

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta informačních technologií

DIPLOMOVÁ PRÁCE

Brno 2002

Igor Potůček

PROHLÁŠENÍ:

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně pod vedením Ing. Martina Fědora. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Brně dne 3.6.2002

podpis

PODĚKOVÁNÍ:

Děkuji vedoucímu diplomové práce Ing. Martinu Fědorovi za velmi užitečnou metodickou pomoc a cenné rady při zpracování diplomové práce.

ABSTRAKT

V této práci se zabývám sledováním pohybu objektů se stejným vzhledem v sekvenci snímků. V úvodu je proveden rozbor metod pro sledování pohybu v obraze a identifikaci trajektorie pohybujícího se objektu. Je zde popsán algoritmus pro sledování trajektorií pohybujících se bodů, přičemž tyto objekty mohou mizet, objevovat se na jiných místech, nebo může docházet k jejich překrývání. Určování korespondencí mezi jednotlivými body je prováděno na základě zpětného vyhodnocování vzniklých hypotéz. Pro sledování trajektorií využívá algoritmus predikce příští polohy objektu. Jako nástroj pro predikci je zvolen Kalmanův filtr, který je výhodný z hlediska své rekurzivní struktury. Dále je zde popsán algoritmus pro spojování korespondujících trajektorií pomocí extrapolace hodnot. Na závěr je uvedeno zhodnocení popsaných algoritmů testovaných na vybraných sekvencích.

KLÍČOVÁ SLOVA

Identifikace trajektorie, Kalmanův filtr, predikce pohybu, určování korespondence objektů, predikční strom, zpětné vyhodnocování, extrapolace trajektorie, spojitost, segmentace obrazu.

ABSTRACT

This paper describes the way to determine trajectory of moving simple objects - tokens in a picture sequence. Modified Kalman filter is used to predict and identify their trajectory. Presented approach resolves trajectory ambiguities, a case when the number of tokens is large and their speeds and accelerations vary. Correspondence problem is determined between two or more consecutive frames based on tokens similarity. Tracked objects may vanish, appear at a new position and/or mutually occlude each other. Backtracking is used to solve these problems.

KEY WORDS

Trajectory identification, target tracking, Kalman filter, movement prediction, motion correspondence problem, prediction trees, backtracking, continuity, picture segmentation.

OBSAH

1. ÚVOD	9
1.1. PŘEHLED POUŽÍVANÝCH METOD	10
1.2. SLEDOVÁNÍ VĚTŠÍHO MNOŽSTVÍ POHYBUJÍCÍCH SE OBJEKTŮ	12
2. EXTRAKCE OBJEKTŮ Z OBRAZU	15
2.1. PROBLÉMY PŘI EXTRAKCI OBJEKTŮ	16
3. URČENÍ KORESPONDENCE	18
3.1. PROBLÉMY KORESPONDENCE OBJEKTŮ.....	19
4. KALMANŮV FILTR PRO PREDIKCI POLOHY	22
4.1. APLIKACE KALMANOVA FILTRU NA POHYB OBJEKTŮ	22
4.2. INICIALIZACE KALMANOVA FILTRU	24
4.2.1. <i>Kovarianční matice a matice chyb</i>	24
4.3. VÝPOČET ZLEPŠENÍ.....	25
4.4. MAXIMÁLNÍ ODCHYLKA OD PREDIKOVANÉ HODNOTY.....	26
4.5. VÝPOČET ZISKU A AKTUALIZACE STAVOVÉHO VEKTORU.....	26
4.6. VÝPOČET KOVARIANČNÍ MATICE.....	27
4.7. MANÉVROVACÍ MATICE	28
4.8. POSTUP VÝPOČTU	29
5. IDENTIFIKACE TRAJEKTORIE	32
5.1. OHODNOCENÍ TRAJEKTORIÍ	33
5.2. PŘÍŘAZENÍ OBJEKTŮ HYPOTÉZÁM.....	33
5.3. IMPLEMENTACE PREDIKCE.....	34
5.4. PREDIKČNÍ STROM	36
5.5. PROŘEZÁVÁNÍ STROMU.....	36
5.6. ROZBOR PROBLÉMŮ MIZENÍ A OBJEVOVÁNÍ	39
5.6.1. <i>Objevení objektu</i>	40
5.6.2. <i>Mizení objektu</i>	41
5.7. PROBLÉMY PŘI SLEDOVÁNÍ TRAJEKTORIÍ	43
6. SPOJOVÁNÍ TRAJEKTORIÍ	45
6.1. SPOJITOST	47
6.2. IMPLEMENTACE SPOJENÍ TRAJEKTORIÍ.....	48
6.3. PROBLÉMY PŘI EXTRAPOLACI	49
7. ROZBOR A VYHODNOCENÍ CHOVÁNÍ ALGORITMŮ	51
7.1. VLASTNOSTI PARAMETRŮ KALMANOVA FILTRU	52
7.2. ODCHYLKY OD PREDIKOVANÉ HODNOTY	56
7.3. VELIKOST PREDIKOVANÉ OBLASTI	58
7.4. EXTRAPOLACE HODNOT	60

7.5. SEKVENCE POHYBU ČLOVĚKA.....	62
8. ZÁVĚR	65
9. SEZNAM POUŽITÉ LITERATURY	67
10. SEZNAM PŘÍLOH.....	69

1. Úvod

V oblasti počítačového vidění se v posledních letech zaměřil výzkum na vývoj efektivních postupů a algoritmů pro sledování pohybu objektů. Využití je v široké oblasti od systémů pro sledování dopravy, v leteckém průmyslu při sledování pohybu letadel, v armádním průmyslu pro navádění střel, navádění satelitů nebo sledování mikroorganismů pod mikroskopem. Tyto systémy se snaží přebírat větší část zpracování a vyhodnocování dat. Z tohoto důvodu je kladen velký důraz na vývoj efektivních algoritmů pro sledování pohybu.

Existuje velké množství způsobů sledování pohybu, které se navzájem od sebe liší vlastnostmi sledovaných obrazů, způsobem snímání obrazů, cílem sledování pohybu a dalšími aspekty. Tyto techniky využívají apriorních znalostí při řešení konkrétních úloh. Takové informace (např. předpokládaný tvar, velikost a prostorové uspořádání objektů, přípustný stupeň křivosti jejich hranic, znalosti o způsobu chování objektů apod.) slouží při zpracování obrazu jako omezující podmínky, případně jako vazby v optimalizaci. Jiným konceptem je rozsáhlé uplatňování heuristických, intuitivně navržených postupů využívajících zkušenost, v kombinaci s formalizovanými metodami.

V této práci jsem se zaměřil na sledování pohybu objektů se stejným vzhledem. Cílem je identifikovat trajektorie značek připevněných na lidském těle. Sledovanou sekvencí je nasnímaný pohyb člověka jednou kamerou. Značky jsou zobrazeny v sledované sekvenci jako bílé pohybuující se body. Hlavním a nejkomplicovanějším problémem je zde určování korespondencí mezi objekty. Nicméně většina prací pokládala problém určování korespondence za jednoduchý a využívala strategie nejbližšího následníka. V mnoha případech je však tato strategie nedostačující, jelikož mohou vznikat mnohoznačná přiřazení. Při sledování objektů s odlišným vzhledem lze tento problém částečně řešit využitím technik k zjištění vlastností pozorovaných objektů a jejich porovnáním. V případě, kdy mají všechny pozorované objekty stejný vzhled, musíme použít jiný postup.

Při sledování a analýze pohybu objektů v obraze využívám pozorování v závislosti na několika po sobě jdoucích snímcích. Tento způsob se používá většinou při sledování pohybu objektů ve 3D scéně snímané jednou kamerou, jak je tomu i v našem případě. Součástí této metody je predikce příští polohy objektu realizovaná pomocí Kalmanova filtru. Při pohybu objektů však může dojít k následujícím problémům, které je nutné vyřešit. Objekty se mohou

při pohybu překrývat nebo mizet a objevovat se na jiných místech. Vlivem těchto problémů se zvyšuje náročnost a složitost algoritmů na určování vzájemných korespondencí.

V této práci je proveden rozbor problémů, které se vyskytují při sledování trajektorií a popis jejich řešení. V úvodu jsou popsány techniky, využívané při sledování objektů. Další část práce je koncipována chronologicky v pořadí řešení problému sledování objektů. Na konci každé kapitoly jsou uvedeny problémy a jejich možná řešení, které se vyskytují u dané problematiky. Na závěr je provedeno vyhodnocení chování implementovaných metod a zhodnoceny výhody a nevýhody jejich použití. Tato práce navazuje jen na semestrální projekt, ve kterém byly rozebrány metody a postupy obecného sledování pohybu objektů a provedena aplikace Kalmanova filtru na predikci pohybu.

1.1. Přehled používaných metod

Techniky detekce pohybu můžeme rozdělit podle způsobu snímání obrazu na :

- Zpracování sterea – tato metoda pracuje na principu stereovize. Zpracovává dvě sekvence obrazů, snímané jako oddělené obrazy (levý a pravý) jedné snímané scény. Využívá pak drobné odlišnosti v obou obrazech. Tímto způsobem snímání získáme třídimensionální obraz snímané scény. V současné době se používá sledování scény více než dvěma kamerami.
- Zpracování jedné sekvence snímků – metoda zpracovává dva a více snímků získané jednou kamerou. Většinou snímky představují snímanou 3D scénu transformovanou na 2D obraz.

Metody se mohou od sebe lišit způsobem práce s obrazem. Např. metody pracující s celým obrazem, jako je metoda detekce aktivity, která je základním elementem detekce pohybu. Představuje jednoduše porovnání dvou snímků. Druhým typem jsou metody, které vyhledávají v obrazech jednotlivé objekty, se kterými dále pracují. U těchto technik je důležité vybrat vhodné parametry, podle kterých se detekují objekty v obraze. Objektové techniky jsou obecně méně citlivé na fotometrické změny v obrazech a jsou rychlejší při hledání korespondencí [17]. Jejich nevýhodou je někdy obtížné a časově náročné vyhledávání jednotlivých objektů. U objektových technik se využívá při hledání korespondencí různých vlastností :

- Podobnost – objekty sledované z různých míst mají podobné charakteristiky.

- Jednoznačnost - jeden objekt v jednom snímku má maximálně jeden obraz ve druhém snímku.
- Spojitost – posunutí objektu mezi dvěma snímky se nemění skokově, ale spojitě, tzn. objekt (kamera) se pohybuje po hladké křivce.

Při hledání korespondencí využíváme různé techniky pro nalezení nejlepšího kandidáta. U příznakových metod jsou obrazy předmětů reprezentovány n -rozměrnými vektory číselných příznaků. Každý vektor jednoznačně určuje bod v n -rozměrném obrazovém prostoru. Metody klasifikace pak vycházejí z předpokladu, že body obrazů předmětů jednotlivých tříd leží v obrazovém prostoru blízko sebe, neboli že v obrazovém prostoru vytvářejí shluky. Korelační techniky využívají porovnání obrazových funkcí všech možných kandidátů s obrazovou funkcí původního objektu. Jako nejlepšího kandidáta vybereme toho, jehož obrazová funkce se shoduje nebo se nejvíce blíží obrazové funkci původního objektu. Relaxační techniky procházejí všechny objekty p_i z prvního obrazu a p_j z druhého obrazu. Ke každé dvojici určí míru pravděpodobnosti, že objekt p_i koresponduje s objektem p_j . Následovně provádíme opravy těchto hodnot na základě vlastností sousedních bodů. Metody dynamického programování využívají rozdělení obrazů pomocí mřížky. Tu tvoříme prokládáním přímek v prvním obraze, které odpovídají přímkám v druhém obraze. Úkolem je nalezení spojnice průsečíků, s minimálním ohodnocením na základě podobnosti okolí.

Dalším kritériem při sledování pohybu objektů je změna tvaru (vzhledu) v čase. Podle toho dělíme techniky na dvě základní skupiny :

- Sledování pevných objektů.
- Sledování proměnlivých objektů.

U první skupiny si objekty zachovávají svůj tvar v čase během celé sekvence snímků. U druhé skupiny dochází při sledování pohybu ke změně tvaru obrazu objektu. Nebere se však v úvahu změna, která je způsobena různou polohou objektu vůči kameře. Příkladem první skupiny je sledování objektů vybavení kanceláře – stůl, židle, počítač a jiné. Naopak příkladem proměnlivých objektů mohou být obrysy pohybujícího se člověka nebo kontura pohybujících se rtů.

1.2. Sledování většího množství pohybujících se objektů

Problém sledování velkého množství objektů je dán prostorovou blízkostí pohybujících se objektů, přičemž musíme určit, které objekty náležejí pozorovaným trajektoriím.

Použití vybraných metod sledování pohybu objektů závisí na následujících schopnostech :

- Schopnost rozlišit mezi získanými hodnotami skutečných objektů a chybami vzniklými při extrakci objektů.
- Schopnost určit správné korespondence mezi objekty a spojit je do výsledných trajektorií.

Rozlišujeme dva typy metod při zpracování trajektorií podle způsobu, jakým provádí zpracování získaných dat :

- Hromadné zpracování : všechny pozorované objekty zpracováváme společně, pokud se nevyskytuje mizení objektů, je tato technika ideální.
- Rekurzivní zpracování : data získaná při posledním zpracování budou použita k aktualizaci předchozích výsledků.

Při sledování pohybu objektů se výzkum zaměřil na nejdůležitější problém a to určování korespondencí. Jelikož při vyhodnocování korespondencí je zpracováváno velké množství kandidátů, byly vyvinuty aplikace algoritmů využívající statistické zpracování dat. Apriorní znalosti použité ve statistických modelech se neliší mezi různými objekty. Tyto metody jsou citlivé na nastavení jednotlivých parametrů, např. u predikce Kalmanovým filtrem. Výhodou těchto metod je využití sledování pohybu objektů v závislosti na několika snímcích, což je důležité při sledování objektů se stejným vzhledem a při výskytu velkého množství objektů v pozorované sekvenci. Z tohoto důvodu však vzniká početní závislost, která s přibývajícím objekty exponenciálně roste. Koncem 90. let byla zaměřena pozornost na dva algoritmy : „Multiple hypothesis tracking“ (MHT) od D.B.Reida [9] a „Joint probabilistic data-association filter“ (JPDAF) od Bar-Shaloma [5]. Ačkoliv jsou tyto dva algoritmy odlišné zcela svou myšlenkou, mají společné dvě části. První z nich je testování měření v pořadí vývoje asociační cenové matice. Nenulový vstup $d_{i,j}$ indikuje, že naměřená hodnota z_i odpovídá cílovému objektu y_i , kde hodnota $d_{i,j}$ představuje cenu přiřazení z_i k objektu y_i . Druhou částí je, že oba algoritmy potřebují výpočet všech legálních přiřazení. Každé přiřazení

nazýváme hypotézou, která obsahuje cenu přiřazení. Tato cena je vypočtena z pravděpodobnostní hodnoty získané v předchozích výpočtech. Algoritmus JPDAF provádí aktualizaci filtru pro každou dráhu založenou na spojené pravděpodobnosti asociace mezi poslední množinou měření a každou trajektorií. Je vhodný pro sledování změní pohybujících se objektů. Dobrých výsledků se však dá dosáhnout zanedbáním hypotéz s nízkou pravděpodobností a výběrem množiny k -nejlepších. Danchick a Newman [8] připustili, že nalezení k nejlepších hypotéz lze formulovat jako klasický problém lineárního přiřazení.

Chang a Aggarwal [7] aplikovali JPDA filtr na problém 3D rekonstrukci struktury v pohybové sekvenci. Nicméně tento algoritmus je vhodný jen pro pevný počet objektů, který zůstává zachován po celou dobu sekvence. Zhang a Faugeras [1] použili „Track splitting filter“ od Smithe a Beuchlera, který je podobný algoritmu MHT a který využívá stromy a zpožděné vyhodnocení. Nicméně tato metoda dovoluje sdílení objektů v jednotlivých snímcích různými trajektoriemi, což bývá v mnoha případech nerealistické. Racionálnější tak připadá přiřazení objektu vždy jen jedné trajektorii. Určování korespondencí se tak stává rozdělením jednotlivých objektů ve snímcích do disjunktních množin.

Další možností, jak řešit problém určení korespondence, je využít heuristické metody. Deterministické algoritmy jsou mnohem jednodušší a obsahují méně parametrů. Místo funkce hustoty pravděpodobnosti jsou použity kvalitativní heuristiky pohybu, které jsou využívány k odstranění možných trajektorií a identifikaci optimálních množin trajektorií. Využívají přitom kvalitativní popis jako vyhlazenost a tuhost pohybu nebo vzdálenost od optimální dráhy. Nejpoužívanějším známým algoritmem je „greedy exchange algorithm“, který iterativně optimalizuje kritérium lokálního vyhlazeného pohybu zprůměrnovaného přes všechny objekty v sekvenci. Výhodou tohoto algoritmu je jednoduché začlenění omezení jako je maximální rychlost nebo maximální odchylka od vyhlazeného pohybu, které zvyšují kvalitu vyhodnocení.

Chetverikov [10] provedl ve své práci shrnutí 5 algoritmů, které využívají heuristických metod pro určení trajektorií. Tyto algoritmy využívají vyhlazený pohyb jako předpoklad pro ohodnocení cenové funkce definované pro tři body ve třech po sobě jdoucích snímcích. Liší se od sebe svými schopnostmi řešit problémy mizení, objevování a překrývání objektů při pohybu, což je shrnuto v tabulce (Tab. 1.1 : Souhrn vlastností).

Algoritmus	Schopnosti			
	Samo inicializující	Přerušení	Zmizení	Objevení
Sethi & Jain SJ87	+	+	-	-
Salari & Sethi SS90	+	-	+	+
Rang. & Shah RS91	-	+	-	-
Hwang HW89	+	±	-	+
IPAN Tracker IP97	+	±	+	+

Tab. 1.1 : Souhrn vlastností

Jednotlivé vlastnosti jsou ohodnoceny následovně : + vyjadřuje výskyt, - vyjadřuje absenci, ± omezená schopnost. Podrobnější porovnání těchto algoritmů naleznete v literatuře [10]. Obecný popis sledování pohybu objektů za použití predikce je obsažen v literatuře od Faugerase [1].

2. Extrakce objektů z obrazu

Prvním krokem při sledování objektů v sekvenci je extrakce objektů z jednotlivých snímků. Cílem je detekovat všechny objekty ve snímku a určit jejich polohu, popřípadě i další vlastnosti jako je obsah, křivost, textura apod. Jednou z nejpoužívanějších metod při rozdělení obrazu na objekty je *prahování* viz. literatura [13], [14]. Prahování je účinný způsob segmentace pro scény obsahující předměty na konstantním pozadí. Výpočetně je nenáročný a vždy zachovává spojitost oblastí v uzavřených spojitých hranicích. Tato metoda odděluje objekt od pozadí přidělením dvou hodnot jasů. Jedním jasnem je interpretováno pozadí a druhým jasnem objekty v obraze. Pro rozdělení obrazu na dvě hodnoty je nutné znát prahovou hodnotu. V histogramu můžeme nalézt i dvě prahové hodnoty, podle kterých rozdělíme obraz na dvě skupiny objektů a pozadí. Najít pravidlo pro určení, zda je histogram bimodální, není jednoduché, protože neumíme vždy jednoznačně rozhodnout o významu lokálních maxim a minim.

