

- WILLIMCZIK, K./ROTH, K.: Bewegungslehre. Reinbek 1983.
- WULF, G.: Schema Theory and Mass-spring Control of Movements: An Attempt at Integration. In: Sportwissenschaft 19(1989), 204-215.
- WULF, G.: Neue Befunde zur Effektivierung des Bewegungslernens. In: Sportpsychologie 6(1992), H.1, 12-16.
- ZIMMER, A.C./KÖRNDE, H.: A Model for Hierarchically Ordered Schemata in the Control of Skilled Action. In: Gestalt Theory 10(1988), 85-102.
- ZIMMERMANN, K.W./KAUL, P.: Einführung in die Psychomotorik. Kassel 1990.

Martin Lames

Zeitreihenanalyse in der Trainingswissenschaft¹

Abstract: The Use of Time Series Analysis in the Theory of Training

After presenting considerations pertaining to the definition of time-series and the relation of time-series vs. single case-analyses, the second section describes a number of useful applications of time-series analysis in the theory of training. The most important fields of application are the description of training-processes as timebends (e.g. periodization), the statistical analysis of training-experiments and analyses of training-effects. Besides these compelling indications for the use of case analyses and time-series analyses as methods in the theory of training it is shown in the first part of this section, that 'traditional' sample-based statistical methods often do not have the potential to answer specific questions on the theory of training. Major handicaps of these methods lie in the process-diagnostics (e.g. objective and subjective stress) and in the analysis of complex, individually determined phenomena (e.g.: stress-reaction, interactive, spontaneous and random courses of competitive sports games and combatant sports disciplines).

These convincing arguments for the use of single case and time-series analyzing methods is counteracted by grave problems with their practical application - as they are described in chapter 4.1... They should, however, only function as a retarding factor, time-series analyses being the only methodical approach to a number of central scientific questions on the theory of training. One important task is the identification of questions for which time-series can be utilized. The first steps with this procedure should be made on the basis of simple, descriptive questions in order to gain experience with the method. On the basis of these and with plenty of careful preparation valid experiments should be possible. All in all a broader use of time-series analysis assures a considerably deeper scientific understanding of the training-process.

Zusammenfassung

Nach allgemeinen Ausführungen zur Definition von Zeitreihen und zum Verhältnis Zeitreihen- vs. Einzelfallanalysen wird im zweiten Abschnitt eine Fülle von lohnenden Anwendungen der Zeitreihenanalyse in der Trainingswissenschaft beschrieben. Die wichtigsten Einsatzgebiete sind die Abbildung von Trainingsprozessen als Verläufe in der Zeit (z.B. Periodisierung), die Auswertung von Trainingsexperimenten und Trainingswirksamkeitsanalysen.

Neben dieser überzeugenden Indikationslage für den Einsatz einzelfall- und zeitreihenanalytischer Methoden in der Trainingswissenschaft kann darüber hinaus im ersten Abschnitt gezeigt werden, daß "traditionelle" gruppenstatistische Verfahren oft nicht in der Lage sind, spezifische Fragen der Trainingswissenschaft zu beantworten. So liegen große Handicaps der gruppenstatistischen Verfahren in der Prozeßdiagnostik (z.B. Belastungs-Anpassungsprozesse) und in der Analyse von individuell determinierten, komplexen Sachverhalten vor (z.B. Belastungs-Bearspruchungsreaktionen, interaktive, spontane und zufällige Verläufe von Wettkämpfen in Sportspielen und Kampfsportarten).

Diesen starken Argumenten für den Einsatz einzelfall- und zeitreihenanalytischer Methoden stehen allerdings erhebliche Probleme im praktischen Einsatz gegenüber, wie in Abschnitt 4.1 ausgeführt wird. Diese sollten aber letztlich nur aufschließenden Charakter haben, da Zeitreihenanalysen als Zugang zu gewissen zentralen trainingswissenschaftlichen Fragen die einzige methodische Alternative darstellen.

¹ Überarbeitete Fassung eines Referates auf dem 4. dvs-Workshop zur Förderung des sportwissenschaftlichen Nachwuchses zum Thema: "Aktuelle Probleme der Trainingswissenschaft" vom 23.-27. August 1993 in Berlin.

Eine wichtige Aufgabe angesichts der hohen Anforderungen an die Daten ist zunächst die Identifikation von Fragestellungen, für die man diesbezüglich brauchbare Zeitreihen vorfindet. Die konkrete Annäherung an das Verfahren sollte dann mit einfachen, beschreibenden Fragestellungen beginnen, um Erfahrungen mit der Methode zu sammeln. Auf diesen aufbauend sollten bei sorgfältiger Planung aussagekräftige Einzelfallexperimente möglich sein.

Insgesamt kann man sich von einer verbreiteten Anwendung der Zeitreihenanalyse eine erhebliche Vertiefung der wissenschaftlichen Durchdringung des Trainingsprozesses versprechen.

Einleitung

"Das Kugelstoßen der Männer hat sich seit 1960 nach dem Modell ARIMA(1,0,0)(1,0,0)4 entwickelt!" Diese Aussage soll zwar noch im weiteren Verlauf der Erörterungen getroffen werden, aber auch der sich in ihr andeutenden Gefahr einer technizistischen Auffassung wird im folgenden begegnet. Es wird versucht, eine Einbettung der Zeitreihenanalyse als Methode der Datenverarbeitung in die spezifischen Problemstellungen der Trainingswissenschaft zu leisten.

1. Forschungsmethodische Aspekte der Zeitreihenanalyse

Definition Zeitreihe

Unter einer Zeitreihe versteht man allgemein eine zeitlich geordnete Folge x_t von Beobachtungen. Für jeden Zeitpunkt aus einer Indexmenge $t \in T$ liegt genau eine Beobachtung vor.

Aus mathematischer Sicht werden Zeitreihen als *Folge von Zufallsvariablen* aufgefaßt. Eine Zufallsvariable X ordnet dem Ergebnis eines Würfels die Seite mit sechs Punkten oben liegt, nimmt die Zufallsvariable "Ergebnis des Würfelwurfs" den Wert 6 an.) Eine solche Folge (X_{t+1}) von Zufallsvariablen ist ein *stochastischer Prozeß*. Eine Zeitreihe wird statistisch als Realisierung eines stochastischen Prozesses aufgefaßt (vgl. z.B. SCHLITTGEN/STREITBERG 1984). Eine Zeitreihe steht zu einem stochastischen Prozeß in der Relation Stichprobe - Grundgesamtheit. Die allgemeine Problemstellung in der Zeitreihenanalyse kann also so formuliert werden, daß anhand einer konkreten Zeitreihe der zugrundeliegende stochastische Prozeß geschätzgt werden soll.

Die Begriffe "Zeitreihenanalyse" und "Einzelfallanalyse"

Gelegentlich werden die Begriffe "Zeitreihenanalyse" und "Einzelfallanalyse" synonym verwendet. SCHLICHT und JANSSEN (1990) vereinbaren deshalb ausdrücklich, daß sie den Terminus "Einzelfallanalyse" im Sinne von "statistisch kontrollierter Einzelfallanalyse" gebrauchen. PETERMANN (1982) grenzt die quantitative Einzelfallanalyse von der Einzelfallanalyse als qualitativer Forschungsmethode in den Sozialwissenschaften ab.

Eine Einzelfallanalyse (auch: Einzelfallstudie) im Zusammenhang des qualitativen Forschungsparadigmas versucht, das Geflecht der Wahrnehmungen und Interpretationen eines Individuums in seiner Umwelt wissenschaftlich zu rekonstruieren. Sie weist die typischen Merkmale der qualitativen Methodologie auf, wie beispielsweise *Offenheit* be-

züglich des theoretischen Konzepts und der Erhebungssituation. Weiters wird der Zugriff auf die Wirklichkeit in einer sozialen Situation als *kommunikativer Akt* aufgefaßt, und die Erschließung des Sinngehalts einer sozialen Situation geschieht bewußt *interpretativ* (vgl. z.B. LAMNEK 1989).

Die qualitative Variante der Einzelfallanalyse ist also mit der eingangs entwickelten Definition von Zeitreihen in mehrerer Hinsicht unvereinbar. Eine weitere terminologische Unterscheidung zwischen "Einzelfallanalyse" und "Zeitreihenanalyse" erzwingt die Tatsache, daß selbstverständlich auch Mittelwerte von Zufallsvariablen (also z.B. Gruppenmittelwerte) wieder Zufallsvariablen sind. Eine Folge von Gruppenmittelwerten in der Zeit stellt also durchaus eine Zeitreihe dar.

Zeitreihen beschreiben also weder immer Einzelfälle, noch impliziert eine Einzelfallanalyse das Vorliegen einer Zeitreihe. Allerdings gilt die Zeitreihenanalyse als die klassische Methode der Datenverarbeitung bei quantitativen Einzelfallanalysen, weshalb im folgenden die speziellen Vorteile der Einzelfallanalyse gegenüber Gruppenanalysen herausgestellt werden sollen.

Einzelfall- vs. Gruppenanalysen

Das klassische Ziel der Wissenschaft ist es, allgemeine Gesetzmäßigkeiten aufzudecken (Nomothetik). Dieses Ziel impliziert bereits weitgehend Methoden der Datenerhebung und Datenauswertung. Allgemeine Aussagen sind insbesondere solche über Grundgesamtheiten, die aufgrund der Ausprägungen von Merkmalen im Stichproben ermittelt werden. Der klassische statistische Test und das Konzept der Konfidenzgrenzen liegen als Werkzeuge seit den 20er bzw. 30er Jahren dieses Jahrhunderts vor.

Gruppenanalysen galten lange Zeit ausschließlich als das angemessene Design nomothetischer Forschung (vgl. BARLOW/HERSEN 1984). Die Kritik an dieser Position, die schon immer vorhanden war, verstärkt sich allerdings etwa seit den 70er Jahren. Folgende Gründe können in aller Kürze aufgelistet werden:

- Als Ausgangspunkt der Kritik spielt sicherlich die *Praxis*, also die jeweiligen Anwendungsfelder der Verhaltenswissenschaften, eine wichtige Rolle. Praktiker in nahezu allen Sozialwissenschaften monieren, daß die Ergebnisse von Gruppenanalysen für ihre Arbeit kaum brauchbar seien. Wahrscheinlichkeitsaussagen über Gruppenmittelwerte liefern der Praxis im Umgang mit einzelnen Individuen nur wenig Hilfestellungen.
- Fortschritte in der *Wissenschaftstheorie* brachten klarere Vorstellungen darüber, wie eine wissenschaftliche Begründung praktischen Handelns gestaltet sein könnte. Es wird heute allgemein zwischen den forschungsbezogenen Tätigkeitsfeldern "Wissenschaft" und "Technologie" unterschieden. In beiden Feldern werden bestimmte Hypothesenarten geprüft, die jeweils spezielle Forschungsdesigns verlangen².
- Fortschritte in der *Theoriebildung der Verhaltenswissenschaften* rückten immer mehr die komplexen, individuelle Bedingtheit menschlichen Verhaltens in den Blickpunkt. Als Beispiel kann das Persönlichkeitstypkonzept in der Psychologie gelten, das sich vom starren Eigenschaftsmodell hin zu interaktionistischen Ansätzen entwickelte. Die Erklärung von individuellem Verhalten entzieht sich demnach weitgehend gruppenanalytischem Vorgehen.

