

**EIN ZEITREIHENMODELL
FÜR DIE ÖSTERREICHISCHE WIRTSCHAFT**

Robert Kunst

Forschungsbericht/
Research Memorandum No. 211

März 1985

Die in diesem Forschungsbericht getroffenen Aussagen liegen im Verantwortungsbereich des Autors und sollen daher nicht als Aussagen des Instituts für Höhere Studien wiedergegeben werden.

ZUSAMMENFASSUNG

Die Untersuchung von Zeitreihenmodellen für ökonomische Daten stellt eine faszinierende Aufgabe für den ökonometrischen Modellbau dar. Diese Arbeit macht sich die Erstellung eines solchen Modells ebenso zum Ziel wie die Ausleuchtung der damit verbundenen technischen wie grundsätzlichen Probleme. Kapitel 2 beschäftigt sich mit der Durchführung eines umfassenden Kausalitätstests über die wesentlichsten wirtschaftlichen Variablen Österreichs. Eine weitgehende Diskussion des Kausalitätskonzepts nach Wiener-Granger legt den Grundstein für die Umsetzung dieses Konzepts in die Praxis. Die Ergebnisse dieses Vorgehens sind ausführlich dargestellt.

Das dritte Kapitel geht nun von dem Ergebnis der Kausalitätstests aus und setzt sich die Erstellung eines operationalen Zeitreihenmodells zu Prognosezwecken zum Ziel. Auch hier wird der Hintergrund dargestellt, bevor das multivariate autoregressive Modell detailliert geschildert wird. Vergleiche mit univariaten Modellen werden angestellt. Prognosen bis zum Jahr 1990 werden produziert und zu guter Letzt wird das Modell einer teilweisen Revision unterzogen, wobei die robuste Filterprozedur nach Martin verwendet wird. Die Prognosen, welche dieses robustifizierte Modell liefert, schließen die Arbeit ab.

ABSTRACT

The investigation of time series models for economic data represents an interesting task for the econometric model builder. This paper concentrates on the creation of such a model as well as on a discussion of the fundamental problems involved. Answers are searched for technical as well as for theoretical questions.

Following an introductory overview, chapter 2 starts with the preparation of causality tests. Notes about the selection of the economic variables involved and about the transformations of those variables used for the remainder of the paper pave the ground for a thorough discussion of the Wiener-granger causality concepts. Along these lines, the test procedure is put into practice and the results are displayed in a graphical diagram.

Chapter 3 is based on the foregoing causality tests and aims for an operational time series model for forecasting. Again the background is depicted before the multivariate autoregressive model is represented in all its details. The model is compared with univariate models, it produces forecasts until 1990, and it is finally revised using a robust filtering procedure due to Martin. The forecasts based on this revised model complete the paper.

INHALT

Seite

1. Einleitung	1
2.1 Die Variablen des Modells	2
2.2 Transformation der Daten	2
2.3 Kausalitätstests in der Theorie	5
2.4 Kausalitätstests in der Praxis	10
3.1 Einiges über Zeitreihenmodelle	15
3.2 Univariate und multivariate Zeitreihenmodellierung	16
3.3 Prognosen mit dem Zeitreihenmodell	20
3.4 Robustifizierung der Prognose	23
3.5 Ausblick	26
Literatur	27

Einleitung

Die vorliegende Arbeit wurde in zwei Phasen durchgeführt. Die Interdependenzen zwischen den beiden Phasen sind nicht unproblematisch. Dieser Punkt soll im Laufe des Folgenden noch berührt werden.

In der ersten Phase wurde die Kausalitätsstruktur in einem 12-Variablen-System untersucht. Bei den zwölf Variablen handelt es sich um VGR-Aggregate und sonstige Hauptindikatoren der österreichischen Volkswirtschaft. Zum Zweck der Kausalitätsuntersuchung wurden die Variablen generellen Transformationen (Δ_1, Δ_4, \ln) unterzogen, ohne Rücksicht darauf, ob diese der Form gerecht werden, in der die tatsächlichen Dependenz ablaufen. Bei dieser Vorgangsweise wurden theoretisch-ökonomische Gesichtspunkte sowie die zweite Phase (Prognosefähigkeit des zu erstellenden Modells) im Auge behalten. Aufgrund der für ein Kausalitätsmodell unüblichen Größe mußten die Tests iterativ und selektiv angewendet werden. Damit werden die Signifikanzbewertungen der Abhängigkeiten mehrdeutig und verlieren an Aussagekraft.

In der zweiten Phase wurde auf der Basis der festgestellten Kausalitätsbeziehungen ein Zeitreihenmodell erstellt. Dabei handelt es sich im Grunde um ein multivariates autoregressives Modell, in welchem insignifikante Einflüsse auf 0 restringiert wurden. Zu den insignifikanten Einflüssen wurden hierbei die in der ersten Phase ausgeschiedenen Dependenz und die während des Schätzvorganges festgestellten insignifikanten Lags gezählt. Für die Form des Lagpolynoms wurde lediglich unterstellt, daß der Einfluß mit eventueller Verzögerung eintritt und bis zu maximal vier Quartalen anhält, es wurden also keine "Löcher" in der Koeffizientenstruktur zugelassen. Die Koeffizientenschätzer wurden aus einem Zeitraum bestimmt, der mit dem 3. Quartal 1984 endet und sich soweit zurückerstreckt, wie der Datenvorrat es zuläßt. Anschließend wurde das Modell zu Prognosen für den Zeitraum 1984.4-1990.4 herangezogen, in der klassischen Form, also mit Nullresiduen. Für den dauerhaften Konsum, der in den letzten Beobachtungen ein anormales Verhalten zeigt, wurde vergleichsweise eine univariate robuste Prozedur verwendet, die Ergebnisse dieses Vorgehens wirken leider künstlicher als die Originalprognosen.

2.1 Die Variablen des Modells

Die Arbeit baut auf Quartalswerten folgender ökonomischer Größen auf:

CD	dauerhafter Konsum real
CNDS	nicht dauerhafter Konsum real (inkl. Dienste)
IFE	Ausrüstungsinvestitionen real
IFC	Bauinvestitionen real
XO1	Exporte Nahrungs- und Genußmittel nominell
M01	Importe Nahrungs- und Genußmittel nominell
X24	Exporte Energie und Rohstoffe nominell
M24	Importe Energie und Rohstoffe nominell
X59	Exporte Industriegüter nominell
M59	Importe Industriegüter nominell
PGDP	Deflator des Bruttoinlandsprodukts
RSECL	Rendite der Neuemissionen langfristiger Bonds

Diese Auswahl umfaßt die wesentlichen Komponenten des Volkseinkommens, wobei es wegen der starken internationalen Verflechtung Österreichs, aber auch als Kontrast zur exogenen Natur der Exporte in vielen ökonometrischen Modellen, sinnvoll schien, die Außenhandelsdaten stärker zu disaggregieren. Da längere homogene Quartalsreihen für reale Außenhandelsaggregate nicht vorliegen, wurde hier, also aus technischen Gründen, auf nominelle Größen übergegangen. Die letzten beiden Variablen sollen repräsentativ für die Preis- bzw. Zinsstruktur stehen. Eine genauere Auffächerung der Preisstruktur erschiene sicher wünschenswert, ebenso könnte man sich vorstellen, dieses System später um Variablen aus dem öffentlichen Sektor zu bereichern. Für eine zeitreihenanalytische Behandlung liegt aber die Größe des hier abgesteckten Systems schon am Rande der Möglichkeiten.

2.2 Transformation der Daten

Die meisten Zeitreihenmodelle setzen voraus, daß die involvierten Daten (i.a. kovarianz-)stationären Prozessen entstammen. Natürlich besteht bei beliebigen Daten kein Grund dafür, daß diese Annahme erfüllt ist. In vielen Fällen, so auch bei den oben gelisteten Zeitreihen, bestehen hingegen triftige Gründe dafür, daß diese Annahme **nicht** erfüllt ist.

