

Eine methodenorientierte Einführung in die synergetische Psychologie

Wolfgang Tschacher und Günter Schiepek

1 Konzepte dynamischer Systeme

Die systemorientierte oder „systemische“ Perspektive hat in der Psychologie bereits eine lange Geschichte (Hall & Fagen, 1968; vgl. auch die Gestaltpsychologie der ersten Hälfte dieses Jahrhunderts, z.B. Köhler, 1920). In Teildisziplinen der Psychologie, besonders in der Klinischen Psychologie, haben sich mehrere Schulen gebildet, die als kennzeichnendes Merkmal die Systemsicht anführen (von Schlippe & Schweitzer, 1996). Was meint nun dieses Attribut der Systemhaftigkeit, und was macht den spezifischen Unterschied systemorientierten Forschens aus?

Folgende Aussagen werden bei der Bestimmung von Systemen in der Psychologie häufig gemacht (vgl. Bunge, 1979; Brunner, 1986):

- Ein System ist ein Sachverhalt, der aus Komponenten aufgebaut ist;
- die Komponenten stehen miteinander in Wechselwirkung;
- ein System ist abgegrenzt von einer Umwelt;
- die Grenze kann aus Komponenten bestehen;
- ein System wird durch einen Beobachter aufgrund von Kriterien festgelegt;
- die Stellung des Beobachters zum System kann problematisiert werden (als Exo- und Endo-Perspektive: Rössler, 1992; Atmanspacher & Dalenoort, 1994; in Begriffen des Konstruktivismus: Schiepek, 1991).

Bevor wir zu einer für die Psychologie sinnvollen Konzeptualisierung eines *komplexen* Systems kommen (Schiepek & Tschacher, 1992), wollen wir uns die Begriffsgeschichte der dynamischen Systeme kurz vor Augen führen: In der Theorie dynamischer Systeme und in den Naturwissenschaften (Rosen, 1970; Hirsch & Smale, 1974; Thompson & Stewart, 1986; 1993) ist der Begriffsgebrauch in der Regel noch allgemeiner als eben skizziert. Ein „System“ ist einfach jedes Objekt, jeder Gegenstand einer Untersuchung, dessen Verhalten in Frage steht. Dieses Objekt muß intern nicht differenziert sein: auch ein als Massepunkt gedachter Körper ist ein „System“ in diesem Sinne. Der Beobachter ist systemextern.

Der Zusatz „dynamisch“ geht auf das griechische Wort für „Kraft, Vermögen“ zurück und entstammt der klassischen Dynamik Newtons: die (Orts-)Veränderung des Systems wird zurückgeführt auf das Wirken einer (äußeren) Kraft. Diese Dynamik gilt in einer idealisierten Welt, in der keine Reibung den Energiegehalt des Systems dissipiert und Körper als immaterielle Massepunkte gedacht werden. Wegen der Annahme, daß die sich bewegenden und elastisch kollidierenden Massen keine Energie verlieren, spricht man hier von *konservativen* Prozessen bzw. Systemen. Die sog. Ha-

Hamilton-Funktion ist dabei die Summe aus kinetischer und potentieller Energie eines Systems. In einem konservativen System können diese Energieformen zwar fortwährend ineinander überführt werden (z.B. beim Pendel), bleiben in ihrer Summe jedoch konstant. Charakteristisch für Hamiltonische Systeme ist weiterhin, daß sie invariant gegenüber Zeitumkehr sind: in den Gleichungen taucht die Zeit in quadrierter Form auf, so daß sich für t und $-t$ dieselben Lösungen ergeben. Die Hamiltonische Welt ist damit *reversibel*; einem Hamiltonischen Film sieht man sozusagen nicht an, ob er vorwärts oder rückwärts läuft. Es herrscht „das gute alte mechanische Billard-Universum aus dem letzten Jahrhundert“ (Rössler, 1992).

Diese Weltsicht ist anschaulich in der *reduktionistischen* Vorstellung eines „Laplace’schen Dämons“ enthalten: Würde dieser Dämon Ort und Impuls jedes Teilchens im Universum bestimmen, könnte er jedes beliebige Ereignis in der Zukunft vorhersagen und hätte zudem genaue Kenntnis über jedes vergangene Ereignis. Zu den Eigenschaften der Konservativität und Reversibilität kommt also noch die strikte *Determiniertheit* jeder Dynamik, sowie die Reduzierbarkeit der Wirklichkeit, auf eine Summe vieler mikroskopischer Wirklichkeiten.

Das auf diesen Grundannahmen basierende Wissenschaftsprogramm war sehr erfolgreich. Es wurde im Laufe der Entwicklung der Physik über die Mechanik hinaus sukzessive auf weitere Problemfelder angewandt, z.B. auf die Optik und die Elektrizitätslehre. Die klassische Dynamik steht - man denke an Galileo, Leibniz und Newton - am Beginn der modernen Wissenschaft.

Die weitere Entwicklung der klassischen Dynamik erbrachte weitgehende Erneuerungen und zugleich einen Rückzug in verschiedener Hinsicht. Es kamen gewissermaßen die Antithesen (im Sinne Hegels) zur rationalen und überschaubaren Ordnung der klassischen Dynamik zum Tragen. Die Kritik betraf nach und nach alle oben genannten Attribute der „klassischen“ Auffassung der Dynamik:

- 1.) Die Thermodynamik vertrat eine makroskopische und statistische Herangehensweise, mit der sie die fundamentale Irreversibilität der Entwicklung von Populationen von Teilchen postulierte. Pioniere dieses Ansatzes waren Boltzmann und Maxwell. Der bekannte zweite Hauptsatz der Thermodynamik betrifft die irreversible Zunahme der Entropie (Unordnung) in abgeschlossenen Viel-Teilchen-Systemen.
- 2.) Mit diesem makroskopischen Gesetz wird dem Reduktionismus eine Grenze gesetzt: die Eigenschaften makroskopischer Systeme sind nicht direkt aus den (noch klassisch gedachten) Eigenschaften der atomaren Teilchen ableitbar. Makroskopische Variablen wie Volumen, Temperatur oder Druck spielen nun eine Rolle; sie stehen nur statistisch in Beziehung zu den Newton’schen Größen „Kraft“, „Beschleunigung“ und „Masse“.
- 3.) Poincaré (1899) zeigte anhand des „Drei-Körper-Problems“, daß auch eine beliebig genaue Messung der Anfangsbedingungen nicht genügt, um die zukünftige Entwicklung eines aus drei oder mehr Körpern bestehenden Systems vorherzusagen. Das System ist nicht integrierbar. Das gleiche Prinzip liegt auch der viel jüngeren Chaostheorie zugrunde: die sensible Abhängigkeit von den Anfangsbedingungen führt zu einem endlichen Vorhersagehorizont. Die „starke“ Version des Determinis-

mus wird damit fragwürdig (Schiepek & Tschacher, 1992).

- 4.) Mit der Selbstorganisationstheorie und der Theorie nichtlinearer dynamischer Systeme beginnt sich allmählich ein integratives und umfassendes Bild der dynamischen Wissenschaft herauszuformen (Haken & Wunderlin, 1991; Nicolis & Prigogine, 1987). Die produktiven Folgen der gegenüber der Newton'schen Dynamik zu erhebenden Vorbehalte werden (als Hegel'sche „Synthese“) sichtbar: Die Irreversibilität zieht ein Verständnis von Gleichgewichten nach sich; das Studium von Gleichgewichten wird schließlich zu einem Hauptthema der Kybernetik und der Systemtheorie allgemein. Die Erweiterung auf nicht-konservative Systeme ermöglicht Ordnungszunahme trotz des global gültigen Entropiesatzes der Thermodynamik. Die Untersuchung spontaner Ordnungsbildung bleibt damit nicht länger der Metaphysik vorbehalten. Der Verzicht auf die starke Formulierung des Kausalitätsprinzips eröffnet die Welt des deterministischen Chaos und der Fraktale (Peitgen & Richter, 1986; Kriz, 1992).

Wir plädieren dafür, an diese Entwicklungen der Dynamik und der Systemtheorie in den Naturwissenschaften anzuknüpfen, wenn es um einen „systemischen“ Ansatz in der Psychologie geht. Diese Sichtweise ist klarer definiert als die metaphorische Rede von Systemen, wie sie häufig in der angewandten Psychologie verwendet wird.

Der Kern dieser Konzeptualisierung liegt in einem Phänomen, das auch den Kern der Synergetik (Haken, 1990) ausmacht, nämlich dem der *Selbstorganisation*. Selbstorganisation meint die spontane Emergenz von Ordnungszuständen in gewissen Systemen. Dieser Vorgang ist in den unterschiedlichsten Systemen der belebten und unbelebten Natur zu finden (Jantsch, 1979; Tschacher, 1990; Schiepek & Strunk, 1994). Um nur einige Beispiele zu nennen, die in der Literatur paradigmatischen Charakter haben: Der Laser beruht auf der Selbstorganisation der Lichtemissionen vieler Atome oder Moleküle, die bei angelegter Spannung beginnen, kohärent Licht auszusenden. Als Bénard-Instabilität bezeichnet man ein Flüssigkeitssystem, das, einer Temperaturdifferenz unterworfen, geordnete Konvektionsmuster ausformt. In chemischen Systemen wie der Belousov-Zhabotinski-Reaktion treten räumliche oder zeitliche Muster auf, wenn energiereiche Reaktanten zugeführt werden.

Es gibt eine Reihe von Voraussetzungen, die an ein System gestellt werden müssen, um Selbstorganisation möglich zu machen:

Dynamik: Selbstorganisation ergibt sich nur in Systemen, die sich verändern können, etwa indem ihre Komponenten beweglich, variabel sind. Systeme mit fester, statischer Struktur (ein Kristall, eine rigide Gesellschaft) erlauben keine ausreichende Dynamik, so daß sich auch keine (neuen) dynamischen Muster etablieren können.

Offenheit: das System muß in eine Umwelt eingebettet sein, die es antreibt und das System in „thermodynamischem Ungleichgewicht“ (far from equilibrium) hält. Dieses Ungleichgewicht wird durch einen Flux von Energie, Materie oder Information durch das System erreicht.

Komplexität: Das System muß aus vielen Komponenten bestehen bzw. viele Freiheitsgrade aufweisen, denn, wo keine Komplexität vorab besteht, kann auch keine Musterbildung in Sinne einer Reduktion von Freiheitsgraden bzw. von Komplexität stattfinden.

Auf der Basis des Gesagten können wir nun die Bestandteile eines komplexen Systems benennen. Wir halten uns dabei an die Begrifflichkeit der Theorie dynamischer Systeme und der Synergetik (Kaplan & Glass, 1995; Haken & Wunderlin, 1991; Schiepek & Strunk, 1994; Tschacher, im Druck).

In Abbildung 1 ist ein solches System schematisch dargestellt. Auf das komplexe System der vielen Komponenten bzw. Freiheitsgrade wirkt eine Umwelt - hier als Kontrollparameter bezeichnet - ein. Dies führt zur Ordnungsbildung im Sinne der Selbstorganisation. Die entstehenden emergenten Muster werden in der Synergetik als Ordner oder Ordnungsparameter bezeichnet. Im Gegenzug werden die Komponenten des Systems durch die Ordner versklavt (synchronisiert, kohärent gemacht). Dieses Konzept eines Systems wird auch als Mikro-Makro-System bezeichnet, wobei die emergenten Ordner die Makroebene darstellen (Troitzsch, 1990).

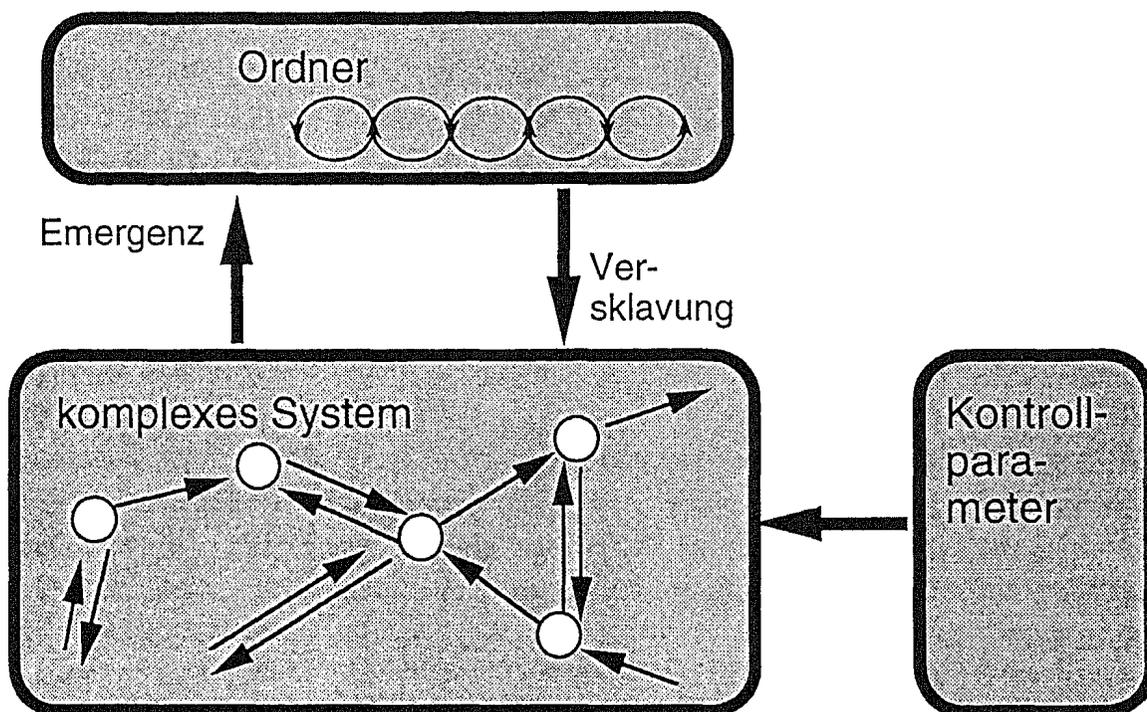


Abb.1: Schematische Darstellung eines selbstorganisierten Systems (aus Tschacher, im Druck).