² Zu den Konsequenzen aus diesem Sachverhalt für die Trainingswissenschaft vgl. SCHLICHT/LAMES (1993).

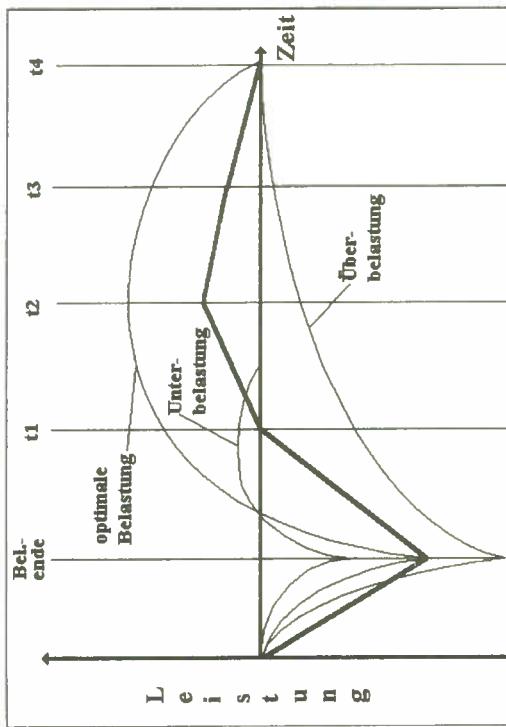


Abb. 1: Illustration der Notwendigkeit von kontinuierlichem und einzelfallbezogenem Vorgehen in der Prozeßdiagnostik am Beispiel individueller Reaktionen in einem Belastungs-Erholungs-Prozeß. Der Gruppenmittelwert (dicke Linie) vermag keinen der drei individuellen Verläufe angemessen abzubilden. Die Rekonstruktion individueller Entwicklungskurven setzt überwiegend ein zeitreiches Vorgehen voraus. In Abbildung 1 ist verdeutlicht, daß eine gruppenanalytische längsschnittliche Prozeßdiagnostik unter Umständen den zugrundeliegenden Wirkmechanismus sogar verschleiert. Eine Zeitreihenanalyse hätte in diesem Beispiel erkannt, daß es sich um eine mehrmalige Realisation des gleichen Prozesses mit verschiedenen Zeit-Parametern handelt.

- Fortschritte in der *mathematischen Statistik* ermöglichen erst seit relativ kurzer Zeit Interventionsanalysen auf der Basis von Zeitreihen. Ein wesentlicher Beitrag, die Integration der Interventionskomponente in die Zeitreihe von BOX und TIAQ, stammt beispielsweise aus dem Jahre 1975³. Die bislang dominante klassische Testtheorie ist ein Abbild der (psychologischen) Theoriebildung ihrer Zeit. Dem "wahren Wert" entsprechen die stabilen Persönlichkeitseigenschaften. Dieses Konzept führt notwendigerweise zu Problemen im Zusammenhang der Veränderungsmessung. Die von BEREITER (1963) formulierten Dilemmata der Veränderungsmessung (Regression zur Mitte, Reliabilitäts-Validitäts-Dilemma und Maßbedeutungsproblem, vgl. PETERMANN 1978) bezeichnen deshalb MÖBUS und NAGL als "Scheinprobleme ... , wenn man einmal das Reliabilitätskonzept der klassischen Testtheorie nicht kritisiert und zum anderen Veränderungsanalyse unter einer systemtheoretischen Perspektive betreibt" (1983, 241). Heute teilt man das Erstaunen von BARLOW und HERSEN (1984) über die Tatsache, daß die Varianzanalyse, die von Fisher zur Kontrolle verschiedener Einflüsse auf landwirtschaftliche Erntemengen entwickelt wurde, lange Zeit völlig analog auf die Kontrolle verschiedener Einflüsse auf menschliches Verhalten eingesetzt wurde.
- Ein offensichtliches Handicap von Gruppenanalysen ist die *Limitierung auf Aussagen über Mittelwerte*. Oft werden entsprechende Resultate falsch interpretiert, etwa wenn aus signifikanten Verbesserungen in einem Trainingsexperiment die Wirksamkeit des dort applizierten Treatments für ein Individuum als nachgewiesen gilt. Besonders gravierend wirkt sich eine Mittelung bei Entwicklungsanalysen aus. So repräsentieren die bekannten Verlaufskurven für die motorische Entwicklung möglicherweise in keinem einzigen Fall die Entwicklung eines Individuums.

Zeitreihenanalyse als Instrument der Prozeßdiagnostik

Die oben zitierten Bedenken gegen Gruppenanalysen kumulieren in Untersuchungen, die sich der Beschreibung und Analyse von Entwicklungen widmen. Veränderungen im menschlichen Verhalten sind grundsätzlich komplex determiniert. Sie sind nur aus Kenntnis der individuellen Konstellation hinreichend erklärbar. Die Einzelfallanalyse ist also zur *Prozeßdiagnostik* stark indiziert.

Die Zeitreihenanalyse bietet darüber hinaus noch besondere Vorteile für die Prozeßdiagnostik. Da der Prozeß über einen längeren Zeitraum mit einer relativ hohen Beobachtungsfrequenz erfäßt wird, kann bei geeigneter Wahl des Beobachtungsintervales von einer quasi kontinuierlichen Abbildung des Prozesses gesprochen werden. Wenn man beispielsweise davon ausgeht, daß die Reaktion auf eine physische Belastung eine individuelle Dynamik aufweist, ist einzige eine solche quasi kontinuierliche Erfassung der körperlichen Reaktionen über einen geeigneten Zeitraum hinweg in der Lage, den Belastungs-Anpassungs-Prozeß adäquat abzubilden (vgl. Abb. 1).

Wegen dieser überzeugenden Indikationslage muß nicht mehr der Einsatz der Zeitreihenanalyse legitimiert werden, sondern man kann sich darauf beschränken, ihre speziell trainingswissenschaftlichen Anwendungsfelder aufzuzeigen. Überträgt man die Anwendungsgebiete der Zeitreihenanalyse, die REVENSTORF und KEESEER (1979) für die klinische Psychologie nennen, auf die Trainingswissenschaft, so ergeben sich die folgenden drei Gebiete:

³ Die theoretischen Fortschritte der mathematischen Statistik wurden ihrerseits durch die technologischen Entwicklungen auf dem Gebiet der Computertechnik ermöglicht. Diese machen erst die umfangreichen Rechnungen praktikabel, mit denen Zeitreihenanalysen verknüpft sind.

1. Durch die Anpassung eines Zeitreihenmodells an die gefundenen Daten erhält man *Beschreibungen von Verläufen* unter Berücksichtigung der seriellen und periodischen Struktur der untersuchten Trainingsprozesse.
2. Zeitreihenanalysen sind das geeignete Mittel, um die *Wirksamkeit von Interventionen* zu überprüfen. Unter einer Intervention wäre beispielsweise der Einsatz eines bestimmten Trainingsmittels zur Erreichung eines speziellen Trainingsziels zu verstehen.
3. Die Beschreibung des u.U. *zeitverzögerten Wirkungszusammenhangs mehrerer Variablen* ist Gegenstand der multivariaten Zeitreihenanalyse. Von besonderem trainingswissenschaftlichem Interesse ist hier beispielsweise der Zusammenhang zwischen Trainingsumfang, Trainingsintensität und der sportlichen Form oder der Zusammenhang zwischen einzelnen Leistungsvoraussetzungen und der komplexen Leistungsfähigkeit.

Beschreibung von Verläufen

Im Zusammenhang des sportlichen Trainings ist zunächst der Verlauf der sportlichen Leistungsfähigkeit oder einzelner Komponenten der Leistungsfähigkeit von Bedeutung. Über die zyklische Struktur solcher Verläufe oder ihre kurz-, mittel- und langfristige Gestalt existieren eine Fülle von Idealvorstellungen, die meist noch wenig empirisch belegt sind.

SCHLICHT (1988) untersuchte über den Zeitraum von 26 bzw. 34 Wochen einer Freiluft-Saison den Verlauf vor allem psychischer Variablen des Trainingsprozesses von zwei Leichtathleten. An jedem Mittwoch und an jedem Samstag wurden Fragebogen zu Kognitionen, zur Zustandsangst und zur Befindlichkeit ausgefüllt. Darüber hinaus wurden der Trainingsumfang bzw. die Trainingsinhalte protokolliert, die Wettkampfleistungen der Saison festgehalten und besondere Ereignisse erfaßt. Zur Beschreibung der Verläufe der Zeitreihen wurden u.a. ARIMA-Modelle (siehe 3.2) eingesetzt und zeitversetzte Korrelationen zwischen den erhobenen Variablen berechnet. Als Ergebnis konnte gezeigt werden, daß ein Großteil der psychischen Zustände serielle Strukturen aufweist. Darüber hinaus beeinflußten bei beiden Athleten die psychischen Variablen zeitversetzt die Wettkampfleistung.

SCHLICHT und JANSEN (1990) verwenden zur Beschreibung des zyklischen Verlaufs eines Trainingsprozesses u.a. die Spektraldichte über den täglichen Tempolaufumfang. Es lassen sich Zyklen der Länge 7 (Wochenzyklus) und 2 (Belastungs-Erholungswechsel) nachweisen. In einer bivariaten Spektralanalyse (vgl. 3.5) wurde gezeigt, daß dies auch die wichtigen Zyklen sind, mit denen "subjektive Erfolgswahrscheinlichkeit" und Tempolaufumfang gemeinsam schwingen.

Neben der Beschreibung von Verläufen im Training sei aber auch auf ein weiteres Einsatzfeld aufmerksam gemacht, in dem Zeitreihenanalysen nützliche Beschreibungen liefern können. Es handelt sich um das in der Trainingswissenschaft eher vernachlässigte Feld der *Wettkampfanalyse*. Zum einen in den Sportartengruppen der Sportspiele und Kampfsportarten muß der Wettkampf als prozessuales Interaktionsgeschehen aufgefaßt werden. Der Ablauf von Maßnahme und Gegenmaßnahme in der Zeit ist charakteristisch für das Geschehen und läßt die Zeitreihenanalyse als konzeptionell besonders geeignete Methode erscheinen.

LAMES (1992) beschreibt den zeitlichen Verlauf einiger Variablen der Spielanlage im Tennis mit Methoden der Zeitreihenanalyse. Es konnte gezeigt werden, daß häufig seriell

- le Abhängigkeiten im Spielerhalten bestehen. Die Beschreibung des Verlaufs von Verhaltensweisen belegte deren starke Schwankungen innerhalb eines Matches. Es existieren Fälle, in denen über das gesamte Match gemittelte Häufigkeiten, beispielsweise die Aufschlagfehlerrate, zu fast keinem Zeitpunkt den tatsächlichen Wert widerspiegeln (s.u. Abb. 4). Als Konsequenz sollten Beschreibungen und Analysen eines Matches auf der Basis von gemittelten Werten sehr zurückhaltend betrachtet werden.

