

Univerza v Ljubljani
Fakulteta za elektrotehniko

Matej Perše

**AVTOMATSKA ANALIZA GIBANJA
V IZBRANIH MOŠTVENIH
ŠPORTNIH IGRAH**

DOKTORSKA DISERTACIJA

Mentor: prof. dr. Stanislav Kovačič

Ljubljana, 2009

*To delo posvečam ženi Tini in mojima dvema navihancema
Matevžu in Urbanu.*

Zahvala

”Čeprav si igral tekmo svojega življenja, je občutek skupinskega dela tisti, ki si ga zapomniš. Pozabiš na igro, zadetke in izid, nikoli pa ne pozabiš svojih kolegov.”

(John C. Maxwell)

Rad bi se zahvalil vsem, ki so kakorkoli prispevali k nastanku tega dela.

Še posebej bi se rad zahvalil dr. Mateju Kristanu, dr. Janezu Peršu, dr. Goranu Vučkoviču, Vildani Sulić in mentorju prof. dr. Stanislavu Kovačiču, ki so s svojimi kreativnimi predlogi in polemično diskusijo odločilno prispevali k nastanku tega dela.

Poleg tega bi se rad zahvalil tudi svoji družini za moralno podporo in razumevanje.

Matej Perše

Povzetek

V doktorski disertaciji je opisan koncept avtomatske analize skupinskega gibanja v moštvenih igrah, na podlagi trajektorij gibanja igralcev. V ta namen je bil razvit hierarhični koncept analize, pri katerem je upoštevana hierarhična struktura moštvenih iger. Upoštevanje strukture igre omogoča, da kompleksen problem analize moštvenih iger razgradimo na več enostavnejših, vsebinsko ločenih podproblemov ter s tem zmanjšamo računsko kompleksnost uporabljenih metod analize. Upoštevajoč strukturo igre je predlagana trinivojska analiza, ki je sestavljena iz segmentacije zveznega dogajanja v posamezne pomensko zaključene faze igre, razpoznavanja vrste aktivnosti znotraj posamezne faze igre in vrednotenje (ocenjevanje) izvedbe aktivnosti z uporabo šablon aktivnosti. Predstavljeni postopki so bili aplicirani na domeni košarke in deloma rokometu, saj ta dva športa, zaradi velike raznovrstnosti pri gibanju igralcev in velikega števila igralcev, ki sodelujejo v posamezni aktivnosti, predstavljata poseben raziskovalni izziv.

Prvo stopnjo analize moštvenih iger predstavlja segmentacija zveznega dogajanja v posamezne pomensko zaključene faze igre. Glavni cilj segmentacije je poiskati tiste dele igre, ki so najzanimivejši za nadaljnjo analizo (npr. faza napada ali faza obrambe). V ta namen je predlagan postopek segmentacije, ki je sestavljen iz dveh korakov. V prvem koraku so z uporabo statističnega modela igre, ki je podan v obliki mešanice Gaussovih porazdelitev (ang. *Gaussian Mixture models*), posamezni časovni trenutki klasificirani v eno izmed faz igre. Parametri modela so določeni z uporabo algoritma EM (ang. *Expectation Maximization*) iz ročno označenih odsekov igre. V drugem koraku je faza igre za vsak posamezni trenutek na novo preračunana, tako da so upoštevani tudi sosednji vzorci, s čimer je dosežena časovna konsistentnost dobljenih rezultatov. Rezultati eksperimentov so pokazali, da je predlagana metoda segmentacije zelo robustna, zaradi česar bi jo lahko aplicirali v različnih moštvenih igrah, saj omogoča natančno segmentacijo tudi v primeru različnih nepredvidljivih dogodkov, ki se lahko pojavijo med igro (npr. poškodbe, menjave ali izključitve igralcev).

Na podlagi segmentacije dobimo množico kratkih segmentov igre, ki predstavljajo napadalne ali obrambne aktivnosti ekipe. Zato je potrebno v drugem koraku analize, z uporabo šablon aktivnosti, razpoznati tip aktivnosti, ki jo je ekipa odigrala. V ta namen je bila predlagana uporaba, na trajektorijah temelječih detektorjev osnovnih košarkarskih akcij, s pomočjo katerih je iz trajektorij gibanja igralcev mogoče zgraditi visokonivojski semantični opis dogajanja na igrišču. Razpoznavanje aktivnosti je doseženo s primerjanjem opisa neznane aktivnosti z opisom šablone, ki ga dobimo po istem postopku. Pri tem je najprej potrebno rešiti problem korespondence med vlogami igralcev v šabloni in vlogami v analizirani aktivnosti. Za rešitev tega problema je predlagana razgradnja semantičnega opisa na posamezne agende igralcev, ki vsebujejo akcije, v katerih je posamezen igralec sodeloval. S primerjanjem agend igralcev določimo korespondence med vlogami igralcev ter podobnost med primerjanima semantičnima opisoma. Na podlagi izračunane podobnosti med opisom aktivnosti in opisi šablon, ki so na voljo, razporedimo neznano aktivnost v razred aktivnosti, z najmanjšo razdaljo med semantičnima opisoma. Kot je razvidno iz eksperimentov, je s predlagano metodo mogoče pravilno določiti tako vrsto odigrane aktivnosti kot tudi korespondenco med vlogami igralcev. Metoda se izkaže kot zelo robustna tudi v primerih pomanjkljivega sledenja in segmentacije, zaradi česar pride v semantičnem opisu do dodatnih, odvečnih simbolov.

Po tem ko sta tip aktivnosti in korespondenca med vlogami igralcev pravilno določeni, je mogoče izvesti tudi podrobnejšo analizo aktivnosti. Pri tem je potrebno upoštevati časovno-logične relacije med posameznimi akcijami, ki aktivnost sestavljajo. V ta namen sta predlagana dva različna pristopa za modeliranje teh relacij. V prvem primeru je uporabljena večnivojska Bayesova mreža, s katero modeliramo različne nivoje abstraktnosti analizirane aktivnosti (aktivnost, igralec, akcija, časovne relacije). Vozlišča Bayesove mreže so medsebojno povezana tako, da so upoštevane časovno-logične relacije med akcijami. V drugem primeru je za ocenjevanje uporabljena Petrijeva mreža. V tem primeru modeliramo posamezno akcijo kot trenutni dogodek v obliki verig, ki so sestavljene iz dveh mest in enega prehoda. Te verige medsebojno povežemo tako, da upoštevamo časovno-logične relacije med akcijami. Rezultati eksperimentov so pokazali, da je mogoče s predlaganima postopkoma ocenjevanja pravilno oceniti tako kakovost izvedbe aktivnosti kot tudi fazo, do katere je bila

aktivnost izvedena. Kljub temu je bilo ugotovljeno, da bi bilo potrebno za še podrobnejšo analizo, s katero bi se lahko še bolj približali dejanskim ocenam eksperta, v sam proces analize vpeljati dodatno komplementarno informacijo o dogajanju na igrišču, ki jo iz trajektorij gibanja igralcev ni mogoče pridobiti.

Metode analize so bile vgrajene v prototipni sistem za analizo igre, ki je del veliko večjega sistema za analizo dvoranskih športov. Prototipni sistem omogoča kvalitativno analizo, ki temelji na predhodno opisanih metodah, poleg tega pa so bile izdelane še dodatne funkcije za kvantitativno analizo, ki uporabniku omogočajo tudi analizo kvantitativnih parametrov gibanja igralcev med tekmo. Sistem je plod sodelovanja s športnimi strokovnjaki in je že bil uspešno uporabljen pri sodelovanju tako z domačimi kot tudi s tujimi strokovnjaki. Ključne besede:

računalniški vid, verjetnostni modeli, analiza skupinskega gibanja, hierarhična analiza aktivnosti, moštvene igre, trajektorije gibanja, Bayesove mreže, Petrijeve mreže, model mešanice Gaussovih porazdelitev, metoda podpornih vektorjev, segmentacija igre, košarka, roket

Abstract

This thesis is focused on the automatic multi-agent trajectory-based analysis of player motion in team sports. The hierarchical structure of the sport games is considered when developing the analysis methods. This way we decompose a very complex problem of team sport analysis into several subproblems. Given the hierarchical structure of the team sports, we propose a three-step analysis procedure comprised of segmentation of continuous game into several game phases, activity recognition inside the individual game phases and activity evaluation using activity templates. The proposed methods have been tested in basketball and partially in handball since, from the analysis standpoint, this two games represent a very challenging multi-agent environment.

In the process of the game segmentation we try to find parts of the game that are particularly interesting for further analysis (e.g. offensive phase or defensive phase of the game). To do this we propose a two-stage segmentation procedure. In the first stage a probabilistic game model is applied to the player-trajectory data in order to segment individual game instants into one of the three game phases (offensive game, defensive game and time-outs). In the second stage a nonlinear or Gaussian smoothing kernel is used to enforce the temporal continuity of the game. The obtained results suggest that the proposed approach is very robust and as such could be applied to various team sports. It can handle unusual game situations such as player exclusions, substitution or injuries which may happen during the game.

Once the game is segmented into the game phases we obtain a set of short game segments which denote the offensive or defensive team activities. For this reason, the next step of the analysis procedure focuses on the recognition of the type of activity the team was performing. To do this, we propose the use of trajectory-based action detectors (e.g. starting formation, screen and move) which are the building blocks of basketball game. These detectors are used to produce a semantic description of the observed activity. Finally, the activity is recognized by comparing its semantic description with the descriptions of manually defined

activity templates, stored in a database. To do this we have to solve the problem of player-role correspondence between the player roles in the analyzed activity and the activity template. For this reason we decompose the compared semantic description into five distinctive player agendas. By comparing the individual player agendas we solve the problem of player correspondence and at the same time obtain the similarity of the compared semantic description. Finally, the analyzed activity is assigned the label of the template that obtained the highest similarity (smallest distance of descriptions). Such an approach has turned out to be extremely robust with regard to the spurious symbols in the descriptions. The spurious symbols are obtained as a consequence of incomplete segmentation and errors in the data acquisition procedures.

Once the activity is recognized and the players-role correspondence is established, we can perform a detailed analysis of the activity by precisely analyzing different temporal and logical relations between individual actions. To do this we propose two different approaches for modeling the temporal and logical relations between actions. In the first case a multi-level Bayesian network is used to model the relations between different levels of abstraction which can be observed in the activity (i.e. activity, player, individual actions and temporal relations). In the second case the Petri net is used for evaluation. In this case the individual actions are modeled as instantaneous events in the form of a three-node action chains which are connected together by considering the previously described relations. The evaluation of the spatial and temporal properties is in both cases carried out using trajectory-based action detectors. The two presented approaches were evaluated using several examples of real basketball activities. The obtained experimental results suggest that these approaches can be used for the activity evaluation as well as to determine the stage in which the activity was concluded. Additionally, we can conclude that some complementary information should be used in order to bridge the gap between the scores obtained by the experts and the scores obtained by the proposed evaluation methods.

Described analysis methods were built into a prototypical game analysis module which is a minor part of a larger analysis system that was developed in recent years. The game analysis module enables the user to perform the qualitative analysis of the game using the previously described analysis methods. Furthermore, several additional functions were developed which enable the user to obtain the quantitative data about the player motion during the game. The

developed system is a result of collaboration with different sport experts and was already successfully tested in several domestic and international studies.

KEY WORDS: *computer vision, probabilistic models, multi-agent motion analysis, trajectory data, Bayesian networks, Petri nets, Gaussian Mixture models, Support Vector Machines, game segmentation, basketball, handball*

Vsebina

Povzetek	v
Abstract	ix
1 Uvod	1
1.1 Cilji in motivacija	3
1.1.1 Hierarhična analiza skupinskih aktivnosti	6
1.1.2 Izvirni znanstveni prispevki	8
1.2 Pregled literature	9
1.2.1 Analiza aktivnosti posameznika	11
1.2.2 Analiza skupinskih aktivnosti	12
1.3 Struktura doktorske disertacije	15
2 Struktura moštvenih iger in pridobivanje podatkov	17
2.1 Struktura moštvenih iger	17
2.1.1 Predstavitev taktično-tehničnih lastnosti moštvenih aktivnosti	20
2.2 Pridobivanje in obdelava podatkov	22
2.2.1 Obdelava podatkov	24
3 Časovna segmentacija moštvenih iger	26
3.1 Modeliranje igre	27
3.2 Časovna segmentacija	30

3.2.1	Klasifikacija posameznih vzorcev	30
3.2.2	Zagotavljanje časovne konsistentnosti	31
3.3	Eksperimenti	32
3.3.1	Eksperiment 1: Določanje parametrov metode	32
3.3.2	Eksperiment 2: Ostali vidiki segmentacije	39
3.4	Zaključek	44
4	Razpoznavanje aktivnosti	46
4.1	Izgradnja semantičnega opisa aktivnosti	47
4.1.1	Model igrišča	47
4.1.2	Detektorji košarkarskih akcij	48
4.2	Razpoznavanje aktivnosti	52
4.2.1	Določanje korespondence med vlogami igralcev	53
4.2.2	Določanje tipa aktivnosti	56
4.3	Eksperimenti	57
4.4	Zaključek	61
5	Ocenjevanje izvedbe aktivnosti z uporabo šablon aktivnosti	64
5.1	Določanje časovnih relacij	65
5.1.1	Ocenjevanje tehničnih lastnosti posameznih košarkarskih akcij	67
5.2	Uporaba Bayesovih mrež za ocenjevanje ustreznosti izvedbe aktivnosti	69
5.2.1	Izgradnja Bayesove mreže iz šablone aktivnosti	70
5.2.2	Časovne funkcije	71
5.2.3	Določanje parametrov Bayesove mreže	73
5.3	Uporaba Petrijevih mrež za ocenjevanje aktivnosti	80
5.3.1	Določanje časovnih parametrov mreže	83
5.3.2	Mehanizem ocenjevanja izvedbe aktivnosti	85

5.4	Eksperimenti	87
5.4.1	Eksperiment 1: Ocenjevanje z uporabo Bayesove mreže . .	88
5.4.2	Eksperiment 2: Ocenjevanje z uporabo Petrijevih mrež . .	91
5.4.3	Primerjava dobljenih rezultatov z ocenami eksperta	94
5.5	Zaključek	97
6	Prototipni sistem za analizo moštvenih iger	100
6.1	Zaključek	104
7	Zaključki	105
7.1	Smernice za nadaljnji razvoj	109
	Literatura	110
	Dodatek A	121
	Dodatek B	125
	Dodatek C	129
C.1	Algoritem EM	129
C.2	Metoda podpornih vektorjev (ang. Support Vector Machine - SVM)	131
C.2.1	Linearna klasifikacija	132
C.2.2	Nelinearna klasifikacija	133
C.2.3	Večrazredna klasifikacija	134
C.3	Bayesove Mreže	135
C.3.1	Uporaba navideznih dejstev pri vrednotenju Bayesove mreže	137
C.4	Petrijeve mreže	139
C.4.1	Primer delovanja Petrijeve mreže	141
C.4.2	Nadgradnja osnovnega koncepta Petrijeve mreže	142

Življenjepis	145
Bibliografija	147
Izjava	151

Poglavje 1

Uvod

V zadnjih dveh desetletjih je mogoče zaslediti velik razmah na področju video tehnologij. Te tehnologije omogočajo zajem in shranjevanje velikih količin posnetkov, ki vsebujejo informacije o gibanju ljudi, njihovih aktivnostih in medsebojnem sodelovanju ter njihovih interakcijah z okoljem. Skladno s hitrim razvojem teh tehnologij, se je povečalo zanimanje in možnosti za razvoj naprednih metod analize gibanja ljudi na video posnetkih. Na ta način se je analiza gibanja ljudi razvila v eno izmed najaktivnejših raziskovalnih usmeritev na področju računalniškega vida, digitalne obdelave podatkov, razpoznavanja vzorcev in umetne inteligence.

Rezultati teh raziskav se uporabljajo na številnih področjih kot so:

- **Interaktivna okolja**, kjer se pri načrtovanju in gradnji pametnih hiš, dognanja o gibanju ljudi uporabljajo pri načrtovanju različnih *pametnih senzorjev* v hiši.
- **Video nadzor**, kjer je glavni cilj analize video posnetkov detekcija nepredvidljivih, nenaravnih in sumljivih dogodkov.
- **Interakcije človeka in stroja**, kjer je cilj raziskav razviti postopke, s katerimi bi lahko stroji/roboti kot avtonomni agenti sodelovali z ljudmi in drugimi stroji.
- **Multimedija**, kjer se metode analize uporabljajo za potrebe avtomatskega razvrščanja, označevanja in iskanja po posnetkih.
- **Raziskave v športu**, s katerimi se skuša določiti zakonitosti, ki krojijo uspeh športnikov.

Na vseh naštetih področjih nastajajo velike količine podatkov, ki jih je zaradi časovnih omejitev, možno in smiselno ročno analizirati le do neke mere. Poleg tega pa se pri določenih področjih, kot so raziskave v športu, pojavlja še dodatna zahteva o nepristranskosti analize, saj bi lahko operater bistveno vplival na končne rezultate analize. To je le nekaj razlogov, zaradi katerih postaja avtomatska analiza gibanja ljudi, z uporabo metod *računalniškega vida*, vse pomembnejša.

Analizo gibanja ljudi sestavljajo postopki, na podlagi katerih iz slike pridobimo podatke o človeškem gibanju in njihovih aktivnostih. Hierarhično jih lahko uredimo v tri nivoje [1]:

1. **Detekcijo ljudi na sliki ali zaporedju slik.** Za detekcijo ljudi na sliki je bistvena *segmentacija* slike na premikajoče objekte in statično ozadje ter *klasifikacija* objektov na osebe (ljudi) in ostale premične objekte (npr. vozila ali živali). Rezultat detekcije so manjša področja slike, ki so zanimiva za nadaljnje postopke analize, kot so sledenje ali razpoznavanje aktivnosti, saj lahko ob dobri detekciji v nadaljnjih postopkih uporabimo zgolj ta področja.
2. **Sledenje ljudi.** V postopku sledenja povežemo značilnosti zaznanih objektov ali delov objektov na zaporednih slikah v smiselne sledi in na ta način dobimo dvodimenzionalne (2D) ali tridimenzionalne (3D) *trajektorije*. Pri določanju relacij med značilnostmi na dveh zaporednih slikah se uporabljajo tako modeli gibanja objekta (npr. hitrost gibanja objekta in/ali njegov položaj na sliki) kot tudi modeli njegovih prostorskih značilnosti (npr. višina ali širina). Pravilno sledenje objektov je zelo pomemben del analize gibanja, saj so običajno rezultati sledenja (trajektorije) uporabljeni v procesu razumevanja in opisovanja človeških aktivnosti.
3. **Analiza človeških aktivnosti.** Tako aktivnosti posameznika, kot tudi skupinske aktivnosti, so sestavljene iz večjega števila medsebojno ločenih *akcij*, ki morajo biti izvedene v točno določenem časovnem zaporedju. Čeprav je termin *akcija* v športu (zlasti v košarki) pogosto uporabljen pri poimenovanju aktivnosti (npr. napadalna akcija ponazarja aktivnost, ki se je zgodila v napadu), bomo v tem delu uporabljali terminologijo s področja računalniškega vida. Tako bomo uporabljali hierarhijo: *aktivnost* (npr. igranje določenega tipa napada), ki jo sestavlja več *akcij* (npr. bloкаде,

podaje, itd.). Akcije pa so sestavljene iz *elementov akcij* (premik igralčevih rok, nog ali glave).

Analiza človeških aktivnosti načeloma zajema ***zaznavanje akcij*** ter ***razpoznavanje aktivnosti*** in ***ocenjevanje izvedbe aktivnosti***. Da bi lahko aktivnost analizirali, moramo najprej *zaznati* posamezne akcije, ki sestavljajo aktivnost. V okviru zaznavanja akcij je potrebno izdelati različne *detektorje akcij*, s pomočjo katerih pridobimo višjenivojsko informacijo o izvedbi aktivnosti. To informacijo nato uporabimo v procesu *razpoznavanja aktivnosti*, katerega cilj je aktivnosti pripisati nek pomen oziroma ji poiskati najbolj podobno že razpoznano aktivnost. Zadnji korak analize aktivnosti predstavlja *ocenjevanje izvedbe aktivnosti*, katere cilj je ugotoviti, ali je bila aktivnost izvedena v skladu z našimi pričakovanji oziroma pričakovanji eksperta.

V doktorski disertaciji so predstavljene metode in postopki za analizo človeških aktivnosti v moštvenih športnih igrah. Glavni namen disertacije je bil preučiti možnost uporabe obstoječih metod računalniškega vida za analizo skupinskih aktivnosti ter razviti postopke, na podlagi katerih bi bilo tovrstno analizo mogoče uporabljati pri vsakodnevni analizi kot pomoč trenerjem pri treningih in pripravi na tekme.

1.1 Cilji in motivacija

Ključna razlika med analizo gibanja posameznika in analizo gibanja skupine ljudi je predvsem v kompleksnosti metod analize. Tako je potrebno pri analizi skupinskega gibanja poleg analize vsakega posameznika upoštevati tudi interakcije med njimi, saj lahko zgolj na ta način naredimo verodostojno analizo opazovanega dogajanja. Pri tem se pojavljajo nekateri problemi, ki so specifični za analizo skupinskega gibanja, med katerimi lahko izpostavimo:

- **Velikost prostora stanj** oziroma število različnih situacij, v katerih se lahko znajde večje število ljudi. Prostor s povečevanjem števila ljudi, ki so vključeni v aktivnost, narašča eksponentno. Če je v primeru analize posameznika velikost prostora stanj, s katerim lahko opišemo njegovo gibanje, enaka M , se v primeru opazovanja n ljudi ta prostor poveča na

kar M^n različnih stanj. V primeru, da predstavimo obnašanje posameznega človeka z dvema stanjema in je v aktivnost vključenih pet ljudi, pomeni to kar $2^5 = 32$ različnih stanj. V primeru, da posameznikovo gibanje opišemo s petimi stanji, pa celoten prostor stanj naraste na kar 3125 različnih stanj. To pa pomeni, da je uporaba verjetnostnih metod, kot so prikriti Markovski modeli (ang. *Hidden Markov Models - HMM*) ali dinamične Bayesove mreže (ang. *Dynamic Bayesian Networks*), ki se pogosto uporabljajo za modeliranje aktivnosti posameznika, za analizo skupinskih aktivnosti praktično neuporabna. Zaradi velikosti prostora stanj, bi bil tak model aktivnosti preveč kompleksen in bi ga bilo brez določenih poenostavitev ali omejitev, tudi v primeru, ko bi imeli na voljo veliko količino učnih vzorcev, zelo težko zgraditi.

- **Časovna izvedba aktivnosti** predstavlja drugi velik izziv pri analizi skupinskih aktivnosti, saj lahko skupina ljudi izvede določeno aktivnost na veliko različnih načinov, ki vsi privedejo do enakega končnega cilja. To dejstvo je potrebno upoštevati pri načrtovanju postopkov analize, ki morajo biti dovolj fleksibilni, da omogočajo možnost različnih (predvsem časovnih) izvedb aktivnosti.
- **Kombinatorična kompleksnost določanja vlog posameznikov.** Določanje vlog posameznikov znotraj skupine predstavlja enega ključnih dejavnikov uspešne analize skupinskega gibanja, ker lahko šele v primeru, da poznamo posameznikove naloge znotraj skupine, določimo oziroma ovrednotimo, kako uspešno je dane naloge opravil. To pa pomeni, da je potrebno v primeru analize skupine petih ($N = 5$) ljudi opraviti kar 120 ($N!$) ponovitev postopka analize, s čimer se čas izvedbe analize občutno poveča. Rešitev tega problema zahteva razvoj ustreznih metod, na podlagi katerih je mogoče za vsakega posameznika določiti njegovo vlogo v skupini.
- **Kompleksnost interakcij med posamezniki.** Z večanjem števila oseb, ki so vključene v aktivnost, se povečuje tudi kompleksnost interakcij med temi osebami. V splošnem bi lahko rekli, da se s povečevanjem števila oseb fokus analize spreminja, saj je v primeru opazovanja majhnega števila oseb veliko bolj pomembno njihovo individualno obnašanje, medtem ko postaja s povečevanjem števila oseb vse bolj pomembna njihova medsebojna interakcija.


- **Nivo podrobnosti analize.** Pravilno izbran nivo podrobnosti opazovanja je gotovo eden ključnih faktorjev analize in bistveno vpliva na njeno uspešnost. Ključno vprašanje pri tem pa je, kako natančno je sploh smiselno opazovati osebo, saj s povečevanjem nivoja podrobnosti bistveno povečamo tudi kompleksnost opazovanja [2]. Tako bi bilo nesmiselno opazovati gibanje igralčevih okončin v primeru, da želimo opazovati gibanje igralca po igrišču. V splošnem velja, da se pri analizi posameznikov uporabljajo bolj grobi nivoji podrobnosti kot v primeru analize skupinskega dogajanja, in se najpogosteje opazuje človeka kot celoto.

Zaradi navedenih razlogov se, za razliko od analize gibanja posameznika, pri analizi skupinskega gibanja večinoma uporabljajo enostavnejše značilnice za opis človekovega telesa, kot so denimo težišče človekovega telesa na sliki ali predstavitev telesa z očrtanim pravokotnikom (angl. bounding box) ali elipso. Razlog za to je, da je pri analizi skupinskega gibanja fokus raziskav usmerjen predvsem k analizi dogajanja in ne toliko v detekcijo ljudi in njihovo sledenje, ki sta običajno zgolj implicitno vključena v sam postopek analize. Drugi razlog za uporabo preprostejših značilnic pa lahko najdemo v dejstvu, da je pri analizi skupinskega gibanja veliko bolj pomembna prostorska informacija o tem, kje se posameznik oziroma skupina nahaja na posnetku. Zaradi tega se za opis gibanja najpogosteje uporabljajo *trajektorije gibanja*, saj predstavljajo zelo zgoščeno informacijo o tem, *kaj* je človek oziroma skupina počela, poleg tega pa vsebujejo tudi informacijo o tem, *kje* se je to dogajalo.

Raziskave, povezane z analizo aktivnosti, so še v začetnih fazah in šele pridobivajo na pomenu. Delno je to posledica velike odvisnosti tega nivoja analize od rezultatov detekcije in sledenja, delno pa je to posledica dejstva, da je človeško obnašanje zelo *raznovrstno* in *kompleksno*. Zaradi tega sta razvoj in implementacija metod računalniško podprte analize gibanja bistveno otežena. Prav velika kompleksnost človeškega gibanja predstavlja za analizo aktivnosti velik raziskovalni izziv. Velika večina raziskovalcev skuša problem razpoznavanja in interpretacije skupinskega gibanja rešiti z uporabo zelo kompleksnih modelov gibanja, ki so pogosto neprimerni v situacijah, ko je potrebno analizirati velike količine podatkov v zelo omejenem času. Zato je v takšnih primerih, problem analize skupinskih aktivnosti potrebno rešiti sistematično, z uvedbo hierarhične strukture analize. Na ta način kompleksno dogajanje razgradimo na množico enostavnejših aktivnosti, ki jih je možno analizirati ločeno.

1.1.1 Hierarhična analiza skupinskih aktivnosti


Cilj te doktorske disertacije je bil razviti postopke, ki omogočajo avtomatsko, večnivojsko analizo skupinskega gibanja v moštvenih igrah. Predlagan postopek analize "od zgoraj navzdol" (ang. *top-down*) je bil izdelan z upoštevanjem hierarhične strukture moštvenih iger, ki jih želimo analizirati ter z uspevanjem količine podatkov, ki jih moramo obdelati v posameznem koraku analize (slika 1.1). Tako lahko na prvem (najbolj grobem in računsko najmanj zahtevnem) nivoju analize, kjer imamo opravka z ogromno količino podatkov, opazujemo skupino kot celoto in njeno obnašanje časovno razdelimo - *segmentiramo* v določeno število vsebinsko zaključenih aktivnosti, ki jih nato v naslednjih korakih podrobneje proučimo s kompleksnejšimi postopki. V primeru varnostnih aplikacij so tovrstne aktivnosti na primer prihod ali odhod skupine v oziroma iz določenega območja, v primeru športa pa faza igre, v kateri se skupina nahaja (npr. napad, obramba, aktivna ali neaktivna igra).



Slika 1.1: Prikaz nivoja podrobnosti analize gibanja v odvisnosti od količine podatkov.

Šele ko je aktivnost, v kateri se skupina nahaja, pravilno segmentirana, je smiselno podrobneje analizirati tudi dogajanje znotraj te aktivnosti. Tovrstna analiza lahko obsega *razpoznavanje tipa aktivnosti* ter podrobnejše *ocenjevanje kakovosti izvedbe te aktivnosti*. V ta namen predlagamo uporabo že uveljavljenih metod za analizo gibanja posameznika (npr. Bayesovih ali Petrijevih mrež ter semantičnih opisov dogajanja), ki jih bomo v okviru tega dela nadgradili do te

mere, da bodo uporabne tudi za analizo skupinskih aktivnosti. Slika 1.2 prikazuje shemo predlaganega večnivojskega postopka analize skupinskih aktivnosti ter dodatne informacije, ki je potrebna pri določenem koraku analize (npr. modeli igre in šablone aktivnosti) in mora biti v naprej naučena oziroma definirana s strani eksperta.



Slika 1.2: Shema hierarhične analize skupinskih aktivnosti.

Kot je razvidno iz slike, je proces analize skupinskih aktivnosti sestavljen iz štirih korakov:

- **Zajem in predobdelava podatkov**, pri katerem z uporabo senzorjev dobimo podatke o gibanju igralcev po igrišču. V našem primeru je bil uporabljen slikovni senzor.
- **Segmentacija zveznega dogajanja**. Bistvo tega koraka je z uporabo modela igre poiskati pomensko podobne dele igre, ki jih lahko v naslednjih korakih podrobneje analiziramo. Ker imamo na tem nivoju analize opravka z ogromno količino podatkov (npr. 1.5 milijona pozicij igralcev za en polčas košarkarke tekme), mora biti postopek segmentacije čim bolj učinkovit.
- **Razpoznavanje aktivnosti**. Potem, ko so različne vrste aktivnosti pravilno segmentirane (npr. napad ali obramba), je potrebno določiti tip aktivnosti, ki jo je skupina izvedla. Istočasno lahko v tem koraku analize določimo tudi vlogo, ki jo ima posamezen igralec v skupini. Razpoznavanje aktivnosti je izvedeno tako, da primerjamo množico neznanih aktivnosti z

množico šablon, ki so shranjene v zbirki šablon. Ker je število aktivnosti še vedno precej veliko, poleg tega pa je potrebno vsako neznano aktivnost analizirati z vsemi šablonami iz zbirke, mora biti razpoznavanje izvedeno na takšnem nivoju podrobnosti, ki nam še omogoča razločevanje med posameznimi vrstami aktivnosti.

- **Ocenjevanje ustreznosti izvedbe aktivnosti.** Ko je bila vrsta aktivnosti pravilno razpoznana in vloga posameznih igralcev pravilno določena, lahko izvedemo podrobnejšo analizo njenih prostorskih in časovnih lastnosti. Ker gre v tem primeru za analizo posamezne aktivnosti z eno samo šablono, so lahko uporabljeni postopki analize bolj kompleksni, s čimer dobimo boljši in natančnejši vpogled v samo dogajanje med izvajanjem aktivnosti.

1.1.2 Izvirni znanstveni prispevki

V okviru zadanih ciljev so bile razvite metode za analizo skupinskih aktivnosti, ki so v doktorski disertaciji zajete v štirih izvirnih znanstvenih prispevkih k znanosti:

- **Metoda segmentacije zveznega skupinskega dogajanja na pomensko zaključene aktivnosti.** Najprej je predstavljen postopek, na podlagi katerega iz ročno označenih učnih vzorcev tekme zgradimo statistični model igre, ki je nato uporabljen pri segmentaciji igre v zaključene faze igre. Predlagana sta bila dva različna statistična modela za opis posameznih faz igre ter proučeni različni vzroki, ki vplivajo na končni rezultat segmentacije.
- **Shema razpoznavanja tipa aktivnosti na podlagi šablon aktivnosti.** V ta namen so bili izdelani specifični, na trajektorijah temelječi detektorji posameznih elementov aktivnosti, na podlagi katerih je mogoče iz trajektorij gibanja igralcev izdelati kompakten *semantični opis* dogajanja na igrišču, ki ga imenujemo *opis aktivnosti*. Enak postopek uporabimo tudi na trajektorijah, ki jih pridobimo iz šablon aktivnosti. Razpoznavanje neznane aktivnosti je izvedeno na podlagi primerjanja opisa neznane aktivnosti z opisom šablone. Rezultat primerjanja je razdalja, ki odraža podobnost med aktivnostjo in šablono. Z uporabo istega postopka je možno določiti tudi korespondenco med vlogami igralcev na igrišču ter vlogami v šabloni.

Ta informacija je ključna v naslednjem koraku analize, ki ga predstavlja podrobnejše ocenjevanje uspešnosti izvedbe aktivnosti.

- **Shema vrednotenja ustreznosti izvedbe aktivnosti s predlogami aktivnosti na podlagi statističnih modelov obnašanja.** V ta namen sta predlagana dva pristopa za vrednotenje uspešnosti izvedbe aktivnosti. Oba pristopa temeljita na ocenjevanju izvedbe posameznih elementov aktivnosti ter njihovih medsebojnih časovnih in logičnih relacij. Pri prvem pristopu so uporabljene štiri-nivojske Bayesove mreže, kjer vsak nivo predstavlja določen abstraktni nivo aktivnosti (skupna ocena aktivnosti, ocene posameznih igralcev, ocena posameznih akcij, ocena časovnih relacij). Predlagani so detektorji za detajlno ocenjevanje prostorskih parametrov akcij ter njihovih časovnih relacij v primerjavi z ostalimi akcijami iz aktivnosti. Izhodi teh detektorjev predstavljajo ocene uspešnosti izvedbe posameznih akcij. Delne ocene razširimo skozi mrežo do najbolj abstraktnega nivoja ter na ta način dobimo skupno oceno izvedbe aktivnosti. Pri drugem pristopu so za modeliranje časovnih in logičnih zakonitosti med akcijami uporabljene Petrijeve mreže. Tudi v tem primeru so uporabljeni isti detektorji akcij, struktura Petrijevih mrež pa je uporabljena za modeliranje časovnih in logičnih zakonitosti med temi akcijami.
- **Prototipni sistem za analizo skupinskih aktivnosti v moštvenih športnih igrah (predvsem v košarki in rokometu).** Glavni namen sistema je omogočiti uporabniku, ki nima poglobljenega znanja s področja metod računalniškega vida in razpoznavanja vzorcev, čim bolj enostavno pridobivanje tako kvalitativnih kot tudi kvantitativnih podatkov o analizirani moštveni igri. V ta namen so bili uporabljeni predhodno opisani postopki. Hkrati pa je bil izdelan še poseben nabor funkcij, ki omogočajo avtomatsko analizo različnih kvantitativnih parametrov igre. Prototipni sistem je bil izdelan v programskem okolju Matlab.

1.2 Pregled literature

Pomembnejši dosežki, povezani z analizo gibanja ljudi, so bili zbrani in predstavljeni v številnih preglednih člankih [1, 3, 4, 5, 6, 7]. Ob preučitvi teh

člankov lahko ugotovimo, da ne obstaja enotna metodologija delitve različnih postopkov analize. Tako denimo Wang, Hu in Tan [1] razdelijo metode analize glede na kompleksnost uporabljenih postopkov na splošne postopke (dinamično ukrivljaje časa - ang. *Dynamic Time Warping*, prikriti Markovovi modeli in nevronske mreže - ang. *Neural networks*), na razpoznavanje aktivnosti (z uporabo šablon aktivnosti in metod osnovanih na prostoru stanj) ter na semantični opis aktivnosti (z uporabo naravnih jezikov za opis dogajanja). Aggarwal [4] razdeli metode razpoznavanja aktivnosti na takšne, ki pri razpoznavanju uporabljajo šablone aktivnosti in na metode, osnovane na prostoru stanj. Isti avtor razdeli v poznejšem pregledu metode analize na *neposredne* in *posredne* [6]. V prvem primeru so aktivnosti človeka razpoznane neposredno iz slike, medtem ko so v drugem primeru najprej na posameznih slikah razpoznane različne poze človekovega telesa, ki so nato uporabljene v procesu razpoznavanja njegovih aktivnosti.

Pomembno vlogo pri analizi gibanja ima tudi *nivo podrobnosti*, na katerem opazujemo gibanje človeka. Ta problem sta v svojem pregledu posebej izpostavila Aggarwal in Park [6], kjer avtorja razdelita postopke razpoznavanja v tri nivoje podrobnosti - grob, srednji in podroben nivo opazovanja. Na grobem nivoju je človeško telo predstavljeno kot celota, pri čemer so ljudje predstavljeni s pravokotniki, elipsami ali pa zgolj s težiščem njihovega telesa. Na srednjem nivoju so ljudje predstavljeni na podlagi njihovih glavnih delov telesa, kot so glava, trup, roke in noge. Na najbolj podrobnem nivoju pa so pri razumevanju obnašanja najpogosteje uporabljeni zgolj posamezni deli telesa, kot so roke, glava, ustnice, itd. Pri tem lahko ugotovimo, da se s povečevanjem števila ljudi, ki so vključeni v neko aktivnost, nivo podrobnosti, na katerem opazujemo dogajanje, zmanjšuje. Analogno s tem se zmanjšuje kompleksnost uporabljenih modelov za predstavitev aktivnosti. Po drugi strani pa se pri bolj detajlni analizi gibanja posameznih delov telesa uporabljajo zelo kompleksni in specifični modeli gibanja.

Pri proučevanju člankov s področja analize gibanja lahko prav tako zasledimo zelo nekonsistentno uporabo *terminologije* za opis dogajanja, saj avtorji zelo nedosledno uporabljajo izraze kot so *akcije* (angl. *actions*), *aktivnosti* (angl. *activities*) in *obnašanje* (angl. *behavior*). Tako je Nagel [8] v enem prvih del s področja analize obnašanja predlagal hierarhijo petih terminov za opis dogajanja - *sprememba* (angl. *change*), *dogodek* (angl. *event*), *glagol* (angl. *verb*), *epizoda* (angl. *episode*) in *zgodovina* (angl. *history*). Alternativno hierarhijo je uporabil

Bobick [9], ki je predlagal uporabo treh terminov *gibanje* (angl. motion), *aktivnost* (angl. activity) in *akcija* (angl. action) za opis dogajanja na različnih nivojih podrobnosti. Poleg tega pa so nekateri avtorji [10, 11] uporabljali tudi termine kot so *situacija* (angl. situation), *elementi akcije* (angl. action primitives). V zadnjem času pa se je še najbolj uveljavila hierarhija, ki za opis dogajanja uporablja tri termine in sicer ***element akcije***, ***akcija*** in ***aktivnost*** [7]. Kot primer vzemimo hierarhijo v športu, kjer zaporedje *elementov akcij* (fizičnih gibov igralca), kot so premiki roke ali noge, sestavljajo *akcijo*, katere namen je podaja žoge. *Aktivnost* pa v tem primeru predstavlja igranje določenega košarkarskega napada.