Wir können in unserer methodenorientierten Einführung leider nur kurz umreißen, wie das Systemkonzept von Abbildung 1 in die Psychologie umgesetzt werden kann. Die Arbeiten hierzu sind bei weitem nicht abgeschlossen (Kriz, 1990; Tschacher, 1990; Schiepek & Tschacher, 1992; Schiepek, 1994; Schiepek & Strunk, 1994). Neben den theoretischen Überlegungen gibt es eine zunehmende Zahl empirischer Befunde, auf die wir in den folgenden Abschnitten verweisen werden. Den Stand der Dinge reflektieren auch einige einschlägige Sammelbände (Haken & Stadler, 1990; Tschacher et al., 1992; Schiepek & Spörkel, 1993; Vallacher & Nowak, 1994; Abraham & Gilgen, 1995; Langthaler & Schiepek, 1995; Sulis & Combs, 1996; Reiter et al., im Druck).

Eine Möglichkeit zur „Übersetzung“ in psychologische Begriffe besteht darin, auf der Mikroebene von einem komplexen psychologischen System auszugehen, dessen

Bestandteile rudimentäre Kognitionen und Handlungsmöglichkeiten sind. Diese hypothetischen unbewußten psychologischen Bausteine können als *Verhaltenskerne* bezeichnet werden. Durch Selbstorganisation emergieren Muster dieser Komponenten, die bewußtseinsfähig sind: Handlungen, Gedanken, Absichten. Diese sehen wir als Ordner oder Gestalten, die aus der Dynamik der vielen Verhaltenskerne evolvieren und diese rekursiv zugleich auch versklaven (daher *Prozeßgestalten*). Die wirksame Umwelt (die Kontrollparameter) dieses psychologischen Systems ist eine Motivationsquelle; die Kontrollparameter bezeichnen wir in Anlehnung an die Lewin'sche Psychologie (Lewin, 1936) und die neuere Volitionspsychologie (Heckhausen & Kuhl, 1985) deshalb als *Valenzen*. Diese Konzeptualisierung ist in Tschacher (im Druck) ausführlich beschrieben.

In einem methodischen Überblick werden wir im Rest dieses Kapitels eine anschauliche Einführung in die Theorie dynamischer Systeme geben. Wir werden exemplarisch darstellen, wie Konzepte zustande kommen und mit welchen Verfahren sie bearbeitet werden können. Hierzu sind Methoden notwendig, die teilweise noch nicht in den üblichen Methodenkanon der wissenschaftlichen Psychologie aufgenommen sind.

Wir verstehen unsere Ausführungen als ein Plädoyer: von Selbstorganisation und allgemein, von einer Systemperspektive in der Psychologie zu reden bedeutet, die Dynamik konkreter Realisationen von psychologischen Systemen empirisch zu untersuchen.

2 Modellierung dynamischer Systeme

Zwei Zugangsweisen zur dynamischen Modellierung sind möglich: die *induktive* dynamische Modellierung oder Zeitreihenanalyse geht von Beobachtungen eines Sachverhalts in der Zeit aus (also von einer oder von mehreren „parallel“ erhobenen Zeitreihen). Ziel ist es dabei, die Eigenschaften eines Verlaufs darzustellen und zu charakterisieren und/oder Eigenschaften des generierenden Systems zu induzieren. Modellierung heißt hier also, sich ein Bild von der Gestalt eines Prozesses und des zugrunde liegenden Systems aufgrund empirischer Daten zu machen.

Die *deduktive* Modellierung beschreitet den umgekehrten Weg. Aus „first principles“, theoretischen Grundannahmen und - in der Psychologie in der Regel - Plausibilitätsgründen kann man zu Evolutionsgleichungen oder Simulationssystemen gelangen, die ein dynamisches System definieren. Die solcherart theoriegeleitet gefundenen Eigenschaften (bzw. untersuchbare Folgerungen aus ihnen) können anschließend im Experiment überprüft werden.

2.1 Lineare induktive Modellierung

Jede induktive Modellierung beginnt mit einer Messung oder Datenerhebung. Da wir uns für die Modellierung von Prozeßgestalten interessieren, werden wir versuchen, ein und dieselbe(n) Variable(n) in der Zeit wiederholt zu erheben. Das Resultat einer solchen Erhebung ist eine (multiple) Zeitreihe, die die Dynamik eines bestimmten Systems

in einem bestimmten Kontext abbildet.

In unserem Beispiel steht die Befindlichkeit einer Patientin im Zentrum, die sich nach einer Krise im Rahmen einer psychotherapeutischen Krisenintervention in stationärer Behandlung befand (Tschacher, 1996). Das Meßinstrument ist eine Analogskala mit 16 Abstufungen zur Selbsteinschätzung der „Stimmung“, mit den Extrema „äußerst stark gut“ bzw. „äußerst stark schlecht“. Diese Bewertung sollte dreimal am Tag (zu festen Zeitpunkten morgens, mittags und abends) durchgeführt werden. Die Zeitreihendarstellung in Abbildung 2 umfaßt 79 Meßpunkte.

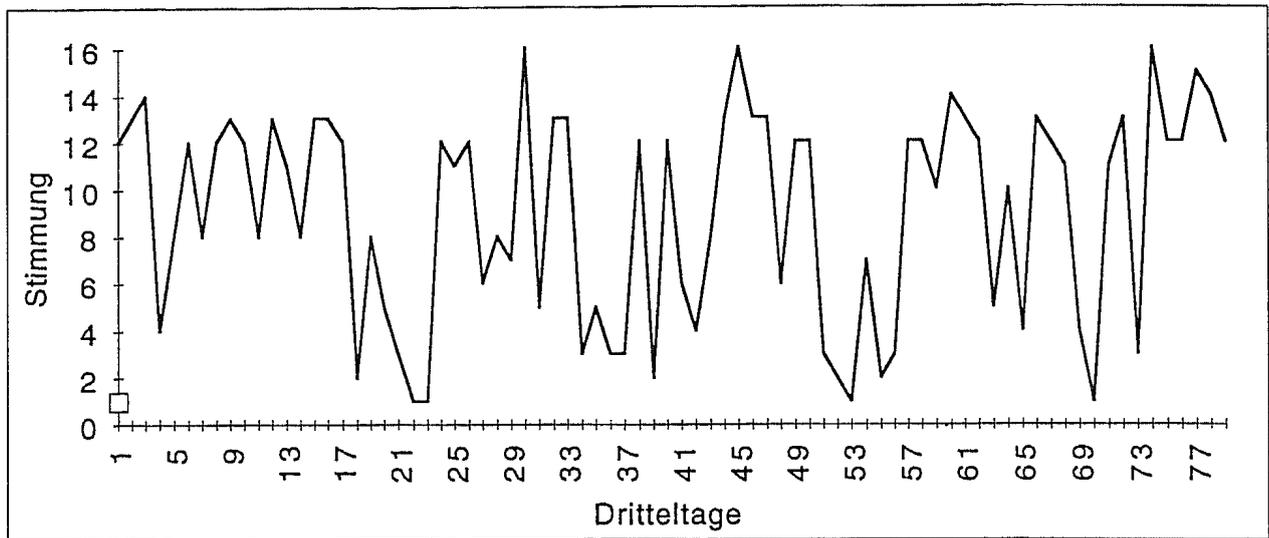


Abb. 2: Stimmungszeitreihe einer Patientin während eines krisenhaften Lebensabschnitts.

Autokorrelation: Welche „dynamische Information“ ist in dieser Zeitreihe enthalten? Man kann diese Frage so auffassen, daß man untersucht, wie die Zeitreihe mit sich selbst korreliert ist. Die herkömmliche, lineare Herangehensweise untersucht denn auch zunächst die korrelativen Zusammenhänge der Zeitreihe mit der um τ Schritte („lags“) verschobenen identischen Zeitreihe. Man erhält dadurch die Autokorrelationsfunktion (ACF) und die partielle Autokorrelationsfunktion (PACF); in der PACF sind die Einflüsse der zwischenliegenden lags herauspartialisiert.

Es zeigt sich eine signifikante Autokorrelation der Zeitreihendaten nur für lag 1. Die Werte der ACF schwanken innerhalb eines Bereichs mit der Amplitude des Standardfehlers in der Art einer gedämpften Oszillation. Die PACF bricht nach lag 1 ebenfalls ab; sie zeigt eine weitere Signifikanz bei lag 14 (also nach etwa 5 Tagen).

ARMA-Modellierung: Innerhalb der linearen Zeitreihenanalyse werden nun die Informationen über die serielle Abhängigkeit, die in der ACF und PACF repräsentiert sind, in ein Modell umgesetzt (Box & Jenkins, 1976; Schmitz, 1989). Zwei Möglichkeiten der Modellierung bestehen prinzipiell: die serielle Abhängigkeit wird entweder als Autoregression dargestellt, d.h. ein Wert ist ein mit einem Regressionsfaktor ϕ gewichteter vergangener Wert plus eine aktuelle Zufallsgröße; oder es wird der jeweilige Wert der Zeitreihe verstanden über die mit einem Faktor θ multiplizierten vergan-

genen Zufallseinwirkungen (moving average-Prozeß). In jeder Zeitreihenanalyse ist gesondert zu entscheiden, wieviele Zeitschritte zurückgegangen werden muß, um ein hinreichend gutes, aber auch möglichst sparsames Modell anzupassen. Ein allgemeines ARMA(p, q)-Modell (autoregressive moving average) ist zusammengesetzt aus einem AR-Modell p -ter Ordnung und einem MA-Modell q -ter Ordnung:

$$z_t = \phi_1 z_{t-1} + \phi_2 z_{t-2} + \dots + \phi_p z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (1)$$

Diese Form der Modellierung stellt den seit einigen Jahrzehnten eingeführten Kern der linearen Zeitreihenanalyse dar. Die ARMA-Methodik und verwandte Methoden (z.B. Markov-Modelle) fanden zunächst vor allem in der Ökonomie und in naturwissenschaftlichen Anwendungen Verwendung, seit einiger Zeit auch in der (v.a. Klinischen) Psychologie (Gottman et al., 1969; Petermann, 1989; Aebi et al., 1993).

Auf die verschiedenen Test und Kriterien, die die Güte einer ARMA-Modellierung betreffen und eine sukzessive Modellschätzung ermöglichen, soll hier nicht eingegangen werden. Im oben genannten Beispiel ergibt ein solches Verfahren, daß ein AR(1)-Modell den besten Kompromiß zwischen Erklärungsstärke und Sparsamkeit darstellt. Das Modell für die Patientin lautet:

$$z_t = 6.729 + 0.253z_{t-1} + a_t \quad (2)$$

Nimmt man die Signifikanz der PACF bei lag14 in das Modell auf (wofür Kriterien wie das AIC-Informationskriterium und der White-noise-Test der Residuen sprechen), erweitert sich das Modell um die gelagte (zeitverzögerte) Variable:

$$z_t = 4.061 + 0.233z_{t-1} + 0.339z_{t-14} + a_t \quad (3)$$

Fourieranalyse: Eine weitere „traditionelle“ Möglichkeit der Modellierung von Zeitreihen ist die Spektralanalyse, die in der Psychologie außerhalb psychophysiologischer Anwendungen bisher selten verwendet wurde. Die Fourier-Transformation zerlegt die Zeitreihe in zyklische Muster, d.h. sie wird aufgefaßt als Summe von Sinus- und Cosinuswellen verschiedener Frequenz und Amplitude. Die Fourier-Transformation ist insofern ebenso wie die ARMA-Modellierung eine lineare Abbildung: sie geht von der Summativität der (zyklischen) Komponenten aus. Analog dazu sind die ARMA-Modelle als Summen von AR- und MA-Prozessen verschiedener lags zu verstehen. Die Modellierung einer Zeitreihe mittels der Fourier-Transformation und die Modellierung mittels der oben beschriebenen ARMA-Methode, welche die ACF der Zeitreihe ausschöpft, sind ineinander überführbar. Prozesse mit identischem Powerspektrum besitzen auch dieselbe Autokorrelationsfunktion: sie sind also bezüglich ihrer linearstochastischen Serialität gleichwertige Prozesse. Dies wird bei der Methode der sog. phasenrandomisierten Surrogate (Kennel & Isabelle, 1992) ausgenutzt (s.u., Surrogatdatenmethoden).

Das Ergebnis der Fourier-Transformation einer Zeitreihe aus n Beobachtungen ist

von der Form:

$$z_t = \sum_{k=1}^m (A_k \cos(\omega_k t) + B_k \sin(\omega_k t)) + a_t \quad \text{mit } m = n/2 \quad (4)$$

Eine anschauliche Darstellung der Spektralanalyse bietet das Periodogramm, in dem die Quadratsumme der Amplituden gegen die Frequenzen abgetragen wird. Die Ordinaten bieten damit ein Maß für den Beitrag jeder Frequenz zur gesamten Variation in der Zeitreihe. Das Periodogramm der obigen Stimmungszeitreihe ist in Abbildung 3 dargestellt.

