

UNIVERZA V LJUBLJANI
FAKULTETA ZA DRUŽBENE VEDE

Luka Kronegger

DINAMIKA OMREŽIJ SOAVTORSTEV
SLOVENSKIH RAZISKOVALCEV

Doktorska disertacija

Ljubljana, 2011

UNIVERZA V LJUBLJANI
FAKULTETA ZA DRUŽBENE VEDE

Luka Kronegger

MENTOR: izr. prof. dr. Andrej Mrvar

SOMENTOR: red. prof. dr. Franc Mali

DINAMIKA OMREŽIJ SOAVTORSKEV
SLOVENSKIH RAZISKOVALCEV

Doktorska disertacija

Ljubljana, 2011

Najlepša hvala Anuški, Patu in Francu
za odlično partijo igre z znanostjo.



IZJAVA O AVTORSTVU doktorske disertacije

Podpisani **Luka Kronegger**, z vpisno številko **21050018**, sem avtor doktorske disertacije z naslovom: **Dinamika omrežij soavtorstev slovenskih raziskovalcev**.

S svojim podpisom zagotavljam, da:

- je predložena doktorska disertacija izključno rezultat mojega lastnega raziskovalnega dela;
- sem poskrbel/-a, da so dela in mnenja drugih avtorjev oz. avtoric, ki jih uporabljam v predloženem delu, navedena oz. citirana v skladu s fakultetnimi navodili;
- sem poskrbel/-a, da so vsa dela in mnenja drugih avtorjev oz. avtoric navedena v seznamu virov, ki je sestavni element predloženega dela in je zapisan v skladu s fakultetnimi navodili;
- sem pridobil/-a vsa dovoljenja za uporabo avtorskih del, ki so v celoti prenesena v predloženo delo in sem to tudi jasno zapisal/-a v predloženem delu;
- se zavedam, da je plagiatorstvo – predstavljanje tujih del, bodisi v obliki citata bodisi v obliki skoraj dobesednega parafraziranja bodisi v grafični obliki, s katerim so tuje misli oz. ideje predstavljene kot moje lastne – kaznivo po zakonu (Zakon o avtorstvu in sorodnih pravicah, Uradni list RS št. 21/95), prekršek pa podleže tudi ukrepom Fakultete za družbene vede v skladu z njenimi pravili;
- se zavedam posledic, ki jih dokazano plagiatorstvo lahko predstavlja za predloženo delo in za moj status na Fakulteti za družbene vede;
- je elektronska oblika identična s tiskano obliko doktorske disertacije ter soglašam z objavo doktorske disertacije v zbirki "Dela FDV".

Povzetek

Dinamika omrežij soavtorstev slovenskih raziskovalcev

V doktorski disertaciji proučujemo znanstveno sodelovanje, kot enega pomembnejših gonil razvoja sodobne znanosti. Kljub temu, da je termin 'znanstveno sodelovanje' v literaturi opredeljen z različnimi pomeni, se v disertaciji ukvarjam z znanstvenim sodelovanjem, katerega rezultat so skupne znanstvene objave sodelujočih raziskovalcev. Upoštevane znanstvene objave obsegajo znanstvene članke, dele monografij, monografije, objavljene prispevke na konferencah, zbirke podatkov in patente. Zanima nas, ali, v kolikšni meri, in v kakšnih oblikah se skozi daljše časovno obdobje tovrstna oblika sodelovanja v slovenski znanstveni skupnosti pojavlja in kateri dejavniki vplivajo na spremembe v dinamiki sodelovanja.

V disertaciji obravnavamo vzorce sodelovanja med znanstveniki v Sloveniji v obdobju zadnjih 20 let. V tem času je v slovenskem prostoru prišlo do velikih družbenih in institucionalnih sprememb, kot tudi sprememb v vsebinu in izvajanju znanstvene politike. Vse našteto je pričakovano vplivalo na individualne strategije raziskovalcev o obsegu in načinu medsebojnega sodelovanja. Proučevanje vzorcev znanstvenega sodelovanja omejujemo na štiri znanstvene discipline: matematiko, fiziko, biotehnologijo in sociologijo. Razlogi za to odločitev so tako kognitivni kot tudi institucionalno-organizacijski. Že opravljene analize na področju družbenih študij znanosti in tehnologije so namreč pokazale, da med znanstvenimi disciplinami obstajajo razlike, ki jih določajo družbeni in kognitivni dejavniki. V tem kontekstu nas zanimajo predvsem razlike v doseženi stopnji sodelovanja med disciplinami in družbeni dejavniki, ki na to stopnjo vplivajo.

Sodelovanje med raziskovalci konceptualiziramo kot socialno omrežje in operacionaliziramo s pomočjo soavtorstev. Znanstveniki v tem kooperativnem omrežju nastopajo kot vozlišča, med katerimi se vzpostavlja vezi sodelovanja. Vsako soavtorstvo oziroma skupna udeležba pri dogodku, ki ga predstavlja znanstveno delo, obravnavamo kot vez med dvema posameznikoma. Na podlagi zbranih informacij za določeno časovno obdobje in za izbrane znanstvene discipline izdelamo socialna omrežja, v katerih merimo intenzivnost in strukturo sodelovanja. Primerjava omrežij med različnimi časovnimi obdobji glede na discipline ter osebne, vsebinske in institucionalne dejavnike,

omogoča analizo vplivov na dinamiko v omrežjih in na trende v smeri večje ali manjše kooperativnosti.

V prvem delu disertacije se osredotočamo na glavne kvantitativne pristope k proučevanju strukture in dinamike omrežij sodelovanj, merjenih s soavtorskimi objavami, ter predstavimo klasifikacijo pristopov k proučevanju znanstvenega sodelovanja glede na disciplinarno, sektorsko in nacionalno raven. V nadaljevanju opravimo kratek pregled razvoja analize socialnih omrežij, ki je temelj za obravnavo uporabljenih metodoloških pristopov. To začnemo s povezavo novejših modelov "malih svetov" in "preferenčne izbire" s starejšimi sociološkimi koncepti znanstvenega sodelovanja. Temu sledi opis determinističnih in stohastičnih modelov uporabljenih za proučevanje dinamičnih omrežij sodelovanj. Pri tem poudarjamo pomen razumevanja topologije omrežij v povezavi s procesi, ki se dogajajo na (mikro) ravni posameznega raziskovalca.

Drugi del je namenjen operacionalizaciji spremenljivk ter predstavitvi metod in modelov, uporabljenih za preverjanje hipotez. Metode in modele predstavljamo skupaj, saj modele realiziramo na več načinov z različnimi metodami.

Empirični del disertacije je namenjen predstavitvi podatkov, njihovi analizi in modeliranju. Najprej utemeljimo meje omrežja in obrazložimo izbiro enot, vključenih v raziskavo, ter se posvetimo osnovnim analizam omrežij. Analize predstavljamo po vrsti od enostavnih statičnih opisov struktturnih značilnosti omrežij in prikazov gibanj strukture znanstvenega sodelovanja kot časovnih vrst do diskretnih prikazov bločnih modelov omrežij v povezavi z zunanjimi spremenljivkami. Na koncu se posvetimo še modeliranju dinamike znanstvenega sodelovanja z uporabo stohastičnega modeliranja na podlagi delovanja akterjev.

Na osnovi naštetih pristopov zaključujemo, da število soavtorskih publikacij v času narašča hitreje kot število samostojnih objav raziskovalcev. Znanstveniki iz različnih disciplin rezultate svojih raziskav objavljam na različne načine (npr. pretežno članki v naravoslovnih vedah ter pogosteje poglavja in monografije pri sociologih), med posameznimi disciplinami pa obstajajo tudi konkretne razlike v kulturi sodelovanja, ki so posledica organiziranosti procesa znanstvenega raziskovanja in integracije raziskovalcev. Glede na stopnjo integracije lahko discipline razdelimo na laboratorijske in pisarniške. V vseh analiziranih disciplinah je prisotna struktura center-periferija z večimi med seboj močno povezanimi skupinami raziskovalcev, semi-periferijo raziskovalcev z manj definiranim vzorcem povezovanja in periferijo raziskovalcev,

ki znotraj discipline ne sodelujejo. Nadgradnja metode posplošenega bločnega modeliranja, ki omogoča sledenje spremembam v strukturi znotraj disciplin, pokaže, da imajo laboratorijske discipline, kjer je delitev dela, virov in vlog natančneje določena, stabilnejšo strukturo od pisarniških disciplin, v katerih raziskovalci niso tako strogo povezani z raziskovalnim okoljem. V vseh disciplinah lahko na podlagi uporabe večih metod potrdimo močno prisotnost strukture malih svetov, hkrati pa je v laboratorijskih disciplinah struktura, ki je posledica preferenčne izbire, manj izrazita kot v pisarniških disciplinah.

Ključne besede: analiza omrežij, modeliranje omrežij, evolucija omrežij, znanstveno sodelovanje, Slovenija

Abstract

Dynamics of Slovenian Co-authorship Networks

This doctoral dissertation examines scientific cooperation as one of the major drivers of development in modern science. Although the term ‘scientific collaboration network’ has various connotations in literature, we use the term in its narrow sense in order to focus on scientific collaboration resulting in co-authored scientific publications (scientific articles, chapters, monographs, published contributions at scientific conferences, scientific databases and patents). We are interested in the extent, and the ways, in which this type of collaboration appears within the Slovenian scientific community. We are also interested in the factors that influence the changes in the dynamics of collaboration over time.

The dissertation considered cooperation patterns between scientists in Slovenia over the past 20 years. During this time, Slovenia witnessed major social and institutional changes, as well as changes in the content and implementation of its science policy. All of this is expected to affect the strategies of individual researchers as regards both, the extent and form of scientific collaboration. Our examination of the patterns of scientific collaboration was limited to four scientific disciplines: mathematics, physics, biotechnology and sociology. The reasons behind selecting these disciplines are both, cognitive as well as institutional and organizational. The previous social studies analyses of science and technology have shown that the differences between scientific disciplines are imposed by social and cognitive factors. In this context we are mainly interested in the differences according to the level of collaboration and social factors that influence the rate.

The collaboration between the various researchers in this dissertation is conceptualized as a social network and operationalized through co-authorship. Scientists within this collaborative network act as nodes, which are linked by co-authorship ties. Each co-authorship and joint participation that resulted in a scientific publication is considered a link between two individuals. From the information gathered over a specified period of time and dealing with a selected scientific discipline we generated social networks in which we measured the intensity and structure of collaboration. A comparison of the networks over various time periods, depending on the discipline, personal, substantive and institutional factors, was used to explain the effects on the

network dynamics and observe the trends towards higher or lower collaboration levels.

In the first part of this thesis we focused on the main quantitative approaches dealing with the structure and dynamics of scientific collaboration networks through co-authored publications. We reviewed conceptual classifications of co-authorship networks and distinguished between cross-disciplinary, cross-sectoral and cross-national levels, and compiled a broad list of published studies dealing with the discussed topic. We continued with a brief history of social network analysis that serves as the foundation of the overview of methodological approaches studying network dynamics. The overview starts with coupling the newer ideas of ‘small world’ and ‘preferential attachment’ models to older sociological conceptions of scientific collaboration. This is followed by descriptions of deterministic and stochastic models that have been used in the studies of dynamic scientific collaboration networks. We stress the importance of delineating the topology of collaboration networks, understanding the micro-level processes and then coupling them.

In the second part, we operationalize the variables, and present methods and models used to test hypotheses.

The empirical part of the dissertation is devoted to the presentation of data, analysis and modelling. First, we defined the network boundaries, explained the selection of disciplines and units that were included into the analysis, and focused on the basic analysis of network properties. The analyses are presented in order from simple static descriptions of structural network characteristics, presentations of time series of basic structural network characteristics, to discrete presentations of blockmodels in combination with additional variables. At the end we have modelled the network dynamics using stochastic actor based network modelling.

The use of the listed approaches shows, that the number of co-authored publications is ascending faster than the number of single authored publications. Scientists from various scientific disciplines are publishing in different forms of scientific publications (e.g. articles in natural sciences and chapters or monograph in sociology); there are large differences in the culture of collaboration between different disciplines – these result from the organization of the scientific research process and the integration of researchers. According to the level of integration the disciplines can be divided into “lab” and “office” disciplines. All of the analysed disciplines have shown to have a core-periphery structure, with several internally highly connected cores of

researchers, a semi-periphery with researchers with less structured connections, and a periphery of researchers, who do not collaborate within the research discipline. Using an updated generalised blockmodeling method that was introduced in the dissertation we can follow the changes in the collaborative structure of disciplines. Lab disciplines with a stricter division of tasks, resources, and roles among researchers have a more stable structure than office disciplines in which researchers are not as strictly integrated into the research environment. The analysed disciplines have inherited a small world structure, while the preferential attachment structure can be found only in lab disciplines. Both structures are identified and confirmed through a number of methods.

Key words: network analysis, network modeling, network evolution, scientific collaboration

Kazalo

1	Uvod	31
1.1	Pregled po poglavjih	34
2	Znanstveno sodelovanje	35
2.1	Definicija in opredelitev pojma	35
2.2	Nivoji proučevanja znanstvenega sodelovanja	38
2.2.1	Disciplinarnost	41
2.2.2	Sektorska delitev	44
2.2.3	Geografska delitev	46
2.3	Znanstveno sodelovanje kot socialno omrežje	51
2.3.1	Kratka zgodovina razvoja analize dinamike socialnih omrežij znanstvenega sodelovanja	53
2.4	Metode proučevanja dinamike omrežij soavtorstev	58
2.4.1	Osnovne analize značilnosti omrežij skozi čas	59
2.4.2	Deterministični pristopi k analizi dinamike omrežij	60
2.4.3	Modeliranje dinamike v omrežjih soavtorstev	62
2.5	Proučevanje znanstvenega sodelovanja v Sloveniji	81

2.6	Hipoteze	82
3	Operacionalizacija spremenljivk in metode	85
3.1	Operacionalizacija spremenljivk	85
3.1.1	Omrežje kot odvisna spremenljivka	85
3.1.2	Zunanje spremenljivke	86
3.2	Metode in modeli	87
3.2.1	Osnovne definicije	88
3.2.2	Časovne vrste	90
3.2.3	Center - periferija model	92
3.2.4	Model malih svetov	98
3.2.5	Model preferenčne izbire	99
3.2.6	Stohastično modeliranje dinamike v omrežjih	99
4	Analiza dinamike soavtorskih omrežij	107
4.1	O podatkih	107
4.1.1	Priprava podatkov za analizo	108
4.1.2	O avtorjih kot enotah analize	111
4.1.3	O bibliografskih enotah kot povezavah v omrežju	112
4.2	Splošne značilnosti omrežij	115
4.3	Znanstveno sodelovanje skozi čas	120
4.4	Deterministični pristop k analizi dinamike	124
4.4.1	Omrežja v štirih časovnih obdobjih	124
4.4.2	Iskanje struktur z bločnim modeliranjem	129

4.4.3	Evolucija bločnih modelov	144
4.4.4	Struktura sodelovanja v povezavi z lastnostmi raziskovalcev	157
4.5	Stohastično modeliranje dinamike soavtorskih omrežij	167
4.5.1	Modeliranje omrežij ‐realnega sveta‐	167
4.5.2	SIENA model	176
5	Zaključek	183
6	Literatura	191
Priloga A	Izpisi iz programa SIENA	207
Stvarno kazalo		238

Slike

2.1	Modeliranje strukture malih svetov v omrežju	66
2.2	Primer brezlestvičnega omrežja	69
4.1	Struktura znanstvene bibliografije po disciplinah	114
4.2	Popolno soavtorsko omrežje štirih raziskovalnih disciplin . . .	116
4.3	Samostojne in soavtorske objave raziskovalcev skozi čas	121
4.4	Struktura znanstvenega sodelovanja skozi čas	123
4.5	Primer bločnega modela omrežja	131
4.6	Bločni modeli omrežja sociologov v 4. obdobjih	134
4.7	Bločni modeli omrežja fizikov v 4. obdobjih	136
4.8	Bločni modeli omrežja matematikov v 4. obdobjih	139
4.9	Bločni modeli omrežja biotehnologov v 4. obdobjih	141
4.10	Pripadnost skupinam v omrežju sociologov na prehodu iz t_1 v t_2	146
4.11	Pripadnost skupinam v omrežju sociologov na prehodu iz t_2 v t_3	146
4.12	Pripadnost skupinam v omrežju sociologov na prehodu iz t_3 v t_4 (1. del)	147
4.13	Pripadnost skupinam v omrežju sociologov na prehodu iz t_3 v t_4 (2. del)	149

4.14	Pripadnost skupinam v omrežju sociologov na prehodu iz t_3 v t_4 (3. del)	149
4.15	Pripadnost skupinam v omrežju fizikov na prehodu iz t_1 v t_2	150
4.16	Pripadnost skupinam v omrežju fizikov na prehodu iz t_2 v t_3	151
4.17	Pripadnost skupinam v omrežju fizikov na prehodu iz t_3 v t_4	151
4.18	Pripadnost skupinam v omrežju matematikov na prehodu iz t_1 v t_2	152
4.19	Pripadnost skupinam v omrežju matematikov na prehodu iz t_2 v t_3	153
4.20	Pripadnost skupinam v omrežju matematikov na prehodu iz t_3 v t_4	153
4.21	Pripadnost skupinam v omrežju biotehnologov na prehodu iz t_1 v t_2	154
4.22	Pripadnost skupinam v omrežju biotehnologov na prehodu iz t_2 v t_3	155
4.23	Pripadnost skupinam v omrežju biotehnologov na prehodu iz t_3 v t_4	155
4.24	Primerjava centralnih skupin omrežja glede na pripadnost raziskovalnim skupinam za področje sociologije.	158
4.25	Primerjava centralnih skupin omrežja glede na pripadnost raziskovalnim skupinam za področje fizike.	160
4.26	Primerjava centralnih skupin omrežja glede na pripadnost raziskovalnim skupinam za področje matematike.	161
4.27	Primerjava centralnih skupin omrežja glede na pripadnost raziskovalnim skupinam za področje biotehnologije.	161
4.28	Primerjava raziskovalcev v centrih glede na skupno raziskovalno vsebino (sociologi v t_3 in t_4).	164
4.29	Porazdelitev stopenj in stabilnost komponent v soavtorskem omrežju fizikov	171

4.30 Porazdelitev stopenj in stabilnost komponent v soavtorskem omrežju matematikov	172
4.31 Porazdelitev stopenj in stabilnost komponent v soavtorskem omrežju biotehnologov	173
4.32 Porazdelitev stopenj in stabilnost komponent v soavtorskem omrežju sociologov	174

Tabele

2.1	Razvrstitev pristopov k proučevanju znanstvenega raziskovanja glede na nivo analize	39
4.1	Klasifikacija disciplin glede na funkcionalno in normativno integracijo	109
4.2	Pregled osnovnih omrežnih značilnosti po obravnavanih disciplinah	117
4.3	Pregled osnovnih omrežnih značilnosti v štirih časovnih obdobjih za področje matematike in fizike	126
4.4	Pregled osnovnih omrežnih značilnosti v štirih časovnih obdobjih za področje biotehnologije in sociologije	127
4.5	Strukturne lastnosti omrežij v obdobjih t_2 , t_3 , t_4 in t_{2-4}	169
4.6	Siena model za štiri znanstvene discipline	178

Poglavlje 1

Uvod

Znanstveno sodelovanje je eden ključnih mehanizmov sodobne znanosti, ki prispeva k novim odkritjem in rasti znanstvene produktivnosti. Proučevati ga je mogoče iz različnih perspektiv in na različnih ravneh delovanja družbenega sistema znanosti, tako med posameznimi znanstveniki in znanstvenimi skupinami kot med raziskovalnimi institucijami in nacionalnimi sistemi znanosti. Glede na nivo proučevanja nas zanima širši spekter socioloških, organizacijskih in psiholoških dejavnikov, ki bodisi vzpodbujujo bodisi zavirajo različne oblike znanstvenega sodelovanja. Iz vidika posameznika nas zanimajo predvsem njegovi interesi in zmožnost za sodelovanje. Ko govorimo o raziskovalnih organizacijah, se sprašujemo o tem, kakšna organizacija dela in tip vodenja vplivata na večjo ali manjšo stopnjo sodelovanja med zaposlenimi. Na nacionalni ravni so v središču pozornosti znanstvene politike in ukrepi, ki imajo pomembne posledice za znanstveno sodelovanje s tem, ko določajo različne vzpodbude in postavljajo omejitve za sodelovanje.

Znanstveno sodelovanje predstavlja kompleksen sistem interakcij med vklju-

čenimi akterji. Glede na kompleksnost proučevanega predmeta je najbolj primeren interdisciplinarni pristop: iz perspektive sociologije in organizacijskih ved, analize politik s poudarkom na znanstveni politiki, kot tudi iz perspektive bibliometričnih študij in analize socialnih omrežij.

Sodelovanje je prisotno v vseh fazah produkcije novega znanstvenega vedenja. Institucionalne in pravno zavezujoče dogovore o sodelovanju med raziskovalnimi organizacijami je na primer mogoče razumeti kot enega od kontekstualnih dejavnikov, ki prispevajo k razvoju sodelovanja med posameznimi znanstveniki. Na drugi strani seminarji in konference kot del vsakdanje raziskovalne prakse že odražajo dejansko sodelovanje. Kot odraz sodelovanja lahko obravnavamo tudi različne uporabe informacijsko-komunikacijske tehnologije, ki pomaga pri vzpostavljanju in ohranjanju komunikacije in prenosa informacij med znanstveniki (npr. pošiljanje elektronskih sporočil, povezave med spletnimi stranmi ipd).

V doktorski disertaciji bomo proučevali eno najpomembnejših oblik sodelovanja med znanstveniki v sodobni znanosti. Gre za sodelovanje, ki se odraža kot soavtorstvo znanstvenih objav. Za znanstvenike, ki se pojavljajo kot soavtorji določenega znanstvenega članka, monografije, poglavja v monografiji ali kakšne drugačne znanstvene objave, se smatra, da so med seboj razvili pomembno obliko sodelovanja. Zanima nas, ali, v kolikšni meri in v kakšnih oblikah se skozi daljše časovno obdobje tovrstna oblika sodelovanja v slovenski znanstveni skupnosti povečuje in kateri dejavniki vplivajo na spremembe v dinamiki sodelovanja.

V disertaciji obravnavamo vzorce sodelovanja med znanstveniki v Sloveniji v obdobju zadnjih 20 let. V tem času je v slovenskem prostoru prišlo do velikih družbenih in institucionalnih sprememb, kot tudi sprememb v vsebini

in izvajanju znanstvene politike. Vse našteto je po pričakovanju vplivalo na individualne strategije raziskovalcev glede tega, v kolikšni meri in kako naj sodelujejo med seboj.

Proučevanje vzorcev znanstvenega sodelovanja bo omejeno na štiri znanstvene discipline: matematiko, fiziko, biotehnologijo in sociologijo. Razlogi za to odločitev so tako kognitivni kot tudi institucionalno-organizacijski. Že opravljene analize na področju družbenih študij znanosti in tehnologije so namreč pokazale, da med znanstvenimi disciplinami obstajajo razlike, ki jih določajo družbeni in kognitivni dejavniki (npr. Price, 1963; Li in drugi, 2005; Ramasco in Morris, 2005; Goldstein in drugi, 2004). Nas zanimajo predvsem razlike glede dosežene stopnje sodelovanja in družbeni dejavniki, ki na stopnjo vplivajo.

Sodelovanje med raziskovalci je v disertaciji konceptualizirano kot socialno omrežje in operacionalizirano s pomočjo soavtorstev. Znanstveniki v tem kooperativnem omrežju nastopajo kot vozlišča, med katerimi se vzpostavlja vezi sodelovanja. Vsako soavtorstvo oziroma skupna udeležba pri dogodku, ki ga predstavlja znanstveno delo, se smatra kot vez med dvema posameznikoma. Na podlagi zbranih informacij smo za določeno časovno obdobje in za izbrano znanstveno disciplino izdelali socialna omrežja, v katerih smo merili intenzivnost in strukturo sodelovanja. Primerjava omrežij med različnimi časovnimi obdobji glede na discipline, osebne, vsebinske in institucionalne dejavnike omogoča analizo vplivov na dinamiko v omrežjih omrežij in na trende v smeri večje ali manjše kooperativnosti.

1.1 Pregled po poglavjih

V začetku drugega poglavja predstavimo znanstveno sodelovanje iz perspektive sociologije znanosti. S klasifikacijo pristopov k proučevanju znanstvenega sodelovanja predstavimo nivoje proučevanja in širok spekter raziskav obravnavane teme. V nadaljevanju poglavja predstavimo razvoj metodoloških prijemov za prikaz in analizo dinamike v omrežjih sodelovanj s poudarkom na analizi soavtorskih omrežij v znanosti. Del poglavja je namenjen razvoju pristopov k modeliranju omrežij sodelovanj, pred zaključnim delom, kjer opredelimo hipoteze, pa se posvetimo raziskovanju znanstvenega sodelovanja v Sloveniji.

Tretje poglavje je namenjeno operacionalizaciji spremenljivk ter predstavitvi metod in modelov, ki smo jih uporabili za preverjanje hipotez. Metode in modeli so predstavljeni skupaj, saj so uporabljeni modeli realizirani na več načinov z različnimi metodami.

Četrto poglavje je namenjeno predstavitvi podatkov, njihovi analizi in modeliranju. V poglavju najprej utemeljimo meje omrežja in obrazložimo izbiro enot, vključenih v raziskavo, ter se posvetimo osnovnim analizam omrežij. Analize so predstavljene po vrsti od enostavnih statičnih opisov strukturnih značilnosti omrežij, prikazov gibanj strukture znanstvenega sodelovanja kot časovnih vrst, do diskretnih prikazov bločnih modelov omrežij v povezavi z zunanjimi spremenljivkami. Na koncu se posvetimo še modeliranju dinamike znanstvenega sodelovanja z uporabo stohastičnega modeliranja na podlagi delovanja akterjev.

V petem poglavju podamo še kratek pregled rezultatov analiz in zaključkov na podlagi teoretičnih izhodišč, predstavljenih v drugem poglavju.

Poglavlje 2

Znanstveno sodelovanje

2.1 Definicija in opredelitev pojma

Sodelovanje v znanosti lahko definiramo kot: "skupno delo raziskovalcev z namenom ustvarjanja novega znanja, vedenja." (Katz in Martin, 1997). Prisotno je v vseh fazah in na vseh nivojih produkcije znanstvenega vedenja: od institucionalnih in pravno zavezujočih dogovorov med organizacijami do seminarjev, konferenc in vsakodnevnega sodelovanja med posameznimi raziskovalci. Sodelovanje v znanosti se kot tema znanstvenega raziskovanja uveljavlja v prehodu v 70. leta prejšnjega stoletja z deli Pricea in Beaverja (Price in Beaver, 1966) ter Roberta Mertona (Merton, 1968, 1973).

Znanstveno raziskovanje je mogoče proučevati iz različnih perspektiv in na različnih ravneh delovanja družbenega sistema znanosti, tako med posameznimi znanstveniki in znanstvenimi skupinami kot tudi med raziskovalnimi institucijami in nacionalnimi sistemi znanosti. Glede na raven proučevanja

se lahko osredotočamo na sociološke, organizacijske, ekonomske in/ali psihološke dejavnike, ki bodisi vzpodbujujo bodisi zavirajo različne oblike znanstvenega sodelovanja.

Z vidika posameznika nas zanimajo predvsem njegovi interesi, motivi in zmožnost za sodelovanje. Ko govorimo o raziskovalnih organizacijah, se sprašujemo o tem, kakšna organizacija dela in tip vodenja vplivata na večjo ali manjšo stopnjo sodelovanja med zaposlenimi. Če pa gremo še nivo više in gledamo na sodelovanje na ravni države, pa so v ospredju pozornosti znanstvene politike in ukrepi, ki imajo pomembne posledice za znanstveno sodelovanje s tem, ko določajo različne vzpodbude in postavljajo omejitve za sodelovanje.

Laudel (2001) opredeli znanstveno sodelovanje kot vertikalno in horizontalno specializacijo ter delitev dela glede na hierarhijo v ekipi, ki izvaja neko raziskavo. Vertikalna specializacija dela znotraj raziskovalne skupine pripelje do delitve dela med vodjo skupine in njenimi člani. Od vodje raziskovalne skupine se pričakuje kreativnost pri teoretičnem delu raziskave, na primer pri iskanju izzivov in formulaciji znanstvenih vprašanj, ter pri končni integraciji rezultatov. Ostali člani raziskovalne skupine, ki naj bi delali predvsem na eksperimentalnem delu raziskave, potrebujejo in morajo razvijati metodološka in tehnična znanja ter kreativnost. Laudel na horizontalno delitev dela gleda predvsem kot na delitev dela med raziskovalnimi skupinami. Sodelovanje razdeli na pet tipov glede na kreativni prispevek posameznih partnerjev: 1) *dejanska delitev* dela, o kateri natančneje piše npr. Hagstrom (1965). Pri tem tipu sodelovanja gre za delitev znanstvene kreativnosti in intelektualnega dela. Rezultat dejanskega sodelovanja so npr. soavtorske objave, na podlagi katerih temelji večina empiričnih raziskav o znanstvenem sodelovanju;

2) *servisno sodelovanje*, kjer je naloga sodelavca oz. sodelujoče raziskovalne skupine zgolj priprava raziskovalnega objekta ali na primer merjenje. V tem primeru sodelavec ni udeležen v celotnem znanstvenem procesu, v primeru objave rezultatov znanstvenega dela je naveden v zahvali ali kot soavtor; 3) še šibkejši tip sodelovanja je *zagotavljanje dostopa do raziskovalne opreme*, kjer je sodelavec ob objavi rezultatov zgolj omenjen v zahvali; 4) *podajanje specifičnih znanj (know-how)* za izvajanje določenih procedur znotraj procesa raziskovanja; v tem tipu sodelovanja sodelavec ob objavi rezultatov ni nujno naveden v zahvali; 5) tip sodelovanja, ki se od ostalih precej razlikuje – *vzajemna stimulacija*. Stimulacija je tip, ker je sama po sebi posledica znanstvene komunikacije in je delno vključena v vse tipe sodelovanj. Laudel ta tip obrazloži iz vidika komunikacije (lahko neposredne, na konferenci, branja prispevkov ipd.), ki raziskovalce vzpodbudi k razmišljanju o nerazrešenih znanstvenih problemih v svoji disciplini.

Če se osredotočimo na dejansko sodelovanje raziskovalcev, ki ga je kot soavtorstvo posredno mogoče izmeriti s pomočjo bibliografskih zbirk podatkov, je dejavnikov, ki vplivajo na znanstveno sodelovanje, toliko, da jih je težko zbrati in opredeliti v enem samem delu. Nekaj primerov dejavnikov, ki so jih različni avtorji proučevali v vrsti raziskav, sta v članku o znanstvenem sodelovanju zbrala Katz in Martin (1997). Ti so:

- spremembu v vzorcu oz. nivoju financiranja znanstvenega delovanja Smith (1958); Heffner (1981); Rigby (2005)
- težnja raziskovalcev, da bi s sodelovanjem povečali svoj znanstven ugled Beaver in Rosen (1978, 1979a,b); Crane (1972)
- vse večje zahteve po racionalizaciji znanstvenih virov Beaver in Rosen

(1978, 1979a,b); Price (1963)

- potrebe in zahteve po vse zahtevnejših in obsežnejših raziskavah, v okviru katerih raziskovalci potrebujejo tudi več raziskovalne opreme. Glänel in Schubert (2004)
- vse večja specializacija znanj Smith (1958); Moody (2004)
- razvoj znanstvenih disciplin, ki je pripeljal do tega, da en sam raziskovalec ni sposoben zaobjeti vseh znanj, ki so potrebna za izpeljavo dobre raziskave, kar posledično vodi v združevanje znanj Piette in Ross (1992); Norgaard (2004).

V okviru tega širokega spektra pristopov k proučevanju tega področja in spoznanju o znanstvenem sodelovanju, ki skupaj presegajo okvire disertacije, bomo v nadaljevanju predstavili klasifikacijo pristopov k proučevanju znanstvenega sodelovanja. Opisali bomo osnovne značilnosti posameznih kategorij in ob vsaki navedli nekaj primerov raziskav.

2.2 Nivoji proučevanja znanstvenega sodelovanja

Raziskave o sodelovanju v znanosti se problema raziskovanja lotevajo na zelo različne načine. Že samo merjenje različnih oblik sodelovanja (Hagstrom, 1965) ter nabor tem, predstavljen v prejšnjem delu poglavja (Katz in Martin, 1997), sta jasna potrditev te trditve. Kadar se znajdemo v vlogi raziskovalca znanosti, se moramo zavedati tudi, da je posamezen raziskovalec kot predmet

Tabela 2.1: Razvrstitev pristopov k proučevanju znanstvenega raziskovanja glede na nivo analize

Dimenzija proučevanja	primeri raziskav	
Osnovna dimenzija	Nivo proučevanja	
Disciplina	Znotraj discipline	Povezave med avstralskimi raziskovalnimi omrežji (Rigby, 2005),(glej tudi: Wray, 2002; Glänel in Schubert, 2004; Laband in Tollison, 2000; Hornbostel, 1997; Rodriguez in Pepe, 2008)
	Med disciplinami	Meddisciplinarno raziskovalno sodelovanje francoskih laboratorijev (Sigogneau in drugi, 2005)(glej tudi: Gibbons in drugi, 1994; Etzkowitz in Leydesdorff, 2001; Qin in drugi, 1997; Braun in Schubert, 2003; Han, 2003)
Sektor	Znotraj sektorja	Analiza akademskega raziskovalnega omrežja (Lowrie in McKnight, 2004; Wray, 2002)
	Med sektorji	Modeli sodelovanja med industrijo in univerzami v Belgiji (Veugelers in Cassiman, 2005)
Država	Znotraj države	Sodelovanje nemških imunoloških inštitutov, glede na geografsko bližino (Havemann in drugi, 2006)
	Mednarodno	Primerjalna analiza soavtorskega sodelovanja navznoter in navzven med državami (Glänel in Schubert, 2005; Mattison in drugi, 2008)

raziskovanja s svojim znanstvenim delovanjem del večplastnega sistema znanosti. Raziskovalec deluje na področju neke znanstvene discipline, je del raziskovalne skupine, zaposlen je v določeni instituciji, ki ima sedež v konkretnem mestu oz. državi. Vsak posamezen akter, ki je del globalnega znanstvenega sistema, je hkrati del vseh naštetih nivojev sistema znanosti. Kadar dva akterja med seboj sodelujeta, posredno med seboj sodelujejo tudi raziskovalne skupine, institucije, sektorji, discipline, države itn. Znanstveno sodelovanje seveda ne poteka nujno zgolj med posameznimi raziskovalci. Lahko je formalizirano v obliki pogodb med institucijami ali opredeljeno v okviru znanstvenih politik dveh nacionalnih znanstvenih sistemov. Poleg različnih nivojev sodelovanja se moramo zavedati, da raziskovalec le redko deluje povsem sam. Praviloma je namreč vpet v širši kontekst interakcij, tako horizontalnih na

posameznem nivoju sistema znanosti kot vertikalnih med nivoji (Glänel in Schubert, 2004).

K raziskovanju znanstvenega sodelovanja lahko tako pristopimo na različnih nivojih znanstvenega delovanja. Rogers je s sodelavci predlagal tipologijo, ki se proučevanja loteva: (1) glede na enote analize - posamezni, raziskovalne skupine, organizacije iz področja R&R; (2) glede na tip informacije, ki povezuje akterje, npr. različne oblike komunikacije, pozicije v socialni strukturi ipd. (3) glede na institucionalizirana področja, katerim akterji pripadajo, s poudarkom na intra-organizacijskem oz inter-organizacijskem sodelovanju (Rogers in drugi, 2001). Sonnenwald (2007) je predlagal bolj splošno razdelitev sodelovanja glede na to, ali gre za sodelovanje raziskovalcev iz univerz in gospodarstva, sodelovanje raziskovalcev iz različnih disciplin ali za sodelovanje raziskovalcev iz različnih držav.

Iskanje najprimernejše razdelitve pristopov je stvar posameznega raziskovalca. V disertaciji bomo uporabili nekoliko prirejeno razdelitev, predlagano s strani Andradea in sodelavcev. Slednja sicer povzema delitev iz vplivnega članka Katza in Martina (Katz in Martin, 1997). Andrade in drugi (2009) so za delitev predlagali tri dimenzijske znanstvenega sodelovanja s pripadajočimi poddimenzijami, ki opisujejo nivo sodelovanja, npr. sodelovanje znotraj (intra) entitet dimenzijske oz. sodelovanje med (inter) entitetami dimenzijske. Predlagane dimenzijske so: *disciplinarnost* s poddimenzijama, ki opisujeta sodelovanje znotraj disciplin in med disciplinami (trans-disciplinarnost), *sektorska delitev* z inter-sektorsko in intra-sektorsko, ter *geografska* z mednarodno in domačo oz. notranjo poddimenzijo. Uporabljeni delitev je izvirno predstavljeni v poglavju knjige o modeliranju znanosti (Mali in drugi, 2011).

2.2.1 Disciplinarnost

Proučevanje znanosti in znanstvenega sodelovanja glede na discipline je nekako naraven in eden pogostejših pristopov v sociologiji znanosti. Proučevanje znanstvenega sodelovanja glede na disciplinarnost delimo na sodelovanje znotraj in sodelovanje med disciplinami.

Sodelovanje znotraj discipline

Sodelovanje raziskovalcev znotraj discipline je najnaravnejša in samoumevna oblika znanstvenega sodelovanja. Znanstvena disciplina se je kot primarna enota diferenciacije v znanosti skozi zgodovino iz področja raziskovanja preoblikovala tudi v socialni sistem, povezan z lastnim institucionalnim okvirjem.

Mnogi raziskovalci, ki se ukvarjajo s teorijo znanosti, trdijo, da so znanstvene discipline tako kognitivni–intelektualni kot socialni pojav. Obe omenjeni dimenziji v svojem bistvu nosita tudi določeno strukturo, ki definira ustroj (akademske) znanosti (glej: Stichweh, 2001; Whitley, 1984).

Znanstvene discipline predstavljajo institucionalni, organizacijski in, splošneje, socialni okvir, ki usmerja ustvarjanje znanstvenega vedenja.

Struktura znanstvenega sodelovanja se znotraj posameznih disciplin razlikuje glede na naravo raziskovalnih problemov, značilnosti institucionalne organiziranosti discipline in drugih dejavnikov. Hargens (1975) tako discipline deli glede na stopnjo normativne in funkcionalne integracije ter glede na rutino, ki je prisotna v znanstvenem raziskovanju. Glede na prisotnost rutine Hargens jasno deli discipline na formalne, kjer je stopnja rutine visoka, in empirične, kjer že samo zbiranje podatkov predstavlja izziv tudi iz vidika znanstvenega

sodelovanja.

Kljub temu, da je sodelovanje v splošnem najbolj prisotno v naravoslovnih disciplinah, se v zadnjih desetletjih velike spremembe v tej smeri dogajajo tudi na področju humanistike, družboslovja in na znanstvenih področjih (več v: Wray, 2002; Glänzel in Schubert, 2004; Laband in Tollison, 2000; Hornbostel, 1997).

Ne glede na trende vse močnejšega prepletanja disciplin ostajajo samostojne znanstvene discipline osnova za razvoj karier raziskovalcev in njihovo socijalizacijo. Predstavljajo temelj socialne identitete in javni prostor, v katerem posamezniki delujejo kot raziskovalci. Posledica tega je, da so znanstvene skupnosti v moderni znanosti še vedno jasno določene s pripadnostjo določenim znanstvenim disciplinam, ki predstavljajo samosvoje intelektualno in družbeno okolje, drugačno od okolij, ki so se razvila v sozvočju z drugimi disciplinami (Mali in drugi, 2011). V skladu s to ugotovitvijo so tudi izsledki raziskave Rodriguesa in Pepe-ja (2008), ki ugotavlja, da ne glede na ravnen povezovanja raziskovalcev, osnovna celica ostaja primarna raziskovalna skupina.

Multidisciplinarno sodelovanje

Multidisciplinarno sodelovanje se je v zadnjih dveh desetletjih iz neobičajne prelevilo v vsesplošno prakso. Prisotnost sodelovanja, ki prehaja meje znanstvenih disciplin, se še vedno povečuje eksponentno (glej: Gibbons in drugi, 1994; Etzkowitz in Leydesdorff, 2001). Vseprisotno sodelovanje med raziskovalci je posledica spoznanja, da heterogene (multidisciplinarne) ekipe raziskovalcev veliko uspešneje in bolj učinkoviteje rešujejo probleme, s katerimi

se znanost ukvarja.

Danes se znanost na vsakem koraku srečuje s težnjo po preseganju meja disciplin. Glavni vzgib za to so nenehna pričakovanja in zahteve po inovacijah, ki jih znanost laže doseže s soočenjem idej, orodij in raziskovalcev iz različnih znanstvenih področij. Sinergija virov tako z združevanjem ustvari neprecenljivo intelektualno in tehnično moč. Lep primer tovrstnega sodelovanja je združitev moči t.i. NBIC področij: nanotehnologije, biotehnologije, informacijskih in kognitivnih znanosti (glej: Buter in drugi, 2010).

Organizacijski problemi in kulturne ovire med disciplinami predstavljajo poseben izziv pri razvoju interdisciplinarnih raziskav. Ideja interdisciplinarnosti temelji na velikih znanstvenih omrežjih, odprtosti do novih konceptov in idej ter velikih vložkih v čas, namenjen koordinaciji in usklajevanju med vsemi udeleženimi akterji. V splošnem je menedžiranje virov eden pomembnejših izzivov moderne znanosti. Znanstveniki, ki izvirajo iz različnih disciplin, so ponavadi izšolani v različnih akademskih krogih, discipline imajo različne pristope k profesionalizaciji in socializaciji akterjev, ki jo soustvarjajo. Poleg tega objavlja znanstveniki iz različnih disciplin rezultate svojega dela v različnih znanstvenih revijah in se udeležujejo različnih konferenc. Vsa ta razpršenost predstavlja svojevrsten dodaten problem. Kot pravi Maria Bordons, je kljub vsesplošni prisotnosti sodelovanja med disciplinami le-to zelo težko izmeriti (Bordons in drugi, 2004, pp. 441). Zelo pogosto uporabljen pristop za merjenje meddisciplinarnega sodelovanja je uporaba bibliometrije s katero sodelovanje merimo z različimi indikatorji, kot so: soavtorstva publikacij z avtorji iz različnih disciplin, skupno pojavljanje različnih klasifikacijskih kriterijev v publikacijah, splošna interdisciplinarna narava znanstvenih revij ter meddisciplinarne reference in citati v objavljenih prispevkih.

Najpogosteje uporabljen bibliometrični indikator za tovrstno sodelovanje je delež objav, pri katerih avtorji izvirajo iz dveh ali več disciplin. Izračun tega deleža je zopet stvar različnih pogledov, na katere vpliva narava organizacije znanstvenih skupnosti, naravnost politik iz področja R&R, ter, končno, operacionalizacija različnih konceptov (kot na primer: način klasifikacije znanstvenih disciplin (Qin in drugi, 1997; Braun in Schubert, 2003).

2.2.2 Sektorska delitev

Ko govorimo o znanstvenem sodelovanju, ne moremo mimo delitve na sodelovanje znotraj akademskih krogov in sodelovanje, ki presega zgolj akademske okvire. Prvo je ponavadi omejeno na sodelovanje znotraj oddelkov, raziskovalnih skupin ali institucij, slednje pa na sodelovanje z industrijo in upravnim, vladnim ali drugimi sektorji (glej: Gläzel in Schubert, 2004).

Sodelovanje znotraj sektorja

Znanstveno sodelovanje znotraj sektorjev je, podobno kot sodelovanje znotraj drugih opisanih nivojev, vezano na določeno organizacijsko strukturo sektorja, delitev virov, kulturo sodelovanja v sektorju ipd. V primeru znanstvenega sodelovanja so akterji znotraj znanstvenega sektorja vpeti v delovanje univerz, v neprofitnem sektorju naj bi šlo za neodvisne akterje, medtem ko je raziskovalna sfera, ki deluje v okviru gospodarstva, formalno in vsebinsko vezana na delovanje podjetij, katerih del so.

Povezanost znotraj posameznih sektorjev je po Zimanu posledica procesov profesionalizacije, ki se je zgodila praktično v vseh poklicih. Kot drugod, so

tudi v znanosti velike organizacijske spremembe pripeljale tudi do tega, da “osnovne organizacijske strukture v moderni znanosti niso več posamezniki, ampak raziskovalne skupine” (Ziman, 1994, str. 227).

Organizacija aktivnosti na področju raziskav in razvoja je v akademskih ustanovah sčasoma pripeljala do tipične organizacijske strukture znanstvenih ekip, kakrsna je na primer raziskovalna skupina z glavnim oz. odgovornim raziskovalcem, ostalimi raziskovalci, doktorskimi študenti in drugimi. Price je bil tako mnenja, da je znanstveno sodelovanje v bistvu posledica pomanjkanja raziskovalcev, kar vodi v drobljenje vlog v raziskovalnem procesu (Price in Beaver, 1966).

Kadar merimo sodelovanje raziskovalcev s številom večavtorskih publikacij, ki so produkt znanstvenega udejstvovanja v organiziranih skupinah, največkrat zanemarimo velik del sodelovanja, ki se dogaja znotraj raziskovalnih organizacij. Kljub temu pa predpostavljamo, da soavtorstvo predstavlja aktivno sodelovanje med raziskovalci znotraj organizacij, raziskovalnih skupin, oddelkov ipd. V tem kontekstu velja omeniti, da v moderni znanosti znanstveno sodelovanje razumemo kot sodelovanje ekipe raziskovalcev, ki skupaj ustvarjajo znanstvene rezultate in so zanje tudi vsi odgovorni.

Sodelovanje med sektorji

Danes razumemo sodelovanje med različnimi sektorji: akademskim, industrijo in vladnim sektorjem, kot najpomembnejši element znanstvenega sodelovanja poleg interdisciplinarnosti. Koncepta Mode 2 in Trojna spirala¹ sta razširila idejo sodelovanja znotraj in med sektorji. Oba koncepta so so-

¹Triple Helix

ciologi znanosti razvili v okviru debat o R&R politikah v devetdesetih letih prejšnjega stoletja. Koncept produkcije znanja Mode 2 je bil predstavljen v knjigi *The New Production of Knowledge* (Gibbons in drugi, 1994). V sredini devetdesetih je pomenil simboličen preboj pri preučevanju znanstvenega sodelovanja med različnimi sektorji. Avtorji so v tem novem pristopu povezali klasičen koncept transdisciplinarnosti z dvema dodatnima dejavnikoma: problemskim raziskovanjem in raziskovanjem z neposredno uporabo rezultatov. Podobno je bila koncept Trojna spirala razvita kot neoinstitucionalen in neoevolucijski model za proučevanje sodelovanja med znanostjo v akademski sferi, uporabno znanostjo v industriji, gospodarskim in vladnim sektorjem. V tem modelu je v danem okolju, bolj kot posamezni agenti, pomembna kvaliteta odnosov med njimi (Etzkowitz in Leydesdorff, 2001).

Kljub temu, da obstaja na področju medsektorskega sodelovanja že precej literature, konkretnih bibliometričnih raziskav, ki bi proučevale soavtorstva med akademskim in podjetniškim sektorjem, kronično primanjkuje (Lowrie in McKnight, 2004, pp. 436). V Sloveniji se je z idejo trojne spirale ukvarjal Mali (2002).

2.2.3 Geografska delitev

Geografsko bližina je zgolj ena izmed mer, s katerimi lahko merimo bližino med dvema sodelujočima akterjema. Bližina v kontekstu lastnosti posameznikov sodi med mere podobnosti, ki jih pogosteje obravnavamo v kontekstu raziskav socialne psihologije in socialnega kapitala (Jha in Welch, 2010). Kadar gledamo na znanstveno sodelovanje z vidika prostorske bližine (glej npr: Oort in drugi, 2006), ne moremo mimo velike razlike med dejansko geo-

grafsko razdaljo in sodelovanjem preko mednarodnih meja. Medtem ko so lahko geografske razdalje med sodelavci v državah z veliko površino velike, so, nasprotno, v majhnih državah geografske razdalje pri čezmejnem sodelovanju majhne. Z vidika znanstvenega sodelovanja je pri obeh primerih prečkanje mednarodnih meja bolj pomembno. V nasprotju s sodelovanjem znotraj države, kjer stopnja sodelovanja med partnerji z razdaljo pada, se je na mednarodni ravni v zadnjih desetletjih zgodil dramatičen preobrat (glej na primer: Glänsel in Schubert, 2004; Katz, 1994).

Mednarodno sodelovanje

Že na splošno pomembno mednarodno sodelovanje pa dobi še večjo težo v znanstvenih skupnostih majhnih držav, kakršna je npr. v Sloveniji. Izolirane znanstvene skupnosti danes ne nudijo več zadostne podpore in pretoka informacij za ustvarjanje vidnejših znanstvenih dosežkov. Seveda ta argument v preteklosti ni igral tako pomembne vloge kot danes, vendar že iz zgodovine znanstvenega delovanja poznamo primere, ko je mednarodno sodelovanje znanost poneslo na višjo raven. Ziman (1994) tako navaja, da se "tradicionalni kozmopolitski individualizem v znanosti hitro transformira v nekaj, kar bi lahko opisali kot transnacionalni kolektivizem". V tem kontekstu se je v zadnjih letih kot skrajen primer pojavila nova oblika soavtorskega sodelovanja, imenovana hiper-avtorstvo Cronin (2001). Kot hiper-avtorstvo je označen pojav objav, v katerih sodeluje več sto soavtorjev, ki prihajajo iz različnih institucij iz deset ali več držav. Takšne objave so posledica združevanja moči pri velikih (predvsem fizikalnih) projektih, kakršen je npr. Cernski pospeševalnik.

V preteklosti so mnoge bibliometrične analize potrdile postopno zviševanje

mednarodnega sodelovanja. Trend zviševanja mednarodnega sodelovanja v obliki soavtorstev postaja v zadnjih desetletjih vse bolj intenziven, česar pa ne moremo trditi za klasična soavtorstva na nacionalni ravni (glej npr: Wagner, 2005)².

Kot je navedeno v zelo obsežni literaturi, je nivo sodelovanja na mednarodni ravni opredeljen z mnogimi dejavniki. Najpomembnejši izmed teh so: velikost države, "bližina" držav, pri čemer poleg geografske bližine upoštevamo tudi kulturni, zgodovinski, jezikovni in druge vidike, socio-ekonomski dejavniki ter dinamika, ki jo ustvarjajo raziskovalci sami s svojimi osebnimi preferencami. Kot primer omenimo le nekaj primerov raziskav:

Georghiou (1998) je proučeval naraščajoč pojav globalnega znanstvenega sodelovanja med industrializiranimi državami, ki se odraža v velikem povečanju soavtorskih objav med Evropo in drugimi regijami.

Gómez in drugi (1999) se osredotočajo na mednarodno znanstveno sodelovanje latinsko-ameriških držav. Tako držav med seboj, kot sodelovanje z ZDA in evropskimi državami med leti 1991 in 1995. S soavtorji opisuje vzorce sodelovanja glede na velikost znanstvene skupnosti posamezne države, tematska področja raziskovanja in obliko sodelovanja, v smislu bilateralnega oz multilateralnega sodelovanja. de Lange in Glänel (1997) sta opisovala zgolj vzorce sodelovanja. Razvila sta model za merjenje in analizo obsežnosti multilateralnega mednarodnega sodelovanja v obliki soavtorstev. Model vključuje indeks multilateralnega sodelovanja, ki je definiran kot delež publikacij, objavljenih v soavtorstvu z raziskovalci iz tujine. Nekoliko drugačen pristop sta ubrala Wagner in Leydesdorff (2005), ki sta z uporabo analize social-

²Dokumentiranje trendov sodelovanj omogoča institucionalizirana podatkovna zbirka, ki jo upravlja Institute for Scientific Information, ISI.

nih omrežij testirala hipotezo o mednarodnem sodelovanju kot samoorganizirajočem se omrežju. Pokazala sta, da je rast mednarodnega soavtorskega omrežja mogoče opisati s principom preferenčne izbire³. Obravnavala sta tudi nekaj možnih razlag za odstopanja od idealne potenčne porazdelitve stopenj v omrežju, vključno z vplivom institucionalnih ovir za samoorganizacijo znanstvenega delovanja.

Razlike v intenzivnosti sodelovanja so raziskovalce, ki proučujejo vidike mednarodnega sodelovanja, vzpodbudile k raziskovanju struktur sodelovanja med državami ter iskanju skupin znotraj omrežja mednarodne znanstvene skupnosti. Ena pomembnejših ugotovitev na tem področju je, da v znanosti podobno kot na gospodarskem področju sodelovanje poteka po modelu center - periferija (Wallerstein, 1974). Raziskovanje strukture znanstvenega sodelovanja, z uporabo Wallersteinovega modela, je po eni zgodnejših raziskav na Finskem primeru (Stolte-Heiskanen, 1987) postalo dokaj pogosto, tako na mednarodni kot tudi na lokalni ravni (glej: Moody, 2004; Schubert in Sooryamoorthy, 2010; Kuhn in Weidemann, 2010).

Sodelovanje na lokalno-nacionalni ravni

Sodelovanje v okvirih nacionalne znanstvene skupnosti je z vidika znanstvene vplivnosti in splošne pomembnosti pogosto obravnavano kot manjvredno v primerjavi z mednarodnim sodelovanjem. Pogosto opazovan vpliv in dozvetnost za citiranje pri znanstvenih prispevkih, ki nastajajo v soavtorstvu na mednarodni ravni, odražajo pravilo, da mednarodne soobjave prejmejo več pozornosti, so sprejete v revije z višjim faktorjem vpliva in so pogosteje citirane kot "domače objave" (Glänsel in Schubert, 2004). Kljub temu je

³Ta bo natančneje opredeljena v naslednjih poglavjih.

treba poudariti, da splošna pozornost, namenjena prispevkom, in mednaroden vpliv le-teh ne odraža vedno vrednosti in pomembnosti znanstvenih ugotovitev specifičnih člankov, posvečenih specifičnim temam in problemom, relevantnim na lokalni ravni.

Analize rezultatov sodelovanja v okviru nacionalnih znanstvenih skupnosti so pogosto vključene v publikacije, ki obravnavajo medinstitucionalna ali mednarodna avtorstva (glej npr.: Munshi in Pant, 2004), nekatere pa to tematiko obravnavajo celostno za področje posamezne države (Gossart in Ozman, 2009; Mali in drugi, 2010).

Drug pomemben vidik predvsem merjenja sodelovanja na lokalni ravni je vključenost manj vidnih publikacij v mednarodne bibliografske zbirke, kakršni sta *Web of Science* in *Scopus*. To je pereč problem predvsem v manjših nacionalnih znanstvenih skupnostih, kakršna je slovenska, saj je iz mednarodne perspektive lokalno sodelovanje v obliki soavtorstev, pa tudi citiranje, na lokalni ravni povsem spregledano.

Podoben odklon je prisoten tudi pri merjenju medsektorskega sodelovanja na nacionalni ravni, pri čemer je merjenje sodelovanja na lokalni ravni zaradi fizične bližine in večplastnosti sodelovanja še bolj kompleksno kot sicer. Na nacionalni ravni so se v preteklosti in tudi danes (kot odgovor na omenjeno težavo) razvile lokalne bibliografske zbirke in informacijski sistemi, ki nudijo vpogled v delovanje znanstvene skupnosti na lokalni ravni. V Sloveniji sta taka sistema med seboj povezana SICRISS in COBISS, v Turčiji npr. ULAKBIM⁴.

⁴Seznam bibliografskih sistemov in iskalnikov po znanstvenih bazah je mogoče najti na spletni strani http://en.wikipedia.org/wiki/Category:Bibliographic_databases

2.3 Znanstveno sodelovanje kot socialno omrežje

Definicijo socialnega omrežja je v svojih delih podalo več avtorjev. Granovetter (1973), Wellman in Berkowitz (1988) ter Otte in Rousseau (2002) socialno omrežje opisujejo kot opis družbenih struktur kot skupin pripadnikov sistema in povezav med njimi, ki predstavlja družbene odnose. Marsden tako pravi, da socialno omrežje ni niti metoda niti metafora, temveč pomembno orodje za proučevanje družbene strukture (Marsden, 1990). Socialno omrežje skozi opis strukture interpretira vedenje akterjev iz perspektive njihove pozicije v socialni strukturi (Marsden, 1990; Wellman in Berkowitz, 1988). Matematični pristopi k analizi socialnih omrežij se omrežij lotevajo z vidika teorije grafov; socialno omrežje definirajo kot končno množico akterjev, povezav in funkcij, definiranih s strani teh akterjev (Scott, 2000; Wasserman in Faust, 1994). Kljub temu, da so lahko omrežja definirana v n-dimenzionalnem prostoru, jih največkrat predstavimo grafično, kjer točke v omrežju predstavljajo akterje, povezave med njimi pa socialne relacije oz. komunikacijske kanale (Scott, 2000; Wasserman in Faust, 1994). Kadar uporabimo idejo socialnega omrežja za analizo znanstvenih raziskovalnih sistemov, točke v omrežju predstavljajo raziskovalce, raziskovalne skupine, institucije, države, povezave med njimi pa so komunikacijski kanali, sodelovanje v procesu raziskovanja, soavtorstva idr.

