Konstrukcija i aplikacija novog modela za evaluaciju uspješnosti u kompleksnim sportskim aktivnostima

Jelaska, Igor

Doctoral thesis / Disertacija

2011

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of Kinesiology / Sveučilište u Splitu, Kineziološki fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:221:672556

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Repository / Repozitorij:

Repository of Faculty of Kinesiology, University of Split

SVEUČILIŠTE U SPLITU

KINEZIOLOŠKI FAKULTET

IGOR JELASKA

KONSTRUKCIJA I APLIKACIJA NOVOG MODELA ZA EVALUACIJU USPJEŠNOSTI U KOMPLEKSNIM SPORTSKIM AKTIVNOSTIMA

DOKTORSKA DISERTACIJA

SPLIT, SRPANJ 2011.

SVEUČILIŠTE U SPLITU

KINEZIOLOŠKI FAKULTET

IGOR JELASKA

KONSTRUKCIJA I APLIKACIJA NOVOG MODELA ZA EVALUACIJU USPJEŠNOSTI U KOMPLEKSNIM SPORTSKIM AKTIVNOSTIMA

DOKTORSKA DISERTACIJA

MENTOR: PROF. DR.SC. VLADAN PAPIĆ

SUMENTOR: PROF. DR. SC. SLAVKO TRNINIĆ

SPLIT, SRPANJ 2011.

ZAHVALA

osobama bez kojih izrada ove disertacije ne bi bila moguća:

sumentoru, prof. dr. sc. Slavku Trniniću, na savjetima i kontinuiranoj podršci,

mentoru, prof. dr. sc. Vladanu Papiću pod čijim vodstvom je ovaj rukopis u konačnici oblikovan,

članu povjerenstva, prof.dr. Nenadu Rogulju, bih se htio zahvaliti na konstruktivnim primjedbama i primjerenim sugestijama.

Posebnu zahvalnost upućujem dr. sc. Anti Perici, s kojim sam uložio zajednički napor u prikupljanju, obradi i interpretaciji podataka.

SAŽETAK

Svrha ovog istraživanja je empirijska verifikacija i validacija diskretnih slučajnih procesa – Markovljevih lanaca u području istraživanja kompleksnih sportskih aktivnosti. U skladu s tim, cilj ove studije je postavljanje diskretnog modela za tranzicijski i pozicijski napad u košarkaškoj igri.

Pritom je korišten uzorak od 24 košarkaške utakmice Top 16 Eurolige za sezonu 2009./2010. U sklopu ovog rada definirana je i izmjerena 231 varijabla - stanje košarkaške igre.

U programskom jeziku C# programiran je interaktivan i reprogramabilan softver *State Analyzer 1.0.* Navedenim je softverom, korištenjem striktno definiranog protokola bilježenja stanja, izvršena detaljna deskripcija košarkaške igre u fazi pozicijskog i tranzicijskog napada.

Temeljem navedenih 231 stanja košarkaške igre u fazi pozicijskog i tranzicijskog napada definirane su nestandardne situacijske varijable za pozicijski napad. Primjenom softvera *State Analyzer 1.0.* odredile su se njihove vrijednosti.

Izvedena je matrica prijelaznih vjerojatnosti Markovljevog lanca, čijom analizom su provjerene hipoteze istraživanja.

Nadalje, eksplorativnom strategijom faktorske analize u manifestnom prostoru nestandardnih situacijskih pokazatelja ekstrahirana su 2 faktora: faktor tehničko-taktičke aktivnosti bloka na loptu i faktor tehničko-taktičke aktivnosti bloka na igrače bez lopte.

Višestrukom regresijskom analizom na dvije hijerarhijski različite razine promatranja, korištenjem forward algoritma, utvrđeno je da:

a) uspješnost pozicijskog napada je primarno određena sa efikasnošću *pick and roll/pop* i *handoff* manevra, a sekundarno učinkovitošću blok igre u napadu na igračima bez lopte;

b) uspješnost pozicijskog napada je u najvećoj mjeri određena s tri aspekta situacijske efikasnosti: prodorom loptom, utrčavanjem u prostor reketa te igrom na niskom postu.

Diskriminacijskom analizom su utvrđene razlike između uspješnih i neuspješnih ekipa u fazi napada. Pritom je granična uspješnost pozicijskog napada za diskriminaciju bila 55,5%. Dvije različite hijerarhijske razine diskriminacijske analize pokazale su da:

a) uspješnom pozicijskom napadu najviše pridonose učinkovita utrčavanja, učinkoviti prodori loptom s vanjskog prostora te učinkovita igra na niskom postu. Nadalje, neuspješnom pozicijskom napadu najviše pridonose neučinkoviti prodori loptom s vanjskog prostora;

b) uspješnom pozicijskom napadu primarno doprinosi učinkovita *pick and pop/roll i handoff* igra u napadu, a sekundarno učinkoviti blokovi na igračima bez lopte. Važno je istaknuti da za neuspješan pozicijski napad dobiveni rezultati ukazuju na neadekvatnu učinkovitost navedenih manevara.

Dobiveni rezultati potvrđuju spoznajne činjenice koje su ekspertni treneri i znanstvenici praktičari odavno isticali i koristili u oblikovanju tehničko taktičkih programa u situacijskom treningu.

U konačnici, važno je kako se korišteni metodološki pristup, primijenjen na analizu slojevitosti elemenata taktike košarkaške igre može generalizirati i primijeniti na momčadske sportske igre.

Ključne riječi: košarka, tranzicijski napad, pozicijski napad, Markovljev lanac, nestandardne situacijske varijable.

ABSTRACT

The aim of this investigation is empirical validation and verification of discrete stohastic processes – Markov chains in complex sports activities research. Also, the goal was to ground discrete model for transition and positional offense in basketball.

In accordance with goal oft his research a sample of 24 basketball games in 2009/2010 Top 16 Euroleague season and 231 variables – game states were defined and measured.

By use of programming language C# interactive and reprogramable software was made - *State Analyzer Ver 1.0.* and it is given on the CD. With this software as a tool, from strictly defined measuring procedure protocol, detailed description of basketball game in position and transition offense was performed.

On the basis of 231 game states in position and transition offense, a set of nonstandard situational variables was defined and by use of *State Analyzer 1.0.* software their values were obtained.

Transition probabilities matrix was analised and by the help of their values hypotheses were checked.

Furthermore, by use of explorative strategies of factor analysis, within manifest space of nonstandard situational parameters 2 latent factors were extracted: (1) pick and pop/roll and handoff activity offensive factor (2) screen off the ball activity offensive factor.

By use of forward algorithm in multiple regression analysis on two hierarchically different levels of observation is determined that

a) Successful positional offense is primarily influenced by successful *pick and roll/pop* and *handoff* maneuvers and secondarily by successful screening off the ball

b) Successful positional offense is mainly determined by successful ball penetration, inside cutting and successful low post game

With the help of discriminant analysis the differences between offensive successful and unsuccessful teams were obtained. Threshold criteria for discrimination was 55,5%. Two different levels of hierarchical analysis showed that

a) Successful inside cutting, ball penetration from perimeter and successful low post game; contribute the most to successful positional offense; Unsuccessful ball penetration from perimeter are main generators of unsuccessful positional offense.

b) Successful pick and roll/pop handoff offense contributes primarily, and screening off the ball secondarily to successful positional offense; for unsuccessful positional offense results are simmetric.

Empirical facts, known from the long history of basketball, which have been used by expert coaches and scientists in creating technical and tactical programmes in situational training are scientificaly verified.

This methodological approach, which has been applied to analysis of basketball layer-type elements of tactics can be generalized and applied to the other team sport games.

Key words: basketball, transition offense, positional offense, Markov chain, nonstandard situational variables

SADRŽAJ

1. UVOD 11
1.1. Mehanizmi i metode za objašnjenje i razumijevanje složenih kineziloških pojava ... 13
1.1.1. Izomorfizmi između formalnih struktura i procesa u primijenjenoj kineziologiji 14
1.1.2. Klasično reguliranje dinamičkih sustava primijenjeno u društvenim i humanističkim znanostima 16
1.1.3. Sustavi (ne)linearnih (diferencijalnih) jednadžbi 19
1.1.3.1. Sustavi linearnih jednadžbi 19
1.1.3.2. Sustavi diferencijalnih jednadžbi 21
1.1.4. Metode umjetne inteligencije 22
1.1.4.1. Neuronske mreže 23
1.1.4.2. Evolucijski algoritmi 24
1.1.4.3. Apstraktni automati 28
1.1.4.3.1. Deterministički i nedeterministički konačni automat 28
1.1.4.3.2. Turingov stroj 30
1.1.4.4. Slučajni procesi 33
1.1.4.4.1. Markovljevi lanci 34
1.2. Problematika jednadžbe uspjeha u momčadskim sportskim igrama 41
1.2.1. Problem odabira modela čimbenika uspješnosti u momčadskim sportskim igrama 43
1.2.2. Metodološki problemi istraživanja jednadžbe uspjeha u momčadskim sportskim igrama 49
1.2.3. Istraživanja ishoda suprotstavljanja tehničko - taktičkih modaliteta u situacijskim uvjetima 50
1.2.3.1. Istraživanja ishoda suprotstavljanja tehničko-taktičkih modaliteta u situacijskim uvjetima u drugim sportskim igrama 59
1.2.4. Jednadžba uspjeha u momčadskim sportskim igrama 64
1.2.5. Prijedlog nelinearnog modela čimbenika uspješnosti u sportu 67
1.3. Metodologija istraživanja u kineziologiji 69
1.3.1. Svrha metoda istraživanja 71
1.3.2. Metodološki principi u polju kineziologije 71
2. DOSADAŠNJA ISTRAŽIVANJA 73
2.1. Istraživanja Markovljevim lancima 73
2.2. Istraživanja košarkaške igre 75
2.3. Istraživanja evaluacije uspješnosti u momčadskim sportskim igrama 87

2.4. Istraživanja načina procjene i predviđanja uspješnosti u momčadskim sportskim igrama 88
2.5. Istraživanja modela uspješnosti u sportu u momčadskim sportskim igrama 89
3. PROBLEM RADA 90
3.1. Principi ravnoteže igre 91
3.1.1. Analiza stanja košarkaške igre korištenjem Markovljevih lanaca 94
4. CILJ RADA 100
5. HIPOTEZE 101
6. METODE RADA 103
6.1. Uzorak entiteta 103
6.2. Uzorak varijabli 103
6.3. Opis eksperimenta (postupka) 120
6.4. Metode obrade rezultata 122
6.5. Opis funkcionalnosti software-a State Analyzer ver. 1.0. 122
7. REZULTATI I RASPRAVA 127
7.1. Rezultati 127
7.1.1. Uspješnost napada 127
7.1.1.1. Opća uspješnost napada 127
7.1.1.2. Zastupljenost i uspješnost pozicijskog napada 131
7.1.2. Pozicijski napad 132
7.1.2.1. Analiza središnjice pozicijskog napada 132
7.1.2.1.1.*Pick and roll/pop* igra u središnjici. 133
7.1.2.1.2.*Handoff* igra 135
7.1.2.1.3.*Screens off the ball* - blokovi na igračima bez lopte 136
7.1.2.1.4.Cut igra 140
7.1.2.1.5.Igra na niskom postu 143
7.1.2.1.6.Ubacivanje lopte izvan linija igrališta 144
7.1.2.1.7.Napad na zonsku obranu 146
7.1.2.2. Analiza taktičkih aktivnosti u završnici pozicijskog napada 147
7.1.2.2.1.*Pick and roll/pop* napad u završnici 148
7.1.2.2.2.*Handoff* (uručenje lopte) u završnici 150
7.1.2.2.3.*Screens off the ball* (blokovi na igračima bez lopte) u završnici 151
7.1.2.2.4.*Inside cut* (utrčavanja) u završnici 153
7.1.2.2.5.*Low post game* (igra na niskom postu) u završnici 155
7.1.2.2.6.Izolacije na perimetru u završnici 156
7.1.2.2.7.Načini realizacije u završnici pozicijskog napada 158
7.1.2.2.8.Napadački skakački rasporedi 161
7.1.3. Tranzicijski napad 165

7.1.3.1. Zastupljenost i uspješnost tranzicijskog napada 165
7.1.3.2. Završnica protunapada 166
7.1.3.2.1. Primarni protunapad 167
7.1.3.2.2. Sekundarni protunapad 168
7.1.3.2.3. Rani napad 169
7.1.3.2.4. Analiza načina realizacije protunapada 169
7.1.3.3. Analiza središnjice protunapada 171
7.1.3.4. Tranzicijski napad protiv presinga 172
7.1.3.5. Napadački skakački raspored u tranzicijskom napadu 174
7.1.4. Analiza matrice prijelaznih vjerojatnosti Markovljevog lanca 176
7.1.5. Deskriptivna i distribucijska analiza uzorka 179
7.1.6. Latentna struktura prostora uspješnih nestandardnih situacijskih varijabli .. 184
7.1.7. Analiza povezanosti nekih nestandardnih situacijskih varijabli napada 187
7.1.8. Analiza razlika između napadački uspješnih i neuspješnih momčadi u prostoru nestandardnih situacijskih varijabli 191
7.2. Rasprava 194
7.2.1. Ograničenja istraživanja 194
7.2.2. Znanstveni i stručni značaj istraživanja 195
7.2.3. Budući pravci istraživanja 196
8. ZAKLJUČAK 198
9. LITERATURA 203
10. PRILOG 216
10.1. Prilog 1 – Izvorni kod: SSA ver. 1.0. 216
10.2. Prilog 2 – Izlazni rezultati programa SSA 238
10.3. Prilog 3 - Najučestalija stanja napada 246
10.4. Prilog 4 - Najučestaliji fragmenti napadačkih akcija 246
10.5. Prilog 5 - Dijagrami stanja pozicijskog napada 251

1. UVOD

Na samom početku ovog rada potrebno je istaknuti da mogućnosti za provedbu istraživanja određenog tipa nisu jednake u svim znanstvenim disciplinama koje pripadaju području društvenih i humanističkih znanosti. Wright (1975.) smatra da će humanističke i društvene znanosti primjenom sintetičke discipline, kibernetike i drugih egzaktnih metoda doživjeti pozitivne i konstruktivne promjene. U skladu s tim, mnogi istraživači primjerice Momirović (1971.), Malacko i Popović (2001.) naglašavaju nužnost upotrebe kibernetičkih modela u kineziologiji te daju smjernice za njihovo buduće korištenje. Metode umjetne inteligencije (Lapham & Bartlett, 1995), umjetne neuronske mreže (Perl, 2001., Perl & Weber 2004., Lees, Barton & Kershaw 2003.), metode teorijskog računarstva (Perl, 2005.), nelinearni modeli (Ambrožič, 1996.,1999., Sekulić, Viskić-Štalec & Rausavljević 2003., Sekulić, Zenić, Marković, 2005., Sekulić, Zenić & Grčić Zubčević 2007., Trninić, Jelaska & Papić, 2009.a, 2009.b) postaju nezaobilazan alat u analizama kompleksnih sportskih aktivnosti.

Lees (2002.) naglašava da nove metode, primjerice umjetne neuronske mreže mogu biti prikladan alat koji će pomoći nadilaženju postojećih ograničenja, kako tehničke analize tako i općenitih kvantitativnih analiza.

Piaget (1972.) navodi da se logičko i matematičko zaključivanje, čak i kad je konstruktivno, ne odnosi na činjenice, osim ako je generirano modelom koji je prilagođen samim činjenicama. Također tvrdi da model nužno mora biti takav da se deduktivne transformacije dovode u korespondenciju sa stvarnim transformacijama, odnosno da model mora predstavljati projekciju logičko-matematičke sheme u realnost. Model se sastoji od konkretnog predstavljanja transformacija koje se mogu izraziti pomoću sheme. U skladu s time tvrdi da je model eksplicitan obrazac u onoj mjeri u kojoj omogućava da se objektivnim procesima pripiše struktura koja im je izomorfna. Također upućuje da zahvaljujući neiscrpnom bogatstvu iskustva i neograničenoj plodnosti logičko-matematičkih struktura modeli mogu oblikovati deduktivnu konstrukciju koja je u suglasju sa stvarnošću. Vjerojatno je za psihologiju sporta i kineziologiju sporta najzanimljiviji i najpraktičniji aspekt primjene matematičkih i fizikalnih modela, a ne samo

hipotetičko svođenje neke mentalne strukture ili kineziološkog procesa na matematičku strukturu ili fizikalni model. Odnosno, cilj je uspostavljanje analogije između funkcija mentalne strukture ili kineziološkog procesa te matematičkog modela.

Fressard (prema Piaget, 1972.) naglašava da proces znanstvenog raščlanjivanja nužno zahtijeva apstraktne modele koji su istovremeno stohastički i algebarski. Pritom apstraktni modeli nastaju iz napora da se formaliziraju zakonitosti, čime se omogućava precizno kvalitativno i kvantitativno predviđanje.

Potrebno je naglasiti da se termin *model* često zloupotrebljava do te mjere da *model* postaje svaka deduktivna cjelina korištena u kineziologiji i njoj srodnim disciplinama. Izraz model stječe svoje pravo značenje onog trenutka kad je jasna egzistencija okvira koji je općenitiji od zakona analiziranih u proučavanom eksperimentalnom području. Okvir mora biti u stanju pružiti ne samo formulaciju problema i mogućnost predviđanja već i izvor objašnjenja, u onoj mjeri u kojoj transformacije unutar modela odgovaraju stvarnim transformacijama pojave koju treba objasniti. U skladu s tim, uporaba matematičkih modela u predstavljanju kinezioloških procesa ili pojava u formalno matematički oblik omogućuje kvantitativno predočavanje-interpolaciju, te predviđanje-ekstrapolaciju.

Važnost matematičkih modela u društvenim i humanističkim znanostima je u tome što se u stvarnosti neprestano suočavamo s neizbježnošću biranja među mnogobrojnim posredujućim varijablama. Prednost apstraktnih modela je u tome što istovremeno otkrivaju nužne i dovoljne uvjete i što ih formuliraju u generalnoj formi, odnosno u apstraktnom obliku tako da mogu biti primijenjeni na više konkretnih različitih ciljeva. Također, apstraktni modeli su povezani s konkretnim modelima koji su prisutni u društvenim i humanističkim znanostima te se trebaju na njih nastaviti nadograđivati u svojim daljnjim istraživanjima i primjenama. Matematički model obuhvaća više konkretnih modela i na taj način njegovo postavljanje predstavlja neophodan prijelazni korak između općih hipoteza i posebnih hipoteza koje će se moći na osnovu formalne analize postaviti i podvrgnuti eksperimentalnim provjerama.

Ako proučavamo ulogu apstraktnih modela u društvenim i humanističkim znanostima, možemo konstatirati da se ona uvijek sastojala u tome da potpomaže razvoj strukturalizma i to proporcionalno nastojanjima da se model podudara sa stvarnim istraživanim mehanizmima.

S obzirom na nužnost promjene poimanja kineziloških problema i pojava, nužno je i dokinuti jednosmjernu i linearnu relaciju između pojedinca i okoline te obuhvatiti uzajamne, dinamičke i recipročne procese. Tako primjerice, ono što je u jednoj vremenskoj točki posljedica, u drugoj vremenskoj točki može postati uzrokom. Pritom je uporaba transakcijskih modela jedan od pristupa koji ne polazi od jednosmjerne već dvosmjerne relacije osobe i okoline.

Zato je potrebno učiniti iskorak primjenom i povezivanjem teorije kaosa, teorije dinamičkih sustava, teorije transakcijskih modela i koncepta recipročnog determinizma kao jednog od mogućih oblika izbjegavanja parcijalnog pristupa ili eksplicitnije transcendencije redukcionizma. Navedene teorije se međusobno ne isključuju, već su u komplementarnom odnosu. Standardno se matematičkim postupcima linearizacije, složeniji sustavi, procesi i/ili nelinearni modeli u polju kineziologije svode na linearni.

Dva su standardna pristupa istraživanju čimbenika uspješnosti u sportu. Prvi, strukturalni pristup, temelji se na utvrđivanju diferencijalno ponderirane linearne kombinacije faktora koji mogu opisati jednadžbu uspjeha ovisno o teoriji sportske uspješnosti i sportskoj aktivnosti (Momirović, 1966., 1969., 1972.; Trninić, Jelaska i Papić, 2009.a). Drugi, funkcionalni pristup, prikazuje čimbenike uspješnosti u međudjelovanju tj. kao proces međudjelovanja čimbenika uspješnosti koji određuju sportaševu izvedbu i sportsko postignuće, što generira nelinearni odnos među promatranim relevantnim faktorima (Trninić, Jelaska i Papić, 2009.b). Ta dva pristupa nisu nužno međusobno isključivi pristupi čimbenicima uspješnosti u sportu.

1.1. Mehanizmi i metode za objašnjenje i razumijevanje složenih kineziloških pojava

Popper (1973.) tvrdi da su empirijske znanosti sustavi teorija te da su teorije mreže koje se bacaju da bi se ulovilo ono što se naziva „svijet“: da bi se taj svijet racionalizirao, objasnio i da bi se njime zavladalo. Pritom navodi da se znanstvene teorije neprekidno mijenjaju te da mogu biti podložne više ili manje oštrim provjerama. U skladu s time mogu biti lako opovrgljive, a stupanj njihove provjerljivosti ima značaja prilikom selekcije teorija. Nadalje, Popper (1973.) upozorava da na području psihologije (a vjerojatno i kineziologije op.a.) teže otkrivamo univerzalne zakone (kao i zakonitosti op. a.). Mogli bismo reći da zato psihologija i kineziologija kao

znanosti imaju veoma složen odnos između teorije i znanstvenih istraživanja. Premisa mogućnosti znanstvenog istraživanja i formaliziranja kompleksnih interakcija u kineziološkim pojavama je poznavanje rigoroznih formalno opisanih matematičkih procedura i definicija, a neke od njih će biti opisane u daljnjim poglavljima.

1.1.1. Izomorfizmi između formalnih struktura i procesa u primijenjenoj kineziologiji

U matematici, svaka formalna struktura opisana je svojim elementima i aksiomatski striktno definiranim odnosima među njima. (Horn i Johnson, 1990.; Roman, 2005.) Matematički objekti grupoid, polugrupa, grupa, prsten, integralna domena, polje, vektorski prostor... su uvijek zadani kao skup objekata među kojima je definirano neko pravilo interakcije: „ * “, „ + “, „#“ itd. Stoga se formalna matematička struktura standardno notira kao uređen par skupa i operacije ili uređena trojka skupa i više operacija (Judson, 1997.; La Harpe, 2000.).

Tako je primjerice formalna definicija matematički formalne strukture grupe (Kleiner, 1986.; Golubitsky i Stewart 2006.) :

Grupa $(G, +)$ je skup G sa binarnom operacijom +, koja zadovoljava sljedeća četiri aksioma:

1. Za svaka dva elementa a, b iz G, rezultat $a + b$ je također u G. (Svojstvo zatvorenosti na operaciju +)
2. Za svaka tri elementa a, b i c iz G, vrijedi $(a + b) + c = a + (b + c)$. (Svojstvo asocijativnosti)
3. Postoji element e iz G takav da za svaki a iz G, $e + a = a + e = a$. (Egzistencija neutralnog elementa)
4. Za svaki a iz G, postoji element b, također iz G, takav da $a * b = b * a = e$, gdje je e neutralni element. (Svojstvo egzistencije inverznog elementa)

Često se svojstvo zatvorenosti na operaciju ne navodi jer se podrazumijeva u iskazu da je + binarna operacija. Lako se iz pokazanih aksioma dokazuje egzistencija samo jednog neutralnog

elementa i da su lijevi i desni inverz elementa jednaki. Također često se grupa $(G,+)$ označuje samo sa G, kad ne postoji nejednoznačnost oko označavanja operacije u grupi.

Preslikavanja između grupa se često koriste u primijenjenim znanostima s ciljem uspostavljanja analogije između struktura (La Harpe, 2000.; Shores, 2006.; Golubitsky i Stewart, 2006.). Pri proučavanju analogija između formalnih struktura i struktura primijenjene kineziologije važno je za svaki pojedini element formalne strukture uspostaviti njegov kineziološki analogon.

Ako su definirane dvije strukture $(G, +)$ i $(H, \cdot)$, homomorfizam struktura je preslikavanje $h : G \to H$ takvo da za svako x i y iz G vrijedi

$$h(x + y) = h(x) \cdot h(y)$$

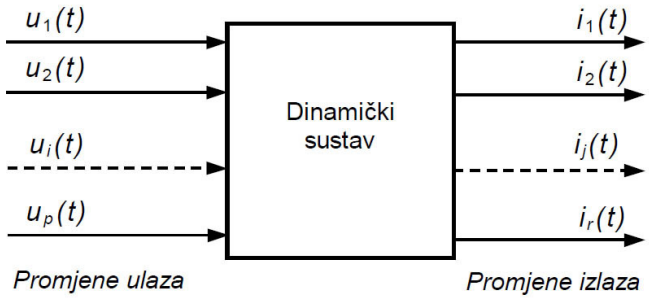
gdje je operacija s lijeve strane operacija iz strukture G, a s desne strane je operacija iz H.
Gore navedeni stavak znači da homomorfizam zadržava strukturu pojedinih operacija. Ako homomofrizam i ima svojstvo bijektivnosti,[1] tada ga nazivamo izomorfizam (Weibel, 1994.).
Izomorfizam govori o strukturnoj identičnosti objekata te je to nezaobilazni mehanizam u svim primijenjenim znanostima kada je potrebno pokazati ekvivalentnost, odnosno identičnost između pojedinih formalno definiranih sustava. (Kleiner, 1986.; Weibel, 1994.) Konkretno, ako se uspostavi izomorfizam između dvije grupe, one su matematički gledano jednake. Tako u primijenjenoj kineziologiji, ako možemo uspostaviti izomorfnu vezu između matematičkog modela i opisanog i kineziološki analiziranog sustava, imamo mogućnost da korištenjem teorije matematičkog modela ekstrapoliramo akcije i transformacije kineziološkog sustava (Piaget, 1972.) te pojednostavnimo proces znanstvenog istraživanja istog. U praktičnim istraživanjima, primjerice u kineziologiji, izomorfizam među strukturama se ne definira formalno, već se samo definira matematički model koji opisuje proučavani kompleksni kineziološki sustav iz kojega je očita izomorfnost njega i proučavanog.

[1] Bijektivno preslikavanje je ono preslikavanje koje je injektivno i surjektivno. Injektivno preslikavanje je ono preslikavanje koje različite elemente domene preslikava u različite elemente kodomene. Surjektivno je ono preslikavanje za koje su svi elementi kodomene, funkcijske slike elemenata domene.

1.1.2. Klasično reguliranje dinamičkih sustava primijenjeno u društvenim i humanističkim znanostima

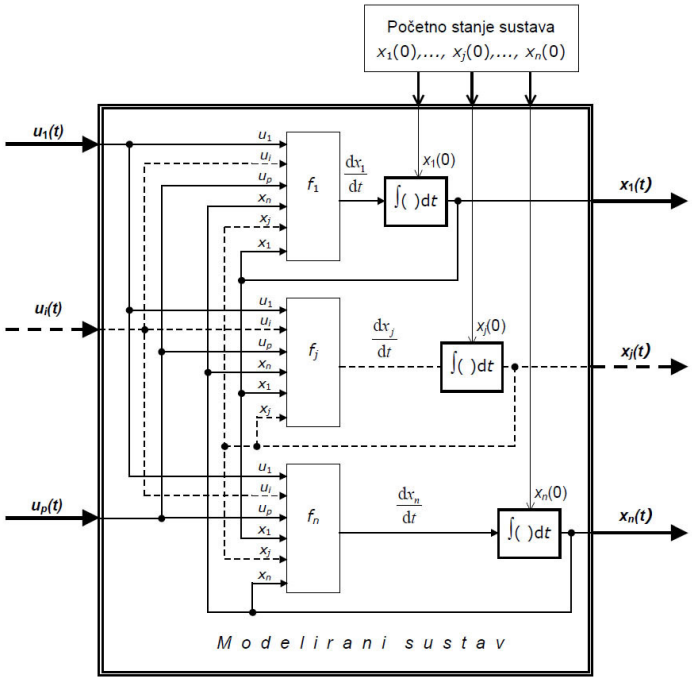
Ovisnost izlaznih o ulaznim varijablama u dinamičkim sustavima koji opisuju stvarnosti u pojedinim znanstvenim istraživanjima u društvenim i humanističkim znanostima, uspostavlja se djelovanjem različitih fizikalnih zakonitosti. (Radošević, 2001.) Postupak modeliranja dinamičkih sustava u znanstvenim problemima u društvenim i humanističkim znanostima obuhvaća prije svega odabir pretpostavki i aproksimacija koje će rezultirati optimalno točnim modelom s obzirom na svrhu modeliranja (Radošević, 2001.; Vidačić, 2005.a, 2005.b) Također, tim znanstvenika odnosno eksperata u proučavanom području mora razložiti sustav na elementarne komponente u skladu s polaznim pretpostavkama i aproksimacijama te matematički formulirati zakonitosti koje određuju veze između ulaza i izlaza (Slika 1.1, Slika 1.2).

Slika 1.1: Shematski makro prikaz dinamičkog sustava



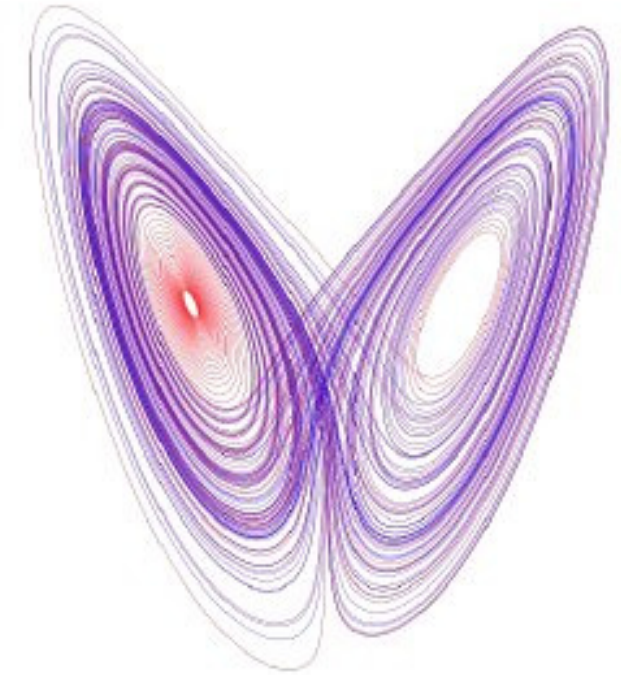
Tako primjerice u kineziologiji, u polistrukturnim i kompleksnim timskim sportovima je dodatno potrebno matematički formulirati višestruko interakcijske odnose između ulaznih i izlaznih varijabli (Birkhoff, 1966.). Komponente dinamičkih sustava smatrat ćemo elementarnim kada se ovisnost izlaza o ulazima, u okviru prihvaćenih pretpostavki i aproksimacija, može eksplicitno izraziti matematičkim formuliranjem zakonitosti kojima je ovisnost uvjetovana. U modeliranju složenih dinamičkih sustava pod pojmom proces podrazumijevamo zbivanja kojima se realiziraju uzročno-posljedične veze između ulaznih i izlaznih varijabli te samih elementarnih komponenata (Birkhoff, 1966.; Ott, 1993.; Ott, Sauer i Yorke 1994.) .

Slika 1.2: Princip rada dinamičkog sustava



Skup mogućih stanja dinamičkog sustava zove se fazni prostor (Birkoff, 1966.). Koordinate faznog prostora opisuju dinamičko stanje sustava u svakom trenutku i dinamičko pravilo: budući trend ponašanja sustava. Grafički prikaz faznog prostora (Slika 1.3) naziva se atraktor (Bertalanffy, 1968.). Ruele (1989.) i Barton (1994.) tvrde da postoje četiri tipa strukture dinamičkog sustava, odnosno četiri temeljne vrste sustava.

Slika 1.3: Atraktor



Ukoliko staza atraktora dođe do jednog mjesta i stane, znači da se sustav smirio u stabilnom stanju. Ako staza oblikuje zatvorenu krivulju (tzv. petlju), znači da se ponašanje sustava periodično ponavlja. Tako primjerice Losada i Heapy, 2004., analiziranjem djelovanja kontrolnog parametra, povezivosti, među grupama ispitanika, proučavaju nelinearni dinamički model koji generira tri vrste atraktora. Pritom kompleksnost i oblik pojedinog atraktora povezuju s kvalitetom izvedbe zadataka pojedinog tima. Iscrtavanjem kaotičnog sustava, dobivamo uzorak poznat pod imenom neobični atraktor (eng. *strange attractor*).

Jasna je velika mogućnost primjene dinamičkih sustava u primijenjenoj kineziologiji. Dinamički sustavi bi, metodološki gledano, trebali biti okosnica kineziološkog modeliranja, naročito polistrukturalnih i kompleksnih sportskih aktivnosti. Dinamički sustavi mogu opisivati sve kineziološki analizirane sustave, čak i one koji konvergiraju kaotičnosti, s obzirom na to da u kineziologiji moraju (mogući ishodi su poznati) imati stabilnu strukturu. McGarry i sur. (2002.),

promatraju sportsko natjecanje kao dinamički i samoorganizirajući sustav. Pault i Zanone (2005.) prave dinamičku analizu gibanja tenisača te ističu nužnost više upotrebe dinamičkih sustava u sportskoj znanosti.

1.1.3. Sustavi (ne)linearnih (diferencijalnih) jednadžbi

U primijenjenim znanostima, pa tako i u kineziologiji, mnogi problemi se u konačnici svode na rješavanje sustava linearnih, odnosno nelinearnih diferencijalnih ili običnih jednadžbi. Stoga je dublji uvid u njihovu strukturu nužan za dodatno produbljivanje spoznaja o strukturi samih problema (Poole, 2006.; Steven, 2006.).

1.1.3.1. Sustavi linearnih jednadžbi

U matematici i linearnoj algebri, sustav linearnih jednadžbi je skup linearnih jednadžbi koji je generiran rješavanjem nekog problema.

Standardni problem predstavlja utvrđivanje postoji li skup vrijednosti za nepoznanice, $x_1, x_2, ..., x_n$ koji zadovoljava sve jednadžbe istovremeno, kao i pronalaženje takovog skupa ako postoji. Postojanje skupa rješenja ovisi od jednadžbi, ali i od dostupnih vrijednosti.

Sustavi linearnih jednadžbi spadaju među najstarije matematičke probleme i imaju mnoge primjene, kao što su obrada digitalnih signala, procjene, predviđanja, te linearno programiranje ili aproksimacija nelinearnih problema u numeričkoj analizi (Steven, 2006.).

Poopćeno, sustav sa m linearnih jednadžbi i n nepoznanica se zapisuje na sljedeći način:

$$\begin{aligned} a_{11}x_1 + a_{12}x_2 + \cdots + a_{1n}x_n &= b_1 \\ a_{21}x_1 + a_{22}x_2 + \cdots + a_{2n}x_n &= b_2 \\ &\vdots \\ a_{m1}x_1 + a_{m2}x_2 + \cdots + a_{mn}x_n &= b_m \end{aligned}$$

odnosno u matričnoj notaciji:

$$Ax=\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix}\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}=\begin{bmatrix} a_{11}x_1+a_{12}x_2+\cdots+a_{1n}x_n \\ a_{21}x_1+a_{22}x_2+\cdots+a_{2n}x_n \\ \vdots \\ a_{m1}x_1+a_{m2}x_2+\cdots+a_{mn}x_n \end{bmatrix}=\begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix}=b$$

pri čemu je:

$$A=\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix},\ x=\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix},\ b=\begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix}$$

Za primijenjene kineziološke analize potrebno je uočiti sljedeće transformacije:

$$Ax=\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix}\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}=\begin{bmatrix} a_{11}x_1+a_{12}x_2+\cdots+a_{1n}x_n \\ a_{21}x_1+a_{22}x_2+\cdots+a_{2n}x_n \\ \vdots \\ a_{m1}x_1+a_{m2}x_2+\cdots+a_{mn}x_n \end{bmatrix}$$

$$=\begin{bmatrix} a_{11}x_1 \\ a_{21}x_1 \\ \vdots \\ a_{m1}x_1 \end{bmatrix}+\begin{bmatrix} a_{12}x_2 \\ a_{22}x_2 \\ \vdots \\ a_{m2}x_2 \end{bmatrix}+\cdots+\begin{bmatrix} a_{1n}x_n \\ a_{2n}x_n \\ \vdots \\ a_{mn}x_n \end{bmatrix}=\begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{m1} \end{bmatrix}x_1+\begin{bmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{m2} \end{bmatrix}x_2+\cdots+\begin{bmatrix} a_{1n} \\ a_{2n} \\ \vdots \\ a_{mn} \end{bmatrix}x_n$$

odnosno da, rješavajući sustav, imamo linearnu kombinaciju nepoznanica $x_1, x_2, \ldots, x_n$, pri čemu su koeficijenti vektori stupce matrice (Poole, 2006.; Steven, 2006.).

U slučaju da su realni ili kompleksni brojevi elementi matrice A, moguća su samo sljedeća tri međusobno isključiva slučaja za svaki dani sustav linearnih jednadžbi:

- sustav nema rješenja
- sustav ima točno jedno rješenje

- sustav ima beskonačno mnogo rješenja

Sustav oblika $Ax=0$ se naziva homogenim sustavom linearnih jednadžbi. Skup svih rješenja se naziva nul prostorom matrice A. Uočimo da, ako je matrica A regularna, sustav $Ax=b$ ima jedinstveno rješenje $x = A^{-1}b$**.** S obzirom na postojanje izomorfizma između skupa svih matrica i skupa svih linearnih operatora, kineziološki problemi koji se mogu svesti na sustav linearnih jednadžbi su ekvivalentni odgovarajućem linearnom operatoru (Steven, 2006.).

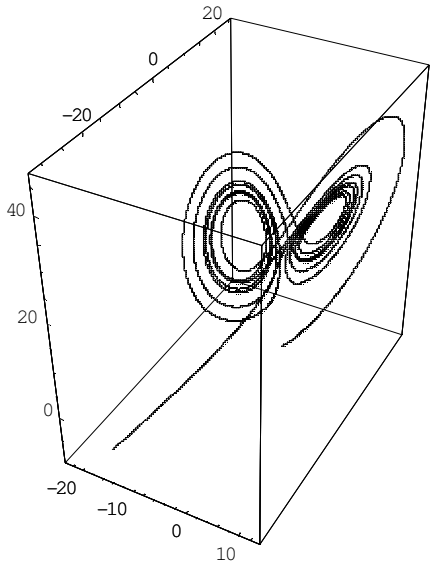
1.1.3.2. Sustavi diferencijalnih jednadžbi

Sustavi diferencijalnih jednadžbi su klasični mehanizam opisivanja dinamičkih sustava i kaotičnih procesa. Tako primjerice, sustav diferencijalnih jednadžbi oblika

$$
\begin{aligned}
&X'(t) = -3X(t) + 3Y(t)\\
&Y'(t) = -X(t)Z(t) + 26{,}5X(t) - Y(t)\\
&Z'(t) = X(t)Y(t) - Z(t)\\
&X(0) = Z(0) = 0, Y(0) = 1.
\end{aligned}
$$

generira rješenje oblika atraktora (Slika 1.4) i najčešće se, variranjem konstantnih parametara i koristi za opisivanje kaotičnih sustava. Napominjemo da sustavi diferencijalnih jednadžbi moraju imati poznate početne uvjete na varijable ($X(0),Y(0),...$) da bi bilo moguće dobiti jedinstveno rješenje.

Slika 1.4: Numeričkim postupkom dobiveno rješenje sustava diferencijalnih jednadžbi



Generalno se sustavi diferencijalnih jednadžbi dijele na linearne i nelinearne i problematični su za praktična razmatranja s obzirom na to da generirani sustavi diferencijalnih jednadžbi često nemaju egzaktna, već samo aproksimativna, numerička rješenja. U kineziologiji i sportskoj znanosti se sustavi diferencijalnih jednadžbi mogu koristiti pri modeliranju kaotičnih sustava u kojima su poznate inicijalne vrijednosti promatranih varijabli ili njihovih fragmenata.

1.1.4. Metode umjetne inteligencije

Umjetna inteligencija je naziv interdisciplinarnog područja istraživanja koje kombinira spoznaje i metode kognitivne psihologije, kineziologije, tehničkih i računalnih znanosti s ciljem razvoja umjetnih sustava koji bi postigli neke karakteristike ljudskog mišljenja. Ovakav pristup u kineziologiji je usmjeren na razumijevanje i objašnjavanje psihičkih procesa koji se odvijaju pri motoričkim aktivnostima, ali i pri modeliranju dinamičkih sustava koji opisuju i reprezentiraju kineziološke procese. Primjene metoda umjetne inteligencije gleda se kao nedovoljno istražen revolucionarni zaokret u psihologiji i kineziologiji (Bartlett, 2006.). Pritom se kineziologija sporta mora baviti motoričkim ponašanjem i temeljnim objašnjenjima uzroka.

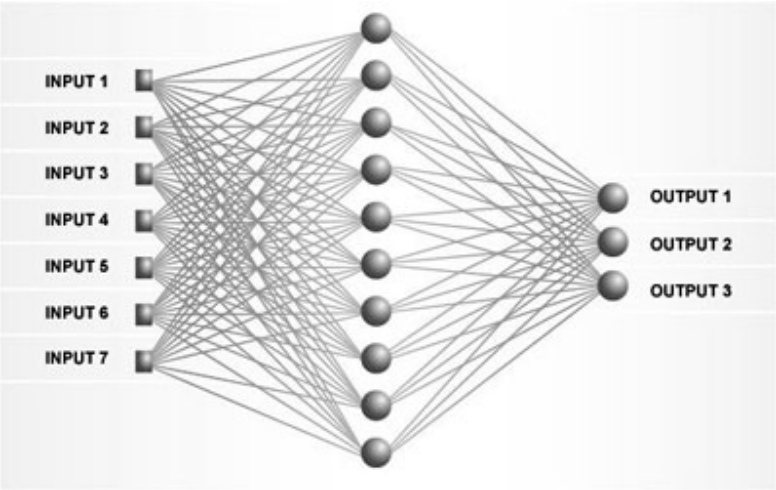
1.1.4.1. Neuronske mreže

Neuronske mreže su sustavi modelirani od procesirajućih elemenata, neurona, po uzoru na mrežu ljudskih moždanih ćelija. Neuronske mreže spadaju u područje umjetne inteligencije (AI – *Artificial Intelligence*), strukturirane da rade na način kao što radi ljudski mozak.

Ključni element ove vrste umjetne inteligencije je specifična struktura obrade informacija, sastavljena od velikog broja međusobno povezanih elemenata obrade, koji zajednički rade na rješavanju problema. Te jedinice su povezane komunikacijskim kanalima, odnosno formalnim vezama. Podaci koji se ovim kanalima razmjenjuju su obično numerički. Neuroni obrađuju samo svoje lokalne podatke i ulaze koje primaju preko konekcije (Negnevitsky, 2002.).

Važna osobina neuronskih mreža je njihova sposobnost učenja na ograničenom skupu primjera te su zbog toga sposobne izaći na kraj sa problemima koji se tradicionalnim pristupom teško rješavaju.

Slika 1.5: Pojednostavljeni prikaz višeslojne umjetne neuronske mreže



Možemo reći da je neuronska mreža zbir neurona koji su međusobno povezani i interaktivni kroz operacije obrade signala.

Umjetna neuronska mreža je građena od međusobno povezanih umjetnih neurona tj. programskih konstrukata sa svojstvima bioloških neurona. Umjetne neuronske mreže se mogu koristiti za razumijevanje bioloških neuronskih mreža ili za rješavanje problema za koji je potrebna umjetna inteligencija, bez potrebe stvaranja modela stvarnog biološkog sustava.

Stvarni, biološki nervni sustav je iznimno složen i uključuje neka svojstva koja mogu biti redundantna za shvaćanje rada umjetnih, neuronskih mreža.

U kineziologiji, neuronske mreže mogu biti korištene za modeliranje kompleksnih kinezioloških te s njima povezanih interakcijskih sustava (Lees, 2002.; Edelmann-Nusser, Hohmann i Henneberg, 2002.; Lees, Barton i Kershaw, 2003.; Perl, 2001., 2005.; Perl i Weber, 2004.). Bartlett (2006.) diskutira problematiku korištenja modela umjetne inteligencije u biomehanici sporta i naglašava da su umjetne neuronske mreže korištene u sportu, ali da njihova potpuna primjena još nije sasvim objašnjena.

1.1.4.2. Evolucijski algoritmi

Evolucijski algoritmi definiraju se kao postupci optimiziranja, učenja i modeliranja, koji se temelje na mehanizmu evolucije u prirodi. Njihov nastanak uzrokovali su prvenstveno pokušaji primjene načela evolucije u prirodi pri rješavanju nekih problema, ali i nastojanja za boljim razumijevanjem same evolucije u prirodi (Eiben i Smith, 2003.; De Jong, 2006.).

Evolucijski algoritmi spadaju u šire područje znanosti o spoznaji (engl. *cognitive science*), a uže, u područje inteligentnih algoritama (engl. *computational intelligence*).

Genetski algoritmi čine jedan je od četiri tipa evolucijskih algoritama. To je heuristička metoda optimiranja, koja oponaša proces evolucije u prirodi. Genetski algoritam je metoda analize koja se temelji na Darwinovoj teoriji evolucije. On započinje nekim skupom jedinki koje posjeduju slučajno generirana svojstva. Za svaku od jedinki pomoću neke metode možemo procijeniti koliko su nam njena svojstva poželjna. One jedinke koje imaju poželjnija svojstva određenim metodama kombiniramo nastojeći im time dodatno poboljšati svojstva.
Genetski algoritmi su iterativni, što znači da im se izvođenje sastoji od nekog broja ponavljanja, pri čemu se u svakoj iteraciji dolazi sve bliže i bliže poželjnom rješenju. Pri svakoj iteraciji promatra se trenutno postojeći skup jedinki (generacija). Nad jedinkama se tada primjenjuju genetski operatori i metode selekcije, pomoću čega se stvara nova generacija.

Najčešću primjenu genetski algoritmi pronalaze na području neuronskih mreža, pri problemima traženja najkraćeg puta, kod problema trgovačkog putnika, problema transporta i raspoređivanja procesa, optimiranja upita nad bazom podataka, itd… (De Jong, 2006.).

Lapham i Bartlett (1995.) analiziraju općenito korištenje metoda umjetne inteligencije i daju smjernice za njihovu upotrebu u biomehanici sporta.

Genetsko programiranje proširuje genetski model učenja na programe. Osnovna je ideja postići da računalo riješi neki problem, a da mu zapravo ne kažemo kako. Postoje brojne sličnosti, ali i neke bitne razlike od genetskih algoritama. Temeljna je ideja ista: stvoriti neku populaciju početnih rješenja (u ovom slučaju programa za rješavanje problema), kroz određeni broj generacija pronaći optimalno rješenje, djelovanjem genetskih operatora i provjeravanjem u kojoj nas mjeri pojedino rješenje zadovoljava.
Kao i kod genetskih algoritama i kod genetskog programiranja postoje parametri koji bitno utječu na izvođenje programa i u njemu se zadaju. To su:

1. SKUP FUNKCIJA I ULAZA

Skup ulaza uglavnom se sastoji od ulaza karakterističnih za promatrani problem i numeričkih konstanti, a skup funkcija, od funkcija koje želimo obavljati nad tim ulazima. Sve su funkcije definirane nad istim tipom podataka, to jest ulaza.

2. POČETNA VELIČINA POPULACIJE

Veličina populacije također spada među ključne parametre za izvođenje programa, a kreće se od 50 pa do više od nekoliko desetaka milijuna jedinki, opet ovisno o problemu koji promatramo.

3. BROJ GENERACIJA

Zadaje se kao i kod genetskih algoritama: brojem iteracija ili duljinom vremena izvođenja.

4. VJEROJATNOST MUTACIJE I SELEKCIJE

Identična je odgovarajućim vjerojatnostima kod genetskih algoritama.

5. MAKSIMALNA POČETNA I KONAČNA VELIČINA STABLA

Velika dozvoljena dubina ili uopće izuzimanje granice veličine stabla može rezultirati nerealno velikim stablima koja će oduzimati puno vremena za izvođenje. Premala stabla opet previše ograničavaju pretragu prostora programskih rješenja.

Evolucijske strategije potencijalna rješenja prikazuju kao konstantno velike vektore realnih brojeva. Broj na određenom mjestu unutar vektora opisuje neku karakteristiku rješenja. Kroz određeni broj generacija opet se pokušava pronaći najbolje rješenje problema korištenjem operatora selekcije i mutacije (Fogel, 1995.).

Za razliku od genetskih algoritama, koji nerijetko rade s populacijama veličine nekoliko tisuća jedinki, u ovom će nam slučaju veličina populacije tipično biti dva: trenutni roditelj i novi kromosom koji je rezultat mutacije nad njim. Suvremene evolucijske strategije ipak ponekad koriste više roditelja i dodatno operator križanja kako bi se izbjeglo eventualno zaglavljivanje rješenja u području nekoga lokalnog optimuma.

Mutacija kod evolucijskih strategija naziva se tipično *Gausijanska mutacija* i obavlja se tako da se svakoj komponenti vektora doda slučajnu varijablu koja poprima vrijednosti prema Gaussovoj ili normalnoj razdiobi. Normalna razdioba zadaje se u potpunosti s dva parametra: μ i σ. Za μ se obično postavlja vrijednost nula, dok se vrijednost σ mijenja iz generacije u generaciju.

Općenito se može stvoriti λ mutacija μ roditelja (nema veze s prethodnim parametrom normalne razdiobe μ) od kojih biramo μ najboljih mutiranih jedinki i prenosimo ih u iduću generaciju. Tada govorimo o (λ,μ)-selekciji. Ako jedinke nove generacije biramo i između roditelja i djece (mutiranih roditelja), tada je riječ o $(\lambda+\mu)$ selekciji.

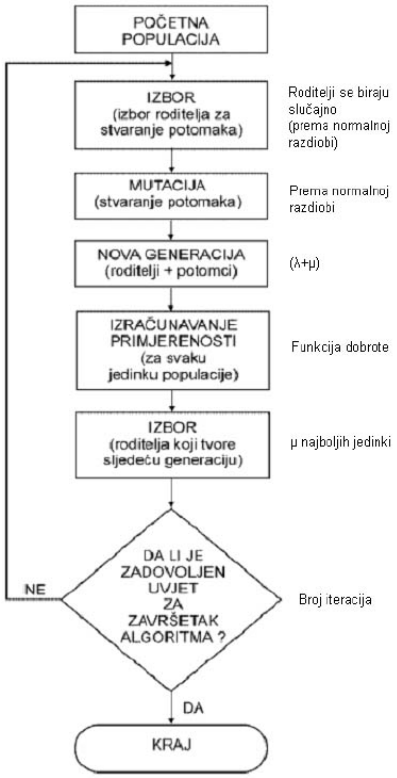
Postupak kreiranja nove generacije možemo opisati kroz sljedeće korake:

1. Stvori novih λ jedinki tako da
    - Odabereš slučajnih $\varsigma \leq \mu$ roditelja
    - Križaš ς roditelja kako bi dobio dijete
    - Odrediš salučajnu novu vrijednost parametra *p* prema normalnoj razdiobi
    - Mutiraš dijete pomoću nove vrijednosti parametra *p*
2. Odaberi novu populaciju na temelju funkcije dobrote iz
    - populacije djece - (λ,μ)-selekcija
    - populacije djece i roditelja - $(\lambda+\mu)$-selekcija

Dijagram tijeka evolucijske strategije prikazan je na slici 1.6.

Glavna razlika između evolucijskog programiranja i ostalih evolucijskih algoritama je u tome da kod evolucijskog programiranja ne postoji razmjena genetskog materijala između jedinki,

Slika 1.6: Dijagram tijeka evolucijske strategije



odnosno, ne koristi se operator križanja, već samo mutacije. Ako to zanemarimo, evolucijsko je programiranje vrlo slično evolucijskim strategijama.

Uobičajena metoda selekcije pri evolucijskom programiranju je da svaku od N jedinki iz generacije mutiramo te dobijemo ukupno 2N jedinki od kojih N najboljih ostavimo za iduću generaciju. Mutacija koja se primjenjuje obično je gausijanska kao i kod evolucijskih strategija.

Evolucijsko programiranje najčešće se primjenjuje na traženje minimuma ili maksimuma funkcija realnih varijabli.

Bartlett (2006.) navodi da primjenama metoda i tehnika umjetne inteligencije (uključivo) evolucijskim algoritmima nije posvećeno dovoljno pažnje u biomehanici sporta.

1.1.4.3. Apstraktni automati

Apstraktni automati su matematičke idealizacije diskretnih deterministčkih procesa. Najčešće su korišteni u tehničkim znanostima za analizu i simulaciju diskretnih problema.

1.1.4.3.1. Deterministički i nedeterministički konačni automat

Konačni automat (DKA, konačni stroj, automat konačnih stanja) je diskretni matematički model koji se sastoji od konačnog broja stanja, prijelaza između tih stanja, i akcija koje obavlja (Booth, 1967.; Arbib, 1969.; Sipser, 1997.).

Konačni automati su najčešće predstavljeni dijagramom stanja, tablicom prijelaza ili ekvivalentno, nizom trojki koje opisuju njegov rad.

DKA se formalno definira uređenom petorkom, (Q,Σ,δ,q_0,F) koja se sastoji od

- konačnog skupa stanja (Q)
- konačnog skupa ulaznih znakova zvanog ulazna abeceda (Σ)
- funkcije prijelaza - $\delta : Q\times\Sigma \to Q$
- početnog (inicijalnog) stanja - $q_0 \in Q$
- skupa prihvatljivih stanja $F \subset Q$. (Booth, 1967.; Arbib, 1969.; Brookshear, 1989.; Sipser, 1997.).

Kineziološki gledano, skup stanja Q predstavlja moguće načine djelovanja, situacije, odnosno stanja pojedinog kineziološkog sustava ili njegovih fragmenta koje modeliramo. Ulazni znakovi su mogući podražaji koji generiraju prelazak u novo stanje, odnosno u novi način djelovanja, tj. rada. Funkcija prijelaza je „mozak“ automata, a u kineziologiji ona predstavlja način reakcije na pojedini podražaj. Inicijalno stanje opisuje početni način djelovanja kineziološkog sustava dok je skup prihvatljivih stanja onaj skup u kojem je poželjno da sustav završi svojim radom.

Neka je M DKA takav da $M = (Q, \Sigma, \delta, q_0, F)$, i $X = x_0 x_1 ... x_n$ niz znakova nad abecedom Σ. M prihvaća niz znakova X ako slijed stanja $r_0, r_1, ..., r_n$ postoji u Q uz sljedeće uvjete:

1. $r_0 = q_0$
2. $r_{i+1} = \delta(r_i, x_i)$ za i = 0,...,n – 1
3. $r_n \in F$

Kao što je pokazano u prvom uvjetu, stroj započinje rad u početnom stanju r_0. Drugi uvjet kaže da će za svaki znak ulaznog niza X stroj prijeći iz trenutnog stanja u stanje upravljano funkcijom prijelaza δ. Posljednji uvjet kaže da stroj prihvaća ulazni niz ako posljednji znak ulaznog niza X uzrokuje prijelaz u jedno od prihvatljivih stanja. Inače kažemo da stroj ne prihvaća (odbija) ulazni niz. Skup nizova znakova koje DKA prihvaća naziva se formalni jezik, i predstavlja oblik jezika koji DKA prepoznaje.

Za dva dana DKAa postoje učinkoviti algoritmi za pronalaženje DKA koji prepoznaje uniju, presjek te komplement jezika koje oni prepoznaju. Postoje također učinkoviti algoritmi za određivanje prihvaća li DKA bilo koji niz znakova, prihvaća li DKA sve nizove znakova, prihvaćaju li dva DKA isti jezik, te za pronalaženje DKA s minimalnim brojem stanja za zadani jezik (Wagner, 2006.).

Pored uporabe u modeliranju reaktivnih sustava poput onih ovdje predstavljenih, uporaba konačnih automata je značajna u mnogim različitim područjima, uključujući elektrotehniku, lingvistiku, računarstvo, filozofiju, biologiju, matematiku i logiku. U kineziologiji konačni automati mogu predstavljati one sustave ili fragmente sustava koji u danom stanju reagiraju na podražaj te prelaze u novo stanje (Tiziano, 1997.).

Stroj može biti opisan i definiranjem formalnog, apstraktnog jezika koji bi sadržavao sve „riječi“ koje stroj prihvaća i nijednu od onih koje odbija; kažemo da tad stroj taj jezik prihvaća. Po definiciji, jezici koje prihvaćaju konačni automati su regularni jezici, tj. jezik je regularan ako postoji neki konačni automat koji ga prihvaća.

Prihvatljivo stanje (ponekad još zvano i prihvaćajuće stanje) je stanje u kojem je stroj uspješno obavio svoj namjenski postupak. Obično je predstavljen dvostrukim koncentričnim krugom.

Daljnja je razlika između deterministčkih (DKA) i nedeterminističkih konačnih automata (NDKA). U deterministčkim automatima, za svako stanje postoji točno jedan prijelaz za svaki mogući ulaz. U nedeterminističkim automatima može postojati više od jednog prijelaza za dani ulaz. Ova je razlika važna u praksi, ali ne i u teoriji jer postoji algoritam koji može pretvoriti svaki NDKA u istovjetni DKA, iako ova pretvorba obično znatno poveća složenost automata.

U drugu ruku, DKA-i su strogo ograničene moći nad jezicima koje mogu prepoznati — mnogi jednostavni jezici, uključujući bilo koji problem čije rješenje zahtijeva više nego konstantan prostor, ne mogu biti prepoznati od strane DKA-a.

U svojoj najvećoj općenitosti DKA-i su predložak modernim metodama kineziologije i psihologije – modeliranja strukturalnim jednadžbama (**S**tructural **E**quation **M**odelling - SEM).

1.1.4.3.2. Turingov stroj

U primijenjenim znanostima pa tako i u kineziologiji, Turingovi strojevi su prikladni za modeliranje diskretnih problema koji se mogu raščlaniti na konačan niz elementarnih operacija, „taktova“. Stoga Turingovi strojevi u kineziologiji mogu pomoći definiranju egzaktne kompleksnosti pojedinih akcija, odnosno transformacija.

Rad Turingovog stroja opisat ćemo i intuitivno i strogo matematički. Intuitivni opis, iako vrlo jednostavan, daje lakši pogled te nam omogućuje lakše razumijevanje formalne definicije, koja mehanizmima matematičke logike objašnjava što je Turingov stroj. Intuitivni opis gubi na svom stvarnom značenju u kategorijama suvremene logike upravo zbog nedostatka logičkog formalizma, koji u dubljoj kineziološkoj primjeni može implicirati da Turingov stroj postaje višeznačan, predeterminiran u svom radu.

Intuitivno Turingov stroj možemo zamisliti kao vozilo na željezničkim tračnicama, u kojem je jedna osoba. Osoba radi na stroju. U radnoj vremenskoj jedinici, „taktu“ svog rada, osoba može pogledati što se nalazi između dva praga, promijeniti dotični sadržaj te pomaknuti vozilo jedan prag lijevo ili desno. Uočavamo da je Turingov stroj taj koji se treba koristiti za opisivanje diskretne stvarnosti.

Formalno, definicija Turingovog stroja je:

Definicija 1.1. (Sipser, 1997.)

Turingov stroj je uređena sedmorka $(Q,\Sigma,\Gamma,\delta,q_0,q_p,q_h)$, pri čemu je:

1. $Q=(q_1, q_2,.., q_n)$ konačan skup čije elemente nazivamo stanja
2. $\Sigma=(w_1, w_2,..., w_m)$ konačan skup čiji su elementi simboli kojima operira stroj-abeceda stroja
3. $\Gamma=(u_1,u_2...,u_k)$ konačan skup čiji su elementi simboli koji se mogu nalaziti na traci-abeceda trake, $\Sigma\subseteq\Gamma$. Ističe se poseban znak $\wedge$, kao oznaka da je polje trake prazno. Znak $\wedge$ nije element abecede stroja, odnosno vrijedi $\wedge\notin\sum$.
4. $\delta : Q\times\Gamma\rightarrow Q\times\Sigma\times\{L,D\}$ funkcija koja definira rad Turingovog stroja - funkcija prijelaza
5. $q_0\in Q$ istaknuto početno stanje
6. $q_p\in Q$ istaknuto završno stanje - stanje „prihvaćanja“
7. $q_h\in Q$ istaknuto završno stanje - stanje „odbijanja“.

Važno je primijetiti da imamo n stanja, te m elemenata abecede stroja, k elemenata abecede trake, naglašavajući tako različitost kardinalnih brojeva (kardinalni broj je „broj“ koji kategorizira skupove po veličini). Greška bi bila algebru kardinalnih brojeva pokušati poistovjetiti s klasičnom aritmetikom.

Funkcija prijelaza δ je centralni kontrolni mehanizam stroja. Oznaka:

$$\delta : Q\times\Gamma\rightarrow Q\times\Sigma\times\{L,D\}$$

govori formalno logički: domena funkcije je uređeni par koji se sastoji od stanja u kojem je Turingov stroj q_i i elementa koji se nalazi na traci u_j tj. (q_i,u_j), a kodomena uređena trojka koja se sastoji od novog stanja Turingovog stroja q_l, novog znaka na traci w_s, te simbola za pomak na traci tj. (q_l,w_s,X), pri čemu je $X\in\{L,D\}$, tj. „pomičemo se“ lijevo ili desno. Dakle, u ovisnosti o stanju q_i u kojem se nalazimo i simbolu na traci u_j idemo u novo stanje q_l, pišemo na traku simbol w_s te se mičemo lijevo ili desno.

Ta činjenica generira da se rad Turingovog stroja u jednom taktu može opisati uređenom petorkom (q_i,u_j,q_l,w_s,X). Kako se rad svakog Turingovog stroja događa unutar konačno mnogo koraka, rad svakog Turingovog stroja može biti opisan konačnim nizom uređenih petorki oblika (q_i,u_j,q_l,w_s,X), $X\in\{L,D\}$. Petorka oblika (q_i,u_j,q_l,w_s,X) je opis djelovanja funkcije prijelaza na elemente domene. Definicija opisuje deterministički Turingov stroj. Transformirana definicija,

koja umjesto funkcije prijelaza sadrži relaciju prijelaza, opisuje nedeterministički Turingov stroj[2], odnosno Turingov stroj kojem u pojedinom koraku nije jednoznačno određeno djelovanje u ovisnosti o stanju i elementu na traci.

Stanja stroja q_i su formalne situacije u kojima se stroj može naći, odnosno načini rada stroja.

Stroj počinje rad u stanju q_0, te ulaskom u stanje q_p ili q_h stroj prestaje s radom. Ako stroj stane u stanju q_p , problem je riješen, a ako stane u stanju q_h , problem je iz nekog razloga ostao neriješen.

Napomenimo da postoje ekvivalentne reprezentacije Turingovog stroja. Jedna od takvih reprezentacija je već spomenuti višetračni Turingov stroj (Sipser, 1997.), koja se u primijenjenoj kineziologiji može koristiti za opisivanje kompleksnih situacija, kada se više „akcija“ radi istovremeno.

Bitno je naglasiti da su sve definicije ekvivalentne, odnosno sve opisuju jednu te istu stvarnost. Dakle, Turingov stroj ne mijenja svoj formalni, logički smisao i rješava istu klasu problema. Može se dokazati da transformirana definicija može riješiti samo one probleme koji su rješivi i prvom definicijom. (Sipser, 1997.). Nadalje, s obzirom na svojstvo Turingovih strojeva da diskretne procese raščlanjuju na elementarne operacije, oni se u teoretskom računarstvu koriste da se definiraju pojmovi tipa složenost algoritma ili procedure, odlučivost i sl. Stoga bi u primijenjenoj kineziologiji oni mogli poslužiti za definiranje mjera kompleksnosti pojedinih kineziloških transformacija pa i čitavih kineziološki analiziranih sustava.

[2] Promotrimo dva izraza koji opisuju formalne matematičke objekte.
Izraz 1:
f (x)=x+5.
Izraz 2:
g(y)=y+1, g(y)=y
Izraz 1 daje jednoznačnu definiciju funkcije f, izrazom x+5, dok izraz 2 sadrži višeznačnu definiciju funkcije g, odnosno definiciju relacije g. Treba primjetiti distinkciju među pojmovima funkcija i relacija, mada su obje f i g definirane domenom i kodomenom, razlikuju se u jedinstvenosti (funkcija) odnosno višeznačnosti (relacija) povezanosti elementa svoje definicije. Vidljivo je kako je svaka funkcija relacija, odnosno skup svih funkcija je pravi podskup skupa svih relacija. Aka sa X označimo skup svih funkcija, sa Y skup svih relacija tada vrijedi $X \subset Y$.

1.1.4.4. Slučajni procesi

U statistici pod pojmom slučajna varijabla podrazumijevamo preslikavanje sa skupa elementarnih događaja u skup realnih brojeva, odnosno $X:\Omega\to R$. Za svaku realizaciju elementarnog događaja slučajna varijabla poprima vrijednosti $X(\omega)$ u skupu realnih brojeva. Pritom se zahtijeva da skup $\{\omega\in\Omega: X(\omega)<a\}$ bude događaj za svaki izbor realnog broja a. Tada je određena njegova vjerojatnost i dobro je definirana funkcija $F(a)=P(X<a)$ koju nazivamo funkcija razdiobe slučajne varijable *X*.

Pojam slučajne varijable neovisan je o vremenu, a mnogi procesi čiji je ishod neizvjestan se odvijaju u vremenu. Stoga takvi procesi zahtijevaju da se koncept slučajne varijable poopći tako da uključuje i vremensku komponentu. Navedeno je naročito prisutno u kineziologiji, koja kao primijenjena i interdisciplinarna znanost proučava procese tijekom vremena. Promatrajući familiju slučajnih varijabli koja ovisi o vremenu, dolazimo do pojma stohastičkog/slučajnog procesa.

Neka je *T* podskup skupa realnih brojeva, koji ćemo promatrati kao skup vremena u kojima promatramo stohastički proces. Za svako vrijeme $t\in T$ određena je slučajna varijabla koju ćemo označavati sa X_t ili sa *X(t)*. Familija tih slučajnih varijabli definira stohastički proces X:

$$X=\{X_t, t\in T\}$$

Stohastički proces možemo shvatiti i kao funkciju dviju varijabli:

$$X: T\times\Omega\to S$$

pri čemu je S skup stanja, odnosno skup unutar kojeg proces poprima vrijednosti. Za izabrani elementarni događaj ω i trenutak *t*, $X(\omega,t)$ je realizacija procesa u trenutku t.

Ako izaberemo fiksni $\omega\in\Omega$, tada preslikavanje $t\to X(t,\omega)$ opisuje realizacije procesa *X* tijekom vremena. Tu funkciju nazivamo trajektorija. Izgled trajektorije se mijenja za svaku drugu realizaciju elementarnog događaja.

Pri proučavanju procesa, obično ih dijelimo po njihovim svojstvima u različite skupine. Temeljna podjela je po prirodi skupova *T* i *S*. Ukoliko je skup *T* zadan po točkama (diskretan), odnosno $T=\{t_1,t_2,...,t_n,...\}$, tada govorimo o nizu slučajnih varijabli. Ako je i skup *S* diskretan, tada govorimo o Markovljevim lancima.

1.1.4.4.1. Markovljevi lanci

Kako je u uvodnim poglavljima rečeno, model je imitacija više ili manje kompleksnog sustava ili procesa stvarnog svijeta. Stoga je s ciljem izgradnje modela sustava ili procesa, potrebno razviti skup strogih matematičkih i logičkih pretpostavki o tome kako sustav radi. Pritom je kompleksnost modela određena kompleksnošću odnosa među raznim parametrima modela.

Važno je naglasiti da je deterministički model u stvarnosti samo specijalan slučaj stohastičkog (slučajnog) modela (Baum i Petrie, 1966.). U znanstvenoj praksi, u društvenim i humanističkim znanostima, odluka želimo li koristiti deterministički ili stohastički model ovisi o tome jesmo li zainteresirani za rezultate jednog jedinog "scenarija" ili za distribuciju rezultata mogućih "scenarija". Deterministički model daje rezultate relevantnih izračuna za jedan scenarij; stohastički model, a tako i Markovljev lanac, daje distribucije relevantnih rezultata za distribuciju scenarija (Guard i sur., 1969.).

Nadalje, da bi se stvorio stohastički model, a tako i specijalno model korištenjem Markovljevih lanaca i odredili prikladni parametri, potrebno je razmatrati podatke i donijeti sud o relevantnosti opaženih podataka na buduće okruženje (Haussler, 1989.). Takvi podaci mogu potjecati od prošlih opažanja, od trenutnih opažanja ili od očekivanja od budućih promjena.

Dok u stvarnosti proces stohastičkog modeliranja ne prati krutu shemu propisanih koraka, kod uvođenja formalizma važno je formalno uobličiti skup ključnih koraka. U praksi se ključni koraci u procesu statističkog i stohastičkog modeliranja, a tako i korištenja modela Markovljevih lanaca, mogu se opisati kako slijedi (Norris, 1998.):

1. Razviti dobro definiran skup ciljeva koje treba ispuniti procesom modeliranja.
2. Planirati proces modeliranja te kako će model biti potvrđen.
3. Prikupiti i analizirati podatke potrebne za model.
4. Prvo definirati model uhvativši bit sustava stvarnog svijeta, a profinjenje razine detaljnosti modela može doći u kasnijoj fazi.
5. Uključiti stručnjake za sustav stvarnog svijeta koji pokušavate oponašati, tako da dobijete povratnu informaciju o vrijednosti konceptualnog modela.

6. Odlučiti o prikladnosti simulacijskog paketa ili općeg jezika za implementaciju modela. Odabrati statistički pouzdan generator slučajnih brojeva koji može biti od pomoći za verifikaciju i validaciju modela.
7. Napisati računalni program za model.
8. Otkloniti greške u programu tako da je sigurno da izvodi zamišljene operacije iz definicije modela.
9. Testirati da li su rezultati modela razumni.
10. Pregledati i pažljivo razmotriti je li model odgovarajući u svjetlu malih promjena u ulaznim parametrima.
11. Analizirati rezultate modela.
12. Priopćiti i dokumentirati rezultate modela.

Velika prednost stohastičkih modela u društvenim i humanističkim znanostima je ta što se kompleksni sustavi sa stohastičkim elementima, kao što je primjerice kompleksna dinamika košarkaške igre, ne mogu dovoljno dobro opisati matematičkim ili logičkim modelom koji je sposoban proizvesti lako interpretabilne rezultate (Giarratano & Riley, 1998.). Stoga je modeliranje simulacije jedan način proučavanja navedene kompleksne dinamike. Nadalje, govoreći o momčadskim sportskim igrama, mogu se primjerice usporediti različiti taktički pristupi tako da se vidi koji od njih generiraju optimalan rezultatski ishod. Također je važno istaknuti da korištenjem stohastičkih modela, a tako i Markovljevih lanaca, možemo bolje kontrolirati eksperimentalne uvjete i na taj način smanjiti varijancu izlaznih rezultata modela bez kvarenja njihovih srednjih vrijednosti (McGarry i Franks, 2001.).

Potrebno je naglasiti da stohastički modeli a tako i Markovljevi lanci nisu jednostavno rješenje za sve realne znanstvene probleme – oni imaju nedostatke koje je potrebno razumjeti prilikom interpretiranja izlaza iz modela. Nedostaci uključuju činjenicu da razvoj stohastičkih modela zahtijeva značajno ulaganje vremena i stručnosti, a dodatno u stohastičkim modelima, tako da i u primjenama Markovljevih lanaca za dani skup ulaza svaka obrada daje *samo procjene* izlaznih rezultata modela. Stoga bi bilo idealno imati nekoliko nezavisnih obrada za proučavanje izlaza za svaki dani skup ulaza. Hsieh, (2009.) navodi kako je čak moguće da model bude korisniji za usporedbu rezultata ulaznih varijacija nego za optimiziranje izlaznih rezultata. Nadalje, najvažniji

problemi Markovljevih lanaca a tako i stohastičkih modela je da se jako oslanjanju na ulazne podatke. Ako je kvaliteta podataka slaba ili nevjerodostojna, tada je vjerojatno da će i izlaz iz modela imati grešku.

Također, kako su modeli po definiciji pojednostavljene verzije „stvarnog svijeta“, mogu zanemarivati perturbacijske odnose “višeg reda” koji kratkoročno imaju mali značaj, ali se dugoročno mogu akumulirati. Primjerice, eksponencijalan rast može se činiti linearnim ako se promatra kroz kratak vremenski period. Odnosno, stabilnost odnosa uključenih u model ne mora dugoročno biti realistična.

Temeljni matematički aspekti Markovljevih lanaca

Promatrano s neformalne strane, stanje modela možemo jednostavno opisati skupom varijabli koje opisuju sustav u određenoj točki u vremenu, uzimajući u obzir ciljeve našeg proučavanja. Također, slučajni (stohastički) proces intuitivno shvaćamo kao model slučajne pojave ovisne o vremenu. Kao što slučajna varijabla opisuje statičku slučajnu pojavu, tako je stohastički proces niz slučajnih varijabli, jedna za svako vrijeme t u nekom skupu J.

