

Die statistische Analyse dynamischer Netzwerkdaten

Christian Steglich
Universität Groningen

Andrea Knecht
Universität Erlangen-Nürnberg

Beitrag zum „Handbuch der Netzwerkforschung“, herausgegeben von Christian Stegbauer und Roger Häußling, Wiesbaden: Verlag für Sozialwissenschaften.

Das sozialwissenschaftliche Interesse an dynamischen Netzwerkfragestellungen ergibt sich aus dem oft vorläufigen Charakter von Analysen einzelner Messungen eines Netzwerks. Solche Querschnittsanalysen lassen im allgemeinen wenig kausale Rückschlüsse zu und bieten daher lediglich ein eingeschränktes Verständnis des Netzwerkes. So kann man mit klassischen (d.h., beschreibenden) Querschnittsverfahren z.B. den Zusammenhang zwischen strukturellen Eigenschaften der Akteure im Netzwerk und ihren individuellen Eigenschaften studieren. Beispiele hierfür finden sich überall in der Netzwerkliteratur, zu denken wäre etwa an den Zusammenhang zwischen *strukturellen Löchern* in Netzwerken von Managern und deren *Arbeitsleistung* (Burt, 1992), zwischen *strukturell kohäsiven* Netzwerkregionen und *Kooperation* der Akteure (Gould, 1993), oder zwischen *Segregation* von Netzwerken und *Ethnizität, Geschlecht* oder *Verhaltensdimensionen* der Akteure (Moody, 2001; Knecht, 2008). Solche beschreibenden Analysen einzelner Netzwerke werfen aber vor allem die Frage auf, wie sich der gefundene Zusammenhang erklären lässt. Oft gibt es verschiedene Erklärungen für denselben Sachverhalt. Am Beispiel der Theorie struktureller Löcher illustriert wäre die Frage zu beantworten, ob tatsächlich die Fähigkeit individueller Manager, unverbundene Netzwerkregionen zu vernetzen, zu ihrem Berufserfolg beiträgt – oder ob nicht vielmehr umgekehrt ihr Berufserfolg es ihnen erst ermöglicht, von unverbundenen Netzwerkregionen Kenntnis zu erhalten, und ihnen erst eine formelle Position zuteil werden lässt, in der sie diese Kenntnis auch ausnutzen können. Empirisch lassen sich diese Erklärungen nur dann voneinander unterscheiden, wenn man longitudinale Daten zur Verfügung hat. Wie das Beispiel verdeutlicht sind es oft gerade die Prozesse, die zur Entstehung eines beobachteten Netzwerks führten, die von inhaltlichem Interesse sind. In vielen Fällen lassen sich Netzwerkdaten daher als Momentaufnahme eines Evolutionsprozesses verstehen. Dem beschreibenden Schritt der Analyse einer solchen Momentaufnahme folgt dann auf natürliche Weise der im Verständnis tiefer gehende Schritt der Analyse der generierenden Netzwerkdynamik, den wir in diesem Kapitel behandeln wollen.

Wie bei der Analyse von Netzwerk-Querschnittsdaten, ist auch für den Fall dynamischer Daten zu zwischen zwei Möglichkeiten der Datenerhebung zu unterscheiden. Es gibt einerseits die ego-zentrierte Datenerhebung innerhalb eines Surveys, in denen die lokale Netzwerknachbarschaft einzelner, isolierter Respondenten erhoben wird. Dem gegenüber steht die Erhebung vollständiger Netzwerkdaten innerhalb einer sinnvoll abgegrenzten Gruppe sozialer Akteure, die einzeln als Respondenten fungieren, aber auch gemeinsam den Pool der nennbaren Netzwerkpartner darstellen. Nur dieser letztere Datentyp ist Gegenstand dieses Kapitels, da der Fall ego-zentrierter Daten im allgemeinen durch nicht netzwerkspezifische Verfahren der Datenanalyse abgedeckt ist, wie Regressionsverfahren (wenn auf der Respondentenebene analysiert wird), oder Mehrebenenanalyse (wenn Partnernennungen der Respondenten analysiert werden). Für vollständige Netzwerke ist die statistische Modellierung aber allein deshalb schon eine Herausforderung, weil die zu modellierenden Abhängigkeitsstrukturen zwischen Akteuren nicht-trivial sind – was sich in der relativen Komplexität der Modelle niederschlägt. In diesem Kapitel wollen wir die einschlägigen Verfahren der Analyse dynamischer Netzwerke kurz vorstellen, mit Schwerpunkt auf das am weitesten verbreitete Verfahren, die stochastische, akteurbasierte Modellierung von Netzwerkevolutionsprozessen (Snijders 1996; 2001; 2005; Snijders et al. 2008). Nach der einführenden allgemeinen Motivation, warum das Studium von Netzwerkveränderungsprozessen in vielen Fällen sinnvoller sein kann als die Analyse von Querschnittsdaten werden im Folgenden die Eigenheiten von Netzwerk-Längsschnittsdaten diskutiert. Wir geben dann eine kurze Übersicht über gängige Analyseverfahren, gefolgt von einer Beschreibung des stochastischen, akteurbasierten Ansatzes. Dieser wird durch Analyse eines Beispieldatensatzes illustriert. In der abschließenden Diskussion werden Grenzen des skizzierten Modells aufgezeigt und es wird auf Erweiterungsmöglichkeiten eingegangen.

Netzwerk-Längsschnittsdaten

Zum Studium dynamischer Netzwerkprozesse sind Längsschnittsdaten nötig. Das wohl am häufigsten erhobene Datenformat ist das Netzwerkpanel. Hierbei wird für eine gewisse Anzahl von Zeitpunkten jeweils das gesamte Netzwerk innerhalb der betrachteten Akteurengruppe gemessen. Meist enthalten diese Daten zusätzlich Informationen über die individuellen Akteure (z.B. demografische Eigenschaften) und umfassen nicht nur eine Netzwerkvariable, sondern mehrere (z.B. Vertrauen, Freundschaft, formelle Hierarchie). Ein allgemeines Problem, das der Gebrauch von Paneldesigns nach sich zieht, ist die Unvollständigkeit der Beobachtungen¹. Wenn in zwei aufeinanderfolgenden Messungen einer Beziehung zwischen zwei Akteuren keine Veränderung beobachtet wird, muss das nicht heißen, dass in der dazwischenliegenden, unbeobachteten Periode tatsächlich keine – wenn auch vorübergehende – Veränderung auftrat. Der dem Paneldatensatz zugrunde liegende Echtzeitprozess kann komplizierter sein und gerade bei der Erforschung sozialer Mechanismen ist es wichtig, dies auch in der Modellierung zu berücksichtigen.