1.2.1 Analiza aktivnosti posameznika

Postopki analize gibanja posameznika so bili podrobno predstavljeni v preglednem članku, ki ga je podal Gavrilica [3]. V članku avtor problem razpoznavanja posamičnih aktivnosti poda kot problem klasifikacije časovno spremenljivih značilnic, pri katerem je potrebno neznani sekvenci poiskati najbolj podobno že razpoznano prototipno sekvenco. Pri tem razdeli postopek razpoznavanja v dva ločena problema - v učenje prototipne sekvence iz učnih sekvenc (gradnjo modela) ter v klasifikacijo neznane sekvence na podlagi teh prototipov.

Pri učenju in klasifikaciji se uporabljajo tehnike modeliranja, s katerimi skušajo avtorji zajeti časovno komponento spreminjanja značilnic. Tak primer je denimo uporaba prostorsko-časovnih predlog (angl. *spatio-temporal templates*) pri razpoznavanju hoje [12, 13] ali pa uporaba prikritih Markovih modelov (angl. Hidden Markov Models - HMMs) [14, 15, 16, 17] oziroma Bayesove mreže [18, 19], s katerimi je mogoče modelirati različna stanja človekovega obnašanja ter prehodov med temi stanji. Najpogostejše ta stanja predstavljajo kar posamezne akcije, ki naj bi jih človek izvedel v okviru določene aktivnosti.

Čeprav je pri analizi gibanja posameznega človeka običajno uporabljen podrobnejši opis človeškega telesa, pa je mogoče tudi tu zaslediti metode, ki razpoznavajo človeško obnašanje na grobem nivoju podrobnosti. Tako sta Johnson in Hogg [20, 21] predstavila dva pristopa k modeliranju nelinearnega obnašanja, na podlagi trajektorij gibanja ljudi, pri čemer sta opazovala zgolj gibanje težišča njihovega telesa. V prvem primeru sta avtorja pri razpoznavanju različnih stanj njihovega gibanja uporabila vektorje njihovih trenutnih položajev

in hitrosti gibanja, ki sta jih nato klasificirala z uporabo nevronske mreže (angl. Neural network). V drugem primeru, pa sta pri klasifikaciji uporabila model, ki je temeljil na mešanici Gaussovih porazdelitev, kjer je posamezna Gaussova porazdelitev predstavljala določeno stanje človeka (npr. mirovanje, hoja ali tek). Podoben pristop sta v svojem delu uporabila Nair in Clark [22], ki sta pri razpoznavanju neobičajnega gibanja ljudi po hodnikih uporabila prikrite Markovove modele, s katerimi sta modelirala gibanje ljudi med različnimi prostori stavbe.

1.2.2 Analiza skupinskih aktivnosti

Analiza skupinskih aktivnosti predstavlja neke vrste nadgradnjo analize aktivnosti posameznika, saj je potrebno pri analizi skupinskih aktivnosti, poleg opazovanja akcij posameznika, opazovati tudi njegove interakcije z drugimi osebami. Tovrstno analizo najpogosteje zasledimo na dveh področjih in sicer pri video nadzoru ljudi ter analizi aktivnosti v športu.

Analiza obnašanja ljudi na področju video nadzora [23, 24, 25, 26, 27] najpogosteje vključuje, poleg analize akcij posameznikov, tudi analizo njihovih interakcij z drugimi ljudmi. Čeprav so predstavljeni postopki večinoma omejeni na interakcije med dvema posameznikoma, pa bi jih lahko razširili tudi na večje število ljudi [28]. Tako Hongeng in Nevatia [24] pri razpoznavanju različnih aktivnosti med pešci na ulici (angl. *pedestrians*), aktivnost predstavita kot skupek eno-nitnih (ang. *single thread*) ali večnitnih dogodkov (ang. *multiple thread events*). Te dogodke medsebojno povežeta z uporabo končnih avtomatov (ang. *Finite State Machines*). Rezultat razpoznavanja je podan kot verjetnost, da so se opazovane akcije zgodile v točno določenem zaporedju. Nurita in ostali [26] v svojem delu predstavijo zelo enostaven pristop razpoznavanja preprostejših interakcij med dvema pešcema, ki temelji na uporabi prikritih Markovovih modelov. Glavna pomankljivost predlaganega pristopa je slaba izraženost interakcij med pešcema, saj gre predvsem za opazovanje kombinacij različnih možnih stanj (npr. pozicije in hitrosti gibanja) med opazovanima pešcema na sliki, pri čemer so njune relacije zgolj implicitno izražene znotraj posameznih stanj modela.

V področje analize skupinskih aktivnosti bi pogojno lahko uvrstili tudi raziskave, ki se ukvarjajo z indeksiranjem videoposnetkov na podlagi vizualne

informacije [29, 30, 31, 32, 33]. V tovrstnih raziskavah skušajo avtorji na podlagi vizualne vsebine slike (barve ali teksture) ali spremembe te vsebine na zaporedju slik iz daljših posnetkov pridobiti zanimivejše odseke dogajanja. Čeprav v tem primeru ne gre neposredno za razpoznavanje gibanja ljudi na sliki, pa metode indeksiranja pogosto temeljijo na tem, kaj ljudje na sliki počnejo, zaradi česar jih lahko uvrstimo v področje analize skupinskega gibanja.

Najpogosteje se z raziskavami skupinskega gibanja srečamo v športu [34, 35, 36, 37], kjer se pojavljajo zelo zapleteni vzorci obnašanja, ki vključujejo tako akcije posameznih ljudi, kot tudi koordinirano medsebojno sodelovanje celotne skupine. Pri tem skušajo avtorji *kompleksne aktivnosti* modelirati z določenim naborom enostavnejših akcij in interakcij med posamezniki, pri čemer upoštevajo različne časovne in logične omejitve med temi akcijami. Pionirsko delo na področju razpoznavanja skupinskih aktivnosti sta v svojem delu predstavila Intille in Bobick [34], ki pri analizi organiziranih aktivnosti v ameriškem nogometu uporabljata nizkonivojske detektorje časovnih in logičnih relacij med igralci. Podatke iz teh detektorjev nato z uporabo zelo kompleksnih Bayesovih mrež povežeta v skupno predstavitev dogajanja na igrišču. Na področju analize košarke so Jug in ostali [36] predstavili postopek za detekcijo in razpoznavanje koordiniranih aktivnosti, ki temelji na razčlenjevanju strukture igre na posamezne tehnične elemente in opazovanje taktične strukture med temi elementi. Za detekcijo tehničnih elementov so uporabljeni na trajektorijah temelječi detektorji osnovnih košarkarskih elementov. Informacija iz teh detektorjev pa se združuje v skupno oceno, ki predstavlja skupno taktično-tehnično izvedbo napada, z uporabo časovnih relacij in logičnih relacij v obliki Noisy AND in Noisy OR operatorjev [38].

Pomembno področje analize skupinskega gibanja predstavlja tudi uporaba determinističnih modelov skupinskega gibanja. V glavnem v to skupino spadajo metode, ki temeljijo na uporabi končnih avtomatov [35, 39] in Petrijevih mrež (ang. *Petri nets*) [40, 41, 42]. Tako Li in Woodham [35, 39], pri modeliranju specifičnih hokejskih aktivnosti (protinapadov in strelav na gol) uporabljata končne avtomate (angl. *Finite state machines*), s katerimi modelirata različne zaključke hokejskih protinapadov. Dobljene modele nato uporabita pri ocenjevanju kakovosti izvedbe opazovanega napada in pri iskanju morebitnih boljših scenarijev za zaključek le-teh. V primeru uporabe Petrijevih mrež [40, 41, 42] so možna stanja sistema predstavljena z mesta, prehajanje med stanji

pa je ponazorjeno s prehodi. Poleg prijazne grafične zasnove, ki uporabniku omogoča detajlen vpogled v samo izvajanje procesa, omogočata opisani metodi tudi relativno enostavno gradnjo modela, saj ti modeli ne vsebujejo velikega števila parametrov. Slaba stran teh metod pa je, da so primerne za modeliranje rigidnejših aktivnosti, pri katerih ne prihaja do velikih odstopanj pri časovni izvedbi posameznih akcij, ki sestavljajo aktivnost.

V kategorijo razpoznavanja skupinskega gibanja bi lahko šteli tudi uporabo prenašalnih mrež (ang. *Propagation nets*) [43, 44], ki so po delovanju zelo podobne Petrijevim mrežam, vendar temeljijo na statističnem modeliranju zakonitosti med stanji sistema, zaradi česar bi jih lahko uvrtili tako med deterministične kot tudi stohastične metode, saj predstavljajo nek hibrid med obema kategorijama. Avtorji predlagani postopek uporabljajo za razpoznavanje korakov pri merjenju glukoze v krvi, ki je sestavljena iz večjega števila sočasno odvijajočih se akcij.

1.3 Struktura doktorske disertacije

Doktorska disertacija je strukturirana tako, da sledi predlaganim znanstvenim prispevkom. V ta namen je v vsakem poglavju predstavljena problematika posameznega prispevka, nato metodologija in eksperimenti, na koncu pa so podani rezultati in iz njih izpeljana dognanja in zaključki.

POGLAVJE 2 je namenjeno predstavitvi problematike analize skupinskega gibanja in pomembnejših značilnosti skupinskih aktivnosti. Podan je način predstavitve in zapisa tovrstnih aktivnosti v športu (še posebej v košarki). Na koncu so opisani postopki pridobivanja in predobdelave podatkov, ki so bili uporabljeni pri validaciji predlaganih metod za analizo.

V POGLAVJU 3 so podani postopki za časovni razrez zveznega skupinskega dogajanja v posamezne faze igre (faza napada, faza obrambe in odmori). V ta namen je predstavljen postopek izgradnje modela iz vnaprej ročno označenih podatkov ter njegova uporaba. Ovrednoteni so različni parametri modela kot sta dolžina uporabljenega filtra in število učnih vzorcev. Rezultati predlagane metode so primerjani z drugim postopkom segmentacije, pri katerem je za modeliranje uporabljena metoda Podpornih vektorjev (ang. *Support Vector Machines*).

V POGLAVJU 4 je predlagan postopek za razpoznavanje aktivnosti z uporabo šablon aktivnosti. Bistvo postopka je iz trajektorij aktivnosti in trajektorij, ki jih dobimo na podlagi simulacije šablone, zgraditi strjen visokonivojski zapis dogajanja, ki ga imenujemo *semantični opis aktivnosti*. S primerjavo semantičnega opisa šablone in opazovane aktivnosti lahko ugotovimo, kateri šabloni je neznana aktivnost najbolj podobna, prav tako pa lahko določimo korespondenco med vlogami igralcev na igrišču in tistimi v šabloni.

V POGLAVJU 5 sta podana dva postopka ocenjevanja pravilnosti izvedbe aktivnosti, ki je podana s šablono. Oba postopka temeljita na razgradnji aktivnosti na posamezne elemente - akcije ter ocenjevanje prostorskih in časovnih lastnosti teh akcij. Z uporabo različnih postopkov modeliranja teh lastnosti in uporabo na trajektorijah temelječih detektorjev akcij dobimo celovito informacijo o tem, kako uspešno je bila aktivnost izvedena.

V POGLAVJU 6 je predstavljen prototipni sistem za analizo moštvenih iger. Poseben poudarek je posvečen predstavitvi metod za analizo košarkarske igre. V prototipu so za namene kvalitativne analize igre (npr. kvaliteta in tipi izvedenih


akcij) uporabljena dognanja, ki so bila pridobljena v okviru opisanih raziskav. Poleg tega so bila izdelana še orodja za kvantitativno analizo igre (npr. pretečene razdalje, posest žoge, hitrosti gibanja igralcev), ki uporabniku omogoča hiter in učinkovit vpogled v dejavnike, ki so pripomogli k boljši igri posameznega igralca in ekipe.

Poglavje 2

Struktura moštvenih iger in pridobivanje podatkov

2.1 Struktura moštvenih iger

Moštvene igre, kot so košarka, nogomet ali rokomet, so večstrukturne športne dejavnosti sestavljenega tipa [45]. Večstrukturne zato, ker so sestavljene iz večjega števila tehničnih elementov brez žoge in z njo. Sestavljenega tipa pa zato, ker se lahko tehnični elementi povezujejo med seboj v zelo različnih, taktično smiselnih kombinacijah oziroma taktičnih elementih [46]. Tako lahko z analizo moštvenih iger razdelimo v dva dela in sicer *analizo tehničnih elementov* in *analizo taktičnih elementov* igre. Strukturo moštvenih iger bi lahko s stališča nivoja analize dogajanja na igrišču v grobem razdelili v tri nivoje (slika 2.1). Ti nivoji so *faza igre*, *vrsta faze igre* (imenovan tudi podfaza) in *individualne aktivnosti igralcev*. Če opazujemo igro enega moštva, lahko potek igre razdelimo na več igralnih enot, v katerih si izmenično sledita *faza napada* in *faza obrambe*. Tako obdobju igre v obrambi sledi prenos žoge, temu pa priprava in zaključek napada. Znotraj vsake faze igre se odvijajo različne aktivnosti, ki so odvisne od trenutne situacije na igrišču ter od taktičnih ciljev ekipe. V fazi napada ekipa odigra različne tipe napada (npr. protinapad, zgodnji napad, postavljen napad ali napad proti postavljeni obrambi), v fazi obrambe pa se ekipa prilagaja tipu nasprotnikovega napada (npr. obramba proti protinapadu, conska obramba, osebna obramba, presing, itd.).



Slika 2.1: Prikaz poenostavljene strukture košarkarske igre.

V nadaljevanju so podrobneje predstavljena pravila in taktično-tehnične značilnosti košarkarske igre, ki nam je služila kot testno okolje pri razvoju in evalvaciji metod avtomatične analize moštvenih iger.

Osnove košarkarske igre

Košarkarsko igrišče meri 28 x 15 metra. Košarkarska igra je sestavljena iz dveh polčasov, vsak polčas pa iz dveh četrtin. Skupni aktivni čas igre je 4 x 10 minut, med tem časom pa prihaja do številnih prekinitev in odmorov. Odmor med polčasoma traja od 10 do 15 minut, med četrtinama pa po 2 minuti. Če se redni del tekme konča z neodločenim rezultatom, se igra toliko podaljškov po 5 minut, z 2 minutnim odmorom, dokler eno moštvo ne zmaga. Igra v napadu je omejena na 24 sekund. Tako kratek čas za napad naredi košarkarsko igro hitro in atraktivno. Poleg omejitve napada, je z 8 sekundami omejen tudi prenos žoge v napadalno polovico, s 5 sekundami držanje žoge ob agresivni obrambi in s 3 sekundami zadrževanje napadalca v prostoru pod košem (raketi).

Košarkarsko igro lahko razdelimo tudi na aktivno in pasivno fazo. Aktivna faza je faza igranja, ki traja od trenutka, ko postane žoga živa in do sodnikovega piska. Pasivna faza pa predstavljajo prekinitev, ki trajajo od sodnikovega piska, do nove žive žoge. Tipi prekinitev so: prekrški, male napake, menjave, velike napake, minute odmora, sodniški meti, druge prekinitev [47].

Košarkarska tehnika

Košarkarska tehnika je sklop najbolj učinkovitih načinov gibanj igralca z in brez žoge (tehničnih elementov in njihovih povezav), ki morajo biti usklajena s pravili igre in taktiko reševanja igralne situacije [48]. Tehnični elementi so temeljna gibanja igralca brez in z žogo v napadu ter obrambi. Med seboj jih lahko sestavljamo v različnih povezavah (kombinacijah). Poznamo začetne, vezne in sklepne tehnične elemente (npr. lovljenje, vodenje in podaja). Kombinacije tehničnih elementov dobijo taktični značaj šele v okviru taktične zasnove igre [48].

Košarkarska taktika

Taktika predstavlja smotrno izbiro in uporabo posamičnih, skupinskih in skupnih igralnih dejavnosti v igri s tekmeči, proti katerim želimo doseči čim boljši izid [48]. Taktika košarkarske igre je skupek posamičnih in skupinskih akcij igralcev, ki so organizirane in koordinirane v mejah pravil igre, z namenom doseči končni cilj - zmago. Taktiko pri košarki delimo na taktiko napada in taktiko obrambe. Obe pa nadalje delimo na posamično, skupinsko in skupno oziroma moštveno [48].

Posamična taktika zajema taktične elemente, ki jih izvaja v igri posamezni igralec brez neposredne pomoči soigralcev. Ta taktika je zajeta v igri 1:1. Skupinska taktika zajema taktične elemente, v katerih sodelujeta dva ali trije igralci. Z njimi želijo rešiti del skupne taktične naloge. Ta taktika je zajeta v igri 2:2 in 3:3. Skupna (moštvena) taktika zajema delovanje in sodelovanje vseh igralcev v igri, v okviru izbranega taktičnega sistema in taktične kombinacije [47].

Sredstva taktike igre so tehnični in taktični elementi, njihove sestave (kombinacije) in taktični sistemi. Taktični (igralni) sistem je shema postavljanja in gibanja igralcev, v katerem so položaji in vloge posameznih igralcev, v napadu in obrambi okvirno določene. Taktična (igralna) sestava pa zajema postavljanje in gibanje skupine igralcev ali celotnega moštva v okviru izbranega taktičnega sistema. Njihov cilj je, da pridejo napadalci v ugoden položaj za nadaljevanje ali zaključek napada oziroma, da obrambni igralci preprečijo namere napadalcev. Taktične sestave igralci igrajo med igro ali v posebnih situacijah. Poznamo zaprte, odprte in zaprto - odprte taktične sestave. Zaprtim taktičnim sestavam pravimo tudi šablone in jih morajo igralci izvesti do konca, ne glede na situacijo na igrišču. Odprte taktične sestave omogočajo igralcem več svobode in ustvarjalnosti v igri.


Pri teh je gibanje in medsebojno sodelovanje igralcev določeno samo z osnovnimi pravili, ki jih morajo igralci upoštevati. Zaprto - odprte taktične sestave zahtevajo od igralcev organiziran začetek, v nadaljevanju pa bolj svobodno in ustvarjalno gibanje v okviru določenih pravil [47].

2.1.1 Predstavitev taktično-tehničnih lastnosti moštvenih aktivnosti


V našem delu smo se omejili na proučevanje zakonitosti zaprtih taktičnih sestav/aktivnosti, ki jih lahko uvrstimo v skupino postavljenih košarkarskih napadov. Trenerji tovrstne aktivnosti pogosto podajajo igralcem v obliki šablon, v katerih so zajete prostorske in časovne taktično-tehnične lastnosti aktivnosti (slika 2.2). Šablone so lahko sestavljene iz več slik, ki si zaporedoma sledijo. V splošnem lahko v aktivnosti aktivno sodeluje poljubno število igralcev - od dveh pa do vseh petih igralcev. Soigralci, ki v aktivnost niso neposredno vključeni, pa morajo zagotavljati pogoje za pravilno izvedbo aktivnosti. To pomeni predvsem, da morajo zagotoviti prostor na delu igrišča, v katerem naj bi potekala aktivnost, s tem da se sami čim bolj umaknejo iz tega dela igrišča. Praviloma morajo biti šablone sestavljene tako, da je za vsak trenutek aktivnosti možno definirati položaj vsakega posameznega igralca, ki je vključen v aktivnost. Tako je zelo pomembno, da se končni položaj na določeni sliki in položaj igralca na naslednji sliki ne spremeni.

Pogosto trenerji pri svojih navodilih igralcem podajo zelo natančne prostorske lastnosti o aktivnosti, medtem ko so časovne lastnosti podane precej ohlapno in v veliko primerih podane zgolj kot časovno-logične relacije med posameznimi akcijami, ki sestavljajo aktivnost. Tovrsten pristop je za analizo neprimeren, saj je za modeliranje aktivnosti potrebno poznati tudi dokaj natančen časovni profil aktivnosti. V ta namen je bil razvit uporabniški vmesnik, ki trenerju poleg prostorskih lastnosti aktivnosti omogoča tudi zelo natančno definiranje časovnih lastnosti. Poleg tega pa mu omogoča tudi simulacijo zamišljene aktivnosti, s čimer je trenerju omogočena boljša vizualizacija aktivnosti ter zaznavanje morebitnih pomankljivosti v aktivnosti. Končna zasnova aktivnosti je shranjena v zbirki šablon aktivnosti in je primerna za uporabo pri poznejših analizah.


Slika 1 od 3



Slika 2 od 3



Slika 3 od 3



Slika 2.2: Primer šablone napada imenovanega "52". Šablona je sestavljena iz treh slik, ki si zaporedoma sledijo. Vsaka izmed slik vsebuje prostorsko (levo) in časovno (desno) informacijo o akcijah igralcev med izvajanjem aktivnosti.

2.2 Pridobivanje in obdelava podatkov

Metode, opisane v tem delu, ne pogojujejo načina pridobivanja podatkov o gibanju igralcev. Tako bi lahko poleg metod računalniškega vida za zajem in obdelavo podatkov o gibanju igralcev uporabili tudi katero izmed metod, ki so danes sicer še v razvoju, a bodo v prihodnosti gotovo bistveno olajšale pridobivanje tovrstnih podatkov. Takšni, trenutno še alternativni pristopi k sledenju, so uporaba RFID radiofrekvenčne identifikacije [49, 50], uporaba brezžičnih tehnologij kot je Bluetooth ali uporaba satelitskega navigacijskega sistema GPS za določanje položaja človeka na zemlji. Glavne pomanjkljivosti tovrstnih sistemov so omejeno območje uporabe (npr. RFID in Bluetooth od nekaj 10 do 100 metrov) in precejšnja nenatančnost pridobljenih podatkov, saj je na primer za GPS sisteme napaka pozicioniranja okoli enega metra. Kljub temu pa danes že obstajajo tudi različne izboljšave, kot je vpeljava DGPS sistema (ang. *Differential Global Positioning System*), ki deluje na podlagi uporabe referenčnih baznih postaj, s katerimi je mogoče napako pozicioniranja zmanjšati nekaj deset centimetrov.

Poleg zgoraj omenjenih težav pa je glavna pomanjkljivost vseh tovrstnih sistemov, da zahtevajo neke vrste *značko* (ang. *tag*), ki omogoča razpoznavanje in lokalizacijo osebe oziroma objekta. Tovrstne značke pa so s športnimi pravili, ki jih določajo mednarodne športne organizacije, strogo prepovedane, zaradi česar je uporaba omenjenih sistemov vsaj trenutno še precej oddaljena. Poleg pravnega vidika je pri vpeljavi tovrstnih sistemov vedno potrebno upoštevati tudi psihološki vidik, saj se pogosto zgodi, da se igralci ob zavedanju, da so "nadzorovani", začnejo drugače obnašati in lahko postane njihova igra drugačna - običajno slabša. Zaradi tovrstnih omejitev je trenutno edina sprejemljiva tehnologija za pridobivanje podatkov o gibanju igralcev uporaba metod računalniškega vida. Tovrstna tehnologija omogoča brezkontaktno prepoznavanje položaja igralcev in tako ne vpliva neposredno na pravila igre ali na obnašanje igralcev.


Pridobivanje podatkov

Eden izmed ključnih dejavnikov za uspešno analizo obnašanja igralcev na podlagi njihovih trajektorij gibanja je prav gotovo natančnost podatkov, ki jih uporabljamo pri analizi. V ta namen je bila razvita metodologija, na podlagi katere je možno iz video posnetkov pridobiti podatke o gibanju igralcev med

tekmo. Postopek je sestavljen iz štirih delov in sicer zajema video posnetkov, kalibracije posnetkov, sledenja igralcev ter končne obdelave podatkov. V nadaljevanju je podrobneje opisan vsak izmed štirih sklopov.

Zajem video posnetkov

Kot je v svojih delih ugotovil Perš [2, 51], je s stališča optimalnega sledenja in minimizacije napake pri sledenju najboljša postavitev kamer neposredno nad igriščem, tako da oklepa optična os kamere z igriščem pravi kot. Da bi zagotovili pokritost celotnega igrišča smo pri zajemanju posnetkov uporabili dve nepremični kameri s širokokotnim objektivom, ki smo ju pritrdili pod strop dvorane (slika 2.3). Vsaka kamera je pokrivala polovico igrišča, pri čemer sta se vidni polji na sredini deloma pokrivali, kar je omogočalo sledenje igralcev tudi med prehajanjem čez sredino igrišča. Video posnetki so bili zajeti s hitrostjo 25 slik na sekundo, kar je omogočalo, da s postopki sledenja za vsako sekundo igre za vsakega igralca na igrišču pridobimo 25 njegovih pozicij.



Slika 2.3: Postavitev kamer pri zajemu video posnetkov [52, 53]

Kalibracija video posnetkov

Pravilno izvedena kalibracija kamer je bistvenega pomena za kvaliteto izhodnih podatkov. Pri tem je potrebno opraviti dve vrsti kalibracije in sicer časovno kalibracijo, ki jo imenujemo tudi *sinhronizacija* kamer ter *prostorsko kalibracijo* kamer.

Bistvo sinhronizacije kamer je zagotoviti sledenje igralcev pri njihovem prehajanju čez sredino oziroma pri spremembi video posnetka, na katerem se izvaja sledenje igralca. Sinhronizacijo posnetkov dosežemo z uporabo kamer, ki sta sinhronizirani na omrežno napetost (ang. *AC lock*). Časovno poravnavo posnetkov pa dosežemo tako, da na obeh posnetkih ročno določimo nek značilen trenutek na začetku tekme (npr. prvi met sodnika).


Glavni namen prostorske kalibracije video posnetkov je določiti korespondenco med točkami na igrišču ter točkami na sliki. Pri kalibraciji predstavljata glavni problem radialno popačenje slike, ki je posledica uporabe širokokotnih objektivov ter dejstvo, da ni mogoče postaviti kamer poljubno visoko in popolnoma pravokotno nad center igrišča, zaradi česar pride do translacije in rotacije slike glede na igrišče. Da bi rešili to težavo, je bil razvit postopek, pri katerem ročno označimo linije na sliki, ki ustrezajo določenim linijam na igrišču. Z uporabo optimizacijskih postopkov nato iz dobljenih točk izračunamo parametre modela kamere.

Sledenje igralcev

Z uporabo postopka sledenja lahko za vsakega od igralcev na igrišču določimo njegovo pozicijo na posamezni sliki. S povezovanjem teh pozicij na zaporedju slik dobimo njihovo trajektorijo gibanja. Da bi pridobili informacijo o tem, kje se na posamezni sliki nahaja posamezni igralec je bil razvit postopek za sledenje igralcev na podlagi njihove vizualne informacije. Postopek temelji na uporabi vizualnega sledenja s filtrom z delci, ki upošteva domnevo zaprtega sveta [54, 55]. Prav tako pa se v procesu sledenja upoštevajo določene fizikalne zakonitosti o gibanju igralcev, kot sta vztrajnostni moment in fizični obseg človeškega telesa, ki ju lahko izkoristimo pri razreševanju trkov med igralci [56]. V postopku sledenja vsakemu igralcu na igrišču priredimo svojo značko (ang. *tag*), ki predstavlja ločen filter z delci (slika 2.4). Začetno pozicijo značke določi operater, ki nadzoruje postopek sledenja. Ker je postopek sledenja podvržen napakam, mora operater med sledenjem ročno odpravljati napake, ki se pojavijo pri sledenju.

2.2.1 Obdelava podatkov

Rezultat sledenja so podatki o poziciji igralcev na igrišču, ki pa vsebujejo določen delež šuma in sistemske napake [51]. Šum je predvsem posledica napak pri



Slika 2.4: *Prikaz sledenja igralcev.*

sledenju in gibanja igralčevih ekstremitet, sistemske napake pa se lahko pojavijo zaradi pomanjkljive oziroma nepopolne kalibracije posnetkov. Medtem ko lahko sistemske napake odpravimo zgolj s čim natančnejšo kalibracijo posnetkov, pa lahko šum, ki nastane pri sledenju, odpravimo z dodatno obdelavo dobljenih podatkov. To naredimo z uporabo simetričnega Gaussovega filtra, ki odpravi manjše nekonistentnosti v podatkih (npr. velike spremembe pozicije v dveh zaporednih trenutkih, ki so posledica popravljanja položaja igralca s strani operaterja) in istočasno odpravi napake v meritvah zaradi gibanja igralčevih ekstremitet. Perš in drugi [57] predlagajo uporabo Gaussovega filtra dolžine 25 vzorcev, kar je pri frekvenci vzorčenja 25 vzorcev na sekundo enako dolžini ene sekunde. Takšen filter optimalno odpravi šum in istočasno ohranja koristno vsebino v podatkih. Tudi tako obdelani podatki pa še vsebujejo določeno napako, ki je ocenjena na 0.3 metra na sredini igrišča pa do 0.6 metra na robovih. Ker lahko ta napaka bistveno vpliva na rezultate analize gibanja igralcev, jo je v postopkih analize (še posebej pri detekciji in ocenjevanju akcij) vsekakor potrebno upoštevati.

Poglavje 3

Časovna segmentacija moštvenih iger

Hiter razvoj video tehnologij v zadnjem desetletju nam mogoča pridobivanje ogromnih količin podatkov o gibanju igralcev med tekmami, ki jih ni več mogoče analizirati ročno. Zaradi tega se pojavlja vse več raziskav, povezanih z avtomatsko segmentacijo tekem in iskanjem njenih najzanimivejših delov. Segmentacija tekme predstavlja prvi korak v procesu analize aktivnosti igralcev, zaradi česar je velika natančnost tega koraka zelo pomembna, saj se vse napake v segmentaciji odražajo v poznejših korakih analize. Poleg tega mora biti metoda segmentacije čim manj računsko potratna, saj je v tej fazi analize potrebno obdelati velike količine podatkov, zaradi česar jo je smiselno izvajati na čim bolj grobem nivoju podrobnosti - na nivoju gibanja ekipe kot celote in ne posameznih igralcev.

V večini moštvenih iger (npr. košarki, roketu, hokeju ali odbojki) fazo igre, v kateri se ekipa nahaja, določa posest žoge ali ploščka. Na žalost pa je zaradi velikosti teh objektov na sliki, njihove hitrosti in številnih zakrivanj, ki se pojavljajo med igro, pridobivanje podatkov o njihovem gibanju zelo oteženo tudi v primeru uporabe najnaprednejših metod računalniškega vida. Poleg tega pa bi bilo tudi v primeru, da bi bil položaj žoge znan, še vedno zelo težko nedvoumno določiti fazo igre. Zaradi navedenih razlogov predlagamo postopek za avtomatsko razgradnjo zveznega skupinskega dogajanja v posamezne faze igre, ki temelji na uporabi trajektorij igralcev ene ali obeh ekip.

V preostanku tega poglavja je v podpoglavju 3.1 najprej opisan postopek za gradnjo modela igre, ki ga nato uporabimo pri segmentaciji tekme v več vsebinsko zaključenih faz igre - podpoglavje 3.2. V nadaljevanju je v podpoglavju 3.3 opisana eksperimentalna validacija predlaganega postopka, s katero želimo

preučiti vpliv različnih dejavnikov na natančnost segmentacije. Na koncu pa so v pod poglavju 3.4 podani zaključki in ugotovitve o predlagani metodi.

3.1 Modeliranje igre

Moštvene športne igre sestavljajo pravila in taktični cilji, ki jim ekipa sledi, da bi premagala nasprotnika. V številnih športnih igrah se moštva izmenjujejo v napadu in obrambi, z manjšimi prekinitvami, kot so na primer odmori, prosti meti ali prosti streli. S tega stališča lahko moštvene igre obravnavamo kot zvezni proces, ki je sestavljen iz določenega števila vsebinsko zaključenih faz. Te faze so na primer faza napada, faza obrambe ter faza neaktivne igre, ki jo v našem primeru predstavljajo predvsem odmori, ker so to najdaljši odseki neaktivne igre, ki so za podrobnejšo analizo popolnoma nezanimivi. Tako model igre predstavimo s tremi fazami: fazo napada (m_1), fazo obrambe (m_2) in odmorov (m_3)

$$M = \{m_1, m_2, m_3\}. \quad (3.1)$$

Pri modeliranju faz igre lahko uporabimo različne pristope. Osnovni, najbolj intuitiven pristop, temelji na zamisli, da za vsako od ekip izdelamo ločen model igre [58]. V ta namen uporabimo pristop, ki ga je leta 1992 za namene analize gibanja ekip prvi uporabil Erdmann [59]. Tako opišemo stanje igre z vektorjem značilnk $\mathbf{z}_{\text{team}}(\mathbf{t})$, ki ga sestavljajo kolektivna pozicija - centroid igralcev v ekipi ter gibanje tega centroida po igrišču:

$$\mathbf{z}_{\text{team}}(t) = [x_t, y_t, \Delta x_t, \Delta y_t]^T. \quad (3.2)$$

Položaj centroida v dvodimenzionalnih kartezičnih koordinatah, je v tem primeru izračunan kot srednja vrednost položajev vseh igralcev v eni ekipi

$$x_t = \frac{1}{n} \sum_{i=1}^n x_i, \quad y_t = \frac{1}{n} \sum_{i=1}^n y_i; \quad (3.3)$$

Δx_t in Δy_t predstavljata gibanje centroida v kartezičnih koordinatah igrišča in sta definirana kot razlika med dvema zaporednima položajema centroida.

Z upoštevanjem določenih ugotovitev, ki so bile dobljene na osnovi preliminarne rezultate, pa lahko osnovno metodo izračuna vektorja značilk še izboljšamo in jo naredimo bolj robustno. Prva izboljšava pri izračunu vektorja značilk temelji na opazanju, da se igralci obeh ekip med igro gibljejo zelo podobno, ne glede na fazo igre, v kateri se nahajajo. Tako lahko, namesto da bi za vsako ekipo zgradili ločen model igre, zgradimo en skupen model igre, pri katerem upoštevamo vseh $m = 2n$ igralcev na igrišču. Tak model predstavlja stanje ene od ekip, medtem ko je, zaradi narave igre, stanje druge ekipe ravno komplementarno stanju prve. Torej je v primeru, ko je prva ekipa v fazi napada, druga ekipa v fazi obrambe in obratno. Faza odmora pa je skupna obema ekipama.


Druga izboljšava, ki jo lahko vpeljemo v izračun tega vektorja, temelji na opazanju, da so za izračun vektorja značilk položaji različnih igralcev na igrišču različno pomembni. Na ta način želimo predvsem odpraviti anomalije, ki se med igro pojavljajo zaradi napak pri sledenju, poškodb igralcev med igro ali v primeru rokometnega menjav med aktivno igro. Da bi odpravili tovrstne izjeme, ki vplivajo na končni rezultat segmentacije, vpeljemo uteži w_i , ki določajo kako pomemben je položaj posameznega igralca za izračun centroida. Utež w_i izračunamo tako, da pozicije igralcev na igrišču modeliramo z Gaussovo porazdelitvijo $\mathcal{N}(\cdot; \mu(t), \Sigma(t))$ s srednjo vrednostjo $\mu(t) = [\mu_x(t), \mu_y(t)]^T$ in kovarianco $\Sigma(t)$. Utež posameznega igralca je nato določena kot verjetje za pozicijo igralca i glede na dano Gaussovo porazdelitev

$$w_i(t) = \frac{\mathcal{N}(p_i(t); \mu(t), \Sigma(t))}{\sum_{i=1}^m \mathcal{N}(p_i(t); \mu(t), \Sigma(t))}, \quad (3.4)$$

kjer $p_i(t) = [x_i, y_i]^T$ predstavlja pozicijo igralca i v katrtezičnih koordinatah. Položaj uteženega centroida je sedaj določen kot

$$x_t = \sum_{i=1}^m w_i(t) \cdot x_i(t) \quad , \quad y_t = \sum_{i=1}^m w_i(t) \cdot y_i(t). \quad (3.5)$$

Slika 3.1 prikazuje primer trajektorije uteženega centroida vseh igralcev na igrišču za en polčas košarkarske in rokometne tekme. Tako izračunane trajektorije centroida še vedno vsebujejo precej variabilnosti za posamezno fazo igre, zaradi česar se pojavi potreba po statističnem modelu s katerim bi lahko te faze ustrezno



Slika 3.1: Trajektorija uteženega centroida vseh igralcev na igrišču: (a) Košarka. (b) Rokomet.

modelirali. V ta namen predlagamo model mešanice Gaussovih porazdelitev, s katerim je mogoče zajeti variabilnost in negotovost, ki se pojavlja pri gibanju igralcev med igro. Tako za vsako izmed faz igre definiramo verjetnosti, da je model m_i generiral vektor značilk $\mathbf{z}_{team}(\mathbf{t})$

$$p(\mathbf{z}_{team}(t)|m_i) = p(\mathbf{z}_{team}(t)|\theta_i) = \sum_{k=1}^K \alpha_k^{(i)} \cdot \mathcal{N}(\mathbf{z}_{team}(t); \mu_k^{(i)}, \Sigma_k^{(i)}), \quad (i = 1, 2, 3). \quad (3.6)$$

V enačbi (3.5) predstavlja m_i fazo igre; $\alpha_k^{(i)}$ utež posamezne Gaussove porazdelitve, tako da je $\sum_{k=1}^K \alpha_k^{(i)} = 1$; $\mathcal{N}(\mathbf{z}_{team}(t); \mu_k^{(i)}, \Sigma_k^{(i)})$ predstavlja k -to funkcija Gaussove porazdelitve s srednjo vrednostjo $\mu_k^{(i)}$ in kovariančno matriko $\Sigma_k^{(i)}$; parameter K pa predstavlja število Gaussovih funkcij, ki jih uporabimo pri modeliranju posamezne faze igre.

Za določitev parametrov porazdelitve uporabimo algoritem EM (ang. Expectation maximization) [60, 61], na podlagi katerega iz množice ročno segmentiranih trajektorij pridobimo vektorje značilk $\mathbf{Z} = \{\mathbf{z}_1, \dots, \mathbf{z}_N\}$, ki jih nato uporabimo za določitev parametrov modela igre $\theta_i = \{\alpha_k, \mu_k, \Sigma_k\}$ (Dodatek C.1).

