

GESTALTMERKMALE IN PSYCHOLOGISCHEN ZEITREIHEN

Christian Scheier und Wolfgang Tschacher¹

1. Einleitung

Die künftige Entwicklung der Psychologie wird entscheidend davon geprägt sein, welche Bedeutung der „Dimension Zeit“ in der psychologischen Forschung eingeräumt werden kann. Noch werden psychologische Gegenstände und Zusammenhänge in der überwiegenden Mehrzahl der Studien in einer Weise beschrieben und untersucht, als ob sie durch konstante Meßgrößen hinreichend charakterisiert seien. Querschnittsuntersuchungen und gruppenstatistische Vergleiche bieten sich dann zur Hypothesenprüfung an - sie ergeben aber prinzipiell keinen Aufschluß über die Dynamik, also die zeitlichen Verlaufscharakteristika psychologischer Zusammenhänge. Dies aber scheint uns eine zentrale Forderung an die Psychologie zu sein: Wenn sich, wie wir meinen, fast alle Gegenstände der Psychologie als dynamisch und prozeßhaft erweisen (s. u.), so muß dies auch zu entsprechenden Konsequenzen für Theorie und Methodologie führen.

Obwohl die Forderung nach der quantitativen Erforschung psychologischer Verläufe keineswegs neu ist (vgl. z. B. GLASS et al., 1975; PETERMANN, 1977) scheint sich die Einsicht, daß die Zeit im Mittelpunkt der Analyse stehen sollte, erst in jüngster Zeit in breiterem Maße durchzusetzen. Dies zeigt sich beispielsweise im Rahmen der Psychotherapieforschung, in welcher der Analyse therapeutischer Prozesse ein immer größeres Gewicht zukommt (z. B. GRAWE, 1992; RICE & GREENBERG, 1984). Dabei stellt sich allgemein die Frage nach der Konzeptualisierung, Messung und Analyse von Prozeßverläufen und -gestalten.

Zur Verlaufstypisierung und Veränderungsmessung sequentiell erhobener Daten sind unterschiedliche mathematische Modelle gebräuchlich, die allgemein als Zeitreihenmodelle bezeichnet werden (vgl. SCHMITZ, 1989). Die

¹ Die in diesem Artikel vorgestellten Methoden sind auf PC-Basis implementiert und können beim Erstautor bestellt werden. (Bitte eine formatierte DOS-Diskette und einen frankierten und adressierten Umschlag beilegen).

in der Psychologie mit Abstand am häufigsten zur Anwendung gekommenen Prozeßmodelle stammen aus der *Theorie stochastischer Prozesse* (z. B. RHENIUS, 1974). Stochastische Prozesse stellen eine Folge zeitlich ausgedehnter, d. h. durch einen Zeitparameter bestimmte, Realisationen von Zufallsprozessen dar, deren Ereignisraum aus mindestens zwei Elementarereignissen besteht, über deren Eintreten nur probabilistische Aussagen getroffen werden können (DEPPE, 1977).

Ein besonders einfaches Beispiel *abhängiger* stochastischer Prozesse stellen MARKOV-Modelle dar, die die Wahrscheinlichkeit eines Ereignisses zum Zeitpunkt t als ausschließlich abhängig von der Realisation des Ereignisses zum Zeitpunkt $t - 1$ betrachten. MARKOV-Prozesse können bestimmte „Zustände“ in einem Zustandsraum einnehmen, wobei die Übergangswahrscheinlichkeiten zwischen diesen verschiedenen Zuständen durch sogenannte Übergangsmatrizen beschrieben werden. Die naheliegende Analogie zwischen „Zuständen“ der MARKOV-Prozesse und solchen im Verlauf psychologischer Prozesse dürfte mit zur großen Beliebtheit dieser Modelle in der psychologischen Forschung beigetragen haben.

Neben den MARKOV-Modellen haben insbesondere die auf BOX & JENKINS (1970) zurückgehenden ARIMA-Modelle in der Literatur weite Verbreitung gefunden, da sie sich besonders zur Beschreibung von Prozeßabläufen eignen (GREGSON, 1983). ARIMA-Prozesse können über die Rückführung auf eine Zustandsraumdarstellung ebenfalls durch MARKOV-Eigenschaften 1. Ordnung beschrieben werden (PRIESTLEY, 1990).

Allerdings beinhalten die genannten Modelle einige u. E. gravierende Nachteile in Bezug auf die Analyse, Simulation und Interpretation psychologischer Datenverläufe. Zunächst unterliegt die Anwendbarkeit insbesondere von ARIMA-Modellen der restriktiven Bedingung, daß die Zufallsvariablen eine GAUSSsche Verteilung mit festgelegter Varianz aufweisen müssen. Diese Annahme schließt damit die Beschreibung irreversibler Verläufe aus, bei denen sich die Verteilungsfunktion der Zufallsvariablen im Laufe der Zeit ändert (MEIER, 1988). Eine weitere Schwierigkeit ist im „Linearitätsproblem“ (SCHMITZ, 1987, 186 ff.) zu sehen. Alle der bisher genannten Zeitreihenmodelle basieren auf der Grundannahme der Linearität, diese kann jedoch in Anbetracht der Komplexität psychischen Geschehens bestenfalls eine Annäherung darstellen und dürfte häufig inadäquat sein (vgl. PRIESTLEY, 1990).

Die Voraussetzungen der Linearität und Reversibilität erscheinen gerade auf der Basis neuerer theoretischer Überlegungen problematisch, die psychische und soziale Systeme im Gegenteil als dissipative, nichtlineare Systeme auffassen (BUDER, 1991; KRIZ, 1992b; MAHONEY, 1991; TSCHACHER et al., 1992; WARNER, 1992). Auch Gestaltphänomene sind in ihrem Wesen nichtlinear und irreversibel (Hystereseeffekt).

Dynamische Systeme sind Gegenstand einer Disziplin, die sich seit Poincaré zwischen Physik und Mathematik herausgebildet hat: der „Theorie dynamischer Systeme“ (z. B. KRIZ, 1992a; TSONIS, 1992). Derzeit findet in diesem interdisziplinären Forschungszusammenhang besonders das Phänomen des *deterministischen Chaos* besondere Beachtung. Chaotisches Funktionieren ist sozusagen eine dritte Dynamik zwischen den Polen des klassischen Determinismus (d. h. dem „starken“ Kausalitätsprinzip: ähnliche Ursachen führen zu ähnlichen Wirkungen) und der reinen Stochastizität.

Weiterhin verweist die offensichtliche Komplexität von Systemen, die im Bereich der Psychologie untersucht werden, auf Fragen der nichtlinearen Musterentstehung und *Selbstorganisation* (HÖGER, 1992; TSCHACHER et al., 1992). Mathematische Formulierungen für Selbstorganisationsprozesse in Vielkomponentensystemen entstanden im Rahmen der Synergetik (HAKEN, 1990) und der Theorie dissipativer Systeme (NICOLIS & PRIGOGINE, 1977). Die Literatur zeigt überzeugend, daß in Systemen unterschiedlichster Herkunft analoge Phänomene (Selbstorganisation, niedrigdimensionales Chaos und andere Gleichgewichtszustände) auftreten können.

In der Psychologie gehen die Wurzeln der Selbstorganisationstheorie auf die frühe Gestalttheorie zurück (vgl. STADLER & KRUSE, 1989). Insbesondere KÖHLER hat sich bereits 1920 mit Fragen der autonomen Ordnungsentstehung auseinandergesetzt, wobei er die nach heutiger Terminologie auf Selbstorganisationsprinzipien beruhende „freie Ordnung“ von einer durch starre Strukturen kanalisiertem „Zwangsordnung“ unterschied (KÖHLER, 1920). BISCHOF (1990) hat kürzlich darauf hingewiesen, daß dissipative Systeme als Gestalten im Sinne der Gestalttheorie konzeptualisiert werden können. Gestalten (bzw. dissipative Systeme) sind so verstanden also jede Form von freier Ordnung, die sich innerhalb gegebener Grenzen autonom entfalten kann. Dazu zählen auch „Verlaufsgestalten“, die - Melodien vergleichbar - als nichtstochastische Muster in sequentiellen Daten vorliegen.