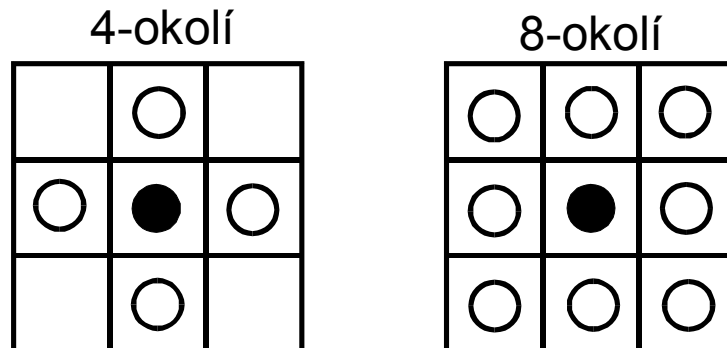
Základní postup při vyhledávání prahové hodnoty je následující :

1. Určíme minimální vzdálenost d pro jasové úrovně.
2. Najdeme dvě největší lokální maxima v histogramu, které jsou od sebe vzdálené nejméně d .
3. Mezi těmito maximy najdeme minimum, které označíme jako práh.

Jakmile známe hodnotu prahu, můžeme převést obraz na dvouúrovňový snímek. Úrovní větším než práh přidělíme hodnotu L a úrovní menším než práh přidělíme hodnotu H . Nyní nám body označené jednou hodnotou představují extrahované objekty a zbylé body představují pozadí, čímž jsme docílili oddělení objektů od pozadí. Prahování je účinné, mají-li sledované objekty stejnou vnitřní úroveň barvy, která se však odlišuje od úrovně barvy pozadí. Liší-li se objekty od pozadí jinou vlastností než úrovní barvy, např. texturou, je obvykle výhodné vhodnou operací převést tuto vlastnost na úroveň barvy.

V dalším kroku provádíme extrakci objektů z obrazu. Existuje více způsobů jak zjistit polohu objektů a jejich vlastnosti, které využijeme při určení korespondence objektů. Jedním z nich je procházet obraz po řádcích. Narazíme-li na bod o úrovni, která nám představuje objekt, spustíme z tohoto bodu semínkový algoritmus testování. Tento algoritmus testuje okolní body zadaného bodu, zda patří objektu. Podle počtu testovaných bodů dělíme

algoritmy na testování 4-okolí nebo 8-okolí viz. obrázek (Obr. 2.1 : Okolí bodu). Druhý algoritmus má výhodu v prohledávání i rohových bodů.



Obr. 2.1 : Okolí bodu

Výstupem semínkového algoritmu je množina všech bodů patřící k danému objektu, představovaného plochou bodů o dané úrovni. Z této množiny pak určíme souřadnice těžiště objektu zprůměrováním souřadnic bodů objektu :


$$x_T = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{a} \quad y_T = \frac{1}{n} \sum_{i=1}^n y_i, \quad (2.1)$$

kde x_i a y_i jsou souřadnice bodů, které připadly objektu a n představuje celkový počet bodů objektu. Z těchto bodů pak můžeme dále zjistit obvod, obsah, tvar a jiné vlastnosti objektu, které můžeme dále využít jako pomocný nástroj při určování korespondencí.

2.1. Problémy při extrakci objektů

Nasnímaný pohyb člověka je pořízen v temné místnosti, přičemž značky jsou nasvíceny ultrafialovým světlem z důvodu potlačení vlivu okolí a vyniknutí značek. Značky po nasnímání kamerou však obsahují různé stupně odstínů bílé barvy a při nízkém prahu se rozpadají, tzn. jejich okrajové body vytvářejí samostatné objekty. Při nastavení vysokého prahu však v obraze přibývají chybné objekty. Vliv na vzhled objektů mají i komprimované AVI sekvence. Při komprimaci tvoří vyšší stupně odstínu barvy objektu rušivé okolí. Proto je výhodné prah nastavit ručně pro konkrétní sekvenci.

Další problém při snímání pohybu vzniká nedokonalostí snímacího zařízení, kdy rychle pohybující značky vytvářejí ve snímku protažený objekt. Tento problém vzniká příliš dlouhou expozicí v jednotlivých snímcích viz. obrázek (Obr. 2.2 : Rozmazání objektu rychlým pohybem).




Obr. 2.2 : Rozmazání objektu rychlým pohybem

Nedošlo-li při rozmazání k překrytí s jinými objekty, je objekt detekován jako jeden, i když má větší objem. Jeho těžiště však může být vlivem rozmazání a zvětšení objemu posunuté. Dojde-li však vlivem rozmazání ke spojení objektů, nedokážeme rozlišit u kolika objektů došlo ke splynutí a jakým podílem působí rozmazaný objekt. V kapitole 5.7 je popsán problém při překrývání objektů, jehož řešením je detekce splynutí pomocí objemu objektu. V tomto případě je však metoda neúčinná a nedokážeme rozlišit na základě objemu zda došlo k rozmazání objektu či k překrytí.

3. Určení korespondence

Při sledování pohybu objektů potřebujeme určit trajektorie, po kterých se objekty pohybují. Tyto trajektorie se skládají z poloh jednotlivých objektů v jednotlivých snímcích. V našem případě je problém určování korespondence zaměřen na případ, kdy mají všechny sledované objekty stejný vzhled. Z tohoto důvodu nemůžeme při určování korespondencí




Obr. 3.1 : Korespondence objektů

využít vlastností objektů. Kdybychom předpokládali, že všech M objektů se bude vyskytovat v n snímcích, byl by počet všech možných trajektorií roven $(M!)^{n-1}$. Mezi těmito trajektoriemi se nachází unikátní trajektorie, které popisují skutečný pohyb objektů. Abychom mohli tyto trajektorie identifikovat, potřebujeme mít znalosti o pohybu objektů. Tyto znalosti získáme z dosavadního chování objektu. Z poloh v jednotlivých snímcích jsme schopni vypočítat rychlost a zrychlení sledovaného objektu. Při sledování pohybu vycházíme většinou z předpokladu vyhlazeného pohybu objektů. Tímto předpokladem můžeme vyloučit trajektorie, které z fyzikálního hlediska nemají význam. Cílem je pak každému objektu ve snímku t přiřadit jeho korespondující objekt v následujícím snímku $t+1$ viz. obrázek (Obr. 3.1 : Korespondence objektů).

Pro pozorované objekty vytvoříme stavový vektor pohybu a vybereme vhodný kinematický model, který nejlépe popisuje jeho změny v čase viz. kapitola 4.1. S pomocí zvolených modelů předpovíme polohu v následujícím snímku $t+1$ a vypočteme pravděpodobnost této předpovědi. Pravděpodobnost pak slouží k určení oblasti kolem předpověděné pozice \hat{X}_{t+1} viz obrázek (Obr. 3.2 : Predikovaná oblast). Oblast bývá většinou

kruh o poloměru r . V této oblasti se mohou nacházet kandidátní objekty Y_{t+1} . Z této množiny kandidátů pak vybereme jednoho nejlepšího, který bude reprezentovat korespondující objekt X_{t+1} .



Obr. 3.2 : Predikovaná oblast


3.1. Problémy korespondence objektů

Během pohybu objektů v sekvenci mohou nastat následující případy :

- Objekty se mohou při pohybu vzájemně překrývat.
- Objekty mohou v sekvenci mizet a objevovat se na jiných místech.
- V sledované sekvenci snímků se může pohybovat větší množství objektů, čímž vzniká problém víceznačného přiřazení.
- Chyby při snímání obrazu kamerou – objekty mohou při rychlejším pohybu zanechávat stopu svého obrazu a tím vznikají ve snímcích klamně nové objekty.
- Chyby při extrakci objektů z obrazu.

Pozorujeme-li projekci objektů z 3D scény ve 2D obraze mohou nastat případy, kdy dojde k překrytí sledovaných objektů jinými objekty ve scéně. Situace mizení a objevování objektů je znázorněna na obrázku (Obr. 3.3 : Překrývání). Pozorovaným objektem je rotující krychle. Bod A je viditelný na všech třech snímcích na rozdíl od bodu B, který je viditelný jen


v prvním snímku, v druhém a třetím snímku je neviditelný. Bod C, který není vidět na prvním a druhém snímku, se objeví až na třetím snímku.



Obr. 3.3 : Překrývání

Dalším typem překrytí, které může nastat a není zobrazeno na obrázku je překrytí v případě, kdy oba objekty leží na stejné přímce procházející středem promítání.

Na obrázku (Obr. 3.4 : Nejednoznačnost přiřazení objektů) jsou dva snímky, které obsahují stejné objekty. U těchto objektů nejsme schopni určit na základě dvou snímků jejich korespondence a dochází tu k problému nejednoznačnosti přiřazení. Tento problém můžeme vyřešit, máme-li k dispozici větší počet snímků, kde je pak korespondenci z kontextu možné vyvodit.



Obr. 3.4 : Nejednoznačnost přiřazení objektů

Vyskytuje-li se v obraze příliš velké množství objektů, může dojít k problému přeplnění. Existuje zde totiž velká pravděpodobnost výběru nesprávného kandidáta, jelikož mohou být v tomto případě kandidáti blízko u sebe. Řešením je vhodné nastavení parametrů použité pro predikci a tak minimalizovat okolí predikované pozice objektu. Toto řešení však nemusí být dostačující, a proto se využívá navíc zpožděného vyhodnocení, které je popsáno v kapitole 5.

Další problémy se mohou vyskytnout, jestliže je pohyb objektu nerovnoměrný, nebo se pohybuje tak rychle, že změna polohy mezi snímky je příliš velká. To způsobuje problémy při predikci nové polohy objektu. Proto některé metody požadují pro správnou predikci polohy objektu vyhlazený pohyb s dostatečně malými rozdíly změny polohy při pohybu.

4. Kalmanův filtr pro predikci polohy

Kalmanův filtr je adaptivní filtr používaný k modelování stavů diskrétního dynamického systému. Tato technika byla vyvinuta v 60tých letech k filtraci šumu v elektrických signálech, ale později našla uplatnění i v sledování objektů v aplikacích počítačového vidění. Výhodou tohoto filtru je jeho rekurzivní struktura, přičemž jeho koeficienty se v každém kroku upravují na základě dostupné informace tak, aby poskytly optimální odhad budoucího stavu. Nový filtr v každém kroku vzniká opravou filtru z kroku předcházejícího na základě nově příšle informace, aniž by bylo třeba pamatovat všechny předchozí hodnoty vstupních parametrů.

U Kalmanova filtru můžeme využít stavové reprezentace, která umožňuje vytvářet systémy vyšších řádů jako simultánně pracující soustavu vzájemně vázaných systémů prvního řádu.

4.1. Aplikace Kalmanova filtru na pohyb objektů

Pohyb objektu můžeme specifikovat polohou $x(t)$, rychlostí $v(t)$ a zrychlením $a(t)$, což popíšeme následujícími diferenciálními rovnicemi :

$$v(t) = \dot{x}(t) = \frac{dx(t)}{dt} , \quad (4.1)$$

$$a(t) = \dot{v}(t) = \frac{dv(t)}{dt} . \quad (4.2)$$

Pozice objektu a rychlost jsou uloženy ve stavovém vektoru. Tento vektor obvykle obsahuje první derivace jeho komponent. Abychom popsali pohyb objektu dokonale i pro případ změny zrychlení, bude obsahovat stavový vektor polohu x , rychlost v a zrychlení a .

$$\begin{bmatrix} x \\ v \\ a \end{bmatrix} = \begin{bmatrix} x \\ \dot{x} \\ \ddot{x} \end{bmatrix} . \quad (4.3)$$

Vzhledem k zvolenému stavovému vektoru použijeme následující rovnice, které popisují pohyb objektu :

$$x(t+T) = x(t) + v(t) * T + \frac{1}{2} aT^2 , \quad (4.4)$$

$$v(t+T) = v(t) + a(t) * T. \quad (4.5)$$

Pro naši soustavu přepíšeme rovnice pohybu následovně a dostaneme stavovou rovnici:

$$\mathbf{x}(t+T) = \Phi(T)\mathbf{x}(t) + \mathbf{w}(t) , \quad (4.6)$$

$$\begin{pmatrix} x(t+T) \\ \dot{x}(t+T) \\ \ddot{x}(t+T) \end{pmatrix} = \begin{pmatrix} 1 & T & \frac{T^2}{2} \\ 0 & 1 & T \\ 0 & 0 & 1 \end{pmatrix} * \begin{pmatrix} x(t) \\ \dot{x}(t) \\ \ddot{x}(t) \end{pmatrix} + \begin{pmatrix} w_1(t) \\ w_2(t) \\ w_3(t) \end{pmatrix} . \quad (4.7)$$

kde T představuje krok vzorkování, nebo-li časový úsek mezi naměřenými hodnotami polohy objektu. Pro danou stavovou rovnici (4.6) a stavový vektor se třemi hodnotami (4.3) má rozšiřující matice tvar :

$$\Phi(T) = \begin{bmatrix} 1 & T & \frac{T^2}{2} \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix} . \quad (4.8)$$

Naměřené hodnoty obvykle obsahují méně informace než stavový vektor. Při sledování pohybu objektu budeme mít k dispozici jen informaci o jeho poloze $x(t)$. Stavový vektor naměřených hodnot má však stejný tvar jako stavový vektor využívající Kalmanův filtr. Z tohoto důvodu musíme provést transformaci vstupní polohy pro stavový vektor obsahující polohu, rychlost a zrychlení :

$$y(t) = Hx(t) + v(t) . \quad (4.9)$$

Pro transformaci využijeme matici H , která má pro náš případ tvar :

$$H = (1 \quad 0 \quad 0) . \quad (4.10)$$

Po dosazení do rovnice (4.9) dostaneme :

$$y(t) = (1 \quad 0 \quad 0) * \begin{pmatrix} x(t) \\ \dot{x}(t) \\ \ddot{x}(t) \end{pmatrix} + v(t) , \quad (4.11)$$

přičemž měření je zkresleno hodnotou $v(t)$.

Předpokládáme-li, že $v(t)$ a $w(t)$ se chovají jako náhodný proces s charakterem bílého šumu s nulovou střední hodnotou, bude mít kovarianční matice tvar :

$$\mathcal{E} \left\{ \begin{bmatrix} w(t) \\ v(t) \end{bmatrix} \begin{bmatrix} w(t) \\ v(t) \end{bmatrix}^T \right\} = \begin{bmatrix} Q & 0 \\ 0 & R \end{bmatrix}. \quad (4.12)$$

Matice Q představuje manévrovací šum :

$$Q(t) = E[w(t)w(t)^T]. \quad (4.13)$$

Matice R představuje šum měření :

$$R(t) = E[v(t)v(t)^T]. \quad (4.14)$$

V další části budeme vyjadřovat hodnoty prvků v čase t pomocí indexů k .

4.2. Inicializace Kalmanova filtru

Na počátku sledování objektu (čas $t = 0$) máme k dispozici hodnotu polohy objektu a tedy jeho stavový vektor. Nemáme žádné poznatky o chování objektu v předchozím čase, a proto musíme nastavit počáteční hodnoty matic šumů a Kalmanova zisku s ohledem na tuto skutečnost. V dalších krocích Kalmanova filtru se hodnoty postupně upraví.

Při pozorování počátečního snímku máme k dispozici informace jen o poloze objektu $x(0)$, stavový vektor bude tedy vypadat následovně :

$$\begin{bmatrix} x(0) \\ 0 \\ 0 \end{bmatrix}. \quad (4.15)$$

4.2.1. Kovarianční matice a matice chyb

Odhady chyb (nejistoty) udržujeme v kovarianční matici označené jako P . Matice tedy obsahuje kovariance naměřených a odhadnutých hodnot. Při inicializaci nastavíme hodnoty λ_i na diagonále matice na velmi velká čísla, jelikož neznáme dosavadní chování sledovaného objektu. Velké hodnoty prvků kovarianční matice představují nedůvěru v naměřené hodnoty a filtr se tak bude přiklánět značnou mírou k predikovaným hodnotám.

Nastavením dostatečně velkých hodnot zajistíme předpoklad, že změna polohy v příštím snímku bude malá. Počáteční kovarianční matice má pak následující tvar :

$$P = \begin{bmatrix} r_{11} & 0 & 0 \\ 0 & \lambda_1 & 0 \\ 0 & 0 & \lambda_2 \end{bmatrix} . \quad (4.16)$$

Diagonály představují disperse komponent stavového vektoru. Hodnota r_{11} je chyba měření, tedy nepřesnost měřené polohy objektu. Každé měření může mít nějakou náhodnou chybu. Matice chyb měření je čtvercová matice, jejíž velikost je rovna počtu měřených hodnot. Tato matice obsahuje odhady chyb měřícího systému pro každou měřenou hodnotu na rozdíl od kovarianční matice, která obsahuje odhady chyb filtru. Pro naměřenou hodnotu polohy y_k určíme základní chybu měření u . Tato chyba bude pro náš případ v jednotkách určení polohy objektu. Matice měřeného šumu R bude mít pak hodnotu :

$$R = [r_{11}] = [u^2] . \quad (4.17)$$

4.3. Výpočet zlepšení

Při výpočtu nové predikované hodnoty polohy a zjištění polohy objektu je potřeba vypočítat zlepšení, tedy rozdíl hodnot mezi predikovanou polohou a naměřenou polohou. Jestliže nemáme k dispozici všechny naměřené hodnoty, které obsahuje stavový vektor, musíme provést transformaci stavového vektoru pomocí matice H . Obecný vztah pro výpočet zlepšení má tvar :

$$Z = Y - \tilde{X} . \quad (4.18)$$

kde Y je stavový vektor měření a \tilde{X} je predikovaný stavový vektor. V našem případě vypočteme zlepšení z naměřené polohy y_k a predikované polohy objektu x_k .

$$z_k = [y_k] - [1 \ 0 \ 0] \begin{bmatrix} x_k \\ \dot{x}_k \\ \ddot{x}_k \end{bmatrix} \text{ tedy } z_k = y_k - x_k . \quad (4.19)$$

Zlepšení se mimo jiné využívá při určování poloměru predikované oblasti, či k určení spouštění přidávání manévrovacího šumu ke kovarianční matici.

4.4. Maximální odchylka od predikované hodnoty

Při výpočtu predikované polohy kontrolujeme, zda je naměřená hodnota dostatečně blízko predikované hodnotě. Někdy totiž může dojít k tomu, že naměřená hodnota má příliš velkou odchylku od predikované, v takovém případě můžeme hodnotu extrapolovat a pokračovat dál s extrapolovanou hodnotou nebo ji prohlásit za chybnou.

Hodnotu prahu odchylky můžeme pevně zvolit pro všechny kroky Kalmanova filtru, nebo ji adaptivně přizpůsobovat. Při adaptivním výpočtu využíváme nejistot obsažených v kovarianční matici. Jednou z možností jak vypočítat tuto odchylku je výpočet pomocí Mahalanobovy vzdálenosti [1] :

$$d_k = (y_k - H\tilde{x}_k)\tilde{P}_k^{-1}(y_k - H\tilde{x}_k). \quad (4.20)$$

Naměřené hodnoty, které mají menší vzdálenost od predikované hodnoty než je vypočtená odchylka, spadají do množiny potencionálních výsledků viz.kapitola 3.

4.5. Výpočet zisku a aktualizace stavového vektoru

V této fázi již máme vypočítané zlepšení a nyní je potřeba vypočítat Kalmanův zisk, který indikuje jak velkou mírou ovlivňuje zlepšení odhad. Kalmanův zisk je uložen v matici K se stejným počtem elementů jako stavový vektor. Hodnoty zisku jsou obvykle v rozmezí 0 až 1. V systému, kde nemáme k dispozici pokaždé naměřenou hodnotu, jsou hodnoty zisku korespondující s nenaměřenými hodnotami během několika prvních cyklů větší než jedna. Tato vlastnost je závislá na počátečních hodnotách stavového vektoru [11].

