založené na klasifikaci

Metody založené na klasifikaci jsou zástupcem metod učení s učitelem, kdy detekce odlehlých trajektorií probíhá podle modelu vstupních dat, který musí být vytvořen na základě trénovací datové sady. Nevýhodou těchto metod může být silná závislost výsledků na kvalitě trénovací množiny. Výhodou je oproti metodám učení bez učitele časová efektivita procesu detekce.

V [53] je pro detekci odlehlých trajektorií využito principu neuronových sítí. Trénování probíhá nad celými trajektoriemi, které jsou transformované na vektory rysů, které mají za úkol reprezentovat nejen prostorové pozice, ale i rychlost a zrychlení pohybu.

Přístup kombinující shlukování a klasifikaci pomocí SVM klasifikátoru za účelem nalezení odlehlých trajektorií je navržen v [58].

Metoda *ROAM*, navržená v [36], zastupuje ucelený rámec, jenž je určený pro detekci anomálií v datech pohybujících se objektů. Celý proces prochází postupně třemi moduly. Nejprve jsou ze vstupních trajektorií kombinací metody klouzavého okna a shlukování extrahovány společné vzory, tzv. *motify*. Každý motif reprezentuje nějaký typický vzor pohybu, například odbočení doprava, otočení a podobně. Každá trajektorie je pak reprezentována jako sekvence výskytů různých motifů. Příklad dvou trajektorií po extrakci motifů je zobrazen na obrázku 6. Trajektorie v pravé části obrázku má oproti levé trajektorii navíc výskyt motifu m_1 . Ve druhé fázi je každému výskytu motifu přiřazena množina odpovídajících atributů, kterými jsou pozice a čas výskytu, případně některé další jako rychlost pohybu a podobně. Množina všech motifů tvoří hierarchický prostor rysů. Trajektorie se tak stává vektorem rysů v tomto novém prostoru. Takto transformované trajektorie jsou klasifikovány pomocí klasifikátoru založeného na pravidlech, který pracuje nad vytvořeným hierarchickým prostorem rysů.



Obrázek 6: Příklad dvou trajektorií po extrakci motifů (převzato z [36]).

Přístup založený na vyvíjející se míře odlehlosti

Pro detekci odlehlých trajektorií již v průběhu jejich vývoje je v [13] navržena metoda nazvaná *TOP-EYE*. Tato metoda umožňuje, při vhodně nastavených vstupních parametrech, identifikovat odlehlé trajektorie v reálném čase a varovat se velkého množství planých poplachů, které mohou být způsobeny například šumem ve vstupních datech.


Algoritmus uvažuje sledovaný prostor jako pravidelnou mřížku malých buněk. Každá buňka je dále členěna do 8 směrových výsečí, kde každá výseč odpovídá úhlu $\pi/4$. Cílem tohoto dělení je sumarizovat směrovou informaci trajektorií procházejících konkrétní buňkou jako vektor osmi hodnot, které vyjadřují pravděpodobnosti pohybu objektu v osmi různých směrech. Tato metoda vyžaduje trénovací datovou množinu, na jejímž základě je vypočtena hustota jednotlivých buněk. Analýzou každé trajektorie z této datové množiny jsou navýšeny odpovídající hodnoty směrového vektoru u buněk, kterými daná trajektorie prochází.

Pro každou novou trajektorii pak algoritmus průběžně počítá *okamžitou míru odlehlosti*. Míru odlehlosti je možné sledovat podle směru trajektorie nebo podle hustoty buněk. Hlavní myšlenkou algoritmu TOP-EYE je postupně v čase akumulovat okamžité míry odlehlosti s tím, že vliv předchozích měr odlehlosti je snižován prostřednictvím exponenciální funkce v závislosti na čase. Tímto způsobem je možné pozorovat postupný vývoj míry odlehlosti trajektorie v průběhu pohybu objektu. Při vhodně nastaveném parametru, který určuje hranici mezi odlehlými a normálními trajektoriemi, je tato míra odlehlosti odolná vůči planým poplachům. Jako hlavní nevýhodu této metody lze považovat, že sledovaná oblast je uvažována jako pravidelná mřížka.

2.6 Sémantické trajektorie

Většina prací zabývajících se aplikací metod dolování z dat na trajektorie pohybujících se objektů se zaměřuje zejména na časoprostorové geometrické rysy trajektorií. Tyto metody však vedou většinou na získávání geometrických vzorů, které nemusí odhalit některé vztahy zajímavé z pohledu konkrétní aplikační domény. Některé analytické dotazy týkající se chování pohybujících se objektů je možné zodpovědět pouze při uvažování trajektorií včetně jejich sémantiky [2].

Sémantické rysy trajektorie jsou, na rozdíl od rysů geometrických, aplikačně závislé, mohou být nezávislé na prostorových souřadnicích a mohou se vyskytovat v řídkých oblastech bez geometrických podobností s ostatními trajektoriemi [8]. Sémantické rysy typicky odkazují na geografické či doménově specifické informace. *Sémantické vzory* jsou z uživatelského pohledu ve srovnání s geometrickými vzory více pochopitelné a lépe interpretovatelné, a to právě díky uvažování konceptů z aplikační domény. Sémantika tak může hrát důležitou roli při analýze trajektorií a získávání znalostí z nich [1]. Na obrázku 7 je znázorněn příklad trajektorie před a po přidání sémantické informace pro účely dvou různých aplikací. Sémantická trajektorie v těchto případech propojuje časoprostorovou reprezentaci trajektorie se sémantickou geografickou informací.



Obrázek 7: Příklad časoprostorové trajektorie (1) a odpovídající sémantické trajektorie pro turisticky zaměřenou aplikaci (2) a pro dopravní aplikaci (3) (převzato z [46]).

Sémantické trajektorie jsou založeny na konceptu *zastavení* (anglicky *stop*) a *pohybů* (anglicky *move*), který byl poprvé představen v [62]. Zastavení reprezentují důležitá místa trajektorie, kde objekt zůstal po určité minimální dobu. Pohyby jsou pak části trajektorie ohraničené jednotlivými po sobě následujícími zastaveními. Zastavení odpovídají zajímavým místům v prostoru (také nazývaným prostorové rysy), která jsou určena konkrétní aplikací. *Sémantická trajektorie* pak může být definována jako konečná posloupnost položek $\langle I_1, I_2, \dots, I_n \rangle$, kde každá položka I_m je zastavení nebo pohyb [7]. Tento model byl dále využit pro sémantické obohacení trajektorií geografickými či aplikačně specifickými informacemi, například v [1], [15] nebo [66]

2.6.1 Metody pro sémantické obohacení trajektorií

Pro obohacení trajektorie o sémantické informace je nutné strukturovat trajektorii na posloupnost zastavení a pohybů. Klíčovým problémem je zde rozhodnutí, zda konkrétní časoprostorový bod trajektorie patří do zastavení nebo do pohybu trajektorie.

Pro účely identifikace zastavení trajektorie, tedy významných míst trajektorie z pohledu konkrétní aplikační domény, je možné zvolit různé přístupy. Jedním z nich je například DJ-Cluster [73], který je variantou shlukovacího algoritmu DBSCAN a jehož cílem je najít zajímavá místa jednotlivých trajektorií. Hlavní nevýhodou této metody je, že neuvažuje časovou dimenzi.

Různé algoritmy byly navrženy přímo pro nalezení zastavení a pohybů trajektorií. Ve zbytku této sekce budou tyto metody postupně stručně popsány.

IB-SMoT [1]

Vstupem tohoto algoritmu je množina trajektorií a konkrétní aplikace sestávající z množiny kandidátních zastavení. Kandidátní zastavení je dvojice (R, Δ) , kde R

je geometrie zastavení definovaná pomocí polygonu ve dvourozměrném prostoru a Δ je minimální doba zastavení. Výstupem algoritmu je množina zastavení a množina pohybů.

Algoritmus IB-SMoT (*Intersection-Based Stops and Moves of Trajectories*) pro každý bod trajektorie s využitím prostorového indexu ověřuje, zda bod leží uvnitř geometrie nějakého kandidátního zastavení. Pokud tomu tak je, dojde k ověření, zda doba, po kterou trajektorie danou geometrii protíná, je alespoň stejně dlouhá jako minimální doba setrvání v daném kandidátním zastavení. V kladném případě je kandidátní zastavení považováno jako zastavení a je zaznamenáno. Úsek trajektorie mezi předchozím a aktuálním zastavením je zaznamenán jako pohyb. Předchozí zastavení může být prázdné, pokud je aktuální zastavení prvním zastavením dané trajektorie. Pro případné budoucí prostorové analýzy pohybů je spolu s pohybem zaznamenávána i jeho geometrie a časové razítko.

CB-SMoT [54]

Nevýhodou algoritmu IB-SMoT může být, že některá důležitá zastavení, která mohou vést například k objevení zajímavých vzorů, nemusí být nalezena, pokud jim neodpovídá žádné kandidátní zastavení konkrétní aplikace. Příkladem je třetí trajektorie na obrázku 7. Trajektorie obsahuje dvě husté části (označené jako neznámá zastavení), kterým ale v dané aplikaci neodpovídá žádné kandidátní zastavení.