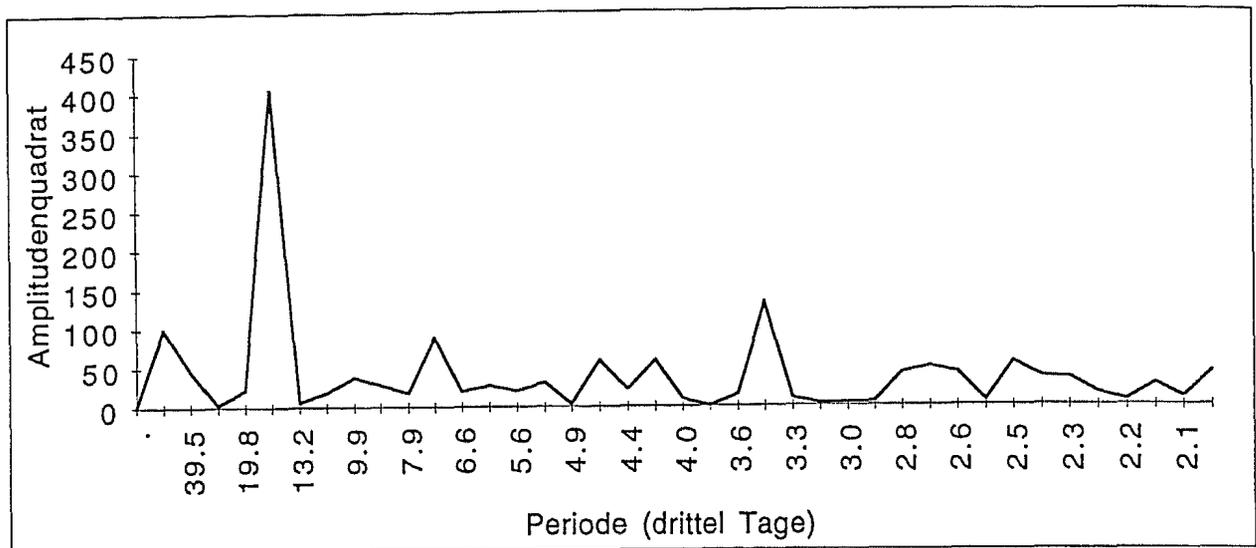


Abb. 3: Periodogramm der Stimmungszeitreihe in Abb. 2.

Die Spitze („Peak“) im ansonsten „flachen“ Spektrum hebt eine einzelne Frequenz hervor, die einer Periode von ca. 5 Tagen im Stimmungsverlauf der Patientin entspricht. Die Autokorrelation in der Gegend von lag 14 bis lag 16 deutete bereits auf diese Auffälligkeit hin. Man kann nun auf der Basis der Spektralzerlegung ebenfalls ein Modell der Zeitreihe aufschreiben. Dieses lautet im Beispiel der Stimmungsdynamik bei Berücksichtigung nur der 5-Tages-Periodik:

$$z_t = 0.93 \cos(0.4t) - 3.06 \sin(0.4t) + a_t \quad (5)$$

Multivariate lineare Modellierung: Wenn mehrere Observablen eines Systems beobachtet werden können, ist neben der Information aus den Autokorrelationen der Einzelzeitreihen natürlich zusätzlich die der Crosskorrelationen vorhanden. Es kann daher nicht nur modelliert werden, wie ein Zustand der Variable mit einem Zustand dieser selben Variable zu einem folgenden Zeitpunkt zusammenhängt, sondern zusätzlich eine Aussage über die wechselseitigen zeitverschobenen Wirkungen zwischen verschiedenen Variablen gemacht werden. Solche zeitverschobenen Einflüsse geben Hinweise auf kausale Relationen.

In empirischen Studien (Tschacher, 1996; Brunner et al., in diesem Band) wird als Methode häufig die sog. Zustandsraummodellierung angewendet, die im SAS-Statistikpaket als Prozedur STATESPACE vorliegt. STATESPACE führt eine kanonische Korrelationsanalyse durch, um das Zustandsraummodell einer multiplen Zeitreihe zu bestimmen; dabei werden die zeitverschobenen Crosskorrelationen zwischen Variablen bestimmt, wobei der Beitrag der jeweiligen Autokorrelationen herauspartialisiert wird. Die Anzahl lags, die in das Modell aufgenommen werden müssen, können durch verschiedene Kriterien bestimmt werden. Wie bei den univariaten ARMA-Modellen können Signifikanzen für die einzelnen Koeffizienten angegeben werden. Der Modellierungsansatz für ein System mit Mittelwert = 0 lautet $z_t = Fz_{t-1} + Ga_t$, wobei F die Übergangsmatrix (deren Komponenten den Zustandsvektor z_t gewichten) und G die Inputmatrix (Gewichte der Zufallsvektoren a_t) genannt werden.

Für den bereits modellierten Stimmungsverlauf der Patientin liegen nun insgesamt Erhebungen von drei Observablen vor: neben der „Stimmung“ wurden gleichzeitig noch die „Spannung“ und die „Aktivität“ geratet. Die Reihenfolge der Variablen in der unten dargestellten F -Matrix lautet „Spannung“-„Aktivität“-„Stimmung“.

$$z_{t+1} = \begin{bmatrix} .29 & .18 & -.26 \\ .25 & .01 & .17 \\ .09 & .12 & .16 \end{bmatrix} z_t + \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} a_t \quad (6)$$

Die Werte der Zellen $F(1,1)$, $F(2,1)$ und $F(1,3)$ sind signifikant. Sie können folgendermaßen interpretiert werden: die Stimmung erniedrigt die Spannung (-.26), nicht aber umgekehrt (.09). Spannung erhöht die Aktivität (.25). Die Spannung ist autoregressiv stabil (.29).

Es wird an unserem Beispiel ersichtlich, daß diese Methode eine sehr praktikable Modellierung des Gefüges der Wechselwirkungen in einem System erlaubt. Rechnungen mit nichtlinear-chaotischen Zeitreihen zeigen darüber hinaus, daß STATESPACE auch hier die linearen Zusammenhänge korrekt herausfiltert und keine falsch-positiven Signifikanzen anzeigt.

2.2 Nichtlineare induktive Modellierung

2.2.1 Einbettung einer Zeitreihe

Bislang wurden einfache Möglichkeiten einer stochastischen linearen Modellierung von Zeitreihen besprochen, die in der Psychologie und den Sozialwissenschaften seit Jahrzehnten eingeführt sind. Die Querschnittsorientierung in der psychologischen Methodenlehre hat allerdings bedauerlicherweise verhindert, daß selbst einfache zeitreihenanalytische Methoden in größerem Ausmaß eingesetzt wurden. Die Theorie dynamischer Systeme entspringt - wie einleitend erwähnt - einer physikalisch-mathematischen Tradition; die Theorie gründet sich mathematisch auf Gleichungen, welche die (meist zeitliche) Evolution einer Variablen bestimmen, also auf Differentialrechnung.

Die Konzepte und Methoden der Theorie dynamischer Systeme lassen sich am besten einführen und begründen, wenn man den Weg der geometrischen Veranschaulichung wählt. Der anschauliche Zugang geht vom Konzept des Zustandsraums (synonym: Phasenraum) aus. Ein Zustand eines dynamischen Systems zu einem Zeitpunkt t_0 ist dann genau spezifiziert, wenn die Ausprägungen aller m relevanten Variablen des Systems zu diesem Zeitpunkt bekannt sind. Man kann dies durch einen Vektor darstellen, dessen Komponenten diese Variablenausprägungen sind: $z_0 = (x_1, x_2, \dots, x_m)$. Ein einfaches Beispiel aus der Mechanik wäre ein Pendel: dessen Zustand ist zu jedem Zeitpunkt durch den Ort und den Impuls (jeweils gemessen am Pendelkörper) gegeben. Der Zustandsraum des Pendels ist damit eine Ebene, die durch ein Koordinatensystem mit den Achsen Ort und Impuls aufgespannt wird. Der Zustand des Pendels ist ein Punkt in dieser Ort-Impulsebene.

In Abbildung 4 ist entsprechend der „psychologische Zustandsraum“ der oben angeführten Patientin dargestellt. Wie bereits erwähnt, wurde nicht nur die in Abbildung 1 gezeigte Stimmungsvariable erhoben, sondern simultan auch die subjektiv wahrgenommene bzw. beobachtete „Spannung“ und die „Aktivität“. Diese drei Observablen können natürlich nicht beanspruchen, den psychologischen Zustand eines Individuums vollständig zu charakterisieren; immerhin steht hinter der Auswahl der Versuch, einen repräsentativen Ausschnitt der psychologischen Mannigfaltigkeit global zu erfassen (vgl. die Osgood'schen Dimensionen „evaluation“, „potency“ und „activity“; Osgood et al., 1957). Wenn wir also davon ausgehen, daß der im Sinne einer bestimmten Fragestellung relevante Zustandsraum eines komplexen psychologischen Systems durch die „Spannung“, „Aktivität“ und „Stimmung“ hinreichend bestimmt wäre, käme einem einzelnen Zustand genau ein Punkt in diesem dreidimensionalen Raum zu. Auch die Dynamik des Systems läßt sich dann leicht geometrisch veranschaulichen: sie ist repräsentiert durch eine Linie (in der Theorie dynamischer Systeme „Trajektorie“ genannt), die einer kontinuierlichen Abfolge von Punkten entspricht. Durch die Sukzession der Zeitpunkte, zu denen die Zustände gehören, ist die Trajektorie in unserem Beispiel mit einer Richtung ausgestattet.

Wir wollen diese grundlegenden Definitionen mit einem Blick auf das Konzept des Systemgleichgewichts (Stabilität eines Systems) abrunden. Ein Gleichgewicht kann ebenso wie ein beliebiger Systemzustand durch einen bestimmten ausgezeichneten Punkt im Zustandsraum markiert sein. Am Beispiel des gedämpften Pendels läßt sich dies leicht zeigen: Wenn das Pendel, durch Reibungskräfte gebremst, schließlich zur Ruhe kommt, sind sein Impuls und sein Ort (bei geeigneter Wahl der Koordinaten) gleich Null geworden. Der Punkt $z(0,0)$ wird Attraktor des Systems genannt. Alle Trajektorien eines gewissen Bereiches im Phasenraum (dem Bassin oder Einzugsbereich) enden im Attraktor, der in diesem Fall ein sog. Fixpunkt ist. Attraktoren brauchen jedoch nicht konstante Zustände (also Fixpunkte) sein. So können auch periodische Veränderungen (konstante Oszillationen) attrahierenden Charakter haben. Ein einleuchtendes Beispiel ist die Pendeluhr, die so konstruiert ist, daß ihr Pendel eine konstante Bewegung beschreibt. Störungen durch Anstoßen oder Festhalten des Pendels werden durch den Mechanismus kompensiert. Im Phasenraum ist dieser Attraktor eine

geschlossene Trajektorie: es werden stets dieselben Zustände wieder und wieder durchlaufen. Solche periodischen Attraktoren heißen „Grenzzyklen“. Treten solche attrahierenden Oszillationen in mehr als einer Phasenraumrichtung auf, resultieren zwei- und höherdimensionale Attraktoren („Tori“).

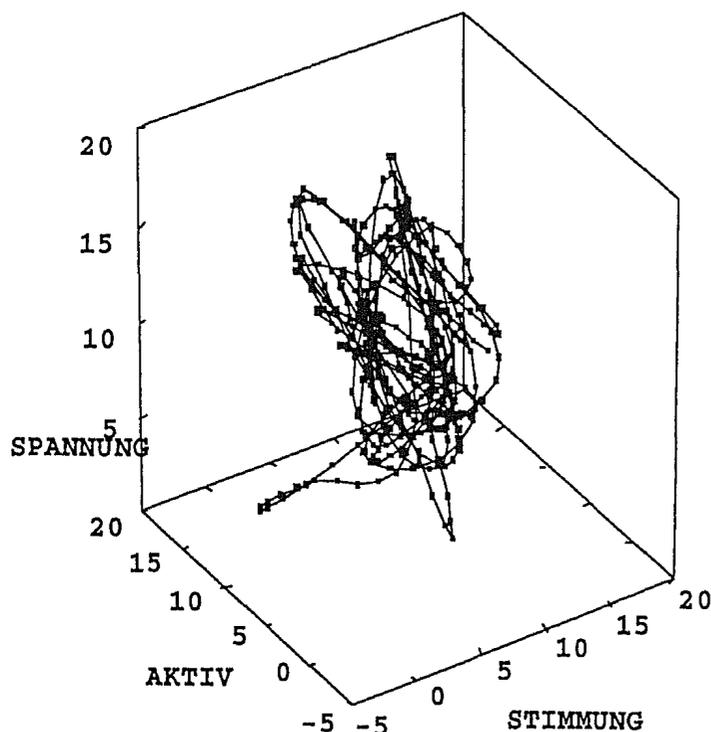


Abb. 4: Trajektorie der Dynamik einer Patientin im Phasenraum (Achsen des Raums: Spannung, Aktivität, Stimmung). Rohdaten sind 79 Meßzeitpunkte (entsprechend ca. 26 Tagen). Die Trajektorie wurde mit einem spline-Verfahren interpoliert und geglättet.

In vielen Anwendungen ist es nicht möglich, mehr als eine Observable des Systems in der Zeit zu erheben. Wie wäre es dann möglich, etwa einen Grenzzyklus darzustellen, der wenigstens eine zweidimensionale Repräsentation erfordert? Es ist durch einen „Kunstgriff“ dennoch möglich, eine Zustandsraumdarstellung des Systems zu rekonstruieren, wenn nur die Zeitreihe einer einzelnen generellen Observablen vorliegt. In dieser Observablen sind die relevanten Zustandsvariablen des Systems in unbekannter Kombination versteckt. Dafür wird nun die Autokorrelation der einzelnen Zeitreihe ausgenutzt: statt der Komponenten x_1, x_2, \dots, x_m des „wahren“ Zustandsvektors werden zeitverschobene Werte der einen erhobenen Variablen x verwendet. Bei einer Zeitverschiebung τ ergibt sich ein rekonstruierter Zustandsvektor $\mathbf{z}_{t_0} = (x_{t_0}, x_{t_0+\tau}, x_{t_0+2\tau}, \dots, x_{t_0+(m-1)\tau})$, wobei m die Dimension des Zustandsraums (die Anzahl der „Einbettungsdimensionen“) bezeichnet. Takens (1981) bewies, daß „typische“ Eigenschaften des Systems im Phasenraum (s.u.) bei der Rekonstruktion durch die zeitverzögerten Koordinaten erhalten bleiben. Das Einbettungstheorem wurde zu einem wichtigen (wenngleich gelegentlich überstrapazierten) Hilfsmittel in der dynamischen Forschung.