Kalmanův zisk vypočítáme podle následujícího vztahu :

$$K_k = \tilde{P}_k H_k^T [H_k \tilde{P}_k H_k^T + R_k]^{-1}. \quad (4.21)$$

Pro zjednodušení výpočtu, si zjednodušíme vztah výpočtem inverzní matice pro náš daný případ.

$$K = \tilde{P}_k \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \left(\begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} p_{11} & p_{12} & p_{13} \\ p_{21} & p_{22} & p_{23} \\ p_{31} & p_{32} & p_{33} \end{bmatrix} \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} + \begin{bmatrix} r_{11}^2 \end{bmatrix} \right)^{-1}. \quad (4.22)$$

Dosazením a zjednodušením dostaneme následující rovnici :

$$K = \begin{bmatrix} p_{11} \\ p_{21} \\ p_{31} \end{bmatrix} \left(\frac{1}{p_{11} + r_{11}^2} \right) . \quad (4.23)$$

Kalmanův zisk vypočtený pro náš případ obsahuje tři hodnoty, pro každou položku stavového vektoru jednu. Máme-li vypočteny hodnoty Kalmanova zisku, můžeme provést určení odhadu stavového vektoru :

$$\hat{x}_k = \tilde{x}_k + K_k z_k . \quad (4.25)$$

Po provedení aktualizace stavového vektoru jsme schopni vypočítat predikovanou hodnotu stavového vektoru v následujícím čase $k+1$:

$$\tilde{x}_{k+1} = \Phi \hat{x}_k . \quad (4.26)$$

4.6. Výpočet kovarianční matice

Aktualizujeme-li stavový vektor hodnotami nového měření, musíme také aktualizovat kovarianční matici. Výpočet nové hodnoty odhadu kovarianční matice je následující :

$$\hat{P}_k = [I - K_k H_k] \tilde{P}_k . \quad (4.27)$$

Po dosazení a zjednodušení pro náš případ dostaneme :


$$\hat{P}_k = \begin{bmatrix} 1 - k_1 & 0 & 0 \\ -k_2 & 1 & 0 \\ -k_3 & 0 & 1 \end{bmatrix} * \begin{bmatrix} p_{11} & p_{12} & p_{13} \\ p_{21} & p_{22} & p_{23} \\ p_{31} & p_{32} & p_{33} \end{bmatrix} . \quad (4.28)$$

Odhadnuté hodnoty stavového vektoru obsahují chyby, které se rozšiřují každým cyklem filtru. Nové odhady by se stávaly horšími a nejistota by se zvyšovala. Proto provádíme vynásobení kovarianční matice rozšiřující maticí Φ_k . Pro výpočet predikční kovarianční matice potřebujeme znát navíc hodnotu manévrovacího šumu, jehož výpočet je popsán v následující kapitole. Známe-li novou hodnotu matice Q_k manévrovacího šumu, vypočteme predikovanou kovarianční matici následovně :

$$\tilde{P}_{k+1} = \Phi_k \hat{P}_k \Phi_k^T + Q_k . \quad (4.29)$$

4.7. Manévrovací matice

Při změně pohybu objektu může dojít k případu, kdy se predikované hodnoty odchyli od naměřených a tato odchylka se bude v dalších krocích zvětšovat. Abychom mohli sledovat objekt, který mění směr a rychlost pohybu, musíme přičíst ještě ke kovarianční matici tzv. manévrovací šum označený Q . Tím dosáhneme dostatečně velkých nejistot tak, aby mohli postihnout i výchylku ze směru pohybu. Pokud je Q velmi malé, může dojít k chybě filtru, jestliže objekt prudce změní polohu což je znázorněno na obrázku (Obr. 4.1 : Odchylka od predikce od naměřených hodnot).



Obr. 4.1 : Odchylka od predikce od naměřených hodnot

Jeden z jednoduchých modelů pro manévrovací šum říká, že objekt se pohybuje s náhodným zrychlením se standardní odchylkou δ_a viz. literatura [11]. Použijeme-li stavový vektor se třemi prvky, můžeme modelovat zvyšování nejistoty ve zrychlení následovně :

$$Q_0 = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & \delta_a \end{bmatrix}. \quad (4.30)$$

Náhodné zrychlení má vliv na ostatní komponenty, což způsobí rozšíření Q_0 stejně jako u kovarianční matice :

$$Q = \Phi Q_0 \Phi^T. \quad (4.31)$$

$$Q = \delta_a^2 \begin{bmatrix} T^4/4 & T^3/2 & T^4/4 \\ T^3/2 & T^2 & T \\ T^2/4 & T & 1 \end{bmatrix}. \quad (4.32)$$

Objekt nemění svůj směr pohybu pořád a proto by jsme neměli používat přidávání manévrovacího šumu neustále. Použijeme proto metodu detekce změny pohybu, abychom mohli zvolit správný model manévrovacího šumu. Nejjednodušší používanou metodou je počítání kladných a záporných zlepšení uvnitř vybraného okna. Pokud dojde k detekci změny pohybu objektu, použijeme zvolený model manévrovacího šumu.

$$C = \sum_{k=i-n}^i \text{sign}(z_k) \quad (4.33)$$

Změna pohybu nastane, jeli $\text{abs}(C)$ větší jak zvolený práh. Tedy pokud bylo zjištěno větší množství kladných nebo záporných odchylek od predikované hodnoty. Další metoda je detekce průměrováním, kdy si detektor pamatuje posledních N zlepšení a počítá jejich průměr.

$$C_p = k \frac{1}{n} \sum_{k=i-n}^i z_k \quad (4.34)$$

Jakmile průměr překročí určitou mez, můžeme zvolit jiný model manévrovacího šumu. Tato metoda kvantitativně měří velikost změny pohybu a má výhodu v tom, že můžeme použít víc než jeden model manévrovacího šumu. Volba závisí na velikosti odchylky od průměrné hodnoty.

4.8. Postup výpočtu

V této kapitole jsou shrnuty všechny rovnice pro použití Kalmanova filtru. Stavové rovnice a rovnice měření jsou následující :

$$z_k = y_k - H_k \tilde{x}_k \quad \text{Zlepšení} = \text{měřená hodnota} - \text{predikce} \quad (4.35)$$

$$\hat{x}_k = \tilde{x}_k + K_k z_k \quad \text{Odhad stavu} \quad (4.36)$$

$$\tilde{x}_{k+1} = \Phi \hat{x}_k \quad \text{Predikce stavu} \quad (4.37)$$

Kalmanův zisk a chybové kovarianční rovnice :

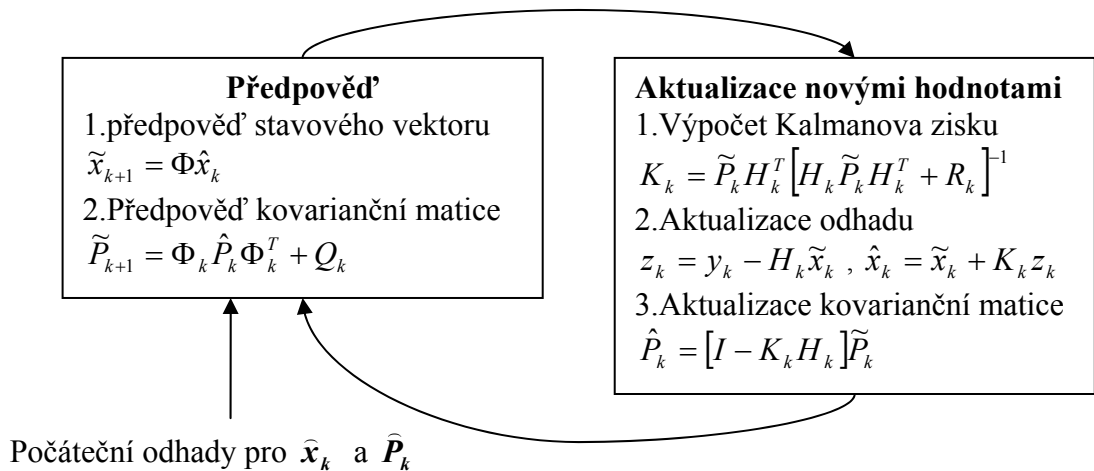
$$K_k = \tilde{P}_k H_k^T [H_k \tilde{P}_k H_k^T + R_k]^{-1} \quad \text{Kalmanův zisk} \quad (4.38)$$

$$\hat{P}_k = [I - K_k H_k] \tilde{P}_k \quad \text{Odhad kovarianční matice} \quad (4.39)$$

$$\tilde{P}_{k+1} = \Phi_k \hat{P}_k \Phi_k^T + Q_k \quad \text{Predikce kovarianční matice} \quad (4.40)$$

Na obrázku (Obr. 4.2 : Diagram rekurze) je znázorněn diagram postupu jednotlivých kroků při výpočtu. Předpověď nové polohy se skládá ze dvou kroků :

- Aktualizace filtru
- Předpověď nových hodnot



Obr. 4.2 : Diagram rekurze

Získáme-li nové hodnoty měření, můžeme provést aktualizaci filtru. Při aktualizaci se vypočtou nové hodnoty koeficientů s ohledem na nové měření. Filtr se tak přizpůsobuje novým naměřeným hodnotám. V dalším kroku pak můžeme provést předpověď nového stavového vektoru a kovarianční matice. V tomto okamžiku obsahuje stavový vektor predikované hodnoty polohy, rychlosti a zrychlení. Tento postup můžeme opakovat s každým nově příchozím měřením, přičemž nám bude Kalmanův filtr poskytovat v každém kroku nové predikované hodnoty stavového vektoru.

Při predikci však může nastat případ, kdy nemáme k dispozici naměřené hodnoty a potřebujeme provádět predikci dál. Kalmanův filtr má schopnost provádět extrapolaci stavového vektoru i při nezadaných naměřených hodnotách. V tomto případě budou nastaveny koeficienty Kalmanova zisku na 0. Aktualizace odhadu stavového vektoru bude rovna extrapolovanému stavovému vektoru, jelikož nemáme novou vstupní hodnotu, ze které

bychom mohli vypočítat zlepšení z_k . Kalmanův filtr bude provádět jen extrapolaci stavového vektoru a kovarianční matice, přičemž manévrovací šum nebude použit. Postupnou extrapolací hodnot se snižuje pravděpodobnost správné předpovědi filtru. Snižování kvality extrapolovaných hodnot se projeví zvýšením neurčitosti predikce a tím ke zvýšení hodnot prvků kovarianční matice.

5. Identifikace trajektorie

Zaměříme se na sledování objektů jednou statickou kamerou. Problém je omezen na 2D projekci skutečného 3D pohybu. Necht' F_k , $k = 1, 2, \dots, M$ je k-tý sledovaný snímek sekvence, kde M vyjadřuje celkový počet snímků. V každém snímku F_k předpokládáme nalezení určitého počtu objektů, přičemž se počet může v různých snímcích měnit. Vzhledem k vlastnostem pohybu objektů použijeme metody využívající predikce pohybu pomocí Kalmanova filtru. Máme-li v pozorované sekvenci snímků všechny objekty se stejným obrazem, nemůžeme využít ke zpřesnění určování korespondence vlastností objektů. Jsme tedy omezeni jen na predikci příští polohy objektu z dosavadního chování objektu. Použijeme-li sledování pohybu objektu v závislosti na několika po sobě jdoucích snímcích, vznikne nám ke každé sledované trajektorii několik hypotéz přiřazení jednotlivých objektů ve snímcích. Tyto hypotézy vytvoří tzv. predikční strom viz. obrázek (Obr. 5.2 : Predikční strom). Hypotéza tedy obsahuje sledovanou trajektorii a kandidátní objekty, které představují možné pokračující objekty v trajektorii. Ke každé hypotéze provádíme predikci příští polohy objektu, kterou pak porovnáváme s nalezenými objekty z aktuálního sledovaného snímku. Výběr kandidátů pro jednotlivé hypotézy popisuje kapitola 5.2.

Objekty mohou být součástí pokračujících trajektorií, nebo mohou představovat počáteční objekt nově vzniklé trajektorie. Abychom mohli vyhodnotit přiřazení jednotlivých objektů, musíme použít metodu prořezání stromů popsánu v kapitole 5.4. Při použití této metody využíváme zpožděného vyhodnocování. Při pohybu objektů však dochází k mizení objektů, a tím i ukončování trajektorií nebo k objevení objektů, čímž vznikají nové trajektorie. Neposledním problémem je i překrývání objektů, při kterém nastane zmizení jednoho, či více překrytých objektů. Jelikož využíváme zpožděného vyhodnocování, stává se určování zmizení a objevení objektu komplikovanějším. Vyhodnocování výsledných kandidátních objektů, které náleží jednotlivým trajektoriím provádíme o n kroků zpět, kde n představuje výšku predikčního stromu. Použití predikčního stromu předpokládá využití metody zpětného vyhodnocování. O objevení či zmizení objektu nedokážeme rozhodnout v okamžiku, kdy tato situace nastala, jelikož výsledné přiřazení objektů je provedeno o n kroků později. Tato metoda se nejvíce týká vyhodnocování ukončených nebo vzniklých trajektorií. Výslednou trajektorii definujeme jako seznam objektů z jednotlivých snímků. Po vyhodnocení je každý

objekt přiřazen jen jediné trajektorii. Za tohoto předpokladu provedeme přiřazení objektů do disjunktních množin.

5.1. Ohodnocení trajektorií

Abychom mohli určovat výsledné přiřazení objektů trajektoriím, provádíme ohodnocení jednotlivých hypotéz. Každá hypotéza obsahuje pravděpodobnost, se kterou patří objekty dané trajektorii. Tuto pravděpodobnost reprezentuje ohodnocení přiřazení objektů hypotéze, které můžeme počítat různými způsoby.

Jedním z nich je průměr odchylek naměřených hodnot od predikovaných :

$$K_1 = \frac{1}{n} \sum_{i=k}^{k+n} (z_{x,i} + z_{y,i}) . \quad (5.1)$$

kde k představuje číslo aktuálního snímku, n je hloubka stromu a z je odchylka od predikované hodnoty pro x a y souřadnice. Další variantou je výpočet odchylek zvlášť pro x a y souřadnice, přičemž porovnání provádíme opět zvlášť pro práh v ose x a v ose y . Odchytky bereme jen z posledních n úrovní stromu, jelikož polohy těchto objektů mají vliv na výslednou pravděpodobnost hypotézy. Ostatní objekty v trajektorii jsou již unikátně přiřazeny. Toto kritérium se často využívá, avšak jistou nevýhodou jsou větší odchylky od predikce při náhlé změně směru. Tato vlastnost může způsobit chybné určování korespondencí v případech, kdy se mění směr pohybu dvou trajektorií, jejichž objekty padnou do obou predikčních oblastí.

Dalším možným kritériem je výpočet rozdělení zrychlení a posunutí mezi snímky. Počítáme jej vždy ze tří po sobě jdoucích bodů jako rozdíl rozdílů vzdáleností. Toto okénko tří bodů pak posouváme po sledované trajektorii od konce až k rozvětvení stromu. Dáváme přitom přednost malým odchylkám.

5.2. Přiřazení objektů hypotézám

Pro přiřazení objektů k jednotlivým hypotézám využíváme predikci příští polohy objektu. Predikce nám určí oblast, ve které by se měl vyskytovat pozorovaný objekt v příštím snímku viz. obrázek (Obr. 3.2 : Predikovaná oblast). Jednou z možností jak určit tuto oblast je výpočet poloměru predikované oblasti pomocí Mahalanobovy vzdálenosti viz. kapitola 4.4. Výsledné objekty určíme podle toho, zda padnou do oblasti vymezené touto vzdáleností od predikované polohy.

Nepotřebujeme-li při určování predikované oblasti velkou přesnost, můžeme využít Kalmanova filtru pro rozhodnutí, zda nová hodnota vyhovuje předchozím zadaným hodnotám. Použijeme přitom koeficient kovarianční matice, podle kterého určíme, zda se zadaná poloha příliš neodchyluje od predikované. O přiřazení rozhodujeme na základě porovnání vypočtené odchyly polohy objektu s vypočteným prahem :

$$Pr\ \acute{a}h = konst * \sqrt{p_{11}}, \quad (5.2)$$

kde p_{11} představuje koeficient kovarianční matice. Pomocí parametru *konst* určujeme velikost odchyly. Odchyly od predikované polohy vypočteme jako absolutní hodnotu zlepšení $abs(z_k)$ podle rovnice 4.18 a 4.19. Nyní můžeme porovnat tuto odchyly s vypočteným prahem a určit výsledné kandidáty :

$$Kandidát = \begin{cases} Ano & abs(z_k) < Pr\ \acute{a}h \\ Ne & jinak \end{cases}$$

Jelikož poloha pozorovaného objektu obsahuje souřadnice x a y, používáme Kalmanovy filtry pro obě souřadnice. Aby mohl být objekt prohlášen za kandidáta hypotézy, musí být splněna předchozí podmínka pro x a y souřadnici současně.

5.3. Implementace predikce


Pro sledování pohybu objektů v 2D obraze provádíme predikci polohy objektů zvlášť pro x a y souřadnice. V kapitole 4 je popsána aplikace Kalmanova filtru na predikci pohybu v jedné ose. Pro sledování pohybu v obou osách použijeme tedy dva nezávislé Kalmanovy filtry. Na začátku sledování pohybu objektů nemáme o jejich chování žádnou informaci. V počátečním snímku známe jen polohy objektů, které se v něm vyskytují. Každému objektu přidělíme Kalmanův filtr pro x a y souřadnice a provedeme jejich inicializaci. Každá sledovaná trajektorie bude mít přidělený Kalmanův filtr pro x a y souřadnice a bude obsahovat seznam poloh pozorovaného objektu v jednotlivých snímcích. Tyto informace jsou uloženy v objektu, který nazveme „Tracker“. Tento objekt poskytuje výpočet predikované polohy objektu na základě dosavadních poloh v jednotlivých snímcích a poskytuje uchování ukazatelů na objekty obsažené v sledované trajektorii. Tracker tak představuje implementaci hypotézy pro sledovanou trajektorii.

Na začátku sledování pohybu objektů musíme provést inicializaci. Po inicializaci bude každý objekt z prvního sledovaného snímku představovat začátek sledované trajektorie.

Vznikne nám tedy stejný počet hypotéz jako je objektů v prvním snímku sekvence. V prvním kroku bude filtr predikovat stejnou polohu jako při inicializaci, jelikož počáteční hodnoty rychlosti a zrychlení jsou nulové. Hodnoty kovarianční matice jsou nastaveny na vysoké hodnoty tak, aby představovaly neurčitost predikce. Kalmanův filtr bude tedy v počátečních krocích brát více v úvahu naměřené hodnoty, na rozdíl od predikovaných. V dalších snímcích pak budeme pokračovat následujícím způsobem :

1. Provedeme extrakci objektů z aktuálního snímku a určíme jejich polohu.
2. Pro všechny hypotézy (trackery), které jsou v seznamu aktuálně sledovaných hypotéz, provedeme predikci příští polohy.
3. Každé hypotéze přiřadíme objekty, které padly do její predikované oblasti.
4. Provedeme prořezání stromu v nejvyšší úrovni, kde dochází k rozvětvení.
5. Provedeme vyhodnocení nově vzniklých a ukončených trajektorií, pokud existují.