Algoritmus CB-SMoT (*Clustering-Based Stops and Moves of Trajectories*) je založen na shlukování jednotlivých trajektorií podle změn rychlosti pohybu a snaží se tak odhalit i neznámá zastavení. Tento algoritmus vychází z myšlenky, že části trajektorie, v nichž je rychlost pohybu výrazně nižší než v jiných částech stejné trajektorie, odpovídají zajímavým místům. Algoritmus pracuje ve dvou krocích. V prvním kroku jsou pomocí modifikace algoritmu DBSCAN, který shlukuje na základě hustoty, identifikována potenciální zastavení. Shlukování probíhá vždy pouze v rámci jedné trajektorie na základě změn rychlosti pohybu. Ve druhém kroku algoritmus určí prostorové umístění potenciálních zastavení (shluků) a ověří průsečíky a minimální dobu trvání s kandidátními zastaveními aplikace. Pokud potenciální zastavení neprotíná geometrii žádného kandidátního zastavení, je označeno jako neznámé zastavení.

DB-SMoT [59]

V některých aplikacích může být žádoucí identifikovat zajímavá místa trajektorie na základě změn směru pohybu. Pro tento účel může být použit algoritmus DB-SMoT (*Direction-Based Stops and Moves of Trajectories*). Vstupem algoritmu je množina trajektorií, minimální změna směru, minimální doba trvání a maximální tolerance.

Algoritmus nejprve pro každé dva po sobě jdoucí body trajektorie vypočítá změnu směru. Následně je v rámci trajektorie provedeno shlukování, přičemž nalezené shluky odpovídají zastavením trajektorie. Části trajektorie, které leží

mimo nalezené shluky, jsou označeny jako pohyby trajektorie. Při shlukování probíhá postupné ověřování, zda změna směru mezi dvěma následujícími body trajektorie je alespoň stejně velká jako hodnota minimální změny směru. Dokud tomu tak je, jsou body přidávány do stejného shluku. Jakmile změna směru nevyhovuje podmínce minimální změny směru, je vzhledem k maximální toleranci ověřeno, zda tato nedostatečná změna směru není způsobena náhodně, například šumem. Pokud tomu tak není, je aktuální shluk uzavřen a je ověřeno, zda vyhovuje omezení na minimální dobu trvání zastavení. Pokud daný shluk splňuje všechna omezení, je označen jako zastavení.

Další metody

V [66] a [68] jsou pro identifikaci zastavení a pohybů trajektorie popsány algoritmy založené na rychlosti, na hustotě a na analýze časové řady.

Hlavní myšlenkou algoritmu založeného na rychlosti je určovat zastavení a pohyby podle prahové hodnoty rychlosti Δ_{speed} . Jestliže je okamžitá rychlost pohybu nižší než Δ_{speed} , je daný bod považován za součást zastavení, v opačném případě patří do pohybu. Kromě toho je u každého zastavení kontrolováno, zda jeho doba trvání je alespoň stejně velká jako hodnota minimální doby trvání zastavení za účelem vyhnout se náhodnému snížení rychlosti, které může být způsobeno například krátkodobou dopravní zácpou a podobně. Problémem této metody může být určení správné hodnoty Δ_{speed} , která by měla být definována spíše dynamicky vzhledem ke konkrétní aplikaci, například na základě průměrné rychlosti pohybujícího se objektu, průměrné rychlosti pohybu v daném místě a podobně.

Algoritmus založený na hustotě kromě rychlosti pohybu uvažuje také maximální vzdálenost, kterou může pohybující se objekt urazit během určité doby.

Algoritmus založený na analýze časové řady vychází z [67], kde je představen přístup pro modelování síťově omezených trajektorií za pomoci časových řad. Navržený model může být následně využit pro predikci rychlosti pohybu a lze ho tak využít pro identifikaci zastavení trajektorie. Jestliže se predikovaná rychlost výrazně liší od rychlosti skutečné, může se jednat o zastavení.


3 Dolování v trajektoriích extrahovaných z videa

Dohledové kamerové systémy jsou v současné době široce používány v různých prostředích a pro různé účely jako je monitorování dopravy, sledování parkovišť, národní bezpečnost, prevence kriminality a další. Takové systémy neustále porizují velké množství video dat, která je potřeba efektivně zpracovávat a analyzovat. Manuální monitorování prostřednictvím lidských operátorů se kvůli velkému objemu video dat stává nezvládnutelné, únavné a nespolehlivé. Toto se projevuje zejména v případě multikamerových systémů, obzvláště pokud více kamer sdílí jeden monitor. Proces monitorování a analýzy video dat tak vyžaduje

automatizovanou podporu využívající metody počítačového vidění, strojového učení a dolování z dat.

Myšlenkou celého procesu automatické analýzy video dat z dohledových kamer je pochopení chování pohybujících se objektů. Tento cíl vyžaduje extrakci významných informací v podobě časoprostorových a vizuálních rysů objektů, jejich vhodnou reprezentaci a interpretaci za účelem naučení se obvyklému chování objektů a rozpoznávání jejich aktivit. Dosažení tohoto cíle však nemusí být přímočaré a z mnoha důvodů se stává náročným úkolem, který je výzvou pro současný výzkum v této oblasti. Dohledové systémy obvykle mají složitou strukturu a mohou monitorovat velkou škálu různých prostředí, z nichž vyvstávají různá omezení a velké množství různých aktivit [50, 56].

Chování pohybujícího se objektu se ve velké míře projevuje na trajektorii jeho pohybu. Pohyb objektu však může být popsán na různých úrovních abstrakce. Na nejnižší úrovni se jedná o trajektorii v podobě sekvence časoprostorových pozic, která je výstupem procesu sledování objektů. Tímto způsobem je pohyb popsán pomocí *nízkoúrovňových rysů*. Pro popis pohybu objektu pomocí *rysů na vyšší úrovni abstrakce* jako jsou konkrétní události, aktivity nebo chování je většinou potřeba využít i určitých doménových znalostí a jejich manuální specifikace. Častým požadavkem na analýzu chování pohybujících se objektů je však automatické vytvoření modelu sledované oblasti (*scény*), což vyžaduje využití metod strojového učení bez učitele [51]. Proto se nelze spoléhat na doménově specifické znalosti a využít spíše popisu pohybu formou časoprostorových trajektorií, jež jsou výstupem sledování objektů. Tento přístup je podpořen i faktem, že typické pohybové vzory se často opakují, zatímco mnoho zajímavých aktivit se vyskytuje spíše zřídka [50]. Na základě rozsáhlé sady trajektorií, v níž tedy převažují opakující se pohyby, jsme schopni automaticky sestavit model chování a aktivit objektů ve scéně a tento model následně využít v procesu analýzy aktivit. Celý tento proces je znázorněn na obrázku 8. Každý objekt ve videu je nejprve detekován (blok *Object Detection*) a sledován (blok *Tracking*). Výstupem jsou trajektorie, které mohou být využity pro modelování scény (blok *Scene Modeling*) a pro analýzu aktivit (blok *Activity Analysis*). Výstupem analýzy aktivit objektů je pak anotované video.



Obrázek 8: Blokový diagram procesu analýzy aktivit pohybujících se objektů ve videu (převzato z [50]).

Základem modelu scény nejčastěji bývá topologický popis zajímavých nebo význačných míst ve scéně a cest, které objekty používají k pohybu mezi jednotlivými význačnými místy. Učení modelu scény je v takovém případě zaměřeno na identifikaci a popis význačných míst a cest mezi nimi. Výsledný model pak popisuje rutinní chování objektů pohybujících se sledovanou oblastí. Snaží se modelovat sémantiku pohybu ve scéně a poskytnout tak podporu pro pochopení a analýzu chování objektů na vyšší úrovni abstrakce [43]. Slouží jako spojovací vrstva mezi dvěma úrovněmi zpracování a analýzy video dat, která sbírá a organizuje nízkourovňová data o pohybu objektů do abstraktnější reprezentace, jež umožňuje analýzu aktivit na vyšší úrovni abstrakce [56]. Model pak umožňuje například klasifikaci a rozpoznávání pohybových aktivit, predikci budoucích aktivit a detekci abnormálních nebo podezřelých aktivit objektů.

Jedním z důležitých požadavků na vytvářený model přitom je, aby umožňoval také efektivní online provádění jednotlivých analytických úloh. Mezi další požadavky na modelování pohybu objektů patří odolnost vůči nekvalitnímu výstupu sledování objektů, schopnost průběžně se přizpůsobovat měnícím se podmínkám prostředí, vhodná volba reprezentace trajektorií a vhodný způsob jejich vzájemného porovnávání [50].

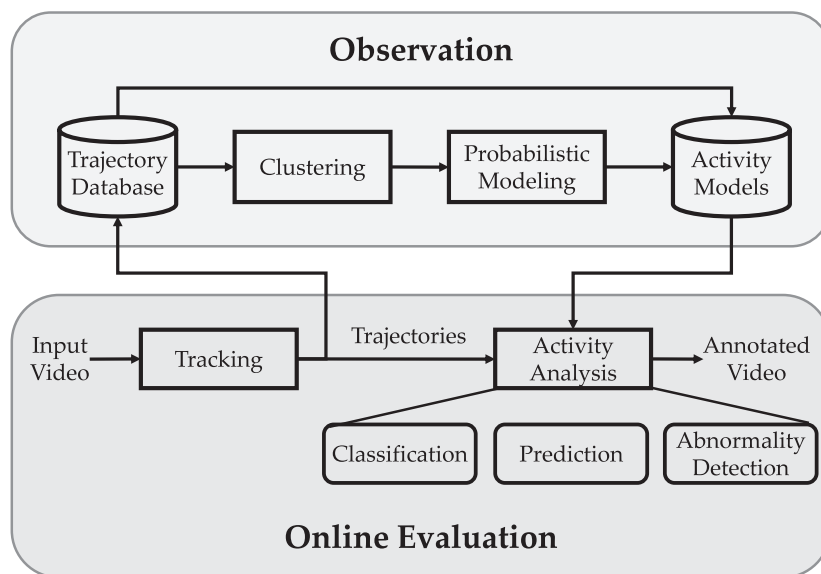
Takto popsaný model je vytvořen pouze na základě pohybu objektů, což umožňuje jeho obecné použití v různých monitorovaných prostředích. V některých případech však nemusí být takový popis dostatečný pro rozlišení všech aktivit specifických pro konkrétní aplikační doménu, a proto může být žádoucí proces analýzy aktivit rozšířit o uvažování dalších, například vizuálních rysů pohybujících se objektů.