¹ Im Zuge der zunehmend automatisierten Datenerfassung werden auch Echtzeit-Datensätze, in denen jede Veränderung des Netzwerks protokolliert ist, immer häufiger. Wegen der mit diesem Datenformat verbundenen Problematiken der Netzwerkabgrenzung und der de-facto Gleichzeitigkeit von erzwungenermaßen sequentiellen Ereignissen (Stegbauer & Rausch, 2006), wollen wir hierauf nur am Rande (in der abschließenden Diskussion) eingehen.

Des Weiteren ist bei Netzwerk-Längsschnittdaten zu unterscheiden zwischen *Ereignisdaten* und *Zustandsdaten*. Unter Zustandsdaten verstehen wir ein sich vergleichsweise langsam veränderndes Netzwerk, wie es etwa im Fall von Freundschaftsbeziehungen oder Vertrauensverhältnissen vorliegt. Als typisches Ereignisnetzwerk hingegen kann man sich das Netzwerk von Telefongesprächen vorstellen, die zu einem bestimmten Zeitpunkt stattfinden. Der genaue Zeitpunkt der Messung bestimmt hier sehr stark, wie das Netzwerk aussieht. In der sozialwissenschaftlichen Netzwerkforschung haben solche vom exakten Messungszeitpunkt stark abhängigen Daten wenig Aussagekraft, da man ja mit der Messung die Anwesenheit sozialer Beziehungen zwischen den Akteuren feststellen will. Erst durch Aggregation von Ereignisdaten über einen gewissen Zeitraum hinweg ergibt sich ein zuverlässiges Bild über den Zustand dieser sozialen Beziehungen. Im Folgenden wollen wir stets von Zustandsdaten ausgehen.

Longitudinale Modellierung

Für Quer- wie Längsschnittdatensätze gleichermaßen gibt es nur wenige Verfahren, die für die Analyse kompletter Netzwerke geeignet sind. Das rührt vor allem daher, dass in kompletten Netzwerken weder die Akteure noch die Dyaden statistische Unabhängigkeit aufweisen. Einerseits sind sie nicht als Zufallsstichprobe gezogen worden, andererseits gibt es endogene, durch die Daten selbst ausgedrückte Abhängigkeiten, wie sie sich in Tendenzen zur Triangulierung, Clusterbildung, oder Segregation äußern können. Wenn man Abhängigkeiten zwischen sozialen Akteuren studieren will (und das ist ja das Ziel der Netzwerkforschung), sind statistische Verfahren, die die Unabhängigkeit eben jener Akteure erfordern, prinzipiell nicht anwendbar. Das betrifft die große Mehrheit der Standardmethoden, wie Regressions- und Varianzanalyseverfahren. Stochastische Verfahren der Netzwerkanalyse hingegen geben ein explizites Abhängigkeitsmodell vor, dessen Parameter an den Datensatz angepasst werden. Für Querschnittdaten sind die am häufigsten gebrauchten Modelle dieser Art das exponentielle Zufallsgraphenmodell (ERGM) für einzelne Netzwerke (Wasserman & Robins, 2005; Snijders et al., 2006a), das Social Relations Model (Kenny et al., 2006) und das p2-Modell (Zijlstra et al., 2006). Für Längsschnittdaten ist es das stochastische, akteurbasierte Modell für dynamische Netzwerke, das Snijders (1996; 2001; 2005) und Kollegen (Snijders et al., 2007; *in press*) entwickelten. Dieses letztere Modell werden wir in den folgenden Abschnitten etwas detaillierter vorstellen, da es die besten Möglichkeiten bietet, soziale Mechanismen in Netzwerkevolutionsprozessen zu identifizieren.

Auf andere, noch sehr junge Ansätze, die in der Zukunft sicherlich an Bedeutung gewinnen werden, wollen wir hier nicht tiefer eingehen, sie aber hier übersichtshalber erwähnen. Einerseits handelt es sich hierbei um verwandte Modelle für Netzwerkevolution in diskreter Zeit (Franzese et al., 2008), welche sich vornehmlich zur Analyse aggregierter Ereignisdaten eignen. Andererseits handelt es sich um Erweiterungen stochastischer Modelle für Querschnittsdaten auf den longitudinalen Fall, wie exponentielle Zufallsgraphenmodelle (Igarashi et al., 2006; Goodreau et al., 2008) oder das social relations model (Westveld & Hoff, 2008). Ebenfalls auf Analyseverfahren für Querschnittsdaten beruhende Techniken sind einerseits die Metaanalyse (oder Mehrebenenanalyse) von Resultaten aus separaten Querschnittsanalysen (Lubbers, 2003; Snijders & Baerveldt, 2003), in denen der Zeitfaktor als erklärende Variable auf dem Metaniveau hinzugezogen werden kann. Andererseits lassen sich in allen erwähnten stochastischen Querschnittsverfahren frühere Messungen eines Netzwerks als erklärende Variable für eine darauffolgende Messung benutzen, was es vor allem erlaubt, Stabilität

des Netzwerks von verschiedenen Veränderungsmustern abzugrenzen. Unseres Wissens sind aber auch diese Verfahren noch nicht breiter eingesetzt worden.

Schließlich wollen wir noch kurz eine Technik erwähnen, die aus der Analyse ego-zentrierter (also: nicht kompletter) Netzwerkdaten stammt. Da ego-zentrierte Daten gemeinhin in Zufallsstichproben erhoben werden, lassen sich hier Standardverfahren der Datenanalyse durchaus anwenden. Die im Netzwerkmodul erhobenen persönlichen Netzwerke der Respondenten können aggregiert werden zu Variablen auf Akteursniveau (z.B. Grad, clustering coefficient, Burt constraint), die dann wie andere Variablen auch in gebräuchlichen Längsschnitt-Analyseverfahren eingesetzt werden können, wie z.B. Varianzanalyse für wiederholte Wahrnehmungen, oder Panelregressionsmodellen wie Poisson-Regression. Dieses Prinzip der Aggregation lässt sich auch auf komplette Netzwerke anwenden. Durch Aggregation von kompletten Netzwerken in eine Handvoll zusammenfassende Statistiken lassen sich z.B. Zeitreihenmodelle zur Datenanalyse einsetzen. Aufgrund des massiven Datenverlusts bei der Aggregation ist ein solches Vorgehen aber nur für sehr spezielle Anwendungen sinnvoll, die meist auf riesige, automatisch gesammelte Datensätze zurückgreifen können, und Signaldetektion als Hauptziel haben. Fragwürdiger ist die Anwendung von Aggregationsverfahren in Kombination mit Standardmethoden, wenn komplette Netzwerkdaten auf Akteursniveau aggregiert werden. Durch die oben beschriebenen Abhängigkeiten in kompletten Netzwerken lässt sich die Anwendung von Standardverfahren nur durch komplizierte konditionelle Unabhängigkeitsannahmen rechtfertigen, die wenig überzeugend sind. Das hindert leider Forscher wie Herausgeber von Zeitschriften nicht immer daran, solche Analysen zu publizieren (z.B. Hochberg et al., 2007), freilich ohne Diskussion der implizit zugrundeliegenden Annahmen.