Na konci sledování pohybu trajektorií, tedy na konci sledované sekvence, musíme provést vyhodnocení (prořezání) rozvětvených stromů tak, aby byly určeny i nevyhodnocené úrovně. V bodě 3. mohou nastat dva případy výskytu objektů v predikované oblasti, jak je znázorněno na obrázku (Obr. 5.1 : Případy výskytu predikovaných oblastí).




Obr. 5.1 : Případy výskytu predikovaných oblastí

V prvním případě a) nebyl nalezen pro sledovanou trajektorii žádný kandidátní objekt. V tomto případě došlo k ukončení trajektorie. Všechny hypotézy týkající se sledované trajektorie budou mít tedy prázdnou predikovanou oblast a budou ukončeny.

V případě b) dochází k víceznačnému přiřazení objektů k jednotlivým trajektoriím. V pozorovaném snímku padne do predikované oblasti dva a více objektů. Vzniknou tak nové hypotézy předchozích hypotéz, které budou obsahovat společné objekty.

5.4. Predikční strom

Padne-li do predikované oblasti dva a více objektů, dochází k vytvoření hypotéz se společnou trajektorií, ale s odlišnými koncovými objekty. Predikční strom, který obsahoval původní hypotézu, se tak rozvětví a vzniknou nové hypotézy představující jednotlivé větve stromu. Tento případ nastává, pohybují-li si objekty tak blízko sebe, že padnou do stejné predikované oblasti. Každým krokem pak dochází k dalšímu větvení hypotéz. Každá větev stromu představuje přiřazení různých kandidátních objektů k trajektorii. Predikční stromy tak poskytují uchování vztahů mezi jednotlivými hypotézami. Každá hypotéza, která je součástí predikčního stromu obsahuje shodné objekty trajektorií po úroveň, kde dochází k rozvětvení. Proto nám stačí uchovávat jen listy jednotlivých větví.



Obr. 5.2 : Predikční strom

Při sledování pohybu objektů se každým krokem predikční stromy rozvětřují, proto musíme použít metodu prořezání viz. kapitola 5.5, která ponechá nejlepší kandidáty a ostatní zruší. Predikční strom představuje použití metody zpětného vyhodnocování. Výhodou je určení korespondencí v závislosti na několika po sobě jdoucích snímcích.

5.5. Prořezávání stromu

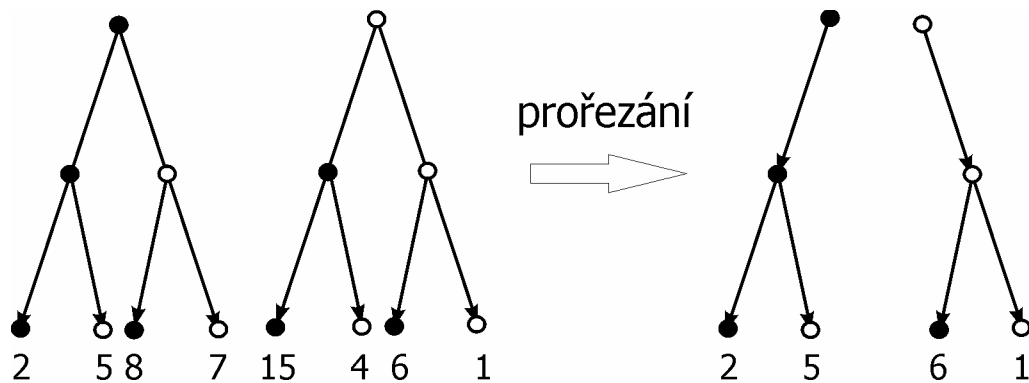
Prořezávání je jedním z klíčových algoritmů při vyhodnocování výsledných kandidátů trajektorií. Vycházíme přitom z předpokladu, že žádná z výsledných trajektorií nebude obsahovat duplicitní objekty v jednotlivých snímcích. Při překrývání objektů během pohybu

se však stává jeden objekt součástí více trajektorií. Tuto vlastnost nahradíme mizením a pozdějším objevením objektu. Již po několika krocích od rozvětvení stromu jsme schopni určit výsledného kandidáta trajektorie. Prořezávání tedy provádíme o n -kroků zpět, kde n představuje hloubku stromu.

Při prořezávání vybereme jednu kandidátní větev (hypotézu) určující, který podstrom zůstane zachován. Pro výběr kandidáta můžeme použít několik kritérií, které jsou popsány v kapitole 5.1. Při prořezávání stromu provádíme současně rušení duplicitních větví s vybranou větví s minimálním ohodnocením, abychom zachovali přiřazení objektů do disjunktních množin. Tuto kontrolu duplicit provádíme u všech aktuálně sledovaných trajektorií. Jelikož se kontrola duplicit provádí v každém kroku při ořezávání stromu, stačí kontrolovat jen $n-1$ objekt od konce trajektorie, který je synem otcovského objektu, u kterého dochází k rozvětvení stromu. Vybraný objekt porovnááme s objekty u všech aktuálně sledovaných hypotéz. Mezi ně patří všechny hypotézy, které obsahují v predikované oblasti alespoň jeden objekt. Pokud obsahuje některá hypotéza stejný objekt jako hypotéza s minimálním ohodnocením, pak je zrušena. Odstraněním duplicitních hypotéz dosáhneme zachování unikátnosti přiřazení objektů k trajektoriím. Trajektorie, které jsou součástí podstromu s daným objektem jsou však zachovány. Po vyhodnocení jsou objekty, které se nacházejí v trajektoriích od úrovně $n-1$ až po začátek, pro každou trajektorii unikátní. Tyto trajektorie jsou však součástí jednotlivých hypotéz.


Postup při prořezávání je následující :

1. Výběr větve s minimálním ohodnocením : Ze seznamu aktuálně sledovaných hypotéz vybereme hypotézu (větev) s minimálním ohodnocením.
2. Provedeme zrušení všech hypotéz (větví), které obsahují duplicitní objekty v prořezávané úrovni.
3. Podstrom, který obsahuje vybranou větev s minimálním ohodnocením, přesuneme do výstupního seznamu a zbylé větve ze stromu zrušíme.
4. Při prořezávání pokračujeme tak dlouho, dokud není vstupní seznam s hypotézami prázdný.



Obr. 5.3 : Prořezání stromů

Na obrázku (Obr. 5.3 : Prořezání stromů) je zobrazeno rozvětvení predikčních stromů pro trajektorie černého a bílého bodu, jejichž objekty padnou do obou predikovaných oblastí. Výška rozvětvení stromu je rovna 3. Pro demonstrováný případ je vybrána minimální hypotéza s ohodnocením 1. Podstrom, který obsahuje vybranou hypotézu s ohodnocením 1 přesuneme do výstupního seznamu (větvě 1,6) a ostatní hypotézy ze stromu zrušíme (větvě 15,4). Provedeme odstranění duplicitních hypotéz (větvě 7,8). V druhém kroku vybereme minimální hypotézu s ohodnocením 2. Podstrom s touto hypotézou přesuneme do výstupního seznamu (větvě 2,5). V tomto okamžiku je již vstupní seznam prázdný a prořezání je ukončeno.



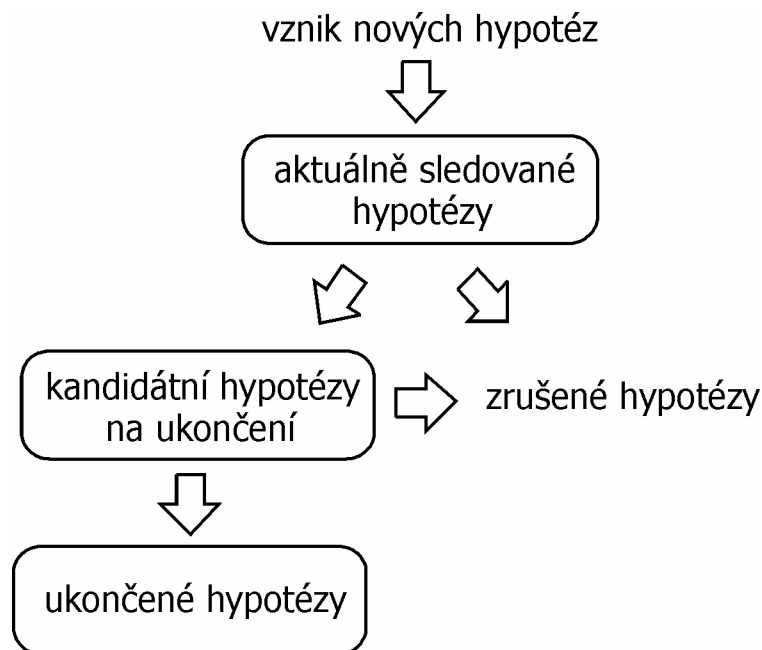
Obr. 5.4 : Rozptyl ohodnocení

Metoda hledání minimálního ohodnocení může mít v některých případech za následek výběr méně vhodného kandidáta. Příklad kdy dochází k výběru méně výhodného kandidáta je zobrazen na obrázku (Obr. 5.4 : Rozptyl ohodnocení). V prvním průchodu při prořezání je vybrána hypotéza s ohodnocením 2. Tím však pro druhý predikční strom zůstane jen kandidátní hypotéza s ohodnocením 12. Trajektorie sledující černý bod tak sice obsahuje objekt s výhodnějším ohodnocením, avšak u trajektorií dojde k chybnému přiřazení. Z tohoto příkladu je vidět, že přesnost výběru správného kandidáta při prořezávání závisí na přesnosti výpočtu ohodnocení jednotlivých hypotéz.

Testováním jsem zjistil, že lze dosáhnout dobrých výsledků již při úrovni rozvětvení rovnu 3. Tím se velmi sníží počet kandidátních hypotéz, které by vznikaly rozvětčováním predikčních stromů. Naopak při větší úrovni rozvětvení stromu se zvyšuje rozptyl hodnot ohodnocení jednotlivých objektů, přiřazených k hypotézám, což může ovlivnit přesnost vyhodnocení.

5.6. Rozbor problémů mizení a objevování

Naším cílem je rozpoznání mizení a objevení objektů v sekvenci, ke kterému dochází ukončením trajektorie, nebo vznikem nové trajektorie. Jelikož zpracováváme velké množství hypotéz, je nutné tyto hypotézy uchovávat v seznamu. Při zmizení objektu je však potřeba hypotézy, které představují zmizelou trajektorii, uložit mimo seznam aktuálně sledovaných hypotéz, jelikož pro tuto hypotézu již nebudeme hledat další kandidátní objekty. Z tohoto důvodu použijeme dva seznamy pro uložení hypotéz. Jeden bude obsahovat aktuálně sledované trajektorie, které nebyly ještě ukončeny a pro které jsou hledáni kandidátní objekty na pokračování. Druhý seznam bude obsahovat ukončené trajektorie. Neoptimální a duplicitní hypotézy budeme rušit.




Obr. 5.5 : Uchování hypotéz

Jelikož však nejsme schopni určit okamžitě zda se jedná o ukončenou hypotézu, musíme je uchovávat ve zvláštním seznamu kandidátů na ukončení, který pak dále

zpracováváme. Na obrázku (Obr. 5.5 : Uchování hypotéz) je zobrazen životní cyklus hypotéz. Rámečky zde představují seznamy jednotlivých hypotéz. Po provedení sledování pohybu v celém snímku budou výsledné hypotézy v seznamu ukončených hypotéz.

5.6.1. Objevení objektu

V sledované sekvenci může dojít k objevení nového objektu, který je začátkem nové trajektorie. V obrázku (Obr. 5.6 : Případy objevení objektu) jsou naznačeny případy, které mohou nastat při objevení nového objektu ve scéně.



Obr. 5.6 : Případy objevení objektu

V prvním případě dochází k výskytu nového objektu mimo predikované oblasti všech aktuálních hypotéz. V tomto případě můžeme provést vytvoření nové hypotézy pro bílý objekt v druhém snímku, jelikož není přiřazen žádné jiné hypotéze. V druhém případě se nový objekt nachází v predikované oblasti některé z hypotéz. Jelikož vyhodnocení přiřazení objektů nejsou v tomto okamžiku provedena, nemůžeme určit, který objekt je nově vzniklý. Vznik nového objektu je detekován až o n kroků později, kdy je provedeno zpětné vyhodnocení v této úrovni. V předchozích dvou případech bylo možno detekovat vznik objektu rozdílným počtem objektů ve dvou po sobě jdoucích snímcích. V posledním případě však dojde současně k zmišení (překrytí) i objevení objektu. Pomocí předchozí podmínky


rozdílu počtu objektů objevení detekovat nelze. Proto zde musíme počkat opět n snímků, než se vyhodnotí přiřazení objektů jednotlivým trajektoriím. Abychom tuto nově vzniklou trajektorii mohli sledovat, musíme pro ni vytvořit novou hypotézu. Tato hypotéza bude obsahovat nově vzniklý objekt jako začátek nové trajektorie. Jelikož však využíváme zpětného vyhodnocování, nejsme schopni v okamžiku objevení nového objektu určit, o který objekt se jedná z celkového počtu všech objektů ve snímku. Testování objevení nových objektů provádíme v okamžiku, kdy jsou již predikční stromy v dané úrovni vyhodnoceny. Opět zde využijeme zpětného vyhodnocování. V této úrovni porovnáme všechny objekty aktuálně sledovaných trajektorií s objekty v odpovídajícím snímku. Není-li některý z objektů ze snímku součástí aktuálně sledované trajektorie, jedná se o nový objevený objekt. Pro tento objekt provedeme inicializaci hypotézy, která bude sledovat jeho pohyb. Abychom tuto hypotézu mohli přidat do seznamu aktuálně sledovaných trajektorií provedeme $n-1$ kroků sledování jeho pohybu. Nyní je vyhodnocen pohyb tohoto nového objektu až do posledního snímku, kde jsme skončili s vyhodnocováním korespondencí. Sledování pohybu nového objektu po dobu $n-1$ snímků můžeme provádět, aniž by na tuto hypotézu měly vliv ostatní hypotézy, jelikož predikční strom pro nově vzniklou trajektorii ještě nedosáhl úrovně, kdy se vyhodnocuje v závislosti na ostatních hypotézách.

5.6.2. Mizení objektu

Nejkomplikovanějším problémem při sledování trajektorií je detekce ukončení trajektorie. Jelikož při určování správných hypotéz využíváme zpožděného vyhodnocování, nemůžeme určit zmizení objektu okamžitě, ale až po n krocích, kdy dojde k vyhodnocení přiřazení objektů. Vzhledem k tomu, že využíváme zpožděného vyhodnocování, vzniká velké množství hypotéz, ze kterých musíme vybrat nejoptimálnější unikátní hypotézy, které představují trajektorie pohybujících se bodů. Ukončené trajektorie vyhodnocujeme z hypotéz, které byly odstraněny při jednom z těchto případů :


- Prázdna predikovaná oblast.
- Odstranění při prořezání.

Dojde-li k jednomu ze dvou případů, uložíme odstraněné hypotézy do seznamu kandidátů na ukončení, který dále vyhodnocujeme a vybíráme z něj ukončené trajektorie. První případ nastane, jestliže do predikované oblasti sledované trajektorie nepadne žádný objekt v aktuálně sledovaném snímku viz. obrázek (Obr. 5.7 : Prázdna predikovaná oblast).



Obr. 5.7 : Prázdná predikovaná oblast


Tento případ zmizení objektu bude obsahovat jen jednu hypotézu, která bude uznána za ukončenou a vložena do seznamu ukončených trajektorií. Prázdné predikované oblasti se však mohou vyskytnout i u hypotéz, které se odchýlily od optimální trajektorie a jsou větvemi stromu, který stále sleduje aktivní trajektorii. Důležitým nástrojem při vyhodnocování ukončených trajektorií je proto kontrola duplicitních objektů. Při sledování pohybu jsme stanovili podmínku neduplicitních trajektorií. To znamená, že žádná z výsledných trajektorií nesmí obsahovat stejné objekty jako jiná trajektorie. Proto provádíme kontrolu duplicit před tím, než trajektorii zařadíme do seznamu kandidátů na ukončení. Kontrolou duplicit zjišťujeme zda není testovaná hypotéza součástí některého predikčního stromu, který stále ještě sleduje aktivní trajektorii. V tomto případě danou hypotézu zrušíme a nezařadíme ji do seznamu ukončených.



Obr. 5.8 : Současné ukončení trajektorií

Dojde-li ke zmizení objektu v okamžiku, kdy obsahovaly sledované hypotézy ještě jiné kandidáty, bude obsahovat seznam kandidátů na ukončené trajektorie všechny hypotézy rozvětveného stromu. Tento případ je znázorněn na obrázku (Obr. 5.8 : Současné ukončení trajektorií). V třetím snímku dojde ke zmizení obou objektů. Tyto objekty jsou součástí trajektorie tmavého a světlého bodu. Pro tyto trajektorie jsou vytvořeny hypotézy, které vytvářejí predikční strom. V okamžiku kdy dojde ke zmizení jsou jejich predikované oblasti prázdné. Hypotézy pro tyto trajektorie však nejsou v tomto okamžiku vyhodnoceny, a proto se musí provést dodatečné prořezání a vyhodnocení stromů až po listy.

Další případ, který musíme ošetřit zvlášť, je postupné ukončení trajektorií, jejichž hypotézy obsahují shodné objekty. Při zmizení objektu se přikloní hypotézy zmišlého bodu k ostatním bodům, které se vyskytují v jejich blízkosti. K odstranění těchto hypotéz ze seznamu aktivních sledovaných hypotéz dochází při prořezání nebo při prázdné predikované oblasti. Po odstranění těchto hypotéz musíme provést odstranění shodných objektů ve výsledné ukončené trajektorii. Tyto shodné objekty jsou součástí jiné trajektorie, ke které se přiklonila sledovaná trajektorie. Na obrázku (Obr. 5.9 : Postupné ukončení trajektorií) nastane ve druhém snímku zmizení světlého bodu a v třetím snímku zmizení tmavého bodu.



Obr. 5.9 : Postupné ukončení trajektorií

Při zmizení světlého bodu však nedojde k ukončení predikčního stromu, který obsahuje hypotézy sledující trajektorii světlého bodu, jelikož do predikované oblasti padne objekt z jiné trajektorie. K vyhodnocení hypotéz sledujících ukončenou trajektorii světlého bodu dojde v okamžiku, kdy budou odstraněny při prořezání nebo při prázdné predikované oblasti. V tomto okamžiku však obsahují hypotézy společné body z obou trajektorií, ve kterých došlo ke sledování společných bodů. Proto provedeme odstranění společných bodů, které obsahují hypotézy z odlišných predikčních stromů. Společné body budou odstraněny u trajektorie s horším ohodnocením, zatímco nejlépe ohodnocená trajektorie zůstane zachována.

5.7. Problémy při sledování trajektorií

Při sledování trajektorií, u kterých dochází k překrývání pohybujících se objektů, dochází k problémům chybně přiřazených částí trajektorií. Při překrytí dochází totiž ke splynutí objektů, čímž se částečně změní jejich tvar, velikost a tím i poloha těžiště výsledného objektu. Tato změna polohy těžiště má za následek odchýlení pohybujícího se objektu z původní trajektorie na trajektorie pohybujícího se společného bodu. Při znovuoobjevení objektu, tedy dojde-li ke zrušení překrytí, mohou vznikat chybná přiřazení k výsledné

trajektorii. Jednou z možností jak tento problém minimalizovat je pokusit se rozpoznat splynuté objekty a rozdělit je. Při extrakci objektů ze snímků získáme obsah každého detekovaného objektu. Pokud tento obsah překročí určitou hranici, která je dána maximální velikostí objektu, prohlásíme tento objekt za splynutí dvou objektů a můžeme ho rozdělit. Maximální velikost objektu můžeme nastavit ručně nebo vypočítat z několika snímků, ve kterých nedošlo k překrytí.