Proučevanje znanosti s pomočjo uporabe analize socialnih omrežij lahko moreno pripomore k razširjenju vedenja o procesu ustvarjanja in prenosa znanja v družbi. V kontekstu tovrstne analize lahko znanost definiramo kot socialno omrežje znanstvenikov ali pa kot kognitivno omrežje znanja oz. vedenja. Če kognitivna struktura znanosti sestoji iz povezav med znanstvenimi idejami, potem se socialna struktura znanosti kaže skozi povezave med raziskovalci.

V tem primeru lahko soavtorska omrežja znanstvenikov obravnavamo tudi kot družbeno strukturo znanosti. Splošni trendi soobjavljanja v znanosti in struktura tovrstnega sodelovanja dejansko zelo dobro orisujejo družbeno strukturo znanosti, zaradi česar je bilo soavtorstvo med raziskovalci znanstvenega sodelovanja vedno v ospredju zanimanja. Skupna objava dveh ali večih avtorjev ima kot indikator precej globji pomen kot zgolj komunikacija med znanstveniki v takšni ali drugačni obliki. Kljub temu pa je sodelovanje med znanstveniki zelo širok pojem, kar mnogi teoretiki znanosti opredeljujejo z idejo, da moderno znanost najbolje opišemo kot multidimenzionalni proces sodelovanja. De Haan (1997) npr. predлага šest indikatorjev za merjenje sodelovanja med znanstveniki: soavtorstvo, souredništvo, skupno mentorstvo doktorandom, skupno prijavljanje na raziskovalne projekte, skupno sodelovanje v raziskovalnih programih in sodelovanje pri pripravi konferenc. Podobno kot De Haan tudi drugi raziskovalci omenjajo zelo širok spekter aktivnosti, ki jih zajema znanstveno sodelovanje (Melin in Persson, 1996; Katz, 1994; Laudel, 2002). Laudel (2002) pravi tudi, da poteka skoraj polovica komunikacije mimo formalnih komunikacijskih kanalov, torej ni zavedena v obliki soavtorske objave oz. formalne opombe ali priznanja v znanstvenem tekstu.

Konceptualizacija in merjenje vseh dimenzijs znanstvenega sodelovanja je torej precej problematična, kar pripelje do pragmatičnega sklepa, da bomo v pričujočem delu znanstveno sodelovanje konceptualizirali s komponento sodelovanja, ki ga lahko nepristransko in formalno definiramo, torej kot skupno objavo oz. soavtorstvo dveh ali več znanstvenikov.

Konceptualizacija znanstvenega sodelovanja kot omrežja je v začetnih fazah bibliometričnih raziskav potekala na intuitivni ravni, kjer so avtorji obravnavali povezavo med so- in več- avtorstvom ter različnimi vidiki znanstvenega

ustvarjanja (glej npr: Price, 1965; Zuckerman, 1967). Do dejanske uporabe metod za analizo socialnih omrežij in razcveta bibliometrije v povezavi z analizo socialnih omrežij je prišlo šele po razvoju elektronskih bibliografskih baz podatkov, kakršne so *Web of Science* (Garfield in Merton, 1979), *SCOPUS* in podobne v osemdesetih letih prejšnjega stoletja. Razvoj metod za analizo socialnih omrežij s poudarkom na analizi dinamike v omrežjih bo predstavljen v nadaljevanju, najprej s splošnim zgodovinskim pregledom dogajanja na področju, pozneje pa tudi s podrobnejšim pregledom metod in vključevanjem primerov analiz omrežij soavtorstev.

2.3.1 Kratka zgodovina razvoja analize dinamike socialnih omrežij znanstvenega sodelovanja

Določanje začetka razvoja nekega področja je nehvaležno opravilo, saj se ideje, ki konstituirajo področje, in metode, ki s časom preidejo pod okrilje nekega področja v prostoru in času, oblikujejo zelo razpršeno. Lep pregled razvoja analize dinamike v socialnih omrežjih sta pripravila Doreian in Snijders (2010) v uvodniku revije *Social Networks*. Za začetek analize socialnih omrežij kot samosvojega področja Freeman (2004) povzame štiri ločene dogodke, ki soustvarjajo začetek discipline. To so: a) fokusiranje na strukturne lastnosti posameznikovega okolja, ki jih določajo posameznikove socialne povezave; b) vsesplošna sistematična uporaba empiričnih podatkov; c) razvoj različnih oblik grafičnih prikazov; d) formulacija pravil in zakonitosti v obliki matematičnih in računskih modelov. S priznanjem štirih dejavnikov, ki oblikujejo analizo socialnih omrežij postane iskanje začetne točke razvoja področja drugotnega pomena. Kakorkoli že, začetek analize socialnih omrežij kot discipline bi lahko, glede s Freemanovo idejo, postavili v trideseta leta

prejšnjega stoletja. Seveda so od določitve nastanka nekega raziskovalnega področja veliko pomembnejši načini kombiniranja štirih komponent skozi čas z namenom razumevanja struktur in procesov v socialnih omrežjih.

Raziskovalna področja, ki želijo v akademskem svetu obstati in se uveljaviti, potrebujejo poleg definiranega problema raziskovanja in kognitivnega omrežja tudi socialno okolje in organizacijo, ki predstavlja prostor za izmenjavo idej in ojačanje identitete discipline. V primeru analize socialnih omrežij je bilo okolje ustvarjeno v kratkih štirih letih. Leta 1976 je Barry Wellman ustanovil mednarodno zvezo raziskovalcev področja (International Network of Social Networks Analysts - INSNA), leto pozneje je ustanovil revijo Connections, ki je namenjena širjenju novic, idej in informacij članom nove raziskovalne discipline. V letu 1978 je izšla prva številka revije Social Networks, ki predstavlja steber za širjenje idej in osrednjo točko promocije napredka analize socialnih omrežij. Kot piko na i sta Russ Bernard in Alvin Wolfe leta 1980 organizirala prvo konferenco Sunbelt, namenjeno socialnim omrežjem. Vsi našteti dogodki so analizo socialnih omrežij povzdignili v samostojno disciplino, ki velja za eno hitreje rastočih in razvijajočih se področij. V Evropi je bila prva konferenca organizirana leta 1989, leta 1995 pa se je združila s konferenco Sunbelt. Sunbelt od takrat poteka vsako leto.

Iz tega, da analiza socialnih omrežij druži skupino raziskovalcev z vidika uporabe določenih metod, ne moremo enostavno sklepati, da govorimo o koherentnem raziskovalnem področju. Da bi preverila strukturo področja, sta Hummon in Carley (1993) analizirala članke, objavljene v prvih dvajstih številkah revije Social Networks. Ugotovila sta, da analizo socialnih omrežij predstavlja integrirana znanstvena skupnost s skupno paradigma. Z *metodo glavne poti*, ki sta jo Hummon in Doreian (1989, 1990) definirala za

proučevanje vzorcev citiranja, sta Hummon in Carely v objavljeni literaturi opredelila šest glavnih poti: a) analizo vlog in bločno modeliranje; b) metode za analizo omrežij; c) ukvarjanje z omrežnimi podatki; d) pristranskostjo v omrežjih; e) strukturo v omrežjih in f) analizo osebnih oz. egocentričnih omrežij. Seveda so poti med seboj povezane in prepletene. Hummon in Carley sta z analizo prišla tudi do drugih ugotovitev, ki definirajo raziskovalno področje. Prva izmed njih je uporaba formalnih matematičnih in kvantitativnih metod, druga vzpostavitev omrežja idej in tretja vzpostavitev vidnih raziskovalnih skupin, ki delujejo na področju analize socialnih omrežij. Vse ugotovitve sovpadajo s prakso *normalne znanosti*, kakršno je definiral Kuhn (1996).

Če gledamo na omenjeni seznam glavnih poti kot na tematski fokus analize socialnih omrežij, v oko zbode dejstvo, da niti ena izmed tem ne obravnavata časovne dimenzije. Do začetka devetdesetih let je bila analiza socialnih omrežij zapisana statičnim metodam. Glavne teme so se dotikale predvsem socialne strukture ter vzorcev, ki jih najdemo v njej. Glede na to ugotovitev so tu še širje dogodki oz. procesi, ki so raziskovalno področje, v devetdesetih zelo spremenili.

Kot začetek velike spremembe lahko zaznamo izid serije treh posebnih izdaj revije *The Journal of Mathematical Sociology* (1996, 2001 in 2003), ki je bila posvečena *evoluciji omrežij*. Urednika serije sta bila Frans Stokman in Patrick Doreian. Z idejo, da so "omrežni procesi serije dogodkov, ki ustvarjajo, vzdržujejo in razkrajajo socialno strukturo" (Doreian in Stokman, 1997), so tri posebne izdaje vsebovale vrsto člankov, ki so za opis dinamike v omrežjih in evolucije omrežij uporabili različne formalne modele, simulacijske metode in statistične modele. V zadnjem času, leta 2010, je tudi v reviji *Social*

Networks izšla posebna številka (30/(1)), posvečena dinamiki v omrežjih, ki seriji v *Journal of Mathematical Sociology* priznava pomembno vlogo v razvoju analize dinamike v omrežjih.

Drugi pomemben dogodek je začetek razvoja modelov eksponentnih slučajnih grafov⁵ (ERGM) za proučevanje sprememb v socialnih omrežjih. Ti modeli izvirajo iz nekoliko zgodnejšega obdobja in temeljijo na delih Hollanda in Leinhardta (Holland in Leinhardt, 1981) ter Franka in Straussa (Frank in Strauss, 1986). Ena linija razvoja izhaja iz del Wassermana in Pattisona (Wasserman in Pattison, 1996; Pattison in Wasserman, 1999), ki sta razvila t.i. p^* modele. Ta linija je implementirana v programskem paketu Pnet (Wang in drugi, 2006), ki služi ocenjevanju ERGM - modelov. Drugo linijo razvoja je utemeljil Snijders (2001) in jo implementiral v obliki programa SIENA (Snijders in drugi, 2010). Tudi ta program je namenjen ocenjevanju ERGM - modelov za analizo koevolucije vedenja akterjev in socialnih omrežij. Obstaja tudi tretja linija, predstavljena v programu Statnet (Handcock in drugi, 2003). Vse tri linije razvoja modelov eksponentnih slučajnih grafov se vzajemno dopolnjujejo in tekmujejo, kar predstavlja odličen teren za razvoj celotnega področja.

Tretji dogodek, ki je zaznamoval obdobje devetdesetih let prejšnjega stoletja, je vstop fizikov na področje analize socialnih omrežij. Bonacich (2004) je v oceni del, ki sta jih napisala Watts (2003) in Barabási (2002), ta vstop označil kot "vdor fizikov." Vdor je mišljen predvsem zaradi fizikalne neobčutljivosti za vse prej kot enostavno in enoznačno naravo vsebine socialnih omrežij, katerih analize so se lotili. Kljub še vedno prisotnim trenjem med družboslovnim in fizikalnim pristopom k analizi socialnih omrežij so fiziki v vedo prinesli

⁵Exponential random graph models (ERGM)

več novih strategij pri modeliranju omrežij in konceptualizaciji pojavov, ki vključujejo strukturi t.i. *malih svetov* in *preferenčne izbire*. Gre za koncepta, ki sta v analizi socialnih omrežij zavzela vidni in pomembni mesti. V splošnem so se fiziki osredotočali predvsem na velika omrežja s ciljem opisati topologijo omrežij in njihovo dinamiko.

Zadnje pomembno dogajanje devetdesetih se je začelo v začetku desetletja in se razvilo v posplošeno bločno modeliranje (Doreian in drugi, 2005) kot posplošitev in nadgradnja tradicionalnega bločnega modeliranja, ki sta ga v osnovi opredelila Hummon in Carley (1993). Kljub temu, da ta pristop pravtno ni bil razvit za analizo omrežne dinamike ima s svojim determinističnim opisovanjem strukture v omrežjih z uporabo širokega nabora tipov blokov in bločnih modelov, lep potencial za nadgradnjo analize dinamike osnovnih omrežnih struktur.

Štirje dogodki in razvoj, ki jim je sledil, so si med seboj precej različni in bi nanje lahko gledali kot na potencialno konkurenco. Slednje bi v zdravem znanstvenem duhu lahko pomenilo priložnost za povezovanje pristopov in principov med seboj. Nekatere ideje, ki so jih v analizo socialnih omrežij prinesli fiziki, bi bile vsekakor vredne vključitve v mehanizme ERGM. Jasno je tudi, da je trud fizikov pri odkrivanju struktur v omrežjih nekako podobnen bločnemu modeliranju, kar napeljuje na idejo združevanja pristopov tako bločnega modeliranja, ERGM kot *malih svetov* in *preferenčne izbire*. Vsi ti pristopi so se pojavili potem, ko sta celotno področje socialnih omrežij analizirala Hummon in Carley (1993) in ne gre jim oporekat priložnosti za nov prodror v analizi omrežij, saj odpirajo polje dinamike in hkrati še vedno odražajo vse štiri lastnosti analize socialnih omrežij ki jih je navedel Freeman (2004).

2.4 Metode proučevanja dinamike omrežij s-avtorstev

Razvoj metodoloških pristopov k analizi in modeliranju dinamike znanstvenih soavtorskih omrežij je bil poleg dejavnikov, omenjenih v poglavju o razvoju analize socialnih omrežij, močno odvisen tudi od razvoja in dostopnosti podatkovnih zbirk s podatki o znanstvenem sodelovanju. Zbiranje bibliometričnih podatkov je bilo do razvoja elektronskih bibliografskih baz izjemno zamudno, zahtevno in drago opravilo. Za najpomembnejši razvojni korak bibliometrije velja elektronska implementacija znanstvenega indeksa citirnosti, ki ga je v teoriji relativno zgodaj opisal Garfield (1955).

Kot je bilo omenjeno, je dinamika v omrežjih postala aktualna tema v letu 1996, ko so bili prvi razvojni koraki metod predstavljeni v posebnih izdajah revije *Journal of Mathematical Sociology* (1996, 1997, 2001, 2003) ter v zadnjem času s posebno izdajo revije *Social Networks* (2010).

V nadaljevanju predstavljamo tri osnovne pristope k proučevanju dinamike socialnih omrežij z aplikacijami na soavtorskih omrežjih: osnovne analize omrežnih lastnosti z uporabo časovnih vrst, deterministične pristope k analizi znanstvenih soavtorskih omrežij ter statistično modeliranje omrežne dinamike. Modeliranje dinamike v omrežjih nudi širok nabor modelov za proučevanje soavtorskih omrežij, zato bo nekaj več prostora namenjeno prav njim.

2.4.1 Osnovne analize značilnosti omrežij skozi čas

Eno prvih analiz sodelovanja raziskovalcev v obliki soobjavljanja, ki je obravnavala tudi časovno komponento, je predstavila Henrietta Zuckerman (1967). Proučevala je vzorce produktivnosti in sodelovanja (predvsem soavtorstev) med Nobelovimi nagrajenci. V primerjavi z današnjimi raziskavami je bila z vidika količine analiziranih podatkov raziskava borna, vendar se ta pokaže v drugačni luči, če upoštevamo, da so bili podatki za raziskavo zbrani neposredno pri nobelovcih.

Več kot dvajset let pozneje sta Bayer in Smart analizirala vzorce objav ameriških doktorandov iz področja kemije v obdobju 1960-62 (Bayer in Smart, 1991).

Uporabila sta longitudinalne podatke iz obdobia med letoma 1962 in 1985 ter tako sledila znanstvenim karieram raziskovalcev skozi čas. Poleg samoavtorskih in večavtorskih objav sta posebej obravnavala tudi dvoavtorske objave. V raziskavi sta predstavila tipologijo vzorcev objavljanja, sestavljeno iz šestih kategorij raziskovalcev: nizko produktivnih, izgorelih, samostojnih, vodij timov, timskih igralcev, dvojčkov ter ‐delavcev,‐ ki skušajo s čim manj dela doseči čim več.

Z razvojem elektronskih bibliografskih baz so enostavne longitudinalne analize podatkov ter posebej osnovnih značilnosti omrežij, kakršne so povprečna stopnja, koeficient grozdenja, gostota⁶, postale obvezen del praktično vsake raziskave o soavtorskih omrežjih (glej za primer: Babchuk in drugi, 1999; Glänsel in drugi, 1999; Kronegger in drugi, 2011).

⁶Definicije mer so podane v poglavju 3.2, ki je posvečeno metodam uporabljenem v praktičnem delu disertacije.

2.4.2 Deterministični pristopi k analizi dinamike omrežij

Kljub temu, da je časovna dimenzija pogosto vključena v analize soavtorskih omrežij, je največkrat omejena zgolj na, v prejšnjem razdelku opisane, časovne vrste nekaterih omrežnih značilnosti. Take analize lahko najdemo praktično povsod, saj je mogoče rezultate večine metod, ki se uporabljajo v analizi socialnih omrežij, predstaviti kot posnetke stanja omrežja v določeni časovni točki. Največkrat je cilj takih predstavitev opisovanje globalnih strukturnih značilnosti soavtorskih omrežij v času v povezavi z merjenimi zunanjimi dejavniki. Primeri iskanja rešitev raziskovalcev, ki bi metodologijo popeljale na višjo raven od zgolj enostavnega opisovanja sprememb med statičnimi slikami omrežij skozi čas, so tako zelo redki.

Kot smo že omenili v delu poglavja o zgodovini razvoja analize socialnih omrežij in metod za preučevanje dinamike v omrežjih, je eden bolj prepričljivih nastavkov za razvoj analize dinamike v omrežjih nadgradnja tradicionalnega bločnega modeliranja (Doreian in drugi, 2005), ki se je začela razvijati v devetdesetih letih prejšnjega stoletja. Osnovna ideja tega pristopa je združevanje enot v skupine glede na podobnost vzorcev povezovanj z drugimi enotami. Načine za interpretacijo povezav med skupinami sta leta 1971 predstavila Lorrain in White (1971). V zadnjih letih je bilo v literaturi objavljenih več aplikacij posplošenega bločnega modeliranja na podatkih o soavtorskih omrežjih: Said je s sodelavci opredelil nekaj stilov soavtorskega sodelovanja, ki vključujejo samoavtorstvo, mentorski model, podjetniški in timski model. Zaključili so, da nekateri soavtorski stili lahko vodijo v skupinsko razmišljanje, zmanjšano kreativnost in manj rigorozeni ocenjevalni postopek. Zaključki Saida in drugih kažejo tudi na to, da se v soavtorskih omrežjih pogosto pojavlja bločna struktura z velikim številom centrov (Said in drugi,

2008).

Nooraie je s sodelavci raziskoval soavtorska omrežja treh iranskih akademskih raziskovalnih centrov. Iskali so povezavo med znanstveno produktivnostjo, indikatorji vpliva in značilnostmi omrežij. Omrežja sodelovanj v raziskovalnih centrih so med seboj delila več strukturnih značilnosti, kakršno je na primer sodelovanje v obliki zvezd, kjer z enim samim raziskovalcem sodeluje veliko število različnih soavtorjev. V znanstveno bolj uspešnih raziskovalnih centrih je Nooraie s sodelavci odkril bolj povezana, gostejša omrežja (Nooraie in drugi, 2008).

Nekoliko nadgrajena aplikacija metode je bila pred kratkim objavljena v reviji Q&Q, kjer smo Kronegger in drugi (2011) ločili različne kulture soobjavljanja med različnimi analiziranimi disciplinami. Metodo smo nadgradili s sledenjem povezav v času ter interpretirali bločne modele v povezavi z zunanjimi spremenljivkami. Rezultati te raziskave so natančneje predstavljeni v nadaljevanju naloge.

Poleg bločnega modeliranja predstavlja pomemben korak naprej od statične k dinamični analizi omrežij delo Ertna, Ganserja in njunih sodelavcev (Erten in drugi, 2004; Gansner in drugi, 2004). Razvili so nadgradnjo metode večrazsežnega lestvičenja (Richardson, 1938; Torgerson, 1952). Večrazsežno lestvičenje ⁷ je skupek metod, ki služijo vizualni predstavitev večrazsežnih podatkov. Algoritem dinamičnega večrazsežnega lestvičenja omogoča optimizacijo napetosti tako na ravni posameznega leta oz. merjenja omrežja kot tudi optimizacijo na ravni daljšega obdobja. Algoritem, umeščen v program Visone (Leydesdorff in Schank, 2008), je namenjen vizualizaciji omrežij in uporabljen na soavtorskih omrežjih z dodano informacijo o sopojavljanju

⁷multidimensional scaling

besed in indeksom citiranja (Leydesdorff, 2010).

Loet Leydesdorff se je z analizo dinamike v omrežjih ukvarjal tudi s precej samosvojim pristopom z uporabo teorije prenosa informacij in entropije (Leydesdorff, 1991). Pristop je zaradi računskih omejitev bolj primeren za analizo usmerjenih omrežij.

2.4.3 Modeliranje dinamike v omrežjih soavtorstev

V tem delu poglavja predstavljamo pregled metod za modeliranje dinamike v socialnih omrežjih. V prvem delu se ukvarjamo z modeli, ki temeljijo na stohastičnih pravilih generiranja omrežij tako, da odražajo določene lastnosti na makro - globalnem nivoju. Razvoja teh modelov so se v 90-tih lotili fiziki z idejo reproduciranja z grafi predstavljenih omrežij iz realnega sveta. V praksi so iskali algoritme, s katerimi bi umetno ustvarili omrežja, ki bi odražala značilnosti realnih omrežij.

Razvoj tovrstnih modelov je potekal od enostavnih slučajnih grafov, generiranih po Erdős–Rényi modelu (Erdős in Rényi, 1959), do omrežij s strukturo malih svetov (Watts in Strogatz, 1998) in serijo modelov, ki temeljijo na konceptu preferenčne izbire (Barabási in drugi, 2002; Newman, 2000) .

Druga smer razvoja modeliranja dinamike v omrežjih, predstavljena v drugem delu poglavja, sloni na delu raziskovalcev, ki izhajajo iz družboslovnih znanosti in psihologije. Če so se fiziki modeliranja lotili z idejo reprodukcije realnega omrežja, neupoštevajoč dolgoletno tradicijo družboslovnega in psihološkega raziskovanja vedenja posameznika in družbe, so se sociologi modeliranja lotili iz perspektive posameznega akterja ter njegove vpetosti v diado,

to je najmanjšo možno enoto analize z vidika povezanosti v omrežju. Tovrstno modeliranje se imenuje stohastično modeliranje na nivoju posameznika (Snijders, 1996)⁸. Metoda je namenjena predstavitev dinamike v socialnih omrežjih na podlagi longitudinalnih podatkov. Ena pomembnejših lastnosti metode je, da omogoča poleg predstavitev rezultatov tudi njihovo evalvacijo glede na paradigma statističnega sklepanja. S tovrstnimi modeli dinamiko v omrežjih opisujemo kot rezultat kompleksnega prepleta različnih dejavnikov, ki so vnaprej definirani na podlagi sociooloških oz. psiholoških teorij ali predpostavljeni na podlagi predhodnih empiričnih raziskav. Vsi ti dejavniki v modelu delujejo simultano (Snijders in drugi, 2010).

Fizikalne metode in modeliranje omrežij iz “realnega sveta”

Raziskave s področja sociologije znanosti so strukturo v omrežjih znanstvenih skupnosti pogosto povezovale z znanstveno produktivnostjo. Za opisovanje in modeliranje velikih znanstvenih omrežij je Moody opisal tri značilne strukturne tipe: (1) Kadar se znanstveniki znotraj omrežja povezujejo na podlagi specialnosti oz. področij, ki jih preiskujejo, lahko v omrežju pričakujemo grozdenje (ang.: clustering), to je nastanek bolj ali manj ločenih skupin raziskovalcev. Taka omrežna struktura sovpada z strukturo, ki odraža *male svetove*. (2) Če se raziskovalci povezujejo po principu *preferenčne izbire*, se novi raziskovalci v omrežje povezujejo predvsem z objavljanjem skupaj z že uveljavljenimi, dobro povezanimi raziskovalci, t.i. znanstvenimi zvezdami. V takem omrežju lahko pričakujemo potenčno porazdelitev stopenj oz. brezlestvično omrežje⁹. (3) Kadar omenjeni strukturni značilnosti v omrežju nista prisotni, govorimo o strukturno-kohezivnem modelu, kjer vzpostavlja-

⁸stochastic actor based modeling

⁹scale-free network

nje povezav poteka naključno z enakomerno verjetnostjo. Tak strukturni tip je posledica sodelovanja med raziskovalci z različnih raziskovalnih področij in specialnosti - nekakšen idealni tip delitve dela (Moody, 2004).

Vse tri strukturne lastnosti omrežij so posledica specifične dinamike v procesu generiranja omrežja, ki vpliva tako na lokalne značilnosti v omrežju kakršni sta koeficient grozdenja ali stopnja za posameznega akterja, kot na globalne značilnosti, kakršna je na primer povprečna razdalja med enotami omrežja.

Osnova za vsakršno modeliranje socialnih omrežij je Erdős–Rényi model (Erdős in Rényi, 1959) generiranja slučajnih grafov, ki je določen s številom enot n in verjetnostjo p , s katero obstaja povezava med dvema enotama. Vsak tako generiran graf ima potem takem približno $p \cdot n(n - 1)/2$ neusmerjenih povezav. Porazdelitev stopenj v takem omrežju je porazdeljena po Poissonovi porazdelitvi (Kejžar, 2007). Prva poslošitev Erdős–Rényijevega modela je t.i. konfiguracijski model, v katerem porazdelitev stopenj med enotami določimo glede na vnaprej predvideno porazdelitev. V drugem koraku enote naključno povežemo glede na njihovo stopnjo. Konfiguracijski model je predlagal Molloy in Reed (1995), preučevala pa ga je cela vrsta avtorjev (za pregled literature glej Newman, 2003). S tem postopkom so raziskovalci sicer rešili problem porazdelitve stopenj, ki v realnih omrežjih praviloma ni Poissonova tako kot v Erdős–Rényijevih grafih, ostala pa je težava grozdenja, s katero so se spopadli nekaj let pozneje.

V nadaljevanju bomo nekoliko natančneje opisali algoritme modelov malih svetov in preferenčne izbire ter opredelili sociološke dejavnike za njihov razvoj.

Model malih svetov

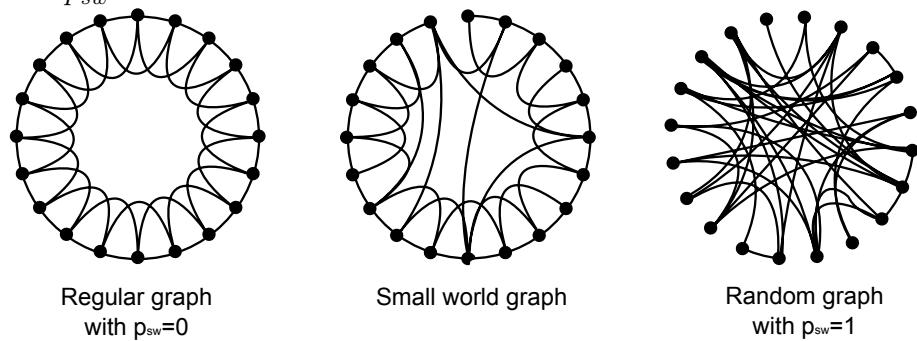
Omrežna struktura malih svetov je v tehničnem smislu definirana z dvema lastnostma: visokim povprečnim koeficientom grozdenja, ki nekoliko poenostavljeno predstavlja verjetnost, da imata dva soavtorja enega raziskovalca skupno objavo, ter relativno kratko povprečno razdaljo med vsemi člani omrežja. Omrežje s tako strukturo sestavljajo skupine močno povezanih posameznikov, ki so med seboj jasno ločene in hkrati povezane z redkimi povezavami. Raziskovalci s področja analize socialnih omrežij pravijo, da ideja malih svetov izhaja iz dela, ki sta ga objavila de Sola Pool in Kochen (1978) v članku, ki je (sicer le delno) formaliziral izsledke veliko bolj znane raziskave Treversa in Milgrama (Travers in Milgram, 1969). Zaključek raziskave je enostavna ideja, da je vsak naključno izbran par posameznikov, živež praktično kjerkoli na svetu, povezan z verigo majhnega števila neposrednih znancev. Empirični rezultati raziskave so pokazali, da je število okrog 6^{10} . Prvi praktični dokaz za obstoj malih svetov je predstavil psiholog Milgram (v Berg, 2004, str. 46), ki je tako postavil tudi temelje za analizo tovrstne strukture v soavtorskih znanstvenih omrežjih.

Pozneje sta Watts in Strogatz (1998) formalno definirala *model malih svetov* z namenom generiranja omrežij, ki bi odražala lastnosti nekaterih opazovanih omrežij: 1) kratke poti med katerima koli dvema enotama in posledično kratko povprečno razdaljo med njimi in 2) da bi vsebovala grozdenje, manjše dele omrežij, ki so navznoter bolj močno (gosto) povezana kot navzven. Glede na to, da vemo, da geografska bližina igra pomembno vlogo pri ustvarjanju novih povezav (predvsem med ljudmi), sta Watts in Strogatz model razvila

¹⁰Poimenovanje tega fenomena se je v splošno uporabo prebilo z upodobitvijo v Broadwayski predstavi "Six degrees of separation."

iz obroča povezanih enot¹¹ sestavljenega iz n enot, v katerem ima vsaka enota m_{sw} povezav do svojih sosedov. V drugi fazi sta enote izbirala z verjetnostjo p_{sw} in jih povezovala z naključnimi točkami v omrežju. Verjetnost p_{sw} definira to omrežje od povsem urejene ‐enostavne mrež‐ do povsem neurejenega slučajnega omrežja.

Slika 2.1: Modeliranje strukture malih svetov v omrežju z različnimi vrednostmi p_{sw}



(vir: Watts in Strogatz, 1998)

Omrežje v obliki obroča nima lastnosti malih svetov, saj povprečna najkrajša pot med dvema enotama z večanjem omrežja narašča hitreje kot logaritemsko, ima pa visoko stopnjo grozdenja. Z dodatnim povezovanjem enot podremo čisto strukturo obroča in povežemo enote naključno. Watts in Strogatz sta opazila, da že samo nekaj takih povezav občutno zmanjša povprečno najkrajšo pot na nivoju celotnega omrežja. Kot posledica spremembe se pojavi učinek malih svetov.

Kadar je $p_{sw} = 1$, postane omrežje povsem neurejeno, z lokalnim koeficientom grozdenja blizu 0 in zelo kratko povprečno najkrajšo razdaljo. S simulacijo sta pokazala, da med ekstremno urejenostjo in neurejenostjo omrežja obstaja relativno velik interval vrednosti p_{sw} , pri katerih sta povprečna najkrajša pot

¹¹ring lattice

in koeficient grozdenja taka, da lahko govorimo o strukturi malih svetov.

Newman (2001, 2004) podaja odličen pregled analiz topologije malih svetov s poudarkom na ključnih organizacijskih principih, ki usmerjajo ustvarjanje povezav med enotami v omrežjih. Kot pravi Moody (2004), vsebuje arhetipsko omrežje s strukturo malih svetov veliko število med seboj ločenih skupin, ki so med seboj povezane z majhnim številom povezav. Empirična analiza dinamike soavtorskih omrežij slovenskih sociologov (Mali in drugi, 2010), katere rezultati so natančneje predstavljeni v poznejših poglavjih, je pokazala navznoter zelo povezane skupine raziskovalcev, ki so med seboj izrazito ločene. Nadaljnji rezultati iste raziskave so pokazali, da pretirana vpetost v skupine močno vpliva na strukturo znanstvenih objav posameznega raziskovalca. Močno interno povezani raziskovalci so usmerjeni na objave znanstvenih poročil in člankov v domačih, lokalnih znanstvenih revijah z nizkim znanstvenim vplivom na mednarodnem nivoju. Obratno omrežja raziskovalcev z veliko strukturnih lukenj omogočajo so-objavljanje z raziskovalci iz različnih okolij, ki tako objavljujo v mednarodnem okolju in pomembnejših revijah. Burt je na podobno temo predstavil dokaze, iz katerih lahko sklepamo, da se nove ideje v družbi porajajo skozi procese izborov in sintez, ki potekajo na področju strukturnih lukenj med posameznimi družbenimi skupinami. Pozitivne ocene delovanja in dobre ideje so tako predvsem v rokah povezovalcev skupin, katerih omrežja zapolnjujejo strukturne luknje (Burt, 2004).

Model preferenčne izbire

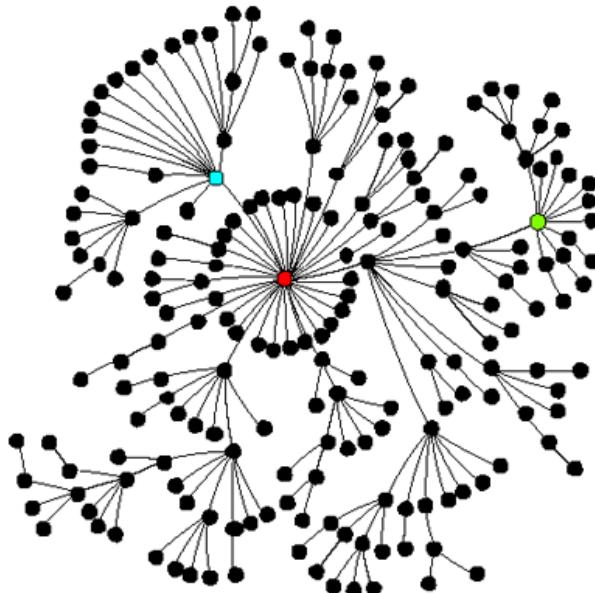
Brezlestvična¹² omrežna struktura, precej dobro sovpada s sociološkim modelom *kumulativne prednosti* v znanosti. Prvo sistematično predstavitev tega modela je zagotovil Merton (1973). Mertonovi sodobniki so idejo kumulativne prednosti nadgradili in jo predstavili kot temeljni pojasnjevalni princip družbene stratifikacije znanosti. Merton je na fenomen znanosti gledal tako iz organizacijskega kot funkcionalnega vidika znanosti, ki je samo-regulirajoča se institucija. Znanost je definiral s štirimi institucionalnimi imperativi: univerzalizem, komunizem, nesebičnost in organiziran skepticizem. Tako Merton kot drugi raziskovalci, ki so delovali iz podobne perspektive (npr. Barber, Zuckerman, Hagstrom), so analizirali norme, ki regulirajo znanstveno dejavnost. Raziskovali so načine, kako so viri in nagrade (vključno z znanstvenim prestižem in možnostmi objavljanja) pripisani in razdeljeni znotraj znanstvenih skupnosti (glej za primer: Matthew, 2005; Bucchi, 2004).

Ideja kumulativne prednosti izhaja iz nasprotnega pomena odlomka Matejevega evangelija, ki govorí o tem, da "bodo bogati bogatejši revni še revnejši". Od tod tudi ime Matejev efekt oz. Matejev učinek. Če idejo prevedemo, kumulativna prednost v znanosti pomeni, da so znanstveniki, ki v sedanjosti zasedajo ugledne položaje v znanosti, za enak trud veliko bolje nagrajeni kot tisti z manj uglednih položajev. Delo bolj uglednih raziskovalcev prej doseže priznanje v znanstveni skupnosti kot pri manj uglednih. Merton je trdil, da je kumulativna prednost mehanizem moderne znanosti, oz. funkcionalnost distribucije moči, ki služi ohranjanju moči in ustvarjanju znanstvenih zvezd¹³.

¹²Scale-free oz. brezlestvična omrežja so tista, pri katerih so stopnje porazdeljene po približno potenčni porazdelitvi

¹³Merton in njegovi sociološki sodobniki (glej: Allison in drugi, 1982; Cole in Cole, 1973)

Slika 2.2: Primer brezlestvičnega omrežja



(vir: <http://mcdb.colorado.edu/>)

Pojav neenake porazdelitve publikacij v povezavi s porazdelitvijo nagrad za znanstveno delovanje je na računski in bibliometrični osnovi med drugimi opredelil tudi Price (1976; 1963), in sicer z izpeljavo svoje mere znanstvene produktivnosti. Po Priceovem zakonu: "... polovico znanstvenih objav na

so poleg kumulativne prednosti analizirali tudi druge mehanizme ki poganjajo znanstvena omrežja, strukture sodelovanja in nagrajevanja v znanosti:

1. "Halo efekt" v znanosti označuje prednost posameznikov na ustreznih institucionalnih pozicijah;
2. "Matilda efekt" kaže na mehanizme diskriminacije žensk v znanstvenem delovanju;
3. "Vratarji" so tisti znanstveniki, ki lahko vplivajo na razdeljevanje virov npr. sredstev, pedagoških pozicij ali možnosti objavljanja, ker zasedajo odločevalno pozicijo znotraj znanstvene organizacije oz. skupnosti;
4. Ideja "nevidnih znanstvenih skupnosti" (invisible colleges) je bila predstavljena na temelju trditve iz sedemnajstega stoletja, ki označuje neformalne strukture raziskovalcev, ki se ustvarijo okrog specifičnih projektov in se v smislu ustvarjanja novih znanj pogosto izkažejo kot bolj vplivne od formalnih skupnosti (oddelki, raziskovalni centri ipd.).

nekem področju objavi kvadratni koren števila vseh avtorjev, ki delujejo na tem področju” (Price, 1963, str. 67). To pomeni, da celotno znanstveno producijo ustvari relativno majhno število zelo produktivnih raziskovalcev. Priceov zakon temelji na podobnih idejah kot starejši Lotkov zakon¹⁴, Bradfordov zakon¹⁵, ter Paretova in Zipfova¹⁶ porazdelitev.

Tako Priceov zakon kot Matejev učinek poudarjata, da je znanstvena skupnost strukturirana na bazi neenakosti in piramidne porazdelitve znanstvenih objav in nagrad. Oba sta povezana s principom preferenčne izbire, ki tudi v primeru znanstvenega sodelovanja v obliki soavtorstev vsebuje dva splošna principa: 1) neprestano dodajanje novih enot v omrežje in 2) preferenčno povezovanje novih enot z bolje povezanimi enotami. To pomeni, da vsi tovrstni modeli neprestano rastejo z dodajanjem novih enot, ki se povezujejo z enotami iz že obstoječega omrežja. Velja tudi to, da posamezniki, ki vstopajo v tako omrežje, praviloma vstopajo v vlogi podpornikov že uveljavljenih akterjev. S podobnimi modeli so se ukvarjali tudi drugi raziskovalci. Berg je za opis enake strukture opredelil sistem povratnih dejavnikov¹⁷, kjer razvoj na enak način kot pri ostalih modelih vodijo tako prednosti starejših akterjev pred novimi, kot, pri že povezanih, prednosti tistih z več povezavami pred tistimi z manj povezavami. Slednje povsemsovпада z modelom preferenčne izbire (Berg, 2004).

¹⁴Lotkov zakon pravi, da: število avtorjev, ki ustvari n znanstvenih prispevkov, predstavlja približno $1/n$ tistih, ki ustvarijo samo en znanstven prispevek, kjer je vrednost ’ a pogosto enaka 2

¹⁵Bradfordov zakon pravi, da: lahko revije iz nekega področja razdelimo na tri dele: 1) nekaj centralnih revij, 2) drug del z večjim številom revij in 3) tretji del z večino revij. Število revij v treh skupinah je porazdeljeno v razmerju $1 : n : n^2$.

¹⁶Zipfov zakon pravi da je verjetnost pojavljanja besed na začetku visoka, potem pa počasi pada. Vseeno pa se nekatere besede ves čas pojavljajo pogosto, nekatere pa redko. Formalna definicija zakona pravi: $P_n \sim 1/n^a$, kjer P_n predstavlja frekvenco pojavljanja n -te rangirane enote in je a blizu 1.

¹⁷feedback effects

Diana Crane (1972) je predstavila analizo (globalnih) znanstvenih omrežij, s poudarkom na neformalni pripadnosti znanstvenim elitam (če uporabimo Moodyeve terminologije, skupini znanstvenih zvezd), preko katerih poteka komunikacija znotraj in med znanstvenimi disciplinami. Z vidika analize omrežij pripada takim posameznikom vloga vozlišč (hubs), ki posredujejo informacije vsem drugim raziskovalcem v omrežju. Hkrati pa tudi intenzivno komunicirajo med seboj. Idejo znanstvenih omrežij z vozlišči lahko uporabimo kot osnovo za povezavo med mikro nivojem interakcij (npr. med lokalno in nacionalno znanstveno skupnostjo) in makro nivojem (npr. globalno znanstveno skupnostjo). S pomočjo neformalnih znanstvenih elit interakcijo na osebnem, lokalnem nivoju prevedemo v vzorce komuniciranja na nivoju celotne skupnosti. Vzorci komuniciranja na visokem nivoju (mednarodne znanosti) imajo potem zopet vpliv na majhne znanstvene skupine v lokalnem okolju znanstvenega delovanja. Ustvarjanje in razširjanje najbolj prodornih znanstvenih idej v svetovnem merilu prihaja iz omrežij, ki so med seboj povezana z vozlišči (brokered networks) (Granovetter, 1973, str.1360).

Albert in Barabási (2001) sta k proučevanju realnih omrežij pristopila z analizo večih podatkovnih zbirk. Ugotovila sta, da pri večini analiziranih omrežij porazdelitev stopenj odstopa od Poissonove porazdelitve, značilne za slučajno generirana omrežja. Pokazala sta, da lahko porazdelitev stopenj v realnih omrežjih opišemo s potenčno funkcijo. Predlagala sta nov, razvijajoč model preferenčne izbire (Barabási in Albert, 1999).

Model je bil predstavljen kot prehod od “modeliranja topologije omrežij, k modeliranju rasti in razvoja omrežij v času” (Albert in Barabási, 2001). Njuna ideja je bila v model zajeti pravila, ki usmerjajo razvoj omrežja, s katerimi bi lahko pojasnila prisotnost potenčne porazdelitve stopenj v opazovanih

omrežjih. Prejšnji pristopi k modeliranju so delovali na fiksniem številu enot, kjer so bile povezave med enotami dodajane glede na določeno pravilo. Ker realna omrežja največkrat rastejo z dodajanjem novih enot in povezav, ki niso vzpostavljeni slučajno, sta Albert in Barabási v model vključila ideje, algoritemsko zapisane v dveh korakih:

- V vsakem koraku omrežju dodamo novo enoto v .
- Ustvarimo m_{ba} povezav, ki enoto v povezujejo z enotami, ki so že del omrežja. Povezane enote so izbrane z verjetnostjo, ki je sorazmerna z njihovo stopnjo. Verjetnost, da bo izbrana enota u lahko izrazimo kot $k_u / \sum_j k_j$, kjer k_u predstavlja stopnjo enote u).

Po t korakih je v omrežju $t + m_0$ enot, kjer m_0 predstavlja število enot v omrežju na začetku procesa in tm_{ba} povezav. Na podlagi simulacij sta Albert in Barabási pokazala, da je porazdelitev stopenj takega omrežja mogoče opisati s potenčno funkcijo $p_k \sim k^{-\gamma}$ z eksponentom $\gamma = 3$.

Poleg omenjene osnovne opredelitve je bilo predstavljenih še veliko posproštev modela preferenčne izbire (Albert in Barabási, 2001; Newman, 2003).

Sistematične odklone od potenčne porazdelitve pri majhnih stopnjah lahko najdemo v veliko različnih realnih omrežjih. Da bi to upošteval, je Pennock s sodelavci predlagal model z (uteženo) kombinacijo preferenčne in naključne izbire (Pennock in drugi, 2002). Precešen korak pri izpopolnitvi modela predstavlja tudi implementacija v programu Pajek (Batagelj in Mrvar, 2010), kjer je implementirana verzija algoritma za usmerjena omrežja. V tem primeru so enote za povezovanje lahko izbrane na podlagi utežene vhodne, izhodne stopnje ali pa uniformno.

Drugo pomembno posplošitev obeh modelov tako malih svetov kot preferenčne izbire je na soavtorskih omrežjih s spektrom projekcij in z implementacijo različnih metod za dvovrstna omrežja predstavil Latapy s sodelavci, ki v članku predstavlja tudi lep pregled razvoja metod za dvovrstna omrežja (Latapy in drugi, 2008). Opsahl (2010) pa se na različne načine prebija skozi težave pri računanju koeficientov grozdenja za projekcije iz dvovrstnih v enovrstna omrežja. Problem rešuje z redefinicijo globalnega in lokalnega koeficiente grozdenja tako, da ju po njegovi zaslugi lahko izračunamo že na dvovrstnih omrežjih.

Uporaba fizikalnih modelov na soavtorskih omrežjih

Newman (2001) je pokazal, da vsebujejo soavtorska omrežja strukturo malih svetov, v katerih je povprečna najkrajša pot med dvema raziskovalcema relativno kratka. Prav tako je analiziral porazdelitev stopenj iz. števila soavtorjev posameznega raziskovalca, prisotnost grozdenja in poudaril številne očitne razlike v vzorcih sodelovanja med posameznimi disciplinami.

Pozneje je Newman (2004) analiziral podatke treh bibliografskih zbirk iz področij biologije, fizike in matematike, kjer je podobno kot v prejšnjem članku predstavil omrežja sodelovanja med raziskovalci. V članku je analiziral različne vidike znanstvenega delovanja, kot so: število člankov, ki jih objavi posamezen avtor, število soavtorjev posameznega raziskovalca in število avtorjev posameznega članka. Tudi tu je preučeval tipično razdaljo med dvema pripadnikoma omrežja ter spremembe analiziranih parametrov skozi čas.

Barabási in sodelavci so analizirali soavtorska omrežja, generirana iz elek-

tronskih baz, ki vsebujejo vse relevantne revije iz področja matematike in neuro-znanosti v obdobju od leta 1991 do 1998. Ugotovili so, da razvoj omrežja sicer usmerja princip preferenčne izbire, kljub temu pa se je v nasprotnu z njihovimi pričakovanji povprečna stopnja v omrežju s časom povečevala, razdalja med enotami pa je bila vedno manjša (Barabási in drugi, 2002).

Moody (2004) je pri opisovanju struktur v omrežjih soavtorstev naredil velik korak naprej, saj je v članku principa malih svetov in preferenčne izbire opredelil iz nivoja posameznega raziskovalca. Kljub opredelitvi pa je v analizi omrežja še vedno uporabil že preverjene metode, ki so jih razvili Albert in Barabási (2001), ter Watts in Strogatz (1998). Slednje metode so postale pomemben del analiz različnih podatkovnih zbirk, tako da so uporabljene v vrsti člankov (npr. Perc, 2010; Wagner in Leydesdorff, 2005; Tomassini in Luthi, 2007).

Modeliranje longitudinalnih podatkov o omrežjih

V obdobju, ko sta Erdős in Rényi proučevala lastnosti slučajnih omrežij in sta Pool in Kochen objavila rezultate prve raziskave, kjer sta teorijo grafov uporabila kot orodje za analizo družboslovnih podatkov (de Sola Pool in Kochen, 1978), je del znanstvene skupnosti, predvsem raziskovalcev s področja matematike v povezavi s sociologi, raziskoval lokalne mehanizme, ki uravnavaajo in vzpodbujujo spremembe v socialnih omrežjih na mikro ravni. Hkrati so iskali tudi možnosti za vpeljavo inference, sklepanja iz vzorca na populacijo, ki v analizi socialnih omrežij z uporabnimi metodami dotlej ni bila mogoča. Osnova za modele dinamičnih omrežij so, kot smo omenili že v prejšnjem razdelku, slučajni grafi in naključni procesi v grafih, s katerimi je mogoče pokriti negotovos, t vsebovano v realnih, merjenih omrežjih. Nego-

tovost, ki mora biti zajeta tudi v modelu, je prisotna zaradi velikega števila nemerjenih dejavnikov, ki vplivajo na dogajanje v omrežjih. Statistično analizo socialnih omrežij spremljajo specifične težave, ki močno otežujejo razvoj tovrstnih metod. Če omrežje opišemo kot matriko in kot osnovno enoto analize obravnavamo diado, to je povezavo med dvema akterjema, so medsebojne odvisnosti med akterji v omrežju lahko: a) odvisnost med dvema akterjema ene diade, b) odvisnost med vrsticami oz stolpci v matriki in c) zapletena sestavljena odvisnost, ki je npr. posledica tranzitivnosti - *“prijatelj mojega prijatelja je tudi moj prijatelj”*. K problemu odvisnosti različni modeli pristopajo na različne načine.

K modeliranju sprememb v omrežjih skozi čas obstajata dva pristopa: prvi, ki spremembe v omrežju obravnava v diskretnih časovnih korakih, ter drugi nekoliko mlajši in naprednejši pristop, kjer je čas obravnavan zvezno. Obširen pregled razvoja metod obeh pristopov lahko najdemo v Frank (1991), Snijders (1996) in v Snijders in drugi (2010).

Markovski modeli z diskretno obravnavo časa

Prvi članek, ki je obravnaval spremembe znotraj socialnih omrežij, sta objavila Katz in Proctor (1959). Pokazala sta, da lahko preference posameznikov, ki vodijo v vzpostavitev novih povezav, predstavimo kot stacionaren, diskreten Markovski model. Definicija tega modela temelji na predpostavki, da so posamezne diade v omrežju med seboj neodvisne. Ta predpostavka je najrazličnejše modele spremljala vse do nedavnega, kljub temu, da naj bi vsak netrivialen družboslovni model upošteval vse tri prej omenjene tipe odvisnosti.

Leta 1981 sta Holland in Leinhardt objavila odmeven članek o loglinearnih modelih sprememb v omrežjih, ki je vzpodbudil razcvet in hiter razvoj novih modelov. Osnovni model Hollanda in Leinhardta, ki se je imenoval p_1 model, so pozneje nadgradili Fienberg in Wasserman (1981) ter Wasserman in Weaver (1985). Wasserman in Weaver sta predstavila tudi učinkovite algoritme za iskanje ocen parametrov z metodo največjega verjetja, s katerimi sta definirala primerno porazdelitveno funkcijo. Fienberg je s sodelavci definiral postopke za uporabo Holland-Leinhardtovega modela v kombinaciji s kontingenčnimi tabelami ter uporabo osnovnih loglinearnih modelov (Fienberg in drugi, 1985). Loglinearni model sta s časovno dimenzijo nadgradila Wasserman (1987) in Wasserman in Iacobucci (1988). Kljub temu, da je metodologija napredovala, pa je predpostavka o neodvisnosti diad ostala nedotaknjena.

Modeli pogojno enakomernih porazdelitev verjetnosti vzpostavljanja novih povezav (Holland in Leinhardt, 1975) so bili praviloma uporabljeni za usmerjena omrežja, kjer je porazdelitvena funkcija enakomerna glede na določeno skupino dejavnikov oz. lastnosti akterjev. V tem modelu je pogojna statistika definirana glede na najpomembnejše lastnosti v model vključene kot spremenljivke, ostali dejavniki pa so v model vključeni kot naključni oz. kot napaka. Kadar želimo v model vključiti več kot zgolj peščico lastnosti akterjev, postane model močno zapleten in nepregleden. Tovrstne modele za uporabo na longitudinalnih omrežjih brez vrednosti na povezavah, zgolj v dveh časovnih točkah, je predstavil Tom Snijders (1990). Snijdersov model je pogojen s celotnim omrežjem v začetni časovni točki ter s številom novo vzpostavljenih in prekinjenih povezav, kar je princip, ki je zaživel tudi v poznejših modelih.

Markovske verige v nediskretnem času

Idejo, da bi za nekatere klasične sociološke probleme uporabil Markovske verige z zvezno obravnavo časa, je že leta 1964 predstavil in realiziral James S. Coleman. Holland in Leinhardt (1977) sta idejo uporabila za modeliranje medosebnih odnosov. Razvila sta pristop, s katerim lahko z uporabo Markovskih verig modeliramo proces, v katerem družbena struktura iz omrežja vpliva na vedenje posameznega akterja.

Osnovne predpostavke, ki usmerjajo delovanje Markovskih verig v zveznem času, so:

1. Med posameznimi opazovanji oz. zbiranji podatkov čas nepretrgoma teče. Spremembe v omrežju se lahko zgodijo v katerikoli (neopazovani) časovni točki t .
2. Omrežje $X(t)$ je rezultat Markovskega procesa.
3. V vsakem trenutku t se lahko zgodi natanko ena sprememba v omrežju ali sprememba spremenljivke z lastnostmi akterjev.

Stanley Wasserman (1978, 1980b,a) je nadaljeval z razvojem tega pristopa in predstavil ocene parametrov za različne modele, začenši z enostavnimi modeli vzajemnosti v usmerjenih omrežjih, a še vedno brez upoštevanja zapletenih odvisnosti, kakršne so posledica tranzitivnih triad.

Naslednji velik preboj v modeliranju dinamike v socialnih omrežjih je bila sprostitev predpostavke o pogojni neodvisnosti posamičnih diad med seboj (Mayer, 1984). To je bil velik korak, glede na to, da večina socioloških teorij predpostavlja vsaj kakšno strukturno odvisnost med dvojicami. Serijo

pomembnih korakov v razvoju metod pa je nadaljeval Leenders (1995), ki je omogočil sprostitev predpostavke o stacionarnosti markovske verige. Leenders je razvil tudi mehanizem, ki omogoča spreminjanje hitrosti sprememb v diadah glede na spremenljivke, ki so del modela, s predpostavko, da se vrednost spremenljivke med dvema merjenjema ne spremeni.

Stohastični modeli delovanja posameznikov v omrežju

V zadnjih letih je bilo razvitih precej stohastičnih modelov delovanja posameznikov v omrežjih, ki vsak na svoj način obravnavajo kakšnega izmed specifičnih psiholoških ali socioloških mikro mehanizmov. Vsi ti modeli temeljijo na predpostavki, da ima vsak posameznik svoje cilje, ki jim skuša slediti v skladu z omejitvami, ki ga obkrožajo, in svojimi sposobnostmi. Snijders (1995) je tak pristop k modeliranju dinamike v omrežjih poimenoval metodološki individualizem, kjer je gonilo sprememb v omrežju dejanja posameznih akterjev.

Raziskovalci, ki se ukvarjajo z modeliranjem dinamike v omrežjih so v ta namen razvili vrsto matematičnih modelov, katerih večina je namenjena modeliranju specifičnih socioloških vidikov ali teorij. Eden izmed parametrov, ki je vključen v večino tovrstnih modelov, je na primer strošek, ki ga vsaka nova povezava predstavlja vsakemu avtorju posebej. S tem stroškom opredelimo realno omejitev, s katero se prej ali slej sreča raziskovalec, ki nima časa, energije ali drugih virov, da bi lahko sodeloval s prav komerkoli iz omrežja. Prvo povezavo torej vzpostavi enostavno, vsaka naslednja pa je "dražja". Bala in Goyal (2000) sta tako na primer predstavila model, v katerem strošek ustvarjanja povezave prizadene samo akterja, ki iniciira povezavo. Hummon (2000) je idejo nadgradil z modeliranjem izbire med štirimi kombinacijami vzposta-

vitve oz. prekinitve povezave: unilateralna in skupna vzpostavitev povezave, unilateralna in skupna prekinitve povezave. Tak proces generira osem tipov omrežij: prazno (nepovezano), skoraj prazno, zvezdo, skoraj zvezdo, deljeno, skoraj deljeno, celotno in skoraj celotno¹⁸.

Drug primer modela sta definirala Skyrms in Pemantle (2000), kjer posamezni akterji z interakcijo začnejo naključno, pri čemer so interakcije modelirane po teoriji iger. Rezultat vsake igre določi, katere interakcije postanejo aktivne, tako da struktura omrežja raste kot posledica učenja posameznega akterja. Marsili je s sodelavci predstavil enostaven model z vzpostavitvijo povezav druge stopnje - do prijateljev akterjevih prijateljev (Marsili in drugi, 2004). Model izhaja iz tistega, ki ga je v kontekstu rastočih omrežij predstavil Vázquez (2003), podoben pa je Davisenovem modelu (2002), namenjenem pojasnjevanju vzpostavitve malih svetov. Kljub temu, da je cilj večine reproduciranje dogajanja v realnosti, pa v večini modelov manjka teorija za ocenjevanje kakovosti modelov.

Bolj kompleksen model dinamike v omrežjih, v katere je vključen večji (a še vedno precej omejen) nabor tendenc, je predstavila Emily Jin s sodelavci (Jin in drugi, 2001). Skupina predлага nekaj enostavnih modelov za modeliranje rasti omrežij, ki temeljijo na treh splošnih principih: 1) srečevanje oz. možnost vzpostavitve povezave se dogaja bolj pogosto pri parih z vsaj enim skupnim znancem; 2) povezave med pari, ki povezav ne obnavljajo (se ne srečujejo) s časoma zbledijo oz. izginejo; 3) obstaja zgornja meja povezav, ki jih posameznik lahko vzdržuje. Poleg naštetih principov njihovi modeli reproducirajo tudi lastnosti realnih omrežij, vključno z visokim koeficientom grozdenja in močno skupnostno strukturo. Zelo pomemben element njih-

¹⁸Hummon (2000) je v angleščini omrežja poimenoval kot: Null, near-Null, Star, near-Star, Shared, near-Shared, Complete and near-Complete.

vih modelov je vključitev časovnega okvira, v katerem akterji ustvarjajo in prekinjajo povezave med seboj.