Was die nominellen Variablen und den GDP-Deflator betrifft, so läßt sich aufgrund historischer Erfahrungen mit dem Phänomen Inflation die Hypothese konstanter Mittelwerte verwerfen. Auch die realen Größen (vielleicht mit Ausnahme der Bauinvestitionen) folgen innerhalb der Beobachtungsperiode mittelfristigen Trendentwicklungen, die wiederum mit dem Phänomen Wirtschaftswachstum zusammenhängen. Lediglich im Falle des Zinssatzes läßt sich die Vermutung der Stationarität nicht auf den ersten Blick abweisen.

Box & Jenkins (1976) schlagen vor, in solchen Fällen die Daten durch Transformationen wie 1. und 4. Differenzen, eventuell nach vorherigem Logarithmieren oder mehrmals hintereinander angewendet, auf stationäre Form (oder - realistischer - auf eine von der Stationarität empirisch nicht trennbare Form) zu bringen. Dabei dienen vor allem die ACF (autocorrelation function) und die PACF (partial autocorrelation function) als Hilfsmittel zur Auffindung der optimalen Transformation.

Im vorliegenden Fall bestand die Zielsetzung darin, ohne genauere Vorinformation Interdependenzen zwischen den Zeitreihen festzustellen. Daher schien es sinnvoll, alle Variablen denselben Transformationen zu unterziehen. Nun verlangten die meisten Reihen nach einer vollständigen Trend- und Saisonkorrektur, was durch starke Spitzen der empirischen Spektren im langfristigen Bereich sowie bei der Einjahresfrequenz zum Ausdruck kam. Das Logarithmieren hatte zwar kaum Einfluß auf das univariate Verhalten, ein Rechnen mit relativen oder logarithmischen Differenzen ist aber plausibler als mit absoluten Differenzen der Daten. Solcherart wurden alle Daten X_t^0 in

$$X_t = \ln(X_t^0/X_{t-4}^0) - \ln(X_{t-1}^0/X_{t-5}^0)$$

verwandelt und mit den X_t dann weitergearbeitet. Da diese Transformation leicht invertierbar ist, leistet sie für ein Prognosemodell, wo man ja wieder nur an X_t^0 interessiert ist, gute Dienste. RSECL wurde in logischer Übereinstimmung mit den übrigen Variablen nur ersten Differenzen unterzogen.

Durch diese Umformung wurde die ursprüngliche Forderung "das Mittel der Variable ist zeitlich konstant" in die Annahme "die Änderung der Zuwachsraten ist im Mittel Null" abgeschwächt (eigentlich im Mittel konstant, indes waren konstante Terme bei sämtlichen Schätzungen insignifikant und wurden daher unterdrückt). Dies hat vor allem Folgen für das asymptotische Verhalten des Modells.

Alle ARMA-Modelle für stationäre Variablen X lassen sich, sofern sie gewisse Stabilitätsanforderungen erfüllen, in der reinen MA-Form

$$X_t = A(L)e_t = \sum_{j=0}^{\infty} A_j e_{t-j}$$

mit weißem Rauschen e_t anschreiben. Die Folge der Koeffizienten (A_j) konvergiert dann zumindest im quadratischen Sinne (d.h. die Summe der Quadrate bilden eine konvergente Reihe) gegen 0. Bei Prognosen, in denen die Störungen im Prognosezeitraum mit 0 fortgeschrieben werden, stirbt daher der Einfluß der im (dem Prognosezeitraum vorhergehenden) Beobachtungszeitraum stattfindenden (und zumindest als Residuen beobachtbaren) Störungen meist sehr schnell ab und die Prognosewerte für X nähern sich 0 oder - in Modellen mit Konstanten - ihrem Mittelwert an. Je größer die Varianz der Störungen ist, je weniger also durch das Modell erklärt wird, desto schneller verläuft diese Annäherung und desto schneller verlieren Zeitreihenprognosen jeglichen Informationsgehalt.

Unterstellt man jedoch ein ARMA-Modell für die in obiger Form transformierten Daten, so nähern sich die Originaldaten im Prognosezeitraum einem Wert an, in dem sich die Zuwachsraten nicht mehr ändern. Die dabei im Limes erreichten Zuwachsraten lehnen sich oft stark an die jüngsten beobachteten Zuwachsraten an, der Prozeß des endgültigen Einschwingens verläuft jedoch im allgemeinen sehr viel langsamer als bei der Modellierung der Originaldaten. Wieder gilt natürlich, daß große Varianzen in den Störungen ein schnelles Einschwingen nach sich ziehen. Im Grenzfall reinen weißen Rauschens werden überhaupt die letzten vier Quartalswerte in Jahreszyklen abwechselnd als beste Prognose in alle Zukunft fortgeschrieben.

Das letzterwähnte Phänomen stellt einen weiteren Vorteil der beschriebenen Transformationen dar. Während eine direkte Modellierung der Daten das Saison-

muster innerhalb weniger Prognoseschritte zerstören würde, konservieren ARMA-Modelle der transformierten Daten gerade dieses Muster. Ein eventuelles Saisonmuster innerhalb der Wachstumsraten (gegenüber dem Vorjahr) geht allerdings verloren. Theoretisch könnte man einem solchen Phänomen mit mehrfacher Differenzenbildung zu Leibe rücken, Inferenzresultate sprechen aber dafür, daß dieses im vorliegenden Fall nicht auftritt.

Die für univariate Modelle angestellten Überlegungen lassen sich ohne größeren Komplexitätszuwachs auf multivariate Modelle, in denen die eingepaßten Variablen Vektoren und ihre Koeffizienten Matrizen sind, übertragen. Wegen den im allgemeinen höheren Erklärungswerten multivariater Modelle schwingen diese meist langsamer ein. Ob die Erklärungskraft solcher multivariater Modelle nun tatsächlich größer ist als die univariater, wird mit den im folgenden beschriebenen Kausalitätstests untersucht.

2.3 Kausalitätstests in der Theorie

Das hier geschilderte Kausalitätskonzept geht auf Granger (1969), der - eine frühere Bemerkung von Wiener aufgreifend und konkurrenzierende Konzepte wie jenes von Wold ausblendend - Ursache und Wirkung folgendermaßen definierte:

"X verursacht Y genau dann, wenn die Ein-Schritt-Prognose für Y durch Verwendung vergangener Realisierungen von X gegenüber jener Prognose verbessert werden kann, welche die gesamte Information aus der Vergangenheit eines entsprechend spezifizierten Universums unter Einschluß von Y, jedoch gerade ohne X, zur Verfügung hat".

Unter Beschränkung auf stationäre Prozesse (X_t) , (Y_t) , (Z_t) , wo Z einen Vektorprozeß aller übrigen Information im "Universum" darstellt, und lineare Prognosen sowie unter Zuhilfenahme der in der Ökonometrie üblichen Prognosegütemessung durch Fehlervarianzen ergibt sich folgende operationale Formulierung der Definition:

"X verursacht Y genau dann, wenn die Varianz des Schätzfehlers für Y_t aus der besten linearen Prognose bedingt durch $(X_{t-1}, X_{t-2}, \dots, Y_{t-1}, Y_{t-2}, \dots, Z_{t-1}, Z_{t-2}, \dots)$ kleiner ist als die Varianz des Prognosefehlers für Y_t aus $(Y_{t-1}, Y_{t-2}, \dots, Z_{t-1}, Z_{t-2}, \dots)$ "

Der Rückzug auf lineare Prognosen kann, zumal lineare Modellbildung auch theoretisch nur als Approximation nichtlinearer Zusammenhänge angesehen werden kann, den logischen Gehalt der Definition stören. Deshalb wird gelegentlich von "linearer Kausalität", "linearer Abhängigkeit" oder "linearem Feedback" gesprochen. Der Tester mag zwar obige Definition akzeptieren, im Hinterkopf wird er freilich kausale Beziehungen im Sinne des Sprachgebrauchs haben. Ergibt sich dementsprechend zwischen X und Y keinerlei Abhängigkeit, zwischen logX und logY aber schon, so wird er der Hypothese zuneigen, zwischen X und Y existierten "tatsächlich" Ursache-Wirkung-Beziehungen. In diesem Sinne können auch Transformationen der Daten gefährlich werden, im speziellen die in dieser Arbeit verwendeten 1. und 4. Differenzen, da diese Abhängigkeiten in den Frequenzbereichen nahe den gelöschten Schwingungskomponenten schwächen und damit statistisch zerstören können. Granger bringt in seiner Arbeit auch Zusammenhänge zwischen seiner Definition und der Kreuzspektralanalyse. Später wurden allerdings Frequenzbereichsverfahren nur selten zur Kausalitätsanalyse herangezogen.