Tato metoda pracuje nezávisle na určených korespondencích mezi objekty, a proto se provádí již při extrakci objektů z obrazu. Její nevýhodou je však malá účinnost, pokud mění objekty během pohybu svou velikost. Jelikož v našem případě snímáme pohyb ve 3D scéně nastává změna velikosti při pohybu objektů v ose promítání nebo při mizení za objekt, který není sledován. Dalším nedostatkem je neschopnost detekovat překrytí většího počtu objektů.

6. Spojování trajektorií

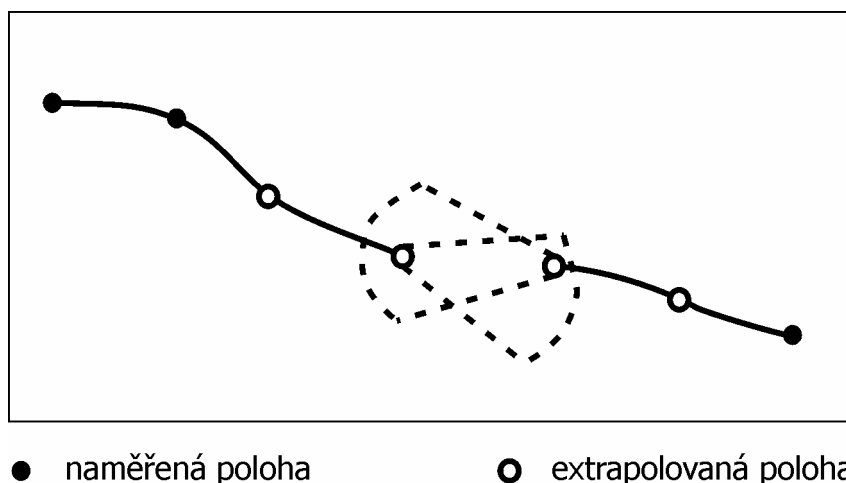
Posledním krokem při sledování trajektorií je spojení korespondujících trajektorií, které byly přerušeny vlivem zmizení a objevení pohybuujícího se objektu v sekvenci. Abychom tyto trajektorie mohli spojit, potřebujeme znát polohy objektů ve snímcích, kde došlo ke zmizení objektu. Tyto polohy můžeme získat za pomoci extrapolace trajektorie pohybuujícího se objektu. Jelikož využíváme k předpovědi Kalmanova filtru, můžeme ho v tomto případě použít i k extrapolaci hodnot viz. kapitola 4.8. Při předpovědi nových poloh není filtr aktualizován novými měřeními a předpokládá se tedy, že se objekt bude pohybovat s konstantním zrychlením a rychlostí, která byla vypočtena při posledním měření. Každým krokem se však při extrapolaci nové polohy snižuje pravděpodobnost správné předpovědi. Objekty totiž mohou během zmizení měnit směr nebo svou rychlost. Z tohoto důvodu se bude zvyšovat i hodnota koeficientů kovarianční matice. Podle hodnoty těchto koeficientů můžeme určovat velikost oblastí, ve které by se mohl nacházet začátek korespondující trajektorie viz. kapitola 5.2. Čím se bude predikovaná oblast zvětšovat, tím se zvětšuje i pravděpodobnost, že nám do ní padne více kandidátních trajektorií nebo nám do predikované oblasti padne nekorespondující trajektorie.

Proto musíme použít tato omezení :

- Maximální počet extrapolovaných hodnot.
- Maximální velikost predikované oblasti.

Extrapolace končí v okamžiku, kdy do predikované oblasti padne nově vzniklý objekt, tedy došlo k navázání nové trajektorie. V opačném případě ukončíme extrapolaci v okamžiku, kdy bude překročena jedna z omezujících podmínek. Není-li nalezen vhodný kandidát pro napojení trajektorie, jsou extrapolované hodnoty zahozeny a trajektorie je považována za ukončenou.

Dojde-li k výskytu více kandidátních trajektorií v predikované oblasti, provádíme výběr podle kritéria odchylky od predikované hodnoty. Výhodou tohoto napojování trajektorií je možnost provádění extrapolace ukončených trajektorií současně při jejich sledování. Nevýhodou je značná nepřesnost pro složitější případy pohybu. Vhodnější metodou je obousměrná extrapolace hodnot viz. obrázek (Obr. 6.1 : Obousměrná predikce). Výhodou je znalost chování objektu i v druhé části trajektorie, kde objekt po znovuobjevení pokračuje.




Obr. 6.1 : Obousměrná predikce

Obousměrnou extrapolaci však můžeme provádět až v případě kdy jsou vyhodnoceny všechny trajektorie v sledované sekvenci. První podmínkou k tomu, abychom mohly dvě trajektorie spojit je, že první trajektorie musí končit ve snímku dřívějším než druhá trajektorie začíná. Spojováním dvou nalezených trajektorií získáme znalost o počtu snímků, ve kterých je nutné extrapolovat hodnoty, což předchozí metoda neumožňovala. V tomto případě tedy víme, ve kterém snímku by mělo dojít ke spojení trajektorií. V průběhu extrapolace provádíme střídatě predikce polohy jedné a druhé trajektorie až do doby kdy je počet extrapolovaných hodnot roven rozdílu snímků konce první trajektorie a začátku druhé trajektorie. U napojující trajektorie přitom musíme provádět zpětnou predikci hodnot. Vytvoříme si k tomu pomocný Kalmanův filtr, který inicializujeme s koncovým objektem trajektorie a jednotlivé kroky pohybu provádíme pozpátku. Tímto vlastně projdeme celou trajektorií opačným směrem a Kalmanův filtr nám bude na konci predikovat dřívější polohy pohybujícího se bodu. V tomto případě budeme vyhodnocovat korespondence mezi trajektoriemi pomocí určení spojitosti viz. kapitola 6.1. Při určování korespondence pak využijeme vypočtených hodnot stavových vektorů obou koncových bodů extrapolovaných křivek. Jelikož obsahuje stavový vektor informace o poloze, rychlosti a zrychlení bodu, můžeme provést určení spojitosti od nultého až po druhý řád spojitosti. Pro každý řád testované spojitosti stanovíme tolerance, podle kterých určíme, zda extrapolované trajektorie spolu korespondují. Opět zde použijeme kritérium s maximálním počtem extrapolovaných hodnot, jelikož při zmizení může dojít ke změně pohybu.

6.1. Spojitost

Při navazování dvou trajektorií je významným faktorem spojitost. Výslednou trajektorii můžeme prohlásit za spojitou, pokud je spojitá ve všech svých bodech, a tedy zejména v navazovacích bodech. Křivka je hladká, pokud jsou ve všech jejích bodech spojitě i její první derivace. Pro vyšší derivace má křivka spojitost druhého, třetího a obecně n -tého řádu. Nejčastější rozdělení spojitosti je na dva typy: spojitost geometrická G^x a parametrická spojitost C^x .



Obr. 6.2 : Rozdíl mezi geometrickou (G^1) a parametrickou (C^1) spojitostí

V našem případě je však výhodnější použít spojitost parametrickou, jelikož při této spojitosti se musí shodovat i velikosti vektorů. Jelikož stavový vektor pozorovaného bodu trajektorie obsahuje nejvýše hodnotu druhé derivace polohy, budou nám stačit k porovnání parametrické spojitosti do druhého řádu. Parametrickou spojitost dvou částí trajektorií můžeme popsat následovně :

1. Spojitost třídy C^0 : dva segmenty trajektorie jsou spojitě navázány, pokud je koncový bod prvního segmentu počátečním bodem segmentu druhého.
2. Spojitost třídy C^1 : dva segmenty trajektorie mají spojení třídy C^1 , pokud je tečný vektor v koncovém bodě prvního segmentu roven tečnému vektoru druhého segmentu v jeho počátečním bodě.
3. Spojitost třídy C^2 : dva segmenty trajektorie mají spojení třídy C^2 , jsou-li vektory první a druhé derivace rovny.

Ze spojitosti C^0 plyne, že se bod pohybuje po spojitě dráze, ale v uzlu může měnit skokem směr pohybu, rychlost i zrychlení. Směr pohybu a velikost rychlosti se nemůže měnit

skokem při spojitosti C^1 a zrychlení zůstává nezměněné při spojitosti C^2 . Dva segmenty trajektorie můžeme prohlásit za spojité, pokud je koncový bod prvního segmentu počátečním bodem druhého segmentu, přičemž vypočtená odchylka spojitostí je menší než zvolený práh. Odchylku spojitosti 0. řádu, tedy poloh bodů ve kterých došlo ke spojení, vypočteme jako Euklidovskou vzdálenost :

$$\delta_0 = |\vec{a} - \vec{b}| = \sqrt{(a_x - b_x)^2 + (a_y - b_y)^2} . \quad (6.1)$$

Jelikož trajektorii sledujeme v opačném směru ve stejné souřadné soustavě, budou v ideálním případě vektory prvních a vyšších derivací vzájemně otočeny o 180° . Abychom mohli vypočítat jejich odchylku musíme jeden z vektorů otočit o 180° . Výpočet odchylek spojitostí vyšších řádů se liší od předchozího případu následovně :

$$\delta_k = |\vec{a} + \vec{b}| = \sqrt{(a_x + b_x)^2 + (a_y + b_y)^2} , \quad (6.2)$$

kde vektory \vec{a} a \vec{b} představují vektory k -té derivace v bodech, ve kterých došlo ke spojení trajektorií, přičemž k nabývá hodnot $1-n$. V našem případě použijeme spojitosti 0. až 2. řádu, které využívají k výpočtu vektory polohy, rychlosti a zrychlení koncových bodů, ve kterých došlo ke spojení. Výsledná odchylka Δ spojitosti dvou bodů je vypočtena jako váhová funkce, kde je každé odchylce spojitosti přiřazena zvolená váha :

$$\Delta = v_0 \delta_0 + v_1 \delta_1 + \dots + v_n \delta_n , \quad (6.3)$$

přičemž musí platit následující rovnice pro přiřazené váhy v_0 až v_n :

$$v_0 + v_1 + \dots + v_n = 1 . \quad (6.4)$$

Z praktického hlediska je výhodnější přiřadit větší váhu spojitostem nižšího řádu. Prvním předpokladem korespondence trajektorií je co nejmenší odchylka poloh bodů, ve kterých došlo ke spojení trajektorií. Dalším kritériem je rychlost a zrychlení těchto bodů, které zajistí kontrolu správnosti směru, rychlosti a zrychlení spojovaných trajektorií. Při volbě velikostí jednotlivých vah musíme brát i v úvahu poměr mezi odchylkou polohy, rychlosti a zrychlení.

6.2. Implementace spojení trajektorií

Pro spojování trajektorií je z hlediska kvality a jednoduchosti lépe využít metody obousměrné extrapolace trajektorií, pokud nepotřebujeme provádět extrapolace a spojování

trajektorií v okamžiku určování korespondencí. Spojování trajektorií začneme tedy provádět, jakmile máme vyhodnocenou sekvenci obrazů a určené všechny trajektorie, po kterých se pohybovaly objekty. V tomto okamžiku obsahuje vstupní seznam pro spojování všechny nalezené trajektorie s určením snímku, ve kterém vznikly a ve kterém byly ukončeny. Při spojování trajektorií budeme postupně hledat ke každé trajektorii jejího pokračujícího následníka. Abychom věděli, ke které trajektorii neexistuje žádná navazující trajektorie, nastavíme u všech trajektorií pomocný příznak.

1. Nastavení příznaku „vhodný kandidát“ u všech trajektorií.
2. Ze seznamu všech trajektorií vybereme trajektorii, která končí nejdříve a je stále kandidátem na spojení s jinou trajektorií.
3. Vybereme všechny trajektorie, které začínají později než vybraná trajektorie končí. Rozdíl snímků mezi začátkem a koncem nesmí překročit maximální nastavenou hodnotu. Pokud není vybrána žádná vhodná trajektorie pro napojení, nastavíme příznak „nehodný kandidát“ a jdeme do bodu 1, jinak pokračujeme v bodě 4.
4. Provedeme obousměrnou extrapolaci vybrané trajektorie v kroku 2 postupně se všemi trajektoriemi vybranými v kroku 3. Vypočteme spojitosti mezi extrapolovanými trajektoriemi.
5. Vybereme spojené extrapolované trajektorie, které mají nejlépe ohodnocené spojení extrapolovaných hodnot, tedy trajektorie s nejmenší odchylkou polohy, rychlosti a zrychlení spojených bodů.
6. Tuto spojenou trajektorii vložíme zpět do seznamu a odstraníme z něj obě trajektorie, které jsme spojili.

Tento algoritmus provádí výběr nejlepšího vhodného kandidáta pro napojení trajektorie z množiny všech možných kandidátů. Kritériem je přitom spojitost obou trajektorií v bodě napojení.

6.3. Problémy při extrapolaci

Při mizení objektu může mít deformace vzhledu objektu vliv na polohu vypočteného těžiště. Tento problém způsobuje ovlivnění extrapolovaných hodnot. Pohyb objektu je ovlivněn změnou polohy koncových bodů trajektorie, což má za následek změnu rychlosti a

zrychlení a tím i změnu pohybu objektu. Kalmanův filtr má však vlastnost, pomocí které lze tyto problémy minimalizovat. Zvýšením chyby měření viz. kapitola 4.2.1 lze docílit menšího vlivu naměřených hodnot na predikci. Toho můžeme využít při aplikaci na extrapolovanou trajektorii. Tím budou mít tyto hodnoty polohy ve výsledném pohybu menší váhu a tak méně ovlivní pozdější extrapolované polohy objektu. V tomto případě však musíme provést aplikaci Kalmanova filtru znova na celou trajektorii, kterou chceme extrapolovat, ovšem s nastavením nových hodnot chyb měření.

7. Rozbor a vyhodnocení chování algoritmů

Prvním krokem při realizaci metody pro určení trajektorií pohybujících se bodů byl návrh a implementace Kalmanova filtru. V kapitole 4. je uveden teoretický rozbor návrhu Kalmanova filtru pro predikci pohybu v jedné ose. Pro tento navržený filtr jsem provedl implementaci funkcí pro predikci příští polohy objektu. Abych mohl otestovat nastavení jednotlivých koeficientů Kalmanova filtru, vytvořil jsem pomocný program, který provádí predikci hodnot polohy na základě zadaných vstupních hodnot. Program umožňuje nastavovat jednotlivé koeficienty Kalmanova filtru a zobrazuje průběhy jeho stavových veličin. Pomocí testovacích sad vstupních hodnot jsem odvodil vhodné nastavení jednotlivých parametrů Kalmanova filtru.

Dalším krokem byla implementace algoritmů pro sledování pohybu objektu. Tento problém jsem rozdělil na dvě části. První část řeší problém určení korespondencí mezi jednotlivými snímky, jejímž výstupem je seznam trajektorií, po kterých se sledované objekty pohybovaly. Druhou částí je spojení korespondujících trajektorií za pomoci extrapolace hodnot v částech, kde došlo k jejich přerušení.

Pro ověření chování funkcí programu byla využita výstupní data z programu pro sledování trajektorií a programu pro simulaci predikce polohy pomocí Kalmanova filtru. Cílem bylo ověřit funkčnost a přesnost implementovaných algoritmů a vyzorovat chování jednotlivých částí algoritmů při různém nastavení jejich parametrů. Z hlediska přiřazení parametrů k jednotlivým funkcím je rozdělíme do tří skupin :

- Kalmanův filtr pro predikci polohy.
- Určování korespondencí.
- Spojování trajektorií.

Nejvíce komplikovanějším prvkem, co se týče nastavení parametrů, je Kalmanův filtr. Před jeho inicializací je nutno provést nastavení parametrů, které budou neměnné po celou dobu predikce. Mezi parametry které budeme nastavovat patří :

- Chyba : určuje chybu měření (určení polohy objektu), hodnota je uváděna v pixelech.
- Mez : vyjadřuje práh pro použití aditivního manévrovacího šumu.

- Koeficient : velikost konstanty, kterou se násobí všechny prvky matice manévrovacího šumu.
- Okno : počet posledních hodnot, ze kterých se počítá průměrná hodnota odchylky od predikovaných hodnot (parametr detekce průměrováním viz. kapitola 4.7).

Druhou částí je určování korespondencí, která využívá Kalmanova filtru pro predikci polohy a provádí vyhodnocení vzniklých hypotéz. Mezi parametry, které je nutné nastavit při vyhodnocování korespondencí, patří :

- Odchylka : koeficient, kterým násobíme vypočtenou odchylku od predikované hodnoty. Výsledná hodnota určuje velikost predikované oblasti.
- Úroveň : hloubka predikčního stromu, ve které dochází k rozvětvení.

Poslední částí, kde budeme provádět nastavení parametrů je spojování trajektorií. Tento algoritmus opět využívá Kalmanova filtru pro extrapolaci hodnot, avšak s odlišným nastavením jeho vybraných parametrů. K těmto parametrům patří :

- Chyba : určuje chybu měření (určení polohy objektu), hodnota je uváděna v pixelech.