Akteurbasierte Modellierung der Netzwerkevolution

Die von Snijders (1996; 2001; 2005) eingeführte stochastische, akteurbasierte Modellierung von Netzwerkevolutionsprozessen ist zurzeit die meistverbreitete Analyseverfahren für dynamische Netzwerkdaten. Ausgegangen wird bei diesem Ansatz von Netzwerkpaneldaten, die sich als Zustandsdaten interpretieren lassen, also eine gewisse Stabilität aufweisen. Der Einfachheit halber gehen wir hier von einem Panel mit nur zwei Erhebungen aus, gemessen zu den Zeitpunkten $t_1 < t_2$ in einer Gruppe von n Akteuren. Die Netzwerkdaten seien gegeben als gerichtete, binäre $n \times n$ Adjazenzmatrizen $x(t_1)$ und $x(t_2)$, d.h. $x_{ij}(t_m)=1$ steht für Anwesenheit der gerichteten sozialen Beziehung von Akteur i zu Akteur j zum Zeitpunkt t_m , während $x_{ij}(t_m)=0$ für deren Abwesenheit steht. Im empirischen Teil werden wir hier das Beispiel von Freundschaftsnennungen unter Oberschülern betrachten. Nähere Informationen über die Akteure seien vorhanden als individuelle Variablen v , z.B. in Vektorform, wobei v_i den Wert angibt, den Akteur i auf der Variable annimmt. Als Beispiel kann man an eine Geschlechtsindikatorvariable denken. Informationen über weitere soziale Beziehungen zwischen den Akteuren seien gegeben als dyadische Variablen w , die in Matrixform ausgedrückt werden können; dabei steht w_{ij} für den Wert der Beziehung von Akteur i zu Akteur j . Im Beispiel unten betrachten wir die dem Analysezeitraum zeitlich vorgelagerten Freundschaftsbeziehungen an der Grundschule als eine solche dyadische Variable.

Die Paneldaten werden modelliert durch einen stochastischen Prozess $X(t)$ auf dem Zeitintervall $[t_1, t_2]$, der Werte im Raum $\mathcal{X}=\{0,1\}^{n(n-1)}$ aller möglichen gerichteten, binären Netzwerke zwischen n Akteuren annimmt. Die erste Wahrnehmung des Netzwerks $x(t_1)$ fungiert hierbei als Startwert des

Prozesses, wird also selbst nicht modelliert. Das Evolutionsmodell lässt sich nun am einfachsten als stochastische Simulation verstehen: ausgehend von einer vorläufigen Modellparametrisierung wird für jeden Akteur i eine zufallsbedingte Wartezeit τ_i gezogen. Falls das Zeitintervall $[t_1, t_2]$ dadurch nicht verlassen wird, bekommt der Akteur mit der kürzesten Wartezeit die Möglichkeit, die von ihm kontrollierte Netzwerknachbarschaft leicht zu verändern. Das bedeutet, dass er entweder einen neuen Partner nominieren, eine bestehende Nominierungen zurückziehen oder den status quo beibehalten kann. Nach diesem sogenannten *Mikroschritt* im Netzwerkevolutionsprozess werden erneut für alle Akteure Wartezeiten gezogen, und die Mikroschritt-Prozedur wiederholt sich, bis das Ende des Zeitintervalls $[t_1, t_2]$ erreicht ist. Idealerweise endet eine solche Sequenz von Mikroschritten in der zweiten Wahrnehmung des Netzwerks $x(t_2)$. Da dies aber besonders unter vorläufigen Modellparametrisierungen unwahrscheinlich ist, werden Diskrepanzen zwischen den beobachteten Daten und parameterabhängigen Tendenzen in der Simulation dazu genutzt, die vorläufige Modellparametrisierung iterativ zu verbessern², was im Normalfall zu Konvergenz und eindeutiger Identifikation der Modellparameter führt.

Die Modellierung der Wartezeiten τ_i und das den Mikroschritten zugrunde liegende Entscheidungsmodell sind somit die Hauptbestandteile des Modells. Beide Komponenten werden durch Spezifikation parameterabhängiger Funktionen definiert.

Wartezeiten werden mithilfe der Exponentialverteilung modelliert, also $\tau_i \propto \exp(-\rho_i)$, wobei $\rho_i(X, t) = \sum_k \lambda_k r_{ik}(X(t))$ die *Ratenfunktion* heißt. Je höher die Veränderungsrate ρ_i eines Akteurs, desto kürzer ist seine gemittelte Wartezeit, und desto höher somit die Wahrscheinlichkeit, dass er den nächsten Mikroschritt setzen darf. Die Ratenfunktion ist ihrerseits eine Linearkombination von Statistiken r_{ik} , die positionelle Eigenschaften des Akteurs im Netzwerk (aber auch andere individuelle Eigenschaften) ausdrücken können. Die Gewichte λ_k dieser Statistiken geben an, welchen Einfluss die jeweilige Statistik auf die Wartezeit des Akteurs hat. Diese *Ratenparameter* werden aus den Daten geschätzt, wobei ein positiver Wert für kürzere Wartezeit steht.

Entscheidungen über Mikroschritte werden mithilfe der multinomialen Logit-Verteilung modelliert. Wenn $X(i \rightsquigarrow j)$ abkürzend für dasjenige Netzwerk steht, das aus Netzwerk $X(t)$ entsteht indem Akteur i seine gerichtete Beziehung zu Akteur j verändert (also von $X_{ij}(t)=0$ zu $X_{ij}(t+\tau_i)=1$, oder umgekehrt), und wenn $X(i \rightsquigarrow i) = X(t)$ formell für die Option „keine Veränderung“ steht, dann sind die für Akteur i möglichen Mikroschritte beschrieben durch die Menge $\{X(i \rightsquigarrow j) \mid j \in \{1, \dots, n\}\}$. Die Wahlwahrscheinlichkeiten für Akteur i sind nun gegeben als $P(X(i \rightsquigarrow j)) \propto \exp(f_i(X(i \rightsquigarrow j)))$, wobei $f_i(X) = \sum_k \alpha_k s_{ik}(X)$ die *Zielfunktion (objective function)* heißt. Je höher der Wert der Zielfunktion f_i für einen

² Das kann auf unterschiedliche Weise geschehen. Bei Modellschätzung nach der Momentenmethode werden hierfür Differenzen zwischen Statistiken des simulierten Endnetzwerk $X(t_2)$ und des beobachteten Netzwerk $x(t_2)$ herangezogen. Unter Maximum-Likelihood-Schätzung wird die Gleichheit dieser beiden Netzwerke erzwungen, und man nutzt die mit Hilfe von MCMC-Methoden berechnete Wahrscheinlichkeit von verschiedenen interpolierenden Mikroschritt-Sequenzen zum iterativen Verbessern der Modellparameter. Wir verweisen in diesem Zusammenhang auf Snijders et al. (2006b) und Snijders (2005), die die Schätzalgorithmen im Detail darstellen.