Wichtiger scheint die Operationalisierung der Granger'schen Definition mittels Regressionen, zum Zwecke derer er (X,Y) oder (X,Y,Z) als endlich autoregressive Vektorprozesse voraussetzt. Dann läßt sich die optimale lineare Prognose für Y_t in der Form

$$\hat{Y}_t = \sum_{i=1}^p A_i Y_{t-i} + \sum_{i=1}^q B_i X_{t-i} \left(+ \sum_{i=1}^r C_i Z_{t-i} \right)$$

anschreiben. Die B_i widerspiegeln dann den kausalen Einfluß von X nach Y und können mit den üblichen F-Tests auf Signifikanz überprüft werden. Zur Bestimmung der Koeffizienten schlägt Granger OLS vor und auch diese Arbeit hält sich an dieses Verfahren. Solange keine Gegenwartswerte bei X,Z auftreten und p,q,r genügend groß gewählt wurden, ist ja OLS zumindest konsistent. Da aber (X,Y,Z) als System aufgefaßt werden muß, ist der OLS-Schätzer jedenfalls ineffizient, da er wesentliche Informationen nicht berücksichtigt.

Zur Verbesserung der Effizienz wurden schon des öfteren Vorschläge gemacht. Pierce & Haugh (1977) schlagen vor, sämtliche Zeitreihen univariat vorzumodellieren und den eigentlichen Test mit den Residuen der univariaten Modelle durchzuführen. Damit vertiefen sie die Methode von Sims (1972), der alle seine Daten mit dem gleichen ad-hoc-Glättungsfilter vorbehandelt hatte. Eine Alternative, die in der jüngsten Zeit von mehreren Autoren in Angriff genommen wurde, besteht in der direkten Anwendung von FIML-Prozeduren auf das gesamte System. Dieser Vorgangsweise sind durch die Vielzahl der auftretenden Parameter und oft auch durch die Software-Implementation speziell bei größeren Systemen enge Grenzen gesteckt.

Der Granger'sche Kausalitätsbegriff wirft - darauf soll hier nicht vergessen werden - neben technischen Problemen auch solche inhaltlicher Natur auf. Granger's Kausalität entspricht durchaus nicht dem im Sprachgebrauch üblichen Konzept von Ursache und Wirkung, und dies beileibe nicht nur deswegen, weil er in seiner operationalen Form auf lineare Prognosen beschränkt ist. Überzeugte Empiristen hätten wahrscheinlich weniger Schwierigkeiten damit, Ursache und Wirkung jeder logisch nachvollziehbaren Zusammenhänge zu berauben als jener harte Kern von Aprioristen, der die mittelalterlichen Naturwissenschaften und die neuzeitliche Ökonomie dominierte. Zwischen beiden Extremen liegt der zahlreiche vertretene Menschentypus, der Theoriebildung und Erfahrung, Kopf und Sinne gleichermaßen zur Wahrheitsfindung einsetzt, der die Welt ebenso erkennen wie verstehen will. Für ihn muß eine Ursache-Wirkung-Beziehung nicht notwendig theoretisch begründet sein, wohl aber muß sie denkmöglich erscheinen. Diesem Einwand kann man durch Selektion der untersuchten Variablen allerdings entgegenkommen. Zwischen den in dieser Arbeit angegebenen 12 Größen sind alle x-beliebigen Zusammenhänge prinzipiell denkmöglich.

Drei weitere Punkte sollen noch berührt werden, in denen Granger's Definition aus dem Sprachgebrauch her Angriffen ausgesetzt sein könnte. Es handelt sich dabei um deterministische Zusammenhänge, zeitlich unbeschränkte Verzögerung und diskrete Datenerfassung.

Hängen zwei Variable aufgrund institutioneller Gegebenheiten in der Form $y=f(x)$ direkt zusammen, im Fall linearer Prognose etwa $y=x+a$ mit a konstant, so gelten x und y nach der Granger-Definition als unabhängig. Dasselbe gilt

auch für verzögerte exakte Abhängigkeiten in Trendkomponenten zweier Variablen, deren übrige Schwankungen nicht interkorreliert sind. Es ist klar, daß in solchen Fällen Ursache und Wirkung empirisch nicht trennbar sind und daß tatsächliche (im Sinne des Sprachgebrauchs) Abhängigkeiten sich fast immer auch in den Anomalien widerspiegeln. Trotzdem kann hier bei unvorsichtiger Trendextraktion ein Problem auftreten.

Laut Definition geht die gesamte Vergangenheit, ausgehend von einem ideellen Weltenbeginn, als Information in die Prognose ein. Ein derartiges zeitliches Auseinanderklaffen von Ursache und Wirkung scheint implausibel, die Definition ist aber in dieser Form funktionalanalytisch sauberer zu handhaben als etwa ein Anfangswertkonzept. Man möge sich damit trösten, daß die Asymptotik als Approximation zu verstehen ist und daß begrenzte Beobachtungsintervalle und Freiheitsgrade das Intervall zwischen Ursache und Wirkung limitieren. Granger brachte eine Definition über kausale Effekte mit Verzögerung k , die später allerdings kaum mehr Beachtung fand. Die plausibelste Erklärung für die oft angefeindeten Verzögerungswirkungen über mehrere Zeitintervalle hinweg liegt meist darin, daß Größen, die das Signal in der Zwischenzeit weitergegeben haben, nicht in die Datenmatrix aufgenommen wurden.

Die diskrete Datenerfassung verhindert das Erkennen aller Effekte, die mit zu großer Geschwindigkeit eintreten. Signale, die per Telefon vermittelt werden, können mit Jahresdaten sicher nicht abgetestet werden. In diesem Sinn ist auch praktisch das Auftreten instantaner Kausalität zu verstehen, die so definiert wurde:

X verursacht Y instantan, wenn die (lineare) Prognose für Y durch den gegenwärtigen Wert von X verbessert werden kann, wobei die Information der gesamten Vergangenheit (incl. X, Y) in beiden Fällen ausgenützt wurde.

Die instantane Kausalität kann durch die Korrelation der Residuen aus der oben geschilderten Regressions- oder Zeitreihenmodell-Prozedur überprüft werden. Schon daraus sieht man, daß hier Ursache und Wirkung nicht unterscheidbar sind. Ob das Phänomen der instantanen Kausalität im buchstäblichen Sinn eine Daseinsberechtigung besitzt, bleibe dahingestellt. Die Überprüfung der instantanen Kausalität durch Inklusion der gegenwärtigen Beobachtungen

in die Schätzung ist prinzipiell möglich, führt aber zu Identifikations- und Verzerrungsproblemen (Pierce & Haugh (1977)).

Ist die Auswahl an Variablen, die das "Universum" bilden, insofern unvollständig, als diese mit weiteren, nicht berücksichtigten oder gar nicht erhobenen Variablen vernetzt sind, so tritt mit großer Wahrscheinlichkeit das Phänomen der dritten Ursache auf. Hier wirkt eine unberücksichtigte Quelle auf zwei Systemvariable, sodaß es den Anschein hat, als bedingten diese beiden einander. Dieses Phänomen ist kein Makel der Definition, sondern eine Folge der Unvollständigkeit des Systems. Ist das Endziel, so wie in der vorliegenden Arbeit, ein Prognosemodell, so ist das Problem von sekundärer Bedeutung.

Florens & Mouchart (1985) präsentieren weitere Resultate, die die Natur der Granger-Kausalität betreffen. Zunächst zeigen sie, daß Kausalität nicht transitiv ist, d.h. daß aus "X verursacht Y" ($X \rightarrow Y$) und " $Y \rightarrow Z$ " nicht " $X \rightarrow Z$ " geschlossen werden kann. Diese Tatsache gibt einerseits Anlaß zur Vorsicht, zeigt aber andererseits, daß in der Kausalitätsdefinition mehr Inhalt steckt als bloße Aneinanderreihungen von Einflüssen in einem fiktiven System. Der von Y nach Z weitergegebene Impuls kann (muß aber nicht) von dem auf Y einwirkenden Impuls völlig unabhängig sein.