Nimmt man nun KÖHLERs Gedanken ernst, daß psychische Phänomene wesentlich durch Ordnungsbildung und -umstrukturierung gekennzeichnet sind (vgl. z. B. auch TSCHACHER et al. und die Referenzen dort), und geht man weiter davon aus, daß Gestalten von dissipativen - also dynamischen und nichtlinearen - Systeme herrühren, so drängt sich für ihre empirische Untersuchung die Methodik der *nichtlinearen Zeitreihenanalyse* auf. Dieser neue Forschungszweig ist gerade aus der Erkenntnis heraus entstanden, daß das lineare Modell der herkömmlichen Zeitreihenanalyse für die Erforschung dissipativer Systeme (Gestalten) aufgrund der ihnen inhärenten Nichtlinearität nicht ausreicht (SCHEIER & TSCHACHER, 1994). In jüngster Zeit sind deshalb verschiedenste Techniken entstanden, mit deren Hilfe

solche Gestaltmerkmale in Zeitreihen quantifiziert werden können (vgl. WEIGEND & GERSHENFIELD, 1994 für eine Übersicht).

Dabei gilt es jedoch einschränkend zu sagen, daß viele dieser Algorithmen in der Physik entwickelt wurden und sich demnach nicht a priori für die psychologische Anwendung eignen. So haben etwa bisherige Untersuchungen, die chaotische Dynamik in psychologischen Zeitreihen über die fraktale Dimensionalität (GRASSBERGER & PROCACCIA, 1983; THEILER, 1990) zu messen suchten, keine eindeutigen oder nur vorläufige Ergebnisse bringen können (STEITZ et al., 1992; RUELLE, 1990; CIOMPI et al., 1992). Unzureichende Länge der Zeitreihen, verrauschte Messungen und begrenzte Anzahl von Skalenabstufungen sind charakteristisch für im psychologischen Bereich erhobene Daten; zugleich aber sind sie schwerwiegende Einschränkungen beim Einsatz von Algorithmen, die die Dimensionalität, LYAPUNOV-Exponenten und ähnliche ergodische Maße² abschätzen. Als ein weiteres Problem erwies sich der Mangel an Verfahren zur Hypothesensicherung; bei der Anwendung deterministischer Verfahren in der Psychologie ist man derzeit fast ausschließlich auf die Interpretation und visuelle Inspektion von Plots angewiesen. Wir wollen deshalb im folgenden an psychologischen Daten zeigen, daß der Methodenkanon der Psychologie sinnvoll ergänzt werden kann, wenn deterministische und statistische Verfahren *integriert* werden.

Zudem greifen wir in erster Linie auf Methoden zurück, die explizit vor dem Hintergrund der genannten Einschränkungen entwickelt worden sind. So ist z. B. der im folgenden Abschnitt erläuterte nichtlineare Vorhersagealgorithmus von SUGIHARA & MAY (1990) in der Biologie entstanden, die sich in der Untersuchung dynamischer Gestalten in Zeitreihen in der Regel mit ähnlichen Problemen (z. B. kurze, verrauschte Datenreihen, s. o.) konfrontiert sieht wie die Psychologie. In der vorliegenden Arbeit wird gezeigt, wie mit Hilfe einer *integrativen Prozeßanalyse*, die nichtlineare und lineare Ansätze vereinigt, in psychologischen Zeitreihen verschiedenster Provinienz über den Weg des sukzessiven Hypothesentestens Gestaltmerkmale quantifiziert werden können.


2. Methoden

² Die Dimensionalität einer Zeitreihe gibt an, viele unabhängige Variablen nötig sind, das den Daten zugrundeliegende dynamische System zu beschreiben; der LYAPUNOV-Exponent beschreibt die mittlere Divergenzrate zweier benachbarter Punkte auf einem Attraktor; weitere gebräuchliche ergodische Maße aus der Theorie dynamischer Systeme sind die KOLMOGOROV-Entropie oder die Informationsdimension (siehe TSONIS, 1992, für eine Übersicht).

Beschreibung der Datenerhebung

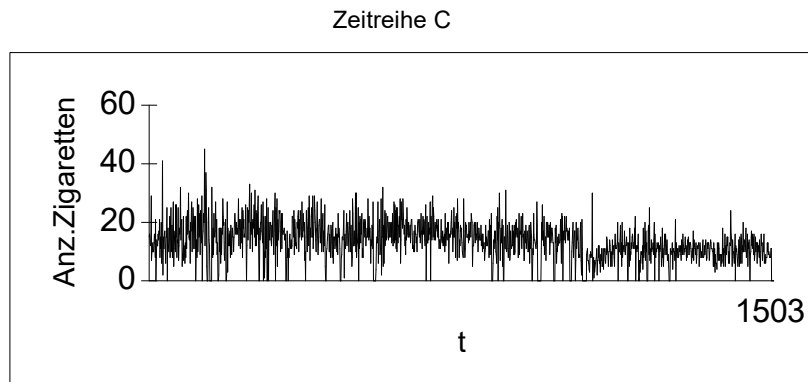
Gestimmtheitsdaten: Zeitreihen A und B (N=424) wurden durch Selbstrating der Gestimmtheit auf einer Skala von -5 (sehr schlecht gestimmt) bis 5 (sehr gut gestimmt) erhoben. Die Ratings erfolgten durch ein Paar (Mann A und Frau B) während einer vierwöchigen Ferienzeit in stündlichen Abständen während der gesamten Wachzeit.

Abbildung 1:



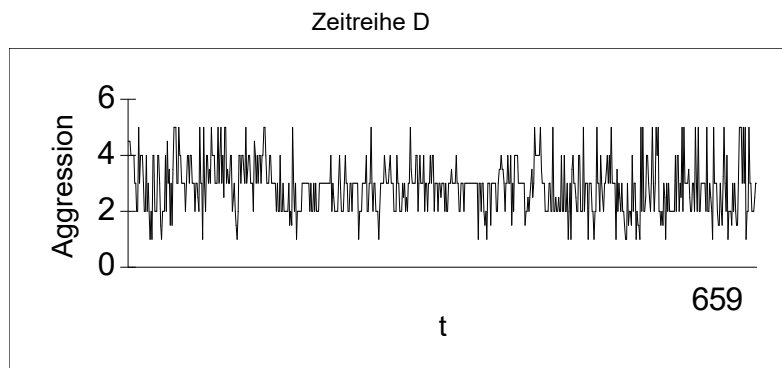
Rauchdaten: Zeitreihe C (N=1503) enthält die Anzahl der Zigaretten, die durch einen 28jährigen Mann täglich konsumiert wurden. Die Verhaltensdaten wurden vom Probanden selbst beobachtet und dokumentiert.

Abbildung 2:



Aggressionsdaten: Zeitreihe D quantifiziert die Aggression und Autoaggression einer 20jährigen Frau, die langjährig in einem Behindertenheim lebte. Die neunstufige Skala zur Einschätzung wurde vom Betreuer der Frau entwickelt. Die Daten sind tägliche Fremdbeurteilungen (N=659) durch den Betreuer.


Abbildung 3:



Pulsdaten: Diese Datenreihe (N=11'664) beschreibt das kardiovaskuläre Pulsvolumengeschehen eines 26jährigen männlichen Probanden mit einer Schizophreniediagnose. Die Daten wurden durch eine spezielle Weiterverarbeitung des Fingerplethysmogramm-Signals gewonnen (KÄSERMANN & ALTORFER, 1989).