Trainingsexperimente

Interventionsanalysen in der Trainingswissenschaft werden in einer kontrollierten Form in der Regel als Trainingsexperimente durchgeführt. Aus den bereits mehrfach erwähnten Gegebenheiten im sportlichen Training, dem komplexen Leistungsgefüge und dem individuellen Ansprechen auf Trainingsserize, sollten zur Durchführung von Trainingsexperimenten vermehrt Einzelfallexperimente und zu deren Auswertung vermehrte Zeitreihenanalysen eingesetzt werden. Dabei ist besonders Wert auf angemessene Designs und geeignete Generalisierungsstrategien zu legen⁴.

Wirksamkeitsanalysen

Der komplexe Wirkungszusammenhang von Variablen des Trainingsprozesses im Verlauf der Zeit ist von zentralem Interesse für die Trainingswissenschaft. Die multivariate Zeitreihenanalyse bietet die prinzipielle Möglichkeit zu deren problemangemessener Behandlung.

Eine Studie zu diesem Thema wurde von HOHMANN (1988) vorgelegt. In einem regressionsanalytischen Ansatz wird die Aufklärung der Spieleistung im Wasserball durch gleichzeitige und vorausgehende Trainingsparameter (Umfang und Intensität, Inhalte und Methoden) bestimmt. Pro Parameter werden die "signifikanten Lags" ermittelt, d.h. die Tage vor dem Wettkampftag, die einen überzufälligen Beitrag zur Aufklärung der Wettkampfleistung liefern. Es ergeben sich individuelle Zusammensetzungsmuster. HOHMANN ist in der Lage, je nach Charakteristik der zeitlich verzögerten Trainingseffekte zwischen verschiedenen Adaptationstypen zu unterscheiden und fordert eine stärkere Berücksichtigung der verschiedenen Spielerotypen in Vorbereitungsmodeilen zu besonderen Wettkampfhöhepunkten.

3. Methoden der Zeitreihenanalyse

Aus dem umfangreichen Spektrum an zeitreihenanalytischen Methoden werden hier Tendenzberechnungen, die ARIMA-Modelle und kurz die Spektralanalyse angeführt. Viele weitere Verfahren können nicht berücksichtigt werden, beispielsweise Zeitreihenanalysen für nominalskalierte Daten (vgl. z.B. MÖBUS/GÖRICKE/KRÖH 1985, BORTZ/LIENERT/BOEHNKE 1990) oder Markov-Modelle (Überblick bei MÖBUS/NAGL 1983).

⁴) Auf das umfangreiche Feld des Designs von Zeitreihenexperimenten wird genau wie auf das Problem der Verallgemeinerbarkeit von Einzelfallbefunden nicht näher eingegangen (vgl. BARLOW/HERSEN 1984 und FICHTER 1979).

3.1 Trendberechnungen

Polynomregression

Eine verbreitete Form der Beschreibung von Zeitreihen ist die Berechnung von Trends. In der einfachsten Form werden die Parameter a und b einer Regressionsgeraden

$$y_t = ax_t + b$$

aus den Daten nach der *Methode der kleinsten Quadrate* geschätzt. Die Methode der kleinsten Quadrate legt die Parameter einer Funktion so fest, daß die Summe der quadrierten Abstände zwischen Regressionsfunktion und den Daten (Residuensumme) minimal wird. Dies geschieht mathematisch durch die Lösung eines linearen Gleichungssystems mit der Parameteranzahl als Anzahl der Gleichungen.

Auf die prinzipiell gleiche Art und Weise kann man Polynome an die Daten anpassen. Es erhöht sich die Parameteranzahl auf den Wert "Grad des Polynoms + 1". Ein quadratisches Polynom (Polynom 2. Grades) hat beispielsweise drei Parameter a , b , und c :

$$y_t = ax_t^2 + bx_t + c.$$

Zur Polynomregression sind zwei Bemerkungen anzufügen:

- Bei der Bestimmung des Grades des Regressionspolynoms tritt leicht ein Konflikt zwischen Trendberechnung und Interpolation auf. Bei der *Interpolation* wird eine Funktion gesucht, welche die Daten möglichst genau abbildet. Ein Regressionspolynom vom Grad $N-1$ ($N = \text{Datenanzahl}$) durchläuft exakt alle Datenpunkte, hält sich aber zwischen den Datenpunkten und vor allem auch im weiteren Verlauf nicht an die Daten. Der Fragestellung der Regression (dt.: Ausgleichsrechnung) kommen möglichst niedriggradige Polynome entgegen, welche den generellen Verlauf der Daten charakterisieren.

- Polynome sind äußerst ungeeignet zur *Extrapolation* von zeitlichen Prozessen, da sie ab Grad 2 ein ausgesprägtes asymptotisches Verhalten gegen ∞ aufweisen. Auch ein linearer Trend übersteigt bald jede Grenze, was i.a. natürlichen Prozessen nicht eigen ist. Vom Standpunkt der *Modellbildung* sind also generelle Bedenken gegen Polynome als Modelle von Zeitreihen anzuführen. Sie sollten als Beschreibung des generellen Verlaufs der Zeitreihe innerhalb des Datenzitraumes angesehen werden.

Nicht-lineare Trends

Liegen fachliche Argumente dafür vor, daß der Verlauf einer Zeitreihe sich durch eine nicht-lineare (und nicht linearisierbare) mathematische Funktion beschreiben läßt, können deren Parameter durch das Gauß-Newton-Verfahren ermittelt werden. Der entsprechende Algorithmus benötigt die Funktionsgleichung mit den Parametern und die partielle Ableitung der Funktionsgleichung nach den Parametern.

Im Bereich der Trainingswissenschaft haben beispielsweise FUCHS und LAMES (1990) den Geschwindigkeitsverlauf im 100m-Sprint mit zwei überlagerten Wachstumsprozessen modelliert: dem Beschleunigungsprozeß und dem Ermüdungsprozeß. Die Modellfunktion lautet:

$$v(t) = A(1-e^{-\tau t}) + B(1-e^{\mu t}).$$

Für die Parameter A , B , τ und μ können fachliche Interpretationen gegeben werden, z.B. ist τ die Stärke des Beschleunigungsvorganges. Aus der analytischen Funktion können dann weitere interessante Kennwerte des 100m-Laufs berechnet werden (vgl. Abb. 3).

Oft liegen jedoch keine plausibel anwendbaren Modellvorstellungen vor, welche die Formulierung einer mathematischen Funktion zur Beschreibung der Zeitreihe erlauben.

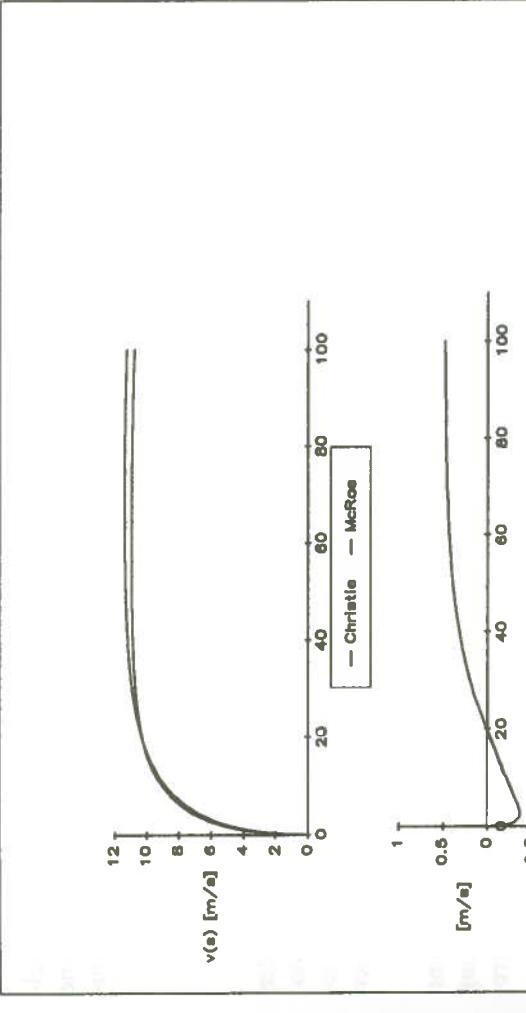


Abb. 3: Geschwindigkeitsverlauf und Geschwindigkeitsdifferenz (untere Grafik) zwischen zwei Vertretern von Sprintertypen: McRae mit hoher Anfangsbeschleunigung und geringerer Maximalgeschwindigkeit und Christie mit geringerer Anfangsbeschleunigung und hoher Maximalgeschwindigkeit (nach FUCHS/LAMES 1990).

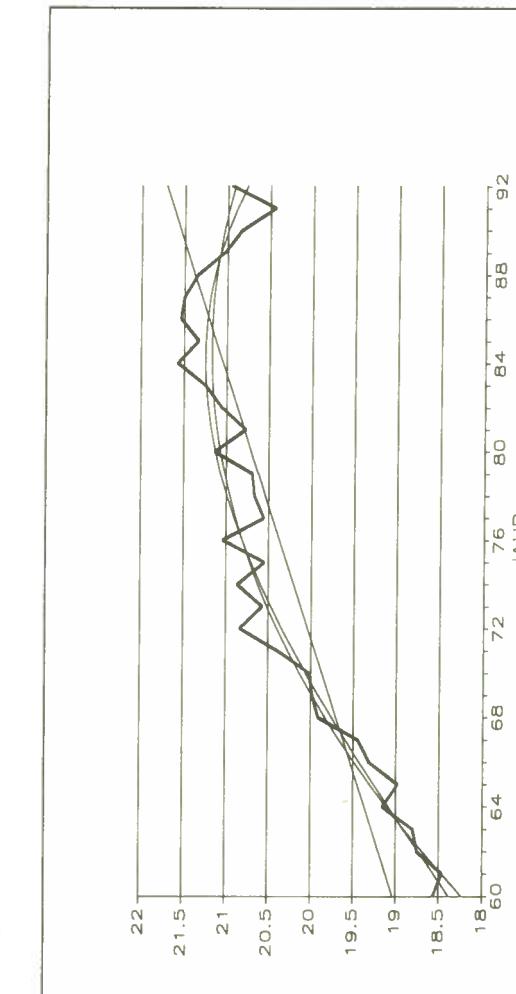


Abb. 2: Polynomregression ersten bis dritten Grades durch den Verlauf der Mittelwerte der ersten 20 Ränge der Kugelstoß-Weltjahresbestenliste von 1960 bis 1992

Gleitende Durchschnitte

Ein weiteres Verfahren zur Glättung von Daten ist das Verfahren der Gleitenden Durchschnitte (Moving Average). Im einfachsten Fall wird statt des Wertes x_t einer Zeitreihe der Mittelwert von x_t und seiner m Nachbarn gebildet. Für $m=2$ ergibt sich das Gleitmittel:

$$y_t = (x_{t-2} + x_{t-1} + x_t + x_{t+1} + x_{t+2}) / 5$$

Das Gleitmittel zeichnet sich durch einen glatteren Verlauf durch die Daten aus, wobei das Ausmaß der Glättung von der Anzahl der ins Gleitmittel einbezogenen Werte abhängt. Eine Glättung der Reihe gelungener und mißlungener 1. Aufschläge im Tennis hängt.