Mikroschritt $X(i \rightarrow j)$ ist, desto höher die Wahrscheinlichkeit, dass dieser Mikroschritt gewählt wird. Auch die Zielfunktion ist ihrerseits eine Linearkombination von Statistiken s_{ik} , die positionelle Eigenschaften des Akteurs im Netzwerk (aber auch andere individuelle oder dyadische Eigenschaften) ausdrücken. Das Gewicht α_k einer Statistik gibt an, inwieweit die entsprechende Eigenschaft von den Akteuren im Netzwerk angestrebt bzw. (im Falle eines negativen Wertes) vermieden wird. Auch diese *Zielfunktionsparameter* werden empirisch aus den Daten geschätzt. In Tabelle 1 wird eine kleine Liste von Beispielstatistiken gegeben, welche auch im Anwendungsbeispiel zur Modellparametrisierung eine Rolle spielen. Eine größere Auswahl findet sich bei Snijders et al. (2008).

Tabelle 1: Beispiele von Zielfunktionseffekten*

Effektname	Statistik s_{ik}	Verbale Umschreibung
Außengrad	$\sum_j x_{ij}$	Gemittelte Netzwerkaktivität der Akteure; der Parameterwert 0 steht für eine (hohe!) Netzwerkdichte von 0,5 .
Reziprozität	$\sum_j x_{ij}x_{ji}$	Neigung der Akteure zur gegenseitigen Nennung.
Transitive Tripel	$\sum_{jh} x_{ij}x_{jh}x_{ih}$	Neigung der Akteure zur Schließung transitiver Dreiecksbeziehungen.
Effekt einer dyadischen Variable w	$\sum_j x_{ij}w_{ij}$	Haupteffekt einer zweiten Beziehungsvariable auf Partnernennung.
Ego-Effekt einer individuellen Variable v	$v_i \sum_j x_{ij}$	Effekt einer individuellen Eigenschaft auf Aktivität im Netzwerk, d.h., die Anzahl abgegebener Nennungen.
Alter-Effekt einer individuellen Variable v	$\sum_j x_{ij}v_j$	Effekt einer individuellen Eigenschaft auf Popularität im Netzwerk, d.h., die Anzahl empfangener Nennungen.
Ähnlichkeitseffekt einer individuellen Variable v	$\sum_j x_{ij} \left(1 - \frac{ v_i - v_j }{v_{\max} - v_{\min}} \right)$	Effekt von Ähnlichkeit in einer individuellen Eigenschaft auf Partnernennung.

* *dyadische und individuelle Variablen werden vom SIENA-Programm intern zentriert, d.h. in den Formeln müssen unzentrierte Rohdaten w_{ij} und v_i substituiert werden durch $(w_{ij} - \bar{w})$ bzw. $(v_i - \bar{v})$.*

Insgesamt gehört das vorgestellte Modell zur Klasse der Markoffprozesse in kontinuierlicher Zeit. Mithilfe des SIENA-Programms (Snijders et al., 2008) lassen sich Modellspezifikationen an empirische Datensätze anpassen. Existenz und Eindeutigkeit der hierfür zu bestimmenden Parameterschätzer wird durch Theoreme aus der Theorie der Markoffprozesse garantiert. Neben den Parametern λ_k und α_k werden durch SIENA auch deren Standardfehler geschätzt, was Signifikanztests mithilfe approximativ normalverteilter t-Verhältnisse ermöglicht.

Im Folgenden werden wir auf die Modellierung der Ratenfunktion nicht weiter eingehen. In Anwendungen, in denen die Akteure im Netzwerk prinzipiell gleichgestellt sind (z.B. die Schüler in einer Schulklasse) ist es meist auch nicht nötig, Geschwindigkeitsunterschiede zwischen den

Akteuren zu modellieren. Eine für alle Akteure identische Veränderungsrate ρ ist im allgemeinen für erste Analysen mit einem Basismodell zu empfehlen. Wenn sich hierbei Schätzprobleme ergeben (Divergenz oder unrealistisch hohe Standardfehler) sollte man die Akteure auf Heterogenität hin untersuchen. Auf die Modellierung der Verhaltensregeln der Netzwerkakteure mithilfe der Zielfunktion wird im Anwendungsbeispiel noch deutlicher eingegangen.

Wie aus der Modellskizze folgt, erfordert der Modellansatz, dass sich die beobachteten Veränderungen zwischen zwei Messpunkten als Sequenz konditionell unabhängiger Mikroschritte darstellen lassen. Aus der empirischen Anwendung heraus sollte es also zu rechtfertigen sein, dass zu jedem Zeitpunkt höchstens ein solcher Schritt stattfindet. Ausgeschlossen werden hiermit koordinierte Aktionen mehrerer Akteure oder simultane Aktionen desselben Akteurs. Hieraus ergeben sich Probleme für die Anwendbarkeit des Basismodells für spezielle Datentypen, wie z.B. Vertragsabschlüsse zwischen Firmen (bei denen stets zwei Akteure am Zustandekommen einer Beziehung aktiv beteiligt sind) oder Koautorschaft (bei denen sogar mehr als zwei Akteure beteiligt sein, aber auch mehrere bilaterale Zusammenarbeitsbeziehungen simultan entstehen können). In der das Kapitel abschließenden Diskussion wird ein wenig näher darauf eingegangen, inwieweit diese Datentypen durch leichte Modifikation des Modellansatzes analysierbar werden.