Abbildung 4:

Zeitreihe E



Surrogat-Daten-Methode

Die Methode der Surrogat-Daten (MSD) ist eine statistische Methode zur Quantifizierung und Charakterisierung nichtlinearer und deterministischer Muster in Zeitreihen (SCHIFF & CHANG, 1992; THEILER et al., 1992; WEIGEND & GERSHENFIELD, 1994). Analog zum inferenzstatistischen Ansatz werden hierbei die beobachteten Werte über eine diskriminierende Größe gegen eine Nullhypothese getestet. Die Nullhypothese stellt eine mögliche Erklärung der Daten dar, von der man zeigen möchte, daß sie inadäquat ist. Sie hat üblicherweise die Form: „Der Zeitreihe liegt eine Dynamik vom Typ X zugrunde“, wobei ein konkreter Typ beispielsweise weißes Rauschen, d. h. die Realisation eines Zufallsprozesses, sein kann. Die diskriminierende Statistik ist im allgemeinen ein Kennwert, der einen gegebenen Aspekt der vorliegenden Zeitreihe quantifiziert. In manchen Fällen ist die analytische Beschreibung der Verteilung einer gegebenen Statistik unter einer bestimmten Nullhypothese möglich. Dieser Ansatz bildet die Basis mancher bekannter Nichtlinearitäts-Tests (TONG, 1990). Die analytische Herleitung kann sich jedoch in vielen Fällen als äußerst schwierig bzw. unmöglich erweisen.

Die MSD ist ein Monte-Carlo Ansatz zur Schätzung dieser Verteilung. Das Ziel ist es also zu zeigen, daß die echten Daten B im Bezug auf eine geeignete Kenngröße G signifikant von einer Anzahl unter der Nullhypothese generierter Surrogat-Zeitreihen S abweichen, d. h. $G_B \neq G_S$. Surrogat-Daten sind Datensätze, die gewisse Eigenschaften (z. B. Mittelwert, Varianz oder Fourierspektrum) mit der originalen Zeitreihe gemeinsam haben, ansonsten jedoch mit der Nullhypothese konsistent sind. Sei also G_B der für die empirischen Werte berechnete Kennwert. Analog sei μ_S der Mittelwert und σ_S die Standardabweichung der Verteilung der für die Surrogat-Daten berechneten Kennwerte G_S . Dann berechnet sich das Effektmaß ζ als:

$$\zeta = \frac{|G_B - \mu_S|}{\sigma_S} \quad (1)$$

Das Effektmaß ist eine dimensionslose Quantität; wenn jedoch die Verteilung der Kenngröße normalverteilt ist, und dies hat sich in numerischen Experimenten häufig gezeigt (s. u.), dann läßt sich der p -Wert leicht berechnen. Ein Wert

$\zeta = 1.96$ entspricht beispielsweise dem Signifikanzniveau $p = .05$.

Wir benutzen Gleichung (1), da wir die oben beschriebenen empirischen Zeitreihen untersuchen („single case approach“). Wenn allerdings multiple Realisationen für die empirischen Daten vorhanden sind, können über einen KOLMOGOROV-SMIRNOFF oder MANN-WHITNEY Test die beiden Verteilungen (empirische Daten und Surrogat-Daten) bzw. über einen t -Test ihre Mittelwerte verglichen werden. Für lange Zeitreihen besteht zusätzlich die Möglichkeit, die Analyse für mehrere Zeitreihenabschnitte durchzuführen und so ebenfalls auf einen Vergleich der Verteilungen zu gelangen.

Der große Vorteil dieses Ansatzes liegt in der Möglichkeit, durch eine geeignete Wahl der Nullhypothese(n) bzw. der Kenngröße(n), beliebige Prozeßmodelle (z. B. stochastische oder deterministische) gegen die empirischen Daten zu testen und damit abklären zu können, welches Modell die Daten am besten erklärt. Hierfür ist ein sorgfältig ausgearbeiteter Auswertungsplan in Form einer adäquaten Auswahl von interessierenden Nullhypothesen wichtig.

Hierarchie von Nullhypothesen

Die Nullhypothese spezifiziert die Eigenschaften eines Prozesses, der die Daten möglicherweise adäquat erklärt. Für die empirische Forschung haben sich folgende Nullhypothesen als relevant erwiesen (SMITH, 1992; THEILER et al., 1992; WEIGEND & GERSHENFIELD, 1994):

(1) $H_0^{(SP)}$: Die Zeitreihe stellt die Realisation eines stochastischen Prozesses (SP) dar, d. h. es existiert in ihr keinerlei dynamische Struktur wie z. B. zeitliche Korrelationen. Die Surrogat-Daten können dann im einfachsten Fall über einen Standardzufallsgenerator generiert und bezüglich Mittelwert und Standardabweichung der Originaldaten normalisiert werden (Algorithmus 1). Dies entspricht der Hypothese $H_0^{(RSP)}$, daß den Daten ein *rein* stochastischer Prozeß (random walk) mit Normalverteilung (RSP) zugrunde liegt. Als weitere Nullhypothese kann die Annahme getestet werden, daß den Daten ein Zufallsprozeß mit der Verteilung der Originaldaten - die nicht normalverteilt zu sein braucht - zugrunde liegt, in diesen jedoch keine zeitliche Struktur enthalten ist ($H_0^{(VSP)}$). Die Surrogat-Zeitreihen werden in diesem Fall durch die Randomisierung der sequentiellen Ordnung der empirischen Signale erstellt (Algorithmus 2). Mit anderen Worten, die Eigenschaften der origina-

len Zeitreihe werden im wesentlichen beibehalten, zerstört wird einzig ihre zeitliche Korrelation.

(2) $H_0^{(LP)}$: Den Daten liegt ein linearer stochastischer Prozeß (LP) zugrunde, d. h. ihre dynamische Struktur beruht auf linearen Korrelationen und läßt sich durch ein lineares Modell erklären. Dies ist die Hypothese der klassischen BOX-JENKINS-Methodologie (BOX & JENKINS, 1970), wie sie sich auch in der Psychologie durchgesetzt hat (SCHMITZ, 1989). Die lineare Struktur einer Zeitreihe kann durch autoregressive (AR) und/oder Moving-Average (MA) Komponenten verschiedener Ordnung beschrieben werden (Gleichung (3) und (4))³. Beide Prozeßmodelle können in ein allgemeines ARIMA-Modell zusammengefaßt werden und einzeln oder in Kombination die Basis einer Nullhypothese der MSD bilden. Die Surrogat-Daten werden dann auf zwei Arten erstellt.

Eine Möglichkeit besteht darin, mit Hilfe der BOX-JENKINS-Technik das lineare Modell bzw. seine Ordnung aus den empirischen Daten zu bestimmen und anschließend mit Hilfe der so berechneten Koeffizienten einen linearen Prozeß mit normalverteilten Störgrößen und ersten zwei statistischen Momenten der Originalzeitreihe zu generieren (Algorithmus 3). Da die Identifikation des ARIMA-Modells nicht immer eindeutig ist, benutzen wir die Prozedur STATESPACE im Programmpaket SAS (SAS, 1992), die eine automatische Identifikation ermöglicht. Eine weitere Möglichkeit zur Generierung von Surrogat-Daten unter der „linearen“ Nullhypothese besteht darin, eine Fouriertransformation der Originalzeitreihe zu berechnen, die Fourierphasen zu randomisieren und schließlich die inverse Fouriertransformation durchzuführen (Algorithmus 4). Dieser Algorithmus bewahrt das Powerspektrum der „echten“ Zeitreihe und den Großteil der linearen Korrelation.

Mit Hilfe der Algorithmen 3 und 4 kann also geprüft werden, ob neben der linearen Struktur noch eine signifikante nichtlineare Struktur in den Daten vorhanden ist. Diese Methode ist im übrigen der nichtlinearen Residualanalyse linear gefilterter Daten vorzuziehen, da bei der linearen Filterung viel der nichtlinearen Struktur einer Zeitreihe verloren gehen kann (THEILER et al., 1992). Können diese Hypothesen nicht verworfen werden, dann ist die Anwendung der linearen Zeitreihentechniken (z. B. ARIMA) adäquat.

Hat man einmal eine Hierarchie von Nullhypothesen der obigen Art und Weise aufgestellt und Surrogat-Datensätze generiert, besteht der nächste Schritt in der Wahl einer der Fragestellung angemessenen diskriminierenden Statistik.