3.2 Časovna segmentacija

Ko je model igre zgrajen, ga lahko uporabimo za segmentacijo oziroma časovni razrez zveznega dogajanja v posamezne zaključene faze igre. Postopek segmentacije je razdeljen v dva dela:

- V prvem koraku, z uporabo statističnega modela igre, klasificiramo vsak posamezen trenutek igre v eno izmed faz igre. Bistvo tega koraka je čim boljša klasifikacija posameznih vzorcev.
- V drugem koraku na novo preračunamo fazo igre za vsak posamezen vzorec, pri čemer upoštevamo tudi podatek o fazi igre za sosednje vzorce. Na ta način želimo zagotoviti časovno konsistentnost dobljenih rezultatov in zmanjšati oziroma odpraviti nezaželen efekt prehitrega spreminjanja faze igre.

3.2.1 Klasifikacija posameznih vzorcev

V fazi klasifikacije posameznih vzorcev z uporabo Bayesovega pravila in naučenih statističnih modelov igre (m_i), izračunamo največjo *a posteriori* verjetnost, da je model m_i generiral dani vzorec $\mathbf{z}_{team}(t)$

$$p(m_i|\mathbf{z}_{team}(t)) = \frac{p(\mathbf{z}_{team}(t)|m_i)p(m_i)}{p(\mathbf{z}_{team}(t))}, \quad (i = 1, 2, 3). \quad (3.7)$$

Glede na to, da je verjetnost $p(\mathbf{z}_{team}(t))$ enaka za vse modele m_i , klasificiramo vzorec $\mathbf{z}_{team}(t)$ v razred z najvišjo skupno verjetnostjo (m_*)

$$m_*(t) = \arg \max_{m_i \in M} \{p(\mathbf{z}_{team}(t)|m_i)p(m_i)\}, \quad (i = 1, 2, 3), \quad (3.8)$$

kjer je $p(m_i)$ *a priori* verjetnost za fazo igre m_i . *A priori* verjetnosti so bile ocenjene na podlagi eksperimentalnega opazovanja časa, ki ga določena faza zavzema znotraj celotne tekme. Na podlagi merjenja razmerij časov na treh košarkarskih in treh rokometnih tekmah smo dobili naslednje ocene *a priori* verjetnosti. Za košarko

$$p(M) = [0.4, 0.4, 0.2]^T, \quad (3.9)$$

za roket pa

$$p(M) = [0.48, 0.48, 0.04]^T. \quad (3.10)$$

3.2.2 Zagotavljanje časovne konsistentnosti

Na podlagi klasifikacijskega postopka, opisanega v prejšnjem poglavju, lahko dosežemo precej dobro segmentacijo igre v posamezne faze. Vendar pa je tovrstna segmentacija za analizo še ni primerna, saj dobimo poleg pravilno segmentiranih faz tudi množico napačnih odsekov, ki so zelo kratki in so dolgi nekaj deset vzorcev. Razlog za to je, da v postopku klasifikacije ni upoštevana časovna konsistentnost igre, saj pri klasifikaciji posameznega vzorca ne upoštevamo njegovih časovnih sosedov. Da bi zadostili pogoju časovne konsistentnosti, zgladimo rezultate iz prvega koraka z uporabo neutženega filtra ali uteženega filtra z Gaussovim jedrom.

V prvem primeru za glajenje rezultatov uporabimo neutženi filter, ki ima naslednjo obliko

$$m_{**}(t) = \arg \max_{m_i \in M} \left\{ \sum_{k=t-K}^{t+K} D_{m_*, m_i}(k) \right\}, \quad (3.11)$$

kjer je

$$D_{m_*, m_i}(k) = \begin{cases} 1; & m_*(k) = m_i \\ 0; & \text{drugače} \end{cases}. \quad (3.12)$$

V tem primeru je $i - ti$ vzorec uvrščen v fazo $m_{**}(t)$, v katero je razporejenih največ sosednjih vzorcev znotraj opazovanega okna širine $2K + 1$. Teoretično bi morala biti širina okna določena kot dvakratnik dolžine najkrajšega še uporabnega segmenta igre. Po mnenju eksperta je najmanjše možno trajanje posamezne faze igre (v košarki in roketu) med tri in štiri sekunde (med 75 in 100 vzorci), kar pomeni, da mora biti dolžina okna med 150 in 200 vzorci.

Uteženi filter z Gaussovim jedrom lahko zapišemo kot

$$m_{**}(t) = \arg \max_{m_i \in M} \left\{ \sum_{k=t-3\sigma}^{t+3\sigma} \mathcal{N}(k; t, \sigma) D_{m_*, m_i}(k) \right\}. \quad (3.13)$$

V tem primeru vsak vzorec najprej utežimo z uporabo Gaussove distribucije. Na podlagi teh uteži razporedimo opazovani vzorec v fazo $m_{**}(t)$ pri kateri dobimo največjo vsoto Gaussovih uteži $\mathcal{N}(k; t, \sigma)$.

Prednost uporabe neuteženega filtra je, da je z njim možno odpraviti vse napačne segmente, krajše od polovice uporabljenega okna. Pri tem pa se meje med posameznimi fazami ne spremenijo. Prednost uporabe uteženega filtra z Gaussovim jedrom pa je v tem, da se bolj upoštevajo manj oddaljeni vzorci, zaradi česar so napake iz prve faze, ki so časovno bolj oddaljeni od opazovanega vzorca, v končnih rezultatih manj izrazite.

3.3 Eksperimenti


Da bi preučili natančnost segmentacije s predlagano metodo, smo z uporabo metod računalniškega vida, opisanih v poglavju 2.2, pridobili podatke o gibanju igralcev na treh rokometnih in treh košarkarskih tekmah. Tekme smo razdelili v šest ločenih polčasov. Na ta način smo za vsakega igralca pridobili 376.000 vzorcev trajektorij za košarko in 331.000 vzorcev za roket. Glavni namen eksperimentov je bil določiti optimalne parametre metode ter preučiti, kako ti parametri, poleg njih pa tudi drugi dejavniki (npr. število učnih vzorcev), vplivajo na končni rezultat segmentacije.

3.3.1 Eksperiment 1: Določanje parametrov metode

Predlagana metoda segmentacije ima dva prosta parametra, ki ju je potrebno določiti pred začetkom segmentacije. Prvi parameter je število komponent v modelu mešanice Gaussovih porazdelitev, s katerim modeliramo posamezno fazo igre, drugi pa širina filtra, ki je uporabljen za zagotavljanje časovne konsistentnosti končnih podatkov.

Pri določanju optimalnega števila komponent, s katerimi je mogoče najbolj modelirati posamezno fazo igre, smo fiksirali vrednost drugega prostega parametra, tako da smo uporabili neuteženi filter dolžine 180 vzorcev. Pri tako določenem filtru smo izbrali različno število komponent za predstavitev posamezne faze igre ter opazovali, kako število komponent vpliva na končni rezultat segmentacije. V ta namen smo za vsako izbiro števila komponent izvedli navzkrižno validacijo. Pri učenju modela smo uporabili podatke iz petih

polčasov, šesti polčas pa je bil uporabljen za testiranje metode. Slika 3.2 prikazuje natančnost segmentacije, ki je izražena kot odstotek pravilno klasificiranih vzorcev, v primeru uporabe modela z različnim številom komponent. Slika 3.3 in Slika 3.4 pa prikazujeta nekaj primerov teh modelov za košarko in roket.




Slika 3.2: Natančnost klasifikacije pri uporabi različnega števila komponent za predstavitev posamezne faze igre. Oznaka 1,1,1 na abscisni osi pomeni, da je bila vsaka posamezna faza igre predstavljena z eno samo Gaussovo porazdelitveno funkcijo.


Kot je razvidno iz slike 3.2, se natančnost segmentacije pri košarkarski ne spreminja bistveno v primeru uporabe dvo ali več-komponentnega modela igre. V primeru roketne igre pa uporaba večjega števila komponent modela bistveno izboljša natančnost segmentacije. Eden od glavnih razlogov za to je, da roketna pravila dovoljujejo bistveno večjo raznolikost pri gibanju igralcev, saj lahko ti med samo igro zapustijo igrišče (menjave) ali v primeru izključitev ostanejo na klopi za dlje časa, pri čemer ekipa tekmo nadaljuje z enim igralcem manj. Vse te dejavnike mora model igre zajeti, zaradi česar se za bolj primernega izkaže model z večjim številom komponent. Prav tako lahko ugotovimo, da je model najbolj občutljiv na modeliranje faze odmorov. Eksperimenti so prav tako pokazali, da je natančnost segmentacije najbolj občutljiva na izbiro števila komponent, s katerimi modeliramo faza odmorov. Tako je natančnost segmentacije bistveno slabša v primeru, da to fazo modeliramo zgolj z eno komponento (primer 3,3,1 na abscisni osi) kot pa v primeru, da jo modeliramo z dvema komponentama (primer 3,3,2). Pri ostalih dveh fazah pa je ta razlika bistveno manjša, saj so razlike v primeru modeliranja faze

napada z dvema (primer 2,2,3) ali tremi (primer 3,3,3) komponentami bistveno manjše. Ob upoštevanju dobljenih rezultatov in dejstva, da se s povečevanjem števila komponent modela povečuje tudi računska kompleksnost metode, se v splošnem izkaže za najbolj primerne uporaba modela igre, pri katerem opišemo posamezno fazo igre s šest-komponentnim GMM modelom. V primeru, da bi želeli narediti metodo bolj specifično za posamezen šport, pa bi v primeru košarke lahko uporabili tudi model, pri katerem bi bila posamezna faza igre predstavljena z zgolj dvema komponentama.


dvo-komponentni model




tri-komponentni model




štiri-komponentni model




pet-komponentni model



šest-komponentni model



Slika 3.3: Prikaz avtomatsko naučenih modelov pri košarki. Levo so prikazani modeli za fazo napada, na sredini za fazo obrambe in desno za fazo odmorov.




Slika 3.4: Prikaz avtomatsko naučenih modelov pri rokometu. Levo so prikazani modeli za fazo napada, na sredini za fazo obrambe in desno za fazo odmorov.


Po tem, ko smo analizirali vpliv števila komponent modela na natančnost segmentacije, smo preučili še vpliv vrste filtra in njegove širine. V ta namen smo ponovili predhodno opisan eksperiment, tako da smo izbrali šest-komponentni model igre in spreminjali širino neuteženega oziroma uteženega filtra. Širino filtra smo spreminjali v korakih po 20 vzorcev od širine enega vzorca, kar pomeni, da rezultata iz prvega koraka sploh nismo filtrirali, pa do dolžine 480 vzorcev. Poleg natančnosti segmentacije, smo želeli preučiti tudi sposobnost zagotavljanja časovne konsistentnosti v igri, ki jo izmerimo kot razmerje med številom faz igre, ki jih proizvede opisana metoda ter dejanskim številom faz, ki so bile označene ročno. Rezultati eksperimenta so prikazani na sliki 3.5.

Kot je razvidno iz slike 3.5(a) vrsta uporabljenega filtra ne vpliva bistveno na natančnost segmentacije, saj so rezultati v obeh primerih dokaj podobni. Kljub temu pa lahko ugotovimo, da v primeru uporabe neuteženega filtra dosežemo največjo natančnost pri obeh športih v primeru, ko je širina filtra enaka 200 vzorcev oziroma 8 sekund. Ta rezultat ustreza tudi iskustveno določeni širini filtra, ki je bila ocenjena na interval med 150 do 200 vzorci (poglavje 3.2). Poleg tega lahko ugotovimo, da je v primeru uporabe uteženega filtra natančnost segmentacije bolj stabilna, saj je sprememba natančnosti segmentacije ob spremembi širine filtra manj izrazita. Vendar pa se v tem primeru širina filtra, pri kateri je dosežen optimalen rezultat filtriranja, razlikuje glede na analiziran šport. Pri košarki je ta širina 270 vzorcev, medtem ko je pri rokometu optimalen rezultat dosežen pri 460 vzorcih.

Na podlagi analize slike 3.5(b) lahko ugotovimo, da obe vrsti filtra bistveno izboljšata razmerje v številu faz igre, saj je bilo pred filtriranjem število faz kar pet krat večje od dejanskega števila, po filtriranju pa število dobljenih faz približno ustreza dejanskemu številu faz. Torej lahko ugotovimo, da je z obema filtroma mogoče uspešno odpraviti napačne, običajno zelo kratke segmente in tako zagotoviti časovno konsistentnost v igri. Poleg tega lahko ugotovimo, da se v primeru uporabe neuteženega filtra, število faz igre približa dejanskemu številu faz pri širini filtra med 200 in 300 vzorci, medtem ko je v primeru uporabe uteženega filtra to področje med 400 in 500 vzorci. Na podlagi teh ugotovitev lahko zaključimo, da je neuteženi filter širine 200 vzorcev bolj primeren za uporabo, saj se širina filtrira pri spremembi športa ne spremeni, poleg tega pa je tudi razmerje v številu faz igre pri izbrani širini tega filtra bolj ugodno. Po drugi strani pa je uporaba uteženega filtra z Gaussovim jedrom priporočljiva tedaj, ko



(a)



(b)

Slika 3.5: Rezultati segmentacije pri uporabi različnih dolžin neuteženega in uteženega filtra. (a) Natančnost segmentacije. (b) Razmerje med številom faz igre dobljenih s predlagano metodo in dejanskim številom faz.

želimo stabilnejše rezultate segmentacije. Vendar pa je potrebno v tem primeru širino filtra prilagajati športu, ki ga analiziramo.

3.3.2 Eksperiment 2: Ostali vidiki segmentacije

V tem poglavju bomo preučili še nekatere druge vidike metode, ki prav tako vplivajo na natančnost segmentacije. Tako bomo poskušali ugotoviti, koliko h končnemu rezultatu prispeva prava izbira vektorja značilnk in metode modeliranja igre ter kako na rezultate segmentacije vpliva število učnih vzorcev, ki jih porabimo za učenje modela.

Da bi preučili učinkovitost modela mešanice Gaussovih porazdelitev (GMM) pri modeliranju faz igre, smo ta model v fazi klasifikacije vzorcev nadomestili z modelom, ki temelji na metodi podpornih vektorjev (SVM) [62, 63, 64, 65] ter predhodno opisan eksperiment ponovili. Podrobnejši opis metode podpornih vektorjev je podan v Dodatku C.2.

Poleg uporabe različnega modela igre, smo preučili tudi, kako na rezultat segmentacije vpliva izbira vektorja značilnk. V ta namen smo za učenje modela uporabili tri različne vektorje značilnk:

- V prvem primeru je bil uporabljen dvo-komponentni GMM model (GMM_dvojni), ki je temeljil na vektorju značilnk, dobljenem na podlagi opazovanja centroida ene same ekipe [66].
- V drugem primeru je bil uporabljen šest-komponentni GMM model (GMM_normalni), ki je temeljil na vektorju značilnk, izračunanem iz centroida obeh ekip.
- V tretjem primeru pa je bil uporabljen šest-komponentni GMM model (GMM_uteženi), ki je temeljil na uteženem vektorju značilnk, izračunanem iz centroida obeh ekip (poglavje 3.1).

Vrsta model igre	Košarka	Rokomet
GMM_dvojni	89.18 %	90.55 %
SVM_uteženi	90.05 %	90.73 %
GMM_normalni	92.18 %	92.83 %
GMM_uteženi	92.47 %	93.11 %


Tabela 3.1: *Povprečna natančnost segmentacije za različne modele igre v primeru uporabe maksimalnega števila učnih vzorcev.*

Tabela 3.1 prikazuje natančnost segmentacije v primeru, ko je bilo za učenje posameznih modelov uporabljeno maksimalno število učnih vzorcev, to je 376.000 vzorcev pri košarki in 331.000 vzorcev pri roketu. Kot je razvidno iz tabele, je bil najboljši rezultat segmentacije dobljen v primeru, ko je bil za modeliranje igre uporabljen GMM model z uteženim vektorjem značilk. Glavni razlog za to je, da je s tovrstnim vektorjem značilk možno najboljše kompenzirati posebnosti, ki se pojavljajo med igro in za dejanski potek igre niso pomembne. Prav tako lahko na podlagi rezultatov ugotovimo, da je bila natančnost segmentacije v primeru uporabe modela igre, ki je temeljil na metodi podpornih vektorjev (SVM_uteženi) bistveno slabša kljub temu, da je bil uporabljen enak vektor značilk kot v primeru uteženega GMM modela.


Natančnost segmentacije v odvisnosti od števila učnih vzorcev

Da bi preučili, kako število učnih vzorcev, ki jih uporabimo za učenje modela igre, vpliva na natančnost segmentacije, smo izvedli navzkrižno validacijo, pri kateri smo za učenje modela uporabili določeno količino podatkov iz petih polčasov tekme, šesti polčas pa je bil uporabljen za testiranje. Število učnih vzorcev smo spreminjali od začetnih 500 vzorcev, pa do maksimalnega števila vzorcev, kar pomeni 310.000 vzorcev za košarko oziroma 270.000 vzorcev za roketu. Ker so bili vzorci naključno izbrani iz učne množice, smo eksperiment za posamezno število vzorcev ponovili 20, s čimer smo se želeli znebiti vpliva izbire vzorcev na končni rezultat.

Na podlagi analize odvisnosti rezultatov od števila učnih vzorcev, ki je prikazana na sliki 3.6, lahko ugotovimo, da se tudi v primeru uporabe manjšega števila učnih vzorcev najboljše obnese GMM model z uteženim vektorjem značilk, medtem ko v primeru SVM modela natančnost segmentacije z manjšanjem števila učnih vzorcev hitro pada. Ob primerjavi različnih vektorjev značilk in iste metode modeliranja igre pa lahko ugotovimo, da lahko v primeru uporabe uteženega vektorja značilk dobimo nekoliko boljši rezultat, kot v primeru uporabe navadnega vektorja, čeprav razlika v natančnosti ni statistično signifikantna. Iz navedenega lahko zaključimo, da je GMM model bolj primeren za modeliranje igre ne glede na uporabljen vektor značilk, saj omogoča natančno segmentacijo tudi v primeru, ko je model naučen iz relativno majhnega števila vzorcev (npr. 500 vzorcev).



(a)




(b)


Slika 3.6: Rezultati segmentacije pri uporabi različnega števila učnih vzorcev. Črtkane črte ponazarjajo standardni odklon rezultatov. (a) Košarka. (b) Rokomet.

Čas učenja modela

Poleg natančnosti je pomemben vidik segmentacije tudi čas njenega izvajanja. Slika 3.7(a) prikazuje razmerje med časom učenja modela in številom učnih vzorcev. Na sliki 3.7(b) pa je prikazana odvisnost med časom segmentacije enega polčasa tekme in številom učnih vzorcev. Kot je razvidno iz obeh slik, je v primeru uporabe SVM modela čas za učenje in segmentacijo zelo odvisen od števila učnih vzorcev, saj se s povečevanjem števila učnih vzorcev čas učenja bistveno poveča. Tako je v primeru uporabe nekaj 100 učnih vzorcev čas učenja nekaj sekund pri povečevanju števila vzorcev na nekaj 100.000 pa se čas učenja modela poveča na nekaj ur. Prav tako linearno narašča čas segmentacije in sicer iz nekaj sekund na nekaj minut. Razlog za to je v načinu zapisa SVM modela, saj se s povečevanjem učnih vzorcev povečuje tudi število podpornih vektorjev, ki jih uporabimo za zapis hiperravnine, ki razmejuje posamezne razrede vzorcev. V primeru GMM modela se čas učenja s številom učnih vzorcev povečuje linearno od nekaj sekund na nekaj minut. Čas segmentacije pa je v tem primeru popolnoma neodvisen od števila učnih vzorcev in je odvisen zgolj od števila komponent, ki jih uporabimo za modeliranje posamezne faze igre.



(a)



(b)

Slika 3.7: Časovna odvisnot metode od števila učnih vzorcev. (a) Čas učenja modela. (b) Čas segmentacije enega polčasa tekme (približno 50.000 vzorcev).

3.4 Zaključek

V tem poglavju smo predstavili postopek segmentacije zveznih moštvenih iger v več vsebinsko zaključenih faz. Predstavljen je bil postopek izgradnje modela igre (podpoglavje 3.1), na podlagi katerega, iz ročno označenih podatkov, z uporabo algoritma EM zgradimo ločene modele za posamezno fazo igre. Predlagani so bili različni postopki za opis stanja igre z vektorjem značilk, ki temeljijo na opazovanju gibanja igralcev posamezne ekipe ali gibanja vseh igralcev na igrišču. Prav tako je bil opisan postopek za robusten izračun tega vektorja, ki dodatno odpravlja občutljivost segmentacije na neobičajne situacije, ki se pojavljajo med tekmami. V nadaljevanju je bil v podpoglavju 3.2 opisan dvostopenjski postopek segmentacije igre. V prvem koraku smo na podlagi predhodno naučenega modela igre klasificirali posamezne časovne trenutke v ustrezne faze igre. V drugem koraku smo na novo preračunali fazo igre posameznega vzorca tako, da smo upoštevali tudi informacijo o sosednjih vzorcih. Na ta način smo lahko z uporabo neutženega filtra ali uteženega filtra z Gaussovim jedrom zagotovili časovno konsistentnost dobljenih rezultatov.

Validacijo predlagane metode smo izvedli na podatkih o gibanju igralcev na treh košarkarskih in treh roketnih tekmah (podpoglavje 3.3). Cilj prvega eksperimenta je bil določiti proste parametre modela, ki zagotavljajo čim bolj natančno segmentacijo. Na podlagi tega eksperimenta je bilo ugotovljeno, da je za modeliranje posamezne faze igre najbolj primeren šest-komponentni model mešanice Gaussovih porazdelitev (GMM). Za zagotavljanje časovne konsistence v igri pa se je za najbolj učinkovitega izkazal neutženi filter širine 200 vzorcev.

Cilj drugega eksperimenta je bil preučiti, kako na natančnost segmentacije vplivajo število učnih vzorcev, izbira modela, s katerim modeliramo igro ter izbira vektorja značilk, ki ga uporabimo za predstavitev igre. Na podlagi dobljenih rezultatov lahko ugotovimo, da je za modeliranje igre primernejša uporaba GMM modela. Poleg tega se je izkazalo, da izbira vektorja značilk ne vpliva bistveno na končni rezultat segmentacije. Prav tako se je pokazalo, da je mogoče dobiti zelo dober model igre tudi v primeru, da je le-ta naučen na relativno majhnemu številu učnih vzorcev (500 ali več). Kljub temu, da je potrebno model igre za določen šport zgraditi samo enkrat, je ta informacija pomembna, ker lahko na podlagi tega eksperimenta zaključimo, da za učenje modela ne potrebujemo velikega števila učnih vzorcev. To pa je še posebej pomembno v primerih, ko

metodo v nekem športu uporabimo prvič, ali v primeru, da bi jo želeli uporabiti na drugih področjih analize aktivnosti (npr. video nadzor), kjer globalni model skupinskega obnašanja še ni poznan.

Poglavje 4

Razpoznavanje aktivnosti

S postopkom segmentacije dobimo kratke odseke tekme, ki so označeni kot napadi, obrambe in odmori. Ta informacija nam omogoča, da lahko v naslednjem koraku analize za različne faze igre uporabimo različne pristope analize. Tako nas v fazi napada predvsem zanimajo tipi napadov in način njihove izvedbe, medtem ko nas v fazi obrambe zanimajo popolnoma drugi parametri, kot so število in načini prevzemanja napadalnih igralcev ter obrambne postavitve ekipe. V tem poglavju se bomo omejili na analizo igre v fazi napada, ker je le-ta s stališča analize za trenerje in druge športne eksperte najbolj zanimiva.

Na podlagi segmentacije dobimo čas začetka in konca napada, ne dobimo pa informacije o tem, kakšno vrsto napada je ekipa odigrala. Zato je bil naš cilj razviti postopek avtomatskega razpoznavanja vrste aktivnosti/napada z uporabo šablon aktivnosti. Predlagani postopek temelji na zamisli, da lahko aktivnost razgradimo na določeno število visoko-nivojskih akcij igralcev, ki jih predstavimo v tekstovni obliki kot zapis treh elementov in sicer imena akcije, oznake igralca oziroma igralcev, ki v akciji sodelujejo in regije igrišča, kjer je bila akcija opažena¹:

akcijai_gralec_regija.

Tako na primer tekstovni zapis

BLOK_P2_P3_CENTER_LEVO,

označuje blokado med igralcema P1 in P2 v regiji CENTER_LEVO.

¹V primeru oznake za začetno formacijo sta oznaki igralcev in regije izpuščeni, ker v formaciji sodelujejo vsi igralci in ni omejena na specifično regijo na igrišču.

Z združevanjem tako dobljenih simbolov dobimo *semantični opis aktivnosti* (poglavje 4.1), s katerim opišemo dogajanje na igrišču. Na podlagi primerjave opisov aktivnosti in opisov šablon (poglavje 4.2) lahko določimo podobnost med njima. V primeru velike podobnosti opisov lahko sklepamo, da odigrana aktivnost ustreza aktivnosti iz šablone.

Iz teorije športa sledi, da športne aktivnosti sestavljajo tehnični elementi, ki jih imenujemo akcije igralcev, kot so blokade, vtekanja, vodenje žoge, podaje, meti na koš in drugi, ki jih v sklopu taktike povezujemo v različno tehnično-taktične kombinacije. Te akcije so specifične za posamezen šport in so zelo odvisne od športnih pravil. Predlagana metoda temelji na opazovanju treh različnih tehničnih košarkarskih elementov/akcij, ki jih lahko pridobimo iz trajektorij gibanja igralcev. Te akcije so *blokada*, *premik* igralcev po igrišču in *začetne formacije* ekipe. Opisi akcij skupaj z informacijo o tem, kje na igrišču se je posamezen element zgodil, predstavljajo slovar znakov, ki ga uporabimo za opis aktivnosti. Na ta način dobimo iz trajektorij igralcev niz simbolov, ki predstavljajo enostaven in zgoščen višjenivojski zapis o dogajanju na igrišču. Tako problem analize skupinskih aktivnosti na podlagi trajektorij pretvorimo v problem analize niza simbolov, ki opišejo potek igre. Problem iskanja podobnosti med aktivnostjo in šablono pa pretvorimo v problem primerjanja podobnosti med nizi simbolov.

4.1 Izgradnja semantičnega opisa aktivnosti

Da bi lahko iz trajektorij pridobili semantični opis dogajanja, moramo najprej izdelati, na trajektorijah temelječe detektorje košarkarskih akcij, s katerimi modeliramo ekspertno znanje o košarki. Ker opis predvideva, da je poznan tudi položaj izvajanja določene akcije, je potrebno izdelati tudi geometrijski model košarkarskega igrišča.

4.1.1 Model igrišča

Pri pretvorbi trajektorij v niz simbolov je potrebno obdržati prostorsko informacijo o tem, kje na igrišču se je določena akcija zgodila. To prostorsko informacijo v opis akcije vpeljemo tako, da blokadam in gibanju igralcev po igrišču pripišemo informacijo o regiji, kjer je bila posamezna akcija opažena. Na

ta način zagotovimo, da za akcije, ki so se zgodile na istem delu igrišča - v isti regiji, pridobimo enak opis ne glede na dejanski položaj akcije znotraj te regije. Na ta način zmanjšamo vpliv morebitnih napak pri sledenju in variabilnosti v trajektorijah, ki se pojavlja med različnimi ponovitvami iste aktivnosti.


Ker v športni literaturi nismo zasledili razdelitve igrišča na regije, ki bi služila našemu namenu, smo izdelali lasten model igrišča. Model igrišča mora biti sestavljen iz določenega števila medsebojno neprekrivajočih se regij. Pravilna izbira števila regij je v procesu modeliranja pomembna. V primeru prevelikega števila regij pri kvantizaciji pozicij ne bi mogli izničiti variabilnosti, ki je prisotna med različnimi ponovitvami iste aktivnosti. Na drugi strani pa bi premajhno število regij pomenilo, da bi bila kvantizacija pozicij in posledično opis aktivnosti preveč posplošen. Tako bi lahko za različne aktivnosti, dobili podobne opise zaradi česar bi prišlo do slabše ločljivosti med različnimi tipi aktivnosti.

Da bi zgradili model igrišča, smo iz literature [67, 68] pridobili 17 šablon košarkarskih napadov. Za vsako izmed šablon smo uporabili levo in desno izvedbo napada. Tako smo imeli skupaj na voljo 34 šablon, iz katerih smo pridobili absolutne pozicije vsebovanih akcij (začetne formacije, gibanje igralcev, blokade), ki smo jih nato uporabili pri delitvi igrišča na različno število regij. Središča in meje med posameznimi regijami smo določili z uporabo metode K-tih povprečij [69], s katero smo množico pozicij razdelili v K razredov. Tako smo zgradili nabor modelov košarkarskih igrišč in ovrednotili njihov vpliv na natančnost razpoznavanja aktivnosti. Slika 4.1 prikazuje model igrišča z devetimi regijami, ki se je izkazal za najbolj primerne in smo ga zato uporabljali pri razpoznavanju.

4.1.2 Detektorji košarkarskih akcij

Potem, ko je model igrišča zgrajen, je potrebno določiti še detektorje akcij, v katerih je zakodirano ekspertno znanje o igri. Z uporabo teh detektorjev, ki so izdelani specifično za košarko, iz trajektorij pridobimo informacijo o tem, katere akcije so bile izvedene. V našem primeru uporabljamo tri detektorje akcij:

Detektor začetne formacije. Začetno formacijo igralcev detektiramo tako, da primerjamo N trenutnih pozicij igralcev na igrišču $X_t = \{x_t^{(n)}\}_{n=1:N}$ z referenčnimi pozicijami $X_{ref} = \{x_{ref}^{(n)}\}_{n=1:N}$, ki jih pridobimo iz šablone napada. Manjša kot je razdalja med referenčnimi pozicijami in trenutnimi pozicijami, večja



Slika 4.1: Model igrišča, ki ga sestavlja 9 regij. Levo: Imena regij so bila izbrana glede na imena vlog, ki igralci običajno igrajo v teh regijah. Desno: Točke na igrišču predstavljajo začetne in končne pozicije elementov, ki so bili pridobljeni iz 34 šablon aktivnosti v napadu.


je verjetnost, da se igralci nahajajo v dani začetni formaciji. Poleg tega lahko na podlagi eksperimentov ugotovimo, da se igralci, ki se nahajajo bližje košu, bolje postavljajo na začetno pozicijo, ker so jim pri tem v pomoč označbe, ki se nahajajo na igrišču. Spričo tega lahko referenčne pozicije, ki so bližje košu, bolj utežimo od tistih, ki se nahajajo dlje od koša (slika 4.2).

Vzemimo, da je $d_n = \|\mathbf{x}_t^{(n)} - \mathbf{x}_{ref}^{(n)}\|$ Evklidska (l_2) razdalja med n -to referenčno pozicijo in n -tim igralcem in da je $r_n = \|\mathbf{x}_{ref}^{(n)} - \mathbf{x}_{basket}\|$ Evklidska razdalja med referenčno pozicijo in košem. Potem lahko verjetje za formacijo k pri danih pozicijah X_t zapišemo kot

$$\mathcal{L}(\text{formacija} = k | X_t) \triangleq \sum_{n=1}^N \mathcal{N}(d_n; 0, \sigma_d) \cdot w_n, \quad (4.1)$$

kjer $\mathcal{N}(\cdot; 0, \sigma)$ označuje Gaussovo porazdelitev s srednjo vrednostjo nič in varianco σ^2 ; w_n pa predstavlja vpliv n -te referenčne pozicije na celotno formacijo in jo izračunamo kot

$$w_n = \frac{\mathcal{N}(r_n; 0, \sigma_r)}{\sum_{n=1}^N \mathcal{N}(r_n; 0, \sigma_r)}. \quad (4.2)$$



Slika 4.2: Utežnostna funkcija w_n in ponazoritev razdalj d in r .

Oceno kvalitete k -te formacije $S(formacija = k)$ pa določimo kot razmerje verjetja za formacijo k pri trenutnih pozicijah igralcev in verjetja za formacijo v primeru idealnih (referenčnih) pozicij igralcev.

$$S(formacija = k) \triangleq \frac{\mathcal{L}(formacija = k | X_t)}{\mathcal{L}(formacija = k | X_{ref})}. \quad (4.3)$$

Parameter σ_d v enačbi (4.1) predstavlja varianco oddaljenosti igralca od referenčne pozicije. Vrednost tega parametra smo izbrali kot $\sigma_d = 1$ meter. Parameter σ_r v enačbi (4.2) pa predstavlja prostorsko pomembnost posamezne referenčne pozicije na igrišču glede na oddaljenost od koša. Ta parameter smo določili kot $\sigma_r = 6.25$ metra, kar ustreza razdalji med košem in črto meta za tri točke. Ocena za kvaliteto formacije je omejena na interval $[0-1]$, pri čemer vrednost nič pomeni, da ni ujemanja med trenutno postavitvijo igralcev in postavitvijo v formaciji, vrednost ena pa predstavlja primer, ko se pozicije igralcev popolnoma ujemajo z referenčnimi. Da je bila formacija opažena predpostavimo tedaj, ko vrednost ocene za formacijo $S(formacija = k)$ preseže hevristično določeno vrednost 0.85 [70].

Blokada. V literaturi je blokada, z vidika ene ekipe, definirana kot bližnje srečanje dveh soigralcev, kjer v idealnem primeru igralec, ki postavlja blokado miruje, igralec, ki koristi blokado, pa se giblje čim bližje svojega soigralca. S tega stališča je bolj verjetno, da interakcijo med dvema igralcema interpretiramo kot blokado v primeru, da je hitrost počasnejšega igralca nizka in da je razdalja med igralcema majhna. Vzemimo, da je spremenljivka d_t Evklidska l_2 razdalja med dvema igralcema, spremenljivka v_t pa hitrost počasnejšega izmed obeh igralcev. Funkcijo verjetja za blokado v primeru d_t in v_t lahko definiramo kot

$$\mathcal{L}(blokada|d_t, v_t) \triangleq \mathcal{N}(d_t; 0, \sigma_d) \cdot \mathcal{N}(v_t; 0, \sigma_v), \quad (4.4)$$

kjer je $\mathcal{N}(\cdot; 0, \sigma)$ Gaussova porazdelitev s srednjo vrednostjo nič in varianco σ^2 . Oceno izvedbe blokade $S_{blokada}$ pa definiramo kot razmerje verjetij med blokado v opazovani situaciji in idealno blokado, ko sta razdalja med igralcema in hitrost počasnejšega igralca enaki nič


$$S_{blokada} \triangleq \frac{\mathcal{L}(blokada|d_t, v_t)}{\mathcal{L}(blokada|0, 0)}. \quad (4.5)$$

Za parameter bližine σ_d v enačbi (4.4) smo enako kot v primeru formacije vzeli $\sigma_d = 1$ meter. Parameter minimalne hitrosti σ_v , ki označuje vrednost, za katero predvidevamo, da igralec še dovolj miruje, pa smo določili kot $\sigma_v = 0.5$ m/s. Da bi bila interakcija med igralcema ocenjena kot blokada, mora vrednost ocene blokade $S_{blokada}$ preseči hevristično določeno vrednost 0.8.

Gibanje igralca. Gibanje igralca po igrišču pretvorimo v simbolično oznako tako, da opazujemo prehode med posameznimi regijami igrišča. Tako ob prehodu igralca iz ene regije v drugo preprosto dodamo v opis aktivnosti oznako, ki vsebuje imeni začetne in končne regije premika. Da ne bi prišlo do generiranja večjega števila simbolov v primeru, ko se igralec giblje vzgolž meje med dvema regijama, pri preverjanju prehoda igralca med dvema regijama upoštevamo še histerezo velikosti 0.5 metra. Velikost histereze ustreza oceni napake, ki jo vsebujejo analizirani podatki. S histerezo zahtevamo, da se igralec premakne vsaj pol metra v novo regijo, preden je prehod med regijama zaznan.

4.2 Razpoznavanje aktivnosti

Z uporabo detektorjev osnovnih elementov košarkarske igre dobimo iz segmentov trajektorij sekvenco simbolov, ki predstavlja *semantični opis* aktivnosti. Tabela 4.1 prikazuje primer semantičnega opisa za trajektorije na sliki 4.3. Z uporabo istih detektorjev zgradimo semantični opis tudi za šablone aktivnosti. Na ta način dobimo zbirko semantičnih opisov šablon, ki jo uporabimo v fazi razpoznavanja neznane aktivnosti.



Slika 4.3: Primer trajektorij za napad tipa "Flex". Številke ob krogih označujejo posamezne igralce.

Tabela 4.1: Del semantičnega zapisa za trajektorije na sliki 4.3. Številke v oklepajih označujejo vrstni red simbolov.

(1) M_P1_CENTER_DESNO,	(9) M_P1_KRILO_DESNO_CENTER_DESNO,
(2) M_P2_CENTER_LEVO,	(10) M_P3_CENTER_CENTER_LEVO,
(3) M_P3_KRILO_DESNO,	(11) M_P4_CENTER_LEVO_BRANILEC_LEVO,
(4) M_P4_BRANILEC_LEVO,	(12) BLOK_P2_P4_CENTER_LEVO,
(5) M_P5_BRANILEC_DESNO,	(13) FORMACIJA_flex1 inv,
(6) FORMACIJA_flex1,	(14) M_P2_BRANILEC_LEVO_CENTER_LEVO,
(7) M_P3_CENTER_LEVO_KRILO_LEVO,	(15) BLOK_P2_P3_CENTER_LEVO...
(8) BLOK_P2_P3_CENTER_LEVO,	

Postopek razpoznavanja aktivnosti z uporabo semantičnega opisa je sestavljen iz dveh korakov:

1. V šabloni so vloge igralcev označene s številkami od P1 do P5. Te oznake nimajo neposredne povezave z vlogami igralcev na igrišču. Zato je v prvem koraku razpoznavanja potrebno poiskati korespondenco med vlogami igralcev na igrišču ter vlogami iz šablone. S tem, ko določimo korespondenco med posameznimi vlogami igralcev, izračunamo tudi podobnost med obema semantičnima zapisoma, ki jo ponazorimo z razdaljo med zapisoma. Manjša kot je razdalja med zapisoma večja je podobnost med njima.
2. Prvi korak ponovimo za vsak semantični opis iz zbirke opisov. Na ta način dobimo vektor razdalj med opisom razpoznavane aktivnosti ter opisom vsake od šablon. Razpoznavano aktivnost uvrstimo v razred aktivnosti z največjo podobnostjo opisov, vendar le v primeru, da je ta podobnost večja od predpisanega praga.