Prvi res uporaben pristop, ki združuje možnost sestavljanja modelov z vključevanjem širokega spektra mikro mehanizmov in hkrati omogoča ocenjevanje zanesljivosti parametrov, je modeliranje dinamike v socialnih omrežjih na podlagi opazovanih longitudinalnih podatkov, ki so ga predstavili Snijders (1996) ter Snijders in drugi (2010). S stohastičnim modeliranjem dinamike v omrežjih na podlagi delovanja akterjev na ravni posameznika modeliramo verjetnost, da bo ta ustvaril ali prekinil povezavo do drugega akterja oz. da v omrežju ne bo spremenil ničesar. Verjetnost je odvisna od pozicije posameznika v omrežju ter značilnosti posameznika, ki so v model vključene kot intervenirajoče zunanje spremenljivke. Stohastično modeliranje dinamike v omrežjih je vključeno v program SIENA.¹⁹

Večina stohastičnih modelov temelji na usmerjenih omrežjih, zaradi česar so le pogojno uporabni za modeliranje dinamike v omrežjih soavtorstev, kjer je v vsako neusmerjeno povezavo posredno vključen mehanizem recipročnosti. Problem modeliranja neusmerjenih omrežij je prvič rešen v programu SIENA, kjer za proces vzpostavitve neusmerjene povezave skrbi poseben algoritem (Snijders in drugi, 2010).

Kljub temu, da je aplikacija modeliranja s programom SIENA že objavljena v nekaj člankih(Lazega in drugi, 2011; Schaefer in drugi, 2010), objavljene uporabe modeliranja na neusmerjenih omrežjih po naših informacijah še ni bilo.

¹⁹Natančnejši opis modeliranja dinamike omrežij je opisan v poglavju o metodah.

2.5 Proučevanje znanstvenega sodelovanja v Sloveniji

Analiza in proučevanje znanstvenega sodelovanja je izredno aktualna tema a ji v slovenskem prostoru v preteklosti nismo posvečali veliko znanstvene pozornosti. V preteklosti se je neposredno s proučevanjem znanstvenega sodelovanja ukvarjal Franc Mali, ki je v slovensko okolje apliciral ideje Etzkowitza in Leydesdorffa o trojni spirali med znanstvenim, ekonomskim in političnim družbenim sistemom (Etzkowitz in Leydesdorff, 2001; Mali, 2002). Nekaj študij primerov sodelovanja med industrijo in znanostjo sta na primer predstavila tudi Bučar in Rojec (Kajnč, 2009).

O odnosu med lokalnim in globalnim raziskovalnim okoljem sta razpravljala Mlinar in Splichal (Mlinar in Splichal, 1988; Mlinar, 1994, 2001).

Z vidika socialnega kapitala se je znanstvenega sodelovanja posredno lotila še Petra Ziherl s sodelavci (Ziherl in drugi, 2006). Proučevala je vpliv okolja, v katerem deluje mladi raziskovalec/ka, na njegovo oz. njeno znanstveno pot.

Druge dostopne raziskave niso neposredno vezane na vlogo znanstvenega sodelovanja ampak bolj na znanstveno produkcijo. Iz bogate zbirke podatkov (COBISS) izhajajo dela Sorčana, Demšarja in sodelavcev (Demšar in Sorčan, 2007; Sorčan in drugi, 2008), v katerih opisujejo strukturo znanstvenih objav glede na jezik in okolje objave ter predstavijo poglobljeno primerjavo med znanstveno-raziskovalnima sistemoma Slovenije in Finske. Na podoben način se z analizo znanstvene produkcije glede na vložena sredstva na področju biomedicine ukvarja tudi Petruša Miholič (2005).

V zadnjem času se s popularizacijo raziskav soavtorskih omrežij pojavljajo novi članki, temelječi na bibliografski zbirk COBISS. V povezavi z analizami, katerih rezultati so delno objavljenimi tudi v tej disertaciji, je bilo objavljenih nekaj znanstvenih prispevkov o znanstvenem sodelovanju v Sloveniji (Ferligoj in Kronegger, 2009; Mali in drugi, 2010; Kronegger in drugi, 2011). Vzporedno z našimi raziskavami se je Matjaž Perc ukvarjal z modeliranjem znanstvenega omrežja sodelovanj slovenskih raziskovalcev (Perc, 2010).

Poleg raziskav, ki potekajo v domačem okolju, je raziskovanje slovenske znanstvene produkcije in sodelovanja raziskovalcev vključeno tudi v nekatere mednarodne raziskave, v katere so zajeti tudi slovenski raziskovalci (glej na primer: Glänzel in de Lange, 2002; Marshakova-Shaikevich, 2006).

2.6 Hipoteze

Na podlagi predstavljenih raziskav, temelječih na analizah bibliografskih zbirk in širšega pogleda na znanje, ki ga imamo o znanstvenem sodelovanju, v nadaljevanju predstavljamo hipoteze, ki so osnova za proučevanje soavtorskih omrežij slovenskih raziskovalcev.

H1: Prva hipoteza, ki med drugim tudi osmisli proučevanje soavtorskih omrežij, je, da število soavtorskih objav v času narašča hitreje kot število samostojnih objav. O slednjem je v svojem delu, ki velja za temeljno bibliometrično delo, pisal že Price (1963).

H2: Raziskovalci, ki delujejo na področju naravoslovnih ali tehničnih ved, sodelujejo pogosteje kot raziskovalci iz družboslovnih področij (Price, 1963; Katz in Martin, 1997).

H3: Podobno kot v omrežjih gospodarskega sodelovanja med državami (Wallerstein, 1974) lahko tudi v omrežjih znanstvenega sodelovanja slovenskih raziskovalcev najdemo enega ali več centrov raziskovalcev, ki med seboj intenzivno sodelujejo, ter nepovezano periferijo (Said in drugi, 2008; Schubert in Sooryamoorthy, 2010; Ferligoj in Kronegger, 2009).

H4: V soavtorskih omrežjih slovenskih raziskovalcev pričakujemo strukturo malih svetov in brezlestvične porazdelitve števila soavtorjev, ki je posledica preferenčne izbire.

H5: Na spremembe v strukturi sodelovanja vplivajo različni zunanji dejavniki kot formalna in neformalna organizacijska struktura (Perianes-Rodríguez in drugi, 2010; Crane, 1972), vsebina raziskovalnih problemov (Kuhn, 1996; Leahey in Reikowsky, 2008), znanstvena uspešnost posameznikov ipd.

H6: Znanstvena sodelovanja se v času različno spreminjajo po disciplinah. V znanstvenih disciplinah, kjer je sodelovanje sistemsko organizirano zaradi specifične raziskovalne opreme (ang. LAB disciplines), se sodelovanje med raziskovalci v času manj pogosto spreminja kot v znanstvenih disciplinah, kjer raziskovalci niso vezani na draga raziskovalna opremo (ang. OFFICE disciplines).

Poglavlje 3

Operacionalizacija spremenljivk in metode

3.1 Operacionalizacija spremenljivk

V analizi dinamike socialnih omrežij kot odvisno spremenljivko obravnavamo celotno soavtorsko omrežje. Na dinamiko v omrežju vplivajo notranji dejavniki, ki so lastnosti omrežja, in zunanji dejavniki, ki predstavljajo osebne lastnosti akterjev v omrežju in jih merimo kot klasične spremenljivke.

3.1.1 Omrežje kot odvisna spremenljivka

Konceptualizacija znanstvenega sodelovanja raziskovalcev kot soavtorskega omrežja temelji na skupnih objavah znanstvenih del. Raziskovalci so v omrežju predstavljeni kot točke, skupne objave pa kot povezave med njimi.

Vsaki povezavi v omrežju je pripisano tudi leto objave znanstvenega dela, na podlagi katerega je povezava definirana.

Med znanstvene objave uvrščamo izvirne in pregledne znanstvene članke, kratke znanstvene prispevke, znanstvene objave na konferencah, dele monografij ali celotne znanstvene monografije, raziskovalne ali dokumentarne filme, zvočne ali video posnetke, zaključene znanstvene zbirke podatkov in patente. Kriterij opredelitve znanstvenih del smo povzeli po klasifikaciji znanstvenih del Agencije za raziskovalno dejavnost Republike Slovenije.

Glede na postavljene hipoteze, je potrebno iz omrežij računati tudi različne strukturne značilnosti omrežij, ki jih shranimo v obliki klasičnih enodimenzijskih spremenljivk. Te spremenljivke v empiričnem delu uporabljamo za statistično analizo in modeliranje.

3.1.2 Zunanje spremenljivke

V nalogi dinamiko soavtorskih omrežij pojasnjujemo z “znanstveno starostjo” posameznega raziskovalca, članstvom v raziskovalni skupini, z znanstveno uspešnostjo posameznega raziskovalca, s stopnjo znanstvenega sodelovanja raziskovalcev izven omrežij disciplin, v katerih delujejo, ter vsebino objav.

Znanstveno starost raziskovalca merimo z letnico prve dostopne objave raziskovalca v bibliografski zbirki COBISS, iz katere črpamo podatke o bibliografiji raziskovalcev. Dejanska starost in znanstvena starost raziskovalcev sicer močno korelirata, ne gre pa za isto spremenljivko, saj je jasno, da razvoj znanstvenega delovanja raziskovalca ni nujno vezan na posameznikovo starost.

Članstvo v raziskovalni skupini je definirano z raziskovalno skupino, ki jo je raziskovalec sam izbral in v kateri primarno deluje. Članstvo je zapisano v podatkovni zbirkni SICRISS.

Znanstvena uspešnost je operacionalizirana kot število člankov, ki jih je raziskovalec objavil v revijah, uvrščenih na seznam revij z izračunanim faktorjem vpliva.

Sodelovanje izven meja discipline je merjeno kot del omrežja in predstavlja število soavtorstev posameznika z raziskovalci zunaj njegove znanstvene discipline.

Vsebino publikacij posameznega avtorja merimo z besedami iz naslovov in ključnih besed (zavedenih v bibliografski zbirki) objavljenih publikacij posameznega avtorja.

3.2 Metode in modeli

V tem delu poglavja predstavljamo metode, uporabljenne za testiranje hipotez. Poleg enostavnih grafičnih prikazov, kjer so podatki predstavljeni v obliki časovnih vrst, so omrežja analizirana s pomočjo posplošenega bločnega modeliranja (v programu Pajek), z uporabo mer za prepoznavanje struktur malih svetov, ter brezlestvičnih omrežij in metodo stohastičnega modeliranja dinamike v omrežjih na podlagi delovanja posameznikov (program SIENA).

Večina uporabljenih metod in sestavljenih mer je uporabljenih kot orodje znotraj teoretičnih modelov, ki predstavljajo idejno in teoretično izhodišče za preverjanje hipotez.

3.2.1 Osnovne definicije

Socialno omrežje kot graf

Omrežje sodelovanj je operacionalizirano kot socialno omrežje. Enoto v omrežju predstavlja posamezni raziskovalec, povezava v omrežju pa je definirana na podlagi skupnega avtorstva bibliografske enote.

Socialno omrežje je sestavljeno iz opazovanih enot in povezav med njimi. Enote v omrežju so predstavljene kot točke, odnosi med njimi pa kot povezave. Kadar za predstavitev omrežja uporabimo zgolj točke in povezave med njimi, je omrežje predstavljeno kot graf.

Graf je zgolj poenostavitev omrežja. Enote (točke) v omrežju imajo lahko namreč različne lastnosti. V omrežju so lahko različni tipi enot npr. socialno omrežje, kjer točke predstavljajo ljudje in skupine, ki jim ljudje pripadajo. Enote v omrežju imajo lahko najrazličnejše lastnosti (npr. spol, starost, dohodek).

Tudi povezave v omrežju je lahko več različnih tipov. Hkrati lahko z utežmi na povezavah opišemo tudi moč in predznak povezanosti npr. stopnjo prijateljstva s pozitivnimi vrednostmi in stopnjo sovražnosti z negativnimi vrednostmi. Kadar omrežje proučujemo z upoštevanjem časovne dimenzije, imajo enote in povezave med njimi dodatne lastnosti, s katerimi so določene časovne točke vzpostavitev in prekinitve povezav med enotami, prihod in odhod enote v omrežje ipd. Trajanje povezave je vsekakor zelo pomembna lastnost, ki vpliva na strukturo socialnega omrežja.

Informacije o grafu je mogoče predstaviti tudi v matrični obliki. Najpogo-

stejša predstavitev je matrika sosednosti M , kjer enoto i v grafu predstavlja vrstica i in stolpec i . Neničelne vrednosti v matriki M predstavljajo povezave med enotami.

Matriko sosednosti lahko uporabimo tudi za predstavitev bolj kompleksnih grafov. Če želimo na primer predstaviti graf z večkratnimi povezavami med enotami, celici m_{ij} med izbranima večkrat povezanima enotama i in j v matriki M pripisemo število povezav med enotama. Pri predstavitvi grafov z vrednostmi na povezavah tako celica m_{ij} v matriki sosednosti predstavlja utež na povezavi med enotama i in j .

Osnovne strukturne mere za opis lastnosti omrežij

Pristopi proučevanja socialnih omrežij so se razvijali postopoma. Od enostavnih k vedno kompleksnejšim. Za lažje razumevanje proučevanja dinamike v omrežjih najprej predstavimo osnovne strukturne mer s katerimi opisujemo lastnosti omrežij. Razširjen in poglobljen pregled razvoja analize socialnih omrežij z obrazložitvijo terminologije sta sicer prispevala Wasserman in Faust (1994):

- *Stopnja* točke v omrežju je definirana kot število povezav, ki to točko povezujejo z drugimi točkami v omrežju. V omrežjih, ki jih v obravnavamo v tem delu, predstavlja stopnja število različnih soavtorjev posameznega raziskovalca. Na nivoju celotnega omrežja kot mero ponavadi predstavimo povprečno stopnjo.
- *Gostota* omrežja je delež realiziranih povezav v omrežju glede na število vseh mogočih povezav v omrežju (redka vs. gostota omrežja).

- *Pot* je zaporedje točk in povezav od izbrane začetne točke do izbrane končne točke v omrežju, v katerem se točke in povezave ne ponovijo.
- *Dolžina poti* je število povezav, ki jih pot vsebuje. V soavtorskem omrežju je razdalja med raziskovalcema s skupno objavo razdalja 1.
- *Najkrajša pot* med točkama u in v , ki jo označimo kot l_{uv} , je pot z najkrajšo razdaljo med temi točkama. Na nivoju celotnega omrežja ponavadi uporabimo mero povprečne najkrajše poti.
- *Globalni koeficient grozdenja* lahko definiramo kot povprečno verjetnost, da sta dva soavtorja enega raziskovalca med seboj povezana. Tehnično gledano, koeficient merimo kot gostoto povezanih trikotnikov v omrežju tako, da z njim merimo raven prisotnosti gosto povezanih podskupin v omrežju.
- Skupina točk omrežja se imenuje *krepko povezana komponenta*, če lahko ob upoštevanju smeri povezav pridemo iz vsake točke te skupine v vsako drugo točko iz iste skupine. Če smer ni pomembna (omrežje obravnavamo kot neusmerjeno), se taka skupina imenuje šibko povezana komponenta.

3.2.2 Časovne vrste

Prvi dve hipotezi sta v nadaljevanju preverjani grafično s predstavitvijo dveh sestavljenih mer kot časovnih vrst.

Prva mera je definirana na ravni posamezne bibliografske enote, kjer število samoavtorskih objav predstavlja število bibliografskih enot z enim samim

avtorjem. Število soavtorskih objav je definirano na podlagi objav z več kot enim avtorjem.

Druga mera je izračunana na nivoju posameznega raziskovalca kot struktura soavtorstev v vseh objavah obravnavanega raziskovalca skupaj. Struktura je razčlenjena na i) samostojne objave oz. samoavtorstva, ii) objave z raziskovalci, ki delujejo v isti raziskovalni disciplini kot obravnavani raziskovalec, iii) objave z raziskovalci, ki prihajajo iz drugih raziskovalnih disciplin in so zavedeni na seznamu slovenske Agencije za raziskovalno dejavnost, ter iv) objave z avtorji, ki niso zavedeni na seznamu Agencije za raziskovalno dejavnost. Merjenje soavtorske strukture je opredeljeno kot število bibliografskih enot raziskovalca objavljenih v soavtorstvu z avtorji iz izbrane strukturne kategorije, deljeno s številom vseh bibliografskih enot, ki jih je raziskovalec objavil, ter pomnoženo s 100. Na podoben način je definiran tudi del samostojnih objav, kjer je s številom vseh objav raziskovalca deljeno število samostojnih objav. Pri taki obravnavi strukture velja opozoriti, da seštevi strukturni odstotki v večini primerov presežejo vrednost 100, saj lahko avtor pri objavi ene bibliografske enote sodeluje z več različnimi kategorijami soavtorjev.

Predstavitev podatkov v obliki časovnih vrst se pogosto uporablja v najrazličnejše namene. Gre za vrsto podatkov izmerjenih v urejenem časovnem sosledju. Kadar nek pojav opazujemo z upoštevanjem časovne dimenzije, ga je smiselno z upoštevanjem časa tudi predstaviti, saj so posamezne meritve, ki si sledijo med seboj odvisne. Časovne vrste ponavadi predstavimo z razsevnim grafikonom, kjer na vertikalno os nanašamo izmerjene vrednosti pojava (X), na horizontalno pa čas (t). Čas obravnavamo kot neodvisno spremenljivko, saj nanj nimamo vpliva.

Poznamo dve obliki časovnih vrst:

- Neprekinjene, kjer so opazovane vrednosti na voljo v vsakem trenutku v času, npr. napetost v električnem omrežju. V grafikonu vrednost X v času t označimo z $X(t)$.
- Diskretne, kjer so opazovane vrednosti razporejene v (ponavadi enakomernih) intervalih. Te označujemo z X_t .

Za glajenje grafa časovne vrste je uporabljena kubična interpolacija, ki so jo predstavili Forsythe, Malcolm in Moler (1979). Postopek je sprogramiran v paketu “stats” programa R.

3.2.3 Center - periferija model

Tretja hipoteza je preverjana z modelom center-periferija. Model je v raziskavi razvoja svetovnega gospodarskega sistema v letu 1974 opredelil Wallerstein (Wallerstein, 1974). Ideja originalnega prispevka, napisanega iz perspektive teorije odvisnosti je, da lahko države delimo na bolj razvite - centralne in manj razvite - periferne. Ključna lastnost modela, je, da govori o povezavah med skupinama držav. Medtem, ko centralne države med seboj veliko sodelujejo, periferne države sodelujejo predvsem s centralnimi, med seboj pa ne. Z razširitvijo modela center-periferija je Wallerstein uvedel idejo semi-periferije, ki ima v odnosu do centra periferno vlogo, v odnosu do periferije pa igra vlogo centra. Obstajajo tudi druge alternativne oblike modela (glej npr.: Said in drugi, 2008). Poleg proučevanja ekonomskega sistema se zdi uporaba te teorije primerna tudi za proučevanje sistema znanosti, kar sta za področje družboslovja uporabila Cullen in Pretes (2000), na individualnem nivoju se je z večnivojskim center-periferija sistemom ukvarjal Hwang (2008).

Bločno modeliranje

Model center-periferija je s pomočjo bločnega modeliranja opredelil White s sodelavci (1976). Nekoliko modernejši opis modela, v kontekstu posplošenega bločnega modeliranja, je dosegljiv tudi v Doreian in drugi (2005).

Bločno modeliranje je metoda, s katero odkrivamo osnovne strukture v omrežju in hkrati ločujemo sisteme vlog, ki jih imajo enote v omrežju. Cilj metode je odkrivanje skupin enot v omrežju, ki imajo podobne strukturne značilnosti, torej so na podoben način povezane z drugimi skupinami v omrežju. Dobljenim skupinam pravimo pozicije. Enote znotraj skupine družijo podobni povezovalni vzorci (Doreian in drugi, 2005). Bločno modeliranje sta uvedla Lorrain in White (1971).

Razvrstitev enot omrežja v skupine imenujemo tudi razbitje množice enot. Slednje poteka tako, da vse skupine skupaj vsebujejo vse enote in da vsaka enota sodi le v eno skupino. Vsako razbitje definira določeno enakovrednost in obratno, vsaka enakovrednost definira razbitje. Pojem enakovrednosti je zelo pomemben v bločnem modeliranju. Najbolj znani sta strukturalna in regularna enakovrednost. Enote so strukturno enakovredne, če so popolnoma enako povezane s preostalimi enotami v omrežju (Lorrain in White, 1971). Regularno enakovredne, pa so enote, ki so enako povezane z enotami, ki so si med seboj enakovredne (White in Reitz, 1983).

Rezultat bločnega modela je poenostavljen graf, kjer posamezno skupino enot predstavimo kot eno novo enoto. Povezave med novimi enotami so v graf umeščene na podlagi povezav v med dobljenimi skupinami.

V nekoliko bolj tehničnem jeziku lahko proceduro bločnega modeliranja opi-

šemo na naslednji način:

Naj bo U končna množica enot povezanih z binarno relacijo $R \subseteq U \times U$, ki definira omrežje $\mathbf{N} = (U, R)$. Eden izmed osnovnih ciljev analize socialnih omrežij je v danem omrežju identificirati skupine enot z enakimi oz. podobnimi karakteristikami, ki so določene glede na relacijo R . Enote znotraj ene identificirane skupine imajo enake oz. podobne vzorce povezav z enotami v drugih skupinah.

Rezultat bločnega modeliranja je *razbitje* enot \mathcal{U} v skupine $\mathbf{C} = \{C_1, C_2, \dots, C_k\}$ in relacije R na *bloke* $R(C_i, C_j) = R \cap C_i \times C_j$. Vsak blok je definiran z vsemi povezavami od enot v skupini C_i z enotami v skupini C_j . Če je $i = j$, imenujemo blok $R(C_i, C_i)$ *diagonalni* blok.

Bločni model sestavlja strukturo, ki jih dobimo z združitvijo vseh enot, ki pripadajo posameznim skupinam razbitja \mathbf{C} . Katere skupine povezav med skupinami enot so povezave v bločnem modelu, je odvisno od izbrane vrste enakovrednosti. Graf bločnega modela lahko predstavimo tudi z matriko, ki jo imenujemo *bločna matrika*.

Razbitje pri bločnem modeliranju je odvisno zgolj od strukturne informacije, vsebovane v R . Enote vsebovane v eni skupini so si enakovredne zgolj glede na to relacijo. Te enote si delijo strukturno *pozicijo* v omrežju. Empirični postopki, ki združujejo enote na osnovi izbrane enakovrednosti so seveda odvisni od tega kako je ta enakovrednost definirana:

Lorrain in White (1971) sta opredelila *strukturno enakovrednost*, ki pravi, da so enote enakovredne, kadar so z preostalimi enotami povezane na *identičen* način. Iz te definicije sledi, da lahko dobimo zgolj štiri idealne bloke (Batagelj in drugi, 1992b; Doreian in drugi, 2005):

$$\begin{array}{ll} \text{Tip 0.} & b_{ij} = 0 \\ \text{Tip 1.} & b_{ij} = \delta_{ij} \end{array} \quad \begin{array}{ll} \text{Tip 2.} & b_{ij} = 1 - \delta_{ij} \\ \text{Tip 3.} & b_{ij} = 1 \end{array}$$

kjer je δ_{ij} Kroneckerjeva delta funkcija v $i, j \in C$. Bloka tipov 0 in 1 sta *prazna* bloka, bloka 2 in 3 pa *polna* bloka. Za nediagonalne bloke $R(C_u, C_v)$, $u \neq v$, sta možni samo obliki blokov tipa 0 in 3.

Iskanja novih tipov enakovrednosti se je prvi lotil Sailer (1978). Enakovrednosti imajo veliko različnih oblik, ki jih druži ideja, da so enote enakovredne, če na enakovreden način povezane z enotami, ki so tudi med seboj enakovredne. Ena izmed takih posplošitev je regularna enakovrednost (White in Reitz, 1983; Batagelj in drugi, 1992a). Za analizo soavtorskih omrežij bomo uporabili zgolj strukturno enakovrednost.

Bločno modeliranje, kakršnega so zasnovali prvi raziskovalci, je temeljilo na določitvi enakovrednosti za *celotno* omrežje. Tu je bilo omrežje analizirano glede na dovoljene idealne bloke. Doreian, Batagelj in Ferligoj (2005) so posplošili idejo bločnega modeliranja tako, da so lahko bloki poleg prej opisanih idealnih, tudi drugačnih tipov. Poleg sprostitev bločnih tipov so posplošili tudi vnaprejšnjo definicijo 'enakovrednosti' za celotno omrežje.

Problem razbitja enot v omrežju glede na uporabljenou definicijo enakovrednost je poseben primer združevanja v skupine, kjer do končnega razbitja pridemo z uporabo kriterijske funkcije, ki odraža uporabljenou enakovrednost. S kriterijsko funkcijo merimo usklajenost dobljene razvrstitev z idealno razvrstvijo znotraj posamezne skupine in med skupinami glede na izbran tip enakovrednosti. Končna izvedba bločnega modeliranja poteka po metodi prestavljanja z menjavami parov enot iz dveh skupin ali prestavljanjem enote iz ene skupine v drugo skupino, tako, da se zmanjša vrednost kriterijske funkcije

(Ferligoj, 1989).

V izvedbeni fazi bločnega modeliranja ločimo dva pristopa:

- *Induktivni pristop*, kjer modeliranje začnemo na celotnem omrežju brez predhodnih vedenj o strukturi v omrežju.
- *Deduktivni pristop*, kjer proces razvrščanja v skupine začnemo z bločnim modelom, ki ga določimo vnaprej na podlagi predhodnih analiz. V tem primeru dane enote v omrežju razvrstimo v vnaprej izbran bločni model, sestavljen iz idealnih tipov tako, da čim bolj zmanjšamo kriterijsko funkcijo (za natančnejši opis glej: Batagelj in drugi, 1998; Doreian in drugi, 2005). Nekateri vnaprej določeni bločni modeli so lahko hierarhije s pozicijami povezanimi le v eno smer. Eden izmed tako zasnovanih modelov je tudi model center-periferija uporabljen za preverjanje tretje hipoteze.

Različni pristopi k bločnemu modeliranju za binarne relacije so implementirani v programu Pajek (Batagelj in Mrvar, 2010).

Bločni modeli skozi čas

Kadar omrežje predstavimo v obliki bločnega modela, enote uredimo glede na dobljeno razbitje, omrežje pa predstavimo kot matriko sosednosti M . S predstavitvijo bločnih modelov omrežja, definiranega v dveh soslednih časovnih intervalih ali točkah t_1 in t_2 , lahko analiziramo spremembe, ki se zgodijo pri prehodu iz t_1 v t_2 v globalni strukturi omrežja na nivoju skupin. S tako predstavitvijo dinamike v omrežju nimamo vpogleda v spremembo strukture skupin iz vidika posamezne enote. Da bi lahko sledili evoluciji bločnih

modelov na nivoju posamezne enote, smo bločnemu modelu v t_2 enotam v diagonalna polja matrike M pripisali skupino, ki so ji pripadale v bločnem modelu v t_1 . Na tak način lahko sledimo menjavam pozicij (skupin) posameznih enot v času.

Razširitev bločnih modelov z dodatnimi spremenljivkami

Predstavitev omrežja z relacijsko matriko, pri čemer uporabimo skupine, ki smo jih dobili z razbitjem omrežja pri bločnem modeliranju, je ena pregledejših možnosti predstavitve omrežja. Glede na to, da je za postopek bločnega modeliranja uporabljeni omrežje brez uteži na povezavah, torej imajo vse povezave v omrežju vrednost 0 ali 1, lahko vrednosti na povezavah za prikaz omrežja nadomestimo s poljubnimi vrednostmi. Te lahko predstavljajo nominalne kategorije, ki jih v predstavitvi upodobimo z barvami, ali moč povezave, ki jo lahko ponazorimo s sivinami. Z dodatno, zunanjim informacijo, ki jo tako dodamo strukturi omrežja, preverjamo 5. hipotezo.

Poleg spremenljivke, s katero merimo pripadnost raziskovalnim skupinam (relacija med dvema raziskovalcema je tu merjena kot pripadnost isti raziskovalni skupini), smo bločnim modelom dodali informacijo o podobnosti dveh raziskovalcev glede na vsebino vseh objavljenih publikacij. Vsebina, s katero se ukvarja posamezni raziskovalec, je merjena z besedami iz nasloovov in ključnih besed zavedenih v bibliografski zbirk za vse objavljene bibliografske enote tega avtorja. Uporabljeni so bili zgolj naslovi v slovenskem jeziku, saj smo za čiščenje podatkov uporabili slovenski lematizator (Erjavec in drugi, 2005)¹. Z uporabo metode glavnih komponent smo besede razvrstili v 200 skupin. Delili smo jih glede na njihovo pojavljanje pri posameznih

¹<http://nl2.ijs.si/analyze/>

avtorjih. Prekrivanje dobljenih skupin besed za par avtorjev smo uporabili kot mero podobnosti med avtorjema.

3.2.4 Model malih svetov

Struktura malih svetov (Watts in Strogatz, 1998) je podrobno predstavljena že v drugem poglavju (2.4.3). Model malih svetov je za analizo podatkov uporabljen večkrat. Prvič v svoji originalni obliki, kakršno sta definirala Watts in Strogatz, kjer v danih omrežjih iščemo splošne značilnosti, ki potrjujejo, da so nastala po principu tega modela. Na ta način smo preverjali prvi del četrte hipoteze. Drugič, bomo model malih svetov definirali znotraj programa SIENA (Snijders in drugi, 2010) v enem naslednjih podpoglavljev.

Naj še enkrat pojasnimo pristop za preverjanje dela četrte hipoteze z natančno opredelitvijo karakteristik omrežja, ki nakazujejo na prisotnost strukturne značilnosti malih svetov. Osnovni značilnosti omrežij, ki rastejo po modelu malih svetov sta relativno kratka povprečna pot ter relativno velik koeficient grozdenja. Glede na to, da sta obe značilnosti odvisni od več dejavnikov, npr. velikosti omrežja in gostote, je vrednosti težko primerjati med različnimi omrežji. Da bi se izognili tem težavam, smo jih primerjali z lastnostmi slučajnega grafa na danem številu točk generiranega po modelu Erdős-Rényija. V omrežju, v katerem je prisotna struktura malih svetov je povprečna dolžina poti približno enaka tisti v slučajnem omrežju, koeficient grozdenja pa je v takih omrežjih višji od koeficiente v slučajnih omrežjih.

3.2.5 Model preferenčne izbire

Pristopa k iskanju struktur v omrežju, ki potrjujejo, da je to nastalo po modelu preferenčne izbire, sta dva. Prvi pristop identificira porazdelitev stopnje v omrežju, ki se v primeru prisotnosti tega mehanizma porazdeljujejo s potenčno porazdelitvijo. To pomeni, da je v omrežju zelo majhno število raziskovalcev, ki sodelujejo z veliko soavtorji, ter veliko število raziskovalcev z majhnim številom sodelavcev. Drug pristop identifikacije mehanizma preferenčne izbire pri rasti omrežja se zanaša na lastnost brezlestvičnega omrežja, da to razпадne na več komponent, kadar iz omrežja odstranimo točke z najvišjo stopnjo. Prisotnost mehanizma identificiramo tako, da spremljamo velikost največje komponente v omrežju z odvzemanjem najbolj povezanih enot. Če se velikost največje komponente zmanjša hitro oz. takoj po odstranitvi najbolj povezane enote, to kaže na prisotnost rasti omrežja po modelu preferenčne izbire.

3.2.6 Stohastično modeliranje dinamike v omrežjih

Analiza dinamike v socialnih omrežjih je zelo kompleksen problem že zaradi same narave omrežij. Vezi med posamezniki so na začetku lahko bežne in pozneje prerastejo v bolj poglobljene odnose, tudi prekinitev povezav med njimi je lahko počasna ali hitra in intenzivna. Vse spremembe povezav so posledica različnih dejavnikov: strukturne pozicije posameznika znotraj omrežja, lastnosti posameznika samega ali lastnosti parov posameznikov. Poleg naštetih dejavnikov deluje na posameznika v omrežju in omrežje v celoti še veliko drugih vplivov, ki jih v analizo in modeliranje dinamike v omrežjih vključujemo kot naključne vplive nepojasnjениh dejavnikov. Stohastično mo-

deliranje dinamike v omrežjih na podlagi delovanja posameznikov (Snijders, 1996; Snijders in drugi, 2010) je pristop k proučevanju opazovanih omrežij v času in ocenjevanju parametrov s statistično inferenco. Slednje je ena pomembnejših lastnosti tovrstnih modelov, saj to omogoča testiranje hipotez o parametrih, ki vplivajo na vzpostavljanje in prekinitve povezav posameznimi enotami. Z uporabo parametrov tako modeliramo najrazličnejše mehanizme na mikro ravni, operacionalizirane kot vzajemnost, tranzitivnost, homofilijo ipd. Enote v omrežju bomo v tem delu poglavja v skladu z avtorji pristopa obravnavali kot akterje.

Osnovne značilnosti modela:

- V osnovi je model definiran za usmerjene povezave, ki jih akterji inicirajo oz. sprejemajo. V primeru neusmerjenih povezav (npr. omrežja soavtorstev) je ustvarjanje povezav modelirano z dodatnimi mehanizmi npr.: z enostranskim prisilnim modelom, kjer akter ustvari povezavo z drugim akterjem ne glede na potrditev drugega akterja; z modelom enostranske pobude z recipročno potrditvijo, kjer akter predlaga vzpostavitev ali prekinitve povezave drugi akter pa se mora s spremembami strinjati; ter drugimi modeli vzpostavljanja relacij med dvema akterjema.
- Omrežje je opazovano v dveh ali več diskretnih časovnih točkah. Podatki o omrežju se zbirajo na način kot v panelnih raziskavah. Samo modeliranje pa poteka v zveznem času.
- Spremembe v omrežju so rezultat Markovskega procesa kar pomeni, da je vsaka sprememba v omrežju iz enega stanja v časovni točki t_i v novo stanje v časovni točki t_{i+1} odvisno zgolj od stanja omrežja in zu-

nanjih karakteristik v času t_i . Proces ne upošteva nobenih predhodnih dogodkov in značilnosti.

- V vsakem trenutku ima samo en akter, ki je izbran po verjetnostnem ključu, možnost spremeniti samo eno povezavo (oz. lastnost kadar kot odvisno spremenljivko poleg omrežja modeliramo kakšno izmed akterjevih lastnosti).
- Akterji kontrolirajo svoje povezave kar pomeni, da jih ustvarjajo glede na svoje lastnosti, lastnosti drugih akterjev v omrežju, glede na lastno pozicijo v omrežju in dojemanju okolice omrežja. Glede slednjega predpostavljamo, da imajo akterji celotno sliko o omrežju in akterjih v njem.

Proces delovanja posameznikov je razdeljen na dva stohastična pod-procesa: modeliranje frekvence sprememb v omrežju ter modeliranje dejanskih sprememb v omrežju.

S prvim procesom modeliramo priložnost posameznika za delovanje, modeliramo torej frekvenco sprememb v omrežju. Priložnost posameznika, da v svojem osebnem omrežju nekaj spremeni, je odvisna od pozicije posameznika (npr. centralnosti) in posameznikovih lastnosti (npr. spol ali starost). Našteti parametri, ki vplivajo na ritem, so vključeni v funkcijo frekvence sprememb ².

Z drugim stohastičnim procesom modeliramo odločitev posameznika, kakšno spremembo (če sploh kakšno) bo naredil potem, ko dobi priložnost zanjo. Spremembo povezave lahko določimo z enakomerno verjetnostjo ali z verje-

²Rate function - v teoriji velikih odstopanj (Vardhan 1966) je funkcija frekvence sprememb uporabljena za merjenje verjetnosti redkih dogodkov.

tnostmi odvisnimi od posameznikovih lastnosti, zapisanih v zunanjih spremenljivkah oz. njegove pozicije v omrežju. Zaznane lastnosti in pozicija, torej okolje akterja, je vključeno v njegovo optimizacijsko funkcijo³, ki izraža kako verjetno in na kakšen način bo akter spremenil svoje omrežno okolje (ustvaril novo povezavo, prekinil povezavo ali ohranil obstoječe stanje). Optimizacijska funkcija je v nekaterih primerih nadgrajena s ‐funkcijo opremljenosti,‐⁴ s katero je določena razlika med ‐starejšimi‐ in ‐mlajšimi‐ povezavami v omrežju. S to funkcijo lahko opredelimo vrednost posamezne povezave glede na njeni ‐starost‐ (npr. starejša poznanstva so več vredna kot bežni kontakti).

Pri modeliranju verjetnosti se predpostavlja, da bodo akterji v odvisni spremenljivki (v našem primeru je to omrežje), vrednosti spremenili tako, da bodo povečali svoje skupno zadovoljstvo (rezultat optimizacijske funkcije).

Optimizacijska funkcija za i -tega akterja je definirana kot:

$$f^{net}(x) = \sum_k \beta_k^{net}(x) + g^{net}(x)$$

kjer β_k^{net} predstavlja parametre g^{net} pa učinke (Snijders in drugi, 2008). Učinke, uporabljene za modeliranje dinamike omrežij soavtorstev v disertaciji bomo predstavili v nadaljevanju poglavja.

Uporaba tega modela na realnih podatkih zahteva ocenjevanje parametrov z enim izmed statističnih postopkov. Glede na to, da je model prezapleten za klasične metode ocenjevanja parametrov, kakršna je na primer metoda največjega verjetja, je Snijders predlagal postopek ocenjevanja z uporabo me-

³objective function

⁴endowment function

tode momentov. To izvedemo z računalniško simulacijo procesa sprememb v omrežju (Snijders, 1996, 2001). V predlaganem postopku je postopek ocenjevanja parametrov odvisen od prvega iz vrste opazovanj omrežja. Slednje pomeni, da je omrežje v prvi opazovani časovni točki tretirano kot začetna točka simulacije (ostane nemodelirano).

Omejitev metode je vnaprej določenem številu enot, vključenih v analizo omrežja tako, da neposredno ne upošteva mehanizmov rasti omrežja. Ker gre za računsko izjemno zahtevno metodo, danes zaradi pomanjkanja tehničkih zmožnosti število enot v omrežju ostaja pod 300 akterji. Mehanizmi in algoritmi, ki jih je razvil Tom Snijders s kolegi so implementirani v programu SIENA.

Preden se lotimo definicij parametrov s katerimi smo opredelili modela malih svetov in preferenčne izbire, omenimo dva dodatna parametra, ki sta obvezno vključena v vsak model. Prvi parameter je del funkcije sprememb in meri ocenjeno frekvenco sprememb na enoto (npr.: spremembe v povezavah akterja merjene kot število sprememb vrednosti v vrstici matrike sosednosti) v omrežju med dvema merjenjema. Poudariti velja, da gre pri oceni frekvence sprememb za neopazovane spremembe, ki lahko ena drugo v času izničijo. Opazovanih sprememb je lahko tako v omrežju nekaj manj kot je predstavljenih neopazovanih.

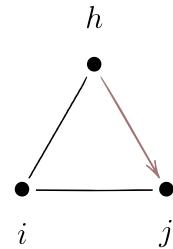
Drugi parameter, ki je v optimizacijsko funkcijo, kot del modela, vključen vedno, je gostota. Ta je matematično definirana kot $s_i^{net}(x) = x_{i+} = \sum_j x_{ij}$, pri čemer $x_{ij} = 1$ pomeni, da sta akterja i in j povezana, ter $x_{ij} = 0$ da nista. Vrednost parametra v smislu interpretacije celotnega modela ni pomembna, saj je ta v model vključen zgolj zaradi kontrole. Interpretacija je celo težavna, saj parameter praviloma močno korelira z ostalimi, vsebinsko pa bi ga lahko

povezali s stroškom akterja, ki ga ima z vzpostavitvijo vsake nove povezave.

Opredelitev modela malih svetov

Mehanizem razvoja omrežij po principu malih svetov lahko operacionaliziramo tudi posredno z uporabo stohastičnega modeliranja omrežij na podlagi delovanja posameznih akterjev.

Razvoj omrežja po principu malih svetov smo prej operacionalizirali kot globalni koeficient grozdenja na nivoju posameznih akterjev. Tukaj pa ga lahko vsaj delno operacionaliziramo kot težnjo akterjev k ustvarjanju povezav na tak način, da zapirajo trikotnike povezav med akterji oz. da ustvarjajo **tranzitivne triade**. Vpliv tranzitivnih triad je klasičen primer zaprtja omrežja, pozitiven parameter v optimizacijski funkciji kaže na pozitiven učinek tranzitivnosti pri vzpostavljanju povezav. Matematično gledano je definiran na številu tranzitivnih triad, ki jim pripada i -ti akter: $s_i^{net}(x) = \sum_{j < h} x_{ij}x_{ih}x_{jh}$.



Vprašanje zunanjih dejavnikov, ki vplivajo na razvoj strukture malih svetov v omrežju (4. in 5. hipoteza) bo operacionalizirano po principu homofilije oz. *podobnosti* med enotami. Pozitiven parameter v optimizacijski funkciji nakazuje, da akterji nove vezi raje vzpostavljajo z akterji, ki imajo na določeni “zunanji” spremenljivki podobno vrednost. Podobnost akterjev glede na “zunanj” spremenljivko je definirana kot seštevek centriranih vrednosti sim_{ij}^v med i -tim in j -tim akterjem, s katerim je prvi povezan: $s_i^{net}(x) = \sum_j x_{ij}(sim_{ij}^v - \widehat{sim^v})$. Vrednost $\widehat{sim^v}$ je definirana kot povprečje vseh podobnosti definiranih kot $\frac{\sum_{ij}^{sim_{ij}=\Delta-|v_i-v_j|}}{\Delta}$ z $\Delta = max_{ij}|v_i - v_j|$, opre-

deljeno na vrednostih opazovane spremenljivke. Spremenljivka je pred samo proceduro centrirana v programu SIENA.

Na enak način kot podobnost lahko na nominalnih spremenljivkah uporabimo tudi parameter **enakosti** med enotami. Parameter je definiran kot število povezav akterja i z vsemi drugimi akterji j , ki imajo na zunanji spremenljivki natanko enako vrednost: $s_i^{net}(x) = \sum_j x_{ij} I\{v_i = v_j\}$ kjer je vrednost funkcije $I\{v_i = v_j\}$ enaka 1, kadar je pogoj $v_i = v_j$ izpolnjen, in 0 kadar ni.

Opredelitev modela preferenčne izbire

Model preferenčne izbire je podobno kot pri modelu malih svetov preverjan z uporabo stohastičnega modeliranja delovanja posameznikov v programu SIENA. V tem primeru preferenco posameznikov k povezovanju z bolj povezanimi akterji nekoliko razširimo. Poleg povezanosti posameznika v omrežju smo v model dodali še učinek povezanosti akterjev izven omrežja (govorimo o omrežjih raziskovalcev na področju posameznih disciplin), ter učinek znanstvene uspešnosti akterjev, merjene s številom člankov objavljenih v revijah s faktorjem vpliva (merjeno v obravnavanem obdobju). Z dodajanjem zunanjih dejavnikov v model tako poleg 4., preverjamo tudi 5. hipotezo.

Učinek, povezan s stopnjo povezanosti akterjev (število različnih soavtorjev) odraža težnje akterjev po povezovanju z akterji, ki že imajo visoko stopnjo. Tisti z visoko stopnjo torej privlačijo še več povezav. Matematično učinek zapišemo kot $s_i^{net}(x) = x_{i+}$.

Čisti učinek “zunanje spremenljivke” predstavlja vpliv te spremenljivke na vzpostavljanje povezav. Pozitivni parameter tega učinka kaže na težnjo ak-

terjev, da tisti z višjo vrednostjo na spremenljivki bolj verjetno vzpostavljajo nove povezave. Učinek je definiran kot seštevek vseh vrednosti spremenljivke pri akterjih, s katerimi je i povezan: $s_i^{net}(x) = x_{ij}v_j$, pri čemer z v_j označujemo vrednost spremenljivke pri akterju j . Spremenljivka je pred samo proceduro centrirana v programu SIENA.

Poglavlje 4

Analiza dinamike soavtorskih omrežij

4.1 O podatkih

Podatke o raziskovalcih in njihovih bibliografijah smo pridobili iz dveh med seboj povezanih podatkovnih sistemov: (i) informacijskega sistema o raziskovalni dejavnosti v Sloveniji (SICRISS), v katerem najdemo širok spekter informacij o raziskovalcih, zaposlenih v slovenskih raziskovalnih ustanovah, o raziskovalnih ustanovah, skupinah, raziskovalnih projektih in programih, ter (ii) Kooperativnega Online Bibliografskega Sistema in Servisov (COBISS), kjer so zbrani podatki o vseh publikacijah, ki jih najdemo v slovenskih knjižnicah. Povezava sistemov SICRIS in COBISS predstavlja v svetovnem merilu izjemen vir bibliografskih podatkov, saj je njuno vzdrževanje sistemsko urejeno, tako da so podatki o raziskovalcih in njihove osebne bibliografije dostopne za praktično vse slovenske raziskovalce. Oba sistema vzdržuje

Inštitut za informacijske znanosti v Mariboru (IZUM) v sodelovanju z Agencijo za raziskovalno dejavnost Republike Slovenije (ARRS).

4.1.1 Priprava podatkov za analizo

V prvem koraku smo iz spletne strani SICRIS pripravili seznam vseh raziskovalcev, ki so bili v maju 2008 zavedeni kot zaposleni raziskovalci na ARRS. Na seznamu je ima vsak raziskovalec pripisani do dve področji znanstvenega delovanja. Da bi se izognili težavam z umestitvijo, smo kot vedo, v kateri raziskovalec deluje, zavedli prvi zapis.

Za potrebe analize smo svoje raziskovalno polje omejili zgolj na štiri raziskovalne discipline: biotehnologijo, fiziko, matematiko in sociologijo. Omejitve disciplin je posledica predvsem obsežnosti celotne podatkovne zbirke.

Kot argument za izbiro teh štirih disciplin lahko poleg že predstavljenih Newmanovih raziskav strukture v omrežjih fizikov, matematikov in biologov (Newman, 2004) ter Moodijevega dela, ki temelji na omrežju sociologov (Moody, 2004), je Hargensova tipologija disciplin, ki jo je razvil na osnovi Durkheimovega modela socialne integracije (Hargens, 1975, str.: 5). Hargens trdi, da: “discipline lahko ločimo glede na relativno raven *normativne* in *funkcionalne* integracije,” ki ju povezuje z Durkheimovima konceptoma *mehanske* in *organske* solidarnosti (Durkheim, 1947). Mehansko solidarnost Durkheim poimuje kot vrednostni sistem v katerem so si člani družbe glede na vrednote med seboj zelo podobni. Organsko solidarnost pa opredeli v duhu delitve dela in medsebojne odvisnosti glede na specializirane individualne aktivnosti in funkcije. Hargens v dvodimensionalni prostor, določen z normativno in funkcionalno integracijo postavi tri discipline: matematiko,

kemijo in politične vede (glej tabelo 4.1). Matematika in kemija imata visoko raven normativne, medtem ko imata kemija in politične vede visoko raven funkcionalne integracije.

Tabela 4.1: Klasifikacija disciplin glede na funkcionalno in normativno integracijo

		integracija	
		normativna	
		visoka	nizka
funkcionalna		kemija	politične vede
visoka		matematika	×
nizka			

V kontekstu predstavljene raziskave bi v tabelo 4.1 namesto disciplin, ki jih je razvrščal Hargens, lahko na mesto kemije uvrstili fiziko in biotehnologijo, namesto političnih ved pa sociologijo kot primer družboslovne vede.

Večina raziskovalcev kljub predstavljeni klasifikaciji ved, te deli predvsem na podlagi funkcionalne integracije oz. narave raziskovanja in s tem povezane organizacije znanstvenega dela. Eden prvih raziskovalcev, ki je opazoval razlike med objavami disciplin, ki se ukvarjajo pretežno s teoretičnimi znanstvenimi problemi (angl. OFFICE disciplines), in disciplin, katerih objave temeljijo na eksperimentalnem delu (angl. LAB disciplines), je bil Smith (1958). Njegove ugotovitve so pozneje empirično potrdili tudi drugi avtorji na primer Price (1963), Hagstrom (1965), Meadows in Connor (1971) in Mulkay (1975). Modernejše raziskave na to temo so prispevali tudi Katz in Martin (1997) ter Han (2003).

Znanstvena področja za empirični del disertacije so izbrana načrtno glede na svoje posebnosti in značilnosti, s čimer smo skušali zajeti najrazličnejše vidike znanstvenega sodelovanja, področja so na različnih stopnjah razvoja (že uveljavljena in nova) ter z različnimi disciplinarnimi tradicijami (naravo-

slovne vs. družbene znanosti). Z izbranimi disciplinami smo prav tako zajeli dve disciplini, v katerih je delo organizirano v okviru laboratorijev in dve, kjer raziskovalci delujejo bolj samostojno.

Fizika je stara uveljavljena naravoslovna disciplina, v kateri raziskovalci za svoje delo običajno potrebujejo zahtevno in draga raziskovalno opremo. Pri objavljanju rezultatov so kot avtorji velikokrat navedeni številni člani raziskovalne skupine, npr. celoten raziskovalni laboratorij. Na področju fizike se zaradi tega v globalnem merilu pojavlja relativno nov fenomen, kjer na enem projektu deluje tudi več sto raziskovalcev, ki so ob objavi rezultatov navedeni kot soavtorji publikacije.

Matematika je prav tako stara uveljavljena disciplina, pri kateri sodelovanje ni ključnega pomena. Usmerjena je v reševanje problemov, ki v večini primerov niso neposredno vezani na draga raziskovalno opremo in konkretno okolje. Matematični problemi so v svojem tradicionalnem smislu abstraktni, tako da morebitno sodelovanje ni vezano na geografsko bližino.

Biotehnologija je primer discipline, ki je pred 30 leti še ni bilo. Potem ko se je pojavila, je kot ‐nano‐ znanost hitro postala pomemben akter na znanstvenem področju. Organizacija tega področja je podobna fiziki, zanimaliva pa je predvsem iz vidika razvoja in konsolidacije znanstvene discipline. Iz vidika organizacije znanosti, je izbira biotehnologije med naše raziskovane discipline nekoliko nerodna, saj po klasifikacijskem sistemu ARRS (ARRS, 2010) sodi med biotehniške vede in je tako razvrščena en nivo nižje od ostalih obravnavanih področij.

Sociologija je edina obravnavana disciplina iz področja družboslovja. Glede na strukturo sodelovanja bi jo lahko umestili podobno kot matematiko, med discipline, kjer sodelovanje ni obvezno. Narava dela na področju sociologije, pa je vseeno bolj kot pri matematiki vezana na lokalno okolje, saj je njen predmet raziskovanja družba, ki je geografsko vezana na neko področje.

V naslednjem koraku smo neposredno od zavoda IZUM pridobili natančneje podatke o izbranih raziskovalcih, ki so sicer javno dostopni v sistemu SICRIS in njihove celotne bibliografije dostopne v sistemu COBISS, na osnovi katerih smo generirali soavtorsko omrežje.

4.1.2 O avtorjih kot enotah analize

Enote v omrežju predstavljajo avtorji bibliografskih enot, na podlagi katerih smo generirali soavtorsko omrežje. Osnovni seznam avtorjev, na katerem je temeljil zajem podatkov, predstavlja raziskovalci, ki so bili v maju 2008 registrirani pri ARRS. Zaradi narave raziskovanja smo v seznam vključili le raziskovalce, ki imajo kot prvo raziskovalno področje pri ARRS navedeno eno izmed 4 področij: biotehnologijo, fiziko, matematiko ali sociologijo. Osnovni seznam tako predstavlja 819 raziskovalcev, med katerimi 89 v podatkovni zbirki nima zavedene nobene bibliografske enote, tako da je omrežje zgenerirano s 740 raziskovalci. Ker avtorji iz osnovnega seznama sodelujejo z raziskovalci iz tega seznama kot tudi z drugimi avtorji, je končni seznam avtorjev vključenih v omrežje 28937. Med temi je 740 raziskovalcev iz osnovnega seznama (štirih raziskovalnih področij), 5799 raziskovalcev, ki so registrirani pri ARRS in delujejo na drugih raziskovalnih področjih, ter 22398 avtorjev, ki niso registrirani pri ARRS.

4.1.3 O bibliografskih enotah kot povezavah v omrežju

Informacije o bibliografskih enotah smo zbrali iz podatkovne zbirke COBISS <http://www.cobiss.net/>. Povezava v omrežju je definirana kot so-avtorstvo neke bibliografske enote. Bibliografske enote z enim samim avtorjem definirajo povezavo, ki povezuje avtorja samega s seboj (angl. loop). Omrežje je bilo generirano na podlagi seznama 740 raziskovalcev. Ti raziskovalci predstavljajo centralni del omrežja, kjer imamo podatke za vse povezave med temi enotami, gre torej za popolno omrežje sodelovanj. Za preostalih 28197 avtorjev nimamo podatkov o njihovi celotni bibliografiji oz. sodelovanju temveč zgolj o sodelovanju z avtorji iz osnovnega dela omrežja. Najstarejša zavedena objava v podatkovni zbirki COBISS izhaja iz leta 1957. Tehnično gledano ima 740 raziskovalcev v podatkovni zbirki COBISS zavedenih skupno 63251 bibliografskih enot. Zapis o posamezni bibliografski enoti je bil shranjen v datoteki formata xml (63251 datotek), ki smo jih uporabili za generiranje omrežja.

Vsebina bibliografske zbirke COBISS je zastavljena zelo široko, saj poleg znanstvenih člankov in monografij vsebuje še veliko drugih tipov publikacij in drugih objektov, ki jih hranijo knjižnice ter informacij o izvedenih delih¹. Glede na to, da smo se tu omejili na znanstveno sodelovanje raziskovalcev smo povezave v omrežju definirali zgolj na bibliografskih enotah, ki po kriteriju Agencije za raziskovalno dejavnost veljajo za znanstvene²:

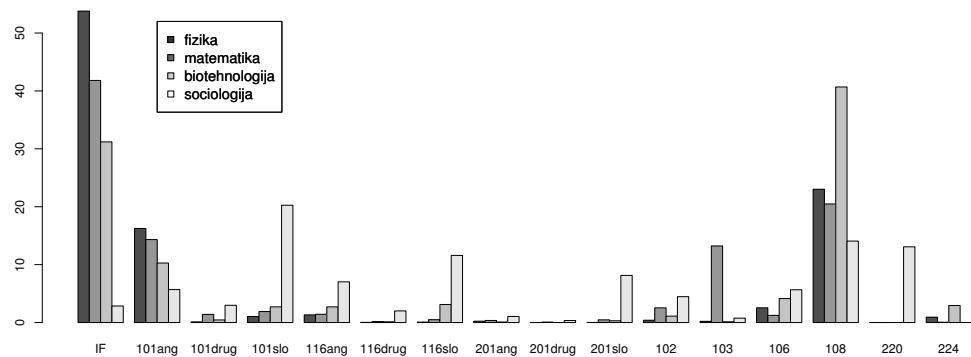
¹Celotna tipologija bibliografskih enot je dostopna na spletnem naslovu: http://home.izum.si/COBISS/bibliografije/Tipologija_slv.pdf

² Kriterij je povzet po pravilniku o vrednotenju znanstvenih del raziskovalcev <http://www.arrs.gov.si/sl/akti/prav-znan-strok-uspesn-jul10.asp>.

- 1.01 izvirni znanstveni članek
- 1.02 pregledni znanstveni članek
- 1.03 kratki znanstveni prispevek
- 1.06 objavljen znanstveni prispevek na konferenci (vabljeno predavanje)
- 1.08 objavljen znanstveni prispevek na konferenci
- 1.16 strokovni znanstveni sestavek ali poglavje v monografiji
- 2.01 znanstvena monografija
- 2.18 raziskovalni ali dokumentarni film, zvočni ali video posnetek
- 2.20 zaključena znanstvena zbirka podatkov ali korpus
- 2.24 patent

V naslednjem koraku smo analize omejili tudi časovno. Večina analiz v tem delu je opravljenih na bibliografskih enotah, ki so bile objavljene, med letoma 1986 in 2005. Izbran časovni okvir dvajsetih let zajema obdobje pred osamosvojitvijo Slovenije, s čimer smo skušali zaznati spremembo znanstvene klime v sodelovanju raziskovalcev pred in po dogodkih, ki poleg osamosvojitve države predstavljajo tudi novo obdobje za znanstveno skupnost. Slednje je s seboj prineslo novo oblikovanje znanstvenih politik, ki prav gotovo vplivajo tudi na znanstveno delovanje in sodelovanje med raziskovalci. Zaključna časovna točka je izbrana glede na več kriterijev. Prvi je, da smo podatke zbirali v letu 2008, ob tem smo predpostavili, da proces sodelovanja dveh raziskovalcev, priprava znanstvenega dela, objava tega dela v znanstveni publikaciji in na koncu vnos v bibliografsko bazo traja vsaj eno leto. Časovni okvir je izbran tudi iz praktičnega vidika delitve časovnega obdobja na 4 petletne intervale, ki smo jih uporabili za večino analiz. Sidrna točka za to delitev je leto 1991, tako da imamo en interval za obdobje pred osamosvojitvijo in tri po osamosvojitvi.