³ Ein MA-Modell stellt das Gegenstück zur Hypothese dar, daß psychologische Verläufe durch eine selbstorganisierende Dynamik verursacht sind, da hier die gesamte Varianz durch Umwelteinwirkungen entsteht; aber auch ein AR-Modell widerspricht dieser Annahme, da Selbstorganisation per definitionem nichtlinear ist (HAKEN, 1990).

Diskriminierende Prüfgröße

Die MSD kann prinzipiell mit jeder Prüfgröße benutzt werden. Um eine Nullhypothese verwerfen zu können, muß die Prüfgröße der Originaldaten von der Verteilung für die Surrogat-Daten abweichen. In dieser Arbeit interessiert in erster Linie die Frage nach nichtlinearen und deterministischen Strukturen. Determinismus manifestiert sich durch Vorhersagbarkeit, weshalb im folgenden auf einen von den Biologen SUGIHARA & MAY (1990) entwickelten nichtlinearen Vorhersagealgorithmus (NVA) zurückgegriffen wird. Dieser NVA eignet sich speziell für die psychologische Anwendung, da er insbesondere für kurze und verrauschte Zeitreihen konzipiert ist.

Die wesentliche Idee besteht darin, die erste Hälfte der Zeitreihe als „Bibliothek“ zu verwenden, um die zweite Hälfte vorherzusagen. Die Güte der Vorhersage wird mittels PEARSONs Korrelationskoeffizienten r zwischen vorhergesagten und echten Daten bestimmt und kann als diskriminierende Prüfgröße im Rahmen der MSD benutzt werden.

Der NVA läßt sich mit gängigen Programmiersprachen (z. B. C) leicht implementieren. Da nichtlineare Systeme in der Regel mehr als einen Freiheitsgrad aufweisen, d. h. mehrdimensional sind, müssen zunächst aus der eindimensionalen Originalzeitreihe die „fehlenden“ Dimensionen rekonstruiert werden. Dies gelingt mit der Methode von TAKENS (1981), mit der die eindimensionalen empirischen Werte in einen E -dimensionalen Raum „eingebettet“ werden können. Nach TAKENS' Theorem lassen sich aus einer empirischen Zeitreihe E -dimensionale Vektoren bilden, indem E aufeinanderfolgende Punkte der Zeitreihe zu einem Vektor zusammengefaßt werden: $X_t(E) = (x_t, x_{t-1}, \dots, x_{t-E+1})$. Jeder Vektor beschreibt einen Punkt im Phasenraum des Systems, das die Zeitreihe generierte, d. h. einen „Zustand“ dieses Systems. Wesentlich ist nun, daß durch diese Methode die topologischen Invarianten (z. B. die Dimensionalität) des dynamischen Systems erhalten bleiben bzw. aus einer eindimensionalen Zeitreihe berechnet werden können.

Als nächsten Schritt sagt man für alle Punkte der zweiten Hälfte der Zeitreihe die jeweilige zukünftige Entwicklung vorher. Hierzu verwendet man die in der ersten Hälfte der Zeitreihe enthaltene Information. Die Vorhersage $X_{t+1}^{(pred)}$ für einen Referenzpunkt X aus der zweiten Hälfte ($t > N/2$) berechnet sich nach der folgenden einfachen Gleichung:

$$X_{t+1}^{(pred)} = \sum_{i=1}^{E+1} NN(X_t)_{k(i)+1} \cdot e^{(-dist(NN(X_t)-X_t))} \quad (2)$$

wobei

$X_{t+1}^{(pred)}$: Vorhersage für Referenzpunkt X_t

E :	Einbettungsdimension
X_t :	Referenzpunkt
$NN(X_t)$:	Nächster Nachbar des Referenzpunktes
ν :	Konstante (= 0.005)
$dist(NN(X_t) - X_t)$:	Euklidische Distanz
k :	Laufvariable über die erste Zeitreihenhälfte ($1 \leq k < N/2$)
i :	Index des i -ten nächsten Nachbars
(1 $\leq i \leq E + 1$)	

Gleichung (2) erklärt sich wie folgt: Für den Referenzpunkt X_t - den Datenpunkt, für welchen wir eine Vorhersage berechnen möchten - werden $E + 1$ nächste Nachbarn NN in der ersten Hälfte der Zeitreihe eruiert. Hierfür wird zunächst die euklidische Distanz vom Referenzpunkt zu allen Daten in der ersten Hälfte berechnet. Anschließend werden die $E + 1$ Punkte mit den kleinsten Distanzen als nächste Nachbarn ausgewählt. Die Idee ist nun, daß sich der Referenzpunkt im nächsten Zeitschritt in die gleiche Richtung wie seine nächsten Nachbarn bewegen wird (lokal lineare Approximation). Dies entspricht einer Methode der Wettervorhersage: Um das Wetter am nächsten Tag vorherzusagen, kann man nach möglichst ähnlichen Wetterkonstellationen in der Vergangenheit suchen und annehmen, daß sich das aktuelle Wetter analog diesen vergangenen Mustern entwickeln wird.

Die Vorhersage im NVA ergibt sich deshalb aus der Aufsummierung der Folgewerte der Nachbarn, wobei ihr Einfluß auf die Vorhersage in Abhängigkeit ihrer Distanz zum Referenzpunkt exponentiell gewichtet wird. Die Gewichtung bewirkt, daß ähnliche und damit relevantere Nachbarn stärker in die Vorhersage einfließen. Die Konstante ν schließlich ist ein Skalierungsfaktor und wird im folgenden auf $\nu = 0.005$ gesetzt. (Der genaue Wert dieses Faktors hat wenig Einfluß auf die Resultate, vgl. FRANASZCUZK & BLINOWSKA, 1991).

Zusammenfassend quantifiziert die mit dem NVA berechnete Kenngröße r (Korrelation zwischen vorhergesagten und empirischen Werten) die nicht-lineare Vorhersagbarkeit einer gegebenen Zeitreihe und damit nichtlinearen Determinismus. Als nichtparametrische Methode eignet sich der NVA zudem speziell für psychologische Zeitreihen, die häufig mittels Rating-Skalen erhoben werden.

3. Ergebnisse

Numerische Experimente

Um den Nutzen und die Fähigkeit der MSD bzw. der gewählten Prüfgröße genauer testen zu können, generierten wir eine Reihe artifizierlicher Zeitreihen. Die Anzahl Surrogat-Datensätze wurde für alle Analysen auf $N_S = 30$ festgelegt, was in einer signifikanten Normalverteilung der Prüfgröße für die Surrogat-Daten resultierte ($p < .001$). Eine Zeitreihe, die tatsächlich von einem linearen und stochastischen Prozeß generiert worden ist, sollte mit dem von uns gewählten Prüfwert ein negatives Resultat liefern bzw. nicht in einen α -Fehler münden. Mit anderen Worten, die Nullhypothese $H_0^{(LP)}$ sollte in diesem Falle *nicht* verworfen werden können. Um dies zu testen, wurden zwei lineare Prozesse generiert

($N = 150$), ein autoregressiver Prozeß erster Ordnung (AR(1)):

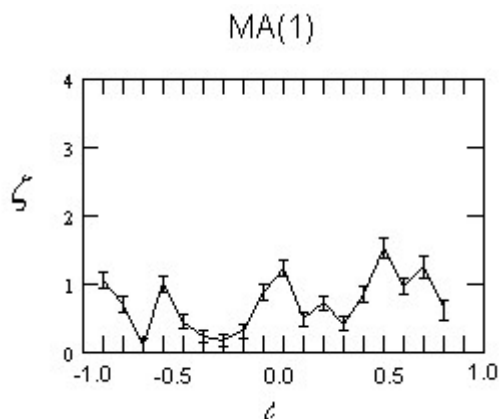
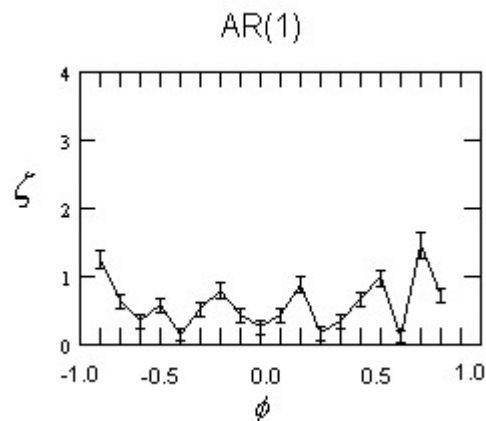
$$x_t = \phi x_{t-1} + \varepsilon_t \quad (3)$$

und ein Moving-Average Prozeß erster Ordnung (MA(1)):

$$x_t = \varepsilon_t + \theta \varepsilon_{t-1} \quad (4)$$

Abbildung 5 zeigt das MSD-Effektmaß, berechnet mittels dem oben beschriebenen Algorithmus 4, für beide Prozesse als Funktion einer Reihe von Parameterwerten $(\phi, \theta) \in [-0.9, \dots, 0.9]$.