Tato kapitola je zaměřena na popis existujících metod pro modelování chování objektů na základě trajektorií extrahovaných z dohledového videa bez nutnosti doménově specifických znalostí daných konkrétní aplikací. Obecný rámec pro analýzu trajektorií objektů ve videu, na jehož základě je tato kapitola dále strukturována, je ilustrován na obrázku 9.

3.1 Modelování sledované oblasti

Sémantický model sledované oblasti, neboli scény, reprezentující prostorové uspořádání scény byl představen v [43]. Tento model se snaží popsat aktivity pohybujících se objektů vzhledem k prostorovým rysům scény (například vchod či východ, různé překážky a podobně). Důležitou vlastností tohoto modelu je jeho pravděpodobnostní charakter, což může do jisté míry odstraňovat chyby vznikající při sledování objektů a neurčitost způsobenou vzorkováním pohybu a zároveň je tak vytvořen pravděpodobnostní rámec pro analýzu aktivit a chování objektů.

Model scény zjednodušeně sestává z *význačných míst* scény, které odpovídají prostorovým lokacím spojeným s nějakými zajímavými událostmi a z *cest objektů*, které charakterizují pohyb objektů mezi těmito význačnými místy. Scéna je pak reprezentována na dvou úrovních, a to v podobě topografické mapy a topologického grafu [43]. Topografická mapa popisuje jednotlivé prvky scény z hlediska jejich prostorových vlastností. Topologická reprezentace ukazuje scénu



Obrázek 9: Obecný rámec pro analýzu trajektorií objektů ve videu (převzato z [51]).

v podobě grafu, jehož uzly odpovídají význačným místům a hrany odpovídají cestám objektů. Topografická reprezentace tak odráží prostorovou povahu modelu, zatímco topologická reprezentace určitým způsobem zachycuje pravděpodobnostní povahu pohybu objektů ve scéně.

3.1.1 Sledování objektů

Cílem procesu sledování objektů (anglicky *object tracking*) je extrahovat z videa data popisující pohyb objektů ve sledované oblasti. Výstup sledování objektů je obvykle tvořen trajektoriemi v podobě sekvencí časoprostorových pozic, může ale zahrnovat také další rysy objektů, například rychlost pohybu, tvary objektů a podobně.

Ačkoliv se jedná o relativně dobře prostudovanou oblast, jedná se stále o složitou úlohu, která naráží na mnoho problémů způsobených například překrýváním objektů nebo zkreslením velikosti objektů vlivem perspektivní projekce. Výsledné trajektorie tak mohou být ovlivněné šumem, mohou být nekompletní nebo přerušené a podobně. Tento aspekt by proto měl být při učení se modelu scény brán v potaz.

Podrobnější informace o sledování objektů a popis metod používaných v dohledovém videu lze najít například v [69] nebo [23].

3.1.2 Význačná místa

Prvním krokem při modelování scény je identifikace zajímavých prostorových lokací, které budou odpovídat uzlům topologického grafu scény. Jako zajímavá nebo význačná místa (v angličtině *points of interest* nebo *regions of interest*) lze uvažovat vstupní nebo výstupní místa a místa zastavení.

Vstupní místa a *výstupní místa* popisují prostorové lokace, kde objekty vstupují do nebo vystupují z oblasti sledované kamerou. Pro modelování těchto míst je nejčastěji využíván dvourozměrný Gaussian Mixture Model (GMM), k jehož učení je použito algoritmu Expectation-Maximization (EM) [6]. Vstupní datová sada pro natrénování modelu vstupních, resp. výstupních míst je tvořena počátečními, resp. koncovými body trajektorie. Každé místo je pak reprezentováno jednou komponentou (shlukem) příslušného GMM modelu. Problémem tohoto přístupu může být určení počtu vstupních a výstupních míst. V [43] je tento problém řešen nadhodnocením počtu hledaných míst algoritmem EM. Ve výsledném modelu jsou pak ponechány pouze ta místa, která mají dostatečnou hustotu (na základě zvolené prahové hodnoty).

Místa zastavení popisují prostorové lokace, kde objekty po nějakou dobu zůstávají nebo se pohybují velmi pomalu [50]. Taková místa mohou být definována různými způsoby. V [43] jsou jako události odpovídající zastavení objektu detekovány takové části trajektorie, v nichž se objekt pohybuje rychlostí nižší než je určitá prahová hodnota. Alternativní definice pro událost odpovídající zastavení se objevuje například v [9], kde je jako součást zastavení považována část pohybu, kdy objekt zůstává v kruhové oblasti o poloměru R po dobu alespoň τ . Všechny takto detekované události zastavení jsou pak vstupem EM algoritmu, který má za úkol vytvořit odpovídající dvourozměrný GMM model, podobně jako v případě vstupních a výstupních míst. Jednotlivá místa zastavení jsou navíc rozšířena o informaci o obvyklé době setrvání objektu na daném místě. Tato doba může být reprezentována různými způsoby, například v [43] je aproximována exponenciální funkcí.

Znalost význačných míst scény může být s výhodou využita pro odstranění trajektorií ovlivněných chybami při sledování objektů. Nekompletní nebo přerušené trajektorie tak mohou být z trénovací datové sady odstraněny ještě před procesem učení modelu scény. V [51] jsou takto odstraněny všechny trajektorie, které nezačínají nebo nekončí v některém z význačných míst.

3.1.3 Cesty objektů

Po identifikaci a popisu význačných míst, která odpovídají uzlům topologického grafu scény, následuje modelování pohybu objektů mezi jednotlivými význačnými místy. Tyto cesty objektů pak odpovídají hranám v topologickém grafu sledované oblasti.

Trajektorie jsou nejprve podle míst zastavení, kterými procházejí, rozděleny na sub-trajektorie. Pokud trajektorie neprochází žádným místem zastavení, nedochází k žádnému dělení. Výsledkem je tak nová sada trajektorií, které odpovídají hranám mezi význačnými místy v topologickém grafu scény. Na hranu

mezi dvěma uzly grafu pak lze nahlížet jako na samostatnou aktivitu [50].

V prostředí, kde je pohyb objektů jasně omezen (například v silniční dopravě), může být učení se cest pohybujících se objektů relativně jednoduchým úkolem. V takovém případě je možné totiž uvažováním omezení daných konkrétní aplikací problém určitým způsobem zjednodušit. Obecně je však nutné uvažovat téměř libovolné vzory pohybu objektů.

Problematikou učení se modelu sledované oblasti se zaměřením právě na učení se typických cest pohybujících se objektů se zabývá následující sekce.

3.2 Učení se modelu sledované oblasti

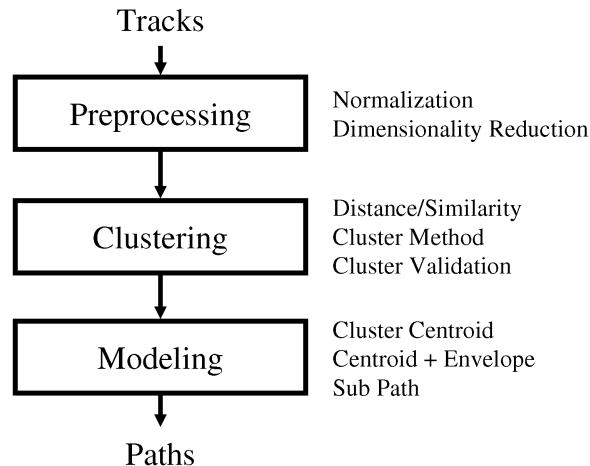
Ústřední fází učení se modelu scény je hledání a popis obvyklých cest pohybujících se objektů na základě jejich trajektorií. Trajektorii lze obecně definovat jako sekvenci

$$F_T = \langle f_1, f_2, \dots, f_T \rangle \quad (1)$$

kde každý vektor f_t (v angličtině *flow vector*) definovaný jako

$$f_t = (x^t, y^t, v_x^t, v_y^t, a_x^t, a_y^t)^T \quad (2)$$

reprezentuje pohybové rysy objektu v čase t . (x, y) popisuje prostorovou lokaci objektu, (v_x, v_y) popisuje rychlost pohybu objektu a (a_x, a_y) popisuje jeho zrychlení [50]. Většinou je však pro popis trajektorie využita pouze prostorová informace, případně informace o rychlosti pohybu. Sekvence reprezentující trajektorie mají většinou různou délku, a to často i tehdy, když mají podobný průběh. V takovém případě bývá důvodem různá rychlost pohybu objektů.



Obrázek 10: Učení se modelu pohybu objektů z trajektorií (převzato z [50]).