V nadaljevanju so posamezni koraki razpoznavanja podrobneje opisani in prikazani na konkretnem primeru.

4.2.1 Določanje korespondence med vlogami igralcev

S postopkom določanja korepsondence med igralci rešujemo kombinatorični problem, ki ga večina raziskovalcev [34, 36] izpusti, ker korespondenco določajo ročno. Ročno določanje vlog v praksi ne pride v poštev, saj je zgolj v primeru analize ene košarkarske tekme potrebno analizirati okoli sto aktivnosti. Ta problem z avtomatskim postopkom določanja korespondence popolnoma odpravimo.

Da bi rešili problem korespondence, moramo v primeru košarke preveriti 120 (5!) različnih permutacij vlog igralcev. Pri tem predpostavimo, da bo razdalja med semantičnima opisoma najmanjša v primeru pravilne korespondence med vlogami. Postopek preverjanja hipotez izvedemo tako, da najprej iz semantičnega opisa aktivnosti zgradimo $N = 5$ *agend igralcev*, ki vsebujejo samo akcije posameznega igralca. To storimo tako, da oznako začetne formacije pripišemo vsem petim agendam. Oznako blokade dodamo zgolj agendama, ki označujeta tista igralca, ki sodelujeta pri blokadi. Posamezno gibanje igralcev pa dodamo zgolj v agendo, ki predstavlja tega igralca. Pri tem v oznaki elementa izpustimo številko vloge igralca, saj je ta sedaj predstavljena s številko agende. Na podlagi

teh pravil lahko semantični opis iz Tabele 4.1 pretvorimo v pet agend igralcev, ki so prikazane v Tabeli 4.2.

Tabela 4.2: *Pet agend igralcev zgrajenih iz semantičnega opisa v Tabeli 4.1. Številke agend sovpadajo s številkami igralcev iz semantičnega opisa.*

ag1	ag2
(1) M.CENTER_DESNO	(1) M.CENTER_LEVO
(2) FORMACIJA_flex1	(2) FORMACIJA_flex1
(3) M.KRILO_DESNO_CENTER_DESNO	(3) BLOK_CENTER_LEVO
(4) FORMACIJA_flex1 inv ...	(4) BLOK_CENTER_LEVO
	(5) FORMACIJA_flex1 inv
	(6) M.BRANILEC_LEVO_CENTER_LEVO
	(7) BLOK_CENTER_LEVO...
ag3	ag4
(1) M.KRILO_LEVO	(1) M.BRANILEC_LEVO
(2) FORMACIJA_flex1	(2) FORMACIJA_flex1
(3) BLOK_CENTER_LEVO	(3) M.LEFT_POST_BRANILEC_LEVO
(4) M.CENTER_CENTER_LEVO	(4) BLOK_CENTER_LEVO
(5) FORMACIJA_flex1 inv	(5) FORMACIJA_flex1 inv...
(6) BLOK_CENTER_LEVO ...	
	ag5
	(1) M.BRANILEC_DESNO
	(2) FORMACIJA_flex1
	(3) FORMACIJA_flex1 inv...

Potem, ko so agende igralcev zgrajene, lahko testiramo 120 možnih hipotez tako, da navzkrižno primerjamo agende neznane aktivnosti z agendami, ki so bile pridobljene iz šablone. Na podlagi teh primerjav dobimo *matriko podobnosti agend* $A = [a_{ij}]_{NxN}$, v kateri posamezen element predstavlja razdaljo med dvema agendama. Tako element a_{ij} ponazarja, kako dobro se opis v agendi i ujema z opisom v agendi j , oziroma kako dobro se vloga i -tega igralca podreja j -ti vlogi iz šablone.

Kot mero podobnosti med agendami uporabljamo nekoliko modificirano Levenshteinovo razdaljo [71]. Algoritem za izračun modificirane Levenshteinove razdalje je ponazorjen v Algoritmu 1. Razlika naše implementacije algoritma v

primerjavi z njegovo klasično izvedbo je rezultat, ki ga dobimo po primerjavi, saj je v našem primeru končna razdalja deljena s dvakratnikom dolžine daljšega izmed primerjanih nizov. Na ta način dobimo *normirano Levenshteinovo razdaljo*. Tako dobljena razdalja lahko zavzame vrednosti v območju $[0, \dots, 1]$ in ni odvisna od dolžine nizov, ki jih primerjamo. V primeru, popolnega ujemanja med nizi je razdalja enaka 0, v primeru popolnega neujemanja pa je enaka 1. Na ta način lahko na podlagi primerjav med agendami izračunamo celotno razdaljo med primerjanima opisoma.

Algoritem 1 Modificirana Levenshteinova razdalja.

VHODNE SPREMENLJIVKE:Niz znakov s , niz znakov t **REZULTAT:**Razdalja med nizoma d **for** $i = 1$ to N **do** $d[i, 0] = i$;**end for****for** $j = 1$ to M **do** $d[0, j] = j$;**end for****for** $i = 1$ to N **do** **for** $j = 2$ to M **do** **if** $(s[i] = t[j])$ **then** $\text{cost} = 0$; **else** $\text{cost} = 2$; **end if** $d[i, j] = \min(d[i - 1, j] + 1, d[i, j - 1] + 1, d[i - 1, j - 1] + \text{cost})$ **end for****end for** $d = d / \max(2 \cdot N, 2 \cdot M)$;**return** d

Celotno podobnost med dvema semantičnima opisoma (S_l) za l -to permutacijo vlog izračunamo kot povprečno razdaljo posameznih agend a_{ij} za vseh N igralcev. Optimalno korespondenco med vlogami pa določimo kot permutacijo, pri kateri je podobnost največja oziroma razdalja med opisi najmanjša.

$$S(C_{min}) = \min\left\{\frac{1}{N} \sum_{i=1}^N a_{ij}\right\}; \quad j = C_l(i), \quad l = 1, \dots, N! \quad (4.6)$$


Tako za matriko podobnosti

$$A = \begin{bmatrix} \mathbf{0.22} & 0.81 & 0.66 & 0.77 & 0.59 \\ 0.45 & 0.32 & 0.99 & \mathbf{0.14} & 0.87 \\ 0.28 & \mathbf{0.19} & 0.94 & 0.40 & 0.77 \\ 0.91 & 0.95 & \mathbf{0.31} & 0.49 & 0.89 \\ 0.48 & 0.71 & 0.72 & 0.84 & \mathbf{0.24} \end{bmatrix},$$

dobimo pravilno korespondenco med vlogami, ki jo predstavlja vektor $C_l = \{1, 4, 2, 3, 5\}$, pri čemer je najmanjša razdalja med opisoma enaka $S(C_l) = (a_{11} + a_{24} + a_{32} + a_{43} + a_{55})/5 = 0.22$.

4.2.2 Določanje tipa aktivnosti

V postopku določanja korespondence med vlogami igralcev dobimo poleg korespondence tudi informacijo o tem, kako podobni sta si šablona in opazovana aktivnost. Če postopek ocenjevanja ponovimo za vsako izmed šablon aktivnosti, ki se nahajajo v zbirki šablon, dobimo informacijo o tem, kateri šablona je analizirana aktivnost najbolj podobna. Analizirano aktivnost uvrstimo v razred aktivnosti, ki jo predstavlja šablona z največjo podobnostjo (najmanjšo razdaljo) med opisoma, vendar le v primeru, da je razdalja manjša od določenega praga. V nasprotnem primeru sklepamo, da razpoznavana aktivnost ne pripada nobenemu izmed razredov v zbirki šablon in jo razporedimo v nov razred. Slika 4.4 prikazuje rezultat primerjave analizirane aktivnosti s sedemnajstimi šablonami aktivnosti, ki so predstavljene v prilogi Dodatek A.




Slika 4.4: Rezultati primerjanja neznane aktivnosti s 17 različnimi šablonami aktivnosti. Rdeča črta prikazuje prag, pri katerem je aktivnost še klasificirana v razred šablone.

4.3 Eksperimenti

Da bi ovrednotili uspešnost predlagane metode za razpoznavanje aktivnosti z uporabo šablon aktivnosti, smo z metodami računalniškega vida pridobili podatke za tri tipe košarkarskih aktivnosti ("52", "Flex" in "Motion"). Vsako aktivnost so igralci večkrat ponovili pod strogim nadzorom trenerja. Tako smo pridobili podatke za 61 ponovitev teh treh aktivnosti, od katerih je bilo 32 aktivnosti odigranih brez obrambe, ostalih 29 pa je bilo odigranih v prisotnosti pasivne obrambe. Izmed 61 aktivnosti jih je 20 pripadalo prvemu tipu (9 brez obrambe in 11 z obrambo), 21 drugemu (10 brez in 11 z obrambo) in 20 tretjemu tipu aktivnosti (13 brez in 7 z obrambo). Pri vsakem tipu aktivnosti so bile prisotne tako leve kot desne izvedbe. Slika 4.5 prikazuje nekaj primerov trajektorij za aktivnost tipa "Flex".

Da bi se izognili napaki avtomatske segmentacije, smo testne posnetke segmentirali ročno. V fazi razpoznavanja smo aktivnosti primerjali s 17 šablonami aktivnosti, pri vsaki šablone pa je bila možna njena leva in desna izvedba. Šablone so bile povzete iz košarkarske literature [72, 67, 68] in na podlagi posveta s



Slika 4.5: (a - e) Primer idealnih poti gibanja igralcev (debela črna črta), kot so bile definirane v šabloni aktivnosti ter trajektorij igralcev pri štirikratni ponovitvi iste aktivnosti.

trenerjem. Cilj eksperimenta je bil raziskati različne vidike metode razpoznavanja kot sta optimalni prag, pri katerem še razvrstimo aktivnost v določen razred ter robustnost metode na šum. Šum je lahko posledica pomanjkljive segmentacije podatkov na prvi stopnji analize ali nepopolne detekcije akcij. V opisu pa je izražen z dodatnimi simboli.

Eksperiment 1: Separabilnost metode

Namen testa separabilnosti metode je določiti prag, na podlagi katerega lahko ugotovimo pripadnost neke aktivnosti določenemu razredu aktivnosti. Da bi določili separabilnost med razredoma, smo v prvem primeru opravili navzkrižno analizo med vsemi 61 semantičnimi opisi aktivnosti ter na ta način izračunali povprečno razdaljo med aktivnostmi istega razreda in aktivnostmi, ki pripadajo različnim razredom. Na ta način smo dobili križno-korelacijsko matriko za tri vrste aktivnosti - Tabela 4.3.

V drugem primeru smo želeli določiti razdalje med opisoma v primeru, da je bila aktivnost razpoznavana s šablono istega tipa in v primeru, ko sta bila

Tabela 4.3: *Križno-korelacijska matrika – povprečna razdalja med pari semantičnih opisov za tri izbrane vrste aktivnosti.*

	Vrsta aktivnosti		
Vrsta aktivnosti	52	Flex	Motion
52	0.3205	0.6340	0.7198
Flex	0.6340	0.4893	0.6998
Motion	0.7198	0.6998	0.4667

tip šablone in tip razpoznavane aktivnosti različna. V ta namen smo opazovali, kako se razdalja med aktivnostjo in šablono spreminja v primeru, da gre za isti tip napada in šablone in v primeru, da se tipa razlikujeta. Pri tem smo vedno upoštevali samo izvedbo šablone, pri kateri smo dobili večje ujemanje opisov. Podrobnejši rezultati eksperimenta so podani v poglavju Dodatek B.

Tabela 4.4: *Križno-korelacijska matrika – povprečna razdalja med pari semantičnih opisov aktivnosti in šablon aktivnosti. Primerjava razdalj prave šablone in ostalih 16 šablon.*

	Razred šablon	
Razred aktivnosti	Prava šablona	Povprečje ostalih 16 šablon
52	0.3281	0.6892
Flex	0.3847	0.6757
Moving stack	0.5106	0.7111

Kot je razvidno iz Tabele 4.3, je razdalja med aktivnostmi znotraj istega razreda bistveno manjša od razdalje med aktivnostmi iz različnih razredov. Do podobnega zaključka pridemo tudi v primeru, ko primerjamo razdalje med aktivnostjo in šablono istega ali različnega tipa (Tabela 4.4). Na podlagi teh rezultatov lahko torej zaključimo, da je ta prag, pri katerem lahko aktivnost še pripišemo v določen razred aktivnosti, med 0.51 in 0.64, pri čemer je bolje uporabiti zgornjo mejo, saj nam tako postavljena meja omogoča pravilno razpoznavanje tudi tistih aktivnosti, ki so bile nekoliko slabše izvedene. Z višanjem praga se sicer lahko zgodi, da dobimo pri večjem številu šablon razdalje podobnosti, ki so manjše od praga, vendar pa to ni problem, saj je aktivnost vedno pripisana razredu z najmanjšo razdaljo. Hkrati pa lahko to informacijo koristno uporabimo v naslednjem koraku analize - pri ocenjevanju aktivnosti, saj

lahko postopek ocenjevanja izvedemo z vsemi šablonami, kjer je bila razdalja manjša od mejne vrednosti.

Eksperiment 2: Uspešnost razpoznavanja aktivnosti

Da bi ugotovili, kako na uspešnost razpoznavanja vpliva šum, smo v semantične opise analiziranih aktivnosti dodali različno število dodatnih, napačnih simbolov, ki so bili naključno izbrani iz slovarja simbolov. Dodatni simboli so bili v prvotni opis dodani na naključna mesta, zaradi česar smo vsak eksperiment ponovili 20 krat ter na ta način za vsako izbrano količino šuma proces razpoznavanja ponovili 1220 (20*61) krat. Tabela 4.5 prikazuje povprečno uspešnost razpoznavanja v primeru različne količine dodanih simbolov.

Tabela 4.5: *Povprečna uspešnost razpoznavanja v primeru različnega števila dodanih simbolov. Odstotki predstavljajo rezmerje med številom dodanih simbolov in številom simbolov v prvotnem opisu.*

Delež dodanih simbolov [%]	0	50	100	200	300	400	500
Uspešnost razpoznavanja [%]	100	99.0	98.9	97.5	96.2	94.8	91.8

Kot je razvidno iz Tabele 4.5, je bila v primeru brez šuma uspešnost razpoznavanja aktivnosti 100%. Pri tem je bila uspešnost določanja korespondence med igralci 95,1% (Dodatek B). Pri podrobnejši analizi smo ugotovili, da pride v treh izmed 61 primerov do napake pri določanju korespondence v primeru slabše izvedbe aktivnosti enega izmed igralcev. V navedenih primerih je prišlo do zamenjave vlog dveh igralcih, kljub temu pa je bila razdalja med opisoma $S(C_l)$ še vedno najmanjša pri šabloni, ki je bila istega tipa kot analizirana aktivnost. Tako je bila aktivnost, klub napačno določenim vlogam, vseeno pravilno razpoznana.

V primeru dodanih simbolov lahko ugotovimo, da se uspešnost razpoznavanja z dodajanjem nepravilnih simbolov sicer zmanjšuje, vendar ne bistveno. Tako je tudi v primeru ekstremnega šuma, ko je bilo dodanih petkrat več dodatnih simbolov kot je bila prvotna dolžina opisa, uspešnost razpoznave še vedno 91.8%, kar pomeni, da je bilo v tem primeru napačno razpoznanih zgolj 5 od 61 aktivnosti. Na podlagi teh rezultatov lahko zaključimo, da je predlagana metoda zelo robustna na vplive pomanjkljive segmentacije ali nepopolne detekcije akcij. Razlog za to je mera podobnosti (Levenshteinova razdalja), ki smo jo uporabili


za izračun podobnosti med opisoma, saj le-ta upošteva tako prisotnost simbolov v opisu kot njihov vrstni red. V primeru, da pride v procesu pridobivanja semantičnega opisa do razumne količine napačnih simbolov, se sicer razdalje med analiziranim opisom in opisi šablon povečajo, vendar pa to ne vpliva na končni vrstni red podobnosti med opisi. Prav tako lahko ob podrobni analizi posameznih rezultatov, ki se nahajajo v prilogi Dodatek B, ugotovimo, da je metoda razpoznavanja precej neobčutljiva na to, ali je pri izvedbi aktivnosti bila prisotna obramba ali ne, saj so rezultati razpoznavanja praktično identični.

Eksperiment 3: Razpoznavanje zaporednih aktivnosti

Med košarkarsko tekmo se večkrat zgodi, da ekipa v enem napadalnem ciklu odigra več zaporednih aktivnosti. To se zgodi v primeru, ko si po odigrani prvi aktivnosti ekipa ne uspe ustvariti dobre priložnosti za met, pa tudi v primeru skoka v napadu ali v primeru prekrška obrambe. Zato nas je zanimalo, ali je mogoče s predlagano metodo razpoznati tudi večje število zaporedno odigranih aktivnosti. V ta namen smo več sekvenc aktivnosti različnega tipa združili v eno skupno aktivnost. Ugotovili smo, da je s predlagano metodo mogoče uspešno razpoznati dve zaporedno odigrani aktivnosti, saj je v tem primeru razdalja do tistih dveh šablon, ki predstavljata odigrane aktivnosti, bistveno nižja kot do vseh ostalih (slika 4.6). Pri razpoznavanju večjega števila zaporedno odigranih aktivnosti, ki pa se pri košarki pojavljajo precej redkeje, pa metoda ni več uspešna. Tako bi bilo v teh primerih potrebno izbrati nekoliko drugačen pristop analize. Ena izmed rešitev je uporaba drsečega časovnega okna, ki bi ga premikali od začetka pa do konca aktivnosti. Znotraj tega okna pa bi s opisano metodo razpoznavali aktivnosti, ki so bile odigrane.

4.4 Zaključek

Predstavljen je bil postopek razpoznavanja aktivnosti z uporabo šablon aktivnosti. V ta namen smo razvili model igrišča (poglavje 4.1.1) in na trajektorijah temelječe detektorje košarkarskih akcij (poglavje 4.1.2), s pomočjo katerih lahko iz trajektorij gibanja igralcev dobimo strnjen višjenivojski opis dogajanja na igrišču. Z uporabo istih detektorjev pred postopkom razpoznavanja zgradimo tudi semantične opise za trajektorije, ki jih pridobimo iz šablon



Slika 4.6: Rezultati primerjanja dveh zaporedno odigranih aktivnosti s 17 različnimi šablonami aktivnosti. Rdeča črta prikazuje prag pri katerem je aktivnost še klasificirana v razred šablone.

aktivnosti. Na ta način dobimo zbirko semantičnih opisov, ki jih uporabimo v postopku razpoznavanja.

Razpoznavanje temelji na primerjavi semantičnega opisa neznane aktivnosti z opisom šablone. Postopek primerjave je razdeljen v dve fazi. V prvi fazi iz primerjanih semantičnih opisov določimo korespondenco med vlogami igralcev v šabloni in vlogami v analizirani aktivnosti (poglavje 4.2.1). V ta namen za vsakega igralca na igrišču zgradimo njemu lastno agendo, ki vsebuje opise vseh akcij, v katerih je igralec sodeloval. Z navzkrižnim primerjanjem dobljenih agend lahko določimo pravilno korespondenco med vlogami igralcev ter izračunamo podobnost med neznano aktivnostjo in šablono. Podobnost je podana kot razdalja med opisoma, ki jo izračunamo z uporabo modificirane Levenshteinove razdalje. Postopek primerjanja ponovimo za vsako izmed šablon aktivnosti ter na podlagi dobljenih razdalj klasificiramo neznano aktivnost v razred s šablono, pri kateri je bila razdalja med opisoma najmanjša (poglavje 4.2.2).

Evaluacijo predlagane metode smo izvedli na 61 vzorcih treh različnih košarkarskih aktivnosti. Kot je razvidno iz rezultatov, je predlagana metoda razpoznavne zelo robustna, saj je z njo mogoče pravilno razpoznati tip odigrane aktivnosti tudi v primeru slabše segmentacije ali slabše izvedbe aktivnosti.

Predlagana metoda omogoča razpoznavanje tudi dveh zaporedno odigranih aktivnosti, medtem ko bi v splošnem problem večjega števila ponavljajočih se aktivnosti morali rešiti z uvedbo drsečega časovnega okna primerne dolžine, znotraj katerega bi iskali odigrane aktivnosti.

Poleg dobre uspešnosti razpoznavanja vrste odigranega napada, so rezultati eksperimentov pokazali tudi veliko uspešnost pri določanju korespondence med vlogami igralcev v šabloni in vlogami v aktivnosti. Oba podatka sta namreč ključna za naslednjo fazo analize - to je ocenjevanje izvedbe aktivnosti z uporabo šablon aktivnosti.

Poglavje 5

Ocenjevanje izvedbe aktivnosti z uporabo šablon aktivnosti

Eden pomembnih dolgoročnih ciljev športne stroke je izdelava postopkov, ki bi omogočali čim bolj objektivno analizo dogajanja na igrišču. To je eden od razlogov za vse večje zanimanje športnih in drugih strokovnjakov za izdelavo avtomatskih ali pol-avtomatskih metod za analizo gibanja ljudi v športu [34, 35, 36, 58, 73]. Glavni namen tovrstnih raziskav je izdelava metod za avtomatsko interpretacijo in ocenjevanje dogajanja na igrišču, na podlagi katerih bi bilo mogoče pridobiti informacijo o bistvenih prednostih in slabostih posameznega igralca in ekipe kot celote.

V tem koraku analize imamo opravka z relativno majhno količino zelo specifičnih podatkov, kar nam omogoča, da izvedemo zelo natančno analizo aktivnosti. To pa pomeni, da je potrebno kar se da natančno preučiti vsako posamezno akcijo, ki sestavlja opazovano aktivnost. Poleg tega pa je potrebno natančno preučiti tudi taktično sestavo aktivnosti, ki jo predstavlja predvsem analiza časovnih lastnosti izvedbe teh akcij oziroma njihova časovna usklajenost.

V nadaljevanju bomo predstavili dva metodološko različna pristopa za ocenjevanje kakovosti izvedbe aktivnosti. Obema postopkoma je skupno to, da uporabljata na trajektorijah temelječe detektorje osnovnih elementov košarkarske igre in to, da upoštevata prostorske in časovne lastnosti aktivnosti, ki jih dobimo iz šablon. Bistvena razlika med obema postopkoma pa je način modeliranja teh lastnosti. Prva metoda temelji na uvedbi hierarhične strukture aktivnosti, medtem ko je glavna ideja drugega pristopa zagotoviti strogo časovno strukturo aktivnosti, ki ponazarja usklajenost med igralci.

V tem poglavju je najprej opisan postopek, s katerim iz šablon aktivnosti določimo časovne in logične relacije med akcijami igralcev (podpoglavje 5.1). Dobljeno informacijo uporabimo v postopku gradnje modelov aktivnosti (podpoglavji 5.2 in 5.3). V podpoglavju 5.4 je opisana eksperimentalna validacija obeh postopkov ocenjevanja izvedbe aktivnosti. Na koncu pa so v podpoglavju 5.5 podani zaključki in iz rezultatov pridobljene ugotovitve.


5.1 Določanje časovnih relacij

Da bi lahko ocenili časovno usklajenost igralcev oziroma njihovih akcij, je najprej potrebno določiti tiste časovne relacije med temi akcijami, ki so za dano aktivnost ključnega pomena. V ta namen uporabimo šablono aktivnosti, v kateri je natančno navedeno, kdaj in kje se mora posamezen igralec nahajati med samo izvedbo aktivnosti. Slika 5.1 prikazuje primer relativno preproste aktivnosti, imenovane "Zaporedni blokadi". Aktivnost sestavljajo 4 akcije, ki jih izvajajo trije igralci. Opišemo jo lahko na naslednji način:

- Najprej se mora igralec 4 premakniti na točko blokade.
- Potem, ko se je igralec 4 postavil na mesto blokade, mora igralec 5 steči čim bližje igralca 4 ter tako izkoristiti postavljeno blokado. Medtem se mora igralec 3 postaviti na mesto blokade za igralca 4.
- Potem, ko se igralca 3 in 5 postavita na novi poziciji, mora igralec 4 steči mimo igralca 3 ter izkoristiti postavljeno blokado.

Zgornji opis vsebuje vse podatke, ki so za akcijo pomembni. Te podatke v šabloni predstavimo ločeno, kot prostorske značilnosti (slika 5.1-a) in časovne značilnosti (slika 5.1-b) aktivnosti. Podan zapis je zelo podoben zapisu, s katerim športni strokovnjaki podajajo svoje ideje igralcem, vendar je nekoliko prilagojen za namene računalniške obdelave.

Čeprav je predstavljena aktivnost razmeroma enostavna, pa vsebuje več sočasnih in zaporednih akcij, ki se morajo zgoditi v točno določenem časovnem zaporedju. Pri določanju časovnih relacij med igralci uporabimo tri najbolj splošne časovne relacije, ki jih določa Allenova časovna algebra [74, 75]. Te relacije so:




Slika 5.1: Primer aktivnosti "Zaporedni blokadi". a) Prikaz prostorskih značilnosti. b) Prikaz časovnih značilnosti.

- Akcija A se mora zgoditi **pred** akcijo B. V tem primeru se mora akcija A začeti in končati pred začetkom akcije B.
- Akcija A se mora zgoditi **znotraj** akcije B. V tem primeru se mora začetek akcije B zgoditi po začetku akcije A, konec akcije B pa se mora zgoditi pred koncem akcije A.
- Akcija A se mora zgoditi **sočasno** z akcijo B. V tem primeru se morata začetka in konca obeh akcij zgoditi približno ob istem času.

Da bi določili časovne relacije med akcijami, na podlagi podatkov iz šablone zgradimo trajektorije posameznih igralcev ter jih analiziramo z detektorji akcij. Tako pridobimo časovni profil aktivnosti, ki pove, kdaj se je določena akcija zgodila (slika 5.2). V procesu gradnje časovnega profila se nekatere akcije razdelijo v več novih podakcij. Tako na primer iz blokade nastaneta dve podakciji - *gibanje* igralca na pozicijo blokade in dejanska *blokada* med igralcema.

Iz časovnega profila šablone lahko z upoštevanjem zgornjih pravil avtomatsko določimo relacije med akcijami. Pri tem je potrebno poudariti, da je pri določanju relacij med akcijami zelo pomembno, da se upoštevajo zgolj najpomembnejše relacije. Torej zgolj relacije med tistimi akcijami, ki se zgodijo neposredno *pred* ali *znotraj* opazovanega elementa. V postopku določanja relacij se sicer lahko zgodi, da pride tudi do relacij med tistimi akcijami, ki medsebojno niso neposredno odvisne, vendar pa bi v primeru dobro odigrane aktivnosti, vseeno morale biti opažene. Na sliki 5.2 je takšna relacija med akcijama *znotraj*, med blokado 4-5 in gibanjem igralca 3. Ti dve akciji sta medsebojno zgolj posredno odvisni, saj ni nujno, da se mora blokada zares zgoditi med gibanjem igralca 3, vendar pa



Slika 5.2: Časovni profil aktivnosti "Zaporedni blokadi". Polne črte predstavljajo časovno relacijo pred, črtkane črte pa relacijo znotraj.

bi morala biti v primeru pravilno odigrane aktivnosti opažena tudi ta relacija. Potrebno je poudariti, da je takšnih primerov malo in zato ne vplivajo bistveno (v večini primerov sploh ne vplivajo) na končno oceno izvedbe aktivnosti.

5.1.1 Ocenjevanje tehničnih lastnosti posameznih košarkarskih akcij

V poglavju 4.1.2 smo že opisali nekatere detektorje osnovnih košarkarskih akcij, s katerimi smo želeli ugotoviti zgolj ali se je neka akcija zgodila ali ne. Sedaj pa potrebujemo bolj natančne detektorje teh akcij. Pri ocenjevanju kakovosti izvedbe posamezne akcije predpostavimo, da je kvaliteta izvedbe akcije korelirana tudi s položajem izvedbe te akcije. V primeru večjih odstopanj v položaju pa to neposredno pomeni, da je bil opazovani element slabše izveden.

- **Blokada** je bila že podrobneje opisana v poglavju 4.1.2, zato jo na tem mestu zgolj povzamemo. Ocena kvalitete blokade je definirana kot

$$S_{blok} \triangleq \frac{\mathcal{L}(blok|d_t, v_t)}{\mathcal{L}(blok|0, 0)}, \quad (5.1)$$

kjer je verjetje za blokado definirano kot

$$\mathcal{L}(blok|d_t, v_t) \triangleq \mathcal{N}(d_t; 0, \sigma_d) \cdot \mathcal{N}(v_t; 0, \sigma_v). \quad (5.2)$$

Kot je razvidno iz definicije detektorja blokade, pri ocenjevanju blokade ni upoštevan dejanski položaj njene izvedbe. Glavni razlog za to je, da se igralci med samo izvedbo blokade prilagajajo tudi obrambnim igralcem, zaradi česar lahko položaj blokade nekoliko odstopa od položaja, definirane v šabloni. Poleg tega pa je ta položaj že implicitno zajet v oceni gibanja igralca na mesto blokade. Tako je v primeru velikega odstopanja položaja blokade ta napaka že zajeta v oceni gibanja igralca na mesto blokade.

- **Gibanje igralca** je v šablonah košarkarskih napadov podano s točno določeno potjo, ki naj bi jo igralec opravil. Pot je sestavljena iz enega ali več linearnih odsekov, kjer ima vsak odsek začetno točko A_i in končno točko B_i . Kvaliteto izvedbe gibanja igralca ($S_{gibanje}$) definiramo kot produkt funkcije oddaljenosti od predpisane poti $\mathcal{N}(d_t; 0, \sigma_d)$ ter razmerja $f_{pot}(t)$ med predpisano potjo in potjo, ki jo je igralec dejansko opravil do trenutka t

$$S_{gibanje}(t) \triangleq \mathcal{N}(d_t; 0, \sigma_d) \cdot f_{pot}(t). \quad (5.3)$$

Parameter d_t v enačbi (5.3) predstavlja l_2 razdaljo med trenutno pozicijo igralca in najbližjo točko na predvideni poti, funkcija $f_{pot}(t)$ pa je definirana kot

$$f_{pot}(t) = \frac{\sum_{i=1}^M \sum_{j=1}^t (\Delta \vec{x}_j \cdot \overrightarrow{A_i B_i})}{\sum_{i=1}^M \|\overrightarrow{A_i B_i}\|}, \quad (5.4)$$

kjer predstavlja M število linearnih odsekov poti, $\|\overrightarrow{A_i B_i}\|$ predstavlja dolžino i -tega segmenta in izraz $\sum_{j=1}^t (\Delta \vec{x}_j \cdot \overrightarrow{A_i B_i})$ označuje vsoto skalarnih produktov med trenutnim vektorjem gibanja igralca $\Delta \vec{x}_j$ in vektorjem idealnega gibanja $\overrightarrow{A_i B_i}$ na i -tem segmentu.

- **Podaja žoge.** V primeru, da je na voljo tudi podatek o gibanju žoge, le-to obravnavamo enako kot gibanje igralcev. Torej je kvaliteta podaje definirana z enačbama (5.3) in (5.4), le da trajektorijo igralca nadomesti trajektorija žoge. Odsek, ki ga opazujemo, pa je v šabloni definiran kot pot, ki jo mora žoga opraviti med podajo.

Na podlagi opisanih detektorjev dobimo dober vpogled v tehnično izvedbo posameznih akcij, vendar pa ne moremo na podlagi teh ocen še nič reči o skupni izvedbi celotne aktivnosti, saj mora ta ocena vsebovati tudi oceno o taktični izvedbi aktivnosti. V ta namen sta v nadaljevanju opisana dva različna pristopa za ocenjevanje teh taktičnih značilnosti. Prvi temelji na **Bayesovih mrežah** (dodatek C.3), kjer skušamo v mrežo vgraditi hierarhično strukturo aktivnosti. Časovno-taktične značilnosti aktivnosti v tem primeru ocenjujemo s časovnimi funkcijami, ki predstavljajo najnižji nivo v mreži. Pri drugem pristopu pa poskušamo časovno-taktično zasnovo aktivnosti modelirati z uporabo **Petrijeve mreže** (dodatek C.4). V tem primeru je mreža zgrajena na tak način, da so relacije med posameznimi akcijami zajete v sami strukturi mreže.

5.2 Uporaba Bayesovih mrež za ocenjevanje ustreznosti izvedbe aktivnosti

Da bi lahko Bayesove mreže uporabili pri ocenjevanju izvedbe aktivnosti, jih moramo najprej zgraditi. V ta namen moramo določiti število spremenljivk mreže ter vzročne zveze med temi spremenljivkami. V splošnem sta se za reševanje tega problema izoblikovala dva pristopa. Prvi temelji na določanju strukture mreže s pomočjo učnih podatkov, ki jih je možno dobiti z dolgotrajnim opazovanjem spremenljivk sistema, ki ga želimo analizirati. Drugi pristop pa temelji na uporabi ekspertnega znanja, kjer ekspert določi strukturo mreže.

Za prvi pristop je na voljo veliko metod in postopkov [76, 77, 78], s katerimi je mogoče iz podatkov določiti strukturo in parametre Bayesove mreže. Glavni problem teh metod je, da zahtevajo veliko število učnih primerov že pri učenju mrež z relativno majhnim številom spremenljivk. Tako so na primer Cheng in drugi [79] za učenje mreže, ki je bila sestavljena iz osmih spremenljivk in osmih povezav med spremenljivkami, potrebovali vsaj tisoč učnih vzorcev, za učenje mreže z 37 spremenljivkami in 46 povezavami, pa kar 10.000 učnih vzorcev. V našem primeru je tak pristop praktično neuporaben, saj bi bilo potrebno za namene takšnega modeliranja aktivnost ponoviti nekaj tisočkrat.

Druga možnost je izgradnja mreže s pomočjo eksperta, kjer ekspert določi število in vzročne zveze med spremenljivkami v mreži. V tem primeru bi moral športni ekspert poznati teorijo ter zakonitosti Bayesovih mrež ali pa bi moral

imeti vedno na voljo računalniškega eksperta, ki mu na podlagi določenih pravil, kot je na primer postopek gradnje Bayesovih mrež s pomočjo vzročnih mrež [19], pomaga pri gradnji mrež. Ker pa športni strokovnjaki razvijajo vedno nove taktične zamisli, bi bil takšen postopek precej zamuden in drag. Zato smo razvili nov pristop na podlagi katerega je mogoče iz šablone košarkarske aktivnosti avtomatsko zgraditi Bayesovo mrežo.


5.2.1 Izgradnja Bayesove mreže iz šablone aktivnosti

Šablona aktivnosti vsebuje vso informacijo, ki je potrebna pri izgradnji Bayesove mreže. V njej sta že določena število in vrsta akcij, ki so pomembne za pravilno izvedbo aktivnosti, prav tako pa so določene tudi časovne odvisnosti med njimi (poglavje 5.1). Vso to informacijo upoštevamo pri gradnji Bayesove mreže. Spremenljivke mreže razdelimo v štiri nivoje (slika 5.3). Spremenljivke na višjih dveh nivojih (aktivnost in igralci) so abstraktne, saj jih ni mogoče določiti neposredno iz trajektorij igralcev. Te spremenljivke podajajo informacijo o tem, kako natančno je bila izvedena opazovana aktivnost (najvišji nivo) oziroma kako dobro je posamezen igralec odigral svojo vlogo znotraj te aktivnosti (drugi nivo). Spremenljivke teh dveh nivojev so pogojno odvisne od spremenljivk na spodnjih dveh nivojih. Končna verjetnost teh stanj je podana v obliki pogojne verjetnosti $p(A_i = da|e)$ in je odvisna od navideznih dejstev (e) na spodnjih dveh nivojih, ki jih dobimo z uporabo detektorjev akcij. Verjetnost odraža uspešnost izvedbe celotnega napada (stanje na najvišjem nivoju) ter oceno kvalitete izvedbe posameznega igralca (stanja na drugem nivoju). Maksimalna končna ocena aktivnosti $p(A_i = da|e)$ je odvisna od strukture mreže ter njenih parametrov in ni omejena na področje med 0 in 1. Zato je potrebno, zaradi možnosti primerjanja ocen za različne tipe aktivnosti, to oceno normalizirati na to področje. Tako je končna ocena aktivnosti določena kot

$$p_{norm}(A_i = da|e) = \frac{p(A_i = da|e)}{p(A_i = da| \forall e = da)}. \quad (5.5)$$

Spremenljivke na tretjem in četrtem nivoju se razlikujejo glede na vsebino, ki jo predstavljajo v hierarhiji aktivnosti. Tako spremenljivke na tretjem nivoju predstavljajo tehnično izvedbo posamezne akcije. Na zadnjem, četrtem nivoju pa se nahajajo spremenljivke, ki predstavljajo časovne relacije med temi

akcijami. Verjetnosti teh spremenljivk so dobljene z uporabo časovnih funkcij (Poglavje 5.2.2).



Slika 5.3: Primer Bayesove mreže za aktivnost "Zaporedni blokadi". Vozlišča predstavljajo naključne spremenljivke, povezave med njimi pa predstavljajo pogojne odvisnosti med posameznimi spremenljivkami.

Zaradi izbranega verjetnostnega modela odločanja (Bayesove mreže), se pri ocenjevanju uspešnosti izvedbe aktivnosti upoštevajo maksimalne vrednosti odzivov detektorjev in časovnih funkcij, saj bi bila v primeru upoštevanja trenutnega odziva končna ocena napada zelo nizka. Razlog za to je, da so akcije izvedene v določenem časovnem zaporedju, odziv detektorja pa, po tem ko igralec akcijo preneha izvajati, izzveni. To posledično pomeni, da bi bila končna ocena izvedbe aktivnosti v večini primerov nizka, saj bi upoštevala zgolj akcije, ki so bile odigrane na koncu aktivnosti. Kljub temu se pri analizi aktivnosti upošteva tudi časovni profil detektorja, saj je le-ta uporabljen pri določanju časovnih relacij. Te relacije so določene s časovnimi funkcijami, ki so definirane v nadaljevanju.