Das zweite Resultat von Florens & Mouchart lautet:

Y und Z verursachen genau dann gemeinsam W, wenn $Y \rightarrow W$ oder $Z \rightarrow W$ (im nicht ausschließenden Sinn).

Das Zusammenwirken zweier Ursachen allein ist also für kausale Beziehungen irrelevant insoferne, als zumindest eine der beiden Ursachen die Information über die Beziehung bereits beinhaltet. Dies steht sicher im Widerspruch zu manchen Alltagsphänomenen, es ist aber zu bedenken, daß auch dann das Auftreten einer der Ursachen die Wahrscheinlichkeit des Auftretens des Effektes erhöht.

Das dritte Resultat zeigt, daß die Umkehrung nicht gilt:

- a) aus $Y \rightarrow (Z, W)$ folgt nicht $Y \rightarrow Z$ oder $Y \rightarrow W$
- b) daraus, daß $Y \rightarrow (Z, W)$ nicht gilt, folgt weder, daß $Y \rightarrow Z$ nicht gilt noch daß $Y \rightarrow W$ nicht gilt.

Aus der Beeinflussung eines Subsystems durch ein Y läßt sich also nicht darauf schließen, welches Element des Subsystems auf Y anspricht (irgend ein solches Element muß es wohl schon geben)¹⁾. Andererseits können die Elemente eines Subsystems sehr wohl auf Y reagieren, ohne daß das gesamte Subsystem durch Y verursacht wird, nämlich dann, wenn die Kreuzkausalitäten zwischen den Elementen die Prognosekraft des Y absorbieren. Letzterer Fall ist nicht möglich, wenn man von vollständigen Universen ausgeht.

Um noch ein letztes Mal zu dem Punkt zurückzukehren, inwiefern Kausalität im Sprachgebrauch und in der Granger'schen Definition übereinstimmen, sollte noch gesagt werden, daß schon mehrfach pragmatische Lösungen vorgeschlagen wurden, wie etwa eine Umbenennung des Begriffs oder seine sprachinhaltliche Leerung. In Anbetracht des bisher Gesagten erscheinen solche Standpunkte übertrieben.

2.4 Kausalitätstests in der Praxis

Im letzten Abschnitt wurde bereits das Regressionsverfahren angerissen, das nun zur Untersuchung der Kausalitätsbeziehungen zwischen den gemäß Abschnitt 2.3 transformierten Variablen dienen soll. Das eigentliche Problem bei der praktischen Durchführung liegt in der großen Anzahl an Variablen im System. Eine Regression einer als vermutete Wirkungsgröße eingestuft Variable auf nur wenige eigene Verzögerungen und eine vernünftige Anzahl (etwa 4 bei Quartalsdaten) verzögerter Werte sämtlicher anderer Variablen würde bereits eine Regression mit etwa 50 Regressoren darstellen und unter anderem die implementierten Software-Routinen überfordern, abgesehen von der geringen Zahl an Freiheitsgraden. Daher wurde in folgenden Schritten vorgegangen:

1) Bei Florens & Mouchart tritt das Paradoxon in seiner scharfen Form auf, was aber nur bei einer leicht veränderten, weniger intuitiven Kausalitätsdefinition möglich ist, wobei der Unterschied die Spezifikation des Universums U betrifft (hier ein stationärer Prozeß Z).

1. Jede Variable wurde in ein univariates autoregressives Modell der Form

$$X_t = \sum_{i=1}^p A_i X_{t-i} + e_t$$

eingepaßt, wobei p nach dem BIC-Kriterium bestimmt wurde, jedoch mit der Restriktion, über 8 nicht hinauszugehen. Die signal/noise-ratio wurde dabei notiert und zu späteren Vergleichen aufgehoben. Sollte die Variable X signifikant von anderen Größen beeinflusst werden, sollte sich ja auch die Erklärungsrate verbessern. Dies entspricht nicht nur buchstäblich der Definition von Granger, sondern wurde auch zur Stütze des Kausalitätskonzepts nach Geweke (1982), dessen relative Kausalitätsmaße hier nur am Rande erwähnt bleiben sollen.

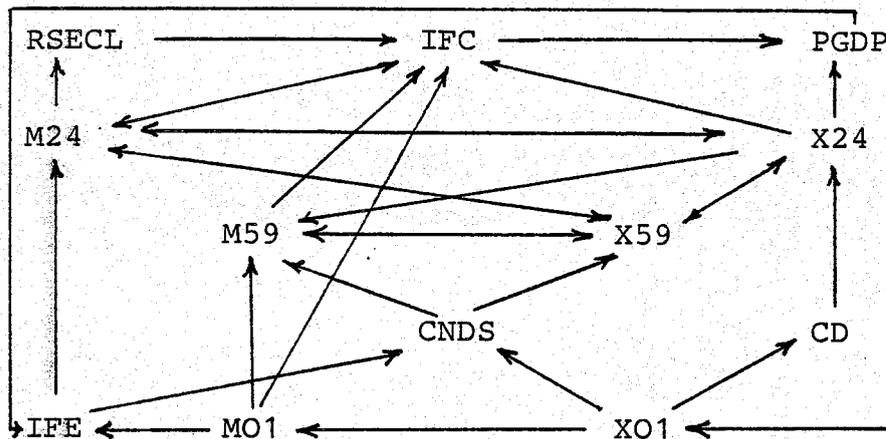
2. Jetzt werden sukzessive Regressionen der Form

$$X_t = \sum_{i=1}^p A_i X_{t-i} + \sum_k \sum_{j=i}^4 B_{kj} Z_{k,t-j} + e_t$$

durchgeführt, wobei so viele verschiedene Z_k berücksichtigt werden, wie die Differenz zwischen dem Regressoren-Limit 20 und p zuläßt, also drei oder vier Stück. Diejenigen Z_k , deren Gesamteinfluß gemäß der F-Statistik 10%-Signifikanz nicht erreicht, scheiden aus und werden in einer neuen Regression durch andere ersetzt. Durch eine Fügung des Schicksals wurden bei keiner Variable mehr als drei oder vier Ursachen ermittelt, sonst wäre das Verfahren zusammengebrochen.

Aufgrund dieser schrittweisen Methode ist es abschließend nicht mehr möglich, die Signifikanz der Einflüsse festzulegen, wie man dies anderswo öfters sieht, da sich diese durch Modifikation der übrigen Regressoren ändert. Ähnliches gilt für die r^2 , weshalb letztendlich nur das r^2_c der Prognosemodelle aus Abschnitt 3 gelistet ist.

Tafel 1



- CD dauerhafter Konsum real
- CNDS nicht dauerhafter Konsum real (inkl. Dienste)
- IFE Ausrüstungsinvestitionen real
- IFC Bauinvestitionen real
- XO1 Exporte Nahrungs- und Genußmittel nominell
- M01 Importe Nahrungs- und Genußmittel nominell
- X24 Exporte Energie und Rohstoffe nominell
- M24 Importe Energie und Rohstoffe nominell
- X59 Exporte Industriegüter nominell
- M59 Importe Industriegüter nominell
- PGDP Deflator des Bruttoinlandsprodukts
- RSECL Rendite der Neuemissionen langfristiger Bonds

Das auf Tafel 1 präsentierte Diagramm entspricht nun nicht ganz dem Ergebnis der Kausalitätstests. In zwei Fällen, nämlich bei CD (dauerhafter Konsum) und bei IFC (Bauinvestitionen), in welchen das im nächsten Abschnitt beschriebene Zeitreihenmodell kontraintuitive Prognoseresultate lieferte, wurden noch einmal alle zunächst ausgeschiedenen Variablen danach abgegrast, ob gewisse Lags signifikante Verbesserungen der Erklärung bieten könnten. Es kann vorweggenommen werden, daß trotz erfolgreicher Suche die Verbesserung der Prognosesimulation marginal war.