Proces učení se obvyklých vzorů pohybu objektů v dohledovém videu je znázorněn na obrázku 10. V první fázi jsou trajektorie předzpracovány do podoby vhodné pro zvolenou metodu shlukování trajektorií. Ve druhé fázi je pak aplikován shlukovací algoritmus s využitím určité podobnostní metriky. Nalezené shluky odpovídají konkrétním pohybovým vzorům (aktivitám). Ve třetí fázi dochází k pravděpodobnostnímu modelování nalezených shluků tak, aby byl výsledný model vhodný pro následnou analýzu chování objektů.

3.2.1 Předzpracování trajektorií

Cílem předzpracování trajektorií je jejich transformace do reprezentace vhodné pro shlukování v další fázi procesu učení. Jednotlivé kroky této fáze se odvíjí jednak od zvoleného shlukovacího algoritmu, ale také od zvolené podobnostní metriky pro porovnávání trajektorií. Některé podobnostní metriky vyžadují, aby trajektorie měly stejnou délku. V takovém případě je nutné použít některou z technik normalizace. V případě, že zvolený algoritmus není vhodný pro shlukování vysoce dimenzionálních dat, je nutné použít některou z technik redukce dimenzionality. Pro odstranění šumu ve vstupních datech je možné použít například Kalmanův filtr nebo částicový filtr a podobně (viz [72]).

Normalizace trajektorií se snaží zajistit, aby všechny trajektorie určené pro shlukování byly stejně dlouhé, přesněji aby byly reprezentovány sekvencemi o stejném počtu časoprostorových bodů. Mezi nejjednodušší techniky zde patří doplnění nul na konec trajektorie [24] a rozšíření trajektorie [23]. V obou případech je jednotný počet bodů trajektorie zvolen podle nejdelší trajektorie v databázi. V případě rozšíření trajektorie je trajektorie doplněna o body odpovídající její poslední zaznamenané pozici. Odlišným způsobem normalizace je převzorkování všech trajektorií na předem zvolenou délku. K tomuto účelu se používá například lineární interpolace [49] nebo podvzorkování na požadovaný počet bodů [25]. Ačkoliv jsou techniky normalizace jednoduše použitelné a mohou umožnit použití mnoha podobnostních metrik, mohou způsobit určitá zkreslení vstupních dat i výsledků shlukování.

Redukce dimenzionality mapuje trajektorie do méně dimenzionálního prostoru a usnadňuje tak mnoho výpočetních operací při shlukování. Při redukci dimenzionality je většinou zvolen určitý model trajektorie a cílem je najít jeho parametry [50]. Příkladem takového modelu může být určitý polynom v případě, že trajektorii uvažujeme jako dvourozměrnou křivku. Často je využívána analýza hlavních komponent (anglicky *Principal Component Analysis*). Využít lze i některých generativních modelů, spektrálních metod a dalších, viz [50]. Redukce dimenzionality sice může přinést řadu výhod pro shlukování trajektorií, výsledky shlukování však odpovídají tomu, jak zvolený model odpovídá vstupním datům.

3.2.2 Shlukování trajektorií

Shlukování trajektorií (viz také sekce 2.2) je zástupcem metod učení bez učitele. Cílem shlukování je identifikovat ve vstupních datech určitou strukturu. V případě využití shlukové analýzy pro učení se modelu scény jsou touto strukturou

obvyklé trasy pohybu objektů.

Pro získání smysluplných shluků je nutné správně vyřešit tři hlavní problémy, kterými jsou volba podobnostní (vzdálenostní) metriky, volba algoritmu shlukování a validace nalezených shluků.

Podobnostní (vzdálenostní) metrika

Shlukovací algoritmus porovnává trajektorie na základě metriky pro určování vzdálenosti, případně podobnosti dvou trajektorií. Pro tento účel může být využita některá z běžně používaných vzdálenostních funkcí nebo lze použít některou metriku navrženou přímo pro porovnávání trajektorií. Využitelné metriky lze dále rozdělit podle toho, zda vyžadují trajektorie stejné délky či nikoliv.

Zatímco vzdálenost (anglicky *distance*) určuje, jak moc se dvě trajektorie liší, podobnost (anglicky *similarity*) vyjadřuje, jak moc si jsou dvě trajektorie podobné. V případě potřeby může být podobnost trajektorií odvozena z jejich vzdálenosti. Například v [25] je podobnost s_{ij} trajektorií i a j počítána jako

$$s_{ij} = e^{-D(i,j)/\sigma^2} \quad (3)$$

kde σ je parametr řídicí rychlost poklesu podobnosti s rostoucí vzdáleností $D(i, j)$.

Následující stručný přehled některých vzdálenostních či podobnostních metrik vychází zejména z [50, 48, 71].

Nejjednodušší metrikou může být *Euklidovská vzdálenost*, která ovšem vyžaduje vektory stejné délky. Tuto nevýhodu odstraňuje modifikace Euklidovské vzdálenosti, která rozšiřuje kratší trajektorii na délku delší trajektorie. Hlavním problémem Euklidovské vzdálenosti však je neschopnost zachytit podobnost trajektorií, které se liší pouze časovým posunem. V [5] je vzdálenost trajektorií počítána po transformaci trajektorií metodou PCA. Vzdálenost je pak určena jako Euklidovská vzdálenost PCA koeficientů.

Metoda DTW (*Dynamic Time Warping*), která je běžně používaná pro hledání vzdálenosti mezi dvěma různě dlouhými signály, může být využita i pro trajektorie. Cílem této metody je najít optimální zarovnání dvou trajektorií minimalizací celkové vzdálenosti mezi odpovídajícími body. Výhodou této metriky je zejména odolnost vůči časovému posunu mezi trajektoriemi.

Nejdelší společná podsekvence (*Longest Common Subsequence*, LCSS) je další technika vzájemného zarovnání dvou sekvencí. Její výhodou oproti DTW je větší odolnost vůči šumu a odlehlým hodnotám, protože ne všechny body musí být zarovnány. Bod, který nemá dobrou shodu s žádným bodem druhé trajektorie, může být vynechán.

Podobný princip jako u DTW a LCSS byl použit při definici nové vzdálenostní metriky v [56]. Tato metrika využívá myšlenku, že obecně si trajektorie bývají nejpodobnější ze začátku jejich průběhu a s rostoucím časem mají tendenci se vzájemně oddalovat z důvodu rozdílných rychlostí pohybu. Vzhledem k tomu je při zarovnávání trajektorií používáno časové okno, jehož rozsah roste s rostoucím časem. Výhodou této metriky je schopnost porovnávat nekompletní trajektorie, a proto je vhodná pro online shlukování.

Pro vzájemné porovnávání dvou množin o různě velkém počtu prvků se často používá *Hausdorffova vzdálenost*. Její využití pro porovnávání trajektorií však není vhodné, protože tato metrika neuvažuje pořadí jednotlivých bodů. V [3] je však navržena modifikace Hausdorffovy vzdálenosti, která bere v potaz pořadí bodů.

V [48] bylo provedeno experimentální srovnání většiny výše zmíněných podobnostních metrik na různých datových sadách v kombinaci s různými shlukovacími algoritmy. V celkovém srovnání bylo nejlepších výsledků shlukování dosaženo s využitím metriky LCSS.

Shlukovací algoritmus

Cílem shlukovacího algoritmu je, vzhledem ke zvolené podobnostní metrice, rozdělit předzpracované vstupní trajektorie do skupin, které odpovídají obvyklým cestám pohybujících se objektů ve sledované oblasti. Pro shlukování existuje velké množství algoritmů, které lze rozdělit do několika kategorií. Podrobný popis shlukovacích metod lze najít například v [20]. Pro účely učení se cest objektů byly využity například následující přístupy [50, 48]:

- *Metody založené na rozdělování* – tyto metody rozdělují n trajektorií do k shluků. Prvním krokem metody je náhodný výběr k trajektorií, které reprezentují jednotlivé shluky. Následně dochází k iterativní optimalizaci reprezentantů shluků. Přiřazování trajektorií do shluků probíhá na základě podobnosti s reprezentanty shluků. Nejznámějším zástupcem této skupiny je metoda k -means, případně její varianta FCM (fuzzy c means), která je pro učení cest objektů použita například v [47].
- *Hierarchické metody* – metody tohoto typu vytvářejí hierarchický rozklad množiny trajektorií, přičemž shluky jsou organizány ve stromové struktuře. Shlukování může probíhat přístupem zdola-nahoru (shlukující metoda), kdy na počátku každý objekt patří do vlastní třídy a postupně dochází ke slučování nejpodobnějších shluků. Opakem je přístup shora-dolů (rozdělující metoda), kdy na počátku patří všechny objekty do jednoho shluku, který je postupně dělen na menší shluky. Výhodou těchto metod je flexibilita ve volbě počtu shluků. Nevýhodou naopak může být volba kritéria pro spojování, respektive rozdělování shluků. Hierarchického shlukování trajektorií pro účely analýzy chování se zaměřením na detekci abnormálních trajektorií bylo využito například v [28].
- *Grafové metody* – trajektorie jsou organizovány v grafové struktuře, jejíž uzly reprezentují jednotlivé trajektorie. Každý uzel je propojen s uzly, které reprezentují nejpodobnější trajektorie. Hrany grafu jsou ohodnoceny na základě podobnosti mezi trajektoriemi, které propojují. Shlukování pak probíhá dělením grafu na k podgrafů tak, aby byla minimalizována ztráta celkového ohodnocení hran. Tento přístup byl pro shlukování trajektorií využit například v [37].