Schließlich wollen wir noch erwähnen, dass das skizzierte Modell sich einfach im Sinne eines locker gefassten *Rational-Choice-Paradigmas* interpretieren lässt (Heidler, 2007). Der Grund hierfür ist statistischer Natur: nach McFadden (1974) lassen sich die multinomialen Logit-Wahrscheinlichkeiten für die Mikroschritte interpretieren als das Resultat von Optimierungsentscheidungen der Netzwerkakteure. Die Zielfunktion spielt hierbei die Rolle einer mikroökonomischen Nutzenfunktion, zu der aber noch eine Gumbel-verteilte Zufallskomponente addiert wird (*Random-Utility-Modell*). Bei einer solchen Interpretation des Modells muss man sich aber immer darüber im Klaren sein, dass zahlreiche Modellparameter nicht eigentlich den *Nutzen* des Netzwerks für den Akteur ausdrücken, sondern vielmehr *Randbedingungen* wie Anreize oder Restriktionen, die sich aus dem Netzwerk für den Akteur ergeben. Weiterhin ist die Maximierungsentscheidung als bestenfalls myopisch zu sehen, da strategische Berücksichtigung des zukünftigen Verhaltens anderer Akteure im Modell nicht stattfindet. Vor allem in frühen Publikationen wie Snijders (1996) wird auf diese Interpretation viel Nachdruck gelegt, hier scheint es uns aber eher hilfreich, auf die Hinlänglichkeit des akteurbasierten Modellansatzes auch ohne Rationalitätsannahmen hinzuweisen.

Ein Anwendungsbeispiel

Als Anwendungsbeispiel betrachten wir die Dynamik eines Freundschaftsnetzwerks in einer niederländischen Schulklasse während des ersten Schuljahres an der Oberschule. Die Daten wurden im Rahmen einer größeren Panelstudie zu Freundschaftsbeziehungen in Schulklassen an weiterführenden Schulen erhoben (Knecht 2006). Insgesamt wurden im Rahmen dieser Studie Schüler aus 126 Klassen an 14 unterschiedlichen Schulen in den Niederlanden befragt. Es gab vier Erhebungswellen im Abstand von jeweils 3 Monaten. Die für unsere Beispielanalyse ausgewählte Klasse zeichnet sich durch ihr vollständiges Antwortverhalten aus. Alle 25 Schüler nahmen zu allen vier Zeitpunkten an der Studie teil, füllten die Fragebögen vollständig aus, und es gab keine Veränderung in der Klassenzusammenstellung (kein Neuzugang oder Abgang von Schülern). Die ausgewählte Klasse ist eine von 7 Klassen ihres Jahrgangs an einer Schule auf dem Niveau

HAVO/VWO (Hochschulreife). In der Klasse waren keine ethnischen Minderheiten anwesend, 44% der Schüler waren Mädchen (Kodierung Geschlecht: 1=Mädchen, 2=Junge), und das modale Alter der Schüler zu Beginn des Schuljahres war 12 Jahre. Im Netzwerkmodul konnten die Schüler bis zu 12 Klassenkameraden als Freunde angeben; gemittelt stieg die Zahl der genannten Freunde von 2,5 in der ersten Erhebung auf 4,7 in der vierten. Über alle Erhebungen hinweg gemittelt war die Netzwerkdichte 0,16 (16% aller theoretisch möglichen Freundschaften wurden tatsächlich genannt), der Reziprozitätsindex betrug 0,63 (63% aller Freundschaftsnennungen wurden vom genannten Freund bestätigt), der Transitivitätsindex betrug 0,45 (45% aller indirekten Freundschaftsnennungen $i \rightarrow j \rightarrow h$ wurden auch direkt $i \rightarrow h$ genannt), und 95% aller Freundschaftsnennungen waren gleichgeschlechtlich.

Wir wollen in unserem Beispiel der Frage nachgehen, in welchem Maße diese in solchen Netzwerken typische Segregation der Geschlechter sich direkt durch den sozialen Mechanismus der Wahl von gleichgeschlechtlichen Freunden erklären lässt, und welche modifizierende Rolle netzwerkendogene Prozesse hierbei spielen. Zu denken ist hierbei einerseits an Reziprozitätsnormen, nach denen potentiell bis zur Hälfte aller gleichgeschlechtlichen Freundschaftsbeziehungen sich alternativ als reziproke Bestätigung einer einseitig initiierten Freundschaft auffassen lassen. Andererseits könnten Prozesse der Gruppenbildung wie transitive Schließung von Dreiecksbeziehungen („Die Freunde meiner Freunde sind auch meine Freunde“) schwache Segregationstendenzen deutlich verstärken. Als Nebeneffekt motivieren wir so auch gleich, warum ein Netzwerkansatz umfassender und in diesem Fall auch realistischer ist als ein rein interpersoneller Ansatz, wie er die Literatur in der Entwicklungspsychologie bis heute dominiert.

Wir schätzen hierfür drei ineinander geschachtelte Modelle. Das erste Modell für die Freundschaftsdynamik unter den 25 Schülern enthält den Basiseffekt *Außengrad*, der die gemittelte Anzahl von Freundschaftsnennungen modelliert, einen Haupteffekt von *Grundschulfreundschaft*, sowie drei geschlechtsabhängige Effekte, die angeben, ob die Geschlechter (1) in gemittelter Popularität oder (2) Aktivität voneinander abweichen, bzw. (3) ob Freundschaft vornehmlich innerhalb desselben Geschlechts geschlossen wird. Die genannten netzwerkendogenen Prozesse werden in dieser Modellspezifikation noch nicht mit aufgenommen, wohl aber in Modellen 2 (Reziprozität) und 3 (Reziprozität und Transitive Tripel). In Tabelle 2 werden die Ergebnisse der Modellschätzungen wiedergegeben. Neben dem Schätzwert ist (in Klammern) dessen geschätzter Standardfehler angegeben sowie auf dem approximativ normalverteilten t-Verhältnis dieser Werte beruhende Signifikanzindikatoren für den Test, dass der Parameter Null ist.

Die Schätzwerte der Parameter sind wie folgt zu interpretieren: Die Ratenparameter geben die Häufigkeit an, mit der die Modellakteure die Gelegenheit haben, die Zusammenstellung ihres Freundeskreises zu verändern. Zu Beginn des Schuljahres, also in Periode $t_1 \rightarrow t_2$, wenn neue Freundschaften sich nach dem Übergang zur Oberschule erst formieren müssen, werden signifikant mehr Mikroschritte gesetzt als in den folgenden Perioden. Welcher Art diese Mikroschritte sind, wird durch die Zielfunktionsparameter angegeben. Zu deren Interpretation sind ein paar begleitende Überlegungen sinnvoll. Zunächst ist zu bemerken, daß eine konstante Zielfunktion, die jedem möglichen Mikroschritt denselben Wert zuordnet, Indifferenz des Akteurs ausdrückt und gleiche Wahlwahrscheinlichkeiten für alle Mikroschritte. Ein solcher (fiktiver) Netzwerkevolutionsprozess strebt einem Gleichgewichtszustand zu, in dem jede Freundschaftsbeziehung mit gleicher