Beim Anblick des Diagramms wird verständlich, warum verschiedentlich "non-causality" und nicht "causality" als die testenswerte Hypothese unterlegt wird, nicht nur jedenfalls wegen der statistischen Nullhypothesenformulierung. Vielmehr ist in einem derart interdependenten System, wie es eine Volkswirtschaft nun einmal darstellt, der kausale Zusammenhang die Regel eher als die Ausnahme. Keine der Variablen tritt nur als Quelle oder nur als Ziel der Kausalitätspfeile auf, das gesamte System ist durch ein Netz von Feedback-Schleifen miteinander verwoben. Pierce & Haugh (1977) verwendeten den Begriff "Feedback" lediglich in Fällen, in denen zwischen zwei Variablen beiderseits gerichtete Kausalitäten liegen. Hier soll unter Feedback i.w.S. aber auch jede Aneinanderreihung von Pfeilen verstanden sein, die zum Ausgangspunkt zurückführt. Man erinnere sich, daß Granger-Kausalität einerseits nicht transitiv ist, andererseits aber festgestellte Kausalität durch Zwischenschalten einer dritten Variable im direkten Sinne verschwinden kann.

Im einzelnen wird der Zinssatz (RSECL) lediglich durch die Rohstoffimporte beeinflusst, die, da nominell, auch die Importpreise widerspiegeln (z.B. Ölschock). Seinerseits treibt RSECL die Bauinvestitionen (IFC), aber nicht IFE, was Erfahrungstatsachen über Schätzung österreichischer Investitionsfunktionen entspricht. Die Feedback-Schleife RSECL/IFC/PGDP/IFE/M24/RSECL verdient hingegen Beachtung.

IFC wirkt sowohl auf die Preise als auch auf die Rohstoffimporte, wobei mit letzteren direktes Feedback besteht. Zu behaupten, Kraftwerksbauten könnten hier eine tragende Rolle spielen, könnte als Polemik verstanden werden. Außer RSECL und M24 wirken noch einige sonstige Außenhandelsaggregate eher kontraintuitiv auf IFC ein.

Die Preise (PGDP) bestimmen sich durch die Bauinvestitionen und die Rohstoffexporte (oder, da diese nominell sind, deren Preise). Von PGDP werden die Ausrüstungsinvestitionen (IFE) und die landwirtschaftlichen Exporte (X01) direkt berührt. Durch eine genauere Behandlung des Preissystems könnte sich hier einiges ändern, jedenfalls aber gibt es keinen direkten Zusammenhang mit Zinssätzen oder Konsumaggregaten.

Die Ausrüstungsinvestitionen (IFE) werden durch PGDP getrieben, wobei sowohl Rationalisierungsinvestitionen zur Erhaltung der Konkurrenzfähigkeit als auch der Effekt der Investitionsgüterpreise zum Ausdruck kommen könnte. Darüber hinaus erkennt man eine Feedback-Beziehung zum nicht-dauerhaften Konsum und eine eigenartig anmutende Einflußkomponente von den landwirtschaftlichen Importen (M01) her. IFE seinerseits wirkt auf die miteinander starkverwobenen Import- und Exportdaten über Energie und Rohstoffe, was wieder anschaulich klingt.

Der dauerhafte Konsum (CD) wird fast zur Gänze aus der eigenen Geschichte erklärt und gehört zu den Sorgenkindern der Modellierung. Wiederholte Mehrwertsteuer-Umstellungen und die damit verbundenen Vorziehkäufe und Flauten haben hier sicher de-facto Abhängigkeiten statistisch vernichtet. Lediglich ein schwacher Zusammenhang mit gewissen Exportdaten ist feststellbar.

Der nicht-dauerhafte Konsum (CNDS) reagiert interessanterweise ebenso wie CD auf die Landwirtschafts-Exporte, in denen vielleicht irgendeine schwer dechiffrierbare Information über internationale wie österreichische Konjunktur steckt, die in den übrigen Variablen nicht enthalten ist. Darüber hinaus existiert das schon erwähnte Feedback mit den Investitionen. Ähnlich wie diese auf die Außenhandelsdaten der SITC 2 bis 4 wirken, treibt der CNDS die interdependenten Exporte und Importe der SITC 5 bis 9, also Industriegüter und Fertigwaren. Der Zusammenhang zu den verschiedenen Stadien der Verarbeitung erscheint nachvollziehbar.

Zwischen den Außenhandelsdaten bestehen verschiedenartige Interdependenzen, wobei die landwirtschaftlichen Erzeugnisse eine Sonderstellung einnehmen und lediglich über die Abfolge X01/M01/M59 mit den übrigen verbunden sind. Die für Österreich recht wichtigen Dienstleistungsexporte (Fremdenverkehr) kommen im Modell nicht vor.

3.1 Einiges über Zeitreihenmodelle

Als Zeitreihenmodell im weitesten Sinne könnte man jedes Modell bezeichnen, das in fixen zeitlichen Abständen erhobene Daten unter gewissen Annahmen über Konstanz in der Struktur in eine mathematische Gesetzmäßigkeit einpaßt. Ganz sicher zählen hierzu übliche makroökonomische Modelle.

Im üblichen Sprachgebrauch läßt sich aber folgende Dichotomie fixieren, wobei die Übergänge fließend sein können:

Zeitreihenmodell

möglichst langer Beobachtungszeitraum

Sonderentwicklungen werden mechanisch ausgeglättet

geringe Dimensionen aus technischen Gründen

starke Dynamik

asymptotisches Gleichgewicht

erster Versuch zur Erklärung einer Variable: eigene Vergangenheit

exogene Variable, die nicht direkt beeinflussbar sind, werden zur Prognose endogenisiert

hohe Bereitschaft dazu, das Modell anhand der Empirie zu revidieren

geringe Information aus der Theorie

Ökonomie ist einer Naturwissenschaft wesensähnlich, wenn sie empirisch betrieben wird

die Welt folgt einfachen Gesetzen, die wir nicht kennen, und stochastischen Abweichungen

Ökonometrisches Modell

Beobachtungszeitraum auf homogene Regimes beschränkt

Sonderentwicklungen werden mit Dummies kaltgestellt

Dimension unbeschränkt

Dynamik nur mit geringen Verzögerungen in nachvollziehbaren Fällen
prinzipiell ständiges Gleichgewicht mit Abweichungen (shocks)

erster Versuch zur Erklärung einer Variable: andere, meist gleichzeitig erhobene Variable

solche exogenen Variablen werden im Kopf und über den Daumen prognostiziert

Bereitschaft zur Revision anhand der Empirie durch a-priori-Vorgaben beschränkt

substantielle Information aus der Theorie

Ökonomie ist einer Naturwissenschaft immer wesensfremd, weil Menschen auch als Wirtschaftssubjekte etwas Besonderes sind

die Welt ist sehr kompliziert, ihre Gesetze sind ständig im Fluß

Trotz solcher massiver Differenzen in der zugrundeliegenden Philosophie kann man von einem Modell, das sich in der Form

$$Y\Gamma_0 + Y_{-1}\Gamma_1 + \dots + Y_{-h}\Gamma_h + XB + U = 0$$

anschreiben läßt, nicht auf Anhieb sagen, ob es sich um ein ökonometrisches oder ein Zeitreihenmodell i.e.S. (im folgenden ÖMES und ZMES) handelt. Hier ist die gebräuchliche Notation beibehalten, nach der Y die endogenen, X die exogenen Variablen und U die Störungen beinhaltet, wobei Γ_i und B noch zu schätzende Parameter (-Matrizen) sind. Je stärker die Parametermatrizen restringiert, je höher die Dimension von X relativ zu Y und je niedriger der Maximallag h, desto eher wird man von einem ÖMES sprechen.

Die Gegensätze auf dem theoretischen Niveau spiegeln sich auf dem erdnäheren Niveau der Praxis wider. Die starke Problemreduktion des Zeitreihenanalytikers, sein Verzicht auf menschliche Intuition stellen ihn genauso in Opposition zur Tendenz des klassisch-ökonometrischen Modellbauers, jeden Zusammenhang verstehen zu wollen, in sein festgestecktes Weltbild einzuzwängen, wie die sture Dampfwalze der der in Abschnitt 2 dargelegten Kausalitätstests und der noch darzulegenden multivariaten AR-Prozeduren der disaggregierenden Feinarbeit mit den künstlich anmutenden Korrekturen in einem ÖMES diametral entgegengesetzt ist. Bei extremer Durchführung eines der beiden Wege geht die Balance leicht verloren, das ZMES hält sich krampfhaft unter blindem Vertrauen an den inhaltsleer gewordenen Daten fest, das ÖMES wird zum Spiegel der Ideologie seines Erbauers. Die optimale Ausnützung der Information wie der geistigen Ressourcen liegt naturgemäß in der Mitte.