- *Spektrální metody* – tyto metody nevytvářejí žádný předpoklad o distribuci vstupních dat, ale zaměřují se na vlastní (*eigen*) dekompozici podobnostní matice za účelem aproximovat optimální dělení grafu [48]. Hlavní výhodou těchto metod je vysoká efektivita výpočtu. Spektrální shlukování je pro učení se cest objektů použito například v [51].
- *Neuronové sítě* – pro shlukování lze využít tzv. samoorganizující se mapu (Self-Organizing Map, SOM). Každý výstupní uzel takové neuronové sítě odpovídá jedné trajektorii s tím, že sousední uzly odpovídají vzájemně podobným trajektoriím. Výhodou SOM je, že trénování sítě může probíhat postupně, nevýhodou pak potřeba velkého množství trénovacích dat a pomalá konvergence [50].
- *Metody inspirované shlukováním dokumentů* – na trajektorii je nahlíženo jako na dokument, na jednotlivé stavy trajektorie jako na slova v dokumentu. Pro shlukování pak mohou být použity metody, jež vychází z oblasti získávání znalostí z dokumentů. Tento přístup byl pro sémantické modelování chování pohybujících se objektů ve videu využito například v [64].
- *Online shlukování* – využití takových metod je výhodné v případě, že pro učení modelu není k dispozici dostatečně rozsáhlá trénovací databáze trajektorií. Učení modelu tak probíhá průběžně při sledování scény. Jakmile je z procesu sledování objektů generována nová trajektorie, dochází k jejímu zahrnutí do budovaného modelu. Tyto metody většinou vyžadují určení parametrů, které řídí vliv nových dat na změnu modelu, což je hlavní nevýhodou těchto metod. Metoda online shlukování trajektorií za účelem vytvoření modelu aktivít pro následnou analýzu chování objektů byla navržena například v [56, 57].

Validace shluků


Většina shlukovacích metod vyžaduje znalost přesného počtu shluků, které má vytvořit. Počet cest objektů (tedy i odpovídajících aktivit) však není dopředu známý.

Nejčastějším přístupem pro nalezení správného počtu shluků je optimalizace hodnoty určitého kritéria opakovaným shlukováním pro postupně se měnící počet požadovaných shluků. Výsledný počet shluků je pak zvolen na základě výsledku shlukování s nejlepší dosaženou hodnotou optimalizačního kritéria. Příkladem používaného kritéria je „těsnost a separace“ (anglicky *Tightness and Separation Criterion*, TSC) [25], které je založeno na porovnání blízkosti trajektorií uvnitř shluků vzhledem ke vzdálenosti mezi shluky. Dalším příkladem je Bayesovské informační kritérium (BIC), které je navrženo pro výběr nejlepšího modelu z množiny pravděpodobnostních modelů, viz [6].

Jiný přístup k řešení problému předem neznámého počtu shluků je zvolen v [49, 51]. Pro shlukování je nastaven relativně velký počet požadovaných shluků. Výsledný počet shluků je následně snížen postupným spojováním podobných shluků.

3.2.3 Modelování cest

Cesty objektů pohybujících se ve scéně odpovídají shlukům, které jsou výsledkem fáze shlukování trajektorií. Tyto shluky je však potřeba vhodně pravděpodobnostně modelovat za účelem následné analýzy chování. Existující přístupy k modelování cest jsou většinou založeny na jednom ze dvou odlišných přístupů: modelování cesty jako celku nebo rozložení cesty na více menších částí (podcest).




Obrázek 11: Ilustrace modelování cesty pomocí obálky (převzato z [50]).

První přístup vychází z centroidu (prototypu) modelovaného shluku, který rozšiřuje pomocí určité obálky (anglicky *envelope*), viz obrázek 11. Obálka definuje prostorový rozměr modelované cesty a je součástí topografické reprezentace modelu sledované oblasti. Tento způsob popisu cesty může být dále rozšířen o pravděpodobnostní modelování, kdy centroid shluku hraje roli střední hodnoty a obálka reprezentuje rozptyl. Pravděpodobnostní model je odhadnut na základě trajektorií, které tvoří příslušný shluk. Tento princip byl využit například v [43]. V [65] je kromě prostorové obálky shluku modelována jeho hustota a rozložení směru a rychlosti pohybu. Pro pravděpodobnostní modelování bývají často používány skryté Markovské modely (HMM), pomocí kterých lze jednoduše modelovat sekvenční chování, viz například [51].

Druhý přístup pro modelování cest rozděluje prostor odpovídající cestě na více menších atomických prvků, tzv. podcest. Jednotlivé podcesty reprezentují podobné regiony cesty jako jsou části cest před dělením do více směrů [56] nebo například části cesty s podobným zakřivením [5]. Jednotlivé podcesty jsou dále propojeny s jinými podcestami, čímž jsou vyjádřeny přechody mezi nimi. Tyto přechody mohou být rozšířeny o pravděpodobnost. Příklad organizace podcest do stromové struktury ukazuje obrázek 12. Podcesty jsou modelovány jako shluky vytvořené podle dělení cesty do více různých směrů [56].

Jedním z požadavků na model sledované oblasti může být jeho schopnost přizpůsobovat se změnám ve sledovaném prostředí. V takovém případě je tedy nedostačující jednorázové naučení modelu a jeho následné používání bez reakce na případné změny. Ke změnám může docházet u již naučených aktivit objektů, mohou se však objevovat i nové aktivity. Oba tyto případy se snaží řešit například [51]. Případné změny již naučených aktivit jsou v modelu zachyceny průběžnou úpravou parametrů HMM modelů, použitých pro popis chování objektů, na základě chování objektů během používání modelu. Pro objevení



Obrázek 12: Ilustrace modelování cesty pomocí podcest a jejich organizace do stromové struktury (převzato z [56]).

nových aktivit je nutné provádět periodické přetrénování modelu. Pro tento účel je však dostačující ukládat pouze trajektorie označené modelem jako abnormální. Jakmile je objem těchto trajektorií dostatečně velký, jsou použity jako vstup celého procesu učení se modelu scény, který se snaží identifikovat případné nové aktivity, jež by mohly být použity pro rozšíření stávajícího modelu.

Ačkoliv je modelování obvyklých cest pohybujících se objektů využíváno pro analýzu na vyšší úrovni abstrakce, může být užitečné i jako zpětná vazba pro některé nízkourovňové procesy jako je sledování objektů, viz například [61].

3.3 Analýza chování objektů

Model sledované oblasti, popsany v předchozích sekcích, může být po úspěšném dokončeném procesu učení použit pro automatickou analýzu chování a aktivit pohybujících se objektů. Jako aktivity objektů lze chápat jednotlivé cesty, které naučený model popisuje. Využitím modelu tedy může být popsáno chování nových objektů pohybujících se sledovanou oblastí. Mezi typické úlohy analýzy chování patří klasifikace trajektorií, detekce neobvyklých trajektorií a online analýza, která zahrnuje predikci pohybu a detekci neobvyklého chování.

3.3.1 Klasifikace trajektorií

Trajektorie objektu ve scéně může být klasifikována pomocí metody maximální věrohodnosti (anglicky *maximum likelihood estimation*), viz [6]. Objektu je tak přiřazena aktivita (cesta) λ^* , která nejlépe popisuje jeho trajektorii F_T :

$$\lambda^* = \arg \max_k p(F_T | \lambda_k) \quad (4)$$

kde $p(F_T | \lambda_k)$ vyjadřuje, s jakou pravděpodobností je trajektorie F_T generována aktivitou λ_k [51]. Tohoto přístupu lze s výhodou využít zejména tehdy, jsou-li aktivity modelovány nějakým pravděpodobnostním modelem, například HMM.

3.3.2 Detekce neobvyklých trajektorií

Jednou z nejdůležitějších úloh analýzy scény monitorované dohledovým systémem je detekce neobvyklého nebo podezřelého chování objektů.

Jelikož je model scény zaměřen na popis typického chování pohybujících se objektů, lze ho využít pro detekci neobvyklých trajektorií tak, že jako neobvyklá bude označena trajektorie, která dostatečně nevyhovuje žádné z naučených cest. Trajektorie F_T je detekována jako neobvyklá pomocí inteligentního prahování (anglicky *thresholding*) [50] pokud platí

$$p(\lambda^*|F_T) < L_{\lambda^*} \quad (5)$$

kde λ^* je nejpravděpodobnější cesta objektu podle klasifikace jeho trajektorie (viz výše) a L_{λ^*} je prahová hodnota, která může být přizpůsobena každé cestě zvlášť. Například v [24] je jako prahová hodnota zvolena minimální pravděpodobnost zjištěná klasifikací všech trajektorií z trénovací datové sady.

Tento jednoduchý přístup však často vede na vysoké množství chybně klasifikovaných trajektorií [50]. Proto je v současné době snaha vylepšit proces detekce neobvyklých trajektorií za účelem zvýšení úspěšnosti klasifikace. V [29] jsou cesty objektů modelovány z pohledu různých rysů trajektorií, konkrétně je modelována prostorová obálka cesty, rychlost pohybu a zakřivení trajektorie. Trajektorie je pak považována za neobvyklou, pokud nevyhovuje žádné cestě vzhledem ke všem modelovaným rysům.