Ali, za napredna korištenja slučajnih procesa, posebice Markovljevih lanaca, nužno je uvesti matematički formalizam koji će omogućiti dublji uvid u navedenu kompleksnu materiju.
Markovljevi lanci su specijalan tip diskretnih slučajnih procesa koji računaju vjerojatnost da promatrani sustav u trenutku t, u trenutku $t+1$ bude u nekom drugom stanju sustava i to samo znajući stanje sustava u trenutku t , zanemarujući putanju do stanja u kojem je sustav u trenutku t. Pritom skup svih stanja označavamo sa S.
Matematički, prethodno navedeni iskaz možemo opisati jednadžbom

$$\begin{aligned} P(X_{t+1} = i_{t+1} \mid X_t = i_t, X_{t-1} = i_{t-1}, \ldots, X_1 = i_1, X_0 = i_0) \\ = P(X_{t+1} = i_{t+1} \mid X_t = i_t). \end{aligned} \qquad (1)$$

pri čemu je X_t stanje sustava u trenutku t. Dana formula nam također daje mogućnost izračunavanja vjerojatnosti da će sistem, koji je u stanju i, nakon n vremenskih jedinica (vremena $t + n$), biti u stanju j, što je dano sljedećom formulom

$$P(X_{t+n} = j \mid X_t = i) = P(X_n = j \mid X_0 = i) = P_{ij}(n). \qquad (2)$$

Pritom se standardno koristi oznaka $P_{ij}(n)$ za prijelaznu vjerojatnost iz stanja *i* u stanje *j* u n koraka, odnosno $P_{ij}(n)$ je element na poziciji *(i,j)* u matrici koja opisuje vjerojatnost prijelaza iz stanja *i* u stanje *j* u *n* koraka.
Matrica prijelaznih vjerojatnosti Markovljevog lanca u jednom „koraku“ dana je općim izrazom

$$P = P_{ij}(1) = \begin{bmatrix} p_{1,1} & p_{1,2} & \cdots & p_{1,n} \\ p_{2,1} & p_{2,2} & & p_{1,1} \\ \vdots & & \ddots & \vdots \\ p_{n,1} & p_{n,2} & \cdots & p_{n,n} \end{bmatrix}.$$

Potrebno je naglasiti da se u matrici prijelaznih vjerojatnosti Markovljevog lanca na poziciji *(i,j)* nalazi vjerojatnost da Markovljev lanac koji je u stanju *i* u jednom koraku prijeđe u stanje *j*.

Nadalje, pogledajmo primjerice odvojeno skalarni umnožak prvog vektor-retka i drugog vektor-stupca:

$$\begin{bmatrix} p_{1,1} & p_{1,2} & \cdots & p_{1,n} \end{bmatrix} \cdot \begin{bmatrix} p_{1,2} \\ p_{2,2} \\ \vdots \\ p_{n,2} \end{bmatrix} = p_{1,1}p_{1,2} + p_{1,2}p_{2,2} + \cdots + p_{1,n}p_{n,2}$$

Dobiveni umnošci vjerojatnosti se mogu interpretirati na sljedeći način:

$p_{1,1}p_{1,2}$ - vjerojatnost da Markovljev lanac koji je u prvom stanju ostane u prvom stanju (prvi korak) pa da sustav koji je u prvom stanju prijeđe u drugo stanje (drugi korak);

$p_{1,2}p_{2,2}$ - vjerojatnost da Markovljev lanac koji je u prvom stanju prijeđe u drugo stanje (prvi korak) pa da sustav koji je u drugom stanju prijeđe u drugo stanje (drugi korak).

Analogno tome, za *n*-ti umnožak:

$p_{1,n}p_{n,2}$ - vjerojatnost da Markovljev lanac koji je u prvom stanju prijeđe u *n*-to stanje (prvi korak) pa da sustav koji je u *n*-tom stanju prijeđe u drugo stanje (drugi korak).

Stoga navedene vjerojatnosti zbrojene

$$\sum_{i=1}^{n} p_{1,i}p_{i,2} = p_{1,1}p_{1,2} + p_{1,2}p_{2,2} + \cdots + p_{1,n}p_{n,2} = p_{1,2}^{(2)}$$

daju upravo vjerojatnost da Markovljev lanac koji je u prvom stanju unutar dva koraka prijeđe u drugo stanje. Prethodno razmatranje poopćeno na sva stanja nam govori o činjenici da *k*-ta potencija matrice prijelaza zapravo sadrži prijelazne vjerojatnosti među stanjima Markovljevog lanca u *k* koraka.

$$P^k = P_{ij}(k) = \begin{bmatrix} p_{1,1}^{(k)} & p_{1,2}^{(k)} & \cdots & p_{1,n}^{(k)} \\ p_{2,1}^{(k)} & p_{2,2}^{(k)} & & p_{2,n}^{(k)} \\ \vdots & & \ddots & \vdots \\ p_{n,1}^{(k)} & p_{n,2}^{(k)} & \cdots & p_{n,n}^{(k)} \end{bmatrix}$$

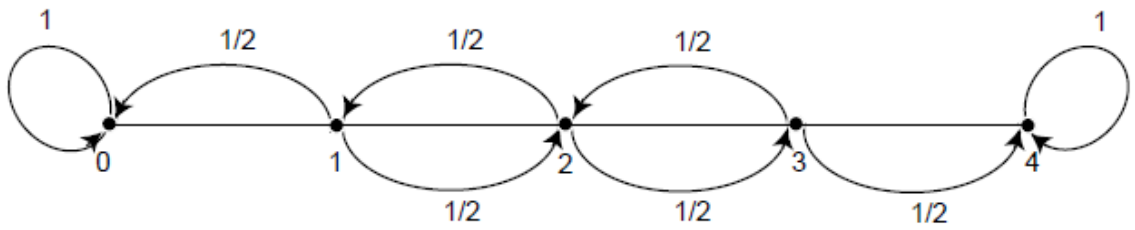
Apsorbirajući Markovljevi lanci

Ako u Markovljevom lancu postoji stanje koje nije moguće napustiti ($p_{i,i}$=1), kažemo da je to stanje apsorbirajuće. Markovljev lanac koji ima apsorbirajuće stanje i ako se u konačno mnogo koraka iz bilo kojeg stanja Markovljevog lanca može doći u apsorbirajuće stanje, kažemo da je Markovljev lanac apsorbirajući. Adsorbirajući lanci, s aspekta primjene jesu važna klasa Markovljevih lanaca. Pritom se stanja koja nisu apsorbirajuća standardno nazivaju tranzitivna.

Na slici 1.7 nalazi se prikaz apsorbirajućeg Markovljevog lanca s pet stanja danog matricom prijelaznih vjerojatnosti

$$P = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 1/2 & 0 & 1/2 & 0 & 0 \\ 0 & 1/2 & 0 & 1/2 & 0 \\ 0 & 0 & 1/2 & 0 & 1/2 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

Slika 1.7



U skladu s definicijom apsorbirajućeg Markovljevog lanca, postavljaju se sljedeća pitanja:

a) Koja je vjerojatnost da će proces završiti u jednom od apsorbirajućih stanja?

b) Koliko će u prosjeku, trebati taktova Markovljevog lanca da proces dođe do apsorbirajućeg stanja?

c) Koliko će u prosjeku biti puta posjećeno svako tranzitivno stanje prije nego što Markovljev lanac dođe do apsorbirajućeg stanja?

U cilju lakšeg odgovora na postavljena pitanja i preglednijeg analiziranja navedenih pojmova, uvodimo kanonsku formu matrice prijelaznih vjerojatnosti formulom

$$P = \begin{bmatrix} Q & R \\ 0 & I \end{bmatrix},$$

pri čemu je matrica P matrica prijelaznih vjerojatnosti ali su stanja renumerirana tako da prvo dolaze tranzitivna (ukupno t tranzitivnih stanja), a nakon toga apsorbirajuća stanja (ukupno r tranzitivnih stanja).

Pri tome je:

- Q – kvadratna matrica reda t
- R – matrica s t redaka i r stupaca
- I – jedinična matrica reda r
- 0 - nul-matrica r redaka i t stupaca

Nadalje, potencija matrice kanonskog oblika matrice P može biti zapisana u obliku

$$P^n = \begin{bmatrix} Q^n & * \\ 0 & I \end{bmatrix}$$

pri čemu koristimo oznaku * za matricu na mjestu matrice R - koja je dobivena potenciranjem. Potrebno je uočiti da se unutar konačno mnogo koraka mora dogoditi da Markovljev lanac dođe do apsorbirajućeg stanja, odnosno, formalno zapisano, u smislu prijelaznih vjerojatnosti među tranzitivnim stanjima

$$\lim_{n\to\infty} Q^n = 0.$$

Također je za apsorbirajuće Markovljeve lance iznimno važno svojstvo da *fundamentalna* matrica koja je opisana izrazom

$$N = (I - Q)^{-1} = \sum_{k=0}^{\infty} Q^n$$

na poziciji *(i,j)* ima očekivani broj dolazaka Markovljevog lanca u stanje *j* ako je krenuo iz stanja *i*.

Tako primjerice za matricu prijelaznih vjerojatnosti danu slikom 1.7 se može dobiti

$$P = \begin{bmatrix} Q & R \\ 0 & I \end{bmatrix} = \left[\begin{array}{ccccc} 0 & 1/2 & 0 & 1/2 & 0 \\ 1/2 & 0 & 1/2 & 0 & 0 \\ 0 & 0 & 1/2 & 0 & 1/2 \\ \hline 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{array}\right], \quad Q = \begin{bmatrix} 0 & 1/2 & 0 \\ 1/2 & 0 & 1/2 \\ 0 & 0 & 1/2 \end{bmatrix}, \quad I = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}, \quad R = \begin{bmatrix} 1/2 & 0 \\ 0 & 0 \\ 0 & 1/2 \end{bmatrix},$$

Pritom se lako izračuna matrica

$$I - Q = \begin{bmatrix} 1 & -1/2 & 0 \\ -1/2 & 1 & -1/2 \\ 0 & 0 & -1/2 \end{bmatrix}.$$

U konačnici se izračunavanjem inverzne matrice lako dobije

$$N = (I - Q)^{-1} = \begin{bmatrix} 3/2 & 1 & 1/2 \\ 1 & 2 & 1 \\ 1/2 & 1 & 3/2 \end{bmatrix}.$$

Uvidom u srednji redak matrice, lagano se vidi da je očekivani broj koraka da lanac dođe redom u prvo, drugo i treće stanje ako je krenuo iz prvog stanja. To su redom 1 korak, 2 koraka i 1 korak.

Također je potrebno naglasiti da se očekivani broj koraka (ako lanac kreće iz stanja *i*) do apsorpcije može izračunati korištenjem formule

$$t = Nc$$

pri čemu je *c* vektor koji se sastoji od samo jedinica (sumacijski vektor), *N* fundamentalna matrica, a *t* vektor dimenzije *n* koji se sastoji od očekivanih broja koraka za svako pojedino početno stanje.

Nadalje, potrebno je naglasiti da su s aspekta primjene Markovljevih lanaca važne još dvije klase Markovljevih lanaca, ergodični i regularni Markovljevi lanci. Definira se da je Markovljev lanac ergodičan ako je moguće iz bilo kojeg stanja doći u bilo koje drugo stanje. Također se Markovljev lanac naziva regularnim ako neka potencija matrice prijelaznih vjerojatnosti ima sve pozitivne elemente. Pritom je potrebno naglasiti da je svaki regularan Markovljev lanac ergodičan, dok suprotna tvrdnja ne vrijedi. Daljnja svojstva Markovljevih lanaca, iako su s aspekta praktične primjene u društvenim i humanističkim znanostima vrlo zanimljiva, nadilaze potrebe ovog rada.

1.2. Problematika jednadžbe uspjeha u momčadskim sportskim igrama

S kineziološkog stajališta, jednadžbu uspjeha u momčadskim sportskim igrama nije moguće objasniti i razumjeti bez strukturne i funkcionalne analize sportske aktivnosti. Strukturna analiza sportske aktivnosti obuhvaća analizu strukturalne složenosti pojedinog sporta. U skladu s time moraju se utvrditi i objasniti: broj i složenost akcija te broj i složenost različitih oblika kretanja (Horga, 2006.). Pritom je važno identificirati tipične i atipične strukture gibanja i situacija te analizu tehničko - taktičkih aktivnosti ili zadataka za pojedine tipove igrača u svim fazama tijeka igre. Također je nužno odrediti uloge igrača kao i unutarnje i vanjsko trenažno opterećenje za pojedine pozicije u igri. Nadalje, potrebno je eksplicitno definirati podfaze unutar faza igre te strukturne jedinice pojedinog polistrukturnog i kompleksnog sporta. S obzirom na to da je uspješnost rješavanja problemskih situacija u momčadskim sportskim igrama ovisna o funkcionalnim odnosima unutar momčadi (kvaliteti suradnje među igračima u okviru odabranog modela taktike igre) te o stvarnoj kvaliteti igrača na različitim pozicijama u igri kao i o obilježjima protivničkih igrača i momčadi, nužno je uporabiti interakcijski pristup objašnjenju individualne i timske situacijske učinkovitosti. Takva funkcionalna analiza polistrukturalnih i kompleksnih sportova istražuje prvenstveno procese interakcije igrača jedne i obiju momčadi, a te pojedinačno razvrstane motoričke aktivnosti primarno su određene akcijama suradnje i suprotstavljanja. Funkcionalnu strukturu momčadske sportske igre moguće je analizirati s

gledišta odnosa tehničko - taktičkog djelovanja, unutar faza tijeka igre i postavljenog modela taktike. U skladu s time, nužno je istražiti odnos suradnja - suprotstavljanje obje momčadi. Dakle, učinkovitost djelovanja pojedine momčadi je ovisna o odgovarajućem modelu taktike igre, koji mora biti u suglasju s cjelokupnim potencijalom te trenutnom stvarnom kvalitetom igrača pojedine momčadi. Pored navedenog, momčad se mora znati samoregulirati i bez neposrednog utjecaja trenera (Trninić, Papić i Dimec, 2008.). Potrebno je istaknuti da kvaliteta sportske individualne i timske izvedbe u momčadskim sportskim igrama nije samo neposredno povezana s razinom razvijenosti cjelokupnog sportaševog potencijala i cijele momčadi, njihovom trenutnom stvarnom kvalitetom, već i s razinom primjerenosti modela taktike igre obje momčadi, razinom uigranosti igrača, trenerovim vođenjem utakmice, uvjetima natjecanja, kriterijem suđenja i drugim vanjskim čimbenicima.

S antropološkog aspekta faktorsku strukturu sporta moguće je svesti na pitanje: Koje temeljne i sportsko - specifične sposobnosti, osobine, znanja, vještine i navike sportaš mora posjedovati kao preduvjet za postizanje učinkovite sportske izvedbe i sportskog postignuća? Inspekcijom dosadašnjih istraživanja (Horga, 1993., Trninić, 1996.) prepoznato je nekoliko problema. Prvi problem se očituje u redukciji čimbenika uspješnosti u sportu na sportaševe antropološke karakteristike. Nužno je potrebno objasniti multikauzalnost modela jednadžbe uspjeha u sportu. Stvarna deficitarnost sadašnje jednadžbe uspjeha u sportu proizlazi iz linearnog modela koji nije dovoljan da bi se spoznaje o interakciji unutarnjih i vanjskih čimbenika uspješnosti u potpunosti shvatile.

Stoga u polistrukturalnim i kompleksnim sportovima za objašnjavanje čimbenika uspješnosti sportaša i cijele momčadi nužno je uporabiti teoriju ili koncept međusobne zavisnosti unutarnjih i vanjskih faktora (Gabrijelić 1977.; Pavlović 1977,; Dežman 1988., 1999.).

Dakle, momčadske sportske igre obilježavaju odnosi međuzavisnosti između pojedinog sportaša i/ili cijele momčadi te glavnog trenera, ali i ponašanje protivničke momčadi. Polistrukturalni i kompleksni sportovi se po odnosima među sudionicima nadmetanja i njihovom ponašanju smatraju autoregulirajućim dinamičkim sustavima (McGarry i Franks, 2007.; Lebed, 2006., 2007.).

1.2.1. Problem odabira modela čimbenika uspješnosti u momčadskim sportskim igrama

U kineziologiji sporta postoji velik broj paradigmi modela čimbenika uspješnosti u sportu. (Filipčić, 1996.; Dežman, 1998.). Primjer adekvatnog paradigmatskog okvira momčadskih sportskih igara oblikovao je Dežman (1998.). Na slici 1.8 prikazani su odnosi osnovnih čimbenika uspješnosti u sportu.

Među neposredne čimbenike navode se kvaliteta natjecanja, vođenje utakmice, uvjeti natjecanja (prilike za igru, kriterij suđenja, ponašanje gledalaca). Nadalje, u posredne čimbenike uspješnosti u sportu su uvršteni: stručni kadar, menadžerski, organizacijski i tehnički kadrovi, roditelji i materijalno - tehnički uvjeti. Dežman, (1998.) u prikazu unutarnjih čimbenika potencijalne uspješnosti igrača ukazuje na postojanje temeljnih, realizacijskih i mobilizacijskih dimenzija. Nadalje, unutarnji čimbenici uspješnosti momčadi uključuju strukturu momčadi, prikladnost modela taktike igre (u obrani i napadu) te razinu pripremljenosti na igru protivničke momčadi. U završnom sklopu općedruštvenih čimbenika koji utječu na potencijalnu uspješnost momčadi uvršteni su: odnos društva prema momčadskim igrama, osnovni uvjeti, razina izobrazbe i organiziranosti stručnog, organizacijskog i tehničkog kadra te razina razvijenosti struke i znanosti (Slika 1.8).

U skladu s navedenim, vjerojatno uspješnost u sportu varira ako se mijenjaju unutarnji i vanjski čimbenici uspješnosti te opći društveni čimbenici. Nužno je pronaći funkciju koja pokazuje kako se mijenja sportaševa izvedba i natjecateljska uspješnost pod utjecajem variranja relevantnih unutarnjih, vanjskih i općih društvenih čimbenika.

Sportska uspješnost u trenutku t se može opisati rekurzivnim formulama:

$SU(t)=F(SU(t-1), UČ(t),VČ(t))$

$UČ(t)=G(SM(t),PMTI(t))$

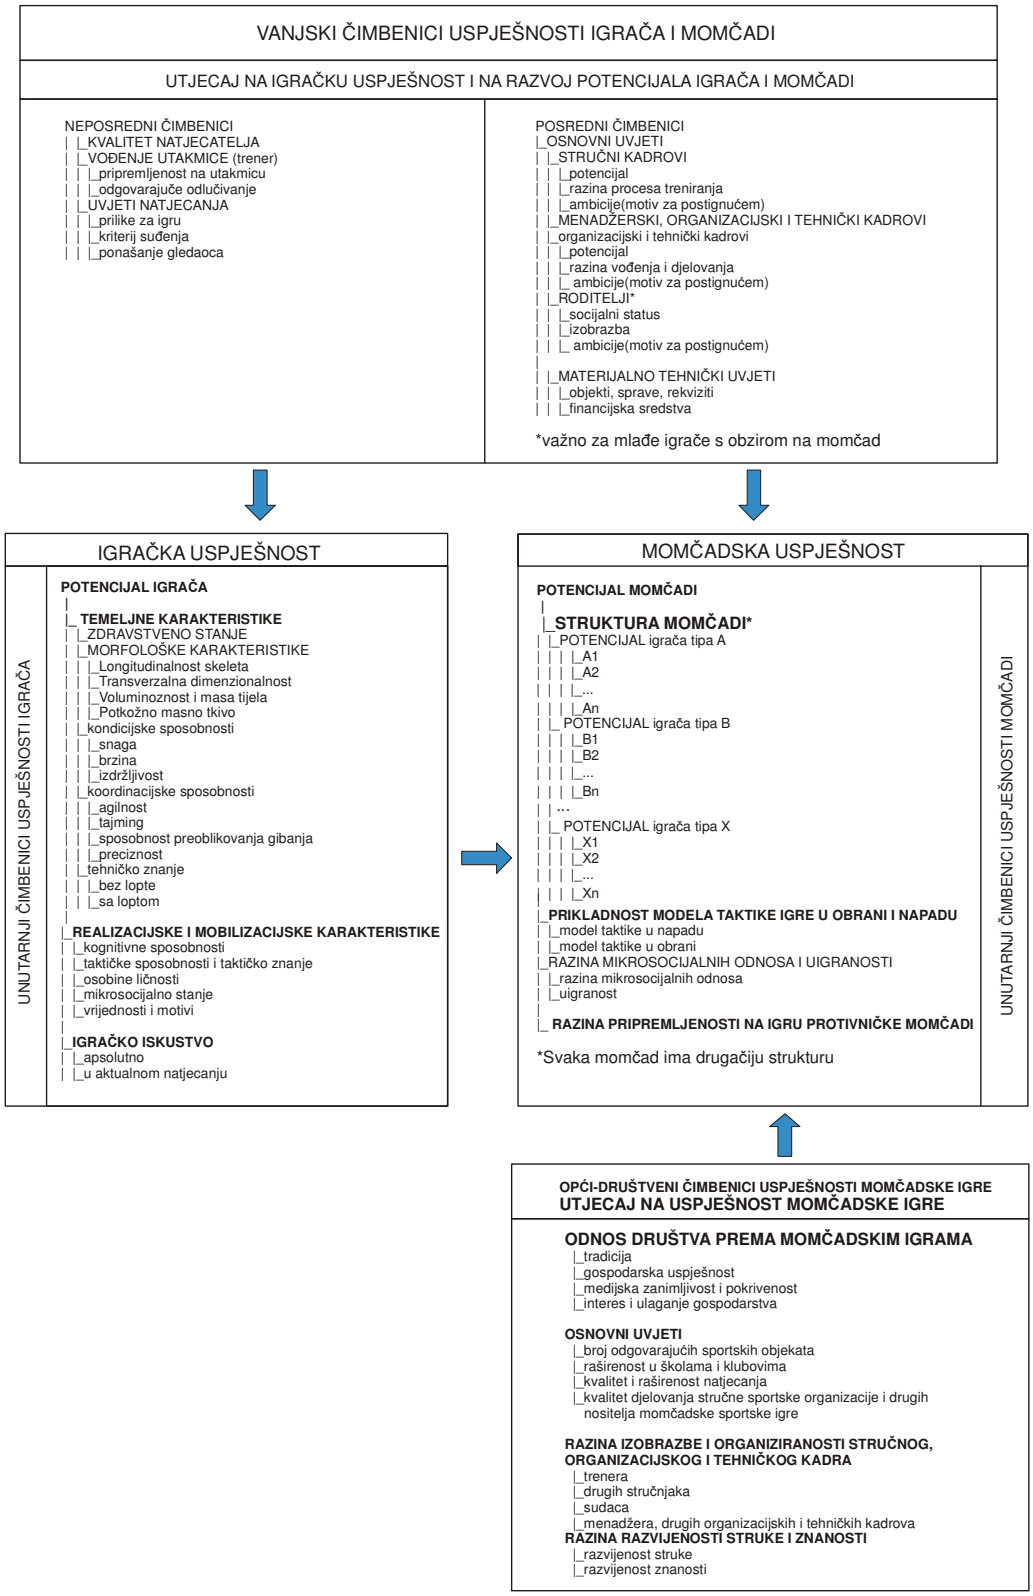
$VČ(t)=H(ODI(t),OU(t),RIO(t), RRS(t))$

gdje je

UČ - unutarnji čimbenici; VČ - vanjski čimbenici; SU – sportska uspješnost; SM - struktura momčadi; PMTI - prikladnost modela taktike igre (u obrani i napadu); RPI - razina

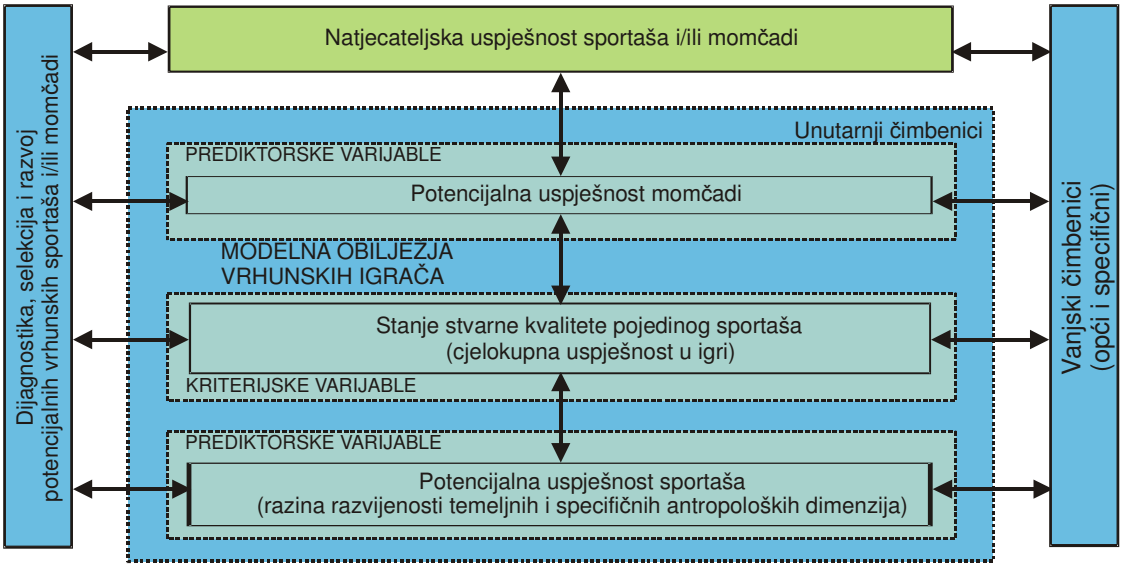
pripremljenosti na igru protivničke momčadi; ODI - odnos društva prema momčadskim igrama; OU - osnovni uvjeti, RIO - razina izobrazbe i organiziranosti stručnog, organizacijskog i tehničkog kadra; RRS - razina razvijenosti struke i znanosti; F, G, H – funkcije koje opisuju odnose među danim varijablama

Slika 1.8. Primjer paradigmatskog okvira pojednostavljenog modela stabla strukture čimbenika uspješnosti u momčadskim sportskim igrama (prema Dežman, 1998.)


VANJSKI ČIMBENICI USPJEŠNOSTI IGRAČA I MOMČADI
UTJECAJ NA IGRAČKU USPJEŠNOST I NA RAZVOJ POTENCIJALA IGRAČA I MOMČADI
NEPOSREDNI ČIMBENICI
|_KVALITET NATJECATELJA
|_VOĐENJE UTAKMICE (trener)
|_pripremljenost na utakmicu
|_odgovarajuče odlučivanje
|_UVJETI NATJECANJA
|_prilike za igru
|_kriterij suđenja
|_ponašanje gledaoca
POSREDNI ČIMBENICI
|_OSNOVNI UVJETI
|_STRUČNI KADROVI
|_potencijal
|_razina procesa treniranja
|_ambicije(motiv za postignućem)
|_MENADŽERSKI, ORGANIZACIJSKI I TEHNIČKI KADROVI
|_organizacijski i tehnički kadrovi
|_potencijal
|_razina vođenja i djelovanja
|_ ambicije(motiv za postignućem)
|_RODITELJI*
|_socijalni status
|_izobrazba
|_ ambicije(motiv za postignućem)
|_MATERIJALNO TEHNIČKI UVJETI
|_objekti, sprave, rekviziti
|_financijska sredstva
*važno za mlađe igrače s obzirom na momčad
IGRAČKA USPJEŠNOST
UNUTARNJI ČIMBENICI USPJEŠNOSTI IGRAČA
POTENCIJAL IGRAČA
|_ TEMELJNE KARAKTERISTIKE
|_ZDRAVSTVENO STANJE
|_MORFOLOŠKE KARAKTERISTIKE
|_Longitudinalnost skeleta
|_Transverzalna dimenzionalnost
|_Voluminoznost i masa tijela
|_Potkožno masno tkivo
|_kondicijske sposobnosti
|_snaga
|_brzina
|_izdržljivost
|_koordinacijske sposobnosti
|_agilnost
|_tajming
|_sposobnost preoblikovanja gibanja
|_preciznost
|_tehničko znanje
|_bez lopte
|_sa loptom
|_ REALIZACIJSKE I MOBILIZACIJSKE KARAKTERISTIKE
|_kognitivne sposobnosti
|_taktičke sposobnosti i taktičko znanje
|_osobine ličnosti
|_mikrosocijalno stanje
|_vrijednosti i motivi
|_ IGRAČKO ISKUSTVO
|_apsolutno
|_u aktualnom natjecanju
MOMČADSKA USPJEŠNOST
UNUTARNJI ČIMBENICI USPJEŠNOSTI MOMČADI
POTENCIJAL MOMČADI
|_ STRUKTURA MOMČADI*
|_POTENCIJAL igrača tipa A
|_A1
|_A2
|_...
|_An
|_ POTENCIJAL igrača tipa B
|_B1
|_B2
|_...
|_Bn
|_ ...
|_ POTENCIJAL igrača tipa X
|_X1
|_X2
|_...
|_Xn
|_ PRIKLADNOST MODELA TAKTIKE IGRE U OBRANI I NAPADU
|_model taktike u napadu
|_model taktike u obrani
|_RAZINA MIKROSOCIJALNIH ODNOSA I UIGRANOSTI
|_razina mikrosocijalnih odnosa
|_uigranost
|_ RAZINA PRIPREMLJENOSTI NA IGRU PROTIVNIČKE MOMČADI
*Svaka momčad ima drugačiju strukturu
OPĆI-DRUŠTVENI ČIMBENICI USPJEŠNOSTI MOMČADSKE IGRE
UTJECAJ NA USPJEŠNOST MOMČADSKE IGRE
ODNOS DRUŠTVA PREMA MOMČADSKIM IGRAMA
|_tradicija
|_gospodarska uspješnost
|_medijska zanimljivost i pokrivenost
|_interes i ulaganje gospodarstva
OSNOVNI UVJETI
|_broj odgovarajućih sportskih objekata
|_raširenost u školama i klubovima
|_kvalitet i raširenost natjecanja
|_kvalitet djelovanja stručne sportske organizacije i drugih nositelja momčadske sportske igre
RAZINA IZOBRAZBE I ORGANIZIRANOSTI STRUČNOG, ORGANIZACIJSKOG I TEHNIČKOG KADRA
|_trenera
|_drugih stručnjaka
|_sudaca
|_menadžera, drugih organizacijskih i tehničkih kadrova
RAZINA RAZVIJENOSTI STRUKE I ZNANOSTI
|_razvijenost struke
|_razvijenost znanosti

Razvoj paradigmatskog modela nužno zahtijeva unapređivanje mjernih instrumenta (nestandardnih specifičnih i situacijskih testova) koji imaju visoku prognostičku uspješnost. S druge strane, hipotetički model interakcije čimbenika uspješnosti sportaša i/ili cijele momčadi moguće je promatrati kroz međudjelovanje većeg broja modula (Slika 1.9).

Slika 1.9. Hipotetički model interakcije čimbenika uspješnosti sportaša i/ili cijele momčadi.



Kada govorimo o unutarnjim čimbenicima uspješnosti, tada mislimo primarno na strukturu potencijalne uspješnosti i stvarnu kvalitetu pojedinih tipova igrača i/ili momčadi (Slika 1.9.). Pritom pojam potencijalna uspješnost igrača čini razina razvijenosti bazičnih i specifičnih antropoloških karakteristika koje utječu na sportaševu uspješnost u igri. Potencijalna uspješnost se dijeli na djelomičnu (trenutačna razina razvijenosti motoričko - funkcionalnih sposobnosti i morfoloških osobina) i cjelokupnu (razina razvijenosti svih relevantnih antropoloških ili psihosomatskih obilježja). Također, uspješnost u igri se može podijeliti na djelomičnu (čimbenici koji se bilježe pomoću statističkog zapisa završnih akcija a nazivaju se pokazatelji situacijske učinkovitosti) i cjelokupnu (čimbenici stvarne kvalitete igrača koje procjenjuju stručnjaci pomoću određenog sustava kriterija). Temelj proučavanja cjelokupne uspješnosti u igri postavila je skupina istraživača (Trninić, 1996.; Trninić, Perica, Dizdar, 1999.; Trninić, Dizdar, 2000.; Trninić, Dizdar, Dežman, 2000.; Trninić, Dizdar, Dežman, 2002.a, 2002.b). Smatramo da se u sustavu procjenjivanja potencijala i trenutačne razine kvalitete izvedbe ili stvarne kvalitete igrača

primarno treba fokusirati na dinamičko a ne statičko evaluiranje. Nadalje, kvaliteta igrača i kvaliteta suradnje koja je određena odgovarajućom taktikom, razinom uigranosti i mikrosocijalnim odnosima primarno određuje potencijalnu uspješnost momčadi, s time da cjelokupna kvaliteta igrača vjerojatno ima najveći koeficijent važnosti (ponder) za potencijalnu uspješnost momčadi koja u konačnici primarno determinira natjecateljsku uspješnost. Dakle, u unutarnje čimbenike pripadaju i razina uigranosti u svim fazama tijeka igre, emocionalni i funkcionalni odnosi među igračima te trenerovo rukovodstveno ponašanje.

Osim unutarnjih, postoji sklop vanjskih ili okolinskih faktora koji neposredno ili posredno utječu na potencijalnu uspješnost pojedinog igrača ili momčadi. U vanjske faktore pripadaju: sportski trening, potencijal i stvarna kvaliteta igrača protivničke momčadi, model taktike protivnika, uvjeti igranja, društvena sredina, domaći ili strani teren, sportski savez, škola, interakcija obitelj - sportaš, interakcija trener - sportaš, način rukovođenja, interakcija obitelj - trener, prijatelji, posebnosti kulture, mediji, javno mnijenje, adekvatnost modela taktike igre, sustav organizacije, sustav stručne politike i logistike sportske institucije, funkcionalni odnosi između igrača, odnosi unutar kluba, mikrosocijalno stanje u momčadi, uvjeti za organizaciju procesa sportske pripreme (Slika 1.9). Nadalje, vanjski faktori se ne mogu promatrati u cjelini kao jedinstveni skup utjecaja, već ih je nužno podijeliti na najmanje dvije komponente: opći (osnovni uvjeti, razina izobrazbe i organiziranosti stručnog, organizacijskog i tehničkog kadra te razina razvijenosti struke i znanosti, utjecaj obitelji, socijalno iskustvo) i specifični (stvarna kvaliteta i model taktike protivnika, kriterij suđenja, utjecaj gledalaca, uvjeti igranja...). Pitanje kakav je utjecaj općih i specifičnih faktora na varijabilitet potencijalne uspješnosti sportaša i potencijalne uspješnosti momčadi. Pretpostavlja se da specifični faktori (npr. djelovanje sportske aktivnosti ili pojedine sportske igre) različito utječu na razinu razvoja sportaševog potencijala. Dakle, učinci pojedinih sportova na promjene sportaševog potencijala ne mogu biti i nisu jednaki jer su različiti zahtjevi na cjelokupni sportašev potencijal, a time i jednadžba uspjeha pojedine sportske aktivnosti. Tako primjerice, što je veći broj tehničko-taktičkih elemenata unutar pojedine sportske aktivnosti i što su u složenijim međusobnim odnosima, time je i kompleksnija jednadžba uspjeha. Pritom interakcija vanjskih i unutarnjih faktora, odnosno njihovo međudjelovanje, diferencijalno djeluje na razvoj i promjenu potencijalne uspješnosti sportaša i/ili momčadi, ovisno i o spolu sudionika. U skladu s time faktori zajedno djeluju na drugačiji način nego što djeluju svaki za sebe. Horga (1993.) tvrdi kako je moguće da jedan faktor poništi djelovanje drugog ili da ga pojača.

Poznato je da vanjski čimbenici mogu poticati ili prigušiti kontinuitet razvoja i sazrijevanje sportaša te da postoji mnoštvo interakcija između unutarnjih i vanjskih čimbenika uspješnosti u sportu. Erčulj, (1998.) navodi da vanjski čimbenici utječu na izraženost unutarnjih čimbenika uspješnosti u sportu te da imaju posredan utjecaj na potencijalnu uspješnost igrača i/ili momčadi. Međudjelovanje unutarnjih i vanjskih čimbenika te procesa sportske pripreme utječe na karakteristike višeg reda koje nazivamo stvarna kvaliteta pojedinog sportaša i/ili momčadi (cjelokupna uspješnost u igri). Za mnoge ekspertne trenere završni rezultat sustava treninga je koliko je sportaš pripremljen za izvedbu te koliko je sportaševa izvedba blizu razini kompetencije i/ili potencijala (Wooden i Jamison, 1997.).

Model hijerarhijske strukture čimbenika uspješnosti sportaša i/ili cijele momčadi može biti formaliziran sljedećim sustavom nelinearnih jednadžbi:

$$SSK = F_1(NUS, UČ, VČ, DIS)$$

$$UČ = F_2(PUS, PUM)$$

$$MOIM = F_3(UČ, SSK).$$

Dakle, natjecateljska uspješnost sportaša i/ili momčadi može se opisati jednadžbom,

$NUS = F_{tot}(DIS, MOIM, VČ)$ odnosno

$$NUS = F_{tot}(DIS, F_3(UČ, SSK), VČ) = F_{tot}(DIS, F_3(F_2(PUS, PUM), F_1(NUS, UČ, VČ, DIS)), VČ)$$

gdje je:

SSK – stanje stvarne kvalitete pojedinog sportaša (igrača na pojedinim pozicijama u igri) i/ili momčadi; NUS – natjecateljska uspješnost sportaša i/ili momčadi; UČ - unutarnji čimbenici;

VČ – vanjski čimbenici; PUS – potencijalna uspješnost sportaša; PUM - potencijalna uspješnost momčadi; MOIM – modelna obilježja igrača i momčadi; DIS – dijagnostika i selekcija potencijalnih vrhunskih sportaša.

Navedeni sustav jednadžbi ne ovisi o vremenskoj varijabli, već je prikazan općim funkcijskim odnosima.

1.2.2. Metodološki problemi istraživanja jednadžbe uspjeha u momčadskim sportskim igrama

Procjena i predviđanje uspješnosti u sportu zahtijevaju multivarijantni pristup, jer je uvijek veći broj karakteristika istovremeno povezan s uspješnošću u sportu (Horga, 1993.). Preciznost jednadžbe specifikacije uspješnosti u sportu ovisi ponajviše o cjelokupnoj metodologiji istraživanja. Također (Horga, 1993.) upućuje da će rješenja biti različite kvalitete s obzirom na različite pristupe konkretnom istraživanju.

Hughes i Bartlett (2002.) upućuju na problematiku optimalnog odabira varijabli pokazatelja uspješnosti izvedbe u kontekstu različitih definicija timske sportske igre.

Silva i sur., (1981.) navode da valjanost predviđanja uspješnosti vrhunskih sportaša može biti potvrđena samo onda kada se identificira sklop psiholoških, fizioloških i motoričkih faktora za neku skupinu vrhunskih sportaša pri ponovljenim istraživanjima.

Temeljni problem dosadašnjih pokušaja definiranja komponenti uspješnosti u sportu se očituje u nedovoljnoj sukladnosti dobivenih podataka, da bi se moglo s izvjesnošću zaključiti što čini model uspješnosti sportaša i/ili momčadi.

U istraživanjima koja su usmjerena na komponente uspjeha u sportskoj aktivnosti (jednadžbe specifikacije uspješnosti u sportu), Matycin i Daškevič, (1988.) tvrde da bi ispitanici trebali biti elitni sportaši. Analizom dosadašnjih istraživanja u sportskim igrama moguće je uočiti da ne postoji velik broj studija na uzorcima elitnih sportaša u momčadskim sportskim igrama koji bi obuhvatili sportsko - specifične varijable.

Sa stajališta metodologije za pojedinu sportsku igru nužna je konstrukcija specifičnih mjernih instrumenata. Bez navedenog koraka nije moguće definirati sportsko - specifična antropološka obilježja, niti utvrditi relacije između bazičnih i sportsko - specifičnih varijabli sportaša (skup prediktorskih varijabli) i njihove stvarne kvalitete (kriterijske varijable) u pojedinoj sportskoj igri. Navedeni neriješeni metodološki problemi imali su za posljedicu nemogućnost određivanja utjecaja bazičnih i sportsko - specifičnih antropoloških varijabli na stvarnu kvalitetu igrača i momčadi te na natjecateljsku uspješnost.

S metodološkog aspekta nužno je riješiti navedene probleme, što zahtijeva unapređivanje mjernih instrumenata u prvom redu usmjerenih za: procjenu sportsko - specifičnih varijabli, razvoj metoda za procjenu cjelokupne uspješnosti u pojedinoj sportskoj igri, usmjerenih na aproksimativno utvrđivanje vanjskih čimbenika na natjecateljsku uspješnost sportaša i sportski rezultat u momčadskim sportskim igrama. Danish i Hale, (1981.), navode niz faktora koji bi mogli utjecati na sportsko postignuće. S njihovog stajališta, istraživanja bi trebala biti metodološki usmjerena na proučavanje neuropsiholoških, biofizičkih, psihosocijalnih i intrapersonalnih faktora.

1.2.3. Istraživanja ishoda suprotstavljanja tehničko - taktičkih modaliteta u situacijskim uvjetima

Košarkašku igru kao strukturiranu aktivnost možemo istraživati sa strukturnog i funkcionalnog stajališta. S jedne strane, strukturna analiza košarkaške igre koristi se u istraživanju strukture gibanja, strukture situacija te u analizi slijeda akcija unutar faza tijeka igre. S obzirom na to da se cjelokupna motorička aktivnost i ponašanje pojedinih igrača realiziraju zadacima ili poslovima u igri, smatramo da se košarkaška igra može opisati kao uređen niz vještina koje se primjenjuju unutar dinamike igre. S druge strane, funkcionalna analiza košarkaške igre istražuje prvenstveno procese interakcije igrača jedne i obiju momčadi, a te pojedinačno razvrstane motoričke aktivnosti primarno su određene akcijama suradnje i suprotstavljanja. Košarkašku igru moguće je analizirati s gledišta odnosa: tehnika - taktika, faza tijeka igre te suradnja i suprotstavljanje (Trninić, 1995., 1996.). U tom kontekstu pojavnost stanja napada možemo promatrati kao posljedicu pojavnosti stanja suprotstavljenih obrana. Pritom važnost utjecaja taktike suprotstavljenih ekipa na manifestaciju stanja igre je nedvojbeno (Rogulj, 2003.).

Iz strukturnih i funkcionalnih istraživanja koja su proveli Hernandez (1987.) i Javier (1992.), vidljivo je da košarka ima specifična strukturna i funkcionalna obilježja prema kojima se razlikuje od ostalih momčadskih sportova, iako pripada skupini sportskih igara kojih je korijen suradnja unutar ekipe te suprotstavljanje protivniku, gdje ubrajamo i nogomet, rukomet, hokej, ragbi i vaterpolo. Važno je istaknuti kako empirijska istraživanja ishoda suprotstavljanja tehničko-taktičkih modaliteta u situacijskim uvjetima nužno zahtjeva ekspertno znanje i iskustvo

kao i poznavanje temeljnih pojmova, kao što su taktičko ponašanje, sruradnja, operativna taktika i strategija.

Trninić (2006.) navodi da je taktika sustav individualnih i momčadskih planiranih akcija i odluka koje se realiziraju uspješnim obavljanjem zadataka svih igrača na svim pozicijama u igri. Taktičko ponašanje zahtijeva prilagođavanje dogovorenih akcija i odluka nepredviđenim događajima tijekom igre, kao i usklađivanje individualnog i momčadskog koncepta igre. Globalni taktički koncept, a time i zadatke u igri s obzirom na tijek igre, moguće je promatrati kroz četiri osnovne faze igre: postavljenu obranu, tranziciju napada, postavljeni napad i tranziciju obrane. Nadalje, ukazuje da se taktiku na planu igre cijele momčadi može točno definirati terminima obavljanja zadataka i uloga, pri čemu bi svaki igrač, prvenstveno s individualnog aspekta, u svakom trenutku trebao znati individualne i kolektivne odgovornosti u igri.

Trninić (2006.) koncept suradnje definira kao ponašanje koje maksimalizira kvalitetu ishoda timske igre te potiče pozitivnu unutarnju "kemiju" momčadi. Isto tako, Gabrijelić (1977.) navodi da se suradnja u momčadskoj sportskoj igri ostvaruje strukturalno putem bipolarne komunikacijske mreže napada i obrane, a funkcionalno putem interpersonalne motoričke komunikacije.

Hernandez, 1987., prema Trninić, 1995., 1996., 2006.) ukazuje kako su parametri koji oblikuju akcije u igri ekipa: pravila igre, tehnika (modeli tehničke realizacije), prostor igre, motorička komunikacija i motorička strategija. Između tih parametara postoji uzajamno zavisan odnos i on oblikuje akciju igre.

Usavršavanje kolektivne taktike, odabir i određivanje uloga i poslova igračima unutar momčadi, kao i razina organizacije igre unutar faza tijeka igre osnovne su brige današnjih trenera a donio ih je rezultatski imperativ.S pozicije teorije igara, o taktici semože govoriti kao o izboru optimalnog djelovanja kojim se osigurava najveća vjerojatnost postizanja cilja (McGarry i Franks, 2007.).

Mogli bismo pretpostaviti kako košarkaška igra zahtijeva strukturu znanja sačinjenu od svih elemenata košarkaške igre, strategije i taktičkih varijanti koje se ostvaruju zadacima ili poslovima u igri i moraju biti organizirane na optimalan i sustavan način.

Hernandez (1987., prema Trninić, 1995., 1996., 2006.) na temelju empirijskih nalaza ishoda suprotstavljenih tehničko -taktičkih modaliteta u situacijskim uvjetima izvodi slijedeće zaključke:

1. Proučavanje razvoja akcije igre, s aspekta tehnike - taktike i obrane - napada, pokazuje se nedovoljnim da bismo mogli shvatiti ukupnost razvoja akcije igre i parametara koji ulaze u akciju igre.
2. Suradnja/suprotstavljanje predstavlja jedan novi model analize, specifičnost koje leži u činjenici sukoba između suparnika.
3. Razvoj akcije igre u momčadskim sportovima, koji su karakterizirani postojanjem komunikacije i protukomunikacije i održavaju se u jednom standardiziranom i stabilnom prostoru (zatvoreno igralište), ovisi o interakciji tehničkih parametara, pravila igre, prostora igre, komunikacije i strategije (koja uključuje taktiku).
4. Pojavljivanje pet navedenih parametra u razvoju akcija igre u momčadskim sportovima (u općenitom obliku i posebno u košarci), viđeno iz perspektive suradnje/suprotstavljanja, pokazuje, u skladu sa provedeno studijom, sljedeće karakteristike:
    - Modeli tehničke egzekucije imaju značenje elemenata koji su u službi strateških odluka igrača i momčadi.
    - Pravila igre su najznačajniji parametri u konfiguraciji momčadskih sportova i slijedom toga u košarci se naročito manifestiraju u ograničavanju prostora igre, određivanju nekih modela tehničke realizacije, interakcije, konačnog rezultata, mreže komunikacije i protukomunikacije, kao i prostora interakcije.
    - Prostor igre ima dvostruki izvor ograničenja: pravila igre i korištenje istih u funkciji razvoja igre. To se manifestira podjelom prostora na polje za napad i polje za obranu, zonu 3 sekunde i crtu 6.25 ili tri poena.
    - Komunikacija, koja ima specifičan karakter za momčadske sportove, označena je kao: motorička komunikacija (direktna i indirektna) ili mreža komunikacija i protukomunikacija te komunikacija gestama i praksemima. Praksem sadrži ključeve interpretacije igre i njenu fundamentalnu aktualizaciju u razvoju akcija igre.
    - Motorička strategija, posjedovanje ili neposjedovanje lopte, fundamentalna je činjenica koja određuje svako moguće strategijsko ponašanje, kako momčadi tako i pojedinih igrača.

- Koncept sociomotoričke uloge viđene iz perspektive dinamike razvoja akcije igre, ujedinjen nizom sociomotoričkih poduloga, određuje sva motorička ponašanja igrača tog sporta.
- Košarka je jedno institucionalizirano situacijsko igračko - motoričko natjecanje u kojem se suprotstavljaju dvije momčadi.
- Ludogram se pokazao vrijednim radnim instrumentom koji nam omogućava upoznavanje strateškog ponašanja igrača i momčadi. To je stoga što je ludogram grafički prikaz kretanja igrača i lopte tijekom utakmice na temelju objektivno prikupljenih podataka o: putanji lopte tijekom igre, broju i tipovima skokova koje izvedu pojedini igrači tijekom susreta, udaljenosti koju pretrče igrači i središtu dinamike razvoja akcije. Taj nam instrument dopušta registraciju ukupnosti situacijskih košarkaških događaja koji se razvijaju u uvjetima utakmice, kako sa stajališta pojedinog igrača, tako i sa stajališta momčadi. To svojevrsno *pismo igre* omogućava da se zabilježi tko zadatke u igri u sklopu određenog modela taktike igre obavlja, a tko ne.
- Metodologija korištena za promatranje razvoja akcija igre u košarci omogućila je istražiti kako se tehnički parametri, pravila igre, prostor igre, prostor igre i motorička strategija manifestiraju tijekom razvoja akcije.
- Tip slika, koje su realizirane, i elaborirani modeli oblika obrade dobivenih podataka mogu biti upotrijebljeni, s nužnim promjenama u skladu s karakteristikama svakog sporta, na većinu momčadskih sportova.
- Nužna je revizija metodologije koja nas mora dovesti do donošenja odluka o igraču i strukturi sportske aktivnosti koja se realizira i to tako da bude ishodište odakle ćemo početi, umjesto da nastavimo s prakticiranjem stereotipnih modela.

Jedan od autora koji je nastojao prikazati funkcionalnu analizu košarkaške igre je i Javier (1992., prema Trninić, 1995., 1996., 2006.). Njegovo teorijsko mišljenje o košarkaškoj igri svodi se na parametre: prostor i podprostori igrališta, lopta, vrijeme igre, bodovanje poena, cilj (koš), pravila igre, razina: motoričke interakcije, tehnika, taktika i strategija (Tablica 1.1). Također Javier (1992.) interpretira bazična znanja i bazične motoričke sposobnosti kao „servis“ tehničkim

znanjima, dok tehnička znanja promatra u kontekstu sredstava taktičkog djelovanja pojedinih igrača. Pored toga naglašava da je kapacitet percepcije i analize pretpostavka za uspješno donošenje odluka u igri, što dopušta izgrađivanje maštovitog i kreativnog igrača. U skladu s tim navodi da funkcionalni pristup analizi košarkaške igre omogućava raščlanjivanje međudjelovanja i međuovisnosti parametara unutar strukture košarkaške igre. Pritom smatra kako postoji unutarnja struktura igre, koju naziva **funkcionalnom strukturom**, a koju obilježavaju interakcije igrača.

Tablica 1.1.: Sumarni prikaz funkcionalne analize košarkaške igre (modificirano prema Javier, 1992.)

PROSTOR IGRALIŠTA	
Površina: pravokutnik, 420 m^2	Smanjen prostor za igru.
Prostor za pojedinačno djelovanje igrača iznosi u prosjeku 42 m^2	Zahtijeva visoku razinu tehničko-taktičkog znanja, brzinu, ravnotežu i kontrolu tijela te sposobnost realizacije.
Neregularni kontakt zabranjen je pravilima	To otvara mogućnost za ispravno i kontrolirano izvođenje tehnike.

PODPROSTORI IGRALIŠTA	
Vanjske crte: dok lopta ne dodirne podlogu, nekoga ili nešto što se nalazi izvan igrališta.	Mogućnost za požrtvovnost s ciljem osvajanja "ničije" lopte. Akrobatski skokovi za vraćanje lopte u igralište.
Središnja linija: stražnje polje i pravilo 8 sekundi	Lopta se ne smije vratiti iz prednjeg (polje napada) u stražnje polje (polje obrane). Maksimalno vrijeme za prijenos lopte iz stražnjeg u prednje polje iznosi 8 sekundi, što potiče agresivnost u obrani.
Krugovi: središnji i dva na crti slobodnih bacanja	Početak prvog dijela susreta (središnji krug). Polukrug pripada izvođaču slobodnih bacanja (periferni krugovi).
Reket: pravilo 3 sekunde i mjesto za skok poslije izvođenja šuta s crte slobodnih bacanja	Smanjuje prednost visokih igrača, ograničava stajanje duže od tri sekunde igračima momčadi koja posjeduje loptu. Razmještaj igrača za skok poslije slobodnog bacanja.
Crta 6.25 m: ubacivanje lopte u koš iz polja za tri poena	Otvaranje i razvlačenje obrane, tijek napada, povećanje prostora za individualno djelovanje igrača.

LOPTA	
Lopta: Manipulacija rukom Dobra prilagođenost Poteškoća kontroliranja jednom rukom Ograničeno napredovanje s loptom (dvostruko vođenje i koraci)	Dopušta kontrolirano manipuliranje. Omogućava uspješnost u individualnim akcijama. Visoka preciznost u dodavanju. Pravila nalažu kažnjavanje nepravilne akcije kada je pojedini igrač u posjedu lopte. Loša hvatanja, nepravilna kretanja u vođenju lopte itd.

VRIJEME	
Dva (2) poluvremena od dva puta deset (2x10) minuta - efektivno vrijeme igranja	
24 sekunde: posjed "žive" lopte na igralištu za realizaciju napada	Sprječava pasivnost igre i kontroliranje rezultata utakmice.
8 sekundi: vrijeme za prenošenje lopte iz obrambenog (stražnje) u napadačko (prednje) polje	Omogućava pritisak obrane na cijelom igralištu.
5 sekundi: za ubacivanje lopte u igru. Pravo držanja lopte u slučaju agresivne obrane	Potiče agresivnost obrane (pritisak na loptu, sprječavanje linija dodavanja i linija kretanja).
3 sekunde: ograničeno zadržavanje igrača momčadi koja posjeduje loptu u reketu protivnika	Smanjuje prednost visokih igrača. Igra je visokog intenziteta s djelomičnim oporavkom tjelesne snage. Odnos akcije i pauze: oko 50% - 50%

CILJ	
Obruč: vodoravni položaj s unutarnjim promjerom 0.45 m	Potrebna je preciznost. Šutiranje zahtijeva: selekciju šuta, ravnotežu, opuštenost itd. Veća udaljenost - manja preciznost.
Gornji rub obruča mora biti postavljen 3.05 m od poda	Morfološke kvalitete igrača.

BODOVANJE POGODAKA	
1 poen: slobodno bacanje	Osobne i tehničke pogreške utječu na rezultat.
2 poena: šut ispod crte 6.25m	Manja udaljenost - veća preciznost.
3 poena: šut iz polja tri poena	Šutevi velike strateške važnosti.

PRAVILA IGRE	
Ograničava kretanje s loptom (dvostruko vođenje i koraci)	Isključuje prednosti napada u prodiranju prema košu, uključujući i dribling.
Sankcioniranje osobnih, tj. neregularnih kontakata, koji ometaju kretanje protivničkog igrača osobnom pogreškom	Postoji dozvola regularnih kontakata u akciji bez lopte ako ta akcija ne dovodi suparnika u podređeni položaj.
Utjecaj osobnih pogrešaka na rezultat utakmice	Tehnička pogreška: dosuđuju se dva (2) slobodna bacanja protivničkoj momčadi. Nesportska pogreška: dosuđuju se dva (2) slobodna bacanja + posjed lopte igraču nad kojim je počinjena. 4 momčadska prekršaja u četvrtini: dva (2) slobodna bacanja. 5 osobnih pogrešaka: isključenje i zamjena igrača.

RAZINA MOTORIČKE INTERAKCIJE	
Pravila igre ograničavaju protukomunikaciju (odnose između suparnika)	Najpoznatije interakcije su: međudjelovanje između suigrača, uključuje i znakove razumljive samo unutar vlastite momčadi.
Postoji sustav sudačkih gestovnih znakova (koji razumiju svi sudionici), sustav gestovnih znakova (gestema) unutar svake momčadi i praktičnih znakova (praksema).	Interakcija trener - igrač: dopuštena samo za vrijeme minute odmora. Interakcija sudaca: međunarodnim gestovnim znakovima (FIBA).
Prevladava praktična direktna komunikacija u vidu suradnje i suprotstavljanja te praktična indirektna komunikacija (gestemična i praksemična).	Rijetke su “čiste” psihomotoričke situacije (primjerice: slobodno bacanje ili situacije 1 na 0)

STRATEGIJA	
Individualno i kolektivno taktičko ponašanje	Nametnuto od trenera u većoj ili manjoj mjeri
Sinkronizacija momčadskih akcija (usklađivanje momčadskog djelovanja u vremenu)	Važnost percepcije i analize situacija, predviđanje, odlučivanje i motoričko rješavanje situacija u igri
Sociomotoričke uloge na igralištu	Specijalizacija igrača ovisno o njihovim antropometrijskim, motoričkim, psihosocijalnim obilježjima i tehničko - taktičkom znanju

TEHNIKA I TAKTIKA	
Napadačka tehnika sa i bez lopte Obrambena taktika	Razvoj osnovnih motoričkih sposobnosti (brzina, snaga, agilnost, koordinacija, fleksibilnost itd.) u svrhu uspješne individualne i timske izvedbe
Važnost tehnike kao sredstva taktike	Tehnika je kod pojedinog igrača sredstvo taktičkog djelovanja u igri i u funkciji je postizanja maksimalne učinkovitosti u obavljanju nekog posla u igri.
Interakcija između tehnike - taktike posredstvom kapaciteta percepcije, odlučivanja i motoričkog rješavanja situacija u igri	Igrač mora primati i analizirati podatke iz različitih situacija koje se javljaju u natjecateljskoj igri i iskazati odgovarajuću odluku preko "kapaciteta egzekucije". Potrebno je poticati percepciju i anticipaciju poteza protivnika[3], jer je to uvjet za uspješno, točno i brzo donošenje odluka u igri i za izgrađivanje maštovitog, kreativnog igrača. Razvijanje isključivo predvidljivog motoričkog obrasca, dakle, ustaljenog načina motoričkog rješavanja situacija u igri, vodi stvaranju robotiziranih igrača, tj. ne potiče sposobnost pronalaženja novih rješenja u igri, prilagodljivost, maštu i slobodne improvizirane završetke akcija u igri.

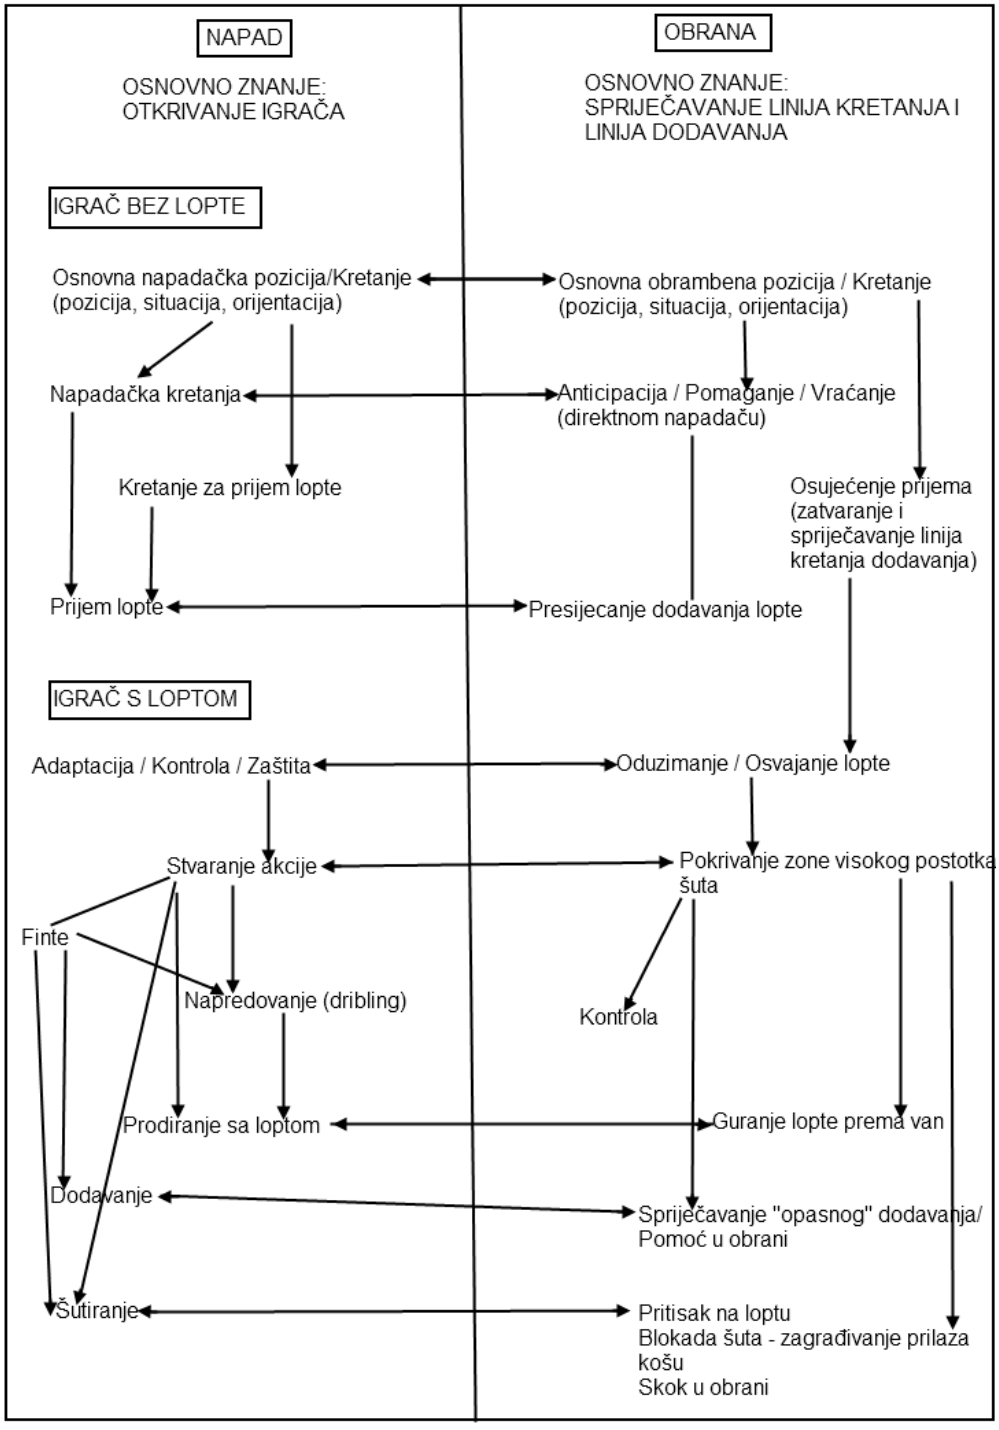
Napomena: S obzirom na to da su mjerenja provedena u momčadima u Top 16 natjecateljske sezone 2009./2010. navedena su pravila košarkaške igre koja su tada vrijedila.

Iz sheme funkcionalne analize taktičkih nakana u košarci vidljivo je da je košarkaška igra rezultat interakcije različitih čimbenika, a to djelovanje produkt je suradnje i suprotstavljanja (slika 1.10). Suradnja i suprotstavljanje odvijaju se u tranzicijskom i postavljenom napadu te u obrani. Primjerice: igrači u tranzicijskoj i postavljenoj obrani surađuju međusobno kako bi organizirali suprotstavljanje tranzicijskom i postavljenom napadu i obrnuto.

Na slici 1.10 pokazana je funkcionalna analiza taktičkih nakana u košarci iz koje je vidljivo da je košarkaška igra rezultat interakcije različitih čimbenika, a to djelovanje produkt je suradnje i suprotstavljanja.

[3] U situacijskim i natjecateljskim uvjetima vjerojatno je najvažnije prepoznavanje međusobnih odnosa igrača u prostoru, kao i mogućih budućih akcija protivnika, a tu funkciju ne obavlja perceptivni faktor, već paralelni procesor (sposobnost edukcije relacija i korelata - Horga, 1993.). Iz košarkaške prakse vidljivo je da optimalno izvođenje akcija, kojima se rješavaju situacije u igri, zahtijeva skladan odnos između usvojenog modela igre na razini navike i prilagodbu naučenog kretanja u rješavanju situacija u igri s obzirom na položaj protivnika.

Slika 1.10: Funkcionalna analiza taktičkih nakana u košarci (Javier, 1992).



Osim navedenih studija, koje su obuhvatile funkcionalnu unutarnju strukturu igre, Hagedorn, Lerenz i Meseck (1982.) su korištenjem uzorka od 37 kvalitetnih košarkaških utakmica izvršili kompjutorsku analizu tipičnih pojedinačnih taktičkih akcija u odnosu na površinu igrališta koja je podijeljena u 46 polja. Utvrđeno je da šutovi s male udaljenosti odlučujuće utječu na rezultat igre zbog povećane vjerojatnosti uspješnosti takvog načina realizacije i veće vjerojatnosti protivničke individualne greške u obrani.

Hajnal (1990.) je korištenjem uzorka 30 košarkaških utakmica podijeljenih u tri kvalitetne skupine analizirao 75 varijabli - pokazatelja individualne situacijske tehničko -taktičke aktivnosti. Varijable su podijeljene u 4 grupe u odnosu na tri karakteristične igračke pozicije te na pripadnost momčadi određenoj kvalitetnoj skupini. Na temelju razlika u faktorskim strukturama grupa varijabli za pojedina igračka mjesta kod ekipa različite kvalitete, autor je predložio primjerene modele individualne taktike.

1.2.3.1. Istraživanja ishoda suprotstavljanja tehničko-taktičkih modaliteta u situacijskim uvjetima u drugim sportskim igrama

Postoje različite studije koje su proučavale strukture kretanja, pokazatelje situacijske učinkovitosti te ishode suprotstavljanja tehničko - taktičkih modaliteta u situacijskim uvjetima u pojedinim sportskim igrama.

Gajić, 1972., prema Rogulj, 2003. je predložio ususatvljenje struktura kretanja u rukometu na temelju analize 40 vrhunskih utakmica.

U odnosu na taktički aspekt utvrdio je da efektivno vrijeme igre iznosi svega 40,37 minuta, odnosno 67,97%. U prosjeku je izvedeno 89 napada na utakmici od čega je bilo 14 protunapada. Napad je prosječno trajao 37,45 sekundi, odnosno 27,44 sekunde u efektivnom vremenu. Odnos uspješnosti realizacije napada bio je približno 2:1 u korist obrane. U prosjeku su izvedena 82 udarca po utakmici, a prosjek postignutih pogodaka je 30. Autor je također pratio učestalost i uspješnost završnice u odnosu na pojedine igračke pozicije, različite daljine šutiranja, faze igre (protunapad-pozicijski napad), izvođenje slobodnih udaraca (sedmerac - deveterac) i u odnosu na način izvođenje (iz skoka - s tla).

U odnosu na tehnički aspekt rukometne igre, autor je utvrdio kvantitetu različitih kretanja i tehničkih elemenata. Najviše je bilo zastupljeno raznog trčanja (77,11%). Igrači su 87,30% vremena utrošili na igru bez lopte, najviše na trčanje kratkih dionica do 5 metara, a na igru s loptom samo 6,95%, od čega se najviše utroši na dodavanja i hvatanja lopte (64%). Igrači su za vrijeme igre u prosjeku izveli 150 pokreta s loptom i pretrčali 2.680 metara.

Rogulj (1985.) je korištenjem uzorka od 67 rukometnih utakmica različitih kvalitativnih razina pratio situacijsku učinkovitost vratara u odnosu na neke tehničko-taktičke značajke udarca. Rezultati ukazuju da je u odnosu na igračku poziciju, najveća efikasnost iskazana kod obrane udaraca s krilnih (43%) i vanjskih pozicija (36,7%), a najmanja iz protunapada (10%) i sedmerca (18%). Nadalje, u odnosu na visinu ulaska lopte u vrata, vratari su bili efikasniji kod obrane poluvisokih udaraca (56%) nego visokih (28%) i niskih udaraca (14%). U konačnici, u odnosu na tehniku izvođenja, zabilježena je efikasnost obrane udaraca iz skoka (30%), a iz koraka s tla (25%). Prosječna efikasnost vratara iznosila je 27%.

Czerwinski, 1998. prema Rogulj, 2003. je korištenjem uzorka Evropskog prvenstva u rukometu 1998. godine analizirao neke statističke pokazatelje igre u napadu i obrani te zabilježio sljedeće prosječne vrijednosti: efikasnost završnice napada (53,7%), efikasnost realizacije iz sedmerca (71%), efikasnost realizacije iz brzog napada (75,3%), efikasnost završnice napada iz skupne suradnje 2 - 3 igrača (50,4%) te efikasnost obrane vratara (34,2%).

Prethodno navedene studije su temeljene na registraciji tehničko-taktičkih parametara bez adekvatnog utvrđivanja njihove učinkovitosti u odnosu na određene situacijske kriterije.Vidljivo je kako nedostaju empirijski nalazi koji obuhvaćaju učinkovitost primjene individualnih, a posebno skupnih i kolektivnih taktičkih djelovanja u situacijskim uvjetima u odnosu na ostale kriterije, kao što su suprotstavljena protivnička aktivnost ili vremenska komponenta igre (Rogulj, 2003.).

Rogulj, 2003. za rukometnu igru, navodi kako taktička aktivnost u širem smislu sadržava:

- procjenu vanjskih uvjeta igre (vremenski uvjeti, vrsta podloge, vrijeme igranja utakmice, način suđenja, utjecaj publike);
- poznavanje i procjenu tehničko-taktičkih, motoričkih, morfoloških i mentalnih značajki naših i protivničkih igrača;

- poznavanje i predviđanje primjene individualnih, skupnih i kolektivnih djelovanja protivničke momčadi u predstojećoj utakmici;
- uočavanje i predikciju situacijskih događanja tijekom utakmice u svrhu pravovremene provedbe ili pripreme primjerenog taktičkog odgovora;
- optimiziranje momčadi u odnosu na vrijednost i specifičnost igrača, značajke i "težinu" pojedine igračke pozicije, te specifičnost i kvalitetu suprotstavljenih igrača na određenim pozicijama.

Nadalje, Rogulj (2003.), u rukometnoj igri, u svrhu utvrđivanja učinkovitosti modaliteta taktičkih djelovanja u uvjetima situacijskog sučeljavanja te njihovog doprinosa rezultatskoj uspješnosti analizira taktičke aktivnosti rukometne igre. Sukladno rezultatima ovog, a i prijašnjih istraživanja, predlaže modele osobnog, skupnog i kolektivnog taktičkog djelovanja, koji se u natjecateljskim uvjetima prepoznaju kao uspješni. Pritom taksativno navodi navodi kako je u fazi napada potrebno:

- što brže započeti napad nakon dolaska u posjed lopte;
- što više koristiti brze kontinuirane napade na neorganiziranu obranu protivnika u vidu protunapada i poluprotunapada;
- kod napada na postavljenu obranu težiti kraćim kontinuiranim napadima, odnosno što prije pokazati cjelokupni napadački angažman, maksimalnu dinamičnost i kinetički potencijal, te ustrajati u visokom intenzitetu i ritmu igre dok se ne izbori mogućnost postizanja zgoditka;
- izbjegavati duge diskontinuirane napade, osim kod izrazito pozitivnog rezultata ili protiv izrazito kvalitetnijeg suparnika;
- izbjegavati prekide napada zbog prekršaja braniča, odnosno održavati dinamičnost i fluidnost napada distribucijom lopte neposredno prije prekršaja u trenucima maksimalne angažiranosti braniča;
- ravnomjerno koristiti sustav s jednim ili dva, a protiv brojnije obrane s jednim kružnim napadačem;
- izbjegavati pretjeranu kombinatoriku u vidu izmjena mjesta, osim kada se igra protiv manjeg ili većeg broja braniča ili protiv kombiniranih obrana;
- učestalo koristiti nabiranja i blokade braniča;

- pozicijski napad na postavljenu obranu prvenstveno temeljiti na osnovnim principima širine i dubine napada, maksimalnoj iskoristivosti prostora, optimizaciji kretanja igrača i lopte, te usklađenom djelovanju što većeg broja napadača u cilju stvaranja prostorno vremenske prednosti na principu "mozaika";
- izbjegavati napad zasnovan na izoliranoj aktivnosti manje skupina igrača;
- napadačku aktivnost dominantno usmjeravati u dubinu, odnosno završnicu napada skupno pozicionirati ka suradnji vanjskih s linijskim igračima, tj. kružnim napadačima i krilima;
- nastojati napade završavati iz blizine s linijskih pozicija, dakle iz izrađenih izglednih prigoda bez suprotstavljanja braniča;
- koristiti individualne akcije u vidu prolaza varkom ili uskokom, ali više kao završnicu kolektivnog djelovanja;
- u pripremi udarca povećavati kut područja šutiranja, približavanjem ili otvaranjem u odnosu na vrata, a izbjegavati zatvaranje kuta;
- dominantno rabiti udarac u donje, a kod naglašenog izlaska vratara i u gornje dijelove vrata, te maksimalno izbjegavati poluvisoki udarac u središnje dijelove vrata.

S druge strane, Rogulj (2003.) taksativno specificira modalitete za fazu obrane:

- što prije uspostaviti organizirani sustav obrane;
- sustav obrane izabrati sukladno antropološkim značajkama braniča, razini uvježbanosti te značajkama igre i napadača suprotstavljene momčadi za svaku utakmicu;
- koristiti više različitih sustava obrane, i što prije promijeniti sustave igre u obrani, ako ne iskazuju očekivanu uspješnost;
- protiv dužih napada manje koristiti obranu 6:0 ili 4+2, a više 3:2:1 ili 5:1 te naročito kombiniranu obranu 5+1;
- preferirati obranu 5:1, posebno protiv sustava igre u napadu s jednim kružnim napadačem, protiv organiziranog i kombinatornog napada te kada brojčano slabiji protivnik primjenjuje sustav igre bez kružnog napadača;
- u načelu obranu 3:2:1 preferirati u prvoj i trećoj četvrtini, posebno protiv kvalitetnih ekipa, obranu 5+1 u drugoj, a 4+2 u završnoj četvrtini utakmice, posebno protiv manje kvalitetnih ekipa;

- protiv brojčano slabijeg napada kvalitetne momčadi protežirati obranu 6:0, a protiv nekvalitetne 3:2:1;
- protiv napada zasnovanog na osnovnim principima igre ili skupnim kombinacijama, izbjegavati plitku obranu 6:0 i kombiniranu obranu 4+2;
- obrambenu aktivnost u načelu usmjeriti ka onemogućavanju organizacije protivničkog napada, odnosno učestalim agresivnim kontaktnim djelovanjem iznuđivati prekide napada i onemogućavati provedbu završnice;
- težiti dubinskoj usmjerenosti obrane, odnosno okomitom rasporedu braniča;
- skupnu obrambenu aktivnost zasnivati na raznim varijantama kontaktnog angažmana te kombiniranim kontaktno-beskontaktnim djelovanjima, u kojima jedan branič ostvaruje aktivni kontakt s izlaskom prema napadaču, a drugi zatvara put lopti blokom;
- onemogućiti završnicu protivniku s povoljnih bliskih pozicija i obrambenim ga djelovanjem udaljiti od vrata;
- nastojati izvršiti pravovremeni izlazak prema napadaču i zaustaviti ga kontaktno, a u protivnom primijeniti beskontaktno djelovanje u vidu bloka lopte;
- maksimalno izbjegavati pasivnost braniča u obrambenim zadaćama;
- koristiti taktička djelovanja vratara primjerena značajkama pojedinog udarca; protiv udarca iz daljine primjenjivati obranu čekanjem neposredno na crti vrata, a protiv udarca iz blizine naglašeni izlazak i obranu u vidu postavljanja ili otvaranja. Naročito izbjegavati branjenje u "međuprostoru", osim protiv udarca s krilne pozicije.