Wahrscheinlichkeit an- wie abwesend ist, deren Wahrscheinlichkeit also 50% ist. Empirische Netzwerkdatensätze weisen aber meist eine viel geringere Dichte auf; bei unserem Datensatz sind es, wie oben genannt, 16%. Diese Abweichung nach unten von einer 50% Netzwerkdichte wird ausgedrückt durch den signifikant negativen „Außengrad“-Parameter. Er gibt an, dass die Schüler konsistent weniger als die Hälfte ihrer Klassenkameraden als Freunde nominieren, oder (äquivalent) dass zwei willkürlich identifizierte Schüler mit einer Wahrscheinlichkeit unter 50% in einer Freundschaftsbeziehung miteinander stehen. Für Modell 3 ist diese Wahrscheinlichkeit über eine invers-logistische Transformation zu berechnen als $\exp(-2,19)/(1+\exp(-2,19))=0,10$. Dass dieser Wert unter den beobachteten 16% liegt, legt nahe, dass die in unserem Datensatz beobachteten Freundschaften sich nicht hinreichend durch die im „Außengrad“-Parameter ausgedrückte allgemeine Tendenz zu Freundschaftsbildung erklären lassen. Vielmehr sind die anderen geschätzten Modellparameter nötig sind, um die genaue Natur der beobachteten Dynamik zu erklären.

Tabelle 2: Ergebnisse der Beispielanalyse (Maximum-Likelihood-Schätzung)

	Modell 1	Modell 2	Modell 3
Ratenfunktion (Freundschaftsnetzwerk)			
Veränderungsrate $t_1 \rightarrow t_2$	7,54 (0,97)	8,81 (1,31)	10,87 (2,63)
Veränderungsrate $t_2 \rightarrow t_3$	2,73 (0,45)	2,92 (0,50)	3,04 (0,52)
Veränderungsrate $t_3 \rightarrow t_4$	3,29 (0,49)	3,56 (0,54)	3,80 (0,65)
Zielfunktion (Freundschaftsnetzwerk)			
Außengrad	-1,92 (0,17) ***	-2,03 (0,16) ***	-2,19 (0,16) ***
Reziprozität	—	1,09 (0,16) ***	0,84 (0,17) ***
Transitive Tripel	—	—	0,18 (0,03) ***
Grundschulfreundschaft	0,54 (0,21) *	0,30 (0,21)	0,40 (0,20) *
Genannter Schüler ist Junge	0,30 (0,18)	0,28 (0,18)	0,05 (0,17)
Nennender Schüler ist Junge	0,11 (0,19)	0,07 (0,19)	-0,17 (0,18)
Gleiches Geschlecht	1,70 (0,18) ***	1,39 (0,18) ***	0,93 (0,18) ***

Modellparameter und (in Klammern) deren Standardfehler; * $p < 0,05$; ** $p < 0,01$; *** $p < 0,001$.

Der signifikant positive Reziprozitätsparameter gibt an, dass in der analysierten Schulklasse Freundschaftsnennungen sehr oft von beiden Seiten bestätigt werden. Der Parameterwert 0,84 (nach Modell 3) ergibt eine um den Faktor $\exp(0,84)=2,31$ erhöhte (also 131% höhere) Wahrscheinlichkeit einer zweiseitigen Freundschaftsnennung, wenn bereits eine einseitige Nennung

vorliegt, als wenn diese nicht vorliegt. Der Parameter „Transitive Tripel“ zeigt, dass es Tendenzen zur Clusterbildung (Gruppenformation) gibt; nach Modell 3 erhöht jede Zwischenperson, über die eine indirekte Freundschaftsverbindung läuft, die Zielfunktion um 0,18 und somit die Wahrscheinlichkeit für eine direkte Freundschaft um Faktor $\exp(0,18)=1,20$ (also um 20%). Neben diesen dem Netzwerk endogenen, strukturellen Effekten findet sich auch ein Effekt von Grundschulfreundschaft auf Freundschaft an der Oberschule, und ein Effekt von Geschlechtersegregation. Effekte der Geschlechtsvariable auf die Anzahl empfangener oder gegebener Freundschaftsnominierungen sind nicht signifikant. Besondere Aufmerksamkeit gilt aber dem Parameter „Gleiches Geschlecht“, der die Tendenz zur Geschlechtersegregation direkt modelliert. In allen Modellen ist er signifikant positiv, jedoch nimmt Signifikanz und Effektgröße umso mehr ab, je mehr endogen-strukturelle Netzwerkendenzen das Modell als Kontrollvariablen enthält. Berechnet man 95%-Konfidenzintervalle für diesen Parameter, so überlappen diese sich für Modelle 1 und 3 nicht einmal. Transformiert in Mikroschritt-Wahrscheinlichkeiten ergibt sich unter Modell 1 ein Intervall von 79% bis zu 89% für die Wahrscheinlichkeit, einen Freund des gleichen anstelle des anderen Geschlechts zu nominieren (bei ansonsten identischen Bedingungen). Unter dem realistischeren Modell 3 liegt dieses Intervall nur noch zwischen 64% und 78%, was nahelegt, dass tatsächlich ein beträchtlicher Anteil der Tendenz zur Geschlechtersegregation im studierten Netzwerk auf segregationsverstärkende Tendenzen von Reziprozitätsnormen und Gruppenbildung zurückzuführen ist. Die Resultate deuten also an, dass falsch spezifizierte Modelle, in denen strukturelle Tendenzen vernachlässigt werden, den direkten Segregationseffekt systematisch überschätzen. Diese Resultate über endogene Netzwerkmechanismen stehen folglich in einer Reihe mit Forschungsergebnissen, die ähnliche Verzerrungseffekte bei Vernachlässigung von Informationen über Zugehörigkeit zu sozialen Kontexten (Feld, 1982) oder von Wohnsitzinformationen (Mouw & Entwisle, 2006) nachweisen konnten.

Diskussion

In diesem Kapitel haben wir, nach einer kurzen Übersicht über alternative Methoden, die zurzeit am weitesten verbreitete Methode der dynamischen Netzwerkanalyse beschrieben: das Modellieren von Netzwerkpaneldaten mithilfe des stochastischen, akteurbasierten Ansatzes von Snijders (2005) und Kollegen (Snijders et al., 2007; 2008). Die beobachtete globale Netzwerkdynamik eines kompletten Netzwerks wird hier aufgefasst als Resultat von lokalen und unbeobachteten Veränderungen, die als Aktionen der Netzwerkakteure begriffen und modelliert werden. Die Regeln, nach denen die Akteure neue Beziehungen zu anderen Akteuren eingehen oder bestehende Beziehungen abbrechen, werden als ein Satz von Modellparametern aus den Daten geschätzt. Als Beispiel betrachteten wir die Evolution eines Freundschaftsnetzwerks in einer niederländischen Schulklasse im ersten Jahr an der Oberschule. Wir konnten zeigen, dass die beträchtliche Geschlechtersegregation in diesem Netzwerk sich nicht als einfacher Haupteffekt verstehen läßt, nach dem Schüler sich zum gleichen Geschlecht hingezogen fühlen. In signifikantem Maß wird sie auch durch zwei netzwerkendogene, strukturelle Effekte verursacht: eine Reziprozitätsnorm beim Benennen von Freunden, und Gruppenbildung folgend dem Muster des Schließens transitiver Dreiecksbeziehungen.