3.2 Univariate und multivariate Zeitreihenmodellierung

Dem Grundelement des ÖMES, dem multiplen Regressionsansatz, entspricht in der Zeitreihenanalyse das AR(p)-Modell, das in der Form

$$e_t = \sum_{i=0}^p A_i Y_{t-i} = \left(\sum_{i=0}^p A_i L^i \right) Y_t = A(L)Y_t \quad (A_0=1)$$

angeschrieben wird. Dabei ist e_t stets weißes Rauschen und y_t kovarianzstationär. Läßt man p gegen ∞ gehen, so läßt sich zeigen, daß jeder nicht-

antizipative stationäre Prozeß mit Ausnahme gewisser Randfälle in obiger Art darstellbar ist (siehe etwa Hannan (1970)). Antizipative Prozesse, deren Bildungsgesetz der Zeit entgegenläuft, wollen wir hier ausschließen.

Ähnlich wie sich Regressionsmodelle zu simultanen Gleichungssystemen erweitern lassen, kann auch obige Gleichung unter völliger Beibehaltung der Schreibweise als Beschreibung eines multivariaten AR(p)-Modells angesehen werden, wobei nun e und y Vektoren der Dimension n sind und die A_i $n \times n$ -Matrizen (Der degenerierte Fall, wo $\dim y > \dim e$, ist hier ausgeschlossen). Natürlich besteht jetzt keine Veranlassung dazu, p in allen Komponenten $A_{jk}(L)$ der Polynommatrix $A(L)$ identisch zu fixieren. Das erste nichttriviale Problem ist hier also die Wahl der richtigen p_{jk} . Im folgenden wurde von Obergrenzen von B für die Diagonalelemente p_{ii} und 4 für die off-diagonal-Elemente ausgegangen. Verlässliche Kriterien, wie BIC oder AIC, existieren leider in rigoroser und operationaler Form nur im univariaten Fall.

Das zweite Problem besteht in der bereits im ÖMES bekannten Parameterinflation. Ein vollbesetztes n -dimensionales AR(p)-Modell weist eben np^2 Parameter $A_{i,jk}$ auf, die Varianzenmatrix der "Innovationen" e noch nicht mitgerechnet. Im vorliegenden Fall ($n=12, p=4(8)$) ergeben sich 240 Parameter. Eine solche Masse von Parametern effizient aus jeweils etwa 80 Daten zu schätzen, etwa mit Hilfe von ML-Methoden, würde die technischen Möglichkeiten überstrapazieren.

Es wurde demgemäß eine Einzelgleichungsstrategie eingeschlagen, die mit den Kausalitätsmodellen aus Abschnitt 2 begann, d.h. es wurden zunächst die volle Anzahl der univariaten Lags und 4 Lags aller als Ursache erkannten Variablen in eine OLS-Regression eingebaut.

$$Y_t = \sum_{i=1}^p A_i Y_{t-i} + \sum_k \sum_{j=1}^4 B_{kj} Z_{k,t-j} + e_t$$

Im zweiten Schritt wurde ein sparsames Modell durch schrittweise Elimination insignifikanter Regressoren approximiert. Das sich ergebende Modell hat die Form

$$Y_t = \sum_{i=1}^p A_i Y_{t-i} + \sum_t \sum_{j=J_{ku}}^{J_{ko}} B_{kj} Z_{k,t-j} + e_t \quad (1 \leq J_{ku} \leq J_{ko} \leq 4)$$

d.h. insignifikante Verzögerungen zwischen zwei signifikanten Regressoren wurden beibehalten. In einigen Fällen mußte der autoregressive Teil $\sum A_i Y_{t-i}$ reduziert oder vollends eliminiert werden, meist jedoch blieb er unangetastet. Hauptsächliches Kriterium für die Variablenselektion waren auch hier, wie im Kausalitätsverfahren, F-Tests.

Man könnte fragen, warum nicht direkt das Kausalitäts-Testmodell mit allen Variablen beibehalten wurde. Der Grund liegt in der Zielsetzung des Zeitreihenmodells, nämlich in der Prognose. Hier können insignifikante Koeffizienten starke Verzerrungen bewirken, wenn die ihnen zugeordneten Variablen in den letzten Perioden des Beobachtungszeitraumes quasi ceteris paribus eingehen. Vor diesem Effekt muß man sich schützen. Die Zielsetzung des Kausalitätsmodells lag in der Gewinnung von Aufschlüssen über Wechselwirkungsmechanismen, diejenige des Zeitreihenmodells in der Auswertung dieser Aufschlüsse zur Prognose.

Eine dritte Stufe, ein Scanning der übrigen, in der Kausalitäts-Testphase als Ursachen ausgeschiedenen Variablen nach signifikanten Lags, wurde nicht durchgeführt. Die beiden Ausnahmen (CD und IFC) wurden bereits in Abschnitt 2.4 berührt.

Auf Tafel 2 sind nun einige wesentliche Statistiken zusammengestellt, die den Informationsgewinn des multivariaten Modells gegenüber den reinen univariaten Modellen wiedergeben sollen. Für jede Variable wird hier angegeben:

1. die Ordnung p des univariaten $AR(p)$ -Modells nach dem BIC-Kriterium unter der Restriktion $p \leq 8$, die mit Ausnahme von M24 auch der Anzahl der Lags im multivariaten Modell entspricht
2. $1-NVR$, wobei NVR die noise/variance-ratio des $AR(p)$ -Modells ist, welche in etwa den r -Werten der Regressionsmodelle entspricht
3. das r^2_c der fertig modellierten Gleichung im Zeitreihenmodell
4. $(1-NVR)/r^2_c$ als Hinweis für den gesamten "kausalen" Einfluß auf die jeweilige Variable. Kleine Werte bedeuten großen Einfluß, große Werte deuten auf approximative Exogenität (im Sinne von Granger) hin.

Tafel 2

UNIVARIATES UND MULTIVARIATES MODELL:
VERGLEICHSTATISTIKEN

	P	1-NVR	r^2_c	$(1-NVR)/r^2_c$
IFE	5	.358	.540	.663
IFC	1	.035	.404	.087
CD	8	.453	.457	.991
CNDS	8	.474	.486	.975
RSECL	5	.252	.260	.969
PGDP	4	.313	.423	.740
M01	5	.214	.273	.784
M24	4	.344	.426	.808
M59	4	.252	.431	.535
X01	5	.403	.440	.916
X24	4	.328	.513	.639
X59	4	.378	.676	.559

Die Ergebnisse sind recht heterogen. Absolut niedrig sind die Erklärungsraten für Zinssatz und landwirtschaftliche Importe, aber auch bei vielen anderen Variablen, so beim GDP-Deflator (PGDP) und bei den Bauinvestitionen (IFC) bleibt der r^2_c unter 50%.

Starke Exogenität ist bei beiden Konsumaggregaten und beim Zinssatz (RSECL) feststellbar, auch bei X01 liegt der Quotient der Erklärungssätze über 90%. Im Fall der Konsumvariablen wirkt das Resultat zunächst überraschend, man bedenke aber, daß die üblichen Konsumfunktionen den Großteil der Erklärung aus dem Einkommen holen, welches wiederum aus dem Konsum erwächst und durch verzögerte Konsumdaten gut erklärbar ist. Die ausbleibende Reaktion auf Preise wie auch auf Investitionsdaten oder auf das jeweils andere Aggregat (CD auf CNDS und umgekehrt), die schon im Abschnitt 2 berührt wurde, erhärtet sich hier.

Stark endogene Variable sind neben den Bauinvestitionen noch die Außenhandelsdaten (Exporte wie Importe) der SITC 5-9. Die in manchen ÖMES unterstellte Exogenität der Exporte scheint mehr als zweifelhaft.