Slika 4.1: Struktura znanstvene bibliografije po disciplinah z informacijo o jeziku objave



1.01 izvirni znanstveni članek	1.16 strokovni znanstveni sestavki ali poglavje v monografiji
1.02 pregledni znanstveni članek	2.01 znanstvena monografija
1.03 kratki znanstveni prispevek	2.18 raziskovalni ali dokumentarni film, zvočni ali video posnetek
1.06 objavljen znanstveni prispevek na konferenci (vabljeno predavanje)	2.20 zaključena znanstvena zbirka podatkov ali korpus
1.08 objavljen znanstveni prispevek na konferenci	2.24 patent
IF članki objavljeni v revijah vključenih v sistem izračuna faktorja vpliva	

Osnovna analiza porazdelitvene strukture objav glede na štiri znanstvene discipline pokaže izrazite razlike med disciplinami. V diagramu 4.1 so predstavljeni deleži objav v posamezni kategoriji po disciplinah. Poleg kategorij po klasifikaciji v bazi COBISS smo dodali kategorijo člankov, objavljenih v revijah s faktorjem vpliva (IF), ter delitev kategorij 1.01 - izvirni znanstveni članek, 1.16 - poglavja v monografijah in 2.01 - monografije v celoti glede na jezik objave: slovenski, angleški in drugi tuji jeziki. Iz grafa je razvidno, da v naravoslovnih vedah večina znanstvenih objav izide v revijah z izračunanim faktorjem vpliva. Največ (več kot polovico), takih objav imajo fiziki, sledijo jim matematiki in biotehnologi. Izrazito najmanj objav v tovrstnih revijah lahko zasledimo med raziskovalci iz področja sociologije. Slednje lahko razložimo kot posledico dveh prepletajočih se dejavnikov: prvi je lokalna na-

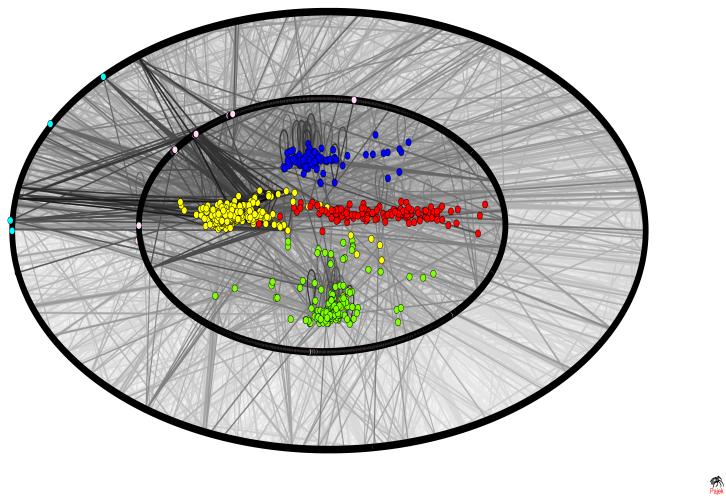
ravnost in problemska usmerjenost sociologije, druga pa povsem tehnična, saj je revij s faktorjem vpliva iz področja sociologije že na globalni ravni manj, na področju Slovenije pa take revije sploh ni. Podobne, čeprav manj izrazite razlike lahko opazimo tudi pri znanstvenih člankih, objavljenih v angleškem jeziku, medtem ko je situacija obratna v primeru objav v slovenščini. Če raziskovalce iz naravoslovnih disciplin svoje rezultate objavljajo predvsem v obliki znanstvenih člankov, sociologi izrazitejše objavljajo v obliki delov monografij v vseh jezikih in monografij predvsem v slovenskem jeziku. Pregledne znanstvene članke objavljajo predvsem raziskovalci iz področja matematike in sociologije, medtem ko so kratki znanstveni prispevki domena matematikov. Ena najpogostejših oblik bibliografskih zapisov v COBISSu v praktično vseh disciplinah je objava znanstvenega prispevka na konferenci. V tem tipu objav izrazito prednjačijo raziskovalci iz področja biotehnologije.

Pri kategorijah 2.20 - znanstvene zbirke podatkov ali korpus in 2.24 - patent opazimo najizrazitejše razlike med znanstvenimi disciplinami. To da je patentiranje prisotno zgolj na področju fizike in biotehnologije niti ni prese netljivo, je pa zanimivo, da je objava znanstvenih zbirk podatkov ali korpusov izključno domena raziskovalcev iz področja sociologije.

4.2 Splošne značilnosti omrežij

Že prve analize soavtorskih omrežij so razkrile velike razlike med raziskovalnimi disciplinami. Če začnemo s številom raziskovalcev je fizikalna znanstvena skupnost z 250 raziskovalci dvakrat večja od skupnosti s področja sociologije ali biotehnologije (glej 1. vrstico tabele 4.2). Razlike so še izrazitejše, če primerjamo razširjena omrežja z vključenimi sekundarnimi enotami

Slika 4.2: Popolno soavtorsko omrežje štirih raziskovalnih disciplin. Štiri skupine v notranjem delu omrežja predstavljajo raziskovalce iz področja fizike (rumeni na levi), matematike (zeleni na dnu), biotehnologije (rdeči na desni) ter sociologije (modri na vrhu). Na notranjem krogu so raziskovalci, registrirani pri Agenciji za raziskovalno dejavnost, ki delujejo v drugih disciplinah. Na zunanjem krogu so avtorji, ki niso raziskovalci, registrirani pri Agenciji za raziskovalno dejavnost. Tu gre za skupino avtorjev, ki večinoma prihajajo iz tujine, nekateri izmed njih pa so neraziskovalci, ki so sodelovali pri pripravi znanstvene objave.



(raziskovalci iz drugih disciplin in tujine). Če za trenutek odmislimo razlike v velikosti omrežij disciplin in omrežja primerjamo glede na povprečno število soavtorjev posameznega avtorja, imajo fiziki v povprečju 18 soavtorjev, matematiki 7, biotehnologi 13 in sociologi 7. Iz teh osnovnih lastnosti omrežij lahko sklepamo, da imajo fiziki in biotehnologi podoben vzorec sodelovanja: oboji sodelujejo z veliko večjim številom soavtorjev kot matematiki in sociologi, pri katerih je izrazitejša kultura samoavtorskih objav. Podobne vzorce lahko razkrijemo tudi z drugimi omrežnimi značilnostmi: visokim povprečnim številom soavtorjev posamezne bibliografske enote in visokim številom objav na posameznega avtorja na področju fizike in biotehnologije ter obratno pri raziskovalcih iz področja matematike in sociologije.

Če se osredotočimo zgolj na ta vzorec v sodelovanju, bi raziskovalne discipline lahko opredelili kot ‐laboratorijske‐, kjer raziskovalci delujejo v skupinah, ter ‐pisarniške‐ discipline, kjer raziskovalci delujejo bolj samostojno. V splošnem število objav po disciplinah proporcionalno sledi velikosti omrežij posameznih disciplin z opaznim odstopanjem biotehnologije, pri kateri je zaradi relativne ‐mladosti‐ discipline, skupno število objav nekoliko nižje³.

Tabela 4.2: Pregled osnovnih omrežnih značilnosti po obravnavanih disciplinah

\times	Fiz.	Mat.	Bioteh.	Soc.
osnovno omrežje				
število avtorjev	250	152	105	117
bibl. enot na avtorja	52.5	23.9	21.4	29.9
št. soavtorjev ene enote (brez samoavt.)	4.6	2.8	4.6	3.7
samoavtorstva (%)	5	32.9	8	52.4
soavtorstva znotraj disc. (%)	72.2	29	46.5	27.6
soavtorstva znotraj raz. agencije (%)	44.3	25.4	67.6	26.1
soavtorstva izven raz. agencije (%)	62.7	28.2	35.4	16.4
razširjeno omrežje				
največja komponenta(%)	97.2	80.3	97.5	90.8
število komponent	11	43	7	24
povprečna razdalja	4.5	5.5	4	4
največja razdalja	10	14	8	9
koefficient grozdenja	0.246	0.493	0.419	0.490
gostota	0.0019	0.0045	0.0057	0.0098
povprečna stopnja	9.1	5.6	8.2	8.7

Kljub temu, da se v analizi osredotočamo na omrežje soavtorstev, je informacija o samostojnih objavah raziskovalcev prav tako pomembna. V vrsticah 5-7 tabele 4.2 je predstavljeno število publikacij objavljenih v samoavtorstvu oz. soavtorstvu deljeno s številom vseh objavljenih publikacij. Vsaka bibliografska enota ima lahko več avtorjev, ki pripadajo različnim kategorijam v tabeli, tako da se števek deležev pogosto presega 100 odstotkov. Pri sociologih, jih je več kot polovica objavljenih v samoavtorstvu, pri matematikih

³Biotehnologija se je kot mlada disciplina razvila v 70-ih letih prejšnjega stoletja.

je takih objav nekaj več kot 30 odstotkov. Nasprotno fiziki in biotehnologji le redko objavljamjo kot samostojni avtorji (glej 4. vrstico tabele 4.2). Fiziki objavljamjo predvsem s kolegi iz svoje discipline in z raziskovalci iz tujine, medtem ko biotehnologi pogosteje sodelujejo s slovenskimi raziskovalci iz drugih disciplin. Slednje je nedvomno povezano z mladostjo discipline, kot tudi z dejstvom, da je biotehnologija po naravi dela bolj povezana z drugimi disciplinami. V sodelovanju raziskovalcev iz področja matematike lahko zasledimo podoben vzorec. Razliko med matematiko in biotehnologijo lahko opazimo v bolj prisotnem sodelovanju matematikov z raziskovalci, ki niso del slovenskega znanstvenega sistema (glej tabelo 4.2).

V vseh disciplinah število publikacij na posameznega avtorja močno presega to število v podobni analizi Newmana (2004). Glavni vzrok za to sta razlika v časovnem okvirju raziskave ter v definiciji soavtorske povezave. Večina podobnih raziskav temelji na podatkovnih zbirk Web of Science, SCOPUS ali specifičnih znanstvenih revij, ki vsebujejo zgolj podatke znanstvenih člankih v revijah s faktorjem vpliva ne pa tudi drugih člankov, monografij, objav na konferencah ipd.

Velikost omrežij in aktivnost sodelovanja raziskovalcev, ki delujejo v obravnavanih disciplinah, lahko razberemo na osnovi različnih omrežnih lastnosti. Največja komponenta je definirana kot največja med seboj povezana skupina posameznikov v omrežju. Na področju fizike in biotehnologije največja komponenta pokriva več kot 97 odstotkov celotnega omrežja. V omrežju sociologov je ta odstotek približno 90 odstotkov, pri matematikih pa 80 odstotkov vseh avtorjev v omrežju. Vse štiri discipline so torej dobro povezane skupnosti raziskovalcev kljub temu, da matematiki pri tem nekoliko odstopajo. Tudi število komponent v omrežju odraža velikost in razdrobljenost omrežja.

V našem primeru število komponent jasno kaže na razlike v strukturi sodelovanja glede na prej omenjeno delitev na ‐laboratorijske‐ in ‐pisarniške‐ discipline.

Razdalja v omrežju je definirana kot najkrajša pot med dvema izbranima točkama. Razdalja med dvema avtorjema s skupno objavo je torej 1. Povprečne razdalje analiziranih omrežij disciplin v splošnem sovpadajo s tistimi, ki jih je v analizi soavtorstev predstavil Newman (2004). Povprečna razdalje je največja med matematiki, sledijo jim fiziki, biotehnologi in sociologi. Seveda je treba biti pri interpretaciji in primerjavi povprečnih razdalj med različnimi omrežji previden, saj je mera odvisna tudi od velikosti analiziranega omrežja.

Globalni koeficient grozdenja lahko interpretiramo kot verjetnost, da bosta dva različna soavtorja nekega raziskovalca povezana s skupno objavo. V obravnavanih razširjenih omrežjih je koeficient grozdenja v omrežjih sociologov in matematikov najvišji, nekoliko nižji pri biotehnologih in precej nižji v omrežju fizikov. Tudi ta mera je težko primerljiva med različnimi raziskavami (Newman, 2004), lahko pa jo interpretiramo v kontekstu razlik v strukturi sodelovanj med posameznimi disciplinami v Sloveniji. Z mero grozdenja in analizo strukture, kjer se raziskovalci znotraj omrežja povezujejo v skupine, se bomo v nalogi ukvarjali tako z uporabo bločnega modeliranja⁴ kot tudi pri stohastičnem modeliranju dinamike v omrežjih⁵.

Gostota v omrežju je definirana kot število povezav v omrežju glede na vse mogoče povezave (de Nooy in drugi, 2005, str. 63). Gostote ne smemo enačiti s prej omenjenimi karakteristikami, kjer smo predstavljalci število avtorjev na

⁴referenco na poglavje naprej

⁵še eno referenco na poglavje naprej

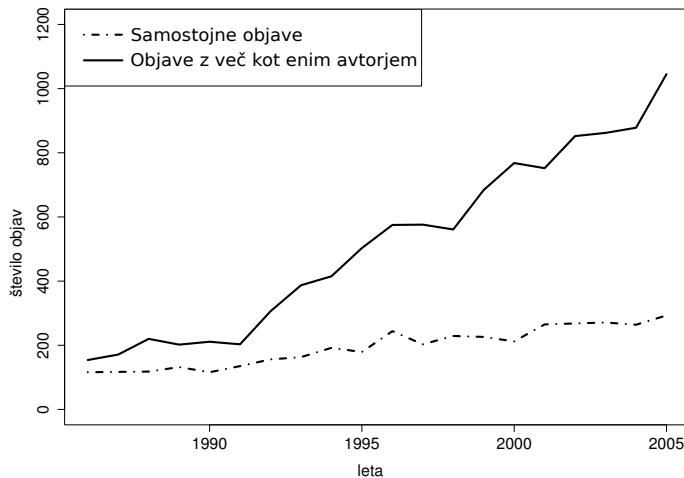
eno bibliografsko enoto. Gostota je definirana kot delež realiziranih povezav v omrežju glede na vse mogoče povezave. Najgostejše omrežje je omrežje sociologov, temu sledijo omrežja biotehnologov, matematikov in fizikov.

Druga, že omenjena značilnost je stopnja posamezne točke v omrežju. Gre torej za število povezav ene enote (de Nooy in drugi, 2005, str. 63). Tu v povprečju z največ različnimi soavtorji objavljajo fiziki, sledijo jim sociologi z 8.7 soavtorji, biotehnologi z 8.2 in matematiki z 5.6 različnimi soavtorji. Pri tej meri je zelo pomemben podatek, da smo stopnjo izračunali na omrežjih brez samoavtorstev. Torej sociologi so v obravnavanem obdobju dvajsetih let v povprečju sodelovali z 8.7 različnimi soavtorji.

4.3 Znanstveno sodelovanje skozi čas

V tem delu poglavja predstavljamo značilnosti soavtorskih omrežij v obdobju med letoma 1986 in 2005. Prva in najočitnejša ugotovitev, predstavljena na sliki 4.3, je, da število soavtorskih publikacij po letu 1990 narašča nepriimerljivo hitreje kot število publikacij samostojnih avtorjev. Kljub temu, da nekateri raziskovalci govorijo o eksponentni rasti, lahko v Sloveniji govorimo zgolj o prelomu linearnega trenda rasti. Časovne vrste strukture sodelovanj, predstavljene na sliki 4.4, jasno kažejo na velike spremembe znotraj štirih obravnavanih disciplin. Vrednosti, prikazane kot časovne vrste, predstavljajo del publikacij, objavljenih samostojno ali v soavtorstvu z avtorji iz ene izmed treh kategorij deljenih s številom vseh objav v disciplini v obravnavanem letu. Poleg samostojnih objav ostale tri kategorije predstavljajo: soavtorstva znotraj obravnavane discipline, soavtorstva izven discipline vendar v slovenskem znanstvenem sistemu in soavtorstva z raziskovalci, ki niso del sloven-

skega znanstvenega sistema. Splošne značilnosti in razlike med disciplinami so s povprečnimi vrednostmi za celotno dvajsetletno obdobje predstavljene v prejšnjem delu poglavja v tabeli 4.2. Najpomembnejše značilnosti so: (i) visok delež samostojnih objav matematikov in sociologov; (ii) visoka raven sodelovanja fizikov znotraj discipline ter sodelovanja z avtorji izven slovenskega znanstvenega sistema; (iii) visoka raven sodelovanja biotehnologov s slovenskimi raziskovalci iz drugih disciplin. Najpomembnejša razlika med matematiki in sociologi je, da matematiki več objavljujo z raziskovalci iz tujine.



Slika 4.3: Samostojne in soavtorske objave raziskovalcev skozi čas

Če natančno pregledamo spremembe v strukturi sodelovanja skozi čas vidimo, da je obravnavanem časovnem intervalu v omrežjih sociologov in matematikov prišlo do dramatičnih sprememb. Pri matematikih je delež samostojnih objav postopno padal prvih 10 let, medtem ko je delež samostojnih objav pri sociologih v prvem desetletju ostal nespremenjen, potem pa je hitro padel in po letu 2000 ostal na konstantni ravni. Pri matematikih je delež samoavtorskih objav padel iz nad 60 odstotkov na pod 30 odstotkov. Pri sociologih je ta delež najprej narasel nad 80 odstotkov, potem pa padel pod 40. V socio-

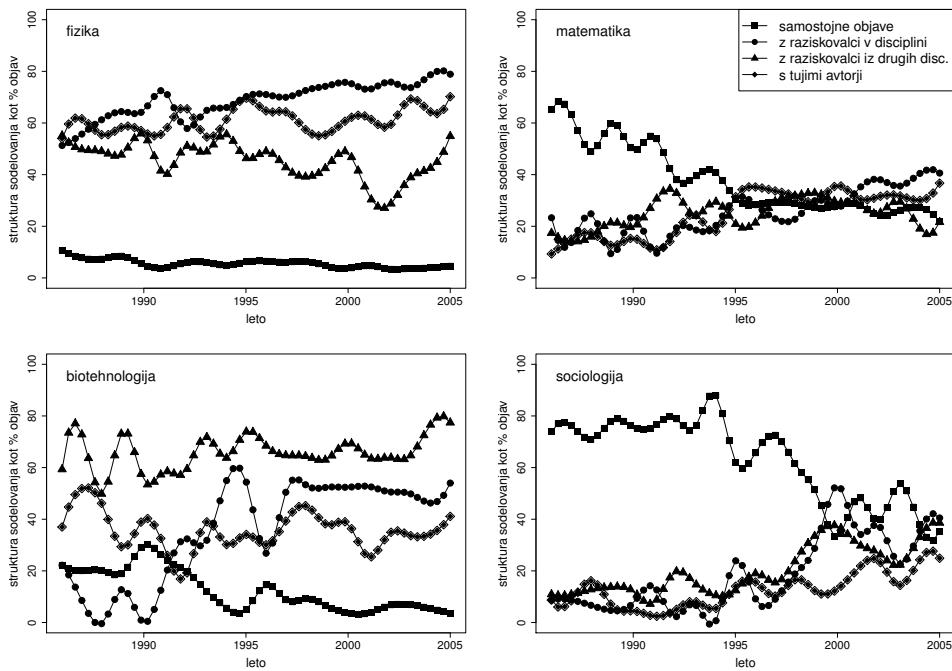
giji samostojno avtorstvo ostaja najpogosteji način objavljanja, medtem ko matematiki v zadnjem obdobju več objavljojo v soavtorstvu z raziskovalci iz lastne discipline ter soavtorji, ki niso del slovenske znanstvene skupnosti.

Pri matematikih je bilo sodelovanje z raziskovalci iz lastne discipline, slovenskimi raziskovalci iz drugih disciplin ter soavtorji iz tujine stabilno do zgodnjih devetdesetih let, potem pa vsi trije grafi počasi naraščajo. Pri sociologih so vrednosti vseh treh tipov sodelovanj v času padale vse do srede 1990, potem pa začele naraščati. Sodelovanje znotraj discipline je bilo pri sociologih vseh 20 let z manjšimi odstopanjami tako kot pri matematikih.

Soavtorsko sodelovanje med sociologi v Sloveniji kaže drugačne tendence od tistih, ki jih je Moody (2004) odkril, ko je analiziral članke objavljene v reviji American Sociological Review (1936-1999) in Sociological Abstracts (1963-1999). Moody namreč za analizirane revije poroča o enakomerni rasti dela soavtorskih objav.

V fiziki se delež samostojnih objav v celotnem časovnem intervalu praktično ni spremenjal in je bil ves čas na zelo nizki ravni. V biotehnologiji je delež samostojnih objav v prvih letih nekoliko nihal, na koncu opazovanega obdobja pa se je ustalil podobno kot pri fizikih. Delež samostojnih objav so tako v fiziki kot v biotehnologiji veliko nižji kot v matematiki in sociologiji. Delež soavtorstev znotraj discipline pri fizikih konstantno raste vseh 20 let, z nekoliko večjimi odstopanjami raste tudi sodelovanje izven slovenske raziskovalne agencije. Sodelovanje z avtorji iz drugih disciplin prav tako niha, z izrazitim padcem po letu 2000, potem pa v zadnjem obdobju zopet naraste na raven pred padcem.

Časovne vrste vseh vrednosti med biotehnologijami veliko bolj variirajo kot pri



Slika 4.4: Struktura znanstvenega sodelovanja skozi čas

fizikih. Variiranje je prisotno predvsem v prvem desetletju, ko se je disciplina šele začela razvijati in je bilo število raziskovalcev in objav v njej majhno. V biotehnologiji raziskovalci največ objavlja v soavtorstvu z raziskovalci iz drugih disciplin - delež tovrstnega sodelovanja je najvišji med vsemi štirimi obravnavanimi disciplinami. Druga najpomembnejša oblika sodelovanja znotraj discipline je ob koncu 20-letnega obdobja, ko je veliko višja kot na začetku, kar kaže na konsolidacijo in pridobivanje ugleda discipline. V zadnjem obdobju je v biotehnologiji sodelovanje znotraj discipline na višjem nivoju kot na primer v sociologiji, vendar še vedno nižje kot pri fizikih.

Z ugotovitvami predstavljenih analiz dinamike v sodelovanju raziskovalcev lahko potrdimo ugotovitve drugih avtorjev zapisane v prvi hipotezi, da je od začetka devetdesetih let objavljanje znanstvenih publikacij v soavtorstvu

vse bolj prisotno. Število soavtorskih objav raste neprimerno hitreje od rasti števila samostojnih objav. Druge hipoteze na podlagi teh rezultatov ne moremo potrditi. Med disciplinami vsekakor obstajajo precejšnje razlike v strukturi objav, čeprav so se s časom občutno zmanjšale. Trditev, da je sodelovanje v naravoslovnih vedah pogosteje kot v družboslovnih, je morda nekoliko preuranjeno, glede na to, da je struktura sodelovanja pri matematikih in sociologih zelo podobna in se občutno razlikuje od strukture pri biotehnologih in fizikih. To pomeni, da dejavnik, ki vpliva na strukturo sodelovanja, ni vezan na to ali je disciplina naravoslovna ali družboslovna temveč na drug dejavnik, ki smo ga opredelili v šesti hipotezi, kjer strukturo sodelovanja opredelimo glede na organizacijo raziskovalnega dela. Če sta fizika in biotehnologija vezani na raziskovalno okolje, kjer je vložek v raziskovalno opremo velik (npr. laboratorij) in je zaradi tega delo organizirano znotraj jasno definiranih raziskovalnih skupin, sta matematika in sociologija v tem pogledu veliko manj strukturirani. Matematiki in sociologi veliko pogosteje delujejo kot samostojni avtorji in se povezujejo po potrebi glede na naravo raziskovanja, ki se lahko v času spreminja.

4.4 Deterministični pristop k analizi dinamike

4.4.1 Omrežja v štirih časovnih obdobjih

Za natančnejšo analizo omrežij ter modeliranje sodelovanja skozi čas smo omrežja raziskovalcev po disciplinah opazovali na štirih 5-letnih obdobjih. Tu obravnavamo zgolj primarna omrežja raziskovalcev znotraj štirih raziskoval-

nih disciplin: biotehnologije, fizike, matematike in sociologije. Najpomembnejši razlog za tako določene meje omrežij je, da imamo samo za ta omrežja podatke o celotnih bibliografijah raziskovalcev, torej popolna omrežja raziskovalnih disciplin. Omeniti velja tudi, da so metode, ki jih uporabljamo v nadaljevanju računsko zelo zahtevne, tako da z obravnavo zgolj primarnih omrežij disciplin rešimo tudi problem prevelike količine podatkov, ki bi pri današnji tehnologiji za analizo zahtevali ogromno količino računskega časa.

V nadaljevanju iščemo spremembe v strukturi soavtorskih omrežij skozi štiri časovna obdobja. Z namenom ‐zabrisa‐ variacij, ki se v omrežjih dogajajo v enoletnjem obdobju, smo dvajsetletno obdobje, za katerega imamo podatke, razdelili na štiri petletne intervale. Na omrežja v teh štirih intervalih gledamo kot na posnetke strukture sodelovanja za obravnavane petletke v obdobjih med leti 1986-1990, 1991-1995, 1996-2000 in 2001-2005. Prvo obdobje zazema čas pred osamosvojitvijo Slovenije, ki je povezan z začetkom uvajanja lastnih raziskovalnih politik, zadnja tri pa od začetka razvoja samostojnega nacionalnega znanstvenega sistema pa vse do vključitve Slovenije v Evropsko unijo, ko je bila slovenska znanost že dobro integrirana v strukturo in sisteme znotraj EU.

Glede na rezultate analize časovnih vrst ter obravnavo relativno dolgega obdobia ni presenetljivo, da se struktura omrežij posameznih disciplin v vsakem izmed obravnavanih petletk spreminja. Preden se lotimo iskanja struktur v omrežjih z uporabo posplošenega bločnega modeliranja si oglejmo nekaj splošnih indikatorjev, s katerimi opisujemo strukturne lastnosti omrežij. Enostavni struktturni indikatorji so predstavljeni v tabelah 4.3 in 4.4:

- Vsa soavtorska omrežja so s časom rasla tako v številu enot (razisko-

Tabela 4.3: Pregled osnovnih omrežnih značilnosti v štirih časovnih obdobjih za področje matematike in fizike

Omrežje	t_1	t_2	t_3	t_4	
	1986-1990	1991-1995	1996-2000	2001-2005	
Fizika	število enot	84	125	183	234
	število povezav	173	274	487	686
	gostota	0.050	0.035	0.029	0.025
	povprečna stopnja	4.86	5.06	6.1	6.55
	najdaljša razdalja	9	8	15	16
	povprečna razdalja	2.66	3.44	4.8	5.15
	število komponent	18	20	19	21
	največja komponenta (%)	52.38	64.8	81.42	80.77
	koeficient grozdenja	0.467	0.461	0.473	0.492
Matematika	št. skupin - bločno	8	8	10	11
	število enot	40	65	96	135
	število povezav	14	42	63	122
	gostota	0.018	0.020	0.014	0.013
	povprečna stopnja	0.7	1.29	1.31	1.81
	najdaljša razdalja	5	5	9	10
	povprečna razdalja	2.62	2.34	3.94	4.52
	število komponent	27	35	49	53
	največja komponenta (%)	30	29.23	33.33	44.44
	koeficient grozdenja	0	0.246	0.302	0.285
	št. skupin - bločno	3	5	7	9

valcev) kot tudi v številu povezav (skupnih objav).

- Spremembe v gostoti so med disciplinami različne:
 - Pri fizikih skozi vsa štiri obdobja gostota počasi pada. Padec gostote je poleg dejanske spremembe zaznan tudi zaradi večanja omrežja.
 - V sociologiji gostota s časom počasi narašča. Kot smo ugotovili že v prejšnjem delu poglavja so sociologi v zgodnjih letih analiziranega obdobja objavljali predvsem kot samostojni avtorji, zato je bilo v omrežju relativno malo povezav. Z usmeritvijo k sodelovanju se je povečalo absolutno in relativno število povezav in

Tabela 4.4: Pregled osnovnih omrežnih značilnosti v štirih časovnih obdobjih za področje biotehnologije in sociologije

Omrežje	t_1	t_2	t_3	t_4	
	1986-1990	1991-1995	1996-2000	2001-2005	
Biotehnologija	število enot	16	33	50	79
	število povezav	5	42	48	147
	gostota	0.042	0.080	0.047	0.048
	povprečna stopnja	0.63	2.55	2.32	3.72
	najdaljša razdalja	1	5	6	8
	povprečna razdalja	1	2.45	2.88	3.34
	število komponent	11	6	9	8
	največja komponenta (%)	12.5	42.42	42	68.35
	koeficient grozdenja	0	0.555	0.339	0.480
Sociologija	št. skupin - bločno	6	7	7	8
	število enot	42	61	88	111
	število povezav	8	26	124	199
	gostota	0.009	0.014	0.032	0.033
	povprečna stopnja	0.38	0.85	2.82	3.59
	najdaljša razdalja	3	4	8	7
	povprečna razdalja	1.57	1.74	3.14	3.37
	število komponent	35	40	41	36
	največja komponenta (%)	11.9	11.48	52.27	65.77
	koeficient grozdenja	0.246	0.493	0.419	0.490
	št. skupin - bločno	5	6	7	7

povezanih avtorjev, kar je vplivalo na zgostitev omrežja.

- Gostota omrežja biotehnologov se s časom ne spreminja izrazito, z izjemo povečanja gostote v obdobju 1991-95, ki pa v naslednjem obdobju zopet pada na začetno raven.
- Pri matematikih je gibanje gostote podobno kot pri biotehnologijah, kjer v prehodu iz prvega obdobja v drugo gostota zraste, že v naslednjem obdobju pa se spusti na začetno raven, kjer ostane nespremenjena tudi v zadnjem časovnem obdobju.
- Povprečna stopnja v omrežju v vseh štirih disciplinah narašča skozi celotno obravnavano obdobje. Torej ne gre zgolj za splošno povečanje

sodelovanja temveč tudi večjo in bolj razpršeno aktivnost posameznih raziskovalcev, ki sodelujejo z vedno večjim krogom soavtorjev.

- Tudi povprečna razdalja med raziskovalci v omrežju ves čas narašča v vseh štirih disciplinah. To nakazuje, da se različna podpodročja znotraj disciplin, ki so bila nekoč definirana z ločenimi skupinami strokovnjakov, med seboj povezujejo. Večanje razdalje je nerazdružljivo povezano tudi z rastjo omrežij.
- Spremembe v številu komponent se med disciplinami razlikujejo:
 - Sprememb v številu komponent ni veliko pri fizikih in sociologih, vseeno pa jih je na področju sociologije skoraj dvakrat več kot pri fizikih. Na veliko razliko lahko gledamo iz perspektive velike razdrobljenosti tem, s katerimi se ukvarja sociologija, in hkrati večje koherentnosti fizike.
 - Pri matematikih se število komponent v obravnavanem obdobju podvoji, kar je verjetno posledica vsebinsko zelo razdrobljenega znanstvenega področja.
 - V biotehnologiji število komponent nekoliko niha, se pa nakazuje nižanje števila, kar bi v bodoče lahko, podobno kot pri fiziki, vodilo v višjo koherentnost discipline.
- Spremembra v deležu enot, v največji komponenti je pri vseh štirih disciplinah skozi vsa obdobja pozitivna. Delež podobno kot število komponent kaže raven povezanosti enot v omrežju. Fizika ima tako na začetku, kot na koncu celotnega obdobja relativno in absolutno največjo komponento. Biotehnologija in sociologija v začetnem obdobju začneta z nizkim deležem vsebovanih enot, končata pa na podobno

visokem nivoju kot fizika. Pri matematikih relativna velikost največje komponente počasi in stabilno raste.

- V omrežjih sodelovanj sociologov in matematikov koeficient grozdenja v prvih treh obdobjih narašča, v zadnjem pa nekoliko pade. V omrežju biotehnologov je koeficient najmanj stabilen, medtem ko je pri fizikih v začetnem obdobju med vsemi disciplinami najvišji njegova vrednost najprej nekoliko pade potem pa zraste na svojo končno raven. V zadnjem obdobju ima sociologija najvišji koeficient grozdenja, matematika pa najnižjega.
- Število pozicij (skupin v bločnem modelu) je najvišje v zadnjem časovnem obdobju. Najizrazitejša spremembra števila skupin je pri matematikih, najmanjša pa v omrežju biotehnologov. Interpretacijo bločnih modelov in sprememb v številu pozicij predstavljamo v nadaljevanju.

4.4.2 Iskanje struktur z bločnim modeliranjem

Glede na to, da je v družboslovju koncept strukture center–periferija uporabljan pogosto in v različnih oblikah, bomo v nadaljevanju koncept uporabljen v našem primeru opisali nekoliko bolj natančno. Najprej poudarimo, da je v našem primeru uporabljena definicija centra, semi-periferije in periferije nekoliko drugačna od tiste, ki jo je v svojem članku uporabil Wallerstein (1974). V nadaljevanju termin 'raziskovalec' predstavlja raziskovalca, ki deluje v določeni obravnavani raziskovalni disciplini. Center je definiran kot skupina povezanih raziskovalcev, katere vsi člani med seboj sodelujejo (objavlja delo v soavtorstvu). V jeziku bločnega modeliranja je center poln diagonalni blok. Za razliko od klasičnega pojmovanja strukture

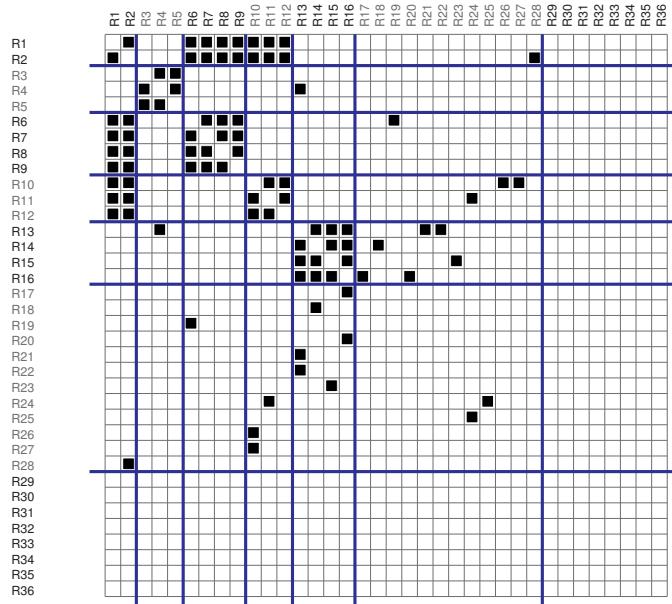
center-periferija, kjer govorimo o enem centru in periferiji, v celotni strukturi soavtorskih omrežij lahko obstaja več centrov. V primeru, ko raziskovalci iz centra sodelujejo zgolj s člani svojega centra, govorimo o enostavnih centrih. V primeru, ko člani nekega centra sistematično sodelujejo s člani drugega centra, lahko govorimo o povezovalnem (angl. bridging) centru. Če se vrnemo k jeziku bločnega modeliranja je povezovalni center definiran z izven diagonalnimi polnimi bloki, ki povezujejo center z drugimi centri.

Poleg večih centrov v strukturi omrežja, je prisotna semi-periferija v kateri so znanstveniki z vsaj eno soavtorsko objavo z drugimi raziskovalci iz discipline. Sodelovanje raziskovalcev iz semi-periferije je veliko manj strukturirano oz. določeno z ozko in zaprto skupino soavtorjev kot sodelovanje raziskovalcev iz centrov. To pomeni, da je diagonalni blok semi-periferije, glede na število povezav redek in bliže praznemu kot polnemu bloku. Nekateri člani semi-periferije seveda lahko sodelujejo tudi z raziskovalci iz centrov vendar ta sodelovanja ostajajo brez sistematičnega vzorca.

Čisto periferijo sestavljajo raziskovalci, ki znotraj discipline nič ne sodelujejo. Slednje ne pomeni, da gre za raziskovalce brez objav, saj so v omrežje vključeni le aktivni avtorji. Raziskovalci iz periferije objavljamjo zgolj kot samostojni avtorji ali pa z avtorji iz drugih disciplin oziroma tujine. Iz vidika bločnega modeliranja so za to skupino vsi bloki (diagonalni in izven diagonalni) prazni.

Šibka, neurejena povezanost semi-periferije in nepovezanost periferije sta posebnost uporabljenega modela, saj Wallersteinov center-periferija model predpostavlja šibko povezanost perifernega dela omrežja znotraj periferije in relativno močno povezanost s centralnim delom omrežja.

Slika 4.5: Bločni model za primer omrežja, v katerem ima omrežje strukturo z več centri, semi-periferijo in periferijo. V tej specifični strukturi, ki jo najdemo v soavtorskih omrežjih, so enostavnii centri sestavljeni iz klik avtorjev, ki med seboj (skoraj) vsi sodelujejo (enote R3 do R5 in R13 do R16), povezovalni centri sestavljeni iz raziskovalcev, ki povezujejo dva ali več enostavnih centrov (enoti R1 in R2), semi-periferija sestavljena iz avtorjev, ki sodelujejo, vendar manj strukturirano, ter periferija avtorjev, ki ne objavlja v soavtorstvu z ostalimi raziskovalci iz discipline.



Pri uporabi poslošenega bločnega modeliranja skupine v omrežjih iščemo vnaprej predvideno strukturo, v kateri vnaprej določimo tipe blokov (Doreian in drugi, 2005). V našem primeru smo iskano strukturo oblikovali zgolj z idealnimi "polnimi" in "praznimi" bloki (struktturna enakovrednost), število skupin pa smo določili z uporabo kriterijske funkcije. Kriterijska funkcija je definirana kot število odstopanj od vnaprej definirane strukture bločnega modela. Skupine raziskovalcev v bločnem modelu imenujemo tudi 'pozicije'. Struktura vnaprej določenega bločnega modela je ključen element uporabe te metode v disertaciji. Na diagonali bločnega modela so za centre polni bloki.

Izven diagonalni bloki, s katerimi so določene povezave med centri, so lahko polni ali prazni. Bloki, ki jih določa semi-periferija so ‐redki‐ oz. določeni z majhnim številom povezav, bloki periferije pa povsem prazni.

Za oblikovanje center–periferija strukture kot vnaprej določenega bločnega modela, smo uporabili struktурno enakovrednost med raziskovalci, število skupin v modelu pa smo iskali med tremi (center – semi-periferija – periferija) in dvajstimi pozicijami (10 centrov – semi-periferija – periferija). Rezultate bločnega modeliranja praviloma predstavimo s kvadratno relacijsko matriko, kjer smo vrstice in stolpce permuntirali, tako da so enote, ki pripadajo eni skupini predstavljene skupaj. Vsaka skupina je od drugih ločena z obarvano ali odebeleno črto. Po dogovoru najprej predstavimo enote prve skupine, potem druge in tako dalje. Število skupin za vsako omrežje posebej (za vsako izmed disciplin v vsakem izmed štirih časovnih intervalov), smo določili glede na padec kriterijske funkcije (Doreian in drugi, 2005). Število skupin v omrežjih za vsa štiri obdobja so predstavljena v zadnji vrstici tabel 4.3 in 4.4. Število variira med 3 in 9 pri matematikih, med 5 in 7 pri sociologih, med 6 in 8 v omrežju biotehnologov ter med 8 in 11 skupin v omrežju fizikov. V splošnem število skupin narašča z večanjem omrežja, kar je logična posledica povsem osebnih omejitev raziskovalcev, ki lahko aktivno sodelujejo z zgolj omejenim številom soavtorjev in ustvarijo omejeno število objav (Price, 1963).

Osnovo za bločno modeliranje predstavljajo izsledki raziskave pozicij in vlog v sistemu znanosti (Ferligoj in drugi, 2011). Na raziskovalce je tako smiselno gledati kot na igralce vlog v strukturi lastne raziskovalne discipline. Iskanje struktur v omrežju nam tako omogoča razkritje vzorcev sodelovanja med raziskovalci. V nadaljevanju predstavljamо bločne modele za vsako izmed

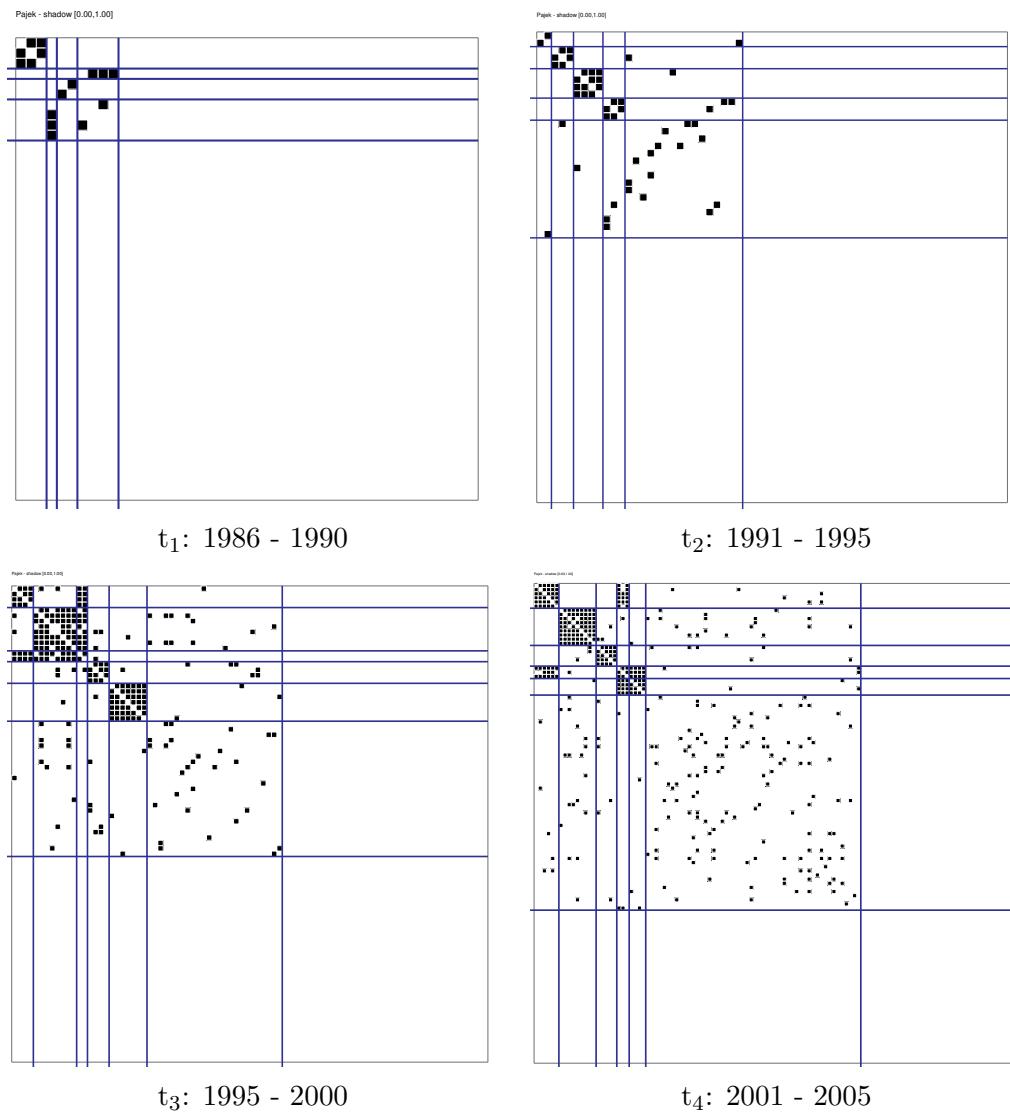
disciplin v štirih zaporednih petletnih časovnih intervalih. Pozneje bomo iskali še vzgibe in mehanizme, ki vzpodbujujo spremembe v teh strukturah. Začnimo z opisom struktur v omrežju sociologov.

Sociologija

Bločni modeli omrežja sociologov so prikazani v diagramu 4.4.2, kjer črno obarvana polja predstavljajo povezave dveh raziskovalcev z vsaj eno skupno publikacijo. Bela polja predstavljajo pare raziskovalcev brez skupnih objav. V prvem obravnavanem obdobju (t_1), so raziskovalci razvrščeni v 5 skupin. Skupine na prvih treh pozicijah so enostavni centri, na četrtni je semi-periferija, sestavljena iz štirih raziskovalcev. Peta, največja skupina je periferija sestavljena iz avtorjev, ki znotraj discipline v obravnavanem obdobju niso sodelovali. V omrežje so zajeti samo aktivni raziskovalci z objavljenimi bibliografskimi enotami, kar pomeni, da ti raziskovalci ustvarjajo samostojno ali sodelujejo z raziskovalci iz drugih raziskovalnih disciplin oz. avtorji, ki niso registrirani pri slovenski raziskovalni agenciji. Glede na rezultate, predstavljene v poglavju 4.3, velja predvsem prvo, da raziskovalci objavljamajo kot samostojni avtorji. Prvi bločni model nima pričakovane povsem čiste center-periferija bločne strukture. Anomalijo predstavlja raziskovalec na drugi poziciji, ki objavlja z vsemi raziskovalci razen enim iz semi-periferije. Avtor na drugi poziciji torej opravlja vlogo povezovalnega centra.

V drugem obdobju (t_2), ima omrežje čisto center-periferija strukturo, v kateri so štirje enostavni centri, sestavljeni iz navznoter povsem povezanih raziskovalcev. Nobeden izmed štirih centrov v tem obdobju nima povezovalne vloge. Naslednjo pozicijo ima v primerjavi s prvim obdobjem povečana semi-

Slika 4.6: Center – periferija bločni modeli omrežja sociologov v 4 časovnih obdobjih



periferija. Ta diagonalni blok z redko posejanimi povezavami med raziskovalci je s šestimi povezavami nesistematično povezan z raziskovalci iz centrov. Na zadnji poziciji je periferija. Število raziskovalcev v periferiji je približno enako kot v prvem obdobju (t_1), vendar se je ta proporcionalno glede na ostali del

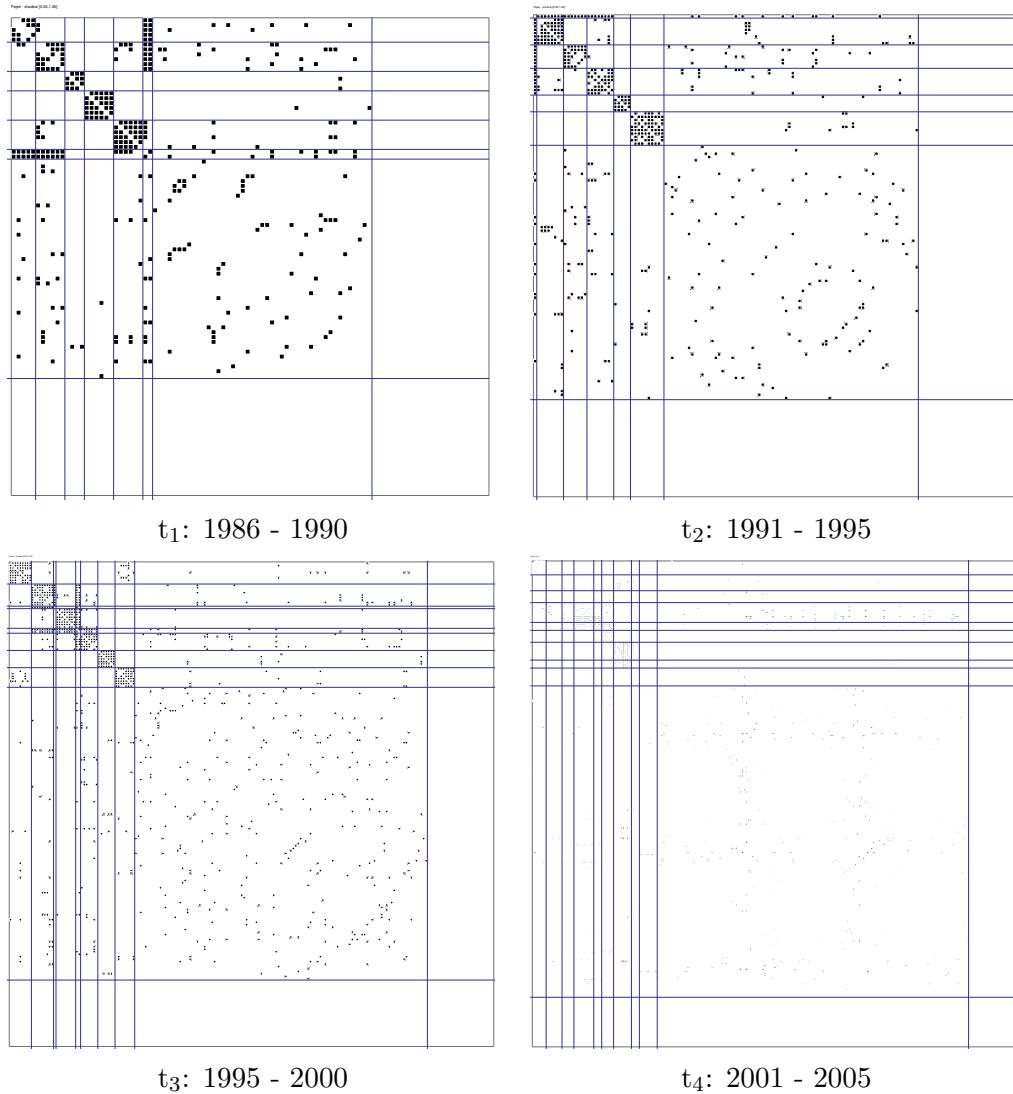
omrežja zmanjšal. Center omrežja (s štirimi pozicijami) je nekoliko večji.

V tretjem obdobju (t_3), pride v omrežju sociologov do precejšnje spremembe v strukturi sodelovanja. V obdobju med leti 1995 in 2005 je v omrežju pet centralnih pozicij. Prvi, drugi, četrти in peti center so notranje močno povezani, z malo povezavami med centri. Tretja pozicija je povezovalni center. Dva raziskovalca, ki mu pripadata, sodelujeta med seboj in z vsemi raziskovalci iz prvega in drugega centra. Na šesti poziciji je semi-periferija in na sedmi periferija. Podobna omrežna struktura je prisotna tudi v zadnjem analiziranem obdobju (t_4) s štirimi enostavnimi centri in povezovalnim centrom na četrti poziciji. Pet centralnih pozicij, v omrežju zaseda zgolj en raziskovalec več kot v prejšnjem obdobju. Semi-periferija na šesti poziciji je postala nekoliko večja, medtem ko se je periferija relativno zopet precej pomanjšala. Ob precejšnjem povečanju celotnega omrežja v t_4 , so novi raziskovalci, ki so postali del sociološke znanstvene skupnosti, prevzeli vloge v semi-periferiji in periferiji.

Fizika

Bločne strukture omrežja fizikov so prikazane v diagramu 4.4.2, kjer vsak bločni model predstavlja eno od štirih časovnih obdobij. V prvem obdobju (t_1) ima bločni model pet enostavnih centrov, med katerimi so tretji, četrти in peti notranje povsem povezani. To pomeni, da vsi raziskovalci znotraj teh skupin med seboj sodelujejo. Na peti poziciji sta v tem obdobju dva avtorja, ki sodelujeta z raziskovalci prvih dveh enostavnih centrov. Eden izmed avtorjev tega povezovalnega centra sodeluje tudi z večino avtorjev na peti poziciji. Poleg čistega povezovalnega centra, je v omrežju nekaj povezav

Slika 4.7: Center – periferija bločni modeli omrežja fizikov v 4 časovnih obdobjih



tudi med drugim in petim centrom. Siceršnja nepovezanost članov različnih centrov kaže na prisotnost povsem različnih raziskovalnih tem posameznih sodelujočih skupin. Na sedmi poziciji je semi-periferija, ki je v primerjavi z omrežjem sociologov absolutno in relativno glede na preostali del omrežja

veliko večja, med raziskovalci v semi-periferiji je tudi več soavtorskih povezav. Če smo natančni, take razpršenosti povezav v semi-periferiji v omrežju sociologov ne zasledimo do zadnjega obravnavanega obdobja. V omrežju fizikov je v t_1 semi-periferija večja kot periferija, kar prav tako potrjuje razliko v strukturi sodelovanja med fiziki in sociologi (glej poglavje: 4).

Tudi v drugem analiziranem obdobju je omrežje fizikov razdeljeno na pet enostavnih in en povezovalni center. Povezovalni center v tem primeru predstavlja en sam raziskovalec, ki sodeluje z vsemi pripadniki prvih treh enostavnih centrov. Vseh pet enostavnih centrov je v t_2 večjih kot v t_1 . Dejansko se je centralni del omrežja povečal za več kot 60 odstotkov. V omrežju sociologov se je v tem prehodu center povečal zgolj za enega avtorja. Podobno kot v prvem obdobju je v omrežju fizikov nekaj več povezav med pripadniki dveh enostavnih centrov (tokrat prvega in tretjega). Razen teh povezav med centri ni soavtorskih vezi, kar kaže na ohranjanje ločenih raziskovalnih domen. Semi-periferija na sedmi poziciji in periferija na osmi sta se povečali, semi-periferija ostaja večja od periferije.

V tretjem obdobju se število centrov poveča na osem. Šest izmed teh je enostavnih centrov, en povezovalni center v svoji čisti obliki in dodaten povezovalni center, sestavljen zgolj iz enega raziskovalca. Slednji je praktično del drugega enostavnega centra, saj sodeluje z vsemi raziskovalci iz njega. Drugače je obravnavan, ker za razliko od ostali članov centra ne sodeluje z nikomer drugim iz omrežja. Peti (povezovalni) center ima soavtorske objave z avtorji iz štirih izmed sedmih centrov.

Lepo soavtorsko strukturo med centri lahko opazimo tudi med pripadniki centrov 2 do 6 in pripadniki prvega in osmega centra. Pripadniki sedmega centra ne sodelujejo z avtorji iz drugih centrov, sodelujejo pa z avtorji iz

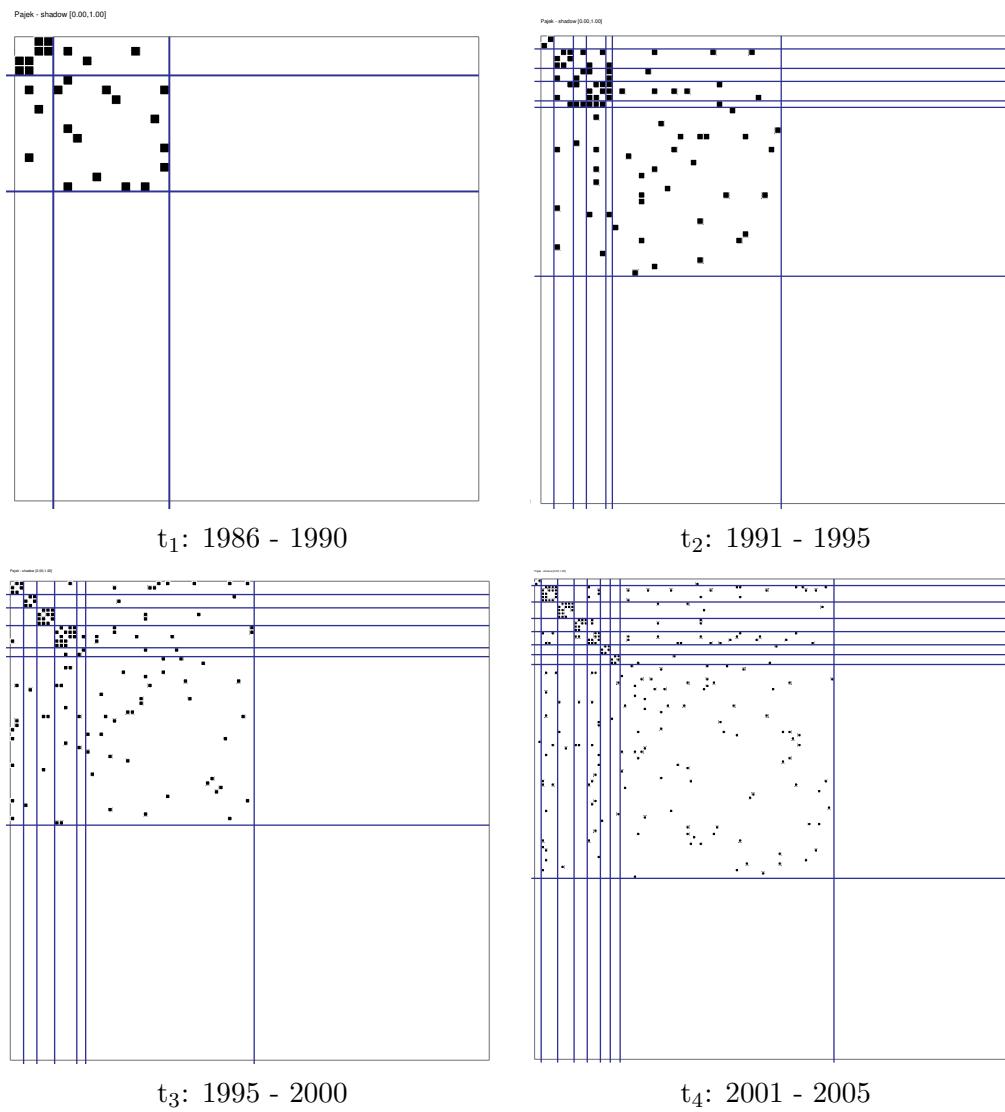
semi-periferije. Ta se je v prehodu iz t_2 v t_3 izredno povečala in se tako še bolj razlikuje od periferije na osmi poziciji, ki se manjša.