Die beschriebene Methode ist bisher erfolgreich angewandt worden auf Netzwerkdatsätze zwischen ca. 20 Akteuren (Schulklassengröße; Knecht, 2008) und wenigen hundert Akteuren (Schulkohorten; Burk et al., 2007; Steglich et al., 2008). Kleine(re) Netzwerke erlauben es nicht,

Modelle von theoretisch sinnvollem Umfang zu schätzen, da die statistische Teststärke der Methode in solchen Datensätzen nicht hoch genug ist, um Effekte aufzuspüren. In solchen Fällen kann man aber mehrere kleine Datensätze analysieren, und die Resultate meta-analytisch zusammenfassen und so die Teststärke erhöhen (Knecht et al., 2009b; Snijders & Baerveldt, 2003). Für größere Netzwerke mit etlichen hundert oder mehr Akteuren wiederum wird vor allem die Modellannahme fragwürdig, dass ein Akteur sich jederzeit aller Netzwerkooptionen bewusst ist und tatsächlich Beziehungen zu allen Akteuren im Netzwerk in Betracht zieht. Für derartige Datensätze sind Modellanpassungen nötig, die bislang noch nicht ausgearbeitet sind.

Die Anzahl der Messpunkte in bisherigen Analysen liegt üblicherweise bei wenigen (2-5) Messungen, Analysen von 10-20 Messungen bereiten aber keine Probleme (Checkley & Steglich, 2007; Whitbred et al., 2007). Wichtig ist hier einerseits, dass gute Information über Netzwerkdynamik vorhanden sein muss, also nicht zu wenig Veränderung zwischen dem ersten und dem letzten Messpunkt vorliegt (um überhaupt etwas zum Analysieren zu haben), aber auch nicht zu viel Veränderung zwischen zwei aufeinanderfolgenden Messpunkten (weil es ansonsten schwierig werden kann, Veränderungsmuster im Detail zu identifizieren). Andererseits dürfen die Verhaltensregeln der Akteure in den verschiedenen aufeinanderfolgenden Perioden nicht wesentlich voneinander abweichen, denn das Modell postuliert eine gemeinsame Zielfunktion für alle Perioden. Falls das Akteursverhalten über die Perioden hinweg zu heterogen ist, sollte man entweder periodenweise Analysen von jeweils zwei aufeinanderfolgenden Zeitpunkten machen (Steglich et al., 2010), oder aber Interaktionseffekte mit Zeitindikatoren in die Zielfunktion aufnehmen.

Basierend auf dem skizzierten Grundmodell für Netzwerkevolution gibt es einige Modellerweiterungen, die den Ansatz breiter anwendbar machen. Einerseits betrifft dies die Art der Netzwerke die analysiert werden können. Während das beschriebene Modell von gerichteten Netzwerkdaten ausgeht, lassen sich ähnliche Modell auch für ungerichtete Netzwerke formulieren. Durch den akteurbasierten Ansatz ist dies etwas komplizierter, da eine Verbindung zwischen zwei Akteuren hier potentiell die Aktionen zweier Akteure benötigt (was bei einseitigen Nennungen nicht so ist). Eine Beschreibung dieser Modellerweiterung findet sich z.B. bei van de Bunt & Groenewegen (2007), eine Anwendung bei Checkley & Steglich (2007). An Erweiterungen auf nicht-binäre, ordinale Netzwerkdaten (z.B. starke und schwache Beziehungen), bipartite Daten (z.B. Koautorennetzwerke), und multiplexe Daten wird gearbeitet, zurzeit wird deren Analyse nicht unterstützt.

Andererseits gibt es Modellerweiterungen, die es erlauben, die Koevolution von Netzwerken mit individuellen Verhaltens- oder Einstellungsvariablen multivariat zu analysieren (Snijders et al., 2007). Besonders für Fragen nach der Kausalität, wie sie in der Einleitung angesprochen wurden, sind diese Modelle nützlich, da sie es erlauben, empirisch Beeinflussungseffekte (vom Netzwerk auf das Individuum) von Selektionseffekten (vom Individuum aufs Netzwerk) zu trennen (Burk et al., 2007; Knecht, 2008; Knecht et al., 2009a, 2009b; Steglich et al., 2006, 2009; 2010). Nicht unerwähnt bleiben sollten auch die Option, mithilfe von Anpassungstests (Schweinberger, 2007) ineinander geschachtelte Modelle miteinander zu vergleichen.

Angesichts der mit fortschreitender Kenntnis immer weniger im Beschreiben verharrenden Forschungsfragen, und der daraus sich ergebenden wachsenden Zahl von guten Längsschnitt-Netzwerkdatensätzen, wird der hier beschriebene akteurbasierte Analyseansatz sicherlich noch

einigen Belastungsproben ausgesetzt werden. Ein systematischer Vergleich der in der Übersicht genannten alternativen Methoden, dynamische Netzwerkprozesse zu studieren, ist aufgrund des wachsenden Bedarfs für solche Methoden überfällig.