3.3 Prognosen mit dem Zeitreihenmodell

Hat man ein Zeitreihenmodell, wie es in 3.2. beschrieben wurde, also von der Form

$$e_t = A(L)Y_t = \sum_{i=1}^p A_i Y_{t-i} \quad \dim A_i = nxn$$

so ergibt sich die beste lineare Prognose unter Verwendung des Kriteriums kleinster Prognosevarianz, etwa für den dem Beobachtungsintervall erstnachfolgenden Zeitpunkt T+1 durch

$$\hat{Y}_{T+1} = - \sum_{i=1}^p A_i Y_{T+1-i}$$

also durch Nullsetzen der unbekanntes und als white noise vorausgesetzten Störgröße e_{T+1} . Analog entstehen die "besten" Mehrschrittprognosen durch Einsetzen der in den früheren Prognosen errechneten y-Werte in die rechte Seite, so z.B.

$$Y_{T+3} = - \sum_{i=1}^2 A_i \hat{Y}_{T+3-i} - \sum_{i=3}^3 A_i Y_{T+3-i}$$

Nach $p+1$ Schritten gehen überhaupt keine Beobachtungen mehr direkt in die Prognose ein.

Durch das Nullsetzen der e_{T+i} geht die Information über die Varianz der Innovationen leider verloren. Erhalten bliebe diese Information bei der sogenannten stochastischen Simulation, wobei e_{T+i} aus normalverteilten Pseudozufallszahlen mit Mittel 0 und Varianz $\hat{\sigma}^2$ generiert wird. Im vorliegenden Fall wurde allerdings von derartigen, sehr rechenzeitaufwendigen Strategien Abstand genommen.

Weiters ist zu beachten, daß die Parametermatrizen A_i nicht bekannt sind, sondern OLS geschätzt werden. Der tatsächliche Prognosefehler setzt sich also aus dem Einfluß der e_{T+i} und dem Einfluß des Schätzfehlers von \hat{A}_i zusammen.

Mittels des in 3.2. dargelegten Zeitreihenmodells wurde die Prognose für den Zeitraum 1984.4-1990.4 quartalsweise durchgeführt. Die zu Jahreswerten zurückaggregierten Prognoseresultate sind in Tafel 3 aufgelistet. Dabei ist der Wert für 1984 teilweise realisiert, alle Werte nachher rein prognostiziert. Ausgegeben wurden natürlich nicht die direkten Prognoseresultate, sondern die bereits vor der Aggregation gemäß

$$Y_t^0 = Y_{t-1}^0 \cdot Y_{t-4}^0 / Y_{t-5}^0 \cdot \exp(Y_t)$$

rücktransformierten Daten.

Im einzelnen zeigt sich eine kontraintuitiv schlechte Entwicklung des dauerhaften Konsums (CD), die sehr wahrscheinlich in der Mehrwertsteuerumstellung 1983/84 begründet liegt, d.h. die letzten wahren Werte sind "Ausreißer", die die gesamte Prognose verzerren. Im nächsten Abschnitt soll eine alternative Strategie beschrieben werden, um diesem Problem Herr zu werden. Demgegenüber zeigt der sonstige Konsum einen ruhigen Zeitpfad mit Zuwachsraten um die 2%.

ZEITREIHENPROGNOSE

LABEL	I	1983	1984	1985	1986	1987	1988	1989	1990
CD	I	62.075	57.139	57.531	56.265	55.057	54.298	53.132	52.323
		15.3%	-8.0%	7%	-2.2%	-2.1%	-1.4%	-2.1%	-1.5%
CNDS	I	421.528	427.614	435.813	445.863	454.432	464.251	473.656	483.559
		3.6%	1.4%	1.9%	2.3%	1.9%	2.2%	2.0%	2.1%
IFE	I	80.910	84.805	83.963	85.925	86.115	87.453	88.131	89.221
		-3.2%	4.8%	-1.0%	2.3%	.2%	1.6%	.8%	1.2%
IFC	I	93.678	91.828	87.685	83.671	80.331	76.911	73.578	70.505
		-.5%	-2.0%	-4.5%	-4.6%	-4.0%	-4.3%	-4.3%	-4.2%
X01	I	12.323	13.665	13.932	14.832	15.504	16.229	17.148	17.859
		1.6%	10.9%	2.0%	6.5%	4.5%	4.7%	5.7%	4.1%
X24	I	22.444	25.485	24.195	24.827	25.019	25.296	25.375	25.709
		2.9%	13.5%	-5.1%	2.6%	.8%	1.1%	.3%	1.3%
X59	I	242.373	274.010	299.086	327.901	359.452	396.149	432.382	476.358
		4.1%	13.1%	9.2%	9.6%	9.6%	10.2%	9.1%	10.2%
M01	I	21.369	23.469	25.070	27.530	29.602	32.297	34.902	37.939
		2.8%	9.8%	6.8%	9.8%	7.5%	9.1%	8.1%	8.7%
M24	I	70.534	87.272	95.890	107.605	121.380	137.474	153.820	173.875
		-8.2%	23.7%	9.9%	12.2%	12.8%	13.3%	11.9%	13.0%
M59	I	256.436	286.938	311.866	335.996	366.020	397.827	430.294	468.351
		9.2%	11.9%	8.7%	7.7%	8.9%	8.7%	8.2%	8.8%
PGDP	I	142.775	149.159	155.635	162.269	169.226	176.487	184.050	191.950
		3.8%	4.5%	4.3%	4.3%	4.3%	4.3%	4.3%	4.3%
RSECL	I	8.090	8.495	8.564	8.365	8.401	8.432	8.422	8.414
		-17.2%	5.0%	.8%	-2.3%	.4%	.4%	-.1%	-.1%
Var1	I	483.603	484.753	493.344	502.128	509.488	518.550	526.788	535.882
		5.0%	.2%	1.8%	1.8%	1.5%	1.8%	1.6%	1.7%
Var2	I	174.588	176.632	171.648	169.596	166.446	164.365	161.709	159.726
		-1.8%	1.2%	-2.8%	-1.2%	-1.9%	-1.3%	-1.6%	-1.2%
Var3	I	658.191	661.386	664.992	671.724	675.935	682.914	688.497	695.608
		3.1%	.5%	.5%	1.0%	.6%	1.0%	.8%	1.0%
Var4	I	48.527	52.487	54.167	56.628	59.089	61.998	64.508	67.716
		.1%	8.2%	3.2%	4.5%	4.3%	4.9%	4.0%	5.0%
Var5	I	60.994	66.653	69.526	72.585	76.377	80.402	84.083	88.587
		.9%	9.3%	4.3%	4.4%	5.2%	5.3%	4.6%	5.4%

Die Ausrüstungsinvestitionen zeigen einen deutlichen zweijährigen Zyklus mit abklingenden Schwankungen. Dieser dürfte einer Wiedergabe früherer Schwankungen entsprechen. Ab 1986 liegt IFE über IFC, man vergleiche hier die mittelfristige Prognose des IHS(1984) mit dem gleichen Resultat. IFC zeigt einen trägen Trend um die 4% nach unten. Eine Anhebung dieser Tendenz durch Ummodellierung gelang nicht, IFC stellt also eine der intuitiven Schwachstellen des Modells dar.

Die Außenhandelsaggregate zeigen ruhige Zuwächse, mit Ausnahme der Rohstoff- und Energieexporte, die mit dem übrigen Außenhandelswachstum nicht Schritt halten, was ökonomisch nicht ganz unplausibel ist. Man beachte auch, daß die Industrieexporte ab 1989 die Importe (M59) überholen.

Preise und Zinssatz erfahren keine besonderen Impulse und stagnieren bei konstanten Raten.

Am Fuße der Tafel erscheinen einige aufaggregierte oder umskalierte Größen. $CD+CNDS+IFE+IFC$ entspricht dabei etwa einer realen Inlandsnachfrage. Diese wächst mit Raten unter 1%.