U konačnici, Rogulj (2003.) tvrdi kako navedeni prostor nije imao primjereni stručni i znanstveni interes što je vjerojatno određeno visokim metodološkim zahtjevima provedbe istraživanja taktičkih modaliteta u konfliktnim situacijama, posebno u momčadskim sportskim igrama.

1.2.4. Jednadžba uspjeha u momčadskim sportskim igrama

Primjerena procjena potencijalne uspješnosti i stvarne kvalitete sportaša je preduvjet strukturiranja nelinearne jednadžbe uspjeha te u skladu s time primjerene selekcije i usmjerenog razvoja vrhunskih sportaša. Pritom je važno istaknuti da je hijerarhija čimbenika uspješnosti različita u pojedinom biološkom razvojnom razdoblju te na pojedinim kvalitativnim razinama natjecanja.

Momirović (prema Sabioncello, 1971.) navodi jednadžbu uspjeha s ograničenim brojem relevantnih faktora koji imaju utjecaj na uspješnost u sportu:

$$Zs = A_1 K_b + A_2 F + A_3 K_k + A_4 G + ... + A_{k+1} S + A_{k+2} E$$

Pri oblikovanju hipotetske jednadžbe specifikacije uspješnosti u sportu, pored temeljnih antropoloških obilježja istaknut je i specifični faktor (S) koji egzistira samo za pojedini sport kao i pogreška (E), te nepoznati čimbenici. Pretpostavlja se da što je viša razina natjecanja to su važnije sportsko-specifične dimenzije sportaševe ličnosti (Trninić, Kardum, Mlačić, 2009.).

Cilj kineziološke znanosti je da otkrije temeljne i specifične dimenzije koje utječu na uspješnost u pojedinoj sportskog grani i disciplini.

Sabioncello (prema Horga 1993.) navodi da u čimbenike uspješnosti u sportu pripadaju sportske situacije: faktori treninga (T), objektivni faktori sportske situacije (S_1) (klima, protivnik, suci i slično) te sociološki faktor, odnosno šire socijalne okolnosti u kojima se sportaš nalazi (S_2). Također smatra da (se) kod sportaša treba procjenjivati: motoričke sposobnosti (K), kognitivne sposobnosti (C), ličnost sportaša u užem smislu (L) i motivacijske faktore (M). Navedeni faktori nemaju jednaki doprinos u jednadžbi uspjeha. Pritom Horga navodi da se jednadžba uspješnosti u sportu može formulirati na sljedeći način:

faktori sportske situacije faktori sportaša

$$SU = (A_1T + A_2S_1 + A_3 S_2) + (A_4K + A_5C + A_6L + A_7M)$$

Legenda: Koeficijenti A_i označavaju relativni doprinos pojedinih faktora na uspješnost u sportu.

Malacko i Popović (2001.) navode da prilikom analiziranja čimbenika uspješnosti u sportskim aktivnostima podatak o tome koliko faktora $F_1,...,F_n$ utječe na pojedinu aktivnost predstavlja osnovni zadatak istraživača u području primijenjene kineziologije. Također naglašavaju da se generiranje hijerarhijske strukture antropoloških karakteristika sportaša izvodi primjenom matematičko - statističkih metoda te da je najčešći oblik jednadžbe specifikacije:

$$Y = \sum_{i=1}^{n} a_i F_i + ex,$$

gdje je

Y – uspješnost u određenoj sportskoj aktivnosti

F_i – faktori od kojih zavisi uspješnost u sportskoj aktivnosti, i=1,...,n

a_i – koeficijenti utjecaja pojedinih faktora (doprinosi uspjeha) , i=1,...,n

ex - faktor greške

Također Malacko i Popović, (2001.) upućuju na nedovoljnu istraženost primjene metode modeliranja u kineziološko antropološkim istraživanjima. Pritom tvrde da se matematičko-kibernetičke metode sve više primjenjuju u znanostima (biologiji, medicini, kineziologiji, psihologiji, sociologiji i dr.), smatrajući da buduće linije istraživanja trebaju obuhvatiti područje odgovora koliko su postojeće metode i modeli prikladni na polju kineziološko antropološkog istraživanja.

U skladu s navedenim pretpostavlja se da bi se sustavom diferencijalnih jednadžbi moglo primjerenije opisati visoku složenost unutarnjih i vanjskih odrednica sportaševe izvedbe i natjecateljske uspješnosti te njihovu interakciju u polistrukturalnim i kompleksnim sportovima.

Primjerenost pojedine jednadžbe uspjeha određena je metodologijom istraživanja, izborom eksperata i mjernih instrumenata te uzorkom vrhunskih sportaša u pojedinom sportu. Pitanje je može li jednadžba uspjeha u složenim dinamičkim sustavima (polistrukturalne i kompleksne sportske aktivnosti) prikazati skrivene čimbenike i relacije koji djeluju na natjecateljsku uspješnost sportaša.

Sabioncello (1971.) navodi da čak i kad bi se svi relevantni faktori izmjerili i pomnožili s koeficijentima te sumirali, dobilo bi se teoretski potencijalnu uspješnost u pojedinoj sportskoj aktivnosti. Međutim kad bismo to učinili bez unošenja faktora S (specifična obilježja za pojedini sport) vjerojatno bismo prepoznali da rezultat naše jednadžbe nije suglasan sa sportaševom izvedbom i sportskim postignućem. Ta specifična obilježja, a vjerojatno i specifične ili uske osobine ličnosti nazivaju se sportsko - specifične varijable koje, ako su uključene u jednadžbu uspjeha, smanjuju mogućnost pogreške u predviđanju uspješnosti sportaša i/ili momčadi. Uključivanjem vanjskih odrednica natjecateljske uspješnosti, povećava se točnost predviđanja uspjeha.

Milanović (2004., 2009.) navodi da ako vrijedi relacija:

$$Rs = f(X_i, Y_j)$$

pri čemu su X_i činioci na koje se može utjecati, Y_j činioci kojima se ne može upravljati, Rs rezultat u sportu, tada rezultat u sportu ovisi o faktorima koji su podložni utjecaju treninga (nizak koeficijent urođenosti) i faktorima koji su otporni na utjecaj treninga (visok koeficijent urođenosti). Očigledno je da jednadžba specifikacije uspješnosti u sportu, koja je dobivena korištenjem načela recipročnog determinizma i kaotičnih modela, nužno ukazuje da rezultat u sportu ovisi o faktorima koji su podložni utjecaju treninga i faktorima koji su otporni na utjecaj treninga. Tako primjerice, Malina i Bouchard (1991.), Bouchard, Malina i Perusse (1997.) i navode da su nasljedni faktori (genotiop, predispozicija) različiti za različite faktore od kojih ovisi uspjeh u sportu.

U skladu s time, na varijabilitet natjecateljske uspješnosti u sportu utječu: varijabilitet nasljednih faktora, varijabilitet egzogenih faktora, varijabilitet sportaševe aktivnosti i varijabilitet greške.

Međutim, u momčadskim sportskim igrama pored genskog potencijala sportaša važan je kompenzacijski pristup koji omogućava minimiziranje nedostataka koje ima pojedinac sa stajališta potencijalne uspješnosti.

1.2.5. Prijedlog nelinearnog modela čimbenika uspješnosti u sportu

Pretpostavlja se da bismo sustavom diferencijalnih jednadžbi mogli primjerenije opisati visoku složenost unutarnjih i vanjskih odrednica sportaševe izvedbe i natjecateljske uspješnosti te njihovu interakciju u polistrukturalnim i kompleksnim sportskim aktivnostima. Potrebno je naglasiti da sustavi opisani diferencijalnim jednadžbama moraju kao varijable imati objekte opisane funkcijski, kontinuiranim objektima. To je problem stoga što kineziologija kao primijenjena znanost varijable dobiva mjerenjima, kao konačan diskretan skup normalno distribuiranih podataka. U tom kontekstu moguće je uporabiti kontinuiranu aproksimaciju. Nadalje, prikazana jednadžba specifikacije uspjeha može se shvatiti kao linearni dio razvoja u Taylorov red potencija funkcije n varijabli. Stoga se pretpostavlja da će ponderi u sumi, dobiveni faktorskom analizom biti jednaki koeficijentima dobivenim razvojem u Taylorov red potencija funkcije uspješnosti:

$$Y = f(x_1, x_2, ..., x_n)$$

koja je dobivena rješavanjem nelinearnog sustava (diferencijalnih) jednadžbi, koji u sebi integrira dinamičke relacije među varijablama sustava. Pritom je moguće sustav riješiti numeričkom shemom i dobiti diskretno rješenje (Smith, 1978.) pa ga interpolacijskim tehnikama generalizirati na kontinuirano (Fröberg, 1966.; Kvasov, 2003.; Jelaska, 2005.).

U kontekstu multi-indeksne notacije, zapis razvoja u red funkcije d varijabli, u okolini d-dimenzionalne točke $a = (a_1, ..., a_d)$ bi bio slijedeći (Bermant i Aramanovich, 1975.; Atkinson, 1988.; Bajpai i sur., 1973.):

$$f(x) = \sum_{|\alpha|=0}^{n} \frac{1}{\alpha!} \frac{\partial^\alpha f(a)}{\partial x^\alpha} (x-a)^\alpha + \sum_{|\alpha|=n+1} R_\alpha(x)(x-a)^\alpha \,.$$

Pritom je prvi dio konačna aproksimacija funkcije *f(x)* polinomom *n-tog* stupnja, a drugi dio greška aproksimacije.

Standardno i egzaktno prikazano, zapis se može svesti na:

$$f(x_1,x_2,...,x_d)=\sum_{\alpha_1=0}^{\infty}\cdots\sum_{\alpha_d=0}^{\infty}\frac{(x_1-a_1)^{\alpha_1}\cdots(x_d-a_d)^{\alpha_d}}{\alpha_1!\cdots\alpha_d!}\left(\frac{\partial^{\alpha_1+...+\alpha_d}f}{\partial x_1^{\alpha_1}\cdots\partial x_d^{\alpha_d}}\right)(a_1,...,a_d)$$

Tako primjerice, ako bismo uzeli *d=2*, odnosno da funkcija ovisi o samo dvije varijable *x* i *y*, tada bi Taylorov razvoj u red do uključivo druge potencije u okolini točke (*a*, *b*) glasio:

$$f(x,y)\approx f(a,b)+(x-a)f_x(a,b)+(y-b)f_y(a,b)+$$

$$+\frac{1}{2!}\left[(x-a)^2f_{xx}(a,b)+2(x-a)(y-b)f_{xy}(a,b)+(y-b)^2f_{yy}(a,b)\right]$$

pri čemu smo iskoristili standardne oznake za parcijalne derivacije:

$$\frac{\partial^2 f}{\partial x^2}=f_{xx},\frac{\partial^2 f}{\partial x\partial y}=f_{xy}=f_{yx}$$

Pritom uočavamo da uz drugačiji zapis:

$$f(x,y)\approx xf_x(a,b)+yf_y(a,b)+f(a,b)-af_x(a,b)-bf_x(a,b)$$

$$+\frac{1}{2!}\left[(x-a)^2f_{xx}(a,b)+2(x-a)(y-b)f_{xy}(a,b)+(y-b)^2f_{yy}(a,b)\right]$$

imamo separiran linearni dio od nelinearnog pa bi prva dva člana gornjeg izraza odgovarala nekom dvofaktorskom modelu uspješnosti

$$Y=a_1F_1+a_2F_2+ex$$

uz pondere $a_1=f_x(a,b)$ i $a_2=f_y(a,b)$, dok bi ostali dio ušao u faktor greške *ex*. Sasvim analogno se iščitavaju koeficijenti za model uspješnosti s *n* faktora.

Potrebno je istaknuti da Taylorov razvoj u red može u kompaktnijoj formi biti zapisan u matričnom obliku (Bermant i Aramanovich, 1975.):

$$T(x)=f(a)+(x-a)^T Df(a)+\frac{1}{2!}(x-a)^T\left\{D^2f(a)\right\}(x-a)+...$$

pri čemu je *Df(a)* gradijent funkcije f izračunat u točki *x=a* te $D^2f(a)$ matrica Hesijan.

Bitno je napomenuti da promjenom stupnja aproksimacije, variramo i s njenom preciznošću. Isto tako, nelinearan i recipročan funkcijski odnos varijabli X i Y može biti integriran u dijelu

Taylorovog polinoma koji sadrži potencije varijable X te njene višestruke umnoške s varijablom Y.

1.3. Metodologija istraživanja u kineziologiji

Pri oblikovanju kineziolologije ili sportske znanosti kao temeljne znanosti za područje tzv. fizičke kulture ozbiljan problem bilo je pojmovno određenje te znanosti i argumentacija opravdanosti njenog postojanja, kontinuiteta i važnosti (Mraković, 1971.). Problem se također sastojao u definiranju metodološke orijentacije, posebno u vidu razvoja kineziometrije, odnosno sustava mjerenja, metoda za analizu podataka i informatičke potpore (Momirović, 1972., Mraković, 1971.). Nadalje, problem je bio oblikovanje istraživačke metodologije primjerene rješavanju praktičkih i teorijskih pitanja. Pri njenom utemeljenju istaknuta je važnost teorijskog pristupa istraživanja. U skladu s time poticana su empirijska istraživanja koja imaju tendenciju oblikovanja koherentnih teorija.

Metode i metodologija istraživanja strukturirane su u jedinstvenu metodološku orijentaciju kineziološke znanosti. Nadalje, metode i metodologija istraživanja su determinirane u prvom redu strukturom znanstvenih i stručnih problema. Pritom se temelje na istraživanju zakonitosti i načela transformacijskih procesa. Kineziologija ili sportska znanost inklinira istraživanjima čiji je predmet osobito složen te znanstvenici moraju raspolagati primjereno složenom, učinkovitom i pouzdanom metodologijom. Najveći dio problema kineziološke znanosti može se svrstati u nekoliko linija istraživanja:

1. analiza struktura gibanja
2. analiza struktura situacija
3. dijagnostika potencijalne uspješnosti sportaša i momčadi
4. dijagnostika cjelokupne uspješnosti sportaša i momčadi
5. antropološka prognostika
6. analiza transformacijskih operatora (određivanje sadržaja, modaliteta,opsega i intenziteta aktivnosti usmjerenih prema postizanju cilja).

Pritom se metodološka istraživanja u kineziologiji temelje na:

1. kineziometriji (teoriji mjerenja, konstrukciji novih mjernih instrumenata)
2. kineziološkoj statistici (primjeni statističkih metoda analize podataka i konstrukcija novih metoda)
3. kineziološkoj informatici (izradi programske podrške za informacijske sustave i analizu podataka).

Nadalje sistematska primjena istraživačkih metoda dovodi do prepoznavanja metodoloških principa u kineziologiji:

- Induktivno-hipotetičko-deduktivni pristup
- Mjerljivost veličina i kineziloških pojava
- Multivarijatnost
- Kibernetička i matematička utemeljenost

Dosegnuta iskustva s matematičko - statističkog aspekta kao i brojne aplikacije razvijenih metoda te evolucija programske podrške prema tehnologiji ekspertnih sustava, umjetnih neuronskih mreža poticajno djeluju na razvoj nove metodologije okrenute prema zahvaćanju ekspertnog znanja. Uz uvažavanje spoznajnih dosega umjetne inteligencije, ozbiljno se pristupa definiranju kompjutorske snimke sportske igre, a istražuju se mogućnosti formalnog definiranja sportskih igara (Pavičić, 1991.).

U sistematskoj kineziologiji je prihvaćen i razvijen kibernetički sustav pristupa kineziološkim pojavama i problemima (Momirović, 1969.).

Od 1974. do 1987. godine se u području kineziologije i psihologije sporta (kineziološke psihologije) ističu radovi i rezultati proistekli iz istraživanja kognitivnih funkcija i kibernetički model regulativnih mehanizama ličnosti (Momirović i Ignjatović, 1977.).

Discipline u sportskoj znanosti se međusobno razlikuju po ukupnoj količini relevantnih spoznaja te moraju osigurati molarnu koncepciju koja teži rješavanju problema tj. tendira većim i širim cjelinama gdje se ne gubi smisao cjeline. Dakle, holističko poimanje profesionalnog i stručnog znanja te rješavanje kineziloških problema i fenomena mora biti imperativ kineziološke znanosti.

1.3.1. Svrha metoda istraživanja

Metode istraživanja u kineziologiji omogućavaju rješavanje četiri osnovne grupe problema (deskripcije, eksplanacije, predikcije i utvrđivanja zakonitosti):

1. Deskripcija nije samo opis pojavnih obilježja. To je prikupljen optimalan broj objektivno mjerljivih podataka koji omogućuju i definiranje latentnih struktura koje su u osnovi neke pojave ili procesa.
2. Eksplanacija je postupak utvrđivanja uzroka mehanizama, koji reguliraju neki proces, gdje su kvantitavne veličine tek podloga za utvrđivanje kvalitativnih i strukturalnih obilježja koja su u osnovi neke pojave.
3. Za predikciju nisu dostatne samo informacije o stanju aktualne pojave ili procesa, već informacije o poželjnom stanju. Ciljevi i predikcije u kineziologiji sporta najčešće su natjecateljski (npr. predviđanje natjecateljskog uspjeha u nekoj sportskoj aktivnosti).
4. Da bismo utvrdili zakonitost u polju kineziologije, nužno je oblikovati matematički konstrukt.

1.3.2. Metodološki principi u polju kineziologije

Metodološki principi u kineziologiji su višestruki, tj. postoje različiti pristupi i načela u istraživanju kinezioloških problema i pojava:

1. Hipotetičko - deduktivni pristup polazi od orijentacije da je u istraživanjima nužno prethodno eksplicitno definiranje hipoteza. U skladu s time nužno je adekvatno prikupljanje podataka te provjeravanje statističko-matematičkim postupcima, kako bi se dobiveni rezultati mogli izraziti u obliku matematičkih zakonitosti.
2. Pozitivistički pristup istraživanju kineziloških problema i pojava je usmjeren na „pozitivne činjenice“, koje su stvarne, pouzdano utvrđene. Zasniva se na proučavanju činjenica koje su dostupne osjetima i percepciji. Kineziologijska znanost je ograničena na opažanje činjenica i na zaključke koji se na činjenice odnose i iz njih proizlaze te koje se

mogu empirijski provjeravati. U kineziologiji je pozitivizam najviše izražen u biheviorizmu, u stavljanju težišta na objektivno ponašanje.

3. U kineziologiji se uvijek analizira međusobna zavisnost i povezanost između više varijabli. Strogo univarijatni problemi nužno su posljedica redukcije kompleksnosti proučavanog kineziološkog sustava. Svaki kineziološki problem je multivarijatan bilo da je riječ o subjektu u kojem svaka ljudska karakteristika nema vrijednost sama za sebe, bilo da se analizira sportska aktivnost. Stoga u kineziologiji opstojnost imaju samo one metode koje omogućuju multivarijatnu analizu kineziloških problema koji se mogu podijeliti u dvije skupine. Jedna skupina postupaka namijenjena je analizi zavisnosti jedne ili više zavisnih ili kriterijskih varijabli od nekoliko nezavisnih, prediktorskih varijabli, (npr. višesmjerna i multivarijatna analiza varijance, multipla regresijska analiza). Druga skupina postupaka namijenjena je analizi međuzavisnosti između većeg broja varijabli u cilju njihove racionalne klasifikacije i nalaženja temeljnih dimenzija koje su u osnovi analiziranih varijabli (npr. faktorska analiza, taksonomska analiza, tehnike multidimenzionalnog skaliranja).

Problemi u kineziologiji uvijek su kibernetički i matematički. Izvan kibernetičkih principa obuhvaćenih teorijom sustava, teorijom informacija, teorijom upravljanja, teorijom igara i analizama strategija nema kineziloških problema. Stoga vrijedi pravilo ukoliko neki problem nije tretiran kibernetički i matematički, tada nije znanstveno utemeljen.

2. DOSADAŠNJA ISTRAŽIVANJA

2.1. Istraživanja Markovljevim lancima

U dosadašnjim istraživanjima u kineziologiji sporta i sportskoj znanosti Markovljevi procesi i specijalno Markovljevi lanci su korišteni u rijetkim istraživanjima kao model koji može opisivati razne diskretne i stohastičke sustave u sportu. S gledišta povijesne geneze, Bellman (1977.) je prvi primijenio Markovljeve procese i dinamičko programiranje u modeliranju u bejzbolu. Nadalje, Norman (1999.) radi analizu mogućnosti korištenja Markovljevih procesa pri modeliranju u sportu. Također, Clarke i Norman (1998.a, 1998.b) istražuju primjene raznih stohastičkih tehnika i elemenata teorije odlučivanja na kriket i ragbi.

Također, Bukiet, Harold i Palacios (1997.), analiziraju bejzbolsku igru korištenjem Markovljevih lanaca, formalizirajući pojam „stanja u bejzbolskoj igri“ te pokazuju kako optimalni odabiri udarača mogu povećati vjerojatnost pobjede. U skladu s tim istraživanjem, Hirotsu i Wright (2003.a) prave ekstenziju navedenog modela te korištenjem vjerojatnosnog modeliranja pokazuju kako takav pristup može pomoći pri odabiru optimalnih strategija udaranja. Računanjem sustava jednadžbi s približno milijun nepoznanica, računaju vjerojatnost pobjede ako se sustav nalazi u pojedinom stanju.

Unutar momčadskih sportskih igara, Forbes i Clarke (2004.), konstruiraju Markovljev lanac za analizu ragbi igre sa samo sedam stanja te predlažu mogućnosti njegove ekstenzije u ovisnosti o poziciji lopte na terenu. Mali broj stanja bio je glavno ograničenje navedenog istraživanja te se očito iz danog Markovljevog modela mogla analizirati samo „makro“ struktura ragbi igre. Analizirana stanja su redom: tim A u posjedu lopte, tim B u posjedu lopte, lopta u nedefiniranom posjedu (*Ball in dispute*), zgoditak tima A, zgoditak tima B, tim A u pozadini i tim B u pozadini

Zaključno autori navode da je model prikladan za analizu nakon utakmice te može biti od koristi samim timovima.

U kineziologiji sporta i sportskoj znanosti diskretni slučajni procesi, Markovljevi lanci imaju mogućnost upotrebe (Hirotsu, 2002.; Hirotsu i Wright, 2003.a; 2003.b; Meyer, Forbes i Clarke, 2006.), ali nije specificiran metodološki pristup njihovoj upotrebi u sportskoj znanosti.
Razni primjeri znanstvenih istraživanja strukture poentiranja na temelju vjerojatnosti uključujući identifikaciju optimalne strategije odlučivanja nađeni su u skvošu (Ap Simon, 1951., 1957.; Clarke & Norman, 1979.; Pollard, 1985.; Schutz & Kinsey, 1977.; i Wright, 1988.), tenisu (Croucher, 1982., 1986.; Morris, 1977.; Pollard, 1987.; i Schutz, 1970.), badmintonu (Clarke, 1979.; Renick, 1977.), odbojci (Pfeifer & Deutsch, 1981.) i bejzbolu (Trueman, 1977.). Slijedeći te autore, McGarry i Franks (1994.; 1996.a; 1996.b) su modelirali ponašanje (udarce) u skvošu koristeći Markovljeve lance. Lames je koristio konačne Markovljeve lance u modeliranju sportskih igara uključujući njihov izračun (Kemeny & Snell, 1976.). Napravljene su simulacije za procjenu uspješnosti određenih taktičkih ponašanja kao i procjene izvedbe pojedinih igrača u momčadskim igrama. Ta ideja je primijenjena na tenis, (Lames, 1988.; 1991.), skvoš (McGarry & Franks, 1994.; 1996.a; 1996.b) odbojku (Lames & Hohmann, 1997.; Lames et al., 1997.), stolni tenis (Zhang, 2003.) i rukomet (Pfeiffer, 2003.).

Shirley (2007.) primjenjujući Markovljeve lance na košarkašku igru definira stanja Markovljevog lanca preko tri faktora:
1. Koja momčad ima posjed lopte (domaćin ili gost)
2. Kako je momčad došla do posjeda lopte (ubacivanje lopte iza bočne ili čeone linije, ukradena lopta, napadački skok, obrambeni skok, slobodna bacanja)
3. Broj poena koji je postignut u prošlom posjedu (0,1,2 ili 3)
Najširi mogući model bi imao 2*5*4=40 stanja, ali budući da su određene kombinacije tri faktora nemoguće, model ima 30 stanja. Isključivanjem nekih rijetkih događaja u igri, model ima još manje stanja. Također navodi da se u kontekstu navedenog modela može realizirati vrlo detaljna mikrosimulacija košarkaške igre.

Osnovna obilježja istraživanja u sportskoj znanosti koja su kao metodološki alat koristili Markovljeve lance

Istraživanja koja koriste diskretne stohastičke procese i specijalno Markovljeve procese/lance kao metodološki alat su vrlo rijetka i korištena su u sportovima koji su, makar djelomično, diskretni (bejzbol, kriket). Potrebno je naglasti kako pod pojmom diskretnost podrazumijevamo da je sport moguće analizirati kroz niz odvojenih taktova-stanja. Za momčadske sportske igre, kontinuiranog tijeka (košarka, nogomet, rukomet, odbojka, hokej, ragbi, vaterpolo,…) iznimno je teško diskretizirati kontinuirani tijek kompleksnih interakcija među stanjima pojedine igre. To je naročito stoga što navedena diskretizacija zahtijeva interdisciplinarnu ekspertnu analizu strukture tijeka pojedine momčadske sportske igre, a unutar softvera implementirani algoritmi koji analiziraju pojedini momčadski sport još uvijek nisu u mogućnost u potpunosti detektirati stanja unutar pojedine momčadske sportske igre.

2.2. Istraživanja košarkaške igre

Na temelju uvida u dosadašnja istraživanja košarkaške igre, moguće je razlikovati nekoliko osnovnih pravaca istraživanja

1. Istraživanja s ciljem utvrđivanja relacija pokazatelja situacijske uspješnosti i konačnog natjecateljskog rezultata

Cilj ovih istraživanja bio je ispitati jesu li pojedini pokazatelji situacijske aktivnosti povezani s konačnim rezultatom utakmice te u kojim su elementima situacijske učinkovitosti pobjedničke ekipe uspješnije od poraženih. U skladu s navedenim, Trninić (1995.), naglašava potrebu povezivanja znanstvenog istraživanja sa stručnim analizama igre na video zapisima. Ova istraživanja, između ostalog, pokušavaju pronaći karakteristične modele igranja, što ima značajnu spoznajnu i uporabnu vrijednost u košarkaškoj praksi te doprinose racionalnom upravljanju trenažnog procesa vrhunskih košarkaša i povećanju učinkovitosti pripreme.

Gomez, Lorenzo, Bakarat i sur. (2008.) koriste uzorak od 306 utakmica od 18 timova, natjecateljske sezone 2004./05. Diskriminacijsku analizu koriste za razlikovanje pobjedničkih i poraženih timova. Rezultati ukazuju na činjenice da su za utakmice kod kuće prikladni prediktori

uspjeha obrambeni skok i asistencije. Za utakmice u gostima prediktori uspjeha su obrambeni skok, asistencije, uspješan šut za 2 poena i neuspješan šut za 3 poena.

Gomez, Lorenzo, Sampaio i sur. (2008.) koriste uzorak od 306 utakmica od 18 timova, natjecateljske sezone 2004./05. Diskriminacijska analiza je korištena za razlikovanje pobjedničkih i poraženih timova, ali u odnosu na balansiranu igru (<=12 poena razlike) i nebalansiranu (>12 poena razlike). Rezultati ukazuju da je za balansirane utakmice prediktor uspjeha skok u obrani dok su za nebalansirane utakmice prediktori uspjeha skok u obrani, uspješan šut za 2 poena te asistencije.

Ibanez i sur. (2008.) koriste uzorak od 870 utakmica odigranih između 2001./02. i 2005./06. u španjolskoj košarkaškoj ligi. Korištenjem diskriminacijske analize boljih i lošijih timova u prostoru standardnih pokazatelja situacijske učinkovitosti, pokazuju da su varijable koje najviše diskriminiraju asistencije, ukradene lopte i blokade šuta. Diskriminacijska funkcija je ispravno klasificirala 82,4% entiteta.

Sampaio i Janeira (2003.) na uzorku od 353 utakmice portugalske lige i 56 utakmica doigravanja, koriste diskriminacijsku analizu u odnosu na bliske utakmice (1-8 poena razlike), balansirane (9-17 poena razlike) i nebalansirane (više od 18 poena razlike) i igru kod kuće ili u gostima. Pritom zaključuju da kada se igraju ligaške utakmice kod kuće prediktori uspjeha su prekršaji, neuspješan šut 2 i 3 poena, uspješna slobodna bacanja, skok u napadu. Kad se igraju ligaške utakmice u gostima, prediktori uspjeha su: prekršaji, neuspješan šut za 3 poena, uspješna slobodna bacanja, skok u obrani, ukradene lopte. Za utakmice doigravanja kod kuće prediktori uspjeha su prekršaji, dok su za one u gostima uspješan šut 3, neuspješna slobodna bacanja i skok u napadu.

Trninić i sur. (2002.) koriste uzorak od 36 utakmica u razdoblju od 1992 do 2000, final- four. Diskriminacijska analiza pobjedničkih od poraženih ekipa ukazuje na varijable skok u obrani neuspješan šut za 2 i 3 poena.

Melnick, (2001.) korištenjem korelacijske analize, određuje odnose među asistencijama i omjerom pobjeda i poraza u 5 sukcesivnih NBA sezona. Rezultati ukazuju da asistencije objašnjavaju 36% varijance u omjeru pobjeda i poraza.

Trninić i Dizdar (1999.) koriste diskriminacijsku analizu za identifikaciju i objašnjenje razlika europske i američke vrhunske sveučilišne košarke u prostoru 12 standardnih pokazatelja situacijske uspješnosti. Rezultati ukazuju na činjenicu da vrhunske američke sveučilišne ekipe u odnosu na vrhunske europske ekipe u završnici doigravanja imaju znatno više asistencija, izgubljenih lopti, skokova u napadu te neznatno više osvojenih lopti, skokova u obrani i šutova za tri poena uz nešto viši postotak šuta. Europske vrhunske ekipe u završnici doigravanja imaju veći broj osobnih pogrešaka i slobodnih bacanja.

Filipovski (1999.) analiziraju četiri utakmice završnog turnira Europske lige u Rimu 1997. god. i pritom pokušavaju eksplicirati odnose između primarnih protunapada, ranih protunapada i postavljenih napada najboljih europskih košarkaških momčadi. Koriste korelacijsku analizu i analizu proporcija. Utvrđeno je da su osvojene lopte temeljna pretpostavka za primarni protunapad jer sudjeluju s 45,7% u ukupnom broju protunapada, dok je nakon skoka u obrani izvedeno 50,8% protunapada. Najmanje protunapada izvedeno je nakon blokade šuta (1,7%) i nakon primljenog koša (3,5%).

Lidor i Arnon (1997.) analiziraju 2. europsko juniorsko prvenstvo u košarci do 22. godine. Korelacijskom analizom pokazuju da su varijable značajno korelirane s finalnim rezultatom: prekršaji napravljeni od tima i na timu.

Trninić, Milanović i Dizdar (1997.) koriste diskriminacijsku analizu pobjedničkih i poraženih ekipa na svjetskom košarkaškom prvenstvu u Kanadi 1994. na uzorku od 64 utakmice. Dobiveni rezultati ukazuju da su pobjedničku ekipu najbolje definirale varijable skok u obrani, uspješno ubacivanje lopte u koš za dva poena, asistencija i uspješna slobodna bacanja, dok su poraženu ekipu opisale varijable neuspješnog ubacivanja lopte u koš za dva poena i neuspješno ubacivanje lopte za 3 poena.

Trninić, Milanović, Blašković, Birkić i Dizdar (1995.) primijenjuju regresijsku analizu na 64 utakmice svjetskog košarkaškog prvenstva u Torontu 1994. godine. Pritom je rezultat košarkaške utakmice bio definiran binarnom varijablom pobjeda-poraz. Rezultati regresijske analize pokazali su značajan utjecaj skokova u obrani i napadu na konačan rezultat košarkaše utakmice.

Pleslić (1994.) koristi uzorak od 20 košarkaških utakmica igranih na europskom prvenstvu u Zagrebu 1989. Primjenjuje se regresijskom analizom uz dvije kriterijske varijable: rang (pobjeda-poraz) i razlika (odnos između danih i primljenih koševa). U predikciji kriterija rang i razlika kao

najznačajnije u oba slučaja izdvojile su se varijable uspješnog ubacivanja lopte u koš iz prostora reketa, s poludistance i s linije slobodnih bacanja.

Dizdar (1997.) na uzorku od 56 utakmica hrvatskog košarkaškog prvenstva odigranog 1994./95. godine, u prostoru 13 standardnih situacijskih varijabli koristi regresijsku analizu, modificiranu metodologiju. Rezultati ukazuju da je moguće iscrpnije i potpunije utvrđivati relacije situacijskih varijabli na konačan rezultat u košarkaškoj igri. Predlaže se primjena predložene metodologije i u drugim ekipnim sportovima, kao i u individualnim sportovima gdje postoji neposredan sukob s protivnikom.

Varca (1980.) diskriminacijskom analizom istražuje razlike u nekim situacijskim varijablama koje postižu ekipe s obzirom na to da igraju na svojem ili gostujućem terenu (domaći - gosti). Rezultati pokazuju da su ekipe na svom terenu imale značajno više blokada šuta a značajno manje osobnih pogrešaka. Pritom su na utakmicama na protivničkom terenu ekipe imale znatno više osobnih pogrešaka, a manje osvojenih lopti i blokada šuta. Predloženo je računanje indeksa frustracije.

Milanović (1978.) koristi uzorak od 26 utakmica košarkaškog prvenstva bivše Jugoslavije. Regresijskom analizom pokazuje utjecaj četiriju situacijskih varijabli ubacivanja lopte u koš s različitih udaljenosti te 11 situacijskih varijabli ubacivanja lopte u koš različitim načinima na konačan rezultat u košarkaškoj igri.

A.H. Ismail, (prema Trniniću, 1975.) korelacijskom analizom istražuje relacije frekvencija uhvaćenih lopti u fazi obrane i napada u odnosu na konačan rezultat u košarkaškoj igri. Potvrđena je statistički značajna povezanost frekvencije uhvaćenih lopti s konačnim rezultatom u košarkaškoj igri.

Trninić (1975.) koristi korelacijsku analizu na uzorku od 25 utakmica 1. savezne košarkaške lige, 1973./74. Pritom rezultati ukazuju na korelaciju između frekvencija uhvaćenih lopti u fazi obrane i fazi napada, korelaciju frekvencija uhvaćenih lopti u fazi obrane i napada s konačnim rezultatom košarkaške igre te malu korelacija frekvencije uhvaćenih lopti s brojem koševa pobjedničkih ekipa.

Bertram i Rao (1974.), koriste službenu statistiku NBA lige u natjecateljskim sezonama (1968.-1971.) i (1972.-1973). Regresijskom analizom pokazuju da su značajne prediktorske varijable

postotak ubacivanja lopte u koš iz igre, postotak ubacivanja slobodnih bacanja, skok u obrani i napadu te varijable osobne pogreške.

Lukšić (2001.) utvrđuje kako postoje značajne razlike koje određuju konačni uspjeh i/ili neuspjeh momčadi u završnicama doigravanja europske (FIBA) te sveučilišne (NCAA) i profesionalne (NBA) američke košarke. Iz dobivenih rezultata moguće je utvrditi indikatore koji razlikuju pobjedničke od poraženih momčadi.

Završnica doigravanja Kupa europskih prvaka u FIBA natjecanju:

- Pokazuje se kako postoje statistički značajne razlike između pobjedničkih i poraženih ekipa unutar ovog sustava natjecanja;
- Pobjedničke ekipe imaju statistički značajno veći broj: skok u obrani, slobodna bacanja-uspješno i ubacivanje lopte u koš za 3 poena – uspješno;
- Poražene ekipe imaju statistički značajno veći broj: ubacivanje za 3 poena - neuspješno i ubacivanje lopte u koš za 2 poena – neuspješno;
- Pobjedničke ekipe imaju bolje rezultat u indeksu apsolutne i relativne učinkovitosti u napadu od poraženih ekipa.

Završnica doigravanja u NBA natjecanju:

- Pokazuje se kako postoje statistički značajne razlike između pobjedničkih i poraženih ekipa unutar ovog sustava natjecanja;
- Pobjedničke ekipe imaju statistički značajno veći broj asistencija, osvojenih lopti i slobodna bacanja – neuspješno;
- Poražene ekipe imaju statistički značajno veći broj osobnih pogrešaka i ubacivanja lopte za 3 poena – neuspješno;
- Na osnovi izvedenih pokazatelja situacijske efikasnosti moguće je zaključiti da su pobjedničke ekipe bolje i u obrani i u napadu.

Završnica doigravanja u NCAA natjecanju:

- Pokazuje se kako postoje statistički značajne razlike između pobjedničkih i poraženih ekipa unutar ovog sustava natjecanja;
- Pobjedničke ekipe imaju statistički značajno veći broj slobodnih bacanja;
- Poražene ekipe imaju statistički značajno veći broj osobnih pogrešaka;

- Na osnovi izvedenih pokazatelja situacijske efikasnosti moguće je zaključiti da su pobjedničke ekipe bolje i u obrani i u napadu.

Na temelju dobivenih rezultata moguće je ustvrditi da standardi i izvedeni pokazatelji situacijske efikasnosti dobro razlikuju uspješne (pobjedničke) od neuspješnih (poražene) ekipe te potvrđuju prediktivnu vrijednost tih pokazatelja za konačan rezultat utakmice, definiran kao pobjeda-poraz.

U skladu s prethodno navedenim istraživanjima, može se zaključiti da 13 standardnih pokazatelja situacijske uspješnosti razlikuju pobjedničke od poraženih ekipa te samim time imaju dobru prognostičku valjanost, odnosno da su pokazatelji upotrebljivi za procjenu situacijske učinkovitosti igrača i ekipa.

Nedostaci navedenih istraživanja temelje se na činjenici da se izdvajanjem nekih situacijskih varijabli iz ukupnog prostora varijabli situacijske efikasnosti gubi značajna količina informacija, te se ne dobiva realan uvid u stvarnu važnost tog dijela situacijskog prostora na konačan rezultat utakmice. Naime, navedene varijable nisu nezavisne od ostalih, već zajedno s njima čine jednu međusobno strukturiranu cjelinu. Nadalje, natjecateljski rezultat koji postiže jedna ekipa nije apsolutan, već relativan jer ovisi o stilu i sustavu igre obiju ekipa, o kvaliteti vlastite momčadi (razina kooperativnog ponašanja), kao i o kvaliteti protivnika. Sve to određuje frekvenciju standardnih pokazatelja situacijske uspješnosti jedne i druge ekipe, koja se mijenja iz utakmice u utakmicu. Prema tome, svaka je utakmica poseban entitet. Također, u sustavima natjecanja u kojima svaka ekipa ima priliku igrati sa svakom ekipom i kao domaćin i kao gost (kružni sustav natjecanja), dobiveni rezultati imaju veću generalizibilnost s aspekta interpretacije rezultata. U konačnici, jedan od najvećih problema dosadašnjih istraživanja u timskim sportovima očituje se u činjenici da su se rezultati ekipa u situacijskim varijablama tretirali nezavisno od karakteristika igre protivnika na svakoj utakmici (kao da je rezultat pojedinaca ili ekipe dobiven bez utjecaja protivnika), što nije u skladu sa stvarnim događajima u igri. Jedan od mogućih metodoloških modela za rješavanje ovog problema predložio je Dizdar (1997.).

2. Istraživanja provedena s ciljem utvrđivanja latentne strukture situacijskog prostora košarkaške igre

Trninić, Viskić-Štalec, Štalec, Dizdar i Birkić (1995.) istražuju latentnu strukturu košarkaške igre primjenom ALPHA faktorske metode (inicijalni koordinatni sustav transformiran je neortogonalnom rotacijom po OBLIMIN - kriteriju) na 13 standardnih pokazatelja situacijske efikasnosti košarkaške igre, praćenih na 64 utakmice Svjetskog košarkaškog prvenstva u Torontu 1994. godine. Izolirali su četiri relativno nezavisne latentne dimenzije po GK kriteriju, koje su imenovali kao: (a) efikasnost igrača stražnje linije obrane i prednje linije napada, (b) efikasnost igrača prednje linije obrane i stražnje linije napada, (c) opća napadačka efikasnost i (d) efikasnost ubacivanje lopte u koš s distance.

Jeličić (2003.) koristi uzorak od 133 vrhunska juniorska košarkaša sudionika 19. juniorskog prvenstva Europe u Zadru od 14. do 23. srpnja 2000. godine, na 13 standardnih pokazatelja situacijske učinkovitosti košarkaške igre, praćenih na 12 momčadi koje odigrale 46 utakmice evropskog juniorskog prvenstva. Inicijalni koordinatni sustav transformiran je neortogonalnom rotacijom po varimax kriteriju. Izolirane su dvije relativno nezavisne latentne dimenzije imenovane kao: faktor situacijske aktivnosti igrača na unutarnjim pozicijama i faktor situacijske aktivnosti igrača na vanjskim pozicijama

Zaključno, standardno korištenje varijable situacijske efikasnosti, kao i iz njih izvedene latentne dimenzije, nisu dovoljne da potpuno objasne strukturu košarkaške igre. Osim toga, važno je napomenuti da primjena različitih modela faktorske analize može dati različite strukture, čime se osobito bavio Dizdar (neobjavljeni radovi, predavanja). Objavljena latentna struktura u istraživanju Trninić i sur. (1995.) nije bila potkrijepljena višekratnim provjerama. Dizdar je u seriji provjera dobivenog modela najveći broj puta dobio sasvim drugačiji latentni model za koji se vjeruje da ima realniju egzistenciju:

1. faktor - opća uspješnost, čine: skok u obrani, osvojene lopte, asistencije i šut za dva poena

2. faktor - efikasnost ubacivanja lopte u koš distance – šut za tri poena

3. faktor - slobodna bacanja i osobne pogreške

4. faktor - slabo definiran ostalim varijablama.

3. Istraživanja u kojima su se utvrđivale karakteristike, mahom antropološke, sličnosti i razlike pojedinih tipova košarkaša, kao i njihove relacije s natjecateljskim rezultatom

Ova istraživanja istražuju (proučavaju) relacije morfoloških osobina, motoričkih sposobnosti, znanja i vještina te funkcionalnih sposobnosti, a zabilježene značajke pokušale su se dovesti i u relacije s natjecateljskim rezultatom.

Dizdar, Trninić i Matković (1996.) provode strukturnu analizu pozicija igrača u košarkaškoj igri na temelju nekih bazičnih motoričkih i funkcionalnih sposobnosti te morfoloških karakteristika. Korištenjem hijerarhijske klaster analize dobivaju dvije relativno homogene skupine. Skupinu A, imenovanu kao vanjski igrač, čine pozicije 1, 2 i 4, a skupinu B, imenovanu kao unutarnji igrači, čine pozicije 4 i 5. Na temelju dobivenih rezultata, a prema mišljenju eksperata, vanjski igrači posjeduju visoku razinu brzine jednog pokreta, agilnosti, eksplozivne snage, koordinacije, preciznosti i izdržljivosti, dok unutarnji igrači posjeduju visoku longitudinalnu i transverzalnu dimenzionalnost skeleta, veću količinu mišićne mase i potkožnog masnog tkiva te veću razinu apsolutne, statičke i repetitivne snage.

Dizdar, Trninić i Milanović (1997.) koriste hijerarhijsku klaster analizu (Wardovom metodom na temelju euklidske metrike), te je primjenjuju na 70 košarkaša (iz 8 ekipa plasiranih u završnicu košarkaškog prvenstva Hrvatske 1994. godine koji su u prosjeku igrali više od 10 minuta po utakmici), u prostoru 13 standardnih pokazatelja situacijske efikasnosti. Dobivene su četiri homogene skupine koje su na temelju rezultata diskriminacijske analize definirane kao: A-VANJSKI IGRAČI, skupina B- IGRAČI SPECIJALISTI, skupina C- POLIVALENTNI IGRAČI i skupina D – UNUTARNJI IGRAČI.

Trninić, Dizdar i Jaklinović - Fressl (1999.) diskriminacijskom analizom istražuju razlike između košarkaša koji dominantno igraju na pozicijama 1 i 2 – bekovi , 3 – krila, 4 i 5 – centri, na temelju tjelesne visine i tjelesne mase te 13 standardnih pokazatelja situacijske uspješnosti sudionika olimpijskog turnira u Atalanti 1996. godine. Pritom rezultati ukazuju da antropometrijski status razlikuje igrače po pozicijama te time određuje zaduženja i poslove u igri koji se očituju u pokazateljima igračke uspješnosti. Nadalje, skokovi u obrani i napadu te blokade šuta najviše razlikuju centre od bekova i krila, dok asistencije značajno razlikuju bekove od krila i centara, a šut izvan crte tri poena bekove i krila od centara.

Osnovna obilježja u navedenim istraživanjima bila su da su to mahom istraživanja o karakteristikama pojedinih tipova košarkaša te afirmativne studije kojima su se potvrđivale iskustvene spoznaje o specifičnoj građi, specifičnim osobinama, sposobnostima, znanjima i vještinama potrebnima za uspješno igranje košarke. Pritom novija istraživanja potvrđuju veliku kompleksnost košarkaške igre, a u povijesti rješavanja raznih znanstvenih problema vezanih za košarku ta su istraživanja bila nužna za oblikovanje istraživačkih temelja.

4. Istraživanja u kojima se procjenjivala stvarna kvaliteta košarkaša

Temeljni cilj ove skupine istraživanja jest pokušaj definiranja i oblikovanja postupaka, metoda i modela za procjenu i predikciju uspjeha ekipe, kao i za ocjenu individualnog doprinosa svakog igrača na temelju opservacije motoričkog ponašanja igrača i bilježenja događaja u utakmici u stvarnom natjecateljskom okruženju. Pritom su ove metode pokušaj vrednovanja igre te ekipne i individualne kvalitete u realnim, autentičnim uvjetima utakmice, natjecanja te stoga za praksu možda najkorisnija istraživanja jer daju plastičnu sliku o stvarnoj kvaliteti ekipa i pojedinaca. Važno je istaknuti da se u ovim metodama standardno koriste specifične metode subjektivne procjene od strane skupine neovisnih košarkaških eksperata.

Elbel i Allen već 1941. g. predlažu metodu za procjenu pojedinačne i timske uspješnosti na temelju registriranja događaja u igri koji imaju pozitivan ili negativan utjecaj na konačan rezultat utakmice. Svaki registrirani čimbenik subjektivno je vrednovan ocjenama proporcionalno važnosti u odnosu na doprinos uspjehu. Ograničenje navedenog istraživanja je bilo to da nisu prikupljeni podaci o protivničkim momčadima tijekom utakmice, niti se procedura prikupljanja podataka provodila neprekidno kroz tri promatrane natjecateljske sezone. U konačnici, autori zaključuju da se mnogi od tih čimbenika često pojavljuju na utakmici pa je izvjesno da utječu na krajnji ishod utakmice. Stoga smatraju da predloženi model može poslužiti u vrednovanju učinka pojedinog igrača i momčadi. Pored toga, autori su već tada razlikovali individualni i timski aspekt igre, što zasigurno omogućava kvalitetniju analizu košarkaške igre.

U daljnjim istraživanjima (Blašković i Milanović 1983.; Matković i Blašković 1983.; Blašković i Hofman 1983.; Horga i Milanović 1983.; Bosnar i Matković, 1983.) kojima su se utvrđivale relacije između varijabli antropološkog statusa i uspješnosti u košarkaškoj igri, temeljni problem bila je nemogućnost objektivnog mjerenja kriterijske varijable - uspješnosti entiteta u

košarkaškoj igri. Zbog nedostatka mjernih instrumenata za objektivnu procjenu kvalitete košarkaša u dosadašnjim istraživanjima standardno se koristila subjektivna procjena nezavisnih košarkaških eksperata. Tako su nezavisni kompetentni košarkaški stručnjaci na nekoj mjernoj skali (najčešće ocjenama od 1 do 5) procjenjivali uspješnost košarkaša na temelju predloženih kriterija. Blašković i Milanović (1983.) su predložili procjenu kvalitete košarkaša na temelju sljedećih ocjena: efikasnosti tehnike, uspješnosti igrača u fazi napada, uspješnosti igrača u fazi obrane, individualnog stvaralaštva, odgovornosti, angažiranosti u igri, ponašanja te na temelju opće ocjene uspješnosti u igri.

U istraživanjima Dežman (1992., 1993., 1995., 1996.), Erčulj, (1997.), Grehaigne, Bouthier i Godbout (1977.), Swalgin (1993., 1995., 1996., 1998.) pokušalo se napraviti metodološki iskorak u navedenom smjeru. Tako Swalgin (1998.) na temelju sustava za vrednovanje učinka igrača proučava povezanost neponderiranog i ponderiranog sustava s ocjenama igračke uspješnosti koje su dali košarkaški stručnjaci. Rezultati su pokazali kako su obje metode visoko povezane s trenerskim kriterijima vrednovanja.

Trninić (1996.) je analizirao košarkašku igru sa strukturalnoga i funkcionalnog aspekta, definirao stanja igre te opisao pozicije i uloge igrača na temelju njihovih zaduženja u igri. Pritom je argumentirano prikazao poželjen smjer razvoja igrača u skladu s pretpostavljenim promjenama pravila i poimanjem košarkaške igre u budućnosti. Nadalje, pretpostavlja kako će za igrače biti važno što i koliko poslova mogu obaviti tijekom igre, a ne na kojoj poziciji igraju (polivalencija u sklopu svih faza tijeka igre).

Trninić i Dizdar (2000.) na temelju ekspertne procjene deset eminentnih košarkaških stručnjaka, primjenom AHP-metode, utvrđuju koeficijente važnosti dvanaest kriterija (Trninić, Perica i Dizdar, 1999.) za procjenu situacijske uspješnosti igrača u obrani i napadu po pozicijama u košarkaškoj igri. Eksperti su pokazali visok stupanj slaganja (od 0.91 do 0.98) u procjeni važnosti kriterija za sve pozicije u košarkaškoj igri. U skladu s dobivenim rezultatima eksplicitno su opisane pojedine pozicije u igri kao i usporedne sličnosti i razlike između njih.

Trninić, Dizdar, Dežman (2000.) emprijski provjeravaju ponderirani sustav kriterija za procjenu stvarne kvalitete košarkaša koji su preložili Trninić i Dizdar (2000.). Na temelju deskriptivnih pokazatelja i koeficijenata važnosti kriterija te stupnja objektivnosti (slaganja) ekspertnih ocjena moguće je zaključiti kako su za većinu kriterija metrijska svojstva (objektivnost i osjetljivost) u

skladu s time i predložena struktura relevantnih kriterija za svaku poziciju (bek organizator igre, bek šuter, krilo, krilni centar, centar).

5. Analiza poslova u igri i stanja igre

Istraživanja stanja košarkaške igre su započeli Trninić, Perica, Pavičić (1994.), koji su napravili potpuni matematički opis sustava "košarkaška utakmica". Proces košarkaške utakmice, iako kontinuiran, diskretiziran je korištenjem niza karakterističnih situacija koje se ponavljaju. Pritom ih autori označavaju kategorijom stanje igre. Sukcesivni slijed tih stanja označen je kategorijom *tijek igre*. U skladu s tim, generiran je formalni matematički model za deskripciju sistema "košarkaška utakmica" s gledišta kinematičkog opisa. Model omogućava raspoznavanje dvaju bazičnih stanja sistema koja su u radu definirana i označena kategorijama: *pozicija* i *tranzicija*. Također, Trninić, Perica i Pavičić (1995.) zaključuju da je osnovno svojstvo stanja sistema „košarkaška utakmica" težnja zadržavanja *ravnoteže* te na osnovi košarkaških zakonitosti i iskustva iz košarkaške prakse izlažu sustav principa za održavanje ravnoteže, kao i popis nužnih pravila koja ostvaruju taj cilj. Pritom stanje sustava opisuju skupom informacija o sustavu kojima raspolažemo u određenom trenutku ***t***. Korištenjem oznaka

$\vec{r}_{i(t)}$ - položaj *i* - tog konstituenta (igrača ili lopte) u trenutku *t,*

$\vec{v}_{i(t)}$ - brzina *i* - tog konstituenta u trenutku *t,*

(pri čemu je *i=1,...,n* - *n* je broj konstituanata sustava), te uz reprezentiranje elemenata sustava materijalnim točkama, onda u tom kinematičkom opisu definiraju težište sustava (cm-centar mase) sljedećom relacijom:

$$\vec{R}_{cm(t)} = \frac{\sum_{i=1}^{n} m_i \vec{r}_{i(t)}}{\sum_{i=1}^{n} m_i}$$

gdje su m_i mase pojedinih konstituenata. Indeks *i* poprima *n* vrijednosti, ovisno o našoj definiciji sustava.

Time smo skup od *n* elemenata zamijenili jednom točkom položaj koje je, u nekom izabranom koordinatnom sustavu, upravo $R_{cm(t)}$, a brzina $\vec{V}_{cm(t)} = \frac{\mathbf{d}\vec{R}_{cm(t)}}{\mathbf{d}t}$, tj. derivacija vektora položaja po vremenu.

Nadalje, autori naglašavaju da u pozicijskom stanju prevaljeni put (translacija) težišta sustava - (igrači+lopta) u smjeru vertikale (smjer određen spojnicom koš-koš) jest zanemariv u odnosu na prevaljeni put u tranzicijskom stanju. S druge strane, za gibanje po horizontali može vrijediti obratan odnos.

Nadalje, Trninić (1995.), u radu analizira pojam *poslovi u igri* i daje prijedlog novog obrasca za hijerarhijsku strukturu znanja u košarkaškoj igri. Radi unaprjeđivanja dosadašnjeg pristupa analizi i učenju košarkaške igre, profesionalnoj orijentaciji i selekciji te profesionalnom osposobljavanju i usavršavanju igrača, poslovi u igri su znanstveno istraženi te stavljeni u homogene skupine. Znanje je u košarkaškoj igri prezentirano kao hijerarhijski strukturirano binarno stablo s osnovnim kategorijama: strategija, taktika, stanja igre, poslovi u igri, osnovne igre te elementi košarkaške tehnike i individualne taktike. U vrhunskoj se košarci motorička aktivnost i ponašanje igrača svode na igranje uloga i obavljanje poslova tj. na usmjereno ispunjavanje funkcija u igri a vrhunski rezultat može se postići samo ako svatko obavi svoj posao. Nakon različitih pristupa razvrstavanju poslova, opisane su uloge igrača prema pozicijama u igri. Znanstvena deskripcija koncepta poslova u igri čini sukus, bit, srž autorove doktorske disertacije. Taj koncept poslova u igri izvoran je i predstavlja okosnicu znanstvene studije. Na osnovi toga, a sa čime su se u eksperimentalnom istraživanju anketirani košarkaški eksperti (igrači i treneri) suglasili, načinjen je popis poslova u igri, koje svaki igrač obavlja s obzirom na poziciju i ulogu u igri u pojedinim fazama tijeka igre. Taj popis, zapravo, predstavlja obrazac aktualne europske košarke. Nadalje, autor predviđa da će se nastaviti usavršavanje igre s tendencijom da se zadrži ravnoteža između svih faza tijeka igre, a istodobno će se nastojati sačuvati ona obilježja koja omogućavaju kolektivnu igru, kreativnost u rješavanju i realizaciji akcija te reciprocitet pomaganja u rješavanju situacija tijekom igre. Sa stajališta faza igre vjerojatno će prevladati kontinuitet prijelaza iz obrane u napad i obrnuto, s visokim intenzitetom tijeka igre. Autor smatra kako je stanje ravnoteže u tranzicijskoj obrani određeno već u fazi napada, odnosno stanje ravnoteže u tranzicijskom napadu određeno je već u fazi obrane. To vodi prema zaključku da su obrana i napad dva nedjeljiva prožimajuća segmenta igre. Također se

navodi da ipak nije moguće iscrpiti sve aspekte, manifestne i latentne, igre unutar pojedinog sustava istraživanja jer košarka ostavlja dovoljno prostora ekspertima za potkrjepljivanje ili opovrgavanje dosadašnjih spoznaja, te za utemeljivanje novih pristupa istraživanjima ovog područja. Valja napomenuti kako ne postoje konačne spoznaje o čimbenicima odgovornim za uspjeh u košarci (selekcija i dijagnostika) jer je košarka najpromjenljivija od svih ekipnih sportova.

Temeljem uvida u dosadašnje znanstvene radove, pristup košarkaškoj igri nije obrađivan korištenjem stanja igre kao stanja Markovljevih lanaca.

2.3. Istraživanja evaluacije uspješnosti u momčadskim sportskim igrama

Sa stajališta povijesne geneze razvoja kineziologije sporta ili sportske znanosti, već 60-ih godina prošlog stoljeća je Konstantin Momirović (1966., 1969., 1972.), kao protagonist novoutemeljene kvantitativno rigorozne znanosti kineziologije prvi ukazao na nužnost uvođenja pojednostavljenih linearnih modela u objašnjenju čimbenika uspješnosti u sportu. Tvrdio je da linearni model tj. diferencijalno ponderirana suma utjecaja (varijabli) prikladno opisuje skup poznatih i nepoznatih čimbenika koji utječu na uspješnost sportaša ili momčadi.

Takva pojednostavljena predodžba, diferencijalno ponderirana linearna kombinacija antropoloških faktora zanemarila je utjecaj vanjskih faktora na sportaševu izvedbu i sportsko postignuće. Međutim, Momirović (1966.) je već tada smatrao da takav obrazac poimanja faktorske strukture sporta ne zadovoljava kriterije „tvrde“ znanost,i osobito kad su u pitanju kompleksne sportske aktivnosti (Matvejev, 1977., 1981., 1999.) jer imaju značajno složenije zahtjeve za pojedinog sportaša nego monostrukturalne cikličke i acikličke sportske aktivnosti.

Pretpostavlja se da su momčadske sportske igre multikauzalne prirode gdje se sportaševa izvedba i natjecateljska uspješnost temelji na multikauzalnim mehanizmima u kojima je temeljna ideja da su unutarnje i vanjske varijable u recipročnom determinističkom odnosu (Philips i Orton, 1983.). Zato istraživanja u sportskoj znanosti moraju biti bezuvjetno interdisciplinarna (Trninić i sur., 2008.). U skladu s time, u modelu uspješnosti u momčadskim sportskim igrama nužno je uključiti

pored unutarnjih čimbenika u koje spada i sportašev potencijal i potencijalnu uspješnost momčadi i vanjske odrednice.

2.4. Istraživanja načina procjene i predviđanja uspješnosti u momčadskim sportskim igrama

Horga, (1993.) navodi da postoje dva temeljna načina procjene i predviđanja uspješnosti u sportu, a tako i u momčadskim sportskim igrama. Prvi se odnosi na usporedbu sportaša različite stvarne kvalitete u obilježjima za koja se pokušava utvrditi koliko doprinose predviđanju uspješnosti, a drugi se sastoji u povezivanju uspješnosti u sportu sa skupom relevantnih antropoloških obilježja sportaša. U skladu s navedenim, pretpostavlja se da će ona obilježja koja imaju visok relativni utjecaj na uspjeh pokazati povezanost s nekom od mjera natjecateljske uspješnosti. Horga (1993.) navodi da ovaj način analize zahtijeva egzaktno specificiranje kriterija uspješnosti u sportu. Isto tako Morgan (1979.) navodi da fiziološki ili psihološki pokazatelji sami za sebe nikada ne mogu biti primjereni prediktori uspjeha te samo kada se sportaš istražuje kao kompleksni psihobiološki sustav, moguće se približiti idealnoj razini predviđanja. U konačnici, Deshaies i sur. (1979.), navode da se sportsko ponašanje treba proučavati pod vidom interakcije brojnih i fizioloških i psiholoških varijabli te da je takav pristup primjereniji u odnosu na samo fiziološke ili samo psihološke prediktivne modele uspjeha u sportu na temelju testova i upitnika ličnosti i vjerojatno nije moguće osigurati zadovoljavajuću uspješnost prognoze ako pokazatelji za predviđanje uspješnosti u sportu ne obuhvaćaju sklop unutarnjih i vanjskih faktora.

2.5. Istraživanja modela uspješnosti u sportu u momčadskim sportskim igrama

Kompleksnost momčadskih sportskih igara uzrokuje nemogućnost postavljanja matematičkog modela koji bi obuhvatio sve čimbenike koji utječu na uspješnost u sportu kao i njihov međusobni i recipročni utjecaj. Stoga su se kao rješenje nametnuli ekspertni sustavi. Neki od razloga primjene ekspertnih sustava u polju kineziologije mogu se objasniti njihovim zadovoljavanjem principa jednostavnosti i principa obuhvatnosti. Pritom je potrebno istaknuti da su modularnost i proširivost ekspertnih sustava poticali niz novih znanstvenih istraživanja koja su omogućila daljnji napredak sportske znanosti (Dežman, 1988., 1992., 1995.; Jošt i sur., 1992.; Dežman i Leskošek, 1993.; Filipčić, 1996.; Dežman i Erčulj, 1995.; Dežman i sur. 2001.a, 2001.b; Trninić i sur. 2002.a, 2002.b).

Ekspertni sustavi generiraju rješenja, ali bez matematički strukturirane jednadžbe koja bi precizno definirala cjelokupni model uspješnosti i njegovo ponašanja u ovisnosti o variranju unutrašnjih i vanjskih parametara. Pritom se temelje na znanju prikupljenom od ljudi-eksperata i skupu pravila koja se oblikuju njihovim anketiranjem, a emulacija ljudskog razmišljanja se dalje proširuje primjenom tzv. neizrazite (engl. *fuzzy*) logike (Zadeh, 1965.; Siler i Buckley, 2005.; Papić i sur., 2009.; Rogulj i sur, 2009.). Novi znanstveni nacrti su usmjereni na istraživanje čimbenika uspješnosti u kompleksnim sportovima kao u složenim dinamičkim sustavima koje obilježavaju procesi interakcije koji se neprestano mijenjaju te na funkcionalnu međuzavisnost igrača koji igraju na različitim pozicijama u pojedinoj momčadskoj sportskoj igri (Trninić, 1995., Rogulj, 2003., Lebed, 2006., 2007., Trninić i sur., 2008.).

Dežman (1992., 1995., 1997.) i Erčulj (1998.), navode da je utvrđivanje modela uspješnosti igrača i/ili momčadi moguće provesti na dva načina. Prvi je mjerenjem ili ocjenom svih čimbenika koji imaju najveći (važan) utjecaj na kvalitetu igranja pojedinog igrača i/ili momčadi. Pritom je temeljem korištenja testova i dobivenih rezultata moguće (korištenjem multiple regresijske analize) izračunati beta pondere, kojima se različito ponderiraju pojedini testovi u ukupnom zbroju bodova. Drugi način je procjenjivanjem cjelokupne uspješnosti u igri. Cjelokupna uspješnost u igri obuhvaća sve bitne čimbenike stvarne kvalitete igrača koje procjenjuju stručnjaci pomoću određenog sustava kriterija (Trninić, 1996.; Trninić i sur, 1999.a;

Trninić, Dizdar, 2000.; Trninić i sur., 2000.; Dežman i sur., 2001.a, 2001.b; Trninić i sur., 2002.a, 2002.b; Hraste i sur., 2008.).

3. PROBLEM RADA

Kao što se može uočiti iz prethodno navedenog, metodološki problem u društvenim i humanističkim istraživanjima je taj što ne postoji adekvatno povezivanje teoretskih koncepata koji omogućavaju cjelovit, holistički pristup rješavanju znanstvenih problema. Tu se primarno misli na uporabu modela teorije kaosa, teorije dinamičkih sustava, teorije transakcijskih modela kao i na primjenu recipročnog determinizma kao istaknutog koncepta unutar teorije obostranog i neprestanog utjecaja varijabli. Oblikovanje novih spoznaja o primjeni ovih teoretskih koncepata može omogućiti izgrađivanje novih paradigmi u kineziološkoj znanosti.

Znanstveni i društveni status suvremene kineziologije, između ostalog, determiniran je novim epistemološkim i metodološkim trendovima. U tom kontekstu nužno je napraviti iskorak u razvoju suvremene kineziološke metodologije. Sadašnji dometi spoznaja kineziologije i njenih disciplina limitirani su metodološkim trendovima koji imaju ograničavajući utjecaj na praktično djelovanje. U suvremenoj kineziologiji je nužna interdisciplinarnost, multidisciplinarnost i transdisciplinarnost koje mogu pomoći generiranju novih kvalitativnih i kvantitativnih modela i metoda u istraživanju. Osnovna intencija suvremene kineziologije trebala bi biti integracija znanja i eklekticizam Također, tendencija treba biti generiranje, validacija i verifikacija novih metodoloških mehanizama. Naglasak bi trebao biti stavljen na primjene i modifikacije suvremenih metoda matematičkog modeliranja, a naročito na metodološke i epistemološke trendove pri modeliranju u multivarijatnim statističkim sustavima.

Glavni problem u pogledu korištenja apstraktnih modela u društvenim i humanističkim znanostima predstavlja određivanje stupnja njihove ontološke adekvatnosti na proučavanoj stvarnosti. Prema pozitivističkom pristupu koji se ograničava na opažljivo, apstraktni model ne može dosegnuti realnost, s obzirom da je to samo prikladan jezik poput bilo koje druge matematičke strukture, a njegovu prikladnost obilježavaju istovremeno njegova jednostavnost i njegova sposobnost da pruža osnovu za predviđanje. Uspješnost predviđanja se potkrjepljuje u

eksperimentalnim zakonima kojima model manipulira, a ne u osobini modela da izražava svojstva nedostupne realnosti. Nasuprot tome, za znanstvenike koji vjeruju u stvarnost nad opažljivim, apstraktni model je koristan ako pruža uvid u stvarne, ali još uvijek neotkrivene procese koji objašnjavaju opažljivo i ako na taj način doprinose njihovom objašnjenju.

U skladu s navedenim, u ovom radu je odabran matematički model diskretnih slučajnih procesa, Markovljenih lanaca za evaluaciju uspješnosti u kompleksnoj sportskoj aktivnosti - košarkaškoj igri.

3.1. Principi ravnoteže igre

Stanje sustava možemo promatrati i s aspekta ravnoteže. Smatra se da je stanje sustava u ravnoteži kada su zadovoljeni principi organizirane igre unutar modela taktike. Dakle, principi ravnoteže, u kontekstu košarkaške igre, ovise o tome slijedi li momčad principe organizacije igre koji su definirani na temelju košarkaških zakonitosti, ekspertnog znanja i iskustva trenera i igrača.

Narušavanje stanja ravnoteže u trenutku t otvara mogućnost za prijelaz iz pozicijskog u tranzicijsko stanje ili iz tranzicijskog u novo tranzicijsko stanje. No, prijelaz iz jednih stanja u druga nije nužna posljedica narušavanja ravnoteže; ona se može, ali i ne mora dogoditi. S druge strane, očuvanje ravnoteže tijekom trajanja tranzicijskih stanja otvara mogućnost za prijelaz u pozicijska stanje. U skladu s time Hughes i sur. (1998.) su definirali perturbaciju u nogometu kao događaj koji mijenja tijek (engl. *rhythmic flow*) napada ili obrane koje vode do mogućnosti zgoditka. Perturbacija se može identificirati iz bilo koje akcije koja stvara smetnju u obrani I dopušta napadaču mogućnost pucanja prema golu. Nadalje, ako perturbacija rezultira s udarcem na gol onda se ona naziva "kritični incident" (engl. *critical incident*). Korištenjem ove definicije perturbacije Hughes i sur. (1998.) dobivaju statistički značajnu razliku u omjeru frekvencija perturbacija među uspješnim i neuspješnim timovima na Evropskom nogometnom prvenstvu 1996.

Sa stajališta praktičnog djelovanja ekspertni treneri u sportskim igrama u analizi video zapisa pojedinog situacijskog treninga ili utakmice nastoje detektirati koji igrači generiraju stanje

neravnoteže u pojedinoj fazi tijeka igre. Zato je u procesu tehničko-taktičke pripreme nužno igrače poučavati i uvježbavati da u svakoj fazi tijeka igre moraju znati što mogu, što moraju i što ne smiju individualno, u grupi ili kao cijela momčad činiti kako bi ostvarili uspješno obavljanje zadataka u igri. Takav situacijski pristup potiče razvoj dinamičke ravnoteže unutar faza tijeka igre ali je i preduvjet kontrole ritma igre i natjecateljskog rezultata. Dakle, stanja dinamičke ravnoteže i/ili stanja neravnoteže su determinirana obavljanjem zadataka u igri.

Slika 3.1*: Prikaz stanja igre s obzirom na faze tijeka igre (Trninić, 1995.)*



Činjenica da su u košarkaškoj praksi objekti sustava strukturirani ukazuje na mogućnost da se, poštujući tu strukturu, model može dovesti na sofisticiraniju razinu na kojoj se diferencira veći broj stanja u okvirima prezentiranog kinematičkog opisa (slika 3.1).

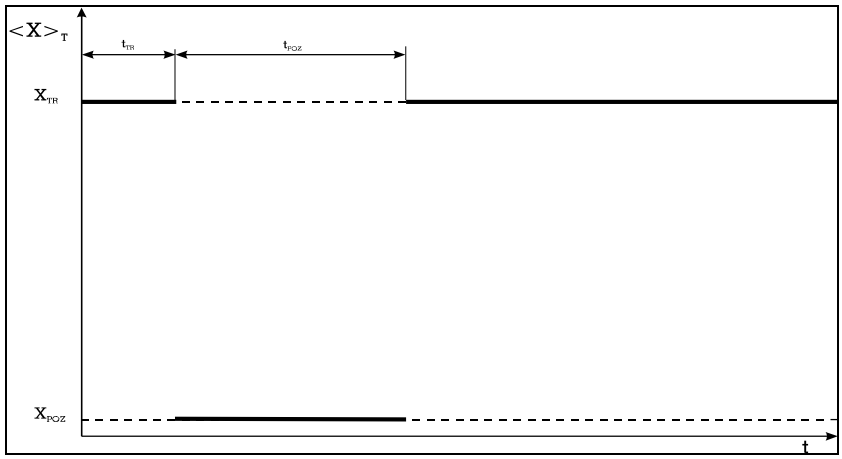
Trninić (1995.) navodi kako kriterije za određivanje faze tijeka igre možemo raščlaniti na sljedeći način (tablica 3.1):

Tablica 3.1: Kriteriji za određivanje faze tijeka igre (Trninić, 1995.)

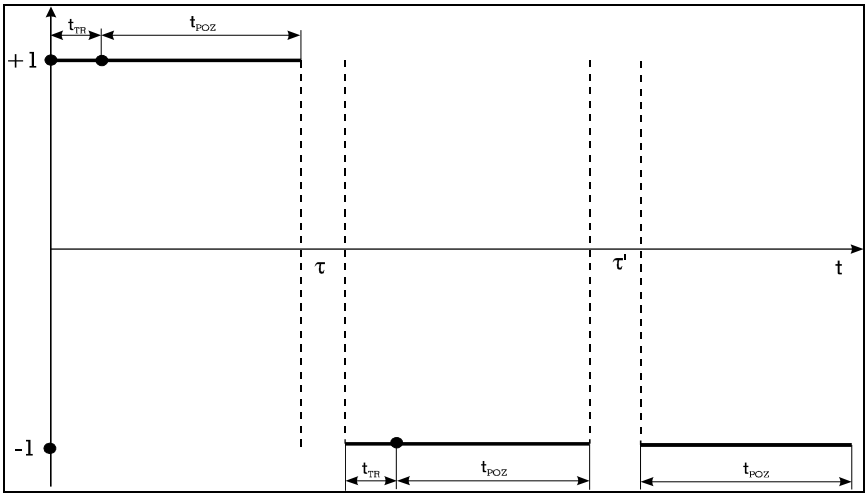
Posjed lopte • obrana • napad • faza latencije (nedefiniran posjed lopte)	Prevaljeni put (translacija) težišta sustava u smjeru vertikale • pozicija • tranzicija

Objašnjenje tih kriterija moguće je prikazati na najjednostavniji način u grafičkom obliku. Slika 3.2 prikazuje dinamiku prosječnih vrijednosti prevaljenog puta težišta sustava u smjeru vertikale tijekom trajanja pozicijskog (t_{POZ}) i tranzicijskog stanja (t_{TR}), a slika 3.3 dinamiku varijable posjeda lopte.

Slika 3.2. Razlika između pozicijskog i tranzicijskog stanja (Trninić, 1995.). *Legenda*: $<X>_T$ - prosječna vrijednost prevaljenog puta težišta sustava u smjeru vertikale u odnosu na vrijeme, t_{TR} - vrijeme trajanja tranzicijskog stanja, t_{POZ} - vrijeme trajanja pozicijskog stanja, X_{TR} - prosječna vrijednost prevaljenog puta težišta sustava u smjeru vertikale u odnosu na vrijeme u stanju tranzicije, X_{POZ} - prosječna vrijednost prevaljenog puta težišta sustava u smjeru vertikale u odnosu na vrijeme u stanju pozicije



Slika 3.3. Dinamika varijable posjeda lopte (Trninić, 1995.). *Legenda*: t_{TR} - vrijeme trajanja tranzicijskog stanja, t_{POZ} - vrijeme trajanja pozicijskog stanja, τ, τ' - vrijeme trajanja faze latencije nakon pozicijskog ili tranzicijskog napada, (+1) - posjed lopte ekipe A, (-1) - posjed lopte ekipe B.



Kategorija **faza latencije** stanje je igre nedefiniranog posjeda lopte. Ta faza traje kratko vrijeme i to od trenutka šuta do hvatanja lopte (skok u obrani ili skok u napadu). Između mogućih promjena (obrana/napad, napad/obrana, obrana/obrana i napad/napad) javlja se faza "ničje" lopte, gdje regularna obrana zatvara prilaze košu i organizira skok u obrani, dok u organiziranom napadu postoji napadački skakački plan (pokrivanje skoka u napadu i obrambena ravnoteža).