5.2.2 Časovne funkcije

Časovne relacije definirajo zaporedje, v katerem morajo igralci izvesti posamezne akcije. Predhodno smo že opisali tri časovne relacije, ki jih matematično opišemo z uporabo časovnih funkcij:

- Akcija A_1 se je zgodila **pred** akcijo A_2 . Pri določanju časovne funkcije za to relacijo je potrebno najprej izračunati časovni težišči (t_X) odzivov S_{A_1} in S_{A_2} za opazovani akciji A_1 in A_2

$$t_X = \frac{\sum_{i=1}^N i \cdot S_X(i)}{\sum_{i=1}^N i}, \quad (5.6)$$

kjer je $X \in \{A1, A2\}$, N je trajanje opazovanja in $S_X(i)$ vrednost detektorja v trenutku i . Kvaliteta ocene časovne relacije *pred* je določena kot

$$TR_{pred} = \begin{cases} 0 & t_{E1} > t_{E2} \\ k \cdot g(x; \mu, \sigma) & t_{E1} \leq t_{E2} \end{cases}, \quad (5.7)$$

kjer predstavlja $g(x; \mu, \sigma)$ log-normalno porazdelitveno funkcijo s srednjo vrednostjo μ in varianco σ^2

$$g(x; \mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} e^{-\{\ln x - \mu\}^2 / 2\sigma^2}. \quad (5.8)$$

V enačbi (5.7) predstavlja parameter k normalizacijski faktor, ki normalizira funkcijo $g(x; \mu, \sigma)$ na interval $[0, 1]$. S funkcijo $g(x; \mu, \sigma)$ dodatno kaznujemo izredno kratke časovne intervale $t_{A2} - t_{A1}$ (krajše od pol sekunde) med dogodkoma, poleg tega pa kaznujemo tudi predolge časovne intervale, s čimer omejimo časovno okno, v katerem se dva zaporedna dogodka lahko zgodita.

- Akcija $A1$ se je zgodila **znotraj** akcije $A2$. Časovna relacija *znotraj* predstavlja dva dogodka, kjer se prvi dogodek začne in konča znotraj drugega dogodka. Časovna funkcija za oceno te relacije je podana z enačbo

$$TR_{znotraj} = \frac{\sum_{i=1}^N \min\{S_{A1}(i), S_{A2}(i)\}}{\min\{\sum_{i=1}^N S_{A1}(i), \sum_{i=1}^N S_{A2}(i)\}}. \quad (5.9)$$

S to funkcijo ugotovimo, kolikšna je pokritost prvega odziva z drugim. Ta pokritost je izražena kot razmerje med presekom (operacijo min) odzivov obeh detektorjev ter ploščino manjšega odziva (torej odziva, ki naj bi se zgodil *znotraj*).

- Akcija $A1$ se je zgodila **sočasno** z akcijo $A2$. Časovna relacija *sočasno* predstavlja dva dogodka, ki naj bi se začela in končala v približno istih časovnih trenutkih. Časovna funkcija za oceno te relacije je podana z enačbo

$$TR_{socasno} = \frac{\sum_{i=1}^N \min\{S_{A1}(i), S_{A2}(i)\}}{\sum_{i=1}^N \max\{S_{A1}(i), S_{A2}(i)\}}. \quad (5.10)$$


Funkcija podaja razmerje med presekom (operacija min) in unijo (operacija max) odzivov detektorjev. V primeru, da sta odziva detektorjev popolnoma poravnana, je presek odzivov enak njuni uniji.

5.2.3 Določanje parametrov Bayesove mreže

Poleg strukture Bayesove mreže je za ocenjevanje aktivnosti potrebno določiti tudi parametre vzročnih povezav med posameznimi spremenljivkami. Ker tega ne moremo narediti na podlagi učnih primerov, smo vrednosti posameznih parametrov določili hevristično, na podlagi ekspertnega znanja in izkušenj, ki smo jih pridobili v času raziskav. Intille in Bobick sta v svojih delih [34, 80] ugotovila, da je pri določanju parametrov predvsem pomembna pravilna interpretacija relacij med vzroki in posledicami, manj pa dejanska vrednost parametra. Kot bomo pokazali v nadaljevanju je tako na primer veliko bolj pomembno, da je pravilno določene relacija, da dobra ocena posameznega igralca pozitivno vpliva na oceno celotne aktivnosti, kot pa ali je vrednost tega parametra 0.9 ali 0.95.

Slika 5.4 prikazuje primer razmeroma preprostega modela aktivnosti, ki ga sestavlja 17 spremenljivk - *aktivnost*, 3 igralci, 5 akcij in 8 časovnih relacij. Spremenljivke mreže predstavljajo uspešnost izvedbe posameznih elementov aktivnosti. Tako na primer spremenljivka *aktivnost* podaja uspešnost izvedene aktivnosti, atributi $p1$, $p2$ in $p3$ podajajo uspešnost igranja posameznih igralcev, atributi BLOKADA in GIBANJE predstavljajo uspešnost izvedbe posameznih akcij igralcev, atributi PRED in ZNOTRAJ pa uspešnost izvedbe časovne relacij med ustreznimi akcijami.

Naš cilj je ugotoviti, kolikšna je verjetnost uspešno odigrane aktivnosti v primeru, da so bile posamezne akcije uspešno odigrane in da so bile časovne relacije med njimi pravilne. Torej želimo določiti uspešnost aktivnosti ($p_{norm}(aktivnost|e)$) v primeru, da so bila opažena dejstva (e) o tej aktivnosti. V



Slika 5.4: Primer Bayesove mreže, za aktivnost "Slovan1".

ta namen moramo najprej določiti parametre, ki definirajo mrežo. Prvi parameter je *a priori* verjetnost, da je bila aktivnost uspešno odigrana ($p(aktivnost)$). Ker nimamo nobene *a priori* informacije o aktivnosti, postavimo to verjetnost na $p(aktivnost = da) = 0.5$.

aktivnost	
da	ne
0.5	0.5

Tabela 5.1: Tabela *a priori* verjetnosti za uspešno izvedeno aktivnost $p(aktivnost)$.

Poleg *a priori* verjetnosti za aktivnost je potrebno določiti tudi verjetnosti, da je igralec uspešno odigral aktivnost v primeru, da je bila aktivnost odigrana uspešno ali neuspešno (Tabela 5.2). Torej želimo določiti pogojno verjetnost za uspešnost igralca pri pogoju uspešne aktivnosti $p(igr|aktivnost)$.

Pri določanju parametrov v tabeli 5.2 smo predpostavili, da je pogojna verjetnost za to, da je igralec dobro odigral svojo vlogo v primeru, da je bila aktivnost uspešno odigrana, enaka $p(igralec = da|aktivnost = da) = 0.9$. Pogojna verjetnost, da je igralec dobro odigral svojo vlogo, kljub temu, da je bila aktivnost odigrana slabo, pa je $p(igralec = da|aktivnost = ne) = 0.3$. Parametre določimo na podlagi predpostavke, da so igralci izkušeni in so opazovano aktivnost na treningih že večkrat odigrali. Zaradi tega je verjetnost, da bodo svojo vlogo

	aktivnost	
igralec	da	ne
da	0.9	0.3
ne	0.1	0.7

Tabela 5.2: Tabela pogojskih verjetnosti za uspešnost igralca pri pogoju uspešne aktivnosti $p(igr|aktivnost)$.

odigrali uspešno, večja. Ker nimamo nobene dodatne informacije o uspešnosti posameznih igralcev, predpostavimo, da so pogojske verjetnosti za vse igralce enake. V primeru, da bi imeli na voljo tudi to informacijo, ki bi jo lahko pridobili od trenerja ali iz statistike tekem, bi lahko parametre v tabeli temu ustrezno spreminjali. Tako bi na primer uspešnejšim igralcem pripisali višjo vrednost parametra $p(igr1 = da|aktivnost = da)$, manj uspešnim pa nižjo.

Poleg navedenih pogojskih verjetnosti moramo določiti tudi verjetnost, da je bila posamezna akcija igralca odigrana uspešno v primeru, da je bila igra igralca dobra. V ta namen določimo pogojsko verjetnost za uspešnost akcije v primeru uspešnosti igralca $p(akcija|igr)$.

	igralec	
akcija	da	ne
da	0.8	0.4
ne	0.2	0.6

Tabela 5.3: Tabela pogojskih verjetnosti za uspešnost posamezne akcije v primeru uspešnega igranja igralca $p(akcija|igralec)$.

V tabeli 5.3 predstavlja parameter $p(akcija = da|igralec = da) = 0.8$ pogojsko verjetnost, da je bila akcija uspešno odigrana v primeru, da je igralec igral dobro, parameter $p(akcija = da|igralec = ne) = 0.4$ pa pogojsko verjetnost, da je bila akcija uspešna, kljub temu, da je igralec igral slabo.

Zadnja izmed pogojskih verjetnosti je pogojska verjetnost za pravilno opaženo časovno relacijo v primeru, da sta bili akciji, na kateri se časovna relacija nanaša, uspešno izvedeni ($p(cas|akcija1, akcija2)$).

	akcija1,akcija2			
čas	da da	ne da	da ne	ne ne
da	0.9	0.5	0.5	0.1
ne	0.1	0.5	0.5	0.9

Tabela 5.4: Tabela pogojskih verjetnosti za pravilno časovno izvedbo akcij v primeru, da sta bili akciji pravilno izvedeni $p(cas|akcija1, akcija2)$.


V tabeli 5.4 predstavlja parameter $p(cas = da|akcija1 = da, akcija2 = da) = 0.9$ verjetnost, da je bila časovna relacija med akcijama pravilna v primeru, da sta bili akciji pravilno izvedeni. Vrednost tega parametra predpostavlja, da tudi v primeru, ko bosta obe akciji uspešno odigrani, v enem izmed desetih primerov časovna usklajenost med tema dvema akcijama ne bo ustrezna. V primeru ko bi bila ena akcija slabo izvedena, je verjetnost za uspešno časovno relacijo zgolj še 0.5, v primeru, ko bi bili obe akciji slabo izvedeni pa zgolj še 0.1.

Da bi podrobneje preučili vpliv izbranih parametrov na ocene aktivnosti, smo izvedli niz eksperimentov, v katerih smo ocenjevali isto aktivnost z različnimi vrednostmi zgornjih parametrov. Tako smo v vsakem izmed eksperimentov spreminjali enega izmed parametrov a priori ali pogojskih verjetnosti ($p(x = da|y = da)$) od vrednosti 0.05 do vrednosti 1 po korakih po 0.05 in opazovali, kako tako določeni parametri vplivajo na končno oceno aktivnosti. Ker smo želeli preučiti, kako se ocena aktivnosti odziva na spremembo parametra pri različnem številu opaženih akcij, smo število opaženih akcij spreminjali od 1 (nobena akcija ni bila opažena) do 6 (vse akcije so bile opažene), v drugem primeru pa smo isti eksperiment ponovili za časovne relacije. Rezultati eksperimentov so prikazani na slikah 5.5 in 5.6.

Kot je razvidno iz rezultatov, je pravilna izbira parametrov zelo pomembna. Tako lahko na primer pri določanju a priori verjetnosti za aktivnost (slika 5.5-a in slika 5.6-a) v primeru napačne izbire tega parametra bistveno vplivamo na končni rezultat ocene aktivnosti. V skrajnem primeru, ko za ta parameter izberemo vrednost $p(aktivnost = da) = 1$, sama ocena aktivnosti sploh ni več odvisna od opaženih dejstev in je enaka ne glede na to, kaj se dogaja na igrišču.


Pri izbiri pogojske verjetnosti $p(igralec|aktivnost)$ (slika 5.5-b in slika 5.6-b) lahko ugotovimo, da je ustrezna izbira tega parametra med 0.3 in 1, saj bi

vrednosti pod 0.3 pomenile, da je bilo za skupno oceno aktivnosti bolje, da je igralec svojo vlogo znotraj aktivnosti odigral slabo. Ker je končna ocena aktivnosti normirana z vrednostjo maksimalne možne ocene za aktivnost pri danih parametrih, to pomeni, da je vrednost končne ocene večja od 1 oziroma večja od 100% kar seveda ni mogoče. Pri tem je bolje, da se izbrana vrednost parametra $p(\text{igralec}|\text{aktivnost})$ nahaja bližje vrednosti 1, saj to pomeni, da je vloga posameznega igralca bolj izražena v skupni oceni izvedbe aktivnosti.



Slika 5.5: Vpliv vrednosti parametrov na končno oceno aktivnosti v primeru različnega števila opaženih akcij. Zelena vertikalna črta prikazuje izbrano vrednost parametra. a) Odvisnost končnega rezultata od a priori verjetnosti za aktivnost $p(\text{aktivnost} = \text{da})$. b) Odvisnost končnega rezultata od pogojne verjetnosti $p(\text{igralec} = \text{da} | \text{aktivnost} = \text{da})$. c) Odvisnost končnega rezultata od pogojne verjetnosti $p(\text{akcija} | \text{igralec})$. d) Odvisnost končnega rezultata od pogojne verjetnosti $p(\text{cas} | \text{akcija})$.

Podoben zaključek lahko naredimo tudi na pogojne verjetnosti $p(akcija|igralec)$ (slika 5.5-c in 5.6-c) in $p(cas|akcija)$ (slika 5.5-d in 5.6-d), kjer prav tako lahko ugotovimo, da bi skrajne vrednosti parametrov pomenile zelo velik vpliv posamezne akcije oziroma relacije na skupno oceno aktivnosti. Poleg tega lahko ugotovimo, da ima spreminjanje parametra $p(akcija|igralec)$ zelo majhen vpliv na skupno oceno v primeru, da se spreminja število opaženih časovnih relacij (slika 5.6-c), saj se vrednost ocene s spreminjanjem vrednosti parametra praktično ne spremeni in je odvisna zgolj od števila opaženih relacij. Do istega zaključka lahko pridemo tudi pri opazovanju vpliva parametra $p(cas|akcija)$ na skupno oceno v primeru spreminja števila opaženih akcij (slika 5.6-c), saj se tudi v tem primeru izkaže, da je vpliv tega parametra praktično zanemarljiv. Dobljeni rezultati in na podlagi njih dobljeni zaključki so skladni z našimi pričakovanji in so posledica hierarhično zasnovane strukture Bayesove mreže.



Slika 5.6: Vpliv vrednosti parametrov na oceno aktivnosti v primeru različnega števila opaženih časovnih relacij. Zelena, vertikalna črta prikazuje izbrano vrednost parametra. a) Odvisnost končnega rezultata od a priori verjetnosti za aktivnost $p(\text{aktivnost} = da)$. b) Odvisnost končnega rezultata od pogojne verjetnosti $p(\text{igralec} = da | \text{aktivnost} = da)$. c) Odvisnost končnega rezultata od pogojne verjetnosti $p(\text{akcija} = da | \text{igralec} = da)$. d) Odvisnost končnega rezultata od pogojne verjetnosti $p(\text{cas} = da | \text{akcija} = da)$.

5.3 Uporaba Petrijevih mrež za ocenjevanje aktivnosti


Petrijeve mreže [81, 82, 83] so se v preteklosti, zaradi možnosti lepega formalističnega zapisa in nazornega grafičnega prikaza, izkazale kot zelo uporabno orodje pri razpoznavanju strukturiranih aktivnosti [40, 41, 42], modeliranju znanjem podprti časovno zahtevnih procesov [84, 85, 86]. Še posebej so se izkazale uporabne za:

- modeliranje zaporednih in istočasnih dogodkov in njihove časovne usklajenosti,
- obravnavanje večjega števila različnih scenarijev z uporabo iste mreže,
- modeliranje hierarhične strukture aktivnosti in
- modeliranje determinističnih in stohastičnih modelov za sklepanje o opazovanih dogodkih.

V postopku ocenjevanja ustreznosti izvedbe aktivnosti zgradimo Petrijevo mrežo avtomatsko na podlagi upoštevanja že opisanih časovnih relacij. Pri tem mrežo uporabimo za modeliranje časovnih in logičnih relacij med posameznimi akcijami. Torej skušamo s Petrijevo mrežo modelirati časovno-taktične lastnosti aktivnosti, med tem ko za ocenjevanje njenih tehničnih lastnosti, podobno kot v primeru uporabe Bayesove mreže, uporabljamo na trajektorijah temelječe detektorje akcij. Postopek gradnje Petrijeve mreže je sestavljen iz dveh korakov:

1. V prvem koraku zgradimo dele mreže, ki predstavljajo posamezne akcije. Tako lahko akcije predstavimo kot različno dolge verige mest in prehodov, s katerimi lahko modeliramo različne koncepte razpoznavanja in ocenjevanja akcij.
2. V drugem koraku z uporabo znanja o časovnih relacijah med akcijami povežemo posamezne verige v skupno mrežo.

Na podlagi predhodno razvitih ontologij, ki sta jih v svojih delih predstavila Ghanem et.al [42] and Lavee et al. [41], lahko akcijo predstavimo kot verigo treh ali petih elementov (slika 5.7).




Slika 5.7: Primer verig za modeliranje posameznih akcij. a) Veriga sestavljena iz treh elementov (dveh mest in enega prehoda) b) Veriga sestavljena iz petih elementov (treh mest in dveh prehodov).

Pri prvem pristopu modeliramo akcijo kot trenuten dogodek, pri tem pa opazujemo zgolj, ali je bila ta akcija izvedena oziroma opažena ali ne. V drugem primeru [41] pa modeliramo akcijo kot dogodek, ki ima svoj začetek, trajanje in konec. V tem primeru je pri ocenjevanju izvedbe aktivnosti potrebno za vsako od akcij detektirati njen začetek in konec izvajanja, kar pa se zaradi dolžine posamezne akcije ter različnih dejavnikov, ki vplivajo na odziv detektorja, izkaže za precej težavno. V odzivu detektorja akcije so namreč prisotne napake, ki nastanejo v procesu sledenja, pa tudi napake, ki so posledica načina detektiranja teh akcij, saj je model detektorja zgolj nek približek idealnega modela. Zaradi tega lahko pride do velikih razlik pri opaženih začetkih in koncih istih akcij pri različnih ponovitvah enake aktivnosti. Posledično je tovrsten način modeliranja akcij precej neuporabnen, saj so začetki in konci akcij v primerjavi z uteženo srednjo vrednostjo odziva detektorja bistveno manj stabilni.


Zaradi navedenih razlogov modeliramo posamezne akcije kot verigo treh elementov (slika 5.7-a). Prvi in tretji element sta mesti, ki ponazarjata, da so bili pogoji za akcijo izpolnjeni oziroma, da je bila akcija opažena. Drugi element pa je časovni prehod, ki ponazarja dejansko izvedbo akcije. V primeru, da pride do proženja prehoda, se žeton prenese iz vhodnega mesta, ki predstavlja pogoje za akcijo, na izhodno mesto. Do proženja prehoda lahko pride v dveh primerih in sicer je proženje lahko posledica izpolnitve nekega logičnega stanja ali preteka določenega časa, v katerem je bil prehod omogočen. V prvem primeru je proženje posledica odziva detektorja akcije, zaradi česar sklepamo, da je prišlo do izvedbe te akcije. V drugem primeru pa je proženje posledica prekoračitve maksimalnega časa, v katerem naj bi bila akcija izvedena. Podrobnejši opis mehanizma proženja prehodov in določanja maksimalnih časov akcij je podan v poglavju 5.3.1.

Po tem, ko so zgrajene verige za posamezne akcije, je potrebno te verige povezati v končno mrežo, ki jo lahko uporabimo za ocenjevanje izvedbe aktivnosti (slika 5.8). V ta namen v mrežo dodamo logične *razvejitvene* (ang. *split*) in *združitvene* (ang. *join*) prehode (sivi prehodi na sliki 5.8), ki jih z verigami povežemo na tak način, da upoštevamo časovne zakonitosti, ki jih dobimo iz časovnega profila aktivnosti (poglavje 5.1). Logični prehodi in njihove povezave služijo pravilnemu prehajanju žetonov skozi mrežo in so v mrežo dodani na tak način, da preprečimo morebitne zastoje v mreži ter konflikte med različnimi verigami. Poleg tega pa pri povezovanju logičnih prehodov pazimo tudi na to, da so vse verige dostopne iz začetne označitve.



Slika 5.8: Petrijeva mreža za aktivnost "Zaporedni blokadi". Črne pike znotraj mest predstavljajo trenutno označitev mreže. Številke nad žetoni predstavljajo oceno izvedbe akcije do danega trenutka. Črno obarvani pravokotniki predstavljajo že opažene akcije, prazni še neopažene akcije, sivi pa predstavljajo logične - povezovalne prehode mreže.

Poleg logičnih povezav dodamo v mrežo tudi dve navidezni (ang. *dummy*) mesti, ki predstavljata začetek in konec aktivnosti. Ti dve mesti služita predvsem pravilnemu delovanju mreže. Tako je namen začetnega mesta predvsem, da žetoni pravilno preidejo v začetne verige, medtem ko je naloga končnega prehoda ta, da združi žetone, ki se pojavijo v posameznih nitih (ang. *threads*) mreže, spet v en skupen žeton. Poleg tega bi lahko ti dve mesti uporabili tudi v primeru, da bi želeli neko aktivnost istočasno ocenjevati z večjim številom šablon, saj bi lahko posamezne modele aktivnosti s temi mesti združili v eno skupno mrežo (slika 5.9).




Slika 5.9: *Primer povezovanja večjega števila šablon v skupno mrežo.*

5.3.1 Določanje časovnih parametrov mreže

Po tem, ko je struktura mreže ustrezno definirana, je potrebno določiti tudi njene parametre, s čimer omogočimo njeno pravilno delovanje. V našem primeru to pomeni, da je potrebno določiti pogoje, pri katerih lahko pride do proženja posameznih prehodov. Kot je že bilo omenjeno, lahko pride do proženja posameznega prehoda zaradi dveh razlogov. Prvi razlog je, da je bila akcija opažena, drugi pa, da je potekel čas, v katerem naj bi bila akcija opažena.

V prvem primeru je proženje prehoda doseženo na podlagi odziva detektorja akcije, ki so bili opisani v poglavju 4.1.2. Slika 5.10 prikazuje primer odziva detektorja gibanja na gibanje igralca po igrišču. Čas proženja detektorja je določen kot utežena srednja vrednost časa, ko je odziv detektorja nad določeno mejno vrednostjo. V našem primeru je bila ta mejna vrednost določena z vrednostjo 0.5 (slika 5.10).


V drugem primeru, ko akcija ni bila opažena, pa pride do časovnega proženja prehoda, zaradi prekoračitve maksimalnega časa, v katerem naj bi se akcija zgodila. V ta namen je potrebno za vsako posamezno akcijo, ki sestavlja določeno aktivnost, določiti njen maksimalni čas trajanja. V primeru, da nimamo na voljo učnih vzorcev, na podlagi katerih bi lahko te čase izmerili, lahko določimo enak čas trajanja vseh akcij. Natančnejšo predstavitev dejanskih časov lahko dobimo v primeru, da upoštevamo relativne čase posameznih akcij v šabloni. Na podlagi teh časov lahko proporcionalno razdelimo celoten čas trajanja aktivnosti med posamezne akcije.



Slika 5.10: Primer odziva detektorja na gibanje igralca. a) Gibanje igralca po igrišču. Odebeljena črna črta predstavlja trajektorijo gibanja igralca, tanjša rdeča črta pa predstavlja predvideno pot igralca. b) Odziv detektorja na gibanje. Zelena vertikalna črta predstavlja čas proženja prehoda, ki je določen kot utežena srednja vrednost odziva detektorja nad mejno vrednostjo.

V primerih, ko imamo na voljo vsaj nekaj učnih vzorcev, v katerih je bila aktivnost pravilno odigrana, pa lahko čase trajanja posamezne akcije določimo neposredno iz teh vzorcev. To dosežemo tako, da učne vzorce analiziramo z ustreznim modelom Petrijeve mreže, pri katerem postavimo maksimalne čase proženja prehodov na zelo visoke vrednosti, tako da ne vplivajo na delovanje mreže (npr. 6 sekund) ter opazujemo, kdaj pride do proženja prehoda zaradi odziva detektorja. V primeru, da do odziva ne pride, tega rezultata v nadaljnjih postopkih ne upoštevamo. Na podlagi dobljenih časov proženja lahko za vsak prehod zgradimo ločen časovni model tako, da dobljene podatke modeliramo z ustrezno verjetnostno porazdelitvijo, ki jo pozneje uporabimo tudi pri ocenjevanju časovne ustreznosti izvajanja aktivnosti (poglavje 5.3.2). V naših raziskavah sta bili za modeliranje časovnih intervalov uporabljena normirana Gamma in normirana Gaussova porazdelitev. Zaradi majhne količine podatkov in boljše porazdelitve preko vseh učnih vzorcev, se je za bolj primerno izkazala normirana Gaussova porazdelitev, ki smo jo uporabljali pri vseh v nadaljevanju opisanih eksperimentih. V primeru uporabe te funkcije je bil maksimalni čas T_{max}^j v katerem mora biti aktivnost opažena, določen na meji ene standardne deviacije porazdelitve ($T_{max}^j = \mu_j + \sigma_j$). Slika 5.11 prikazuje nekaj primerov funkcij verjetnostnih porazdelitev trajanja akcij ter njihovih maksimalnih časov trajanja.

S tem, ko so bili določeni tudi časovni parametri prehodov, je model Petrijeve mreže popolnoma definiran in je lahko uporabljen za ocenjevanje aktivnosti. Še



Slika 5.11: Štirje različni časovni modeli predstavljeni z normiranimi Gaussovimi porazdelitvenimi funkcijami. Črne zvezdice predstavljajo čase proženja za posamezne učne vzorce. Rdeča vertikalna črta predstavlja maksimalni čas trajanja posamezne akcije.

pred tem pa je potrebno definirati mehanizem ocenjevanja izvedbe aktivnosti, ki je uporabljen za to, da dobimo skupno oceno o tem, kako uspešno je bila aktivnost izvedena.

5.3.2 Mehanizem ocenjevanja izvedbe aktivnosti

Pri snovanju mehanizma ocenjevanja je bila uporabljena glavna ideja Barvnih Petrijevih mrež (ang. *Colored Petri nets*) [81], pri katerih so žetoni uporabljeni kot nosilci neke dodatne informacije o predmetu ali stanju, ki ga ti žetoni v mreži predstavljajo. Tako lahko na primer pri modeliranju industrijske linije za izdelavo

avtomobila žetoni nosijo informacijo o barvi avtomobila, vgrajenem tipu motorja in drugih podatkih, ki so povezani s samim procesom izdelave.

V našem primeru so žetoni uporabljeni za zbiranje informacije o tem, kako dobro je bila aktivnost izvedena. To oceno imenujemo *ocena aktivnosti*. Žetoni pri prehajanju skozi mrežo zbirajo ocene posameznih akcij, celotna ocena pa je na končnem mestu prikazana kot seštevek delnih ocen. Delne ocene so sestavljene iz informacije o tehnični izvedbi akcije (S) ter njeni časovni ustreznosti v okviru opazovane aktivnosti (T). Celotna ocena aktivnosti se na novo preračuna po vsakem proženju prehoda. Pri tem se ocena za žeton, ki preide skozi prožen prehod, izračuna kot

$$X_{nova}^i = X_{stara}^i + S_j \cdot T_j, \quad (5.11)$$

kjer je S_j maksimalni odziv detektorja za akcijo j , T_j je ocena časovne ustreznosti opažene akcije in X_{stara}^i je predhodna ocena aktivnosti na žetonu i , ki prehaja skozi prehod j . Ocena časovne ustreznosti akcije je dobljena iz časovne porazdelitve, ki je bila opisana v prejšnjem poglavju in je definiran kot

$$T_j = \begin{cases} e^{-\frac{\mu_j^2}{2 \cdot \sigma_j^2}} & ; \quad t_j < 0 \\ e^{-\frac{(\mu_j - t_j)^2}{2 \cdot \sigma_j^2}} & ; \quad 0 < t_j < T_{max}^j \\ 0 & ; \quad t_j > T_{max}^j \end{cases}, \quad (5.12)$$

kjer je t_j čas, v katerem je bil prehod j omogočen, μ_j in σ_j sta srednja vrednost in standardna odklon časovne porazdelitve in T_{max}^j je maksimalni čas, v katerem bi morala biti j -ta akcija opažena. V primeru, da v tem času akcija ni bila opažena, pride do časovnega proženja prehoda, zaradi česar je ocena izvedbe akcije enaka 0.

Logični *razveji* in *združi* prehodi skrbijo za prenašanje in zbiranje informacije, ki jo prenašajo žetoni. V primeru, da pride do združevanja žetonov z uporabo logičnega prehoda *združi*, pri čemer se n žetonov združi v en skupen žeton, je ocena na združenem žetonu (X_{nova}^{i+1}) določena kot vsota vseh ocen žetonov (X_{stara}^i), ki vstopajo v logični prehod

$$X_{nova}^{i+1} = \sum_{i=1}^n X_{stara}^i. \quad (5.13)$$

V primeru proženja logičnega prehoda *razveji* pa se celotna ocena pripiše enemu od na novo nastalih žetonov.

Ker je maksimalna možna ocena aktivnosti pri različnih mrežah različna in je odvisna od števila akcij, ki jih mora ekipa odigrati, so končne ocene aktivnosti normirane s številom akcij v šabloni. Takšna normalizacija nam omogoča, da lahko pri ocenjevanju posamezne aktivnosti primerjamo ocene za različne šablone.

5.4 Eksperimenti

Za preizkus predlaganih postopkov ocenjevanja organiziranih košarkarskih aktivnosti smo z uporabo metod računalniškega vida, ki so bile opisane v poglavju 2.2, pridobili dve testni zbirki aktivnosti.

Prva zbirka je bila sestavljena iz 61 testnih primerov treh različnih košarkarskih aktivnosti, katerih struktura je že bila podrobneje opisane v eksperimentalnem delu prejšnjega poglavja (poglavju 4.3). Druga zbirka podatkov pa je bila sestavljena iz 40 ponovitev ene aktivnosti, pri čemer so bile posamezne ponovitve odigrane do različnih faz izvedbe. Tako se je na primer prvih 10 aktivnosti (v nadaljevanju jih označujemo kot Slovan1) zaključilo kmalu po začetku izvajanja, medtem ko je bilo zadnjih 10 (Slovan4) odigranih v celoti. V vsakem izmed desetih primerov je bilo prvih pet aktivnosti odigranih brez obrambe, drugih pet pa proti pasivni obrambi.

Za vsako vrsto aktivnosti smo izdelali ustrezno šablono, poleg tega pa smo uporabili še dodatnih 14 šablon, ki smo jih pridobili iz literature in so nam služile za primerjavo rezultatov. Na podlagi šablon je bilo z zgornjim postopkom zgrajenih 21 Bayesovih mrež ter 7 Petrijevih mrež, za katere smo imeli na voljo učne podatke. V primeru Petrijevih mrež ostalih šablon nismo uporabljali, saj za te šablone ni bilo mogoče določiti časovnih intervalov na enak način kot za šablone, za katere so učni podatki bili na voljo. Zaradi tega smo se odločili, da teh šablon ne bomo uporabljali.

Ker postopek zahteva, da je korespondenca med vlogami igralcev v testnih podatkih in vlogami v šablonah poznana, smo pred vsakim postopkom ocenjevanja izvedli postopek za določanje korespondence med vlogami, ki je opisan v poglavju 4.2.1. Poleg tega, smo pri gradnji časovnih porazdelitev za

posamezne akcije, ki jih potrebujemo pri ocenjevanju aktivnosti s Petrijevo mrežo, pred vsakim testiranjem iz učne množice odstarnili vzorec, ki smo ga testirali.

Namen opravljenih eksperimentov je bil ugotoviti, ali je z opisanima postopkoma ocenjevanja aktivnosti mogoče oceniti, če je bila aktivnost izvedena v skladu s predpisano šablono. Pri tem smo predpostavili, da morajo biti aktivnosti, ki ustrezajo šabloni, ocenjene bistveno bolje od tistih, ki šabloni ne ustrezajo. Poleg ocene pa smo želeli ugotoviti, ali je mogoče pravilno določiti tudi fazo oziroma stopnjo, do katere je bila posamezna aktivnost odigrana.

Za eksperimentalno validacijo ocenjevanja aktivnosti z Bayesovimi mrežami je bilo uporabljeno orodje, ki ga je razvil Kevin Murphy [87], pri ocenjevanju z uporabo Petrijevih mrež pa je bilo uporabljeno orodje, ki so ga razvili Mušič in drugi [88].

5.4.1 Eksperiment 1: Ocenjevanje z uporabo Bayesove mreže

Tabela 5.4.1 prikazuje povprečne ocene za posamezno vrsto aktivnosti pri uporabi metode Bayesovih mrež. Ker so bile pri testiranju uporabljene zelo dobro in nekoliko slabše izvedene aktivnosti, so rezultati predstavljeni s povprečno oceno, poleg tega pa so na dnu tabele predstavljene tudi minimalne ocene za primere, ko sta bili aktivnost in šablona istega tipa ter maksimalne ocene za primere, ko sta se tip šablone in aktivnosti razlikovala. Pri določanju maksimalne vrednosti napačne ocene za aktivnosti tipa "Slovan" ocen za aktivnosti tega tipa bile upoštevane, saj gre za isto aktivnost z različno dolžino izvedbe. Ocena aktivnosti je bila podana kot normirana *a posteriori* verjetnost, da je bila aktivnost uspešno odigrana $p_{norm}(akcija_i = da|e)$. Ocena se lahko giblje v intervalu $[0 \dots 1]$, pri čemer ocena 1 predstavlja aktivnost, ki je bila izvedena idealno.

Na podlagi rezultatov v tabeli 5.4.1 lahko zaključimo, da je z uporabo nabora mrež, ki predstavljajo različne tipe aktivnosti, mogoče določiti, kakšno vrsto aktivnosti je ekipa odigrala. Kot lahko vidimo, je v primeru, ko se tip odigrane aktivnosti in tip šablone ujemata, povprečna ocena aktivnosti kar trikrat višja kot v nasprotnem primeru. Prav takšen zaključek bi bilo možno narediti tudi ob pogledu minimalnih in maksimalnih vrednosti ocen, kjer lahko ugotovimo, da je bila pozitivno ocenjena zgolj ena aktivnost, ki ni ustrezala šabloni pa še v tem primeru je bila ocena te aktivnosti komajda pozitivna (z vrednostjo 0.54). Iz


Tip šablone	Ocene aktivnosti [%]						
	52	flex	motion	slovan1	slovan2	slovan3	slovan4
52	0.89	0.17	0.045	0.01	0.02	0.03	0.11
flex	0.11	0.87	0.03	0.29	0.32	0.08	0.17
motion	0.02	0.02	0.91	0.00	0.00	0.14	0.16
slovan1	0.11	0.08	0.22	0.99	0.91	0.80	0.81
slovan2	0.04	0.06	0.14	0.78	0.95	0.80	0.71
slovan3	0.01	0.02	0.10	0.24	0.49	0.97	0.92
slovan4	0.01	0.01	0.01	0.02	0.12	0.64	0.96
atlanta	0.12	0.33	0.08	0.04	0.06	0.12	0.17
california	0.06	0.02	0.02	0.00	0.00	0.03	0.06
double	0.05	0.11	0.16	0.01	0.01	0.04	0.06
fist	0.03	0.04	0.22	0.00	0.00	0.02	0.10
five	0.16	0.15	0.13	0.15	0.14	0.14	0.32
greenville	0.07	0.08	0.17	0.01	0.01	0.01	0.15
indiana	0.03	0.09	0.04	0.00	0.00	0.01	0.09
jacksonville	0.02	0.03	0.04	0.03	0.04	0.02	0.08
jersey	0.09	0.28	0.04	0.09	0.11	0.16	0.28
middle	0.011	0.06	0.06	0.02	0.02	0.04	0.16
russellRight	0.05	0.03	0.03	0.07	0.02	0.09	0.10
transition	0.18	0.11	0.02	0.01	0.02	0.03	0.07
turnover	0.13	0.09	0.05	0.01	0.01	0.09	0.11
ucla	0.19	0.10	0.04	0.01	0.01	0.04	0.011
Min. enaka	0.76	0.72	0.74	0.97	0.80	0.89	0.92
Max. različna	0.34	0.54	0.38	0.20	0.23	0.42	0.49

Tabela 5.5: Povprečna ocena, izražena v obliki normirane a posteriori verjetnosti $p_{norm}(\text{aktivnost} = da|e)$. Najboljša povprečna ocena za posamezno vrsto aktivnosti je prikazana odebeljeno. Spodnji dve vrstici prikazujeta minimalno oceno aktivnosti za primer, ko sta bili aktivnost in šablona istega tipa in maksimalno oceno v primerih, ko sta se razlikovali.

tega lahko zaključimo, da je predlagano metodo mogoče uporabiti za ocenjevanje uspešnosti izvedbe aktivnosti.

Druga pomembna informacija, ki jo poleg ocene izvedbe aktivnosti lahko pridobimo iz mreže, je informacija o tem, koliko so k skupni oceni prispevali posamezni igralci oziroma kateri izmed igralcev je svojo vlogo odigral najboljše in kateri najslabše. Slika 5.12 prikazuje Bayesovo mrežo za aktivnost tipa "Flex", ki je bila slabše izvedena.


Ob podrobni preučitvi mreže lahko ugotovimo, da nosita največji delež krivde za slabše odigran napad drugi in peti igralec (p2 in p5), ki sta za svojo igro dobila najslabše ocene. Prav tako lahko ugotovimo, da je bil vzrok za njuno zelo nizko oceno ta, da nista odigrala zadnje blokade (BLOK 5-2), poleg tega pa drugi igralec ni izvedel še ene blokade (BLOK 1-2).



Slika 5.12: Primer Bayesove mreže za aktivnost vrste "Flex", ki je bila slabše izvedena. Iz mreže je možno ugotoviti, da sta igralec 2 in igralec 5 svoje akcije slabo odigrala.

5.4.2 Eksperiment 2: Ocenjevanje z uporabo Petrijevih mrež

Tabela 5.6 prikazuje povprečne ocene aktivnosti v primeru ocenjevanja s Petrijevimi prežami. Primere mrež, ki so bile uporabljene pri ocenjevanju, prikazuje slika 5.13.




Slika 5.13: Primera Petrijevih mrež, ki sta bili uporabljene pri ocenjevanju aktivnosti. Temnejši (rdeči) prehodi označujejo že opažene aktivnosti. a) Model Petrijeve mreže za aktivnost "Slovan1". b) Model Petrijeve mreže za aktivnost "Flex".