Bei der Einbettung einer Zeitreihe stellt sich sofort die Frage, wie die Parameter τ und m zu wählen sind. Die Größe der Zeitverzögerung sollte gewährleisten, daß die

gelagten Komponenten des Zustandsvektors weder völlig unabhängig noch völlig abhängig voneinander sind. Der Grund hierfür ist folgender: Sind die Komponenten zu wenig voneinander getrennt (τ ist zu klein), wird der Attraktor schlecht aufgefalted, denn die Achsen des Phasenraums geben dieselbe Information wieder; ist dagegen τ so groß, daß die Komponenten völlig unkorreliert sind, wird der Attraktor in ganz unabhängige Richtungen des Phasenraums projiziert, und seine Gestalt ginge wiederum verloren. Also ist ein Rezept für einen Mittelweg zu suchen (Abarbanel et al., 1993). Als Faustregel für die Wahl von τ wird generell der lag des ersten Minimums der ACF verwendet. Das Problem hierbei kann sein, daß die Autokorrelation als lineares Maß die nichtlineare Abhängigkeit der Komponenten des Zustandsvektors unzureichend erfaßt. Mayer-Kress und Layne (1987) schlagen deshalb vor, die mutual information als besseren Indikator heranzuziehen. Die mutual information ist gewissermaßen die nichtparametrische Version der ACF. Als Wert für τ wird analog der lag des ersten Minimums der mutual information gewählt.

Die zweite Frage bei der Rekonstruktion des Phasenraums aus einer einzelnen Observablen betrifft die Einbettungsdimension m , und damit die zentrale Frage nach der Anzahl der Freiheitsgrade (der Dimensionalität) des Systems. Für manche Systeme, für die multiple Zeitreihen vorliegen, kann die Dimensionalität aus der Kovarianzmatrix linear geschätzt werden, indem man ein etwa faktorenanalytisches Verfahren über die Zeit verwendet (Tschacher & Grawe, 1996). Wie soll man aber vorgehen, wenn der Phasenraum selbst aus einer einzelnen Zeitreihenrealisation des Systems rekonstruiert werden soll? Roux et al. (1983) führen an der Belousov-Zhabotinski-Reaktion vor, daß ein rekursives trial-and-error-Verfahren möglich ist (vgl. Tschacher, 1990). Weiterhin kann man im Prinzip die im folgenden aufgeführten „typischen“ Eigenschaften des Systems für wachsende Einbettungsdimensionen jeweils berechnen, und somit die Abhängigkeit der Eigenschaften von m bestimmen (die Frage lautet also: Wie skaliert eine Eigenschaft mit der Einbettungsdimension?). Die kleinste Einbettungsdimension, ab der eine Berechnung konstant bleibt, ist dann eine Schätzung der geeigneten Einbettungsdimension, die allein schon aus datenökonomischen Gründen zu bevorzugen ist.

Wenn keine solche „Saturation“ oder Sättigung auftritt, so ist dies selbst ein wichtiges Ergebnis der Zeitreihenanalyse: nur von Prozessen mit serieller Struktur ist ja zu erwarten, daß sie sich finitdimensional repräsentieren lassen. Ein reiner Zufallsprozeß füllt jeden rekonstruierten Phasenraum aus; seine Komplexität ist prinzipiell nicht reduzierbar auf eine „typische“ Eigenschaft. In der Praxis der linearen und nicht-linearen Zeitreihenanalyse ist es denn auch die Kardinalaufgabe, die Gestalt einer Zeitreihe (möge sie aus einem autoregressiven Prozeß oder auch aus niedrigdimensionalem Chaos hervorgegangen sein) von bloßem Zufall zu unterscheiden. Eine Sättigung kann bei Schätzprozeduren der dimensional Komplexität allerdings auch dann ausbleiben, wenn die innere Struktur der Zeitreihe *nichtstationärer* Art ist, d.h. wenn sich die Prozeßgestalt des Signals selbst verändert. Topologisch würde dies bedeuten, daß sich Attraktoren mit unterschiedlichen Eigenschaften gewissermaßen überlagern und damit die Identifikation klarer Strukturen erschwert oder verunmöglicht. Dies ist gerade für psychologische und biologische Prozesse ein sehr relevanter Fall, denn für diese ist die Eigenschaft der Nichtstationarität geradezu eine Funktionsvoraussetzung. Auch Psy-

chotherapien setzen nichtstationäre Prozesse des Erlebens und der Interaktion voraus und zielen auf solche ab (Schiepek et al., im Druck; Kowalik et al., im Druck). Nichtlineare Maße für nichtstationäre Zeitreihen werden im Anhang des Beitrags von Kowalik und Schiepek (in diesem Band) vorgestellt.

Eine weitere Methode zur Bestimmung der Einbettungsdimension m ist die Methode der „falschen nächsten Nachbarn“ (false nearest neighbors, Kennel et al., 1992). Nächste Nachbarn (NN) sind die Zustände eines Systems (also Punkte im Phasenraum), die den geringsten Abstand zu einem Referenzpunkt haben. Falsche NN sind solche Punkte in einem rekonstruierten Phasenraum, die nur deshalb einem Referenzpunkt benachbart sind, weil der noch nicht genügend aufgefaltete Phasenraum sie in eine solche Nachbarschaft projiziert (analog wie etwa der Schatten eines über mir fliegenden Flugzeugs direkt neben meinem eigenen Schatten auf die Erde geworfen sein kann, ohne daß das Flugzeug und ich im „wirklichen“ dreidimensionalen Raum benachbart sind). Im richtig dimensionierten Phasenraum sollten solche irreführenden Nachbarschaften nicht mehr vorkommen; die gewählte Einbettung entfaltet dann die Zustände des Systems topologisch zutreffend. Falsche NN sind also Indikatoren für die Wahl von m . Das Verfahren funktioniert folgendermaßen: Man berechnet die Abstände l zwischen benachbarten Punkten im Phasenraum, zunächst für eine Einbettungsdimension m , dann für die nächstgrößere Einbettung $m+1$. Das Auftreten von sprunghaft größer werdenden Abständen $l_{m+1} \gg l_m$ deutet auf das Vorhandensein von falschen NN hin, denn wirkliche Nachbarn werden auch in höheren Dimensionen wieder als Nachbarn abgebildet. Diejenige Einbettung, bei der im Idealfall keine falschen NN mehr auftreten, ist die zu wählende Dimension des Phasenraums. Die falsche NN-Methode ist die beste derzeit verfügbare Methode zur Bestimmung der Dimension des Phasenraums (Stewart, 1995). Wir haben ein analoges Verfahren bei verschiedenen Anwendungen (Scheier & Tschacher, 1996) benutzt, indem diejenige Einbettung gewählt wurde, bei der die Vorhersagbarkeit des Systems aufgrund der NN ein Optimum aufweist (s. unter Forecasting in diesem Beitrag).

2.2.2 „Typische“ Eigenschaften eines Systems im Phasenraum

Im folgenden wollen wir einige Maße besprechen, die es erlauben, ein dynamisches System im Zustandsraum zu charakterisieren: die „ergodischen Maße“ der Informationsdimension, Entropie und Lyapunov-Exponenten. Die ergodische Theorie (Eckmann & Ruelle, 1985) liefert den mathematischen Ausgangspunkt für eine Diskussion solcher *zeitinvarianter* Maße von dynamischen Systemen.

Dem Aufsuchen von Invarianten kommt bei der nichtlinearen Modellierung (sowohl der induktiven wie der deduktiven Variante) eine zentrale Rolle zu. Invarianten sind solche Maße, die bei einer Reihe von Transformationen des untersuchten Systems konstant bleiben: etwa bei einer Veränderung der Anfangsbedingungen, während verschiedener Zeitabschnitte des Systems, oder bei einer Veränderung des Koordinatensystems. Invariante Maße können quantitative Maße sein; es existieren aber auch qualitative Eigenschaften, die etwa topologische Attribute von Attraktoren im Phasenraum ansprechen, um ein System klassifizieren zu helfen. Erstere Invarianten werden auch

als „continuous invariants“, letztere topologische Invarianten als „discrete invariants“ bezeichnet (Thompson & Stewart, 1993). Abarbanel et al. (1993) vermuten, daß quantitative Invarianten, wie die im folgenden zu besprechenden Lyapunov-Exponenten oder die Dimensionalität eines Attraktors, allein nicht genügen, um Systeme erschöpfend zu charakterisieren.

Dimensionalitäten: Die Bestimmung der fraktalen Dimension als eine Methode zur Quantifizierung chaotischer Dynamik erhielt in den vergangenen Jahren viel Popularität - vielleicht zu viel, was den Bereich der Psychologie und der Sozialwissenschaften anbelangt. Der Begriff des Attraktors wurde bereits erwähnt; nun hat die dynamische Forschung mit Lorenz' (1963) und Rösslers (1976) Beschreibungen nichtperiodischer Flüsse eine weitere Klasse von Attraktoren entdeckt, die weder zu den Fixpunkten noch zu den periodischen Attraktoren zu rechnen sind: die chaotischen Attraktoren. Trajektorien, die auf solchen Attraktoren verlaufen, zeigen viele Eigenschaften von rein zufälligen Entwicklungen: sie sind (zumindest auf Dauer) nicht vorhersagbar und zeigen u.U. ein flaches Periodogramm. Chaotische Dynamik läßt sich aber (im Idealfall) von stochastischer Dynamik durch ihre finite fraktale Dimension trennen. Stochastisch erscheinende Verläufe, die aus Systemen mit wenigen Freiheitsgraden herrühren, gehören also zu einer speziellen, diagnostizierbaren Klasse von Dynamiken.

Damit stehen wir wieder vor dem oben gestellten Problem, wie die beste Einbettungsdimension m eines nur in *einer* Zeitreihe vorliegenden empirischen Systems zu bestimmen sei. Die Lösung besteht darin zu untersuchen, wie die Verteilung der Punkte im Phasenraum (d.h. der Systemzustände) mit dem Phasenraum skaliert. Für beliebige Längenskalen r im Phasenraum beobachten wir das Verhalten der Punkteverteilung $p(r)$. Ein Beispiel für $p(r)$ könnte etwa die Anzahl der Punkte in einem Volumenelement des Radius r sein. Für den Grenzwert $r \rightarrow 0$ gilt nun die Beziehung

$$p(r) \propto r^d \quad (7)$$

wobei d die Dimension bezeichnet. Zur Plausibilisierung dieser Proportionalität: Man sieht unmittelbar, daß die Anzahl von *in der Ebene* gleichverteilten Punkten mit dem *Quadrat* von r skaliert; im (dreidimensionalen) *Raum* ist der Skalierungswert $d = 3$, usw. Zugleich wird etwa eine (zweidimensionale) Fläche mit dem Quadrat eines Beobachtungsausschnitts r skalieren, auch wenn diese Fläche in beliebig hochdimensionalen Phasenräumen eingebettet wird. Der Skalierungswert d wird also bei wachsenden $m > d$ saturieren. Dieser Wert, die *Dimensionalität* d muß keine ganze Zahl sein; chaotische Attraktoren weisen meist ein gebrochenzahliges (fraktales) d auf (Abraham & Shaw, 1984).

Wenn man (7) beidseitig logarithmiert

$$\log p(r) \propto d \log r \quad (8)$$

wird deutlich, daß die Dimensionalität d als Steigung in einem log-log-Diagramm ab-

gelesen werden kann (Mayer-Kress, 1986).

Es gibt mehrere Möglichkeiten, $p(r)$ zu berechnen. Eine detaillierte Diskussion findet man z.B. in Farmer et al. (1983), Mayer-Kress (1986) und in Theiler (1990). Der in den Anwendungen am weitaus häufigsten verwendete Algorithmus stammt von Grassberger und Procaccia (1983). Zur Bestimmung des Skalierungsverhaltens eines Systems wird das „Korrelationsintegral“ $C(r)$ herangezogen, das als die durchschnittliche Anzahl von Punktepaaren mit einem Abstand kleiner als r definiert ist. Die Korrelationsdimension d_2 ergibt sich damit als

$$d_2 = \lim_{r \rightarrow 0} \log \frac{C(r)}{\log r}. \quad (9)$$

Die Korrelationsdimension gilt im Bereich bis zur Einbettungsdimension $m = 10$ als relativ zuverlässig, falls die Meßqualität der Rohdaten genügend ist (fast kein Rauschen), und mindestens $N = 10^{m/2}$ Datenpunkte zur Verfügung stehen (Ruelle, 1990).

Entropie: Ein chaotisches System kann, wie auch eine stochastische Zeitreihe, als Informationsquelle betrachtet werden (Shaw, 1981). Zwei minimal unterschiedliche Anfangswerte führen bei chaotischer Dynamik nach einer finiten Zeit zu deutlich unterschiedlichen Zuständen, d.h. benachbarte Trajektorien divergieren. Diese Informations- bzw. Entropieproduktion läßt sich für jedes differenzierbare System quantifizieren; sie ist eine dynamische Invariante des Systems. Es läßt sich wiederum ein ergodisches Maß finden, das die mittlere Rate der Informationsgenerierung (Kolmogorov-Sinai-Entropie K) beschreibt (Eckmann & Ruelle, 1985; Abarbanel et al., 1993). Ist $K > 0$, kann man von einer Entropie- oder Informationsproduktion des Systems sprechen. K ist damit ein Indikator von Chaos wie auch von Stochastizität.