3.4 Robustifizierung der Prognose

Wie bereits in 3.1 erwähnt, ist ein ZMES in seiner Grundkonzeption starr, d.h. es wird vorausgesetzt, daß sich das Verhalten des Systems im Zeitverlauf nicht ändert. Weisen demgemäß die errechneten Residuen Schwankungen auf, die sich mit der Annahme des (im Extremfall normalverteilten) white noise schlecht vereinbaren lassen, so wird man nicht folgern, das System habe sich geändert oder laufe in mehreren Regimes, sondern eher, die stochastischen Annahmen über die Störungen seien revisionsbedürftig, nicht jedoch die Basisannahme des white noise. Diesen Weg beschreiten die Ausreißermodelle.

Eines der gebräuchlichsten Ausreißermodelle ist das additive outliers-Modell (AO), wie es etwa bei Kleiner, Martin & Thomson (1977) dargelegt wird. Dabei wird unterstellt, daß sich eine beobachtete Variable y_t von der Trendvariable y_t^* unterscheidet, die ihrerseits einem regulären, etwa autoregressiven Prozeß gehorcht.

$$(AO) \quad y_t = y_t^* + f_t$$
$$A(L)y_t^* = e_t$$

Für die Verteilung der (f_t) wird i.a. eine Mischverteilung unterstellt, die mit hoher Wahrscheinlichkeit (z.B. 90%) in 0 konzentriert ist und sonst aus einer Verteilung mit großer Streuung erwächst. Kleiner et al. bringen Beispiele für AO-Modelle in der Anwendung, die auch auf ökonomische Systeme übertragbar sein könnten.

Für den Fall der AO-Modelle präsentieren Kleiner et al. ein robustes Glättungsverfahren (robust filtering), welches vom Autor am IHS implementiert wurde (für eine Beschreibung siehe Bomze, Kunst & Reschenhofer (1983)). Dabei werden iterativ mit hoher Wahrscheinlichkeit "falsche" Daten durch gewichtete Mittel aus Daten und Prognosewerten ersetzt und anschließend neue Koeffizientenschätzer gewonnen.

Dieses Programm METH wurde nun auf den dauerhaften Konsum (CD) bis 1982.4, also bis vor Beginn der vermuteten Störungen, angewendet. Anschließend wurden Werte bis 1990.4 mittels Fortschreibung mit Nullresiduen prognostiziert. Dabei liegt der letzte vom Programm als Ausreißer erkannte Wert relativ weit zurück (4.Quartal 1980), sodaß von einer verlässlichen Prognosebasis ausgegangen werden konnte. Die Werte für CD wurden sodann nicht mehr angetastet, d.h. von ihrer Reaktion auf andere Variablen entkoppelt.

Tafel 4 zeigt das Ergebnis der robusten univariaten Prognose für CD in Verbindung mit der Reaktion des restlichen, aus 3.3 übernommenen Modells. CD wächst jetzt ruhig mit Zuwachsraten um die 3.5%. Stärkere Reaktionen auf diese Änderung sind im Bereich des Mechanismus CD/X24/M24 zu erkennen, während ein Durchschlagen auf die Investitions- und Preisgrößen unterbleibt. Die Änderungen der relativen Differenzen bei den Außenhandelsdaten bezüglich Rohstoffe und Energie bewegen sich zwischen .5% und 1.8% (positiv!).

ZEITREIHENPROGNOSE MIT ROBUST GEFILTERTEM DAUERHAFTEN KONSUM

LABEL	I	1983	1984	1985	1986	1987	1988	1989	1990
CD	I	62.075	56.463	59.232	61.319	63.349	65.542	67.802	70.103
	I	15.3%	-9.0%	4.9%	3.5%	3.3%	3.5%	3.4%	3.4%
CNDS	I	421.528	427.614	435.813	445.853	454.424	464.235	473.639	483.535
	I	3.6%	1.4%	1.9%	2.3%	1.9%	2.2%	2.0%	2.1%
IFE	I	80.910	84.805	83.960	85.830	86.021	87.295	87.939	88.984
	I	-3.2%	4.8%	-1.0%	2.2%	.2%	1.5%	.7%	1.2%
IFC	I	93.678	91.828	87.689	83.775	80.433	77.036	73.742	70.682
	I	-.5%	-2.0%	-4.5%	-4.5%	-4.0%	-4.2%	-4.3%	-4.1%
X01	I	12.323	13.665	13.932	14.825	15.500	16.218	17.137	17.843
	I	1.6%	10.9%	2.0%	6.4%	4.5%	4.6%	5.7%	4.1%
X24	I	22.444	25.499	24.635	25.604	26.115	26.710	27.167	27.850
	I	2.9%	13.6%	-3.4%	3.9%	2.0%	2.3%	1.7%	2.5%
X59	I	242.373	274.010	299.529	329.912	362.178	400.038	438.001	483.437
	I	4.1%	13.1%	9.3%	10.1%	9.8%	10.5%	9.5%	10.4%
M01	I	21.369	23.469	25.070	27.529	29.602	32.295	34.903	37.936
	I	2.8%	9.8%	6.8%	9.8%	7.5%	9.1%	8.1%	8.7%
M24	I	70.534	87.272	96.330	109.270	124.036	141.322	159.411	181.391
	I	-8.2%	23.7%	10.4%	13.4%	13.5%	13.9%	12.8%	13.8%
M59	I	256.436	286.938	312.649	338.691	369.835	403.240	437.833	477.965
	I	9.2%	11.9%	9.0%	8.3%	9.2%	9.0%	8.6%	9.2%
PGDP	I	142.775	149.159	155.667	162.331	169.326	176.617	184.226	192.163
	I	3.8%	4.5%	4.4%	4.3%	4.3%	4.3%	4.3%	4.3%
RSECL	I	8.090	8.495	8.565	8.376	8.410	8.437	8.429	8.422
	I	-17.2%	5.0%	.8%	-2.2%	.4%	.3%	-.1%	-.1%

3.5 Ausblick

Das vorliegende Modell versteht sich als ein erster Schritt zur Erstellung eines umfassenderen Zeitreihenmodells zur Prognose der österreichischen Wirtschaft. Das Modell ist sowohl in seiner Dimension ausbaubar, etwa durch Hinzunahme von Preis- oder Arbeitsmarktvariablen, als auch in seiner Methodik verbesserungsfähig. Im Zusammenhang mit starker Ausreißerbelastung einiger Variablen erschiene eine weitergehende Verwendung robuster Methoden zweckmäßig. In ein Übergehen zu Systemschätzung setzt der Autor demgegenüber keine besonderen Erwartungen, zumal auch eine stichprobenweise Überprüfung der Fehlerkorrelation nur geringe Werte produzierte.

Zweck der Zeitreihenprognose kann sowohl die Kontrolle eines ÖMES durch ein mechanistisches Modell sein, das Grundstrukturen besser abschöpft, als auch die Erstellung eines Hybridmodells, in welchem exogene Variable eines ÖMES zeitreihenmäßig fortgeschrieben werden.

LITERATUR

- BOMZE, E., R.M. KUNST, E. RESCHENHOFER (1983). Über die Schätzung von Spektraldichten. Forschungsbericht Nr. 184. Wien, Institut für Höhere Studien.
- BOX, G.E.P., G.M. JENKINS (1976). Time Series Analysis: Forecasting and Control. Revised Edition. San Francisco: Holden-Day.
- FLORENS, J.P., M. MOUCHART (1985). A Linear Theory for Noncausality. *Econometrica* 53, 157-175.
- GEWEKE, J. (1982). Measurement of Linear Dependence and Feedback between Time Series. *Journal of the American Statistical Association* 77, 304-324.
- GRANGER, C.W.J. (1969). Investigating Causal Relations by Econometric Models and Cross-Spectral Methods. *Econometrica* 37, 424-438.
- HANNAN, E.J. (1970). Multiple Time Series. New York: John Wiley.
- INSTITUT FÜR HÖHERE STUDIEN. (1984). Prognose der österreichischen Wirtschaft. Institutsarbeit Nr. 218. Wien, Institut für Höhere Studien.
- KLEINER, B., R.D.MARTIN, D.J. THOMSON (1979). Robust Estimation of Power Spectra. *Journal of Royal Statistical Society B* 41, 313-351.
- PIERCE, D.A., L.D. HAUGH (1977). Causality in Temporal Systems. *Journal of Econometrics* 5, 265-293.
- SIMS, C.A. (1972). Money, Income, and Causality. *American Economic Review* 62, 540-552.