Abbildung 5: Resultate der MSD für zwei lineare Prozesse. Auf der y-Achse ist das MSD - Effektmaß ζ aufgetragen. Die Einbettungsdimension beträgt für beide Prozesse $E = 3$. Die Nullhypothese, daß den Daten ein linearer und stochastischer Prozeß zugrunde liegt, kann nicht verworfen werden.

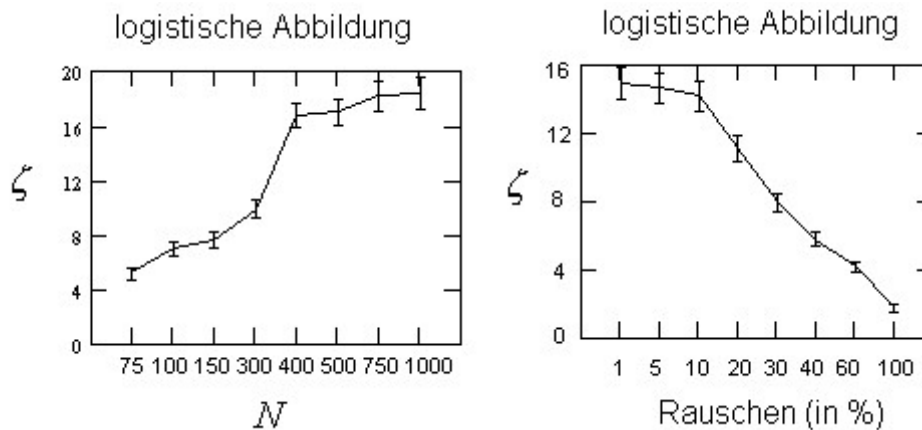


In beiden Fällen (AR(1) und MA(1)) kann die MSD die „echte“ Zeitreihe nicht signifikant von den Surrogat-Daten unterscheiden. Die Nullhypothese $H_0^{(LP)}$ kann nicht verworfen werden, d. h. die Zeitreihen werden korrekt als lineare Prozesse identifiziert. In einem solchen Fall kann also die empirische Zeitreihe ausreichend mit einer linearen Differenzgleichung der Art (3) oder (4) korrekt beschrieben werden.

Die eigentliche Stärke der MSD liegt in der Möglichkeit, *nichtlineare* Muster in den Daten charakterisieren zu können. Wir testeten dies, indem wir eine nichtlineare Zeitreihe durch Iteration der logistischen Abbildung $x_{t+1} = \lambda x_t(1-x_t)$ generierten, die für den Parameterwert $\lambda = 4.0$ chaotisches Verhalten zeigt und in der Biologie zur Modellierung von Populationsdynamiken benutzt wird (MAY, 1976; vgl. auch KRIZ, 1992a).

In Abbildung 6 links ist das Effektmaß als Funktion der Anzahl Datenpunkte für die logistische Abbildung ($\lambda = 4$) unter der $H_0^{(LP)}$ dargestellt. Wie erwartet nimmt das Effektmaß mit steigender Zeitreihenlänge deutlich zu, die MSD ist jedoch in der Lage, Nichtlinearität auch in der äußerst limitierten Datenlänge von $N = 75$ mit einem Signifikanzniveau von $p < .001$ auszumachen. Zudem erscheint eine Zeitreihenlänge von $N = 400$ ausreichend, da das Effektmaß auch für längere Datensätze nicht mehr bedeutend ansteigt und saturiert. Diese geringe Datenanforderung steht in direktem Zusammenhang mit der benutzten Prüfgröße und kann deshalb nicht auf andere Kennwerte (z. B. die fraktale Dimension) generalisiert werden.

Abbildung 6: Mit Hilfe der MSD können nichtlineare Strukturen in kurzen (links) und verrauschten (rechts) Zeitreihen identifiziert werden. Die Einbettungsdimension wurde für alle Zeitreihen auf $E = 2$ gesetzt.



Empirische Zeitreihen weisen in den allermeisten Fällen einen beträchtlichen Prozentsatz an von der Systemdynamik unabhängigen Zufallseinflüssen (z. B. Meßfehler) auf. Mit anderen Worten, die Daten y_t setzen sich in der Regel aus einem echten Signal x_t und einem unbekanntem Zufallseinfluß ε_t zusammen. In Abbildung 6 rechts ist das MSD-Effektmaß als Funktion eines zunehmenden Prozentsatzes von Zufallseinflüssen ε_t für eine Realisation der logistischen Abbildung dargestellt ($N = 400$). Nichtlineare Strukturen werden auch für eine zu 60% verrauschte Zeitreihe auf einem 99.99% Signifikanzniveau identifiziert.

Zusammenfassend zeigen diese Experimente, daß mit der MSD und dem von uns gewählten Kennwert Nichtlinearitäten bzw. Determinismus in äußerst kurzen und verrauschten Datensätzen signifikant identifiziert werden können.

Empirische Analysen

Im Gegensatz zu den eben angeführten numerischen Experimenten ist bei empirischen Datensätzen die Frage, ob sie eine erkennbare dynamische Struktur aufweisen, insbesondere bei größeren Meßzeitintervallen (z. B. Stunden oder Tage) nicht trivial. Dies verdeutlicht die optische Inspektion der Zeitreihen in Abbildungen 1-4. Für keine Zeitreihe ist eine signifikante Gestalt erkennbar, vielmehr scheinen sie zufällig zu fluktuieren.

Alle Zeitreihen wurden zunächst mit dem von SAID & DICKEY (1984) entwickelten Test auf Stationarität hin geprüft. Während sich die Reihen A, B und D als signifikant stationär ($p < .001$) erwiesen, mußten die Zeitreihen C und E einmal differenziert werden, um ihre Stationarität sicherzustellen.

In einem weiteren Schritt wurde mittels den oben beschriebenen Algorithmen 1 und 2 die Nullhypothese getestet, daß den Daten ein reiner Zufallsprozeß zugrundeliegt. Die Ergebnisse dieser Analysen, die in Tabelle 1 neben den ersten beiden statistischen Momenten für alle Zeitreihen zusammenfassend dargestellt sind, zeigen, daß in den Zeitreihen signifikante zeitliche Korrelationen enthalten sind. Es kann demnach nicht nur die Nullhypothese eines rein stochastischen und normalverteilten Prozesses, $H_0^{(RSP)}$, sondern auch diejenige eines Zufallsprozesses mit gleicher Verteilung wie die empirische Zeitreihe, $H_0^{(VSP)}$, für alle Zeitreihen verworfen werden.

Tabelle 1: Erste und zweite statistische Momente (zentrale Tendenz (M) und Dispersion (SD)) sowie Effektmaß-Werte der MSD für die empirischen Zeitreihen der Gestimmtheit (A,B), der differenzierten Rauchdaten (C), der Aggressionsdaten (D) und der differenzierten Pulsdaten (E).