Kot je razvidno iz tabele 5.6, so bile najboljše povprečne ocene aktivnosti dobljene v primeru, ko sta se ujemala tako tip aktivnosti, kot tudi faza, do katere je bila aktivnost izvedena. Prav tako lahko ugotovimo, da dobimo tudi v primeru, ko se faza aktivnosti in faza šablone ne ujemata, boljše ocene v

Vrsta šablone	Vrsta aktivnosti						
	52	flex	motion	Slovan1	Slovan2	Slovan3	Slovan4
52	0.55	0.15	0.17	0.09	0.10	0.18	0.16
flex	0.22	0.33	0.18	0.03	0.05	0.19	0.23
motion	0.15	0.20	0.40	0.06	0.04	0.16	0.13
Slovan1	0.13	0.04	0.03	0.83	0.51	0.44	0.51
Slovan2	0.05	0.05	0.14	0.51	0.77	0.50	0.52
Slovan3	0.10	0.13	0.16	0.32	0.32	0.72	0.55
Slovan4	0.12	0.15	0.18	0.20	0.20	0.48	0.65

Tabela 5.6: *Povprečne ocene aktivnosti v primeru ocenjevanja s Petrijevim prežami, ki so bile zgrajene z različnimi šablonami. Najvišji povprečni rezultat je prikazan odebeljeno.*

primerih, ko se ujemata vsaj tipa aktivnosti. Tako so na primer ocene za aktivnost "Slovan1" v primeru, da je ocenjen s šablono "Slovan2", "Slovan3" ali "Slovan4" bistveno boljše, kot v primeru, da je ocenjen s šablono "Flex". Na podlagi tega lahko zaključimo, da je predlagana metoda zelo robustna tudi v primeru, ko ocenjujemo aktivnost, ki je bila zaključena prezgodaj ali prepozno. Poleg tega lahko ugotovimo, da so ocene višje v primerih, da so razlike med fazo šablone in fazo opazovane aktivnosti manjše. Na podlagi te ugotovitve lahko zaključimo, da je mogoče ob uporabi večjega števila šablon, ki predstavljajo isto izvedbo aktivnosti odigrane do različnih faz, pravilno določiti fazo, do katere je bila aktivnost odigrana. Slika 5.14 prikazuje ocene vseh aktivnosti iz druge zbirke v primeru, ko so bile ocenjene z najdaljšo šablono - šablono "Slovan4". Iz slike je lepo razvidno, kako se rezultati izboljšujejo v primeru, ko se razlika med fazama šablone in aktivnosti zmanjšuje.



Slika 5.14: Rezultati ocejavanja iste aktivnosti z različnimi fazami zaključkov. Aktivnosti so bile ocenjene s šablono Slovan4. Imena na grafu predstavljajo fazo, do katere je bila aktivnost odigrana.

5.4.3 Primerjava dobljenih rezultatov z ocenami eksperta

Glavni namen analize aktivnosti je objektivno ocenjevanje teh aktivnosti, ki bi služilo kot pomoč športnemu ekspertu pri njegovem delu. V določenih segmentih bi sistem eksperta lahko celo nadomestil. Da bi se v to lahko prepričali, je najprej potrebno primerjati dobljene rezultate avtomatskega ocenjevanja z ocenami eksperta. Tovrstna primerjava pa se kmalu izkaže za problematično oziroma zelo težavno iz več razlogov.

Prvi razlog je ta, da je ocenjevanje športnih ekspertov do neke mere nekonsistentno, kar se je pokazalo že pri ocenjevanju enega samega eksperta. Tako smo v razmiku nekaj mesecev prosili košarkarskega eksperta, da oceni določeno število akcij z ocenami od ena do pet, pri čemer je ocena ena pomenila zelo slabo izvedbo akcije, ocena pet pa njeno odlično izvedbo. Kmalu se je izkazalo, da se ocene, dobljene v obeh ocenjevanjih razlikujejo, saj se je ocena razlikovala (največ za eno oceno) pri 18 od 40 ponovno ocenjenih aktivnostih (tabela 5.8). Ravno tako smo ugotovili, da je bila večina aktivnosti ocenjenih z ocenami 4 ali 5, kar je kazalo na to, da nimamo na voljo neuspešno zaključenih primerov aktivnosti, saj se za tovrstne aktivnosti smatrajo tiste aktivnosti, pri katerih se je struktura napada porušila ali je eden od igralcev storil večjo napako, zaradi česar se aktivnost ni nadaljevala. Tako so dobljene ocene po mnenju eksperta odražale predvsem minimalne razlike v izvedbi posameznih aktivnosti, v splošnem pa so bile vse aktivnosti izvedene pravilno.

Navkljub navedenim težavam, so v tabeli 5.8 prikazani rezultati avtomatskega ocenjevanja aktivnosti in ocene eksperta. Pri kvantizaciji ocen, ki so bile pridobljene avtomatsko, smo za pretvorbo ocen v razrede uporabili linearni skali (tabela 5.7). V primeru, da bi imeli na voljo več znanja o ocenjevanju ekspertov (npr. več ocenjevanj), pa bi lahko razrede postavili v skladu s tem znanjem.

ocena	Bayesove mreže	Petrijeve mreže
1	≤ 0.59	≤ 0.19
2	0.60 - 0.69	0.20 - 0.39
3	0.70 - 0.79	0.40 - 0.59
4	0.80 - 0.89	0.60 - 0.79
5	0.90 - 1.00	0.80 - 1.00

Tabela 5.7: Mejne vrednosti ocen, ki so bile uporabljene pri kvantizaciji.

aktivnost	Ocena eksp. 1	Ocena eksp. 2	Bayesove mreže	Petrijeve mreže
S1-1	4	4	5 (0.99)	5 (0.91)
S1-2	3	4	5 (0.98)	5 (0.91)
S1-3	5	5	5 (0.99)	5 (0.88)
S1-4	5	5	5 (1.00)	5 (0.91)
S1-5	3	4	5 (0.99)	5 (0.93)
S1-6	3	4	5 (0.98)	4 (0.72)
S1-7	4	5	5 (0.99)	4 (0.75)
S1-8	5	4	5 (0.97)	4 (0.65)
S1-9	4	5	5 (0.98)	4 (0.77)
S1-10	5	5	5 (0.97)	5 (0.82)
S2-1	4	5	5 (0.98)	5 (0.81)
S2-2	5	4	5 (0.98)	4 (0.77)
S2-3	5	5	5 (0.98)	4 (0.77)
S2-4	4	5	5 (0.97)	5 (0.81)
S2-5	4	4	5 (0.92)	4 (0.77)
S2-6	4	4	5 (0.98)	4 (0.79)
S2-7	5	4	5 (0.95)	4 (0.71)
S2-8	4	5	5 (0.97)	4 (0.75)
S2-9	4	4	5 (0.98)	4 (0.69)
S2-10	5	4	4 (0.80)	4 (0.78)
S3-1	4	5	5 (0.99)	4 (0.73)
S3-2	3	4	5 (0.99)	4 (0.67)
S3-3	4	3	5 (0.97)	4 (0.66)
S3-4	4	4	5 (0.99)	4 (0.64)
S3-5	5	5	5 (0.99)	4 (0.79)
S3-6	4	3	5 (0.94)	4 (0.70)
S3-7	5	4	5 (0.98)	4 (0.65)
S3-8	4	4	5 (0.99)	4 (0.75)
S3-9	4	4	5 (0.96)	4 (0.76)
S3-10	4	5	4 (0.89)	4 (0.77)
S4-1	4	5	5 (0.99)	4 (0.65)
S4-2	5	4	5 (0.94)	4 (0.60)
S4-3	5	4	5 (0.98)	4 (0.68)
S4-4	4	3	5 (0.98)	3 (0.59)
S4-5	5	5	5 (0.93)	4 (0.62)
S4-6	5	5	5 (0.96)	5 (0.87)
S4-7	4	4	5 (0.92)	5 (0.84)
S4-8	4	4	5 (0.98)	4 (0.72)
S4-9	5	5	5 (0.99)	5 (0.85)
S4-10	4	4	5 (0.98)	4 (0.68)

Tabela 5.8: Primerjava ocen eksperta in ocen, pridobljenih z opisanima metodama. Prva dva stolpca predstavljata prvo in drugo ocenjevanje eksperta. Tretji in četrti stolpec predstavljata avtomatsko pridobljene ocene. Odebeljene ocene predstavljajo primere, v katerih avtomatično pridobljena ocena ustreza vsaj eni izmed obeh ocen eksperta.

Kot je razvidno iz tabele 5.8, rezultati, dobljeni z predlaganima postopkoma v večji meri odražajo mnenje eksperta, saj so ocene, ki so bile dobljene z avtomatskima postopkoma ocenjevanja, precej podobne ocenam eksperta. Pri tem se za nekoliko boljše izkaže metoda, ki temelji na Petrijevih mrežah, saj v tem primeru dobljeni rezultati kar v 83% primerov (33 od 40 primerov) ustrezajo eni od ocen eksperta. V primeru metode, ki temelji na Bayesovih mrežah je takšnih zgolj 57% procentov primerov (23 od 40 primerov). V primeru, da primerjamo ocene, dobljene z uporabo Petrijevih mrež s posameznimi ocenjevanji eksperta, pa je v primeru prvega ocenjevanja ujemanje ocen 40% v primeru drugega pa 60%. Pri uporabi Bayesove mreže je v prvem primeru ujemanje ocen 37.5%, v drugem pa 40%. Odstotek ujemanja se sicer na prvi pogled ne zdi visok, če pa dobljene odstotke primerjamo s ponovljivostjo eksperta, ki je zgolj 45% (18 od 40 primerov), lahko ugotovimo, da so dobljeni rezultati kar dobri. Tako lahko iz rezultatov zaključimo, da je metoda, ki temelji na Petrijevih mrežah, bistveno uspešnejša. Razlog za to je, da je pri metodi, ki temelji na Bayesovih mrežah, način ocenjevanja aktivnosti bistveno drugačen od načina ocenjevanja eksperta. Tako na primer ekspert pri ocenjevanju aktivnosti upošteva predvsem opažene napake, zaradi česar lahko že ena sama slabo izvedena akcija bistveno pokvari skupno oceno aktivnosti. V primeru Bayesove mreže je skupna ocena v bistvu neke vrste uteženo povprečje ocen posameznih akcij in časovnih funkcij. Ker je aktivnost običajno sestavljena iz precejšnjega števila akcij, posamezna slabo izvedena akcija v tem primeru ne vpliva bistveno na skupno oceno aktivnosti. Nekoliko drugačna je situacija v primeru uporabe Petrijevih mrež, kjer lahko že ena slabo odigrana akcija poruši časovno usklajenost aktivnosti, kar se bistveno bolj odrazi tudi v skupni oceni. Tako ni presenetljivo, da je bilo ocenjevanje s to metodo veliko uspešnejše oziroma bolj primerljivo z ocenjevanjem eksperta.

Vzroke za razlike med avtomatsko pridobljenimi ocenami in ocenami eksperta je potrebno iskati tudi v tem, da športni ekspert pri svojem ocenjevanju poleg gibanja igralcev upošteva še kup drugih dejavnikov, ki jih ni mogoče pridobiti iz podatkov o gibanju igralcev. Ključna sta predvsem dva:

- Prvi dejavnik je ta, da športni ekspert uspešnost izvedbe aktivnosti vedno ocenjuje po končnem rezultatu. Torej je ocena aktivnosti v primeru koša oziroma čistega meta na koš, višja kot v primeru, da koša oziroma meta na koš ni bilo. Pri tem se lahko v določenih primerih zgodi, da je celo bolje, da igralec predčasno zaključi oziroma prekine začeto aktivnost z metom na

koš ali prodorom proti košu, pri čemer bo za to dobil visoko oceno. Ker z opisanimi metodama ocenjujemo, *kaj se je zgodilo in ne kaj bi se lahko oziroma, kaj bi si želeli, da se zgodi*, lahko pride pri ocenjevanju do razlik.

- Drugi dejavnik, ki vpliva na oceno eksperta, pa je, da ekspert pri ocenjevanju tehničnih vidikov posamezne akcije te akcije ocenjuje na različnih nivojih podrobnosti. Na ta način upošteva še precej drugih dejavnikov, ki ji ni mogoče dobiti iz trajektorij gibanja igralcev. Tako na primer pri izvedbi podaje ekspert ocenjuje tudi to, ali je igralec, ki mu je bila podaja namenjena, pravilno obrnjen oziroma celo, ali je sploh videl, da bo do podaje prišlo. Tovrstne informacije iz trajektorij igralcev ni mogoče pridobiti.

Na podlagi tega lahko zaključimo, da je s predlaganimi postopkoma ocenjevanja sicer do neke mere možno pravilno oceniti izvedbo aktivnosti, saj je tudi v našem primeru za uspešno izvedeno aktivnost moštvo dobilo pozitivno oceno. Vendar pa tovrsten pristop in podatki, ki so nam bili na voljo, niso primereni za zelo poglobljeno tehnično-taktično analizo o dogajanju na igrišču, na način, kot to počnejo športni eksperti. Da bi to lahko dosegli, bi bilo v samo analizo potrebno vključiti bistveno več informacij o dogajanju na igrišču. Poleg tega je bistvo našega pristopa objektivno ocenjevanje tega, kar se je zgodilo in ne tega, kar bi bilo v dani situaciji za doseg koša optimalno. Tudi v tem primeru, bi za takšno ocenjevanje potrebovali več informacij o igri. To bi lahko storili bodisi v obliki dodatnih ročnih oznak o dogajanju na igrišču, kar je s stališča uporabnika manj primerno, ali s pomočjo dodatnih komplementarnih podatkov, ki bi bili pridobljeni iz drugih virov (npr. vizualna informacija o igralcih ali trajektorije žoge).

5.5 Zaključek

V tem poglavju sta bila predstavljena dva pristopa ocenjevanja aktivnosti z uporabo šablon aktivnosti. Po definiciji je aktivnost sestavljena iz večjega števila tehničnih elementov - akcij, ki so skupaj časovno povezane v neko koherentno taktično zamisel. Predstavljena pristopa ocenjevanja temeljita na predpostavki, da je mogoče z ocenjevanjem posameznih tehničnih elementov in časovne usklajenosti med njimi oceniti, kako uspešno je bila aktivnost izvedena.

V ta namen je bil v poglavju 5.1 opisan postopek, s pomočjo katerega je mogoče iz šablone aktivnosti zgraditi časovni profil aktivnosti ter določiti časovne relacije med posameznimi akcijami, ki predstavljajo časovno taktično zasnovo aktivnosti. V nadaljevanju so bili v poglavju 5.1.1 definirani na trajektorijah temelječi detektorji akcij, s katerimi je mogoče oceniti, kako tehnično uspešno je bila, s stališča vzorcev gibanja igralcev po igrišču, izvedena posamezna akcija. V našem delu smo se omejili na uporabo treh časovnih relacij med akcijami (*pred*, *med* in *sočasno*) ter na ocenjevanje treh košarkarskih akcij (*blokada*, *gibanje/premik igralca* in *podaje žoge*).

Za ocenjevanje taktičnega dela izvedbe aktivnosti sta bili razviti dve metodi ocenjevanja, ki temeljita na dveh različnih matematičnih formalizmi. V prvem primeru so bile za ocenjevanje ustreznosti izvedbe aktivnosti uporabljene Bayesove mreže, s pomočjo katerih v ocenjevalni proces vpeljemo hierarhično strukturo aktivnosti. Postopek gradnje mrež temelji na definiranju štirih različnih nivojev mreže - *aktivnost*, *igralec*, *akcija*, *časovne relacije med akcijami*, ki jih medsebojno povežemo ob upoštevanju časovno-logične zasnove aktivnosti, ki jo pridobimo iz časovnega profila. Za ocenjevanje časovnih relacij med posameznimi akcijami so bile definirane *časovne funkcije*, za ocenjevanje tehničnih lastnosti akcij pa *detektorji akcij*. Tako dobljena informacija je bila v obliki dokazov uporabljena na spodnjih dveh nivojih Bayesovih mrež. Skupna ocena aktivnosti in ocena uspešnosti posameznih igralcev je bila dobljena na podlagi prenašanja teh dokazov po mreži. Da bi zagotovili možnost primerjanja posameznih ocen igralcev, je bila končna ocena aktivnosti normirana z oceno, ki bi jo aktivnost dobila v primeru, da bi bila izvedena brezhibno. Tako je končna ocena aktivnosti izražena kot normirana *a posteriori* verjetnost za aktivnost ob danih dokazih.

V drugem primeru je bila za ocenjevanje taktičnega dela aktivnosti uporabljena Petrijeva mreža. V tem primeru je bila mreža zgrajena na takšen način, da so bile najprej za posamezne akcije zgrajene verige mest in prehodov, s katerimi smo predstavili posamezno akcijo. V nadaljevanju so bile, z upoštevanjem časovno-logičnih relacij med akcijami, te verige povezane z logičnimi *razveji* in *združi* prehodi v skupno mrežo. Za ocenjevanje posameznih akcij so bili tudi v tem primeru uporabljeni detektorji akcij. Posamezne ocene so bile v skupno oceno združene z uporabo žetonov, ki so poleg zbiranja informacije skrbeli tudi za simulacijo pravilnosti časovno-taktične zasnove akcije, na podlagi katere je bila pridobljena ocena časovne izvedbe posamezne akcije.

Ovrednotenje predlaganih metod smo izvedli na 61 vzorcih treh različnih košarkarskih aktivnosti in 40 vzorcih ene aktivnosti, ki je bila v posameznih ponovitvah zaključena v različnih fazah izvedbe. Ker nismo imeli na voljo slabo izvedenih aktivnosti, smo za pozitivne oziroma pravilno izvedene aktivnosti določili vse aktivnosti, ki so pripadale določeni šabloni, medtem ko so bile aktivnosti, ki so pripadale ostalim šablonam, določene za slabo izvedene. Rezultati so pokazali, da je mogoče s predlaganima metodama ocenjevanja pravilno oceniti izvedbo aktivnosti. V primeru uporabe večjega števila šablon za isto aktivnost pa je mogoče v večini primerov pravilno določiti tudi fazo, do katere je bila aktivnost izvedena. Pri tem se je za nekoliko uporabnejšo izkazala metoda z Bayesovimi mrežami, saj za uporabo te metode zadostuje zgolj šablona in ne potrebujemo učnih vzorcev.

Ob primerjavi dobljenih rezultatov z ocenami eksperta lahko ugotovimo, da je s predlaganima metodama mogoče dobiti ocene, ki v precejšnji meri sovpadajo z ocenami eksperta. Kljub temu, pa bi bilo za podrobnejšo analizo in možnost natančnejšega ocenjevanja aktivnosti, na način kot to počnejo športni eksperti, potrebno v samo analizo vključiti več informacije o dogajanju na igrišču. To bi lahko storili bodisi v obliki dodatnih ročnih oznak o dogajanju na igrišču, kar je s stališča uporabnika manj primerno, ali s pomočjo dodatnih komplementarnih podatkov, s katerimi bi bilo mogoče izvesti podrobnejšo analizo aktivnosti na različnih nivojih podrobnosti.

Poglavje 6

Prototipni sistem za analizo moštvenih iger


Na področju košarke je proučevanje obremenitev na tekmah, zaradi kompleksnosti te športne igre in težko dostopne tehnologije za merjenje obremenitev, zelo zahtevno in zamudno delo. Zaradi tega dejstva in pomanjkanja ustrezne tehnologije in metodologije je bilo s stališča športnih raziskav na področju analize gibanja igralcev moč zaznati praznino. V zadnjem obdobju je tehnologija zelo napredovala, tako je na osnovi sodelovanja s strokovnjaki Fakultete za šport nastal računalniški sistem, ki omogoča pridobivanje podatkov o strukturi gibanja igralcev. Sistem je velika pridobitev, ne samo z vidika znanstvenega raziskovanja, temveč kot prepotrebno orodje trenerjem in igralcem, saj jim je s tem omogočen kvaliteten vpogled in analiza dogodkov na treningih in tekmah.

Opisani prototipni sistem za analizo igre je le del veliko večjega sistema za analizo moštvenih iger, ki skupaj obsega naslednje module:

- **Modul za kalibracijo video posnetkov** (slika 6.1-a), ki omogoča časovno in prostorsko kalibracijo video posnetkov. Bistvo tega modula je določiti parametre transformacije, s katero je mogoče pretvoriti položaje igralcev v slikovnih koordinat v položaje igralcev na igrišču.
- **Modul za sledenje igralcev po igrišču** (slika 6.1-b), omogoča relativno enostavno pridobivanje podatkov o gibanju igralcev po igrišču.
- **Modul za vnos dodatnega znanja o igri** (slika 6.1-c), s pomočjo katerega lahko uporabnik v sistem vnese dodatno znanje, ki ga lahko v


nadaljevanju uporabimo pri analizi igre z uporabo metod analize, ki so opisane v tej disertaciji pa tudi z drugimi statističnimi metodami.

- **Modul za prikaz in izvoz podatkov** (slika 6.1-d) omogoča iskanje morebitnih napak, ki se lahko pojavijo pri sledenju igralcev. Poleg tega pa omogoča tudi izvoz podatkov v formatu, ki je primeren za uporabo v modulu za analizo in v različnih drugih programih za statistično obdelavo podatkov, kot so na primer SPSS ali Microsoft Access in Excel.
- **Modul za analizo igre** (slika 6.2) omogoča vizualizacijo in analizo različnih podatkov o gibanju igralcev.



Slika 6.1: Prikaz modulov za pridobivanje, prikaz in izvoz podatkov o gibanju igralcev med tekmami. a) Modul za kalibracijo posnetkov. b) Modul za sledenje. c) Modul za vnos dodatnega ekspertnega znanja o igri. d) Modul za prikaz in izvoz podatkov.

Modul za analizo igre vključuje dognanja, izkušnje in zaključke, ki so bili pridobljeni v okviru predhodno opisanih raziskav. Ta spoznanja so bila ključnega




Slika 6.2: Prikaz modula za analizo igre.

pomena pri izdelavi prototipnega sistema za *kvalitativno analizo* moštvenih iger, ki smo ga v sodelovanju s športnimi strokovnjaki nadgradili tudi z metodami, ki omogočajo *kvantitativno analizo* podatkov o gibanju igralcev.

Bistvo **kvantitativne analize** tekem je pridobiti čim več različnih statističnih podatkov o gibanju igralcev med tekmo. Tako prototip omogoča:

- Analizo pretečenih razdalj za posamezne igralce znotraj različnih regij igrišča v različnih fazah igre (slika 6.3-a).
- Analizo povprečnih hitrosti gibanja, ki so jih posamezni igralci dosegali znotraj različnih regij igrišča v različnih fazah igre (slika 6.3 -b).
- Analizo prehodov igralcev med različnimi regijami igrišča.
- Generiranje trajektorije žoge na podlagi ročnih oznak o podajah s strani uporabnika.
- Analizo posesti žoge s strani ekip in s strani posameznih igralcev.
- Analizo podaj med igralci ter podaj med različnimi igralnimi regijami.



Slika 6.3: Prikaz nekaterih kvantitativnih rezultatov analize, ki jih omogoča prototipni modul za analizo moštvenih iger. a) Pretečene razdalje. b) Povprečna hitrost in čas nahajanja v regiji. c) Smer in število prehodov igralca med dvema regijama. d) Smer in število podaj žoge med dvema regijama

Vsi navedeni kvantitativni rezultati lahko pripomorejo k boljšemu vpogledu v dejansko dogajanje na tekmi ter na ta način k izboljšanju organizacije igre. Po drugi strani pa lahko pripomorejo tudi k boljši kondicijski pripravi igralcev, saj je na ta način mogoče točno analizirati fizične obremenitve posameznih igralcev med tekmo.

V okviru **kvantitativne analize** so bile implementirane metode za visokonivojsko analizo tekem, ki so bile opisane v prejšnjih poglavjih. Sistem omogoča avtomatsko segmentacijo igre v posamezne faze ter iskanje znanih aktivnosti znotraj teh faz. Poleg tega omogoča tudi ocenjevanje izvedbe posamezne aktivnosti na podlagi izbrane šablone ter podroben vpogled v dobljene rezultate.

Ena glavnih prednosti sistema za analizo igre je skoraj popolna avtonomnost njegovega delovanja, saj uporabnik pri analizi igre ne potrebuje znanja iz področja

računalniškega vida, razpoznavanja vzorcev ali statistične obdelave podatkov, saj zadostuje, da izbere oziroma zgradi ustrezno šablono aktivnosti, iz katere se avtomatsko zgradijo modeli, ki so uporabljeni pri analizi. To pomeni, da se lahko popolnoma posveti proučevanju igre, pri čemer mu program služi kot orodje, s katerim lahko proučuje različne parametre igre.

6.1 Zaključek

V poglavju so bile predstavljene tehnične lastnosti prototipnega Modula za analizo igre, ki je le del veliko večjega sistema za analizo moštvenih iger. Modul za analizo igre omogoča tako kvantitativno kot kvalitativno analizo podatkov o gibanju igralcev med igro. Z njim lahko pridobimo podatke o tehničnih in kondicijskih sposobnostih posameznih igralcev, zaradi česar se je izkazal kot uporabno orodje pri načrtovanju treningov in pri pripravi na tekme.

Sistem za analizo je plod sodelovanja komplementarnih znanosti in omogoča merjenje in opazovanje novih kazalcev, ki jih v dosedanjih raziskavah ni bilo moč zaslediti. To dokazuje tudi dejstvo, da je bil sistem za analizo že večkrat uspešno uporabljen v okviru različnih raziskav [9, 90, 91] ter pri sodelovanju tako z domačimi kot tudi tujimi športnimi ustanovami in strokovnjaki.

Poglavje 7

Zaključki

V doktorski disertaciji so opisani postopki za analizo skupinskega gibanja na podlagi trajektorij gibanja igralcev. Predstavljeni postopki analize so bili aplicirani na domeni moštvenih iger s poudarkom na košarki, saj to področje zaradi velike raznovrstnosti pri gibanju igralcev in velikega števila igralcev, ki sodelujejo v posamezni aktivnosti, predstavlja poseben raziskovalni izziv. Cilj disertacije je bil razviti postopke za visokonivojsko analizo skupinskega gibanja z uporabo in nadgradnjo že obstoječih, najnaprednejših metod s področja računalniškega vida in razpoznavanja vzorcev.

Pri razvoju hierarhičnega koncepta analize je bila upoštevana hierarhična struktura moštvenih iger, s čimer smo zelo kompleksen problem analize moštvenih iger razdelili na več manjših, vsebinsko ločenih podproblemov. Upoštevajoč strukturo igre, je bila razvita trinivojska analiza skupinskega gibanja, ki je sestavljena iz:

- segmentacije zveznega dogajanja v posamezne pomensko zaključene faze igre,
- razpoznavanja vrste aktivnosti znotraj posamezne faze igre in
- vrednotenjeja (ocenjevanje) ustreznosti izvedbe aktivnosti z uporabo šablon aktivnosti.

Delo proučuje možnost uporabe metod računalniškega vida na področju analize skupinskih aktivnosti. Na podlagi raziskav so bili v delu podani štirje originalni prispevki k znanosti.

Prispevek 1: Metoda segmentacije zveznega skupinskega dogajanja na pomensko zaključene aktivnosti

Predstavljen je bil postopek segmentacije zveznih moštvenih iger v več vsebinsko zaključenih faz. Najprej je bil opisan postopek, s katerim na podlagi ročno označenih podatkov, z uporabo algoritma EM, zgradimo ločene modele za posamezno fazo igre. Predlagani so bili različni postopki za opis stanja igre z vektorjem značilk ter postopek za robusten izračun tega vektorja, ki dodatno odpravlja občutljivost segmentacije na neobičajne situacije, ki se pojavljajo v različnih moštvenih igrah. V nadaljevanju je bil opisan dvostopenjski postopek segmentacije igre. V prvem koraku na podlagi predhodno naučenega modela igre klasificiramo posamezne časovne trenutke v ustrezne faze. V drugem koraku na novo preračunamo fazo igre za posamezen vzorec tako, da upoštevamo tudi informacijo o sosednjih vzorcih. Na ta način lahko z uporabo neuteženega filtra ali uteženega filtra z Gaussovim jedrom, zagotovimo časovno konsistentnost dobljenih rezultatov.

Validacije predlagane metode smo izvedli na podatkih o gibanju igralcev na treh košarkarskih in treh roketnih tekmah. Na podlagi izvedenih eksperimentov je bilo ugotovljeno, da je za modeliranje posamezne faze igre najbolj primeren šest-komponentni model mešanice Gaussovih porazdelitev (GMM), za zagotavljanje časovne konsistence v igri pa se je za najbolj učinkovitega izkazal neuteženi filter širine 200 vzorcev. Poleg tega smo analizirali tudi, kako na uspešnost segmentacije vpliva število učnih vzorcev, izbira modela, s katerim modeliramo posamezne faze igre ter izbira vektorja značilk, ki ga uporabimo za predstavitev igre. Na podlagi dobljenih rezultatov lahko ugotovimo, da je za modeliranje igre najprimernejša uporaba GMM modela. Poleg tega se je izkazalo, da izbira vektorja značilk ne vpliva bistveno na končni rezultat segmentacije in da je mogoče dobiti zelo dober model igre tudi v primeru, da je le-ta naučen na relativno majhnemu številu učnih vzorcev (npr. 500).

Prispevek 2: Shema razpoznavanja tipa aktivnosti na podlagi šablon aktivnosti.

Za namene razpoznavanja aktivnosti z uporabo šablon aktivnosti smo razvili model igrišča in na trajektorijah temelječe detektorje osnovnih elementov košarkarske igre, ki ji jih imenujemo *detektorji akcij*. S pomočjo teh detektorjev

iz trajektorij gibanja igralcev izluščimo zelo kompakten visokonivojski opis dogajanja na igrišču. Z uporabo istih detektorjev pred samim postopkom razpoznavanja zgradimo tudi semantični opis za trajektorije, ki jih pridobimo iz šablon aktivnosti. Na ta način dobimo zbirko semantičnih opisov, ki jih uporabimo v postopku razpoznavanja.

Razpoznavanje temelji na primerjavi semantičnega opisa neznane aktivnosti z opisom šablone. Postopek primerjave je razdeljen v dve fazi. V prvi fazi iz primerjanih semantičnih opisov določimo korespondenco med vlogami igralcev v šabloni in vlogami v analizirani aktivnosti. V ta namen za vsakega igralca na igrišču zgradimo njemu lastno agendo, ki vsebuje opise vseh akcij, v katerih je igralec sodeloval. Z navzkrižnim primerjanjem dobljenih agend lahko določimo pravilno korespondenco med vlogami igralcev ter izračunamo podobnost med neznano aktivnostjo in šablono. Podobnost je podana kot razdalja med opisoma, ki jo izračunamo z uporabo modificirane Levenshteinove razdalje. Postopek primerjanja ponovimo za vsako izmed šablon aktivnosti ter na podlagi dobljenih razdalj klasificiramo neznano aktivnost v razred s šablono, pri kateri smo dobili najmanjšo razdaljo med opisoma.

Vrednotenje predlagane metode je bila izvedena na večjem številu različnih košarkarskih aktivnosti. Rezultati so pokazali, da je na podlagi predlagane metode mogoče pravilno razpoznati tip odigrane aktivnosti tudi v primeru velikega števila dodatnih simbolov, ki v opisu predstavljajo šum. Prav tako je bilo ugotovljeno, da je predlagana metoda dovolj robustna, da omogoča razpoznavanje tudi dveh zaporedno odigranih aktivnosti, medtem ko bi morali problem večjega števila zaporedno odigranih aktivnosti rešiti z uporabo drsečega časovnega okna, v katerem bi iskali aktivnosti, ki so bile v tem času odigrane. Poleg dobre uspešnosti razpoznavanja vrste odigrane aktivnosti, so rezultati eksperimentov pokazali tudi veliko uspešnost pri določanju korespondence med vlogami igralcev v šabloni in analizirani aktivnosti. Oba podatka sta namreč ključna pri ocenjevanju izvedbe aktivnosti z uporabo šablon aktivnosti.

Prispevek 3: Shema vrednotenja ustreznosti izvedbe aktivnosti s predlogami aktivnosti na podlagi statističnih modelov obnašanja.

Predstavljena sta bila dva pristopa za ocenjevanje izvedbe aktivnosti z uporabo šablon aktivnosti. V ta namen je bil najprej razvit postopek, s pomočjo katerega

je mogoče iz šablone aktivnosti zgraditi časovni profil aktivnosti ter določiti časovne relacije med posameznimi akcijami. Za ocenjevanje taktičnega dela izvedbe aktivnosti sta bili razviti dve metodi ocenjevanja, ki temeljita na dveh različnih matematičnih formalizmih. V prvem primeru so bile za ocenjevanje ustreznosti izvedbe aktivnosti uporabljene Bayesove mreže, s pomočjo katerih v ocenjevalni proces vpeljemo hierarhično strukturo aktivnosti. V drugem primeru so bile za ocenjevanje taktičnega dela aktivnosti uporabljene Petrijeve mreže. V tem primeru so bile mreže zgrajene na takšen način, da so bile najprej zgrajene verige mest in prehodov, ki so predstavljale posamezne akcije. Te verige so bile nato z logičnimi *razveji* in *združi* prehodi povezane v skupno mrežo.

Rezultati evaluacije obeh metod so pokazali, da je mogoče s predlaganima metodama ocenjevanja dokaj pravilno oceniti izvedbo akcije. V primeru uporabe večjega števila šablon za isto aktivnost pa je mogoče v večini primerov pravilno določiti tudi fazo, do katere je bila aktivnost izvedena. Pri tem se sicer za uporabo izkaže bolj primerna metoda z Bayesovimi mrežami, saj za uporabo te metode zadostuje zgolj šablona, medtem ko potrebujemo pri metodi, ki temelji na Petrijevih mrežah, tudi nekaj učnih primerov aktivnosti. Ob primerjavi dobljenih rezultatov z ocenami eksperta lahko ugotovimo, da je z opisanima metodama mogoče dobiti precej podobne rezultate kot v primeru, če aktivnosti ocenjuje ekspert. Pri tem se za boljšo izkaže metoda, ki temelji na uporabi Petrijevih mrež, saj je način ocenjevanja v tem primeru veliko bolj podoben postopku, po katerem aktivnosti ocenjuje ekspert. Prav tako je bilo ugotovljeno, da bi bilo v primeru, da bi želeli izvajati bolj podrobno analizo, na način kot to počne ekspert, v proces analize vključiti več komplementarne informacije o dogajanju na igrišču.

Prispevek 4: Prototipni sistem za analizo skupinskih aktivnosti v moštvenih športnih igrah (predvsem v košarki in rokometu).

Predstavljen je bil prototipni modul za analizo igre, ki je le del veliko večjega sistema za analizo moštvenih iger. Modul za analizo igre omogoča tako kvantitativno kot tudi kvalitativno analizo pridobljenih podatkov o igri. V ta namen so bili uporabljeni postopki, opisani v predhodnih treh točkah. Poleg tega je bil izdelan še poseben nabor funkcij, ki omogočajo poglobljeno analizo različnih kvantitativnih parametrov igre, zaradi česar se je sistem izkazal kot uporabno orodje pri načrtovanju treningov in pri pripravah na tekme. Sistem za analizo je plod sodelovanja komplementarnih znanosti in omogoča merjenje

in opazovanje novih kazalcev, ki jih v dosedanjih raziskavah ni bilo zaslediti. Njegov glavni namen je trenerju omogočiti bolj raznovrstno in poglobljeno analizo o performančnih sposobnostih igralcev med dejansko košarkarsko tekmo ter tako vplivati na hitrejši razvoj te moštvene športne igre, predvsem z vidika učinkovitejšega treniranja in izboljšanja procesa igranja.

7.1 Smernice za nadaljnji razvoj

V delu so predstavljene bazične raziskave s področja uporabe računalniškega vida pri analizi skupinskega gibanja v moštvenih športnih igrah. Kljub temu, da so opisane metode in z njimi dobljeni rezultati že uporabni, pa bi bilo te metode mogoče še nadgraditi. Tako bi lahko v vseh korakih analize upoštevali tudi trajektorijo žoge, saj predstavlja podatek o gibanju žoge dodatno, zelo pomembno informacijo pri razpoznavanju vrste aktivnosti, še pomembnejša pa je ta informacija pri ocenjevanju aktivnosti. Predvsem bi podatek o gibanju žoge pomagal odpraviti nepravilnosti pri določanju korespondence med vlogami igralcev v primeru, ko gre za simetrične akcije, kjer so trajektorije gibanja igralcev diametralne po vzdolžni osi igrišča, zaradi česar je proces določanja korespondence med igralci bistveno otežen. Poleg tega bi bilo smiselno pri ocenjevanju aktivnosti v proces analize vpeljati dodatno komplementarno informacijo o dogajanju na igrišču. Tako bi na primer v proces analize lahko vpeljali vizualno informacijo o igralcih iz stranskih kamer ali zvočni zapis tekme, s čimer bi lahko izboljšali postopek segmentacije ter izvedli še podrobnejšo analizo aktivnosti v postopku ocenjevanja izvedbe aktivnosti.

Opisane metode analize so dovolj splošne, da bi jih bilo možno uporabiti v številnih športih, kot so na primer rokomet, nogomet ali hokej, pa tudi na drugih področjih računalniškega vida, kot je na primer video nadzor. V ta namen bi bilo potrebno izvesti manjše prilagoditve detektorjev, ker so ti specifični za posamezno domeno analize.

Literatura

- [1] L. Wang, W. Hu, and T. Tan. Recent developments in human motion analysis. *Pattern Recognition*, 136:585–601, 2003.
- [2] Janez Perš. *Analiza človeškega gibanja na različnih nivojih podrobnosti z metodami računalniškega vida*. PhD thesis, Fakulteta za elektrotehniko, Univerza v Ljubljani, 2004.
- [3] D. M. Gavrila. The Visual Analysis of Human Movement: A survey. *Computer Vision and Image Understanding: CVIU, Academic Press*, 73(1):82–98, 1999.
- [4] J. K. Aggarwal and Q. Cai. Human Motion Analysis: A Review. *Computer Vision and Image Understanding: CVIU*, 73(3):428–440, 1999.
- [5] Moeslund, B. T. and Granum, E. A survey of computer vision-based human motion capture. *Computer Vision and Image Understanding: CVIU*, 81(3):231–268, 2001.
- [6] J. K. Aggarwal and S. Park. Human Motion: Modeling and Recognition of Actions and Interactions. In *3DPVT '04: Proceedings of the 3D Data Processing, Visualization, and Transmission, 2nd International Symposium on (3DPVT'04)*, pages 640–647, 2004.
- [7] B. T. Moeslund, A. Hilton, and V. Krüger. A survey of advances in vision-based human motion capture and analysis. *Special issue on modeling people: Vision-based understanding of a person's shape, appearance, movement, and behaviour, Computer Vision and Image Understanding*, 104(2):90–126, November 2006.
- [8] H.H. Nagel. From image sequences towards conceptual descriptions. *Image Vision Comput.*, 6(2):59–74, 1988.