Operationale Methoden zur Abschätzung von Entropie und Komplexität in Zeitreihen sind für psychologische Anwendungen von großer Bedeutung. Zur Prüfung der Hypothese, daß in Therapiesystemen entsprechend der Selbstorganisationstheorie die Komplexität der therapeutischen Dyade im Verlauf der Therapie abnimmt, wurde eine lineares Maß für die Komplexität in einer multiplen Zeitreihe (die Variablen von Therapeuten- und Patientenstundenbögen enthält) benutzt. Das Maß bestimmt die Ordnung mit Hilfe der Determinante der Kovariationsmatrix. Es zeigt sich in einer Stichprobe von 22 Psychotherapieverläufen, daß die Ordnung zum Ende der Therapien hin sehr signifikant zunimmt (Tschacher & Grawe, 1996).

Lyapunov-Exponenten: Der Charakter eines Flusses im Phasenraum kann dadurch eingeschätzt werden, daß das Schicksal eines kleinen Phasenraumvolumens, das der Systemdynamik ausgesetzt ist, untersucht wird. Man kann sich folgendes vorstellen: Man markiert eine kleine Stelle eines Teiges mit Farbe und beobachtet, wie sich die farbige Stelle beim Kneten, Auswalzen und Zurückfalten des Teiges verändert: Beim Auswalzen werden farbige Stellen auseinandergezogen (divergiert), während beim Zusammenklappen bereits voneinander entfernte farbige Punkte wieder nahe beieinan-

der zu liegen kommen (konvergieren). Das markierte Volumen ist also dauernden Veränderungen unterworfen, die offensichtlich von der Dynamik des Systems abhängen. Die Beschreibung der Raten, mit der die Markierung in alle Raumrichtungen gedehnt oder gestaucht wird, ist offensichtlich ein Charakteristikum dieser Dynamik.

Formal kann man im Phasenraum eines zu untersuchenden Systems entsprechend vorgehen. Man wählt eine m -dimensionale Kugel zu einer Zeit $t=0$ als Ausgangspunkt, und kann dann den i -ten Lyapunov-Exponenten folgendermaßen definieren (Wolf et al., 1985):

$$\lambda_i = \lim_{t \rightarrow \infty} \frac{1}{t} \log_2 \frac{p_i(t)}{p_i(0)}. \quad (10)$$

Dabei bezeichnet $p_i(t)$ eine Hauptachse des aus der Kugel in der Zeit t entstandenen Ellipsoids (vorausgesetzt ist eine differenzierbare Zeitevolution des Systems sowie die Existenz eines Grenzwerts). Die Exponenten λ_i konstituieren das Lyapunov-Spektrum, da in jeder Phasenraumrichtung eine Ellipsoidachse und ihre Länge p_i definiert ist; divergierende bzw. expandierende Richtungen haben positive Exponenten. Die Summe $\sum_{i=1}^m \lambda_i$ gibt an, ob das Phasenraumvolumen durch den Fluß insgesamt kontrahiert oder expandiert. Ist diese Summe negativ, spricht man von einem dissipativen System (einem in toto homöostatischen System); für ein konservatives System im Sinne von Hamilton gilt $\sum_{i=1}^m \lambda_i = 0$; ein stochastisches System ist durch $\sum_{i=1}^m \lambda_i > 0$ gegeben. Ein dissipatives System mit mindestens einem positiven Exponenten definiert Chaos. Die experimentelle Bestimmung der Lyapunov-Exponenten ist also wichtig für die Charakterisierung einer gegebenen Dynamik. In der Regel können experimentell nur die positiven λ_i berechnet werden (Eckmann & Ruelle, 1985). Ein Beispiel für die Berechnung des jeweils größten Lyapunov-Exponenten (LLE) aus sieben Verhaltenszeitreihen von Therapeut und Klientin (erhoben mit der Methode der „Sequentiellen Plananalyse“) findet sich in Schiepek und Kowalik (1994) sowie in Schiepek et al. (im Druck). Das interaktionelle Verhalten bzw. die Selbstdarstellung der Klientin erwies sich in dieser Einzelfallstudie als „chaotischer“, d.h. weniger vorhersagbar als das des Therapeuten.

Topologische Invarianten: Ein idealer seltsamer Attraktor hat in sich eine Menge instabiler periodischer Orbits (vgl. Droste & Schiepek, in diesem Band). Die topologischen Eigenschaften der Verknüpfungen zwischen diesen instabilen Orbits charakterisieren verschiedene Klassen der Dynamik, und diese topologische Klassifikation bleibt auch dann erhalten, wenn die Parameter des Systems sich ändern, also das System etwa von oszillativem Verhalten über Periodenverdopplungen zu chaotischem Verhalten evolviert. Dies steht offenbar in direktem Kontrast zu den bisher besprochenen quantitativen Invarianten, die mit den Kontrollparameteränderungen gekoppelt sind (Abarbanel et al., 1993).

Eine topologische Invariante kann etwa darin bestehen, daß ein Attraktor im Phasenraum unter der Dynamik verdreht wird. Die Orbits auf dem Rössler-Attraktor z.B. werden bei jedem Umlauf wie ein Möbiusband einmal gedreht (Abraham & Shaw, 1983; Tschacher, 1990). Andere seltsame Attraktoren können andere solche Verwindungszahlen aufweisen. Ein anderes Beispiel einer topologischen Invariante kann am Lorenz-Attraktor plausibel gemacht werden, dessen Trajektorien auf zwei „Flügeln“ verlaufen können. Weiterhin können Attraktoren mit einem Loch in der Mitte (wie der Ueda-Attraktor, Stewart, 1995) von anderen Attraktoren unterschieden werden, deren Mitte zum Einzugsbereich des Attraktors gehört. Die Klassifizierung anhand diskreter Invarianten hat sich allerdings bislang erst für Attraktoren in dreidimensionaler Einbettung als praktikabel erwiesen.

Im Hintergrund dieser Charakterisierung von Dynamiken steht die Idee, eine Bibliothek von Attraktorschablonen aufzubauen: eine neue Dynamik kann dann anhand mehrerer qualitativer Eigenschaften einer Attraktorklasse zugeordnet werden. Eine solche Zuordnung könnte eine sozusagen „natürliche“ Diagnostik von Dynamiken eröffnen, ganz im Sinne der Hoffnungen, die Lewin (1936) in die topologische Psychologie setzte.

Solche qualitativen Klassifikationen könnten eines Tages im Bereich der Psychologie und Psychiatrie eingesetzt werden, um chaosverdächtige Verläufe gruppieren zu können, auch wenn aufgrund der Datenqualität oder Skalendignität die Bestimmung kontinuierlicher Invarianten schwierig ist. Bislang ist uns jedoch keine Anwendung außerhalb der Physik bekannt.

Forecasting: Ein wesentliches Ziel jeder Modellierung ist es, ein besseres Verständnis dynamischer Systeme zu erlangen, d.h. Anhaltspunkte für die Vorhersage und Kontrolle von Entwicklungen zu gewinnen. In der Psychologie stellen sich der dynamischen Forschung letztlich Fragen der Anwendung: Welche Entwicklung in einem System kann ich erwarten? sowie: Wie kann ich intervenieren?

Man sieht sofort, daß die oben erörterten Modelle (z.B. Gl. 3) eine Prognose (einen „Forecast“) liefern, wenn man einen beliebigen Anfangswert z_{t-1} einsetzt, um einen Forecast z_t zu berechnen. Selbstverständlich ist das Zutreffen der Prognosen ein Gütekriterium der gewonnenen Modelle. Man kann etwa durch Forecasting ein bereits erhaltenes Modell schrittweise optimieren.

Es besteht nun auch die Möglichkeit, durch wiederholtes Forecasting innerhalb einer empirischen Zeitreihe Informationen zur Modellierung der Dynamik selbst zu gewinnen. Ein Verfahren, das (anders als ARMA- oder Fourier-Modelle) auf lineare Parameterschätzungen verzichtet, wurde von Sugihara und May (1990) vorgestellt. Diese Methode kann mit statistischen Hypothesenprüfungen kombiniert werden (Scheier & Tschacher, 1994; 1996) und soll nun vorgestellt werden.

Die Diskussion im Bereich dynamischer Systeme hat sich bisher vorwiegend mit strukturellen Eigenschaften nichtlinearer Systeme in einer geeigneten Einbettung befaßt, nämlich mit der Dimensionalität. Unterschiedliche dynamische Systeme zeichnen sich jedoch vor allem selbstverständlich durch spezifische *dynamische* Merkmale aus: Deterministisches Chaos etwa bedeutet langfristige Unvorhersagbarkeit bei kurzfristi-

ger Vorhersagbarkeit (Drazin, 1992). Mit anderen Worten, eine wesentliche Eigenschaft dieser Systeme ist, daß sie aufgrund ihres Determinismus über kurze Zeit gut vorhersagbar sind, diese Vorhersagbarkeit jedoch mit anwachsender Zeitspanne exponentiell abnimmt. Das Ausmaß dieser Unvorhersagbarkeit drücken die Entropie K und die Lyapunov-Exponenten aus. Genau diese Information nutzt nun auch der *nicht-lineare Vorhersagealgorithmus* (Sugihara & May, 1990; Casdagli, 1992).

Dieser Algorithmus benutzt die erste Hälfte einer Zeitreihe als „Bibliothek“, um den zukünftigen Verlauf für alle Punkte der zweiten Zeitreihenhälfte (bei variabler Zahl von Vorhersagezeitschritten) vorherzusagen. Zunächst wird wiederum der m -dimensionale Phasenraum mittels der Zeitverzögerungskordinaten rekonstruiert. Jeder Zustandsvektor ist durch m Komponenten festgelegt. Dann wird jeder Zustandsvektor durch seine nächsten Nachbarn (NN) „eingekreist“: hierzu verwendet man einen sog. Simplex, der einem Punkt umschrieben wird. In der Phasenebene ($m = 2$) beispielsweise besteht ein Simplex aus $m + 1$ dreiecksförmig angeordneten NN. Die Evolution der NN dient nun zur Schätzung der Evolution des Indexvektors.

Die Vorhersagequalität wird schließlich als Korrelation zwischen vorhergesagten und tatsächlichen Datenpunkten quantifiziert. Wie man in Computersimulationen (Scheier & Tschacher, 1996) klar erkennt, fällt die Vorhersagequalität für chaotische Prozesse mit zunehmenden Vorhersagezeitschritten signifikant ab. Dagegen bleibt die Vorhersagbarkeit für die linearen Prozesse über alle Vorhersagespannen konstant. Für einen rein stochastischen Zufallsprozeß kann überhaupt keine Vorhersagbarkeit erreicht werden. Mit anderen Worten, der Vorhersagealgorithmus ist in der Lage, drei zentrale Prozeßklassen (stochastische, lineare und chaotische) zu differenzieren.

Es ist im übrigen deutlich, daß ein enger Zusammenhang zwischen der Abnahme der Vorhersagegüte und der Entropie wie auch den charakteristischen Exponenten besteht. Alle diese Methoden quantifizieren die Dissipativität eines Systems, also das Ausmaß, in welchem es Komplexität erzeugt. Auf die Verbindungen zur Dimensionsanalyse wurde bereits hingewiesen: man kann die Einbettungsdimension dadurch schätzen, indem man das Maximum der Vorhersagekorrelation sucht (entsprechend dem Verfahren der false nearest neighbors).

Surrogatdatenmethode: Theiler et al. (1992) haben eine Surrogatdatenmethode vorgestellt, die eine statistische Absicherung dieser Resultate ermöglicht. Dieser statistische Bootstrap-Ansatz scheint sehr geeignet, die Reliabilität von Ergebnissen einzustufen, wenn nur einzelne Zeitreihen vorliegen. Letzteres ist in dynamischen Untersuchungen nicht nur in der Psychologie die Regel.

Es wird jeweils eine Nullhypothese der Art „Die Zeitreihe ist vom Typ X“ aufgestellt, wobei X einen Zeitreihentypus quantifiziert, von dem man zeigen möchte, daß die empirische Zeitreihe ihm nicht zugehört (z.B. X ist ein Zufallsprozeß, oder: X ist ein autoregressiver Prozeß). Als Prüfstatistik, die einen relevanten dynamischen Aspekt der Daten beschreibt, kann man im Prinzip jede quantitative Invariante wählen (also etwa die Korrelationsdimension, den größten Lyapunov-Exponenten oder die Vorhersagegüte).

Der nächste Schritt besteht dann darin, Surrogatdatensätze zu erstellen, die

bezüglich Länge, Mittelwert und Varianz mit der Originalzeitreihe identisch sind, ansonsten jedoch z.B. verrauscht sind. Für jeden Surrogatdatensatz berechnet man die gewählte Prüfstatistik und erhält so eine Verteilung dieser Prüfgröße. In einem letzten Schritt prüft man, wo sich der für die empirische Zeitreihe berechnete Wert innerhalb dieser Verteilung befindet. Dies geschieht praktischerweise durch die Berechnung eines Effektmaßes E , das analog den in der Psychotherapieforschung oft verwendeten Effektstärken definiert ist. Wenn die Prüfgrößen für die Surrogatdaten normalverteilt sind, läßt sich der p -Wert (Wahrscheinlichkeit eines Wertes in der Verteilung) für das Effektmaß der getesteten Originalzeitreihe aus den Tabellen für die Standardnormalverteilung entnehmen.