Literaturverzeichnis

- Burk, William J., Christian Steglich und Tom A.B. Snijders (2007). Beyond dyadic interdependence: Actor-oriented models for co-evolving social networks and individual behaviors. *International Journal of Behavioral Development* 31: 397–404.
- Burt, Ronald S. (1992). *Structural Holes: The Social Structure of Competition*. Cambridge, Mass.: Harvard University Press.
- Checkley, Matthew, und Christian Steglich (2007). Partners in Power: Job Mobility and Dynamic Deal-Making. *European Management Review* 4: 161–171.
- Feld, Scott L. (1982). Social structural determinants of similarity among associates. *American Sociological Review* 47: 797–801.
- Franzese, Robert J. Jr., Jude C. Hays und Aya Kachi. The m-STAR Model as an Approach to Modeled, Dynamic, Endogenous Interdependence in Comparative & International Political Economy. Arbeitspapier präsentiert auf der Konferenz Networks in Political Science (NIPS 2008), Boston Massachusetts.
- Goodreau, Steven M., James A. Kitts und Martina Morris (2008). Birds of a Feather, or Friend of a Friend? Using Statistical Network Analysis to Investigate Adolescent Social Networks. Erscheint in „*Demography*“.
- Gould, Roger V. (1993). Collective Action and Network Structure. *American Sociological Review* 58, 182–196.
- Heidler, Richard (2008). Zur Evolution sozialer Netzwerke. Theoretische Implikationen einer akteursbasierten Methode. In: Stegbauer, Christian (Hrsg.): *Netzwerkanalyse und Netzwerktheorie. Ein neues Paradigma in den Sozialwissenschaften*. Wiesbaden: Verlag für Sozialwissenschaften.
- Hochberg, Yael, Alexander Ljungquist und Yang Lu, 2007. Whom You Know Matters: Venture Capital Networks and Investment Performance. *Journal of Finance* 62: 251–301.
- Igarashi, Tasuku, Garry Robins und Philippa Pattison (2006). Longitudinal Changes in Friendship Networks: An Approach from Exponential Random Graph Models. Arbeitspapier präsentiert auf der Konferenz NetSci2006, Bloomington, Indiana.
- Kenny, David A., Deborah A. Kashy und William L. Cook (2006). *Dyadic Data Analysis*. New York: The Guilford Press.
- Knecht, Andrea (2006). *The dynamics of networks and behavior in early adolescence [2003/04]*. Utrecht, Universität Utrecht (ICS Codebook #61).
- Knecht, Andrea (2008). *Friendship Selection and Friends' Influence. Dynamics of networks and actor attributes in early adolescence*. Dissertation, Universität Utrecht (ICS Dissertationsreihe #140).
- Knecht, Andrea, Chris Baerveldt, Tom A.B. Snijders, Christian Steglich und Werner Raub (2009a). Friendship and Delinquency in Early Adolescence: A study of selection and influence effects. Erscheint in *Social Development*.

- Knecht, Andrea, William J. Burk, Jeroen Weesie und Christian Steglich (2009b). Friendship and alcohol use in early adolescence: a social network approach. Erscheint in *Journal of Research on Adolescence*.
- Lubbers, Miranda (2003). Group composition and network structure in school classes: a multilevel application of the p* model. *Social Networks* 25: 309–332.
- McFadden, Daniel L. (1974). Conditional Logit Analysis of Qualitative Choice Behavior. In Paul Zarembka (Hrsg.): *Frontiers in Econometrics*. New York, Academic Press. 105–142.
- Moody, James (2001). Race, School Integration, and Friendship Segregation in America. *American Journal of Sociology* 107(3): 679–716.
- Mouw, Ted, und Barbara Entwisle (2006). Residential Segregation and Interracial Friendship in Schools. *American Journal of Sociology* 112: 394–441.
- Schelling, Thomas C., 1971. Dynamic Models of Segregation. *Journal of Mathematical Sociology* 1: 143–186.
- Schweinberger, Michael (2007). *Statistical methods for studying the evolution of networks and behavior*. Dissertation, Universität Groningen (ICS Dissertationsreihe #132).
- Snijders, Tom A.B. (1996). Stochastic actor-oriented dynamic network analysis. *Journal of Mathematical Sociology* 21, 149–172.
- Snijders, Tom A.B. (2001). The statistical evaluation of social network dynamics. *Sociological methodology* (pp. 361-395). London: Basil Blackwell.
- Snijders, Tom A.B. (2005). Models for longitudinal network data. In P. J. Carrington, J. Scott, and S. Wasserman (Hrsg.): *Models and Methods in Social Network Analysis*. New York: Cambridge University Press, S. 215–247.
- Snijders, Tom A.B, und Chris Baerveldt (2003). A Multilevel Network Study of the Effects of Delinquent Behavior on Friendship Evolution. *Journal of Mathematical Sociology*, 27: 123–151.
- Snijders, Tom A. B., Philippa E. Pattison, Garry L. Robins, und Mark S. Handcock (2006a). New specifications for exponential random graph models. *Sociological Methodology*, 99–153.
- Snijders, Tom A.B., Johan Koskinen und Michael Schweinberger (2006b). Maximum likelihood estimation for social network dynamics. Working paper, University of Groningen.
- Snijders, Tom A.B., Christian Steglich und Michael Schweinberger (2007). Modeling the co-evolution of networks and behavior. In Kees van Montfort, Han Oud and Albert Satorra (Hrsg.): *Longitudinal models in the behavioral and related sciences*. Mahwah, New Jersey: Lawrence Erlbaum, S. 41–71.
- Snijders, Tom A.B., Christian Steglich, Michael Schweinberger und Mark Huisman (2008). *Manual for SIENA version 3.2*. Groningen: ICS, University of Groningen; Oxford: Department of Statistic, University of Oxford. <http://stat.gamma.rug.nl/snijders/siena.html>.
- Snijders, Tom A.B., Christian Steglich, und Gerhard G. van de Bunt (2009). Introduction to Actor-Based Models for Network Dynamics. *Erscheint in „Social Networks“*.
- Stegbauer, Christian und Alexander Rausch (2006). „Moving Structure“ als Analyseverfahren für Verlaufsdaten am Beispiel von Mailinglisten. Sozialwissenschaftlicher Fachinformationsdienst (soFid) - Methoden und Instrumente der Sozialwissenschaften 1, 11–30.
- Steglich, Christian, Tom A.B. Snijders und Patrick West (2006). Applying SIENA: An illustrative analysis of the co-evolution of adolescents' friendship networks, taste in music, and alcohol consumption.” *Methodology* 2(1), 48–56.

- Steglich, Christian, Philipp Sinclair, Jo Holliday und Laurence Moore (2009). Actor-based analysis of adolescents' friendship and smoking behavior in the ASSIST data set. Erscheint in *Social Networks*.
- Steglich, Christian, Tom A.B. Snijders und Mike Pearson (2010). Dynamic Networks and Behavior: Separating Selection from Influence. *Sociological Methodology* 40.
- Wasserman, Stanley, und Garry Robins (2005). An Introduction to Random Graphs, Dependence Graphs, and p^* . In P. J. Carrington, J. Scott, and S. Wasserman (Hrsg.): *Models and Methods in Social Network Analysis*. New York: Cambridge University Press, S. 148–161.
- Westveld, Anton H., und Peter D. Hoff (2008). Statistical Methodology for Longitudinal Social Network Data – The Gaussian Case. Arbeitspapier präsentiert auf der Konferenz Networks in Political Science (NIPS 2008), Boston Massachusetts.
- Whitbred, Rob, Fabio Fonti, Noshir Contractor und Christian Steglich (2007). From micro-actions to macro-structure: A structural approach to the evolution of organizational networks. Arbeitspapier.
- Zijlstra, Bonne J. H., Marijtje A. J. van Duijn, und Tom A. B. Snijders (2006). The Multilevel p2 Model. A Random Effects Model for the Analysis of Multiple Social Networks. *Methodology* 2(1): 42–47.