Další nevýhodou může být statické nastavení prahové hodnoty bez uvažování potřeb konkrétního prostředí. V některých aplikacích může být důraz kladen na odhalení všech neobvyklých trajektorií na úkor větší míry falešných poplachů, v jiných případech může být naopak důležitější se falešným poplachům vyhnout. V [51] je prahová hodnota pro konkrétní cestu automaticky naučena během fáze učení modelu scény porovnáním průměrné věrohodnosti trajektorií uvnitř cesty vzhledem ke všem ostatním. Při učení prahové hodnoty je zahrnutý také parametr, který řídí poměr mezi počtem správně a chybně klasifikovaných trajektorií.

3.3.3 Online analýza

Často může být mnohem důležitější analyzovat chování objektů online, tedy již v průběhu pohybu. Cílem online analýzy chování objektů je být schopen posuzovat aktuální situaci ve scéně a případně na ní odpovídajícím způsobem reagovat [51]. Úlohami online analýzy bývá nejčastěji predikce následujícího pohybu objektu a detekce neobvyklého chování na základě dosavadního průběhu trajektorie.

Predikce pohybu

Při online analýze chování pohybujících se objektů může být užitečné předpokládat, jakým způsobem se bude ubírat budoucí pohyb objektů ve scéně. Přesná predikce následujícího chování objektu může pomoci při reakci na určité události nebo může přispívat k předcházení určitých situací.

Vstupem pro predikci pohybu je nekompletní trajektorie reprezentující dosavadní pohyb objektu. Většinou je navíc vstupní trajektorie omezena časovým oknem. Pro predikci může být využita metoda maximální věrohodnosti, podobně jako v případě klasifikace celé trajektorie. V čase t je jako předpokládané budoucí chování objektu zvolena aktivita (cesta) $\hat{\lambda}_t$, která nejlépe vyhovuje dosavadní nekompletní trajektorii \hat{F}_t :

$$\hat{\lambda}_t = \arg \max_k p(w_t \hat{F}_{t+k} | \lambda_k) \quad (6)$$

kde w_t je okenní funkce (anglicky *windowing function*) a \hat{F}_{t+k} je dosavadní trajektorie objektu v čase t rozšířená o k predikovaných bodů trajektorie [50, 51].

Rozeř časového okna má vliv na přesnost predikce a na dobu potřebnou pro její výpočet. Tímto způsobem tak lze volit vhodný kompromis mezi těmito dvěma aspekty. Na vlastnosti predikce také může mít vliv použitá okenní funkce. Například v [25] je použita pro určení časového okna exponenciální funkce, v [49] pak obdélníkové okno.

Detekce neobvyklého chování

Detekovat neobvyklé chování již v průběhu pohybu objektu ve scéně je možné využitím podobných přístupů jako v případě klasifikace celých trajektorií (viz sekce 3.3.2) v kombinaci s časovým oknem jako v případě predikce pohybu. Zároveň je potřeba při určování prahové hodnoty brát v potaz fakt, že klasifikované trajektorie jsou nekompletní [51].

4 Experimenty s identifikací význačných míst scény

V rámci přípravy této technické zprávy bylo provedeno experimentální ověření fáze identifikace význačných míst ve sledované oblasti. Teoreticky byla tato fáze stručně popsána v sekci 3.1.2, včetně odkazů na relevantní zdroje.

Identifikace význačných míst je v celém procesu modelování sledované oblasti jedním z prvních kroků. Kvalita výsledků této fáze však může významně ovlivnit kvalitu celého modelu pohybu objektů ve scéně. Význačná místa tvoří uzly vznikajícího topologického grafu scény a vlastní pohyb objektů je v další fázi modelován vždy mezi konkrétními dvěma uzly grafu.

Jak již bylo uvedeno v sekci 3.1.2, význačná místa lze rozdělit následovně:

- *Vstupní místa scény* – reprezentují prostorové oblasti, kde pohybující se objekty typicky vstupují do scény.
- *Výstupní místa scény* – reprezentují prostorové oblasti, kde pohybující se objekty typicky vystupují ze scény.
- *Místa zastavení* – popisují prostorové oblasti, kde objekty po určitou dobu setrvávají nebo se pohybují velmi pomalu.

Při prováděných experimentech byly uvažovány všechny tři typy význačných míst, nicméně důraz byl kladen zejména na třetí typ, tedy tzv. místa zastavení. Důvodem byl fakt, že zajímavá místa jsou v existujících přístupech identifikována příliš přímočarým způsobem, navíc pouze na základě změn rychlosti pohybu. Zejména v komplexních scénách se však význačné místo (například překážka) může projevit na jiných charakteristických vlastnostech pohybu.

Pro vylepšení výsledků identifikace význačných míst bylo využito některých přístupů použitých pro jiné účely nebo pro jiné aplikační oblasti. Konkrétně se jednalo o některé metody pro sémantické obohacení trajektorií, viz sekce 2.6.1. Cílem tedy bylo ověření a zhodnocení těchto metod při použití pro účely identifikace význačných míst oblasti sledované dohledovou kamerou. Na základě kladných výsledků by pak mohla být navržena nová metoda, která by vhodně kombinovala a rozšiřovala zmíněné přístupy.

Experimentální ověření bylo provedeno nad několika volně dostupnými reálnými datovými sadami videí pocházejících z dohledových systémů. Nejprve byla provedena fáze sledování objektů (*object tracking*), jejímž výsledkem je sada trajektorií reprezentujících pohyb objektů ve scéně.

Vlastní fáze identifikace význačných míst probíhala v následujících krocích:

1. *Předzpracování trajektorií* – trajektorie, jež jsou výsledkem fáze sledování objektů, jsou k dispozici pouze v podobě sekvencí časoprostorových pozic. Algoritmy pro identifikaci potenciálních míst zastavení však vyžadují různé jiné ukazatele pohybu objektu. Musí tak být nejprve pro každou trajektorii vypočteny sekvence okamžitých rychlostí pohybu, vzdáleností mezi jednotlivými body, okamžitých směrů pohybu a změn rychlosti pohybu.
2. *Identifikace vstupních/výstupních míst* – k tomuto účelu je využito shlukování počátečních/koncových bodů všech trajektorií pomocí algoritmu Expectation-maximization (EM), jehož cílem je odhadnout parametry modelu GMM (Gaussian Mixture Model). V této fázi dochází k záměrnému nadhodnocení počtu shluků.
3. *Detekce a odstranění semi-stacionárních trajektorií* – jedná se o trajektorie vzniklé pohybem např. dveří, reklamních panelů, větví stromů apod. Takové trajektorie nejsou pro modelování pohybu objektů vhodné, a proto je třeba je odstranit. K tomuto jsou využity nalezené shluky, které odpovídají potenciálním vstupním či výstupním místům. Jako semi-stacionární jsou označeny trajektorie, jejichž vstupní a výstupní místo se překrývá a celý pohyb objektu byl zaznamenán pouze v oblasti omezené těmito místy.
4. *Identifikace vstupních/výstupních míst* – v tomto kroku je opětovně pro vstupní/výstupní místa provedeno shlukování počátečních/koncových bodů sady hledaných shluků nadhodnocen, nicméně již ne tak výrazně. Výsledné shluky jsou následně podrobeny ověření, zda je jejich hustota dostatečná vzhledem k uživatelsky specifikovanému kritériu. Dostatečně husté shluky jsou pak označeny jako vstupní/výstupní místa.

5. *Transformace trajektorií na sekvence zastavení* – pro každou trajektorii jsou provedeny všechny ověřované metody pro identifikaci potenciálních míst zastavení objektu. Konkrétně byly zvoleny následující metody:
 - *Základní metoda* – jednoduchá metoda využívající pouze změny rychlosti pohybu, viz sekce 3.1.2.
 - *CB-SMoT* – metoda založená na shlukování jednotlivých trajektorií podle změn rychlosti pohybu, viz sekce 2.6.1.
 - *DB-SMoT* – metoda založená na shlukování jednotlivých trajektorií podle změn směru pohybu, viz sekce 2.6.1.
6. *Identifikace míst zastavení* – výsledky každé metody pro všechny trajektorie jsou předloženy EM algoritmu za účelem nalezení shluků potenciálních míst zastavení. Podobně jako u hledání vstupních a výstupních míst je i zde počet shluků nadhodnocen. Výsledné shluky jsou taktéž podrobeny ověření, zda je jejich hustota dostatečná vzhledem k uživatelsky specifikovanému kritériu. Dostatečně husté shluky jsou pak označeny jako zajímavá místa zastavení.

Všechny kroky fáze identifikace význačných míst byly implementovány v jazyce C++. Pro přístup k datům bylo využito rozhraní VTApi, které je vyvíjeno v rámci projektu MVČR VG20102015006 – „Nástroje a metody zpracování videa a obrazu pro boj s terorismem“.

Celý výše uvedený proces byl opakovaně prováděn pro různá vstupní data, různá nastavení uživatelských parametrů ověřovaných metod a různá nastavení parametrů shlukování, včetně počtu shluků.

Z provedeného experimentálního ověření lze vyvodit následující závěry:

- Zvolený přístup k identifikaci význačných míst sledované oblasti není vhodný pro datové sady obsahující velké množství trajektorií, které jsou nekompletní nebo přerušené a podobně. Vstupní datová sada tak musí být velmi kvalitní, což však v případě reálných dat často splněno není.
- Algoritmus Expectation-maximization není pro účely identifikace význačných míst scény příliš vhodný, zejména kvůli nutnosti přesně specifikovat cílový počet shluků. Lepších výsledků by potenciálně mohlo být dosaženo například pomocí algoritmu Mean-Shift.
- Ověřované a porovnávané algoritmy pro hledání zajímavých míst zastavení neposkytovaly v žádném testovacím případě významně odlišné výsledky. Z tohoto důvodu lze tvrdit, že základní jednoduchá metoda je pro tyto účely dostačující.