V četrtem obravnavanem obdobju se v centralnem delu omrežja oblikuje nekaj strukturnih oblik, ki jih doslej še nismo opazili. Na prvi, tretji in deveti poziciji so povsem normalni enostavnii centri, med seboj močno povezanih raziskovalcev. Raziskovalci na četrtni, peti in šesti poziciji dejansko pripadajo dvema prekrivajočima se skupinama raziskovalcev na poziciji štiri in šest, medtem ko raziskovalci petega (povezovalnega) centra pripadajo preseku prekrivajočih se skupin. Zanimiv je tudi odnos med sedmim in osmim centrom. Med raziskovalci teh pozicij se je razvil odnos, kjer vsi pripadniki osme pozicije sodelujejo z vsemi pripadniki sedme pozicije, medtem ko znotraj pozicije praktično ne sodelujejo. Iz vidika Wallersteinove teorije svetovnega sistema (Wallerstein, 1974), bi odnos med tema blokom opisali kot idealni sistem center–periferija. Poleg ostalih vzorcev soavtorskega sodelovanja med fiziki v tem obdobju lahko omenimo še relativno slabo povezan center raziskovalcev na drugi poziciji, ki so si glede na strukturo povezav izven centra tako podobni, da so razvrščeni v samostojno skupino. V t_4 se center omrežja glede na obdobje prej poveča za 50 odstotkov. To povečanje je še vedno manjše od rasti semi-periferije, ki je postala res velika. Periferija na enajsti poziciji je absolutno gledano ostala enako velika, njena relativna velikost glede na ostale dele omrežja pa se je precej pomanjšala.

Matematika

Bločni modeli omrežja matematikov predstavljeni na sliki 4.4.2 se že na prvi pogled od že predstavljenih omrežij fizikov in sociologov razlikujejo po eno-

Slika 4.8: Center – periferija bločni modeli omrežja matematikov v 4 časovnih obdobjih



stavnejši strukturi. V t_1 smo z metodo bločnega modeliranja določili samo tri pozicije. Prvo pozicijo lahko opisemo kot enostaven center, kateremu manjkata dve povezavi, da bi bil povsem poln diagonalni blok. Na drugi poziciji je semi-periferija, kjer o urejeni strukturi sodelovanja težko govorimo. Tretja

pozicija, periferija zavzema večino soavtorskega omrežja matematikov. Celoten bločni model jasno kaže, da matematiki v prvem obravnavanem obdobju niso objavljeni v sodelovanju s kolegi iz discipline. V smislu strukture omrežja je v prvem obdobju vladala precejšnja razdrobljenost discipline.

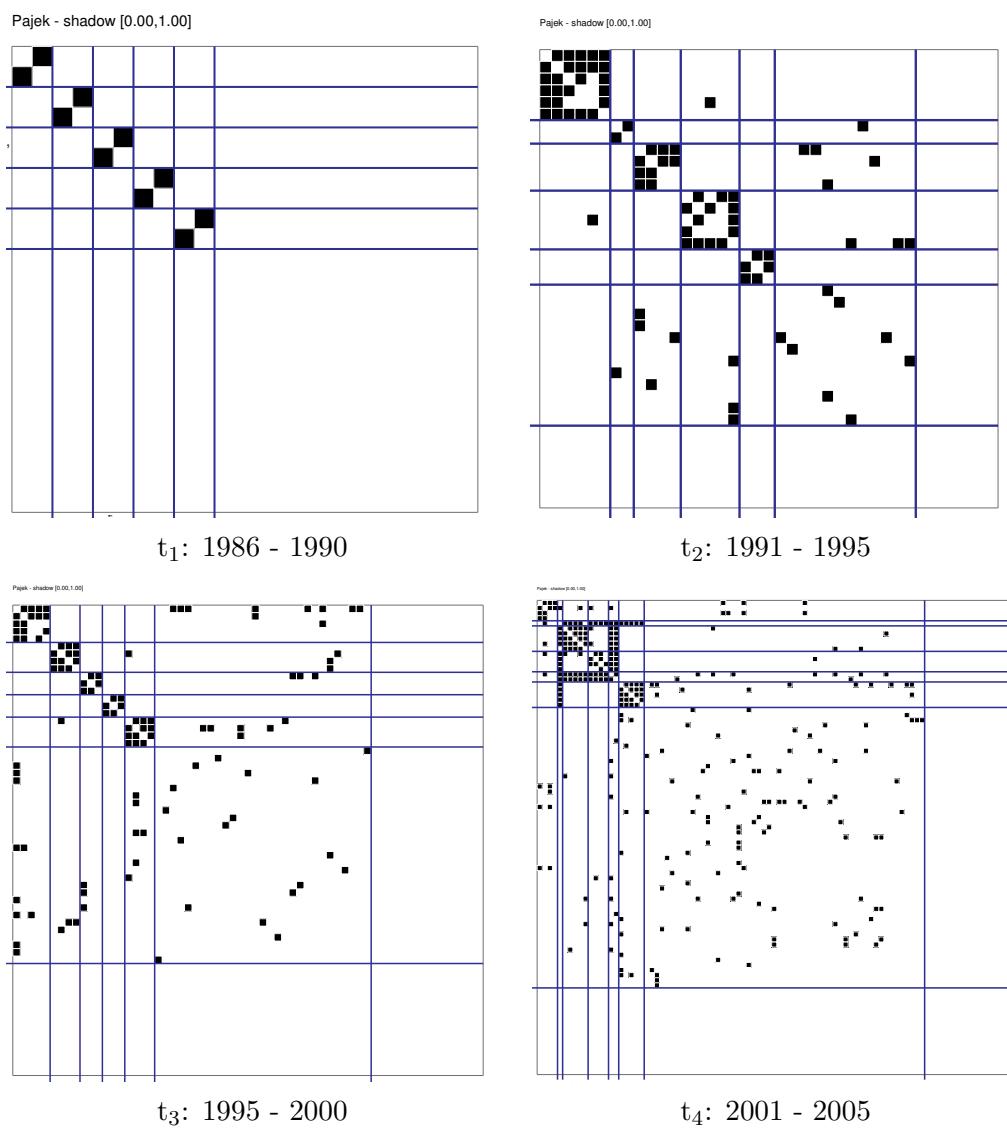
Struktura v drugem obdobju je drugačna. Prve štiri začrtane pozicije so enostavni centri. V primerjavi s prej opisanimi omrežji sociologov in fizikov, so ti centri majhni. Peto pozicijo v bločnem modelu zavzema en sam raziskovalec, ki objavlja z avtorji treh različnih centrov. Podoben pojav smo v drugem obravnavanem obdobju opazovali tudi v omrežju fizikov, kjer je en raziskovalec sistematično povezoval več pozicij. Semi-periferija na šesti poziciji, je sestavljena iz avtorjev z manjšo, razpršeno povezanostjo med seboj in z avtorji iz različnih centrov. Semi-periferija je manjša kot periferija v prvem časovnem obdobju. Obe periferni skupini sta v tem obdobju precej zrasli.

V t_3 bločni model omrežja kaže enostavnejšo center–periferija strukturo. Vsebuje pet enostavnih centrov, med katerimi največji šteje 5, najmanjši pa dva člana. Med centri sta samo dve soavtorski povezavi, kar kaže na pet različnih raziskovalnih tem, s katerimi se raziskovalci ukvarjajo. Tako semi-periferija kot periferija sta zrasli, pri čemer periferija med njima še vedno zajema več prostora. Celotna struktura se v zadnjem obravnavanem obdobju praktično ne spremeni. Število enostavnih centrov se poveča na sedem, povezav med centri je samo šest. Tudi tokrat sta semi-periferija in periferija pridobili na velikosti.

Biotehnologija

Na sliki 4.4.2 predstavljamo bločne modele soavtorskega omrežja biotehnologov v štirih analiziranih obdobjih. V prvem obdobju je struktura osupljivo

Slika 4.9: Center – periferija bločni modeli omrežja biotehnologov v 4 časovnih obdobjih



enostavna. Celotno omrežje tvori pet parov povezanih avtorjev iz področja biotehnologije, ki so v parih objavili znanstvena dela. Semi-periferije v obliki, kakršno smo definirali v omrežju, ni, periferija pa je nekoliko večja od centralnega dela omrežja. V drugem obravnavanem obdobju pride do konkretno spremembe v omrežju, ki se razvije v čisto center–periferija strukturo s petimi enostavnimi centri velikosti med 2 in 6 avtorjev. Soavtorskih povezav z izjemo ene, med enostavnimi centri ni. V bločnem modelu prav tako ni nobenega povezovalnega centra. Kljub vsemu centralni del omrežja predstavlja skoraj polovica raziskovalcev celotne discipline, kar med obravnavanimi omrežji, najdemo zgolj v omrežju biotehnologov. Semi-periferija je na šesti poziciji, periferija na sedmi, ki je v primerjavi z drugimi omrežji zelo majhna. Predstavljena struktura se v obdobju t_3 praktično ne spremeni. Centri ostanejo majhni, medtem ko velikost semi-periferije in periferije zraste. Do večje strukturne spremembe bločnega modela pride v zadnjem obravnavanem obdobju (t_4). Centralni del omrežja ima šest centrov. Prvi, tretji, četrtni in šesti so enostavni centri, medtem ko sta drugi in peti povezovalna centra. Drugo pozicijo bločnega modela v t_4 , predstavljenega na sliki 4.4.2, zaseda en sam avtor. Ta avtor je povezan z enim avtorjem iz prvega centra, ter vsemi avtorji iz ostalih centrov (z izjemo enega avtorja v tretjem centru). Oba pripadnika petega, povezovalnega centra imata skupne objave z vsemi pripadniki drugega, tretjega in četrtega centra. Sedmo pozicijo v bločnem modelu ima velika semi-periferija ter osmo relativno majhna periferija.

Raziskovalec, ki v četrtem obdobju zaseda drugo pozicijo v bločnem modelu ima podobno vlogo kot posameznik, ki v omrežju fizikov povezuje več centrov v obdobjih t_1 in t_2 , ter posameznik iz omrežja matematikov v t_2 . V primerjavi z drugimi omrežji sta pri biotehnologih dve očitni razliki. Prva razlika je, da se omrežje s povezovalnimi centri ustali šele v zadnjem obdobju, kar se je pri

ostalih omrežjih dogajalo prej. Druga posebnost pa je, da ima biotehnologija dva povezovalna centra, kar kaže na višjo stopnjo konsolidacije med centri discipline. Centralni del soavtorskega omrežja biotehnologov je istočasno rasel in postal bolje povezan, kar kaže na na višjo stopnjo koherentnosti v primerjavi z drugimi analiziranimi omrežji, kljub temu, ali morda ravno zato, ker je biotehnologija ‐nova‐ disciplina.

Opis bločnih modelov

Za vse obravnavane discipline lahko trdimo, da nimajo ene same bločne strukture skozi vsa analizirana obdobja. Med vsemi disciplinami lahko v različnih časovnih točkah najdemo tako podobnosti kot razlike v strukturi soavtorskega sodelovanja. Najpogostejsa struktura v omrežjih je center–periferija. To je struktura, z več enostavnimi centri, semi-periferijo in periferijo, s čimer smo potrdili tretjo raziskovalno hipotezo. Ta enostavna struktura je prisotna pri sociologih v t_1 , in t_2 , pri fizikih v t_3 in t_4 , pri matematikih v t_1 , t_3 in t_4 , ter pri biotehnologih v t_1 , t_2 in t_3 . V splošnem pri tej strukturni obliki število centrov pri vseh disciplinah skozi čas narašča. Druga najpogostejsa bločna struktura v omrežjih je enostavna center–periferija struktura z dodatnimi povezovalnimi centri. Ta se pojavi v t_3 in t_4 pri sociologih, v t_1 in t_2 pri fizikih, v t_2 pri matematikih in v t_4 pri biotehnologih. Povezovalni centri so praviloma manjši od enostavnih centrov, ki jih povezujejo. Zanimivo je, da se ta struktura najpozneje pojavi v omrežju biotehnologov, v znanstveni disciplini, ki je najmlajša med obravnavanimi znanstvenimi disciplinami, najprej pa v omrežjih fizikov (v t_1) in matematikov (v t_2). Taka ustaljena struktura ni nujno tudi stabilna. V fiziki je bila na primer prisotna v t_1 in t_2 , v zadnjih dveh obravnavanih obdobjih pa je ni bilo (kljub temu, da se v t_4

taka povezava nakazuje). V matematiki je bila povezovalna struktura oblika prisotna v t_2 , v sociologiji v t_3 in t_4 , ter v biotehnologiji v t_4 . Vsekakor bo v prihodnje zanimivo opazovati, če se bo poenostavljena struktura v obliki enostavnih centrov, zopet pojavila tudi v sociologiji in biotehnologiji. Glede na strukturo omrežja biotehnologov v t_4 , z dvema povezovalnima centromi, bi lahko v prihodnje pričakovali drugačen razvoj kot v omrežju sociologov.

Pomembna potrditev strukturnih lastnosti omrežij, prikazanih v poglavju 4, predstavlja tudi relativno majhna periferija v disciplinah, kjer delo poteka organizirano v laboratorijih t.i. "lab" disciplinah (fizika in biotehnologija), medtem ko v "pisarniških" disciplinah (matematiki in sociologiji) semi-periferija in periferija obsegata večji del omrežja, s čimer podobno kot v delu poglavja, kjer smo strukturo analizirali z uporabo časovnih vrst, potrjujemo šesto hipotezo.

4.4.3 Evolucija bločnih modelov

V prejšnjem delu poglavja smo predstavili bločno strukturo soavtorskih omrežij štirih disciplin v štirih zaporednih petletnih obdobjih, opredeljenih z leti 1986-1990 (t_1), 1991-1996 (t_2), 1995-2000 (t_3) in 2001-2005 (t_4). Vse štiri discipline imajo strukturo, ki se med posameznimi obravnavanimi obdobji bolj ali manj spreminja. Spremembe strukturne oblike, ki smo jih v prejšnjem delu poglavja opredelili in opisali, sicer imajo neko sporočilno vrednost, vseeno pa iz njih izvemo bore malo o ozadju sprememb in mehanizmih, ki jih vzpodbujujo. V nadaljevanju si bomo natančneje ogledali premike raziskovalcev med posameznimi pozicijami skozi čas. Tako bomo izvedeli, na kakšen način se spreminja struktura prej opisanih skupin raziskovalcev. V

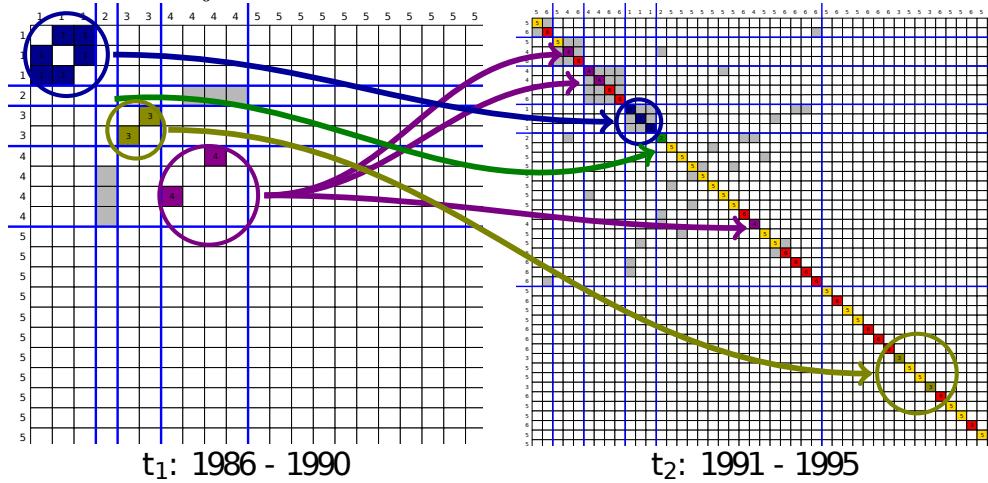
naslednjem koraku bomo poleg informacije o spremembi strukture na individualnem nivoju bločnim modelom dodali še dodatno relacijsko informacijo npr. pripadnost isti raziskovalni skupini ali podobnost obravnavanih raziskovalnih tem, s katerimi se ukvarjajo raziskovalci v posamezni skupini.

Primer evolucije bločnih modelov omrežja sociologov

Oglejmo si najprej dinamiko v omrežju sociologov. Začeli bomo z opisom posameznih obdobjij in prehodov med njimi, zaključili pa s povzetkom dinamike za obdobje vseh dvajsetih let. V predstavitvi evolucije bločnih modelov so predstavljeni zgolj centralni deli omrežij, ki so za interpretacijo pomembni. Bločne modele v celoti smo namreč že predstavili in interpretirali v poglavju 4.4.2. Analiza dinamike poteka na naslednji način: levi del slike 4.4.3 prikazuje bločno strukturo omrežja sociologov v začetni točki (t_1). Števila na povezavah diagonalnih blokov predstavljajo pripadnost skupini, definirani s pozicijo. Z zaporednimi števili so označeni prvi štirje bloki, s 5 je označena periferija. Poleg petih skupin, ki označujejo pozicije v t_1 , je v t_2 na desnem delu slike 4.4.3 še 6 skupina raziskovalcev, ki v omrežje vstopi v t_2 in v t_1 še ni bila del omrežja. Povezav med pozicijami v bločnem modelu nismo posebej označevali, saj za interpretacijo premikov avtorjev med pozicijami v tem primeru nimajo pomena. Povezave izven diagonalnih blokov so tako označene zgolj s sivo barvo. Na desnem delu slike niso označene povezave med raziskovalci ampak je na diagonalnih poljih s številkami označena skupina, ki ji je posamezen raziskovalec pripadal v začetnem obdobju (t_1).

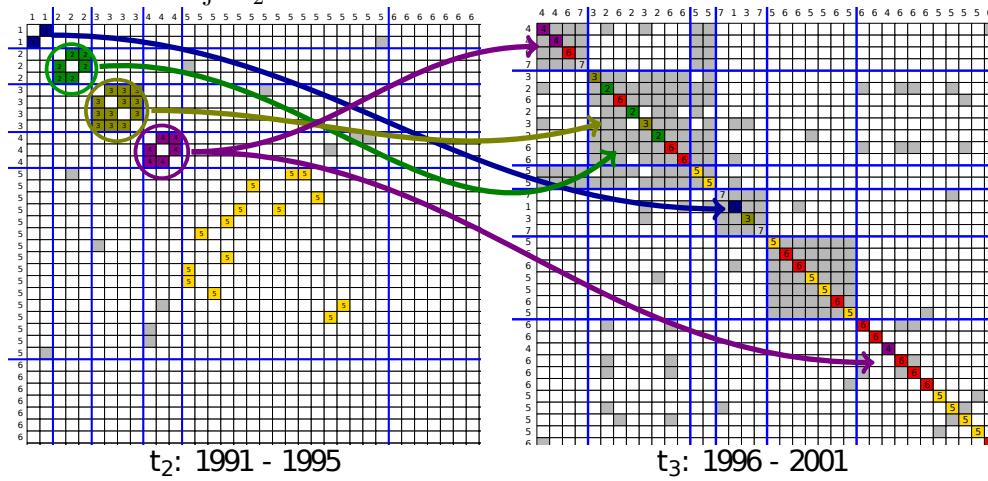
V prvem obdobju je omrežje sociologov majhno in precej nepovezano. Sestavljen je iz klike treh raziskovalcev na prvi poziciji, para raziskovalcev na tretji poziciji, ter nepovezane skupine avtorjev na četrtni poziciji. To si-

Slika 4.10: Primerjava pripadnosti skupinam v omrežju sociologov v obdobjih t_1 in t_2 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_1 .



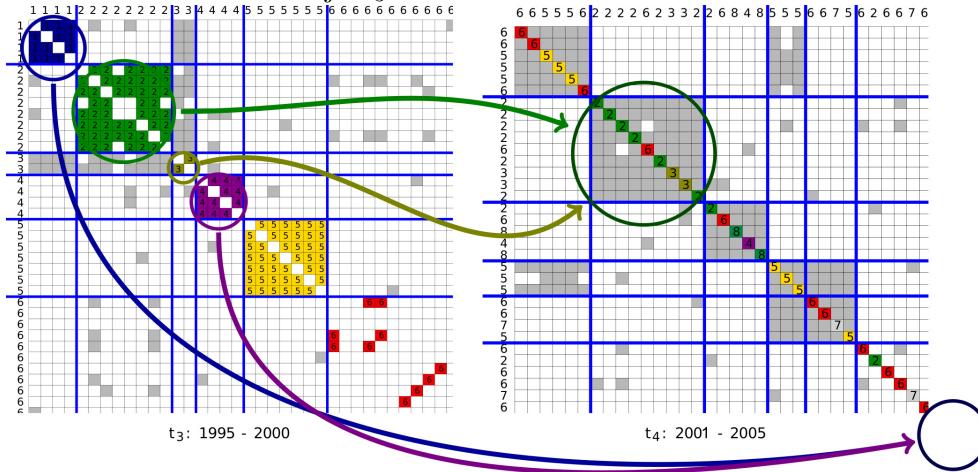
cer nepovezano skupino definira skupno soavtorstvo z raziskovalcem, ki tvori drugo pozicijo. Preostali del omrežja predstavlja velika periferija avtorjev, ki objavlja zgolj samostojno ali v soavtorstvu z avtorji, ki niso del omrežja.

Slika 4.11: Primerjava pripadnosti skupinam v omrežju sociologov v obdobjih t_2 in t_3 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_2 .



Prehod v t_2 za omrežje sociologov predstavlja velik preskok iz vidika strukture omrežja. V drugem obdobju lahko vidimo jasno strukturo štirih centrov, semi-periferije in periferije. V tem prehodu klika iz prve pozicije v t_1 ostane nedotaknjena in je na četrtri poziciji v t_2 . Povezovalni avtor iz druge pozicije v t_1 je v tem obdobju manj aktiven (iz vidika sodelovanja z različnimi avtorji), tako da je pristal v semi-periferiji. Enako se zgodi s parom iz tretje pozicije. Skupina iz četrte pozicije, ki v drugem obdobju izgubi povezovalnega avtorja iz druge pozicije, razpade. En avtor iz četrte skupine v t_1 se v t_2 poveže v skupino na drugi poziciji z raziskovalcem iz periferije in avtorjem, ki je v t_2 vstopil v omrežje, dva iz četrte skupine v t_1 sta se prav tako povezala z dvema novo-pristopnikoma, en raziskovalec pa je pristal v semi-periferiji. Prvo pozicijo v t_2 zaseda par raziskovalcev, med katerima je bil eden v t_1 v periferiji drugi pa še ni bil del omrežja.

Slika 4.12: Primerjava pripadnosti skupinam v omrežju sociologov v obdobjih t_3 in t_4 (prvi del). Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_3 .



S prehodom v tretje obdobje postane omrežje sociologov še kompleksnejše. Klika, ki je bila v t_1 na prvi, ter v t_2 na četrtri poziciji razpade. Dva raz-

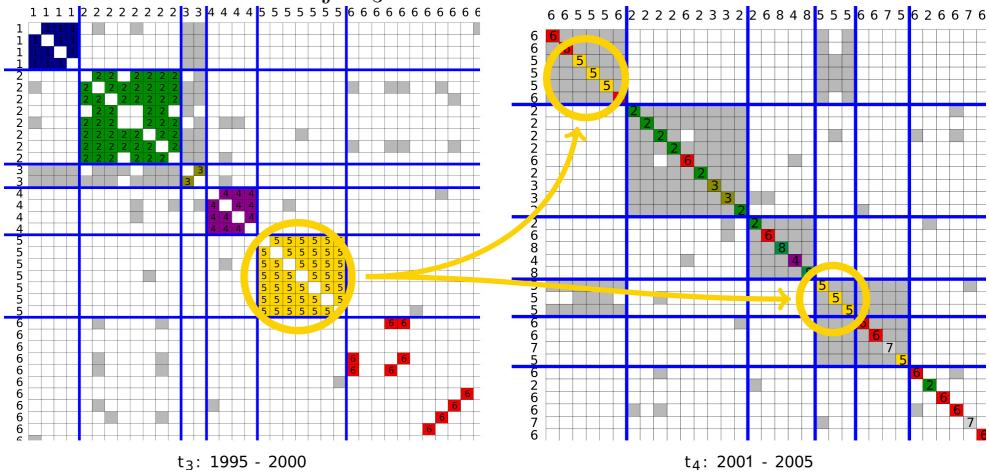
iskovalca se povežeta z enim, ki je bil v t_2 del periferije, in enim, ki je v tem obdobju vstopil v omrežje. Tretji raziskovalec iz te klike se umakne v semi-periferijo. Raziskovalci, ki so bili v t_2 na drugi in tretji poziciji, se v t_3 povežejo v veliko skupino, ki se popolni s tremi raziskovalci, ki so bili v prejšnjem obdobju del periferije. En raziskovalec iz tretje skupine in eden od para iz prve, se z dvema novima raziskovalcema povežeta v skupino na četrti poziciji. Pomembno vlogo v omrežju v t_3 imata raziskovalca, ki v tem obdobju zasedata tretjo pozicijo. Raziskovalca, ki sta bila v t_2 del semi-periferije, sedaj povezujeta raziskovalce iz prvega in drugega centra. V prehodu iz t_2 v t_3 se na peti poziciji oblikuje še en precej velik nov center, sestavljen iz raziskovalcev, ki so bili v t_2 del semi-periferije in periferije.

S prehodom v zadnje obravnavano obdobje t_4 se iz centralnega dela v periferijo umaknejo raziskovalci iz prve in četrte pozicije. Naj spomnimo, da so raziskovalci iz prve pozicije v t_3 del klike, ki je bila aktivna že v t_1 , kar pomeni, da so bili akterji v centralnem delu omrežja več kot 15 let. V tem prehodu pride do nadaljnje združitve raziskovalcev iz druge in tretje pozicije, kar v t_4 pripelje do konsolidacije močnega centra na drugi poziciji (glej sliko 4.4.3).

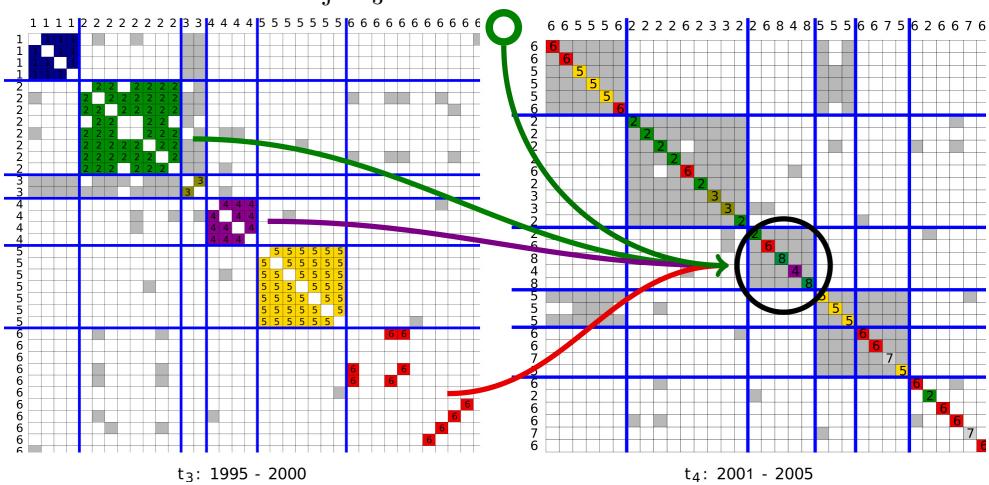
Peti center iz t_3 , v t_4 razpade na dva centra. Vsak del raziskovalcev se poveže z raziskovalci iz semi-periferije in periferije (slika 4.4.3). Zanimivo je, da je en del prej pete skupine navezal stike z novimi raziskovalci iz drugega dela skupine, medtem ko drugi del raziskovalcev iz skupine ne.

V tem zadnjem analiziranem obdobju, se v omrežju sociologov na tretji poziciji poveže nova skupina sestavljena iz raziskovalcev, ki izhajajo iz dveh različnih skupin, semi-periferije in dveh raziskovalcev, ki sta v tem obdobju na novo postala del omrežja sociologov (slika 4.4.3).

Slika 4.13: Primerjava pripadnosti skupinam v omrežju sociologov v obdobjih t_3 in t_4 (drugi del). Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_3 .



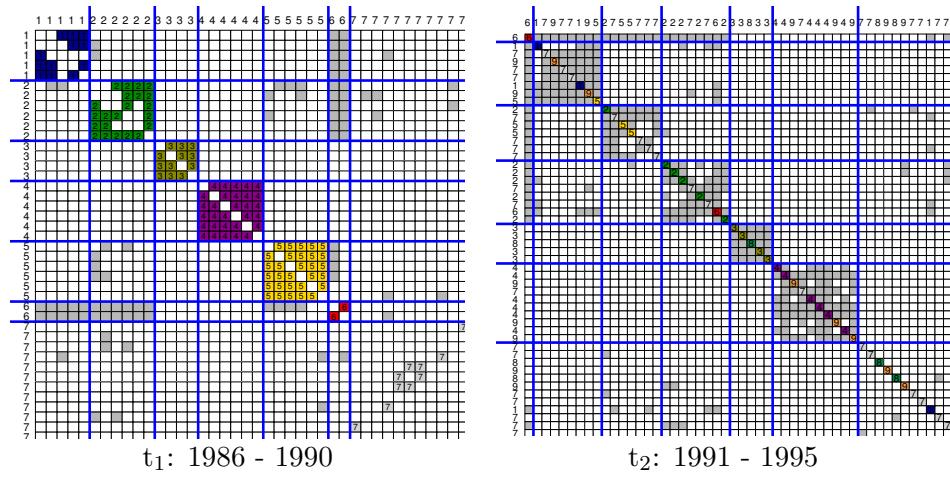
Slika 4.14: Primerjava pripadnosti skupinam v omrežju sociologov v obdobjih t_3 in t_4 (tretji del). Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_3 .



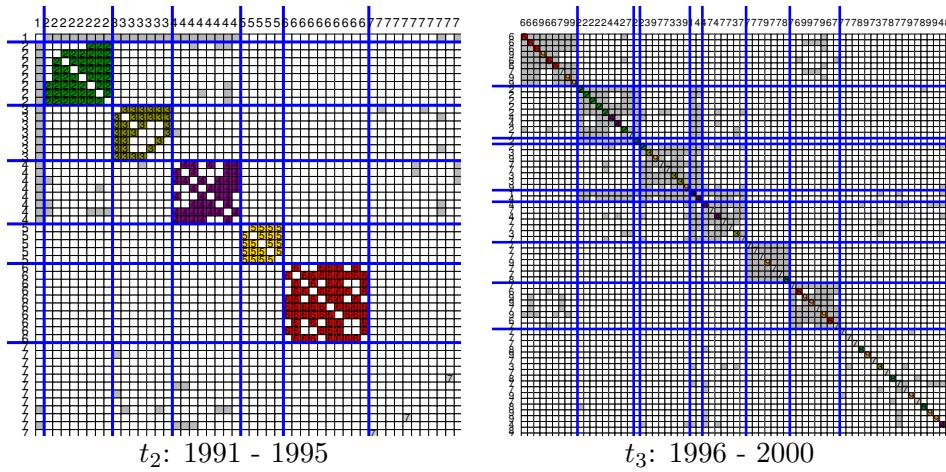
Bločna dinamika v omrežju fizikov

Kot smo omenili že v začetku tega poglavja (4.4.2), je omrežje fizikov že v prvem obravnavanem obdobju močno konsolidirano z izrazito strukturo šestih centrov, semi-periferijo in majhno periferijo. V primerjavi z omrežjem sociologov so pri fizikih spremembe manj izrazite (glej slike 4.4.3 do 4.17). Centri v večini primerov ostanejo nespremenjeni skozi daljša časovna obdobja, pri čemer se dopolnjujejo z novimi kadri iz semi-periferije, periferije in raziskovalci, ki na novo vstopajo v omrežje. Edina izrazita posebnost v omrežju fizikov je pozicija enega raziskovalca, ki v omrežju igra pomembno vlogo kot povezovalni center. V drugem obdobju je ta vloga še posebej izrazita, saj raziskovalec sam povezuje tri relativno velike skupine, v prvem in tretjem obdobju raziskovalec pozicijo deli z drugim raziskovalcem, tako da tri centre povezujeta v paru.

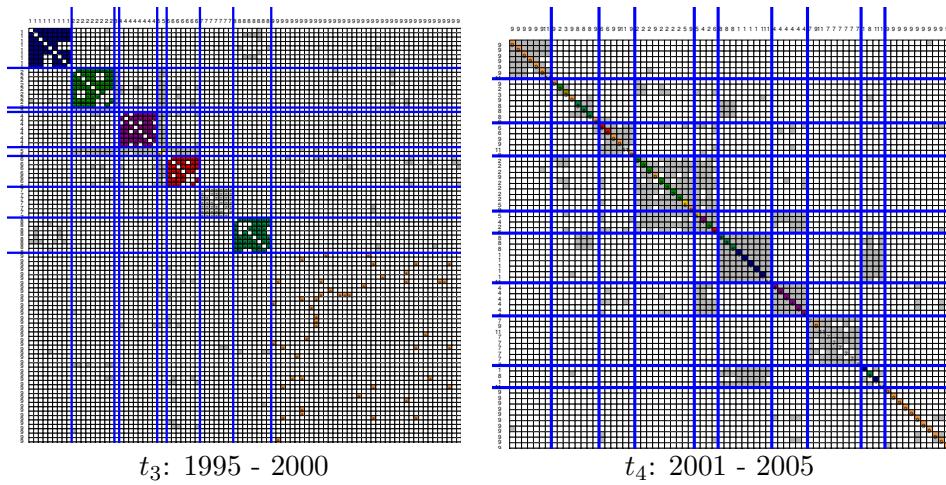
Slika 4.15: Primerjava pripadnosti skupinam v omrežju fizikov v obdobjih t_1 in t_2 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_1 .



Slika 4.16: Primerjava pripadnosti skupinam v omrežju fizikov v obdobjih t_2 in t_3 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_2 .



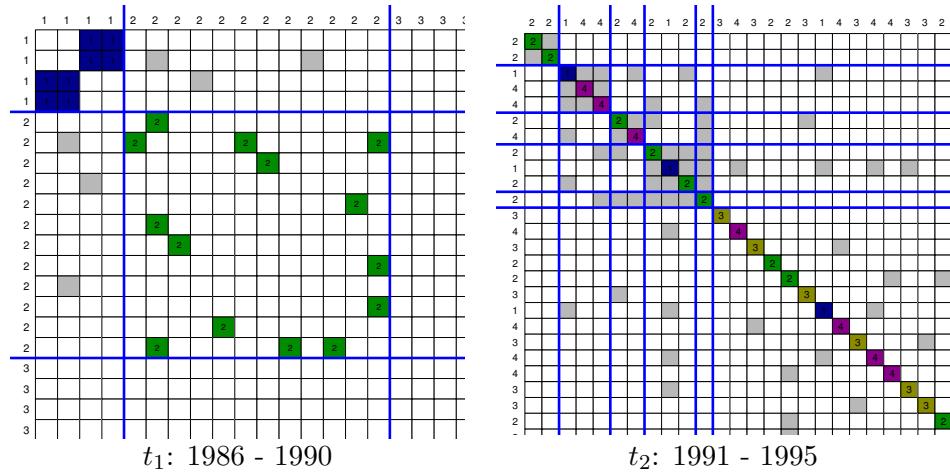
Slika 4.17: Primerjava pripadnosti skupinam v omrežju fizikov v obdobjih t_3 in t_4 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_3 .



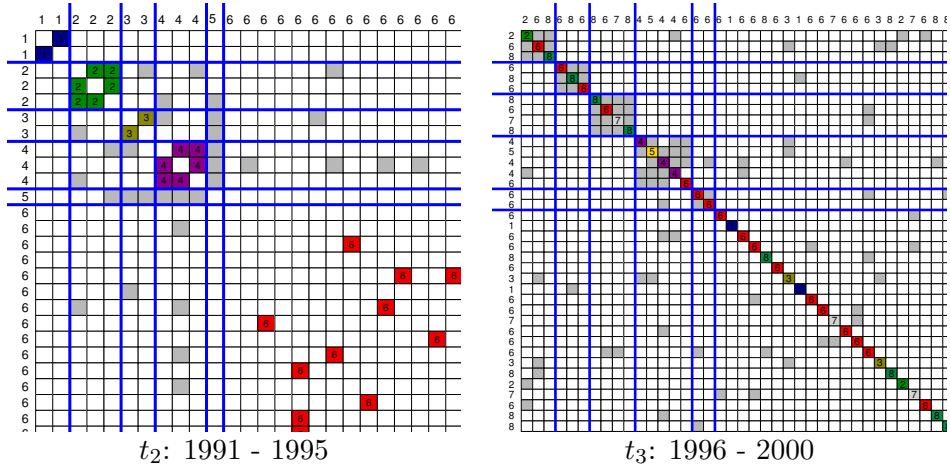
Posamezniki v bločnih modelih omrežja matematikov

Za dinamiko v strukturi omrežja matematikov bi lahko rekli, da je povsem nasprotna dinamiki pri fizikih. Če pri fizikih govorimo o kontinuiteti skupin v času, se pri matematikih skupine formirajo v vsakem analiziranem obdobju na novo. Prva skupina, ki se vsaj delno ohrani, je četrta v t_2 , ki tudi v t_3 z dvema novima članoma ohranja četrto pozicijo. V prehodu iz t_3 v t_4 , ista skupina razпадa na dva dela, ki se okreipa z raziskovalci iz semi-periferije in periferije. V tem prehodu se ohrani še skupina na tretji poziciji, ki v t_4 ohrani pozicijo (glej slike 4.18 do 4.20).

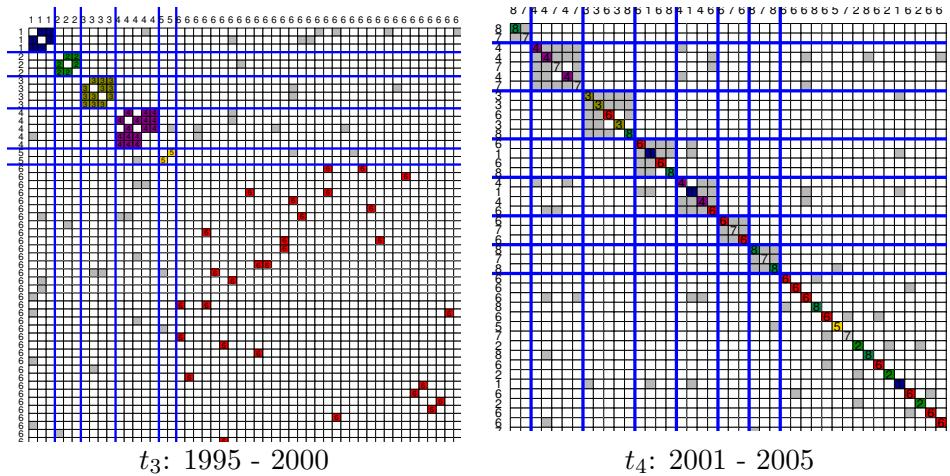
Slika 4.18: Primerjava pripadnosti skupinam v omrežju matematikov v obdobjih t_1 in t_2 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_1 .



Slika 4.19: Primerjava pripadnosti skupinam v omrežju matematikov v obdobjih t_2 in t_3 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_2 .



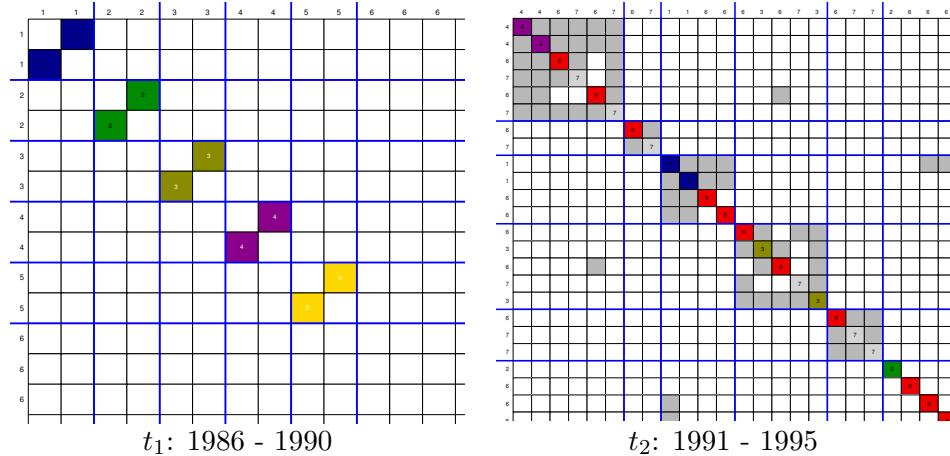
Slika 4.20: Primerjava pripadnosti skupinam v omrežju matematikov v obdobjih t_3 in t_4 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_3 .



Biotehnologija

Biotehnologija je kot nova disciplina v prvem obdobju izrazito razdrobljena. Omrežje namreč predstavlja 5 med seboj nepovezanih parov raziskovalcev. Ob prehodu v t_2 se trije pari ohranijo in z vključevanjem novih raziskovalcev prerastejo v skupine velikosti med 4 in 6 raziskovalcev (slika 4.21).

Slika 4.21: Primerjava pripadnosti skupinam v omrežju biotehnologov v obdobjih t_1 in t_2 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_1 .

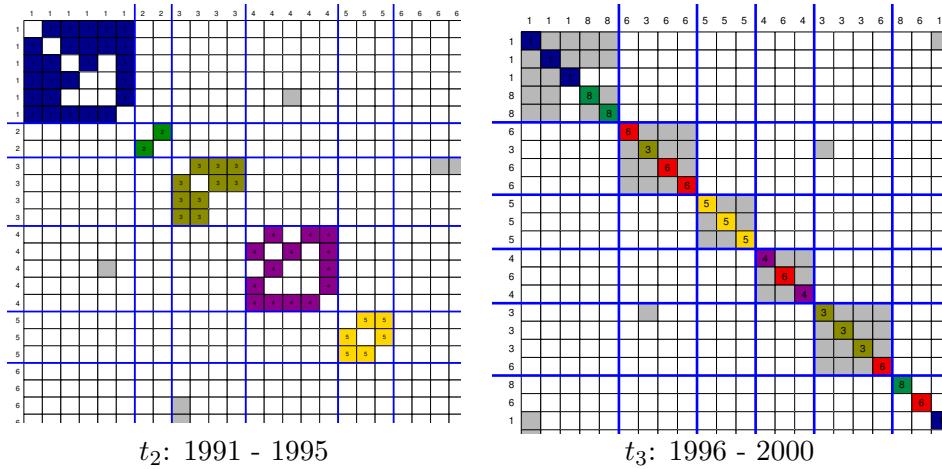


V prehodu v tretje obravnavano obdobje t_3 , že lahko zasledimo kontinuiteto skupin, ki smo jo opazili v omrežju fizikov. Štiri izmed petih pozicij ohrani večina raziskovalcev, nove moči pa črpajo iz semi-periferije in periferije.

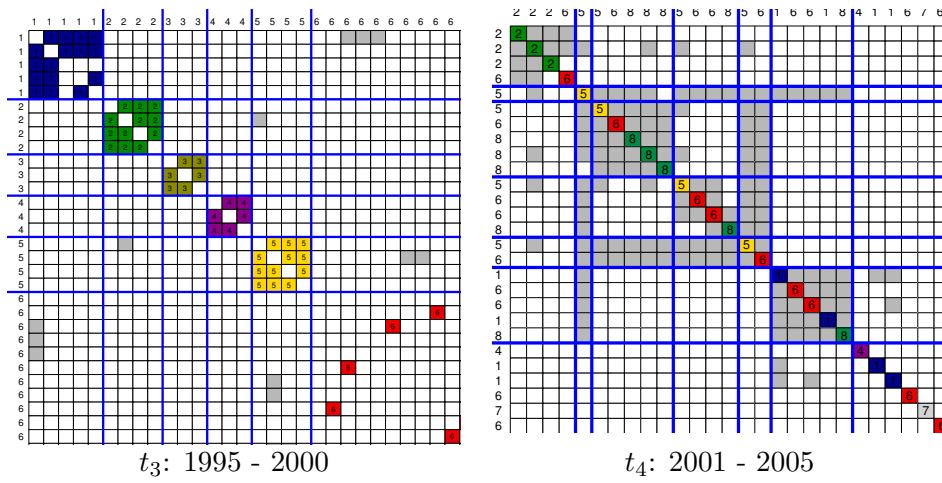
V prehodu iz tretjega v četrto obdobje (slika 4.23), pride v omrežju biotehnologov do zanimivega razbitja pete skupine, kjer vsak izmed raziskovalcev v t_4 deluje v svojem centru. En raziskovalec na drugi poziciji deluje kot povezovalni center 3., 4., 5. in 6. centra. V prehodu v to obdobje se delno ohranita tudi prvi center, ki ohrani prvo pozicijo, in drugi center, kjer dva preostala člana dopolnita skupino s tremi avtorji iz semi-periferije in novimi

raziskovalci.

Slika 4.22: Primerjava pripadnosti skupinam v omrežju biotehnologov v obdobjih t_2 in t_3 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_2 .



Slika 4.23: Primerjava pripadnosti skupinam v omrežju biotehnologov v obdobjih t_3 in t_4 . Označene skupine predstavljajo centralne pozicije v bločnem modelu v obdobju t_3 .



Opis dinamike bločnih modelov

Rezultati posplošenega bločnega modeliranja, predstavljeni v začetnem delu tega poglavja (4.4.2) so pokazali prisotnost večih močno povezanih centrov raziskovalcev v vseh obravnavanih obdobjih v omrežjih vseh štirih obravnavanih disciplin. Z rezultati smo lahko predvsem spremljali variiranje števila centrov v omrežju, ob interpretaciji pa so se porajala nova vprašanja o tem, kaj se dogaja s centri, ki so del omrežja skozi daljše obdobje, izginejo iz omrežja, oz. se v nekem obdobju pojavi v omrežju. Na podlagi rezultatov v tem delu poglavja lahko zaključimo, da nekateri centri enostavno razpadajo, raziskovalci iz njih postanejo akterji v drugih centrih ali pa se umaknejo na (semi-)periferni del omrežja. Ustvarjanje novih centrov in dinamika v omrežjih se med disciplinami razlikuje. Če je za fiziko skozi celotno obravnavano obdobje značilna kontinuiteta centrov, ki se zgolj dopolnjujejo z novimi raziskovalci v omrežju in raziskovalci iz (semi-) periferije, je pri matematikih situacija obratna. Tam se centri v vsakem obdobju vzpostavijo praktično na novo iz raziskovalcev iz obrobja omrežja. O kontinuiteti lahko govorimo šele ob prehodu v zadnje obravnavano obdobje t_4 , a tudi tu prehod ni tako čist kot npr. v omrežju fizikov. V dinamiki omrežja biotehnologov se jasno pokaže *mladost discipline*, saj centri v omrežju rastejo iz parov raziskovalcev, ki med seboj sodelujejo že v prvem obravnavanem obdobju. Za omrežje biotehnologov je značino še to, da akterji iz enega centra v t_3 prevzamejo vloge v štirih različnih centrih, ki so potem v t_4 relativno močno povezani. Iz celotne zgodbe o dinamiki v omrežjih izstopa omrežje sociologov, ki bi ga težko umestili v okvir matematikov ali fizikov. V omrežju sociologov prihaja do večjega števila sprememb med centralnimi bloki, razpadov, združevanja in povezovanja skupin. V omrežju skozi daljše obdobje

pride tudi do konsolidacije enega večjega, močno povezanega centra.

4.4.4 Struktura sodelovanja v povezavi z lastnostmi raziskovalcev

Pripadnost raziskovalnim skupinam

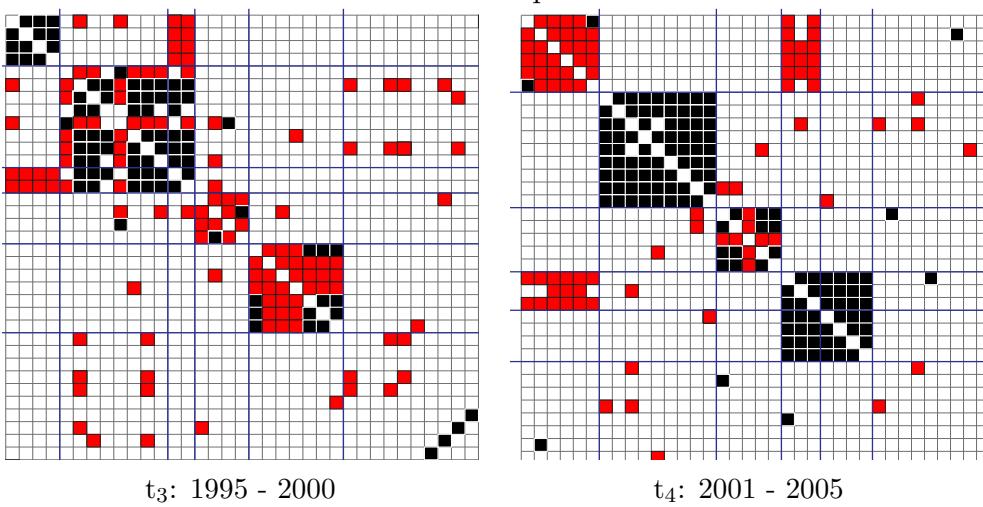
Ena od samoumevnih idej, ki se porajajo ob analizi znanstvenega sodelovanja, je, da raziskovalci, ki znanstveno objavljujo skupaj, tudi delajo na skupni lokaciji. Kljub temu, da ima taka domneva nekako pred-internetno konotacijo, je hkrati dokaj smiselna iz vidika osebne bližine pri sodelovanju in izmenjavi mnenj. Iz vidika sistema raziskovalnih skupin v Sloveniji, tè raziskovalce družijo formalno glede na skupna raziskovalna izhodišča in cilje, kar neposredno vpliva tudi na večjo verjetnost skupnega objavljanja. Vprašanje je torej enostavno: ali raziskovalci v centralnem delu omrežja delajo v isti raziskovalni skupini? V tem delu poglavja se osredotočamo zgolj na zadnji dve obravnavni obdobji t_3 in t_4 oz. zadnji prehod, ki smo ga na nivoju posameznih raziskovalcev za vse štiri obravnavane discipline natančno opisali v prejšnjem delu poglavja. Podatek o pripadnosti raziskovalni skupini je dostopen v bazi SICRIS⁶. Podatki so zajeti skupaj s podatki o raziskovalcih, torej veljajo za leto 2008 in ne za obdobje na katerem je definirano omrežje sodelovanj.

Analizo začnimo z omrežjem sociologov. Na sliki 4.4.4 je predstavljen centralni del omrežja, tako kot na sliki 4.4.3 iz prejšnjega dela poglavja, le da so

⁶Znano je, da ažuriranje podatkov o pripadnosti raziskovani skupini v sistemu SICRIS ni povsem urejeno, česar posledica so manjša odstopanja od realnega stanja.

povezave med raziskovalci predstavljene nekoliko drugače. Med dvema sodelujočima raziskovalcema, ki prihajata iz iste raziskovalne skupine, je povezava označena s črnim poljem, med sodelujočima raziskovalcema iz različnih raziskovalnih skupin pa z rdečim poljem.

Slika 4.24: Primerjava centralnih skupin omrežja glede na pripadnost raziskovalnim skupinam za področje sociologije. S črno so označene povezave med raziskovalci iz istih raziskovalnih skupin in z rdečo pa povezave med raziskovalci iz različnih raziskovalnih skupin.



Povezave med raziskovalci iz prvega centra bločnega modela omrežja v t_3 , prikazanega na levem delu slike 4.4.4, potrjujejo tezo, da raziskovalci, ki skupaj objavljujo tudi formalno delajo v isti raziskovalni skupini. Kljub temu, da vsi raziskovalci tega centra prihajajo iz iste raziskovalne skupine, pa v naslednjem obdobju (t_4) celotna skupina izgine iz centralnega dela omrežja. Premike med obdobjji lahko opazujemo na sliki 4.4.3.

Večina raziskovalcev, z izjemo dveh iz drugega centra v t_3 , deluje znotraj iste raziskovalne skupine. Ta center se v t_4 s tretjim centrom združi v veliko skupino med seboj sodelujočih raziskovalcev, v kateri so vsi člani iste raziskovalne

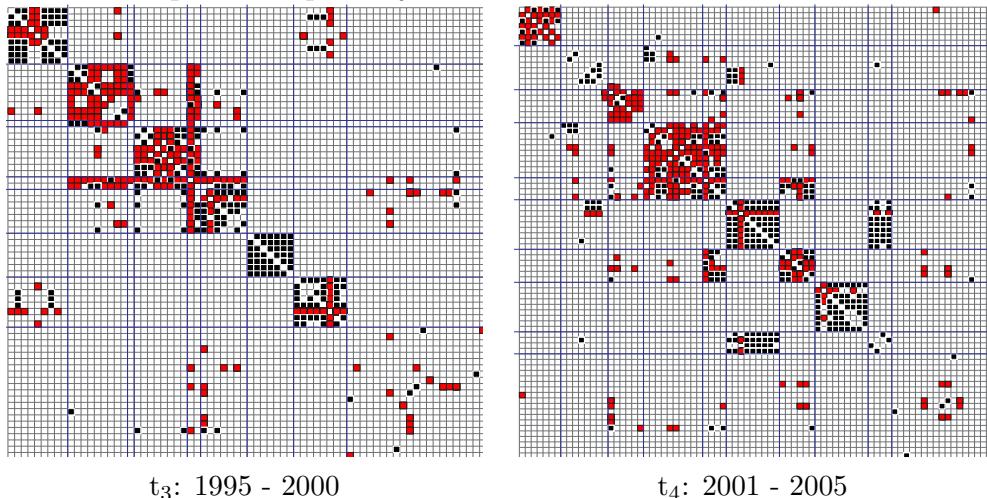
skupine. Raziskovalca, ki v t_3 predstavlja tretji center, imata v omrežju zanimivo vlogo: poleg tega, da sodeluje z s praktično vsemi raziskovalci iz drugega centra, ki pripadajo isti raziskovalni skupini, sta povezana tudi z vsemi raziskovalci iz prvega centra, ki delujejo v drugi raziskovalni skupini. V tem primeru gre pri prehodu iz t_3 v t_4 za primer konsolidacije raziskovalnih skupin.

Center, ki je v t_3 na četrtni poziciji, sestavlja štirje raziskovalci, med katerimi zgolj dva pripadata skupni raziskovalni skupini. Kot smo ugotovili iz slike 4.4.3, ta center tako kot prvi izgine iz centralnega dela omrežja pri prehodu v t_4 . Zanimivo pri tem je, da je sestava prvega in četrtega centra glede na pripadnost raziskovalnim skupinam povsem različna, kar nekoliko spodkoplje idejo o povezovalnem učinku raziskovalnih skupin na sodelovanje raziskovalcev. Ideja se ob končni situaciji v t_4 kljub vsemu večkrat potrdi.

Peti center v t_3 , sestavljen pretežno iz raziskovalcev iz različnih raziskovalnih skupin v prehodu v t_4 razпадa na dva dela. Prvi del se z raziskovalci iz semi-periferije poveže v prvi center s pestro strukturo v smislu pripadnosti raziskovalnim skupinam, drugi del petega centra pa se poveže z drugimi raziskovalci iz perifernega dela omrežja, s katerimi formirajo tudi formalno raziskovalno skupino.

V omrežju fizikov bi glede na organizacijo dela v laboratorijih pričakovali, da je sodelovanje raziskovalcev veliko bolj povezano s pripadnostjo istim raziskovalnim skupinam kot je to razvidno iz bločnih modelov na sliki 4.4.4. Edino povsem enotno skupino močno povezanih raziskovalcev, ki tudi formalno pripadajo isti raziskovalni skupini, lahko zasledimo na sedmi poziciji bločnega modela v tretjem obdobju t_3 . Dokaj homogeni sta le še skupini na prvi in osmi poziciji. S prehodom v zadnje obdobje t_4 ob primerjavi te slike s sliko

Slika 4.25: Primerjava centralnih skupin omrežja glede na pripadnost raziskovalnim skupinam za področje fizike.



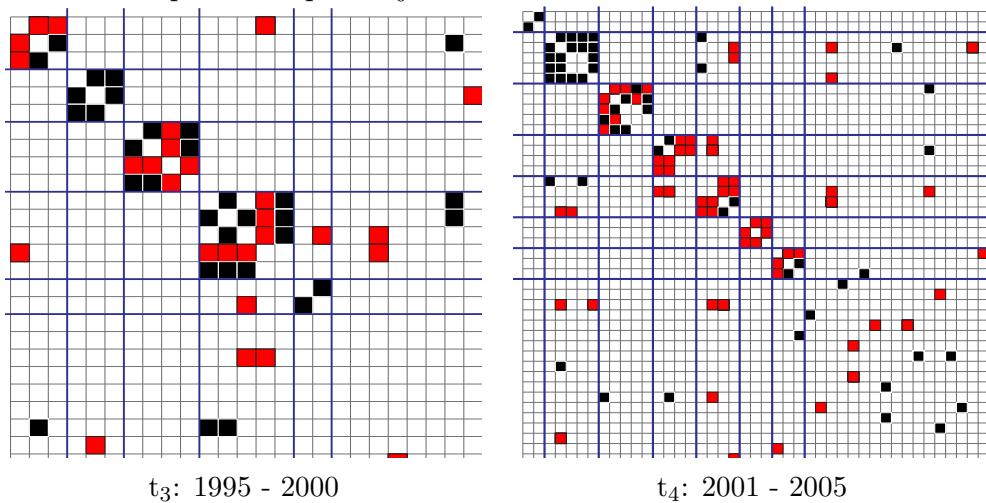
4.17 postane jasno, da v centralnem delu omrežja nastopa ena velika formalna raziskovalna skupina, znotraj katere raziskovalci objavljujo v dveh med seboj ločenih skupinah, pri čemer je ena izmed teh dveh skupin zopet razdeljena na dva dela. V t_4 so te skupine na poziciji 8, ter razdeljena na pozicijah 6 in 9. Preostali del omrežja je iz vidika formalnih raziskovalnih skupin in dejanskega sodelovanja med raziskovalci precej neurejen in razpršen. Morda je to specifika omrežja fizikov, kjer so sicer tesno sodelujoči raziskovalci zaposleni na dveh raziskovalnih institucijah: Fakulteti za matematiko in fiziko in/ali Institut "Jožef Stefan".