-
- [9] A. F. Bobick. Movement, Activity and Action: The Role of Knowledge in the Perception of Motion. *Royal Society of London Philosophical Transactions Series B*, 352:1257–1265, August 1997.
 - [10] J. Gonzalez, J. Varona, F.X. Roca, and J.J. Villanueva. aSpaces : Action Spaces for Recognition and Synthesis of Human Actions. *Lecture Notes in Computer Science*, 2492:942–946, 2002.
 - [11] O.C. Jenkins and M.J. Mataric. Automated derivation of behavior vocabularies for autonomous humanoid motion. In *Proceedings of the Second International Joint Conference on Autonomous Agents and Multiagent Systems*, 2003.
 - [12] M. Dimitrijevic, V. Lepetit, and P. Fua. Human body pose detection using Bayesian spatio-temporal templates. *Comput. Vis. Image Underst.*, 104(2):127–139, 2006.
 - [13] R. Urtasun, D.J. Fleet, and P. Fua. Monocular 3D tracking of the golf swing. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, volume 2, pages 932–938, June 2005.
 - [14] A. Wiloson and A. F. Bobick. Learning Visual Behavior for Gesture Analysis. In *Proceeding of the IEE Symposium on Computer Vision, Florida, USA*, pages 19–21, 1995.
 - [15] A. Galata, N. Johnson, and D. Hogg. Learning Variable Length Markov Models of Behaviour. *Computer Vision and Image Understanding: CVIU*, 81(3):398–413, 2001.
 - [16] N. Robertson and I. Reid. Behaviour understanding in video: a combined method. *Computer Vision, 2005. ICCV 2005. Tenth IEEE International Conference on*, 1:808– 815, October 2005.
 - [17] T.V. Duong, H.H. Bui, D.Q. Phung, and S. Venkatesh. Activity Recognition and Abnormality Detection with the Switching Hidden Semi-Markov Model. In *CVPR '05: Proceedings of*, pages 838–845, 2005.
 - [18] Y. Luo, W. Tzong-Der, , and H. Jenq-Neng. Object-based analysis and interpretation of human motion in sports video sequences by dynamic

- Bayesian networks. *Computer Vision and Image Understanding*, 92(2-3):196–216, 2003.
- [19] S. Nadkarni and P.P. Shenoy. A Causal Mapping Approach to Constructing Bayesian Networks. *Decision Support Systems*, 38:259–281, 2004.
- [20] H. Johnson and D. Hogg. Learning the distribution of object trajectories for event recognition. *Image and Vision Computing*, 14:609–615, 1996.
- [21] H. Johnson and D. Hogg. Representation and synthesis of behavior using Gaussian mixtures. *Image and Vision Computing*, 20:889–894, 2002.
- [22] V. Nair and J. Clark. Automated visual surveillance using hidden markov models. In *VI02 - International Conference on Vision Interface*, pages 88–93, 2002.
- [23] F. Cupillard, F. Bremond, and M. Thonnat. Group behavior recognition with multiple cameras. In *Applications of Computer Vision, 2002. (WACV 2002). Sixth IEEE Workshop on*, pages 177–183, 2002.
- [24] S. Hongeng and R. Nevatia. Multi-agent event recognition. In *Computer Vision, 2001. ICCV 2001. Eighth IEEE International Conference on, Vancouver, BC, Canada*, volume 2, pages 84–91, 2001.
- [25] S. Hongeng, R. Nevatia, and F. Bremond¹. Video-based event recognition: activity representation and probabilistic recognition methods. *Computer Vision and Image Understanding, Special Issue on Event Detection in Video*, 96(2):129–162, February 2004.
- [26] Nuria M.O., B. Rosario, and A.P. Pentland. A Bayesian Computer Vision System for Modeling Human Interactions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(8):831–843, 2000.
- [27] Y. Du, F. Chen, W. Xu, and Y. Li. Recognizing Interaction Activities using Dynamic Bayesian Network. In *Proceedings of the 18th International Conference on Pattern Recognition*, volume 1, page 618–621, 2006.
- [28] S. Gong and T. Xiang. Recognition of Group Activities using Dynamic Probabilistic Networks. *iccv*, 2:742, 2003.

-
- [29] C.G.M. Snoek and M. Worring. Multimodal Video Indexing: A Review of the State-of-the-art. *Multimedia Tools and Applications*, 25(1):5–35, 2005.
 - [30] X. Zhu, X. Wu, A. K. Elmagarmid, Z. Feng, and L. Wu. Video Data Mining: Semantic Indexing and Event Detection from the Association Perspective. *IEEE Transactions on Knowledge and Data Engineering*, 17(5):665–677, 2005.
 - [31] L. Xie, S. Chang, A. Divakaran, and H. Sun. Structure Analysis of Soccer Video with Hidden Markov Models. In *IEEE International Conference Acoustics, Speech, and Signal Processing (ICASSP)*, 2002.
 - [32] Y. Rui, A. Gupta, and A. Acero. Automatically Extracting Highlights for TV Baseball Programs. In *ACM Multimedia*, pages 105–115, 2000.
 - [33] G. Zhu, Q. Huang, C. Xu, Y. Rui, S. Jiang, W. Gao, and H. Yao. Trajectory based event tactics analysis in broadcast sports video. In *MULTIMEDIA '07: Proceedings of the 15th international conference on Multimedia*, pages 58–67, 2007.
 - [34] S. S. Intille and A. F. Bobick. Recognizing Planned, Multiperson Action. *Computer Vision and Image Understanding: CVIU*, 81(3):414–445, 2001.
 - [35] F. Li and R. J. Woodham. Analysis of Player Actions in Selected Hockey Game Situations. In *Proceedings of the The 2nd Canadian Conference on Computer and Robot Vision (CRV'05), Canada*, pages 152–159, 2005.
 - [36] M. Jug, J. Perš, B. Dežman, and S. Kovačič. Trajectory Based Assessment of Coordinated Human Activity. In *Computer Vision Systems, Proceedings of Third International Conference ICVS 2003*, pages 534–543, Graz, Austria, April 2003.
 - [37] J. Perš. *Analiza človeškega gibanja na različnih nivojih podrobnosti z metodami računalniškega vida*. PhD thesis, Univerza v Ljubljani, Fakulteta za elektrotehniko, 2004.
 - [38] Marko Jug. *Analiza taktičnih značilnosti napada v košarki na osnovi trajektorij igralcev*. Master's thesis, Fakulteta za elektrotehniko, Univerza v Ljubljani, 2002.

-
- [39] F. Li. Description, analysis and prediction of player actions in selected hockey game situations. master's thesis,. Master's thesis, University of British Columbia, 2004.
 - [40] C. Castel, L. Chaudron, and C. Tessier. What is going on? A high level interpretation of sequences of images. In *Proc. of the Workshop on Conceptual Descriptions from Images (ECCV, 96)*, pages 13–27, 1996.
 - [41] G. Lavee, A. Borzin, E. Rivlin, and M. Rudzsky. Building Petri Nets from Video Event Ontologies. In *ISVC07*, pages 442–451, 2007.
 - [42] N.M. Ghanem, D.F. DeMenthon, D. Doermann, and L.S. Davis. Representation and Recognition of Events in Surveillance Video Using Petri Nets. In *EventVideo04*, pages 112–120, 2004.
 - [43] Y. Shi, Y. Huang, D. Minnen, A. Bobick, and I. Essa. Propagation Networks for Recognition of Partially Ordered Sequential Action. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR 2004)*, pages 862–870. IEEE Computer Society, June 2004.
 - [44] Y. Shi, A. Bobick, and I. Essa. Learning Temporal Sequence Model from Partially Labeled Data. In *CVPR'06*. IEEE Computer Society, 2006.
 - [45] B. Dežman. *Osnove teorije treniranja v izbranih moštvenih športnih igrah*. Fakulteta za šport, Univeza v Ljubljani, 1999.
 - [46] M. M. Cilenšek. *Osnove tehnične in taktične priprave mladih košarkarjev*. Agencija Studio Trg, 2001.
 - [47] B. Dežman. *Osnove teorije treniranja v izbranih moštvenih športnih igrah*. Ljubljana: Univerza v Ljubljani, Fakulteta za šport, Inštitut za šport, 2005.
 - [48] B. Dežman. *Košarka za mlade igralce in igralke. Ljubljana:.* Fakulteta za šport, Inštitut za šport., 2004.
 - [49] D. Hahnel, W. Burgard, D. Fox, K. Fishkin, and M. Philipose. Mapping and localization with RFID technology. *Robotics and Automation, 2004. Proceedings. ICRA '04. 2004 IEEE International Conference on*, 1:1015–1020 Vol.1, April-1 May 2004.

- [50] Yimin Zhang, Moeness G. Amin, and Shashank Kaushik. Localization and Tracking of Passive RFID Tags Based on Direction Estimation. *International Journal of Antennas and Propagation*, 1:in Print, 2007.
- [51] J. Perš. Sledenje ljudi z metodami računalniškega vida. Master's thesis, Fakulteta za elektrotehniko, Univerza v Ljubljani, 2001.
- [52] M. Kristan. Sekvenčne monte carlo metode za sledenje oseb v računalniškem vidu m.sc. thesis,. Master's thesis, Fakulteta za elektrotehniko, Univerza v Ljubljani, 2005.
- [53] Matej Perse Stanislav Kovacic. Janez Pers, Matej Kristan. Analysis of Player Motion in Sport Matches. In *Arnold Baca , Martin Lames, Keith Lyons, Bernhard Nebel, Josef Wiemeyer (eds.), Computer Science in Sport - Mission and Methods, (Dagstuhl Seminar Proceedings, no.08372), Schloss Dagstuhl - Leibniz-Zentrum fuer Informatik, Germany.*, 2008.
- [54] M Kristan, J. Perš, M. Perše, and Kovačič S. Implementacija algoritma Condensation v domeni zaprtega sveta. *Proceedings of the thirteenth Electrotechnical and Computer Science Conference ERK'04*, B:179–182, September 2004.
- [55] M. Kristan, J. Perš, M. Perše, and S. Kovačič. Closed-world tracking of multiple interacting targets for indoor-sports applications. *Computer Vision and Image Understanding*, 1:In press, March 2008.
- [56] M. Perše, M. Kristan, J. Perš, G. Vučkovič, and S. Kovačič. Physics-Based Modelling of Human Motion using Kalman Filter and Collision Avoidance Algorithm. In *International Symposium on Image and Signal Processing and Analysis, ISPA05, Zagreb, Croatia*, pages 328–333, September 2005.
- [57] J. Perš, M. Bon, and S. Kovačič. Errors and Mistakes in Automated Player Tracking. In *B. Likar (ed.), Proceedings of the Sixth Computer Vision Winter Workshop CVWW'01, Bled, Slovenia*, page 25–36, February 2001.
- [58] M. Perše, M. Kristan, J. Perš, G. Vučkovič, and S. Kovačič. A Template-Based Multi-Player Action Recognition of the Basketball Game. In *In: Janez Pers, Derek R. Magee (eds.), Proceedings of the ECCV Workshop on Computer Vision Based Analysis in Sport Environments, Graz, Austria*, pages 71–82, May 2006.

- [59] W. S. Erdmann. Gathering of kinematic data of sport event by televising the whole pitch and track. In *Proceedings of 10th ISBS symposium, International Society of Biomechanics in Sports, Rome, Italy*, pages 159–162, 1992.
- [60] G. J. McLachlan and T. Krishnan. *The EM Algorithm and Extensions*. Wiley Series in Probability and Statistics. John Wiley & Sons, Inc., New York, 1997.
- [61] N. Vlassis and A. Likas. A greedy EM algorithm for Gaussian mixture learning. *Neural Processing Letters*, 15:77–87, 2002.
- [62] C. J. C. Burges. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2):121–167, 1998.
- [63] V. N. Vapnik. *Statistical Learning Theory*. John Wiley and Sons, Inc., New York, 1998.
- [64] N. Cristianini and J. Shawe-Taylor. *An Introduction to Support Vector Machines (and other kernel-based learning methods)*. Cambridge University Press, 2000.
- [65] C. Chih-Chung and L. Chih-Jen. *LIBSVM: a library for support vector machines*, 2001. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- [66] M. Perše, M. Kristan, J. Perš, G. Vučkovič, and S. Kovačič. A Trajectory-Based Analysis of Coordinated Team Activity in a Basketball Game. *Computer Vision and Image Understanding*, 1:In Press, March 2008.
- [67] J. Kresse and R. Jablonski. *The Complete Book of Man-To-Man Offense*. Coaches Choice, 2nd edition, 2004.
- [68] H. L. Harkins and J. Krause. *Motion Game Offenses – For Men’s and Women’s Basketball*. Coaches Choice, 3 edition, 2001.
- [69] R. O. Duda, P. E. Hart, and D. G. Strok. *Pattern Classification*. John Wiley & Sons, Inc., 2 edition, 2000.
- [70] M. Perše, M. Kristan, J. Perš, and S. Kovačič. ”avtomatsko zaznavanje osnovnih elementov košarkarske igre na podlagi trajektorij igralcev”. In

Zbornik štirinajste mednarodne Elektrotehniške in računalniške konference ERK 2005, pages 191–194, 2005.

- [71] V. I. Levenshtein. Binary Codes Capable of Correcting Deletions, Insertions and Reversals. *Soviet Physics Doklady*, 10:707–710, February 1966.
- [72] R. Righter. *Flex: The Total Offense*. Championship Books, Ames, Iowa, USA, 1984.
- [73] M. Perše, J. Perš, M. Kristan, and S. Kovačič. Automatic Evaluation of Organized Basketball Activity. In *Michael Grabner, Helmut Grabner (eds.), Computer Vision Winter Workshop 2007, St. Lambrecht, Austria*, pages 11–18, February 2007.
- [74] J.F. Allen. Maintaining knowledge about temporal intervals. *Communications of the ACM*, 11:832–843, November 1983.
- [75] J.F. Allen and G. Ferguson. Actions and Events in Interval Temporal Logic. *Journal of Logic and Computation*, 4:531 – 579, 1994.
- [76] R.E. Neapolitan. *Learning Bayesian Networks*. Prentice Hall, 1 edition, April 2003.
- [77] D. Heckerman. A tutorial on learning with bayesian networks. Technical report, Technical Report MSR-TR-95-06, Microsoft Research, Redmond, Washington, 1995.
- [78] Wray L. Buntine. Operations for Learning with Graphical Models. *Journal of Artificial Intelligence Research*, 2:159–225, 1994.
- [79] Jie Cheng, David A. Bell, and Weiru Liu. Learning Belief Networks from Data: An Information Theory Based Approach. In *CIKM*, pages 325–331, 1997.
- [80] S. S. Intille and A. F. Bobick. A Framework for Recognizing Multi-Agent Action from Visual Evidence. In *Proceedings of the sixteenth national conference on Artificial intelligence and the eleventh Innovative applications of artificial intelligence conference innovative applications of artificial intelligence, Orlando, Florida, United States*, pages 518–525, July 1999.

-
- [81] Kurt Jensen. *Coloured Petri Nets: Basic Concepts, Analysis Methods and Practical Use*, volume 1. Springer-Verlag, Berlin, 1997.
- [82] M. Marsan, G. Balbo, G. Conte, S. Donatelli, and G. Franceschinis. *Modelling with Generalized Stochastic Petri Nets*. John Wiley and Sons, 1998.
- [83] Peter J. Haas. *Stochastic Petri Nets - Modelling, Stability, Simulation*. Springer Series in Operations Research and Financial Engineering, 2002.
- [84] Slobodan Ribarić. Temporal knowledge representation and reasoning model for temporally rich domains. *Lecture Notes in Computer Science*, 3682/2005:403–436, 2005.
- [85] Maja Gerškšič. Časovne petrijeve mreže v z znanjem podprtih sistemih za razpoznavanje vzorcev. Master's thesis, Fakulteta za elektrotehniko, 1995.
- [86] Mojca Parkelj. Z znanjem podprt sistem umetnega vida. Master's thesis, Fakulteta za elektrotehniko, 1996.
- [87] Kevin P. Murphy. The Bayes Net Toolbox for Matlab. *Computing Science and Statistics*, 33:2001, 2001.
- [88] G. Mušič, T. Löscher, and D. Gradišar. An open Petri net modelling and analysis environment in Matlab. In *I3M*, pages 123–128, 2006.
- [89] F. Erčulj, G. Vučković, J. Perš, M. Perše, and M. Kristan. Razlike v opravljeni poti in povprečni hitrosti gibanja med različnimi tipi košarkarjev. In *Zbornik naučnih i stručnih radova (N. Smajlović, ed.)*, pages 175–179, 2007.
- [90] Miha Marinič. Analiza gibanja različnih tipov igralcev na tekmi evropskega košarkarskega prvenstva za mlajše člane s pomočjo računalniškega sistema SAGIT, Diplomsko delo. Master's thesis, Fakulteta za šport, Univerza v Ljubljani, 2008.
- [91] Domen Ambrož. Analiza gibanja različnih tipov igralcev na tekmi Slovenija : Rusija na evropskem košarkarskem prvenstvu za mlajše člane, Diplomsko delo. Master's thesis, Fakulteta za šport, Univerza v Ljubljani, 2008.


-
- [92] Sonka M., V. Hlavac, and R. Boyle. *Image Processing, Analysis, and Machine Vision, Third Edition*. Thomson Learning, 2008.
 - [93] J. Shawe-Taylor and N. Cristianini. *Kernel Methods for Pattern Analysis*. Cambridge University Press, 2004.
 - [94] V. Vapnik and A. Lerner. Pattern Recognition using Generalized Portrait Method. In *Automation and Remote Control, 24.*, 1963.
 - [95] Bernhard E. Boser, Isabelle M. Guyon, and Vladimir N. Vapnik. A training algorithm for optimal margin classifiers. In *Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory*, pages 144–152. ACM Press, 1992.
 - [96] Andrew R. Webb. *Statistical Pattern Recognition. Second Edition*. John Wiley and Sons Ltd., 2002.
 - [97] Chih wei Hsu, Chih chung Chang, and Chih jen Lin. A practical guide to support vector classification. Technical report, Department of Computer Science, National Taiwan University, Taipei 106, Taiwan, 2003.
 - [98] C. W. Hsu and C. J. Lin. A Comparison of Methods for Multiclass Support Vector Machines. *IEEE TRANSACTIONS ON NEURAL NETWORKS*, 13(2):415–425, March 2002.
 - [99] J. Pearl. *Probabilistic Reasoning in Intelligent Systems: networks of plausible inference*. Morgan Kaufmann, 2 edition, 1988.
 - [100] F.V. Jensen. *An introduction to Bayesian networks*. UCL Press, London, 1996.
 - [101] T.A. Stephenson. An Introduction to Bayesian Network Theory and Usage. Technical report, IDIAP-RR 00-03, 2000.
 - [102] Carl Adam Petri. *Kommunikation mit Automaten*. Bonn: Institut für Instrumentelle Mathematik, Schriften des IIM Nr. 2, 1962.
 - [103] Carl Adam Petri. Kommunikation mit Automaten. *New York: Griffiss Air Force Base, Technical Report RADC-TR-65-377*, 1:1–Suppl. 1, 1966. English translation

- [104] Nikola Pavešić. *Razpoznavanje vzorcev: Uvod v analizo in razumevanje vidnih in slušnih signalov*. Založba FE in FRI, 2000.
- [105] T. Murata. Petri nets: Properties, analysis and applications. *Proceedings of the IEEE*, 77(4):541–580, Apr 1989.

Dodatek A


Šablone aktivnosti

V nadaljevanju so prikazane prostorske lastnosti šablon aktivnosti, ki so bile uporabljene pri razpoznavanju in ocenjevanju aktivnosti (poglavji 4 in 5).




Slika A.1: Šablone napadov, ki so bile uporabljene pri razpoznavanju in ocenjevanju aktivnosti.


Šablona "Motion"




Šablona "Atlanta"




Šablona "California"



Šablona "Double"




Šablona "Fist"




Slika A.2: Šablone napadov, ki so bile uporabljene pri razpoznavanju aktivnosti.


Šablona "Five"




Šablona "Greenville"




Šablona "Indiana"



Šablona "Jacksonville"




Šablona "Jersey"




Slika A.3: Šablone napadov, ki so bile uporabljene pri razpoznavanju aktivnosti.


Šablona "Middle"




Šablona "Russell Right"




Šablona "Trasition"



Šablona "Turnover"



Šablona "UCLA"



Slika A.4: Šablone napadov, ki so bile uporabljene pri razpoznavanju aktivnosti.

Dodatek B

Podrobni rezultati ekperimentov iz poglavja 4

Aktivnost	Korespondenca med igralci	Pravilen vrstni red
52_1	4,1,3,2,5	da
52_10p	4,1,3,2,5	da
52_11p	4,1,3,2,5	da
52_1p	4,1,3,2,5	da
52_2	4,1,3,2,5	da
52_2p	4,1,3,2,5	da
52_3	4,1,3,2,5	da
52_3p	4,1,3,2,5	da
52_4	4,1,3,2,5	da
52_4p	4,1,3,2,5	da
52_5	4,1,3,2,5	da
52_5p	4,1,3,2,5	da
52_6	4,1,3,2,5	da
52_6p	4,1,3,2,5	da
52_7	4,1,3,2,5	da
52_7p	4,1,3,2,5	da
52_8	4,1,3,2,5	da
52_8p	4,1,3,2,5	da
52_9	4,1,3,2,5	da
52_9p	4,1,3,2,5	da

Tabela B.1: Rezultati razpoznavanja korespondence med vlogami za aktivnosti tipa "52". Oznaka "p" v imenu aktivnosti pomeni, da je bila aktivnost odigrana v prisotnosti obrambe.

Aktivnost	Korespondenca med igralci	Pravilen vrstni red
flex1	5,4,2,3,1	da
flex10	1,2,4,3,5	da
flex10p	2,1,4,5,3	da
flex11	1,2,4,3,5	da
flex11p	1,2,4,3,5	da
flex12p	2,1,4,3,5	da
flex13p	1,3,2,5,4	ne
flex14p	2,1,4,3,5	da
flex15p	2,1,4,5,3	da
flex2	1,2,4,3,5	da
flex2p	4,2,1,3,5	da
flex3	2,1,4,5,3 inv	da
flex3p	2,1,4,5,3 inv	da
flex4	1,2,4,5,3 inv	da
flex4p	1,4,2,3,5	ne
flex5	2,1,4,5,3	da
flex5p	2,1,4,5,3 inv	da
flex6	2,1,4,5,3	da
flex6p	2,4,1,5,3 inv	da
flex7	1,2,4,3,5	da
flex9	1,2,4,3,5	da

Tabela B.2: Rezultati razpoznavanja korespondence med vlogami za aktivnosti tipa "Flex". Oznaka "p" v imenu aktivnosti pomeni, da je bila aktivnost odigrana v prisotnosti obrambe.

Aktivnost	Korespondenca med igralci	Pravilen vrstni red
motion1	5,3,2,1,4	da
motion10	5,2,3,1,4	da
motion12	5,2,3,1,4	da
motion13	5,2,3,1,4	da
motion2	4,3,2,1,5	da
motion2p	4,3,2,1,5	da
motion3	4,3,2,1,5	da
motion3p	4,3,2,1,5 inv	da
motion4	4,3,2,1,5	da
motion4p	4,3,1,2,5	da
motion5	5,3,2,1,4	da
motion5p	4,3,2,1,5	ne - inverzna akcija
motion6	4,2,3,1,5 inv	da
motion6p	4,3,2,1,5 inv	da
motion7	4,3,2,1,5 inv	da
motion8	2,5,3,1,4 inv	da
motion8p	4,3,2,1,5 inv	da
motion9	4,3,2,1,5	da
motion9p	4,3,2,1,5	da

Tabela B.3: Rezultati razpoznavanja korespondence med vlogami za aktivnosti tipa "Motion". Oznaka "p" v imenu aktivnosti pomeni, da je bila aktivnost odigrana v prisotnosti obrambe.

	Šablone																
akt	52	fl	mot	t4	t5	t6	t7	t8	t9	t10	t11	t12	t12	t14	t15	t16	t17
52_1	0.27	0.59	0.74	0.62	0.65	0.7	0.7	0.62	0.69	0.68	0.61	0.62	0.55	0.57	0.67	0.61	0.65
52_10p	0.41	0.57	0.68	0.63	0.66	0.71	0.68	0.67	0.6	0.69	0.66	0.64	0.57	0.58	0.65	0.62	0.67
52_11p	0.37	0.61	0.68	0.59	0.69	0.71	0.68	0.71	0.67	0.72	0.66	0.64	0.57	0.58	0.68	0.66	0.67
52_1p	0.38	0.68	0.72	0.64	0.72	0.72	0.69	0.68	0.74	0.69	0.59	0.64	0.58	0.63	0.68	0.67	0.63
52_2	0.41	0.61	0.75	0.59	0.66	0.71	0.68	0.67	0.7	0.72	0.58	0.64	0.57	0.63	0.68	0.66	0.71
52_2p	0.33	0.6	0.72	0.63	0.62	0.63	0.68	0.67	0.63	0.65	0.57	0.63	0.51	0.57	0.64	0.62	0.62
52_3	0.28	0.58	0.73	0.64	0.63	0.69	0.69	0.6	0.64	0.7	0.67	0.6	0.53	0.59	0.66	0.63	0.64
52_3p	0.3	0.58	0.71	0.61	0.64	0.66	0.64	0.66	0.69	0.6	0.64	0.61	0.49	0.6	0.67	0.64	0.65
52_4	0.32	0.63	0.79	0.57	0.61	0.67	0.68	0.62	0.7	0.65	0.61	0.62	0.5	0.61	0.71	0.65	0.61
52_4p	0.31	0.61	0.72	0.59	0.63	0.68	0.72	0.64	0.67	0.66	0.58	0.59	0.52	0.53	0.68	0.67	0.63
52_5	0.38	0.6	0.79	0.58	0.66	0.67	0.68	0.63	0.67	0.69	0.62	0.58	0.51	0.57	0.71	0.66	0.62
52_5p	0.33	0.59	0.73	0.65	0.67	0.65	0.67	0.65	0.65	0.67	0.68	0.61	0.54	0.56	0.69	0.68	0.64
52_6	0.28	0.63	0.75	0.57	0.65	0.71	0.68	0.62	0.66	0.65	0.57	0.62	0.5	0.56	0.64	0.65	0.61
52_6p	0.39	0.65	0.75	0.65	0.67	0.69	0.72	0.69	0.71	0.7	0.71	0.65	0.58	0.64	0.72	0.67	0.72
52_7	0.25	0.6	0.75	0.58	0.62	0.67	0.72	0.63	0.7	0.69	0.57	0.63	0.51	0.52	0.68	0.66	0.62
52_7p	0.33	0.6	0.75	0.58	0.66	0.67	0.68	0.63	0.7	0.69	0.57	0.63	0.56	0.52	0.68	0.62	0.62
52_8	0.28	0.61	0.69	0.6	0.63	0.69	0.69	0.6	0.64	0.67	0.59	0.6	0.53	0.55	0.66	0.63	0.64
52_8p	0.32	0.58	0.73	0.64	0.63	0.69	0.69	0.64	0.64	0.67	0.63	0.65	0.53	0.55	0.69	0.67	0.64
52_9	0.25	0.6	0.75	0.58	0.62	0.67	0.72	0.63	0.7	0.69	0.57	0.63	0.51	0.52	0.68	0.66	0.62
52_9p	0.37	0.62	0.7	0.61	0.67	0.74	0.67	0.7	0.68	0.67	0.6	0.66	0.54	0.56	0.69	0.68	0.64

Tabela B.4: Križno-korelacijska matrika modificiranih Levenshteinovih razdalj med semantičnima opisoma analizirane aktivnosti tipa "52" in različnimi šablonami. Oznaka "p" v imenu aktivnosti pomeni, da je bila aktivnost odigrana v prisotnosti obrambe.

	Šablone																
akt	52	f1	mot	t4	t5	t6	t7	t8	t9	t10	t11	t12	t12	t14	t15	t16	t17
f1	0.6	0.45	0.72	0.68	0.69	0.76	0.63	0.76	0.67	0.69	0.67	0.73	0.58	0.59	0.68	0.7	0.67
f10	0.65	0.47	0.72	0.72	0.65	0.75	0.64	0.72	0.71	0.73	0.71	0.76	0.64	0.68	0.74	0.74	0.71
f10p	0.64	0.46	0.69	0.61	0.67	0.73	0.63	0.76	0.71	0.63	0.64	0.74	0.58	0.6	0.72	0.64	0.68
f11	0.63	0.49	0.71	0.67	0.66	0.78	0.62	0.71	0.67	0.66	0.69	0.72	0.58	0.63	0.65	0.69	0.7
f11p	0.65	0.45	0.72	0.68	0.61	0.75	0.63	0.68	0.74	0.67	0.67	0.73	0.59	0.64	0.71	0.7	0.68
f12p	0.66	0.49	0.7	0.69	0.68	0.76	0.67	0.73	0.71	0.62	0.68	0.7	0.57	0.66	0.69	0.71	0.66
f13p	0.56	0.51	0.65	0.63	0.59	0.71	0.56	0.67	0.67	0.62	0.66	0.73	0.53	0.58	0.68	0.7	0.63
f14p	0.61	0.51	0.74	0.65	0.64	0.74	0.68	0.74	0.73	0.66	0.7	0.75	0.66	0.67	0.73	0.7	0.67
f15p	0.63	0.50	0.73	0.67	0.63	0.73	0.62	0.77	0.69	0.77	0.69	0.75	0.65	0.66	0.7	0.72	0.73
f2	0.61	0.48	0.67	0.65	0.7	0.74	0.63	0.78	0.65	0.71	0.64	0.76	0.58	0.6	0.69	0.64	0.69
f2p	0.69	0.49	0.68	0.7	0.68	0.79	0.68	0.76	0.72	0.74	0.72	0.74	0.68	0.73	0.72	0.72	0.76
f3	0.69	0.42	0.7	0.62	0.62	0.77	0.64	0.74	0.66	0.61	0.68	0.75	0.53	0.69	0.7	0.72	0.65
f3p	0.66	0.58	0.68	0.63	0.71	0.73	0.73	0.73	0.72	0.71	0.75	0.75	0.71	0.73	0.7	0.75	0.69
f4	0.63	0.49	0.68	0.67	0.69	0.78	0.62	0.82	0.67	0.66	0.69	0.8	0.58	0.67	0.74	0.73	0.67
f4p	0.67	0.51	0.71	0.68	0.69	0.71	0.66	0.71	0.73	0.77	0.73	0.72	0.66	0.7	0.71	0.73	0.7
f5	0.62	0.47	0.65	0.63	0.65	0.71	0.58	0.75	0.69	0.61	0.65	0.67	0.6	0.62	0.67	0.69	0.62
f5p	0.67	0.53	0.73	0.64	0.74	0.7	0.65	0.74	0.67	0.74	0.69	0.79	0.71	0.7	0.73	0.75	0.67
f6	0.55	0.45	0.7	0.66	0.68	0.66	0.64	0.74	0.66	0.74	0.68	0.79	0.53	0.62	0.7	0.75	0.69
f6p	0.6	0.54	0.66	0.6	0.67	0.64	0.59	0.73	0.68	0.63	0.67	0.65	0.57	0.64	0.69	0.67	0.68
f7	0.6	0.39	0.69	0.64	0.69	0.76	0.56	0.8	0.67	0.63	0.67	0.73	0.54	0.59	0.71	0.67	0.63
f9	0.63	0.46	0.7	0.73	0.68	0.73	0.64	0.76	0.69	0.74	0.71	0.74	0.54	0.72	0.69	0.71	0.72

Tabela B.5: Križno-korelacijska matrika modificiranih Levenshteinovih radalj med semantičnima opisoma analizirane aktivnosti tipa "Flex" in različnimi šablonami. Oznaka "p" v imenu aktivnosti pomeni, da je bila aktivnost odigrana v prisotnosti obrambe.

	Šablone																
akt	52	f1	mot	t4	t5	t6	t7	t8	t9	t10	t11	t12	t12	t14	t15	t16	t17
mot1	0.7	0.73	0.49	0.7	0.74	0.7	0.71	0.77	0.78	0.71	0.69	0.75	0.68	0.73	0.7	0.72	0.77
mot10	0.71	0.66	0.53	0.69	0.7	0.76	0.72	0.72	0.74	0.7	0.71	0.7	0.67	0.75	0.72	0.68	0.72
mot12	0.73	0.73	0.58	0.74	0.77	0.74	0.63	0.74	0.7	0.75	0.7	0.75	0.72	0.74	0.73	0.7	0.74
mot13	0.78	0.72	0.62	0.66	0.73	0.73	0.7	0.66	0.71	0.74	0.62	0.74	0.7	0.69	0.75	0.68	0.76
mot2	0.73	0.64	0.38	0.67	0.71	0.7	0.71	0.74	0.69	0.65	0.66	0.71	0.68	0.7	0.7	0.69	0.7
mot2p	0.68	0.69	0.55	0.65	0.73	0.73	0.67	0.73	0.71	0.7	0.64	0.7	0.67	0.69	0.66	0.68	0.69
mot3	0.72	0.59	0.39	0.69	0.73	0.69	0.7	0.73	0.65	0.64	0.64	0.7	0.67	0.69	0.69	0.68	0.73
mot3p	0.68	0.71	0.57	0.69	0.76	0.69	0.66	0.61	0.71	0.67	0.67	0.65	0.66	0.72	0.69	0.64	0.68
mot4	0.73	0.7	0.57	0.67	0.74	0.71	0.71	0.75	0.73	0.72	0.66	0.72	0.72	0.7	0.68	0.69	0.74
mot4p	0.74	0.68	0.54	0.64	0.75	0.71	0.69	0.71	0.7	0.72	0.67	0.73	0.69	0.67	0.68	0.67	0.75
mot5	0.64	0.71	0.51	0.68	0.72	0.71	0.69	0.75	0.76	0.69	0.63	0.73	0.69	0.71	0.68	0.7	0.67
mot5p	0.7	0.73	0.66	0.71	0.71	0.74	0.74	0.74	0.78	0.72	0.7	0.72	0.72	0.7	0.71	0.7	0.74
mot6	0.73	0.7	0.47	0.63	0.71	0.7	0.71	0.67	0.75	0.65	0.69	0.67	0.71	0.7	0.7	0.69	0.7
mot6p	0.72	0.72	0.57	0.73	0.76	0.77	0.7	0.7	0.69	0.71	0.72	0.71	0.74	0.73	0.73	0.72	0.73
mot7	0.71	0.68	0.58	0.68	0.69	0.72	0.69	0.68	0.74	0.7	0.7	0.77	0.66	0.71	0.74	0.7	0.68
mot7p	0.75	0.66	0.5	0.69	0.7	0.72	0.69	0.72	0.65	0.7	0.68	0.74	0.67	0.68	0.69	0.68	0.68
mot8	0.7	0.7	0.58	0.74	0.69	0.77	0.71	0.68	0.73	0.72	0.7	0.68	0.72	0.74	0.73	0.7	0.7
mot8p	0.73	0.73	0.61	0.71	0.71	0.74	0.74	0.71	0.7	0.69	0.7	0.72	0.72	0.74	0.76	0.7	0.7
mot9	0.68	0.71	0.52	0.68	0.69	0.72	0.69	0.75	0.71	0.7	0.67	0.73	0.69	0.71	0.69	0.7	0.68
mot9p	0.72	0.72	0.56	0.69	0.7	0.76	0.7	0.69	0.74	0.74	0.68	0.7	0.74	0.72	0.69	0.71	0.72

Tabela B.6: Križno-korelacijska matrika modificiranih Levenshteinovih radalj med semantičnima opisoma analizirane aktivnosti tipa "Motion" in različnimi šablonami. Oznaka "p" v imenu aktivnosti pomeni, da je bila aktivnost odigrana v prisotnosti obrambe.

Dodatek C

Osnovni pregled uporabljenih metod

V tem poglavju je podan osnovni pregled formalizmov in metod, ki so bili uporabljeni v okviru doktorske disertacije. V nadaljevanju so opisani algoritem EM (ang. *Expectation Maximization algorithm*), metoda podpornih vektorjev (ang. *Support Vector Machines*), model mešanice Gaussovih porazdelitev (ang. *Gaussian Mixture Models*), Bayesove mreže (ang. *Bayesian Networks*) in Petrijeve Mreže (ang. *Petri Nets*).

C.1 Algoritem EM

Algoritem EM je učinkovita metoda za izračun ocene maksimalnega verjetja (ang. *Maximal Likelihood estimate*) v primeru nepopolnih ali manjkajočih podatkov, pri čemer želimo oceniti parametre modela, za katerega je najbolj verjetno, da je generiral učne podatke [69]. Predpostavimo, da imamo na voljo množico n -dimenzionalnih vzorcev $X = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$, ki predstavljajo položaj centroida na igrišču. Naš cilj je poiskati model mešanice Gaussovih porazdelitev (ang. *Gaussian Mixture model* - GMM), ki je sestavljen iz K Gaussovih porazdelitev s parametri $\theta_k = \{\mu_k, \Sigma_k\}$, ki so utežene z utežmi α_k . Z uporabo algoritma EM želimo dobiti parametre modela $\Theta = \{\alpha_k, \theta_k\}_{k=1:K}$, s katerimi je možno najbolje predstaviti množico meritev X .

Verjetnost, da je dana porazdelitev s parametri Θ generirala poljuben vzorec $\mathbf{x}_j$ lahko zapišemo kot

$$\begin{aligned}
p(\mathbf{x}_j|\Theta) &= \sum_{k=1}^K \alpha_k \cdot \mathcal{N}(\mathbf{x}_j|\theta_k) \\
&= \sum_{k=1}^K \frac{\alpha_k}{(2\pi)^{n/2} |\Sigma_k|^{n/2}} e^{-\frac{1}{2}(\mathbf{x}_j - \mu_k)^T \Sigma_k^{-1} (\mathbf{x}_j - \mu_k)}. \tag{C.1}
\end{aligned}$$

Če predpostavimo, da so posamezni vzorci iz množice X medsebojno neodvisni, lahko zapišemo verjetnost $p(X|\Theta)$ za vzorce iz množice X pri pogoju Θ oziroma verjetje za parametre Θ pri množici vzorcev X kot

$$\begin{aligned}
p(X|\Theta) &= \prod_{j=1}^N p(\mathbf{x}_j) \\
&= \prod_{j=1}^N \sum_{k=1}^K \frac{\alpha_k}{(2\pi)^{n/2} |\Sigma_k|^{n/2}} e^{-\frac{1}{2}(\mathbf{x}_j - \mu_k)^T \Sigma_k^{-1} (\mathbf{x}_j - \mu_k)}. \tag{C.2}
\end{aligned}$$

Logaritem tega verjetja pa zapišemo kot

$$\begin{aligned}
L(\Theta) &= \sum_{k=1}^N \log(p(\mathbf{x}_j)) \\
&= \sum_{k=1}^N \log\left(\sum_{k=1}^K \frac{\alpha_k}{(2\pi)^{n/2} |\Sigma_k|^{n/2}} e^{-\frac{1}{2}(\mathbf{x}_j - \mu_k)^T \Sigma_k^{-1} (\mathbf{x}_j - \mu_k)}\right). \tag{C.3}
\end{aligned}$$

Vsako iteracijo algoritma EM sestavljata dva koraka: E-korak in M-korak [92]. V E-koraku izračunamo vpliv posamezne komponente GMM modela na posamezen vzorec iz množice X . V M-koraku pa izboljšamo oceno parametrov modela na podlagi ocene pogojne verjetnosti v E-koraku.