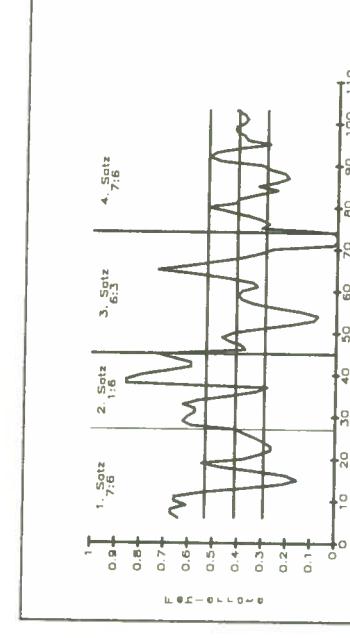


Abb. 4: Gleitmittel der Aufschlagfehlerrate von Becker im US-Open-Finale 1989 (nach LAMES 1992).

3.2 ARIMA-Modelle

Mit der ARIMAs-Methode nach BOX und JENKINS (1976⁵) werden bestimmte serielle Strukturen von Zeitreihen ermittelt und quantitativ erfaßt. Die Methode erlaubt eine Schätzung, inwieweit der Zeitreihe ein stochastischer Prozeß eines gewissen Typs zugrunde liegt.

Zur Modelldiagnostik werden folgende Kenngrößen von Zeitreihen herangezogen:

1. die *Autokorrelation* einer Zeitreihe: Korrelationen zwischen einer Zeitreihe und den um 0, 1, 2, ... Zeittakten (den sog. Lags) verschobenen Werten der Zeitreihe. Die Autokorrelation zum Lag 0 ist die Korrelation der Zeitreihe mit sich selbst, also $r_0=1$. Zu jedem Lag wird die Autokorrelation berechnet. Die Abhängigkeit der Autokorrelationen vom Lag wird durch die Autokorrelationsfunktion (ACF) beschrieben.
2. die *partielle Autokorrelation* einer Zeitreihe: Korrelation zwischen einer Zeitreihe und den um 0, 1, 2, ... Zeittakten verschobenen Werten der Zeitreihe unter Auspartialisierung der dazwischenliegenden Lags ($rp_0=1, rp_1=r_1$). Den Verlauf der partiellen Autokorrelationen über den Lags beschreibt die Partialautokorrelationsfunktion (PACF).

⁵ ARIMA steht für Auto Regressive, Integrated, Moving Average, womit die drei Typen von serieller Abhängigkeit bezeichnet sind, die von BOX/JENKINS (1976) untersucht werden.

Der White-Noise-Prozeß

Der White-Noise-Prozeß ist ein stochastischer Prozeß ohne serielle Strukturen. Er dient im Zusammenhang der ARIMA als Referenzmuster und zur Modelldiagnostik. Ein White-Noise-Prozeß schwankt zufällig um einen Mittelwert (Random Shock). Die Abweichungen vom Mittelwert sind unabhängig und werden meist als $N(0, \sigma^2)$ -verteilt angenommen:

$$x_t = \mu + e_t$$

Dies ist die Grundannahme der klassischen Testtheorie: Die Meßwerte schwanken zufällig um den wahren Wert. Es wäre interessant, diese Annahme mit Mitteln der Zeitreihenanalyse zu überprüfen. Beispielsweise ergaben Analysen von empfindlichen medizinischen Meßgeräten Abweichungen vom White-Noise. Wie steht es um Bewegungsbeurteilungen oder Klausurnoten, um Pulsraten oder Testwiederholungen?

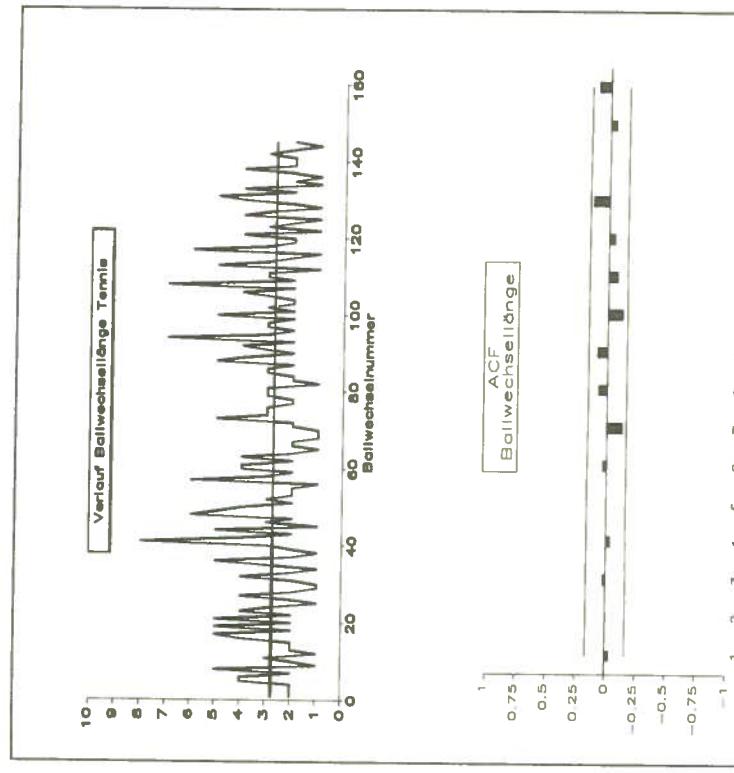


Abb. 5: Verlauf der Ballwechsellänge in einem Tennismatch der Herren in Wimbledon (Stich-Sampas, Viertelfinale 1992). Darunter die typische ACF dieses White-Noise-Prozesses.

Bei einem White-Noise-Prozeß sind die ACF und die PACF nach Lag 0 verschwindend, d.h. Null. Beispiel: In einem Tennismatch weist die Ballwechsellänge gelegentlich keinerlei sequentielle Strukturen auf (vgl. Abb. 5). Dies ist allerdings eher als Ausnahme zu betrachten.

Der Random-Walk-Prozeß

Ein Random-Walk ist ein stochastischer Prozeß, bei dem auf dem gegenwärtigen Stand des Prozesses ein Zufallsexperiment ausgeführt wird, mit dem der nächste Wert ermittelt wird:

$$x_t = x_{t-1} + e_t$$

In einem Wert ist also die gesamte Vergangenheit dieses Prozesses als Summe der früheren Random Shocks enthalten. Beispiel: Der Spielstand in einem Sportspiel wie Volleyball kann als Random Walk aufgefaßt werden: Auf der Basis des gegenwärtigen Spielstandes entscheidet ein Zufallsexperiment über den nächsten Spielstand, ein Spielstand stellt so die Summe aller früheren Zufallsexperimente dar.

Die ACF eines Random Walks hat hohe Werte, die nur wenig mit zunehmendem Lag abnehmen. Die PACF dagegen ist nach Lag 1 identisch Null.

Im Zusammenhang des Random Walks kann ein Grundbegriff der ARIMA-Methode eingeführt werden, die *Stationarität* eines Prozesses: Der Erwartungswert eines Random Walks: $E(x_t) = t E(e)$ ist von Null verschieden und zeitabhängig, wenn der Random Shock einen von Null verschiedenen Erwartungswert hat. Die Varianz eines Random Walk kein stationärer Prozeß ist, denn bei einem (schwach) stationären Prozeß sind Mittelwert und Varianz konstant. Die Stationarität der Prozesse ist Voraussetzung für die Bestimmung serieller Abhängigkeiten. Wenn diese Voraussetzung verletzt ist, kann sie eventuell durch (mehrfache) Differenzierung wieder hergestellt werden. Differenzierung für einen Random Walk ergibt eine Folge von Random Shocks; also White-Noise, dieser ist stationär:

$$\text{Diff}(x_t) = x_t - x_{t-1} = e_t$$

Autoregressive Prozesse

Eine Form der seriellen Abhängigkeit von Zeitreihen liegt dann vor, wenn der aktuelle Wert vom vorangegangenen Wert beeinflußt wird. Solche Prozesse heißen *Autoregressive Prozesse*. Falls genau ein vorangegangener Wert Einfluß ausübt, spricht man von einem Autoregressiven Prozeß erster Ordnung AR(1):

$$x_t = e_t + \Phi_1 x_{t-1}$$

Der aktuelle Wert eines Prozesses kann also sehr ähnlich zur linearen Regression (Name!) aus dem Prozeß zu einem Zeitpunkt vorher und einem White-Noise-Fehlerterm bestimmt werden. Hängt der aktuelle Wert von mehreren (p) Vorgängern ab, so hat man einen Autoregressiven Prozeß der Ordnung p: AR(p).

Charakteristisch für AR-Prozesse ist der asymptotisch abklingende Verlauf der ACF, während die PACF nach genau p Lags verschwindet.

In einem AR(1) steckt also der letzte Zeitpunkt anteilig im gegenwärtigen. Genauso steckt der vorletzte Zeitpunkt im letzten usw. In der autoregressiven Variante der seriellen Abhängigkeit kommt es also zu einer Aufstockung des Einflusses der zurückliegenden Zeitpunkte (vgl. Abb. 6). Der Prozeß hat ein asymptotisch in die Vergangenheit nachlassendes Gedächtnis.

Moving-Average Prozesse

Eine zweite Form der seriellen Abhängigkeit beschreiben *Moving-Average Prozesse*. Hier ist der gegenwärtige Wert vom Random Shock des letzten Wertes abhängig:

$$x_t = e_t - \theta_1 e_{t-1}$$

Hängt der aktuelle Wert von einer Kombination der letzten q Random Shocks ab, so spricht man von einem *Moving-Average Prozeß* der Ordnung q: MA(q).

Die ACF eines MA-Prozesses verschwindet nach genau q Lags. Die PACF klingt asymptotisch ab.

In einem MA(1)-Prozeß steckt also anteilig der Random Shock des letzten Wertes. Darunter wären inhaltlich beispielsweise die Besonderheiten genau des letzten Wertes zu verstehen. Wichtig ist vor allem, daß über den letzten Wert hinaus keine Abhängigkeit vorliegt, da die Random Shocks als unabhängig betrachtet werden (vgl. Abb. 6).