3.1.1. Analiza stanja košarkaške igre korištenjem Markovljevih lanaca

Momčadske sportske igre su višestrukturne i kompleksne sportske aktivnosti u kojima je prisutna simbioza cikličkih i acikličkih gibanja sa i bez lopte. Kako je prije rečeno, određuju ih odnosi suradnje suigrača i suprotstavljanja protivničkih igrača. Važno je naglasiti da košarkaška utakmica ima *kontinuirani tijek* a može se prikazati kao uređen niz zadataka koji generiraju stanja igre (Trninić, 1995.). Unutar modela analize stanja košarkaške igre pretpostavljamo da je tijek

igre diskretiziran na konačno mnogo vremenskih trenutaka. Taj tijek moguće je podijeliti na određene faze: napad, obrana i konverzija[4] (Knight i Newell, 1986.). S druge strane, to je igra ravnoteže, suradnje i suprotstavljanja, ali i igra koja zahtijeva prostorno-vremensko usklađivanje akcija.

Svaka faza tijeka igre ima konkretna obilježja s vrlo specifičnim i precizno definiranim ciljevima unutar složenog taktičkog kolektivnog djelovanja, što potvrđuje da je košarkaška igra visokog stupnja taktičke složenosti.

U kontekstu prije navedene definicije stanja u košarkaškoj igri jasno je da imamo beskonačno različitih stanja igre. Takav pristup definiciji stanja košarkaške igre je, iako formalan i znanstven, nepraktičan za analizu Markovljevim lancima. Stoga definiramo da su dva stanja ekvivalentna ako su srodna u smislu prostorno vremenskih odnosa. Potrebno je naglasiti svojstvo tranzitivnosti, odnosno ako su A i B ekvivalentna stanja te ako su B i C ekvivalentna stanja, tada su A i C ekvivalentna stanja. Sada definiramo stanje Markovljevog lanca kao skup svih ekvivalentnih stanja pojedinom stanju.

Očito je da se pojedino stanje Markovljevog lanca sastoji od beskonačno međusobno ekvivalentnih stanja košarkaške igre te da se pojedino stanje igre može nalaziti samo u jednom stanju Markovljevog lanca. Pritom se pojedino stanje Markovljevog lanca događa u intervalu $< t_i, t_i + \Delta t >$ pri čemu se Δt bira iskustveno, tako da naše razmatranje ima praktičnu svrhu. Odnosno Δt ćemo odabrati tako da se svaka faza tijeka igre dijeli na 3 podfaze (ulaznu, srednju i završnu).

Sa stajališta Markovljevih lanaca, trenutno stanje Markovljevog lanca ima sve informacije potrebne za odluku odabira budućeg stanja Markovljevog lanca odnosno računanje vjerojatnosti prijelaza u buduće stanje. U našem pristupu analizi stanja košarkaške igre to je prikladan model, obzirom da je akcija u stanju pozicije/tranzicije u trenutku t posljedica prethodnih stanja i nije potrebna nikakva dodatna informacija koja bi određivala mogućnost prelaska u buduće stanje.

[4] conversion - act or state of converting (akt ili stanje pretvaranja), Webster's Encyclopedic Unerbridged Dictionay of English Language. 1993., str. 320.
[4] transition - an act, processes, or instances of changing, from one state, from, activity, or place to another (akt, proces ili moment promjene iz jednog stanja, forme, aktivnosti ili mjesta u drugo) Webster's II, New Riverside University Dictionary, Riverside Publishing Company, 1988., str. 1227.

Pretpostavljamo da obavljanje zadataka pojedinih igrača unutar modela taktike igre generira ukupno $N = \sum_{i=1}^{6} n_i + 1$ stanja podijeljenih u četiri temeljne grupe stanja:

1. Stanja koja zadovoljavaju principe ravnoteže igre u 4 faze tijeka igre:
   - pozicijska obrana (n_1 stanja) - prvi skup stanja
   - tranzicija obrane (n_2 stanja) - drugi skup stanja
   - tranzicija napada (n_3 stanja) - treći skup stanja
   - pozicijski napad (n_4 stanja) - četvrti skup stanja
2. Stanja s neuspješnim ishodom (n_5 stanja) -peti skup stanja (*turnover*)
3. Stanja s uspješnim ishodom (n_6 stanja) – šesti skup stanja
4. Stanje s nedefiniranim posjedom lopte; faza latencije (jedno stanje)– sedmi skup stanja

Dakle, pojedina faza tijeka igre se sastoji od relativno neovisnog skupa stanja.

Standardno pretpostavljamo da je za sva stanja *i,j* i za sve trenutke *t* uvjetna vjerojatnost $P(X_{t+1} = j | X_t = i)$ tranzicije među stanjima Markovljevog lanca neovisna o trenutku *t.* Pritom izraz $P(X_{t+1} = j | X_t = i)$ označava vjerojatnost prelaska u *(t+1)*-om trenutku u stanje *j*, ako je u prethodnom trenutku, trenutku *t* lanac bio u stanju *i.* Standardno ćemo koristiti notaciju $P(X_{t+1} = j | X_t = i) = p_{i,j}$, $i, j \in \{1,...,N\}$.

Nadalje, s $i \in \{1,...,n_1\}$, označavat ćemo stanje pozicijske obrane, s $i \in \{n_1 + 1,...,n_1 + n_2\}$, stanje tranzicije obrane, s $i \in \{n_1 + n_2 + 1,...,n_1 + n_2 + n_3\}$ stanje tranzicije napada, a s $i \in \{n_1 + n_2 + n_3 + 1,...,n_1 + n_2 + n_3 + n_4\}$ stanje pozicijskog napada. Analogno se notiraju stanja za ostale grupe stanja.

Nadalje, pretpostavljamo da je u inicijalnom trenutku, *t = 0* aktivno istaknuto stanje unutar skupa stanja narušene ravnoteže, stanje latencije. Odnosno, ako *k* označimo stanje latencije tada vrijedi:

$$P(X_0 = i) = 0, \quad i \neq k$$
$$P(X_0 = k) = 1. \tag{1}$$

Dakle, matrica prijelaza Markovljevog lanca je blok matrica P reda N dana s:

$$P = \left[P_{i,j}\right]_{i,j=1,\ldots,7} \tag{2}$$

gdje su $P_{i,j}$, $i=1,\ldots,7$ matrice prijelaznih vjerojatnosti iz n_i stanja *i-tog* skupa stanja u n_j stanja *j-tog* skupa stanja. Pritom je pojedina blok matrica $P_{i,j}$ dimenzija $n_i \cdot n_j$. Kako je primjerice $P(X_{t+1} = j \mid X_t = i) = 0$, ako je $i \in \{1,\ldots,n_1\}, j \in \{n_1+n_2+1,\ldots,n_1+n_2+n_3\}$ i $i \in \{n_1+n_2+1,\ldots,n_1+n_2+n_3\}, j \in \{1,\ldots,n_1\}$, u predloženom modelu nije moguće prijeći iz stanja pozicijske obrane izravnno u stanje tranzicije napada. To stoga što je za prijelaz iz pozicijske obrane u tranziciju napada nužno prvo prijeći u stanje koje će odrediti uspješnost/ili neuspješnost akcije. Iz toga slijedi da je $P_{1,3} = P_{3,1} = 0$ (nul matrica). Daljnom analizom zaključujemo da je matrica P blok matrica oblika:

$$P = \left[\begin{array}{cccc|ccc} P_{1,1} & 0 & 0 & 0 & P_{1,5} & P_{1,6} & P_{1,7} \\ P_{2,1} & P_{2,2} & 0 & 0 & P_{2,5} & P_{2,6} & P_{2,7} \\ 0 & 0 & P_{3,3} & P_{3,4} & P_{3,5} & P_{3,6} & P_{3,7} \\ 0 & 0 & 0 & P_{4,4} & P_{4,5} & P_{4,6} & P_{4,7} \\ \hline P_{5,1} & P_{5,2} & P_{5,3} & 0 & 0 & 0 & 0 \\ \hline 0 & P_{6,2} & P_{6,3} & P_{6,4} & 0 & 0 & 0 \\ \hline p_{7,1} & p_{7,2} & p_{7,3} & p_{7,4} & 0 & 0 & 0 \end{array}\right] \tag{3}$$

Elemente matrice P interpretiramo na sljedeći način:

1. Matrice $P_{i,5}$, $P_{i,6}$ *i* $P_{i,7}$ *za* $i=1,\ldots,4$ su **pokazatelji uspješnosti** unutar pojedine faze igre, s obzirom na to da sadrže vjerojatnosti ulaska u stanja uspjeha, neuspjeha ili latencije.
2. Elementi $p_{7,j}$ $j=1,\ldots,4$ sadrži **pokazatelje skakačke uspješnosti** koji ulaze u standardne pokazatelje situacijske uspješnosti košarkaške igre.
3. $P_{2,1}$ i $P_{3,4}$ su **pokazatelji kontrole intenziteta (tempa)** košarkaške igre.

S obzirom na to da se pojedina faza tijeka igre može podijeliti na inicijalnu, središnju i završnu fazu, pri čemu je moguće imati I_i inicijalnih stanja, M_i središnjih stanja i F_i finalnih stanja, pojedina matrica $P_{i,i}$ $i=1,2,3,4$ će biti kvadratna matrica s n_i redaka i n_i stupaca sljedećeg oblika:

$$P_{i,i}=\left[\begin{array}{ccc|ccc|ccc}
0 & \cdots & 0 & p_{1,I_i+1} & \cdots & p_{1,I_i+M_i} & p_{1,I_i+M_i+1} & \cdots & p_{1,n_{i,i}} \\
\vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\
0 & \cdots & 0 & p_{I_i,I_i+1} & \cdots & p_{I_i,I_i+M_i} & p_{I_i,I_i+M_i+1} & \cdots & p_{I_i,n_{i,i}} \\
\hline
0 & \cdots & 0 & 0 & \cdots & 0 & p_{I_i+1,I_i+M_i+1} & \cdots & p_{I_i+1,n_{i,i}} \\
\vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\
0 & \cdots & 0 & 0 & \cdots & 0 & p_{I_i+M_i,I_i+M_i+1} & \cdots & p_{I_i+M_i,n_{i,i}} \\
\hline
0 & \cdots & 0 & 0 & \cdots & 0 & 0 & \cdots & 0 \\
\vdots & \ddots & \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\
0 & \cdots & 0 & 0 & \cdots & 0 & 0 & \cdots & 0
\end{array}\right]$$

Naglasimo da vrijedi $I_i + M_i + F_i = n_i$. Pritom budući da se pojedino stanje događa u intervalu $< t_i, t_i + \Delta t >$, odabiremo takav Δt da je nužan prijelaz iz pojedinog stanja faze tijeka u neko stanje iduće faze tijeka igre.

U skladu s time,

4. Dijagonalne blok matrice $P_{i,i}$, $i=1,...,4$ oslikavaju **kombinatoriku igre**.

Pretpostavljamo da je proces stacionaran unutar jedne utakmice, odnosno pojedine vjerojatnosti se ne mijenjaju tijekom jedne utakmice. Vjerojatno će procesom sportske pripreme doći do promjene vrijednosti pojedinih elemenata matrice, odnosno do promjena vjerojatnosti prijelaza. Tako primjerice, u pojedinom stanju tranzicije iz obrane u napad, u idealnom slučaju bi trebalo vrijediti da je vjerojatnost prijelaza u neko drugo stanje tranzicije minimalna, a vjerojatnost ostajanja u istom stanju maksimalna, sve do trenutka prelaska u neko drugo stanje pozicijskog napada, prethodno definiranog modelom taktike igre.

Unutar šestog skupa stanja je potrebno istaknuti stanje postignutog koša. To stoga što će nam egzistencija tog stanja omogućiti konstrukciju definicije uspješnosti prijelaza kroz stanja - uspješni napadi (postignut koš) i neuspješne obrane završe s inicijalnim stanjem tranzicije obrane odnosno napada. Najuspješnija „šetnja“ Markovljevim lancem (u fazi napada) bi bila ona koja završi inicijalnim stanjem tranzicije, a produkt vjerojatnosti svih tranzicija iz stanja u stanje je maksimalan. Pritom bi ona odgovarala najuspješnijem napadu (bez prelaska u stanje latencije). Svaki drugi prijelaz u Markovljevom lancu je posljedica narušene ravnoteže.

Općenito, što je pojedina ekipa više taktički uvježbala sustave igre, vjerojatnosti ulaska u stanje latencije ili neuspješnog stanja, iz stanja napada su manja. Pritom treba naglasiti da je u stanju obrane ulazak u fazu latencije poželjna situacija jer to znači da protivnik ne kontrolira u potpunosti svoj napad. Tako primjerice, u idealnom slučaju, granična vrijednost ulaska u stanje neuspješnog ishoda, iz stanja napada je 0. Pritom se misli na konvergenciju dijelova matrice u smislu da nakon svakog učinkovitog trenažnog procesa dolazi do promjena vjerojatnosti unutar matrice.

U našem modelu je moguće u konačnom broju koraka prijeći iz svakog stanja u bilo koje drugo stanje, stoga je Markovljev lanac ergodičan. Nadalje, potrebno je naglasiti da je unutar našeg modela stanja košarkaške igre, nakon postignutog koša, aktivno stanje tranzicije.

U kontekstu konkretno odabranog modela taktike igre postavlja se pitanje koja "šetnja" po Markovljevom lancu ima najveće vjerojatnosti, bez prelaska u stanje latencije, pri čemu je postignut koš.

Popis svih stanja unutar faze tranzicije i pozicijskog napada nalazi se u poglavlju 6.2. –uzorak varijabli.

Važno je naglasiti da ako promotrimo k-tu potenciju matrice prijelaza:

$$P^k = \left[\begin{array}{cccc|ccc} P^{(k)}_{1,1} & P^{(k)}_{1,2} & P^{(k)}_{1,3} & P^{(k)}_{1,4} & P^{(k)}_{1,5} & P^{(k)}_{1,6} & P^{(k)}_{1,7} \\ P^{(k)}_{2,1} & P^{(k)}_{2,2} & P^{(k)}_{2,3} & P^{(k)}_{2,4} & P^{(k)}_{2,5} & P^{(k)}_{2,6} & P^{(k)}_{2,7} \\ P^{(k)}_{3,1} & P^{(k)}_{3,2} & P^{(k)}_{3,3} & P^{(k)}_{3,4} & P^{(k)}_{3,5} & P^{(k)}_{3,6} & P^{(k)}_{3,7} \\ P^{(k)}_{4,1} & P^{(k)}_{4,2} & P^{(k)}_{4,3} & P^{(k)}_{4,4} & P^{(k)}_{4,5} & P^{(k)}_{4,6} & P^{(k)}_{4,7} \\ \hline P^{(k)}_{5,1} & P^{(k)}_{5,2} & P^{(k)}_{5,3} & P^{(k)}_{5,4} & 0 & 0 & 0 \\ \hline P^{(k)}_{6,1} & P^{(k)}_{6,2} & P^{(k)}_{6,3} & P^{(k)}_{6,4} & 0 & 0 & 0 \\ \hline p^{(k)}_{7,1} & p^{(k)}_{7,2} & p^{(k)}_{7,3} & p^{(k)}_{7,4} & 0 & 0 & 0 \end{array}\right]$$

njen pojedini (blok) element je prijelazna vjerojatnost između 2 pojedina stanja unutar *k* koraka.

4. CILJ RADA

Cilj ovog rada je objasniti teoretske koncepte koji omogućavaju upotrebu diskretnih slučajnih procesa, Markovljevih lanaca u analizi stanja i prijelaznih vjerojatnosti u košarkaškoj igri. U skladu s time, pokušat će se objasniti opće metodološke smjernice za korištenje teoretskog koncepta Markovljevih lanaca u metodologiji znanstvenog istraživanja na polju kineziologije. Nadalje, cilj je analizirati i objasniti mogućnosti ekstenzije definicije Markovljevog lanca da bi u potpunosti odgovarali pojedinoj proučavanoj kineziološkoj stvarnosti.

U skladu s time, cilj ovog rada je empirijska verifikacija modela diskretnih slučajnih procesa, Markovljevih lanaca u kineziologiji kroz utvrđivanje i analiziranje prijelaznih vjerojatnosti i razlike između prijelaznih vjerojatnosti među pojedinim stanjima napada unutar faza napada košarkaške igre.

Da bi se realizirao opći cilj istraživanja, postavljeni su slijedeći parcijalni ciljevi:

1. Diskriminirati uspješan od neuspješnog modela taktike igre (strukture faze napada) s obzirom na postavljena stanja u pojedinoj fazi napada za pojedini klub, odnosno za europsku košarku u cjelini.

2. Utvrditi dominantno kontrolirani model europske košarke u smislu prijelaznih vjerojatnosti među stanjima pojedine faze tijeka igre.

3. Definirati nestandardne napadačke situacijske varijable u košarci, te ih analizirati klasičnim multivarijatnim statističkim metodama.

U skladu s ciljem rada, dane su glavne definicije i svojstva slučajnih procesa, specijalno Markovljevih lanaca te usporedo s tim funkcionalna svojstva košarkaške igre koja su kompatibilna za njihovo korištenje u kineziološkoj znanosti.

5. HIPOTEZE

Temeljem prethodno postavljenih ciljeva istraživanja oblikovane su sljedeće hipoteze koje se mogu podijeliti u tri skupine.

Prva skupina hipoteza se odnosi na diskriminaciju uspješnih napadačkih taktičkih djelovanja od neuspješnih.

U skladu s time može se postaviti slijedeća hipoteza:

H1:

Postoji podskup skupa svih stanja napada (tranzicije i pozicije) takav da je statistički značajno veća vjerojatnost prelaska iz bilo kojeg njegovog stanja u neko stanje s uspješnim ishodom, nego vjerojatnost prijelaza bilo kojeg stanja ostalih elemenata skupa svih stanja napada u neko stanje sa uspješnim ishodom.

Odnosno, ako sa A označimo skup koji se sastoji od svih stanja tranzicije napada ili pozicijskog napada odnosno $A=\{n_1+n_2+1,...,n_1+n_2+n_3+n_4\}$, s D označimo skup koji se sastoji od stanja s uspješnim ishodom $D=\{n_1+n_2+n_3+n_4+n_5+1,...,n_1+n_2+n_3+n_4+n_5+n_6\}$, tada je moguće skup A particionirati u dva disjunktna podskupa, B i C ($A=B\cup C, B\cap C=\phi$) tako da vrijedi:

Za svako stanje $l\in B$ i za svako stanje $m\in C$ vrijedi:

$$\sum_{k\in D} p_{l,k} >> \sum_{k\in D} p_{m,k}$$

Druga skupina hipoteza se odnosi na potvrđivanje dominantno kontroliranog modela igre u sadašnjoj europskoj košarci.

H2:

Vjerojatnost prijelaza iz bilo kojeg stanja prve grupe u bilo koje stanje druge grupe stanja je statistički značajno manja od 0.15, odnosno vjerojatnost gubljenja lopte iz bilo kojeg stanja napada (n_3 i n_4) je statistički manja od 0.15, odnosno:

elementi matrica $P_{i,5}$ *za* $i=3,4$ su statistički značajno manji od 0.15.

H3:

Vjerojatnost prijelaza iz pojedinog stanja tranzicijskog napada u bilo koje stanje pozicijskog napada je statistički značajno veća od 0.85.

Odnosno ako uzmemo stanje $i \in \{n_1+n_2+1,...,n_1+n_2+n_3\}$ te stanje $j \in \{n_1+n_2+n_3+1,...,n_1+n_2+n_3+n_4\}$ vrijedi

$$\sum_j p_{i,j} \geq 0.85$$

Treća skupina hipoteza se odnosi na doprinose analizi standardnih pokazatelja situacijske učinkovitosti

H4:

Statistički značajno je veća vjerojatnost prijelaza iz faze latencije u pojedino stanje tranzicije obrane nego u novo stanje pozicijskog napada.

Odnosno, ako je $j \in \{n_1+1,...,n_1+n_2\}$ i $k \in \{n_1+n_2+n_3+1,...,n_1+n_2+n_3+n_4\}$ statistički značajno vrijedi

$$\sum_j p_{7,j} \geq \sum_k p_{7,k}$$

H5:

Unutar tranzicije napada, odnosno pozicijskog napada, vjerojatnost prijelaza iz inicijalne faze u završnu fazu je statistički značajno manja od 5%.

Odnosno ako pojedina faza napada (tranzicija ili pozicija) ima I_i inicijalnih stanja, M_i središnjih stanja i F_i finalnih stanja pri čemu je $I_i + M_i + F_i = n_i$ $i=3,4$, tada za svako inicijalno stanje l i finalno stanje m vrijedi:

$$\sum_m p_{l,m} \leq 0.05$$

6. METODE RADA

6.1. Uzorak entiteta

Podaci će biti prikupljeni na pseudoslučajan način odabrane 24 utakmice Europske košarkaške lige u natjecateljskoj sezoni 2009./2010. u kojoj je sudjelovalo 16 košarkaških ekipa (Top 16). Pseudoslučajan odabir je korišten da bi se postiglo približno jednoliko distribuiranje broja utakmica za svaki pojedini klub.

6.2. Uzorak varijabli

Inicijalna stanja pozicijskog napada:

1. V_PN_I_1: Raspored 1-4 visoko (3 vanjska igrača, 2 visoka posta) *(engl. Offensive alignment 1-4 high)*
2. V_PN_I_2: Raspored 1-4 nisko (3 vanjska igrača, 2 niska posta) *(engl. Offensive alignment 1-4 low)*
3. V_PN_I_3: Raspored 1-2-2 (1 središnji igrač, 2 visoka posta i 2 igrača u kutovima) *(engl. Offensive alignment 1-2-2)*
4. V_PN_I_4: Raspored 1-2-2 invertirano (1 središnji igrač, 2 niska posta i 2 krilna igrača) *(engl. Offensive alignment 1-2-2 inverted)*
5. V_PN_I_5: Raspored 1-2-2 široko (5 igrača na vanjskim pozicijama) *(engl. Offensive alignment 1-2-2 spread)*
6. V_PN_I_6: Raspored 1-2-2 box (1 središnji igrač, 2 niska i 2 visoka posta) *(engl. Offensive alignment 1-2-2 box)*
7. V_PN_I_7: Raspored 2-3 duboko (4 vanjska igrača i 1 niski post ili 3 vanjska i 2 niska posta) *(engl. Offensive alignment 2-3 low)*

8. V_PN_I_8: Raspored 2-3 visoko (4 vanjska igrača i 1 visoki post) *(engl. Offensive alignment 2-3 high)*
9. V_PN_I_9: Raspored 2-1-2 (4 vanjska igrača i visoki post) *(engl. Offensive alignment 2-1-2)*
10. V_PN_I_10: Raspored 2-2-1 (4 vanjska igrača i 1 niski post) *(engl. Offensive alignment 2-2-1 spread)*
11. V_PN_I_11: Raspored 1-3-1 (3 vanjska igrača, 1 visoki post i 1 niski post) *(engl. Offensive alignment 1-3-1, 3 outside, 1 high post, 1 low post)*
12. V_PN_I_12: Raspored 1-3-1 (2 igrača na rubu linije slobodnih bacanja, 1 visoki post, 1 ispod koša) *(engl. Offensive alignment 1-3-1, 2 elbow, 1 high post, 1 deep)*
13. V_PN_I_13: Raspored 1-3-1 (2 igrača na rubu linije slobodnih bacanja, 1 u sredini, 1 ispod koša) *(engl. Offensive alignment 1-3-1, 2 elbow, 1 middle, 1 deep)*
14. V_PN_I_14: Raspored 1-1-3 dijamant (2 vanjska igrača, 1 visoki post i 2 niska posta) *(engl. Offensive alignment 1-1-3 diamond)*
15. V_PN_I_15: Raspored 2 igrača u liniji s obje strane napada (*engl. Double stack*)
16. V_PN_I_16: Raspored 3 igrača u liniji (*engl. Triple stack*)
17. V_PN_I_17: Raspored 4 igrača u liniji *(engl. 4 men stack)*
18. V_PN_I_18: Nedefiniran raspored napada *(engl. Undefined offensive alignment)*
19. V_PN_I_19: Nesimetričan raspored (*engl. Asimmetrical alignment*)

Stanja središnjice pozicijskog napada:

1. V_PN_S_1: Vanjsko otkrivanje za prijem lopte (*engl. V and L cut*)
2. V_PN_S_2: Utrčavanje iza leđa (*engl. Backdoor cut*)
3. V_PN_S_3: Utrčavanje ispred igrača (*engl. Front cut*)
4. V_PN_S_4: Čišćenje strane napada (*engl. Clear out*)

5. V_PN_S_5: Z otvaranje (*engl. Z cut)*
6. V_PN_S_6: Dodaj i idi *(engl. Give and Go)*
7. V_PN_S_7: Uručenje lopte *(engl. Handoff)*
8. V_PN_S_8: Varka uručenja (*engl. Fake handoff*)
9. V_PN_S_9: Postavljanje leđima košu *(engl. Post-up)*
10. V_PN_S_10: Ponovno postavljanje leđima košu (*engl. Reposting*)
11. V_PN_S_11: Otvaranje na kratkom korneru (*engl. Short corner*)
12. V_PN_S_12: Unutarnje utrčavanje s slabe strane napada (*engl. Inside cut from weak side*)
13. V_PN_S_13: Ubacivanje u prednju poziciju u trapezu *(engl. Duck in)*
14. V_PN_S_14: Lob dodavanje u trapez s središnje pozicije *(engl. High-low, lob pass)*
15. V_PN_S_15: Lob dodavanje niskom postu s krilne pozicije *(engl. Lob pass from the wing)*
16. V_PN_S_16: Otkrivanje na poziciju visokog posta (*engl. Flash post*)
17. V_PN_S_17: Otkrivanje na poziciju visokog posta kao pomoć protiv presinga (*engl. Flash post as press release*)
18. V_PN_S_18: Križanje oko visokog posta (*engl. High post split*)
19. V_PN_S_19: Križanje oko srednjeg posta) (*engl. Middle post split*)
20. V_PN_S_20: Dva direktna pravolinijska utrčavanja nakon dodavanja srednjem postu (*engl. Middle post pass – two straight cuts*)
21. V_PN_S_21: Promjena pozicije na vanjskom prostoru nakon dodavanja niskom postu (*engl. Low post pass – relocation*)
22. V_PN_S_22: Pravolinijsko utrčavanje nakon dodavanja niskom postu (*engl. Low post pass – solo cut*)
23. V_PN_S_23: Postavljanje suprotnog bloka nakon dodavanja niskom ili srednjem postu (*engl. Middle/Low post pass - split screen*)
24. V_PN_S_24: Čeonolinijski blok *(engl. Baseline screen- single)*

25. V_PN_S_25: Horizontalni blok s 2 igrača *(engl. Horizontal double stack)*
26. V_PN_S_26: Vertikalni blok s 2 igrača *(engl. Vertical double stack)*
27. V_PN_S_27: Vertikalni blok u donjem smjeru na jakoj strani napada *(engl. Single down screen- strong side)*
28. V_PN_S_28: Vertikalni blok u donjem smjeru na slaboj strani napada *(engl. Single down screen)*
29. V_PN_S_29: Uvijanje oko vertikalnog bloka *(engl. Curl)*
30. V_PN_S_30: Otvaranje od lopte nakon bloka na igrača bez lopte *(engl. Fade)*
31. V_PN_S_31: UCLA manevar *(engl. UCLA cut)*
32. V_PN_S_32: Lažni UCLA manevar *(engl. Fake UCLA cut)*
33. V_PN_S_33: UCLA manevar – leđni blok *(engl. UCLA cut – backscreen)*
34. V_PN_S_34: Pojedinačni leđni blok na korner i krilnoj poziciji *(engl. Single backscreen corner-wing)*
35. V_PN_S_35: Dva uzastopna vertikalna bloka na slabijoj strani napada *(engl. Vertical staggered screen (weak side))*
36. V_PN_S_36: Dva uzastopna vertikalna bloka na jačoj strani napada *(engl. Vertical staggered screen (strong side))*
37. V_PN_S_37: Dva uzastopna dijagonalna bloka na jačoj strani napada *(engl. Diagonal staggered screen (strong side))*
38. V_PN_S_38: Tri uzastopna vertikalna bloka *(engl. Triple staggered vertical screen)*
39. V_PN_S_39: Tri uzastopna horizontalna bloka *(engl. Triple staggered horizontal screen)*
40. V_PN_S_40: Dva uzastopna horizontalna bloka *(engl. Horizontal staggered screen)*
41. V_PN_S_41: Dva uzastopna horizontalna bloka na razini linije slobodnih bacanja *(engl. Horizontal staggered screen on free throw line extended level)*
42. V_PN_S_42: Blok kroz trapez *(engl. Cross screen)*
43. V_PN_S_43: Blok kroz trapez u suprotnom smjeru *(engl. Inverted cross screen)*

44. V_PN_S_44: Blok na razini linije slobodnih bacanja *(engl. Cross screen on free throw line extended level)*
45. V_PN_S_45: Dijagonalni leđni blok *(engl. Diagonal backscreen)*
46. V_PN_S_46: Vertikalni leđni blok na jačoj strani napada) *(engl. Vertical backscreen (strong side))*
47. V_PN_S_47:Vertikalni leđni blok na slaboj strani napada) *(engl. Vertical backscreen (weak side)-alley oop action)*
48. V_PN_S_48: Leđni blok-čeonolinijski blok u korneru *(engl. Backscreen - rescreen (corner)*)
49. V_PN_S_49: Dva uzastopna leđna bloka *(engl. Staggered backscreen)*
50. V_PN_S_50: Dvostruki leđni blok *(engl. Double backscreen)*
51. V_PN_S_51: Blok od lopte *(engl. Flare screen)*
52. V_PN_S_52: Dvostruki blok od lopte *(engl. Double flare screen)*
53. V_PN_S_53: Dva uzastopna bloka od lopte *(engl. Staggered flare screens)*
54. V_PN_S_54: Blok za blokera na igraču bez lopte *(engl. Screen for screener)*
55. V_PN_S_55: Dijagonalni blok za blokera na igraču bez lopte) *(engl. Diagonal screen for screener)*
56. V_PN_S_56: Blok za blokera –flex manevar *(engl. Screen for screener (flex maneuver))*
57. V_PN_S_57: Blok za igrača sa loptom na strani s otvaranjem prema košu ili prema vani *(engl. Pick and roll (pop) – side)*
58. V_PN_S_58: Blok za igrača sa loptom na sredini s otvaranjem prema košu ili vani *(engl. Pick and roll (pop) – middle)*
59. V_PN_S_59: Leđni blok za igrača sa loptom s otvaranjem prema košu ili vani *(engl. Pick and roll (pop) – flat)*
60. V_PN_S_60: Blok za igrača s loptom na razini kuta linije slobodnih bacanja sa otvaranjem prema košu ili vani *(engl. Pick and roll (pop) – elbow)*

61. V_PN_S_61: Blok za igrača sa loptom na krilu s otvaranjem prema košu ili vani *(engl. Pick and roll (pop) – wing)*

62. V_PN_S_62: Blok za igrača sa loptom u korneru s otvaranjem prema košu ili vani *(engl. Pick and roll (pop) – corner)*

63. V_PN_S_63: Ponovljeni blok za igrača s loptom *(engl. Repick)*

64. V_PN_S_64: Uzastopni blokovi za igrača s loptom *(engl. Staggered picks)*

65. V_PN_S_65: Lažni blok za igrača s loptom *(engl. Slip screen)*

66. V_PN_S_66: Blok za igrača s loptom na niskom postu *(engl. Low post pick)*

67. V_PN_S_67: Blok za blokera *(engl. Pick for picker)*

68. V_PN_S_68: Ubacivanje lopte ispod koša; *Box* raspored *(engl. Baseline out of bound; box alignment)*

69. V_PN_S_69: Ubacivanje lopte ispod koša; 4 *Stack* raspored *(engl. Baseline out of bound;4 stack alignment)*

70. V_PN_S_70: Ubacivanje lopte ispod koša; 3 *Stack* raspored *(engl. Baseline out of bound;3 stack alignment)*

71. V_PN_S_71: Ubacivanje lopte ispod koša; trokut raspored *(engl. Baseline out of bound; triangle alignment)*

72. V_PN_S_72: Ubacivanje lopte ispod koša; raspored 4 duboko *(engl. Baseline out of bound;4 low alignment)*

73. V_PN_S_73: Ubacivanje lopte ispod koša; raspored 4 visoko *(engl. Baseline out of bound;4 high alignment)*

74. V_PN_S_74: Ubacivanje lopte ispod koša; raspored 3 duboko *(engl. Baseline out of bound;3 low alignment)*

75. V_PN_S_75: Ubacivanje lopte ispod koša; raspored 3 visoko *(engl. Baseline out of bound;3 high alignment)*

76. V_PN_S_76: Dijamant raspored *(engl. Diamond alignment)*

77. V_PN_S_77: Ubacivanje lopte ispod koša; asimetrični rasporedi *(engl. Baseline out of bound; asymmetrical alignments)*

78. V_PN_S_78: Ubacivanje lopte s bočne linije; *Box* raspored *(engl. Sideline out of bound frontcourt; box alignment)*

79. V_PN_S_79: Ubacivanje lopte s bočne linije; *Wall* raspored – 4 igrača u liniji *(engl. Sideline out of bound frontcourt; wall alignment – 4 in line)*

80. V_PN_S_80: Ubacivanje lopte s bočne linije; *Wall* raspored – 3 igrača u liniji *(engl. Sideline out of bound frontcourt; wall alignment – 3 in line)*

81. V_PN_S_81: Ubacivanje lopte s bočne linije; trokut raspored *(engl. Sideline out of bound frontcourt; triangle alignment)*

82. V_PN_S_82: Ubacivanje lopte s bočne linije; dijamant raspored *(engl. Sideline out of bound frontcourt; diamond alignment)*

83. V_PN_S_83: Ubacivanje lopte s bočne linije; asimetrični rasporedi *(engl. Sideline out of bound frontcourt; asymmetrical alignments)*

84. V_PN_S_84: Ubacivanje lopte s bočne linije; nakon minute odmora, zadnje dvije minute utakmice; *High box* raspored *(engl. Sideline out of bound after time out, last 2 minutes; high box alignment)*

85. V_PN_S_85: Ubacivanje lopte s bočne linije; nakon minute odmora, zadnje dvije minute utakmice; *Low box* raspored *(engl. Sideline out of bound after time out, last 2 minutes; low box alignment)*

86. V_PN_S_86: Ubacivanje lopte s bočne linije; nakon minute odmora, zadnje dvije minute utakmice; *High stack* raspored *(engl. Sideline out of bound after time out, last 2 minutes; high stack alignment)*

87. V_PN_S_87: Ubacivanje lopte s bočne linije; nakon minute odmora, zadnje dvije minute utakmice; *Double stack* raspored *(engl. Sideline out of bound after time out, last 2 minutes; double stack alignment)*

88. V_PN_S_88: Ubacivanje lopte s bočne linije; nakon minute odmora, zadnje dvije minute utakmice; *Low stack* raspored *(engl. Sideline out of bound after time out, last 2 minutes; Low stack alignment)*

89. V_PN_S_89: Ubacivanje lopte s bočne linije; nakon minute odmora, zadnje dvije minute utakmice; Nesimetrični raspored *(engl. Sideline out of bound after time out, last 2 minutes; Asymmetrical alignment)*

90. V_PN_S_90: Opterećenje strane u napadu na zonu *(engl. Overload vs zone)*

91. V_PN_S_91: Dvostruko opterećenje strane u napadu na zonu *(engl. Double overload vs zone)*

92. V_PN_S_92: Prelazak s pozicije visokog posta na vanjsku poziciju u napadu protiv zone *(engl. High post step out vs zone)*

93. V_PN_S_93: Protok lopte protiv zonske obrane *(engl. Ball flow vs zone)*

94. V_PN_S_94: Dodavanje s opterećene na rasterećenu stranu u napadu na zonu *(engl. Skip pass vs zone)*

95. V_PN_S_95: *High-low* kretnja protiv zone *(engl. High-low move vs zone)*

96. V_PN_S_96: Zavlačenje iza leđa zonske obrane *(engl. Operating behind zone defense)*

Stanja završnice pozicijskog napada:

1. V_PN_Z_1: Šut s mjesta *(engl. Spot up shot)*
2. V_PN_Z_2: Šut ispod koša *(engl. Lay-up)*
3. V_PN_Z_3: Šut iz vođenja *(engl. Dribble jumper)*
4. V_PN_Z_4: Utrčavanje prema košu uključujući dodavanja *(engl. Cut to basket including passes)*
5. V_PN_Z_5: Ubacivanje u prednju poziciju u trapezu *(engl. High-low)*

6. V_PN_Z_6: Prodor prema košu uključujući dodavanja *(engl. Drive to basket including passes)*
7. V_PN_Z_7: Dodaj i idi *(engl. Give and go)*
8. V_PN_Z_8: Loš razmak između igrača u napadu *(engl. Bad spacing)*
9. V_PN_Z_9: Izolacije uključujući dodavanja *(engl. Isolations including passes)*
10. V_PN_Z_10: Igra leđima prema košu uključujući dodavanja *(engl. Post up including passes)*
11. V_PN_Z_11: Blok na igrača s loptom s otvaranjem prema košu uključujući dodavanja *(engl. Pick and roll including passes)*
12. V_PN_Z_12: Prodor igrača s loptom suprotno od smjera postavljanja bloka *(engl. Penetration opposite of pick)*
13. V_PN_Z_13: Blok na igrača s loptom s otvaranjem prema vani uključujući dodavanja *(engl. Pick and pop including passes)*
14. V_PN_Z_14: Uručenja uključujući dodavanja *(engl. Handoffs including passes)*
15. V_PN_Z_15: Izlaz iz bloka na igrača bez lopte, uključujući dodavanja *(engl. Cut off the screen including passes)*
16. V_PN_Z_16: Skok u napadu s poentiranjem *(engl. Offensive rebound –putback)*
17. V_PN_Z_17: Napadački skakački raspored 2-2-1 *(engl. Offensive rebounding plan 2-2-1)*
18. V_PN_Z_18: Napadački skakački raspored 3-1-1 *(engl. Offensive rebounding plan 3-1-1)*
19. V_PN_Z_19: Napadački skakački raspored 4-0-1 *(engl. Offensive rebounding plan 4-0-1)*
20. V_PN_Z_20: Napadački skakački raspored 3-0-2 *(engl. Offensive rebounding plan 3-0-2)*
21. V_PN_Z_21: Napadački skakački raspored 2-1-2 *(engl. Offensive rebounding plan 2-1-2)*
22. V_PN_Z_22: Napadački skakački raspored 1-1-3 *(engl. Offensive rebounding plan 1-1-3)*

Kao što je i vidljivo iz prethodno definiranih stanja igre, **inicijalna** stanja pozicijskog napada su definirana početnim igračkim rasporedom. **Središnjica** pozicijskog napada je definirana daljnjim

tijekom napada, dok će **završnica** pozicijskog napada bit procijenjena ekspertnim znanjem i iskustvom kao završni manevar[5] kojim se ostvaruje prednost i u konačnici šut.

Inicijalna stanja tranzicijskog napada:

1. V_TN_I_1: Prvo vanjsko dodavanje prema sredini nakon skoka u obrani *(engl. Outlet pass middle after rebound)*
2. V_TN_I_2: Prvo vanjsko dodavanje prema sredini nakon uspješnog šuta iz igre i/ili ubacivanje lopte ispod koša u zadnjem polju *(engl. Outlet pass middle after made basket and/or inbound in backcourt)*
3. V_TN_I_3: Ubacivanje lopte s bočne linije u zadnjem polju *(engl. Sideline inbound backcourt)*
4. V_TN_I_4: Prvo vanjsko dodavanje prema sredini nakon uspješnog šuta s linije slobodnih bacanja *(engl. Outlet pass middle after made free throw)*
5. V_TN_I_5: Prvo vanjsko dodavanje prema boku nakon skoka u obrani *(engl. Outlet pass side after rebound)*
6. V_TN_I_6: Prvo vanjsko dodavanje prema boku nakon uspješnog šuta iz igre *(engl. Outlet pass side after made basket)*
7. V_TN_I_7: Prvo vanjsko dodavanje prema boku nakon uspješnog šuta s linije slobodnih bacanja *(engl. Outlet pass side after made free throw)*
8. V_TN_I_8: Prvo vanjsko dodavanje prema boku pa dodavanje prema sredini *(engl. Outlet pass side – pass middle)*
9. V_TN_I_9: Dolazak na uručenje nakon skoka *(engl. Handoff after rebound)*
10. V_TN_I_10: Skakač kreće u vođenje prema sredini *(engl. Rebounder drive middle)*
11. V_TN_I_11: Skakač kreće u vođenje prema boku *(engl. Rebounder drive side)*

[5] Manevar je kompleksni skup elemenata košarkaške igre koji tvore svrhovitu taktičku cjelinu

12. V_TN_I_12: Dugo dodavanje nakon skoka u obrani – situacija pretrčavanja obrane *(engl. Baseball long pass after rebound -run out situation)*

13. V_TN_I_13: Dugo dodavanje nakon uspješnog šuta iz igre – situacija pretrčavanja obrane *(engl. Baseball long pass after made basket (run out situation))*

14. V_TN_I_14: Dugo dodavanje nakon uspješnog šuta s linije slobodnih bacanja – situacija pretrčavanja obrane *(engl. Baseball long pass after made free throw (run out situation))*

15. V_TN_I_15: Protunapad nakon ukradene lopte *(engl. Push the ball after steal)*

16. V_TN_I_16: Napad protiv presinga nakon uspješnog šuta iz igre/ šuta s linije slobodnih bacanja sa dva igrača na rubovima linije slobodnih bacanja koji se otvaraju za prijem lopte *(engl. Press offense after made basket/made free throw; two guards on elbows get open)*

17. V_TN_I_17: Napad protiv presinga nakon uspješnog šuta iz igre/ šuta s linije slobodnih bacanja sa jednim igračem na liniji slobodnih bacanja koji se otvara za prijem lopte *(engl. Press offense after made basket/made free throw; guard on elbow gets open)*

18. V_TN_I_18: Napad protiv presinga nakon uspješnog šuta iz igre/ šuta s linije slobodnih bacanja sa horizontalnim blokom visokog igrača za beka organizatora u visini linije slobodnih bacanja *(engl. Press offense after made basket/made free throw; horizontal cross screen for point guard)*

19. V_TN_I_19: Napad protiv presinga nakon uspješnog šuta iz igre/ šuta s linije slobodnih bacanja s dva igrača na rubovima linije slobodnih bacanja koji se otvaraju za prijem lopte i visokog igrača koji izvodi *flash* utrčavanje u sredinu prema lopti u visini linije slobodnih bacanja *(engl. Press offense after made basket/made free throw; two guards on elbows get open, big guy flash to the middle)*

20. V_TN_I_20: Napad protiv presinga nakon uspješnog šuta iz igre/ šuta s linije slobodnih bacanja s tri igrača na razini linije slobodnih bacanja koji se otvaraju za prijem lopte *(engl. Press offense after made basket/made free throw; three players on elbows get open)*

21. V_TN_I_21: Bočno ubacivanje lopte protiv presinga s dva igrača koji se otvaraju za prijem lopte *(engl. Side line inbound vs press; two guards get open)*

Stanja središnjice tranzicijskog napada:

1. V_TN_S_1: Vođenje lopte prema sredini terena, dva pratioca trče po jedan prema svakom rubu linije slobodnih bacanja, dva krila trče na svakoj strani korak od bočne linije *(engl. Push to the middle, two trailers, two wings)*
2. V_TN_S_2: Brzi prodor na otvorenom igralištu *(engl. Open court penetration)*
3. V_TN_S_3: Vođenje lopte prema rubu linije slobodnih bacanja, dva pratioca trče prema suprotnom rubu linije slobodnih bacanja, dva krila trče na svakoj strani korak od bočne linije *(engl. Push to the elbow, two trailers, two wings)*
4. V_TN_S_4: Vođenje lopte prema rubu linije slobodnih bacanja, jedan pratilac trči prema suprotnom rubu linije slobodnih bacanja, dva igrača popunjavaju istu bočnu liniju *(engl. Push to the elbow, one trailer, two players side line)*
5. V_TN_S_5: Dodavanje lopte prema boku u tranziciji *(engl. Sideline pass in transition)*
6. V_TN_S_6: Vođenje lopte uz bočnu liniju, krilni igrač trči duž iste bočne linije, dva pratioca trče kroz sredinu igrališta, krilni igrač duž suprotne bočne linije *(engl. Sideline push, occupied side)*
7. V_TN_S_7: Vođenje lopte uz bočnu liniju, dva igrača trče duž suprotne bočne linije, dva pratioca trče kroz sredinu igrališta *(engl. Sideline push, clear side)*
8. V_TN_S_8: Napad protiv presinga; utrčavanje krila sa slabe strane napada prema sredini nakon ulaznog dodavanja beku *(engl. Press offense; weakside wing cut to the middle after inbound pass)*
9. V_TN_S_9: Napad protiv presinga; napredovanje lopte kontroliranim driblingom uz zadržavanje igrača osiguranja 1 korak iznad linije lopte za pomoć u slučaju udvajanja*(engl. Press offense;safety player one step above ball level as trap release)*
10. V_TN_S_10: Napad protiv presinga; nekontrolirano vođenje uz bočnu liniju *(engl. Press offense;uncontrolled dribble along sideline)*
11. V_TN_S_11: Napad protiv presinga; loš raspored igrača *(engl. Press offense; bad alignment)*

12. V_TN_S_12: Napad protiv presinga; flash istrčavanje visokog igrača prema sredini igrališta *(engl. Press offense;flash cut to middle big guy as press release)*

13. V_TN_S_13: Napad protiv čistog m~m presinga; leđni blok igraču s loptom *(engl. Press offense; backscreen to dribbler as a release against straight m~m press)*

14. V_TN_S_14: Omogućavanje napredovanja lopte pod pritiskom pozicioniranjem visokog igrača ispred beka *(engl. Big guy helps to the guard)*

Stanja završnice tranzicijskog napada:

1. V_TN_Z_1: 1-0
2. V_TN_Z_2: 1-1
3. V_TN_Z_3: 2-1
4. V_TN_Z_4: 2-2
5. V_TN_Z_5: 1-2
6. V_TN_Z_6: 3-1
7. V_TN_Z_7: 3-2
8. V_TN_Z_8: 2-3
9. V_TN_Z_9: 3-3
10. V_TN_Z_10: 4-2
11. V_TN_Z_11: 4-3
12. V_TN_Z_12: 5-3
13. V_TN_Z_13: 5-4
14. V_TN_Z_14: 5-5 Rani napad: suradnja visokog i niskog posta *(engl. Early offense: hi-low game)*

15. V_TN_Z_15: 5-5 Rani napad: brzi prijenos lopte preko drugog pratioca *(engl. Early offense: swing the ball trough second trailer)*

16. V_TN_Z_16: 5-5 Rani napad: dodavanje lopte s opterećene na rasterećenu stranu igrališta *(engl. Early offense: skip pass)*

17. V_TN_Z_17: 5-5 Rani napad: prodor s loptom prema košu – poentiranje ili dodavanje slobodnom igraču *(engl. Early offense: drive – kick)*

18. V_TN_Z_18: Izolacije u tranziciji *(engl. Early offense: isolation)*

19. V_TN_Z_19: 5-5 Rani napad: raspored 2-3, „trokut napad“ (*engl. Early offense: 2-3 alignment, triangle offense*)

20. V_TN_Z_20: 5-5 Rani napad: raspored 2-3, (*engl. Early offense: 2-3 alignment*)

21. V_TN_Z_21: 5-5 Rani napad: tranzicijski blok na igrača sa loptom s prvim pratiocem kao blokerom *(engl. Early offense: transition pick with first trailer)*

22. V_TN_Z_22: 5-5 Rani napad: tranzicijski blok na igrača s loptom s drugim pratiocem kao blokerom *(engl. Early offense: transition pick with second trailer)*

23. V_TN_Z_23: 5-5 Rani napad: tranzicijski leđni blok na igrača s loptom *(engl. Early offense: transition pick – flat)*

24. V_TN_Z_24: 5-5 Rani napad: tranzicijski leđni blok *(engl. Early offense: backscreen)*

25. V_TN_Z_25: 5-5 Rani napad: turnout manevar *(engl. Early offense: turnout maneuver)*

26. V_TN_Z_26: 5-5 Rani napad: blok za blokera *(engl. Early offense: screen for screener)*

27. V_TN_Z_27: 5-5 Rani napad: blok za blokera na igraču s loptom *(engl. Early offense: pick for picker)*

28. V_TN_Z_28: Prodor prema košu uključujući dodavanja *(engl. Drive to basket including passes)*

29. V_TN_Z_29: Šut s mjesta *(engl. Spot up shot)*

30. V_TN_Z_30: Šut iz dotrčavanja prvog pratioca *(engl. First trailer transition shot)*

31. V_TN_Z_31: Šut iz vođenja *(engl. Dribble jumper)*

32. V_TN_Z_32: Šut ispod koša *(engl. Lay up)*

33. V_TN_Z_33: Pretrčavanje bočnog igrača - šut ispod koša *(engl. Run out wing - lay up)*

34. V_TN_Z_34: Pretrčavanje pratioca - šut ispod koša *(engl. Run out trailer - lay up)*

35. V_TN_Z_35: Unutarnje utrčavanje *(engl. Inside cut)*

36. V_TN_Z_36: Rano postavljanje leđima košu, uključujući dodavanja *(engl. Early post up including passes)*
37. V_TN_Z_37: Izlaz iz bloka na igrača bez lopte, uključujući dodavanja *(engl. Off the screen including passes)*
38. V_TN_Z_38: Skok u napadu s poentiranjem *(engl. Offensive rebound - putback)*
39. V_TN_Z_39: Napadački skakački raspored 2-2-1 *(engl. Offensive rebounding plan 2-2-1)*
40. V_TN_Z_40: Napadački skakački raspored 3-1-1 *(engl. Offensive rebounding plan 3-1-1)*
41. V_TN_Z_41: Napadački skakački raspored 4-0-1 *(engl. Offensive rebounding plan 4-0-1)*
42. V_TN_Z_42: Napadački skakački raspored 3-0-2 *(engl. Offensive rebounding plan 3-0-2)*
43. V_TN_Z_43: Napadački skakački raspored 2-1-2 *(engl. Offensive rebounding plan 2-1-2)*
44. V_TN_Z_44: Napadački skakački raspored 1-1-3 *(engl. Offensive rebounding plan 1-1-3)*
45. V_TN_Z_45: Napadački skakački raspored 0 *(engl. Offensive rebounding plan 0)*

Kao što je vidljivo iz definiranih stanja, navedene varijable obuhvaćaju **inicijalna stanja** tranzicijskog napada koja su definirana kao prva akcija[6] nakon dolaska u posjed lopte te stanja **središnjice** tranzicijskog napada koja su definirana načinom popunjavanja linija kretanja i daljnjim tijekom akcije do središnje linije igrališta. U konačnici, **završnica** tranzicijskog napada je definirana situacijama brojčane nadmoći i prostorne prednosti koja se ostvaruje u prednjem polju igrališta (*front court*), situacijama ranog napada te završnom akcijom koja dovodi do šuta.

Pritom je važno istaknuti da je mjerenje stanja bilo temeljeno na sljedeći način definiranim zonama igrališta:

- Središnja zona igrališta je koridor unutar rubova linije slobodnih bacanja
- *Elbow* je rub linije slobodnih bacanja

[6] Napadačka akcija je element košarkaške igre: šut, dodavanje, vođenje, jednostavna kretnja bez lopte,...

- *Side* pozicija je područje omeđeno s jedne strane rubom linije slobodnih bacanja, a s druge strane zamišljenom linijom koja spaja koš i liniju 3 poena pod kutem od 60 stupnjeva u odnosu na čeonu liniju
- Krilno područje je područje između zamišljenih linija koje spajaju koš i liniju 3 poena pod kutevima od 15 do 60 stupnjeva
- Korner pozicija je područje između zamišljenih linija koje spajaju koš i liniju 3 poena pod kutevima od 0 do 15 stupnjeva
- *High Post* - pozicija u razini linije slobodnih bacanja udaljena 4,6m od koša
- *Low post* – područje na rubu linije reketa, vrlo blizu košu (temeljeno na ekspertnoj procjeni)

Stanja uspješnog ishoda:

1. V_U_1: Uspješna realizacija 2 poena
2. V_U_2: Uspješna realizacija 2 poena, dodatno slobodno bacanje
3. V_U_3: Uspješna realizacija 3 poena
4. V_U_4: Uspješna realizacija 3 poena, dodatno slobodno bacanje
5. V_U_5: Napravljen prekršaj obrambenog igrača, ubacivanje lopte sa strane / ispod koša
6. V_U_6: Napravljen prekršaj obrambenog igrača, 3 slobodna bacanja
7. V_U_7: Napravljen prekršaj obrambenog igrača, 2 slobodna bacanja
8. V_U_8: Napravljen nesportski prekršaj
9. V_U_9: Priznat koš, prekršaj, lopta sa strane

Stanja neuspješnog ishoda:

1. V_N_TURN: Izgubljena lopta *(engl. Turnover)*
2. V_N_SO: Neuspješan šut → Skok protivnika u obrani *(engl. Missed shot → Defensive rebound)*

U kontekstu analize napada istaknut ćemo jednu varijablu koja u sebi implicitno sadrži fazu latencije i koja označava nastavak napada, varijablu blokade i dodatno varijablu igranja nogom.

3. V_B_N: Blokirana lopta
4. V_NOGA: Igranje nogom protivničkog igrača

   Također istaknuto mjesto ima varijabla:

5. V_NEUT_SN_N: Neuspješan šut → Skok u napadu (*engl. Missed shot → Offensive rebound*)

Uočimo da je za potrebe našeg istraživanja definirano 19 + 96 + 22 + 21 + 14 + 45 + 9 + 5 = 231 stanje košarkaške igre.

Nadalje, izračunavanjem frekvencija pojedinih stanja u fazama tijeka košarkaške igre, definirane su i oblikovane sljedeće nestandardne napadačke situacijske varijable:

1. NAPUK – ukupan broj napada
2. NAPUS – broj napada koji su završili uspješnim ishodom
3. PNUK – ukupan broj pozicijskih napada
4. PNUS – broj pozicijskih napada koji su završili uspješnim ishodom
5. TNUK – ukupan broj napada koji su započeli i imali neki ishod u tranzicijskom stanju napada
6. TNUS –broj napada koji su završili uspješnim ishodom u tranzicijskom stanju
7. NPICKUK – ukupan broj *pick and roll*, *pick and pop* i *handoff* manevara u pozicijskom napadu
8. NPICKUS – broj *pick and roll*, *pick and pop* i *handoff* manevara koji su završili uspješnim ishodom u pozicijskom napadu

9. NLPUK – ukupan broj prijema lopte na *low post*-u u pozicijskom napadu
10. NLPUS –broj prijema lopte na *low post*-u koji su završili uspješnim ishodom u pozicijskom napadu
11. NISOUK – ukupan broj izolacija na perimetru u pozicijskom napadu
12. NISOUS –broj izolacija na perimetru koje su završile uspješnim ishodom u pozicijskom napadu
13. NBLUK – ukupan broj blokova na igračima bez lopte u pozicijskom napadu
14. NBLUS –broj blokova na igračima bez lopte koji su završili uspješnim ishodom u pozicijskom napadu
15. NPRODUK – ukupan broj prodora s loptom u pozicijskom napadu
16. NPRODUS –broj prodora s loptom koji su završili uspješnim ishodom u pozicijskom napadu
17. NUTRUK – ukupan broj utrčavanja s perimetra te ubacivanja visokih igrača u srce trapeza u pozicijskom napadu
18. NUTRUS – broj utrčavanja s perimetra te ubacivanja visokih igrača u srce trapeza u pozicijskom napadu koji su završili uspješnim ishodom

6.3. Opis eksperimenta (postupka)

Unutar pojedine utakmice košarkaškog prvenstva, izravnim opažanjem i analizom svakog napada su se uočila i identificirala pojedina stanja košarkaške igre - stanja Markovljevog lanca. Stanja su se kodirala (korištenjem kodova danih prije svake varijable u popisu varijabli) i upisivala u *.txt* file.

Tako primjerice ako se u procesu mjerenja, tijekom mjerenja uočilo inicijalno stanje pozicijskog napada „V_PN_I_1: Raspored 1-4 visoko“ zatim stanje središnjice pozicijskog napada „V_PN_S_1: Vanjsko otkrivanje za prijem lopte“ pa nakon toga „V_PN_S_22: Pravolinijsko utrčavanje nakon dodavanja niskom postu“ ,to je upisano kao

…-V_PN_I_4-V_PN_S_1-V_PN_S_22-…

Kao što se može vidjeti iz navedenog niza od 3 stanja, pojedine varijable dijeli separator '-'. Potrebno je naglasiti da je unutar pojedine linije u file-u zabilježen jedan napad. Pritom svaki napad završava s nekom od varijabli koja označava uspješnost. Tako je primjerice nizom stanja

2.V_TN_I_2-V_TN_S_1-V_PN_I_4-V_PN_S_1-V_PN_S_5-V_PN_S_17-V_PN_S_40-V_PN_S_21-V_PN_Z_11-V_PN_Z_5-V_PN_Z_2-V_PN_Z_14-V_U_1

zabilježen jedan napad.

Pritom redni broj na početku linije označava pojedini napad u četrvrtini. Korištena je oznaka QT3 kako bi se specificiralo da se primjerice radi o trećoj četvrtini. Niz znakova X oblika:

XXXXXXXXXXXXXXXXXXX

XXXXXXXXXXXXXXXXXXX

je korišten kao separator između rezultata dviju utakmica. Nakon toga navedena je promatrana utakmica pa u novom redu tim koji se promatra, zatim „Napad" pa oznaka četvrtine npr, QT1.

Tako je primjerice fragment mjerenja drugog, trećeg i četvrtog napada tima Unicaja, prve četvrtine utakmice Žalgiris-Unicaja, dan sa:

XXXXXXXXXXXXXXXXXXX

XXXXXXXXXXXXXXXXXXX

Zalgiris-Unicaja

Unicaja

Napad

QT1

…

2.V_TN_I_2-V_TN_S_1-V_PN_I_4-V_PN_S_1-V_PN_S_5-V_PN_S_17-V_PN_S_40-V_PN_S_21-V_PN_Z_11-V_PN_Z_5-V_PN_Z_2-V_PN_Z_14-V_U_1

3.V_TN_I_9-V_TN_S_5-V_N_TURN

4.V_PN_S_65-V_PN_I_1-V_PN_S_1-V_PN_S_22-V_PN_S_21-V_PN_S_5-V_PN_S_40-V_PN_S_5-V_PN_Z_6-V_PN_Z_3-V_PN_Z_14-V_N_SO

…

6.4. Metode obrade rezultata

Korištenjem programskog jezika C# isprogramirano je interaktivno i reprogramabilno sučelje - softver *State Analyzer ver 1.0.* korištenjem kojeg su izračunati potrebni podaci.

Uz deskriptivni dio, definirane su nestandardne situacijske varijable te je t-testom za nezavisne uzorke ispitana statistička značajnost razlika aritmetičkih sredina varijabli promatranih za uspješne i neuspješne momčadi. Eksplorativnom strategijom određena je latentna struktura nestandardnih uspješnih situacijskih varijabli.

Također su primijenjene multivarijatna regresijska analiza te diskriminacijska analiza za dobivanje povezanosti među odabranim kriterijskim i prediktorskim varijablama, kao i za pronalaženje varijabli koje diskriminiraju uspješne od manje uspješnih napada.

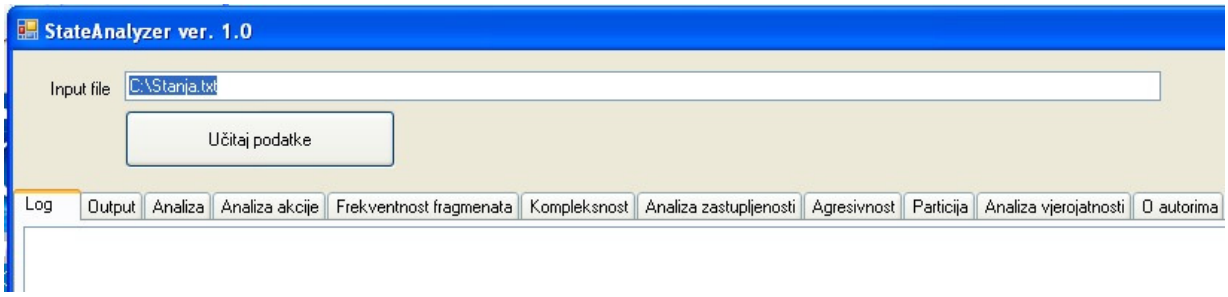
6.5. Opis funkcionalnosti software-a State Analyzer ver. 1.0.

Kao što je i prethodno rečeno, u svrhu lakšeg analiziranja mjerenih podataka, u programskom jeziku C# isprogramirano je interaktivno i reprogramabilno sučelje – softver *State Analyzer ver. 1.0.* Navedeni softver je bio nužan, s obzirom na to da sustavi za statistiku računalom nemaju u sebi integrirane module za analizu Markovljevih procesa.

Izvorni kod softwarea dan je u prilogu u Dodatku 1, dok je izvršna verzija softvera dana na CD-u u privitku ove disertacije.

Na slici 6.1 prikazano je sučelje softwera State Analyzer ver. 1.0.

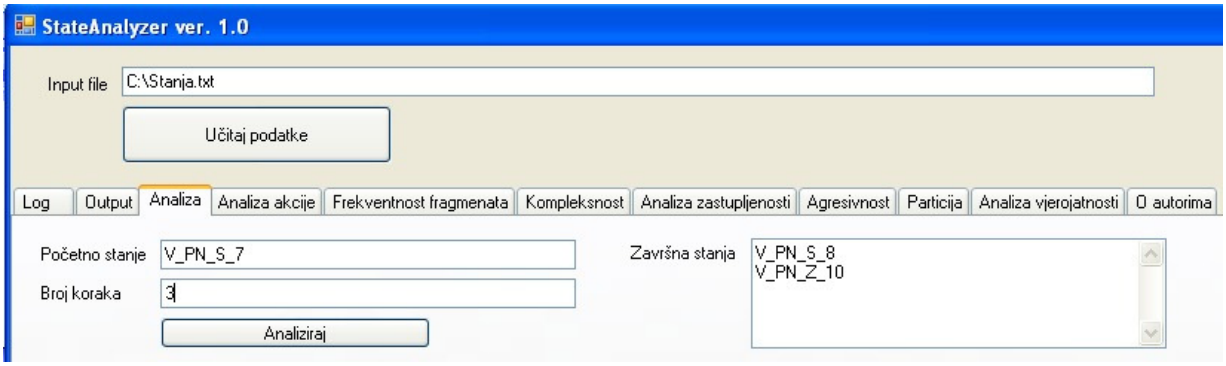
Slika 6.1.: Prikaz sučelja softwarea State Analyzer ver. 1.0.



Kao što je vidljivo sa Slike 6.1. isprogramirani moduli su:

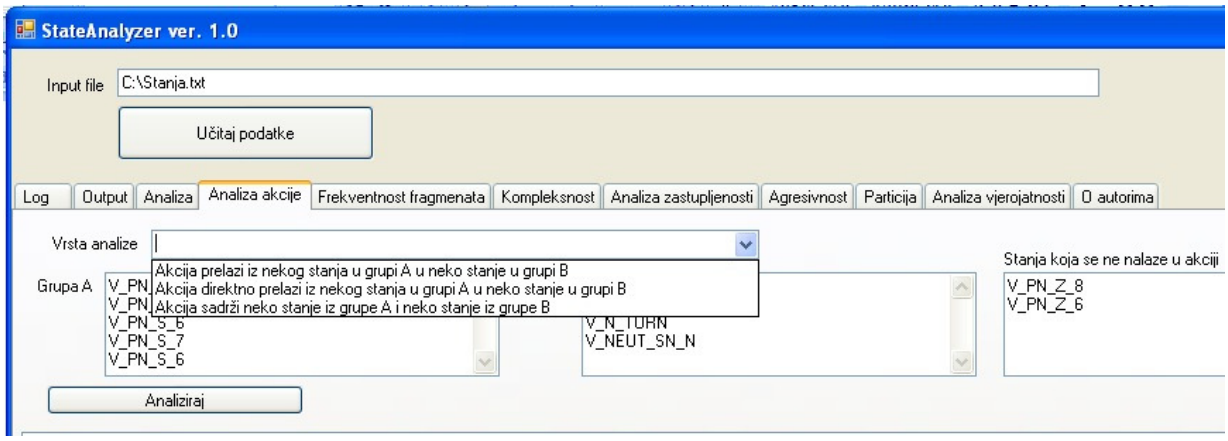
- Log – modul koji daje ispis učitanih utakmica i koji vrši inicijalnu validaciju podataka
- Output – modul koji opcionalno generira *xml* ili *xls* file s frekvencijama prijelaza iz stanja u stanje
- Analiza – modul koji za dano početno stanje i dan broj koraka računa prijelazne vjerojatnosti u završna stanja u danom broju koraka (Slika 6.2.)

  Slika 6.2. Modul analiza – računanje prijelaznih vjerojatnosti



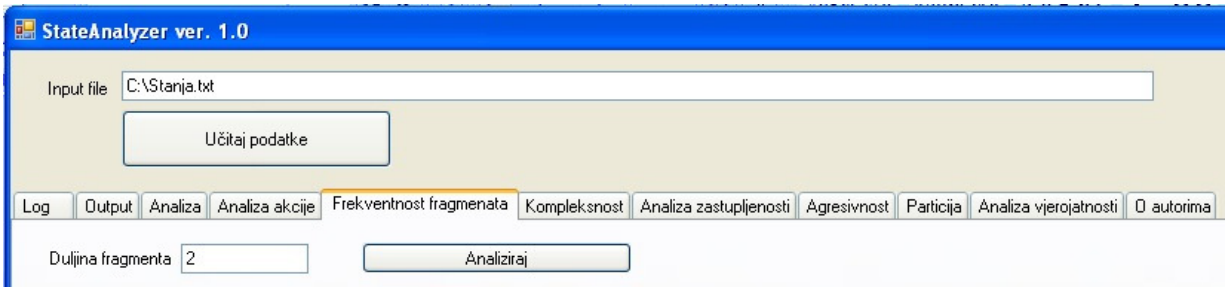
- Analiza akcije – modul koji za zadani skup stanja grupe A računa broj onih akcija koje sadrže stanje iz grupe A, a dođu do stanja grupe B. Pritom možemo isključiti stanja koja se ne smiju nalaziti u akciji. U padajućem izborniku imamo 3 modaliteta računanja (Slika 6.3.).

  Slika 6.3. Modul analiza akcije – računanje prijelaznih vjerojatnosti



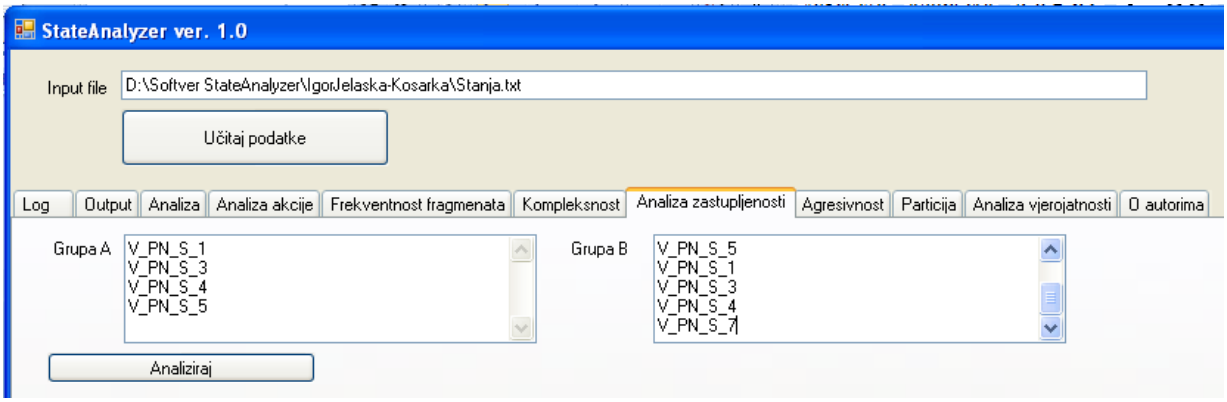
- Frekventnost fragmenata – modul koji pronalazi najfrekventnije lance dane duljine (Slika 6.4.)

Slika 6.4. Modul frekventnost fragmenata



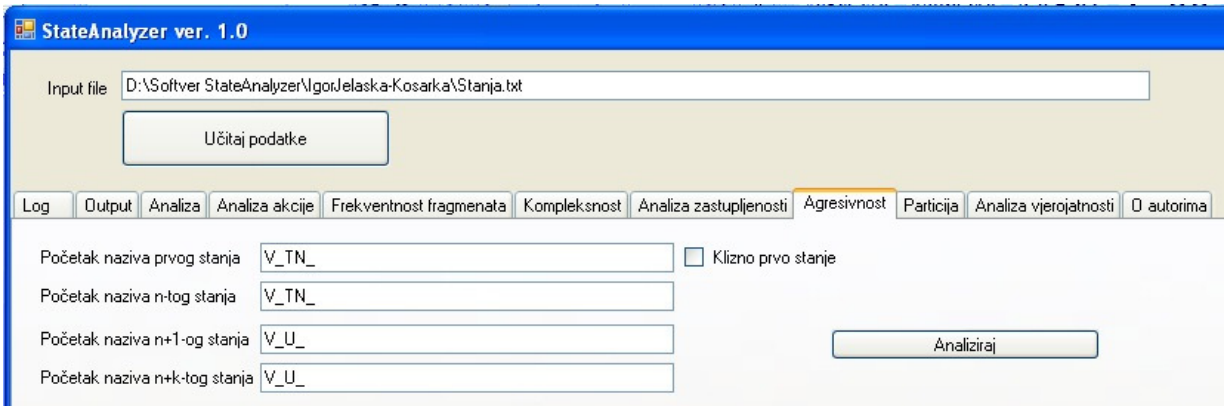
- Kompleksnost – modul koji računa prosječan broj stanja pojedine akcije uz dane uvjete na stanje
- Analiza zastupljenosti – modul koji računa apsolutnu frekvenciju stanja grupe A i B te nalazi njihov relativan omjer (Slika 6.5).

Slika 6.5. Modul analiza zastupljenosti



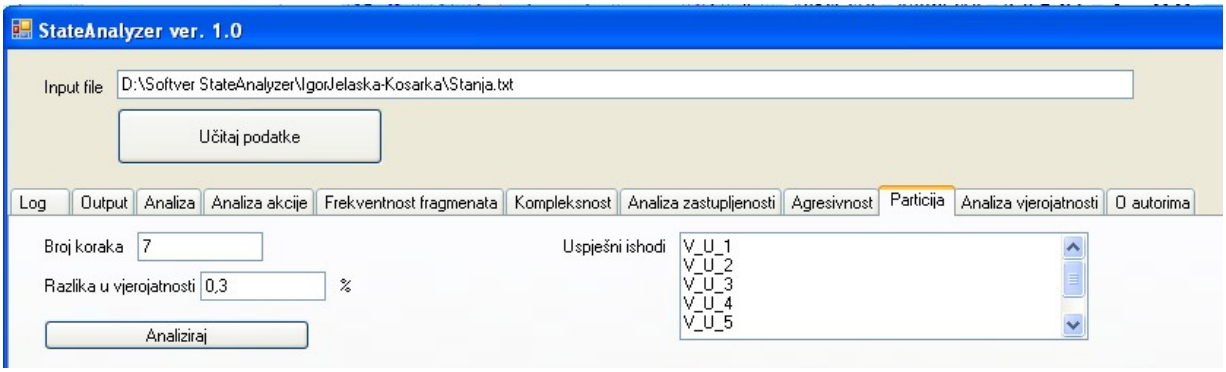
- Agresivnost – modul koji računa frekvenciju onih akcija koje imaju zadovoljene uvjete. Modul se naziva *agresivnost* jer je primarno korišten za izračunavanje frekvencija kontranapada (Slika 6.6.).

Slika 6.6.: Modul agresivnost



- Particija – Modul programiran u svrhu provjere hipoteze H1 (Slika 6.7.)

Slika 6.7.: Modul particija



- Analiza vjerojatnosti – Modul korišten za provjeru hipoteza H2-H5
- O autorima – Tekstualni modul s navedenim autorima softwarea *State Analyzer ver. 1.0.* i onima koji su omogućili njegov nastanak.

7. REZULTATI I RASPRAVA

7.1. Rezultati

7.1.1. Uspješnost napada

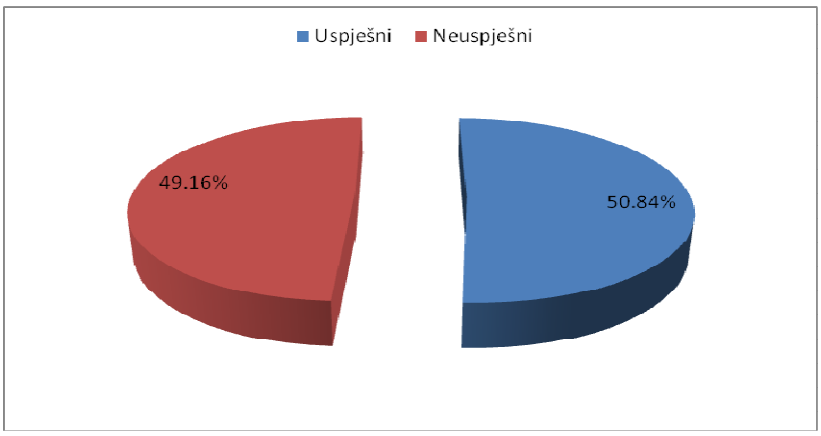
Frekvencija pojedinih napadačkih manevara i njihova uspješnost u fazi napada izračunata je korištenjem software-a State Analyzer ver 1.0.

7.1.1.1. Opća uspješnost napada

Analizom dobivenih rezultata u prostoru napada očito je da cjelokupan uzorak od 24 utakmice obuhvaća 3273 napadačke akcije.