Zeitreihe	M	SD	MSD-Effektmaß $\langle \xi \rangle$	
			$H_0^{(RSP)}$	$H_0^{(VSP)}$

A	1.60	2.32	22.24 ***	9.46 ***
B	2.39	1.77	19.45 ***	6.67 ***
C	0.01	9.12	32.85 ***	18.72 ***
D	2.88	0.96	21.42 ***	11.38 ***
E	0.00	1.54	46.43 ***	32.10 ***

Anmerkungen: $\langle \zeta \rangle$ bezeichnet den Mittelwert der über 10 Einbettungsdimensionen berechneten MSD-Effektmaßen.

*** $\rho < .001$; ** $\rho < .01$; * $\rho < .05$

Anschließend wurde deshalb getestet, ob diese signifikante dynamische Struktur auf linearen oder nichtlinearen zeitlichen Korrelationen beruht. Hierfür wurden mit Hilfe der Box-Jenkins-Methodik die linearen Komponenten in den Daten bestimmt und mit den signifikanten ARIMA-Koeffizienten die Surrogat-Daten generiert (Algorithmus 3). Die optimale Einbettungsdimension E_{opt} kann über verschiedene Techniken berechnet werden. Die einfachste und in der einschlägigen Literatur am häufigsten verwendete Prozedur (vgl. FARMER & SIDOROWICH, 1988) besteht darin, die Vorhersagequalität (quantifiziert über PEARSONS r , s. o.) über eine repräsentative Anzahl von Einbettungsdimensionen zu berechnen, wie in Abbildung 7 gezeigt. Die gesuchte Einbettungsdimension ist dann diejenige, für welche sich die besten Vorhersagen ergeben.

Abbildung 7: Vorhersagequalität in Abhängigkeit von der Einbettungsdimension E (am Beispiel der Raucherdaten)




Tabelle 2: Effektmaß-Werte der MSD für die Nullhypothese eines linearen Prozesses.

Zeitreihe	ARIMA-Modell	Modell - Parameter	t - Wert	E_{opt}	$\zeta(E_{opt})$
-----------	--------------	--------------------	----------	-----------	------------------

A	AR(1)	$\phi = 0.56$	13.85 ***	3	1.39 n.s.
B	AR(1)	$\phi = 0.62$	16.47 ***	3	3.19 **
C	ARIMA(1,2)	$\phi = 0.66$	10.92 ***	6	2.23 *
		$\theta_1 = 1.54$	19.32 ***		
		$\theta_2 = 0.55$	8.02 ***		
D	ARMA(1,1)	$\phi = 0.80$	12.06 ***	6	2.79 **
		$\theta = 0.63$	7.24 ***		
E	ARI(1)	$\phi = 0.48$	11.54 ***	9	6.43 ***

Anmerkungen: $\zeta(E_{opt})$ bezeichnet den MSD-Wert für die optimale Einbettungsdimension.

*** $\rho < .001$; ** $\rho < .01$; * $\rho < .05$

In Tabelle 2 sind die Resultate der MSD für die Nullhypothese eines linearen Prozesses zusammen mit den jeweils für die Erstellung der Surrogat-Daten benutzten ARIMA-Modellen dargestellt. Für die Zeitreihen B - E kann die Hypothese, daß die Daten von einem linearen Prozeß stammen, verworfen werden. Mit anderen Worten, da sich für diese Datensätze signifikante nichtlineare Strukturen nachweisen lassen, ist die Anwendung linearer Modelle für ihre Analyse nicht ausreichend. Welcher Art ist nun jedoch diese Nichtlinearität? Zunächst ist festzuhalten, daß wir aufgrund unserer Prüfstatistik auf nichtlinearen Determinismus testen. Dieser kann nun chaotisch oder nicht-chaotisch sein. Um uns der Frage, ob in den Zeitreihen chaotische Komponenten enthalten sind, anzunähern, haben wir für die Reihen B bis E den LYAPUNOV-Exponenten (LE) berechnet. Diese Wahl wird durch die Tatsache begründet, daß Chaos durch einen positiven LE definiert ist (SCHUSTER, 1988).

Tabelle 3: LYAPUNOV-Exponent für die Zeitreihen B bis E.

Zeitreihe	LYAPUNOV-Exponent
B	0.023
C	0.982
D	-0.021
E	0.012

Die Resultate, die in Tabelle 3 dargestellt sind, zeigen, daß sich nur für die Reihe C ein signifikant positiver LE findet, die anderen Reihen jedoch nicht-chaotisch sind. Zusammenfassend finden wir in vier der von uns untersuchten Zeitreihen nichtlinear-deterministische Strukturen, wobei in einer

- der Reihe C - diese Komponenten einer chaotischen Dynamik zu entstammen scheinen.

4. Diskussion

Welche Aussagen lassen sich aus diesen Resultaten ableiten? Auf methodischer Seite ist festzuhalten, daß es mittels der MSD gelingt, zwischen stochastischen, linearen und nichtlinear-deterministischen Gestaltmerkmalen in empirischen Zeitreihen zu differenzieren. Dies scheint uns ein zentrales Resultat zu sein, da die dynamische Varianz psychologischer Prozesse auf einer Mischung verschiedenster Einflüsse gründet und es demzufolge wichtig ist, diese Mixtur zu „entwirren“.

Ein weiterer wichtiger Punkt betrifft die Möglichkeit, in relativ kurzen und verrauschten Zeitreihen, wie sie in der Psychologie typischerweise vorliegen, signifikante nichtlineare Komponenten zu identifizieren. Dies eröffnet die Möglichkeit, theoretische Konzepte zur Selbstorganisation bzw. Chaos in der Psychologie empirisch zu prüfen. Trotzdem muß erwähnt werden, daß sich die nichtlineare Zeitreihenanalyse psychologischer Verläufe noch in einem Anfangsstadium befindet und einige theoretisch wichtige Fragen zur Zeit noch offen bleiben müssen (vgl. auch SCHEIER & TSCHACHER, 1994).

So wäre es beispielsweise wichtig, multivariate Untersuchungen durchführen zu können, die Aufschlüsse über das nichtlineare Zusammenwirken mehrerer Variablen geben könnten. Zudem fehlt bis heute die Möglichkeit, die Nichtlinearität genauer bestimmen zu können. Ein prominentes und theoretisch interessantes Beispiel nichtlinearer Dynamik stellt das deterministische Chaos dar. Die Entdeckung des Chaos als einer komplexen Form von Ordnung, die sich den Anschein der Unordnung gibt und sich zudem der Vorhersage nach kurzer Zeit entzieht, fasziniert eine zunehmende Zahl an Psychologen. Hierzu trägt auch der enge Zusammenhang zwischen Chaos und der - ästhetischen - Welt der Fraktale bei. Sind also Systeme, die durch die Psychologie untersucht werden, chaotisch? Oder ist die immer neue Vielfalt dieser Systeme weniger Ausdruck ihrer inneren Komplexität als vielmehr Folge der durch Meßfehler und Umgebungsrauschen erzeugten stochastischen Varianz? Alle uns bekannten Studien zu diesen Fragen beschränken sich auf phänomenologische Hinweise und Interpretationen von chaostheoretischen Methoden, deren Anwendbarkeit auf die zur Frage stehenden Zeitreihen nicht sicher ist. Die Verifikation chaotischer Dynamik in einer gegebenen Zeitreihe ist jedoch fragwürdig; wir meinen, mit dem von uns verwendeten ausschließenden Verfahren der „integrativen Prozeßanalyse“ einen wichtigen Schritt weiter gekommen zu sein. Durch die Implementation der Surrogat-Daten-Methode (MSD) unter Verwendung des nichtlinearen Vorhersagealgorithmus (NVA) finden wir nun statistisch abgesicherte Hinweise auf Determinismus und Nichtlinearität in psychologischen Zeitrei-

hen, die auf sehr unterschiedliche Weise zustande gekommen sind. Wie ist dies *inhaltlich* zu interpretieren?