- **E-korak:** Predpostavimo, da imamo v neki iteraciji algoritma porazdelitev s parametri μ_k in kovariančno matriko Σ_k , ki je utežena z utežjo α_k . Potem lahko izračunamo prispevek te komponente k celotni verjetnosti $p(\mathbf{x}_j|\Sigma_k)$ kot

$$p_{jk} = \alpha_k \frac{p(\mathbf{x}_j|\Sigma_k)}{\sum_{i=1}^K p(\mathbf{x}_j|\Sigma_i)}. \tag{C.4}$$

- **M-korak:** Po izračunanem prispevku posameznih komponent lahko izračunamo nove parametre k -te komponente kot

$$\alpha_k^{i+1} = \frac{1}{N} \sum_{j=1}^N p_{jk}. \quad (\text{C.5})$$

$$\mu_k^{i+1} = \frac{\sum_{j=1}^N p_{jk} \mathbf{x}_j}{\sum_{k=1}^N p_{jk}}. \quad (\text{C.6})$$

$$\Sigma_k^{i+1} = \frac{\sum_{j=1}^N p_{jk} (\mathbf{x}_j - \mu_k^{i+1})^T \Sigma_k^{-1} (\mathbf{x}_j - \mu_k^{i+1})}{\sum_{k=1}^N p_{jk}}. \quad (\text{C.7})$$

Začetne vrednosti parametrov porazdelitve lahko izberemo poljubno, čeprav se najpogosteje za izračun začetnih parametrov uporablja metoda K-tih povprečij (ang. *K-means*) [69], na podlagi katere določimo začetnih K razredov vzorcev. Nato za vsakega izmed razredov izračunamo srednjo vrednot μ_k^0 in kovariančno matriko Σ_k^0 . V primeru, da nimamo na voljo boljše ocene uteži α_k , le-te določimo kot $\alpha_k = 1/N$.

Postopek ocenjevanja parametrov ponavljamo, dokler je sprememba Logaritma verjetja med dvema zaporednima iteracijama $L(\Theta^i) - L(\Theta^{i+1})$ večja od naprej izbranega praga ε .

C.2 Metoda podpornih vektorjev

(ang. Support Vector Machine - SVM)


Metoda podpornih vektorjev je eno izmed osnovnih metod za binarno klasifikacijo podatkov [62, 63, 64, 65, 93], ki je bila prvič predstavljena že leta 1963 [94]. Glavni cilj metode je v n -dimenzionalnem prostoru poiskati hiperravnino (ang. *hyperplane*), s katero je mogoče optimalno ločiti dva razreda vzorcev. Pri tem skušamo v postopku optimizacije poiskati tisto hiperravnino, s katero je mogoče doseči maksimalno razdaljo med razredoma, s čimer dosežemo najboljšo generalizacijo razvrščanja.

C.2.1 Linearna klasifikacija

Vzemimo, da imamo na voljo set vzorcev $\mathbf{x}_i$, ki pripadajo enemu izmed razredov $R1$ ali $R2$ in so označeni z oznako $y_i \in \{-1, 1\}$. V primeru, da vzorec pripada prvemu razredu, ima oznako $L = +1$, v nasprotnem primeru pa $L = -1$. Hiperravnino v primeru linearno separabilnih razredov definiramo kot

$$\mathbf{w}^T \mathbf{x} + b = 0, \quad (\text{C.8})$$

kjer je $\mathbf{w}$ normala hiperravnine, $b/|\mathbf{w}|$ pa predstavlja pravokotno razdaljo med ravnino in izhodiščem; $|\mathbf{w}|$ je Evklidska norma za vektor $\mathbf{w}$.



Slika C.1: Primer optimalne hiperravnine z največjo razdaljo med razredoma. Obkroženi vzorci predstavljajo podporne vektorje.

Naš cilj je poiskati hiperravnino, ki omogoča optimalno ločevanje vzorcev iz obeh razredov. Torej želimo v primeru vzorcev iz prvega razreda, zadostiti pogoju

$$\mathbf{w}^T \mathbf{x}_i + b > +1; \text{ za } y_i = +1, \quad (\text{C.9})$$

v drugem primeru pa

$$\mathbf{w}^T \mathbf{x}_i + b > -1; \text{ za } y_i = -1. \quad (\text{C.10})$$

Enačbi C.8 in C.9 določata vzporedni hiperravnini $H1$ in $H2$ za posamezna razreda, ki imata isto normalo kot glavna hiperravnina in sta od nje oddaljeni natančno za $1/|\mathbf{w}|$. Torej je skupna razdalja med obema razredoma vzorcev enaka $2/|\mathbf{w}|$. Cilj optimizacijskega postopka, ki ga na tem mestu ne bomo podrobneje obravnavali, a ga lahko najdemo v številnih publikacijah [69, 95, 96], je minimizirati Evklidsko normo $|\mathbf{w}|$, s čimer dobimo maksimalno razdaljo med obema razredoma. Pri tem igrajo ključno vlogo vzorci, ki se nahajajo bližje glavni hiperravnini, medtem ko so vzorci, ki se nahajajo zelo daleč proč, praktično nepomembni.

C.2.2 Nelinearna klasifikacija

Do sedaj smo hiperravnino opisali kot linerano prostorsko funkcijo. V večini primerov pa je problem, ki ga želimo rešiti, nelinearnega značaja. Leta 1992 so Boser, Buyon in Vapnik [95] predstavili preprosto rešitev, pri kateri originalni prostor klasifikacije razširijo v prostor višje dimenzije, pri čemer se problem nelinearne klasifikacije pretvori v linearen problem. V ta namen je najprej potrebno, z uporabo transformacijske funkcije ϕ , pretvoriti originalni niz vzorcev $\mathbf{x}$ v prostor višje dimenzije H

$$\phi : R^n \rightarrow H, \quad (\text{C.11})$$

pri čemer dobimo nov niz vzorcev $\phi(\mathbf{x}_i)$. V praksi za rešitev problema transformacija vzorcev v nov prostor ni potrebna, saj za določitev hiperravnine zadostuje že izračun *skalarnega produkta* $K(\mathbf{x}_i\mathbf{x}_j)$ vektorjev, ki bi jih morali transformirati v prostor višje dimenzije

$$K(\mathbf{x}_i\mathbf{x}_j) = \langle \phi(\mathbf{x}_i)\phi(\mathbf{x}_j) \rangle. \quad (\text{C.12})$$

Funkcijo $K(\mathbf{x}_i\mathbf{x}_j)$, na podlagi katere lahko izračunamo skalarni produkt vektorjev v pretransformiranem prostoru H z uporabo netransformiranih vektorjev značilk, imenujemo *trnasformacijsko jedro* (ang. *kernel*). Tovrstno jedro mora zadostiti določenim pogojem [69], ki jih na tem mestu ne bomo naštevali. Eno izmed takšnih jeder, ki je v praksi najpogosteje uporabljeno je, RBF (ang. *Radial Basis Function*) jedro:

$$K_{RBF}(\mathbf{x}_i \mathbf{x}_j) = e^{-\gamma \|\mathbf{x}_i - \mathbf{x}_j\|^2}. \quad (\text{C.13})$$

S pomočjo tega jedra je mogoče rešiti tako linearne kot tudi nelinearne probleme klasifikacije, zaradi česar smo ga uporabljali pri eksperimentih v poglavju 3. Pri določanju parametrov jedra smo se oprli na priporočila avtorjev [97] knjižnice LIBSVM [65] in parametre ocenili z navzkrižno validacijo na manjši množici testnih podatkov, ki jih uporabljamo pri eksperimentih v tem poglavju.

C.2.3 Večrazredna klasifikacija

Metoda podpornih vektorjev je bila prvotno razvita za binarno klasifikacijo. Vendar pa so bili predlagani različni postopki, ki temeljijo na uporabi večjega števila binarnih klasifikatorjev in omogočajo tudi klasifikacijo v večje število razredov [98]. Dva najbolj uveljavljena postopka za združevanje binarnih klasifikatorjev sta postopek *eden-proti-vsem* (ang. *one-against-all*) in *eden-proti-enemu* (ang. *one-against-one*). V prvem primeru zgradimo v fazi učenja $K - 1$ klasifikatorjev tako, da uporabimo vzorce enega razreda kot pozitivne primere in vzorce iz vseh ostalih razredov kot negativne primere. V tem primeru je v fazi klasifikacije testni vzorec razvrščen v razred, ki ga predstavlja klasifikator, pri katerem dobi vzorec najvišjo oceno pripadnosti razredu

$$m_*(t) = \max_{k=1:K-1} y_k(\mathbf{x}(t)). \quad (\text{C.14})$$

V primeru uporabe metode *eden-proti-enemu* zgradimo v fazi učenja $K(K - 1)/2$ binarnih klasifikatorjev tako, da vzamemo vzorce iz enega razreda kot pozitivne primere, vzorce iz drugega pa kot negativne. V tem primeru je vzorec razvrščen v razred, v katerega je največkrat razvrščen pri binarni klasifikaciji vseh $K(K - 1)/2$ klasifikatorjev.

V našem primeru smo za namene več-razredne klasifikacije vzorcev v poglavju 3 uporabili metodo *eden-proti-enemu* in RBF transformacijsko jedro. Uporabljen postopek je podrobneje opisan v [98].

C.3 Bayesove Mreže

Bayesove mreže [99] so usmerjen aciklični graf, ki podaja vezano verjetnost na domeni U . Domeno U sestavlja niz naključnih spremenljivk $U = \{A_1, \dots, A_n\}$, kjer lahko vsaka spremenljivka A_i zavzame določeno vrednost iz zaloge vrednosti $ZM = \{a_1, \dots, a_m\}$. Formalno lahko Bayesovo mrežo B opišemo kot par $B = \{G, \Theta\}$, kjer komponenta G predstavlja usmerjen aciklični graf z vozlišči in povezavami med vozlišči. Vozlišča predstavljajo spremenljivke, povezave med njimi pa njihove medsebojne odvisnosti. Komponenta Θ pa predstavlja parametre, ki kvantizirajo mrežo in vsebuje tabele pogojnih verjetnosti $p(A_i | Pa\{A_i\})$ za vsak niz spremenljivk A_i in njenih staršev $Pa\{A_i\}$. Ob poznanih zgornjih lastnostih mreže, lahko za vsako spremenljivko mreže A_i določimo njeno *a priori* verjetnost $p(A_i)$. Glavni namen uporabe mreže je *vrednotenje mreže*; to je računanje *a posteriori* verjetnosti $p(A_i | e)$ za poljubno spremenljivo A_i , ki jo dobimo na podlagi novih opažanj o vrednostih drugih spremenljivk v mreži - dejstvih e (ang. evidence).

Vezano verjetnost porazdelitve vseh spremenljivk za $p(U)$ dobimo z uporabo *verižnega pravila*

$$p(U) = \prod_k P\{A_k | Pa(A_k)\}. \quad (C.15)$$


Pogojna verjetnost za spremenljivko A_i ob poznanih vrednostih nekaterih ali vseh ostalih spremenljivk $e = A_1, \dots, A_{i-1}, A_{i+1}, \dots, A_n$ pa je tako določena kot

$$p(A_i | e) = \frac{p(U)}{\sum_{A_i} p(U)} = \frac{p(A_1, \dots, A_n)}{p(e)}. \quad (C.16)$$

V enačbi (C.16) predstavlja izraz $\sum_{A_i} p(U)$ marginalizacijo vezane verjetnosti po spremenljivki A_i . Ker je računanje vezane verjetnosti v primeru velikega števila spremenljivk lahko zelo računsko potratno, so bile razvite številne metode za poenostavitev tega postopka [99, 100, 76, 101].

Slika C.2 prikazuje primer alarmnega sistema, ki ga sestavljajo štiri spremenljivke, ki jih modeliramo s štirimi atributi mreže. Povezave in usmerjenost povezav predstavljajo odvisnosti med posameznimi atributi, tabele pa prikazujejo pogojne odvisnosti med njimi. V prikazanem primeru skušamo modelirati verjetnost, da pride do alarma v primeru, ko pride do potresa ali vloma. Poleg

tega pa predvidimo tudi, da nas bo v primeru, da se je alarm sprožil, poklical sosed. Vrednosti v tabelah prikazujejo pogojno verjetnost dogodka v primeru, da je določen atribut znan. Vzemimo na primer, da nas zanima, kakšna je verjetnost, da je prišlo do vloma v primeru, da nas je poklical sosed ($p(V|K_{da})$).



Slika C.2: Primer Bayesove mreže za modeliranje Alarmnega sistema

V ta namen moramo najprej določiti začetno stanje mreže, ki nam pove, kolikšna je verjetnost za posamezen atribut v primeru, da nimamo nobene dodatne informacije o sistemu. To naredimo tako, da najprej po enačbi (C.16) izračunamo skupno verjetnost sistema, pri čemer upoštevamo odvisnosti med posameznimi spremenljivkami

$$p(V, E, A, K) = p(K|A)p(A|V, E)p(V)p(E). \quad (C.17)$$

V primeru, da želimo dobiti verjetnost za posamezno spremenljivko, moramo skupno verjetnost marginalizirati po tej spremenljivki. Tako je na primer verjetnost za klic soseda

$$\begin{aligned}
p(K_{da}) &= p(K_{da}|A_{da})\{p(A_{da}|V_{da}, E_{da})p(V_{da})p(E_{da}) + \\
&\quad p(A_{da}|V_{da}, E_{ne})p(V_{da})p(E_{ne}) + \\
&\quad p(A_{da}|V_{ne}, E_{da})p(V_{ne})p(E_{da}) + \\
&\quad p(A_{da}|V_{ne}, E_{ne})p(V_{ne})p(E_{ne})\} + \\
&\quad p(K_{da}|A_{ne})\{p(A_{ne}|V_{da}, E_{da})p(V_{da})p(E_{da}) + \\
&\quad p(A_{ne}|V_{da}, E_{ne})p(V_{da})p(E_{ne}) + \\
&\quad p(A_{ne}|V_{ne}, E_{da})p(V_{ne})p(E_{da}) + \\
&\quad p(A_{ne}|V_{ne}, E_{ne})p(V_{ne})p(E_{ne})\} \\
&= 0.011736,
\end{aligned} \tag{C.18}$$

verjetnost, da se bo sprožil alarm pa

$$\begin{aligned}
p(A_{da}) &= p(A_{da}|V_{da}, E_{da})p(V_{da})p(E_{da}) + \\
&\quad p(A_{da}|V_{da}, E_{ne})p(V_{da})p(E_{ne}) + \\
&\quad p(A_{da}|V_{ne}, E_{da})p(V_{ne})p(E_{da}) + \\
&\quad p(A_{da}|V_{ne}, E_{ne})p(V_{ne})p(E_{ne}) \\
&= 0.002516.
\end{aligned} \tag{C.19}$$


Vzemimo, da nas je poklical sosed in nam povedal, da se je sprožil alarm. Zanima nas, kakšna je verjetnost, da je prišlo do vloma. Torej nas zanima, kakšna je verjetnost vloma pri dejstvu, da nas je sosed poklical $p(V_{da}|K_{da})$. Tako lahko izračunamo, da je verjetnost vloma ob dejstvu, da nas je sosed poklical, enaka $p(V_{da}|K_{da}) = 0.056117$. Vidimo, se je verjetnost za vlom ob znanem dejstvu V_{da} iz prvotnih 0.001 povečala na 0.056117. Verjetnost za vlom se poveča zato, ker je se je ob klicu soseda bistveno povečala verjetnost za alarm ($p(A_{da}|K_{da}) = 0.15009$), ki posledično vpliva tudi na dvig verjetnosti za vlom. Ravno tako pa se je povečala tudi verjetnosti za potres, ki se je iz prvotnih 0.0002, povečala na $p(V_{da}|K_{da}) = 0.035881$.

C.3.1 Uporaba navideznih dejstev pri vrednotenju Bayesove mreže

Najpogosteje se v Bayesovih mrežah uporabljajo binarne spremenljivke, ki lahko zavzamejo le dve možni stanji, na primer A_{da} ali A_{ne} . Pri vrednotenju mreže

pa spremenljivka zavzame le eno izmed dveh možnih stanj (na primer A_{da}). V določenih primerih pa zaradi narave uporabljenih senzorjev, ki vsebujejo neko negotovost, takšnih kategoričnih dejstev nočemo uporabiti, temveč želimo podati verjetnost nekega stanja v obliki navideznega dejstva (ang. *virtual* ali *soft evidence*). Tako bi si na primer želeli podati verjetnosti za spremenljivko A v obliki navideznega dejstva $p(A_{da}) = 0.8$ in $p(A_{ne}) = 0.2$. Takšno dejstvo se pri sklepanju v mreži interpretira, kot da je verjetnost za stanje spremenljivke A_{da} štiri krat višja od verjetnosti za stanje A_{ne} . V sami mreži pa lahko takšno dejstvo prikažemo kot nov "navidezen" atribut s tabelo pogojnih verjetnosti, ki ustreza navideznim dejstvom, stanje novega atributa pa je $p(A_{da}) = 1$.

Slika C.3 prikazuje uporabo navideznega dejstva za primer alarma iz prejšnjega poglavja. Kot lahko vidimo, je bil primer razširjen z dodatnim vozliščem "Navidezno dejstvo", ki ponazarja verjetnost, da je do klica sosedu zares prišlo. Takšno "Navidezno dejstvo" bi na primer lahko uporabili v primeru, da smo slišali zvonjenje telefona in se je na telefon javil nekdo drug, mi pa na podlagi pogovora sklepamo, da je "navidezna" verjetnost, da je klical sosed $p(K_{da}) = 0.8$. To informacijo bi v dani mreži interpretirali kot $p(ND_{da}) = 1$, pri čemer bi preko vzročne povezave med vozliščema K in ND , to dejstvo na vozlišču K prikazali kot $p(K_{da}) = 0.8$. Dodatna pojasnila v zvezi z uporabo navideznih dejstev so na voljo v [99].



Slika C.3: Primer navideznega dejstva za spremenljivko "Klic sosedu".

Navidezna dejstva imajo pred klasičnimi dejstvi predvsem to prednost, da pri uporabi zveznih detektorjev ni potrebno določiti mejnih vrednosti posameznega

elementa, ampak lahko vrednost detektorja neposredno preslikamo v verjetnost, da je bilo neko stanje opaženo. S tem se izognemo določanju dodatnih parametrov (mejnih vrednosti stanj), ki jih je težko določiti in lahko vplivajo na končno oceno aktivnosti.

C.4 Petrijeve mreže

Teorijo Petrijevih mrež je leta 1992 v svoji doktorski disertaciji predstavil Karel Adam Petri [102, 103]. Petrijeve mreže so matematični formalizem, ki se uporablja za načrtovanje, modeliranje in predstavitev determinističnih in stohastičnih sistemov s pretežno deterministično strukturo. Tako se na primer uporabljajo za modeliranje računalniških sistemov, programske opreme, kemijskih reakcij, industrijskih procesnih linij in še na številnih drugih področjih.

Grafično lahko Petrijevo mrežo predstavimo kot usmerjen bipartitni graf (slika C.4), ki ga sestavljata dva tipa vozlišč - mesta M in prehodi P , ki jih grafično predstavimo kot kroge oziroma pravokotnike [82]. Puščice med njimi predstavljajo smer prehajanja žetonov po mreži. Žetoni so v mreži predstavljeni kot črne pike. Ločimo dve vrsti povezav med posameznimi elementi mreže in sicer *vhodne*, *izhodne* povezave.

Formalno lahko Petrijevo mrežo opišemo kot model, ki je sestavljen iz petih parametrov

$$PM = \{P, T, I, O, M\}. \quad (C.20)$$

V enačbi (C.20) posamezne spremenljivke predstavljajo:

- oznaka $P = \{p_1, p_2, \dots, p_n\}$ predstavlja množico mest, ki običajno predstavljajo možna stanja sistema ali njegove sestavne dele.
- oznaka $T = \{t_1, t_2, \dots, t_m\}$ predstavlja množico prehodov v mreži. Ločimo dve vrsti prehodov in sicer *časovne* (ang. *timed*) in *takojšnje* (ang. *immediate*). Prvi se prožijo po preteku določenega časa, drugi pa v primeru izpolnitve določenega logičnega stanja.

- preslikava $I : P \rightarrow Pn$ predstavlja matriko vhodnih povezav. Matrika I podaja število žetonov na posameznem mestu p_i , ki so potrebni za proženje prehoda t_j .
- preslikava $O : T \rightarrow Tn$ predstavlja matriko izhodnih povezav. Matrika O , določa koliko žetonov se bo ob proženju prehoda t_j generiralo na mestu p_k .
- vektor $M : P \rightarrow \mathbb{N}$ predstavlja funkcijo označitve in podaja število žetonov na posameznem mestu p_i . Označitev M predstavlja trenutno stanje sistema.

Za Petrijeve mreže veljajo številna pravila, ki jih najdemo v številnih virih [82, 83, 104], od njih pa bomo omenili zgolj tista, ki so pomembna za naše delo. Glavni izmed teh sta *pravilo omogočenosti* (ang. *enabling rule*) in *pravilo proženja* (ang. *firing rule*).

Definicija 1: *Pravilo omogočenosti* določa, da je prehod omogočen, če ima vsako njegovo vhodno mesto vsaj toliko žetonov, kolikor jih določa povezava od tega mesta k danemu prehodu.

Definicija 2: *Pravilo proženja* določa, da se prehod t_j lahko proži zgolj v primeru, da je omogočen. Proženje prehoda spremeni razporeditev žetonov v Petrijevi mreži, zato se spremeni vektor označitve na naslednji način:

$$M_{(t)} = M_{(t-1)} + (O - I) \cdot E_{(t)}, \quad (\text{C.21})$$

kjer sta spremenljivki O in I matriki vhodnih in izhodnih povezav, $M_{(t-1)}$ in $M_{(t)}$ označitev pred oziroma po proženju, spremenljivka $E_{(t)}$ pa vektor prehodov, ki so bili proženi.

Poleg teh dveh pravil sta zelo pomembni lastnosti mreže tudi *zastoj* (ang. *deadlock*) in *dosegljivostna množica* mreže (ang. *reachability set*).

Definicija 3: *Zastoj* predstavlja označitev mreže, ki ne omogoča proženja nobenega novega prehoda, zaradi česar ni mogoče preiti v nobeno novo označitev. Zaradi tega dejstva moramo biti pri načrtovanju mrež na možne zastoje v mreži še posebej pozorni.


Definicija 4: *Dosegljivostna množica* je najmanjša množica označitev, ki jih lahko v Petrijevi mreži dosežemo, s proženjem različnih prehodov. Med mnogimi metodami, ki se uporabljajo za določanje dosegljivostne množice sta temeljni dve in sicer ***invariantna metoda***, ki temelji na opisu dinamičnih

lastnosti Petrijevih mrež z matričnimi enačbami ter **metoda dosegljivostnih dreves** [105], ki temelji na določanju vseh možnih označitev Petrijeve mreže iz začetne označitve M_0 na podlagi proučevanja različnih možnosti proženja prehodov v primeru različnih označitev.

C.4.1 Primer delovanja Petrijeve mreže

Vzemimo, da imamo za primer na sliki C.4, ki ga sestavljajo tri mesta $P = [p_1, p_2, p_3]$ in trije prehodi $T = [t_1, t_2, t_3]$, podane naslednje parametre:

$$\mathbf{I} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad \mathbf{O} = \begin{bmatrix} 0 & 0 & 2 \\ 0 & 0 & 1 \\ 1 & 3 & 0 \end{bmatrix}. \quad (\text{C.22})$$



Slika C.4: Primer Petrijeve mreže [83].

Iz slike lahko ugotovimo, da je trenutna označitev mreže enaka $\mathbf{M} = [2, 1, 3]^T$. Ker je na mestu m_1 in m_3 prisotnih več žetonov, kot jih zahteva izhodna funkcija I , sta prehoda t_1 in t_3 omogočena, medtem ko je na mestu m_2 premalo žetonov in je zato prehod t_2 onemogočen. Vzemimo, da pride do proženja prehoda t_3 . V tem primeru novo stanje oziroma novo označitev mreže izračunamo po enačbi (C.21) kjer je $E_{(t)} = [0, 0, 1]^T$ in dobimo, da je ta nova označitev enaka $\mathbf{M}' = [2, 4, 2]^T$. Z novim stanjem mreže postane omogočen tudi prehod t_2 , ker je na mestu m_2 dovolj žetonov, da zadostimo pogojem matrike izhodnih povezav I . V naslednjem

koraku lahko tako pride do proženja katere koli izmed treh prehodov, vendar pa pride najprej do proženja prehoda t_3 , saj je ta prehod takojšen, kar pomeni, da se proži takoj za tem, ko je omogočen. Celoten iterativni postopek se lahko ponavlja, dokler ne pridemo do nekega zelenega končnega stanja mreže, vendar pa moramo v fazi načrtovanja mreže paziti, da je to stanje dejansko dosegljivo.

C.4.2 Nadgradnja osnovnega koncepta Petrijeve mreže

S časom se je osnovni koncept Petrijevih mrež razvijal v različnih smereh. Posledica tega so različne nadgradnje osnovnega koncepta Petrijevih mrež, od katerih so najbolj razširjeni in najpogostejše uporabljeni naslednji:

- **Časovne Petrijeve mreže (ang. *Time Petri Nets*).** Bistvo časovni PM je uvedba časa v mehanizem proženja prehodov v mreži. Tako lahko pride do proženja mreže po preteku določenega časa, v katerem je nek prehod omogočen. Obstajajo različni principi merjenja tega časa v primeru, ko je bil prehod sicer omogočen, a je prišlo do proženja drugega prehoda, zaradi česar postane dotični prehod onemogočen. Med temi mehanizmi sta najpogostejše uporabljena *Nadaljevalni mehanizem* (ang. *Continue*) in *Ponastavitveni mehanizem* (ang. *Reset*). V prvem primeru pride do seštevanja časov omogočenosti prehoda, medtem ko se v drugem primeru čas v primeru, da postane prehod onemogočen, resetira na nič. Tako začne čas v prvem primeru ob ponovni omogočenosti prehoda teči iz stare vrednosti, medtem ko začne v drugem primeru čas vedno teči znova.
- **Barvne (podatkovne) Petrijeve Mreže (ang. *Coloured Petri Nets*).** Bistvo Barvnih petrijevih mrež je v tem, da se žetoni uporabljajo kot nosilci neke dodatne informacije o predmetu ali stanju, ki ga v mreži predstavljajo. Tako lahko na primer pri modeliranju industrijske linije za izdelavo avtomobila žetoni nosijo informacijo o barvi avtomobila, vgrajenem tipu motorja in drugih podatkih, ki so povezani s samim procesom izdelave.
- **Hierarhične Petrijeve Mreže (ang. *Hierarchy Petri Nets*).** Bistvo Hierarhičnih Petrijevih mrež je možnost združevanja različnih ločenih Petrijevih mrež, ki na primer ponazarjajo delovanje nekega podsistema v neko skupno mrežo, pri čemer lahko modeliramo hierarhijo med posameznimi enotami.

- **Stohastične Petrijeve mreže (ang. *Stochastic Petri Nets*).**
Bistvo Stohastičnih Petrijevih mrež je možnost stohastičnega modeliranja časovnega proženja posameznih prehodov mreže. V ta namen lahko uporabimo poljubno porazdelitveno funkcijo, čeprav se v realnih problemih najpogosteje uporablja negativna eksponentna porazdelitev.
- **Generalizirane stohastične Petrijeve mreže (ang. *Generalized Stochastic Petri Nets – GSPN*).** Generalizirane stohastične Petrijeve mreže so nadgradnja Stohastične Petrijeve mreže na takšen način, da v samem modelu podamo tudi prioritete posameznih neposrednih prehodov. Te prioritete omogočajo razreševanje konfliktov med posameznimi prehodi in s tem izogibanje možnim zastojem v mreži. Poleg tega pa tovrsten koncept omogoča tudi boljše modeliranje samega realnega sistema.

Življenjepis

Matej Perše se je rodil 9.6.1979 v Šempetru pri Gorici. Po končani osnovni šoli se je vpisal na srednjo šolo Tehnični šolski center (TŠC) v Novi Gorici, smer Elektrotehnik - elektronika in jo uspešno zaključil leta 1998. Po opravljeni maturi, se je vpisal na Fakulteto za elektrotehniko, Univerze v Ljubljani, smer Procesna avtomatika. Leta 2003 se je kot dodiplomski študent pridružil Laboratoriju za strojni vid, kjer je do leta 2005 sodeloval na komercialnem projektu *Sports Tracking*. V okviru tega projekta je leta 2004 nastalo tudi njegovo diplomsko delo z naslovom *Sledenje športnikov na osnovi Kalmanovega filtra*. Istega leta se je vpisal na podiplomski študij na Fakulteti za elektrotehniko, kjer je od novembra 2005 zaposlen kot mladi raziskovalec. V okviru dodiplomskega in podiplomskega študija se je udeležil številnih tujih in domačih konferenc, kjer je predstavil rezultate svojega raziskovalnega dela, ki zajema uporabo računalniškega vida pri analizi in razumevanju človeškega gibanja na podlagi trajektorij njihovega gibanja. V okviru svojega raziskovalnega dela je kot avtor ali soavtor objavil štiri izvirne znanstvene prispevke, 16 znanstvenih prispevkov na konferencah ter dva strokovna prispevka.

Osebni podatki

Ime in priimek	Matej Perše
Datum rojstva	9. junij 1979
Kraj rojstva	Šempeter pri Gorici
Stalno prebivališče	Zofke Kvedrove ulica 16, 1000 Ljubljana
Državljanstvo	Slovensko
Šifra raziskovalca	27516

Izobrazba

1998	Dokončal srednjo elektrotehniško šolo v Novi gorici.
1998-2004	Vpisan kot redni študent na dodiplomski študij na Fakulteti za elektrotehniko, Univerza v Ljubljani. Študijska smer: avtomatika.
september, 2004	Diplomiral na Fakulteti za elektrotehniko, Univerza v Ljubljani. Naslov diplomske naloge: Sledenje športnikov na osnovi Kalmanovega filtra. Naziv: univerzitetni diplomirani inženir elektrotehnike.
2004-2009	Doktorski študent na Fakulteti za elektrotehniko (enovit doktorski študij), Univerza v Ljubljani.
2005 - 2009	Zaposlen kot mladi raziskovalec na Fakulteti za elektrotehniko, Univerza v Ljubljani.

Objavljena dela

1.01 Izvirni znanstveni članek

- [1] M. Perše, M. Kristan, G. Vučkovič, S. Kovačič, and J. Perš, *A trajectory-based analysis of coordinated team activity in a basketball game*, Computer Vision and Image Understanding (2008), in press.
- [2] M. Kristan, M. Perše, S. Kovačič, and J. Perš, *Closed-world tracking of multiple interacting targets for indoor-sports applications*, Computer Vision and Image Understanding (2008), in press.
- [3] M. Kristan, M. Perše, S. Kovačič, and J. Perš, *Sledenje več igralcev v športnih igrah na podlagi vizualne informacije*, Electrotechnical Review 74 (2007), no. 1-2, 19–24.
- [4] M. Kristan, J. Perš, M. Perše, and S. Kovačič, *A Bayes-spectral-entropy-based measure of camera focus using a discrete cosine transform*, Pattern Recognition Letters 27 (2006), no. 13, 1419–1580.

1.08 Objavljeni znanstveni prispevek na konferenci

- [5] M. Perše, M. Kristan, J. Perš, and S. Kovačič, *Recognition of multi-agent activities with Petri nets.*, Zbornik sedemnajste mednarodne Elektrotehniške in računalniške konference ERK 2008, 29. september - 1. oktober 2008, Portorož, Slovenija, 2008, zv. B, str. 217-220.
- [6] M. Perše, M. Kristan, J. Perš, G. Vučkovič, and S. Kovačič, *Temporal segmentation of group motion using Gaussian mixture models*, Computer Vision Winter Workshop, 2008, pp. 47–54.

- [7] M. Perše, M. Kristan, J. Perš, S. Kovačič, *Automatic evaluation of organized basketball activity*, Computer Vision Winter Workshop 2007 (Helmut Grabner Michael Grabner, ed.), 2007, pp. 11–18.
- [8] J. Perš, M. Kristan, M. Perše, and S. Kovačič, *Motion based human identification using histograms of optical flow*, Computer Vision Winter Workshop 2007 (Helmut Grabner Michael Grabner, ed.), 2007, pp. 19–26.
- [9] F. Erčulj, G. Vučković, J. Perš, M. Perše, and M. Kristan, *Razlike v opravljeni poti in povprečni hitrosti gibanja med različnimi tipi košarkarjev*, Zbornik naučnih i stručnih radova (N. Smajlović, ed.), 2007, pp. 175–179.
- [10] A. Jarc, J. Perš, P. Rogelj, M. Perše, and M. Kristan, *Texture features for affine registration of thermal (FLIR) and visible images.*, RABNER, Michael (ur.), GRABNER, Helmut (ur.). CVWW 2007 : proceedings of the 12th Computer Vision Winter Workshop, February 6-8, 2007, St. Lambrecht, Austria. Graz: Institute for Computer Graphics and Vision, Graz University of Technology, 2007, str. 35-41.
- [11] M. Kristan, J. Perš, M. Perše, and S. Kovačič, *Towards fast and efficient methods for tracking players in sports*, Proceedings of the ECCV Workshop on Computer Vision Based Analysis in Sport Environments (J. Perš and D. R. Magee, eds.), May 2006, pp. 14–25.
- [12] M. Perše, M. Kristan, J. Perš, and S. Kovačič, *A template-based multi-player action recognition of the basketball game*, Proceedings of the ECCV Workshop on Computer Vision Based Analysis in Sport Environments (J. Perš and D. R. Magee, eds.), May 2006, pp. 71–82.
- [13] M. Kristan, J. Perš, M. Perše, M. Bon, and S. Kovačič, *Multiple interacting targets tracking with application to team sports*, International Symposium on Image and Signal Processing and Analysis, September 2005, pp. 322–327.
- [14] M. Perše, J. Perš, M. Kristan, G. Vuckovic, and S. Kovačič, *Physics-based modelling of human motion using kalman filter and collision avoidance algorithm*, International Symposium on Image and Signal Processing and Analysis, September 2005, pp. 328–333.
- [15] M. Perše, M. Kristan, J. Perš, and S. Kovačič, *Avtomatsko zaznavanje osnovnih elementov košarkarske igre na podlagi trajektorij igralcev*, Zbornik

- štirinajste mednarodne Elektrotehniške in računalniške konference ERK 2005, 26. - 28. september 2005, Portorož, Slovenija, (Zbornik ... Elektrotehniške in računalniške konference ERK ...). Ljubljana: IEEE Region 8, Slovenska sekcija IEEE, 2005, zv. B, str. 191-194.
- [16] M. Kristan, J. Perš, M. Perše, and S. Kovačič, *Bayes spectral entropy-based measure of camera focus*, Computer Vision Winter Workshop, February 2005, pp. 155–164.
- [17] M. Kristan, J. Perš, M. Perše, and S. Kovačič, *Implementacija Condensation algoritma v domeni zaprtega sveta*, Proceedings of the thirteenth Electrotechnical and Computer Science Conference, vol. B, September 2004, pp. 179–182.
- [18] J. Perš, M. Kristan, M. Perše, and S. Kovačič, *Observing human motion using far-infrared (FLIR) camera – some preliminary studies*, Proceedings of the thirteenth Electrotechnical and Computer Science Conference, vol. B, September 2004, pp. 187–190.
- [19] M. Perše, J. Perš, M. Kristan, and S. Kovačič, *Vrednotenje učinkovitosti kalmanovega filtra pri sledenju ljudi*, Proceedings of the thirteenth Electrotechnical and Computer Science Conference, vol. B, September 2004, pp. 191–194.
- [20] M. Perše, J. Perš, M. Kristan, and S. Kovačič, *Nekatere prednosti uporabe multivariabilnih regulatorjev pri vodenju industrijskih procesov*, TOVORNIK, Boris (ur.), MUŠKINJA, Nenad (ur.). Avtomatizacija v industriji in gospodarstvu : zbornik tretje konference AIG'03, 10. in 11. april 2003, Maribor, Slovenija. [Maribor]: Društvo avtomatikov Slovenije, 2003, str. 325-330.

1.09 Objavljeni strokovni prispevek na konferenci

- [21] V. Sulić, J. Perš, M. Kristan, A. Jarc, M. Perše, and S. Kovačič, *Izvedba algoritma računalniškega vida na omrežni kameri*, Računalniška obdelava slik in njena uporaba v Sloveniji (P. Božidar, ed.), 2008, pp. 35–40.

- [22] J. Perš, M. Kristan, M. Perše, M. Bon, G. Vučković, and S. Kovačič, *Analiza gibanja igralcev med tekmami*, Računalniška obdelava slik in njena uporaba v Sloveniji (P. Božidar, ed.), 2006, pp. 97–103.

Monografije in druga zaključena dela

2.11 Diplomsko delo

- [23] M. Perše, *Sledenje športnikov na osnovi Kalmanovega filtra : diplomsko delo*, Fakulteta za elektrotehniko, Univerza v Ljubljani, September 2004.

Izjava

Izjavljam, da sem doktorsko nalogo izdelal samostojno pod vodstvom mentorja prof. dr. Stanislava Kovačiča. Izkazano pomoč drugih sodelavcev sem v celoti navedel v zahvali.

V Ljubljani, 21. september 2009.

Matej Perše, univ. dipl. inž. el.