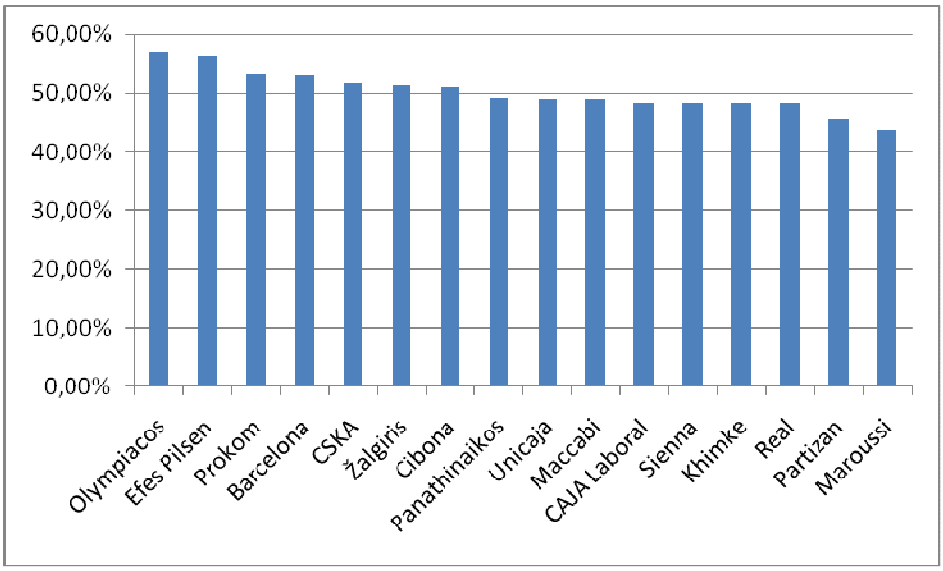
Od toga je 1664 (50,84%) akcija s uspješnim ishodom a 1609 (49,16%) akcija s neuspješnim ishodom. Testiranjem hipoteze o različitosti dobivenih proporcija dobiva se da ne postoji statistički značajna razlika između opće uspješnosti i neuspješnosti napada. Sa stajališta ekspertnih košarkaških trenera napad uvijek ima prednost, u odnosu na obranu, samom činjenicom da je momčad u fazi napada u posjedu lopte i da na taj način određuje dinamiku igre (npr. kontrola lopte do selektivnog šuta) i obrambene reakcije neovisno o konceptu proaktivnosti obrane. U skladu s navedenim, moguće je argumentirati da navedeni podatak svjedoči o određenoj dominaciji obrane nad napadom u evropskoj elitnoj seniorskoj košarci.

Slika 7.1. Opća uspješnost napada



Iz slike 7.2. je vidljiva opća napadačka uspješnost po momčadima koje su sudjelovale u Top 16. Također se iz tablice 7.1. te slika 7.3.sve do slike 7.6.može usporediti plasman ekipa, ali i njihova napadačka uspješnost po grupama. Vidljivo je da je Olympiacos uvjerljivo vodeći u tom poretku.

Slika 7.2. Opća uspješnost pojedinih ekipa u fazi napada u Top 16



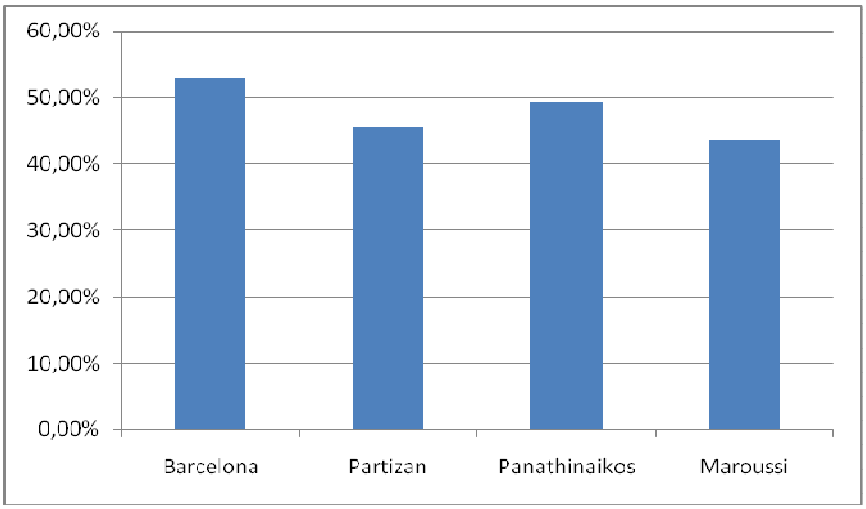
Važno je istaknuti kako su se među 8 napadački najuspješnijih klubova samo 4 plasirala u četvrtfinale.

Tablica 7.1. Prikaz rezultata u 4 grupe TOP 16 Eurolige

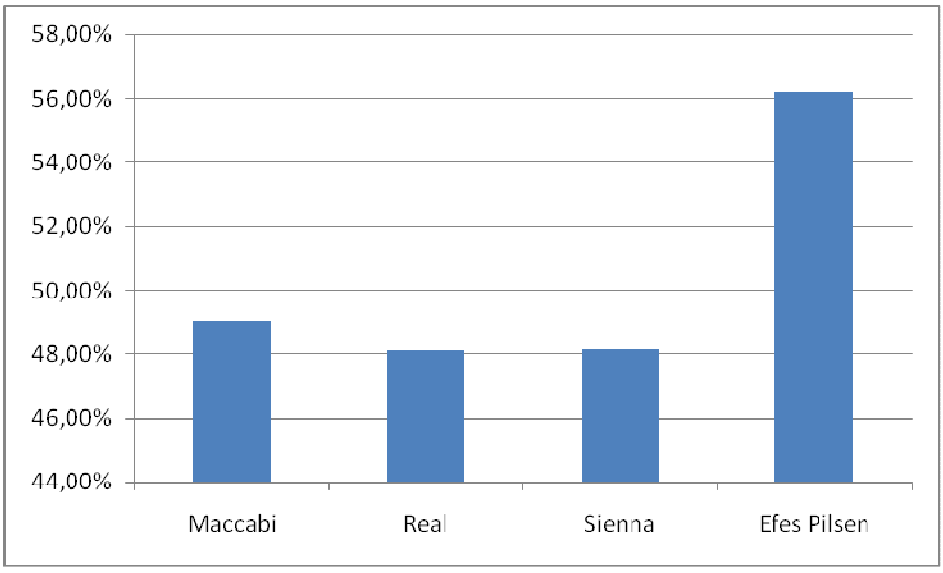
	GRUPA 1	**GRUPA 2**	**GRUPA 3**	**GRUPA 4**
1	Barcelona 5-1 (+69)	Maccabi 4-2 (+21)	CSKA 5-1 (+43)	Olympiacos 5-1 (+32)
2	Partizan 3-3 (-33)	Real 3-3 (+3)	Prokom 3-3 (+16)	CAJA Laboral 3-3 (-6)
3	Panathinaikos 2-4 (-3)	Sienna 3-3 (-16)	Unicaja 2-4 (-2)	Khimki 3-3 (-11)

4	Maroussi 2-4 (-33)	Efes Pilsen 2-4 (-8)	Žalgiris 2-4 (-60)	Cibona 1-5 (-15)

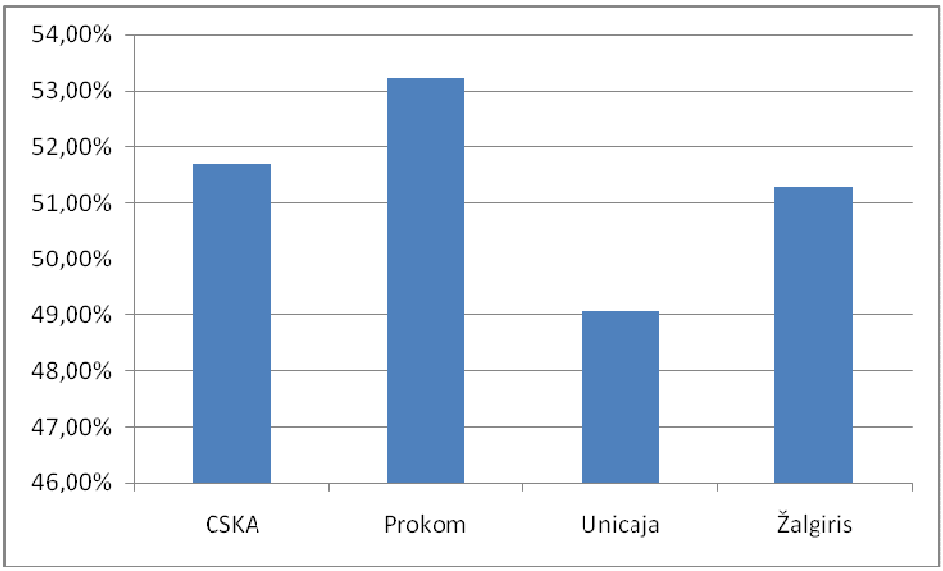
Slika 7.3. Poredak po općoj napadačkoj uspješnosti - grupa 1:



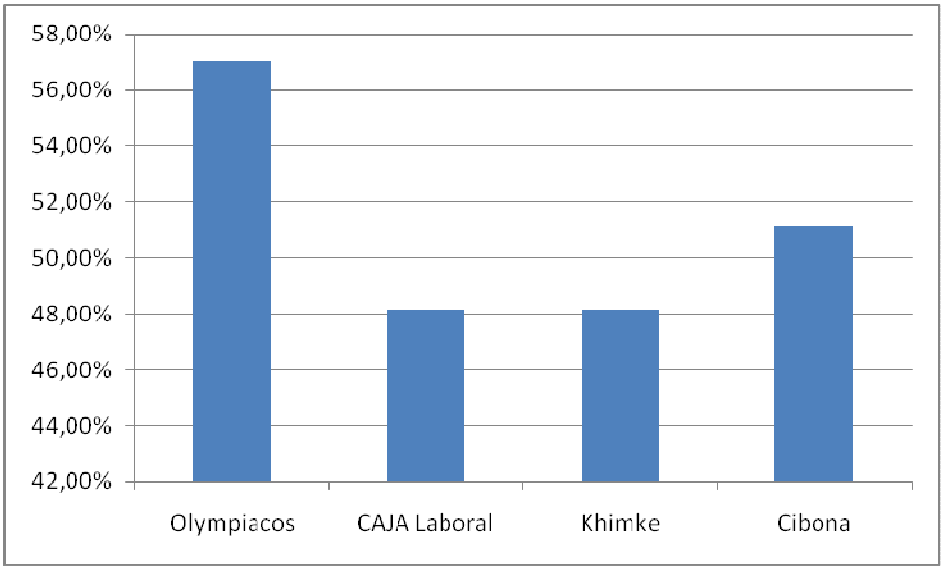
Slika 7.4. Poredak po općoj napadačkoj uspješnosti - grupa 2:



Slika 7.5. Poredak po općoj napadačkoj uspješnosti - grupa 3:



Slika 7.6. Poredak po općoj napadačkoj uspješnosti - grupa 4.



Na slikama 7.3.-7.6. može se uočiti da postoji neravnoteža u rezultatima napadačke uspješnosti i uspješnosti pojedinih klubova u smislu sportskog postignuća (plasmana na tablici). Vjerojatno je to posljedica činjenice da kod tih momčadi ne postoji ravnoteža uspješnosti u fazi obrane i fazi

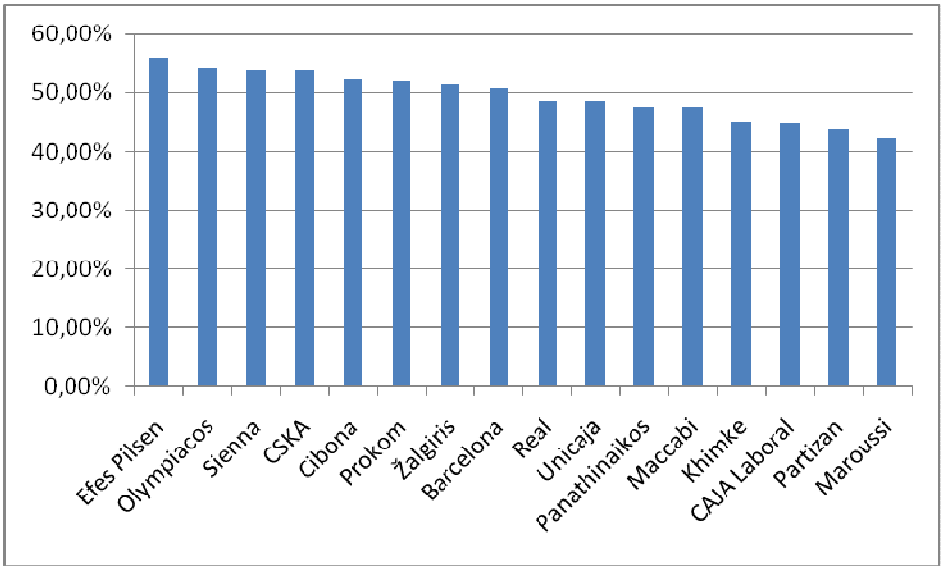
napada. Evropska košarka primarno traži ravnotežu u treningu i procesu sportske pripreme, odnosno uravnotežen razvoj obrane i napada.

7.1.1.2. Zastupljenost i uspješnost pozicijskog napada

Pokazuje se da je **zastupljenost** pozicijskog napada u kontekstu frekvencija 2552, što je **78%** od ukupnog broja napada. Od toga **uspješnih** ima 1261, što je **49,4**%.

U odnosu na pojedine ekipe u Top 16 navedena je uspješnost koja je prikazana na slici 7.7.. Tako je primjerice, Barcelona (europski prvak u natjecateljskoj sezoni 2009./2010.) pozicionirana pri sredini, dok je momčad Efes Pilsen-a koja nije prošla u četvrtfinale, prva po uspješnosti pozicijskog napada.

Slika 7.7. Uspješnost pozicijskog napada pojedinih ekipa u Top 16



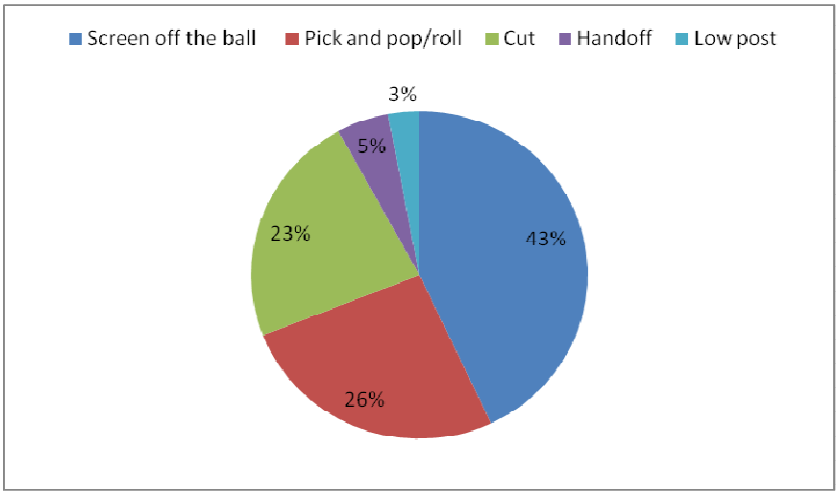
7.1.2. Pozicijski napad

7.1.2.1. Analiza središnjice pozicijskog napada

Potrebno je istaknuti da središnjica pojedine faze igre najbolje oslikava njenu taktičku kombinatoriku. Stoga nam je nakana u ovoj studiji raščlaniti dinamiku i strukturu igre u središnjici pozicijskog napada. Poznato je da je u današnjoj evropskoj košarci *pick and roll/pop* (blok na igraču sa loptom sa otvaranjem blokera u post prostor ili perimetar prostor) akcija je vrlo zastupljen dio kombinatorike u fazi napada. Cilj nam je pobliže analizirati njegovu strukturu.

Analogno tome ćemo učiniti sa manevrima *handoff* (uručenje lopte), igra na niskom postu (*low post game*), različite vrste blokova na igračima bez lopte (*screens off the ball*), te različitih unutarnjih i vanjskih otvaranja (*inside/outside cut*). Njihova zastupljenost u središnjici pozicijskog napada prikazana je na slici 7.8.

Slika 7.8. Zastupljenost napadačkih manevara *screen off the ball, pick and pop/roll, cut, handoff i low post* u središnjici pozicijskog napada



Manevri *screens of the ball, pick and pop/roll* i *cut* u relativnoj su ravnoteži po zastupljenosti dok su manevri *low post* i *handoff* vrlo malo prisutni. To vjerojatno stoga što u evropskoj elitnoj košarci nema dominantnih *low post* igrača. Nadalje, u kombinatorici središnjice napada su izuzetno važni blokovi na igračima bez lopte jer oni određuju razvoj napada.

7.1.2.1.1. *Pick and roll/pop* igra u središnjici

Ako analiziramo, *pick* (blok na igrača sa loptom) na različitim mjestima na kojima se izvodi možemo to svesti na slijedeće:

a) *pick and roll (pop)* na sredini.

   Reprezentiran je varijablom V_PN_S_58 koja je zastupljena s 21%

b) *Pick and roll (pop)* na strani

   Reprezentiran je varijablom V_PN_S_57 koja je zastupljena s 35%

c) *Pick and roll (pop)* na rubu linije slobodnih bacanja

   Reprezentiran je varijablom V_PN_S_60 koja je zastupljena sa 17%

d) *Pick and roll (pop)* na krilu

   Reprezentiran je varijablom V_PN_S_61 koja je zastupljena sa 16%

e) *Pick and roll (pop)* u korneru

   Reprezentiran je varijablom V_PN_S_62 koja je zastupljena s 0,5%

f) *Flat pick* (leđni blok na igrača s loptom)

   Reprezentiran je varijablom V_PN_S_59 koja je zastupljena s 5%

g) *Pick and roll* na niskom postu

   Reprezentiran je varijablom V_PN_S_66 koja je zastupljena s 0,05%

h) *Pick for picker*-a (blok za blokera na igrača a loptom)

   Reprezentiran je varijablom V_PN_S_67 koja je zastupljena s 1%

i) *Staggered picks* (dva uzastopna bloka na igrača s loptom)

   Reprezentiran je varijablom V_PN_S_64 koja je zastupljena s 0,2%

j) *Repick* (ponovljeni blok na igrača s loptom)

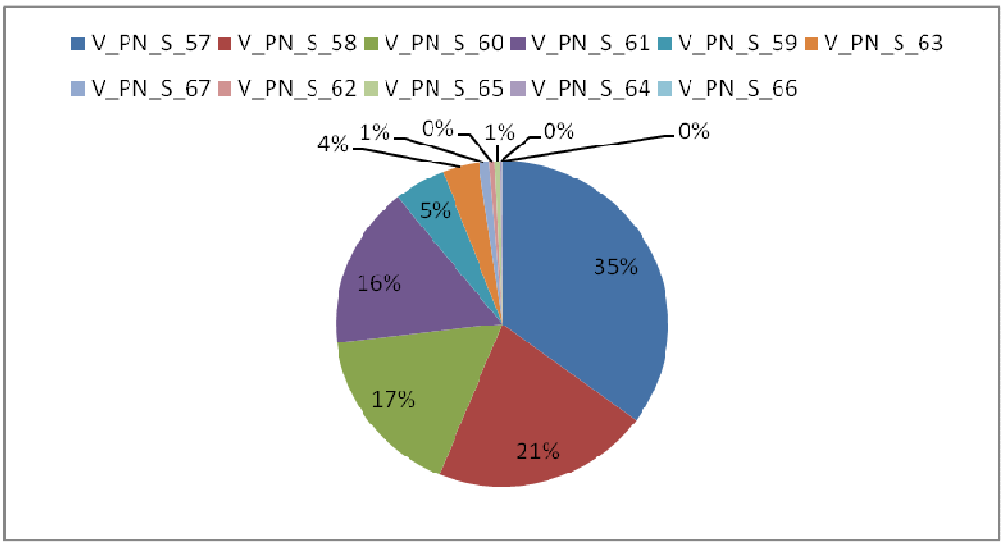
Reprezentiran je varijablom V_PN_S_63 koja je zastupljena s 3,5%

k) *Slip screen* (varka bloka na igraču s loptom) V_PN_S_65 (0,5%)

Reprezentiran je varijablom V_PN_S_65 koja je zastupljena s 0,5%

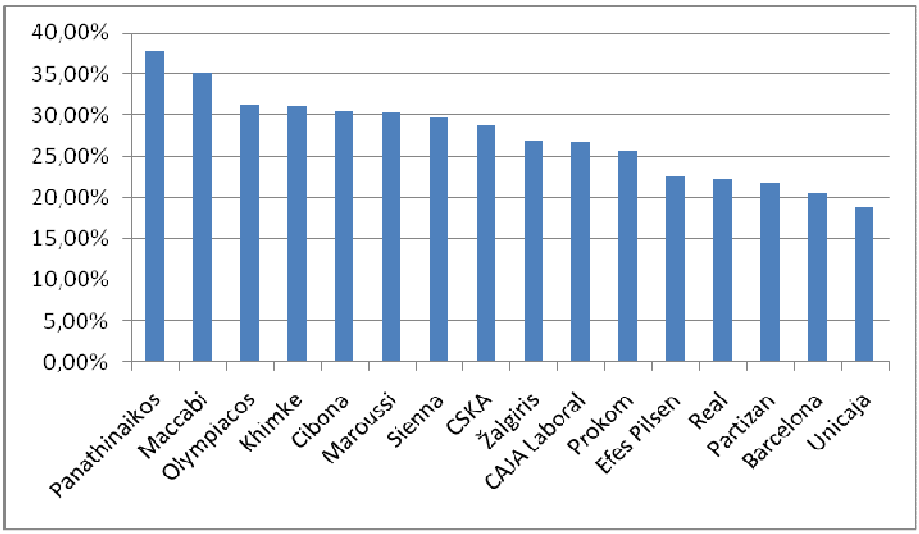
Navedeni podaci vidljivi su na slici 7.9. , a vidljivo je da su blokovi na strani najzastupljeniji, slijede ih blokova na sredini, rubu linije slobodnih bacanja te na krilu. Potrebno je naglasiti da su to ujedno i najstandardniji *pick and roll* manevri u elitnoj europskoj košarci. To je naročito stoga što se zbog mogućnosti udvajanja *pick and roll* u korneru izbjegava, a *flat pick* se može odigrati samo ako je agresivna obrana na igraču sa loptom već na polovini terena. Nadalje, *pick and roll* na niskom postu je specijalan manevar prisutan u NBA ligi te traži posebno treniranog visokog igrača, a *repick* je moguć samo pri prolasku obrane ispod bloka, što je rijedak slučaj u elitnoj europskoj košarci. Također, *slip screen* dolazi u obzir samo kod *hedge*-a, a to nije dominantni način obrane na *pick*-u.

Slika 7.9. Distribucija zastupljenosti p*ick and roll/pop* igre u središnjici u odnosu na mjesto odigravanja



Udio *pick*-a u odnosu na sve manevre koje ćemo promatrati u središnjici napada (*pick and roll/pop*, *handoff*, *screens off the ball*, *low post* igra i *cut* igra) iznosi **27% ,** a distribucija po klubovima je prikazana na slici 7.10.

Slika 7.10. Prikazi udjela *pick and roll/pop* akcija u središnjici napada u odnosu na sve manevre središnjice napada pojedinih ekipa u Top 16.



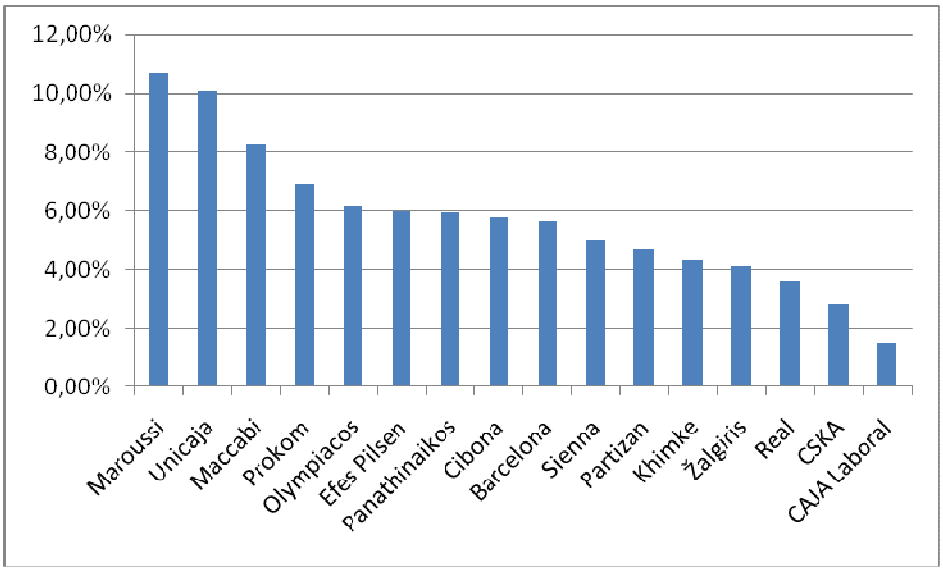
Na slici 7.10 je očito da se momčadi Panathinaikos i Maccabi ističu po udjelu *pick and roll/pop*-a u središnjici napada. Za Panathinaikos je to karakterističan način igre koji je prisutan u zadnjem desetljeću. Barcelona i Unicaja imaju najniži udio navedenih manevara.

7.1.2.1.2. *Handoff* igra

Handoff je manevar uručenja lopte, najčešće od strane visokog igrača vanjskom suigraču. On pruža, za razliku od *pick and roll (pop)* manevra dodatnu mogućnost šuta iz mjesta nakon uručenja. U skladu s navedenim formalizmom, reprezentiran je varijablama V_PN_S_7, V_PN_S_8.

Nadalje, udio *handoff*-a u odnosu na sve manevre (*pick and roll (pop)*, *handoff*, *screen off the ball*, *low post* igra i *cut* igra) iznosi **5,6%**, a distribucija po klubovima je prikazana na slici 7.11.

Slika 7.11. Prikaz udjela *handoff*-a u središnjici napada pojedinih ekipa u Top 16



Na slici 7.11. vidljiv je relativno visok udio *handoff* manevara kod momčadi Maroussi i Unicaja, dok momčadi CSKA i CAJA Laboral obilježava niski udio *handoff* manevara u središnjici napada.

7.1.2.1.3. *Screens off the ball* - blokovi na igračima bez lopte

Ove napadačke manevre dijelimo u 3 kategorije: blok igra za vanjske igrače, blok igra za unutarnje igrače te blok za blokera:

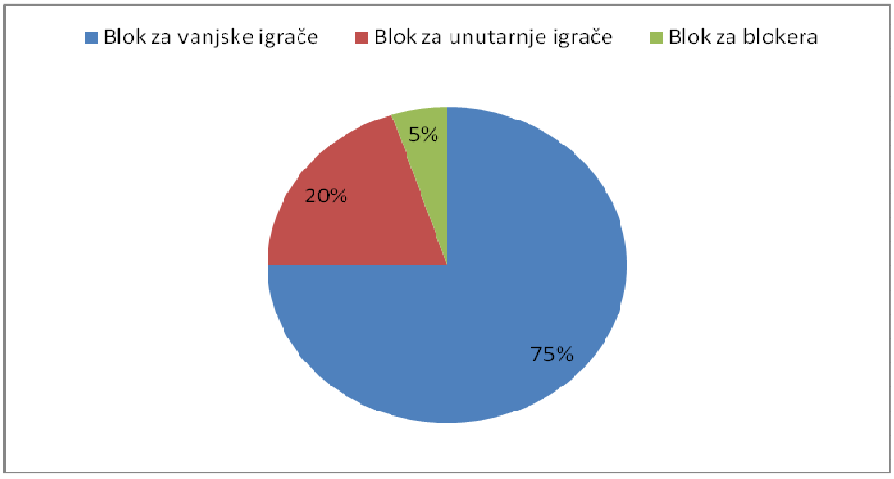
a) blok igra za vanjske igrače reprezentirana je varijablama: V_PN_S_23, V_PN_S_24, V_PN_S_25, V_PN_S_26, V_PN_S_27, V_PN_S_28, V_PN_S_31, V_PN_S_32, V_PN_S_35, V_PN_S_36, V_PN_S_37, V_PN_S_38, V_PN_S_39, V_PN_S_40, V_PN_S_41, V_PN_S_44, V_PN_S_48, V_PN_S_51, V_PN_S_52, V_PN_S_53, a zastupljena je sa 75%.

b) blok igra za unutarnje igrače reprezentirana je varijablama: V_PN_S_33, V_PN_S_34, V_PN_S_42, V_PN_S_43, V_PN_S_45, V_PN_S_46, V_PN_S_47, V_PN_S_49, V_PN_S_50, a zastupljena je s 20%.

c) blok za blokera reprezentirana je varijablama: V_PN_S_54, V_PN_S_55, V_PN_S_56, a zastupljen je s 5%.

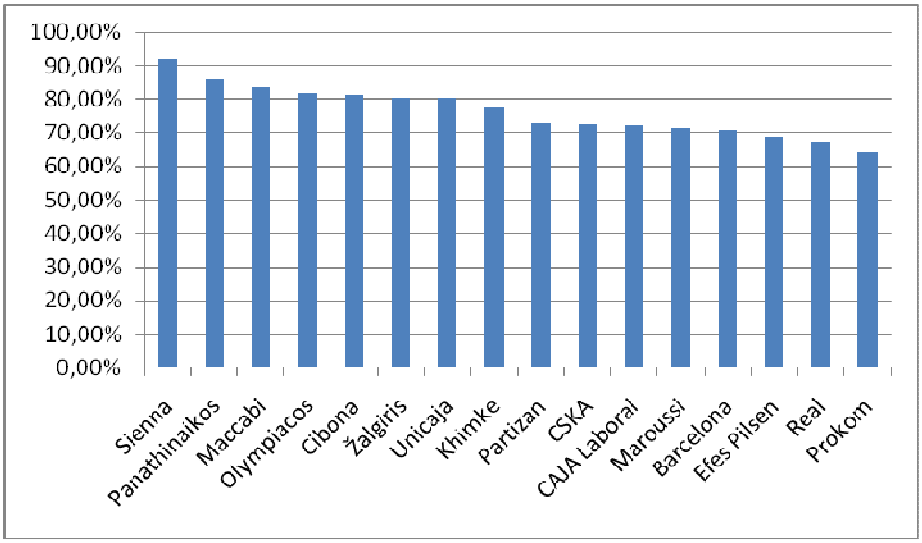
Ukupna distribucija je prikazana na slici 7.12. iz koje je vidljiva apsolutna dominacija blokova za vanjske igrače sa 75% i minimalna zastupljenost bloka za blokera s 5%. U pravilu su vanjski igrači nosioci kvalitete u evropskim klubovima, zato se većina blokova izvodi za njih. Navedena činjenica omogućava razvoj dinamike središnjice napada (priprema akcije). Mali udio manevra blok za blokera (za razliku od suprotne situacije 90-ih godina) se može objasniti efikasnošću obrane protiv takvih situacija odnosno *bump*-iranjem i preuzimanjem sa strane pomoći.

Slika 7.12. Udio s*creens off the ball* u središnjici napada



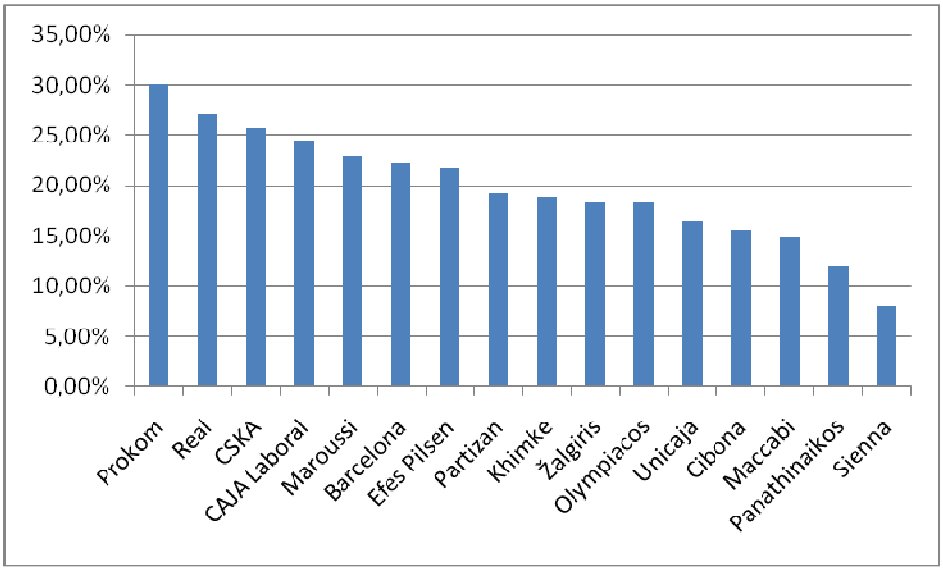
Nadalje, na slici 7.13. prikazana je raspodjela postavljanja bloka za vanjske igrače u odnosu na ostala 2 navedena napadačka manevra.

Slika 7.13. Raspodjela postavljanja bloka za vanjske igrače po klubovima u odnosu na sve vrste blokova na igračima bez lopte pojedinih ekipa u Top 16



Također je na slici 7.14. izvedena raspodjela postavljanja blokova za unutarnje igrače. Vidljivo je da ispodprosječni udio bloka za vanjske igrače (ispod 70%) imaju Efes Pilsen, Real i Prokom. Također je očito da Sienna ima iznad 90% udjela bloka za vanjske igrače.

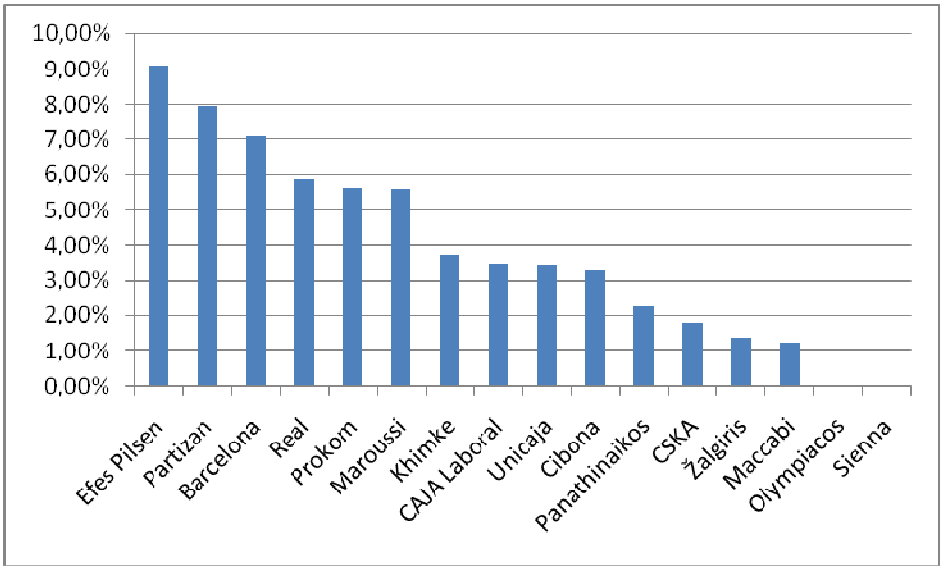
Slika 7.14. Distribucija bloka za unutarnje igrače pojedinih ekipa u Top 16 u odnosu na sve vrste blokova na igračima bez lopte



Važno je istaknuti kako nizak udio (ispod 15%) bloka za unutarnje igrače imaju Maccabi, Panathinaikos i Sienna, dok Prokom ima najveći udio navedenih akcija (30%).

S druge strane, na slici 7.15. prikazana je raspodjela manevra blok za blokera prema pojedinim momčadima.

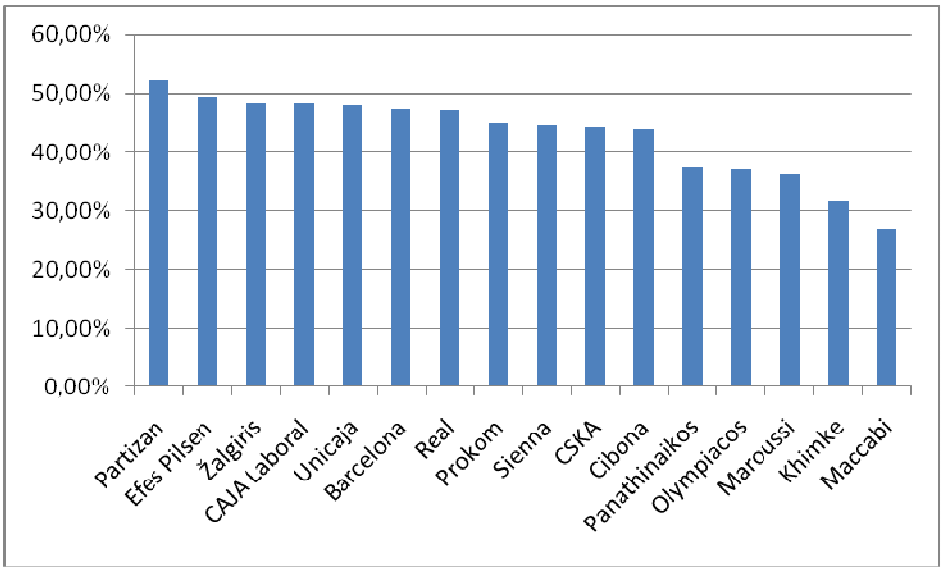
Slika 7.15. Distribucija bloka za blokera pojedinih ekipa u Top 16 u odnosu na sve blokove na igračima bez lopte



Očigledno je kako Efes Pilsen ima 9% zastupljenosti manevra blok za blokera. Zanimljivo je da momčadi Olympiacos i Sienna navedeni manevar nisu koristile.

Na slici 7.16. prikazana je ukupna zastupljenost blok igre na igrača bez lopte u odnosu na sve ostale kategorije, što iznosi 43%.

Slika 7.16. Zastupljenost blok igre na igrača bez lopte pojedinih ekipa u Top 16



Momčadi Maccabi i Khimke obilježava niži udio zastupljenosti postavljanja bloka na igrača bez lopte. S druge strane momčad Partizana je dominirala, imala je preko 50% udjela u ovom napadačkom manevru.

7.1.2.1.4. Cut igra

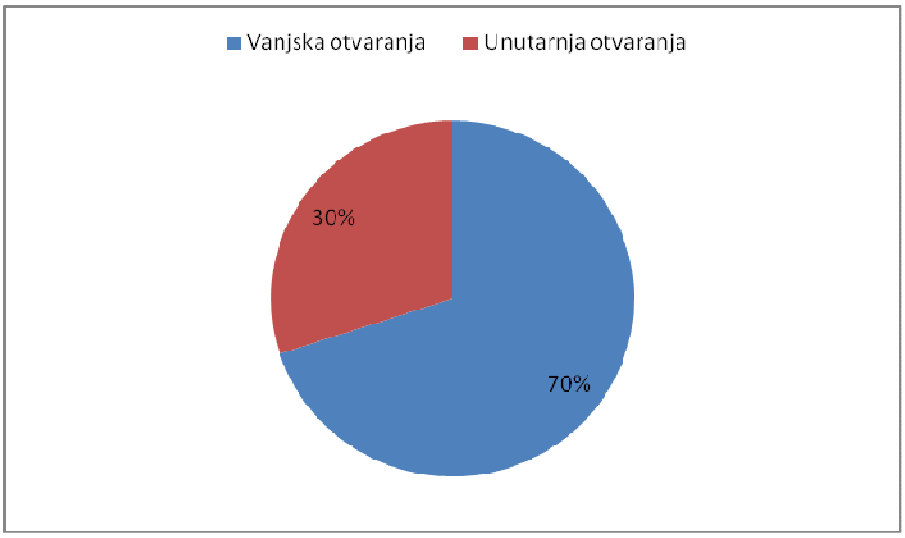
Kretanje igrača bez lopte bez korištenja blokova možemo podijeliti u dvije kategorije: vanjska otvaranja i unutarnja otvaranja.

a) Vanjska otvaranja reprezentirana su varijablama: V_PN_S_1, V_PN_S_5, V_PN_S_11, V_PN_S_16, V_PN_S_17, V_PN_S_21

b) Unutarnja otvaranja reprezentirana su varijablama: V_PN_S_2, V_PN_S_3, V_PN_S_6, V_PN_S_9, V_PN_S_10, V_PN_S_12, V_PN_S_13, V_PN_S_18, V_PN_S_19, V_PN_S_20, V_PN_S_22

Na slici 7.17. je prikazana zastupljenost vanjskih i unutarnjih otvaranja.

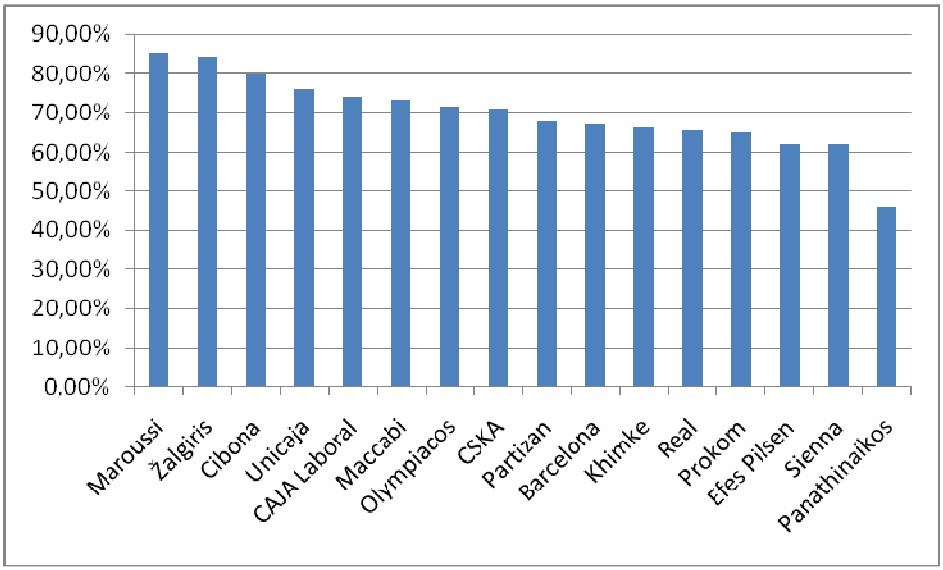
Slika 7.17. Distribucija *cut* igre u središnjici



Na slici 7.17. očigledna je dominacija vanjskih otvaranja s čak 70% udjela, što je razumljivo kada se zna da ti napadački manevri prethode unutarnjim otvaranjima.

Distribucija vanjskih otvaranja po klubovima je prikazana na slici 7.18.

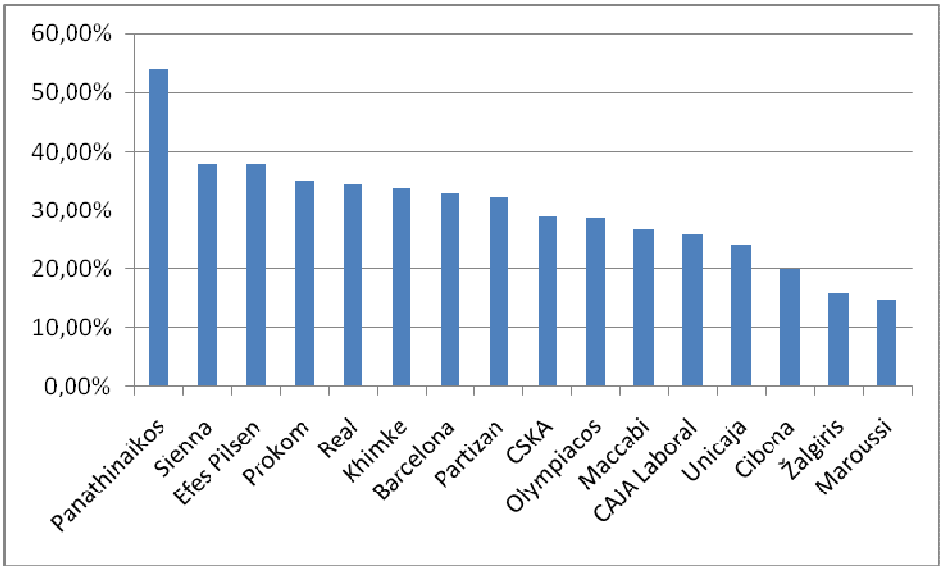
Slika 7.18. Distribucija vanjskih otvaranja pojedinih ekipa u Top 16



Panathinaikos se ističe niskim udjelom vanjskih otvaranja, što je objašnjivo visokim udjelom *pick and roll* manevara u igri te momčadi (*roll* manevri odgovaraju *inside cut*-u) Nadalje, Maroussi i Žalgiris se ističu relativno visokim udjelom, preko 80%.

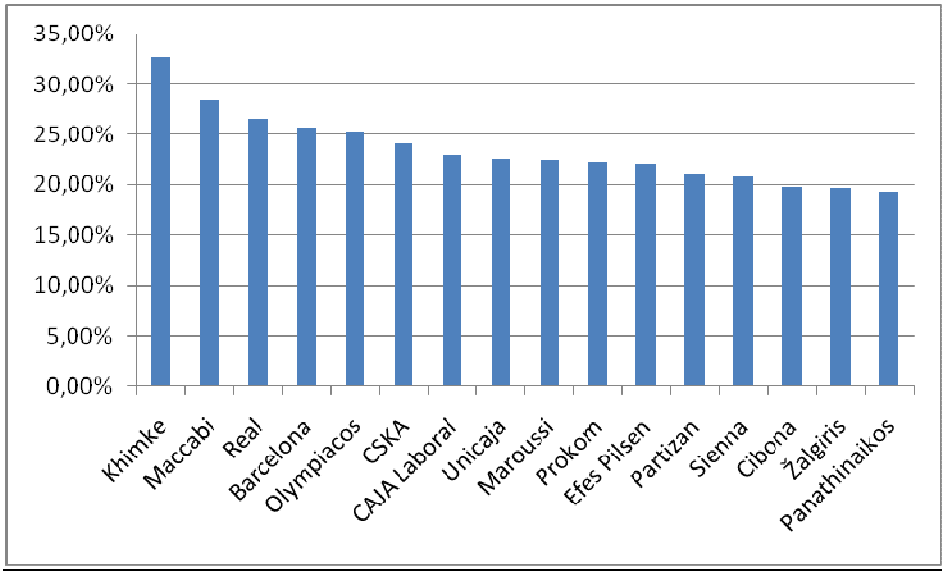
Distribucija unutranjih otvaranja po klubovima je vidljiva na slici 7.19.

Slika 7.19. Distribucija unutranjih otvaranja pojedinih ekipa u Top 16



Panathinaikos se ističe s relativno visokim udjelom od preko 50% unutarnjih otvaranja, dok se Žalgiris i Maroussi ističu udjelom ispod 17%. Visoki udio Panathinaikosa je moguće protumačiti visokim udjelom *pick and roll* manevara pri čemu se *roll* interpretira kao unutarnje otvaranje. Nadalje, na slici 7.20 prikazana je ukupna zastupljenost *cut* igre po klubovima koja iznosi 23%.

Slika 7.20. Distribucija *cut igre* pojedinih ekipa u Top 16



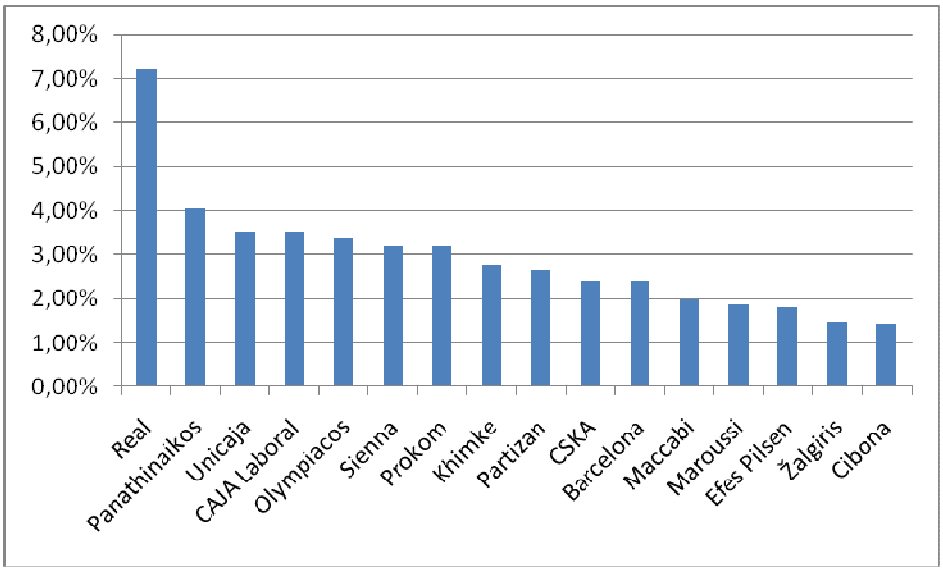
7.1.2.1.5. Igra na niskom postu

Igra na niskom postu može biti izvedena kao posljedica nekog od gore navedenih manevara, ali i samostalno kao manevar svojevrsne izolacije. Ovaj drugi slučaj ćemo promatrati u završnici pod konceptom izolacije.

Post up manevar je reprezentiran varijablama V_PN_S_9 i V_PN_S_10 a njegova zastupljenost u odnosu na ostale napade u središnjici je 3% , distribucija po klubovima je prikazana na slici 7.21.

Potrebno je naglasiti da se tijekom razvoja napada u središnjici preferiraju ostali manevri dok je *post-up* rezerviran za završnicu akcije. To je vjerojatno stoga što u europskoj elitnoj košarci postoji veoma mali broj napadački dominantnih igrača na niskom postu.

Slika 7.21. Distribucija *low post* igre pojedinih ekipa u Top 16



Na slici 7.21. je očito kako se momčad Reala ističe po zastupljenosti *low post* igre i to preko 7%.

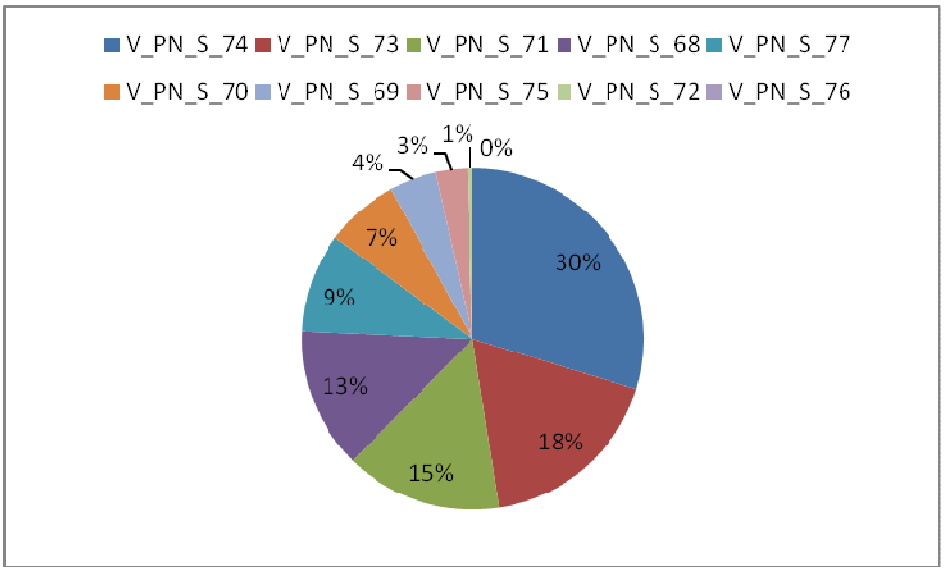
7.1.2.1.6. Ubacivanje lopte izvan linija igrališta

U košarkaškoj igri razlikujemo situacije ubacivanja lopte s bočne i čeone linije.

a) Ubacivanje lopte s bočne linije

Stanja ubacivanja lopte s bočne linije opisana su varijablama V_PN_S_68, V_PN_S_69, V_PN_S_70, V_PN_S_71, V_PN_S_72, V_PN_S_73, V_PN_S_74, V_PN_S_75, V_PN_S_76, V_PN_S_77 , a zastupljenost njihovog pojavljivanja je prikazana na slici 7.22.

Slika 7.22. Zastupljenost pojedinih načina ubacivanja lopte s bočne linije

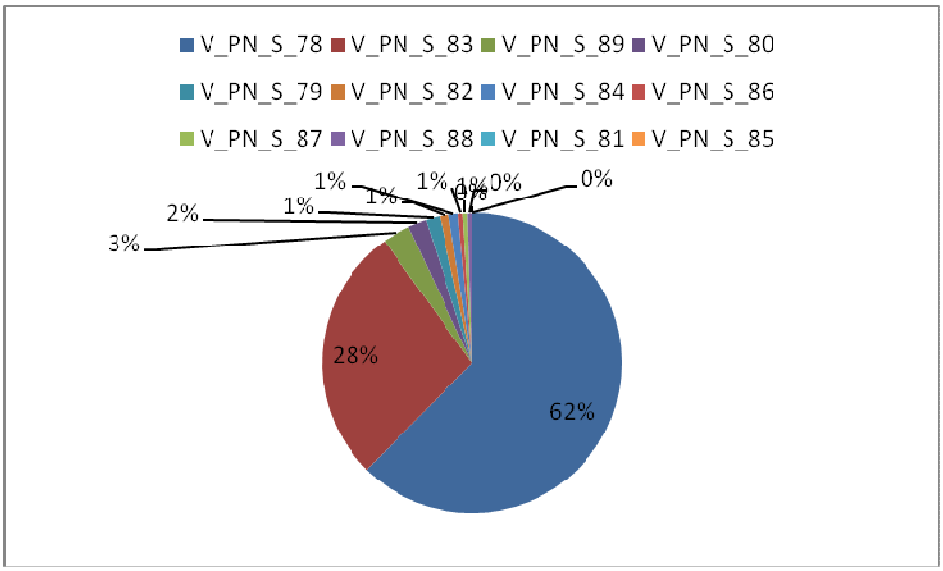


Vidljivo je na slici 7.22. kako se najčešće javljaju stanja: V_PN_S_74 - tri igrača duboko postavljena duž čeone linije, zatim V_PN_S_73 - raspored 4 visoko te V_PN_S_71 - trokut raspored.

b) Ubacivanje lopte s čeone linije

Opisano je varijablama V_PN_S_78, V_PN_S_79, V_PN_S_80, V_PN_S_81, V_PN_S_82, V_PN_S_83, V_PN_S_84, V_PN_S_85, V_PN_S_86, V_PN_S_87, V_PN_S_88, V_PN_S_89 a zastupljenost njihovog pojavljivanja je prikazana na slici 7.23.

Slika 7.23. Zastupljenost pojedinih načina ubacivanja lopte s čeone linije

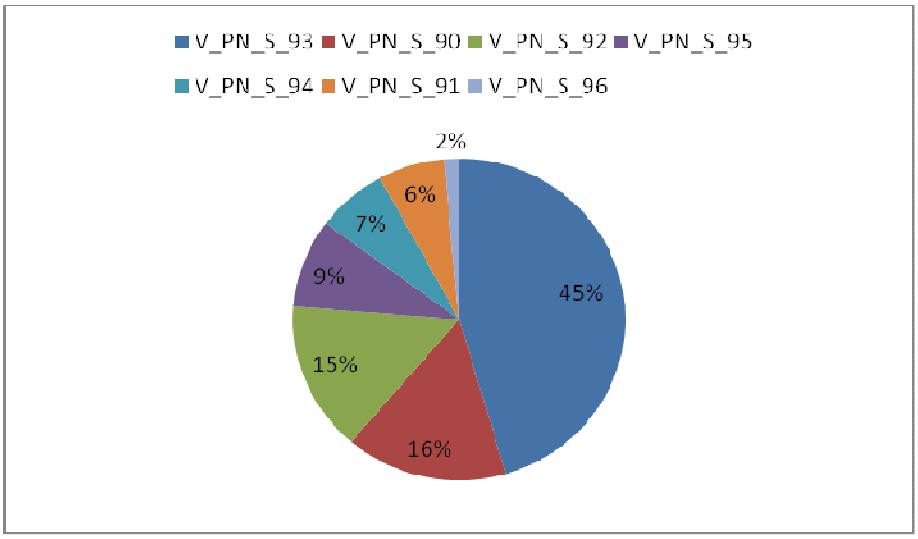


Očigledno je kako je najdominantnija varijabla sa čak 63% V_PN_S_78 - *box* raspored, dok asimetrični rasporedi slijede s 28% zastupljenosti.

7.1.2.1.7. Napad na zonsku obranu

Manevri protiv zonske obrane (neovisno o ulaznom rasporedu protiv zonske obrane) mogu se opisati varijablama V_PN_S_90, V_PN_S_91, V_PN_S_92, V_PN_S_93, V_PN_S_94, V_PN_S_95, V_PN_S_96, a distribucija zastupljenosti je dana na slici 7.24.

Slika 7.24. Zastupljenost pojedinih načina napadanja zonske obrane

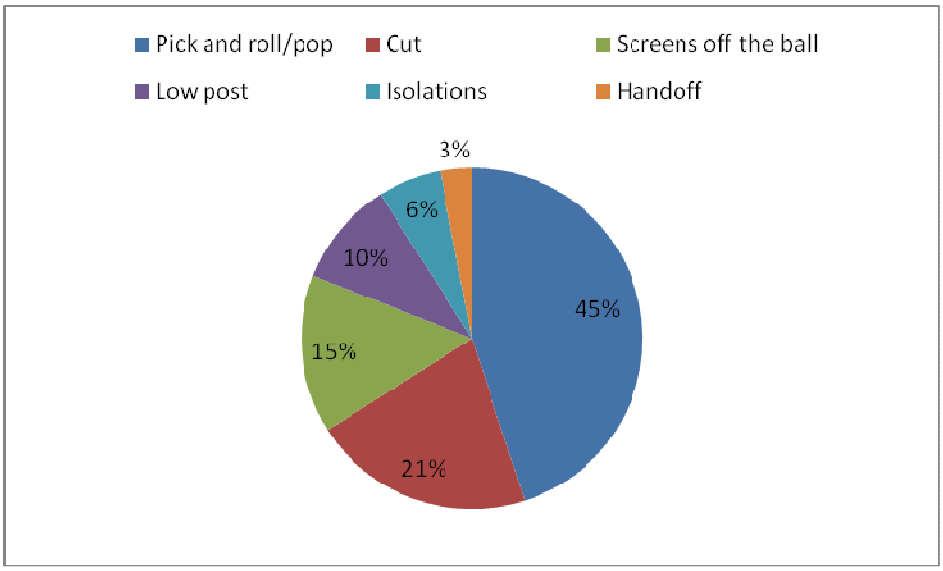


U kontekstu načina napadanja zonske obrane, ističe se varijabla V_PN_S_93 - brzi protok lopte protiv svih tipova zonskih obrana s 45% , zatim slijedi varijabla V_PN_S_90 - opterećenje strane u napadu na zonu s 19% te varijabla V_PN_S_92 s 15% - prelazak post igrača u perimetar prostor, pri čemu se stvara otvorena geometrija s 4 vanjska igrača. Brzi protok lopte protiv zonskih obrana je temeljni način stvaranja „rupa“ u zonskoj obrani. To je stoga što se obrana prisiljava na brzu transformaciju od strane pomoći do strane lopte, a navedeno nužno generira otvaranje „rupa“ u zonskoj strukturi.

7.1.2.2. Analiza taktičkih aktivnosti u završnici pozicijskog napada

U završnici pozicijskog napada je vidljivo (Slika 7.25), da je za razliku od središnjice, gotovo dvostruko veći udjel broja *pick and roll/pop* manevara. Nadalje, *handoff* manevara je relativno mali broj, dok se približno tri puta smanjio udio blokova na igračima bez lopte. Također, udio *low post* manevara se povećao, ali i dalje je na relativno malih 10%. Pritom je udio vanjskih i unutarnjih otvaranja podjednak, dok su izolacije u završnici prisutne sa 6%. Jedina razlika je činjenica da su *pick and roll* manevri u završnici postali dominantni, dok se proporcionalno smanjio broj blokova na igračima bez lopte.

Slika 7.25 Zastupljenost napadačkih manevara *screen off the ball, pick and pop/roll, cut, handoff, low post i isolations* u završnici pozicijskog napada



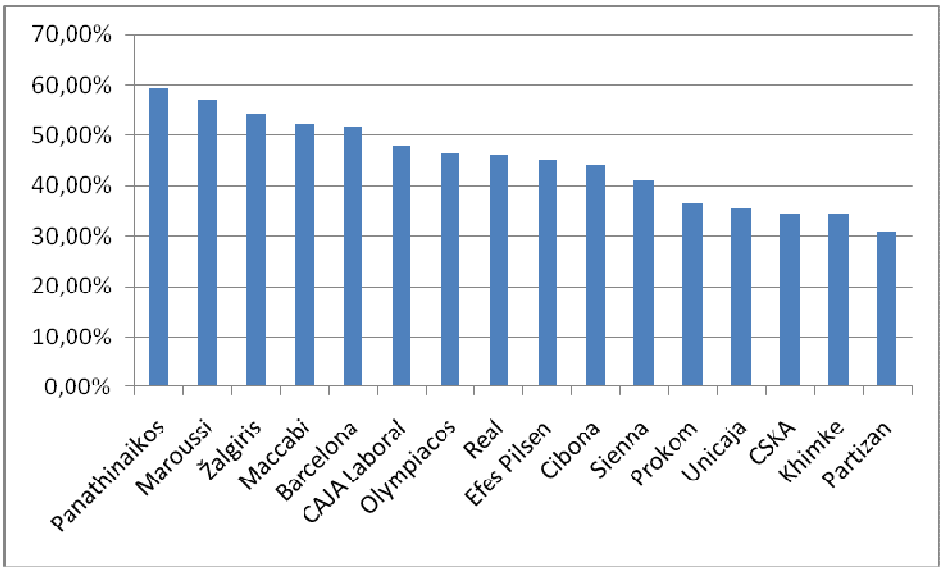
Važno je istaknuti da analiza taktičkog djelovanja u završnici pozicijskih akcija u košarkaškoj igri čini važan aspekt preispitivanja pojedinih napadačkih manevara koji su zastupljeni u elitnoj europskoj košarci. Zato su, isto kao u središnjici, izolirani pojedini aspekti igre: *pick and roll/pop, handoff* (uručenje), *inside cut* (utrčavanja), *screens off the ball* (blokovi na igrača bez lopte), *low post game* (igra na niskom postu), *isolations* (izolacije na perimetru).

7.1.2.2.1. *Pick and roll/pop* napad u završnici

U završnici pozicijskog napada, *pick and roll* opisan je varijablama V_PN_Z_11, V_PN_Z_12, V_PN_Z_13.

Zastupljenost navedenih napadačkih manevara iznosi **44,1%**, a po klubovima je to prikazano na slici 7.26.

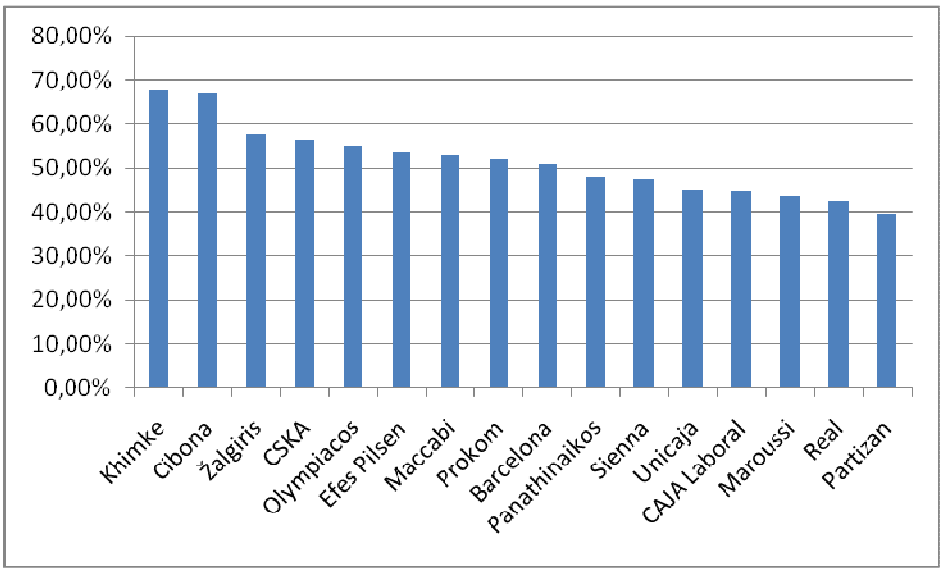
Slika 7.26. Zastupljenost *pick and roll/pop* manevra u završnici pojedinih ekipa u Top 16



Kao i u središnjici, tako i u završnici pozicijskih akcija Panathinaikos i Maroussi najviše koriste manevar *pick and roll/pop,* a najmanje Partizan i Khimke. Pritom Khimke daleko manje koristi *pick* u završnici nego u središnjici.

Prosječna uspješnost navedenih manevara je 50,9% što je više od prosječne uspješnosti pozicijskog napada (49,4%).

Slika 7.27. Uspješnost *pick and roll/pop* manevra u završnici pojedinih ekipa u Top 16

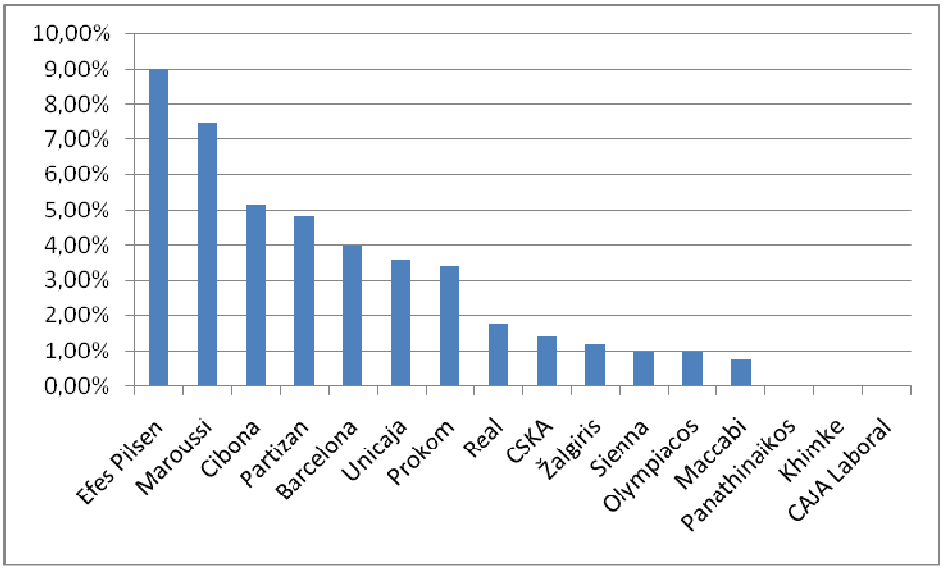


Na slici 7.27. prikazana je distribucija uspješnosti *pick and pop/roll* manevara u završnici u kojima su najuspješniji Khimke (68%) i Cibona (67%). S druge strane, Partizan je najneuspješnija momčad u navedenom manevru (40%).

7.1.2.2.2. *Handoff* (uručenje lopte) u završnici

Uručenje lopte u završnici pozicijskih akcija opisano je varijablom V_PN_Z_14, a zastupljenost tog manevra je 2,7%.

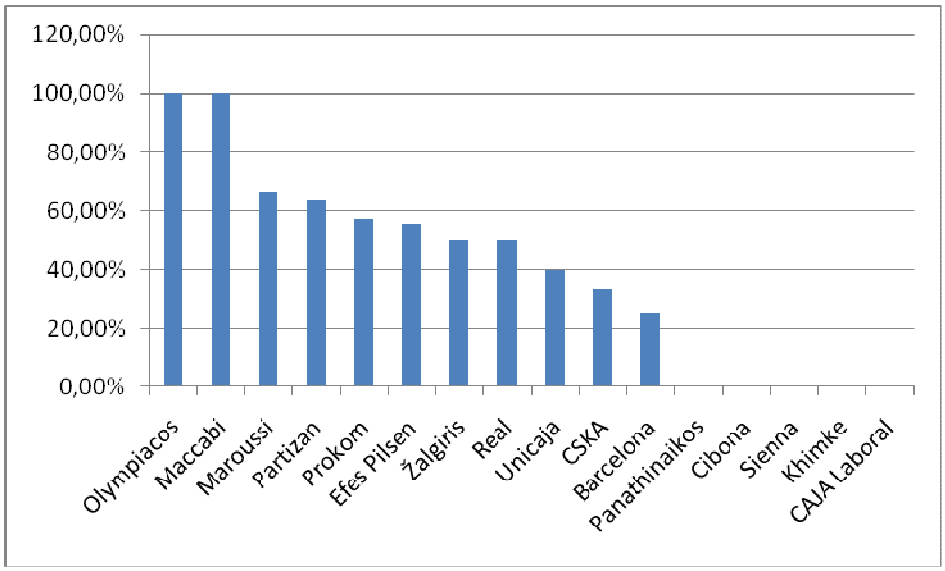
Slika 7.28. Zastupljenost *handoff* manevra u završnici pojedinih ekipa u Top 16



Na slici 7.28. prikazana je zastupljenost *handoff* manevra u kojem su momčadi Efes Pilsen (9%) i Maroussi (7,4%) imale relativno visoku zastupljenost *handoff*-a.

Opća uspješnost *handoff* manevra u završnici je dana sa 49,3%, a uspješnost po klubovima je prikazana histogramom na slici 7.29.

Slika 7.29. Uspješnost *handoff* manevra u završnici pojedinih ekipa u Top 16

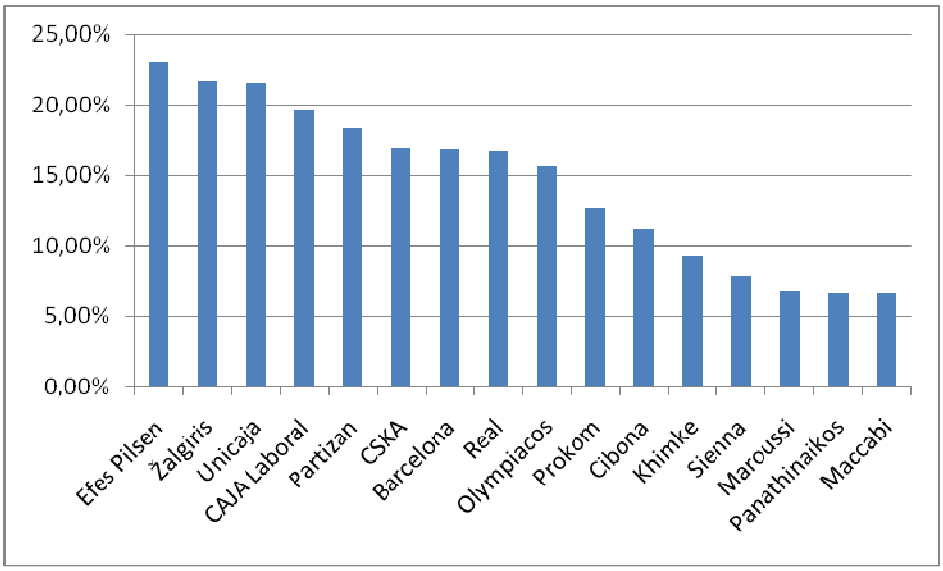


Zbog male frekvencije Olympiacos te Maccabi imaju 100%-tnu uspješnost, dok za čak 5 klubova nije registriran manevar *handoff* u završnici, pa se ovi rezultati moraju uzeti sa zadrškom.

7.1.2.2.3. *Screens off the ball* (blokovi na igračima bez lopte) u završnici

Blokovi na igračima bez lopte u završnici pozicijskog napada opisani su varijablom V_PN_Z_15 čija je zastupljenost u pozicijskim napadima 14,7%.

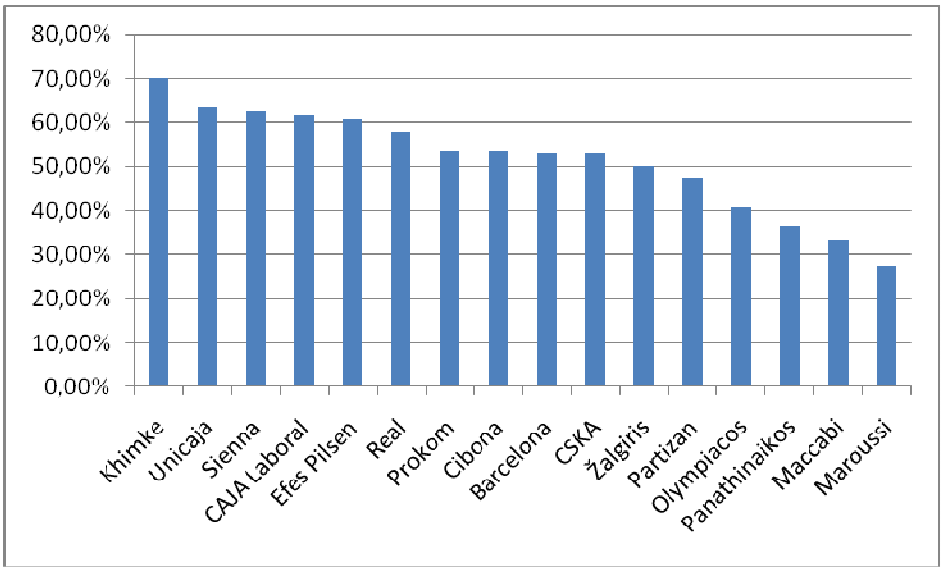
Slika 7.30. Zastupljenost *screens off the ball* manevra u završnici pojedinih ekipa u Top 16



Na slici 7.30. vidljivo je da se 3 momčadi, Efes Pilsen, Žalgiris i Unicaja ističu s preko 20% udjela blokova na igračima bez lopte u završnici pozicijskog napada, a neznatni udio imaju momčadi Khimke, Sienna, Maroussi, Panthinaikos i Maccabi.

Ukupna uspješnost navedenog manevra u završnici je 52,4%, što je više od prosjeka uspješnosti pozicijskog napada.