Aus der theoretischen Diskussion in der Psychologie lassen sich unter anderem zwei komplementäre Modellvorstellungen über psychisches Funktionieren herausarbeiten. Die eine „dynamische“ Gruppe von Theorien geht von der Annahme eines psychologischen Determinismus aus: Erleben und Verhalten wird weitgehend als von innerpsychischen Faktoren des Individuums gesteuert angesehen (HOROWITZ, 1988; KIHLMSTROM, 1987; REDINGTON & REIDBORD, 1992). Dieser Vorstellung entspricht die Erwartung, in Zeitreihen, die psychisches Geschehen abbilden, eine zugrundeliegende Ordnung feststellen zu können. Auch wenn diese Ordnung kaum als regelmäßiges Muster manifest sein wird, könnte in diesem theoretischen Rahmen chaotische Dynamik etwa als Konkurrenz mehrerer innerpsychischer oder -systemischer Ordnungsparameter im Sinne der Synergetik angesehen werden.

Eine andere Tradition in der Psychologie bezieht sich wesentlich stärker auf die Kontingenz von Verhalten und Umwelt (RACHLIN, 1970, 1989; SKINNER, 1987). Diese lerntheoretische Erwartung wäre eher, daß Verhalten in einer nicht kontrollierten Umwelt weitgehend von ihren jeweiligen Fluktuationen geprägt ist. Das Verhalten ist also zwar sinnvoll in die jeweils aktuellen Reiz-Reaktionsketten eingepaßt, zeigt aber über die Zeit hinweg das gleiche Ausmaß an Stochastizität, das auch der bedingenden Umwelt eigen ist. Geht man hiervon aus, müßten Felddaten, wie die von uns untersuchten, einen bedeutenden Anteil von Rauschen aufweisen.

Der Datensatz A und B (die Gestimmtheitsdaten von Mann und Frau) weist jeweils eine serielle Struktur auf, die im Falle des Mannes mit einem linearen autoregressiven Modell erklärt werden kann: seine Gestimmtheit ist schlicht eine lineare Funktion der Gestimmtheit zum vorangegangenen Zeitpunkt. Im Falle der Frau muß ein komplizierteres, nichtlineares Modell zugrunde liegen, da die Vorhersage mit Hilfe des Phasenraums bessere Resultate als die lineare AR(1)-Modellierung ergibt. Die serielle Struktur beider Zeitreihen spricht eher für die dynamische Erwartung einer systeminternen Determination des Gestimmtheitsverlaufs, wobei der Rauschanteil, gemessen mit dem NVA ca. 45% beträgt. Die Interpretation ist durch die Tatsache der Kopplung von A und B (im Sinne einer Paardynamik) zu erweitern: Eine multivariate lineare Analyse ergibt jedoch keine kausalen Wechselwirkungen zwischen den Partnern, sondern lediglich die in Tabelle 3 beschriebenen AR-Komponenten sowie eine signifikante, aber niedrige Cross-Korrelation ($r = .23$). Eine nichtlineare Wechselwirkung im Paarsystem könnte dennoch bestehen; hierzu existieren jedoch noch keine adäquaten Methoden.

Die Rauchdaten C weisen eine signifikante nichtlineare Serialität auf; der positive LE weist auf Chaotizität hin. Interessanterweise haben wir die Zeitreihe C bereits früher in einer methodenkritischen Studie (STEITZ et al.,

1992) behandelt. Wir befaßten uns dort mit der Frage, wie robust die Bestimmung der Dimensionalität nach GRASSBERGER & PROCACCHIA hinsichtlich Rauschen, Zeitreihenumfang sowie -auflösung sei. Auf der Basis der damaligen Methode war die Annahme einer finiten Dimensionalität nicht gestützt worden, so daß wir die „lerntheoretische Erwartung“ für das Rauchverhalten für plausibel erachteten: Rauchen sei im wesentlichen eine Frage der Umweltkontingenzen, also etwa der zufälligen Verfügbarkeit von Zigaretten und der zufälligen Exposition an rauchbezogenen Stimuli. Auf der Basis der hier vorgetragenen Ergebnisse ist dies wohl „nicht die ganze Wahrheit“. Vielmehr können wir vertreten, daß der Rauchzeitreihe C zusätzlich eine latente chaotische Struktur zugrunde liegt, die durch ein nichtlineares System von etwa sechs Freiheitsgraden erzeugt wurde. Der Anteil zufälliger Fluktuation liegt bei etwa 50%. Wir denken daher, daß die Daten nicht allein durch die lerntheoretische Erwartung, d. h. umweltkontingente Reaktionen erklärbar sind.

Diese Analyse gilt ebenso für die Daten der Aggressionszeitreihe D und der physiologischen Zeitreihe E. In beiden Fällen ist der größte LE nicht mit Sicherheit positiv, so daß wir annehmen, daß die zugrundeliegenden Systeme nicht chaotisch sind. Jedoch wird auch im Falle der Aggressionszeitreihe die dynamische Erwartung gestützt, wobei einschränkend zu sagen ist, daß mit ca. 60% Stochastizität unbekannte Zufallseinflüsse etwa im Sinne von nichtstationären Umweltkontingenzen bedeutsamer als das diagnostizierte nichtlineare System sind. Die Gestalt ist gewissermaßen in Zufälligkeit eingebettet, bleibt aber dennoch mit unserer Methode signifikant erkennbar.

Bei der physiologischen Zeitreihe drängt sich eine weitere Frage auf: Ist die offensichtliche Periodizität der Zeitreihe weiter aufklärbar? Um diese Frage beantworten zu können, müßte die MSD um die Nullhypothese eines periodischen Prozesses erweitert werden.

Hier kann sich zukünftig der große Vorteil dieser Methode zeigen: durch sukzessives Hypothesentesten („Baukastenprinzip“) gelingt es, eine differenzierte und zugleich statistisch abgesicherte Einsicht in die Verlaufsgestalten einer Zeitreihe zu erlangen. Obwohl wir also keine sicheren Aussagen bezüglich der Chaotizität und der Art der Nichtlinearität machen können, sind wir mittels der MSD erstmals in der Lage, fundamentale Gestaltmerkmale psychologischer Zeitreihen - reine Stochastizität, Linearität und Nichtlinearität - zu differenzieren. Aus psychologischer Sicht eröffnet sich hiermit die Möglichkeit, prozeßorientierte Forschung unter Einbezug nichtlinearer Phänomene wie Selbstorganisation und Chaos zu betreiben.

Zusammenfassung

Die Analyse psychologischer Prozesse gewinnt in jüngster Zeit zunehmend an Bedeutung und zwingt zu einem methodischen Umdenken, da herkömmliche statistische Verfahren die Zeitdimension ausklammern. Die bisherigen prozeßorientierten Untersuchungen beschränken

sich in der Regel auf die Identifikation linearer Komponenten in den Daten; hierfür wird auf das methodische Instrumentarium der linearen Zeitreihenanalyse zurückgegriffen. In den hier berichteten methodenorientierten Untersuchungen wird ein alternatives Verfahren zur Typisierung psychologischer Prozesse vorgestellt, das die Quantifizierung nichtlinearer Verlaufsgestalten erlaubt. Zu seiner Exemplifizierung werden numerische Experimente wie psychologische Zeitreihen verwendet. Es zeigt sich, daß in den untersuchten Datensätzen signifikante nichtlineare Strukturen vorhanden sind. Die Resultate werden im Kontext neuer theoretischer Ansätze diskutiert, die psychologische Systeme als selbstorganisiert und nichtlinear konzeptualisieren.

Summary

The analysis of psychological processes is recently gaining increasing attention. This leads to a change in methodology since traditional statistical methods do not include the time dimension. Process-oriented research has so far been limited to the identification of linear components in the data; linear time series methodology is commonly used. In this paper an alternative approach to the classification of psychological processes is presented which allows for the quantification of nonlinear *Verlaufsgestalten*. This approach is applied to artificial test data and empirical psychological time series. We find significant nonlinear structures in the examined time series. The results are discussed in the context of recent theoretical approaches which conceptualize psychological systems as being self-organized and nonlinear.