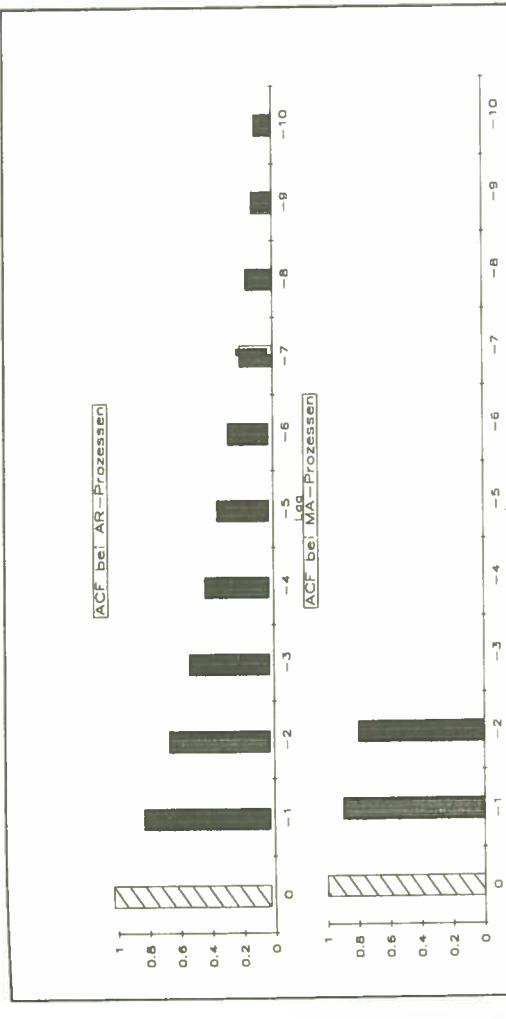


Abb. 6: Vergleich des Einflusses zurückliegender Zeitpunkte auf die Gegenwart in AR- und MA-Prozessen, hier MA(2).

ARIMA (p,d,q)-Modelle

In der Diskussion des Random Walks wurde bereits erwähnt, daß die Bestimmung von seriellen Abhängigkeiten stationäre Prozesse verlangt. Falls die ACF nur langsam abklingt, liegt ein Prozeß vor. Zur Herstellung eines stationären Prozesses genügt es oftmals, die Zeitreihe der Differenzen zu betrachten. Die *Anzahl der Differenzbildung* bis zum stationären Prozeß wird im Parameter d eines ARIMA-Modells ausgedrückt. Auf der Basis dieses stationären Prozesses werden dann die AR- und MA-Komponenten identifiziert. Dabei können diese gleichzeitig auftreten: ARIMA(p,q). In diesem Fall klingen sowohl ACF als auch PACF asymptotisch ab. Zeitreihen mit $p+q>2$ sind allerdings sehr selten. Die Gleichung für einen ARIMA(1,1)-Prozeß lautet:

$$x_t = \Phi_1 x_{t-1} + e_t - \theta_1 e_{t-1}$$

Die Theorie der ARIMA-Prozesse sieht auch eine Erweiterung durch eine saisonale Komponente vor. Die saisonale Komponente in ARIMA-Modellen wird durch den Einfluß der um eine Periode P verschobenen Werte bzw. Random Shocks beschrieben. Übliche Perioden sind 12 bei monatlicher und 7 bei täglicher Datenerfassung. Durch die Beurteilung des Verlaufs von ACF und PACF an diesen Perioden lassen sich evtl. periodische autoregressive oder periodische Moving-Average Prozesse identifizieren. Ein allgemeines ARIMA-Modell mit saisonaler Komponente hat also die Form

$$\text{ARIMA}(\text{p}, \text{d}, \text{q})_1(\text{p}, \text{d}, \text{q})_P$$

Anzeichen für Periodizität sind periodische "Spikes" in der ACF der Residualreihe eines ARIMA(p,d,q). Deren Folge wird dann isoliert betrachtet, um die Modellparameter der zyklischen Komponente zu identifizieren. Aus dieser Vorgehensweise folgt, daß ein Zeitraum von möglichst vielen (mindestens sechs) Perioden zu erfassen ist, um die serielle Struktur der zyklischen Komponente identifizieren zu können.

3.3 Ablauf der Zeitreihenanalyse mit dem ARIMA-Modell

Die Zuordnung einer empirischen Zeitreihe zu einem ARIMA-Modell, also ihre Identifikation als Realisierung eines bestimmten stochastischen Prozesses, ist in der Regel ein iterativer Prozeß. Ein Modell wird identifiziert, die Parameter werden geschätzt und schließlich wird das Modell geprüft. Diese Prüfung kann die Notwendigkeit einer neuen Modellidentifikation nahelegen, wobei mit den nun verbesserten Kenntnissen über die Zeitreihe eine Annäherung an das "wahre Modell" zu erwarten ist. Allerdings kann eine gewisse verbleibende Mehrdeutigkeit nicht ausgeschlossen werden. Beispielsweise können Mehrdeutigkeiten auftreten, weil die ARIMA-Methode nur die eben genannten Typen von stochastischen Prozessen beschreibt, aber viele weitere Typen denkbar sind. Für die einzelnen Ablaufschritte einer Zeitreihenanalyse nach der ARIMA-Methode haben sich einige Standardverfahrensweisen eingebürgert.

Modellidentifikation

Zunächst wird die Zeitreihe grafisch inspiziert. Ausreißer, Trends und Zyklen lassen sich häufig schon auf diese Weise erkennen (vgl. Abb. 7). Das Verlaufsmuster von ACF und PACF der stationären Zeitreihe wird auf Übereinstimmung mit den Mustern der gängigen Modelle geprüft. Anhaltspunkte liefern die Konfidenzgrenzen für Autokorrelationen und partielle Autokorrelationen, welche "bedeutsame" Lags markieren. Anhand des empirischen Musters sollte ein ARIMA-Modell vorläufig identifiziert werden können.

Dann wird die ACF der Originalreihe betrachtet und bei nicht abklingenden Autokorrelationen zur (mehrfachen) Differenzbildung bis zur Stationarität gegriffen (vgl. Abb. 8).

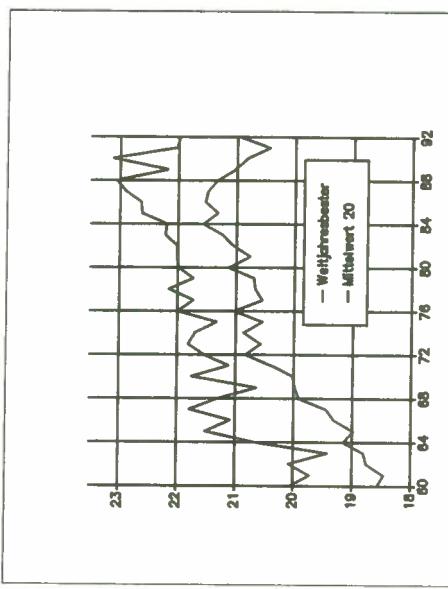


Abb. 7: Verlauf des Weltbesten und des Mittelwertes der 20 Weltbesten im Kugelstoßen der Männer. Man erkennt einen hoch autokorrierten Verlauf sowie Zyklen mit Höhepunkten in den Olympiajahren. Im folgenden wird die Zeitreihe der Mittelwerte der 20 Weltbesten (im folgenden "Originalreihe") analysiert.

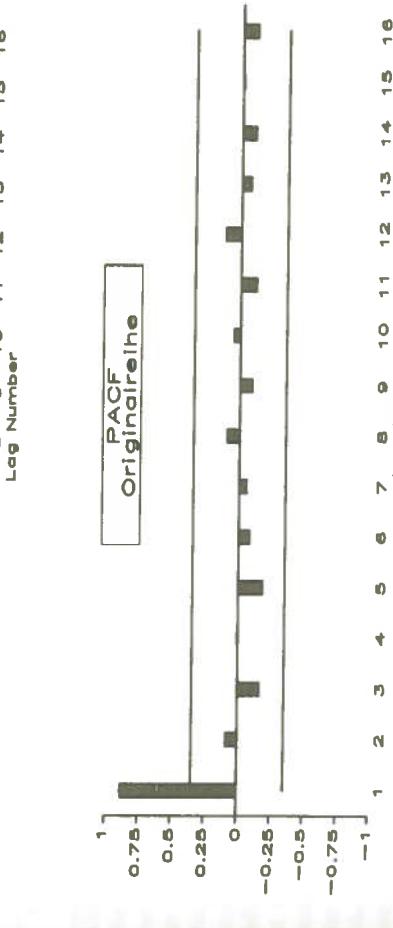
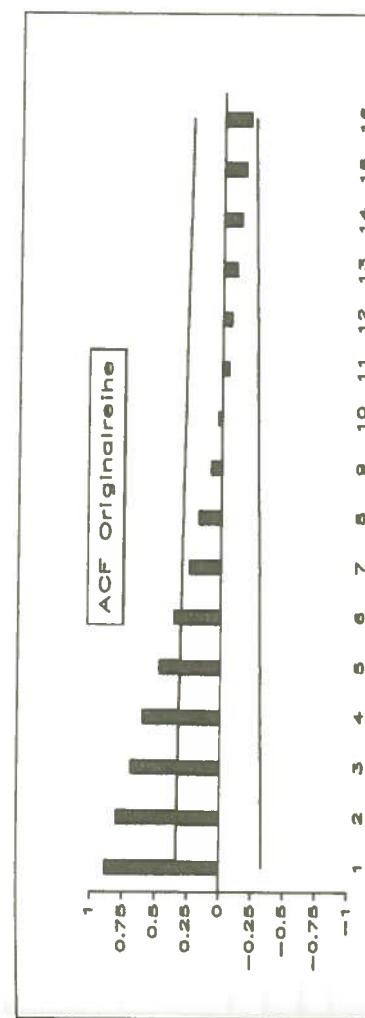


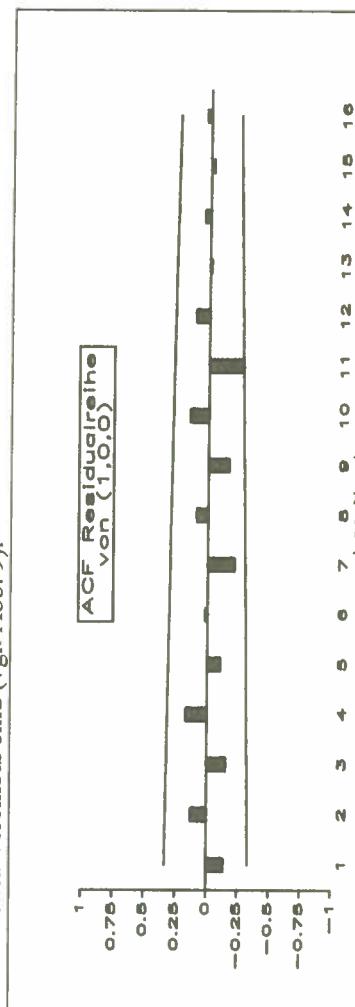
Abb. 8: ACF und PACF der Originalreihe. Die ACF weist einen abklingenden Verlauf auf, während die PACF nach Lag 1 insignifikant ist. Damit muß die Reihe nicht differenziert werden, und das Muster von ACF und PACF erlaubt die Identifikation eines AR(1)-Prozesses, d.h. ARIMA(1,0,0).

Parameterschätzung

Die umfangreichen Rechnungen zur Parameterschätzung von ARIMA-Prozessen werden in der Praxis von Computerprogrammen ausgeführt. Es handelt sich um die iterative Lösung von Gleichungssystemen, z.B. den Yule-Walker-Gleichungen für Autoregressive Prozesse. Erst die Fortschritte in der Rechentechnik ermöglichen den breiten Einsatz der Zeitreihenanalyse. Dies hat auch Einfluß auf das Verfahren der Modellidentifikation. Es ist beispielsweise möglich und verbreitet, induktiv vorzugehen, indem für eine ganze Reihe der üblichen Modelle die Parameter geschätzt werden. Anschließend kann jeweils eine Modelldiagnose vorgenommen werden.