Slika 7.31. Uspješnost *screens off the ball* manevra u završnici pojedinih ekipa u Top 16

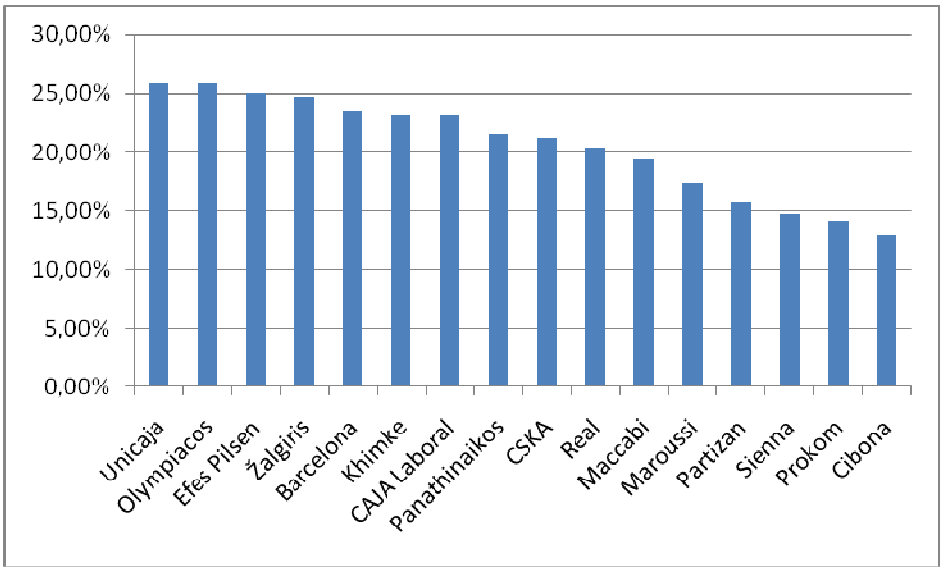


Na slici 7.31. vidljivo je da se momčad Khimke ističe s relativno visokih 70%, dok momčadi Panathinaikos, Maccabi i Maroussi obilježava relativno mali postotak uspješnosti (ispod 40%) *screens off the ball* manevra.

7.1.2.2.4. *Inside cut* (utrčavanja) u završnici

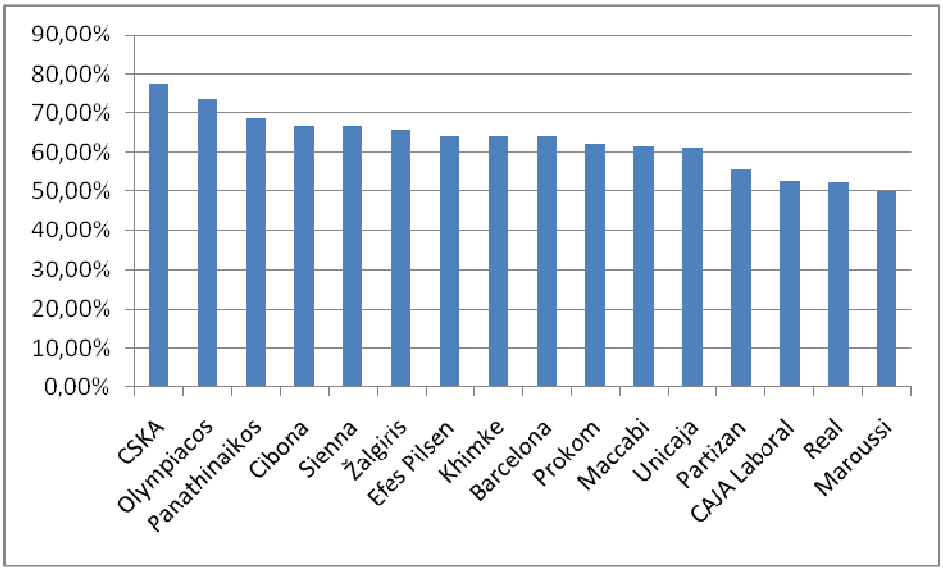
U završnici pozicijskog napada, manevar utrčavanja je pokriven varijablama V_PN_Z_4, V_PN_Z_5, V_PN_Z_7, a njihova zastupljenost po napadima je 20% (Slika 7.32.).

Slika 7.32. Zastupljenost manevra utrčavanja u završnici pojedinih ekipa u Top 16



Uspješnost unutarnjih utrčavanja u završnici pozicijskih akcija je 64%, što je znatno iznad prosjeka uspješnosti pozicijskog napada te ih čini najuspješnijim napadačkim manevrima. Distribucija uspješnosti po klubovima je dana slikom 7.33.

Slika 7.33. Uspješnost manevra utrčavanja u završnici pojedinih ekipa u Top 16

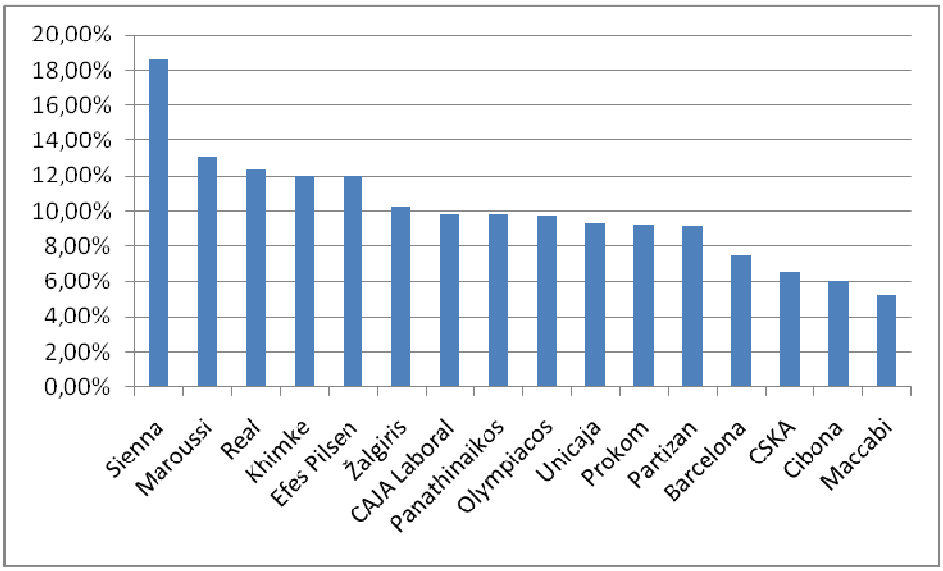


Na slici 7.33. očito je da su CSKA i Olympiacos najuspješnije momčadi u manevru utrčavanja u završnici pozicijskih akcija s preko 70%.

7.1.2.2.5. *Low post game* (igra na niskom postu) u završnici

Igra na niskom postu u završnici pozicijskih akcija pokrivena je varijablom V_PN_Z_10 čija je zastupljenost 10%.

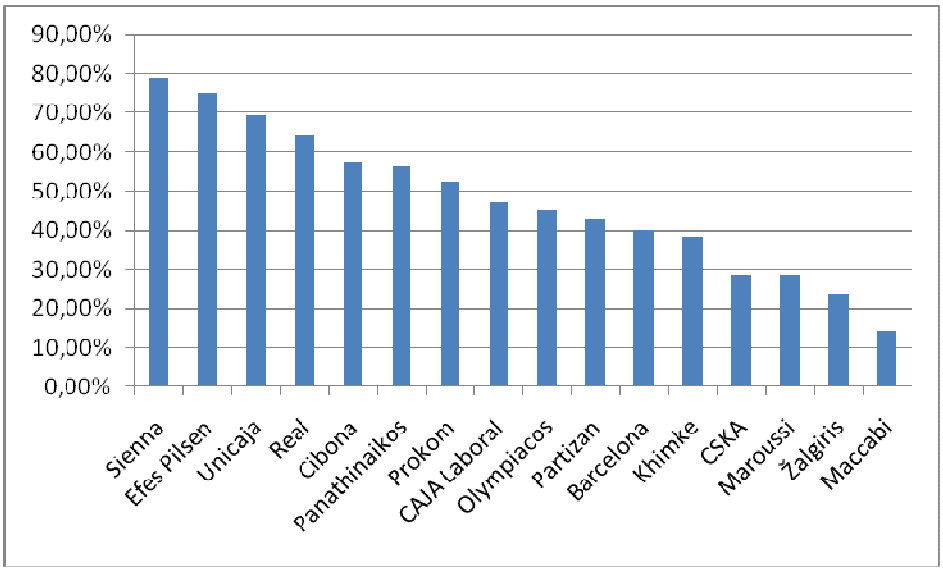
Slika 7.34. Zastupljenost igre na niskom postu u završnici pojedinih ekipa u Top 16



Na slici 7.34. prikazana je zastupljenost igre na niskom postu u završnici pozicijskog napada u kojem se momčad Sienne ističe s relativno visokih preko 18%, dok momčad Cibone obilježava svega 6%, a Maccabi 5% unutarnje igre na low post poziciji.

Uspješnost igre na niskom postu u završnici je **ispod** prosječne uspješnosti pozicijskog napada sa 47,8%. Pretpostavlja se da u ovom trenutku nema dovoljan broj kvalitetnih centara u evropskoj košarci koji posjeduju visoku razinu vještina u *post* prostoru, što se očituje na razinu efikasnosti na *low post* poziciji.

Slika 7.35. Uspješnost igre na niskom postu u završnici pojedinih ekipa u Top 16

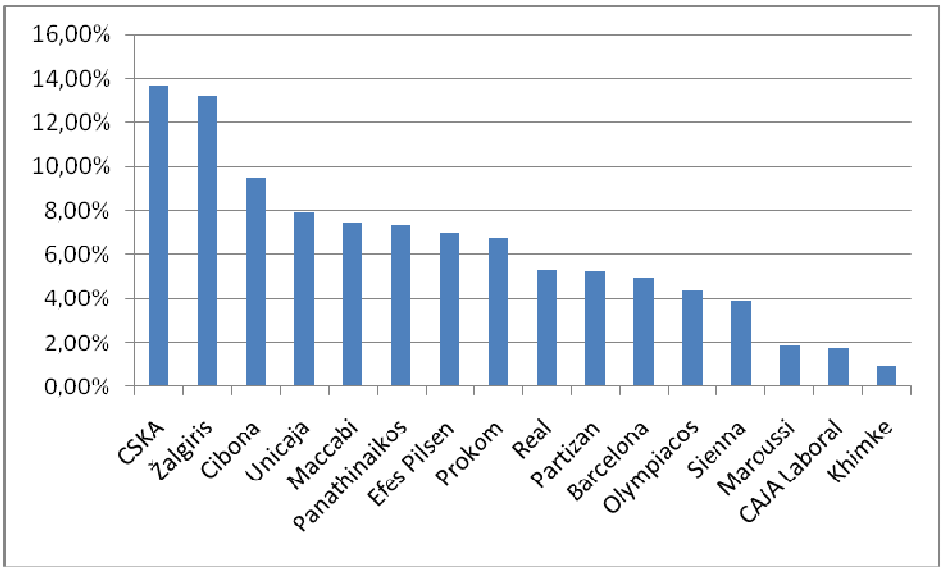


Usporedna analiza pokazuje kako su momčadi Sienna, Efes Pilsen, Unicaja i Real uspješne ekipe u igri na niskom postu. Momčadi kao što su CSKA, Maroussi, Žalgiris i Maccabi su izrazito neuspješne u igri na *low post* poziciji (Slika 7.35).

7.1.2.2.6. Izolacije na perimetru u završnici

Izolacije na perimetru u završnici pokrivene su varijablom V_PN_Z_9 čija je zastupljenost 6%.

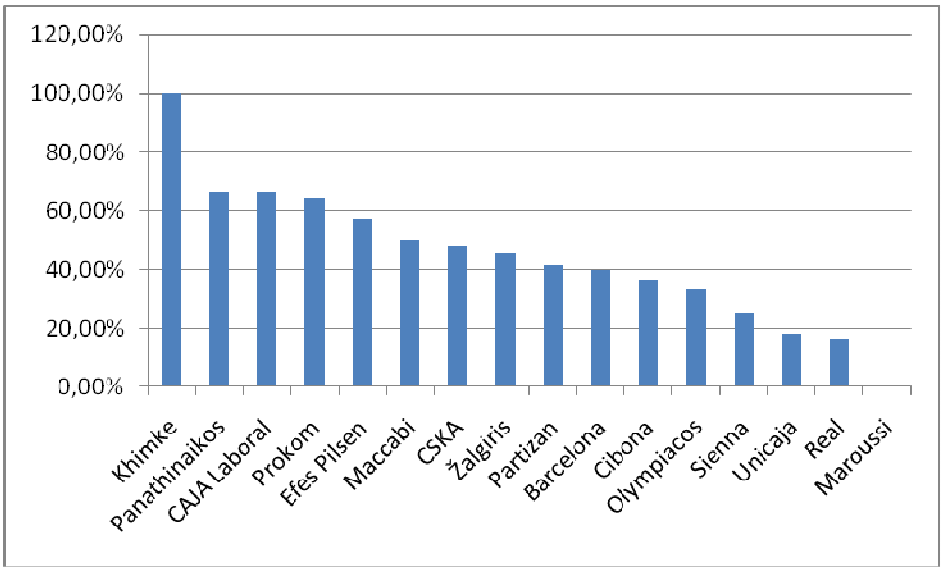
Slika 7.36. Zastupljenost izolacija na perimetru u završnici pojedinih ekipa u Top 16



Iz slike 7.36 možemo uočiti da se CSKA i Žalgiris ističu s relativno visokom zastupljenošću izolacija na vanjskom prostoru i to preko 13% dok se momčadi Maroussi, CAJA Laboral i Khimke ističu relativno niskom primjenom takvih završnica u pozicijskom napadu.

Uspješnost izolacija na perimetru je 47%, što je **ispod** prosječne uspješnosti pozicijskog napada. Vjerojatno je to iz razloga što timski mehanizmi obrane puštaju uspješno pomaganje i zatvaranje reketa protiv navedenog napadačkog manevra, a distribucija po klubovima je dana slikom.

Slika 7.37. Uspješnost izolacija na perimetru u završnici pojedinih ekipa u Top 16

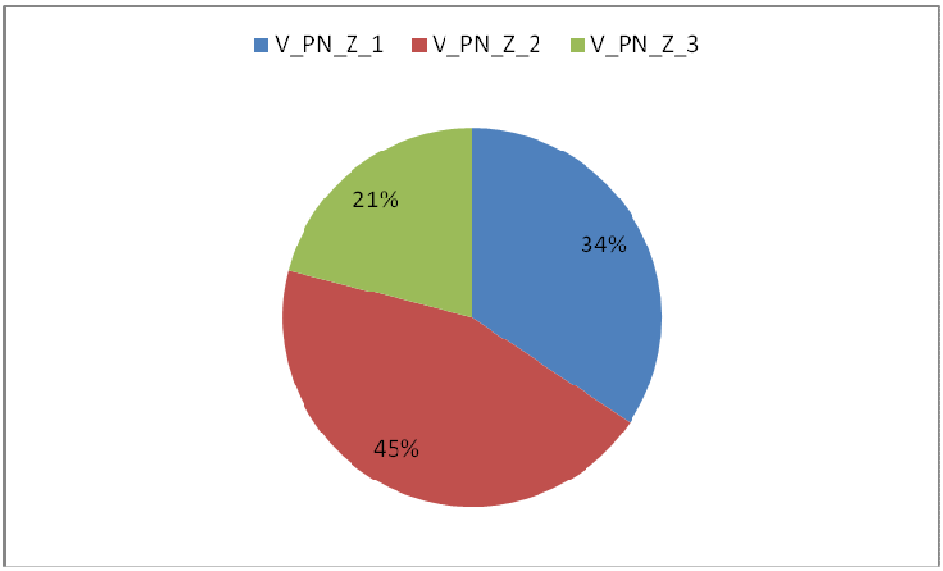


Zbog relativno male frekvencije u promatranom uzorku, Khimke se ističe sa 100% uspješnošću, a Maroussi s 0% (Slika 7.37.).

7.1.2.2.7. Načini realizacije u završnici pozicijskog napada

U sklopu ove studije, interesira nas način realizacije u završnici pozicijskog napada. Pritom analiziramo učestalost izvedbe šut s mjesta - V_PN_Z_1, šut ispod koša V_PN_Z_2 ili šut iz vođenja V_PN_Z_3. Zastupljenost navedenih modaliteta realizacije prikazana je na slici 7.38.

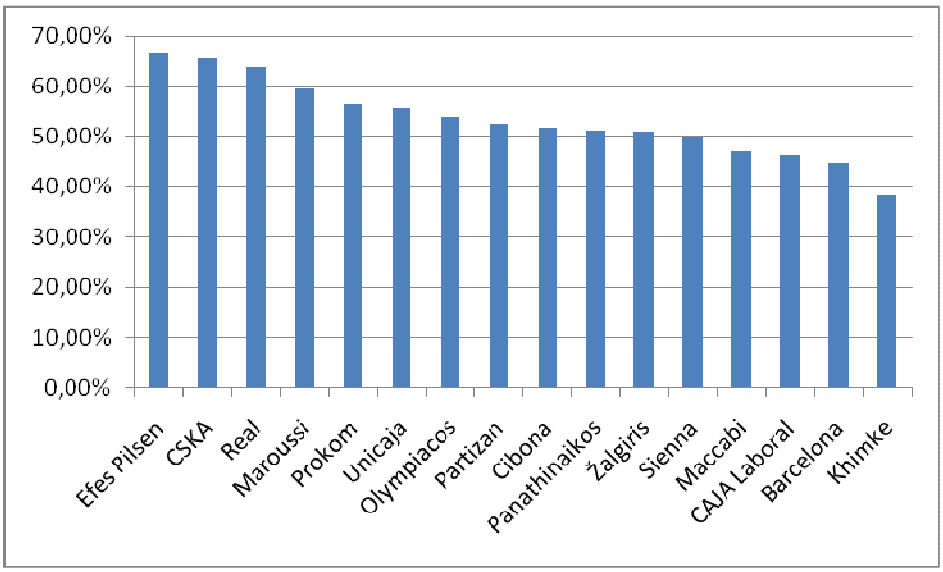
Slika 7.38. Zastupljenost pojedinog načina realizacije u završnici



Vidljivo je na slici 7.38. kako je šut iz vođenja najmanje zastupljen, što je obilježje igre na svim razinama natjecanja u evropskoj košarci. To je vjerojatno stoga što je obrana svake sezone sve agresivnija i agresivnija i sve je teže ostvariti dovoljno prostora za neometan šut iz vođenja.

Nadalje, ukupna uspješnost šuta s mjesta je 53,5%.

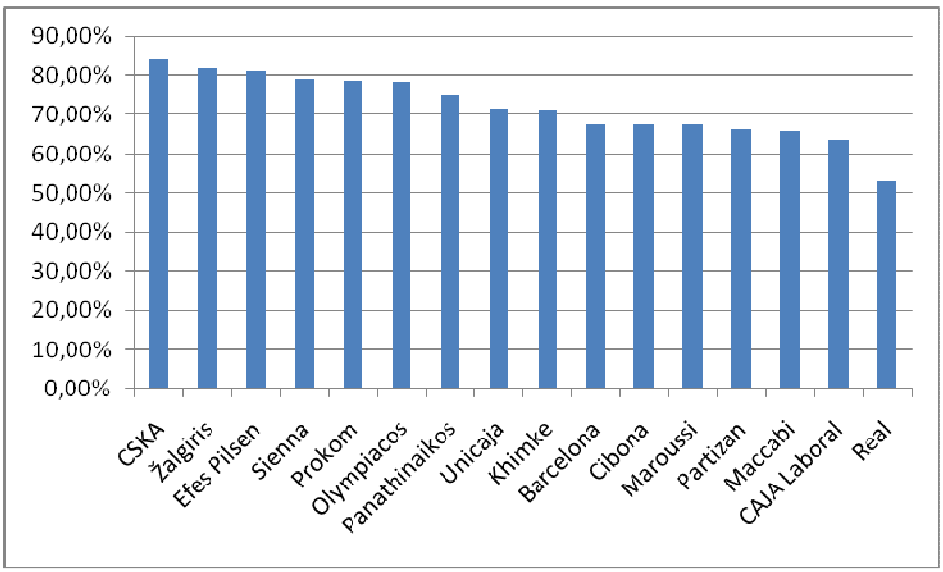
Slika 7.39. Uspješnost šuta s mjesta u završnici pojedinih ekipa u Top 16



Na slici 7.39. prikazana je uspješnost šuta s mjesta u završnici, u kojem se ističu momčadi Efes Pilsen, CSKA i Real s preko 63% uspješnosti, dok su momčadi Maccabi, CAJA Laboral, Barcelona i Khimke uspješni ispod 50%.

S druge strane ukupna uspješnost šuta iz reketa je 72,5%, što ga čini najuspješnijim načinom realizacije u fazi napada.

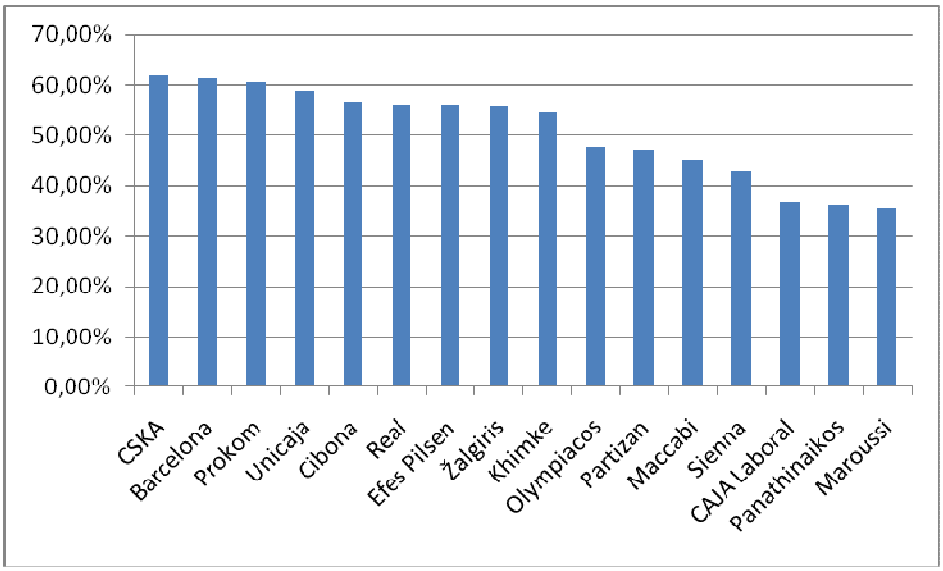
Slika 7.40. Uspješnost šuta iz reketa u završnici pojedinih ekipa u Top 16



Na slici 7.40. očita je ujednačena uspješnost šuta iz reketa ekipa u Top 16. Jedino momčad Reala obilježava relativno niska uspješnost (52%).

Uspješnost šuta iz vođenja iznosi 51,4%, a po klubovima, što je najneuspješnije od sva 3 načina realizacije.

Slika 7.41. Uspješnost šuta iz vođenja u završnici pojedinih ekipa u Top 16

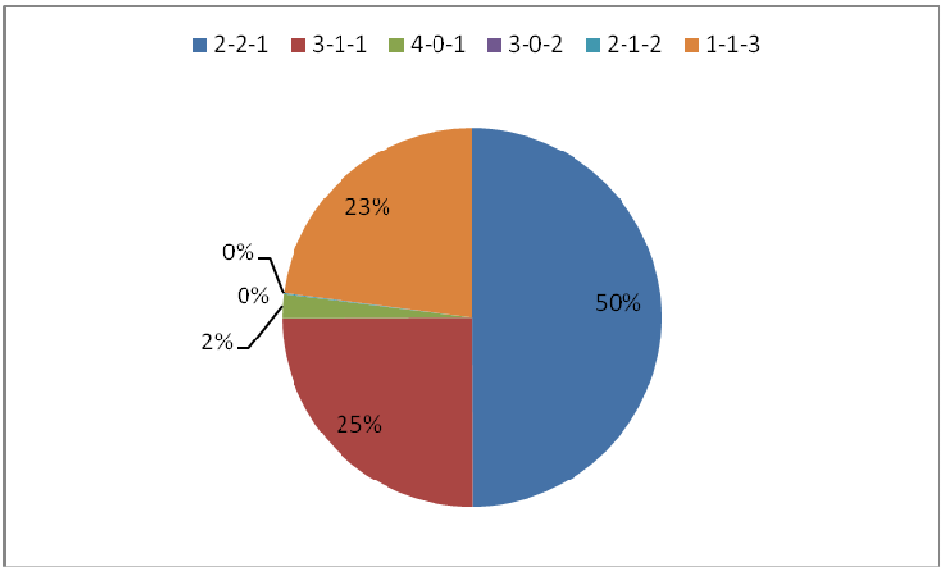


Na slici 7.41. vidljivo je kako relativno nisku uspješnost šuta iz vođenja u završnici imaju momčadi CAJA Laboral, Panathinaikos i Maroussi.

7.1.2.2.8. Napadački skakački rasporedi

U kontekstu ove studije, napadački skakački rasporedi opisani su varijablama V_PN_Z_17 (raspored 2-2-1), V_PN_Z_18 (raspored 3-1-1), V_PN_Z_19 (raspored 4-0-1), V_PN_Z_20 (raspored 3-0-2), V_PN_Z_21 (raspored 2-1-2), V_PN_Z_22 (raspored 1-1-3), a njihova zastupljenost je prikazana slikom 7.42.

Slika 7.42. Zastupljenost pojedinog napadačkog skakačkog rasporeda

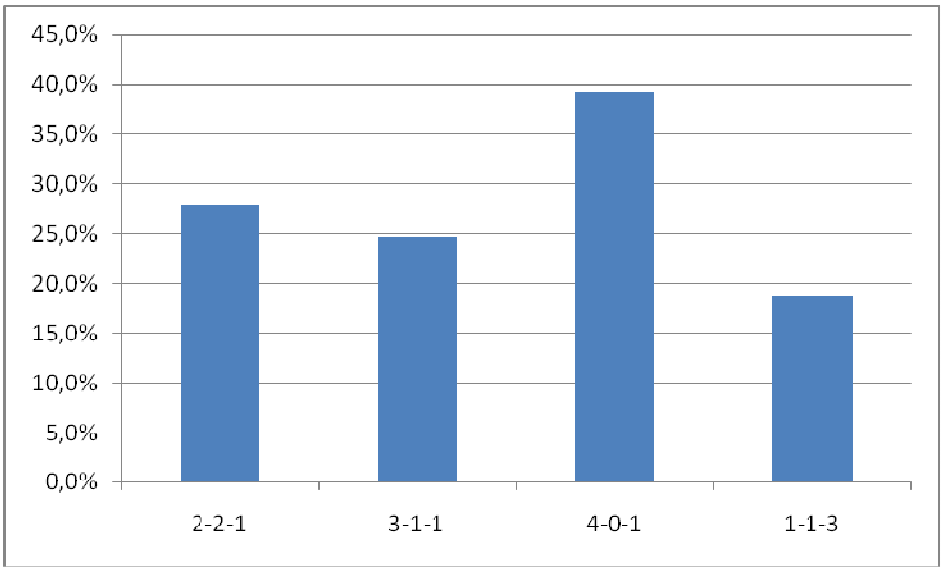


Na slici 7.42. prikazana je zastupljenost napadačkih skakačkih rasporeda. Važno je istaknuti da je zastupljenost napadačkih skakačkih rasporeda 3-0-2 i 2-1-2 u našem uzorku 0%. Nadalje, ističe se kako je najzastupljeniji raspored 2-2-1 s relativno visokih 50%. Napadački skakački raspored 2-2-1 je konzervativan i uravnotežen te predstvlja optimalan pritisak na skoku s 2 igrača u reketu, 2 igrača koja su jednim dijelom u obrambenoj ravnoteži, a drugim dijelom spremini za dugo dobijene lopte (*long rebound*) te s jednim igračem osiguranja koji je potpuno u obrambenoj ravnoteži.

Podaci upućuju kako najveću zastupljenost napadačkog skakačkog rasporeda 2-2-1 imaju Panathinaikos sa 63,8% i Cibona s 59,1%. Nadalje, najveću zastupljenost napadačkog skakačkog rasporeda 3-1-1 imao je Partizan sa 63,8% te Unicaja s 39,6%. Najveću zastupljenost napadačkog skakačkog rasporeda 4-0-1 imao je Partizan sa 17,3% te Cibona sa 4,6%, dok su najveću zastupljenost napadačkog skakačkog rasporeda 1-1-3 imali Prokom s 38,3%, Efes Pilsen s 36,9% te CAJA Laboral s 36,8%.

Uspješnost navedenih napadačkih skakačkih rasporeda prikazana je na slici 7.43.

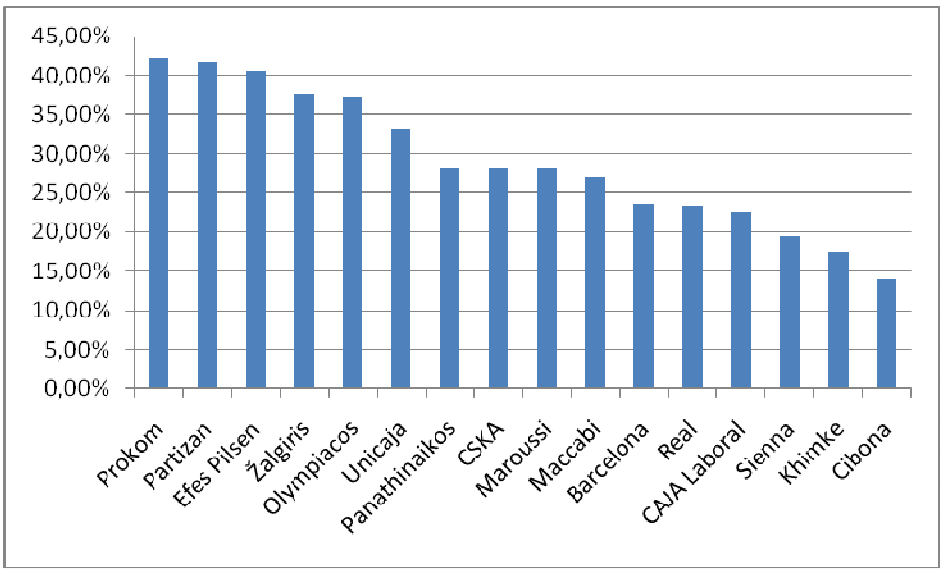
Slika 7.43. Uspješnost pojedinog napadačkog skakačkog rasporeda



Na slici 7.43. vidljiva je dominantna uspješnost skakačkog rasporeda s 4 igrača koji pokrivaju pozicije za hvatanje odbijenih lopti. Taj raspored je visoko rizičan u smislu obrane od kontranapada. Iako malo klubova koristi taj raspored (u našem uzorku izrazito Partizan) bitno se povećava vjerojatnost skakačke uspješnosti.

Opća napadačka skakačka uspješnost u pozicijskom napadu je 30,0%.

Slika 7.44. Uspješnost pojedinog napadačkog skakačkog rasporeda pojedinih ekipa u Top 16



Na slici 7.44. vidljivo je da su najuspješnije napadačke skakačke ekipe Prokom (42,1%), Partizan (41,6%) te Efes Pilsen (40,6%), dok je najneuspješnija napadačka skakačka ekipa Cibona (14,0%). U košarkaškoj praksi se smatra da je napadačka skakačka učinkovitost iznad 33,3% nadprosječno uspješna. U tom smislu se elitna europska seniorska košarka u prosjeku ne može smatrati uspješnom u pokrivanju skoka u napadu koji interpretiramo kao produžetak agresivnosti napada te kao prvu fazu tranzicijske obrane.

To je vjerojatno stoga što:

- Igrači nisu u procesu integralne sportske pripreme stvorili naviku primjene fizičke agresivnosti u borbi za prostor i prednju poziciju za kratko ili dugo odbijene lopte;
- Igrači nisu stekli vještine da izbore prednju poziciju i stav pred skok (pozicija spreman za hvatanje odbijenih lopti) prije nego što je šut izveden;
- Igrači nisu poticali razvoj percepcije u smjeru da svaki šut promatraju kao promašaj;
- Igrači nisu u procesu situacijskog treninga razvijali sposobnost brzih i višestrukih skokova te koordinaciju hvatanja lopte s obje ruke ispred i iznad glave;
- Igrači nisu razvijali u procesu cjelokupne sportske pripreme sposobnost temporalne i spacijalne anticipacije (gdje i kada će se lopta odbiti nakon šuta).

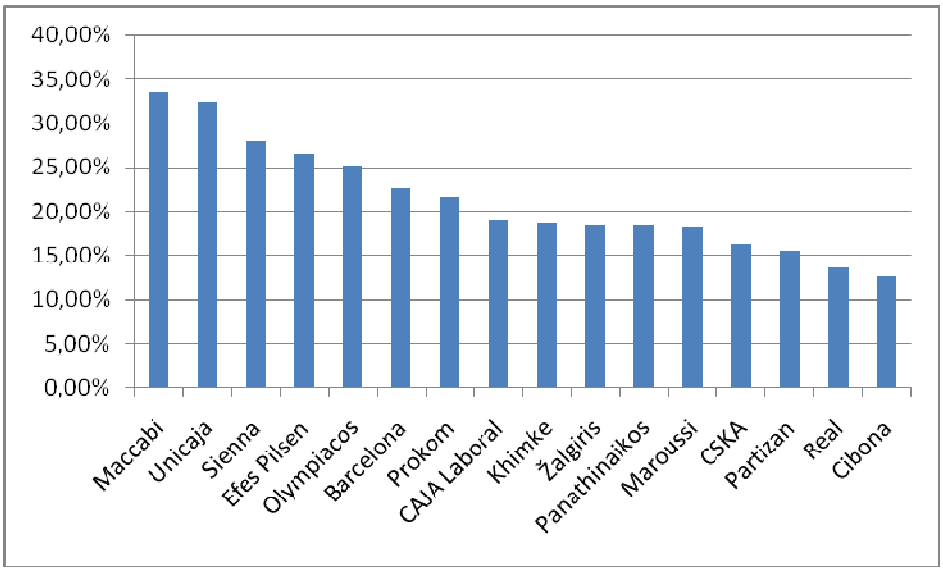
Pretpostavlja se kako ni kriteriji selekcije visokih igrača nisu u dovoljnoj mjeri usmjereni prema navedenim zahtjevima. S druge strane, s gledišta tijeka igre zahtjev obrambene ravnoteže u trenutku šuta u svrhu prevencije protivničke tranzicije napada je toliko važan da može smanjiti tendenciju pojedinih igrača u kretanju prema košu s ciljem hvatanja odbijenih lopti. U mnogim situacijama igrači ne primjenjuju fizičku agresivnost u izboru unutarnje pozicije za skok u napadu, već su usmjereni primarno na uspješnu obranu protuudara protivničke momčadi.

7.1.3. Tranzicijski napad

7.1.3.1. Zastupljenost i uspješnost tranzicijskog napada

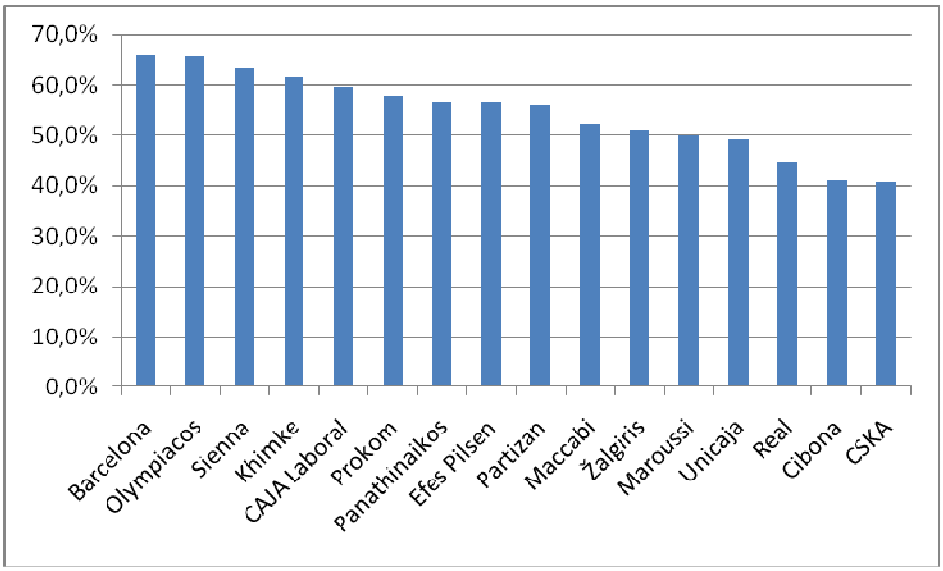
U ovoj studiji evidentirano je 716 napada koji su počeli i **imali neki ishod** u stanju tranzicijskog napada. To iznosi 22% od ukupnog broja napada. Od toga je 398 uspješnih, odnosno 55,6%. Na slici 7.45. prikazana je zastupljenost tranzicijskog napada pojedinih ekipa u Top 16.

Slika 7.45. Zastupljenost tranzicijskog napada pojedinih ekipa u Top 16



Pojedine momčadi kao što su Maccabi i Unicaja se ističu visokom zastupljenosti tranzicijskog napada (30%), dok Cibonu i Real obilježava niska zastupljenost igre protuudara (14%).

Slika 7.46. Uspješnost tranzicijskog napada pojedinih ekipa u Top 16



Na slici 7.46. prikazana je relativno visoka uspješnost tranzicijskog napada momčadi kao što su Barcelona, Olympiacos, Sienna i Khimke (preko 60%), dok momčadi Cibona i CSKA imaju uspješnost tranzicijskog napada ispod 42%.

Međutim, ako promatramo tranzicije napada koje su izvedene do završnice (nisu bile prije ulaska u završnicu prekinute izgubljenim posjedom lopte ili prekršajem pravila), onda je ukupan broj tranzicija 605 što čini **18,5%** od ukupnog broja napada. Od toga je 377 uspješnih, što čini ukupnu uspješnost **62,3%**.

7.1.3.2. Završnica protunapada

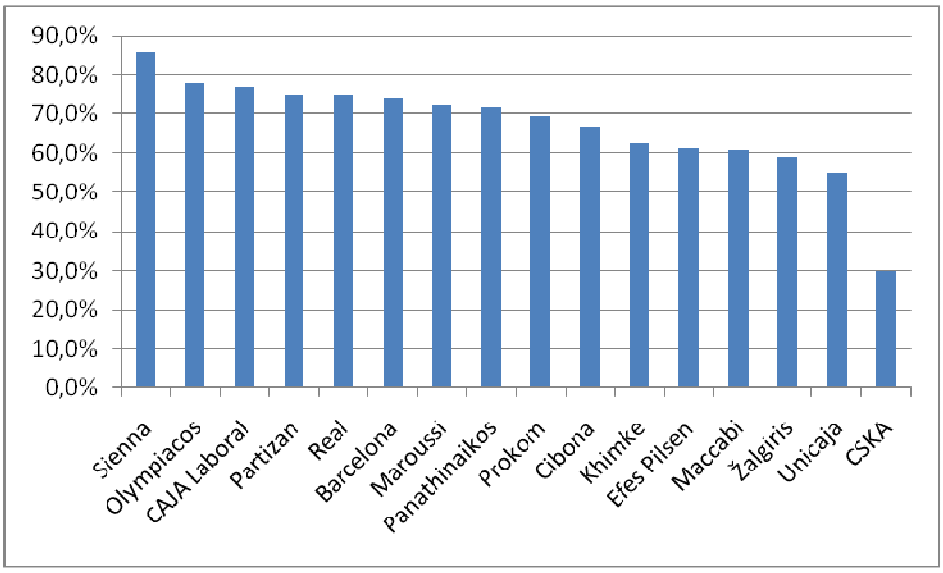
U analizi tranzicijskog napada u završnici, nužno je odvojeno promatrati zastupljenost i uspješnost primarnog protunapada („prvog udara“ - vrijeme realizacije 3 do 6 sekundi od trenutka dolaska u posjed lopte), sekundarnog protunapada („drugog udara“ - vrijeme realizacije 6 do 10 sekundi od trenutka dolaska u posjed lopte) te tzv. „ranog napada“ (vrijeme realizacije 10 do 15 sekundi od trenutka dolaska u posjed lopte).

7.1.3.2.1. Primarni protunapad

Primarni protunapad je definiran situacijama i/ili prostorne prednosti: 1 na 0, 1 na 1, 2 na 1, 2 na 3 , 3 na 1 i 3 na 2, koje završavaju u vremenu od 3 do 6 sekundi od trenutka dolaska u posjed lopte. Pritom je opisan varijablama: V_TN_Z_1, V_TN_Z_2, V_TN_Z_3, V_TN_Z_4, V_TN_Z_5, V_TN_Z_6, V_TN_Z_7, V_TN_Z_8, V_TN_Z_28, V_TN_Z_29, V_TN_Z_30, V_TN_Z_31, V_TN_Z_32, V_TN_Z_33 i V_TN_Z_34.

Frekvencija navedenih stanja iznosi 299, što čini **49,4%** od 605 stanja koja su izvedena do završnice tranzicije. Uspješnih je 204, što čini **68,2%** uspješnosti. Udio primarnih protunapada u ukupnom broju napada je **9,1%**.

Slika 7.47. Uspješnost primarnog protunapada pojedinih ekipa u Top 16



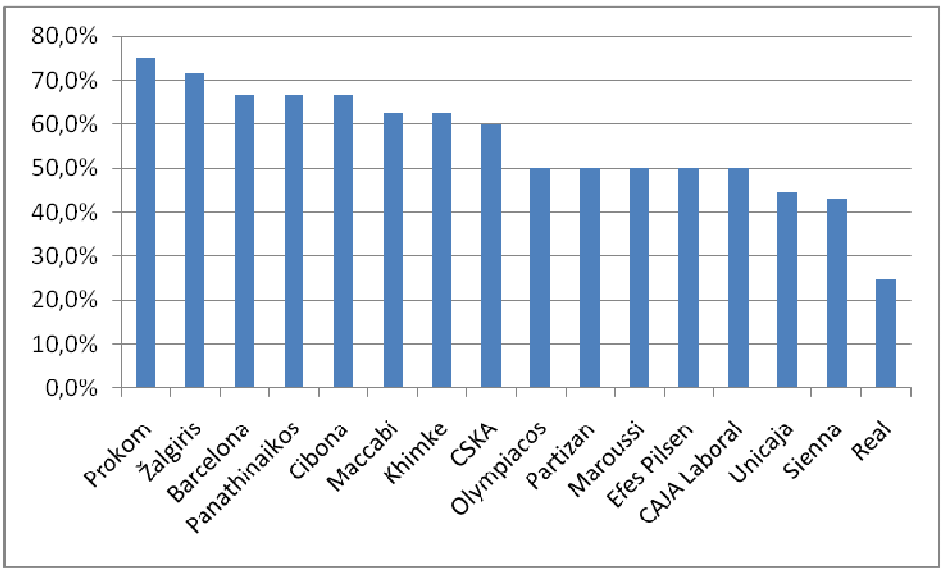
Na slici 7.47. očigledno je kako u uspješnosti primarnog protunapada dominira momčad Sienna s relativno visokih 86% dok je najneuspješnija momčad u prvom protuudaru CSKA s relativno niskih 30%.

7.1.3.2.2. Sekundarni protunapad

Sekundarni protunapad opisan situacijama 3 na 3, 4 na 3, 4 na 2, 5 na 3 i 5 na 4 koje se realiziraju od 6 do 10 sekundi od dolaska u posjed lopte. Pritom je opisan stanjima: V_TN_Z_9, V_TN_Z_10, V_TN_Z_11, V_TN_Z_12, V_TN_Z_13, V_TN_Z_35, V_TN_Z_36 i V_TN_Z_37.

Zastupljenost situacija sekundarnog protunapada je 96 od 605, što čini **15,9%** od ukupnog broja protunapada koja su došli do završnice, a ima ih **2,9%** od ukupnog broja napada. Pritom je ukupna prosječna uspješnost **52%.**

Slika 7.48. Uspješnost sekundarnog protunapada pojedinih ekipa u Top 16



Na slici 7.48. očito je da momčadi Prokom i Žalgiris imaju uspješnost sekundarnog protunapada (preko 70%), dok momčad Reala obilježava niska uspješnost (manje od 25%).

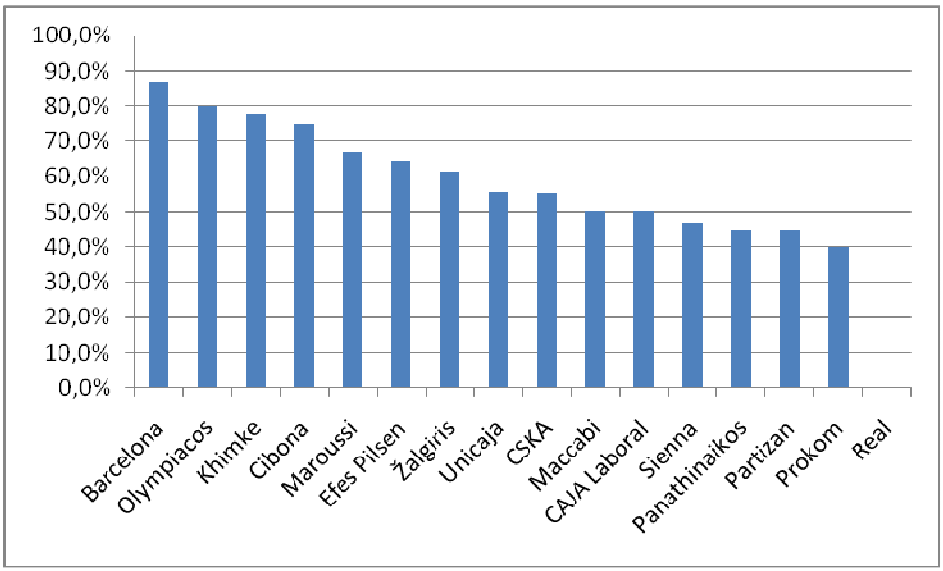
Kada zbrojimo primarne i sekundarne, protunapade dobivamo 395 napada, što čini **12,1%** od ukupnog broja napada. Taj udio je ono što se kolokvijalno naziva „protunapad“ ili „protuudar“. Ukupna uspješnost tako definiranog protunapada iznosi **65%**.

7.1.3.2.3. Rani napad

Rani napad se odnosi na situacije 5 na 5 u kojima nema brojčane prednosti, ali u kojima je prisutno nastojanje da se u vremenskom okviru od 10 do 15 sekundi od trenutka dolaska u posjed lopte iskoristi trenutna neorganiziranost obrane. Način realizacije ranog napada je opisan varijablama V_TN_Z_14, V_TN_Z_15, V_TN_Z_16, V_TN_Z_17, V_TN_Z_18, V_TN_Z_19, V_TN_Z_20, V_TN_Z_21, V_TN_Z_22, V_TN_Z_23, V_TN_Z_24, V_TN_Z_25, V_TN_Z_26 i V_TN_Z_27.

Ranih napada je evidentirano ukupno 210, što čini **34,7%** od 605 napada koji su izvedeni do završnice, a **6,4 %** od ukupnog broja napada. Ukupna uspješnost ranog napada je **57,1%**.

Slika 7.49. Uspješnost ranog napada pojedinih ekipa u Top 16



Na slici 7.49. vidljiva je relativno visoka uspješnost momčadi kao što su Barcelona, Olympiacos, Khimke i Cibona (preko 70%), dok Real ima uspješnost 0%, što je vjerojatno posljedica neznatnog broja izvedenih ranih napada.

7.1.3.2.4. Analiza načina realizacije protunapada

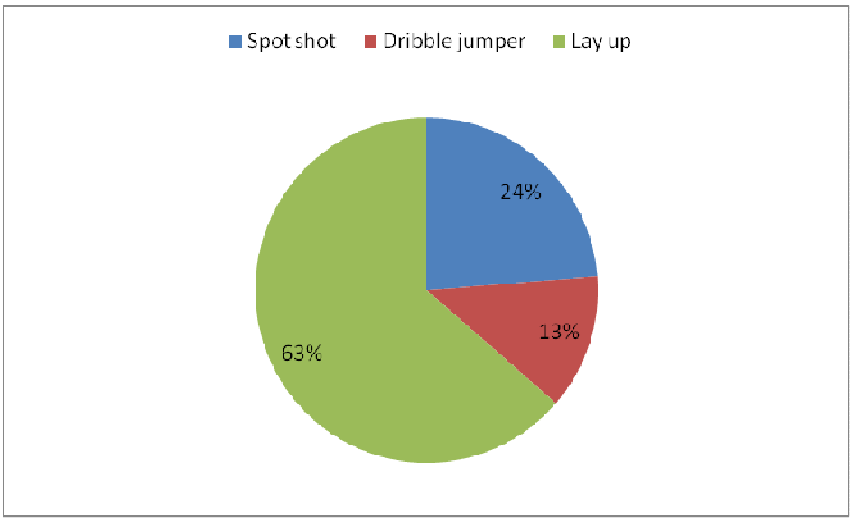
Načini realizacije protunapada opisani su kroz tri kategorije:

a) šut s mjesta odnosno dotrčavanja – *spot shot,* što je opisano varijablama V_TN_Z_29 i V_TN_Z_30

b) šut iz vođenja – *dribble jumpr,* što je opisano varijablom V_TN_Z_31

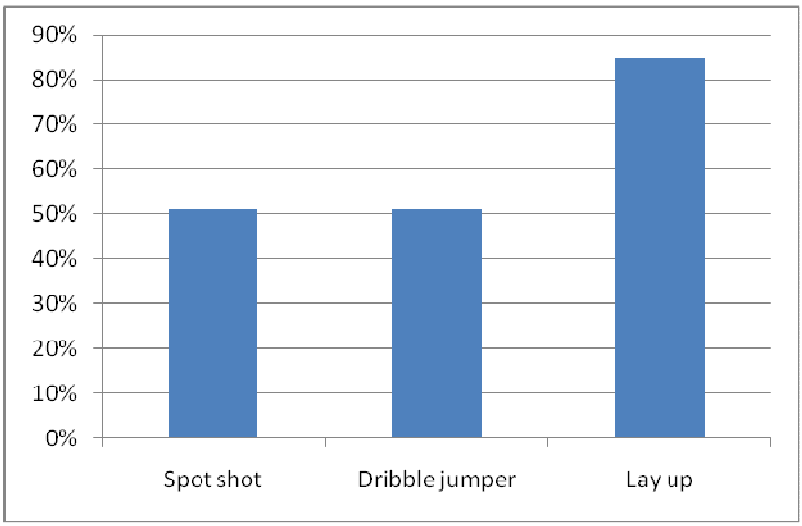
c) šut ispod koša - *lay up,* što je opisano varijablama V_TN_Z_32, V_TN_Z_33 i V_TN_Z_34

Slika 7.50. Zastupljenost pojedinog načina realizacije protunapada



Na slici 7.50. najučestaliji način realizacije u protunapadu je šut ispod koša sa 63% zatim slijedi šut s mjesta s 24% a najneučestaliji je šut iz vođenja s 13%.

Slika 7.51. Uspješnost pojedinog načina realizacije protunapada

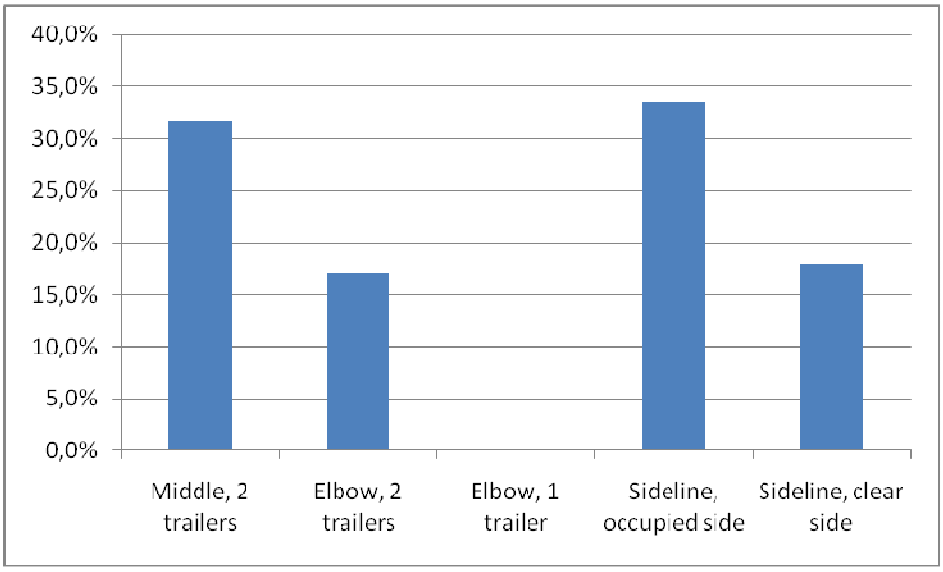


U usporedbi s pozicijskim napadom vidljivo je kako šut ispod koša predstavlja najuspješniji način realizacije (85%). S druge strane, uspješnost šuta iz vođenja i šuta iz mjesta (kao preostala 2 načina realizacije protunapada) iznosi 50% (Slika 7.51).

7.1.3.3. Analiza središnjice protunapada

U središnjici protunapada nas primarno zanima način popunjavanja linija. Pripadne varijable su V_TN_S_1 - središnji igrač s loptom i dva pratioca (*middle, 2 trailers*), V_TN_S_3 - igrač s loptom na rubu linije slobodnih bacanja i dva pratioca (*elbow, 2 trailers*), V_TN_S_4 - igrač s loptom na rubu linije slobodnih bacanja i jedan pratilac (*elbow, 1 trailer*), V_TN_S_6 - igrač s loptom na bočnoj liniji, popunjena strana lopte (*sideline, occupied side*), V_TN_S_7 - igrač s loptom na bočnoj liniji, prazna strana lopte (*sideline, clear side*).

Slika 7.52. Zastupljenost pojedinog načina popunjavanja linija u središnjici protunapada



U odnosu na pojedine klubove zastupljenost različitih načina popunjavanja linija kretanja u središnjici tranzicije napada može se svesti na sljedeće:

- U *middle, 2 trailers* sustavu visokim postotkom ističe se CSKA 48,1%, Panathinaikos s 45,8% te Žalgiris s 45,5% dok momčadi kao što su Maroussi i Maccabi obilježava niska zastupljenost (12,2% i 13,3%).

- U *elbow, 2 trailers* sustavu visokim postotkom ističu se Prokom s 33,3% i Partizan s 31,6% dok momčad Khimke ima 0,0%, a Maccabi 4,6% zastupljenosti.

- U *sideline, occupied side* sustavu sa visokim postotkom ističu se Maccabi sa 70,7%, Sienna s 50,0% i Khimke s 46,2%, dok momčadi kao što su CAJA Laboral i Žalgiris obilježava relativno niska zastupljenost (12,5% i 15,2%).

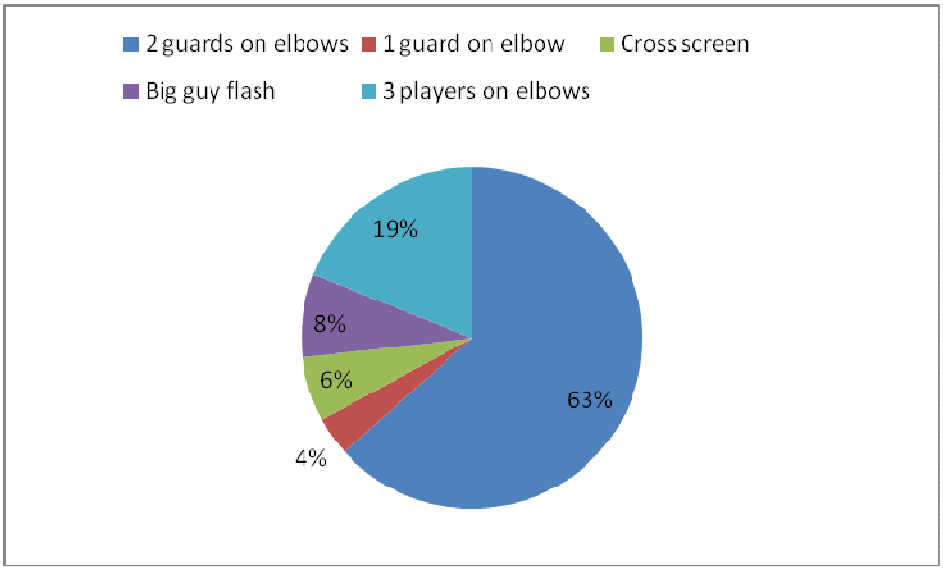
- U *sideline, clear side* sustavu visokim postotkom ističu se Unicaja sa 46,2% i Khimke 38,5% dok suprotno tome Cibona ima 0,0%, a Sienna 4,5% zastupljenosti.

7.1.3.4. Tranzicijski napad protiv presinga

Također je u ovoj studiji obrađena struktura tranzicijskog napada protiv presing obrane.

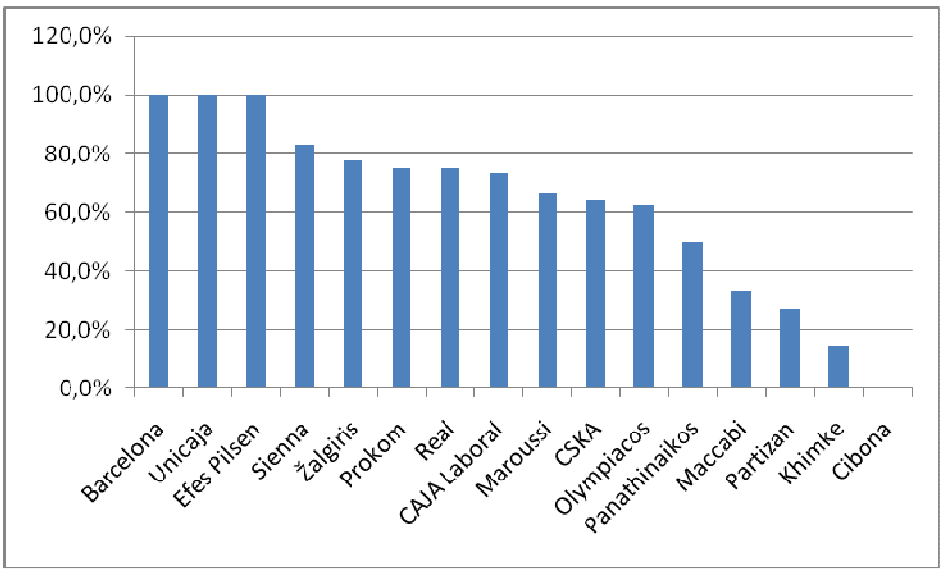
a) Ulazni raspored u napadu na presing opisan je varijablama: V_TN_I_16 - 2 beka na rubovima linije slobodnih bacanja (*2 guards on elbows*), V_TN_I_17 - 1 bek na rubu linije slobodnih bacanja (1 *guard on elbow*), V_TN_I_18 – suprotni blok (*cross screen*), V_TN_I_19 – visoki igrač se otvara prema lopti (*big guy flash*), V_TN_I_20 – 3 igrača u razini linije slobodnih bacanja (*3 players on free throw line*).

Slika 7.53. Zastupljenost načina otvaranja protiv presinga



Najstandardnije otvaranje protiv presing obrane kojemu su 2 igrača na rubovima linije slobodnih bacanja (*2 guards on elbows*) je najzastupljenije sa 63% (Slika 7.53), a po klubovima je distribucija prikazana slikom 7.54. Zatim slijedi način otvaranja protiv presinga s 3 igrača u razini linije slobodnih bacanja, što je metoda standardno primjenjivana zadnjih nekoliko godina i to u cilju olakšanja uvođenja lopte. To je stoga što se otvaraju tri mogućnosti ulazne linije dodavanja protiv presinga, za razliku od prethodne metode koja otvara samo dvije linije ulaznog dodavanja.

Slika 7.54. Zastupljenost otvaranja protiv presinga s 2 igrača na rubovima linije slobodnih bacanja pojedinih ekipa u Top 16

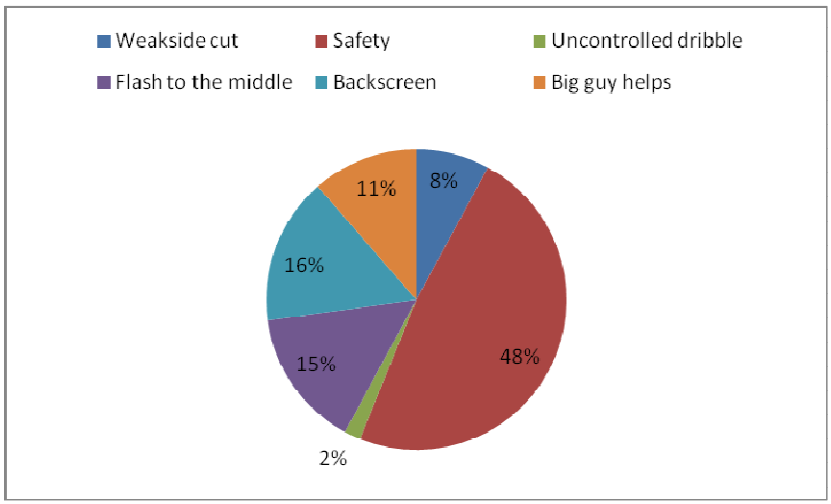


Na slici 7.54. očito je da su momčadi Barcelona, Unicaja i Efes Pilsen isključivo usmjerene na način otvaranja s *2 guards on elbows*, dok se momčadi Khimke (85%) i Partizan (65%) otvaraju s *3 players on elbows*. Većina klubova primjenjuje najmanje dva načina otvaranja protiv presing obrane.

b) Taktička kombinatorika napada protiv presing obrane opisana je varijablama V_TN_S_8 – utrčavanje sa suprotne strane (od lopte ili sa slabije strane napada) (*weakside cut*), V_TN_S_9 – zadržavanje igrača 1 korak iznad linije lopte (*safety*), V_TN_S_10 – nekontrolirani dribling (*uncontrolled dribble*), V_TN_S_12 – utrčavanje visokog igrača prema sredini (*flash to the middle*), V_TN_S_13 – leđni blok na igrača s loptom (*backscreen*), V_TN_S_14 – visoki igrač postavljanjem

između obrambenog igrača i napadača s loptom pomaže prijenosu lopte (*big guy helps*).

Slika 7.55. Zastupljenost načina napada na presing

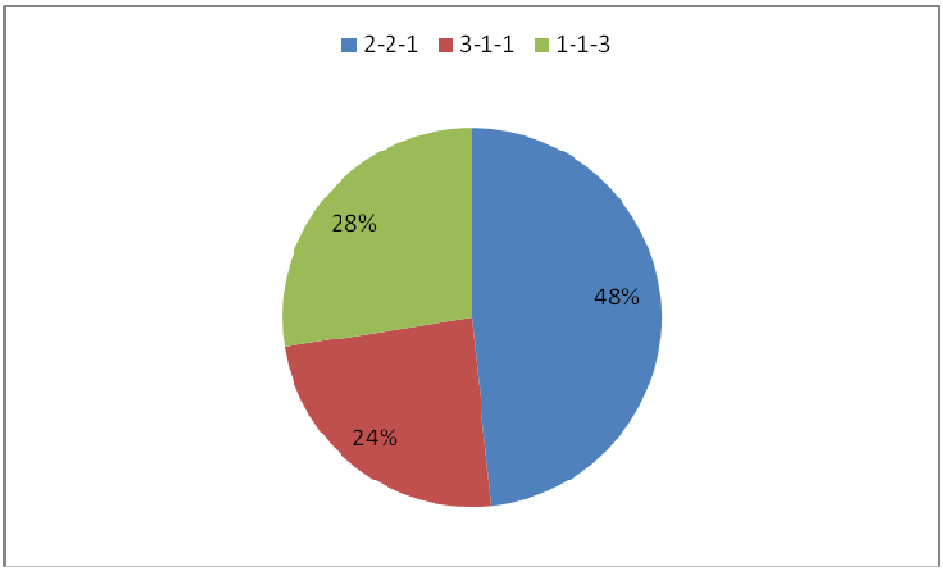


Na slici 7.55. očigledno je da je najzastupljenija taktička kombinatorika napada protiv presing obrane usmjerena na postavljanje beka jedan korak iznad linije lopte (*safety* 48%), na primjenu leđnog bloka na igraču s loptom (*backscreen* 16%) te na utrčavanje visokog igrača prema lopti (*flash* 15%). Također je očita niska frekvencija nekontroliranog driblinga (uz bočnu liniju). U sustavu napada protiv presinga obrane preferira se prijenos lopte dodavanjem ili kontroliranim driblingom u organizaciji nadigravanja presing obrane.

7.1.3.5. Napadački skakački raspored u tranzicijskom napadu

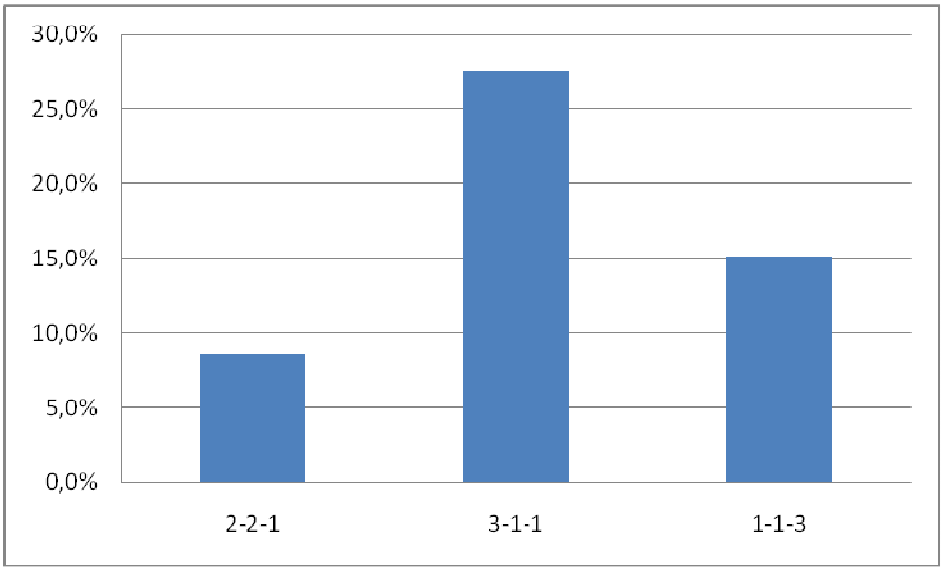
Napadački skakački raspored u tranzicijskom napadu opisan je varijablama V_TN_Z_39 (*2-2-1*), V_TN_Z_40 (*3-1-1*), V_TN_Z_41 (*4-0-1*), V_TN_Z_42 (*3-0-2*), V_TN_Z_43 (*2-1-2*), V_TN_Z_44 (*1-1-3*), V_TN_Z_45 (*0*), a zastupljenost je dana slikom 7.56.

Slika 7.56. Zastupljenost pojedinih napadačkih skakačkih rasporeda u tranziciji



Na slici 7.57. prikazana je zastupljenost napadačkog skakačkog rasporeda 2-2-1, 3-1-1 i 1-1-3. Vidljivo je kako nisu korišteni u navedenom uzorku utakmica napadački skakački plan 4-0-1, 3-0-2, 2-1-2, 1-1-3 i 0. Uočljiv je manji varijabilitet skakačkih napadačkih rasporeda u tranzicijskom napadu u odnosu na pozicijske (izostanak skakačkog rasporeda 4-0-1). Distribucija ostalih skakačkih napadačkih rasporeda je slična kao kod pozicijskog napada.

Slika 7.57. Uspješnost pojedinih napadačkih skakačkih rasporeda u tranziciji:



Na slici 7.57. uočljiva je najveća uspješnost rasporeda sa sudjelovanjem 3 igrača u organizaciji skoka u napadu.

Opća uspješnost napadačkog skoka u tranziciji napada je 15%, što je 2 puta manje nego u pozicijskom napadu pa stoga možemo reći da je razina uspješnosti napadačkog skoka u tranziciji nezadovoljavajuća zato što je manja gustoća u tranziciji obrane, a veća mogućnost radijusa kretanja u tranziciji napada te u pokrivanju skoka u napadu.

7.1.4. Analiza matrice prijelaznih vjerojatnosti Markovljevog lanca

Temeljem prethodno postavljenih ciljeva istraživanja, u kontekstu postavljenog općeg modela, oblikovane su hipoteze od kojih se prva skupina odnosi na diskriminaciju uspješnih od neuspješnih napadačkih taktičkih djelovanja. U skladu s time je postavljena hipoteza H1 egzistencije podskupa skupa svih stanja napada (tranzicije i pozicije) takvog da je statistički značajno veća vjerojatnost prelaska iz bilo kojeg njegovog stanja u neko stanje s uspješnim ishodom, nego vjerojatnost prijelaza bilo kojeg stanja ostalih elemenata skupa svih stanja napada u neko stanje s uspješnim ishodom.

Formalno, u kontekstu prikazane numeracije stanja, hipoteza navodi da ako s A označimo skup koji se sastoji od svih stanja tranzicije napada ili pozicijskog napada odnosno $A=\{n_1+n_2+1,...,n_1+n_2+n_3+n_4\}$, s D označimo skup koji se sastoji od stanja s uspješnim ishodom $D=\{n_1+n_2+n_3+n_4+n_5+1,...,n_1+n_2+n_3+n_4+n_5+n_6\}$, tada je moguće skup A particionirati u dva disjunktna podskupa, B i C ($A=B\cup C, B\cap C=\phi$), tako da

za svako stanje $l\in B$ i za svako stanje $m\in C$ vrijedi

$$\sum_{k\in D} p_{l,k} >> \sum_{k\in D} p_{m,k}$$

Pritom u hipotezi nije ekspliciran broj koraka unutar Markovljevog lanca za koju se vjerojatnost računa i stoga je u softveru *State Analyzer* implementiran modul koji je operativan za bilo koji broj koraka (*k*). Konstrukcijom algoritma koji računa prijelazne vjerojatnosti, sumira ih kako je zapisano u gornjoj formuli pa uspoređuje dane vjerojatnosti, dobiveno je da je u bilo kojem

koraku nemoguće napraviti danu particiju. Potrebno je naglasiti da je u softwareu isprogramirano rješenje za općenitiji problem, razlika vjerojatnosti može biti veća od nekog broja, ne samo od 0. Zbog obimnosti ispisa danih vjerojatnosti one su eksplicirane za k=3 u dodatku disertacije. Uvidom u rezultate možemo uočiti da je problem u statističkoj značajnosti razlika danih proporcija – mnoge vjerojatnosti su statistički jednake.

Ovdje ćemo navesti pseudo-kod algoritma korištenog u softwareu kojim je provjerena egzistencija tražene particije skupa stanja:

1. Učitaj broj koraka *k*
2. Izračunaj frekvencije prijelaza iz stanja u stanje
3. Izračunaj matricu prijelaznih vjerojatnosti
4. Izračunaj *k*-tu potenciju matrice prijelaznih vjerojatnosti
5. Za svako pojedino stanje izračunaj sumu svih vjerojatnosti u stanja uspjeha (vjerojatnost prijelaza u uspjeh u *k* koraka)
6. Sortiraj sva stanja uzlazno po vjerojatnosti prijelaza u stanje uspješnosti
7. Ponavljaj korake 7.1 i 7.2 : stavi separirajuću liniju na mjesto *k*
   7.1. Uzmi pojedino stanje ispod linije
   7.2. Provjeri je li statistički značajno manja vjerojatnost prijelaza u stanje uspjeha tog stanja i svih stanja iznad linije (ako nije uzmi novu separirajuću liniju, ako je, uzmi novo stanje)
8. Ako je moguće postaviti liniju (particija postoji) ispiši stanja grupa A i B, pripadne vjerojatnosti.

Druga hipoteza odnosila se na potvrđivanje dominantno kontroliranog modela igre u sadašnjoj europskoj košarci, odnosno tvrdilo se da je vjerojatnost prijelaza iz bilo kojeg stanja prve grupe u bilo koje stanje druge grupe stanja statistički značajno manja od 0.15, odnosno vjerojatnost gubljenja lopte iz bilo kojeg stanja napada (n_3 i n_4) statistički manja od 0.15, odnosno da su blok-elementi matrica prijelaznih vjerojatnosti $P_{i,5}$ *za* $i=3,4$ statistički značajno manji od 0.15. Provjerom matričnih elemenata potvrđuje se da navedeni rezultati vrijede.

Također je postavljena hipoteza da je vjerojatnost prijelaza iz pojedinog stanja tranzicijskog napada u bilo koje stanje pozicijskog napada statistički značajno veća od 0.85.

Formalno, ako uzmemo stanje $i \in \{n_1+n_2+1,...,n_1+n_2+n_3\}$ te stanje $j \in \{n_1+n_2+n_3+1,...,n_1+n_2+n_3+n_4\}$ vrijedi

$$\sum_j p_{i,j} \geq 0.85$$

Uvidom u rezultate vidi se da hipoteza **ne vrijedi** jer je vjerojatnost manja od 0.85.

Treća skupina hipoteza odnosila se na doprinose analizi standardnih pokazatelja situacijske učinkovitosti. Preciznije, statistički značajno je veća vjerojatnost prijelaza iz faze latencije u pojedino stanje tranzicije obrane nego u novo stanje pozicijskog napada. Formalno, ako je $j \in \{n_1+1,...,n_1+n_2\}$ i $k \in \{n_1+n_2+n_3+1,...,n_1+n_2+n_3+n_4\}$, statistički značajno vrijedi

$$\sum_j p_{7,j} \geq \sum_k p_{7,k}$$

Provjerom prijelaznih vjerojatnosti pokazuje se da tvrdnja vrijedi.

Također se tvrdilo da je unutar tranzicije napada odnosno pozicijskog napada vjerojatnost prijelaza iz inicijalne faze u završnu fazu statistički značajno manja od 5%. Formalno, ako pojedina faza napada (tranzicija ili pozicija) ima I_i inicijalnih stanja, M_i središnjih stanja i F_i finalnih stanja pri čemu je $I_i + M_i + F_i = n_i$ $i=3,4$ tada za svako inicijalno stanje l i finalno stanje m vrijedi:

$$\sum_m p_{l,m} \leq 0.05$$

Uvidom u rezultate dane softverom može se vidjeti da tvrdnja vrijedi, što je objašnjivo dominacijom kontroliranog stila igre u napadu i obrani.