Literatur

- BISCHOF, N. (1990). Ordnung und Organisation als heuristische Prinzipien des reduktiven Denkens. *Nova Acta Leopoldina*, 272, 285-312.
- BOX, G.E.P. & JENKINS, G.M. (1976). *Forecasting and control*. San Francisco: Holden Day.
- BUDER, E.H. (1991). A nonlinear dynamic model of social interaction. *Communication Research*, 18, 174-198.
- CASDAGLI, M. (1992). Chaos and deterministic versus stochastic nonlinear modelling. *Journal of the Royal Statistical Society*, 2, 2-29.
- CIOMPI, L., AMBÜHL, H. & DÜNKI, R. (1992). Schizophrenie und Chaostheorie. *System Familie*, 5(3), 133-147.
- DEPPE, W. (1977). *Formale Modelle in der Psychologie*. Stuttgart: Kohlhammer.
- FARMER, J.D. & SIDOROWICH, J. J. (1988). Exploiting chaos to predict the future and reduce noise. In: Y.C. Lee (Ed.). *Evolution, Learning and Cognition*. (S. 277-330). Singapore: World Scientific.
- FRANASZCUZK, F. & BLINOWSKA, M. (1991). Linear and nonlinear forecasting of rat EEG. *Biological Cybernetics*, 4, 23-34.
- GLASS, G.V., WILLSON, V.L. & GOTTMANN, J.M. (1975). *Design and analysis of time-series experiment* Boulder, Colorado: Colorado A&C. University Press.
- GRASSBERGER, P. & PROCACCIA, I. (1983). Measuring the strangeness of strange attractor *Physica D*, 9, 189-208.

- GRAWE, K. (1992). Psychotherapieforschung zu Beginn der neunziger Jahre. *Psychologische Rundschau*, 43, 132-162.
- GREGSON, R.A.M. (1983). *Time series in Psychology*. Hillsdale, NJ: Erlbaum.
- HAKEN, H. (1990). *Synergetik*. Berlin: Springer.
- HOROWITZ, M.J. (1988). *Introduction to Psychodynamics: A New Synthesis* New York: Basic Book
- HÖGER, R. (1992). Chaos-Forschung und ihre Bedeutung für die Psychologie. *Psychologische Rundschau*, 43, 223-231.
- KÄSERMANN, M.L. & ALTORFER, A., (1989). Family Discourse: Physiological Correlates of Different Degrees of Stress, *British Journal of Psychiatry*, 155, 136-143.
- KIHLSTROM, J.F. (1987). The cognitive unconscious. *Science*, 237, 1445-1452.
- KÖHLER, W. (1920). *Die physischen Gestalten in Ruhe und im stationären Zustand. Eine naturphilosophische Untersuchung*. Braunschweig: Vieweg.
- KRIZ, J. (1992a). *Chaos und Struktur*. München: Quintessenz.
- KRIZ, J. (1992b). Synergetics in Clinical Psychology. In: W. Tschacher, G. Schiepek, E.J. Brunner (Eds.), *Self-Organization in Clinical Psychology* (S. 120-134). Berlin: Springer.
- MAHONEY, M.J. (1991). *Human Change Prozesse* The Scientific Foundations of Psychotherapy. Chicago: Basic Book
- MAY, R.M. (1976). Simple Mathematical Models with Very Complicated Dynamics. *Nature*, 261, 459-467.
- MEIER, F. (1988) (Hrsg). *Prozeßforschung in den Sozialwissenschaften*. Stuttgart: Fischer.
- NICOLIS, G. & PRIGOGINE, I. (1987). *Self-Organization in Nonquilibrium Systems*. New York: Wiley.
- PETERMANN, F. (1978). *Veränderungsmessung*. Stuttgart: Kohlhammer.
- PRIESTLEY, M.B. (1990). *Nonlinear and non-stationary time series*. New York: Academic Press.
- Rachlin, H. (1970). *Introduction to modern behaviorism*. San Francisco: W.H. Freeman.
- RACHLIN, H. (1989). *Judgement, decision and choice: A cognitive/behavioral synthesis*. San Francisco: W.H. Freeman.
- REDINGTON, D.J. & REIDPORD, P. (1992). Chaotic Dynamics in Autonomic Nervous System Activity of a Patient During a Psychotherapy Session. *Biological Psychiatry*, 31, 993-1008.
- RHENIUS, D. (1974). *Theorie stochastischer Prozesse*. Bern: Huber.
- RICE, L.N. & GREENBERG, L. (1984). The New Research Paradigm. In: L.N. RICE & L. GREENBERG (Ed.), *Patterns of change: Intensive analysis of psychotherapy process* (S. 7-26). New York: Guilford Press.
- RUELLE, D. (1990). Deterministic Chaos: the science and the fiction. *Proc.R.Soc.Lond.A.*, 427, 241-248
- SAID & DICKEY (1984). Testing for Unit Roots in Moving Average Models of Unknown Order. *Biometrika*, 71, 599-607.
- SAS, 1992. *SAS/ETS User's Guide*, Version 6. Cary, N.C: SA.
- SCHEIER, Ch. & TSCHACHER, W. (1994). Nichtlineare Analyse dynamischer psychologischer Systeme I: Konzepte und Methoden. *System Familie*, 7, 133-144.
- SCHMITZ, B. (1987). *Einzelfallforschung in der Psychologie*. Weinheim: Beltz.
- SCHMITZ, B. (1989). *Zeitreihenanalyse in der Psychologie*. Bern: Huber.
- SCHUSTER, H.G. (1988). *Deterministic Chaos: an Introduction*. (2nd revised edn.) Weinheim: VCH.

- SKINNER, B.F. (1987). What happened to psychology as the science of behavior? *American Psychologist*, 42, 780-786.
- SMITH, R.L. (1992). Estimating Dimension in Noisy Chaotic Time Serie *J.R. Statist. Soc. B*, 54, 329-351.
- STADLER, M. & KRUSE, P. (1989). The Self-Organization Perspective in Cognition Research: Historical Remarks and New Experimental Approache In: H. Haken und M. Stadler (Eds.), *Synergetics of Cognition* (S. 32-52). Berlin: Springer.
- 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 in Clinical Psychology* (S. 367 - 384). Berlin: Springer.
- SUGIHARA, G. & MAY, R. (1990). Nonlinear forecasting as a way of distinguishing chaos from measurement error in time series. *Nature*, 344, 734-741.
- TAKENS, F. (1981). Detecting strange attractors in turbulence. *Lect. Notes Math.*, 898, 230-242.
- THEILER, J. (1990). Estimating fractal dimension. *J. Opt. Soc. Am.*, 7, 1055-1073.
- THEILER, J., GALDRIKIAN, B., LONGTIN, A., EUBANK, F. & FARMER, J.D. (1992). Using surrogate data to detect nonlinearity in time serie In: CASDAGLI, M. & EUBANK, (Eds.). *Nonlinear Modeling and Forecasting* (S. 230 - 245). Redwood City: Addison-Wesley.
- TONG, H. (1992). A note on a bridge between nonlinear dynmicists and statistican *Physica D.*, 58, 299-304.
- TSCHACHER, W. (1990). *Interaktion in selbstorganisierten Systemen*. Heidelberg: Asanger.
- TSCHACHER, W., SCHIEPEK, G. & BRUNNER, E.J. (Ed). *Self-Organization in Clinical Psychology*. Berlin: Springer.
- TSONIS, A. (1992). *Chao* From theory to application New York: Plenum Preß.
- WARNER, R.M. (1992). Cyclitcty of vocal activity increases during conversation: support for a nonlinear systems model of dyadic social interaction. *Behavioral Science*, 37, 128-138.
- WEIGEND, A. & Gershenfield, T. (1994) (Eds.). *Predicting the future and understanding the past*. Redwood City: Addison-Wesley.

Anschriften der Verfasser:

Christian SCHEIER
 Institut für Informatik, AILab
 Winterthurerstraße 190
 CH-8075 Zürich

Dr. Wolfgang TSCHACHER
 Sozialpsychiatrische Universitätsklinik Bern
 Murtenstraße 21
 CH-3000 Bern

Wolfgang Tschacher
 Institut für Informatik AILab
 Winterthurerstraße 190
 8057 Zürich