Modelldiagnose

Wenn ein Modell hinreichend gut die serielle Abhängigkeit in den Daten beschreibt, dann sollten die Residuen einen White-Noise-Prozeß bilden, d.h. keinerlei serielle Abhängigkeit mehr aufweisen. Um dies zu prüfen, werden ACF und PACF der Residuen auf Abweichungen von Nullkorrelationen getestet. Dies geschieht mit dem Ljung-Box-Q-Test, der pro Lag angibt, ob die bisher aufgetretenen Korrelationen mit einem White-Noise Prozeß vereinbar sind (vgl. Abb. 9).



Die in der *Parameterschätzung* erhaltenen Parameter werden auf Signifikanz geprüft (vgl. Abb. 10). Zusätzlich müssen sie in gewissen Bereichen liegen (Stationaritäts- bzw. Invertierbarkeitsbereiche).

Durch ein systematisches *Overfitting*, also der Schätzung eines Modells mit zu vielen Parametern, kann die Wahl eines Modells erhärtet werden, wenn seine Parameter auch "overfitted" stabil bleiben, wenn keine signifikanten Parameter hinzukommen und sich die Anpassungsgüte nicht wesentlich verbessert (vgl. Abb. 10).

Durch den Vergleich der *Anpassungsgüte* kann unter mehreren Modellen eine Auswahl treffen werden. Verschiedene Kriterien für die Anpassungsgüte kommen in Frage, die alle mit der Quadratsumme der Residuen arbeiten. Sie unterscheiden sich lediglich in ihrer Adjustierung an die Anzahl der Parameter und an die Länge der Zeitreihe. Die bekanntesten sind: AIC (Akaike Information Criterion), BIC (Bayes Information Criterion) oder auch SBC (Schwarz-Bayes Criterion) genannt (vgl. Abb. 10) sowie das HQ (Hannan-Quinn-Kriterium). In der Praxis unterscheidet sich ein Kriterium für verschiedene Modelle oft nur minimal, sodaß durch den alleinigen Vergleich der Anpassungsgüte keine eindeutige Lösung des Identifikationsproblems zu erwarten ist.

Modell	AIC	SBC	Parameter	Sign.
1,0,0	20,6	23,6	ARI: 0,96	ss
1,1,0	11,7	14,6	ARI: -,37	s
1,2,0	19,7	22,6	ARI: -,71	ss
2,0,0	20,2	24,6	ARI: -,69	ss
			AR2: -,28	ns
2,1,0	10,9	15,3	ARI: -,28	ns
			AR2: -,30	ns
2,2,0	20,8	25,1	ARI: -,95	ss
			AR2: -,19	ns

Modell	AIC	SBC	Parameter	Sig.
(1,0,0)(0,1,0) ₄	11,6	14,3	ARI: -,66	ss
(1,0,0)(1,0,0) ₄	11,5	16,0	ARI: -,92	ss
(1,0,0)(1,1,0) ₄	10,2	14,3	ARI: -,89	ss
			ARZ: -,37	ns

Abb. 10: Ergebnisse der Berechnung mehrerer ARIMA-Modelle (Overfitting) für die Original-Zeitreihe. Die obere Tabelle zeigt Resultate für die Zeitreihe ohne saisonale Komponente. Hier wurde trotz der numerisch besseren Anpassung von ARIMA(1,1,0) wegen des Musters von ACF und PACF (vgl. Abb. 8) für ARIMA(1,0,0) entschieden. Die deutliche Verbesserung der Anpassungen in der unteren Tabelle für die saisonalen ARIMA-Modelle gegenüber der oberen unterstützt die Wahl eines saisonalen Modells. Die verschiedenen saisonalen Modelle sind unter sich nahezu gleichwertig, was sicherlich auch durch die Kürze der Zeitreihe verursacht ist. Die Zeitreihe wurde als ARIMA (1,0,0)(1,0,0)4 identifiziert, da hier ein signifikanter saisonaler Parameter ARZ (der autoregressive Parameter in der zyklischen Komponente) vorliegt. Das Beispiel zeigt anschaulich, daß die Identifikation eines ARIMA-Modells keinesfalls eine algorithmische Vorgehensweise erlaubt ("Kochbuch-Methode"), sondern daß sie erst durch die Verbindung von methodischen und fachlichen Kenntnissen gelingen kann.

Abb. 9: ACF der Residualreihen der ARIMA-Modelle (1,0,0) und (1,0,0)(1,0,0)4. In der oberen ACF treten periodische Spikes auf, was die Einführung einer saisonalen Komponente nahelegt. In der Residualreihe des saisonalen Modells liegen offensichtlich keinerlei serielle Strukturen mehr vor, da die ACF das typische Muster eines White-Noise-Prozesses aufweist.

3.4 Multivariate Methoden

Während univariante Zeitreihenanalysen vorwiegend beschreibenden Charakter haben, können mit multivariaten Analysen auch Erklärungen geprüft werden. Dabei kann man allgemein zwischen den Fällen einer kontrollierten Intervention, der Analyse der Kovation zweier Zeitreihen und der Transferfunktionsanalyse unterscheiden.

Interventionsanalyse

Zur Interventionsanalyse existieren unterschiedlich komplexe Verfahren (vgl. z.B. MÖBUS/NAGL 1983, SCHMITZ 1989 und REVENSTORF/KEEESER 1979). An dieser Stelle soll lediglich eine einfache Variante vorgestellt werden, welche Interventionsanalysen mit verbreiteten Programmpaketen erlaubt.

Bei der Spezifikation von Interventionen ist zu unterscheiden zwischen der *Intervention selbst* und der *Interventionswirkung*. Die Intervention im klassischen Superkompensationsmodell stellt beispielsweise ein einmaliger Belastungsreiz dar. Die Reaktion des Organismus, also die Interventionswirkung, besteht jedoch in einer komplizierten Gleichgewichtsreaktion. In konventionellen Interventionsanalysen, wie hier geschildert, wird die *Interventionswirkung* modelliert.

Diese Modellierung geschieht durch sogenannte "Dummy-Variablen", die als "Kovariate" in die Parameterschätzung eines ARIMA-Modells eingegeben werden. Mit einer oder mehreren Dummy-Variablen kann die als Folge der Intervention erwartete Wirkung beschrieben werden. Verbreitete Modelle für Interventionswirkungen sind z.B. Stufen, d.h. der Prozeß wird auf einem anderen Niveau fortgesetzt, Rampen, d.h. der Prozeß nimmt allmählich ein neues Niveau an, oder kompliziertere Wirkungen.

Zur Berechnung der Interventionswirkung muß ein ARIMA-Modell spezifiziert werden, das ohne die Intervention die Zeitreihe beschreiben würde. Diese sog. Baseline wird in der Regel aus der Analyse des Präinterventionszeitraumes erhalten. Die Parameterschätzung mit diesem ARIMA-Modell und dem Modell der Interventionswirkung ergibt neben den ARIMA-Parametern auch eine quantitative Schätzung der Interventionswirkung. Mit Hilfe der Anpassungsmaße (s.o.) können verschiedene Interventionsmodelle bezüglich ihrer Aussagekraft verglichen werden (vgl. Abb. 11).

Parameter	Wert	Std.abw.	T-Wert	Sign.
AR1	-0.84	.11	7.96	.000
DOPE_IN	1.95	.33	5.98	.000
DOPE_OUT	-0.48	.35	-1.39	.176
CONSTANT	18.98	.28	67.60	.000

Abb. 11: Parameterschätzung für eine Interventionsanalyse der Kugelstoß-Zeitreihe (saisonbereinigte Daten). Die Dummy-Variable "Dope_in" modelliert die Wirkung einer Intervention in der Gestalt einer Rampe von 1966 bis 1972 und "Dope_out" diejenige einer Rampe von 1988 bis 1992. Die Baseline wurde im Beispiel durch die Zeitreihe zwischen 1972 und 1988 geschätzt, da kein hinreichender Präinterventionszeitraum gegeben ist.

Es ergibt sich ebenfalls ARIMA (1,0,0) mit einem AR(1)-Koeffizienten von $\Phi_1=0.93$.

Im Interventionsmodell ist $\Phi_1=-0.84$. Die Anpassungsgröße ist verbessert, das SBC sinkt von 0.52 für das Ausgangsmo-

dell auf -4.75. Es ergibt sich eine hoch signifikante Interventionswirkung von Dope_in, die einen Zu-

wachs von 1.95 (Metern) ausmacht. Dope_out beschreibt einen Leistungsrückgang um 0.48 (Meter), der allerdings nicht signifikant ist (möglichlicherweise nur wegen der Kürze der Interventionswirkung).⁶

Kreuzkorrelationen

Der Zusammenhang zwischen zwei Zeitreihen wird durch die sog. Kreuzkorrelationsfunktion (CCF) beschrieben. Diese enthält die zeitversetzten Korrelationen zwischen den Zeitreihen, also die Korrelationen zwischen den Lags und Leads einer Variablen und der anderen. Der zeitversetzte Zusammenhang bietet die Möglichkeit einer Interpretation im Sinne von Ursache und Wirkung. Eine notwendige Bedingung, um eine Variable als Ursache einer anderen zu identifizieren, ist ihr zeitliches Vorlaufen. Dies drückt sich in signifikanten Kreuzkorrelationen der abhängigen Variablen mit Lags der unabhängigen aus. Läuft sie dagegen der abhängigen Variablen hinterher (signifikante "Leads"), so kann die Ursache-Wirkungs-Interpretation kaum aufrecht erhalten werden (vgl. Abb. 12).

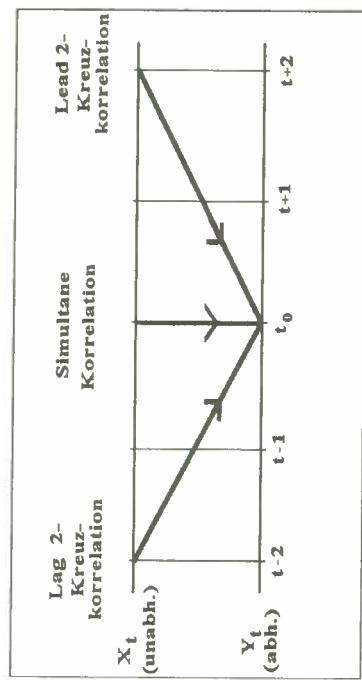


Abb. 12: Illustration von Kreuzkorrelationen

Zwar liefern Kreuzkorrelationen recht anschauliche Informationen über das gemeinsame Kovariieren zweier Zeitreihen, aber es tritt der Effekt auf, daß die Höhe der Kreuzkorrelationen von der internen Zeitreihenstruktur der einzelnen Zeitreihen abhängt. Dies ist plausibel, da beispielsweise eine hoch autokorrierte Zeitreihe in benachbarten Kreuzkorrelationen ähnliche Werte aufweisen wird. Als Verfahren, mit dem man dieser Überhöhung begegnen kann, wird das sog. "Prewhiting" angegeben. Es werden nun nicht mehr die Originalzeitreihen kreuzkorriert, sondern die "vorgeweißten", d.h. die Residualreihen der beiden Zeitreihen.