Za področje matematike smo že v prejšnjem delu poglavja omenili, da skupine nastajajo ob vsakem prehodu omrežja med obdobji na novo. Tako tudi v omrežju težko sledimo formalni raziskovalni strukturi. Edina izmed skupin, kjer v zadnjem obdobju vsi raziskovalci tudi formalno pripadajo isti raziskovalni skupini, lahko v t_4 najdemo na drugi poziciji. To je tudi edina skupina, za katero smo na sliki 4.20 ugotovili, da se ohranja skozi več obravnavanih

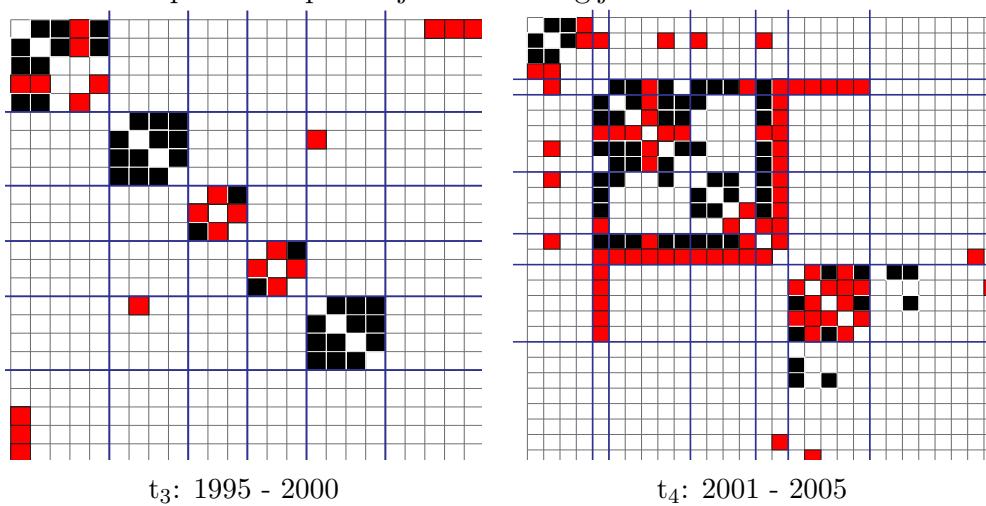
obdobj.

Na področju biotehnologije je struktura nekoliko nenavadna, saj v prehodu iz t_3 v t_4 omrežje iz čiste strukture s 5 centri, v katerih so raziskovalci pretežno

Slika 4.26: Primerjava centralnih skupin omrežja glede na pripadnost raziskovalnim skupinam za področje matematike.



Slika 4.27: Primerjava centralnih skupin omrežja glede na pripadnost raziskovalnim skupinam za področje biotehnologije.



povezani tudi formalno iz vidika pripadnosti raziskovalnim skupinam, preide v dokaj prepleteno strukturo. Ta struktura je posledica ustvarjanja lastnih skupin sodelavcev vsakega izmed raziskovalcev, ki so bili v t_3 skupaj v skupini na 5 poziciji. V t_4 so na drugi tretji in četrtri poziciji raziskovalci iz iste raziskovalne skupine (s tremi izjemami). Na prvi in šesti poziciji sta dve skupini, ki formalno nista povezani.

Natančna analiza v tem delu poglavja je pokazala, da je od raziskovalcev samoumevno pričakovati sodelovanje zgolj na podlagi pripadnosti isti formalni raziskovalni skupini preuranjeno, saj sodelovanje poteka precej neodvisno od formalnih struktur v organizacijah. To seveda ni nič nenavadnega, je pa dobra osnova za proučevanje motivov sodelovanj znotraj in med raziskovalnimi skupinami.

Sodelovanje na podlagi tem raziskovanja

Eden izmed samoumevnih mehanizmov, ki vzpodbujujo znanstveno sodelovanje, so podobne raziskovalne teme, s katerimi se raziskovalci ukvarjajo. Gre za natančnejšo opredelitev področja raziskovanja kot je definirano zgolj z znanstveno disciplino. Glede na to, da se posamezen raziskovalec v svoji karieri v večini primerov loteva širokega nabora tem in da je na podlagi obravnavane vsebine podoben drugim raziskovalcem iz svoje discipline, ni nujno, da z drugimi raziskovalci tudi sodeluje. Sodelovanje ni pogojeno s podobnim referenčnim okvirjem, saj je za sodelovanje dovolj zgolj ena skupna raziskovalna tema.

Za proučevanje skupnih interesov raziskovalcev, ki vodijo v znanstveno sodelovanje, smo za vsakega posameznega raziskovalca zbrali ključne besede in

besede iz naslovov vseh njegovih/njenih publikacij dostopnih v bibliografski zbirki COBISS. Ker je teh besed veliko, smo jih z uporabo metode voditeljev glede na pojavljanje pri posameznih raziskovalcih združili v 100 skupin. S prekrivanjem dobljenih skupin pri dveh raziskovalcih smo operacionalizirali moč povezave med sodelujočim parom kot delež prekrivajočih se skupin besed vseh njunih publikacij.

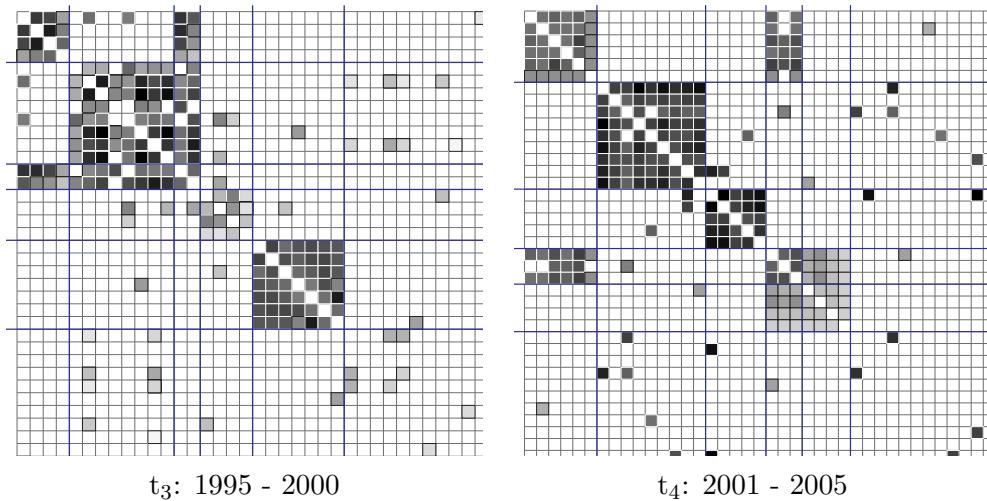
Postopek, ki smo ga uporabili, ima v fazi tehnične izvedbe nekaj pomanjkljivosti. Prva omejitev je, da smo zaradi uporabe slovenskega lematizatorja (Erjavec in drugi, 2005) za analizo zajeli zgolj besede v slovenskem jeziku⁷.

Lematizator uporabljam za urejanje in čiščenje seznama besed tako, da besedam, ki so v besedilu v različnih slovničnih oblikah pripisemo osnovne (slovarske) oblike. Ker smo za vse publikacije ne glede na jezik objave uporabili zgolj slovenske besede, je manjkajočih podatkov relativno veliko. Pravzaprav je manjkajočih podatkov toliko, da smo se odločili v tem delu predstaviti zgolj primer analize za področje sociologije, kjer je na voljo vsaj nekaj podatkov o vsebini raziskovanja za nekaj več kot 85 odstotkov raziskovalcev. Relativno dobro pokritost imamo še za področje matematike, medtem ko je ta pri fiziki manj kot 30, pri biotehnologiji pa med 50 in 80 odstotna.

Slika 4.4.4 predstavlja izsek istega bločnega modela, ki smo ga analizirali in predstavili že na slikah 4.4.3 in 4.4.4. Gre za omrežje sodelovanj, pri čemer so povezave med raziskovalci utežene glede na njihove skupne raziskovalne interese. Tudi tokrat se osredotočamo zgolj na bločna modela omrežja v obdobjih t_3 in t_4 . Na sliki temnejše povezave med akterji predstavljajo večjo podobnost med raziskovalcema glede na ključne besede in besede iz naslo-

⁷V podatkovni zbirki COBISS ima večina bibliografskih enot ključne besede navedene v slovenskem jeziku ne glede na jezik objave

Slika 4.28: Primerjava raziskovalcev v centrih glede na skupno raziskovalno vsebino (sociologi v t_3 in t_4). Uteži na povezavah med raziskovalci predstavljajo delež skupnih skupin besed, uporabljenih v naslovih in ključnih besed publikacij posameznih avtorjev.



vov vseh raziskovalčevih znanstvenih objav. Iz vidika dinamike sta zanimivi predvsem četrta skupina in prva skupina raziskovalcev v t_3 , ki v t_4 v celoti izgineta iz centralnega dela omrežja. V četrtri skupini intenzivnost povezav kaže na nizko raven podobnosti glede na pretekle objave, medtem ko so si raziskovalci iz prve skupine precej bolj podobni. Ta ugotovitev ni presenetljiva, če jo povežemo s pripadnostjo raziskovalnim skupinam. Naj spomnimo, da raziskovalci prve skupine tudi formalno sodijo v isto raziskovalno skupino, medtem ko raziskovalci iz četrte skupine ne. Seveda *razpad* prve, močno formalno kot vsebinsko povezane skupine na prehodu iz t_3 v t_4 , predstavlja zanimivo vprašanje, ki ostaja odprto. Nasprotno se drugi center, ki se ob prehodu v t_4 poveže s tretjim centrom v veliko in močno raziskovalno skupino (tudi formalno) konsolidira tudi iz vidika vsebine, kar je v precejšnji meri verjetno posledica velikega števila publikacij skupine in publikacij, v katerih je udeleženo veliko raziskovalcev te skupine. Starost centrov ni nujno povezana

z intenzivnostjo prekrivanja splošnih raziskovalnih interesov posameznikov, ki so del teh centrov. V novo vzpostavljeni tretji center (t_4) so se namreč povezali raziskovalci, ki se pri svojem delu ukvarjajo s podobnimi temami. Kljub temu, da skupina na peti poziciji na prehodu iz t_3 v t_4 razпаде, se vezi med raziskovalci stare skupine ohranijo, kar je verjetno predvsem posledica skupnih raziskovalnih interesov.

Stopnja zanimanja za iste raziskovalne teme, kljub ne povsem čisti sliki, ima opazno vlogo pri oblikovanju strukture znanstvenega sodelovanja. Nizko stopnjo skupnih interesov tako povezujemo s povezovanjem v centre za krajše obdobje, medtem ko je velika podobnost vezana na daljša obdobja sodelovanja.

Dinamika bločnih modelov in lastnosti povezav

Rezultati analize kažejo, da med centri sodelujočih raziskovalcev, formalno organizacijsko strukturo in skupnimi interesi glede raziskovalnih tem posameznih raziskovalcev ni povsem enostavne povezave. Sploh ne, ko v analizo vključimo tudi dimenzijo časa. Rezultat je smiseln, saj so sodelovanja lahko posledica zanimanja za neka ozka specifična področja in ni nujno, da si sodelujoči raziskovalci delijo neka širša raziskovalna zanimanja oz. da izhajajo iz vsebinsko enakega raziskovalnega okolja. Poleg tega, da imajo raziskovalne teme svojo življenjsko dobo, imajo tudi raziskovalci svoje osebne interese in ideje o temah, s katerimi se ukvarjajo. Ko je določena tema *aktualna* pritegne večje število raziskovalcev. Po zatonu teme nekateri raziskovalci ostanejo zvesti določenemu področju, medtem ko del raziskovalne sfere sledi novim interesom in raziskovalnim izzivom.

Kljub temu, da se fokus raziskav s časom spreminja, ostajajo raziskovalci vezani na neko širše raziskovalno področje, ki predstavlja osnovo za formalno združevanje raziskovalcev v raziskovalne skupine. Te raziskovalcev ne vežejo k sodelovanju, ga pa vsekakor vzpodbujujo. Če poleg omenjenih vidikov vključimo še vpliv virov na znanstveno delovanje in rezultat predstavimo kot 'enotno soavtorsko omrežje,' postane jasno, da je dinamiko v omrežju težko opisati neposredno brez interakcij med vsemi dejavniki.

4.5 Stohastično modeliranje dinamike soavtorskih omrežij

Stohastične pristope k modeliranju dinamike v omrežjih smo podrobno opisali v uvodnih poglavjih disertacije. Tu se bomo s temi postopki in metodami lotili analize soavtorskih omrežij štirih disciplin. Prvi del je namenjen iskanju struktur omrežij na podlagi fizikalnih pristopov k modeliranju omrežij ‐realnega sveta,‐ v drugem delu pa se lotevamo modeliranja omrežij z uporabo stohastičnega modeliranja dinamike delovanja posameznikov v programu SIENA.

V tem delu disertacije analiziramo omrežja, definirana med letoma 1991 in 2005. Prvi del analize poteka na združenih podatkih, medtem ko modeliranje s programom SIENA poteka na podatkih, urejenih v tri zaporedna obdobja, ki si kot slike omrežja sledijo v obdobjih t_2 (1991-1995), t_3 (1996-2000) in t_4 (2001-2005), torej obdobia po osamosvojitvi Slovenije s podobno znanstveno politiko. Razlog za izločitev zgodnejšega obdobia t_1 (1986-1990), so tudi manjše skupine raziskovalcev v obravnavanih disciplinah z nestabilno omrežno strukturo, ki smo jo podrobno predstavili v prejšnjem delu poglavja (4.4). Omrežja so definirana na enak način kot v prejšnjem delu poglavja.

4.5.1 Modeliranje omrežij ‐realnega sveta‐

Pristop, ki so ga za iskanje struktur v omrežjih razvili fiziki, v fazi analize realnih podatkov težko opredelimo kot modeliranje. Pristopi namreč temeljijo na reprodukciji značilnosti realnih omrežij z uporabo stohastičnih algoritmov, kjer sta npr. v našem primeru uporabljeni modela malih sve-

tov in preferenčne izbire. Ko se lotimo analize realnih podatkov glede na določeno značilnost realnih omrežij, primerjamo značilnosti na realnih podatkih z značilnostmi slučajnih grafov, generiranih na podlagi uporabljenih modelov.

Kadar skušamo v nekem omrežju dokazati strukturo *malih svetov*, za dokaz uporabimo dve specifični omrežni lastnosti. Prva lastnost omrežja, ki se razvija po principu malih svetov, je relativno kratka povprečna razdalja med enotami v omrežju. Glede na to, da je povprečna razdalja v omrežju odvisna od velikosti in gostote omrežja in jo težko primerjamo med posameznimi realnimi omrežji, za primerjavo generiramo vrsto primerljivih slučajnih grafov, na podlagi katerih izračunamo pričakovano vrednost.

V omrežjih vseh štirih analiziranih disciplin povprečna razdalja v omrežju s časom narašča, kar je pričakovana posledica rasti omrežij. Povprečna razdalja v omrežjih v obravnavanih obdobjih (t_{2-4}) je nekaj manj kot 4, podobna v omrežjih fizikov in biotehnologov, pri matematikih je 4.4 in v omrežju sociologov 3.0. Indic za prisotnost strukture malih svetov je, kot smo opisali v poglavjih 2.4.3 in 3.2.4, povprečna razdalja, ki je nekoliko krajsa oz. podobna pričakovani povprečni razdalji v slučajnem grafu. Primerjava razdalj pokaže, da so bile te najprej nižje, potem pa so zrasle nad pričakovane vrednosti. V omrežju sociologov za 0.2, 1.1 nad pričakovano vrednost pri matematikih in 2 nad pričakovano vrednostjo pri fizikih. Pod pričakovano vrednostjo ostane le povprečna razdalja v omrežju biotehnologov. Če omrežje obravnavamo nedeljeno, za vsa tri obdobja skupaj, je razdalja visoka le v omrežju matematikov, pri fizikih ne odstopa zelo od pričakovane vrednosti, pri sociologih in biotehnologih pa je razdalja nižja od pričakovane. V omrežjih fizikov, biotehnologov in sociologov lahko torej trdimo, da je prvi indikator prisotnosti

Tabela 4.5: Strukturne lastnosti omrežij v obdobjih t_2 , t_3 , t_4 in t_{2-4}

omrežje	t_2	t_3	t_4	t_{2-4}
	1991-1995	1996-2000	2001-2005	1991-2005
fizika	št. raziskovalcev	125	183	234
	št. povezav	274	487	686
	povpr. stopnja	4.38	5.32	5.86
	povpr. razdalja	3.44	4.8	5.15
	(pričakovana razdalja*)	3.75	4.20	3.10
	koeficient grozdenja	0.461	0.473	0.492
matematika	(pričakovan k.g.*)	0.032	0.031	0.014
	št. raziskovalcev	65	96	135
	št. povezav	42	63	122
	povpr. stopnja	1.29	1.30	1.81
	povpr. razdalja	2.34	3.94	4.52
	(pričakovana razdalja*)	3.41	4.16	3.45
biotehnologija	koeficient grozdenja	0.246	0.302	0.285
	(pričakovan k.g.*)	0.047	0.044	0.073
	št. raziskovalcev	33	50	79
	št. povezav	42	58	147
	povpr. stopnja	2.47	2.32	3.72
	povpr. razdalja	2.45	2.88	3.34
sociologija	(pričakovana razdalja*)	6.62	5.39	4.36
	koeficient grozdenja	0.555	0.339	0.480
	(pričakovan k.g.*)	0.013	0.013	0.018
	št. raziskovalcev	61	88	111
	št. povezav	26	124	199
	povpr. stopnja	0.85	2.82	3.59

* Pričakovane vrednosti so izračunane na slučajnem grafu generiranem po modelu Erdős-Rényi-a z danim številom enot in povprečno stopnjo pri 10000 ponovitvah.

strukture malih svetov nesporno prisotnen. Glede na to, da rezultat matematikih nekoliko bolj odstopa od pričakovane vrednosti, ga bomo vzeli na znanje in obravnavali z rezervo.

Druga lastnost omrežja, ki opredeljuje prisotnost strukture malih svetov, je

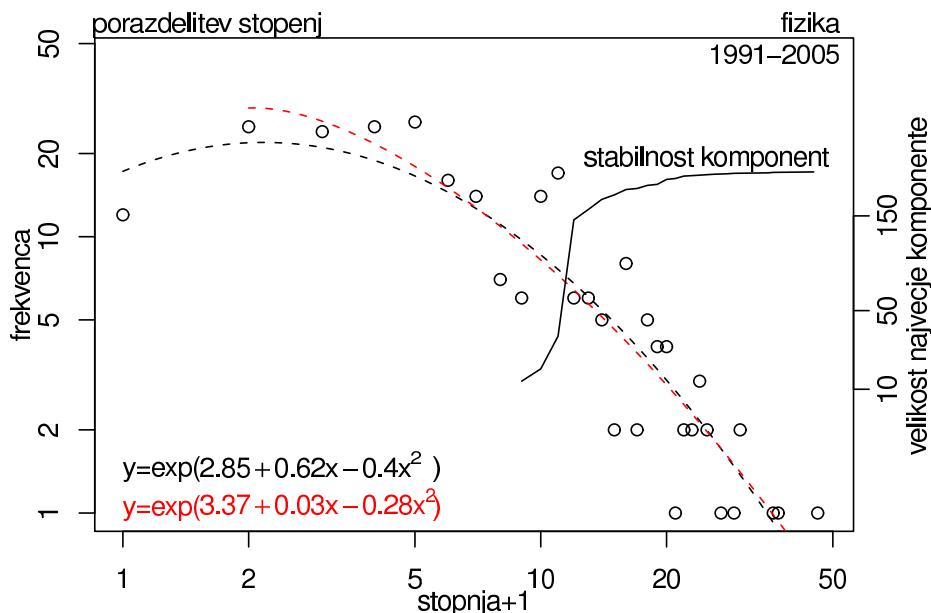
relativno visok koeficient grozdenja. Tudi to mero primerjamo s pričakovano vrednostjo v slučajnem grafu. Iz predhodnih raziskav vemo, da je na realnih podatkih koeficient grozdenja v večini primerov precej višji od pričakovane vrednosti koeficiente na primerljivem slučajnem grafu. Vrednost koeficiente je relativno visoka skozi vsa tri obravnavana obdobja v omrežjih vseh štirih disciplin. Če gledamo zgolj vrednosti za vsa tri obdobja skupaj, je vrednost koeficiente pri sociologih 0.5, pri biotehnologih in fizikih 0.44 ter pri matematikih 0.25. Primerjava teh vrednosti z rezultati nekaterih drugih raziskav omogoča bolj zanimivo interpretacijo. Moody (2004) je v raziskavi soavtorskih omrežij sociologov, generiranih iz baze člankov objavljenih v reviji *Sociological abstracts*, ugotovil, da je koeficient grozdenja pri sociologih nekje med 0.2 in 0.3. Podobno je Newman (2004) zaključil, da je koeficient v omrežju biologov 0.07, fizikov 0.36 in matematikov 0.12. Perc (2010) je pred kratkim proučeval celotno soavtorsko omrežje slovenskih raziskovalcev na osnovi baze COBISS in ugotovil, da koeficient grozdenja s časom linearno pada, tako da je imel leta 1990 vrednost 0.35, leta 2005 pa približno 0.23. Zanimivo je, da v omrežjih, ki jih analiziramo tu, vrednost koeficiente niha, ne moremo pa govoriti o urejenih padajočih trendih, ki jih opisuje Perc. Specifične lastnosti tu analiziranih omrežij so verjetno posledica dejstva, da v našem primeru analiziramo celotna popolna omrežja znanstvenih skupnosti, ki delujejo na izbranih področjih znotraj majhne države. To pomeni, da so omrežja veliko manjša od omrežij analiziranih v drugih raziskavah, omejena so na sodelovanje znotraj države, ki so močno definirana s formalno organizacijsko strukturo znanosti v državi, o kateri smo govorili že v enem prejšnjih delov tega poglavja.

Globalne lastnosti soavtorskih omrežij fizikov, matematikov, biotehnologov in sociologov kažejo na prisotnost strukture malih svetov. To pomeni, da raz-

iskovalci soavtorje iščejo med kolegi, ki so blizu njihovemu krogu sodelavcev. Glede na izračunane lastnosti je struktura pri matematikih nekoliko manj izrazita kot v omrežjih ostalih treh disciplin. Lastnosti omrežij so stabilne, spremenljajo se zgolj v skladu z rastjo omrežij.

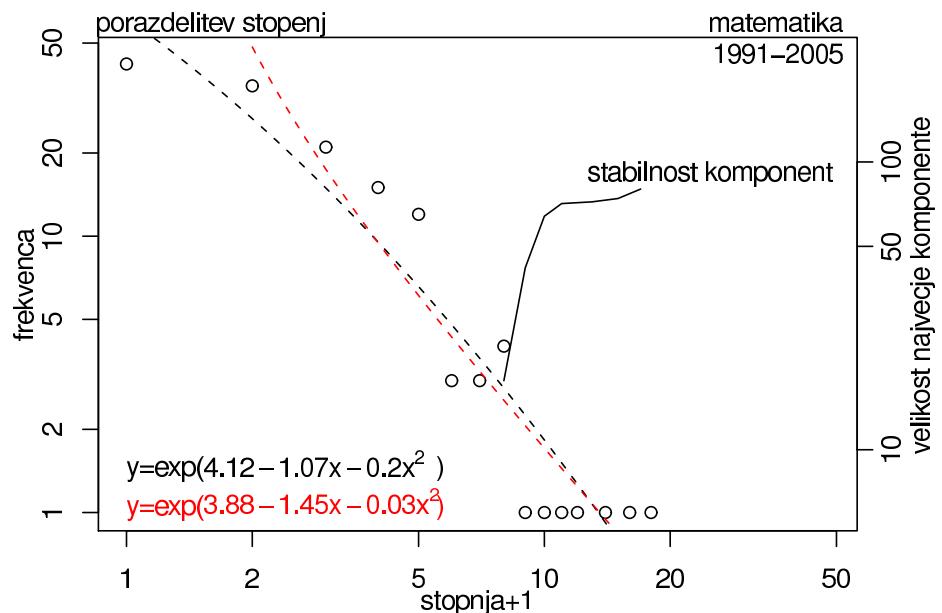
Drugi strukturni tip, katerega prisotnost pričakujemo v analiziranih omrežjih, je posledica principa preferenčne izbire. Podobno kot pri prej opisanem pristopu, se tudi pri iskanju te strukture zanašamo na globalne lastnosti omrežij. Glavni indikator za prisotnost tovrstne strukture je t.i. brezlestvična porazdelitev stopenj v omrežju. V realnosti je v omrežju glede na to strukturo zelo majhen del enot v omrežju povezan z zelo veliko drugih enot in velik del enot zgolj z nekaj drugimi enotami. Kadar porazdelitev stopenj takega *zvezdastega* omrežja predstavimo na diagramu z log-log lestvico, lahko poiščemo linearno funkcijo, katere graf se prilega podatkom.

Slika 4.29: Porazdelitev stopenj in stabilnost komponent v soavtorskem omrežju fizikov



Kot smo omenili v poglavju 2.4.3, so raziskovalci porazdelitev stopenj opisovali z različnimi funkcijami. V naši analizi smo se zgledovali po članku Moodya (2004), ki je ne povsem linearno porazdelitev opisal s kvadratno funkcijo. Bolj kot je funkcija nelinearna, močnejši so poleg preferenčne izbire drugi dejavniki, ki vplivajo na razvoj omrežja. V primeru predstavljene

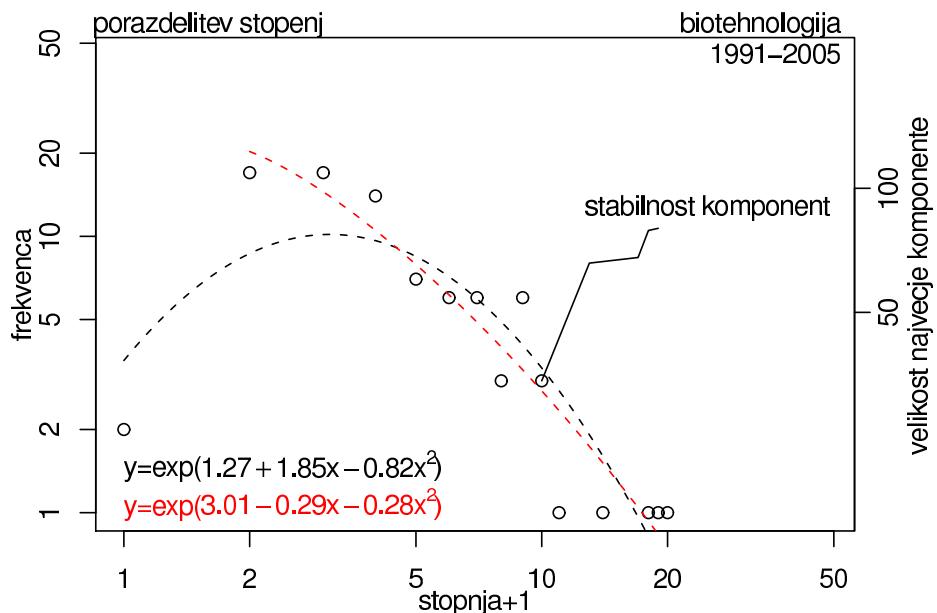
Slika 4.30: Porazdelitev stopenj in stabilnost komponent v soavtorskem omrežju matematikov



analize obstajata še dve posebnosti: v omrežjih vseh štirih disciplin je v primerjavi z drugimi raziskavami relativno veliko avtorjev, ki ne sodelujejo z nikomer oz. imajo stopnjo enako 0. Slednje je v veliki meri posledica definicije mej omrežij, v katera so vključeni raziskovalci določene discipline, v kolikor imajo v obravnavanem obdobju objavljeno vsaj eno znanstveno publikacijo. Ker analiziramo zgolj omrežje med raziskovalci obravnavane discipline, sodelovanja raziskovalcev z avtorji iz drugih disciplin, torej izven meja omrežja, nimamo zavedenega. Druga posebnost, ki je posledica prve,

je, da smo na vsakem diagramu predstavili dva grafa prileganja porazdelitvi stopenj. Prvega (črnega), pri katerem smo upoštevali avtorje s stopnjo 0 in drugega (rdečega), pri katerem jih nismo.

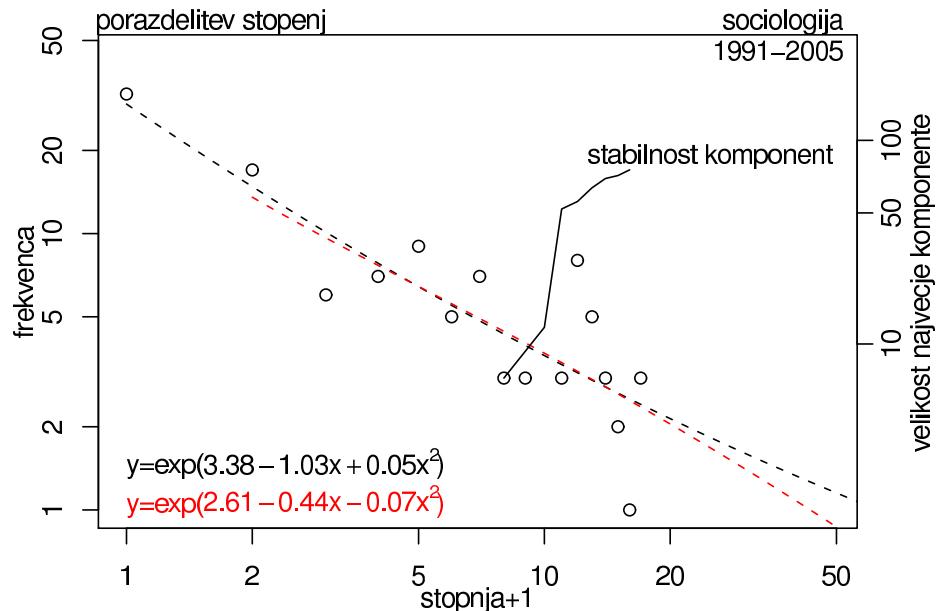
Slika 4.31: Porazdelitev stopenj in stabilnost komponent v soavtorskem omrežju biotehnologov



Prileganje funkcij porazdelitvam stopenj in njihova oblika, predstavljena v diagramih 4.5.1-4.5.1, kažejo na precejšnje razlike v prisotnosti principa preferenčne izbire pri rasti omrežja med disciplinami. Nelinearnost porazdelitve stopenj v omrežjih fizikov in biotehnologov je očitna, kar kaže na to, da v teh dveh disciplinah princip preferenčne izbire nima močnega, sploh pa ne izključnega vpliva na povezovanje raziskovalcev. V omrežjih matematikov in sociologov je linearost funkcij veliko izrazitejša, kar kaže na veliko močnejši vpliv preferenčne izbire. V omrežju sociologov se pri upoštevanju raziskovalcev brez soavtorjev porazdelitev celo usloči tako, da ima zadnji člen kvadratne funkcije pozitiven predznak, kar je glede na rezultate drugi raziskav zelo

nenavadno⁸.

Slika 4.32: Porazdelitev stopenj in stabilnost komponent v soavtorskem omrežju sociologov



Drugi indikator strukture v omrežju, ki raste po principu preferenčne izbire je nestabilnost omrežja v smislu števila komponent, kadar iz omrežja izključimo najbolj povezane enote. Vzrok te nestabilnosti je lepo viden na sliki 2.4.3 v drugem poglavju, kjer najbolj povezana enota (rdeče obarvana točka) povezuje veliko med seboj sicer povsem ločenih delov omrežja. Skratka, če omrežje povezuje najuglednejši raziskovalec, bo to omrežje razpadlo, v kolikor tega raziskovalca izločimo iz omrežja. Občutljivost omrežja je na diagramih predstavljena kot stabilnost komponent. Stabilnost merimo z velikostjo največje komponente v omrežju ob postopnem izločanju najbolj povezanih enot. Če največja komponenta ob izločitvi raziskovalca z največ povezavami v omrežju

⁸Rezultate prileganj funkcij podatkom je treba zaradi nezanesljivosti obravnavati s precejšnjo rezervo. Pri fizikih je interval zaupanja za kvadratni člen funkcije prileganja ± 0.17 , pri matematikih ± 0.41 , pri biotehnologih $\pm 0.37(\pm 0.39)$ in pri sociologih $\pm 0.38(\pm 0.42)$

ne razpade, lahko pod vprašaj postavimo hipotezo o prisotnosti strukture, vzpostavljeni z mehanizmom preferenčne izbire.

Najstabilnejše izmed štirih soavtorskih analiziranih omrežij je omrežje fizikov. Iz diagrama lahko razberemo, da omrežje fizikov razpade šele potem, ko iz njega izločimo 35 avtorjev, ki imajo 12 ali več soavtorjev. Pri matematičnih pride do razpada, ko iz omrežja izločimo 5 avtorjev z vsaj 10 soavtorji, pri biotehnologih 4 avtorje z vsaj 13 soavtorji in v omrežju sociologov 22 avtorjev, ki imajo vsaj 11 različnih soavtorjev. Iz navedenih vrednosti je razvidno, da slovenske znanstvene skupnosti analiziranih disciplin povezuje zgolj majhno število pomembnih raziskovalcev. V tem smislu še dodatno izstopata matematika in biotehnologija. Seveda je primerjava teh rezultatov praktično nemogoča z analizami drugih raziskav, kjer so analizirana precej večja omrežja od soavtorskih omrežij slovenskih raziskovalcev.

4.5.2 SIENA model

Z uporabo stohastičnega modeliranja delovanja posameznika v omrežju prehajamo od determinističnih opisov omrežij in iskanja struktur v njih k statističnim pristopom modeliranja dinamike v omrežjih s kombiniranjem različnih vplivov, ki raziskovalcu omogočajo tudi oceno dobljenih rezultatov v skladu s paradigmo statistične inference.

Modeliranje v programu SIENA poteka na osnovi podatkov o omrežjih zbranih v vsaj dveh časovnih točkah. V našem primeru smo podobno kot v prejšnjem delu poglavja analizirali omrežja štirih disciplin na podlagi treh petletnih časovnih intervalov, označenih s t_2 , t_3 in t_4 , ki se raztezajo med leti 1991 in 2005. Kot smo nakazali že v poglavju o metodah in modelih (3.2.6), bomo v model vključili različne mikro mehanizme, s katerimi bomo iz vidika delovanja posameznika opisali vzvode, ki v omrežju vzpodbujo povezovanje raziskovalcev po principu preferenčne izbire in hkrati preverili ali se posamezniki v omrežju povezujejo v skupine in tako v omrežju tvorijo strukturo malih svetov.

Oglejmo si še enkrat posamezne parametre funkcij frekvenc sprememb in optimizacijskih funkcij, s katerimi opisujemo mikro vplive, vključene v model. Prvi trije parametri, frekvenca sprememb v prehodu iz t_2 v t_3 , frekvenca sprememb v prehodu iz t_3 v t_4 in stopnja, so v model vključeni zaradi tehničnih predpostavk modela in za interpretacijo niso ključnega pomena. O njih smo več zapisali v poglavju 3.2.6. Iz prvih dveh parametrov lahko razberemo ocenjeno frekvenco sprememb v omrežjih. Ob prehodu iz t_2 v t_3 se tako v omrežju fizikov (Tabela: 4.6) v povprečju zgodi nekaj več kot 15 sprememb (vzpostavitev novih povezav oz. prekinitev obstoječih), v omrežju sociologov

12, v omrežju biotehnologov nekaj manj kot 5 in v omrežju matematikov 2.6. Ob naslednjem prehodu iz t_3 v t_4 povprečno število sprememb na raziskovalca v omrežjih matematikov in biotehnologov nekoliko naraste, medtem ko pri fizikih in sociologih pade. Vrednosti tretjega parametra (stopnja) so v vseh štirih omrežjih negativne, kar je pričakovana posledica stroškov, ki jih ima raziskovalec z vsako novo povezavo. Z drugimi besedami: raziskovalec lahko zaradi povsem fizičnih omejitev sodeluje zgolj z omejenim številom avtorjev, vsaka nova povezava pa raziskovalcu predstavlja določeno breme.

Nadalujmo z opisom mikro vplivov, katerih posledica je povezovanje v strukturo malih svetov. Četrти parameter, vpliv tranzitivnih triad, meri tendenco akterjev, da vezi v omrežju vzpostavljajo tako, da s soavtorji tvorijo zaprte trikotnike. Preverili smo, če raziskovalci nove soavtorje iščejo med soavtorji raziskovalcev, s katerimi že sodelujejo. Parameter je statistično značilen v omrežjih vseh štirih disciplin, kar je nedvomna potrditev visoke stopnje grozdenja v omrežjih, ki ga povezujemo s strukturo malih svetov.

S petim parametrom smo preverili enega izmed možnih dejavnikov, ki po našem mnenju vzpodbujujo grozdenje v omrežjih in ki se je nakazoval v analizi, predstavljeni v poglavju 4.4.4 . Gre za pripadnost isti raziskovalni skupini, ki naj bi pozitivno vplivala na vzpostavljanje novih soavtorskih povezav med raziskovalci. Parameter je statistično značilen in pozitiven v vseh štirih omrežjih, s čimer smo potrdili domnevo o močnem vplivu institucionalne organiziranosti na vzpostavljanje soavtorskih povezav med raziskovalci.

Tudi s šestim parametrom opisujemo zunanji vpliv na dogajanje v omrežju. Ta parameter smo definirali kot podobnost znanstvene starosti oz. podobnost letnice prve objave raziskovalca z raziskovalcem, s katerim bi vzpostavil novo soavtorsko vez, ki jo lahko najdemo v bibliografski zbirkici COBISS. Z

njim opisujemo vpliv znanstvene starosti na vzpostavljanje novih povezav v omrežju. Ocena parametra je statistično značilna zgolj v omrežju biotehnologov. Negativna vrednost parametra kaže na večjo verjetnost vzpostavitve povezave med dvema raziskovalcema, ki sta si starostno manj podobna. To pomeni, da ima v omrežju biotehnologov odnos mentor-študent pomemben vpliv pri vzpostavljanju novih soavtorskih povezav.

Če splenemo, strukturo malih svetov, katere obstoj v omrežjih vseh štirih disciplin smo že potrdili v prejšnjem delu poglavja, smo potrdili tudi z uporabo metode stohastičnega modeliranja dinamike v omrežjih na podlagi delovanja posameznega akterja. Tu smo ugotovili tudi, da ima v vseh obravnnavanih disciplinah na povezovanje v zaprte triade oz. na grozdenje v omrežju močan vpliv pripadnost skupni raziskovalni skupini. Poleg raziskovalne skupine v biotehnologiji na vzpostavitev novih povezav vpliva tudi znanstvena starost raziskovalca.

Tabela 4.6: Siena model za štiri znanstvene discipline

Parameters:	fizika param. n.	matematika param. n.	biotehnologija param. n.	sociologija param. n.
1. frekv. sprememb 1	15.347* (1.541)	2.599* (0.558)	4.683* (1.326)	12.176* (1.947)
2. frekv. sprememb 2	13.676* (0.986)	4.829* (0.756)	5.233* (0.807)	9.615* (1.329)
3. stopnja (gostota)	-1.765* (0.058)	-1.932* (0.120)	-1.987* (0.134)	-1.913* (0.081)
4. tranzitivne triade	0.383* (0.016)	0.403* (0.240)	0.804* (0.189)	0.519* (0.058)
5. ista razisk. skupina	0.578* (0.057)	0.428* (0.109)	1.123* (0.169)	1.264* (0.107)
6. podobna "znanstvena starost"	-0.214 (0.136)	0.174 (0.303)	-1.141* (0.372)	-0.112 (0.288)
7. sodelovanje znotraj disc.	-0.044* (0.003)	-0.011 (0.046)	0.018 (0.025)	0.003 (0.006)
8. sodelovanje izven disc.	0.004 (0.003)	0.022* (0.006)	0.010 (0.022)	-0.058* (0.007)
9. št. člankov z IF	-0.003 (0.003)	0.021 (0.022)	0.020 (0.034)	0.172* (0.061)

Druga vrsta strukture, ki smo jo opredelili z delovanjem posameznih raziskovalcev in zunanjimi dejavniki, je posledica principa preferenčne izbire. Iz vidika posamezne enote v omrežju je ideja preferenčne izbire preprosta: vzpostavitev nove povezave je bolj verjetna z raziskovalci, ki imajo višjo stopnjo, oz. večje število sodelavcev. Seveda je stopnja najvplivnejših raz-

iskovalcev v realnosti posledica zapletene kombinacije različnih dejavnikov, zaradi česar smo v poenostavljen model poleg stopnje v omrežju in števila sodelavcev izven meja omrežja vključili tudi vpliv znanstvene odličnosti oz. število člankov objavljenih v revijah, za katere je izračunan faktor vpliva (angl. impact factor).

Sedmi parameter, število sodelavcev v disciplini, je statistično značilen zgolj omrežju fizikov. Parameter ima negativen predznak kar pomeni, da v omrežju fizikov raziskovalci, ki veliko sodelujejo znotraj discipline, ne vzpostavljajo novih povezav z drugimi raziskovalci v disciplini.

Vpliv števila povezav z avtorji, ki niso del omrežja, merjen z osmim parametrom, je statistično značilen v omrežjih sociologov in matematikov. Za omrežje matematikov je parameter pozitiven, kar pomeni, da raziskovalci, ki sodelujejo z veliko različnimi avtorji izven discipline, pogosteje vzpostavljajo nove povezave tudi v disciplini. Nasprotno pri sociologih sodelovanje z raziskovalci iz drugih disciplin na sodelovanje v disciplini vpliva negativno.

Zadnji parameter, število člankov v revijah s faktorjem vpliva, kaže na to, da ima znanstvena uspešnost, merjena s številom kvalitetnih objav, pozitiven vpliv na vzpostavljanje novih povezav znotraj discipline zgolj v omrežju sociologov. Ugotovitev je na prvi pogled morda presenetljiva, vendar razumljiva, če jo interpretiramo v skladu s strukturo objav v posameznih disciplinah (glej sliko: 4.1) in pomembnostjo objav, ki jo posamezne znanstvene skupnosti pripisujejo člankom v revijah z izmerjenim faktorjem vpliva.

Pregled rezultatov, dobljenih z modeliranjem s programom SIENA, nam kaže, da raziskovalci v vseh štirih disciplinah znanstvene objave ustvarjajo s sodelavci tako, da v omrežjih ustvarjajo in ohranljajo strukturo malih svetov,

medtem ko je mehanizem preferenčne izbire bolj zapleten in močno vezan na kulturo sodelovanja znotraj posamezne znanstvene discipline:

- Fiziki, ki sodelujejo z večjim številom raziskovalcev iz lastne discipline, redko ustvarjajo nove povezave z raziskovalci iz te discipline. Slednje je lahko posledica zasičenosti s številom povezav. Glede na to, da v modelu pojasnjujemo verjetnost vzpostavitve novih povezav lahko rezultat pojasnimo tudi z ugotovitvijo iz analize, opravljene z uporabo bločnega modeliranja, da se sodelujoče skupine v času le malo spremi-njajo, saj se struktura sodelovanja organiziranega znotraj raziskovalnih laboratorijev praktično ne spreminja.
- Pri matematikih, je situacija drugačna kot v omrežju fizikov. Tu na vzpostavljanje povezav znotraj discipline pozitivno vpliva število sodelavcev, ki jih ima raziskovalec izven omrežja matične discipline. Matematiki, ki veliko sodelujejo z raziskovalci iz drugih disciplin in avtorji iz tujine, pogosto iščejo sodelavce tudi med slovenskimi matematiki.
- Na področju biotehnologije, ki je mlajša znanstvena disciplina, nobeden izmed vplivov, s katerimi smo preverjali prisotnost mehanizma preferenčne izbire, ni statistično značilen. To pomeni, da razvoj omrežja usmerjajo drugi mehanizmi. Eden takih je vsekakor grozdenje raziskovalcev podobno kot v omrežjih drugih disciplin, kjer pomembno vlogo za sodelovanje igra pripadnost isti raziskovalni skupini. Pri biotehno-logih je poleg organizacijskega vidika pomemben tudi vpliv razlike v znanstveni izkušenosti raziskovalcev, merjeni kot razlika v letih prvih objavljenih del v bibliografski zbirki COBISS. Slednje je najverjetneje posledica prisotnosti sodelovanja med mlajšimi raziskovalci in njihovimi mentorji.

- V sociologiji ima intenzivnejše sodelovanje z avtorji iz drugih disciplin oz. iz tujine, v nasprotju z matematiki, negativen vpliv na sodelovanje z raziskovalci iz matične discipline. Hkrati je sociologija edina izmed štirih obravnavanih disciplin, kjer ima število objav v revijah s faktorjem vpliva značilen pozitiven vpliv na vzpostavljanje novih povezav znotraj soavtorskega omrežja slovenskih sociologov.

Poglavlje 5

Zaključek

V doktorski disertaciji smo proučevali soavtorstvo znanstvenih objav kot eno najpomembnejših oblik sodelovanja med znanstveniki v sodobni znanosti. Za znanstvenike, ki se pojavljajo kot soavtorji določenega znanstvenega članka, monografije, poglavja v monografiji ali kakšne drugačne znanstvene objave, se smatra, da so med seboj razvili pomembno obliko sodelovanja. Zanima nas ali, v kolikšni meri in v kakšnih oblikah se skozi daljše časovno obdobje tovrstno sodelovanje v slovenski znanstveni skupnosti povečuje in kateri dejavniki vplivajo na spremembe v dinamiki sodelovanja.

V prvem delu besedila smo predstavili znanstveno sodelovanje iz perspektive sociologije znanosti. S klasifikacijo pristopov k proučevanju znanstvenega sodelovanja smo predstavili nivoje proučevanja in širok spekter raziskav obravnavane teme. Za delitev raziskav na nivoje smo uporabili tipologijo proučevanja na ravni znanstvenih disciplin, sektorjev in geografske bližine med raziskovalci, ki jo je opredelil Andrade in drugi (2009). V nadaljevanju smo predstavili razvoj metodoloških pristopov za prikaz in analizo di-

namike v omrežjih sodelovanj s poudarkom na analizi soavtorskih omrežij v znanosti. Pristope smo predstavili po vrsti od enostavnih statičnih opisov strukturnih značilnosti omrežij in prikazov gibanj strukture znanstvenega sodelovanja s časovnimi vrstami do diskretnih prikazov z bločnimi modeli omrežij v povezavi z zunanjimi spremenljivkami. Na koncu smo se posvetili še dinamiki znanstvenega sodelovanja z uporabo stohastičnega modeliranja na podlagi delovanja akterjev. Del besedila je namenjen razvoju analize socijalnih omrežij s poudarkom na omrežni dinamiki kot samostojne znanstvene vede.

V drugem delu smo operacionalizirali spremenljivke ter predstavili metode in modele, uporabljene za preverjanje hipotez. Sodelovanje med raziskovalci je v disertaciji konceptualizirano kot socialno omrežje in operacionalizirano s pomočjo soavtorstev. Znanstveniki v tem kooperativnem omrežju nastopajo kot vozlišča, med katerimi se vzpostavlja vezi sodelovanja. Vsako soavtorstvo oziroma skupna udeležba pri dogodku, ki ga predstavlja znanstveno delo, se smatra kot vez med dvema posameznikoma. Na dinamiko v omrežju vplivajo notranji dejavniki, ki so lastnosti omrežja, in zunanji dejavniki, ki predstavljajo osebne lastnosti akterjev v omrežju in jih merimo kot klasične spremenljivke.

Empirični del disertacije je namenjen predstavitvi podatkov, njihovi analizi in modeliranju. Proučevanje vzorcev znanstvenega sodelovanja v disertaciji smo omejili na štiri znanstvene discipline: biotehnologijo, matematiko, fiziko in sociologijo. Obravnavali smo vzorce sodelovanja med znanstveniki v Sloveniji med letoma 1986 in 2005. V tem času je v slovenskem prostoru prišlo do velikih družbenih in institucionalnih sprememb, kot tudi sprememb v vsebini in izvajanju znanstvene politike. Analize predstavljajo pomemben vpogled

v strukturo sodelovanja v slovenskem sistemu znanosti in znanosti nasploh, saj so opravljene na celotni populaciji raziskovalcev obravnavanih disciplin.

Soavtorska omrežja smo obravnavali s širokim spektrom metod, razvitih za proučevanje dinamike v omrežjih. Z različnimi pristopi smo sledili ciljem, ki smo si jih zastavili v teoretičnem delu, predstavili značilnosti sodelovanja raziskovalcev štirih disciplin ter jih med seboj primerjali.

Glavne ugotovitve analize

V nadaljevanju podajamo glavne ugotovitve obsežne analize bibliografskih podatkov slovenskih raziskovalcev in njihovih soavtorskih omrežij.

Število soavtorskih objav skladno s pričakovanji narašča hitreje kot število samostojnih objav.

Tipi znanstvenih objav se med posameznimi disciplinami močno razlikujejo. V naravoslovnih vedah raziskovalci rezultate znanstvenega delovanja najpogosteje objavljamajo v obliki izvirnih znanstvenih člankov v tujih revijah, uvrščenih na seznam revij z izračunanim faktorjem vpliva. Pri sociologih pa je najpogosteje objavljanje v slovenskem jeziku, torej domačih znanstvenih revijah. Sociologi od ostalih disciplin odstopajo tudi po objavah poglavij v monografijah in celotnih monografij, prav tako predvsem v slovenskem jeziku. Med drugimi posebnostmi velja omeniti še visok delež objav kratkih znanstvenih prispevkov pri matematikih, visok delež znanstvenih prispevkov na konferencah pri biotehnologih in objavljanje znanstvenih zbirk podatkov ali korpusov pri sociologih.

Ugotovili smo, da obstajajo konkretne razlike med znanstvenim sodelovanjem

raziskovalcev po disciplinah. Kultura in posledično struktura sodelovanja nista neposredno odvisni od delitve disciplin na naravoslovne in družboslovne, temveč od oblike raziskovalnega procesa in organizacije raziskovalnega dela, vezanega npr. na raziskovalno opremo in raziskovalno okolje. Discipline lahko glede na strukturo znanstvenega sodelovanja delimo na laboratorijske (ang. LAB) in pisarniške (ang. OFFICE). Če to delitev povežemo s Hargensovo klasifikacijo disciplin glede na funkcionalno in normativno integracijo (Hargens, 1975), lahko trdimo, da je v disciplinah z visoko stopnjo tako funkcionalne kot normativne integracije sodelovanje veliko bolj podrejeno organizacijski strukturi kot v drugih disciplinah.

Z bločnim modeliranjem smo v vseh disciplinah ugotovili prisotnost strukture center-periferija, ki se izoblikuje glede na stopnjo razvitosti znanstvene discipline v različnih obdobjih. Pri tem ne gre za tipično strukturo center-periferija, kakršno je opisal Wallerstein (1974), saj obsegata več navznoter močno povezanih centrov, semi-periferijo raziskovalcev, ki znotraj discipline sodelujejo manj strukturirano, in periferijo raziskovalcev, ki objavlja samostojno ali sodelujejo zgolj z avtorji iz drugih disciplin oz. tujine. Poleg večih centrov v bločnih modelih se občasno pojavljajo tudi posebne povezovalne strukture, ki povezujejo dve ali več močno povezanih (centralnih) skupin raziskovalcev.

Z novo razvitim pristopom sledenja dinamiki bločnega modeliranja smo prišli do sklepa, da je struktura sodelovanja v laboratorijskih disciplinah stabilnejša od strukture sodelovanja v kabinetnih disciplinah, kjer raziskovalci pogosteje objavlja samostojno.

Glede na ideji strukture malih svetov (Watts in Strogatz, 1998) v omrežjih in preferenčne izbire (Barabási, 2002) pri rasti omrežja lahko trdimo, da

je struktura malih svetov v omrežjih slovenskih raziskovalcev zelo prisotna. Strukturo malih svetov, ki je posledica povezovanja raziskovalcev v zaprte trikotnike, najdemo v vseh analiziranih disciplinah. Z uporabo modeliranja s programom SIENA smo ugotovili, da na sodelovanje v vseh disciplinah močno pozitivno vpliva formalna organizacijska struktura raziskovalnih skupin. Poleg tega je (edino) v biotehnologiji značilno prisotno povezovanje med (znanstveno) starejšimi in mlajšimi raziskovalci, najverjetneje v odnosu mentor–raziskovalec. Rast omrežja po principu preferenčne izbire poteka tako, da se raziskovalci, ki postanejo del omrežja, bolj verjetno povežejo z vplivnejšimi in bolje povezanimi raziskovalci, ki so že del omrežja. Strukturo, ki je posledica take rasti, smo z Barabásijevo metodo potrdili v omrežjih matematikov in sociologov, kar zopet potrjuje večkrat omenjeno domnevo o delitvi disciplin na laboratorijske in pisarniške. Ustrezno opredeljen stohastični model je razkril različne oblike principa preferenčne izbire. V omrežju matematikov na vzpostavljanje novih povezav znotraj discipline pozitivno vpliva število povezav z raziskovalci, ki niso del slovenske matematične skupnosti. Nasprotno ima intenzivno sodelovanje izven discipline pri sociologih negativen vpliv na vzpostavljanje novih povezav znotraj discipline, kar je v nasprotju z idejo preferenčne izbire na ravni slovenske socioološke skupnosti. Princip preferenčne izbira se pri sociologih potrjuje s pozitivnim vplivom števila člankov, objavljenih v revijah z izračunanim faktorjem vpliva, ki vzpodbuja sodelovanje sociologov z drugimi raziskovalci iz discipline. Ugotovitev, da preferenčna izbira v omrežjih fizikov in biotehnologov ni prisotna, se je pri fizikih potrdila z negativnim vplivom intenzivnejšega sodelovanja znotraj discipline na vzpostavljanje novih povezav v disciplini in pri biotehnologih z neznačilnimi vsemi vplivi, vključenimi v model. Odsotnost preferenčne izbire v omrežjih laboratorijskih disciplin lahko pojasnimo z zaključeno organizacijsko struk-

turo in visoko stopnjo integracije raziskovalcev, ki onemogoča prosto izbiro sodelavcev za znanstveno sodelovanje in možnost vzpostavitev novih soavtorskih povezav.

Na tem mestu velja za konec, poleg predstavljenih dejavnikov vzpodbujanja oz. zaviranja sodelovanja raziskovalcev, omeniti tudi nekaj negativnih plati takšnega sodelovanja. Prva je strošek sodelovanja raziskovalcev med samim procesom raziskovanja zaradi usklajevanja različnih mnenj, pa tudi strošek pri vrednotenju znanstvenega dela. Ob objavi se namreč znanstveni doprinos, tako v obliki simbolnega ugleda, kot morebitnega točkovana za potrebe ocenjevanja znanstvene uspešnosti, razdeli med vse avtorje. Drugi pomemben negativni vidik izhaja iz sprejemanja odgovornosti za objavljene rezultate in lahko nastopi ob pojavu nezaupanja med sodelujočimi raziskovalci. Dodaten pomislek je v svojem delu izpostavil Wray (2006) z ocenjevanjem doprinsa posameznikov pri znanstvenem ustvarjanju v večjih skupinah. Wray je nižjoraven motivacije raziskovalcev povezal s skrivanjem "za skupino".

Negativne vidike znanstvenega sodelovanja največkrat povezujemo z osebnim dojemanjem situacije posameznega raziskovalca, česar v disertaciji nismo obravnavali, saj smo analize izvedli na podatkih iz administrativnih virov. Proučevanje motivov in osebnih pogledov na izkušnje s sodelovanjem bo zagotovo vključeno v katero izmed prihodnjih raziskav.

Znanstveni doprinos

Najpomembnejši znanstveni doprinos doktorske disertacije je podrobna analiza strukture znanstvenega sodelovanja po posameznih disciplinah in primerjava med njimi v slovenski znanstveni skupnosti. Uporabljena vira podatkov,

bibliografski sistem COBISS in sistem SICRIS, ki sta v svetovnem merilu edinstven vir podatkov o znanstvenem sistemu celotne države, ostajata z vidika analize znanstvenega delovanja slovenskih raziskovalcev vse premalo izkoriščena. Raziskava, poleg raziskave Perca (2010), ki obravnava vse discipline skupaj in se osredotoča zgolj na iskanje struktur z uporabo "fizikalnih" modelov, je tako prva poglobljena analiza dinamike znanstvenega sodelovanja v Sloveniji skozi daljše časovno obdobje.