7.1.5. Deskriptivna i distribucijska analiza uzorka

U svrhu daljnjih razmatranja definirane su, a korištenjem software-a State Analyzer oblikovane sljedeće nestandardne napadačke situacijske varijable:

1. NAPUK – ukupan broj napada
2. NAPUS – broj napada koji su završili uspješnim ishodom
3. PNUK – ukupan broj pozicijskih napada
4. PNUS – broj pozicijskih napada koji su završili uspješnim ishodom
5. TNUK – ukupan broj napada koji su započeli i imali neki ishod u tranzicijskom stanju napada
6. TNUS –broj napada koji su završili uspješnim ishodom u tranzicijskom stanju
7. NPICKUK – ukupan broj *pick and roll*, *pick and pop* i *handoff* manevara u pozicijskom napadu
8. NPICKUS – broj *pick and roll*, *pick and pop* i *handoff* manevara koji su završili uspješnim ishodom u pozicijskom napadu
9. NLPUK – ukupan broj prijema lopte na *low post*-u u pozicijskom napadu
10. NLPUS –broj prijema lopte na *low post*-u koji su završili uspješnim ishodom u pozicijskom napadu
11. NISOUK – ukupan broj izolacija na perimetru u pozicijskom napadu
12. NISOUS –broj izolacija na perimetru koje su završile uspješnim ishodom u pozicijskom napadu
13. NBLUK – ukupan broj blokova na igračima bez lopte u pozicijskom napadu
14. NBLUS –broj blokova na igračima bez lopte koji su završili uspješnim ishodom u pozicijskom napadu

15. NPRODUK – ukupan broj prodora s loptom u pozicijskom napadu
16. NPRODUS –broj prodora s loptom koji su završili uspješnim ishodom u pozicijskom napadu
17. NUTRUK – ukupan broj utrčavanja s perimetra te ubacivanja visokih igrača u srce trapeza u pozicijskom napadu
18. NUTRUS – broj utrčavanja s perimetra te ubacivanja visokih igrača u srce trapeza u pozicijskom napadu koji su završili uspješnim ishodom

Izvršena je deskriptivna analiza generiranih situacijskih varijabli.

Tablica 7.2. Osnovni parametri deskriptivne statistike za **pobjedničke ekipe**: aritmetička sredina (AS), minimalna (Min) i maksimalna vrijednost rezultata (Max), standardna devijacija (SD), koeficijent varijabilnosti (CV), zakrivljenost (α_3), spljoštenost (α_4) te empirijski nivo signifikantnosti pri testiranju normaliteta Kolmogorov Smirnovljevim testom.

	AS	Min	Max	SD	CV	α3	α4	KS
NAPUK	51,96	44,00	59,00	4,11	7,91	-0,00	-0,67	>0,2
NAPUS	29,67	22,00	39,00	4,15	13,97	-0,02	-0,11	>0,2
PNUK	15,54	9,00	28,00	5,69	36,64	0,98	0,02	>0,2
PNUS	9,08	3,00	17,00	4,11	45,21	0,73	-0,35	>0,2
TNUK	24,33	13,00	36,00	6,14	25,24	0,06	-0,60	>0,2
TNUS	13,25	6,00	24,00	4,87	36,72	0,65	-0,46	>0,2
NPICKUK	4,33	1,00	11,00	2,53	58,41	0,91	0,61	>0,2
NPICKUS	2,46	0,00	5,00	1,69	68,89	-0,04	-1,25	>0,2
NLPUK	7,83	0,00	15,00	3,90	49,75	-0,19	-0,59	>0,2
NLPUS	5,00	0,00	10,00	2,84	56,88	-0,22	-0,83	>0,2

NISOUK	3,79	1,00	10,00	2,90	76,59	0,96	-0,39	<0,05
NISOUS	1,33	0,00	5,00	1,52	114,21	0,83	-0,31	>0,1
NBLUK	22,17	12,00	33,00	5,43	24,48	0,06	-0,58	>0,2
NBLUS	12,54	4,00	22,00	4,30	34,31	0,00	-0,24	>0,2
NPRODUK	10,54	6,00	20,00	3,64	34,49	0,99	0,47	>0,2
NPRODUS	7,25	3,00	16,00	3,04	41,93	1,23	1,72	>0,2
NUTRUK	21,48	7,00	46,00	8,37	38,95	0,78	2,21	>0,2
NUTRUS	15,65	3,00	29,00	6,71	42,88	0,09	-0,53	>0,2

U tablici 7.2. dat je prikaz deskriptivnih statističkih pokazatelja izvedenih varijabli za uzorak uspješnih timova. Pritom možemo uočiti da su sve varijable normalno distribuirane osim varijable NISOUK kod koje je uočeno blago odstupanje od normalne distribucije. Nadalje, kod varijabli PNUK, NPICKUK, NISOUK, NPRODUK i NPRODUS uočena je nešto veća pozitivna vrijednost koeficijenta zakrivljenosti, dok je kod varijable NUTRUK prisutna blago izraženija vrijednost koeficijenta spljoštenosti.

Tablica 7.3. Osnovni parametri deskriptivne statistike za **poražene ekipe**: aritmetička sredina (AS), minimalna (Min) i maksimalna vrijednost rezultata (Max), standardna devijacija (SD), koeficijent varijabilnosti (CV), zakrivljenost (α_3), spljoštenost (α_3) te empirijski nivo signifikantnosti pri testiranju normaliteta Kolmogorov Smirnovljevim testom.

	AS	**Min**	**Max**	**SD**	**CV**	**α_3**	**α_4**	**KS**
NAPUK	53,54	42,00	61,00	4,93	9,22	-0,62	-0,09	>0,2
NAPUS	27,75	18,00	37,00	4,60	16,57	-0,08	-0,33	>0,2
PNUK	15,04	7,00	29,00	5,84	38,84	0,56	-0,30	>0,2

PNUS	7,96	2,00	15,00	3,68	46,20	-0,05	-0,50	>0,2
TNUK	25,17	15,00	37,00	6,51	25,88	0,52	-0,68	>0,2
TNUS	13,25	7,00	25,00	4,65	35,07	0,89	0,29	>0,2
NPICKUK	6,08	1,00	15,00	3,93	64,66	0,62	-0,63	>0,2
NPICKUS	3,21	0,00	12,00	2,92	90,98	1,58	2,58	>0,2
NLPUK	8,54	1,00	19,00	4,14	48,45	0,44	0,61	>0,2
NLPUS	4,33	0,00	12,00	2,94	67,94	0,60	0,69	<0,1
NISOUK	4,71	1,00	14,00	3,18	67,59	1,05	1,55	>0,2
NISOUS	1,79	0,00	6,00	1,72	95,94	0,86	0,11	>0,2
NBLUK	22,63	16,00	33,00	3,66	16,16	0,90	1,92	>0,2
NBLUS	11,83	7,00	17,00	2,65	22,38	0,06	-0,66	>0,2
NPRODUK	10,96	4,00	16,00	3,28	29,90	0,02	-0,48	>0,2
NPRODUS	6,71	2,00	11,00	2,53	37,68	-0,05	-0,79	>0,2
NUTRUK	22,13	9,00	38,00	7,24	32,71	0,47	-0,03	>0,2
NUTRUS	16,00	8,00	30,00	5,49	34,34	1,06	0,88	>0,2

U tablici 7.3 dat je prikaz deskriptivnih statističkih pokazatelja izvedenih varijabli za uzorak poraženih timova. Pritom možemo uočiti da su sve varijable normalno distribuirane osim varijable NLPUS kod koje je uočeno blago odstupanje od normalne distribucije. Nadalje, kod varijabli TNUS, NPICKUK, NISOUK, NUTRUS uočena je nešto veća pozitivna vrijednost koeficijenta zakrivljenosti, dok je kod varijale NBLUK i NUTRUS prisutna blago izraženija vrijednost koeficijenta spljoštenosti.

U tablici 7.4 prikazani su rezultati t-testa .

Tablica 7.4. t-test za pobjedničke i poražene ekipe: Aritmetička sredina poraženih ekipa (AS-0), aritmetička sredina pobjedničkih ekipa (AS-1), vrijednost t testa (t), značajnost razlika između varijanci (p var).

	AS-0	AS-1	T	p	p var
NAPUK	68.46	67.50	0.79	0.43	0.83
NAPUS	37.04	39.29	-1.58	0.12	0.72
KVN	0.54	0.58	-2.17	0.04	0.81
PNUK	53.54	51.96	1.21	0.23	0.39
PNUS	27.75	29.67	-1.52	0.14	0.62
KVPN	0.52	0.57	-2.24	0.03	0.17
TNUK	15.04	15.54	-0.30	0.77	0.90
TNUS	7.96	9.08	-1.00	0.32	0.60
KVTN	0.51	0.58	-1.67	0.10	0.77
NPICKUK	25.17	24.33	0.46	0.65	0.78
NPICKUS	13.25	13.25	0.00	1.00	0.83
KVNPICK	0.53	0.54	-0.45	0.65	0.77
NLPUK	6.08	4.33	1.83	0.07	0.04
NLPUS	3.21	2.46	1.09	0.28	0.01
KVNLP	0.49	0.54	-0.63	0.53	0.48
NISOUK	4.71	3.79	1.04	0.30	0.66
NISOUS	1.79	1.33	0.98	0.33	0.57
KVNISO	0.30	0.27	0.50	0.62	0.68
NBLUK	8.54	7.83	0.61	0.54	0.78

NBLUS	4.33	5.00	-0.80	0.43	0.87
KVNBL	0.45	0.61	-2.51	0.02	0.44
NPRODUK	22.63	22.17	0.34	0.73	0.06
NPRODUS	11.83	12.54	-0.69	0.50	0.02
KVNPROD	0.53	0.55	-0.62	0.54	0.05
NUTRUK	10.96	10.54	0.42	0.68	0.62
NUTRUS	6.71	7.25	-0.67	0.51	0.38
KVNUTR	0.61	0.69	-1.97	0.05	0.62

Vidljivo je da, na razini značajnosti 0,05, varijable relativne uspješnosti napada (KVN), relativne uspješnosti pozicijskog napada (KVPN), relativne uspješnosti blokova na igračima bez lopte (KVNBL) i relativne uspješnosti utrčavanja (KVNUTR) razlikuju pobjedničke ekipe od poraženih. Nadalje, može se uočiti da u varijablama NLPUS i NISOUS postoji neravnoteža u rezultatima napadačke uspješnosti i sportskog postignuća, odnosno rezultati pokazuju da poražene ekipe imaju veće srednje vrijednosti uspješnih napadačkih varijabli. To je vjerojatno posljedica činjenice da ukupno gledajući, u elitnoj evropskoj košarci ne postoji potpuna ravnoteža u uspješnostima faza obrane i napada.

7.1.6. Latentna struktura prostora uspješnih nestandardnih situacijskih varijabli

U narednim razmatranjima pokušat ćemo objasniti latentnu strukturu prostora napadačkih nestandardnih uspješnih situacijskih varijabli. Analizirat ćemo interkorelacije varijabli NPICKUS, NLPUS, NBLUS, NISOUS, NPRODUS i NUTRUS.

Eksplorativnom strategijom faktorske analize obuhvaćena je deskripcija interkorelacija navedenih varijabli u terminima manjeg broja faktora, odnosno hipotetičkih, latentnih varijabli.

Ekstrahirane su 2 latentne dimenzije koje iscrpljuju 50,8% varijabiliteta manifestnog prostora. Od toga prva latentna dimenzija objašnjava 30,2% a druga 20,6% varijance (Tablica 7.5).

Tablica 7.5. Svojstvene vrijednosti matrice korelacija (λ), postotci doprinosa svake svojstvene vrijednosti ukupnoj količini objašnjene varijance (λ%) i kumulativni postotci doprinosa svake svojstvene vrijednosti ukupnoj količini objašnjene varijance (kum%).

Faktor	λ	λ%	kum%
1.	1,81	30,2%	30,2
2.	1,23	20,6%	50,8

U tablici 7.6 dani su pokazani odnosi između pojedinih varijabli i faktora dobivenih korištenjem *varimax normalized* rotacije.

Tablica 7.6. Matrica paralelnih projekcija manifestnih varijabli i komunaliteti manifestnih varijabli (SMC)

	F1	F2	SMC
NPICKUS	**0,86**	-0,04	0,42
NLPUS	0,08	**0,58**	0,07
NBLUS	-0,18	**0,80**	0,11
NISOUS	**0,56**	0,10	0,17
NPRODUS	**0,62**	-0,22	0,17
NUTRUS	**0,57**	**0,44**	0,24

Prvu hipotetičku latentnu dimenziju određuju NPICKUS, NPRODUS, NUTRUS i NISOUS. To je logično budući da *pick and roll*, *pop* i *handoff* manevri uzrokuju različite sustave pomaganja u

obrani i rotaciju te su najčešći napadački završeci (osim vanjskog šuta) prodor nakon protoka lopte s vanjskih pozicija, *roll* visokog igrača nakon bloka na lopti te izolacije na perimetru u situaciji obrambenog preuzimanja. Stoga ovaj faktor možemo imenovati faktor tehničko-taktičke aktivnosti bloka na loptu.

Drugu latentnu dimenziju određuju varijable NBLUS, NLPUS i NUTRUS. To je stoga što se značajan dio blokova na igrača s loptom odnosi na postavljanje blokova visokim igračima u funkciji *post up* igre ili igre leđima košu. Također leđni blokovi za vanjske i unutarnje igrače kreiraju utrčavanja u *post* - prostor s visokim postotkom realizacije. U skladu s tim drugi faktor možemo imenovati faktor tehničko - taktičke aktivnosti blok - igre na igračima bez lopte.

Važno je naglasiti da je postavljanje blokova na loptu i igrače bez lopte jedan od najvažnijih taktičkih aspekata koji kreira otvoren šut ili *mismatch* situacije. Također, ekspertni treneri navode da postavljanje uspješnih blokova (pravovremenost u postavljanju bloka te postavljanje bloka pod kutom najtežim za obrambenog igrača) unapređuje egzekuciju ili realizaciju (Trninić, 2006.). Vjerojatno u europskoj košarci postavljanje bloka upravo zbog proaktivne obrane nije nikad prije imalo veći značaj.

Evidentno je da dvije izolirane latentne dimenzije ne oslikavaju cjelokupnu igru u fazi napada. U skladu s tim, pretpostavlja se kako utvrđivanje latentnog prostora nije dostatno, s obzirom na činjenicu da je ekstrakcijom dviju latentnih dimenzija ostalo 49,2% neprotumačenog varijabiliteta manifestnog prostora. Kompleksna dinamika napada u košarkaškoj igri, između ostalog, generirana učincima čestih perturbacija je vjerojatno znatno više determinirana recipročnim i nelinearnim modelima i vezama koje metodologija faktorske analize ne obuhvaća. Vjerojatno bi tehnike nelinearne faktorske analize bile prikladan metodološki alat kojim bi se reducirao neprotumačeni varijablitet manifestnog prostora, odnosno u potpunosti ekstrahirali traženi uzročnici varijabiliteta napada u košarkaškoj igri.

Ekstrahirana latentna struktura dodatno ukazuje na činjenicu da definirane nestandardne situacijske varijable u fazi napada prikladno opisuju analizirani prostor. Isto tako uvidom u apsolutnu vrijednost matrice korelacija promatranih varijabli (Tablica 7.7.) možemo zaključiti da su korelacije po apsolutnom iznosu premale da bi formirale više od dvije dimenzije. To potvrđuje činjenica da promatranjem komunaliteta manifestnih varijabli (Tablica 7.6.) možemo uočiti da dva ekstrahirana faktora prosječno objašnjavaju približno 20% variabliteta pojedine nanifestne

varijable, dok prva dimenzija sama objašnjava 30% varijabiliteta cjelokupnog manifestnog prostora. Odnosno, očito je da čak dolazi do prefaktorizacije. Vjerojatno je da je druga ekstrahirana dimenzija dimenzionalno nestabilna - dodavanjem nove varijable u manifestni prostor bi se vjerojatno „raspala“ ili zbog bitno promijenjenih paralelnih projekcija nužno bila drugačije interpretirana.

7.1.7. Analiza povezanosti nekih nestandardnih situacijskih varijabli napada

U konačnici nužno je analizirati povezanost između kriterija i prediktora. Stoga je nužno promotriti različite razine povezanosti među definiranim nestandardnim situacijskim varijablama napada. Pritom je analiza usmjerena na povezanost uspješnosti pozicijskog napada (PNUS) sa skupom varijabli NPICKUS, NLPUS, NISOUS, NBLUS, NPRODUS i NUTRUS te sa skupom analognih varijabli relativne uspješnosti definiranih kvocijentom između uspješnih i ukupnih varijabli. U skladu s time, potrebno je pogledati matricu Pearsonovih koeficijenata korelacija navedenih varijabli (Tablica 7.7.).

Tablica 7.7. : Koeficijenti korelacija između uspješnih nestandardnih situacijskih varijabli napada.

	PNUS	NPICKUS	NLPUS	NISOUS	NBLUS	NPRODUS	NUTRUS
PNUS							
NPICKUS	**0.49**						
NLPUS	**0.34**	0.13					
NISOUS	**0.35**	**0.33**	0.05				
NBLUS	0.28	-0.21	0.14	0.00			
NPRODUS	**0.45**	**0.39**	-0.06	0.14	-0.06		
NUTRUS	**0.44**	**0.40**	0.03	0.15	0.18	0.13	

Boldani koeficijenti korelacije su statistički značajni, $p<0,05$

Uvidom u matricu korelacija (Tablica 7.7.) uočavamo da je kriterijska varijabla PNUS statistički značajno povezana s prediktorskim varijablama NPICKUS, NLPUS, NISOUS, NPRODUS te NUTRUS. Također vidimo da je varijabla NPICKUS statistički značajno povezana savarijablama NISOUS, NPRODUS i NUTRUS. To je logično s aspekta košarkaške igre jer nakon *pick* ili *handoff* manevra slijedi manevar utrčavanja prema košu (*roll*), manevar prodora s loptom ili manevar izolacija u slučaju obrambenog preuzimanja.

Isto tako preostale varijable nisu statistički značajno korelirane i mali iznosi koeficijenata korelacija sugeriraju separiraciju originalnog kontinuuma varijabli na dva relativno neovisna podskupa: NPICKUS i NBLUS s jedne strane, te NLPUS, NISOUS, NPRODUS i NUTRUS s druge strane. Pritom se nužno usmjeriti na linearnu povezanost kriterijske varijable uspješnog pozicijskog napada (PNUS) s prediktorskim varijablama uspješnog *pick and roll*-a, *pick and pop*-a i *handoff*-a (NPICKUS) te uspješnog bloka na igračima bez lopte (NBLUS).

Tablica 7.8.: Rezultati višestruke regresijske analize - predikcija varijable PNUS korištenjem varijabli NPICKUS i NBLUS s isključenim *interceptom*. (R – koeficijent multiple korelacije, R^2-koeficijent determinacije, β – beta ponderi prediktorskih varijabli, Se(β)- standardna greška beta pondera, b – b ponderi prediktorskih varijabli, Se(b) - standardna greška b pondera, p-razina signifikantnosti koeficijenta)

	β	Se(β)	b	Se(b)	p
NPICKUS	0,72	0,05	1,48	0,10	0,00
NBLUS	0,31	0,05	1,66	0,26	0,00
R	0,98				
R^2	0,96				
p	0,0000				

Vidljivo je iz tablice 7.8. da postoji značajna statistička linearna povezanost između kriterijske varijable PNUS te prediktorskih varijabli NPICKUS i NBLUS. Koeficijent multiple korelacije je 0,98. Iz pondera b je vidljivo da je utjecaj prediktorske varijable NBLUS neznatno veći od NPICKUS, no iz pondera beta je jasno da je opći utjecaj prediktorske varijable NPICKUS na

varijablu PNUS znatno veći iz razloga dominantne zastupljenosti *pick* napadačkih manevara u odnosu na postavljanje blokova na igračima bez lopte.

Tablica 7.9.: Rezultati višestruke regresijske analize - predikcija varijable KVPN korištenjem varijabli KVNPICK i KVNBLUS s isključenim *interceptom*. (R – koeficijent multiple korelacije, R^2-koeficijent determinacije, β – beta ponderi prediktorskih varijabli, Se(β)- standardna greška beta pondera, b – b ponderi prediktorskih varijabli, Se(b) - standardna greška b pondera, p-razina signifikantnosti koeficijenta)

	B	Se(β)	b	Se(b)	p
KVNPICK	0,85	0,05	0,86	0,05	0,00
KVNBL	0,16	0,05	0,15	0,05	0,00
R	0,99				
R^2	0,98				
p	0,0000				

Iz tablice 7.9. je vidljivo da je i na razini kvocijenata povezanost vrlo snažna R=0,99 s vrlo visokim koeficijentom determinacije (0,98). Utjecaj varijable KVNPICK je znatno veći (b=0,85) nego varijable KVNBL (b=0,16).

Nadalje, nužno je promotriti utjecaj prediktorskih varijabli NLPUS, NISOUS, NPRODUS i NUTRUS na kriterijsku varijablu uspješnost pozicijskog napada.

Tablica 7.10.: Rezultati višestruke regresijske analize - predikcija varijable PNUS korištenjem varijabli NLPUS, NISOUS, NPRODUS i NUTRUS s isključenim *interceptom*. (R – koeficijent multiple korelacije, R^2-koeficijent determinacije, β – beta ponderi prediktorskih varijabli, Se(β)- standardna greška beta pondera, b – b ponderi prediktorskih varijabli, Se(b) - standardna greška b pondera, p-razina signifikantnosti koeficijenta)

	β	Se(β)	b	Se(b)	p
NPRODUS	0,55	0,06	1,27	0,14	0,00
NUTRUS	0,30	0,06	1,18	0,23	0,00

NLPUS	0,14	0,04	1,11	0,29	0,00
NISOUS	0,05	0,04	0,69	0,45	0,14
R	0,99				
R^2	0,97				
p	0,0000				

Model je vrlo prikladan obzirom na činjenicu da je R=0,99 i R^2=0,97 te da je sam model statistički pouzdan (Tablica 7.10.). Iz b podera je vidljivo da je utjecaj varijable NPRODUS na PNUS najveći (b=1,27). Zatim slijedi NUTRUS (b=1,18), NLPUS (1,11) dok je utjecaj NISOUS najmanji (b=0,69) a ujedno i statistički nepouzdan. Naglasimo da nema razlike u modelu ako se primijeni forward algoritam selekcije varijabli u model.

Napravimo li analogno razmatranje na razini kvocijenata dobit ćemo slične rezultate.

Tablica 7.11: Rezultati višestruke regresijske analize - predikcija varijable KVPN korištenjem varijabli KVNLP, KVNISO, KVNPROD i KVNUTRUS korištenjem *forward* algoritma uključivanja varijabli u model, sa isključenim *interceptom*. (R – koeficijent multiple korelacije, R^2-koeficijent determinacije, β – beta ponderi prediktorskih varijabli, Se(β)- standardna greška beta pondera, b – b ponderi prediktorskih varijabli, Se(b) - standardna greška b pondera, p-razina signifikantnosti koeficijenta)

	β	Se(β)	b	Se(b)	p
KVNPROD	0,55	0,07	0,55	0,07	0,00
KVNUTR	0,33	0,07	0,27	0,06	0,00
KVNLP	0,14	0,04	0,13	0,03	0,00
R	0,99				
R2	0,99				
p	0,0000				

Iz tablice 7.11. vidljivo je da je i na razini kvocijenata model prikladan (R=0,99, R^2=0,99). Forward algoritmom eliminirana je varijabla KVNISO. Varijabla KVNPROD ima najveći utjecaj (b=0,55) zatim slijedi KVNUTR (0,27) i KVNLP (0,13).

7.1.8. Analiza razlika između napadački uspješnih i neuspješnih momčadi u prostoru nestandardnih situacijskih varijabli

Razmotrimo sada separirano dva podprostora napadačkih situacijskih varijabli te kako one razlikuju napadački uspješne od neuspješnih momčadi. Varijable koje su uzete u diskriminacijski model u prvom skupu su NISOUS, NISONE, NBLUS, NBLNE, NPRODUS, NPRODNE, NUTRUS, NUTRNE. U drugom skupu su obuhvaćene varijable NPICKUS, NPICKNE, NLPUS, NLPNE. Pritom je kriterij razlikovanja napadački uspješnih od neuspješnih momčadi bio kvocijent broja uspješnih i ukupnog pozicijskih napada iznosa 0,555. Navedeni podatak je u skladu s košarkaškom ekspertnom znanstvenom i stručnom praksom gdje se uzima kao granična diskriminirajuća vrijednost od 56% uspješnosti. U skladu s tim, 24 utakmice, odnosno 48 momčadi je kvocijentom od 0,555 kao rubnim podijeljeno na 24 momčadi s uspješnim pozicijskim napadom i 24 momčadi s neuspješnim pozicijskim napadom.

Tablica 7.12. Svojstvena vrijednost (λ), Wilksova lambda (W λ), kanonička korelacija (Rc), vrijednost hi-kvadrat testa (χ^2), broj stupnjeva slobode (df) i razina značajnosti diskriminacijske funkcije (p), postotak uspješne reklasifikacije entiteta temeljem diskriminacijske funkcije (ReClass%).

λ	W λ	Rc	χ^2	df	p	ReClas%
0,68	0,60	0,64	22,55	5	0,00	81,3%

Iz tablice 7.12. možemo uočiti da je model 100% pouzdan pri čemu je kanonička korelacija 0,64, a Wilksova lambda 0,60. Nadalje, diskriminacijska funkcija klasificira ispravno 81,3% utakmica. Naglasimo da je korišten *forward* algoritam selekcije varijabli u diskriminacijski model, pri čemu

su varijable (NISOUS, NISONE, NUTRNE) isključene iz modela zbog neznačajnog doprinosa diskriminacijskoj funkciji.

Tablica 7.13: Projekcije varijabli i centroida na diskriminacijsku funkciju korištenjem forward algoritma te značajnost diskriminacijskih koeficijenata

Varijabla	**DF1**	**p**
NPRODNE	-0,65	0,01
NUTRUS	0,51	0,05
NPRODUS	0,40	0,03
NLPUS	0,24	0,10
NLPNE	-0,09	0,18
Grupa	**DF1**	
G1_0	-0,81	
G1_1	0,81	

Iz tablice 7.13 vidljivo je da uspješni pozicijski napad obilježavaju uspješna utrčavanja (0,51), uspješni prodori s loptom s vanjskog prostora (0,40) te uspješna igra na niskom postu (0,24).

Nadalje, neuspješan pozicijski napad najviše obilježavaju neuspješni prodori s loptom s vanjskog prostora ili *perimetra* (-0,65).

Dakle, dobili smo da na „mikrorazini“ uspješni pozicijski napad najviše određuju prodori s loptom, utrčavanja te igra na niskom postu.

Tablica 7.14.: Svojstvena vrijednost (λ), Wilksova lambda (W λ), kanonička korelacija (Rc), vrijednost hi-kvadrat testa ($\aleph^2$), broj stupnjeva slobode (df) i razina značajnosti diskriminacijske funkcije (p), postotak uspješne reklasifikacije entiteta temeljem diskriminacijske funkcije (ReClass%).

λ	W λ	Rc	$\aleph^2$	Df	P	ReClas%
0,59	0,63	0,61	20,3	4	0,00	77,1%

Iz tablice 7.14. možemo uočiti da je model 100% pouzdan pri čemu je kanonička korelacija 0,61, a Wilksova lambda 0,63. Nadalje, diskriminacijska funkcija klasificira ispravno 77,1% utakmica. Naglasimo da je korišten *forward* algoritam selekcije varijabli u diskriminacijski model pri čemu su sve varijable uključene u model zbog značajnog doprinosa diskriminacijskoj funkciji.

Tablica 7.15.: Projekcije varijabli i centroida na diskriminacijsku funkciju korištenjem forward algoritma te značajnost diskriminacijskih koeficijenata

Varijabla	DF1	p
NPICKUS	-0,62	0,00
NPICKNE	0,40	0,05
NBLUS	-0,27	0,03
NBLNE	0,19	0,30
Grupa	**DF1**	
G1_0	0,75	
G1_1	-0,75	

Iz tablice 7.15. vidljivo je da uspješni pozicijski napad najviše obilježava uspješna *pick and roll*, *pick and pop* i *handoff* igra u napadu (-0,62), a nakon toga uspješni blokovi na igračima bez lopte (-0,27). S druge strane, neuspješan pozicijski napad obilježava neuspješan *pick and roll*, *pick and pop* i *handoff* (0,40) a potom neuspješni blokovi na igračima bez lopte (0,19). Dakle, uspješni pozicijski napad najviše određuju *pick* i *handoff* manevri u fazi napada.

7.2. Rasprava

7.2.1. Ograničenja istraživanja

Glavno ograničenje ovog istraživanja je činjenica da je košarkaška sezona 2009./2010. bila zadnja koja se igrala po do tadašnjim FIBA pravilima pa se dobiveni zaključci, iako pretpostavljamo da vrijede i dalje, moraju uzeti sa zadrškom, obzirom na postojanje novog skupa pravila.

Nadalje, uzorak od 24 utakmice, iako relativno velik, ne omogućava dostatan izvor podataka za svaki klub unutar Top 16 Eurolige s obzirom na to da se svaka ekipa u uzorku pojavila u dvije do 4 utakmice. Potrebno je naglasiti da je postupak mjerenja stanja napada košarkaške igre s trenutno dostupnom tehnologijom trajao 7 mjeseci. Pritom je *Synergy Software* korišten kao „pomoćni“ sustav sa arhiviranim svim potrebnim utakmicama. Postojanje usko specijaliziranog softvera koji bi integrirao module za evidenciju stanja igre te generirao prijelazne vjerojatnosti bitno bi pojednostavnilo i ubrzalo proces mjerenja. Tako bi se mogao obraditi relativno veći uzorak a samim time bi se dobili i detaljni zaključci o igri svakog pojedinog kluba.

Nadalje, potrebno je naglasiti da u kontekstu praktične primjene definiranih stanja igre kao i teorijske formulacije istog, promatranje interakcijskih odnosa između pojedinih faza tijeka, s obzirom na kompleksnost samog istraživanja u fazi napada, nije bilo predmet ovog istraživanja. Naime, u radnoj veziji doktorske disertacije dr.sc. Ante Perice koja je temeljena na istom uzorku utakmica kao i ova radnja, definirana su stanja košarkaške igre u fazi obrane te je neovisno o rezultatima u fazi napada izvšena detaljna analiza igre u fazi obrane. Rezultate suradnje i suprotstavljanja, korištenjem definiranjih stanja igre u obrani i napadu, bi bilo moguće napraviti samo korištenjem varijabli i mjerenja iz obe disertacije.

Također, nije primijenjena perturbacijska teorija koja implicira da mala narušenja ravnoteže sustava uzrokuju nelinearno, kaotično i kompleksno ponašanje sustava. To naročito stoga što bi se za implementaciju modela i metoda perturbacijske teorije nužno trebali validirati do sada u kineziološkoj znanosti još primjenjivani alati.

Nadalje, iako teoretski moguće, vremensko preklapanje pojedinih stanja se ekspertnom procjenom aproksimiralo uređenim sukcesivnim vremenskim slijedom, te se nije pokazalo kao problem pri provedbi mjerenja u ovoj radnjij.

7.2.2. Znanstveni i stručni značaj istraživanja

Znanstveni doprinos se očituje u oblikovanju novog metodološkog pristupa u polju kineziologije koji obuhvaća formalne matematičke modele, diskretne slučajne procese, Markovljeve lance na sustav košarkaške igre. Pritom korišteni funkcionalni pristup analizi stanja u košarkaškoj igri i prijelaznih vjerojatnosti Markovljevim lancima omogućava validaciju i verifikaciju sustava košarkaške igre.

Pristup oblikovanju modela uspješnosti u kompleksnim sportskim aktivnostima korištenjem Markovljevih lanaca integrira dinamički i interakcijski pristup koji kroz pojam „stanje igre“ implicitno uračunava utjecaj unutarnjih i vanjskih varijabli.

Analiza stanja i podstanja u tranziciji napada i pozicijskom napadu će omogućiti ekspertnim trenerima razumijevanje strukture tijeka igre, a time i pretpostavku za uspješnu pripremu i vođenje utakmice. Pritom će navedeno pridonijeti razvoju funkcionalne analize košarkaške igre, traženju sveza, uzroka i posljedica kao i izvođenja zaključaka na temelju raščlanjivanja cjelovitog sustava parametara koji čine košarkašku igru iz perspektive suradnje i suprotstavljanja. To će se eksplicitno očitovati na unaprjeđivanje izravnog izvidničkog izvješća timskih tendencija u tranziciji napada i pozicijskom napadu (engl. *scouting report*), implicitno na izvidničko izvješće individualnih tendencija igrača te na pripremu za vođenje utakmice. To je stoga što poznavanje vlastite i suparničke momčadi te prikaz profila igrača i momčadi određuju taktičku pripremu za utakmicu, odnosno razradu plana operativne taktike.

Pretpostavlja se da bi suradnja znanstvenika i ekspertnih trenera o problematici korištenja Markovljevih lanaca mogla generirati povratne informacije koje će omogućiti daljnji razvoj i upotrebu u praksi naprednih metodoloških alata (ekspertnih sustava, neuronskih mreža i kibernetičkih modela).

S obzirom da navedeni model diferencira stanja košarkaške igre tijekom utakmice, analiza prijelaznih vjerojatnosti omogućava predikciju budućih stanja unutar faza tijeka igre, kao i njihovu uspješnost. Također se može istraživati tijek promjena stanja igre, tj. zadržavanje i narušavanje ravnoteže igre, što vjerojatno može omogućiti detekciju faktora koji uvjetuju navedena stanja. Pritom bi analiza izračunatih vrijednosti vjerojatno bila značajan doprinos situacijskom pristupu istraživanju košarkaških zakonitosti i principa ravnoteže unutar kompleksnih sportskih aktivnosti.

7.2.3. Budući pravci istraživanja

Predloženi sustav diskretizacije kontinuiranog tijeka košarkaške igre na stanja te evaluacija uspješnosti ima mogućnost generalizacije na sve momčadske sportske igre. Nadalje, predloženi novi metodološki pristup analizi stanja košarkaške igre i prijelaznih vjerojatnosti Markovljevim lancima nije konačan, nego se treba shvatiti kao polazišna točka za empirijsku provjeru i daljnja istraživanja na temelju kojih će se model mijenjati i dorađivati. Kao što je i rečeno u prethodnom poglavlju, buduća istraživanja bi se morala fokusirati na promatranje interakcijskih odnosa između pojedinih faza tijeka igre. Također, rigorozna formalizacija te u skladu s tim evaluacija koncepta narušenja ravnoteže unutar pojedinih faza tijeka igre bi trebala biti prioritet budućih znanstvenih istraživanja košarkaške igre. To stoga što je narušena ravnoteža zapravo perturbacija dinamičkog sustava koja u pravilu uzrokuje njegovo nelinearno i kaotično ponašanje.

Sa stajališta teorije sportskih igara važno je nastaviti istraživanja stanja, tijeka i ravnoteže igre, kao dijelova sustava "košarkaška utakmica" i to u svrhu utvrđivanja povezanosti između kinematičkih parametara stanja igre pojedinih igrača, unutarnjeg stanja igrača i ravnoteže tijekom igre te oblikovanja matematičkog modela koji bi obuhvatio i te veze, analiziranja akcija u košarkaškoj igri i analiziranja pravila koja omogućavaju postizanje ravnoteže u pojedinim stanjima igre. Posebno dragocjene spoznaje dobile bi se istraživanjem dijelova sistema

"košarkaška utakmica": stanje, tijek i ravnoteža igre, a unutar njih ispitivanjem kinematičkih parametara stanja igre u vremenu *t*, unutarnjeg stanja igrača u vremenu *t*, parametre razvoja događanja do vremena *t* i prostorno-vremenska ograničenja, za što još postoje tehničko-tehnološka ograničenja.

Također bi trebalo istaknuti da bi buduće linije istraživanja u kineziološkoj znanosti nužno trebale tendirati prema konstrukciji, validaciji i aplikaciji suvremenih matematičkih mehanizama i metoda, naročito onih danih u uvodu ove doktorske disertacije.

8. ZAKLJUČAK

Važnost primjene matematičkih modela u društvenim i humanističkim znanostima je u tome što istovremeno otkrivaju nužne i dovoljne uvjete, a formuliraju ih u generalnoj formi, odnosno u apstraktnom obliku tako da mogu biti primijenjeni na više konkretnih različitih ciljeva. Također, apstraktni modeli moraju oslikavati stvarne procese koji su prisutni u društvenim i humanističkim znanostima. Matematički model obuhvaća čitav kontinuum konkretnih modela i na taj način njegovo postavljanje predstavlja neophodan prijelazni korak između općih hipoteza i posebnih hipoteza koje će se moći na temelju formalne analize postaviti i podvrgnuti eksperimentalnim provjerama.

Tako primjerice, sportaša, momčad kao i sportsku aktivnost nije moguće primjereno interpretirati jednosmjernim odnosima, a ni kao statičke pojave, već kao nelinearne dinamičke sustave koji u sebi imaju implementirane jednosmjerne i/ili dvosmjerne veze između pojedinih unutarnjih i vanjskih odrednica izvedbe i sportskog postignuća. Stoga je u sportskoj znanosti nužno korištenje primjerenih matematičkih i logičkih modela koji imaju izomorfnu vezu s modeliranim problemom, kako bi se proučavanje kineziološke stvarnosti svelo na akcije i transformacije samog modela.

U ovom radu je korištena metodologija diskretnih slučajnih procesa, Markovljevih lanaca kao modela za evaluaciju uspješnosti u kompleksnim sportskim aktivnostima. U skladu s navedenim, definiran je pojam stanja sustava sa stajališta teorije sportskih igara, a tijek košarkaške utakmice je diskretiziran - promatran je kao jedan karakterističan slijed stanja. Pritom je oblikovan apstraktni sustav košarkaške igre kao teoretski temelj za njegovo kasnije validiranje te provjeru njegovog djelovanja. Kroz taktičku segmentaciju košarkaške igre dan je metodološki predložak za korištenje Markovljevih lanaca u području istraživanja momčadskih sportskih igara.

Analizom dobivenih rezultata u prostoru napada izračunato je da je uzorak od 24 utakmice sastavljen od 3273 napadačke akcije. Opća uspješnost napadačkih akcija iznosi 51%. Pritom je udio pozicijskog napada u ukupnom broju napada 78% s uspješnošću 49,4%.

Taktička kombinatorika košarkaške igre u **središnjici** pozicijskog napada je opisana strukturom *pick and roll/pop* manevra, *handoff* manevra, igre na niskom postu, različitih vrsta blokova na igračima bez lopte te različitih utrčavanja (*cut* igra).

U prostoru *pick and roll/pop* manevara najzastupljeniji je *pick and roll/pop* na strani (35%), zatim *pick and roll/pop* na sredini (21%) te *pick and roll/pop* na rubu linije slobodnih bacanja (17%) i na krilu (16%). *Repick* (ponovljeni blok na igraču s loptom) je prisutan samo u 3,5% slučajeva, što je vjerojatno posljedica činjenice da samo u manjem broju slučajeva unutar situacija u igri obrambeni igrač na igraču s loptom prolazi ispod bloka.

Nadalje, udio *pick*-a u odnosu na sve promatrane manevre u središnjici napada (*pick and roll/pop*, *handoff*, *screens off the ball*, *low post* igra i *cut* igra) iznosi 27%.

Isto tako, udio *handoff*-a u odnosu na sve prethodne navedene manevre (*pick and roll (pop)*, *handoff*, *screen off the ball*, *low post* igra i *cut* igra) iznosi 5,6%.

Ukupna zastupljenost blok igre u središnjici napada, promatrano u odnosu na sve ostale evidentirane kategorije iznosi 44%. S gledišta sadržaja igre, na blok igru za vanjske igrače otpada 75%, na blok igru za unutarnje igrače 20%, a manevar blok za blokera je zastupljen u svega 5% slučajeva.

Ukupna zastupljenost *cut* igre je 23% od čega se 70% odnosi na vanjska otvaranja, a 30% na unutarnja otvaranja. Nadalje, p*ost up* manevar (igra na niskom postu) je zastupljen s 3% u središnjici napada.

U taktičkoj kombinatorici napada na zonsku obranu ističe se brzi protok lopte (45%), zatim slijedi opterećenje strane napada (19%) te brzi prijelaz post igrača u perimetar prostor pri čemu se stvara otvorena geometrija napada sa 4 vanjska igrača (15%).

Nasuprot gornjim rezultatima, u **završnici** pozicijskog napada se udio *pick and roll/pop* manevra bitno povećao i iznosi 44% s prosječnom uspješnošću od 51%. Zastupljenost *handoff* manevra je niži i iznosi 2,7% s uspješnošću 49%. Zastupljenost blokova na igračima bez lopte je znatno niža i iznosi 14,7% s uspješnošću 52%. *Cut* (utrčavanja) su približno jednako zastupljena (20%) s uspješnošću od nadprosječnih 64%. Tako visoka uspješnost je očekivana jer se radi o visokopostotnoj realizaciji u prostoru pod košem. Igra na niskom postu u završnici je zastupljena

sa značajno viših 9,6% s uspješnošću od 48%. Također, u završnici akcija pojavljuje se manevar izolacija na perimetru čiji je udio 6,4% s uspješnošću 47%.

Nadalje, u završnici akcija najuspješniji način realizacije je šut ispod koša (72,5%), a najneuspješniji šut iz vođenja (51,4%). Pritom je najzastupljeniji napadački skakački raspored 2-2-1 (50%), zatim 3-1-1 (25%) te 1-1-3 (23%). Iako malo klubova koristi napadački skakački raspored sa 4 igrača, on je dominantno uspješan (39%).

Opća napadačka uspješnost u pozicijskom napadu iznosi 30,0%, što je ispod praktičnog kriterija koji iznosi više od 33,3% osvojenih lopti u napadačkom skoku.

U izmjerenom uzorku bilo je 716 akcija u fazi napada koje su počele i imale neki ishod u stanju **tranzicijskog napada** čija učestalost iznosi 22% od ukupnog broja napada. Od toga je 398 akcija u fazi napada uspješno, odnosno 55,6% uspješnosti. Međutim, ako promatramo tranzicije napada koje su došle do završnice (nisu bile prije ulaska u završnicu prekinute neadekvatnom kontrolom lopte ili prekršajem pravila), onda ukupan broj tranzicija napada iznosi 605 akcija, što čini 18,5% od ukupnog broja napada. Od toga je 377 akcija uspješnih, što čini 62,3% uspješnosti.

Važno je istaknuti kako je udio **primarnih protunapada** u ukupnom broju napada 9,1%, odnosno 50% od svih tranzicijskih napada, čija je uspješnost 68%. Nadalje, zastupljenost situacija **sekundarnog protunapada** iznosi 2,9% od ukupnog broja napada, a 15,9% od ukupnog broja tranzicijskih napada čija je uspješnost 52%. Za razliku od primarnih i sekundarnih protunapada, udio ranih napada iznosi 6,4% od ukupnog broja napada, odnosno 34,7% od izvedenih tranzicijskih napada, čija je uspješnost 57%, što je iznad opće uspješnosti napada (49,16%) i opće uspješnosti pozicijskog napada (49,4%).

Temeljem deskriptivne analize u prostoru 231 varijable – stanja igre konstruirani su nestandardni situacijski parametri u prostoru pozicijskog napada: ukupan broj napada (NAPUK), broj napada koji su završili uspješnim ishodom (NAPUS), ukupan broj pozicijskih napada (PNUK), broj pozicijskih napada koji su završili uspješnim ishodom (PNUS), ukupan broj napada koji su započeli i imali neki ishod u tranzicijskom stanju napada (TNUK), broj napada koji su završili uspješnim ishodom u tranzicijskom stanju (TNUS), ukupan broj *pick and roll*, *pick and pop* i *handoff* manevara u pozicijskom napadu (NPICKUK), broj *pick and roll*, *pick and pop* i *handoff* manevara koji su završili uspješnim ishodom u pozicijskom napadu (NPICKUS), ukupan broj prijema lopte na *low post*-u u pozicijskom napadu (NLPUK), broj prijema lopte na *low post*-u

koji su završili uspješnim ishodom u pozicijskom napadu (NLPUS), ukupan broj izolacija na perimetru u pozicijskom napadu (NISOUK), broj izolacija na perimetru koje su završile uspješnim ishodom u pozicijskom napadu (NISOUS), ukupan broj blokova na igračima bez lopte u pozicijskom napadu (NBLUK), broj blokova na igračima bez lopte koji su završili uspješnim ishodom u pozicijskom napadu (NBLUS), ukupan broj prodora s loptom u pozicijskom napadu (NPRODUK), broj prodora s loptom koji su završili uspješnim ishodom u pozicijskom napadu (NPRODUS), ukupan broj utrčavanja s perimetra te ubacivanja visokih igrača u srce trapeza u pozicijskom napadu (NUTRUK) i broj utrčavanja s perimetra te ubacivanja visokih igrača u srce trapeza u pozicijskom napadu koji su završili uspješnim ishodom (NUTRUS).

Eksplorativnom tehnikom faktorske analize u manifestnom prostoru nestandardnih situacijskih varijabli NPICKUS, NLPUS, NBLUS, NISOUS, NPRODUS i NUTRUS ekstrahirane su 2 latentne dimenzije koje objašnjavaju 51% varijabiliteta. Faktori su imenovani faktor tehničko taktičke aktivnosti bloka na loptu te faktor tehničko taktičke aktivnosti bloka na igrače bez lopte. Izvjesna je činjenica da u današnjoj europskoj elitnoj košarci napadačka blok igra (kreira prostornu prednost, trenutnu brojčanu nadmoć i otvoren šut) upravo zbog proaktivne obrane nije nikad prije imala veći značaj.

Multivarijatnom regresijskom analizom istražena je povezanost kriterijske varijable uspješnost pozicijskog napada (PNUS) s prediktorskim varijablama NPICKUS i NBLUS te nakon toga odvojeno s prediktorskim varijablama NLPUS, NISOUS, NPRODUS i NUTRUS.

Pokazano je da postoji značajna statistička linearna povezanost između kriterijske varijable PNUS te prediktorskih varijabli NPICKUS i NBLUS s koeficijentom determinacije 0,98. Opći utjecaj prediktorske varijable NPICKUS na varijablu PNUS je znatno veći iz razloga dominantne zastupljenosti blokova na igrača s loptom u odnosu na blokove na igrače bez lopte.

Drugi model je također vrlo prikladan s obzirom na činjenicu da je koeficijent determinacije R^2=0,97. Nadalje, dobiveni rezultati ukazuju da uspješnom pozicijskom napadu najviše pridonose učinkoviti prodori s loptom s vanjskog prostora (NPRODUS), učinkovita utrčavanja u srce reketa (NUTRUS) te učinkovita igra leđima prema košu (NLPUS).

Diskriminacijskom analizom na dva podprostora nestandardnih situacijskih napadačkih varijabli utvrđene su razlike između uspješnih i neuspješnih ekipa u fazi napada. Pritom je kriterij razlikovanja bio 55,5% uspješnosti pozicijskog napada.

S jedne strane, u prvom potprostoru utvrđeno je da uspješnom pozicijskom napadu najviše pridonose učinkovita utrčavanja, učinkoviti prodori s loptom s vanjskog prostora te učinkovita igra na niskom postu. S druge strane, neuspješnom pozicijskom napadu najviše pridonose neuspješni prodori s loptom s vanjskog prostora.

Nadalje, na razini drugog potprostora utvrđeno je da uspješnom pozicijskom napadu najviše pridonosi učinkovita *pick and roll/pop* i *handoff* igra u napadu, a nakon toga učinkoviti blokovi na igračima bez lopte. Isto tako, neuspješan pozicijski napad najviše određuju neučinkoviti *pick and roll/pop* i *handoff* manevri, a potom neučinkoviti blokovi na igračima bez lopte.

Primijenjeni metodološki pristup apliciran je na analizu pozicijskog i tranzicijskog napada te se može generalizirati na interaktivne ili timske sportove.

9. LITERATURA

1. Ambrožič, F. (1996.). Linearni in nelinearni modeli povezav morfoloških in motoričkih spremenljivk (disertacija). University of Ljubljana – Faculty of Sport.
2. Ambrožič, F. (1999.). Linear and non-linear correlation models of morphological variables. *Kinesiology*, 31, 1:74 - 81.
3. Ap Simon, H.G. (1951.) The luck of the toss in squash rackets. *Mathematical Gazette*, 35, 193 -194.
4. Ap Simon, H.G. (1957.) Squash chances. *Mathematical Gazette*, 41, 136 - 137.
5. Arbib, M.A., (1969.). Theories of Abstract Automata, 1st ed., *Englewood Cliffs*, N.J.: Prentice-Hall, Inc.
6. Atkinson, K.E., (1988.). An introduction to numerical analysis, *John Wiley & Sons*, Inc.
7. Bajpai A.C., Calus I.M., Fairley J.A. & D. Walker (1973). *Mathematics for Engineers and Scientist* , Vol 2, John Wiley & Sons, Inc.
8. Bartlett, R. (2006.). Artificial intelligence in sports biomechanics: New dawn or false hope? *Journal of Sports Science and Medicine*, 5, 474 – 479.
9. Barton, S. (1994.). Chaos, self-organisation, and psychology. *American Psychologyst*, 49(1), 5 - 14.
10. Baum, L. E. & Petrie, T. (1966.). Statistical inference for probabilistic functions of finite state Markov chains. *Annals of Mathematical Statistics,* 37(6), 1554-1563.
11. Bellman, R. (1977.). Dynamic Programming and Markovian decision processes, with application to baseball. *Optimal strategies in sports*, Eds, S.P. Ladany & R.E. Machol, North Holland: Amsterdam, 77 - 85.
12. Berberović, J. (1978.). *Filozofija Ludwiga Wittgensteina*. Svjetlost, Sarajevo.
13. Bermant, A.F. & I.G. Aramanovich (1975.). *Mathematical Analysis*, Mir publishers, Moscow.
14. Bertalanffy, L. (1968.). *General System Theory.* New York, George Braziller.
15. Birkhoff, G.D. (1966.). *Dynamical Systems*. American Mathematical Society, *Providence*, Rhode Island.
16. Booth, T.L., (1967.). *Sequential Machines and Automata Theory*, 1st ed., New York: John Wiley and Sons, Inc.
17. Bouchard, C., Malina, R.M. & L. Perusse (1997.). *Genetics of Fitness and Physical Performance*. Champaign, IL: Human Kinetics.
18. Bukiet, B., Harold, E. & J. Palacios (1997.). A Markov chain approach to baseball. *Operations Research,* 45, 14-23.

19. Clarke, S.R. (1979.). Tie-point strategy in American and International squash and badminton. *Research Quarterly*, 50, 729 - 734.

20. Clarke, S.R., & Norman, J.M. (1979.). Comparison of North American and International squash scoring system – analytic results. *Research Quarterly*, 50, 723 - 728.

21. Clarke, S.R. & Norman, J.M. (1998.a). When to rush behind in Australian Rules football: a Dynamic Programming approach. *Journal of Operational Research Society*, 49(5), 530 - 536.

22. Clarke, S.R. & Norman, J.M. (1998.b). Dynamic Programming in cricket: Protecting the weaker batsman. *Asia Pacific Journal of Operational Research,* 15, 93 - 108.

23. Croucher, J.S. (1982.). The effect of the tennis tie-breaker. Research Quarterly for Exercise and Sport, 53, 336 - 339.

24. Croucher, J.S. (1986.). The conditional probability of winning games in tennis. Research Quarterly for Exercise and Sport, 57, 23 - 26.

25. Czerwinski, J. (1998.). Statistical analysis of the men's European Championsfip held in Italy in 1998. European Handball, 2, 10 - 18.

26. Ćorluka, M. (2008.). Pragmatična valjanost inicijalnog motoričkog statusa u procjeni stvarne kvalitete nogometaša uzrasta od 14 do 16 godina. (Doktorska disertacija) *Fakultet prirodoslovno-matematičkih i odgojnih znanosti Sveučilišta u Mostaru*.

27. Čaklović, L. & J. Štalec (1999.). The best five for a given strategy. U: Zbornik radova II međunarodne znanstvene konferencije kineziologija za 21. stoljeće, str. 441 – 444, Dubrovnik.

28. Danish, S. J. & B. D. Hale (1981.). Toward an understanding of the practice of sport psychology. *Journal of sport psychology*, 3, 90-99.

29. De Jong, K.A. (2006.). *Evolutionary computation: a unified approach*. *MIT Press*. Cambridge MA.

30. Deshaies, P., Pargman, D. & C. Thiffault (1979.). A psychobiological profile of individual performance in junior hockey players. In: Roberts, G. C. and NewelI, M. *Pscyhology of motor behavior and sport* - 1978, Human kinetics, Champaign, 37 - 50.

31. Dežman, B. & B. Leskošek (1993.). Ekspertni sistem ocenjevanja nadarjenosti otrok za igranje košarke. *U Zbornik referatov na Drugemu mednarodnem simpoziju „Šport mladih"*, Ljubljana-Bled (str. 40 - 46). Fakulteta za telesno kulturo, Ljubljana.

32. Dežman, B. & F. Erčulj (1995.). Die Anwendbarkeit des Expertensystem-Modell zur Erfolgsprognose junger Basketballspieler. In J. Bergier (Ed.), *Proceedings of the International Conference on Science in sports Team Games* (pp. 187 - 194). Biala Podlaska, Instytut Wychowania Fizycznego i Sportu, Poland.

33. Dežman, B. (1988.). Določanje homogenih skupin na osnovi nekaterih antropometričnih in motoričnih razsežnosti pri mladih košarkarjih. (Doktorska disertacija). *Fakulteta za telesno kulturo*, Ljubljana.

34. Dežman, B. (1992.). Ekspertensystem – Model zur Erfolgprognose der Spieler im Basketball. *U Proceedings of the 6th ICHPER – Europe Congress*, Praga (str. 111 - 117).

35. Dežman, B. (1995.). An example of usefulness of expert modelling in sport. In*: Proceedings of the International Symposium „Sport motorics."* Prague, Czech Republic.

36. Dežman, B. (1996.). Dijagnosticiranje morfološkog, motoričkog i igračkog statusa mlađih košarkaša. *Kineziologija*, 28 (2), 37–41.

37. Dežman, B. (1997.). Orienting young basketball players into best-suited playing roles using discriminant analysis. U M. Pavlovič (ur.), *Proceedings, III. International Symposium* (str. 345 - 351). *Fakulteta za šport*, Ljubljana.

38. Dežman, B. (1998.). Osnove teorije treniranja v izabranih moštvenih športnih igrah. *Fakulteta za šport*, Inštitut za šport, Ljubljana.

39. Dežman, B. (1999.). Zunanje in notranje obremenitve igralcev med košarkaško tekmo. (Prijedlog projekta). *Fakulteta za šport Univerze v Ljubljani*.

40. Dežman, B., Trninić, S. & D. Dizdar (2001.a). Expert model of decision-making system for efficient orientation of basketball players to positions and roles in the game – Empirical verification. *Collegium Antropologicum*, 25(1), 141 - 152.

41. Dežman, B., Trninić, S. & D. Dizdar (2001.b). Models of expert system and decision-making systems for efficient assessment of potential and actual quality of basketball players. *Kinesiology*, 33(2), 207 - 215.

42. Dictionary of Sport and Exercise science (2006.). A & C Black Publishers Ltd, London.

43. Dizdar, D. (2002.). Vrednovanje skupa metoda za procjenu stvarne kvalitete košarkaša. (Doktorska disertacija) *Kineziološki fakultet Sveučilišta u Zagrebu*.

44. Dizdar, D., Trninić, S. & D. Milanović (1997.). Determining basketball player types according to standard indicators of situation-related efficiency. *Kinesiology*, 29 (2), 49-55.

45. Edelmann-Nusser, J., Hohmann, A. & Henneberg, B. (2002.). Modelling and prediction of competitive swimming performance in swimming upon neural networks. *European Journal of Sport Science* 2(2), 1 - 10.

46. Eiben, A.E. & J.E. Smith (2003.). *Introduction to Evolutionary Computing*. *Springer,* New York.

47. Erčulj, F. (1998.). Morfološko - motorični potencijal in igralna učinkovitost mladih košarkarskih reprezentanc Slovenije. (Doktorska disertacija) *Fakulteta za šport*, Ljubljana.

48. Eysenck, H. J. (1991.). Dimensions of personality. 16, 5 or 3? - Criteria for a taxonomic paradigm. *Personality and Individual Differences*, 12 (8). 773-790.

49. Ferrari, M., Pinard, A., Reid, L. & T.Bouffard-Bouchard (1991.). The relationship between expertise and self-regulation in movement performance: some theoretical issues. *Perceptual and Motor Skills*, 72, 139 - 150.

50. Filipčič, A. (1996.). Evalvacija tekmovalne in prognostičke uspešnosti mladih teniških igralcev z metodo regresijske analize in ekspertnega sistema (Doktorska disertacija). *Fakulteta za šport, Ljubljana*.

51. Fogel, D.B. (1995.). *Evolutionary Computation. Toward a New Philosophy of Machine Intelligence*. Piscataway: IEEE Press.

52. Forbes, D. & S. Clarke (2004.). A seven state Markov process for modeling Australian rules football. In: *Proceedings of Seventh Conference on Mathematics and Computers in Sport.* Ed: Morton, H. Palmerston North: Massey University, 148 - 158.

53. Fröberg, C.E. (1966.). *Introduction to numerical analysis*. Addison-Wesley Publishing Company, Inc.

54. Gabrijelić i sur. (1980.). *Postupci izbora, usmjeravanja i praćenja u području vrhunskog sporta*. Fakultet za fizičku kulturu, Zagreb.

55. Gabrijelić, M. (1977.). Manifestne i latentne dimenzije vrhunskih sportaša nekih momčadskih sportskih igara u motoričkom, kognitivnom i konativnom prostoru. (Doktorska disertacija) Fakultet za fizičku kulturu, Zagreb.

56. Gajić, V. (1970.). Analiza VII. prvenstva sveta u rukometu, Sportska praksa, 3-4:4-9.

57. Garland, D.J. & J.R. Barry (1990.). Sport expertise: The cognitive advantage. *Perceptual and Motor Skills*, 70, 1299 - 1314.

58. Giarratano, J., & Riley, G. (1998). Expert Systems Principles and Programming. 3rd ed. China Machine Press.

59. Gödel, K. (1931). On Formally Undecidable Propositions of Principia Mathematica and Related Systems I, *Reprints:* S. Feferman et al., eds., *Kurt Gödel. Collected Works. Volume I: Publications 1929 – 1936.* Oxford University Press, pp. 116 – 195, New York.

60. Golubitsky, M. & I. Stewart (2006.). Nonlinear dynamics of networks: the groupoid formalism, *Bull. Amer. Math. Soc. (N.S.)* 43, 305 - 364.

61. Gomez, M.A., Lorenzo, A., Barakat, R., Ortega, E. & Palao, J.M. (2008.). Differences in game-related statistics of basketball performance by game location for men's winning and losing teams. *Perceptual and Motor Skills*, 106, 43 - 50.

62. Gomez, M.A., Lorenzo, A., Sampaio, J., Ibanez, S. J. & Ortega, E. (2008.). Game related statistics that discriminated winning and losing teams from Spanish men's professional basketball teams. *Collegium Antropologicum.* 32*,* 451 - 456.

63. Gréhaigne, J.-F. & P. Godbout (1995.). Tactical knowledge in team sports - From a constructivist and cognitivist perspective. *Quest, 47,* 490 - 505.

64. Guard, J., Oglesby, R, Bennett, J., and Settle, L.(1969.). Semi-automated mathematics. *Journal of the Association for Computing Machinery,* 16, 49 - 62.

65. Hagedorn, H., Lerenz, H. & U. Meseck (1982.). Kompjuterska analiza rasporeda tipičnih akcija na košarkaškom igralištu. *Sportska praksa* 1, 18 - 22.

66. Hajnal, L. (1990.). *Košarka - savremeni model igre*. Novi Sad.

67. Haussler, D. (1989.). Learning conjunctive concepts in structural domains. *Machine Learning,* 4(1), 7 - 40.

68. Hernandez, J. (1987.). Estudio Sobre el Analisis de la Accion de Juego en los Deportes de Equipo: Su Aplicacion al Baloncesto. (Doktorska disertacija). Universidad de Barcelona, Facultad de Filosofia y Ciencias de la Educacion.

69. Hewstone, M. & W. Stroebe (2001.). *Socijalna psihologija*. Naklada Slap, Jastrebarsko.

70. Hirotsu, N. & M. Wright (2003.a). An evaluation of characteristics of teams in association football by using a Markov process model. *Journal of the Royal Statistical Society,* Series D*,* 52, 591 - 602.

71. Hirotsu, N. & M. Wright (2003.b). A Markov chain approach to optimal pinch-hitting strategies in a designated hitter rule baseball game. *Journal of the Operations Research Society of Japan,* 46, 353 - 371.

72. Hirotsu, N. (2002). A formulation of optimal substitution strategies using a Markov process model in baseball and soccer. *Management Science,* 48, 306.

73. Horga, S. (1993.). *Psihologija sporta*. Fakultet za fizičku kulturu, Zagreb.

74. Horn, R.A. & C.R. Johnson (1990.). *Matrix Analysis*, Cambridge University Press.

75. Hraste, M., Dizdar, D. & V. Trninić (2008.). Experts Opinion about System of the Performance Evaluation Criteria Weighted per Positons in the Water Polo Game. *Collegium Antropologicum*, 32 (2), 851 - 861.

76. Hughes, M., Dawkins, N., David, R., & Mills, J. (1998.). The perturbation effect and goal opportunities in soccer. *Journal of Sports Sciences,* 16, 20.

77. Hughes, M.D. & Bartlett, R.M., (2002.) The use of performance indicators in performance analysis. *Journal of Sport Sciences*, 20, 739 - 754.

78. Hughes, M.D., Evans, S. & Wells, J. (2001.). Establishing normative profiles in performance analysis. *Electronic International Journal of Performance Analysis of Sport*, 1, 1 – 25.

79. Ibanez, S.J., Sampaio, J., Feu, S., Lorenzo, A., Gomez, M.A. & Ortega, E. (2008.). Basketball game-related statistics that discriminate between teams' season-long success. *European Journal of Sport Science.*

80. Jacob, C.S. & A.V. Carron (1997.). The sources of status on sport teams. *International journal of Sport Psychology*, 27, 369 - 382.

81. Jeličić, M. (2003.). Veličina i obilježja morfološke uvjetovanosti situacijske učinkovitosti vrhunskih juniorskih košarkaša. (Doktorska disertacija). Kineziološki fakultet Sveučilišta u Zagrebu.

82. Jelaska, I. (2005.). Interpolacija rješenjima diskretnih višetočkovnih rubnih problema. (Magistarski rad) Sveučilište u Zagrebu, Prirodoslovno - Matematički fakultet, Matematčki odjel, Zagreb.

83. Jošt, B., Dežman, B. & J. Pustovrh (1992.). Vrednotenje modela uspješnosti v posameznih športnih panogah na podlagi ekspertnega modeliranja (str. 158 - 161). *Fakulteta za telesno kulturo, Inštitut za šport*, Ljubljana.

84. Judson, T. W. (1997.). *Abstract Algebra: Theory and Applications*, dostupno na: http://abstract.ups.edu

85. Kam, T. (1997.). *Synthesis of Finite State Machines: Functional Optimization*. Kluwer Academic Publishers, Boston.

86. Kent, M. (1998.). *The Oxford Dictionary of Sports Science and Medicine*, Oxford University Press Inc.*,* New York.

87. Kemeny, J.G. & Snell, J.L. (1976.). *Finite Markov Chains*. Springer, New York.

88. Kiš M. (2000.). *Englesko - hrvatski i hrvatsko - engleski informatički rječnik*, Naklada Ljevak, Zagreb.

89. Kleiner, I. (1986.). The evolution of group theory: a brief survey, *Mathematics Magazine* 59 (4): 195 – 215.

90. Knight, B. (1994.). Conversion/transition. U: J.Krause (Ed.): Coaching basketball., 237 - 238). *Masters Press*, Indianapolis.

91. Knight, B., P. Newell, (1986.). *Basketball*. Graessle Mercer co., Seamoor, vol.1.

92. Kvasov, B. (2003.). *Methods of Shape Preserving Spline Approximation*, World Scientific, Moscow.

93. La Harpe, P. (2000.). *Topics in geometric group theory*. University of Chicago Press, Chicago.

94. Lames, M. (1988.). Techniktraining im Tennis durch Computersimulation. In R. Andresen & G. Hagedorn (Hrsg.), *Sportspiele: animieren – trainieren* (S. 181 – 191). Ahrensburg, Czwalina.

95. Lames, M. (1991.). Leistungsdiagnostik durch Computersimulation: Ein Beitrag zur Theorie der Sportspiele am Beispiel Tennis. Thun: Harry Deutsch, Frankfurt.

96. Lames, M. & Hohmann, A. (1997.). Zur Leistungsrelevanz von Spielhandlungen im Volleyball. In: B. Hoffmann & P. Koch (Hrsg.), *Integrative Aspekte in Theorie und Praxis der Rückschlagspiele* (S. 121 - 128). Hamburg, Czwalina.

97. Lames, M., Hohmann, A., Daum, M., Dierks, B., Fröhner, B., Seidel, I. & Wichmann, E. (1997.). Top oder Flop: Die Erfassung der Spielleistung in den Mannschaftssportspielen. In: E. Hossner & K. Roth (Hrsg.), Sport-Spiel-Forschung Zwischen Trainerbank und Lehrstuhl (S. 101 - 117). Hamburg, Czwalina.

98. Lapham, A.C. & R.M. Bartlett (1995.). The use of artificial intelligence in the analysis of sports performance: a review of applications in human gait analysis and future directions for sports biomechanics. *Journal of Sports Sciences*, 13, 229 - 237.

99. Lapham, A.C. & R.M. Bartlett (1995.). The use of artificial intelligence in the analysis of sports performance: a review of applications in human gait analysis and future directions for sports biomechanics. *Journal of Sports Sciences*, 13, 229 - 237.

100. Lebed, F. (2006.). System approach to games and competitive playing. *European* Journal of Sport Science, 7(1), 55 - 62.

101. Lebed, F. (2007.). A dolphin only looks like a fish: Player's behaviour analysis is not enough for game understanding in the light of the systems approach – a response to the reply by McGarry and Franks. *European Journal of Sport Science*, 7(1), 55 - 62.

102. Lees, A. (2002.). Technique analysis in sports: a critical review. *Journal of Sports Sciences*, 20, 813 - 828.

103. Lees, A., Barton, G. & L. Kershaw (2003.). The use of Kohonen neural network analysis to qualitatively characterize technique in soccer kicking. *Journal of Sports Sciences,* 21, 243 - 244.

104. Leskošek, B. (1996.). Komparativna analiza ekspertnih metoda z vidika uporabnosti za

začetni izbor in usmerjanje otrok v različne športne panoge. (Doktorska disertacija) *Fakulteta za šport*, *Ljubljana.*

105. Lewin, K. (1935.). A dynamic theory of personality. *McGraw-Hill,* New York.
106. Libermann, D.G., Katz, L., Hughes, M.D., Bartlett, R.M., McClements, J. & I.M. Franks (2002.). Advances in the application of information technology to sport performance. *Journal of Sports Sciences*, 20, 755 - 769.
107. Lidor, R. i Arnon, M. (1997.). Correlational relationships between tehnical variables and final placing of basketball teams. *Coaching & Sport Science Journal*, 2, 39 - 47.
108. Losada, M. & E. Heapy (2004.). The Role of Posityvity and Connectivity in the performance of Business Teams: A Nonlinear Dynamics Model, *American Behavioral Scientist*, 47, 740 - 765.
109. Malacko, J. & D. Popović (2001.). *Metodologija kineziološko antroploških istraživanja*. Leposavić: Fakultet za fizičku kulturu Univerziteta u Prištini.
110. Malina, R.M. & C. Bouchard (1991.). Growth, maturation, and physical activity, Champaign, IL: *Human Kinetics*.
111. Matvejev, L. P. (1977.). *Osnovi sportivnoj trenirovki*. Fizkultura i sport, Moskva.
112. Matvejev, L. P. (1981.). *Grundlagen des sportlichen Trainings*. Sportverlag, Berlin.
113. Matvejev, L. P. (1999.). *Osnovi suvremenog sistema sportivnoj trenirovki*. Fizkultura i sport, Moskva,
114. Matycin O. V. & O.V. Daškevič (1989.). Naučno-praktičeskije aspekty issledovanija osobennostej ličnosti vysokokvalificirovannyh sportsmenov po nastol'nomu tennisu. *Teorija i praktika fizičeskoj kultury*, 5, 12 - 16.
115. McGarry, T. & Franks, I.M. (1994.). A stochastic approach to predicting competition squash match play. *Journal of Sports Sciences*, 12, 573 - 584.
116. McGarry, T. & Franks, I.M. (1996.a). In search for invariant athletic behaviour in competitice sports systems: An example from championship squash match-play. *Journal of Sports Sciences*, 14, 445 - 456.
117. McGarry, T. & Franks, I.M. (1996.b). Development, application, and limitation of stochastic Markov model in explaining championship squash performance. *Research Quarterly for Exercise and Sport*, 67, 406 - 415.
118. McGarry, T. & J.M. Franks (2007.). System approach to games and competitive playing: Reply to Lebed (2006.). *European Journal of Sport Science*, 7(1), 47 - 53.
119. McGarry, T. and Franks, I.M. (1996.). In search of invariant athletic behaviour in

competetive sport systems: an example from championship squash match-play. *Journal of Sport Sciences*, 14, 445 - 456.

120. McGarry, T., Anderson, D.I., Wallace, S.A., Hughes, M.D. & I.M. Franks (2002.). Sport competition as a dynamical self-organizing system. *Journal of Sport Sciences,* 20, 771-781.
121. Mejovšek, M. (2003.). *Uvod u metode znanstvenog istraživanja društvenim i humanističkim znanostima*. ERF - Naklada Slap*,* Jastrebarsko.
122. Mejovšek, M. (2008.) *Metode znanstvenog istraživanja u društvenim i humanističkim znanostima*. Naklada Slap, Jastrebarsko.
123. Melnick, M.J. (2001.). Relationship betweenteam assists and win-loss record in the National Basketball Association. *Perceptual and Motor Skills*, 92, 595 - 602.
124. Meyer, D., Forbes, D. & S.R. Clarke (2006). Statistical analysis of notational AFL dana using continous time Markov Chains, *Journal of Sports Science and Medicine*, Vol 5, 525 – 532.
125. Milanović, D. (2004). *Teorija treninga: Priručnik za praćenje nastave i pripremanje ispita*. Kineziološki fakultet Sveučilišta u Zagrebu.
126. Milanović, D. (2009.). *Teorija i metodika treninga*. Kineziološki fakultet Sveučilišta u Zagrebu.
127. Momirović, K. & I. Ignjatović (1977.). Struktura konativnih faktora. *Psihologija,* 10,3 - 4,25 - 32.
128. Momirović, K. (1969.). *Faktorska struktura antropometrijskih varijabli*. Institut za kineziologiju, VŠFK, Zagreb.
129. Momirović, K. (1972.). *Metode za transformaciju i kondenzaciju kineziloških informacija*. Institut za kineziologiju, FFK, Zagreb.
130. Momirović, K. i sur. (1966.). Utjecaj latentnih antropometrijskih varijabli na orijentaciju i selekciju vrhunskih sportaša. *Visoka škola za fizičku kulturu*, *Zagreb.*
131. Morgan, W.P. (1979.). *Prediction of performance in athletics*. In Klavora, P. and Daniel, J.V. Coach, athlete, and the sport psychologist: Human kinetics, Champaign, 173 -188.
132. Morris, C. (1977.). *The most important points in tennis*. In S.P. Ladany and R.E. Machol (Eds.), Optimal strategies in sport (pp. 131-140). North Holland, Amsterdam:
133. Mraković, M. (1971.). Kineziologija. *Kineziologija,* 1,1, 1-5.
134. Mraković, M. (1994.). Uvod u sistematsku kineziologiju. *Fakultet za fizičku Kulturu,* Zagreb.

135. Negnevitsky, M. (2002.). Artificial Intelligence: A Guide to Intelligent Systems, *Addison-Wesley*.
136. Nikolić, A. (1993.). *Per aspera ad astra*. Beograd: Playmaker Co.
137. Norman, J.M. (1999.). Markov Process Applications in sport. In IFORS conference. Beijing, China
138. Ott, E. (1993.). *Chaos in Dynamical Systems.* Cambridge University Press, Cambridge.
139. Ott, E., Sauer, T. & J.A. Yorke (1994.). Coping with Chaos, Analysis of Chaotic Dana and Exploatation of Chaotic Systems. *John Wiley & Sons*.
140. Palut, Y. & P.S. Zanone (2005.). A dynamical analysis of tennis players' motion: Concepts and data. *Journal of Sports Science* 23, 1021 - 1032.
141. Papić, V., Rogulj, N. & V. Pleština (2009.). Identification of sport talents using a web-oriented expert system with a fuzzy module, *Expert Systems with Applications*. 36, 5; 8830 - 8838.
142. Partridge, J. & D.E. Stevens (2002.). Group Dinamics: The Influence of the Team in Sport. In book Silva, J. M., Stevens, D. E., *Psychological Foundations of Sport*. Pearson Education Company, Boston.
143. Pavičić, L. (1991.). Some possibilities for formal definition of waterpolo game. U J. Perl (ur.), *Sport und Informatik II* (str. 124 -133). Köln, Bundesinstitut fur Sportwissenschaft.
144. Pavlovič, M. (1977.). Struktura taktičnega mišljenja košarkarja. (Doktorska disertacija). *Fakultet za fizičku kulturu*, Zagreb.
145. Perl, J. & K. Weber (2004.). A Neural Network approach to pattern learning in sport. *International Journal of Computer Science in Sport* 3, 67 - 70.
146. Perl, J. (2001.). Artificial neural networks in sports: New concepts and approaches. *International Journal of Performance Analysis in Sport,* 1, 106 - 121.
148. Perl, J. (2005.). A computer Science in sport: An overview of present fields and future applications (Part II). *International Journal of Computer Science in Sport* 4, 35 - 45.
149. Perše, M., Kristan M., Kovačić, S., Vučković, G., & J. Perš (2009.). A trajectory-based analysis of coordinated team activity in a basketball game. *Computer Vision and Image Understanding*, 113, 612 – 621.
150. Pfeifer, P.E., & Deutsch S.J. (1981.). A probabilistic model for evaluation of volleyball scoring systems. *Research Quarterly for Exercise and Sport,* 52, 330 - 338.
151. Pfeiffer, M. (2003.). Leistungsdiagnostik im Handball. Dissertationsschrift. Universität Leipzig.

152. Philips, D.C. & R. Orton (1983.). The new causal principle of cognitive learninig theory: Perspective on Bandura's „reciprocal determinism“. *Psychological Review*, 90, 158-165.