Die Probleme des Prewhitings sind von SCHMITZ (1989) aufgelistet worden. Neben technischen Problemen, wie etwa der Unsicherheit bei der Erstellung der Residualreihen und die in der Regel unbedeutenden Kreuzkorrelationen zwischen Residualreihen, ist vor allem die inhaltliche Bedeutung des Prewhitings unklar. Falls die hohe Autokorrelation einer der Zeitreihen erst durch die Kreuzkorrelation mit der anderen Variablen entsteht, ist Prewhiting nicht gerechtfertigt. Es liegen hier ähnliche Verhältnisse wie in der schrittweisen Multiplen Regression vor, in der später einbezogene Variablen nur noch mit ihrer zusätzlichen Varianzaufklärung eingehen.

⁶ Mit diesem Beispiel soll lediglich eine Interventionsanalyse demonstriert werden. Inhaltlich ist dieses Vorgehen als ex-post-facto zu kritisieren. Die Bezeichnungen der Interventionen sind bewußt einfachplakativ gehalten.

Transferfunktionsmodelle

Problematisch am oben geschilderten Vorgehen der Interventionsanalyse ist die Annahme, daß die Interventionswirkung zumindest modellhaft bekannt ist. Liegen jedoch zwei Zeitreihen vor, von denen die eine den Verlauf einer unabhängigen Variablen X_t und die andere den Verlauf einer abhängigen Variablen Y_t beschreibt, so kann die zeitverzögerte Wirkung von X auf Y durch ein sog. Transferfunktionsmodell empirisch bestimmt werden (vgl. MÖBUS/NAGL 1983, 268ff).

Dazu wird die abhängige Zeitreihe Y_t aus einem Anteil, der auf die Wirkung der Variablen X_t zurückgeht (Y_t^*), und einem Rest-ARIMA-Prozeß (N_t) zusammengesetzt angenommen:

$$Y_t = Y_t^* + N_t = f(X_t) + N_t$$

Aufgabe der Transferfunktionsanalyse ist es nun, den Einfluß der Variablen X auf die Variable Y zu schätzen, indem die Transferfunktion bestimmt wird. Dazu werden zuerst aus den Komponenten des obigen Transfermodells die autokorrierten Anteile von X "herauspartialisiert", indem man sie mit dem Filter, der die Zeitreihe X_t in ihre unkorrierte Residualreihe überführt, vorweift. Nun werden die Kreuzkorrelationen zwischen den vorgeweiteten Zeitreihen von X_t und des Transfermodells berechnet und mit ihnen das Transfermodell identifiziert. Es umfaßt Parameter n_k , welche spezifizieren, mit welchem Gewicht das Lag k Einfluß nimmt.

Die beschriebene Methode zeichnet sich durch die empirische Bestimmung der Wirkung einer unabhängigen Zeitreihe aus. Diese sehr vielversprechende Methode ist leider noch nicht im Umfang der Standardsoftware für Zeitreihenanalysen enthalten.

3.5 Spektralanalyse

Während man sich bei den bisher geschilderten Formen der Zeitreihenanalyse im "Zeitbereich" bewegte (vgl. die Definition von Zeitreihen zu Beginn), können Zeitreihen auch im "Frequenzbereich" beschrieben werden, womit sich die Spektralanalyse befaßt (vgl. SCHLITTGREN/STREITBERG 1984). Der mathematische Hintergrund ist die Fourier-Transformation, die es erlaubt, jede Funktion⁷ oder Folge als Reihe von harmonischen Sinus- und Cosinusschwingungen aufzufassen:

$$f(x) = \sum_{j=1}^{\infty} a_j \sin jx + \sum_{j=1}^{\infty} b_j \cos jx$$

Aus dieser Zerlegung wird die Spektraldichte einer Zeitreihe gewonnen, welche über allen harmonischen Frequenzen deren Intensität abbildet. Der Wertebereich der Spektraldichte ist das Intervall von Null bis 0.5. Diese Frequenzen entsprechen Perioden der Länge ∞ , also konstante Terme, bis Perioden der Länge 2, was der kleinstmöglichen Periode bei diskreten Zeitintervallen entspricht.

Zerlegt man statt eines mathematisch definierten stochastischen Prozesses eine empirisch gewonnene Zeitreihe, so erhält man das *Periodogramm* der Zeitreihe. Das Periodogramm ist nur an den Stellen $1/N, 2/N, \dots$ definiert. Die kleinstmögliche Frequenz $1/N$ beschreibt eine Schwingung mit Periode N , also über die gesamte Zeitreihe hinweg. Aus

⁷Genauer: jede stetige Funktion mit endlicher Anzahl von Maxima und Minima auf einem beliebigen, abgeschlossenen Intervall.

einem Periodogramm lassen sich beispielsweise Hinweise auf die zugrundeliegenden stochastischen Prozesse durch einen Vergleich mit deren Spektraldichte gewinnen.

Es besteht eine Dualität zwischen Spektraldichte und ACF. Beide sind ineinander überführbar. Gewisse Sachverhalte sind in Periodogrammen besser erkennbar, insbesondere natürlich die zyklische Struktur der Zeitreihe, die sich in "Peaks" im Periodogramm ausdrückt. Die Spektralanalyse drängt sich also zur Analyse von Zeitreihen dann auf, wenn hauptsächlich deren periodische Eigenschaften Gegenstand des Interesses sind (vgl. Abb. 13).

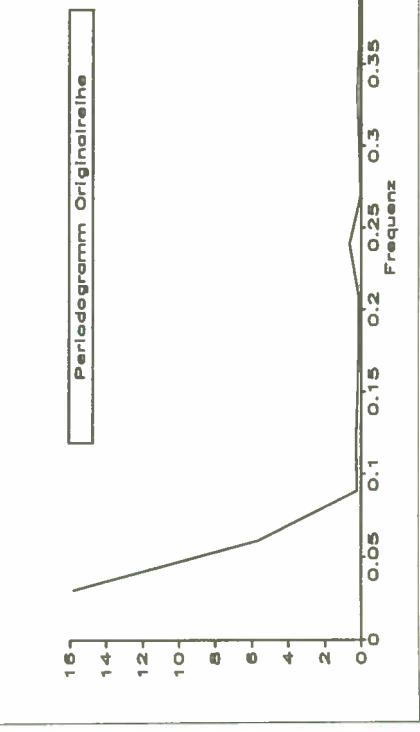


Abb. 13: Periodogramm der Original-Zeitreihe. Es dominiert die niedrigste Frequenz, was einer Schwung über den gesamten Datenzzeitraum gleichkommt und typisch für hoch autoregressive Prozesse ist. Das Auf-und-Ab der gesamten Zeitreihe ist also im Frequenzbereich ihre auffälligste Eigenschaft. Weit weniger auffällig sind die Schwierungen mit der höchsten Frequenz, also einer zweijährigen Periode. Damit drückt sich ein Auf-und-Ab von Saison zu Saison aus, für das es im Zeitbereich zwar einige Hinweise gibt, das aber dort nicht vergleichbar deutlich wurde. Die dritte Auffälligkeit ist ein lokales Intensitätsmaximum bei etwa 0.25, was mit Periode 4 sehr schön als Olympiazzyklus identifiziert werden kann.

Der periodische Zusammenhang zwischen zwei Zeitreihen läßt sich durch sog. Kreuzspektren beschreiben, auf die hier nicht weiter eingegangen werden soll (vgl. SCHLICHT/JANSSEN 1990 und SCHLITTGREN/STREITBERG 1984).

4. Probleme des Einsatzes von Zeitreihenanalysen

4.1 Praktische Probleme bei der Durchführung

Die Zeitreihenanalyse stellt ein elaboriertes Werkzeug zur Charakterisierung von Zufallsprozessen in der Zeit dar. Im konkreten Umgang mit ihr stellen sich jedoch meist einige Probleme ein, die im folgenden kurz aufgelistet sind:

Die Anforderungen der Zeitreihenanalyse an die Daten sind recht anspruchsvoll. Damit ist einmal die relativ *große Anzahl von Meßzeitpunkten* gemeint, die für eine zuverlässige ARIMA-Modellierung nicht unter 50 liegen sollte und für Kreuzkorrelationen und Kreuzspektren etwa bei 100 liegt. Die zur Illustration der Zeitreihentechniken begleitend analysierte Kugelstoß-Zeitreihe erfüllt also beispielweise nicht diese Bedingung ($N=33$).

Zusätzlich müssen die Datenpunkte noch *äquidistant* sein, womit allerdings eine Ereignis-Äquidistanz gemeint ist und nicht etwa eine strikte zeitliche Äquidistanz. Bei-

spielsweise wird der Verlauf der Börsenkurse an den Börsentagen und nicht an allen aufeinanderfolgenden Tagen betrachtet.

Diese Forderungen stellen für Zeitreihen in der Trainingswissenschaft ernsthafte Probleme dar. Der Verlauf der komplexen Leistungsfähigkeit eines 800m-Läufers kann kaum durch tägliche 800m-Läufe ermittelt werden! Ähnliches gilt für den Verlauf von Ausdauer- und Kraftfähigkeiten. Auch im Bereich der Analyse von Zeitreihen aus dem Wettkampfverhalten treten Limitierungen auf, etwa wenn der Aufschläger wechselt oder ungenügende Anzahlen von Ereignissen auftreten.

Ein weiteres Problem der Zeitreihenanalyse sind *Mehrdeutigkeiten bei der Modellidentifikation*. Es existieren mehrere Kriterien, die durchaus zu widersprüchlichen Befunden führen können. Der angemessene Umgang mit dieser Problematik setzt eine gewisse Erfahrung mit dem Verfahren voraus.

Die Theorie der Zeitreihenanalyse ist mathematisch recht anspruchsvoll, was sie allerdings mit den meisten "höheren" statistischen Verfahren teilt. Lehrbücher der Zeitreihenanalyse tragen das Handicap, daß sich die Theoriebildung der Zeitreihenanalyse noch im Fluss befindet. Ältere Lehrbücher verzeichnen einige neuere Entwicklungen noch nicht, und bei neueren hat sich noch kein didaktischer Standard entwickelt.

Das zur Verfügung stehende Spektrum an zeitreihenanalytischen Verfahren wird in der Praxis vollständig von dem Programm (den Programmen) determiniert, das zur Auswertung herangezogen werden kann. Die gegenwärtigen Statistikpakete für den PC-Bereich lassen immer noch einige Wünsche offen, was den Programmumfang angeht. Frühere Probleme mit der Rechenzeit dürften allerdings immer weniger auftreten. Überblicke über Zeitreihenanalyseprogramme bieten SCHLICHT/JANSEN (1990) und STRAUSS/STEMMLER (1985). Diese Überblicke entbinden jedoch nicht von eigenen Erkundungen, da die Entwicklung rasch voranschreitet.