Z metodološkega vidika je ključna novost nadgradnja metode posplošenega bločnega modeliranja s sledenjem posameznih enot znotraj bločnih modelov v zaporednih časovnih intervalih, kar omogoča spremeljanje dinamike v strukturi omrežja skozi daljše časovno obdobje.

Drugi pomemben metodološki rezultat disertacije je izvirna uporaba stohastičnega modeliranja dinamike v omrežjih s programom SIENA. Glede na dostopne vire gre za prvo obširnejšo uporabo tovrstnega modeliranja na neusmerjenih omrežjih, vsekakor pa prvo modeliranje popolnih soavtorskih omrežij disciplin celotne države.

Nadaljnje raziskave

Z obsežnimi analizami dinamike soavtorskih omrežij slovenskih raziskovalcev, predstavljenimi v disertaciji, smo odgovorili na večino zastavljenih vprašanj iz teoretičnega dela naloge. Hkrati so se odprle številne nove ideje in možnosti nadaljnjega raziskovanja.

Samoumevna se zdi ideja o nadaljevanju študija dinamike, saj je od zajema podatkov za predstavljeno raziskavo preteklo že več kot pet let. Poleg časovne

razširitve, je smiselna razširitev števila obravnavanih znanstvenih disciplin in primerjava med njimi, kar bi omogočilo veliko zanesljivejše sklepe o strukturi in dinamiki znotraj disciplin in med disciplinami na nivoju celotne države. Poleg sodelovanja med disciplinami dostopne podatkovne zbirke omogočajo tudi analizo med posameznimi sektorji.

V disertaciji smo se ukvarjali predvsem s strukturnimi lastnostmi omrežij in dejavniki iz okolja, ki vplivajo na znanstveno sodelovanje. Pomemben vidik tega sodelovanja pa so seveda tudi osebni, kognitivni in motivacijski dejavniki, ki dajejo nov vpogled v znanstveno sodelovanje iz perspektive vrednot.

Poglavlje 6

Literatura

- Albert, Reka in Albert-László Barabási. 2001. Statistical mechanics of complex networks. *Reviews of Modern Physics* 74 (1): 47–97. doi: 10.1103/RevModPhys.74.47.
- Allison, Paul D., J. Scott Long in Tad K. Krauze. 1982. Cumulative Advantage and Inequality in Science. *American Sociological Review* 47 (5): 615–625.
- Andrade, Helga B., Ernesto de los Reyes Lopez in Tomas B. Martin. 2009. Dimensions of scientific collaboration and its contribution to the academic research groups' scientific quality. *Research Evaluation* 18 (4): 301–311. doi:10.3152/095820209X451041.
- ARRS. 2010. Raziskovalne vede, področja in podpodročja (klasifikacija ARRS).
- Babchuk, N, B Keith in G Peters. 1999. Collaboration in sociology and other scientific disciplines. *The American Sociologist* 30: 5–21.
- Bala, Venkatesh in Sanjeev Goyal. 2000. A Noncooperative Model of Network Formation. *Econometrica* 68 (5): 1181–1229.
- Barabási, Albert-László. 2002. *Linked: The New Science of Networks*. Basic Books, 1st izd..
- Barabási, Albert-László in Reka Albert. 1999. Emergence of scaling in random networks. *Science* 286: 509–512.
- Barabási, Albert-László, Hawoong Jeong, Z. Neda, E. Ravasz, Andreas Schubert in T. Vicsek. 2002. Evolution of the social network of scientific collaborations. *Physica A: Statistical Mechanics and its Applications* 311 (3-4): 590–614.

- Batagelj, Vladimir, Patrick Doreian in Anuška Ferligoj. 1992a. An optimizational approach to regular equivalence. *Social Networks* 14: 121–135.
- Batagelj, Vladimir, Anuška Ferligoj in Patrick Doreian. 1992b. Direct and indirect methods for structural equivalence. *Social Networks* 14: 63–90.
- . 1998. Fitting to pre-specified blockmodels. V *Classification and Related Methods*, ur. N. Hayashi, K. Jajima, H.H. Bock in Y. Baba, 199–206. Berlin: Springer.
- Batagelj, Vladimir in Andrej Mrvar. 2010. *Pajek - Analysis and Visualization of Large Networks (Reference manual)*, 1.27 izd..
- Bayer, Alan E. in John C. Smart. 1991. Career Publication Patterns and Collaborative “Styles” in American Academic Science. *The Journal of Higher Education* 62 (6): 613–636.
- Beaver, Donald in Richard Rosen. 1978. Studies in scientific collaboration - Part I. The professional Origins of Scientific Co-Authorship. *Scientometrics* 1 (1): 65–84. doi:10.1007/BF02016840.
- . 1979a. Studies in scientific collaboration - Part II. Scientific co-authorship, research productivity and visibility in the French scientific elite, 1799–1830. *Scientometrics* 1 (2): 133–149. doi:10.1007/BF02016966.
- . 1979b. Studies in scientific collaboration - Part III. Professionalization and the natural history of modern scientific co-authorship. *Scientometrics* 1 (3): 231–245. doi:10.1007/BF02016308.
- Berg, Christian. 2004. *Vernetzung als Syndrom. Risiken und Chancen von Vernetzungsprozessen fuer eine nachhaltige Entwicklung*. Frankfurt/New York: Campus Verlag.
- Bonacich, Phillip. 2004. The Invasion of the Physicists. *Social Networks* 26 (3): 285–288. doi:DOI:10.1016/j.socnet.2004.06.002.
- Bordons, Maria, Fernanda Morillo in Isabel Gómez. 2004. Analysis of Cross-Disciplinary Research Through Bibliometric Tools. V *Handbook of Quantitative Science and Technology Research*, ur. Henk Moed, Wolfgang Glänzel in Ulrich Schmoch, 437–456. Springer Netherlands. doi: 10.1007/1-4020-2755-9\20.
- Braun, Tibor in Andreas Schubert. 2003. A quantitative view on the coming of age of interdisciplinarity in the sciences 1980-1999. *Scientometrics* 58 (1): 183–189. doi:10.1023/A:1025439910278.
- Bucchi, Massimiano. 2004. *Science In Society. An Introduction to Social Studies of Science*. London and New York: Routledge.

- Burt, Ronald S. 2004. Structural Holes and Good Ideas. *The American Journal of Sociology* 110 (2): 349–399.
- Buter, Reindert K., Noyons in Anthony F. J. van Raan. 2010. Identification of converging research areas using publication and citation data. *Research Evaluation* 19 (1): 19–27. doi:10.3152/095820210X492503.
- Cole, Stephen in Jonathan R Cole. 1973. *Social Stratification in Science*. Chicago, Illinois: The University of Chicago Press.
- Coleman, James S. 1964. *An Introduction to Mathematical Sociology*. Free Press.
- Crane, Diana. 1972. *Invisible colleges: Diffusion of knowledge in scientific communities*. Chicago: University of Chicago Press.
- Cronin, B. 2001. Hyperauthorship: a postmodern perversion or evidence of a structural shift in scholarly communication practices? *Journal of the American Society for Information Science and Technology* 52 (7): 558–569. doi:10.1002/asi.1097.abs.
- Cullen, Bradley T. in Michael Pretes. 2000. The meaning of marginality: Interpretations and perceptions in social science. *The Social Science Journal* 37 (2): 215–229. doi:DOI:10.1016/S0362-3319(00)00056-2.
- Davidson, Jörn, Holger Ebel in Stefan Bornholdt. 2002. Emergence of a Small World from Local Interactions: Modeling Acquaintance Networks. *Phys Rev Lett* 88 (12): 128701. doi:10.1103/PhysRevLett.88.128701.
- De Haan, J. 1997. Authorship patterns in Dutch sociology. *Scientometrics* 39 (2): 197–208. doi:10.1007/BF02457448.
- de Lange, Cornelius in Wolfgang Glänzel. 1997. Modelling and measuring multilateral co-authorship in international scientific collaboration. Part I. Development of a new model using a series expansion approach. *Scientometrics* 40 (3): 593–604–604. doi:10.1007/BF02459303.
- de Nooy, Wouter, Andrej Mrvar in Vladimir Batagelj. 2005. *Exploratory Social Network Analysis with Pajek*. Cambridge: Cambridge University Press.
- de Sola Pool, Ithiel in Manfred Kochen. 1978. Contacts and influence. *Social Networks* 1 (1): 5–51. doi:10.1016/0378-8733(78)90011-4.
- Demšar, Franci in Stojan Sorčan. 2007. Znanstvene objave v slovenskem in tujem jezik. *Jezik in slovstvo* 52 (5).
- Doreian, Patrick, Vladimir Batagelj in Anuška Ferligo. 2005. *Generalized Blockmodeling*. Cambridge University Press, Cambridge.

- Doreian, Patrick in Tom A.B. Snijders. 2010. Introduction to the special issue on network dynamics. *Social Networks* 32 (1): 1–3.
- Doreian, Patrick in Frans N. Stokman, ur.. 1997. *Evolution of social networks*. Routledge.
- Durkheim, Emile. 1947. *The Division of Labor in Society*. Glencoe, IL.: Free Press.
- Erdős, P. in A. Rényi. 1959. On random graphs, I. *Publicationes Mathematicae (Debrecen)* 6: 290–297.
- Erjavec, Tomaž, Camelia Ignat, Bruno Pouliquen in Ralf Steinberger. 2005. Massive multi-lingual corpus compilation: Acquis Communautaire and totale. V *Proceedings of the 2nd Language & Technology Conference, Poznan, Poland*, 32–36.
- Erten, Cesim, Philip J. Harding, Stephen G. Kobourov, Kevin Wampler in Gary Yee. 2004. GraphAEL: Graph Animations with Evolving Layouts. V *Graph Drawing*, ur. Giuseppe Liotta, knj. 2912 zbirke *Lecture Notes in Computer Science*, 98–110. Springer Berlin / Heidelberg. 10.1007/978-3-540-24595-7_9.
- Etzkowitz, Henry in Loet Leydesdorff. 2001. Universities in the Global Knowledge Economy. V *Universities and the Global Knowledge Economy. A Triple Helix of University – Industry – Government Relations.*, ur. Henry Etzkowitz in Loet Leydesdorff, 1–11. Continuum.
- Ferligoj, Anuška. 1989. Razvrščanje v skupine. V *Metodološki Zvezki*, knj. 4. Ljubljana: FSPN.
- Ferligoj, Anuška, Patrick Doreian in Vladimir Batagelj. 2011. Positions and roles. V *Sage Handbook of Social Network Analysis*, ur. John Scott in Peter Carrington. Sage, London.
- Ferligoj, Anuška in Luka Kronegger. 2009. Clustering of Attribute and/or Relational Data. *Metodološki Zvezki (Advances in Methodology and Statistics)* 6 (2): 135–153.
- Fienberg, Stephen E., Michael M. Meyer in Stanley Wasserman. 1985. Statistical Analysis of Multiple Sociometric Relations. *Journal of the American Statistical Association* 80 (389): 51–67. doi:10.2307/2288040.
- Fienberg, Stephen E. in Stanley Wasserman. 1981. Categorical data analysis of single sociometric relations. V *Sociological Methodology*, ur. Stephen E. Fienberg, 156–192. Jossey-Brass, San Francisco.

- Forsythe, G. E., M. A. Malcolm in C. B. Moler. 1979. Computer Methods for Mathematical Computations. *Journal of applied Mathematics and Mechanics* 59 (2): 141–142.
- Frank, O. 1991. Statistical analysis of change in networks. *Statistica Nederländica* 45 (3): 283–293.
- Frank, O. in D. Strauss. 1986. Markov graphs. *Journal of the American Statistical Association* 81: 832–842.
- Freeman, L. C. 2004. *The Development of Social Network Analysis: A Study in the Sociology of Science*. Empirical Press.
- Gansner, Emden R., Yehuda Koren in Stephen C. North. 2004. Graph Drawing by Stress Majorization. V *Graph Drawing*, 239–250.
- Garfield, Eugene. 1955. Citation Indexes for Science. *Science* 122: 108–111.
- Garfield, Eugene in Robert K. Merton. 1979. *Citation indexing: Its theory and application in science, technology, and humanities*. Wiley, New York.
- Georghiou, Luke. 1998. Global cooperation in research. *Research Policy* 27 (6): 611–626. doi:DOI:10.1016/S0048-7333(98)00054-7.
- Gibbons, Michael, Helga Nowotny in Peter Scott. 1994. *The New Production of Knowledge. The Dynamics of Science and Research in Contemporary Societies*. London: Sage Publications.
- Glänzel, Wolfgang in Cornelius de Lange. 2002. A distributional approach to multinationality measures of international scientific collaboration. *Scientometrics* 54 (1): 75–89. doi:10.1023/A:1015684505035.
- Glänzel, Wolfgang in Andreas Schubert. 2004. Analysing scientific networks through co-authorship. V *Handbook of Quantitative Science and Technology Research. The Use of Publication and Patent Statistics in Studies of S&T Systems.*, ur. Henk F. Moed, 257–276. Kluwer Academic Publishers.
- . 2005. Domesticity and internationality in co-authorship, references and citations. *Scientometrics* 65 (3): 323–342. doi:10.1007/s11192-005-0277-0.
- Glänzel, Wolfgang, Andreas Schubert in C Hans-Jürgen. 1999. A bibliometric analysis of international scientific cooperation of the European Union (1985-1995). *Scientometrics* 45: 185–202.
- Goldstein, Michel L., Steven A. Morris in Gary G. Yen. 2004. A Group-Based Yule Model for Bipartite Author-Paper Networks.

- Gómez, Isabel, María Teresa Fernández in Jesús Sebastián. 1999. Analysis of the structure of international scientific ooperation networks through bibliometric indicators. *Scientometrics* 44 (3): 441–457.
- Gossart, Céderic in Müge Ozman. 2009. Co-authorship networks in social sciences: The case of Turkey. *Scientometrics* 78 (2): 323–345.
- Granovetter, Mark S. 1973. The Strength of Weak Ties. *The American Journal of Sociology* 78 (6): 1360–1380. doi:10.2307/2776392.
- Hagstrom, W. 1965. *The Scientific Community*. New York: Basic Books.
- Han, S.K. 2003. Tribal regimes in academia: a comparative analysis of market structure across disciplines. *Social networks* 25 (3): 251–280.
- Handcock, M. S., D. R. Hunter, C. T. Butts, S. M. Goodreau in M. Morris. 2003. Statnet: An R package for the Statistical Modeling of Social Networks.
- Hargens, Lowell L. 1975. *Patterns of scientific research*. American Sociological Associa.
- Havemann, Frank, Michael Heinz in Hildrun Kretschmer. 2006. Collaboration and distances between German immunological institutes – a trend analysis. *Journal of Biomedical Discovery and Collaboration* 1 (6).
- Heffner, A. 1981. Funded research, multiple authorship, and subauthorship collaboration in four disciplines. *Scientometrics* 3 (1): 5–12. doi:10.1007/BF02021860.
- Holland, Paul W. in Samuel Leinhardt. 1975. Local structure in social networks. V *Sociological Methodology*, ur. D.R. Heise, knj. 76. Jossey-Brass, San Francisco.
- . 1977. A DYNAMIC MODEL FOR SOCIAL NETWORKS. *Journal of Mathematical Sociology* 5 (1): 5–20.
- . 1981. An exponential family of probability distributions for directed graphs. *Journal of the American Statistical Association* 76: 33–50.
- Hornbostel, S. 1997. *Bewertungen in der Wissenschaft*. Wissenschaftsindikatoren. Opladen, Germany: Westdeutscher Verlag.
- Hummon, Norman P. 2000. Utility and dynamic social networks. *Social Networks* 22 (3): 221–249. doi:10.1016/S0378-8733(00)00024-1.
- Hummon, Norman P. in Kathleen Carley. 1993. Social networks as normal science. *Social Networks* 15 (1): 71–106. doi:DOI:10.1016/0378-8733(93)90022-D.

- Hummon, Norman P. in Patrick Doreian. 1989. Connectivity in a citation network: The development of DNA theory. *Social Networks* 11 (1): 39–63. doi:DOI:10.1016/0378-8733(89)90017-8.
- . 1990. Computational methods for social network analysis. *Social Networks* 12 (4): 273–288. doi:DOI:10.1016/0378-8733(90)90011-W.
- Hwang, Kumju. 2008. International Collaboration in Multilayered Center-Periphery in the Globalization of Science and Technology. *Science, Technology & Human Values* 33 (1): 101–133. doi:10.1177/0162243907306196.
- Jha, Yamini in Eric W. Welch. 2010. Relational mechanisms governing multifaceted collaborative behavior of academic scientists in six fields of science and engineering. *Research Policy* 39 (9): 1174–1184. doi:DOI:10.1016/j.respol.2010.06.003.
- Jin, Emily M., Michelle Girvan in M. E. J. Newman. 2001. Structure of growing social networks. *Physical Review E* 64 (4): 046132+. doi:10.1103/PhysRevE.64.046132.
- Kajnč, Sabina, ur.. 2009. *Cases of Science-industry Cooperation in Slovenian Food and Chemical Industries*, Analize CMO / CIR Analyses. Faculty of Social Sciences, Založba FDV.
- Katz, J. Sylvan. 1994. Geographical proximity and scientific collaboration. *Scientometrics* 31 (1): 31–43. doi:10.1007/BF02018100.
- Katz, J. Sylvan in Ben R. Martin. 1997. What is research collaboration? *Research policy* 26: 1–18.
- Katz, Leo in Charles Proctor. 1959. The concept of configuration of interpersonal relations in a group as a time-dependent stochastic process. *Psychometrika* 24 (4): 317–327. doi:10.1007/BF02289814.
- Kejžar, Nataša. 2007. Evolution of networks. Ph.D. thesis, University of Ljubljana, Faculty of Mathematics and Physics.
- Kronegger, Luka, Anuška Ferligoj in Patrick Doreian. 2011. On the dynamics of national scientific systems. *Quality & Quantity* 1–27. 10.1007/s11135-011-9484-3.
- Kuhn, Michael in Doris Weidemann, ur.. 2010. *Internationalization of the Social Sciences*. transcript Verlag, Bielefeld.
- Kuhn, Thomas S. 1996. *The Structure of Scientific Revolutions*. Chicago: University Of Chicago Press, 3rd izd..
- Laband, David N. in Robert D. Tollison. 2000. Intellectual Collaboration. *Journal of Political Economy* 108 (3): 632–662. doi:10.1086/262132.

- Latapy, Matthieu, Clémence Magnien in Nathalie Del Vecchio. 2008. Basic notions for the analysis of large two-mode networks. *Social Networks* 30 (1): 31–48. doi:DOI:10.1016/j.socnet.2007.04.006.
- Laudel, Grit. 2001. Collaboration, creativity and rewards: why and how scientists collaborate. *International Journal of Technology Management* 22: 762–781.
- . 2002. What do we measure by co-authorship? *Research Evaluation* 11 (1): 3–15.
- Lazega, Emmanuel, Sarai Sapulete in Lise Mounier. 2011. Structural stability regardless of membership turnover? The added value of blockmodelling in the analysis of network evolution. *Quality & Quantity* 45 (1): 129–144. doi:10.1007/s11135-009-9295-y.
- Leahy, Erin in Ryan C. Reikowsky. 2008. Research Specialization and Collaboration Patterns in Sociology. *Social Studies of Science* 38 (3): 425–440. doi:10.1177/0306312707086190.
- Leenders, R. Th. A. J. 1995. Models for network dynamics: A Markovian framework. *Journal of Mathematical Sociology* 20: 1–21.
- Leydesdorff, Loet. 1991. The static and dynamic analysis of network data using information theory. *Social Networks* 13 (4): 301–345. doi:DOI:10.1016/0378-8733(91)90001-A.
- . 2010. Eugene Garfield and Algorithmic Historiography: Co-Words, Co-Authors, and Journal Names. *Annals of Library and Information Studies* 57 (3): 248–260.
- Leydesdorff, Loet in T. Schank. 2008. Dynamic animations of journal maps: Indicators of structural changes and interdisciplinary developments. *Journal of the American Society for Information Science and Technology* 59 (11): 1532–2890.
- Li, Menghui, Jinshan Wu, Dahui Wang, Tao Zhou, Zengru Di in Ying Fan. 2005. Evolving Model of Weighted Networks Inspired by Scientific Collaboration Networks.
- Lorrain, Franois in Harrison C. White. 1971. Structural equivalence of individuals in social networks. *The Journal of Mathematical Sociology* 1 (1): 49–80.
- Lowrie, Anthony in Phillip J. McKnight. 2004. Academic Research Networks:: A Key to Enhancing Scholarly Standing. *European Management Journal* 22 (4): 345–360. doi:DOI:10.1016/j.emj.2004.06.011.

- Mali, Franc. 2002. Sodelovanje med akademsko raziskovalno sfero in industrijo kot dejavnik družbenega in ekonomskega razvoja. *Teorija in Praksa* 39 (3): 305–320.
- Mali, Franc, Luka Kronegger, Patrick Doreian in Anuška Ferligoj. 2011. Dynamic scientific co-authorship networks. V *Modeling Science*, ur. Katy Börner in Andrea Scharnhorst, (v tisku). Springer.
- Mali, Franc, Luka Kronegger in Anuška Ferligoj. 2010. Co-authorship trends and collaboration patterns in the Slovenian sociological community. *Corvinus Journal of Sociology and Social Policy (CJSSP)* 1 (2).
- Marsden, Peter V. 1990. Network Data and Measurement. *Annual Review of Sociology* 16: 435–463.
- Marshakova-Shaikevich, Irina. 2006. Scientific collaboration of new 10 EU countries in the field of social sciences. *Information Processing & Management* 42 (6): 1592–1598. doi:DOI:10.1016/j.ipm.2006.03.023. Special Issue on Informetrics.
- Marsili, Matteo, Fernando Vega-Redondo in František Slanina. 2004. The rise and fall of a networked society: A formal model. *Proceedings of the National Academy of Sciences of the United States of America* 101 (6): 1439–1442. doi:10.1073/pnas.0305684101.
- Matthew, David. 2005. *Science in Society*. New York: Palgrave.
- Mattison, Pauline, Patrice Laget, Anna Nilsson in Carl-Johann Sundberg. 2008. Intra-EU vs. extra-EU scientific co-publication patterns in EU. *Scientometrics* 75 (3): 555–574.
- Mayer, T. 1984. Parties and networks: stochastic methods for relationship networks. *Journal of Mathematical Sociology* 10: 51–103.
- Meadows, A.J. in J.G. O'Connor. 1971. Bibliographical Statistics as a Guide To Growth Points in Science. *Social Studies of Science* 1: 95–99.
- Melin, Göran in Olle Persson. 1996. Studying research collaboration using co-authorship. *Scientometrics* 36 (3): 363–377.
- Merton, Robert K. 1968. The Matthew Effect in Science. *Science* 159: 56–63.
- . 1973. *Sociology of Science*. Chicago: Chicago University Press.
- Miholič, Petruša. 2005. Znanstveno publiciranje v slovenskem prostoru. *Zdravstveni vestnik* 74: 103–106.
- Mlinar, Zdravko. 1994. Deterritorialization and re-territorialization of cultural identities. *Družboslovne razprave* 10 (15/16): 140–153.

- . 2001. Krepitev in slabitev moči lokalnih akterjev ter nastajanje in izginjanje lokalnih posebnosti v procesu globalizacije. *Teorija in praksa* 38 (5): 765–785.
- Mlinar, Zdravko in Slavko Splichal. 1988. Primerjalno raziskovanje in razvojni procesi. *Družboslovne razprave* 5 (6): 33–42.
- Molloy, Michael in Bruce Reed. 1995. A critical point for random graphs with a given degree sequence. *Random Structures & Algorithms* 6: 161–179.
- Moody, James. 2004. The Structure of a Social Science Collaboration Network: Disciplinary Cohesion from 1963 to 1999. *American Sociological Review* 69 (2): 213–238.
- Mulkay, M.J. 1975. Three models of scientific development. *Sociological Review* 23 (3): 509–526.
- Munshi, Usha Mujoo in Piyush Pant. 2004. Regional, National, International Coauthorship and Subauthorship collaboration and Author productivity as manifested in the Scholarly Journal Literature of Nuclear Science. <http://hdl.handle.net/123456789/461>.
- Newman, M. E. J. 2000. Small worlds: the structure of social networks. *Condmat/0111070*.
- . 2001. The structure of scientific collaboration networks. *Proceedings of the National Academy of Sciences of the United States of America* 98 (2): 404–409. doi:10.1073/pnas.021544898.
- . 2003. The structure and function of complex networks. *arXiv:cond-mat/0303516v1 [cond-matstat-mech]*.
- . 2004. Coauthorship networks and patterns of scientific collaboration. *Proceedings of the National Academy of Sciences of the United States of America* 101 (Suppl 1): 5200–5205.
- Nooraie, Reza Y., Marjan A. Kamrani, Robert Hanneman in Arash Etemadi. 2008. Association between co-authorship network and scientific productivity and impact indicators in academic medical research centers: A case study in Iran. *Health Research Policy and Systems* 6 (9). doi: 10.1186/1478-4505-6-9.
- Norgaard, Richard B. 2004. Learning and knowing collectively. *Ecological Economics* 49 (2): 231–241. doi:DOI:10.1016/j.ecolecon.2004.03.021. Papers of the Eight Meeting of the International Society for Ecological Economics; Montreal, Ont. Canada; July 11-14, 2004.

- Oort, Frank Van, Roderik Ponds in Koen Frenken. 2006. *The Geographical and Institutional Proximity of Scientific Collaboration Networks*. ERSA conference papers ersa06p762. European Regional Science Association.
- Opsahl, Tore. 2010. Triadic closure in two-mode networks: Redefining the global and local clustering coefficients. *arXiv:10060887v2 [physics:stat-ph]* doi:arXiv:1006.0887.
- Otte, E. in R. Rousseau. 2002. Social network analysis: a powerful strategy, also for the information sciences. *Journal of Information Science* 28 (6): 443–455.
- Pattison, Philippa in Stanley Wasserman. 1999. Logit models and logistic regressions for social networks: II. Multivariate relations. *British Journal of Mathematical and Statistical Psychology* 169–193.
- Pennock, David M., Gary W. Flake, Steve Lawrence, Eric J. Glover in C. Lee Giles. 2002. Winners don't take all: Characterizing the competition for links on the web. *Proceedings of the National Academy of Sciences of the United States of America* 99 (8): 5207–5211. doi:10.1073/pnas.032085699.
- Perc, Matjaz. 2010. Growth and structure of Slovenia's scientific collaboration network. *Journal of Informetrics* 4: 475–482.
- Perianes-Rodríguez, Antonio, Carlos Olmeda-Gómez in Félix Moya-Anegón. 2010. Detecting, identifying and visualizing research groups in co-authorship networks. *Scientometrics* 82 (2): 307–319.
- Piette, Michael J. in Kevin L. Ross. 1992. An Analysis of the Determinants of Co-Authorship in Economics. *The Journal of Economic Education* 23 (3): pp. 277–283.
- Price, De Solla. 1963. *Little Science, Big Science and Beyond*. Columbia University Press, New York.
- . 1965. Networks of Scientific Papers. *Science* 149: 510–515.
- . 1976. A general theory of bibliometric and other cumulative advantage processes. *Journal of the American Society for Information Science* 27 (5): 292–306. doi:10.1002/asi.4630270505.
- Price, De Solla in Donald Beaver. 1966. Collaboration in an Invisible College. *American Psychologist* 21 (11): 1011–1018. doi:DOI:10.1037/h0024051.
- Qin, Jian, F. W. Lancaster in Bryce Allen. 1997. Types and Levels of Collaboration in Interdisciplinary Research in the Sciences. *Journal of the American Society for Information Science* 48 (10): 893–916.

- Ramasco, Jose J. in Steven A. Morris. 2005. Social inertia in collaboration networks .
- Richardson, M.W. 1938. Multidimensional psychophysics. *Psychological Bulletin* 35: 659–660.
- Rigby, John. 2005. Handcrafted by 16 men: The impact of single and multiple authorship in collaborative research networks. *Research Evaluation* 14 (3): 199–206. doi:10.3152/147154405781776148.
- Rodriguez, Marko A. in Alberto Pepe. 2008. On the relationship between the structural and socioacademic communities of a coauthorship network. *Journal of Informetrics* 2 (3): 195–201. doi:DOI:10.1016/j.joi.2008.04.002.
- Rogers, Juan, Barry Bozeman in Ivan Chompalov. 2001. Obstacles and opportunities in the application of network analysis to the evaluation on R&D. *Research Evaluation* 10 (3): 161–172.
- Said, Yasmin H., Edward J. Wegman, Walid K. Sharabati in John Rigsby. 2008. Social networks of author-coauthor relationships. *Computational Statistics & Data Analysis* 52 (4): 2177–2184. doi:DOI:10.1016/j.csda.2007.07.021.
- Sailer, L. 1978. Structural equivalence: Meaning and definition, computation and application. *Social Networks* (1): 73–90.
- Schaefer, David R., John M. Light, Richard A. Fabes, Laura D. Hanish in Carol Lynn Martin. 2010. Fundamental principles of network formation among preschool children. *Social Networks* 32 (1): 61–71. doi:DOI:10.1016/j.socnet.2009.04.003. Dynamics of Social Networks.
- Schubert, Torben in Radhamany Sooryamoorthy. 2010. Can the centre–periphery model explain patterns of international scientific collaboration among threshold and industrialised countries? The case of South Africa and Germany. *Scientometrics* 83 (1): 181–203. doi:10.1007/s11192-009-0074-2.
- Scott, John P. 2000. *Social Network Analysis: A Handbook*. SAGE Publications.
- Sigogneau, Anne, Ornella Malagutti, Michele Crance in Serge Bauin. 2005. Cross-disciplinary research: co-evaluation and co-publication practices of the CNRS laboratories. *Research Evaluation* 14 (2): 165–176. doi:10.3152/147154405781776210.
- Skyrms, B. in R. Pemantle. 2000. A dynamic model of social network formation. *Proceedings of the National Academy of Sciences of the United States of America* 97 (16): 9340–9346. doi:10.1073/pnas.97.16.9340.

- Smith, Mapheus. 1958. The trend toward multiple authorship in psychology. *American Psychologist* 13 (10): 596–599.
- Snijders, Tom A.B. 1990. Testing for change in digraph at two time points. *Social Networks* 12: 359–373. doi:DOI:10.1016/j.socnet.2009.02.004. Dynamics of Social Networks.
- . 1995. Methods for longitudinal social network data. V *New Trends in Probability and Statistics*, ur. E.-M. Tiit, T. Kollo in Niemi H., knj. 3 zbirke *Multivariate Statistics and MAtrices in Statistics*, 221–227. Vilnius, Lithuania: TEV and Utrecht, The Nederlands: VSP.
- . 1996. Stochastic actor-oriented models for network change. *Journal of Mathematical Sociology* 21: 149–176.
- . 2001. The statistical evaluation of social network dynamics. V *Sociological Methodology—2001*, ur. M.E. Sobel in M.P. Becker, 361–395. Basil Blackwell.
- Snijders, Tom A.B., Christian Steglich, M. Schweinberger in K. Huisman. 2008. *Manual for SIENA version 3.2*. ICS, University of Groningen, Department of Statistics, University of Oxford.
- Snijders, Tom A.B., Gerhard G. van de Bunt in Christian Steglich. 2010. Introduction to stochastic actor-based models for network dynamics. *Social Networks* 32 (1): 44–60. doi:DOI:10.1016/j.socnet.2009.02.004. Dynamics of Social Networks.
- Sonnenwald, Diane H. 2007. Introduction Scientific Collaboration: A Synthesis of Challenges and Strategies. *Annual Review of Information Science and Technology* 41.
- Sorčan, Stojan, Franci Demšar in Tina Valenci. 2008. *Znanstveno raziskovanje v Sloveniji : primerjalna analiza*. Ljubljana : Javna agencija za raziskovalno dejavnost Republike Slovenije, 2008.
- Stichweh, R. 2001. Scientific Disciplines, History of. V *International Encyclopedia of the Social & Behavioral Sciences*, ur. Neil J. Smelser in Paul B. Baltes, 13727–13731. Oxford: Pergamon. doi:DOI:10.1016/B0-08-043076-7/03187-9.
- Stolte-Heiskanen, Veronica. 1987. The Role of Centre-Periphery Relations in the Utilisation of the Social Sciences. *International Sociology* 2 (2): 189–203. doi:10.1177/026858098700200205.
- Tomassini, Marco in Leslie Luthi. 2007. Empirical analysis of the evolution of a scientific collaboration network. *Physica A: Statistical Mechanics and its Applications* 385 (2): 750–764.

- Torgerson, W. S. 1952. Multidimensional scaling: I. Theory and method. *Psychometrika* 17: 401–419.
- Travers, Jeffrey in Stanley Milgram. 1969. An Experimental Study of the Small World Problem. *Sociometry* 32 (4): 425–443. doi:10.2307/2786545.
- Vázquez, Alexei. 2003. Growing network with local rules: Preferential attachment, clustering hierarchy, and degree correlations. *Phys Rev E* 67 (5): 056104. doi:10.1103/PhysRevE.67.056104.
- Veugelers, Reinhilde in Bruno Cassiman. 2005. R&D cooperation between firms and universities. Some empirical evidence from Belgian manufacturing. *International Journal of Industrial Organization* 23 (5-6): 355–379.
- Wagner, Caroline S. 2005. Six case studies of international collaboration in science. *Scientometrics* 62 (1): 3–26. doi:10.1007/s11192-005-0001-0.
- Wagner, Caroline S. in Loet Leydesdorff. 2005. Network structure, self-organization, and the growth of international collaboration in science. *Research Policy* 34 (10): 1608–1618.
- Wallerstein, I. 1974. *The Modern World System: Capitalist Agriculture and the Origins of the European World-Economy in the Sixteenth Century*. New York: Academic.
- Wang, P., G. Robins in Philippa Pattison. 2006. *PNET: Program for the simulation and estimation of p^* exponential random graph models*. Melbourne: University of Melbourne.
- Wasserman, Stanley. 1978. Models for binary directed graphs and their applications. *Advances in Applied Probability* 10: 803–818.
- . 1980a. Analyzing Social Networks As Stochastic Processes. *Journal of the American Statistical Association* 75 (370): 280–294.
- . 1980b. A Stochastic Model for Directed Graphs with Transition Rates Determined by Reciprocity. *Sociological Methodology* 11: pp. 392–412.
- . 1987. Conformity of two sociometric relations. *Psychometrika* 52 (1): 3–18. doi:10.1007/BF02293953.
- Wasserman, Stanley in Katherine Faust. 1994. *Social Network Analysis : Methods and Applications*. New York: Cambridge University Press.
- Wasserman, Stanley in D Iacobucci. 1988. Sequential social network data. *Psychometrika* 53: 261–282.

- Wasserman, Stanley in Philippa Pattison. 1996. Logit models and logistic regressions for social networks: I. An introduction to Markov graphs and p. *Psychometrika* 61 (3): 401–425–425. doi:10.1007/BF02294547.
- Wasserman, Stanley in Sheila OLeary Weaver. 1985. Statistical analysis of binary relational data: Parameter estimation. *Journal of Mathematical Psychology* 29 (4): 406–427. doi:DOI:10.1016/0022-2496(85)90003-3.
- Watts, D. J. in S. H. Strogatz. 1998. Collective dynamics of 'small-world' networks. *Nature* 393 (6684): 440–442. doi:10.1038/30918.
- Watts, Duncan J. 2003. *Six Degrees: The Science of a Connected Age*. W. W. Norton & Company, 1st izd..
- Wellman, Barry in S.D. Berkowitz, ur.. 1988. *Social Structures: A Network Approach*. Cambridge: Cambridge University Press.
- White, D. in K. Reitz. 1983. Graph and semigroup homomorphisms on networks of relations. *Social Networks* 5: 193–234.
- White, Harrison C., Scott A. Boorman in Ronald L. Breige. 1976. Social Structure from Multiple Networks. I. Blockmodels of Roles and Positions. *The American Journal of Sociology* 81 (4): 730–780.
- Whitley, Richard. 1984. *The intellectual and social organization of the sciences*. Oxford: Clarendon Press.
- Wray, K. Brad. 2002. *The Epistemic Significance of Collaborative Research*, knj. 69. The University of Chicago Press on behalf of the Philosophy of Science Association.
- . 2006. Scientific authorship in the age of collaborative research. *Studies In History and Philosophy of Science Part A* 37 (3): 505–514. doi: DOI:10.1016/j.shpsa.2005.07.011.
- Ziherl, Petra, Hajdeja Iglič in Anuška Ferligoj. 2006. Research Groups' Social Capital: A Clustering Approach. *Metodološki Zvezki (Advances in Methodology and Statistics)* 3 (2): 217–237.
- Ziman, John. 1994. *Prometheus Bound. Science in Dynamic Steady State*. Cambridge: Cambridge University Press.
- Zuckerman, Harriet. 1967. Nobel Laureates in Science: Patterns of Productivity, Collaboration, and Authorship. *American Sociological Review* 32: 391–403.

Priloga A

Izpis iz programa SIENA

```
*****
fiz_pr2_3.out
*****
Filename is fiz_pr2_3.out.

This file contains primary output for SIENA project <<fiz_pr2_3>>.
File fiz_pr2_3.log contains secondary output.

Date and time: 1/12/2011 3:20:30 PM
SIENA version 3.181 (08 April 10)

@1
Data input.
=====

Read basic information file fiz_pr2_3.in.
3 observations,
250 actors,
1 dependent network variable,
0 dependent actor variables,
2 files with constant actor covariates,
2 exogenous changing actor covariates,
0 constant dyadic covariates,
0 exogenous changing dyadic covariates,
no file with times of composition change.

@2
Reading network variables.
-----
Reading digraph files for the 1st network variable:

File fiz2.mat contains observation moment 1.
nonzero code is 1; missing codes are .... (none).
File fiz3.mat contains observation moment 2.
nonzero code is 1; missing codes are .... (none).
File fiz4.mat contains observation moment 3.
nonzero code is 1; missing codes are .... (none).

For file fiz2.mat, degree distributions are as follows:
Nodes
 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20
 21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40
 41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60
 61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80
 81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99 100
101 102 103 104 105 106 107 108 109 110 111 112 113 114 115 116 117 118 119 120
121 122 123 124 125 126 127 128 129 130 131 132 133 134 135 136 137 138 139 140
```

```

141142143144145146147148149150151152153154155156157158159160
161162163164165166167168169170171172173174175176177178179180
181182183184185186187188189190191192193194195196197198199200
201202203204205206207208209210211212213214215216217218219220
22122223224225226227228229230231232233234235236237238239240
241242243244245246247248249250
out-degrees
 1 2 4 0 34 0 1 13 11 1 0 2 1 0 2 7 0 9 9 9
 8 0 0 9 0 8 2 6 2 1 12 7 11 3 0 0 0 11 0 0
 0 2 9 0 3 6 3 2 2 0 1 0 3 11 0 5 2 5 0 4
 3 0 0 5 1 0 9 4 0 4 1 8 8 2 4 1 0 0 5 0
 1 1 0 5 0 3 4 6 0 4 0 1 0 3 1 0 3 1 0 9
 5 0 3 8 5 1 0 2 15 4 0 0 3 0 10 12 4 0 1 4
 0 1 3 3 2 9 0 0 0 0 0 3 5 1 6 7 0 0 4 7
 0 14 4 0 2 0 0 2 3 0 0 0 0 0 4 3 3 0 9 3
 0 0 0 0 3 0 1 0 0 1 2 6 0 2 2 7 0 0 1 2
 0 0 0 2 0 0 3 0 0 0 0 0 0 0 0 0 0 0 0 0
 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
in-degrees
 1 2 4 0 34 0 1 13 11 1 0 2 1 0 2 7 0 9 9 9
 8 0 0 9 0 8 2 6 2 1 12 7 11 3 0 0 0 11 0 0
 0 2 9 0 3 6 3 2 2 0 1 0 3 11 0 5 2 5 0 4
 3 0 0 5 1 0 9 4 0 4 1 8 8 2 4 1 0 0 5 0
 1 1 0 5 0 3 4 6 0 4 0 1 0 3 1 0 3 1 0 9
 5 0 3 8 5 1 0 2 15 4 0 0 3 0 10 12 4 0 1 4
 0 1 3 3 2 9 0 0 0 0 0 3 5 1 6 7 0 0 4 7
 0 14 4 0 2 0 0 2 3 0 0 0 0 0 4 3 3 0 9 3
 0 0 0 0 3 0 1 0 0 1 2 6 0 2 2 7 0 0 1 2
 0 0 0 2 0 0 3 0 0 0 0 0 0 0 0 0 0 0 0 0
 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

```

The input file contains codes for structurally determined values:

34194 structural zeros were found (code 10).

0 structural one was found (code 11).

Actors 6, 22, 23, 35, 36, 39, 50, 59, 63, 83, 91, 96, 107, 111, 112, 130, 137, 138, 146, 147, 158, 163, 168, 177, 178, 181, 182, 183, 185, 186, 188, 189, 190, 191, 192, 193, 194, 195, 196, 197, 199, 200, 201, 202, 203, 204, 206, 208, 210, 211, 212, 213, 214, 216, 217, 218, 220, 221, 223, 224, 225, 226, 227, 228, 229, 230, 231, 232, 233, 234, 235, 237, 238, 239, 240, 241, 243, 244, 246, 247, 249, 250, are inactive at this observation.

The structurally free (non-determined) values separate

the actors into 83 components:

component	actors	1	2	3	4	5	7	8	9	10	11
1		12	13	14	15	16	17	18	19	20	21
		24	25	26	27	28	29	30	31	32	33
		34	37	38	40	41	42	43	44	45	46
		47	48	49	51	52	53	54	55	56	57
		58	60	61	62	64	65	66	67	68	69
		70	71	72	73	74	75	76	77	78	79
		80	81	82	84	85	86	87	88	89	90
		92	93	94	95	97	98	99	100	101	102
		103	104	105	106	108	109	110	113	114	115
		116	117	118	119	120	121	122	123	124	125
		126	127	128	129	131	132	133	134	135	136
		139	140	141	142	143	144	145	148	149	150
		151	152	153	154	155	156	157	159	160	161
		162	164	165	166	167	169	170	171	172	173
		174	175	176	179	180	184	187	198	205	207
		209	215	219	222	236	242	245	248		
2		6 (inactive)									
3		22 (inactive)									
4		23 (inactive)									
5		35 (inactive)									
6		36 (inactive)									
7		39 (inactive)									
8		50 (inactive)									
9		59 (inactive)									
10		63 (inactive)									
11		83 (inactive)									
12		91 (inactive)									
13		96 (inactive)									
14		107 (inactive)									
15		111 (inactive)									
16		112 (inactive)									
17		130 (inactive)									

```

18      137 (inactive)
19      138 (inactive)
20      146 (inactive)
21      147 (inactive)
22      158 (inactive)
23      163 (inactive)
24      168 (inactive)
25      177 (inactive)
26      178 (inactive)
27      181 (inactive)
28      182 (inactive)
29      183 (inactive)
30      185 (inactive)
31      186 (inactive)
32      188 (inactive)
33      189 (inactive)
34      190 (inactive)
35      191 (inactive)
36      192 (inactive)
37      193 (inactive)
38      194 (inactive)
39      195 (inactive)
40      196 (inactive)
41      197 (inactive)
42      199 (inactive)
43      200 (inactive)
44      201 (inactive)
45      202 (inactive)
46      203 (inactive)
47      204 (inactive)
48      206 (inactive)
49      208 (inactive)
50      210 (inactive)
51      211 (inactive)
52      212 (inactive)
53      213 (inactive)
54      214 (inactive)
55      216 (inactive)
56      217 (inactive)
57      218 (inactive)
58      220 (inactive)
59      221 (inactive)
60      223 (inactive)
61      224 (inactive)
62      225 (inactive)
63      226 (inactive)
64      227 (inactive)
65      228 (inactive)
66      229 (inactive)
67      230 (inactive)
68      231 (inactive)
69      232 (inactive)
70      233 (inactive)
71      234 (inactive)
72      235 (inactive)
73      237 (inactive)
74      238 (inactive)
75      239 (inactive)
76      240 (inactive)
77      241 (inactive)
78      243 (inactive)
79      244 (inactive)
80      246 (inactive)
81      247 (inactive)
82      249 (inactive)
83      250 (inactive)

```

No missing data for observation 1 (file fiz2.mat).

For file fiz3.mat, degree distributions are as follows:

Nodes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80
	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
101	110	121	130	141	151	161	171	181	191	201	211	221	231	241	251	261	271	281	291	20
121122123124125126127128129130131132133134135136137138139140	141142143144145146147148149150151152153154155156157158159160	161162163164165166167168169170171172173174175176177178179180	181182183184185186187188189190191192193194195196197198199200	201202203204205206207208209210211212213214215216217218219220	22122223224225226227228229230231232233234235236237238239240															

241242243244245246247248249250

out-degrees

4	3	6	2	33	2	1	18	10	1	1	6	4	3	6	15	1	14	10	8
10	2	2	8	1	5	3	12	4	8	13	9	9	1	5	0	1	18	6	1
0	1	12	3	5	4	3	6	3	2	1	1	8	17	0	9	2	5	3	2
1	0	1	4	2	0	11	5	0	7	1	10	19	1	4	3	0	5	3	2
1	1	5	10	7	5	7	11	0	5	0	1	4	4	2	2	2	4	4	11
0	0	1	11	8	2	0	7	22	8	7	7	10	12	11	13	16	0	4	7
2	1	7	5	2	9	5	0	7	1	1	9	15	3	9	9	6	2	10	2
4	23	9	0	3	11	1	1	3	0	0	0	4	3	4	3	8	0	3	10
3	0	0	6	4	0	0	0	2	1	0	0	3	5	0	9	2	0	6	7
1	0	0	7	0	0	10	0	2	3	0	3	7	0	0	6	4	0	0	5
0	6	0	0	4	0	0	1	0	0	1	1	0	4	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0

in-degrees

4	3	6	2	33	2	1	18	10	1	1	6	4	3	6	15	1	14	10	8
10	2	2	8	1	5	3	12	4	8	13	9	9	1	5	0	1	18	6	1
0	1	12	3	5	4	3	6	3	2	1	1	8	17	0	9	2	5	3	2
1	0	1	4	2	0	11	5	0	7	1	10	19	1	4	3	0	5	3	2
1	1	5	10	7	5	7	11	0	5	0	1	4	4	2	2	2	4	4	11
0	0	1	11	8	2	0	7	22	8	7	7	10	12	11	13	16	0	4	7
2	1	7	5	2	9	5	0	7	1	1	9	15	3	9	9	6	2	10	2
4	23	9	0	3	11	1	1	3	0	0	0	4	3	4	3	8	0	3	10
3	0	0	6	4	0	0	0	2	1	0	0	3	5	0	9	2	0	6	7
1	0	0	7	0	0	10	0	2	3	0	3	7	0	0	6	4	0	0	5
0	6	0	0	4	0	0	1	0	0	1	1	0	4	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0

The input file contains codes for structurally determined values:

16668 structural zeros were found (code 10).

0 structural one was found (code 11).

Actors 36, 168, 178, 183, 195, 199, 204, 210, 213, 216, 217, 218, 220, 221, 223, 224, 225, 226, 227, 228, 229, 230, 231, 232, 233, 234, 235, 237, 238, 239,

240, 241, 244, 246, 249, 250, are inactive at this observation.

The structurally free (non-determined) values separate

the actors into 37 components:

component	actors
1	1 2 3 4 5 6 7 8 9 10
11	12 13 14 15 16 17 18 19 20
21	22 23 24 25 26 27 28 29 30
31	32 33 34 35 37 38 39 40 41
42	43 44 45 46 47 48 49 50 51
52	53 54 55 56 57 58 59 60 61
62	63 64 65 66 67 68 69 70 71
72	73 74 75 76 77 78 79 80 81
82	83 84 85 86 87 88 89 90 91
92	93 94 95 96 97 98 99 100 101
102	103 104 105 106 107 108 109 110 111
112	113 114 115 116 117 118 119 120 121
122	123 124 125 126 127 128 129 130 131
132	133 134 135 136 137 138 139 140 141
142	143 144 145 146 147 148 149 150 151
152	153 154 155 156 157 158 159 160 161
162	163 164 165 166 167 169 170 171 172
173	174 175 176 177 179 180 181 182 184
185	186 187 188 189 190 191 192 193 194
196	197 198 200 201 202 203 205 206 207
208	209 211 212 214 215 219 222 236 242
243	245 247 248
2	36 (inactive)
3	168 (inactive)
4	178 (inactive)
5	183 (inactive)
6	195 (inactive)
7	199 (inactive)
8	204 (inactive)
9	210 (inactive)
10	213 (inactive)
11	216 (inactive)
12	217 (inactive)
13	218 (inactive)
14	220 (inactive)
15	221 (inactive)
16	223 (inactive)
17	224 (inactive)
18	225 (inactive)
19	226 (inactive)
20	227 (inactive)
21	228 (inactive)
22	229 (inactive)

```

23      230 (inactive)
24      231 (inactive)
25      232 (inactive)
26      233 (inactive)
27      234 (inactive)
28      235 (inactive)
29      237 (inactive)
30      238 (inactive)
31      239 (inactive)
32      240 (inactive)
33      241 (inactive)
34      244 (inactive)
35      246 (inactive)
36      249 (inactive)
37      250 (inactive)

```

No missing data for observation 2 (file fiz3.mat).

For file fiz4.mat, degree distributions are as follows:

Nodes

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80
81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100

10110210310410510610710810911011112113114115116117118119120
121122123124125126127128129130131132133134135136137138139140
141142143144145146147148149150151152153154155156157158159160
161162163164165166167168169170171172173174175176177178179180
181182183184185186187188189190191192193194195196197198199200
201202203204205206207208209210211212213214215216217218219220
221222223224225226227228229230231232233234235236237238239240
241242243244245246247248249250

out-degrees

5	7	9	0	30	2	2	23	9	1	1	5	9	5	7	20	1	14	19	4
8	3	1	9	2	6	2	13	2	7	17	11	10	2	9	3	1	23	15	1
0	2	8	5	6	4	4	11	3	1	0	1	5	22	0	5	2	3	4	3
2	3	1	8	3	2	9	4	1	8	3	19	14	5	8	2	0	2	3	4
1	0	6	8	12	4	13	5	0	7	6	3	3	18	0	0	6	4	3	9
0	0	1	22	2	1	7	8	27	10	14	5	5	13	13	15	14	0	2	11
4	4	8	10	0	12	0	1	5	6	2	14	15	3	16	12	7	2	6	6
8	23	6	1	4	13	3	1	7	3	4	0	3	5	4	6	10	2	1	6
8	5	4	9	7	1	0	5	3	2	0	0	3	8	0	15	3	1	4	6
2	1	3	4	4	4	6	1	9	5	10	13	13	3	4	8	0	1	2	7
0	18	1	1	9	2	1	2	0	1	3	3	2	2	0	10	1	4	0	5
9	0	11	1	3	6	10	3	3	3	4	3	3	2	2	3	5	2	5	4
1	0	0	1	0	4	2	4	0	0										

in-degrees

5	7	9	0	30	2	2	23	9	1	1	5	9	5	7	20	1	14	19	4
8	3	1	9	2	6	2	13	2	7	17	11	10	2	9	3	1	23	15	1
0	2	8	5	6	4	4	11	3	1	0	1	5	22	0	5	2	3	4	3
2	3	1	8	3	2	9	4	1	8	3	19	14	5	8	2	0	2	3	4
1	0	6	8	12	4	13	5	0	7	6	3	3	18	0	0	6	4	3	9
0	0	1	22	2	1	7	8	27	10	14	5	5	13	13	15	14	0	2	11
4	4	8	10	0	12	0	1	5	6	2	14	15	3	16	12	7	2	6	6
8	23	6	1	4	13	3	1	7	3	4	0	3	5	4	6	10	2	1	6
8	5	4	9	7	1	0	5	3	2	0	0	3	8	0	15	3	1	4	6
2	1	3	4	4	4	6	1	9	5	10	13	13	3	4	8	0	1	2	7
0	18	1	1	9	2	1	2	0	1	3	3	2	2	0	10	1	4	0	5
9	0	11	1	3	6	10	3	3	3	4	3	3	2	2	3	5	2	5	4
1	0	0	1	0	4	2	4	0	0										

No missing data for observation 3 (file fiz4.mat).

Name of this network variable:(none given).

```

@2
Reading constant actor covariates.
-----
```

Covariate data file fiz_prvao.dat with 1 variables, named:
1.OBJJAVA (code for missing data is 1).
Covariate data file fiz_razskup.dat with 1 variables, named:
RAZ.SKUPINA (code for missing data is 9999).

A total of 2 non-changing individual covariates.

Number of missing cases:
1.objava 0 (0.0 %)
Raz.Skupina 9 (3.6 %)

Information about covariates (missings not counted):
minimum maximum mean

```

1.objava    1957.0  2005.0  1988.396
Raz.Skupina   3.0    176.0   57.651

The mean values are subtracted from the covariates.

@2
Reading exogenous changing actor covariates.
-----
Exogenous changing covariate named IFARTICLES read from file fiz_pr2_3_stcIF.din.
No code for missing data is specified; SIENA will treat scores of -9 as missing data.
Exogenous changing covariate named DEGREEOUT read from file fiz_pr2_3_nondiscDegree.din.
No code for missing data is specified; SIENA will treat scores of -9 as missing data.

A total of 2 exogenous changing actor covariates.

Number of missing cases per period:
  period      1      2     overall
IFArticles      0      0      0  ( 0.0 %)
DegreeOut       0      0      0  ( 0.0 %)

Information about changing covariates:
  minimum     maximum      mean
IFArticles
  period      1      0.0    60.0    4.080
  period      2      0.0   136.0    8.160
Overall                    6.120

DegreeOut
  period      1      0.0   100.0    7.276
  period      2      0.0    90.0   12.248
Overall                    9.762

The overall mean values are subtracted from the covariates.

For the similarity variable calculated from each actor covariate,
the mean is subtracted.
These means are :
Similarity 1.objava : 0.7304
Similarity Raz.Skupina : 0.6645
Similarity IFArticles : 0.9341
Similarity DegreeOut : 0.8711

The mean structural dissimilarity value subtracted in the
balance calculations is 0.0236 .

Siena version 3.181 (08 April 10)

@1
Initial data description.
=====

@2
Change in networks:
-----
For the following statistics, missing values (if any) are not counted.
Further, structurally determined entries are treated as observed entries.
All 3 observed networks are symmetric.
Therefore, it is assumed that this is an analysis of an non-directed relation.

Network density indicators:
observation time      1      2      3
density            0.009  0.016  0.022
average degree     2.192  3.896  5.488
number of ties      274    487    686
missing fraction   0.000  0.000  0.000

Edge changes between subsequent observations:
periods      0 => 0  0 => 1  1 => 0  1 => 1  Distance  Jaccard  Missing
  1 ==> 2      30543    308     95    179     294    0.308    0 ( 0%)
  2 ==> 3      30268    370    171    316     421    0.369    0 ( 0%)

Distances do not consider structurally fixed network ties.
This may imply that the columns 0 => 1 and 1 => 0 do not add up to the distance column.

```

(The distances reported in the output file for conditional estimation for the network variable refer to the total symmetric adjacency matrix, and therefore are double the distance reported above.)

```
Dyad counts:
observation    total     mutual     asymm.     null
  1.        31125      274          0     30851
  2.        31125      487          0     30638
  3.        31125      686          0     30439

Standard values for initial parameter values
-----
constant network rate (period 1)           4.7243
constant network rate (period 2)           6.7644
degree (density)                         -1.4302
- and zero for all other parameters

Siena version 3.181 (08 April 10)
Model descriptions are written to file fiz_pr2_3.log.

A list of objective function effects is given in file fiz_pr2_3.eff.
The numbers in this list can be used for specifying interaction effects (see the SIENA manual).

Initialisation of project <>fiz_pr2_3> executed successfully.

-----
New analysis started.
Date and time: 1/16/2011 11:40:17 PM
New results follow.
-----

Siena version 3.181 (08 April 10)

@1
Estimation by stochastic approximation algorithm.
=====
Random initialization of random number stream.
Current random number seed is 2420362.
Model Type 2: Initiative - confirmation.
Estimation method: conditional moment estimation.
Conditioning variable is the total number of observed changes ("distance")
in the network variable.
Distances for simulations are
period :   1   2
distance :  588  842 .
Standard errors are estimated with the finite difference method.
Initial value of gain parameter is 0.2000000 .
Number of subphases in Phase 2 is 4.

Initial parameter values are
  0.1 Rate parameter period 1           15.2450
  0.2 Rate parameter period 2           13.6384
  1. eval: degree (density)           -1.7410
  2. eval: transitive triads           0.3904
  3. eval: degree of alter            -0.0467
  4. eval: 1.objava similarity         -0.2203
  5. eval: same Raz.Skupina           0.5760
  6. eval: IFArticles                 -0.0037
  7. eval: DegreeOut                  0.0049

Observed values of target statistics are
  1. Number of edges                   944.0000
  2. Number of transitive triads       1410.0000
  3. Sum of squared degrees           19138.0000
  4. Similarity on 1.objava           3.5207
  5. Same values on Raz.Skupina       846.0000
  6. Sum of degrees [U+FFFD] IFArticles 15456.4400
  7. Sum of degrees [U+FFFD] DegreeOut 22208.3440

7 parameters, 7 statistics
Estimation of derivatives by the finite differences method.

@2
End of stochastic approximation algorithm, phase 3.
-----
Total of 2328 iterations.
Parameter estimates based on 1328 iterations,
basic rate parameters as well as
convergence diagnostics, covariance and derivative matrices based on 1000 iterations.
```

```

Information for convergence diagnosis.
Averages, standard deviations, and t-ratios for deviations from targets:
 1.    0.478   29.415   0.016
 2.    1.921   152.334   0.013
 3.   -30.886  1311.285  -0.024
 4.    0.252    9.012   0.028
 5.    0.356   39.190   0.009
 6.   20.511  1118.194   0.018
 7.    2.685   950.177   0.003

```

Good convergence is indicated by the t-ratios being close to zero.

```

@2
Estimation results.
-----

```

Regular end of estimation algorithm.
Total of 2328 iteration steps.

```

@3
Estimates and standard errors

```

Rate parameters:
 0.1 Rate parameter period 1 13.0849 (1.3241)
 0.2 Rate parameter period 2 11.6452 (0.8354)

Other parameters:
 1. eval: degree (density) -1.3013 (0.0295)
 2. eval: transitive triads 0.5005 (0.0174)
 3. eval: degree of alter -0.0335 (0.0026)
 4. eval: 1.objava similarity -0.2040 (0.1326)
 5. eval: same Raz.Skupina 0.8216 (0.0627)
 6. eval: IFArticles -0.0042 (0.0026)
 7. eval: DegreeOut 0.0048 (0.0032)

```

@3
Covariance matrices

```

Covariance matrix of estimates (correlations below diagonal):

0.001	0.000	0.000	0.000	-0.001	0.000	0.000
-0.301	0.000	0.000	0.000	0.000	0.000	0.000
0.100	0.271	0.000	0.000	0.000	0.000	0.000
-0.001	0.037	0.221	0.018	-0.001	0.000	0.000
-0.359	-0.206	-0.348	-0.110	0.004	0.000	0.000
-0.091	-0.235	-0.870	-0.175	0.308	0.000	0.000
-0.118	-0.266	-0.787	-0.213	0.300	0.435	0.000

Derivative matrix of expected statistics X by parameters and
covariance/correlation matrix of X are written to file fiz_pr2_3.log.