5 Závěr

Získávání znalostí z dat pohybujících se objektů je významou oblastí analýzy časoprostorových dat. V kapitole 2 byly představeny typické úlohy dolování

v datech pohybujících se objektů a existující metody pro jejich řešení. Nejprve bylo posáno hledání vzorů pohybujících se objektů se zaměřením na vztahy mezi objekty, na frekventované pohyby a periodické vzory. V další části byla pozornost zaměřena na dolování v trajektoriích pohybujících se objektů. Do této skupiny úloh patří shlukování trajektorií, predikce budoucí pozice, klasifikace trajektorií a detekce odlehlých hodnot. V závěru kapitoly byl představen pojem sémantických trajektorií, které přirozeně rozšiřují zavedený pohled na trajektorii jako na posloupnost časoprostorových bodů o sémantické rysy odrážející geografické pozadí a doménově specifické znalosti konkrétní aplikace. Pozornost byla zaměřena zejména na existující algoritmy pro obohacení trajektorií o sémantickou informaci.

Významným zdrojem velkého množství dat popisujících pohyb objektů jsou v současné době dohledové kamerové systémy. Tyto systémy neustále pořizují video data, která je nutné zpracovávat a analyzovat za účelem pochopení chování objektů pohybujících se ve scéně sledované dohledovou kamerou. Vzhledem k obrovskému množství dat je potřeba proces analýzy aktivit a chování objektů zautomatizovat. Touto problematikou se zabývala kapitola 3. Nejprve byly představeny existující přístupy k modelování pohybu objektů ve sledované oblasti a metody učení tohoto modelu. Závěrečná část této kapitoly se pak věnovala jednotlivým úlohám analýzy aktivit a chování objektů s využitím modelu sledované oblasti.

Reference

- [1] Alvares, L. O.; Bogorny, V.; Kuijpers, B.; aj.: A Model for Enriching Trajectories with Semantic Geographical Information. In *Proceedings of the 15th International Symposium on Advances in Geographic Information Systems*, 2007, s. 22:1–22:8.
- [2] Alvares, L. O.; Bogorny, V.; de Macedo, J. A. F.; aj.: Dynamic Modeling of Trajectory Patterns using Data Mining and Reverse Engineering. In *Tutorials, Posters, Panels and Industrial Contributions at the 26th International Conference on Conceptual Modeling - ER 2007*, 2007, s. 149–154.
- [3] Atev, S.; Masoud, O.; Papanikolopoulos, N.: Learning Traffic Patterns at Intersections by Spectral Clustering of Motion Trajectories. In *Proceedings of the 2006 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2006, s. 4851–4856.
- [4] Bashir, F. I.; Khokhar, A. A.; Schonfeld, D.: View-invariant motion trajectory-based activity classification and recognition. *Multimedia Systems*, ročník 12, 2006: s. 45–54.
- [5] Bashir, F. I.; Khokhar, A. A.; Schonfeld, D.: Object Trajectory-Based Activity Classification and Recognition Using Hidden Markov Models. *IEEE Transactions on Image Processing*, ročník 16, 2007: s. 1912–1919.
- [6] Bishop, C. M. (editor): *Pattern Recognition and Machine Learning*. Springer, 2006, ISBN 978-0-387-31073-2, 738 s.
- [7] Bogorny, V.; Heuser, C. A.; Alvares, L. O.: A Conceptual Data Model for Trajectory Data Mining. In *Geographic Information Science, LNCS 6292*, 2010, s. 1–15.
- [8] Bogorny, V.; Wachowicz, M.: A Framework for Context-Aware Trajectory Data Mining. In *Data Mining for Business Applications*, 2009, s. 225–239.
- [9] Brandle, N.; Bauer, D.; Seer, S.: Track-Based Finding of Stopping Pedestrians – A Practical Approach for Analyzing a Public Infrastructure. In *Proceedings of the 2006 IEEE Intelligent Transportation Systems Conference*, 2006, s. 115–120.
- [10] Bu, Y.; Chen, L.; Fu, A. W.-C.; aj.: Efficient Anomaly Monitoring Over Moving Object Trajectory Streams. In *Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2009, s. 159–168.
- [11] Ferreira, N.; Klosowski, J. T.; Scheidegger, C.; aj.: Vector Field k-Means: Clustering Trajectories by Fitting Multiple Vector Fields. *CoRR*, ročník abs/1208.5801, 2012.

- [12] Fraile, R.; Maybank, S. J.: Vehicle Trajectory Approximation and Classification. In *Proceedings of the British Machine Vision Conference 1998*, 1998, s. 832–840.
- [13] Ge, Y.; Xiong, H.; hua Zhou, Z.; aj.: TOP-EYE: Top-k Evolving Trajectory Outlier Detection. In *Proceedings of the 19th ACM International Conference on Information and Knowledge Management*, 2010, s. 1733–1736.
- [14] Giannotti, F.; Nanni, M.; Pinelli, F.; aj.: Trajectory Pattern Mining. In *Proceedings of the 13th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2007, s. 330–339.
- [15] Gómez, L.; Kuijpers, B.; Vaisman, A.: Querying and Mining Trajectory Databases Using Places of Interest. In *New Trends in Data Warehousing and Data Analysis*, 2009, s. 249–274.
- [16] Güting, R. H.; Almeida, V.; Ansoorge, D.; aj.: SECONDO: An Extensible DBMS Platform for Research Prototyping and Teaching. In *Proceedings of the 21st International Conference on Data Engineering*, 2005, s. 1115–1116.
- [17] Güting, R. H.; Schneider, M.: *Moving Objects Databases*. Morgan Kaufmann Publishers, 2005, ISBN 978-0-12-088799-6, 416 s.
- [18] Gudmundsson, J.; Kreveld, M.; Speckmann, B.: Efficient Detection of Patterns in 2D Trajectories of Moving Points. *GeoInformatica*, ročník 11, 2007: s. 195–215.
- [19] Han, J.; Kamber, M.: *Data Mining: Concepts and Techniques*. Morgan Kaufmann Publishers, druhé vydání, 2006, ISBN 978-1-55860-901-3, 770 s.
- [20] Han, J.; Kamber, M.; Pei, J.: *Data Mining: Concepts and Techniques*. Morgan Kaufmann Publishers, třetí vydání, 2011, ISBN 978-0-12-381479-1, 744 s.
- [21] Han, J.; Li, Z.; Tang, L. A.: Mining Moving Object, Trajectory and Traffic Data, DASFAA 2010 Tutorial. URL <http://www.cs.uiuc.edu/homes/hanj/pdf/dasfaa10_han_tuto.pdf>.
- [22] Han, J.; Li, Z.; Tang, L. A.: Mining Moving Object, Trajectory and Traffic Data. In *Database Systems for Advanced Applications, Part II, LNCS 5982*, 2010, s. 485–486.
- [23] Hu, W.; Tan, T.; Wang, L.; aj.: A survey on visual surveillance of object motion and behaviors. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, ročník 34, 2004: s. 334–352.

- [24] Hu, W.; Xiao, X.; Fu, Z.; aj.: A system for learning statistical motion patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 28, 2006: s. 1450–1464.
- [25] Hu, W.; Xie, D.; Fu, Z.; aj.: Semantic-Based Surveillance Video Retrieval. *IEEE Transactions on Image Processing*, ročník 16, 2007: s. 1168–1181.
- [26] Jeung, H.; Liu, Q.; Shen, H. T.; aj.: A Hybrid Prediction Model for Moving Objects. In *Proceedings of the 2008 IEEE 24th International Conference on Data Engineering*, 2008, s. 70–79.
- [27] Jeung, H.; Yiu, M. L.; Zhou, X.; aj.: Discovery of Convoys in Trajectory Databases. *Proceedings of the VLDB Endowment*, ročník 1, 2008: s. 1068–1080.
- [28] Jiang, F.; Wu, Y.; Katsaggelos, A. K.: Abnormal event detection based on trajectory clustering by 2-depth greedy search. In *Proceedings of the 2008 IEEE International Conference on Acoustics, Speech and Signal Processing*, 2008, s. 2129–2132.
- [29] Junejo, I. N.; Javed, O.; Shah, M.: Multi Feature Path Modeling for Video Surveillance. In *Proceedings of the 17th International Conference on Pattern Recognition*, 2004, s. 716–719.
- [30] Kalnis, P.; Mamoulis, N.; Bakiras, S.: On Discovering Moving Clusters in Spatio-temporal Data. In *Advances in Spatial and Temporal Databases, LNCS 3633*, 2005, s. 364–381.
- [31] Knorr, E. M.; Ng, R. T.; Tucakov, V.: Distance-based outliers: algorithms and applications. *The VLDB Journal*, ročník 8, 2000: s. 237–253.
- [32] Laube, P.; van Kreveld, M.; Imfeld, S.: Finding REMO – Detecting Relative Motion Patterns in Geospatial Lifelines. In *Developments in Spatial Data Handling*, 2005, s. 201–215.
- [33] Lee, J.-G.; Han, J.; Li, X.: Trajectory Outlier Detection: A Partition-and-Detect Framework. In *Proceedings of the 2008 IEEE 24th International Conference on Data Engineering*, 2008, s. 140–149.
- [34] Lee, J.-G.; Han, J.; Li, X.; aj.: TraClass: Trajectory Classification Using Hierarchical Region-Based and Trajectory-Based Clustering. *Proceedings of the VLDB Endowment*, ročník 1, 2008: s. 1081–1094.
- [35] Lee, J.-G.; Han, J.; Whang, K.-Y.: Trajectory Clustering: A Partition-and-Group Framework. In *Proceedings of the 2007 ACM SIGMOD International Conference on Management of Data*, 2007, s. 593–604.
- [36] Li, X.; Han, J.; Kim, S.; aj.: ROAM: Rule- and Motif-Based Anomaly Detection in Massive Moving Object Data Sets. In *Proceedings of the 7th SIAM International Conference on Data Mining*, 2007, s. 273–284.