4.2 Zeitreihenanalyse als Modellbildungsprozeß

Auf ein wichtiges Problem der Zeitreihenanalyse wird auch in ihren Lehrbüchern kaum hingewiesen. Dort wird im wesentlichen das Problem behandelt, aus einer empirischen Zeitreihe auf den zugrundeliegenden stochastischen Prozeß zu schließen. Was bedeutet es aber nun für den realen Prozeß, wenn eine Zeitreihe als Realisierung eines gewissen stochastischen Prozesses identifiziert wurde?

Diese Frage berührt das Problem der zugrundeliegenden Modellbildung in Zeitreihenanalysen. In ihren Ursprüngen, etwa im ökonometrischen Bereich, existieren möglicherweise unmittelbar Theorien über die Natur der stochastischen Prozesse, die ökonomischen Phänomenen zugrunde liegen. Beispielsweise sollte sich ein funktionierender Aktienmarkt in einem Random-Walk-Prozeß der Aktienkurse ausdrücken. Im Bereich der Trainingswissenschaft liegen jedoch kaum entsprechende Theorien vor. Aus diesem Grund muß der Modellbildungsprozeß einer Zeitreihenanalyse um die Komponente des realen Prozesses erweitert werden (vgl. Abb. 14).

Im konkreten Ablauf ist zu spezifizieren, was die Befunde des ARIMA-Modells im realen Prozeß bedeuten! Man kann zwar den Lehrbüchern vorwerfen, nicht genügend auf diese Problematik hinzuweisen, aber die fachliche Interpretation der Befunde ist Aufgabe des Anwenders der Zeitreihenanalyse. Wenn sie nicht gelingt, macht die Anwendung des Verfahrens wenig praktischen Sinn. SCHLICHT (1988) erwähnt diesbezügliche Defizite in der Psychologie, wenn er zu AR- und MA-Prozessen bemerkt: "Eine unmittelbare psychologische Interpretation der Prozesse fällt schwer". Er zitiert REVENSTORF und

KEESEER (1979), die sehr knapp (und irreführend! d. Verf.) MA-Prozesse als homöostatische und AR-Prozesse als Wachstumsprozesse beschreiben.

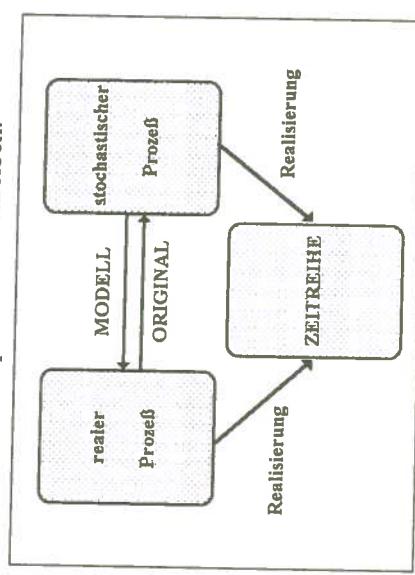


Abb. 14: Schematische Darstellung der Komponenten des Modellbildungsprozesses bei einer Zeitreihenanalyse

In der ARIMA-Analyse des Verlaufes von Ballwechsellängen im Tennis versucht LAMES (1992), mögliche Interpretationen der Parameter p , d und q zu geben. Zunehmende oder abnehmende Trends in der Ballwechsellänge werden als ermüdungsbedingte Änderungen der Spielanlage interpretiert. Eine AR-Komponente deutet einen aufgestockten Ermüdungseinfluß der letzten Ballwechsel an, während MA-Komponenten einen Einfluß der Verarbeitung genau der letzten q Ballwechsel bedeuten.

Ähnliche Interpretationsversuche müssen auch für andere Fragestellungen angestellt werden, wenn ein inhaltliches Interesse an der ARIMA-Modellierung besteht. Die Relationen zwischen realem Prozeß und identifiziertem stochastischem Prozeß muß geklärt werden, wenn aus dem Einsatz der Zeitreihenanalyse zur Modellierung von realen Prozessen Nutzen gezogen werden soll.

Literatur

- BARLOW, D.N./HERSEN, M.: Single Case Experimental Designs. New York 1984².
- BEREITER, C.: Some persisting dilemmas in the measurement of change. In: HARRIS, C.W.(Ed.): Problems in Measuring Change. Madison, Mi./London 1963, 3-20.
- BORTZ, J./LIENERT, G.A./BOEHNKE, K.: Verteilungsfreie Methoden in der Biostatistik. Berlin 1990.
- BOX, G.E.P./TIAO, G.C.: Intervention Analysis with Applications of Economic and Environmental Problems. In: Journal of the American Statistical Association 70(1975), 70-79.
- BOX, G.E.P./JENKINS, G.M.: Time-Series Analysis: Forecasting and control. San Francisco 1976³.
- FICHTER, M.M.: Versuchsplanung experimenteller Einzelfalluntersuchungen in der Psychotherapieforschung. In: PETERMANN, F./HEHL, F.-J.(Hrsg.): Einzelfallanalyse. München/Wien/Baltimore 1979, 140-158.
- FUCHS, P./LAMES, M.: Mathematische Modellierung des Wettkampfverhaltens im Sprint. In: Leistungssport 20(1990), 35-41.
- GLASS, G.G./WILLSON, V.L./GOTTMAN, J.M.: Design and Analysis of Time-Series Experiments. Boulder, Co. 1975.

- HAASE, H.: Einführung in die Forschungsmethoden der Sportpsychologie. In: BALLREICH, R., u.a.(Hrsg.): Trainingswissenschaft Bd. 1. Bad Honburg 1982, 135-244.
- HOHMANN, A.: Zur Analyse zeitlich verzögter Trainingseffekte im Sportspiel. In: Leistungs-sport 18(1985), 32-37.
- KENDALL, M.: Time-Series. London 1976.
- LAMES, M.: Zum Problem der Stabilität von Wettkampfverhalten im Sportspiel Tennis. In: HAGEDORN, G./HEYMEN, N.(Hrsg.): Methodologie der Sportspielforschung. Ahrens-burg 1992, 31-41.
- LAMNEK, S.: Qualitative Sozialforschung. Band 2: Methoden und Techniken. München 1989.
- MÖBUS, C./GÖRICKE, G./KRÖH, P.: Parametrische und nichparametrische Methoden der Einzelfallstatistik. In: APPELT, H./STRAUSS, B.(Hrsg.): Ergebnisse einzelfallstatistischer Untersuchungen in Psychosomatik und klinischer Psychologie. Berlin/Heidelberg/ New York/Tokyo 1985, 170-188.
- MÖBUS, C./NAGL, W.: Messung, Analyse und Prognose von Veränderungen. In: BREDENKAMP, J./FEGER, H.(Hrsg.): Hypothesenprüfung. Göttingen/Toronto/Zürich 1983, 239-470.
- PETERMANN, F./HEHL, F.-J.(Hrsg.): Einzelfallanalyse. München/Wien/Baltimore 1979.
- PETERMANN, F.: Einzelfalldiagnose und klinische Praxis. Stuttgart/Berlin/Köln/Mainz 1982.
- PETERMANN, F.: Veränderungsmessung. Stuttgart/Berlin/Köln/Mainz 1978.
- REVENSTORF, D./KEESER, W.: Zeitreihenanalyse von Therapieverläufen - ein Überblick. In: PETERMANN, F./HEHL, F.-J.(Hrsg.): Einzelfallanalyse. München/Wien/Baltimore 1979, 183-228.
- SCHLICHT, W./JANSSEN, J.-P.: Der Einzelfall in der empirischen Forschung der Sportwissen-schaft: Begründung und Demonstration zeitreihen-analytischer Methoden. In: Sportwissen-schaft 20(1990)3, 263-280.
- SCHLICHT, W.: Einzelfallanalyse im Hochleistungssport. Schorndorf 1988.
- SCHLICHT, W./LAMES, M.: Wissenschaft und Technologie. Ideen zu einer Forschungskon-zepition in der Trainingswissenschaft. In: MARTIN, D./WEIGELT, St.(Hrsg.): Trainings-wissenschaft - Selbstverständnis und Forschungsansätze. Sankt Augustin 1993, 78-94.
- SCHLITZEN, R./STREITBERG, B.H.: Zeitreihenanalyse. München/Wien 1984.
- SCHMITZ, B.: Einführung in die Zeitreihenanalyse. Bern/Stuttgart/Toronto 1989.
- SPSS Inc.: SPSS-X Trends. Chicago, Il. 1988.
- STRAUSS, B./STEMMLER, G.: Praktische Probleme bei der Anwendung von Zeitreihenanaly-sen. In: APPELT, H./STRAUSS, B.(Hrsg.): Ergebnisse einzelfallstatistischer Untersu-chungen in Psychosomatik und klinischer Psychologie. Berlin/Heidelberg/New York/Tokyo 1985, 139-155.

Hinweis: Zu diesem Beitrag finden Sie auf S.109f ein Interpretorial sowie ein Glossar.

Sport und Europa

Vom Wandel der Strukturen und des Bewußtseins im neuen Europa¹

Das Thema "Sport und Europa" ist spätestens seit der Einführung des europäischen Binnenmarktes am 1. Januar 1993 aktuell geworden. Der folgende Beitrag beschäftigt sich mit dem Stand der gegenwärtigen Diskussion im Hinblick auf den Sport in diesem "neuen" Europa. Der schwierige Weg zum euro-päischen Binnenmarkt, die bisherige Rolle des Sports darin sowie die aktuelle Lage werden dargestellt und bewertet; einige Gedanken zu zukünftigen Notwendigkeiten schließen sich daran an.

Summary

With the start of the Single European Market on the 1st January 1993 "Sport and Europe" has become an actual topic. The following article reflects the present state of discussion concerning sport in the "new" Europe. The difficulties on the way to the Single European Market and the former and present role of sport within this market are discussed as well as the evaluation of this situation and some future aspects and necessities.

1. Vorbermerkung

So klar und eindeutig das Thema klingt, so schwierig, sprich: vielschichtig, oft schwer nachvollziehbar und zum Teil auch verwirrend, stellt es sich dar. Dies wird jedem sehr deutlich, der versucht, etwas über den Wandel der Strukturen und des Bewußtseins im nationalen Sportorganisations und Regierungen, die Sportwissenschaften, die Eu-ropäische Gemeinschaft, das Europäische Parlament, der Europarat und die internationa-ler europäischen Sportorganisationen und -zusammenschlüsse ebenso beteiligen wie letztlich auch die sporttreibenden Bürger.

Der folgende Artikel beschäftigt sich damit, wie sich die Lage des Sports im neuen Eu-ropa gegenwärtig darstellt, was sich verändert hat und was sich voraussichtlich dem-nächst verändern wird. In erster Linie wird auf die Situation eingegangen, die sich durch die Einführung des Europäischen Binnenmarktes ergeben hat. Über die Folgen dieses

¹ Der vorliegende Artikel basiert auf dem Material eines Vortrages auf dem 3. Symposium der Deutschen Olympi-schen Gesellschaft „Sport auf neuen Wegen. Rendezvous Europa - Sport verbindet“ vom 18.-20.10.1993 in Saar-brücken.