Ostatní parametry Kalmanova filtru přebíráme z nastavení při určování korespondencí. Dalšími parametry při provádění spojování omezení :

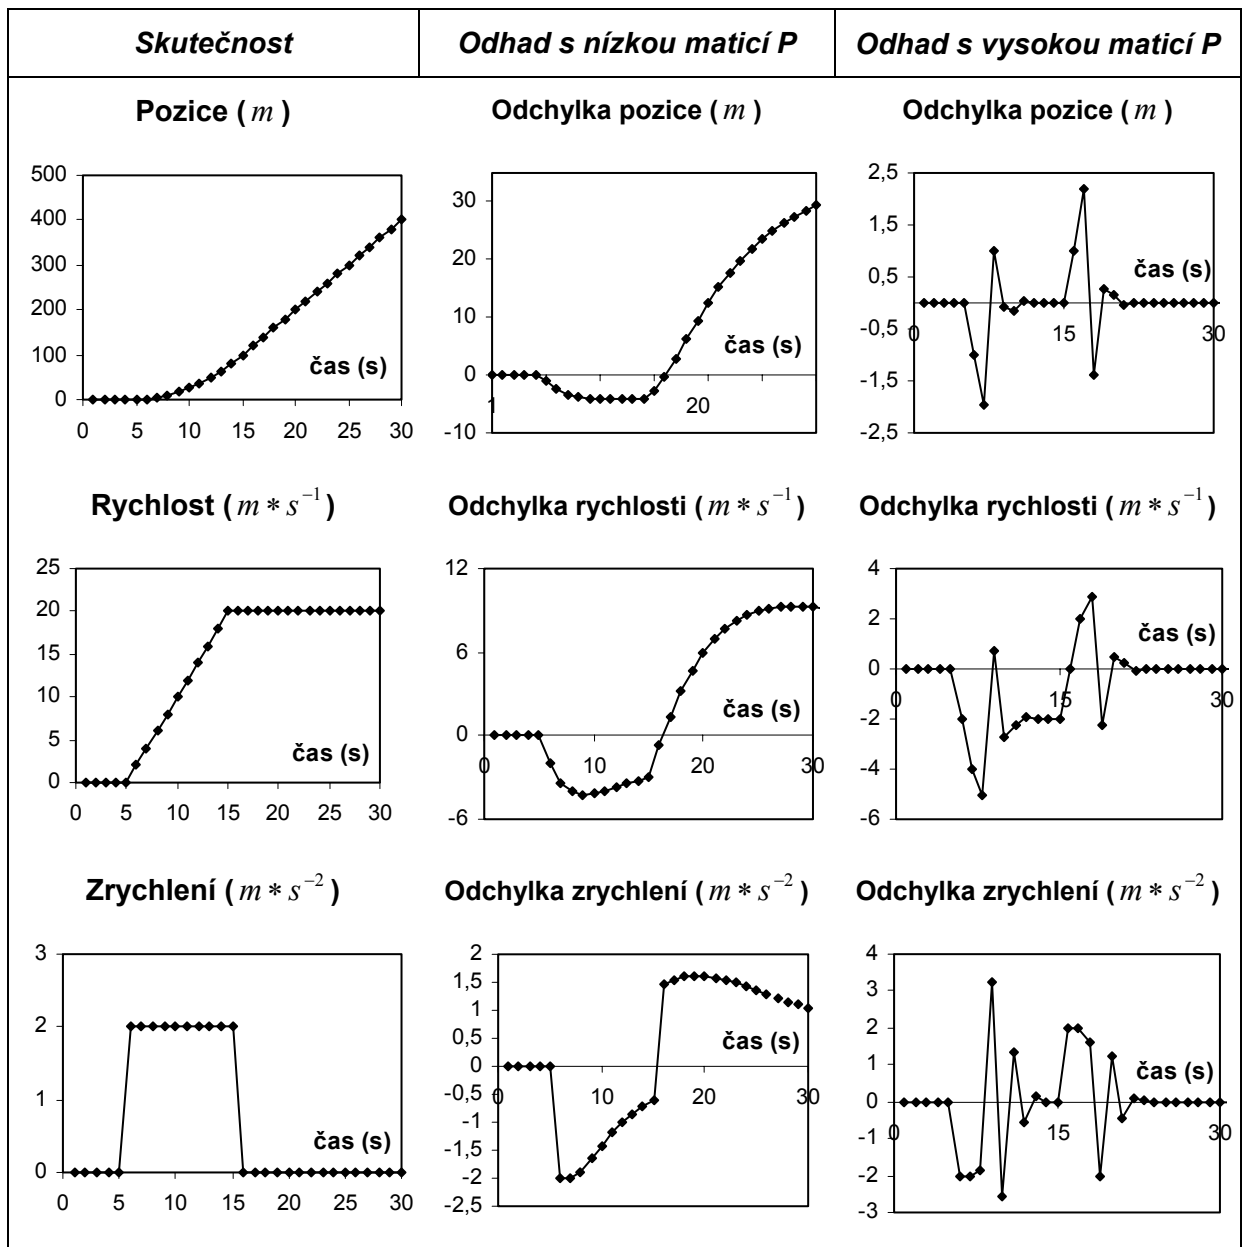
- Odchylka : vyjadřuje práh, který určuje, zda spolu dvě extrapolované trajektorie korespondují, či ne. S tímto prahem se porovnává vypočtená spojitost viz. kapitola 6.1.
- Max.snímků : vyjadřuje maximální počet snímků mezi koncem jedné trajektorie a začátkem druhé trajektorie, které chceme spojit.

Použité sekvence snímků byly v rozlišení 384x288 pixelů. Pozorované objekty představují bílé body na černém pozadí.

7.1. Vlastnosti parametrů Kalmanova filtru

Prvním úkolem bylo najít nejvhodnější nastavení koeficientů Kalmanova filtru tak, aby dokázal rychle reagovat na změny vstupních hodnot s minimálními odchylkami od predikce. Filtr využívá kovarianční matici P , která velikostí svých hodnot udává míru pravděpodobnosti

správnosti naměřené a predikované hodnoty. Filtr se potom v dalším kroku přiklání více k predikované nebo naměřené hodnotě v závislosti na velikosti koeficientů. Čím jsou koeficienty kovarianční matice menší, tím se filtr více přiklání k predikovaným hodnotám a naopak při velkých koeficientech se přiklání k naměřeným hodnotám.

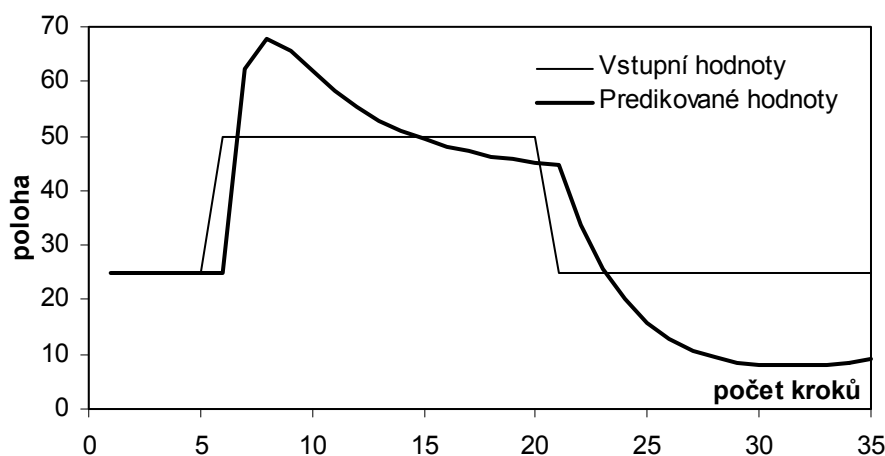


Tab. 7.1 : Průběh chyb predikce

V tabulce (Tab. 7.1 : Průběh chyb predikce) je simulován pohyb objektu a provedeno měření odchylek od predikovaných hodnot polohy, rychlosti a zrychlení objektu. Druhý a třetí

sloupec v tabulce představuje porovnání naměřených odchylek pro různé hodnoty nastavení kovarianční matice. V prvním případě není kovarianční matice ovlivňována aditivním šumem. Odchyly od predikce nemění svou hodnotu skokově, jelikož filtr provádí menší korekce Kalmanova zisku. V druhém případě byla kovarianční matice uměle ovlivňována přidáváním šumu. V tomto případě jsou vidět prudké změny odchylek v obou směrech, které jsou způsobeny snahou filtru o rychlejší přiblížení predikce ke vstupním hodnotám.

Velikost prvků kovarianční matice ovlivňuje více faktorů. Chyba měření je jedním z faktorů, které ovlivňují velikost prvků kovarianční matice po celou dobu predikce. Čím je chyba měření větší, tím se filtr více přiklání k predikovaným hodnotám. Což v důsledku znamená menší citlivost reakce na změny naměřených hodnot. Druhým významným faktorem je matice manévrovacího šumu, která se přidává ke kovarianční matici viz. kapitola 4.7. Tento faktor nepůsobí však po celou dobu predikce, spouští se jen po překročení zvoleného prahu. Nepoužijeme-li korekci maticí manévrovacího šumu, dochází při větších změnách hodnot ke špatné predikci. Tento případ je znázorněn na obrázku (Obr. 7.1 : Graf predikce hodnot bez použití manévrovací matice).



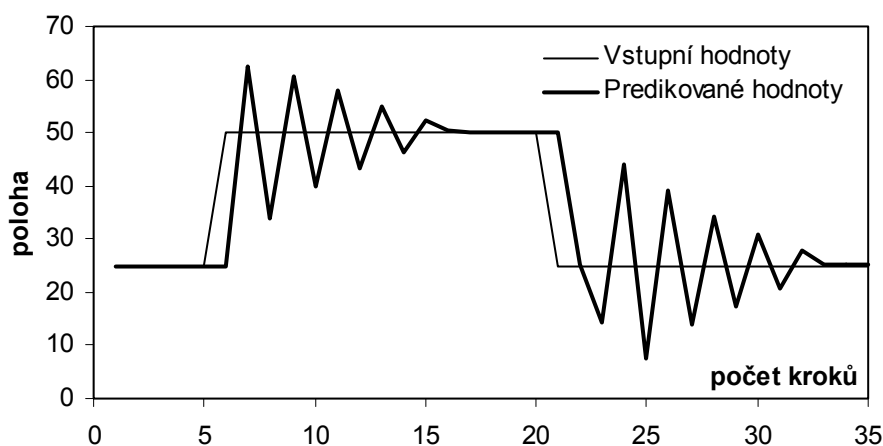
Obr. 7.1 : Graf predikce hodnot bez použití manévrovací matice

Filtr se při velkých změnách vstupních hodnot nedokáže rychle přizpůsobit, což je způsobeno velkým tlumením filtru. Proto využíváme přidání nejistot do kovarianční matice za pomoci manévrovacího šumu, jehož koeficienty pro nastavení jsou tyto :

- velikost okna odchylek (Okno)
- mez spouštění (Mez)

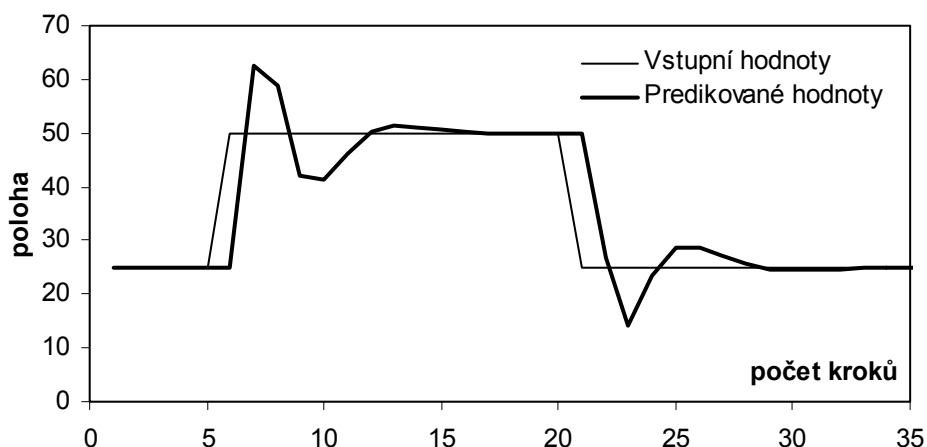
- velikost konstanty pro násobení manévrovací matice (Koeficient).

Používáme přitom detekce spouštění pomocí průměrování odchylek. Mez spouštění udává překročení odchylky naměřené a predikované hodnoty. Tato odchylka však představuje průměr součtu odchylek v posledních n krocích, jejichž počet je dán velikostí okna odchylek. Zvětšováním okna odchylek se zpožďuje reakce predikce filtru na změnu naměřených hodnot. Správné nastavení velikosti okna závisí na četnosti změn hodnot v měřeném úseku. Při nízké četnosti změn je možné nastavit velikost okna větší než 1. Při používání manévrovacího šumu můžeme nastavovat i velikost manévrovací matice přičítané ke kovarianční matici. Velikost se nastavuje pomocí koeficientu, kterým násobíme manévrovací matici. Čím je hodnota koeficientu vyšší, tím se bude filtr více přiklánět k naměřené hodnotě. Je-li však hodnota manévrovacího šumu příliš velká a mez spouštění nebo chyba měření malá, může docházet ke kmitání predikovaných hodnot, což je znázorněno na obrázku (Obr. 7.2 : Graf predikce hodnot – nevhodné nastavení koeficientů).



Obr. 7.2 : Graf predikce hodnot – nevhodné nastavení koeficientů

Vhodně nastavenými koeficienty dosáhneme tvaru predikované křivky, která obsahuje minimální odchylky predikovaných hodnot od naměřených viz obrázek (Obr. 7.3 : Graf predikce hodnot – správné nastavení koeficientů). Je nutné podotknout, že vhodné nastavení filtru se liší pro různé skupiny hodnot, které mají odlišné vlastnosti. Mezi tyto vlastnosti patří velikost změny hodnot v daném intervalu, rychlost změny, chyba měření a další.



Obr. 7.3 : Graf predikce hodnot – správné nastavení koeficientů


V grafech jsou znázorněny reakce Kalmanova filtru na skokovou změnu hodnoty. Provádíme tak simulaci skokové změny polohy objektu. Simulace je prováděna po dobu 35 kroků včetně inicializace. V tabulce (Tab. 7.2 : Nastavení jednotlivých parametrů Kalmanova filtru) jsou uvedeny hodnoty parametrů Kalmanova filtru pro jednotlivé případy.

Graf	Chyba měření	Manévrovací matice		
		Okno	Mez	Koeficient
Obr. 7.1	2	<i>nepoužita</i>		
Obr. 7.2	2	3	2	10
Obr. 7.3	2	1	1	1

Tab. 7.2 : Nastavení jednotlivých parametrů Kalmanova filtru

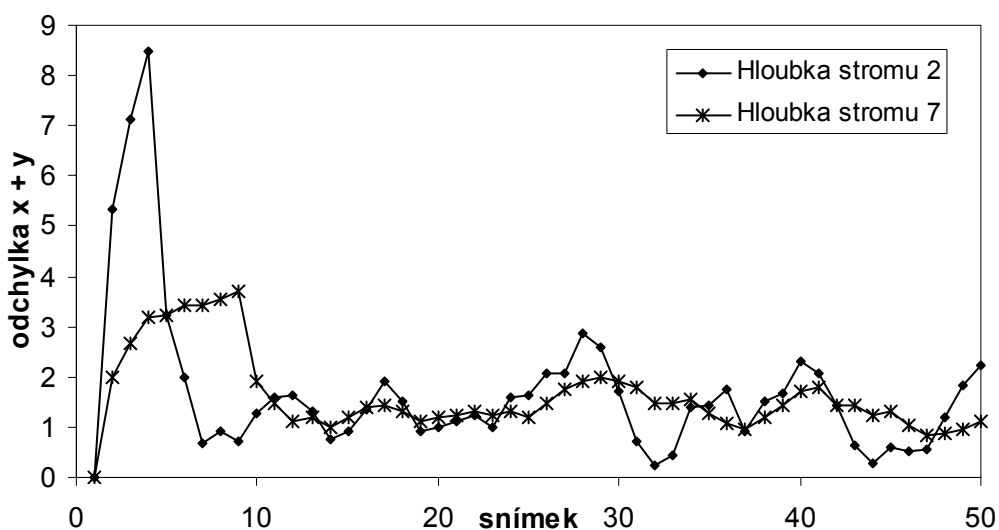
7.2. Odchytky od predikované hodnoty

Pro měření odchylek od predikované hodnoty jsem vybral pohyb jednoho objektu po kružnici s poloměrem $r = 95 \text{ pixelů}$. Objekt se pohybuje po dobu 50 snímků rychlostí 11,94 pixelů/snímek. Jeho trajektorie je znázorněna na obrázku (Obr. 7.4 : Trajektorie pohybujícího se bodu).



Obr. 7.4 : Trajektorie pohybujícího se bodu

První pozorování provedeme v závislosti na hloubce stromu. Odchylka od predikovaných hodnot se počítá jako průměrná hodnota součtu odchylek x a y souřadnice v posledních n snímcích viz. rovnice 5.1. Čím je hloubka predikčního stromu větší, tím bude větší hodnota n a výsledná odchylka průměrem větší skupiny hodnot. V grafu na obrázku (Obr. 7.5 : Porovnání průběhů odchylek) je zobrazen průběh vypočtených odchylek při hloubce stromu 2 a 7. Měření jsem provedl s následujícím nastavením hodnot : Chyba=1, Mez=1, Koefficient=0.5, Okno=2, Odchylka=20.




Obr. 7.5 : Porovnání průběhů odchylek

Jak je vidět z grafu, na začátku sledování (po inicializaci) dosahují odchylky nejvyšších hodnot. Tento počáteční nárůst je způsoben nepřesností počátečních predikcí. Po inicializaci filtr předpovídá stejnou polohu, jaká byla zadána při inicializaci, jelikož nemá o pohybu objektu žádné informace. Po několika krocích se predikce ustálí, pokud se pohyb objektu nemění příliš velkým způsobem. Porovnáme-li průběhy pro obě zvolené hloubky stromu,

dochází při větší hloubce k průměrování z většího počtu hodnot, čímž dochází k menšímu ovlivnění výsledné střední hodnoty vzniklými maximy.

7.3. Velikost predikované oblasti

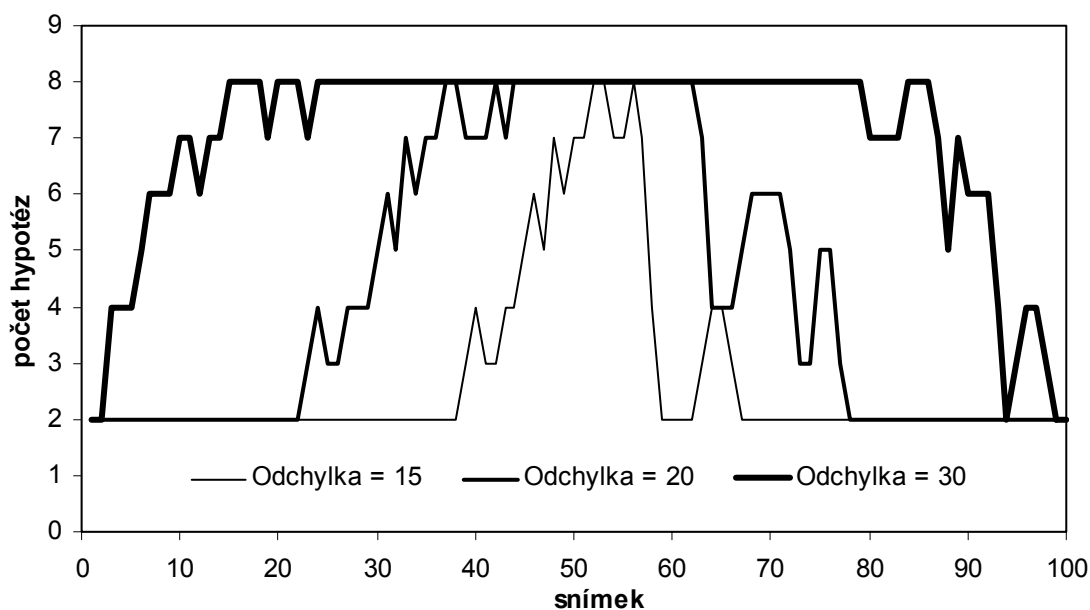
Pozorujeme-li pohyb dvou bodů, které se k sobě přibližují, můžeme pozorovat vznik nových vícenásobných hypotéz, které vznikají při padnutí více objektů do jedné predikované oblasti. Tuto vlastnost budeme demonstrovat na dvou pohybujících bodech, které se k sobě přibližují do poloviny sekvence a od poloviny sekvence zase vzdalují. Trajektorie pohybujících bodů jsou znázorněny na obrázku (Obr. 7.6 : Trajektorie pohybu dvou bodů).



Obr. 7.6 : Trajektorie pohybu dvou bodů

Pozorovaná sekvence obsahuje 100 snímků a oba objekty se pohybují rychlostí 3,1 pixelů/snímek. Měření provádíme s nastavením následujících hodnot : Chyba = 1, Mez = 0.5, Koeficient = 0.5, Okno = 2 a Úroveň = 3.