Total computation time 11199.36 seconds.

```

*****
mat_pr2_3.out
*****
Filename is mat_pr2_3.out.

This file contains primary output for SIENA project <<mat_pr2_3>>.
File mat_pr2_3.log contains secondary output.

Date and time: 1/12/2011 3:20:50 PM

SIENA version 3.181 (08 April 10)

@1
Data input.
=====
Read basic information file mat_pr2_3.in.
3 observations,
152 actors,
1 dependent network variable,
0 dependent actor variables,
2 files with constant actor covariates,
2 exogenous changing actor covariates,
0 constant dyadic covariates,
0 exogenous changing dyadic covariates,
no file with times of composition change.

@2
Reading network variables.
-----
Reading digraph files for the 1st network variable:

File mat2.mat contains observation moment 1.
nonzero code is 1; missing codes are .... (none).
File mat3.mat contains observation moment 2.
nonzero code is 1; missing codes are .... (none).
File mat4.mat contains observation moment 3.
nonzero code is 1; missing codes are .... (none).

For file mat2.mat, degree distributions are as follows:
Nodes
  1  2   3   4   5   6   7   8   9   10  11  12  13  14  15  16  17  18  19  20
  21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40
  41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60
  61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80
  81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99100
10110210310410510610710810911011112113114115116117118119120
121122123124125126127128129130131132133134135136137138139140
141142143144145146147148149150151152
out-degrees
  1   6   7   1   7   0   1   0   0   0   0   1   0   7   1   4   4   1   0   0   0
  4   1   0   1   0   0   0   1   2   0   0   5   1   1   0   0   0   0   1   3
  0   0   3   0   0   0   0   0   0   1   0   0   0   2   0   1   0   0   0   2
  0   0   1   0   0   0   0   1   0   1   0   0   0   2   1   0   0   0   0   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   1   0   0   0   1
  1   1   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   4   0   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0
in-degrees
  1   6   7   1   7   0   1   0   0   0   0   1   0   7   1   4   4   1   0   0   0
  4   1   0   1   0   0   0   1   2   0   0   5   1   1   0   0   0   0   1   3
  0   0   3   0   0   0   0   0   0   1   0   0   0   2   0   1   0   0   0   2
  0   0   1   0   0   0   0   0   1   0   1   0   0   0   2   1   0   0   0   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   1   0   0   0   1
  1   1   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   4   0   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0   0

The input file contains codes for structurally determined values:
10070 structural zeros were found (code 10).
  0 structural one was found (code 11).
Actors 23, 25, 57, 59, 61, 72, 82, 88, 95, 99,
103, 104, 107, 113, 116, 117, 119, 120, 122, 123,
125, 126, 127, 133, 134, 135, 136, 137, 138, 139,
140, 144, 145, 146, 147, 148, 149, 150, are inactive at this observation.
The structurally free (non-determined) values separate
the actors into 39 components:
component      actors
    1           1   2   3   4   5   6   7   8   9   10

```

11	12	13	14	15	16	17	18	19	20
21	22	24	26	27	28	29	30	31	32
33	34	35	36	37	38	39	40	41	42
43	44	45	46	47	48	49	50	51	52
53	54	55	56	58	60	62	63	64	65
66	67	68	69	70	71	73	74	75	76
77	78	79	80	81	83	84	85	86	87
89	90	91	92	93	94	96	97	98	100
101	102	105	106	108	109	110	111	112	114
115	118	121	124	128	129	130	131	132	141
142	143	151	152						
2	23 (inactive)								
3	25 (inactive)								
4	57 (inactive)								
5	59 (inactive)								
6	61 (inactive)								
7	72 (inactive)								
8	82 (inactive)								
9	88 (inactive)								
10	95 (inactive)								
11	99 (inactive)								
12	103 (inactive)								
13	104 (inactive)								
14	107 (inactive)								
15	113 (inactive)								
16	116 (inactive)								
17	117 (inactive)								
18	119 (inactive)								
19	120 (inactive)								
20	122 (inactive)								
21	123 (inactive)								
22	125 (inactive)								
23	126 (inactive)								
24	127 (inactive)								
25	133 (inactive)								
26	134 (inactive)								
27	135 (inactive)								
28	136 (inactive)								
29	137 (inactive)								
30	138 (inactive)								
31	139 (inactive)								
32	140 (inactive)								
33	144 (inactive)								
34	145 (inactive)								
35	146 (inactive)								
36	147 (inactive)								
37	148 (inactive)								
38	149 (inactive)								
39	150 (inactive)								

No missing data for observation 1 (file mat2.mat).

For file mat3.mat, degree distributions are as follows:

Nodes

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80
81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
101	110	112	113	114	115	116	117	118	119	120	121	122	123	124	125	126	127	128	129
130	131	132	133	134	135	136	137	138	139	140	141	142	143	144	145	146	147	148	149
150	151	152																	

out-degrees

2	5	6	1	7	0	2	0	0	0	2	1	8	2	3	4	5	0	0	0
3	1	0	1	0	3	2	2	2	0	1	5	2	1	0	0	0	0	2	5
0	0	2	0	0	0	0	0	1	0	3	0	0	1	2	2	1	0	1	3
0	0	5	0	4	0	0	1	0	1	0	0	1	0	1	0	1	0	1	0
0	1	1	3	0	0	1	1	0	1	0	0	0	0	0	0	2	0	0	0
1	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0	2	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

in-degrees

2	5	6	1	7	0	2	0	0	0	2	1	8	2	3	4	5	0	0	0
3	1	0	1	0	3	2	2	2	0	1	5	2	1	0	0	0	0	2	5
0	0	2	0	0	0	0	0	1	0	3	0	0	1	2	2	1	0	1	3
0	0	5	0	4	0	0	1	0	1	0	0	1	0	1	0	1	0	1	0
0	1	1	3	0	0	1	1	0	1	0	0	0	0	0	2	0	0	0	0
1	1	0	0	0	1	0	0	0	0	0	0	0	0	0	2	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

The input file contains codes for structurally determined values:
2646 structural zeros were found (code 10).

0 structural one was found (code 11).
 Actors 103, 122, 123, 133, 137, 140, 144, 148, 149, are inactive at this observation.
 The structurally free (non-determined) values separate
 the actors into 10 components:

component	actors	1	2	3	4	5	6	7	8	9	10
1		11	12	13	14	15	16	17	18	19	20
		21	22	23	24	25	26	27	28	29	30
		31	32	33	34	35	36	37	38	39	40
		41	42	43	44	45	46	47	48	49	50
		51	52	53	54	55	56	57	58	59	60
		61	62	63	64	65	66	67	68	69	70
		71	72	73	74	75	76	77	78	79	80
		81	82	83	84	85	86	87	88	89	90
		91	92	93	94	95	96	97	98	99	100
		101	102	104	105	106	107	108	109	110	111
		112	113	114	115	116	117	118	119	120	121
		124	125	126	127	128	129	130	131	132	134
		135	136	138	139	141	142	143	145	146	147
		150	151	152							
2		103	(inactive)								
3		122	(inactive)								
4		123	(inactive)								
5		133	(inactive)								
6		137	(inactive)								
7		140	(inactive)								
8		144	(inactive)								
9		148	(inactive)								
10		149	(inactive)								

No missing data for observation 2 (file mat3.mat).

For file mat4.mat, degree distributions are as follows:

Nodes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40	
41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60	
61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80	
81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100	
101	102	104	105	106	107	108	109	110	111											
112	113	114	115	116	117	118	119	120	121											
124	125	126	127	128	129	130	131	132	134	135	136	137	138	139	140					
135	136	138	139	141	142	143	145	146	147											
150	151	152																		
out-degrees	3	6	10	2	12	0	4	0	1	0	4	0	9	3	4	5	6	3	4	2
4	0	1	1	1	3	4	1	0	1	7	0	2	1	0	2	1	1	5		
0	2	2	1	0	2	1	0	5	2	0	0	0	2	3	10	2	4	2	6	
1	2	6	1	5	0	0	1	5	2	0	1	1	2	4	4	4	0	1	0	
0	0	0	2	0	1	1	1	0	0	1	1	1	0	0	0	2	1	0		
1	1	2	0	0	2	1	0	3	0	0	1	0	0	0	3	2	1	0	0	
0	2	0	0	0	1	0	0	0	1	0	3	2	2	0	0	1	0	2	0	
1	0	0	2	0	0	0	0	1	0	0	0	0	0	1	0	0	2	0		
in-degrees	3	6	10	2	12	0	4	0	1	0	4	0	9	3	4	5	6	3	4	2
4	0	1	1	1	3	4	1	0	1	7	0	2	1	0	2	1	1	5		
0	2	2	1	0	2	1	0	5	2	0	0	0	2	3	10	2	4	2	6	
1	2	6	1	5	0	0	1	5	2	0	1	1	2	4	4	4	0	1	0	
0	0	0	2	0	1	1	1	0	0	1	1	1	0	0	0	2	1	0		
1	1	2	0	0	2	1	0	3	0	0	1	0	0	0	3	2	1	0	0	
0	2	0	0	0	1	0	0	0	1	0	3	2	2	0	0	1	0	2	0	
1	0	0	2	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0		

No missing data for observation 3 (file mat4.mat).

Name of this network variable:(none given).

@2
 Reading constant actor covariates.

Covariate data file mat_prvao.dat with 1 variables, named:
 1.OBJAVA (code for missing data is 1).
 Covariate data file mat_raszup.dat with 1 variables, named:
 RAZ.SKUPINA (code for missing data is 9999).

A total of 2 non-changing individual covariates.

Number of missing cases:
 1.objava 0 (0.0 %)
 Raz.Skupina 3 (2.0 %)

Information about covariates (missings not counted):
 minimum maximum mean
 1.objava 1964.0 2003.0 1987.013

```

Raz.Skupina      1.0   173.0    46.584
The mean values are subtracted from the covariates.

@2
Reading exogenous changing actor covariates.
-----
Exogenous changing covariate named IFARTICLES read from file mat_pr2_3_stcIF.din.
No code for missing data is specified; SIENA will treat scores of -9 as missing data.
Exogenous changing covariate named DEGREEOUT read from file mat_pr2_3_nondiscDegree.din.
No code for missing data is specified; SIENA will treat scores of -9 as missing data.

A total of 2 exogenous changing actor covariates.

Number of missing cases per period:
  period      1      2      overall
  IFArticles  0      0      0      ( 0.0 %)
  DegreeOut   0      0      0      ( 0.0 %)

Information about changing covariates:
  minimum     maximum     mean
  IFArticles
    period 1      0.0     24.0     1.605
    period 2      0.0     44.0     2.658
    Overall          2.132
  DegreeOut
    period 1      0.0     21.0     1.520
    period 2      0.0     55.0     3.243
    Overall          2.382

The overall mean values are subtracted from the covariates.

For the similarity variable calculated from each actor covariate,
the mean is subtracted.
These means are :
Similarity 1.objava :      0.7016
Similarity Raz.Skupina :  0.6441
Similarity IFArticles :  0.9205
Similarity DegreeOut :  0.9301

The mean structural dissimilarity value subtracted in the
balance calculations is      0.0090 .

Siena version 3.181 (08 April 10)

@1
Initial data description.
=====

@2
Change in networks:
-----
For the following statistics, missing values (if any) are not counted.
Further, structurally determined entries are treated as observed entries.
All 3 observed networks are symmetric.
Therefore, it is assumed that this is an analysis of an non-directed relation.

Network density indicators:
observation time      1      2      3
density            0.004  0.005  0.011
average degree     0.553  0.829  1.605
number of ties      42      63     122
missing fraction   0.000  0.000  0.000

Edge changes between subsequent observations:
  periods      0 => 0  0 => 1  1 => 0  1 => 1  Distance  Jaccard  Missing
  1 ==> 2      11399    35     14      28      43    0.364    0 ( 0%)
  2 ==> 3      11333    80     21      42      92    0.294    0 ( 0%)

Distances do not consider structurally fixed network ties.
This may imply that the columns 0 => 1 and 1 => 0 do not add up to the distance column.
(The distances reported in the output file for conditional estimation

```

for the network variable refer to the total symmetric adjacency matrix,
and therefore are double the distance reported above.)

```
Dyad counts:
observation    total     mutual     asymm.     null
  1.        11476       42          0      11434
  2.        11476       63          0      11413
  3.        11476      122          0      11354

Standard values for initial parameter values
-----
constant network rate (period 1)           1.1416
constant network rate (period 2)           2.4395
degree (density)                         -1.4067
- and zero for all other parameters

Siena version 3.181 (08 April 10)
Model descriptions are written to file mat_pr2_3.log.

A list of objective function effects is given in file mat_pr2_3.eff.
The numbers in this list can be used for specifying interaction effects (see the SIENA manual).

Initialisation of project <>mat_pr2_3> executed successfully.

-----
New analysis started.
Date and time: 1/17/2011 8:55:29 AM
New results follow.
-----

Siena version 3.181 (08 April 10)

@1
Estimation by stochastic approximation algorithm.
=====
Random initialization of random number stream.
Current random number seed is 3330250.
Model Type 2: Initiative - confirmation.
Estimation method: conditional moment estimation.
Conditioning variable is the total number of observed changes ("distance")
in the network variable.
Distances for simulations are
period :   1   2
distance :  86 184 .
Standard errors are estimated with the finite difference method.
Initial value of gain parameter is 0.2000000 .
Number of subphases in Phase 2 is 4.

Initial parameter values are
  0.1 Rate parameter period 1           2.5986
  0.2 Rate parameter period 2           4.8290
  1. eval: degree (density)           -1.9317
  2. eval: transitive triads           0.4028
  3. eval: degree of alter            -0.0106
  4. eval: 1.objava similarity         0.1740
  5. eval: same Raz.Skupina           0.4279
  6. eval: IFArticles                 0.0211
  7. eval: DegreeOut                  0.0229

Observed values of target statistics are
  1. Number of edges                  170.0000
  2. Number of transitive triads      54.0000
  3. Sum of squared degrees          1402.0000
  4. Similarity on 1.objava          11.7989
  5. Same values on Raz.Skupina      164.0000
  6. Sum of degrees [U+FFFD] IFArticles 1627.2560
  7. Sum of degrees [U+FFFD] DegreeOut 1291.2560

7 parameters, 7 statistics
Estimation of derivatives by the finite differences method.

@2
End of stochastic approximation algorithm, phase 3.
-----
Total of 2066 iterations.
Parameter estimates based on 1066 iterations,
basic rate parameters as well as
```

convergence diagnostics, covariance and derivative matrices based on 1000 iterations.

Information for convergence diagnosis.

Averages, standard deviations, and t-ratios for deviations from targets:

1.	-0.024	10.482	-0.002
2.	1.073	16.445	0.065
3.	14.724	202.296	0.073
4.	0.056	4.330	0.013
5.	1.344	14.445	0.093
6.	1.127	189.805	0.006
7.	1.551	162.646	0.010

Good convergence is indicated by the t-ratios being close to zero.

@2

Estimation results.

Regular end of estimation algorithm.

Total of 2066 iteration steps.

@3

Estimates and standard errors

Rate parameters:

0.1	Rate parameter period 1	2.4088 (0.4773)
0.2	Rate parameter period 2	4.5095 (0.6579)

Other parameters:

1. eval: degree (density)	-1.8566 (0.1078)
2. eval: transitive triads	1.0536 (0.1333)
3. eval: degree of alter	0.0089 (0.0434)
4. eval: 1.objava similarity	0.1265 (0.2896)
5. eval: same Raz.Skupina	0.4280 (0.1198)
6. eval: IFArticles	0.0210 (0.0214)
7. eval: DegreeOut	0.0226 (0.0052)

@3

Covariance matrices

Covariance matrix of estimates (correlations below diagonal):

0.012	0.003	-0.003	-0.001	-0.005	0.001	0.000
0.229	0.018	-0.003	0.001	-0.001	0.002	0.000
-0.633	-0.556	0.002	-0.001	0.000	-0.001	0.000
-0.035	0.020	-0.086	0.084	0.004	0.000	0.000
-0.402	-0.072	0.073	0.126	0.014	0.000	0.000
0.625	0.547	-0.974	0.044	-0.099	0.000	0.000
0.370	0.372	-0.703	0.197	0.095	0.563	0.000

Derivative matrix of expected statistics X by parameters and covariance/correlation matrix of X are written to file mat_pr2_3.log.

Total computation time 1875.73 seconds.

```

*****
bio_pr2_3.out
*****

Filename is bio_pr2_3.out.

This file contains primary output for SIENA project <>bio_pr2_3>>.
File bio_pr2_3.log contains secondary output.

Date and time: 1/12/2011 3:24:18 PM

SIENA version 3.181 (08 April 10)

@1
Data input.
=====
Read basic information file bio_pr2_3.in.
3 observations,
105 actors,
1 dependent network variable,
0 dependent actor variables,
2 files with constant actor covariates,
2 exogenous changing actor covariates,
0 constant dyadic covariates,
0 exogenous changing dyadic covariates,
no file with times of composition change.

@2
Reading network variables.
-----
Reading digraph files for the 1st network variable:

File bio2.mat contains observation moment 1.
nonzero code is 1; missing codes are .... (none).
File bio3.mat contains observation moment 2.
nonzero code is 1; missing codes are .... (none).
File bio4.mat contains observation moment 3.
nonzero code is 1; missing codes are .... (none).

For file bio2.mat, degree distributions are as follows:
Nodes
  1  2   3   4   5   6   7   8   9   10  11  12  13  14  15  16  17  18  19  20
  21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40
  41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60
  61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80
  81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99100
101102103104105

out-degrees
  5   3   5   4   0   1   1   3   4   5   4   2   1   3   4   0   3   3   0
  0   0   1   2   0   1   2   0   0   0   0   0   5   0   0   1   0   0   0   2
  1   2   0   0   0   7   2   2   0   0   0   0   0   0   0   0   0   0   0   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   1   0   0   0   2   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   1   0   0   0   0   0
  0   0   0   0   0

in-degrees
  5   3   5   4   0   1   1   1   3   4   5   4   2   1   3   4   0   3   3   0
  0   0   1   2   0   1   2   0   0   0   0   0   5   0   0   1   0   0   0   2
  1   2   0   0   0   7   2   2   0   0   0   0   0   0   0   0   0   0   0   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   1   0   0   0   2   0
  0   0   0   0   0   0   0   0   0   0   0   0   0   0   1   0   0   0   0   0
  0   0   0   0   0

The input file contains codes for structurally determined values:
  8164 structural zeros were found (code 10).
    0 structural one was found (code 11).
Actors 22, 25, 28, 29, 30, 31, 32, 37, 38, 39,
45, 49, 50, 52, 54, 55, 56, 59, 62, 63,
65, 66, 67, 68, 69, 71, 72, 73, 75, 76,
77, 79, 81, 82, 83, 86, 87, 88, 89, 90,
91, 92, 93, 95, 97, 98, 99, 100, 101, 102,
103, 104, are inactive at this observation.
The structurally free (non-determined) values separate
the actors into 53 components:
component      actors
  1           1   2   3   4   5   6   7   8   9   10
                11  12  13  14  15  16  17  18  19  20
  21          23  24  26  27  33  34  35  36  37
```

41	42	43	44	46	47	48	51	53	57
58	60	61	64	70	74	78	80	84	85
94	96	105							
2	22 (inactive)								
3	25 (inactive)								
4	28 (inactive)								
5	29 (inactive)								
6	30 (inactive)								
7	31 (inactive)								
8	32 (inactive)								
9	37 (inactive)								
10	38 (inactive)								
11	39 (inactive)								
12	45 (inactive)								
13	49 (inactive)								
14	50 (inactive)								
15	52 (inactive)								
16	54 (inactive)								
17	55 (inactive)								
18	56 (inactive)								
19	59 (inactive)								
20	62 (inactive)								
21	63 (inactive)								
22	65 (inactive)								
23	66 (inactive)								
24	67 (inactive)								
25	68 (inactive)								
26	69 (inactive)								
27	71 (inactive)								
28	72 (inactive)								
29	73 (inactive)								
30	75 (inactive)								
31	76 (inactive)								
32	77 (inactive)								
33	79 (inactive)								
34	81 (inactive)								
35	82 (inactive)								
36	83 (inactive)								
37	86 (inactive)								
38	87 (inactive)								
39	88 (inactive)								
40	89 (inactive)								
41	90 (inactive)								
42	91 (inactive)								
43	92 (inactive)								
44	93 (inactive)								
45	95 (inactive)								
46	97 (inactive)								
47	98 (inactive)								
48	99 (inactive)								
49	100 (inactive)								
50	101 (inactive)								
51	102 (inactive)								
52	103 (inactive)								
53	104 (inactive)								

No missing data for observation 1 (file bio2.mat).

For file bio3.mat, degree distributions are as follows:

Nodes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80
	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
	101	10102103104105																		
out-degrees	12	2	5	3	1	3	1	0	0	2	5	7	4	3	5	2	2	4	1	0
	1	1	1	2	0	1	1	2	0	0	1	0	2	1	0	1	0	0	0	5
	4	2	0	0	0	1	2	2	1	0	0	0	2	2	0	0	1	0	0	2
	0	2	0	3	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
	0	0	0	0	1	0	0	0	1	0	3	3	0	0	0	0	0	0	0	0
	0	0	0	0	1	0	0	0	1	0	3	3	0	0	0	0	0	0	0	0
in-degrees	12	2	5	3	1	3	1	0	0	2	5	7	4	3	5	2	2	4	1	0
	1	1	1	2	0	1	1	2	0	0	1	0	2	1	0	1	0	0	0	5
	4	2	0	0	0	1	2	2	1	0	0	0	2	2	0	0	1	0	0	2
	0	2	0	3	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0
	0	0	0	0	1	0	0	0	1	0	3	3	0	0	0	0	0	0	0	0

The input file contains codes for structurally determined values:
4600 structural zeros were found (code 10).

0 structural one was found (code 11).
 Actors 45, 55, 56, 63, 67, 69, 71, 73, 75, 79,
 81, 82, 83, 86, 87, 88, 90, 93, 95, 97,
 99, 101, 102, 103, 104, are inactive at this observation.
 The structurally free (non-determined) values separate
 the actors into 26 components:

component	actors
1	1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40 31 32 33 34 35 36 37 38 39 40 41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60 52 53 54 55 56 57 58 59 60 61 62 64 65 66 68 70 72 74 76 77 78 80 84 85 89 91 92 94 96 98 100 105
2	45 (inactive)
3	55 (inactive)
4	56 (inactive)
5	63 (inactive)
6	67 (inactive)
7	69 (inactive)
8	71 (inactive)
9	73 (inactive)
10	75 (inactive)
11	79 (inactive)
12	81 (inactive)
13	82 (inactive)
14	83 (inactive)
15	86 (inactive)
16	87 (inactive)
17	88 (inactive)
18	90 (inactive)
19	93 (inactive)
20	95 (inactive)
21	97 (inactive)
22	99 (inactive)
23	101 (inactive)
24	102 (inactive)
25	103 (inactive)
26	104 (inactive)

No missing data for observation 2 (file bio3.mat).

For file bio4.mat, degree distributions are as follows:

Nodes

1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80
81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100

101102103104105

out-degrees

13	2	5	0	6	3	0	1	7	16	19	9	8	7	2	1	6	1	0	
8	6	4	2	3	1	4	2	7	0	3	0	0	2	0	13	0	2	3	6
4	4	0	0	2	3	2	2	6	0	3	9	2	1	0	2	0	0	1	1
4	7	8	3	0	2	2	0	1	0	1	1	0	0	0	2	5	1	0	3
1	2	3	2	2	0	3	3	0	2	5	1	1	0	0	0	1	2	0	3
0	5	1	1	0															

in-degrees

13	2	5	0	6	3	0	1	7	16	19	9	8	7	2	1	6	1	0	
8	6	4	2	3	1	4	2	7	0	3	0	0	2	0	13	0	2	3	6
4	4	0	0	2	3	2	2	6	0	3	9	2	1	0	2	0	0	1	1
4	7	8	3	0	2	2	0	1	0	1	1	0	0	0	2	5	1	0	3
1	2	3	2	2	0	3	3	0	2	5	1	1	0	0	0	1	2	0	3
0	5	1	1	0															

No missing data for observation 3 (file bio4.mat).

Name of this network variable:(none given).

@2
 Reading constant actor covariates.

 Covariate data file bio_prvao.dat with 1 variables, named:
 1.QJAVA (code for missing data is 1).
 Covariate data file bio_razskup.dat with 1 variables, named:
 RAZ.SKUPINA (code for missing data is 9999).

A total of 2 non-changing individual covariates.

Number of missing cases:

```

1.objava      0  ( 0.0 %)
Raz.Skupina   4  ( 3.8 %)

Information about covariates (missings not counted):
      minimum   maximum   mean
1.objava     1974.0  2005.0  1993.314
Raz.Skupina    4.0    175.0   46.287

The mean values are subtracted from the covariates.

@2
Reading exogenous changing actor covariates.
-----

Exogenous changing covariate named IFARTICLES read from file bio_pr2_3_stcIF.din.
No code for missing data is specified; SIENA will treat scores of -9 as missing data.
Exogenous changing covariate named DEGREEOUT read from file bio_pr2_3_nondiscDegree.din.
No code for missing data is specified; SIENA will treat scores of -9 as missing data.

A total of 2 exogenous changing actor covariates.

Number of missing cases per period:
  period      1      2      overall
IFArticles    0      0      0  ( 0.0 %)
DegreeOut     0      0      0  ( 0.0 %)

Information about changing covariates:
      minimum   maximum   mean
IFArticles
  period  1    0.0    11.0    0.790
  period  2    0.0    21.0    2.124
Overall          1.457

DegreeOut
  period  1    0.0    49.0    3.581
  period  2    0.0    74.0    8.133
Overall          5.857

The overall mean values are subtracted from the covariates.

For the similarity variable calculated from each actor covariate,
the mean is subtracted.
These means are :
Similarity 1.objava :      0.6901
Similarity Raz.Skupina :    0.7510
Similarity IFArticles :    0.8880
Similarity DegreeOut :    0.8831

The mean structural dissimilarity value subtracted in the
balance calculations is      0.0178 .

Siena version 3.181 (08 April 10)

@1
Initial data description.
=====

@2
Change in networks:
=====

For the following statistics, missing values (if any) are not counted.
Further, structurally determined entries are treated as observed entries.
All 3 observed networks are symmetric.
Therefore, it is assumed that this is an analysis of an non-directed relation.

Network density indicators:
observation time      1      2      3
density            0.008  0.011  0.027
average degree     0.800  1.105  2.800
number of ties       42      58     147
missing fraction    0.000  0.000  0.000

Edge changes between subsequent observations:
  periods      0 => 0  0 => 1  1 => 0  1 => 1  Distance  Jaccard  Missing

```

```

1 ==> 2      5383      35      19      23      38      0.299      0 ( 0%)
2 ==> 3      5298     104      15      43      82      0.265      0 ( 0%)

```

Distances do not consider structurally fixed network ties.
This may imply that the columns 0 => 1 and 1 => 0 do not add up to the distance column.
(The distances reported in the output file for conditional estimation
for the network variable refer to the total symmetric adjacency matrix,
and therefore are double the distance reported above.)

```

Dyad counts:
observation   total    mutual    asymm.    null
1.           5460      42        0       5418
2.           5460      58        0       5402
3.           5460     147        0       5313

```

Standard values for initial parameter values

```

-----
constant network rate (period 1)          1.4651
constant network rate (period 2)          3.1571
degree (density)                         -1.4221
- and zero for all other parameters
-----
```

Siena version 3.181 (08 April 10)
Model descriptions are written to file bio_pr2_3.log.

A list of objective function effects is given in file bio_pr2_3.eff.
The numbers in this list can be used for specifying interaction effects (see the SIENA manual).

Initialisation of project <>bio_pr2_3> executed successfully.

```

-----
New analysis started.
Date and time: 1/17/2011 8:56:22 AM
New results follow.
-----
```

Siena version 3.181 (08 April 10)

```

@1
Estimation by stochastic approximation algorithm.
=====
```

```

Random initialization of random number stream.
Current random number seed is 3383011.
Model Type 2: Initiative - confirmation.
Estimation method: conditional moment estimation.
Conditioning variable is the total number of observed changes ("distance")
in the network variable.
Distances for simulations are
period : 1 2
distance : 76 164 .
Standard errors are estimated with the finite difference method.
Initial value of gain parameter is 0.2000000 .
Number of subphases in Phase 2 is 4.
```

```

Initial parameter values are
 0.1 Rate parameter period 1          4.6835
 0.2 Rate parameter period 2          5.2335
 1. eval: degree (density)          -1.9870
 2. eval: transitive triads          0.8041
 3. eval: degree of alter           0.0183
 4. eval: 1.objava similarity       -1.1412
 5. eval: same Raz.Skupina          1.1237
 6. eval: IFArticles                0.0200
 7. eval: DegreeOut                 0.0102
```

```

Observed values of target statistics are
 1. Number of edges                  152.0000
 2. Number of transitive triads      118.0000
 3. Sum of squared degrees          1700.0000
 4. Similarity on 1.objava          -4.0335
 5. Same values on Raz.Skupina      154.0000
 6. Sum of degrees [U+FFFD] IFArticles 807.0416
 7. Sum of degrees [U+FFFD] DegreeOut 3220.4416
```

7 parameters, 7 statistics
Estimation of derivatives by the finite differences method.

```

@2
End of stochastic approximation algorithm, phase 3.
```

Total of 2701 iterations.
Parameter estimates based on 1701 iterations,
basic rate parameters as well as
convergence diagnostics, covariance and derivative matrices based on 1000 iterations.

Information for convergence diagnosis.
Averages, standard deviations, and t-ratios for deviations from targets:
1. 0.800 11.575 0.069
2. 1.141 21.559 0.053
3. 15.932 239.436 0.067
4. 0.075 4.316 0.017
5. 0.200 14.888 0.013
6. 7.553 112.719 0.067
7. 30.702 393.820 0.078

Good convergence is indicated by the t-ratios being close to zero.

@2
Estimation results.

Regular end of estimation algorithm.
Total of 2701 iteration steps.

@3
Estimates and standard errors

Rate parameters:
0.1 Rate parameter period 1 4.6204 (1.3483)
0.2 Rate parameter period 2 4.9123 (0.7337)

Other parameters:
1. eval: degree (density) -1.9444 (0.1170)
2. eval: transitive triads 1.0531 (0.1230)
3. eval: degree of alter 0.0309 (0.0192)
4. eval: 1.objava similarity -1.1867 (0.3573)
5. eval: same Raz.Skupina 1.1907 (0.1681)
6. eval: IFArticles 0.0378 (0.0359)
7. eval: DegreeOut 0.0057 (0.0221)

@3
Covariance matrices

Covariance matrix of estimates (correlations below diagonal):
0.014 -0.007 -0.001 0.006 -0.008 -0.002 0.001
-0.473 0.015 0.000 -0.014 0.002 0.001 -0.001
-0.456 0.207 0.000 0.000 0.001 0.000 0.000
0.152 -0.316 0.037 0.128 0.000 0.005 -0.002
-0.384 0.076 0.169 0.006 0.028 0.002 -0.001
-0.382 0.115 0.455 0.359 0.259 0.001 -0.001
0.470 -0.197 -0.854 -0.222 -0.230 -0.805 0.000

Derivative matrix of expected statistics X by parameters and
covariance/correlation matrix of X are written to file bio_pr2_3.log.

Total computation time 1171.14 seconds.

```

*****
soc_pr2_3.out
*****
*****
```

Filename is soc_pr2_3.out.

This file contains primary output for SIENA project <>soc_pr2_3>>.
File soc_pr2_3.log contains secondary output.

Date and time: 1/12/2011 3:28:11 PM

SIENA version 3.181 (08 April 10)

```

@1
Data input.
=====
Read basic information file soc_pr2_3.in.
3 observations,
117 actors,
1 dependent network variable,
0 dependent actor variables,
2 files with constant actor covariates,
2 exogenous changing actor covariates,
0 constant dyadic covariates,
0 exogenous changing dyadic covariates,
no file with times of composition change.
```

```

@2
Reading network variables.
-----
Reading digraph files for the 1st network variable:
```

File soc2.mat contains observation moment 1.
nonzero code is 1; missing codes are (none).
File soc3.mat contains observation moment 2.
nonzero code is 1; missing codes are (none).
File soc4.mat contains observation moment 3.
nonzero code is 1; missing codes are (none).

For file soc2.mat, degree distributions are as follows:

```

Nodes
 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20
21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40
41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60
61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80
81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99100
10110210310410510610710810911011112113114115116117
```

```

out-degrees
 3 0 4 0 4 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 0 3 0 0 0 0 2 2 0 2 0 0 0 0 0 1 0 0 0 1 0 0
 1 0 0 0 0 0 0 0 0 0 0 3 0 0 0 0 3 1 0 1 0
 1 0 0 0 0 0 2 0 0 1 3 0 0 0 2 0 0 0 1 0 0
 0 0 1 0 0 3 0 1 0 0 1 2 0 0 0 0 0 0 0 0 0 0
 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
```

```

in-degrees
 3 0 4 0 4 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
 0 3 0 0 0 0 2 2 0 2 0 0 0 0 0 1 0 0 0 1 0 0
 1 0 0 0 0 0 0 0 0 0 0 3 0 0 0 0 3 1 0 1 0
 1 0 0 0 0 0 2 0 0 1 3 0 0 0 2 0 0 0 1 0 0
 0 0 1 0 0 3 0 1 0 0 1 2 0 0 0 0 0 0 0 0 0 0
 0 1 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
```

The input file contains codes for structurally determined values:
7252 structural zeros were found (code 10).
0 structural one was found (code 11).
Actors 9, 12, 36, 42, 54, 62, 66, 68, 72, 73,
77, 81, 82, 84, 85, 87, 89, 90, 93, 95,
96, 99, 100, 103, 104, 105, 106, 107, 108, 109,
110, 111, 112, 114, 115, 116, 117, are inactive at this observation.
The structurally free (non-determined) values separate
the actors into 38 components:

component	actors
1	1 2 3 4 5 6 7 8 10 11
	13 14 15 16 17 18 19 20 21 22
	23 24 25 26 27 28 29 30 31 32
	33 34 35 37 38 39 40 41 43 44
	45 46 47 48 49 50 51 52 53 55
	56 57 58 59 60 61 63 64 65 67
	69 70 71 74 75 76 78 79 80 83
	86 88 91 92 94 97 98 101 102 113

```

2      9 (inactive)
3     12 (inactive)
4     36 (inactive)
5     42 (inactive)
6     54 (inactive)
7     62 (inactive)
8     66 (inactive)
9     68 (inactive)
10    72 (inactive)
11    73 (inactive)
12    77 (inactive)
13    81 (inactive)
14    82 (inactive)
15    84 (inactive)
16    85 (inactive)
17    87 (inactive)
18    89 (inactive)
19    90 (inactive)
20    93 (inactive)
21    95 (inactive)
22    96 (inactive)
23    99 (inactive)
24   100 (inactive)
25   103 (inactive)
26   104 (inactive)
27   105 (inactive)
28   106 (inactive)
29   107 (inactive)
30   108 (inactive)
31   109 (inactive)
32   110 (inactive)
33   111 (inactive)
34   112 (inactive)
35   114 (inactive)
36   115 (inactive)
37   116 (inactive)
38   117 (inactive)

```

No missing data for observation 1 (file soc2.mat).

For file soc3.mat, degree distributions are as follows:

Nodes

```

1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20
21 22 23 24 25 26 27 28 29 30 31 32 33 34 35 36 37 38 39 40
41 42 43 44 45 46 47 48 49 50 51 52 53 54 55 56 57 58 59 60
61 62 63 64 65 66 67 68 69 70 71 72 73 74 75 76 77 78 79 80
81 82 83 84 85 86 87 88 89 90 91 92 93 94 95 96 97 98 99 100
101 102 103 104 105 106 107 108 109 110 111 112 113 114 115 116 117

```

out-degrees

```

7 4 7 1 2 4 4 0 0 0 0 0 2 1 0 0 0 6 0 0
0 8 0 0 0 0 14 4 0 5 8 0 0 0 4 0 0 1 1 0
7 1 1 0 0 5 0 0 1 10 1 6 2 0 0 11 3 1 6 6
0 0 5 0 6 0 10 0 0 1 2 0 2 13 11 0 0 1 8 0
0 0 13 0 0 6 0 1 0 0 3 2 0 0 0 0 0 10 0 0
3 7 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

```

in-degrees

```

7 4 7 1 2 4 4 0 0 0 0 0 2 1 0 0 0 6 0 0
0 8 0 0 0 0 14 4 0 5 8 0 0 0 4 0 0 1 1 0
7 1 1 0 0 5 0 0 1 10 1 6 2 0 0 11 3 1 6 6
0 0 5 0 6 0 10 0 0 1 2 0 2 13 11 0 0 1 8 0
0 0 13 0 0 6 0 1 0 0 3 2 0 0 0 0 0 10 0 0
3 7 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0

```

The input file contains codes for structurally determined values:

3066 structural zeros were found (code 10).

0 structural ones was found (code 11).

Actors 9, 82, 85, 90, 99, 103, 104, 105, 106, 107,

109, 110, 114, 117, are inactive at this observation.

The structurally free (non-determined) values separate

the actors into 15 components:

component actors

1	1	2	3	4	5	6	7	8	10	11
	12	13	14	15	16	17	18	19	20	21
	22	23	24	25	26	27	28	29	30	31
	32	33	34	35	36	37	38	39	40	41
	42	43	44	45	46	47	48	49	50	51
	52	53	54	55	56	57	58	59	60	61
	62	63	64	65	66	67	68	69	70	71
	72	73	74	75	76	77	78	79	80	81
	83	84	86	87	88	89	91	92	93	94
	95	96	97	98	100	101	102	108	111	112
	113	115	116							

```

2          9 (inactive)
3         82 (inactive)
4         85 (inactive)
5         90 (inactive)
6         99 (inactive)
7        103 (inactive)
8        104 (inactive)
9        105 (inactive)
10       106 (inactive)
11       107 (inactive)
12       109 (inactive)
13       110 (inactive)
14       114 (inactive)
15       117 (inactive)

```

No missing data for observation 2 (file soc3.mat).

For file soc4.mat, degree distributions are as follows:

Nodes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	37	38	39	40
	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57	58	59	60
	61	62	63	64	65	66	67	68	69	70	71	72	73	74	75	76	77	78	79	80
	81	82	83	84	85	86	87	88	89	90	91	92	93	94	95	96	97	98	99	100
	101	102	103	104	105	106	107	108	109	110	111	112	113	114	115	116	117			
out-degrees	14	3	2	7	5	3	0	0	0	0	3	9	2	2	4	0	9	1	1	
	0	7	0	0	0	10	4	0	10	9	0	1	0	7	2	0	0	0	0	
	10	4	2	3	0	4	1	3	2	9	8	13	7	1	0	9	2	6	11	
	4	1	6	3	12	0	9	0	0	2	5	0	12	9	12	1	4	2	5	
	1	0	10	1	0	7	4	5	0	1	12	2	1	0	0	0	8	9	4	
	4	6	3	2	4	0	0	0	1	0	4	1	0	0	0	3	0			
in-degrees	14	3	2	7	5	3	0	0	0	0	0	3	9	2	2	4	0	9	1	
	0	7	0	0	0	0	10	4	0	10	9	0	1	0	7	2	0	0	0	
	10	4	2	3	0	4	1	3	2	9	8	13	7	1	0	9	2	6	11	
	4	1	6	3	12	0	9	0	0	2	5	0	12	9	12	1	4	2	5	
	1	0	10	1	0	7	4	5	0	1	12	2	1	0	0	0	8	9	4	
	4	6	3	2	4	0	0	0	1	0	4	1	0	0	0	3	0			

No missing data for observation 3 (file soc4.mat).

Name of this network variable:(none given).

```

@2
Reading constant actor covariates.
-----

```

```

Covariate data file soc_prvao.dat with 1 variables, named:
1.OBJAVA (code for missing data is 1).
Covariate data file soc_razskup.dat with 1 variables, named:
RAZ.SKUPINA (code for missing data is 9999).

```

A total of 2 non-changing individual covariates.

```

Number of missing cases:
1.objava      0  ( 0.0 %)
Raz.Skupina   3  ( 2.6 %)

```

```

Information about covariates (missings not counted):
           minimum   maximum   mean
1.objava    1962.0   2003.0   1988.427
Raz.Skupina  28.0     177.0    85.763

```

The mean values are subtracted from the covariates.

```

@2
Reading exogenous changing actor covariates.
-----

```

```

Exogenous changing covariate named IFARTICLES read from file soc_pr2_3_stcIF.din.
No code for missing data is specified; SIENA will treat scores of -9 as missing data.
Exogenous changing covariate named DEGREEOUT read from file soc_pr2_3_nondiscDegree.din.
No code for missing data is specified; SIENA will treat scores of -9 as missing data.

```

A total of 2 exogenous changing actor covariates.

```

Number of missing cases per period:
  period      1        2      overall
IFArticles    0        0        0  ( 0.0 %)
DegreeOut     0        0        0  ( 0.0 %)

```

```

Information about changing covariates:
      minimum   maximum     mean
IFArticles
  period 1    0.0    6.0    0.137
  period 2    0.0    5.0    0.162
Overall                      0.150

DegreeOut
  period 1    0.0   14.0    1.000
  period 2    0.0   54.0    5.350
Overall                      3.175

```

The overall mean values are subtracted from the covariates.

```

For the similarity variable calculated from each actor covariate,
the mean is subtracted.
These means are :
Similarity objava : 0.7212
Similarity Raz.Skupina : 0.7781
Similarity IFArticles : 0.9524
Similarity DegreeOut : 0.9110

```

The mean structural dissimilarity value subtracted in the
balance calculations is 0.0210 .

Siena version 3.181 (08 April 10)

```

@1
Initial data description.
=====

```

```

@2
Change in networks:
=====

```

```

For the following statistics, missing values (if any) are not counted.
Further, structurally determined entries are treated as observed entries.
All 3 observed networks are symmetric.
Therefore, it is assumed that this is an analysis of an non-directed relation.

```

Network density indicators:	1	2	3
observation time	0.004	0.018	0.029
density	0.444	2.120	3.402
average degree	26	124	199
number of ties	0.000	0.000	0.000
missing fraction			

Edge changes between subsequent observations:	0 => 0	0 => 1	1 => 0	1 => 1	Distance	Jaccard	Missing
periods	0 => 0	0 => 1	1 => 0	1 => 1			
1 => 2	6652	108	10	16	115	0.119	0 (0%)
2 => 3	6542	120	45	79	151	0.324	0 (0%)

Distances do not consider structurally fixed network ties.
This may imply that the columns 0 => 1 and 1 => 0 do not add up to the distance column.
(The distances reported in the output file for conditional estimation
for the network variable refer to the total symmetric adjacency matrix,
and therefore are double the distance reported above.)

Dyad counts:	total	mutual	asymm.	null
observation				
1.	6786	26	0	6760
2.	6786	124	0	6662
3.	6786	199	0	6587

Standard values for initial parameter values

constant network rate (period 1)	3.9684
constant network rate (period 2)	5.2096
degree (density)	-1.4562
- and zero for all other parameters	

Siena version 3.181 (08 April 10)
Model descriptions are written to file soc_pr2_3.log.

A list of objective function effects is given in file soc_pr2_3.eff.

The numbers in this list can be used for specifying interaction effects (see the SIENA manual).

Initialisation of project <>soc_pr2_3> executed successfully.

```
-----  
New analysis started.  
Date and time: 1/17/2011 7:31:25 AM  
New results follow.  
-----
```

Siena version 3.181 (08 April 10)

```
@1  
Estimation by stochastic approximation algorithm.  
=====
```

```
Random initialization of random number stream.  
Current random number seed is 1886231.  
Model Type 2: Initiative - confirmation.  
Estimation method: conditional moment estimation.  
Conditioning variable is the total number of observed changes ("distance")  
in the network variable.  
Distances for simulations are  
period : 1 2  
distance : 230 302 .  
Standard errors are estimated with the finite difference method.  
Initial value of gain parameter is 0.2000000 .  
Number of subphases in Phase 2 is 4.
```

```
Initial parameter values are  
0.1 Rate parameter period 1 10.9440  
0.2 Rate parameter period 2 8.4827  
1. eval: degree (density) -1.6422  
2. eval: transitive triads 0.7727  
3. eval: degree of alter 0.0164  
4. eval: 1.objava similarity -0.2636  
5. eval: same Raz.Skupina 1.3500  
6. eval: IFArticles 0.2260  
7. eval: DegreeOut -0.0792
```

Observed values of target statistics are

1. Number of edges	306.0000
2. Number of transitive triads	393.0000
3. Sum of squared degrees	4710.0000
4. Similarity on 1.objava	13.7712
5. Same values on Raz.Skupina	280.0000
6. Sum of degrees [U+FFFD] IFArticles	74.4448
7. Sum of degrees [U+FFFD] DegreeOut	2467.7776

7 parameters, 7 statistics

Estimation of derivatives by the finite differences method.

```
@2  
End of stochastic approximation algorithm, phase 3.  
-----
```

Total of 2415 iterations.
Parameter estimates based on 1415 iterations,
basic rate parameters as well as
convergence diagnostics, covariance and derivative matrices based on 1000 iterations.

Information for convergence diagnosis.

Averages, standard deviations, and t-ratios for deviations from targets:

1.	0.290	15.220	0.019
2.	-0.417	83.158	-0.005
3.	-11.346	637.393	-0.018
4.	0.346	5.314	0.065
5.	0.466	21.375	0.022
6.	1.365	26.573	0.051
7.	3.050	404.788	0.008

Good convergence is indicated by the t-ratios being close to zero.

```
@2  
Estimation results.  
-----
```

Regular end of estimation algorithm.
Total of 2415 iteration steps.

```

@3
Estimates and standard errors

Rate parameters:
 0.1 Rate parameter period 1          10.8563  (  1.7080)
 0.2 Rate parameter period 2          8.0483  (  1.1610)

Other parameters:
 1. eval: degree (density)           -1.7807  (  0.0576)
 2. eval: transitive triads          0.7626  (  0.0644)
 3. eval: degree of alter           0.0345  (  0.0054)
 4. eval: 1.objava similarity       -0.2308  (  0.2690)
 5. eval: same Raz.Skupina          1.3926  (  0.1090)
 6. eval: IFArticles                0.2426  (  0.0596)
 7. eval: DegreeOut                 -0.0894  (  0.0088)

@3
Covariance matrices

Covariance matrix of estimates (correlations below diagonal):
 0.003   -0.001    0.000    0.000   -0.001    0.000    0.000
 -0.373    0.004    0.000   -0.002    0.000    0.000    0.000
 -0.088    0.075    0.000    0.000    0.000    0.000    0.000
 -0.006   -0.095   -0.247    0.072   -0.003    0.003    0.000
 -0.165    0.053    0.136   -0.089    0.012    0.001    0.000
 -0.085   -0.011    0.010    0.170    0.105    0.004    0.000
  0.113   -0.159   -0.661    0.104   -0.147   -0.321    0.000

Derivative matrix of expected statistics X by parameters and
covariance/correlation matrix of X are written to file soc_pr2_3.log.

Total computation time 1580.65 seconds.

```


Stvarno kazalo

- Albert 71, 72, 74, 191
Allison 68, 191
Andrade 40, 183, 191
ARRS 110, 191
Babchuk 59, 191
Bala 78, 191
Barabási 56, 62, 71, 72, 74, 186, 191
Batagelj 72, 94-96, 191, 192
Bayer 59, 192
Beaver 35, 37, 38, 45, 192, 201
Berg 65, 70, 192
Berkowitz 51, 205
Bonacich 56, 192
Bordons 43, 192
Braun 39, 44, 192
Bucchi 68, 192
Burt 67, 192
Buter 43, 193
Carley 54, 57, 196
Cassiman 39, 204
center-periferija, 49, 92, 129
COBISS, 50, 107
Cole 68, 193
Coleman 77, 193
Connor 109, 199
Crane 37, 71, 83, 193
Cronin 47, 193
Cullen 92, 193
časovne vrste, 90, 120
Davidson 79, 193
De Haan 52, 193
de Sola Pool 65, 74, 193
de Lange 48, 82, 193, 195
de Nooy 119, 120, 193
disciplina, 32, 33, 37, 38, 41, 109
lab, 83, 109, 117, 180, 186
office, 83, 109, 180, 186
Demšar 81, 193
Doreian 53-55, 57, 60, 93-96, 131, 132, 193, 194
Doreian 54, 57, 60, 93-96, 131, 132, 193, 196
Durkheim 108, 194
Erdős 62, 64, 194
Erjavec 97, 163, 194
Erten 61, 194
Etzkowitz 39, 42, 46, 81, 194
Faust 51, 89, 204
Ferligoj 82, 83, 96, 132, 194
Fienberg 76, 194
Fienbergn 76, 194
Forsythe 92, 194
Frank 56, 75, 195
Freeman 53, 57, 195
Gómez 48, 195
Gansner 61, 195
Garfield 53, 58, 195
geografski, 38, 40, 46, 110, 111, 183
Georghiou 48, 195
Gibbons 39, 42, 46, 195
Glänsel 38-40, 42, 44, 47-49, 59, 82, 193, 195
Goldstein 33, 195
Gossart 50, 196
gostota, 59, 89, 98, 103, 117, 119, 120, 125, 126, 168, 178

- Goyal 78, 191
 graf, 51, 56, 62, 74, 171
 slučajni, 64, 74, 168, 170
 Granovetter 51, 71, 196
 Hagstrom 36, 38, 109, 196
 Han 39, 109, 196
 Handcock 56, 196
 Hargens 41, 108, 186, 196
 Havemann 39, 196
 Heffner 37, 196
 Holland 76, 77, 196
 Hollandt 56, 76, 196
 Hornbostel 39, 42, 196
 Hummon 54, 57, 78, 79, 196, 197
 Hwang 92, 197
 Iacobucci 76, 204
 integracija, 41, 108, 109
 Jhah 46, 197
 Jin 79, 197
 Kajnč 81, 197
 Katz 35, 37, 38, 40, 47, 52, 75, 83,
 109, 197
 Kejžar 64, 197
 Kochen 65, 74, 193
 koeficient grozdenja, 59, 64–67, 73,
 79, 90, 98, 104, 117, 119, 125,
 129, 168, 170
 Kronegger
 Kronegger 59, 61, 82, 83, 194, 197
 Kuhn 49, 55, 83, 197
 kumulativna prednost, 68
 Laband 39, 42, 197
 Latapy 73, 197
 Laudel 36, 52, 198
 Lazega 80, 198
 Leahey 83, 198
 Leenders 78, 198
 Leinhardt 56, 76, 77, 196
 lematizator, 97
 Leydesdorff 39, 42, 46, 48, 61, 62, 74,
 81, 194, 198, 204
 Li 33, 198
 Lorrain 60, 93, 94, 198
 Lowriet 39, 46, 198
 Luthi 74, 203
 makro nivo, 62
 Mali 40, 42, 46, 50, 67, 81, 82, 198,
 199
 Marsden 51, 199
 Marshakova-Shaikevich 82, 199
 Marsili 79, 199
 Martin 35, 37, 38, 40, 83, 109, 197
 matrika, 75, 94, 96, 132
 Matthew 68, 199
 Mattison 39, 199
 Mayer 77, 199
 McKnight 39, 46, 198
 Meadows 109, 199
 Melin 52, 199
 Merton 35, 53, 68, 195, 199
 metoda voditeljev, 98, 163
 Miholič 81, 199
 mikro nivo, 71, 74, 100, 176
 Milgram 65, 204
 Mlinar 81, 199, 200
 model
 bločni, 93, 129
 center-periferija, 49, 92
 malih svetov, 57, 63, 65, 98
 preferenčne izbire, 57, 63, 68, 99
 stohastično modeliranje, 74, 98,
 99
 Molloy 64, 200
 Moody 38, 49, 64, 67, 74, 108, 122,
 170, 172, 200
 Morris 33, 201
 Mrvar 72, 96, 192
 Mulkay 109, 200
 Munshi 50, 200
 Newman 62, 64, 67, 72, 73, 108, 170,
 118–200
 nivo proučevanja, 31

- disciplina, 41
- država, 46
- sektor, 44
- Nooraie 61, 200
- Norgaard 38, 200
- omrežje, 51, 63, 85, 111
 - enota, 111
 - graf, 88
 - lastnosti, 89
 - matrika, 89
- Oort 46, 200
- Opsahl 73, 201
- Otteu 51, 201
- Ozman 50, 196
- Pajek, 87, 96
- Pant 50, 200
- Pattison 56, 201, 204
- Pemantle 79, 202
- Pennock 72, 201
- Pepe 39, 42, 202
- Perc 74, 82, 170, 189, 201
- Perianes-Rodríguez 83, 201
- Persson 52, 199
- Piette 38, 201
- podatki
 - enote analize, 111, 112
 - priprava, 108
- Pretes 92, 193
- Price 33, 35, 38, 45, 53, 69, 70, 82, 83, 109, 132, 201
- Proctor 75, 197
- Qin 39, 44, 201
- Rényi 62, 64, 194
- Ramascos 33, 201
- Reed 64, 200
- Reikowsky 83, 198
- Reitz 93, 95, 205
- Richardson 61, 202
- Rigby 37, 39, 202
- Rodriguez 39, 42, 202
- Rogers 40, 202
- Rosen 37, 38, 192
- Ross 38, 201
- Rousseau 51, 201
- Said 60, 83, 92, 202
- Sailer 95, 202
- Schaefer 80, 202
- Schank 61, 198
- Schubert 38–40, 42, 44, 47, 49, 83, 192, 195, 202
- SCOPUS, 50, 53
- Scott 51, 202
- semi-periferija, 130
- SICRIS, 50, 107
- SIENA, 87
- Sigogneau 39, 202
- Skyrms 79, 202
- Smart 59, 192
- Smith 37, 38, 109, 202
- Snijders 53, 56, 63, 75, 76, 78, 80, 98, 100, 102, 103, 193, 203
- Sonnenwald 40, 203
- Sooryamoorthy 49, 83, 202
- Sorčan 81, 193, 203
- Splichal 81, 200
- Stichweh 41, 203
- stohastično modeliranje, 78
- Stokman 55, 194
- Stolte-Heiskanen 49, 203
- stopnja, 120
- Strauss 56, 195
- Strogatz 62, 65, 66, 74, 98, 186, 205
- Tollison 39, 42, 197
- Tomassini 74, 203
- Torgerson 61, 203
- Travers 65, 204
- trend, 120
- Vázquez 79, 204
- večrazsežno lestvičenje, 61
- Veugelers 39, 204
- Wagner 48, 74, 204

Wallerstein 49, 83, 92, 129, 138, 186,
204
Wang 56, 204
Wasserman 51, 56, 76, 77, 89, 194,
201, 204, 205
Watts 56, 62, 65, 66, 74, 98, 186, 205
Weaver 76, 205
Web of Science, 50, 53
Weidemann 49, 197
Welch 46, 197
Wellman 51, 205
White 60, 93-95, 198, 205
Whitley 41, 205
Wray 39, 42, 188, 205
Ziherl 81, 205
Ziman 45, 47, 205
znanstveno sodelovanje, 36
definicija, 35
dejavniki, 37
nivoji proučevanja, 38
Slovenija, 81
socialno omrežje, 51
Zuckerman 53, 59, 205
zunanje spremenljivke, 86