Noise-versus-Chaos (NVC): NVC ist eine weitere Methode, die Forecasting und Bootstrap-Tests miteinander verbindet. Der NVC-Algorithmus prüft, ob eine einzelne univariate Zeitreihe eine serielle Struktur besitzt, die von der eines linear-stochastischen Prozesses statistisch unterschieden werden kann. Die zu testende Nullhypothese besagt also: Die Indexzeitreihe ist ein linear korrelierter Prozeß (ARMA-Prozeß), der ein Powerspektrum besitzt, das Nichtlinearität oder Chaos vortäuscht. Diese Problematik entstand im Zusammenhang mit der Tatsache, daß weißes Rauschen und besonders „farbiges Rauschen“ (das durch autokorreliertes Rauschen entsteht) finite Dimensionalitäten fingiert (Osborne & Provenzale, 1989; Theiler, 1991).

Der NVC-Algorithmus geht zunächst wieder davon aus, daß eine univariate Zeitreihe nach der bereits beschriebenen Methode der Zeitverzögerungskordinaten von Takens m -dimensional eingebettet wird. Als Prüfstatistik wird wie bei der oben dargestellten Forecasting-Methode von Sugihara und May (1990) die Vorhersagbarkeit verwendet. Dies ist eine Eigenschaft von zentraler Bedeutung für sich in der Zeit erstreckende Prozesse, die den Determinismus, der in einem Prozeß „enthalten“ ist, anspricht. Zur Schätzung der Vorhersagbarkeit wird für jeden Referenzpunkt \bar{x} des eingebetteten Systems der geometrisch nächstgelegene Nachbar gesucht. Die zeitliche Evolution dieses Nachbars wird mit der Evolution des Referenzpunktes verglichen, indem zwischen beiden die euklidische Differenz gebildet wird. Um künstlich hohe Vorhersagegüten zu vermeiden, werden solche nächsten Nachbarn ausgespart, die in zeitlicher Nachbarschaft des Referenzpunktes liegen. Eine Zeitreihe aus N skalaren Werten liefert $N - (m-1)\tau - T$ solcher Differenzen, wobei τ die für die Einbettung benutzte Zeitverzögerung und T die Anzahl der Zeitschritte in der Zukunft ist, für die die Vorhersage getroffen wird. Man erhält eine Verteilung von Differenzen, die den Vorhersagefehler quantifiziert, der der Zeitreihe inhärent ist (Kennel & Isabelle, 1993).

Dasselbe Verfahren wird nun für Surrogatzeitreihen durchgeführt, die dasselbe Powerspektrum haben wie die Indexzeitreihe, d.h. deren Autokorrelation identisch zu der der Indexzeitreihe ist (phasenrandomisierte Surrogate nach Theiler et al., 1992). Diese Surrogate simulieren damit eine Vorhersagbarkeit, die nur auf der Korrelation zwischen aufeinander folgenden Zuständen des sonst stochastischen Systems basiert. Die Surrogate sind also ARMA-Modelle der Indexzeitreihe.

Schließlich werden die Vorhersagefehler von Indexzeitreihe und Surrogaten darauf geprüft, ob sie derselben Population entstammen. Kennel und Isabelle (1993) schlagen

hierfür eine Mann-Whitney Rangsummenstatistik vor, die negative Werte von $z < -2.33$ dann ergibt, wenn die Vorhersagbarkeit der Indexzeitreihe 1%-signifikant besser ist als die der Surrogate. In unserer Implementation (Tschacher et al., submitted) werden diese z-Werte berechnet.

Eine Reihe von 14 über lange Zeit täglich beobachteter Schizophrenieverläufe wurde mit den beiden beschriebenen Forecastingmethoden klassifiziert, indem jeder der Verläufe mit dem Bootstrapverfahren nach Theiler et al. (1992) und dem NVC getestet wurde. Zusammenfassend wurden dadurch folgende drei Nullhypothesen geprüft:

- 1.) Die Zeitreihe ist eine rein stochastische Zeitreihe ohne deterministische Struktur.
- 2.) Die Zeitreihe ist ein linearer autoregressiver Prozeß.
- 3.) NVC: Die Zeitreihe ist ein linear-stochastischer Prozeß mit einem Powerspektrum, das nichtlinearen Determinismus (Chaos) vortäuscht.

Die Ergebnisse der Tests an den 14 Psychoseverläufen sind in Tabelle 1 zusammengefaßt. Sie lassen es plausibel erscheinen, daß ein beträchtlicher Anteil von Schizophrenien einen wohl teilweise stochastischen, insbesondere aber auch nichtlinear-deterministischen Charakter aufweist (Tschacher et al., 1996). Diese Ergebnisse sind kompatibel mit Auffassungen von der Chaotizität der Schizophreniedynamik (Ciompi et al., 1992).

Patient	Vorhersagbarkeit	Zufallstest	Linearitätstest	NVC	Modell
53	0.757	4.59**	3.42**	-5.12**	nonlinear
56	0.578	9.26**	6.66**	-8.32**	nonlinear
47	0.698	15.27**	2.18*	-12.55**	nonlinear
58	0.358	2.72**	8.16**	-7.12**	nonlinear
51	0.92	11.28**	1.9	-2.9**	nonlinear
19	0.671	5.13**	2.33*	-3.45**	nonlinear
34	0.479	11.64**	2.28*	-1.88	nonlinear
48	0.472	4.70**	2.18*	-3.16**	nonlinear
54	0.696	17.13**	1.23	0.47	AR
13	0.661	10.84**	1.72	0.66	AR
24	0.852	11.97**	0.87	1.09	AR
62	0.79	12.22**	0.98	-0.23	AR
57	0.174	0.8	(5.26**)	0.77	Zufall
41	0.477	1.66	(4.91**)	2.33*	Zufall

Tab. 1: Ergebnisse der Surrogatdatenmethode bei 14 Schizophrenieverläufen.

In den bisherigen Ausführungen zur induktiven Modellierung wurden Begriffe und Konzepte der Theorie dynamischer Systeme eingeführt, wobei wir davon ausgingen, daß vom System jeweils lediglich Realisationen in der Zeit bekannt sind. Man kann

diese induktive Form der Modellierung als „behavioristisch“ bezeichnen: das System wurde als black box behandelt, über die nichts als ihr Verhalten bekannt ist. Allein der Output des Systems, sein Verhalten in der Zeit, sowie gegebenenfalls seine Input-Output-Relationen wurden herangezogen, um Binnenstrukturen der black box zu erhellen.

Häufig aber scheint ein rein induktives Vorgehen anhand der Messung an einem oder wenigen empirischen Systemen unnötig asketisch. Oft ist ja das Fachwissen zum Gegenstand weit umfangreicher, ja unüberschaubar. Ist es also nicht der angemessenere Weg, aus bereits bekanntem und repliziertem Zusammenhangswissen eine Theorie oder ein Simulationssystem zusammenzustellen und deren dynamische Folgerungen zu studieren? Dies soll unter dem Begriff „deduktiver Modellierung“ diskutiert werden.

3 Deduktive Modellierung und Simulationsverfahren

In diesem Abschnitt wollen wir eine knappe Übersicht zu verschiedenen Simulationsansätzen geben, die im Bereich der Psychologie verwendet wurden. Es wird deutlich, daß heute eine überaus breite Palette von computergestützten Verfahren für Simulationen zur Verfügung steht und in der Psychologie auch eingesetzt wird. Es besteht eine Spannbreite zwischen vom Anwender selbst programmierten Simulationssystemen und Software, die die Eingabe von Gleichungen erlaubt, bis hin zu Programmen, die es ermöglichen, Simulationssysteme schrittweise grafisch am Bildschirm zu entwickeln. Schließlich müssen wir auf Simulationen als der zentralen Methode im Feld der Künstlichen Intelligenz-Forschung zu sprechen kommen, die für die Fragestellungen auch der synergetischen Psychologie von wachsender Bedeutung sind.

Simulation durch Gleichungssysteme: In verschiedenen Arbeiten wurde versucht, psychologische Systeme durch Differential- und Differenzgleichungssysteme zu modellieren. Kriz (1990) entwickelte ein siebendimensionales Gleichungssystem zur Modellierung familiendynamischer Prozesse auf der Basis der Populationsdynamik (Verhulst-Gleichungen). Eine ähnliche Methode verwandten Schiepek und Schoppek (1991) im Rahmen einer Simulation schizophrener Verläufe als dynamischer Krankheit. Fünf Konstrukte (Kognitive Störungen, Stress, Rückzug, Expressed Emotions und Wahn) wurden auf der Grundlage nichtlinearer Differenzgleichungen abgebildet. Es läßt sich in beiden Simulationsansätzen zeigen, daß die entwickelten Modelle je nach Parametereinstellung in der Lage sind, in der Realität vorfindliche Verlaufsmuster zu erzeugen (entsprechend unter Verwendung der graphischen Simulationssoftware STELLA: Kupper & Hoffmann, 1995). Saam (1996) implementierte in der für Mikro-Makro-Modelle entwickelten Simulationssprache MIMOSE ein Modell des politischen Systems Thailands und seiner wechselnden Regierungssysteme.

Simulation mit logischen und propositionalen Systemen: Die Wechselwirkungen zwischen psychologischen Variablen können auch in mehr qualitativer, symbolischer Weise dargestellt werden, nämlich durch Propositionen (Wenn-Dann-Aussagen). Die-

sen Weg beschritten Schiepek und Schaub (1990), die im Rahmen einer Einzelfallstudie die persönliche Biografie eines Klienten mit einer depressiven Symptomatik simulierten (vgl. Schiepek, 1991). Kupper und Hoffmann (1996) und Lemay et al. (1996) benutzen Boole'sche Gleichungen zur Darstellung von Dynamik im Bereich der psychiatrischen Rehabilitationsforschung und dem Studium der Lebensqualität. Boole-Modelle (auch Karnaugh maps) gehen zumeist von lediglich binären Aussagen über Variablen aus (also dem Nominalskalenniveau: vorhanden/nicht vorhanden), was die Modellierung auch schwer zugänglicher Gegenstandsbereiche ermöglicht. Die durch die „klassische“ Künstliche Intelligenz-Forschung präferierten propositionalen Systeme und semantischen Netzwerke fallen ebenfalls in diese Kategorie. Sie spielen eine große Rolle bei der Modellierung deklarativen Wissens.

Konnektionistische Simulationen: Konnektionistische Systeme bzw. neuronale Netzwerke haben einen besonders engen Bezug zur synergetischen Psychologie, da sie eine Alternative zum Ansatz der symbolischen Informationsverarbeitung versprechen. Neuronale Netze können kognitive Eigenschaften wie Mustererkennung (als Umkehrung des synergetischen Vorgangs der Musterbildung) realisieren (Rumelhart & McClelland, 1986; Haken, 1987; 1996). Netzwerke weisen bei nichtsupervidiertem Lernen die Fähigkeit zur Selbstorganisation auf, was sie für psychologische Modellierungen sowie für Anwendungen im Bereich autonomer Agenten (Pfeifer & Scheier, im Druck) prädestiniert (Schaub, in diesem Band; Vanger et al., in diesem Band). Die konnektionistische Simulation im Bereich der Klinischen Psychologie wird in Znoj (1992) und in Caspar et al. (1992) diskutiert. In ihrem Verhalten sind neuronale Netzwerke den zellulären Automaten ähnlich: eine Simulation der Regulierung sozialer Nähe und Distanz durch eine Abart eines zellulären Automaten ist in Brunner und Tschacher (1991) beschrieben.

Systemspiele: Neben dem Einsatz von Computerszenarien als Versuchssituation in der kognitiven Psychologie (Schaub, 1993) nehmen die in der Art eines komplexen Rollenspiels inszenierten Plan- bzw. Systemspiele eine besondere Stellung ein. Die sich selbstorganisierende Beziehungsdynamik eines Sozialsystems läßt sich im Rahmen von Systemspielen anregen (experimentell variieren) und untersuchen (Schiepek & Reicherts, 1992; Schiepek et al., 1995). Die Psychologie komplexer Sozialsysteme erhält damit ein realitätsnahes Forschungs- und Ausbildungsparadigma (vgl. das Konzept der Systemkompetenz, Manteufel & Schiepek, 1993).

Künstliche Intelligenz-Forschung und Robotik: Die Psychologie ist Grundlagenwissenschaft in einem sehr simulationsorientierten interdisziplinären Feld, der Forschung zur Künstlichen Intelligenz und der Cognitive Science. Interessanterweise hat sich hier eine Entwicklung ergeben, die einen Weg zu brauchbaren Simulationsmethoden zeigen kann. Der ursprüngliche Versuch, psychologische kognitive Theorien direkt in Computermodelle umzusetzen (z.B. die ACT-Modellierung nach Anderson, 1983), hat sich nicht durchgängig bewährt; man schuf im wesentlichen ausgefeilte Deskriptionen von kognitiven Vorgängen, die sich angesichts neuer Kontexte und Problemstellungen völ-

lig „unintelligent“ verhielten. Die logische Entwicklung in der Cognitive Science war daher zunächst die Wiederentdeckung des Konnektionismus, der von einfachen, lernfähigen neuronalen Netzwerken ausgeht, um kognitive Teilprozesse auf der Basis subsymbolischer Komponenten realistischer zu modellieren. In neuerer Zeit zeichnet sich eine weitere Wandlung der künstlichen Intelligenz-Forschung ab („new AI“): in der Robotik (Pfeifer & Scheier, im Druck) werden einfache Maschinen (autonomous agents, „kybernetische Vehikel“, Braitenberg, 1986) mit rudimentärem Sensorium und Motorik eingesetzt, um in einer realen Umwelt autonom Aufgaben zu erledigen, sowie implizites Weltwissen im Sinne der Situated Cognition zu erwerben (Scheier & Lambrinos, 1996). Ähnliche Zielsetzungen verfolgt auch die Forschung zu Artificial Life. Eine Verbindung der synergetischen Psychologie und der „new AI“ ist in Tschacher & Scheier (im Druck) skizziert.