Budeme-li zvětšovat predikovanou oblast jak je znázorněno v grafu na obrázku (Obr. 7.7 : Počet hypotéz v závislosti na velikosti predikované oblasti), bude se zvyšovat počet sledovaných hypotéz. Tento nárůst bude tím větší, čím více se budou oba body k sobě přibližovat. Platí přitom následující pravidlo : hypotézy, které vzniknou při nastavení menší odchylky, jsou podmnožinou hypotéz vzniklých při nastavení větší odchylky za podmínky stejné výšky predikčního stromu a nastavení stejných parametrů Kalmanova filtru. Padne-li objekt z jiné trajektorie do predikované oblasti pozorované trajektorie, je brán jako kandidát. V dalším kroku se provádí predikce příští polohy a tím i predikované oblasti s ohledem na kandidáty z minulého snímku. Pokud jsou predikované oblasti dostatečně velké a trajektorie dostatečně blízko, může do nich opět padnout nevhodný kandidát, čímž vznikají nové chybné hypotézy. Tyto hypotézy budou při prořezání odstraněny, mají však vliv na rychlost provádění vyhodnocování, jelikož se musí vyhodnocovat více kandidátních hypotéz.



Obr. 7.7 : Počet hypotéz v závislosti na velikosti predikované oblasti

Na druhou stranu však musí být predikovaná oblast dostatečně velká, aby nebyl pozorovaný objekt při změně pohybu ztracen. Velikost dolní hranice velikosti predikované oblasti je závislá na změnách rychlosti a zrychlení pozorovaného objektu. Čím jsou tyto změny větší, tím více musíme zvětšovat i predikovanou oblast. Tuto vlastnost nám zajišťuje výpočet predikované oblasti pomocí Mahalanobovy vzdálenosti, nebo výpočet za použití prvků kovarianční matice viz. kapitola 5.2. V našem případě násobíme velikost predikované oblasti koeficientem „Odchylka“. Abychom minimalizovali vznik vícenásobných hypotéz, které překračují množinu nejlepších kandidátů, snažíme se velikost predikované oblasti minimalizovat. Následující tabulka (Tab. 7.3 : Porovnání časů) představuje porovnání délek trvání vyhodnocení použité sekvence při různém nastavení predikovaných oblastí.

Odchylka	10	15	20	30
Čas(s)	3,6	4,2	5,5	8,7

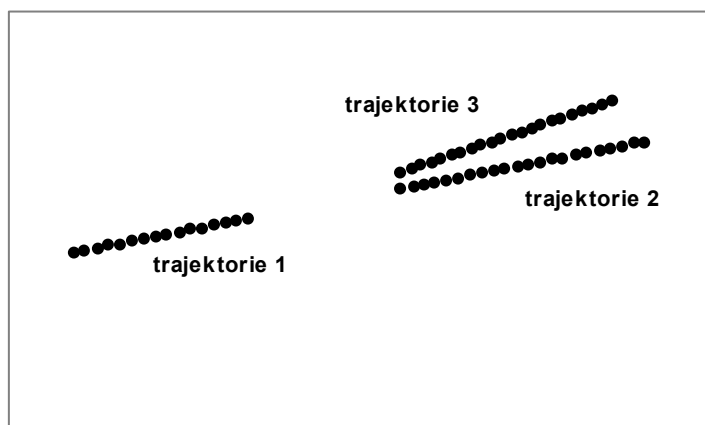
Tab. 7.3 : Porovnání časů vyhodnocení sekvence – testováno na počítači s procesorem Duron 1GHz

Jak je vidět v tabulce, výsledný čas vyhodnocení trajektorií se zvyšuje se zvětšováním predikované oblasti, která měla vliv na počet vzniklých hypotéz. Snížením velikosti predikované oblasti můžeme docílit zrychlení provádění vyhodnocování pohybu objektů v

sekvenci. Velikost predikované oblasti musí být však dostatečně velká, aby nedošlo při sledování objektu k jeho ztracení.

7.4. Extrapolace hodnot

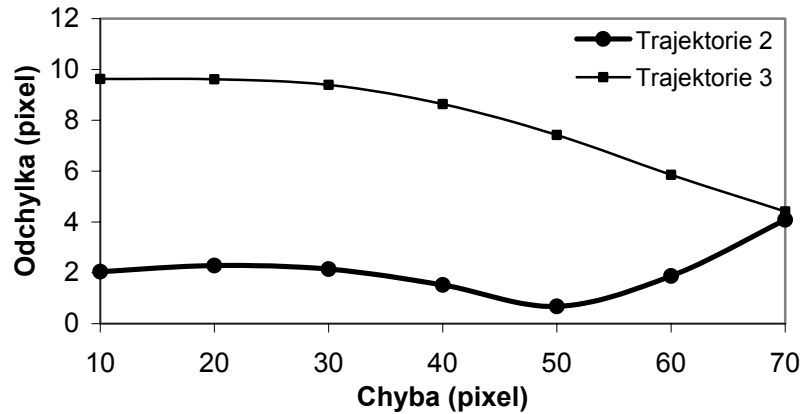
Dojde-li k přerušení trajektorií vlivem zmizení objektu, provádíme jejich spojování. Pro testování jsem zvolil tři trajektorie. Sledované trajektorie jsou zobrazeny na obrázku (Obr. 7.8 : Přerušení vlivem zmizení a znovuoobjevení objektu). V průběhu pohybu objektu dojde ke zmizení a potom ke znovuoobjevení objektu. Abychom mohly otestovat správné spojení trajektorií, je vložena po znovuoobjevení objektu další trajektorie. Objekty se v sekvenci pohybují rovnoměrným pohybem. Pozorovaná sekvence obsahuje 50 snímků. V 17. snímku dojde ke zmizení objektu a v 29. snímku dojde ke znovuoobjevení zmizelého objektu a navíc k objevení dalšího objektu.



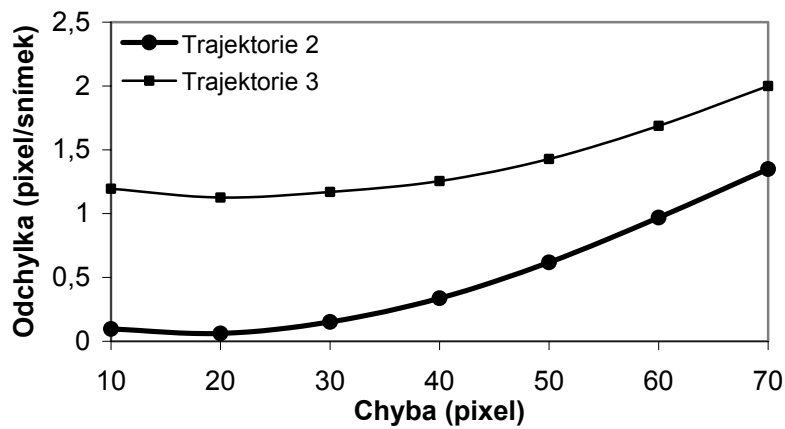
Obr. 7.8 : Přerušení vlivem zmizení a znovuoobjevení objektu

Na tomto příkladě testujeme výběr správného kandidáta pro navázání trajektorie. Trajektorie budou spojeny jen v případě, pokud odchylky spojitosti nepřekročí nastavenou hranici. Pro tento případ jsou nastaveny parametry pro spojování trajektorií následovně : Odchylka = 10, Max.snímků = 20. Hodnotu chyby měření budeme postupně zvyšovat a pozorovat změny odchylek polohy, rychlosti a zrychlení bodů, ve kterých došlo ke spojení trajektorií. Změnou chyby měření dochází ke změně extrapolace hodnot. Čím je chyba měření menší, tím se extrapolace více přiklání k posledním hodnotám trajektorie. Naopak při zvyšování chyby měření bude ovlivněna extrapolace větší částí trajektorie. Jak již bylo řečeno v kapitole 6.3, zvýšení chyby měření slouží k redukci problému deformace trajektorie při zmizení a objevení objektu. V případě trajektorií na obrázku


(Obr. 7.8 : Přerušení vlivem zmizení a znovuobjevení objektu) se bude provádět vyhodnocování kandidátů trajektorie 2 a 3, které je možno spojit s trajektorií 1. V následujících grafech jsou zobrazeny průběhy odchylek bodů, ve kterých došlo ke spojení extrapolované trajektorie 1 s extrapolovanou trajektorií 2 nebo 3.



Obr. 7.9 : Odchylka polohy (pixel)




Obr. 7.10 : Odchylka rychlosti (pixel/snímek)

Obr. 7.11 : Odchylka zrychlení (pixel/snímek²)

V jednotlivých grafech je vidět změna odchylek hodnot při změně hodnoty parametru „Chyba“. Při vyšších hodnotách je vidět nárůst odchylek. Jelikož se však jednalo o rovnoměrný pohyb beze změny směru pohybu objektu, není tento nárůst tak velký. Z těchto měření můžeme usoudit, že příliš velké nastavení hodnot parametru „Chyba“, který má za následek ovlivnění extrapolovaných hodnot, vede k nepřesné extrapolaci. Proto je nutné dbát na správnou volbu velikosti tohoto parametru s ohledem na četnost změn pohybu objektů.

7.5. Sekvence pohybu člověka

Pozorovaná sekvence nasnímaného pohybu člověka obsahuje 1098 snímků. Postava má na sobě připevněno 18 značek viz. obrázek (Obr. 7.12 : Sekvence pohybu člověka). Tyto značky představují pozorované pohybující se objekty. Jak již bylo řečeno v kapitole 2.1 dochází při extrakci objektů k problémům vzniku falešných objektů rozpadem sledovaných objektů, nebo chybách při snímání. Po určení všech korespondencí tvoří falešné objekty krátké trajektorie. Pokud došlo k rozpadu objektu jen v jednom snímku, obsahuje trajektorie jednu polohu vzniklého falešného objektu. V druhém případě dojde vlivem chyby při snímání ke spojení dvou objektů. Výsledný objekt je pak přiřazen jen jedné trajektorii a druhá trajektorie bude v tomto okamžiku přerušena. Tyto aspekty mají za následek zvyšování počtu výsledných trajektorií, které byly vyhodnoceny z celé sekvence.



Obr. 7.12 : Sekvence pohybu člověka

Správnost vyhodnocení trajektorií pro tuto sekvenci nebylo možno určit, jelikož jsem neměl k dispozici vhodný nástroj pro vyhodnocení správnosti určení trajektorií pohybujících se objektů.

Jednou z možností jak provést kontrolu správnosti výsledných trajektorií je svázat trajektorie s kinematickým modelem kostry člověka. Tímto budou vymezeny polohy jednotlivých objektů v závislosti na kinematice pohybového aparátu člověka. Tato aplikace nám pomůže odstranit chybné trajektorie, které vznikly chybami při extrakci objektů, nebo při snímání kamerou. Jelikož docházelo při pohybu k mizení značek, byly trajektorie často přerušovány. Extrapolací lze část těchto trajektorií spojit. Pokud však došlo ke zmizení delšímu než nastavená mez, nebo došlo ke změně pohybu po dobu zmizení, nelze tyto trajektorie spojit. Následující tabulka (Tab. 7.4 : Počet trajektorií po vyhodnocení) udává počet trajektorií vzniklých při určování korespondencí. Hodnoty nastavení manévrovací matice u Kalmanova filtru byly shodné pro všechna měření : Mez = 0.5, Koeficient = 0.5, Okno = 2.

Chyba	1	1	0,5	0,5
Odchylka	5	10	10	15
Úroveň	2	2	2	2
Počet trajektorií	776	478	762	533

Tab. 7.4 : Počet trajektorií po vyhodnocení

Z tabulky je vidět velký rozptyl počtu trajektorií při různém nastavení velikosti predikované oblasti (Odchylka). Na velikost predikované oblasti působí i velikost kovarianční matice ovlivněná chybou měření (Chyba) a další parametry, jejichž nastavení je v tomto

případě neměnné. Nastavování různých hodnot parametrů má velký vliv na výsledné vyhodnocení korespondencí. Počet trajektorií se může zvyšovat vlivem rozpadu sledovaných trajektorií, ke kterému došlo při ztrátě sledovaného bodu. Ztráta mohla nastat zmizením bodu, nebo chybnou predikcí a malou predikovanou oblastí. Výsledný počet trajektorií je tedy velmi závislý na nastavení parametrů při vyhodnocování.

Přerušení trajektorií můžeme částečně minimalizovat spojováním trajektorií za pomoci extrapolace viz.kapitola 6. Počet spojených trajektorií je závislý na nastavení meze odchylky od vypočtené spojitosti viz.kapitola 6.1. Při nastavení příliš velké odchylky dochází ke spojení trajektorií, které spolu nekorrespondují. Z tohoto důvodu je důležité najít vhodné nastavení meze, které by mělo za následek spojení co největšího počtu korespondujících trajektorií, avšak bez chybných spojení.

8. Závěr

Cílem mé diplomové práce bylo prostudovat dostupnou literaturu, týkající se problému sledování pohybu objektů se stejným vzhledem a provést rozbor používaných metod. Navrhnout možné řešení sledování pohybu objektů v obraze a provést jeho implementaci. Na závěr pak zhodnotit použitou metodu a uvést její výhody a nevýhody.

Z dostupné odborné literatury jsem získal informace o vývoji jednotlivých metod a způsobu řešení této problematiky. Ze všech existujících metod jsem jako nejvhodnější pro řešení problému vybral metodu využívající sledování pohybu v závislosti na několika po sobě jdoucích snímcích, která využívá predikce příští polohy objektu. Pro predikci polohy jsem použil Kalmanovu filtraci, která je nejpoužívanější metodou využívanou v této oblasti.

V první části mé práce jsem popsal postup aplikace Kalmanova filtru na predikci pohybu objektu v jedné dimenzi. Takto modifikovaný filtr lze použít pro predikci pohybu objektu, máme-li k dispozici informace o jeho poloze. Predikci příští polohy jsem využil při vytváření nových hypotéz sledovaných trajektorií, přičemž jsem vycházel z metod využívajících vícenásobného sledování hypotéz (MHT) a heuristického vyhodnocování korespondencí. Při sledování pohybu objektů se vyskytly problémy při určování zmizení, objevení a překrývání objektů. Tyto problémy jsem vyřešil využitím metod zpětného vyhodnocování. Dosažené výsledky jsem zhodnotil v kapitole 7.

Zvětšováním predikované oblasti a úrovně predikčního stromu dochází ke zvýšení počtu nových hypotéz, přičemž vznikají možné nadbytečné hypotézy. Tímto roste časová náročnost na vyhodnocení všech hypotéz. K největšímu zpomalení při vyhodnocování trajektorií dochází při určování ukončených trajektorií, jelikož zvolená metoda provádí kontrolu všech rušených hypotéz. Tento problém se dá částečně omezit minimalizací počtu hypotéz vhodným nastavením parametrů. Z tohoto důvodu není implementovaný algoritmus vhodný pro real-time aplikace. Cox a Hingorani uvedli ve své studii [2] efektivní hloubku predikčního stromu rovnu dvěma až třem úrovním. Na zvolených sekvencích jsem tuto vlastnost ověřil. Již při dvou úrovních predikčního stromu dokázal algoritmus efektivně vyhodnotit pozorované trajektorie. Z tohoto důvodu není nutné používat algoritmy pro větší hloubku zpětného vyhodnocování, ale spíše se zaměřit na vyhodnocení korespondencí mezi 3 po sobě jdoucími snímky. Tímto omezením a optimalizací algoritmů pro pevnou délku zpětného vyhodnocování můžeme dosáhnout podstatného zrychlení. U všech testovaných

sekvencí se přesnost určování korespondencí, při použití větší hloubky stromu než tři, nezvyšovala.

Nevýhodou použité metody je značné množství parametrů, které je nutné vhodně nastavit, abychom mohli dosáhnout uspokojivých výsledků při sledování pohybu. Jednotlivé nastavení parametrů Kalmanova filtru jsou na sobě značně závislé a jejich hodnoty jsou pro každý sledovaný pohyb individuální.

Výhodou zvoleného postupu oproti některým jednoduchým metodám je efektivní řešení problému objevování, mizení a překrývání objektů. Další výhodou je pak libovolný počet sledovaných objektů ve scéně, který nemusí být předem znám.

Řešený problém sledování pohybu objektů skýtá velkou řadu problémů, přičemž řadu z nich jsem popsal ve své práci. Tyto problémy se vyskytují hlavně při řešení mizení, objevování a překrývání objektů. Jako další kroky pro optimalizaci zvoleného postupu navrhuji :

- Vytvořit adaptivní nastavování parametrů Kalmanova filtru.
- Optimalizovat zpětné vyhodnocování trajektorií pro 3 po sobě jdoucí snímky.
- Optimalizovat extrapolaci poloh při spojování trajektorií na základě nastavení parametrů použité Kalmanovy filtrace.
- Pro zdokonalení konkrétního problému sledování značek na lidském těle je možné svázat techniku určování korespondencí s kinematickým modelem kostry člověka.

9. Seznam použité literatury

- [1] Faugeras, O., Three-Dimensional Computer Vision, A Geometric Viewpoint, The MIT Press, Cambridge, Massachusetts, 1993.
- [2] Cox, I., Hingorani, S., An Efficient Implementation of Reid's Multiple Hypothesis Tracking Algorithm and its Evaluation for the Purpose of Visual Tracking, Published in IEEE Trans. on PAMI, 1996.
- [3] Cox, I., Miller, M., On Finding Ranked Assignments with Application to Multi-target Tracking and Motion Correspondence, Published in IEEE Trans. on AES, 1995.
- [4] Veenman, C., Reinders, M., Backer, E., Resolving Motion Correspondence for Densely Moving Points, Faculty of Information Technology and Systems, Delft University of Technology, IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001.
- [5] Bar-Shalom, Y., Fortmann, T., Tracking and Data Association, Academic press, 1988.
- [6] Veenman, C., Reinders, M., Backer, E., A Composite Model and Algorithm for Motion Correspondence, Information and Communication Theory Group Faculty of Information Technology and Systems, Delft university of technology, The Neaderlands, 2000.
- [7] Chang, Y., Aggarwal, J., 3D Structure Reconstruction From an Ego Motion Sequence Using Statistical Estimation and Detection Theory, IEEE Workshop on Visual Motion, 1991.
- [8] Danchick, R., Newman, G., A Fast Method for Finding the Exact N-best Hypotheses for Multitarget Tracking, IEEE Transaction Aerospace and Electronic Systems, 1993.
- [9] Reid, D., An Algorithm for Tracking Multiple Targets, IEEE Transaction on Automatic Control, December 1979.
- [10] Verestóy, J., Chetverikov, D., Feature Point Tracking Algorithms, Computer and Automation Research Institute, Budapest, 1998.
- [11] Eiserloh, P., An Introduction to Kalman Filters and Applications, Assault and Special Projects Naval Air Warfare Center, China Lake, 2002, dokument je dostupný na URL <http://www.eiserloh.org/~peter/kalman.pdf>

- [12] Thales Research Ltd, Kalman Filters Tutorial and Pitfalls, Stansfield, 2001, dokument je dostupný na URL
http://www.aspc.qinetiq.com/Events/Mar01/Kalman_Tutorial_Slides.pdf
- [13] Slavík, P., Metody zpracování grafické informace, Grada, Praha, 1995.
- [14] Žára, J., Moderní počítačová grafika, první vydání, Computer Press Praha, 1998.
- [15] Moravec, M., Sledování objektu za pomoci CCD kamery, Diplomová práce, VUT Brno FEI, 1997.
- [16] Havlena, V., Štěcha, J., Moderní teorie řízení, ČVUT Praha, Vydavatelství ČVUT, 1994.
- [17] Filip, J., Sledování objektů v sekvenci obrazů, Diplomová práce, VŠB – Technická univerzita Ostrava, 2000.
- [18] Jan, J., Číslíková filtrace, analýza a restaurace signálů, Vysoké učení technické v Brně, 1997.