- [37] Li, X.; Hu, W.; Hu, W.: A Coarse-to-Fine Strategy for Vehicle Motion Trajectory Clustering. In *Proceedings of the 18th International Conference on Pattern Recognition*, 2006, s. 591–594.
- [38] Li, X.; Li, Z.; Han, J.; aj.: Temporal Outlier Detection in Vehicle Traffic Data. In *Proceedings of the 2009 IEEE International Conference on Data Engineering*, 2009, s. 1319–1322.
- [39] Li, Z.; Ding, B.; Han, J.; aj.: Mining Periodic Behaviors for Moving Objects. In *Proceedings of the 16th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2010, s. 1099–1108.
- [40] Li, Z.; Ding, B.; Han, J.; aj.: Swarm: Mining Relaxed Temporal Moving Object Clusters. *Proceedings of the VLDB Endowment*, ročník 3, 2010: s. 723–734.
- [41] Li, Z.; Han, J.; Ji, M.; aj.: MoveMine: Mining Moving Object Data for Discovery of Animal Movement Patterns. *ACM Transactions on Intelligent Systems and Technology*, ročník 2, 2011: s. 37:1–37:32.
- [42] Liu, L.; Fan, J.; Qiao, S.; aj.: Efficiently Mining Outliers From Trajectories of Unrestraint Movement. In *Proceedings of the 3rd International Conference on Advanced Computer Theory and Engineering*, 2010, s. V2–261–V2–265.
- [43] Makris, D.; Ellis, T.: Learning Semantic Scene Models From Observing Activity in Visual Surveillance. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, ročník 35, 2005: s. 397–408.
- [44] Mamoulis, N.; Cao, H.; Kollios, G.; aj.: Mining, Indexing, and Querying Historical Spatiotemporal Data. In *Proceedings of the 10th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2004, s. 236–245.
- [45] Monreale, A.; Pinelli, F.; Trasarti, R.; aj.: WhereNext: a Location Predictor on Trajectory Pattern Mining. In *Proceedings of the 15th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2009, s. 637–646.
- [46] Moreno, B. N.; Times, V. C.; Renso, C.; aj.: Looking inside the Stops of Trajectories of Moving Objects. In *XI Brazilian Symposium on Geoinformatics (GeoInfo)*, 2010, s. 9–20.
- [47] Morris, B.; Trivedi, M.: An Adaptive Scene Description for Activity Analysis in Surveillance Video. In *Proceedings of the 19th International Conference on Pattern Recognition*, 2008, s. 1–4.
- [48] Morris, B.; Trivedi, M.: Learning Trajectory Patterns by Clustering: Experimental Studies and Comparative Evaluation. In *Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition*, 2009, s. 312–319.

- [49] Morris, B. T.; Trivedi, M. M.: Learning and Classification of Trajectories in Dynamic Scenes: A General Framework for Live Video Analysis. In *Proceedings of the 2008 IEEE Fifth International Conference on Advanced Video and Signal Based Surveillance*, 2008, s. 154–161.
- [50] Morris, B. T.; Trivedi, M. M.: A Survey of Vision-Based Trajectory Learning and Analysis for Surveillance. *IEEE Transactions on Circuits and Systems for Video Technology*, ročník 18, 2008: s. 1114–1127.
- [51] Morris, B. T.; Trivedi, M. M.: Trajectory Learning for Activity Understanding: Unsupervised, Multilevel, and Long-Term Adaptive Approach. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, ročník 33, 2011: s. 2287–2301.
- [52] Nanni, M.; Pedreschi, D.: Time-focused clustering of trajectories of moving objects. *Journal of Intelligent Information Systems*, ročník 27, 2006: s. 267–289.
- [53] Owens, J.; Hunter, A.: Application of the Self-Organising Map to Trajectory Classification. In *Proceedings of the Third IEEE International Workshop on Visual Surveillance*, 2000, s. 77–83.
- [54] Palma, A. T.; Bogorny, V.; Kuijpers, B.; aj.: A Clustering-based Approach for Discovering Interesting Places in Trajectories. In *Proceedings of the 2008 ACM Symposium on Applied Computing (SAC)*, 2008, s. 863–868.
- [55] Pelekis, N.; Theodoridis, Y.; Vosinakis, S.; aj.: Hermes – A Framework for Location-Based Data Management. In *Advances in Database Technology – EDBT 2006, LNCS 3896*, 2006, s. 1130–1134.
- [56] Piciarelli, C.; Foresti, G. L.: On-line trajectory clustering for anomalous events detection. *Pattern Recognition Letters*, ročník 27, 2006: s. 1835–1842.
- [57] Piciarelli, C.; Foresti, G. L.; Snidaro, L.: Trajectory Clustering and its Applications for Video Surveillance. In *Proceedings of the 2005 IEEE Conference on Advanced Video and Signal Based Surveillance*, 2005, s. 40–45.
- [58] Piciarelli, C.; Micheloni, C.; Foresti, G.: Anomalous Trajectory Patterns Detection. In *Proceedings of the 19th International Conference on Pattern Recognition*, 2008.
- [59] Rocha, J. A. M. R.; Oliveira, G.; Alvares, L. O.; aj.: DB-SMoT: A Direction-Based Spatio-Temporal Clustering Method. In *Proceedings of the 5th IEEE International Conference on Intelligent Systems*, 2010, s. 114–119.

- [60] Sbalzarini, I. F.; Theriot, J.; Koumoutsakos, P.: Machine Learning for Biological Trajectory Classification Applications. In *Proceedings of the Summer Program 2002, Center for Turbulence Research*, 2002, s. 305–316.
- [61] Song, X.; Shao, X.; Zhao, H.; aj.: An online approach: Learning-Semantic-Scene-by-Tracking and Tracking-by-Learning-Semantic-Scene. In *Proceedings of the 2010 IEEE Conference on Computer Vision and Pattern Recognition*, 2010, s. 739–746.
- [62] Spaccapietra, S.; Parent, C.; Damiani, M. L.; aj.: A conceptual view on trajectories. *Data & Knowledge Engineering*, ročník 65, 2008: s. 126–146.
- [63] Tao, Y.; Faloutsos, C.; Papadias, D.; aj.: Prediction and Indexing of Moving Objects with Unknown Motion Patterns. In *Proceedings of the 2004 ACM SIGMOD International Conference on Management of Data*, 2004, s. 611–622.
- [64] Wang, X.; Ma, K. T.; Ng, G.-W.; aj.: Trajectory Analysis and Semantic Region Modeling Using Nonparametric Hierarchical Bayesian Models. *International Journal of Computer Vision*, ročník 95, 2011: s. 287–312.
- [65] Wang, X.; Tieu, K.; Grimson, E.: Learning Semantic Scene Models by Trajectory Analysis. In *Computer Vision – ECCV 2006, LNCS 3953*, 2006, s. 110–123.
- [66] Yan, Z.: Towards Semantic Trajectory Data Analysis: A Conceptual and Computational Approach. In *Proceedings of the VLDB 2009 PhD Workshop*, 2009.
- [67] Yan, Z.: Traj-ARIMA: A Spatial-Time Series Model for Network-Constrained Trajectory. In *Proceedings of the Second International Workshop on Computational Transportation Science (IWCTS)*, 2010, s. 11–16.
- [68] Yan, Z.; Parent, C.; Spaccapietra, S.; aj.: A Hybrid Model and Computing Platform for Spatio-semantic Trajectories. In *The Semantic Web: Research and Applications, LNCS 6088*, 2010, s. 60–75.
- [69] Yilmaz, A.; Javed, O.; Shah, M.: Object tracking: A survey. *ACM Computing Surveys*, ročník 38, 2006.
- [70] Ying, X.; Xu, Z.; Yin, W. G.: Cluster-based Congestion Outlier Detection Method on Trajectory Data. In *Proceedings of the 6th International Conference on Fuzzy Systems and Knowledge Discovery*, 2009, s. 243–247.
- [71] Zhang, Z.; Huang, K.; Tan, T.: Comparison of Similarity Measures for Trajectory Clustering in Outdoor Surveillance Scenes. In *Proceedings of the 18th International Conference on Pattern Recognition*, 2006, s. 1135–1138.

- [72] Zheng, Y.; Zhou, X. (editoři): *Computing with Spatial Trajectories*. Springer, 2011, ISBN 978-1-4614-1628-9, 333 s.
- [73] Zhou, C.; Bhatnagar, N.; Shekhar, S.; aj.: Mining Personally Important Places from GPS Tracks. In *Proceedings of the 2007 IEEE 23rd International Conference on Data Engineering Workshop*, 2007, s. 517–526.