Man kann die Entwicklung der Cognitive Science also gewissermaßen als eine Bewegung weg von der deduktiven Modellierung aufgrund theoretischer Annahmen und aufgrund von vorgegebenen symbolischen Algorithmen verstehen. Die Vorgabe fester kognitiver Struktur- und Regelhierarchien erwies sich für die Begründung einer „Maschinenintelligenz“ als nicht adaptiv genug. Im Kontext und im Hinblick auf die Zielsetzungen von Künstlicher Intelligenz und Robotik erfolgte eine Eingrenzung des Modellierungszieles bei zunehmender Bedeutung realer empirischer Kontexte, an denen die Modellierung in Form eines nicht a-priori vorgegebenen Lernens stattfindet. Ein Trend geht in die Richtung, Intelligenz sich in Auseinandersetzung mit einer realen Umwelt selbstorganisatorisch entwickeln zu lassen. Vorgegeben sind nicht Inhalte und Strukturen, sondern nur Randbedingungen. Eine „Methode“ der Wahl in der neuen Cognitive Science heißt also Selbstorganisation.

4 Diskussion

Methodenkritik und Methodenindikation: An verschiedenen Stellen unserer Darstellung von Möglichkeiten induktiver Modellierung wurde deutlich, daß Probleme entstehen können, sobald man die genannten ergodischen und invarianten Maße in empirischen Daten evaluieren will. Viele Voraussetzungen, unter denen Konzepte und Koeffizienten definiert sind, sind angesichts im Feld oder Experiment erhobener psychologischer Daten nur teilweise oder näherungsweise erfüllt (vgl. Kowalik & Schiepek, in diesem Band). Es ist deshalb in jeder empirischen Anwendung ein methodenkritisches Vorgehen erforderlich.

Insbesondere Verfahren zur Charakterisierung chaotischer Dynamik waren bislang mit Datenanforderungen verbunden, die in psychologischen Datensätzen selten verwirklicht werden konnten. In einem Aufsatz (Steitz et al., 1992) untersuchten wir die Anwendbarkeit der am häufigsten in der Literatur anzutreffenden Technik der Dimensionsanalyse (nach Grassberger & Procaccia, 1983). Die Länge der erhobenen Zeitreihe, die Auflösung der Meßwerte und der Meßfehler, sowie das Ausmaß der Zufallsfluktuationen des Systems erweisen sich dabei als stark limitierende Faktoren. Die-

sen Einwänden können neuere methodische Ansätze in der Zeitreihenanalyse gerecht werden, die statistische Verfahren in die Analyse nichtlinearer Dynamik integrieren (s.o. Surrogatdatenmethode und Noise-versus-Chaos) und den nichtstationären Charakter psychologischer Zeitreihen berücksichtigen (Kowalik & Schiepek, in diesem Band).

Integration der beiden Modellierungs-, „Richtungen“: Abarbanel et al. (1993) stellen in ihrem Review-Artikel fest, daß die Aufgaben, die die Analyse beobachteter und deduzierter Signale von Systemen zu bewältigen hat, ziemlich die gleichen sind, die Methoden für die Analyse dagegen substantiell voneinander abweichen. Kann man also beide Modellierungsrichtungen integrieren?

Es wäre eine Idealform dynamischer Forschung, sich einem Problem von beiden Seiten - deduktiv und induktiv - anzunähern: Zeitreihenanalysen gäben die Zwangsbedingungen vor, innerhalb derer ein tentatives Modell formuliert werden könnte. Die Eigenschaften des Modells könnten wiederum rekursiv Hypothesen für weitere empirische Beobachtungen liefern, die rückwirkend das Modell weiter verfeinern helfen, etc. (Schaub & Schiepek, 1992). Als Grenzwert einer solchen Einkreisung eines Sachverhalts entstünde eine hypothetiko-deduktive Modellierung eines dynamischen Systems, schließlich eine Theorie über einen Prozeß. Die Probleme der Induktion (fragliche Verallgemeinerbarkeit) und der Deduktion (fragliche Realitätsnähe) könnten sich gewissermaßen wechselseitig im Rahmen halten und so die beste (nützlichste, viabelste) Theorie iterativ lokalisieren helfen.

Dieser Idealfall der Theoriebildung durch dynamische Forschung ist aber mit einer Reihe von Problemen konfrontiert. Verschiedene Gründe sprechen dafür, daß sich die „Grenzwerte“ induktiver und deduktiver Modellierung nicht immer so annähern, daß sie in einem *beidseitig* gesicherten Modell resultieren:

- Die Grenzen der starken Kausalität: Wie oben ausgeführt, sind komplexe Systeme häufig Informationsquellen (sie haben positive Lyapunov-Exponenten). Dies führt dazu, daß auch im unwahrscheinlichen Fall eines strikten Determinismus' ein Prozeß nach individuell variabler Zeit zu unvorhersagbaren Resultaten führen muß.
- Nicht-Stationarität: Psychologische und soziale Prozesse sind in der Regel nichtstationär und nichtwiederholbar. Es kann nicht sichergestellt werden, daß ein komplexes soziales oder kognitiv-emotionales System sich auch nur zweimal im gleichen dynamischen Zustand befindet.
- Was bei linearen Modellen nach Kriterien und Tests (Methode kleinster Quadrate, Likelihood) festgelegt werden kann, ist bei nichtlinearen Modellen uferlos: die Zahl infragekommender Modellformen. Es gibt keine Methode, welche die exakte Form (die Gleichungen) eines nichtlinearen Zusammenhangs aus einer noch so idealen zeitlichen Realisation des Systems heraus bestimmen könnte. Hier bleibt das Experiment unverzichtbar.
- Es ist schwierig, eine Intuition für komplizierte Differentialgleichungen oder Differenzgleichungen zu entwickeln. Dies gilt gerade auch für Systeme aus gekoppelten Gleichungen. Das Verhalten des Systems bei nichtlinearer Kopplung ist gewissermaßen übersummativ.

- Frühe Simulationen im Bereich der Psychologie und Psychiatrie verwendeten oft Gleichungen als Schablone, von denen von vornherein bekannt war, welches Verhalten sie produzieren (z.B. das Lorenz-System (Troitzsch, 1990); die logistische Map (Simon, 1989; Höger, 1991); gekoppelte van der Pol-Systeme (Warner, 1992)). Es besteht daher eine gewisse Gefahr, die simulierten Ostereier zu entdecken, die man selbst versteckt hat.
- Ein weiteres Problem besteht in der reinen Anzahl von Konstanten, Parametern und Variablen des Simulationssystems. Ist diese nur hinreichend groß, so läßt sich *jedes* Verhalten eines zu modellierenden Sachverhalts repräsentieren. Ob daraus noch Erkenntnisse über den Sachverhalt zwingend resultieren, erscheint unsicher.

Welche Konsequenzen haben diese Punkte für die Modellierung? Zunächst sollte man sich vergegenwärtigen, daß die Suche nach dem jeweils einen „richtigen“ Modell wahrscheinlich ohnehin zum Scheitern verurteilt ist. Auch elaborierte Methoden kommen an einer „Mehr-Mehrdeutigkeit“ zwischen Phänomenen bzw. Empirie und Modellen bzw. Theorien nicht vorbei. Modellierungen machen für ein vertieftes Verständnis dynamischer Phänomenbereiche dennoch Sinn, wenn man ihren erkenntnistheoretischen Stellenwert, ihre Möglichkeiten und Grenzen realistisch einschätzt (s. Schiepek & Strunk, 1994).

Zum anderen sollten (nichtlineare) Simulationsmodelle natürlich systematisch getestet werden (z.B. durch Parameter- und Inputvariation), um ihren Mehrwert, ihre emergenten Möglichkeiten über die hineingesteckten Annahmen hinaus zu prüfen. Hier setzt eine Kombination aus Simulations- und Realexperimenten an.

Wir würden weiter dafür plädieren, methodologisch sorgfältig vorzugehen: Der Versuchung, die Strenge des wenn auch linearen, so doch hypothesentestenden experimentellen Vorgehens mit der Beliebigkeit einer irgendwie nichtlinearen Methodik einzutauscht, sollte widerstanden werden. Es ist nicht so, daß „nichtlinear“ gut ist, und „linear“ schlecht. Vielmehr weisen nach unserer Erfahrung hybride Untersuchungsdesigns (etwa eine Stichprobe aus Einzelfalldynamiken, deren Invarianten im Querschnitt statistisch getestet werden) weiter, indem sie die „methodologischen Welten“ sinnvoll miteinander verbinden.

Das oben gegebene Beispiel der Entwicklung in der Kognitionswissenschaft ist sicher ebenfalls lehrreich; insgesamt liefert es nach unserer Einschätzung Argumente für eine evolutionäre Erkenntnistheorie, in der Selbstorganisation eine zentrale Rolle spielt. Im Kontext der in diesem Beitrag behandelten Frage der Modellierung von psychologischen Sachverhalten weist das Beispiel darauf hin, daß zunächst eine induktive Erkundung von empirischer Dynamik erfolgen muß. Aufbauend auf den so gewonnenen Erfahrungen können die vielfältigen heute zur Verfügung stehenden Methoden zur Simulation psychologischer Systeme fruchtbar werden.

Literatur

- Abarbanel, H. D. I., Brown, R., Sidorowich, J. J. & Tsimring, L.S. (1993). The Analysis of Observed Chaotic Data in Physical Systems. *Reviews of Modern Physics*, 65, 1331-1392.
- Abraham, F. D. & Gilgen, A. R. (Eds.) (1995). *Chaos Theory in Psychology*. Westport: Praeger.
- Abraham, R. H. & Shaw, C. D. (1984). *Chaotic Behavior*. Santa Cruz: Aerial Press.
- Aebi, E., Ackermann, K. & Revenstorff, D. (1993). Ein Konzept der sozialen Unterstützung für akut Schizophrene. *Zeitschrift für Klinische Psychologie, Psychopathologie und Psychotherapie*, 41, 18-30.
- Anderson, J. R. (1983). *The Architecture of Cognition*. Cambridge: Harvard University Press.
- Atmanspacher, H. & Dalenoort, G. J. (Eds.) (1994). *Inside Versus Outside*. Berlin: Springer.
- Box, G. E. P. & Jenkins, G. (1976). *Time Series Analysis: Forecasting and Control*. San Francisco: Holden-Day.
- Braitenberg, V. (1986). *Künstliche Wesen: Verhalten kybernetischer Vehikel*. Braunschweig: Vieweg.
- Brunner, E. J. (1986). *Grundfragen der Familientherapie*. Berlin: Springer.
- Brunner, E. J. & Tschacher, W. (1991). Distanzregulierung und Gruppenstruktur beim Prozeß der Gruppenentwicklung. *Zeitschrift für Sozialpsychologie*, 22, 87-101.
- Bunge, M. (1979). *Treatise on Basic Philosophy. Vol. 4, Ontology II: A World of Systems*. Dordrecht: Reidel.
- Casdagli, M. (1992). Chaos and Deterministic Versus Nonlinear Modelling. *Journal of the Royal Statistical Society*, 2, 2-29.
- Caspar, F., Rothenfluh, T. & Segal, Z. (1992). The Appeal of Connectionism for Clinical Psychology. *Clinical Psychology Review*, 12, 719-762.
- Ciampi, L., Ambühl, B. & Dünki, R. (1992). Schizophrenie und Chaostheorie. *System Familie*, 5, 133-147.
- Drazin, K. (1992). *Nonlinear Systems*. Berlin: Springer.
- Eckmann, J.-P. & Ruelle, D. (1985). Ergodic Theory of Chaos and Strange Attractors. *Reviews of Modern Physics*, 57, 617-656.
- Farmer, J. D., Ott, E. & Yorke, J. A. (1983). The Dimension of Chaotic Attractors. *Physica D*, 7, 153-180.
- Gottman, J. M., McFall, R. M. & Barnett, J. T. (1969). Design and Analysis of Research Using Time Series. *Psychological Bulletin*, 72, 299-306.
- Grassberger, P. & Procaccia, I. (1983). Measuring the Strangeness of Strange Attractors. *Physica D*, 9, 189-208.
- Haken, H. (1990). *Synergetik. Eine Einführung*. Berlin: Springer.
- Haken, H. (Ed.) (1987). *Computational Systems - Natural and Artificial*. Berlin: Springer.
- Haken, H. (1996). *Principles of Brain Functioning: A Synergetic Approach to Brain Activity, Behavior, and Cognition*. Berlin: Springer.
- Haken, H. & Stadler, M. (Eds.) (1990). *Synergetics of Cognition*. Berlin: Springer.
- Haken, H. & Wunderlin, A. (1991). *Die Selbststrukturierung der Materie*. Braunschweig: Vieweg.
- Hall, A. D. & Fagen, R. E. (1968). Definition of System. In W. Buckley (Ed.), *Modern Systems Research for the Behavioral Scientist* (pp. 81-92). Chicago: Aldine.
- Heckhausen, H. & Kuhl, J. (1985). From Wishes to Action: The Dead Ends and Short Cuts on the Long Way to Action. In M. Frese & J. Sabini (Eds.), *Goal Directed Behavior: The Concept of Action in Psychology* (pp. 134-160). Hillsdale: Erlbaum.
- Hirsch, M. W. & Smale, S. (1974). *Differential Equations, Dynamical Systems, and Linear Algebra*. New York: Academic Press.
- Höger, R. (1991). Chaos-Forschung und ihre Bedeutung für die Psychologie. *Psychologische Rundschau*, 43, 223-231.