153. Piaget, J. (1972.). *Epistemologie des sciences de l homme*, Paris: Gallimard.

154. Pollard, G.H. (1985.) A statistical investigation of squash. *Research Quarterly for Exercise and Sport*, 56, 144 - 150.

155. Pollard, G.H. (1987.) A new tennis scoring system. *Research Quarterly for Exercise and Sport*, 58, 229 - 233.

156. Poole, D. (2006.). *Linear Algebra: A Modern Introduction* (2nd ed.), Brooks/Cole.

157. Popper, K. (1973.). *Logika naučnog otkrića*. Nolit, Beograd.

158. Radošević, D. (2001.). *Osnove teorije sustava*, Nakladni zavod Matice hrvatske, Zagreb.

159. Read, B. & P. Edwards (1992.). Teaching Childern to Play Games. Leeds: *White Line Publishing*.

160. Renick, J. (1977.). Tie point strategy in badminton and international squash. Research Quarterly, 48, 492 - 498.

161. Rogulj, N. (2003.). Učinkovitost taktičkih modela u rukometu. (Doktorska disertacija). *Kineziološki fakultet sveučilišta u Zagrebu.*

162. Rogulj, N. (1985.). Struktura psihomotoričkog prostora vratara u rukometu. (Diplomski rad) Filozofski fakultet u Zadru.

163. Rogulj, N., Papić, V. & M. Čavala (2009.). Evaluation Models of Some Morphological Characteristics for Talent Scouting in Sport, *Collegium Antropologicum*. 33, 1; 105 - 110.

164. Roman, S. (2005.). *Advanced Linear Algebra*, Graduate Texts in Mathematics (2nd ed.), *Springer*.

165. Ruell, D. (1989.). *Chaotic evolution and strange attractors*. Cambridge University Press

166. Sabioncello, N. (1971.). Odabrana poglavlja iz kineziologijske psihologije, *Visoka škola za fizičku kulturu Sveučilišta u Zagrebu*.

167. Sabioncello, N. (1973.). Osnove psihologije sporta, *Visoka škola za fizičku kulturu Sveučilišta u Zagrebu*.

168. Sabioncello, N. (1977.). Osnove psihologije sporta. *Fakultet za fizičku kulturu, Sveučilište u Zagrebu*.

169. Sampaio, J. & Janeira, M. (2003.). Statistical analises of basketball team performance: Understanding teams' wins and losses according to a different index of ball possesions. *International Journal of Performance Analysis in Sport*, 3, 40 - 49.

170. Schilling, G. (1975.). Sport, psychology of. In: Eysenck, H. J., Arnold, W. J. and Meili, R., *Encyclopedia of psychology*, Fontana, Collins, 1048 - 1049.

171. Schutz, R.W. (1970.). A mathematical model for evaluating scoring systems with specific reference to tennis. *Research Quarterly*, 41, 552 - 561.

172. Schutz, R.W., & Kinsey, W.J. (1977.). Comparison of North American and International squash scoring systems. *Research Quarterly*, 48, 248 - 251.

173. Seifriz, F. & J. Mester (2002.). Modelling in sports: from mathematical fundamentals to applied use in mass media. *International Journal of Computer Science in Sport,* 2, 135.

174.Sekulić D.,N.Zenić, G.Marković (2005.). Non linear relationships between antropometric and motor - endurance variables. *Collegium Antropologicum*, 29(2) 723 - 730.

175. Sekulić, D., N. Viskić-Štalec, N. Rausavljević (2003.). Non Linear relations between selected anthropological predictors and psycho-physiological exercise responses. *Collegium Antropologicum*, 27(2) 587 - 599.

176. Sekulić, D., Zenić N. & N. Grčić Zubčević (2007.). Non linear anthropometric predictors in swimming. *Collegium Antropologicum* 31(3) 803 - 810.

177. Shirley, K. (2007.).
a. URL:
http://www.amstat.org/Chapters/boston/nessis07/presentation_material/Kenny_Shirley.pdf (02.05.2010)

178. Shores, T.S. (2006.). *Applied Linear Algebra and Matrix Analysis*, Undergraduate Texts in Mathematics, Springer.

179. Siler, W., & J.J. Buckley (2005.). *Fuzzy expert systems and fuzzy reasoning*. Hoboken, John Wiley & Sons, New Jersey.

180. Silva, J. M. & D.E. Stevens (2002.). *Psychological Foundations of Sport*. Pearson Education Company, Boston.

181. Silva, J. M. & D.E. Stevens (2002.). Psychological Foundations of Sport. *Pearson Education Company*, Boston.

182. Silva, J. M. III, Shultz, B. B., Haslam, R. W. & D. Murray (1981.). A psychophysiological assesment of elite wrestlers, *Research Quarterly*, 52, 3, 348 - 358.

183. Sipser, M. (1997.). Introduction to the Theory of Computation, *PWS Publishing Company*, Boston.

184. Smith, G.D. (1978.). *Numerical Solution of Partial Differential Equations: Finite Difference Methods*, Second ed., Clarendon Press, Oxford.
185. Steven J.L. (2006.). *Linear Algebra With Applications* (7th ed.), Pearson Prentice Hall.
186. Swalgin, K. (1994.). The basketball evaluation system: A scientific approach to player evaluation. U J. Krause (ur.), *Coaching basketball* (str. 40 - 43). Masters Press, Indianapolis.
187. Swalgin, K. (1998.). The basketball evaluation system: a computerized factor weighted model with measures of validity. *Kinesiology*, 30 (1), 31 - 37.
188. Šošić, I. & V. Serdar (2000.). *Uvod u statistiku* (jedanaesto izdanje). Školska knjiga, Zagreb.
189. Tiziano, V. (1997.). *Synthesis of Finite State Machines: Logic Optimization*. Kluwer Academic Publishers, Boston.
190. Trninić, M., Trninić, S. & V. Papić (2009.). Development Management Model of Elite Athletes in Team Sports Games. *Collegium Antropologicum*. 33(2): 363 - 372.
191. Trninić, S. & D. Dizdar (2000.). System of the performance evaluation criteria weighted per positions in the basketball game. *Collegium Antropologicum*, 24 (2), 217 - 234.
192. Trninić, S. (1995.). *Strukturna analiza znanja u košarkaškoj igri*. (Doktorska disertacija) Fakultet za fizičku kulturu, Zagreb.
193. Trninić, S. (1996.). *Analiza i učenje košarkaške igre*. Vikta, Pula.
194. Trninić, S. (2006.). Selekcija, priprema i vođenje košarkaša i momčadi. *Vikta-Marko*, Zagreb.
195. Trninić, S., Dizdar, D. & B. Dežman (2000.). Empirical verification of the weighted system of criteria for the elite basketball players quality evaluation. *Collegium Antropologicum*, 24 (2), 431 - 442.
196. Trninić, S., Dizdar, D. & B. Dežman (2002.a). Combined model of expert system for the actual quality assessment in basketball players. U D. Milanović i F. Prot (ur.) Kinesiology – New Perspectives: *Zbornik radova 3. međunarodne znanstvene konferencije*, Opatija, 25-29. 09. 2002. (str. 664 - 667). Kineziološki fakultet, Zagreb.
197. Trninić, S., Dizdar, D. & B. Dežman (2002.b). Pragmatic validity of the combined expert system model for the evaluation and analysis of overall structure of actual quality in basketball players. *Collegium Atropologicum*, 26(1), 199 - 210.
198. Trninić, S., Dizdar, D. & Lukšić, E. (2002.). Differences between winning and defeated top quality basketball teams in final tournaments of European club champoinship.

Collegium Antropologicum, 26, 521 - 531.

199. Trninić, S., Dizdar, D. & Ž. Jaklinović-Fressl (1999.b). Analysis of differences between guards, forwards and centres based on some anthropometric characteristics and indicators of playing performance in basketball. *Kinesiology*, 31 (1), 29 - 36.
200. Trninić, S., Jelaska, I. & V. Papić (2009.a). Kineziološki, antropološki i metodološki aspekti jednadžbe uspjeha u momčadskim sportskim igrama. *Acta Kinesiologica*. 3 (2), 7-18.
201. Trninić, S., Jelaska, I. & V. Papić (2009.b). Globalni nelinearni model za evaluaciju uspješnosti u momčadskim sportskim igrama, *Sport Scientific and Practical Aspects,* 2(2), 73 - 80.
202. Trninić, S., Kardum, I. & B. Mlačić (2009.). Hipotetski model specifičnih osobina vrhunskih sportaša u momčadskim sportskim igrama. *Društvena istraživanja*. 19(3), 463- 485.
203. Trninić, S., Milanović, D. & D. Dizdar (1997.). Worin unterscheiden sich Sieger von verlieren im Basketball. *Leistungsport*, 29 (2), 29 - 34.
204. Trninić, S., Perica, A. & D. Dizdar (1999.a). Set of criteria for the actual quality evaluation of the elite basketball players. *Collegium Antropologicum*, 23 (2), 707 - 721.
205. Trninić, S., Perica, A. i L. Pavičić (1994.). Analiza stanja igre u košarkaškoj utakmici. *Kineziologija*, 26 (1-2), 27 - 32.
206. Trninić, V., Papić, V. & M. Trninić (2009.). Role of expert coaches in development of top-level athletes' careers in individual and team sports. *Acta Kinesiologica*. 3(1), pp. 98 - 105.
207. Trninić, V., Papić, V. & T. Dimec (2008.). Concepts of Developing Groups in Team Sports, *Acta Kinesiologica*, 2(2), 74 - 81.
208. Trueman, R.E. (1977.). Analysis of baseball as a Markov process. In S.P. Ladany and R.E. Machol (Eds.), Optimal strategies in sport (pp. 68 -76). Amsterdam: North Holland.
209. Vidačić, S. (2005.a). The use of information system in the management of business rules. *Proceedings of the 16th International Conference of Information and Inteligent Systems* -IIS2005, Varaždin, str. 145 - 151.
210. Vidačić, S. (2005.b). The use of information system in evaluation of the performance of Employees.*Proceedings of the 16th International Conference of Information and Inteligent Systems* – IIS2005, Varaždin, str. 229 - 234.
211. Wagner, F., (2006.). *Modeling Software with Finite State Machines: A Practical*

Approach, Auerbach Publications.

212. Webster's Encyclopedic Unabridged Dictionary of the English Language (1993.). Gramercy Books, New York.
213. Webster's II, New Riverside University Dictionary (1988.). Riverside Publishing Company, New York:
214. Weibel, C.A. (1994.). *An introduction to homological algebra*, Cambridge Studies in Advanced Mathematics, 38, Cambridge University Press.
215. Wright, G.H. (1975.). *Objašnjenje i razumevanje*. Nolit, Beograd.
216. Wright, M.B. (1988.). Probabilities and decision rules for the game of squash rackets. *Journal of the Operational Research Society*, 39, 91 - 99.
217. Zadeh, L. A. (1965.). Fuzzy sets. *Information and Control*, 8, 338 – 353.
218. Zhang, H. (2003.). Leistungsdiagnostik im Tischtennis. Dissertation. Universität Potsdam.

10. PRILOG

10.1. Prilog 1 – Izvorni kod: SSA ver. 1.0.

U ovom prilogu dani su fragmenti glavnih C# izvornih kodova algoritama software-a State Analyzer ver. 1.0.

Form1.cs

```
using System;
using System.Collections.Generic;
using System.IO;
using System.Text.RegularExpressions;
using System.Windows.Forms;
namespace Analiza
{
   public partial class Form1 : Form
   {
      private Dictionary<string, Tim> _Podaci;
```

```
public Form1()
{
   InitializeComponent();
}
#region btnUcitajPodatke_Click
private void btnUcitajPodatke_Click( object fSender, EventArgs fArgs )
{
   List<Utakmica> myUtakmice;
   myUtakmice = UcitajPodatkeOUtakmicama();
   ObradiPodatkeOUtakmicama( myUtakmice );
   KreirajStatistikuPromjenaStanja( myUtakmice );
   KreirajUkupnePodatke();
}
#endregion
#region btnSnimiPodatke_Click
private void btnSnimiPodatke_Click( object fSender, EventArgs fArgs )
{
   if( txtOutputCSV.Text.Length > 0 )
   {
      SnimiKaoCSV( _Podaci, txtOutputCSV.Text );
   }
}
#endregion
#region UcitajPodatkeOUtakmicama
private List<Utakmica> UcitajPodatkeOUtakmicama()
{
   List<Utakmica> myUtakmice = new List<Utakmica>();
   string myText = File.ReadAllText( txtInputFile.Text );
   myText = myText.Replace( "\r", "" );
   Match myUtakmiceMatch = Regex.Match( myText, @"(?:  [^\n]*  [xX]{4,} \n )+
(?'TimA'[^-\n/]+)  [-/]  (?'TimB'[^-\n/]+)   \n", RegexOptions.IgnorePatternWhitespace |
RegexOptions.Singleline );
   Log( "\nPronadjene utakmice:" );
   while( myUtakmiceMatch.Success )
   {
      string myTimA = myUtakmiceMatch.Groups["TimA"].Value.Trim();
```

```
            string myTimB = myUtakmiceMatch.Groups["TimB"].Value.Trim();
            int myMatchStart = myUtakmiceMatch.Index + myUtakmiceMatch.Length;
            int myMatchEnd;
            myUtakmiceMatch = myUtakmiceMatch.NextMatch();
            if( myUtakmiceMatch.Success )
            {
               myMatchEnd = myUtakmiceMatch.Index;
            }
            else
            {
               myMatchEnd = myText.Length;
            }
            string myTextStatistike = myText.Substring( myMatchStart, myMatchEnd -
myMatchStart );
            myUtakmice.Add( new Utakmica( myTimA, myTimB, myTextStatistike ) );
            Log( "Utakmica: " + myTimA + " - " + myTimB );
         }
         return myUtakmice;
      }
      #endregion
      #region ObradiPodatkeOUtakmicama
      private void ObradiPodatkeOUtakmicama( List<Utakmica> fUtakmice )
      {
         Log( Environment.NewLine + "Analiza:" );
         foreach( var myUtakmica in fUtakmice )
         {
            Match myStatistikaMatch =
               Regex.Match( myUtakmica.TextStatistike,
                        myUtakmica.TimA.Replace( " ", @"\ " ) + "(?'A'.*)    \n [xX]{8,} \n
.*"     +     myUtakmica.TimB.Replace(     "     ",     @"\     "     )     +     "(?'B'.*)",
RegexOptions.IgnorePatternWhitespace          |          RegexOptions.Singleline          |
RegexOptions.IgnoreCase );
            if( !myStatistikaMatch.Success )
            {
               myStatistikaMatch =
                  Regex.Match( myUtakmica.TextStatistike,
```

```
                myUtakmica.TimB.Replace( " ", @"\ " ) + "(?'B'.*)  \n [xX]{8,} \n
.*"  +  myUtakmica.TimA.Replace(  "  ",  @"\  "  )  +  "(?'A'.*)",
RegexOptions.IgnorePatternWhitespace  |  RegexOptions.Singleline  |
RegexOptions.IgnoreCase );
            }
            if( myStatistikaMatch.Success )
            {
               string myTimAText = myStatistikaMatch.Groups["A"].Value;
               string myTimBText = myStatistikaMatch.Groups["B"].Value;
               myUtakmica.NapadiA = KreirajPromjenuStanjaJednogTima( myTimAText );
               myUtakmica.NapadiB = KreirajPromjenuStanjaJednogTima( myTimBText );
               Log( "Analiziram " + myUtakmica.Name + " "
                   + myUtakmica.TimA + "-" + myUtakmica.NapadiA.Count + " akcija" + "
"
                   + myUtakmica.TimB + "-" + myUtakmica.NapadiB.Count + " akcija" );
            }
            else
            {
               Log( "Greska prilikom analiziranja podataka za utakmicu " +
myUtakmica.Name );
            }
         }
      }

      private static List<Napad> KreirajPromjenuStanjaJednogTima( string fText )
      {
         List<Napad> myNapadi = new List<Napad>();
         fText = "\n" + fText + "\n";
         Match myMatch = Regex.Match( fText, @"\n[0-9]+\. (?'podaci'[^\n]+)",
RegexOptions.IgnorePatternWhitespace | RegexOptions.Singleline );
         while( myMatch.Success )
         {
            myNapadi.Add(                    KreirajPromjenuStanjaJednogNapada(
myMatch.Groups["podaci"].Value.Trim() ) );
            myMatch = myMatch.NextMatch();
         }
         return myNapadi;
      }
```

```
private static Napad KreirajPromjenuStanjaJednogNapada( string fPopisStanja )
{
   Napad myNapad = new Napad();
   Match myMatch = Regex.Match( fPopisStanja, @"[^-]+",
RegexOptions.IgnorePatternWhitespace | RegexOptions.Singleline );
   while( myMatch.Success )
   {
      myNapad.DodajStanje( myMatch.Value );
      myMatch = myMatch.NextMatch();
   }
   return myNapad;
}
#endregion
#region KreirajStatistikuPromjenaStanja
private void KreirajStatistikuPromjenaStanja( List<Utakmica> fUtakmice )
{
   _Podaci = new Dictionary<string, Tim>();
   Log( Environment.NewLine + "Kreiram statistiku" );
   foreach( var myUtakmica in fUtakmice )
   {
      Log( "Kreiram statistiku na osnovu " + myUtakmica.Name );
      DodajStatistikuZaJedanTim( myUtakmica.TimA, myUtakmica.NapadiA );
      DodajStatistikuZaJedanTim( myUtakmica.TimB, myUtakmica.NapadiB );
   }
}
private void DodajStatistikuZaJedanTim( string fTimName, List<Napad> fNapadi )
{
   if( !_Podaci.ContainsKey( fTimName ) )
   {
      _Podaci[fTimName] = new Tim( fTimName );
   }
   foreach( Napad myNapad in fNapadi )
   {
      for( int i = 1; i < myNapad.Stanja.Count; ++i )
      {
```

```
                _Podaci[fTimName].PromjeneStanja.Dodaj( myNapad.Stanja[i - 1], myNapad.Stanja[i] );
            }
            _Podaci[fTimName].Napadi.Add( myNapad );
        }
    }
    #endregion
    private void KreirajUkupnePodatke()
    {
        Tim myUkupnaStatistika = new Tim( "UKUPNO" );
        foreach( Tim myTim in _Podaci.Values )
        {
            foreach( string myPocetnoStanje in myTim.PromjeneStanja.Stanja )
            {
                foreach( string myKrajnjeStanje in myTim.PromjeneStanja.Stanja )
                {
                    myUkupnaStatistika.PromjeneStanja.Dodaj( myPocetnoStanje, myKrajnjeStanje, myTim.PromjeneStanja.BrojPromjena( myPocetnoStanje, myKrajnjeStanje ) );
                }
            }
            foreach( Napad myNapad in myTim.Napadi )
            {
                myUkupnaStatistika.Napadi.Add( myNapad );
            }
        }
        _Podaci["UKUPNO"] = myUkupnaStatistika;
    }
    #region SnimiKaoCSV
    private void SnimiKaoCSV( Dictionary<string, Tim> fTimovi, string fFileName )
    {
        bool myIsFirst = true;
        const string cCSVSeparator = ";";
        Log( Environment.NewLine + "Snimam CSV u " + fFileName );
        StreamWriter myFile = File.CreateText( fFileName );
        foreach( Tim myTim in fTimovi.Values )
        {
```

```
            if( myIsFirst )
            {
               myIsFirst = false;
            }
            else
            {
               myFile.WriteLine();
               myFile.WriteLine();
            }
            myFile.WriteLine( myTim );
            myFile.Write( "Stanje" );
            foreach( String myStanje in myTim.PromjeneStanja.Stanja )
            {
               myFile.Write( cCSVSeparator + myStanje );
            }
            myFile.WriteLine();
            foreach( String myStanjeRedak in myTim.PromjeneStanja.Stanja )
            {
               myFile.Write( myStanjeRedak );
               foreach( String myStanjeStupac in myTim.PromjeneStanja.Stanja )
               {
                  myFile.Write( cCSVSeparator + myTim.PromjeneStanja.BrojPromjena(
myStanjeRedak, myStanjeStupac ) );
               }
               myFile.WriteLine();
            }
         }
         myFile.Close();
      }
      #endregion
      #region Log
      private void Log( string fLogText )
      {
         txtLog.Text += fLogText + Environment.NewLine;
         txtLog.SelectionStart = txtLog.TextLength;
         txtLog.ScrollToCaret();
```

```
            txtLog.Update();
        }
        #endregion
        private void btnAnaliziraj_MouseClick( object fSender, MouseEventArgs fArgs )
        {
            txtAnalizaRezultat.Text = "";
            string myPocetnoStanjeText = txtAnalizaPocetnoStanje.Text.Trim();
            int myBrojKoraka = int.Parse( txtAnalizaBrojKoraka.Text.Trim() );
            foreach( string myTim in _Podaci.Keys )
            {
                double myUkupnaVjerojatnost = 0;
                txtAnalizaRezultat.AppendText( myTim + Environment.NewLine );
                string myZavrsnaStanjaText = txtAnalizaZavrsnaStanja.Text.Replace( "\r", "" );
                Match myZavrsnaStanjaMatch = Regex.Match( myZavrsnaStanjaText,
@"(?'Stanje' [^\n]+)[\n]*", RegexOptions.IgnorePatternWhitespace |
RegexOptions.Singleline );
                while( myZavrsnaStanjaMatch.Success )
                {
                    string myZavrsnoStanje =
myZavrsnaStanjaMatch.Groups["Stanje"].Value.Trim();
                    double myVjerojatnostPromjene =
_Podaci[myTim].PromjeneStanja.VjerojatnostPromjene( myPocetnoStanjeText,
myZavrsnoStanje, myBrojKoraka );
                    txtAnalizaRezultat.AppendText( "   "
                                    + myPocetnoStanjeText + " --> "
                                    + myZavrsnoStanje
                                    + "    " + myVjerojatnostPromjene.ToString( "0.00 %" )
                                    + Environment.NewLine );
                    myUkupnaVjerojatnost += myVjerojatnostPromjene;
                    myZavrsnaStanjaMatch = myZavrsnaStanjaMatch.NextMatch();
                }
                txtAnalizaRezultat.AppendText( "   "
                                + myPocetnoStanjeText + " --> "
                                + "UKUPNO"
                                + "    " + myUkupnaVjerojatnost.ToString( "0.00 %" )
                                + Environment.NewLine );
        }
```

```
    }
    private void btnAnalizirajNapad_Click( object fSender, EventArgs fArgs )
    {
       List<string> myPocetnaStanja = GetStanja( txtAnalizaNapadaPocetnaStanja );
       List<string> myZavrsnaStanja = GetStanja(txtAnalizaNapadaZavrsnaStanja);
       List<string> myNedozvoljenaStanja = GetStanja(txtAnalizaNapadaNedozvoljenaStanja);
       int myCount;
       txtAnalizaNapada.Text = "";
      foreach( Tim myTim in _Podaci.Values )
       {
          myCount = 0;
          foreach( Napad myNapad in myTim.Napadi )
          {
             if( CheckNapad( myPocetnaStanja, myZavrsnaStanja, myNedozvoljenaStanja, myNapad ) )
             {
                myCount++;
             }
          }
          txtAnalizaNapada.AppendText( "   "
                                + myTim.Naziv + "      "
                                + "Ukupno akcija = " + myTim.Napadi.Count + "      "
                                + "Traženih akcija = " + myCount + "      "
                                +  (  (  (double)myCount  )/myTim.Napadi.Count  ).ToString( "0.00 %" )
                                + Environment.NewLine );
       }
    }
    private bool CheckNapad(List<string> fPocetnaStanja, List<string> fZavrsnaStanja, List<string> fNedozvoljenaStanja, Napad fNapad)
    {
       foreach( string myNedozvoljenoStanje in fNedozvoljenaStanja )
       {
          if( fNapad.Stanja.Contains( myNedozvoljenoStanje ) )
          {
             return false;
```

```
            }
         }
         foreach( string myPocetnoStanje in fPocetnaStanja )
         {
            foreach( string myZavrsnoStanje in fZavrsnaStanja )
            {
               if( fNapad.ZadovoljavaUvjet( myPocetnoStanje, myZavrsnoStanje, cmbVrstaAnalize.SelectedIndex ) )
               {
                  return true;
               }
            }
         }
         return false;
      }
      private static List<string> GetStanja( TextBox fStanja )
      {
         string myStanjaText = fStanja.Text.Replace( "\r", "" );
         Match myMatch = Regex.Match( myStanjaText, @"(?'Stanje' [^\n]+)[\n]*", RegexOptions.IgnorePatternWhitespace | RegexOptions.Singleline );
         List<string> myStanja = new List<string>();
         for( ; myMatch.Success; myMatch = myMatch.NextMatch() )
         {
            myStanja.Add( myMatch.Groups["Stanje"].Value.Trim() );
         }
         return myStanja;
      }
      private void btnAnalizirajFragmente_Click( object fSender, EventArgs fArgs )
      {
         int myDuljinaFragmenta = int.Parse( txtDuljinaFragmenta.Text );
         foreach( Tim myTim in _Podaci.Values )
         {
            AnalizirajFragmente( myTim, myDuljinaFragmenta, 20 );
         }
      }
      private void AnalizirajFragmente( Tim fTim, int fDuljinaFragmenta, int fPrintTopNfragments )
```

```
      {
         Dictionary<string, int> myStatistika = new Dictionary<string, int>();
         foreach( Napad myNapad in fTim.Napadi )
         {
            for( int i = 0; i <= myNapad.Stanja.Count - fDuljinaFragmenta; ++i )
            {
               string myFragmentName = "";
               for( int j = 0; j < fDuljinaFragmenta; ++j )
               {
                  myFragmentName += ( j > 0 ? "-->" : "" ) + myNapad.Stanja[i + j];
               }
               if( !myStatistika.ContainsKey( myFragmentName ) )
               {
                  myStatistika[myFragmentName] = 0;
               }
               myStatistika[myFragmentName] = myStatistika[myFragmentName] + 1;
            }
         }
         List<KeyValuePair<string, int>> myStatistika2 = new List<KeyValuePair<string,
int>>( myStatistika );
         myStatistika2.Sort( ( fA, fB ) => -fA.Value + fB.Value );
         txtAnalizaFragmenataRezultat.AppendText( ""
                                    + fTim.Naziv + "      "
                                    + "Ukupno fragmenata = " + myStatistika2.Count + "
"
                                    + Environment.NewLine );
         for( int i = 0; i < fPrintTopNfragments && i < myStatistika2.Count; ++i )
         {
            txtAnalizaFragmenataRezultat.AppendText( "   "
                                       + myStatistika2[i].Key + "                    " +
myStatistika2[i].Value
                                       + Environment.NewLine );
         }
         txtAnalizaFragmenataRezultat.AppendText( Environment.NewLine +
Environment.NewLine );
      }
      private void btnAnalizirajKompleksnost_Click( object fSender, EventArgs fArgs )
```

```
      {
         string myPrefixStanja = txtPocetakNazivaStanja.Text;
         foreach( Tim myTim in _Podaci.Values )
         {
            int myBrojTrazenihStanja = 0;
            foreach( Napad myNapad in myTim.Napadi )
            {
               foreach( string myStanje in myNapad.Stanja )
               {
                  if( myStanje.StartsWith( myPrefixStanja ) )
                  {
                     myBrojTrazenihStanja++;
                  }
               }
            }
            txtKompleksnostRezultat.AppendText( ""
                                    + myTim.Naziv + "      "
                                    + "Ukupno akcija = " + myTim.Napadi.Count + "      "
                                    + "Ukupno traženih stanja = " + myBrojTrazenihStanja
+ "      "
                                    + "Prosječno po akciji = " + (
myBrojTrazenihStanja/(double)myTim.Napadi.Count ).ToString( "#0.00" ) + ""
                                    + Environment.NewLine );
         }
      }
      private void btnAnalizirajZastupljenost_Click( object fSender, EventArgs fArgs )
      {
         List<string> myGrupaA = GetStanja( txtZastupljenostGrupaA );
         List<string> myGrupaB = GetStanja( txtZastupljenostGrupaB );
         foreach( Tim myTim in _Podaci.Values )
         {
            int myBrojTrazenihGrupaA = 0;
            int myBrojTrazenihGrupaB = 0;
            foreach( Napad myNapad in myTim.Napadi )
            {
               foreach( string myStanje in myNapad.Stanja )
```

```
            {
               if( myGrupaA.Contains( myStanje ) )
               {
                  myBrojTrazenihGrupaA++;
               }
               if( myGrupaB.Contains( myStanje ) )
               {
                  myBrojTrazenihGrupaB++;
               }
            }
         }
         txtAnalizaZastupljenostiRezultat.AppendText( ""
                                    + myTim.Naziv + "      "
                                    + "Ukupno akcija = " + myTim.Napadi.Count + "
"
                                    + "Ukupno stanja iz GrupeA = " +
myBrojTrazenihGrupaA + "      "
                                    + "Ukupno stanja iz GrupeB = " +
myBrojTrazenihGrupaB + "      "
                                    + "Relativan odnos = " + (
myBrojTrazenihGrupaA/(double)myBrojTrazenihGrupaB*100 ).ToString( "#0.00" ) + "%"
                                    + Environment.NewLine );
      }
   }

   private void btnAgresivnost_Click( object fSender, EventArgs fArgs )
   {
      string myPrvoStanje = txtAgresivnostPrvoStanje.Text;
      string myNStanje = txtAgresivnostNtoStanje.Text;
      string myN1Stanje = txtAgresivnostN1Stanje.Text;
      string myNKStanje = txtAgresivnostNKStanje.Text;
      bool myLabavoPrvoStanje = chkLabavoPrvoStanje.Checked;
      foreach( Tim myTim in _Podaci.Values )
      {
         int myNapadi = 0;
         foreach( Napad myNapad in myTim.Napadi )
         {
```

```
            if( NapadJeAgresivan( myNapad, myPrvoStanje, myLabavoPrvoStanje,
myNStanje, myN1Stanje, myNKStanje ) )
            {
               myNapadi++;
            }
         }
         txtAgresivnostRezultat.AppendText( ""
                                 + myTim.Naziv + "      "
                                 + "Ukupno akcija = " + myTim.Napadi.Count + "      "
                                 + "Agresivnih akcija = " + myNapadi + "      "
                                 + "Postotak = " + (
myNapadi/(double)myTim.Napadi.Count*100 ).ToString( "#0.00" ) + "%"
                                 + Environment.NewLine );
      }
   }
   private bool NapadJeAgresivan(Napad fNapad, string fPrvoStanje, bool
fLabavoPrvoStanje, string fNStanje, string fN1Stanje, string fNKStanje)
   {
      for (int p = 0; p < fNapad.Stanja.Count - 1; ++p)
      {
         if ((fNapad.Stanja[p] + "#").StartsWith(fPrvoStanje))
         {
            for (int i = p+1; i < fNapad.Stanja.Count - 1; ++i)
            {
               if ((fNapad.Stanja[i] + "#").StartsWith(fNStanje) && (fNapad.Stanja[i + 1]
+ "#").StartsWith(fN1Stanje))
               {
                  for (int k = i + 2; k < fNapad.Stanja.Count - 1; ++k)
                  {
                     if ((fNapad.Stanja[k] + "#").StartsWith(fNKStanje))
                     {
                        return true;
                     }
                  }
               }
            }
         }
```

```
            if (!fLabavoPrvoStanje)
                return false;
        }
        return false;
    }
    private void btnH1_Click( object sender, EventArgs e )
    {
        int myBrojKoraka = Int32.Parse( txtH1BrojKoraka.Text );
        double myZnacajnaRazlika = double.Parse( txtH1ZnacajnaRazlika.Text ) / 100;
        List<string> myUspjesnaStanja = GetStanja( txtH1UspjesnaStanja );
        foreach( Tim myTim in _Podaci.Values )
        {
            Dictionary<String, double> myVjerojatnosti = new Dictionary<string, double>();
            foreach( String myStanje in myTim.PromjeneStanja.Stanja )
            {
                double myVjerojatnost = 0;
                foreach( String myUspjesnoStanje in myUspjesnaStanja )
                {
                    myVjerojatnost += myTim.PromjeneStanja.VjerojatnostPromjene(
myStanje, myUspjesnoStanje, myBrojKoraka );
                }

                myVjerojatnosti.Add( myStanje, myVjerojatnost );
            }

            List<String> myStanja = new List<string>( myTim.PromjeneStanja.Stanja );
            myStanja.Sort( ( fStanjeA, fStanjeB ) => myVjerojatnosti[fStanjeA].CompareTo(
myVjerojatnosti[fStanjeB] ) );
            txtH1Rezultat.AppendText( myTim.Naziv + Environment.NewLine +
Environment.NewLine );
            bool myIsPrvoStanje = true;
            bool myPostojiPodjela = false;
            bool myIspisanaCrta = false;
            double myLastValue = 0;
            foreach( String myStanje in myStanja )
            {
```

```
            if( (!myIsPrvoStanje) && (!myIspisanaCrta) && (myVjerojatnosti[myStanje] -
myLastValue > myZnacajnaRazlika) )
            {
               txtH1Rezultat.AppendText( "----------------------------------------------------
--------------" + Environment.NewLine );
               myPostojiPodjela = true;
               myIspisanaCrta = true;
            }
            txtH1Rezultat.AppendText(  myStanje  +  "                              "  +
myVjerojatnosti[myStanje].ToString(              "P04"              )              +
((myVjerojatnosti[myStanje]*1000)%2==1?"  *":"") + Environment.NewLine );
            myLastValue = myVjerojatnosti[myStanje];
            myIsPrvoStanje = false;
         }

         txtH1Rezultat.AppendText( Environment.NewLine  );
/*          if( myPostojiPodjela )
         {
            txtH1Rezultat.AppendText( "                                >>>>>>>>>>>
POSTOJI PODJELA" + Environment.NewLine );
         }
         else*/
         {
            txtH1Rezultat.AppendText( "                               >>>>>>>>>>> NE
POSTOJI PODJELA" + Environment.NewLine );
         }
         txtH1Rezultat.AppendText(  Environment.NewLine  +  Environment.NewLine  +
Environment.NewLine + Environment.NewLine );
      }
   }
   private void btnH2Analiziraj_Click( object sender, EventArgs e )
   {
      double myDonjaGranica = double.Parse( txtH2DonjaGranica.Text );
      double myGornjaGranica = double.Parse( txtH2GornjaGranica.Text );
      List<string> myPocetnaStanja = GetStanja( txtH2GrupaA );
      List<string> myZavrsnaStanja = GetStanja( txtH2GrupaB );
      foreach( Tim myTim in _Podaci.Values )
      {
```

```
            double myVjerojatnost = 0;
            foreach( String myPocetnoStanje in myPocetnaStanja )
            {
               double myVjerojatnost2 = 0;
               foreach( String myZavrsnoStanje in myZavrsnaStanja )
               {
                  myVjerojatnost      +=      myTim.PromjeneStanja.VjerojatnostPromjene(
myPocetnoStanje, myZavrsnoStanje, 1 );
                  myVjerojatnost2     +=      myTim.PromjeneStanja.VjerojatnostPromjene(
myPocetnoStanje, myZavrsnoStanje, 1 );
               }
               txtH2Rezultat2.AppendText( ""
                     + myTim.Naziv + Environment.NewLine
                     +       "Vjerojatnost       ["+myPocetnoStanje+"]:       "       +
myVjerojatnost2.ToString( "P04" )
                     + "           "
                     + (myVjerojatnost2 <= myDonjaGranica ? "MANJE OD DONJE
GRANICE" + ((myVjerojatnost2*1000)%10<9?"*":"") : "")
                     + (myVjerojatnost2 >= myGornjaGranica ? "VECE OD GORNJE
GRANICE" + ((myVjerojatnost2 * 1000) % 10 < 9 ? "*" : "") : "")
                     + "           "
                     + Environment.NewLine
                     );
            }
            txtH2Rezultat2.AppendText( ""
                           + myTim.Naziv + Environment.NewLine
                           + "Vjerojatnost: " + myVjerojatnost.ToString( "P04" )
                           + "           "
                           + (myVjerojatnost <= myDonjaGranica ? "MANJE OD DONJE
GRANICE" + ((myVjerojatnost * 1000) % 10 < 9 ? "*" : "") : "")
                           + (myVjerojatnost >= myGornjaGranica ? "VECE OD GORNJE
GRANICE" + ((myVjerojatnost * 1000) % 10 < 9 ? "*" : "") : "")
                           + "           "
                           + Environment.NewLine
                           + Environment.NewLine
                           );
         }
      }
```

```
   }
}
```

Napad.cs

```
using System;
using System.Collections.Generic;
namespace Analiza
{
   public class Napad
   {
      public List<string> Stanja { get; private set; }
      public Napad()
      {
         Stanja = new List<string>();
      }
      public void DodajStanje( string fStanje )
      {
         Stanja.Add( fStanje );
      }
      public bool ZadovoljavaUvjet( string fPocetnoStanje, string fZavrsnoStanje, int fTipUvjeta )
      {
         switch( fTipUvjeta )
         {
            case 0: //Napad prelazi iz nekog stanja u grupi A u neko stanje u grupi B
               int myPocetno = Stanja.FindIndex( fStanje => fStanje == fPocetnoStanje );
               int myZavrsno = Stanja.FindLastIndex( fStanje => fStanje == fZavrsnoStanje );
               return ( myPocetno != -1 ) && ( myZavrsno != -1 ) && ( myPocetno < myZavrsno );
               break;
            case 1: //Napad direktno prelazi iz nekog stanja u grupi A u neko stanje u grupi B
               int myCurrentItem = 0;
               while (myCurrentItem < Stanja.Count)
               {
                  myCurrentItem = Stanja.FindIndex( myCurrentItem, fStanje => fStanje == fPocetnoStanje );
```

```
                if( ( myCurrentItem == - 1 ) || ( myCurrentItem == Stanja.Count - 1 ) )
                {
                   return false;
                }
                if( Stanja[myCurrentItem + 1] == fZavrsnoStanje )
                {
                   return true;
                }
                myCurrentItem++;
             }
             break;
          case 2: //Napad sadrži neko stanje iz grupe A i neko stanje iz grupe B
             int myPocetno2 = Stanja.FindIndex(fStanje => fStanje == fPocetnoStanje);
             int myZavrsno2 = Stanja.FindLastIndex(fStanje => fStanje ==
fZavrsnoStanje);
             return (myPocetno2 != -1) && (myZavrsno2 != -1);
             break;
       }
       return false;
    }
  }
}
```

Promjene stanja.cs

```
using System.Collections.Generic;
namespace Analiza
{
  public class PromjeneStanja
  {
    private readonly List<string> _Stanja;
    private readonly Dictionary<string, int> _Promjene;
    private readonly Dictionary<int, double[,]> _VjerojatnostiPromjene;
    public PromjeneStanja()
    {
      _Stanja = new List<string>();
      _Promjene = new Dictionary<string, int>();
      _VjerojatnostiPromjene = new Dictionary<int, double[,]>();
```

```
    }
    public List<string> Stanja
    {
       get { return _Stanja; }
    }
    public void Dodaj( string fPocetnoStanje, string fKrajnjeStanje )
    {
       Dodaj( fPocetnoStanje, fKrajnjeStanje, 1 );
    }
    public void Dodaj( string fPocetnoStanje, string fKrajnjeStanje, int fCount )
    {
       if( !_Stanja.Contains( fPocetnoStanje ) )
       {
          _Stanja.Add( fPocetnoStanje );
          _Stanja.Sort();
       }
       if( !_Stanja.Contains( fKrajnjeStanje ) )
       {
          _Stanja.Add( fKrajnjeStanje );
          _Stanja.Sort();
       }
       string myPromjenaNaziv = KreirajNazivPromjeneStanja( fPocetnoStanje,
fKrajnjeStanje );
       if( !_Promjene.ContainsKey( myPromjenaNaziv ) )
       {
          _Promjene.Add( myPromjenaNaziv, 0 );
       }
       _Promjene[myPromjenaNaziv] += fCount;
    }
    public int BrojPromjena( string fPocetnoStanje, string fKrajnjeStanje )
    {
       string myPromjenaNaziv = KreirajNazivPromjeneStanja( fPocetnoStanje,
fKrajnjeStanje );
       if( !_Promjene.ContainsKey( myPromjenaNaziv ) )
       {
          return 0;
```

```
        }
        return _Promjene[myPromjenaNaziv];
    }
    public double VjerojatnostPromjene( string fPocetnoStanje, string fKrajnjeStanje, int fBrojKoraka )
    {
        if( _Stanja.IndexOf( fPocetnoStanje ) == -1 || _Stanja.IndexOf( fKrajnjeStanje ) == -1 )
        {
            return 0;
        }
        if( !_VjerojatnostiPromjene.ContainsKey( fBrojKoraka ) )
        {
            // matrica vjerojatnosti za fBrojKoraka ne postoji
            double[,] myVjerojatnost, myOriginal;
            myVjerojatnost = new double[_Stanja.Count, _Stanja.Count];
            myOriginal = new double[_Stanja.Count, _Stanja.Count];
            for( int i = 0 ; i < _Stanja.Count ; ++i )
            {
                for( int j = 0 ; j < _Stanja.Count ; ++j )
                {
                    myOriginal[i, j] = VjerojatnostJednePromjene( _Stanja[i], _Stanja[j] );
                    myVjerojatnost[i, j] = myOriginal[i, j];
                }
            }
            for( int myKorak = 1 ; myKorak < fBrojKoraka ; ++myKorak )
            {
                double[,] myRezultat = new double[_Stanja.Count, _Stanja.Count];
                for( int i = 0 ; i < _Stanja.Count ; ++i )
                {
                    for( int j = 0 ; j < _Stanja.Count ; ++j )
                    {
                        myRezultat[i, j] = 0;
                        for( int k = 0 ; k < _Stanja.Count ; ++k )
                        {
                            myRezultat[i, j] += myVjerojatnost[i, k] * myOriginal[k, j];
```

```
                    }
                }
            }
            for( int i = 0 ; i < _Stanja.Count ; ++i )
            {
                for( int j = 0 ; j < _Stanja.Count ; ++j )
                {
                    myVjerojatnost[i, j] = myRezultat[i, j];
                }
            }
        }
        _VjerojatnostiPromjene[fBrojKoraka] = myVjerojatnost;
    }
    return _VjerojatnostiPromjene[fBrojKoraka][_Stanja.IndexOf( fPocetnoStanje ),
_Stanja.IndexOf( fKrajnjeStanje )];
  }
  private double VjerojatnostJednePromjene( string fPocetnoStanje, string fKrajnjeStanje
)
  {
    string myPromjenaNaziv;
    int myUkupnoPromjena = 0;

    foreach( var myStanje in _Stanja )
    {
      myPromjenaNaziv = KreirajNazivPromjeneStanja( fPocetnoStanje, myStanje );
      if( _Promjene.ContainsKey( myPromjenaNaziv ) )
      {
        myUkupnoPromjena += _Promjene[myPromjenaNaziv];
      }
    }
    if (myUkupnoPromjena == 0)
      return 0;
    myPromjenaNaziv = KreirajNazivPromjeneStanja( fPocetnoStanje, fKrajnjeStanje );
    if( !_Promjene.ContainsKey( myPromjenaNaziv ) )
    {
      return 0;
```

```
        }
        return _Promjene[myPromjenaNaziv]/( (double)myUkupnoPromjena );
    }
    private static string KreirajNazivPromjeneStanja( string fPocetnoStanje, string fKrajnjeStanje )
    {
        return fPocetnoStanje + "-->" + fKrajnjeStanje;
    }
  }
}
```

10.2. Prilog 2 – Izlazni rezultati programa SSA

U ovom prilogu dani su rezultati generirani software-om u kontekstu pri dokazivanju hipoteze H1. Zbog prevelikog opsega prikazani podaci generirani za broj koraka u lancu k=3 i danu razliku vjerojatnosti od 1%.

```
V_TN_S_49     0.0000 %
V_PN_Z_8      0.0000 %
V_TN_Z        0.0000 %
V_U_4         0.0000 %
V_TN_Z_45     0.0000 %
V_PN_Z_27     0.0000 %
V_PN_S_87     0.0000 %
V_TN_S_32     0.0000 %
V_TN_S_27     0.00000 %
V_N_1         0.0000 %
V_N_7         0.0000 %
V_N_SO        0.0000 %
V_N_8         0.0000 %
```

V_N_TURN 0.0000 %
V_PN_Z_21 0.1299 %
V_TN_Z_43 0.2597 %
V_TN_Z_42 0.2597 %
V_PN_Z_25 0.6149 %
V_TN_Z_20 0.8065 %
V_TN_S_4 1.1683 %
V_U_3 1.3199 %
V_U_1 1.3199 %
V_NOGA 1.3458 %
V_TN_I_17 1.4975 %
V_N_5 1.6915 %
V_TN_I_2 1.7121 %
V_PN_S_19 1.7805 %
V_TN_I_4 1.8005 %
V_TN_S_8 1.8011 %
V_TN_I_3 1.8268 %
V_PN_S_80 1.8789 %
V_JB 1.9022 %
V_U_5 1.9121 %
V_TN_I_18 1.9438 %
V_PN_Z_16 1.9965 %
V_PN_I_47 2.0723 %
V_PN_S_53 2.0822 %
V_U_8 2.0905 %
V_PN_S_79 2.0944 %
V_PN_S_5 2.1339 %
V_TN_I_16 2.1605 %
V_PN_S_30 2.1703 %
V_TN_S_11 2.2239 %
V_TN_I_21 2.2268 %
V_PN_S_123 2.2620 %
V_TN_I_9 2.2982 %
V_PN_S_69 2.3081 %
V_TN_S_46 2.3141 %
V_PN_I_1 2.3960 %

V_PN_S_82 2.4117 %
V_TN_I_8 2.4450 %
V_PN_S_84 2.4605 %
V_PN_I_8 2.4897 %
V_PN_I_3 2.5010 %
V_PN_S_26 2.5076 %
V_TN_I_19 2.5396 %
V_PN_I_2 2.5741 %
V_PN_I_14 2.6591 %
V_PN_I_12 2.6791 %
V_TN_S_1 2.7237 %
V_U_9 2.7361 %
V_PN_S_75 2.7539 %
V_PN_S_36 2.7602 %
V_PN_S_78 2.7713 %
V_PN_S_73 2.7811 %
V_PN_I_19 2.7989 %
V_PN_S_68 2.8215 %
V_PN_S_6 2.8276 %
V_PN_I_4 2.8456 %
V_TN_I_20 2.8735 %
V_PN_I_6 2.8949 %
V_PN_S_71 2.9038 %
V_TN_I_1 2.9091 %
V_PN_Z_22 2.9091 %
V_TN_I_7 2.9114 %
V_PN_I_15 2.9130 %
V_PN_S_70 2.9193 %
V_TN_S_14 2.9644 %
V_PN_S_27 2.9688 %
V_PN_S_74 2.9834 %
V_PN_S_89 2.9841 %
V_TN_I_6 3.0468 %
V_PN_S_50 3.0886 %
V_PN_I_13 3.1918 %
V_PN_S_31 3.2237 %

V_PN_S_72 3.2486 %
V_PN_I_9 3.2845 %
V_PN_I_11 3.3299 %
V_PN_S_49 3.3434 %
V_PN_S_32 3.4349 %
V_PN_S_41 3.4386 %
V_PN_S_55 3.5143 %
V_TN_S_9 3.5528 %
V_TN_Z_38 3.5632 %
V_TN_I_5 3.6019 %
V_TN_I_10 3.6186 %
V_PN_S_35 3.6458 %
V_PN_Z_23 3.7349 %
V_TN_Z_39 3.7447 %
V_PN_S_83 3.7900 %
V_PN_I_7 3.8183 %
V_PN_S_28 3.9399 %
V_PN_S_47 3.9547 %
V_PN_S_44 4.0286 %
V_PN_S_64 4.1356 %
V_PN_S_24 4.1541 %
V_PN_S_7 4.2096 %
V_PN_S_34 4.2666 %
V_PN_S_17 4.3276 %
V_PN_S_4 4.4346 %
V_PN_S_1 4.4667 %
V_PN_Z_17 4.4702 %
V_PN_S_52 4.4773 %
V_PN_S_48 4.4887 %
V_TN_Z_44 4.4907 %
V_TN_Z_25 4.6451 %
V_TN_I_11 4.7529 %
V_PN_S_37 4.8772 %
V_TN_S_3 4.8939 %
V_TN_S_6 4.9192 %
V_PN_S_29 4.9391 %

V_PN_S_56	5.0500 %
V_PN_S_77	5.0518 %
V_PN_S_45	5.0927 %
V_TN_S_12	5.2246 %
V_PN_S_39	5.4598 %
xxx	5.5331 %
V_PN_S_42	5.5624 %
V_PN_S_43	5.5780 %
V_PN_S_40	5.6591 %
V_TN_I_14	5.6778 %
V_PN_S_60	5.6911 %
V_PN_I_10	5.7160 %
V_PN_S_54	5.7734 %
V_PN_4	5.8074 %
V_TN_S_50	5.9749 %
V_TN_I_15	6.0486 %
V_TN_S_13	6.1008 %
V_PN_S_59	6.1084 %
V_PN_S_58	6.1987 %
V_PN_S_63	6.2193 %
V_PN_S_57	6.2906 %
V_PN_S_61	6.3624 %
V_PN_S_46	6.4361 %
V_PN_S_18	6.6292 %
V_PN_I_30	6.6292 %
V_PN_Z_34	6.6292 %
V_PN_S_66	7.0474 %
V_PN_Z_47	7.0474 %
V_PN_S_62	7.1453 %
V_PN_Z_18	7.1666 %
V_PN_I_18	7.1673 %
V_TN_Z_26	7.3145 %
V_PN_Z_19	7.3410 %
V_PN_Z_24	7.3418 %
V_PN_Z_33	7.3418 %
V_PN_S_91	7.4192 %

V_PN_S_86 7.4698 %
V_TN_S_7 7.5276 %
V_PN_S_25 7.7460 %
V_TN_Z_40 8.0517 %
V_PN_S_67 8.4052 %
V_PN_S_90 8.4300 %
V_TN_S_2a 8.8645 %
V_PN_S_88 8.9456 %
V_PN_Z_26 8.9456 %
V_PN_Z_38 8.9456 %
V_PN_Z_12 8.9456 %
V_TN_Z_41 9.2176 %
V_PN_I_5 9.2905 %
V_PN_S_92 9.4188 %
V_PN_S_2 10.2956 %
V_PN_S_12 10.3292 %
V_PN_S_38 10.5279 %
V_PN_S_65 10.7631 %
V_NEUT_SN 10.7903 %
V_PN_S_95 11.2820 %
V_B_N 11.3878 %
V_TN_S_10 11.5730 %
V_PN_S_96 11.6085 %

V_PN_S_3 13.7356 %
V_TN_Z_23 13.9732 %
V_PN_S_93 14.1414 %
V_TN_Z_21 14.4938 %
V_TN_S_15 14.6387 %
V_TN_S_14 15.0269 %
V_TN_S_2 15.0975 %
V_TN_Z_15 15.1838 %
V_PN_S_16 15.2157 %
V_TN_S_5 15.4219 %
V_TN_Z_22 15.9810 %
V_PN_S_9 16.0612 %

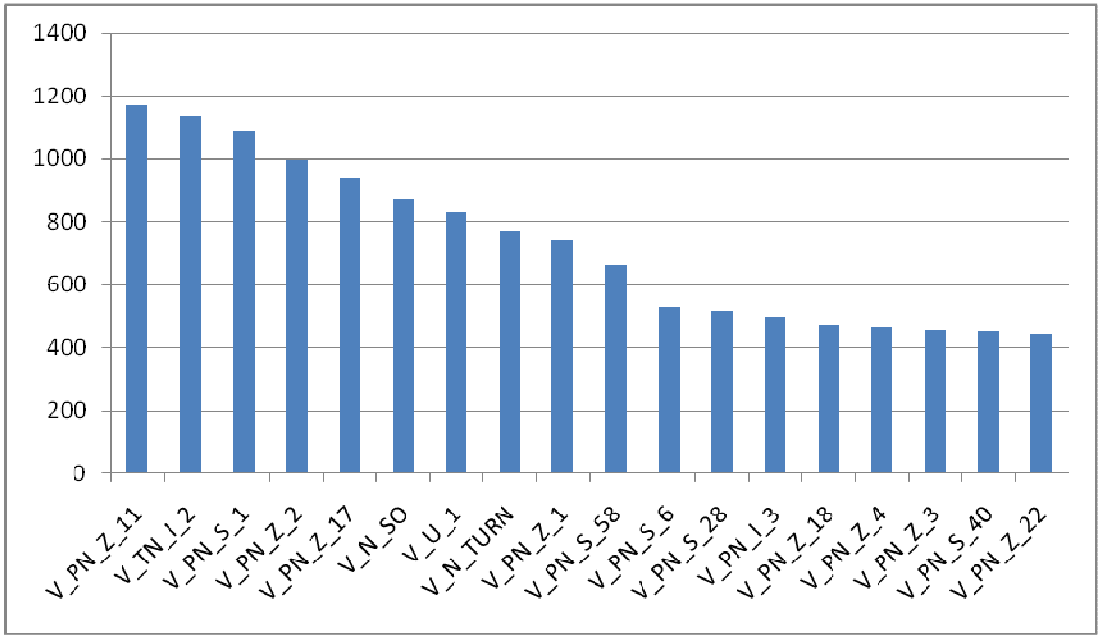
V_TN_Z_10	16.0829 %
V_PN_S_13	16.2221 %
V_TN_S_18	16.9022 %
V_PN_Z_11	18.1764 %
V_TN_Z_9	18.3348 %
V_PN_S_10	18.8894 %
V_PN_S_8	19.4510 %
V_PN_Z_9	21.2546 %
V_TN_Z_8	21.2982 %
V_PN_Z_5	21.6448 %
V_TN_I_12	21.8699 %
V_TN_Z_12	22.4385 %
V_PN_S_22	22.4982 %
V_TN_Z_17	22.6753 %
V_U_7	23.1156 %
V_TN_Z_5	23.4520 %
V_PN_Z_14	23.4567 %
V_TN_Z_14	23.4800 %
V_PN_Z_13	24.0389 %
V_PN_S_14	24.0644 %
V_PN_S_15	24.6435 %
V_PN_S_21	24.8579 %
V_PN_Z_15	24.9656 %
V_PN_Z_6	25.8206 %
V_PN_S_94	25.8207 %
V_TN_Z_36	25.8699 %
V_TN_Z_32	26.2634 %
V_TN_Z_4	26.2935 %
V_PN_S_23	26.7536 %
V_PN_Z_10	26.7700 %
V_TN_S_24	26.8165 %
V_PN_Z_32	27.1334 %
V_U_6	27.1334 %
V_U_2	27.1334 %
V_TN_Z_7	27.4060 %
V_TN_Z_16	27.6517 %

V_TN_Z_3 29.6219 %
V_PN_Z_4 30.2693 %
V_TN_Z_37 31.6808 %
V_NEUT_SN_N 31.6910 %
V_TN_Z_2 31.8507 %
V_TN_Z_11 32.6421 %
V_TN_Z_35 33.5274 %
V_PN_Z_2 34.1383 %
V_TN_Z_13 34.5814 %
V_TN_Z_33 34.6536 %
V_PN_Z_7 34.7951 %
V_TN_Z_28 35.1090 %
V_TN_Z_31 37.9197 %
V_TN_Z_34 39.4808 %
V_PN_Z_3 39.7733 %
V_TN_Z_1 39.8604 %
V_PN_Z_1 40.3661 %
V_TN_Z_6 40.8958 %
V_TN_Z_30 41.1696 %
V_PN_Z_74 43.7520 %
V_PN_5 43.7520 %
V_TN_Z_29 43.8087 %
V_TN_Z_27 45.7019 %
V_TN_Z_18 45.7019 %
V_PN_Z_28 50.0000 %
>> >>>>>>>>>>> NE POSTOJI PODJELA

10.3. Prilog 3 - Najučestalija stanja napada

U ovom prilogu je prikazano 20 najfrekventnijih stanja napada.

Slika 10.1: 20 najfrekventnijih stanja napada



10.4. Prilog 4 - Najučestaliji fragmenti napadačkih akcija

U ovom dodatku su dani najfrekventniji fragmenti napadačkih akcija duljine 3, 4 i 5 te njihova frekvencija i uspješnost.

Duljina napada: 3	**Ukupno fragmenata** = 17975	
Fragmenti (Stanje1->Stanje2->Stanje3)	**Broj pojavljivanja**	**Uspješnost (%)**
V_PN_Z_2-->V_PN_Z_17-->V_U_1	193	100
V_TN_I_2-->V_TN_S_1-->V_PN_I_3	193	47,4
V_PN_S_58-->V_PN_Z_11-->V_PN_Z_6	183	52,3

V_PN_Z_6-->V_PN_Z_2-->V_PN_Z_17	167	55,4
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_2	159	53,4
V_PN_Z_1-->V_PN_Z_17-->V_N_SO	143	0
V_TN_I_2-->V_TN_S_1-->V_PN_I_14	143	49,9
V_TN_S_1-->V_PN_I_3-->V_PN_S_60	129	46,4
V_TN_S_1-->V_PN_I_3-->V_PN_S_1	126	46,2
V_TN_I_2-->V_TN_S_1-->V_PN_I_6	124	51,1
V_PN_Z_4-->V_PN_Z_2-->V_PN_Z_17	114	52,6
V_TN_S_1-->V_PN_I_1-->V_PN_S_1	112	50,2
V_PN_S_57-->V_PN_Z_11-->V_PN_Z_6	110	53,5
V_PN_Z_2-->V_PN_Z_17-->V_N_SO	109	0
V_PN_Z_2-->V_PN_Z_22-->V_U_1	104	100
V_PN_Z_6-->V_PN_Z_4-->V_PN_Z_2	102	52,1
V_PN_Z_1-->V_PN_Z_17-->V_U_3	101	100
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_1	100	53,3
V_TN_S_1-->V_PN_I_14-->V_PN_S_24	95	47,6
V_PN_Z_6-->V_PN_Z_1-->V_PN_Z_17	92	49,1

Duljina napada: 4	**Ukupno fragmenata** = 11877	
Fragmenti (Stanje1->Stanje2->Stanje3->Stanje4)	**Broj pojavljivanja**	**Uspješnost (%)**
V_PN_Z_6-->V_PN_Z_2-->V_PN_Z_17-->V_U_1	81	100
V_TN_I_2-->V_TN_S_1-->V_PN_I_3-->V_PN_S_60	78	51,3

V_TN_I_2-->V_TN_S_1-->V_PN_I_14-->V_PN_S_24	68	49,2
V_PN_Z_4-->V_PN_Z_2-->V_PN_Z_17-->V_U_1	68	100
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_2-->V_PN_Z_17	67	44,7
V_TN_I_2-->V_TN_S_1-->V_PN_I_3-->V_PN_S_1	66	51,7
V_TN_I_2-->V_TN_S_1-->V_PN_I_1-->V_PN_S_1	63	49,9
V_PN_S_58-->V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_2	57	52,0
V_TN_S_1-->V_PN_I_3-->V_PN_S_60-->V_PN_Z_11	53	51,5
V_PN_Z_6-->V_PN_Z_4-->V_PN_Z_2-->V_PN_Z_17	50	46,8
V_PN_Z_6-->V_PN_Z_2-->V_PN_Z_17-->V_N_SO	49	0
V_TN_I_2-->V_TN_S_1-->V_PN_I_6-->V_PN_S_44	47	51,6
V_PN_Z_4-->V_PN_Z_2-->V_PN_Z_22-->V_U_1	44	100
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_1-->V_PN_Z_17	44	52,2
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_4-->V_PN_Z_2	42	53,0
V_TN_S_1-->V_PN_I_1-->V_PN_S_1-->V_PN_S_6	41	49,6
V_PN_Z_6-->V_PN_Z_1-->V_PN_Z_17-->V_N_SO	39	0
V_TN_S_1-->V_PN_I_1-->V_PN_S_1-->V_PN_S_31	39	44,7
V_PN_S_58-->V_PN_Z_11-->V_PN_Z_4-->V_PN_Z_2	39	50,5

V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_2-->V_PN_Z_22	39	49,6

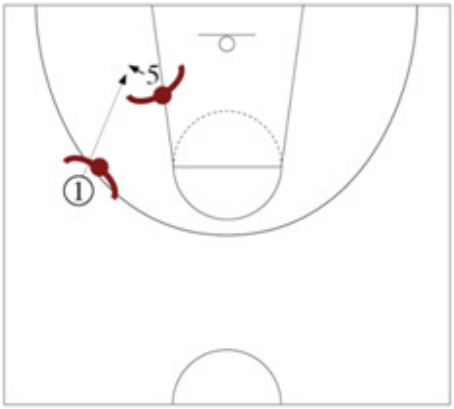
Duljina napada: 5	**Ukupno fragmenata** = 6325	
Fragmenti (Stanje1->Stanje2->Stanje3->Stanje4->Stanje5)	**Broj pojavljivanja**	**Uspješnost (%)**
V_TN_I_2-->V_TN_S_1-->V_PN_I_3-->V_PN_S_60-->V_PN_Z_11	33	51,7
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_2-->V_PN_Z_17-->V_U_1	33	100
V_PN_Z_6-->V_PN_Z_4-->V_PN_Z_2-->V_PN_Z_17-->V_U_1	30	100
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_4-->V_PN_Z_2-->V_PN_Z_17	28	54,4
V_TN_S_1-->V_PN_I_3-->V_PN_S_1-->V_PN_S_6-->V_PN_S_28	27	50,9
V_TN_I_2-->V_TN_S_1-->V_PN_I_1-->V_PN_S_1-->V_PN_S_31	25	47,9
V_TN_I_2-->V_TN_S_1-->V_PN_I_6-->V_PN_S_44-->V_PN_S_42	25	46,8
V_TN_S_1-->V_PN_I_3-->V_PN_S_60-->V_PN_Z_11-->V_PN_Z_6	24	49,1
V_TN_I_2-->V_TN_S_1-->V_PN_I_1-->V_PN_S_1-->V_PN_S_6	24	51,9
V_TN_I_2-->V_TN_S_1-->V_PN_I_3-->V_PN_S_1-->V_PN_S_6	23	52,2
V_PN_Z_11-->V_PN_Z_4-->V_PN_Z_2-->V_PN_Z_22-->V_U_1	22	100
V_TN_S_1-->V_PN_I_1-->V_PN_S_1-->V_PN_S_31-->V_PN_S_1	21	44,6
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_2--	20	20

>V_PN_Z_17-->V_N_SO		
V_PN_S_58-->V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_2-->V_PN_Z_17	20	51,7
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_1-->V_PN_Z_17-->V_N_SO 19(0%)	19	0
V_TN_I_2-->V_TN_S_1-->V_PN_I_3-->V_PN_S_60-->V_PN_S_40	19	53,3
V_PN_S_58-->V_PN_Z_11-->V_PN_Z_4-->V_PN_Z_2-->V_PN_Z_22	18	51,0
V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_1-->V_PN_Z_18-->V_N_SO	17	0
V_PN_S_58-->V_PN_Z_11-->V_PN_Z_6-->V_PN_Z_4-->V_PN_Z_2	17	53,9
V_TN_S_1-->V_PN_I_1-->V_PN_S_1-->V_PN_S_6-->V_PN_S_28	16	55,1

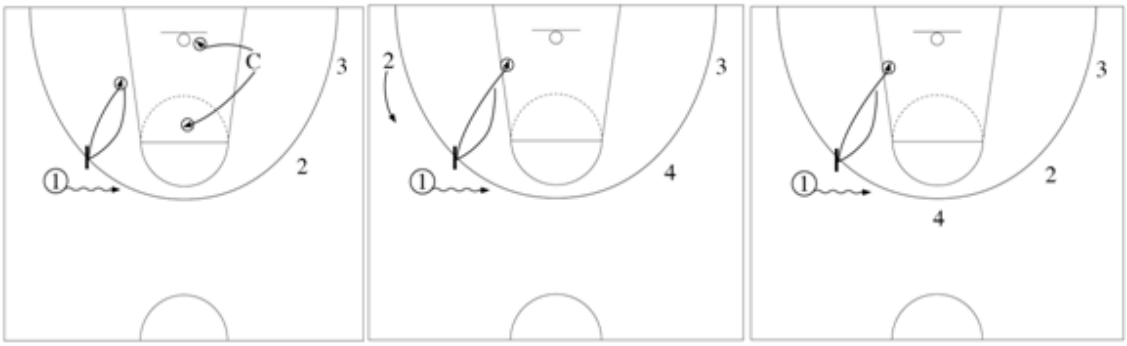
10.5. Prilog 5 - Dijagrami stanja pozicijskog napada

U ovom prilogu dan je shematski prikaz najvažnijih stanja košarkaške igre u fazi napada.

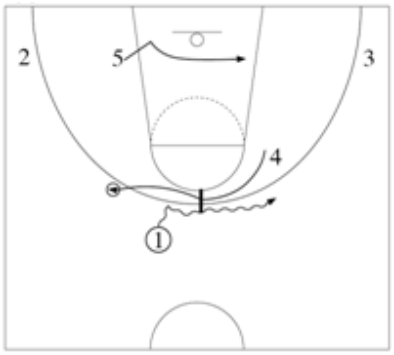
Dijagram 1: Igra na niskom postu (*low post game*)



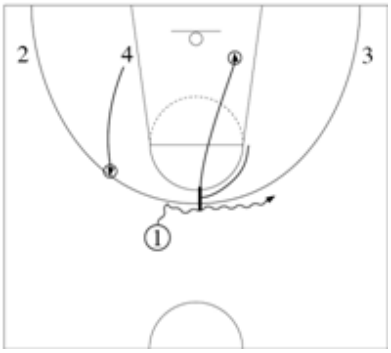
Dijagram 2a, 2b i 2c: *Pick and roll* manevar na strani



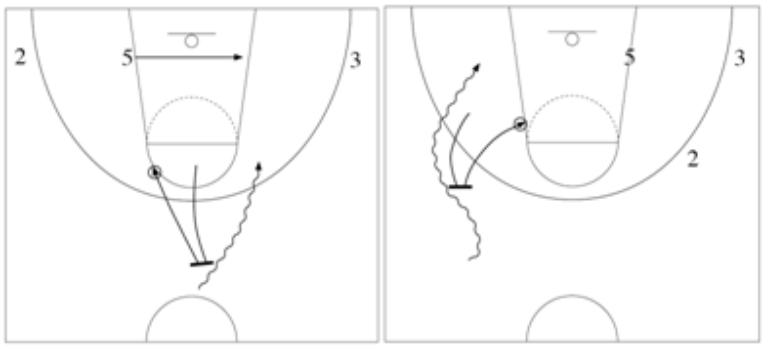
Dijagram 3: *Pick and pop* manevar na sredini



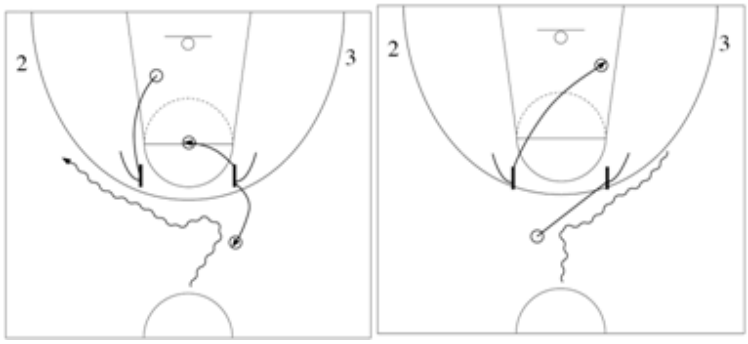
Dijagram 4: *Pick and roll* manevar na sredini



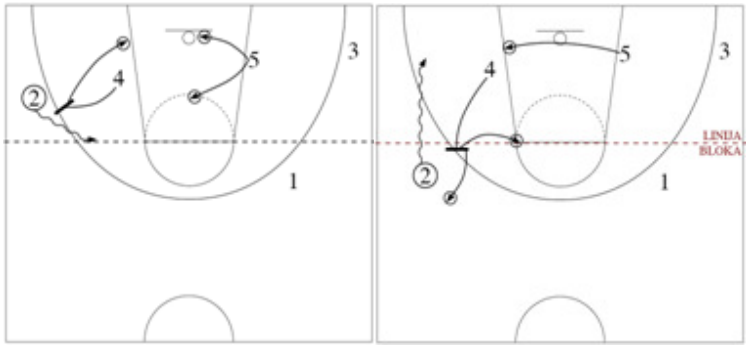
Dijagram 5a i 5b: *Flat pick* – leđni blok na igraču s loptom



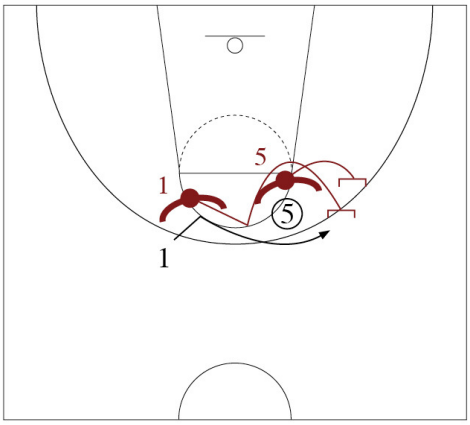
Dijagram 6a i 6b: *Pick and roll/pop* na rubu linije slobodnih bacanja (*elbow*)



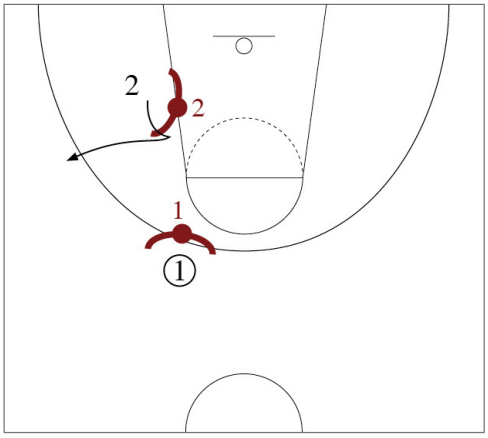
Dijagram 7a i 7b: *Pick and roll* manevar na krilu (*wing*) s vanjske/unutarnje strane



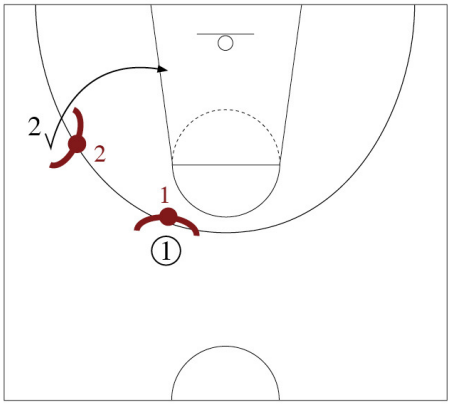
Dijagram 8: Uručenje lopte (*handoff*)



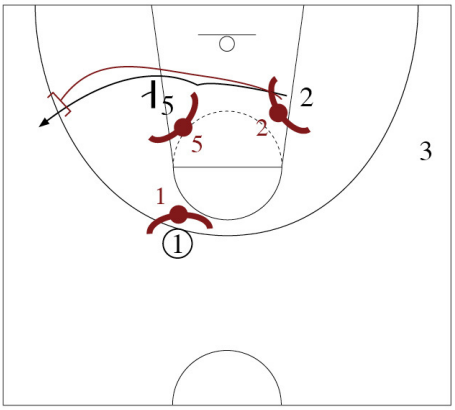
Dijagram 9: Vanjsko otvaranje (*V-cut*)



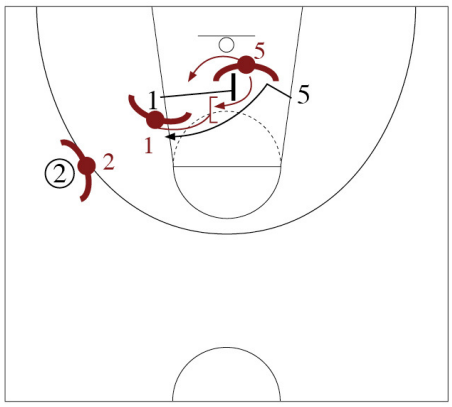
Dijagram 10: Utrčavanje iza leđa (*Backdoor cut*)



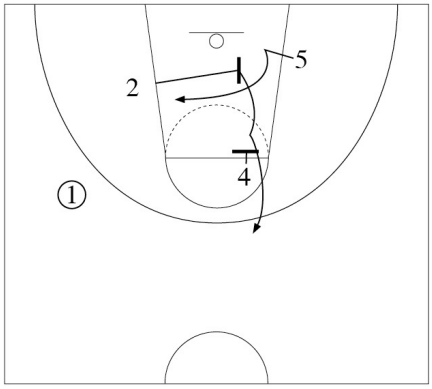
Dijagram 11: Čeonolinijski blok (*Baseline screen*)



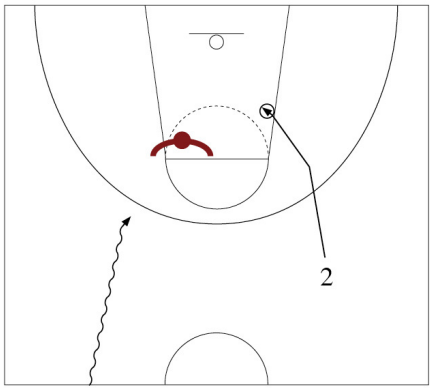
Dijagram 12: Horizontalni blok preko reketa (*Cross screen*)



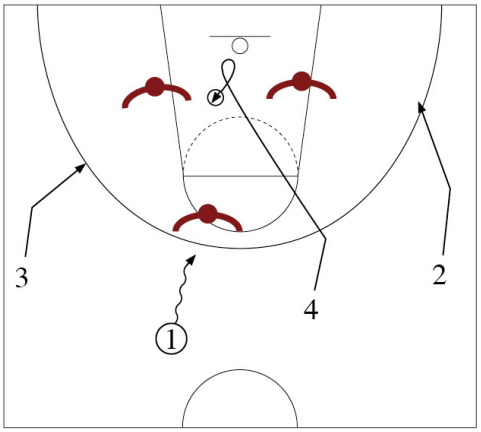
Dijagram 13: Blok za blokera (Screen for screener)



Dijagram 14: Primarni kontranapad 2 na 1



Dijagram 15: Sekundarni protunapad 4 na 3



Dijagram 16a i 16b: Rani napad i rani napad *high-low*