10. Seznam příloh

Příloha I Programová dokumentace

Příloha I Programová dokumentace

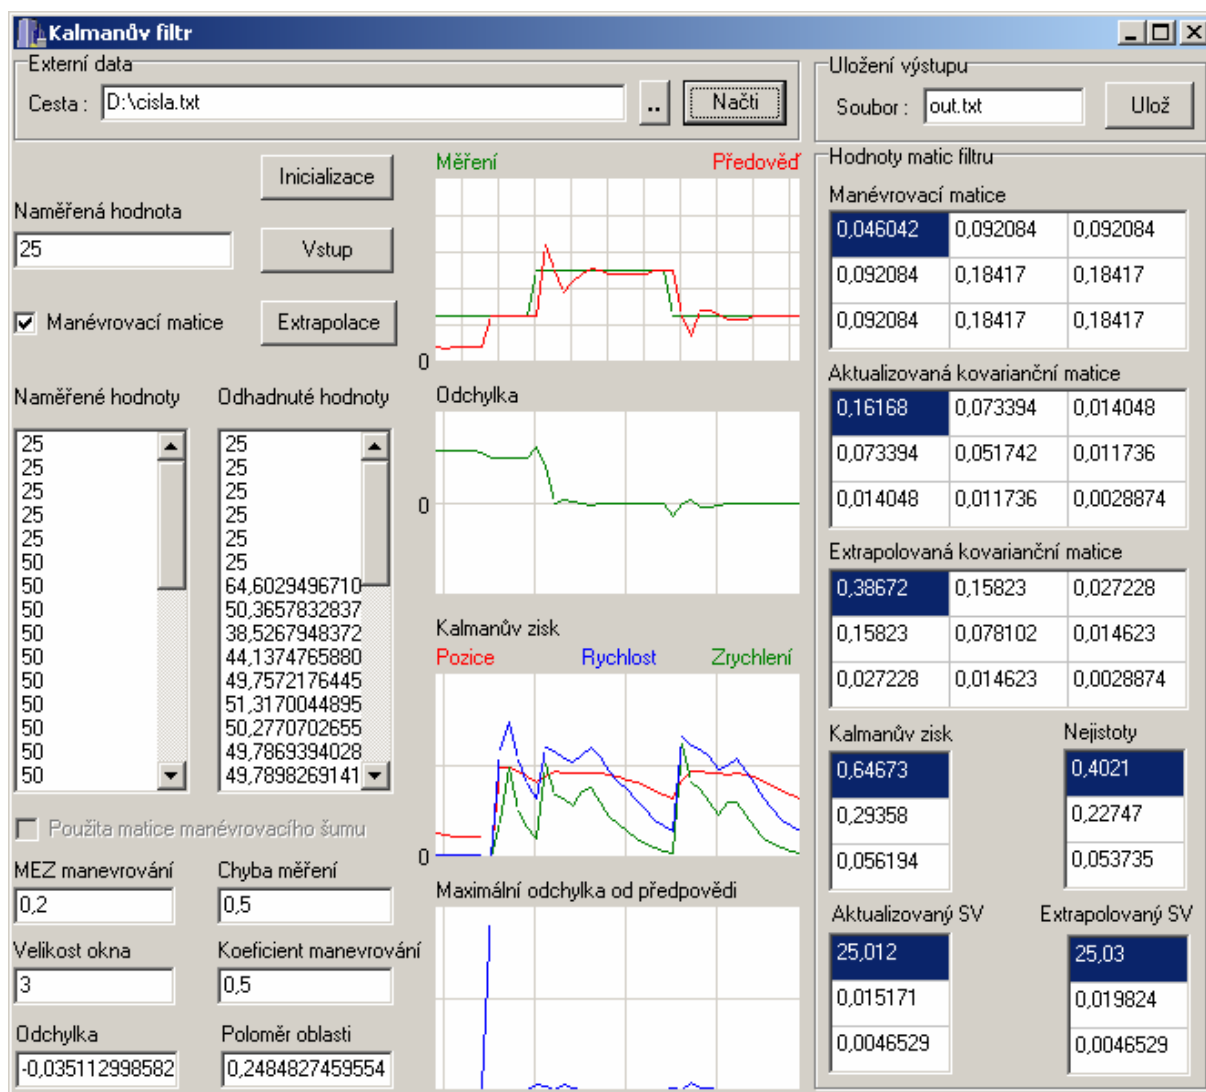
Program „Kalmanův filtr“

Pro otestování funkce a vyhodnocení chování Kalmanova filtru při nastavení různých parametrů jsem vytvořil program „Kalmanův filtr“. Program provádí predikci polohy pohybujícího se objektu pro zadané vstupní hodnoty polohy. Implementace filtru je provedena jen pro pohyb objektu v 1 dimenzi. Aplikace Kalmanovy filtrace pro pohybující se objekt je popsána v kapitole 4. Program umožňuje nastavení jednotlivých parametrů Kalmanovy filtrace a zobrazuje hodnoty a průběhy jeho stavových proměnných.

Vstupní hodnoty pro provádění predikce můžeme zadávat dvěma způsoby – ze souboru nebo z klávesnice. Ve vstupním souboru musí být přítom hodnoty udány zvlášť na každém řádku. Jelikož simulujeme pohyb objektu v animační sekvenci, kde jsou mezi jednotlivými snímky konstantní časové úseky, bude nastavena časová konstanta mezi vstupními hodnotami na hodnotu 1. Z tohoto důvodu nám pro popis pohybu objektu stačí jen jednotlivé polohy. Při využití hodnot ze souboru se provede simulace predikce automaticky pro všechny hodnoty v souboru. Hodnoty z klávesnice zadáváme do pole „Naměřená hodnota“. Před započítáním predikce polohy musíme provést nastavení jednotlivých hodnot parametrů Kalmanova filtru :

- Mez manévrování : vyjadřuje práh, který určuje mez pro použití aditivního manévrovacího šumu.
- Chyba měření : určuje chybu měření (určení polohy objektu), hodnota je uváděna v jednotkách určení polohy objektu.
- Velikost okna : počet posledních hodnot, ze kterých se počítá průměrná hodnota odchylky od predikovaných hodnot.
- Koeficient manévrování : velikost konstanty, kterou se násobí všechny hodnoty matice manévrovacího šumu.

Poslední volbou je výběr použití matice manévrovacího šumu. Pokud tuto volbu nezvolíme nebude ke kovarianční matici v průběhu simulace přičítána manévrovací matice. Vzhled programu je vidět na obrázku (Obr. 1 : Program „Kalmanův filtr“).



Obr. 1 : Program „Kalmanův filtr“

Na začátku predikce příští polohy objektu musíme provést inicializaci Kalmanova filtru – tlačítko „Inicializace“. Při inicializaci zadáváme počáteční polohu objektu. V dalších krocích pak provádíme jen vkládání dalších hodnot polohy pomocí tlačítka „Vstup“. Program v každém kroku vypočte nové hodnoty proměnných Kalmanova filtru a jejich hodnoty zobrazí v tabulkách. Abychom měli přehled o průběhu důležitých veličin v čase (v jednotlivých krocích predikce) jsou vybraná data zobrazována i v grafech. Program umožňuje ukládat predikované hodnoty opět do souboru ve stejném formátu jako má soubor se vstupními hodnotami – tlačítko „Ulož“.

Popis implementace

Jelikož bylo potřeba vizuálně demonstrovat výstupní hodnoty Kalmanovy filtrace, zvolil jsem pro implementaci programu vývojové prostředí Borland C++ Builder 5.0. Stavové veličiny Kalmanova filtru jsou uloženy v maticích a k výpočtu hodnot těchto veličin je potřeba funkce pro operace s maticemi. Abych nemusel provádět implementace maticových operací, využil jsem volně dostupné šablony třídy pro práci s maticemi Matrix TCL Lite v1.12.

Vytvořil jsem třídu „Kalman“, ve které jsou implementovány funkce pro práci s Kalmanovým filtrem. Popis jednotlivých funkcí je uveden v hlavičkovém souboru „kalman.h“, zde jsem uvedl nejdůležitější z nich :

- **InitKalman** : tato funkce provede inicializaci Kalmanova filtru a současně predikuje příští polohu pro zadanou počáteční polohu objektu.
- **Evaluation** : provede aktualizaci hodnot Kalmanova filtru na základě nově zadané hodnoty polohy a předpoví polohu v dalším kroku.
- **Extrapolation** : provede extrapolaci polohy bez nutnosti zadání nové vstupní hodnoty polohy.
- **Manevrovani** : vypočte novou odchylku pro spouštění manévrovací matice, pokud odchylka překročí zadaný práh, je manévrovací matice přičtena ke kovarianční matici.

Pro určování průměrné hodnoty odchylek jsem vytvořil třídu „Maneuver“, která uchovává posledních n hodnot, ze kterých počítá průměrnou hodnotu odchylky, přičemž n je nastaveno na hodnotu „Velikost okna“.

Pro třídy potřebné pro implementaci funkcí Kalmanova filtru jsem vytvořil knihovnu „kalman.cpp“. Tato knihovna funkcí se dá použít samostatně v dalších aplikacích.

Program „Sledování pohybu objektů“

Pro sledování pohybujících se objektů v sekvenci snímků jsem vytvořil program „Sledování pohybu objektů“. Program se skládá ze dvou funkčních částí. První část provádí extrakci objektů z jednotlivých snímků a určuje korespondence mezi těmito objekty. Výstupem je seznam trajektorií, po kterých se detekované objekty pohybovaly. Druhá část provádí spojení korespondujících trajektorií. Využívá přitom extrapolace hodnot mezi zmizelými částmi trajektorie a jako kritérium pro vyhodnocení korespondencí používá výpočet odchylek polohy, rychlosti a zrychlení.

Program zpracovává vstupní sekvence pohybujících se objektů v libovolném formátu video sekvence. Pro nestandardní videoformáty je potřeba nainstalovat potřebný kodek. Vstupní sekvence pohybujících se objektů musí splňovat následující požadavky, aby mohl program provést extrakci objektů z jednotlivých snímků :

- Tmavé pozadí bez textury.
- Světlé objekty.

Tyto omezující podmínky jsou dány zaměřením programu na sledování bílých značek připevněných na lidském těle. Přičemž předměty mimo značky jsou potlačeny. K extrakci používá program prahování. Hodnotu prahu je možno nastavit ručně podle zobrazeného histogramu. Histogram můžeme kdykoliv aktualizovat pro aktuální snímek pomocí tlačítka „Histogram“.

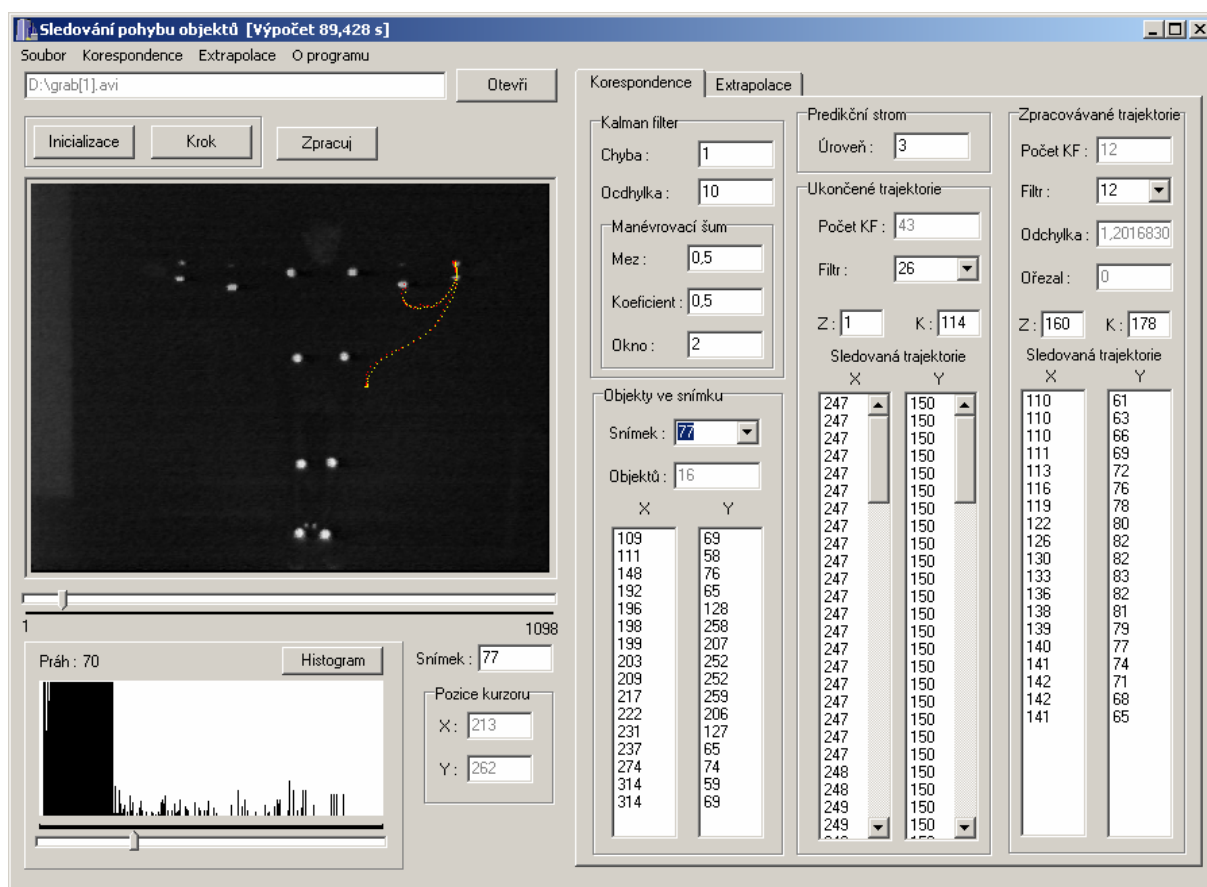
V programu je možno nastavovat hodnoty parametrů Kalmanova filtru, který provádí predikce příští polohy objektu. Parametry nastavení jsou shodné s parametry, které je možno nastavit v programu „Kalmanův filtr“. Dalšími parametry, které je možno nastavovat v programu jsou :

- Odchylnka : představuje koeficient, kterým určujeme velikost predikované oblasti.
- Úroveň : vyjadřuje hloubku stromu, ve které dochází k rozvětvení predikčního stromu, nebo-li počet kroků ve zpětném vyhodnocování.

V pravé části okna programu jsou dvě složky s výstupními hodnotami :

- Korespondence : obsahuje prvky pro nastavení parametrů při vyhodnocování korespondencí, seznam objektů pro jednotlivé vyhodnocené snímky, seznam ukončených trajektorií, seznam všech aktuálně sledovaných hypotéz.

- Extrapolace : obsahuje prvky pro nastavení parametrů při spojování trajektorií a seznam spojovaných trajektorií.



Obr. 2 : Program „Sledování pohybu objektů“

Abychom mohly vyhodnotit sekvenci pohybujících se objektů, zvolíme v menu „Soubor“ dále pak „Otevřít“ a vybereme videosekvenci. Zvolená videosekvence se načte a vybraný snímek bude zobrazen v levém okně. Posuvným šoupátkem pod oknem se zobrazeným snímkem je možno vybrat libovolný snímek ze sekvence.

Jakmile máme načtenou vybranou sekvenci snímků, můžeme spustit vyhodnocování pohybu. Pro vyhodnocení pohybu můžeme zvolit jednu ze dvou možností :

- Vyhodnotit celou sekvenci snímků : spouští se tlačítkem „Zpracuj“
- Vyhodnocovat postupně po jednotlivých snímcích, přičemž máme možnost pozorovat vznik jednotlivých hypotéz.

Při postupném vyhodnocování program zpracuje extrahované objekty v aktuálním snímku a přiřadí je jednotlivým hypotézám. Před započítím sledování pohybu objektů musíme provést inicializaci pomocí tlačítka „Inicializace“. Další snímky potom zpracováváme pomocí tlačítka „Krok“. Po každém kroku vyhodnotí program jeden snímek a umožní zobrazit aktuální stav hypotéz, tedy aktuálně sledovaných a ukončených trajektorií. Jednotlivé sledované hypotézy je možno vybrat z roletových menu ukončených, nebo zpracovávaných trajektorií. U každé pozorované trajektorie je zobrazen počáteční a koncový snímek, přičemž se po inicializaci nastaví jako počáteční snímek 1. U zpracovávaných trajektorií je možno navíc pozorovat aktuální odchylku od predikovaných hodnot. Při výběru některé z hypotéz se zobrazí sledovaná trajektorie. Žluté body představují skutečné polohy objektu a červené body představují predikovanou polohu. Chceme-li pozorovat pohyb bodu po zobrazené trajektorii, měníme aktuální snímek z roletového menu „Snímek“. Vybraná trajektorie zůstane zobrazena a bude se měnit zobrazení aktuálního snímku.

Jsou-li vyhodnoceny trajektorie pohybujících se bodů v sekvenci, můžeme provést jejich spojení, pokud mezi nimi existují korespondence. Pro ovládání funkcí pro spojování trajektorií se přepneme do složky „Extrapolace“. Při extrapolaci trajektorií máme možnost nastavit následující parametry :

- Chyba : určuje jakou mírou se má přiklánět extrapolace k naměřeným hodnotám.
- Odchylka : maximální odchylka od vypočtené odchyly spojivosti.
- Max.snímků : maximální počet extrapolovaných hodnot mezi spojovanými trajektoriemi.

První parametr „Chyba“ slouží k nastavení chyby Kalmanova filtru při predikci polohy. Tento parametr ovlivňuje kovarianční matici a důsledkem je vliv na extrapolované hodnoty. Čím větší nastavíme hodnotu tohoto parametru, tím méně budou extrapolované hodnoty ovlivněny posledními polohami objektů v trajektorii. Nastavení hodnot parametrů určování korespondence, kromě parametru „Úroveň“, je na sobě značně závislé. Z tohoto důvodu je nastavení parametrů individuální pro každou sledovanou sekvenci.

Popis implementace

Program obsahuje velké množství parametrů, které bylo nutné nastavovat a testovat jednotlivé funkce při různém nastavení hodnot. Proto jsem opět zvolil pro implementaci programu vývojové prostředí Borland C++ Builder 5.0. Funkce, které provádějí

vyhodnocování pohybu objektů a spojování trajektorií, jsou implementované do zvláštní knihovny, která je znovupoužitelná a nezávislá na vývojovém prostředí. Tyto funkce jsou implementovány v jazyce C++. Extrakce objektů je provedena v závislosti na vytvořené aplikaci a není tedy znovupoužitelná. Extrakce objektů se liší pro různé typy sledovaných sekvencí a proto jsem ji nepřidával do knihovny funkcí pro sledování pohybu. Hlavní funkce pro určování korespondencí pohybujících se objektů jsou následující :

- InitTracing – pro zadanou množinu objektů z počátečního snímku provede vytvoření a inicializaci nových hypotéz sledovaných objektů.
- TraceActiveObjects – pro zadanou množinu objektů provede vykonání všech příslušných operací při sledování pohybu objektů (predikce, prořezání, vyhodnocení vzniklých a ukončených trajektorií).
- EvalEndingList - provede vyhodnocení hypotéz při ukončení sledování pohybu.

Funkce pro spojování trajektorií využívají výstup funkcí pro určování korespondencí. Hlavní z nich jsou :

- GetDataExtrapolation – převezme seznam sledovaných trajektorií a nastavení parametrů, které byly využity při určování korespondencí.
- SearchLink – pro vybranou trajektorii hledá v seznamu nejlepší trajektorii pro napojení, v případě že ji nalezne, provede spojení obou trajektorií.
- IsExtrapolEnd – testuje, zda jsou v seznamu trajektorií ještě kandidáti na spojení.