- Jantsch, E. (1979). *Die Selbstorganisation des Universums*. München: Hanser.
- Kaplan, D. & Glass, L. (1995). *Understanding Nonlinear Dynamics*. New York: Springer.
- Kennel, M. B., Brown, R. & Abarbanel, H. D. I. (1992). Determining Embedding Dimension for Phase-Space Reconstruction Using a Geometrical Construction. *Physical Review A*, 45, 3403-3411.
- Kennel, M. B. & Isabelle, S. (1992). Method to Distinguish Chaos from Colored Noise and to Determine Embedding Parameters. *Physical Review A*, 46, 3111-3118.
- Köhler, W. (1920). *Die physischen Gestalten in Ruhe und in stationärem Zustand*. Braunschweig: Vieweg.
- Kowalik, Z. J., Schiepek, G., Kumpf, K., Roberts, L. E. & Elbert, T. (in press). Psychotherapy as a Chaotic Process II: The Application of Nonlinear Analysis Methods on Quasi Time Series of the Client-Therapist Interaction. A Nonstationary Approach. *Psychotherapy Research*, 7(3).
- Kriz, J. (1990). Synergetics in Clinical Psychology. In H. Haken & M. Stadler (Eds.), *Synergetics of Cognition* (pp. 393-404). Berlin: Springer.
- Kriz, J. (1992). *Chaos und Struktur*. München: Quintessenz.
- Kupper, Z. & Hoffmann, H. (1995). The 3 Months' Crisis: Empirical Investigation and Simulation of the Rehabilitation Dynamics in Chronic Mental Disorders. *Swiss Journal of Psychology*, 54, 211-224.
- Kupper, Z. & Hoffmann, H. (1996). Logical Attractors: A Boolean Approach to the Dynamics of Psychosis. In W. Sulis & A. Combs (Eds.), *Nonlinear Dynamics in Human Behavior* (pp. 211-224). Singapore: World Scientific.
- Langthaler, W. & Schiepek, G. (Hrsg.) (1995). *Selbstorganisation und Dynamik in Gruppen*. Münster: LIT-Verlag.
- Lemay, P., Vuadens, P. & Dauwalder, J.-P. (1996). Quality of Life - A Dynamic Perspective. In W. Sulis & A. Combs (Eds.), *Nonlinear Dynamics in Human Behavior*. Singapore: World Scientific.
- Lewin, K. (1936). *Principles of Topological Psychology*. New York: McGraw-Hill. (deutsche Ausgabe: Grundzüge der topologischen Psychologie. Bern: Huber, 1969).
- Lorenz, E. N. (1963). Deterministic Non-Periodic Flow. *Journal of Atmosphere Sciences*, 20, 130-141.
- Manteufel, A. & Schiepek, G. (1993). Systemspiele und Systemkompetenz. *Systema*, 7, 19-27.
- Mayer-Kress, G. (Ed.) (1986). *Dimensions and Entropies in Chaotic Systems*. Berlin: Springer.
- Mayer-Kress, G. & Layne, S. P. (1987). Dimensionality of the Human Electroencephalogram. *Annals of the NY Academy of Sciences*, 504, 62-87.
- Nicolis, G. & Prigogine, I. (1987). *Die Erforschung des Komplexen*. München: Piper.
- Osborne, A. R. & Provenzale, A. (1989). Finite Correlation Dimension for Stochastic Systems with Power Law Spectra. *Physica D*, 35, 357-379.
- Osgood, C. E., Suci, G. J. & Tannenbaum, P. H. (1957). *The Measurement of Meaning*. Urbana: University of Illinois Press.
- Peitgen, H.-O. & Richter, P. H. (1986). *The Beauty of Fractals*. Berlin: Springer.
- Petermann, F. (Hrsg.) (1989). *Einzelfallanalyse*. München: Urban & Schwarzenberg.
- Pfeifer, R. & Scheier, C. (in press). *Introduction to „New Artificial Intelligence“*. Cambridge: MIT Press.
- Poincaré, H. (1899). *Les methodes nouvelles de la mécanique celeste*. Paris: Gauthier-Villars.
- Reiter, L., Brunner, E. J. & Reiter-Theil, S. (Hrsg.) (im Druck). *Von der Familientherapie zur systemischen Perspektive* (2. Auflage). Berlin: Springer.
- Rosen, R. (1970). *Dynamical System Theory in Biology*. New York: Wiley.
- Rössler, O. (1992). *Endophysik. Die Welt des inneren Beobachters*. Berlin: Merve.
- Rössler, O. (1976). An Equation for Continuous Chaos. *Physics Letters*, 57A, 397-398.
- Roux, J.-C., Simoyi, R. H. & Swinney, H. L. (1983). Observation of a Strange Attractor. *Physica D*, 8, 257-266.

- Ruelle, D. (1990). Deterministic Chaos: The Science and the Fiction. *Proceedings of the Royal Society London*, 427A, 241-248.
- Rumelhart, D. E. & McClelland, J. L. (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. Cambridge: MIT Press.
- Saam, N. (1996). Multilevel Modelling with MIMOSE: Experience from a Social Science Application. In J. Doran, G. N. Gilbert, U. Mueller & K. G. Troitzsch (Eds.), *Social Science Microsimulation*. Berlin: Springer.
- Schaub, H. (1993). Computersimulation als Forschungsinstrument in der Psychologie. In F. Tretter & F. Goldhorn (Hrsg.), *Computer in der Psychiatrie. Diagnostik, Therapie, Rehabilitation* (S. 393-423). Heidelberg: Asanger.
- Schaub, H. & Schiepek, G. (1992). Simulation of Psychological Processes: Basic Issues and an Illustration Within the Etiology of a Depressive Disorder. In W. Tschacher, G. Schiepek & E. J. Brunner (Eds.), *Self-Organization and Clinical Psychology* (pp. 121-149). Berlin: Springer.
- Scheier, C. & Lambrinos, D. (1996). Categorization in a Real-world Agent Using Haptic Exploration and Active Perception. In P. Maes, M. Mataric, J.-A. Meyer, J. Pollack & S. Wilson (Eds.), *From Animals to Animats*. Cambridge: MIT Press.
- Scheier, C. & Tschacher, W. (1996). Appropriate Algorithms for Nonlinear Time Series Analysis in Psychology. In W. Sulis & A. Combs (Eds.), *Nonlinear Dynamics in Human Behavior* (pp. 27-43). Singapore: World Scientific.
- Scheier, C. & Tschacher, W. (1994). Gestaltmerkmale in psychologischen Zeitreihen. *Gestalt Theory*, 16, 151-171.
- Schiepek, G. (1991). *Systemtheorie der Klinischen Psychologie*. Braunschweig: Vieweg.
- Schiepek, G. (1994). Der systemwissenschaftliche Ansatz in der Klinischen Psychologie. *Zeitschrift für Klinische Psychologie*, 23, 77-92.
- Schiepek, G. & Schaub, H. (1990). Als die Theorien laufen lernten. Anmerkungen zur Computersimulation einer Depressionsentwicklung. *System Familie*, 3, 49-60.
- Schiepek, G. & Schoppek, W. (1991). Synergetik in der Psychiatrie: Simulation schizophrener Verläufe auf der Grundlage nichtlinearer Differenzgleichungen. In U. Niedersen & L. Pohlmann (Hrsg.), *Der Mensch in Ordnung und Chaos* (Vol. 2, S. 69-102). Berlin: Duncker & Humblot.
- Schiepek, G. & Reicherts, M. (1992). The System Game as a Research Paradigm for Self-Organization Processes in Complex Social Systems. In W. Tschacher, G. Schiepek & E. J. Brunner (Eds.), *Self-Organization and Clinical Psychology* (pp. 385-415). Berlin: Springer.
- Schiepek, G. & Tschacher, W. (1992). Application of Synergetics to Clinical Psychology. In W. Tschacher, G. Schiepek & E. J. Brunner (Eds.), *Self-Organization and Clinical Psychology* (pp. 3-31). Berlin: Springer.
- Schiepek, G. & Spörkel, H. (Hrsg.) (1993). *Verhaltensmedizin als angewandte Systemwissenschaft*. Bergheim bei Salzburg: Mackinger Verlag.
- Schiepek, G. & Kowalik, Z. J. (1994). Dynamik und Chaos in der psychotherapeutischen Interaktion. *Verhaltenstherapie und psychosoziale Praxis*, 26, 503-527.
- Schiepek, G. & Strunk, G. (1994). *Dynamische Systeme. Grundlagen und Analysemethoden für Psychologen und Psychiater*. Heidelberg: Asanger.
- Schiepek, G., Manteufel, A., Strunk, G. & Reicherts, M. (1995). Kooperationsdynamik in Systemspielen. Ein empirischer Ansatz zur Analyse selbstorganisierter Ordnungsbildung in komplexen Sozialsystemen. In W. Langthaler & G. Schiepek (Hrsg.), *Selbstorganisation und Dynamik in Gruppen* (S. 123-160). Münster: LIT-Verlag.
- Schiepek, G., Kowalik, Z. J., Schütz, A., Köhler, M., Richter, K., Strunk, G., Mühlnickel, W. & Elbert, T. (in press). Psychotherapy as a Chaotic Process I: Coding the Client-Therapist Interaction by means of Sequential Plan Analysis and the Search for Chaos. A Stationary Approach. *Psychotherapy Research*, 7(2).
- Schlippe, A. v. & Schweitzer, J. (1996). *Lehrbuch der systemischen Therapie und Beratung*.

- Göttingen: Vandenhoeck & Ruprecht.
- Schmitz, B. (1989). *Einführung in die Zeitreihenanalyse*. Bern: Huber.
- Shaw, R. (1981). Strange Attractors, Chaotic Behavior, and Information Flow. *Zeitschrift für Naturforschung A*, 36, 80-112.
- Simon, F. B. (1989). Das deterministische Chaos schizophrener Denkers. *Familiendynamik*, 14, 236-258.
- Steitz, A., Tschacher, W., Ackermann, K. & Revenstorf, D. (1992). Applicability of Dimension Analysis to Data in Psychology. In W. Tschacher, G. Schiepek & E. J. Brunner (Eds.), *Self-Organization and Clinical Psychology* (pp. 367-384). Berlin: Springer.
- Stewart, H. B. (1995). *Recent Trends in Dynamical Systems Theory*. Adelphi University NY: Lecture given at the Annual Conference of the Society for Chaos Theory in Psychology and the Life Sciences.
- Sugihara, G. & May, R. (1990). Nonlinear Forecasting as a Way of Distinguishing Chaos from Measurement Error in Time Series. *Nature*, 344, 734-741.
- Sulis, W. & Combs, A. (Eds.) (1996). *Nonlinear Dynamics in Human Behavior*. Singapore: World Scientific.
- Takens, F. (1981). Detecting Strange Attractors in Turbulence. In D. A. Rand & L. S. Young (Eds.), *Lecture Notes in Mathematics* (pp. 366-381). Berlin: Springer.
- Theiler, J. (1991). Some Comments on the Correlation Dimension of 1/f Noise. *Physics Letters A*, 155, 480-493.
- Theiler, J. (1990). Statistical Precision of Dimension Estimators. *Physical Review A*, 41, 3038-3051.
- Theiler, J., Galdrakian, B., Longtin, A., Eubank, S. & Farmer, J. D. (1992). Using Surrogate Data to Detect Nonlinearity in Time Series. In M. Casdagli & S. Eubank (Eds.), *Nonlinear Modeling and Forecasting* (pp. 163-188). Reading: Addison-Wesley.
- Thompson, J. M. T. & Stewart, H. B. (1986). *Nonlinear Dynamics and Chaos*. Chichester: Wiley.
- Thompson, J. M. T. & Stewart, H. B. (1993). A Tutorial Glossary of Geometrical Dynamics. *International Journal of Bifurcation and Chaos*, 3, 223-239.
- Troitzsch, K. G. (1990). *Modellbildung und Simulation in den Sozialwissenschaften*. Wiesbaden: Westdeutscher Verlag.
- Tschacher, W. (1990). *Interaktion in selbstorganisierten Systemen*. Heidelberg: Asanger.
- Tschacher, W. (1996). The Dynamics of Psychosocial Crises. Time Courses and Causal Models. *Journal of Nervous and Mental Disease*, 184, 172-179.
- Tschacher, W. (im Druck). *Prozessgestalten. Modellierung der Zeitlichkeit psychologischer Systeme*. Göttingen: Hogrefe.
- Tschacher, W. & Grawe, K. (1996). Selbstorganisation in Therapieprozessen. Die Hypothese und empirische Prüfung der „Reduktion von Freiheitsgraden“ bei der Entstehung von Therapiesystemen. *Zeitschrift für Klinische Psychologie*, 25, 55-60.
- Tschacher, W., Scheier, C. & Aebi, E. (1996). Nichtlinearität und Chaos in Psychoseverläufen - eine Klassifikation der Dynamik auf empirischer Basis. In W. Böker & H. D. Brenner (Hrsg.), *Integrative Therapie der Schizophrenie* (S. 48-65). Göttingen: Hogrefe.
- Tschacher, W., Schiepek, G. & Brunner, E. J. (Eds.) (1992). *Self-Organization and Clinical Psychology. Empirical Approaches to Synergetics in Psychology*. Berlin: Springer.
- Tschacher, W. & Scheier, C. (in press). Toward a New Action Psychology: The Perspective of Situated and Self-Organizing Cognition. *CCAI*.
- Vallacher, R. R. & Nowak, A. (Eds.) (1994). *Dynamical Systems in Social Psychology*. San Diego: Academic Press.
- Warner, R. M. (1992). Cyclicity of Vocal Activity During Conversation: Support for a Nonlinear Systems Model of Dyadic Social Interaction. *Behavioral Science*, 37, 128-138.
- Wolf, A., Swift, J. B., Swinney, H. L. & Vastano, J. (1985). Determining Lyapunov Exponents from a Time Series. *Physica D*, 16, 285-317.